MATHunesa
Jurnal Ilmiah Matematika *Volume 7 No.2 Tahun 2019*
ISSN 2301-9115

KLASIFIKASI SCHIZOPHRENIA BERDASARKAN SINYAL EEG MENGGUNAKAN ALGORITMA *SUPPORT VECTOR MACHINE*

Ivan Kurnia Laksono
Jurusan Matematika, FMIPA, Universitas Negeri Surabaya
e-mail : ivanlaksono@mhs.unesa.ac.id,

Abstrak

Schizophrenia adalah sindrom yang disertai dengan manifestasi psikologis spesifik yang disebabkan ketidakseimbangan dopamin dalam otak. Salah satu metode yang dapat digunakan untuk mendeteksi *schizophrenia* adalah *elektroensephalogram* (EEG). Kemampuan EEG untuk merekam perubahan aktifitas listrik otak membuatnya dapat digunakan sebagai alat identifikasi dengan luaran berupa rekaman sinyal. Pada penelitian ini digunakan algoritma *Support Vector Mechine* sebagai metode pengolahan data sinyal EEG untuk pengklasifikasian *schizophrenia*. Dataset yang digunakan adalah kaggle dataset yang terdiri dari 3072 atribut dan 2 kelas yaitu kelas normal dan kelas schizophrenia yang diambil dari 81 subyek, dengan 32 subyek normal dan 49 subyek penderita schizophrenia. Sebelum proses pelatihan, data latih dan data uji dipisah secara acak dengan metode hold-out validation dengan rasio data latih dan data uji 9 : 1, 4 : 1, 7 : 3 dan 3 : 2. Hasil pengujian menghasilkan akurasi terbaik saat rasio 9 : 1 yaitu 70%.

Kata kunci : Kaggle dataset, klasifikasi, schizophrenia , sinyal EEG, SVM

Abstract

Schizophrenia is a syndrome accompanied by specific psychological manifestations caused by dopamine imbalance in the brain. One method that can be used to detect schizophrenia is electroensephalogram (EEG). The ability of the EEG to record changes in the electrical activity of the brain makes it able to be used as an identification tool with output in the form of signal recording. In this study used the Support Vector Mechine algorithm as a method of processing EEG signal data for the classification of schizophrenia. The dataset used is the Kaggle dataset consisting of 3072 attributes and 2 classes, namely the normal class and schizophrenia class which was taken from 81 subjects, with 32 normal subjects and 49 subjects with schizophrenia. Before the training process, training data and test data were separated randomly by the hold-out validation method with the ratio of training data and test data 9: 1, 4: 1, 7: 3 and 3: 2. The test results produced the best accuracy when the ratio was 9: 1 is 70%.

Keywords : Classification, dataset kaggle, EEG signal, *schizophrenia*, SVM

Universitas Negeri Surabaya

1. PENDAHULUAN

Dibandingkan teknik lainnya EEG memiliki keunggulan lebih ekonomis, cara pengoprasian lebih mudah dan bersifat non-invasif sehingga tidak mengakibatkan kerusakan fisik. Namun EEG juga memiliki kelemahan yaitu kurang memiliki resolusi spasial yang tinggi (Ibrahim, 2016).

Diperkirakan lebih dari 21 juta orang di seluruh dunia menderita *schizophrenia* (World Health Organization, 2018). Penderita *schizophrenia* berisiko 2-3 kali lebih tinggi mengalami kematian di usia muda, sehingga melakukan *diagnose* awal terhadap penyakit *schizophrenia* penting dilakukan agar perkembangan penyakit dapat dikontrol.

Pada tahun 2013 Judith M.Ford melakukan penelitian tentang prediksi respon kortikal pendengaran terhadap nada yang disampaikan melalui penekanan tombol berdasarkan sinyal EEG, data yang digunakan pada penelitian tersebut bersumber dari *kaggle.com* yang direkam dari 81 subyek, terdiri dari 32 normal dan 49 penderita *schizophrenia* (Judith M.Ford, 2013). Disisi lain pada tahun 2018 Daisy melakukan klasifikasi

penyakit *Schizophrenia* menggunakan 75 data gelombang EEG yang terdiri dari data EEG *paranoid schizophrenia* dan *simple schizophrenia* yang bersumber dari data Rekam Medik RSUD Dr. Soeroto Ngawi pada tahun 2016. Penelitian tersebut dilakukan dengan menggunakan algoritma SVM dan menghasilkan tingkat akurasi sebesar 90% (Daisy Kurniawaty, 2018).

Berdasarkan latar belakang tersebut pada penelitian ini dilakukan klasifikasi *schizophrenia* berdasarkan sinyal EEG menggunakan algoritma SVM. Dataset yang digunakan pada penelitian ini bersumber dari kaggle.com yang terdiri dari data gelombang EEG yang diambil dari 81 subyek (32 normal dan 49 penderita schizophrenia) (kaggle.com, 2017).

2. KAJIAN TEORI

Electroencephalography

EEG (*Electroencephalography*) adalah suatu teknik yang digunakan untuk merekam perubahan-perubahan aktivitas otak dengan cara memasang elektroda-elektroda pada kulit kepala yang berfungsi sebagai penghantar listrik ke atau dari jaringan otak. Dengan cara ini dapat diketahui adanya perubahan-perubahan pada potensi listrik otak, sehingga EEG dapat digunakan sebagai alat dignosa awal penyakit neuron. Sinyal EEG dijelaskan dalam hal frekuensi yang perbedaannya bergantung pada rangsangan dari luar maupun dalam. Gelombang EEG memiliki beberapa jenis gelombang yang diklasifikasi berdasarkan frekuensi. Frekuensi gelombang otak sebagian besar berkisar dari 0,5-500 Hz. Namun, kategori frekuensi paling relevan secara klinis yaitu gelombang *delta* berkisar 0,5 hingga 3Hz, gelombang *tetha* berkisar lebih dari 3 hingga 7 Hz, gelombang *alpha* berkisar lebih dari 7 hingga 13 Hz, gelombang *beta* Lebih besar dari 13 Hz (Roy Sucholeiki, 2017).

Schizophrenia

Schizophrenia adalah sindrom yang disertai dengan manifestasi psikologis spesifik. Manifestasi ini meliputi halusinasi auditorik, delusi, gangguan pikiran dan perilaku (Judith M.Ford, 2013). *Schizophrenia* merupakan gangguan mental serius dimana penderita tidak normal dalam menafsirkan realita dan dapat menyebabkan kombinasi antara halusinasi, delusi dan pemikiran serta perilaku yang tidak teratur**.** Penyakit *schizophrenia* disebabkan ketidakseimbangan dopamin dalam otak. Dopamin memiliki fungsi mengatur pergerakan tubuh, kognisi, daya ingat, emosi, rasa senang, tidur serta untuk menghantarkan sinyal dalam otak (Risky Candra Swari, 2018).

Support Vector Mechine

SVM (*Support Vector Mechine*) merupakan algoritma klasifikasi yang bekerja dengan cara mencari hyperplane dalam ruang dimensi-N yang berfungsi sebagai pemisah data antar kelas. Penelitian ini menggunakan 2 parameter 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).

3. METODE

Penelitian ini terdiri dari dua proses yaitu *preprocessing* dan pengklasifikasian. Tahap *preprocessing* bertujuan untuk menyiapkan data masukan agar sesuai dengan algoritm SVM. Proses pengklasifikasian *schizophrenia* berdasarkan sinyal EEG menggunakan algoritma SVM menggunakan parameter C dan epsilon. C yang digunakan pada penelitian ini adalah 1, 5 dan 10 sedangkan epsilon (ε) yang digunakan adalah $10^{-3}, 10^{-6}, \text{dan } 10^{-9}$.

Pra-pemrosesan

Gambar 1. Diagram Blok preprocessing

Pada gambar 1 dapat diketahui bahwa terdapat 3 tahapan dalam pra-pemrosesan data. Tahap pertama adalah melakukan input data berupa data numerik sinyal EEG. Tahap kedua dalam adalah mengambil sampel data sinyal EEG dengan mengambil data sinyal EEG dari *chanel* Fz N100 yang terletak di kepala bagian depan (*lobus frontalis*). Tahap ketiga adalah melakukan pembagian data (*split data*) antara data latih dan data uji menggunakan metode *hold out validation*, dimana data dijadikan dua bagian sesuai dengan rasio yang ditentukan. Dalam penelitian ini menggunakan 4 rasio yang berbeda yaitu ratio 9 : 1, 4 : 1, 7 : 3 dan 3 : 2.

Proses Klasifikasi dengan SVM

Algoritma SVM melakukan pengklasifikasian data antar kelas dengan cara mencari *hyperplane* optimal yang berfungsi sebagai pemisah data antar kelas. *Hyperplane* optimal ditentukan dengan menghitung margin maksimum. Nilai margin merupakan nilai yang merepresentasikan jarak suatu kelas dengan kelas lain. Sedangkan titik setiap kelas yang memiliki jarak terdekat dari *hyperplane* disebut *support vector*.

Jika terdapat dataset dengan dua kelas misal $x_i \, \epsilon \, R^n, n > 1, i = 1,23, \ldots, I$ dan $y_i \epsilon \{-1, +1\}$ dengan

hyperplane $g(x) = \langle w, x \rangle + c$ maka *decision rule* didefinisikan sebagai berikut :

$$f(x) = \begin{cases} +1, g(x) \geq 1 \\ -1, g(x) < 1 \end{cases} \quad (1)$$

Selanjutnya untuk mencari hyperplane optimal perlu meminimalkan nilai berikut:

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

dengan syarat:

$$(w_1.x_i + w_2.x_i + c) \geq 1 \quad (3)$$

Setelah didapat *hyperplane* optimal, maka dihitung fungsi keputusan $sign(f(x))$ untuk menentukan kelas data.

$$f(x_d) = \sum_{i=1}^{m} \alpha_i y_i K(x_i, x) + y \quad (4)$$

Dimana m merupakan banyak *support vector*, α_i merupakan bobot setiap data, dan $K(x_i, x)$ merupakan fungsi kernel, pada penelitian ini menggunakan *polykernel* yang dirumuskan sebagai berikut :

$$K(x, y) = (x^T y + c)^d \quad (5)$$

4. DATASET

Kaggle Dataset

Dataset yang digunakan pada penelitian ini bersumber dari kaggle.com. Kaggle merupakan komunitas online yang diakuisisi oleh Google LLC pada 8 Maret 2017 (Moyer, 2017). Kaggle terdiri dari ilmuan yang mendalami data dan *mechine learning* dan memungkinkan pengguna untuk menemukan dan mempublikasikan dataset, mengeksplorasi dan membangun model dalam lingkungan sains data berbasis web serta mengikuti kompetisi untuk menyelesaikan tantangan sains data.

Deskripsi Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari data sinyal EEG *Schizophrenia* dan data sinyal EEG normal dengan domain frekuensi. Data tersebut diambil dari 81 subyek, dengan 32 subyek normal dan 49 subyek penderita *schizophrenia* . Rentang usia subyek adalah 19 hingga 63 tahun, dengan jumlah subyek pria 67 orang dan wanita 14 orang. Data gelombang EEG diambil dari setiap subyek dengan cara meletakan kawat elektroda dan diletakan pada kulit kepala subyek. Elektroda tersebut diletakan pada 36 titik (*chanel*) diantaranya Fz N100, FCz N100, Cz N100, FC3 N100, FC4 N100, C3 N100, C4 N100, CP3 N100, CP4 N100, Fz P200, FCz P200, Cz P200, FC3 P200, FC4 P200, C3 P200, C4 P200, CP3 P200, CP4 P200, Fz B0, FCz B0, Cz B0, FC3 B0, FC4 B0, C3 B0, C4 B0, CP3 B0, CP4 B0, Fz B1, FCz B1, Cz B1, FC3 B1, FC4 B1, C3 B1, C4 B1, CP3 B1, CP4 B1. Pada saat perekaman sinyal EEG, subyek berada dalam 3 kondisi, pertama subyek diminta untuk menekan tombol ketika mendengar suara, kedua subyek diberi stimulus berupa nada yang sama atau nada berulang dan ketiga subyek diminta untuk menekan tombol dengan kecepatan sama dalam selang waktu tertentu.. Setiap kondisi menghasilkan rekaman data sinyal EEG yang terdiri dari 3072 atribut, karena terdapat 3 kondisi dan 81 subyek maka ukuran data sinyal EEG menjadi 243×3072.

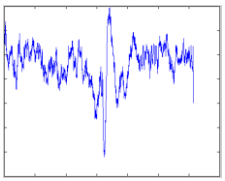

Gambar 2. Plot data sinyal EEG normal (data ke-1)

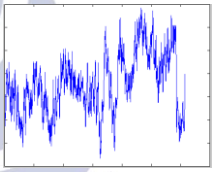

Gambar 3. Plot data sinyal EEG kelas schizophrenia (data ke-97)

Pada gambar 2 dan gambar 3 dapat dilihat perbedaan grafik sinyal EEG normal dan *schizophrenia.* Grafik sinyal data EEG normal t lebih teratur dibanding dengan sinyal data EEG *schizophrenia.*

5. PEMBAHASAN

Berikut adalah hasil eksperimen klasifikasi sinyal EEG menggunakan Algoritma SVM dengan parameter epsilon, C dan rasio seperti yang dapat dilihat pada tabel berikut :

Tabel 1. Hasil percobaan dengan algoritma SVM (epsilon = 10^{-9})

C	Rasio	Akurasi	Waktu pembuatan model (s)
1	9 : 1	**70**	1.19
	4 : 1	57.143	1.4
	7 : 3	60.274	1.14
	3 : 2	**61.856**	1.2
5	9 : 1	58.333	3.38
	4 : 1	55.102	3.02
	7 : 3	56.164	2.91
	3 : 2	60.825	4.03

UNESA Universitas Negeri Surabaya

10	9 : 1	58.333	2.94
	4 : 1	55.102	2.98
	7 : 3	56.164	3.26
	3 : 2	60.825	3.08

Tabel 2. Hasil percobaan dengan algoritma SVM (epsilon = 10^{-6})

C	Rasio (%)	Akurasi	Waktu pembuatan model (s)
1	9 : 1	62.5	0.86
	4 : 1	**61.225**	0.72
	7 : 3	50.685	0.2
	3 : 2	54.639	0.69
5	9 : 1	54.167	1.89
	4 : 1	**61.225**	0.72
	7 : 3	56.164	0.7
	3 : 2	54.639	0.71
10	9 : 1	54.167	0.76
	4 : 1	**61.225**	0.66
	7 : 3	56.164	0.72
	3 : 2	54.639	0.67

Tabel 3. Hasil percobaan dengan algoritma SVM (epsilon = 10^{-3})

C	Rasio (%)	Akurasi	Waktu pembuatan model (s)
1	9 : 1	62.5	0.71
	4 : 1	**61.225**	0.6
	7 : 3	58.904	0.67
	3 : 2	60.825	0.82
5	9 : 1	54.167	1.02
	4 : 1	**61.225**	0.97
	7 : 3	**63.014**	0.78
	3 : 2	51.546	0.75
10	9 : 1	54.167	0.74
	4 : 1	**61.225**	0.78
	7 : 3	63.013	0.83
	3 : 2	51.346	0.94

Pengklasifikasian data sinyal EEG menggunakan algoritma SVM, parameter C menyatakan *threshold*, sedangkan nilai *epsilon* menyatakan level akurasi dari fungsi aproksimasi yang dapat dapat berpengaruh terhadap penggunaan *support vector*. Berdasarkan hasil eksperimen klasifikasi data sinyal EEG dengan aloritma SVM yang dapat dilihat pada Tabel 1, Tabel 2 dan Tabel 3 menunjukan untuk rasio 9 : 1 akurasi tertinggi dicapai saat parameter *epsilon* = 10^{-9} dan C = 1 yaitu 70%, untuk akurasi rasio 4 : 1 akurasi tertinggi dicapai saat parameter *epsilon* = 10^{-6} dan *epsilon* = 10^{-3} pada setiap perubahan parameter C yaitu 61.225%, rasio 7 : 3 akurasi tertinggi dicapai saat parameter *epsilon* = 10^{-3} dan C = 5 yaitu 63.14% dan rasio 3 : 2 akurasi tertinggi dicapai saat parameter *epsilon* = 10^{-9} dan C = 1 yaitu 61.856%. *Confusion matriks* untuk hasil percobaan terbaik pada rasio 9 : 1 ditunjukan pada Tabel 4, untuk rasio 4 : 1 ditunjukan pada Tabel 5, untuk rasio 7 : 3 ditunjukan pada Tabel 6 dan untuk rasio 3 : 2 ditunjukan Tabel 7.

Tabel 4. Confusion Matrix Hasil Percobaan SVM rasio 9 : 1, C = 1 dan epsilon = 10^{-9}

Kelas	Normal	*Schizophrenia*
Normal	5	4
Schizophrenia	3	12

Tabel 5. Confusion Matrix Hasil Percobaan SVM rasio 4 : 1, C = 1 dan epsilon = 10^{-9}

Kelas	Normal	*Schizophrenia*
Normal	8	8
Schizophrenia	13	20

Tabel 6. Confusion Matrix Hasil Percobaan SVM rasio 7 : 3, C = 5 dan epsilon = 10^{-3}

Kelas	Normal	*Schizophrenia*
Normal	18	32
Schizophrenia	23	44

Tabel 7. Confusion Matrix Hasil Percobaan SVM rasio 3 : 2, C = 1 dan epsilon = 10^{-9}

Kelas	Normal	*Schizophrenia*
Normal	13	12
Schizophrenia	15	33

Tabel 8. Hasil TP Rate, FP Rate, Precision, dan Recall algoritma SVM

Rasio	Parameter		TP Rate	FP Rate	Precition	Recall	Class
	C	ε					
9 : 1	1.0	10^{-9}	0.556	0.200	0.625	0.556	Normal
			0.800	0.444	0.750	0.800	*Schizo*
			0.708	0.353	0.703	0.78	Avg
4 : 2	1.0	10^{-9}	0.500	0.394	0.381	0.500	Normal
			0.606	0.500	0.714	0.606	*Schizo*
			0.571	0.465	0.605	0.571	Avg
7 : 3	5	10^{-3}	0.520	0.313	0.464	0.520	Normal
			0.688	0.480	0.733	0.688	*Schizo*
			0.630	0.423	0.641	0.630	Avg
3 : 2	1	10^{-9}	0.667	0.414	0.520	0.667	Normal

UNESA Universitas Negeri Surabaya

			0.586	0.333	0.723	0.586	*Schizo*
			0.619	0.366	0.642	0.619	Avg

True Positive (TP) adalah banyak data kelas 1 (normal) yang terklasifikasi dengan benar pada kelas 1 (normal), *False Positive* (FP) adalah banyak data kelas -1 (*schizophrenia*) yang terklasifikasi pada kelas 1 (normal), True Negative (TN) adalah banyak data kelas -1 (*schizophrenia*) yang terklasifikasi dengan benar pada kelas -1 (*schizophrenia*), dan *False Negative* (FN) adalah banyak data kelas 1 (normal) yang terklasifikasi pada kelas -1 (normal).

TP *Rate* adalah tingkat keakuratan hasil prediksi data kelas 1, dirumuskan sebagai berikut:

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

FP *Rate* adalah tingkat kesalahan hasil prediksi data kelas 1, dirumuskan sebagai berikut:

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

Precision adalah tingkat ketepatan antara informasi yang diinginkan dengan prediksi yang dihasilkan oleh sistem, dirumuskan sebagai berikut:

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

Recall adalah tingkat keberhasilan system dalam mengklasifikasi data secara benar, *recall* memiliki formula sebagai berikut:

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

Pada Tabel 8 ditampilkan TP rate, FP rate, Precition dan Recal untuk hasil percobaan terbaik pada setiap rasio.

Tabel 9. Hasil F-Measure, MCC, ROC, dan PRC algoritma SVM

Rasio	F-Measure	MCC	ROC Area	PRC Area	Class
9 : 1	0.588	0.365	0.678	0.514	Normal
	0.744	0.365	0.678	0.725	*Schizo*
	0.704	0.365	0.678	0.646	Avg
4 : 2	0.432	0.101	0.553	0.354	Normal
	0.656	0.101	0.553	0.698	*Schizo* l
	0.583	0.101	0.553	0.586	Avg
7 : 3	0.491	0.202	0.604	0.406	Normal
	0.710	0.202	0.604	0.710	*Schizo* l
	0.635	0.202	0.604	0.606	Avg
3 : 2	0.584	0.248	0.626	0.481	Normal
	0.648	0.248	0.626	0.671	*Schizo*
	0.622	0.248	0.626	0.595	Avg

F-*Measure* adalah hitungan evaluasi pengklasifikasian dari *precision* dan *recall*, dirumuskan sebagai berikut:

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

Matthews correlation coefficient (MCC) digunakan dalam pembelajaran mesin sebagai ukuran kualitas klasifikasi biner (dua kelas) yang dalam penghitungannya menggunakan nilai TP, TN, FP, dan FN (Saito and Rehmsmeier 2015) :

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

Receiver Operating Characteristic (ROC) dibuat berdasarkan nilai *True Positive Rate* dan *False Positive Rate*. *Baseline* pada ROC berupa garis diagonal yang dilukis dari titik (0,0) ke (1,1). Jika klasifikasi mendekati titik (0,0) maka klasifiksi tersebut kurang baik sedangkan jika klasifikasi mendekati titik (1,1), klasifikasi tersebut dikatakan baik Sedangkan *Precision-Recall Curves* (PRC) digunakan untuk menyajikan hasil untuk masalah keputusan biner dalam *mechine learning* dibuat berdasarkan nilai *Precision* dan *Recall*. *Baseline* pada PRC ditentukan oleh rasio data. 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).

Nilai Akurasi dihitung menggunakan rumus:

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

Pada Tabel 9 Dapat dilihat hasil F-Measure, MCC, ROC, dan PRC untuk hasil percobaan terbaik pada setiap rasio.

Berdasarkan hasil penelitian diketahui akurasi maksimum yang diperoleh adalah 70%. Hasil akurasi tidak bias lebih dari 70% dikarenakan data sampel yang digunakan pada penelitian ini hanya 1 *channel* yang memungkinkan data dengan karakter pembeda antar dua kelas terletak pada *channel* lain selain itu dataset yang digunakan tidak seimbang dalam perbandingan jumlah data kelas *schizophrenia* dan kelas normal. Jumlah data sinyal EEG kelas *schizophrenia* sebanyak 147 sedangkan data kelas normal sebanyak 96 data. Hal ini menyebabkan hasil klasifikasi cenderung ke arah kelas *schizophrenia* sehingga terdapat banyak data sinyal EEG *schizophrenia* yang tidak terklasifikasi dengan benar. Untuk mengatasi masalah ketidakseimbangan data bisa menggunakan teknik *over-sampling* atau *over-sampling*, namun teknik tersebut tidak diterapkan pada penelitian ini karena teknik *over-sampling* memiliki kelemahan membuat model menjadi *overfitting* sedangkan teknik *down-sampling* memiliki kelemahan dapat mengakibat data yang penting sebagai pembeda

UNESA Universitas Negeri Surabaya

dua kelas menjadi diluar dari data-set. Terlebih penelitian yang dilakukan ini menggunakan data sinyal EEG yang bersifat sensitif, dengan tanpa adanya perlakuan *over-sampling* atau *under-sampling* sudah rentan terpengaruh oleh gerakan-gerakan atau adanya pikiran pada subjek saat dilakukan perekaman.

6. PENUTUP

Simpulan

Pada penelitian ini, klasifikasi *schizophrenia* berdasarkan sinyal EEG menggunakan algoritma SVM. Parameter yang digunakan adalah C dengan nilai 1, 5 dan 10 serta epsilon (ε) dengan nilai $10^{-3}, 10^{-6}$ dan 10^{-9}. akurasi tertinggi dicapai saat rasio data latih dan data uji 9:1 dengan parameter *epsilon* = 10^{-9} dan C = 1 yaitu 70%.

Saat dicapai akurasi tertinggi diperoleh nilai rata-rata F-measure 0.704 hal itu menunjukan rata-rata jaringan dapat mengklasifikasi 70.4% data pada kelas yang sesuai. Untuk nilai MCC yang diperoleh adalah 0.365, nilai ini cukup kecil yang mengindikasikan bahwa performa jaringan dalam melakukan klasifikasi belum cukup baik karena dalam melakukan pengklasifikasian jaringan masih cenderung memberikan hasil pada kelas *schizophrenia.* Untuk nilai ROC yang diperoleh adalah 0.678 hal ini mengindikasikan bahwa secara umum jaringan mengenali dan dapat mengklasifikasikan 67.8% data dengan tepat. Rata-rata nilai PRC yang diperoleh adalah 0.646 hal ini menunjukan jika dilakukan pengklasifikasin dengan data yang baru maka jaringan mampu memprediksi kelas dengan benar pada 64.6% data yang diberikan.

DAFTAR PUSTAKA

Daisy Kurniawaty, I. C. (2018). Klasifikasi Gangguan Jiwa Skizofrenia Menggunakan Algoritme Support Vector Mechine (SVM). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 1866-1873.

Ibrahim, S. W. (2016). *https://kipmi.or.id/*. Retrieved from https://kipmi.or.id/: https://kipmi.or.id/mengenal-eeg-and-aplikasinya.html

Judith M.Ford, V. A. (2013). Did I Do That? Abnormal Predictive Processes in Schizophrenia When Button Pressing to Deliver a Tone. *Schizophrenia Bulletin*, 804-812.

kaggle.com. (2017). Retrieved Desember 20, 2018, from kaggle.com: https://www.kaggle.com/broach/button-tone-sz

Moyer, E. (2017, maret 8). *CNet*. Retrieved from CNet.com: https://www.cnet.com

Risky Candra Swari, d. T. (2018, April 25). *https://hellosehat.com/*. Retrieved from https://hellosehat.com/: https://hellosehat.com/penyakit/skizofrenia/

Roy Sucholeiki, M. (2017, Oktober 6). *emedicine.medscape.com*.Retrieved Desember 24, 2018, from emedicine.medscape.com

Swari, R. C. (2018, April 25). *Hello Sehat*. Retrieved from hellosehat.com:https://hellosehat.com/penyakit/skizofrenia/

World Health Organization. (2018). *Schizophrenia.* World Health Organization.

UNESA Universitas Negeri Surabaya