

DAFTAR ISI

PERNYATAAN BEBAS PLAGIASI.....	iii
PRAKATA.....	iv
ARTI LAMBANG DAN SINGKATAN	vi
ABSTRACT.....	vii
INTISARI.....	viii
DAFTAR ISI	ix
DAFTAR GAMBAR	xi
DAFTAR TABEL.....	xiii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Perumusan masalah.....	4
1.3 Batasan Penelitian	5
1.4 Keaslian penelitian.....	5
1.5 Tujuan Penelitian	13
1.6 Manfaat Penelitian	14
BAB II TINJAUAN PUSTAKA DAN LANDASAN TEORI.....	15
2.1 Tinjauan Pustaka	15
2.2 Landasan Teori	17
2.2.1 <i>Emotion Model</i>	17
2.2.1.1 Categorical Model.....	17
2.2.1.2 Dimensional Models	19
2.2.2 <i>Dataset</i>	20
2.2.3 <i>Sinyal Physiological</i>	22
2.2.3.1 <i>Cardiac Activity</i>	22
2.2.3.2 <i>Accelerometer</i>	24
2.2.3.3 <i>Respiration</i>	27
2.2.3.4 <i>Electrodermal Activity</i>	28
2.2.3.5 <i>EMG</i>	30
2.2.3.6 <i>Temperature</i>	32
2.2.4 <i>Pre-Processing Data</i>	34
2.2.5 Ekstraksi Ciri Statistik	37
2.2.5.1 <i>Mean (μ)</i>	37
2.2.5.2 <i>Standar Deviasi (σ)</i>	38
2.2.6 Pemilihan Fitur.....	38
2.2.6.1 <i>Metode Wrapper</i>	39
2.2.7 <i>K-Nearest Neighbors</i>	41
2.2.8 <i>Quadratic Discriminant Analysis</i>	43
2.2.9 <i>Decision Tree</i>	44
2.2.10 <i>Support Vector Machine</i>	49

2.2.11	<i>Boosting</i>	54
2.2.10.1	<i>Extreme Gradient Boosting</i>	55
2.2.12	<i>K-Fold Cross Validation</i>	57
2.2.13	Indeks Kerja Klasifikasi	59
2.2.13.1	<i>Precision</i>	61
2.2.13.2	<i>Recall</i>	61
2.2.13.3	<i>F1-score</i>	61
2.2.14	Pengujian Statistika	62
2.3	Hipotesis	62
BAB III METODOLOGI		63
3.1	Alat dan Bahan.....	63
3.1.1	Alat.....	63
3.1.2	Bahan.....	65
3.1.2.1	Struktur Dataset	66
3.1.2.2	Subjek Penelitian	66
3.1.2.3	Format Dataset.....	66
3.1.2.3	Subjek Penelitian	68
3.1.2.4	Groundtruth.....	69
3.2	Jalannya Penelitian.....	69
3.3	Perancangan Sistem	74
3.3.1	Pengumpulan Data	75
3.3.2	Pelabelan Data.....	77
3.3.3	<i>Pre-Processing Data</i>	79
3.3.4	Ekstraksi dan Seleksi Ciri	84
3.3.5	Algoritma Klasifikasi	87
3.3.5	<i>K-Fold Cross Validation</i>	87
3.3.5	Evaluasi Performa Klasifikasi.....	88
3.3.6	Pengujian Statistika.....	90
3.4	Cara Analisis	91
BAB IV HASIL DAN PEMBAHASAN		93
4.1	Analisis plot gambar sensor data untuk 4 keadaan emosi.....	94
4.2	Hasil Pengujian <i>Quadratic Discriminant Analysis (QDA)</i>	99
4.3	Hasil Pengujian <i>k-Nearest Neighbors (k-NN)</i>	102
4.4	Hasil Pengujian <i>Decision Tree (DT)</i>	105
4.5	Hasil Pengujian <i>Extreme Gradient Boosting</i>	108
4.6	Hasil Pengujian <i>Support Vector Machine</i>	111
4.7	Perbandingan Metode Klasifikasi	112
4.8	Pengujian Statistika.....	115
4.9	Perbandingan Performa Model dengan Penelitian Sebelumnya	117
BAB V KESIMPULAN DAN SARAN		119
5.1	Kesimpulan	119
5.2	Saran	119
DAFTAR PUSTAKA		121

DAFTAR GAMBAR

Gambar 2.1 Dua dimensi model emosi yang dimodifikasi oleh Wundt [48].....	19
Gambar 2.2 Teori emosi oleh A: James-Lang Theory B: Cannon-Bard Theory C: Schachter-Singer Theory D: Cognitive Appraisal Theory.	20
Gambar 2.3 Sensor EKG biosignalsplux dengan kabel elektroda	23
Gambar 2.4 Contoh visualisasi sinyal <i>physiological</i> EKG.....	24
Gambar 2.5 Sensor <i>accelerometer</i> dari <i>biosignalsplux</i>	25
Gambar 2.6 Contoh visualisasi sinyal <i>physiological accelerometer</i>	26
Gambar 2.7 Sensor <i>respiration</i> dari biosignalsplux.....	27
Gambar 2.8 Contoh visualisasi sinyal <i>physiological respiration</i>	28
Gambar 2.9 Sensor <i>electrodermal</i> dari biosignalsplux	29
Gambar 2.10 Visualisasi sinyal <i>physiological</i> EDA	30
Gambar 2.11 Sensor <i>Electromyography</i> dari biosignalsplux	31
Gambar 2.12 Visualisasi sinyal <i>physiological</i> EMG.....	32
Gambar 2.13 Sensor <i>temperature</i> dari biosignalsplux	33
Gambar 2.14 Visualisasi sinyal <i>physiological temperature</i>	34
Gambar 2.15 Contoh visualisasi nilai <i>Inter Quartile Range</i> pada distribusi data.	35
Gambar 2.16 Langkah dalam melakukan seleksi fitur.....	39
Gambar 2.17 Ilustrasi metode <i>wrapper</i> pada seleksi fitur	40
Gambar 2.18 Ilustrasi Algoritma <i>K-Nearest Neighbors</i> [73]	42
Gambar 2.19 Contoh plot elipsoid kovarian dari setiap kelas dan batas keputusan yang dipelajari oleh LDA dan QDA [75]	44
Gambar 2.20 Struktur dan komponen dari algoritma <i>decision tree</i>	45
Gambar 2.21 Contoh visualisasi <i>hyperplane</i> pada klasifikasi SVM.....	50
Gambar 2.22 <i>Hyperplane</i> yang memisahkan dua kategori	53
Gambar 2.23 Proses <i>Cross-Validation</i> pada model klasifikasi	58
Gambar 2.24 Ilustrasi skema 5-Fold <i>Cross Validation</i> pada kumpulan data	59
Gambar 3.1 Lokasi penempatan sensor [7].....	67
Gambar 3.2 Empatica E4 wristband [7].....	68
Gambar 3.3 Alur penelitian	70
Gambar 3.4 Representasi umum metode dan alur model yang akan digunakan ..	74
Gambar 3.5 Jumlah total sampel data yang dikumpulkan untuk setiap label	77
Gambar 3.6 Studi protokol pelabelan data pada tiap sesi perekaman data	78
Gambar 3.7 <i>Boxplot</i> data yang belum dibersihkan dari <i>outlier</i>	80
Gambar 3.8 <i>Boxplot</i> data setelah membersihkan data sensor dan menghapus <i>outlier</i>	81
Gambar 3.9 5 <i>Value</i> awal dari data yang sudah di bersihkan.....	82
Gambar 3.10 Informasi penting tentang jumlah baris dan kolom untuk data yang sudah dibersihkan.....	82
Gambar 3.11 Informasi statistik tentang kumpulan data yang sudah dibersihkan	83
Gambar 3.12 Visualisasi <i>heatmap</i> dengan nilai korelasi menggunakan <i>corelation</i>	

<i>matrix</i>	85
Gambar 3.13 P-value tiap sensor physiological.....	86
Gambar 3.14 Hasil dari feature selection menggunakan <i>sequential backward selection</i>	86
Gambar 3.15 Hasil dari feature selection menggunakan <i>sequential forward selection</i>	87
Gambar 3.16 Pembagian data 10-fold cross validation pada dataset WESAD	88
Gambar 3.17 Contoh hasil <i>confusion matrix</i>	90
Gambar 4.1 Data sumbu X pada sensor akselerometer untuk 4 kondisi emosi	94
Gambar 4.2 Data sumbu Y pada sensor akselerometer untuk 4 kondisi emosi	95
Gambar 4.3 Data sumbu Z pada sensor akselerometer untuk 4 kondisi emosi.....	95
Gambar 4.4 Visualisasi data sensor temperatur untuk kondisi netral, stres, <i>amusement</i> , dan meditasi	96
Gambar 4.5 Visualisasi data sensor EKG untuk kondisi netral, stres, <i>amusement</i> , dan meditasi	97
Gambar 4.6 Visualisasi data sensor EDA untuk kondisi netral, stres, <i>amusement</i> , dan meditasi	97
Gambar 4.7 Visualisasi data sensor EMG untuk kondisi netral, stres, <i>amusement</i> , dan meditasi	98
Gambar 4.8 Visualisasi data sensor RESP untuk kondisi netral, stres, <i>amusement</i> , dan meditasi	99
Gambar 4.9 Matriks klasifikasi QDA dengan 10-Fold Cross Validation.....	100
Gambar 4.10 Matriks klasifikasi QDA dengan 20-Fold Cross Validation.....	100
Gambar 4.11 Matriks klasifikasi QDA dengan reg_param 0.7 dan 10-Fold Cross Validation	101
Gambar 4.12 Matriks klasifikasi k-NN dengan <i>hyperparameter</i> K=3 dan 10-Fold Cross Validation	103
Gambar 4.13 Matriks klasifikasi k-NN dengan K=5 dan 20-Fold Cross Validation	103
Gambar 4.14 Matriks klasifikasi k-NN dengan K=40 dan 10-Fold Cross Validation	104
Gambar 4.15 Matriks klasifikasi DT dengan Criterion = Gini, Max_depth = 5, CV = 10	106
Gambar 4.16 Matriks klasifikasi DT dengan Criterion = Entropy, Max_depth = 5, CV = 10	106
Gambar 4.17 Matriks klasifikasi DT dengan Criterion = Entropy, Max_depth = 7, CV = 10	107
Gambar 4.18 Matriks klasifikasi XGBoost model pertama	109
Gambar 4.19 Matriks klasifikasi XGBoost model kedua	110
Gambar 4.20 Matriks klasifikasi XGBoost model ketiga	111
Gambar 4.21 Hasil matriks klasifikasi model SVM	112
Gambar 4.22 <i>Machine learning</i> model yang diajukan.....	114
Gambar 4.23 Hasil uji normalitas tiap <i>classifier</i> pada SPSS	116
Gambar 4.24 Hasil uji homogenitas tiap <i>classifier</i> pada SPSS.....	117
Gambar 4.25 Hasil uji One Way ANOVA tiap <i>classifier</i> pada SPSS.....	117

DAFTAR TABEL

Tabel 1.1 Penelitian sebelum dan saat ini studi klasifikasi emosi menggunakan sinyal <i>physiological</i> berbasis perangkat <i>wearable</i>	8
Tabel 2.1 <i>Categorical model emotion</i>	18
Tabel 2.2 <i>Dataset</i> tentang rekognisi emosi menggunakan <i>physiological signal</i> yang dapat di akses bebas oleh publik	21
Tabel 3.1 Detail kondisi subjek penelitian	66
Tabel 3.2 Nilai IQR tiap sensor.....	79
Tabel 3.3 Perbandingan data statistik sebelum dan sesudah dilakukan <i>pre-processing</i>	83
Tabel 3.4 Pengurangan jumlah sampel dalam <i>dataset</i> WESAD	84
Tabel 3.5 <i>Confusion matrix multi-class</i>	89
Tabel 4.1 Analisis performa melalui <i>Precision, Recall, Accuracy, F1-score</i> dari setiap model	113
Tabel 4.2 Hasil akurasi model QDA pertama pada subjek penelitian lainnya	114

BAB I

PENDAHULUAN

1.1 Latar Belakang

Emosi merupakan bagian integral dari perilaku manusia, memberikan pengaruh yang kuat dalam mekanisme pemikiran manusia seperti persepsi, perhatian, pembelajaran dan pengambilan keputusan. Emosi adalah bagian penting dari komunikasi manusia yang mempengaruhi kesadaran kita secara dramatis. Emosi manusia dapat diekspresikan dalam bentuk keadaan afektif. Keadaan afektif mewakili perasaan atau emosi seperti kegembiraan, ketakutan, stres, dll. dalam periode waktu tertentu.

Pengertian emosi menurut Kamus Besar Bahasa Indonesia adalah luapan perasaan yang berkembang dan surut dalam waktu singkat; keadaan dan reaksi psikologis dan fisiologis [1]. Emosi juga dapat didefinisikan sebagai suatu keadaan yang kompleks dan dari perasaan tersebut dapat dilihat perubahan fisik maupun psikologisnya, sehingga dapat mempengaruhi pemikiran dan perilaku [2]. Proses kemunculan emosi melibatkan faktor psikologis maupun faktor fisiologis. Emosi pertama kali muncul akibat adanya rangsangan atau sebuah peristiwa, yang bisa bersifat netral, positif, ataupun negatif. Rangsangan tersebut kemudian ditangkap oleh reseptor seseorang, lalu melalui otak seseorang dapat menginterpretasikan kejadian tersebut sesuai dengan kondisi pengalaman dan kebiasaannya dalam mengartikan persepsi sebuah kejadian. Interpretasi yang telah dibuat seseorang akan memunculkan perubahan secara internal dalam tubuh.

Dalam beberapa dekade terakhir, sinyal *physiological* telah mendapatkan banyak perhatian di antara para peneliti di bidang komputasi afektif. Respons fisiologis pada tubuh dapat digunakan untuk mengukur keadaan afektif seseorang, hal itu terjadi karena terdapat reaksi perubahan pada *Autonomic Nervous System* [3]. Respons *Autonomic Nervous System* mengubah pola sinyal *physiological* di dalam tubuh sehingga dapat diteliti lebih lanjut dikarenakan sinyal *physiological* di dalam tubuh merupakan respons tak sadar dari tubuh yang tidak dapat dimanipulasi

saat tubuh merespons evokasi atau rangsangan sebuah peristiwa. Hal ini merupakan kelebihan dari penggunaan sinyal *physiological* dikarenakan aspek emosi seseorang dapat dan dimungkinkan terlihat pada saat orang tersebut melakukan pemeriksaan dengan sensor *physiological* yang dapat merekam data sinyal *pyhsiological* dalam tubuh.

Pengenalan emosi menggunakan sinyal *physiological* telah menjadi area yang sangat aktif di bidang komputasi afektif. Kemajuan baru dalam teknologi sensor memungkinkan untuk menemukan sensor fisiologis yang tertanam di banyak perangkat sehari-hari, seperti *armbands* dan *smartwatch*. Salah satu keuntungan mengukur respons fisiologis terhadap emosi adalah bahwa respons tersebut tidak mudah dipicu oleh pengguna [4]. *Smartwatch* dan *smartband* lebih cocok untuk penggunaan sehari-hari karena tidak mengganggu mobilitas, mudah digunakan, dan tidak memerlukan gerakan dan instalasi yang rumit.

Pengenalan emosi berbasis sensor tetap menjadi subjek yang relatif belum dewasa karena kompleksitas yang ditimbulkan oleh beberapa faktor seperti kesulitan untuk memberi label data dengan benar dan heterogenitas yang tinggi di dalam kelas saat menggunakan sinyal *physiological* di lingkungan luar ruangan [5]. Metode evaluasi data sinyal *physiological* jangka panjang juga dapat menjadi tantangan bagi individu dan sangat memakan waktu, terutama untuk *smartwatch* atau pemantauan medis elektronik yang dapat dikenakan (*Wearable Device*). Oleh karena itu, kesalahan yang lebih spesifik dapat muncul selama tinjauan pengenalan emosi. Sinyal *physiological* merupakan tanda-tanda yang sangat penting dari tubuh manusia. Contoh yang termasuk dalam kategori sinyal *physiological* antara lain: sinyal Elektrokardiogram (EKG), sinyal Elektroensefalogram (EEG), sinyal *Electromyogram* (EMG), *Blood Volume Pressure* (BVP), variabilitas denyut jantung (HRV), *Galvanic Skin Response* (GSR), suhu kulit (*Skin Temperature*), konduktivitas kulit (*Skin Conductivity*) dan laju pernapasan (*Respiration Rate*).

Pengenalan emosi dalam lingkungan terkendali telah diselidiki dalam banyak penelitian [6][7][8]. Terlepas dari keberhasilan banyak sistem pengenalan dalam kondisi lab, deteksi emosi dalam skenario dunia nyata tetap merupakan tugas

yang menantang. Kinerja dan keakuratan pengenalan sistem semacam itu terbatas, yang mengurangi potensinya untuk aplikasi dunia nyata.

Saat ini, tidak ada kesepakatan umum tentang universalitas atau standar respons sinyal *physiological* tubuh terhadap emosi. Oleh karena itu, banyak peneliti melaporkan hasil yang lebih baik dalam pengenalan emosi saat menggunakan model yang dilatih untuk setiap individu secara terpisah. Tantangan lain dalam menggunakan sinyal fisiologis untuk pengenalan emosi adalah untuk memahami pengaruh faktor-faktor lain (misalnya, aktivitas fisik) terhadap respons fisiologis tubuh manusia. Namun, sebagian besar penelitian yang menyelidiki efek ini berfokus pada kondisi laboratorium di mana perekaman sinyal *physiological* terbatas menggunakan alat perekam sinyal *physiological medical grade*, di satu pihak tidak menggunakan *consumer wearable devices* sehingga tidak dapat digunakan bebas di pasaran.

Pada penelitian terkait rekognisi dan klasifikasi *multi-class* emosi seperti pada penelitian Schmidt, dkk. [7], klasifikasi *multi-class* untuk 4 label yang ditetapkan masih memiliki akurasi yang rendah yaitu sebesar 80,34% pada seluruh sensor dada menggunakan *classifier* AdaBoost. Penelitian Murthada [9] juga melakukan klasifikasi *multi-class* emosi menggunakan *convolutional neural network* (CNN) menggunakan *physiological signal* data yang ada pada sensor dada dengan akurasi yang didapatkan sebesar 80% dengan kelebihan yaitu tanpa harus menentukan fitur mana yang memiliki pengaruh paling besar pada proses klasifikasi emosi.

Siirtola [10] melakukan penelitian untuk mempelajari apakah mungkin untuk mendeteksi emosi menggunakan data *physiological signal* yang ada pada sensor jam tangan pintar komersial yang tidak menyertakan sensor EDA. Pada penelitian Siirtola dimungkinkan mendeteksi emosi menggunakan data *physiological signal* sensor jam tangan pintar komersial yang tidak menyertakan sensor EDA dengan akurasi pengenalan emosi sebesar 87,4% menggunakan pengklasifikasi LDA untuk deteksi kondisi *stress* dan non *stress*. Lalu tingkat pengenalan emosi akurasinya sedikit turun jika sinyal EDA digunakan bersama

dengan sinyal *physiological* yang lain.

Selain itu penerapan *feature selection* juga mempengaruhi hasil klasifikasi emosi menggunakan data *physiological signal*. Metode *feature selection* diterapkan pada tahap *pre-processing* data dengan memilih fitur/atribut yang optimal dari *dataset* yang dianalisis. Ada berbagai teknik dalam metode seleksi fitur, seperti RF-RFE, *Genetic Algorithm*, *Stepwise Regression*, *Wrapper*, dan lainnya. Beberapa penelitian yang menerapkan metode seleksi fitur, seperti [6], [11]–[14] terbukti mampu meningkatkan kinerja pemodelan.

Beberapa penelitian yang telah dipaparkan menunjukkan kenaikan kinerja metode namun belum cukup baik untuk klasifikasi *multi-class* emosi. Sebagian penelitian hanya menerapkan metode pada tahap *pre-processing* saja atau pada saat pemodelan dijalankan serta hanya mengklasifikasikan emosi sebagai dua kelas seperti *positive affective* dan *negative affective* sehingga mendapatkan akurasi yang tinggi [9], [10], [15], [16]. Klasifikasi emosi *multiclass* yang dimaksud adalah klasifikasi beberapa emosi tersendiri dan tidak mengklasifikasikan emosi yang ter evokasi secara bersamaan. Untuk klasifikasi *multi-class* emosi sendiri akurasi yang didapatkan masih belum baik [7], [15], [16]. Penelitian ini difokuskan pada bagaimana meningkatkan kinerja model menjadi lebih baik dengan memaksimalkan performa hasil klasifikasi *multi-class* emosi dan penggunaan *feature selection* dalam memprediksi kondisi emosi. Kinerja pemodelan yang baik akan memberikan hasil prediksi yang lebih akurat.

1.2 Perumusan masalah

Berdasarkan latar belakang yang telah diuraikan sebelumnya, maka rumusan masalah penelitian ini dapat diidentifikasi sebagai berikut;

1. Penelitian terkait klasifikasi *multi-class* emosi belum memberikan hasil kinerja yang belum cukup baik.
2. Bagaimana membangun model klasifikasi serta meningkatkan performa klasifikasi *multi-class* emosi menggunakan data sinyal *physiological* yang ada pada *wearable devices*.

1.3 Batasan Penelitian

Terdapat *exclusion* kriteria subjek penelitian yaitu tidak boleh keadaan hamil [17], dalam pengaruh minuman beralkohol [18], perokok berat [19], memiliki gangguan kesehatan mental [20], memiliki riwayat gangguan penyakit jantung serta gangguan jantung kronis [21]. Dalam penelitian Wiggert, dkk. menyebutkan bahwa kondisi yang sudah disebutkan di atas mempengaruhi aktivitas *physiological* pada tubuh. Subjek penelitian memiliki rata-rata umur 27.5 Tahun dengan dua belas subjek berjenis kelamin laki-laki dan tiga orang perempuan. Hal ini dikarenakan rentang usia tersebut mudah untuk diberikan stimulus/rangsangan agar dapat menganalisis kondisi emosi [7]. Subjek penelitian dibatasi pengukuran sinyal *physiological* yaitu, Elektrokardiogram (EKG), *Electromyogram* (EMG), *Electrodermal activity* (EDA), *Respiration* (RSP) dan Temperatur (TEMP) pada alat *wearable* RespiBan Professional. Lalu untuk identifikasi pengaruh aktivitas fisik menggunakan data sensor ACC. Selanjutnya penelitian ini membatasi kondisi emosi yang akan diidentifikasi yaitu kondisi emosi netral, emosi negatif (*stress*), emosi positif (*amusement*), dan emosi kondisi relaksasi (*relax*).

1.4 Keaslian penelitian

Dalam beberapa tahun terakhir, ada upaya untuk mengotomatiskan prediksi dan deteksi emosi dengan model pembelajaran mesin, yang dilatih menggunakan sinyal *physiological* terhadap stres dan rangsangan emosional. Guo, dkk. [22] telah mengklasifikasikan 5 kondisi emosi yaitu di lingkungan laboratorium menggunakan *wearable device* XYZlife C1. Mereka mengekstrak 13 fitur HRV dalam sinyal EKG dan mengevaluasi hasilnya dengan *Principal Component Analysis* (PCA) dan *Support Vector Machine* (SVM). Kemudian digunakan 5 fitur pilihan PCA untuk memperoleh 71,4% dan 56,9% untuk klasifikasi 2 dan 5 keadaan emosi. Dalam studi percontohan ini, Guo, dkk. mendemonstrasikan bahwa fitur HRV tunggal dapat digunakan untuk klasifikasi keadaan emosi melalui pengklasifikasi SVM. Meskipun penelitian ini menggunakan *wearable device* EKG, Akan tetapi penelitian ini terbatas pada kondisi lab tanpa melakukan aktivitas fisik.

Schmidt, dkk. [7] telah memperkenalkan *dataset* WESAD untuk tujuan *wearable* mempengaruhi dan deteksi stres dan membuatnya tersedia untuk umum. Untuk mengumpulkan data ini mereka telah memilih 15 orang dan mencatat data fisiologis seperti percepatan tiga sumbu, elektrokardiogram, volume darah nadi, suhu tubuh, pernapasan, *electromyogram* dan aktivitas *electrodermal* dengan meletakkan perangkat *wearable* - RespiBAN Professional dan Empatica E4 di dada dan di pergelangan tangan masing-masing subjek uji coba. Mereka menjadikan subjek berbagai kondisi stres seperti *baseline*, hiburan, stres, meditasi, dll. Mereka telah menggunakan dan membandingkan kinerja lima algoritma pembelajaran mesin untuk deteksi status stres: *K-Nearest Neighbor* (kNN), *Linear Discriminant Analysis* (LDA), *Random Forest* (RF), *Decision Tree* (DT), *AdaBoost* (AB). Mereka mencapai akurasi klasifikasi hingga 80,34% dengan mempertimbangkan masalah klasifikasi tiga kelas (hiburan vs. *baseline* vs. stres), masing-masing dengan menggunakan fitur umum yang ada dan metode pembelajaran mesin.

Xu, dkk. [23] melakukan penelitian dan menyimpulkan bahwa ER (*Emotion Recognition*) dengan menggunakan sinyal *physiological* dapat dipengaruhi oleh gerakan manusia. Xu, dkk. menyelidiki pengenalan sekelompok emosi dengan menggunakan berbagai sinyal fisiologis dan algoritme yang umum digunakan dengan skenario di dalam laboratorium, dan skenario dunia nyata. Hasilnya menunjukkan bahwa sinyal SKT (*Skin Temperature*), EDA (*Electrodermal Activity*), dan EMG (*Elektromiograf*) mencapai keakuratan tertinggi saat data dikumpulkan saat peserta sedang istirahat. Selanjutnya juga menunjukkan bahwa *output* klasifikasi *Decision Tree* memiliki hasil terbaik. Dari penelitian tersebut dapat disimpulkan bahwa gerakan manusia (*Physical Activity*) memengaruhi sinyal fisiologis yang diukur dari pengguna, dan oleh karena itu memengaruhi hasil ER (*Emotion Recognition*). Untuk alasan ini, penelitian emosi harus memperhitungkan efek *physical activity* saat mengembangkan model untuk pengenalan emosi. Model ER berdasarkan eksperimen terkontrol tidak dapat digunakan secara akurat untuk mengenali emosi dalam skenario dunia nyata.

Penelitian terbaru menunjukkan bahwa deteksi dan klasifikasi emosi

menggunakan Multi-modal sinyal *physiological* yaitu sinyal EKG, sinyal EMG, volume tekanan darah (BVP), aktivitas *electrodermal* (EDA), suhu kulit (TEMP), dan laju pernapasan (RESP). Alasannya sinyal *physiological* merupakan reaksi tak sadar dari tubuh yang diatur oleh *autonomous nervous system* (ANS), dan dengan demikian sangat sulit untuk menutupinya sehingga emosi yang muncul tidak dapat di manipulasi. Dengan metode ekstraksi ciri dan klasifikasi yang berbeda-beda, hasil penelitian [6], [22], [24]–[26] menunjukkan tingkat akurasi yang cukup tinggi dengan *range* akurasi adalah 56% - 92%. Tabel 1.1 menunjukkan detail penelitian yang telah dilakukan dalam mengidentifikasi dan mengklasifikasikan berbagai jenis emosi menggunakan alat perekam sinyal *physiological*, *wearable* atau tidak, *emotion stimuli* yang digunakan serta keterangan *environment*, *feature selection* dan metode klasifikasinya.

Tabel 1.1 Penelitian sebelum dan saat ini studi klasifikasi emosi menggunakan sinyal *physiological* berbasis perangkat *wearable*.

No	Peneliti	Tahun	<i>Physiological Signal</i>	Emosi	Stimulus	Lingkungan	Wearable	Feature Selection	Klasifikasi
1	Huang, dkk. [11]	2018	EKG, HRV	Kondisi kelelahan mental	Quiz	Lab dalam ruangan	Ya	<i>Random Forest</i>	<i>SVM, kNN, Naïve Bayes, LR</i>
2	Judith, dkk. [27]	2018	BVP, ST	Netral	IAPS	Luar ruangan terbatas	Ya	Tidak	<i>kNN, RF</i>
3	Schmidt, dkk. [7]	2018	ACC, EKG, EDA, BVP, EMG, RSP, ST	Netral, Hiburan, Stres, Meditasi	Video, TSST, <i>Breathing exercise</i>	Lab Dalam Ruangan, Aktivitas Terkendali	Ya	Tidak	<i>DT, RF, AdaBoost, LDA, kNN</i>
4	Fenghua Li, dkk. [28]	2018	<i>Pulse rate variability (PRV)</i>	Stres, Tidak stres	<i>Mental Arithmetic Test</i>	Lab dan Luar Ruangan	Ya	Tidak	<i>Self-report with feature labeling</i>
5	Quiroz, dkk. [29]	2018	<i>Heart Rate (HR)</i>	Bahagia, Sedih, dan Netral	Audio dan Video	Lab Dalam Ruangan,	Ya	Tidak	<i>RF, LR</i>
6	Xiefeng, dkk. [6]	2019	EKG HRV, Heart Sound	Relaxed, Sad, Happy, Angry	IAPS, IADS, CADS	Lab Dalam Ruangan	Ya	<i>Genetic Algorithm</i>	<i>SVM</i>
7	Menghini, dkk. [8]	2019	HR, HRV	Stres	Stress Reactivity Research Task	Lab, Aktivitas Terbatas	Ya	Tidak	<i>Bland-Altman plots</i>

8	Siirtola. [10]	2019	ST, BVP, HR, HRV	Stres	TSSST	Lab Dalam Ruangan, Aktivitas Terkendali	Ya	Tidak	<i>LDA, QDA, RF</i>
9	Jiménez, dkk. [12]	2019	PPG, GSR	Hiburan, sedih, dan netral	FilmStim Dataset	Lab Dalam Ruangan	Ya	RF-RFE, GA, Stepwise Regression	<i>SVML, LDA, MN, DT, XGBOOST, BLR</i>
10	Hsu, dkk. [13]	2020	EKG	<i>Valence, Arousal,</i>	Audio	Lab Dalam Ruangan	Ya	<i>Sequential Forward Floating Selection</i>	<i>LS-SVM</i>
11	Shu, dkk. [14]	2020	<i>Heart Rate</i>	Netral, Bahagia, Sedih	CEVS	Lab Dalam Ruangan	Ya	SelectKBest	<i>kNN, RF, DT, GBDT, AdaBoost</i>
12	Zhang, dkk. [30]	2020	EDA, HR	<i>Valence, Arousal</i>	CASE, MERCA	Lab, <i>Indoor,</i> dan <i>Outdoor</i>	Ya	Tidak	<i>Broad Learning System</i>
13	Frédéric, dkk. [5]	2020	EOG, EMG, GSR, BVP, ST, and RSP	Valence, Arousal	Music Videos	Lab, <i>Indoor</i>	Ya	Tidak	Variational Autoencoder-Transfer, CNN-transfer
14	Feng, dkk. [31]	2020	HR, GSR, ST, Walking Steps	PERMA	<i>Daily Activity</i>	Luar ruangan, Aktivitas Harian	Ya	Tidak	<i>Binary classification</i>

15	Umair, dkk. [4]	2021	HRV	Baseline, Stres, dan Istirahat	Stressor Tasks: Stroop Color Test, TSST, Cycling	Lab Dalam Ruangan	Ya	Tidak	<i>Bland-Altman plots</i>
16	Shuhao, dkk. [32]	2021	Skin Potential (SP)	Bahagia, sedih, marah, takut	Video	Lab Dalam Ruangan	Ya	SelectKBest	<i>kNN, neural network (NN), LDA, LR, RF, DT, SVM, and GBDT</i>
17	Miranda, dkk. [33]	2021	EKG, GSR, ST	Takut	Video Clips	Lab Dalam Ruangan	Ya	Tidak	<i>SVM, kNN, ENS</i>
18	Penelitian ini	2021	ACC, EKG, EDA, BVP, EMG, RSP, ST	Netral, Hiburan, Stres, Meditasi	Video, TSST, <i>Breathing exercise</i>	Lab Dalam Ruangan, Aktivitas Terkendali	Ya	<i>Wrapper</i>	QDA, kNN, XGBoost, DT, SVM

Dilihat dari Tabel 1.1, klasifikasi biner dilakukan di sebagian penelitian yang disajikan (63%). Hal ini berlaku untuk kasus-kasus di mana protokol penelitian ditujukan untuk memunculkan emosi yang berbeda di model emosi *valence* dan *arousal*. Berdasarkan penelitian-penelitian yang telah dilakukan, data yang paling banyak digunakan untuk pengenalan atau identifikasi kondisi emosi adalah sinyal *physiologicial*, khususnya fitur yang ada di sinyal *physiological* EKG. Akan tetapi pada lima tahun terakhir fokus penelitian deteksi dan ER (*emotion recognition*) berfokus pada pengaruh aktivitas fisik dan menggunakan multi-modal sinyal *physiological*, daripada dengan hanya menggunakan satu sinyal *physiological*. Satu sinyal *physiological* tidak bisa dijadikan standar karena menghasilkan terlalu spesifik terhadap pengguna yang akhirnya mendapat tingkat akurasi yang tinggi dan tidak bisa digunakan terhadap data sinyal *physiological* pasien yang lain.

Mempertimbangkan *setting environment* penelitian, tiga jenis studi dibedakan menjadi studi lab, lapangan atau luar ruangan, dan lapangan/luar ruangan dengan aktivitas terbatas. Studi yang dilakukan di dalam keadaan luar laboratorium disebut sebagai studi luar ruang dengan aktivitas terbatas, karena pergerakan subjek dibatasi. Selain itu, studi adalah subjek mengikuti jalur tertentu (luar ruangan), misalnya [27] disebut sebagai studi luar laboratorium dengan aktivitas terbatas. Sebagian besar 13 dari 17 studi yang disajikan pada Tabel 1.1, hanya mendasarkan hasil mereka pada data yang direkam di laboratorium. Popularitas studi laboratorium dengan mudah dijelaskan dikarenakan dalam studi laboratorium protokol studi dirancang untuk memperoleh sekumpulan status emosi tertentu. Oleh karena itu, rasio *signal to noise* studi di laboratorium jauh lebih tinggi daripada di studi luar ruangan. Selain itu, setelah rangkaian rangsangan dipilih, protokol yang sama diterapkan pada banyak subjek, yang membuat studi laboratorium menjadi sangat efisien. Namun, model yang dilatih pada data yang dikumpulkan di lingkungan laboratorium dan melakukan validasi pada kondisi luar laboratorium seperti pada [28], cenderung menunjukkan kinerja yang kurang baik karena dalam pengaturan yang tidak terlalu dibatasi karena subjek penelitian tidak sadar dengan emosinya sendiri.

Metode klasifikasi yang banyak digunakan adalah LDA, SVM, DT dan kNN. Teknik klasifikasi menggunakan metode SVM umumnya mempunyai tingkat akurasi prediksi tinggi dari fungsi target belajar. Kelemahan umum dari teknik non-parametrik seperti SVM adalah kurangnya transparansi hasil. Sedangkan klasifikasi menggunakan kNN lebih efektif digunakan pada data pelatihan yang besar, dapat menghasilkan data yang lebih akurat, dan tangguh terhadap pelatihan data yang *noisy*. Akan tetapi, perlu ditentukan nilai k yang paling optimal yang menyatakan jumlah tetangga terdekat, pembelajaran berdasarkan jarak tidak jelas mengenai jenis jarak apa yang harus digunakan dan atribut mana yang harus digunakan untuk mendapatkan hasil yang terbaik, komputasi yang dilakukan juga cukup tinggi karena perhitungan jarak harus dilakukan pada setiap *query instance* bersama-sama dengan seluruh *instance* dari sampel latih.

Lalu untuk metode klasifikasi *decision tree* juga berguna untuk mengeksplorasi data, menemukan hubungan tersembunyi antara sejumlah calon variabel *input* dengan sebuah variabel target. *decision tree* juga menggabungkan eksplorasi data dan pemodelan yang menjadikannya langkah pertama yang sangat baik dalam proses pemodelan bahkan ketika digunakan sebagai model akhir untuk beberapa teknik lainnya. Meskipun demikian *decision tree* memiliki risiko terjadinya tumpang tindih terutama ketika sangat banyak kelas dan kriteria digunakan. Hal ini juga dapat menyebabkan waktu keputusan yang lebih lama dan memori yang dibutuhkan, serta akumulasi jumlah kesalahan dari setiap level dalam pohon keputusan besar serta kesulitan dalam merancang pohon keputusan yang optimal sehingga hasil kualitas keputusan yang diperoleh dengan metode *decision tree* sangat tergantung pada bagaimana *decision tree* itu dirancang. Berikutnya ada teknik klasifikasi *Linear Discriminant Analysis* (LDA), LDA sendiri adalah sebuah teknik klasifikasi sederhana tetapi robust yang bekerja dengan mencari kombinasi linear dari fitur-fitur yang ada untuk memisahkan sampel ke dalam kelas yang sesuai. Akan tetapi, LDA memiliki kelemahan yaitu sebaiknya tidak digunakan untuk data dengan sampel yang lebih kecil dari jumlah fiturnya. Oleh karena itu, diperlukan sebuah teknik reduksi dimensi agar LDA bisa memiliki kinerja yang baik saat melakukan klasifikasi data.

Untuk penggunaan *feature selection* sendiri, terdapat beberapa metode seleksi fitur yang telah digunakan dalam penelitian klasifikasi sebelumnya di antaranya ada Random Forest [11], RF-RFE [12], *Genetic Algorithm* [6], *Stepwise Regression* [12], *Sequential Forward Floating Selection* [13], dan *toolbox SelectKBest* [14][32].

Terlepas dari metode klasifikasi yang disebutkan di atas, berbagai metode klasifikasi telah digunakan untuk menggambarkan emosi, seperti *Ensemble Models* (AdaBoost) [14][7], *XGBoost* [12], [34], *Continuous Decomposition Analysis* (CDA) [10], *Random Forest* (RF) [27], *Logistic Regression* (LR) [11], *Quadratic Discriminant Analysis* (QDA) [10], *Boosted Logistic Regression* (BLR) [12], *Gradient Boost Decision Tree* (GBDT) [14], *Naïve Bayes* [11], *Multinomial Regression* (MN) [12], dan *Ensemble Classifier* (ENS) [33].

Pada penelitian ini menginvestigasi beberapa *classifier* dan penggunaan *feature selection wrapper* untuk meningkatkan akurasi klasifikasi emosi menggunakan *classsifier Quadratic Discriminant Analysis* (QDA), *k-Nearest Neighbor* (kNN), *Decision Tree* (DT), *XGBoost*, dan *Support Vector Machine* (SVM) menggunakan sinyal *physiological* yang ada pada *smartwatch* atau *wearable device* dikarenakan dapat digunakan pada aktivitas sehari-hari dan tidak terikat pada kondisi laboratorium. Model yang diusulkan mampu melebihi kinerja model klasifikasi *multi-class* emosi pada penelitian sebelumnya sehingga akurasi menjadi lebih baik. Penelitian ini berhasil menyelidiki *machine learning* model yang lebih baik dan optimal untuk mengatasi masalah klasifikasi *multi-class* emosi.

1.5 Tujuan Penelitian

1. Menyusun *machine learning* model untuk menentukan model klasifikasi emosi dengan menggunakan sinyal *physiological* yang ada pada *wearable devices*.
2. Meningkatkan akurasi serta menurunkan waktu pemrosesan klasifikasi emosi pada *machine learning* model sebelumnya dengan menyusun model *machine learning* yang tepat.