

Optimalisasi *Support Vector Machine* (SVM) Berbasis *Particle Swarm Optimization* (PSO) Pada Analisis Sentimen Terhadap *Official Account* Ruang Guru Di Twitter

Rizqi Darmawan¹, Indra¹, Asep Surahmat^{1,*}

¹ Fakultas Teknologi Informasi; Universitas Budi Luhur; Jl. Ciledug Raya, RT. 10/RW 02, Petukangan Utara, Kec. Pesanggrahan, Kota Jakarta Selatan, DKI Jakarta 12260, 0215853753; e-mail: rizqidarmawan95@gmail.com, indra@budiluhur.ac.id, asepsurahmat09@gmail.com

* Korespondensi: e-mail: asepsurahmat09@gmail.com

Submitted: 22/04/2022; Revised: 27/04/2022; Accepted: 13/05/2022; Published: 27/05/2022

Abstract

The significant increase in the number of users has caused public opinion on the Ruang Guru application to be widely spread through social media, especially Twitter. From 15,000 twitter data taken with the keyword Ruang Guru, a total of 2,358 datasets were obtained through the process of handling duplicates. In this study, sentiment analysis was carried out using the Support Vector Machine (SVM) algorithm which was optimized with Particle Swarm Optimization (PSO) then tested using the 10-Fold Cross Validation method which resulted in the highest accuracy rate of 89.20%, while the Support Vector Machine algorithm (SVM) only produces the highest accuracy rate of 88.56%. There is an increase of 0.64% with Particle Swarm Optimization optimization. Sentiment analysis results are positive, with positive results as much as 1463 data or 62.04% and 895 or 37.96% negative sentiment. From the results of this study, it is expected to be a material consideration for Ruang Guru to improve the quality of the service sector found on social media, especially Twitter.

Keywords: *Particle Swarm Optimization, Ruang Guru, Sentiment Analysis, Support Vector Machine*

Abstrak

Peningkatan jumlah pengguna yang cukup signifikan menyebabkan opini masyarakat terhadap aplikasi Ruang Guru tersebar luas melalui media sosial khususnya *twitter*. Dari 15.000 data *twitter* yang diambil dengan keyword Ruang Guru, didapatkan dataset sejumlah 2.358 melalui proses *handling duplicate*. Pada penelitian ini dilakukan analisis sentimen dengan menggunakan algoritma *Support Vector Machine* (SVM) yang dioptimalisasikan dengan *Particle Swarm Optimization* (PSO) kemudian diuji dengan metode *10-Fold Cross Validation* yang menghasilkan tingkat akurasi tertinggi sebesar 89.20%, sementara algoritma *Support Vector Machine* (SVM) hanya menghasilkan tingkat akurasi tertinggi sebesar 88.56%. Terdapat peningkatan sebesar 0.64% dengan optimalisasi *Particle Swarm Optimization*. Hasil pada analisis sentimen mayoritas bersifat positif, dengan hasil positif sebanyak 1463 data atau 62.04% dan 895 atau 37.96% sentimen negatif. Dari hasil penelitian ini diharapkan menjadi bahan pertimbangan bagi Ruang Guru untuk meningkatkan kualitas sektor pelayanan yang terdapat pada media sosial khususnya *Twitter*.

Kata kunci: *Particle Swarm Optimization, Ruang Guru, Analisis Sentimen, Support Vector Machine*

1. Pendahuluan

Covid-19 memberikan dampak perubahan gaya belajar dari offline menjadi online. Untuk itu Ruang Guru hadir sebagai salah satu bimbingan belajar online di Indonesia. Ruangguru menjadi solusi yang menjembatani masalah sulitnya penerimaan materi secara online dari sekolah dengan berbagai fasilitas yang ditawarkan oleh Ruangguru, seperti Ruangbelajar, Ruangkelas, Ruanguji, Brain Academy, English Academy, roboguru, ruangbaca, ruanglesonline, dan dafalulu.

Peningkatan popularitas pengguna Ruang Guru menyebabkan banyak masyarakat memberikan tanggapannya terhadap Ruang Guru itu sendiri melalui berbagai media sosial, khususnya media sosial Twitter, dan tentunya mengetahui respon masyarakat akan sangat bermanfaat guna meningkatkan kualitas yang akan diberikan kepada pengguna kedepannya. Ruang Guru perlu mengetahui bagaimana respon masyarakat terhadap perubahan yang mereka lakukan, hal ini dapat dilakukan dengan salah satu cara yaitu analisis sentiment.

Fokus penelitian ini yaitu mengukur seberapa jauh tingkat akurasi yang dapat dihasilkan oleh algoritma *Support Vector Machine* (SVM) yang telah dioptimalisasi oleh algoritma *Particle Swarm Optimization* (PSO) yang diterapkan pada analisis sentiment terhadap bimbingan belajar Ruang Guru. Selanjutnya data akan diambil serta diolah melalui beberapa tahapan proses, mulai dari pengumpulan data dengan teknik crawling, lalu selanjutnya dilakukan labelling dan masuk pada tahapan pre-processing meliputi, case folding, cleaning, tokenizing, stopword removal, dan stemming (Du et al., 2017).

Algoritma *Support Vector Machine* (SVM) dipilih karena memiliki tingkat ketahanan serta kinerja yang sangat baik secara general, banyak peneliti mempertimbangkan metode SVM untuk meningkatkan akurasi pada model yang digunakan (Du et al., 2017), selain itu Algoritma *Support Vector Machine* (SVM) dipilih dikarenakan algoritma tersebut telah digunakan secara luas dan berhasil dalam analisis sentiment (Moraes et al., 2013). Sedangkan untuk algoritma *Support Vector Machine* (SVM) yang telah dioptimalisasi oleh *algoritma Particle Swarm Optimization* (PSO) terbukti dapat meningkatkan nilai akurasinya (Sasongko, 2016).

Hasil yang diharapkan dalam penelitian ini adalah, bimbingan belajar Ruangguru dapat mengetahui tanggapan atau opini masyarakat luas, khususnya pada media sosial Twitter tentang perusahaan mereka. Algoritma *Support Vector Machine* (SVM) yang telah dioptimalisasi oleh algoritma *Particle Swarm Optimization* (PSO) diharapkan menghasilkan tingkat akurasi yang lebih baik dalam analisis sentiment dibandingkan dengan algoritma *Support Vector Machine* (SVM) yang digunakan secara konvensional.

2. Metode Penelitian

2.1. *Support Vector Machine* (SVM)

Support Vector Machine (SVM) adalah suatu teknik untuk melakukan prediksi, baik dalam kasus klasifikasi maupun regresi (Santoso et al., 2016). SVM memiliki prinsip dasar linier classifier yaitu kasus klasifikasi yang secara linier dapat dipisahkan, namun SVM telah

dikembangkan agar dapat bekerja pada problem non-linier dengan memasukkan konsep kernel pada ruang kerja berdimensi tinggi (Ahmad et al., 2018) .Pada ruang berdimensi tinggi, akan dicari hyperplane (hyperplane) yang dapat memaksimalkan jarak (margin) antara kelas data. Menurut santosa (2007) hyperplane klasifikasi linier SVM dinotasikan :

$$f(x) = w^T x + b$$

sehingga menurut Vapnik dan Cortes (1995) diperoleh persamaan

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

$$[(w^T \cdot x_i) + b] \leq -1 \quad \text{untuk } y_i = -1$$

Dengan x_i himpunan data training, $i = 1,2,\dots,n$ dan $y_i =$ label kelas dari x_i Untuk mendapatkan hyperplane terbaik adalah dengan mencari hyperplane yang terletak di tengah-tengah antara dua bidang pembatas kelas dan untuk mendapatkan hyperplane terbaik itu, sama dengan memaksimalkan margin atau jarak antara dua set objek dari kelas yang berbeda (Santosa, 2007).

2.2. Particle Swarm Optimization (PSO)

Algoritma ini merupakan algoritma berbasis populasi yang mengeksplorasi individu dalam pencarian (Xia et al., 2020). Dalam PSO populasi disebut swarm dan individu disebut particle. Tiap particle berpindah dengan kecepatan yang diadaptasi dari daerah pencarian dan menyimpan sebagai posisi terbaik yang pernah dicapai (Sulistiyanto, 2018). Dalam algoritma PSO terdapat beberapa proses sebagai berikut (Naseem et al., 2020) :

1. Inisialisasi

- a. Inisialisasi kecepatan awal. Pada iterasi ke-0, dapat dipastikan bahwa nilai kecepatan awal semua partikel adalah 0.
- b. Inisialisasi posisi awal partikel. Pada iterasi ke-0, posisi awal partikel dibangkitkan dengan persamaan :

$$x = x_{min} + rand[0,1]_x (x_{max} - x_{min})$$

- c. Inisialisasi lBest (local best) dan gBest (global best). Pada iterasi ke-0, lBest (local best) akan disamakan dengan nilai posisi awal partikel. Sedangkan gBest (global best) dipilih dari satu lBest dengan fitness tertinggi.

2. Update Kecepatan

Untuk melakukan update kecepatan, digunakan rumus berikut:

$$v_{i,j}^{t+1} = w \cdot v_{i,j}^t + c_1 \cdot r_1 (Pbest_{i,j}^t - x_{i,j}^t) + c_2 \cdot r_2 (Gbest_{g,j}^t - x_{i,j}^t)$$

Dimana :

$v_{i,j}$ = komponen kecepatan individu ke i pada d dimensi

w = parameter inertia weight

c_1, c_2 = konstanta akselerasi (learning rate), nilainya antara 0 sampai 1

r_1, r_2 = parameter random antara 0 sampai 1

$Pbest_{i,j}$ = Pbest (local best) individu i pada j dimensi

$Gbest_{g,j}$ = Gbest (local best) individu g pada j dimensi

3. Update Posisi dan Hitung Fitness

Untuk melakukan update posisi, digunakan rumus berikut:

$$x_{i,j}^{t+1} = x_{i,j}^t + v_{i,j}^{t+1}$$

Dimana:


$x_{i,j}$ = posisi individu i pada j dimensi

4. Update IBest (local best) dan gBest (global best)

Dilakukan perbandingan antara IBest (local best) pada iterasi sebelumnya dengan hasil dari update posisi. Fitness yang lebih tinggi akan menjadi IBest yang baru. IBest terbaru yang memiliki nilai fitness tertinggi akan menjadi gBest yang baru

2.3. K-Fold Cross Validation

K-fold cross validation adalah teknik untuk mengestimasi performansi dari model pelatihan yang telah dibangun. Metode ini membagi data training dan data testing sebanyak k bagian data. Fungsi dari k-fold cross validation adalah agar tidak ada overlapping pada data testing. Berikut ilustrasi sederhana dari k-fold cross validation ditunjukkan pada Gambar dibawah ini.



Sumber: Hasil Penelitian (2022)

Gambar 1. Ilustrasi K-fold Cross Validation (Que et al., 2020)

Pada ilustrasi yang tertera pada Gambar 1 dapat dijabarkan bahwa percobaan menggunakan 4-fold cross validation. Untuk menghitung nilai akurasi yang dihasilkan oleh K-fold Cross Validation digunakan rumus sebagai berikut.

$$Akurasi = \frac{\text{Jumlah Data Prediksi Benar}}{\text{Jumlah Prediksi yang dilakukan}} \times 100\%$$

2.4 Metode Pengumpulan Data

Pada penelitian dibutuhkan pengumpulan data-data berupa informasi dan referensi untuk bahan yang dapat mendukung materi uraian dan pembahasan. Hal ini menjadikan salah satu tahapan yang penting dalam melakukan kegiatan penelitian. Teknik pengumpulan data yang benar akan menunjang hasil akhir dengan kredibilitas yang tinggi.

Studi data Twitter menjadi metode yang dipakai pada penelitian ini. Dataset yang digunakan berasal dari media sosial Twitter dengan kata kunci yang digunakan adalah cuitan yang mengandung Ruangguru. Data yang diambil dari periode bulan Juli 2020 sampai Agustus 2021 dikumpulkan dan disatukan guna menjadi satu kesatuan data yang utuh. Agar dapat digunakan untuk melakukan analisis sentimen dan pengujian dari algoritma yang digunakan.

Proses pengumpulan data dilakukan dengan menggunakan metode *crawling* data yang terdapat pada tools rapidminer, hal ini dijelaskan lebih lanjut pada proses langkah-langkah penelitian dihalaman selanjutnya.

2.5 Instrumentasi

Instrument yang digunakan dalam penelitian ini, berupa dokumen penunjang seperti buku, jurnal, skripsi dan tesis tentang penelitian terdahulu. Dokumen yang digunakan untuk Analisis sentimen terhadap bimbingan belajar Ruangguru menggunakan *Support Vector Machine* (SVM) yang dioptimalisasi dengan *Particle Swarm Optimization* (PSO). Dalam penelitian ini, instrumen yang digunakan untuk mengumpulkan data adalah **a)** instrumen untuk pengumpulan data dengan metode observasi; **b)** instrumen untuk pengumpulan data dengan metode studi pustaka. Instrumen observasi ini adalah peneliti yang melakukan pengamatan pada data cuitan Twitter yang mengandung *keyword* Ruangguru dan Ruang guru dengan menggunakan tools *Rapidminer*. Instrumen studi pustaka ini adalah peneliti yang mempelajari literatur yang bersumber dari beberapa jurnal dan buku tentang machine learning, data mining, text mining, algoritma *Support Vector Machine*, algoritma *Support Vector Machine* dan *Particle Swarm Optimization* dan langkah-langkah proses pada sebuah analisis sentimen.

3. Hasil dan Pembahasan

3.1. Data Preparation

Data diambil melalui media sosial Twitter dengan kata kunci yang digunakan adalah ruangguru & ruang guru. Didapatkan sejumlah 15.000 data lalu dilakukan proses cleaning data menjadi 2.358 data yang siap diproses.

3.2. Labeling

Labeling dilakukan untuk menentukan Tweet mana yang bernilai positif, dan Tweet mana yang bernilai negatif.

Tabel 1. Pelabelan Data Twitter

No.	Isi Tweet	Label
1.	setelah aku pake @ruangguru ngebantu banget buat lebih memahami materi pelajaran 👍	Positif
2.	setelah belajar pake Ruangguru atau Zenius ttg Kimia kelas 10. Bedain sama ajarin dosen Kimdas 1 di kampus. Emng benar gaada murid yg bodoh atau gagal adanya guru yg gabisa ngajar dan gagal! Learning is fun. The teacher isnt.	Positif
3.	Sharing ruang belajar RG dong , please reply #zonauang #zonaba #ruangguru	Negatif

Sumber: Hasil Penelitian (2022)

3.3. Proses Preprocessing

Proses preprocessing adalah proses dimana data yang didapatkan diubah sedemikian rupa untuk dilakukan penyesuaian terhadap susunan, dimana proses yang dilakukan adalah Tokenize, Case Folding, Stopword Removal, Cleansing, Stemming.

3.4. Data Splitting

Proses pemecahan data dilakukan dengan membagi data menjadi dua kelompok, yaitu data latih dan data uji. Data latih digunakan sebanyak 80% atau 1886 data dari jumlah total dataset yang didapatkan dalam proses crawling data, sedangkan data uji menggunakan sisa data yang tersedia, yaitu sebanyak 20% data atau sebanyak 472 data. Data positif yang digunakan untuk training sebanyak 1170 data, sedangkan untuk testing 293 data. Selanjutnya, data negatif digunakan sebanyak 716 data training dan 179 data testing.

Tabel 2. Data Splitting

Data Splitting			
Positif		Negatif	
Training	Testing	Training	Testing
1170	293	716	179
1186		472	

Sumber: Hasil Penelitian (2022)

3.5. Pengujian Algoritma Support Vector Machine

Pada tabel 3 dapat dilihat bahwa tabel perhitungan akurasi dari proses testing dari algoritma Support Vector Machine dilakukan sebanyak 10-Fold Cross Validation, dimana rata-rata akurasi yang dihasilkan yaitu 87,67%, sedangkan akurasi terendah pada 7-fold Cross

Validation yaitu 86,25% dan nilai akurasi tertinggi dihasilkan pada 3-fold Cross validation yaitu nilai akurasi yang dihasilkan adalah 88,56%.

Tabel 3. Hasil Pengujian Menggunakan Algoritma SVM

K-fold Cross Validation		Score	Percentage
0	2	0.879237	87.9237
1	3	0.885633	88.5633
2	4	0.872881	87.2881
3	5	0.877223	87.7223
4	6	0.875176	87.5176
5	7	0.862505	86.2505
6	8	0.879237	87.9237
7	9	0.881511	88.1511
8	10	0.877394	87.7394
Average			87.6755
MIN			86.2505
MAX			88.5633

Sumber: Hasil Penelitian (2022)

3.6. Pengujian Algoritma Support Vector Machine yang Dioptimalisasi Menggunakan Particle Swarm Optimization

Dari Tabel 4 dapat dilihat bahwa tabel tersebut menampilkan nilai akurasi yang dihasilkan oleh data uji dan diolah menggunakan algoritma Support vector machine particle swarm optimization. Dimana hasil rata-rata akurasi yang dihasilkan yaitu sebesar 87.82%, untuk nilai akurasi tertinggi yang dihasilkan Support vector machine particle swarm optimization yaitu sebesar 89.2% dihasilkan oleh pemrosesan 3-fold Cross validation. Nilai akurasi terendah yang diproses pada data latih menggunakan metode Support vector machine particle swarm optimization sebesar 86,67% dihasilkan oleh pemrosesan 7-fold Cross Validation.

Tabel 4. Hasil Pengujian Menggunakan Algoritma SVM Dioptimalisasi PSO

K-fold Cross Validation		Score	Percentage
0	2	0.8782881	87.8288
1	3	0.892015	89.2015
2	4	0.875000	87.5
3	5	0.879328	87.9328
4	6	0.873039	87.3039
5	7	0.866675	86.6675
6	8	0.881356	88.1356
7	9	0.881551	88.1551
8	10	0.877349	87.7349
Average			87.8289

K-fold Cross Validation	Score	Percentage
MIN		86.6675
MAX		89.2015

Sumber: Hasil Penelitian (2022)

3.7. Komparasi Model

Tahapan terakhir yang dilakukan adalah mengkomparasi hasil klasifikasi yang telah dibangun menggunakan prototipe. Baik itu algoritma Support Vector Machine dan Support Vector Machine Particle Swarm. Berikut adalah hasil komparasi yang didapatkan

Tabel 5. Komparasi Model SVM dan SVM + PSO

	SVM		SVM+PSO	
	Training	Testing	Training	Testing
AVERAGE	87.55%	87.68%	87.86%	87.83%
MIN	87.22%	86.25%	87.64%	86.67%
MAX	87.81%	88.56%	88.07%	89.20%

Sumber: Hasil Penelitian (2022)

Dari tabel hasil komparasi diatas dapat kita lihat bahwa tingkat akurasi yang dihasilkan algoritma Support vector machine terbilang cukup baik dengan menghasilkan masing-masing nilai rata-rata untuk data latih sebesar 87,55%, dan data uji 87,68% tingkat akurasi minimum untuk data latih sebesar 87,22%, sedang data uji 86,25% dan nilai akurasi maksimum pada data latih algoritma Support Vector Machine sebesar 87,81%, dan 88,56% untuk data uji. Hal ini menunjukkan bahwa algoritma Support Vector Machine yang digunakan untuk proses analisis sentimen mengalami penurunan sebanyak 0.97% pada nilai minimum yang didapatkan, serta kenaikan masing-masing sebesar 0.13% dan 0.75% untuk rata-rata dan nilai maksimum dari tingkat akurasi yang dihasilkan.

Tingkat akurasi yang dihasilkan algoritma Support vector machine yang telah dioptimalisasi oleh Particle Swarm Optimization menghasilkan nilai yang lebih baik dibandingkan dengan algoritma Support Vector Machine, yaitu dengan menghasilkan masing-masing nilai rata-rata untuk data latih sebesar 87,86%, dan data uji 87,83% tingkat akurasi minimum untuk data latih sebesar 87,64%, sedang data uji 86,67% dan nilai akurasi maksimum pada data latih algoritma Support Vector Machine yang telah dioptimalisasi dengan algoritma Particle Swarm Optimization sebesar 88,07%, dan 89,20% untuk data uji. Hal ini menunjukkan bahwa algoritma Support Vector Machine yang telah dioptimalisasi dengan algoritma Particle Swarm Optimization semua menunjukkan peningkatan baik pada nilai rata-rata, maupun nilai maksimum yang dihasilkan, yaitu masing-masing sebanyak 0,03%, 1,13%. Sedangkan untuk nilai minimum yang dihasilkan mengalami penurunan tingkat akurasi sebesar 0.97%.

Tingkat akurasi yang dihasilkan oleh algoritma Support Vector Machine yang dioptimalisasikan dengan Particle Swarm Optimization menunjukkan peningkatan dibandingkan algoritma Support Vector Machine. Peningkatan terjadi pada semua aspek, mulai dari data

training, maupun testing yang diuji pada prototipe. Peningkatan signifikan terjadi pada data testing, dimana Algoritma support vector machine yang dioptimalisasi particle swarm optimization berhasil mencetak 89.20%, skor akurasi ini lebih tinggi dibandingkan algoritma support vector machine yang menghasilkan 88.56%.

4. Kesimpulan

Penelitian mengenai Optimalisasi support vector machine (SVM) berbasis particle swarm optimization (PSO) pada analisis sentimen terhadap Ruangguru menggunakan dataset yang berupa data Twitter sebanyak 15.000 data yang ditarik, kemudian dilakukan proses handling duplikat dan menjadi 2.358 dataset dimana data tersebut terbagi menjadi 1463 Tweetpositif & 895 Tweetnegatif. Algoritma support vector machine yang dioptimalisasi dengan Particle Swarm Optimization dengan nilai parameter C1 & C2 1, mencatatkan tingkat akurasi sebesar 89.20% dan algoritma support vector machine menghasilkan tingkat akurasi sebesar 88.56%. Algoritma Support Vector Machine yang dioptimalisasikan dengan Particle Swarm Optimization yang digunakan untuk proses analisis sentimen terhadap ruangguru berhasil meningkatkan nilai akurasi yang dihasilkan sebesar 0.64% dibandingkan dengan algoritma Support Vector Machine. Peningkatan yang dihasilkan oleh support vector machine yang dioptimalisasi dengan Particle Swarm Optimization tidak begitu signifikan, namun tetap berhasil meningkatkan nilai akurasi yang dihasilkan terhadap proses analisis sentimen. Sementara itu nilai tingkat akurasi yang dihasilkan oleh Algoritma support vector machine yang dioptimalisasi dengan Particle Swarm Optimization dengan nilai parameter C1 & C2 0,5, hanya mencatatkan tingkat akurasi sebesar 87.49%. ini menunjukkan bahwa nilai parameter Partcile Swarm Optimization pada C1 & C2 mempengaruhi tingkat optimalisasi yang dihasilkan terhadap SVM. Dari penelitian ini diharapkan dapat memberikan gambaran kepada Runagguru bahwa pandangan masyarakat terhadap Ruangguru di media sosial khususnya Twitter mendapatkan setimen positif, yaitu sebanyak 1463 data atau 62.04% dan 895 atau 37.96% sentimen negatif data keseluruhan dataset yang diolah.

Daftar Pustaka

- Ahmad, I., Basher, M., Iqbal, M. J., & Rahim, A. (2018). Performance Comparison of Support Vector Machine , Random Forest , and Extreme Learning Machine for Intrusion Detection. *IEEE Access*, 6, 33789–33795. <https://doi.org/10.1109/ACCESS.2018.2841987>
- Du, J., Liu, Y., Yu, Y., & Yan, W. (2017). *A Prediction of Precipitation Data Based on Support Vector Machine and Particle Swarm Optimization*. <https://doi.org/10.3390/a10020057>
- Moraes, R., Valiati, J. F., & Gavião Neto, W. P. (2013). Document-level sentiment classification: An empirical comparison between SVM and ANN. *Expert Systems with Applications*, 40(2), 621–633. <https://doi.org/10.1016/j.eswa.2012.07.059>
- Naseem, U., Razzak, I., Musial, K., & Imran, M. (2020). Transformer based Deep Intelligent Contextual Embedding for Twitter sentiment analysis. *Future Generation Computer*

- Systems*, 113, 58–69. <https://doi.org/10.1016/j.future.2020.06.050>
- Que, V. K. S., Iriani, A., & Purnomo, H. D. (2020). Analisis Sentimen Transportasi Online Menggunakan Support Vector Machine Berbasis Particle Swarm Optimization. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 9(2), 162–170. <https://doi.org/10.22146/jnteti.v9i2.102>
- santosa. (2007). *Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis*.
- Santoso, H., Hariyadi, I. P., & Prayitno. (2016). Data Mining Analisa Pola Pembelian Produk. *Teknik Informatika*, 1, 19–24. <http://ojs.amikom.ac.id/index.php/semnasteknomedia/article/download/1267/1200>
- Sasongko, T. B. (2016). Komparasi dan Analisis Kinerja Model Algoritma SVM dan PSO-SVM (Studi Kasus Klasifikasi Jalur Minat SMA). *Jurnal Teknik Informatika Dan Sistem Informasi*, 2(2), 244–253. <https://doi.org/10.28932/jutisi.v2i2.476>
- Sulistiyanto. (2018). Penerapan C4 . 5 Berbasis Particle Swarm Optimization (PSO) dalam Memprediksi Siswa Lolos Seleksi Perguruan Tinggi. *Seminar Nasional Teknologi Dan Bisnis*, 162–170.
- Xia, X., Gui, L., Yu, F., Wu, H., Wei, B., & Zhang, Y. (2020). Triple Archives Particle Swarm Optimization. *IEEE Transactions on Cybernetics*, 50(12), 4862–4875. <https://doi.org/10.1109/TCYB.2019.2943928>