

Optimizing Support Vector Machine (SVM) for Sentiment Analysis of Blu by BCA Reviews with Chi-Square

Aldi Widodo^{1*}, Bambang Agus Herlambang^{2*}, Ramadhan Renaldy^{3*}

* Informatika, Universitas Persatuan Guru Republik Indonesia Semarang

aldiwidodo75@gmail.com¹, bambangherlambang@upgris.ac.id² ramadhanrenaldy@upgris.ac.id³

Article Info

Article history:

Received 2025-07-29

Revised 2025-09-01

Accepted 2025-09-10

Keyword:

Sentiment Analysis, Support Vector Machine, Term Frequency-Inverse Document Frequency, Chi-Square, SMOTE.

ABSTRACT

One of the products resulting from the development of financial technology is the blu by BCA application. This app can be downloaded by BCA bank users via the Google Play Store and has received various user responses in the form of reviews. Analyzing these user reviews can serve as a valuable reference for further development and decision-making by BCA regarding the blu app. Sentiment analysis is conducted using the Support Vector Machine (SVM) algorithm, with SMOTE and TF-IDF techniques, and feature selection via Chi-Square. Sentiment classification using the SVM algorithm and feature selection has produced various outcomes in previous studies. Therefore, further research is necessary to analyze reviews of the blu application. This study aims to optimize the SVM method in analyzing user sentiment on the blu by BCA application by applying Chi-Square feature selection to improve sentiment classification performance. The research method includes the following stages: scraping, preprocessing, labeling, TF-IDF transformation, Chi-Square feature selection, SMOTE, data splitting, data mining, and evaluation. The testing results show that the RBF kernel achieved the highest performance with an accuracy of 0.8623, precision of 0.8623, recall of 0.8623, and F1-score of 0.8623. After applying Chi-Square feature selection, the accuracy improved to 0.8726, with precision of 0.8747, recall of 0.8725, and F1-score of 0.8723. This optimization successfully increased the accuracy by 0.0103 or 1.03%, while also improving precision, recall, and F1-score, indicating that feature selection contributes significantly to sentiment classification performance.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Perkembangan teknologi finansial (*financial technology/fintech*) telah membawa transformasi besar dalam dunia layanan keuangan. Fintech hadir sebagai solusi inovatif yang memberikan kemudahan, efisiensi, dan aksesibilitas tinggi dalam melakukan berbagai transaksi keuangan [1]. Salah satu bentuk konkret dari inovasi ini adalah pergeseran alat pembayaran dari bentuk konvensional seperti uang tunai dan kartu debit/kredit, menuju penggunaan uang elektronik dan aplikasi dompet digital (*e-wallet*). Tren ini tidak hanya diadopsi oleh startup teknologi finansial, tetapi juga oleh institusi perbankan

konvensional yang mulai merespons perubahan preferensi masyarakat dengan meluncurkan produk digital mereka [2].

Salah satu contoh dari transformasi digital ini adalah blu by BCA, sebuah aplikasi mobile banking dan e-wallet yang dikembangkan oleh PT Bank Digital BCA, anak perusahaan dari Bank Central Asia (BCA). Aplikasi ini hadir sebagai alternatif perbankan modern yang memudahkan nasabah dalam mengelola keuangan secara mandiri, tanpa perlu mengunjungi kantor cabang. blu by BCA memiliki berbagai fitur unggulan seperti pembukaan rekening secara online, pemisahan dana dalam sub-rekening (bluSaving), transaksi pembayaran, transfer, hingga integrasi dengan ekosistem BCA lainnya. Kemudahan ini menjadikan blu sebagai salah

satu pilihan utama masyarakat urban dalam aktivitas finansial sehari-hari [3].

Aplikasi ini dapat dengan mudah diunduh melalui Google Play Store, dan seiring dengan pertumbuhan jumlah penggunaanya, semakin banyak pula ulasan dan komentar yang diberikan melalui platform tersebut. Ulasan ini mencerminkan beragam pengalaman pengguna, mulai dari kepuasan terhadap fitur dan layanan yang diberikan, hingga keluhan atas bug, error, atau ketidaknyamanan dalam penggunaan. Informasi-informasi ini jika dianalisis secara sistematis dapat memberikan *insight* yang sangat bernilai bagi pengembang aplikasi maupun pihak manajemen bank dalam meningkatkan kualitas layanan mereka.

Salah satu pendekatan yang dapat digunakan untuk memahami data ulasan tersebut adalah analisis sentimen, yaitu proses mengidentifikasi dan mengkategorikan opini pengguna ke dalam sentimen positif, negatif, atau netral. Melalui analisis sentimen, perusahaan dapat memperoleh gambaran umum mengenai persepsi publik terhadap produk atau layanan yang ditawarkan, serta mengidentifikasi aspek-aspek yang perlu diperbaiki. Untuk keperluan klasifikasi sentimen ini, algoritma yang sering digunakan adalah Support Vector Machine (SVM), sebuah metode pembelajaran mesin yang efektif dalam memisahkan kelas data dengan margin maksimal.

Dalam proses analisis sentimen, diperlukan representasi fitur teks yang baik. Salah satu metode representasi yang paling populer adalah TF-IDF (Term Frequency-Inverse Document Frequency), yang mampu memberikan bobot pada kata-kata penting berdasarkan frekuensi kemunculannya dalam dokumen. Namun, dalam praktiknya, data ulasan sering kali mengalami ketidakseimbangan kelas misalnya, jumlah ulasan positif jauh lebih banyak daripada ulasan negatif. Untuk mengatasi masalah ini, digunakan teknik SMOTE (Synthetic Minority Over-sampling Technique) yang bertujuan menyeimbangkan distribusi data dengan menciptakan data sintetik pada kelas minoritas [4].

Sejumlah penelitian sebelumnya telah membuktikan efektivitas kombinasi SVM, TF-IDF, dan SMOTE dalam klasifikasi sentimen. Penelitian oleh [5] menunjukkan bahwa kombinasi ini mampu menghasilkan akurasi sebesar 85%. Penelitian lain mencapai akurasi 77% [6], sementara studi dengan pembagian data 70:30 antara training dan testing mencatat akurasi 85,87% [7]. Penelitian oleh [8] menekankan keunggulan kernel RBF dalam menghasilkan akurasi tinggi, meskipun memerlukan waktu pelatihan yang lebih lama. Hal ini diperkuat oleh [4] yang menemukan bahwa kernel RBF secara konsisten memberikan performa terbaik. Namun demikian, studi lain oleh [9] menunjukkan bahwa kernel linear justru memberikan hasil akurasi tertinggi dalam kasus tertentu, menandakan bahwa pemilihan kernel sangat bergantung pada karakteristik data yang digunakan.

Meskipun performa SVM sudah tergolong tinggi, optimisasi lebih lanjut masih dimungkinkan, salah satunya dengan penerapan teknik seleksi fitur Chi Square. Chi Square bertujuan memilih fitur-fitur yang paling relevan dengan kelas target, sehingga dapat mengurangi dimensi data dan meningkatkan efisiensi model. Dengan membatasi fitur hanya pada kata-kata yang memiliki pengaruh signifikan terhadap klasifikasi, proses pelatihan menjadi lebih cepat dan akurasi dapat meningkat. Penelitian oleh [10] menunjukkan bahwa integrasi Chi Square dalam pipeline SVM mampu meningkatkan akurasi secara signifikan dibandingkan model tanpa seleksi fitur.

Sejumlah penelitian sebelumnya telah membuktikan efektivitas kombinasi SVM, TF-IDF, dan SMOTE dalam klasifikasi sentimen [5][6][7]. Selain itu, kernel RBF terbukti unggul dalam banyak kasus [4][8], meskipun ada penelitian yang menunjukkan kernel linear dapat memberikan akurasi tertinggi dalam kondisi tertentu [9]. Hasil-hasil ini menunjukkan bahwa pemilihan kernel sangat dipengaruhi oleh karakteristik data yang digunakan. Namun, penelitian terdahulu umumnya masih berfokus pada variasi kernel dan teknik sampling, sementara integrasi metode seleksi fitur, khususnya Chi Square Feature Selection, belum banyak dieksplorasi dalam konteks klasifikasi sentimen. Berdasarkan studi [10] menunjukkan bahwa teknik ini mampu meningkatkan akurasi dengan menyeleksi fitur yang paling relevan.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengoptimalkan algoritma SVM dalam analisis sentimen terhadap ulasan pengguna aplikasi blu by BCA, dengan menerapkan teknik Chi Square Feature Selection guna meningkatkan akurasi klasifikasi. Pemilihan pendekatan ini didasarkan pada kemampuannya dalam menyeleksi kata-kata kunci yang paling informatif, sehingga tidak hanya mempercepat proses klasifikasi, tetapi juga membantu model untuk fokus pada informasi yang benar-benar penting. Diharapkan melalui pendekatan ini, hasil klasifikasi menjadi lebih akurat dan dapat dimanfaatkan sebagai dasar pengambilan keputusan oleh pihak pengembang maupun manajemen aplikasi blu by BCA.

Analisis sentimen merupakan salah satu teknik dalam pengolahan data teks yang bertujuan untuk mengidentifikasi dan mengklasifikasikan opini atau pernyataan menjadi kategori sentimen tertentu, seperti positif, negatif, atau netral [11]. Teknik ini digunakan untuk memahami perasaan, sikap, dan pendapat individu terhadap suatu topik, produk, atau layanan tertentu. Dalam praktiknya, data yang digunakan dalam analisis sentimen terlebih dahulu diolah melalui proses pembersihan, seperti menghapus karakter yang tidak relevan dan melakukan stemming untuk mendapatkan kata dasar dari teks yang tersedia. Setelah itu, data akan diproses menggunakan algoritma tertentu agar sentimen dari keseluruhan teks dapat dikenali secara akurat [12]. Hasil dari analisis ini dapat dimanfaatkan dalam berbagai bidang, termasuk riset pasar, evaluasi produk, pengembangan aplikasi, dan penguatan citra merek.

Salah satu algoritma yang paling umum digunakan dalam analisis sentimen adalah Support Vector Machine (SVM). SVM merupakan metode klasifikasi yang bekerja dengan menentukan garis atau bidang pemisah terbaik (hyperplane)

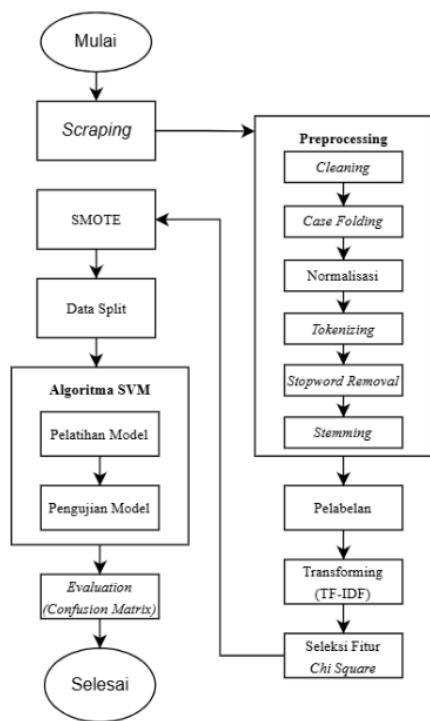
antara dua kelas data, misalnya antara sentimen positif dan negatif [13]. Algoritma ini memanfaatkan data yang berada paling dekat dengan hyperplane sebagai penentu batas klasifikasi yang optimal [14]. Untuk meningkatkan performa klasifikasi pada data non-linear, SVM menerapkan teknik kernel trick, yang memetakan data ke ruang berdimensi lebih tinggi sehingga dapat dipisahkan secara linear. Beberapa jenis kernel yang sering digunakan dalam implementasi SVM meliputi kernel linear, polynomial, dan Radial Basis Function (RBF) [15].

Salah satu objek yang relevan untuk diterapkan analisis sentimen adalah aplikasi blu by BCA, yaitu sebuah layanan perbankan elektronik dalam bentuk aplikasi mobile yang dikembangkan oleh Bank Central Asia (BCA) melalui anak perusahaannya. Aplikasi ini dirancang untuk memberikan kemudahan kepada pengguna dalam melakukan berbagai transaksi keuangan secara digital [16]. Hingga saat ini, blu by BCA telah menempati posisi ke-6 dalam kategori aplikasi keuangan dengan jumlah unduhan lebih dari satu juta pengguna. Di Google Play Store, aplikasi ini mendapatkan rating sebesar 4,6 dari 5, yang menunjukkan tingkat kepuasan pengguna yang relatif tinggi. Ulasan dan komentar yang diberikan oleh pengguna terhadap aplikasi ini menjadi sumber data yang potensial untuk dianalisis guna memahami persepsi masyarakat serta meningkatkan kualitas layanan aplikasi.

II. METODE

A. Alur Penelitian

Penelitian ini dimulai dengan proses pengumpulan dataset berupa ulasan pengguna aplikasi blu by BCA melalui Google Play Store.



Gambar 1. Alur penelitian analisis sentimen

Dataset yang telah dikumpulkan kemudian diproses melalui tahapan preprocessing untuk mempersiapkan data sebelum dilakukan text mining. Selanjutnya, dilakukan pelabelan otomatis menggunakan logika sederhana berdasarkan rating ulasan. Setelah pelabelan, data ditransformasi menggunakan metode TF-IDF untuk merepresentasikan frekuensi kemunculan kata. Tahap selanjutnya adalah penerapan teknik SMOTE guna menangani ketidakseimbangan kelas dalam data.

B. Scraping

Scraping merupakan proses pengambilan data dari internet menggunakan alat atau pustaka khusus. Pada penelitian ini, data ulasan diambil menggunakan pustaka google-play-scrapers, dengan penyaringan berdasarkan urutan ulasan terbaru (newest). Data yang berhasil diambil berupa teks ulasan, tanggal, rating, dan informasi terkait lainnya [17].

C. Preprocessing

Tahapan preprocessing bertujuan untuk membersihkan dan menyiapkan data teks sebelum dianalisis. Langkah-langkah yang dilakukan meliputi:

- 1) *Cleaning*: Menghapus karakter yang tidak diperlukan seperti URL, HTML tag, emoji, angka, dan simbol [18].
- 2) *Case Folding*: Mengubah seluruh huruf menjadi huruf kecil agar standar [19].
- 3) *Normalisasi*: Mengganti kata tidak baku menjadi bentuk baku yang sesuai [20].
- 4) *Tokenizing*: Memecah teks menjadi bagian-bagian kecil (kata/token) [21].
- 5) *Stopword Removal*: Menghapus kata-kata umum yang tidak memiliki pengaruh besar terhadap makna kalimat (seperti "yang", "dan", "di") [22].
- 6) *Stemming*: Mengubah kata berimbuhan menjadi kata dasar [23][24].

D. Pelabelan

Pelabelan dilakukan secara otomatis berdasarkan rating ulasan. Ulasan dengan nilai rating lebih dari 3 dikategorikan sebagai sentimen positif, sementara ulasan dengan rating 3 ke bawah dikategorikan sebagai sentimen negatif.

E. Transformasi TF-IDF (Term Frequency-Inverse Document Frequency)

Metode TF-IDF digunakan untuk menghitung bobot kata berdasarkan frekuensi kemunculannya dalam dokumen tertentu dan keseluruhan dokumen. Rumus TF-IDF sebagai berikut:

$$TF - IDF = tf \times idf \quad (1)$$

1) Term Frequency (TF)

Menaksir seberapa sering kemunculan kata dalam dataset.

$$tf = \frac{\text{jumlah kata terpilih}}{\text{jumlah kata}} \quad (2)$$

2) Inverse Document Frequency (IDF)

Menghitung banyaknya dokumen yang tercantum *term* tertentu dalam dataset.

$$idf = \frac{\text{jumlah dokumen}}{\text{jumlah frekuensi kata terpilih}} \quad (3)$$

F. Seleksi Fitur Menggunakan Chi-Square

Chi-Square merupakan teknik seleksi fitur yang digunakan untuk memilih kata-kata yang paling relevan terhadap kategori tertentu. Fitur yang tidak berkontribusi signifikan terhadap klasifikasi akan dihapus untuk meningkatkan efisiensi dan akurasi model [25]. Rumus Chi-Square adalah:

$$X^2 = \frac{\sum(O_i - E_i)^2}{E_i} \quad (4)$$

Keterangan:

X^2 : Nilai Chi Square

O_i : Frekuensi dari hasil observasi

E_i : Frekuensi dari hasil yang diharapkan

G. SMOTE (Synthetic Minority Over-Sampling Technique)

SMOTE adalah teknik oversampling yang digunakan untuk mengatasi ketidakseimbangan kelas dalam dataset. Teknik ini menghasilkan data sintetis pada kelas minoritas berdasarkan kedekatan antar sampel, sehingga distribusi data menjadi lebih seimbang dan model tidak bias terhadap kelas mayoritas [26].

H. Split Data

Dataset dibagi menjadi dua bagian, yaitu data latih dan data uji. Rasio pembagian yang digunakan adalah 80% data latih dan 20% data uji. Data latih digunakan untuk melatih model, sedangkan data uji digunakan untuk mengevaluasi performa model. Dalam penelitian ini, dari total 5000 data, sebanyak 4000 digunakan untuk pelatihan dan 1000 untuk pengujian [8].

I. Klasifikasi Menggunakan Algoritma SVM

Proses klasifikasi dilakukan menggunakan algoritma Support Vector Machine (SVM), yang bertujuan untuk menemukan hyperplane terbaik dalam memisahkan dua kelas data. Algoritma ini diimplementasikan menggunakan library scikit-learn.

Proses klasifikasi pada suatu model memberikan prediksi untuk menentukan kelas akhir data. Setelah dilakukan seleksi fitur dan *splitting* data, dilanjutkan dengan klasifikasi SVM menggunakan library scikit-learn untuk menemukan garis pemisah (*hyperplane*) terbaik antar dua kelas data sehingga model dapat mempelajari relevansi fitur data. Diperlukan perhitungan melalui kernel untuk memberikan kemudahan dalam penentuan akurasi model terbaik. Kernel yang dimanfaatkan pada penelitian adalah kernel linear, polynomial, dan RBF untuk dilakukan komparasi akurasi terbaik.

Pada penelitian ini, pengujian dilakukan menggunakan kernel linear, polynomial, dan RBF dengan parameter bawaan (*default parameters*) dari library scikit-learn. Pemilihan parameter default

dilakukan karena fokus penelitian adalah pada perbandingan performa kernel dan pengaruh seleksi fitur Chi-Square, bukan pada optimasi hyperparameter. Dengan demikian, hasil yang diperoleh mencerminkan kinerja baseline SVM dengan berbagai kernel, sehingga peningkatan performa akibat penerapan Chi-Square dapat diamati secara lebih objektif

Adapun rumus metode SVM sebagai berikut.

$$(w \cdot x_i) + b = 0 \quad (4)$$

Keterangan:

w : Parameter *hyperplane*

x_i : Data input berbentuk angka

b : Nilai bias

Model dilatih menggunakan data latih untuk mempelajari hubungan antara fitur dan label. Setelah itu, model diuji menggunakan data uji, dan performanya dinilai melalui metrik evaluasi.

J. Evaluasi Model

Evaluasi model menggunakan *confusion matrix* yang menyajikan parameter utama untuk menilai akurasi kinerja model, *precision*, *recall*, dan *F1-score*. Setiap kernel dievaluasi menggunakan *confusion matrix* dan dianalisis menyeluruh

III. HASIL DAN PEMBAHASAN

A. Scraping

Penelitian ini mengumpulkan data melalui scraping menggunakan Python dengan library google-play-scraper. Data review yang diambil merupakan periode 07 Juli 2024 sampai 08 Agustus 2025 dengan total sebanyak 5000 review berbahasa Indonesia dari Google Play Store. Kolom yang digunakan dalam analisis sentimen hanya mencakup rating dan review teks. Keterbatasan penelitian terletak pada ruang lingkup data yang hanya bersumber dari Google Play Store sehingga belum mencerminkan perspektif pengguna di platform lain. Selain itu, tidak semua ulasan memberikan informasi yang jelas dan mendalam sehingga dapat memengaruhi kualitas pelabelan. Dominasi ulasan positif pada aplikasi juga berpotensi menimbulkan ketidakseimbangan kelas meskipun telah dilakukan penanganan dengan teknik SMOTE. Kondisi ini menunjukkan bahwa hasil penelitian perlu dipahami dalam konteks keterbatasan representasi data yang digunakan. Hasil *scraping* dataset dapat dilihat dalam Tabel 1.

TABEL 1.
HASIL SCRAPING

Review ID	Username	Rating	Review teks	Date
59433193-b506-4f03-a03b-afe5129edc24	Pengguna Google	1	SUSAH BANGET MAU VERIFIKA SI E-KTP YA ALLAH. PA...	2025-07-01 14:25:11

B. Preprocessing

Tahapan dilakukan setelah *scraping* terhadap ulasan pengguna blu by BCA. Tahapan ini ditemukan beberapa hasil:

1) Cleaning

Tahapan ini digunakan untuk menghilangkan atribut seperti menghapus URL, HTML, emoji, simbol, angka, dan *username*. Maka menyisakan 4.489 review. Tabel 2 merupakan hasil *cleaning*.

TABEL 2.
HASIL CLEANING

Review Teks	Hasil Cleaning
wahh aku nyoba ternyata gagal. Mgkn krn aku cm ibu rumah tangga, pdhl aku cm mau save uang hasil phk aku	wahh aku nyoba ternyata gagal Mgkn krn aku cm ibu rumah tangga pdhl aku cm mau save uang hasil phk aku

2) Case Folding

Pengubahan huruf agar semua teks berbentuk huruf kecil. Tabel 3 menunjukkan hasil *case folding* dan proses pembersihan data ini dibutuhkan untuk analisis selanjutnya.

TABEL 3.
HASIL CASE FOLDING

Hasil Cleaning	Hasil Case Folding
wahh aku nyoba ternyata gagal Mgkn krn aku cm ibu rumah tangga pdhl aku cm mau save uang hasil phk aku	wahh aku nyoba ternyata gagal mgkn krn aku cm ibu rumah tangga pdhl aku cm mau save uang hasil phk aku

3) Normalisasi

Tabel 4 merupakan hasil normalisasi yang mengonversi bentuk kata tidak baku menjadi baku.

TABEL 4.
HASIL NORMALISASI

Hasil Case Folding	Hasil Normalisasi
wahh aku nyoba ternyata gagal mgkn krn aku cm ibu rumah tangga pdhl aku cm mau save uang hasil phk aku	wahh aku mencoba ternyata gagal mungkin karena aku cuma ibu rumah tangga padahal aku cuma mau save uang hasil phk aku

4) Tokenizing

Pada tahap ini dilakukan melalui tokenisasi, yaitu memecah teks hasil normalisasi menjadi potongan kata (token) agar setiap kata dapat diproses dan dianalisis secara terpisah dalam tahap ekstraksi fitur maupun klasifikasi. Tabel 5 merupakan hasil dari pembentukan token-token melalui pemisahan kata.

TABEL 5.
HASIL TOKENIZING

Hasil Normalisasi	Hasil Tokenizing
wahh aku mencoba ternyata gagal mungkin karena aku cuma ibu rumah tangga padahal aku cuma mau save uang hasil phk aku	['wahh', 'aku', 'mencoba', 'ternyata', 'gagal', 'mungkin', 'karena', 'aku', 'cuma', 'ibu', 'rumah', 'tangga', 'padahal', 'aku', 'cuma', 'mau', 'save', 'uang', 'hasil', 'phk', 'aku']", "[mencoba', 'gagal', 'rumah', 'tangga', 'save', 'uang', 'hasil', 'phk']

	'gagal', 'rumah', 'tangga', 'save', 'uang', 'hasil', 'phk']
--	---

5) Stopwords Removal

Pada tahap ini dilakukan stopword removal, yaitu menghapus kata-kata umum dalam bahasa Indonesia (seperti “yang”, “dan”, “di”) menggunakan daftar stopword dari pustaka NLTK dengan Bahasa Indonesia, sehingga teks hanya menyisakan kata-kata bermakna yang relevan untuk analisis sentimen. Penghapusan kata yang tidak dibutuhkan atau tidak ada relevansi maupun pengaruh terdapat dalam Tabel 6.

TABEL 6.
STOPWORDS REMOVAL

Hasil Tokenizing	Hasil Stopwords Removal
['wahh', 'aku', 'mencoba', 'ternyata', 'gagal', 'mungkin', 'karena', 'aku', 'cuma', 'ibu', 'rumah', 'tangga', 'padahal', 'aku', 'cuma', 'mau', 'save', 'uang', 'hasil', 'phk', 'aku']", "[mencoba', 'gagal', 'rumah', 'tangga', 'save', 'uang', 'hasil', 'phk']	['mencoba', 'gagal', 'rumah', 'tangga', 'save', 'uang', 'hasil', 'phk']

6) Stemming

Pada tahap ini dilakukan stemming, yaitu proses mengubah kata berimbuhan menjadi kata dasar menggunakan pustaka Sastrawi. Misalnya kata “pembayaran”, “dibayar”, atau “membayar” akan direduksi menjadi kata dasar “bayar”. Tahap ini bertujuan untuk menyatukan variasi kata yang memiliki makna sama agar model tidak menganggapnya sebagai kata yang berbeda, sehingga dapat mengurangi dimensi data dan meningkatkan akurasi analisis sentimen. Dari proses ini data yang dihasilkan menjadi 4.426 review. Proses filter setiap kata yang memiliki imbuhan menjadi bentuk baku dengan hasil dalam Tabel 7.

TABEL 7.
HASIL STEMMING

Review Teks	Hasil Stopwords Removal
['mencoba', 'gagal', 'rumah', 'tangga', 'save', 'uang', 'hasil', 'phk']	coba gagal rumah tangga save uang hasil phk

C. Pelabelan

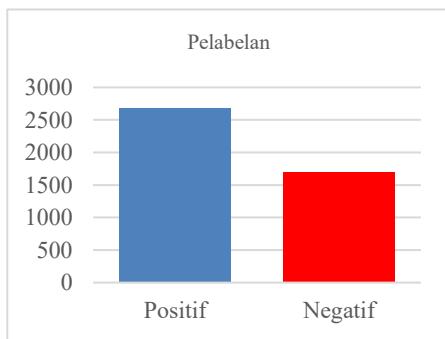
Pelabelan data dilakukan setelah mendapatkan hasil *preprocessing*. Label didapatkan dengan melakukan pengondisian dari kolom *rating* setiap baris data dengan kondisi jika *rating* dengan bintang lebih dari 3 akan masuk ke dalam kategori positif. Sedangkan jika kurang dari atau sama dengan 3 data akan masuk ke dalam kelas negatif. Hasil label 0 menunjukkan pembacaan negatif dan 1 positif. Tabel 8 menyajikan distribusi hasil pelabelan.

TABEL 8.
DISTRIBUSI HASIL PELABELAN

Rating	Stemming Data	Label
1	susah banget verifikasi ektp yaallah terang pas.....	0

1	transaksi blu tarik tunai transfer sama blu...	0
1	bagus	0
5	mantap	1
1	coba gagal rumah tangga save uang hasil phk....	0
1	daftar verifikasi wajah gagal proses klinik ra....	0
3	masuk stuck gambar logo...	0
5	buka rekening blub ca digital bca bank digital...	1
3	aplikasi berat sat set kayak aplikasi bank bel...	0
2	fitur aplikasi bagus berat pas masuk ngelag la....	0

Proses pelabelan dengan hasil positif dan negatif digunakan untuk mengklasifikasikan data ulasan pengguna pada aplikasi blu by BCA. Maka, kelas sentimen netral dihapus.



Gambar 1. Sentimen Pelabelan

Pelabelan dapat dilihat dari Gambar 2 menunjukkan total data ulasan sebanyak 5000 data dengan hasil positif sebanyak 2686 ulasan dan negatif sebanyak 1703 ulasan.

D. TF-IDF

Tahapan ini dilakukan pembobotan seberapa sering kata muncul dalam ulasan dan frekuensi yang lebih jarang menjadi bentuk angka atau numerik untuk diproses ke dalam algoritma klasifikasi.

Hasil ekstraksi fitur melalui *Term Frequency* (TF) mengekstraksi ulasan dari frekuensi kemunculan kata untuk memahami relevansi dengan objek. Sementara itu, *Inverse Document Frequency* (IDF) digunakan untuk menguji seberapa jarang suatu kata muncul dari seluruh ulasan, seiring tingginya nilai IDF maka dianggap unik atau relevan [27]. Tabel 9 menunjukkan hasil TF-IDF.

TABEL 9.
Hasil TF-IDF

Baris	Kolom	Fitur
0	2603	0.25913325433236584
0	3125	0.39382268397843306
0	3979	0.4394124852928733

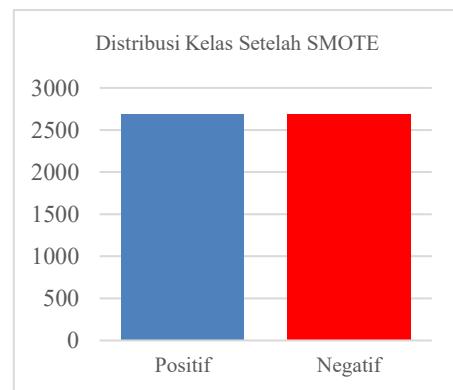
E. Seleksi Fitur Chi Square

Seleksi fitur Chi Square dilakukan setelah pembobotan kata pada tahap TF-IDF dengan menggunakan fungsi *SelectKBest*. Total fitur sebelum

seleksi adalah 4.354 fitur. Pada penelitian ini, jumlah fitur yang dipilih ditentukan berdasarkan nilai parameter *k*, sehingga jumlah fitur yang dihasilkan sesuai dengan *k* yang telah ditetapkan. Untuk tujuan eksperimen, digunakan tiga variasi jumlah fitur terpilih, yaitu 10% (*k* = 435 fitur), 30% (*k* = 1.306 fitur), dan 70% (*k* = 3.047 fitur). Variasi *k* ini dimaksudkan untuk membandingkan performa model dengan jumlah fitur yang berbeda, sekaligus melihat pengaruh reduksi dimensi terhadap akurasi.

F. SMOTE

SMOTE digunakan untuk memunculkan data sintetik untuk kelas minoritas dan menggunakan data yang ada termasuk data baru agar dataset lebih seimbang dan mengenali pola dari semua kelas [28].

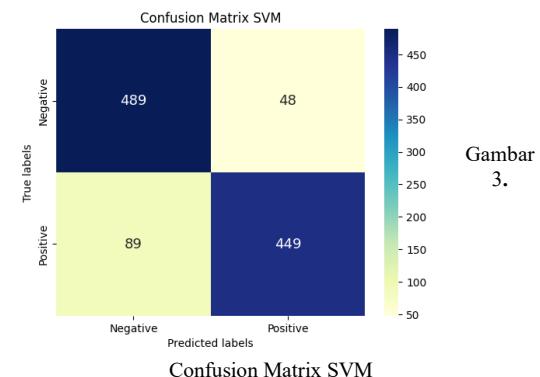


Gambar 2. Distribusi Kelas SMOTE

Hasil SMOTE ditandai dengan kemunculan perbandingan jumlah kelas yang seimbang pada Gambar 3 yaitu label positif 2686 ulasan, dan negatif 2686 ulasan dengan perbandingan yang sama dan dapat dilihat pada Gambar 3.

G. Implementasi Model SVM

Penerapan SVM dilakukan dengan data split untuk melihat konsistensi model [29]. Pembagian dilakukan dengan rasio 80% data *training* dan 20% data *testing*. Hasil prediksi dinyatakan dalam *confusion matrix predicted labels* sebagai berikut.



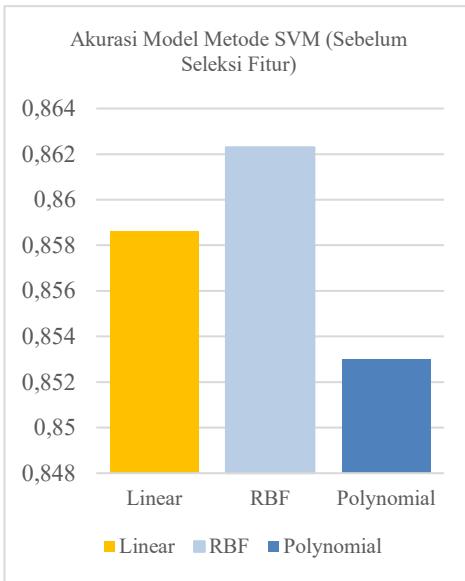
Gambar 3.
Confusion Matrix SVM

Hasil pengujian skenario SVM dalam gambar 4 menunjukkan terdapat 489 ulasan yang terprediksi dan aktual negatif. Adapun 48 ulasan aktual negatif yang terprediksi positif, dan 89 ulasan aktual positif yang terprediksi negatif, serta 449 ulasan aktual dan terprediksi

positif. Adapun persentase ulasan negatif sebanyak 53.77% dan positif 46.23%.

H. Optimasi Kernel

Pengujian ketiga kernel memperoleh performa bervariasi dengan hasil akurasi tertinggi terdapat pada kernel RBF (Radial Basis Function). Nilai akurasi dapat dilihat dalam Gambar 5.



Gambar 4. Perbandingan Akurasi Kernel

Kernel RBF memiliki akurasi tertinggi dengan nilai *F1-score* sebesar 0,8623. Kernel ini juga memperlihatkan keseimbangan antara *precision* dan *recall*.

Dilakukan perbandingan kenaikan akurasi saat menggunakan SVM dan SVM + Chi Square dalam Gambar 6.

Gambar 5. Peningkatan Akurasi.

Hasil seleksi fitur *Chi Square* dan SVM dalam menguji akurasi model terbaik kernel RBF menunjukkan peningkatan.

TABEL 9.

PERBANDINGAN HASIL MODEL RBF METODE SVM DAN SVM + CHI SQUARE

Taraf Nyata (α)	Accuracy	Precision	Recall	F1-score
SVM	0,8623	0,8623	0,8623	0,8623
SVM + Chi (α 0,1)	0,8465	0,8472	0,8465	0,8464
SVM + Chi (α 0,3)	0,8530	0,8544	0,8530	0,8528
SVM + Chi (α 0,5)	0,8558	0,8610	0,8558	0,8553
SVM + Chi (α 0,7)	0,8726	0,8747	0,8725	0,8723

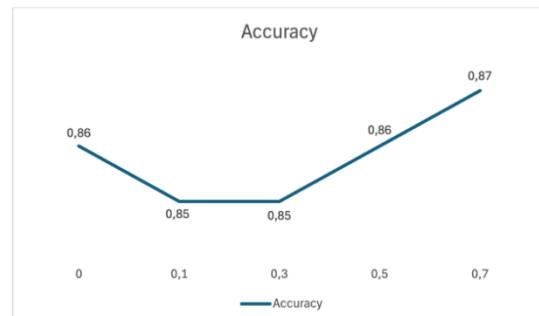
Berdasarkan hasil seleksi fitur pada Tabel 9 terdapat peningkatan performa model kernel RBF yang lebih baik dari pada tanpa seleksi fitur dengan hasil akurasi sebelumnya adalah 0,8623 menjadi 0,8726.

Precision merupakan klasifikasi sentimen positif dengan mengukur nilai akurasi model melalui identifikasi dan prediksi. Hasil *precision* menunjukkan bahwa nilainya adalah 0,8623 mengalami kenaikan menjadi 0,8747 menunjukkan bahwa model memiliki kualitas tinggi dalam mengklasifikasikan sentimen positif dan negatif.

Recall merupakan pengukuran kemampuan model untuk proses klasifikasi sentimen ulasan. Hasil *recall* menunjukkan berada di angka 0,8623 meningkat menjadi 0,8725 yang menunjukkan bahwa model memiliki performa yang tinggi sehingga memudahkan proses klasifikasi dan identifikasi.

F1-score merupakan metrik penilaian untuk mengukur kinerja model klasifikasi berdasarkan hasil metrik lainnya dalam mengenali sentimen ulasan. Hasil *F1-score* menunjukkan angka 0,8623 dan meningkat menjadi 0,8723 yang menunjukkan performa tinggi menyeimbangkan *precision* dan *recall*.

Pemilihan kernel selain RBF dalam penelitian ini menunjukkan dampak yang cukup signifikan terhadap performa klasifikasi. Kernel linear menghasilkan akurasi sebesar 84,56% dan relatif lebih efisien secara komputasi, namun kurang mampu menangkap kompleksitas pola non-linier pada data teks sehingga performanya lebih rendah dibanding RBF. Sementara itu, kernel polynomial hanya mencapai akurasi 79,81% karena cenderung menambah kompleksitas model dan berpotensi menyebabkan overfitting pada data dengan dimensi tinggi seperti TF-IDF. Hal ini membuktikan bahwa meskipun linear dan polynomial memiliki kelebihan dalam konteks tertentu, pada kasus analisis sentimen berbasis teks kernel RBF tetap memberikan hasil yang paling optimal.



Berdasarkan hasil evaluasi menggunakan kernel RBF dengan seleksi fitur Chi-Square ($\alpha = 0,7$), terlihat bahwa performa model meningkat pada kedua kelas, baik positif maupun negatif. Pada kelas negatif, model memperoleh *precision* sebesar 0,85, *recall* 0,91, dan *f1-score* 0,88. Hal ini menunjukkan bahwa model sangat baik dalam mengenali ulasan negatif, dengan tingkat kesalahan yang relatif kecil ketika mengklasifikasikan ulasan negatif sebagai positif. Sementara itu, pada kelas positif, model mencapai *precision* sebesar 0,90, *recall* 0,83, dan *f1-score* 0,87. Artinya, meskipun model cukup akurat dalam memprediksi ulasan positif, masih terdapat beberapa ulasan positif yang salah terdeteksi sebagai negatif. Secara keseluruhan, peningkatan performa tidak hanya terjadi pada satu kelas saja, namun lebih dominan pada kelas negatif, yang ditunjukkan oleh

recall yang lebih tinggi. Hal ini mengindikasikan bahwa penerapan seleksi fitur Chi-Square lebih efektif dalam membantu model mengenali ulasan negatif dibandingkan ulasan positif.

TABEL 10.
PERBANDINGAN HASIL MODEL SVM DENGAN MODEL LAIN

Model	Accuracy	Precision	Recall	F1-score
SVM + <i>Chi</i> (α 0.7)	0.8726	0.8747	0.8725	0.8723
Naive Bayes	0.860	0.893	0.820	0.855
KNN	0.791	0.825	0.738	0.779
Random Forest	0.838	0.842	0.833	0.837

Dari hasil di atas, SVM + Chi ($\alpha = 0.7$) unggul pada semua metrik dengan akurasi tertinggi 87.26%. Precision dan recall juga seimbang, menunjukkan model tidak bias pada salah satu kelas. Naive Bayes berada di posisi kedua (akurasi 86.0%), dengan precision tinggi namun recall lebih rendah, artinya model cenderung lebih baik dalam memprediksi kelas positif tetapi sering meloloskan negatif. Random Forest cukup stabil dengan recall yang hampir sama besar dengan SVM, namun precision lebih rendah. KNN tampil paling lemah, kemungkinan karena kesulitan menangani data teks berdimensi tinggi, sehingga menghasilkan recall dan F1-score yang paling rendah.

I. Evaluasi

Kernel yang diidentifikasi dengan performa terbaik berdasarkan akurasi dilanjutkan dengan eksplorasi kata-kata dalam ulasan pengguna aplikasi blu by BCA dengan frekuensi kemunculan paling sering sesuai dengan kategori sentimen melalui analisis. Visualisasi data sentimen positif dan negatif digunakan untuk memetakan ulasan melalui *word cloud*.

Hasil penelitian ini menunjukkan performa yang kompetitif sekaligus memperlihatkan adanya peningkatan melalui optimasi seleksi fitur. Penelitian [5] melaporkan akurasi sebesar 85% dengan kombinasi SVM, TF-IDF, dan SMOTE, sedangkan penelitian lain hanya mencapai 77% [6]. Studi dengan rasio data 70:30 bahkan mencatat akurasi 85,87% [7]. Hasil penelitian ini, dengan menggunakan kernel RBF dan seleksi fitur Chi-Square, mampu mencapai akurasi 87,26%, yang lebih tinggi dibandingkan ketiga penelitian tersebut. Selain itu, temuan ini selaras dengan penelitian [8] dan [4] yang menekankan keunggulan kernel RBF dalam menghasilkan akurasi tinggi. Namun, berbeda dengan studi [9] yang menemukan bahwa kernel linear bisa lebih unggul pada dataset tertentu, hasil penelitian ini menunjukkan bahwa kernel linear hanya mencapai akurasi 84,56%, masih lebih rendah dibandingkan kernel RBF. Lebih jauh, hasil ini juga mendukung penelitian [10] yang menyatakan bahwa integrasi seleksi fitur Chi-Square ke dalam pipeline SVM dapat meningkatkan performa.

Peningkatan akurasi dari 86,23% (tanpa seleksi fitur) menjadi 87,26% (dengan Chi-Square, $\alpha = 0,7$) menunjukkan bahwa teknik seleksi fitur berkontribusi nyata terhadap peningkatan kualitas model. Meskipun secara persentase terlihat kecil, kenaikan ini konsisten terjadi pada seluruh metrik evaluasi lain, termasuk precision, recall, dan F1-score, sehingga menunjukkan perbaikan yang stabil dan seimbang dalam mengenali sentimen positif maupun negatif. Dalam konteks dataset yang berjumlah 5.000 ulasan, peningkatan 1,03% setara dengan sekitar 50 ulasan tambahan yang berhasil diklasifikasi dengan benar. Jumlah ini cukup signifikan, karena setiap ulasan yang salah klasifikasi berpotensi menimbulkan bias dalam pemahaman persepsi pengguna terhadap aplikasi Blu by BCA. Dengan demikian, penelitian ini tidak hanya konsisten dengan temuan sebelumnya, tetapi juga berhasil membuktikan bahwa penerapan Chi-Square mampu menghasilkan performa yang lebih baik dalam konteks klasifikasi sentimen pada ulasan aplikasi blu by BCA.

Sentimen negatif berjumlah 1703 data negatif mengenai aplikasi blu by BCA dan mendapatkan hasil *word cloud* dengan Kumpulan kata yang sering muncul dalam Gambar 7.



Gambar 6. Visualisasi Sentimen Negatif

Visualisasi data sentimen negatif adalah “aplikasi lambat”, “lambat”, “transaksi”, “loading”, “pakai”, “ribet”, “aplikasi berat”. Kemunculan kata tersebut mencerminkan informasi bahwa pengguna kurang puas atau tidak menyukai sistem dalam aplikasi blu by BCA.

Sentimen positif berjumlah 2686 ulasan positif. Pemaparan dari *word cloud* untuk sentimen positif dapat dilihat dari kemunculan kata dalam Gambar 8.



Gambar 7. Visualisasi Sentimen Positif

Kata yang paling banyak muncul aspek konotasi positif adalah “bagus”, “cepat”, “mantap”. Kemunculan kata dalam sentimen positif ini menunjukkan bahwa pengguna aplikasi blu by BCA menyukai performa aplikasi, sistem, maupun layanannya.

Dalam penelitian ini digunakan metode seleksi fitur Chi-Square karena efisien pada data berdimensi besar seperti teks. Namun, literatur menunjukkan bahwa metode alternatif seperti Recursive Feature Elimination (RFE) dapat memberikan hasil yang lebih optimal. RFE bekerja dengan mengeliminasi fitur-fitur yang kurang berkontribusi berdasarkan model klasifikasi yang digunakan, sehingga subset fitur yang dihasilkan cenderung lebih relevan. Studi oleh [30] menemukan bahwa RFE mampu meningkatkan performa model dibandingkan Chi-Square, meskipun memerlukan komputasi yang lebih tinggi. Hal ini menunjukkan bahwa RFE dapat menjadi opsi potensial untuk penelitian lanjutan ketika sumber daya komputasi memadai.

IV. KESIMPULAN

Berdasarkan hasil penelitian yang dilakukan terhadap ulasan pengguna aplikasi blu by BCA yang diperoleh dari Google Play Store, ditemukan sebanyak 2.686 ulasan positif dan 1.703 ulasan negatif. Untuk mengoptimalkan proses klasifikasi sentimen, algoritma Support Vector Machine (SVM) digunakan dalam kombinasi dengan metode seleksi fitur Chi-Square. Eksperimen dilakukan dengan skenario pembagian data menggunakan rasio 80% untuk data training dan 20% untuk data testing, yang merupakan pendekatan umum dalam pengujian model pembelajaran mesin. Dari ketiga jenis kernel SVM yang digunakan linear, polynomial, dan Radial Basis Function (RBF) diketahui bahwa kernel RBF memberikan performa tertinggi dengan akurasi sebesar 0,8623. Evaluasi metrik lainnya menunjukkan nilai precision, recall, dan F1-score yang konsisten, masing-masing 0,8623. Selanjutnya, penerapan seleksi fitur Chi-Square menunjukkan adanya variasi hasil performa berdasarkan taraf nyata (α) yang digunakan. Pada $\alpha = 0,1$ diperoleh akurasi 0,8465 dengan precision 0,8472, recall 0,8465, dan F1-score 0,8464. Pada $\alpha = 0,3$ performa sedikit meningkat dengan akurasi 0,8530, precision 0,8544, recall 0,8530, dan F1-score 0,8528. Kemudian pada $\alpha = 0,5$ diperoleh akurasi 0,8558 dengan precision 0,8610, recall 0,8558, dan F1-score 0,8553. Peningkatan paling signifikan terjadi pada $\alpha = 0,7$, di mana akurasi mencapai 0,8726, precision 0,8747, recall 0,8725, dan F1-score 0,8723. Hasil ini membuktikan bahwa optimasi seleksi fitur tidak hanya berdampak pada peningkatan akurasi, tetapi juga memberikan kontribusi positif terhadap metrik evaluasi lain seperti precision, recall, dan F1-score. Dengan demikian, penggunaan Chi-Square pada taraf nyata tertentu mampu membantu model untuk lebih fokus pada fitur yang relevan, sehingga performa klasifikasi menjadi lebih baik secara keseluruhan. Untuk pengembangan penelitian selanjutnya, eksplorasi metode seleksi fitur lain seperti Recursive Feature Elimination (RFE) dapat menjadi opsi potensial untuk meningkatkan kualitas fitur yang digunakan dalam klasifikasi sentimen. Selain itu, penerapan algoritma berbasis deep learning, seperti Convolutional Neural Network (CNN) atau Long

Short-Term Memory (LSTM), juga dapat dipertimbangkan.

DAFTAR PUSTAKA

- [1] Imhar and I. Umirrahmah, "Pengaruh Teknologi Finansial (Fintech) Terhadap Strategi Perbankan Pada PT. Bank Central Asia (BCA)," *J. Publ. Sist. Inf. dan Manaj. Bisnis*, vol. 1, no. 1, pp. 58–62, 2022.
- [2] Y. S. Atmaja and D. H. Paulus, "Partisipasi Bank Indonesia Dalam Pengaturan Digitalisasi Sistem Pembayaran Indonesia," *J. Masal. Huk.*, vol. 51, no. 3, pp. 271–286, 2022.
- [3] D. Sabrina, A. D. Sabilla, and N. Azizah, "Kombinasi Vader Lexicon dan Support Vector Machine untuk Klasifikasi Sentimen Komentar Aplikasi Blu BCA," *Inf. Syst. Emerg. Technol. J.*, vol. 6, no. 1, pp. 22–33, 2025.
- [4] S. Rabbani, D. Safitri, N. Ramadhan, A. A. F. Sani, and M. K. Anam, "Perbandingan Evaluasi Kernel SVM untuk Klasifikasi Sentimen dalam Analisis Kenaikan Harga BBM," *Indones. J. Mach. Learn. Comput. Sci.*, vol. 3, no. 2, pp. 153–160, 2023.
- [5] Sukirman, N. P. Husain, A. F. Syam, and R. Mustikosari, "Analisis Sentimen Ulasan Pengguna Tiktok pada Google Play Store Berbasis TF-IDF dan Support Vector Machine," *J. Syst. Comput. Eng.*, vol. 5, no. 1, pp. 91–102, 2024.
- [6] N. Meilani, Furqan, and Suhardi, "Analisis Sentimen Pengguna Aplikasi BSI Mobile Akibat Ransomware Menggunakan Algoritma Support Vector Machine," *J. Inform. Teknol.*, vol. 5, no. 1, pp. 42–51, 2024.
- [7] R. O. Mardiyanto, Kusrini, and F. W. Wibowo, "Analisis Sentimen Pengguna Aplikasi Bank Syariah Indonesia dengan Menggunakan Algoritma Support Vector Machine (SVM)," *J. Tek.*, vol. 4, no. 1, pp. 9–15, 2023.
- [8] I. Bazar, F. Wajidi, and A. A. A. Cirua, "Analisis Sentimen Ulasan Aplikasi Wondr by BNI Menggunakan Algoritma SVM dengan Optimasi Kernel Trick," *J. Ilm. Tek. dan Ilmu Komput.*, vol. 4, no. 2, pp. 69–81, 2025.
- [9] Tinaliah and T. Elizabeth, "Analisis Sentimen Ulasan Aplikasi PrimaKu Menggunakan Metode Support Vector Machine," *J. Tek. Inform. dan Sist. Inf.*, vol. 9, no. 4, pp. 3436–3442, 2022.
- [10] C. A. Aurelia, Trimono, and I. G. S. A. Diyasa, "Analisis Sentimen Penggunaan Galon BPA Menggunakan Seleksi Fitur Chi-Square dan Algoritma Support Vector Machine," *J. Ilm. Teknol. Inf. Asia*, vol. 18, no. 2, pp. 40–49, 2024.
- [11] F. Rahmasari, N. Rahaningsih, R. D. Dana, and C. L. Rohmat, "Optimasi Analisis Sentimen Aplikasi GLINTS Menggunakan Algoritma Support Vector Machine (SVM)," *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 1, pp. 558–570, 2025.
- [12] J. A. Nursiyono, *Machine Learning dengan R Teori dan Praktikum*. Malang: Media Nusa Creative, 2023.
- [13] V. P. Rantung, *Teknik-Teknik Pemrosesan Bahasa Alami (NLP)*. Jawa Tengah: Lakeisha, 2023.
- [14] Harnelia and R. A. Saputra, "Analisis Sentimen Review Skincare Skintific dengan Algoritma Support Vector Machine (SVM)," *J. Inform. dan Tek. Elektro Terap.*, vol. 2, no. 2, pp. 994–1002, 2024.
- [15] Nuryani and F. Alhafid, *Implementasi SWARM Support Vector Machine untuk Deteksi Fibrilasi Atrium Menggunakan Elektrokardiogram*. Surabaya: Jakad Media Publishing, 2024.
- [16] A. Ahmad, R. E. Mirati, and E. Purwaningrum, "Pengaruh Brand Image dan Product Design Terhadap Keputusan Menggunakan Bank Digital (Studi Kasus Blu by BCA Digital)," *Indones. J. Econ. Business, Entrep. Financ.*, vol. 4, no. 1, pp. 606–618, 2024.
- [17] E. R. M. Sholihah, I. G. S. Diyase, and E. Y. Puspaningrum, "Perbandingan Kinerja Kernel Linear dan RBF Support Vector Machine untuk Analisis Sentimen Ulasan Pengguna KAI Access Pada Google Play Store," *J. Mhs. Tek. Inform.*, vol. 8, pp. 728–733, 2024.
- [18] M. U. Albab, Y. Kurniawati, and M. N. Fawaiq, "Optimization of the Stemming Technique on Text Preprocessing President 3 Periods Topic," *J. Transform.*, vol. 20, no. 2, pp. 1–10, 2023.
- [19] S. Khairunnisa, Adiwijaya, and S. A. Faraby, "Pengaruh Text Preprocessing Terhadap Analisis Sentimen Komentar Masyarakat Pada Media Sosial Twitter (Studi Kasus Pandemi COVID-19)," *J. Media Inform. Budidarma*, vol. 5, no. 2, pp.

- 406–414, 2021.
- [20] G. A. B. Suryanegara, Adiwijaya, and M. D. Pubolaksono, “Peningkatan Hasil Klasifikasi Pada Algoritma Random Forest untuk Deteksi Pasien Penderita Diabetes Menggunakan Metode Normalisasi,” *J. Rekayasa Sist. dan Teknol. Inf.*, vol. 5, no. 1, pp. 114–122, 2021.
- [21] A. F. Aufar, M. A. Rosid, I. Ratna, and I. Astutik, “Mengoptimalkan Preprocessing Teks untuk Analisis Sentimen yang Akurat pada Ulasan E-Wallet,” *J. Inf. Comput. Technol. Educ.*, vol. 7, no. 2, pp. 42–50, 2023.
- [22] D. Wardhani, R. Astuti, and D. D. Saputra, “Optimasi Feature Selection Text Mining: Stemming dan Stopword untuk Sentimen Analisis Aplikasi SatuSehat,” *J. Soc. Sci. Res.*, vol. 4, no. 1, pp. 7537–7548, 2024.
- [23] A. Santosa, I. Purnamasari, and R. Mayasari, “Pengaruh Stopword Removal dan Stemming Terhadap Performa Klasifikasi Teks Komentar Kebijakan New Normal Menggunakan Algoritma LSTM,” *J. Sains Komput. dan Inform.*, vol. 6, no. 1, pp. 81–93, 2022.
- [24] A. Nafi, A. T. J. Harjanta, B. A. Herlambang, and F. Saeful, “Analisis Sentimen Review Pelanggan Lazada dengan Sastrawi Stemmer dan SVM-PSO untuk Memahami Respon Pengguna,” *J. Inf. Technol.*, vol. 12, no. 2, pp. 330–339, 2022.
- [25] W. Winata, A. Zaidiah, and N. Chamidah, “Analisis Sentimen Pada Ulasan Produk Masker di Marketplace Shopee Menggunakan Support Vector Machine dan Seleksi Fitur Chi Square,” *Semin. Nas. Mhs. Ilmu Komput. dan Apl.*, vol. 3, no. 2, pp. 491–500, 2022.
- [26] N. Zelina and A. Afiyati, “Analisis Sentimen Ulasan Pengguna Aplikasi M-Banking Menggunakan Algoritma Support Vector Machine dan Decision Tree,” *J. Linguist. Komputasional*, vol. 7, no. 1, pp. 31–37, 2024.
- [27] C. R. A. Widiauwati and A. M. Wahid, *Pemrosesan Bahasa Alami Konsep, Algoritma dan Implementasi*. Banyumas: Zahira Media Publisher, 2025.
- [28] M. A. Hermawan, A. Faqih, and G. Dwilestari, “Implementasi Akurasi Model Naive Bayes Menggunakan SMOTE Dalam Analisis Sentimen Pengguna Aplikasi BRIMO,” *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 1, pp. 855–862, 2025.
- [29] R. Wahyudi, Kurniawan, and Y. A. Wijaya, “Analisis Sentimen Pengguna Terhadap Aplikasi Blu BCA di Playstore Menggunakan Algoritma Naive Bayes (Studi Kasus Sentimen Pengguna Terhadap Pengalaman Aplikasi Blu BCA),” *J. Mhs. dan Tek. Inform.*, vol. 8, no. 3, pp. 2511–2517, 2024.
- [30] P. Setiyadi, M. N. Prayogi, and A. Solichin, “Optimalisasi Prediksi Kehilangan Karyawan Menggunakan Teknik RFE, Smote, dan Adaboost,” *J. Ilm. Penelit. Inform.*, vol. 9, no. 4, pp. 2131–2145, Dec. 2024, doi: 10.29100/jipi.v9i4.5642.