

Sentimen Pengguna Aplikasi BRImo: Kinerja Algoritma *Support Vector Machine, Naive Bayes, dan Adaboost*

Susandri¹, Yurnalis², Edwar Ali³, Susanti⁴, Asparizal⁵

¹STMIK Amik Riau, susandri@sar.ac.id, Jl. Purwodadi Indah Km 1 Panam, Pekanbaru, Indonesia

²STMIK Amik Riau, yurnalisnalis2001@gmail.com, Jl. Purwodadi Indah Km 1 Panam, Pekanbaru, Indonesia

³STMIK Amik Riau, edwarali@sar.ac.id, Jl. Purwodadi Indah Km 1 Panam, Pekanbaru, Indonesia

⁴STMIK Amik Riau, susanti@sar.ac.id, Jl. Purwodadi Indah Km 1 Panam, Pekanbaru, Indonesia

⁵Universitas Dumai, asparizal73@gmail.com, Jl. Natuna Rt. 05 Kel. Sukajadi, Dumai, Indonesia

Informasi Makalah

Submit : November 13, 2023

Revisi : Desember 8, 2023

Diterima : Desember 21, 2023

Kata Kunci :

BRImo
Support Vector Machine
Naive Bayes, Adaboost
Komparasi

Abstrak

Dalam konteks perkembangan industri perbankan yang semakin maju, pemanfaatan teknologi modern menjadi faktor kunci untuk meningkatkan kualitas layanan dan memenangkan persaingan di era digital. Bank Rakyat Indonesia (BRI) memikat perhatian masyarakat melalui peluncuran aplikasi perbankan seluler, BRImo. Namun Bank ini perlu meraih pandangan dan pengalaman nasabah terhadap aplikasi mobile banking untuk meningkatkan kualitas pelayanan. Penelitian ini memiliki tujuan untuk menganalisis ulasan pengguna BRImo sebagai objek penelitian. Komparasi dilakukan antara algoritma Support Vector Machine (SVM), Naive Bayes (NB), dan Adaboost dalam mengolah data teks. Evaluasi dilakukan berdasarkan tingkat akurasi, presisi, recall, dan nilai F1-score. Hasil penelitian menunjukkan bahwa algoritma SVM memberikan kinerja terbaik dalam mengklasifikasikan tanggapan masyarakat terhadap aplikasi BRImo, dengan tingkat akurasi sebesar 90,4%, presisi 90,8%, recall 90%, dan nilai F1-score 90,3%. Sebagai perbandingan, algoritma Adaboost memberikan nilai terendah dengan tingkat akurasi sebesar 87%, presisi 87,2%, recall 86,8%, dan nilai F1-score 86,9%.

Abstract

In the context of the advancing banking industry, the utilization of modern technology is a key factor in enhancing service quality and gaining a competitive edge in the digital era. Bank Rakyat Indonesia (BRI) captured public attention through the launch of its mobile banking application, BRImo. However, banks need to gain insights into customer perspectives and experiences with mobile banking applications to improve service quality. This study aims to analyze user reviews of BRImo as the research object. A comparison is made between the Support Vector Machine (SVM), Naive Bayes (NB), and AdaBoost algorithms in processing textual data. The evaluation was conducted based on accuracy, precision, recall, and F1-score. The research findings indicate that the SVM algorithm performs the best in classifying public responses to the BRImo application, achieving an accuracy rate of 90.4%, precision of 90.8%, recall of 90%, and F1-score of 90.3%. In comparison, the AdaBoost algorithm yielded the lowest values with an accuracy rate of 87%, precision of 87.2%, recall of 86.8%, and an F1-score of 86.9%.

1. Pendahuluan

Dalam konteks perkembangan teknologi yang pesat, evolusi yang signifikan terjadi di berbagai sektor untuk menjawab kebutuhan manusia. Secara khusus, sektor teknologi informasi menjadi pionir dalam menghadirkan inovasi baru (Puji Astuti et al., 2022). Adopsi teknologi informasi telah mengubah lanskap bisnis, termasuk sektor perbankan, dengan cepat mengintegrasikan solusi digital guna meningkatkan efisiensi dan kualitas layanan. Para peneliti menyoroti bahwa kemajuan ini mendorong perusahaan, khususnya di sektor perbankan, untuk meningkatkan kinerjanya dengan fokus pada pemudahan akses masyarakat terhadap layanan keuangan.

Mobile banking adalah fasilitas modern yang mengikuti perkembangan teknologi dan komunikasi. Layanan ini mencakup beragam fitur, termasuk pembayaran, transfer dana, serta akses riwayat transaksi, dan lain sebagainya. Fokus utama dari layanan ini adalah memberikan kemudahan akses kepada nasabah tanpa memerlukan kehadiran fisik di kantor bank (Puji Astuti et al., 2022). Implementasi teknologi mobile banking menjadi salah satu upaya strategis yang diadopsi oleh perusahaan perbankan dalam menghadapi era transformasi digital. Sistem mobile banking memungkinkan pelanggan untuk melakukan berbagai transaksi keuangan melalui perangkat mobile mereka, seperti ponsel pintar atau tablet. Dengan demikian, teknologi mobile banking tidak hanya memfasilitasi transaksi konvensional seperti transfer dana dan pembayaran tagihan, tetapi juga memberikan akses yang lebih luas kepada masyarakat terhadap produk dan layanan keuangan yang disesuaikan dengan kebutuhan individual.

Perusahaan-perusahaan perbankan kini menyediakan aplikasi mobile banking sebagai sarana interaksi dengan nasabahnya. (Alun Sujjadaa et al., 2023) (Puji Astuti et al., 2022). Dalam usaha

meningkatkan kualitas pelayanan, perusahaan perbankan perlu meraih pandangan dan pengalaman nasabah terhadap aplikasi mobile banking. Penelitian ini muncul sebagai respons terhadap kebutuhan untuk memahami secara mendalam interaksi nasabah dengan aplikasi tersebut, mengidentifikasi masalah yang mungkin timbul selama penggunaan, dan memberikan kontribusi pada upaya perusahaan perbankan dalam penyempurnaan dan peningkatan layanan.

Berbagai penelitian telah dilakukan dalam eksplorasi data komunikasi di platform aplikasi perbankan. (Solecha & Irnawati, 2023) mengusulkan metode klasifikasi yang membandingkan Algoritma NB berbasis Particle Swarm Optimization (PSO) yang telah dibuat dalam penelitian sebelumnya dengan Support Vector Machine (SVM) berbasis PSO, khususnya pada ulasan aplikasi Flip. (Alun Sujjadaa et al., 2023) mengevaluasi penilaian pengguna layanan Bank Digital (Bank Jago, Neobank, Seabank) di Google Play Store menggunakan metode SVM. Sedangkan (Ernianti Hasibuan & Elmo Allistair Heriyanto, 2022) melaksanakan penelitian analisis sentimen dengan pendekatan berbasis machine learning menggunakan algoritma NB, dengan fokus pada data ulasan pengguna pada aplikasi Amazon Shopping yang terdapat di Google Play Store. Penelitian sebelumnya juga melibatkan analisis sentimen pada platform Zoom Cloud Meetings dengan membandingkan algoritma NB dan SVM, dengan NB mencapai akurasi 74,37%, sedangkan SVM mencapai 81,22% (Herlinawati et al., 2020). Sedangkan (Puji Astuti et al., 2022) melakukan perbandingan algoritma SVM dan NB untuk analisis sentimen pada aplikasi BRImo, dengan hasil bahwa SVM memberikan kinerja lebih baik dengan akurasi yang lebih tinggi dibandingkan NB. Melalui literatur ini, penelitian-penelitian tersebut memberikan wawasan yang berharga terkait metode dan

pendekatan yang digunakan dalam menganalisis data komunikasi di berbagai aplikasi perbankan dan layanan digital.

Fokus utama penelitian ini adalah pada analisis ulasan aplikasi BRImo yang terdapat di platform Google Play Store sebagai objek penelitian. Sebaliknya, penelitian sebelumnya lebih memusatkan perhatian pada klasifikasi pemasaran langsung bank dengan membandingkan Adaboost dan Bagging menggunakan NB, yang menghasilkan tingkat akurasi tertinggi mencapai 90,29% (Rousyati et al., 2021). Penelitian ini sedikit berbeda dengan mengimplementasikan variasi dalam pemilihan algoritma dan menambahkan fitur pembobotan kata.

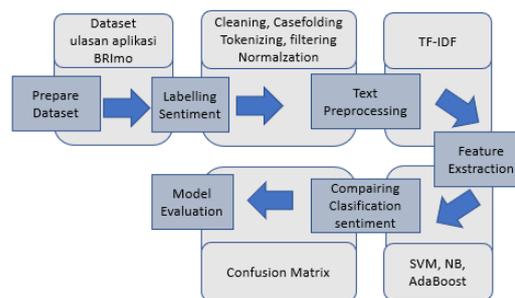
Penelitian ini akan menggunakan algoritma SVM, NB, dan Adaboost dengan tujuan untuk melakukan komparasi. Komparasi ini dilakukan untuk menentukan algoritma terbaik dalam konteks analisis sentimen publik terhadap aplikasi BRImo. Hasil komparasi akan diperoleh dalam bentuk nilai akurasi, presisi, recall, dan F1-score dengan penerapan pembobotan kata TF-IDF. Penelitian ini tidak hanya bertujuan untuk memperoleh pemahaman yang lebih baik terhadap aplikasi BRImo tetapi juga untuk memberikan dasar referensi untuk penelitian selanjutnya dalam domain serupa.

2. Metode Penelitian

Tahap perbandingan dan pengujian merupakan aspek kritis dalam penelitian ini, yang melibatkan serangkaian prosedur metodologis untuk mengukur kinerja model klasifikasi terhadap ulasan aplikasi BRImo. Proses pengumpulan data dilakukan dengan mengambil ulasan dari Google Play Store, dan dataset yang dihasilkan dilabeli berdasarkan sentimen. Langkah selanjutnya melibatkan tahap preprocessing data untuk membersihkan dan mengonversi data ke dalam format yang sesuai, termasuk ekstraksi fitur yang relevan Gambar 1.

Metode analisis yang digunakan mencakup penggunaan kerangka klasifikasi

algoritma Support Vector Machine (SVM), Naive Bayes (NB), dan Adaptive Boosting (AdaBoost). Gambar 1 secara rinci mendokumentasikan perbandingan dan evaluasi model, mencakup langkah-langkah utama dalam penelitian ini. Tahap pelabelan, prapemrosesan, dan ekstraksi fitur memainkan peran kunci dalam memastikan integritas data dan hasil analisis yang holistik.



Gambar 1. Tahapan Penelitian

Langkah-langkah ini diakhiri dengan tahap perbandingan hasil evaluasi kinerja model, yang menjadi puncak dari analisis ini. Evaluasi tersebut mencerminkan langkah integral dalam mengevaluasi kontribusi dan keunggulan masing-masing algoritma SVM, NB, dan AdaBoost. Hasil perbandingan ini tidak hanya memberikan wawasan tentang kinerja relatif dari masing-masing algoritma, tetapi juga mendukung kesimpulan penelitian terkait dengan aplikabilitas dan efektivitas model klasifikasi dalam konteks ulasan aplikasi BRImo. Dengan demikian, tahap penelitian ini bukan hanya menggambarkan pendekatan metodologis yang digunakan, tetapi juga menyajikan analisis mendalam terhadap hasil eksperimen dan interpretasinya yang bersifat komprehensif.

2.1. Dataset

Tahap pengumpulan data merupakan tahap awal yang krusial dalam penelitian ini, di mana teknik web scraping diterapkan dengan dukungan Jupyter Notebook untuk mendapatkan dataset komentar atau ulasan dari aplikasi BRImo di Google Play Store. Proses web scraping dilakukan dengan tujuan mengambil data yang relevan dari halaman web atau aplikasi Android dengan

identifikasi spesifik pada link aplikasi BRImo, yaitu "id.co.bri.brimo." Penggunaan teknik ini memungkinkan akses cepat dan otomatis terhadap ulasan pengguna yang tersebar di platform tersebut.

Implementasi teknik web scraping menggunakan Python di Jupyter Notebook, didukung oleh library pandas dan numpy, memastikan pengelolaan dan penyimpanan data yang efisien dalam format CSV. Dataset yang dihasilkan melibatkan pengumpulan 100.000 ulasan pengguna yang dikumpulkan dari tanggal 27 Februari 2019 hingga 27 Februari 2023. Tanggal-tanggal ini dipilih untuk memberikan representasi yang cukup luas terhadap perkembangan aplikasi dan respons pengguna selama periode waktu yang signifikan.

Hasil dataset dapat ditemukan pada Tabel 1, yang mencakup beragam atribut data seperti teks ulasan, sentimen yang diberikan, dan informasi lainnya yang relevan. Tabel tersebut memberikan gambaran awal tentang kompleksitas data yang dikumpulkan, yang kemudian menjadi subjek utama dalam proses analisis dan evaluasi model klasifikasi. Penggunaan teknik web scraping dalam tahap pengumpulan data ini memberikan fondasi yang kokoh untuk penelitian ini, memungkinkan analisis yang mendalam terhadap persepsi dan respons pengguna terhadap aplikasi BRImo dalam konteks ulasan mereka.

Tabel 1. Contoh Dataset

score	content
1	Makin lama makin ga beres ne apk...kerjanya ka...
4	Belum menemukan solusi yang tepat terkait akun...
1	Sudah di ulang beberapa x ...masih terus belum...
1	Tolonglah pihak BRI perbaiki layanannya, masa sa...
5	Terimakasih aplikasi nya sdh bisa digunakan lagi

2.2. Pelabelan data

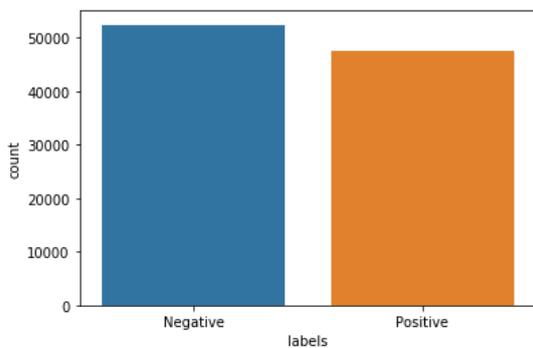
Setelah menyelesaikan proses pengambilan data menggunakan teknik web scraping, langkah selanjutnya yang kritis adalah melakukan pelabelan data berdasarkan kategorinya. Dataset yang terkumpul, berisi 100.000 ulasan pengguna aplikasi BRImo, akan dikelompokkan ke dalam dua kategori utama, yaitu positif dan negatif. Pengkategorian ini dilakukan dengan merujuk pada peringkat, skor, atau jumlah bintang yang diberikan oleh pengguna, sebagaimana terlihat dalam Tabel 2.

Tahap pelabelan data ini penting untuk memberikan dasar pada analisis sentimen yang akan dilakukan pada langkah-langkah berikutnya. Distribusi data pada tahap pelabelan menunjukkan bahwa dari total dataset, sebanyak 52,389 ulasan dikategorikan sebagai "Negative," sementara 47,611 ulasan dikategorikan sebagai "Positive." Distribusi ini memberikan pemahaman awal tentang kecenderungan sentimen pengguna terhadap aplikasi BRImo. Secara visual, distribusi ini dapat dilihat dalam Gambar 2.

Gambar 2 menyoroti prevalensi yang sedikit lebih tinggi pada data yang terlabel sebagai "Negative" dibandingkan dengan "Positive" dalam dataset. Kecenderungan ini memberikan informasi awal yang dapat menjadi dasar untuk analisis lebih lanjut terkait faktor-faktor yang mungkin memengaruhi persepsi negatif pengguna terhadap aplikasi BRImo. Langkah selanjutnya dalam penelitian ini akan berkaitan dengan penggunaan model klasifikasi untuk mengidentifikasi pola sentimen dan faktor-faktor determinan yang mempengaruhi pandangan positif atau negatif dari pengguna terhadap aplikasi tersebut.

Tabel 2. Distribusi Pelabelan Data

Kategori	Rating
<i>Positive</i>	4 dan 5
<i>Negative</i>	1,2 dan 3



Gambar 2. Hasil Pelabelan Dataset

2.3. Text Preprocessing

Proses preprocessing pada data setelah tahap pelabelan merupakan langkah krusial dalam persiapan data untuk analisis sentimen yang lebih mendalam. Langkah-langkah dalam proses ini mencakup serangkaian teknik yang bertujuan untuk meningkatkan kualitas dan konsistensi data. Pertama-tama, dilakukan pembersihan data dengan menghapus entri kosong yang mungkin ada setelah tahap pelabelan. Casefolding diterapkan untuk mengubah semua teks menjadi huruf kecil, memastikan konsistensi dalam representasi huruf sehingga analisis dapat dilakukan tanpa dipengaruhi oleh perbedaan huruf besar dan kecil (Hendriyadi et al., 2023)(Soumya & Pramod, 2022).

Langkah selanjutnya adalah tokenisasi, di mana teks dibagi menjadi token atau unit kata. Proses filtering kemudian dilakukan untuk menghapus kata-kata yang dianggap tidak signifikan dalam analisis sentimen. Normalisasi bahasa digunakan untuk memastikan bahwa kata-kata diwakili dalam bentuk bahasa baku, sehingga dapat meningkatkan konsistensi dan akurasi analisis (Hendriyadi et al., 2023)(Soumya & Pramod, 2022).

Proses preprocessing juga melibatkan penggunaan stemming untuk mengubah kata-

kata ke bentuk dasarnya dengan menghapus imbuhan. Ini bertujuan untuk mencapai konsistensi dan keseragaman dalam representasi kata-kata, mempermudah proses analisis selanjutnya (Tri Julianto et al., 2023)(Hendriyadi et al., 2023). Tahapan ini secara keseluruhan dirancang untuk membersihkan dan merapikan data, sehingga data yang dihasilkan siap untuk dilibatkan dalam analisis sentimen yang mendalam. Proses preprocessing ini menjadi landasan penting bagi analisis lanjut yang bertujuan untuk mengidentifikasi dan memahami pola sentimen dari ulasan pengguna aplikasi BRImo.

2.4. Feature Extraction

Feature extraction merupakan tahap kunci dalam analisis data di mana ciri atau fitur suatu bentuk diambil untuk diproses pada tahap berikutnya (Ramdani et al., 2022)(Gupta & Agrawal, 2020). Dalam konteks ini, Feature Extraction dilakukan melalui pembobotan kata menggunakan metode TF-IDF (Term Frequency-Inverse Document Frequency)(Aljuaid et al., 2021)(Pradipabista et al., 2021). Metode ini memberikan bobot pada setiap kata dalam dokumen berdasarkan frekuensinya dan keberartiannya relatif terhadap seluruh korpus (Hamzah, 2021)(Passi & Kalakala, 2023) (Chao et al., 2023). Hasil dari Feature Extraction ini memberikan representasi numerik informatif dari data teks, yang berguna untuk pelatihan dan pengujian algoritma (Tri Julianto et al., 2023).

3. Hasil dan Pembahasan

Pengujian algoritma merupakan tahap penting dalam penelitian ini, di mana setiap algoritma dievaluasi dengan menggunakan file terpisah, meskipun tetap melibatkan tahapan preprocessing dan feature extraction yang identik. Proses evaluasi ini dirancang untuk memahami kinerja masing-masing algoritma dalam konteks klasifikasi sentimen

terhadap ulasan pengguna aplikasi BRImo. Proses preprocessing dan feature extraction yang identik antara algoritma-algoritma tersebut memberikan dasar yang konsisten untuk perbandingan hasil.

Evaluasi dilakukan melalui empat jenis pembagian data yang terdokumentasi secara rinci pada Tabel 3. Pembagian data ini mencakup proporsi 50%:50%, 70%:30%, 80%:20%, dan 90%:10% untuk data train dan data test. Pembagian data yang bervariasi ini dirancang untuk memberikan wawasan yang komprehensif terhadap performa algoritma pada berbagai skenario, termasuk situasi dengan volume data train yang bervariasi. Rincian lengkap pembagian data, termasuk jumlah sampel pada setiap kategori sentimen, dapat ditemukan pada Tabel 3.

Proses evaluasi ini bukan hanya memberikan gambaran tentang performa relatif dari algoritma SVM, NB, dan AdaBoost, tetapi juga memberikan pemahaman yang mendalam tentang kecocokan model terhadap sejumlah besar data ulasan pengguna aplikasi BRImo. Dengan demikian, tahap pengujian algoritma ini bukan hanya merupakan langkah metodologis, tetapi juga bagian integral dari upaya untuk menganalisis dan memahami kemampuan algoritma klasifikasi sentimen dalam menghadapi variasi data dan skenario pembagian data yang berbeda.

Tabel 3. Pembagian Data

Splitting Data	Data Train	Data Test
50% : 50%	50.000	50.000
70% : 30%	70.000	30.000
80% : 20%	80.000	20.000
90% : 10%	90.000	10.000

Evaluasi model bertujuan mengukur dan memahami performa algoritma yang diimplementasikan. Serangkaian pengujian dilakukan untuk mencapai tujuan tersebut, dan hasilnya divisualisasikan dalam confusion matrix. Pengujian model klasifikasi menggunakan library Python,

yaitu sklearn.metrics, dengan fungsi confusion_matrix untuk menganalisis kinerja model. Visualisasi confusion matrix diwujudkan melalui library seaborn, pustaka visualisasi umum dalam analisis data Python. Penelitian ini menggunakan indikator kinerja berikut untuk mengevaluasi efektivitas algoritma yang dibandingkan:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

TP = True Positif, FN = False Negatif, TN = True Negatif, dan FP = False Positif.

Presisi: Proporsi sampel positif nyata yang secara akurat dikenali sebagai positif dari jumlah total sampel positif.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

Fraksi sampel positif yang dikenali secara akurat di antara seluruh sampel positif.

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

F1 Score: Ukuran lengkap keakuratan model yang dapat ditentukan sebagai rata-rata harmonik antara presisi dan perolehan.

$$F1 - score = \frac{2 * Precision * Recall}{Precision + Recall} \quad (4)$$

3.1 Hasil pengujian Algoritma SVM

Pengujian SVM dilakukan dengan cara mengevaluasi Algoritma SVM non-linear serta model SVM linear untuk mendapatkan hasil evaluasi yang komprehensif. Hasil pengujian ditampilkan pada Tabel 4 dan Tabel 5. Kedua tabel evaluasi model SVM non-linear dan SVM linear menunjukkan performa yang tinggi pada berbagai skenario pembagian data.

Algoritma SVM non-linear (Tabel 5), terlihat bahwa akurasi cenderung meningkat seiring dengan peningkatan proporsi data training, mencapai nilai tertinggi sebesar 90,4% pada pembagian data 80:20. Sementara itu, nilai presisi, recall, dan F1-

score juga menunjukkan konsistensi peningkatan, dengan hasil yang sangat baik di atas 90%.

Algoritma SVM linear (Tabel 4), terlihat bahwa akurasi juga meningkat dengan proporsi data training yang lebih besar, mencapai nilai tertinggi sebesar 90% pada pembagian data 70:30. Meskipun secara umum performanya sangat baik, terdapat sedikit variasi dalam hasil evaluasi antar skenario pembagian data. Nilai presisi, recall, dan F1-score juga menunjukkan kinerja yang konsisten, dengan nilai di atas 89%.

Tabel 4 Hasil evaluasi model SVM linear

Splitting Data	Confusion Matrix(%)			
	Acc	Prec	Recall	F1
50 : 50	89,4	89,9	89,1	89,5
70 : 30	90,0	90,0	89,2	89,5
80 : 20	89,7	90,1	89,4	89,7
90 : 10	89,7	90,1	89,4	89,7

Tabel 5 Hasil evaluasi model SVM nonlinear

Splitting Data	Confusion Matrix(%)			
	Acc	Prec	Recall	F1
50 : 50	89,9%	90,5%	89,7%	90%
70 : 30	90,2%	90,7%	89,8%	90,2%
80 : 20	90,4%	90,8%	90%	90,3%
90 : 10	90,3%	90,9%	90%	90,4%

Secara keseluruhan, hasil evaluasi algoritma SVM non-linear maupun SVM linear memiliki performa yang tinggi, dengan kecenderungan peningkatan performa pada skenario pembagian data yang lebih besar. Pemilihan Algoritma dapat bergantung pada kebutuhan spesifik analisis, dan hasil ini memberikan gambaran yang baik tentang kemampuan klasifikasi keduanya dalam konteks dataset dan skenario yang diuji.

3.2 Algoritma Naive Bayes

Pengujian NB dilakukan dengan cara mengevaluasi empat jenis algoritma NB, yaitu NB Multinomial, Bernoulli, Gaussian, dan Complement. Hasil terbaik didapatkan pada NB Complement yang ditampilkan pada Tabel 6.

Tabel 6 Hasil evaluasi algoritma Complement Naive Bayes

Splitting Data	Confusion Matrix (%)			
	Acc	Prec	Recall	F1
50 : 50	88,7	89,0	88,5	88,7
70 : 30	89,1	89,4	88,8	89,0
80 : 20	88,9	89,2	88,7	88,9
90 : 10	88,9	89,1	88,6	88,8

Tabel 6 menyajikan evaluasi kinerja model Complement NB pada berbagai pembagian data. Pada pembagian data 50:50, model mencapai akurasi 88,7%, dengan presisi 89%, recall 88,5%, dan nilai F1 88,7%. Terjadi peningkatan signifikan pada pembagian data 70:30, dengan akurasi 89,1%, serta presisi, recall, dan nilai F1 masing-masing mencapai 89,4%, 88,8%, dan 89%.

Hasil serupa terlihat pada pembagian data 80:20, di mana akurasi, presisi, recall, dan nilai F1 berturut-turut mencapai 88,9%, 89,2%, 88,7%, dan 88,9%. Dalam pembagian data 90:10, model mempertahankan performa optimal dengan akurasi 88,9%, serta presisi, recall, dan nilai F1 mencapai 89,1%, 88,6%, dan 88,8%.

Hasil pengujian ini menegaskan bahwa model Complement NB menunjukkan konsistensi dan kinerja memuaskan dalam berbagai kondisi pembagian data, tercermin dari capaian nilai tinggi pada metrik evaluasi akurasi, presisi, recall, dan F1-score.

3.3 Algoritma AdaBoost

Pengujian algoritma AdaBoost dilakukan dengan menggunakan modul AdaBoostClassifier dari pustaka scikit-learn untuk mengimplementasikan algoritma Adaboost, dengan penggunaan parameter inialisasi objek AdaBoostClassifier $n_estimators=100$. Parameter ini memegang peranan kunci dalam menentukan jumlah estimator atau model yang digunakan dalam pembentukan model Adaboost. Keputusan untuk menggunakan 100 estimator tersebut didasarkan pada pertimbangan untuk

mencapai keseimbangan antara kompleksitas model dan waktu komputasi yang diperlukan. Pengaturan ini dirancang untuk memberikan representasi yang memadai terhadap kompleksitas struktur sentimen pada ulasan pengguna aplikasi BRImo.

Hasil pengujian, yang mencakup metrik evaluasi seperti akurasi, presisi, recall, dan F1-score, ditampilkan dengan rinci pada Tabel 7. Tabel tersebut memberikan gambaran holistik tentang performa algoritma Adaboost dalam tugas klasifikasi sentimen. Melalui interpretasi hasil pada Tabel 7, peneliti dapat mendapatkan pemahaman yang lebih mendalam tentang sejauh mana Adaboost dapat mengenali dan mengklasifikasikan sentimen positif dan negatif dalam ulasan pengguna aplikasi BRImo.

Selain itu, analisis hasil pada Tabel 7 memungkinkan untuk identifikasi potensi peningkatan atau pengoptimalkan parameter Adaboost dalam konteks dataset yang digunakan. Proses evaluasi ini bukan hanya sebagai langkah akhir dalam pengujian algoritma, tetapi juga sebagai titik awal untuk pengambilan keputusan strategis terkait dengan peningkatan performa algoritma dan optimasi parameter di masa depan. Dengan demikian, hasil pengujian Adaboost pada Tabel 7 merupakan kontribusi penting dalam penilaian keseluruhan efektivitas algoritma klasifikasi sentimen pada ulasan pengguna aplikasi BRImo.

Tabel 7. Hasil evaluasi model adaboost

<i>Splitting Data</i>	<i>Confusion Matrix (%)</i>			
	<i>Acc</i>	<i>Prec</i>	<i>Recall</i>	<i>F1</i>
50 : 50	86,8	87,2	86,7	86,9
70 : 30	87,0	87,2	86,8	86,9
80 : 20	86,9	87,1	86,4	86,7
90 : 10	87,0	87,3	86,6	86,9

Evaluasi kinerja algoritma Adaboost pada berbagai skenario pembagian data menunjukkan gambaran performa klasifikasi (Tabel 7). Pada pembagian data 50:50, model

Adaboost mencapai akurasi 86,8%, presisi 87,2%, recall 86,7%, dan nilai F1 86,9%. Meskipun terdapat sedikit peningkatan pada pembagian data 70:30, dengan akurasi 87%, nilai presisi, recall, dan F1 stabil di sekitar 87,2%, 86,8%, dan 86,9%. Namun, performa model menurun pada pembagian data 80:20, dengan akurasi 86,9%, dan presisi, recall, serta nilai F1 berturut-turut sebesar 87,1%, 86,4%, dan 86,7%.

Pada pembagian data 90:10, model Adaboost tetap menunjukkan konsistensi dengan akurasi 87%, dan nilai presisi, recall, serta F1 masing-masing sebesar 87,3%, 86,6%, dan 86,9%. Hasil pengujian ini menyoroti konsistensi relatif baik pada performa model Adaboost, meskipun mengalami variasi kecil pada beberapa skenario pembagian data.

Algoritma SVM, NB, dan Adaboost dibandingkan untuk menentukan kinerja terbaik. Perbandingan dilakukan berdasarkan hasil evaluasi akurasi, presisi, recall, dan F1-score. Hasil evaluasi menjadi referensi untuk perbandingan algoritma pada penelitian selanjutnya dengan topik serupa. Rangkuman perbandingan evaluasi masing-masing algoritma tercantum pada Tabel 8.

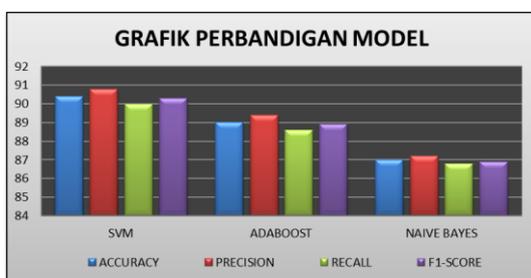
Tabel 8 Hasil perbandingan Algoritma SVM, NB, dan Adaboost

<i>Model</i>	<i>Confusion Matrix(%)</i>			
	<i>Acc</i>	<i>Prec</i>	<i>Recall</i>	<i>F1</i>
SVM	90,4	90,8	90,0	90,3
NB	89,0	89,4	88,6	88,9
Adaboost	87,0	87,2	86,8	86,9

Hasil perbandingan performa tiga algoritma klasifikasi, yaitu SVM, NB, dan Adaboost, dengan memperhitungkan metrik akurasi (Acc), presisi (Prec), recall, dan nilai F1 (Tabel 8). Algoritma SVM menonjol dengan pencapaian tertinggi, mencapai akurasi sebesar 90,4%, presisi 90,8%, recall 90%, dan nilai F1 90,3%. Sementara Algoritma NB menunjukkan performa yang baik dengan akurasi 89%, presisi 89,4%,

recall 88,6%, dan nilai F1 88,9%. Algoritma Adaboost menampilkan performa lebih rendah, tercatat dengan akurasi 87%, dan nilai presisi, recall, serta F1 masing-masing sebesar 87,2%, 86,8%, dan 86,9%.

Temuan ini menggambarkan superioritas model SVM dalam mengklasifikasikan data, diikuti oleh Naive Bayes dan Adaboost (Gambar 3). Hasil penelitian menunjukkan bahwa algoritma SVM mencapai kinerja tertinggi sedikit lebih baik dari hasil penelitian yang dilakukan (Herlinawati et al., 2020), (Puji Astuti et al., 2022) dan (Rousyati et al., 2021).



Gambar 3 Grafik perbandingan Algoritma

Variasi performa ini memberikan wawasan yang signifikan terkait kesesuaian model dengan karakteristik dataset, memberikan dasar penting untuk pemilihan model yang sesuai dengan kebutuhan analisis data.

4. Simpulan

Penelitian ini berhasil membandingkan algoritma SVM, Naive Bayes, dan Adaboost dalam menganalisis sentimen publik terhadap aplikasi BRImo menggunakan 100.000 sampel data. Hasil menunjukkan SVM memiliki akurasi tertinggi sebesar 90,4%, precision 90,8%, recall 90%, dan F1-score 90,3%, sedangkan Adaboost memiliki performa terendah dengan akurasi 87%, precision 87,2%, recall 86,8%, dan F1-score 86,9%. Penelitian ini menghasilkan model klasifikasi tanggapan masyarakat terhadap BRImo, dengan mayoritas tanggapan bersifat negatif.

5. Referensi

- Aljuaid, H., Iftikhar, R., Ahmad, S., Asif, M., & Tanvir Afzal, M. (2021). Important citation identification using sentiment analysis of in-text citations. *Telematics and Informatics*, 56, 101492. <https://doi.org/10.1016/j.tele.2020.101492>
- Alun Sujjadaa, Somantri, Juwita Nurfazri Novianti, & Indra Griha Tofik Isa. (2023). Analisis Sentimen Terhadap Review Bank Digital Pada Google Play Store Menggunakan Metode Support Vector Machine (Svm). *Jurnal Rekayasa Teknologi Nusa Putra*, 9(2), 122–135. <https://doi.org/10.52005/rekayasa.v9i2.345>
- Chao, G., Liu, J., Wang, M., & Chu, D. (2023). Data augmentation for sentiment classification with semantic preservation and diversity. *Knowledge-Based Systems*, 280, 111038. <https://doi.org/https://doi.org/10.1016/j.knsys.2023.111038>
- Ernianti Hasibuan, & Elmo Allistair Heriyanto. (2022). Analisis Sentimen Pada Ulasan Aplikasi Amazon Shopping Di Google Play Store Menggunakan Naive Bayes Classifier. *Jurnal Teknik Dan Science*, 1(3), 13–24. <https://doi.org/10.56127/jts.v1i3.434>
- Gupta, N., & Agrawal, R. (2020). Application and techniques of opinion mining. In *Hybrid Computational Intelligence*. INC. <https://doi.org/10.1016/b978-0-12-818699-2.00001-9>
- Hamzah, M. B. (2021). Classification of Movie Review Sentiment Analysis Using Chi-Square and Multinomial Naïve Bayes with Adaptive Boosting. *Journal of Advances in Information Systems and Technology*, 3(1), 67–74. <https://doi.org/10.15294/jaist.v3i1.49098>
- Hendriyadi, I., Putri, A. F., Rahmawati, R., & Saputra, D. D. (2023). Sentiment Analysis of Rising Fuel Prices on Social Media

- Twitter using the Naïve Algorithm Bayes Classifiers And AdaBoost. *Informatics and Software Engineering*, 1(1), 14–23. <https://doi.org/10.58777/ise.v1i1.55>
- Herlinawati, N., Yuliani, Y., Faizah, S., Gata, W., & Samudi, S. (2020). Analisis Sentimen Zoom Cloud Meetings di Play Store Menggunakan Naïve Bayes dan Support Vector Machine. *CESS (Journal of Computer Engineering, System and Science)*, 5(2), 293. <https://doi.org/10.24114/cess.v5i2.18186>
- Passi, K., & Kalakala, S. (2023). A Rule-Based Sentiment Analysis of WhatsApp Reviews in Telugu Language. In J. Choudrie, P. Mahalle, T. Perumal, & A. Joshi (Eds.), *IOT with Smart Systems* (pp. 167–180). Springer Nature Singapore.
- Pradipabista, B., Adipradana, R., Suryadi, R., & Suhartono, D. (2021). ScienceDirect ScienceDirect Hoax Analyzer for Indonesian News Using Deep Learning Models. *Procedia Computer Science*, 179(2020), 704–712. <https://doi.org/10.1016/j.procs.2021.01.059>
- Puji Astuti, A., Alam, S., & Jaelani, I. (2022). Komparasi Algoritma Support Vector Machine dengan Naive Bayes Untuk Analisis Sentimen Pada Aplikasi BRImo. *Jurnal Bangkit Indonesia*, 11(2), 1–6. <https://doi.org/10.52771/bangkitindonesia.v11i2.196>
- Ramdani, C. M. S., Rachman, A. N., & Setiawan, R. (2022). Comparison of the Multinomial Naive Bayes Algorithm and Decision Tree with the Application of AdaBoost in Sentiment Analysis Reviews PeduliLindungi Application. *International Journal of Information System & Technology Akreditasi*, 6(4), 419–430.
- Rousyati, R., Rais, A. N., Hasan, N., Amir, R. F., & Warjiyono, W. (2021). Komparasi Adaboost dan Bagging Dengan Naïve Bayes Pada Dataset Bank Direct Marketing. *Bianglala Informatika*, 9(1), 12–16. <https://doi.org/10.31294/bi.v9i1.9890>
- Solecha, K., & Irnawati, O. (2023). Komparasi Algoritma Support Vector Machine Dan Naïve Bayes Berbasis Particle Swarm Optimization Pada Analisis Sentimen Ulasan Aplikasi Flip. *JIEET (Journal of Information Engineering and Educational Technology)*, 07(1), 10–15.
- Soumya, S., & Pramod, K. V. (2022). Hybrid Deep Learning Approach for Sentiment Classification of Malayalam Tweets. *(IJACSA) International Journal of Advanced Computer Science and Applications*, 13(4), 891–899.
- Tri Julianto, I., Kurniadi, D., Septiana, Y., & Sutedi, A. (2023). Alternative Text Pre-Processing using Chat GPT Open AI. *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, 12(1), 67–77. <https://doi.org/10.23887/janapati.v12i1.59746>