

**KLASIFIKASI KEADAAAN EMOSIONAL BERDASARKAN SINYAL EEG  
MENGGUNAKAN ALGORITMA SUPPORT VECTOR MACHINE****Annisa' Hilmi Masruroh**Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Surabaya  
e-mail: annisamasruroh@mhs.unesa.ac.id**Abstrak**

Elektroensefalogram (EEG) merupakan salah satu biosinyal yang merekam aktivitas otak melalui kulit kepala. Diperlukan sebuah pengolahan sinyal EEG karena pengenalan secara visual sulit dilakukan. Hal tersebut dikarenakan sinyal EEG berbentuk gelombang elektrik yang sangat lemah. Pada penelitian ini, sinyal EEG diolah secara matematis sehingga dapat digunakan untuk mengklasifikasikan keadaan emosional. Seseorang tidak dapat mengidentifikasi keadaan emosional manusia dari isyarat verbal maupun non verbal saja karena emosi merupakan proses psiko-fisiologis yang dikaitkan dengan suasana hati, temperamen, kepribadian, serta motivasi. Untuk mengklasifikasikan keadaan emosional berdasarkan sinyal EEG, pada penelitian ini digunakan algoritma *Support Vector Machine* (SVM). Dataset yang digunakan adalah DEAP : A Database for Emotion Analysis using Physiological Signals dataset sebanyak 1280 data pada tiap 1 chunk sinyal. Eksperimen dilakukan menggunakan Weka 3.9 dengan split rasio 7:3. Dari hasil pengujian, akurasi yang diperoleh pada  $C=1$  yaitu 56.25% dengan  $\varepsilon = 10^{-3}$ , 56.25% dengan  $\varepsilon = 10^{-6}$ , dan 56.77% dengan  $\varepsilon = 10^{-9}$ .

**Kata kunci :** Klasifikasi, Keadaan Emosional, Sinyal EEG, SVM, DEAP dataset**Abstract**

Electroensephalogram (EEG) is a biosignal that records brain activity through the scalp. An EEG signal processing is required because visual recognition of EEG signals is difficult. It's because EEG signal is form a very smooth electrical waves. In this study, EEG signal was processed mathematically to classify emotional states. Human can't identify another human's emotional state just from verbal or non verbal signals, because emotions are a psycho-physiological process that is associated with mood, temperament, personality, and motivation. To classify emotional states based on EEG signals, in this study used Support Vector Machine (SVM) algorithm. Dataset is from DEAP: A Database for Emotion Analysis using Physiological Signals dataset that contains of 1280 data for each 1 chunk signal. The experiment was used Weka 3.9 with a split ratio of 7: 3. From the test results, the accuracy obtained at  $C = 1$  are 56.25% for  $\varepsilon = 10^{-3}$ , 56.25% for  $\varepsilon = 10^{-6}$ , and 56.77% for  $\varepsilon = 10^{-9}$ .

**Keywords:** Classification, Emotional States, EEG Signals, SVM, DEAP dataset**PENDAHULUAN**

Emosi memiliki peran yang penting dalam komunikasi antar manusia (Wang, Nie, and Lu 2014). Dengan adanya interaksi, otak manusia memproses input sensorik yang datang dari sekitar kita dan memberikan respon berupa emosi yang timbul dari kejadian tersebut. Sejumlah studi oleh ahli saraf, ahli kognitif, dan psikolog telah menunjukkan bahwa emosi sangat penting dalam berpikir rasional. Penelitian menunjukkan bahwa pasien dengan gangguan emosional memiliki kesulitan dalam kegiatan sehari-hari (Petrantonakis

and Hadjileontiadis 2010). Oleh karena itu diperlukan suatu pengenalan emosi pada manusia. Salah satu pendekatan yang paling efektif untuk klasifikasi emosi manusia adalah dengan analisis dan interpretasi sinyal EEG (Teo et al. 2017).

Elektroensefalogram (EEG) merupakan salah satu biosinyal (Tripathi 2011) yang merekam aktivitas otak melalui kulit kepala. EEG digunakan untuk mendeteksi dan menganalisis aktivitas otak dengan bantuan *Brain Computer Interface* (BCI) (Islam et al. 2016). Riset tentang BCI berdasarkan sinyal EEG pernah dilakukan oleh Islam, dkk.

(2016) dan menghasilkan akurasi tertinggi pada algoritma SVM dengan akurasi 95,21% dibandingkan dengan *Artificial Neural Network* (ANN), dan *k-Nearest Neighbor* (*k*-NN) (Islam et al. 2016). Dan penelitian tentang sinyal EEG paling banyak dilakukan untuk mengklasifikasikan keadaan emosional manusia (Ackermann et al. 2016; Koelstra et al. 2012; Li et al. 2018; Mei and Xu 2017; Ozerdem and Polat 2017).

Penelitian oleh Ackermann, dkk. (2016) menggunakan SVM untuk klasifikasi emosi dan dibandingkan dengan *Random Forest* (RF). Hasilnya, akurasi tertinggi diperoleh ketika menggunakan algoritma RF dimana rentang akurasi berkisar 40-60% dengan DEAP dataset (Ackermann et al. 2016). Selain itu, penelitian oleh Ozerdem dan Polat (2017), membandingkan 2 algoritma yaitu ANN dan juga *k*-NN dengan DEAP dataset untuk 5 channel saja yaitu Fp1, FC2, AF3, O1, dan P3. Akurasi tertinggi yaitu ANN dengan akurasi 77,14% (Ozerdem and Polat 2017). Penelitian lain yang dilakukan Li, dkk. (2018) menggunakan SVM dihasilkan akurasi tertinggi untuk SEED dataset yaitu sebesar 83,33% dan DEAP dataset sebesar 59.06% (Li et al. 2018). Dan studi yang pernah dilakukan oleh Koelstra, dkk. (2012) mengklasifikasikan emosi secara biner berdasarkan *valence* menggunakan algoritma naive Bayes. Akurasi yang dihasilkan yaitu sebesar 57% (Koelstra et al. 2012).

SVM merupakan algoritma klasifikasi yang paling banyak digunakan dalam pengenalan emosi berdasarkan sinyal fisiologis (Shu et al. 2018). SVM dikenal sebagai teknik *machine learning* terbaik setelah sebelumnya teori *machine learning* yang disebut *Neural Network* (NN) (Mulyaningtyas and Imah 2018). Cara kerja SVM yaitu dengan mentransformasikan data ke ruang yang lebih tinggi, sehingga diperoleh batas yang optimal antarkelas atau disebut dengan optimal *hyperplane* (L 2017). Parameter SVM yang digunakan pada penelitian ini yaitu C dan epsilon. Parameter C pada SVM menyatakan batas penalti untuk *lagrange multiplier* atau disebut juga dengan *threshold*. Sedangkan untuk parameter epsilon menyatakan error klasifikasi (Katsis et al. 2008).

Oleh karena itu, pada penelitian ini akan dilakukan Klasifikasi Keadaan Emosional Berdasarkan Sinyal EEG Menggunakan Algoritma SVM. Dataset yang digunakan berasal dari DEAP Dataset dengan 32 subjek (Koelstra et al. 2012) (<http://www.eecs.qmul.ac.uk>).

## METODE

Penelitian ini terdiri dari beberapa proses. Yang pertama *preprocessing* yang berguna untuk menyederhanakan input data yang akan digunakan. Kemudian pengklasifikasian data sinyal EEG menggunakan algoritma SVM dengan parameter C dan epsilon. C yang digunakan pada penelitian ini adalah 1 dan epsilon yang digunakan yaitu  $\varepsilon$  sebesar  $10^{-3}, 10^{-6}$ , dan  $10^{-9}$ .

### Preprocessing

Data input akan dilakukan proses pelabelan, pemilihan channel data, dan juga pembagian chunk.

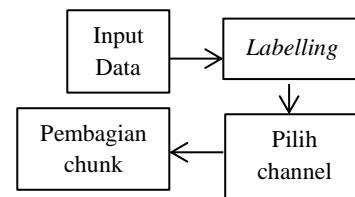


Fig 1. Diagram Blok preprocessing

Untuk proses pelabelan, digunakan label 1 (*high valence*) dan 0 (*low valence*). Proses pelabelan ini menggunakan threshold 5. Dikatakan *low* jika penilaian kurang dari 5 dan dikatakan *high* jika penilaian lebih dari atau sama dengan 5.

Dari 40 channel sinyal EEG, diambil 1 channel yang dapat mewakili emosi subjek tersebut. Dalam hal ini, channel yang diambil adalah channel sinyal EEG yang berada di daerah frontal yaitu Fp1. Untuk 1 channel sinyal EEG terdapat 8064 data numerik. Keadaan emosional yang digunakan pada penelitian ini adalah keadaan *valence* saja.

Data dibagi menjadi beberapa *chunk*, dari 63 detik dibagi menjadi 7 potong dengan masing-masing potong mewakili 9 detik perekaman sinyal EEG. Karena frekuensi data yang telah dilakukan pre-pemrosesan memiliki frekuensi 128 Hz, maka untuk 1 detik sinyal terdapat 128 data numerik. Sehingga terdapat 1152 fitur sinyal EEG.

### Proses Klasifikasi dengan SVM

SVM digunakan untuk memisahkan data dari 2 kelas secara linear (Mulyaningtyas and Imah 2018). Misalkan  $x_i \in \mathbb{R}^d$  adalah dataset dengan  $y_i \in \{-1, +1\}$  untuk  $i = 1, 2, 3, \dots, l$  dengan 1 adalah banyaknya data (Fagerlund 2007). SVM akan mencari *hyperplane* terbaik di ruang input untuk memisahkan beberapa kelas (Mulyaningtyas and Imah 2018). *Hyperplane* terbaik adalah *hyperplane* yang terletak ditengah-tengah antara dua set objek dari dua kelas yang ditentukan dengan mengukur

maximum margin. Nilai margin merepresentasikan jarak antar kelas sedangkan *support vector* adalah titik terdekat dengan *hyperplane* di setiap kelas . Data pada kelas +1 dan kelas -1 dirumuskan sebagai berikut (Mulyaningtyas and Imah 2018):

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

$$(w \cdot x_i) + b \geq -1 \text{ untuk } y_i = -1 \quad (2)$$

Karena terdapat dua kelas ( $y_1$  dan  $y_2$ ), maka  $w$  atau bobot juga akan memiliki dua atribut ( $w_1$  dan  $w_2$ ) (Katsis et al. 2008). Sehingga untuk mencari *hyperplane* terbaik yaitu dengan meminimalkan nilai:

$$\frac{1}{2} \|w\|^2 = \frac{1}{2}(w_1^2 + w_2^2) \quad (3)$$

dengan syarat:

$$y_i = (w \cdot x_i + b) \geq 1, i = 1, 2, 3, \dots, N \quad (4)$$

Vektor  $x_i$  akan ditransformasikan ke dimensi yang lebih tinggi  $F$  dengan fungsi  $\emptyset : R^n \rightarrow F$ . Setelah menentukan *hyperplane* yang optimal, maka kelasnya akan ditentukan dengan fungsi  $f$  sebagai berikut (Katsis et al. 2008):

$$f(x_d) = \sum_{i=1}^m \alpha_i y_i K(x_i, x) + b \quad (5)$$

Dimana  $m$  adalah banyaknya *support vector*,  $\alpha_i$  adalah nilai bobot untuk setiap data, dan  $K(x_i, x)$  adalah fungsi kernel. Pada penelitian ini, kernel yang digunakan adalah *Radial Basis Function* (RBF) kernel, dimana fungsinya dirumuskan sebagai berikut (Katsis et al. 2008):

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0 \quad (6)$$

Dimana  $\gamma = 1/2\sigma^2$  sebagai parameter kernel (Katsis et al. 2008).

## DATASET

### DEAP Dataset

DEAP : A Database for Emotion Analysis using Physiological and Audiovisual Signals dataset memiliki 40 channel diantaranya 32 channel EEG, 4 channel EMG, 1 channel blood pressure, 1 channel GSR, 1 channel temperature, dan 1 channel untuk respiration. Channel EEG yang digunakan dataset ini adalah AF3, Fp1, FC1, F7, FC5, F3, C3, CP5, T7, CP1, PO3, P7, P3, O1, Oz, AF4, Fp2, Pz, Fz, F4, F8, FC6, FC2, Cz, P4, T8, CP6, C4, P8, PO4, dan O2. Untuk tiap channel terdapat 8064 data numerik. Sinyal EEG yang direkam sebanyak 32 subjek (50% pria, 50 % wanita dengan rentang usia 19-37 tahun) yang diberikan stimuli berupa 40 video musik berdurasi 1 menit. Data sinyal EEG ini direkam dengan Biosemi ActiveTwo system dan disimpan dalam file Biosemi Data Format (BDF) dengan sample rate 512 Hz (Koelstra et al. 2012).

Pada data tersebut terdapat 2 variabel, yaitu data sinyal EEG itu sendiri dan juga data *self-*

*assessment* (label) dari *valence*, *arousal*, *dominance*, dan *liking* untuk tiap musik video (Koelstra et al. 2012). Data sinyal EEG yang digunakan adalah data yang sudah melalui tahap *pre-processed*, dimana data sinyal EEG sudah dalam bentuk .mat dan telah di down-sampled menjadi 128 Hz sehingga menjadi 63 detik sinyal (Koelstra et al. 2012).

### Split Dataset

Data latih dan data uji dipisahkan menjadi rasio 7:3. Penentuan besar rasio tersebut bergantung pada banyaknya sampel data yang digunakan dan juga model yang dilatih (Shah 2017). Karena data yang diklasifikasi sebanyak 8960 data, maka data pelatihan dibutuhkan lebih banyak daripada data pengujian.

## HASIL DAN PEMBAHASAN

*True Positive* (TP) adalah banyaknya klasifikasi benar yang diklasifikasi ke kelas1 (*high valence*), *False Positive* (FP) adalah banyaknya klasifikasi salah yang diklasifikasi ke kelas1, *True Negative* (TN) adalah banyaknya klasifikasi benar yang diklasifikasi ke kelas0 (*low valence*), dan *False Negative* (FN) adalah banyaknya klasifikasi salah yang diklasifikasi ke kelas0 (Ozerdem and Polat 2017).

*TP Rate* atau disebut dengan *sensitivity* dirumuskan sebagai berikut:

$$TP Rate = \frac{TP}{TP+FN} \quad (7)$$

*FP Rate* dirumuskan sebagai berikut:

$$FP Rate = \frac{FP}{TN+FP} \quad (8)$$

*Precision* adalah tingkat ketepatan antara informasi dengan prediksi, dirumuskan sebagai berikut:

$$Precision = \frac{TP}{TP+FP} \quad (9)$$

*Recall* sama dengan *TP Rate* yaitu tingkat keberhasilan dalam melakukan klasifikasi pada suatu kelas, memiliki formula sebagai berikut:

$$Recall = \frac{TP}{TP+FN} \quad (10)$$

*F-Measure* adalah *harmonic mean* dari *precision* dan *recall*, dirumuskan sebagai berikut:

$$F = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (11)$$

*Matthews correlation coefficient* (MCC) adalah koefisien korelasi yang dihitung dari keempat *confusion matrix*, dirumuskan sebagai berikut (Saito and Rehmsmeier 2015):

$$MCC = \frac{TP \cdot TN - FP \cdot FN}{((TP+FP)(TP+FN)(TN+FP)(TN+FN))^{1/2}} \quad (12)$$

Kurva *Receiver Operating Characteristic* (ROC) dibuat berdasarkan nilai telah didapatkan pada perhitungan dengan *confusion matrix*, yaitu

## KLASIFIKASI KEADAAAN EMOSIONAL BERDASARKAN SINYAL

antara FP Rate (sumbu x) dengan TP Rate (sumbu y). *Baseline* pada ROC adalah garis lurus diagonal dari (0,0) ke (1,1). Klasifikasi dikatakan kurang baik apabila mendekati titik (0,0) dan klasifikasi dikatakan baik ketika mendekati titik (1,1) (Saito and Rehmsmeier 2015).

Kurva *Precision-Recall* (PRC) dibuat berdasarkan nilai telah didapatkan pada perhitungan dengan *confusion matrix*, yaitu antara *Precision* (sumbu y) dan *Recall* (sumbu x). *Baseline* pada PRC ditentukan dengan rasio data pada tiap kelas. Jika data seimbang maka *baseline* yang digunakan adalah  $y=0.5$  dan ketika data tidak seimbang maka *baseline* yang digunakan adalah  $y=0.1$  (Saito and Rehmsmeier 2015).

Akurasi dihitung menggunakan rumus:

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (13)$$

Tabel 1. Hasil akurasi dengan algoritma SVM

$\varepsilon$	Akurasi (%)	Time build model (s)
$10^{-3}$	56.250	14.44
$10^{-6}$	56.250	14.75
$10^{-9}$	56.771	15.25

Tabel 2. Hasil TP Rate, FP Rate, Precision, dan Recall dengan algoritma SVM

$\varepsilon$	TP Rate	FP Rate	Precision	Recall	Class
$10^{-3}$	0.910	0.908	0.576	0.910	kelas1
	0.092	0.090	0.429	0.092	kelas0
	0.563	0.561	0.513	0.563	Avg
$10^{-6}$	0.910	0.908	0.576	0.910	kelas1
	0.092	0.090	0.429	0.092	kelas0
	0.563	0.561	0.513	0.563	Avg
$10^{-9}$	0.932	0.926	0.577	0.932	kelas1
	0.074	0.068	0.444	0.074	kelas0
	0.568	0.562	0.521	0.568	Avg

Tabel 3. Hasil F-Measure, MCC, ROC, dan PRC dengan algoritma SVM

$\varepsilon$	F-Measure	MCC	ROC Area	PRC Area	Class
$10^{-3}$	0.708	0.003	0.501	0.576	kelas1
	0.152	0.003	0.501	0.425	kelas0
	0.470	0.003	0.501	0.512	Avg
$10^{-6}$	0.708	0.003	0.501	0.576	kelas1
	0.152	0.003	0.501	0.425	kelas0
	0.470	0.003	0.501	0.512	Avg
$10^{-9}$	0.713	0.011	0.503	0.577	kelas1
	0.126	0.011	0.503	0.426	kelas0
	0.464	0.011	0.503	0.513	Avg

Tabel 4. Confusion Matrix

		Prediksi	
		1	0
Kelas	1	TP	FN
	0	FP	TN

Tabel 5. Confusion Matrix  $\varepsilon = 10^{-3}$

		Prediksi	
		1	0
Kelas	1	201	20
	0	148	15

Tabel 6. Confusion Matrix  $\varepsilon = 10^{-6}$

		Prediksi	
		1	0
Kelas	1	201	20
	0	148	15

Tabel 7. Confusion Matrix  $\varepsilon = 10^{-9}$

		Prediksi	
		1	0
Kelas	1	206	15
	0	151	12

## KESIMPULAN

Pada penelitian ini, klasifikasi keadaan emosional berdasarkan sinyal EEG digunakan algoritma SVM. Parameter yang dipakai yaitu  $C=1$  dan juga epsilon sebesar  $10^{-3}, 10^{-6}$ , dan  $10^{-9}$ . Diperoleh akurasi sebesar 56.25% dan waktu membangun model masing-masing 14.44s dan 14.75s ketika epsilonnya  $10^{-3}$  dan  $10^{-6}$  serta akurasi sebesar 56.77% dan waktu membangun model adalah 15.25s ketika epsilonnya sebesar  $10^{-9}$ .

## DAFTAR PUSTAKA

- Ackermann, Pascal, Christian Kohlschein, Klaus Wehrle, and Sabina Jeschke. 2016. “EEG-Based Automatic Emotion Recognition : Feature Extraction , Selection and Classification Methods.” *IEEE 18th International Conference on E-Health Networking, Applications and Services (Healthcom)*.
- Fagerlund, Seppo. 2007. “Bird Species Recognition Using Support Vector Machines.” 2007.
- Islam, Sheikh Rabiul, Ahosanullah Sajol, Xu Huang, and Keng Liang Ou. 2016. “Feature

- Extraction and Classification of EEG Signal for Different Brain Control Machine.”
- Katsis, Christos D., Nikolaos Katertsidis, George Ganiatsas, Dimitrios I. Fotiadis, and Senior Member. 2008. “Toward Emotion Recognition in Car-Racing Drivers : A Biosignal Processing Approach.” *IEEE Transactions On Systems, Man, And Cybernetics Part A: Systems And Humans* 38(3):502–12.
- Koelstra, Sander, Student Member, Student Member, Jong-seok Lee, Ashkan Yazdani, Touradj Ebrahimi, Thierry Pun, Anton Nijholt, and Ioannis Patras. 2012. “DEAP : A Database for Emotion Analysis Using Physiological Signals.” 1–15.
- L, Greg. 2017. “Why Use SVM?” *Alteryx Community*. Retrieved April 2, 2019 (<https://community.alteryx.com/>).
- Li, Xiang, Dawei Song, Peng Zhang, Yazhou Zhang, Yuxian Hou, Bin Hu, and Bin Hu. 2018. “Exploring EEG Features in Cross-Subject Emotion Recognition.” *Frontiers in Neuroscience* 12(March).
- Mei, Han and Xiangmin Xu. 2017. “EEG-Based Emotion Classification Using Convolutional Neural Network.” *International Conference on Security, Pattern Analysis, and Cybernetics (SPAC)* 130–35.
- Mulyaningtyas, Clarin and Elly Matul Imah. 2018. “Barcode Recognition Using Principal Component Analysis and Support Vector Machine.” 157(*Miseic*):106–10.
- Ozerdem, Mehmet Sirac and Hasan Polat. 2017. “Emotion Recognition Based on EEG Features in Movie Clips with Channel Selection.” *Springer Brain Informatics*.
- Petrantonakis, Panagiotis C. and Leontios J. Hadjileontiadis. 2010. “Emotion Recognition From EEG Using Higher Order Crossings.” *IEEE TRANSACTIONS ON INFORMATION TECHNOLOGY IN BIOMEDICINE* 14(2):186–97.
- Saito, Takaya and Marc Rehmsmeier. 2015. “The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets.” *PLoS One* 1–21.
- Shah, Tarang. 2017. “About Train , Validation and Test Sets in Machine Learning Training Dataset Validation Dataset Test Dataset.” *Towards Data Science*. Retrieved February 14, 2019 (<https://towardsdatascience.com/>).
- Shu, Lin, Jinyan Xie, Mingyue Yang, Ziyi Li, Zhenqi Li, Dan Liao, Xiangmin Xu, and Xinyi Yang. 2018. “A Review of Emotion Recognition Using Physiological Signals.” *Sensors*.
- Teo, Jason, Chew Lin Hou, James Mountstephens, Jason Teo, Chew Lin Hou, and James Mountstephens. 2017. “Deep Learning for EEG-Based Preference Classification.” 020141.
- Tripathi, Kush. 2011. “Important Physiological Signals in the Body.” *Biomedical Engineering*. Retrieved April 2, 2109 (<http://biomedikal.in>).
- Wang, Xiao-wei, Dan Nie, and Bao-liang Lu. 2014. “Neurocomputing Emotional State Classification from EEG Data Using Machine Learning Approach.” *Neurocomputing* 129:94–106.