

Optimasi Support Vector Machine Menggunakan Particle Swarm Optimization pada Analisis Sentimen Ulasan Shopee COD

Eka Irawan¹, Wendi Robiansyah², Widodo Saputra³, Anjar Wanto⁴

^{1*,2,3,4} STIKOM Tunas Bangsa, Pematangssiantar, Indonesia

^{1*}eka.irawan@amiktunasbangsa.ac.id, ²wendirobiansyah@amiktunasbangsa.ac.id,

³widodo@amiktunasbangsa.ac.id, ⁴anjarwanto@amiktunasbangsa.ac.id

*) eka.irawan@amiktunasbangsa.ac.id

Abstrak-Layanan *Cash on Delivery* (COD) di platform *e-commerce* Shopee sering kali menghasilkan ribuan ulasan pengguna dengan pola bahasa nonbaku, sehingga diperlukan sistem analisis sentimen yang otomatis dan akurat. Penelitian ini bertujuan untuk mengkategorikan sentimen ulasan Shopee menjadi positif dan negatif menggunakan algoritma Support Vector Machine (SVM) yang dioptimalkan dengan Particle Swarm Optimization (PSO). Tantangan utama dalam analisis teks adalah dimensi fitur yang tinggi yang dapat mempengaruhi kinerja model. Oleh karena itu, PSO digunakan sebagai metode seleksi fitur untuk memilih subset kata paling relevan dari ekstraksi fitur TF-IDF. Hasil penelitian menunjukkan bahwa integrasi PSO berhasil mengurangi dimensi fitur hingga 43,6% dari 1.000 fitur awal. Meskipun jumlah fitur berkurang secara signifikan, model SVM-PSO mampu meningkatkan akurasi menjadi 81,21%, naik dari model baseline yang sebelumnya mencapai 78,79%. Dengan nilai AUC sebesar 0,845, model tetap stabil dan efisien dalam mengenali sentimen walaupun menggunakan jumlah fitur yang lebih sedikit. Penelitian ini membuktikan bahwa optimasi PSO efektif dalam menghilangkan fitur-fitur noise serta memfokuskan model pada kata-kata dengan muatan emosi yang kuat.

Kata Kunci: Analisis Sentimen, Support Vector Machine, Particle Swarm Optimization, Seleksi Fitur, Shopee COD

Abstract-The Cash on Delivery (COD) service provided by the Shopee e-commerce platform often elicits a large volume of user reviews that exhibit unconventional language structures, prompting the need for a precise and automated sentiment analysis mechanism. This research endeavor seeks to categorize sentiments expressed in Shopee reviews as either positive or negative by leveraging the Support Vector Machine (SVM) algorithm, which has been fine-tuned using Particle Swarm Optimization (PSO). A key obstacle in text analysis lies in the vast feature space, which can impair model efficacy. Thus, PSO is utilized as a feature selection technique to identify the most pertinent set of terms from the TF-IDF feature extraction. The findings reveal that the integration of PSO successfully decreased feature dimensionality by 45% from the initial set of 1,000 features. Despite the substantial reduction in features, the SVM-PSO model achieved an enhanced accuracy of 81.21%, surpassing the baseline model's 78.79%. With an AUC value of 0.845, it is evident that the model retains stability and effectiveness in discerning sentiment even with a considerably reduced feature set. This investigation illustrates the efficacy of PSO optimization in eliminating extraneous features and refining the model's focus on sentiment-carrying vocabulary.

Keywords: Sentiment Analysis, Support Vector Machine, Particle Swarm Optimization, Feature Selection, Shopee COD

1. PENDAHULUAN

Perkembangan teknologi informasi dan komunikasi telah mengubah lanskap industri perdagangan di Indonesia secara signifikan [1][2]. Salah satu manifestasi utama dari transformasi ini adalah pertumbuhan pesat platform *e-commerce* [3]. Diantara berbagai penyedia layanan, Shopee berhasil mengukuhkan posisinya sebagai salah satu platform pasar daring yang paling banyak digunakan oleh masyarakat[4]. Untuk menjangkau konsumen yang tidak memiliki akses ke perbankan digital atau masih meragukan keamanan transaksi daring, menghadirkan fitur *Cash on Delivery* (COD)[5][6]. Fitur pembayaran di tempat ini menjadi salah satu pendorong utama peningkatan volume transaksi, terutama di daerah penunjang dan pedesaan[7].

Namun, implementasi fitur COD tidak luput dari berbagai dinamika dan tantangan[6]. Interaksi langsung antara kurir dan pembeli sering kali memicu berbagai ragam opini, baik berupa kepuasan terhadap fleksibilitas metode pembayaran, maupun keluhan terkait keterlambatan pengiriman, ketidaksesuaian barang, hingga kesalahpahaman regulasi sistem COD[8]. Fenomena ini menghasilkan akumulasi data ulasan teks yang sangat besar di media sosial dan platform digital[9]. Di dalam tumpukan data tekstual tersebut, terdapat informasi berharga mengenai sentimen publik yang dapat diekstraksi untuk memahami persepsi konsumen secara mendalam[10]. Oleh karena itu, analisis sentimen menjadi instrumen yang sangat krusial bagi penyedia layanan untuk mengevaluasi kualitas fitur COD dan menyusun strategi perbaikan layanan ke depan[11].

Secara teknis, analisis sentimen teks ulasan merupakan bagian dari bidang *Natural Language Processing* (NLP) dan *Text Mining*[12][13]. Salah satu algoritma pembelajaran mesin (*machine learning*) yang paling populer dan terbukti efektif untuk klasifikasi teks berdimensi tinggi adalah *Support Vector Machine* (SVM)[14]. SVM bekerja dengan cara menemukan *hyperplane* optimal yang memisahkan data antar-kelas dengan margin maksimal [15]. Dalam banyak penelitian sebelumnya, SVM menunjukkan performa akurasi yang unggul dibandingkan algoritma konvensional lainnya seperti *Naive Bayes* atau *Decision Tree* dalam menangani data teks yang *sparse*[16][17].


Meskipun memiliki keunggulan struktur, performa SVM sangat sensitif terhadap pemilihan parameter internal, seperti parameter penalti dan parameter kernel, khususnya *Radial Basis Function* (RBF) yang melibatkan parameter γ [18]. Pemilihan nilai parameter yang kurang tepat atau dilakukan secara acak (*trial and error*) sering kali menyebabkan model mengalami masalah *overfitting* atau *underfitting*, yang pada akhirnya menurunkan akurasi klasifikasi secara drastis[19]. Selain itu, pencarian parameter secara manual atau menggunakan metode *Grid Search* konvensional membutuhkan waktu komputasi yang sangat lama dan kurang efisien ketika dihadapkan pada volume data ulasan yang masif[20].

Untuk mengatasi keterbatasan tersebut, pendekatan metaheuristik berbasis optimasi swarm sering diintegrasikan untuk mencari kombinasi parameter SVM secara otomatis dan cerdas[21][22]. Salah satu algoritma optimasi yang paling efisien dan adaptif adalah *Particle Swarm Optimization* (PSO)[23]. Keunggulan PSO terletak pada konsep mekanika pergerakan kawanan yang mengombinasikan pengalaman lokal (*local best*) dan pengalaman global (*global best*) untuk menemukan solusi optimal dalam ruang pencarian secara cepat[24]. Integrasi PSO dalam SVM (PSO-SVM) terbukti mampu mempercepat waktu konvergensi dan secara signifikan meningkatkan akurasi klasifikasi pada berbagai domain studi kasus linear maupun non-linear[25].

Penelitian terdahulu telah banyak menerapkan kombinasi SVM dan PSO untuk optimasi klasifikasi, seperti pada analisis sentimen produk umum[26], ulasan aplikasi layanan industri[27], hingga opini politik[28]. Namun, penelitian yang secara spesifik mengeksplorasi optimasi SVM berbasis PSO pada sentimen ulasan fitur Shopee COD dengan karakteristik bahasa media sosial yang tidak baku masih sangat terbatas[29]. Penelitian ini bertujuan untuk mengimplementasikan dan menganalisis performa optimalisasi algoritma SVM menggunakan PSO dalam mengklasifikasikan sentimen ulasan pengguna Shopee COD, dan dapat memberikan rekomendasi strategis yang akurat bagi pengembangan sistem *e-commerce* di Indonesia. Melalui penerapan teknik klasifikasi sentimen yang tepat, data teks yang awalnya tidak terstruktur dapat diubah menjadi informasi terstruktur yang kaya akan wawasan (*insight*). Informasi hasil klasifikasi ini-baik berupa sentimen positif, negatif, maupun netral-menjadi aset yang sangat berharga. Bagi pelaku industri atau penyedia layanan, komparasi data sentimen ini berfungsi sebagai bahan evaluasi performa, alat pemantauan reputasi merek (*brand monitoring*), hingga instrumen utama dalam pengambilan keputusan strategis demi meningkatkan kepuasan dan pengalaman pengguna secara berkelanjutan.

2. METODOLOGI PENELITIAN

Penelitian ini menerapkan metode eksperimen kuantitatif untuk meningkatkan klasifikasi sentimen pada review layanan *Cash on Delivery* (COD) Shopee. Proses penelitian direncanakan secara terstruktur mulai dari pengolahan data awal, ekstraksi fitur, penyempurnaan pemilihan fitur dengan menggunakan *Particle Swarm Optimization* (PSO), sampai dengan evaluasi model *Support Vector Machine* (SVM). Kerangka metodologi penelitian secara lengkap dijelaskan dalam Gambar 1.



Gambar 1. Rancangan Penelitian

1. Mulai
Pada Tahap awal atau titik mulai dari seluruh rangkaian proses system yang akan di lakukan.
2. Input Data: Ulasan Shopee COD
Proses memasukkan dataset mentah (*raw data*) berupa ulasan atau *review* dari pengguna mengenai layanan Shopee COD (*Cash on Delivery*).
3. Pra-Pemrosesan Data: Cleaning, Slang, Stopword

Pada tahap ini pembersihan data teks agar siap dianalisis. Proses ini biasanya meliputi: Cleaning: Menghapus karakter yang tidak diperlukan seperti angka, tanda baca, emoji, atau URL, Slang: Mengubah kata-kata tidak baku/gaul menjadi kata baku sesuai kamus bahasa Indonesia dan Stopword: Menghapus kata-kata umum yang sering muncul tetapi tidak memiliki makna penting dalam analisis sentimen (misalnya: "yang", "dan", "di").

4. Ekstraksi Fitur: TF-IDF Unigram

Pada tahapan ini akan dilakukan pengubahan data teks baku menjadi representasi angka (vektor). Metode TF-IDF (*Term Frequency-Inverse Document Frequency*) digunakan untuk menghitung bobot pentingnya suatu kata dalam dokumen. Pendekatan Unigram berarti pembobotan dilakukan per satu kata tunggal.

5. Split Data 80:20

Pada tahapan ini akan dilakukan pembagian dataset yang telah diekstraksi menjadi dua bagian secara acak, yaitu 80% untuk Data Latih (Training Data) yang digunakan untuk melatih model, dan 20% untuk Data Uji (Testing Data) yang digunakan untuk menguji performa model.

6. Seleksi Fitur PSO (Mencari Fitur Terbaik) (*Kotak Garis Putus-putus*)

Tahap optimasi menggunakan algoritma PSO (Particle Swarm Optimization). Tujuannya adalah untuk menyeleksi dan memilih fitur-fitur (kata-kata) yang paling relevan dan berpengaruh besar terhadap sentimen, serta membuang fitur yang tidak penting agar kinerja model lebih cepat dan akurat.

7. Pelatihan SVM (Kernel Linear)

Proses klasifikasi menggunakan algoritma SVM (Support Vector Machine) dengan Kernel Linear. Di tahap ini, model belajar memisahkan data ke dalam kategori sentimen (misalnya: Positif atau Negatif) berdasarkan data latih yang sudah dioptimalkan oleh PSO.

8. Evaluasi Kinerja: Akurasi, CM, ROC

Mengukur seberapa baik model dalam melakukan klasifikasi menggunakan data uji. Metrik yang digunakan meliputi: Akurasi: Persentase prediksi yang benar dari keseluruhan data, CM (Confusion Matrix): Tabel evaluasi untuk melihat detail klasifikasi yang benar dan salah (True Positive, False Positive, dll) dan ROC (Receiver Operating Characteristic): Kurva grafik untuk mengukur performa visual dan performa pemisahan kelas oleh model.

9. Selesai

Tahap akhir yang menandakan seluruh proses analisis sentimen dan evaluasi model telah selesai dilakukan.

2.1 Pra-Pemrosesan Data

Kualitas model klasifikasi sangat dipengaruhi oleh kualitas data input. Oleh karena itu, untuk mengurangi suara dan menstandarisasi format, data ulasan Shopee yang tidak terstruktur harus melalui tahap pra-pemrosesan. Pada tahap awal, seluruh karakter diubah menjadi huruf kecil (*lowercase*) untuk konsistensi. Untuk menghilangkan elemen non-alfabetik seperti angka, tanda baca, dan simbol yang tidak berguna, Data Cleaning juga menggunakan teknik *Regular Expression*, atau *Regex*.

Tahap Normalisasi Slang digunakan untuk mengubah kata tidak baku menjadi bentuk baku yang didasarkan pada kamus referensi (misalnya, mengubah "sy" menjadi "saya"). Ini dilakukan karena banyaknya penggunaan bahasa informal. Terakhir, *Stopword Removal* menggunakan pustaka sastrawi untuk menghilangkan kata hubung, atau kata kerja, yang sering muncul tetapi tidak memberikan banyak informasi tentang perasaan. Proses ini menghasilkan sekumpulan token bersih yang siap digunakan untuk fitur-fiturnya.

2.2 Ekstraksi Fitur

Tahapan ekstraksi fitur bertujuan untuk mengubah data teks tidak terstruktur menjadi representasi vektor numerik yang dapat diproses oleh algoritma Mesin Support Vector (SVM). Dalam penelitian ini, metode pembobotan TF-IDF (*Term Frequency-Inverse Document Frequency*) digunakan. Metode ini dapat digunakan untuk menilai seberapa penting satu kata atau term dalam dokumen dibandingkan dengan kumpulan seluruh dokumen.

Untuk menghitung bobot TF-IDF (W_{ij}) untuk kata i dalam dokumen j , persamaan berikut digunakan:

$$W_{ij} = TF_{ij} \times IDF_i \quad (1)$$

Dimana TF_{ij} mengacu pada frekuensi kemunculan kata i pada dokumen j . Sementara itu, perhitungan nilai IDF_i (*Inverse Document Frequency*) dilakukan untuk mengurangi bobot kata yang terlalu umum, dengan menggunakan rumus berikut:

$$IDF_i = \log \left(\frac{N}{DF_i} \right) \quad (2)$$

Dimana:

N : Total jumlah dokumen (ulasan) dalam dataset.

DFi : Jumlah dokumen yang mengandung kata i.

Melalui prosedur ini, kata-kata umum yang muncul secara konsisten dalam hampir setiap dokumen (seperti "barang" atau "saya") akan cenderung memiliki nilai DFi yang tinggi, sehingga nilai IDF dan bobot akhirnya akan menjadi relatif rendah. Sebaliknya, kata-kata yang bersifat spesifik dan memuat nilai diskriminatif yang tinggi terhadap sentimen (seperti "rusak", "cepat", atau "puas") akan diberikan bobot yang lebih signifikan.

Dalam implementasinya, studi ini menggunakan skema Unigram (satu kata) untuk proses vektorisasi. Untuk menjaga efisiensi komputasi, ekstraksi dibatasi pada 1.000 fitur kata dengan bobot tertinggi. Fitur-fitur awal ini selanjutnya akan diseleksi lebih lanjut menggunakan algoritma optimasi Particle Swarm Optimization (PSO) guna mendapatkan subset fitur yang paling optimal.

2.3 Optimasi Seleksi Fitur dengan Particle Swarm Optimization

Pada fase ini, metode *Binary Particle Swarm Optimization* (BPSO) digunakan untuk mengurangi dimensi fitur yang dihasilkan dari ekstraksi TF-IDF. PSO beroperasi dengan menghasilkan sekelompok partikel yang bergerak dalam ruang pencarian untuk menemukan solusi optimal secara global. Dalam konteks penelitian ini, masing-masing partikel mewakili satu subset fitur yang unik (kombinasi kata-kata tertentu).

Mekanisme seleksi fitur diterapkan dengan menggambarkan setiap partikel sebagai vektor biner yang panjangnya sama dengan jumlah fitur asal (1.000 fitur). Ketika nilai '1' terdapat pada vektor, itu menandakan bahwa fitur kata tersebut terpilih untuk digunakan dalam proses klasifikasi; sebaliknya, ketika nilai '0' ditemukan, fitur tersebut dianggap sebagai gangguan (noise) dan akan diabaikan.

Proses optimasi dilakukan secara iteratif. Pada tiap iterasi, tiap partikel mengevaluasi kinerjanya menggunakan fungsi kebugaran. Fungsi kebugaran yang digunakan dalam penelitian ini adalah tingkat akurasi yang dihasilkan oleh algoritma SVM. Partikel akan terus memperbarui posisi dan kecepatannya berdasarkan pengalaman terbaiknya sendiri (pBest) dan pengalaman terbaik dari seluruh kawanan (gBest) hingga mencapai batas iterasi maksimum yang ditentukan, yaitu 30 iterasi dengan populasi sebanyak 15 partikel. Hasil akhir dari proses ini adalah subset fitur optimal yang diharapkan dapat meningkatkan efisiensi dan akurasi model klasifikasi.

2.4 Pelatihan Model Klasifikasi (*Model Training*)

Subset optimal dari fitur yang dihasilkan oleh PSO akan dimanfaatkan sebagai masukan untuk mengolah model Support Vector Machine (SVM). SVM bertugas mencari *hyperplane* optimal untuk memisahkan antara kelas sentimen positif dan negatif dengan margin maksimum. Pada penelitian ini, digunakan Kernel Linear dikarenakan efektivitasnya dalam mengelola data teks yang memiliki dimensi tinggi. Proses pelatihan dilakukan dengan membagi data menjadi 80% sebagai data latih (*training set*) untuk pembangunan model, dan 20% sebagai data uji (*testing set*) untuk pengujian.

2.5 Evaluasi Kinerja

Untuk melakukan validasi kehandalan model yang diajukan, evaluasi dilakukan pada 20% data uji yang terpisah dari data latih. Penilaian kinerja didasarkan pada empat parameter utama. Pertama, *Confusion Matrix* digunakan untuk memetakan detail kesalahan prediksi, seperti *False Positive* maupun *False Negative*. Berdasarkan matriks tersebut, dihitung nilai Akurasi sebagai tolok ukur utama keberhasilan model dalam mengklasifikasikan sentimen dengan tepat.

Selain metrik berbasis angka, evaluasi visual juga dilakukan dengan menggunakan Kurva ROC (*Receiver Operating Characteristic*). Kurva ini menunjukkan perbedaan antara tingkat sensitivitas dan spesifisitas model, dan nilai *Area Under Curve* (AUC) berfungsi sebagai indikator kinerja secara keseluruhan. Terakhir, analisis *Learning Curve* digunakan untuk memantau stabilitas model seiring bertambahnya data latih. Ini memastikan bahwa model yang dibuat memiliki kemampuan generalisasi yang baik, atau kemampuan penyesuaian yang baik, dan tidak terlalu menyesuaikan dengan data latih.

3. HASIL DAN PEMBAHASAN

Bagian ini menjelaskan serangkaian hasil eksperimen yang mencakup tahap pra-pemrosesan, seleksi fitur, dan evaluasi model. Fokus analisis utamanya adalah membandingkan kinerja antara model SVM konvensional (*Baseline*) dan model SVM yang sudah dioptimalkan menggunakan algoritma *Particle Swarm Optimization* (PSO). Evaluasi ini dilakukan untuk menguji seberapa efektif seleksi fitur dalam meningkatkan akurasi dan efisiensi model.

3.1 Data Awal (*Raw Data*)

Penelitian ini menggunakan dataset ulasan pelanggan Shopee mengenai layanan COD. Total data mentah yang dikumpulkan berjumlah 1.840 ulasan. Setiap entri data memuat informasi tekstual berupa opini pengguna serta rating numerik.

Tabel 1. Sample Data Mentah (*Raw Data*)

No	Konten Ulasan	Rating (1-5)	Label Konversi
1	"Alhamdulillah paket mendarat dgn aman.. kurir langganan, mantull 🍑"	5	Positif
2	"KECEWA BERAT!! pesen warna hitam dtg merah.. nyesel byr cod 😡"	1	Negatif
3	"Lumayan lah harga segitu, pengiriman standar 3 hari nyampe."	3	(Dieliminasi)
4	"Gk bisa dipake, brg rongsokan dijual.. tolong dong dicek dulu sblm krm"	1	Negatif
5	"Bagus bgt, realpict.. next order lagi disini fix! mksh seller"	4	Postif
...	...	...	...
1840	"Gak mau lagi pake cod, ribet"	2	Negatif

Tabel 1 menampilkan ragam data ulasan yang terkumpul. Terlihat bahwa data mentah memiliki beragam pola penulisan, mulai dari penggunaan huruf kapital secara berlebihan (kapitalisasi), singkatan tidak standar ('brg', 'gk', 'dtg'), hingga penggunaan emotikon. Kolom 'Label Konversi' menunjukkan hasil pemetaan skor rating, di mana rating 4 dan 5 digolongkan sebagai sentimen positif, rating 1 dan 2 sebagai negatif, sementara rating 3 dihilangkan karena cenderung bersifat netral dan ambigu.

3.2 Pra-Pemrosesan Data (*Preprocessing Result*)

Tahap pra-pemrosesan memiliki peran penting dalam membersihkan data ulasan yang mengandung banyak noise. Studi ini menerapkan tiga tahapan krusial secara berurutan berdasarkan karakteristik data media sosial yang digunakan, yakni: (1) *Case Folding & Cleaning*, (2) Normalisasi Slang, dan (3) Penghapusan Stopword.

3.2.1 Case Folding dan Cleaning

Tahap awal bertujuan meratakan format teks ke huruf kecil dan menghilangkan elemen non-alfabetik yang tidak relevan seperti angka, tanda baca, simbol, dan emotikon. Tabel 2 menunjukkan hasil dari proses ini.

Tabel 2. Hasil Tahap Case Folding dan Cleaning

No	Data Mentah (Raw Data)	Hasil Cleaning & Case Folding
1	"Barangnya BAGUS bgt!! Pengiriman cpt 100%."	barangnya bagus bgt pengiriman cpt
2	"Kecewa parah... brg yg dikirim rusak :("	kecewa parah brg yg dikirim rusak
3	"Sy gk mau belanja d sini lg, kapok!!"	sy gk mau belanja d sini lg kapok

Pada Tabel 2, terdapat penurunan seluruh huruf kapital menjadi huruf kecil. Angka "100%", tanda baca "!!!", "...", dan simbol emosi ":(" berhasil dihilangkan, sehingga hanya karakter huruf yang tersisa.

3.2.2 Slang Normalization

Tahap ini melakukan pemetaan singkatan atau bahasa gaul menjadi bentuk baku Bahasa Indonesia, guna menghindari pemrosesan kata "bgt" dan "banget" sebagai dua fitur yang berbeda. Data masukan tahap ini merupakan keluaran dari Tabel 2.

Tabel 3. Hasil Tahap Normalisasi Slang

No	Input (Hasil Tahap 1)	Normalisasi Slang	Perubahan Kata
1	barangnya bagus bgt pengiriman cpt	barangnya bagus banget pengiriman cepat	bgt → banget, cpt → cepat
2	kecewa parah brg yg dikirim rusak	kecewa parah barang yang dikirim rusak	brg → barang, yg → yang
3	sy gk mau belanja d sini lg kapok	saya tidak mau belanja di sini lagi kapok	sy → saya, gk → tidak

Tabel 3 menunjukkan peningkatan yang signifikan dalam perbaikan kata singkatan. Kata "gk" telah diubah menjadi "tidak", sedangkan "brg" telah diubah menjadi "barang". Proses ini sangat membantu model dalam menangkap konteks sentimen yang sebenarnya.

3.2.3 Stopword Removal

Tahap terakhir yaitu mengurangi dimensi data dengan menghapus kata-kata umum (stopwords) yang sering muncul tetapi memiliki sedikit informasi, seperti kata sambung atau kata depan. Input untuk tahap ini merupakan hasil dari Tabel 3.

Tabel 4. Hasil Tahap Stopword Removal

No	Input (Hasil Tahap 2)	Output Akhir (<i>Final Tokens</i>)	Kata yang dihapus
1	barangnya bagus banget pengiriman cepat	barangnya bagus banget pengiriman cepat	(Tidak Ada)
2	kecewa parah barang yang dikirim rusak	kecewa parah barang dikirim rusak	“yang”
3	saya tidak mau belanja di sini lagi kapok	saya tidak belanja sini lagi kapok	“mau”, “di”

Berdasarkan Tabel 4, kata “yang”, “mau”, dan “di” telah dihapus dari teks karena termasuk dalam daftar stopwords. Data bersih dan siap dikonversi menjadi vektor numerik untuk tahap ekstraksi fitur terdapat dalam kolom ‘Output Akhir’.

3.3 Ekstraksi Fitur (*Feature Extraction Result*)

Setelah melewati proses pra-pemrosesan, data teks yang telah bersih diubah menjadi representasi vektor numerik untuk kemudian diproses secara matematis oleh algoritma pembelajaran mesin. Studi ini mengadopsi teknik pembobotan TF-IDF (Term Frequency-Inverse Document Frequency) dengan skema Unigram (satu kata). Untuk menjaga efisiensi komputasi sebelum memasuki tahap optimasi PSO, proses ekstraksi fitur dibatasi pada 1.000 fitur kata yang memiliki bobot tertinggi. Setiap dokumen ulasan diwakili sebagai vektor dengan dimensi 1.000, di mana nilai tiap elemen vektor mencerminkan tingkat urgensi kata tersebut dalam dokumen. Ilustrasi dari hasil pembobotan TF-IDF pada beberapa contoh dokumen terdapat dalam Tabel 5.

Tabel 5. Sampel Matriks Pembobotan TF-IDF


No Dok.	“Bagus”	“rusak”	“cepat”	“kecewa”	“mantap”	“tidak”	...(hingga 100 fitur)
1	0.521	0.000	0.438	0.000	0.312	0.000	...
2	0.000	0.615	0.000	0.582	0.000	0.210	...
3	0.000	0.000	0.395	0.000	0.000	0.455	...
...	...	...	...	...	...	...	...

Berdasarkan Tabel 5, setiap baris merepresentasikan dokumen ulasan dan kolom sebagai fitur kata. Nilai bobot positif (seperti 0.521) mencerminkan tingkat signifikansi kata dalam dokumen, sedangkan nilai 0.000 menunjukkan sparsity (ketidakhadiran kata). Matriks vektor berdimensi $N \times 1000$ ini selanjutnya digunakan sebagai input utama untuk proses optimasi seleksi fitur menggunakan algoritma PSO.

3.4 Optimasi Seleksi Fitur dengan PSO


Setelah data telah diubah menjadi vektor numerik melalui proses ekstraksi fitur, langkah berikutnya adalah melakukan reduksi dimensi dengan menerapkan algoritma Particle Swarm Optimization (PSO). Tujuan utama dari tahapan ini adalah untuk menyeleksi subset fitur yang paling informatif dari total 1.000 fitur awal, dengan tujuan meningkatkan efisiensi komputasi dan akurasi model.

Proses optimisasi dilakukan menggunakan 15 partikel sebagai populasi dan dengan batasan 30 iterasi sebagai batas maksimum. Perilaku pencarian solusi optimal oleh kawanan partikel dapat dipantau melalui grafik riwayat biaya (Cost History) pada Gambar 2.



Gambar 2. Grafik Konvergensi Algoritma PSO (*Cost History*)

Grafik menunjukkan kecenderungan penurunan yang drastis pada fase awal (iterasi 0 hingga 10). Hal ini mengindikasikan bahwa kawanan partikel berhasil melakukan eksplorasi ruang pencarian dengan efektif dan menemukan kombinasi fitur yang menghasilkan akurasi lebih tinggi dengan cepat. Ketika memasuki iterasi ke-20, kurva mulai melandai (plateau), mengisyaratkan bahwa algoritma telah mencapai titik konvergensi. Ini mengindikasikan bahwa posisi global terbaik telah tercapai dan tidak ada perubahan signifikan dalam solusi hingga iterasi berakhir. Stabilitas ini menunjukkan bahwa algoritma PSO mampu menghindari optima lokal dan memberikan hasil seleksi fitur yang konsisten.




Gambar 3. Grafik Bobot Fitur (*Feature Importance*)

Visualisasi bobot fitur pada Gambar 3 memberikan gambaran yang jelas mengenai kata-kata yang menjadi diskriminator utama dalam menentukan sentimen. Fitur dengan bobot positif tertinggi didominasi oleh kata sifat positif seperti "bagus", "suka", dan "mantap". Sebaliknya, fitur dengan bobot negatif didominasi oleh keluhan pelanggan seperti "lelet", "kecewa", dan "aneh". Terdapat temuan menarik dengan munculnya kata "gak" sebagai salah satu fitur dengan bobot yang signifikan. Keberhasilan model dalam mengenali kata informal ini menunjukkan adaptabilitas sistem terhadap karakteristik asli ulasan di media sosial yang cenderung tidak formal. Kata "gak" berperan sebagai pembalik makna (negation) yang penting untuk memahami konteks keluhan pelanggan dengan tepat.

3.5 Evaluasi Kinerja Model

Tahap evaluasi dilakukan untuk menilai sejauh mana kemampuan model SVM yang telah dioptimalkan dengan PSO dalam mengklasifikasikan ulasan sentimen secara akurat. Uji coba dilakukan dengan menggunakan pembagian data dengan rasio 80% untuk data latih dan 20% untuk data uji. Metrik yang digunakan dalam evaluasi ini meliputi akurasi, precision, recall, dan f1-score, serta visualisasi melalui Confusion Matrix untuk melihat detail perbandingan antara label aktual dengan hasil prediksi model sebagaimana terlihat dalam Gambar 4.



Gambar 4. Confusion Matriks Model SVM Baseline dan SVM + PSO

Berdasarkan Gambar 4, model menunjukkan performa yang sangat baik dalam mengenali kedua kelas sentimen. Jumlah prediksi benar pada kelas Positif (True Positive) dan kelas Negatif (True Negative) mendominasi diagonal utama matriks, yang mengindikasikan bahwa model memiliki tingkat kesalahan yang minim dalam membedakan antara ulasan kepuasan dan keluhan pelanggan. Performa ini didukung oleh rangkuman metrik evaluasi yang disajikan pada Tabel 5, di mana hasil pengujian model SVM-PSO dibandingkan dengan model SVM Baseline (tanpa seleksi fitur) untuk melihat dampak nyata dari penerapan optimasi PSO.

Tabel 6. Perbandingan Performa Klasifikasi


Metrik	SVM Baseline (1000 Fitur)	SVM + PSO (± 500)
Akurasi	78.79%	81.21%
Precision	0.79	0.82
Recall	0.78	0.81
F1-Score	0.78	0.81

Tabel 6 menunjukkan bahwa integrasi PSO meningkatkan akurasi sebesar 2.42%. Meskipun kenaikan tingkat akurasi tidak begitu signifikan, pencapaian ini memiliki signifikansi dalam konteks teknis karena model SVM-PSO berhasil beroperasi dengan jumlah fitur yang 43.6% lebih sedikit daripada model baseline. Peningkatan ini mengindikasikan bahwa proses seleksi fitur menggunakan PSO bukan hanya meningkatkan efisiensi komputasi, tetapi juga berhasil mengevaluasi fitur-fitur yang memiliki daya pembeda tertinggi. Dengan menghilangkan fitur-fitur yang bersifat noise atau ambigu, model lebih dapat fokus pada kata-kata kunci yang esensial, sehingga dapat memberikan hasil prediksi yang lebih stabil dan akurat dalam menangani variasi ulasan layanan COD di Shopee.

3.6 Analisis Kurva ROC dan Learning Curve


Hasil evaluasi mendalam terhadap kemampuan model dalam membedakan kelas sentimen dilakukan dengan menggunakan kurva *Receiver Operating Characteristic* (ROC) dan nilai *Area Under Curve* (AUC). Dari hasil pengujian, ditemukan bahwa model SVM Baseline memiliki nilai AUC sebesar 0.847, sementara model SVM-PSO memiliki nilai AUC sebesar 0.845. Meskipun terjadi sedikit penurunan nilai AUC sebesar 0.002, namun performa kedua model tetap dikategorikan sebagai sangat baik (*Excellent Classification*).

Penurunan minimum dalam nilai AUC tersebut merupakan bentuk pertukaran yang wajar dalam proses optimasi seleksi fitur. Dengan mengurangi dimensi hingga 43.6% (memotong sekitar 450 fitur yang dianggap noise), model kehilangan sedikit kemampuan dalam pemisahan probabilitas secara keseluruhan, namun menjadi jauh lebih fokus dan akurat dalam menentukan label sentimen ulasan. Hal ini menunjukkan bahwa PSO berhasil menyaring fitur-fitur yang redundan tanpa mengganggu kemampuan fundamental model dalam mengenali pola sentimen positif dan negatif pada layanan COD Shopee.



Gambar 5. Kurva ROC

Stabilitas model dinilai juga melalui analisis Learning Curve sebagaimana tergambar pada Gambar 5. Grafik tersebut mencerminkan respons model ketika dipelajari dengan ukuran dataset yang berbeda. Dapat diamati bahwa tingkat keakuratan pada data latih dan data validasi cenderung menyatu seiring pertambahan sampel, dengan perbedaan yang minimal di tahap akhir.



Gambar 6. Learning Curve SVM + PSO

Kondisi tersebut menunjukkan bahwa model SVM-PSO berada pada status Fitting yang Baik. Ini berarti, model tidak mengalami overfitting (menghafal data secara berlebihan) maupun underfitting (gagal menangkap pola). Stabilitas yang terlihat dari Learning Curve ini memberikan keyakinan bahwa model seleksi fitur berbasis PSO memiliki kemampuan generalisasi yang kuat, sehingga tetap reliabel saat digunakan untuk memprediksi data ulasan baru di masa mendatang meskipun dengan jumlah fitur yang jauh lebih sedikit dibandingkan model awal.

4. KESIMPULAN

Integrasi algoritma Support Vector Machine (SVM) dan Particle Swarm Optimization (PSO) dalam analisis sentimen ulasan layanan COD Shopee memberikan hasil yang signifikan baik dari aspek performa maupun efisiensi model. Penerapan PSO sebagai metode seleksi fitur terbukti mampu mengatasi permasalahan dimensi data yang tinggi dengan mereduksi jumlah fitur sebesar 45% (dari 1.000 fitur awal menjadi subset yang lebih ringkas). Proses reduksi ini tidak hanya mempercepat waktu komputasi, tetapi juga berhasil menyaring fitur-fitur yang bersifat noise atau netral. Dari sisi kinerja klasifikasi, penggunaan fitur hasil optimasi PSO mampu meningkatkan akurasi model menjadi 81,21%, naik dibandingkan model baseline (tanpa optimasi) yang berada di angka 78,79%. Meskipun terdapat penurunan nilai AUC yang sangat tipis dari 0,847 menjadi 0,845, hal ini merupakan bentuk trade-off yang wajar mengingat model kini bekerja dengan jumlah fitur yang jauh lebih sedikit.

Stabilitas model juga terverifikasi melalui Learning Curve yang menunjukkan kondisi Good Fitting, yang berarti model memiliki kemampuan generalisasi yang kuat terhadap data baru. Secara kualitatif, model terbukti cerdas dalam mengenali pola bahasa di media sosial. Algoritma secara konsisten mempertahankan kata-kata dengan bobot sentimen kuat seperti "bagus", "cepat", dan "rusak", serta tetap mampu menangani bahasa informal dengan menjadikan kata negasi "gak" sebagai fitur penting. Di sisi lain, fitur netral seperti kata "kurir" berhasil dieliminasi karena dianggap tidak memiliki daya pembeda yang kuat. Secara keseluruhan, penelitian ini membuktikan bahwa optimasi PSO efektif dalam menghasilkan model analisis sentimen yang lebih ringan, akurat, dan stabil untuk data ulasan e-commerce.

UCAPAN TERIMAKASIH

Penulis menyampaikan ucapan terima kasih yang tulus dan penghargaan setinggi-tingginya kepada Pengurus Yayasan STIKOM Tunas Bangsa Pematangsiantar atas dukungan finansial dan fasilitas pendanaan penelitian yang diberikan melalui program Hibah Penelitian Internal. Ucapan terima kasih juga disampaikan kepada **STIKOM Tunas Bangsa** yang telah memberikan dukungan akademik, pendampingan, serta sarana dan prasarana penelitian.

REFERENCES

- [1] E. H. Prasetyo, "Digital platforms' strategies in Indonesia: Navigating between technology and informal economy," *Technol. Soc.*, vol. 76, 2024, doi: 10.1016/j.techsoc.2023.102414.
- [2] D. Radiananda Barus *et al.*, "Pengaruh Perkembangan Teknologi Informasi Terhadap Pasar Global," *J. Intelek Insa. Cendikia*, vol. 1, no. 4, pp. 495–500, 2024, [Online]. Available: <https://jicnusantara.com/index.php/jiic>
- [3] O. : Melisa, T. Faisal, and M. I. Fasa, "PT. Media Akademik Publisher TRANSFORMASI DIGITAL: PERAN E-COMMERCE DALAM PERTUMBUHAN EKONOMI DIGITAL DI INDONESIA," *Jma*, vol. 3, no. 4, pp. 3031–5220, 2025.
- [4] F. I. Santoso, *PEMASARAN DIGITAL (Strategi Pemasaran Digital)*. 2024.
- [5] I. Isalman, F. Ramadhani I, I. Ilyas, and S. Sahdarullah, "Investigasi Faktor Pendukung Dan Penghambat Belanja Online Di Kota Kendari," *J. Ilm. Manaj. dan Bisnis*, vol. 7, no. 1, pp. 30–46, 2022, doi: 10.38043/jimb.v7i1.3413.
- [6] S. Simatupang, D. Susanti, M. Butarbutar, K. Indajang, and R. M. Girsang, "Sistem Pembayaran Cash on Delivery Terhadap Keputusan Pembelian di Shopee," *Edunomika*, vol. 8, no. 1, pp. 109–122, 2023.
- [7] R. Angel, "a Study on Online Shopping Behaviour Among Youth 'a Study on Online Shopping Behaviour Among Youth,'" pp. 1–23, 2024.
- [8] Dani Lailatul Magviro and Yasid Amali, "Perlindungan Hukum Terhadap Kurir Paket Dalam Jual Beli Online Dengan Metode Pembayaran Cash on Delivery (Cod)," *J. Sains Student Res.*, vol. 1, no. 1, pp. 1166–1173, 2023, doi: 10.61722/jssr.v1i1.449.
- [9] S. Stieglitz, M. Mirbabaie, B. Ross, and C. Neuberger, "Social media analytics – Challenges in topic discovery, data collection, and data preparation," *Int. J. Inf. Manage.*, vol. 39, no. October 2017, pp. 156–168, 2018, doi: 10.1016/j.ijinfomgt.2017.12.002.
- [10] A. W. Nugroho and A. A. G. S. Utama, "Business Intelligence Systems and Their Impact on Organizational Decision-Making and Performance Outcomes: Literature Review," *Owner*, vol. 9, no. 2, pp. 1269–1284, 2025, doi: 10.33395/owner.v9i2.2646.
- [11] P. K. Sari, A. Alamsyah, and S. Wibowo, "Measuring e-Commerce service quality from online customer review using sentiment analysis," *J. Phys. Conf. Ser.*, vol. 971, no. 1, 2018, doi: 10.1088/1742-6596/971/1/012053.
- [12] M. F. Ramadhan, F. Panjaitan, and H. Oktafiandi, "Analisis Sentimen Kutipan Media Sosial Berbahasa Indonesia Menggunakan Convolutional Neural Network," *J. Komput. , Inf. dan Teknol.*, no. 2, pp. 1–17, 2025.
- [13] M. I. Adrian and E. A. Laksana, "Optimalisasi Parameter Support Vector Machine dengan Algoritma PSO untuk Tugas Klasifikasi Sentimen Ulasan IMDb," *J. Algoritma*, vol. 22, no. 1, pp. 288–299, 2025, doi: 10.33364/algoritma/v.22-1.2306.
- [14] M. Wahiddianty, G. Firmasyah, H. A. Magister, and I. Komputer, "Analisis Sentimen Omnibus Law Pada Umkm Menggunakan Support Vector Machine, Naive Bayes Berbasis Particle Swarm Optimization," *J. Bisnis dan Manaj.*, vol. 3, no. 5, pp. 2477–178, 2023.
- [15] Normah, B. Rifai, S. Vambudi, and R. Maulana, "Analisa Sentimen Perkembangan Vtuber Dengan Metode Support Vector Machine Berbasis SMOTE," *J. Tek. Komput. AMIK BSI*, vol. 8, no. 2, pp. 174–180, 2022, doi: 10.31294/jtk.v4i2.
- [16] M. Nizam Fadli, I. Sudahri Damanik, E. Irawan, S. Tunas Bangsa, and S. Utara, "KLIK: Kajian Ilmiah Informatika dan Komputer Penerapan Metode Naive Bayes Dalam Menentukan Tingkat Kenyamanan

- Pada Rumah Sakit Terhadap Pasien,” *Media Online*, vol. 2, no. 3, pp. 117–122, 2021, [Online]. Available: <https://djournals.com/klik>
- [17] K. Septia *et al.*, “ANALISIS KESADARAN MAHASISWA TERHADAP PRIVASI DATA DENGAN,” vol. 17, no. c, pp. 29–37, 2026.
- [18] W. Silalahi and A. Hartanto, “Klasifikasi Sentimen Support Vector Machine Berbasis Optimasi Menyambut Pemilu 2024,” *JRST (Jurnal Ris. Sains dan Teknol.*, vol. 7, no. 2, p. 245, 2023, doi: 10.30595/jrst.v7i2.18133.
- [19] Y. Omae, “Effects of Exploration Weight and Overtuned Kernel Parameters on Gaussian Process-Based Bayesian Optimization Search Performance,” *Mathematics*, vol. 11, no. 14, pp. 1–13, 2023, doi: 10.3390/math11143067.
- [20] A. Berlian Agustina, H. Permatasari, and J. Maulindar, “Analisis Sentimen Pada Ulasan Tempat Wisata Desa Ponggok Menggunakan Natural Language Processing,” *Pros. Semin. Nas. Teknol. Inf. dan Bisnis*, pp. 50–59, 2025, doi: 10.47701/s9qesx65.
- [21] J. D. Fernández, J. Vega, and S. Dormido-Canto, *GAGS: parallelized genetic algorithm-based grid search for SVM + model optimization*, vol. 32, no. 2. 2026. doi: 10.1007/s10732-026-09588-3.
- [22] M. Béréte, A. Ehtioui, L. Sellami, and A. A. M. Ben Hmida, “Hybrid CNN + LSTM + SVM model for advanced brain tumor classification,” *Netw. Model. Anal. Heal. Informatics Bioinforma.*, vol. 15, no. 1, pp. 1–23, 2026, doi: 10.1007/s13721-025-00718-8.
- [23] G. Urva, K. Azmi, and W. Desriyati, “Model Optimalisasi Pemilihan Ekstrakurikuler Menggunakan Algoritma Particle Swarm Optimization (PSO),” *J. Algoritm.*, vol. 22, no. 2, pp. 268–276, 2025, doi: 10.33364/algoritma/v.22-2.2488.
- [24] T. Atha Anastasya, A. Diani Putri Saka, M. Juventus Dappa Deke, and A. Mustika Rizki, “Optimasi Algoritma Svm Dengan Pso Untuk Analisis Sentimen Pada Media Sosial X Terhadap Kinerja Timnas Di Era Shin Tae-Yong,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 1, pp. 384–391, 2024, doi: 10.36040/jati.v9i1.12298.
- [25] A. A. G. A. Pranandita and I. M. Widiartha, “Optimasi Metode Support Vector Machine (SVM) Menggunakan Particle Swarm Optimization pada Permasalahan Klasifikasi Diabetes,” *J. Nas. Teknol. Inf. dan Apl.*, vol. 3, no. 4, pp. 879–888, 2025, [Online]. Available: <https://ejournal2.unud.ac.id/index.php/jnatia/article/view/46>
- [26] Wildan Nugraha and Mardi Hardjianto, “Optimasi Support Vector Machines (SVM) Menggunakan Particle Swarm Optimization (PSO) pada Analisis Sentimen Ulasan Pengguna Layanan Bukalapak di Twitter,” *Decod. J. Pendidik. Teknol. Inf.*, vol. 4, no. 3, pp. 1082–1100, 2024, doi: 10.51454/decode.v4i3.686.
- [27] A. S. Rusydiana, I. Firmansyah, and L. Marlina, “Sentiment Analysis of Microtakaful Industry: Comparison between Indonesia and Malaysia,” *Int. J. Nusantara Islam*, vol. 6, no. 1, pp. 20–34, 2019, doi: 10.15575/ijni.v6i1.3004.
- [28] D. A. Kristiyanti, S. A. Sanjaya, Irmawati, K. Ekachandra, J. Suhali, and A. H. Umam, “Comparison of Salp Swarm Algorithm and Particle Swarm Optimization as Feature Selection Techniques for Recession Sentiment Analysis in Indonesia,” *Int. J. Informatics Vis.*, vol. 9, no. 5, pp. 2080–2087, 2025, doi: 10.62527/joiv.9.5.3102.
- [29] N. F. Adhim and N. Cahyono, “Optimization of IndoBERT for Sentiment Analysis of FOMO on Social Media Through Fine-Tuning and Hybrid Labeling,” *J. Appl. Informatics Comput.*, vol. 9, no. 6, pp. 3786–3797, 2025, doi: 10.30871/jaic.v9i6.11686.