

Performance Analysis of SVM Kernels in Sentiment Classification on Indonesian Local Skincare Dataset

Analisis Performa Kernel SVM dalam Klasifikasi Sentimen pada Dataset Skincare Lokal Indonesia

Sindy Merdiriyani¹, Alam Rahmatulloh²

^{1,2}Informatika, Universitas Siliwangi, Indonesia

¹217006105@student.unsil.ac.id, ^{2*}alam@unsil.ac.id

Informasi Artikel

Received: July 2025

Revised: August 2025

Accepted: November 2025

Published: October 2025

Abstract

Purpose: Sentiment analysis is an important aspect of understanding consumers' views on products, especially in the growing skincare industry. This study aims to compare the accuracy and effectiveness of various kernels in the Support Vector Machine (SVM) algorithm, including linear, polynomial (poly), and radial basis function (RBF) kernels, in predicting three types of sentiment: positive, neutral, and negative based on reviews of local Indonesian skincare products.

Design/methodology/approach: The dataset used includes consumer reviews classified by rating, which are then processed using Term Frequency-Inverse Document Frequency (TF-IDF) technique for feature extraction.

Findings/result: The evaluation results show that the RBF kernel achieves the highest accuracy of 74.78%, followed by the linear kernel with 74.51% accuracy, and the polynomial kernel with 74.10% accuracy. Although the difference between the three kernels is not significant, the RBF kernel excels in positive sentiment classification, while all three kernels struggle in predicting neutral and negative classes.

Originality/value/state of the art: These findings make an important contribution to the development of effective sentiment analysis methods, especially in the context of datasets with high class imbalance. To handle class imbalance, techniques such as oversampling smaller classes or using cost-sensitive learning techniques to give more weight to negative and neutral classes can be used.

Abstrak

Keywords: Linear; Polynomial; RBF;
Skincare; SVM

Tujuan: Analisis sentimen merupakan salah satu aspek penting dalam memahami pandangan konsumen terhadap produk, terutama dalam industri skincare yang terus

Kata kunci: Kernel; Linier; Polinomial;
RBF; Skincare; SVM

berkembang. Studi ini bertujuan untuk membandingkan akurasi dan efektivitas berbagai kernel pada algoritma *Support Vector Machine* (SVM), termasuk kernel Linear, Polinomial, dan Radial Basis Function (RBF) dalam memprediksi tiga jenis sentimen yaitu positif, netral, dan negatif berdasarkan ulasan produk *skincare* lokal Indonesia. Perancangan/metode/pendekatan:Pendekatan: Dataset yang digunakan mencakup ulasan konsumen yang diklasifikasikan berdasarkan rating, yang kemudian diolah menggunakan teknik *Term Frequency-Inverse Document Frequency* (TF-IDF) untuk ekstraksi fitur.

Hasil: Hasil evaluasi menunjukkan bahwa kernel RBF mencapai akurasi tertinggi sebesar 74.78%, diikuti oleh kernel linear dengan akurasi 74.51%, dan kernel polinomial dengan akurasi 74.10%. Meskipun perbedaan antara ketiga kernel tidak signifikan, kernel RBF unggul dalam klasifikasi sentimen positif, sementara ketiga kernel kesulitan dalam memprediksi kelas netral dan negatif.

Keaslian/ *state of the art*: Temuan ini memberikan kontribusi penting bagi pengembangan metode analisis sentimen yang efektif, terutama dalam konteks dataset dengan ketidakseimbangan kelas yang tinggi. Dalam menangani ketidakseimbangan kelas, bisa dilakukan teknik seperti oversampling pada kelas yang lebih kecil atau menggunakan teknik cost-sensitive learning untuk memberi bobot lebih pada kelas negatif dan netral.

1. Pendahuluan

Industri kosmetik di Indonesia dalam beberapa tahun terakhir ini menunjukkan pertumbuhan yang signifikan. Menurut data Kementerian Koordinator Bidang Perekonomian RI, pertumbuhan jumlah perusahaan kosmetik di Indonesia mencapai 21,9%, yakni dari 913 perusahaan pada tahun 2022 menjadi sebanyak 1.010 perusahaan pada pertengahan 2023 [1]. Segmen pasar terbesar didominasi oleh kategori perawatan diri dengan nilai pasar sebesar USD3,18 miliar pada tahun 2022, disusul *skincare* sebesar USD2,05 miliar, kosmetik USD1,61 miliar, dan wewangian USD39 juta [1]. Peningkatan ini didorong oleh meningkatnya kesadaran masyarakat terhadap perawatan kulit, serta hadirnya berbagai merek lokal yang menawarkan produk berkualitas dengan harga terjangkau [2]. Di tengah perkembangan tersebut, ulasan konsumen di platform *online* menjadi salah satu faktor penting yang memengaruhi keputusan pembelian. Dalam penelitian yang dilakukan terhadap 105 sampel berjenis kelamin perempuan, disimpulkan bahwa *Online Consumer Review* khususnya pada platform Female Daily Network berpengaruh terhadap keputusan pembelian produk *skincare* [3]. Nilai rating yang diberikan oleh konsumen tidak hanya mencerminkan kepuasan terhadap produk, tetapi juga menyimpan informasi berharga mengenai pandangan positif, netral, dan negatif terhadap produk *skincare* lokal.

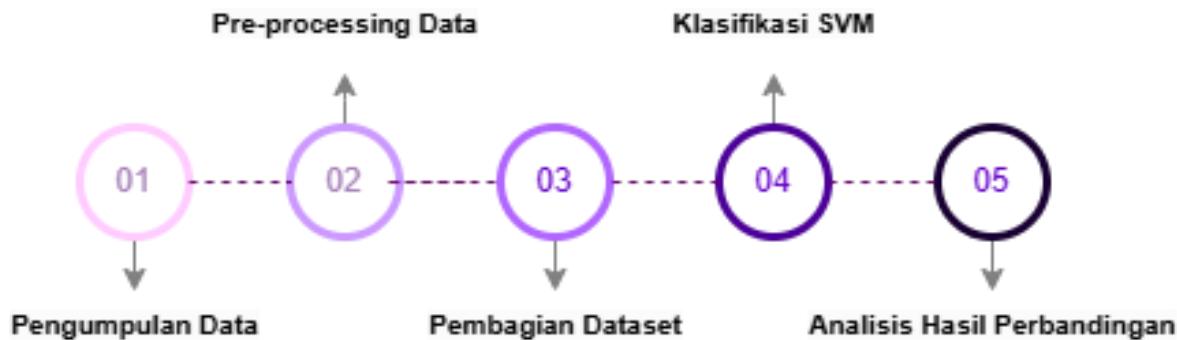
Dalam konteks ini, analisis sentimen menjadi alat yang sangat penting untuk menggali persepsi konsumen, di mana sentimen positif menunjukkan kepuasan dan rekomendasi, sentimen netral mencerminkan ketidakpastian, dan sentimen negatif sering kali berhubungan dengan kekecewaan atau ketidakpuasan. Namun, tantangan yang dihadapi adalah bagaimana mengidentifikasi dan mengklasifikasikan sentimen ini secara akurat, terutama pada dataset yang tidak seimbang, di mana sentimen positif sering kali lebih mendominasi. Selain itu, permasalahan yang dihadapi dalam penelitian ini adalah bagaimana memilih metode klasifikasi yang optimal untuk menganalisis sentimen dari rating produk skincare lokal. Dalam beberapa penelitian dikatakan bahwa metode *Support Vector Machine* (SVM) unggul untuk analisis sentimen, seperti penelitian [4] yang menunjukkan bahwa SVM mengungguli pengklasifikasi tradisional seperti Regresi Logistik, K-Nearest Neighbors, Naïve Bayes dan XGBoost dalam tugas analisis sentimen, *Support Vector Machine* (SVM) memberikan presisi dan tingkat ingatan yang lebih baik. Dalam analisis sentimen pariwisata, *Support Vector Machine* (SVM) tanpa *Synthetic Minority Over-sampling Technique* (SMOTE) mencapai akurasi 97,79%, menunjukkan efektivitasnya dalam mengklasifikasikan sentimen positif [5]. Algoritma ini juga unggul dalam efisiensi penggunaan memori melalui teknik pemetaan kernel ke dalam ruang fitur berdimensi tinggi, yang semakin memperkuat posisinya dalam menangani klasifikasi data yang kompleks [6]. *Support Vector Machine* (SVM) telah berhasil diterapkan di berbagai domain, termasuk pemantauan tempat parkir secara *real-time* [7], analisis sentimen tweet Indonesia [8], analisis sentimen tingkat kepuasan layanan data operator [9], pengenalan wajah, pengenalan teks, dan identifikasi penyakit tanaman [10]

Support Vector Machine (SVM) sangat bergantung pada pemilihan kernel yang sesuai, yang secara langsung mempengaruhi keakuratan tugas klasifikasi. Kernel yang berbeda menunjukkan efektivitas yang bervariasi berdasarkan karakteristik spesifik dari data yang dianalisis. Seperti polinomial dan *Radial Basis Function* (RBF), pada penelitian [11] menghasilkan tingkat akurasi yang bervariasi dalam analisis sentimen, dimana *Radial Basis Function* (RBF) mencapai akurasi 86,17% dibandingkan dengan 84,56% untuk kernel polinomial dalam analisis sentimen perawatan kulit. Dalam deteksi *cyberbullying* di Twitter, kernel sigmoid mencapai akurasi tertinggi 83,85%, menyoroti pentingnya pemilihan kernel dalam tugas klasifikasi teks [12]. Pada analisis sentimen ulasan aplikasi, kernel RBF mencapai akurasi yang lebih tinggi (86,1%) dibandingkan dengan kernel linear (83,1%) [13]. Untuk deteksi spam, *kernel linear* dan polinomial derajat 1 memiliki performa terbaik, keduanya mencapai presisi dan *recall* sebesar 0,99 [14]. Dengan demikian, melakukan perbandingan antar *kernel Support Vector Machine* (SVM) merupakan pendekatan yang penting untuk menentukan metode yang paling efektif untuk klasifikasi sentimen dalam konteks ini. Maka dari itu, penelitian ini bertujuan untuk mengevaluasi dan membandingkan akurasi serta efektivitas *kernel linear*, polinomial, dan RBF dalam klasifikasi sentimen negatif, netral dan positif berdasarkan rating dari platform Female Daily Network.

2. Metode/Perancangan

Metode penelitian ini berfokus pada penggunaan algoritma *Support Vector Machine* (SVM) dengan berbagai *kernel* yaitu kernel linier, polinomial, dan RBF dalam klasifikasi sentimen pada ulasan produk *skincare* lokal dari Indonesia. Tahapan penelitian melibatkan proses pengumpulan data, *pre-processing* data, vektorisasi fitur teks, pembagian *dataset*, pelatihan model, pengujian akurasi, serta evaluasi performa menggunakan berbagai metrik evaluasi

seperti akurasi, *precision*, *recall*, *f1-score*, dan *confusion matrix*. Tahapan penelitian ini lebih jelasnya dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini adalah data Indonesia Skincare From Female Daily Reviews yang diperoleh dari Kaggle. *Dataset* ini berisi informasi seperti *type*, nama produk, *rating*, dan total *reviewers*.

2.2. Pre-processing Data

Pre-processing data adalah tahap dalam mempersiapkan kumpulan data yang bertujuan untuk meningkatkan kualitas dan akurasi data sebelum diproses lebih lanjut [15]. Pada tahap ini dilakukan 3 langkah dalam pre-processing data, yaitu penanganan missing values, pelabelan data, serta vektorisasi teks.

2.3. Pembagian Dataset

Pada pembagian *dataset*, data dibagi menjadi dua bagian, yaitu data latih dan data uji dengan pembagian yang digunakan adalah 80% data latih dan 20% data uji. Pembagian *dataset* ini bertujuan untuk memastikan bahwa model dapat belajar dari sebagian besar data yang tersedia, sementara performanya diuji pada data yang belum pernah dilihat sebelumnya untuk menghindari *overfitting* [16].

2.4. Klasifikasi SVM

Support Vector Machine (SVM) adalah metode klasifikasi yang mendefinisikan batas-batas antar kelas dengan memaksimalkan jarak dari titik data terdekat. SVM bekerja dengan cara menemukan *hyperplane* yang optimal dalam ruang fitur berdimensi tinggi menggunakan fungsi kernel [17]. Terdapat 3 kernel yang digunakan dalam klasifikasi SVM pada penlitian ini, yaitu linear, polinomial, dan RBF.

2.4.1. Kernel Linear

Kernel linier bekerja dengan menemukan *hyperplane* linier yang memisahkan kelas-kelas data [18]. Model nantinya berusaha mencari garis atau *hyperplane* yang memisahkan kelas sentimen positif, negatif, dan netral berdasarkan fitur yang diperoleh dari proses vektorisasi teks dengan TF-IDF.

2.4.2. Kernel Polynomial

Polynomial *kernel* adalah *kernel* yang mengizinkan SVM untuk menemukan *hyperplane* non-linier [18]. *Kernel* ini memetakan data ke ruang dimensi yang lebih tinggi menggunakan kombinasi polinomial dari fitur asli [19]. Ketika kernel polinomial digunakan, model mencoba menemukan pemisahan non-linier di ruang fitur yang diperoleh dari TF-IDF.

2.4.3. Kernel RBF

RBF atau Gaussian *kernel* dapat menangani data yang tidak linier. RBF *kernel* bekerja dengan memetakan setiap titik data ke dalam ruang dimensi yang sangat tinggi di mana data lebih mungkin dapat dipisahkan secara linier [18]. Kernel RBF digunakan untuk mencoba memisahkan data secara lebih efektif dengan mempertimbangkan pola-pola yang sangat kompleks.

2.5. Analisis Hasil Perbandingan

Setelah model dilatih, kinerjanya dievaluasi menggunakan metrik evaluasi standar dalam klasifikasi. Akurasi dan metrik evaluasi seperti *precision*, *recall*, dan *f1-score* digunakan untuk menilai performa setiap *kernel*. Akurasi mengukur persentase prediksi yang benar dari seluruh prediksi yang dilakukan oleh model. Persamaan akurasi model adalah sebagai berikut.

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Jumlah Data}}$$

Precision berguna untuk mengukur seberapa banyak dari prediksi positif yang benar-benar positif. *Precision* berguna dalam situasi di mana biaya kesalahan prediksi positif lebih tinggi, dimana persamaannya adalah sebagai berikut.

$$\text{Precision} = \frac{\text{True Positives (TP)}}{\text{True Positives (TP)} + \text{False Positives (FP)}}$$

Recall digunakan untuk mengukur seberapa banyak data positif yang teridentifikasi dengan benar oleh model. Ini berguna ketika biaya kesalahan pada data positif yang tidak terdeteksi tinggi. Persamaan dari *recall* adalah sebagai berikut.

$$\text{Recall} = \frac{\text{True Positives (TP)}}{\text{True Positives (TP)} + \text{False Negatives (FN)}}$$

F1-score adalah rata-rata harmonis antara *precision* dan *recall*. *F1-score* memberikan gambaran yang lebih seimbang, terutama jika ada ketidakseimbangan antara *precision* dan *recall*. Dimana persamaannya adalah sebagai berikut.

$$F1 - Score = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

3. Hasil dan Pembahasan

3.1. Pengumpulan Data

Proses pengumpulan data menggunakan dataset berformat CSV dimana dataset yang digunakan dalam penelitian ini adalah data Indonesia Skincare From Female Daily Reviews yang diperoleh dari website Kaggle. Dataset ini berjumlah 7432 data yang memuat informasi tipe atau jenis skincare, nama produk skincare, nama brand, rating, total reviewers dan link produk dari

platform female daily network. *Dataset* ini berisi informasi seperti yang dapat dilihat pada Gambar 2.

Type	Name	Brand	Rating	Total Reviewers	Link
0 Sunscreen	Sun Protection SPF 30 PA+++	Emina	3.6	13,700	https://reviews.femaledaily.com/products/moist...
1 Sunscreen	Hydrasoothe Sunscreen Gel SPF 45+++	Azarine Cosmetics	4.1	9,441	https://reviews.femaledaily.com/products/moist...
2 Sunscreen	UV Moisture Milk	Skin Aqua	4.2	8,947	https://reviews.femaledaily.com/products/moist...
3 Sunscreen	UV Shield Essential Sunscreen Gel SPF 35 PA +++	Wardah	3.3	8,358	https://reviews.femaledaily.com/products/moist...
4 Sunscreen	UV Aqua Rich Watery Essence SPF 50+/PA++++	Biore	4.2	7,362	https://reviews.femaledaily.com/products/moist...

Gambar 2. Tampilan Isi Dataset

3.2. Pre-processing Data

Pada tahap ini, dilakukan beberapa langkah diantaranya sebagai berikut.

3.2.1. Penanganan Missing Values

Pada tahap ini missing values dalam kolom rating dan total *reviewers* dihapus dari *dataset*, dengan tujuan agar model hanya dilatih menggunakan data yang lengkap.

3.2.2. Pelabelan Data

Pelabelan data dilakukan pada kolom Rating yang diubah menjadi label sentimen dengan aturan rating ≥ 4 dikategorikan positif, rating = 3 dikategorikan netral, rating < 3 dikategori negatif. label sentimen yang dihasilkan kemudian di-encode menjadi bentuk numerik, di mana positif diwakili dengan angka 2, netral dengan angka 1, dan negatif dengan angka 0. berikut ini adalah hasil dari pelabelan data yang dapat dilihat pada Gambar 3.

Data setelah penambahan kolom Sentiment:		
Rating	Sentiment	
0	3.6	Negative
1	4.1	Positive
2	4.2	Positive
3	3.3	Negative
4	4.2	Positive

Data setelah encoding kolom Sentiment:		
Rating	Sentiment	
0	3.6	0
1	4.1	2
2	4.2	2
3	3.3	0
4	4.2	2

(a) (b)

Gambar 3. Hasil Tahap Pelabelan Data Sebelum (a) dan Sesuai Encoding (b)

3.2.3. Vektorisasi Teks

Pada tahap ini teks kolom name yang berisi nama produk diubah menjadi representasi numerik menggunakan teknik TF-IDF Vectorizer untuk menangkap pentingnya kata dalam nama produk. Hanya 5000 fitur (kata) teratas yang dipilih untuk diolah oleh model. Hasil dari vektorisasi teks dapat dilihat pada Gambar 4.

```
Hasil vektorisasi TF-IDF (5 baris pertama):
[[0. 0. 0. ... 0. 0. 0.]
 [0. 0. 0. ... 0. 0. 0.]
 [0. 0. 0. ... 0. 0. 0.]
 [0. 0. 0. ... 0. 0. 0.]
 [0. 0. 0. ... 0. 0. 0.]]
Fitur TF-IDF: ['01' '05' '10' '100' '100h' '100ml' '1025' '1028' '11' '12']
```

Gambar 4. Hasil Vektorisasi Teks

3.3. Pembagian Dataset

Setelah proses pre-processing, dataset dibagi menjadi dua bagian yaitu Training Set sebanyak 80% data digunakan untuk melatih model. Dan Test Set sebanyak 20% data sisanya digunakan untuk menguji model. Pembagian dilakukan secara acak menggunakan fungsi *train test split* dengan parameter *random state* yaitu 42 dalam memastikan pembagian data yang konsisten di setiap pengujian.

3.4. Klasifikasi SVM

Proses klasifikasi dilakukan dengan melatih model menggunakan *training set* dan kemudian menguji performa model tersebut menggunakan *test set*. Dimana hasil dari klasifikasi diketahui kernel linear menghasilkan akurasi sebesar 0.745, kernel polinomial memberikan akurasi 0.741, dan kernel RBF menghasilkan akurasi 0.748.

3.5. Analisis Hasil Perbandingan

Pengujian dilakukan dengan confusion matrix melalui library SVM. Hasil dari perbandingan kernel disajikan menggunakan Tabel 1. yang menampilkan akurasi dan metrik lainnya.

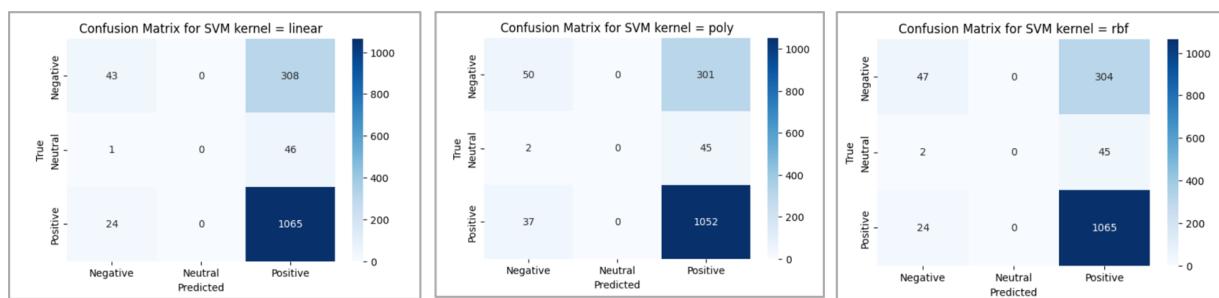
Table 1. Perbandingan Nilai kernel

Kernel	Akurasi	Precision (Negatif)	Recall (Negatif)	F1-Score (Negatif)	Precision (Netral)	Recall (Netral)	F1-Score (Netral)	Precision (Positif)	Recall (Positif)	F1-Score (Positif)
Linear	74,51%	0,63	0,12	0,21	1,00	0,00	0,00	0,75	0,98	0,85
Polinomial	74,11%	0,56	0,14	0,23	1,00	0,00	0,00	0,75	0,97	0,85
RBF	74,78%	0,64	0,13	0,22	1,00	0,00	0,00	0,75	0,98	0,85

Dari Tabel 1. dapat dilihat bahwa akurasi terbaik diperoleh dari kernel RBF dengan nilai 74.7%, sedikit lebih tinggi dibandingkan kernel linear (74.5%) dan kernel polinomial (74.1%). Hal ini sejalan dengan penelitian sebelumnya [20], yang menyebutkan bahwa kernel RBF sering kali memberikan hasil terbaik dalam kasus data non-linear, terutama ketika distribusi data antar kelas tidak terpisahkan secara linear. Dalam penelitian tersebut, kernel RBF mencapai akurasi lebih tinggi dibandingkan kernel lainnya untuk deteksi serangan jaringan, meskipun tetap menghadapi tantangan serupa terkait ketidakseimbangan kelas. Pada semua kernel, performa untuk kelas positif secara konsisten lebih baik, dengan *precision* dan *recall* mendekati atau mencapai 0.75 dan 0.98. Sebaliknya, performa untuk kelas negatif dan netral jauh lebih rendah. F1-score untuk kelas negatif berada di sekitar 0.21-0.23, menunjukkan bahwa model kesulitan untuk mengklasifikasikan produk dengan *rating* yang rendah. Kelas netral menunjukkan hasil yang sangat buruk, dengan *recall* dan F1-score bernilai 0.00, yang berarti model hampir tidak dapat mendeteksi produk dengan sentimen netral, kemungkinan karena jumlah data pada kelas ini sangat kecil dan tidak seimbang.

Dalam melihat performa ketiga kernel, dilakukan juga visualisasi data dengan *confusion matrix*. *Confusion matrix* digunakan karena dapat memberikan gambaran yang lebih detail tentang bagaimana model SVM dengan berbagai kernel memprediksi setiap kelas sentimen. Kernel linear menghasilkan matriks yang menunjukkan sebagian besar prediksi yang benar berada pada kelas positif, namun prediksi untuk kelas negatif masih kurang akurat, dan kelas netral hampir tidak terdeteksi. Kernel polinomial juga menunjukkan pola yang mirip, dengan performa yang

sedikit lebih rendah daripada kernel linear dalam mendeteksi kelas negatif. Kernel RBF, meskipun memiliki akurasi keseluruhan terbaik, masih mengalami masalah yang sama dalam mendeteksi kelas netral dan negatif, terutama karena model kesulitan dalam mendeteksi kelas dengan data yang lebih sedikit. *Confusion matrix* dari setiap kernel tersebut dapat dilihat dengan visualisasi pada Gambar 5.



Gambar 5. Confusion Matrix Kernel Linear, Polinomial, dan RBF

4. Kesimpulan dan Saran

Dari hasil klasifikasi menggunakan SVM dengan tiga jenis kernel yaitu Linear, Polinomial dan RBF, dapat disimpulkan bahwa SVM mampu memberikan akurasi yang cukup baik dalam mendeteksi sentimen produk *skincare* lokal. Kernel RBF memberikan akurasi terbaik sebesar 74.7%, diikuti oleh kernel linear dengan akurasi 74.5%, dan kernel polinomial sebesar 74.1%. Meskipun ketiga kernel memiliki akurasi yang relatif serupa, model menunjukkan performa terbaik dalam mendeteksi kelas positif, dengan f1-score mencapai 0.85 untuk semua kernel. Namun, model mengalami kesulitan dalam mendeteksi kelas negatif dan netral, yang terlihat dari rendahnya f1-score pada kedua kelas tersebut, dengan f1-score 0.21 untuk kelas negatif dan 0.00 untuk kelas netral. Kelemahan ini disebabkan oleh ketidakseimbangan jumlah data antar kelas, di mana kelas positif mendominasi dataset, sedangkan kelas netral dan negatif memiliki jauh lebih sedikit data.

Untuk meningkatkan performa model, disarankan untuk mempertimbangkan metode yang dapat menangani ketidakseimbangan kelas, seperti oversampling pada kelas yang lebih kecil atau menggunakan teknik cost-sensitive learning untuk memberi bobot lebih pada kelas negatif dan netral. Selain itu, eksplorasi model machine learning lain yang dapat dilakukan untuk melihat apakah mereka mampu meningkatkan performa dalam mendeteksi kelas dengan jumlah data yang lebih sedikit. Penerapan data augmentation atau peningkatan jumlah data untuk kelas minoritas juga dapat membantu memperbaiki performa model di masa depan.

Daftar Pustaka

- [1] H. Limanseto, "Hasilkan Produk Berdaya Saing Global, Industri Kosmetik Nasional Mampu Tembus Pasar Ekspor dan Turut Mendukung Penguatan Blue Economy - Kementerian Koordinator Bidang Perekonomian Republik Indonesia," [Https://Www.Ekon.Go.Id/](https://Www.Ekon.Go.Id/). Accessed: Oct. 04, 2024. [Online]. Available: <https://www.ekon.go.id/publikasi/detail/5626/hasilkan-produk-berdaya-saing-global-industri-kosmetik-nasional-mampu-tembus-pasar-ekspor-dan-turut-mendukung-penguatan-blue-economy>

- [2] N. Nawiyah, R. C. Kaemong, M. A. Ilham, and F. Muhammad, "Penyebab Pengaruhnya Pertumbuhan Pasar Indonesia Terhadap Produk Skin Care Lokal Pada Tahun 2022," *ARMADA : Jurnal Penelitian Multidisiplin*, vol. 1, no. 12, pp. 1390–1396, 2023, doi: 10.55681/armada.v1i12.1060.
- [3] J. Trivena and R. Erdiansyah, "Pengaruh Online Consumer Reviews Pada Aplikasi Female Daily Network terhadap Keputusan Pembelian Produk Skincare Somethinc," *Kiwari*, vol. 1, no. 3, pp. 460–466, 2022, doi: 10.24912/ki.v1i3.15771.
- [4] X. He, "Sentiment Classification of Social Media User Comments Using SVM Models," *2024 5th International Seminar on Artificial Intelligence, Networking and Information Technology, AINIT 2024*, pp. 1755–1759, 2024, doi: 10.1109/AINIT61980.2024.10581547.
- [5] Y. A. Singgalen, "Performance evaluation of SVM with synthetic minority oversampling technique in sentiment classification," *Jurnal Mantik*, vol. 8, no. 1, pp. 326–336, 2024, doi: 10.35335/mantik.v8i1.5077.
- [6] M. Birjali, M. Kasri, and A. Beni-Hssane, "A comprehensive survey on sentiment analysis: Approaches, challenges and trends," *Knowl Based Syst*, vol. 226, p. 107134, 2021, doi: 10.1016/j.knosys.2021.107134.
- [7] A. Zacepins, V. Komasilovs, and A. Kviesis, "Implementation of smart parking solution by image analysis," *VEHITS 2018 - Proceedings of the 4th International Conference on Vehicle Technology and Intelligent Transport Systems*, vol. 2018-March, pp. 666–669, 2018, doi: 10.5220/0006629706660669.
- [8] D. Alita, Y. Fernando, and H. Sulistiani, "Implementasi Algoritma Multiclass Svm Pada Opini Publik Berbahasa Indonesia Di Twitter," *Jurnal Tekno Kompak*, vol. 14, no. 2, p. 86, 2020, doi: 10.33365/jtk.v14i2.792.
- [9] R. N. Chory, M. Nasrun, and C. Setianingsih, "Sentiment analysis on user satisfaction level of mobile data services using Support Vector Machine (SVM) algorithm," *Proceedings - 2018 IEEE International Conference on Internet of Things and Intelligence System, IOTAIS 2018*, pp. 194–200, 2018, doi: 10.1109/IOTAIS.2018.8600884.
- [10] D. M. Abdullah and A. M. Abdulazeez, "Machine Learning Applications based on SVM Classification: A Review," *Qubahan Academic Journal*, vol. 1, no. 2, pp. 81–90, 2021, doi: 10.48161/qaj.v1n2a50.
- [11] V. D. Yunanda and N. Hendrastuty, "Perbandingan Kernel Polynomial dan RBF Pada Algoritma SVM Untuk Analisis Sentimen Skincare di Indonesia," *Jurnal Media Informatika Budidarma*, vol. 8, no. 2, p. 726, 2024, doi: 10.30865/mib.v8i2.7425.
- [12] S. S. Wijayanti, E. Utami, and A. Yaqin, "Comparison of Kernels on Support Vector Machine (SVM) Methods for Analysis of Cyberbullying," *Proceeding - 6th International Conference on Information Technology, Information Systems and Electrical Engineering: Applying Data Sciences and Artificial Intelligence Technologies for Environmental Sustainability, ICITISEE 2022*, pp. 104–108, 2022, doi: 10.1109/ICITISEE57756.2022.10057761.

- [13] E. Rizqi Mar'atus Sholihah, I. G. Susrama Mas Diyasa, and E. Yulia Puspaningrum, "Perbandingan Kinerja Kernel Linear Dan Rbf Support Vector Machine Untuk Analisis Sentimen Ulasan Pengguna Kai Access Pada Google Play Store," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 1, pp. 728–733, 2024, doi: 10.36040/jati.v8i1.8800.
- [14] A. E. Karyawati, K. D. Y. Wijaya, I. W. Supriana, and I. W. Supriana, "a Comparison of Different Kernel Functions of Svm Classification Method for Spam Detection," *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, vol. 8, no. 2, pp. 91–97, 2023, doi: 10.33480/jitk.v8i2.2463.
- [15] R. Sharma, J. Sandhu, and V. Bharti, "Experimental Analysis of a Multimodal biometric System using Preprocessing and Feature Extraction Techniques and Their Impact on Analytical Results," *Proceedings - 2024 6th International Conference on Computational Intelligence and Communication Technologies, CCICT 2024*, pp. 212–219, 2024, doi: 10.1109/CCICT62777.2024.00043.
- [16] O. A. Montesinos López, A. Montesinos López, and J. Crossa, *Overfitting, Model Tuning, and Evaluation of Prediction Performance*. 2022. doi: 10.1007/978-3-030-89010-0_4.
- [17] D. K. Khanduja and S. Kaur, "The Categorization of Documents Using Support Vector Machines," *International Journal of Scientific Research in Computer Science and Engineering*, vol. 11, no. 6, pp. 1–12, 2023, doi: 10.26438/ijsrcse/v11i6.112.
- [18] M. Gori, A. Betti, and S. Melacci, "Kernel machines," *Mach Learn*, pp. 169–215, 2024, doi: 10.1016/b978-0-32-389859-1.00011-8.
- [19] D. Virmani and H. Pandey, "Comparative Analysis on Effect of Different SVM Kernel Functions for Classification," *Lecture Notes in Networks and Systems*, vol. 492, pp. 657–670, 2023, doi: 10.1007/978-981-19-3679-1_56.
- [20] M. F. Fibrianda and dan Adhitya Bhawiyuga, "Analisis Perbandingan Akurasi Deteksi Serangan Pada Jaringan Komputer Dengan Metode Naïve Bayes Dan Support Vector Machine (SVM)," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 2, no. 9, pp. 3112–3123, 2018.