

Perbandingan Teknik Optimasi *Grid Search* dan *Randomized Search* dalam Meningkatkan Akurasi Metode Klasifikasi SVM Pada Sentimen Ulasan Pengguna Aplikasi JKN Mobile

Agus Dendi Rachmatsyah¹, Tri Sugihartono^{2*}, Khoiril Irfan³

¹Fakultas Teknologi Informasi, Sistem Informasi, Institut Sains dan Bisnis Atma Luhur, Pangkalpinang, Indonesia

^{2,3}Fakultas Teknologi Informasi, Teknik Informatika, Institut Sains dan Bisnis Atma Luhur, Pangkalpinang, Indonesia

E-mail: ¹dendi@atmaluhur.ac.id, ^{2*}trisugihartono@atmaluhur.ac.id,
³2311500034@mahasiswa.atmaluhur.ac.id
(* : corresponding author)

Abstrak

Penelitian ini membahas perbandingan dua teknik optimasi, Grid Search dan Randomized Search, dalam meningkatkan akurasi metode klasifikasi Support Vector Machine (SVM) pada analisis sentimen ulasan pengguna aplikasi JKN Mobile. Masalah yang dihadapi adalah rendahnya akurasi klasifikasi SVM dalam analisis sentimen ketika parameter hiper tidak dioptimalkan secara efektif. Penelitian ini bertujuan untuk mengidentifikasi teknik optimasi yang lebih efektif dalam meningkatkan performa model SVM. Metodologi penelitian mencakup langkah-langkah pengumpulan data ulasan pengguna, preprocessing, ekstraksi fitur, pembagian data, pelatihan model, optimasi parameter hiper, serta evaluasi model. Selain itu, digunakan Synthetic Minority Over-Sampling Technique (SMOTE) untuk menangani ketidakseimbangan kelas. Hasil penelitian menunjukkan bahwa kombinasi SVM dengan Randomized Search memberikan akurasi tertinggi sebesar 82%, dibandingkan dengan Grid Search yang menghasilkan akurasi 81,5%. Waktu eksekusi untuk Randomized Search juga lebih cepat, yakni 1 menit 21 detik dibandingkan dengan Grid Search yang memerlukan 3 menit 28 detik. Teknik SMOTE berhasil meningkatkan keseimbangan distribusi kelas sentimen negatif, netral, dan positif, meskipun nilai F1-score untuk kelas netral dan positif tetap rendah. Kesimpulannya, Randomized Search lebih unggul dalam hal efisiensi waktu dan peningkatan akurasi, meskipun tantangan masih ada dalam mengklasifikasikan sentimen netral dan positif.

Kata kunci: Support Vector Machine, Grid Search, Randomized Search, Sentimen Analysis, SMOTE.

Abstract

This study discusses the comparison of two optimization techniques, Grid Search and Randomized Search, in improving the accuracy of the Support Vector Machine (SVM) classification method in sentiment analysis of JKN Mobile application user reviews. The problem faced is the low accuracy of SVM classification in sentiment analysis when hyper parameters are not optimized effectively. This study aims to identify a more effective optimization technique in improving the performance of the SVM model. The research methodology includes the steps of collecting user review data, preprocessing, feature extraction, data sharing, model training, hyper parameter optimization, and model evaluation. In addition, Synthetic Minority Over-Sampling Technique (SMOTE) is used to handle class imbalance. The results show that the combination of SVM with Randomized Search provides the highest accuracy of 82%, compared to Grid Search which produces an accuracy of 81.5%. The execution time for Randomized Search is also faster, which is 1 minute 21 seconds compared to Grid Search which requires 3 minutes 28 seconds. The SMOTE technique successfully improves the balance of the distribution of negative, neutral, and positive sentiment classes, although the F1-score values for the neutral and positive classes remain low. In conclusion, Randomized Search is superior in terms of time efficiency and accuracy improvement, although challenges still remain in classifying neutral and positive sentiments.

Keywords: Support Vector Machine, Grid Search, Randomized Search, Sentiment Analysis, SMOTE.

1. PENDAHULUAN

Dalam beberapa tahun terakhir, perkembangan teknologi digital telah mendorong transformasi di berbagai sektor, termasuk kesehatan. Aplikasi kesehatan digital, seperti JKN

Mobile, menjadi platform penting bagi masyarakat untuk mengakses layanan kesehatan secara lebih mudah. Selain itu, aplikasi ini memungkinkan pengguna untuk memberikan umpan balik atau ulasan yang berharga terkait layanan yang mereka terima. Ulasan pengguna tersebut mengandung sentimen yang dapat mencerminkan tingkat kepuasan atau ketidakpuasan mereka terhadap layanan kesehatan. Oleh karena itu, analisis sentimen menjadi alat penting untuk mengidentifikasi pola dan tren dalam persepsi pengguna terhadap Aplikasi [1]. Namun, tantangan utama dalam analisis ini terletak pada bagaimana cara meningkatkan akurasi klasifikasi sentimen dari data teks yang beragam [2].

Salah satu metode yang sering digunakan dalam analisis sentimen adalah Support Vector Machine (SVM), sebuah algoritma pembelajaran mesin yang dikenal karena kemampuannya menangani data dimensi tinggi dan memiliki performa yang baik pada berbagai tugas klasifikasi teks [3]. Meskipun demikian, efektivitas SVM sangat bergantung pada pemilihan parameter hiper, seperti C (regularization) dan γ (koefisien kernel RBF). Pemilihan parameter yang tidak tepat dapat menyebabkan performa model yang suboptimal, mengurangi akurasi dalam mengklasifikasikan ulasan pengguna. Dalam upaya mengatasi masalah ini, optimasi parameter hiper menjadi langkah penting dalam meningkatkan performa SVM [4].

Untuk mengoptimalkan parameter hiper SVM, teknik Grid Search dan Randomized Search sering digunakan. Grid Search adalah metode pencarian parameter yang dilakukan secara sistematis dengan mengevaluasi setiap kombinasi parameter yang mungkin dalam ruang pencarian. Teknik ini dianggap menghasilkan solusi yang optimal karena semua kemungkinan diuji secara ekstensif. Namun, Grid Search memiliki kelemahan dalam hal efisiensi waktu karena proses ini memakan waktu yang sangat lama, terutama ketika ruang parameter besar atau dataset yang digunakan sangat besar [5]. Pada sisi lain, Randomized Search menawarkan pendekatan yang lebih efisien dengan memilih kombinasi parameter secara acak dari ruang pencarian. Teknik ini tidak menjamin menemukan solusi optimal seperti Grid Search, tetapi dalam banyak kasus, Randomized Search dapat menemukan parameter yang mendekati optimal dengan waktu komputasi yang jauh lebih cepat [6].

Selain masalah optimasi parameter, tantangan lain yang dihadapi dalam analisis sentimen adalah ketidakseimbangan kelas dalam data. Ulasan dengan sentimen negatif biasanya lebih dominan dibandingkan ulasan dengan sentimen positif atau netral. Ketidakseimbangan ini dapat menyebabkan model klasifikasi lebih cenderung mengklasifikasikan data ke kelas mayoritas, yang mengakibatkan penurunan akurasi untuk kelas minoritas [7]. Untuk mengatasi masalah ini, salah satu teknik yang populer digunakan adalah Synthetic Minority Over-Sampling Technique (SMOTE). SMOTE bekerja dengan menambah sampel sintetis untuk kelas minoritas sehingga dapat meningkatkan keseimbangan distribusi kelas dan memperbaiki performa model klasifikasi pada kelas minoritas [8].

Beberapa penelitian telah membandingkan efektivitas Grid Search dan Randomized Search dalam konteks optimasi parameter hiper, baik pada tugas klasifikasi umum maupun analisis sentimen. Misalnya, penelitian [9] menunjukkan bahwa Randomized Search sering kali dapat mencapai hasil yang setara atau bahkan lebih baik dibandingkan Grid Search dengan waktu eksekusi yang jauh lebih singkat. Dalam konteks analisis sentimen, menggunakan teknik optimasi ini dalam kombinasi dengan metode penanganan ketidakseimbangan data, seperti SMOTE [10], dapat memberikan hasil yang lebih akurat dalam mengklasifikasikan sentimen ulasan pengguna. Namun, masih sedikit penelitian yang secara khusus mengeksplorasi efektivitas teknik-teknik ini dalam konteks analisis sentimen aplikasi kesehatan, seperti JKN Mobile [11].

Penelitian ini bertujuan untuk membandingkan dua teknik optimasi parameter hiper, yaitu Grid Search dan Randomized Search, dalam meningkatkan akurasi model SVM pada tugas klasifikasi sentimen ulasan pengguna aplikasi JKN Mobile. Selain itu, penelitian ini juga mengeksplorasi dampak dari penerapan teknik SMOTE [12] dalam menangani masalah ketidakseimbangan kelas pada data ulasan. Melalui evaluasi ini, diharapkan dapat diperoleh informasi yang lebih jelas mengenai teknik optimasi mana yang lebih efisien dan efektif dalam konteks ini.

Adapun langkah-langkah yang akan dilakukan dalam penelitian ini meliputi pengumpulan data ulasan pengguna aplikasi JKN Mobile, *pre-processing* data [13] untuk menghilangkan *noise*, ekstraksi fitur menggunakan teknik TF-IDF untuk merepresentasikan teks, pembagian dataset menjadi data pelatihan dan pengujian, serta pelatihan model SVM dengan optimasi parameter menggunakan Grid Search dan Randomized Search. Setelah model dioptimasi, teknik SMOTE akan diterapkan untuk menangani ketidakseimbangan kelas, dan hasilnya akan dievaluasi berdasarkan metrik akurasi, precision, recall, dan F1-score untuk setiap kelas sentiment [14].

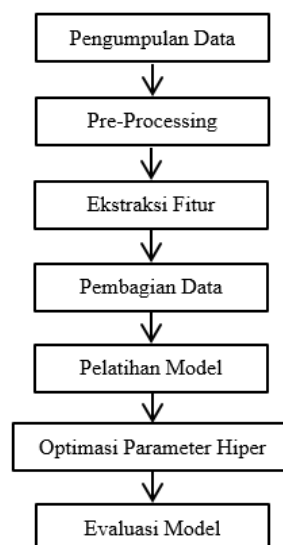
Dengan mengevaluasi efektivitas kedua teknik optimasi ini, diharapkan penelitian ini dapat memberikan kontribusi pada pemahaman lebih dalam mengenai penerapan Grid Search [15] dan Randomized Search [16] pada analisis sentimen, khususnya dalam konteks aplikasi kesehatan digital. Temuan penelitian ini diharapkan dapat membantu pengembang aplikasi dan peneliti lainnya dalam memilih strategi optimasi yang tepat untuk meningkatkan akurasi model klasifikasi pada dataset yang memiliki karakteristik serupa.

Penelitian ini berfokus pada perbandingan efisiensi dan akurasi antara Grid Search dan Randomized Search dalam mengoptimalkan metode klasifikasi Support Vector Machine (SVM) untuk analisis sentimen. Secara spesifik, penelitian ini menyoroti efisiensi waktu eksekusi dan peningkatan akurasi, terutama dalam konteks ulasan pengguna aplikasi JKN Mobile, yang menjadi domain baru. Meskipun penelitian sebelumnya, seperti yang dilakukan oleh [17] sudah mengeksplorasi Randomized Search untuk optimasi SVM dalam skenario yang berbeda (misalnya aktivitas kerja dari rumah), fokus mereka tidak mencakup perbandingan mendalam dengan Grid Search dalam konteks distribusi kelas yang tidak seimbang.

Lebih lanjut, studi lain seperti yang dilakukan oleh [15], membahas optimasi parameter menggunakan Grid Search pada model Long Short-Term Memory (LSTM). Namun, konteksnya lebih ke pengenalan aktivitas manusia, tanpa mencakup efisiensi waktu eksekusi atau penerapan SMOTE untuk penanganan ketidakseimbangan kelas. Dalam hal ini, penelitian yang diajukan memperluas cakupan dengan menggunakan SMOTE dan mengevaluasi efisiensi optimasi kedua metode ini dalam skenario analisis sentimen spesifik.

2. METODE PENELITIAN

Penelitian ini bertujuan untuk membandingkan efektivitas dua teknik optimasi, yaitu Grid Search [18], dan Randomized Search, dalam meningkatkan akurasi metode klasifikasi Support Vector Machine (SVM) pada analisis sentimen ulasan pengguna aplikasi JKN Mobile. Langkah-langkah dalam metode penelitian ini meliputi pengumpulan data, *pre-processing*, ekstraksi fitur, pembagian data, pelatihan model, optimasi parameter hiper, serta evaluasi model.



Gambar 1. Metodologi Penelitian

2.1. Pengumpulan Data

Data ulasan pengguna aplikasi JKN Mobile dikumpulkan dari platform Google Play Store menggunakan teknik web scraping. Data yang dikumpulkan terdiri dari ulasan pengguna berupa teks, tanggal, dan rating yang diberikan oleh pengguna. Rentang waktu pengumpulan data dilakukan selama satu tahun terakhir untuk memastikan relevansi ulasan yang dianalisis. Total data ulasan yang dikumpulkan berjumlah sekitar 1.000 ulasan.

2.2. Pre-processing Data

Proses *pre-processing* bertujuan untuk membersihkan dan mempersiapkan data ulasan sebelum analisis sentimen dilakukan. Langkah-langkah *pre-processing* meliputi:

Step 1 - Lowercase:

Tabel 1. Pre-Processing Step 1 Lowercase

	Content		Lowercase
1	Aplikasi sampah. Tiap kali mau cek sesuatu sel...	1	aplikasi sampah. tiap kali mau cek sesuatu sel...
2	Mohon di perbaiki lagi sistemnya, pengalaman k...	2	mohon di perbaiki lagi sistemnya, pengalaman k...
3	Pendaftarannya sangat sulit Kode OTP nya lama ...	3	pendaftarannya sangat sulit kode otp nya lama ...
4	Aplikasi buruk tp harus dipunya. Aplikasi dah ...	4	aplikasi buruk tp harus dipunya. aplikasi dah ...
5	Sangat lambat, cuma mau ganti email dan pin aj...	5	sangat lambat, cuma mau ganti email dan pin aj...

Pada tahap *Lowercase*, seluruh teks pada ulasan pengguna dikonversi menjadi huruf kecil (*lowercase*) untuk memastikan keseragaman dalam proses analisis teks. Ini dilakukan untuk menghilangkan perbedaan antara huruf besar dan huruf kecil yang dapat memengaruhi proses pemrosesan data, terutama dalam analisis sentimen atau klasifikasi teks. Sebagai contoh, pada baris pertama, teks awal "Aplikasi sampah. Tiap kali mau cek sesuatu sel..." dikonversi menjadi "aplikasi sampah. tiap kali mau cek sesuatu sel...". Hal ini berlaku juga pada baris-baris selanjutnya, di mana seluruh kata yang awalnya menggunakan huruf kapital diubah menjadi huruf kecil, seperti "Mohon di perbaiki lagi sistemnya..." menjadi "mohon di perbaiki lagi sistemnya...". Dengan melakukan langkah ini, data ulasan menjadi lebih seragam dan memudahkan algoritma untuk memproses informasi tanpa terganggu oleh variasi kapitalisasi.

Tabel 2. Pre-Processing Step 2 Remove Characters

	Lowercase		no_special_chars
1	aplikasi sampah. tiap kali mau cek sesuatu sel...	1	aplikasi sampah tiap kali mau cek sesuatu sela...
2	mohon di perbaiki lagi sistemnya, pengalaman k...	2	mohon di perbaiki lagi sistemnya pengalaman ko...
3	pendaftarannya sangat sulit kode otp nya lama ...	3	pendaftarannya sangat sulit kode otp nya lama ...
4	aplikasi buruk tp harus dipunya. aplikasi dah ...	4	aplikasi buruk tp harus dipunya aplikasi dah ...
5	sangat lambat, cuma mau ganti email dan pin aj...	5	sangat lambat cuma mau ganti email dan pin aja...

Pada Step 2 – Remove Special Characters, proses ini dilakukan untuk membersihkan teks dari karakter-karakter khusus, seperti tanda baca, simbol, atau karakter non-alfabet lainnya, yang tidak relevan dalam analisis teks. Langkah ini membantu meningkatkan kualitas data untuk proses pemrosesan teks selanjutnya, terutama dalam model pembelajaran mesin atau analisis sentimen.

Sebagai contoh, pada baris pertama, teks "aplikasi sampah. tiap kali mau cek sesuatu sel..." diubah menjadi "aplikasi sampah tiap kali mau cek sesuatu sela...", di mana tanda titik dihapus. Pada baris kedua, kalimat "mohon di perbaiki lagi sistemnya, pengalaman k..." diubah menjadi "mohon di perbaiki lagi sistemnya pengalaman ko...", dengan penghapusan tanda koma. Proses serupa dilakukan pada baris-baris lainnya, di mana semua tanda baca seperti titik, koma, dan simbol lainnya dihilangkan.

Tabel 3. *Pre-Processing Step 3 Remove Extra Space*

	<i>no_special_chars</i>		<i>Clean text</i>
1	aplikasi sampah tiap kali mau cek sesuatu sela...	1	aplikasi sampah tiap kali mau cek sesuatu sela...
2	mohon di perbaiki lagi sistemnya pengalaman ko...	2	mohon di perbaiki lagi sistemnya pengalaman ko...
3	pendaftarannya sangat sulit kode otp nya lama ...	3	pendaftarannya sangat sulit kode otp nya lama ...
4	aplikasi buruk tp harus dipunya aplikasi dah	4	aplikasi buruk tp harus dipunya aplikasi dah l...
5	sangat lambat cuma mau ganti email dan pin aja...	5	sangat lambat cuma mau ganti email dan pin aja...

Tabel 4. *Pre-Processing Step 4 Remove Stopwords*

	<i>Clean text</i>		<i>final_clean_text</i>
1	aplikasi sampah tiap kali mau cek sesuatu sela...	1	aplikasi sampah tiap kali mau cek sesuatu sela...
2	mohon di perbaiki lagi sistemnya pengalaman ko...	2	mohon di perbaiki lagi sistemnya pengalaman ko...
3	pendaftarannya sangat sulit kode otp nya lama ...	3	pendaftarannya sangat sulit kode otp nya lama ...
4	aplikasi buruk tp harus dipunya aplikasi dah l...	4	aplikasi buruk tp harus dipunya aplikasi dah l...
5	sangat lambat cuma mau ganti email dan pin aja...	5	sangat lambat cuma mau ganti email dan pin aja...

Langkah Remove Stopwords dalam pemrosesan teks merupakan tahap penting dalam *Natural Language Processing* (NLP) yang bertujuan menghapus kata-kata yang tidak memiliki kontribusi signifikan terhadap analisis, seperti kata sambung atau kata fungsi yang biasanya tidak menambah nilai pada konteks teks. Stopwords ini biasanya berupa kata-kata seperti "dan", "yang", "di", "adalah", dan lain-lain. Dalam tabel yang diberikan, teks ulasan pengguna aplikasi JKN Mobile telah diproses melalui tahap remove stopwords, yang ditunjukkan pada kolom "Clean Text" dan "Final Clean Text". Pada kedua kolom tersebut, terlihat bahwa kata-kata yang tidak relevan dihapus untuk menyisakan kata-kata yang lebih penting dalam konteks analisis. Misalnya, kalimat awal "aplikasi sampah tiap kali mau cek sesuatu selalu ada masalah" setelah diproses menjadi "aplikasi sampah tiap kali cek sesuatu selalu masalah." Kata-kata seperti "mau" dan "ada" dihapus karena dianggap *stopwords* yang tidak menambah makna signifikan pada analisis.

Pentingnya menghapus *stopwords* terletak pada beberapa hal. Pertama, ini membantu meningkatkan akurasi analisis, karena model akan lebih fokus pada kata-kata penting yang benar-benar memengaruhi hasil, misalnya kata-kata yang membawa sentimen positif atau negatif. Kedua, proses ini mengurangi dimensi data, yang berarti ukuran data menjadi lebih kecil dan lebih mudah diproses. Hal ini juga berdampak pada peningkatan efisiensi model, karena dengan data yang lebih bersih dan ringkas, algoritma dapat bekerja lebih cepat dan memberikan hasil yang lebih akurat. Dalam konteks analisis sentimen ulasan aplikasi JKN Mobile, langkah ini membantu membersihkan teks dari kata-kata tidak relevan, sehingga model dapat menangkap esensi dari ulasan dan memberikan penilaian yang lebih efektif.

2.3. Ekstraksi Fitur

Setelah pre-processing, ekstraksi fitur dilakukan menggunakan metode Term Frequency-Inverse Document Frequency (TF-IDF) [16]. Metode ini mengonversi teks ulasan menjadi representasi numerik yang siap digunakan dalam model SVM. TF-IDF memberikan bobot pada setiap kata berdasarkan frekuensinya dalam dokumen; kata-kata yang lebih sering muncul mendapatkan bobot yang lebih rendah, sedangkan kata-kata yang lebih jarang namun penting mendapatkan bobot yang lebih tinggi.

2.4. *Balancing* Data Menggunakan SMOTE

Balancing Data adalah langkah penting dalam pemrosesan data, terutama ketika menangani dataset yang tidak seimbang, di mana jumlah sampel dalam satu kelas jauh lebih banyak daripada

kelas lainnya. Dalam konteks klasifikasi, ketidakseimbangan ini dapat menyebabkan model cenderung memprediksi kelas mayoritas dan mengabaikan kelas minoritas, yang akhirnya menurunkan akurasi prediksi pada kelas-kelas yang lebih sedikit datanya. Misalnya, pada analisis sentimen ulasan aplikasi JKN Mobile, jumlah ulasan negatif mungkin jauh lebih banyak dibandingkan ulasan netral atau positif. Jika tidak diatasi, model klasifikasi seperti Support Vector Machine (SVM) akan lebih cenderung memprediksi ulasan negatif karena dominasi data tersebut.

SMOTE (Teknik Over-Sampling Minoritas Sintetis) bekerja dengan meningkatkan jumlah sampel kelas minoritas secara sintetis—yaitu, sampel baru dibuat melalui interpolasi antara titik-titik data minoritas yang ada. Ini adalah salah satu teknik yang paling umum digunakan untuk mengatasi masalah ketidakseimbangan data. Ini berbeda dari pendekatan tradisional yang hanya menduplikasi data minoritas, karena SMOTE menciptakan variasi baru dari data minoritas yang meningkatkan generalisasi model.

Cara kerja SMOTE melibatkan beberapa langkah. Pertama, SMOTE memilih sampel dari kelas minoritas secara acak, lalu menentukan beberapa tetangga terdekat berdasarkan jarak tertentu, misalnya jarak Euclidean. Kemudian, SMOTE membuat sampel baru dengan menggabungkan data asli dan tetangga terdekatnya, menghasilkan data baru yang berada di antara dua titik tersebut. Dengan cara ini, variasi baru dari kelas minoritas dihasilkan tanpa hanya mengulang sampel yang sudah ada.

Manfaat dari SMOTE adalah mampu mengatasi ketidakseimbangan data dan meningkatkan performa model dalam memprediksi kelas minoritas, yang sebelumnya mungkin kurang dipelajari oleh model. Dengan data yang lebih seimbang, model klasifikasi seperti SVM dapat meningkatkan akurasi prediksi, terutama untuk kelas minoritas, karena semua kelas kini memiliki representasi yang lebih baik dalam proses pembelajaran.

2.5. Pembagian Data

Data pelatihan (training data) dan data pengujian adalah dua kelompok yang terpisah dari data ulasan. Dalam penelitian ini, 80% data digunakan untuk pelatihan dan 20% untuk pengujian. Untuk mengevaluasi dampak jumlah data pelatihan terhadap kinerja model, skenario pembagian ini dipilih.

2.6. Pelatihan Model SVM

Model klasifikasi Support Vector Machine (SVM) digunakan sebagai algoritma utama dalam analisis sentimen. Model SVM dilatih menggunakan dataset yang telah dibagi dan fitur-fitur yang diekstraksi dari ulasan pengguna. SVM dipilih karena kinerjanya yang unggul dalam klasifikasi teks dan kemampuannya untuk bekerja dengan baik pada dataset yang memiliki dimensi tinggi.

2.7. Optimasi Parameter Hiper

Untuk meningkatkan performa SVM, penelitian ini menerapkan tiga teknik optimasi parameter hiper, yaitu Grid Search [19] dan Randomized Search. Grid Search melakukan pencarian secara menyeluruh (exhaustive) pada grid parameter yang telah ditentukan sebelumnya. Setiap kombinasi nilai parameter diuji, dan parameter yang memberikan performa terbaik dipilih sebagai hasil akhir. Meskipun metode ini sederhana dan sering memberikan hasil optimal, Grid Search membutuhkan waktu komputasi yang cukup tinggi karena harus mencoba semua kombinasi parameter yang mungkin, tanpa memperhitungkan efisiensi waktu.

Sebaliknya, Randomized Search menggunakan pendekatan yang lebih cepat dengan memilih subset acak dari kombinasi parameter, sehingga tidak harus menguji setiap kemungkinan kombinasi seperti pada Grid Search [17]. Metode ini jauh lebih efisien dalam hal waktu komputasi, tetapi karena tidak mengeksplorasi seluruh ruang parameter, hasil yang diperoleh bisa kurang optimal dibandingkan dengan Grid Search. Namun, dalam banyak kasus, Randomized Search masih dapat memberikan performa yang sangat baik dengan waktu komputasi yang lebih singkat.

2.8. Evaluasi Model

Evaluasi performa model dilakukan menggunakan data pengujian (testing data), dengan beberapa metrik evaluasi yang digunakan untuk mengukur kinerja model. Metrik pertama adalah akurasi, yang mengukur persentase prediksi yang benar dari total prediksi yang dilakukan oleh model. Selanjutnya, presisi digunakan untuk mengukur rasio ulasan positif yang diklasifikasikan dengan benar terhadap total ulasan positif yang diklasifikasikan sebagai positif. Recall mengukur rasio ulasan positif yang diklasifikasikan dengan benar terhadap total ulasan positif yang sebenarnya. Untuk memberikan gambaran yang lebih seimbang antara presisi dan recall, digunakan F1-Score, yaitu rata-rata harmonik dari kedua metrik tersebut. Evaluasi ini memungkinkan pengukuran yang lebih menyeluruh atas kinerja model, terutama dalam situasi di mana distribusi kelas tidak seimbang.

Performa dari setiap teknik optimasi, yaitu Grid Search dan Randomized Search, dibandingkan berdasarkan metrik-metrik ini untuk menentukan teknik mana yang memberikan akurasi dan performa terbaik. Dengan demikian, perbandingan ini membantu memilih teknik optimasi yang paling efektif dalam meningkatkan kinerja model pada analisis sentimen ulasan pengguna aplikasi JKN Mobile.

3. HASIL DAN PEMBAHASAN

Hasil analisis yang dilakukan menggunakan Support Vector Machine (SVM) yang menggunakan metode optimasi Grid Search dan Randomized Search menunjukkan bahwa akurasi meningkat setelah pengaturan parameter hiper. Sebelum optimasi, model SVM yang digunakan pada data ulasan aplikasi JKN Mobile memiliki akurasi sebesar 79,50%.

Tabel 5. Hasil *Balance* Data Menggunakan SMOTE

	<i>Class distribution before balancing</i>	<i>Class distribution after SMOTE</i>
Negatif	815	652
Positif	100	652
Netral	85	652

Tabel 6. Hasil Performance Model SVM sebelum Menggunakan *Technique* SMOTE

Accuracy : 77.50%				
	Precision	Recall	F1-score	Support
Negatif	0.84	0.91	0.88	163
Netral	0.08	0.07	0.07	15
Positif	0.50	0.23	0.31	22

Tabel 7. Hasil Performance Model SVM pasca Menggunakan *Technique* SMOTE

Accuracy : 79.50%				
	Precision	Recall	F1-score	Support
Negatif	0.83	0.96	0.89	163
Netral	0.00	0.00	0.00	15
Positif	0.50	0.09	0.15	22

Tabel 8. Hasil Performance Mengkombinasikan Optimasi *Grid Search* [15]

Accuracy : 81.50%				
	Precision	Recall	F1-score	Support
Negatif	0.81	1.00	0.90	163
Netral	0.00	0.00	0.00	15
Positif	0.00	0.00	0.00	22

Tabel 9. Hasil Performance Mengkombinasikan Optimasi *Randomized Search*

Accuracy : 82.00%				
	Precision	Recall	F1-score	Support
Negatif	0.82	1.00	0.90	163
Netral	0.00	0.00	0.00	15
Positif	1.00	0.05	0.09	22

Tabel 10. Perbandingan Teknik Optimasi *Grid Search*[17] dengan *Randomized Search*

Teknik Optimasi	Time Execution	Accuration	C	Gamma	Kernel
Grid Search	3 minute 28 second	81.50%	10	scale	Rbf
Randomized Search	1 minute 21 second	82%	4.660699	0.619386	Rbf

Setelah optimasi menggunakan Grid Search, akurasi meningkat menjadi 81,50%, dan dengan Randomized Search akurasi meningkat lebih lanjut menjadi 82,00%. Hasil ini menunjukkan bahwa optimasi parameter hiper berperan signifikan dalam meningkatkan kinerja klasifikasi SVM, di mana Randomized Search memberikan hasil yang sedikit lebih baik dibandingkan Grid Search.

Selain itu, waktu eksekusi kedua teknik optimasi juga dibandingkan. Grid Search membutuhkan waktu 3 menit 28 detik untuk menyelesaikan optimasi parameter, sementara Randomized Search hanya membutuhkan 1 menit 21 detik. Perbedaan signifikan dalam waktu eksekusi ini menunjukkan bahwa Randomized Search lebih efisien dari segi waktu, terutama dalam menangani ruang parameter yang besar. Hasil ini sejalan dengan temuan [15] yang menyatakan bahwa Randomized Search sering kali lebih cepat dalam menemukan parameter yang mendekati optimal dibandingkan dengan Grid Search.

Hasil evaluasi performa model setelah optimasi mencakup metrik ketepatan, recall, dan skor F1 untuk kelas sentimen negatif, netral, dan positif. Pada Grid Search, ketepatan kelas negatif adalah 0,81, dengan recall 1,00, dan skor F1 0,90. Namun, kelas netral dan positif menunjukkan hasil yang jauh lebih rendah, dengan F1-score masing-masing 0,00 dan 0,00. Hal ini mengindikasikan bahwa meskipun model dapat mengklasifikasikan kelas negatif dengan sangat baik, performanya pada kelas netral dan positif masih jauh dari memuaskan. Ketidakseimbangan distribusi kelas menjadi salah satu faktor utama yang memengaruhi hasil ini.

Pada model yang dioptimasi dengan Randomized Search, performa untuk kelas negatif tetap kuat dengan precision 0,82, recall 1,00, dan F1-score 0,90. Namun, yang menarik adalah peningkatan pada kelas positif, di mana precision mencapai 1,00 meskipun recall masih rendah di angka 0,05, menghasilkan F1-score sebesar 0,09. Walaupun peningkatan pada kelas positif terlihat dalam metrik precision, hasil ini tetap menunjukkan tantangan besar dalam mengklasifikasikan kelas minoritas, seperti kelas netral dan positif, terutama dalam dataset yang tidak seimbang.

Penelitian menunjukkan pengaruh yang signifikan terhadap distribusi kelas dalam dataset. Ini dicapai melalui penerapan teknik over-sampling minoritas sintetis, atau SMOTE. Sebelum penerapan SMOTE, distribusi ulasan negatif, netral, dan positif masing-masing adalah 815, 85, dan 100. Setelah SMOTE diterapkan, jumlah sampel pada ketiga kelas menjadi seimbang, dengan 652 sampel untuk setiap kelas. Meskipun SMOTE berhasil meningkatkan keseimbangan distribusi kelas, dampaknya terhadap performa klasifikasi pada kelas netral dan positif tetap tidak maksimal, terutama pada Grid Search, di mana model tetap gagal mengklasifikasikan sampel dari kelas-kelas tersebut.

Performa rendah pada kelas netral dan positif, meskipun setelah penerapan SMOTE, dapat disebabkan oleh beberapa faktor. Salah satunya adalah karakteristik data ulasan itu sendiri, di mana ulasan netral dan positif mungkin memiliki kesamaan yang tinggi dengan ulasan negatif, sehingga model kesulitan membedakan antar kelas. Selain itu, meskipun SMOTE dapat

meningkatkan keseimbangan kelas, metode ini hanya menambah sampel sintesis tanpa memperbaiki kualitas representasi fitur dari kelas minoritas. Hal ini menyoroti perlunya eksplorasi lebih lanjut terhadap metode penanganan ketidakseimbangan data yang lebih canggih, seperti ensemble learning atau cost-sensitive learning.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa Randomized Search lebih unggul dalam hal efisiensi waktu dan sedikit lebih baik dalam meningkatkan akurasi dibandingkan dengan Grid Search. Namun, baik Grid Search [18] maupun Randomized Search menghadapi tantangan yang sama dalam menangani ketidakseimbangan kelas, terutama pada kelas netral dan positif. Meskipun SMOTE mampu meningkatkan distribusi kelas yang lebih seimbang, teknik ini tidak sepenuhnya menyelesaikan masalah rendahnya performa pada kelas minoritas. Oleh karena itu, diperlukan pendekatan yang lebih holistik dalam menangani ketidakseimbangan data selain hanya menggunakan metode oversampling.

4. KESIMPULAN DAN SARAN

Penelitian ini membandingkan dua teknik optimasi parameter hiper, yaitu Grid Search dan Randomized Search, dalam meningkatkan akurasi model Support Vector Machine (SVM) untuk analisis sentimen pengguna dalam aplikasi JKN Mobile. Hasil menunjukkan bahwa Randomized Search berhasil mencapai akurasi tertinggi sebesar 82%, sedikit lebih baik dibandingkan dengan Grid Search yang menghasilkan akurasi 81,50%. Selain itu, Randomized Search juga terbukti lebih efisien dari segi waktu eksekusi, dengan durasi optimasi yang jauh lebih singkat dibandingkan Grid Search. Kedua metode optimasi menunjukkan performa yang kuat pada kelas sentimen negatif, namun mengalami kesulitan dalam mengklasifikasikan sentimen netral dan positif, terutama karena ketidakseimbangan kelas dalam dataset.

Membantu meningkatkan keseimbangan distribusi kelas dalam dataset dengan menggunakan teknik SMOTE (Teknik Pengambilan Sampel Minoritas Sintesis), tetapi tidak sepenuhnya menyelesaikan masalah rendahnya performa klasifikasi pada kelas minoritas, seperti netral dan positif. Meskipun distribusi kelas lebih seimbang setelah menggunakan SMOTE, model tetap mengalami kesulitan dalam membedakan antara ulasan netral, positif, dan negatif, yang mungkin disebabkan oleh tumpang tindih fitur antar kelas. Secara keseluruhan, meskipun optimasi parameter dengan Randomized Search menawarkan peningkatan akurasi dan efisiensi waktu, tantangan utama dalam menangani ketidakseimbangan data tetap ada, dan teknik optimasi serta penanganan data yang lebih canggih mungkin diperlukan untuk hasil yang lebih baik.

UCAPAN TERIMA KASIH

Direktorat Riset, Teknologi, dan Pengabdian kepada Masyarakat (DRTPM) memberikan dana melalui Program Pendanaan Penelitian Tahun 2024 untuk mendukung penelitian ini. Kami sangat berterima kasih kepada DRTPM atas bantuan keuangan yang telah memungkinkan penelitian ini dilakukan. Kami juga mengucapkan terima kasih kepada semua orang yang telah membantu penelitian berjalan lancar.

DAFTAR PUSTAKA

- [1] P. Handayani and A. Charis Fauzan, "KLIK: Kajian Ilmiah Informatika dan Komputer Machine Learning Klasifikasi Status Gizi Balita Menggunakan Algoritma Random Forest," *Media Online*, vol. 4, no. 6, pp. 3064–3072, 2024, doi: 10.30865/klik.v4i6.1909.
- [2] D. A. Anggoro and S. S. Mukti, "Performance Comparison of Grid Search and Random Search Methods for Hyperparameter Tuning in Extreme Gradient Boosting Algorithm to Predict Chronic Kidney Failure," *International Journal of Intelligent Engineering and Systems*, vol. 14, no. 6, pp. 198–207, Dec. 2021, doi: 10.22266/ijies2021.1231.19.
- [3] R. Habibi, "Svm Performance Optimization Using PSO for Breast Cancer Classification," *Budapest International Research in Exact Sciences (BirEx) Journal*, vol. 3, no. 1, pp. 741–754, Dec. 2020, doi: 10.33258/birex.v3i1.1499.

- [4] S. Rabbani, D. Safitri, N. Rahmadhani, A. A. F. Sani, and M. K. Anam, "Perbandingan Evaluasi Kernel SVM untuk Klasifikasi Sentimen dalam Analisis Kenaikan Harga BBM," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 3, no. 2, pp. 153–160, Oct. 2023, doi: 10.57152/malcom.v3i2.897.
- [5] T. Sugihartono, R. Rian, and C. Putra, "Penerapan Metode Support Vector Machine dalam Classifikasi Ulasan Pengguna Aplikasi Mobile JKN," vol. 7, no. 2, pp. 144–153, 2024.
- [6] M. Nurmalasari, N. Anggita Temesvari, S. Ni, and matul Maula, "Analisis Sentimen terhadap Opini Masyarakat dalam Penggunaan Mobile-JKN untuk Pelayanan BPJS Kesehatan Tahun 2019," 2020.
- [7] N. B. B. Tjikdaphia and S. Sulastri, "Comparison Of Nbc, SVM, KNN Classification Results In Sentiment Analysis of Mobile JKN," *JURTEKSI (Jurnal Teknologi dan Sistem Informasi)*, vol. 9, no. 4, pp. 665–672, Sep. 2023, doi: 10.33330/jurtekxi.v9i4.2539.
- [8] P. Arsi and R. Waluyo, "Analisis Sentimen Wacana Pindahan Ibu Kota Indonesia Menggunakan Algoritma Support Vector Machine (SVM)," vol. 8, no. 1, pp. 147–156, 2021, doi: 10.25126/jtiik.202183944.
- [9] P. Arsi, R. Wahyudi, and R. Waluyo, "Optimasi SVM Berbasis PSO pada Analisis Sentimen Wacana Pindah Ibu Kota Indonesia," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 2, pp. 231–237, Apr. 2021, doi: 10.29207/resti.v5i2.2698.
- [10] R. Darmawan and A. Surahmat, "Optimalisasi Support Vector Machine (SVM) Berbasis Particle Swarm Optimization (PSO) Pada Analisis Sentimen Terhadap Official Account Ruang Guru Di Twitter," 2022. [Online]. Available: <http://ejournal.ubharajaya.ac.id/index.php/JKI>
- [11] V. Kevin, S. Que: Analisis, S. Transportasi, A. Iriani, and H. D. Purnomo, "Analisis Sentimen Transportasi Online Menggunakan Support Vector Machine Berbasis Particle Swarm Optimization (Online Transportation Sentiment Analysis Using Support Vector Machine Based on Particle Swarm Optimization)," 2020. [Online]. Available: www.tripadvisor.com,
- [12] D. Wirasmita, dan Efi Anisa Sekolah Tinggi Teknologi Duta Bangsa, and J. Kalibaru Timur, "Jurnal Asimetrik: Jurnal Ilmiah Rekayasa Dan Inovasi Analisis Sentiment Twitter Berbasis Grid Search Algorithm (GSA) dengan Metode Support Vector Machine (SVM) Twitter Sentiment Analysis Based on Grid Search Algorithm (GSA) with Support Vector Machine (SVM) Method," vol. 5, pp. 35–42, 2023.
- [13] V. W. D. Thomas and F. Rumaisa, "Analisis Sentimen Ulasan Hotel Bahasa Indonesia Menggunakan Support Vector Machine dan TF-IDF," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 6, no. 3, p. 1767, Jul. 2022, doi: 10.30865/mib.v6i3.4218.
- [14] Fatihah Rahmadayana and Yuliant Sibaroni, "Sentiment Analysis of Work from Home Activity using SVM with Randomized Search Optimization," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 5, pp. 936–942, Oct. 2021, doi: 10.29207/resti.v5i5.3457.
- [15] Z. Budiarmo, H. Listiyono, and A. Karim, "Optimizing LSTM with Grid Search and Regularization Techniques to Enhance Accuracy in Human Activity Recognition," *Journal of Applied Data Sciences*, vol. 5, no. 4, pp. 2002–2014, 2024, doi: 10.47738/jads.v5i4.433.
- [16] T. Sugihartono, R. Rian, and C. Putra, "Penerapan Metode Support Vector Machine dalam Classifikasi Ulasan Pengguna Aplikasi Mobile JKN," vol. 7, no. 2, pp. 144–153, 2024.
- [17] E. A. U. Malahina, G. R. Iriane, Y. S. Belutowe, P. Katemba, and J. Asmara, "A Grid-search Method Approach for Hyperparameter Evaluation and Optimization on Teachable Machine Accuracy: A Case Study of Sample Size Variation," *Journal of Applied Data Sciences*, vol. 5, no. 3, pp. 1008–1025, Sep. 2024, doi: 10.47738/jads.v5i3.290.
- [18] M. A. P. Putra, K. R. P. Utama, N. W. Utami, and I. G. J. E. Putra, "Enhancing Federated Learning Performance through Adaptive Client Optimization with Hyperparameter Tuning," *Journal of Applied Data Sciences*, vol. 5, no. 2, pp. 747–755, May 2024, doi: 10.47738/jads.v5i2.251.
- [19] A. A. Abu-Shareha, H. Qutaishat, and A. Al-Khayat, "A Framework for Diabetes Detection Using Machine Learning and Data Preprocessing," *Journal of Applied Data Sciences*, vol. 5, no. 4, pp. 1654–1667, 2024, doi: 10.47738/jads.v5i4.363.