

KLASIFIKASI EFEK *FAMILIARITY* PADA SINYAL EEG MANUSIA MENGUNAKAN METODE *HJORTH DESCRIPTOR*

CLASSIFICATION OF FAMILIARITY EFFECTS IN HUMAN EEG SIGNAL USING HJORTH DESCRIPTOR METHOD

Hannissa Sanggarini¹, Rita Purnamasari², Sugondo Hadiyoso³

^{1,2}Prodi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom, Bandung

³Prodi D3 Teknik Telekomunikasi, Fakultas Ilmu Terapan, Universitas Telkom, Bandung

¹hanissas@student.telkomuniversity.ac.id, ²ritapurnamasari@telkomuniversity.ac.id, ³sugondo@telkomuniversity.ac.id

Abstrak

Dalam *Human-Computer Interaction*, audiovisual sangat berpengaruh bagi kondisi fisiologis yang mempengaruhi perasaan manusia. Hal ini dapat dilihat dari kemampuan manusia yang mampu merasakan perasaan yang berbeda-beda saat melihat tayangan video musik. Perasaan ini muncul akibat stimulus yang dihasilkan dari tayangan video musik tersebut sehingga terjadi fluktuasi aktifitas otak dan menghasilkan karakteristik sinyal otak tertentu. Dengan menggunakan *Electroencephalogram* (EEG), dilakukan klasifikasi karakteristik sinyal otak pada kategori *familiarity*. *Familiarity* adalah keadaan saat manusia mengenali sesuatu.

Penelitian ini menggunakan data sekunder yang diambil dari *DEAP: A Database for Emotion Analysis using Physiological Signals*. Data yang diambil dari DEAP berjumlah 32 data yang telah melalui beberapa tahap *pre-processing*, maka data dapat langsung diproses dengan menggunakan metode *Hjorth Descriptor* untuk ekstraksi ciri dan metode *Multilayer Perceptron* (MLP) untuk klasifikasi.

Pengujian dilakukan dengan skenario dimana data dari 29 data yang digunakan, 15 data digunakan sebagai data latih dan 14 data digunakan sebagai data uji. Dari hasil pengujian yang dilakukan, didapatkan akurasi terbaik pada kondisi *balance class* sebesar 78.57% pada percobaan 1, 2 dan 27 dengan kombinasi ciri *Hjorth Descriptor activity, mobility* dan *complexity*. Digunakan juga dua *hidden layer* dengan 12 *neurons* pada tiap *hidden layer* serta *epoch* berjumlah 1.000 *epochs* pada MLP.

Kata Kunci: EEG, *familiar*, *Hjorth Descriptor*, *Multilayer Perceptron*.

Abstract

In *Human-Computer Interaction*, audiovisual is very influential for physiological condition that affects human's feelings. This can be seen from human ability to feel different feelings while watching music video. This feeling occurred because of the stimulus elicited from the music video, so that brain activity fluctuation happened and obtained certain brain signals characteristics. By using *Electroencephalogram* (EEG), we did a classification of brain signal characteristics in *familiarity* category. *Familiarity* is a state when human recognize something.

This research is using secondary data taken from *DEAP: A Database for Emotion Analysis using Physiological Signals*. Data taken from *deap* is the amount of 32 and has been through several *pre-processing* methods, so data can go straight to be processed using *Hjorth Descriptor* as the feature extraction method and *Multilayer Perceptron* (MLP) as the classifier method.

The test is done with scenario where from 29 data used, 15 data is used as training data and 14 data is used as testing data. From the test result, the best accuracy is gained in *balance class* is 78.57% in trial 1, 2 and 27 with *Hjorth Descriptor* feature combinations of *activity, mobility* and *complexity*. Two *hidden layers* with 12 *neurons* in each *hidden layer* and *epoch* with the amount of 1000 is also used in MLP.

Keywords: EEG, *familiar*, *Hjorth Descriptor*, *Multilayer Perceptron*.

1. Pendahuluan

Kebanyakan sistem *Human-Computer Interactions* (HCI) kontemporer belum mampu mengidentifikasi tahap emosional pada manusia, informasi emosional ini seharusnya dipakai dalam menentukan aksi yang sesuai untuk dilakukan selanjutnya. *Affective computing* bertujuan untuk mengisi kekurangan tersebut dengan mendeteksi tanda-tanda emosional yang muncul saat interaksi pada *human-computer* dan menyatukan respon-respon emosionalnya [1]. *Affective computing* dapat dilakukan dengan banyak modal, salah satunya adalah dengan *Electroencephalogram* (EEG) yang dihasilkan dari stimulus audiovisual [2].

EEG adalah teknologi yang dipakai untuk membaca dan mengukur aktifitas elektrik dari otak manusia. Aktifitas elektrik ini akan berubah-ubah sesuai emosi yang dirasakan. EEG dapat mendeteksi perubahan aktifitas elektrik dari beberapa pita frekuensi sinyal yang ada pada otak manusia yaitu sinyal alfa, beta, delta, teta dan gama [3].

Telah banyak penelitian yang dilakukan terkait klasifikasi sinyal EEG manusia, namun belum banyak penelitian tentang klasifikasi sinyal EEG manusia saat mengalami efek *familiar*. *Familiar* adalah keadaan saat mengenali sesuatu. Menurut Thammasan, efek *familiar* melibatkan ekspektasi dan prediksi berdasarkan pengetahuan sebelumnya mengenai kutipan dari stimulus *familiar* itu sendiri. Memori manusia kemungkinan memiliki peran yang besar dan dapat mempengaruhi reaksi emosionalnya [4].

Berdasarkan permasalahan diatas, dibuat sistem untuk mengklasifikasi emosi manusia yang muncul setelah menonton video musik dengan menggunakan data sekunder dari *DEAP: A Database for Emotion Analysis Using Physiological Signal*. Tugas akhir ini menggunakan *familiarity* sebagai fokus penelitian. Metode ekstraksi ciri yang dipilih adalah *Hjorth Descriptor* karena *Hjorth Descriptor* memakai hanya tiga parameter (*activity*, *mobility* dan *complexity*) [5], sehingga kompleksitas komputasi yang lebih rendah bisa dicapai [6]. Metode klasifikasi yang dipilih adalah *Multilayer Perceptron* (MLP). Gabungan dari kedua metode tersebut dipilih karena menurut Rizal dan Hadiyoso, metode-metode tersebut dapat menghasilkan akurasi klasifikasi sinyal EEG yang tinggi [7].

2. Dasar Teori

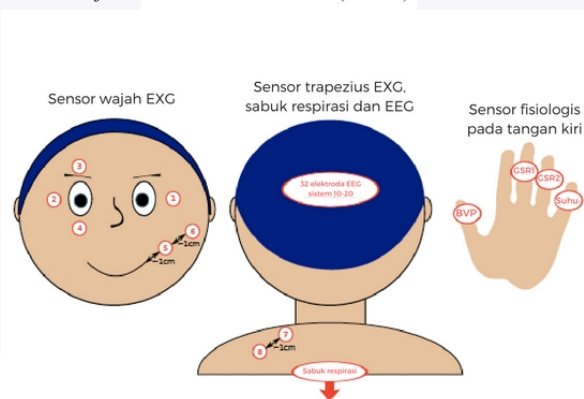
2.1 Electroencephalography

Electroencephalography adalah sebuah domain mengenai perekaman dan penginterpretasian dari *electroencephalogram*. *Electroencephalogram* (EEG) adalah rekaman dari sinyal elektrik yang dihasilkan dari aktivitas sel-sel otak. EEG biasanya didigitalkan dengan sebuah 12-bit *Analog-Digital Conversion* (ADC) dengan frekuensi *sampling* yang berkisar dari 100 Hz untuk EEG spontan, beberapa ratus Hz untuk ERP, hingga beberapa kHz untuk merekam *short latency far-field* ERP [8].

2.2 DEAP Dataset

DEAP: A Database for Emotion Analysis Using Physiological Signal adalah multi-modal *dataset* untuk stase afektif manusia. DEAP merekam sinyal EEG dan sinyal fisiologis perifer dari 32 orang peserta. Setiap pesertanya diwajibkan menonton 40 video musik berdurasi satu menit untuk dinilai dari level *arousal*, *valence*, *like/dislike*, *dominance* dan *familiarity*.

Arousal dapat berkisar dari *inactive* (tidak tertarik, bosan) hingga *active* (waspada, gembira), sedangkan *valence* berkisar antara *unpleasant* (sedih, stres) hingga *pleasant* (senang, gembira). *Dominance* berkisar antara *helpless* dan *weak* (tidak terkendali) hingga *empowered* (terkendali dalam segala hal). Pada penilaian diri dalam skala-skala ini, DEAP memakai *The Self-assessment Manikin* (SAM).



Gambar 1 Gambar Ilustrasi Penempatan Elektroda.

Gambar 1 merupakan ilustrasi penempatan elektroda saat subjek sedang menonton video musik untuk percobaan. Percobaan DEAP ini dilakukan di dua lingkungan laboratorium dengan pencahayaan yang dapat dikendalikan. EEG dan sinyal fisiologis perifer direkam memakai *Biosemi ActiveTwo System* pada *recording personal computer* (PC). Stimulus ditampilkan memakai PC yang di sinkronisasi langsung ke *recording PC*. Karena EEG sangat sensitif terhadap pergerakan mata, stimulus video ditampilkan pada resolusi 800 x 600 (2/3 layar) untuk meminimalisasi pergerakan mata. EEG direkam pada *sampling rate* 512 Hz memakai 32 AgCl elektroda aktif yang ditempatkan sesuai dengan sistem internasional 10-20[2].

2.3 Familiarity

Familiarity adalah pengetahuan penuh, atau keakraban terhadap sesuatu atau seseorang [9]. Walaupun deteksi emosi dengan menggunakan EEG telah menjadi area riset yang sangat aktif dalam satu dekade terakhir, belum banyak penelitian mengenai stimulus *familiarity*, yang sebenarnya adalah sebuah masalah subjektivitas yang krusial [4]. Penelitian menunjukkan bahwa *familiarity* adalah faktor individual yang penting dalam menentukan variasi dari menikmati dan menyukai musik. Saat seseorang semakin *familiar* terhadap bagian tertentu pada musik, tingkat menyukai musik tersebut semakin meningkat. Fenomena yang diketahui sebagai *mere exposure effect* ini menunjukkan bahwa *familiarity* mungkin memainkan peran penting dalam keterlibatan emosional pada pendengar dengan musik itu sendiri [10]. Penelitian pada *emotion recognition* di wajah manusia juga menunjukkan adanya pengaruh efek *familiarity* pada akurasi *emotion recognition*. Semakin *familiar* seseorang dengan sebuah stimulus, semakin besar kemungkinan seseorang untuk mengidentifikasi emosi dengan akurat [11].

2.4 Hjorth Descriptor

Hjorth Descriptor adalah metode ekstraksi ciri yang pada awalnya digunakan untuk menganalisis sinyal EEG dalam domain waktu. Kemudian *Hjorth Descriptor* juga dipakai untuk menganalisis *Electromyogram* (EMG), repolarisasi ventrikel dari *Electrocardiography* (ECG) dan pemrosesan suara pada paru-paru. Metode *Hjorth Descriptor* memiliki tiga parameter, yaitu *activity*, *mobility* dan *complexity*[5].

a. Activity

Parameter *activity* merepresentasikan daya sinyal dan variansi dalam fungsi waktu. Parameter ini dapat menunjukkan permukaan dari spektrum daya didalam domain frekuensi. Parameter aktifitas direpresentasikan dengan persamaan berikut:

$$Activity = var(y(t)) \quad (1)$$

dimana $y(t)$ merepresentasikan sinyal.

b. Hjorth Mobility

Parameter *mobility* merepresentasikan frekuensi rata-rata atau proporsi dari standar deviasi spektrum daya. Parameter ini didefinisikan dengan akar dari variansi turunan pertama sinyal $y(t)$ dibagi dengan variansi sinyal $y(t)$.

$$Mobility = \sqrt{\frac{var(y'(t))}{var(y(t))}} \quad (2)$$

c. Hjorth Complexity

Parameter *complexity* merepresentasikan perubahan pada frekuensi.

$$Complexity = \frac{Mobility(y'(t))}{Mobility(y(t))} \quad (3)$$

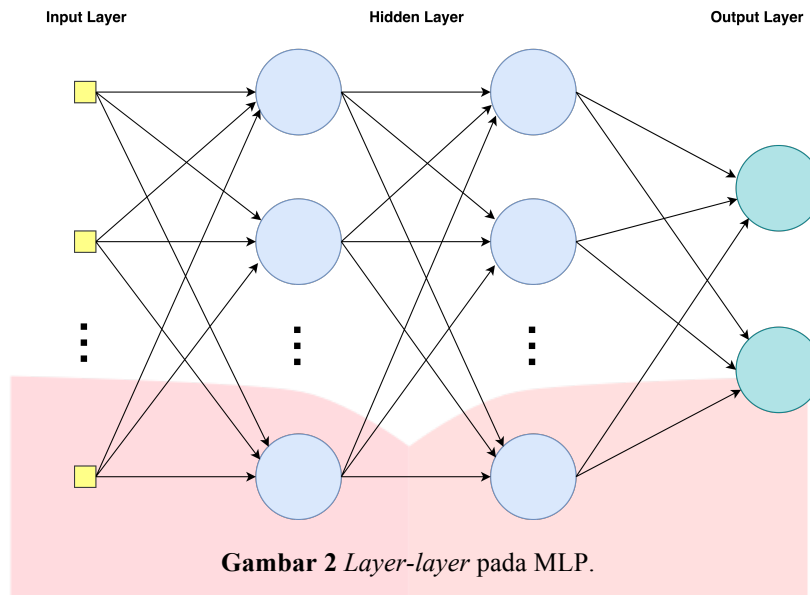
2.5 Multi Layer Perceptron

Multilayer Perceptron (MLP) adalah salah satu algoritma jaringan saraf tiruan yang mengadopsi cara kerja jaringan saraf pada manusia. Seperti fungsi otak manusia, MLP mampu menganalisis masalah serta melakukan klasifikasi pola dan pemodelan sistem. Pengenalan pola memiliki dua tahap, yaitu:

1. Tahap pelatihan: Pada tahap ini, pola dipelajari untuk menentukan ciri yang akan dipakai dalam proses pengenalan awal dan klasifikasi.
2. Tahap pengenalan latihan: Pada tahap ini dilakukan pengambilan ciri pola dan ditentukan klasifikasinya.

Pemodelan sistem dilakukan untuk membuat simulasi agar menghasilkan keluaran dan masukan yang akan disimulasikan.

MLP terdiri dari *input layer*, satu atau lebih *hidden layer* dan *output layer* [12] yang diilustrasikan pada Gambar 2.




Pada MLP, jumlah pembobotan dari *input* dan bias dikirimkan ke koneksi selanjutnya melalui fungsi aktivasi. Unit-unit ini diatur dalam lapisan topologi *Feed Forward Neural Network* (FFNN) [13]. Keluaran dari *hidden layer* dimasukkan ke *hidden layer* berikutnya. Saat ada lebih dari satu *hidden layer*, bobot terpisah digunakan untuk penjumlahan ke lapisan-lapisan berikutnya [14]. Keluaran dari *output layer* biasanya adalah nilai antara 0-1 [15].

Fungsi aktivasi atau fungsi transfer pada jaringan memodifikasi *input* untuk memberikan *output* yang diinginkan[13]. Fungsi aktivasi yang digunakan adalah fungsi sigmoid, dimana fungsi ini memiliki nilai antara 0-1 seperti ditunjukkan pada persamaan 2.4 dengan x merepresentasikan nilai neuron.

$$f(x) = \frac{1}{1+e^{-x}} \quad (4)$$

Kelebihan MLP adalah kemampuannya untuk melakukan proses pembelajaran yang kemudian digunakan untuk proses memperbaiki arsitektur jaringan dan bobot koneksi. Metode pembelajaran pada tugas akhir ini yaitu *Supervised learning*. Tahap ini menggunakan dua pasangan data dimana data pertama digunakan sebagai masukan. Data kedua digunakan sebagai target keluaran untuk melatih jaringan agar diperoleh bobot yang diharapkan. Tahap ini bertujuan untuk mendapatkan arsitektur terbaik.

3. Rancangan Sistem



Gambar 3 Flowchart sistem.

Pada sistem ini dirancang sistem klasifikasi karakteristik sinyal EEG saat subjek merasa *familiar* dengan menggunakan metode ekstraksi ciri *Hjorth Descriptor* dan metode klasifikasi MLP. Data diambil dari DEAP: *A Database for Emotion Analysis Using Physiological Signals*. Data pada dataset tersebut adalah data dari 32 subjek.

4. Pengujian Sistem dan Analisis

Tahap pengujian sistem dilakukan dengan menggunakan parameter yang diperoleh selama pemrograman sistem dengan hasil yang direpresentasikan dalam bentuk tabel, grafik dan analisis. Pengujian sistem dibagi menjadi beberapa skenario sebagai berikut:

1. Skenario 1, yaitu pengujian pada tiap percobaan untuk mengetahui percobaan dengan *balance class* dan nilai akurasi tertinggi.
2. Skenario 2, yaitu pengujian seleksi fitur pada ekstraksi ciri untuk menentukan fitur yang terbaik.

4.1 Pengambilan Data

Data *preprocessed* yang diambil dari DEAP *Dataset* berjumlah 32 data dengan format (.mat) yang mewakili data untuk 32 peserta. Tiap *file* peserta memiliki data berukuran 40 *trial* x 40 *channel* x 8.064 *data*. Pada *dataset* ini juga disertakan *participant rating* yaitu *rating* setelah subjek menonton 40 video musik pada level *valence*, *arousal*, *dominance*, *liking* dan *familiarity*.

Dari data *preprocessed* tersebut dilakukan iterasi pembacaan data 32 subjek, 40 percobaan (saat menonton video musik), 32 kanal dan 8.064 ukuran data yang menghasilkan uraian setiap *file* peserta menjadi 1 subjek, 1 kanal dan 1 *trial* (percobaan) atau disebut juga s1_t1_k1 sampai dengan s1_t40_k32 untuk peserta pertama dan seterusnya.

Pada proses ekstraksi ciri, keluaran yang didapatkan terkonversi dalam bentuk file Excel (.xlsx). Ekstraksi ciri dilakukan terhadap 32 subjek pada 40 percobaan dan 32 kanal, sehingga data keluaran sebesar 40.960x3. Dari 40.960 data yang ada, dilakukan pencarian nilai rata-rata dari 32 kanal pada tiap percobaan. Maka, hasil akhir data untuk dilanjutkan ke tahap selanjutnya sebesar 1280x3. Data kemudian diberi penomoran untuk memudahkan pengolahan. Pada awalnya data diurutkan sesuai subjek, namun pada penelitian ini data diurutkan sesuai percobaan.

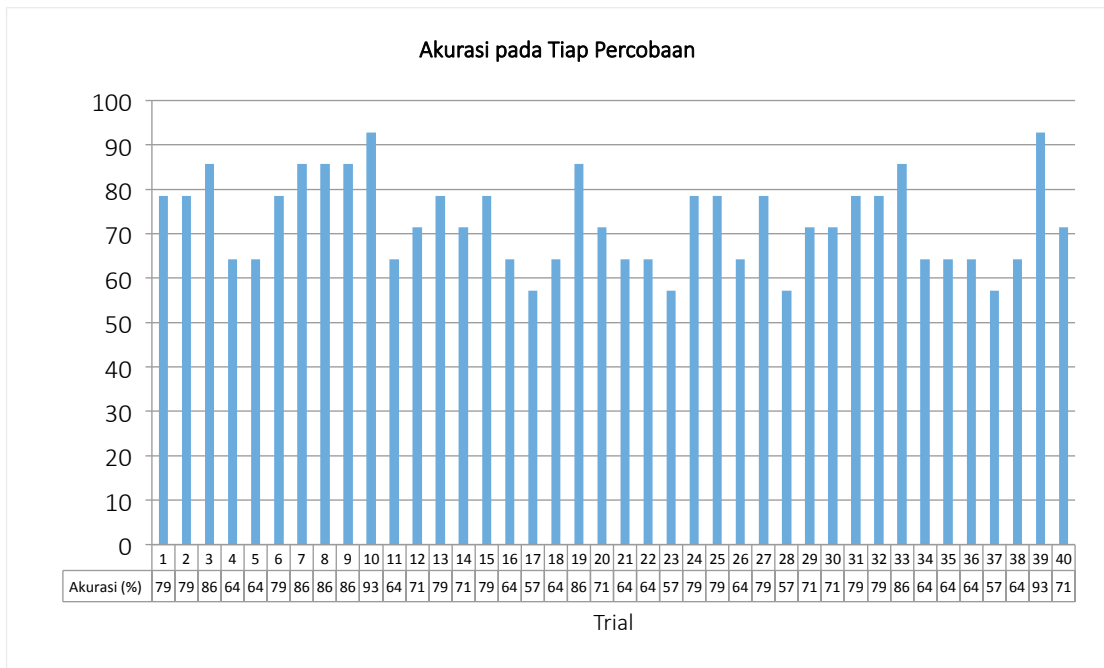
Setelah dilakukan ekstraksi ciri, data ditentukan kelasnya menjadi dua kelas dengan melihat *rating* pada *participant rating*, yaitu:

1. *Familiar*, yaitu parameter saat subjek mengetahui atau akrab dengan video musik yang ditonton dan *rating* berkisar antara 4-5.
2. *Unfamiliar*, yaitu parameter saat video musik terasa asing bagi subjek dengan *rating* berkisar antara 1-3.

Data pada subjek 2, 15 dan 23 tidak memiliki *familiarity rating* untuk dijadikan acuan, maka data ketiga subjek dihapus secara manual pada tiap percobaan. Setelah menghapus data pada subjek-subjek tersebut, maka data untuk dilanjutkan ke tahap selanjutnya yaitu sebesar 1160x3.

4.2 Hasil Pengujian Pada Skenario 1

Dari proses ekstraksi, pembagian kelas dan penghapusan data yang tidak memiliki kelas, dihasilkan 1.160 data yang mewakili 40 percobaan pada tiap subjek. Pada langkah ini dilakukan skenario untuk menentukan percobaan terbaik. Penentuan percobaan terbaik dilakukan dengan membandingkan nilai akurasi yang didapat pada tiap percobaan. Fitur dari *Hjorth Descriptor* yang digunakan adalah gabungan dari semua fitur *activity*, *mobility* dan *complexity*. Jumlah *hidden layer* yang digunakan pada metode MLP adalah empat *layer*. Data yang digunakan yaitu 15 data latihan dan 14 data uji dan dibagi menjadi dua kelas yaitu *familiar* dan *unfamiliar*.



Gambar 4 Hasil Pengujian pada Tiap Percobaan.

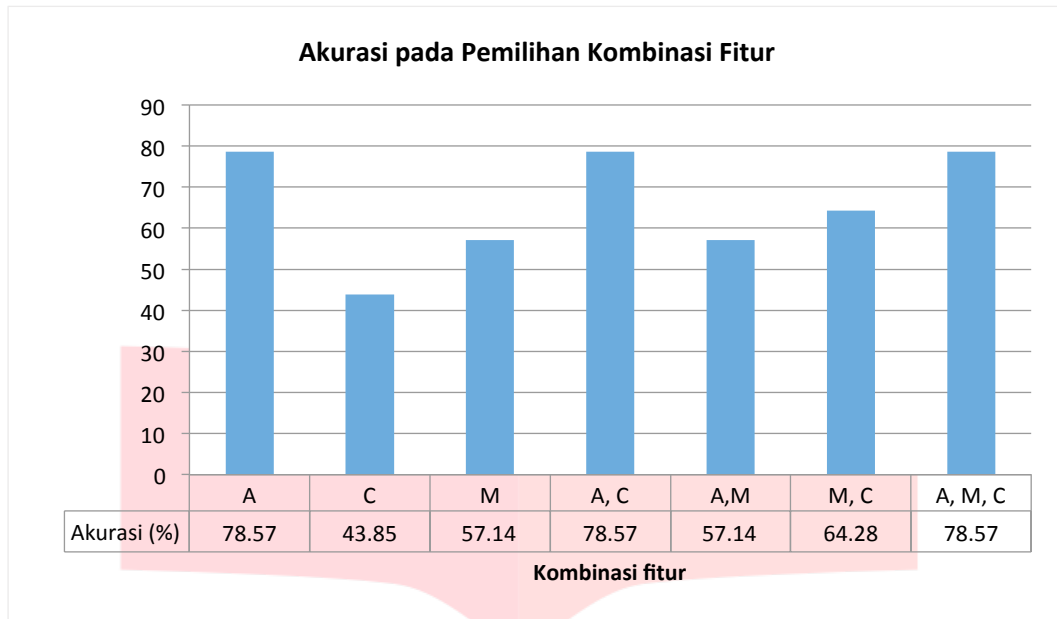
Berdasarkan Gambar 4.4 dapat dilihat bahwa nilai akurasi terbesar didapatkan pada percobaan 10 dan 39 dengan nilai akurasi sebesar 92.85 %. Akan tetapi, percobaan tersebut tidak dapat digunakan karena adanya *imbalance class* pada kelas *familiar* dan *unfamiliar*. Nilai akurasi tertinggi sebesar 78.57% didapatkan pada percobaan 1, 2 dan 27 dengan kondisi *balance class*, yaitu jumlah data *familiar* sejumlah 12 data dan *unfamiliar* sejumlah 17. Adapun yang digunakan untuk skenario selanjutnya adalah hasil perhitungan pada percobaan kedua.

4.3 Hasil Pengujian pada Skenario 2

Pada skenario ini akan dilakukan pengujian pada percobaan terbaik yang didapat dari skenario sebelumnya, yaitu percobaan kedua. Data pada percobaan kedua berjumlah 29 data, dimana 15 digunakan sebagai data latih dan 14 digunakan sebagai data uji, data dibagi menjadi dua kelas yaitu *familiar* dan *unfamiliar*. Tujuan skenario ini adalah untuk memilih kombinasi fitur terbaik dari keseluruhan fitur yang digunakan. Data yang dijadikan input pada skenario ini dikelompokkan berdasarkan kombinasi fitur yang telah ditentukan pada Tabel 1.

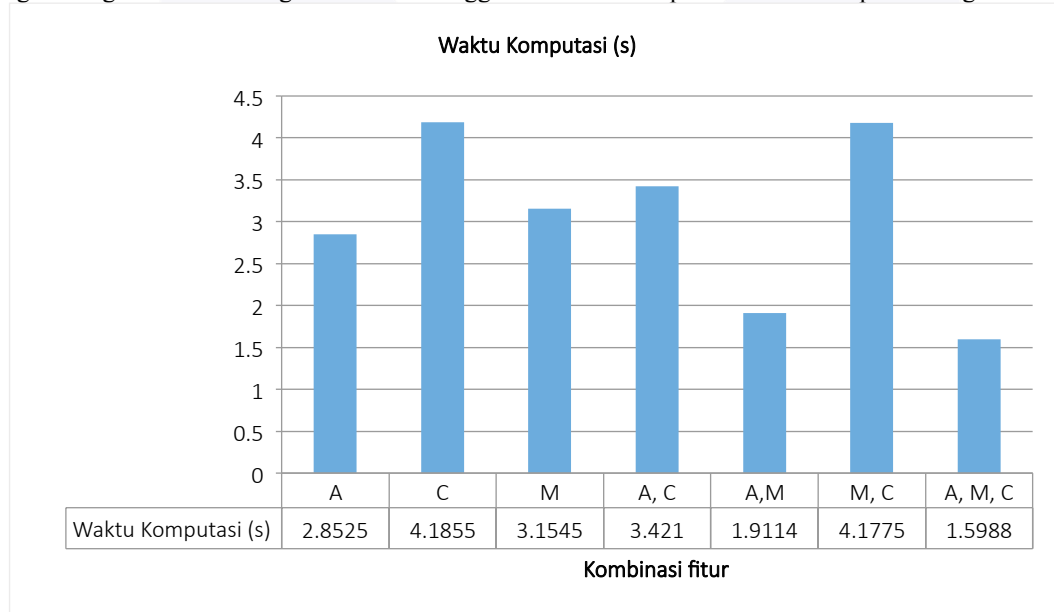
Tabel 1 Variabel kombinasi fitur untuk pengujian

Variabel	Kombinasi Fitur
A	Activity
C	Complexity
M	Mobility
A, C	Activity, Complexity
A, M	Activity, Mobility
M, C	Mobility, Complexity
A, M, C	Activity, Mobility, Complexity



Gambar 5 Hasil Pengujian pada Seleksi Fitur.

Berdasarkan Gambar 5 dapat dilihat bahwa fitur *activity*, gabungan fitur *activity* dan *complexity*, serta gabungan ketiga fitur *activity*, *mobility* dan *complexity* menghasilkan nilai akurasi yang sama yaitu 78.57%. Untuk memilih fitur terbaik, pada skenario ini ditambahkan parameter dengan melihat waktu komputasi masing-masing fitur. Fitur dengan akurasi tertinggi dan waktu komputasi terendah dipilih sebagai fitur terbaik.



Gambar 6 Hasil Pengujian Waktu Komputasi pada Seleksi Fitur.

Berdasarkan data dari Gambar 6, fitur gabungan *activity*, *mobility* dan *complexity* menghasilkan waktu komputasi terendah yaitu 1.5988 detik. Maka dengan menggabungkan data dari Gambar 5 dan Gambar 6, fitur gabungan *activity*, *mobility* dan *complexity* ditentukan sebagai fitur terbaik.

5. Analisis

Proses pengujian dilakukan dengan memproses data pada tiap percobaan karena semua subjek mendapatkan stimulus video musik yang sama pada setiap percobaan. Alasan lainnya adalah tidak memungkinkan melakukan generalisasi tingkat *familiarity* antar satu orang dengan orang lainnya, karena tingkat *familiarity* setiap orang akan berbeda-beda. Meskipun diberi stimulus video musik yang sama, respon yang dihasilkan akan berbeda.

Pada hasil pengujian di tiap percobaan dihasilkan nilai akurasi yang berbeda-beda. Perbedaan dari nilai akurasi yang didapatkan pada tiap percobaan disebabkan oleh jumlah data *familiar* yang tidak seimbang dengan jumlah data *unfamiliar*. Jumlah data *unfamiliar* jauh lebih banyak daripada jumlah data *familiar*, sehingga kami melakukan pemilihan percobaan dengan jumlah data *familiar* dan *unfamiliar* yang hampir seimbang yaitu pada percobaan kedua.

Pada skenario perhitungan akurasi pada kombinasi fitur, kombinasi fitur *activity*, *mobility* dan *complexity* menghasilkan akurasi tertinggi dan waktu komputasi terendah. Hal ini dapat disebabkan karena semakin banyak ciri maka akan membantu sistem untuk lebih cepat mengenali kelasnya.

6. Kesimpulan

Sistem yang telah dibuat mampu mengklasifikasi *familiarity* pada sinyal EEG manusia setelah menonton video musik dengan *Hjorth Descriptor* sebagai metode ekstraksi ciri dan MLP sebagai metode klasifikasi. Dari pengujian dan analisis yang telah dilakukan sebelumnya, dapat disimpulkan bahwa:

1. Percobaan terbaik yang diperoleh dari proses pengujian pada semua percobaan dengan metode ekstraksi ciri *Hjorth Descriptor* dan klasifikasi MLP adalah percobaan yang menghasilkan akurasi tertinggi pada kondisi *balance class*, yaitu pada percobaan 1, 2 dan 27 dengan akurasi sebesar 78.57%.
2. Berdasarkan gabungan hasil pengujian akurasi dan waktu komputasi pada seleksi fitur, gabungan ketiga fitur *activity*, *mobility* dan *complexity* adalah fitur terbaik karena menghasilkan akurasi tertinggi sebesar 78.57% dan waktu komputasi terendah yaitu selama 1.5988 detik. Hal ini dapat disebabkan karena semakin banyak ciri maka akan membantu sistem untuk lebih cepat mengenali kelasnya.

7. Saran

Adapun beberapa saran untuk membantu pengembangan sistem selanjutnya adalah sebagai berikut:

1. Menggunakan data yang jumlah kelasnya seimbang atau tidak terlalu jauh perbedaannya untuk memperbaiki *learning process* pada MLP.
2. Melakukan analisis terhadap tahap emosional lainnya yaitu *valence*, *dominance* atau *liking* dengan menggunakan dataset yang sama.
3. Melakukan analisis pengaruh *familiarity* terhadap *liking* saat subjek menonton video musik.

Daftar Pustaka

- [1] S. Koelstra, C. Muhl, and M. Soleymani, "Deap: A database for emotion analysis; using physiological signals," *IEEE Trans.*, pp. 1–15, 2012.
- [2] A. Al-Nafjan, M. Hosny, Y. Al-Ohali, and A. Al-Wabil, "Review and Classification of Emotion Recognition Based on EEG Brain-Computer Interface System Research: A Systematic Review," *Appl. Sci.*, vol. 7, no. 12, p. 1239, 2017.
- [3] J. S. Kumar and P. Bhuvaneshwari, "Analysis of Electroencephalography (EEG) Signals and Its Categorization - A Study," vol. 38, pp. 2525–2536, 2012.
- [4] N. Thammasan, K. Moriyama, K. Fukui, and M. Numao, "Familiarity effects in EEG-based emotion recognition," *Brain Informatics*, vol. 4, no. 1, pp. 39–50, 2017.
- [5] B. Hjorth, "EEG analysis based on time domain properties," *Electroencephalogr. Clin. Neurophysiol.*, vol. 29, no. 3, pp. 306–310, 1970.
- [6] S.-H. Oh, Y.-R. Lee, and H.-N. Kim, "A Novel EEG Feature Extraction Method Using Hjorth Parameter," *Int. J. Electron. Electr. Eng.*, vol. 2, no. 2, pp. 106–110, 2014.
- [7] A. Rizal and S. Hadiyoso, "ECG Signal Classification Using Hjorth Descriptor," vol. 6, no. 2, pp. 3–6.
- [8] K. Blinowska and P. Durka, "ELECTROENCEPHALOGRAPHY (EEG)," *J. Crim. law Criminol. Incl. Am. J. police Sci.*, vol. 37, no. 6, pp. 491–497, 2006.
- [9] P. Turner, "Being-with : A study of familiarity," vol. 20, pp. 447–454, 2008.
- [10] C. S. Pereira, "Music and Emotions in the Brain : Familiarity Matters," vol. 6, no. 11, 2011.
- [11] C. M. Huynh, G. I. Vicente, and J. J. Peissig, "The Effects of Familiarity on Genuine Emotion Recognition," *J. Vis.*, vol. 10, no. 7, pp. 628–628, Aug. 2010.
- [12] C. Vercellis, *Business Intelligence: Data Mining and Optimization for Decision Making*. 2009.
- [13] P. Venkatesan and S. Anitha, "Application of a radial basis function neural network for diagnosis of diabetes mellitus," no. September, 2015.
- [14] A. Setiadi, "Penerapan Algoritma Multilayer Perceptron untuk Deteksi Dini Penyakit Diabetes," vol. XIV, no. 1, 2012.
- [15] J. Bonnell, "Implementation of a New Sigmoid Function in Backpropagation Neural Networks," 2011.