

## KLASIFIKASI TINGKAT KEBINGUNGAN SISWA TERHADAP VIDEO PEMBELAJARAN MASSIVE OPEN ONLINE SOURCE (MOOC) MENGGUNAKAN METODE SUPPORT VECTOR MACHINE (SVM)

Tukhfatur Rizmah Azis

Program Studi Matematika, FMIPA, Universitas Negeri Surabaya,

email : tukhfatur.17030214056@mhs.unesa.ac.id

### Abstrak

Pembelajaran online telah dilakukan oleh beberapa dosen maupun siswa dalam menyampaikan dan menerima materi. Hal ini biasa dilakukan dengan memberikan video di platform kelas online atau mengajak bergabung dalam ruang obrolan online. MOOC atau *Massive Open Online Course* adalah salah satu platform kursus online yang telah digunakan oleh kalangan dosen, peneliti, dan siswa dengan menyuguhkan video pembelajaran kepada siswa dari dosen. Namun setelah adanya pembelajaran online terdapat perbedaan perilaku siswa ketika menerima pembelajaran online dan offline. Tidak seperti pendidikan di kelas, di mana guru dapat menilai apakah siswa dapat memahami materi melalui pertanyaan verbal atau bahasa tubuh mereka. Maka dalam hal ini penelitian akan difokuskan pada salah satu permasalahan yakni mendeteksi tingkat kebingungan pada siswa saat menonton video pembelajaran dengan menggunakan metode *Support Vector Machine* (SVM) dan data sinyal *electroencephalography* (EEG). Analisis dilakukan dengan melakukan perbandingan nilai ketepatan klasifikasi dari tiga fungsi kernel SVM yakni *linear*, *Radial Basic Function* (RBF), serta Polinomial Regresi. Berdasarkan pengolahan data yang telah diperoleh pada metode SVM *Linear* pada *pre-defined label* mendapatkan hasil akurasi mencapai 63,16% pada *user-defined label* mendapatkan hasil akurasi mencapai 63,16%. Sedangkan metode Polinomial Regresi pada *pre-defined label* mendapatkan hasil akurasi mencapai 68,42%, pada *user-defined label* mendapatkan hasil akurasi mencapai 57,89%. Serta metode RBF pada *pre-defined label* mendapatkan hasil akurasi mencapai 63,16% pada *user-defined label* mendapatkan hasil akurasi mencapai 57,89%. Hal ini menunjukkan bahwa metode SVM dapat digunakan untuk mengklasifikasikan data sinyal EEG.

**Kata Kunci:** SVM, MOOC, Sinyal *Electroencephalography*, Linear, RBF, Polinomial Regresi

### Abstract

*Online learning has been carried out by several lecturers and students in delivering and receiving material. This is usually done by giving videos on online class platforms or inviting them to join online chat rooms. MOOC or Massive Open Online Course is an online course platform that has been used by lecturers, researchers, and students by presenting learning videos to students from lecturers. However, after online learning there are differences in student behavior when receiving online and offline learning. Unlike classroom education, where teachers can judge whether students can understand the material through verbal questions or their body language. So in this case the research will focus on one of the problems, namely detecting the level of confusion in students when watching learning videos using the Support Vector Machine (SVM) method and electroencephalography (EEG) signal data. The analysis was carried out by comparing the classification accuracy values of the three SVM kernel functions, namely linear, Radial Basic Function (RBF), and Regression Polynomial. Based on data processing that has been obtained in the Linear SVM method on pre-defined labels, the accuracy results reach 63.16% on user-defined labels, the accuracy results reach 63.16%. While the Regression Polynomial method on pre-defined labels gets an accuracy of 68.42%, on user-defined labels it reaches 57.89% accuracy. And the RBF method on pre-defined labels gets an accuracy of 63.16% on a user-defined label and gets an accuracy of 57.89%. This shows that the SVM method can be used to classify EEG signal data.*

**Keywords:** SVM, MOOC, *Electroencephalography* Signal, Linear, RBF, Regression Polynomials.

### PENDAHULUAN

Saat ini pembelajaran melalui internet sudah banyak dilakukan oleh pengajar dan siswa, salah satunya MOOC (*Massive Open Online Course*). MOOC adalah kursus online yang sedang tren dikalangan peneliti, dosen, dan universitas (Brame,

2016) ditandai dengan tidak adanya persyaratan masuk formal, partisipasi gratis, konten yang disampaikan sepenuhnya secara online, proyek yang dirancang untuk mendukung ribuan siswa (Feitosa dkk, 2020).

Namun setelah adanya pembelajaran online terdapat perbedaan perilaku siswa ketika menerima pembelajaran online dan offline. Tidak seperti pendidikan di kelas, di mana guru dapat menilai apakah siswa dapat memahami materi melalui pertanyaan verbal atau bahasa tubuh mereka (misalnya, alis berkerut, garukan kepala) (Sharma dkk, 2019). Maka dalam penelitian ini akan difokuskan pada salah satu permasalahan yakni mendeteksi tingkat kebingungan pada siswa saat menonton video pembelajaran.

Sekarang MOOC mengadakan sesi interaktif dimana guru dan siswa dapat mendiskusikan beberapa hal dan juga memberikan formulir umpan balik kepada siswa untuk mendapatkan ulasan siswa. Tidak ada yang dapat menyangkal bahwa pendidikan online memberikan banyak manfaat bagi para siswa. Namun, tetap saja kurangnya ruang kelas menjadi perhatian besar. Namun, deteksi tingkat kebingungan siswa saat menonton video MOOC adalah ide kunci untuk membuat sistem pendidikan online lebih efisien (Bikram dkk, 2019).

EEG biasanya merupakan teknik diagnostik medis non-invasif, di mana elektroda dipasang di kulit kepala subjek untuk merekam aktivitas listrik otak (Teplan, 2002). Data EEG dapat memprediksi tingkat kebingungan saat menonton video MOOC guna meningkatkan kualitas dan efektivitas sistem pendidikan online (Bikram, 2019). Pada penelitian sebelumnya telah diadakan penelitian pengklasifikasian kebingungan pada siswa saat memahami video pembelajaran dari MOOC dengan metode *K-Nearest Neighbors*, *Multilayer Perceptron* (MLP) (Mampusti dkk, 2011), *Random Forest*, dan *Bagging with Decision*. Dalam penelitian klasifikasi menggunakan metode *Random Forest* diperoleh nilai akurasi sebesar 66.6% untuk *user defined label* sedangkan 61.89% untuk *pre-defined label* (Bikram dkk, 2019).

Dalam penelitian ini, data sinyal EEG kebingungan siswa saat menonton video pembelajaran dari MOOC akan dijadikan sebagai data untuk diklasifikasikan dengan metode Algoritma SVM dengan tujuan apakah algoritma SVM dapat digunakan untuk mengklasifikasi data sinyal EEG dinilai dari nilai akurasinya dengan melakukan perbandingan nilai ketepatan klasifikasi dari tiga fungsi kernel SVM yaitu linear, Radial Basic Function (RBF), serta Polinomial Regresi.

## METODE

### EEG DAN TINGKAT KEBINGUNGAN SISWA

MOOC (*Massive Open Online Source*) adalah kursus online yang dapat diskalakan, gratis, atau terjangkau yang muncul sebagai salah satu platform pendidikan jarak jauh yang tumbuh paling cepat dalam dekade terakhir (Amirhessam, 2016) yang diajarkan oleh universitas melalui internet menggunakan berbagai teknik seperti video kuliah / webcast mingguan, penilaian online, forum diskusi, dan bahkan diskusi dan bantuan obrolan video langsung sesi. MOOC telah muncul sebagai salah satu platform dengan pertumbuhan tercepat untuk pendidikan jarak jauh dalam lima tahun terakhir.

Kursus online ini memungkinkan ribuan siswa mendaftar untuk belajar dengan menyesuaikan keinginan mereka dan tanpa biaya moneter. Terlepas dari potensi yang luar biasa, MOOC memiliki tingkat atrisi yang sangat tinggi untuk menyelesaikannya (Jordan, 2014).

*Electroencephalography* (EEG) adalah metode non-invasif dan relatif murah untuk menilai fungsi neurofisiologis. EEG mengukur aktivitas listrik dari populasi neuron yang besar dan serentak kemudian diteruskan ke otak dengan elektroda yang ditempelkan di kulit kepala. Untuk mengumpulkan data EEG, elektroda ditempatkan pada kulit kepala dan wajah, dan digosok gel konduktor untuk memfasilitasi pengukuran aktivitas listrik populasi neuron (elektroda kulit kepala) dan aktivitas otot (elektroda wajah). Metode dasar untuk mempersiapkan partisipan manusia untuk pengumpulan data EEG akan berfungsi sebagai fondasi untuk dua protokol Alternatif (Gregory, 2010). Sinyal yang dihasilkan oleh EEG yakni *gamma*, *beta*, *alpha*, *tetha*, dan *delta*.

### SVM

SVM adalah teknik klasifikasi pola berbasis teknik *Machine Learning* (ML) yang paling banyak digunakan saat ini. Ini didasarkan pada teori pembelajaran statistik dan dikembangkan oleh Vapnik pada tahun 1995. Tujuan utama dari teknik ini adalah untuk memproyeksikan sampel terpisah nonlinier ke ruang dimensi lain yang lebih tinggi dengan menggunakan berbagai jenis fungsi kernel. Di tahun-tahun terakhir, metode kernel telah mendapat perhatian besar, terutama karena semakin populernya SVM (Satapathy dkk, 2019).

Fungsi kernel memiliki peran penting dalam SVM (Limaa, 2011) untuk menjembatani dari linear ke nonlinier. *Least square SVM* (LS-SVM) (Siuly, 2009) juga merupakan teknik SVM penting yang dapat diterapkan untuk tugas klasifikasi data (Ubeyli, 2010).

Setiap data latih dinyatakan oleh  $(x_i, y_i)$  dengan  $i = 1, 2, \dots, N$ , dan  $x_i = \{x_{i1}, x_{i2}, \dots, x_{iq}\}^T$  merupakan atribut set untuk data ke- $i$ . Untuk  $y_i \in \{-1, +1\}$  menyatakan label kelas. *Hyperplane* klasifikasi linear SVM seperti pada gambar diatas dinotasikan sebagai

$$w \cdot x_i + b = 0 \tag{1}$$

$w$  dan  $b$  adalah parameter model  $w \cdot x_i$  merupakan inner-product antara  $w$  dan  $x_i$ .

*Radial Basis Functions* (RBF) telah populer selama beberapa waktu dalam pendekatan dimensi tinggi (Buhmann, 2003) dan semakin banyak digunakan dalam solusi numerik persamaan diferensial parsial. Diketahui satu set pusat  $\xi_0, \dots, \xi_N$  di  $R^d$ , sebuah pendekatan RBF didapatkan formula

$$F(x) = \sum_{k=0}^N \lambda_k \phi(\|x - \xi_k\|) \tag{2}$$

di mana menunjukkan jarak Euclidean antara dua titik dan  $\phi(r)$  adalah fungsi yang didefinisikan untuk  $r \geq 0$ . Koefisien  $\lambda_0, \dots, \lambda_N$  dapat dipilih dengan interpolasi atau kondisi lain pada satu set node yang biasanya bertepatan dengan pusat. Pilihan umum untuk  $\phi$  terbagi dalam dua kategori utama yakni (1) *infinitely smooth* dan berisi parameter bebas, seperti multiquadrat ( $\phi(r) = \sqrt{r^2 + c^2}$ ) dan Gaussians ( $\phi(r) = e^{-(r/c)}$ ); (2) *piecewise smooth* dan parameter bebas, seperti kubik ( $\phi(r) = r^3$ ) dan *thin plate splines* ( $\phi(r) = r^2 \ln r$ ).

Polinomial regresi merupakan model regresi linier yang dibentuk dengan menjumlahkan pengaruh masing-masing variabel prediktor (X) yang dinaikkan terhadap kenaikan k-order. Secara umum

model regresi polinomial dituliskan pada persamaan:

$$(X_1, X_2) = (a + X_1^T X_2)^b \tag{3}$$

Klasifikasi data menggunakan SVM terbagi menjadi beberapa tahapan yakni (1) Memvisualisasikan data dengan data yang ada dalam garis koordinat; (2) Meminimalkan nilai margin karena ada dua fitur ( $x_1$  dan  $x_2$ ), maka  $w$  juga akan memiliki 2 fitur ( $w_1$  dan  $w_2$ ).

Dalam mengukur kinerja klasifikasi dengan menggunakan perbandingan nilai sebenarnya dan

nilai prediksi. *Confusion Matrix* merupakan pengukuran performa untuk masalah klasifikasi machine learning yang outputnya bisa berupa dua kelas atau lebih. *Confusion Matrix* adalah tabel dengan empat campuran berbeda antara nilai prediksi dan nilai aktual. Terdapat empat sebutan yang merepresentasikan hasil proses klasifikasi pada confusi matrix, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN).

Tabel 2. *Confussion Matrix*

		Actual Values	
		True (+)	False (-)
Predicted Values	True (+)	TP	FP
	False (-)	FN	TN

Akurasi merupakan persentase dari total sentimen yang benar dikenali. Perhitungan akurasi dilakukan dengan membagi jumlah data yang benar dengan total data dan data uji. TP (*True Positive*) adalah jumlah data di kelas *not confused* yang berhasil terklasifikasi di kelas *not confused*, TN (*True Negative*) adalah jumlah data di kelas *confused* yang terklasifikasi sebagai *confused*, FP (*False Positive*) adalah jumlah data di kelas *not confused* yang terklasifikasi sebagai *confused*, FN (*False Negative*) adalah jumlah data di kelas *confused* yang diklasifikasikan sebagai data di kelas *not confused*. Untuk perhitungan nilai akurasi maka akan dilakukan uji coba dengan menggunakan persamaan.

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \tag{4}$$

Untuk pengukuran performa klasifikasi metode yang digunakan tidak hanya menghitung akurasi yakni menghitung presisi serta recall. Presisi merupakan perbandingan jumlah informasi signifikan yang ditemui terhadap jumlah informasi yang ditemui. *Recall* ialah perbandingan jumlah modul relevan yang ditemui terhadap jumlah modul yang relevan. Nilai Precision dan recall dapat diketahui dalam persamaan :

$$Presisi = \frac{TP}{TP+FP} \tag{5}$$

$$Recall = \frac{TP}{TP+FN} \tag{6}$$

**CROSS VALIDATION**

*Cross Validation* (CV) adalah teknik standar untuk menyesuaikan hyperparameter model prediktif. Di CV K-fold, data S yang tersedia dipartisi menjadi K subset  $S_1, \dots, S_k$ . Setiap titik data di S secara acak ditetapkan ke salah satu himpunan bagian sehingga

ukurannya hampir sama (contoh,  $||S|/K| \leq |S_i| \leq ||S/K||$ ). Selanjutnya, kita mendefinisikan  $S_{\setminus i} = \cup_{j=1, \dots, K \wedge j \neq i} S_j$  sebagai gabungan dari semua titik data kecuali yang ada di  $S_i$ . Untuk setiap  $i = 1, \dots, K$ , model individu dibangun dengan menerapkan algoritme ke data pelatihan  $S_{\setminus i}$ . Model ini kemudian dievaluasi dengan menggunakan fungsi biaya menggunakan data uji di  $S_i$ . Rata-rata hasil K dari evaluasi model disebut kinerja validasi silang (tes) atau kesalahan validasi silang (tes) dan digunakan sebagai prediktor kinerja algoritma ketika diterapkan ke S. Nilai tipikal untuk K adalah 5 dan 10 (Hastie dkk, 2008).

Untuk memilih C dan  $\gamma$  menggunakan CV *K-fold*, pertama-tama kami membagi data yang tersedia menjadi subset K. Kemudian kami menghitung kesalahan CV menggunakan kesalahan pemisahan ini untuk pengklasifikasi SVM menggunakan nilai berbeda untuk C dan  $\gamma$ . Terakhir, kami memilih C dan  $\gamma$  dengan kesalahan CV terendah dan menggunakannya untuk melatih SVM pada kumpulan data lengkap S.

## HASIL DAN PEMBAHASAN

### DATASET

Dalam penelitian ini terdiri dari 2 tahapan yakni tahap klasifikasi dan tahap evaluasi klasifikasi. Pada penelitian ini data diperoleh dari website Kaggle (<http://www.kaggle.com/wanghaohan/confused-eeg>) yang dimana terdapat 10 video pembelajaran yang dijadikan objek kebingungan pada siswa. Dalam 10 video tersebut ada beberapa model pembelajaran yakni : rekaman dosen menjelaskan materi di papan tulis, pemateri menjelaskan materi melalui rekaman layar. Materi yang diberikan adalah aljabar dasar dan geometri. Serta ada materi yang biasanya tidak diberikan umum kepada mahasiswa yakni video mengenai quantum leap dan stem cells research. Dalam dataset tersebut terdapat 15 atribut namun hanya digunakan 10 atribut yang digunakan yakni : *delta*, *tetha*, *gamma1*, *gamma2*, *alfa1*, *alfa2*, *beta1*, *beta 2*, *pre-defined label*, dan *user defined label*. Lima atribut lainnya tidak digunakan karena bukan termasuk sinyal EEG.

*Pre-defined label* adalah label pada video berdasarkan tingkat kebingungan yang diberikan oleh guru. *User defined label* adalah label pada video berdasarkan tingkat kebingungan yang dialami oleh siswa. Pada *pre-defined* dan *user pre-defined label* terdapat nilai 0

dimana termasuk kelas *not confused* dan nilai 1 dimana termasuk kelas *confused*. Tujuan diberikan label kepada siswa agar guru dapat merespon kebingungan yang dialami oleh siswa.

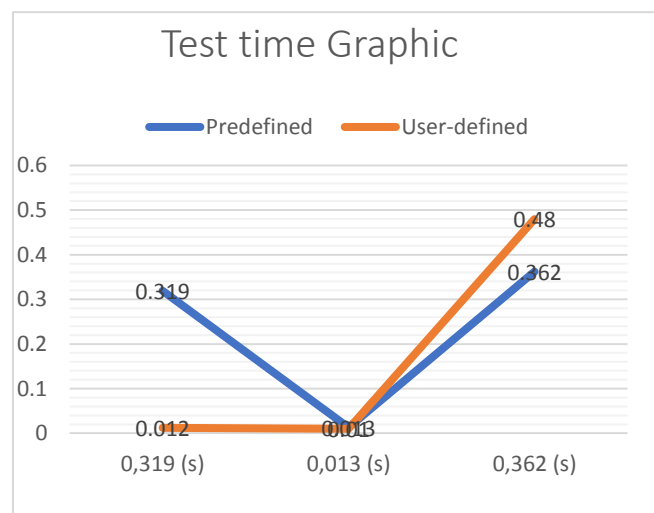
### Hasil dan Pembahasan

Dalam penelitian ini telah dilakukan proses klasifikasi data kebingungan siswa saat menonton video pembelajaran dari MOOC menggunakan metode *Support Vector Machine*(SVM). Data yang diambil yakni 1257 baris data dan 9 atribut untuk menjadi data latih pada masing masing uji coba *predefined label* dan *userdefined label* sedangkan untuk data *testing* menggunakan 90 baris data dan 8 atribut.

Dalam proses klasifikasi, data latih diolah sehingga memperoleh model klasifikasi yang akan digunakan untuk menguji klasifikasi dengan data testing. Model hasil latih berisi parameter-parameter yang optimal dari hasil latih. Pada tabel 3 memperlihatkan perbandingan tingkat akurasi pengklasifikasian data menggunakan SVM (kernel='linear'), SVM (kernel='poly'), serta SVM (kernel='rbf').

Tabel 3. Hasil Klasifikasi SVM

Label	Klasifikasi	Akurasi (%)	Test Time (s)	Recall	Presisi
Userdefined label	Linear	63,16	0,012	0,65	0,58
	Polinomial	57,89	0,01	0,50	0,29
	RBF	57,89	0,48	0,50	0,29
Predefined label	Linear	63,16	0,319	0,42	0,5
	Polinomial	68,42	0,013	0,50	0,47
	RBF	63,16	0,362	0,53	0,57

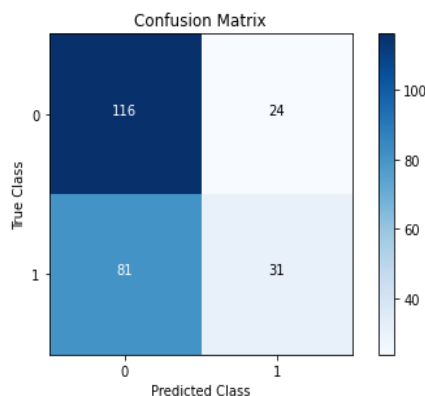


Gambar 3. Grafik Test time Graphic


Tabel 3 menunjukkan bahwa pada userdefined label menggunakan (1) klasifikasi SVM (kernel='linear') mendapatkan hasil akurasi mencapai 63,16%, recall mencapai 0,65, dan presisi mencapai 0,58 dengan waktu tes 0,012 detik; (2) klasifikasi SVM (kernel='poly') mendapatkan hasil akurasi 57,89%, recall 0,50, dan presisi mencapai 0,29 dengan waktu tes 0,01 detik; (3) klasifikasi SVM (kernel='rbf') mendapatkan hasil akurasi 57,89%, recall 0,50, dan presisi mencapai 0,29 dengan waktu tes 0,48 detik. Sedangkan pada predefined label menggunakan (1) klasifikasi SVM (kernel='linear') mendapatkan hasil akurasi mencapai 63,16%, recall mencapai 0,42, dan presisi mencapai 0,5 dengan waktu tes 0,319; (2) klasifikasi SVM (kernel='poly') mendapatkan hasil akurasi 68,42%, recall 0,5, dan presisi mencapai 0,47 dengan waktu tes 0,013 detik; (3) klasifikasi SVM (kernel='rbf') mendapatkan hasil akurasi 63,16%, recall 0,53, dan presisi mencapai 0,57 dengan waktu tes 0,362 detik.

Gambar 3 adalah test time graphic. Test time tersebut menunjukkan performa waktu tes yang dibutuhkan untuk mengklasifikasikan data predefined dan user defined dalam metode SVM (kernel='linear'), SVM (kernel='poly'), dan SVM (kernel='rbf') dan dinyatakan dalam second (s).

Dari data tersebut mendapatkan nilai iConfusion Matrix seperti pada gambar :



Gambar 4. Confusion Matrix Userdefined Label



Gambar 5. Confusion Matrix Predefined Label

Pada gambar 4 menunjukkan bahwa User-defined Label mendapatkan nilai true positive 31, true negative senilai 116, false positive 24, dan false negative 81. sedangkan pre-defined label pada gambar 5 mendapatkan dengan nilai true positive 3, true negative senilai 9, false positive 4, dan false negative bernilai 3.

Pada label pre-defined dan user-defined mewakili 11 data EEG secara umum karena label diberikan oleh siswa sebelum menonton MOOC. Dari hasil uji coba diatas akurasi terbaik mencapai 63,16% pada user defined SVM (kernel='linear') dan 68,42% pada predefined label dalam uji coba menggunakan metode SVM (kernel='poly') dan hasil tersebut lebih baik dibandingkan hasil uji coba penelitian ke beberapa metode kernel SVM yang lain dengan dataset yang sama.

Pada penelitian sebelumnya oleh Bikram dkk dengan dataset yang sama dan menggunakan metode yang sama namun hasil yang diperoleh akurasinya pada predefined label mencapai 52,52% dan user defined label mencapai 53,02% menggunakan metode SVM (kernel='linear') (Bikram dkk, 2019)

Pada penelitian lain pada dataset yang sama oleh Hanief, 2021, dengan menggunakan metode KNearest Neighbor (KNN) mendapatkan hasil akurasi yang cukup tinggi yakni 73,33% pada user-defined dan pada user predefined label mencapai 63,33% (Hanief, 2021). Namun pada penelitian sebelumnya yang menggunakan metode KNN pada user defined label memerlukan waktu tes 0,13 detik dan pada predefined label memerlukan 0,42 detik untuk waktu tes sedangkan pada penelitian ini waktu tes paling cepat pada user predefined memerlukan waktu 0,1 detik dan pada predefined

label 0,13 detik. Hal ini menunjukkan bahwa metode algoritma SVM dapat digunakan untuk mengklasifikasi suatu dataset dengan waktu tes yang cepat dan akurasi yang sangat baik.

## PENUTUP

## SIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan mengenai pengklasifikasian tingkat kebingungan siswa terhadap video pembelajaran MOOC menggunakan metode SVM ini telah melaksanakan uji kelayakan. Analisis data yang diperoleh pada pengklasifikasian dataset telah mendapatkan hasil akurasi yang baik. Dari hasil uji coba diatas akurasi terbaik mencapai 63,16% pada *user defined* SVM (kernel='linear') dan 68,42% pada *predefined label* dalam uji coba menggunakan metode SVM (kernel='poly') dan hasil tersebut lebih baik dibandingkan hasil uji coba penelitian ke beberapa metode kernel SVM yang lain dan dari hasil tersebut maka dapat disimpulkan bahwa metode SVM untuk klasifikasi tingkat kebingungan siswa terhadap video pembelajaran MOOC dapat digunakan untuk pengklasifikasian dataset dengan akurasi yang sangat baik.

## DAFTAR PUSTAKA

- Brame, C. J. (2016). Effective Educational Videos: Principles and Guidelines for Maximizing Student Learning from Video Content. *CBE Life Sciences Education*, 15(4), es6. <https://doi.org/10.1187/cbe.16-03-0125>
- M. D. Buhmann. (2003). Radial Basis Functions. Cambridge University Press. Cambridge. United Kingdom.
- Kumar, Bikram, Gupta, Deepak, Goswami, Rajat Subhra. (2019). Classification of Student's Confusion Level in E-Learning using Machine Learning. *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*. <https://doi.org/10.35940/ijitee.B1092.1292519>
- Feitosa de Moura, Valéria, Alexandre de Souza, Cesar, Viana, Adriana Backx Noronha. (2020). The use of Massive Open Online Courses (MOOCs) in blended learning courses and the functional value perceived by students. *Computers & Education*. Vol. 161. <https://doi.org/10.1016/j.compedu.2020.104077>.
- Gregory A. Light Lisa E. Williams Falk Minow Joyce Sprock Anthony Rissling Richard Sharp Neal R. Swerdlow David L. Braff. (2010). Electroencephalography (EEG) and Event Related Potentials (ERPs) with Human Participants. *Current Protocols in Neuroscience*. <https://doi.org/10.1002/0471142301.ns0625s52>
- Hastie, Trevor, Robert Tibshirani, dan Jerome Friedman. (2008). *The Elements of Statistical Learning*, 2nd Edition. Springer.
- Jamielatuththooah, Hanief. (2021). Klasifikasi Video Pembelajaran Daring yang Membingungkan Siswa dengan Algoritma K-Star Nearest Neighbor. *MATHunesa* Vol. 9 No. 1.
- Jordan, K. (2014). Initial Trends in Enrolment and Completion of Massive Open Online Courses. *The International Review of Research in Open and Distance Learning*, 15(1), 133-160.
- Lima CAM, Coelho ALV, Eisenkraft M. (2010). Tackling EEG signal classification with least squares support vector machines: a sensitivity analysis study. *Comput Biol Med*. 40(8):705-14
- Lima CAM, Coelhob ALV. (2011). Kernel machines for epilepsy diagnosis via EEG signal classification: a comparative study. *Artif Intell Med*. 53(2):83-95.
- E. Mampusti, J. Quinto, G. Teng, M. Suarez, and R. Trogo. (2011). Measuring Academic Affective States of Students via Brainwave Signals. *Proc. International Conference on Knowledge and System Engineering (KSE)*. pp. 226-231.
- Sharma, T. C., & Jain, M. (2013). WEKA Approach for Comparative Study of Classification Algorithm. (*IJARCCCE*) *International Journal of Advanced Research in Computer and Communication Engineering*, 2(4), 1925-1931. [www.ijarccce.com](http://www.ijarccce.com)
- Siuly YL, Wen P. (2009). Classification of EEG signals using sampling techniques and least square support vector machines. *Rough Sets Knowl Technol*. 5589:375-82.
- Teplan, M. (2002). Fundamentals of EEG Measurement. *IEEE Measurement Science Review* vol. 2.
- T. A. Driscoll and B. Fornberg. (2002). Interpolation in the limit of increasingly flat radial basis functions. *Comput. Math. Appl.* 43. pp. 413-422.

- Ubeyli ED. (2010). Least squares support vector machine employing model-based methods  $\epsilon$  coefficients for analysis of EEG signals. *Expert Syst Appl.* 37(1):233-9.
- W. R. Madych and S. A. Nelson. (1992). Bounds on multivariate polynomials and exponential error estimates for multiquadric interpolation. *J. Approx. Theory.* 70. pp. 94-114.