

Penerapan *Particle Swarm Optimization* (PSO) dalam Pemilihan Parameter Secara Otomatis pada *Support Vector Machine* (SVM) untuk Prediksi Kelulusan Mahasiswa Politeknik Amamapare Timika

Sepriadi Bumbungan^{1*}, Kusrini², Kusnawi³

^{1,2,3}Magister Teknik Informatika, Universitas Amikom, Jl. Ring Road Utara, Ngringin, Condongcatur, Kec. Depok, Kabupaten Sleman, Daerah Istimewa Yogyakarta 55281

*Corresponding Author

E-mail Address: sepriadibumbungan@students.amikom.ac.id

ABSTRAK

Ketepatan waktu kelulusan mahasiswa, memiliki pengaruh terhadap kualitas Perguruan Tinggi karena merupakan salah satu indikator penilaian dalam proses akreditasi Perguruan Tinggi, sehingga memprediksi kelulusan mahasiswa dianggap penting untuk dilakukan. Prediksi kelulusan dapat dilakukan dengan menggunakan teknik data mining. Salah satunya dengan Support Vector Machine (SVM) yang memiliki performa yang baik dalam melakukan klasifikasi, karena dapat menyelesaikan masalah overfitting, data training yang sedikit, dan lambatnya konvergensi. Namun, Support Vector Machine (SVM) masih memiliki kekurangan, dalam hal komputasi data dengan jumlah yang besar dan dalam pemilihan parameter secara optimal. Untuk hal itu, diperlukan algoritma Particle Swarm Optimization (PSO) dalam pemilihan parameter yang sesuai pada metode Support Vector Machine (SVM). Eksperimen pada metode Support Vector Machine (SVM) dan Particle Swarm Optimization (PSO) dilakukan dengan optimasi parameter Gamma, C, dan Epsilon. Software yang digunakan untuk mendapatkan hasil eksperimen yaitu RapidMiner 9.10. Hasil eksperimen dengan menggunakan algoritma Support Vector Machine (SVM) menghasilkan nilai accuracy, recall, precision, dan F1 score masing-masing dengan nilai 93,33%, 91,04%, 98,39%, dan 94,57%. Sementara itu, Optimasi algoritma Support Vector Machine (SVM) dengan menggunakan Particle Swarm Optimization (PSO) menghasilkan nilai accuracy, recall, precision, dan F1 score masing-masing dengan nilai 98,02%, 98,55%, 98,08%, dan 98,31%. Berdasarkan hasil eksperimen yang telah dilakukan, dinyatakan terbukti bahwa penerapan algoritma Particle Swarm Optimization (PSO) dapat meningkatkan kinerja dari algoritma Support Vector Machine (SVM).

Kata Kunci: Kelulusan Mahasiswa, Data Mining, Klasifikasi, *Support Vector Machine*, *Particle Swarm Optimization*.

ABSTRACT

The accuracy of student graduation time has an impact on the quality of higher education institutions as it is one of the assessment indicators in the accreditation process. Therefore, predicting student graduation is considered important. Graduation prediction can be done using data mining techniques, such as Support Vector Machine (SVM), which has good performance in classification because it can solve overfitting problems, handle small training data, and slow convergence. However, Support Vector Machine (SVM) still has limitations in computing data with large amounts and in selecting parameters optimally. For this reason, the Particle Swarm Optimization (PSO) algorithm is needed in selecting suitable parameters in the Support Vector Machine (SVM) method. Experiments on the Support Vector Machine (SVM) and Particle Swarm Optimization (PSO) methods were conducted by optimizing the Gamma, C, and Epsilon parameters. The software used to obtain experimental results was RapidMiner 9.10. The results of the experiments using the Support Vector Machine (SVM) algorithm produced accuracy, recall, precision, and F1 score values of 93.33%, 91.04%, 98.39%, and 94.57%, respectively. Meanwhile, optimizing the Support Vector Machine (SVM) algorithm using Particle Swarm Optimization (PSO) produced accuracy, recall, precision, and F1 score values of 98.02%, 98.55%, 98.08%, and 98.31%, respectively. Based on the experimental results, it is proven that the application of the Particle Swarm Optimization (PSO) algorithm can improve the performance of the Support Vector Machine (SVM) algorithm.

Keywords: Student Graduation, Data Mining, Classification, Support Vector Machine, Particle Swarm Optimization.

PENDAHULUAN

Kelulusan mahasiswa memiliki pengaruh terhadap kualitas Perguruan Tinggi karena merupakan salah satu indikator penilaian dalam proses akreditasi Perguruan Tinggi yang tertuang dalam Peraturan BAN-PT No. 3 Tahun 2019.

Jumlah data lulusan mahasiswa pada Perguruan Tinggi dapat diolah dan dijadikan rujukan dalam proses pengambilan keputusan, baik bagi pihak Perguruan Tinggi untuk peningkatan kualitas lulusan, maupun bagi mahasiswa untuk melanjutkan studi ke jenjang berikutnya. Untuk melakukan pengolahan data, dibutuhkan teknik data mining atau metode *machine learning* untuk membentuk dan menemukan pola dan hubungan dari data dalam jumlah yang besar.

Ada beberapa metode *machine learning* yang dapat digunakan untuk melakukan prediksi dan klasifikasi, contohnya *Random Forest*, *Naive Bayes Classifier*, *Support Vector Machine* (SVM), *Decision Tree*, dan lain-lain (Arsi et al., 2021). Dari beberapa metode tersebut, *Support Vector Machine* (SVM) yang memiliki performa yang baik dalam melakukan prediksi, karena dapat menyelesaikan masalah *overfitting*, data training yang sedikit, dan lambatnya konvergensi.

Support Vector Machine (SVM) adalah metode untuk menganalisis data dan mengenali pola yang dapat digunakan untuk pengklasifikasian. Dalam pemakaian metode ini, harus menggunakan pelabelan. Pelabelan adalah kalimat positif atau kelas negatif (Basari et al., 2013). Model *Support Vector Machine* (SVM) dalam proses training, mencoba untuk memilih batas keputusan dengan memaksimalkan jarak minimum ke masing-masing kategori.

Dalam praktiknya, teknik pemilihan itu akan membuat keputusan yang lebih baik. Pemilihan batas dilakukan berdasarkan titik-titik yang disebut support vector (Joloudari et al., 2019). Namun, *Support Vector Machine* (SVM) masih memiliki kekurangan, yaitu dalam hal komputasi data dengan jumlah yang besar (Wang & Zhao, 2020) dan dalam

pemilihan parameter secara optimal (Ariyati et al., 2018).

Pada tahun 2019, Riyanto melakukan penelitian "Prediksi kelulusan mahasiswa dengan membandingkan ketiga model *Neural Network* (NN), *Support Vector Machine* (SVM), dan *Decision Tree* (DT)", yang menghasilkan akurasi tertinggi model *Support Vector Machine* (SVM) 85.18% (Riyanto et al., 2019). *Support Vector Machine* (SVM) dengan model *supervised learning* memiliki keunggulan dalam mengklasifikasikan suatu dataset sebagai titik dalam ruang vektor. Titik data baru di dalam ruang vektor dipetakan ke dalam ruang yang sama untuk diprediksi (Sugimoto et al., 2013). *Support Vector Machine* (SVM) dengan kemampuan generalisasi yang berdimensi tinggi untuk masalah nonlinear (Ren, 2012) dapat membuat pengklasifikasi data menjadi optimal (Xiang et al., 2013).

Pemilihan parameter sering digunakan untuk menemukan parameter yang tidak relevan, dan tidak optimal sehingga parameter tersebut dapat dihilangkan karena dapat mempengaruhi penurunan akurasi (Ridwansyah & Purwaningsih, 2018).

Particle Swarm Optimization (PSO), salah satunya, merupakan metode yang digunakan untuk menyelesaikan masalah optimasi yang memungkinkan untuk diterapkan pada berbagai jenis masalah optimasi.

Model *Particle Swarm Optimization* (PSO) adalah model pencarian yang didasarkan pada perilaku kawanan burung. Prinsip kerja dari PSO berdasarkan pada momen nilai tertentu, di mana setiap partikel menyesuaikan menurut tempat terbaiknya, pada ruang pencarian. Juga, setiap partikel mencakup jumlah keseimbangan yang diperoleh dengan menilai kinerja keseimbangan pada posisi partikel (Joloudari et al., 2019).

Particle Swarm Optimization (PSO) mensimulasikan perilaku kawanan burung, terbangnya kawanan burung dapat disimulasikan dengan akurasi, dengan menjaga jarak target antara setiap burung dan kawanan terdekatnya. Jarak ini mungkin tergantung pada ukuran dan perilaku yang

diinginkan. *Particle Swarm Optimization* (PSO) melakukan pembelajaran dan menggunakannya untuk memecahkan masalah optimasi.

Oleh karena itu, dalam *Particle Swarm Optimization* (PSO), setiap solusi tunggal atau seekor burung pada ruang pencarian yang dinamakan dengan partikel, dan setiap partikel memiliki *fitness value* yang dievaluasi oleh fungsi tujuan yang akan dioptimalkan, dan memiliki kecepatan yang mengarahkan terbangnya partikel (A. et al., 2015).

METODE PENELITIAN

1. Jenis Penelitian

Jenis penelitian yang akan dilakukan oleh Jenis penelitian yang akan dilakukan oleh peneliti, yaitu penelitian eksperimen yang berhubungan dengan pemilihan parameter menggunakan *Particle Swarm Optimization* (PSO) pada algoritma *Support Vector Machine* (SVM). Output dari penelitian ini yaitu berupa data statistik, angka, dan tingkat akurasi.

2. Sifat Penelitian

Sifat pada penelitian ini, yaitu penelitian deskriptif. Peneliti nantinya menerapkan beberapa teknik untuk mendapatkan akurasi yang terbaik, terhadap dataset serta model algoritma *Support Vector Machine* (SVM) yang akan diuji serta menghitung validitas nilainya menggunakan *Cross Validation*.

3. Pendekatan Penelitian

Pada penelitian ini, peneliti menggunakan pendekatan penelitian kuantitatif dengan studi eksperimen, yaitu peneliti melakukan eksperimen terhadap dataset yang telah ada untuk kemudian diuji menggunakan algoritma *Support Vector Machine* (SVM) dengan pemilihan otomatis menggunakan *Particle Swarm Optimization* (PSO) yang tujuannya untuk meningkatkan hasil akurasi. Selanjutnya, dokumentasi atas hasil evaluasi dijabarkan dalam bentuk statistik, tabel, serta kesimpulan.

4. Metode Pengumpulan Data

Metode pengumpulan data yang dilakukan peneliti, yaitu dengan melakukan studi literatur dan dokumen. Data yang digunakan dalam penelitian ini adalah data primer yang diperoleh dari lembaga pendidikan Politeknik

Amamapare Timika. Dataset yang diuji adalah dataset privat, sesuai dengan kriteria pemetaan masalah atau sesuai dengan atribut yang nantinya digunakan dalam penelitian.

Dataset yang dikumpulkan adalah dataset yang telah melalui proses preprocessing berupa data mahasiswa 4 tahun ajaran mulai dari tahun ajaran 2016/2017 sampai dengan 2020/2021 sebanyak 353 mahasiswa yang terdiri atas atribut NIM, prodi, jenis kelamin, indeks prestasi semester (IPK 1-5), dan status kelulusan tepat waktu "Ya" atau "Tidak".

5. Metode Analisis Data

Metode analisis data yang digunakan peneliti, yaitu analisis deskriptif kuantitatif untuk melihat dan mengetahui performa data pada masa lalu, agar dapat diambil kesimpulan dari hal tersebut.

Metode analisis data jenis ini diaplikasikan pada data dengan volume besar yang pada akhirnya akan menghasilkan output sebagai bahan pengambilan keputusan. Oleh karena itu, untuk mendapatkan data yang berkualitas, digunakan beberapa teknik pengolahan data sebagai berikut:

a. Data *validation*

Digunakan untuk mengidentifikasi dan menghapus data yang ganjil (*outlier/noise*), data yang tidak konsisten, dan data yang tidak lengkap (*missing value*).

b. Data *integration and transformation*

Digunakan untuk meningkatkan akurasi dan efisiensi algoritma. Data yang digunakan dalam penelitian ini adalah data yang berlabel. Data ditransformasikan ke dalam software *RapidMiner*.

c. Data *size reduction and discretization*

Digunakan untuk memperoleh dataset dengan jumlah attribute dan record yang lebih sedikit, tetapi bersifat informatif.

Metode yang diusulkan merupakan metode *Support Vector Machine* (SVM) berbasis *Particle Swarm Optimization* (PSO) untuk pemilihan parameter. Dengan mengolah data yang sudah bersih dari data noise dan data yang tidak lengkap yang di uji menggunakan metode *Support Vector Machine* (SVM) dengan seleksi subset fitur.


Setelah menyeleksi subset fitur, dilakukan uji validitas dengan 10 *Cross-Validation*

dengan model *Support Vector Machine* (SVM). Setelah dilakukan training dan test dataset dengan model *Support Vector Machine* (SVM), kemudian divalidasi menggunakan operator *Cross Validation*, dengan penambahan parameter *Gamma*, *C*, dan *Epsilon*.

Selanjutnya, proses optimasi parameter dilakukan dengan menerapkan metode *Particle Swarm Optimization* (PSO). Pada proses ini, *Particle Swarm Optimization* (PSO) akan mengoptimasi parameter *Gamma*, *C*, dan *Epsilon* dan melakukan pembobotan 8 (delapan) atribut untuk mendukung proses klasifikasi data. Model *Support Vector Machine* (SVM) berbasis *Particle Swarm Optimization* (PSO) akan dievaluasi menggunakan *confusion matrix*, yaitu *Accuracy*, *Recall*, *Precision*, dan *F1 Score*.


6. Alur Penelitian

Pada Alur penelitian ini berisi diagram alur langkah penelitian secara lengkap dan terinci, yaitu algoritma yang digunakan, rute, pemodelan, desain, yang terkait dengan masalah, atau aspek dari perancangan sistem.



Gambar 2.1 Alur Proses Data

7. Data Mining



Data mining adalah proses analisis data dari berbagai sudut pandang, kemudian dirangkum menjadi informasi berguna. Hal ini memungkinkan pengguna untuk menganalisis data dari berbagai dimensi, mengkategorikan, dan merangkum hubungan yang diidentifikasi (Kasbe & Pippal, 2018).


Informasi yang paling berhubungan sebagai hasil dari data mining adalah mendapatkan hubungan antara berbagai objek. Saat ini, banyak perusahaan yang menggunakan teknik data mining dalam membantu dan menopang aktivitas perusahaan (Bhise & Kale, 2017).

Gambar 2.2 Tahapan proses Data Mining

8. Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah salah satu metode pengklasifikasian. *Support Vector Machine* (SVM) menggunakan fungsi kernel untuk memetakan data sampel berdimensi rendah dari ruang nonlinier asli ke ruang fitur berdimensi tinggi dan membangun hyperplane klasifikasi optimal pada ruang pencarian (Zhang et al., 2015).

Tingkat akurasi pada model yang akan dihasilkan oleh proses peralihan dengan *Support Vector Machine* (SVM), sangat bergantung pada fungsi kernel serta parameter yang digunakan (Sugara & Subekti, 2019).




Gambar 2.3 Hyperplane Support Vector Machine (SVM)

9. Particle Swarm Optimization (PSO)

Algoritma *Particle Swarm Optimization* (PSO), pertama kali diusulkan oleh Eberhart dan Kennedy pada tahun 1995, adalah algoritma optimasi yang terinspirasi oleh perilaku sosial burung dan digunakan untuk menyelesaikan semua jenis masalah optimasi. Kecepatan partikel menentukan

arah dan jarak pergerakan partikel, sedangkan kecepatan partikel diatur secara dinamis dengan pergerakan partikelnya sendiri dan partikel lain sehingga dapat mewujudkan optimasi individu dalam ruang solusi optimasi. Secara umum, PSO dikodekan dengan enkripsi nilai nyata yang sederhana dan parameter penyesuaian yang lebih sedikit, yang mampu menunjukkan kinerja yang baik dalam menyelesaikan masalah optimasi *multi-objective constrained nonlinier* (Han & Bian, 2018).

Dalam PSO-SVM, *Particle Swarm Optimization* (PSO) digunakan untuk mencari solusi optimal dari *Support Vector Machine* (SVM) dengan menggunakan meminimalkan tingkat kesalahan klasifikasi sebagai kriteria untuk menentukan parameter. Dengan adanya pergerakan partikel dalam ruang masalah, maka akan diperoleh solusi optimal dengan meminimalkan nilai kesalahan prediksi. (Zhang et al., 2015).




Gambar 2.4 Skema *Particle Swarm Optimization* (PSO)

10. K-Fold Cross Validation

K-Fold Cross Validation merupakan salah satu metode yang dapat digunakan untuk mengevaluasi model prediksi. Metode ini membagi data ke dalam k subset dan melakukan pengulangan sebanyak k kali untuk pembelajaran dan pengujian. Metode ini menggunakan satu subset untuk dijadikan sebagai data uji dan subset lainnya digunakan sebagai data pembelajaran, pada setiap pengulangan yang dilakukan (Sang et al., 2021).

Dalam mengembangkan model melalui pelatihan data, model kemudian dievaluasi

stabilitas dan kinerjanya menggunakan kinerja akurasi. Model dengan akurasi tertinggi akan diterapkan untuk pengujian menggunakan dataset pengujian (Asrol et al., 2021).



Gambar 2.5 *Cross Validation* dalam Software *RapidMiner*

11. Confusion Matrix

Performa pada suatu system klasifikasi direpresentasikan oleh seberapa baik sistem dalam mengklasifikasikan data. Evaluasi performa dimaksudkan untuk menguji model klasifikasi untuk mengetahui kinerja sistem. Salah satu metode untuk mengukur evaluasi *performance* adalah *Confusion Matrix*. Confusion matrix adalah alat ukur berbentuk matrix yang digunakan untuk mendapatkan jumlah ketepatan klasifikasi terhadap kelas dengan algoritma yang dipakai (Sang et al., 2021).

Evaluasi performa dapat diukur dengan *accuracy* yang dapat diartikan sebagai tingkat kedekatan antara nilai prediksi dengan nilai aktual. *Recall* berfungsi untuk mengukur proporsi positif aktual yang benar diidentifikasi. *Precision* untuk menunjukkan tingkat ketepatan atau ketelitian dalam pengklasifikasian. *F1 Score* dapat diartikan sebagai alternatif dari metode akurasi yang diperoleh dari hasil perhitungan antara presisi dan recall (Sang et al., 2021).

12. RapidMiner

RapidMiner adalah media interaktif pengguna untuk melakukan pembelajaran mesin dan proses penambangan data. *RapidMiner* bersifat *open-source* atau bersifat umum dan dapat dimodifikasi oleh penggunanya. Mewakili pendekatan modular untuk merancang bahkan untuk masalah yang sangat kompleks, di mana konsep

operator modular yang memungkinkan desain rantai operator bersarang kompleks untuk masalah pembelajaran yang besar.

RapidMiner menggunakan XML untuk menggambarkan proses-proses penemuan pengetahuan pemodelan pohon operator. *RapidMiner* memiliki operator yang mudah dipahami untuk input dan output data dalam format file yang berbeda, dan berisi lebih dari 100 skema pembelajaran untuk tugas klasifikasi, regresi, dan pengelompokan (Naik & Samant, 2016).

RapidMiner dapat menjadi sebuah solusi untuk melakukan analisis terhadap data mining, text mining, dan analisis prediksi. *RapidMiner* menggunakan berbagai teknik deskriptif dan prediksi dalam memberikan pengetahuan kepada pengguna sehingga dapat membuat atau mengambil keputusan yang lebih baik (Sugianto, 2015).

HASIL DAN PEMBAHASAN

1. Pengumpulan Dataset

Dataset yang telah ada, dikelola dan diproses dengan menggunakan *software RapidMiner*. Dataset diperoleh dari data mahasiswa mulai dari tahun ajaran 2016/2017 sampai dengan 2020/2021 sebanyak 353 mahasiswa yang terdiri atas atribut NIM, prodi, jenis kelamin, indeks prestasi semester (IPS 1-5), dan status kelulusan tepat waktu “Ya” atau “Tidak”.


Tabel 3.1 Dataset Awal

NO	NIM	Program Studi	Jenis Kelamin	IPK I	IPK II	IPK III	IPK IV	IPK V	Lulus Tepat Waktu
1	15512039	D3-Teknik Listrik	Perempuan	3.40	3.85	3.86	3.21	3.43	YA
2	15512025	D3-Teknik Mesin	Laki-Laki	3.30	3.85	3.71	3.20	3.55	YA
3	15512036	D3-Teknik Pertambangan	Laki-Laki	3.20	4.00	3.57	3.55	3.25	YA
4	15512015	D3-Teknik Mesin	Perempuan	2.75	3.60	3.71	3.10	3.43	YA
5	15512037	D3-Teknik Pertambangan	Laki-Laki	2.85	2.65	2.78	2.55	2.64	TIDAK
6	15512046	D3-Teknik Pertambangan	Laki-Laki	3.40	3.45	3.86	3.45	3.21	YA
7	15512038	D3-Teknik Sipil	Laki-Laki	3.20	3.25	3.71	3.25	3.21	YA
8	15512049	D3-Teknik Pertambangan	Laki-Laki	2.90	2.70	2.78	2.90	3.01	TIDAK
9	15512044	D3-Teknik Sipil	Perempuan	3.30	3.85	3.71	3.43	3.20	YA
10	15512056	D3-Teknik Sipil	Laki-Laki	3.35	3.55	3.86	3.14	3.21	YA
11	15512001	D3-Teknik Pertambangan	Laki-Laki	3.10	3.65	3.71	3.51	3.43	YA
12	15512033	D3-Teknik Sipil	Laki-Laki	3.30	3.90	3.57	3.52	3.25	YA
13	15512017	D3-Teknik Mesin	Laki-Laki	2.30	2.90	2.43	2.25	2.10	TIDAK
14	15512006	D3-Teknik Mesin	Perempuan	3.40	3.60	3.46	3.43	3.21	YA
15	15512023	D3-Teknik Sipil	Perempuan	2.75	2.85	2.68	3.25	3.15	TIDAK
...	...	...	...	...	...	...	...	...	...
340	19512007	D3-Teknik Mesin	Perempuan	3.40	3.60	3.30	3.40	3.70	YA
341	19512082	D3-Teknik Pertambangan	Laki-Laki	3.46	3.62	3.30	3.32	3.21	YA
342	19512072	D3-Teknik Listrik	Laki-Laki	3.60	3.70	3.72	3.56	3.77	YA
343	19512049	D3-Teknik Mesin	Laki-Laki	2.60	3.10	3.05	2.09	2.21	TIDAK
344	19512050	D3-Teknik Listrik	Perempuan	3.35	3.86	3.30	3.46	3.65	YA
345	19512001	D3-Teknik Listrik	Laki-Laki	3.16	3.72	3.15	3.51	3.42	YA
346	19512025	D3-Teknik Listrik	Laki-Laki	3.15	2.90	2.55	3.20	2.95	TIDAK
347	19512047	D3-Teknik Mesin	Laki-Laki	3.05	2.65	2.65	2.75	2.85	TIDAK
348	19512055	D3-Teknik Sipil	Laki-Laki	2.46	2.86	2.45	2.12	2.18	TIDAK
349	19512062	D3-Teknik Sipil	Perempuan	2.85	3.00	2.47	2.47	2.15	TIDAK
350	19512060	D3-Teknik Listrik	Perempuan	3.55	3.45	3.30	3.15	3.50	YA
351	19512014	D3-Teknik Mesin	Laki-Laki	3.45	3.86	3.87	3.25	3.45	YA
352	19512093	D3-Teknik Listrik	Perempuan	3.35	3.85	3.75	3.25	3.55	YA
353	19512044	D3-Teknik Mesin	Laki-Laki	3.25	3.95	3.58	3.55	3.30	YA


Dataset di atas merupakan data yang telah melalui tahap *preprocessing* data, sesuai dengan kebutuhan atribut atau subset yang nantinya akan digunakan pada tahap proses klasifikasi data menggunakan algoritma *Support Vector Machine* (SVM) dan *Particle Swarm Optimization* (PSO).

2. Pengujian Model Klasifikasi

Klasifikasi pada dataset dilakukan dengan menggunakan algoritma *Support Vector Machine* (SVM). Atribut dari dataset bertipe Nominal diubah menjadi Numerical. Kemudian, dataset dibagi menjadi 2 sebagai data *training* dan data *testing* sesuai dengan ukuran tertentu.




Gambar 3.1 Pembagian data training dan testing pada Support Vector Machine (SVM)



Gambar 3.2 Penerapan Model Support Vector Machine (SVM) dengan 10 Cross Validation

Pada pengujian metode *Support Vector Machine* ini digunakan tipe *kernel Anova* dengan Parameter *Gamma*, *C*, dan *Epsilon*. Menggunakan metode *Cross Validation* pada data *training*. Setting parameter *Gamma*, *C*,

dan *Epsilon* dapat dilihat pada Gambar 3.3 berikut ini.



Gambar 3.3 Parameter Support Vector Machine (SVM)

3. Performance (Training) Model Support Vector Machine (SVM)

Eksperimen ini dilakukan untuk mengetahui seberapa besar akurasi dari performa training Model Support Vector Machine (SVM) dengan menggunakan software *RapidMiner*. Untuk teknik validasi menggunakan cross validation dengan 10fold cross validation dari 70% dataset training. Selanjutnya, pada bagian input parameter Support Vector Machine (SVM) dimasukkan nilai parameter *Gamma*, *C*, dan *Epsilon*.

Performa training model Support Vector Machine (SVM) dengan atribut prodi, jenis kelamin, IPK I, IPK II, IPK III, IPK IV, dan IPK V menghasilkan *performance Confusion Matrix* pada Tabel 4.2 dengan nilai accuracy, recall, precision, dan F1 score masing-masing sebesar 91,97%, 90,41%, 95,65%, dan 92,92%.

Tabel 3.2 **Confusion Matrix Training Model Support Vector Machine (SVM)**

Accuracy: 91.97% +/- 5.66% (micro average: 91.94%)			
	True YA	True TIDAK	Class Precision
Prediksi YA	132	6	95,65%
Prediksi TIDAK	14	96	87,27%
Class Recall	90,41%	94,12%	

Metrik evaluasi *performance training model Support Vector Machine (SVM)* dengan parameter *Gamma* (1), *C* (2), dan *Epsilon* (0,5) pada Tabel 4.2 menunjukkan tingkat akurasi sebesar 91,97%. Nilai evaluasi dari *performance training model Support Vector Machine (SVM)* dapat dihitung dengan persamaan sebagai berikut.

$$\begin{aligned} \text{Accuracy} &= (TP + TN) / (TP + FP + FN + TN) \\ &= (132 + 96) / (132 + 6 + 14 + 96) \\ &= 230 / 248 \\ &= 0,91 \end{aligned}$$

$$\begin{aligned} \text{Recall} &= TP / (TP + FN) \\ &= 132 / (132 + 14) \\ &= 0,90 \end{aligned}$$

$$\begin{aligned} \text{Precision} &= TP / (TP + FP) \\ &= 132 / (132 + 6) \\ &= 0,95 \end{aligned}$$

$$\begin{aligned} \text{F1 Score} &= 2 \times (\text{Recall} \times \text{Precision}) / (\text{Recall} + \text{Precision}) \\ &= 2 \times (0,93 \times 0,94) / (0,93 + 0,94) \\ &= 0,92 \end{aligned}$$

4. Performance (Testing) Model Support Vector Machine (SVM)

Eksperimen ini dilakukan untuk mengetahui akurasi dari performance testing model Support Vector Machine (SVM) menggunakan teknik validasi menggunakan cross validation dengan 10 fold cross validation dari 30% dataset training, dengan parameter *Gamma*, *C*, dan *Epsilon*, performa model Support Vector Machine (SVM) dengan atribut prodi, jenis kelamin, IPK I, IPK II, IPK III, IPK IV, dan IPK V menghasilkan performa *Confusion Matrix* pada Tabel 4.4 dengan nilai accuracy, recall, precision, dan F1 score masing-masing sebesar 93,33%, 98,39%, 91,04%, dan 94,57%.

Tabel 3.3 **Confusion Matrix Testing Model Support Vector Machine (SVM)**

Accuracy: 93,33%			
	True YA	True TIDAK	Class Precision
Prediksi YA	61	6	91,04%
Prediksi TIDAK	1	37	97,37%
Class Recall	98,39%	86,05%	

Metrik evaluasi *performance testing model Support Vector Machine (SVM)*

menggunakan input parameter Gamma dengan nilai 1, C dengan nilai 2, dan Epsilon dengan nilai 0,5 pada Tabel 4.4 menunjukkan tingkat akurasi sebesar 93,33%. Berdasarkan hasil akurasi yang diperoleh, terjadi peningkatan akurasi dari 91,97% menjadi 93,33%. Nilai evaluasi dari *performance training model Support Vector Machine (SVM)* dapat dihitung dengan persamaan sebagai berikut.

$$\begin{aligned} \text{Accuracy} &= (TP + TN) / (TP + FP + FN + TN) \\ &= (61 + 37) / (61 + 1 + 6 + 37) \\ &= 97 / 100 \\ &= 0,97 \end{aligned}$$

$$\begin{aligned} \text{Recall} &= TP / (TP + FN) \\ &= 61 / (61 + 1) \\ &= 0,98 \end{aligned}$$

$$\begin{aligned} \text{Precision} &= TP / (TP + FP) \\ &= 61 / (61 + 6) \\ &= 0,91 \end{aligned}$$


$$\begin{aligned} \text{F1 Score} &= 2 \times (\text{Recall} \times \text{Precision}) / (\text{Recall} + \text{Precision}) \\ &= 2 \times (0,96 \times 0,93) / (0,96 + 0,93) \\ &= 0,94 \end{aligned}$$

5. Support Vector Machine (SVM) berbasis Particle Swarm Optimization (PSO)

Particle Swarm Optimization (PSO) adalah operator yang digunakan untuk melakukan optimasi parameter yang telah ditentukan sebelumnya, yaitu parameter *Gamma*, *C*, dan *Epsilon* sekaligus untuk menghasilkan nilai pembobotan dari 8 (delapan) atribut sebagai penentu status kelulusan mahasiswa.

Penerapan metode *Particle Swarm Optimization (PSO)* ini dilakukan semata untuk meningkatkan hasil akurasi atau mengoptimalkan proses klasifikasi menggunakan algoritma *Support Vector Machine (SVM)*. Metode *Particle Swarm Optimization (PSO)* ini diterapkan setelah eksperimen dengan menggunakan metode *Support Vector Machine (SVM)* berhasil dilakukan, atau setelah performa testing dan training dari *Support Vector Machine (SVM)* telah diketahui hasilnya.

Berikut ini adalah rangkaian proses dalam Software *RapidMiner* untuk pemilihan parameter secara otomatis menggunakan *Particle Swarm Optimization (PSO)* Pada *Support Vector Machine (SVM)*. Penerapan *Particle Swarm Optimization (PSO)* dapat dilihat pada Gambar 2.4 sebagai berikut.



Gambar 3.4 Penerapan Particle Swarm Optimization (PSO) pada algoritma Support Vector Machine (SVM)

6. Performance model Support Vector Machine (SVM) berbasis Particle Swarm Optimization (PSO)

Eksperimen ini dilakukan untuk mengoptimasi parameter pada model *Support Vector Machine (SVM)* dengan menggunakan metode *Particle Swarm Optimization (PSO)*, dengan teknik validasi menggunakan *cross validation* dengan 10fold *cross validation*, dan setting parameter *Support Vector Machine (SVM)* untuk nilai *Gamma* = 1, nilai *C* = 2, dan *Epsilon* = 0,5.

Kemudian pada setting parameter dalam operator *Particle Swarm Optimization (PSO)*, untuk nilai *Population Size* diberikan nilai 15, dan untuk *Inertia Weight* diberikan nilai 1,0. Setelah dilakukan setting parameter dan dilanjutkan dengan proses klasifikasi data, maka menghasilkan *performance Confusion Matrix* pada Tabel 4.5 dengan nilai accuracy, recall, precision, dan F1 score masing-masing sebesar 98,01%, 99,02%, 97,60%, dan 98,29%.

Tabel 3.4 Confusion Matrix Support Vector Machine (SVM) berbasis Particle Swarm Optimization (PSO)

Accuracy: 98,01%			
	True YA	True TIDAK	Class Precision
Prediksi YA	203	2	99,02%
Prediksi TIDAK	5	143	96,62%

Class Recall	97,60%	96,62%	
--------------	--------	--------	--

Metrik evaluasi *performance Support Vector Machine (SVM)* berbasis *Particle Swarm Optimization (PSO)* pada Tabel 4.5, menunjukkan tingkat akurasi sebesar 98,01%. Dengan demikian, evaluasi model *Support Vector Machine (SVM)* berbasis *Particle Swarm Optimization (PSO)* dapat dibuktikan dengan persamaan sebagai berikut.

$$\begin{aligned} \text{Accuracy} &= (TP + TN) / (TP + FP + FN + TN) \\ &= (203 + 143) / (203 + 5 + 2 + 143) \\ &= 346 / 353 \\ &= 0,98 \end{aligned}$$

$$\begin{aligned} \text{Recall} &= TP / (TP + FN) \\ &= 203 / (203 + 2) \\ &= 0,99 \end{aligned}$$

$$\begin{aligned} \text{Precision} &= TP / (TP + FP) \\ &= 203 / (203 + 5) \\ &= 0,97 \end{aligned}$$


$$\begin{aligned} \text{F1 Score} &= 2 \times (\text{Recall} \times \text{Precision}) / (\text{Recall} + \text{Precision}) \\ &= 2 \times (0,99 \times 0,97) / (0,98 + 0,97) \\ &= 0,98 \end{aligned}$$

7. Attribute Weight pada Support Vector Machine (SVM) berbasis Particle Swarm Optimization (PSO)

Proses optimasi parameter dengan penerapan algoritma *Particle Swarm Optimization (PSO)* pada *Support Vector Machine (SVM)*, untuk pembobotan atribut dari 8 (delapan) atribut yang digunakan pada Gambar 2.5 menghasilkan nilai bobot pada atribut Program Studi D3-Teknik Listrik, D3-Teknik Sipil, IPK II, IPK III, IPK IV, dan IPK V masing-masing menghasilkan bobot 1. Atribut Jenis Kelamin (Perempuan) dan IPK I masing-masing menghasilkan bobot sebesar 0,6 dan 0,9. Sementara atribut Program Studi D3-Teknik Mesin, D3-Teknik Pertambangan, Jenis Kelamin (Laki-Laki) dan NIM tidak menghasilkan bobot. Dengan demikian, beberapa atribut berperan signifikan dalam proses klasifikasi, dengan perbandingan pembobotan yang tidak jauh berbeda. Walaupun, ada beberapa atribut yang sama sekali tidak menghasilkan bobot. *Attribute Weights* dengan *Particle Swarm Optimization (PSO)* pada algoritma *Support Vector*

Machine (SVM) dapat dilihat pada Gambar 2.5 sebagai berikut.

Pada pembobotan atribut dihasilkan nilai bobot dari 8 atribut yang digunakan, dapat dilihat pada gambar berikut ini.



Gambar 3.5 Attribute Weights dengan Particle Swarm Optimization (PSO)

Selanjutnya, pada atribut yang tidak memiliki pengaruh signifikan dalam proses klasifikasi akan dieliminasi, dan dilakukan proses klasifikasi lanjutan untuk mengetahui perubahan akurasi yang dihasilkan. Eksperimen sebelumnya dilakukan dengan menggunakan metode *Particle Swarm Optimization (PSO)* untuk optimasi parameter pada model *Support Vector Machine (SVM)* menggunakan *RapidMiner*, dengan teknik validasi menggunakan *cross validation* dengan *10fold cross validation*, dan setting parameter *Support Vector Machine (SVM)* untuk nilai Gamma = 1, nilai C = 2, dan Epsilon = 0,5. Kemudian, pada setting parameter dalam operator *Particle Swarm Optimization (PSO)* untuk *Population Size* diberikan nilai 15, dan untuk *Inertia Weight* diberikan nilai 1,0. Sesuai dengan hasil yang telah diperoleh, dari 8 atribut yang ada pada dataset, yaitu atribut Program Studi (D3-Teknik Listrik, D3-Teknik Sipil, D3-Teknik Mesin dan D3-Teknik Pertambangan), NIM, Jenis Kelamin (Laki-Laki dan Perempuan), IPK II, IPK III, IPK IV, dan IPK V, maka atribut NIM menjadi atribut yang akan dieliminasi karena tidak memiliki pengaruh untuk proses klasifikasi. Langkah ini dilakukan setelah melihat hasil pembobotan atribut (*Attribute Weight*) menggunakan metode *Particle Swarm Optimization (PSO)* dan relevansi atribut terhadap proses klasifikasi untuk target variable.

8. Eliminasi atribut yang tidak relevan pada *Support Vector Machine (SVM)* berbasis *Particle Swarm Optimization (PSO)*

Tujuan dari eliminasi atribut ini adalah untuk menyederhanakan model, mengurangi dimensi atribut, meningkatkan kinerja model untuk membuat keputusan dan prediksi, serta menghindari overfitting. Dengan teknik validasi menggunakan cross validation dengan 10fold cross validation, dan setting parameter *Support Vector Machine (SVM)* untuk nilai $\Gamma = 1$, nilai $C = 2$, dan $\epsilon = 0,5$. Kemudian, pada setting parameter dalam operator *Particle Swarm Optimization (PSO)* untuk Population Size diberikan nilai 15. Maka, diperoleh hasil performance Confusion Matrix pada Tabel 4.6 dengan nilai accuracy, recall, precision, dan F1 score masing-masing sebesar 98,02%, 98,08%, 98,55%, dan 98,31%.

Tabel 3.5 **Confusion Matrix Support Vector Machine (SVM) berbasis Particle Swarm Optimization (PSO) Setelah Dilakukan Eliminasi Atribut**

Accuracy: 98.02%			
	True YA	True TIDAK	Class Precision
Prediksi YA	204	3	98,55%
Prediksi TIDAK	4	142	97,26%
Class Recall	98,08%	97,93%	

Eksperimen lanjutan ini, menunjukkan bahwa terjadi peningkatan akurasi sebesar 0,01% dari 98,01% menjadi 98,02%. Metrik evaluasi performance *Support Vector Machine (SVM)* berbasis *Particle Swarm Optimization (PSO)* sebelum dilakukan pengurangan atribut dapat dilihat pada Table 4.5 dengan akurasi 98,01%, recall 99,02%, precision 97,60%, dan F1 score 98,29%. Kemudian pada metrik evaluasi performance setelah dilakukan pengurangan atribut dapat dilihat pada Tabel 4.6 dengan akurasi 98,02%, Recall 98,08%, Precision 98,55%, dan F1 Score 98,31%. Nilai evaluasi setelah dilakukan pengurangan atribut dapat dibuktikan dengan dengan persamaan sebagai berikut.

$$\begin{aligned} \text{Accuracy} &= (TP + TN) / (TP + FP + FN + TN) \\ &= (204 + 142) / (204 + 4 + 3 + 142) \end{aligned}$$

$$= 346 / 353$$

$$= 0,98$$

$$\text{Recall} = TP / (TP + FN)$$

$$= 204 / (204 + 3)$$

$$= 0,98$$

$$\text{Precision} = TP / (TP + FP)$$

$$= 204 / (204 + 4)$$

$$= 0,98$$


$$\text{F1 Score} = 2 \times (\text{Recall} \times \text{Precision}) / (\text{Recall} + \text{Precision})$$

$$= 2 \times (0,98 \times 0,98) / (0,98 + 0,98)$$

$$= 0,98$$

9. *Attribute Weight* pada *Support Vector Machine (SVM)* berbasis *Particle Swarm Optimization (PSO)* Setelah Eliminasi Atribut

Penerapan algoritma *Particle Swarm Optimization (PSO)* pada *Support Vector Machine (SVM)* untuk pembobotan atribut menghasilkan nilai bobot pada atribut Program Studi D3-Teknik Listrik, D3-Teknik Pertambangan, IPK I, IPK V, dan Jenis Kelamin (Laki-Laki) masing-masing menghasilkan nilai bobot 1. Atribut Program Studi D3-Teknik Mesin, IPK II, dan IPK IV masing-masing menghasilkan bobot nilai sebesar 0,52, 0,84, dan 0,63. Atribut program studi D3 Teknik Sipil, Jenis Kelamin (Perempuan), dan IPK III menghasilkan bobot dengan nilai 0. Dengan demikian, ada beberapa atribut utama dalam dataset yang diberikan bobot nilai 0. Namun, atribut tersebut tidak dapat dihilangkan lagi karena merupakan atribut penting pada proses klasifikasi dalam penelitian ini. *Attribute Weights* dengan *Particle Swarm Optimization (PSO)* pada algoritma *Support Vector Machine (SVM)* dapat dilihat pada Gambar 4.8 berikut.



Gambar 3.6 *Attribute Weights* Setelah Eliminasi Atribut

10. Pengukuran Kenaikan Performance

Berdasarkan eksperimen yang telah dilakukan, baik dengan menggunakan metode *Support Vector Machine* (SVM) maupun dengan penerapan metode *Particle Swarm Optimization* (PSO) pada *Support Vector Machine* (SVM), maka didapatkan hasil perbandingan seperti pada Tabel 4.7 sebagai berikut.

Tabel 3.6 Hasil pengukuran kenaikan performance

Dari hasil pengujian yang telah dilakukan, yaitu untuk data kelulusan mahasiswa, ditunjukkan pada Tabel 4.7, dalam penerapan metode *Particle Swarm Optimization* (PSO) pada *Support Vector Machine* (SVM) dengan penggunaan kernel *Anova*, setting parameters *Gamma* dengan nilai 1, *C* dengan nilai 2, dan *Epsilon* dengan nilai 0,5 serta setting parameter *Population Size* dengan nilai 15, terbukti dapat meningkatkan *accuracy* sebesar 98,02%, *Recall* 98,55%, *Precision* 98,08%, dan *F1 Score* sebesar 98,31%. Dengan demikian, terjadi peningkatan performa sebesar 4,69% lebih tinggi dibandingkan dengan metode *Support Vector Machine* (SVM) tanpa proses optimasi parameter.

11. Perbandingan hasil dengan penelitian sebelumnya

Berikut ini pada Tabel 4.8 merupakan bahan perbandingan dengan penelitian sebelumnya. Penulis menyajikan beberapa penelitian yang serupa dengan metode algoritma dan parameter-parameter pendukung yang digunakan.

Tabel 3.7 Perbandingan hasil dengan penelitian sebelumnya

No	Penulis	Objek Penelitian	Algoritma	Evaluasi	Akurasi
1.	Endang Supriyadi, Dana Indra Sensuse	Prediksi kelulusan mahasiswa	SVM dan PSO	<i>Confusion Matrix</i> dan <i>Kurva ROC</i>	80,34%
2.	Endang Supriyadi	Prediksi Kelulusan Mahasiswa	SVM dan PSO	<i>Confusion Matrix</i> dan <i>Kurva ROC</i>	82,05%
3.	Suhardjono, Ganda Wijaya, Abdul Hamid	Prediksi Kelulusan Mahasiswa	SVM dan PSO	<i>Confusion Matrix</i> dan <i>Kurva ROC</i>	86,43%
4.	Hendra, Moch. Abdul Azis, Suhardjono	Prediksi Kelulusan Mahasiswa	Decision Tree dan PSO	<i>Confusion Matrix</i> dan <i>Kurva AUC</i>	87,56%
5.	Muhammad Iqbal, Irwan Herliawan, Ridwansyah	Prediksi Kinerja Siswa	SVM dan PSO	<i>Confusion Matrix</i> dan <i>Kurva AUC</i>	92,61%
6.	Lala Nilawati, Yuni Eka Achyani	Prediksi Penilaian Apartemen	SVM dan PSO	<i>Confusion Matrix</i> dan <i>Kurva AUC</i>	82,04%

7.	Risa Wati, Siti Ernawati ² , Ina Maryani	Pengguna Maskapai Penerbangan	SVM dan PSO	<i>Confusion Matrix</i>	87,39%
8.	Penelitian terbaru (Penulis)	Prediksi Kelulusan Mahasiswa	SVM dan PSO	<i>Confusion Matrix</i>	98,02%

PENUTUP

Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, maka didapatkan kesimpulan sebagai berikut:

Metode	Kernel	Parameters			Pop. Size	Accuracy	Recall	Precision	F1 Score
		Gamma	C	Epsilon					
SVM (Training)	Anova	1,0	2,0	0,5		91,97%	95,65%	90,41%	92,92%
SVM (Testing)	Anova	1,0	2,0	0,5		93,33%	91,04%	98,39%	94,57%
SVM-PSO	Anova	1,0	2,0	0,5	15	98,01%	97,60%	99,02%	98,29%
SVM-PSO (2)	Anova	1,0	2,0	0,5	15	98,02%	98,55%	98,08%	98,31%

1. Penerapan *Particle Swarm Optimization* (PSO) pada algoritma *Support Vector Machine* (SVM) untuk prediksi kelulusan mahasiswa, dengan penggunaan kernel *Anova*, setting parameter *Gamma* dengan nilai 1, *C* dengan nilai 2 dan *Epsilon* dengan nilai 0,5 serta setting parameter *Population Size* dengan nilai 15, dan pengurangan atribut yang tidak relevan, dapat meningkatkan hasil akurasi sebesar 4,69% dari 93,33% menjadi 98,02%.

a. Hasil eksperimen dengan menggunakan algoritma *Support Vector Machine* (SVM) menghasilkan nilai *accuracy*, *recall*, *precision*, dan *F1 score* dengan nilai masing-masing 93,33%, 91,04%, 98,39%, dan 94,57%.

b. Optimasi algoritma *Support Vector Machine* (SVM) dengan menggunakan *Particle Swarm Optimization* (PSO) yang dilakukan untuk optimasi parameter, pembobotan atribut, dan setelah eliminasi atribut yang tidak relevan dapat menghasilkan nilai *accuracy* 98,02%, *recall* 98,55%, *precision* 98,08%, dan *F1 score* 98,31%.

2. Hasil dari model penerapan *Particle Swarm Optimization* (PSO) pada algoritma *Support Vector Machine* (SVM) dinyatakan terbukti dapat meningkatkan kinerja dan memiliki pengaruh yang signifikan untuk meningkatkan hasil akurasi dari algoritma *Support Vector Machine* (SVM).

3. Pada pengujian algoritma *Support Vector Machine* (SVM) dengan optimasi menggunakan *Particle Swarm Optimization* (PSO), menggunakan tipe *kernel Anova* dengan parameter *Gamma*, *C*, dan *Epsilon*. *Kernel Anova* dengan parameter *Gamma*, *C*, dan *Epsilon* mampu memberikan hasil akurasi yang lebih baik daripada *kernel* lainnya, dengan parameter yang bernilai sama. Parameter *Gamma*, dimasukkan nilai 1, untuk parameter *C* dengan nilai 2, dan untuk parameter *Epsilon* dengan nilai 0,5. Selain itu, *kernel Anova* juga memungkinkan *Support Vector Machine* (SVM) untuk memproses data dengan fitur yang sangat banyak, yang sulit diproses dengan *kernel* lainnya.

REFERENSI

- A., R., -, E. S., A., A., & Ibrahim, B. (2015). Modifications of Particle Swarm Optimization Techniques and Its Application on Stock Market: A Survey. *International Journal of Advanced Computer Science and Applications*, 6(3), 99–108.
<https://doi.org/10.14569/ijacsa.2015.060315>
- Ariyati, I., Ridwansyah, & Suhardjono. (2018). Implementasi Particle Swarm Optimization untuk Optimalisasi Data Mining Dalam Evaluasi Kinerja Asisten Dosen. *JIKO (Jurnal Informatika Dan Komputer) STMIK AKAKOM*, 3(2), 70–75.
- Arsi, P., Wahyudi, R., & Waluyo, R. (2021). Optimasi SVM Berbasis PSO pada Analisis Sentimen Wacana Pindah Ibu Kota Indonesia. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(2), 231–237.
<https://doi.org/10.29207/resti.v5i2.2698>
- Asrol, M., Papilo, P., & Gunawan, F. E. (2021). Support Vector Machine with K-fold Validation to Improve the Industry's Sustainability Performance Classification. *Procedia Computer Science*, 179(2020), 854–862.
<https://doi.org/10.1016/j.procs.2021.01.074>
- Basari, A. S. H., Hussin, B., Ananta, I. G. P., & Zeniarja, J. (2013). Opinion mining of movie review using hybrid method of support vector machine and particle swarm optimization. *Procedia Engineering*, 53, 453–462.
<https://doi.org/10.1016/j.proeng.2013.02.059>
- Bhise, S., & Kale, P. S. (2017). Effieient Algorithms to find Frequent Itemset Using Data Mining. *International Research Journal of Engineering and Technology(IRJET)*, 4(6), 2645–2648.
<https://irjet.net/archives/V4/i6/IRJET-V4I6664.pdf>
- Han, B., & Bian, X. (2018). A hybrid PSO-SVM-based model for determination of oil recovery factor in the low-permeability reservoir. *Petroleum*, 4(1), 43–49.
<https://doi.org/10.1016/j.petlm.2017.06.001>
- Kasbe, T., & Pippal, R. S. (2018). Design of heart disease diagnosis system using fuzzy logic. *2017 International Conference on Energy, Communication, Data Analytics and Soft Computing, ICECDS 2017*, 3183–3187.
<https://doi.org/10.1109/ICECDS.2017.8390044>
- Naik, A., & Samant, L. (2016). Correlation Review of Classification Algorithm Using Data Mining Tool: WEKA, Rapidminer, Tanagra, Orange and Knime. *Procedia Computer Science*, 85(Cms), 662–668.
<https://doi.org/10.1016/j.procs.2016.05.251>
- Ren, J. (2012). ANN vs. SVM: Which one performs better in classification of MCCs in mammogram imaging. *Knowledge-Based Systems*, 26, 144–153.
<https://doi.org/10.1016/j.knosys.2011.07.016>
- Riyanto, V., Hamid, A., & Ridwansyah, R. (2019). Prediction of Student Graduation Time Using the Best Algorithm. *Indonesian Journal of Artificial Intelligence and Data Mining*, 2(1), 1–9.
<https://doi.org/10.24014/ijaidm.v2i1.6424>
- Sang, A. I., Sutoyo, E., & Darmawan, I. (2021). Analisis Data Mining Untuk Klasifikasi Data Kualitas Udara Dki Jakarta Menggunakan Algoritma Decision Tree Dan Support Vector Machine Data Minning Analysis for Classification of Air Quality Data Dki Jakarta Using Decision Tree Algorithm

- and Support Vector. 8(5), 8954–8963.
- Sugara, B., & Subekti, A. (2019). Penerapan Support Vector Machine (Svm) Pada Small Dataset Untuk Deteksi Dini Gangguan Autisme. *Jurnal Pilar Nusa Mandiri*, 15(2), 177–182.
<https://doi.org/10.33480/pilar.v15i2.649>
- Sugianto, C. A. (2015). Analisis Komparasi Algoritma Klasifikasi Untuk Menangani Data Tidak Seimbang Pada Data Kebakaran Hutan. *Techno.Com*, 14(4), 336–342.
- Sugimoto, M., Takada, M., & Toi, M. (2013). Comparison of robustness against missing values of alternative decision tree and multiple logistic regression for predicting clinical data in primary breast cancer. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 3054–3057.
<https://doi.org/10.1109/EMBC.2013.6610185>
- Wang, D., & Zhao, Y. (2020). Using News to Predict Investor Sentiment: Based on SVM Model. *Procedia Computer Science*, 174(2019), 191–199.
<https://doi.org/10.1016/j.procs.2020.06.074>
- Zhang, Y., Tang, L., Zou, H., Yang, Q., Yu, X., Jiang, J., Wu, H., & Yu, R. (2015). Identifying protein arginine methylation sites using global features of protein sequence coupled with support vector machine optimized by particle swarm optimization algorithm. *Chemometrics and Intelligent Laboratory Systems*, 146, 102–107.
<https://doi.org/10.1016/j.chemolab.2015.05.011>