



TESIS - EE185401

**KLASIFIKASI SINYAL *EEG* UNTUK MENDETEKSI
CYBERSICKNESS MELALUI *TIME DOMAIN*
FEATURE EXTRACTION MENGGUNAKAN
*NAÏVE BAYES***

MOCHAMMAD ASYROFUL MAWALID
07111550052005

DOSEN PEMBIMBING

Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.
Dr. Adhi Dharma Wibawa, S.T., M.T.

PROGRAM MAGISTER

BIDANG KEAHLIAN JARINGAN CERDAS MULTIMEDIA

DEPARTEMEN TEKNIK ELEKTRO

FAKULTAS TEKNOLOGI ELEKTRO

INSTITUT TEKNOLOGI SEPULUH NOPEMBER

SURABAYA

2019



TESIS - EE185401

**KLASIFIKASI SINYAL *EEG* UNTUK MENDETEKSI
CYBERSICKNESS MELALUI *TIME DOMAIN*
FEATURE EXTRACTION MENGGUNAKAN
*NAÏVE BAYES***

MOCHAMMAD ASYROFUL MAWALID
07111550052005

DOSEN PEMBIMBING
Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.
Dr. Adhi Dharma Wibawa, S.T., M.T.

PROGRAM MAGISTER
BIDANG KEAHLIAN JARINGAN CERDAS MULTIMEDIA
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI ELEKTRO
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2019

LEMBAR PENGESAHAN

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Teknik (M.T.)
di
Institut Teknologi Sepuluh Nopember

oleh:

Mochammad Asyroful Mawalid
NRP. 07111550052005

Tanggal Ujian : 21 Desember 2018
Periode Wisuda : Maret 2019

Disetujui oleh:


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


2. Dr. Adhi Dharma Wibawa, S.T., M.T. (Pembimbing II)
NIP: 197605052008121003


3. Dr. I Ketut Eddy Purnama, S.T., M.T. (Penguji I)
NIP: 196907301995121001


4. Dr. Eko Mulyanto Yuniarno, S.T., M.T. (Penguji II)
NIP: 196806011995121009



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 “**KLASIFIKASI SINYAL EEG UNTUK MENDETEKSI CYBERSICKNESS MELALUI TIME DOMAIN FEATURE EXTRACTION MENGGUNAKAN NAÏVE BAYES**” 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, 21 Desember 2018



Mochammad Asyroful Mawalid

NRP. 07111550052005

Halaman ini sengaja dikosongkan

KLASIFIKASI SINYAL *EEG* UNTUK MENDETEKSI *CYBERSICKNESS* MELALUI *TIME DOMAIN FEATURE EXTRACTION* MENGGUNAKAN *NAÏVE BAYES*

Nama mahasiswa : Mochammad Asyroful Mawalid
NRP : 07111550052005
Pembimbing : 1. Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.
2. Dr. Adhi Dharma Wibawa, S.T., M.T.

ABSTRAK

Baru-baru ini, perkembangan pesat dalam hiburan seperti film 3D dan video game, menyebabkan fenomena cybersickness menjadi topik yang sangat serius di kalangan ahli kesehatan. Cybersickness terjadi ketika eksposur manusia di lingkungan virtual sehingga dapat menyebabkan efek negatif seperti sakit kepala, kelelahan, kelelahan mata dan muntah. Ini dapat mengganggu fisik dan fisiologis manusia jika tidak diminimalkan dengan benar. Banyak penelitian telah dilakukan untuk menyelidiki cybersickness menggunakan beberapa metode. Salah satu metode yang paling umum adalah menggunakan Electroencephalograph (EEG). Namun, sebelumnya tidak banyak penelitian yang mengeksplorasi ekstraksi fitur domain waktu dalam menyelidiki cybersickness. Dalam tulisan ini, Sembilan peserta sehat (7 pria dan 2 wanita) diukur menggunakan EEG selama bermain video game 3D. Ekstraksi fitur domain waktu, seperti fitur statistik (misalnya, rata-rata, variasi, deviasi standar, jumlah puncak) dan pita persentase daya diterapkan untuk mengenali cybersickness. Pita frekuensi alfa (α) dan beta (β) diekstrak untuk semua saluran. Kemudian, kami melakukan seleksi fitur untuk meningkatkan kinerja pengenalan cybersickness menggunakan K-Nearest Neighbor dan Naïve Bayes *classifier*. Kami mengklasifikasikan hasil ekstraksi fitur untuk menyelidiki gejala cybersickness atau tidak. Menurut penelitian kami, penggunaan tiga ekstraksi fitur (yaitu varian, standar deviasi, dan jumlah puncak) adalah fitur terbaik untuk pengenalan cybersickness. Akurasi adalah 83,8% menggunakan penggolongan Naïve Bayes. Hasil ini dapat meningkatkan akurasi sebesar 6% dibandingkan dengan yang menggunakan lima ekstraksi fitur.

Kata kunci: *Cybersickness, Naïve Bayes, Time Domain Feature Extraction*

Halaman ini sengaja dikosongkan

CLASSIFICATION OF EEG SIGNAL FOR DETECTING CYBERSICKNESS THROUGH TIME DOMAIN FEATURE EXTRACTION USING NAÏVE BAYE

By : Mochammad Asyroful Mawalid
Student Identity Number : 07111550052005
Supervisor(s) : 1. Prof. Dr. Ir. Mauridhi Hery P., M.Eng.
2. Dr. Adhi Dharma Wibawa, S.T., M.T.

ABSTRACT

Recently, the rapid developments in entertainment such as 3D movies and video *games*, causing the phenomenon of *cybersickness* to be a very serious topic among health experts. Cybersickness occurs when the human exposure in virtual environment so that it can cause negative effect like headache, fatigue, eyestrain and vomiting. It can disturb the physical and physiological of the human if it is not minimized properly. Many studies have been done to investigate cybersickness using several methods. One of the most common method is using Electroencephalograph (EEG). However, previously there were not many studies that explored time domain feature extraction in investigating cybersickness. In this paper, Nine healthy participants (7 male and 2 female) were measured using EEG during playing 3D video game. Time domain feature extraction, such as statistical features (e.g., mean, variation, standard deviation, number of peak) and power percentage band were implemented to recognize cybersickness. The frequency band alpha (α) and beta (β) was extracted for all channels. Then, we do the feature selection to improve the performance of cybersickness recognition using K-Nearest Neighbor and Naïve Bayes classifier. We classified the result of feature extraction in order to investigate cybersickness symptoms or not. According to our research, the use of three feature extractions (i.e., variant, standard deviation, and number of peak) are the best feature for cybersickness recognition. The accuracy was 83,8% using Naïve Bayes classifier. This result could improve the accuracy by 6% compared with the one that using five feature extractions.

Key words: *Cybersickness, Naïve Bayes, Time Domain Feature Extraction*

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Alhamdulillah, segala puji bagi Allah SWT, yang telah melimpahkan rahmat dan hidayah-Nya sehingga penulis bias menyelesaikan Tesis yang berjudul “Klasifikasi Sinyal EEG untuk Mendeteksi Cybersickness Senang melalui *Time Domain Feature Extraction* menggunakan *Naïve Bayes*” sesuai dengan yang diharapkan.

Pengerjaan Tesis ini merupakan suatu kesempatan yang sangat berharga bagi penulis, Karena dengan mengerjakan Tesis ini, penulis dapat meningkatkan dan mengimplementasikan apa yang telah didapatkan penulis selama menempuh perkuliahan Program Magister di Pascasarjana Teknik Elektro ITS.

Penyelesaian buku Tesis ini tidak terlepas dari bantuan dan dukungan semua pihak. Oleh karenanya, penulis ingin menyampaikan rasa terima kasih yang sebesar-besarnya kepada:

1. Allah SWT. atas limpahan rahmat-Nya sehingga penulis dapat menyelesaikan Tesis ini dengan baik.
2. Kedua orang tua H. Moch Nadjib Widjaja, S.H. dan drg. Hj. Silfia Rachmi, M.M. selaku kedua orangtua kandung
3. Kedua orang tua istri tercinta Drs. H. Achmad Dawam, M.Kes. dan (alm) Hj. Nurul Maghfiroh, S.H. selaku mertua.
4. Istri tercinta Bintana Afiati, S.Pd., M.Pd. yang selalu menemani penulis di dalam mengerjakan buku.
5. Prof. Joni Hermana, M.Sc.Es., Ph.D., sebagai rektor ITS periode 2015-2019.
6. Dr. Tri Arief Sardjono, S.T., M.T., sebagai Dekan Fakultas Teknologi Elektro dan Dr. Ir. Suwadi, S.T., M.T., selaku Wakil Dekan Fakultas Teknologi Elektro periode pengangkatan tahun 2017.
7. Dr. Eng. Ardyono Priyadi, S.T., M.Eng., selaku Kepala Departemen Teknik Elektro.
8. Dr. Ir. Wirawan, D.E.A., selaku Kepala Program Pascasarjana Departemen Teknik Elektro.

9. Dr. Trihastuti Agustinah, S.T., M.T., selaku Sekretaris Program Pascasarjana S2 Departemen Teknik Elektro.
10. Dr. Eko Mulyanto Yuniarno, S.T., M.T., selaku Ketua Program Studi S2 Jaringan Cerdas Multimedia.
11. Dr. Supeno Mardi Susiki Nugroho, S.T., M.T., selaku dosen wali selama di kampus ITS.
12. Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng., selaku dosen pembimbing pertama dan Dr. Adhi Dharma Wibawa, S.T., M.T., selaku dosen pembimbing kedua.
13. Prof. Dr. Ir. Yoyon Kusnendar Suprpto, M.Sc., selaku dosen pengajar mata kuliah Penulisan Ilmiah dan Topik Khusus JCM.
14. Dr. Diah Puspito Wulandari, S.T., M.Sc., selaku dosen mata kuliah Matematika Diskrit dan Teori Graf.
15. Dr. I Ketut Eddy Purnama, S.T., M.T., selaku Ketua Departemen Teknik Komputer dan Ahmad Zaini, S.T., M.T., selaku sekretaris Departemen Teknik Komputer.
16. Mochamad Hariadi, S.T., M.Sc., Ph.D., selaku dosen pengajar mata kuliah Multimedia dan Jaringan serta Streaming Multimedia.
17. Dr. Surya Sumpeno., S.T., M.Sc., selaku dosen pengajar mata kuliah Komputasi Ubiquitous dan Komputer Bergerak.
18. Rekan-rekan Tendik di lingkungan Fakultas Elektro, Mas Hartono, Bu Rani, Mbak Triana, Pak Suparman, Pak Pambudi, Bu Artin, Mas Aris.
19. Teman-teman S2 Jaringan Cerdas Multimedia ITS, mas Prima, Mas Farid, Mas Fadil, Mbak Nanda, Mas Adi, Mas Afif, Mas Medi dan Wega yang bersama-sama masuk sebagai mahasiswa di ITS dan berjuang dalam studi ini.
20. Bu Evi Septiana Pane dan Mbak Alfi Zuhriya Khoirunnisa, sebagai pengambil data menggunakan alat emotiv epoch untuk bahan baku berupa dataset publik maupun mandiri dalam pembuatan buku tesis.
21. Dan pihak lainnya yang ikut membantu penulis yang tidak dapat disebutkan satu persatu.

Sebagai manusia biasa, penulis menyadari bahwa Tesis ini masih jauh dari kata sempurna dan memiliki banyak kekurangan. Sehingga dengan segala kerendahan hati, penulis mengharapkan saran dan kritik yang membangun dari pembaca.

Surabaya, 21 Desember 2018

Penulis

Halaman ini sengaja dikosongkan

DAFTAR ISI

LEMBAR PENGESAHAN	iii
PERNYATAAN KEASLIAN TESIS.....	v
ABSTRAK.....	vii
ABSTRACT.....	ix
KATA PENGANTAR	xi
DAFTAR ISI.....	xv
DAFTAR GAMBAR.....	xix
DAFTAR TABEL.....	xxi
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	11
1.3 Tujuan.....	11
1.4 Batasan Masalah	11
1.5 Kontribusi	12
1.6 Metodologi Penelitian.....	12
BAB 2 KAJIAN PUSTAKA	13
2.1 Sejarah Awal dari EEG.....	13
2.2 Electroencephalograph	16
2.3 Teori Dasar tentang Cybersickness	19
2.3.1 Konsekuensi dan Implikasi Cybersickness.....	19
2.3.2 Analisis Sistem Vestibular dan Visual.....	20
2.3.3 Sistem Vestibular	20
2.3.4 Persepsi Visual Gerak Diri.....	22
2.3.5 Hubungan antara Sistem Vestibular dan Visual	23
2.3.6 Teori Cybersickness.....	23
2.4 Dasar Pembagian Sinyal EEG	28
2.4.1 Artefact Removal pada sinyal EEG	30
2.5 Ekstraksi dan Seleksi Fitur	31

2.5.1	Fitur Mean.....	32
2.5.2	Fitur Varian.....	32
2.5.3	Fitur Standard Deviasi	32
2.5.4	Fitur Power Percentage.....	33
2.5.5	Fitur Number of Peaks.....	33
2.6	Metode Klasifikasi.....	34
2.6.1	K-NN.....	35
2.6.2	Naïve Bayes	36
2.7	Validitas Stimulus.....	37
BAB 3 METODOLOGI PENELITIAN		41
3.1	Tahapan Penelitian.....	41
3.2	Studi Pustaka	42
3.3	Perancangan Algoritma	42
3.3.1	Pemahaman Dataset.....	44
3.3.2	Proses filtering menggunakan Independent Component Analyst.....	46
3.4	Pra-pemrosesan Data	47
3.4.1	Pelabelan Data	47
3.4.2	Segmentasi Data.....	48
3.4.3	Band Pass Filter	48
3.5	Ekstraksi Fitur.....	49
3.5.1	Fitur Mean.....	49
3.5.2	Fitur Varian.....	49
3.5.3	Fitur Standard Deviasi	50
3.5.4	Fitur Power Percentage.....	50
3.5.5	Fitur Number of Peaks.....	51
3.6	Klasifikasi	51
3.6.1	K-NN.....	52
3.6.2	Naïve Bayes	53
3.7	Visualisasi.....	53
BAB 4 HASIL DAN PEMBAHASAN		57
4.1	Pra-pemrosesan Data	57
4.1.1	Artefact Removal.....	57

4.1.2	Segmentasi Data.....	58
4.1.3	Band Pass Filter	58
4.2	Ekstraksi Fitur.....	58
4.2.1	Fitur Mean.....	59
4.2.2	Fitur Varian.....	60
4.2.3	Fitur Standard Deviasi	61
4.2.4	Fitur Power Percentage	63
4.2.5	Fitur Number of Peaks	64
4.3	Metode Klasifikasi.....	65
4.3.1	K-NN.....	66
4.3.2	Naïve Bayes	69
4.4	Visualisasi.....	70
BAB 5 KESIMPULAN		81
5.1	Kesimpulan.....	81
5.2	Saran	81
DAFTAR PUSTAKA		83
INDEX		87
BIODATA.....		89

Halaman ini sengaja dikosongkan

DAFTAR GAMBAR

Gambar 1.1	Pemeran utama dalam bermain Game Mirror's Edge	2
Gambar 1.2	Stimulus yang digunakan adalah bermain Game Mirror's Edge.....	2
Gambar 1.3	Perilaku positif dan biologis mempengaruhi timbulnya penyakit	3
Gambar 1.4	Pemodelan pengaruh positif dapat menyangga efek stress.....	8
Gambar 2.1	Perangkat pertama EEG portable didesain Franklin Offner 1950's ..	15
Gambar 2.2	Proses perekaman EEG kondisi <i>baseline</i>	17
Gambar 2.3	Posisi 14 kanal sesuai dataset.....	18
Gambar 2.4	Kuadran valence arousal	19
Gambar 2.5	Vestibular sistem dan Semisirkular kanal	21
Gambar 2.6	Horizontal Semisirkular Kanal, Medial, Lateral Rektus dan Mata...	24
Gambar 2.7	Sistem Peletakan Elektrode 10-20	28
Gambar 2.8	Sinyal Delta.....	28
Gambar 2.9	Sinyal Theta	29
Gambar 2.10	Sinyal Alpha.....	29
Gambar 2.11	Sinyal Beta	30
Gambar 2.12	(a) Skema dekomposisi discrete wavelet (b) rekonstruksi wavelet	31
Gambar 2.13	(a) k=1 (b) k=2 (c) k=3-nearest neighbor	35
Gambar 3.1	Tahapan Metodologi Penelitian	41
Gambar 3.2	Diagram alur klasifikasi berdasarkan <i>preprocessing</i> dan ekstraksi ..	43
Gambar 3.3	Detail dari skenario game	44
Gambar 3.4	Posisi 14 <i>Channel</i> sesuai alat emotive epoch.....	45
Gambar 3.5	Data Raw sebelum diproses ICA	46
Gambar 3.6	Data EEG setelah diproses ICA	46
Gambar 3.7	Pelabelan baseline dan cybersickness pada data EEG	47
Gambar 3.8	Segmentasi data EEG.....	48
Gambar 3.9	Filter band alfa dan beta data EEG	48
Gambar 3.10	Tahap urutan metode penelitian.....	52
Gambar 3.11	Tujuh tahap visualisasi.....	54
Gambar 4.1	Karakteristik dataset berdasarkan ekstraksi fitur mean.....	60
Gambar 4.2	Karakteristik dataset berdasarkan ekstraksi fitur varian	61
Gambar 4.3	Karakteristik dataset berdasarkan ekstraksi fitur standard deviasi ...	62
Gambar 4.4	Karakteristik dataset berdasarkan ekstraksi fitur power percentage..	63
Gambar 4.5	Karakteristik dataset berdasarkan ekstraksi fitur number of peaks...	64
Gambar 4.6	Akurasi K-NN data train 60% dan test 40% berdasarkan nilai-k	66
Gambar 4.7	Akurasi K-NN data train 70% dan test 30% berdasarkan nilai-k	67
Gambar 4.8	Akurasi K-NN berdasarkan kombinasi kelima fitur	68
Gambar 4.9	Akurasi Naïve Bayes berdasarkan kombinasi kelima fitur.....	69
Gambar 4.10	Visualisasi fitur mean kanal AF3 kondisi baseline.....	70
Gambar 4.11	Visualisasi fitur mean kanal AF3 kondisi cybersickness.....	70

Gambar 4.12 Visualisasi fitur varian kanal AF3 kondisi baseline.....	72
Gambar 4.13 Visualisasi fitur varian kanal AF3 kondisi cybersickness	72
Gambar 4.14 Visualisasi fitur std. deviasi kanal AF3 kondisi baseline.....	74
Gambar 4.15 Visualisasi fitur std. deviasi kanal AF3 kondisi cybersickness	74
Gambar 4.16 Visualisasi fitur pow. percentage kanal AF3 kondisi baseline	76
Gambar 4.17 Visualisasi fitur pow. percent. kanal AF3 kondisi cybersickness...	76
Gambar 4.18 Visualisasi fitur numb. of peaks kanal AF3 kondisi baseline	78
Gambar 4.19 Visualisasi fitur numb. of peaks kanal AF3 kondisi cybersickness	78

DAFTAR TABEL

Tabel 2.1 Contoh Tabel Frekuensi Naive Bayes	36
Tabel 2.2 Contoh Tabel Likelihood Naïve Bayes.....	36
Tabel 2.3 Kuesioner berdasarkan tingkat keparahan gejala cybersickness	37
Tabel 2.4 Kuesioner gejala cybersickness berdasarkan pengelompokan	38
Tabel 3.1 Karakteristik dataset berdasarkan ukuran dan deskripsi.....	44
Tabel 4.1 Karakteristik dataset berdasarkan ekstraksi fitur mean	59
Tabel 4.2 Karakteristik dataset berdasarkan ekstraksi fitur varian	60
Tabel 4.3 Karakteristik dataset berdasarkan ekstraksi fitur standard deviasi	62
Tabel 4.4 Karakteristik dataset berdasarkan ekstraksi fitur power percentage.....	63
Tabel 4.5 Karakteristik dataset berdasarkan ekstraksi fitur number of peaks	64
Tabel 4.6 Akurasi <i>classifier</i> K-NN data train 60% test 40% berdasarkan nilai-k .	66
Tabel 4.7 Akurasi <i>classifier</i> K-NN data train 70% test 30% berdasarkan nilai-k .	67
Tabel 4.8 Akurasi Klasifikasi K-NN melalui Seleksi Fitur	68
Tabel 4.9 Akurasi Klasifikasi Naïve Bayes melalui Seleksi Fitur.....	69
Tabel 4.10 Visualisasi fitur mean seluruh kanal dan semua partisipan	71
Tabel 4.11 Visualisasi fitur varian seluruh kanal dan semua partisipan.....	73
Tabel 4.12 Visualisasi fitur std. deviasi seluruh kanal dan semua partisipan.....	75
Tabel 4.13 Visualisasi fitur pow. percentage seluruh kanal di semua partisipan ..	77
Tabel 4.14 Visualisasi fitur numb. of peaks seluruh channel di semua partisipan	79

Halaman ini sengaja dikosongkan

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Pada era modern saat ini, kesehatan adalah yang paling utama. Segala sesuatu tidak akan dapat dilakukan jikalau kesehatan kita terganggu. Untuk mengantisipasi masalah tersebut, perlu diadakan penelitian mengenai gangguan kesehatan, salah satu contoh pada penelitian ini adalah gangguan akibat bermain permainan pada gawai (*cybersickness*) atau *Digital Motion Sickness* (DMS).

Cybersickness adalah mengalami mabuk perjalanan (*kinetosis*) karena sensor pada otot dan dalam telinga kita mengalami sensasi adanya gerakan, misalnya ketika kita berada di kapal laut, namun mata kita tidak melihat ‘gerakan’ itu, karena kita berada di dalam kabin. Kebalikannya adalah pada Cybersickness dimana, mata kita melihat gambar yang bergerak dengan cepat pada layar komputer atau gadget, namun tubuh kita tidak merasakan adanya gerakan tersebut.

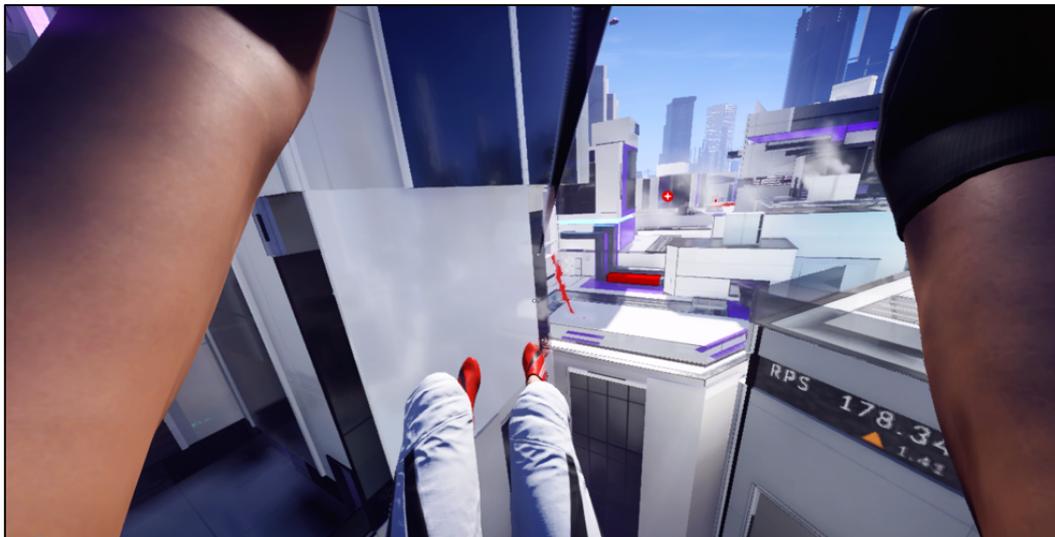
Definisi Cybersickness secara ilmiah yaitu terjadinya konflik persepsi antara mata (visual), sensor dalam telinga (vestibular) dan sensor dalam otot (propioceptive), hal tersebut menimbulkan respon dari tubuh (otak) dengan timbulnya gejala-gejala cybersickness. (LaViola, 2000a). Fenomena *Cybersickness* yang disebabkan karena menonton film 3D dan video game secara berlebihan, memiliki dampak yang buruk bagi masyarakat ketika bermain permainan video 3D *Mirror’s Edge*.

Tema Permainan *Mirror’s Edge* ini adalah *action adventure* dengan tampilan pemeran utamanya, Faith Connors. Faith Connors adalah salah seorang runner yang mempunyai masa lalu yang kelam dimana keluarganya dibunuh. Di scene awal diperlihatkan saat Faith baru keluar dari penjara dan harus membayar hutang dengan cara Faith harus menjadi seorang *runner* di sebuah kota bernama Glass, kota modern di penuh dengan bangunan tinggi dan juga kaca seperti pada Gambar 1.1.



Gambar 1.1 Pemeran utama dalam bermain Game Mirror's Edge

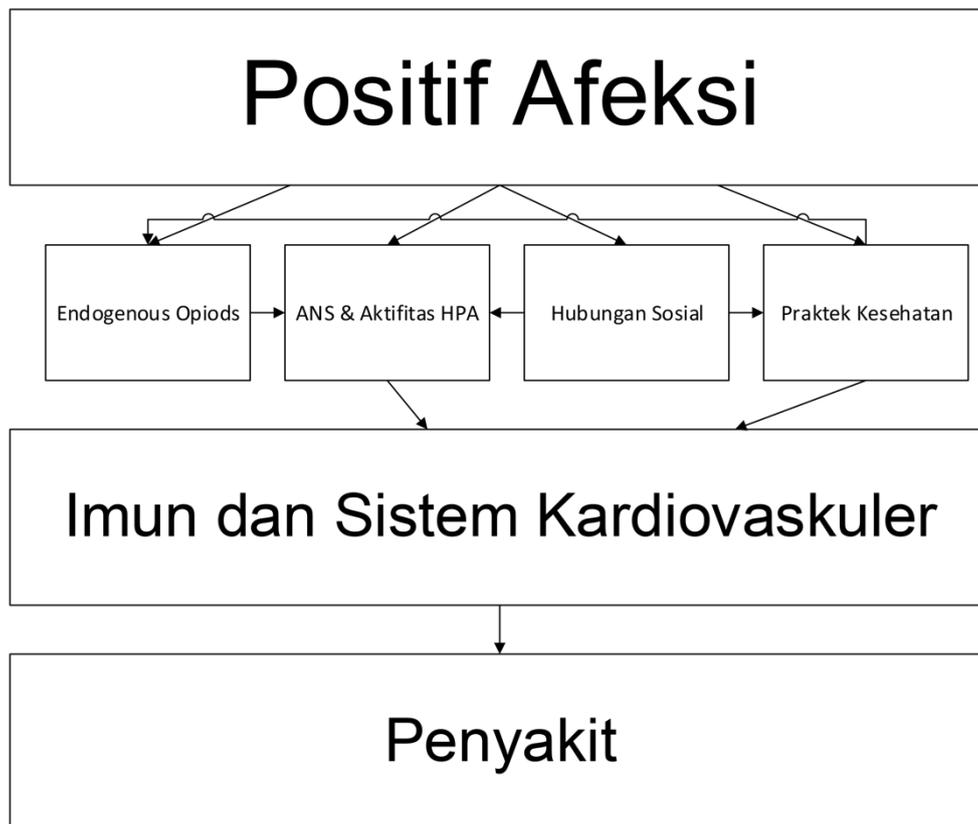
Manusia memiliki kemampuan alami menggunakan semua panca indra mereka dalam menerima pesan dalam keadaan sadar. Melalui pancaindra tersebut, manusia dapat merasakan keadaan psikologi saat mendapatkan sebuah stimulus. Mengenali psikis manusia secara langsung dapat dinilai dari beberapa kriteria seperti ekspresi wajah, suara, atau berupa gerakan tubuh. Kriteria lain dalam mengenali psikis manusia juga dapat didasari oleh data rekaman aktifitas otak manusia atau yang lebih dikenal dengan EEG seperti pada Gambar 1.2.



Gambar 1.2 Stimulus yang digunakan adalah bermain Game Mirror's Edge

Beberapa penelitian (Pressman and Cohen, 2005) telah meneliti apakah PA mengurangi reaksi alergi (ukuran wheal pada hipersensitivitas tipe I) sebagai respons terhadap alergen atau paparan histamin pada peserta alergi. Pengurangan respon alergi ditemukan ketika kesenangan dan relaksasi diinduksi oleh hipnosis (Laidlaw et al., 1996) dan ketika humor diinduksi oleh film. Namun, (Zachariae et al., 2001) gagal menemukan pengaruh kebahagiaan yang diinduksi secara hipnotis (atau kemarahan dan kesedihan) pada respon alergi yang dinilai oleh ukuran wheal.

Dalam studi korelasional, (Laidlaw et al., 1994) menemukan bahwa mereka yang melaporkan lebih banyak keaktifan (bipolar liveliness- faktor tanpa daftar) dan kekuatan memiliki tanggapan alergi yang lebih kecil. Mereka juga menemukan bahwa keaktifan dan kekuatan yang lebih besar dikaitkan dengan tanggapan yang lebih rendah terhadap konsentrasi alergen yang lebih tinggi. Perasaan kedamaian dinilai pada awal (pada skala damai-iritasi bipolar) yang terkait dengan kurang reaktivitas kulit di (Laidlaw et al., 1996) studi yang dijelaskan sebelumnya seperti pada Gambar 1.3.



Gambar 1.3 Perilaku positif dan biologis mempengaruhi timbulnya penyakit

Keterangan:**ANS:** Autonomic Nervous System**HPA:** Hipotalamus Pituitary Adrenal**Endogenous Opioids:** sistem penghilang rasa sakit bawaan yang banyak dipelajari

Singkatnya, induksi PA di laboratorium umumnya dikaitkan dengan perubahan kuantitatif dan kualitatif akut dalam respon imun. Implikasi sebagian besar perubahan untuk kesehatan ini tidak jelas. Namun, kemampuan untuk menghasilkan tanggapan ini dipandang sebagai adaptif. Bagaimanapun PA terinduksi ini terkait dengan hasil imun yang lebih dapat diinterpretasi, respon alergi kulit yang lebih rendah. Ada juga bukti dari studi lapangan bahwa kedua sifat antara PA terkait dengan tingkat SIgA (Secretory Immunoglobulin A) yang tinggi, meskipun hanya ada penelitian yang mengecilkan hubungan PA dan hasil kekebalan lainnya dalam lingkungan naturalistik.

Studi-studi yang telah kami ulas umumnya bersifat teoritis dalam pendekatan ini. Alasan mereka untuk menggunakan langkah-langkah tertentu, atau menggunakan sifat mempengaruhi tindakan, tidak ditentukan, dan mekanisme yang mungkin melalui PA akan berada di bawah kulit umumnya tidak disuntikkan dan belum teruji. Untuk membantu menyediakan kerangka kerja untuk memahami literatur ini dan untuk merencanakan studi masa depan, kami mengusulkan dua model yang mewakili jalur yang masuk akal yang menghubungkan PA dengan hasil kesehatan. Mekanisme yang kami usulkan dimaksudkan dapat bersifat umum dan berpotensi mencakup insiden penyakit (onset), kekambuhan, keparahan, dan pemulihan. Yang pertama membahas efek langsung dari PA pada perilaku dan sistem fisiologis. Yang kedua mengusulkan bahwa itu adalah tekanan psikologis yang memicu respon perilaku dan fisiologis yang bertentangan dengan kesehatan, dan PA mempengaruhi kesehatan karena membantu orang-orang dalam mengatasi peristiwa-peristiwa stres (penyangga stres). Model yang kami sajikan menunjukkan jalur yang bergerak hanya ke satu arah kausal, dari PA ke kesehatan. Jalur alternatif dikesampingkan demi kesederhanaan. Pengecualian mereka tidak dimaksudkan untuk menyiratkan hipotesis tentang keberadaan mereka.

Secara umum, model efek utama paling sesuai dengan gagasan itu adalah sifat PA yang mempengaruhi hasil kesehatan. Ini karena psikis harus bertahan cukup lama untuk mempengaruhi perilaku mediasi yang diusulkan atau respons fisiologis dengan cara yang akan menciptakan risiko jangka panjang. Di sisi lain, dalam membangkitkan pengalaman psikologi yang positif memicu suatu peristiwa dalam proses patologis yang sedang berlangsung, misalnya, asma atau penyakit jantung koroner. Dengan demikian, kami mengharapkan sifat PA dikaitkan dengan hasil kesehatan yang lebih baik, dan PA “menimbulkan” sesuatu yang ekstrem untuk berpotensi dikaitkan dengan pemicu kejadian penyakit yang mendasarinya.

Praktek kesehatan juga dapat secara langsung mempengaruhi kesehatan melalui perubahan dalam praktik kesehatan. Keadaan yang lebih tinggi dan sifat PA telah dikaitkan dengan perilaku yang lebih baik seperti kualitas tidur yang meningkat baik pada sampel yang sehat dan sampel orang dengan narkolepsi (Bardwell et al., 1999), lebih banyak latihan (Ryff et al., 2004), dan lebih banyak asupan zinc diet (Cohen et al., 2003). Namun, satu studi gagal menemukan perbedaan antara praktik kesehatan yang dilaporkan oleh individu yang sangat bahagia dan yang dilaporkan oleh peserta yang kurang bahagia (Diener and Seligman, 2002). Tidur, olahraga, dan diet yang lebih baik semuanya dikaitkan dengan risiko morbiditas dan mortalitas yang lebih rendah (Cohen et al., 1993) dan dengan profil imun dan kardiovaskular yang lebih positif. PA mungkin juga meningkatkan kepatuhan terhadap rejimen medis di antara pasien, mengakibatkan penyakit yang kurang parah, pemulihan lebih cepat, dan kelangsungan hidup lama.

Aktivasi sistem saraf otonom pada PA juga dapat mengubah kerentanan penyakit orang-orang melalui peredam aktivitas SNS (sympathetic nervous system), penurunan HR (*heart rate*), BP (*blood pressure*), dan konsentrasi darah dari hormon epi dan norepi. Bahkan, ulasan kami menyarankan itu (Pedersen and Hoffman-Goetz, 2000; Rod A. Martin, 2002; Wildmann and Niemann, 1986) atau melalui aktivasi psikologi umum (Gerra et al., 1998). Opioid endogen dapat mempengaruhi kesehatan dengan mengurangi aktivitas otonom dan endokrin (DROLET et al., n.d.) yang mungkin menimbulkan risiko bagi kesehatan atau dengan mengubah fungsi kekebalan (McCarthy et al., 2001). Mereka mungkin juga sangat penting dalam

menjelaskan hubungan antara PA dan respon nyeri karena opioid bertindak untuk menumpulkan komponen nyeri afektif yang menyedihkan (DROLET et al., n.d.).

Fungsi kekebalan tubuh. Seperti yang dikaji sebelumnya, PA juga dikaitkan dengan perubahan fungsi kekebalan tubuh, jalur lain yang potensial menuju kesehatan, meskipun sifat hubungan yang tepat tidak sepenuhnya jelas dari literatur. PA terinduksi secara umum menyebabkan perubahan dalam sel darah putih yang bersirkulasi dan naik dalam antibodi SIgA yang sama dengan yang ditemukan sebagai respons terhadap stress di laboratorium, yang menunjukkan efek yang terkait dengan gairah umum. Namun, ada efek lain yang diinduksi PA yang bersifat provokatif, termasuk pengurangan respons alergi, dan berkurangnya respon inflamasi pada pasien.

Dari faktor sosial dan juga studi komunitas prospektif menemukan bahwa isolasi sosial dikaitkan dengan peningkatan risiko morbiditas dan mortalitas serta bahwa peningkatan keterlibatan dalam aktivitas jaringan sosial dapat dikaitkan dengan penurunan risiko (Cohen, 2004). Selain itu, dukungan sosial bermanfaat untuk kelangsungan hidup dari penyakit yang mengancam jiwa (Berkman, 1995; Seeman, 1996) dan dikaitkan dengan peningkatan hasil kekebalan tubuh (Cacioppo and Kiecolt-Glaser, n.d.; Cohen, n.d.). Kami percaya bahwa satu jalur utama dimana sifat PA dapat memengaruhi kesehatan yang baik adalah melalui jejaring sosial seseorang dan manfaat kesehatan yang terkait dengannya. Orang yang melaporkan lebih banyak PA bersosialisasi lebih sering dan mempertahankan ikatan sosial yang lebih tinggi dan lebih berkualitas (Berry et al., 2000; Diener and Seligman, 2002; Lyubomirsky et al., 2005; Nelson, 1990). PA dapat menghasilkan kontak sosial yang lebih banyak dan lebih dekat karena PA memfasilitasi perilaku pendekatan (Davidson, 1992) juga karena orang lain tertarik untuk membentuk lampiran dengan individu yang menyenangkan.

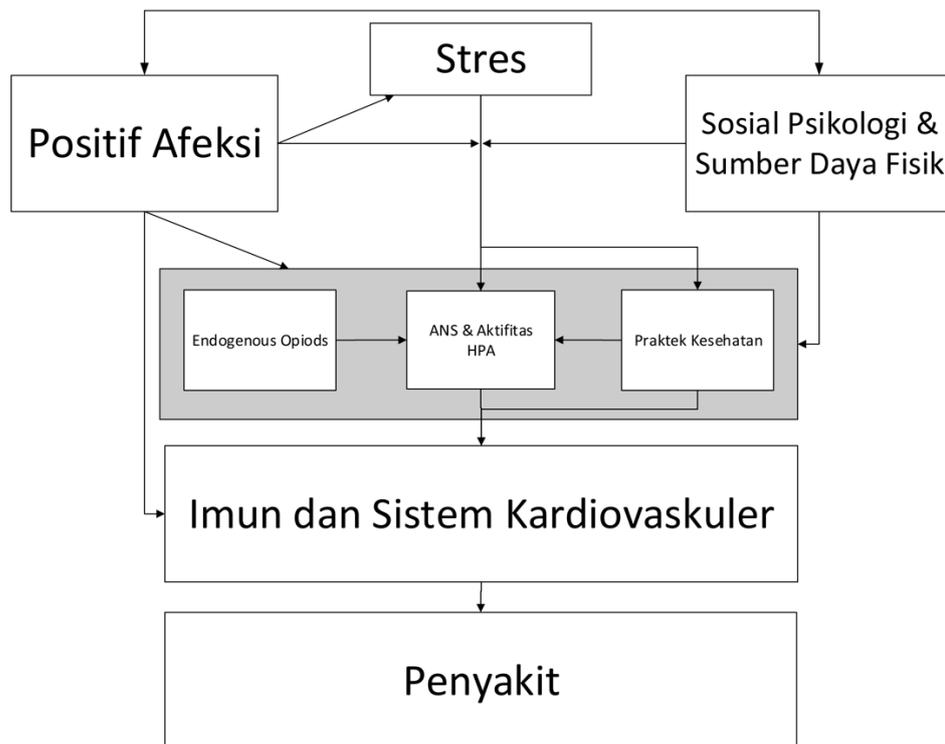
Sebagai alternatif untuk model efek langsung, PA dapat mempengaruhi kesehatan terutama melalui kemampuannya untuk memperbaiki pengaruh potensial patogenik dari peristiwa kehidupan yang membuat stres. Hipotesis ini konsisten dengan (Fredrickson, n.d.) "memperluas dan membangun" teori psikis positif. Dia menyarankan bahwa psikologi positif mendorong eksplorasi dan kreativitas dan menghasilkan pembangunan sumber daya sosial, intelektual, dan fisik melalui

interaksi dan eksplorasi (misalnya, permainan remaja) dengan memperluas kecenderungan aksi. Demikian pula, (Salovey et al., 2000) menyatakan bahwa psikis positif menghasilkan sumber daya psikologis dengan mendorong ketahanan, dan optimisme. Meskipun psikologi positif itu sendiri mungkin berumur pendek, sumber daya ini tahan lama dan dapat ditarik pada saat-saat berkebutuhan, misalnya, ketika seseorang ditantang oleh peristiwa-peristiwa yang menimbulkan stres. Keberadaan sumber daya ini harus memfasilitasi perlindungan dari ketahanan psikologis. Selain itu, ada bukti bahwa PA dikaitkan dengan pemecahan masalah yang lebih kreatif (Ashby and Isen, n.d.), yang mungkin juga mengatasi stres lebih cepat dan menghasilkan manfaat kesehatan.

Sebagai alternatif, sebuah penelitian mengemukakan bahwa PA dapat mendorong kegiatan restoratif seperti tidur, olahraga, relaks, liburan, dan menghabiskan waktu di lingkungan alam. Pada gilirannya, kegiatan ini dianggap membantu mengurangi baik penilaian stres maupun tanggapan afektif negatif terhadap stres. Mereka juga berpendapat bahwa psikis positif dapat melindungi orang dari respon negatif terhadap stres melalui pelepasan opioid endogen. Sebagaimana telah dibahas sebelumnya, opioid endogen mengurangi respons otonom dan endokrin yang sering dipicu oleh stres.

Model kami menunjukkan PA memainkan peran penting di beberapa titik dalam respon stres. Pertama-tama, masuk akal bahwa orang-orang yang tinggi PA mengalami lebih sedikit stres di lingkungan mereka. Misalnya, mereka cenderung terlibat dalam konflik sosial. Selain itu, ketika potensi stres yang dihadapi, sumber daya sosial yang terkait dengan PA membantu mengurangi kembali potensi bahaya dan menambah kemampuan yang dirasakan mengatasi tuntutan yang dikenakan.

Alternatifnya, PA dapat memfasilitasi pemulihan dari aktivasi terkait stres. Sampai saat ini, penelitian telah menemukan bahwa merangsang hiburan atau kepuasan dapat menghasilkan stimulus yang penuh tekanan atau ketakutandan tidak benar-benar menunjukkan bahwa PA bermanfaat untuk kesehatan tetapi sebaliknya menunjukkan pandangan yang lebih berbeda tentang kapan PA penting. Pola-pola dalam literatur yang kami sampaikan berikut digunakan oleh fakta bahwa literatur bersifat teoretis dan terdapat kekurangan di beberapa masalah konseptual yang harus diatasi untuk memberikan bukti yang lebih pasti seperti pada Gambar 1.4.



Gambar 1.4 Pemodelan pengaruh positif dapat menyangga efek stress

Pemodelan stres menunjukkan jalur perilaku dan biologis yang menghubungkan stres dengan timbulnya atau perkembangan penyakit yang menunjukkan tempat-tempat dalam proses di mana pengaruh positif (PA) dapat menyangga efek stres. Untuk mempermudah, model menunjukkan jalur bergerak hanya satu arah (penyakit PA). Garis putus-putus menunjukkan jalur berteori tanpa bukti pendukung. Kotak abu-abu terang yang berisi beberapa faktor dengan PA menunjuk ke luar kotak menunjukkan bahwa PA mempengaruhi semua faktor tersebut.

Manusia memiliki kemampuan alami untuk menggunakan semua indera mereka dalam menerima pesan sadar. Melalui indera ini, manusia bisa merasakan keadaan psikis saat mendapat rangsangan. Mengetahui psikologi manusia secara langsung dapat dinilai dari beberapa kriteria seperti ekspresi wajah, suara, atau gerakan tubuh. Kriteria lain dalam mengenali psikis manusia juga bisa berdasarkan pada pencatatan data aktivitas otak manusia atau yang lebih dikenal dengan Electroencephalography. Berdasarkan penelitian (Koelstra et al., 2012), gagasan tentang psikis manusia adalah persepsi sadar atau tidak sadar terhadap suatu benda yang menjadi pemicu proses psikologis berdasarkan kondisi, yang juga sering

dikaitkan dengan mood, kemarahan, kepribadian dan motivasi. Psikologi manusia juga didasarkan pada aspek seperti budaya, lingkungan, jenis kelamin dan umur.

Aktivitas sinyal EEG dianggap mencerminkan opini dan tuntutan psikologi tertentu ditambah dengan kemampuan untuk mengatur psikis berdasarkan seberapa besar efek aktivitas pemberian sinyal otak di otak kiri atau kanan (Dennis and Solomon, 2010). Pengenalan psikis sinyal EEG berdasarkan rekaman sinyal stimulus musikal di daerah dahi dan area Telinga dapat memberikan informasi penting dalam mengidentifikasi psikis manusia, sehingga dapat membangun pencarian sistematis terhadap fitur spesifik psikis dari sinyal EEG dalam dinamika Hubungan antara sinyal EEG dan psikologi manusia, di mana penelitian ini diuji pada klasifikasi yang berbeda (Yuan-Pin Lin et al., 2010).

(Othman et al., 2013) melakukan penelitian berdasarkan sinyal EEG pada anak-anak, hal ini didasarkan pada sulitnya menentukan usia berapa banyak anak yang dapat direkam dengan sinyal EEG. Dalam penelitian ini, dua pendekatan klasifikasi adalah klasifikasi homogen yang mencerminkan kematangan otak anak dan klasifikasi heterogen. Untuk menggeneralisasi psikologi anak-anak dengan menggunakan game. Pengenalan pola cybersickness ini dengan tujuan untuk mengidentifikasi dan mengenali pola sinyal EEG berdasarkan optimalisasi filter hibrida dengan metode Empiris Mode Decomposition (EMD) dan Genetic Algorithms (GA). Dimana IMF terbaik dari metode EMD dipilih dan mengisolasinya menjadi sinyal saringan untuk mendapatkan representasi sinyal EEG berbasis pola psikis, namun penelitian ini bergantung pada fungsi kebugaran Algoritma Genetik yang sama (Petranonakis and Hadjileontiadis, 2010).

Klasifikasi psikis dengan tujuan menghasilkan beberapa kelas yang berbeda seperti rasa jijik, kesenangan, ketakutan, kejutan dan netral maupun lelah bermain game berdasarkan 5 pita frekuensi yang berbeda (alfa, beta, gamma, delta, tetha) dengan transformasi wavelet sebagai analisis sinyal dapat menjelaskan mekanisme dinamis. Perubahan psikis manusia yang mendasari struktur otak, penelitian ini mengalami hambatan dalam menentukan keakuratan pada saluran rendah karena *common centroid* sebagai ambang batas belum hadir dalam menentukan perubahan psikologi (Murugappan and Yaacob, 2011).

Studi lain berdasarkan 5 pita frekuensi adalah (Vijayan et al., 2015). Penelitian ini menggunakan pendekatan ukuran statistik seperti Shannon entropy dan cross-correlation bersamaan dengan model Autoregressive. Entropi memiliki kemampuan untuk memperoleh informasi kandungan kuantum dari sinyal dan hanya $\frac{3}{4}$ dari ukuran sinyal yang di entropi oleh Shannon sehingga diasumsikan ukuran itu mengandung karakteristik psikologi karena ukurannya memiliki nilai entropi maksimum. Metode yang digunakan dalam menganalisis 5 pita frekuensi adalah wavelet decomposition dan metode ini hanya bekerja pada sinyal EEG yang mengandung noise Gaussian.

Pendekatan psikis berdasarkan pengenalan dan klasifikasi oleh (Lahane and Sangaiah, 2015) bertujuan untuk mengekstrak fitur sinyal EEG dan mengoptimalkan penggunaan memori selama proses berlangsung. Proses pertama adalah menganalisa sinyal dengan Independent Component Analysis (ICA) dimana metode ini merupakan analisis statistik untuk membagi data sinyal EEG menjadi beberapa sumber sinyal. Selanjutnya ekstrak fitur menggunakan metode estimasi density kernel dengan parameter (bandwidth) yang juga merupakan perhitungan statistik dalam memperhatikan noise pada sinyal EEG dan kemudian bersihkan noise. Penentuan kernel dan beberapa parameter harus dioptimalkan untuk membangun mesin pembelajaran yang efisien.

Pengenalan pola menggunakan Bayesian Classification dimana penggunaan kekuatan spektrum untuk fitur tanpa prosedur seleksi fitur. Keakuratan metode ini masih sangat bergantung pada tingkat pembelajaran. Hal ini diperlukan untuk menganalisis metode analisis Fourier Transform yang digunakan untuk ekstraksi fitur sinyal EEG dan untuk menentukan fitur berdasarkan koefisien korelasi Pearson (Yoon and Chung, 2013).

Metode Empirical Mode Decomposition adalah metode yang mampu menganalisis data sinyal nonlinier dan nonstasioner, proses metode ini didasarkan pada ekstraksi energi secara teratur yang terkait dengan berbagai sinyal skala waktu dan mulai dari skala yang lebih tinggi dari mode frekuensi tinggi ke Mode frekuensi rendah skala-keras (Boudraa and Cexus, 2007). Untuk ekstraksi fitur pada sinyal dapat diproses oleh domain waktu, domain frekuensi (Jenke et al., 2014).

1.2 Rumusan Masalah

Cybersickness selama ini banyak diteliti orang dalam bentuk gejala fisik dan divalidasi dengan menggunakan kuisionair. Pengukuran *Cybersickness* menggunakan sinyal *EEG* masih merupakan pendekatan baru dalam memahami pola fisiologis *Cybersickness*. Dalam penelitian ini, pola fisiologis dari *Cybersickness* akan didapatkan menggunakan *Time Domain Features Extraction*. Dengan didapatkannya pola fisiologis dari *Cybersickness* ini, maka akan tersedia informasi dasar yang bisa digunakan oleh Industri *Game* khususnya, *3D Game* untuk melakukan evaluasi tingkat *Cybersickness* yang dihasilkan dari *3D Game* tersebut, sehingga kualitas dari *3D game* yang beredar di masyarakat akan bisa dipantau. Hasil penelitian ini juga bisa digunakan sebagai bahan rekomendasi dari Industri *game*, terutama rekomendasi pada usia berapa yang bisa bermain *game* tertentu serta berapa lama durasi anak tersebut dalam menikmati sebuah *3D Game*.

1.3 Tujuan

Tujuan dari penelitian ini adalah melakukan klasifikasi sinyal EEG antara kondisi normal dan kondisi dimana berpotensi menimbulkan *cybersickness* melalui *Time Domain Feature Extraction* menggunakan *Naïve Bayes*.

1.4 Batasan Masalah

Batasan masalah pada penelitian ini adalah:

1. Penelitian ini menggunakan data sekunder, yaitu data hasil pengukuran Alfi Zuhriya Khoirunnisa.
2. Data eeg yang diamati sudah difilter dari kemungkinan *error skin artefact*, dan band frekuensi yang kami amati adalah *alpha* dan *beta* saja.
3. Stimuli *Game* 3D yang digunakan di penelitian ini adalah game: *Mirror's Edge*.
4. Validasi yang kami gunakan untuk mengukur *cybersickness* yaitu kuisioner SSQ.

1.5 Kontribusi

Penelitian ini diharapkan dapat menjadi dasar pengetahuan sinyal EEG pada *cybersickness* manusia yang bisa digunakan sebagai pendukung industri *game* menentukan seberapa besar efek *cybersickness* bagi pemain game 3D khususnya.

1.6 Metodologi Penelitian

Pada penelitian ini menggunakan metode Naive Bayes. Data diambil dari 9 partisan. Setiap partisan memiliki 14 kanal melalui alat Emotiv Epoch (Ramirez and Vamvakousis, 2012). Pada pengambilan data selama 20 menit, diambil 4 menit pertama dan 4 menit terakhir untuk diolah. Dimana, 4 menit pertama adalah pre *cybersickness* sedangkan 4 menit terakhir saat bermain game *Mirror's Edge*. Kemudian, sinyal yang dianalisa telah dibagi ke dalam 2 bentuk sinyal EEG. Pertama sinyal alpha (α), memiliki rentang frekuensi antara 8-12 Hz. Hal ini terkait dengan relaksasi tanpa perhatian dan konsentrasi. Yang kedua yaitu sinyal low beta (β), memiliki rentang frekuensi antara 12-21 Hz. Hal ini disajikan dalam semangat berpikir seseorang ketika terjaga dan dengan aktifitas mental yang prima (Atkinson & Campos, 2016). Kemudian, pada penelitian ini, partisipan menggunakan alat emotive yang menghasilkan data EEG sambil bermain game 3D.

BAB 2

KAJIAN PUSTAKA

2.1 Sejarah Awal dari EEG

Peralatan EEG dan aplikasi sebagai teknologi baru muncul secara konsisten mengambil keuntungan dari mereka. Sejarah teknologi yang memungkinkan EEG bisa ditelusuri kembali ke abad 16 M sampai sekarang pada penemuan bioelectricity (Yurci, n.d.).

Bioelectric yang ditulis pertama adalah deskripsi dari lele listrik sebagai ikan yang “Merilis Pasukan” untuk muncul di hieroglyph Mesir kuno sekitar 3100 SM. Dokumen tertulis pertama pada aplikasi medis dengan menggunakan listrik muncul di 46 M., ketika Scribonius Largus merekomendasikan penggunaan ikan torpedo untuk menyembuhkan sakit kepala. Istilah listrik ditemukan oleh William Gilbert (Inggris; 1544-1603). Dia membangun sebuah elektroskop sederhana, jarum logam ringan diputar pada pin untuk mengukur kekuatan yang menarik dari amber yang dalam Bahasa Yunani disebut sebagai listrik (ηλεκτρον). Kemajuan berlanjut di tahun 1700, Benjamin Franklin (Amerika; 1706-1790), Luigi Galvani (Italia; 1737-1798), Michael (Inggris; 1791-1867), dan Jacques Arsene d’Arsonval (Prancis; 1851-1940) adalah masing-masing penemu berbagai jenis listrik: listrik statis, arus searah, guncangan kumparan induksi dan frekuensi radio saat ini

Sebuah studi yang signifikan tentang fenomena bioelektrik pada hewan dilakukan oleh Luigi Galvani pada 1780, professor anatomi di University of Bologna, bahwa disebabkan berkedutnya otot kaki katak ketika ia secara bersamaan menyentuh otot-otot dan terkena saraf dengan busur bimetal tembaga dan seng. Penelitian ini dikutip sebagai percobaan pertama kali didokumentasikan di stimulasi listrik neuromuskuler, dan salah satu forays pertama ke dalam studi bioelectricity pada hewan. Dengan ditemukannya galvanometer, yang merupakan aktuator elektromekanis analog digunakan untuk mendeteksi arus listrik, oleh Hans Cristian Oersted (Denmark, 1777-1811) pada tahun 1820 memimpin cara untuk belajar bioelectricity lebih dalam. Carlo Matteucci (Italia; 1811-1865) adalah orang pertama yang mengukur arus bioelectric impuls otot di katak pada 1820 dengan menggunakan static galvanometer Emil Du Bois-Reymond (Jerman; 1818-1896)

mulai mengukur arus biologis dalam ikan listrik pada tahun 1840 oleh galvanometer.

Pada tahun 1875, demonstrasi pertama pada aktivitas listrik otak dilakukan oleh Richard Caton (British;1842-1926). Dia mencatat aktivitas listrik dari otak kelinci, kucing, dan monyet dengan menggunakan cermin galvanometer. Ia berhasil mengamati variasi kondisi terkait tidur, terjaga, anestesi, dan kematian. Dimana, otak diidentifikasi terkait dengan aktivitas motorik termasuk gerakan kepala, pengunyahan, dan gerakan kelopak mata yang ditafsirkan setelah dia dari pekerjaan, membuat EEG mapper otak pertama. Pada tahun 1913, rekaman fotografi pertama dari sinyal EEG diperoleh dengan Vladimir Pravdich-Neminsky (Rusia, 1879-1952) di Kiev, ia memberikan literature pertama yang menunjukkan EEG dengan seri gelombang representasi. Pada tahun 1920, Alexander Forbes, professor di departemen fisiologi Harvard Medical School, mengganti galvanometer senar dengan tabung vakum untuk memperkuat EEG sinyal listrik. Ini menjadi standar untuk EEG amplifikasi di tahun-tahun berikutnya.

Pada tahun 1924, Hans Berger (Jerman; 1873-1941) mencatat gelombang otak manusia pertama dan ia mengenalkan kata electroencepalogram. Dia juga memperkenalkan dua pola gelombang otak yaitu gelombang alpha dan gelombang beta. Toennies, dari Institute of Brain Research di Berlin-Buch J.F., membuat kemajuan penting di bidang instrumentasi EEG. Pada tahun 1932, dia adalah orang pertama yang mengembangkan *multichannel oscillography* pada tulisan dengan tinta untuk merekam potensi otak. Kemudian, dikembangkan penguat diferensial dengan kolaborasi B. H. C. Matthews dari Fisiologi Laboratorium, Universitas Cambridge, Inggris. Sedangkan Berger tidak mendapatkan publisitas kontribusi ilmiah dari seluruh dunia sampai E. D. Adrian dan B. H. C. Matthews menguatkan karya dari Berger. Mereka adalah orang-orang pertama yang berhasil melakukan eksperimennya pada tahun 1934. Mereka mampu merekam secara simultan dan independen dari berbagai area otak yang mengungkapkan hubungan sinyal yang spasial dan temporal. Mereka juga berhasil mendengarkan gelombang otak yang merupakan contoh gelombang yang disonikasi oleh gelombang suara ultra untuk mencitrakan organ internal.

Selain penelitian yang diadakan di Eropa, di Amerika Serikat, Donald B. Lindsley (Amerika; 1907-2003), pendiri lembaga Brain Research UCLA, adalah salah satu yang ilmuwan pertama yang menggunakan teknik dari electroencephalography yaitu menggunakan listrik untuk merekam aktifitas otak. Pada pertengahan 1930-an, sistem EEG komersial mulai muncul banyak di laboratorium membuat kontribusi untuk metodologi EEG dan praktek dengan menggunakan sistem cloning dari desain sebelumnya. Albert Grass menghasilkan perangkat EEG komersial pertama. Model I dari Grass pada tahun 1935, yang memiliki tiga saluran amplifikasi diferensial dan tinta penulis yang direka, pada gulungan kertas. Pada akhir Perang Dunia II, model III diperkenalkan pada tahun 1946, dan memiliki pertama 8 channel dan 16 channel perangkat EEG yang pernah dibuat dan sekitar 5000 sistem yang diproduksi dan dikirim ke seluruh dunia. American Electroencephalography Society (AEEGS) didirikan pada tahun 1946, pertemuan tahunan dan dimiliki pertama diadakan di Atlantic City NJ pada tahun 1947 dengan mendirikan eksperimental dan klinis EEGers. Pada tahun 1949. Edisi pertama dari “The EEG Journal” telah diterbitkan. Pada tahun 1950, transistor amplifier EEG pertama diproduksi oleh Franklin Offner, dinamakan sebagai “Type T”, yang merupakan sistem portabel yang membawa standar baru untuk instrumentasi EEG dengan keuntungan celah panas rendah, tinggi efisiensi, tahanan operasi yang lebih rendah, dan ukurannya kecil seperti yang terlihat pada Gambar 2.1.



Gambar 2.1 Perangkat pertama EEG portable didesain Franklin Offner 1950's

Pada pertengahan tahun 1950-an, EEG memiliki peralatan laboratorium formal dalam lembaga dan rumah sakit. Dengan pendahuluan teknologi digital sistem EEG menjadi lebih otomatis dikendalikan, lebih mudah dalam penyimpanan sinyal, pengambilan dan kemampuan pemrosesan numerik jauh lebih baik. Kemudian, pada masa abad 21 ini, alat EEG memiliki bentuk yang semakin mudah dibawa, sehingga memudahkan setiap penggunaanya dalam mengoperasikan alat ini.

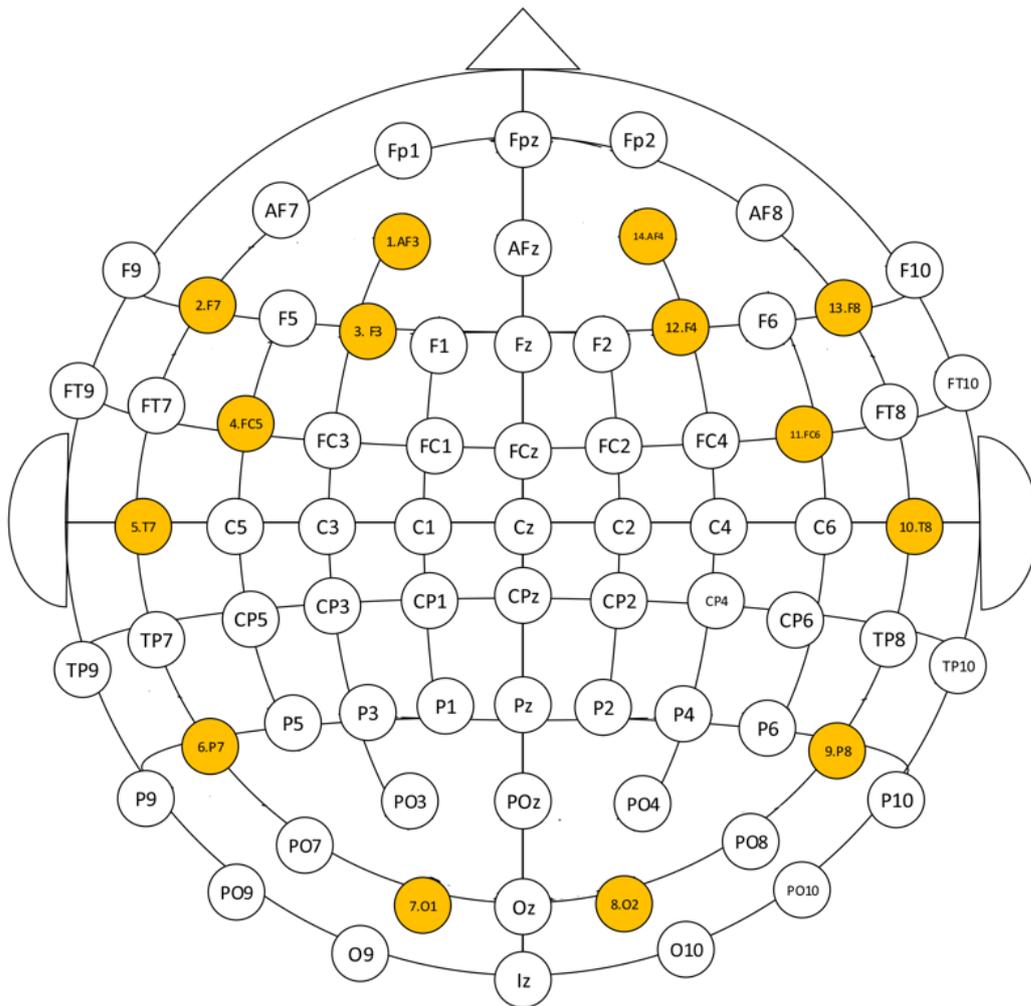
2.2 Electroencephalograph

Electroencephalography adalah rekaman sinyal listrik yang berasal dari sinyal otak manusia. Sinyal listrik dihasilkan secara alami selama periode waktu tertentu dan diterima oleh saluran. Studi yang menjadi fondasi dasar semua penelitian tentang sinyal listrik diperkenalkan oleh Hans Berger pada tahun 1942, pada saat itu sinyal otak manusia diukur pada kulit kepala manusia dengan menggunakan peralatan radio biasa. Gelombang otak manusia dapat dikategorikan menjadi 4. Ada 8 saluran dalam menangkap sinyal otak mental spesifik manusia yaitu C3, Cz, C4, CP1, CP2, P3, Pz dan P4 dimana rentang frekuensi sinyal EEG diterima antara 1- 30 Hz. Pada tahun 1958, Federasi Internasional dalam Elektroencephalografi dan Neurofisiologi Klinis menerapkan standarisasi untuk penempatan elektroda yang disebut sistem penempatan elektroda 10-20. Sistem standar penempatan fisik dan penunjukan elektroda pada kulit kepala dibagi ke dalam jarak proporsional yang menonjol pada tengkorak untuk memberikan cakupan yang memadai pada semua daerah otak. Label 10-20 menunjukkan jarak proporsional dalam persen antara telinga dan hidung dimana titik untuk elektroda dipilih. Penempatan elektroda berlabel sesuai dengan area otak yang berdekatan: F (Frontal), C (Tengah), T (Temporal), P (Parietal), dan O (Occipital). Dengan penomoran angka ganjil di sebelah kiri dan bahkan di sebelah kanan. Setelah memasang semua peralatan sesuai kanal, kami melakukan proses perekaman EEG tanpa adanya stimulus apapun. Dalam kasus kami ini, kami gambarkan dalam tampilan partisipan sedang melihat gambar hitam di laptop sebelum diberi stimulus. Ketika dilakukan perekaman EEG, sinyal yang dihasilkan sangatlah berbeda dibandingkan ketika melakukan aktifitas lain. Ketika partisipan tidak melakukan aktifitas apapun dan tidak diberikan stimulus apapun serta hanya melihat berupa layar hitam laptop, kami memberi nama sebagai baseline seperti pada Gambar 2.2.



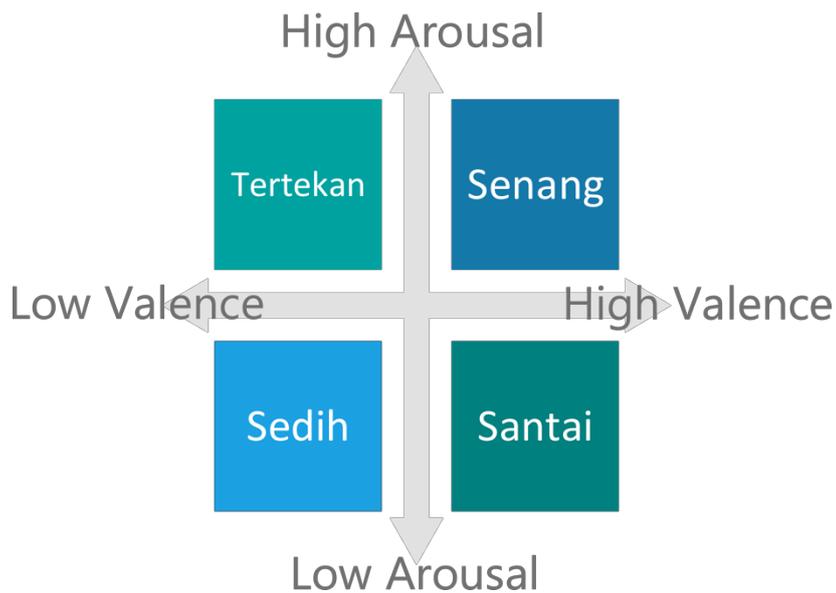
Gambar 2.2 Proses perekaman EEG kondisi *baseline*

Penelitian (Koelstra, 2012) tentang membangun kumpulan data psikis manusia berdasarkan data sinyal EEG yang dipengaruhi oleh tingkat gairah, suka atau tidak suka. Dimana kumpulan data psikis ini adalah analisis psikologis yang mencatat sinyal data EEG, EOG, EMG, GSR, Representationbelt, plethysmography, dan suhu tubuh. Proses pembentukan dataset ini juga mencatat kondisi peserta selama proses perekaman. Ada 9 peserta dalam dataset dimana masing-masing peserta diberi waktu 20 menit. Pengambilan data menggunakan frekuensi sampling $fs=256$ Hz ketika sebelum dan sedang bermain *Game* sebagai stimulus untuk merekam data sinyal psikologis. Dataset EEG dibagi ke dalam dua kondisi yaitu kondisi pertama adalah 4 menit awal perekaman. Dimana, partisipan sebelum bermain *game*, diharuskan tidak melakukan aktifitas apapun. Pada percobaan ini partisipan melihat laptop latar belakan hitam. Dan yang kedua adalah 4 menit terakhir ketika bermain *game*. Dengan demikian, waktu pengambilan data sebelum bermain *game/pre (baseline)* adalah 4 menit x 60 detik = 240 detik. Jumlah datanya adalah 256 sampling/detik x 240 detik = 61440 sample data. Begitu juga pada data ketika partisipan bermain *game* yaitu 61440 sample data. Penelitian ini menggunakan kanal AF3, F7, F3, Fc5, T7, P7, O1, O2, P8, T8, Fc6, F4, F8, dan AF4 dimana A pada AF disini adalah *Earlobe* yang berada pada cuping telinga atau bagian paling bawah daun telinga yang tidak bertulang biasanya terdapat penjepit yang bisa digunakan sebagai *ground* perekaman EEG seperti pada Gambar 2.3.



Gambar 2.3 Posisi 14 kanal sesuai dataset

Studi tentang psikis dalam interaksi manusia komputer telah meningkat di baru-baru ini. Dalam teorinya, penggolongan psikis manusia terbagi ke dalam kuadran. Dimana, kuadran tersebut memiliki sumbu x yaitu valence (1-9) dan sumbu y yaitu arousal (1-9). Ketika valence dan arousal tinggi maka tergolong senang, apabila keduanya rendah maka tergolong sedih, sedangkan apabila kondisi valence rendah arousal tinggi, maka tergolong ke dalam kondisi tertekan. Ketika valence tinggi arousal rendah, maka tergolong kondisi relaksasi/santai. Apabila valence 5 arousal tinggi atau sebaliknya valence tinggi arousal 5, maka tergolong kondisi heboh/gembira. Kemudian, apabila valence rendah arousal 5, maka tergolong kondisi menderita. Dan, apabila valence 5 arousal rendah, maka tergolong kondisi tenang. Terakhir apabila keduanya 5 maka dalam kondisi netral seperti terlihat pada Gambar 2.4.



Gambar 2.4 Kuadran valence arousal

Pada penelitian (Koelstra et al., 2012) membahas tentang psikis manusia ketika dihadapkan dengan lingkungan virtual 3D. Mereka membahas tentang bagaimana dampak positif maupun negative dari stimuli tersebut.

2.3 Teori Dasar tentang Cybersickness

Cybersickness adalah terjadinya konflik persepsi antara mata (visual), sensor dalam telinga (vestibular) dan sensor dalam otot (propioceptive), hal tersebut menimbulkan respon dari tubuh (otak) dengan timbulnya gejala-gejala cybersickness (LaViola, 2000a).

2.3.1 Konsekuensi dan Implikasi Cybersickness

Ada sejumlah konsekuensi dan implikasi yang berkaitan dengan cybersickness di lingkungan virtual. Salah satu masalah yang berpotensi berbahaya dengan cybersickness adalah kemungkinan efek samping yang dapat berkembang dalam beberapa jam setelah pengalaman VE (Virtual Environment). Dalam banyak kasus, gejala dapat bertahan selama berjam-jam dan, dalam beberapa kasus, selama berhari-hari. Dalam salah satu kasus yang lebih aneh, seorang pilot memiliki pandangannya tentang dunia terbalik 180 derajat saat mengendarai mobil berjam-jam setelah pengalaman VE. Sebagai hasil dari jenis efek setelah ini, banyak pangkalan angkatan udara memiliki kebijakan landasan wajib yang mengharuskan pilot tidak dapat menerbangkan pesawat dari mana saja dari 12 hingga 24 jam

setelah terpapar dengan simulator penerbangan VE. Juga, banyak pusat hiburan VR mengharuskan pengguna untuk tidak mengemudi setidaknya 30 hingga 45 menit setelah paparan. Orang bisa berpendapat bahwa ini tidak cukup waktu mengingat beberapa hasil penelitian yang disajikan di atas. Namun, waktu paparan untuk VE di pusat-pusat hiburan ini biasanya hanya beberapa menit sementara paparan simulator penerbangan VE biasanya jauh lebih lama, dan intensitas pengalamannya jauh lebih parah.

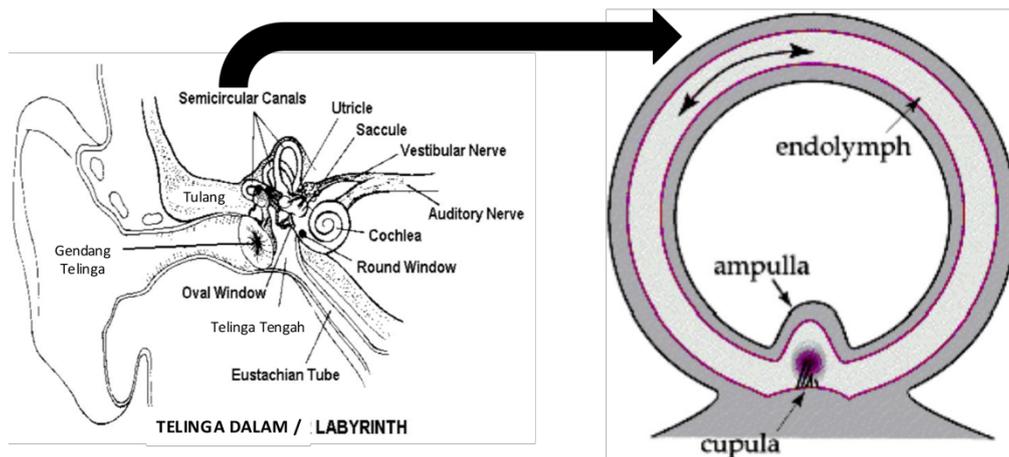
Selain keselamatan penerbangan dan mengemudi sebagai konsekuensi dari efek-akhir, cybersickness menyiratkan penurunan jumlah penggunaan VE. Secara umum, orang berusaha menghindari sakit, dan jika pengalaman VE menyebabkan cybersickness maka orang hanya akan berhenti menggunakan VE. Konsekuensi penting lain dari cybersickness berkaitan dengan pelatihan berkompromi dalam penerbangan, helikopter, dan simulasi VE lainnya. Pertama, proses pelatihan dapat diganggu jika pengguna terganggu oleh berbagai gejala. Kedua, pengguna dapat mengadopsi perilaku untuk menghindari gejala dalam simulasi yang akan mempengaruhi mengemudi / terbang kendaraan fisik.

2.3.2 Analisis Sistem Vestibular dan Visual

Kita telah melihat di bagian sebelumnya bahwa cybersickness bermasalah, dan penyebab serta faktor-faktor yang berkontribusi harus dipahami untuk menentukan bagaimana mengembangkan teori yang dapat memprediksi kapan cybersickness akan terjadi dan bagaimana cara meringankannya. Namun, sebelum membahas tiga teori cybersickness utama dan cara mengatasi masalah cybersickness, penting untuk memahami fisiologi yang mendasari dua komponen utama yang berhubungan dengan gerak diri, sistem vestibular dan persepsi visual. Oleh karena itu, pada bagian ini, kami membahas secara singkat sistem vestibular, persepsi visual gerak diri, dan hubungan penting antara keduanya.

2.3.3 Sistem Vestibular

Sistem vestibular memberikan informasi tentang gerakan dan orientasi kepala di ruang angkasa. Ini terdiri dari bagian non-akustik dari telinga bagian dalam yang terdiri dari tiga kanal setengah lingkaran untuk mendeteksi percepatan sudut dan utricle dan saccule yang mendeteksi percepatan linier seperti pada Gambar 2.5.



Gambar 2.5 Vestibular sistem dan Semisirkular kanal

Tiga kanal setengah lingkaran sesuai dengan masing-masing dari tiga dimensi dimana gerakan manusia dapat terjadi. Karena itu, setiap kanal mendeteksi gerakan dalam satu bidang. Setiap saluran diisi dengan cairan yang disebut endolymph, yang mengalir melalui saluran saat kepala mengalami percepatan sudut. Ketika cairan mengalir melalui kanal, ia membelokkan sel-sel kecil seperti rambut, yang disebut cupula, yang mengirimkan sinyal ke area penerima vestibula otak. Untuk penampang kanal adalah setengah lingkaran. Kita perhatikan bahwa ada dua komponen vestibular, satu di setiap sisi kepala yang saling mencerminkan dan bertindak secara push-pull. Karena setiap kelompok sel-sel rambut terpolarisasi, mereka dapat tereksitasi (didorong) atau dihambat (ditarik) berdasarkan arah mana cupula bergerak. Penting bagi kedua perangkat vestibular untuk sepakat satu sama lain. Dalam operasi normal, satu sisi kepala harus mendorong dan yang lainnya harus menarik. Jika kedua sisi didorong, misalnya, vertigo akan terjadi.

Sistem vestibular juga mendeteksi percepatan linier melalui utrikulus dan sakula. Kedua organ ini memiliki sel-sel seperti rambut, yang disebut makula, dan silia tertanam dalam massa agar-agar. Massa agar-agar memiliki gumpalan kristal kecil, yang disebut otolith, yang menyediakan inersia yang diperlukan untuk menyeret sel-sel rambut dari sisi ke sisi untuk memberikan persepsi gerak. Setelah kecepatan konstan tercapai, otolith menstabilkan dan merasakan gerakan menghilang sehubungan dengan sistem vestibular. Contoh fenomena ini yaitu duduk di dalam mobil ketika pertama berakselerasi dan kemudian menjadi stabil.

Seperti halnya kanal setengah lingkaran, sel-sel rambut dalam utrikel dan sakula dipolarisasi tetapi disusun dalam arah yang berbeda. Setiap makula dapat mencakup dua arah gerakan. Karena utrikel terletak secara horizontal di telinga, ia dapat mendeteksi gerakan pada bidang horizontal sementara sakula berorientasi vertikal sehingga ia dapat mendeteksi gerakan naik, turun, maju dan mundur. Perhatikan bahwa peran utama utrikel dan sakula adalah untuk memberikan orientasi vertikal sehubungan dengan gravitasi. Sebagai contoh, perhatikan goyangan kecil yang terus-menerus dan bergoyang-goyang ketika seseorang mencoba untuk berdiri diam. Ini adalah refleksi langsung dari utricle dan saccule di tempat kerja.

2.3.4 Persepsi Visual Gerak Diri

Ketika seseorang dalam posisi diam, mereka masih bisa mendapatkan kesan gerak diri dalam kondisi tertentu. Kesan gerak diri yang menipu ini disebutvection. Veksi dapat terjadi, misalnya, ketika seseorang berada di kendaraan yang tidak bergerak sementara kendaraan yang berdekatan mulai bergerak. Veksi juga bisa diproduksi dengan tampilan field-of-view yang luas (tampilan yang sama yang digunakan dalam lingkungan virtual) dari pola aliran optik yang merupakan karakteristik gerak diri. Pola aliran optik ini memberikan perubahan temporal dalam struktur array optiks. Pola aliran optik juga memberikan rasa gerak diri berdasarkan komponen translasional dan rasional tentang sumbu yang berpusat pada kepala dalam ruang tiga dimensi. Dalam gerak diri standar, komponen-komponen ini akan disertai dengan informasi vestibular, tetapi denganvection, informasi vestibular tidak hadir atau dipengaruhi oleh pola aliran optik. Ini adalah hubungan visual-vestibular yang merupakan dasar untuk teori konflik sensorik.

Ada sejumlah faktor stimulus penting yang menentukan kekuatan dan lamanya ilusi veksi. Field-of-view memainkan peran penting dalam menyebabkanvection karena bidang pandang yang lebih besar merangsang lebih banyak dari pinggiran retina. Laju aliran optis juga merupakan faktor yang berkontribusi terhadap penginduksian karena laju aliran yang lebih cepat akan meningkatkan kecepatan gerakan yang dirasakan sehingga membuat ilusinya lebih intens. Akhirnya, faktor penting dalam penyebabvection adalah kedalaman nyata dari objek di virtual lingkungan Hidup. Dalam aplikasi di mana pengguna tidak harus

melakukan teknik perjalanan virtual yang signifikan dan objek yang dekat dengan pengguna, seperti desain otomotif atau prototyping virtual, pemilihan akan dibatasi. Namun, dengan aplikasi seperti mengemudi dan simulasi penerbangan, gerakan melekat pada aplikasi yang akan memberikan lebih banyak rangsangan isyarat untuk menginduksi veksi. Perhatikan bahwa ada lebih banyak faktor fisiologis yang berhubungan dengan veksi karena kompleksitas sistem visual. Diskusi tentang faktor-faktor ini berada di luar cakupan makalah ini. Pembaca yang tertarik didorong untuk menjelajahi Gleitman dan Sekuler untuk informasi lebih lanjut.

2.3.5 Hubungan antara Sistem Vestibular dan Visual

Ada hubungan penting antara sistem vestibular dan visual di mana kanal setengah lingkaran menjaga mata di tempat ketika kepala bergerak. Kanal setengah lingkaran memberikan kontrol atas mata sehingga mereka dapat mengimbangi gerakan kepala. Mata dikontrol oleh tiga pasang otot, rektus medial dan lateral, rektus superior dan inferior, dan oblique inferior dan superior. Setiap kanalis setengah lingkaran berinteraksi dengan sepasang otot mata tunggal. Refleksi kompensasi ini dikenal sebagai refleksi vestibulo-okular.

Untuk menggambarkan refleksi vestibulo-okular pertimbangkan contoh berikut. Pada Gambar 2.6, menunjukkan horizontal setengah lingkaran yang akan berkontraksi atau mengendurkan mata pada bidang horizontal. Jika kepala bergerak ke kiri dan mata harus diperbaiki pada titik diam, maka gerakan kepala akan merangsang kanal horizontal kiri dan menghambat kanal horizontal kanan. Kanal horizontal kiri akan mengirim pesan ke rektus lateral kanan dan rektus medialis kiri untuk menarik mata ke kanan. Perhatikan bahwa karena kanal horizontal kanan terhambat, ia tidak memiliki efek pada otot mata. Lihat Gambar 4 untuk lebih jelasnya.

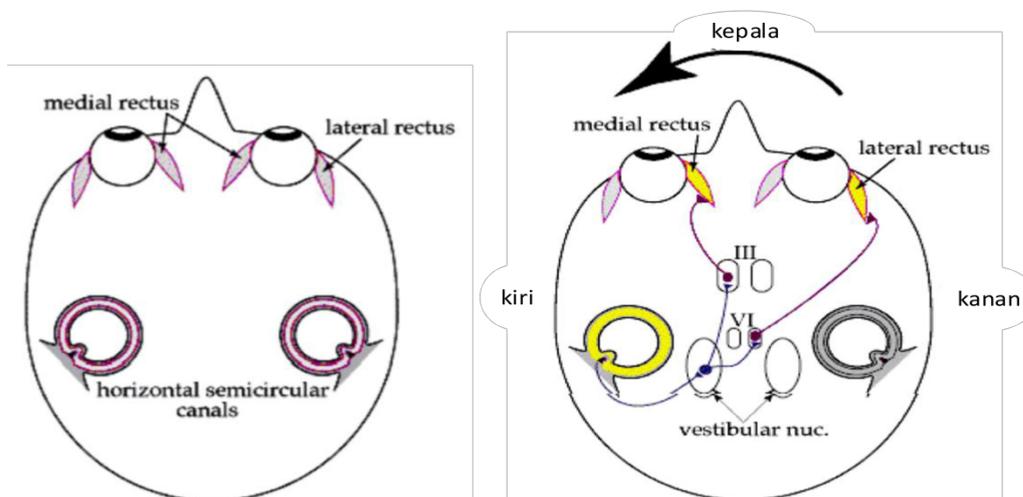
2.3.6 Teori Cybersickness

Sekarang kita telah membahas dua bagian terpenting dari tubuh yang berhubungan dengan cybersickness, muncul pertanyaan mengapa dan bagaimana cybersickness terjadi. Ada tiga teori utama tentang penyebab cybersickness yaitu teori konflik sensorik, teori racun, dan teori ketidakstabilan postural.

Teori Konflik Sensorik

Teori konflik sensorik adalah yang tertua dan paling diterima dari teori-teori yang berkaitan dengan mabuk perjalanan dan cybersickness. Teori ini didasarkan pada premis bahwa perbedaan antara panca indera yang memberikan informasi tentang orientasi dan gerak tubuh menyebabkan konflik persepsi yang mana tubuh tidak tahu cara menanganinya. Dengan cybersickness dan motion sickness, dua indera utama yang terlibat adalah indera vestibular dan indera visual. Konflik sensorik ini muncul ketika informasi sensorik bukan stimulasi yang diharapkan subjek berdasarkan pengalamannya.

Dalam kasus cybersickness, pertimbangkan simulator mengemudi lingkungan virtual. Ketika subjek menggunakan simulasi, pola aliran optis dari jalan, bangunan, dan bagian lain dari lingkungan bergerak melewati pinggiran subjek yang memberinya rasavection. Sistem visual memberi tahu subjek beragam informasi yang mencakup bahwa ia bergerak ke arah tertentu, berakselerasi saat menekan pedal gas dan melambat saat menekan rem. Namun, karena subjek tidak benar-benar bergerak, indera vestibular tidak memberikan rasa akselerasi atau deselerasi linier atau sudut. Dalam kondisi pengendaraan fisik normal, subjek memiliki sistem vestibular dan visual yang menyediakan informasi dan sebagai akibatnya, ini adalah persepsi yang diharapkan dimiliki subjek. Ketika subjek tidak mendapatkan respons yang diharapkan, konflik terjadi dan cybersickness dapat terjadi seperti pada Gambar 2.6.



Gambar 2.6 Horizontal Semisirkular Kanal, Medial, Lateral Rektus dan Mata

Meskipun teori konflik sensorik adalah teori yang paling banyak diterima untuk penyebab cybersickness, ada sejumlah masalah dengan itu. Pertama, ia memiliki sedikit, jika ada, kekuatan prediktif dalam menentukan apakah cybersickness akan terjadi mengingat situasi tertentu atau seberapa parahnya itu, dan itu tidak memperhitungkan beberapa faktor lain yang telah dikaitkan dengan cybersickness. Kedua, meskipun teori tersebut mengklaim adanya pertentangan antara isyarat vestibular dan isyarat yang mungkin menjadi penyebab cybersickness, teori ini tidak menjelaskan mengapa beberapa individu jatuh sakit dan mengapa yang lain tidak memberikan serangkaian rangsangan identik. Akhirnya, teori konflik sensorik mengklaim bahwa konflik isyarat dapat menyebabkan cybersickness, tetapi tidak memberikan penjelasan mengapa konflik seperti itu dapat membuat seseorang sakit.

Teori Racun

Teori racun berusaha memberikan penjelasan mengapa mabuk dan cybersickness terjadi dari sudut pandang evolusi. Teori ini menunjukkan bahwa konsumsi racun menyebabkan efek fisiologis yang melibatkan koordinasi visual, vestibular, dan sistem input sensorik lainnya. Efek fisiologis ini bertindak sebagai sistem peringatan dini yang meningkatkan kelangsungan hidup dengan menghilangkan isi perut. Stimulasi buruk yang ditemukan di beberapa lingkungan virtual dapat mempengaruhi visual dan sistem vestibular tersebut sedemikian rupa sehingga tubuh salah membaca informasi dan mengira telah menelan beberapa jenis zat beracun sehingga menyebabkan gejala yang mengganggu yang mengarah pada respons emetik.

Teori racun memberikan hipotesis yang menarik untuk terjadinya cybersickness dan telah ada beberapa penelitian yang mendukung teori ini. Namun, ia juga tidak memiliki kekuatan prediksi dan tidak menentukan mengapa orang yang sakit di lingkungan virtual tidak selalu memiliki respons emetik. Ini juga tidak memberikan penjelasan mengapa beberapa orang mendapatkan cybersickness di VE dengan rangsangan yang diberikan tetapi orang lain dengan rangsangan yang sama tidak. Sayangnya, sulit untuk memastikan bahwa teori ini valid.

Teori Ketidakstabilan Postural

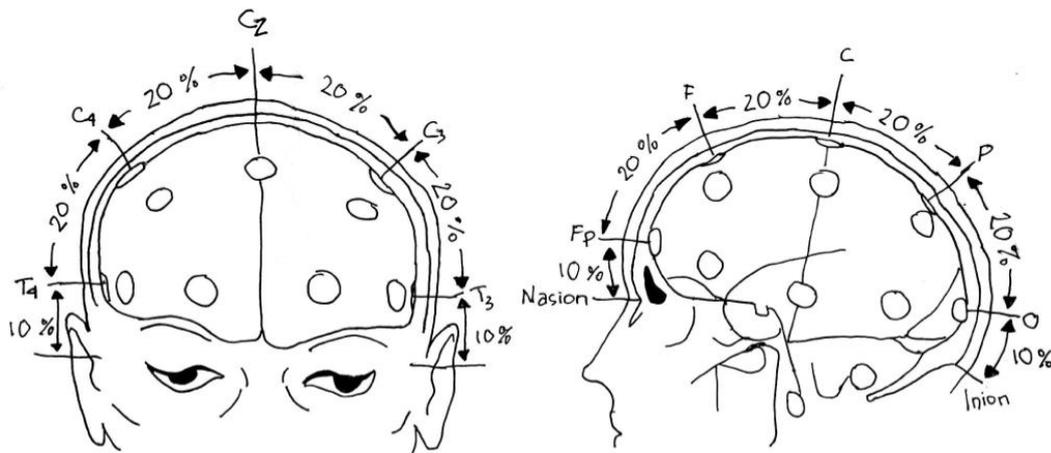
Teori ketidakstabilan postural, yang dikembangkan oleh Ricci dan Stoffregen, berpusat pada gagasan bahwa salah satu tujuan perilaku utama pada manusia adalah untuk menjaga stabilitas postural di lingkungan. Dalam hal ini, stabilitas postural didefinisikan sebagai keadaan di mana gerakan persepsi dan sistem tindakan yang tidak terkontrol diminimalkan. Kestabilan posisi ini dibatasi berdasarkan sifat lingkungan sekitar. Misalnya, pertimbangkan berjalan di atas beton dan berjalan di atas es. Secara umum, orang berjalan di atas beton berbeda dari yang mereka lakukan di atas es, dan jika seseorang mencoba berjalan di atas es seperti yang mereka lakukan di atas beton, mereka biasanya akan jatuh. Namun, reaksi alami berjalan di atas es adalah mengubah pola berjalan untuk menjaga stabilitas postur tubuh. Setiap kali lingkungan berubah secara tiba-tiba atau signifikan, dalam banyak kasus, kontrol postural akan hilang terutama jika strategi kontrol tidak tersedia karena kurangnya pengalaman. Akhirnya, strategi kontrol akan dipelajari dan stabilitas postural akan tercapai sekali lagi. Ketika seseorang memiliki kontrol postural yang rusak atau benar-benar hilang, mereka berada dalam kondisi ketidakstabilan postur tubuh.

Oleh karena itu, teori ketidakstabilan postural menyatakan bahwa penyebab mabuk perjalanan dan cybersickness adalah ketidakstabilan postur yang berkepanjangan. Dengan kata lain, ketidakstabilan postural mendahului dan diperlukan untuk menghasilkan mabuk dan gejala cybersickness, dan keparahan gejala berskala langsung dengan durasi ketidakstabilan. Jadi, semakin lama durasi ketidakstabilan postural, semakin parah gejalanya. Juga, gejala tidak akan terjadi jika kontrol postural hilang sepenuhnya karena kejadian biasanya singkat.

Sekarang muncul pertanyaan tentang bagaimana teori ketidakstabilan postural berhubungan secara eksklusif dengan cybersickness. Ada sejumlah situasi lingkungan yang terjadi yang dapat menyebabkan ketidakstabilan postur tubuh dalam waktu lama. Riccio dan Stof-fregen mengklasifikasikan mereka ke dalam 4 kategori berbeda yang meliputi getaran frekuensi rendah, bobot, perubahan hubungan antara vektor gaya gravitasi dan permukaan dukungan, dan mengubah spesifisitas. Cyber-sickness termasuk dalam kategori spesifisitas yang berubah. Sejak di banyak VE ada percepatan dan rotasi yang ditentukan secara optik yang

tidak terkait dengan kendala pada kontrol tubuh, strategi kontrol postural untuk mendapatkan stabilitas postural tidak akan berfungsi. Sebagai contoh, subjek dapat menggunakan kekuatan otot untuk menahan kemiringan dari percepatan sudut yang dirasakan secara visual. Karena tidak ada kemiringan fisik, subjek membuat perbedaan yang tidak diinginkan dari posisi stabil yang menyebabkan ketidakstabilan postural. Menurut Riccio dan Strof-fregen, ketidakstabilan postural akan terjadi setiap kali seekor hewan mengaitkan kontrolnya dengan pola stimulasi yang tidak lagi spesifik pada kondisi lingkungan di mana pengendaliannya sesuai. Teori ketidakstabilan postural dirancang dalam upaya untuk menyangkal teori konflik sensorik. Ini menyajikan argumen penting yang membuat klaim bahwa penyebab cybersickness dan mabuk perjalanan tidak bisa menjadi konflik sensorik. Argumen menyatakan bahwa ketika sistem vestibular dan visual setuju, mereka menerima informasi yang berlebihan. Jadi, jika kedua sistem tidak dalam persetujuan, maka ada nonredundancy informasi. Dalam banyak kasus, nonredundancy ini tidak menyebabkan penyakit dan teori konflik sensorik tidak memiliki penjelasan. Akibatnya, itu bukan teori yang memadai. Namun, hal yang menarik untuk dicatat adalah bahwa teori ketidakstabilan postural sejajar dengan teori konflik sensorik dalam banyak hal terutama dalam hal cybersickness. Apakah iya atau tidak, itu adalah teori yang tidak pasti meskipun telah ada beberapa bukti yang mendukung bahwa teori konflik sensorik ada yang tidak memadai. Penelitian lebih lanjut perlu dilakukan untuk menentukan validitas teori ketidakstabilan posisi.

Dalam pengukuran tersebut, diperlukan sistem pelatukan elektrode. 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) serta earlobe (A) (Jurcak et al., 2007) seperti Gambar 2.7.



Gambar 2.7 Sistem Peletakan Elektrode 10-20

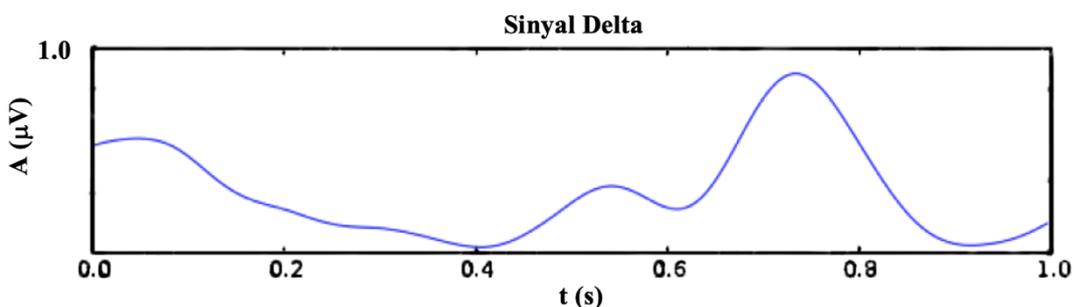
2.4 Dasar Pembagian Sinyal EEG

Rentang frekuensi gelombang otak dapat dikenali 0,5-500 Hz. Rentang frekuensi penting secara klinis dibagi dalam empat kelompok utama; alpha, beta, theta, dan delta band. Frekuensi pengukuran EEG berkisar dari 1 sampai 80 Hz, dengan amplitude 10 sampai 100 microvolts (Jenke et al., 2014).

a) Delta (δ)

Memiliki frekuensi 4 Hz atau di bawah. Hal ini biasanya terlihat pada tidur nyenyak. Pola gelombang delta terlihat pada Gambar 2.8:

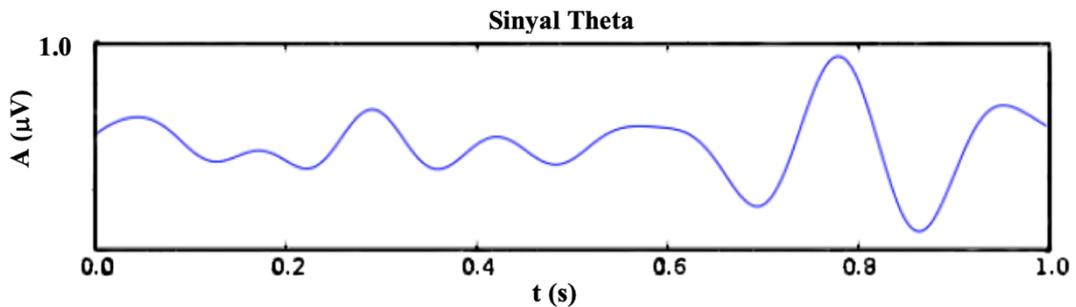
Dari gambar sinyal delta memperlihatkan bahwa memiliki gambaran bentuk sinyal yang landai. Sinyal tersebut tidak memiliki lembah dan puncak yang signifikan. Dari sinyal delta, banyaknya puncak tidak lebih dari tiga pada tiap sekon. Ini menggambarkan bahwa sinyal delta merupakan sinyal yang memiliki frekuensi paling kecil daripada macam sinyal lainnya.



Gambar 2.8 Sinyal Delta

b) Theta (θ)

Memiliki rentang frekuensi antara 4-8 Hz. Hal ini terkait dengan lamunan, bermimpi, dan kondisi tidur ringan. Pola gelombang theta seperti Gambar 2.9.

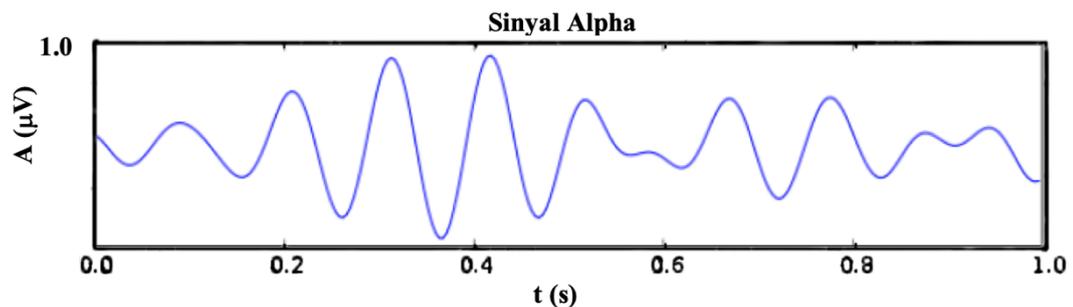


Gambar 2.9 Sinyal Theta

Dari gambar sinyal Theta, kami melihat bahwa sinyal ini memiliki lebih banyak lembah dan puncak daripada sinyal Delta. Karena sinyal ini memiliki frekuensi yang lebih besar dibandingkan sinyal tersebut.

c) Alpha (α)

Memiliki rentang frekuensi antara 8-12 Hz. Hal ini terkait dengan relaksasi tanpa perhatian dan konsentrasi. Pola gelombang Alpha terlihat pada Gambar 2.10.

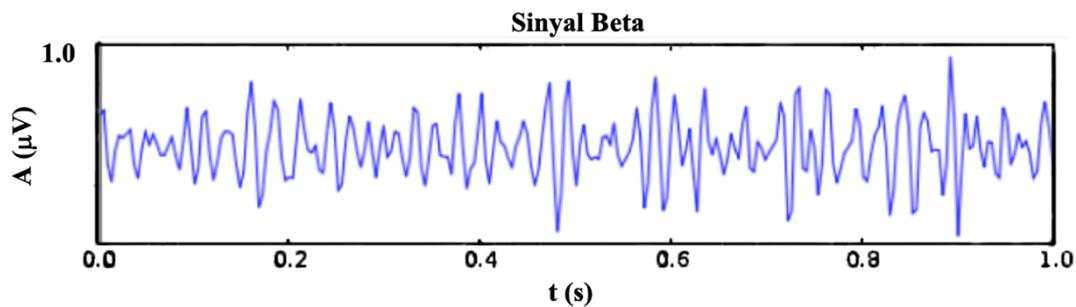


Gambar 2.10 Sinyal Alpha

Pada sinyal alpha, meskipun memiliki frekuensi lebih besar daripada sinyal delta dan theta, namun kami masih melihat bahwa sinyal ini masih tergolong sinyal dengan lembah dan puncak yang landai sama halnya seperti delta dan theta.

d) Beta (β)

Memiliki rentang frekuensi antara 12 dan 30 Hz. Hal ini disajikan dalam kondisi pikiran yang bersemangat ketika seseorang terjaga dan dengan aktivitas mental yang prima. Pola gelombang beta seperti pada Gambar 2.11.

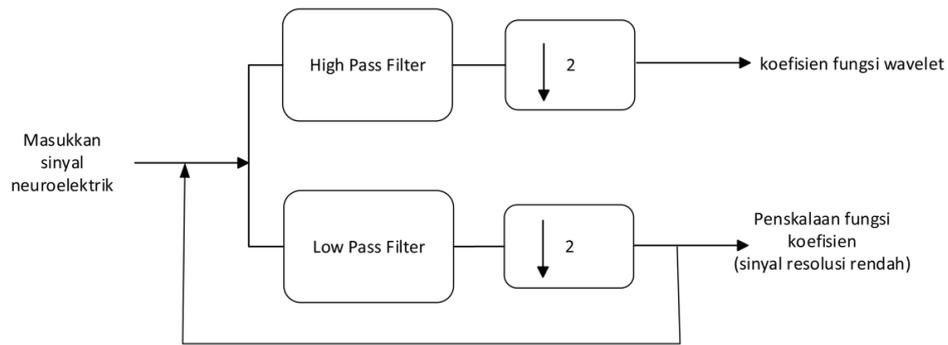


Gambar 2.11 Sinyal Beta

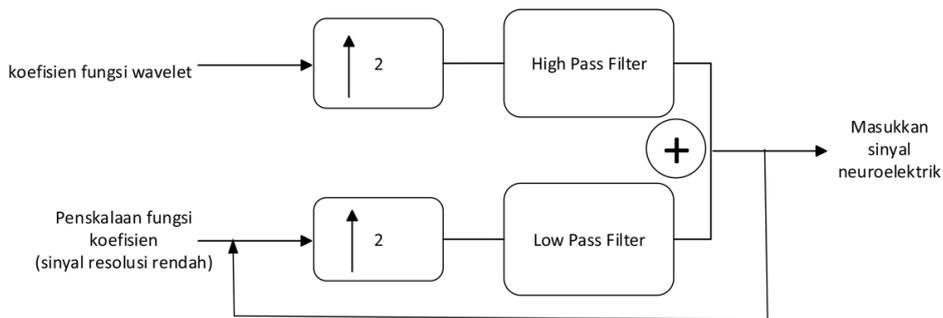
Pada sinyal beta, kami melihat memiliki perbedaan dengan sinyal-sinyal sebelumnya (delta, theta, dan alpha). Sinyal ini memiliki lembah dan puncak yang tergolong signifikan. Dan jumlah gelombang cukup banyak karena memiliki frekuensi yang lebih tinggi dibanding sinyal sebelumnya. Sinyal ini bisa digunakan sebagai indikator pengetahuan bagi manusia dalam mengetahui kondisi psikis manusia tersebut. Apabila sinyal alpha yang muncul, maka mesin cenderung akan mendeteksi bahwa manusia tersebut sedang relaksasi atau santai. Sedangkan apabila sinyal beta yang muncul, maka mesin cenderung akan mendeteksi bahwa manusia tersebut sedang senang, terjaga, dan memiliki mental prima. Studi tentang psikis dalam interaksi manusia-komputer telah hangat di baru-baru ini. Banyak metode untuk memperkirakan psikis manusia telah banyak diusulkan sebelumnya. Metode konvensional pada dasarnya memanfaatkan atribut audio dan visual untuk memodelkan respon psikis manusia, seperti berbicara, ekspresi wajah, gerak tubuh. Namun, psikis tidak selalu diwujudkan dengan cara ekspresi wajah dan suara informasi saja, melainkan juga dapat dikendalikan secara sadar dan dimodifikasi. Dengan demikian, pendekatan lain untuk mendeteksi psikis telah diusulkan dan difokuskan pada informasi fisiologis seperti pada detak jantung, konduktifitas kulit, pupil dilatasi.

2.4.1 Artefact Removal pada sinyal EEG

Pada penelitian ini menggunakan ICA untuk menghilangkan derau yang ada pada sinyal EEG. Pada (Turnip and Pardede, 2017), artefact adalah EOG (pergerakan mata dan kedip), derau otot (EMG), sinyal jantung yang bercampur dengan sinyal otak disebut artefact. Mereka menggunakan daubechies wavelet (db1) dan 3rd decomposition level seperti pada Gambar 2.12.



(a) Menghasilkan lebih banyak skala



(b) Menghasilkan lebih tinggi resolusi sinyal

Gambar 2.12 (a) Skema dekomposisi discrete wavelet (b) rekonstruksi wavelet

Pada gambar skema tersebut memberitahu bahwa dalam proses pembersihan artefact terdiri dari sinyal input yang difilter ke dalam “high pass filter” atau “low pass filter”. Kemudian, apabila sinyal input tergolong pada high pass filter, maka akan diloloskan menuju rekonstruksi sinyal neuroelektrik. Dan, apabila sinyal input tergolong pada low pass filter, maka akan diberikan koefisien fungsi skala sehingga dapat masuk ke dalam high pass filter.

2.5 Ekstraksi dan Seleksi 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 Mean, Varian, Standard Deviasi, *Power Percentage*, dan *Number of Peaks* yang telah digunakan sebelumnya oleh (Diykh et al., 2016; Li et al., 2016) pada sinyal EEG.

2.5.1 Fitur Mean

Mean adalah nilai rata-rata dari tiap kanal data untuk setiap partisipan. Pada penelitian ini, dicari nilai mean karena dapat mewakili value tiap channel. Fitur mean/rata-rata memiliki bermacam-macam bentuk seperti rata-rata geometri $= \sqrt[n]{\prod_{i=1}^n x_i}$, misal data = 6, 3, 9, 3, maka $\sqrt[4]{6 \times 3 \times 9 \times 3} = \sqrt[4]{486} = 4,7$ dan rata-rata harmoni $= n / \sum_{i=1}^n 1/x_i$, data = $4 / (1/6 + 1/3 + 1/9 + 1/3) = 4 / 0,94 = 4,24$. Namun, pada penelitian ini menggunakan rata-rata aritmatika $= (6+3+9+3)/4 = 5,25$ seperti pada Persamaan (2.1).

$$X_{Mean} = \frac{1}{n} \sum_i^n x_i \quad (2.1)$$

mean ini adalah sebagai dasar dari ekstraksi fitur pada penelitian ini. Karena pada fitur selanjutnya masih mengkaitkan fitur ini.

2.5.2 Fitur Varian

Varian adalah jumlah nilai dari rentang kuadrat antara rata-rata dan frekuensi tinggi hingga terendah/mendekati nol. Pada penelitian ini menggunakan varian sebab fitur ini dinilai dapat mewakili suatu channel data. Contoh : data = 6, 3, 9, 3. Maka, memiliki rata-rata (AM) = 5,25. Kemudian, varian = $(1/3)\{(6 - 5,25)^2 + (3 - 5,25)^2 + (9 - 5,25)^2 + (3 - 5,25)^2\}$. Selanjutnya, varian/keragaman = $(1/3)\{(0,75)^2 + (-2,25)^2 + (3,75)^2 + (-2,25)^2\} = 8,25$ seperti Persamaan (2.2).

$$X_{Var} = \frac{1}{N-1} \sum_{n=1}^N (x_n - AM)^2 \quad (2.2)$$

Pada persamaan varian ini merupakan persamaan yang menggambarkan seberapa besar rentang nilai suatu data terhadap rata-rata suatu data. Pada kasus ini, semakin tinggi nilai varian, maka semakin kurang baik data yang dihasilkan.

2.5.3 Fitur Standard Deviasi

Standard Deviasi adalah jumlah nilai akar dari rentang kuadrat antara rata-rata dan frekuensi tinggi hingga terendah/mendekati nol. Contoh : data = 6, 3, 9, 3. Maka, memiliki rata-rata (AM) = 5,25. Kemudian, memiliki varian = 8,25.

Selanjutnya, standard deviation/simpangan baku = $\sqrt{8,25} = 2,872$ seperti Persamaan (2.3).

$$X_{SD} = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (x_n - AM)^2} \quad (2.3)$$

Persamaan standard deviasi ini adalah bentuk yang lebih sederhana daripada varian. Karena nilai standard deviasi ini adalah hasil akar dari varian. Maka dari itu, sama halnya dengan varian, standard deviasi ini memiliki sifat apabila semakin tinggi nilai standard deviasi, maka semakin tidak diharapkan nilai tersebut.

2.5.4 Fitur Power Percentage

Power Percentage adalah nilai persentasi jumlah rata-rata segmentasi filterband alfa yang melebihi/kurang dari *threshold (rata-rata)* lalu dibagi nilai rata-rata segmentasi data raw (mentah). Pada penelitian ini digunakan fitur Power Percentage karena dinilai dapat mewakili satu channel data partisipan. Dimana pada ciri ini, PP memiliki kaitan pola terhadap fitur mean/rata-rata. Untuk rentang alfa = 8-12 Hz, sedangkan low beta = 12-21 Hz. Contoh: data raw= 6, 3, 9, 3. Maka, memiliki rata-rata = 5,25. Selanjutnya, misal kami memiliki data sinyal alfa = 3, 3, 3, 3. Jadi, rata-rata alfa = 3. Sampel data sinyal alfa harus sepanjang data raw juga, apabila panjang tidak sama, data tetap dijumlahkan seluruhnya, kemudian dibagi sejumlah panjang data raw. Maka dari itu, hasil nilai $PP\alpha = 3/5,25 = 0,5714$ seperti Persamaan (2.4).

$$PP\alpha = \frac{\sum_{f\alpha} P(f)}{\sum_{f=f_1}^{f_2} P(f)}, f\alpha \in [8,12] \quad (2.4)$$

Persamaan power percentage ini merupakan persamaan yang melibatkan dua sinyal. Dua sinyal tersebut adalah sinyal awal dan sinyal hasil filter band alpha atau beta. Setiap rata-rata kedua sinyal tersebut dibandingkan antara sinyal hasil filter dan sinyal awal.

2.5.5 Fitur Number of Peaks

Number of Peaks adalah jumlah peak/puncak yang ada pada setiap kanal (Scholkmann et al., 2012). Pada penelitian ini digunakan fitur number of peaks

dikarenakan setiap kondisi partisipan memiliki jumlah nilai puncak yang berbeda (khas) seperti Persamaan (2.5).

$$\sigma_i = \frac{1}{\lambda - 1} \sum_{k=1}^{\lambda} [(m_{k,i} - \frac{1}{\lambda} \sum_{k=1}^{\lambda} m_{k,i})^2]^{\frac{1}{2}}, \text{ for } i \in \{1, 2, \dots, N\} \quad (2.5)$$

Persamaan number of peaks atau peak detection ini bisa digunakan sebagai tolak ukur mengenai seberapa banyak puncak pada sinyal EEG. Dimana, semakin banyak puncak memberitahukan bahwa semakin tinggi nilai frekuensi. Pada literature menuliskan bahwa nilai psikis semangat seseorang bergantung pada sinyal yang memiliki frekuensi seperti sinyal beta keatas (12-30 Hz). Pada fitur ini, semakin tinggi nilai number of peaks, maka semakin diharapkan nilai tersebut dalam mencegah terjadinya gejala cybersickness.

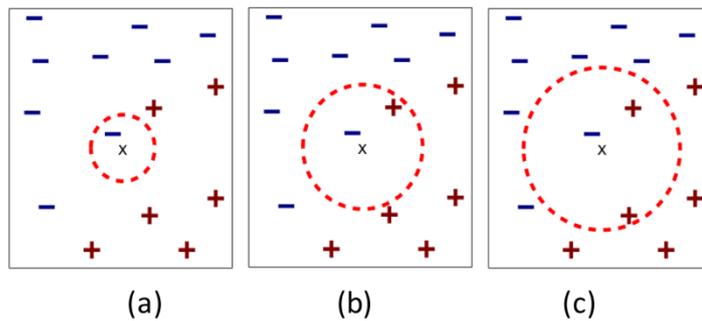
2.6 Metode Klasifikasi

Teori metode klasifikasi atau pengelompokan dibagi menjadi metode supervised (terlatih/pelabelan) dan unsupervised (tidak terlatih) serta semi-supervised. Pada penelitian ini menggunakan model klasifikasi k-NN dan Naïve Bayes. Dimana, kedua model tersebut adalah model yang terlatih. Untuk model tidak terlatih salah satu contohnya adalah K-Means. Untuk model ini dapat menggunakan metode pengelompokan (*clustering*). Metode ini bias digunakan sebagai pengelompokan dokumen, data media social, segmentasi citra, dan lain sebagainya.

Kemudian, untuk model semi-supervised (regression) adalah pembelajaran pada data pelatihan yang mempunyai label kelas dan tidak mempunyai label kelas. Metode ini bisa digunakan sebagai predictor nilai kontinu, indeks saham, cuaca, penjualan, dan lain sebagainya. Kami menggunakan metode supervised karena mengacu pada judul yaitu Klasifikasi. Metode supervised ini dapat digunakan tidak hanya untuk klasifikasi, tetapi juga pengenalan (*recognition*) juga. Model ini bisa digunakan sebagai predictor label kelas (nilai diskrit), suara, karakter, wajah, penyakit, dan lain sebagainya.

2.6.1 K-NN

K-NN adalah metode untuk mencari nilai terdekat. Dengan basis pendekatan algoritma Euclidian Distance. Pada penelitian ini, digunakan K-NN untuk mengetahui bahwa data adalah baseline atau cybersickness. Untuk setiap data poin x , jarak antara x dengan semua data poin pada training set. Selanjutnya, diurutkan berdasarkan jarak terkecil. Kemudian, diperlukan pengambilan sejumlah k -data poin dengan jarak terkecil x . Maka, dapat ditentukan label kelas dari x berdasarkan mayoritas kelas pada k -data poin. Berikut penjelasan berupa diagram blok pada Gambar 2.13.



Gambar 2.13 (a) $k=1$ (b) $k=2$ (c) $k=3$ -nearest neighbor

Selanjutnya adalah keterangan k -NN, apabila nilai k terlalu kecil, maka sensitive terhadap data noise. Dan, apabila nilai k terlalu besar, maka ada kemungkinan data poin dari kelas yang lain menjadi tetangga terdekat.

Persamaan dari metode ini menggunakan Minkowski Distance. Dimana, persamaan tersebut adalah bentuk umum dari euclidian distance Persamaan (2.6).

$$dist = \left(\sum_{k=1}^n |p_k - q_k|^r \right)^{\frac{1}{r}} \quad (2.6)$$

Keterangan n adalah jumlah atribut, p_k dan q_k adalah atribut ke k dari data poin p dan q . Sedangkan $r = 1$ adalah city block (Manhattan) distance, $r = 2$ adalah Euclidean distance. Perbedaan skala yang besar pada atribut menyebabkan atribut bernilai besar menjadi lebih dominan. Hal ini dapat ditangani dengan proses normalisasi terlebih dahulu.

2.6.2 Naïve Bayes

Naïve Bayes adalah metode klasifikasi 10 besar terbaik (Jiang et al., 2018). Metode ini merupakan pengambil keputusan dari probabilitas terhadap suatu aturan. Dalam pengenalan cybersickness, digunakan Persamaan (2.7).

$$P(c|x) = \frac{P(x|c)P(c)}{P(x)} \quad (2.7)$$

keterangan:

x = data dengan class yang belum diketahui

c = hipotesis data

P(x|c) = probabilitas berdasarkan kondisi pada hipotesis

P(x) = probabilitas data class

P(c|x) = Probabilitas hipotesis berdasarkan kondisi

P(c) = probabilitas hipotesis

Pada persamaan naïve bayes ini memiliki tabel contoh frekuensi dalam proses klasifikasi. Berikut adalah contoh tabel ketika menentukan keputusan dari berbagai data yang ditampilkan seperti Tabel 2.1.

Tabel 2.1 Contoh Tabel Frekuensi Naive Bayes

Frequency Table		Play Golf (hipotesis)	
		Yes	No
Outlook (data)	Sunny	3	2
	Overcast	4	0
	Rainy	2	3

Pada Tabel berikutnya merupakan tabel yang bisa digunakan sebagai peraturan menentukan nilai probabilitas/kemungkinan seperti Tabel 2.2.

Tabel 2.2 Contoh Tabel Likelihood Naïve Bayes

Likelihood Table		Play Golf		
		Yes	No	
Outlook	Sunny	3/9	2/5	5/14
	Overcast	4/9	0/5	4/14
	Rainy	2/9	3/5	5/14
		9/14	5/14	

Keterangan: $P(x|c) = \square$ $P(c) = \square$ $P(x) = \square$

$$P(c|x) = P(\text{Yes}|\text{Sunny}) = 0,33 \times 0,64 / 0,36 = 0,60$$

Selanjutnya, dalam melangkah ke proses klasifikasi, perlu dilakukan prediksi dari metode Naïve Bayes. Berikut adalah bentuk umum persamaan Naïve Bayes pada Persamaan (2.8) dan (2.9).

$$P(c|x_1, \dots, X_n) = P(C) \prod_{i=1}^n P(X_i|C) \quad (2.8)$$

$$P(c|X) = P(x_1|c)P(x_2|c) \dots P(x_n|c)P(C) \quad (2.9)$$

Dimana, setiap variabel dapat dikembangkan untuk mencari probabilitas yang lebih akurat. Seperti mencari probabilitas mahasiswa yang mendapatkan beasiswa. Maka, diperlukan tabel frekuensi dengan variabel nilai akademik, penghasilan orang tua, saudara yang ditanggung orang tua, dan lain sebagainya.

2.7 Validitas Stimulus

Validitas stimuli adalah aspek penting penelitian ini seperti Tabel 2.3.

Tabel 2.3 Kuesioner berdasarkan tingkat keparahan gejala cybersickness

Gejala	Level			
	Tidak ada	Sedikit	Sedang	Parah
Ketidaknyamanan secara umum (1)	Tidak ada	Sedikit	Sedang	Parah
Lelah (2)	Tidak ada	Sedikit	Sedang	Parah
Sakit Kepala (3)	Tidak ada	Sedikit	Sedang	Parah
Ketegangan Mata (4)	Tidak ada	Sedikit	Sedang	Parah
Susah untuk Fokus (5)	Tidak ada	Sedikit	Sedang	Parah
Air Liur Meningkat (6)	Tidak ada	Sedikit	Sedang	Parah
Berkeringat (7)	Tidak ada	Sedikit	Sedang	Parah
Mual (8)	Tidak ada	Sedikit	Sedang	Parah
Susah konsentrasi (9)	Tidak ada	Sedikit	Sedang	Parah
Kepala merasa penuh (10)	Tidak ada	Sedikit	Sedang	Parah
Penglihatan blur (11)	Tidak ada	Sedikit	Sedang	Parah
Pusing saat mata terbuka (12)	Tidak ada	Sedikit	Sedang	Parah
Pusing saat mata tertutup (13)	Tidak ada	Sedikit	Sedang	Parah
Vertigo (14)	Tidak ada	Sedikit	Sedang	Parah
Ketidaknyamanan perut (15)	Tidak ada	Sedikit	Sedang	Parah
Bersendawa (16)	Tidak ada	Sedikit	Sedang	Parah

Keterangan:

Mual = (1) + (6) + (7) + (8) + (12) + (13) + (14) + (15) + (16).

Penglihatan = (2) + (3) + (4) + (5) + (9) + (10) + (11).

Tidak ada = 0

Sedikit = 1

Sedang = 2

Parah = 3

Pada penelitian ini digunakan validasi selain objektif, digunakan juga validasi subjektif yaitu menggunakan kuesioner. Untuk membuat kuesioner, pada penelitian sebelumnya menggunakan format kuesioner Simulator Sickness Questionnaire (SSQ) (Kennedy and Fowlkes, 1992) seperti pada Tabel 2.4.

Tabel 2.4 Kuesioner gejala cybersickness berdasarkan pengelompokan

Gejala	Mual	Penglihatan	Kekacauan
Ketidaknyamanan secara umum (1)	*	*	
Lelah (2)		*	
Sakit Kepala (3)		*	
Ketegangan Mata (4)		*	
Susah untuk Fokus (5)		*	*
Air Liur Meningkat (6)	*		
Berkeringat (7)	*		
Mual (8)	*		*
Susah konsentrasi (9)	*	*	
Kepala merasa penuh (10)			*
Penglihatan blur (11)		*	*
Pusing saat mata terbuka (12)			*
Pusing saat mata tertutup (13)			*
Vertigo (14)			*
Ketidaknyamanan perut (15)	*		
Bersendawa (16)	*		
Total	[1]	[2]	[3]

Keterangan:

Mual = [1] * 9,54

Penglihatan = [2] * 7,58

Kekacauan = [3] * 13,92

Total Nilai = ([1] + [2] + [3]) * 3,74

Pada Tabel 2.3 ini, memberitahu bahwa seberapa besar tingkat keparahan ketika melihat stimuli game 3D. Terdapat 4 level pada kuesioner ini, yaitu tidak ada (none=0), sedikit (slight=1), sedang (moderate=2), dan parah (severe=3). Kemudian, setiap gejala memiliki kelompok perhitungan kelas masing-masing. Untuk kelompok 2 kelas, kelas pertama adalah mual (nausea), dan kelas kedua adalah penglihatan (oculomotor) seperti pada Tabel 2.4. Sedangkan kelompok 3 kelas, kelas pertama adalah mual (nausea), kelas kedua adalah penglihatan (oculomotor), dan kelas kekacauan (disorientasi)

Dari 2 macam perhitungan tersebut, kami menggunakan kelompok perhitungan 3 kelas (Tabel 2.4) yang mempunyai total nilai. Kami memilih menggunakan perhitungan ini karena memanfaatkan kelas kekacauan pada kepala (disorientasi) juga.

Halaman ini sengaja dikosongkan

BAB 3

METODOLOGI PENELITIAN

3.1 Tahapan Penelitian

Untuk mencapai tujuan yang diharapkan dalam penelitian tesis ini, kerangka kerja dibuat pada Gambar 3.1. Langkah pertama adalah mempelajari literatur untuk mempelajari isu terkini dan penelitian tentang sinyal EEG terutama pada pengenalan gejala cybersickness pada manusia. Kemudian perancangan algoritma yang diusulkan adalah klasifikasi cybersickness berdasarkan sinyal EEG dengan menggunakan metode Naïve Bayes. Preprocess bahan baku adalah menggunakan filter Chebysev Type II dan ekstraksi fitur *mean*, *varian*, *standard deviasi*, *power percentage* dan *number of peaks*. Dilanjutkan dengan uji coba dan analisis terhadap hasil metode yang diusulkan yaitu perbandingan K-NN dan Naïve Bayes. Dan diakhiri dengan visualisasi seperti pada Gambar 3.1.



Gambar 3.1 Tahapan Metodologi Penelitian

3.2 Studi Pustaka

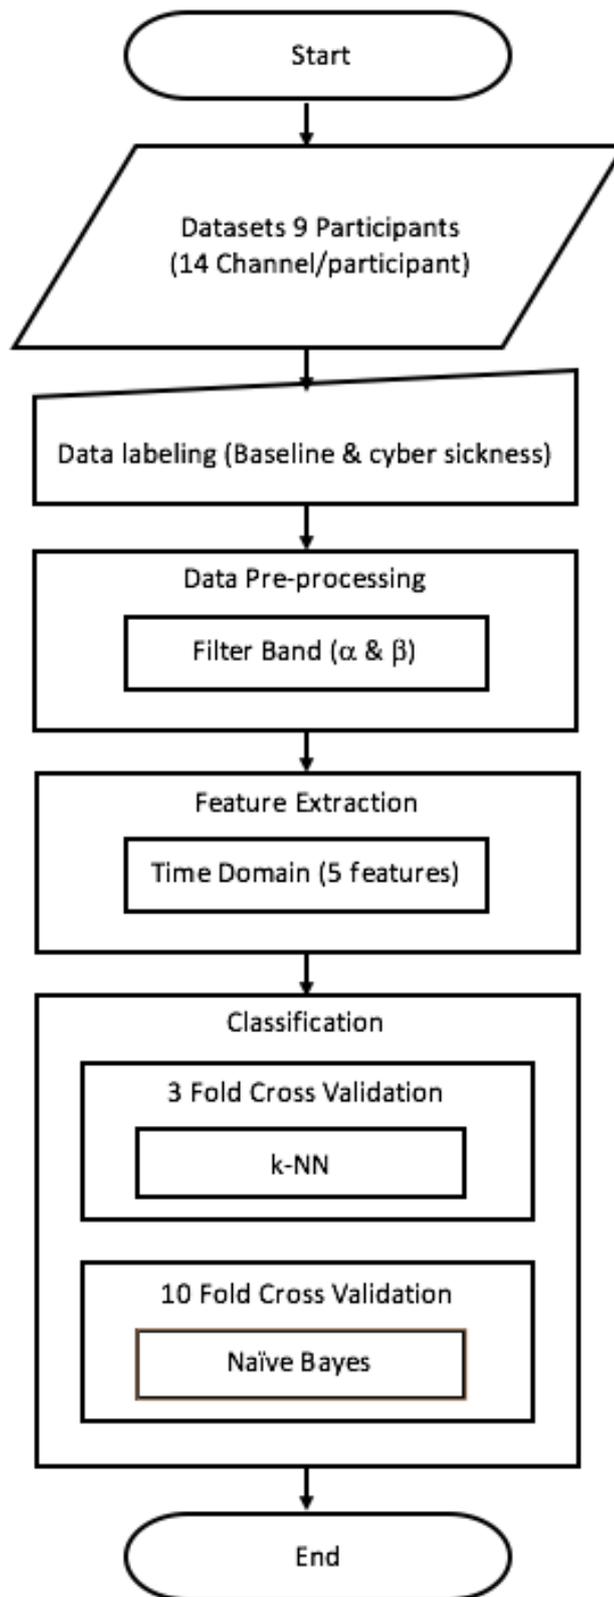
Pada sub bagian ini bertujuan untuk mempelajari dan mengikuti perkembangan penelitian yang berkaitan dengan klasifikasi data sinyal EEG. Dalam mempelajari metode dari penelitian sebelumnya, sangat membantu dalam membangun kerangka kerja baru. Studi literatur yang dilakukan meliputi:

- a. Menganalisa sinyal EEG berdasarkan gejala cybersickness.
- b. Dasar teoritis yang memberikan pengetahuan tentang analisis data suatu sinyal, ekstraksi dan pemilihan fitur serta klasifikasi data sinyal EEG terutama gejala cybersickness.
- c. Penelitian tentang proses pergeseran menggunakan filter chebyshev type-II.
- d. Ekstraksi fitur dan pemilihan sinyal berdasarkan *Feature Selection*.
- e. Klasifikasi dengan menggunakan metode pembelajaran K-NN dan Naïve Bayes.

3.3 Perancangan Algoritma

Dalam bab ini kita membahas kerangka penelitian. Dimana langkah penelitian didasarkan pada bagaimana proses penerapan metode Filter Chebyshev Type-II pada sinyal EEG bertujuan untuk mendapatkan bentuk sinyal yang dibentuk menjadi sinyal baru disebut sinyal alfa dan sinyal beta. Hasil sinyal tersebut akan diterapkan pada metode ekstraksi fitur, dimana metode ini didasarkan pada metode statistik dengan tujuan mencari ciri sinyal sebagai dasar pengetahuan cybersickness. Selanjutnya, hasil setiap ekstraksi statistik fitur ini digunakan sebagai langkah awal pengenalan cybersickness. Proses akhir dari digram alur ini adalah untuk menghitung akurasi klasifikasi dengan menggunakan klasifikasi k-NN dan Naïve Bayes.

Bab ini menjelaskan pemahaman dan pengolahan dataset dalam pemilihan saluran yang diterapkan dalam penelitian ini. Kemudian proses pergeseran atau perubahan data sinyal EEG menggunakan Chebyshev Type-II dan penggalian fitur menggunakan ekstraksi fitur dan klasifikasi menggunakan metode K-NN dan Naïve Bayes. Diagram alir untuk metode penelitian ini dapat dilihat pada Gambar 3.2.



Gambar 3.2 Diagram alur klasifikasi berdasarkan *preprocessing* dan ekstraksi

Setelah menjelaskan diagram alur, diperlukan pemahaman tentang dataset. Dataset pada penelitian ini menggunakan data sekunder, yaitu data hasil pengukuran Alfi Zuhria Khoirunnisa (Khoirunnisaa et al., 2018; Pane et al., 2018).

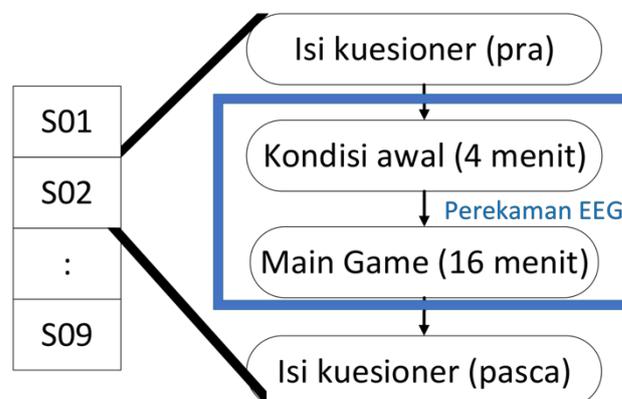
3.3.1 Pemahaman Dataset

Dataset yang digunakan dalam penelitian ini adalah sinyal data EEG berdasarkan alat emotive epoch+ seperti pada Tabel 3.1.

Tabel 3.1 Karakteristik dataset berdasarkan ukuran dan deskripsi

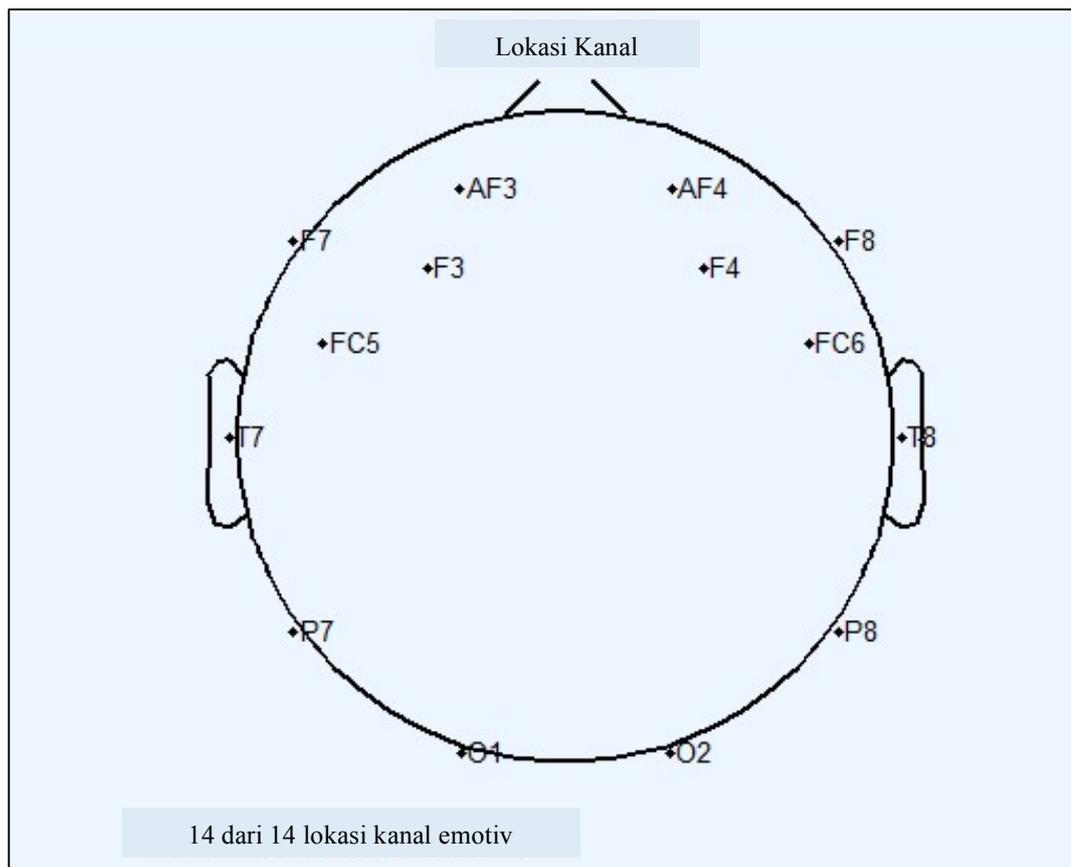
Name	Size	Description
data tiap subjek	14x20x60x256	jumlah kanal x lama bermain video game 3D (s) x data (fs)
label	14x4x60x256	label baseline (jumlah kanal x 4 menit pertama bermain game 3D (s) x data (fs))
	14x4x60x256	label cybersickness (jumlah kanal x 4 menit terakhir bermain game 3D (s) x data (fs))

Proses pencatatan data pada masing-masing peserta dengan memberi stimulus/kondisi bermain *game Mirror's Edge*, dimana setiap *game* berdurasi 20 menit dengan downsampled menjadi 256 Hz. Selain dari dataset, pada penelitian sebelumnya dilakukan pengisian kuesioner Simulator Sickness Questionnaire (SSQ). Pada kuesioner tersebut menunjukkan nilai subjektif yang merupakan hasil dari setiap partisipan. Karena kuesioner merupakan data subjektif, sedangkan emotive merupakan data fisiologis (objektif), maka kami menggunakan data fisiologis yang bisa digunakan sebagai pengukur cybesickness. Untuk setiap pengambilan rekaman sinyal otak pada partisipan seperti pada Gambar 3.3.



Gambar 3.3 Detail dari skenario game

Dalam studi ini, saluran-saluran telah ditentukan setelah beberapa uji coba berjalan, dimulai dengan keseluruhan kanal, memilih beberapa kanal (feature selection) untuk keseluruhan sampai terakhir memilih saluran berdasarkan kelas yang juga merupakan *baseline* atau *cybersickness*. Dimana saluran ini didasarkan pada beberapa area kepala seperti area dahi, area di belakang telinga kiri / kanan dan pada tengkuk leher yang memiliki informasi sangat penting dalam mengenali gejala *cybersickness* berdasarkan sinyal EEG menggunakan kanal AF3, F7, F3, Fc5, T7, P7, O1, O2, P8, T8, Fc6, F4, F8, dan AF4 seperti pada Gambar 3.4.

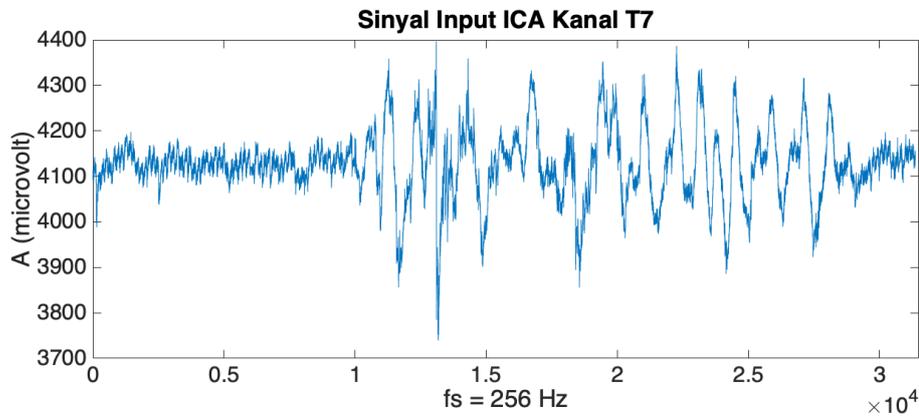


Gambar 3.4 Posisi 14 *Channel* sesuai alat emotive epoch

Proses penentuan lokasi kanal terdapat pada tahap pembersihan sinyal menggunakan Independent Component Analyst (ICA). Proses ini dilakukan oleh Alfi Zuhriya Khoirunnisa. Setelah itu, baru data diolah oleh penyusun tesis menggunakan 5 macam ekstraksi fitur.

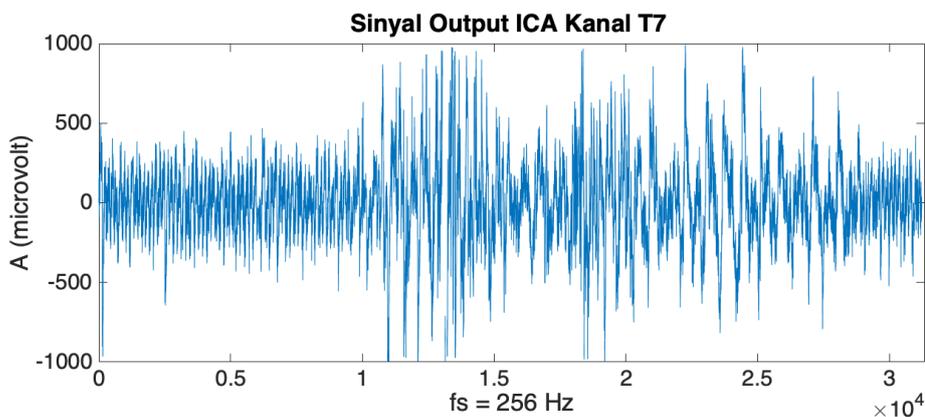
3.3.2 Proses filtering menggunakan Independent Component Analyst

Pada tahap ini, data difilter menggunakan ICA untuk mengurangi noise yang ada pada data EEG ketika proses pengambilan data. Setelah data diambil dari alat emotive, maka akan menghasilkan data raw seperti Gambar 3.5.



Gambar 3.5 Data Raw sebelum diproses ICA

Selanjutnya, kami melakukan proses tahapan artefact removal. Setelah data raw dari alat emotive didapat, kami menentukan lokasi kanal pada model. Kemudian, kami memfilter menggunakan FIR (Finite Invariant Response). Setelah itu, kami memproses menggunakan ICA (Independent Component Analysis). Pada proses ini, data raw dibersihkan dari artefact seperti sinyal EOG, EMG dan lain sebagainya pada sinyal EEG, dimana data masukkan ICA (input ICA) semula berjumlah 31363 sample menjadi 31232 sample setelah diproses ICA (output ICA). Ini membuktikan bahwa terdapat penghilangan sample sejumlah 131 sample yang dianggap sebagai artifact. Berikut contoh data sinyal EEG bersih dari artefact pada Gambar 3.6.



Gambar 3.6 Data EEG setelah diproses ICA

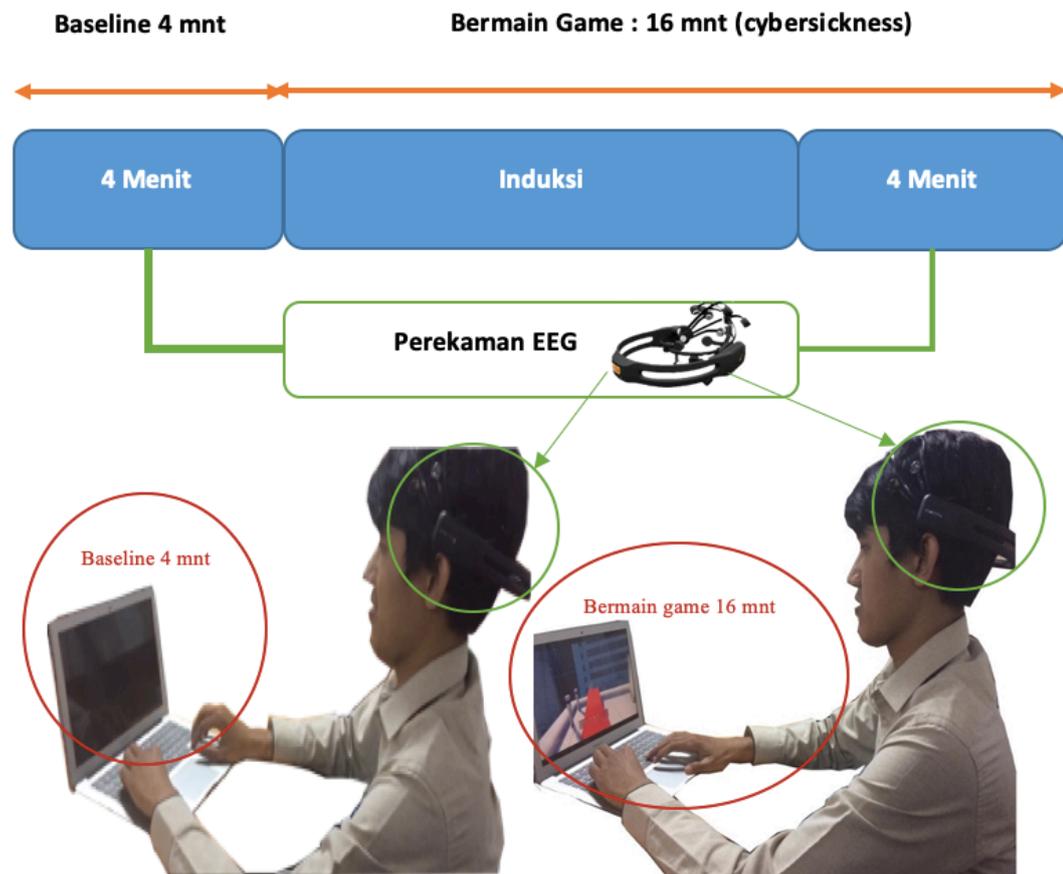
Dari sebelum diproses ICA sampai dengan setelah diproses ICA menggunakan high pass filter. Apabila ada data sinyal yang masuk pada low pass filter, maka program akan looping kembali kemudian diproses scaling function coefficient.

3.4 Pra-pemrosesan Data

Pada tahap ini, terdapat 3 tahap. Tahap pertama yaitu pelabelan data (baseline/cybersickness). Tahap kedua adalah segmentasi data (4 menit awal dan dari 16 menit selanjutnya bermain game diambil 4 menit terakhir). Dan, tahap ketiga merupakan filter band menggunakan filter Chebyshev type-II.

3.4.1 Pelabelan Data

Pada tahapan ini data sinyal EEG diberikan label ‘baseline’ dan “cybersickness” seperti pada Gambar 3.7.

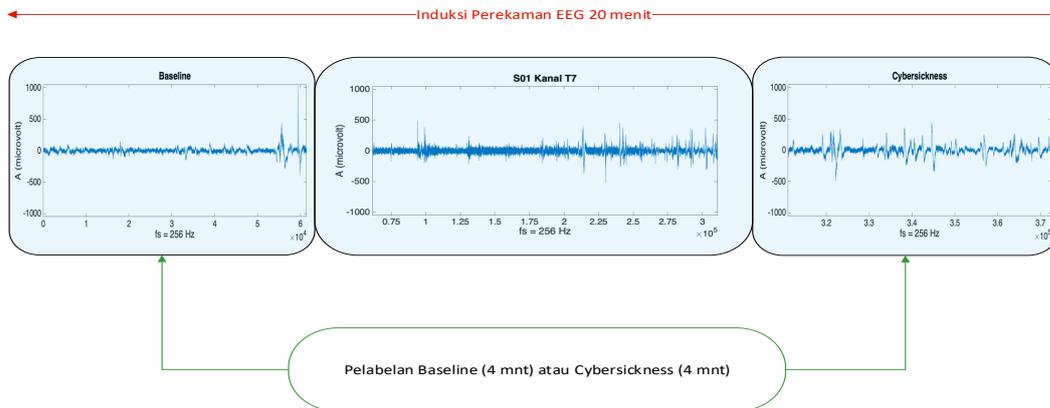


Gambar 3.7 Pelabelan baseline dan cybersickness pada data EEG

Label baseline adalah 4 menit awal ketika partisipan menggunakan alat emotiv tanpa melakukan aktifitas apapun dan tidak diberikan stimuli apapun juga. Label cybersickness adalah dari 20 menit menggunakan alat emotive, diambil 4 menit terakhir saja untuk diberi label cybersickness. Proses ini dilakukan secara manual sebelum dilakukan percobaan apapun. Dimana percobaan setelahnya adalah segmentasi.

3.4.2 Segmentasi Data

Setelah diberi label, selanjutnya sinyal EEG disegmentasi dari 20 menit menjadi 4 menit awal dan 4 menit akhir. Jumlah sampel data dengan frekuensi sampling $f = 256 \text{ Hz}$ untuk 4 menit adalah $4 \times 60\text{s} \times 256 = 61440$ sampel. Berikut contoh gambar segmentasi data pada Gambar 3.8.

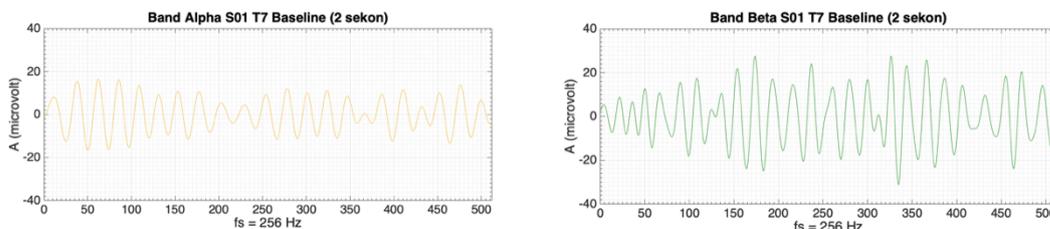


Gambar 3.8 Segmentasi data EEG

Proses ini merupakan awal mula data sebelum diuraikan ke dalam band sinyal alpha dan low beta.

3.4.3 Band Pass Filter

Setelah itu difilter menggunakan Chebysev Type II untuk mengurai menjadi sinyal alfa dan beta. Dimana, sinyal alfa memiliki rentang 8-12 Hz. Selanjutnya, sinyal low beta memiliki rentang 12-21 Hz seperti Gambar 3.9.



Gambar 3.9 Filter band alfa dan beta data EEG

Daripada filter butterworth, kami memilih proses Chebyshev type II karena dinilai lebih bagus dan dapat meminimalkan ripple pada model ini. Selain itu, proses ini sebenarnya dapat juga menggunakan Discrete Wavelet Transform, sebelum menuju ke proses ekstraksi fitur. Tetapi, kami tetap memilih Chebyshev Type II karena dinilai memiliki output keluaran band alpha dan beta lebih baik dibandingkan filter tersebut.

3.5 Ekstraksi Fitur

Mean, varian, standard deviasi, power percentage dan number of peaks adalah fitur yang akan digunakan pada penelitian ini. Dari semua fitur, mean sangat erat kaitannya dengan fitur varian, standard deviasi, dan power percentage karena basis dari ketiga fitur tersebut adalah rata-rata. Berbeda dengan number of peak, fitur ini bermaksud untuk menghitung jumlah puncak pada suatu data sinyal. Ini bertujuan juga agar dapat mengetahui penurunan suatu data tersebut. Dari kelima fitur tersebut, fitur ini yang tidak memiliki kaitan dengan fitur mean.

3.5.1 Fitur Mean

Mean adalah nilai rata-rata dari tiap kanal data untuk setiap partisipan. Pada penelitian ini, dicari nilai mean karena dapat mewakili value tiap channel. Fitur mean/rata-rata memiliki bermacam-macam bentuk seperti rata-rata geometri = $\sqrt[n]{\prod_{i=1}^n x_i}$, misal data = $[x_1, x_2, \dots, x_n]$, maka $\sqrt[n]{x_1 \cdot x_2 \cdot \dots \cdot x_n} = \sqrt[n]{x^n} = \mu_g$ dan rata-rata harmoni = $n / \sum_{i=1}^n 1/x_i$, data = $n / (1/x_1 + 1/x_2 + \dots + 1/x_n) = n / ((x_1 \cdot x_2 \cdot \dots \cdot x_n) / (x_1 + x_1 \cdot x_2 \cdot \dots \cdot x_n / x_2 + \dots + x_1 \cdot x_2 \cdot \dots \cdot x_n / x_n)) = \mu_h$ Namun, pada penelitian ini menggunakan rata-rata aritmatika = $(x_1 + x_2 + \dots + x_n) / n = \mu_a$ seperti pada Persamaan (3.1).

$$X_{Mean} = \frac{1}{n} \sum_i^n x_i \quad (3.1)$$

Persamaan mean ini adalah sebagai dasar dari ekstraksi fitur pada penelitian ini. Karena pada fitur selanjutnya masih mengkaitkan fitur ini. Dan, hanya fitur number of peaks saja yang tidak memiliki kaitan.

3.5.2 Fitur Varian

Varian adalah jumlah nilai dari rentang kuadrat antara rata-rata dan frekuensi tinggi hingga terendah/mendekati nol. Pada penelitian ini menggunakan

varian sebab fitur ini dinilai dapat mewakili suatu channel data. Contoh: data = $[x_1, x_2, \dots, x_n]$. Maka, memiliki rata-rata (AM) = μ_a . Kemudian, varian = $\{1/(n-1)\} \{(x_1 - \mu_a)^2 + (x_2 - \mu_a)^2 + \dots + (x_n - \mu_a)^2\}$. Selanjutnya, varian/keragaman = $\{1/n-1\} \{(a)^2 + (b)^2 + \dots + (k)^2\} = x_{var}$ seperti Persamaan (3.2).

$$X_{var} = \frac{1}{N-1} \sum_{n=1}^N (x_n - AM)^2 \quad (3.2)$$

Pada persamaan varian ini merupakan persamaan yang menggambarkan seberapa besar rentang nilai suatu data terhadap rata-rata suatu data. Pada kasus ini, semakin tinggi nilai varian, maka semakin kurang baik data yang dihasilkan.

3.5.3 Fitur Standard Deviasi

Standard Deviasi adalah jumlah nilai akar dari rentang kuadrat antara rata-rata dan frekuensi tinggi hingga terendah/mendekati nol. Data = $[x_1, x_2, \dots, x_n]$. Maka, memiliki rata-rata (AM) = μ_a . Kemudian, memiliki varian = x_{var} . Kemudian, standard deviation/simpangan baku = $\sqrt{x_{var}} = X_{SD}$ seperti Persamaan (3.3).

$$X_{SD} = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (x_n - AM)^2} \quad (3.3)$$

Persamaan standard deviasi ini adalah bentuk yang lebih sederhana daripada varian. Karena nilai standard deviasi ini adalah hasil akar dari varian. Maka dari itu, sama halnya dengan varian, standard deviasi ini memiliki sifat apabila semakin tinggi nilai standard deviasi, maka semakin tidak diharapkan nilai tersebut.

3.5.4 Fitur Power Percentage

Power Percentage adalah nilai persentasi jumlah rata-rata segmentasi filterband alfa yang melebihi/kurang dari *threshold (rata-rata)* lalu dibagi nilai rata-rata segmentasi data raw (mentah). Pada penelitian ini digunakan fitur Power Percentage karena dinilai dapat mewakili satu channel data partisipan. Dimana pada ciri ini, PP memiliki kaitan pola terhadap fitur mean/rata-rata. Untuk rentang alfa = 8-12 Hz, sedangkan low beta = 12-21 Hz. Contoh: data raw = $[x_1, x_2, \dots, x_n]$. Maka, memiliki rata-rata = μ_a . Selanjutnya, kami memiliki data alfa = $[x_{\alpha 1}, x_{\alpha 2}, \dots, x_{\alpha n}]$. Jadi,

rata- rata alfa = μ_α . Sampel data sinyal alfa harus sepanjang data raw juga, apabila panjang tidak sama, data tetap dijumlahkan seluruhnya, kemudian dibagi sejumlah panjang data raw. Maka dari itu, hasil $PP = \mu_\alpha/\mu_a = PP_\alpha$ seperti Persamaan (3.4).

$$PP_\alpha = \frac{\sum_{f_\alpha} P(f)}{\sum_{f=f_1}^{f_2} P(f)}, f_\alpha \in [8,12] \quad (3.4)$$

Persamaan power percentage ini merupakan persamaan yang melibatkan dua sinyal. Dua sinyal tersebut adalah sinyal awal dan sinyal hasil filter band alpha atau beta. Setiap rata-rata kedua sinyal tersebut dibandingkan antara sinyal hasil filter dan sinyal awal.

3.5.5 Fitur Number of Peaks

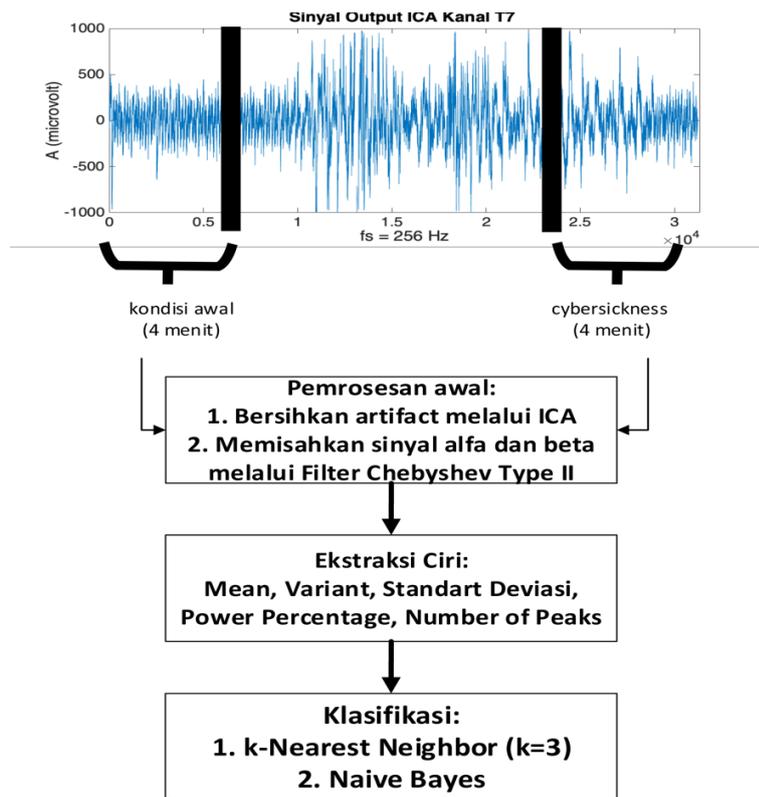
Number of Peaks adalah jumlah peak/puncak yang ada pada setiap kanal (Scholkmann et al., 2012). Pada penelitian ini digunakan fitur number of peaks dikarenakan setiap kondisi partisipan memiliki jumlah nilai puncak yang berbeda seperti Persamaan (3.5).

$$\sigma_i = \frac{1}{\lambda - 1} \sum_{k=1}^{\lambda} [(m_{k,i} - \frac{1}{\lambda} \sum_{k=1}^{\lambda} m_{k,i})^2]^{\frac{1}{2}}, for i \in \{1, 2, \dots, N\} \quad (3.5)$$

Persamaan number of peaks atau peak detection ini bisa digunakan sebagai tolak ukur mengenai seberapa banyak puncak pada sinyal EEG. Dimana, semakin banyak puncak memberitahu bahwa semakin tinggi nilai frekuensi. Pada literature memberitahu bahwa nilai psikis semangat seseorang bergantung pada sinyal yang memiliki frekuensi seperti sinyal beta ke atas (12-30 Hz). ada fitur ini, semakin tinggi nilai number of peaks ini, maka semakin diharapkan nilai tersebut dalam mencegah terjadinya cybersickness.

3.6 Klasifikasi

Pada percobaan kali ini kami menggunakan 2 metode. Metode pertama menggunakan K-NN. Sedangkan, percobaan kedua menggunakan Naive Bayes. Dimana kedua metode tersebut adalah tergolong metode supervised (terlatih) yang menggunakan label sebelum diklasifikasi seperti Gambar 3.10.



Gambar 3.10 Tahap urutan metode penelitian

Pada proses klasifikasi disini, kami mencoba menggunakan metode k-NN dan Naïve Bayes. Pertimbangan kami menggunakan kedua klasifikasi tersebut dirasa memiliki variabel yang dapat dibandingkan satu sama lainnya yaitu pengambilan keputusan. Pada banyak literature tentang cybersickness, kebanyakan tidak memberikan proses klasifikasi didalamnya dikarenakan tema ini masih baru. Maka dari itu, penelitian ini adalah langkah awal yang bisa digunakan sebagai dasar pengetahuan pengenalan pola cybersickness.

3.6.1 K-NN

K-NN adalah metode untuk mencari nilai terdekat. Dengan basis pendekatan algoritma Euclidian Distance. Pada penelitian ini, digunakan K-NN untuk mengetahui bahwa data adalah baseline atau cybersickness. Selanjutnya adalah keterangan k-NN, apabila nilai k terlalu kecil, maka sensitive terhadap data noise. Dan, apabila nilai k terlalu besar, maka ada kemungkinan data poin dari kelas yang lain menjadi tetangga terdekat. Persamaan dari metode ini menggunakan Minkowski Distance. Dimana, persamaan tersebut adalah bentuk umum dari eucliden distance seperti Persamaan (3.6).

$$dist = \left(\sum_{k=1}^n |p_k - q_k|^r \right)^{\frac{1}{r}} \quad (3.6)$$

Keterangan n adalah jumlah atribut, p_k dan q_k adalah atribut ke k dari data poin p dan q. Sedangkan $r = 1$ adalah city block (Manhattan) distance, $r = 2$ adalah Euclidean distance. Perbedaan skala yang besar pada atribut menyebabkan atribut bernilai besar menjadi lebih dominan. Hal ini dapat ditangani dengan proses normalisasi terlebih dahulu.

3.6.2 Naïve Bayes

Naïve Bayes adalah metode klasifikasi 10 besar terbaik (Jiang et al., 2018). Metode ini merupakan pengambil keputusan dari probabilitas terhadap suatu aturan. Naïve Bayes merupakan metode klasifikasi yang berakar pada teorema Bayes. Dalam melangkah ke proses klasifikasi, perlu dilakukan prediksi menggunakan metode Naïve Bayes. Berikut adalah bentuk umum persamaan Naïve Bayes pada Persamaan (3.7) dan (3.8).

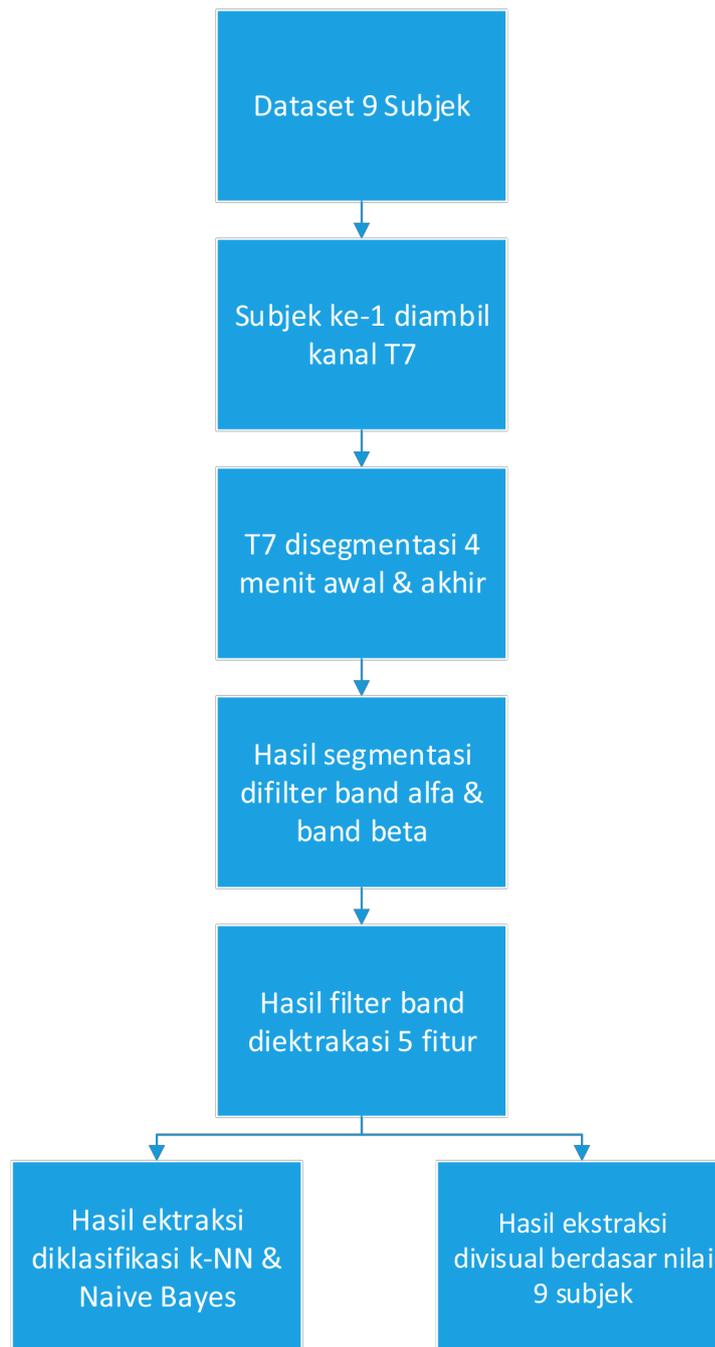
$$P(c|x_1, \dots, X_n) = P(C) \prod_{i=1}^n P(X_i|C) \quad (3.7)$$

$$P(c|X) = P(x_1|c)P(x_2|c) \dots P(x_n|c)P(C) \quad (3.8)$$

Dimana, setiap variabel dapat dikembangkan untuk mencari probabilitas yang lebih akurat. Seperti mencari probabilitas mahasiswa yang mendapatkan beasiswa. Maka, diperlukan tabel frekuensi dengan variabel nilai akademik, penghasilan orang tua, saudara yang ditanggung orang tua, dan lain sebagainya.

3.7 Visualisasi

Pada tahap ini akan diberikan gambaran perbedaan sinyal EEG ketika kondisi normal/*baseline* dan ketika mengalami cybersickness. Visualisasi disini, kami ingin mengetahui perbedaan nilai setiap fitur pada tiap kanal partisipan dalam memberikan ciri sebelum menuju proses klasifikasi. Melalui perbandingan setiap 9 partisipan terhadap nilai variabel yang sebanding, seperti Gambar 3.11.



Gambar 3.11 Tujuh tahap visualisasi

Pada Gambar 3.11 tahap no. 1, pada mulanya dataset terdiri dari 9 subjek. Setiap subjek menggunakan alat emotiv epoch+ 14 kanal selama 20 menit. Salah satu dari 14 kanal tersebut adalah kanal F7. Tahap no. 2 adalah sebagai contoh salah satu kanal yaitu F7 diberi label baseline dan cybersickness. Label baseline adalah 4 menit awal subjek tidak melakukan aktifitas apapun dan tidak diberikan stimuli apapun. Label cybersickness adalah 16 menit terakhir ketika subjek bermain game

3D Mirror's Edge. Tahap no. 3 adalah segmentasi sinyal yang bisa digunakan sebagai penanda baseline dan cybersickness. Setiap segmentasi diambil 4 menit awal dan 4 menit akhir. Tahap no. 4 adalah penguraian dari hasil segmentasi ke sinyal alpha dan beta. Proses sinyal alfa memiliki rentang frekuensi 8-12 Hz dan beta memiliki rentang frekuensi 12-21 Hz. Pada tahap no. 5 adalah proses ekstraksi fitur. Fitur yang digunakan adalah mean, varian, standard deviasi, power percentage dan number of peaks. Dari kelima fitur tersebut, kebaruan penelitian ini terletak pada fitur number of peaks (jumlah puncak). Pada tahap no. 6 adalah klasifikasi. Klasifikasi pada penelitian ini menggunakan metode k-NN dan Naïve Bayes. Sebenarnya pada kebanyakan literatur tentang cybersickness tidak menitik beratkan pada klasifikasi karena dinilai tema ini masih tergolong baru. Saat ini masih dalam masa pengenalan pola sinyal cybersickness. Selanjutnya, tahap terakhir yaitu tahap no. 7 adalah visualisasi. Visualisasi disini memvisualisasikan hasil ekstraksi fitur. Dari hasil visualisasi diharapkan dapat digunakan sebagai pengenalan pola cybersickness.

Halaman ini sengaja dikosongkan

BAB 4

HASIL DAN PEMBAHASAN

Bab ini membahas tentang pengujian dan hasil analisa terhadap framework yang diusulkan. Pengujian pada penelitian ini dilakukan 2 klasifikasi. Klasifikasi pertama menggunakan k -NN, sedangkan klasifikasi kedua menggunakan Naive Bayes. Dimana untuk setiap klasifikasi diterapkan kriteria menggunakan jumlah fitur yang berbeda. Hasil analisa menjelaskan tentang rangkuman analisa dan hasil pengujian berdasarkan penerapan dari kedua klasifikasi.

Selain klasifikasi, pada bab ini akan menjelaskan visualisasi dari hasil ekstraksi fitur. Dimana sebenarnya, pada kebanyakan literatur cybersickness tidak menitik-beratkan pada klasifikasi, melainkan pada fitur yang bisa digunakan sebagai pengenalan pola cybersickness.

4.1 Pra-pemrosesan Data

Pada tahapan ini menjelaskan channel AF3, F7, F3, Fc5, T7, P7, O1, O2, P8, T8, Fc6, F4, F8, dan AF4 yang difilter menggunakan Independent Component Analysis (ICA). Kemudian disegmentasi 4 menit awal dan 4 menit akhir. Setelah itu difilter menggunakan filter Chebysev Type II.

4.1.1 Artefact Removal

Pada tahapan ini sinyal EEG difilter menggunakan Independent Component Analysis (ICA). Terdapat banyak sinyal yang semestinya tidak diambil. Pada literature (Turnip and Pardede, 2017), sumber utama artefact adalah dari EOG artefact, ocular artefact (pergerakan mata dan kedip), derau otot (EMG), sinyal jantung dan bermacam-macam derau lainnya yang bercampur dengan sinyal otak biasa disebut artefact pada perekaman EEG. Mereka menggunakan daubechies wavelet (db1) dan 3rd decomposition level.

Penelitian ini memberitahu bahwa dalam proses pembersihan artefact terdiri dari sinyal input yang difilter ke dalam “high pass filter” atau “low pass filter”. Kemudian, apabila sinyal input tergolong pada high pass filter, maka akan diloloskan menuju rekonstruksi sinyal neuroelektrik. Dan, apabila sinyal input tergolong pada low pass filter, maka akan diberikan koefisien fungsi skala sehingga dapat masuk ke dalam high pass filter. Kemudian hasil dari proses ICA, diteruskan menuju proses segmentasi data.

4.1.2 Segmentasi Data

Setelah diproses ICA pada tahap artefact removal, selanjutnya sinyal EEG disegmentasi dari 20 menit menjadi 4 menit awal dan 4 menit akhir. Jumlah sampel data dengan frekuensi sampling $f = 256$ Hz untuk 4 menit adalah $4 \times 60s \times 256 = 61440$ sampel. Proses ini merupakan persiapan data dimana awal mula data akan diproses sebelum diuraikan ke dalam band sinyal alpha dan low beta.

4.1.3 Band Pass Filter

Setelah sinyal disegmentasi menjadi 61440 sampel, sinyal tersebut difilter menggunakan Chebysev Type II yang bisa digunakan sebagai pengurai menjadi sinyal alfa dan beta. Dimana, sinyal alfa memiliki rentang 8-12 Hz. Selanjutnya, sinyal low beta memiliki rentang 12-21 Hz.

Kami memilih proses Chebyshev type II karena dinilai lebih bagus dan dapat meminimalkan ripple pada model ini. Selain itu, proses ini sebenarnya dapat juga menggunakan Discrete Wavelet Transform, sebelum menuju ke proses ekstraksi fitur. Tetapi, kami tetap memilih Chebyshev Type II karena dinilai memiliki output keluaran band alpha dan beta lebih baik dibandingkan filter tersebut.

4.2 Ekstraksi Fitur

Pada tahap ekstraksi fitur ini 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 Mean, Varian, Standard Deviasi, *Power Percentage*, dan *Number of Peaks* yang telah digunakan sebelumnya oleh (Diykh et al., 2016; Li et al., 2016) pada sinyal EEG satu kanal.

Fitur Mean, varian, standard deviasi, power percentage dan number of peaks adalah fitur yang akan digunakan pada penelitian ini. Dari semua fitur, mean sangat erat kaitannya dengan fitur varian, standard deviasi, dan power percentage karena basis dari ketiga fitur tersebut adalah rata-rata. Berbeda dengan number of peak, fitur ini bermaksud untuk menghitung jumlah puncak pada suatu data sinyal. Ini bertujuan juga agar dapat mengetahui penurunan suatu data tersebut. Dari kelima fitur tersebut, fitur ini yang tidak memiliki kaitan dengan fitur mean.

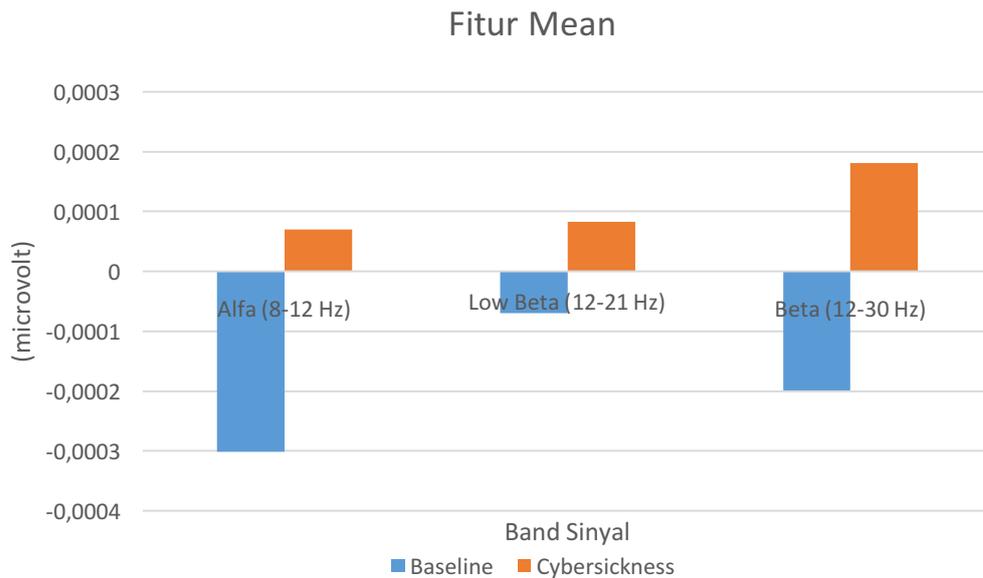
4.2.1 Fitur Mean

Mean adalah nilai rata rata dari tiap kanal data pada setiap partisipan. Seperti dijelaskan pada bab sebelumnya, digunakan kanal AF3, F7, F3, Fc5, T7, P7, O1, O2, P8, T8, Fc6, F4, F8, dan AF4 melalui partisipan S01 sampai S09. Kemudian dataset diekstraksi menggunakan fitur mean. Dari hasil rata-rata seluruh kanal dari semua partisipan, dihasilkan data sebagai seperti pada Tabel 4.1.

Tabel 4.1 Karakteristik dataset berdasarkan ekstraksi fitur mean

Mean	baseline	cybersickness
Alfa (8-12 Hz)	-0,000301048 μ V	0,0000702475777777778 μ V
Low Beta (12-21 Hz)	-0,00007000005 μ V	0,0000822460460317461 μ V
Beta (12-30 Hz)	-0,000198597 μ V	0,000181209 μ V

Dari informasi tentang mean, kami menganalisa bahwa dari fitur mean baseline dan cybersickness pada semua band frekuensi, menghasilkan kenaikan nilai. Apabila nilai mean ketika baseline yang mulanya minus, maka ketika cybersickness positif. Hal ini menjadikan ciri mean merupakan standar yang bisa digunakan sebagai pembeda antara baseline dan cybersickness. Setiap nilai mean yang dalam kondisi tidak melakukan aktifitas apapun rata-rata nilainya adalah cenderung negatif. Sedangkan ketika distimuli menggunakan game 3D, maka rata-rata nilainya adalah cenderung positif seperti Gambar 4.1.



Gambar 4.1 Karakteristik dataset berdasarkan ekstraksi fitur mean

Dari Gambar 4.1, memberitahukan bahwa setiap band sinyal (alfa, low beta, dan beta) ketika kondisi baseline ke cybersickness rata-rata menghasilkan kenaikan nilai mean. Pada fitur mean, kami dapat menyimpulkan bahwa ketika cybersickness memiliki nilai rata-rata mean tinggi.

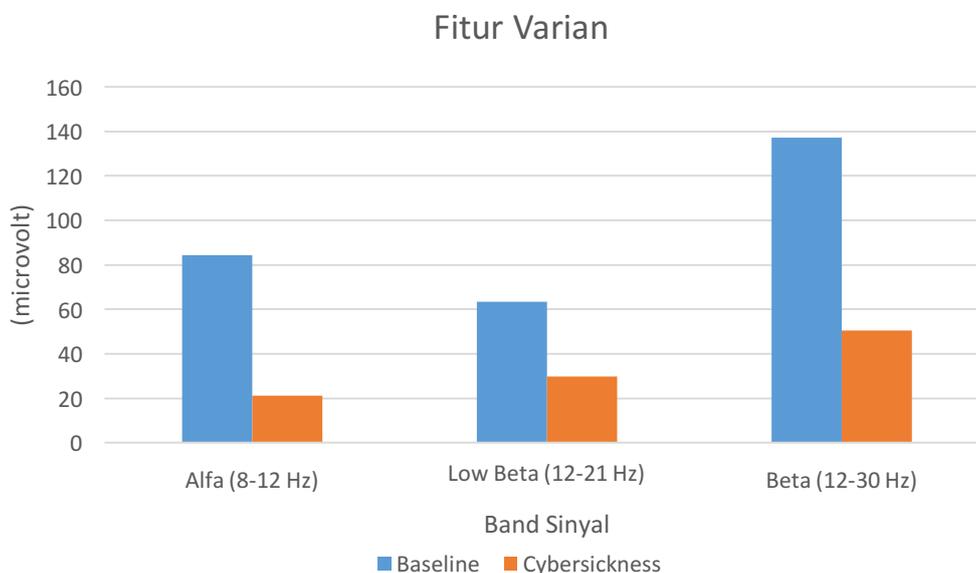
4.2.2 Fitur Varian

Varian adalah jumlah nilai dari selisih antara rata-rata dan nilai yang sering muncul hingga yang jarang lalu dikuadratkan. Nilai varian ini memiliki sifat apabila semakin besar nilai, maka semakin tidak diharapkan nilai tersebut. Seperti dijelaskan pada bab sebelumnya, digunakan kanal AF3, F7, F3, Fc5, T7, P7, O1, O2, P8, T8, Fc6, F4, F8, dan AF4 melalui partisipan S01 sampai S09. Kemudian dataset diekstraksi menggunakan fitur varian. Dari hasil rata-rata seluruh kanal dari semua partisipan, dihasilkan data sebagai seperti pada Tabel 4.2.

Tabel 4.2 Karakteristik dataset berdasarkan ekstraksi fitur varian

Varian	baseline	cybersickness
Alfa (8-12 Hz)	84,46552460 μ V	21,29533119 μ V
Low Beta (12-21 Hz)	63,55423413 μ V	29,93155913 μ V
Beta (12-30 Hz)	137,30615160 μ V	50,53432937 μ V

Dari informasi tentang varian, kami menganalisa bahwa dari fitur varian baseline ke cybersickness pada semua band frekuensi, menghasilkan penurunan nilai. Apabila nilai varian ketika baseline yang mulanya tinggi, maka ketika cybersickness menjadi rendah seperti Gambar 4.2.



Gambar 4.2 Karakteristik dataset berdasarkan ekstraksi fitur varian

Dari Gambar 4.2, memberitahukan bahwa setiap band sinyal (alfa, low beta, dan beta) ketika kondisi baseline ke cybersickness mengalami rata-rata penurunan nilai varian. Kondisi ini menggambarkan bahwa semakin rendah nilai varian pada alfa, maka semakin diharapkan nilai tersebut. Dan, apabila nilai varian rendah berarti persebaran data tidak signifikan (memiliki bentuk sinyal berdempetan). Berbeda ketika kondisi sebelumnya, ketika baseline memiliki nilai varian tinggi (bentuk sinyal lebih renggang). Pada fitur varian ini, kami dapat menyimpulkan bahwa ketika cybersickness memiliki nilai varian yang rendah.

4.2.3 Fitur Standard Deviasi

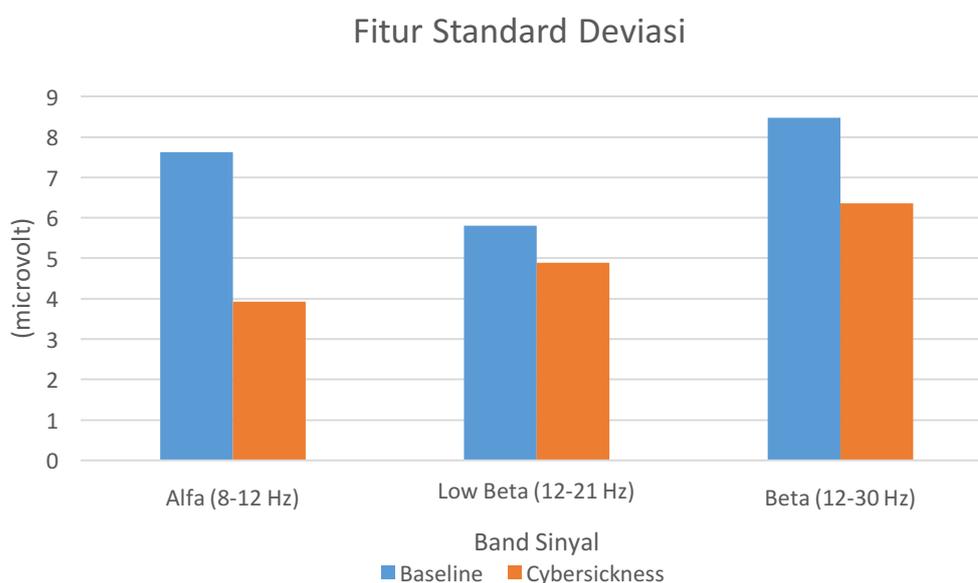
Standard Deviasi adalah jumlah nilai akar dari selisih antara rata-rata dan nilai yang sering muncul hingga yang jarang lalu dikuadratkan. Nilai standard deviasi ini memiliki sifat apabila semakin besar nilai, maka semakin tidak diharapkan nilai tersebut. Seperti dijelaskan pada bab sebelumnya, digunakan kanal

AF3, F7, F3, Fc5, T7, P7, O1, O2, P8, T8, Fc6, F4, F8, dan AF4 melalui partisipan S01 sampai S09. Kemudian dataset diekstraksi menggunakan fitur standard deviasi. Dari hasil rata-rata seluruh kanal dari semua partisipan, dihasilkan data sebagai seperti pada Tabel 4.3.

Tabel 4.3 Karakteristik dataset berdasarkan ekstraksi fitur standard deviasi

Standard deviasi	baseline	cybersickness
Alfa (8-12 Hz)	7,617801587 μV	3,917398333 μV
Low Beta (12-21 Hz)	5,812816667 μV	4,882235952 μV
Beta (12-30 Hz)	8,468657937 μV	6,35737381 μV

Dari informasi tentang standard deviasi, kami menganalisa bahwa dari fitur standard deviasi baseline ke cybersickness pada semua band frekuensi, menghasilkan penurunan nilai. Apabila nilai standard deviasi ketika baseline yang mulanya tinggi, maka ketika cybersickness nilai standard deviasi menjadi rendah seperti pada Gambar 4.3.



Gambar 4.3 Karakteristik dataset berdasarkan ekstraksi fitur standard deviasi

Pada fitur standard deviasi ini, kami dapat menyimpulkan bahwa ketika cybersickness memiliki nilai sama halnya dengan varian, yaitu nilai standard deviasi yang rendah.

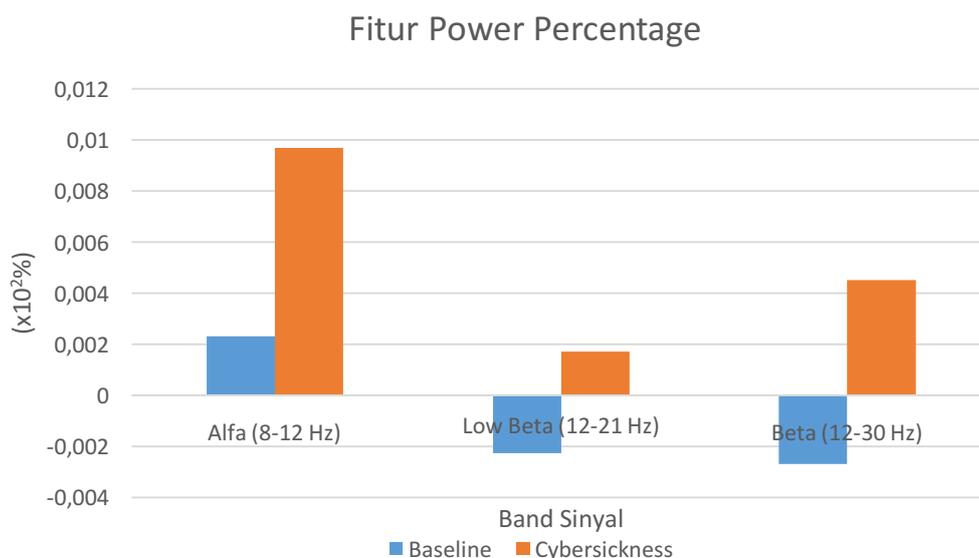
4.2.4 Fitur Power Percentage

Power Percentage adalah nilai persentasi jumlah rata-rata segmentasi sinyal filterband (alfa/beta) lalu dibagi nilai rata-rata segmentasi data raw (sebelum difilter band). Jadi nilai tertinggi fitur adalah 1 dan terendah -1. Seperti dijelaskan pada bab sebelumnya, digunakan kanal AF3, F7, F3, Fc5, T7, P7, O1, O2, P8, T8, Fc6, F4, F8, dan AF4 melalui partisipan S01 sampai S09. Kemudian dataset diekstraksi menggunakan fitur power percentage. Dari hasil rata-rata seluruh kanal dari semua partisipan, dihasilkan data sebagai seperti pada Tabel 4.4.

Tabel 4.4 Karakteristik dataset berdasarkan ekstraksi fitur power percentage

Power Percentage	baseline	cybersickness
Alfa (8-12 Hz)	0,00230944 x10 ² %	0,00969376 x10 ² %
Low Beta (12-21 Hz)	-0,00227564 x10 ² %	0,00169375 x10 ² %
Beta (12-30 Hz)	-0,00271034 x10 ² %	0,00449621 x10 ² %

Dari informasi tentang power percentage, kami menganalisa bahwa dari power percentage baseline ke cybersickness di semua band frekuensi, menghasilkan kenaikan nilai. Apabila nilai power percentage saat baseline mulanya rendah, maka ketika cybersickness nilainya menjadi tinggi seperti Gambar 4.4.



Gambar 4.4 Karakteristik dataset berdasarkan ekstraksi fitur power percentage

Pada fitur ini, kami menyimpulkan bahwa ketika cybersickness memiliki nilai sama halnya dengan mean, yaitu nilai power percentage menjadi tinggi.

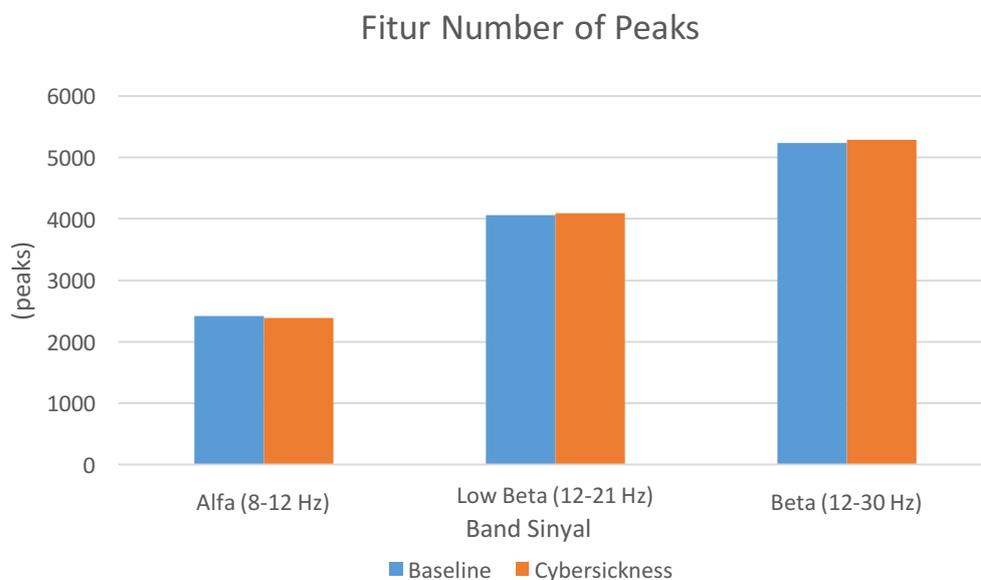
4.2.5 Fitur Number of Peaks

Number of Peaks adalah jumlah peak/puncak yang ada pada setiap kanal (Scholkmann et al., 2012). Seperti dijelaskan pada bab sebelumnya, digunakan kanal AF3, F7, F3, Fc5, T7, P7, O1, O2, P8, T8, Fc6, F4, F8, dan AF4 melalui partisipan S01 sampai S09. Kemudian dataset diekstraksi menggunakan fitur number of peaks. Dari hasil rata-rata seluruh kanal dari semua partisipan, dihasilkan data sebagai seperti pada Tabel 4.5.

Tabel 4.5 Karakteristik dataset berdasarkan ekstraksi fitur number of peaks

Number of Peaks	baseline	cybersickness
Alfa (8-12 Hz)	2416,20634900 peaks	2387,19841300 peaks
Low Beta (12-21 Hz)	4062,56349200 peaks	4091,76984100 peaks
Beta (12-30 Hz)	5228,01587300 peaks	5288,50793700 peaks

Dari informasi tentang number of peaks ini, kami menganalisa bahwa dari fitur number of peaks baseline ke cybersickness pada semua band frekuensi, menghasilkan kenaikan pada sinyal beta dan low beta saja. Apabila nilai number of peaks sinyal beta ketika baseline yang mulanya rendah, maka pada sinyal beta ketika cybersickness nilai number of peaks menjadi tinggi seperti Gambar 4.5.



Gambar 4.5 Karakteristik dataset berdasarkan ekstraksi fitur number of peaks

Pada fitur ini, kami menyimpulkan bahwa dibandingkan ketika baseline ke cybersickness, sinyal alfa mengalami penurunan nilai number of peaks sedangkan sinyal beta dan low beta mengalami kenaikan nilai number of peaks. Disini menggambarkan bahwa ketika partisipan ketika kondisi relax (keadaan sinyal alfa) akan mudah terkena cybersickness dibuktikan dengan rata-rata penurunan jumlah puncak sinyal. Berbeda ketika kondisi mental penuh atau semangat berfikir (keadaan sinyal beta) akan susah terkena cybersickness dibuktikan dengan rata-rata kenaikan jumlah puncak sinyal.

Jadi, apabila partisipan sudah biasa bermain 3D game, maka ketika dari baseline ke cybersickness akan mengalami kenaikan nilai puncak yang signifikan dikarenakan gejala cybersickness sulit untuk masuk ke penderita ketika partisipan dalam kondisi mental penuh (kondisi sinyal beta). Sudah banyak literature menerangkan bahwa semakin banyak nilai puncak maka semakin tinggi mental partisipan dalam menghadapi gejala penyakit (cybersickness). Sedangkan apabila partisipan dalam kondisi relaksasi tanpa perhatian dan konsentrasi (kondisi sinyal alfa), maka lebih rentan terkena gejala cybersickness.

4.3 Metode Klasifikasi

Penelitian kali ini kami menggunakan 2 metode. Metode pertama menggunakan K-NN. Sedangkan, percobaan kedua menggunakan Naive Bayes. Dimana kedua metode tersebut adalah tergolong metode supervised (terlatih) yang menggunakan label sebelum diklasifikasi.

Kami mencoba menggunakan metode k-NN dan Naive Bayes. Pertimbangan kami menggunakan kedua klasifikasi tersebut dirasa memiliki variabel yang dapat dibandingkan satu sama lainnya yaitu pengambilan keputusan. Pada banyak literature tentang cybersickness, kebanyakan tidak memberikan proses klasifikasi didalamnya dikarenakan tema ini masih baru. Maka dari itu, penelitian ini adalah langkah awal yang bisa digunakan sebagai dasar pengetahuan pengenalan pola cybersickness.

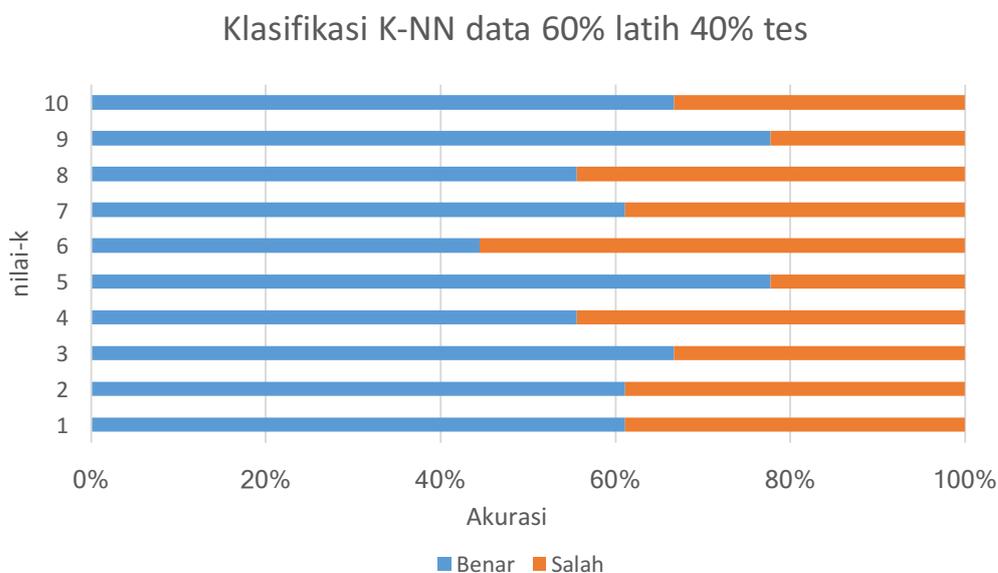
4.3.1 K-NN

K-NN adalah metode untuk mencari nilai terdekat. Dengan basis pendekatan ketika terdapat 2 titik menggunakan algoritma Euclidian Distance yang merupakan penurunan dari Minkowski Distance. Pada penelitian ini, digunakan K-NN untuk mengetahui bahwa data adalah baseline atau cybersickness. Berikut hasil klasifikasi menggunakan K-NN 140 fitur pada Tabel 4.6:

Tabel 4.6 Akurasi *classifier* K-NN data train 60% test 40% berdasarkan nilai-k

nilai k	Terklasifikasi benar (data)	Terklasifikasi salah (data)
1	11	7
2	11	7
3	12	6
4	10	8
5	14	4
6	8	10
7	11	7
8	10	8
9	14	4
10	12	6

Pada data tersebut, kami belum dapat memutuskan untuk menggunakan metode k-NN melalui nilai-k berapa secara pasti karena melihat dari data masih ada yang blum sesuai harapan (signifikan) seperti Gambar 4.6.



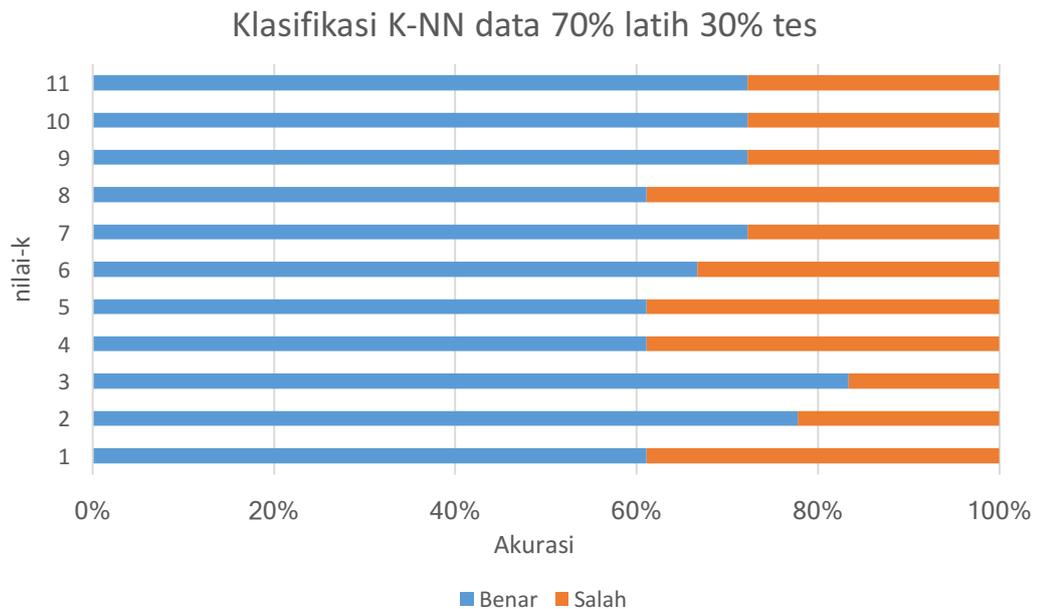
Gambar 4.6 Akurasi K-NN data train 60% dan test 40% berdasarkan nilai-k

Pada grafik akurasi K-NN Gambar 4.6, melalui data training 60% dan data test 40% masih banyak terdapat nilai akurasi yang kurang akurat. Kemudian kami melakukan percobaan kedua kalinya menggunakan split data training 70% dan data test 30%. Seperti pada Tabel 4.7.

Tabel 4.7 Akurasi *classifier* K-NN data train 70% test 30% berdasarkan nilai-k

nilai k	Terklasifikasi benar (data)	Terklasifikasi salah (data)
1	11	7
2	14	4
3	15	3
4	11	7
5	11	7
6	12	6
7	13	5
8	11	7
9	13	5
10	13	5
11	13	5

Pada data tersebut, kami lebih dapat memutuskan daripada sebelumnya untuk menggunakan metode k-NN melalui nilai-k berapa secara pasti karena melihat dari data masih sudah ada yang signifikan. Seperti pada Gambar 4.7.



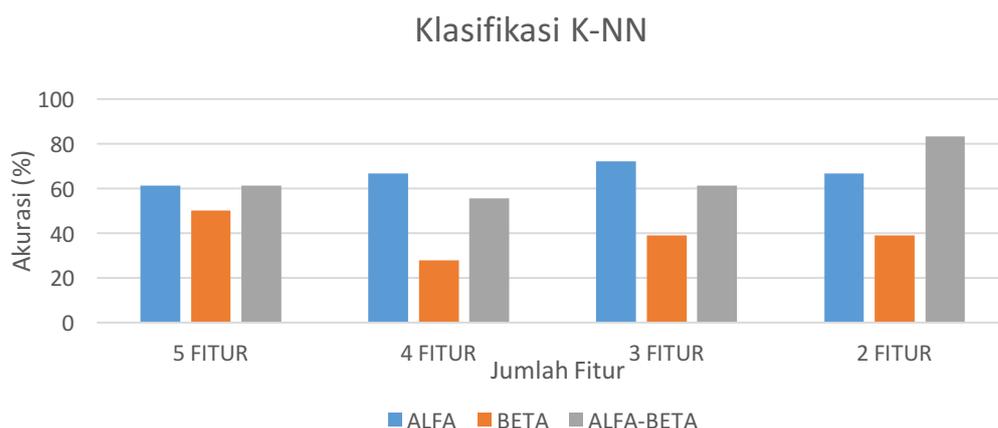
Gambar 4.7 Akurasi K-NN data train 70% dan test 30% berdasarkan nilai-k

Pada grafik akurasi K-NN Gambar 4.7, melalui data training 70% dan data test 30% terdapat nilai akurasi yang lebih besar nilai akurasinya dibandingkan ketika menggunakan data training 60% dan data test 40%. Sebelumnya terdapat salah satu percobaan memiliki akurasi rendah. Selanjutnya ketika menggunakan percobaan kedua, terdapat nilai k=3 sebagai nilai tertinggi akurasi. Setelah mendapatkan nilai-k, lalu diklasifikasi k-NN seperti Tabel 4.8.

Tabel 4.8 Akurasi Klasifikasi K-NN melalui Seleksi Fitur

k-NN	ALFA	BETA	ALFA+BETA	14 CH/FITUR
5 FITUR	61,1%	50,0%	61,1%	MEAN, VAR, STD, PP, NOP
4 FITUR	66,7%	27,8%	55,6%	VAR, STD, PP, NOP
3 FITUR	72,2%	38,9%	61,1%	VAR, STD, NOP
2 FITUR	66,7%	38,9%	83,3%	VAR, STD

Metode k-NN menghasilkan nilai akurasi yang paling tinggi ketika menggunakan 2 macam fitur yaitu varian dan standard deviasi. Akurasi yang paling tinggi tersebut merupakan kombinasi dari sinyal alfa dan beta. Nilai akurasi yang paling tinggi adalah 83,3% seperti pada Gambar 4.8.



Gambar 4.8 Akurasi K-NN berdasarkan kombinasi kelima fitur

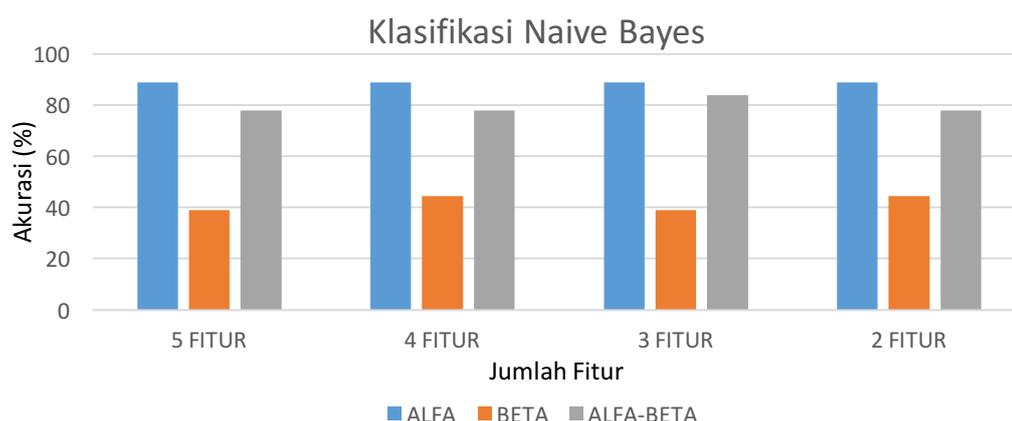
Pada data tersebut, memiliki nilai akurasi paling kecil 27% ketika menggunakan sinyal alfa dan kombinasi 4 fitur (var, std, pp, nop). Disini sangat terlihat bahwa peran fitur mean sangat berperan besar bagi keempat fitur tersebut. Kasus ini dibuktikan ketika dari 5 fitur, dikurangi fitur mean menghasilkan nilai akurasi yang terlampau kecil. Kami menyadari bahwa dari kelima fitur, terdapat 4 fitur yang menggunakan dasar perhitungan menggunakan fitur rata-rata.

4.3.2 Naïve Bayes

Naïve Bayes adalah metode klasifikasi 10 besar terbaik (Jiang et al., 2018). Metode ini merupakan pengambil keputusan dari probabilitas terhadap suatu aturan. Dari percobaan menggunakan metode Naïve Bayes, akurasi tertinggi ketika menggunakan varian, standard deviasi, dan number of peaks seperti pada Tabel 4.9. Tabel 4.9 Akurasi Klasifikasi Naïve Bayes melalui Seleksi Fitur

Naïve Bayes	ALFA	BETA	ALFA-BETA	14 CH/FITUR
5 FITUR	88,9%	38,9%	77,8%	MEAN, VAR, STD, PP, NOP
4 FITUR	88,9%	44,4%	77,8%	VAR, STD, PP, NOP
3 FITUR	88,9%	38,9%	83,8%	VAR, STD, NOP
2 FITUR	88,9%	44,4%	77,8%	VAR, STD

Metode Naïve Bayes menghasilkan nilai akurasi yang paling tinggi ketika menggunakan 3 macam fitur yaitu varian, standard deviasi dan number of peaks. Akurasi yang paling tinggi tersebut merupakan kombinasi dari sinyal alfa saja dan alfa+beta. Nilai akurasi yang paling tinggi melalui sinyal alfa saja adalah 88,9%. Sedangkan, nilai akurasi yang paling tinggi melalui sinyal alfa+beta adalah 83,8% seperti pada Gambar 4.9.

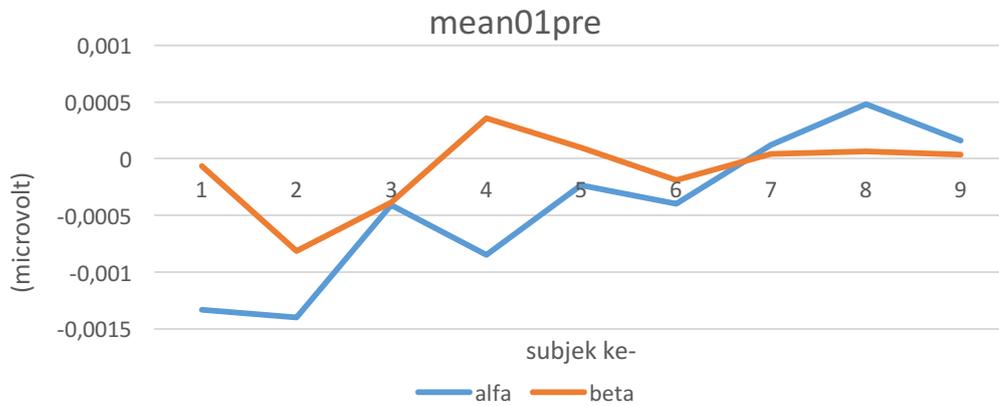


Gambar 4.9 Akurasi Naïve Bayes berdasarkan kombinasi kelima fitur

Pada percobaan tentang akurasi klasifikasi Naïve Bayes ketika menggunakan 5 fitur dibandingkan dengan menggunakan 4, 3, atau 2 fitur, masih memiliki nilai akurasi yang hampir sama. Disini membuktikan bahwa, bukan hanya banyaknya fitur yang digunakan tetapi juga pemilihan fitur juga (feature selection) yang dapat membuat nilai akurasi suatu klasifikasi Naïve Bayes menjadi baik.

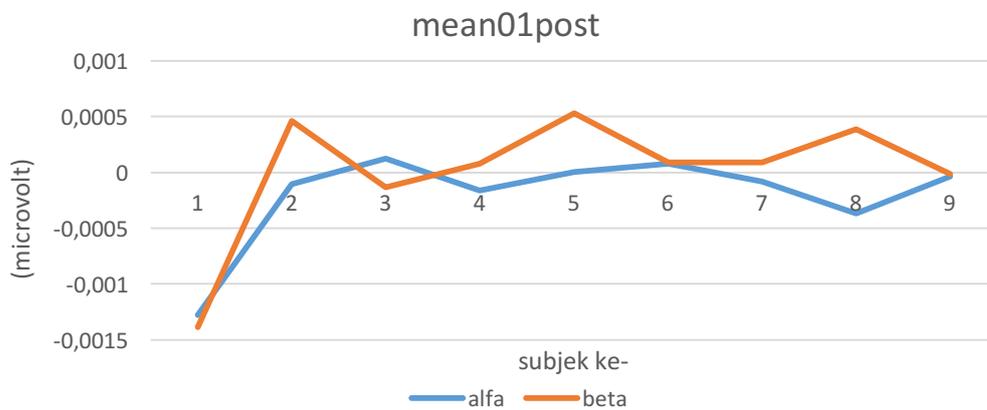
4.4 Visualisasi

Pada tahap ini akan diberikan gambaran perbedaan sinyal EEG ketika kondisi *baseline* dan ketika mengalami *cybersickness* menggunakan channel 01 (AF3). Gambar tersebut adalah grafik perbandingan 1-9 partisipan melalui channel yang sama yaitu AF3 dan fitur yang sama yaitu fitur mean, seperti Gambar 4.10



Gambar 4.10 Visualisasi fitur mean kanal AF3 kondisi baseline

Mean01pre disini bermaksud menjelaskan bahwa pada fitur mean channel 01 (AF3) ketika pre (baseline) menggambarkan perbandingan nilai sinyal alfa mayoritas lebih rendah daripada beta setiap partisipan. Kemudian berikut gambar ketika post (*cybersickness*) seperti Gambar 4.11.



Gambar 4.11 Visualisasi fitur mean kanal AF3 kondisi *cybersickness*

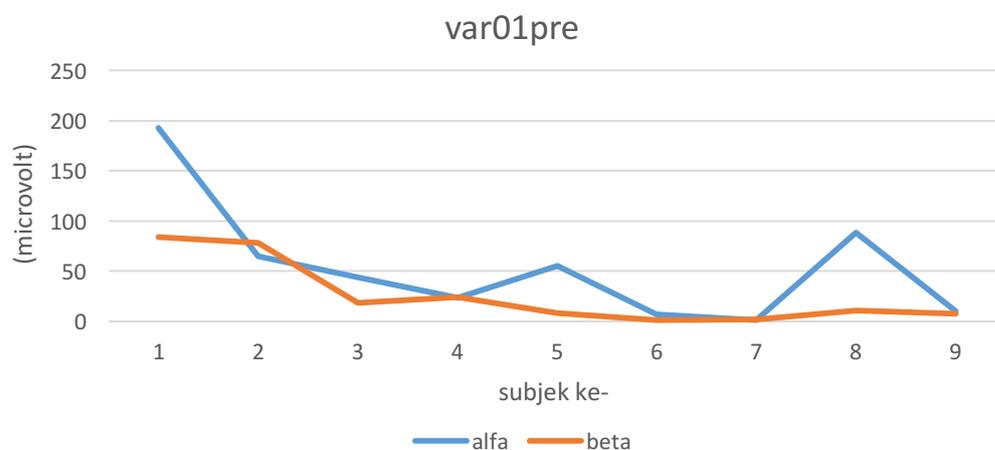
Mean01post disini bermaksud menjelaskan bahwa pada fitur mean channel 01 (AF3) ketika *cybersickness* menggambarkan perbandingan nilai sinyal alfa mayoritas lebih rendah daripada beta setiap partisipan. Selanjutnya adalah tabel fitur mean ketika menggunakan 14 kanal seperti pada Tabel 4.10.

Tabel 4.10 Visualisasi fitur mean seluruh kanal dan semua partisipan

No.	Fitur	Channel	Baseline / Cybersickness	Kecenderungan/Mayoritas
1.	mean	1 (AF3)	Baseline	Alfa lebih rendah dari beta
2.	mean	1 (AF3)	Cybersickness	Alfa lebih rendah dari beta
3.	mean	2 (F7)	Baseline	Alfa lebih rendah dari beta
4.	mean	2 (F7)	Cybersickness	Alfa lebih tinggi dari beta
5.	mean	3 (F3)	Baseline	Alfa lebih rendah dari beta
6.	mean	3 (F3)	Cybersickness	Alfa lebih tinggi dari beta
7.	mean	4 (Fc5)	Baseline	Alfa lebih rendah dari beta
8.	mean	4 (Fc5)	Cybersickness	Alfa lebih rendah dari beta
9.	mean	5 (T7)	Baseline	Alfa lebih tinggi dari beta
10.	mean	5 (T7)	Cybersickness	Alfa lebih rendah dari beta
11.	mean	6 (P7)	Baseline	Alfa lebih rendah dari beta
12.	mean	6 (P7)	Cybersickness	Alfa lebih rendah dari beta
13.	mean	7 (O1)	Baseline	Alfa lebih rendah dari beta
14.	mean	7 (O1)	Cybersickness	Alfa lebih rendah dari beta
15.	mean	8 (O2)	Baseline	Alfa lebih rendah dari beta
16.	mean	8 (O2)	Cybersickness	Alfa lebih rendah dari beta
17.	mean	9 (P8)	Baseline	Alfa lebih rendah dari beta
18.	mean	9 (P8)	Cybersickness	Alfa lebih rendah dari beta
19.	mean	10 (T8)	Baseline	Alfa lebih rendah dari beta
20.	mean	10 (T8)	Cybersickness	Alfa lebih rendah dari beta
21.	mean	11 (Fc6)	Baseline	Alfa lebih rendah dari beta
22.	mean	11 (Fc6)	Cybersickness	Alfa lebih rendah dari beta
23.	mean	12 (F8)	Baseline	Alfa lebih rendah dari beta
24.	mean	12 (F8)	Cybersickness	Alfa lebih rendah dari beta
25.	mean	13 (F4)	Baseline	Alfa lebih rendah dari beta
26.	mean	13 (F4)	Cybersickness	Alfa lebih rendah dari beta
27.	mean	14 (AF4)	Baseline	Alfa lebih rendah dari beta
28.	mean	14 (AF4)	Cybersickness	Alfa lebih rendah dari beta

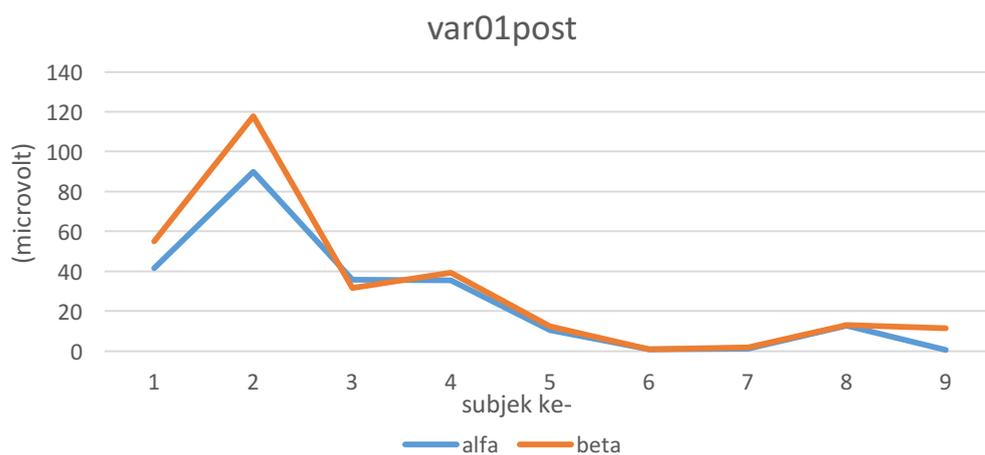
Pada Tabel 4.10 menjelaskan kondisi seluruh channel dan semua partisipan ketika diekstraksi fitur mean. Terdapat 3 dari 28 fitur mean memiliki nilai alfa lebih tinggi daripada nilai beta. Dari data tersebut, mean dapat dikatakan sebagai pembeda antara alfa dan beta dimana alfa mayoritas lebih rendah dari beta.

Selanjutnya adalah visualisasi hasil ekstraksi fitur varian seperti pada Gambar 4.12.



Gambar 4.12 Visualisasi fitur varian kanal AF3 kondisi baseline

Var01pre disini bermaksud menjelaskan bahwa pada fitur varian channel 01 (AF3) ketika pre (baseline) menggambarkan perbandingan nilai sinyal alfa mayoritas lebih tinggi daripada beta setiap partisipan. Kemudian berikut gambar ketika post (cybersickness) seperti Gambar 4.13.



Gambar 4.13 Visualisasi fitur varian kanal AF3 kondisi cybersickness

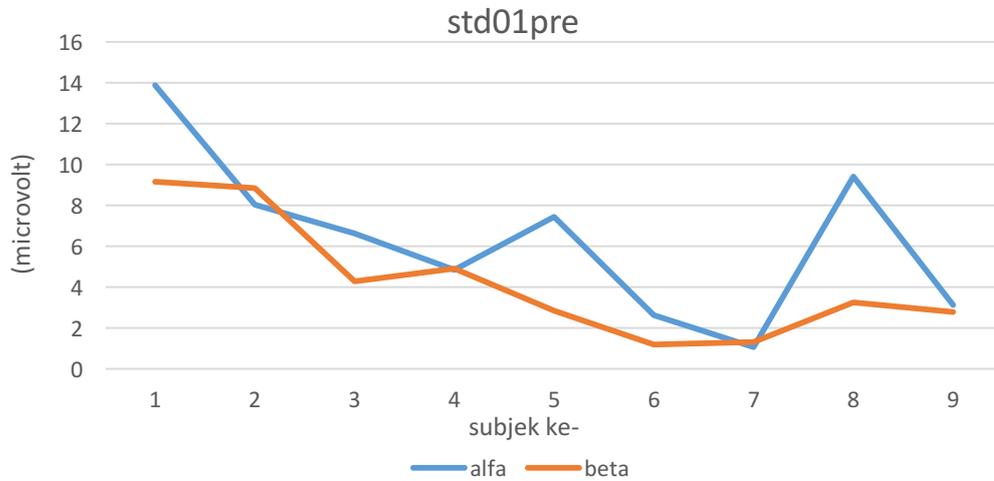
Var01post disini bermaksud menjelaskan bahwa pada fitur varian channel 01 (AF3) ketika post (cybersickness) menggambarkan perbandingan nilai sinyal alfa mayoritas lebih rendah daripada beta setiap partisipan. Selanjutnya adalah tabel fitur varian ketika menggunakan 14 kanal seperti pada Tabel 4.11.

Tabel 4.11 Visualisasi fitur varian seluruh kanal dan semua partisipan

No.	Fitur	Channel	Baseline / Cybersickness	Kecenderungan/Mayoritas
1.	varian	1 (AF3)	Baseline	Alfa lebih tinggi dari beta
2.	varian	1 (AF3)	Cybersickness	Alfa lebih rendah dari beta
3.	varian	2 (F7)	Baseline	Alfa lebih tinggi dari beta
4.	varian	2 (F7)	Cybersickness	Alfa lebih rendah dari beta
5.	varian	3 (F3)	Baseline	Alfa lebih tinggi dari beta
6.	varian	3 (F3)	Cybersickness	Alfa lebih rendah dari beta
7.	varian	4 (Fc5)	Baseline	Alfa lebih tinggi dari beta
8.	varian	4 (Fc5)	Cybersickness	Alfa lebih rendah dari beta
9.	varian	5 (T7)	Baseline	Alfa lebih tinggi dari beta
10.	varian	5 (T7)	Cybersickness	Alfa lebih rendah dari beta
11.	varian	6 (P7)	Baseline	Alfa lebih tinggi dari beta
12.	varian	6 (P7)	Cybersickness	Alfa lebih rendah dari beta
13.	varian	7 (O1)	Baseline	Alfa lebih tinggi dari beta
14.	varian	7 (O1)	Cybersickness	Alfa lebih rendah dari beta
15.	varian	8 (O2)	Baseline	Alfa lebih tinggi dari beta
16.	varian	8 (O2)	Cybersickness	Alfa lebih rendah dari beta
17.	varian	9 (P8)	Baseline	Alfa lebih tinggi dari beta
18.	varian	9 (P8)	Cybersickness	Alfa lebih rendah dari beta
19.	varian	10 (T8)	Baseline	Alfa lebih tinggi dari beta
20.	varian	10 (T8)	Cybersickness	Alfa lebih rendah dari beta
21.	varian	11 (Fc6)	Baseline	Alfa lebih tinggi dari beta
22.	varian	11 (Fc6)	Cybersickness	Alfa lebih rendah dari beta
23.	varian	12 (F8)	Baseline	Alfa lebih tinggi dari beta
24.	varian	12 (F8)	Cybersickness	Alfa lebih rendah dari beta
25.	varian	13 (F4)	Baseline	Alfa lebih tinggi dari beta
26.	varian	13 (F4)	Cybersickness	Alfa lebih rendah dari beta
27.	varian	14 (AF4)	Baseline	Alfa lebih tinggi dari beta
28.	varian	14 (AF4)	Cybersickness	Alfa lebih rendah dari beta

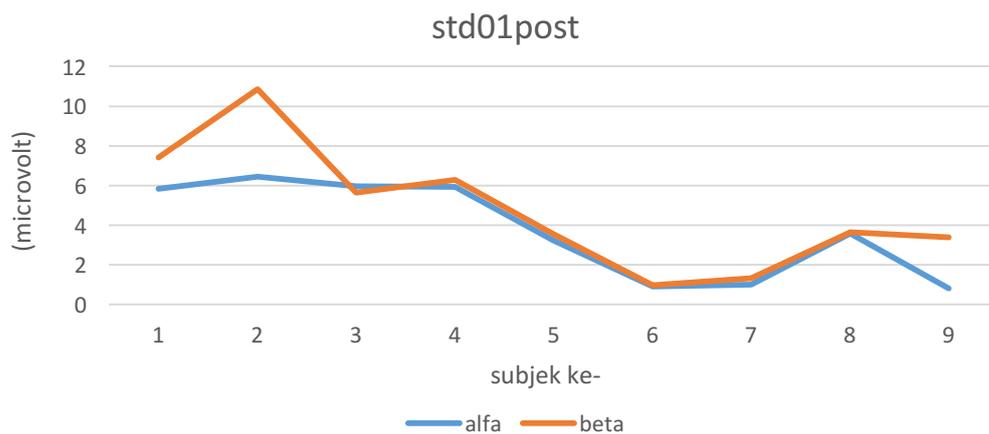
Pada Tabel 4.11 menjelaskan kondisi seluruh channel dan semua partisipan ketika diekstraksi fitur varian. Terdapat nilai alfa lebih tinggi daripada nilai beta ketika baseline. Dari data tersebut, varian dapat digunakan sebagai pembeda antara baseline dan cybersickness. Dimana, alfa mayoritas lebih rendah dari beta ketika cybersickness.

Selanjutnya adalah visualisasi hasil ekstraksi fitur standard deviasi seperti pada Gambar 4.14.



Gambar 4.14 Visualisasi fitur std. deviasi kanal AF3 kondisi baseline

Std01pre disini bermaksud menjelaskan bahwa pada fitur standard-deviasi channel AF3 ketika baseline menunjukkan perbandingan nilai sinyal alfa mayoritas lebih tinggi dari beta setiap partisipan. Selanjutnya adalah kondisi ketika post (cybersickness) seperti pada Gambar 4.15.



Gambar 4.15 Visualisasi fitur std. deviasi kanal AF3 kondisi cybersickness

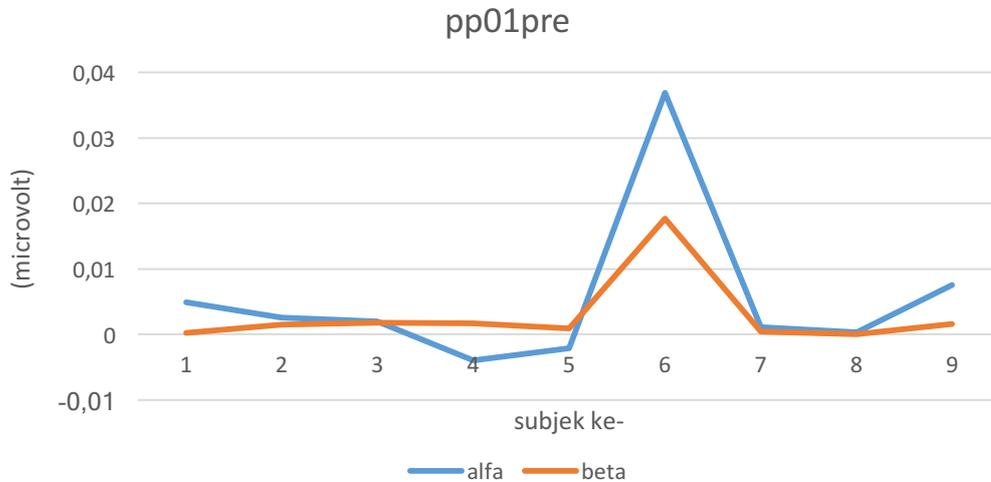
Std01post disini bermaksud menjelaskan bahwa pada fitur standard-deviasi channel AF3 ketika cybersickness menunjukkan perbandingan nilai sinyal alfa mayoritas lebih rendah dari beta setiap partisipan. Kemudian adalah tabel visualisasi fitur standard deviasi seperti pada Tabel 4.12.

Tabel 4.12 Visualisasi fitur std. deviasi seluruh kanal dan semua partisipan

No.	Fitur	Channel	Baseline / Cybersickness	Kecenderungan/Mayoritas
1.	st deviasi	1 (AF3)	Baseline	Alfa lebih tinggi dari beta
2.	st deviasi	1 (AF3)	Cybersickness	Alfa lebih rendah dari beta
3.	st deviasi	2 (F7)	Baseline	Alfa lebih tinggi dari beta
4.	st deviasi	2 (F7)	Cybersickness	Alfa lebih rendah dari beta
5.	st deviasi	3 (F3)	Baseline	Alfa lebih tinggi dari beta
6.	st deviasi	3 (F3)	Cybersickness	Alfa lebih rendah dari beta
7.	st deviasi	4 (Fc5)	Baseline	Alfa lebih tinggi dari beta
8.	st deviasi	4 (Fc5)	Cybersickness	Alfa lebih rendah dari beta
9.	st deviasi	5 (T7)	Baseline	Alfa lebih tinggi dari beta
10.	st deviasi	5 (T7)	Cybersickness	Alfa lebih rendah dari beta
11.	st deviasi	6 (P7)	Baseline	Alfa lebih tinggi dari beta
12.	st deviasi	6 (P7)	Cybersickness	Alfa lebih rendah dari beta
13.	st deviasi	7 (O1)	Baseline	Alfa lebih tinggi dari beta
14.	st deviasi	7 (O1)	Cybersickness	Alfa lebih rendah dari beta
15.	st deviasi	8 (O2)	Baseline	Alfa lebih tinggi dari beta
16.	st deviasi	8 (O2)	Cybersickness	Alfa lebih rendah dari beta
17.	st deviasi	9 (P8)	Baseline	Alfa lebih tinggi dari beta
18.	st deviasi	9 (P8)	Cybersickness	Alfa lebih rendah dari beta
19.	st deviasi	10 (T8)	Baseline	Alfa lebih tinggi dari beta
20.	st deviasi	10 (T8)	Cybersickness	Alfa lebih rendah dari beta
21.	st deviasi	11 (Fc6)	Baseline	Alfa lebih tinggi dari beta
22.	st deviasi	11 (Fc6)	Cybersickness	Alfa lebih rendah dari beta
23.	st deviasi	12 (F8)	Baseline	Alfa lebih tinggi dari beta
24.	st deviasi	12 (F8)	Cybersickness	Alfa lebih rendah dari beta
25.	st deviasi	13 (F4)	Baseline	Alfa lebih tinggi dari beta
26.	st deviasi	13 (F4)	Cybersickness	Alfa lebih rendah dari beta
27.	st deviasi	14 (AF4)	Baseline	Alfa lebih tinggi dari beta
28.	st deviasi	14 (AF4)	Cybersickness	Alfa lebih rendah dari beta

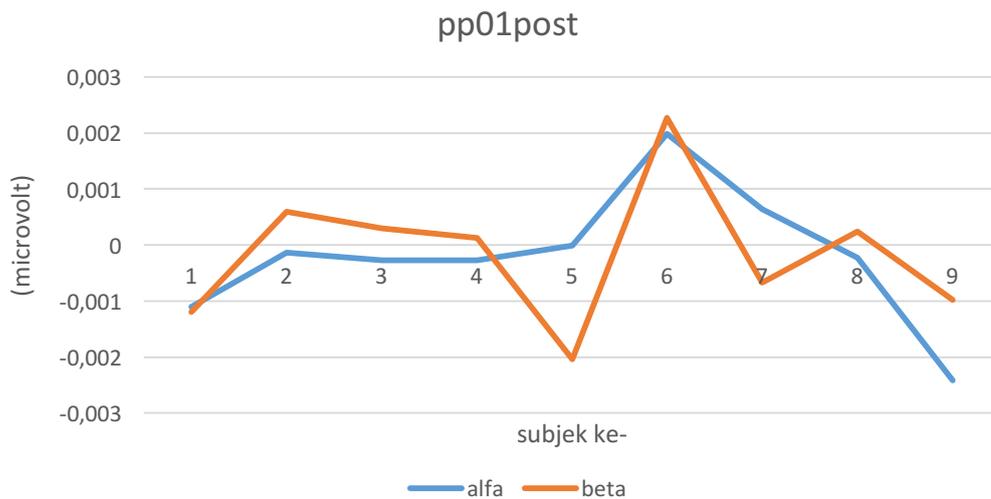
Pada Tabel 4.12 menjelaskan kondisi seluruh channel dan semua partisipan ketika diekstraksi fitur standard deviasi. Terdapat nilai alfa lebih tinggi daripada nilai beta ketika baseline. Sama halnya varian, standard deviasi dapat digunakan sebagai pembeda antara baseline dan cybersickness. Dimana, alfa mayoritas lebih rendah dari beta ketika cybersickness.

Selanjutnya adalah visualisasi hasil ekstraksi fitur power percentage seperti pada Gambar 4.16.



Gambar 4.16 Visualisasi fitur pow. percentage kanal AF3 kondisi baseline

Pp01pre disini bermaksud menjelaskan bahwa pada fitur power-percentage channel 01 (AF3) ketika pre (baseline) menunjukkan perbandingan nilai sinyal alfa mayoritas lebih tinggi dari beta setiap partisipan. Kemudian adalah visualisasi ketika kondisi post (cybersickness) seperti pada Gambar 4.17.



Gambar 4.17 Visualisasi fitur pow. percent. kanal AF3 kondisi cybersickness

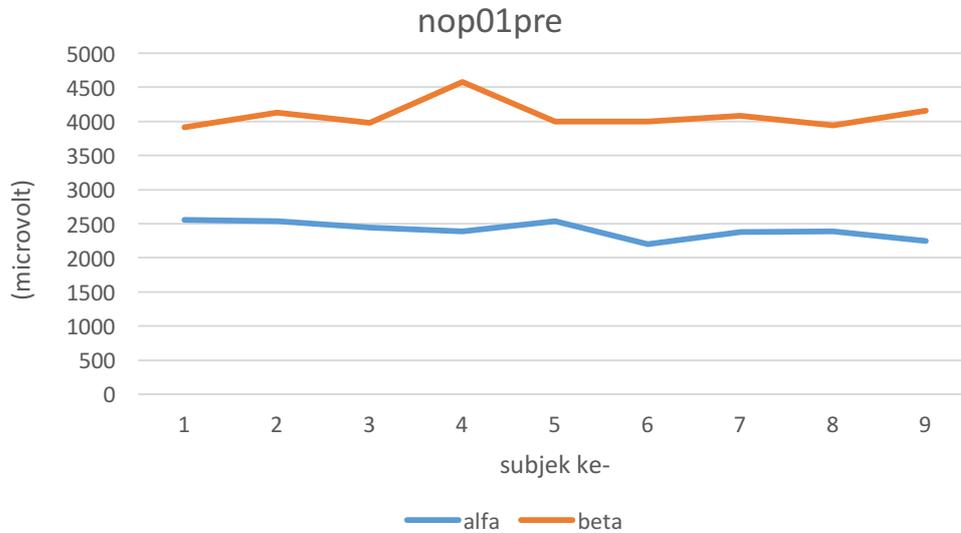
Pp01post disini bermaksud menjelaskan bahwa pada fitur power-percentage channel 01 (AF3) ketika post (cybersickness) menunjukkan perbandingan nilai sinyal alfa mayoritas lebih rendah dari beta setiap partisipan. Selanjutnya adalah tabel visualisasi hasil ekstraksi fitur power percentage seperti pada Tabel 4.13.

Tabel 4.13 Visualisasi fitur pow. percentage seluruh kanal di semua partisipan

No.	Fitur	Channel	Baseline / Cybersickness	Kecenderungan/Mayoritas
1.	p percentage	1 (AF3)	Baseline	Alfa lebih tinggi dari beta
2.	p percentage	1 (AF3)	Cybersickness	Alfa lebih rendah dari beta
3.	p percentage	2 (F7)	Baseline	Alfa lebih tinggi dari beta
4.	p percentage	2 (F7)	Cybersickness	Alfa lebih rendah dari beta
5.	p percentage	3 (F3)	Baseline	Alfa lebih tinggi dari beta
6.	p percentage	3 (F3)	Cybersickness	Alfa lebih tinggi dari beta
7.	p percentage	4 (Fc5)	Baseline	Alfa lebih tinggi dari beta
8.	p percentage	4 (Fc5)	Cybersickness	Alfa lebih rendah dari beta
9.	p percentage	5 (T7)	Baseline	Alfa lebih tinggi dari beta
10.	p percentage	5 (T7)	Cybersickness	Alfa lebih rendah dari beta
11.	p percentage	6 (P7)	Baseline	Alfa lebih rendah dari beta
12.	p percentage	6 (P7)	Cybersickness	Alfa lebih tinggi dari beta
13.	p percentage	7 (O1)	Baseline	Alfa lebih tinggi dari beta
14.	p percentage	7 (O1)	Cybersickness	Alfa lebih rendah dari beta
15.	p percentage	8 (O2)	Baseline	Alfa lebih tinggi dari beta
16.	p percentage	8 (O2)	Cybersickness	Alfa lebih rendah dari beta
17.	p percentage	9 (P8)	Baseline	Alfa lebih rendah dari beta
18.	p percentage	9 (P8)	Cybersickness	Alfa lebih rendah dari beta
19.	p percentage	10 (T8)	Baseline	Alfa lebih tinggi dari beta
20.	p percentage	10 (T8)	Cybersickness	Alfa lebih rendah dari beta
21.	p percentage	11 (Fc6)	Baseline	Alfa lebih tinggi dari beta
22.	p percentage	11 (Fc6)	Cybersickness	Alfa lebih tinggi dari beta
23.	p percentage	12 (F8)	Baseline	Alfa lebih tinggi dari beta
24.	p percentage	12 (F8)	Cybersickness	Alfa lebih tinggi dari beta
25.	p percentage	13 (F4)	Baseline	Alfa lebih tinggi dari beta
26.	p percentage	13 (F4)	Cybersickness	Alfa lebih rendah dari beta
27.	p percentage	14 (AF4)	Baseline	Alfa lebih tinggi dari beta
28.	p percentage	14 (AF4)	Cybersickness	Alfa lebih rendah dari beta

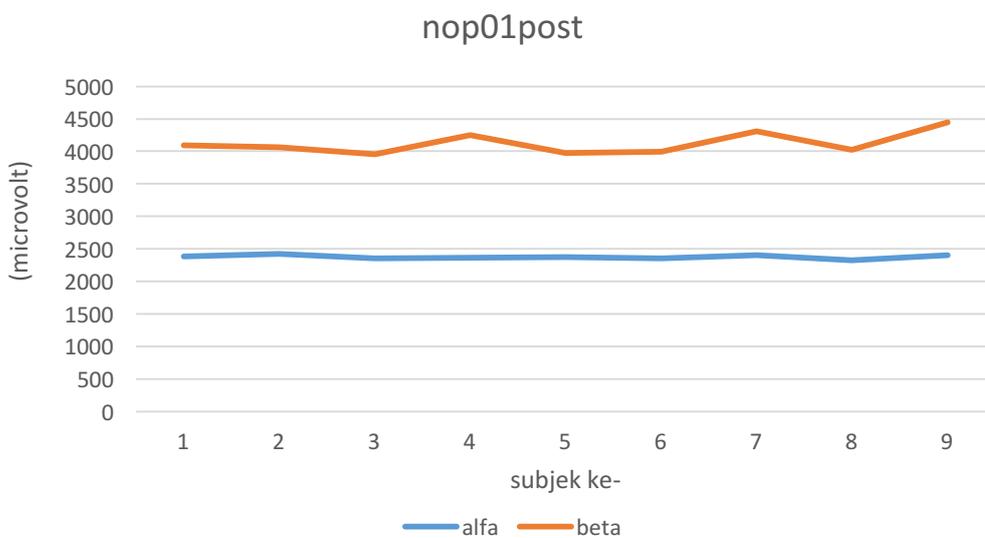
Pada Tabel 4.13 menjelaskan kondisi seluruh channel dan semua partisipan ketika diekstraksi fitur power percentage. Terdapat 16 dari 28 fitur power percentage memiliki nilai alfa lebih tinggi daripada nilai beta. Dari data tersebut, power percentage tidak dapat dikatakan sebagai pembeda antara alfa dan beta karena nilai alfa yang mayoritas lebih tinggi dari beta bersifat random/acak.

Selanjutnya adalah visualisasi ekstraksi fitur number of peaks/jumlah puncak seperti pada Gambar 4.18.



Gambar 4.18 Visualisasi fitur numb. of peaks kanal AF3 kondisi baseline

Nop01pre disini bermaksud menjelaskan bahwa pada fitur number-of-peaks channel 01 (AF3) ketika pre (baseline) menunjukkan perbandingan nilai sinyal alfa mayoritas lebih rendah dari beta setiap partisipan. Kemudian adalah gambar visualisasi ketika kondisi post (cybersickness) seperti pada Gambar 4.19.



Gambar 4.19 Visualisasi fitur numb. of peaks kanal AF3 kondisi cybersickness

Nop01post disini bermaksud menjelaskan bahwa pada fitur number-of-peaks channel 01 (AF3) ketika post (cybersickness) menunjukkan perbandingan

nilai sinyal alfa mayoritas lebih rendah dari beta setiap partisipan. Selanjutnya adalah tabel visualisasi hasil ekstraksi fitur number-of-peaks seperti Tabel 4.14.

Tabel 4.14 Visualisasi fitur numb. of peaks seluruh channel di semua partisipan

No.	Fitur	Channel	Baseline / Cybersickness	Mayoritas nilai partisipan sinyal alfa terhadap beta
1.	numb peak	1 (AF3)	Baseline	Alfa lebih rendah dari beta
2.	numb peak	1 (AF3)	Cybersickness	Alfa lebih rendah dari beta
3.	numb peak	2 (F7)	Baseline	Alfa lebih rendah dari beta
4.	numb peak	2 (F7)	Cybersickness	Alfa lebih rendah dari beta
5.	numb peak	3 (F3)	Baseline	Alfa lebih rendah dari beta
6.	numb peak	3 (F3)	Cybersickness	Alfa lebih rendah dari beta
7.	numb peak	4 (Fc5)	Baseline	Alfa lebih rendah dari beta
8.	numb peak	4 (Fc5)	Cybersickness	Alfa lebih rendah dari beta
9.	numb peak	5 (T7)	Baseline	Alfa lebih rendah dari beta
10.	numb peak	5 (T7)	Cybersickness	Alfa lebih rendah dari beta
11.	numb peak	6 (P7)	Baseline	Alfa lebih rendah dari beta
12.	numb peak	6 (P7)	Cybersickness	Alfa lebih rendah dari beta
13.	numb peak	7 (O1)	Baseline	Alfa lebih rendah dari beta
14.	numb peak	7 (O1)	Cybersickness	Alfa lebih rendah dari beta
15.	numb peak	8 (O2)	Baseline	Alfa lebih rendah dari beta
16.	numb peak	8 (O2)	Cybersickness	Alfa lebih rendah dari beta
17.	numb peak	9 (P8)	Baseline	Alfa lebih rendah dari beta
18.	numb peak	9 (P8)	Cybersickness	Alfa lebih rendah dari beta
19.	numb peak	10 (T8)	Baseline	Alfa lebih rendah dari beta
20.	numb peak	10 (T8)	Cybersickness	Alfa lebih rendah dari beta
21.	numb peak	11 (Fc6)	Baseline	Alfa lebih rendah dari beta
22.	numb peak	11 (Fc6)	Cybersickness	Alfa lebih rendah dari beta
23.	numb peak	12 (F8)	Baseline	Alfa lebih rendah dari beta
24.	numb peak	12 (F8)	Cybersickness	Alfa lebih rendah dari beta
25.	numb peak	13 (F4)	Baseline	Alfa lebih rendah dari beta
26.	numb peak	13 (F4)	Cybersickness	Alfa lebih rendah dari beta
27.	numb peak	14 (AF4)	Baseline	Alfa lebih rendah dari beta
28.	numb peak	14 (AF4)	Cybersickness	Alfa lebih rendah dari beta

Pada Tabel 4.14 menjelaskan bahwa seluruh channel dan semua partisipan setelah diekstraksi fitur number of peaks. Pada fitur ini ketika kondisi baseline dan cybersickness memiliki ciri yaitu sinyal alfa lebih rendah daripada beta.

Halaman ini sengaja dikosongkan

BAB 5

KESIMPULAN

Pada bab ini akan diberikan kesimpulan yang dapat diambil oleh penulis selama proses penelitian serta saran-saran ke depan untuk meningkatkan penelitian ini.

5.1 Kesimpulan

Berdasarkan hasil uji coba klasifikasi K-NN dan Naive Bayes melalui pengambilan dari beberapa fitur yang telah difilter menggunakan ICA pada setiap datanya, dapat diambil kesimpulan sebagai berikut:

1. Naive Bayes berhasil digunakan untuk melakukan klasifikasi menggunakan kombinasi lima ekstraksi fitur (77,8%), dimana akurasi lebih rendah daripada menggunakan tiga ekstraksi fitur (83,8%) dalam mengetahui pola fisiologis sinyal cybersickness.
2. Peningkatan akurasi ditemukan ketika menggunakan dari 5 fitur menjadi 2 fitur untuk metode KNN, akurasi tertinggi adalah 83,3%. Ini dapat meningkatkan akurasi sebesar 22,7% dalam pemilihan classifier yang bisa digunakan industri game terutama aspek potensi menimbulkan cybersickness.
3. Peningkatan akurasi k-NN dalam mendeteksi cybersickness lebih besar dibandingkan Naive Bayes yang hanya 6%. Fenomena ini memberitahukan bahwa k-NN mempunyai varian akurasi lebih tinggi daripada Naive Bayes dalam mendeteksi cybersickness.

5.2 Saran

Berdasarkan kesimpulan, masih terdapat beberapa kekurangan dari penelitian yaitu, oleh karenanya peneliti memiliki saran:

1. Fitur yang digunakan sebaiknya memiliki nilai signifikan yang dapat membedakan cybersickness atau tidak karena banyak fitur tidak menjamin tingkat perbedaan nilai yang signifikan seperti pada fitur sinyal beta.

Halaman ini sengaja dikosongkan

DAFTAR PUSTAKA

- Ashby, F.G., Isen, A.M., n.d. A Neuropsychological Theory of Positive Affect and Its Influence on Cognition 22.
- Bardwell, W.A., Berry, C.C., Ancoli-Israel, S., Dimsdale, J.E., 1999. Psychological correlates of sleep apnea. *Journal of Psychosomatic Research* 47, 583–596. [https://doi.org/10.1016/S0022-3999\(99\)00062-8](https://doi.org/10.1016/S0022-3999(99)00062-8)
- Berkman, L.F., 1995. The Role of Social Relations in Health Promotion: *Psychosomatic Medicine* 57, 245–254. <https://doi.org/10.1097/00006842-199505000-00006>
- Berry, D.S., Willingham, J.K., Thayer, C.A., 2000. Affect and Personality as Predictors of Conflict and Closeness in Young Adults' Friendships. *Journal of Research in Personality* 34, 84–107. <https://doi.org/10.1006/jrpe.1999.2271>
- Boudraa, A.-O., Cexus, J.-C., 2007. EMD-Based Signal Filtering. *IEEE Transactions on Instrumentation and Measurement* 56, 2196–2202. <https://doi.org/10.1109/TIM.2007.907967>
- Cacioppo, J.T., Kiecolt-Glaser, J.K., n.d. Bert N. Uchino University of Utah 44.
- Cohen, S., 2004. Social Relationships and Health. *American Psychologist* 9.
- Cohen, S., n.d. Psychosocial models of the role of social support in the etiology of physical disease. 30.
- Cohen, S., Doyle, W.J., Turner, R.B., Alper, C.M., Skoner, D.P., 2003. Emotional Style and Susceptibility to the Common Cold: *Psychosomatic Medicine* 65, 652–657. <https://doi.org/10.1097/01.PSY.0000077508.57784.DA>
- Cohen, S., Tyrrell, D.A., Russell, M.A., Jarvis, M.J., Smith, A.P., 1993. Smoking, alcohol consumption, and susceptibility to the common cold. *American Journal of Public Health* 83, 1277–1283. <https://doi.org/10.2105/AJPH.83.9.1277>
- Davidson, R.J., 1992. Anterior cerebral asymmetry and the nature of emotion. *Brain and Cognition* 20, 125–151. [https://doi.org/10.1016/0278-2626\(92\)90065-T](https://doi.org/10.1016/0278-2626(92)90065-T)
- Dennis, T.A., Solomon, B., 2010. Frontal EEG and emotion regulation: Electro cortical activity in response to emotional film clips is associated with reduced mood induction and attention interference effects. *Biological Psychology* 85, 456–464. <https://doi.org/10.1016/j.biopsycho.2010.09.008>
- Diener, E., Seligman, M.E.P., 2002. Very Happy People. *Psychological Science* 13, 81–84. <https://doi.org/10.1111/1467-9280.00415>
- Diykh, M., Li, Y., Wen, P., 2016. EEG Sleep Stages Classification Based on Time Domain Features and Structural Graph Similarity. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 24, 1159–1168. <https://doi.org/10.1109/TNSRE.2016.2552539>
- DROLET, G., DUMONT, I.C., GOSSELIN, I., KINKEAD, R., LAFOREST, S., n.d. ROLE OF ENDOGENOUS OPIOID SYSTEM IN THE REGULATION OF THE STRESS RESPONSE 13.
- Fredrickson, B.L., n.d. What Good Are Positive Emotions? 20.

- Gerra, G., Zaimovic, A., Franchini, D., Palladino, M., Giucastro, G., Reali, N., Maestri, D., Caccavari, R., Delsignore, R., Brambilla, F., 1998. Neuroendocrine responses of healthy volunteers to 'techno-music': relationships with personality traits and emotional state. *International Journal of Psychophysiology* 28, 99–111. [https://doi.org/10.1016/S0167-8760\(97\)00071-8](https://doi.org/10.1016/S0167-8760(97)00071-8)
- Jenke, R., Peer, A., Buss, M., 2014. Feature Extraction and Selection for Emotion Recognition from EEG. *IEEE Transactions on Affective Computing* 5, 327–339. <https://doi.org/10.1109/TAFFC.2014.2339834>
- Jiang, L., Zhang, L., Li, C., Wu, J., 2018. A Correlation-based Feature Weighting Filter for Naive Bayes. *IEEE Transactions on Knowledge and Data Engineering* 1–1. <https://doi.org/10.1109/TKDE.2018.2836440>
- Jurcak, V., Tsuzuki, D., Dan, I., 2007. 10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems. *NeuroImage* 34, 1600–1611. <https://doi.org/10.1016/j.neuroimage.2006.09.024>
- Kennedy, R.S., Fowlkes, J.E., 1992. Simulator Sickness Is Polygenic and polysymptomatic: Implications for Research. *The International Journal of Aviation Psychology* 2, 23–38. https://doi.org/10.1207/s15327108ijap0201_2
- Khoirunnisaa, A.Z., Pane, E.S., Wibawa, A.D., Purnomo, M.H., 2018. Channel Selection of EEG-Based Cybersickness Recognition during Playing Video Game Using Correlation Feature Selection (CFS), in: 2018 2nd International Conference on Biomedical Engineering (IBIOMED). Presented at the 2018 2nd International Conference on Biomedical Engineering (IBIOMED), IEEE, Bali, Indonesia, pp. 48–53. <https://doi.org/10.1109/IBIOMED.2018.8534877>
- Koelstra, S., Muhl, C., Soleymani, M., Jong-Seok Lee, Yazdani, A., Ebrahimi, T., Pun, T., Nijholt, A., Patras, I., 2012. DEAP: A Database for Emotion Analysis Using Physiological Signals. *IEEE Transactions on Affective Computing* 3, 18–31. <https://doi.org/10.1109/T-AFFC.2011.15>
- Lahane, P., Sangaiah, A.K., 2015. An Approach to EEG Based Emotion Recognition and Classification Using Kernel Density Estimation. *Procedia Computer Science* 48, 574–581. <https://doi.org/10.1016/j.procs.2015.04.138>
- Laidlaw, T.M., Booth, R.J., Large, R.G., 1996. Reduction in Skin Reactions to Histamine After a Hypnotic Procedure: *Psychosomatic Medicine* 58, 242–248. <https://doi.org/10.1097/00006842-199605000-00008>
- Laidlaw, T.M., Booth, R.J., Large, R.G., 1994. The variability of type I hypersensitivity reactions: The importance of mood. *Journal of Psychosomatic Research* 38, 51–61. [https://doi.org/10.1016/0022-3999\(94\)90008-6](https://doi.org/10.1016/0022-3999(94)90008-6)
- LaViola, J.J., 2000. A discussion of cybersickness in virtual environments. *ACM SIGCHI Bulletin* 32, 47–56. <https://doi.org/10.1145/333329.333344>
- Li, P., Jiang, W., Su, F., 2016. Single-channel EEG-based mental fatigue detection based on deep belief network. *IEEE*, pp. 367–370. <https://doi.org/10.1109/EMBC.2016.7590716>

- Lyubomirsky, S., King, L., Diener, E., 2005. The Benefits of Frequent Positive Affect: Does Happiness Lead to Success? *Psychological Bulletin* 131, 803–855. <https://doi.org/10.1037/0033-2909.131.6.803>
- McCarthy, L., Wetzel, M., Sliker, J.K., Eisenstein, T.K., Rogers, T.J., 2001. Opioids, opioid receptors, and the immune response. *Drug and Alcohol Dependence* 62, 111–123. [https://doi.org/10.1016/S0376-8716\(00\)00181-2](https://doi.org/10.1016/S0376-8716(00)00181-2)
- Murugappan, M., Yaacob, R.N.S., 2011. Combining Spatial Filtering and Wavelet Transform for Classifying Human Emotions Using EEG Signals. *J. Med. Biol. Eng.* 31, 8.
- Nelson, G., 1990. Women's life strains, social support, coping, and positive and negative affect: Cross-sectional and longitudinal tests of the two-factor theory of emotional well-being. *Journal of Community Psychology* 18, 239–263. [https://doi.org/10.1002/1520-6629\(199007\)18:3<239::AID-JCOP2290180307>3.0.CO;2-N](https://doi.org/10.1002/1520-6629(199007)18:3<239::AID-JCOP2290180307>3.0.CO;2-N)
- Othman, M., Wahab, A., Karim, I., Dzulkifli, M.A., Alshaikli, I.F.T., 2013. EEG Emotion Recognition Based on the Dimensional Models of Emotions. *Procedia - Social and Behavioral Sciences* 97, 30–37. <https://doi.org/10.1016/j.sbspro.2013.10.201>
- Pane, E.S., Zuhriya Khoirunnisaa, A., Wibawa, A.D., Purnomo, M.H., 2018. Identifying Severity Level of Cybersickness from EEG signals using CN2 Rule Induction Algorithm, in: 2018 International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS). Presented at the 2018 International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS), IEEE, Bangkok, Thailand, pp. 170–176. <https://doi.org/10.1109/ICIIBMS.2018.8549968>
- Pedersen, B.K., Hoffman-Goetz, L., 2000. Exercise and the Immune System: Regulation, Integration, and Adaptation. *Physiological Reviews* 80, 1055–1081. <https://doi.org/10.1152/physrev.2000.80.3.1055>
- Petrantonakis, P.C., Hadjileontiadis, L.J., 2010. Emotion Recognition From EEG Using Higher Order Crossings. *IEEE Transactions on Information Technology in Biomedicine* 14, 186–197. <https://doi.org/10.1109/TITB.2009.2034649>
- Pressman, S.D., Cohen, S., 2005. Does positive affect influence health? *Psychological Bulletin* 131, 925–971. <https://doi.org/10.1037/0033-2909.131.6.925>
- Ramirez, R., Vamvakousis, Z., 2012. Detecting Emotion from EEG Signals Using the Emotive Epoc Device, in: Zanzotto, F.M., Tsumoto, S., Taatgen, N., Yao, Y. (Eds.), *Brain Informatics*. Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 175–184. https://doi.org/10.1007/978-3-642-35139-6_17
- Rod A. Martin, 2002. Is Laughter the Best Medicine? *Humor, Laughter, and Physical Health*. *Current Directions in Psychological Science* 11, 216–220.
- Ryff, C.D., Singer, B.H., Diener, G., 2004. Positive health: connecting well-being with biology. *Philosophical Transactions of the Royal Society B: Biological Sciences* 359, 1383–1394. <https://doi.org/10.1098/rstb.2004.1521>
- Salovey, P., Rothman, A.J., Detweiler, J.B., Steward, W.T., 2000. Emotional States and Physical Health. *American Psychologist* 12.

- Scholkmann, F., Boss, J., Wolf, M., 2012. An Efficient Algorithm for Automatic Peak Detection in Noisy Periodic and Quasi-Periodic Signals. *Algorithms* 5, 588–603. <https://doi.org/10.3390/a5040588>
- Seeman, T.E., 1996. Social ties and health: The benefits of social integration. *Annals of Epidemiology* 6, 442–451. [https://doi.org/10.1016/S1047-2797\(96\)00095-6](https://doi.org/10.1016/S1047-2797(96)00095-6)
- Turnip, A., Pardede, J., 2017. Artefacts Removal of EEG Signals with Wavelet Denoising. *MATEC Web of Conferences* 135, 00058. <https://doi.org/10.1051/mateconf/201713500058>
- Vijayan, A.E., Sen, D., Sudheer, A.P., 2015. EEG-Based Emotion Recognition Using Statistical Measures and Auto-Regressive Modeling. *IEEE*, pp. 587–591. <https://doi.org/10.1109/CICT.2015.24>
- Wildmann, J., Niemann, Ju., 1986. INCREASE OF CIRCULATING BETA-ENDORPHIN-LIKE IMMUNOREACTIVITY CORRELATES WITH THE CHANGE IN FEELING OF PLEASANTNESS AFTER RUNNING 38, 7.
- Yoon, H.J., Chung, S.Y., 2013. EEG-based emotion estimation using Bayesian weighted-log-posterior function and perceptron convergence algorithm. *Computers in Biology and Medicine* 43, 2230–2237. <https://doi.org/10.1016/j.combiomed.2013.10.017>
- Yuan-Pin Lin, Chi-Hong Wang, Tzyy-Ping Jung, Tien-Lin Wu, Shyh-Kang Jeng, Jeng-Ren Duann, Jyh-Horng Chen, 2010. EEG-Based Emotion Recognition in Music Listening. *IEEE Transactions on Biomedical Engineering* 57, 1798–1806. <https://doi.org/10.1109/TBME.2010.2048568>
- Yurci, E., n.d. EMOTION DETECTION FROM EEG SIGNALS: CORRELATING CEREBRAL CORTEX ACTIVITY WITH MUSIC EVOKED EMOTION 58.
- Zachariae, R., Jorgensen, M.M., Egekvist, H., Bjerring, P., 2001. Skin reactions to histamine of healthy subjects after hypnotically induced emotions of sadness, anger, and happiness. *Allergy* 56, 734–740. <https://doi.org/10.1034/j.1398-9995.2001.056008734.x>

INDEX

- Ket:  Sinyal Alfa;
 Sinyal Beta;
- Mean01Pre => Mean = fitur; 01 = channel; Pre = baseline
Mean01Post => Mean = fitur; 01 = channel; Post = cybersickness
- Fitur:
Mean = Rata-rata
Var = Variasi
Std = Standard deviasi
Pp = Power Percentage
Nop = Number of Peaks
- Channel:
F(frontal), T(temporal), P(parietal), O(occipital), c(central), p(polar), A(ear lobe)
01 = AF3
02 = F7
03 = F3
04 = Fc5
05 = T7
06 = P7
07 = O1
08 = O2
09 = P8
10 = T8
11 = Fc6
12 = F4
13 = F8
14 = AF4
- X axis => 1- 9 = subjek
1 = S01
2 = S02
3 = S03
4 = S04
5 = S05
6 = S06
7 = S07
8 = S08
9 = S09
- Y axis => nilai satuan
mean, varian, std = μV ; power percentage = $10^2\%$; number of peaks = peaks

Halaman ini sengaja dikosongkan

BIODATA



Nama : Mochammad Asyroful Mawalid

TTL : Sidoarjo, 12 September 1993

Agama: Islam

Alamat: Jl. Sekardangan Indah AA-7 Sidoarjo

No HP : 085733757680

Email : mawalid15@mhs.ee.its.ac.id

Riwayat Pendidikan

No	Tingkat Pendidikan	Institusi	Tahun Lulus
1	SD	SD Negeri Pucang IV Sidoarjo	2005
2	SMP	SMP Negeri 1 Sidoarjo	2008
3	SMA	MA Unggulan Amanatul Ummah Sby	2011
4	S1/D4	Politeknik Elektronika Negeri Surabaya	2015
5	Magister	Institut Teknologi Sepuluh Nopember	2019

Halaman ini sengaja dikosongkan