

Pengenalan Karakter Anak Untuk Mengenali Potensi Berdasarkan Sinyal Fisiologi Menggunakan K-Nearest Neighbors Classifier

Sukenda¹, Eka Angga L², M. Kohar³

Universitas Widyatama

Abstrak

Perkembangan teknologi informasi mulai diterapkan di bidang psikologi, salah satu contohnya adalah aplikasi yang digunakan untuk pengenalan emosi. Pada dasarnya, proses pengenalan emosi dapat dilakukan melalui beberapa cara yaitu penulisan (text), sinyal fisiologi, ekspresi wajah, intonasi suara, dan gerak tubuh. Akan tetapi, ada kemungkinan ekspresi wajah, tulisan tangan, intonasi suara dan gerak tubuh bisa dimanipulasi, sehingga membuat pengenalan emosi menjadi kurang valid. Pengenalan emosi melalui sinyal fisiologi lebih representatif dan mampu memberikan hasil yang lebih objektif karena sinyal fisiologi tidak dapat dikontrol secara sadar oleh penggunanya sendiri. Sinyal fisiologi yang dapat digunakan untuk mengenali emosi adalah detak jantung dan respon dari konduktansi kulit. Untuk dapat melakukan pengenalan emosi berdasarkan sinyal fisiologi ini dilakukan dengan membangun sebuah sistem aplikasi. Sistem aplikasi ini, terdiri dari dua unit utama yaitu unit hardware dan unit software. Unit hardware terdiri dari dua sensor yaitu sensor pulse dan sensor GSR yang terintegrasi dengan microcontroller arduino, integrasi ini untuk melakukan pengukuran sinyal dari tubuh. Unit software berfungsi untuk mengolah data yang terdiri dari aplikasi user interface, sistem database, dan machine learning. Data yang diterima dari sensor, akan disimpan ke database yang kemudian dilakukan proses pre-processing data, feature scaling, dan klasifikasi data. Proses pre-processing data terdiri dari dua tahapan, yaitu filter data dan filter attribute. Kemudian feature scaling digunakan untuk proses normalisasi. Setelah melalui kedua proses tersebut, data diklasifikasikan menggunakan algoritma KNN, untuk melakukan proses prediksi emosi. Dari hasil penelitian, sistem aplikasi yang dibangun mampu melakukan proses pengukuran sinyal fisiologi dan klasifikasi emosi dengan rata-rata nilai akurasi, presisi, dan recall adalah 76%.

Kata kunci : Aplikasi, Emosi, Sinyal fisiologi, KNN.

Copyright (c) 2023 Sukenda¹, Eka Angga L², M. Kohar³



Corresponding author : Sukenda¹, Eka Angga L², M. Kohar³

Email Address : ¹kenda@widyatama.ac.id, ²eka.angga@widyatama.ac.id,

³kohar.mudzakar@widyatama.ac.id

PENDAHULUAN

Kemajuan teknologi dan informasi yang semakin berkembang membuat Internet of Thing menjadi topik penelitian yang populer karena mampu menjangkau skenario aplikasi yang cukup luas (Myroniv, et al., 2017). Salah satu bentuk penerapan dari IoT adalah smart wearable technology. Teknologi ini, biasanya digunakan untuk monitoring kesehatan (e-health) salah satunya untuk melakukan monitoring kesehatan mental melalui pengenalan emosi. Sistem pengenalan emosi secara otomatis dapat meningkatkan interaksi manusia dan mesin yang dapat digunakan. Masih ada bidang lainnya seperti kedokteran, psikologi, atau neuromarketing (Tarnowski, Kolodziej, Majkowski, & Rak, Combined analysis of GSR and EEG signals for emotion recognition, 2018). Penelitian mengenai pengenalan emosi saat ini telah banyak dilakukan (Tarnowski, Kolodziej, Majkowski, & Rak, Combined analysis of GSR and EEG signals for emotion recognition, 2018) (Menard, Richard, Hamdi, Dauce, & Yamaguchi, 2015) (Setyohadi, Kusrohmaniah, Gunawan, Pranowo, & Prabuwo, 2018).

Mayoritas penelitian yang dilakukan mengenali emosi berdasarkan identifikasi ekspresi wajah dan kecepatan suara (Menard, Richard, Hamdi, Dauce, & Yamaguchi, 2015). Akan tetapi, cara ini dinilai kurang valid karena mudah untuk menutupi atau memanipulasi wajah serta mensimulasi nada suara (Menard, Richard, Hamdi, Dauce, & Yamaguchi, 2015) (Udovicic, Russo, Derek, & Sikora, 2017). Emosi pada dasarnya merupakan pengalaman positif maupun negatif yang berasosiasi dengan pola khusus aktifitas fisiologi (Cernian, Olteanu, Carstoiu, & Mares, 2017). Oleh karena itu, untuk aplikasi mengenali emosi berdasarkan pembacaan dan pengukuran sinyal fisiologi tubuh lebih representatif dan mampu memberikan hasil yang lebih objektif (Ragot, Martin, Em, Pallamin, & Deverrez, 2017) (Wu & Min Hao, 2010) karena sinyal fisiologi tidak dapat dikontrol secara sadar oleh penggunanya sendiri.

Dalam pengenalan emosi berdasarkan sinyal fisiologi, beragam sinyal digunakan di dalam penelitian mulai dari Electrocardiography (ECG) (Gohsvarpour, Abbasi, & Goshvarpour, 2017), Electroencephalography (EEG) (Tamb & Khachane, 2016) (Tarnowski, Kolodziej, Majkowski, & Rak, Combined analysis of GSR and EEG signals for emotion recognition, 2018), Galvanic Skin Response (GSR) (Tarnowski, Kolodziej, Majkowski, & Rak, Combined analysis of GSR and EEG signals for emotion recognition, 2018) (Fernandes, Helawar, Lokesh, Tari, & Shahapurkar, 2014), tekanan darah (Fernandes, Helawar, Lokesh, Tari, & Shahapurkar, 2014), Heart Rate (Widanti, Sumanto, Rosa, & Miftahudin, 2015), serta kombinasi antara 2 atau lebih sinyal lainnya (Fernandes, Helawar, Lokesh, Tari, & Shahapurkar, 2014) (Gohsvarpour, Abbasi, & Goshvarpour, 2017) (Liu, Fan, Zhang, Gong, & Xiaopeng, 2016) (Liu, Zhang, & Gong, Emotion Recognition Based on Galvanic Skin Response Signal Feature Selection and SVM, 2016) (Widanti, Sumanto, Rosa, & Miftahudin, 2015) yang dibaca oleh sebuah sensor dan selanjutnya dikendalikan mikrokontroler menjadi sistem yang utuh (Myroniv, Wu, Christian, Bajo, & Tseng, 2017).

Dari berbagai ragam sinyal fisiologi yang dapat digunakan untuk mengenali emosi tersebut, heart rate terbukti secara efektif mampu mengenali kemarahan, ketakutan, jijik, dan kesedihan pada manusia (Menard, Richard, Hamdi, Dauce, & Yamaguchi, 2015). Sedangkan konduktansi kulit mampu memberikan gambaran keadaan emosi sebagaimana yang terjadi dalam perubahan sistem saraf simpatis (Wu & Min Hao, 2010). Berdasarkan hal tersebut, penggunaan sensor pulse dan sensor GSR dapat menjadi solusi pada aplikasi yang dibuat untuk pengenalan emosi yang mampu memanfaatkan teknologi smart wearable dengan biaya relatif lebih rendah.

Mengacu pada beberapa permasalahan dan solusi yang telah dikemukakan maka dalam penelitian kali ini, merancang dan membangun aplikasi pengenalan emosi berdasarkan sinyal fisiologi dengan metode yang digunakan adalah K-Nearest Neighbour (KNN).

(1) Sensor Pulse

Sesor pulse merupakan sensor plug and play yang dirancang untuk mengukur detak jantung langsung atau denyut nadi. Sensor pulse ini menggunakan prinsip dari fotoletismografia yaitu detak jantung diukur berdasarkan varis daya optic ketika cahaya tersebar atau diserap selama jalur darah melalui darah serta detak jantung yang berubah. Aliran volume darah ditentukan oleh denyut jantung dan karena cahaya diserap oleh darah, maka hal ini menunjukkan bahwa sensor mengukur perubahan volume darah melalui organ tubuh manapun yang menyebabkan intensitas cahaya melalui organ tubuh itu, sinyal pulsa sama dengan denyut jantung.



Gambar 1. Sensor Pulse

(2) Sensor GSR

GSR (Galvanic Skin Response) merupakan metode pengukuran konduktansi listrik dari koil. Emosi yang kuat mampu menyebabkan stimulus pada sistem saraf simpatis dan menghasilkan keringat lebih yang disekresi oleh kelenjar keringat. Sensor GSR merupakan sensor yang berfungsi untuk melakukan pembacaan GSR. Input dari Sesor GSR adalah resistansi dan daya konduksi, agar bisa digunakan dalam mengukur konduksi pada kulit (human resistance) melalui perhitungan rumus berikut :

$$HR = \frac{(1024 + 2 * Serial_{PortReading}) * 10000}{512 - Serial_{PortReading}}$$



Gambar 2. Sensor GSR

(3) K-Nearest Neighbour


Algoritma K-Nearest Neighbour (KNN) merupakan algoritma yang dapat digunakan untuk klasifikasi dan regresi. KNN membuat keputusan berdasarkan seluruh dataset training. Tidak ada waktu yang dihabiskan untuk melatih algoritma ini, tetapi hanya untuk pra-pemrosesan dan pengujian. KNN memiliki 2 karakteristik utama yaitu nonparametric dan pembelajaran malas (lazy learning). Algoritma KNN mengasumsikan bahwa hal serupa ada dalam jarak dekat. Dengan kata lain, sesuatu yang mirip berdekatan antara satu dengan yang lainnya. KNN menangkap ide dari kesamaan (distance, proximity, atau closeness) dengan matematika yang mungkin mempelajari / menghitung jarak antara satu titik dalam grafik.

Nilai K pada algoritma KNN merupakan point penting. Nilai K mengidentifikasi jumlah tetangga terdekat. Pemilihan nilai yang optimal untuk K yang paling baik dilakukan dengan memeriksa data terlebih dahulu. Secara umum, nilai K yang besar lebih tepat karena mengurangi noise secara keseluruhan tetapi hal ini bukan jaminan. Secara umum, nilai K dapat dihitung dengan pendekatan sederhana berikut:

$$K = \frac{\sqrt{n \text{ (count of sample dataset)}}}{2}$$

Penentuan nilai K berdasarkan rumus tersebut masih belum dapat tervalidasi. Untuk memvalidasi nilai K pada model dapat dilakukan dengan menghitung nilai error pada data uji. Hasil perhitungan nilai error dengan $K = n$ yang menghasilkan rata-rata terendah, maka n merupakan nilai K terbaik.

KNN pada dasarnya melakukan perhitungan jarak antar data. KNN memiliki beberapa metode perhitungan, yang paling umum digunakan adalah euclidean distances. Euclidean distance pada dasarnya menggunakan rumus Teorema Pythagoras yaitu menghitung jarak garis lurus antara 2 titik dalam plane. Secara visual, Euclidean Distance dapat digambarkan sebagai berikut:



Gambar 3. Euclidean Distances


Berikut ini rumus dari *Euclidean Distance*, adalah:

$$(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2}$$

$$d(x, y) = \sqrt{\sum_{i=0}^n (x_i - y_i)^2}$$

3. PEMBAHASAN

Sistem aplikasi pengenalan emosi yang dibangun terdiri dari 2 unit utama yaitu unit hardware dan unit software. Unit hardware terdiri dari wearable sensor yang akan digunakan user serta unit communication yang berfungsi untuk mengirim data ke unit software. Berikut ini diagram blok komunikasi untuk keseluruhan sistem:




Gambar 4. Diagram Blok Sistem Aplikasi

Unit hardware terdiri dari wearable sensor dan communication unit. Unit wearable sensor terdiri dari 2 sensor yang digunakan sebagai input sistem aplikasi yaitu sensor pulse dan Sensor GSR. Sensor Pulse membaca perubahan detak jantung dan sensor GSR mengukur nilai konduktansi listrik yang dihasilkan oleh kelenjar keringat di bawah kulit. Pembacaan ini dibantu oleh microcontroller yang selanjutnya akan dikirim ke unit software menggunakan komunikasi serial.

Unit Software terdiri dari beberapa bagian yaitu visualisasi, database server, dan machine learning knn. Data yang telah diterima dari unit hardware selanjutnya akan ditampilkan dalam bentuk visual grafik untuk mempermudah pembacaan data. Selanjutnya, ketika akan melakukan prediksi emosi, data yang diterima akan disimpan sementara dalam database server. Data ini yang selanjutnya akan digunakan oleh machine learning program untuk memprediksi emosi dengan melakukan pembelajaran (learning) berdasarkan dataset yang telah ada sebelumnya. Output dari sistem aplikasi ini adalah prediksi emosi berdasarkan analisa data yang diterima.

Berikut ini gambaran alur kerja secara umum pada sistem aplikasi untuk pengenalan emosi, yaitu :



Gambar 5. Alur Kerja Sistem

(1) Pengumpulan Data

Proses pengenalan emosi diawali dengan melakukan perekaman pada 15 orang *volunteer* dengan usia sekitar 18-45 tahun. Setiap orang akan dipasang wearable's sensor yang terdiri dari 2 sensor yaitu sensor pulse dan sensor GSR di tangannya. Selanjutnya, masing-masing akan diperlihatkan 6 jenis video berdurasi 1 menit untuk memacu emosi mereka. Jeda masing-masing dari video adalah 2 menit sebelum melanjutkan ke tahap berikutnya, kemudian melihat video emosi lainnya. Wearable's sensor akan melakukan proses perekaman sinyal detak jantung serta resistansi kulit *volunteer* yang diuji coba, ketika sedang melihat video. Data ini selanjutnya disimpan pada database sebelum diolah. Berikut ini beberapa *sample* data yang tersimpan di database, adalah:

id	bpm	ibi	signalps	avg	rst	cdt	time	emotion
742290	87	736	417	469	456279	2.19	6983997	Sureprise
259495	71	900	515	467	435111	2.3	2991418	Sureprise
322213	63	970	443	541	726207	1.38	3611416	Sadness
712825	83	776	919	501	1841820	0.54	6878804	Disgust
652712	82	746	378	493	1057890	0.95	6656573	Sadness
870616	72	774	917	427	220941	4.53	8156009	Disgust
1111932	83	820	725	367	121241	8.25	382583	Anger
208243	64	944	737	521	2295560	0.44	2741213	Fear
365139	63	954	758	533	995238	1	3898859	Disgust
1482235	68	974	485	528	1300000	0.77	17417	Anger

Gambar 6. Sample Raw Data

(2) Preprocessing Data

Preprocessing data merupakan tahapan paling penting sebelum melakukan pembelajaran data. Tahapan ini berfungsi untuk mempersiapkan data agar dapat digunakan oleh machine learning dalam memprediksi emosi. Data mentah yang diterima dari sensor ditransformasikan menjadi data yang dimengerti oleh sistem. Tahapan ini terdiri dari *filtering* data, *removing attribute*, *features scalling* dan *split* data.

(a) Filtering Data

Filtering data bertujuan untuk mengurangi bias data yang dapat mempengaruhi hasil prediksi serta nilai akurasi. Filtering data dilakukan dengan melakukan query database untuk memilih data dengan nilai bpm dari detak jantung antara 60-100 saja untuk disimpan menjadi *instances dataset*.

(b) Filtering Atribut

Data input yang disimpan dalam database terdiri beberapa fitur, yaitu id, bpm (*beats per minutes*), ibi (*interbeat intervoal*), pulse signal, rata-rata GSR sinyal, resistansi, conductivity, waktu, dan emosi. Dari banyaknya fitur tersebut terdapat beberapa yang tidak berkaitan untuk klasifikasi, yaitu id dan waktu. Oleh karena itu, kedua fitur itu akan dihilangkan dari instances data dengan menerapkan fungsi *removing attribute*. Berikut ini beberapa sample data yang telah dilakukan proses *filtering* data dan *filtering attribute* :

bpm	ibi	signalps	avg	rst	cdt
87	736	417	469	456279	2.19
71	900	515	467	435111	2.3
63	970	443	541	726207	1.38
83	776	919	501	1841820	0.54
82	746	378	493	1057890	0.95
72	774	917	427	220941	4.53
83	820	725	367	121241	8.25
64	944	737	521	2295560	0.44
63	954	758	533	995238	1
68	974	485	528	1300000	0.77

Gambar 7. Sample Data After Filtering

(c) *Feature Scaling*

Berdasarkan instances data yang dimiliki, terdapat beberapa features dengan variasi dan format nilai yang berbeda. Oleh karena itu, diterapkan proses feature scaling untuk mentransformasikan feature ke dalam range dan format yang sama. *Feature scaling* yang digunakan dalam penelitian ini adalah normalization, dimana nilai digeser dan diskalakan kembali sehingga menghasilkan nilai berkisar antara 0 dan 1. Adapun rumus yang digunakan untuk normalization dalam perhitungan adalah sebagai berikut:

$$X^i = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Berikut ini sample data setelah dilakukan feature scaling:

bpm	ibi	signalps	avg	rst	cdt
0.0000	0.9832	0.1201	1.0000	0.2782	0.1204
0.0000	0.9160	0.7024	0.9540	0.4020	0.0717
0.0417	0.8739	0.6636	0.8851	1.0000	0.0000
0.2083	1.0000	0.1978	0.9253	0.5421	0.0423
0.3333	0.6891	0.2532	0.5747	0.1444	0.2382
0.3750	0.1597	0.9963	0.3448	0.0459	0.5237
0.7917	0.0420	0.0000	0.7241	0.4308	0.0653
0.8333	0.1681	1.0000	0.7701	0.7913	0.0128
0.8333	0.3529	0.6414	0.0000	0.0000	1.0000
1.0000	0.0000	0.0721	0.5862	0.1541	0.2241

Gambar 8. *Sample Data After Feature Scaling*

(3) *Klasifikasi Data*

Setelah menerapkan pre-processing pada data, data telah sesuai dalam bentuk yang siap untuk diklasifikasi. Klasifikasi data menggunakan algoritma K-Nearest Neighbour. KNN menggunakan “kesamaan fitur” untuk memprediksi nilai titik data baru berikutnya. Secara sederhana, algoritma KNN adalah sebagai berikut:

- Memuat data yang akan diolah.
- Melakukan inisialisasi nilai K dari neighbor terdekat.
- Menghitung distance antara data test dengan masing-masing data training.
- Mengurutkan nilai distance dari yang terkecil ke terbesar (ascending order).
- Memilih nilai K teratas dari hasil pengurutan data.
- Menetapkan kelas ke titik uji berdasarkan kelas yang paling sering dari baris (modus/mode).

Sebagai contoh, berikut ini hasil perhitungan jarak antara data ke-1 dengan sample data lainnya:

bpm	ibi	signalps	avg	rst	cdt	Jarak
0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
0.0000	0.0045	0.3390	0.0021	0.0153	0.0024	0.6028
0.0017	0.0119	0.2953	0.0132	0.5209	0.0145	0.9261
0.0434	0.0003	0.0060	0.0056	0.0696	0.0061	0.3620
0.1111	0.0865	0.0177	0.1809	0.0179	0.0139	0.6542
0.1406	0.6782	0.7676	0.4293	0.0540	0.1627	1.4941
0.6267	0.8858	0.0144	0.0761	0.0233	0.0030	1.2765
0.6944	0.6644	0.7741	0.0528	0.2633	0.0116	1.5687
0.6944	0.3972	0.2717	1.0000	0.0774	0.7738	1.7929
1.0000	0.9667	0.0023	0.1712	0.0154	0.0108	1.4719

Gambar 9. Hasil Perhitungan Jarak *Euclidean*

(4) Pengujian Performances

Masalah yang sering terjadi pada algoritma KNN adalah bagaimana mencari nilai K yang paling sesuai untuk model klasifikasi sehingga menghasilkan nilai akurasi paling baik. Pengujian performance bertujuan untuk melakukan evaluasi terhadap model machine learning yang digunakan pada sistem aplikasi. Pengujian performances dilakukan menggunakan confusion matrix dengan menghitung 3 nilai yaitu recall, precision, dan akurasi. Teknik pengujian dilakukan dengan membagi dataset menjadi 2 bagian yaitu 80% training data dan 20% test data.

4. HASIL

Nilai K terbaik yang dapat digunakan untuk klasifikasi emosi didapatkan pada nilai 69, yang merupakan hasil dari perhitungan berdasarkan jumlah sample data yang dimiliki. Sample dataset yang digunakan berjumlah 18.455 data, maka perhitungan nilai K awal adalah sebagai berikut:

$$K = \frac{\sqrt{18455}}{2} \approx \frac{\sqrt{135,85}}{2} \approx 67$$

Hasil pengujian performances dari model klasifikasi KNN dengan nilai K = 69 serta 10 nilai di atas dan 10 nilai dibawah K adalah sebagai berikut:


No	K Value	Performances		
		Accuracy	Precision	Recall
1	49	77.82%	75.79%	75.79%
2	51	77.27%	75.69%	75.69%
3	53	76.92%	75.61%	75.61%
4	55	76.55%	75.55%	75.55%
5	57	76.76%	75.49%	75.49%
6	59	76.57%	75.42%	75.42%
7	61	76.14%	75.35%	75.35%
8	63	76.11%	75.31%	75.31%
9	65	75.59%	75.26%	75.26%
10	67	76.24%	76.14%	76.14%
11	69	75.73%	75.35%	75.35%
12	71	75.46%	75.30%	75.30%
13	73	75.81%	75.33%	75.33%
14	75	75.46%	75.30%	75.30%
15	77	75.30%	75.26%	75.26%
16	79	75.70%	75.27%	75.27%
17	81	75.43%	75.26%	75.26%
18	83	74.75%	74.41%	74.41%

19	85	74.75%	74.51%	74.51%
20	87	74.92%	74.57%	74.57%

Berdasarkan nilai K dengan akurasi tersebut, maka data berhasil diklasifikasikan dan model klasifikasi dapat digunakan untuk melakukan prediksi pengenalan emosi terhadap data baru.

Berikut hasil akhir dari pembacaan data oleh sensor yang divisualisasikan dalam bentuk diagram pada aplikasi yang kemudian dilakukan prediksi/pengenalan emosi berdasarkan model klasifikasi data yang telah dibuat, pada gambar 10 menunjukkan emosi pada aplikasi pengenalan dapat mengetahui emosi pada anak yang berkebutuhan khusus. Dapat diketahui emosi anak yang berkebutuhan khusus tersebut ketika diperkenalkan berbagai aktivitas yang bisa membangkitkan kepedulian anak tersebut.

Dengan mengenali emosi melalui aplikasi software maka dapat diketahui apakah anak berkebutuhan khusus menyukai atau sebaliknya, atau bisa juga adanya penanganan yang khusus. Pengenalan emosi oleh anak berkebutuhan khusus, dengan melakukan pemeriksaan terlebih dahulu. Pemeriksaan dilakukan dengan menjalankan perangkat lunak aplikasi pengenalan emosi pada anak berkebutuhan khusus. Perangkat lunak aplikasi pengenalan emosi akan menguji berdasarkan detak jantung ketika anak berkebutuhan khusus memberikan respon terhadap sesuatu yang disukai atau tidak disukai.



Gambar 10 . Hasil Uji Rekognisi Emosi

SIMPULAN

Berdasarkan hasil perancangan dan implementasi sistem pengenalan emosi berbasis sinyal fisiologi menggunakan K-Nearest Neighbour dapat disimpulkan bahwa:

- (1) Pengenalan emosi berdasarkan sinyal fisiologi dapat dilakukan dengan mengukur sinyal-sinyal yang terjadi di dalam tubuh ketika adanya pemicu emosi. Sinyal-sinyal fisiologi yang dapat digunakan dalam pengukuran diantaranya detak jantung dan konduktansi listrik (human resistance) pada kulit.

- (2) Sistem pengenalan emosi berdasarkan sinyal fisiologi dibuat dengan menyusun sebuah smart wearable system. Sistem ini terdiri dari perangkat keras yang dipakai (wearable) terintegrasi dengan microcontroller dan sistem pengolah data.
- (3) Proses klasifikasi emosi dilakukan dengan mempelajari (training) data yang telah direkam ketika penggunaan wearable system oleh machine learning dengan algoritma KNN. Hasil klasifikasi digunakan untuk melakukan prediksi emosi terhadap data baru yang diterima sistem aplikasi.
- (4) Pengukuran perfomansi dilakukan dengan menghitung accuracy, precision, dan recall dari setiap proses klasifikasi data dengan nilai K tertentu. Hasil performansi terbaik diperoleh ketika klasifikasi data menggunakan nilai K=67 yaitu accuracy 76.24%, recall 76.14%, dan precision 76.14%.

Referensi

- Ali, M., Al Machot, F., Mosa, A. H., Jdeed, M., Al Machot, E., & Kyamaka, K. (2018). A Globally Generalized Emotion Recognition System Involving Different Physiological Signals. *MDPI Journal*, 18.
- Arduino. (n.d.). Arduino . (Arduino CC) Retrieved June 26, 2019, from <https://www.arduino.cc/en/Guide/Introduct>.
- Axelson, J. (1997). *The Microcontroller Idea Book*. Madison, USA: Lakeview Research.
- Bachynskyi, A. (2018). *Emotional State Recognition Based on Physiological Signals*. Tartu: UNIVERSITY OF TARTU.
- Basu, S., Chakraborty, J., Bag, A., & Aftabuddin, M. (2017). A Review on Emotion Recognition using speech. *International Conference on Inventive Comunication and Computational Technologies*, 17, 109-114.
- Cernian, A., Olteanu, A., Carstoiu, D., & Mares, C. (2017). Mood Detector – On Using Machine Learning to Identify moods and Emotions. *International Conference on Control Sysems and Computer Science*, 213-216.
- Cherry, K. (2019, June 27). The 6 Types of Basic Emotions and Their Effect on Human Behaviour. (verywellmind) Retrieved June 29, 2019, from <https://www.verywellmind.com/anoverview-of-the-types-of-emotions4163976>
- Chopade, C. R. (2015). Text Based Emotion Recognition: A Survey. *International Journal of Science and Research*, 4(6), 409-414.
- Desai, D. (2018). Emotion Recognition using Speech Signal: A Review. *International Research Journal of Engineering and Technology (IRJET)*, 05(04), 1599-1605.
- Farnsworth, B. (2018, July 17). What is GSR (Galvanic Skin response) and how does it work? (Imotions) Retrieved July 4, 2019, from <https://imotions.com/blog/gsr/>
- Fernandes, A., Helawar, R., Lokesh, R., Tari, T., & Shahapurkar, A. V. (2014). Determination of Stress using Blood Pressure and Galvanic Skin Response. 165-168.
- Fraden, J. (2010). *Handbook of Modern Sensors*. London: Springer.

- Gohrani, K. (2019, November 10). Different Types of Distan. (Medium) Retrieved May 2020, from https://medium.com/@kunal_gohrani/differ-ent-types-of-distance-metrics-used-inmachine-learning-e9928c5e26c7
- Gohsvarpour, A., Abbasi, A., & Goshvarpour, A. (2017). An accurate emotion recognition system using ECG dan GSR signals and matching pursuit method. *Biomedical Journal*, 40, 355-368.
- Ingale, A. B., & Chaudhari, D. S. (2012). Speech Emotion Recognition. *International Jounaal of Soft Computing and Engineering (IJSCE)*, 2(1), 235-238.
- Jack, R. E., Garrod, O. G., & Schyns, P. G. (2014). Dynamic Facial Expressions of Emotion Transmit an Envolving Hierarchy of Signals over Time. United Kingdom: Elseiver Ltd.
- Kerkeni, L., Serrestou, Y., Mbarki, M., Raoof, K., Mahjoub, M. A., & Cleder, C. (2018). Automatic Speech Emotion using Machine Learning. In *Social Media and Machine Learning*. IntechOpen.
- Ko, B. C. (2018). A Brief Review of Facial Emotion Recognition Based on Visual Information. *MDPI Sensor Journal*, 18, 1-20.
- Lee, C., Yoo, S., Park, Y., Kim, N., Jeong, K., & Lee, B. (2006). Using Neural Network to Recognize Human Emotions from heart rate variability and skin resistance. *Proceeding of the 2006 IEEE*, 5523-5525.
- Liu, M., Fan, D., Zhang, X., Gong, & Xiaopeng. (2016). Human Emotion Recognition based on GSR signal feature selection and SVM. *International Conference on Smart City and System Engineering*, 157-160.
- Liu, M., Zhang, X., & Gong, X. (2016). Emotion Recognition Based on Galvanic Skin Response Signal Feature Selection and SVM. *International Conference on Smart City and System Engineering*, 157-160.
- M. Talabis, R. M., Miyamoto, I., Kaye, D., McPherson, R., & Martin, J. L. (2014). Information Security Analytics. In *Finding Security Insights, Patterns and Anomalies in Big Data*. Elsevier Science.
- MacGill, M. (2017, November 15). What Should my heart rate be? (Medical News) Retrieved July 04, 2019, from <https://www.medicalnewstoday.com/articles/235710.php>
- McCue, C. (2015). Data Mining and Predictive Analysis. In *Intelligence Gathering and Crime Analysis*. Butterworth-Heinemann.
- Menard, M., Richard, P., Hamdi , H., Dauce, B., & Yamaguchi, T. (2015). Emotion Recognition based on Heart Rate. *Proceedings of the 2nd International Conference on Physiological Computing Systems*, 26-32.
- Morgan, J. (2014, May 13). A Simple Explanation of 'The Internet of Things'. (Forbes) Retrieved June 27, 2019, from <https://www.forbes.com/sites/jacobmorgan/2014/05/13/simple-explanation-internetthings-that-anyone-canunderstand/#609d2cdf1d09>
- Myrnoniv, B., Wu, C.-W., Christian, A., Bajo, E., & Tseng, Y.-C. (2017). Analyzing User Emotions via Physiology Signals. *Data Science and Pattern Recognition Ubiquitous International Journal*, 1, 11- 24.
- Myroniv, B., Wu, C.-W., Ren, Y., Christian, A., Bajo, E., & Tseng, Y.-C. (2017). Analyzing User Emotions via Physiology Signals. *Data Science and Pattern Recognition Ubiquitos International*, 1, 11-24.

- Newman, T. (2018, January 10). The heart: All you need to know. (Medical News)
Retrieved July 04, 2019, from <https://www.medicalnewstoday.com/articles/320565.php>
- Nillson, N. J. (2005). Introduction to Machine Learning. Stanford University.
- Ragot, M., Martin, N., Em, S., Pallamin, N., & Deverrez, J. M. (2017). Emotion Recognition Using Physiological Signals: Laboratory vs. Wearable Sensors. HAL Archives-ouvertes.
- Robin, S. R., Judge, A. T., & Campbell, T. C. (2016). Emotions and Moods. In Organizational Behaviour (pp. 258-297). Harlow, United Kingdom: Pearson Education Limited.
- Setyohadi, D. B., Kusrohmaniah, S., Gunawan, S. B., Pranowo, & Prabuwo, A. S. (2018). Galvanic Skin Response Data Classification for Emotion Detection. International Journal of Electrical and Computer Engineering (IJECE), 8(5), 31-41.
- Sharma, M., Kacker, S., & Sharma, M. (2016). A Brief Introduction and Review on Galvanic Skin Response. International Journal of Medical Research Professionals, 2(06), 13-17.
- Shu, L., Xie, J., Yang, M., Li, Z., Li, Z., Liao, D., . . . Yang, X. (2018). A Review of Emotion Recognition Using Physiological Signals. MDPI Journal - Sensors, 1-3.
- Tamb, N. R., & Khachane, A. (2016). Mood Based E-learning using EEG.
- Tarnowski, P., Kolodziej, M., Majkowski, A., & Rak, R. J. (2017). Emotion Recognition using Facial Expressions. International Conference on Computational Science, 1175-1184.
- Tarnowski, P., Kolodziej, M., Majkowski, A., & Rak, R. J. (2018). Combined analysis of GSR and EEG signals for emotion recognition. 137-141.
- Udovicic, G., Russo, M., Derek, J., & Sikora, M. (2017). Wearable Emotion Recognition based on GSR and PPG Signals. MMHealth, 53-59.
- Verma, M. (2017). Working, Operation, and Types of Arduino Microcontroller. International Journal of Engineering Sciences and Research Technology, 6, 155-158.
- Widanti, N., Sumanto, B., Rosa, P., & Miftahudin, F. (2015). Stress Level Detection using Heart Rate, Blood Pressure, and GSR dan Stress Therapy by Utilizing Infrared. International Conference an Industrial Instrumentation and Control (ICIC) Journal, 275-279.
- Wu, G., & Min Hao, G. L. (2010). The analysis of emotion recognition from GSR based on PSO. International Symposium on Intelligence Processing and Trusted Computing.