



**ANALISIS KEUNIKAN FITUR CWT SINYAL EEG UNTUK
PEMBUATAN LIMA INDIKATOR PENGENDALIAN KURSI
RODA BCI**

TESIS



Oleh:

AHMAD KANZU SYAUQI FIRDAUS
146090300011008

**PROGRAM MAGISTER FISIKA
MINAT INSTRUMENTASI**

**PROGRAM PASCASARJANA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN
ALAM
UNIVERSITAS BRAWIJAYA
MALANG**

2018



TESIS

ANALISIS KEUNIKAN FITUR CWT SINYAL EEG UNTUK PEMBUATAN LIMA INDIKATOR PENGENDALIAN KURSI RODA BCI

Oleh:

AHMAD KANZU SYAUQI FIRDAUS

146090300011008

Telah dipertahankan di depan penguji
pada tanggal 26 Desember 2018
dan dinyatakan lulus

KOMISI PEMBIMBING

Ketua

Anggota

Ahmad Nadhir, MT., Ph.D.
NIP.197412031999031002

Dr. Eng. Agus Naba, MT.
NIP.197208061995121001

Program Pascasarjana Fakultas MIPA
Ketua Program Studi S2 Fisika

Mauludi Ariesto Pamungkas, Ph.D.
NIP.197304122000031013



JUDUL TESIS:

ANALISIS KEUNIKAN FITUR CWT SINYAL EEG UNTUK
PEMBUATAN LIMA INDIKATOR PENGENDALIAN KURSI
RODA BCI

Nama Mahasiswa : Ahmad Kanzu Syaqui Firdaus

NIM : 146090300011008

Program Studi : S2 Fisika

Minat : Instrumentasi

KOMISI PEMBIMBING

Ketua : Ahmad Nadhir, MT, Ph.D

Anggota : Dr. Eng. Agus Naba, MT

TIM DOSEN PENGUJI

Dosen Penguji 1 : Dr. *Sugeng Rianto*, M.Sc

Dosen Penguji 2 : Dr. Eng. Didik Rahadi Santoso, M.Si

Tanggal Ujian : 26 Desember 2018

SK Penguji :



PERNYATAAN ORISINALITAS

Saya menyatakan dengan sebenar-benarnya bahwa sepanjang pengetahuan saya, di dalam naskah Tesis ini tidak terdapat karya ilmiah yang pernah diajukan oleh orang lain untuk memperoleh gelar akademik di suatu Perguruan Tinggi, dan tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain, kecuali yang secara tertulis dikutip dalam naskah ini dan disebutkan dalam sumber kutipan dan daftar pustaka.

Apabila ternyata di dalam naskah Tesis ini dapat dibuktikan terdapat unsur-unsur jiplakan (plagiat) tesis, saya bersedia Tesis (MAGISTER) dibatalkan, serta diproses sesuai dengan peraturan perundang-undangan yang berlaku.

Malang,

Mahasiswa,

Ahmad Kanzu Syauqi Firdaus
NIM.146090300011008



RIWAYAT HIDUP



Ahmad Kanza Syauci Firdaus, lahir di Blitar Jawa Timur, tanggal 20 November 1991. Anak dari ayah Ali Rohmad dan Ibu Nanik. SD sampai SMA di kabupaten Tulungagung, lulus SMA tahun 2010. Pendidikan S1 di Jurusan Fisika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang lulus tahun 2014. Pengalaman kerja sebagai instruktur di lembaga kursus NEC Malang 2014-2017. Telah berpengalaman menjadi pemateri dalam pelatihan MATLAB dan SPSS di Institut Teknologi Sepuluh Nopember (ITS) Surabaya pada tanggal 17-28 Juli 2017.

Malang,

Penulis



UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih sebesar-besarnya kepada:

Bapak Ahmad Nadhir sebagai pembimbing utama, Bapak Agus Naba sebagai pembimbing kedua, Ketua Program Studi S2 Fisika, Program Pascasarjana FMIPA Universitas Brawijaya Bapak Mauludi Ariesto Pamungkas, dan

Bapak Rektor Universitas Brawijaya. Penulis juga menyampaikan terima kasih kepada rekan-rekan penulis di S2 Fisika Universitas Brawijaya dan adik kandung penulis Arina Widda Faradis, S.Si yang telah banyak mendoakan, memberikan dukungan dan bantuan, serta ikut berperan dalam memperlancar penelitian dan penulisan tesis ini.

Sujud dan terima kasih yang dalam penulis persembahkan kepada Ibunda dan Ayahanda serta Ibunda dan Ayahanda mertua tercinta, atas dorongan yang kuat, kebijaksanaan, dan doa.

Ucapan terima kasih secara khusus penulis sampaikan kepada istri tercinta Miftakhul Jannah, M.Pd.I yang selalu mendukung dan membuat hari-hari penulis menjadi sangat indah, serta hadirnya anak-anak kami yang shalih dan shalihah sebagai penyejuk mata dan hati dalam keluarga penulis.

Malang,

Penulis



RINGKASAN

Ahmad Kanzu Syauqi Firdaus, Program Pascasarjana Universitas Brawijaya, 2018. Analisis Keunikan Fitur CWT Sinyal EEG untuk Pembuatan Lima Indikator Pengendalian Kursi Roda BCI; Komisi Pembimbing, Ketua: Ahmad Nadhir, Anggota: Agus Naba.

Penelitian ini dilakukan dengan tujuan untuk membuat lima indikator pengendalian kursi roda BCI berdasarkan fitur yang diekstraksi dari sinyal elektroensefalogram (EEG). Sinyal EEG didekomposisi menggunakan metode *continuous wavelet transform* (CWT). Nilai rata-rata absolut dan standar deviasi dari sinyal yang telah didekomposisi tersebut digunakan sebagai fitur. Fitur hasil ekstraksi kemudian dianalisis keunikannya menggunakan metode Friedman. Untuk mendekati sifat alami fitur sinyal EEG yang nonlinier, metode *support vector machine* (SVM) dengan kernel *radial basis function* (RBF) digunakan untuk membuat indikator pengendalian kursi roda BCI berdasarkan fitur sinyal EEG yang paling unik. Hasil penelitian ini menunjukkan bahwa metode yang diusulkan dapat mengukur tingkat keunikan fitur CWT sinyal EEG. Dari penelitian penentuan keunikan fitur CWT dapat diperoleh lima indikator pengendalian untuk kursi roda BCI yang didasarkan pada sinyal EEG dari Neurosky MW001. Akan tetapi, akurasi kelima indikator tersebut belum dapat digunakan sebagai indikator kontrol untuk aktuator kursi roda BCI. Hal ini disebabkan oleh tingkat kepercayaan rata-rata indikator tersebut masih di bawah 60%, sedangkan untuk indikator yang berpasangan masih di bawah 70%.

SUMMARY

Ahmad Kanzu Syauqi Firdaus, Postgraduate Program Brawijaya University, 2018.
The Analysis of CWT Features' Uniqueness of EEG Signals to Generate BCI-Wheelchair's Five Control Indicators. Supervisor: Ahmad Nadhir, Co-supervisor: Agus Naba.

The aim of this research is to generate five control indicators for the BCI-wheelchair using features extracted from electroencephalogram (EEG) signals. The EEG signals are decomposed using the continuous wavelet transform (CWT) method. The absolute mean and deviation standard values of the decomposed signals are used as features. The uniqueness of extracted features is then analyzed using the Friedman method. To approximate the characteristics of the nonlinear EEG signal feature, the support vector machine (SVM) with the radial basis function (RBF) kernel is used to generate BCI-wheelchair's control indicators based on the most unique EEG signals features. This research results indicate that the proposed method can measure the level of uniqueness of the CWT feature from the EEG signal. Based on the study to determine the uniqueness of CWT features, five BCI wheelchair control indicators based on the Neurosky MW001 EEG signal can be obtained. However, the accuracy of these five indicators can not yet be used as a control indicator for the BCI wheelchair actuator. This is because the confidence level of these indicators is still below 60%, while the confidence of the paired indicators is still below 70%.

KATA PENGANTAR

Puji syukur penulis ucapkan kepada Allah SWT yang telah memberikan rahmat yang tidak terhingga sehingga penulis dapat menyusun tesis ini. Terima kasih banyak penulis sampaikan kepada ayah, ibu, ayah mertua, ibu mertua, istri tercinta, anak, saudara-saudara, dan teman-teman penulis yang selalu memberikan dukungan. Terima kasih banyak juga penulis sampaikan kepada para dosen yang telah membimbing penulis, khususnya kepada dosen pembimbing tesis, yaitu Bapak Ahmad Nadhir dan Bapak Agus Naba.

Tesis ini memuat topik tentang pengembangan teknologi *Brain Computer Interface* (BCI), yaitu teknologi kontrol yang menggunakan sinyal otak sebagai sinyal pemicu kontrolnya. Fokus penelitian dalam tesis ini adalah pada teknik analisis keunikan fitur sinyal *electroencephalograph* (EEG) untuk pembuatan lima indikator pengendalian kursi roda BCI.

Harapan penulis adalah penelitian ini dapat memberikan informasi tambahan kepada para peneliti dan pengembang teknologi BCI mengenai teknik analisis keunikan fitur sinyal EEG untuk keperluan pembuatan indikator pengendalian dengan jumlah banyak. Selain itu penulis juga berharap hasil penelitian ini dapat bermanfaat sebagai referensi tambahan untuk semua peneliti yang tertarik untuk mengembangkan teknologi BCI.

Penulis



DAFTAR ISI

DAFTAR ISI

DAFTAR TABEL

DAFTAR GAMBAR

DAFTAR LAMPIRAN

BAB I PENDAHULUAN

1.1 Latar Belakang

1.2 Rumusan Masalah

1.3 Batasan Masalah

1.4 Tujuan Penelitian

1.5 Manfaat Penelitian

BAB II TINJAUAN PUSTAKA

2.1 Perkembangan Teknologi *Brain Computer Interface*

2.2 Sinyal Otak

2.3 *Electroencephalograph*

2.4 *Brain Computer Interface*

2.5 EEG Neurosky Mindwave

2.6 Indikator Pengendalian Kursi Roda BCI

2.7 *Continuous Wavelet Transform*

2.8 Metode Friedman

2.9 *Support Vector Machine*

BAB III KERANGKA KONSEP PENELITIAN

3.1 Konsep Penelitian

3.2 Variabel Penelitian

BAB IV METODE PENELITIAN

Repository Universitas Brawijaya	1
Repository Universitas Brawijaya	iii
Repository Universitas Brawijaya	iv
Repository Universitas Brawijaya	vii
Repository Universitas Brawijaya	1
Repository Universitas Brawijaya	1
Repository Universitas Brawijaya	3
Repository Universitas Brawijaya	3
Repository Universitas Brawijaya	4
Repository Universitas Brawijaya	4
Repository Universitas Brawijaya	5
Repository Universitas Brawijaya	5
Repository Universitas Brawijaya	8
Repository Universitas Brawijaya	10
Repository Universitas Brawijaya	12
Repository Universitas Brawijaya	14
Repository Universitas Brawijaya	18
Repository Universitas Brawijaya	18
Repository Universitas Brawijaya	21
Repository Universitas Brawijaya	22
Repository Universitas Brawijaya	30
Repository Universitas Brawijaya	30
Repository Universitas Brawijaya	31
Repository Universitas Brawijaya	32

Repository Universitas Brawijaya	1
Repository Universitas Brawijaya	iii
Repository Universitas Brawijaya	iv
Repository Universitas Brawijaya	vii
Repository Universitas Brawijaya	1
Repository Universitas Brawijaya	1
Repository Universitas Brawijaya	3
Repository Universitas Brawijaya	3
Repository Universitas Brawijaya	4
Repository Universitas Brawijaya	4
Repository Universitas Brawijaya	5
Repository Universitas Brawijaya	5
Repository Universitas Brawijaya	8
Repository Universitas Brawijaya	10
Repository Universitas Brawijaya	12
Repository Universitas Brawijaya	14
Repository Universitas Brawijaya	18
Repository Universitas Brawijaya	18
Repository Universitas Brawijaya	21
Repository Universitas Brawijaya	22
Repository Universitas Brawijaya	30
Repository Universitas Brawijaya	30
Repository Universitas Brawijaya	31
Repository Universitas Brawijaya	32

Repository Universitas Brawijaya	Repository Universitas Brawijaya	Repository Universitas Brawijaya
Repository Universitas Brawijaya	Repository Universitas Brawijaya	Repository Universitas Brawijaya
Repository Universitas Brawijaya	Repository Universitas Brawijaya	Repository Universitas Brawijaya
4.1 Tempat dan Waktu Penelitian	32	Repository Universitas Brawijaya
4.2 Alat dan Bahan	32	Repository Universitas Brawijaya
4.3 Prosedur Penelitian	32	Repository Universitas Brawijaya
4.3.1 Studi Literatur	33	Repository Universitas Brawijaya
4.3.2 Penyusunan Sistem Instrumentasi	33	Repository Universitas Brawijaya
4.3.3 Pengujian Sistem Instrumentasi	33	Repository Universitas Brawijaya
4.3.4 Pengambilan Data	35	Repository Universitas Brawijaya
4.3.5 Pemrosesan Data	36	Repository Universitas Brawijaya
4.3.6 Analisis dan Interpretasi	41	Repository Universitas Brawijaya
BAB V HASIL DAN PEMBAHASAN	42	Repository Universitas Brawijaya
5.1 Hasil Pengujian Sistem Instrumentasi	42	Repository Universitas Brawijaya
5.2 Hasil Pengambilan Data	52	Repository Universitas Brawijaya
5.3 Hasil Pemrosesan Data	52	Repository Universitas Brawijaya
5.4 Hasil Analisis Keunikan Fitur	55	Repository Universitas Brawijaya
5.5 Pembuatan Indikator Pengendalian Kursi Roda	61	Repository Universitas Brawijaya
5.6 Pembahasan	66	Repository Universitas Brawijaya
BAB VI KESIMPULAN DAN SARAN	71	Repository Universitas Brawijaya
6.1 Kesimpulan	71	Repository Universitas Brawijaya
6.2 Saran	71	Repository Universitas Brawijaya
DAFTAR PUSTAKA	72	Repository Universitas Brawijaya
LAMPIRAN	94	Repository Universitas Brawijaya



DAFTAR TABEL

Tabel 2.1	Rangkuman penelitian teknologi BCI	6
Tabel 2.2	Frekuensi gelombang otak dan kondisi mentalnya	11
Tabel 2.3	Spesifikasi Neurosky Mindwave MW001	15
Tabel 2.4	Protokol <i>output</i> Neurosky Mindwave	17
Tabel 2.5	Contoh 10 model SVM dengan metode OAO untuk lima kelas	29
Tabel 5.1	Hasil investigasi pembuatan indikator pengendalian kursi roda BCI	62
Tabel 5.2	Kesesuaian hasil investigasi model klasifikasi terhadap keunikan fitur	63
Tabel 5.3	Matriks <i>confusion</i> pembuatan indikator pengendalian kursi roda BCI	64
Tabel 5.4	Akurasi indikator pengendalian kursi roda BCI hasil evaluasi	65

DAFTAR GAMBAR

Gambar 2.1	Perubahan potensial membran neuron dan bentuk sinyal listrik otak yang dihasilkan	9
Gambar 2.2	Contoh komponen ritmis dari sinyal EEG selama 1 sekon; (a) dalam domain waktu; (b) dalam domain frekuensi	12
Gambar 2.3	Prinsip kerja BCI	13
Gambar 2.4	Bagian-bagian dari Neurosky Mindwave model MW001	15
Gambar 2.5	Ilustrasi <i>hyperplane</i> dari data yang terpisah secara linier	23
Gambar 2.6	Ilustrasi <i>hyperplane</i> dari data yang terpisah secara nonlinier	26
Gambar 2.7	Contoh klasifikasi dengan metode OAO	29
Gambar 3.1	Kerangka konsep penelitian	30
Gambar 4.1	Diagram alur prosedur penelitian	32
Gambar 4.2	Susunan Sistem Instrumentasi	33
Gambar 4.3	Diagram alir pengambilan data pada satu subjek	35
Gambar 4.4	Diagram alir pemrosesan data	36
Gambar 4.5	Contoh grafik tingkat keunikan fitur	38
Gambar 4.6	Contoh grafik signifikansi keunikan fitur	39
Gambar 5.1	Sinyal yang dihasilkan saat MW001 tidak digunakan	42
Gambar 5.2	Spektrum frekuensi sinyal saat MW001 tidak digunakan	42
Gambar 5.3	Nilai <i>poor signal</i> saat MW001 dihidupkan namun tidak digunakan	43
Gambar 5.4	Sinyal yang dihasilkan saat MW001 digunakan tanpa menghubungkan <i>ground</i> dengan daun telinga	43
Gambar 5.5	Spektrum sinyal saat MW001 digunakan tanpa menghubungkan klip <i>ground</i> dengan daun telinga	44
Gambar 5.6	Nilai <i>poor signal</i> saat MW001 digunakan tanpa menghubungkan <i>ground</i> dengan daun telinga	44
Gambar 5.7	Sinyal yang dihasilkan saat MW001 dihidupkan dan elektrodanya disentuh ke organ tubuh lain	45

- Gambar 5.8 Spektrum frekuensi sinyal saat MW001 dihidupkan dan disentuhkan ke organ tubuh lain 45
- Gambar 5.9 Nilai *poor signal* saat MW001 dihidupkan dan disentuhkan ke organ tubuh lain 46
- Gambar 5.10 Sinyal yang dihasilkan saat MW001 dihidupkan dan digunakan dengan pemberian interferensi berupa jari tangan pada elektrode sensornya 47
- Gambar 5.11 Spektrum frekuensi sinyal saat MW001 dihidupkan dan digunakan dengan pemberian interferensi organ tubuh lain pada elektrode sensornya 47
- Gambar 5.12 Nilai *poor signal* saat MW001 dihidupkan dan digunakan dengan pemberian interferensi organ tubuh lain pada elektrode sensornya 48
- Gambar 5.13 Sinyal yang dihasilkan saat MW001 digunakan dengan pemberian interferensi berupa kertas tebal pada elektrode sensornya 48
- Gambar 5.14 Spektrum frekuensi sinyal saat MW001 digunakan dengan pemberian interferensi berupa kertas tebal pada elektrode sensornya 49
- Gambar 5.15 Nilai *poor signal* saat MW001 digunakan dengan pemberian interferensi berupa kertas tebal pada elektrode sensornya 49
- Gambar 5.16 Sinyal yang dihasilkan saat MW001 digunakan dengan benar 50
- Gambar 5.17 Spektrum frekuensi sinyal EEG saat alat digunakan dengan benar 50
- Gambar 5.18 Nilai *poor signal* saat alat digunakan dengan benar 50
- Gambar 5.19 Spektrum sinyal yang direkam oleh Neurosky Mindwave saat alat digunakan dengan benar 51
- Gambar 5.20 Sinyal EEG untuk indikator maju; (a) subjek 1 (b) subjek 2 (c) subjek 3 52

- Gambar 5.21 Sinyal EEG untuk indikator maju yang sudah difilter; (a) subjek 1 (b) subjek 2 (c) subjek 3 53
- Gambar 5.22 Hasil CWT sinyal EEG untuk indikator maju; (a) subjek 1 (b) subjek 2 (c) subjek 3 53
- Gambar 5.23 Fitur $|\mu|$ hasil CWT sinyal EEG untuk indikator maju; (a) subjek 1 (b) subjek 2 (c) subjek 3. 54
- Gambar 5.24 Fitur σ hasil CWT sinyal EEG untuk indikator maju; (a) subjek 1 (b) subjek 2 (c) subjek 3 55
- Gambar 5.25 Tingkat keunikan fitur $|\mu|$ hasil CWT sinyal EEG; (a) subjek 1 (b) subjek 2 (c) subjek 3 56
- Gambar 5.26 Tingkat keunikan fitur σ hasil CWT sinyal EEG; (a) subjek 1 (b) subjek 2 (c) subjek 3 56
- Gambar 5.27 Signifikansi keunikan fitur $|\mu|$ hasil CWT sinyal EEG; (a) subjek 1 (b) subjek 2 (c) subjek 3 58
- Gambar 5.28 Signifikansi keunikan fitur σ hasil CWT sinyal EEG; (a) subjek 1 (b) subjek 2 (c) subjek 3 58
- Gambar 5.29 Sebaran data dua fitur yang tingkat keunikannya tinggi dan signifikan 59
- Gambar 5.30 Sebaran data dua fitur yang tingkat keunikannya sedang dan signifikan 60
- Gambar 5.31 Sebaran data dua fitur yang tingkat keunikannya rendah dan tidak signifikan 61



DAFTAR LAMPIRAN

Lampiran 1	Sintaksis program perekam sinyal EEG menggunakan Neurosky Mindwave MW001	94
Lampiran 2	Sinyal EEG	96
Lampiran 3	Sintaksis program <i>pre-processing</i>	99
Lampiran 4	Sintaksis program ekstraksi fitur sinyal EEG menggunakan CWT	100
Lampiran 5	Sintaksis program analisis keunikan fitur menggunakan metode Friedman	107
Lampiran 6	Sintaksis Fungsi “friedmanfcn”	109
Lampiran 7	Sintaksis program pembuatan model klasifikasi SVM SMO RBF OAO	110
Lampiran 8	Sintaksis program investigasi model klasifikasi SVM	113
Lampiran 9	Sintaksis program evaluasi pembuatan indikator pengendalian kursi roda BCI	116
Lampiran 10	Indikator Pengendalian Kursi Roda	117



BAB I

PENDAHULUAN

1.1 Latar Belakang

Banyaknya penyandang disabilitas fungsi mobilitas di dunia menjadi alasan pentingnya pengembangan kursi roda berteknologi *brain computer interface* (BCI) (Balaji dan Venkatasubramanian, 2009; Kraus, 2017). Kursi roda BCI bisa digunakan untuk membantu penyandang disabilitas yang kesulitan mengendalikan kursi roda mekanik karena kursi roda BCI merekam sinyal otak menggunakan elektroensefalograf (EEG) dan memprosesnya sehingga dapat dikendalikan secara mental (Gneo dan Severini, 2011; Al-Qaysi *et al.*, 2018).

Pengembangan kursi roda BCI memiliki persoalan yang menantang. Fitur sinyal EEG bersifat nonlinier (Siuly, 2012; Carvalho *et al.*, 2015; Al-Qammaz, Ahmad dan Yusof, 2016; Torse, Desai dan Khanai, 2018). Sifat ketidaklinieran fitur sinyal EEG menjadi hambatan utama dalam pembuatan BCI yang reliabel dan presisi (Rak, Majkowski dan Kołodziej, 2012; Pattnaik dan Sarraf, 2018). Padahal syarat BCI yang reliabel dan presisi adalah fitur sinyal EEG harus unik terhadap sejumlah perintah mental yang berbeda (Abdalsalam M *et al.*, 2018).

Untuk menjawab tantangan-tantangan tersebut, banyak pilihan metode yang dapat digunakan untuk mengekstraksi fitur sinyal EEG. Berdasarkan domainnya, teknik ekstraksi fitur sinyal EEG dibagi menjadi tiga, antara lain: domain waktu, domain frekuensi, dan domain waktu-frekuensi (Gysels, Renevey dan Celka, 2005; Kołodziej, Majkowski dan Remigiusz, 2012; Wang, Veluvolu dan Lee, 2013; Ali *et al.*, 2016; Siswoyo, Arief dan Sulistijono, 2017; Bousseta *et al.*, 2018). Diantara

ketiga pilihan tersebut, teknik ekstraksi fitur domain waktu-frekuensi lebih cocok diterapkan pada sinyal EEG karena dapat menjaga keutuhan komponen *even-related desynchronization* (ERD) yang berkaitan langsung dengan perintah mental dan bersifat kompleks di dalam sinyal EEG (Rahul, Sharma dan Paul, 2017; Krishnan dan Athavale, 2018). Menurut Bostanov (Bostanov, 2004) dan Hsu (Hsu dan Sun, 2009), salah satu metode ekstraksi fitur domain waktu-frekuensi yang cukup populer untuk pengembangan BCI adalah *continuous wavelet transform* (CWT). Kelebihan CWT adalah kemampuannya menjabarkan sinyal dengan sangat detail dalam domain waktu frekuensi (Aydemir dan Kayıkçıoğlu, 2016).

Ekstraksi fitur saja belum cukup untuk menjawab tantangan sistem BCI mengenai keunikan fitur terhadap pengendalian mental, maka fitur hasil ekstraksi masih perlu diketahui tingkat keunikannya. Penelitian (Bostanov, 2015; Hsu, 2015) menggunakan uji-t dua sampel untuk mengukur tingkat keunikan sekaligus menyeleksi fitur-fitur hasil dekomposisi CWT. Untuk kursi roda BCI dengan lima indikator pengendalian, penggunaan uji-t menjadi tidak relevan. Sebagai alternatif uji-t, Metode Friedman lebih relevan digunakan karena sesuai dengan sifat fitur sinyal, yaitu dihasilkan oleh lebih dari dua sampel (lima indikator pengendalian) dan berasal dari subjek yang sama (dependen) (Simões, 2011; Granato, de Araújo Calado dan Jarvis, 2014). Validitas metode Friedman juga cukup kuat (Chatfield dan Mander, 2009; Eisinga *et al.*, 2017), terutama untuk data dengan jumlah yang besar (Zimmerman dan Zumbo, 1993). Menurut Porkka (Porkka, Jussila dan Suominen, 2008), penghitungan metode Friedman yang berbasis peringkat membuatnya dapat menghilangkan efek nonlinier dalam suatu data sehingga yang semula tidak dapat dibandingkan menjadi bisa dibandingkan.

Penelitian ini dilakukan dengan merekam sinyal EEG dan mengekstraksi fitur-fiturnya menggunakan CWT. Perekaman sinyal dilakukan untuk lima indikator pengendalian kursi roda, yaitu: netral, maju, belok kanan, belok kiri, dan mundur.

Fitur-fitur hasil ekstraksi kemudian dianalisis keunikannya menggunakan metode Friedman. Fitur yang paling unik digunakan untuk pembuatan indikator pengendalian kursi roda BCI menggunakan metode *support vector machine* (SVM).

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, rumusan masalah dalam penelitian ini antara lain:

1. Bagaimana membuat lima indikator pengendalian kursi roda BCI dari sinyal EEG?
2. Seberapa akurat indikator pengendalian kursi roda BCI yang dihasilkan?

1.3 Batasan Masalah

Berdasarkan masalah yang telah dirumuskan, didapatkan batasan-batasan masalah sebagai berikut:

1. Penelitian ini berusaha untuk membuat indikator yang dapat digunakan untuk pengendalian kursi roda BCI, bukan membuat kursi roda BCI.
2. Sinyal EEG direkam menggunakan Neurosky Mindwave.
3. Pengambilan data dilakukan pada tiga subjek yang sehat jasmani dan rohani dengan lima indikator pengendalian kursi roda, yaitu: netral, maju, belok kanan, belok kiri, dan mundur.

4. Teknik ekstraksi fitur yang digunakan adalah *continuous wavelet transform* (CWT) dan keunikan setiap fitur dianalisis menggunakan metode Friedman.

5. Teknik klasifikasi yang digunakan adalah *support vector machine* (SVM).

1.4 Tujuan Penelitian

Tujuan penelitian ini antara lain:

1. Menggunakan sinyal EEG untuk membuat lima indikator yang dapat digunakan untuk pengendalian kursi roda BCI.

2. Mengukur tingkat akurasi indikator pengendalian kursi roda BCI yang telah dibuat.

1.5 Manfaat Penelitian

Manfaat yang ingin dihasilkan dari penelitian ini adalah didapatkannya informasi tambahan mengenai teknik analisis keunikan fitur yang diekstraksi dari sinyal EEG terhadap lima indikator pengendalian kursi roda BCI. Hasil penelitian ini diharapkan dapat bermanfaat untuk peneliti lain di bidang BCI.



BAB II

TINJAUAN PUSTAKA

2.1 Perkembangan Teknologi *Brain Computer Interface*

Telah banyak pengembangan teknologi *brain computer interface* (BCI) untuk kursi roda yang menggunakan EEG Neurosky Mindwave. Berdasarkan mode operasionalnya, Bi (Bi, Fan dan Liu, 2013) membagi pengembangan kursi roda BCI menjadi dua jenis, yaitu kursi roda BCI *direct control* dan kursi roda BCI *shared control*. Kursi roda BCI *direct control* menggunakan indikator pengendalian yang diekstraksi dari sinyal EEG untuk mengendalikan kursi roda BCI secara langsung. Sedangkan kursi roda BCI *shared control* dikendalikan tidak sepenuhnya oleh indikator pengendalian yang diekstraksi dari sinyal EEG, melainkan dikendalikan pula oleh robot dengan sensor lain, seperti sensor ultrasonik dan kamera digital.

Berdasarkan penggunaannya, kursi roda BCI dapat dibagi menjadi dua, yaitu kursi roda BCI sistem umum dan kursi roda BCI sistem khusus. Kursi roda BCI sistem umum, sebagaimana yang dikembangkan oleh Ruiz (Ruiz, 2011), Girase (Girase dan Deshmukh, 2015), Folane (Folane *et al.*, 2017), dan De Souza (De Souza dan Lamounier, 2017), dibuat agar bisa dikendalikan oleh semua orang tanpa adanya proses pembelajaran untuk pembuatan indikator pengendaliannya. Kursi roda BCI sistem umum memanfaatkan fitur-fitur sinyal EEG yang cenderung identik pada semua orang, yaitu: fitur nilai konsentrasi (*attention*), relaksasi (*meditation*), dan kekuatan kedipan mata (*blink strength*). Sensor EEG konvensional seperti Neurosky Mindwave telah menyediakan fitur-fitur tersebut.

Berbeda dengan kursi roda BCI sistem umum, Kursi roda BCI sistem khusus hanya bisa dioperasikan oleh subjek yang sinyal EEG-nya telah direkam dan digunakan dalam proses pembuatan indikator pengendaliannya. Berdasarkan penelitian Karam (Karam *et al.*, 2016) dan Siswoyo (Siswoyo, Arief dan Sulistijono, 2017), umumnya kursi roda BCI sistem khusus menggunakan fitur-fitur yang boleh jadi tidak identik antara satu orang dengan orang lainnya. Contoh fitur-fitur yang biasa digunakan pada kursi roda BCI sistem khusus antara lain: fitur densitas daya spektrum, fitur waktu-frekuensi, energi spektrum, dan lain-lain.

Tabel 2.1 Rangkuman penelitian teknologi BCI

Peneliti	Jenis Sistem	Jumlah Kanal EEG	Jumlah Indikator Pengendalian	Akurasi
Darvishi dan Al-ani, 2007	Sistem Khusus, Direct Control	3	2	81.43%
Hsu dan Sun, 2009	Sistem Khusus, Direct Control	2	2	89.30%
Bassani, 2009	Sistem Khusus, Direct Control	32	2	70.04%
Ruiz, 2011	Sistem Umum, Direct Control	1	5	61.35%
Aydemir dan Kayikcioglu, 2011	Sistem Khusus, Direct Control	64	2	94.00%
Karimoi <i>et al.</i> , 2014	Sistem Khusus, Direct Control	100	3	99.00%
Girase dan Deshmukh, 2015	Sistem Umum, Direct Control	1	4	95.00%
Castillo-Garcia <i>et al.</i> , 2015	Sistem Khusus, Direct Control	14	4	89.00%
Karam <i>et al.</i> , 2016	Sistem Khusus, Direct Control	1	5	70.00%
Folane <i>et al.</i> , 2017	Sistem Umum, Direct Control	1	4	80.00%
Siswoyo, Arief dan Sulistijono, 2017	Sistem Khusus, Direct Control	1	3	92.49%
De Souza dan Lamounier, 2017	Sistem Umum, Shared Control	1	5	87.00%

Tabel 2.1 merangkum beberapa penelitian BCI. Tabel 2.1 dilengkapi dengan kolom yang memuat informasi mengenai jenis sistem BCI yang digunakan. Berdasarkan Tabel 2.1, jenis sistem, jumlah kanal sensor, dan jumlah indikator pengendalian yang beragam menghasilkan nilai akurasi yang beragam. Mengenai akurasi indikator pengendalian yang dihasilkan, informasi yang dapat diambil dari Tabel 2.1 antara lain:

1. Pembuatan dua indikator pengendalian BCI dengan akurasi tertinggi adalah Aydemir (Aydemir dan Kayikcioglu, 2011) yang menggunakan 64 kanal sensor EEG, yaitu sebesar 94%.
2. Pembuatan tiga indikator pengendalian BCI dengan akurasi tertinggi adalah Karimoi (Karimoi *et al.*, 2014) yang menggunakan 100 kanal sensor EEG, yaitu sebesar 99%. Siswoyo (Siswoyo, Arief dan Sulistijono, 2017) yang menggunakan sensor EEG berkanal tunggal juga dapat membuat tiga indikator pengendalian BCI dengan akurasi yang cukup besar, yaitu sebesar 92,49%.
3. Pembuatan empat indikator pengendalian BCI dengan akurasi tertinggi adalah Girase (Girase dan Deshmukh, 2015) yang menggunakan sensor EEG kanal tunggal, yaitu 95%. Nilai akurasi tersebut lebih tinggi dibandingkan yang diperoleh Castillo-Garcia (Castillo-Garcia *et al.*, 2015) yang menggunakan 14 kanal sensor EEG, yaitu sebesar 89%.
4. Pembuatan lima indikator pengendalian BCI dengan akurasi tertinggi adalah De Souza (De Souza dan Lamounier, 2017), yaitu sebesar 87%.

Penulis belum menemukan penelitian pembuatan lima indikator pengendalian BCI yang tidak menggunakan EEG sensor tunggal.


Meskipun penelitian-penelitian BCI dalam Tabel 4.1 bervariasi, korelasi antara jumlah kanal dengan nilai akurasi indikator pengendalian pada teknologi BCI masih belum diketahui.

Delapan dari 12 penelitian dalam Tabel 4.1 mengembangkan kursi roda BCI sistem khusus. Meskipun kursi roda BCI sistem khusus membutuhkan waktu persiapan yang lebih banyak dibandingkan kursi roda BCI sistem umum karena tahap persiapannya lebih banyak (pengumpulan data, proses pembelajaran sistem, dan evaluasi), kursi roda BCI sistem khusus sepatutnya lebih memungkinkan untuk digunakan oleh hampir semua penyandang disabilitas karena fitur-fitur sinyal EEG yang digunakan memang disesuaikan dengan kemampuan dan keadaan penggunaannya.

2.2 Sinyal Otak

Menurut Nunez (Nunez dan Srinivasan, 2006), otak berisi sekitar 10^{10} sel saraf dan setiap *dendrite* sel saraf terhubung tanpa bersentuhan dengan *axon terminal* sel saraf lainnya. Sinyal yang ditangkap oleh EEG adalah beda potensial pada kulit kepala yang ditangkap oleh dua elektrode, yaitu elektrode kanal dan elektrode referensi (Seeck *et al.*, 2017; Gao *et al.*, 2018). Potensial listrik otak ditimbulkan oleh *dipole-dipole* listrik yang dibentuk oleh *post-synaptic potential*, yaitu *action potential* yang terjadi tepat setelah *neurotransmitter* dari *axon terminal* suatu sel saraf mencapai dendrit suatu sel saraf lainnya (Sanei dan Chambers, 2007). Sedangkan *action potential* itu sendiri ditimbulkan oleh aktivitas ionik pada setiap sel saraf (Tatum *et al.*, 2008). Oleh karena potensial yang ditangkap oleh elektrode EEG bersumber dari sekumpulan banyak *post-*

synaptic potential, sedangkan *post-synaptic potential* itu sendiri dipicu oleh *neurotransmitter*, maka potensial tersebut berkaitan dengan aktivitas otak (Graumann, Allison dan Pfurtscheller, 2010). Gambar 2.1 diambil dan direkonstruksi dari buku yang ditulis oleh Sanei (Sanei dan Chambers, 2007) yang mengilustrasikan perubahan potensial membran neuron dan bentuk sinyal listrik otak yang dihasilkan.



Gambar 2.1 Perubahan potensial membran neuron dan bentuk sinyal listrik otak yang dihasilkan

Ditinjau dari frekuensinya, terdapat komponen kompleks di dalam sinyal otak yang disebut *event-related desynchronization* (ERD) (Rahul, Sharma dan Paul, 2017; Krishnan dan Athavale, 2018). Selain ERD, ada juga komponen *event related synchronisation* (ERS). Menurut Wang (Wang *et al.*, 2012), selama otak melakukan perintah mental, maka ERD akan terjadi, yaitu berkurangnya ritme motor sensoris pada frekuensi 8 – 12 Hz. Menurut Thomas (Thomas, Fruitet dan Clerc, 2013), tepat setelah perintah mental berakhir, maka ERS muncul yang ditandai oleh meningkatnya daya pada komponen beta (13 – 35 Hz) pada sinyal

otak. Menurut Pfurtscheller (Pfurtscheller dan Neuper, 2006), ERD/ERS sangat stabil bahkan sampai dua tahun dan cocok digunakan untuk BCI. Meskipun komponen ERD/ERS berpotensi besar untuk dijadikan fitur dalam pembuatan BCI, sifat fitur sinyal EEG adalah nonlinier (Siuly, 2012; Carvalho *et al.*, 2015; Al-Qammaz, Ahmad dan Yusof, 2016; Torse, Desai dan Khanai, 2018). Dengan demikian, penyimpangan-penyimpangan dalam BCI sangat mungkin terjadi.

2.3 *Electroencephalograph*

Electroencephalograph (EEG) ditemukan oleh Hans Berger pada tahun 1929 (Vaque, 1999; Kalagi *et al.*, 2017). EEG adalah alat yang dapat merekam aktivitas kelistrikan otak melalui elektrode tertentu yang ditempelkan pada kulit kepala (Teplan, 2002; Tyagi, Semwal dan Shah, 2012). Elektrode standar dalam perekaman EEG adalah elektrode Ag-AgCl dengan gel konduktif (Fiedler *et al.*, 2014; Fatoorechi *et al.*, 2015; Pedrosa *et al.*, 2016). EEG Ag-AgCl bisa menerima impedansi di bawah 20 k Ω , namun impedansi kulit adalah lebih dari itu (Lopez-Gordo, Sanchez-Morillo dan Pelayo Valle, 2014). Agar impedansi kulit menjadi kurang dari 20 k Ω , pasta abrasif diaplikasikan di permukaan kulit tempat elektrode ditempelkan untuk menghilangkan komponen *stratum corneum* (SC) pada kulit (Alba *et al.*, 2010; Albulbul, 2016). SC merupakan kontributor utama pada impedansi kulit (Cardu *et al.*, 2012; Lu *et al.*, 2018).

Terdapat beberapa kekurangan pada EEG basah (Ag-AgCl) sehingga tidak cocok digunakan untuk BCI, yaitu: waktu persiapan yang dibutuhkan cukup lama, harganya sangat mahal, dan bisa menyebabkan iritasi kulit (*erythema*) (Chi, Jung dan Cauwenberghs, 2010). EEG dengan elektrode kering bisa menggantikan peran

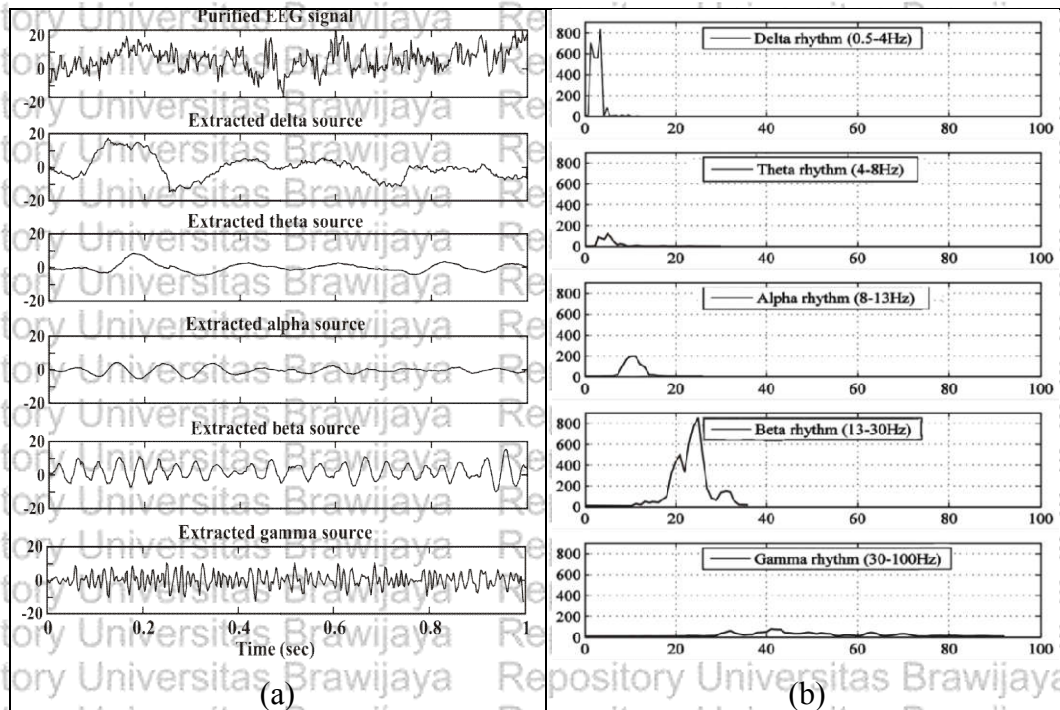
EEG Ag-AgCl karena hasil perekamannya bisa sebaik EEG Ag-AgCl, lebih nyaman digunakan, dan lebih fleksibel (Sellers *et al.*, 2009; Mihajlović, Garcia-Molina dan Peuscher, 2013; Xing *et al.*, 2018). Menurut Fonseca (Fonseca *et al.*, 2007), untuk mengatasi masalah impedansi kulit, EEG elektrode kering dibuat dengan menggunakan prinsip pengukuran diferensial yang menggunakan penguat *front-end* dengan *common-mode rejection ratio* (CMRR) sangat tinggi, sehingga dapat mencegah interferensi elektromagnetik (EMI) yang sebagian besar terkopel pada kulit dan elektrode. Menurut Wolpaw (Wolpaw dan Wolpaw, 2012), *stainless steel*, emas, dan perak adalah contoh material yang cocok untuk elektrode EEG kering karena inert dengan keringat sehingga mencegah korosi material yang bisa menimbulkan *noise* elektrokimia dan degradasi sinyal.

Tabel 2.2 Frekuensi gelombang otak dan kondisi mentalnya

Jenis Gelombang Otak	Rentang Frekuensi	Keadaan dan Kondisi Mental
Delta	0.1 Hz s.d. 3 Hz	Tidur lelap, tidur tanpa bermimpi, tidak sadarkan diri
Teta	4 Hz s.d. 7 Hz	Intuitif, kreatif, ingatan, fantasi, khayalan, dan mimpi
Alfa	8 Hz s.d. 12 Hz	Rileks namun tidak mengantuk, tenang, dan sadar
Beta Rendah	12 Hz s.d. 15 Hz	Sensory Motor Rhythm (SMR), santai namun terfokus, terintegrasi
Beta Tengah	16 Hz s.d. 20 Hz	Berpikir, sadar betul terhadap diri sendiri dan lingkungan
Beta Tinggi	21 Hz s.d. 30 Hz	Waspada, agitasi
Gama	30 Hz s.d. 100 Hz	Fungsi motorik, aktivitas mental yang lebih tinggi

Ada lima frekuensi sinyal EEG yang berkaitan dengan kondisi mental, yaitu: delta, teta, alfa, beta, dan gama (Neurosky, 2009; Larsen dan Wang, 2011; Girase dan Deshmukh, 2015). Tabel 2.2 dibuat berdasarkan uraian Ahn (Ahn *et al.*, 2013) dan Azali (Azali, 2015) yang menyajikan hubungan antara frekuensi

gelombang otak dengan kondisi mental. Berdasarkan Tabel 2.2, komponen sinyal otak alfa, beta, dan gama terlibat dalam aktivitas perintah mental.



Gambar 2.2 Contoh komponen ritmis dari sinyal EEG selama 1 detik; (a) dalam domain waktu; (b) dalam domain frekuensi

Gambar 2.2 mengilustrasikan sinyal EEG beserta komponen ritmisnya dalam domain waktu dan domain frekuensi. Gambar 2.2 direkonstruksi dari Rashed-Al-Mahfuz (Rashed-Al-Mahfuz *et al.*, 2013) dengan modifikasi pada skalanya.

2.4 Brain Computer Interface

Gambar 2.3 mendeskripsikan prinsip kerja teknologi *brain computer interface* (BCI) yang diadaptasi dari Chang (Chang *et al.*, 2016), McFarland (McFarland dan Wolpaw, 2017), Al-Qaysi (Al-Qaysi *et al.*, 2018), dan Tiwari (Tiwari *et al.*, 2018). Sinyal otak diakuisisi lalu diproses sedemikian rupa

sehingga menghasilkan indikator yang dapat digunakan untuk mengendalikan aktuator. Dengan demikian, BCI memungkinkan manusia untuk bisa langsung berinteraksi dengan perangkat aktuator dengan perintah mental tanpa adanya gerakan anggota badan secara aktual.



Gambar 2.3 Prinsip kerja BCI

Sinyal otak yang diakuisisi untuk pembuatan BCI tidak hanya EEG. Satu contoh jenis sinyal otak selain EEG adalah *electrocorticographic* (ECoG). Sinyal ECoG adalah sinyal otak yang ditangkap oleh elektrode yang diimplantasi di bawah tengkorak sehingga sinyal yang dihasilkan kualitasnya lebih baik dibandingkan sinyal EEG (Oosugi *et al.*, 2017). Meskipun ECoG menghasilkan kualitas sinyal yang lebih baik dari EEG dan memungkinkan untuk digunakan dalam pembuatan BCI, ECoG lebih riskan terhadap kesehatan penggunanya dibandingkan EEG (Hill *et al.*, 2012; Ramadan dan Vasilakos, 2017).

Sinyal otak yang telah direkam kemudian diproses agar menghasilkan indikator-indikator yang dapat digunakan untuk menggerakkan aktuator BCI. Pemrosesan sinyal otak yang umumnya diterapkan dalam BCI antara lain: *filtering*, ekstraksi fitur, dan klasifikasi fitur (Müller-Putz, 2011; Nicolas-Alonso

dan Gomez-Gil, 2012; Choi, 2013). Tahap *filtering* diperlukan untuk


menghilangkan sinyal-sinyal yang tidak ada hubungannya dengan aktivitas perintah mental (*noise*) (Wang dan Jung, 2011). Tahap ekstraksi fitur adalah proses pengambilan komponen-komponen dari sinyal otak yang unik dan berkaitan erat dengan aktivitas perintah mental (Millán *et al.*, 2010). Fitur sinyal otak bisa berbentuk komponen frekuensinya, komponen hasil dekomposisinya, densitas daya spektrumnya, entropinya, standar deviasinya, dan lain sebagainya (Jing Fan *et al.*, 2015; Kevric dan Subasi, 2017; Zarei *et al.*, 2017). Untuk sinyal EEG, komponen yang mengandung ERD merupakan fitur yang harus ditemukan karena ERD berkaitan langsung dengan aktivitas perintah mental sebagaimana yang telah diuraikan dalam subbab 2.3. Tahap terakhir dalam pemrosesan sinyal otak dalam sistem BCI adalah klasifikasi, yaitu membuat indikator-indikator pengendalian untuk aktuator (Hill *et al.*, 2014; Spüler, 2017).

Pemrosesan sinyal otak setelah tahap ekstraksi fitur adalah klasifikasi yang hasilnya dapat digunakan untuk menggerakkan aktuator. Banyak pilihan metode klasifikasi yang bisa digunakan untuk BCI, seperti: *k-nearest neighbour* (KNN), Naive Bayes, *naural network*, *support vector machine* (SVM), dan lain sebagainya (Machado dan Balbinot, 2014; Izzuddin *et al.*, 2015; Bose *et al.*, 2016; Torse, Desai dan Khanai, 2018). Aktuator BCI juga beragam bentuknya. Contoh aktuator BCI antara lain: kursi roda, tangan buatan (*bionic*), *speller*, dan lain-lain (Rechy-Ramirez dan Hu, 2015; Voznenko, Chepin dan Urvanov, 2018).

2.5 EEG NeuroskyMindwave

Gambar 2.4 diambil dari Neurosky (Neurosky, 2011) yang menguraikan bentuk dan bagian-bagian Neurosky Mindwave model MW001. Neurosky

Mindwave, atau yang biasa disebut dengan Mindwave, adalah EEG dengan elektrode kering yang dirilis pada tahun 2011 oleh Neurosky (Robbins *et al.*, 2014; Salabun, 2014).



Gambar 2.4 Bagian-bagian dari Neurosky Mindwave model MW001

Tabel 2.3 Spesifikasi Neurosky Mindwave MW001

Spesifikasi	Nilai
Massa	90 gram
Dimensi sensor arm atas	225 mm × 155 mm × 92 mm
Dimensi sensor arm bawah	225 mm × 155 mm × 165 mm
Daya	30 mW
Daya maksimum	50 mW
Frekuensi RF	2,420 - 2,471 GHz
Daya RF Maksimum	6 dBm
RF data rate	250 kbit/s
RF range	10 m
Paket data yang hilang via wireless	5%
UART Baudrate	57.600 Baud
Jarak pk-pk EEG maksimum sinyal input	1 mV
Jarak filter hardware	3 Hz - 100 Hz
Resolusi ADC	12 bit
Sampling rate	512 Hz
Kecepatan penghitungan eSense	1 Hz

Tabel 2.3 menguraikan spesifikasi Neurosky Mindwave MW001 yang bersumber dari Neurosky (Neurosky, 2010) dan Fink (Fink, 2012). Letak elektrode *ground* dan referensinya berada pada *ear-clip*, sedangkan elektrode perekam sinyal EEG adalah pada titik FP1 (dahi sebelah kiri). Menurut Wolpaw (Wolpaw dan Wolpaw, 2012) dan Akila (Akila, Sekar dan Suresh, 2015), posisi FP1 merupakan salah satu titik dari 21 titik standar peletakan elektrode EEG pada sistem 10-20 yang ditetapkan oleh *American Electroencephalographic Society* pada tahun 1994. Menurut Browning (Browning, 2007), posisi FP1 merekam sinyal EEG dari bagian *frontal lobe* otak, yang mana bagian tersebut berhubungan dengan kemampuan untuk melakukan tindakan-tindakan yang disengaja. Dengan kata lain, sinyal EEG yang direkam dari titik FP1 didominasi oleh sinyal yang membawa informasi tentang fungsi mobilitas tubuh manusia. Menurut Ashok (Ashok *et al.*, 2016), penempatan elektrode Mindwave pada titik FP1 juga membuat Mindwave dapat mendeteksi kekuatan kedipan mata. Dengan kemampuan tersebut, boleh jadi, pada kasus penyandang disabilitas fungsi mobilitas tertentu, kekuatan kedipan mata yang dapat dideteksi oleh Mindwave dapat dimanfaatkan.

Neurosky Mindwave telah dibandingkan dengan sistem Biopac (produsen EEG elektrode basah berstandar internasional) dan dinyatakan kompatibel dengan sistem Biopac (Neurosky, 2009; Dobosz dan Wittchen, 2015; Ginete *et al.*, 2015). Neurosky Mindwave menggunakan modul ThinkGear-AM untuk pengondisi sekaligus pengolah sinyal EEG yang hasilnya dapat diakses melalui protokol-protokol yang diuraikan dalam Tabel 2.4 (Neurosky, 2010; Aswathy, 2015). Validitas dan kualitas sinyal EEG Neurosky Mindwave dapat diketahui dengan

mengakses protokol TG_DATA_POOR_SIGNAL dengan keadaan-keadaan berikut:

1. Jika EEG dihidupkan namun tidak digunakan, maka nilai *poor signal* harus menjauhi atau lebih dari nol
2. Jika sensor EEG disentuhkan ke organ tubuh lain, maka nilai *poor signal* harus menjauhi atau lebih dari nol
3. Jika EEG digunakan sebagaimana mestinya namun ada interferensi pada sensornya, maka nilai *poor signal* harus menjauhi atau lebih dari nol.

Jika EEG digunakan sebagaimana mestinya tanpa interferensi pada sensornya, maka nilai *poor signal* harus mendekati atau sama dengan nol.

Tabel 2.4 Protokol *output* Neurosky Mindwave

Nama Protokol	Keterangan
TG_DATA_BATTERY	Kapasitas baterai
TG_DATA_POOR_SIGNAL	Indikator kualitas sinyal; $poor = 0$ berarti kualitas sinyal baik; $0 < poor \leq 200$ berarti kualitas sinyal jelek.
TG_DATA_ATTENTION	Bilangan bulat Attention yang dihasilkan eSense, antara 0 sampai 100.
TG_DATA_MEDITATION	Bilangan bulat Meditation yang dihasilkan eSense, antara 0 sampai 100.
TG_DATA_RAW	Sinyal EEG <i>raw</i> .
TG_DATA_DELTA	Sinyal delta (0,5 s.d. 2,75 Hz).
TG_DATA_THETA	Sinyal teta (3,5 s.d. 6,75 Hz).
TG_DATA_ALPHA1	Sinyal alfa rendah (7,5 s.d. 9,25 Hz).
TG_DATA_ALPHA2	Sinyal alfa tinggi (10 s.d. 11,75 Hz).
TG_DATA_BETA1	Sinyal beta rendah (13 s.d. 16,75 Hz).
TG_DATA_BETA2	Sinyal beta tinggi (18 s.d. 29,75 Hz).
TG_DATA_GAMMA1	Sinyal gama rendah (31 s.d. 39,75 Hz).
TG_DATA_GAMMA2	Sinyal gama tengah (41 s.d. 49,75 Hz).
TG_DATA_BLINK_STRENGTH	Bilangan bulat antara 0 s.d. 255 yang mengindikasikan kekuatan kedipan.

Berdasarkan dialog Firdaus (Firdaus, 2017) dengan pengembang Neurosky melalui *e-mail*, Think Gear telah dilengkapi filter *anti-aliasing* sehingga sinyal

yang dihasilkan berada pada rentang frekuensi antara 3 s.d. 100 Hz. Menurut Akila (Akila, Sekar dan Suresh, 2015), sinyal EEG yang dihasilkan oleh Mindwave tidak bersatuan volt sehingga diperlukan persamaan (2.1) untuk mengonversikan satuan sinyal EEG menjadi volt.

$$\text{Nilai raw (Volt)} = \frac{\text{nilai raw} \times \left(\frac{1,8 \text{ Volt}}{4096}\right)}{2000} \quad (2.1)$$

2.6 Indikator Pengendalian Kursi Roda BCI

Menurut Abiyev (Abiyev *et al.*, 2015), jumlah indikator pengendalian utama pada kursi roda BCI ada lima, yaitu: diam, maju, belok kanan, dan belok kiri, dan mundur. Bila indikator yang digunakan ada empat, maka indikator kendalinya adalah: diam, maju, belok kanan, belok kiri, dan mundur, sebagaimana yang digunakan oleh Folane (Folane *et al.*, 2017). Bila indikator yang digunakan adalah tiga, seperti yang digunakan oleh Al-Qaysi (Al-Qaysi *et al.*, 2018), maka indikator yang digunakan antara lain: maju, belok kanan, dan belok kiri.

2.7 Continuous Wavelet Transform

Continuous wavelet transform (CWT) adalah konvolusi antara sinyal dengan fungsi *wavelet* (Aydemir dan Kayikcioglu, 2011). Persamaan CWT dituliskan dalam persamaan (2.2).

$$CWT(\tau, s) = \frac{1}{\sqrt{|s|}} \int x(t) \Psi^* \left(\frac{t - \tau}{s} \right) dt \quad (2.2)$$

Fungsi *wavelet* dari persamaan (2.2) dituliskan dalam persamaan (2.3).

$$\Psi_{\tau, s}(t) = \frac{1}{\sqrt{|s|}} \Psi \left(\frac{t - \tau}{s} \right) \quad (2.3)$$

yang mana τ adalah pergeseran waktu pada fungsi *wavelet* Ψ dan s adalah skala dari Ψ . Tanda “*” pada Ψ^* melambangkan konjugasi kompleks (Karimoi *et al.*, 2014; Kumari dan Somani, 2015). Hasil CWT adalah koefisien-koefisien spektrum dan perubahannya terhadap waktu. Menurut Darvishi (Darvishi dan Al-ani, 2007), Abibullaev (Abibullaev dan An, 2012) dan Kato (Kato *et al.*, 2018), nilai dari skala spektrum CWT tidak sama dengan skala spektrum dalam satuan Hz sehingga dibutuhkan persamaan (2.4) untuk menentukan letak frekuensi suatu sinyal dalam satuan Hz pada skala spektrum CWT.

$$F_s = \frac{F_c}{s \cdot T_s} \quad (2.4)$$

F_s adalah pseudo-frekuensi pada skala s , T_s adalah periode *sampling*, dan F_c adalah frekuensi tengah dari fungsi *wavelet*.

Hampir semua peneliti dan pengembang BCI tidak menggunakan sinyal dari semua skala CWT. Menurut Bassani (Bassani, 2009), hasil dekomposisi CWT pada sinyal EEG dengan rentang frekuensi 12 – 30 Hz menghasilkan akurasi klasifikasi yang lebih tinggi dibandingkan rentang frekuensi lainnya. Hsu (Hsu, 2015) dan Castillo-Garcia (Castillo-Garcia *et al.*, 2015) menggunakan rentang frekuensi 8 – 30 Hz dan akurasi hasil klasifikasinya di atas 80%. Darvishi (Darvishi dan Al-ani, 2007) dan Kumari (Kumari dan Somani, 2015) menggunakan rentang frekuensi 8 – 13 Hz yang akurasi hasil klasifikasinya adalah 81,43% dan 94,99%. Karimoi (Karimoi *et al.*, 2014) menggunakan rentang frekuensi 2 – 18 Hz dan akurasi hasil klasifikasinya di atas 95%.

Ada beberapa pilihan fungsi *wavelet*, yaitu: *mexican hat*, morlet, symlet, daubachies, dan shannon. Menurut Bostanov (Bostanov, 2004), pemilihan fungsi *wavelet* tergantung dari sifat fitur yang ingin ditinjau. Penggunaan fungsi *mexican*

hat dianjurkan bila ingin meninjau karakteristik perubahan sinyal terhadap waktu, sedangkan fungsi morlet dianjurkan bila ingin meninjau osilasi sinyal. Darvishi (Darvishi dan Al-ani, 2007), Bassani (Bassani, 2009), Aydemir (Aydemir dan Kayikcioglu, 2011), dan Kumari (Kumari dan Somani, 2015) menggunakan fungsi morlet. Hsu (Hsu dan Sun, 2009) dan Karimoi (Karimoi *et al.*, 2014) menggunakan fungsi daubachies. Berdasarkan kesimpulan Aydemir dan Kayikcioglu (Aydemir dan Kayikcioglu, 2016), fungsi shannon dan daubachies cenderung menghasilkan akurasi klasifikasi yang lebih baik pada sistem BCI. Persamaan (2.5) menunjukkan fungsi *wavelet* shannon kontinu (Mallat, 2009).

$$\psi^{(csha)}(t) = \text{sinc}(t) \cdot \exp(-j2\pi t) \quad (2.5)$$

Di mana $\psi^{(csha)}$ adalah *wavelet* shannon, j adalah bilangan kompleks, dan $\text{sinc}(t)$ adalah:

$$\text{sinc}(t) := \frac{\sin \pi t}{\pi t} \quad (2.6)$$

Fitur yang umumnya diambil dari hasil CWT adalah nilai rata-rata dan standar deviasinya. Darvishi (Darvishi dan Al-ani, 2007), Bassani (Bassani, 2009), Castillo-Garcia (Castillo-Garcia *et al.*, 2015), dan Hsu (Hsu, 2015) menggunakan nilai rata-rata sebagai fitur. Aydemir (Aydemir dan Kayikcioglu, 2011) dan Karimoi (Karimoi *et al.*, 2014) menggunakan nilai rata-rata dan standar deviasi sebagai fitur. Nilai rata-rata dan standar deviasi dihitung menggunakan *time window* dengan durasi tertentu. Aydemir (Aydemir dan Kayikcioglu, 2011) menggunakan *time window* berdurasi 4 detik untuk mengklasifikasi dua perintah mental dengan akurasi 94%. Darvishi (Darvishi dan Al-ani, 2007) dan Hsu (Hsu, 2015) menggunakan *time window* berdurasi 3 detik untuk mengklasifikasi dua perintah mental dengan akurasi masing-masing 83% dan 82,14%.

2.8 Metode Friedman

Metode Friedman merupakan metode analisis statistika nonparametrik berbasis peringkat (Pereira, Afonso dan Medeiros, 2015; Ali dan Bhaskar, 2016).

Metode Friedman adalah alternatif dari metode ANOVA untuk data multisampel yang bersifat dependen (Zimmerman dan Zumbo, 1993; Granato, de Araújo Calado dan Jarvis, 2014; Eisinga *et al.*, 2017). Berikut ini adalah tahap-tahap pengukuran signifikansi perbedaan (keunikan) data multisampel dependen yang diadaptasi dari Uyanto (Uyanto, 2009) dan Santoso (Santoso, 2014):

1. Membuat hipotesis:

H_0 : Semua sampel sama (tidak ada keunikan antar sampel)

H_1 : Secara umum, paling sedikit terdapat sepasang sampel yang berbeda (unik) signifikan.

2. Data yang akan diproses berformat $[M \times N]$, dengan M adalah banyak data dan N adalah sampel data.
3. Setiap baris data diberi peringkat.
4. Semua peringkat dari semua baris dijumlahkan dan dihitung rata-ratanya.
5. Nilai Friedman dihitung dengan persamaan (2.7):

$$\chi^2 = \left[\frac{12}{nk(k+1)} \left(\sum R_j^2 \right) \right] - 3n[k+1] \quad (2.7)$$

di mana n adalah banyaknya data tiap sampel, k adalah jumlah sampel, dan R_j adalah jumlah peringkat dari setiap sampel.

6. Nilai Friedman yang diperoleh dikoreksi dengan rumus (2.8):

$$C = 1 - \frac{\sum_{i=1}^n T_i}{nk(k^2 - 1)} \quad (2.8)$$

dengan

$$T_i = \sum t^3 - \sum t \quad (2.9)$$

di mana t adalah banyaknya angka yang sama dalam satu baris data. Nilai χ^2 dari persamaan (2.7) kemudian dibagi dengan C dari persamaan (2.8).

7. Kesimpulan diambil berdasarkan nilai χ yang dibandingkan dengan χ tabel. Bila χ nilainya kurang dari χ tabel, maka H_0 ditolak.
8. Keunikan antar sampel dianalisis dengan pedoman (2.10):

$$[R_j - R'_j] \geq z \sqrt{\frac{nk(k+1)}{6}} \quad (2.10)$$

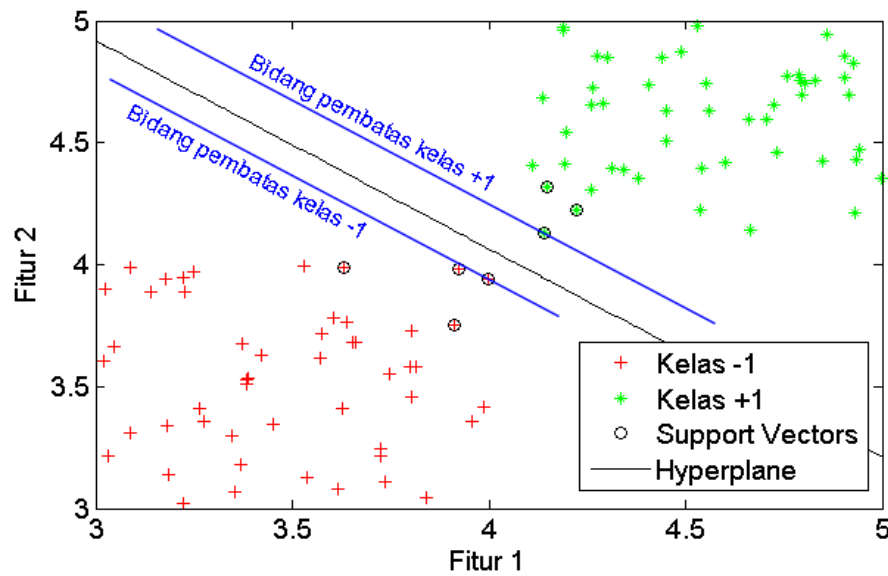
dengan $[R_j - R'_j]$ adalah selisih absolut jumlah peringkat dari sepasang sampel yang dibandingkan, z adalah nilai dari tabel z yang dicari menggunakan kriteria $\alpha/k(k-1)$. Nilai α adalah tingkat signifikansi dari taraf kepercayaan. Jika sepasang sampel memenuhi pedoman (2.10), maka sepasang sampel yang ditinjau adalah berbeda signifikan (saling unik).

Umumnya metode Friedman digunakan tidak untuk menganalisis keunikan fitur sinyal, namun lebih sering untuk menganalisis perbedaan data multisampel (Bose *et al.*, 2016; Pal dan Bandyopadhyay, 2016; Rakshit, Khasnobish dan Tibarewala, 2016; Gupta dan Kumar, 2017; Ramos, 2017).

2.9 Support Vector Machine

Support Vector Machine (SVM) merupakan metode klasifikasi jenis terpandu, yaitu membutuhkan target pembelajaran (Jamal *et al.*, 2014; Raju, Ra dan Sankar, 2015; Masso, 2016). SVM dipelopori oleh Vladimir Vapnik, Bernhard Boser, dan Isabelle Guyon pada tahun 1992, namun dasar SVM sudah ada sejak tahun 1960-an (Widodo, Handayanto dan Herlawati, 2013; Mirvaziri

dan Mobarakeh, 2017). *Hyperplane* SVM adalah kurva batas sekaligus pemisah dua kelas data (Permana, 2016). Semakin besar margin *hyperplane*, hasil klasifikasi data semakin akurat (Qiu, 2018). Gambar 2.5 diadaptasi dari Corazzol (Corazzol, 2012) dan Krell (Krell, 2015) yang mengilustrasikan *hyperplane* dari data dengan dua fitur yang terpisah secara linier oleh dua kelas, yaitu -1 dan +1.



Gambar 2.5 Ilustrasi *hyperplane* dari data yang terpisah secara linier

Titik-titik data yang ditandai sebagai *support vector* di dalam Gambar 2.5 adalah data yang berada pada bidang pembatas. Jarak antara dua bidang pembatas disebut sebagai margin. Sembiring (Sembiring, 2007) menguraikan *hyperplane* untuk kelas -1 dan +1 secara matematis dalam pertidaksamaan (2.11) dan (2.12).

$$x_i \cdot w + b \geq -1, \quad \text{untuk } y_i = -1 \quad (2.11)$$

$$x_i \cdot w + b \geq +1, \quad \text{untuk } y_i = +1 \quad (2.12)$$

Di mana w adalah vektor normal terhadap *hyperplane*, x adalah vektor *input*, dan b adalah posisi *hyperplane* relatif terhadap pusat koordinat. Pertidaksamaan (2.11) dan (2.12) bisa digabungkan sehingga menjadi pertidaksamaan (2.13).

$$y_i(x_i \cdot w + b) - 1 \geq 0 \quad (2.13)$$

Berdasarkan pertidaksamaan (2.11) dan (2.12), nilai margin dapat dihitung dan menghasilkan persamaan (2.14).

$$\text{Margin} = \frac{1 - b - (-1 - b)}{w} = \frac{2}{|w|} \quad (2.14)$$

Konsep SVM adalah menemukan *hyperplane* dengan margin maksimum. Jika ditinjau dari persamaan (2.14), maka margin dapat dimaksimalkan dengan meminimalkan $|w|^2$ dan permasalahan optimasi tersebut dapat diselesaikan dengan mengubah persamaan (2.13) menggunakan pengali lagrange sehingga menjadi persamaan (2.15) (Siuly, 2012).

$$L_p(w, b, a) = \frac{1}{2}|w|^2 - \sum_{i=1}^n a_i y_i (x_i \cdot w + b) + \sum_{i=1}^n a_i \quad (2.15)$$

L_p adalah lagrangian problem primer dan a adalah koefisien lagrange yang syaratnya $a_i \geq 0$. L_p dapat diminimalkan terhadap w dan b dengan menurunkan persamaan (2.15) dan hasil turunannya harus sama dengan nol sebagaimana yang diungkapkan dalam persamaan (2.16) dan (2.17) (Arvaneh *et al.*, 2011).

$$\frac{\partial}{\partial b} L_p(w, b, a) = 0 \quad (2.16)$$

$$\frac{\partial}{\partial w} L_p(w, b, a) = 0 \quad (2.17)$$

Persamaan (2.16) dan (2.17) menghasilkan persamaan (2.18) dan (2.19).

$$\sum_{i=1}^n a_i y_i = 0 \quad (2.18)$$

$$w = \sum_{i=1}^n a_i y_i x_i \quad (2.19)$$

Vektor w bisa tak berhingga, sedangkan nilai a selalu terhingga. Permasalahan tersebut dapat diselesaikan dengan mengubah lagrangian problem primer menjadi lagrangian *dual* problem L_D , yaitu mensubstitusikan persamaan (2.19) ke dalam persamaan (2.15) sehingga menjadi persamaan (2.20) (Wang dan Guo, 2013).

$$L_D(a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i=1, j=1}^n a_i a_j y_i y_j x_i x_j \quad (2.20)$$

Nilai a_i dalam persamaan (2.20) dari data pelatihan bisa digunakan untuk menemukan w . Data dengan nilai $a_i > 0$ adalah *support vector*, sedangkan data dengan nilai $a_i = 0$ adalah sisanya. Dengan demikian, *support vector* menjadi penentu hasil klasifikasi (Tian, 2012). Fungsi keputusan (2.21) dapat menentukan kelas data x .

$$L_D(a) = \sum_{i=1}^n a_i y_i x_i x_d + b \quad (2.21)$$

Variabel x_i adalah *support vector*, n adalah jumlah *support vector*, dan x_d adalah data yang akan diklasifikasikan.

Terkadang data tidak terpisah kelasnya secara linier. SVM dapat mengklasifikasikan data nonlinier dengan cara mentransformasikan data ke dalam ruang fitur sehingga dapat dipisahkan secara linier pada ruang fitur (Zhou, Liu dan Ye, 2009; Yin dan Yin, 2016). Biasanya dimensi ruang fitur lebih tinggi dari dimensi vektor input sehingga komputasinya menjadi lebih kompleks sehingga trik *kernel* merupakan solusi untuk menyederhanakan kompleksitas tersebut, yaitu dengan memanfaatkan adanya *dot product* di dalam persamaan (2.15) (Yu *et al.*, 2012; Jamil *et al.*, 2018). Fungsi kernel dimisalkan dengan persamaan (2.22).

$$K(x_i, x_d) = \phi(x_i) \cdot \phi(x_d) \quad (2.22)$$

Fungsi kernel (2.22) membuat fungsi transformasi $\phi(x)$ tidak perlu diketahui secara detail sehingga fungsi pelatihan dapat dituliskan dengan persamaan (2.23):

$$f(x_d) = \sum_{i=1}^n a_i y_i K(x_i, x_d) + b \quad (2.23)$$

Fungsi kernel harus memenuhi teorema Mercer, yaitu matriks kernel harus bersifat positif semidefinit (Ma dan Liu, 2018; Padierna *et al.*, 2018). Ada empat fungsi kernel umum dan memenuhi teorema Mercer, yaitu fungsi kernel linier, polinomial, *gaussian radial basis* (RBF), dan sigmoid (Quitadamo *et al.*, 2017; Chen *et al.*, 2018). Fungsi kernel linier dituliskan dalam persamaan (2.24):

$$K(x_i, x) = x_i^T x \quad (2.24)$$

Fungsi kernel polinomial dituliskan dalam persamaan (2.25):

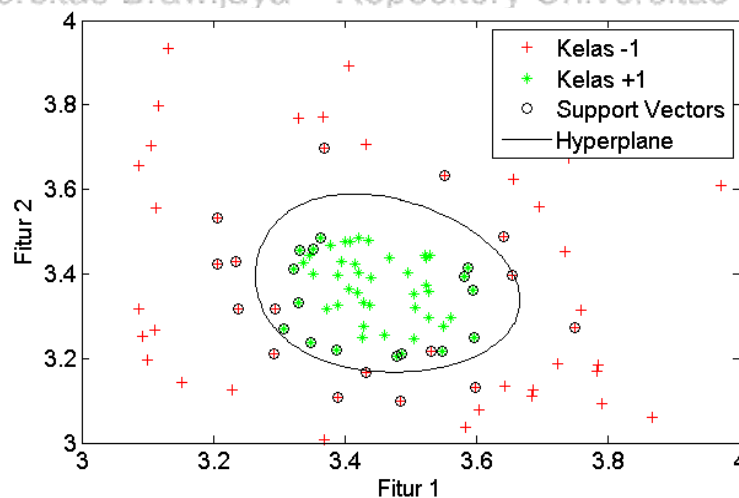
$$K(x_i, x) = (\gamma \cdot x_i^T x + r)^p, \quad \gamma > 0 \quad (2.25)$$

Fungsi kernel *gaussian* RBF dituliskan dalam persamaan (2.26):

$$K(x_i, x) = \exp(-\gamma |x_i - x|^2), \quad \gamma > 0 \quad (2.26)$$

Fungsi kernel *sigmoid* dituliskan dalam persamaan (2.27):

$$K(x_i, x) = \tanh(\gamma x_i^T x + r) \quad (2.27)$$



Gambar 2.6 Ilustrasi *hyperplane* dari data yang terpisah secara nonlinier

Gambar 2.6 diadaptasi dari Widodo (Widodo, Handayanto dan Herlawati, 2013) dan Soman (Soman dan Jayadeva, 2015) yang mengilustrasikan data nonlinier dengan *hyperplane* dari fungsi kernel RBF. Hsu (Hsu, Chang dan Lin, 2008) merekomendasikan penggunaan fungsi kernel RBF karena kernel RBF bisa menyamai fungsi kernel linier dan juga bisa menyerupai fungsi kernel sigmoid tergantung parameter RBF yang digunakan. Hede (Hede, 2010) dan Ghosh (Ghosh, 2012) yang meneliti BCI mengungkapkan tiga kelebihan SVM RBF, yaitu: SVM RBF lebih akurat dibandingkan kernel SVM lainnya, dimensi SVM RBF tidak terbatas, dan SVM RBF sangat efisien.

Nilai γ dalam persamaan (2.26) adalah sama dengan $1/(2\sigma_{RBF}^2)$ (Siuly, 2012; Saranya, Samundeeswari dan Manavalan, 2016), sehingga:

$$K(x_i, x) = \exp\left(-\frac{|x_i - x|^2}{2\sigma_{RBF}^2}\right) \quad (2.28)$$

Persamaan (2.28) diadaptasi dari Tian (Tian, 2012) dan Al-Qammaz (Al-Qammaz, Ahmad dan Yusof, 2016) dengan menambahkan subskrip RBF pada σ_{RBF} untuk membedakannya dengan fitur standar deviasi yang sudah terlebih dahulu disimbolkan dengan σ . Menurut Liu (Liu, Shen dan Wang, 2014), Claesen (Claesen *et al.*, 2014), dan Harafani (Harafani dan Wahono, 2015), γ atau σ_{RBF} sangat memengaruhi akurasi hasil klasifikasi SVM. Menurut Renukadevi (Renukadevi dan Thangaraj, 2013), γ mendefinisikan jarak antara dua kelas data, yang mana semakin tinggi nilai γ maka jarak antara dua kelas data semakin dekat.

Menurut Qiu (Qiu, 2018), nilai σ_{RBF} adalah unik untuk setiap set data, sehingga nilai σ_{RBF} untuk setiap set data perlu diinvestigasi agar hasil klasifikasi SVM menjadi lebih akurat. Aydemir (Aydemir dan Kayikcioglu, 2011) menggunakan

σ_{RBF} dengan rentang 0.1 – 2.5 dan intervalnya 0,1. Kemudian Aydemir (Aydemir dan Kayıkcıoğlu, 2016) meneliti SVM kembali dan menggunakan σ_{RBF} yang sama seperti sebelumnya, namun dengan interval yang berbeda, yaitu 0,2.

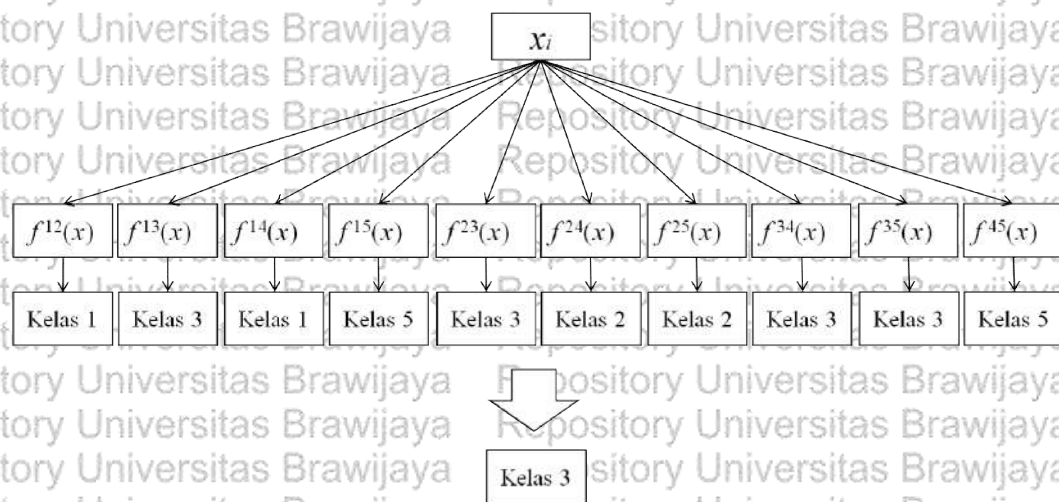
Algoritma dasar SVM adalah *quadratic programming* (QP) yang mana dimensi matriksnya besar dan terdapat banyak jumlah perulangan di dalam komputasi numeriknya (Al-Qammar, Ahmad dan Yusof, 2016; Mirvaziri dan Mobarakeh, 2017). Platt (Platt, 1998) mengembangkan algoritma QP menjadi algoritma *sequential minimal optimization* (SMO) dan menurutnya SMO bisa 1000 kali lebih cepat dibandingkan QP. Bagi Bottou (Bottou dan Lin, 2007), SMO mudah diprogram, bisa bekerja dengan cepat, dan teliti.

SVM pada dasarnya adalah untuk mengklasifikasikan data dengan dua kelas (kelas biner) (Aoki *et al.*, 2013; Guan, Zhao dan Wang, 2018). SVM bisa mengklasifikasi data lebih dari dua kelas dengan mengembangkan SVM biner (Burg dan Groenen, 2016; Xu *et al.*, 2017). Menurut Heyden (Heyden, 2016), ada dua metode standar untuk SVM multikelas, yaitu metode *one against one* (OAO) dan *one against all* (OAA). Berlin (Berlin, 2017) dan Quitadamo (Quitadamo *et al.*, 2017) menambahkan, selain metode OAO dan OAA, ada juga metode *one against rest* (OAR). Masih ada metode lain untuk SVM multikelas, yaitu metode *directed acyclic graph* (DAG) (Hsu dan Lin, 2002). Diantara empat metode tersebut, menurut Azis (Azis, Suhartono dan Himawan, 2017), metode OAO adalah yang paling akurat dengan kompleksitas komputasi yang paling rendah dan paling simetris dibandingkan metode yang lain. Jumlah model klasifikasi biner antarkelas metode OAO adalah sebanyak $\frac{k(k-1)}{2}$, dengan k adalah jumlah kelas (Liu, Yang dan Tang, 2010; Abbey, He dan Wang, 2017).

Tabel 2.5 Contoh 10 model SVM dengan metode OAO untuk lima kelas

$y_i = -1$	$y_i = +1$	Hipotesis
Kelas 1	Kelas 2	$f^{12}(x) = (w^{12})x + b^{12}$
Kelas 1	Kelas 3	$f^{13}(x) = (w^{13})x + b^{13}$
Kelas 1	Kelas 4	$f^{14}(x) = (w^{14})x + b^{14}$
Kelas 1	Kelas 5	$f^{15}(x) = (w^{15})x + b^{15}$
Kelas 2	Kelas 3	$f^{23}(x) = (w^{23})x + b^{23}$
Kelas 2	Kelas 4	$f^{24}(x) = (w^{24})x + b^{24}$
Kelas 2	Kelas 5	$f^{25}(x) = (w^{25})x + b^{25}$
Kelas 3	Kelas 4	$f^{34}(x) = (w^{34})x + b^{34}$
Kelas 3	Kelas 5	$f^{35}(x) = (w^{35})x + b^{35}$
Kelas 4	Kelas 5	$f^{45}(x) = (w^{45})x + b^{45}$

Tabel 2.5 diadaptasi dari Hsu (Hsu dan Lin, 2002; Widodo, Handayanto dan Herlawati, 2013).




Gambar 2.7 Contoh klasifikasi dengan metode OAO

Gambar 2.7 diadaptasi dari Hassan (Hassan dan Damper, 2010) dan Huang (Huang dan Fisher, 2014) yang mengilustrasikan data x_i yang dimasukkan ke dalam fungsi model klasifikasi $f^{ij}(x)$. Masing-masing fungsi model klasifikasi menghasilkan kelas yang merupakan jawaban dari hipotesisnya. Kelas yang paling sering muncul dari semua hasil klasifikasi tersebut merupakan kelas untuk data x_i (Milgram *et al.*, 2006; Nurhanna dan Othman, 2017).

BAB III KERANGKA KONSEP PENELITIAN

3.1 Konsep Penelitian

Bagan kerangka konsep penelitian ini disajikan dalam Gambar 3.1.



Gambar 3.1 Kerangka konsep penelitian

Indikator pengendalian merupakan dasar dari pembuatan kursi roda berbasis *brain computer interface* (BCI). Penelitian ini berusaha membuat lima indikator pengendalian, yaitu: netral, maju, belok kanan, belok kiri, dan mundur.

Pembuatan lima indikator pengendalian tersebut dimulai dengan perekaman sinyal EEG. Sinyal EEG yang telah direkam kemudian diekstraksi fiturnya untuk kemudian diklasifikasi menggunakan algoritma tertentu sehingga dihasilkan lima indikator yang dapat digunakan untuk pengendalian kursi roda BCI. Kursi roda BCI membutuhkan fitur sinyal EEG yang unik terhadap indikator pengendaliannya supaya indikator pengendaliannya akurat. Penelitian ini merekam sinyal EEG menggunakan Neurosky Mindwave. Metode *continuous*

wavelet transform (CWT) digunakan untuk mengekstraksi fitur EEG. Fitur-fitur yang dihasilkan kemudian dianalisis keunikannya menggunakan metode Friedman. Untuk pembuatan lima indikator pengendalian, fitur-fitur yang paling unik diklasifikasi menggunakan *support vector machine* (SVM). Hasil klasifikasi adalah lima indikator yang dapat digunakan untuk pengendalian kursi roda BCI.

3.2 Variabel Penelitian

Variabel dalam penelitian ini dikelompokkan menjadi variabel bebas dan variabel terikat. Variabel bebas dalam penelitian ini adalah fitur hasil ekstraksi sinyal EEG. Variabel terikat dalam penelitian ini adalah lima indikator pengendalian kursi roda BCI, antara lain: netral, maju, belok kanan, belok kiri, dan mundur.

BAB IV METODE PENELITIAN

4.1 Tempat dan Waktu Penelitian

Penelitian dilaksanakan di Laboratorium Elektronika Universitas Brawijaya Malang mulai tanggal 30 Desember 2017 sampai 30 Maret 2018.


4.2 Alat dan Bahan

Alat-alat yang digunakan antara lain:

1. Seperangkat Neurosky Mindwave Model MW001
2. PC/Laptop
3. *Software* MATLAB

4.3 Prosedur Penelitian

Prosedur penelitian diperlihatkan pada Gambar 4.1.



Gambar 4.1 Diagram alur prosedur penelitian

Gambar 4.1 menunjukkan diagram alur prosedur penelitian yang diadaptasi dari Rebsamen (Rebsamen, 2008), Huang (Huang, 2012), dan Hassan (Hassan, 2015).

4.3.1 Studi Literatur

Studi literatur merupakan bagian yang menghimpun informasi dan referensi mengenai tema penelitian ini. Literatur mengenai sinyal otak, teknologi BCI, dan EEG dihimpun dalam bagian ini. Literatur mengenai *continuous wavelet transform* (CWT) untuk mengekstraksi fitur sinyal EEG, metode Friedman untuk menganalisis keunikan fitur, dan metode klasifikasi *support vector machine* (SVM) juga dihimpun sebagai landasan dalam penelitian.

4.3.2 Penyusunan Sistem Instrumentasi



Gambar 4.2 diadaptasi dari (Maly, 2015) dan De Souza (De Souza dan Lamounier, 2017) yang menunjukkan rangkaian sistem instrumentasi penelitian ini. Neurosky Mindwave MW001 dan PC/Laptop adalah perangkat utama penelitian ini. Data sinyal EEG yang direkam Neurosky Mindwave MW001 dapat ditransmisikan ke dalam komputer dengan perantara jaringan *bluetooth*.

4.3.3 Pengujian Sistem Instrumentasi

Sistem instrumentasi perlu diuji agar validitas sinyal yang dihasilkan MW001 dapat diketahui. Pengujian sistem instrumentasi didasarkan dan

dimodifikasi dari penelitian Robbins (Robbins *et al.*, 2014) serta berdasarkan spesifikasi MW001 yang ditulis oleh Neurosky (Neurosky, 2009). Proses pengujian sistem instrumentasi dibagi menjadi tiga tahap, yaitu: pengujian nilai *poor signal*, pengujian semua keluaran MW001, dan pengujian spektrum frekuensi sinyal EEG yang direkam dengan MW001. Pengujian nilai *poor signal* adalah untuk melihat perbedaan antara keluaran yang dihasilkan MW001 saat dipakai dengan benar dengan keluaran yang dihasilkan saat tidak dipakai dengan benar. *Poor signal* merupakan salah satu keluaran MW001 untuk indikator kualitas sinyal. Hasil pengujian ini juga dapat memperlihatkan validitas sinyal yang direkam. Diterapkan empat perlakuan dalam pengujian ini, yaitu:

1. MW001 dihidupkan namun tidak digunakan.
2. MW001 dihidupkan dan disentuh ke organ tubuh lain.
3. MW001 dihidupkan dan digunakan tanpa menghubungkan klip *ground* dengan daun telinga.
4. MW001 dihidupkan dan digunakan sebagaimana mestinya namun diberi interferensi pada sensornya.
5. MW001 dihidupkan dan digunakan sebagaimana mestinya.


Nilai *poor signal* harus sesuai dengan spesifikasi MW001. Jika MW001 tidak digunakan dengan benar, maka nilai *poor signal* lebih dari nol. Pada poin pengujian yang terakhir, MW001 harus menghasilkan sinyal keluaran yang sesuai dengan spesifikasinya. Berdasarkan pernyataan Neurosky bahwa MW001 telah dilengkapi filter *anti-aliasing* sebagaimana yang telah diuraikan dalam subbab 2.5, maka spektrum frekuensi sinyal EEG yang direkam dengan MW001 harus

berada pada rentang 3 s. d. 100 Hz. Untuk membuktikannya, sinyal EEG ditransformasi menjadi domain frekuensi dengan satuan *gain* desibel (dB) dan spektrumnya ditampilkan dalam bentuk grafik beserta kurva $y = -3\text{dB}$. Rumus untuk mengubah gain sinyal menjadi satuan dB disajikan dalam persamaan (4.1) (Ireland, 2010; Lawman, 2011).

$$\text{Gain}_{\text{dB}} = 20 \times 10 \log \text{Gain} \quad (4.1)$$

Jika gain sinyal dalam dB bernilai kurang dari -3 dB, maka sinyal tersebut telah dilemahkan oleh filter (White, 2000; Baker, 2015).

4.3.4 Pengambilan Data




Gambar 4.3 Diagram alir pengambilan data pada satu subjek

Gambar 4.3 merupakan diagram alir pengambilan data yang diadaptasi dari Girase (Girase dan Deshmukh, 2015) dan Folane (Folane *et al.*, 2017).

Apabila sistem instrumentasi yang digunakan sudah dapat dipastikan validitasnya, maka pengambilan data menggunakan sistem instrumentasi tersebut bisa dilakukan. Pengambilan data diterapkan pada tiga subjek yang sehat jasmani dan rohani. Sebelum pengambilan data, mula-mula sistem instrumentasi untuk perekaman sinyal EEG disiapkan. Persiapannya meliputi: menghidupkan komputer, menghidupkan MW001, menghubungkan MW001 dengan komputer melalui jaringan Bluetooth, memasang MW001 pada subjek, serta pengujian sistem instrumentasi sebagaimana yang telah diuraikan sebelumnya.

4.3.5 Pemrosesan Data

Setelah dipastikan alat dapat merekam sinyal EEG dan bekerja dengan baik, tahapan selanjutnya adalah pemrosesan data hingga dihasilkan lima indikator pengendalian kursi roda.



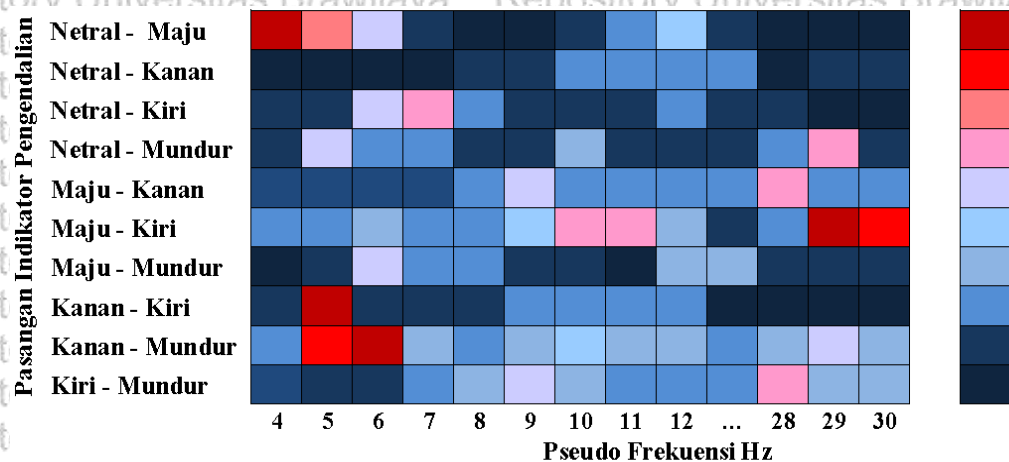
Gambar 4.4 Diagram alir pemrosesan data

Gambar 4.4 diadaptasi dari Rechy-Ramirez (Rechy-Ramirez dan Hu, 2015), Rahul (Rahul, Sharma dan Paul, 2017), Al-Qaysi (Al-Qaysi *et al.*, 2018), Edla (Edla *et al.*, 2018), dan Pattnaik (Pattnaik dan Sarraf, 2018) yang menggambarkan diagram alir pemrosesan data sinyal EEG. Satu per satu antara subjek dengan perekam menentukan indikator pengendalian kursi roda BCI yang hendak dihasilkan. Subjek melakukan perintah mental sesuai indikator pengendalian kursi roda BCI yang telah ditentukan. Sinyal EEG dari subjek ditangkap oleh elektrode MW001. Sinyal EEG selanjutnya diterima dan dikonversi dari sinyal analog menjadi sinyal digital oleh modul TGAM di dalam MW001. Setelah itu, data berupa sinyal digital tersebut dikirimkan oleh modul TGAM ke komputer melalui jaringan Bluetooth. data yang didapatkan diterima oleh komputer dan diteruskan ke *software* MATLAB. *Software* MATLAB kemudian membaca dan menerjemahkan sinyal yang semula berbentuk data biner 16 bit menjadi data berbentuk desimal. data berupa sinyal yang direkam oleh Neurosky diakses menggunakan bahasa pemrograman MATLAB. Perekaman sinyal EEG pada satu subjek dilakukan sejumlah 5 indikator pengendalian \times 105 detik \times 12 perulangan. Dengan demikian, total waktu perekaman untuk satu subjek sekitar 1 jam 45 menit. Semua data disimpan ke dalam *harddisk* komputer. Proses pengambilan data diulangi sampai data dari lima indikator pengendalian kursi roda berhasil dikumpulkan. Jika proses perekaman sudah selesai untuk lima indikator pengendalian, maka proses pengambilan data untuk satu subjek telah selesai.

Data-data yang didapatkan adalah sinyal EEG dan *poor level*. Berdasarkan yang diuraikan dalam latar belakang penelitian mengenai teknik ekstraksi fitur dan perkembangan teknologi BCI yang diuraikan dalam subbab 2.1, maka

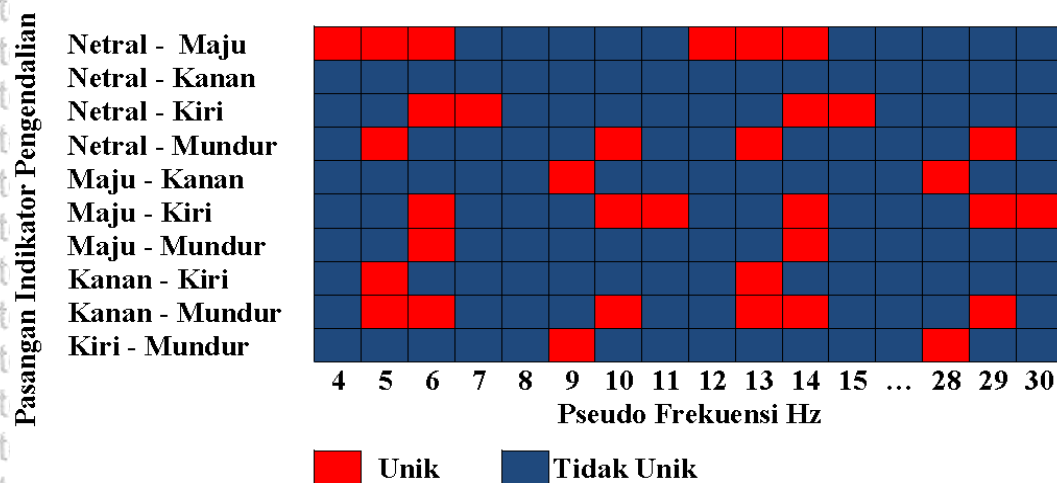
penelitian ini menerapkan CWT untuk mendekomposisi sinyal EEG. Subbab 2.7 yang membahas tentang CWT mengantarkan penelitian ini untuk memilih parameter-parameter dalam proses dekomposisi sinyal EEG. *Pertama*, sebelum didekomposisi, sinyal EEG terlebih dahulu dicuplik dengan *time window* berdurasi 4 detik dan overlap 1 detik. *Kedua*, penelitian ini memilih fungsi *wavelet* shannon dan mengambil sinyal hasil dekomposisi pada rentang frekuensi 4 – 30 Hz dengan memanfaatkan persamaan (2.4). *Ketiga*, nilai rata-rata absolut (μ) dan standar deviasi (σ) digunakan sebagai fitur dari hasil dekomposisi sinyal EEG oleh CWT.

Uraian di dalam latar belakang mengenai teknik analisis keunikan fitur dan uraian dalam subbab 2.8 mengantarkan penelitian ini dalam memilih metode Friedman untuk menganalisis keunikan fitur sinyal EEG. Umumnya, hasil analisis Friedman ditampilkan dalam bentuk tabel dengan keterangan nilai signifikansi yang didapatkan. Namun, karena penelitian ini melibatkan data dengan jumlah yang besar, maka tampilan hasil analisis Friedman seperti uraian Uyanto (Uyanto, 2009) dan Santoso (Santoso, 2014) dimodifikasi dalam bentuk grafik.



Gambar 4.5 Contoh grafik tingkat keunikan fitur

Gambar 4.5 merepresentasikan nilai selisih absolut jumlah peringkat dari sepasang indikator pengendalian kursi roda BCI yang dibandingkan ($[R_j - R_j']$) dalam sel warna. Nilai $[R_j - R_j']$ dijadikan dasar pengukuran tingkat keunikan fitur karena persamaan (2.8) menunjukkan bahwa semakin besar nilai $[R_j - R_j']$, maka keunikannya semakin signifikan.



Gambar 4.6 Contoh grafik signifikansi keunikan fitur

Gambar 4.6 menyajikan hasil uji hipotesis metode Friedman dalam bentuk grafik. Saat fitur pada sepasang indikator pengendalian kursi roda dinyatakan unik signifikan oleh metode Friedman, maka sel pada grafik di dalam Gambar 4.6 direpresentasikan dengan warna merah, jika fitur dinyatakan tidak unik maka sel pada grafik direpresentasikan berwarna biru tua.

Fitur yang paling unik kemudian digunakan untuk pembuatan indikator pengendalian kursi roda BCI. Penelitian ini memilih SVM untuk mengklasifikasi fitur. Proses ekstraksi fitur menghasilkan dua jenis fitur yang berbeda, yaitu fitur $|\mu|$ dan σ . Hal ini membuat proses klasifikasi terbagi tiga, yaitu: pelatihan, investigasi, dan evaluasi. Ketiga tahap tersebut diadaptasi dari Corazzol

(Corazzol, 2012) dan Widodo (Widodo, Handayanto dan Herlawati, 2013). Tahap pelatihan adalah membuat model SVM sebagaimana yang diuraikan dalam subbab 2.9 dan dicontohkan dalam Tabel 2.6. Tahap investigasi adalah menentukan parameter-parameter model SVM dan pasangan fitur yang dapat menghasilkan indikator pengendalian yang paling akurat. Tahap evaluasi adalah menghitung seberapa akurat indikator pengendalian kursi roda BCI yang dihasilkan.

Konsekuensi dari ketiga tahap tersebut adalah pembagian data menjadi tiga, yaitu: 50% untuk pelatihan, 16,7% untuk investigasi, dan 33,3% untuk evaluasi. Tahap pelatihan adalah pembuatan model klasifikasi SVM RBF. Tahap investigasi adalah pengujian sementara pada model klasifikasi yang telah dibuat dengan mengubah-ubah model klasifikasi SVM pada nilai parameter kernel RBF (σ_{RBF}) dan pasangan fiturnya sehingga didapatkan model klasifikasi yang paling akurat.

Investigasi nilai σ_{RBF} diterapkan berdasarkan teori kernel RBF (σ_{RBF}) di dalam subbab 2.9 yang menyatakan bahwa σ_{RBF} memengaruhi hasil SVM (Claesen *et al.*, 2014; Liu, Shen dan Wang, 2014; Harafani dan Wahono, 2015). Penelitian ini menerapkan SVM RBF dengan σ_{RBF} bernilai antara 0,5 – 50 dan intervalnya 0,1.

Rentang nilai σ_{RBF} tersebut diadaptasi dari penelitian Aydemir (Aydemir dan Kayikcioglu, 2011; Aydemir dan Kayikcioglu, 2016) dengan memperlebar rentang nilainya. Sedangkan investigasi model SVM berdasarkan pasangan fitur diterapkan karena ekstraksi CWT pada sinyal EEG menghasilkan fitur dengan jumlah yang sangat banyak, sehingga penelitian ini termotivasi untuk menginvestigasi pasangan fitur yang dapat menghasilkan model klasifikasi SVM yang paling akurat. Ada tiga pasangan fitur yang diinvestigasi secara simultan dengan σ_{RBF} , yaitu: fitur $|\mu|$ yang paling unik pertama dan kedua ($|\mu|_1, |\mu|_2$), fitur σ

yang paling unik pertama dan kedua (σ_1, σ_2), serta fitur $|\mu|$ dan σ yang paling unik ($|\mu|_1, \sigma_1$). Setelah model klasifikasi SVM sudah diinvestigasi, tahap berikutnya adalah evaluasi, yaitu menganalisis tingkat akurasi indikator pengendalian kursi roda BCI berdasarkan data uji.

4.3.6 Analisis dan Interpretasi

Hasil akhir dari SVM adalah indikator pengendalian kursi roda, antara lain: 0 untuk netral, 1 untuk maju, 2 untuk belok kanan, 3 untuk belok kiri, dan 4 untuk mundur. Metode yang diusulkan diimplementasikan ke dalam PC untuk keperluan analisis nilai akurasi dari indikator pengendalian kursi roda yang dihasilkan oleh masing-masing subjek dan hasilnya kemudian diinterpretasikan berdasarkan teori-teori yang telah dikumpulkan.




BAB V

HASIL DAN PEMBAHASAN


5.1 Hasil Pengujian Sistem Instrumentasi

Setelah rangkaian sistem instrumentasi telah dibuat, sistem instrumentasi terlebih dahulu diuji kelayakannya. Pengujian sistem dilakukan dengan maksud untuk memastikan bahwa data berupa sinyal EEG yang direkam menggunakan Neurosky Mindwave MW001 merupakan data yang valid.



Gambar 5.1 Sinyal yang dihasilkan saat MW001 tidak digunakan

Gambar 5.1 menunjukkan sinyal yang dihasilkan saat MW001 dihidupkan namun tidak digunakan. Sinyal yang dihasilkan tampak memiliki amplitudo yang sangat besar, konstan, dan rapat.




Gambar 5.2 Spektrum frekuensi sinyal saat MW001 tidak digunakan

Gambar 5.2 menunjukkan spektrum frekuensi sinyal saat MW001 dihidupkan namun tidak digunakan. Spektrum frekuensi yang disajikan dalam Gambar 5.2


menunjukkan terdapat sinyal yang mendominasi di frekuensi kisaran 100 Hz dan 150 Hz.

MW001 menyediakan sinyal hasil kalkulasi eSense yang disebut *poor signal*. Sinyal ini dibuat oleh Neurosky sebagai ukuran kualitas sinyal. Sebagaimana yang dijelaskan di subbab 2.5, sinyal ini memiliki rentang nilai antara 0 s.d. 200. Semakin mendekati 200 maka kualitas sinyal semakin jelek.



Gambar 5.3 Nilai *poor signal* saat MW001 dihidupkan namun tidak digunakan


Gambar 5.3 menunjukkan *poor signal* saat MW001 dihidupkan namun tidak digunakan. Gambar 5.3 menunjukkan bahwa *poor signal* menghasilkan nilai 200 secara konstan. Hal ini menandakan bahwa sinyal yang dihasilkan saat MW001 tidak digunakan telah sesuai dengan spesifikasinya.



Gambar 5.4 Sinyal yang dihasilkan saat MW001 digunakan tanpa menghubungkan *ground* dengan daun telinga


Gambar 5.4 menunjukkan sinyal yang dihasilkan saat MW001 digunakan tanpa menghubungkan klip *ground* dengan daun telinga. Sinyal yang ditampilkan

pada Gambar 5.4 tampak sukar untuk diamati. Keadaan sinyal saat *ground* tidak terhubung akan lebih mudah diamati bila dalam bentuk spektrum frekuensi.



Gambar 5.5 Spektrum sinyal saat MW001 digunakan tanpa menghubungkan klip *ground* dengan daun telinga


Gambar 5.5 menunjukkan spektrum frekuensi sinyal saat MW001 digunakan tanpa menghubungkan klip *ground* dengan daun telinga. Gambar 5.5 menunjukkan adanya kesamaan bentuk spektrum dengan saat MW001 dihidupkan namun tidak digunakan. Kesamaannya terletak pada adanya sinyal yang mendominasi di frekuensi 150 Hz. Gambar 5.5 juga menunjukkan adanya sinyal pada rentang frekuensi sinyal EEG (3 s.d. 100 Hz).



Gambar 5.6 Nilai *poor signal* saat MW001 digunakan tanpa menghubungkan *ground* dengan daun telinga

Gambar 5.6 menunjukkan nilai *poor signal* yang dihasilkan saat *klip ground* MW001 tidak terhubung dengan daun telinga. Gambar 5.6 menunjukkan bahwa nilai *poor signal* yang dihasilkan saat *ground* tidak terhubung dengan daun telinga adalah bernilai 200. Hal ini menandakan bahwa MW001 mampu


mendeteksi keadaan ini dengan baik. Dengan demikian, sinyal yang dihasilkan saat MW001 digunakan namun *ground* tidak terhubung dengan daun telinga telah sesuai dengan spesifikasinya.



Gambar 5.7 Sinyal yang dihasilkan saat MW001 dihidupkan dan elektrodanya disentuh ke organ tubuh lain

Gambar 5.7 menunjukkan sinyal yang dihasilkan saat MW001 dihidupkan dan elektrodanya disentuh ke organ tubuh lain, yaitu permukaan kulit tangan.


Sinyal yang ditunjukkan dalam Gambar 5.7 memperlihatkan bentuk sinyal yang hampir seragam dalam periode kurang dari satu detik.



Gambar 5.8 Spektrum frekuensi sinyal saat MW001 dihidupkan dan disentuh ke organ tubuh lain


Gambar 5.8 menunjukkan spektrum frekuensi sinyal saat MW001 dihidupkan dan disentuh ke organ tubuh lain. Gambar 5.8 menunjukkan bahwa tidak ada spektrum frekuensi yang mendominasi di 150 Hz. Selain itu terdapat sinyal pada rentang frekuensi 3 s.d. 50 Hz yang merupakan rentang frekuensi sinyal EEG. Sinyal yang ditangkap oleh elektrode MW001 tersebut bisa jadi

berasal dari potensial listrik yang dihasilkan oleh sel epidermis maupun sel saraf pada kulit. Dugaan pertama didasarkan pada pernyataan Kawai (Kawai *et al.*, 2008) bahwa sel epidermis menghasilkan potensial listrik. Sedangkan dugaan kedua didasarkan pada teori tentang terjadinya potensial listrik pada sistem syaraf yang sudah diuraikan dalam subbab 2.2. Meskipun subbab 2.2 menguraikan terjadinya potensial listrik pada otak, namun sistem syaraf juga menyebar di organ tubuh lain termasuk kulit. Spektrum frekuensi sinyal yang ditunjukkan dalam Gambar 5.8 tersebut memicu keraguan pada validitas sinyal saat elektrode ditempelkan di kulit kepala pada titik FP1. Keraguan tersebut bisa dihilangkan dengan meninjau validitas sinyal tersebut. Menurut Kawai (Kawai *et al.*, 2008), untuk merekam potensial listrik pada epidermis secara valid, maka elektrode referensi diletakkan di bawah lapisan epidermis atau di bawah lidah. Sedangkan untuk merekam potensial listrik otak secara valid, McFarland (McFarland *et al.*, 1997), Teplan (Teplan, 2002), Yao (Yao *et al.*, 2005), Choi (Choi *et al.*, 2006), Nunez (Nunez dan Srinivasan, 2006) dan Biopac (Biopac, 2014) menyatakan bahwa elektrode referensi diletakkan di daun telinga. Dengan demikian, potensial listrik yang ditangkap elektrode MW001 di kulit selain kulit kepala adalah sinyal yang tidak valid. Sedangkan saat MW001 digunakan dengan benar, maka sinyal yang ditangkap oleh elektrode MW001 adalah sinyal EEG yang valid.




Gambar 5.9 Nilai *poor signal* saat MW001 dihidupkan dan disentuh ke organ tubuh lain.

Gambar 5.9 menunjukkan nilai *poor signal* saat elektrode MW001 ditempelkan ke organ tubuh lain. Gambar 5.9 menunjukkan bahwa saat elektrode MW001 ditempelkan ke organ tubuh lain, nilai *poor signal* yang dihasilkan tidak selalu nol. *Poor signal* pada beberapa detik menghasilkan nilai lebih dari nol namun kurang dari 50 dan cukup sering terjadi. Sinyal ini bisa dijadikan indikator bahwa MW001 sedang merekam sinyal yang tidak valid.



Gambar 5.10 Sinyal yang dihasilkan saat MW001 dihidupkan dan digunakan dengan pemberian interferensi berupa jari tangan pada elektrode sensornya


Gambar 5.10 menunjukkan sinyal yang dihasilkan dari pemberian interferensi berupa organ tubuh lain yang berupa jari tangan. Gambar 5.10 menunjukkan adanya kemiripan bentuk sinyal dengan saat elektrode ditempelkan di organ tubuh lain sebagaimana yang ditunjukkan dalam Gambar 5.7.



Gambar 5.11 Spektrum frekuensi sinyal saat MW001 dihidupkan dan digunakan dengan pemberian interferensi organ tubuh lain pada elektrode sensornya


Gambar 5.11 menunjukkan spektrum frekuensi dari sinyal yang ditunjukkan dalam Gambar 5.10. Gambar 5.11 menunjukkan bahwa spektrum frekuensi yang

dihasilkan mirip dengan spektrum frekuensi saat elektrode MW001 ditempelkan ke organ tubuh lain sebagaimana yang ditunjukkan dalam Gambar 5.8.



Gambar 5.12 Nilai *poor signal* saat MW001 dihidupkan dan digunakan dengan pemberian interferensi organ tubuh lain pada elektrode sensornya


Gambar 5.12 menunjukkan nilai *poor signal* saat MW001 digunakan dengan interferensi berupa organ tubuh lain. Gambar 5.12. menunjukkan bahwa nilai *poor signal* yang dihasilkan mirip dengan saat elektrode MW001 ditempelkan pada organ tubuh lain. Nilai *poor signal* yang dihasilkan saat kondisi ini menunjukkan bahwa *poor signal* bisa dijadikan sebagai indikator validitas sinyal yang direkam.



Gambar 5.13 Sinyal yang dihasilkan saat MW001 digunakan dengan pemberian interferensi berupa kertas tebal pada elektrode sensornya

Gambar 5.13 menunjukkan sinyal yang dihasilkan saat MW001 digunakan dengan pemberian interferensi berupa kertas tebal pada elektrode sensornya.

Gambar 5.13 menunjukkan bahwa bentuk sinyal yang dihasilkan sangat rapat.




Gambar 5.14 Spektrum frekuensi sinyal saat MW001 digunakan dengan pemberian interferensi berupa kertas tebal pada elektrode sensornya

Gambar 5.14 menunjukkan spektrum frekuensi dari sinyal pada Gambar 5.13.

Gambar 5.14 menunjukkan adanya sinyal yang mendominasi di frekuensi 150 Hz.


Bentuk spektrum frekuensi ini mirip dengan saat MW001 dihidupkan namun tidak digunakan. Spektrum frekuensi ini juga mirip saat MW001 dihidupkan dan digunakan tanpa menghubungkan klip *ground* dengan daun telinga.



Gambar 5.15 Nilai *poor signal* saat MW001 digunakan dengan pemberian interferensi berupa kertas tebal pada elektrode sensornya


Gambar 5.15 menunjukkan nilai *poor signal* saat MW001 digunakan dan diberi interferensi berupa kertas tebal pada elektrode sensornya. Gambar 5.15 menunjukkan indikator *poor signal* selalu bernilai nol. Hasil ini menunjukkan bahwa *poor signal* tidak mampu mendeteksi adanya interferensi kertas tebal.

Meski demikian, munculnya sinyal dengan amplitudo tinggi pada frekuensi 150 Hz saat MW001 berpotensi digunakan sebagai indikator validitas sinyal.




Gambar 5.16 Sinyal yang dihasilkan saat MW001 digunakan dengan benar

Gambar 5.16 menunjukkan sinyal yang dihasilkan saat MW001 digunakan sebagaimana mestinya.




Gambar 5.17 Spektrum frekuensi sinyal EEG saat alat digunakan dengan benar

Gambar 5.17 menunjukkan spektrum frekuensi sinyal yang ditunjukkan pada Gambar 5.16. Gambar 5.17 menunjukkan bahwa spektrum frekuensi sinyal yang dihasilkan adalah berada pada rentang frekuensi EEG, yaitu 0 s.d. 50 Hz, meskipun masih terdapat *noise* dengan amplitudo yang rendah pada frekuensi di atas 100 Hz. Gambar 5.17 menunjukkan bahwa tidak ada sinyal dengan amplitudo yang sangat tinggi pada frekuensi 150 Hz.



Gambar 5.18 Nilai *poor signal* saat alat digunakan dengan benar

Nilai *poor signal* saat MW001 digunakan dengan sebagaimana mestinya ditunjukkan dalam Gambar 5.18. Gambar 5.18 menunjukkan *poor signal* selalu bernilai nol. Hasil ini menunjukkan bahwa *poor signal* yang bernilai nol saat MW001 digunakan dengan benar adalah sesuai dengan spesifikasinya.




Gambar 5.19 Spektrum sinyal yang direkam oleh Neurosky Mindwave saat alat digunakan dengan benar

MW001 memiliki filter *hardware* dengan rentang 3 Hz s.d. 100 Hz dan dilengkapi filter *antialiasing* yang memastikan sinyal yang terekam merupakan sinyal EEG dengan *cut-off* pada 100 Hz. Gambar 5.19 menunjukkan spektrum frekuensi sinyal yang direkam MW001 dalam satuan desibel (dB). Garis putus-putus warna merah pada Gambar 5.19 merupakan garis ambang yang bernilai -3 dB. Berdasarkan ungkapan White (White, 2000) dan Baker (Baker, 2015), diketahui Gambar 5.19 menunjukkan bahwa sinyal dengan frekuensi di atas 100 Hz telah dilemahkan oleh filter karena dayanya kurang dari -3 dB. Hasil ini menunjukkan Neurosky Mindwave MW001 menghasilkan sinyal yang sesuai dengan spesifikasinya.

5.2 Hasil Pengambilan Data

Hasil rekaman sinyal EEG dari masing-masing subjek ditampilkan dalam bentuk grafik. Bagian ini menampilkan sinyal EEG indikator maju dari subjek 1, subjek 2, dan subjek 3. Sedangkan untuk sinyal yang lain terlampir.




Gambar 5.20 Sinyal EEG untuk indikator maju; (a) subjek 1 (b) subjek 2 (c) subjek 3

Gambar 5.20 menunjukkan bahwa sinyal EEG yang dihasilkan dari indikator pengendalian yang sama namun oleh subjek yang berbeda, sekilas bentuknya berbeda.


5.3 Hasil Pemrosesan Data

Setelah sinyal EEG direkam, tahap *pre-processing* dilakukan, yaitu memfilter sinyal EEG menggunakan filter digital *bandpass* dengan rentang frekuensi 4 – 30 Hz.



Gambar 5.21 Sinyal EEG untuk indikator maju yang sudah difilter; (a) subjek 1 (b) subjek 2 (c) subjek 3


Sinyal EEG dari Gambar 5.20 yang telah difilter disajikan dalam Gambar 5.21.




Gambar 5.22 Hasil CWT sinyal EEG untuk indikator maju; (a) subjek 1 (b) subjek 2 (c) subjek 3

Setelah sinyal difilter, sinyal EEG didekomposisi menggunakan CWT dengan time window 4 detik overlap 1 detik dan hasilnya disajikan dalam Gambar 5.22. Meskipun ketiga subjek melakukan perintah mental dengan indikator yang sama, Gambar 5.22 menunjukkan perbedaan bentuk sinyal EEG dalam spektrum CWT dari ketiga subjek.

Selanjutnya, hasil dekomposisi CWT sinyal EEG dengan time window 4 detik overlap 1 detik pada setiap pseudo frekuensi dihitung nilai rata-rata absolut (μ) dan standar deviasinya (σ). Fitur μ dan σ disajikan dalam grafik spektrum dengan kontur warna yang merepresentasikan nilai dari kedua fitur tersebut.



Gambar 5.23 Fitur μ hasil CWT sinyal EEG untuk indikator maju; (a) subjek 1 (b) subjek 2 (c) subjek 3.




Gambar 5.24 Fitur σ hasil CWT sinyal EEG untuk indikator maju; (a) subjek 1 (b) subjek 2 (c) subjek 3


Grafik spektrum dari fitur μ dan σ pada Gambar 5.23 dan Gambar 5.24 menunjukkan bahwa fitur indikator maju dari ketiga subjek sama-sama cenderung besar nilainya pada frekuensi di atas 10 Hz.

5.4 Hasil Analisis Keunikan Fitur

Hasil analisis keunikan fitur menggunakan metode Friedman disajikan dalam subbab ini. Hasil analisis keunikan fitur dari setiap subjek disajikan dalam bentuk grafik sebagaimana yang telah diuraikan dalam subbab 4.3.5. Hasil analisis keunikan fitur μ dan σ masing-masing disajikan dalam Gambar 5.25 dan Gambar 5.26.




Gambar 5.25 Tingkat keunikan fitur μ hasil CWT sinyal EEG; (a) subjek 1 (b) subjek 2 (c) subjek 3




Gambar 5.26 Tingkat keunikan fitur σ hasil CWT sinyal EEG; (a) subjek 1 (b) subjek 2 (c) subjek 3

Gambar 5.25 dan Gambar 5.26 menunjukkan bahwa setiap fitur dari setiap pasangan indikator pengendalian kursi roda memiliki tingkat keunikan yang berbeda. Nilai keunikan fitur $|\mu|$ tertinggi dari subjek 1, subjek 2, dan subjek 3 masing-masing adalah 400 (pasangan indikator “maju – mundur”), 437 (pasangan indikator “netral - kiri”), dan 597 (pasangan indikator “netral - kiri”). Sedangkan nilai keunikan fitur σ tertinggi dari ketiga subjek masing-masing adalah 380, 419, 568. Gambar 5.25 dan Gambar 5.26 menunjukkan bahwa 6 atau 7 dari 10 pasangan indikator pengendalian kursi roda BCI dari ketiga subjek menghasilkan fitur yang paling unik bukan berada pada rentang frekuensi ERD (8 – 12 Hz) maupun ERS (13 – 35 Hz), melainkan pada rentang frekuensi teta (4 – 7 Hz). Hasil ini menyimpang dari teori ERD dan ERS bahwa keduanya berkaitan erat dengan pengendalian mental (Thomas, Fruitet dan Clerc, 2013; Rahul, Sharma dan Paul, 2017; Krishnan dan Athavale, 2018). Seharusnya, fitur yang paling unik terhadap indikator pengendalian selalu terjadi pada komponen ERD dan ERS.

Ahn (Ahn *et al.*, 2013) dan Azali (Azali, 2015) di dalam subbab 2.3 menyebutkan bahwa keadaan-keadaan mental seseorang pada rentang frekuensi teta antara lain: intuitif, kreatif, sedang mengingat, sedang berkhayal, dan sedang melamun. Berdasarkan teori tersebut, dominasi keunikan fitur yang terjadi pada rentang frekuensi teta sebagaimana yang ditunjukkan dalam Gambar 5.25 dan 5.26 kemungkinan kuat disebabkan oleh subjek yang menggunakan khayalannya saat pembuatan indikator pengendalian kursi roda BCI. Pasangan indikator pengendalian kursi roda BCI yang fiturnya paling unik di frekuensi teta menandakan kontrasnya khayalan subjek saat melakukan perintah mental untuk kedua indikator pengendalian tersebut.




Gambar 5.27 Signifikansi keunikan fitur μ hasil CWT sinyal EEG; (a) subjek 1 (b) subjek 2 (c) subjek 3



Gambar 5.28 Signifikansi keunikan fitur σ hasil CWT sinyal EEG; (a) subjek 1 (b) subjek 2 (c) subjek 3

Metode Friedman juga menghasilkan informasi mengenai signifikansi keunikan fitur terhadap setiap pasang indikator pengendalian kursi roda. Gambar 5.27 dan Gambar 5.28 masing-masing menunjukkan signifikansi keunikan fitur $|\mu|$ dan fitur σ dari hasil dekomposisi CWT sinyal EEG ketiga subjek. Gambar 5.27(a) dan Gambar 5.28(a) menunjukkan bahwa pasangan indikator netral dengan kiri pada subjek 1 tidak memiliki fitur $|\mu|$ dan σ yang unik signifikan pada pseudo frekuensi manapun. Sedangkan Gambar 5.27(b,c) dan Gambar 5.28(b,c) menunjukkan bahwa semua pasangan indikator pengendalian kursi roda BCI pada subjek 2 dan subjek 3 memiliki $|\mu|$ dan σ yang unik signifikan.

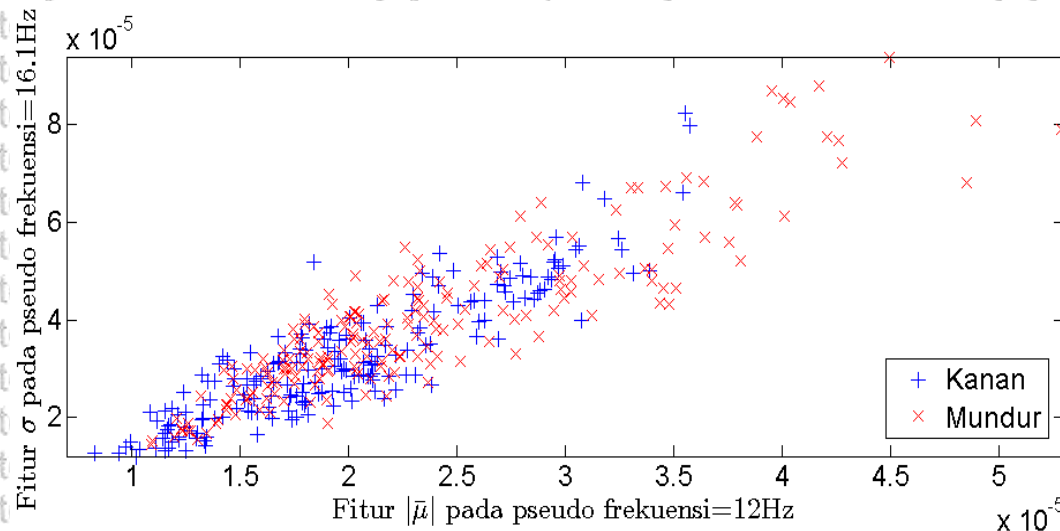
Grafik distribusi data dari hasil analisis keunikan fitur perlu dibuat agar dapat diamati sejauh mana nilai tingkat keunikan fitur dan signifikansinya dapat menggambarkan sebaran data.



Gambar 5.29 Sebaran data dua fitur yang tingkat keunikannya tinggi dan signifikan

Gambar 5.29 menunjukkan sebaran fitur $|\mu|$ dengan tingkat keunikan 597 dan fitur σ dengan tingkat keunikan 568 dari subjek 3 untuk pasangan indikator

pengendalian “netral – kiri”. Gambar 5.29 menunjukkan bahwa data tampak terpisah menurut kelasnya meskipun ada beberapa data yang menyimpang dari kelasnya dengan probabilitas yang tidak terlalu besar.




Gambar 5.30 Sebaran data dua fitur yang tingkat keunikannya sedang dan signifikan

Gambar 5.30 menunjukkan sebaran fitur $|\mu|$ dengan tingkat keunikan 210 dan fitur σ dengan tingkat keunikan 213 dari subjek 2 untuk pasangan indikator pengendalian “kanan – mundur”. Gambar 5.30 menunjukkan bahwa pada fitur

yang tingkat keunikannya sedang dan dinyatakan signifikan oleh metode Friedman, probabilitas penyimpangan datanya terhadap kelasnya lebih besar dibandingkan dengan sebaran data fitur yang telah disajikan di dalam Gambar

5.29. Data-data yang menyimpang di dalam Gambar 5.29 dan Gambar 5.30 terjadi karena fitur sinyal EEG bersifat nonlinier sebagaimana yang telah disebutkan di dalam subbab 2.2 oleh Siuly (Siuly, 2012), Carvalho (Carvalho *et al.*, 2015), Al-Qammaz (Al-Qammaz, Ahmad dan Yusof, 2016), dan Torse (Torse, Desai dan Khanai, 2018).



Gambar 5.31 Sebaran data dua fitur yang tingkat keunikannya rendah dan tidak signifikan

Gambar 5.31 menunjukkan sebaran dua fitur $|\mu|$ dengan tingkat keunikan 74 dan fitur σ dengan tingkat keunikan 81 dari subjek 1 untuk pasangan indikator pengendalian “netral – kiri”. Gambar 5.31 menunjukkan bahwa pada fitur yang tingkat keunikannya rendah dan dinyatakan tidak signifikan, penyimpangan datanya sangat besar. Gambar 5.29, Gambar 5.30, dan Gambar 5.31 menunjukkan bahwa hasil analisis keunikan fitur menggunakan metode Friedman dapat menggambarkan karakteristik sebaran data dari suatu fitur sinyal EEG. Dengan demikian, hasil analisis keunikan fitur dapat dimanfaatkan untuk menyeleksi fitur-fitur yang akan digunakan untuk pembuatan lima indikator pengendalian kursi roda BCI serta dapat digunakan untuk menganalisis penyebab penyimpangan-penyimpangan indikator pengendalian kursi roda BCI yang dihasilkan.

5.5 Pembuatan Indikator Pengendalian Kursi Roda

Sebagaimana yang telah diuraikan dalam 4.3.5, proses pembuatan indikator pengendalian kursi roda dibagi menjadi tiga tahap, yaitu: pelatihan,

investigasi, dan evaluasi. Subbab ini menyajikan hasil investigasi dan hasil evaluasi dari pembuatan lima indikator pengendalian kursi roda BCI menggunakan SVM. Berdasarkan uraian di dalam subbab 4.3.5, hasil investigasi disajikan dalam bentuk tabel dengan mencantumkan nilai σ_{RBF} , pasangan fitur, dan nilai akurasi.

Tabel 5.1 Hasil investigasi pembuatan indikator pengendalian kursi roda BCI

Pasangan Indikator	Subjek 1			Subjek 2			Subjek 3			Akurasi Rata-rata
	σ_{RBF}	Fitur	Akurasi	σ_{RBF}	Fitur	Akurasi	σ_{RBF}	Fitur	Akurasi	
Netral Maju	4,6	$ \mu _1, \mu _2$	71,53%	3,6	σ_1, σ_2	71,74%	24,3	σ_1, σ_2	90,20%	77,82%
Netral Kanan	5,5	$ \mu _1, \sigma_1$	59,42%	7,0	$ \mu _1, \mu _2$	52,17%	8,5	σ_1, σ_2	50,98%	54,19%
Netral Kiri	0,8	σ_1, σ_2	52,89%	13,6	$ \mu _1, \sigma_1$	74,63%	6,6	$ \mu _1, \mu _2$	71,84%	66,45%
Netral Mundur	0,5	σ_1, σ_2	57,25%	4,2	$ \mu _1, \mu _2$	65,94%	2,1	$ \mu _1, \sigma_1$	71,57%	64,92%
Maju Kanan	4,0	σ_1, σ_2	54,01%	17,3	σ_1, σ_2	65,22%	25,8	σ_1, σ_2	77,94%	65,72%
Maju Kiri	6,7	$ \mu _1, \sigma_1$	73,72%	12,5	$ \mu _1, \sigma_1$	74,64%	0,5	$ \mu _1, \sigma_1$	65,69%	71,35%
Maju Mundur	6,2	$ \mu _1, \mu _2$	69,34%	9,2	$ \mu _1, \sigma_1$	50,72%	18,8	σ_1, σ_2	69,85%	63,30%
Kanan Kiri	0,7	σ_1, σ_2	61,59%	9,6	$ \mu _1, \sigma_1$	75,36%	4,5	σ_1, σ_2	77,37%	71,44%
Kanan Mundur	0,5	$ \mu _1, \sigma_1$	54,35%	9,5	$ \mu _1, \sigma_1$	60,87%	16,9	$ \mu _1, \sigma_1$	50,00%	55,07%
Kiri Mundur	10,3	$ \mu _1, \mu _2$	60,86%	2,0	σ_1, σ_2	55,80%	5,3	σ_1, σ_2	57,66%	58,11%

Keterangan:

- $|\mu|_1$ = fitur nilai rata-rata absolut yang paling unik pertama.
- $|\mu|_2$ = fitur nilai rata-rata absolut yang paling unik kedua.
- σ_1 = fitur standar deviasi yang paling unik pertama.
- σ_2 = fitur standar deviasi yang paling unik kedua.

Hasil investigasi model klasifikasi SVM di dalam Tabel 5.1 menunjukkan bahwa nilai σ_{RBF} dari setiap pasangan indikator pengendalian kursi roda BCI pada ketiga subjek adalah variatif. Pasangan fitur yang dinyatakan optimal dari setiap subjek juga variatif terhadap setiap pasangan indikator pengendalian kursi roda BCI.

Terdapat perbedaan pasangan indikator yang menghasilkan model klasifikasi SVM dengan nilai akurasi tertinggi dari ketiga subjek. Model klasifikasi yang paling akurat pada subjek 1, subjek 2, dan subjek 3 masing-masing dihasilkan oleh pasangan indikator pengendalian “maju – kiri” (73,72 %), “kanan – kiri” (75,36 %), dan “netral – maju” (90,20 %). Sedangkan model klasifikasi yang akurasi paling rendah pada subjek 1, subjek 2, dan subjek 3 masing-masing dihasilkan oleh pasangan indikator pengendalian “netral – kiri” (52,89 %), “maju – mundur” (50,72 %), dan “kanan – mundur” (50 %).

Ditinjau dari pasangan indikator pengendalian kursi roda BCI, pasangan indikator “netral – maju” dari ketiga subjek menghasilkan model klasifikasi SVM dengan nilai akurasi rata-rata tertinggi, yaitu 77,82%. Sedangkan pasangan indikator “netral – maju” dari ketiga subjek menghasilkan model klasifikasi SVM dengan nilai akurasi rata-rata paling rendah, yaitu 54,19%.

Tabel 5.2 Kesesuaian hasil investigasi model klasifikasi terhadap keunikan fitur

Akurasi Rata-rata				
Keunikan Tinggi	Keunikan Menengah	Keunikan Rendah		
68,72%	58,94%	56,10%		
Kesesuaian dengan Keunikan Fitur			Jumlah	Persentase
Sesuai Keunikan Fitur			24	80%
Tidak Sesuai Keunikan Fitur			6	20%

Tabel 5.2 menunjukkan bahwa akurasi rata-rata model klasifikasi SVM yang dicapai oleh fitur dengan tingkat keunikan tinggi, menengah, dan rendah masing-masing adalah 68,78%, 58,94%, dan 56,10%. Tabel 5.2 juga menunjukkan bahwa nilai akurasi model klasifikasi SVM dari 30 pasangan indikator pengendalian kursi roda BCI (10 pasangan indikator dari ketiga subjek),

24 di antaranya sesuai dengan tingkat keunikan fitur, sedangkan enam diantaranya tidak sesuai dengan tingkat keunikan fitur. Enam pasangan indikator tersebut antara lain: “kanan – mundur” dan “kiri – mundur” pada subjek 1; “kiri – mundur” pada subjek 2; “netral – kanan”, “kanan – mundur”, dan “kiri – mundur” pada subjek 3. Penyebab 20% ketidaksesuaian hasil investigasi dengan tingkat keunikan fitur tersebut diduga kuat faktor utamanya adalah sifat ketidaklinieran fitur sinyal EEG sebagaimana yang telah diuraikan dalam subbab 2.2.

Tabel 5.3 Matriks *confusion* pembuatan indikator pengendalian kursi roda BCI

		Hasil Prediksi					Total	
		Netral	Maju	Kanan	Kiri	Mundur		
Target	Subjek 1	Netral	5	28	11	21	4	69
		Maju	4	54	9	32	4	103
		Kanan	5	36	4	56	2	103
		Kiri	1	44	24	0	0	69
		Mundur	11	12	1	65	15	104
	Subjek 2	Netral	58	1	7	6	31	103
		Maju	48	5	12	11	27	103
		Kanan	44	2	17	7	33	103
		Kiri	38	1	28	5	31	103
		Mundur	43	1	18	6	35	103
	Subjek 3	Netral	50	3	5	39	6	103
		Maju	60	5	6	25	6	102
Kanan		59	6	7	13	18	103	
Kiri		28	9	13	52	1	103	
Mundur		68	9	11	6	9	103	

Keterangan:

- Angka yang dicetak tebal adalah jumlah hasil prediksi yang sesuai dengan target

Tabel 5.3 menunjukkan jumlah hasil prediksi indikator pengendalian kursi roda BCI yang sesuai dengan target evaluasi dan yang tidak sesuai dengan target evaluasi. Tabel 5.3 menunjukkan bahwa penyimpangan yang terjadi pada indikator pengendalian kursi roda yang dibuat adalah cenderung tinggi. Kolom

“Total” pada Tabel 5.3 menunjukkan adanya dua data yang jumlahnya lebih sedikit dibandingkan data yang lain, yaitu pada baris “netral” dan “kiri” subjek 1.

Jumlah tersebut lebih sedikit karena ada sebagian set sinyal yang tidak lolos uji validitas sinyal (subbab 4.3.3).

Tabel 5.4 Akurasi indikator pengendalian kursi roda BCI hasil evaluasi

	Subjek 1	Subjek 2	Subjek 3
Akurasi	17,41%	23,30%	23,93%
Akurasi dengan toleransi	22,10%	56,89%	65,76%
Deviasi rata-rata	0,78		

Toleransi yang dimaksud dalam Tabel 5.4 adalah jika terdapat hasil prediksi berupa indikator netral yang muncul pada target yang bukan indikator netral, maka hasil prediksi dianggap benar. Alasan pembenaran dalam toleransi tersebut adalah karena secara umum penyimpangan berupa indikator netral tidak membahayakan pengguna kursi roda BCI. Secara umum Tabel 5.4 menunjukkan bahwa indikator pengendalian kursi roda BCI yang dibuat dalam penelitian ini memiliki akurasi yang rendah dan belum dapat diaplikasikan ke dalam kursi roda BCI. Selain itu, Tabel 5.4 juga menunjukkan nilai deviasi rata-rata yang cukup besar, yaitu mencapai 0,78. Ditinjau dari hasil analisis keunikan fitur, rendahnya nilai akurasi dan besarnya deviasi indikator pengendalian yang dihasilkan tersebut adalah akibat dari kurang uniknya fitur sinyal EEG pada beberapa pasangan indikator pengendalian kursi roda BCI. Imbas dari kurang uniknya fitur tersebut adalah rendahnya nilai akurasi model klasifikasi SVM yang dihasilkan. Model klasifikasi yang kurang akurat mengakibatkan besarnya penyimpangan hasil prediksi indikator pengendalian kursi roda BCI yang dihasilkan.

5.6 Pembahasan

Analisis keunikan fitur sinyal EEG terhadap lima indikator pengendalian kursi roda BCI menggunakan metode Friedman telah dilakukan. Metode yang diusulkan dapat mengukur tingkat keunikan fitur beserta tingkat signifikansi keunikannya. Hasil analisis tingkat keunikan fitur menunjukkan bahwa secara kualitatif nilai tingkat keunikan fitur sinyal EEG dan signifikansinya terhadap indikator pengendalian kursi roda BCI berhubungan dengan kelinieran sebaran data fitur sinyal EEG terhadap kelas indikator pengendalian kursi roda BCI. Semakin besar dan signifikan nilai tingkat keunikan fitur sinyal EEG terhadap indikator pengendalian kursi roda, maka probabilitas penyimpangan data dari kelasnya semakin kecil. Semakin kecil dan tidak signifikan nilai tingkat keunikan fitur, maka probabilitas penyimpangan data dari kelasnya semakin besar.

Hasil pembuatan lima indikator pengendalian kursi roda BCI menggunakan metode SVM RBF menunjukkan bahwa probabilitas penyimpangan indikator pengendalian yang dihasilkan masih sangat tinggi dan belum bisa diaplikasikan pada kursi roda BCI. Hasil analisis keunikan fitur menunjukkan bahwa besarnya penyimpangan tersebut diduga kuat disebabkan oleh ketidaklinieran fitur sinyal EEG. Meskipun telah digunakan metode Friedman yang merupakan pendekatan nonlinier untuk menganalisis keunikan fitur sinyal EEG sekaligus fungsi kernel RBF yang merupakan pendekatan nonlinier untuk model klasifikasi SVM, ternyata kombinasi keduanya belum bisa menghasilkan lima indikator pengendalian kursi roda yang cukup akurat.

Penelitian Girase (Girase dan Deshmukh, 2015) dan Siswoyo (Siswoyo, Arief dan Sulistijono, 2017) berhasil membuat lebih dari dua indikator

pengendalian BCI berdasarkan sinyal EEG dengan akurasi di atas 90% padahal sinyalnya direkam menggunakan EEG sensor tunggal. Girase (Girase dan Deshmukh, 2015) memanfaatkan fitur domain waktu dari Mindwave, yaitu *attention* dan *meditation*, serta fitur kedipan mata (*blink*). Sedangkan Siswoyo (Siswoyo, Arief dan Sulistijono, 2017) memanfaatkan fitur domain waktu berupa nilai tegangan sinyal, level alfa 1, level alfa 2, *attention*, dan *meditation*. Fitur level alfa 1 dan alfa 2 juga termasuk fitur bawaan Mindwave. Detail proses ekstraksi fitur Mindwave tidak *open source* sehingga tidak bisa ditampilkan. Berdasarkan kedua penelitian tersebut, fitur domain waktu bisa dipertimbangkan sebagai pilihan untuk pembuatan indikator pengendalian kursi roda BCI dengan catatan fitur yang hendak digunakan dianalisis keunikannya terlebih dahulu. Besarnya deviasi indikator pengendalian kursi roda BCI hasil penelitian ini dan besarnya akurasi indikator pengendalian BCI oleh Girase memunculkan pertimbangan untuk mengombinasikan fitur sinyal EEG dengan fitur sinyal yang lain seperti EMG pada titik FPI atau yang lainnya, sehingga diharapkan indikator pengendalian kursi roda BCI menjadi lebih akurat.

MW001 didesain untuk merekam sinyal EEG dari titik FPI (Neurosky, 2009; Dobosz dan Wittchen, 2015; Ginete *et al.*, 2015) sehingga perekaman pada titik lain belum diketahui validitasnya. Boleh jadi selain titik FPI terdapat titik perekaman yang menghasilkan sinyal EEG dengan fitur lebih unik.

Besarnya penyimpangan Indikator pengendalian BCI hasil penelitian ini memunculkan perhatian pada kualitas sinyal EEG. Sinyal EEG adalah sinyal listrik (Teplan, 2002; Tyagi, Semwal dan Shah, 2012). Penghambat kualitas sinyal EEG adalah impedansi kulit kepala, utamanya oleh *stratum corneum* (SC) (Cardu

et al., 2012; Lu *et al.*, 2018). Mungkin MW001 perlu perlakuan tertentu agar kepekaannya dapat ditingkatkan. Namun, modul TGAM dalam MW001 sudah dipatenkan Neurosky (Neurosky, 2010; Aswathy, 2015). Perlakuan pada elektrode MW001 bisa dipertimbangkan untuk meningkatkan kualitas sinyal EEG.

Berbicara mengenai teknologi kursi roda, telah banyak pengembangan kursi roda yang dapat dikendalikan tanpa gerakan anggota tubuh secara aktual, bahkan tanpa tombol untuk mengontrolnya. Beberapa contohnya antara lain: kursi roda yang digunakan oleh Stephen Hawking (Grabianowski, 2007; Bennett, 2018; Pash, 2018), kursi roda yang dikendalikan dengan ekspresi wajah (Rabhi, Mrabet dan Fnaiech, 2018), kursi roda yang dikendalikan dengan gerakan kepala (Machangpa dan Chingtham, 2018), kursi roda yang dikendalikan dengan suara penggunanya (Al-Rousan dan Assaleh, 2011; Ruiz-Serrano *et al.*, 2013; Škraba *et al.*, 2015), kursi roda yang dikendalikan dengan gerakan tangan (Kundu *et al.*, 2017), dan kursi roda yang dikendalikan dengan sistem pendeteksi lingkungan atau *path planning* (Leishman, Horn dan Bourhis, 2010; Jiao *et al.*, 2018).

Kursi roda Stephen Hawking dapat dikendalikan dengan memanfaatkan sensor inframerah yang diletakkan di pipi kanan Hawking (AMS Vans Team, 2018). Sensor tersebut membuat pipi Hawking menjadi pointer untuk layar komputer di hadapannya, sehingga dia bisa memilih ingin bergerak menuju kemanapun dia mau (How It Works Team, 2016).

Rabhi (Rabhi, Mrabet dan Fnaiech, 2018) membuat kursi roda yang dilengkapi kamera untuk menangkap citra wajah penggunanya. Citra yang ditangkap oleh kamera diolah komputer menggunakan metode Viola Jones dan

neural network. Kursi roda Rabhi dapat digerakkan berdasarkan ekspresi wajah dengan akurasi mencapai 97,10%.

Machangpa (Machangpa dan Chingtham, 2018) mengembangkan kursi roda yang bisa dikendalikan dengan gerakan kepala. Machangpa memanfaatkan sensor aselerometer, giroskop, dan dilengkapi dengan sensor ultra sonik. Machangpa mengklaim bahwa kursi roda buatannya telah didesain dengan biaya yang efektif, aman digunakan, fleksibel, dan mudah dikendalikan.

Al-Rousan (Al-Rousan dan Assaleh, 2011), Ruiz-Serrano (Ruíz-Serrano *et al.*, 2013), dan Skraba (Škraba *et al.*, 2015) mengembangkan kursi roda yang bisa dikendalikan dengan suara penggunanya. Akurasi pengenalan suara yang dicapai oleh Al-Rousan (Al-Rousan dan Assaleh, 2011) dan Ruiz-Serrano (Ruíz-Serrano *et al.*, 2013) adalah di atas 95,00%. Sedangkan Skraba (Škraba *et al.*, 2015), akurasi pengenalan suara yang dicapai adalah antara 60,00 s.d. 97,00 % tergantung penggunanya.

Kundu (Kundu *et al.*, 2017) mengembangkan kursi roda yang bisa dikendalikan dengan gerakan satu tangan. Kundu memanfaatkan sensor elektromiografi (EMG) untuk mendeteksi gerakan satu tangan. Kursi roda yang dibuat kundu dapat dikendalikan dengan akurasi 98,90%.

Leishman (Leishman, Horn dan Bourhis, 2010) dan Jiao (Jiao *et al.*, 2018) mengembangkan kursi roda yang bisa dikendalikan dengan sistem pendeteksi lingkungan atau *path planning*. Leishman (Leishman, Horn dan Bourhis, 2010) menggunakan kamera pada kursi rodanya untuk menangkap citra lingkungan di depan kursi roda lalu memprosesnya menggunakan program yang dia buat untuk mendeteksi beberapa tempat yang bisa dilalui oleh kursi roda dan bisa dipilih oleh

penggunanya. Berbeda dengan Leishman (Leishman, Horn dan Bourhis, 2010), Jiao (Jiao *et al.*, 2018) lebih fokus untuk mengoptimalkan jarak tempuh kursi roda dengan menggunakan algoritma ant-colony sehingga hasil penelitiannya masih berupa simulasi.

Meskipun indikator pengendalian kursi roda BCI yang dibuat dalam penelitian ini belum sebaik kursi roda-kursi roda yang dibuat dengan teknologi selain BCI, Hasil investigasi model klasifikasi SVM dalam penelitian ini menunjukkan adanya potensi untuk pengembangan kursi roda BCI lebih lanjut karena tiga dari 10 model klasifikasi yang dibuat bisa menghasilkan akurasi di atas 70%. Terlebih lagi, sebagaimana yang diungkapkan oleh Bi dan Liu (Bi, Fan dan Liu, 2013), bahwa kursi roda BCI yang semula kurang akurat bisa dikembangkan menggunakan teknologi *shared control*. Apalagi baru-baru ini Pu (Pu *et al.*, 2018) berhasil mengembangkan teknologi kursi roda *shared control* yang hasil pengujiannya menunjukkan bahwa kursi roda yang dikembangkan dapat bekerja secara efektif, reliabel, serta dapat diaplikasikan untuk kursi roda BCI.

Perihal kursi roda berteknologi BCI pun dirasa masih penting untuk dikembangkan lebih lanjut. Alasannya adalah apabila kursi roda BCI dapat bekerja dengan akurat, kursi roda BCI bisa membantu mobilitas penyandang disabilitas yang kondisi fisiknya sama sekali sulit digunakan untuk mengendalikan kursi roda baik dengan ekspresi wajah, gerakan kepala, suara penggunanya, gerakan tangan, maupun aktivitas fisik lainnya.



BAB VI

KESIMPULAN DAN SARAN

6.1 Kesimpulan

Dari penelitian penentuan keunikan fitur CWT dapat diperoleh lima indikator pengendalian untuk kursi roda BCI yang didasarkan pada sinyal EEG dari Neurosky MW001. Akan tetapi, akurasi kelima indikator tersebut belum dapat digunakan sebagai indikator kontrol untuk aktuator kursi roda BCI. Hal ini disebabkan oleh tingkat kepercayaan rata-rata indikator tersebut masih di bawah 60%, sedangkan untuk indikator yang berpasangan masih di bawah 70%.

6.2 Saran

Tingkat kepercayaan indikator pengendalian kursi roda BCI harus lebih dari 70% agar dapat diaplikasikan ke aktuator. Untuk meningkatkan tingkat kepercayaan tersebut, hal-hal yang bisa disarankan antara lain: kepekaan sensor ditingkatkan, penggunaan fitur domain waktu, dan penggunaan fitur kombinasi antara fitur domain waktu dengan fitur domain frekuensi. Karena MW001 juga dapat merekam sinyal EMG, maka bisa disarankan juga agar mengombinasikan sinyal EEG dengan sinyal EMG untuk meningkatkan keunikan fitur sehingga tingkat kepercayaannya bisa bertambah.

DAFTAR PUSTAKA

Abbey, R., He, T. dan Wang, T. (2017) 'Methods of Multinomial Classification Using Support Vector Machines', *SAS Enterprise Miner*, 434, pp. 1–20.

Abdalsalam M, E. *et al.* (2018) 'Discrimination of Four Class Simple Limb Motor Imagery Movements for Brain-Computer Interface', *Biomedical Signal Processing dan Control*. Elsevier Ltd, 44, pp. 181–190.

Abibullaev, B. dan An, J. (2012) 'Classification of Frontal Cortex Haemodynamic Responses During Cognitive Tasks Using Wavelet Transforms dan Machine Learning Algorithms', *Medical Engineering dan Physics*. Institute of Physics dan Engineering in Medicine, 34(10), pp. 1394–1410.

Abiyev, R. H. *et al.* (2015) 'Brain Based Control of Wheelchair', in *International Conference Artificial Intelligence*. North Cyprus: ICAI'15, pp. 542–547.

Ahn, M. *et al.* (2013) 'High theta dan low alpha powers may be indicative of BCI-illiteracy in motor imagery', *PLoS ONE*, 8(11).

Akila, M., Sekar, K. S. dan Suresh, A. (2015) 'Smart Brain-Controlled Wheelchair dan Devices Based on EEG in Low Cost for Disabled Person', *IJCCN*, 1(1), pp. 291–298.

Al-Qammaz, A. Y. A., Ahmad, F. K. dan Yusof, Y. (2016) 'Optimization of Least Squares Support Vector Machine Technique Using Genetic Algorithm for Electroencephalogram Multi-Dimensional Signals', *Jurnal Teknologi*, 78(5–10), pp. 107–115.

Al-Qaysi, Z. T. *et al.* (2018) 'A Review of Disability EEG Based Wheelchair Control System: Coherent Taxonomy, Open Challenges dan

Recommendations', *Computer Methods dan Programs in Biomedicine*. Elsevier B.V., 164, pp. 221–237.

Al-Rousan, M. dan Assaleh, K. (2011) 'A Wavelet dan Neural Network Based Voice System for A Smart Wheelchair Control', *Journal of the Franklin Institute*. Elsevier, 348(1), pp. 90–100.

Alba, N. A. *et al.* (2010) 'Novel Hydrogel-Based Preparation-Free EEG Electrode', *IEEE Transactions on Neural Systems dan Rehabilitation Engineering*, 18(4), pp. 415–423.

Albulbul, A. (2016) 'Evaluating Major Electrode Types for Idle Biological Signal Measurements for Modern Medical Technology', *Bioengineering*, 3(3), p. 20.

Ali, S. *et al.* (2016) 'Time-Frequency Coherence of Multichannel EEG Signals: Synchrosqueezing Transform Based Analysis', *International Journal of Computer Science Trends dan Technology*, 4(3), pp. 40–48.

Ali, Z. dan Bhaskar, S. B. (2016) 'Basic Statistical Tools in Research dan Data Analysis', *Indian Journal of Anaesthesia*, 60(9), pp. 662–669.

AMS Vans Team (2018) *Stephen Hawking's Wheelchair - In Detail!*, *amsvans*. Available at: <https://www.amsvans.com/blog/stephen-hawkings-wheelchair-in-detail/> (Accessed: 4 June 2018).

Aoki, K. *et al.* (2013) 'SVM Analysis of Haemophilia A by Using Protein Structure', in *Computational Intelligence dan Neuroscience*, pp. 681–688.

Arvaneh, M. *et al.* (2011) 'Optimizing The Channel Selection dan Classification Accuracy in EEG-Based BCI', *IEEE Transactions on Biomedical Engineering*, 58(6), pp. 1865–1873.



Ashok, T. *et al.* (2016) 'Robot Control Through An Adaptive Brain Robot Interface Authors', *International Journal of Scientific Research dan Education*, 4(7), pp. 5563–5570.

Aswathy, M. (2015) 'Brain Actuated Wheelchair Using Brain Wave Sensor', *IJABEA*, 11(1), pp. 78–82.

Aydemir, Ö. dan Kayikcioglu, T. (2011) 'Wavelet Transform Based Classification of Invasive Brain Computer Interface Data Onder', *Radioengineering*, 20(1), pp. 31–38.

Aydemir, Ö. dan Kayikcioglu, T. (2016) 'Investigation of the Most Appropriate Mother Wavelet for Characterizing Imaginary EEG Signals Used in BCI Systems', *Turkish Journal of Electrical Engineering dan Computer Sciences*, 24, pp. 38–49.

Azali, N. N. bt M. (2015) *Classification of EEG Signals for Human Computer Interface (HCI) Application*. Batu Pahat.

Azis, A. I. S., Suhartono, V. dan Himawan, H. (2017) 'Model Multi Clas Svm Menggunakan Strategi IV1 Untuk Klasifikasi Wall-Following Robot Navigation Data Model Multi Clas Svm Menggunakan Strategi IV1 Untuk Klasifikasi Wall-Following Robot Navigation Data', *Jurnal Teknologi Informasi*, 13(2), pp. 170–187.

Baker, B. C. (2015) 'Designing An Anti-aliasing Filter for ADCs in The Frequency Domain', *Analog Applications Journal*.

Balaji, R. dan Venkatasubramanian, V. (2009) 'Non Invasive Brain Computer Interface for Movement Control', in *Proceedings of the World Congress on Engineering dan Computer Science*. San Fransisco: WCECS.



Bassani, T. (2009) *Design of A BCI System Using EEG Signal Analysis with Continuous Wavelet Transformation dan Naives Bayes Classifier.*

Pontificia Universidade Católica do Paraná.

Bennett, C. (2018) *Stephen Hawking's Hi-Tech Wheelchair to Live on, PTI.*

Available at: <https://timesofindia.indiatimes.com/world/uk/stephen-hawkings-hi-tech-wheelchair-to-live-on/articleshow/63570714.cms>

(Accessed: 4 June 2018).

Berlin, D. (2017) *Multi-class Supervised Classification Techniques for High-dimensional Data: Applications to Vehicle Maintenance at Scania.*

Stockholm.

Bi, L., Fan, X. A. dan Liu, Y. (2013) 'EEG Based Brain Controlled Mobile Robots: A Survey', *IEEE Transactions on Human-Machine Systems*,

43(2), pp. 161–176.

Biopac (2014) *Ground vs. Reference for EEG Recording.* Available at:

[https://www.biopac.com/knowledge-base/ground-vs-reference-for-eeg-](https://www.biopac.com/knowledge-base/ground-vs-reference-for-eeg-recording/)

[recording/](https://www.biopac.com/knowledge-base/ground-vs-reference-for-eeg-recording/) (Accessed: 20 November 2018).

Bose, R. *et al.* (2016) 'Performance Analysis of Left dan Right Lower Limb Movement Classification from EEG', *3rd International Conference on*

Signal Processing dan Integrated Networks, SPIN 2016, pp. 174–179.

Bostanov, V. (2004) 'BCI Competition 2003--Data Set Ib dan IIb: Feature Extraction from Event-Related Brain Potentials with the Continuous

Wavelet Transform dan the t-Value Scalogram', *{IEEE} Transactions on Biomedical Engineering*, 51(6), pp. 1057–1061.

Bostanov, V. (2015) 'Multivariate Assessment of Event-Related Potentials with



The t-CWT Method', *BMC Neuroscience*. BioMed Central, pp. 1–20.

Bottou, L. dan Lin, C. (2007) *Support Vector Machine Solvers*, MIT Press, Cambridge.

Bousseta, R. *et al.* (2018) 'EEG Based Brain Computer Interface for Controlling a Robot Arm Movement Through Thought', *Irbm*. Elsevier Masson SAS, 39(2), pp. 129–135.

Browning, G. (2007) *Emergenetics: Menyadap Ilmu Kesuksesan Baru*. Jakarta: Gramedia.

Burg, G. J. J. van den dan Groenen, P. J. F. (2016) 'GenSVM: A Generalized Multiclass Support Vector Machine', *Journal of Machine Learning Research*, 17, pp. 1–42.

Cardu, R. *et al.* (2012) 'Electrode Contact Impedance Sensitivity to Variations in Geometry', *Physiological Measurement*, 33(5), pp. 817–830.

Carvalho, S. N. *et al.* (2015) 'Comparative Analysis of Strategies for Feature Extraction dan Classification in SSVEP BCIs', *Biomedical Signal Processing dan Control*. Elsevier Ltd, 21, pp. 34–42.

Castillo-Garcia, J. *et al.* (2015) 'Active Learning for Adaptive Brain Machine Interface Based on Software Agent', in *2015 23rd Mediterranean Conference on Control dan Automation (MED)*. Torremolinos: IEEE, pp. 44–48.

Chang, M. H. *et al.* (2016) 'Eliciting Dual-Frequency SSVEP Using a Hybrid SSVEP-P300 BCI', *Journal of Neuroscience Methods*. Elsevier B.V., 258, pp. 104–113.

Chatfield, M. dan Mander, A. (2009) 'The Skillings-Mack Test (Friedman Test



when There Are Missing Data)', *Stata Journal*, 9(2), pp. 299–305.

Chen, Y. *et al.* (2018) 'Mixed Kernel Based Extreme Learning Machine for Electric Load Forecasting', *Neurocomputing*. Elsevier B.V., 312, pp. 90–106.

Chi, Y. M., Jung, T.-P. dan Cauwenberghs, G. (2010) 'Dry-Contact dan Noncontact Biopotential Electrodes: Methodological Review', *IEEE*, 3, pp. 106–119.

Choi, K. (2013) 'Electroencephalography (EEG)-Based Neurofeedback Training for Brain-Computer Interface (BCI)', *Experimental Brain Research*, 231(3), pp. 351–365.

Choi, S. H. *et al.* (2006) 'Estimation of Optimal Location of EEG Reference Electrode for Motor Imagery Based BCI Using fMRI', in *2006 International Conference of the IEEE Engineering in Medicine dan Biology Society*. IEEE, pp. 1193–1196.

Claesen, M. *et al.* (2014) 'Fast Prediction with SVM Models Containing RBF Kernels', *arXiv preprint*, pp. 1–25.

Corazzol, M. (2012) *Classification of Movements of The Rat Based on Intracortical Signals Using Artificial Neural Network dan Support Vector Machine*. Aalborg University.

Darvishi, S. dan Al-ani, A. (2007) 'Brain-Computer Interface Analysis using Continuous Wavelet Transform dan Adaptive Neuro-Fuzzy Classifier', in *Proceedings of the 29th Annual International Conference of the IEEE EMBS*. Lyon: Cité Internationale, pp. 78–81.

Dobosz, K. dan Wittchen, P. (2015) 'Brain Computer Interface for Mobiloo



Devices', *Journal of Medical Informatics dan Technologies*, 24, pp. 215–222.

Edla, D. R. *et al.* (2018) 'Classification of EEG Data for Human Mental State Analysis Using Random Forest Classifier', *Procedia Computer Science*. Elsevier B.V., 132(Iccids), pp. 1523–1532.

Eisinga, R. *et al.* (2017) 'Exact p-Values for Pairwise Comparison of Friedman Rank Sums, with Application to Comparing Classifiers', *BMC Bioinformatics*. BMC Bioinformatics, 18(1), pp. 1–18.

Fatoorechi, M. *et al.* (2015) 'A Comparative Study of Electrical Potential Sensors dan Ag/AgCl Electrodes for Characterising Spontaneous dan Event Related Electroencephalogram Signals', *Journal of Neuroscience Methods*, 251, pp. 7–16.

Fiedler, P. *et al.* (2014) 'Comparison of Three Types of Dry Electrodes for Electroencephalography', *Acta Imeko*, 3(3), pp. 33–37.

Fink, T. E. (2012) *The Enhancement of Neurofeedback with A Low Cost dan Easy-to-Use NeuroSky EEG Biofeedback-Training Device: The MindReflector Protocols*. Orlando.

Firdaus, A. K. S. (2017) *Anti-aliasing Filter of Neurosky MindWave Starter Kit*, *Academia.edu*.

Folane, N. R. *et al.* (2017) 'Brain Computer Interface Based Wheelchair: A Robotic Architecture', *International Journal of Engineering Sciences & Research Technology*, 6(3), pp. 440–444. Available at: www.ijesrt.com.

Fonseca, C. *et al.* (2007) 'A Novel dry Active Electrode for EEG recording', *IEEE Transactions on Biomedical Engineering*, 54(1), pp. 162–165.



Gao, K. P. *et al.* (2018) 'Soft Pin-shaped Dry Electrode with Bristles for EEG Signal Measurements', *Sensors dan Actuators, A: Physical*. Elsevier B.V., 283, pp. 348–361.

Ghosh, D. (2012) *An Adaptive Human Brain to Computer Interface System for Robotic or Wheel- Chair based Navigational Tasks*. KTH Royal Institute of Technology.

Ginete, A. B. *et al.* (2015) 'ThinkGear TM Pattern Recognition Algorithm for Body Movements using Relativity', *Recent Advances in Electrical Engineering*, pp. 147–152.

Girase, P. D. dan Deshmukh, M. P. (2015) 'Mindwave Device Wheelchair Control', *International Journal of Science dan Research (IJSR)*, 5(6), pp. 2172–2176.

Gneo, M. dan Severini, G. (2011) 'Towards a Brain-Activated dan Eye-Controlled Wheelchair', *International Journal of Bioelectromagnetism*, 13(1), pp. 44–45.

Grabianowski, E. (2007) *Stephen Hawking's Wheelchair*, *Howstuffworks*. Available at: <https://computer.howstuffworks.com/audio.htm> (Accessed: 4 June 2018).

Graimann, B., Allison, B. dan Pfurtscheller, G. (2010) *Brain-Computer Interfaces*, Springer. Edited by A. C. Elitzur et al. New York: Springer.

Granato, D., de Araújo Calado, V. Ô. M. dan Jarvis, B. (2014) 'Observations on the Use of Statistical Methods in Food Science dan Technology', *Food Research International*. Elsevier Ltd, 55, pp. 137–149.

Guan, S., Zhao, K. dan Wang, F. (2018) 'Multiclass Motor Imagery Recognition



of Single Joint in Upper Limb Based on NSGA- II OVO TWSVM', *Computational Intelligence dan Neuroscience*, 2018, pp. 1–11.

Gupta, A. dan Kumar, D. (2017) 'Fuzzy Clustering-Based Feature Extraction Method for Mental Task Classification', *Brain Informatics*. Springer Berlin Heidelberg, 4(2), pp. 135–145.

Gysels, E., Renevey, P. dan Celka, P. (2005) 'SVM-Based Recursive Feature Elimination to Compare Phase Synchronization Computed from Broadband dan Narrowband EEG Signals in Brain-Computer Interfaces', *Signal Processing*, 85(11), pp. 2178–2189.

Harafani, H. dan Wahono, R. S. (2015) 'Optimasi Parameter pada Support Vector Machine berbasis Algoritma Genetika untuk Estimasi Kebakaran Hutan', *Journal of Intelligent Systems*, 1(2), pp. 82–90.

Hassan, A. dan Dampier, R. I. (2010) 'Multi-Class dan Hierarchical SVMs for Emotion Recognition', in *International Speech Communication Association*. Chiba.

Hassan, R. R. B. A. (2015) *EEG Signal Classification for Wheelchair Control Application*. Universiti Tun Hussein Malaysia.

Hede, S. C. (2010) *Signal Detection in EEG Brainwaves - A Classification Based Approach*. Technical University of Denmark.

Heyden, M. (2016) *Classification of EEG Data Using Machine Learning Techniques*. Lund University.

Hill, N. J. *et al.* (2012) 'Recording Human Electroencephalographic (EEG) Signals for Neuroscientific Research dan Real-time Functional Cortical Mapping', *Journal of Visualized Experiments*, 11(64), pp. 199–203.



Hill, N. J. *et al.* (2014) 'A Practical, Intuitive Brain-Computer Interface for Communicating "Yes" or "No" by Listening', *Journal of Neural Engineering*, 11(3).

How It Works Team (2016) *How Stephen Hawking's Wheelchair Works*, *How It Works Magazine*. Available at: <https://www.howitworksdaily.com/how-stephen-hawkings-wheelchair-works/> (Accessed: 4 June 2018).

Hsu, C.-W., Chang, C.-C. dan Lin, C.-J. (2008) 'A Practical Guide to Support Vector Classification', *BJU international*, 101(1), pp. 1396–400.

Hsu, C.-W. dan Lin, C.-J. (2002) 'Errata to "A Comparison of Methods for Multiclass Support Vector Machines"', *IEEE Transactions on Neural Networks*, 13(4), p. 1026.

Hsu, W.-Y. (2015) 'Motor Imagery EEG Discrimination Using the Correlation of Wavelet Features', *Clinical EEG dan Neuroscience*, 46(2), pp. 94–99.

Hsu, W. Y. dan Sun, Y. N. (2009) 'EEG-Based Motor Imagery Analysis Using Weighted Wavelet Transform Features', *Journal of Neuroscience Methods*, 176(2), pp. 310–318.

Huang, D. (2012) *Electroencephalography (EEG)-Based Brain Computer Interfaces for Rehabilitation*. Virginia Commonwealth University.

Huang, P. X. dan Fisher, R. B. (2014) 'Individual Feature Selection in Each One-versus-One Classifier Improves Multi-class SVM Performance', in *the International Conference on Pattern Recognition*. Stockholm.

Ireland, K. H. (2010) *Can The Auditory Late Response Indicate Audibility of Speech Sounds from Hearing Aids with Different Digital Processing Strategies*. University of Southampton.



Izzuddin, T. A. *et al.* (2015) 'Movement Intention Detection Using Neural Network for Quadriplegic Assistive Machine', in *Proceedings - 5th IEEE International Conference on Control System, Computing dan Engineering, ICCSCE 2015*. Penang, pp. 275–280.

Jamal, W. *et al.* (2014) 'Classification of Autism Spectrum Disorder Using Supervised Learning of Brain Connectivity Measures Extracted from Synchrostates', *Journal of Neural Engineering*, 11(4).

Jamil, F. *et al.* (2018) 'Kernel Approaches for Fault Detection dan Classification in PARR-2', *Journal of Process Control*. Elsevier Ltd, 64, pp. 1–6.

Jiao, Z. *et al.* (2018) 'A Path Planning Method Using Adaptive Polymorphic Ant Colony Algorithm for Smart Wheelchairs', *Journal of Computational Science*. Elsevier B.V., 25, pp. 50–57.

Jing Fan *et al.* (2015) 'A Step towards EEG-Based Brain Computer Interface for Autism Intervention', in *2015 37th Annual International Conference of the IEEE Engineering in Medicine dan Biology Society (EMBC)*, IEEE, pp. 3767–3770.

Kalagi, S. *et al.* (2017) 'Brain Computer Interface Systems Using Non-Invasive Electroencephalogram Signal: A literature Review', in *ICE/ITMC*, pp. 1578–1583.

Karam, J. *et al.* (2016) 'Neural Network for Recognition of Brain Wave Signals', *International Journal of Enhanced Research in Science, Technology & Engineering*, 5(10), pp. 36–42.

Karimoi, R. Y. *et al.* (2014) 'EEG Signal Classification Using Bayes dan Naïve Bayes Classifiers dan Extracted Features of Continuous Wavelet



Transform', *Majlesi Journal of Multimedia Processing*, 3(1), pp. 1–7.

Kato, K. *et al.* (2018) 'Online Detection of Amplitude Modulation of Motor-Related EEG Desynchronization Using A Lock-in Amplifier: Comparison with A Fast Fourier Transform, A Continuous Wavelet Transform, dan An Autoregressive Algorithm', *Journal of Neuroscience Methods*. Elsevier B.V., 293, pp. 289–298.

Kawai, E. *et al.* (2008) 'Skin Surface Electric Potential as An Indicator of Skin Condition: A New, Non-Invasive Method to Evaluate Epidermal Condition', *Experimental Dermatology*, 17(8), pp. 688–692.

Kevric, J. dan Subasi, A. (2017) 'Comparison of Signal Decomposition Methods in Classification of EEG Signals for Motor-Imagery BCI System', *Biomedical Signal Processing dan Control*. Elsevier Ltd, 31, pp. 398–406.

Kołodziej, M., Majkowski, A. dan Remigiusz, J. (2012) 'Linear Discriminant Analysis as EEG Features Reduction Technique for Brain-Computer Interfaces', *Przegląd Elektrotechniczny*, (3), pp. 28–30.

Kraus, L. (2017) *2016 Disability Statistics Annual Report*. Durham, NH.

Krell, M. M. (2015) *Generalizing , Decoding , dan Optimizing Support Vector Machine Classification*. Universitas Bremen.

Krishnan, S. dan Athavale, Y. (2018) 'Trends in biomedical signal feature extraction', *Biomedical Signal Processing dan Control*. Elsevier Ltd, 43, pp. 41–63.

Kumari, M. dan Somani, S. B. (2015) 'Enhancing the Classification Accuracy of SSVEP Based BCI Using CWT Method Along with ANN', *International Journal of Advanced Research in Engineering dan Management*, 01(01),



pp. 81–89.

Kundu, A. S. *et al.* (2017) ‘Omnidirectional Assistive Wheelchair: Design dan Control with Isometric Myoelectric Based Intention Classification’, *Procedia Computer Science*. The Author(s), 105(Iris 2016), pp. 68–74.

Larsen, E. A. dan Wang, A. I. (2011) *Classification of EEG Signals in a Brain-Computer Interface System, Norwegian University of Science dan Technology*. Norwegian University of Science dan Technology.

Lawman, S. J. (2011) *Optical dan Material Properties of Varnishes for Paintings*. Nottingham Trent University.

Leishman, F., Horn, O. dan Bourhis, G. (2010) ‘Smart Wheelchair Control Through a Deictic Approach’, *Robotics dan Autonomous Systems*. Elsevier B.V., 58(10), pp. 1149–1158.

Liu, C., Yang, Y. dan Tang, C. (2010) ‘An Improved Method for Multi-class Support Vector Machines’, in *Measuring Technology dan Mechatronics Automation*. IEEE, pp. 504–508.

Liu, L., Shen, B. dan Wang, X. (2014) ‘Research on Kernel Function of Support Vector Machine’, *Journal of Computers*, 25(1), pp. 1–6.

Lopez-Gordo, M. A., Sanchez-Morillo, D. dan Pelayo Valle, F. (2014) ‘Dry EEG electrodes’, *Sensors (Basel, Switzerland)*, pp. 12847–12870.

Lu, F. *et al.* (2018) ‘Review of Stratum Corneum Impedance Measurement in Non-Invasive Penetration Application’, *Biosensors*, 8(2).

Ma, X. dan Liu, Z. (2018) ‘The Kernel-Based Nonlinear Multivariate Grey Model’, *Applied Mathematical Modelling*. Elsevier Inc., 56, pp. 217–238.

Machado, J. dan Balbinot, A. (2014) ‘Executed Movement Using EEG Signals



through a Naïve Bayes Classifier’, pp. 1082–1105.

Machangpa, J. W. dan Chingtham, T. S. (2018) ‘Head Gesture Controlled Wheelchair for Quadriplegic Patients’, *Procedia Computer Science*.

Elsevier B.V., 132(Iccids), pp. 342–351.

Mallat, S. (2009) *A Wavelet Tour of Signal Processing*. Burlington: Elsevier.

Maly, L. (2015) *Wheelchair Control Using EEG Signal Classification*. Brno University of Technology.

Masso, M. (2016) *Empirical Comparison of Machine Learning Algorithms Based on EEG Data*. University of Tartu.

McFarland, D. J. *et al.* (1997) ‘Spatial Filter Selection for EEG-Based Communication’, *Electroencephalography dan Clinical Neurophysiology*, 103(3), pp. 386–394.

McFarland, D. J. dan Wolpaw, J. R. (2017) ‘EEG-Based Brain–Computer Interfaces’, *Current Opinion in Biomedical Engineering*. Elsevier Ltd, 4, pp. 194–200.

Mihajlović, V., Garcia-Molina, G. dan Peuscher, J. (2013) ‘Dry dan Water-Based EEG Electrodes in SSVEP-Based BCI Applications’, *Communications in Computer dan Information Science*, 357 CCIS, pp. 23–40.

Milgram, J. *et al.* (2006) ‘“ One Against One ” or “ One Against All ”: Which One is Better for Handwriting Recognition with SVMs ?’, in *Tenth International Workshop on Frontiers in Handwriting Recognition*. La Baule.

Millán, J. D. R. *et al.* (2010) ‘Combining Brain-Computer Interfaces dan Assistive Technologies: State-of-The-Art dan Challenges’, *Frontiers in*



Neuroscience, 4(SEP), pp. 1–15.

Mirvaziri, H. dan Mobarakeh, Z. S. (2017) 'Improvement of EEG-Based Motor Imagery Classification Using Ring Topology-Based Particle Swarm Optimization', *Biomedical Signal Processing dan Control*. Elsevier Ltd, 32, pp. 69–75.

Müller-Putz, G. R. (2011) 'Tools for Brain-Computer Interaction: A General Concept for A Hybrid BCI', *Frontiers in Neuroinformatics*, 5(November), pp. 1–10.

Neurosky (2009) *Brain Wave Signal (EEG) of Neurosky, Inc.* San Jose: Neurosky.

Neurosky (2010) 'TGAM1 Spec Sheet'. San Jose: Neurosky, pp. 1–10.

Neurosky (2011) *Neurosky Store*. Available at: store.neurosky.com (Accessed: 1 January 2016).

Nicolas-Alonso, L. F. dan Gomez-Gil, J. (2012) 'Brain Computer Interfaces, A Review', *Sensors*, 12(2), pp. 1211–1279.

Nunez, P. L. dan Srinivasan, R. (2006) *Electric Fields of the Brain*. New York: Oxford University Press.

Nurhanna, A. A. dan Othman, M. F. (2017) 'Multi-class Support Vector Machine Application in the Field of Agriculture dan Poultry: A Review', *Malaysian Journal of Mathematical Sciences*, 11(S), pp. 35–52.

Oosugi, N. *et al.* (2017) 'A New Method for Quantifying the Performance of EEG Blind Source Separation Algorithms by Referencing a Simultaneously Recorded ECoG Signal', *Neural Networks*. Elsevier Ltd, 93, pp. 1–6.

Padierna, L. C. *et al.* (2018) 'A Novel Formulation of Orthogonal Polynomial Kernel Functions for SVM Classifiers: The Gegenbauer Family', *Pattern*



Recognition, 84, pp. 211–225.

Pal, M. dan Bandyopadhyay, S. (2016) 'Many-Objective Feature Selection for Motor Imagery EEG Signals Using Differential Evolution dan Support Vector Machine', in *IEEE International Conference on Microelectronics, Computing dan Communications (MicroCom)*. Durgapur: IEEE.

Pash, C. (2018) *Scientists Recall Stories of How They Crashed into Stephen Hawking's Wheelchair*, *Business Insider*. Available at: <http://www.businessinsider.com/stephen-hawkings-wheelchair-crash-story> (Accessed: 4 June 2018).

Patnaik, P. K. dan Sarraf, J. (2018) 'Brain Computer Interface Issues on Hand Movement', *Journal of King Saud University - Computer dan Information Sciences*. King Saud University, pp. 18–24.

Pedrosa, P. *et al.* (2016) 'Ag.TiN-Coated Polyurethane for Dry Biopotential Electrodes: From Polymer Plasma Interface Activation to the First EEG Measurements', *Plasma Processes dan Polymers*, 13(3), pp. 341–354.

Pereira, D. G., Afonso, A. dan Medeiros, F. M. (2015) 'Overview of Friedmans Test dan Post-hoc Analysis', *Communications in Statistics: Simulation dan Computation*, 44(10), pp. 2636–2653.

Permana, R. A. (2016) 'Seleksi Atribut Pada Metode Support Vector Machine Untuk Menentukan Kelulusan E-Learning', *Evolusi-Lppm3.bsi.ac.id*, 4(2015), pp. 8–14.

Pfurtscheller, G. dan Neuper, C. (2006) 'Future Prospects of ERD/ERS in The Context of Brain-computer Interface (BCI) Developments', *Progress in Brain Research*, 159, pp. 433–437.



Platt, J. (1998) *Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines*. Redmond.

Porkka, P., Jussila, J. dan Suominen, A. (2008) *Using Friedman Test for Creating Comparable Group Results of Nonparametric Innovation Competence Data - 2 Specific Features of Nonnumeric dan Nonparametric Data*. Tampere.

Pu, J. *et al.* (2018) 'Low Cost Sensor Network for Obstacle Avoidance in Share-Controlled Smart Wheelchairs Under Daily Scenarios', *Microelectronics Reliability*. Elsevier, 83(March), pp. 180–186.

Qiu, S. (2018) *Support Vector Machine dan Application in Seizure Prediction*. King Abdullah University of Science dan Technology.

Quitadamo, L. R. *et al.* (2017) 'Support Vector Machines to Detect Physiological Patterns for EEG dan EMG-based Human-Computer Interaction: A Review', *Journal of Neural Engineering*, 14(1), pp. 1–35.

Rabhi, Y., Mrabet, M. dan Fnaiech, F. (2018) 'A Facial Expression Controlled Wheelchair for People with Disabilities', *Computer Methods dan Programs in Biomedicine*. Elsevier B.V., 165, pp. 89–105.

Rahul, Y., Sharma, R. K. dan Paul, N. (2017) 'A Review on EEG Control Smart Wheelchair', *IJARCS*, 8(9), pp. 501–507.

Raju, V. N., Ra, I. H. dan Sankar, R. (2015) 'A P300-Based BCI Classification Algorithm Using Least Square Support Vector Machine', *International Journal of Software Engineering dan its Applications*, 9(5), pp. 247–254.

Rak, R. J., Majkowski, A. dan Kołodziej, M. (2012) 'Linear Discriminant Analysis as EEG Features Reduction Technique for Brain-Computer



Interfaces', *Przegląd Elektrotechniczny*, 88(3), pp. 28–30.

Rakshit, A., Khasnobish, A. dan Tibarewala, D. N. (2016) 'A Naïve Bayesian Approach to Lower Limb Classification from EEG Signals', in *2016 2nd International Conference on Control, Instrumentation, Energy dan Communication, CIEC 2016*. Kolkata: IEEE, pp. 140–144.

Ramadan, R. A. dan Vasilakos, A. V. (2017) 'Brain Computer Interface: Control Signals Review', *Neurocomputing*. Elsevier, 223, pp. 26–44.

Ramos, A. C. (2017) *Multiple Classifier System for Motor Imagery Task Classification*. Pontificia Universidade Catolica Do Rio De Janeiro.

Rashed-Al-Mahfuz, M. *et al.* (2013) 'Artifact Suppression dan Analysis of Brain Activities With Electroencephalography Signals', *Neural Regeneration Research*, 8(16), pp. 1500–1513.

Rebsamen, B. (2008) *A Brain Controlled Wheelchair To Navigate in Familiar Environments*. National University of Singapore.

Rechy-Ramirez, E. J. dan Hu, H. (2015) 'Bio-Signal Based Control in Assistive Robots: A Survey', *Digital Communications dan Networks*. Elsevier, 1(2), pp. 85–101.

Renukadevi, N. T. dan Thangaraj, P. (2013) 'Performance Evaluation of SVM – RBF Kernel for Classifying ECoG Motor Imagery', *Global Journal of Computer Science dan Technology Graphics & Vision*, 13(4).

Robbins, R. *et al.* (2014) *Investigating the NeuroSky MindWave™ EEG Headset*. Berkshire.

Ruiz-Serrano, A. *et al.* (2013) 'Development of a Dual Control System Applied to a Smart Wheelchair, using Magnetic dan Speech Control', *Procedia*



Technology. Elsevier B.V., 7, pp. 158–165.

Ruiz, L. O. (2011) *Sistema De Control Intrpretando la Actividad Bioelectrica De Las Señales Cerebrales Usando Una Interfaz BCI*. Universidad Autonoma de Occidente.

Salabun, W. (2014) ‘Processing dan spectral analysis of the raw EEG signal from the MindWave’, *West Pomeranian University of Technology*, (2), pp. 169–173.

Sanei, S. dan Chambers, J. A. (2007) *EEG Signal Processing, Chemistry & biodiversity*. New York: John Wiley & Sons, Ltd.

Santoso, S. (2014) *Statistik Nonparametrik*. Jakarta: PT Elex Media Komputindo.

Saranya, P. K., Samundeeswari, E. S. dan Manavalan, R. (2016) ‘Optimizing the Parameters of SVM with RBF Kernel for Classifying Breast Tumors in Ultrasound Images’, *IOSR-JCE*, 18(6), pp. 60–65.

Seeck, M. *et al.* (2017) ‘The Standardized EEG Electrode Array of the IFCN’, *Clinical Neurophysiology*, 128(10), pp. 2070–2077.

Sellers, E. W. *et al.* (2009) ‘A Novel Dry Electrode for Brain-Computer Interface’, in Kurosu, M. (ed.). Berlin, Heidelberg: Springer Berlin Heidelberg (Lecture Notes in Computer Science), pp. 623–631.

Sembiring, K. (2007) *Penerapan Teknik Support Vector Machine untuk Pendeteksian Intrusi pada Jaringan*. Bandung: Teknik Elektro dan Informatika Institut Teknologi Bandung.

Simões, M. (2011) *A Virtual Reality Application with a Brain-Computer Interface for Rehabilitation of Social Development in Autism*. Universidade De Coimbra.



Siswoyo, A., Arief, Z. dan Sulistijono, I. A. (2017) 'Application of Artificial Neural Networks in Modeling Direction Wheelchairs Using Neurosky Mindset Mobile (EEG) Device', *EMITTER International Journal of Engineering Technology*, 5(1), pp. 170–191.

Siuly (2012) *Analysis dan Classification of EEG Signals*. University of Southern Queensland.

Škraba, A. *et al.* (2015) 'Speech-Controlled Cloud-Based Wheelchair Platform for Disabled Persons', *Microprocessors dan Microsystems*, 39(8), pp. 819–828.

Soman, S. dan Jayadeva (2015) 'High Performance EEG Signal Classification Using Classifiability dan The Twin SVM', *Applied Soft Computing Journal*. Elsevier B.V., 30, pp. 305–318.

De Souza, E. S. dan Lamounier, E. E. L. (2017) *A Virtual Environment-based Training System for the Blind Wheelchair User through use of 3D Audio Supported by EEG A Virtual Environment-based Training System for the Blind Wheelchair User through use of 3D Audio Supported by EEG*, *PeerJ*. Uberlândia.

Spüler, M. (2017) 'A High-Speed Brain-Computer Interface (BCI) Using Dry EEG Electrodes', *PLoS ONE*, 12(2), pp. 1–12.

Tatum, W. *et al.* (2008) *Handbook of EEG Interpretation, Medicine*. New York: Demos.

Teplan, M. (2002) 'Fundamentals of EEG measurement', *Measurement Science Review*, 2(2), pp. 1–11.

Thomas, E., Fruitet, J. dan Clerc, M. (2013) 'Combining ERD dan ERS Features



to Create a System-Paced BCI', *Journal of Neuroscience Methods*. Elsevier B.V., 216(2), pp. 96–103.

Tian, X. (2012) *Apprentissage et Noyau pour les Interfaces Cerveau-machine*.

l'Institut National des Sciences Appliquées de Rouen.

Tiwari, N. *et al.* (2018) 'Brain Computer Interface: A Comprehensive Survey', *Biologically Inspired Cognitive Architectures*, (October).

Torse, D., Desai, V. dan Khanai, R. (2018) 'Classification of EEG Signals in a Seizure Detection System Using Dual Tree Complex Wavelet Transform dan Least Squares Support Vector Machine', *International Journal of Image, Graphics dan Signal Processing*, 10(1), pp. 56–64.

Tyagi, A., Semwal, S. dan Shah, G. (2012) 'A Review of Eeg Sensors Used for Data Acquisition', in *Ncfaiia*. Uttarakhand: International Journal of Computer Applications® (IJCA) A, pp. 13–18.

Uyanto, S. S. (2009) *Pedoman Analisis Data dengan SPSS*. III. Yogyakarta: Graha Ilmu.

Vaque, T. J. La (1999) 'The History of EEG Hans Berger: Psychophysicologist. A Historical Vignette', *Journal of Neurotherapy*, 3(2), pp. 21–27.

Voznenko, T. I., Chepin, E. V. dan Urvanov, G. A. (2018) 'The Control System Based on Extended BCI for A Robotic Wheelchair', in *Procedia Computer Science*. Moscow: Elsevier B.V., pp. 522–527.

Wang, X. dan Guo, J. (2013) 'An Algorithm for Parallelizing Sequential Minimal Optimization', in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence dan Lecture Notes in Bioinformatics)*, pp. 657–664.



Wang, Y. *et al.* (2012) 'Adaptive Estimation of EEG for Subject-Specific Reactive Band Identification dan Improved ERD Detection', *Neuroscience Letters*. Elsevier Ireland Ltd, 528(2), pp. 137–142.

Wang, Y. dan Jung, T. P. (2011) 'A Collaborative Brain-Computer Interface for Improving Human Performance', *PLoS ONE*, 6(5).

Wang, Y., Veluvolu, K. C. dan Lee, M. (2013) 'Time-frequency Analysis of Band-limited EEG with BMFLC dan Kalman Filter for BCI Applications', *Journal of NeuroEngineering dan Rehabilitation*, 10(1), pp. 1–16.

White, S. (2000) *Digital Signal Processing*. Clifton Park: Delmar Cengage Learning.

Widodo, P. P., Handayanto, R. T. dan Herlawati (2013) *Penerapan Data Mining dengan MATLAB*. Bandung: Rekayasa Sains.

Wolpaw, J. dan Wolpaw, E. W. (2012) *Brain-Computer Interfaces: Principles dan Practice*. New York: Oxford University Press.

Xing, X. *et al.* (2018) 'A High-Speed SSVEP-Based BCI Using Dry EEG Electrodes', *Scientific Reports*, 8(1), p. 14708.

Xu, J. *et al.* (2017) 'Multi-Class Support Vector Machine via Maximizing Multi-Class Margins', in *The Twenty-Sixth International Joint Conference on Artificial Intelligence*. Melbourne, pp. 3154–3160.

Yao, D. *et al.* (2005) 'A Comparative Study of Different References for EEG Spectral Mapping: The Issue of The Neutral Reference dan The Use of The Infinity Reference', *Physiological Measurement*, 26(3), pp. 173–184.

Yin, S. dan Yin, J. (2016) 'Tuning Kernel Parameters for SVM Based on Expected Square Distance Ratio', *Information Sciences*. Elsevier Inc.,



370–371, pp. 92–102.

Yu, H. *et al.* (2012) ‘An Efficient Method for Learning Nonlinear Ranking SVM Functions’, *Information Sciences*. Elsevier Inc., 209, pp. 37–48.

Zarei, R. *et al.* (2017) ‘A PCA Aided Cross-Covariance Scheme for Discriminative Feature Extraction from EEG Signals’, *Computer Methods dan Programs in Biomedicine*. Elsevier Ireland Ltd, 146, pp. 47–57.

Zhou, S. S., Liu, H. W. dan Ye, F. (2009) ‘Variant of Gaussian Kernel dan Parameter Setting Method for Nonlinear SVM’, *Neurocomputing*. Elsevier, 72(13–15), pp. 2931–2937.

Zimmerman, D. W. dan Zumbo, B. D. (1993) ‘Relative Power of the Wilcoxon test, the Friedman test, dan Repeated-measures ANOVA on Ranks’, *Journal of Experimental Education*, 62(1), pp. 75–86.

