




TESIS - TE142599

**Pengenalan Emosi pada Manula Berbasis
Sinyal SpO_2 dan Pulse Rate Menggunakan
Metode *SUPPORT VECTOR MACHINE***

LUTFI HAKIM
07111650060001

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

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





TESIS - TE142599

**PENGENALAN EMOSI PADA MANULA BERBASIS
SINYAL SpO_2 DAN PULSE RATE MENGGUNAKAN
METODE *SUPPORT VECTOR MACHINE***

LUTFI HAKIM
07111650060001

DOSEN PEMBIMBING

Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.

Dr. Adhi Dharma Wibawa, S.T., M.T.

PROGRAM MAGISTER

BIDANG KEAHLIAN TELEMATIKA


DEPARTEMEN TEKNIK ELEKTRO

FAKULTAS TEKNOLOGI ELEKTRO

INSTITUT TEKNOLOGI SEPULUH NOPEMBER

SURABAYA

2018



LEMBAR PENGESAHAN

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

oleh:

Lutfi Hakim
NRP. 07111650060001

Tanggal Ujian : 06 Juli 2018
Periode Wisuda : September 2018

Disetujui oleh:

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

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


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

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

5. Dr. Istas Pratomo, ST. MT. (Penguji)
NIP: 197903252003121001

Dekan Fakultas Teknologi Elektro

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




Halaman ini sengaja dikosongkan

PERNYATAAN KEASLIAN TESIS

Dengan ini saya menyatakan bahwa isi keseluruhan Tesis saya dengan judul “**PENGENALAN EMOSI PADA MANULA BERBASIS SINYAL SPO₂ DAN PULSE RATE MENGGUNAKAN METODE *SUPPORT VECTOR MACHINE***” adalah benar-benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diijinkan dan bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri.

Semua referensi yang dikutip maupun dirujuk telah ditulis secara lengkap pada daftar pustaka. Apabila ternyata pernyataan ini tidak benar, saya bersedia menerima sanksi sesuai peraturan yang berlaku.

Surabaya, 1 Juli 2018



Lutfi Hakim

NRP. 07111650060001

Halaman ini sengaja dikosongkan

PENGENALAN EMOSI PADA MANULA BERBASIS SINYAL SPO₂ DAN PULSE RATE MENGGUNAKAN METODE SUPPORT VECTOR MACHINE

Nama mahasiswa : Lutfi Hakim
NRP : 07111650060001
Pembimbing : 1. Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.
2. Dr. Adhi Dharma Wibawa, S.T., M.T.

ABSTRAK

Pengenalan emosi berbasiskan pada sinyal fisiologi menjadi isu penting untuk dikaji dikalangan para peneliti dalam dekade ini. Salah satu alasannya adalah banyak penelitian yang membuktikan bahwa kondisi emosi, terutama pada Manula, mempengaruhi kondisi fisik secara signifikan. Meskipun demikian, masih sangat sedikit penelitian yang membahas dan mengeksplorasi pengenalan emosi berbasiskan pada sinyal SpO₂ dan Pulse rate (PR).

Penelitian ini mengusulkan sebuah sistem untuk mengenali tiga emosi dasar pada Manula, seperti Senang, Sedih dan Marah yang berdasarkan kedua jenis sinyal fisiologi tersebut. Metode segmentasi *window size* digunakan untuk mengekstraksi kedua sinyal fisiologi tersebut yang dibagi menjadi per 15 detik *window size*. Selanjutnya, metode ekstraksi fitur statistik digunakan untuk mendapatkan fitur-fitur dari sinyal SpO₂ dan PR. Metode Support Vector Machine (SVM) dengan pemilihan parameter C dan λ terbaik dan kNN dengan memilih K optimal dari hasil klasifikasi sebagai perbandingan digunakan untuk mengklasifikasikan fitur-fitur yang telah diekstraksi dan diuji kedalam beberapa skenario, diantaranya klasifikasi menggunakan fitur kombinasi SpO₂ dan PR, klasifikasi hanya fitur SpO₂ dan PR.

Berdasarkan pada hasil eksperimen, didapatkan bahwa metode SVM dapat mengenali emosi lebih baik dibandingkan kNN dengan nilai akurasi terbaik 72,775%, dengan presisi 70,50% dan skor F1 69,60%. Selain itu, kombinasi fitur dari kedua sinyal fisiologi dalam meningkatkan nilai akurasi lebih dari 4,00% baik pada SVM dan kNN dibandingkan dengan klasifikasi menggunakan single sinyal fisiologi. Hasil ini menyediakan informasi bahwa pengenalan emosi berdasarkan sinyal SpO₂ dan PR yang dapat dideteksi lebih baik dengan menggunakan kombinasi kedua fitur sinyal tersebut. Lebih jauh, memilih parameter C dan λ pada SVM dan nilai K pada kNN untuk mendapatkan hasil klasifikasi yang optimal dapat diimplementasikan untuk mendapatkan hasil klasifikasi yang lebih baik.

Kata kunci: Pengenalan emosi manusia, klasifikasi sinyal fisiologi, sensor pulse oximeter, Efek stimulasi video, *k-Nearest Neighbors*.

Halaman ini sengaja dikosongkan

EMOTION RECOGNITION IN ELDERLY BASED ON SpO_2 AND PULSE RATE SIGNALS USING SUPPORT VECTOR MACHINE METHOD

By : Lutfi Hakim
Student Identity Number : 07111650060001
Supervisor(s) : 1. Prof. Dr. Ir. Mauridhi H. Purnomo, M.Eng.
2. Dr. Adhi Dharma Wibawa, S.T., M.T.


ABSTRACT

Emotion recognition based on physiological signal has become an important issue among researchers nowadays. It is because many studies have proven that emotion condition, especially in elderly, has influenced the physical condition significantly. Nevertheless, there is still few studies which discusses and explores emotion recognition based on SpO_2 and Pulse Rate (PR) signals.

This research proposed emotion recognition of three basic emotion of elders, such as happy, sad and angry based on those physiological signals. Window size segmentation method was used to extract of both physiological signals reduced to 15 seconds lenght. Then, statistical feature extraction method was used to obtain the features of SpO_2 and PR signals. Support Vector Machine (SVM) with selecting of the best C and λ parameters and choosing of the optimal K parameter of k-Nearest Neighbors (kNN) method as a comparison were used to classify the extracted features which were tested in several scenarios. There were classification using SpO_2 -PR, SpO_2 and PR features.

According to work, SVM method achieved the best accuracy (72,775%), with precision 70,50% and F1 score 69,60% compared to kNN. Furthermore, combining of the features of both physiological signals could improve the accuracy more than 4,0% both SVM and kNN methods compared to the single physiological signal. This result provides information of emotions in term of SpO_2 dan PR signals which can be better detected by combining the features of physiological signals. Also, the selected SVM of the best C and λ parameters and optimal K value of kNN can implement to achieve a better classification result.

Keywords: Human emotion recognition, Classification of an affective physiological signal, Pulse oximetry sensor, Video stimulation effect, k-Nearest Neighbors.



Halaman ini sengaja dikosongkan

KATA PENGANTAR

Alhamdulillah, kalimat pertama yang terucapkan sebagai ungkapan syukur atas segala kenikmatan, kerahmatan dan kasih sayang yang telah dianugerahkan oleh Allah SWT kepada penulis sehingga pengerjaan tesis ini dengan judul “Pengenalan Emosi pada Manula Berbasis Sinyal SpO₂ dan Pulse Rate Menggunakan Metode *Support Vector Machine*” dapat diselesaikan. Penulisan buku tesis ini sebagai syarat dalam rangka menyelesaikan studi magister di Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember.

Selanjutnya, penulis ingin menyampaikan cerita dimana waktu pemilihan tema ini diluar perkiraan awal pada saat pertama kali memutuskan untuk melanjutkan studi magister di ITS. Namun, salah satu supervisor saya mengenalkan bidang kajian yang terbilang baru ini kepada penulis sebagai pilihan topik penelitian. Awalnya penulis terkesan pesimistis karena bidang ini bisa dikatakan bidang yang masih baru dan menjadi trending topik di satu dekade terakhir ini. Namun dengan keputusan pengambilan tema ini untuk penelitian tesis, penulis pada akhirnya merasa jatuh cinta dengan tema riset di bidang ini yakni *affective computing, machine learning, sistem biometrika* dan sejenisnya. Penulis berupaya untuk dapat mengembangkan khasanah keilmuan dan menekuni lebih dalam di bidang ini sehingga dapat berkontribusi di dunia akademisi khususnya riset di bidang ini.

Penulis juga menyadari bahwa tanpa bantuan, bimbingan, saran serta semangat dari berbagai pihak, penulis tidak dapat menyelesaikan tesis ini dengan baik. Untuk itu, penulis ingin mengucapkan rasa terima kasih yang amat sangat besar kepada:

1. Kedua orang tua tercinta, Bapak Faisol dan Ibu Istiqomah yang tak pernah lupa dan lelah untuk memberikan semangat, doa dan dukungan dalam setiap langkah baik dalam karir, studi maupun dalam menyelesaikan tesis ini. Tak lupa juga kepada adik-adik tercinta, Dewi Iripina dan Fitri Yupita.

2. Pendorong mood penulis yakni istri tercinta, Yuniarta Syarifatul Umami, atas kasih sayang dan cinta, semangat, dukungan yang diberikan serta apapun yang tak bisa disebutkan satu persatu. Khususnya juga dengan sabar menemani dan membantu penulis dalam mengambil data penelitian.
3. Lembaga Pengelola Dana Pendidikan (LPDP) atas beasiswa full yang telah diberikan. Sebuah amanah yang besar diberikan kesempatan untuk menempuh studi magister dengan beasiswa LPDP (beasiswa terlengkap hingga saat ini, bukan hanya memberikan full beasiswa, tapi juga konektifitas dengan orang-orang hebat seluruh Indonesia).
4. Bapak Dr. Tri Arief Sarjono, S.T., M.T. selaku Dekan Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember.
5. Bapak Dr. Eng. Ardyono Priyadi, ST., M.Eng. selaku Kepala Departemen Teknik Elektro FTE – ITS.
6. Bapak Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng. selaku supervisor pertama yang selalu sabar membimbing, memberikan semangat, saran dan masukan dalam ranah akademis maupun nonakademis.
7. Bapak Dr. Adhi Dharma Wibawa, S.T., M.T. selaku supervisor kedua sekaligus koordinator bidang program magister telematika, Departemen Teknik Elektro, FTE, ITS yang selalu sabar dalam membimbing, dukungan moril, memberikan semangat dan ilmu yang tak bisa tergambarkan, terutama membimbing langsung dalam teknik penulisan dan juga memperkenalkan tema riset ini, sehingga penulis terdorong untuk mengembangkan kemampuan riset di bidang ini.
8. Seluruh dosen program magister program Telematika, Departemen Teknik Elektro FTE - ITS yang telah memberikan ilmunya kepada penulis selama menjalani studi program magister.
9. Kawan-kawan Telematika dan Petik, diantaranya mbak Alfi, Mas Allan, Mas Andi Setiawan, Mas Andi Akmal, Pak Lukluk, Pak Syamsul, Mas Alfin, Mbak Ika, Mbak Rohmah, Mbak Fahima, Mas Dhanu, Mas Atyanta dan Putri. Terkhusus untuk mbak Alfi, Mas Allan dan Mas Andi Setiawan yang menjadi teman sharing dalam menyelesaikan tesis ini. Juga kepada

Mas Atyanta yang telah berbagi banyak ilmu kepada penulis yang masih fakir ini.

10. Teman-teman dan rekan-rekan Pengayaan Bahasa LPDP ITS 2016, LPDP ITS, LPDP East Java, PK-78 LPDP Mentari Sadajiwa, Mata Garuda Jawa Timur. Terutama kepada rekan-rekan LPDP ITS yang telah memberikan amanah kepada penulis sebagai koordinator.
11. Mahasiswa Doktoral, Bu evi, Bu Yuhana, dan Bu Diana yang telah membantu dan berbagi ilmu kepada penulis.
12. Serta pihak-pihak yang tak bisa disebutkan satu persatu.

Besar harapan bagi penulis bahwa buku tesis ini dapat memberikan informasi dan manfaat kepada semua pembaca khususnya Mahasiswa Fakultas Teknologi Elektro.

Surabaya, 1 Juli 2018

Penulis,
Lutfi Hakim

Halaman ini sengaja dikosongkan

DAFTAR ISI

LEMBAR PENGESAHAN	iii
PERNYATAAN KEASLIAN TESIS	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xv
DAFTAR GAMBAR	xix
DAFTAR TABEL	xxi
DAFTAR NOMENKLATUR	xxiii
 BAB 1 PENDAHULUAN	 1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan	4
1.4 Batasan Masalah	5
1.5 Kontribusi	6
1.6 Metodologi Penelitian	6
BAB 2 KAJIAN PUSTAKA	9
2.1 Kajian Penelitian Terkait	9
2.2 Teori Dasar	10
2.2.1 Emosi Manusia	10
2.2.2 Hubungan Emosi, Aktivitas Fisiologis dan Kesehatan	13
2.2.3 Sinyal SpO ₂ dan Pulse Rate	15
2.2.4 Manula atau Lanjut Usia	21
2.2.5 Metode Stimuli dan Assesmen Emosi	23
2.2.6 Ekstraksi Fitur Sinyal SpO ₂ dan Pulse Rate	25
2.2.7 <i>Support Vector Machine</i>	27
2.2.8 K-Nearest Neighbors	36
2.2.9 <i>K-fold Cross Validation</i>	38

2.2.10	Evaluasi Performansi Metode Klasifikasi	39
BAB 3 METODOLOGI PENELITIAN		41
3.1	Tahap Awal	41
3.1.1	Studi Literatur	41
3.1.2	Eksplorasi Hardware	42
3.1.3	Pemilihan Subjek Penelitian	47
3.2	Pengumpulan Data	48
3.2.1	Pengambilan Data	48
3.2.2	Pre-processing Data Raw	51
3.3	Pengolahan Data Penelitian	52
3.3.1	Ekstraksi Fitur	52
3.3.2	Pelabelan Dataset	54
3.3.3	Klasifikasi Menggunakan SVM dan kNN	54
3.4	Tahap Akhir	58
3.4.1	Evaluasi Performansi Metode Klasifikasi	58
BAB 4 HASIL DAN PEMBAHASAN		61
4.1	Hasil Pengambilan dan Pre-processing Data Raw	61
4.2	Tipikal Data	63
4.3	Ekstraksi Fitur	65
4.4	Klasifikasi Dataset dengan SVM	67
4.4.1	Klasifikasi hanya dengan Fitur Sinyal SpO ₂	68
4.4.2	Klasifikasi dengan Fitur Sinyal Pulse Rate	69
4.4.3	Klasifikasi dengan Kombinasi Fitur dari Sinyal SpO ₂ dan Pulse Rate	70
4.5	Klasifikasi Dataset dengan kNN	71
4.5.1	Klasifikasi dengan Fitur Sinyal SpO ₂	72
4.5.2	Klasifikasi dengan Fitur Sinyal Pulse Rate	73
4.5.3	Klasifikasi dengan Kombinasi Fitur dari Sinyal SpO ₂ dan Pulse Rate	73
4.6	Analisa Hasil Keseluruhan dan Diskusi	74
4.7	Analisa Pola Klasifikasi Per Subjek	78
4.8	Analisa Perbandingan dengan Penelitian Terkait	80
BAB 5 PENUTUP		83

5.1	Kesimpulan	83
5.2	Penelitian Selanjutnya.....	84
DAFTAR PUSTAKA		85
LAMPIRAN		91
BIOGRAFI PENULIS		109

Halaman ini sengaja dikosongkan

DAFTAR GAMBAR

Gambar 1.1. Metodologi Penelitian	7
Gambar 2.1. Model emosi kategorial atau diskrit (A) dan dimensional (B).....	13
Gambar 2.2. Variasi atenuasi ringan menurut jaringan.....	16
Gambar 2.3. Penyerapan HbO ₂ dan Hb pada gelombang yang berbeda.....	18
Gambar 2.4. Sensor Pulse oximeter Cooking Hacks dan cara pemasangan pada jari tangan [41]	19
Gambar 2.5. (a) Fungsi klasifikasi <i>linear</i> pada kasus <i>linierly separable</i> , (b) Fungsi klasifikasi <i>linear</i> yang berbeda (1) dan (2) dan fungsi <i>non-linier</i> (3) pada kasus <i>linearly non-separable</i>	27
Gambar 2.6. <i>Hyperplane</i> pemisah $xTw + b = 0$ dan margin di dalam kasus <i>linearly separable</i>	28
Gambar 2.7. Bidang pemisah $xTw + b = 0$ dan margin di dalam kasus <i>linearly non-separable</i>	31
Gambar 2.8. Transformasi dari ruang data (<i>data space</i>) dua-dimensi menjadi ruang fitur (<i>feature space</i>) tiga dimensi $\mathbb{R}^2 \mapsto \mathbb{R}^3$	33
Gambar 2.9. Ilustrasi klasifikasi vektor data dalam pendekatan <i>One-against-one</i> atau <i>pairwise</i> SVM dimana daerah yang diarsir adalah daerah yang tidak terklasifikasi oleh formula <i>pairwise</i>	35
Gambar 2.10. Ilustrasi <i>k-folds cross validation</i> , dengan $K=3$	39
Gambar 3.1. Metodologi Penelitian	41
Gambar 3.2. Pengaturan aplikasi <i>CoolTerm</i> untuk pembacaan USB port serial ..	44
Gambar 3.3. (Kiri) Pemasangan modul <i>E-Health sensor platform V2.0</i> pada Arduino Uno Rev.3, (Kanan) Pemasangan sensor pulse oximeter pada jari tangan dan modul <i>E-Health Sensor platform V2.0</i> yang sudah terkoneksi dengan <i>Arduino UNO Rev.3</i> [41].....	45
Gambar 3.4. Tampilan aplikasi <i>Coolterm</i> saat membaca dan menampilkan data sinyal SpO ₂ dan Pulse rate	46
Gambar 3.5. Representasi Sinyal SpO ₂ (merah) dan Pulse rate (biru) dalam rentang domain waktu	47

Gambar 3.6. Posisi partisipan pada saat pengambilan data	48
Gambar 3.7. Proses Pengambilan Data Penelitian	49
Gambar 3.8. Urutan sesi stimulasi video	51
Gambar 3.9. Ilustrasi Metode Segmentasi Ukuran Window Sinyal Fisiologi	53
Gambar 3.10. Proses klasifikasi dengan Algoritma SVM dengan modifikasi parameter C dan γ	55
Gambar 3.11. Hasil klasifikasi menggunakan SVM	56
Gambar 3.12. Proses klasifikasi dataset menggunakan metode kNN dengan modifikasi nilai K	57
Gambar 3.13. Hasil klasifikasi menggunakan metode kNN	58
Gambar 3.14. Diagram alir proses klasifikasi	59
Gambar 4.1. Partisipan Penelitian	61
Gambar 4.2. Hasil Pemilahan Data dan Pencocokkan dengan Kuisiomer	62
Gambar 4.3. Tipikal Data Hasil Pengukuran	64
Gambar 4.4. Hasil klasifikasi 8 fitur sinyal SpO ₂ dengan metode SVM	68
Gambar 4.5. Hasil Klasifikasi 8 fitur dari sinyal pulse rate dengan SVM	69
Gambar 4.6. Hasil Klasifikasi 16 Fitur dari Kombinasi Sinyal SpO ₂ dan Pulse Rate dengan Metode SVM	70
Gambar 4.7. Hasil klasifikasi 8 fitur dari sinyal SpO ₂ dengan kNN	72
Gambar 4.8. Hasil klasifikasi 8 fitur dari sinyal Pulse rate dengan kNN	73
Gambar 4.9. Hasil klasifikasi 16 fitur dari kombinasi sinyal SpO ₂ dan Pulse rate dengan Metode kNN	74
Gambar 4.10. Hasil klasifikasi dengan input fitur yang berbeda menggunakan metode SVM dan kNN	77
Gambar 4.11. Klasifikasi menggunakan metode SVM dan kNN per subjek	79

DAFTAR TABEL

Tabel 2.1. Algoritma kNN untuk pendekatan fungsi bernilai diskrit $f: \mathbb{R}^n \rightarrow V$	37
Tabel 2.2. Tabel <i>Confusion Matrix</i>	40
Tabel 3.1. Daftar Stimulan Audio-video	50
Tabel 4.1. Daftar Partisipan yang Lolos Filter	63
Tabel 4.2. Sebaran Sampel Dataset	65
Tabel 4.3. Sampel Hasil Ekstraksi Fitur Sinyal SpO ₂	66
Tabel 4.4. Sampel Hasil Ekstraksi Fitur Sinyal Pulse Rate	67
Tabel 4.5. Tabel <i>Confusion Matrix</i> Klasifikasi Menggunakan Metode SVM	76
Tabel 4.6. Tabel <i>Confusion Matrix</i> Klasifikasi Menggunakan Metode k-NN	76
Tabel 4.7. Perbandingan dengan Penelitian Terkait	81

Halaman ini sengaja dikosongkan

DAFTAR NOMENKLATUR

SpO_2	:	Saturasi Oksigen atau kandungan oksigen dalam darah
HbO_2	:	Persentase oksigen yang diikat oleh hemoglobin
Hb	:	Hemoglobin
I_{DC}	:	Koefisien DC
I_{AC}	:	Koefisien AC
λ	:	Lamda
PaO_2	:	Tensi oksigen arteri
PR	:	Pulse rate atau denyut nadi
bpm	:	Beats per minute
μ	:	<i>mean</i> atau rata-rata
σ	:	Standard deviasi
N	:	Banyaknya data
mo	:	Modus
T_b	:	Tepi bawah kelas modus
d_1	:	Selisi antara fekuensi modus dengan frekuensi sebelumnya
d_2	:	Selisih antara frekuensi modus dengan frekuensi sesudahnya
σ^2 atau s^2	:	Varians
MAD	:	Mean absolute deviasi
w	:	Vector bobot
b	:	Variabel bias
x_i	:	<i>Feature</i> dari data ke-i
y_l	:	Kelas dari data ke-i
d	:	Jarak support vektor dengan <i>hyperplane</i> (margin)
L_p	:	Lagrangian <i>primal problem</i>
L_D	:	Lagrangian <i>dual problem</i>
a, μ	:	Pengali lagrange
ξ_l	:	Variabel <i>slack</i> pada kasus <i>linearly non-separable data</i>
$f(x)$	:	Fungsi klasifikasi
C	:	Parameter <i>cost</i> margin
φ	:	Fungsi <i>mapping non-linear</i>

$K(x_i, x_j)$: Fungsi kernel

Ψ : Parameter transformasi

γ : Parameter gamma pada kernel RBF

D_{ij} : Fungsi keputusan untuk data multikelas SVM

$g(x)$: Fungsi mapping yang memetakan *feature space*

$d(x_i, x_j)$: Jarak euclidean

$a_r(x)$: Nilai atribut ke- r dari *instance* x

V : Bentuk data terbatas $\{v_1, \dots, v_s\}$

TP : Banyaknya data yang diprediksi benar pada kelas positif

FP : Banyaknya data yang diprediksi salah pada kelas positif

TN : Banyaknya data yang diprediksi benar pada kelas negatif

FN : Banyaknya data yang diprediksi salah pada kelas negatif

ACC : Akurasi

PPV : Presisi

F_1 : F-measure

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Emosi dipahami sebagai respon fisik dan fisiologis tubuh dimana aktifitas emosi ini erat kaitannya dengan aktifitas sistem syaraf otonom atau *autonomic nervous system* [1]. Bagian dari sistem syara otonom, yaitu sistem syaraf simpatik dan parasimpatik akan terangsang apabila seseorang mengalami emosi. Emosi sendiri terbagi menjadi dua bagian, yaitu emosi negatif dan emosi positif. Respon emosi negatif merangsang sistem syaraf simpatik, sedangkan emosi positif merangsang sistem syaraf parasimpatik. Kedua jenis rangsangan ini dapat menyebabkan perubahan terhadap aktifitas fisiologis manusia seperti aktifitas pada sistem kardiovaskular, proses respirasi, sekresi hormon, sirkulasi, pencernaan, denyut nadi atau *pulse rate*, kandungan oksigen dalam darah (SpO_2) dan ekskresi [2].

Emosi sendiri merupakan salah satu aspek fundamental dalam kehidupan manusia yang selalu dikaitkan dengan kondisi kesehatan, baik emosi positif maupun negatif [1],[3]. Banyak penelitian terdahulu yang menyebutkan bahwa emosi negatif berdampak buruk terhadap serangan penyakit kronis seperti diabetes militus, tekanan darah tinggi [4], serangan penyakit jantung [5]. Pressman *et al.* menemukan bahwa emosi negatif dapat meningkatkan potensi kematian [6]. Glaser dan Keicolt juga menemukan bahwa kondisi stress sangat berbahaya karena dapat menurunkan sistem kekebalan tubuh atau imun [7]. Akibatnya, seseorang menjadi rentan terhadap serangan penyakit lain. Penelitian lain juga menyebutkan bahwa sedih (tergolong emosi negatif) mempunyai pengaruh yang signifikan terhadap peningkatan aktivitas denyut jantung [8] dan menurunkan level SpO_2 hingga kondisi *hypoxia* [9]. Sebaliknya, emosi positif cenderung dihubungkan dengan peningkatan kelangsungan hidup manula [6], menurunkan potensi kematian, gejala afektif dan rasa sakit [10]. Bahkan, Kok *et al.* juga menemukan bahwa emosi positif, hubungan sosial yang positif dan kesehatan fisik saling berhubungan satu sama lain, terutama terhadap peningkatan kondisi fisik seseorang [11]. Namun,

dengan melihat dampak positif dan negatif yang ditimbulkan dari emosi, langkah pengendalian emosi ini masih bersifat subjektif dan konvensional, terutama sistem peringatan yang dilakukan di rumah sakit. Seorang dokter hanya memberikan peringatan secara konvensional (peringatan secara langsung) terhadap pasien untuk selalu menjaga kondisi fisiologis emosinya. Padahal pengendalian seperti itu bisa saja tidak sepenuhnya maksimal, sehingga menyebabkan proses penanganan medis dan penyembuhan penyakit kurang maksimal.

Berawal dari permasalahan di atas, diperlukan suatu sistem untuk memonitor dan mendeteksi kondisi emosi. Sistem ini diharapkan mampu memberikan peringatan dini terhadap kondisi fisiologis emosi seseorang, sehingga dapat meminimalisasi resiko serangan penyakit kronis yang disebabkan oleh kondisi emosi, terutama emosi negatif. Para peneliti, akademisi dan praktisi hingga saat ini berlomba-lomba melakukan kajian penelitian untuk menyelesaikan permasalahan di atas. Kajian penelitian ini bertujuan untuk mengenali karakteristik dan pola emosi manusia berdasarkan aktivitas fisiologisnya seperti aktivitas pada wajah, denyut jantung, kedipan mata, kandungan oksigen dalam darah dan aktivitas gelombang otak manusia. *Emotion recognition* atau pengenalan emosi merupakan istilah dari kajian penelitian ini. Tujuan akhir dari penelitian ini digunakan untuk pengembangan sistem teknologi monitoring kesehatan berbasis perangkat elektronik atau *e-health monitoring system*. Dalam beberapa dekade terakhir, terdapat beberapa jenis sinyal dan sensor fisiologis yang telah digunakan untuk diterapkan dalam penelitian pengenalan emosi, baik yang memanfaatkan single atau multimodal sinyal fisiologis, seperti *electroencephalogram (EEG)*, *electrocardiogram (ECG)*, *galvanic skin response (GSR)*, *electromyogram (EMG)*, *finger temperature (FT)*, *blood volume pressure (BVP)*, *carbone dioxide (CO₂)*, *respiration rate (RR)*, *pulse rate (PR)*, dan *oxygen saturation (SpO₂)*.

Animo pemanfaatan sinyal EEG dan ECG sangat besar dikalangan peneliti untuk mengenali atau mendeteksi emosi, seperti yang dilakukan oleh Petrantonakis et al. [12], Mert et al. [13], Zhang et al. [14] yang mengenali emosi berdasarkan sinyal EEG. Penelitian lain juga melakukan review deteksi emosi berdasarkan sinyal ECG [15]. Selain itu, terdapat juga peneliti yang memanfaatkan multimodal sinyal fisiologis, seperti GSR, EMG, FT, BVP, CO₂ dan RR [16] [17] [18]. Namun

seperti yang diketahui, kajian penelitian pengenalan emosi berbasiskan sinyal SpO₂ dan PR masih sangat minim baik menggunakan single maupun kombinasi atau multimodal. Padahal kajian penelitian ini sangat penting dilakukan karena penggunaan dan pemasangan sensor yang sangat mudah yakni di jari [19] sehingga fleksibilitas penggunaannya sangat mudah dan simpel dibandingkan dengan sensor ECG dan EEG yang membutuhkan ketelitian dan presisi tinggi dalam pemasangannya. Apalagi digunakan untuk manula dan juga pasien yang mempunyai penyakit jantung, oleh karena itu perlu untuk dikembangkan sebuah sistem teknologi *e-health monitoring* emosi yang simpel, fleksibel, mudah digunakan dan akurat perlu untuk dikembangkan.

SpO₂ dan PR merupakan dua jenis sinyal fisiologis yang didapatkan dari pengukuran menggunakan Sensor Pulse oximeter secara non-invasive [19][20]. Sensor ini merupakan suatu perangkat yang dikembangkan untuk pengukuran denyut nadi dan kandungan oksigen dalam darah yang dapat merepresentasikan aktivitas denyut jantung. Konsep pengukuran sensor ini berdasarkan pada peningkatan penyerapan cahaya yang disebabkan oleh peningkatan tekanan darah sistolik di dalam volume darah arteri [19][20]. Sensor ini biasanya digunakan secara klinis untuk memonitor status pernafasan dari pasien di rumah sakit [19]. Selain itu, beberapa peneliti memanfaatkannya untuk mendeteksi kondisi Sleep Apnea atau Hypopnea [21][22][23][24]. Dalam ranah penelitian pengenalan emosi, Wen *et al.* [25], Huang *et al.* [26], dan Begum *et al.* [27] mengkombinasikan sinyal SpO₂ dengan sinyal fisiologis lainnya untuk mendeteksi emosi. Wen *et al.* [25] mengkombinasikan sinyal SpO₂ dengan sinyal GSR dan HR untuk menemukan fitur unik. Huang *et al.* [26] mengkombinasikan sinyal SpO₂ dengan GSR dan ECG. Sedangkan, Begum *et al.* [27] mengkombinasikan sinyal SpO₂ dengan sinyal HR, FT, RR, dan CO₂. Sementara itu, Marzuki *et al.* [28] menggunakan hanya sinyal pulse rate untuk mengenali pola emosi. Bagaimanapun, hingga saat ini penelitian yang telah dilakukan menunjukkan bahwa hasil klasifikasi belum optimal dan belum ada yang melakukan kajian penelitian pengenalan emosi dengan menggunakan multimodal sinyal SpO₂ dan PR. Selain itu juga, subjek penelitian yang telah dilakukan sebagian besar berumur kurang dari 30 tahun. Masih belum ada kajian penelitian pengenalan emosi dengan pada subjek Manula atau lanjut usia.

1.2 Rumusan Masalah

Perhatian masyarakat terhadap kondisi emosi, terutama pasien yang mempunyai riwayat penyakit kronis, masih sangat minim. Kondisi emosi yang tidak stabil, terutama emosi negatif, mengakibatkan pengaruh yang signifikan terhadap kondisi kesehatan seseorang terutama pasien manula yang mempunyai riwayat penyakit kronis. Kondisi ini dapat meningkatkan potensi kematian, menurunkan sistem kekebalan tubuh sehingga berdampak pada serangan penyakit kronis lainnya. Namun, masalah ini tidak diimbangi dengan perkembangan sistem teknologi yang dapat memonitor kondisi emosi manusia berdasarkan aktivitas fisiologis.

Pemanfaatan sensor Pulse Oximeter dalam mendeteksi kondisi emosi manusia dapat dijadikan tolok ukur baru dalam monitoring kondisi emosi. Sensor ini dapat mengukur kondisi fisiologis seseorang dengan merepresentasikan ke dalam jenis sinyal SpO_2 dan Pulse rate. Selama ini, penelitian yang membahas pengenalan emosi dengan menggunakan sinyal SpO_2 dan Pulse rate masih sangat minim. Para peneliti banyak yang menggunakan sinyal fisiologis lainnya seperti EEG, ECG, BVP, GSR dalam mengenali kondisi emosi seseorang. Selain itu, subjek penelitian yang oleh peneliti-peneliti terdahulu sebagian besar seseorang yang berusia dibawah 30 tahun dan masih sangat minim yang melakukan penelitian pengenalan emosi pada kelompok orang usia lanjut (Manula).

1.3 Tujuan

Berdasarkan permasalahan yang telah diuraikan diatas baik pada latar belakang dan rumusan masalah, tujuan yang menjadi perhatian utama pada penelitian ini adalah mengenali ciri-ciri dan pola emosi atau deteksi emosi pada manula berdasarkan aktivitas fisiologis yang tergambar berdasarkan sinyal SpO_2 dan Pulse rate dengan menggunakan metode yang diusulkan.

Selain itu tujuan utama tersebut, juga terdapat tujuan khusus dari segi teknis pengolahan data untuk mencapai hasil yang maksimal dalam memenuhi tujuan utama di atas, diantaranya adalah 1) mengidentifikasi pengaruh klasifikasi baik menggunakan SVM ataupun kNN dengan melatih dan menguji dataset dengan tiga skenario yang berbeda yakni berdasarkan penggabungan 16 fitur statistik sinyal

SpO₂-Pulse rate, 8 fitur sinyal SpO₂ dan 8 fitur sinyal Pulse rate serta membandingkan hasil klasifikasi yang paling optimal dengan dataset berdasarkan pada tiga skenario klasifikasi tersebut menggunakan SVM dan kNN; 2) mengidentifikasi parameter C dan γ terbaik pada metode klasifikasi Support vector machine dan nilai K optimal pada metode klasifikasi k-Nearest Neighbors berdasarkan sinyal SpO₂ dan Pulse rate yang telah diekstraksi menjadi 8 fitur statistik pada domain waktu; dan 3) mengidentifikasi pola emosi per subjek dengan mengklasifikasikan fitur-fitur dari multimodal sinyal fisiologis yang telah diekstraksi berdasarkan metode yang diusulkan.

1.4 Batasan Masalah

Aspek masalah yang digali sangatlah luas, sehingga perlu untuk mendeskripsikan batasan masalah yang akan diteliti. Batasan penelitian ini adalah:

1. Subjek penelitian ini adalah orang lanjut usia atau Manula yang berumur lebih dari 55 tahun.
2. Penelitian ini mengenali tiga jenis emosi dasar, diantaranya senang, sedih dan marah, yang tergolong dalam kategori emosi diskrit berdasarkan teori emosi yang dikemukakan oleh Paul Ekman.
3. Untuk membangkitkan atau menginduksi emosi pada partisipan, penelitian ini menggunakan stimulan video yang terkategori dalam video clip dan telah divalidasi oleh peneliti sebelumnya yakni Rumpa et al [29].
4. Penelitian ini menggunakan sensor Pulse Oximeter yang dikembangkan oleh Cooking Hacks dengan didukung perangkat Modul E-health tipe V2.0 dan Arduino UNO Rev.3 agar data sinyal fisiologis dapat dibaca dan disimpan oleh komputer.
5. Metode ekstraksi fitur pada penelitian ini menggunakan 8 fitur statistik pada domain waktu.
6. Penelitian ini mengimplementasikan metode SVM dan kNN untuk mengklasifikasi fitur-fitur yang telah diekstraksi dari sinyal SpO₂ dan Pulse rate dengan memilih parameter C dan γ optimal pada SVM dan K optimal pada kNN.

1.5 Kontribusi

Secara keilmuan dan pengembangan teknologi mutakhir, kontribusi penelitian ini adalah:

1. Menambah khasanah keilmuan dan literatur berkaitan dengan pemanfaatan sinyal SpO₂ dan Pulse rate dalam bidang *affective computing*, khususnya dalam pengenalan emosi dengan subjek Manula.
2. Didapatkannya landasan dasar dan pola sinyal SpO₂ dan Pulse rate dalam menggambarkan kondisi emosi Manula sehingga informasi ini dapat digunakan sebagai dasar dalam pengembangan aplikasi *e-Health monitoring system* yang digunakan oleh tenaga medis dalam memonitor kondisi fisiologi emosi, terutama pada pasien yang mempunyai riwayat penyakit kronis.

1.6 Metodologi Penelitian

Secara umum, metodologi penelitian pada tesis ini terbagi menjadi 4 tahapan utama seperti yang diilustrasikan pada gambar 1.1 untuk dapat menyelesaikan tujuan yang akan dicapai. Adapun tahapan-tahapan atau metodologi yang dilakukan dalam penelitian ini dapat dijelaskan sebagai berikut:

Tahapan I:

Pada tahap awal yang terdiri dari proses pengkajian atau studi literatur, eksplorasi hardware dan penentuan atau pemilihan responden penelitian. Tahapan ini merupakan persiapan sebelum melakukan penelitian.

Tahapan II:

Pada tahapan kedua yakni pengambilan data yang terdiri dari dua proses utama yakni pengambilan data dengan partisipan orang manula dan proses filterisasi data raw. Proses filterisasi ini dilakukan dengan mencocokkan data raw dengan hasil pengisian kuisioner.


Tahapan III:

Pada tahapan ketiga ini merupakan tahap pengolahan data yang terdiri dari proses ekstraksi fitur, pelabelan dataset dan klasifikasi. Proses pengolahan data diawal dengan implementasi metode segmentasi *window size* atau *length* dari kedua sinyal fisiologi dan ekstraksi fitur menggunakan metode fitur statistik pada domain waktu. Setelah mendapatkan dataset yang telah diekstraksi fitur, selanjutnya adalah


proses pelabelan dan klasifikasi dengan menggunakan metode SVM dan kNN. Proses klasifikasi dengan SVM dilakukan dengan memilih parameter C (*cost*) dan λ (Gamma) terbaik dan pemilihan parameter K pada kNN untuk mendapatkan hasil klasifikasi yang optimal. Proses pelatihan dan pengujian dataset menggunakan metode *k-fold Cross-validation* untuk menghindari kasus *overfitting*.

Tahapan IV:

Tahap ini merupakan tahap akhir yakni proses evaluasi performansi dari proses klasifikasi dengan dua metode yang telah dijelaskan. Penelitian ini menggunakan parameter Akurasi, presisi dan F1 score untuk menilai kinerja dari metode algoritma yang telah diusulkan.



Gambar 1.1. Metodologi Penelitian



Halaman ini sengaja dikosongkan

BAB 2

KAJIAN PUSTAKA

Bab ini membahas mengenai kajian pustaka yang menjadi dasar dari penelitian ini, diantaranya kajian penelitian yang terkait dan teori dasar dari penelitian ini. Berikut uraian lengkap dari bab kajian pustaka ini.

2.1 Kajian Penelitian Terkait

Penelitian tentang pengenalan emosi hingga saat ini sebagian besar memanfaatkan sinyal ECG dan EEG. Masih sedikit yang memanfaatkan sinyal SpO₂ dan Pulse rate. Kedua jenis sinyal fisiologi ini lebih sering dimanfaatkan dalam pengenalan sleep apnea atau hypopnea [21][24][30][31]. Dalam ranah pengenalan emosi, hanya beberapa yang memanfaatkan keduanya, namun digunakan dalam kasus yang berbeda-beda yakni sinyal SpO₂ dikombinasi dengan sinyal fisiologis lain. Seperti yang dilakukan oleh Wen et al, Huang et al dan Begum *et al.* [25]–[27]. Wen *et al.* [25] memanfaatkan sinyal SpO₂ dengan mengkombinasikan dengan sinyal GSR dan HR untuk mengenali emosi marah, sedih, takut dan terhibur. Mereka menstimulasi 101 partisipan dengan variasi umur menggunakan 4 buah klip film. Sinyal fisiologi emosi yang didapatkan diekstraksi menjadi fitur-fitur unik dengan menggunakan metode korelasi Multi-Varian sinyal fisiologi dan Random Forest untuk mengklasifikasi fitur-fiturnya. Berdasarkan penerapan algoritma tersebut didapatkan nilai rata-rata kebenaran atau akurasi dari penerapan algoritma klasifikasi sebesar 74%. Huang *et al.* [26] mengkombinasikan sinyal SpO₂ dengan sinyal GSR dan ECG. Selain itu juga mengambil emosi yang sama dengan Wen *et al.* [25] yakni emosi marah, sedih, takut dan hiburan/kartu yang distimulikan terhadap 250 subjek dengan umur rata-rata 19,4 tahun. Untuk mendapatkan fitur dari masing-masing emosi, mereka menggunakan metode analisis statistik (domain waktu dan frekuensi) serta algoritma *Random Forest* untuk klasifikasi. Penelitian tersebut didapatkan akurasi klasifikasi sebesar 74,8%. Sementara Begum *et al.* [27] mengkombinasikan sinyal SpO₂ dengan sinyal fisiologi lainnya seperti heart rate (HR), finger temperature (FT), respiration rate

(RR), carbone dioxide (CO₂) untuk mengenali dua emosi yakni kondisi stress dan relax. Metode Multivariate multiscale entropy (MMSE) digunakan untuk fitur ekstraksi dari sinyal fisiologi emosi yang didapatkan. Selanjutnya metode Case-based Reasoning (CBR) digunakan untuk mengklasifikasikan fitur-fitur yang didapatkan dari ekstraksi fitur. Hasilnya didapatkan bahwa sistem yang diusulkan dapat mengenali 87,5% secara akurat kedua kondisi tersebut. Sementara, pemanfaatan sinyal Pulse rate dalam ranah pengenalan emosi dimanfaatkan oleh Marzuki *et al.* [28] saja. Mereka hanya memanfaatkan tipe sinyal fisiologi ini untuk mengenali 6 emosi dasar, diantaranya emosi senang, sedih, marah, kaget, jijik dan marah. Marzuki *et al.* [28] menggunakan metode analisis statistika untuk ekstraksi fitur sinyal dan metode Learning Vector Quantization untuk klasifikasi fitur-fitur yang telah diekstraksi. Hasilnya didapatkan bahwa nilai akurasi tertinggi didapatkan sebesar 68,52% dengan percentage split 70%.

2.2 Teori Dasar

2.2.1 Emosi Manusia

Selama ini, belum ada batasan dan ukuran pasti tentang teori dan definisi emosi. Emosi dikaitkan dengan banyak bidang ilmu pengetahuan, seperti psikiatri, fisiologi, psikologi, neuroscience, ilmu sosial, sosiologi, ilmu komunikasi, antropologi, kriminologi, hukum, ilmu politik, filosofi, dan ilmu komputer. Namun, jika dilihat dari asal bahasa, kata “emosi” diturunkan dari bahasa perancis, *émotion*, dari *émouvoir*, yang berarti ‘kegembiraan’. Sedangkan dari bahasa latin, *emovere*, dari e- (varian eks-) yang berarti 'luar' dan *movere* yang berarti 'bergerak'. Kleinginna & Kleinginna [32] membedakan definisi emosi berdasarkan beberapa kategori, diantaranya berdasarkan definisi afektif, kognitif, stimuli eksternal, fisiologi, kebiasaan ekspresif/emosional, disruptif, adaptif, multiaspek, restriktif, motivasional, statemen skeptikal.

Definisi afektif menekankan perasaan gairah dan/atau nilai hedonis. Definisi kognitif menekankan penilaian dan/atau proses pelabelan. Definisi stimuli eksternal menekankan gerak eksternal dan stimuli pembangkit. Definisi fisiologi menekankan mekanisme fisik internal emosi. Definisi kebiasaan ekspresif/emosional menekankan respon emosional yang diamati secara eksternal.

Definisi disruptif menekankan efek tidak teratur atau tidak berfungsinya emosi. Definisi adaptive menekankan efek keteraturan dan fungsi dari emosi. Definisi multiaspek menekankan beberapa komponen yang berkaitan dengan emosi. Definisi restriktif menekankan emosi dari proses psikologi luar. Definisi motivasional menekankan hubungan antara emosi dan motivasi. Serta statemen skeptikal mempertanyakan kegunaan konsep emosi.

Kleinginna & Kleinginna [32] juga merangkum pengertian Emosi fisiologis berdasarkan para ahli. John B. Watson mengungkapkan bahwa emosi fisiologis adalah sebuah emosi yang merupakan sebuah turunan ‘pola-reaksi’ yang melibatkan perubahan besar dari mekanisme tubuh secara keseluruhan, terutama dari sistem visceral dan kelenjar. Walter B. Cannon untuk teori bahwa pengalaman emosional timbul dari perubahan organ efektor diganti gagasan bahwa mereka diproduksi oleh pengaruh yang tidak biasa dan kuat yang muncul dari daerah thalamus dan mempengaruhi berbagai sistem neuran kortikal. M. A Wenger, F.N Jones dan M.H Jones mengemukakan emosi merupakan aktivitas dan reaktivitas dari jaringan dan organ yang dipersarafi oleh sistem saraf otonom. Ini mungkin melibatkan, tetapi tidak selalu melibatkan, respon otot rangka atau aktivitas mental. Pavel V. Simonov memberikan definisi emosi dari sudut pandang fisiologis, bahwa emosi merupakan mekanisme saraf khusus yang menjamin perilaku adaptif makhluk hidup yang lebih tinggi dalam situasi yang mengganggu sistem kebiasaan mereka, yaitu ketika ada kekurangan dari informasi yang diperlukan untuk mencapai tujuan dan memuaskan kebutuhan. Richard L. Bruce menganalogikan istilah deskriptif untuk ‘merasakan’ emosi sebagian besar merupakan pernyataan dari umpan balik tubuh dari berbagai sistem yang tiba-tiba mengubah aktivitas mereka.


Istilah lain yang dikaitkan dengan emosi adalah *feelings*, *mood* dan *affect* [33]. *Feelings* atau perasaan dipahami paling baik sebagai representasi secara subjektif dari emosi, pribadi terhadap individu yang mengalaminya. *Mood* atau suasana hati adalah keadaan afektif yang umumnya bertahan lebih lama daripada emosi dan biasanya juga kurang kuat daripada emosi. Sedangkan *affect* merupakan istilah yang melingkupi, digunakan untuk menggambarkan topik emosi, perasaan

dan suasana hati secara bersama-sama, meskipun biasanya digunakan secara bergantian dengan emosi.

Beberapa peneliti bidang psikologi mengkategorikan emosi dalam beberapa dimensi. Salah satunya Pressman dan koleganya dalam tulisannya yang berjudul “*Does Positive Affect Influence Health?*”. Mereka membagi emosi menjadi dua jenis berdasarkan durasi berlangsungnya emosi seseorang, yakni *state emotion* dan *trait emotion* [10]. *State emotion* atau status emosi merupakan suatu keadaan emosi seseorang yang berlangsung dalam jangka waktu pendek (*short-term emotion*). Pressman *et al.* [10] mengatakan bahwa emosi jenis ini bisa diukur dan dimanipulasi dengan memberikan induksi atau stimulasi, namun keadaan emosi seseorang pada jenis ini berdurasi pendek bahkan selama ia diinduksi saja. Sebagai contoh misalkan seseorang menonton sinetron atau film di layar lebar, pada saat adegan sedih ia merasakan kesedihan atau bahkan menitikkan air mata. Jika sinetron atau film tersebut selesai, maka emosi orang tersebut akan kembali normal. *Trait emotion* atau sifat emosi dikaitkan dengan emosi seseorang yang berdurasi lama (*long-term emotion*) dan dikaitkan dengan *mood*. Jenis emosi ini sebenarnya terjadi karena adanya *state emotion* yang berlangsung secara terus-menerus dan berulang-ulang. Emosi jenis ini membuat keadaan trauma dalam waktu yang lama. Contoh kasus dari jenis emosi ini adalah: seseorang anak yang melihat ketidakharmonisan hubungan kedua orang tuanya, hingga pada akhirnya kedua orang tuanya bercerai. Keadaan ini membuat seorang anak tersebut merasakan trauma yang tersimpan sepanjang hidupnya. Selain emosi di atas, Pressman *et al.* [10] juga membedakan emosi dasar menjadi dua yakni emosi negatif dan positif (sedih dan senang).

Dalam teori kategorial dan dimensional dari emosi, beberapa peneliti mengklasifikasikan status emosi menjadi dua model, yakni “*basic emotion*” yang dikenal dengan emosi model diskrit dan model dimensional seperti yang terlihat pada gambar 2.1 [34][35]. Kedua model ini yang sering digunakan acuan oleh para peneliti dalam dunia ilmu komputer dan affective computing dalam penelitian pengenalan emosi. Model diskrit dikenalkan oleh Paul Ekman yang menjelaskan bahwa adanya hubungan antara ekspresi wajah dan proses biologis seseorang. Ekman membagi 6 emosi dasar diantaranya adalah senang, sedih, marah, jijik, takut

dan kaget. Sedangkan dalam model dimensional diperkenalkan oleh James A Russel dimana emosi diplot menjadi dua skala yakni skala *arousal* (gairah) dan *valence* (nilai). *Arousal* menggambarkan intensitas emosi sedangkan *valence* menggambarkan polaritas dari emosi (positif dan negatif) [35].



Gambar 2.1. Model emosi kategorial atau diskrit (A) dan dimensional (B)

Perdebatan, perkembangan definisi dan teori tentang emosi masih berlangsung hingga saat ini. Dalam dekade terakhir semakin banyak penelitian bidang affective computing, yakni mengenali emosi secara komputerisasi. Pada penelitian ini definisi emosi yang digunakan adalah status emosi manula yang terjadi dalam rentang waktu yang singkat (*short-term emotion*) berdasarkan pada stimuli yang diterima oleh partisipan. Penelitian ini menggunakan tiga emosi dasar atau *state emotion* dari enam emosi dasar yang dikemukakan oleh Paul Ekman sebagai objek kelas klasifikasi, yakni emosi senang, sedih dan marah. Alasan utama menggunakan tiga jenis emosi ini adalah ketiganya sering dirasakan oleh setiap orang dalam kehidupan sehari-hari, terutama pada manula.

2.2.2 Hubungan Emosi, Aktivitas Fisiologis dan Kesehatan

Definisi emosi yang dipaparkan oleh Kleinginna yang dikelompokkan menjadi beberapa jenis, salah satu diantaranya adalah definisi secara fisiologis [32]. Dari definisi tersebut dapat disimpulkan bahwa emosi fisiologis menekankan perubahan besar mekanisme syaraf khusus yang menjamin kegiatan adaptif dan

mengubah kebiasaan manusia. Uskul et al. mengatakan adanya hubungan yang erat antara emosi dan kondisi kesehatan manusia [3], sehingga dipercaya bahwa emosi memainkan peran penting dalam aktivitas sehari-hari. Pressman *et al.* [10] mengkorelasikan emosi positif dengan penurunan potensi kematian, sebaliknya emosi negatif diasosiasikan sebagai penyebab potensi kematian yang lebih cepat dan menurunkan sistem imun tubuh.

Lebih lanjut, Sylvia D. Kreibig *et al.* menyatakan bahwa aktivitas sistem syaraf otonom atau *Autonomic Nervous System* (ANS) ditunjukkan sebagai komponen utama yang berhubungan dengan aktivitas emosi manusia [1]. Aktivitas ANS yang diakibatkan dari respon emosi ini dapat mempengaruhi perubahan fisiologis tubuh. ANS berperan untuk terus menyempurnakan fungsi dan sistem organ sesuai dengan rangsangan baik internal maupun eksternal, membantu mempertahankan stabilitas internal dan keseimbangan melalui koordinasi berbagai aktivitas seperti aktivitas pada sistem kardiovaskular, proses respirasi, sekresi hormon, sirkulasi, pencernaan dan ekskresi [1], [2]. Selain itu, ANS juga berfungsi menghubungkan sistem saraf pusat dengan kelenjar endokrin, yaitu kelenjar yang mengontrol detak jantung dan organ-organ internal lainnya, seperti perut, intestin, hati, dan paru-paru secara psikologis, serta sangat mempengaruhi dinamika emosi, perasaan dan suasana hati (mood) [1][2].

Sherwood *et al.* dalam bukunya yang berjudul *Human Physiology, From Cells to Systems* dan Guyton et al dalam bukunya *Medical Physiology* menyatakan bahwa ANS terdiri dari sistem syaraf simpatik dan parasimpatik (*Sympathetic and parasympathetic nervous system*) [2], [36]. Sistem syaraf simpatik yang jika dirangsang akan berakibat pupil mengalami dilatasi (membesar), aliran ludah terhambat, kinerja detak jantung meningkat, bronkus mengerut, proses peristaltis dan sekresi terhambat, perubahan glikogen ke glukosa terstimulasi, sekresi adrenalin dan nonadrenalin dan kontraksi kandung kemih menjadi terhambat. Sebaliknya jika sistem syaraf parasimpatik dirangsang, maka pupil akan terjadi *constrict* (mengecil), aliran ludah terstimulasi, kinerja detak jantung menjadi lambat, bronkus membesar, proses peristaltis dan sekresi terstimulasi, terjadi proses stimulasi pelepasan bilus dan kandung kemih mengerut [2] [36]. Sehingga sistem syaraf simpatik ini akan melakukan respon jika mendapat rangsangan emosi negatif


seperti marah, sedih, kaget, dan sebagainya. Sebaliknya jika mendapatkan rangsangan emosi positif seperti senang, gembira, bahagia dan sebagainya, maka sistem syaraf parasimpatik akan melakukan respon.

Sistem syaraf simpatik pada keadaan emosi akan menyebabkan berhentinya hormon *epinephrine* (adrenalin) dan *norepinephrine* (nonadrenalin) [2]. Impuls-impuls syaraf dalam sistem simpatik yang mencapai bagian dalam dari kelenjar adrenalin, berlokasi di bagian atas dari ginjal, membangkitkan sekresi dari hormon ini, yang kemudian pergi ke dalam darah dan bersikulasi di seluruh tubuh. *Epinephrine* membantu banyak struktur dalam tubuh. Dalam hati, *epinephrine* membantu menggerakkan glukosa ke dalam darah dan membuat energi mencapai otak dan otot. *Epinephrine* juga menyebabkan jantung berdetak lebih keras. Dalam otot rangka, *epinephrine* membantu memobilisasi sumber-sumber gula sehingga otot dapat menggunakan gula itu lebih cepat. Pengaruh utama dari *norepinephrine* adalah untuk *constrict* pembuluh darah tepi oleh karena itu tekanan darah akan naik. Pada saat emosi, sistem syaraf simpatik juga membuat perubahan pada aktivitas sistem kardiovaskular, aktivitas jantung, proses pernafasan dan kandungan oksigen dalam darah, konduktansi kulit [1], [2], [36]. Kinerja syaraf simpatik yang meningkat secara terus menerus akan mengakibatkan terjadinya serangan penyakit, terutama penyakit kronis. Pressman dan Cohen [10] yang mengatakan adanya pengaruh emosi negatif terhadap kelangsungan hidup manusia. Namun, jika kinerja syaraf parasimpatik lebih besar atau meningkat daripada kinerja syaraf simpatik, maka resiko terhadap serangan penyakit akan berkurang, sehingga dapat memperpanjang umur manusia.

2.2.3 Sinyal SpO₂ dan Pulse Rate

SpO₂ dan Pulse-rate merupakan dua parameter yang diestimasi dengan metode *photoplethysmogram* (PPG). PPG merupakan metode optik dan noninvasif yang digunakan untuk mendeteksi perubahan volume pada pembuluh darah [37]. PPG menyediakan informasi pada sistem *cardiovascular*, terutama *pulse rate*, *respiratory rate*, *blood flow rate*, dan saturasi oksigen pada pembuluh darah arteri (SpO₂), berdasarkan perubahan pada penyerapan cahaya didalam jaringan pada gelombang merah atau mendekati inframerah tertentu [37].

Perjalanan cahaya melalui jaringan biologis dapat diserap oleh zat yang berbeda, termasuk pigmen di kulit, tulang dan darah arteri dan vena. Sebagian besar perubahan tekanan darah umumnya terjadi di dalam arteri dan arteriol [37]. Gambar 2.2 menunjukkan sebuah contoh gelombang *photoplethysmogram*, yang terdiri dari komponen arus searah (DC) dan arus bolak-balik (AC). Komponen DC dari gelombang PPG berkoresponden terhadap deteksi yang ditransmisikan atau refleksi sinyal optik dari jaringan, bergantung pada struktur jaringan dan rata-rata volume darah baik dari darah arteri dan vena. Komponen DC ini berubah secara lambat sejalan dengan proses pernafasan manusia. Sementara, komponen AC menunjukkan perubahan volume darah, yang terjadi antara aktivitas fase *systolic* (kontraksi *rhythmic*) dan *diastolic* (relaksasi) dari ventrikel kiri jantung manusia [37], [38]. Masing-masing aktivitas *systolic* dan *diastolic* ini dikenal sebagai satu siklus jantung. Frekuensi fundamental dari komponen AC bergantung pada aktivitas jantung dan ditumpangkan di atas komponen DC.



Gambar 2.2. Variasi atenuasi ringan menurut jaringan

SpO_2 atau level saturasi oksigen adalah rasio seberapa banyak persentase oksigen yang diikat oleh hemoglobin [HbO_2] dalam darah arteri yang merupakan

transmitansi dari sinyal PPG. Level SpO₂ seseorang yang didapatkan dari cahaya yang ditransmisikan oleh sensor melalui jaringan dan pembuluh darah yang dibagi menjadi komponen DC (seperti kulit, otot, tulang, dan sebagainya) dan komponen AC (seperti darah arteri) [38]. Dua komponen ini berprinsip pada Hukum Beer-Lambert dimana saat nadi atau denyut jantung tenang dan gelombang γ memancarkan menuju jaringan, komponen DC (I_{DC}) dihitung dengan persamaan berikut:

$$I_{DC} = I_0 e^{-\varepsilon_0 c_0 L} \cdot e^{-\varepsilon_{HbO_2} c_{HbO_2} L} \cdot e^{-\varepsilon_{Hb} c_{Hb} L} \quad (2.1)$$

Keterangan:

ε_0, c_0 : Komponen yang tak berdenyut dari koefisien dan konsentrasi kepunahan;

$\varepsilon_{HbO_2}, c_{HbO_2}, \varepsilon_{Hb}, c_{Hb}$: Koefisien dan konsentrasi HbO₂ dan Hb.

Sedangkan koefisien AC (I_{AC}) didapatkan dari penambahan parameter ΔL dimana parameter ini merepresentasikan saat vasodilatasi detak jantung dan arteri, panjang jalan optik dari pembuluh darah arteri, sehingga I_{AC} dihitung dengan persamaan:

$$I_{AC} = I_{DC} - I_{DC} e^{-(\varepsilon_{HbO_2} c_{HbO_2} + \varepsilon_{Hb} c_{Hb}) \Delta L} \quad (2.2)$$

Karena panjang jalan optik yang tidak diketahui, digunakan dua gelombang berlainan (λ_1 dan λ_2), sehingga diasumsikan :

$$\frac{R_{\lambda_1}}{R_{\lambda_2}} = \frac{I_{AC}^{\lambda_1} / I_{DC}^{\lambda_1}}{I_{AC}^{\lambda_2} / I_{DC}^{\lambda_2}} = \frac{\varepsilon_{HbO_2}^{\lambda_1} c_{HbO_2} + \varepsilon_{Hb}^{\lambda_1} c_{Hb}}{\varepsilon_{HbO_2}^{\lambda_2} c_{HbO_2} + \varepsilon_{Hb}^{\lambda_2} c_{Hb}} \quad (2.3)$$

Berdasarkan pada definisi dasar saturasi oksigen, level SpO₂ didapatkan dengan persamaan berikut:

$$SpO_2 = \frac{c_{HbO_2}}{c_{HbO_2} + c_{Hb}} \times 100\% \quad (2.4)$$


Sehingga dengan kombinasi persamaan 2.3 dan 2.4, didapatkan level SpO₂ dengan persamaan berikut:

$$SpO_2 = \frac{\varepsilon_{Hb}^{\lambda_1} - \varepsilon_{Hb}^{\lambda_2}}{\varepsilon_{Hb}^{\lambda_1} - \varepsilon_{HbO_2}^{\lambda_1}} \cdot \frac{\varepsilon_{AC}^{\lambda_1} / \varepsilon_{DC}^{\lambda_1}}{\varepsilon_{AC}^{\lambda_2} / \varepsilon_{DC}^{\lambda_2}} \quad (2.5)$$

Keterangan:

HbO₂ : rasio konsentrasi hemoglobin yang teroksigenisasi

Hb : Hemoglobin yang terdeoksigenisasi.



Gambar 2.3. Penyerapan HbO₂ dan Hb pada gelombang yang berbeda

Level SpO₂ normal diantara 95-100%. Jika level SpO₂ turun dibawah 95%, maka ada kemungkinan tubuh mengalami hipoksemia. *Hypoxemia* mengacu pada kadar oksigen dalam darah yang diukur dengan konsentrasi O₂ arterial rendah dan saturasi hemoglobin rendah yang diukur dengan gas darah arteri [39]. Dalam arti lain, *hypoxemia* didefinisikan sebagai sebuah kondisi dimana tensi oksigen arteri (PaO₂) terjadi penurunan di bawah level normal (P_{AO2} normal = 80-100 mmHG atau dalam SpO₂ = 95-100%) [40]. Level oksigen dalam darah dibawah 80% dapat membahayakan fungsi organ tubuh, seperti otak dan jantung. Tingkat oksigen yang rendah berlanjut dapat menyebabkan serangan pernafasan atau jantung.

Pulse rate (PR) atau denyut nadi merupakan salah satu parameter yang mengekspresikan denyut jantung (*heart rate*), yang menggambarkan jumlah siklus jantung yang terjadi setiap menitnya atau *beats per minute* (bpm) [38]. Meskipun diekspresikan dalam bpm, pulse rate tidak selalu dibutuhkan untuk menilai frekuensi denyut selama full satu menit. Sebagai contoh, satu metode untuk menilai pulse rate yang melibatkan perhitungan jumlah beat selama 15 detik kemudian mengalikan nilai ini dengan 4, atau menghitung jumlah beat selama 30 detik, kemudian mengalikan nilai tersebut dengan 2, untuk mendapatkan pengukuran pulse rate dalam *beats per minute* (bpm). Level normal pulse rate pada rata-rata orang dewasa diantara 60-100 bpm. Namun jika didetailkan lagi, level normal wanita dewasa diantara 72-80 bpm dan laki-laki diantara 64-72 bpm [38]. Jika level pulse rate seseorang lebih dari 100 bpm, maka dapat didiagnosa orang tersebut

mengalami gejala *tachycardia*. Kondisi lain juga dikatakan seseorang mengalami gejala *bachycardia* jika level pulse rate kurang dari 60 bpm [38].



Gambar 2.4. Sensor Pulse oximeter Cooking Hacks dan cara pemasangan pada jari tangan [41]

Selanjutnya, Sinyal SpO_2 dan Pulse rate direpresentasikan sebagai kumpulan nilai SpO_2 dan Pulse rate yang direkam dalam rentang waktu dan berisi informasi dari sifat fisiologis seseorang berdasarkan metode PPG. Untuk mengukur sinyal SpO_2 dan Pulse rate dalam rentang waktu, penelitian ini menggunakan perangkat Sensor Pulse Oximeter. Pulse Oximeter adalah perangkat yang bekerja berdasarkan metode *photoplethysmogram* seperti yang dijelaskan di atas, dimana perangkat ini digunakan secara universal untuk monitoring pasien dalam pengaturan perawatan kritis [19]. Penelitian ini menggunakan Sensor Pulse Oximeter yang dikembangkan oleh Cooking Hacks. Sensor ini dapat mengukur level SpO_2 dan Pulse rate seseorang dengan memasang perangkat pada jari tangan (Gambar 2.4). Untuk dapat memonitor dan merekam SpO_2 dan Pulse rate pada perangkat komputer, diperlukan perangkat pendukung seperti E-health Platform V2.0, Arduino Uno Rev.3, Kabel USB dan Aplikasi Coolterm yang dijelaskan secara detail pada Bab 3 tentang Eksplorasi Hardware.

Pulse oximeter yang merupakan pengembangan dari Cooking Hacks berprinsip pada sifat hemoglobin yang mampu menyerap cahaya dan denyut alami aliran darah di dalam arteri. Alat ini dilengkapi dengan sumber cahaya, pendeteksi cahaya dan mikroposekor. Terdapat komponen dioda yang memancarkan dua jenis sinar yakni merah dan inframerah dengan panjang gelombang tertentu yang akan

diserap oleh darah. Kedua jenis sinar tersebut disebarkan melalui jaringan tubuh menuju pendeteksi cahaya yang terdapat pada sisi lain dari alat ini. Hemoglobin yang mengandung oksigen lebih banyak akan menyerap lebih banyak cahaya infra merah, sedangkan yang tidak memiliki oksigen akan menyerap cahaya merah. Lebih lanjut, gelombang yang diserap oleh darah, selanjutnya dipantulkan kembali dalam panjang gelombang tertentu yang kemudian akan dideteksi oleh pulse oximeter dan menginterpretasikan nilai SpO_2 dan Pulse rate. Selain itu, Pancaran cahaya melalui bagian tubuh yang relatif tembus dan memiliki aliran darah arteri yang berdenyut bagus, seperti jari, kaki dan daun telinga. Rasio cahaya merah terhadap cahaya inframerah yang melewati situs pengukuran dan diterima oleh detektor oximeter berdasarkan pada persentase dari oksigen terhadap hemoglobin teroksigenasi melalui cahaya yang lewat. Sementara itu, mikropesesor pada alat ini berguna untuk menghitung perbedaan kadar oksigen dan mengubah informasi tersebut ke dalam nilai digital. Nilai tersebut selanjutnya ditaksir untuk menentukan jumlah oksigen yang dibawa oleh darah.

Meskipun Sensor Pulse oximeter memiliki banyak kelebihan, termasuk presisi yang tinggi dan kemudahan penggunaan untuk semua orang, ada beberapa faktor yang menyebabkan terjadinya kesalahan pengukuran. Berdasarkan literatur yang ditulis oleh kontributor Konika Minolta [42] memberikan poin-poin yang perlu diperhatikan oleh pengguna tentang faktor-faktor penyebab kesalahan penggunaan dan langkah-langkah pencegahannya, diantaranya:

- 1) Hemoglobin abnormal. Darah mungkin mengandung hemoglobin abnormal seperti karbonsihemoglobin dan methemoglobin yang tidak berkontribusi terhadap pengiriman oksigen. Pulse oximeter dengan panjang gelombang ganda dapat dipengaruhi oleh hemoglobin abnormal ini.
- 2) Pewarna medis. Jika pewarna seperti kardio hijau, intravaskular dan hijau indosianin telah disuntikkan ke dalam darah, dapat mempengaruhi tingkat transmisi cahaya merah dan inframerah.
- 3) *Manicure* dan *pedicure*. Jika pengguna memakai cat kuku, mungkin akan menyerap cahaya yang dipancarkan oleh LED, mengubah cahaya yang ditransmisikan melalui tubuh, dan mempengaruhi nilai yang dihitung.

- 4) Gerakan tubuh utama. Gerakan tubuh dapat menyebabkan *noise* yang mempengaruhi nilai yang dihitung. Saat *noise*, termasuk yang disebabkan oleh gerakan tubuh, mengurangi reliabilitas nilai yang dihitung, maka pulse oximeter akan menampilkan peringatan.
- 5) Aliran darah terblokir karena tekanan pada lengan atau jari. Pulse oximeter mengukur saturasi atau kadar oksigen berdasarkan perubahan aliran darah. Oleh karena itu, jika aliran darah terhambat, pengukuran yang benar mungkin tidak terjadi. Selain itu, jika jari-jari dilipat dengan kecepatan yang seragam, pulse oximeter dapat menafsirkan tekanan sebagai perubahan denyut nadi yang menyebabkan kesalahan.
- 6) Kegagalan peredaran darah peripher. Pulse oximeter menggunakan aliran darah untuk memantau perubahan jumlah cahaya yang ditransmisikan untuk menghitung nilai. Jika aliran darah perifer berkurang, data yang memadai mungkin tidak didapatkan dan hasilnya adalah pengukuran yang tidak akurat. Dalam hal ini, perlu untuk mendorong aliran darah dengan memijat atau menghangatkan jari atau mengukur jari lainnya dengan aliran darah yang lebih teratur.
- 7) Lampu ambient yang berlebihan. Pulse oximeter biasanya bisa menghilangkan efek cahaya sekitar. Namun, jika lampu sekitar terlalu kuat, perangkat tidak akan bisa menghilangkan efeknya dan hal ini bisa menyebabkan kesalahan pengukuran.
- 8) Gelombang elektromagnetik ambient. Jika peralatan listrik seperti televisi, telepon genggam atau perangkat medis yang menghasilkan gelombang elektromagnetik tingkat tinggi digunakan di dekat pulse oximeter, gelombang elektromagnetik dari perangkat tersebut dapat mengganggu pengukuran yang akurat.
- 9) Probe tidak terpasang dengan benar. Jika probe tidak terpasang dengan benar, mungkin mendeteksi berbagai *noise*, sehingga pengukurannya tidak akurat.

2.2.4 Manula atau Lanjut Usia

Manula merupakan singkatan dari Manusia Usia Lanjut. Definisi mengenai dimulainya fase yang dinamakan usia senja atau lanjut usia menjadi

perdebatan oleh para pakar di bidang sosiologi. Definisi ini menurut Badan Kesehatan Dunia atau *World Health Organization* (WHO) diberbagai belahan dunia berbeda-beda, di Benua Amerika dan Eropa dikatakan lanjut usia dimana umur seseorang sudah memasuki umur lebih dari 60 tahun. Sementara di Afrika, orang dikatakan sudah memasuki usia lanjut dimana mereka berumur lebih dari 50 tahun [43]. Namun dengan banyaknya perbedaan mengenai definisi tentang usia lanjut ini, WHO mencari benang merah diantara banyak pendapat dari para pakar dengan mendefinisikan bahwa orang yang berusia tua/lanjut usia/manula adalah seseorang yang telah berumur lebih dari 50 tahun [43]. Berbeda dengan definisi para pakar dan WHO mengenai kriteria orang yang berusia lanjut, berdasarkan Peraturan Menteri Kesehatan Republik Indonesia Nomor 67 Tahun 2015 tentang Penyelenggaraan pelayanan kesehatan lanjut usia di pusat kesehatan masyarakat pasal 1 ayat 1 menyatakan bahwa Lanjut usia adalah seseorang yang telah mencapai usia di atas 60 tahun [44]. Selain itu Kemenkes RI juga mengelompokkan batasan umur lansia menjadi empat kelompok, diantaranya:

- a. Pertengahan umur usia lanjut (*virilitas*) yaitu masa pra atau persiapan usia lanjut yang menampakkan kematangan jiwa dan keperkasaan fisik (usia 45-54 tahun),
- b. Usia lanjut dini (*prasenium*) yaitu kelompok yang mulai memasuki masa usia lanjut dini (usia 55-64 tahun),
- c. Kelompok usia lanjut (*senium*) yaitu usia antara 65-69 tahun, dan
- d. Manula beresiko tinggi terhadap serangan berbagai penyakit degeneratif atau kardiovaskular (usia >70 tahun).

Manula merupakan kelompok umur pada manusia yang telah memasuki tahapan akhir dari fase kehidupannya. Pada fase ini, seseorang mengalami derajat penurunan kesehatan baik secara alamiah maupun akibat serangan penyakit [45], dan terjadi suatu proses yang disebut dengan *aging process* atau proses penuaan [46]. Proses penuaan adalah siklus kehidupan yang ditandai dengan tahapan-tahapan menurunnya berbagai fungsi organ tubuh. Perubahan ini ditandai dengan semakin rentannya tubuh terhadap berbagai serangan penyakit yang dapat menyebabkan kematian, seperti penyakit kardiovaskular dan pembuluh darah, pernafasan, pencernaan, endokrin dan sebagainya. Hal tersebut disebabkan seiring

meningkatnya usia sehingga terjadi perubahan dalam struktur dan fungsi sel, jaringan serta sistem organ. Kemenkes RI menemukan 10 penyakit yang sering menyerang manula di Indonesia, namun terdapat jenis penyakit yang mendominasi, diantaranya golongan penyakit tidak menular, penyakit kronik dan degeneratif, terutama golongan penyakit kardiovaskular [45].

2.2.5 Metode Stimuli dan Asesmen Emosi

Stimulan merupakan bagian dari respon stimuli yang berupa perubahan lingkungan internal atau eksternal yang dapat diketahui. Menurut Kamus Besar Bahasa Indonesia (KBBI) diartikan sebagai perangsang organisame bagian tubuh atau reseptor lain untuk menjadi aktif. Menurut Quigley K.S *et al.* [47] ada beberapa metode untuk menginduksi atau membangkitkan emosi manusia, diantaranya:

- 1) Stimuli film/video clip adalah metode untuk menstimuli seseorang dengan media suara dan gambar yang bergerak/video/film.
- 2) Stimuli gambar adalah metode stimuli dengan menggunakan media gambar dengan berbagai aturan dan komposisi warna yang dapat merangsang emosi. Pada penelitian tentang induksi emosi, salah satu jenis gambar yang sering dijadikan peneliti untuk menginduksi emosi adalah gambar dari *International Affective Picture Systems (IAPS)*.
- 3) Metode ekspresi wajah. Metode ini dilakukan dengan cara partisipan mengekspresikan wajah mereka sesuai dengan kriteria emosi tertentu. Selanjutnya komputer akan merekam dan menampilkan ekspresi wajah secara digital pada layar komputer dan memprosesnya.
- 4) Stimuli suara dan musik adalah metode stimuli dengan memberikan induksi berupa suara atau musik yang dapat merangsang emosi.
- 5) Stimuli hipnotis adalah metode stimuli dengan media hipnotis. Metode ini sangat jarang digunakan dalam penelitian induksi emosi.
- 6) Stimuli *Virtual Reality*. Teknik stimuli ini dilakukan dengan cara memasang alat yang dinamakan *virtual reality*. Dengan metode ini, memungkinkan seseorang seakan-akan dalam keadaan yang sebenarnya.
- 7) Stimuli *Real-world* merupakan teknik stimuli yang dilakukan dengan menggunakan hal-hal yang ada disekitar kita tanpa ada batasan dari masing-

masing orang. Misalkan untuk membangkitkan rasa takut pada seseorang tentunya dilakukan dengan mendekatkan sesuatu yang ditakuti oleh orang tersebut. Misalnya dengan mendekatkan orang yang takut ketinggian pada sebuah jembatan.

Dari beberapa metode yang dikemukakan tersebut, pada penelitian ini menggunakan metode stimuli berupa video clip. Seperti halnya stimuli lain, jenis metode ini dapat merepresentasikan keadaan pada dunia nyata dan sering digunakan para peneliti di bidang *affective computing* untuk menginduksi emosi dari partisipan [8], [14], [26], [17]. Penelitian ini menggunakan video clip yang telah divalidasi oleh Rumpa *et al.* [29]. Validasi tersebut melibatkan 30 orang partisipan untuk menilai kriteria video berdasarkan emosi dasar, seperti senang, marah, sedih, jijik, takut dan kaget. Pada penelitian ini menggunakan tiga jenis video terkategori senang, sedih dan marah. Pemilihan tiga jenis ini dengan alasan bahwa ketiga emosi ini sering dihadapi dan dirasakan oleh para masyarakat, terutama kelompok manula saat menonton video ataupun sinetron.

Asesmen atau penilaian tentang emosi yang dirasakan oleh partisipan saat menonton video clip adalah dengan cara *self reported* atau *self assesmen*. Hal ini dilakukan karena emosi hanya dapat dikenali oleh orang itu sendiri. Walaupun terkadang orang lain bisa menebak emosi yang dirasakan dari ekspresi dan mimik yang ditampilkan oleh orang yang merasakan emosi. Misalnya orang yang menangis. Dari ekspresi tersebut sebagian besar orangpun mengira bahwa orang yang sedang menangis tersebut sedang merasakan emosi sedih. Namun agar emosi yang dirasakan dapat dipertanggungjawabkan secara ilmiah, penelitian ini menggunakan kuisioner sebagai media penilaian atau asesmen dari partisipan yang telah diinduksi stimulan video. Kuisioner ini digunakan setelah partisipan selesai menonton video stimuli yang mengacu pada kuisioner yang digunakan oleh peneliti terdahulu Rottenberg *et al.* [48]. Kuisioner ini merupakan kuisioner hasil modifikasi dari *post film questionnaire* yang dibuat oleh Rottenberg *et al.* [48] dalam menilai induksi emosi partisipan.

2.2.6 Ekstraksi Fitur Sinyal SpO₂ dan Pulse Rate

Ekstraksi fitur merupakan bagian yang paling penting dalam penelitian pengenalan pola. Kinerja dari algoritma klasifikasi dipengaruhi dari pemilihan metode ekstraksi fitur yang digunakan. Fitur didefinisikan sebagai sebuah variabel input atau atribut. Sehingga proses ekstraksi fitur merupakan proses pencarian ciri-ciri unik dari sebuah variabel input atau atribut yang berupa sinyal fisiologis, dalam hal ini sinyal SpO₂ dan Pulse rate, agar masing-masing kelas dapat dikenali oleh algoritma klasifikasi. Pada penelitian ini metode ekstraksi fitur yang digunakan adalah metode ekstraksi fitur statistik pada domain waktu. Penelitian ini memanfaatkan parameter statistik yang dideskripsikan pada bagian dibawah ini:

- 1) Rata-rata (*mean*) merupakan ukuran tendensi sentral yang didefinisikan sebagai nilai rata-rata dari suatu distribusi. Nilai rata-rata dinyatakan dengan persamaan berikut :

$$X_{\mu} = \frac{1}{n} \sum_{i=1}^N x_i \quad (2.6)$$

Keterangan:

μ = rata-rata (*mean*)

$\sum_{i=1}^N x_i$ = penjumlahan data yang dimulai dari $i = 1$ sampai ke- n

N = Banyaknya data

- 2) Standar deviasi merupakan ukuran sebaran (*dispersi*) suatu distribusi. Jika suatu distribusi flat atau rata, maka nilai standar deviasinya kecil sedangkan jika suatu distribusi berfluktuasi (tidak rata) maka nilai standar deviasinya besar. Standar deviasi dirumuskan oleh persamaan berikut:

$$X_{\sigma} = \sqrt{\sum_{i=1}^N (x_i - \mu)^2 \frac{1}{N-1}} \quad (2.7)$$

Keterangan:

σ = standar deviasi

$\sum_{i=1}^N (x_i - \mu)^2$ = penjumlahan dari kuadrat selisih data ke- i dengan rata-rata

N = Banyaknya data

- 3) Nilai maksimum merupakan nilai maksimal dari level SpO₂ dan Pulse rate dalam rentang waktu. Persamaan berikut digunakan untuk mendapatkan nilai maksimum dari sinyal SpO₂ dan pulse rate.

$$X_{maks} = \max[x_n] \quad (2.8)$$

Keterangan:

x_n = data dalam rentang waktu

- 4) Nilai minimum dari level SpO₂ dan pulse rate dalam rentang waktu. Berikut persamaan untuk mendapatkan nilai minimum.

$$X_{min} = \min[x_n] \quad (2.9)$$

- 5) *Mode* (modus) merupakan nilai yang sering muncul dari SpO₂ dan pulse rate dalam rentang waktu.

$$X_{mo} = T_b + \left(\frac{d_1}{d_1 - d_2} \right) c \quad (2.10)$$

Keterangan:

mo = modus

T_b = tepi bawah kelas modus (kelas dengan frekuensi tertinggi)

d_1 = selisih antara frekuensi modus dengan frekuensi sebelumnya

d_2 = selisih antara frekuensi modus dengan frekuensi sesudahnya.

c = kelas

- 6) Varians merupakan salah satu ukuran dispersi atau ukuran variasi dari data. Varians disimbolkan σ^2 (baca: sigma kuadrat) untuk populasi dan s^2 untuk sampel. Berikut rumus mencari varians.

$$X_{s^2} = \sum_{i=1}^N (x_i - \mu) \cdot \frac{2}{N-1} \quad (2.11)$$

- 7) Rasio dirumuskan seperti persamaan berikut.

$$X_{rasio} = \frac{X_{max}}{X_{min}} \quad (2.12)$$

- 8) *Mean Absolute Deviation (MAD)* adalah metode yang digunakan untuk mengukur tingkat akurasi dari suatu peramalan data. Semakin kecil nilainya, maka peramalan tersebut semakin akurat. Persamaan berikut yang digunakan untuk mendapatkan nilai MAD:


$$X_{MAD} = \frac{1}{N} \sum_{i=1}^N |x_i - \mu| \quad (2.13)$$

Simbol X pada persamaan 1 – 8 merepresentasikan sinyal SpO₂ dan pulse rate. Sehingga semua fitur-fitur dinotasikan sebagai SpO_{2μ}, SpO_{2σ}, SpO_{2maks},

$SpO2_{min}$, $SpO2_{mo}$, $SpO2_{var}$, $SpO2_{rasio}$, $SpO2_{MAD}$, PR_{μ} , PR_{σ} , PR_{maks} , PR_{min} , PR_{mo} , PR_{var} , PR_{rasio} , dan PR_{MAD} .

2.2.7 Support Vector Machine

Support Vector Machine (SVM) atau juga disebut *Support Vector Networks* adalah algoritma pembelajaran *supervised* (*supervised learning model*) yang dikembangkan oleh Vladimir Vapnik dan Corinna Cortes [49]. Algoritma pembelajaran ini bisa digunakan untuk klasifikasi dan regresi. Tujuan dari algoritma pembelajaran SVM adalah untuk mendapatkan bidang pemisah (*hyperplane*) terbaik yang tidak hanya meminimalkan *empirical risk* yaitu rata-rata error pada data pelatihan (*training data*), tetapi juga memiliki generalisasi yang baik [50]. Generalisasi ini diartikan sebagai kemampuan sebuah hipotesis untuk mengklasifikasi data yang tidak terdapat dalam data pelatihan dengan benar. Untuk menjamin generalisasi ini, algoritma SVM didasarkan pada prinsip *Structural Risk Minimization* (SRM). Konsep klasifikasi yang pertama kali dikenalkan oleh V. Vapnik dan C. Cortes masih dalam kasus klasifikasi binary, yaitu klasifikasi dalam kasus dua kelas. Dalam klasifikasi, SVM dapat bekerja pada kasus klasifikasi *linear* dan *nonlinier* seperti yang diilustrasikan pada gambar 2.5. Pada klasifikasi kasus *linear*, SVM dibedakan menjadi dua kasus yakni *linearly separable* dan *linearly non-separable*.



Gambar 2.5. (a) Fungsi klasifikasi *linear* pada kasus *linearly separable*, (b) Fungsi klasifikasi *linear* yang berbeda (1) dan (2) dan fungsi *non-linier* (3) pada kasus *linearly non-separable*

2.1.9.1. SVM pada Kasus *Linearly Separable*

Linearly separable merupakan kasus klasifikasi pada data yang dapat dipisahkan secara linier. Definisi mengenai SVM pada kasus *linearly separable* ini dimulai dari sebuah fungsi *classifier* linier f dideskripsikan dengan sebuah fungsi kelas $\mathcal{F}$. Keluarga $\mathcal{F}$ fungsi klasifikasi para ruang data diberikan oleh:

$$\mathcal{F} = \{x^T w + b, w \in R^p, b \in R\} \quad (2.14)$$


Pertama yang dilakukan adalah memilih $f \in \mathcal{F}$ (atau ekuivalen (w, b)) untuk menentukan *support vector* yang disebut dengan memaksimalkan margin (margin adalah koridor antara *hyperplane* pemisah). Gambar 2.6 menunjukkan proses klasifikasi dua kelas pada SVM. Dimana $d_+ + d_-$ adalah margin. Fungsi klasifikasi adalah *hyperplane* plus zona margin, dimana fungsi ini memisahkan titik dari dua kelas dengan jarak (margin) “paling aman” tertinggi diantara kedua data klasifikasi. Dua tanda silang dan satu lingkaran yang di-bold adalah *support vector*. $x^T w + b = 0$ adalah *hyperplane* pemisah. Kemudian d_+ (d_-) akan menjadi jarak paling dekat dengan objek terdekat dari kelas $+1$ (-1). Karena pemisahan dapat diselesaikan tanpa error, semua observasi $i = 1, 2, \dots, n$ harus memenuhi:

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

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

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

$$y_i(x^T w + b) - 1 \geq 0, i = 1, 2, \dots, n \quad (2.15)$$



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

Bidang pemisah kanonik (*canonical hyperplanes*) $x^T w + b = \pm 1$ adalah sejajar dan jarak antara masing-masing konstrain dan *hyperplane* pemisah adalah $d_+ = d_- = \frac{1}{\|w\|}$, dimana w adalah vektor bobot (*weight vector*), b adalah posisi

bidang relatif terhadap pusat koordinat atau bias yang bernilai skalar. Gambar 2.6.

menunjukkan $\frac{|b|}{\|w\|}$ adalah jarak bidang pemisah yang tegak lurus dari titik pusat koordinat dan $\|w\|$ adalah jarak *euclidean* dari w . Panjang vector w adalah norm $\|w\| = \sqrt{w^T w}$. Bidang pembatas pertama $x_i^T w + b = 1$ mempunyai bobot w dan

jarak tegak lurus dari titik asal sebesar $\frac{|1-b|}{\|w\|}$, sedangkan bidang pembatas kedua $x_i^T w + b = -1$ mempunyai bobot w dan tegak lurus dari titik asal sebesar $\frac{|-1-b|}{\|w\|}$.

Sehingga didapatkan nilai maksimum margin antar bidang pembatas adalah:

$$\frac{1-b-(-1-b)}{\|w\|} = \frac{2}{\|w\|} \quad (2.16)$$

Nilai margin ini dimaksimalkan dengan tetap memenuhi konstrain. Karena, memaksimalkan $\frac{1}{\|w\|}$ sama dengan meminimumkan $\|w\|^2$, maka pencarian bidang pemisah terbaik dengan nilai margin terbesar dapat dirumuskan menjadi masalah optimasi konstrain yaitu:

$$\min \frac{1}{2} \|w\|^2 \quad (2.17)$$

Dengan fungsi kendala $y_i(x_i^T w + b) \geq 1, i = 1, 2, \dots, n$

Secara umum, persoalan ini lebih mudah diselesaikan jika diubah ke dalam formula *lagrangian*. Lagrangian dari *primal problem* (L_p) yang berhubungan dengan maksimalisasi margin adalah:

$$L_p(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i [y_i(x_i^T w + b) - 1] \quad (2.18)$$

Karush-Kuhn-Tucker (KKT) kondisi optimal order pertama adalah:

$$\frac{\partial L_p}{\partial w} = 0 : w - \sum_{i=1}^n \alpha_i y_i x_i = 0$$

$$\frac{\partial L_p}{\partial w} = 0 : \sum_{i=1}^n \alpha_i y_i = 0$$

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

$$\alpha_i \geq 0$$

$$\alpha_i \{y_i(x_i^T w + b) - 1\} = 0$$

Substitusi hasil KKT (*primal problem*) pada persamaan 2.18, didapatkan lagrangian untuk dual problem (L_D) dengan konstrain berbeda:

$$L_D(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j x_i x_j \quad (2.19)$$

Primal (L_P) dan dual (L_D) problem adalah:

$$\begin{aligned} & \min_{w,b} L_P(w,b) \\ & \max_{\alpha} L_D(\alpha) \quad \text{s.t.} \quad \alpha_i \geq 0, \sum_{i=1}^n \alpha_i y_i = 0 \end{aligned}$$

Karena masalah optimasi adalah convex, sehingga formula dual dan primal memberikan solusi yang sama.

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

$$g(x) = \text{sign}(x^T w + b) \quad (2.20)$$

Keterangan:

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

$$f(x) = x^T w + b \quad (2.21)$$

Masing-masing skor $f(x)$ berhubungan secara unik terhadap sebuah *default probability* (PD). Semakin tinggi nilai $f(x)$ maka semakin tinggi pula PD [51].

2.1.9.2. SVM pada Kasus *Linearly Non-separable*

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

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


$$x_i^T w + b \leq -1 + \xi_i \text{ untuk } y_i = -1,$$

$$\xi_i \geq 0.$$

Fungsi tersebut dikombinasikan menjadi dua konstrain:

$$y_i(x_i^T w + b) \geq 1 - \xi_i \quad (2.22)$$

$$\xi_i \geq 0.$$



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

Pinalti untuk kesalahan klasifikasi, error klasifikasi $\xi_i \geq 0$, dihubungkan dengan jarak dari titik kesalahan klasifikasi x_i terhadap *cononical hyperplane* yang membatasi kelasnya. Sehingga fungsi objektif yang sesuai terhadap maksimalisasi margin yang dipinalti diformulasikan menjadi persamaan berikut:

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (2.23)$$

Keterangan:

C : Parameter yang menentukan besar pinalti akibat kesalahan data klasifikasi dan nilainya ditentukan oleh pengguna.

Meminimalkan fungsi objektif 2.23 dengan konstrain 2.22 memberikan kemungkinan margin terbesar dalam bidang pemisah. Selanjutnya, fungsi Lagrange untuk *primal problem* adalah:

$$L_P(w, b, \alpha, \mu, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i - \sum_{i=1}^n \alpha_i \{y_i(x_i^T w + b) - 1 + \xi_i\} - \sum_{i=1}^n \mu_i \xi_i \quad (2.24)$$

Keterangan :

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

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

Kondisi orde pertama pada kasus ini adalah:

$$\frac{\partial L_P}{\partial w} = 0 : w - \sum_{i=1}^n \alpha_i y_i x_i = 0$$

$$\frac{\partial L_P}{\partial w} = 0 : \sum_{i=1}^n \alpha_i y_i = 0$$

$$\frac{\partial L_P}{\partial \xi_i} = 0 : C - \alpha_i - \mu_i = 0$$

Dengan kondisi untuk pengali *lagrange*:

$$\alpha_i \geq 0 \text{ dan } \mu_i \geq 0$$

$$\alpha_i \{y_i(x_i^T w + b) - 1 + \xi_i\} = 0$$

$$\mu_i \xi_i = 0$$

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

$$L_D(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j x_i^T x_j, \quad (2.25)$$

Dan *dual problem* sebagai berikut:


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

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

2.1.9.3. Klasifikasi Non-linear SVM

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

Ilustrasi dari kasus ini ditunjukkan pada gambar 2.8 berikut:



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

Fungsi transformasi pada SVM adalah menggunakan “*Kernel Trick*”. *Kernel trick* adalah menghitung *scalar product* melalui sebuah fungsi kernel $K(x_i, y_i) = \psi(x_i)^T \psi(y_i)$, kemudian kernel trick tersebut dapat digunakan tanpa mengetahui transformasi ψ secara eksplisit [51]. Syarat sebuah fungsi untuk menjadi fungsi kernel adalah memenuhi *teorema mercer* yang menyatakan bahwa matriks kernel yang dihasilkan harus bersifat *positive definiteness*, sehingga untuk beberapa dataset $x_1, \dots, x_n$ dan beberapa bilangan real $\lambda_1, \dots, \lambda_n$, fungsi K harus memenuhi.

$$\sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j K(x_i, x_j) \geq 0 \quad (2.26)$$

Beberapa fungsi kernel yang umum digunakan, diantaranya:

- Kernel linier

$$K(x_i, x_j) = x_i^T x_j \quad (2.27)$$

- Kernel Polinomial

$$K(x_i, x_j) = (\delta x_i^T x_j + r)^P, \delta > 0 \quad (2.28)$$

- Kernel *Radial basis Function* (RBF)

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0 \quad (2.29)$$

- Kernel sigmoid

$$K(x_i, x_j) = \tanh(\delta x_i^T x_j + r) \quad (2.30)$$

Fungsi kernel yang direkomendasikan untuk pertama kali dicoba menurut Hsu *et al.* [52] adalah fungsi kernel RBF karena memiliki performansi yang sama

dengan kernel linier pada parameter tertentu (C, λ) dan lebih *robust* terhadap *outlier* karena range fungsi kernel RBF antara $(-\infty, \infty)$, sedangkan fungsi kernel lain memiliki rentang $(-1, 1)$ atau $(0, 1)$. Hsu et al [52] juga merekomendasikan pengujian SVM yang menggunakan kernel RBF dengan urutan percobaan parameter C dan λ yang bertambah secara eksponensial untuk mengidentifikasi parameter terbaik ($C = 2^{-5}, 2^{-3}, \dots, 2^{15}$ dan $\gamma = 2^{-15}, 2^{-13}, \dots, 2^3$) agar terhindar dari kasus *overfitting*.

2.1.9.4. Klasifikasi SVM pada Kasus *Multiclass*

SVM saat pertama kali dikenalkan oleh Vapnik hanya dapat mengklasifikasikan data ke dalam dua kelas (klasifikasi biner) [49]. Penelitian lebih lanjut terus dilakukan untuk mengembangkan SVM sehingga dapat diimplementasikan kedalam masalah klasifikasi lebih dari dua kelas (*multi class*). Beberapa metode yang umum digunakan untuk kasus klasifikasi *multi class* SVM diantaranya: pendekatan *One-against-all* SVM, *One-against-one* SVM, DAGSVM (*Directed Acyclic Graph Support Vector Machine*), ECOC SVM (*Error-correcting Output-Code Support Vector Machine*), dan *All-at-once* SVM. Pada penelitian ini, implementasi SVM untuk kasus tiga kelas (senang, sedih dan marah) dimana dalam hal ini terkategori kasus *multiclass*. Untuk mengatasi hal tersebut, penelitian ini memanfaatkan *Library Support Vector Machine* (LibSVM) yang dikembangkan oleh Chang dan Lin [53]. Library ini menyediakan algoritma untuk kasus *multiclass* dengan pendekatan *One-against-one* SVM. Pendekatan *One-against-one* SVM disebut juga pendekatan *Pairwise* SVM. Dimana dalam pendekatan ini, semua kombinasi pasangan kelas ditentukan oleh fungsi keputusan. Dalam menentukan fungsi ini, setiap model klasifikasi dilatih pada data dari dua kelas. Hingga, setiap proses pelatihan, jumlah data latih dikurangi dengan jumlah yang besar [54].

Dengan menggunakan pendekatan ini, dibangun $\frac{n(n-1)}{2}$ buah model klasifikasi dimana n = jumlah kelas. Dimisalkan fungsi keputusan untuk data pelatihan dari kelas ke- i dan ke- j , dengan margin maksimum menjadi:

$$D_{ij}(x) = w_{ij}^T g(x) + b_{ij}, \quad (2.31)$$

Keterangan:

w_{ij} : Vektor dimensi l , $g(x) = \text{sign}(x^T w + b)$ adalah sebuah fungsi mapping yang memetakan menjadi *feature space* dimensi l ,

b_{ij} : adalah *bias term* dan $D_{ij}(x) = -D_{ij}(x)$.

Daerah $R_i = \{x \mid D_{ij}(x) > 0, j = 1, \dots, n \text{ dan } j \neq i\}$ tidak *overlap*, dan jika x didalam R_i , maka x diklasifikasikan kedalam kelas i . Jika x tidak didalam $R_i (i = 1, \dots, n)$, maka x diklasifikasikan secara *voting*. Yaitu, untuk vector input atau *data space*, dihitung dengan persamaan:


$$D_{ij}(x) = \sum_{j \neq i, j=1}^n \text{sign}(D_{ij}(x)), \quad (2.32)$$

dimana,

$$\text{sign}(x) = \begin{cases} 1, & x \geq 0 \\ -1, & x < 0 \end{cases} \quad (2.33)$$

dan mengklasifikasikan x ke dalam kelas

$$\arg \max_{i=1, \dots, n} D_{ij}(x) \quad (2.34)$$



Gambar 2.9. Ilustrasi klasifikasi vektor data dalam pendekatan *One-against-one* atau *pairwise SVM* dimana daerah yang diarsir adalah daerah yang tidak terklasifikasi oleh formula *pairwise*

Jika $x \in R_i$, $D_{ij}(x) = n - 1$ dan $D_k(x) < n - 1$ untuk $k \neq i$. Sehingga demikian, x diklasifikasikan ke dalam i . Tetapi beberapa dari $D_i(x) \neq n - 1$, walaupun persamaan 2.34 dapat memenuhi is jamak. Didalam kasus ini, beberapa x tidak terklasifikasi seperti yang diilustrasikan daerah yang diarsir pada gambar 2.9. Dalam daerah yang diarsir berada pada persamaan $D_i(x) = 0, (i = 1, 2, 3)$.

Dalam pendekatan *One-against-one* atau *pairwise* SVM ini, daerah yang tidak terklasifikasi ini jauh lebih kecil daripada pendekatan lain, terutama dibandingkan dengan pendekatan *One-against-all*. Hal ini juga sependapat dengan Hsu dan Lin yang memberikan perbandingan detail dari beberapa pendekatan yang biasa digunakan dan menemukan bahwa pendekatan “*One-against-one* atau *pairwise* SVM” adalah sebuah pendekatan kompetitif [52].

2.2.8 K-Nearest Neighbors

K-Nearest Neighbour (kNN) merupakan salah satu tipe pembelajaran non-parametrik yang digunakan untuk masalah klasifikasi dan regresi data [55]. Algoritma kNN termasuk dalam model pembelajaran *supervised* (*supervised learning algorithm*). Istilah lain dari algoritma kNN selain non-parametrik adalah *instance-based learning* atau *lazy learning*, dimana fungsinya hanya didekati secara lokal dan semua perhitungan ditangguhkan hingga klasifikasi [56]. Mitchell mengungkapkan bahwa algoritma kNN ini merupakan jenis algoritma yang paling simple dibandingkan dengan semua algoritma *machine learning* yang lain. Algoritma kNN mengasumsikan semua *instance* atau sampling data berkorespondensi terhadap titik-titik di ruang dimensi n atau disimbolkan dengan $\mathcal{R}^n$ [56]. kNN menyimpan seluruh data latih dan menampilkan hanya jika atribut berdasarkan data latih yang jaraknya paling dekat dengan objek tersebut. Tetangga terdekat dari sebuah *instance* atau objek data didefinisikan dengan istilah standar rumus jarak (*distance function*). Beberapa rumus jarak yang populer digunakan dalam algoritma kNN diantaranya rumus jarak *Euclidean*, *Manhattan*, *Mahalanobis*, *Minkowski*, *Hamming* dan *Chebyshev*. Rumus jarak *Euclidean* merupakan fungsi jarak standar dari algoritma kNN yang paling sering digunakan oleh para peneliti [56]. Beberapa peneliti menguji mengenai performansi rumus jarak ini, salah satunya adalah Hu *et al.* yang mengujikan beberapa fungsi jarak pada dataset medis [57]. Mereka mendapatkan bahwa rumus jarak *Euclidean* memiliki performansi yang lebih bagus dalam hasil klasifikasi pada dataset medis yang mereka gunakan.

Dimisalkan sebuah *instance* data x dideskripsikan oleh vektor fitur $(\alpha_1(x), \alpha_2(x), \dots, \alpha_n(x))$, dimana $\alpha_r(x)$ melambangkan nilai atribut ke- r dari *instance* x . Kemudian jarak antara dua *instance* x_i dan x_j didefinisikan menjadi $d(x_i, x_j)$ dengan rumus jarak *Euclidean*, dimana:

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^n (\alpha_r(x_i) - \alpha_r(x_j))^2} \quad (2.35)$$

Pada pembelajaran tetangga-terdekat (*nearest-neighbors*), fungsi target tidak hanya bernilai diskrit tapi juga bernilai riil. Dimisalkan pada fungsi target pembelajaran bernilai diskrit $f : \mathbb{R}^n \rightarrow V$, dimana V adalah bentuk data terbatas $\{v_1, \dots, v_s\}$. Algoritma kNN untuk pendekatan fungsi target bernilai diskrit dijelaskan pada tabel 2.1.

Algoritma pelatihan:

- Untuk masing-masing data latih $(x, f(x))$, tambahkan data kedalam data latih.

Algoritma klasifikasi:

- Diberikan sebuah data uji x_q untuk diklasifikasi, misalkan $x_1, \dots, x_k$ melambangkan *instance* k dari data training
- Hitung dengan rumus jarak Euclidean dan tentukan jarak terdekat dengan x_q
- Ulangi

$$\hat{f}(x_q) \leftarrow \underset{v \in V}{\operatorname{argmax}} \sum_{i=1}^k \delta(v, f(x_i)) \quad (2.36)$$

dimana $\delta(a, b) = 1$ jika $a=b$ dan $\delta(a, b) = 0$ lainnya.

Tabel 2.1. Algoritma kNN untuk pendekatan fungsi bernilai diskrit $f : \mathbb{R}^n \rightarrow V$

Seperti yang ditunjukkan pada tabel 2.1, nilai $\hat{f}(x_q)$ yang diulang oleh algoritma kNN sebagai perkiraannya $f(x_q)$ hanya nilai yang paling banyak ditemui dari f diantara data latih. Hitung dengan rumus jarak Euclidean dan tentukan jarak yang paling dekat dengan x_q . Jika kita pilih $k = 1$, kemudian algoritma 1-NN menetapkan $\hat{f}(x_q)$ ke nilai $f(x_i)$ dimana x_i adalah data latih yang paling dekat dengan x_q . Untuk nilai k yang lebih besar, algoritma kNN menetapkan nilai yang paling banyak ditemui pada k buah tetangga terdekat titik tersebut. Konsep lain yang menjadi perdebatan hingga kini adalah penentuan besar parameter k yang menentukan berapa banyak tetangga yang akan dipilih untuk algoritma kNN.

Pemilihan nilai k yang sesuai memberikan pengaruh signifikan pada kinerja algoritma kNN [58]. Beberapa peneliti merekomendasikan untuk memilih $k = \sqrt{n}$, $k = 30$, 45 dan 60.

Dalam kasus fungsi target bernilai riil atau kontinu, algoritma kNN dapat disesuaikan dengan lebih mudah. Yakni dengan cara menghitung nilai rata-rata dari k buah terdekat dari data latih. Lebih tepatnya, untuk pendekatan fungsi target bernilai riil $f: \mathcal{R}^n \rightarrow \mathcal{R}$, persamaan 2.36 pada tabel 2.1 diganti dengan persamaan berikut:

$$\hat{f}(x_q) \leftarrow \frac{\sum_{i=1}^k f(x_i)}{k} \quad (2.37)$$

2.2.9 K-fold Cross Validation

Dalam kasus klasifikasi dan prediksi data, sebuah data dibagi menjadi dua subset yakni data latih atau *training* dan data uji atau *testing*. Proporsi pembagian data latih dan data uji, para pakar merekomendasikan beberapa penggunaan proporsinya, seperti 70% sebagai data latih dan 30% lainnya sebagai data uji. Selain itu juga ada yang merekomendasikan untuk menggunakan 80:20 atau 90:10. Dalam teori pembagian secara konvensional, penguji data hanya membagi sekamuan sendiri proporsi data yang menjadi data latih dan uji. Hal ini tak jadi masalah jika data yang dibagi sebagai data latih dan uji tersebut merepresentasikan keseluruhan data. Sehingga jika dicoba diklasifikasi dengan pembagian yang berbeda, akurasi klasifikasi tidak jauh berbeda dengan hasil klasifikasi pada percobaan sebelumnya. Namun yang menjadi permasalahan adalah data yang dibagi sebagai data latih dan uji tersebut tidak merepresentasikan seluruh data. Hal ini sering dijumpai dalam permasalahan pembagian data latih dan uji secara konvensional atau manual, kasus ini dinamakan dengan *overfitting*. Salah satu metode yang sering dipakai oleh para peneliti agar terhindar dari kasus *overfitting* adalah dengan menggunakan metode *Cross Validation*.

Cross validation adalah sebuah model teknik validasi untuk penilaian kinerja dari sebuah algoritma analisa statistik seperti klasifikasi dan prediksi yang akan membagi data menjadi dua segmen, yakni satu segmen digunakan sebagai data latih dan segmen lainnya digunakan untuk memvalidasi sebuah model algoritma

atau data uji [59]. Ada beberapa metode yang termasuk dalam jenis metode *Cross validation*, diantaranya *Resubstitution validation*, *Hout-out validation*, *k-fold cross validation*, *Leave-One-Out cross validation* dan *Repeated k-fold cross validation*. Refaeilzadeh et al mengatakan bahwa metode *k-fold cross validation* adalah bentuk dasar dari metode *Cross validation* yang sering digunakan oleh para peneliti karena terbukti ampuh untuk menggeneralisasi data ke dalam sebuah subset independen agar terhindar dari kasus *overfitting* [59]. Dalam teknik *k-fold cross validation* ini, pertama dataset dipartisi menjadi sejumlah K-buah partisi/segmen/lipatan (*folds*) yang sama (atau hampir sama) secara acak. Kemudian dilakukan sejumlah K-kali iterasi eksperimen, dimana masing-masing eksperimen menggunakan data partisi atau lipatan ke-K sebagai data latih dan memanfaatkan sisa partisi atau lipatan lainnya (K-1) sebagai data uji atau validasi. Gambar 2.10 mengilustrasikan metode *k-folds cross validation* dengan $K = 3$. Pada bidang *data mining* dan *machine learning* *10-fold cross validation* ($k = 10$) yang paling sering dipilih oleh para peneliti untuk menguji dalam kasus klasifikasi data [59].



Gambar 2.10. Ilustrasi *k-folds cross validation*, dengan $K=3$

2.2.10 Evaluasi Performansi Metode Klasifikasi

Performansi dari sebuah algoritma klasifikasi menunjukkan kemampuan metode algoritma yang diusulkan untuk memprediksi suatu data. Hasil dari klasifikasi data ini disusun dalam sebuah tabel *confusion matrix* seperti tabel 2.2 berikut ini:

Tabel 2.2. Tabel *Confusion Matrix*

		Kelas prediksi	
		Positif	Negatif
Kelas Aktual	Positif	TP	FN
	Negatif	FP	TN

Keterangan:

TP : Banyaknya data yang diprediksi benar pada kelas positif

FP : Banyaknya data yang diprediksi salah pada kelas positif

TN : Banyaknya data yang diprediksi benar pada kelas negatif

FN : Banyaknya data yang diprediksi salah pada kelas negatif

Dari tabel *confusion matrix* tersebut dapat dihitung menjadi beberapa parameter penilaian, pada penelitian ini menggunakan parameter nilai akurasi, presisi, Skor F_1 .

- 1) Akurasi (ACC) adalah parameter untuk menilai keseluruhan efektivitas algoritma yang diusulkan dengan memperkirakan probabilitas nilai benar dari label kelas. Nilai dari akurasi dinyatakan dengan persamaan berikut:

$$\text{Akurasi} = \frac{TN+TP}{TN+TP+FN+FP} \quad (2.38)$$

- 2) Presisi atau *positive predictive value* (PPV)

$$\text{Presisi} = \frac{TP}{TP+FP} \quad (2.39)$$


- 3) Skor F_1 atau *F-measure* merupakan salah satu perhitungan evaluasi pengukuran performansi yang mengkombinasikan parameter *recall* dan *presicion* atau presisi. Nilai dari Skor F_1 dinyatakan dengan persamaan berikut ini:

$$F_1 = 2 \times \frac{\text{Presisi} \cdot \text{recall}}{\text{Presisi} + \text{Recall}} \quad (2.40)$$

BAB 3

METODOLOGI PENELITIAN

Bab ini membahas mengenai metodologi penelitian yang memuat langkah-langkah dan desain dari penelitian yang dilakukan. Langkah dan desain penelitian ini digunakan untuk mencapai tujuan penelitian yang diinginkan, yakni tentang klasifikasi tiga emosi dasar berdasarkan sinyal SpO_2 dan pulse rate pada manula. Berikut metodologi yang dilakukan dalam penelitian ini.



Gambar 3.1. Metodologi Penelitian

3.1 Tahap Awal

Tahap awal merupakan tahap persiapan sebelum melakukan penelitian. Perencanaan penelitian yang matang merupakan kunci utama keberhasilan dari penelitian yang dilakukan, sehingga perlu dikaji lebih mendalam dari beberapa aspek yang mencakup penelitian. Tahap awal penelitian ini terdiri atas:

3.1.1 Studi Literatur

Studi Literatur merupakan tahapan analisis permasalahan mutakhir pada bidang *affective computing*, khususnya penelitian mengenai pengenalan emosi berdasarkan sinyal fisiologis. Literatur yang dijadikan rujukan diantaranya buku, paper proceeding dan jurnal terutama di *IEEE Xplore*, *Scimedirect*, *Springer*, *Pubmed* dan website penyedia jurnal lainnya tentang penelitian terdahulu dan teori yang mendukung dan membahas mengenai pengenalan fisiologi emosi manusia berdasarkan sinyal SpO_2 dan pulse rate, sensor pulse oximeter, metode ekstraksi fitur sinyal-sinyal fisiologis, algoritma klasifikasi dan lainnya yang berkaitan

dengan penelitian. Hasil studi literatur ini dijadikan pedoman utama untuk melakukan eksplorasi dan proses penelitian hingga mendapatkan hasil dan kesimpulan.

3.1.2 Eksplorasi Hardware

Eksplorasi Hardware merupakan tahap pemilihan jenis *hardware* yang digunakan dan tahapan konfigurasi untuk mendapatkan dataset sinyal fisiologis emosi berupa sinyal SpO₂ dan pulse rate. Pada tahap ini, beberapa *hardware* yang dipersiapkan diantaranya:

- 1) Sensor Pulse oximeter
- 2) Modul *E-Health sensor platform V2.0*
- 3) Arduino UNO Rev.3
- 4) Kabel USB printer
- 5) Laptop

Sensor pulse oximeter dan modul *E-Health sensor platform V2.0* yang digunakan merupakan perangkat yang dikembangkan oleh *Cooking Hack Libellium* [41]. Modul *E-Health sensor platform v2.0* berfungsi untuk membaca data berupa sinyal fisiologi dari sensor yang digunakan dan memprosesnya secara digital yang selanjutnya dikirimkan ke perangkat *Arduino*. Modul ini dapat mengaplikasikan pengukuran atau monitoring dalam dunia biometrik dan medis untuk memantau kondisi manusia berdasarkan 9 jenis sensor fisiologis lainnya selain pulse oximeter, seperti *body position*, *body temperature*, *electromyogram*, *electrocardiography*, *airflow*, *galvanic skin response*, *blood pressure* dan *glucometer*.

Setelah eksplorasi sensor pulse oximeter dan modul *E-Health sensor platform V2.0*, selanjutnya adalah eksplorasi dari perangkat *Arduino UNO Rev.3*. Fungsi dari perangkat *Arduino* adalah untuk membaca perangkat input berupa sensor pulse oximeter dan modul *E-Health sensor platform v2.0* agar data pengukuran sinyal fisiologi oleh sensor bisa diproses oleh komputer. Tahapan berikut yang dilakukan dalam proses persiapan perangkat *arduino* diantaranya:

- 1) Menyiapkan *Arduino UNO Rev.3* dan kabel USB yang selanjutnya disambungkan ke laptop. Kabel USB yang digunakan adalah port kabel yang sama digunakan pada printer.

- 2) Download *software* IDE (*Integrated Development Environment*) arduino UNO di website resmi arduino (<http://www.arduino.org/downloads>). Pada penelitian ini menggunakan *software* IDE arduino versi 1.0.6. Setelah selesai download, selanjutnya melakukan instalasi *software* tersebut pada laptop.
- 3) Selanjutnya, agar port arduino bisa dikenali oleh laptop, dilakukan instalasi *port arduino* di *device manager*. Lakukan *setting* pada menu *Tools – Board –* pilih Arduino UNO serta pada pilihan menu *Tools – serial port –* pilih port arduino yang telah diinstal
- 4) *Download library arduino* yang digunakan untuk membaca dan *manage* modul *E-Health sensor platform V2.0*. Penelitian ini menggunakan *library* versi V2.4 juli 2015. Setelah proses download selesai, ekstrak file yang bertipe file zip tersebut ke C:\Users\lutfi\Documents\Arduino\libraries.
- 5) Selanjutnya menuliskan *syntax* program agar Arduino UNO Rev.3 bisa terkoneksi dengan modul *E-Health sensor platform V2.0* dan sensor pulse oximeter. Berikut merupakan *syntax programnya*:

```
#include <PinChangeInt.h>
#include <eHealth.h>
```

```
int cont = 0;
```

```
void setup() {
  Serial.begin(115200);
  eHealth.initPulsioximeter();

  //Attach the interruptions for using the pulsioximeter.
  PCIntPort::attachInterrupt(6, readPulsioximeter, RISING);
}

void loop() {
  Serial.print("PRbpm :");
  Serial.print(eHealth.getBPM());
  Serial.print(" %SPo2 : ");
  Serial.print(eHealth.getOxygenSaturation());
  Serial.print("\n");
  Serial.println("=====");
  delay(10);
}


//Include always this code when using the pulsioximeter sensor
//=====
void readPulsioximeter(){
  cont ++;
```

```

if (cont == 50) { //Get only of one 50 measures to reduce the latency
  eHealth.readPulsioximeter();
  cont = 0;
}
}

```

6) Setelah itu, *verify* – *upload* program ke arduino. Selesai.




Gambar 3.2. Pengaturan aplikasi *CoolTerm* untuk pembacaan USB port serial

Setelah *syntax* program di atas selesai diupload pada perangkat Arduino UNO Rev.3, selanjutnya adalah melakukan instalasi aplikasi pada laptop yang digunakan untuk komunikasi dengan suatu perangkat keras yang terhubung ke *port* serial pada PC. Aplikasi yang digunakan adalah *CoolTerm* yang diunduh dari situs <http://freeware.the-meiers.org>. Aplikasi ini merupakan salah satu *tool* gratis (*free licence*) yang diciptakan oleh Roger Meier yang berfungsi sebagai *port* serial aplikasi terminal sederhana yang ditujukan untuk para penggemar dan profesional dengan kebutuhan untuk bertukar data dengan perangkat keras yang terhubung ke *port* serial seperti mikrokontroler, kontroller servo, kit robot, penerima GPS, dan sebagainya. Pada penelitian ini, aplikasi ini digunakan untuk membaca dan merekam data fisiologis sinyal SpO₂ dan pulse rate selama pengambilan data penelitian. Untuk mendapatkan hasil pembacaan *port* serial dan perekaman data dengan baik, aplikasi *CoolTerm* disetting dengan parameter seperti pada gambar. Karena pada kode program yang diupload ke Arduino UNO menggunakan

komunikasi serial dengan kecepatan 11,52 Kbps, maka pengaturan *Boudrate* pada *CoolTerm* diubah pada mode 115200 dan menggunakan port COM3 sebagai komunikasi serial antara laptop dan perangkat *E-Health sensor platform* yang terhubung dengan Arduino.

Setelah persiapan *hardware* dan perangkat aplikasi sudah disiapkan dan terinstall dengan baik, langkah selanjutnya adalah konektivitas perangkat-perangkat yang telah disiapkan tersebut untuk dapat membaca sinyal fisiologis dari partisipan saat diukur dan diukur dengan sensor pulse oximeter. Berikut langkah-langkah yang harus dilakukan agar sensor pulse oximeter dapat bekerja dan merekam sinyal fisiologis berupa SpO₂ dan pulse rate:


- 1) Memasangkan modul *E-Health sensor platform V2.0* dengan perangkat Arduino UNO Rev.3 (gambar 3.3 kiri)
- 2) Menghubungkan sensor pulse oximeter dengan port seperti yang ditunjukkan pada gambar 3.3. yang dikhususkan untuk input sensor ini pada perangkat *E-health sensor platform V2.0*.



Gambar 3.3. (Kiri) Pemasangan modul *E-Health sensor platform V2.0* pada Arduino Uno Rev.3. (Kanan) Pemasangan sensor pulse oximeter pada jari tangan dan modul *E-Health Sensor platform V2.0* yang sudah terkoneksi dengan *Arduino UNO Rev.3* [41]


- 3) Menghubungkan Arduino yang sudah dikoneksikan dengan *E-health sensor platform V2.0* dan sensor pulse oximeter dengan perangkat komputer melalui kabel USB serial.
- 4) Memasangkan sensor pulse oximeter pada jari tangan (gambar 3.3 kanan).

5) Pada aplikasi *Coolterm* yang sudah diatur seperti pada pengaturan port COM3 dan mode *Boutrate* 115200, selanjutnya klik menu *connection – Capture to textfile–Start (Ctrl+R)* untuk memulai proses perekaman. Selanjutnya, agar data input dari sensor pulse oximeter dapat ditampilkan oleh aplikasi *Coolterm* dan disimpan dengan format *.txt*, klik menu *connection – connect (Ctrl+K)*. Sehingga data pulse rate dan SpO₂ akan terbaca, ditampilkan dan terekam otomatis oleh aplikasi *Coolterm* dalam domain waktu seperti yang ditunjukkan pada gambar 3.4. Jika proses perekaman selesai, dapat klik menu *disconnected*. Selain itu tersedia menu *Clear data* untuk menghapus data yang ditampilkan di window aplikasi dan memulai perekaman data baru.



Gambar 3.4. Tampilan aplikasi *Coolterm* saat membaca dan menampilkan data sinyal SpO₂ dan Pulse rate

Untuk melihat hasil perekaman data baik sinyal SpO₂ dan pulse rate, dapat memplot data dengan *Matlab* yang telah diedit terlebih dahulu data raw yang berformat *.txt* dan hanya menyisakan nilai SpO₂ atau pulse rate saja. Plotting data sinyal SpO₂ dan Pulse rate dapat ditunjukkan pada gambar 3.5.



Gambar 3.5. Representasi Sinyal SpO_2 (merah) dan Pulse rate (biru) dalam rentang domain waktu

3.1.3 Pemilihan Subjek Penelitian

Subjek penelitian ini adalah 31 orang manula (8 laki-laki dan 23 perempuan) yang berasal dari suku Osing (Banyuwangi, Jawa Timur) dan suku Madura (Besuki, Situbondo, Jawa Timur). Kriteria orang manula yang dijadikan sebagai partisipan penelitian adalah orang-orang yang dalam kondisi sehat dan tidak pernah mempunyai riwayat penyakit kronis, terutama penyakit jenis *cardiovaskular*. Kriteria orang tua berdasarkan WHO adalah kelompok manusia yang berumur lebih dari 50 tahun seperti yang dijelaskan pada bab II pada bagian manula [43]. Agar tidak terjadi bias karena terjadi banyak perbedaan pendapat dan kategori mengenai kriteria manula, maka subjek penelitian ini adalah orang-orang yang berumur lebih dari 55 tahun. Pemilihan partisipan berusia lanjut bukan tanpa alasan, karena semakin bertambahnya usia manusia apalagi pada kondisi usia lanjut, rentan sekali terjadi serangan penyakit kronis. Proses penuaan (*aging*) dikaitkan dengan sejumlah perubahan fungsi imunitas tubuh, terutama penurunan *Cell Mediated Immunity (CMI)* atau imunitas yang diperantarai sel [46]. Fatmah juga meneruskan bahwa kemampuan imunitas Manula menurun sesuai dengan bertambahnya usia, termasuk juga kecepatan respon imun terhadap penyakit. Hal itu berdampak Manula beresiko tinggi terserang penyakit seperti infeksi, kanker,

jantung koroner, kelainan autimmun atau penyakit kronis lain. Lebih lanjut, Fatimah juga mengemukakan bahwa hubungan antara marah, perasaan depresi dan sistem imun pada 82 orang Manula yang hidup dengan pasangan penderita penyakit Al-Zheimer. Al-Zheimer merupakan penyakit kondisi kelainan yang ditandai dengan penurunan daya ingat, kemampuan berpikir dan berbicara, serta perubahan perilaku pada penderita akibat gangguan di dalam otak yang sifatnya perlahan-lahan. Studi lain juga menyebutkan bahwa kondisi stress menunjukkan level IL-6 atau interleukin-6 (level tinggi) meningkatkan resiko penyakit jantung dan arthritis.


3.2 Pengumpulan Data

3.2.1 Pengambilan Data

Proses pengambilan data dibagi menjadi dua subproses yang dilakukan secara serentak, yakni proses stimulasi menggunakan media stimulan audio-video dan proses perekaman data fisiologi dari partisipan dengan menggunakan sensor Pulse oximeter dan perangkat pendukung lain yang telah dijelaskan pada bagian eksplorasi *hardware* di atas. Ruangan dipergunakan pada proses pengambilan data ini merupakan ruangan yang anti dari gangguan (*noise*) aktivitas sekitar dan nyaman, sehingga proses stimulasi berjalan maksimal sesuai dengan yang diharapkan dari tujuan penelitian ini. Proses pengambilan data ditunjukkan pada gambar 3.6 dan alur pengambilan data diilustrasikan pada gambar 3.7.



Gambar 3.6. Posisi partisipan pada saat pengambilan data



Gambar 3.7. Proses Pengambilan Data Penelitian

Tahap pertama yang dilakukan adalah persiapan. Pada tahap ini semua perangkat yang dibutuhkan pada penelitian ini disiapkan mulai dari persiapan aplikasi *Coolterm*, perangkat-perangkat yang dibutuhkan seperti yang dijelaskan pada bagian eksplorasi *hardware*, tempat yang nyaman dan anti terhadap gangguan dengan aktivitas sekitar, *headphone*, lembar kuisisioner dan alat tulis. Pada ini, penelitian ini menggunakan dua laptop, satu laptop berguna untuk merekam data fisiologis partisipan dan satunya digunakan untuk menonton video stimulasi. Penggunaan *headphone* ditujukan agar partisipan fokus terhadap video yang diputarkan. Sedangkan lembar kuisisioner digunakan sebagai lembar konfirmasi dan penggalan informasi terhadap partisipan mengenai emosi apa yang dirasakan pada saat stimulasi dilakukan. Kuisisioner yang digunakan pada penelitian ini adalah kuisisioner modifikasi yang mengacu pada penelitian yang dilakukan oleh Rottenberg *et al.* [48]. Pada tahap kedua, peneliti meminta partisipan untuk duduk pada tempat yang telah disediakan dan memastikan agar partisipan merasa nyaman. Apabila partisipan merasa nyaman dengan posisi duduknya, selanjutnya memasang sensor pulse oximeter pada jari partisipan sesuai dengan ketentuan pemasangan dan *headphone* pada kepala partisipan. Selain itu, peneliti juga memberikan instruksi agar partisipan mengerti prosedur penelitian yang dilakukan dan tujuan dari penelitian ini. Sehingga data yang didapatkan sesuai dengan tujuan yang diharapkan dari penelitian ini.


Tahap ketiga merupakan fase *baseline*. Fase ini merupakan proses yang bertujuan untuk memberikan generalisasi awal dari level SpO₂ dan pulse rate partisipan sebelum distimulasi. Pada tahap ini, partisipan diminta untuk menutup mata selama 5 menit dan direkam dengan menggunakan sensor pulse oximeter. Setelah selesai, selanjutnya adalah fase stimulasi emosi partisipan menggunakan stimulan Audio-video. Audio-video yang digunakan merupakan materi audio-video yang telah divalidasi oleh peneliti sebelumnya oleh Rumpa *et al.* [29] yang berjumlah 6 jenis audio-video, diantaranya berkategori senang, takut, sedih, marah, kaget dan jijik. Namun pada penelitian ini hanya mengambil 3 kategori emosi yang sering dirasakan oleh semua orang dalam kehidupan sehari-hari terutama saat menonton sinetron ataupun film, yakni kategori senang, sedih dan marah seperti yang ditunjukkan pada tabel 3.1.

Tabel 3.1. Daftar Stimulan Audio-video

Judul Audio Video	Alias	Target Emosi	Capture Video
<i>New Best of Just for Laughs Gags Epic Collection !! PART 58</i>	ICICI11	Senang	
Iklan Hari Raya 2014 HD Directors Cut	ICICI14	Sedih	

Mama anak	pukul	ICICI9	Marah	
--------------	-------	--------	-------	--

Setelah selesai tahap stimulasi video, selanjutnya adalah pengisian kuisioner dan tahap wawancara secara langsung yang bertujuan untuk menggali informasi partisipan saat distimulasi dengan video. Setelah itu, tahap selanjutnya adalah fase *recovery*. Fase ini merupakan fase istirahat yang bertujuan agar stimulasi video selanjutnya tidak terpengaruh dengan stimulasi video sebelumnya. Tahap ini dilakukan dengan memberi instruksi kepada partisipan untuk menutup mata kembali selama 5 menit dan direkam data fisiologisnya. Proses 4-6 seperti yang ditunjukkan pada gambar 3.7 di atas diulang sebanyak tiga kali secara berurutan dengan urutan sesi pada fase stimulasi video seperti yang ditunjukkan pada gambar 3.8. Sementara tahap perekaman data fisiologis dari proses pengukuran menggunakan sensor pulse oximeter dilakukan secara otomatis dengan bantuan aplikasi *Coolterm* yang menyimpan data dalam format .txt sesuai dengan direktori yang ditentukan pada saat instalasi aplikasi yang dikenal dengan istilah data raw.



Gambar 3.8. Urutan sesi stimulasi video

3.2.2 Pre-processing Data Raw


Tahap ini merupakan tahap pre-pengolahan data, yang artinya bahwa tahap awal sebelum melakukan pengolahan data. Proses yang dilakukan dengan mencocokkan data raw yang telah didapatkan dari hasil pengukuran dan perekaman dengan hasil pengisian kuisioner yang dilakukan oleh partisipan. Desain kuisioner

yang digunakan merupakan jenis kuisioner modifikasi dari penelitian pengenalan emosi yang dilakukan oleh Rottenberg *et al.* [48]. Penelitian ini menggunakan enam butir pertanyaan yang bertujuan untuk mengkonfirmasi emosi yang dirasakan saat menonton video stimulan. Selain itu terdapat pertanyaan tambahan yakni apakah partisipan pernah menonton video stimulasi sebelumnya dan apakah menutup mata pada saat menonton video stimulan. Selanjutnya, Data raw yang digunakan pada tahap selanjutnya (ekstraksi fitur) adalah data dari partisipan yang mengkonfirmasi bahwa subjek merasakan emosi yang sesuai dengan kategori emosi pada saat sesi stimulasi video.

3.3 Pengolahan Data Penelitian

3.3.1 Ekstraksi Fitur

Ekstraksi fitur adalah bagian yang terpenting dalam penelitian tentang *pattern recognition* atau pengenalan pola. Kinerja dari algoritma klasifikasi yang diusulkan sangat dipengaruhi oleh metode ekstraksi fitur yang dipilih. Pada penelitian ini, terdapat dua metode ekstraksi fitur yang dipilih, yakni metode segmentasi ukuran window dari sinyal fisiologis dan ekstraksi fitur statistik pada domain waktu. Metode segmentasi ini telah banyak dilakukan oleh peneliti dibidang *affective computing*, sebagai contoh adalah penelitian yang dilakukan oleh Henry Candra *et al.* [60] dimana mereka mensegmen sinyal fisiologi EEG dengan 10 jenis ukuran segmen, mulai dari segmen per 60 detik sampai dengan per 1 detik. Peneliti lainnya dilakukan oleh peneliti terdahulu yakni Wanhui *et al.* [25] yang mensegmen sinyal SpO₂, GSR dan HR per 15 detik. Pada penelitian ini, menggunakan segmentasi ukuran window dari sinyal SpO₂ dan Pulse rate per 15 detik. Dari metode segmentasi ini, maka pada kategori emosi yang sama didapatkan beberapa data per subjek dengan range domain waktu yang sama yakni per 15 detik seperti yang diilustrasikan pada gambar 3.9 berikut.



Gambar 3.9. Ilustrasi Metode Segmentasi Ukuran Window Sinyal Fisiologi

Setelah proses ekstraksi fitur dengan metode segmentasi yang didapatkan tipikal sampel data raw per 15 detik sinyal SpO₂ dan pulse rate dimana sinyal fisiologi per kategori emosi terbagi menjadi beberapa subsegmen, selanjutnya subsegmen sinyal SpO₂ dan pulse rate tersebut diekstraksi untuk mencari fitur dengan parameter-parameter statistik, seperti parameter mean (rata-rata), mode (modus), maksimum, minimum, standar deviasi, varian, rasio, *mean absolut deviasi* yang didenotasikan dengan lambang: SpO_{2μ}, SpO_{2σ}, SpO_{2maks}, SpO_{2min}, SpO_{2mo}, SpO_{2var}, SpO_{2rasio}, SpO_{2MAD}, PR_μ, PR_σ, PR_{maks}, PR_{min}, PR_{mo}, PR_{var}, PR_{rasio}, dan PR_{MAD}. Sehingga total terdapat 16 jenis fitur (8 fitur sinyal SpO₂ dan 8 fitur sinyal pulse rate) yang terekstraksi dengan dua jenis tipikal sinyal fisiologis yang berbeda dan 8 jenis parameter statistik. Untuk mendapatkan hasil ekstraksi fitur sesuai dengan dua pendekatan metode di atas secara otomatis, penelitian ini menuliskan sebuah *syntax* program di *Matlab* dengan algoritma program berikut.

```

Inisialisasi variabel t = 15; // t = waktu
Inisialisasi variabel fs = 10; // fs = frekuensi sampling

Input data; // data = data raw sinyal
Inisialisasi variabel f_size. Bulatkan f_size ke bilangan bulat
    terdekat(bound), dimana f_size = t * fs; // f_size = ukuran
    frekuensi
Inisialisasi variabel n = panjang (data); // n = data input
Inisialisasi variabel n_f. Bulatkan n_f ke bilangan bulat nilai
    ke bawah (floor), dimana n_f = n / f_size;
Inisialisasi variabel temp = 0; // temp = generalisasi nilai awal
//Pensegmenan sinyal utuh menjadi per 150 sampling data hingga
    menjadi beberapa subsegmen.
Untuk i = 1 : n_f;
    frame(1,:) = data(temp+1 : temp+f_size);
    temp = temp+f_size;
selesai

Inisialisasi variabel hasil, dimana hasil = segmen(t,fs,data);
Inisialisasi variabel untuk menghitung parameter sesuai dengan
    subsegmen, dimana [datasize,~] = ukuran (hasil);
Inisialisasi variabel fitur, dimana fitur = zeros(datasize,8);

```

```
//zeros = pembuatan matrik
```

```
//Melakukan perhitungan tiap subsegmen sinyal dengan parameter statistik berikut
Untuk i = 1:datasize;
    Hitung fitur(i,1) = Dapatkan nilai mean dari hasil(i,:);
    Hitung fitur(i,2) = Dapatkan nilai max dari hasil(i,:);
    Hitung fitur(i,3) = Dapatkan nilai min dari hasil(i,:);
    Hitung fitur(i,4) = Dapatkan nilai std dari hasil(i,:);
    Hitung fitur(i,5) = Dapatkan nilai mode dari hasil(i,:);
    Hitung fitur(i,6) = Dapatkan nilai rasio dari fitur(i,2) dibagi dengan fitur(i,3);
    Hitung fitur(i,7) = Dapatkan nilai varian dari hasil(i,:);
    Hitung fitur(i,8) = Dapatkan nilai mad dari hasil(i,:);
    //mad = Mean absolute deviasi
Selesai
```

Tampilkan hasil ekstraksi fitur dalam bentuk tabel matriks

Pada *syntax* algoritma di atas, *syntax* pada Matlab dibagi menjadi dua jenis file, yakni *syntax* sebagai *function* untuk mendefinisikan segmentasi sinyal dan selanjutnya file *function* tersebut dipanggil kembali pada *syntax* utama untuk perhitungan ekstraksi fitur parameter statistik. Untuk *pseudo-code* program ekstraksi fitur secara lengkap, terdapat pada lampiran 1.

3.3.2 Pelabelan Dataset


Pelabelan dataset merupakan proses dimana penggabungan dan rekapitulasi hasil dari ekstraksi fitur dalam sebuah tabel matriks dimana kolom tabel sebagai jenis fitur dan label kelas, sedangkan baris tabel sebagai *instance* dari dataset. Dataset yang telah dilabeli ini disimpan dalam format *.csv agar aplikasi untuk klasifikasi dataset bisa membaca dan mengenali input dataset. Pada penelitian ini, proses pelabelan dataset menggunakan aplikasi *Microsoft Excel*.

3.3.3 Klasifikasi Menggunakan SVM dan kNN

Melalui proses ekstraksi fitur dan pelabelan dataset yang didapatkan data berupa tabel matriks dalam format *.csv, didapatkan dataset sebanyak 1326 *instance*, yang terbagi menjadi 3 label kelas yakni kelas senang, sedih dan marah. Klasifikasi dilakukan dengan menggunakan algoritma klasifikasi SVM dan kNN, dimana pada penelitian ini menggunakan aplikasi Weka 3.8 untuk proses klasifikasi dataset.

3.3.3.1. Klasifikasi Menggunakan SVM

SVM merupakan salah satu jenis algoritma klasifikasi *supervised learning* yang dikembangkan oleh Vapnik dkk. Jenis *library* SVM yang digunakan adalah LibSVM (*Library Support Vector Machine*) yang dikembangkan oleh Chang *et al.* [53]. Kasus klasifikasi pada penelitian ini merupakan kasus *Multi-class* (tiga kelas), pada LibSVM untuk mengklasifikasi kasus *Multi-class* menggunakan pendekatan *One-against-one* atau *pairwise*. Proses klasifikasi SVM pada penelitian ini juga menggunakan Kernal RBF seperti yang direkomendasikan oleh Hsu *et al.* [52] dengan memilih parameter C (*cost*) dan γ (*gamma*) optimal yang bertambah secara eksponensial untuk mengidentifikasi bidang pemisah (*hyperplane*) terbaik dimana $C = 2^{-5}, 2^{-3}, \dots, 2^{15}$ dan $\gamma = 2^{-15}, 2^{-13}, \dots, 2^3$. Gambar berikut merupakan proses klasifikasi SVM pada penelitian ini.



Gambar 3.10. Proses klasifikasi dengan Algoritma SVM dengan modifikasi parameter C dan γ .

Adapun langkah-langkah klasifikasi dataset menggunakan SVM pada aplikasi Weka 3.8, diantaranya:

- 1) Buka aplikasi Weka 3.8. Pilih menu *explore*.

- 2) Pada menu *Preprocess*, pilih sub menu *Open file* untuk menginputkan dataset dengan format *.csv. Cari file dataset pada direktori tempat menyimpan dataset, klik *Open*.
- 3) Pilih menu *Classify*. Pada bagian *Classifier*, pilih menu *Choose* – pilih jenis *Classifiers* – *functions* – dan pilih LibSVM.
- 4) Klik pada *properties* LibSVM untuk mengubah jenis kernel RBF dan mengubah parameter $C = 2^{-5}, 2^{-3}, \dots, 2^{15}$ dan $\gamma = 2^{-15}, 2^{-13}, \dots, 2^3$. OK.
- 5) Pilih *Cross-validation* pada bagian *test options* dengan folds = 10. Klik menu *Start* untuk memulai klasifikasi seperti yang ditunjukkan pada gambar
- 6) Sehingga didapatkan hasil klasifikasi seperti pada gambar 3.11. Pada penelitian ini menggunakan parameter *Accuracy*, *precision* dan AUC untuk menilai kinerja dari algoritma klasifikasi yang diusulkan serta tabel *confusion matrix*.
- 7) Ulangi langkah 4 – 5 dengan parameter C dan γ yang berbeda.

```

Classifier output
=== Stratified cross-validation ===
=== Summary ===
Correctly Classified Instances      1054      79.4872 %
Incorrectly Classified Instances    272      20.5128 %
Kappa statistic                    0.6588
Mean absolute error                 0.1368
Root mean squared error             0.3698
Relative absolute error             33.0493 %
Root relative squared error         81.3085 %
Total Number of Instances          1326

=== Detailed Accuracy By Class ===

```

	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
	0,915	0,110	0,878	0,915	0,896	0,804	0,903	0,843	Senang
	0,859	0,189	0,727	0,859	0,788	0,652	0,835	0,677	Sedih
	0,317	0,033	0,660	0,317	0,428	0,390	0,642	0,323	Marah
Weighted Avg.	0,795	0,126	0,786	0,795	0,778	0,679	0,834	0,695	

```

=== Confusion Matrix ===
  a  b  c  <-- classified as
563 47  5 | a = Senang
 38 421 31 | b = Sedih
 40 111 70 | c = Marah


```

Gambar 3.11. Hasil klasifikasi menggunakan SVM

3.3.3.2. Klasifikasi Menggunakan kNN

Algoritma pembelajaran kNN (*k-Nearest Neighbors*) dilakukan dengan cara menghitung jarak terdekat data testing terhadap data training dari kriteria kelas yang telah dipelajari oleh algoritma kNN. Proses penentuan kelas dilakukan dengan

cara voting. Misalkan jika hasil voting didominasi kelas A, maka data testing tersebut termasuk dalam kelompok kelas A. Konsep lain dari algoritma pembelajaran kNN adalah parameter K yang menentukan berapa banyak tetangga yang akan dipilih untuk algoritma ini. Banyak rekomendasi untuk pemilihan rentang pengujian nilai K. Pada penelitian, rumus jarak yang digunakan adalah rumus jarak Euclidean dan proses klasifikasi dilakukan dengan $K=1$ sampai $K=36$ untuk mencari hasil klasifikasi terbaik. Sama seperti SVM, aplikasi Weka 3.8 digunakan untuk proses klasifikasi dataset pada penelitian ini.



Gambar 3.12. Proses klasifikasi dataset menggunakan metode kNN dengan modifikasi nilai K

Langkah-langkah klasifikasi dataset menggunakan kNN pada Weka 3.8 adalah sebagai berikut:

- 1) Ulangi langkah 1-3 pada langkah-langkah klasifikasi pada SVM di atas, namun pada saat pemilihan *Classifiers*, pilih *lazy – Ibk*.
- 2) Set nilai K dengan klik *properties* kNN. OK.
- 3) Pilih Cross Validation dengan folds = 10. Dan klik Start untuk memulai klasifikasi.
- 4) Maka didapatkan hasil klasifikasi dengan parameter *Accuracy*, *precision*, *AUC* dan tabel *Confusion Matrix* seperti yang ditunjukkan pada gambar 3.13.

5) Ulangi langkah 2-4 dengan nilai K yang berbeda (K=1 sampai K=36)

Classifier output

```

=== Stratified cross-validation ===
=== Summary ===
Correctly Classified Instances      986      74.359 %
Incorrectly Classified Instances    340      25.641 %
Kappa statistic                    0.5653
Mean absolute error                 0.225
Root mean squared error             0.339
Relative absolute error             54.3865 %
Root relative squared error         74.5254 %
Total Number of Instances          1326

=== Detailed Accuracy By Class ===

```

	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
	0,902	0,163	0,827	0,902	0,863	0,737	0,959	0,954	Senang
	0,824	0,245	0,663	0,824	0,735	0,561	0,865	0,740	Sedih
	0,122	0,017	0,587	0,122	0,202	0,214	0,781	0,363	Marah
Weighted Avg.	0,744	0,169	0,727	0,744	0,706	0,585	0,894	0,777	

```

=== Confusion Matrix ===
  a  b  c  <-- classified as
555 59 18 | a = Senang
 68 404 18 | b = Sedih
 48 146 27 | c = Marah

```


Gambar 3.13. Hasil klasifikasi menggunakan metode kNN

3.4 Tahap Akhir

3.4.1 Evaluasi Performansi Metode Klasifikasi

Tahap ini merupakan tahapan evaluasi dan analisa hasil klasifikasi dengan menggunakan metode SVM dan kNN dengan modifikasi parameter C , γ dan K . Pada penelitian ini, klasifikasi dilakukan menjadi 3 skenario. Skenario pertama dilakukan adalah dengan penggabungan fitur dari sinyal SpO_2 dan pulse rate. Total ada 16 fitur (8 fitur SpO_2 dan 8 fitur PR) dengan dua metode klasifikasi di atas. Skenario kedua dan ketiga, dilakukan klasifikasi baik menggunakan SVM dan kNN dengan menggunakan fitur sinyal SpO_2 dan pulse rate secara terpisah (klasifikasi hanya menggunakan 8 fitur dari sinyal SpO_2 dan 8 fitur dari sinyal pulse rate) dan juga masing-masing dengan metode SVM dan kNN, namun dengan parameter terbaik dari C , γ dan K pada percobaan klasifikasi tahap pertama. Proses training dan testing yang dilakukan pada penelitian adalah dengan menggunakan metode *10-folds cross validation*. Tujuan dari penggunaan metode ini adalah untuk menghindari kasus *overfitting* [59]. Parameter yang digunakan untuk mengukur kinerja dari algoritma yang diusulkan adalah parameter *Accuracy*, *Precision*, *F1-*

score dan tabel *confusion matrix*. Teori mengenai parameter-parameter ini telah dijelaskan pada Bab II. Penentuan kinerja terbaik ditentukan berdasarkan parameter *Accuracy*, dimana parameter *precision* dan F1 sebagai kontrol mengenai tingkat kualitas kinerja dari algoritma yang diusulkan jika dilakukan pengujian ulang. Bagan berikut untuk mengilustrasikan alur proses klasifikasi pada penelitian ini.



Gambar 3.14. Diagram alir proses klasifikasi

Halaman ini sengaja dikosongkan


BAB 4

HASIL DAN PEMBAHASAN

Pada bab ini dijabarkan hasil penelitian dan memberikan analisa serta diskusi dari hasil yang didapatkan. Paparan hasil terdiri dari paparan hasil pengambilan dan pre-processing data raw, tipikal data penelitian, hasil dari ekstraksi fitur, hasil klasifikasi dengan menggunakan SVM, hasil klasifikasi dengan menggunakan kNN dan pemaparan hasil secara keseluruhan dan analisa serta perbandingan dengan penelitian terkait.

4.1 Hasil Pengambilan dan Pre-processing Data Raw


Penelitian ini melibatkan 31 orang manula seperti yang ditunjukkan pada gambar 4.1 dengan rata-rata umur $64,06 \pm 7,97$ tahun. Penentuan atau pemilihan partisipan dilakukan secara random di lingkungan yang homogen dengan kriteria manula yang masih sehat dan tidak mempunyai riwayat penyakit kronis. Hal ini bertujuan agar data yang didapatkan tidak bias karena pengaruh umur ataupun kondisi kesehatan dari subjek penelitian.



Gambar 4.1. Partisipan Penelitian

Proses pengambilan data rata-rata membutuhkan waktu ± 45 menit/partisipan. Sebanyak 31 data raw yang didapatkan masing-masing terdiri dari

7 jenis data, diantaranya data baseline, data emosi senang, data emosi sedih, data emosi marah, data recovery pasca emosi senang, data recovery pasca emosi sedih dan data recovery pasca emosi marah. Dari 7 jenis data raw tersebut, penelitian ini memproses tiga jenis data raw, yakni data emosi senang, emosi sedih dan emosi marah yang nantinya ketiga jenis ini menjadi label kelas, sehingga algoritma yang diusulkan mengklasifikasi dataset kedalam tiga 3 kelas, yakni kelas emosi senang, kelas emosi sedih dan kelas emosi marah. Selain itu, sebanyak 31 data raw yang didapatkan tersebut, dipilah dan dicocokkan dengan hasil pengisian kuisioner. Hasil pemilahan didapatkan bahwa 1 data raw partisipan error saat perekaman sehingga data tidak tersimpan oleh sensor pulse oximeter dan 3 partisipan lainnya menunjukkan bahwa level SpO₂ atau pulse ratenya tidak berada pada kondisi normal pada saat fase baseline. Sehingga tidak memungkinkan untuk memproses pada tahapan selanjutnya. Selain itu, hasil pencocokan dengan pengisian kuisioner didapatkan sebanyak 4 partisipan yang mengkonfirmasi bahwa emosi yang dirasakan pada saat video stimulasi tidak sesuai dengan kategori video yang distimulasikan kepada partisipan dan 5 orang lainnya mengaku bahwa tidak terstimulan (respon emosi datar).



Gambar 4.2. Hasil Pemilahan Data dan Pencocokkan dengan Kuisioner

Sebanyak 18 data raw partisipan (3 laki-laki dan 15 perempuan) yang lolos seleksi tahap pemilahan dan pencocokkan ini dari masing-masing jenis emosi yang jika ditotal terdapat 54 data raw (18x3 jenis emosi) yang digunakan pada tahap




analisa selanjutnya. Tabel 4.1 berikut merupakan daftar data partisipan yang diproses pada tahap pengolahan data berikutnya.

Tabel 4.1. Daftar Partisipan yang Lolos Filter

No.	Nama Partisipan	Kode	Umur (Tahun)
1.	Jaimah	P03	70
2.	Usnati	P04	69
3.	Hamiyah	P05	56
4.	Anis Saati	P06	56
5.	Nur Baiti	P10	62
6.	Anna Aryani	P11	59
7.	Sumiati	P14	58
8.	Sulaiman	P15	69
9.	Suwarna	P16	55
10.	Abdul Adhim	P19	73
11.	Saniti	P20	56
12.	Suyati	P21	55
13.	Lilis Hariana	P22	55
14.	Talhak	P26	71
15.	Hikmah	P27	59
16.	Lamira	P28	64
17.	Sanipah	P30	64
18.	Sulikah	P31	61
Rata-rata ± Standar deviasi			61,78 ± 6,24

4.2 Tipikal Data

Sensor Pulse oximeter merekam aktifitas fisiologis dari partisipan dengan frekuensi sampling 10 Hz. Sehingga dalam satu detik, sensor Pulse oximeter dapat merekam 10 data point dari data SpO₂ dan Pulse rate. Berikut ini disajikan gambaran tipikal data yang didapatkan dari hasil pengukuran dengan memilih salah satu sampel data seorang partisipan yang bernama Suwarna. Selama pengambilan data, Bu Suwarna yang paling responsif diantara subjek penelitian yang lainnya pada saat pengambilan data dan proses pengukuran. Data yang disajikan berupa tipikal data fase video stimulasi yang terdiri dari induksi emosi senang, sedih dan marah.



Gambar 4.3. Tipikal Data Hasil Pengukuran

Berdasarkan gambar 4.3 di atas, ditunjukkan bahwa panjang data dari tiap fase berbeda-beda. Perbedaan ini disebabkan karena panjang durasi video yang berbeda sehingga proses perekaman menyesuaikan panjang durasi video stimulan yang digunakan. Jika dilihat, tipikal data diantara kedua jenis sinyal merupakan sinyal *non-stasioner* sehingga tidak seperti ECG yang memiliki pola yang beraturan (memiliki jenis gelombang tertentu yakni gelombang PQRS), pola fluktuasi dari kedua tipikal sinyal berubah-ubah seperti sinyal EEG. Selain itu, tipikal data dari sinyal SpO_2 cenderung memiliki perbedaan fluktuasi yang kurang dominan. Berbeda dengan tipikal data dari sinyal pulse rate yang memiliki variasi fluktuasi yang sangat terlihat. Data pada saat induksi emosi senang nilai Pulse rate cenderung menurun, sedangkan pada saat sedih dan marah cenderung nilai Pulse ratenya naik. Lain hal pada sinyal SpO_2 , perbedaan terlihat pada fluktuasi nilai dari detik ke detik. Pada saat induksi emosi senang terlihat tidak memiliki fluktuasi yang signifikan, namun pada emosi sedih dan marah fluktuasinya bervariasi. Terkhusus untuk emosi marah, bahkan pada saat tertentu nilainya hingga mencapai kondisi *hypoxia* ($SpO_2 = 85\%$) seperti pada data Bu Suwana pada saat 3000-3500 data point.

4.3 Ekstraksi Fitur

Sebanyak 54 data raw yang lolos tahap pemilihan dan pencocokan dengan kuisioner, selanjutnya diekstraksi dengan dua pendekatan metode ekstraksi fitur yakni metode segmentasi ukuran window sinyal dan ekstraksi fitur statistik pada domain waktu. Metode segmentasi ini membagi sinyal utuh baik SpO_2 dan Pulse rate dari masing-masing partisipan ke dalam beberapa potongan per 15 detik, dimana per potongan ini terdapat 150 data poin ($15 \text{ detik} \times 10 = 150 \text{ data point}$, dimana 10 adalah frekuensi sampling dari Sensor Pulse Oximeter dalam merekam data).

Tabel 4.2. Sebaran Sampel Dataset

Label Kelas	Jumlah Dataset
Senang	615
Sedih	490
Marah	221
Jumlah	1326

Tabel 4.2 diatas merupakan statistika deskriptif sebaran sampel dari dataset perkelas yang dihasilkan dari proses metode segmentasi *window size*. Panjang video dari tiap stimulan yang berbeda mengakibatkan jumlah sampel dataset yang tidak seimbang. Total 1326 sampel dataset dengan panjang data 150 data point yang terdisi dari dataset dengan label senang, sedih dan marah yang masing-masing terdiri dari jenis sinyal SpO₂ dan Pulse rate. Selanjutnya sampel dataset tersebut diproses pada tahap ekstraksi fitur selanjutnya dengan menggunakan metode ekstraksi fitur statistik pada domain waktu dengan 8 jenis parameter (didenotasikan dengan simbol: SpO₂_μ, SpO₂_σ, SpO₂_{maks}, SpO₂_{min}, SpO₂_{mo}, SpO₂_{var}, SpO₂_{rasio}, SpO₂_{MAD}, PR_μ, PR_σ, PR_{maks}, PR_{min}, PR_{mo}, PR_{var}, PR_{rasio}, dan PR_{MAD}). Tabel berikut merupakan sampel dari data yang sudah diekstraksi fitur.

Tabel 4.3. Sampel Hasil Ekstraksi Fitur Sinyal SpO₂

No	Sinyal SpO ₂								Label
	μ	σ	Maks	Min	Mode	Var	Rasio	MAD	Emosi
1	96,86	1,447	98	90	97	2,094	1,089	0,549	Senang
2	95,77	0,420	96	95	96	0,177	1,011	0	Senang
3	97,65	0,477	97	96	97	0,228	1,010	0	Senang
4	98,66	0,475	99	98	99	0,226	1,010	0	Senang
5	98	0	98	98	98	0	1	0	Senang
...	...	...	...	...	...	...	...	...	...
615	98	0	98	98	98	0	1	0	Senang
616	95,76	1,180	96	90	96	1,392	1,067	0	Sedih
617	96,76	1,180	97	91	97	1,392	1,066	0	Sedih
618	98	0	98	98	98	0	1	0	Sedih
619	89,96	3,102	95	85	90	9,622	1,118	2	Sedih
620	96,47	1,527	98	90	96	2,331	1,089	1	Sedih
...	...	...	...	...	...	...	...	...	...
1105	96	0	96	96	96	0	1	0	Sedih
1106	96,72	1,376	97	90	97	1,894	1,078	0	Marah
1107	99	0	99	99	99	0	1	0	Marah
1108	96,04	0,197	97	96	96	0,039	1,010	0	Marah
1109	97,67	0,471	98	97	98	0,221	1,010	0	Marah
1110	98,16	0,368	99	98	98	0,221	1,010	0	Marah
...	...	...	...	...	...	...	...	...	...
1326	98,64	1,770	99	90	99	3,131	1,1	0	Marah

Tabel 4.4. Sampel Hasil Ekstraksi Fitur Sinyal Pulse Rate

No	Sinyal Pulse Rate (PR)								Label Emosi
	μ	σ	Maks	Min	Mode	Var	Rasio	MAD	
1	75,84	1,124	78	75	75	1,263	1,04	0	Senang
2	73,65	0,480	74	73	74	0,230	1,014	0	Senang
3	80,61	0,489	81	80	81	0,239	1,012	0	Senang
4	82,99	0,115	83	82	83	0,013	1,012	0	Senang
5	76,01	0,163	77	75	76	0,027	1,027	0	Senang
...	...	...	...	...	...	...	...	...	...
615	80,27	0,827	81	79	81	0,683	1,025	0	Senang
616	92,19	0,396	93	92	92	0,157	1,011	0	Sedih
617	97,32	0,468	98	97	97	0,219	1,010	0	Sedih
618	101,61	0,793	102	100	102	0,628	1,02	0	Sedih
619	120,75	0,741	123	120	121	0,550	1,025	1	Sedih
620	112,57	2,765	115	108	115	7,643	1,065	2	Sedih
...	...	...	...	...	...	...	...	...	...
1105	100,49	0,502	101	100	100	0,252	1,01	0	Sedih
1106	96,33	6,151	100	84	100	37,834	1,191	0	Marah
1107	96,93	0,791	98	96	97	0,6264	1,021	1	Marah
1108	98,113	0,512	99	97	98	0,2622	1,021	0	Marah
1109	95,253	0,499	96	95	95	0,2495	1,010	0	Marah
1110	95,813	0,689	97	95	96	0,475	1,021	1	Marah
...	...	...	...	...	...	...	...	...	...
1326	99,513	0,872	101	98	100	0,7616	1,031	1	Marah


4.4 Klasifikasi Dataset dengan SVM

Setelah ekstraksi fitur, selanjutnya dilakukan klasifikasi pada dataset. Klasifikasi yang pertama dilakukan adalah dengan menggunakan metode SVM. Untuk mendapatkan hasil klasifikasi yang optimal, dilakukan modifikasi parameter C (*cost*) dan γ (*gamma*) pada persamaan algoritma SVM. Parameter optimal ditentukan berdasarkan nilai rata-rata akurasi (%) tertinggi yang diperoleh dari 10-*fold cross-validation* dengan kombinasi nilai parameter yang digunakan yaitu C pada range $2^{-5}, 2^{-3}, \dots, 2^{15}$ dan γ pada range $2^{-15}, 2^{-13}, \dots, 2^3$. Pemilihan range parameter C dan λ tersebut berdasarkan rekomendasi dari Hsu *et al.* [52]. Skenario klasifikasi yang pertama adalah dengan menggunakan kombinasi fitur dari sinyal

SpO₂ dan Pulse rate yang berjumlah 16 fitur. Sebagai perbandingan, juga dilakukan klasifikasi dengan fitur sinyal SpO₂ dan Pulse rate secara terpisah (8 fitur sinyal SpO₂ dan 8 fitur sinyal PR) juga dengan range parameter C dan γ yang sama.

4.4.1 Klasifikasi hanya dengan Fitur Sinyal SpO₂

Pengujian yang pertama dari algoritma SVM dilakukan pada 8 fitur sinyal SpO₂ (SpO₂_μ, SpO₂_σ, SpO₂_{maks}, SpO₂_{min}, SpO₂_{mo}, SpO₂_{var}, SpO₂_{rasio}, SpO₂_{MAD}). Pengujian klasifikasi ini bertujuan untuk mengetahui pola emosi berdasarkan hasil ekstraksi fitur yang didapatkan pada single sinyal SpO₂. Gambar 4.4 merupakan sampel hasil klasifikasi optimum dari 8 fitur SpO₂ menggunakan SVM dimana skor klasifikasi maksimum pada saat parameter $C = 2^3$ dan $\gamma = 2^{-4}$ yakni sebesar 57,21% (akurasi) dengan presisi 42,2% dan skor F1 45,7%. Namun, skor maksimum pada presisi dan F1 tidak pada saat parameter tersebut. Skor maksimum dari presisi adalah 59,6% pada saat parameter $C = 2^1$ dengan $\gamma = 2^{-2}$ dan $C = 2^2$ dengan $\gamma = 2^{-3}$. Sedangkan F1 pada saat parameter $C = 2^0$ dengan $\gamma = 2^{-2}$ yakni sebesar 47,2%.




Gambar 4.4. Hasil klasifikasi 8 fitur sinyal SpO₂ dengan metode SVM

Berdasarkan dari hasil pengolahan klasifikasi 8 fitur single sinyal SpO₂ menggunakan SVM menunjukkan fluktuasi skor akurasi, presisi dan skor F₁ seiring dengan perubahan parameter C dan γ . Jika kita lihat, hasil klasifikasi dengan fitur ini dikatakan kurang maksimal baik dari parameter akurasi, presisi dan skor F₁. Bahkan pada parameter C dan γ tertentu skor klasifikasi turun hingga kurang dari

50%, terutama pada presisi yang turun hingga 21,5% pada saat $C = 2^{-2} - 2^5$ dan $\gamma = 2^{-7} - 2^{-12}$. Hasil klasifikasi dari 8 fitur ini menunjukkan peningkatan pada saat parameter C antara 2^{-2} sampai dengan 2^4 , sedangkan parameter γ antara 2^{-1} sampai dengan 2^{-5} (Hasil lengkap pada lampiran 4).

4.4.2 Klasifikasi dengan Fitur Sinyal Pulse Rate

Skenario klasifikasi kedua adalah pengujian klasifikasi dengan 8 fitur dari sinyal Pulse Rate (PR_{μ} , PR_{σ} , PR_{maks} , PR_{min} , PR_{mo} , PR_{var} , PR_{rasio} , dan PR_{MAD}). Sama seperti percobaan klasifikasi pada skenario pertama, eksperimen ini juga dengan modifikasi parameter C dan γ untuk mendapatkan hasil klasifikasi optimal yang dinyatakan dengan parameter akurasi, presisi dan F1 score.




Gambar 4.5. Hasil Klasifikasi 8 fitur dari sinyal pulse rate dengan SVM

Gambar 4.5 merupakan hasil klasifikasi optimum 8 fitur sinyal Pulse rate dimana terjadi pada saat parameter $C = 2^5$ dan $\gamma = 2^{-8}$ dengan skor akurasi 68,48%, presisi 70,4% dan F1 63,9%. Seperti juga halnya pada klasifikasi dengan 8 fitur dari sinyal SpO_2 pada eksperimen sebelumnya, klasifikasi pada eksperimen ini juga menunjukkan bahwa skor tertinggi dari parameter presisi dan F1 tidak pada parameter optimum pada akurasi. Hasil optimum pada presisi adalah sebesar 74,6% pada saat parameter $C = 2^{-2}$ dan $\gamma = 2^{-2}$, sedangkan F1 pada saat parameter $C = 2^1$ dan $\gamma = 2^{-3}$ (65,3%). Selain itu, gambar diatas menunjukkan bahwa semakin besar nilai γ menunjukkan hasil yang semakin turun, namun hal sebaliknya terjadi pada parameter C .

Hasil klasifikasi dengan 8 fitur dari sinyal Pulse rate didapatkan bahwa skor akurasi, presisi dan F1 lebih tinggi daripada hasil klasifikasi dengan 8 fitur dari sinyal SpO₂ (hasil lengkap dipaparkan pada lampiran 5). Hal ini menunjukkan bahwa metode ekstraksi fitur yang digunakan lebih cocok digunakan pada sinyal Pulse rate. Trend fluktuasi dari sinyal yang terlihat dibandingkan dengan sinyal SpO₂ merupakan salah satu alasan metode yang digunakan lebih cocok dan hasil klasifikasi dari Pulse rate yang lebih tinggi dibandingkan dengan fitur-fitur sinyal SpO₂. Selain itu, berdasarkan pada ketiga parameter yang dijadikan patokan (akurasi, presisi dan skor F1), menunjukkan skor hasil klasifikasi lebih dari 50%. Skor akurasi dan F1 terlihat fluktuasinya lebih stabil daripada presisi yang mengalami fluktuasi yang berbeda-beda seiring dengan perubahan parameter C dan γ .

4.4.3 Klasifikasi dengan Kombinasi Fitur dari Sinyal SpO₂ dan Pulse Rate

Skenario klasifikasi ketiga adalah klasifikasi sinyal multimodal (kombinasi fitur dari sinyal SpO₂ dan Pulse rate). Sebanyak 16 fitur (SpO_{2 μ} , SpO_{2 σ} , SpO_{2maks}, SpO_{2min}, SpO_{2mo}, SpO_{2var}, SpO_{2rasio}, SpO_{2MAD}, PR _{μ} , PR _{σ} , PR_{maks}, PR_{min}, PR_{mo}, PR_{var}, PR_{rasio}, dan PR_{MAD}), yang telah diekstraksi dari sinyal SpO₂ dan pulse rate dengan metode ekstraksi fitur yang diusulkan, diklasifikasi dengan menggunakan metode SVM seperti pada percobaan sebelumnya.



Gambar 4.6. Hasil Klasifikasi 16 Fitur dari Kombinasi Sinyal SpO₂ dan Pulse Rate dengan Metode SVM

Gambar 4.6 hasil dari klasifikasi maksimum dimana hasil klasifikasi maksimum terjadi pada saat parameter $C = 2^6$ dan $\gamma = 2^{-8}$ dengan presentase 72,775% (akurasi), 69,6% (F1) dan 70,5% (presisi). Hasil klasifikasi dari kombinasi fitur ini menunjukkan performansi yang meningkat lebih dari 4% (akurasi) dibandingkan dengan dua percobaan sebelumnya. Sama halnya dengan hasil klasifikasi dengan single sinyal baik SpO₂ dan Pulse rate bahwa parameter optimum C dan γ dari nilai F1 dan presisi terjadi pada parameter lain yakni F1 pada saat $C = 2^3$ dengan $\gamma = 2^{-4}$ (68,9%) dan presisi pada saat nilai $C = 2^{-1}$ dan $\gamma = 2^{-5}$ yakni dengan skor 73,9%. Hasil klasifikasi dengan fitur sinyal multimodal (hasil lengkap dipaparkan pada lampiran 3) menunjukkan fluktuasi hasil klasifikasi pada SVM yang memilih parameter C dan γ untuk mendapatkan bidang pemisah optimal dengan input 16 fitur kombinasi dari sinyal SpO₂ dan Pulse rate. Hasil klasifikasi menunjukkan peningkatan jika nilai parameter C semakin besar dan parameter γ semakin kecil.


4.5 Klasifikasi Dataset dengan kNN

Eksperimen selanjutnya adalah dengan mengimplementasikan algoritma klasifikasi kNN sebagai pembanding yang melakukan eksperimen dengan parameter K yang berbeda untuk mendapatkan hasil klasifikasi yang optimal. Penentuan nilai K dari algoritma kNN mempengaruhi proses voting untuk penentuan anggota kelas, sehingga dapat mempengaruhi hasil dari klasifikasi. Berdasarkan penelitian sebelumnya yang menggunakan kNN sebagai algoritma klasifikasi, merekomendasikan untuk melakukan percobaan klasifikasi dengan rentang K yang berbeda-beda, antara lain: K sama dengan 1-30, 1-45, 1-60 dan $K = 1-\sqrt{n}$, dimana n adalah jumlah sampel dari dataset [58]. Penelitian ini, memilih rekomendasi untuk melakukan klasifikasi metode kNN dengan $K = 1$ sampai $K = \sqrt{n}$ dimana jumlah sampel dari dataset pada penelitian ini adalah 1326 data point. Sehingga pada penelitian ini rentang K yang diuji antara 1 sampai dengan $K = 36$. Bagian 4.5.1 - 4.5.3 berikut menguraikan eksperimen klasifikasi 8 fitur dari sinyal SpO₂, 8 fitur dari sinyal Pulse rate dan 16 fitur dari kombinasi kedua sinyal

fisiologis tersebut untuk mengenali emosi dasar (senang, sedih dan marah) pada manula dengan menggunakan algoritma kNN yang diusulkan.

4.5.1 Klasifikasi dengan Fitur Sinyal SpO₂

Klasifikasi pertama dengan algoritma kNN dilakukan pada 8 fitur dari sinyal SpO₂ (SpO_{2μ}, SpO_{2σ}, SpO_{2maks}, SpO_{2min}, SpO_{2mo}, SpO_{2var}, SpO_{2rasio}, SpO_{2MAD}). Performansi metode yang diusulkan direpresentasikan berdasarkan parameter akurasi, presisi dan F1 score ditunjukkan pada gambar berikut.




Gambar 4.7. Hasil klasifikasi 8 fitur dari sinyal SpO₂ dengan kNN

Seperti halnya klasifikasi fitur SpO₂ dengan menggunakan SVM di atas, klasifikasi dengan menggunakan kNN juga masih dalam kategori hasil yang rendah, yakni 50,603% (akurasi), 44,6% (presisi) dan 46,1% (F1) seperti yang ditunjukkan pada gambar 4.7 di atas. Hasil ini lebih kecil dibandingkan dengan hasil klasifikasi menggunakan metode SVM. Selain itu, performansi optimum dari akurasi, presisi dan F1 juga dengan K yang berbeda. Performansi optimum pada parameter akurasi pada saat K = 11 (50,603%), presisi pada saat K = 6 (45,7%) dan skor F1 pada saat K = 6 (46,1%). Dari gambar 4.7 menunjukkan bahwa perubahan presentase hasil dari hasil klasifikasi dengan K = 1 sampai dengan K = 36 menunjukkan perubahan yang tidak terlalu signifikan. Namun untuk parameter akurasi, hasil klasifikasi menunjukkan peningkatan dari K = 1 ke K = 10. Setelah parameter K tersebut, hasil klasifikasi menjadi lebih stabil (naik turun yang tidak terlalu signifikan).

4.5.2 Klasifikasi dengan Fitur Sinyal Pulse Rate

Skenario kedua dari eksperimen dengan menggunakan kNN adalah dengan input 8 fitur dari sinyal Pulse rate (PR_{μ} , PR_{σ} , PR_{maks} , PR_{min} , PR_{mo} , PR_{var} , PR_{rasio} , dan PR_{MAD}). Gambar 4.8 berikut menunjukkan performansi dari metode usulan yang direpresentasikan berdasarkan parameter akurasi, presisi dan skor F1.




Gambar 4.8. Hasil klasifikasi 8 fitur dari sinyal Pulse rate dengan kNN

Klasifikasi dengan input 8 fitur dari sinyal pulse rate menggunakan kNN juga mengalami kenaikan dibandingkan dengan menggunakan input 8 fitur sinyal SpO_2 (sama halnya klasifikasi dengan menggunakan metode SVM). Gambar 4.8 merupakan visualisasi performansi dari metode pembandingan dimana klasifikasi optimum terjadi pada saat $K = 29$ baik akurasi, presisi dan F1, yakni 66,893% (akurasi), 65,2% (presisi) dan 63% (F1). Hasil ini meningkat lebih dari 16% dibandingkan dengan input 8 sinyal SpO_2 pada eksperimen pertama menggunakan kNN ini. Selain itu, percobaan dari $K = 1$ sampai 16 (akurasi dan presisi) mengalami peningkatan lebih dari 5%. Namun setelah itu, hasil klasifikasi dikatakan stabil (naik turun yang tidak terlalu signifikan). Sedangkan skor F1 mengalami fluktuasi yang signifikan dari $K=1$ hingga $K=36$.

4.5.3 Klasifikasi dengan Kombinasi Fitur dari Sinyal SpO_2 dan Pulse Rate

Selanjutnya adalah skenario klasifikasi kombinasi 16 fitur sinyal SpO_2 dan Pulse rate ($SpO_{2\mu}$, $SpO_{2\sigma}$, SpO_{2maks} , SpO_{2min} , SpO_{2mo} , SpO_{2var} , SpO_{2rasio} , SpO_{2MAD} ,

PR_{μ} , PR_{σ} , PR_{maks} , PR_{min} , PR_{mo} , PR_{var} , PR_{rasio} , dan PR_{MAD}). Berikut adalah grafik hasil dari klasifikasi 16 fitur-fitur tersebut dengan menggunakan metode k-NN:



Gambar 4.9. Hasil klasifikasi 16 fitur dari kombinasi sinyal SpO₂ dan Pulse rate dengan Metode kNN

Gambar 4.9 menunjukkan klasifikasi optimum terjadi pada saat $K = 9$, yakni dengan akurasi 71,041%, presisi 68,4% dan skor F1 68,2%. Hasil optimum dari ketiga parameter ini terjadi pada saat nilai K yang sama. Seperti pada klasifikasi menggunakan metode SVM, hasil klasifikasi dengan fitur kombinasi sinyal SpO₂ dan pulse rate lebih besar (meningkat lebih dari 4%) dibandingkan dengan menggunakan fitur single sinyal fisiologi (Sinyal SpO₂ ataupun pulse rate). Selain itu, hasil dari parameter akurasi, presisi dan skor F1 meningkat dari $K=1$ ke $K=7$. Setelah itu, hasil klasifikasi lebih stabil (adapun terdapat kenaikan dan penurunan tidak menunjukkan perbedaan yang signifikan). Namun, kondisi anomali terjadi pada $K > 23$, dimana hasil dari parameter presisi dan skor F1 mengalami penurunan yang cukup signifikan.

4.6 Analisa Hasil Keseluruhan dan Diskusi

Metode usulan seperti yang dijelaskan pada Bab III diuji untuk mengenali atau mendeteksi tiga emosi dasar pada Manula, yakni senang, sedih dan marah. Berdasarkan pada eksperimen yang telah dilakukan, dimana dilakukan eksperimen

klasifikasi berdasarkan tiga skenario (menggunakan input fitur sinyal SpO₂, fitur pulse rate dan kombinasi fitur SpO₂ – pulse rate) menggunakan dua metode klasifikasi yang *Support Vector Machine* dan *k-Nearest Neighbors*. Klasifikasi dengan metode SVM dilakukan dengan melakukan perulangan eksperimen dengan memodifikasi besaran nilai parameter *cost* ($C = 2^{-5}, 2^{-3}, \dots, 2^{15}$) dan gamma ($\lambda = 2^{-15}, 2^{-13}, \dots, 2^3$) dan metode kNN dengan melakukan klasifikasi dengan nilai K antara 1 sampai 36. Tujuan dari modifikasi besaran nilai parameter C , λ dan K ini adalah untuk mendapatkan performansi optimal dari algoritma yang diusulkan. Pada bagian sebelumnya telah dipaparkan secara deskriptif performansi algoritma usulan berdasarkan tiga skenario yang telah disebutkan.

Seperti yang dideskripsikan pada bagian sebelumnya bahwa klasifikasi 8 fitur sinyal SpO₂ baik menggunakan SVM ataupun k-NN menunjukkan performansi yang masih rendah dimana skor akurasi tertinggi adalah 57,21%, presisi 42,2% dan skor F1 45,7%. Sedangkan menggunakan kNN adalah yakni 50,603% (akurasi), 44,6% (presisi) dan 46,1% (F1). Hasil ini menunjukkan bahwa performansi klasifikasi menggunakan SVM dengan atribut 8 fitur dari sinyal SpO₂ lebih baik daripada menggunakan kNN. Selain itu, rendahnya skor klasifikasi ini menunjukkan bahwa fitur-fitur yang didapatkan dari metode usulan untuk mengekstraksi sinyal SpO₂ menunjukkan kecondongan kesamaan pada kelas tertentu dimana atribut aktual dari kelas marah dikenali sebagai atribut dari kelas senang dan sedih. Selain itu juga, jumlah sampel dari masing-masing kelas yang tidak seimbang juga mempengaruhi performansi dari hasil klasifikasi dimana jumlah sampel atau *instance* dari kelas marah lebih sedikit dibandingkan dengan jumlah sampel dari kelas senang dan sedih. Akibatnya dalam proses training dan testing jika karakteristik dari fitur-fitur anggota dari kelas yang memiliki jumlah sampel atau *instance* paling sedikit memiliki kemiripan dengan karakteristik dari kelas yang memiliki sampel lebih banyak, maka sampel aktual dari kelas yang memiliki sampel paling sedikit akan dikenali menjadi anggota dari kelas yang memiliki sampel lebih banyak dan memiliki kesamaan dengan sampel dari anggota kelas yang sedikit. Hal ini dapat kita lihat pada tabel *confusion matrix* hasil dari klasifikasi 8 fitur SpO₂ pada tabel 4.5 dan 4.6.

Tabel 4.5. Tabel *Confusion Matrix* Klasifikasi Menggunakan Metode SVM


			Kelas Prediksi		
			Senang	Sedih	Marah
Kelas Aktual	SpO ₂	Senang	470	145	0
		Sedih	280	209	1
		Marah	139	82	0
	PR	Senang	477	135	3
		Sedih	70	418	2
		Marah	63	145	13
	SpO ₂ -PR	Senang	529	72	14
		Sedih	71	403	16
		Marah	529	72	14

Tabel 4.6. Tabel *Confusion Matrix* Klasifikasi Menggunakan Metode k-NN

			Kelas Prediksi		
			Senang	Sedih	Marah
Kelas Aktual	SpO ₂	Senang	465	132	18
		Sedih	275	202	13
		Marah	140	77	4
	PR	Senang	472	138	5
		Sedih	78	398	14
		Marah	67	137	17
	SpO ₂ -PR	Senang	519	77	19
		Sedih	81	388	21
		Marah	69	117	35

Sejalan dengan performansi pada klasifikasi dengan 8 fitur sinyal SpO₂, performansi SVM juga lebih baik dibandingkan kNN pada skenario eksperimen kedua yakni klasifikasi 8 fitur sinyal Pulse rate dimana akurasi optimum dari SVM adalah 68,48%, presisi 70,4% dan F1 63,9% sedangkan skor klasifikasi optimum pada kNN adalah akurasi 66,893%, dengan presisi 65,2% dan skor F1 63%. Performansi SVM lebih baik daripada kNN disebabkan nilai TP dari kelas senang dan sedih lebih besar daripada klasifikasi dengan kNN seperti yang ditunjukkan pada tabel 4.5 dan 4.6, sebaliknya pada kelas marah menunjukkan nilai yang lebih

kecil. Selain itu juga, performansi algoritma usulan pada skenario kedua ini dikatakan lebih baik daripada klasifikasi pada skenario pertama. Hal ini juga ditunjukkan pada tabel 4.5 dan 4.6 serta gambar 4.10. Hasil ini menunjukkan bahwa metode ekstraksi fitur usulan lebih cocok diimplementasikan pada sinyal Pulse rate dimana karakteristik dari sinyal ini lebih terlihat fluktuasinya dibandingkan dengan sinyal SpO₂ yang cenderung fluktuasi nilainya dengan rentang waktu tertentu tidak terlalu signifikan.



Gambar 4.10. Hasil klasifikasi dengan input fitur yang berbeda menggunakan metode SVM dan kNN


Skenario ketiga dimana eksperimen klasifikasi dengan kombinasi 8 fitur dari sinyal SpO₂ dan Pulse rate (Multimodal). Hasil klasifikasi juga menunjukkan metode SVM juga lebih baik daripada k-NN dengan hasil klasifikasi optimal metode SVM adalah 72,775% dari akurasi, presisi 70,50% dan skor F1 69,60% sedangkan hasil klasifikasi optimal dengan metode k-NN adalah akurasi 71,041%, presisi 68,4% dan skor F1 68,2%. Jika kita melihat pola hasil klasifikasi dengan

metode usulan seperti yang ditunjukkan pada gambar 4.10 menunjukkan bahwa klasifikasi dengan fitur kombinasi ($\text{SpO}_2\text{-PR}$) dapat meningkatkan performansi dari algoritma klasifikasi dibandingkan dengan klasifikasi dengan single sinyal fisiologis baik dengan menggunakan SVM ataupun kNN. Hal ini memberikan kesimpulan bahwa fitur-fitur yang lebih banyak dan detail dapat meningkatkan performansi dari algoritma klasifikasi. Selain itu, implementasi SVM dengan memodifikasi dan memilih parameter C dan λ optimal memberikan dampak signifikan terhadap performansi klasifikasi dari SVM. Modifikasi ini adalah rekomendasi dari penelitian yang dilakukan oleh Hsu *et al.* [52] dimana modifikasi parameter C dan λ ini bertujuan untuk mencari bidang pemisah (*hyperplane*) terbaik dengan memperbesar nilai margin dan mengoptimalkan konstrain dimana memperbesar margin artinya memperbesar parameter C (*cost*) sedangkan mengoptimalkan konstrain berarti memperkecil nilai dari parameter λ (*gamma*). Rekomendasi dari Hsu *et al.* [52] terbukti dapat meningkatkan performansi klasifikasi dari metode SVM. Sedangkan pada k-NN, percobaan klasifikasi dengan mencari parameter K optimal dari 1 hingga 36 juga dapat mempengaruhi performansi dari metode kNN.

4.7 Analisa Pola Klasifikasi Per Subjek

Metode segmentasi ukuran window sinyal atau *window size* pada penelitian ini mengakibatkan satu dataset dari masing-masing data partisipan di tiap emosi mempunyai beberapa sampel atau *instance*. Tiap emosi (senang, sedih dan marah) per partisipan terdiri beberapa sampel sub-segmen sinyal dan diekstraksi dengan 8 parameter statistik. Oleh karena itu, dilakukan klasifikasi per subjek untuk mengetahui pola klasifikasi dari tiga skenario seperti pada eksperimen sebelumnya. Hal ini juga untuk membuktikan apakah fitur kombinasi ($\text{SpO}_2\text{-PR}$) juga dapat meningkatkan performansi dari metode usulan atau tidak. Oleh karena itu, dari eksperimen yang dilakukan dengan menggunakan metode SVM dan kNN menunjukkan bahwa 15 dari 18 partisipan menunjukkan hasil klasifikasi menunjukkan performansi yang lebih baik jika menggunakan fitur sinyal kombinasi ($\text{SpO}_2\text{-PR}$) atau lebih dikenal multimodal. Bahkan hasil klasifikasi fitur kombinasi

dari kedua sinyal fisiologis 3 partisipan (partisipan 2, 16 dan 18) pada percobaan klasifikasi dengan menggunakan SVM menunjukkan nilai akurasi lebih dari 85%.



Gambar 4.11. Klasifikasi menggunakan metode SVM dan kNN per subjek

Tren yang sama dengan eksperimen sebelumnya juga ditunjukkan pada klasifikasi per subjek ini dimana performansi klasifikasi dengan metode SVM juga lebih tinggi dibandingkan dengan menggunakan metode kNN. Sebagai contoh pada gambar 4.11 yang menunjukkan bahwa hasil klasifikasi terbesar dengan akurasi 85% pada partisipan 2, sedangkan dengan metode SVM akurasinya 93,94%. Hasil

akurasi yang tinggi dari percobaan klasifikasi per subjek ini mengindikasikan bahwa pola berbeda yang ditunjukkan pada masing-masing emosi dengan metode pengenalan atau deteksi emosi yang diusulkan. Selain itu juga mengindikasikan bahwa video stimulan dapat menginduksi partisipan tersebut dengan baik. Berdasarkan pantauan saat pengambilan data, para partisipan yang menunjukkan nilai akurasi yang bagus, responsif pada saat distimulasi dengan video stimulan. Hal ini dibuktikan bahwa mereka tertawa pada saat stimulasi video senang, beberapa partisipan menangis pada saat stimulasi video sedih dan merasa jengkel dan marah pada saat stimulasi video marah. Hasil pengamatan ini juga didukung dengan hasil dari pengisian kuisioner dimana mereka memberikan skor 8 dari masing-masing emosi (range penilaian konfirmasi emosi yang dirasakan antara 0-8).

4.8 Analisa Perbandingan dengan Penelitian Terkait

Penelitian mengenai pengenalan atau deteksi emosi menjadi topik bahasan baru yang banyak dikaji oleh para peneliti, akademisi dan praktisi, baik menggunakan *single*-modal ataupun multimodal. Namun masih sangat minim yang memanfaatkan sinyal SpO₂ dan Pulse rate untuk mendeteksi atau mengenali pola emosi. Pemanfaatan sinyal SpO₂ dalam bidang penelitian pengenalan atau deteksi emosi ini dimanfaatkan oleh beberapa peneliti namun dengan mengkombinasikannya dengan jenis sinyal fisiologis yang lainnya atau biasa yang disebut multimodal, seperti yang dilakukan oleh Wen *et al.* [25], Huang *et al.* [26] dan Begum *et al.* [27]. Performansi metode yang mereka lakukan menunjukkan hasil yang lebih baik dibandingkan dengan penelitian ini. Sedangkan pemanfaatan sinyal Pulse rate hanya dilakukan oleh Marzuki *et al.* [28] dimana pada penelitian tersebut hanya menggunakan single sinyal Pulse rate saja. Performansi metode usulan dari penelitian ini lebih baik daripada penelitian yang dilakukan oleh Marzuki *et al.* [28]. Namun hal ini tak bisa dijadikan bahan pembanding, karena dataset yang digunakan berbeda dengan penelitian ini. Selain itu, jenis sinyal fisiologis yang digunakan dan umur dari partisipan juga berbeda. Untuk deskripsi secara detail ditunjukkan pada tabel 4.7 berikut.

Tabel 4.7. Perbandingan dengan Penelitian Terkait

No	Nama	Jumlah Partisipan ± Umur	Jenis Sinyal	Metode Ekstraksi Fitur	Metode Klasifikasi	Performansi
1.	Wen <i>et al.</i> [25]	101 orang ± Bawah 25 tahun	SpO ₂ , GSR, HR	Segmentasi <i>window size</i> sinyal per 15 detik, Metode <i>multi-variant correlation</i> , domain waktu,	Random Forest	74%
2.	Huang <i>et al.</i> [26]	250 orang ± Rata-rata umur 19,4 tahun	SpO ₂ , GSR, ECG	233 jenis ekstraksi fitur	Random Forest	74,8%
3.	Begum <i>et al.</i> [27]	8 orang ± Umur antara 26 sampai 50 tahun	HR, FT, RR, CO ₂ , SpO ₂	Domain waktu dan frekuensi, MMSE	<i>Case-based Reasoning</i> (CBR)	87,5%
4.	Marzuki <i>et al.</i> [28]	30 subjek ± Umur bawah 25 tahun	PR	Domain waktu	LVQ	59,52% (presisi), 68,52% (recall)
5.	Metode Usulan Penelitian ini	31 subjek ± Manula	SpO ₂ , PR	Segmentasi <i>window size</i> sinyal, Domain waktu	SVM, kNN	72,775% (SVM), 71,041% (k-NN)

Halaman ini sengaja dikosongkan

BAB 5

PENUTUP

5.1 Kesimpulan

Pada penelitian ini dilakukan pengenalan status emosi berdasarkan aktifitas fisiologis Manula yang tergambar berdasarkan sinyal SpO_2 dan Pulse rate menggunakan metode yang diusulkan. Berdasarkan hasil dari pengolahan data, analisis dan pembahasan dari hasil yang didapatkan maka didapatkan kesimpulan sebagai berikut:

- 1) Metode yang diusulkan terbukti dapat mengenali atau mendeteksi status emosi berbasiskan sinyal SpO_2 dan Pulse rate secara akurat. Proses training dan testing yang menggunakan metode *k-fold cross validation* dapat memprediksi atau mengenali dengan benar dengan persentase akurasi terbaik adalah 72,775%, presisi 70,50% dan skor F1 69,60%. Hasil ini didapatkan dengan menggunakan metode SVM pada saat besar nilai dari parameter C (*cost*) = 2^6 dan λ (*gamma*) = 2^{-8} . Sedangkan, hasil klasifikasi optimal pada kNN, didapatkan pada saat nilai $K = 29$ dengan akurasi 71,041%, presisi 68,4% dan skor F1 68,2%. Hasil klasifikasi ini menunjukkan bahwa performansi metode SVM lebih baik dibandingkan metode kNN, baik dengan klasifikasi 16 fitur SpO_2 – PR, 8 fitur SpO_2 dan 8 fitur Pulse rate.
- 2) Klasifikasi dengan menggunakan kombinasi fitur SpO_2 dan Pulse rate (multimodal) dapat mempengaruhi performa metode usulan dengan menunjukkan peningkatan nilai akurasi 4,325% pada SVM dan 4,148% pada kNN dibandingkan dengan menggunakan single fitur dari SpO_2 dan Pulse rate. Hal ini menunjukkan bahwa fitur yang semakin detail mempengaruhi hasil pengenalan dari metode yang diusulkan.
- 3) Pemilihan parameter C (*cost*) dan λ (*gamma*) terbaik pada SVM terbukti dapat meningkatkan performansi dari hasil klasifikasi. Selain itu juga eksperimen dengan rentang $K = 1$ hingga 36 pada kNN juga dapat mempengaruhi hasil pengenalan atau klasifikasi. Pemilihan parameter C dan λ ini ditujukan untuk mencari bidang pemisah (*hyperplane*) terbaik dari SVM, sedangkan pengujian

K yang berbeda bertujuan untuk mencari hasil voting terbaik pada kNN dalam penentuan tetangga terdekatnya.

- 4) Peningkatan nilai akurasi, presisi dan skor F1 dengan input fitur multimodal sinyal SpO₂ dan Pulse rate juga didapatkan pada klasifikasi fitur per subjek. Didapatkan 15 dari 18 partisipan menunjukkan klasifikasi dengan fitur kombinasi mengalami kenaikan yang signifikan. Selain itu juga, terdapat 3 partisipan yang nilai akurasi klasifikasinya lebih dari 85% bahkan ada yang mencapai lebih dari 94%. Hasil klasifikasi per subjek juga didapatkan nilai akurasi, presisi dan skor F1 pada SVM lebih baik dibandingkan dengan kNN.

5.2 Penelitian Selanjutnya

Berdasarkan hasil analisa dari eksperimen, pengolahan data dan analisa hasil dari penelitian yang telah dilakukan serta kesimpulan yang didapatkan, diperoleh beberapa hal yang dijadikan pertimbangan untuk eksplorasi pada penelitian selanjutnya, diantaranya:

- 1) Penelitian ini menggunakan metode ekstraksi fitur statistik pada domain waktu, penelitian yang lebih lanjut dilakukan dengan metode ekstraksi fitur lainnya seperti metode yang biasanya digunakan untuk analisa sinyal nonlinier diantaranya Multiscale Entropy, Sample entropy, Detrended Fluctuation analysis, Multivariate Multiscale Entropy atau Multifractal Detrended fluctuation analysis. Selain itu juga akan dilakukan metode ekstraksi fitur lain pada domain frekuensi.
- 2) Metode segmentasi *window size* menyebabkan jumlah *instance* dari tiap kelas menjadi tidak seimbang (*imbalanced class*) jika panjang video dari masing-masing emosi tidak sama. Hal ini menyebabkan kelas yang memiliki jumlah *instance* yang lebih sedikit cenderung dianggap menjadi anggota kelas dari jumlah *instance* lebih banyak. Sehingga hal ini dapat menurunkan performa dari algoritma klasifikasi yang diusulkan. Sehingga ke depan metode klasifikasi khusus untuk kasus *imbalanced dataset* seperti FSVM atau EFSVM dapat digunakan untuk mendapatkan hasil klasifikasi yang lebih baik.

DAFTAR PUSTAKA

- [1] S. D. Kreibig, "Autonomic nervous system activity in emotion: A review," *Biol. Psychol.*, vol. 84, no. 3, pp. 394–421, 2010.
- [2] L. Sherwood, *Human Physiology: From Cells to System*, Seventh., vol. 28, no. 3. Canada: Yolanda Cassio, 2010.
- [3] A. K. Uskul and A. B. Horn, "Emotions and Health," *International encyclopaedia of social and behavioral sciences*. pp. 1–24, 2015.
- [4] L. S. Berk, D. L. Felten, S. A. Tan, B. B. Bittman, and J. Westengard, "Modulation of Neuroimmune Parameters during the Eustress of Humor-associated Mirthful Laughter," *Altern. Ther. Health Med.*, vol. 7, no. 2, pp. 62–76, 2001.
- [5] J. F. Brosschot and J. F. Thayer, "Heart Rate Response is Longer after Negative Emotions than after Positive Emotions," *Int. J. Psychophysiol.*, vol. 50, no. 3, pp. 181–187, 2003.
- [6] S. Cohen and S. D. Pressman, "Positive Affect and Health," *Curr. Dir. Psychol. Sci.*, vol. 15, no. 3, pp. 122–125, 2006.
- [7] R. Glaser and J. Kiecolt-Glaser, "Stress Damages Immune System and Health," *Discov. Med.*, vol. 5, no. 26, pp. 165–169, 2005.
- [8] A. D. Wibawa, M. H. Purnomo, A. Marzuki, and L. D. Rumpa, "Physiological Pattern of Human State Emotion based on ECG and Pulse Sensor," *J. Theor. Appl. Inf. Technol.*, vol. 93, pp. 81–87, 2016.
- [9] A. D. Wibawa and M. H. Purnomo, "Physiological Pattern of Human Emotion State based on SPO2 sensor," *Int. J. Syst. Signal Control Eng. Appl.*, 2016.
- [10] S. D. Pressman and S. Cohen, "Does positive affect influence health?," *Psychol. Bull.*, vol. 131, no. 6, pp. 925–971, 2005.
- [11] B. E. Kok *et al.*, "How Positive Emotions Build Physical Health: Perceived Positive Social Connections Account for the Upward Spiral Between Positive Emotions and Vagal Tone," *Psychol. Sci.*, vol. 24, no. 7, pp. 1123–1132, 2013.
- [12] P. C. Petrantonakis and L. J. Hadjileontiadis, "Emotion Recognition from Brain Signals Using Hybrid Adaptive Filtering and Higher Order Crossings Analysis," *IEEE Trans. Affect. Comput.*, vol. 1, no. 2, pp. 81–97, 2010.

- [13] A. Mert and A. Akan, "Emotion recognition from EEG signals by using multivariate empirical mode decomposition," *Pattern Anal. Appl.*, vol. 21, no. 1, pp. 81–89, 2018.
- [14] Y. Zhang, X. Ji, and S. Zhang, "An approach to EEG-based emotion recognition using combined feature extraction method," *Neurosci. Lett.*, vol. 633, pp. 152–157, 2016.
- [15] F. Agrafioti, D. Hatzinakos, and A. K. Anderson, "ECG pattern analysis for emotion detection," *IEEE Trans. Affect. Comput.*, vol. 3, no. 1, pp. 102–115, 2012.
- [16] P. Gong, H. T. Ma, and Y. Wang, "Emotion recognition based on the multiple physiological signals," *2016 IEEE Int. Conf. Real-time Comput. Robot.*, pp. 140–143, 2016.
- [17] F. Canento, A. Fred, H. Silva, H. Gamboa, and A. Lourenço, "Multimodal Biosignal Sensor Data Handling for Emotion Recognition," pp. 1–4, 2011.
- [18] K. Gouizi, F. B. Reguig, and C. Maaoui, "Emotion recognition from physiological signals," *J. Med. Eng. Technol.*, vol. 35, no. 6–7, pp. 300–307, 2011.
- [19] A. Jubran, "Pulse oximetry," *Crit. Care*, vol. 19, no. 1, pp. 1–7, 2015.
- [20] M. Nitzan, A. Romem, and R. Koppel, "Pulse oximetry: Fundamentals and Technology Update," *Med. Devices Evid. Res.*, vol. 7, no. 1, pp. 231–239, 2014.
- [21] B. Koley and D. Dey, "On - line Detection of Apnea / Hypopnea Events Using SpO₂ Signal : A Rule - based Approach Employing Binary Classifier Models," no. c, pp. 1–8, 2013.
- [22] B. Xie and H. Minn, "Real-time sleep apnea detection by classifier combination," *IEEE Trans. Inf. Technol. Biomed.*, vol. 16, no. 3, pp. 469–477, 2012.
- [23] P. Lévy, J. L. Pépin, C. Deschaux-Blanc, B. Paramelle, and C. Brambilla, "Accuracy of oximetry for detection of respiratory disturbances in sleep apnea syndrome," *Chest*, vol. 109, no. 2, pp. 395–399, 1996.
- [24] Q.-V. Nguyen, R. Le Page, J.-M. Goujon, P. Guyader, and M. Billon, "Pulse Rate Analysis in Case of Central Sleep Apnea: A New Algorithm for Cardiac Rate Estimation," *Proc. 31st Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.*, vol. 2009, pp. 5490–5493, 2009.

- [25] W. Wen, G. Liu, N. Cheng, J. Wei, P. Shangguan, and W. Huang, "Emotion Recognition Based on Multi-Variant Correlation of Physiological Signals," *IEEE Trans. Affect. Comput.*, vol. 5, no. 2, pp. 126–139, 2014.
- [26] W. Huang, G. Liu, and W. Wen, "MAPD: A Multi-subject Affective Physiological Database," *Proc. - 2014 7th Int. Symp. Comput. Intell. Des. Isc. 2014*, vol. 2, pp. 585–589, 2015.
- [27] S. Begum, S. Barua, and M. U. Ahmed, "Physiological sensor signals classification for healthcare using sensor data fusion and case-based reasoning," *Sensors (Switzerland)*, vol. 14, no. 7, pp. 11770–11785, 2014.
- [28] A. Marzuki, L. D. Rumpa, A. D. Wibawa, and M. H. Purnomo, "Classification of human state emotion from physiological signal pattern using pulse sensor based on learning vector quantization," *Int. Semin. Intell. Technol. Its Appl.*, pp. 129–133, 2016.
- [29] L. D. Rumpa, A. D. Wibawa, M. H. Purnomo, and H. Tulak, "Validating video stimulus for eliciting human emotion: A preliminary study for e-health monitoring system," *Proc. - 2015 4th Int. Conf. Instrumentation, Commun. Inf. Technol. Biomed. Eng. ICICI-BME 2015*, no. October 2016, pp. 208–213, 2016.
- [30] J. Sun, Y. Ye, L. Chang, J. Jiang, and X. Ji, "Sleep monitoring approach based on belief rule-based systems with pulse oxygen saturation and heart rate," *Proc. 29th Chinese Control Decis. Conf. CCDC 2017*, pp. 1335–1340, 2017.
- [31] G. Memis and M. Sert, "Multimodal Classification of Obstructive Sleep Apnea Using Feature Level Fusion," *Proc. - IEEE 11th Int. Conf. Semant. Comput. ICSC 2017*, pp. 85–88, 2017.
- [32] P. R. Kleinginna and A. M. Kleinginna, "A Categorized List of Emotion Definitions, with Suggestions for a Consensual Definition," *Motiv. Emot.*, vol. 5, no. 4, pp. 345–379, 1981.
- [33] K. R. Scherer, "What are emotions? and how can they be measured?," *Soc. Sci. Inf.*, vol. 44, no. 4, pp. 695–729, 2005.
- [34] P. Ekman, "An Argument for Basic Emotions," *Cogn. Emot.*, vol. 6, no. 3–4, pp. 169–200, 1992.
- [35] J. A. Russell, "A circumplex model of affect," *J. Pers. Soc. Psychol.*, vol. 39, no. 6, pp. 1161–1178, 1980.

- [36] R. Bott, *Guyton and Hall Textbook of Medical Physiology 13ed*, no. 1. 2014.
- [37] T. Tamura and W. Chen, *Seamless healthcare monitoring : Advancements in wearable, attachable, and invisible devices*. Cham: Springer International Publishing AG, 2018.
- [38] S. Walsh and E. King, *Pulse Diagnosis : A Clinical Guide*. Sidney: Churchill Livingstone Elsevier, 2007.
- [39] L.-E. Copstead and J. Banasik, *Pathophysiology*, Fifth. Beijing: Elsevier Inc., 2014.
- [40] J. A. Myers, K. W. Milikan, and T. J. Saclarides, *Common Surgical Diseases*, Second. Chicago: Springer, 2008.
- [41] Cooking hacks, “e-Health Sensor Platform V2.0 for Arduino and Raspberry Pi [Biometric / Medical Applications],” 2016. [Online]. Available: <https://www.cooking-hacks.com/documentation/tutorials/ehealth-biometric-sensor-platform-arduino-raspberry-pi-medical/>.
- [42] K. M. Sensing, “How to Read SpO2.” Konica Minolta, 2006.
- [43] World Health Organization, “Proposed working definition of an older person in Africa for the MDS Project,” *Health statistics and information systems*, 2002. [Online]. Available: <http://www.who.int/healthinfo/survey/ageingdefnolder/en/>.
- [44] Kemenkes RI, “PMK RI No. 67 Tahun 2015 Penyelenggaraan Pelayanan Kesehatan Lanjut Usia di Puskesmas,” Jakarta, 2015.
- [45] Kementerian Kesehatan Republik Indonesia, “Situasi dan analisis lanjut usia,” *Jakarta Selatan*. pp. 4–7, 2014.
- [46] Fatmah, “Respons imunitas yang rendah pada tubuh manusia usia lanjut,” *Makara, Kesehat.*, vol. 10, no. 1, pp. 47–53, 2006.
- [47] K. S. Quigley, K. a Lindquist, and L. F. Barrett, “Inducing and Measuring Emotion and Affect: Tips, Tricks, and Secrets,” in *Handbook of Research Methods in Social and Personality Psychology: Second Edition*, New York: Cambride University Press, 2013, pp. 220–250.
- [48] J. Rottenberg, R. D. Ray, and J. J. Gross, *Emotion Elicitation Using Films*. New York: Oxford University Press, 2007.
- [49] V. Vapnik and C. Cortes, “Support Vector Networks,” *Mach. Learn.*, vol. 20, no. 3, pp. 273–297, 1995.

- [50] N. Cristianini and J. Shawe-Taylor, *An introduction to support vector machines and other kernel-based learning methods*. Cambridge: Cambridge University Press, 2000.
- [51] W. K. Härdle and L. Simar, *Applied Multivariate Statistical Analysis*. Berlin: Springer Berlin Heidelberg, 2015.
- [52] C.-W. Hsu, C.-C. Chang, and C. Lin, "A Practical Guide to Support Vector Classification," *BJU Int.*, vol. 101, no. 1, pp. 1396–400, 2008.
- [53] C. Chang and C. Lin, "LIBSVM: A Library for Support Vector Machines," *ACM Trans. Intell. Syst. Technol.*, vol. 2, pp. 1–39, 2013.
- [54] S. Abe, *Support Vector Machine for Pattern Classification*. London: Springer-Verlag London, 2010.
- [55] T. Cover and P. Hart, "Nearest neighbor pattern classification," *IEEE Trans. Inf. Theory*, vol. 13, no. 1, pp. 21–27, 1967.
- [56] T. M. Mitchell, *Machine learning*. New York: Mc Graw Hill Education, 1997.
- [57] L.-Y. Hu, M.-W. Huang, S.-W. Ke, and C.-F. Tsai, "The distance function effect on k-nearest neighbor classification for medical datasets," *Springerplus*, vol. 5, no. 1, p. 1304, 2016.
- [58] Z. Zhang, "Introduction to machine learning: k-nearest neighbors," *Ann. Transl. Med.*, vol. 4, no. 11, pp. 218–218, 2016.
- [59] P. Refaellizadeh, L. Tang, and H. Liu, "Cross-Validation," in *Encyclopedia of Database Systems*, New York: Springer Science+Business Media, LLC, 2009, pp. 532–538.
- [60] H. Candra *et al.*, "Investigation of window size in classification of EEG-emotion signal with wavelet entropy and support vector machine," *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, vol. 2015–Novem, pp. 7250–7253, 2015.

Halaman ini sengaja dikosongkan

LAMPIRAN

Lampiran 1 : Pseudo-code Segmentasi

1. Function Segmen Sinyal

```
function frames = segmen(s, fs, data)
f_size = round(s * fs);
n = length(data);
n_f = floor (n / f_size); % No frames
temp = 0;
for i = 1 : n_f
    frames(i,:) = data(temp + 1 : temp + f_size);
    temp = temp + f_size;
end
end
```

2. Pseudo-code utama

```
s = 15;
fs = 10;

sig = load('Baseline RISMAN.txt');
plot(sig)
hasil = segmen(s, fs, sig);
datasize, ~] = size(hasil);
feature = zeros(datasize,8);

for i = 1:datasize
    feature(i,1) = mean(hasil(i,:)); %Get Mean Value
    feature(i,2) = max(hasil(i,:)); %Get Maximum Value
    feature(i,3) = min(hasil(i,:)); %Get Minimum Value
    feature(i,4) = std(hasil(i,:)); %Get Standard Deviation
    feature(i,5) = mode(hasil(i,:)); %Get Modus value
    feature(i,6) = var(hasil(i,:)); %Get Variation Data
    feature(i,7) = feature(i,2) / feature(i,3); % Get Ratio
    feature(i,8) = mad(hasil(i,:)); %Get Mean Absolute Deviation
end
```

Lampiran 2 : Kuisioner

KUISIONER PASCA MENONTON VIDEO STIMULI

Nama : _____ Jenis Video : ☐ Senang ☐ Marah
Umur : _____ ☐ Sedih ☐ Takut

Pertanyaan berikut merujuk pada perasaan setelah anda menonton video stimuli :

1. Selama anda menonton video stimuli, emosi apa yang paling anda rasakan?

☐ Senang ☐ Marah ☐ Lainnya _____
☐ Sedih ☐ takut

Dengan menggunakan skala nilai berikut, seberapa besar emosi yang anda rasakan? (Lingkari pilihan nomor)

0	1	2	3	4	5	6	7	8
tidak				sedang				Sangat

2. Apakah anda merasakan emosi lain selama menonton video stimuli?

☐ Iya ☐ Tidak

3. Jika "Iya", emosi apa yang anda rasakan ?

☐ Senang ☐ Marah ☐ Lainnya _____
☐ Sedih ☐ takut

4. Seberapa besar emosi lain yang dirasakan? (Lingkari pilihan nomor jika jawab "iya")

0	1	2	3	4	5	6	7	8
tidak				sedang				Sangat


5. Apakah anda pernah menonton video ini sebelumnya?

☐ Iya ☐ Tidak

6. Apakah anda menutup mata atau memalingkan pandangan selama video berlangsung?

☐ Iya ☐ Tidak





Catatan Peneliti :











Peneliti





Partisipan



Lampiran 3 : Hasil Klasifikasi SVM 16 Fitur SpO₂-PR




























Lampiran 4 : Hasil Klasifikasi SVM 8 Fitur SpO₂





























Lampiran 5 : Hasil Klasifikasi SVM 8 Fitur PR











BIOGRAFI PENULIS



Lutfi Hakim, Magister Teknik Elektro Bidang Keahlian Telematika, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember Surabaya lahir di Banyuwangi, 30 Maret 1992 merupakan anak pertama dari Faishol dan Istiqomah. Penulis mempunyai dua adik kandung bernama Dewi Irpina dan Fitri Yupita serta Istri yang bernama Yuniarta Syarifatul Umami. Selama hidupnya, penulis menempuh pendidikan di TK Aisyah Bustanul Athfal (1997-1999), SDN 1 Kalirejo (1999-2005), SMPN 2 Banyuwangi (2005-2008), SMKN 1 Banyuwangi (2008-2011) Jurusan Rekayasa Perangkat Lunak. Penulis melanjutkan pendidikan sarjana di Universitas Negeri Surabaya (2011-2015) jurusan Pendidikan Teknik Elektro bidang minat Elektronika Komunikasi dengan bantuan Beasiswa Bidik Misi. Keinginan kuat untuk menjadi dosen, akademisi dan peneliti merupakan salah satu alasan utama penulis melanjutkan pendidikan magister di Institut Teknologi Sepuluh Nopember Departemen Teknik Elektro. Sinkronisasi keilmuan dengan latar belakang pendidikan yang telah ditempuh saat SMK (Teknik Informatika) dan sarjana (Elektronika Komunikasi) merupakan salah satu alasan mengapa penulis mengambil bidang keahlian Telematika (Telekomunikasi dan Informatika). Penulis melanjutkan pendidikan magister dengan bantuan beasiswa LPDP (Lembaga Pengelola Dana Pendidikan) dari Kementerian Keuangan Republik Indonesia. Selain aktifitas kuliah saat S1 maupun S2, penulis juga aktif di berbagai organisasi seperti UKKI UNESA dengan jabatan tertinggi Sekretaris Umum, Takmir Masjid Makmur I UNESA, Kepala Departemen Saintek Himpunan Mahasiswa Pascasarjana ITS, Awardee LPDP East Java, sebagai Lurah LPDP ITS, Mata Garuda Jawa Timur dan aktif dalam kepanitiaan event-event besar seperti menjadi ketua pelaksana kegiatan TOQQ Akbar kampus Ketintang UNESA, kepanitiaan berbagai kaderisasi UKKI UNESA, Bakti Karya Mahasiswa, Talkshow dan *Interactive Camp* LPDP East Java dan LPDP Edufair 2017. Selain itu, penulis juga

mengisi waktu luang untuk menjadi guru privat baik SD maupun SMP. Penulis saat ini menggeluti bidang data mining, *pattern recognition*, sistem biometrika, *machine learning*, *affective computing* dan analisa *time series*.

Penulis dapat dihubungi dengan kontak berikut:

Email : lutfi.hakim3003@gmail.com

Linkedin : www.linkedin.com/in/lutfi-hakim3003