

OPTIMASI ALGORITMA SUPPORT VECTOR MACHINE BERBASIS KERNEL RADIAL BASIS FUNCTION (RBF) MENGGUNAKAN METODE PARTICLE SWARM OPTIMIZATION UNTUK ANALISIS SENTIMEN

Cucun Very Angkoso^{*1}, Khozainul Asror², Ari Kusumaningsih³, Andi Kurniawan Nugroho⁴

^{1,2,3} Teknik Informatika, Fakultas Teknik, Universitas Trunojoyo Madura, Kabupaten Bangkalan

⁴ Teknik Elektro, Fakultas Teknik, Universitas Semarang, Semarang

Email: ¹cucunvery@trunojoyo.ac.id, ²khozainulasror1823@gmail.com, ³ari.kusumaningsih@trunojoyo.ac.id,

⁴andikn@usm.ac.id

^{*} Penulis Korespondensi

(Naskah masuk: 10 Oktober 2024, diterima untuk diterbitkan: 20 Juni 2025)

Abstrak

Di era digital, aplikasi Financial Technology (Fintech) telah menjadi bagian penting dalam kehidupan sehari-hari masyarakat. Kemudahan dan efisiensi yang ditawarkan oleh aplikasi Fintech menarik jutaan pengguna, yang aktif memberikan umpan balik dan ulasan di platform seperti Google Play Store. Ulasan ini menjadi sumber informasi berharga bagi pengembang untuk memahami persepsi pengguna, mengidentifikasi masalah, dan meningkatkan kualitas layanan. Penelitian ini bertujuan mengevaluasi efektivitas algoritma Particle Swarm Optimization (PSO) dalam meningkatkan akurasi analisis sentimen pada algoritma Support Vector Machine (SVM) dengan kernel Radial Basis Function (RBF). Data ulasan dikumpulkan melalui web scraping dari komentar di Google Play untuk tiga aplikasi Fintech, yaitu Flip, Neobank, dan Bank Jago. Tahapan pemrosesan meliputi pelabelan, preprocessing untuk membersihkan data, dan pembobotan kata menggunakan metode TF-IDF (Term Frequency-Inverse Document Frequency). Teknik Random Oversampling diterapkan untuk mengatasi ketidakseimbangan kelas dalam dataset. Hasil penelitian menunjukkan bahwa optimasi parameter dengan PSO mampu meningkatkan kinerja analisis sentimen, dengan peningkatan rata-rata sebesar 11,33% untuk setiap aplikasi. PSO juga meningkatkan akurasi model dalam menghadapi tantangan data tidak seimbang, memberikan wawasan yang lebih dalam bagi pengembang aplikasi untuk meningkatkan layanan.

Kata kunci: TF-IDF, Support Vector Machine, Particle Swarm Optimization, RBF, Sentimen.

OPTIMIZING SUPPORT VECTOR MACHINE ALGORITHM USING PARTICLE SWARM OPTIMIZATION METHOD FOR SENTIMENT ANALYSIS OF FINANCIAL TECHNOLOGY APPLICATIONS

Abstract

Financial technology (Fintech) applications have become part of people's daily lives in the digital era. The convenience and efficiency offered by Fintech applications have attracted millions of users, who actively provide feedback and reviews on platforms such as the Google Play Store. These reviews are an important source of information for application developers to understand user perceptions, identify problems, and improve service quality. The study investigates the effectiveness of the Particle Swarm Optimization (PSO) method for balanced and unbalanced datasets and how well it improves sentiment analysis accuracy when applied to the Support Vector Machine (SVM) algorithm when using Radial Basis Function (RBF) kernel. We conducted web scraping to collect user review data from Google Play for three FinTech applications: Flip, Neobank, and Bank Jago as research objects. Following data collection, the review data underwent preprocessing steps, such as word weighting using the TF-IDF (Term Frequency-Inverse Document Frequency), labeling, and preprocessing to clean the data. Random Oversampling resolved the dataset's class imbalance, making all classes representative in the study. The results of this study indicate that parameter optimization with PSO can improve the performance of sentiment analysis on the subjects studied. Furthermore, based on the results of SVM testing using parameter optimization of the PSO algorithm, an average performance increase of 11.33% was obtained for each application that had been analyzed. The results also show that PSO improves model accuracy in sentiment analysis with imbalanced data challenges, providing deeper insights for application developers to improve services.

Keywords: TF-IDF, Support Vector Machine, Particle Swarm Optimization, RBF, Sentiment.

1. PENDAHULUAN

Perkembangan teknologi yang begitu pesat merupakan sebuah fenomena yang dapat membawa dampak perubahan khususnya terhadap perilaku masyarakat yang dulunya konvensional menjadi serba digital seperti sekarang ini (Natalia and Shihab, 2018). Seiring berkembangnya waktu, mulai banyak transaksi yang dilakukan secara digital karena didukung oleh pemerintah dan lembaga keuangan resmi. Transaksi digital menawarkan kemudahan dan efisiensi bagi pengguna. Masyarakat Indonesia mencari cara yang lebih praktis dan cepat untuk melakukan pembayaran, belanja online, transfer uang, dan layanan keuangan lainnya. Dengan adanya transaksi digital, proses tersebut dapat dilakukan dengan mudah melalui aplikasi mobile atau platform online.

Dari data menunjukkan transaksi digital di Indonesia semakin meningkat masing-masing pada tahun 2023 dan 2024. Pada tahun 2023, nilai transaksi perbankan digital tercatat sebesar Rp58.478,24 triliun, menunjukkan pertumbuhan yang kuat dalam sektor ini (IN, 2023). Pertumbuhan ini didukung oleh peningkatan penetrasi internet dan smartphone di Indonesia, yang memudahkan akses masyarakat terhadap layanan perbankan digital. Selain itu, teknologi perbankan digital yang terus berkembang pesat menawarkan berbagai kemudahan dan kenyamanan bagi nasabah. Pada tahun 2024, Bank Indonesia melaporkan bahwa nominal transaksi perbankan digital mencapai Rp5.103,03 triliun pada Februari 2024, tumbuh 19,72% secara tahunan (year on year/yoy). Selain itu, transaksi uang elektronik meningkat 44,24% (yoy) sehingga mencapai Rp80,03 triliun. Pada Juli 2024, transaksi perbankan digital tumbuh sebesar 30,50% (yoy) menjadi 1.845,27 juta transaksi. Transaksi uang elektronik juga tumbuh 22,61% (yoy) mencapai 1.272,35 juta transaksi. Transaksi QRIS terus tumbuh pesat 207,55% (yoy), dengan jumlah pengguna mencapai 51,43 juta dan jumlah merchant 33,21 juta (ANTARA, 2024). Pada tahun 2025, nilai transaksi digital banking diperkirakan akan terus tumbuh 18,8% hingga mencapai Rp85.044 triliun (Bareksa, 2024). Pertumbuhan ini didukung oleh sistem pembayaran yang aman, lancar, dan andal. Selain itu, transaksi e-commerce juga diperkirakan akan terus tumbuh 3,3% menjadi Rp503 triliun pada tahun 2025 (Bareksa, 2024).

Bank terbesar di Indonesia telah menetapkan biaya administrasi untuk melakukannya transfer dana antar bank sebesar Rp 6.500,00. Biaya seperti itulah yang membuat masyarakat terkadang merasa keberatan. Namun, dengan hadirnya aplikasi *fintech* (*financial technology*) seperti Flip.id, Neobank dan Bankjago menjadi solusi terkait masalah tersebut. *Fintech* adalah inovasi yang menggabungkan layanan keuangan dengan teknologi guna mempercepat dan memudahkan transaksi digital atau pembayaran digital (Septiani, 2022). Pelaku *fintech* di Indonesia

masih dominan di segmen pembayaran mencapai (43%) dan pinjaman mencapai (17%) .

Flip.id (PT Fliptech Lentera Inspirasi Pertiwi) didirikan pada tahun 2015, dan tersedia di berbagai platform seperti Android dan iOS (Sahroni et al., 2022). Flip.id adalah aplikasi penyedia layanan transfer antar bank tanpa biaya administrasi yang telah berizin dan diawasi oleh Bank Indonesia. Selanjutnya ada aplikasi Bank Jago adalah sebuah platform perbankan digital yang menyediakan berbagai layanan finansial kepada para penggunanya. didirikan pada 11 Juni 2020, PT Bank Jago Tbk, sebelumnya dikenal sebagai PT Bank Artos Indonesia Tbk (ARTO). Kemudian yang ketiga ada aplikasi Neobank merupakan inovasi berupa *financial technology* yang menawarkan kemudahan layanan perbankan digital tanpa cabang. Terakhir ada aplikasi Neobank juga merupakan salah satu produk perbankan digital yang dikeluarkan oleh PT. Neo Ecommerce Bank diluncurkan sejak 21 maret 2021.

Dengan meningkatnya penggunaan aplikasi seperti Flip.id, Neobank, dan Bank Jago, banyak pengguna yang aktif memberikan pendapat dan diskusi melalui ulasan di *Google Play Store*. ulasan tersebut mencakup sentimen positif, negatif, dan netral, jumlah data yang besar dari ulasan ini membuat penanganan dan pengolahan informasi menjadi banyak memakan waktu. Terlebih lagi, dalam beberapa kasus, nilai bintang yang diberikan tidak selalu mencerminkan isi ulasan, sehingga membuat kesulitan dalam memahami sentimen sebenarnya (Hu, Pavlou dan Zhang, 2006; Fang dan Zhan, 2015). Oleh karena itu, penelitian ini mengevaluasi opini dan ulasan tanpa bergantung pada nilai bintang dengan mengimplementasikan analisis sentimen berbasis *machine learning*. Pendekatan ini diharapkan dapat memberikan gambaran yang lebih akurat terhadap layanan aplikasi.


Berdasarkan penelitian sebelumnya, terdapat penelitian terkait analisis sentimen ulasan pengguna pada aplikasi *Google Classroom* dengan menggunakan algoritma klasifikasi *Support Vector Machine* (SVM) dan *Particle Swarm Optimization* (PSO), algoritma ini banyak digunakan oleh para peneliti pada bidang analisis sentimen. Dari hasil pemodelan klasifikasi menggunakan metode SVM dan PSO, ternyata berjalan dengan baik dan mendapatkan nilai akurasi sebesar 79% dengan metode SVM tanpa PSO, setelah menggunakan PSO hasil dari akurasi meningkat menjadi 83%. Dengan begitu PSO bisa menjadi pilihan fitur yang baik untuk metode SVM dalam klasifikasi sentimen sebagaimana dibuktikan dalam penelitian ini yang berhasil meningkatkan nilai akurasi sebesar 4%. Menunjukkan bahwa penggunaan PSO mampu meningkatkan nilai hasil akurasi (Metode et al., 2022). Implementasi PSO pada proses seleksi fitur dan optimasi *hyperparameter* SVM telah terbukti efektif dalam meningkatkan performa algoritma. PSO melakukan maksimasi performansi SVM dengan

mencari subset fitur dan nilai *hyperparameter* secara iteratif dan telah menunjukkan hasil yang baik (Hitam, Ismail dan Saeed, 2019; Arsi, Wahyudi dan Waluyo, 2021; Mursianto, Widiyanto dan Wahyono, 2022). Kontribusi utama penelitian ini adalah sebagai berikut:

- a. Penerapan kombinasi SVM dan PSO: Penelitian ini memberikan kontribusi dalam penerapan kombinasi algoritma *Support Vector Machine* (SVM) dan *Particle Swarm Optimization* (PSO) untuk analisis sentimen pada ulasan aplikasi keuangan. Penggunaan PSO sebagai seleksi fitur diharapkan dapat meningkatkan akurasi dan kinerja model.
- b. Evaluasi metode penyeimbangan data: Penelitian ini juga melakukan evaluasi terhadap efektifitas metode penyeimbangan data dalam menghadapi ketidakseimbangan kelas yang sering terjadi pada data teks. Hal ini penting karena ketidakseimbangan kelas dapat mempengaruhi kinerja model klasifikasi.
- c. Analisis sentimen pada aplikasi keuangan: Penelitian ini memberikan wawasan mengenai penggunaan analisis sentimen untuk mengevaluasi pendapat pengguna terhadap aplikasi keuangan seperti Flip, Neobank, dan Bank Jago. Hasil penelitian dapat membantu pengembang aplikasi untuk meningkatkan kualitas produk mereka berdasarkan umpan balik pengguna.
- d. Rekomendasi aplikasi: Dengan menganalisis sentimen pengguna, penelitian ini dapat memberikan rekomendasi aplikasi transfer antar bank yang lebih sesuai dengan preferensi dan kebutuhan pengguna.

Masalah mendasar pada algoritma SVM dengan kernel RBF yaitu bergantung pada pemilihan parameter optimal yang seringkali memakan waktu jika dilakukan manual, sehingga PSO berpotensi meningkatkan efisiensi dan akurasi pemilihan parameter tersebut, serta tujuan dan manfaat evaluasi efektivitas PSO untuk meningkatkan kinerja analisis sentimen SVM pada data ulasan aplikasi Fintech.

Pada penelitian ini diharapkan dapat memberikan wawasan dalam bagian menemukan solusi bagi pengembang aplikasi dalam meningkatkan kualitas produk serta menjadi rekomendasi aplikasi transfer antar bank yang lebih cocok digunakan berdasarkan preferensi dan kebutuhan pengguna. Dalam konteks yang lebih luas, penelitian ini dapat berkontribusi pada perkembangan teknologi analisis sentimen dan pemanfaatannya dalam berbagai bidang, seperti pemasaran, layanan pelanggan, dan pengembangan produk.



Gambar 1. Alur penelitian berdasarkan CRISP-DM

2. METODE PENELITIAN

2.1 CRISP-DM

Alur penelitian yang digunakan dalam penelitian ini adalah berbasis model *Cross Industry Standard Process for Data Mining* (CRISP-DM), karena penerapannya cukup efektif dan memiliki langkah-langkah terstruktur dan mudah untuk diterapkan. Tahapan CRISP-DM ada 6 tahapan seperti yang ditunjukkan pada Gambar 1 (Chapman *et al.*, 2000; Schröder, Kruse dan Gómez, 2021).

Berikut adalah detail proses yang dilakukan sesuai urutan pada Gambar 1:

1. Business Understanding

Business understanding atau Pemahaman bisnis merupakan tahap awal dalam proses analisis sentimen yang berfokus pada pemahaman tujuan bisnis dan kebutuhan informasi penggunaan analisis sentimen dalam ulasan aplikasi. Pada tahap ini, kita perlu memahami mengapa analisis sentimen diperlukan dan apa yang ingin kita capai. Dalam konteks aplikasi, analisis sentimen ulasan aplikasi transfer antar bank ini dapat membantu pengembang atau pemilik aplikasi untuk meningkatkan kualitas aplikasi, Analisis sentimen dapat membantu pengembang atau pemilik aplikasi untuk mengetahui umpan balik dan pendapat pengguna tentang aplikasi. Dengan demikian, mereka dapat melakukan perbaikan pada aplikasi untuk memenuhi kebutuhan dan harapan pengguna.

Dalam pemahaman bisnis, dilakukan pemahaman jenis ulasan apa yang akan dianalisis, seperti data ulasan aplikasi yang akan digunakan dalam analisis sentimen berasal dari platform *Google Play Store*, menggunakan data ulasan dan *rating* aplikasi yang diperoleh dari API *Google Play Store* sebagai sumber data. Analisis sentimen ulasan aplikasi akan dilakukan pada ulasan aplikasi yang ditulis dalam bahasa Indonesia dan pada Data yang digunakan dalam analisis sentimen ulasan aplikasi adalah data terbaru.

1. Data Understanding

Tahap selanjutnya adalah Pemahaman Data. Pada tahap ini dilakukan proses pengumpulan data,

kemudian mengidentifikasi, dan memahami data yang dimiliki. Mulai dari memahami karakteristik data ulasan aplikasi seperti jumlah ulasan, jenis ulasan, kategori ulasan, dan format data ulasan. Penelitian ini nantinya akan menggunakan data ulasan yang terdapat pada *Google Play Store* mengenai aplikasi Flip, Neobank dan Bank Jago. Kemudian untuk jumlah ulasan yang akan dianalisis dapat mempengaruhi kualitas dan keakuratan hasil analisis sentimen.

Tabel 1. Jumlah data tiap aplikasi

Aplikasi	Jumlah Data
Flip	10849
Neobank	8174
Bank Jago	7592

Tabel 2. Variabel Penelitian

Variabel	Pengertian
Ulasan	Isi ulasan yang ditulis oleh pengguna aplikasi
Rating	Penilaian yang diberikan pengguna terhadap aplikasi
Tanggal	Tanggal ulasan ditulis oleh pengguna aplikasi

Data yang digunakan dalam analisis sentimen ulasan aplikasi adalah data ulasan dan *rating* aplikasi mulai dari 1-5 yang diambil dari platform *Google Play Store*. Data yang diambil terdiri dari ulasan mulai dari tanggal 1 Januari 2023 – 30 Juni 2023 dengan jumlah data bisa kita lihat pada Tabel 1, sementara setiap data ulasan aplikasi yang diteliti terdiri dari fitur-fitur yang ditunjukkan pada Tabel 2.

Data yang digunakan dalam analisis sentimen ulasan aplikasi tergolong cukup berkualitas. Namun, terdapat beberapa ulasan yang bersifat ambigu atau tidak jelas sehingga sulit untuk dilakukan analisis sentimen. Selain itu, ada beberapa ulasan yang mengandung unsur spam atau tidak relevan dengan aplikasi sehingga perlu dilakukan proses preprocessing data terlebih dahulu.

Dengan memperhatikan hal-hal tersebut pada tahap Data Understanding, kami dapat memahami dengan jelas deskripsi data, kualitas data, dan tahap preprocessing data yang diperlukan dalam analisis sentimen ulasan aplikasi. Hal ini dapat membantu kami dalam mempersiapkan data yang tepat dan berkualitas untuk analisis sentimen ulasan aplikasi yang efektif dan bermanfaat bagi bisnis.

2. Data Preparation

Penyiapan data merupakan tahap ketiga yang diproses dalam proses analisis sentimen yang bertujuan untuk menyiapkan review data aplikasi agar siap diolah dengan algoritma analisis sentimen. Di tahap ini penulis memberi label dataset secara manual yaitu positif, negatif dan netral. Proses ini juga melibatkan ahli bahasa atau ahli bahasa sesuai dengan bahasa yang digunakan, yang bertujuan untuk memungkinkan ahli bahasa memberikan pelabelan tanpa adanya kesalahan. Setelah data sudah diberikan label nilai sentimen dan diterima kembali oleh

peneliti, maka data akan masuk tahap data preprocessing yaitu ada pembersihan data (*cleaning*), mengubah ke huruf kecil (*case folding*), memisahkan kata (*tokenization*), *slang words*, *stopwords removal* dan kata dasar (*stemming*). Kemudian dilakukan proses pembobotan kata dengan *TF-IDF* (*Term Frequency-Inverse Document Frequency*) dan dilanjutkan pada pelatihan model.

Dengan memperhatikan hal-hal tersebut pada tahap Data Preparation, kami dapat mempersiapkan data yang sudah bersih, terstruktur, dan terlabel sentimen dengan tepat. Hal ini dapat membantu kami dalam melatih model analisis sentimen ulasan aplikasi yang efektif dan bermanfaat bagi bisnis.

3. Modeling

Untuk melakukan analisis sentimen ulasan aplikasi keuangan, kami memilih metode *Support Vector Machine* dan *Particle Swarm Optimization* (SVM-PSO). SVM adalah algoritma pembelajaran terbimbing yang banyak digunakan dan telah membuktikan keunggulan dalam berbagai domain, termasuk klasifikasi, regresi, dan tugas deteksi *outlier*. Secara matematis, SVM mengubah data input menjadi ruang fitur berdimensi lebih tinggi, sehingga batas keputusan linier dapat dibangun. Transformasi ini ditangani secara efisien dengan menggunakan trik kernel, yang memungkinkan SVM beroperasi di ruang berdimensi tinggi tanpa secara eksplisit menghitung vektor fitur yang ditransformasikan.

Pada penelitian ini kami memilih kernel *Radial Basis Function* (RBF), karena sebagai kernel fungsi Gaussian, mampu menangani masalah klasifikasi data yang tidak dapat dipisahkan secara linear (Chandra dan Bedi, 2021; Nguyen dan Vu, 2022).

SVM-PSO merupakan pengembangan dari SVM yang menggunakan teknik optimalisasi algoritma *Particle Swarm Optimization* (PSO) untuk mencari parameter yang terbaik, dimana pada penelitian ini kernel RBF diharapkan menghasilkan model yang lebih baik dalam memprediksi sentimen ulasan. Dengan X adalah vektor fitur yang mewakili titik data, maka:

$$\text{Kernel_RBF} = \exp(-\gamma \|x_i - x'\|^2) \quad (1)$$

$$\text{Dengan nilai } \gamma = \frac{1}{2\sigma^2} \quad (2)$$

Dimana, γ (*gamma*) adalah *hyperparameter* yang menentukan penyebaran kernel dan memengaruhi fleksibilitas batas keputusan. Optimasi parameter saat melatih SVM dengan kernel RBF, dua parameter penting harus dicari yaitu C dan nilai parameter γ pada kernel RBF. Gamma ditetapkan untuk menentukan seberapa sensitif model SVM terhadap setiap titik data. Penentuan parameter pada kernel yang dipilih sangat berpengaruh (Ibrahim, Okafor dan Yahaya, 2021; Gopi *et al.*, 2023; Li, Wang dan Dai, 2023) karena dengan gamma tinggi membuat model sangat sensitif terhadap setiap titik data, sehingga *hyperplane* menjadi sangat fleksibel tetapi berisiko *overfitting*. Sebaliknya, gamma rendah

membuat model kurang sensitif terhadap setiap titik data, sehingga *hyperplane* menjadi lebih sederhana tetapi berisiko *underfitting*.

Mengoptimalkan parameter ini sangat penting untuk mencapai kinerja klasifikasi yang unggul. Proses pengoptimalan ini dapat ditingkatkan dengan mengintegrasikan *Particle Swarm Optimization (PSO)*, yang terinspirasi oleh perilaku hewan sosial dan digunakan secara luas untuk berbagai tugas pengoptimalan.

Dalam konteks analisis sentimen, PSO digunakan untuk mengoptimalkan fungsi objektif, yang dapat dihitung dengan menggunakan algoritma pembelajaran mesin seperti SVM (Machová *et al.*, 2020). Fungsi objektif ini mengukur kinerja model dalam memprediksi sentimen ulasan aplikasi berdasarkan subset fitur yang dipilih.

Pada awalnya, setiap partikel akan diberi posisi dan kecepatan acak dalam ruang pencarian solusi. Setiap partikel juga memiliki nilai *pBest* (*best personal*) yang merepresentasikan posisi terbaik yang pernah dicapai oleh partikel tersebut. Selain itu, terdapat nilai *gBest* (*global best*) yang merepresentasikan posisi terbaik yang pernah dicapai oleh seluruh partikel dalam populasi (Xia *et al.*, 2020).

Dalam PSO, terdapat beberapa parameter yang perlu ditentukan untuk mengoptimasi suatu masalah. Beberapa parameter tersebut antara lain:

- Jumlah partikel (*swarm size*): Parameter ini menentukan jumlah partikel atau individu yang terdapat dalam *swarm* atau populasi pada PSO.
- C1 dan C2: Parameter ini menentukan kontribusi partikel terhadap pergerakan *swarm*. C1 dan C2 menentukan seberapa besar partikel akan dipengaruhi oleh posisi partikel terbaik dalam *swarm* (*pbest*) dan posisi global terbaik dalam *swarm* (*gbest*).
- Vmax: Parameter ini menentukan batas maksimum pada pergerakan partikel. Nilai *vmax* dapat membantu mencegah partikel bergerak terlalu jauh dari area pencarian solusi optimal.
- Vmin: Parameter ini menentukan batas minimum pada pergerakan partikel. Nilai *vmin* dapat mencegah partikel bergerak terlalu lambat atau terjebak di dalam suatu daerah.

Dalam konteks analisis sentimen dengan SVM-PSO, Untuk mengoptimasi parameter C dan gamma pada SVM dengan menggunakan PSO, nilai C dan gamma dapat dianggap sebagai posisi partikel pada *swarm*. Dalam hal ini, C1 dan C2 pada PSO dapat diatur sebagai faktor pembobot dalam menghitung posisi partikel terbaik (*pbest*) dan posisi global terbaik (*gbest*).

Vmax dan vmin pada PSO dapat diatur untuk membatasi pergerakan partikel dalam pencarian solusi optimal. Vmax dapat membantu mencegah

partikel bergerak terlalu jauh dari area pencarian solusi optimal, sementara vmin dapat mencegah partikel bergerak terlalu lambat atau terjebak di dalam suatu daerah.

Berikut ini adalah langkah-langkah umum yang dilakukan dalam PSO:

a. Inisialisasi partikel

Langkah pertama adalah membuat populasi partikel secara acak pada ruang pencarian. Setiap partikel diinisialisasi dengan posisi dan kecepatan acak pada ruang pencarian.

$$\begin{aligned} x_i(0) &= x_{\min d} + r_d(x_{\max d}) \\ v_d &= 1, \dots, n_x \\ V &= 1, \dots, n_s \end{aligned} \quad (3)$$

Keterangan :

x_{id} = posisi partikel ke-*i* pada dimensi *d*

r_d = range

V_{id} = Kecepatan setiap partikel, menjadi 0

b. Fungsi objektif

Fungsi objektif dalam PSO diberikan sebagai masukan pada awal proses pencarian dan digunakan untuk mengukur kinerja setiap partikel dalam populasi. Fungsi objektif biasanya didefinisikan sebagai fungsi matematis yang ingin dioptimalkan atau diminimalkan. Dalam PSO, fungsi objektif dievaluasi pada setiap iterasi dan digunakan untuk menghitung nilai fitness setiap partikel dalam populasi. Optimalisasi ini memungkinkan kita memaksimalkan fungsi *h* di mana $f = h$. Namun, untuk mendapatkan nilai minimum dari fungsi *h*, kita dapat menggunakan rumus:

$$f = \frac{1}{h} \quad (4)$$

$$Fitness = x_{optimal} + \frac{1}{x_{min}}$$

Keterangan :

$X_{\min}$ = batas bawah dari *x*

$X_{\max}$ = batas atas dari *x*

c. Personal Best PSO

Personal best merupakan posisi terbaik yang pernah dicapai oleh sebuah partikel sejak dimulainya proses pencarian. Personal best dihitung berdasarkan nilai fitness partikel tersebut. Jika nilai fitness partikel saat ini lebih baik daripada nilai fitness personal best-nya, maka personal best diupdate dengan posisi saat ini. Personal best digunakan untuk memperbarui kecepatan dan posisi partikel pada setiap iterasi.

$$pBest(t+1) = pBest_i(t) \text{ Jika } f(x_{id}(t+1)) \geq f(pBest_i(t))$$

$$x_{id}(t+1) \text{ Jika } f(x_{id}(t+1)) < f(pBest_i(t)) \quad (5)$$

Keterangan :

$pBest_i(t+1)$ = *pBest* iterasi sekarang

$pBest_i(t)$ = *pBest* iterasi sebelumnya

$f(x_{id}(t+1))$ = nilai fitness iterasi sekarang

d. *Global Best* PSO

Global best merupakan posisi terbaik yang pernah dicapai oleh seluruh partikel dalam populasi sejak dimulai proses pencarian. Global best dihitung berdasarkan nilai fitness partikel dalam populasi. Jika ada partikel yang memiliki nilai fitness lebih baik daripada global best saat ini, maka global best diupdate dengan posisi partikel tersebut. Global best digunakan untuk memperbarui kecepatan dan posisi partikel pada setiap iterasi. $pBest$ dalam iterasi t .

$$k = \arg\text{Max}_{i=1}^n \{f(pBest_i(t))\} \quad (6)$$

Keterangan :

$$gBest(t) = pBest_k(t)$$

$$\arg\text{Max}_{i=1}^n = \text{Argumen maksimal}$$

$$f(pBest_i(t)) = \text{Nilai fitness } pBest_i \text{ iterasi } t$$

e. *Update* kecepatan dan posisi partikel

Pada langkah ini, kecepatan dan posisi setiap partikel diperbarui menggunakan rumus PSO. Kecepatan partikel dihitung dengan mempertimbangkan kecepatan sebelumnya, dimana ada posisi partikel terbaik pribadi yang pernah dicapai dan posisi partikel terbaik global yang pernah dicapai oleh seluruh partikel dalam populasi. Kecepatan partikel dapat dihitung menggunakan rumus berikut:

1. Kecepatan (V_{id}) dan posisi dari partikel (x_i) diubah.

$$V_{id}^{t+1} = w * v_{id}^t + c_1 * \text{Rand}() * (p_{id} - x_{id}^t) + c_2 * \text{Rand}() * p_{gd} - x_{id}^t \quad (7)$$

2. Untuk membandingkan antara kecepatan dan v_{max} menggunakan persamaan berikut:

$$v_{max} = k * (v_{max} - v_{min}) \quad (8)$$

3. Persamaan perubahan posisi X_i :

$$x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1} \quad (9)$$

4. Persamaan W inersia (w) :

$$w(i) = w_{max} - \left(\frac{w_{max} - w_{min}}{l_{max}} \right) x_i \quad (10)$$

v_{max} dan v_{min} ditujukan untuk nilai awal dan akhir bobot inersia yaitu 0.9 dan 0.4. l_{max} merupakan jumlah iterasi maksimum.

Keterangan :

v_{id}^t = Kecepatan partikel ke- i untuk dimensi ke- d pada iterasi ke- t

x_{id}^t = Posisi partikel ke- i untuk dimensi ke- d pada iterasi t

w = Faktor yang menentukan seberapa besar pengaruh kecepatan sebelumnya inersia

$\text{Rand}()$ = Nilai acak antara 0 dan 1

c_1, c_2 = Komponen kognitif dan sosial

p_{id} = $gBest$ atau posisi terbaik partikel pada x_{id}


f. Kondisi berhenti

Jika kondisi berhenti terpenuhi (misalnya jumlah iterasi yang telah ditentukan telah tercapai atau solusi yang dihasilkan sudah cukup baik), maka proses berhenti dan solusi ditemukan. Jika tidak, maka akan kembali melakukan evaluasi partikel pada

posisi dan kecepatan yang baru diperbarui. Proses tersebut diulang-ulang hingga kondisi berhenti terpenuhi dan solusi yang dihasilkan sudah baik.

Terkait penjelasan dari alur sistem dari pengumpulan data sampai pada evaluasi. Berikut adalah beberapa proses sesuai Gambar 2:

1. Pengumpulan data: proses ini merupakan pengumpulan data berupa ulasan aplikasi dari playstore yang dilakukan dengan menggunakan *Scraping* Data. ID Google Play Store untuk masing-masing aplikasi adalah 'id.flip' untuk Flip, 'com.bnc.finance' untuk Neobank, dan 'com.jago.digitalBanking' untuk Bank Jago.



Gambar 2. Arsitektur pemodelan sistem usulan


2. Pelabelan data: proses memberikan klasifikasi atau label pada setiap data yang akan digunakan untuk analisis sentimen yaitu sentimen positif, negatif dan netral
3. *Preprocessing* data: pada tahapan ini dilakukan proses mengolah data dari *Data cleaning* sampai pada *Stemming*.
4. Pada tahapan selanjutnya dilakukan ekstraksi fitur menggunakan TF-IDF dan pemberian bobot pada setiap kata.
5. *Random Oversampling* dilakukan penanganan kelas yang tidak seimbang antara sentimen positif, negative dan netral.
6. Optimasi PSO untuk SVM: Pada tahapan ini dilakukan penerapan algoritma PSO untuk mengoptimalkan parameter SVM, seperti C (*cost*) dan γ .

Penjelasan pada gambar 2 adalah dimulai dengan menginisialisasi dan membangkitkan nilai partikel PSO berdasarkan range partikel, lalu proses PSO dengan mengurutkan $pBest$ dan mendapatkan $Gbest$, kemudian menghitung kecepatan partikel, dan mengupdate posisi partikel yang kemudian diperoleh

nilai best parameter dari c dan γ yang digunakan selanjutnya pada metode SVM.

4. Evaluation

Untuk memastikan keandalan model, peneliti menggunakan *confusion matrix* dan menerapkan 5 *k-fold cross-validation* sebagai langkah validasi dengan tujuan untuk meningkatkan hasil akurasi dan evaluasi performa model analisis sentimen ulasan aplikasi dengan menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-score*. Pada *confusion matrix* klasifikasi n -kelas berbentuk matriks persegi dengan n baris dan n kolom. Dalam kasus tiga kelas, matriks ini akan berbentuk 3×3 , yang menampilkan klasifikasi aktual versus prediksi untuk tiga kelas tersebut. Matriks ini ditunjukkan pada Gambar 3 membantu memvisualisasikan performa model klasifikasi.



Gambar 3. *Confusion Matrix* Untuk Evaluasi Multi Kelas

Melalui data pada *Confusion Matrix* selanjutnya perhitungan *Accuracy*, *Precision*, *Recall*, dan *F1-score* dapat dihitung menggunakan persamaan 11 sampai persamaan 16.

$$\text{Akurasi} = \frac{TPos + TNeg + TNet}{TNeg + TNet + TPos + FPosNeg + FPosNet + FNegPos + FNegNet + FNetPos + FNetNeg} \quad (11)$$

$$\text{Precision Positif} = \frac{TPos}{TPos + FPosNeg + FPosNet} \quad (12)$$

$$\text{Precision} = \frac{TPos + FPosNeg + FPosNet}{\text{Precision Pos} + \text{Precision Neg} + \text{Precision Net}} \quad (13)$$

$$\text{Recall Positif} = \frac{TPos}{TPos + FNegPos + FNegNet} \quad (14)$$


$$\text{Recall} = \frac{TPos + FNegPos + FNegNet}{\text{Recall Pos} + \text{Recall Neg} + \text{Recall Net}} \quad (15)$$

$$\text{F1-Score} = \frac{2 \times \frac{\text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}}}{\text{Recall} + \text{Precision}} \quad (16)$$

Parameter TNeg, TNet, TPos, FPosNeg, FPosNet, FNegPos, FNegNet, FNetPos, FNetNeg berturut-turut adalah *True Negative*, *True Netral*, *True Positive*, *False Positive Negative*, *False Positive Netral*, *False Negative Positive*, *False Negative Netral*, *False Netral Positive*, *False Netral Negative*.

Pada penelitian ini, menggunakan beberapa skenario pengujian yang ditunjukkan pada Gambar 4. Skenario pengujian dilakukan untuk memastikan kinerja yang optimal. Penelitian ini melakukan beberapa skenario uji coba untuk mendapatkan hasil akurasi terbaik dengan menggunakan metode yang diusulkan. Berikut skenario uji coba yang akan dilakukan:

1. Skenario 1 dengan pemodelan SVM (*Data Imbalance*)
2. Skenario 2 dengan pemodelan SVM (*Data Balance*)
3. Skenario 3 dengan pemodelan SVM + PSO (*Data Balance*)



Gambar 4. Skenario Evaluasi

4. Skenario 4 dengan pemodelan SVM + PSO (*Data Imbalance*)
5. Skenario 5 dengan prediksi sentimen 3 Bulan (September, Oktober dan November) 2023

3. HASIL DAN PEMBAHASAN

3.1. Pemahaman Data


Data yang diambil dengan Bahasa pemrograman Python 3.9 menggunakan *library google_play_scraper* tentang penggunaan aplikasi Flip, Neobank dan Bank Jago menggunakan data *imbalance* dan data *balance*. Data diambil sejak 01 Januari 2023 sampai 30 Juni 2023 dengan hasil dari aplikasi Flip sebanyak 177.839 ulasan, Neobank 150442 ulasan dan Bank Jago sebanyak 39092 ulasan. Contoh hasil dari *scraping* data pada tiap aplikasi ditunjukkan pada Tabel 3.

Tabel 3 Contoh Data Hasil *Scraping*

Username	Score	At	Content
een	5	06/01	Kerren aplikasi
juhaeria		/2023	memudahkan transfer
		08:47	dan free lg sukses
			selalu utk flip

Username	Score	At	Content
Chiva Bawell	5	06/01/2023 08:41	saya sangat puas menggunakan flip nyaman dan cepat
Muhamad Dafa	1	06/01/2023 11:10	yang eror aplikasi nya yang repot pengguna nya,ga jelas

Pada tahap pelabelan data kami melakukan proses pemberian label secara semi-otomatis menggunakan VADER (*Valence Aware Dictionary and sEntiment Reasoner*) sebagai teknik pelabelan otomatis namun dengan tambahan intervensi manual oleh ahli (Alenzi *et al.*, 2022). Seluruh dataset teks diproses menggunakan VADER untuk mendapatkan skor sentimen awal. Skor ini akan memberikan label dari sentimen teks. Selanjutnya, untuk teks dengan skor sentimen yang ambigu atau berada di dekat batas antara kategori (misalnya, skor mendekati nol) akan dilakukan pelabelan ulang secara manual oleh human annotator. Proses pelabelan data melibatkan ahli bahasa dengan dihubungkan data berdasarkan *rating* ulasan pengguna, hal ini untuk memastikan keakuratan dan konsistensi label yang diberikan.



Gambar 5. Hasil Pelabelan Data

Pada Gambar 5 terlihat bahwa terdapat dominasi sentimen positif pada ketiga aplikasi, Namun, terdapat perbedaan yang signifikan dalam tingkat kepuasan pengguna. Perbandingan eksplorasi sentimen antara ketiga aplikasi ini sangat bervariasi. Flip berhasil meraih tingkat kepuasan pengguna tertinggi dengan persentase sentimen positif sebesar 78.07%, jauh melampaui Neobank yang hanya memiliki 57.76%. Sebaliknya, Neobank menghadapi tantangan signifikan dengan persentase sentimen negatif mencapai 34.42%, hampir dua kali lipat dari Flip. Perbedaan yang mencolok ini menunjukkan bahwa Flip telah berhasil membangun reputasi yang sangat positif di mata pengguna.

Perbandingan sentimen positif dan negatif antar ketiga aplikasi memiliki implikasi yang signifikan bagi strategi bisnis masing-masing perusahaan. Tingginya sentimen positif pada Flip menunjukkan bahwa strategi produk dan pemasaran mereka telah berhasil membuahkan hasil. Di sisi lain, proporsi sentimen negatif yang tinggi pada Neobank menjadi alarm bagi perusahaan untuk melakukan evaluasi menyeluruh dan melakukan perbaikan yang diperlukan. Hasil analisis ini dapat digunakan sebagai dasar untuk mengambil keputusan bisnis yang lebih

baik, seperti pengembangan fitur baru, peningkatan kualitas layanan pelanggan, atau penyesuaian strategi pemasaran.

3.2. Persiapan Data dan Analisa Sentimen

Serangkaian langkah persiapan data digunakan dalam analisis data sentimen untuk mendapatkan kualitas data yang baik, terstruktur dengan benar, dan siap untuk diproses. *Preprocessing* data yang digunakan diantaranya ditunjukkan pada Tabel 4.


Metode TF-IDF yang digunakan untuk pembobotan dan pemilihan fitur kata. Seluruh kumpulan kata yang diambil adalah vektor hasil dari token dan stemming. Jumlah token yang muncul pada setiap dokumen akan dihitung menjadi nilai bobot token dan divisualisasikan. Pada tahap visualisasi data ini menggunakan *Word cloud* dan diagram batang untuk menampilkan kata-kata yang sering muncul. Metode *preprocessing* dan nilai bobot masing-masing kata telah dihitung menggunakan metode TF-IDF. Pada tahap visualisasi data menggunakan *Word cloud* dan diagram batang untuk menampilkan kata-kata yang sering muncul.

Tabel 4. *Preprocessing* Data


Input	Output
Data Cleaning	
Lumayan menghemat utk biaya admin antar Bank.ðŸœ	Lumayan menghemat utk biaya admin antar Bank
Case Folding	
Lumayan menghemat utk biaya admin antar Bank	lumayan menghemat utk biaya admin antar bank
Tokenizing	
lumayan menghemat utk biaya admin antar bank	['lumayan', 'menghemat', 'utk', 'biaya', 'admin', 'antar', 'bank']
Konversi Slang Word	
['lumayan', 'menghemat', 'utk', 'biaya', 'admin', 'antar', 'bank']	['lumayan', 'menghemat', 'untuk', 'biaya', 'admin', 'antar', 'bank']
Stopword Removal	
['lumayan', 'menghemat', 'untuk', 'biaya', 'admin', 'antar', 'bank']	['lumayan', 'menghemat', 'biaya', 'admin', 'bank']
Stemming	
lumayan menghemat biaya admin bank	lumayan hemat biaya admin bank

Dengan menggabungkan TF-IDF dengan *Word cloud*, dapat dapatkan visualisasi dari istilah/kata terpenting dalam sebuah dokumen atau *corpus*. Gambar 5 sampai dengan Gambar 10 merupakan eksplorasi data kata dan visualisasi data yang dilakukan pada semua aplikasi dan divisualisasikan melalui *Word Cloud* dan diagram. Dari analisa yang dilakukan sesuai jumlah mayoritas sentimen pada masing-masing aplikasi adalah sentimen positif sehingga ditemukan kata-kata positif sebagai kata-kata terbanyak untuk ketiga aplikasi yang dianalisa.

a. Visualisasi pada aplikasi Flip



Gambar 5. Word Cloud aplikasi Flip




Gambar 6. Diagram 10 kata terbanyak Flip

Gambar 6 menampilkan data kata yang sering muncul dalam ulasan aplikasi flip adalah “flip”, “transfer”, “bantu”, “aplikasi”, “mantap”, “bagus”, “mudah”, “pakai”, “transaksi” dan “bank”.

b. Visualisasi pada aplikasi Neobank



Gambar 7. Word Cloud aplikasi Neobank




Gambar 8. Diagram 10 kata terbanyak Neobank

Gambar 8 menunjukkan bahwa kata yang sering muncul dalam ulasan aplikasi flip adalah “aplikasi”, “nya”, “bank”, “neo”, “bagus”, “mantap”, “masuk”, “tolong”, “buka” dan “neobank”.

c. Visualisasi pada aplikasi Bank Jago



Gambar 9. Word Cloud aplikasi Bank Jago



Gambar 10. Diagram 10 kata terbanyak Bank Jago

Diagram batang pada Gambar 10 menunjukkan bahwa kata yang paling sering muncul dalam ulasan aplikasi flip adalah “jago”, “bank”, “bagus”, “mantap”, “aplikasi”, “nya”, “mudah”, “bantu”, “uang” dan “kasih”.

3.4. Modeling

Pada pendekatan pertama ini peneliti menggunakan klasifikasi SVM dengan kernel RBF (*Radial Basis Function*) digunakan secara default untuk klasifikasi sentimen dalam ulasan aplikasi Flip Neobank dan Bank Jago. Kernel RBF adalah pilihan umum untuk SVM karena dapat menangani masalah yang tidak linier dengan baik. Dalam kasus ini, SVM mencoba menemukan *hyperplane* yang memisahkan data ke dalam tiga kelas sentimen. K-Fold dilakukan untuk mengukur kinerja model dengan membagi dataset menjadi lima bagian dan melakukan pelatihan serta pengujian pada setiap iterasi

Pendekatan kedua menggunakan SVM dengan kernel RBF yang dioptimalkan menggunakan *Particle Swarm Optimization* (PSO). PSO digunakan untuk menemukan parameter optimal SVM seperti parameter C dan γ . PSO adalah algoritma optimasi yang mencari solusi terbaik dalam ruang pencarian parameter SVM. Dengan mengoptimalkan parameter, diharapkan kinerja model dapat ditingkatkan. Setelah parameter dioptimalkan, model SVM dengan kernel RBF dievaluasi menggunakan K-Fold CV untuk memastikan validitas dan keandalan hasil klasifikasi

3.5. Hasil Pengujian

Proses pengujian merupakan tahapan krusial dalam penelitian ini untuk memvalidasi dan mengevaluasi kinerja model yang telah dibangun. Dalam sub bab ini, kami menyajikan hasil dari semua

skenario percobaan yang telah dilakukan. Sesuai dengan rencana pengujian, lima skenario percobaan telah dijalankan dengan tujuan akhir yaitu untuk mengidentifikasi kerangka usulan terbaik yang dapat direkomendasikan.

3.5.1 Skenario Pertama

Dalam Skenario pertama ini menggunakan dataset asli ulasan aplikasi Flip, Neobank dan Bank Jago dengan kelas tidak seimbang. Melakukan pengujian dengan metode SVM menggunakan kernel RBF dan Mengevaluasi hasil klasifikasi dengan mengukur akurasi, presisi, *recall* dan *F1-Score*. Berikut hasil yang diperoleh dari skenario pertama.

Tabel 5. Hasil Skenario 1 Flip, Neobank dan Bank Jago

Aplikasi	Accurac y	Precision	Recall	F1- score
Flip	86%	82%	86%	84%
Neobank	76%	70%	76%	73%
Bank Jago	84%	80%	84%	82%

3.6.2 Skenario Kedua

Dalam Skenario kedua ini menggunakan dataset ulasan aplikasi Flip, Neobank dan Bank Jago dengan penanganan ketidakseimbangan kelas menggunakan metode *Oversampling*. Melakukan pengujian dengan metode SVM menggunakan kernel RBF dan Mengevaluasi hasil klasifikasi dengan mengukur akurasi, presisi, *recall* dan *F1-Score*. Tabel 6 menunjukkan hasil pengujian dari skenario kedua. Flip menunjukkan performa terbaik dengan skor 89% di semua metrik, diikuti oleh Bank Jago dengan performa baik pada 84-85%, sementara Neobank menunjukkan kinerja terendah dengan 77% di semua metrik evaluasi.

Tabel 6. Hasil Skenario 2 Flip, Neobank dan Bank Jago

Aplikasi	Accurac y	Precisio n	Recall	F1- score
Flip	89%	89%	89%	89%
Neobank	77%	77%	77%	77%
Bank Jago	84%	85%	84%	84%

3.6.3 Skenario Ketiga

Dalam skenario ketiga ini menggunakan dataset asli ulasan aplikasi Flip, Neobank dan Bank Jago dengan penanganan ketidakseimbangan kelas menggunakan metode *Oversampling*. Melakukan pengujian dengan metode SVM dan Optimasi dengan PSO serta menggunakan kernel RBF dan Mengevaluasi hasil klasifikasi dengan mengukur akurasi, presisi, *recall* dan *F1 Score*. Tabel 7 merupakan hasil yang diperoleh dari skenario ketiga.

Tabel 7. Hasil Skenario 3 Flip, Neobank dan Bank Jago

Aplikasi	Accurac y	Precision	Recall	F1- score
Flip	97%	97%	97%	97%
Neobank	95%	95%	95%	95%
Bank Jago	93%	93%	93%	93%

3.6.4 Skenario Keempat

Menggunakan dataset asli ulasan aplikasi Flip, Neobank dan Bank Jago dengan kelas tidak seimbang. Melakukan pengujian dengan metode SVM dan Optimasi dengan PSO serta menggunakan kernel RBF dan Mengevaluasi hasil klasifikasi dengan mengukur akurasi, presisi, *recall* dan *F1-Score*. Tabel 8 merupakan hasil pengujian pada skenario keempat. Menunjukkan hasil kinerja pada semua metrik evaluasi yang memuaskan untuk semua data yaitu dengan hasil diatas 95% disemua data.

Tabel 8. Hasil Skenario 4 Flip, Neobank dan Bank Jago

Aplikasi	Accurac y	Precision	Recall	F1- score
Flip	98%	98%	98%	98%
Neobank	96%	96%	96%	96%
Bank Jago	97%	97%	97%	97%

3.6.5 Skenario Kelima

Dalam skenario kelima adalah prediksi sentimen dengan menggunakan model terbaik dan menggunakan data ulasan dari bulan September sampai November 2023. Tabel 9 menunjukkan aplikasi Flip dan Bank Jago mendapatkan respon komentar pengguna dibanding NeoBank yang bisa menunjukkan justifikasi bahwa tingkat popularitas kedua aplikasi jauh melewati aplikasi NeoBank selain jumlah download.

Tabel 9. Data September sampai November 2023

Aplikasi	Jumlah data
Flip	3540
Neobank	1873
Bank Jago	3250

a. Aplikasi Flip

Tabel 10. Hasil skenario 5 pada aplikasi Flip

Bulan	Sentimen	Jumlah data	
September	Positif	550	1789
	Negatif	687	
	Netral	552	
Oktober	Positif	313	1107
	Negatif	466	
	Netral	328	
November	Positif	216	644
	Negatif	219	
	Netral	209	
Jumlah data			

Pada Tabel 10 menunjukkan hasil mayoritas sentimen dari aplikasi flip untuk tiga bulan adalah sentimen negatif. Hal ini mengindikasikan adanya masalah atau ketidakpuasan pengguna dalam menggunakan aplikasi, seperti bug, fitur yang tidak berfungsi dengan baik, atau pengalaman pengguna yang buruk. Penurunan kualitas layanan atau produk juga dapat menjadi penyebab sentimen negatif yang dominan. Untuk mengatasi situasi ini, disarankan untuk melakukan analisis mendalam, melakukan

perbaikan dan peningkatan aplikasi, serta membangun komunikasi yang lebih baik dengan pengguna. Dengan menangani dominasi sentimen negatif secara komprehensif, diharapkan aplikasi Flip dapat meningkatkan kepuasan pengguna dan memperoleh sentimen yang lebih positif di masa mendatang.

b. Aplikasi Neobank

Tabel 11. Hasil skenario 5 pada aplikasi Neobank

Bulan	Sentimen	Jumlah data	
September	Positif	188	534
	Negatif	175	
	Netral	171	
Jumlah data			
Oktober	Positif	200	621
	Negatif	201	
	Netral	220	
Jumlah data			
November	Positif	225	718
	Negatif	258	
	Netral	235	
Jumlah data			

Pada Tabel 11 menunjukkan hasil mayoritas sentimen dari aplikasi Neobank untuk tiga bulan adalah sentimen Negatif.

c. Aplikasi Bank Jago

Tabel 12. Hasil skenario 5 pada aplikasi Bank Jago

Bulan	Sentimen	Jumlah data	
September	Positif	386	1105
	Negatif	426	
	Netral	293	
Jumlah data			
Oktober	Positif	356	1163
	Negatif	500	
	Netral	307	
Jumlah data			
November	Positif	245	982
	Negatif	312	
	Netral	425	
Jumlah data			

Pada Tabel 12 menunjukkan hasil mayoritas sentimen dari aplikasi Bank Jago untuk tiga bulan adalah sentimen negatif.

Dari kesimpulan analisa 3 bulan didapatkan informasi bahwa sentimen negatif lebih banyak namun secara keseluruhan data mayoritas data yang telah dikumpulkan sentimen positif lebih mendominasi, menunjukkan aplikasi diterima dengan baik oleh pengguna secara umum.

3.6.6 Analisa Keseluruhan

Berdasarkan hasil pengujian pada Gambar 11 perbandingan kinerja model SVM dan SVMPSO, dapat dilihat bahwa model SVMPSO secara konsisten menunjukkan performa yang lebih baik dalam mengklasifikasikan data baik dalam kondisi


seimbang maupun tidak seimbang. Pada kondisi data seimbang, model SVMPSO mampu mencapai akurasi rata-rata sebesar 95% untuk ketiga layanan fintech yang dievaluasi, sedangkan model SVM tanpa optimasi PSO hanya mendapatkan nilai 77%. Hal ini mengindikasikan bahwa optimasi dengan Particle Swarm Optimization (PSO) telah berhasil meningkatkan kemampuan generalisasi model SVM.

Kondisi yang lebih menarik terjadi ketika data tidak seimbang. Model SVMPSO tetap menunjukkan ketahanan yang baik dengan akurasi rata-rata sebesar 96%, sementara model SVM mengalami penurunan yang lebih signifikan menjadi 76%. Hasil ini menunjukkan bahwa SVMPSO lebih robust terhadap ketidakseimbangan kelas yang sering terjadi dalam data nyata.

Khususnya pada layanan fintech "NeoBank", SVMPSO mencapai akurasi tertinggi sebesar 97% pada kondisi data tidak seimbang, sementara SVM hanya mampu mencapai 76%.

Pada akhirnya, hasil pengujian ini secara jelas menunjukkan keunggulan model SVMPSO dibandingkan model SVM, terutama dalam menghadapi tantangan ketidakseimbangan data. Integrasi PSO pada model SVM telah berhasil meningkatkan kinerja klasifikasi secara signifikan.

Penggunaan PSO meningkatkan kinerja model SVM pada semua aplikasi dan skenario, menunjukkan efektivitasnya dalam mengoptimalkan parameter SVM. Dari pengujian juga didapatkan kesimpulan analisa bahwa pada data seimbang memberikan hasil yang lebih baik dibandingkan dengan data tidak seimbang, sehingga menunjukkan bahwa proses penanganan ketidakseimbangan kelas tetap penting untuk dilakukan untuk mendapatkan kinerja optimal.



Gambar 11. Perbandingan kinerja metode usulan pada setiap aplikasi yang dianalisa

4. KESIMPULAN DAN SARAN

4.1 Kesimpulan

Berdasarkan hasil penelitian analisis sentimen ulasan aplikasi Flip, Neobank, dan Bank Jago dengan menggunakan model SVM dengan optimasi PSO. Berikut merupakan beberapa kesimpulan yang didapatkan dari penelitian.

1. Berdasarkan hasil pengujian, optimasi

parameter *Support Vector Machine* (SVM) dengan menggunakan algoritma *Particle Swarm Optimization* (PSO) dapat secara signifikan meningkatkan kinerja model dalam menganalisis sentimen ulasan aplikasi transfer antar bank, seperti pada aplikasi Flip, Neobank, dan Bank Jago. Pada situasi data tidak seimbang, penggunaan PSO meningkatkan performa SVM seperti yang terjadi pada aplikasi Flip, akurasi SVM meningkat dari 86% menjadi 98%, dengan presisi, *recall*, dan *F1-Score* semua mencapai 98%. Hal serupa terjadi pada aplikasi Neobank dan Bank Jago, di mana hasil meningkat menjadi 97%.

2. Hasil pengujian terhadap pengaruh ketidakseimbangan data menunjukkan bahwa model SVM cenderung mengalami penurunan kinerja pada kasus ketidakseimbangan. Penerapan *oversampling*, khususnya pada metode yang digunakan dalam penanganan data, memberikan solusi yang efektif. Pada aplikasi “Flip” dan “Neobank”, *oversampling* berhasil meningkatkan kinerja model yaitu pada aplikasi Flip pada metode SVM meningkat dari 86% menjadi 89% kemudian aplikasi Neobank juga meningkat dari 76% menjadi 77% mengatasi dampak negatif dari ketidakseimbangan data. Pada aplikasi Bank Jago seimbang. Dengan demikian, *oversampling* secara spesifik pada model SVM (*Data Imbalance*) dalam konteks masing-masing aplikasi telah terbukti efektif meningkatkan kinerja model dalam mengatasi ketidakseimbangan data. Namun pada penerapan yang menggunakan PSO berbanding terbalik dengan yang SVM yang mana hasilnya lebih baik menggunakan dataset asli (*Data Imbalance*) ketimbang menggunakan metode *oversampling* dengan beberapa kemungkinan bahwa penerapan PSO saja sudah cukup untuk mengatasi data yang tidak seimbang.

4.2 Saran

Pada penelitian ini terdapat beberapa saran yang dapat dikembangkan untuk penelitian selanjutnya yaitu:

1. Eksplorasi algoritma optimasi lainnya: melakukan evaluasi pada algoritma optimasi selain PSO untuk melihat potensi peningkatan performa pada analisis sentimen ulasan aplikasi.
2. Analisis sentimen pada aplikasi lain: Menganalisis sentimen pada aplikasi transfer antar bank lainnya untuk mendapatkan pemahaman yang lebih luas.
3. Optimasi hyperparameter lebih lanjut: Melakukan optimasi *hyperparameter* lebih mendalam pada model SVM dan algoritma PSO untuk mencari konfigurasi yang lebih optimal.

DAFTAR PUSTAKA

- ALENZI, B.M. *et al.* 2022. Automatic Annotation Performance of TextBlob and VADER on Covid Vaccination Dataset. *Intelligent Automation and Soft Computing*, 34(2), pp. 1311–1331. doi: <https://doi.org/10.32604/iasc.2022.025861>.
- ANTARA. 2024. BI: Transaksi perbankan digital Juli 2024 tumbuh sebesar 30,50 persen, Online. Doi: <https://www.antaranews.com/berita/4276551/bi-transaksi-perbankan-digital-juli-2024tumbuh-sebesar-3050-persen> (Accessed: 10 August 2024).
- 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), pp. 231–237. Doi: <https://doi.org/10.29207/resti.v5i2.2698>.
- BAREKSA. 2024. BI: Nilai Transaksi Digital Banking Bisa Tumbuh 23,2% di 2024. Online. doi: <https://www.bareksa.com/berita/saham/2023-11-30/bi-nilai-transaksi-digital-banking-bisa-tumbuh-232-di-2024> (Accessed: 10 August 2024).
- CHANDRA, M.A. & BEDI, S.S. 2021. Survey on SVM and their application in image classification. *International Journal of Information Technology (Singapore)*, 13(5). doi: <https://doi.org/10.1007/s41870-017-0080-1>.
- CHAPMAN, P. *et al.* 2000. CRISP-DM -Cross-Industry Standard Process for Data Mining-1.0 Step-by-step data mining guide. *CRISP-DM Consortium*, p. 76.
- FANG, X. & ZHAN, J. 2015. Sentiment analysis using product review data. *Journal of Big Data*, 2(1), p. 5. doi: <https://doi.org/10.1186/s40537-015-0015-2>.
- GOPI, A.P. *et al.* 2023. Classification of tweets data based on polarity using improved RBF kernel of SVM. *International Journal of Information Technology (Singapore)*, 15(2), pp. 965–980. doi: <https://doi.org/10.1007/s41870-019-00409-4>.
- HITAM, N.A., ISMAIL, A.R. & SAEED, F. (2019) ‘An Optimized Support Vector Machine (SVM) based on Particle Swarm Optimization (PSO) for Cryptocurrency Forecasting’, *Procedia Computer Science*, 163, pp. 427–433. doi: <https://doi.org/10.1016/j.procs.2019.12.125>.
- HU, N., PAVLOU, P.A. & ZHANG, J. 2006. Can online reviews reveal a product’s true quality? Empirical findings and analytical modeling of online word-of-mouth communication’, in *Proceedings of the 7th ACM conference on*

- Electronic commerce*, pp. 324–330. doi: <https://doi.org/10.1145/1134707.1134743>.
- IBRAHIM, Y., OKAFOR, E. & YAHAYA, B. 2021. Optimization of RBF-SVM hyperparameters using genetic algorithm for face recognit. *Nigerian Journal of Technology*, 39(4), pp. 1190–1197. doi: <https://doi.org/10.4314/njt.v39i4.27>.
- IN. 2023. *Digital Banking Tumbuh 13,48% Dengan Nilai Transaksi Rp 58.478 Triliun di 2023*, Online. doi: <http://www.wantiknas.go.id/id/berita/digital-banking-tumbuh-1348-dengan-nilai-transaksi-rp-58478-triliun-di-2023> (Accessed: 10 August 2024).
- LI, Y., WANG, Z. & DAI, H. 2023. Improved Parkinsonian tremor quantification based on automatic label modification and SVM with RBF kernel. *Physiological Measurement*, 44(2). doi: <https://doi.org/10.1088/1361-6579/acb8fe>.
- MACHOVÁ, K. *et al.* 2020. Lexicon-based sentiment analysis using particle swarm optimization. *Electronics (Switzerland)*, 9(8), pp. 1–22. doi: <https://doi.org/10.3390/electronics9081317>.
- METODE, M. *et al.* 2022. Analisis Sentimen Ulasan Pengguna Pada Aplikasi Google Classroom', 4221, pp. 221–229.
- MURSIANTO, G.A., WIDIYANTO, D. & WAHYONO, B.T. 2022. Analisis Sentimen Ulasan Pengguna Pada Aplikasi Google Classroom Menggunakan Metode SVM Dan Seleksi Fitur PSO. *Informatik : Jurnal Ilmu Komputer*, 18(3), p. 221. doi: <https://doi.org/10.52958/iftk.v18i3.4685>.
- NATALIA, D. & SHIHAB, M. 2018. Public Relations Strategies to Built Financial Technology (Fintech) Awareness The Ikoinsworks Way. 260(Icomacs), pp. 254–257. doi: <https://doi.org/10.2991/icomacs-18.2018.62>.
- NGUYEN, N.K. & VU, P.T. 2022. A Novel Combination of Kernel Radial Basis Function and Finite Element Methods for 2-D Time-Harmonic Eddy Current Problems. *IEEE Transactions on Magnetics*, 58(1). doi: <https://doi.org/10.1109/TMAG.2021.3127651>.
- SCHRÖER, C., KRUSE, F. & GÓMEZ, J.M. 2021. A systematic literature review on applying CRISP-DM process model. *Procedia Computer Science*, pp. 526–534. doi: <https://doi.org/10.1016/j.procs.2021.01.199>.
- SEPTIANI, K. 2022. Perbandingan Analisis Sentimen Terhadap Pembayaran Digital “Go-Pay” Dan “Ovo” Di Media Sosial Twitter Menggunakan Metode Naive Bayes Dan Word Cloud', *Jurnal Ilmu Data*, 2(10), p. 1.
- XIA, X. *et al.* 2020. Triple Archives Particle Swarm Optimization. *IEEE Transactions on Cybernetics*, 50(12), pp. 4862–4875. doi: <https://doi.org/10.1109/TCYB.2019.2943928>.

Halaman ini sengaja dikosongkan