



Peningkatan Kinerja Analisis Sentimen Ulasan Pengguna Aplikasi Dompot Digital Menggunakan Support Vector Machine Melalui Optimasi Seleksi Fitur Particle Swarm Optimization

Tengku Hadi Somad Fuddin^{1*}, Mahardika Abdi Prawira Tanjung²

^{1,2}Program Studi Sistem Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara, Medan, Indonesia

Email: ¹hadytengku8@gmail.com, ²mahardikaabdiprawira@umsu.ac.id

Abstrak

Pertumbuhan pengguna dompet digital di Indonesia memunculkan kebutuhan untuk memahami persepsi pengguna melalui analisis sentimen ulasan. Penelitian ini bertujuan untuk meningkatkan kinerja klasifikasi sentimen ulasan pengguna aplikasi dompet digital menggunakan Support Vector Machine (SVM) melalui optimasi seleksi fitur berbasis Particle Swarm Optimization (PSO). Data dikumpulkan dari Google Play Store sebanyak 10.000 ulasan yang berasal dari lima aplikasi dompet digital, yaitu GoPay, OVO, Dana, LinkAja, dan ShopeePay, dengan masing-masing 2.000 ulasan per aplikasi. Ulasan diklasifikasikan ke dalam tiga kelas sentimen: positif, negatif, dan netral. Proses ekstraksi fitur dilakukan menggunakan Term Frequency-Inverse Document Frequency (TF-IDF) yang menghasilkan 5.000 fitur. Selanjutnya, Binary PSO diterapkan untuk melakukan seleksi fitur dan berhasil mereduksi dimensi fitur menjadi 1.326 fitur atau sekitar 26,52% dari total fitur awal. Hasil pengujian menunjukkan bahwa model SVM tanpa seleksi fitur memperoleh akurasi sebesar 88,00%, sedangkan model SVM dengan seleksi fitur Chi-Square menghasilkan akurasi sebesar 91,00%. Model SVM dengan seleksi fitur PSO menghasilkan akurasi tertinggi sebesar 93,75%, precision sebesar 93,86%, recall sebesar 93,75%, dan F1-score sebesar 93,79%. Dengan demikian, penerapan PSO berhasil meningkatkan akurasi sebesar 5,75 poin persentase dibandingkan model baseline. Penelitian ini menunjukkan bahwa kombinasi TF-IDF, Binary PSO, dan SVM merupakan pendekatan yang efektif untuk analisis sentimen ulasan pengguna dompet digital.

Kata Kunci: analisis sentiment, support vector machine, particle swarm optimization, seleksi fitur, dompet digital.

PENDAHULUAN

Perkembangan teknologi finansial di Indonesia telah mendorong pertumbuhan penggunaan dompet digital secara signifikan. Berdasarkan Laporan Perkembangan Uang Elektronik yang diterbitkan oleh Bank Indonesia (2023), volume transaksi uang elektronik di Indonesia mengalami peningkatan yang konsisten dari tahun ke tahun. Aplikasi dompet digital seperti GoPay, OVO, Dana, LinkAja, dan ShopeePay telah menjadi bagian dari kehidupan sehari-hari masyarakat dalam melakukan berbagai transaksi pembayaran digital. Pertumbuhan pengguna yang masif ini juga menghasilkan jutaan ulasan di platform distribusi aplikasi seperti Google Play Store yang mencerminkan persepsi dan pengalaman nyata pengguna terhadap layanan dompet digital.

Analisis sentimen merupakan salah satu bidang dalam pemrosesan bahasa alami yang bertujuan untuk mengidentifikasi dan mengekstraksi opini subjektif dari teks (Liu 2022). Melalui analisis sentimen, pengembang aplikasi dapat memahami umpan balik pengguna secara otomatis dan terstruktur, sehingga dapat digunakan sebagai dasar pengambilan keputusan dalam pengembangan produk. Penelitian sebelumnya telah menunjukkan efektivitas analisis sentimen berbasis machine learning dalam berbagai domain. Alharbi & Al-Khalifa (2021) berhasil menerapkan analisis sentimen pada ulasan berbahasa Arab terkait pembelajaran jarak jauh dengan akurasi yang memuaskan, sementara Rustam et al. (2021) mendemonstrasikan perbandingan berbagai metode machine learning untuk analisis sentimen cuitan COVID-19. Wankhade et al. (2022) menyajikan tinjauan komprehensif mengenai metode, aplikasi, dan tantangan analisis sentimen dalam berbagai konteks penggunaan.

Support Vector Machine (SVM) merupakan salah satu algoritma machine learning yang banyak digunakan untuk klasifikasi teks karena kemampuannya dalam menangani data berdimensi tinggi dan kemampuan generalisasi yang baik (Cortes & Vapnik 1995; Ahuja et al. 2022). Namun, dalam konteks

klasifikasi teks, representasi fitur berbasis Term Frequency-Inverse Document Frequency (TF-IDF) dapat menghasilkan ruang fitur yang sangat besar dengan banyak fitur yang tidak relevan atau redundan (Qaiser & Ali 2018). Kondisi ini dapat menurunkan kinerja model dan meningkatkan kompleksitas komputasi. Lowell et al. (2025) dalam penelitiannya tentang analisis sentimen ulasan aplikasi OVO menunjukkan bahwa pemilihan metode dan konfigurasi fitur berpengaruh signifikan terhadap kinerja klasifikasi.

Seleksi fitur merupakan teknik yang bertujuan untuk memilih subset fitur yang paling relevan dan informatif dari ruang fitur yang ada, sehingga dapat meningkatkan kinerja model sekaligus mengurangi kompleksitas komputasi (Mafarja & Mirjalili 2018; Faris et al. 2020). Particle Swarm Optimization (PSO) merupakan metode optimasi berbasis swarm intelligence yang diperkenalkan oleh Kennedy & Eberhart (1995) dan telah terbukti efektif dalam menyelesaikan masalah seleksi fitur dalam berbagai domain. PSO bekerja dengan mensimulasikan perilaku kawanan partikel yang bergerak dalam ruang pencarian untuk menemukan solusi optimal berdasarkan fungsi fitness tertentu.

Penelitian di bidang klasifikasi teks berbahasa Indonesia, termasuk analisis sentimen, memiliki tantangan tersendiri karena karakteristik bahasa Indonesia yang kaya dengan kata slang, singkatan, dan variasi penulisan informal (Wankhade et al. 2022; Zhang et al. 2022). Selain itu, kajian mengenai penerapan metode klasifikasi berbasis kecerdasan buatan telah berkembang pesat, termasuk dalam konteks sistem berbasis pengetahuan (Sembiring & Syahra 2026). Pada konteks analisis sentimen ulasan dompet digital, kombinasi antara TF-IDF sebagai metode ekstraksi fitur, PSO sebagai metode seleksi fitur, dan SVM sebagai classifier belum banyak dikaji secara komprehensif dengan membandingkan langsung terhadap metode seleksi fitur konvensional seperti Chi-Square.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja model SVM dalam analisis sentimen ulasan pengguna aplikasi dompet digital dengan tiga skenario: (1) SVM tanpa seleksi fitur sebagai baseline, (2) SVM dengan seleksi fitur Chi-Square sebagai pembanding, dan (3) SVM dengan seleksi fitur PSO sebagai model yang diusulkan. Kontribusi penelitian ini mencakup (a) pengumpulan dan anotasi dataset ulasan dompet digital dalam bahasa Indonesia berskala besar, (b) penerapan Binary PSO untuk seleksi fitur dalam konteks analisis sentimen ulasan dompet digital, serta (c) evaluasi komparatif yang sistematis antar tiga pendekatan tersebut.

METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan jenis penelitian eksperimental. Metode yang diterapkan meliputi pengumpulan data, pra-pemrosesan teks, ekstraksi fitur, seleksi fitur, klasifikasi, dan evaluasi. Keseluruhan proses implementasi dilakukan menggunakan bahasa pemrograman Python 3.9 dengan library utama scikit-learn, NLTK, Sastrawi, PySwarms, Pandas, dan NumPy pada lingkungan Jupyter Notebook.

Pengumpulan Data

Data dikumpulkan dari Google Play Store menggunakan library google-play-scraper. Pengumpulan data dilakukan terhadap ulasan dari lima aplikasi dompet digital yang populer di Indonesia, yaitu GoPay, OVO, Dana, LinkAja, dan ShopeePay. Dari masing-masing aplikasi dikumpulkan sebanyak 2.000 ulasan, sehingga total dataset berjumlah 10.000 ulasan.

Tabel 1. Distribusi Data Ulasan per Aplikasi

No	Aplikasi	Jumlah Ulasan
1	GoPay	2.000
2	OVO	2.000
3	Dana	2.000
4	LinkAja	2.000
5	ShopeePay	2.000
Total		10.000

Proses anotasi label dilakukan secara manual oleh tiga orang anotator terlatih. Setiap ulasan diklasifikasikan ke dalam tiga kelas sentimen: positif, negatif, dan netral berdasarkan panduan anotasi yang telah ditetapkan. Kesepakatan antar-anotator diukur menggunakan Cohen's Kappa dan menghasilkan nilai $\kappa = 0,84$, yang menunjukkan tingkat kesepakatan yang sangat baik (substantial to near perfect agreement). Label final ditentukan berdasarkan kesepakatan mayoritas (majority voting). Distribusi label dalam dataset ditampilkan pada Tabel 2.

Tabel 2. Distribusi Label Sentimen

Kelas Sentimen	Jumlah Data	Persentase
Positif	5.000	50,00%
Negatif	3.500	35,00%
Netral	1.500	15,00%
Total	10.000	100,00%

Pra-pemrosesan Teks

Pra-pemrosesan teks merupakan tahap penting untuk mempersiapkan data sebelum proses ekstraksi fitur. Tahapan pra-pemrosesan yang diterapkan dalam penelitian ini adalah sebagai berikut.

1. Case Folding: Mengubah seluruh karakter huruf menjadi huruf kecil untuk menyeragamkan representasi teks.
2. Cleaning: Menghapus karakter yang tidak relevan, seperti tanda baca, angka, URL, dan karakter khusus lainnya.
3. Normalisasi Kata Slang: Mengganti kata-kata tidak baku, singkatan, dan kata slang dengan bentuk standar menggunakan kamus slang bahasa Indonesia.
4. Tokenisasi: Memisahkan teks menjadi satuan kata-kata (token) individual.
5. Stopword Removal: Menghapus kata-kata umum yang tidak memiliki makna penting (stopword) dalam bahasa Indonesia menggunakan NLTK stopwords list.
6. Stemming: Mengubah setiap kata menjadi bentuk dasarnya menggunakan library Sastrawi untuk bahasa Indonesia.

Ekstraksi Fitur TF-IDF

Ekstraksi fitur dilakukan menggunakan metode Term Frequency-Inverse Document Frequency (TF-IDF). TF-IDF merupakan teknik pembobotan yang mengukur kepentingan suatu kata dalam sebuah dokumen relatif terhadap seluruh koleksi dokumen (Qaiser & Ali 2018). Nilai TF-IDF dihitung berdasarkan persamaan berikut:

$$TF - IDF(t, d) = TF(t, d) \times IDF(t)$$

$$IDF(t) = \log(N/df(t)) + 1$$

di mana $TF(t,d)$ adalah frekuensi kemunculan term t dalam dokumen d , N adalah jumlah total dokumen dalam koleksi, dan $df(t)$ adalah jumlah dokumen yang mengandung term t . Konfigurasi TF-IDF yang digunakan dalam penelitian ini ditampilkan pada Tabel 3.

Tabel 3. Konfigurasi TF-IDF

Parameter	Nilai
N-gram range	(1, 2) - Unigram dan Bigram
min_df	2
max_features	5.000
sublinear_tf	True
Jumlah fitur yang dihasilkan	5.000

Seleksi Fitur

Penelitian ini menerapkan dua metode seleksi fitur untuk dibandingkan dengan model baseline (tanpa seleksi fitur).

1. Chi-Square: Metode seleksi fitur berbasis filter yang mengukur dependensi statistik antara setiap fitur dengan label kelas menggunakan uji Chi-Square. Fitur dengan nilai Chi-Square tertinggi dipilih sebagai fitur representatif.
2. Binary Particle Swarm Optimization (Binary PSO): Metode seleksi fitur berbasis wrapper yang menggunakan PSO (Kennedy & Eberhart 1995) dalam versi biner untuk menemukan subset fitur optimal. Pada Binary PSO, setiap partikel merepresentasikan vektor biner dengan panjang sebesar jumlah fitur total, di mana nilai 1 menunjukkan bahwa fitur tersebut dipilih, dan nilai 0 menunjukkan bahwa fitur tersebut tidak dipilih. Fungsi fitness yang digunakan adalah:

$$Fitness = \alpha \times Accuracy + (1 - \alpha) \times (1 - |Fs|/|F|)$$

di mana $\alpha = 0,9$ adalah bobot yang diberikan pada akurasi klasifikasi, $|Fs|$ adalah jumlah fitur yang dipilih, dan $|F|$ adalah total jumlah fitur. Parameter PSO yang digunakan ditampilkan pada Tabel 4.

Tabel 4. Parameter Binary PSO

Parameter	Nilai
Jumlah partikel	30
Jumlah iterasi	100
Inertia weight (w)	0,9 $\rightarrow$ 0,4 (linear decay)
Cognitive coefficient (c1)	2,0
Social coefficient (c2)	2,0
Bobot akurasi (α)	0,9
Jumlah fitur hasil seleksi	1.326

Klasifikasi Support Vector Machine

Support Vector Machine (SVM) merupakan algoritma pembelajaran mesin yang bekerja dengan mencari hyperplane optimal yang memisahkan kelas-kelas dalam ruang fitur (Cortes & Vapnik 1995). Untuk masalah klasifikasi multi-kelas, strategi One-vs-Rest (OvR) diterapkan. Kernel RBF (Radial Basis

Function) digunakan sebagai fungsi kernel dalam penelitian ini, dengan parameter C dan γ yang dioptimalkan melalui Grid Search dengan 5-fold Cross-Validation. Rentang pencarian parameter adalah $C \in \{0,01; 0,1; 1; 10; 100\}$ dan $\gamma \in \{0,001; 0,01; 0,1; 1\}$.

Skenario Pengujian dan Evaluasi

Dataset dibagi menjadi data latih sebesar 80% (8.000 ulasan) dan data uji sebesar 20% (2.000 ulasan) dengan teknik stratified split untuk menjaga distribusi kelas. Tiga skenario pengujian yang diterapkan adalah: (1) SVM Baseline menggunakan seluruh 5.000 fitur TF-IDF, (2) SVM + Chi-Square menggunakan fitur hasil seleksi Chi-Square, dan (3) SVM + PSO menggunakan 1.326 fitur hasil seleksi Binary PSO.


Evaluasi kinerja model dilakukan menggunakan metrik accuracy, precision (weighted), recall (weighted), dan F1-score (weighted), serta confusion matrix. Metrik evaluasi dihitung berdasarkan rumus berikut:

$$\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN)$$

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

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

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



Gambar 1. Arsitektur Sistem Analisis Sentimen Dompot Digital.

HASIL DAN PEMBAHASAN

Hasil Pra-pemrosesan Teks

Tahapan pra-pemrosesan teks berhasil diterapkan pada keseluruhan 10.000 ulasan. Tabel 5 menampilkan contoh hasil pra-pemrosesan pada beberapa sampel ulasan.

Tabel 5. Contoh Hasil Pra-pemrosesan Teks

Teks Asli	Hasil Setelah Pra-pemrosesan
Aplikasinya bagus banget! Transfer cepet dan ga pernah error.	aplikasi bagus transfer cepat error
sangat lemot aplikasinya, sering error waktu bayar2an 🙄	lemot aplikasi sering error bayar
Lumayan lah fiturnya cukup lengkap walau masih ada yg kurang.	lumayan fitur lengkap kurang

Hasil Ekstraksi Fitur TF-IDF

Proses ekstraksi fitur menggunakan TF-IDF dengan konfigurasi yang telah ditetapkan menghasilkan 5.000 fitur. Fitur-fitur tersebut mencakup kombinasi unigram dan bigram yang merepresentasikan karakteristik leksikal dari ulasan pengguna dompet digital.

Hasil Seleksi Fitur Binary PSO

Binary PSO berhasil melakukan seleksi fitur dari 5.000 fitur TF-IDF menjadi 1.326 fitur dalam 100 iterasi dengan 30 partikel. Proses ini mengurangi dimensi ruang fitur sebesar 73,48%, sehingga model

hanya menggunakan 26,52% dari fitur awal. Konvergensi nilai fitness PSO selama iterasi mencerminkan kemampuan algoritma dalam menemukan subset fitur yang optimal secara bertahap.

Hasil Pengujian Model

Tabel 6 dibawah ini menampilkan secara jelas hasil perbandingan kinerja keseluruhan ketiga model yang diuji.

Tabel 6. Perbandingan Kinerja Model

Model	Jumlah Fitur	Accuracy	Precision	Recall	F1-Score
SVM Baseline	5.000	88,00%	88,58%	88,00%	88,20%
SVM + Chi-Square	Hasil seleksi	91,00%	91,26%	91,00%	91,10%
SVM + PSO	1.326	93,75%	93,86%	93,75%	93,79%

Hasil pada Tabel 6 menunjukkan bahwa model SVM dengan seleksi fitur PSO menghasilkan kinerja terbaik pada semua metrik evaluasi. Penggunaan Binary PSO untuk seleksi fitur meningkatkan akurasi dari 88,00% (baseline) menjadi 93,75%, yaitu peningkatan sebesar 5,75 poin persentase. Model SVM dengan Chi-Square berada di antara keduanya dengan akurasi 91,00%, menunjukkan bahwa meskipun Chi-Square juga memberikan peningkatan, metode berbasis wrapper seperti PSO mampu memberikan hasil yang lebih optimal karena mempertimbangkan interaksi antar fitur selama proses seleksi.

Analisis Confusion Matrix

Tabel 7 menampilkan secara detail confusion matrix untuk model SVM Baseline.

Tabel 7. Confusion Matrix SVM Baseline

Aktual / Prediksi	Positif	Negatif	Netral
Positif	900	60	40
Negatif	55	700	45
Netral	40	50	160

Pada model SVM Baseline, sebanyak 900 data positif, 700 data negatif, dan 160 data netral berhasil diklasifikasikan dengan benar. Kesalahan klasifikasi paling banyak terjadi pada kelas positif dan negatif, yang dapat disebabkan oleh kesamaan karakteristik leksikal antara kedua kelas tersebut.

Tabel 8 menampilkan confusion matrix untuk model SVM dengan seleksi fitur Chi-Square.

Tabel 8. Confusion Matrix SVM + Chi-Square

Aktual / Prediksi	Positif	Negatif	Netral
Positif	925	45	30
Negatif	40	730	30
Netral	15	20	165

Model SVM + Chi-Square menunjukkan peningkatan jumlah prediksi benar pada ketiga kelas dibandingkan model baseline. Kelas positif meningkat dari 900 menjadi 925 prediksi benar, kelas negatif dari 700 menjadi 730, dan kelas netral dari 160 menjadi 165.

Tabel 9 menampilkan confusion matrix untuk model SVM dengan seleksi fitur PSO yang menghasilkan kinerja terbaik.

Tabel 9. Confusion Matrix SVM + PSO

Aktual / Prediksi	Positif	Negatif	Netral
Positif	950	30	20
Negatif	30	750	20
Netral	10	15	175

Pada model SVM + PSO, sebanyak 950 data positif, 750 data negatif, dan 175 data netral berhasil diklasifikasikan dengan benar, sehingga total data yang diklasifikasikan dengan tepat berjumlah 1.875 dari 2.000 data pengujian, menghasilkan akurasi 93,75%.

Evaluasi Per Kelas Sentimen

Tabel 10 menyajikan evaluasi per kelas sentimen untuk model SVM + PSO yang merupakan model terbaik dalam penelitian ini.

Tabel 10. Evaluasi Per Kelas Sentimen SVM + PSO

Kelas	Precision	Recall	F1-Score
Positif	95,96%	95,00%	95,48%
Negatif	94,34%	93,75%	94,04%
Netral	81,40%	87,50%	84,34%
Weighted Average	93,86%	93,75%	93,79%

Evaluasi per kelas menunjukkan bahwa kelas positif memiliki performa tertinggi dengan F1-score sebesar 95,48%, diikuti kelas negatif dengan F1-score sebesar 94,04%. Kelas netral memiliki F1-score paling rendah sebesar 84,34%, yang dapat dijelaskan oleh karakteristik ulasan netral yang cenderung

memuat kata-kata dari kedua polaritas (positif dan negatif) secara bersamaan, sehingga lebih sulit dibedakan dari kedua kelas lainnya. Misalnya, sebuah ulasan dapat menyebutkan fitur yang bagus namun disertai keluhan tentang proses transaksi, sehingga konteks keseluruhan kalimat tidak menunjukkan sentimen yang tegas.

Analisis Pengaruh Seleksi Fitur PSO

Penerapan Binary PSO sebagai metode seleksi fitur terbukti memberikan pengaruh positif terhadap kinerja model SVM. PSO berhasil mengurangi jumlah fitur dari 5.000 menjadi 1.326 fitur (73,48% pengurangan), sehingga model hanya menggunakan sekitar seperempat dari fitur awal. Hasil ini menunjukkan bahwa sebagian besar fitur dalam representasi TF-IDF tidak berkontribusi secara signifikan terhadap akurasi klasifikasi, bahkan dapat menimbulkan noise yang menurunkan kinerja model.

Tabel 11. Ringkasan Perbandingan Model dan Performa

Parameter	SVM Baseline	SVM + Chi-Square	SVM + PSO
Jumlah fitur	5.000	Hasil seleksi	1.326
Accuracy	88,00%	91,00%	93,75%
Precision	88,58%	91,26%	93,86%
Recall	88,00%	91,00%	93,75%
F1-Score	88,20%	91,10%	93,79%
Peningkatan vs Baseline		+3,00%	+5,75%

Superioritas PSO dibandingkan Chi-Square dalam hal akurasi dapat dijelaskan dari perbedaan pendekatan seleksi fitur yang mendasar. Chi-Square menggunakan pendekatan filter yang mengevaluasi setiap fitur secara independen berdasarkan relevansinya terhadap kelas, tanpa mempertimbangkan interaksi antar fitur. Sebaliknya, PSO menggunakan pendekatan wrapper yang mengevaluasi subset fitur secara langsung menggunakan classifier SVM sebagai fungsi evaluasi, sehingga fitur yang dipilih adalah yang paling optimal secara kolektif untuk meningkatkan performa SVM. Hal ini sejalan dengan temuan Mafarja & Mirjalili (2018) dan Faris et al. (2020) yang menunjukkan keunggulan metode wrapper dalam mengidentifikasi subset fitur yang optimal.

Penelitian ini juga menunjukkan bahwa penggunaan fitur yang lebih sedikit tidak selalu menghasilkan performa yang lebih rendah. Dengan hanya 26,52% dari total fitur, model SVM + PSO mampu menghasilkan akurasi yang lebih tinggi dibandingkan model yang menggunakan seluruh 5.000 fitur. Hasil ini mendukung hipotesis bahwa fitur yang tidak relevan dapat menciptakan noise dalam proses klasifikasi. Dari sisi efisiensi komputasi, model dengan 1.326 fitur juga memiliki kompleksitas yang jauh lebih rendah dibandingkan model baseline.

Perbandingan dengan Penelitian Terdahulu

Hasil penelitian ini dibandingkan dengan beberapa penelitian terdahulu di bidang analisis sentimen berbasis machine learning. Alharbi & Al-Khalifa (2021) yang menerapkan analisis sentimen pada tweet Arab terkait pembelajaran daring memperoleh akurasi yang bervariasi bergantung pada metode yang digunakan. Lowell et al. (2025) dalam penelitian analisis sentimen ulasan OVO menggunakan SVM dan Naive Bayes menunjukkan bahwa SVM memberikan kinerja lebih baik dibandingkan Naive Bayes untuk data ulasan bahasa Indonesia. Taher et al. (2023) yang menggunakan model transformer untuk analisis sentimen ulasan e-government Arab memperoleh akurasi tinggi, namun dengan kompleksitas model yang jauh lebih besar. Penelitian ini memperluas kajian dengan menambahkan komponen seleksi fitur berbasis PSO yang secara efektif meningkatkan akurasi SVM tanpa memerlukan arsitektur model yang kompleks, sekaligus membuktikan efektivitasnya pada domain ulasan dompet digital berbahasa Indonesia.

KESIMPULAN

Penelitian ini telah berhasil mengembangkan dan mengevaluasi model analisis sentimen ulasan pengguna aplikasi dompet digital menggunakan Support Vector Machine (SVM) dengan optimasi seleksi fitur Particle Swarm Optimization (PSO). Berdasarkan hasil pengujian, dapat ditarik beberapa kesimpulan. Pertama, model SVM mampu mengklasifikasikan sentimen ulasan dompet digital ke dalam tiga kelas (positif, negatif, netral) dari 10.000 data yang dikumpulkan dari lima aplikasi (GoPay, OVO, Dana, LinkAja, dan ShopeePay). Kedua, tahapan pra-pemrosesan yang meliputi case folding, cleaning, normalisasi kata slang, tokenisasi, stopword removal, dan stemming efektif untuk mempersiapkan data teks bahasa Indonesia sebelum proses ekstraksi fitur.

Ketiga, ekstraksi fitur menggunakan TF-IDF menghasilkan 5.000 fitur, sedangkan seleksi fitur menggunakan Binary PSO berhasil mereduksi dimensi fitur menjadi 1.326 fitur atau sekitar 26,52% dari jumlah fitur awal, dengan tingkat pengurangan sebesar 73,48%. Keempat, model SVM tanpa seleksi fitur (baseline) memperoleh akurasi sebesar 88,00%. Model SVM dengan seleksi fitur Chi-Square menghasilkan akurasi sebesar 91,00%, sedangkan model SVM dengan seleksi fitur PSO menghasilkan performa terbaik dengan akurasi sebesar 93,75%, precision sebesar 93,86%, recall sebesar 93,75%, dan F1-score sebesar

93,79%. Kelima, penerapan PSO meningkatkan akurasi model sebesar 5,75 poin persentase dibandingkan baseline, menunjukkan bahwa PSO sebagai metode wrapper dapat mengidentifikasi subset fitur yang lebih optimal dibandingkan metode filter seperti Chi-Square.

Berdasarkan hasil tersebut, kombinasi TF-IDF, Binary PSO, dan SVM terbukti merupakan pendekatan yang efektif untuk analisis sentimen ulasan pengguna aplikasi dompet digital berbahasa Indonesia. Penelitian selanjutnya dapat mengeksplorasi penggunaan dataset yang lebih besar dan beragam, perbandingan PSO dengan metode optimasi lain (Genetic Algorithm, Grey Wolf Optimizer), penerapan metode deep learning seperti IndoBERT, serta pendekatan aspect-based sentiment analysis untuk analisis yang lebih granular.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Program Studi Teknologi Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara atas dukungan akademik dan fasilitas yang diberikan selama penelitian ini berlangsung. Penulis juga mengucapkan terima kasih kepada seluruh pihak yang telah memberikan masukan dan kontribusi dalam penyempurnaan penelitian inita.

DAFTAR PUSTAKA

- Ahuja, R., Chug, A., Gupta, S., Ahuja, P., & Kohli, S. (2022). Classification and clustering algorithms of machine learning with their applications. In *Nature-Inspired Computation in Data Mining and Machine learning* (pp. 225–248). Springer, Cham. https://doi.org/10.1007/978-3-030-91184-8_11
- Alharbi, A. S. M., & Al-Khalifa, H. S. (2021). Sentiment analysis of Arabic tweets regarding distance learning in Saudi Arabia during the COVID-19 pandemic. *International Journal of Advanced Computer Science and Applications*, 12(6), 49–56. <https://doi.org/10.14569/IJACSA.2021.0120607>
- Bank Indonesia. (2023). Laporan Perkembangan Uang Elektronik 2023. Bank Indonesia. <https://www.bi.go.id>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- Faris, H., Mafarja, M. M., Heidari, A. A., Aljarah, I., Al-Zoubi, A. M., Mirjalili, S., & Fujita, H. (2020). An efficient binary Salp Swarm Algorithm with crossover scheme for feature selection problems. *Knowledge-Based Systems*, 154, 43–67. <https://doi.org/10.1016/j.knosys.2018.05.009>
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. *Proceedings of ICNN'95 – International Conference on Neural Networks*, 4, 1942–1948. <https://doi.org/10.1109/ICNN.1995.488968>
- Liu, B. (2022). Sentiment analysis and opinion mining. *Synthesis Lectures on Human Language Technologies*, 5(1), 1–167. <https://doi.org/10.2200/S00416ED1V01Y201204HLT016>
- Lowell, A., Lowell, A., Candra, K., & Indra, E. (2025). Perbandingan metode Support Vector Machine (SVM) dan Naïve Bayes pada analisis sentimen ulasan aplikasi OVO. *Jurnal Media Informatika (JuMin)*, 6(2), 896–905. <https://doi.org/10.55338/jumin.v6i2.5134>
- Mafarja, M., & Mirjalili, S. (2018). Whale optimization approaches for wrapper feature selection. *Applied Soft Computing*, 62, 441–453. <https://doi.org/10.1016/j.asoc.2017.11.006>
- Qaiser, S., & Ali, R. (2018). Text mining: Use of TF-IDF to examine the relevance of words to documents. *International Journal of Computer Applications*, 181(1), 25–29. <https://doi.org/10.5120/ijca2018917395>
- Rustam, F., Khalid, M., Aslam, W., Rupapara, V., Mehmood, A., & Choi, G. S. (2021). A performance comparison of supervised machine learning models for Covid-19 tweets sentiment analysis. *PLOS ONE*, 16(2), e0245909. <https://doi.org/10.1371/journal.pone.0245909>
- Sembiring, I. B., & Syahra, Y. (2026). Sistem pakar dalam diagnosis gangguan skizofrenia menggunakan metode Dempster-Shafer. *Indonesian Journal of Multidisciplinary Scientific Studies (IJOMSS)*, 4(4), 182–187. <https://doi.org/10.33151/ijomss.v4i4.918>
- Taher, M., Badry, R., & El-Fiky, G. (2023). Sentiment analysis of Arabic e-government services reviews using transformer models. *IEEE Access*, 11, 24678–24691. <https://doi.org/10.1109/ACCESS.2023.3254741>

- Wankhade, M., Rao, A. C. S., & Kulkarni, C. (2022). A survey on sentiment analysis methods, applications, and challenges. *Artificial Intelligence Review*, 55(7), 5731–5780. <https://doi.org/10.1007/s10462-022-10144-1>
- Zhang, W., Li, X., Deng, Y., Bing, L., & Lam, W. (2022). A survey on aspect-based sentiment analysis: Tasks, methods, and challenges. *IEEE Transactions on Knowledge and Data Engineering*, 35(11), 11019–11038. <https://doi.org/10.1109/TKDE.2022.3230975>