Evaluasi Kinerja Support Vector Machine Pada Klasifikasi Sentimen Ulasan *Skincare Whitelab* di Media Sosial

1st Shatsi Soluna
Teknik Informatika
Universitas Telkom Purwokerto
Purwokerto, Indonesia
shatsisoluna@student.telkomuniversity.ac.id

2nd Amalia Beladinna Arifa
Teknik Informatika
Universitas Telkom Purwokerto
Purwokerto, Indonesia
amaliabela@telkomuniversity.ac.id

3rd Atika Ratna Dewi
Teknik Informatika
Universitas Telkom Purwokerto
Purwokerto, Indonesia
atikad@telkomuniversity.ac.id

***Abstrak* — Meningkatnya penggunaan media sosial mendorong konsumen untuk mengekspresikan pengalaman mereka dalam menggunakan produk skincare melalui berbagai ulasan secara daring. Ulasan tersebut mengandung informasi yang dapat digunakan untuk menganalisis tingkat kepuasan serta persepsi konsumen terhadap suatu produk, meskipun besarnya volume data menjadi tantangan tersendiri dalam proses pengolahan dan analisis. Penelitian ini dilakukan untuk mengevaluasi kinerja algoritma *Support Vector Machine* (SVM) dalam melakukan klasifikasi sentimen positif dan negatif pada ulasan produk *skincare Whitelab*, sekaligus mengkaji peran *Synthetic Minority Over-sampling Technique* (SMOTE) dalam menangani permasalahan ketidakseimbangan data. Sebanyak 2.981 data ulasan yang diperoleh dari platform TikTok dan YouTube digunakan dalam penelitian ini, yang selanjutnya melalui tahap prapemrosesan teks serta ekstraksi fitur menggunakan metode TF-IDF. Pengujian model dilakukan dengan dua skema pembagian data, yaitu 70:20:10 dan 80:20. Hasil evaluasi menunjukkan bahwa penerapan SMOTE mampu meningkatkan kinerja model secara signifikan dibandingkan dengan model tanpa penyeimbangan data, dengan capaian akurasi tertinggi sebesar 89,21%. Temuan ini mengindikasikan bahwa kombinasi metode SVM dan SMOTE efektif dalam menghasilkan klasifikasi sentimen ulasan skincare Whitelab yang lebih akurat dan seimbang.**

Kata kunci*— analisis sentimen, Support Vector Machine, smote, ulasan *skincare*, *Whitelab

I. PENDAHULUAN

Industri *skincare* di Indonesia dewasa ini mengalami pertumbuhan pesat sejalan dengan meningkatnya kesadaran masyarakat akan pentingnya menjaga kesehatan kulit. Pertumbuhan pesat ini terlihat dari dominasi merek lokal yang kini bersaing ketat dalam kualitas dan popularitas digital, salah satunya *Whitelab* [1]. Ulasan konsumen menjadi salah satu pendukung dominasi merek lokal dalam persaingan industri *skincare*, dimana ulasan konsumen di berbagai platform daring menjadi sumber informasi strategis untuk memahami persepsi dan kepuasan pasar [2]. Meskipun demikian, volume data yang masif dari ulasan konsumen menjadikan analisis manual tidak lagi relevan dari segi waktu dan biaya, sehingga diperlukan metode klasifikasi sentimen otomatis yang cepat [3].

Algoritma Support Vector Machine (SVM) telah banyak digunakan sebagai metode yang efektif dalam tugas klasifikasi teks, sebagaimana ditunjukkan pada penelitian yang membahas ulasan pada aplikasi kesehatan [4]. Namun demikian, penerapan metode ini masih menghadapi sejumlah kendala, salah satunya adalah kinerja SVM yang sangat bergantung pada pemilihan dan pengaturan parameter, sehingga diperlukan evaluasi yang menyeluruh untuk memperoleh tingkat akurasi yang optimal [5]. Selain itu, permasalahan ketidakseimbangan data kerap muncul dalam analisis sentimen, di mana dominasi kelas mayoritas berpotensi menimbulkan bias dalam hasil prediksi [6]. Sebagai upaya untuk mengatasi permasalahan tersebut, pendekatan *Synthetic Minority Over-sampling Technique* (SMOTE) diterapkan dengan cara menyeimbangkan distribusi data melalui pembangkitan sampel sintetis pada kelas minoritas, sehingga kinerja model dapat ditingkatkan [7].

Namun demikian, efektivitas penerapan kombinasi metode SVM dan SMOTE dalam melakukan klasifikasi sentimen pada produk Whitelab masih belum banyak dikaji. Oleh karena itu, penelitian ini bertujuan untuk menganalisis kinerja algoritma SVM dalam mengklasifikasikan sentimen ulasan produk Whitelab serta menilai kontribusi metode SMOTE dalam mengatasi permasalahan ketidakseimbangan data. Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem analisis sentimen serta membantu perusahaan dalam memahami kebutuhan dan persepsi konsumen secara lebih akurat.

II. KAJIAN TEORI

A. Kajian Teori

Penelitian terdahulu yang mengkaji mengenai data ulasan atau komentar pengguna platform digital menunjukkan bahwa algoritma SVM mampu mengklasifikasikan sentiment dengan performa yang baik pada data teks [8,][9]. Implementasi SVM untuk analisis sentimen berbasis aspek pada review produk elektronik menunjukkan akurasi hingga 89.6% dalam

mengklasifikasikan sentimen berdasarkan aspek-aspek spesifik produk [10],[11]. Penelitian lain mengenai penggunaan SVM untuk analisis sentimen masyarakat terhadap antibiotik di Indonesia menunjukkan nilai akurasi 91.3%, membuktikan kemampuan SVM dalam menangani data dengan istilah teknis atau terminologi khusus serta dan topik spesifik yang paralel dengan karakteristik ulasan produk *skincare* [12]. Penelitian lain yang berfokus pada optimalisasi algoritma SVM dalam klasifikasi data kejadian stunting menunjukkan bahwa penggunaan kernel RBF dengan parameter C sebesar 10 dan gamma 0,1 mampu menghasilkan tingkat akurasi hingga 93,8%, sehingga menegaskan pentingnya proses penyesuaian hyperparameter dalam meningkatkan kinerja model [13]. Selain itu, studi mengenai klasifikasi status pembayaran kredit pada produk elektronik dan furnitur dengan menggunakan metode SVM melaporkan akurasi sebesar 88,9%, yang mencerminkan kemampuan SVM dalam mengolah data transaksional dan potensinya untuk diterapkan dalam pengembangan sistem rekomendasi berbasis analisis sentimen [14],[15].

Integrasi SVM dalam sistem pendukung keputusan mencapai akurasi 90.6%, membuktikan potensi penerapan dalam sistem otomatis untuk evaluasi produk berbasis review konsumen [16]. Penggunaan teknik preprocessing TF-IDF dengan SVM menghasilkan performa yang baik dalam klasifikasi sentiment data teks tidak terstuktur [17]. Optimasi *hyperparameter* menggunakan *Grid Search* pada SVM mencapai akurasi 92.1% dalam analisis sentimen review hotel, menunjukkan efektivitas pendekatan ini dalam domain hospitality yang dapat diadaptasi untuk analisis sentimen produk *skincare* [18], [19].

B. Analisis Sentimen

Analisis sentimen adalah pendekatan komputasional yang digunakan untuk mendeteksi, mengekstraksi, dan mengevaluasi opini, sikap, serta emosi yang terkandung dalam suatu teks, dengan tujuan menentukan polaritas sentimen guna memahami persepsi konsumen terhadap produk atau layanan yang disediakan [20] [21]. Metode ini menggunakan algoritma pembelajaran mesin untuk membangun model prediksi berdasarkan data latih yang telah diberi label sentiment [22]. Implementasi analisis sentimen pada ulasan produk memungkinkan perusahaan untuk mendapatkan insight yang berharga tentang kepuasan dan preferensi konsumen [23].

C. Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan algoritma pembelajaran terawasi yang diterapkan untuk tugas klasifikasi maupun regresi dengan cara menentukan *hyperplane* paling optimal yang mampu memisahkan data ke dalam beberapa kelas dengan margin terbesar [24]. Prinsip utama dari metode ini terletak pada identifikasi support vector, yaitu sejumlah data yang posisinya paling dekat dengan *hyperplane* pemisah dan berperan penting dalam pembentukan batas keputusan. Formulasi matematis SVM untuk klasifikasi dapat dinyatakan sebagai:

1. Fungsi keputusan SVM

$$f(x) = sign(\Sigma_i \alpha_i y_i K(x_i, x) + b) \quad (1)$$

Dalam kerangka optimasi, parameter regulasi C berfungsi untuk mengendalikan keseimbangan antara lebar margin dan tingkat kesalahan klasifikasi yang diizinkan [25].

2. Fungsi objektif optimasi

$$min\ ½||w||^2 + C\ \Sigma_i\ \xi_i \quad (2)$$

Dalam formulasi optimasi SVM, setiap titik data dibatasi untuk berada pada sisi hyperplane yang sesuai dengan margin minimum yang telah ditentukan. Pada konteks ini, parameter C berperan sebagai faktor regularisasi yang mengatur keseimbangan antara upaya memaksimalkan margin dan toleransi terhadap kesalahan klasifikasi [25]. Selain itu, pemilihan fungsi kernel yang sesuai memiliki pengaruh signifikan terhadap kemampuan SVM dalam menangani data yang tidak dapat dipisahkan secara linear.

SVM menyediakan beberapa jenis kernel yang umum digunakan untuk memetakan data masukan ke dalam ruang fitur berdimensi lebih tinggi [26], antara lain:

1. Linear Kernel

Kernel linear pada SVM berfungsi untuk merepresentasikan data dalam ruang fitur yang lebih tinggi tanpa melakukan transformasi nonlinier yang kompleks [26]. Fungsi jenis kernel ini adalah:

$$K(xi, xj) = xi \cdot xj_i \quad (3)$$

2. RBF (Radial Basis Function) Kernel

Kernel Radial Basis Function (RBF) digunakan pada kondisi ketika data tidak dapat dipisahkan secara linear. Dalam penerapannya, analisis menggunakan kernel RBF melibatkan proses optimasi terhadap parameter cost dan gamma untuk memperoleh kinerja model yang optimal [26]. Fungsi jenis kernel ini adalah:

$$K(xi, xj) = exp(-\gamma||xi - xj||^2)_i \quad (4)$$

3. Polynomial Kernel

Fungsi ini mengubah data asli menjadi ruang fitur baru yang lebih tinggi dimensinya [27]. Dalam fungsi ini, nilai D adalah derajat polynomial, γ parameter skala, R konstanta, dan (X .X') adalah produk titik dari vector data X dan X' [27].

$$K(xi, xj) = (\gamma xi \cdot xj + r)\hat{}d \quad (5)$$

D. Text Preprocesing

Text Preprocesing atau prapemrosesan teks merupakan tahapan awal yang bertujuan untuk mempersiapkan data teks agar dapat diolah oleh *algoritma machine learning*, yang meliputi proses pembersihan data, *case folding*, tokenisasi, penghapusan *stopword*, normalisasi, serta *stemming* [28]. Selanjutnya, metode *Term Frequency–Inverse Document Frequency* (TF-IDF) diterapkan untuk mentransformasikan teks ke dalam bentuk representasi numerik.

$$K\text{TF} - \text{IDF}(\text{t}, \text{d}) = \text{TF}(\text{t}, \text{d}) \times \text{IDF}(\text{t}) \quad (6)$$

Di mana

$$\text{TF}(\text{t}, \text{d}) = \frac{(\text{jumlah kemunculan term t dalam dokumen d})}{(\text{total term dalam dokumen d})} \quad (7)$$

$$\text{IDF}(\text{t}) = \log(\text{N} / \text{df}(\text{t}))$$

dengan N adalah total dokumen dan df(t) adalah jumlah dokumen yang mengandung term t [28].

E. Evaluasi Kinerja Klasifikasi

Penilaian kinerja model klasifikasi dilakukan dengan menggunakan sejumlah metrik yang diperoleh dari confusion matrix. Confusion matrix merupakan tabel evaluasi yang menyajikan perbandingan antara hasil prediksi model dan label sebenarnya, sehingga dapat menunjukkan tingkat ketepatan dan kesalahan prediksi pada masing-masing kelas [29].

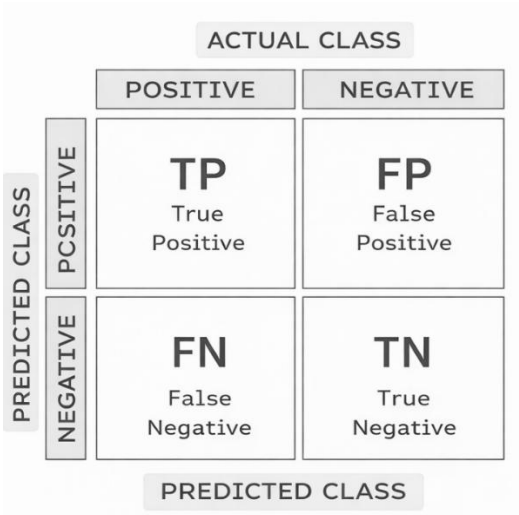

GAMBAR 1
(*Confusion Matrix*)

Untuk klasifikasi biner, confusion matrix terdiri dari:

1. True Positive (TP) : prediksi positif yang benar
2. True Negative (TN) : prediksi negatif yang benar
3. False Positive (FP) : prediksi positif yang salah
4. False Negative (FN) : prediksi negatif yang salah

Metrik evaluasi yang dihitung meliputi:

Persentase prediksi yang benar dari keseluruhan data [29]. Akurasi dihitung dengan menggunakan rumus pada persamaan (8).

$$Accuracy = \frac{TP+TN}{TP+TN+FN+FP} \quad (8)$$

Mengukur seberapa banyak prediksi positif yang benar[29]. *Precision* dihitung dengan menggunakan rumus pada persamaan (9).

$$Precision = \frac{TP}{TP+FP} \quad (9)$$

Mengukur kemampuan model dalam menemukan seluruh data positif [29]. *Recall* dihitung dengan menggunakan rumus pada persamaan (10).

$$Recall = \frac{TP}{TP+FN} \quad (10)$$

Rata-rata dari *precision* dan *recall* [29]. *F1 - score* dihitung dengan menggunakan rumus pada persamaan (11).

$$F1 - Score = \frac{2\times(Precision)\times Recall}{(Precision+Recall)} \quad (11)$$

F. Ulasan Produk *Skincare*

Ulasan produk *skincare* memiliki karakteristik linguistik yang khas pada konsumen Indonesia, termasuk penggunaan istilah teknis dan kata asing/inggris dalam review serta gaya Bahasa yang beragam [30]. Pola sentimen dalam ulasan *skincare* cenderung dipengaruhi oleh aspek-aspek spesifik produk seperti kemasan, tekstur, hasil pemakaian, dan nilai harga. Konsumen seringkali memberikan penilaian yang berbeda untuk setiap aspek, sehingga analisis sentimen pada domain ini memerlukan pemahaman yang mendalam tentang konteks dan terminologi yang digunakan [31].

G. Lexicon Based Sentiment Analysis

Pendekatan *lexicon-based* merupakan metode klasifikasi sentimen yang memanfaatkan kamus kata atau leksikon yang telah dilabeli polaritas sentimen untuk menentukan arah atau kecenderungan sentimen dalam suatu teks [32]. Metode ini bekerja dengan cara mengidentifikasi kata-kata dalam teks yang memiliki konotasi positif, dan negatif berdasarkan kamus yang telah didefinisikan sebelumnya, dengan keunggulan berupa interpretabilitas proses klasifikasi dapat dijelaskan secara eksplisit melalui kata-kata yang berkontribusi terhadap sentimen tertentu [33]. *Lexicon-based approach* terbagi menjadi dua kategori utama yaitu *dictionary-based* yang menggunakan kamus yang telah ada seperti *WordNet* untuk membangun *lexicon sentimen*, dan *corpus-based* yang membangun lexicon dari koleksi dokumen tertentu dengan menggunakan teknik seperti *co-occurrence analysis* [34].

Proses pelabelan sentimen menggunakan *lexicon-based* dilakukan melalui beberapa tahapan sistematis yang meliputi pembersihan teks *input*, *tokenization*, pencocokan token dengan *lexicon*, dan agregasi skor polaritas hingga menghasilkan label akhir. *Lexicon-based approach* dapat dikombinasikan dengan machine learning untuk meningkatkan akurasi, misalnya dengan memanfaatkan hasil *lexicon* sebagai label awal atau fitur tambahan *pada model supervised learning* [35].

H. *Synthetic Minority Over-sampling Technique* (SMOTE)

Synthetic Minority Over-sampling Technique (SMOTE) adalah metode penyeimbangan data yang diterapkan untuk menangani permasalahan ketidakseimbangan kelas, yaitu kondisi ketika jumlah data pada kelas minoritas jauh lebih rendah dibandingkan dengan kelas mayoritas. Metode ini bekerja dengan membangkitkan sampel sintetis baru pada kelas minoritas, bukan melalui penggandaan data secara langsung [36] [37]. Proses ini dilakukan dengan memilih satu *instance* pada kelas minoritas, kemudian mencari *k-nearest neighbors* dari *instance* tersebut yang masih berada dalam kelas minoritas[38]. Selanjutnya, data sintetis dibentuk melalui proses interpolasi antara instance awal dengan tetangga terdekatnya, sehingga menghasilkan variasi data

baru dalam ruang fitur dan mengurangi risiko *overfitting* [38]. Penerapan SMOTE terbukti mampu meningkatkan nilai akurasi, *precision, recall*, dan *F1-score* dibandingkan model tanpa penyeimbangan data [39].

III. METODE

Pengambilan data dilakukan melalui metode eksperimental kualitatif, dimana data diperoleh melalui pengujian dianalisis secara deskriptif untuk menjelaskan efisiensi penggunaan kombinasi metode SVM dan SMOTE dalam klasifikasi sentiment ulasan produk *skincare Whitelab*, dengan subjek para pengguna produk *Whitelab* yang memberikan ulasan dan komentar mengenai pengalaman mereka menggunakan produk tersebut di platform TikTok, dan YouTube.

Perangkat yang digunakan dalam penelitian ini meliputi perangkat keras berupa laptop HP Pavilion Aero yang dilengkapi dengan prosesor AMD Ryzen 5, RAM 16 GB, serta media penyimpanan SSD berkapasitas 512 GB, dan didukung oleh koneksi internet yang stabil untuk menunjang akses ke layanan cloud computing. dan perangkat lunak (*software*) meliputi sistem operasi *Windows 11*, *Google Colab*, *Postman*, dan *Browser*.

Bahan yang digunakan dalam penelitian ini berupa dataset sejumlah 2.981 ulasan pengguna media sosial TikTok dan YouTube berkaitan dengan produk *skincare Whitelab* yang diperoleh melalui web scraping keyword #review*skincareWhitelab* dalam rentang waktu tahun 2022 hingga 2025. Data yang digunakan dalam penelitian ini merupakan data sekunder yang bersifat publik dan diperoleh dari kedua platform media sosial tersebut, sehingga dapat diakses secara terbuka.

Tahapan dalam penelitian ini dirangkum dalam Gambar 2 berikut:

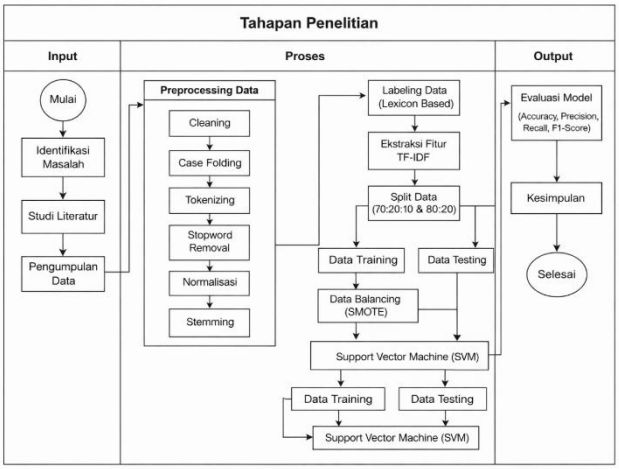

GAMBAR 2
DIAGRAM ALIR RISET

A. Identifikasi Masalah

Identifikasi masalah membahas fokus dan ruang lingkup penelitian. Permasalahan utama dalam riset ini berupa tingginya jumlah ulasan konsumen produk *skincare Whitelab* di media sosial yang sulit dianalisis secara manual. Selain itu, ulasan yang tersedia memiliki distribusi sentiment yang tidak seimbang antara kelas positif dan negatif, sehingga berpotensi mempengaruhi kinerja model klasifikasi. Berdasarkan permasalahan tersebut, diperlukan metode klasifikasi sentiment yang mampu bekerja secara efektif pada data teks berbahasa indonesia serta dapat menangani kondisi ketidakseimbangan data.

B. Studi Literatur

Kajian pustaka dilakukan untuk mengumpulkan dasar teori dan metodologi yang sesuai serta mendukung pelaksanaan penelitian ini.

C. Pengumpulan Data

Pengumpulan data dilakukan untuk memperoleh ulasan-ulasan konsumen mengenai produk *skincare Whitelab* dari platform TikTok, dan YouTube. Data dikumpulkan melalui proses scraping dengan mengambil komentar atau ulasan yang relevan pada konten yang membahas produk *Whitelab* yang kemudian disimpan dalam format *Comma Separated Values File* (CSV) untuk memudahkan proses analisis selanjutnya.

Kategori Sentimen	Jumlah Data
Positif	888
Negatif	2.093
Total	**2.981**

TABEL 1
(Pengelompokan Data Berdasarkan Sentimen)

D. Preprocessing Data

Tahap preprocessing data berupa *Cleaning, Case Folding, Normalization, Tokenizing, Stopword Removal,* dan *Stemming*.

E. Labelling

Setiap ulasan dikelompokkan ke dalam dua kategori sentimen, yaitu positif dan negatif, dengan memanfaatkan leksikon sentimen bahasa Indonesia yang telah dikembangkan khusus untuk domain produk kecantikan. Ulasan kemudian diproses melalui tahap preprocesing dan tokenisasi, kemudian kata-kata yang terdapat dalam ulasan dicocokkan dengan lexicon untuk memperoleh skor sentiment. Skor total dihitung melalui agregasi skor seluruh kata, selanjutnya digunakan untuk menentukan label sentiment positif atau negatif.

F. Pembagian Data

Dataset ulasan *skincare Whitelab* dibagi menggunakan teknik *stratified random sampling* ke dalam dua skenario. Skenario pertama menggunakan rasio 70% *data training*, 20% *data testing*, dan 10% *data validation*, sedangkan skenario kedua berupa rasio 80% *data training* dan 20% *data testing* tanpa data validation. Pada kedua skenario tersebut diterapkan dua perlakuan, yaitu tanpa SMOTE dan dengan SMOTE sebagai upaya penanganan ketidakseimbangan kelas melalui penambahan data sintetis kelas minoritas.

G. Pemodelan SVM

Tahap pemodelan dilakukan menggunakan algoritma SVM dalam mengklasifikasikan sentimen ulasan produk *skincare Whitelab*. Sebelum proses pelatihan model dilakukan, data teks hasil prapemrosesan terlebih dahulu ditransformasikan ke dalam bentuk representasi numerik dengan menggunakan metode *Term Frequency–Inverse*

Document Frequency (TF-IDF) sehingga dapat dipahami oleh algoritma SVM. Proses pelatihan model dilakukan pada dataset yang telah dibagi menurut dua skenario pembagian data pada tahap sebelumnya, baik tanpa SMOTE maupun dengan SMOTE.

H. Evaluasi Model

Tahapan evaluasi model dilaksanakan untuk mengukur kinerja serta kemampuan algoritma SVM dalam mengklasifikasikan sentimen ulasan produk *skincare Whitelab*. Proses evaluasi menggunakan metrik pengukuran kinerja, yaitu accuracy, precision, recall, dan F1-score. Analisis confusion matrix akan digunakan untuk mengidentifikasi pola kesalahan klasifikasi dan memahami karakteristik performa model pada setiap kelas sentiment. evaluasi diharapkan dapat memberikan hasil yang objektif dan representative terhadap kemampuan generalisasi model pada data.

IV. HASIL DAN PEMBAHASAN

A. Kinerja SVM pada Data Imbalance (Tanpa SMOTE)

a. Split Data 70:20:10

TABEL 2
(Hasil Klasifikasi Tanpa Smote (70:20:10))

	***Precision* (%)**	***Recall* (%)**	***F1-score* (%)**	***Support***
Negatif	0.86	0.80	0.83	419
Positif	0.60	0.70	0.65	178
Accuracy			**0.77**	**597**

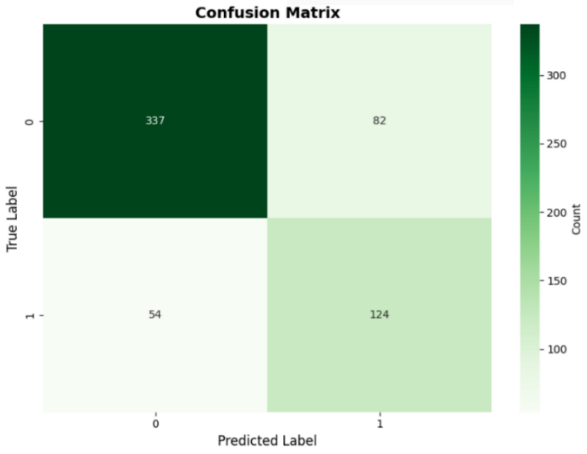

GAMBAR 3
(*Confusion* Matrix Tanpa Smote (70:20:10))

Berdasarkan hasil pengujian yang disajikan pada Tabel 2, model menghasilkan nilai akurasi sebesar 77%. Pada kelas negatif, nilai *precision, recall,* dan *F1-score* tergolong tinggi, masing-masing mencapai 86%, 80%, dan 83%, yang menunjukkan bahwa model memiliki kemampuan yang baik dalam mengidentifikasi kelas mayoritas. Sebaliknya, kinerja model pada kelas positif masih belum optimal, terutama ditunjukkan oleh nilai *F1-score* yang hanya mencapai 65%. Temuan ini mengindikasikan bahwa model mengalami kesulitan dalam mengklasifikasikan data pada kelas minoritas. Selain itu, *confusion matrix* pada Gambar 3 memperlihatkan adanya sejumlah data kelas positif yang masih salah diprediksi sebagai kelas negatif. Kondisi tersebut menegaskan bahwa pada situasi ketidakseimbangan data, model cenderung lebih terfokus pada pola kelas mayoritas sehingga kemampuan dalam mengenali kelas minoritas menjadi terbatas.

b. Split Data 80:20

TABEL 3
(Hasil Klasifikasi Tanpa Smote (80:20))

	***Precision* (%)**	***Recall* (%)**	***F1-score* (%)**	**Support**
Negatif	0.89	0.90	0.90	419
Positif	0.76	0.75	0.76	178
Accuracy			0.85	597

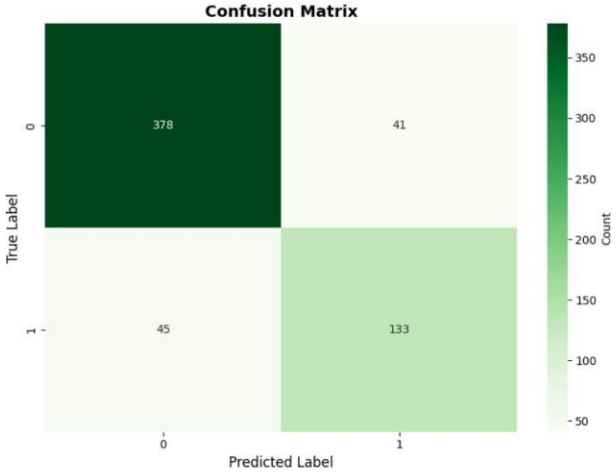

GAMBAR 4
(*Confusion* Matrix Tanpa Smote (80:20))

Pada skema pembagian data dengan proporsi 80% sebagai data latih dan 20% sebagai data uji, model SVM memperlihatkan kinerja yang lebih baik dibandingkan dengan skema pembagian data sebelumnya. Nilai akurasi yang diperoleh mencapai 86%, dengan peningkatan pada seluruh metrik evaluasi baik pada kelas negatif maupun kelas positif. *Recall* pada kelas positif meningkat menjadi 79%, yang menunjukkan bahwa model mulai lebih mampu mendeteksi data dari kelas minoritas. Meskipun demikian, perbedaan performa antara kelas mayoritas dan minoritas masih terlihat, sehingga dapat disimpulkan bahwa ketidakseimbangan data masih berpengaruh terhadap hasil klasifikasi.

B. Kinerja SVM pada Data Balanced Menggunakan SMOTE

a. Split Data 70:20:10

TABEL 4
(Hasil Klasifikasi Dengan Smote (70:20:10))

	***Precision* (%)**	***Recall* (%)**	**F1-*score* (%)**	**Support**
Negatif	0.94	0.92	0.93	457
Positif	0.75	0.81	0.78	139
Accuracy			**0.89**	**596**

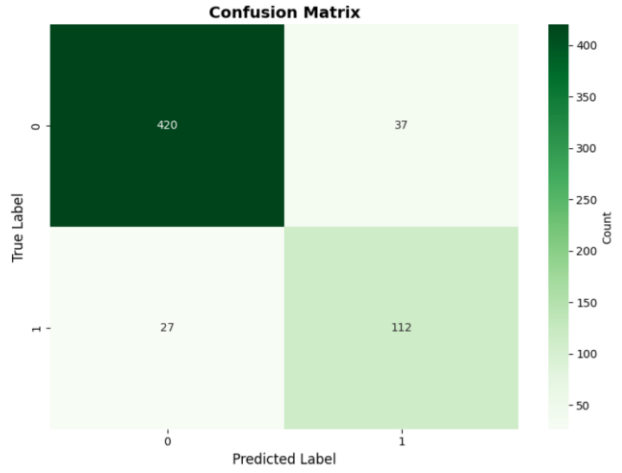

GAMBAR 5
(*Confusion* Matrix Dengan Smote (70:20:10))

Hasil pengujian menunjukkan peningkatan performa yang signifikan, dengan nilai akurasi mencapai 89%. Nilai *recall* pada kelas positif meningkat menjadi 81%, yang menandakan bahwa model semakin mampu mengenali data dari kelas minoritas. Peningkatan ini menunjukkan bahwa penyeimbangan data memberikan dampak positif terhadap kemampuan klasifikasi model. Berdasarkan *confusion matrix*, terlihat bahwa jumlah kesalahan klasifikasi pada kelas positif mengalami penurunan. Hal ini menunjukkan bahwa model menjadi lebih seimbang dalam melakukan prediksi dan tidak terlalu bias terhadap kelas mayoritas.

b. Split Data 80:20

TABEL 5
(Hasil Klasifikasi Dengan Smote (80:20))

	***Precision* (%)**	***Recall* (%)**	***F1-score* (%)**	**Support**
Negatif	0.89	0.90	0.90	419
Positif	0.76	0.75	0.76	178
Accuracy			0.85	597

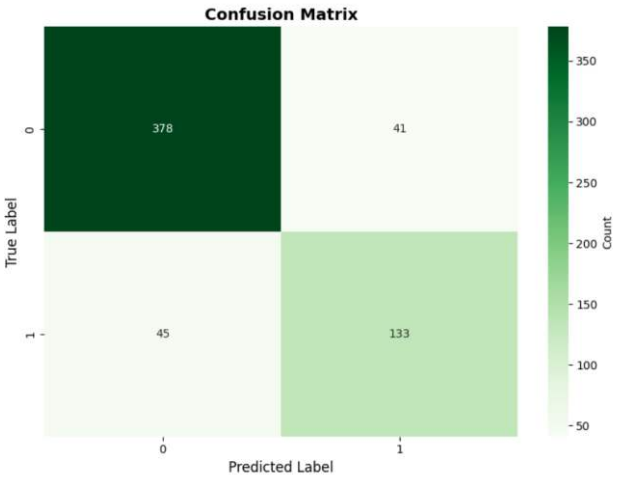

GAMBAR 6
(*Confusion Matrix* Dengan Smote (80:20))

Dengan menggunakan skema pembagian data 80% sebagai data latih dan 20% sebagai data uji serta penerapan metode SMOTE, model SVM berhasil mencapai tingkat akurasi sebesar 85,93%. Meskipun nilai akurasi sedikit lebih rendah dibandingkan pembagian 70:20:10, performa klasifikasi pada kedua kelas tetap relatif stabil. Nilai *F1-score* pada kelas positif sebesar 76% menunjukkan bahwa model masih mampu menjaga keseimbangan antara ketepatan prediksi dan kemampuan dalam mengenali data kelas minoritas. Hal ini menandakan bahwa penerapan SMOTE tetap memberikan kontribusi positif dalam mengatasi permasalahan data tidak seimbang.

C. Evaluasi Kinerja SVM

TABEL 6
(Ringkasan Nilai Akurasi Model Svm Pada Berbagai Skenario)

No	**Skenario**	**Pembagian Data**	***Accuracy* (%)**
1	SVM	70:20:10	77,21%
2	SVM	80:20	86,00%
3	SVM + SMOTE	70:20:10	89,21%
4	SVM + SMOTE	80:20	85,93%

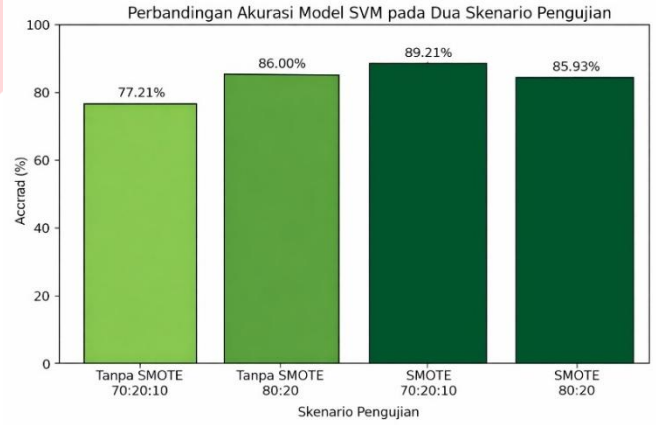

GAMBAR 7
(Perbandingan Akurasi Model SVM)

Struktur pembagian data 70:20:10 memberikan hasil yang lebih stabil dibandingkan pembagian data 80:20 karena adanya pemisahan data validasi yang berperan penting dalam proses evaluasi dan pemilihan model. Pada pembagian ini, model tidak hanya dilatih dan diuji, tetapi juga divalidasi menggunakan data yang tidak terlibat langsung dalam proses pelatihan maupun pengujian akhir. Hal ini membantu dalam memantau performa model secara objektif selama proses eksperimen.

Pada skema yang melibatkan penerapan SMOTE, konsistensi kinerja model menjadi aspek yang krusial karena data sintetis hanya ditambahkan pada tahap pelatihan. Keberadaan data validasi yang terpisah memungkinkan proses evaluasi dilakukan untuk memastikan bahwa peningkatan kinerja yang dihasilkan tidak semata-mata disebabkan oleh overfitting terhadap data latih yang telah diseimbangkan, tetapi juga mencerminkan kemampuan model dalam mempertahankan performa yang baik pada data baru yang belum pernah digunakan sebelumnya.

Sebaliknya, pada pembagian data 80:20, seluruh proses evaluasi hanya bergantung pada data uji. Kondisi ini membuat hasil pengujian lebih sensitif terhadap variasi data, sehingga performa model dapat terlihat tinggi atau rendah tergantung pada karakteristik data uji yang digunakan. Hal ini

menyebabkan hasil yang diperoleh cenderung kurang stabil, terutama pada kasus data tidak seimbang atau data yang telah mengalami proses oversampling seperti SMOTE.

Pembagian data dengan rasio 70:20:10 dipilih karena mampu memberikan keseimbangan yang optimal pada tahap pelatihan, validasi, dan pengujian model. Ketika pembagian data tersebut dikombinasikan dengan penerapan metode SMOTE, model SVM yang dihasilkan menunjukkan tingkat akurasi yang tinggi disertai kinerja klasifikasi yang lebih stabil dan proporsional antara kelas mayoritas dan minoritas. Berdasarkan hasil tersebut, konfigurasi ini dinilai sebagai konfigurasi paling efektif dalam penelitian ini.

Atas dasar hasil analisis yang telah dilakukan, konfigurasi ini dapat dinyatakan sebagai konfigurasi yang memberikan hasil terbaik dalam penelitian ini. Selain itu, distribusi data menunjukan kelas negatif lebih dominan dibandingkan positif, yaitu 2.093 data (70,21%) untuk negatif, dan 888 data (29,79%) untuk positif. Ketidakseimbangan ini berpotensi membuat model cenderung memprediksi kelas mayoritas apabila tanpa penyeimbangan. Dengan kondisi tersebut, SMOTE diperlukan agar model mempelajari kelas positif dengan lebih baik sehingga klasifikasi kedua kelas menjadi seimbang.

V. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilaksanakan, dapat disimpulkan bahwa algoritma *Support Vector Machine* (SVM) mampu digunakan dalam proses klasifikasi sentimen positif dan negatif pada ulasan konsumen terhadap produk *skincare Whitelab*. Kesimpulan tersebut didasarkan pada hasil evaluasi kinerja model yang diukur menggunakan metrik akurasi, *precision, recall*, dan *F1-score* pada berbagai skenario pengujian yang telah dilakukan.

Pada skenario tanpa SMOTE, model menghasilkan akurasi sebesar 77% pada pembagian data 70:20:10 dan 86% pada pembagian data 80:20, namun performa antar kelas belum sepenuhnya seimbang. Penerapan metode SMOTE terbukti mampu meningkatkan kinerja model, khususnya pada skema pembagian data 70:20:10 dengan capaian akurasi sebesar 89%, serta meningkatkan kemampuan model dalam mengidentifikasi data pada kelas minoritas.

Distribusi sentimen pada dataset didominasi oleh sentimen negatif 70,21% (2.093 ulasan) dan sentimen positif 29,79% (888 ulasan), yang menunjukkan bahwa ulasan konsumen pada dataset lebih banyak menyoroti aspek evaluatif dan catatan pengguna. Temuan ini dapat dijadikan pertimbangan bagi konsumen untuk mencermati isu atau topik yang sering dibahas dalam ulasan, dan menyesuikannya dengan kebutuhan serta kondisi masing-masing.

Penerapan SMOTE lebih berpengaruh meningkatkan keseimbangan klasifikasi dibandingkan perubahan rasio pembagian data, dan algoritma SVM mampu memberikan performa klasifikasi yang konsisten sesuai dengan tujuan penelitian yang telah ditetapkan.

REFERENSI

[1] M. A. S. S. Ariqoh Y. Muhyidin T. Informatika S. Tinggi T. Wastukancana and R. Artikel, “Sentiment analysis of cushion products on female daily website using Support Vector Machine (SVM) method,” 2023.

[2] S. F. and P. J. Ramdan, “Machine learning modeling: Public sentiment analysis toward PPKM policy using Twitter data,” 2022.

[3] A. R. and B. Sari, “Product review sentiment analysis using Support Vector Machine with feature selection techniques,” 2021.

[4] D. S. S. Rabbani N. Rahmadhani A. A. F. Sani and M. K. Anam, “Comparative evaluation of SVM kernels for sentiment classification in fuel price increase analysis,” 2023.

[5] R. C. Larasati, C. Dewi, and H. J. Christanto, “ANALISIS SENTIMEN PRODUK KECANTIKAN JENIS MOISTURIZER DI TWITTER MENGGUNAKAN ALGORITMA SUPER VECTOR MACHINE,” *Jurnal Teknik Informasi dan Komputer (Tekinkom)*, vol. 7, no. 1, p. 124, Jun. 2024.

[6] C. Candra, K. W. Chandra, and H. Irsyad, “Efektifitas SMOTE dalam Mengatasi Imbalanced Class Algoritma K-Nearest Neighbors pada Analisis Sentimen terhadap Starlink,” *Jurnal Ilmu Komputer dan Informatika*, vol. 4, no. 1, pp. 31–42, Jul. 2024.

[7] G. Gumelar and H. Al Fatta, “Kombinasi Algoritma Klasifikasi Dengan Algoritma Oversampling Untuk Menangani Ketidakseimbangan Kelas Pada Level Data,” vol. 10, no. 2, pp. 29–39, 2023.

[8] A. G. and F. Crestani, “Twitter sentiment analysis methods: A comprehensive survey,” 2016.

[9] B. Liu, “Sentiment analysis and opinion mining techniques,” 2012.

[10] D. I. Sumantiawan, J. E. Suseno, and W. A. Syafei, “Sentiment Analysis of Customer Reviews Using Support Vector Machine and Smote-Tomek Links For Identify Customer Satisfaction,” *J. Sistem Info. Bisnis*, vol. 13, no. 1, pp. 1–9, Jun. 2023.

[11] T. K. S. Maharani and A. Setiawan, “Implementation of aspect-based sentiment analysis using Support Vector Machine for electronic product reviews,” 2021.

[12] P. H. D. J. K. Sulaiman N. Wanaspati S. Anraeni and I. Abstrak, “Support Vector Machine for public sentiment analysis regarding antibiotics in Indonesia,” 2023.

[13] S. D. Wahyuni and R. H. Kusumodestoni, “Optimalisasi Algoritma Support Vector Machine (SVM) Dalam Klasifikasi Kejadian Data Stunting,” *Bulletin of Information Technology (BIT)*, vol. 5, no. 2, pp. 56–64, 2024.

[14] T. B. and S. R. Nuddin, “Performance analysis of ChatGPT in generating Indonesian text using Support Vector Machines (SVM) method,” 2024.

[15] I. P. Casuarina, M. N. Hayati, and D. S. Prangga, “Klasifikasi Status Pembayaran Kredit Barang Elektronik dan Furniture Menggunakan Support Vector Machine Classification of Credit Payment Status for Electronic and Furniture Using Support Vector Machine.”

[16] N. Putu Della Tirta Yanti, “Sistem Klasifikasi Pengajuan Kredit Dengan Metode Support Vector Machine (SVM) I Made Dwi Putra Asana,” 2023.

[17] N. Arifin, U. Enri, and N. Sulistiyowati, “STRING (Satuan Tulisan Riset dan Inovasi Teknologi) PENERAPAN ALGORITMA SUPPORT VECTOR MACHINE (SVM) DENGAN TF-IDF N-GRAM UNTUK TEXT CLASSIFICATION.”

[18] P. S. L. Handayani and K. Wibowo, "Implementation of Support Vector Machine for hotel review sentiment analysis with grid search hyperparameter optimization," 2021.
[19] K. L. Tan, C. P. Lee, and K. M. Lim, "A Survey of Sentiment Analysis: Approaches, Datasets, and Future Research," Apr. 01, 2023.
[20] S. Fachri and P. J. Ramdan, "Pemodelan Machine Learning : Analisis Sentimen Masyarakat Terhadap Kebijakan PPKM Menggunakan Data Twitter," 2022.
[21] B. M. D. Abighail, Fachrifansyah, M. R. Firmanda, M. S. Anggreainy, Harvianto, and Gintoro, "Sentiment Analysis E-commerce Review," in *Procedia Computer Science*, Elsevier B.V., 2023.
[22] R. S. H. A. Rahman and T. Widiharih, "Sentiment analysis on J&T logistics service provider company utilizing multinomial naive bayes and Support Vector Machine algorithms," 2023.
[23] 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.
[24] Y. C. A. Gerliandeva and H. Ashaury, "Optimization of sentiment classification on online comments using multinomial naïve bayes and TF-IDF feature extraction with N-grams," 2024.
[25] H. A. Noviriandini and Yudhistira, "Support *Vector* Machine classification based on particle swarm optimization for sentiment analysis of PeduliLindungi application users," 2022.
[26] W. T. and A. Wibowo, "ICT service user sentiment analysis using naive bayes classifier and SVM methods with TF-IDF text weighting," 2024.
[27] S. T. I. Dwita R. Habibi R. Nuraini and S. Fatonah, "Evaluation of machine learning classification algorithms for employee performance allowance final value categories," 2023.
[28] B. W. A. Susanto and C. Prasetyo, "Text cleaning, case folding, tokenizing, stopword removal, stemming, normalization methodologies for Indonesian sentiment analysis: A comparative analysis," 2020.
[29] N. Hidayah, "Implementation of multinomial naïve bayes algorithm, TF-IDF and confusion matrix in classifying student monitoring and evaluation suggestions for informatics engineering lecturers at Dayanu Ikhsanuddin University," 2024.
[30] C. H. Yutika, A. Adiwijaya, and S. Al Faraby, "Analisis Sentimen Berbasis Aspek pada Review Female Daily Menggunakan TF-IDF dan Naïve Bayes," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 5, no. 2, p. 422, Apr. 2021.
[31] M. Hannah Zahirah and T. Widarmanti, "Sentiment Analysis and Topic Modeling Study: The Comparison of Cosmetics Product Online Reviews," *International Journal of Sciences: Basic and Applied Research (IJSBAR) International Journal of Sciences: Basic and Applied Research*, vol. 64, no. 1, pp. 50–65, 2022.
[32] J. B. M. Taboada M. Tofiloski K. Voll and M. Stede, "Lexicon-based approaches for sentiment analysis," 2011.
[33] A. E. and F. Sebastiani, "SentiWordNet: A publicly accessible lexical resource for opinion mining," 2006.
[34] S. K. S. M. Mohammad and X. Zhu, "NRC-Canada: Constructing state-of-the-art sentiment analysis for tweets," 2013.
[35] Y. Qi and Z. Shabrina, "Sentiment analysis using Twitter data: a comparative application of lexicon- and machine-learning-based approach," *Soc. Netw. Anal. Min.*, vol. 13, no. 1, Dec. 2023.
[36] M. Carvalho, A. J. Pinho, and S. Brás, "Resampling approaches to handle class imbalance: a review from a data perspective," *J. Big Data*, vol. 12, p. 71, 2025.
[37] N. V Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-sampling Technique," *Journal of Artificial Intelligence Research*, vol. 16, pp. 321–357, 2002.
[38] Y. Yang, H. A. Khorshidi, and U. Aickelin, "A review on over-sampling techniques in classification of multi-class imbalanced datasets: insights for medical problems," 2024.
[39] M. K. Biddinika, H. Yuliansyah, D. Soyusiawaty, and F. R. Razak, "SMOTE-SVM for Handling Imbalanced Data in Obesity Classification," *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 2025