

Comparison of Random Forest and Support Vector Machine Methods in Sentiment Analysis of Student Satisfaction Questionnaire Comments at ITB STIKOM Bali

Purnama Sidik^{1*}, I Made Gede Sunarya^{2**}, I Gede Aris Gunadi^{3**}

* Postgraduate Programs, Computer Science Study Program, Universitas Pendidikan Ganesha

** Postgraduate Programs, Computer Science Study Program, Universitas Pendidikan Ganesha
purnama.sidik@undiksha.ac.id¹, sunarya@undiksha.ac.id², igedearisgunadi@undiksha.ac.id³

Article Info

Article history:

Received 2025-05-06

Revised 2025-06-03

Accepted 2025-06-05

Keyword:

Classification,
Sentiment Analysis,
Random Forest,
Support Vector Machine,
SMOTE.

ABSTRACT

ITB STIKOM Bali is one of the higher education institutions in Bali that focuses on academic activities, particularly in the field of Information Technology. To maintain its educational quality, the Quality Assurance Department collaborates with the Center for Information and Communication (Puskom) to distribute a student satisfaction questionnaire at the end of each semester. In evaluating student satisfaction with campus facilities, the comment section is one of the key indicators, featuring the question: "Based on your experience, please describe which AAK services you found disappointing and in need of improvement." This study compares the performance of the Random Forest and Support Vector Machine (SVM) methods in conducting sentiment analysis on historical student satisfaction comments. The research involved several stages, including literature review, data collection, preprocessing, transformation, data mining, evaluation, and visualization. The results demonstrate strong accuracy, precision, recall, and F1-scores for both methods using an 80:20 data split. Before applying the SMOTE technique, the best result was achieved by the Support Vector Machine method with a score of 0.90, while the Random Forest method yielded an accuracy of 0.81, precision of 0.85, recall of 0.81, and F1-score of 0.76. After applying SMOTE, both methods achieved an improved and equal score of 0.90. The study also produced an excellent classification result based on the ROC curve. It is expected that this research can serve as an additional reference for the assessment of student satisfaction at ITB STIKOM Bali at the end of each academic semester.



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

I. PENDAHULUAN

ITB STIKOM Bali merupakan salah satu perguruan tinggi swasta di Bali yang dimana perguruan tinggi ini berfokus pada teknologi informasi (TI). Penerapan TI dalam sebuah institusi pendidikan sangatlah penting dalam menunjang efektivitas pelayanan dan pembelajaran sehingga sangat dibutuhkan pengetahuan serta sumber daya yang efisien dan terlatih dibidangnya. Pemanfaatan TI merupakan salah satu faktor pendukung pelaksanaan rencana strategis di perguruan tinggi dimana pengelolaan sistem informasi secara efektif dapat menjadi dasar keunggulan kompetitif. Banyak perguruan tinggi yang mengembangkan dan memberikan

perhatian khusus pada sistem informasi sebagai sumber yang memfasilitasi penggunaan informasi secara efektif [1].

Dalam melakukan evaluasi terhadap ITB STIKOM Bali terutama dibagian fasilitas yang ada di ITB STIKOM Bali, divisi Pusat Pengembangan Sistem Informasi (PSI) bekerja sama dengan divisi Pusat Jaminan Mutu (PJM) melakukan evaluasi kepuasan mahasiswa dengan cara menyebarkan Kuesioner Kepuasan Mahasiswa (KKM) yang dilakukan setiap akhir semester tepatnya sebelum melakukan ujian akhir semester (UAS). Penyebaran Kuesioner Kepuasan Mahasiswa (KKM) ini dilakukan secara daring yang mana kuesioner ini ditampilkan pada Sistem Informasi Online (SION) ITB STIKOM Bali dan akan terus aktif selama

mahasiswa belum mengisi kuesioner atau masih dalam jangka waktu penyebaran kuesioner.

Kuesioner Kepuasan Mahasiswa (KKM) ini sudah dilakukan secara rutin kepada mahasiswa dimulai sejak tahun 2017 dan masih berlanjut secara berkala sampai sekarang dalam penyebaran rutin kuesioner. Adapun kuesioner ini memiliki 7 penilaian, diantaranya 5 berupa variabel numerik, 2 berupa variabel komentar. lima variabel itu dibagi menjadi variabel *reliability* (keandalan), variabel *responsiveness* (daya tanggap), variabel *assurance* (kepastian), variabel *empathy* (empati), dan variabel *tangible* (bukti langsung) [2]. Sedangkan dua variabel komentar meliputi komentar tanggapan dan komentar harapan.

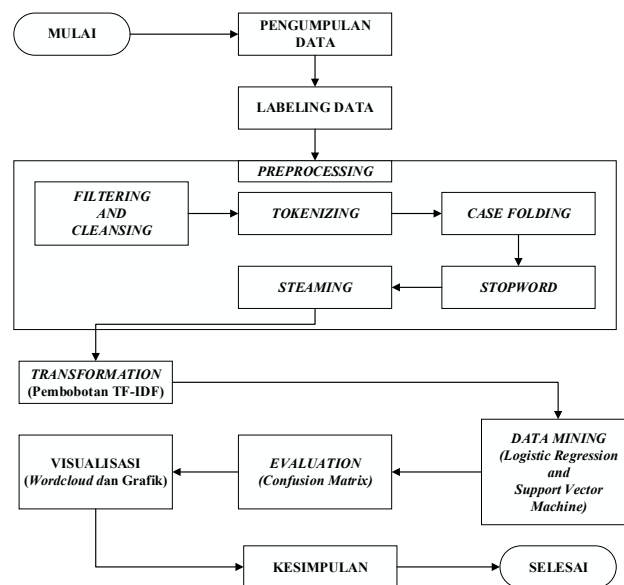
Berdasarkan penelitian terdahulu yang ditulis oleh Putri Kumala Sari dan Ryan Randy Suryono [3], Penelitian tersebut dilakukan untuk menilai sentimen masyarakat terhadap teknologi *metaverse* dengan menggunakan algoritma *support vector machine* dan *random forest* dengan bantuan optimasi *SMOTE* agar mendapatkan kinerja yang optimal dari kedua algoritma. Hasil yang didapat dari penelitian tersebut adalah dengan *accuracy* dari *Random Forest accuracy* sebesar 0.91, *precision* 0.92, *recall* 0.97 dan *f1-score* 0.95. Sedangkan untuk *Support Vector Machine accuracy* sebesar 0.90, *precision* 0.94, *recall* 0.95 dan *f1-score* 0.94.

Peneliti menggunakan metode *random forest* dan *support vector machine* sebagai metode untuk dikomparasi dikarenakan *random forest* dan *support vector machine* mampu menilai data yang berskala kecil hingga menengah dan juga peneliti ingin menilai bagaimana hasil dari *accuracy*, *recall*, *precision* dan *f1-score* dari kedua metode ini yang memiliki cara kerja berbeda dalam melakukan sentimen analisis.

Analisis sentimen merupakan kegiatan yang dilakukan untuk mengekstrak serta mempelajari data teks yang ada dalam penelitian yang berupa opini atau pendapat yang mengungkapkan persepsi serta mengandung sentimen terhadap sebuah topik bahasan seperti kejadian, tren, dan kebijakan [4] [5]. Analisis sentimen ditujukan untuk menilai suatu sentimen apakah dia berupa sentimen *positive* dan *negative* berdasarkan teks [6]. Penilaian sentimen dilakukan bertujuan untuk mendapatkan wawasan mengenai pandangan mahasiswa terhadap ITB STIKOM Bali melalui Kuesioner Kepuasan Mahasiswa (KKM), sehingga dapat diidentifikasi hal yang perlu diperbaiki dan dievaluasi [7].

II. METODE

Knowledge Discovery in Database (KDD) merupakan metode *data mining* yang digunakan untuk mencari informasi berharga dengan pola yang ada di dalam data, serta melibatkan algoritma untuk mengidentifikasi pola pada data tersebut [8]. Pada Gambar 1 adalah beberapa tahapan yang harus dilewati dalam penggunaan metode KDD [9].



Gambar 1. Alur Penelitian

A. Pengumpulan Data

Data yang digunakan dalam penelitian merupakan data riwayat komentar terhadap kepuasan mahasiswa pada layanan akademik dan fasilitas ITB STIKOM Bali. Data diambil dari database ITB STIKOM Bali dengan rentang waktu 2017-2023 dan memiliki minimal huruf dalam setiap komentar melebihi 50 huruf.

B. Labeling Data

Dalam penelitian ini, data riwayat komentar akan diberi label sentimen secara manual atau dilakukan oleh manusia yang adalah peneliti itu sendiri dengan membaca satu persatu komentar. Labeling manual yang dilakukan bernilai *positive* atau *negative*. Setelah melakukan labeling data secara manual, peneliti melakukan validasi terhadap sentimen kepada ahli psikologi dan ahli Bahasa Indonesia.

C. Machine Learning

Machine Learning merupakan kegiatan mesin mempelajari pola terhadap data dengan pendekatan sistematis. Inti dari *machine learning* adalah untuk membuat model sistematis yang merefleksikan pola-pola data. Biasanya menggunakan statistika atau aljabar *linear* [10]. Pada prosesnya, *machine learning* akan mengambil informasi yang berguna dengan cara menganalisis pola-pola ataupun hubungan keterkaitan tertentu dari data yang berukuran besar [11].

D. Preprocessing

Preprocessing adalah kegiatan dan langkah penting dalam melakukan *text mining*. Di bidang *text mining*, data *preprocessing* digunakan untuk mengekstraksi pengetahuan yang menarik dan penting serta dari data teks yang tidak terstruktur [12]. *Preprocessing* dilakukan sebelum masuk kedalam tahap *transformation* agar mempersiapkan dokumen dalam bentuk teks mentah hingga menjadi siap untuk

dilakukan analisis teks sesuai dengan metode yang digunakan [13]. *Preprocessing* juga menjadi sangat terkendala ketika *data training* yang digunakan relatif buruk, sehingga diperlukan *preprocessing* sebelum masuk kedalam tahap klasifikasi [14]. Terdapat 5 tahapan yang dilakukan selama *preprocessing* yaitu *filtering and cleansing*, *case folding*, *tokenizing*, *stopword* dan *stemming*. Setelah seluruh data sudah dilabeli dan tahap *preprocessing* selesai, maka dilakukan pemisahan menjadi data training dan data testing [15].

E. Transformation

Pada tahap ini, teks yang sudah di transformasi akan dikonversi ke angka menggunakan TF-IDF. TF-IDF adalah salah satu metrik terbaik untuk menentukan seberapa signifikan suatu istilah terhadap teks dalam rangkaian atau *corpus* [16]. Sistem pembobotan TF-IDF berdasarkan frekuensi *term* (TF) dan frekuensi resiprokal dokumen (TF-IDF) memberikan bobot pada setiap kata dalam dokumen [17]. TF-IDF dilakukan dengan menggunakan rumus 1,2 dan 3.

$$TF_{t,d} = \frac{f_{t,d}}{\text{Jumlah kata pada } d} \quad (1)$$

$$idf(t) = \log\left(\frac{\text{Total Dokumen}}{\text{Jumlah Kata Yang Muncul}}\right) \quad (2)$$

$$TF - IDF_{(i,j,k)} = TF_{ij} \times IDF_i \quad (3)$$

Keterangan:

$TF_{t,d}$ = Menghitung jumlah kata yang muncul dalam satu dokumen.

$idf(t)$ = Menghitung berapa banyak kata yang muncul pada dokumen.

$TF - IDF_{(i,j,k)}$ = Menghitung setiap kata yang muncul pada dokumen.

F. K-Fold Cross Validation

Cross Validation merupakan salah satu metode dalam melakukan validasi model. Teknik ini akan menguji keefektifan dari model yang dibentuk dengan melakukan penyusunan ulang (*resampling*) pada data untuk membaginya menjadi 2 bagian yaitu data *training* dan data *testing*. Data *training* digunakan untuk melatih model sehingga model dapat memahami pola pada data dan data testing digunakan untuk validasi terhadap latihan model tersebut [18].

Nilai *K* dibebaskan kepada peneliti, tetapi disarankan tidak terlalu besar dan tidak terlalu kecil. Nilai *K* yang biasa digunakan adalah $K=5$ atau $K=10$ [19].

G. SMOTE

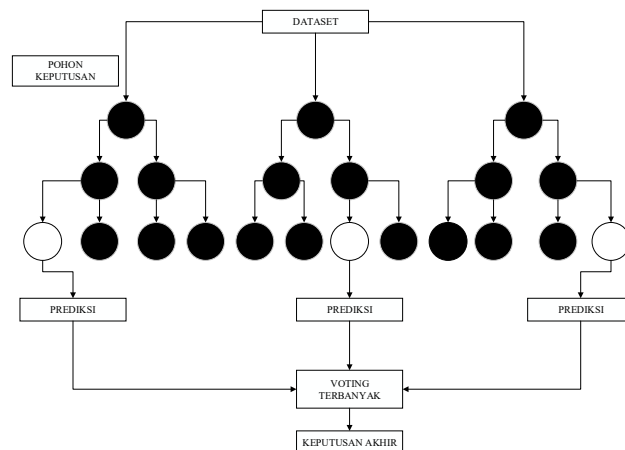
Pada tahap ini, sebelum melakukan evaluasi data setelah melakukan transformasi data, data akan diseimbangkan terlebih dahulu menggunakan metode SMOTE. *SMOTE* (*Synthetic Minority Oversampling Technique*) merupakan salah satu metode *oversampling* yang untuk mengatasi

permasalahan ketidakseimbangan distribusi data pada pemodelan *machine learning*. *SMOTE* bertujuan untuk menyeimbangkan distribusi kelas dengan meningkatkan jumlah kelas minoritas secara acak dengan cara membuat data sintesis untuk tujuan *oversampling* [20].

H. Random Forest

Random Forest adalah salah satu metode *machine learning* yang digunakan untuk klasifikasi model prediksi berdasarkan banyaknya pohon keputusan. Model *random forest* memiliki tujuan untuk membangun pohon keputusan yang terdiri dari simul-simul akar yang merupakan akar dari pohon keputusan [21].

Random Forest dibuat dengan memilih atribut secara acak dan menerapkan metode CART. Metode CART merupakan salah satu metode yang digunakan untuk melakukan pembuatan pohon-pohon keputusan atau *decision tree*, selanjutnya pohon-pohon keputusan akan dikumpulkan menjadi satu menggunakan *bootstrap aggregating* (*bagging*) sehingga terbentuklah *forest* [22]. Model *random forest* dapat dipresentasikan seperti pada Gambar 2.



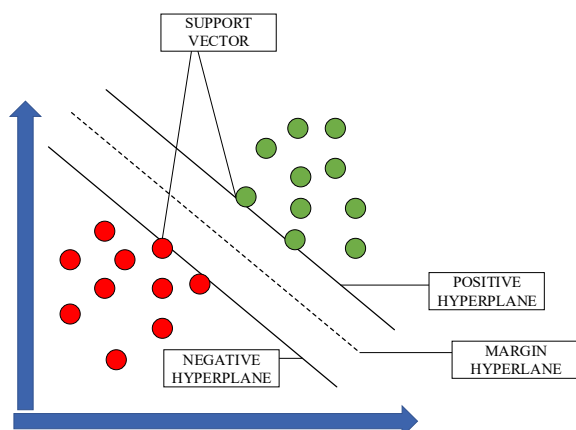
Gambar 2. Representasi *Random Forest*

I. Support Vector Machine

SVM atau *Support Vector Machine* adalah algoritma *machine learning* yang menerapkan fungsi *hyperplane* pada data sehingga terbentuk daerah-daerah tiap kelas. *Hyperplane* merupakan fungsi yang digunakan sebagai pemisah antara kelas yang ada [23]. Dalam memprediksi suatu kelas pada data, SVM akan memberikan nilai berdasarkan daerah kelas mana yang merupakan tempat dari data tersebut. SVM biasanya digunakan pada dataset besar yang diambil dari situs online dan menjadi populer karena penerapannya dalam klasifikasi teks [24].

Didalam metode SVM, terdapat 3 kernel yang bisa digunakan dalam melakukan klasifikasi yaitu kernel linier, polynominal, Radial Basic Function (RBF) [25]. Didalam penelitian ini, linear dan RBF kernel akan digunakan untuk melakukan perhitungan dalam penelitian sentimen analisis

ini. Model *support vector machine* dapat dipresentasikan seperti pada Gambar 3.



Gambar 3. Representasi *Support Vector Machine*

J. Evaluasi Model

Pada tahap ini, data yang telah di klasifikasi oleh kedua metode tersebut akan di evaluasi menggunakan *confusion matrix*. *Confusion Matrix* merupakan metode yang digunakan untuk mengukur kinerja sebuah metode klasifikasi *machine learning* dimana memiliki sentimen 2 kelas atau lebih [26] [27]. Nilai dari *Confusion Matrix* tersebut nantinya akan digunakan untuk menghitung *accuracy*, *precision*, *recall* dan *f1-Score* sebagai hasil nilai evaluasi dari suatu model dengan rumus 4, 5, 6 dan 7 [28].

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+FN+TN} \quad (4)$$

$$\text{Precision} = \frac{TP}{TP+FN} \quad (5)$$

$$\text{Recall} = \frac{TP}{TP+FP} \quad (6)$$

$$f1 - \text{Score} = 2 \times \frac{\text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (7)$$

K. Visualisasi Data

Setelah melakukan evaluasi data, hasil dari evaluasi data akan di presentasikan kedalam 2 visualisasi yaitu *wordcloud* dan kurva ROC. *Wordcloud* merupakan visualiasi data yang menampilkan kata-kata yang paling sering muncul dalam proses evaluasi [29]. Sedangkan kurva ROC merupakan alat ukur perfomansi yang nilainya berasal dari hasil perhitungan *confusion matrix* [30]. Adapun tingkatan nilai yang digunakan kurva ROC dalam menentukan tingkat klasifikasi [31].

- Akurasi bernilai 0,90 – 1,00 = *excellent classification*
- Akurasi bernilai 0,80 – 0,90 = *good classification*
- Akurasi bernilai 0,70 – 0,80 = *fair classification*
- Akurasi bernilai 0,60 – 0,70 = *poor classification*
- Akurasi bernilai 0,50 – 0,60 = *failure*

III. HASIL DAN PEMBAHASAN

A. Pengumpulan Data

Pengumpulan data dilakukan dengan mengambil data pada *database* dari ITB STIKOM Bali dengan mengambil data riwayat komentar sejumlah 2000 data untuk dijadikan dataset. Pada Tabel 1 adalah contoh pengumpulan data riwayat komentar yang dikumpulkan pada *file excel*.

TABEL I
PENGUMPULAN DATA

No	Komentar
1	Pelayanan senyum salam sapa masih harus diperbaiki demi kenyamanan mahasiswa
2	Meja banyak rusak, beberapa AC dikelas tidak berfungsi

B. Labeling Data

Setelah melakukan proses pengumpulan data, peneliti melakukan pelabelan komentar secara *manual* atau proses yang dilakukan oleh manusia dengan membaca satu persatu komentar. Setelah melakukan pelabelan *manual*, peneliti melakukan validasi label kepada ahli dari psikologi dan ahli Bahasa Indonesia. Didapatkan jumlah sentimen *positive* sebesar 1500 dan sentimen *negative* sebesar 500 Pada Tabel 2 adalah contoh dari komentar yang telah di labeli.

TABEL II
LABELING DATA

No	Komentar	Label
1	Pelayanan senyum salam sapa masih harus diperbaiki demi kenyamanan mahasiswa	<i>Positive</i>
2	Meja banyak rusak, beberapa AC dikelas tidak berfungsi	<i>Negative</i>

C. Preprocessing

Setelah melakukan labelling data, dilanjutkan proses preprocessing yang bertujuan untuk mendapatkan kata dasar dari sebuah kata. Pada Tabel 3 adalah contoh dari *preprocessing*

TABEL III
PREPROCESSING

No	Tahap	Komentar
1	Filtering And Cleasing	Pelayanan senyum salam sapa masih harus diperbaiki demi kenyamanan mahasiswa
		Meja banyak rusak, beberapa AC dikelas tidak berfungsi
2	Case Folding	pelayanan senyum salam sapa masih harus diperbaiki demi kenyamanan mahasiswa
		meja banyak rusak, beberapa ac dikelas tidak berfungsi
3	Tokenizing	“pelayanan” “senyum” “salam” “sapa” “masih” “harus” “diperbaiki” “demi” “kenyamanan” “mahasiswa”
		“meja” “banyak” “rusak” “beberapa” “ac” “dikelas” “tidak” “berfungsi”
4	Stopword	“pelayanan” “senyum” “salam” “sapa” “diperbaiki” “kenyamanan” “mahasiswa”

No	Tahap	Komentar
5	Stemming	“meja” “banyak” “rusak” “ac” “dikelas” “tidak” “berfungsi”
		“layan” “senyum” “salam” “sapa” “perbaiki” “nyaman” “mahasiswa”
		“meja” “banyak” “rusak” “ac” “kelas” “tidak” “fungsi”

Pada tahap ini, data riwayat komentar yang telah dilabeli *positive* dan *negative* akan melewati proses *preprocessing*. Terdapat 5 tahapan yang dilakukan dalam *preprocessing*.

- 1) *Filtering and cleansing*
- 2) Pada proses ini, komentar akan dibersihkan dari kata-kata tidak penting dan menghapus kata duplikat yang bermakna sama serta penghapusan karakter-karakter yang bukan huruf seperti angka, simbol, url, dan lainnya.
- 3) *Case folding*
- 4) Pada proses ini, kata-kata yang sudah melalui tahap *filtering and cleansing* akan diubah seluruh huruf nya menjadi kecil.
- 5) *Tokenizing*
- 6) Pada proses ini, data komentar akan dipisahkan menjadi kata perkata untuk memetakan setiap kata yang ada pada satu kalimat komentar.
- 7) *Stopword*
- 8) Pada proses ini, kata yang sering muncul yang mana dirasa tidak penting seperti kata *hubung* atau *waktu*
- 9) *Stemming*
- 10) Pada proses ini, proses yang bertujuan untuk menghapus imbuhan pada setiap kata atau mengubah setiap kata menjadi kata dasarnya. Serta memperbaiki suatu kata dengan ejaan yang salah.

D. Transformation

Setelah melakukan proses *preprocessing*, dilakukan tahap *transformation* dengan menggunakan pembobotan TF-IDF. Pada Tabel 4 adalah contoh dari hasil kata yang dikonversi menjadi angka.

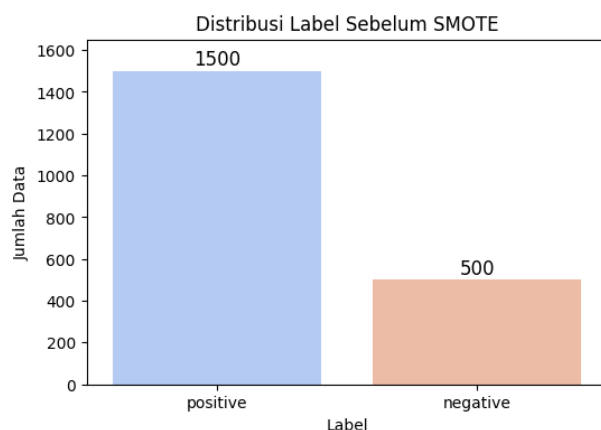
TABEL IV
TRANSFORMATION

Kata	Dokumen 1	Dokumen 2
layan	0.086	0
senyum	0.086	0
salam	0.086	0
sapa	0.086	0
perbaiki	0.086	0
nyaman	0.086	0
mahasiswa	0.086	0
meja	0	0.086
banyak	0	0.086
rusak	0	0.086
ac	0	0.086
kelas	0	0.086
tidak	0	0.086
fungsi	0	0.086

Pada Tabel 4, kata-kata yang digunakan dalam data riwayat komentar telah melewati proses *preprocessing* dan melalui tahap *transformation*. Dalam melakukan *transformation*, peneliti memilih TF-IDF sebagai alat bantu untuk mengkonversi kata menjadi angka. Tujuan dari TF-IDF ini agar mengetahui bobot dari setiap kata setelah melihat berapa banyak kata yang muncul di dokumen.


E. SMOTE

Setelah melakukan tahap *transformation*, dilakukan penyeimbangan *dataset* terlebih dahulu, dikarenakan mencegah terjadinya *overfitting* pada proses evaluasi model. Pada Gambar 4 dan Gambar 5 merupakan hasil dari penerapan metode SMOTE untuk penyeimbangan data.



Gambar 4. Distribusi label sebelum SMOTE

Gambar 4 menunjukkan bahwa label untuk sentimen *positive* memiliki jumlah komentar senilai 1500 data sedangkan untuk sentimen *negative* memiliki jumlah 500 data.




Gambar 5. Distribusi label setelah SMOTE

Gambar 5 menunjukkan bahwa label untuk sentimen *positive* memiliki jumlah komentar senilai 1200 data sedangkan untuk sentimen *negative* memiliki jumlah 1200 data. Data sentimen *positive* dan *negative* mengalami penyeimbangan data pada nilai 1200 dikarenakan data

minoritas melakukan sintesis data agar menyeimbangkan label dengan data mayoritas. Proses sintesis dilakukan setelah dilakukan proses *train-test split* sebelum evaluasi model pada perbandingan 80:20


F. Evaluasi Model

Setelah melakukan penyeimbangan data, dilakukan evaluasi model dengan perbandingan 80:20 meliputi hasil *confusion matrix*, *accuracy*, *precision*, *recall* dan *f1-score*, *wordcloud* dan kurva ROC.



Gambar 6. Confusion Matrix Random Forest

Hasil pada Gambar 6 menunjukkan jika *confusion matrix* yang dianalisa menggunakan perbandingan 80:20 dengan metode *random forest*. Didapatkan bahwa model mampu memprediksi *positive* dengan realita *positive* atau TP (*True Positive*) bernilai 218. Selanjutnya, model memprediksi *negative* tetapi seharusnya *positive* atau FN (*False Negative*) bernilai 19. Selanjutnya, model memprediksi *negative* tetapi seharusnya *positive* atau FP (*False Positive*) bernilai 22 sedangkan model memprediksi *negative* dengan realita *negative* atau TN (*True Negative*) bernilai 78.



Gambar 7. Confusion Matrix SVM

Hasil pada Gambar 7 menunjukkan jika *confusion matrix* yang dianalisa menggunakan perbandingan 80:20 dengan metode *Support Vector Machine*. Didapatkan bahwa model mampu memprediksi *positive* dengan realita *positive* atau TP (*True Positive*) bernilai 269. Selanjutnya, model memprediksi *negative* tetapi seharusnya *positive* atau FN (*False Negative*) bernilai 31. Selanjutnya, model memprediksi *negative* tetapi seharusnya *positive* atau FP (*False Positive*) bernilai 10 sedangkan model memprediksi *negative* dengan realita *negative* atau TN (*True Negative*) bernilai 90.

TABEL V
SEBELUM SMOTE

Metode		Hasil			
		Accuracy	Precision	Recall	F1-Score
Random Forest	Sebelum SMOTE	0.81	0.85	0.81	0.76
	Setelah SMOTE	0.90	0.90	0.90	0.90

Berdasarkan Tabel 5 diatas, metode *random forest* melakukan klasifikasi terhadap data *training* dan data *test* dengan perbandingan 80:20 menghasilkan 2 hasil yang cukup berbeda antara sebelum SMOTE dan sesudah SMOTE, pada hasil sebelum SMOTE, hasil *accuracy* sebesar 0.81, *precision* sebesar 0.85, *recall* sebesar 0.81 dan *f1-score* sebesar 0.76. sedangkan setelah SMOTE, hasil *accuracy* sebesar 0.90, *precision* sebesar 0.90, *recall* sebesar 0.90 dan *f1-score* sebesar 0.90. Dengan hasil tersebut menunjukkan bahwa *random forest* sebelum dilakukan penyeimbangan data dengan metode SMOTE, mengalami *overfitting* dikarenakan metode *random forest* memilih label mayoritas daripada label minoritas. Setelah melakukan penyeimbangan data dengan metode SMOTE, *random forest* mampu mempelajari data lebih baik sehingga tidak terjadinya *overfitting* dan meningkatkan hasil dari klasifikasi.

TABEL VI
SEBELUM SMOTE 5-FOLD CROSS VALIDATION RANDOM FOREST

Fold	Accuracy	Precision	Recall	F1-Score
1	0.92	0.92	0.92	0.91
2	0.92	0.92	0.92	0.92
3	0.89	0.89	0.89	0.89
4	0.89	0.89	0.89	0.89
5	0.93	0.93	0.93	0.93
Rata-Rata	0.91	0.91	0.91	0.91

Berdasarkan hasil evaluasi menggunakan *5-fold cross-validation* pada data Tabel 6, model menunjukkan rata-rata *accuracy* sebesar 0.91. Hasil menunjukkan stabilitas yang baik di seluruh fold. Evaluasi lebih lanjut mengungkapkan bahwa *precision*, *recall*, dan *F1-score* semuanya memiliki

nilai rata-rata yang sama, yaitu 0.91, dengan performa tertinggi tercatat pada fold ke-5 untuk accuracy sebesar 0.93.

Secara keseluruhan, hasil ini mengindikasikan bahwa model dapat mengklasifikasikan data dengan baik, meskipun masih ada sedikit penurunan performa pada *fold* ke-3 dan *fold* ke-4 dengan *accuracy* 0.89.

TABEL VII

SETELAH SMOTE 5-FOLD CROSS VALIDATION RANDOM FOREST

<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	0.95	0.95	0.95	0.95
2	0.94	0.94	0.94	0.94
3	0.94	0.94	0.94	0.94
4	0.94	0.94	0.94	0.94
5	0.97	0.97	0.97	0.97
Rata–Rata	0.95	0.95	0.95	0.95

Berdasarkan hasil evaluasi menggunakan *5-fold cross-validation* pada data Tabel 7, model menunjukkan rata-rata *accuracy* sebesar 0.95. Hasil menunjukkan stabilitas yang baik di seluruh fold. Evaluasi lebih lanjut mengungkapkan bahwa *precision*, *recall*, dan *F1-score* semuanya memiliki nilai rata-rata yang sama, yaitu 0.95, dengan performa tertinggi tercatat pada fold ke-5 untuk *accuracy* sebesar 0.97.

Secara keseluruhan, hasil ini mengindikasikan bahwa model dapat mengklasifikasikan data dengan baik, meskipun masih ada sedikit penurunan performa pada *fold* ke-2, *fold* ke-3 dan *fold* ke-4 dengan *accuracy* 0.94.

TABEL VIII
SETELAH SMOTE

Metode		Hasil			
		<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Support Vector Machine	Sebelum SMOTE	0.90	0.90	0.90	0.90
	Setelah SMOTE	0.90	0.90	0.90	0.90

Berdasarkan Tabel 8 diatas, metode *support vector machine* melakukan klasifikasi terhadap data *training* dan data *test* dengan perbandingan 80:20 menghasilkan *accuracy* sebesar 0.90, *precision* sebesar 0.90, *recall* sebesar 0.90 dan *f1-score* sebesar 0.90. Dengan hasil tersebut menunjukkan bahwa *support vector machine* mampu melakukan klasifikasi dan mempertahankan performa pada data prediksi yang belum dilihat sebelumnya serta tidak mengalami *overfitting* serta tidak ada perubahan walaupun melewati proses sintesis data dengan metode SMOTE.

TABEL IX

SETELAH SMOTE 5-FOLD CROSS VALIDATION SVM

<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	0.92	0.92	0.92	0.91
2	0.92	0.92	0.92	0.92
3	0.89	0.89	0.89	0.89
4	0.89	0.89	0.89	0.89
5	0.93	0.93	0.93	0.93
Rata–Rata	0.91	0.91	0.91	0.91

Berdasarkan hasil evaluasi menggunakan *5-fold cross-validation* pada data Tabel 9, model menunjukkan rata-rata *accuracy* sebesar 0.91. Hasil menunjukkan stabilitas yang baik di seluruh fold. Evaluasi lebih lanjut mengungkapkan bahwa *precision*, *recall*, dan *F1-score* semuanya memiliki nilai rata-rata yang sama, yaitu 0.91, dengan performa tertinggi tercatat pada fold ke-5 untuk *accuracy* sebesar 0.93.

Secara keseluruhan, hasil ini mengindikasikan bahwa model dapat mengklasifikasikan data dengan baik, meskipun masih ada sedikit penurunan performa pada *fold* ke-3 dan *fold* ke-4 dengan *accuracy* 0.89.

TABEL X

SETELAH SMOTE 5-FOLD CROSS VALIDATION SVM


<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	0.96	0.96	0.96	0.96
2	0.94	0.94	0.94	0.94
3	0.97	0.97	0.97	0.97
4	0.94	0.94	0.94	0.94
5	0.97	0.97	0.97	0.97
Rata–Rata	0.96	0.96	0.96	0.96

Berdasarkan hasil evaluasi menggunakan *5-fold cross-validation* pada data Tabel 10, model menunjukkan rata-rata *accuracy* sebesar 0.96. Hasil menunjukkan stabilitas yang baik di seluruh fold. Evaluasi lebih lanjut mengungkapkan bahwa *precision*, *recall*, dan *F1-score* semuanya memiliki nilai rata-rata yang sama, yaitu 0.96, dengan performa tertinggi tercatat pada fold ke-5 untuk *accuracy* sebesar 0.97.

Secara keseluruhan, hasil ini mengindikasikan bahwa model dapat mengklasifikasikan data dengan baik, meskipun masih ada sedikit penurunan performa pada *fold* ke-2 dan *fold* ke-4 dengan *accuracy* 0.94.


G. Visualisasi Model

Tahap selanjutnya yaitu proses visualisasi data, proses visualisasi data dilakukan dengan 2 cara yaitu dengan *wordcloud* dan kurva ROC.




Gambar 8. WordCloud Positive

Pada Gambar 8, terlihat bahwa kata dengan ukuran yang lebih besar menunjukkan kata-kata yang sering muncul, pada sentimen *positive*, seperti kata “baik”.



Gambar 9. WordCloud Negative

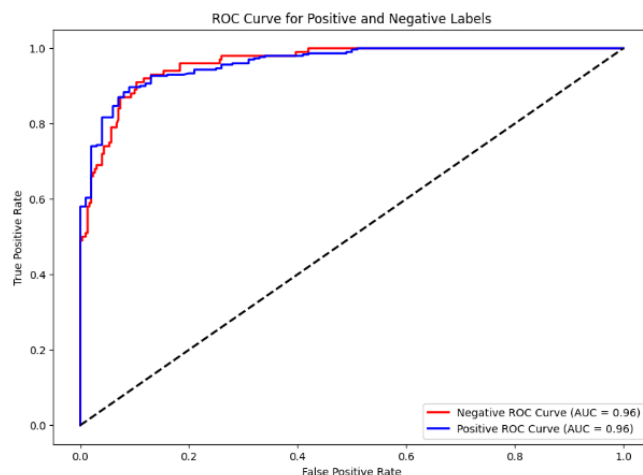
Pada Gambar 9, terlihat bahwa kata dengan ukuran yang lebih besar menunjukkan kata-kata yang sering muncul, pada sentimen *negative*, seperti kata “kurang”.



Gambar 10. Kurva ROC Random Forest

Berdasarkan Gambar 10, AUC dari kelas *positive* dan *negative* mampu bekerja dengan baik dalam melakukan klasifikasi komentar yang berjumlah besar yang mana hasil dari masing-masing AUC adalah AUC untuk *positive* sebesar

0.95 dan AUC untuk *negative* sebesar 0.95. Secara keseluruhan, perhitungan menggunakan kurva ROC untuk klasifikasi perbandingan data 80:20 dan menggunakan metode *random forest*, mendapat hasil *excellent classification* dikarenakan masuk kategori 0.90-1.00.



Gambar 11. Kurva ROC SVM

Berdasarkan Gambar 11, AUC dari kelas *positive* dan *negative* mampu bekerja dengan baik dalam melakukan klasifikasi komentar yang berjumlah besar yang mana hasil dari masing-masing AUC adalah AUC untuk *positive* sebesar 0.96 dan AUC untuk *negative* sebesar 0.96. Secara keseluruhan, perhitungan menggunakan kurva ROC untuk klasifikasi perbandingan data 80:20 dan menggunakan metode *support vector machine*, mendapat hasil *excellent classification* dikarenakan masuk kategori 0.90-1.00.

IV. KESIMPULAN

Penelitian ini menghasilkan dua hasil *accuracy*, *precision*, *recall* dan *f1-score* diantaranya sebelum dilakukan SMOTE dan setelah dilakukan SMOTE. Metode *random forest* berdampak pada penelitian ini dikarenakan sifat dari metode *random forest* yang lebih kearah kelas mayoritas daripada kelas minoritas. Terlihat ketika sebelum menerapkan metode SMOTE pada *random forest*, hasil yang didapatkan metode *random forest* yaitu *accuracy* 0.81, *precision* 0.85, *recall* 0.81 dan *f1-score* 0.76. Sedangkan setelah diterapkan metode *random forest*, terjadi keseimbangan dalam hasil dari metode *random forest* yaitu *accuracy* 0.90, *precision* 0.90, *recall* 0.90 dan *f1-score* 0.90. Sedangkan untuk metode *support vector machine* tidak ada perubahan ketika sebelum diterapkan metode SMOTE dan sesudah diterapkan metode SMOTE dengan hasil *accuracy* 0.90, *precision* 0.90, *recall* 0.90 dan *f1-score* 0.90. Adapun sentimen *positive* dominan pada layanan akademik sedangkan sentimen *negative* dominan pada fasilitas ITB STIKOM Bali terutama bagian pendingin ruangan dan kamar mandi

DAFTAR PUSTAKA

- [1] Ni Made Rai Masita Dewi, I Made Candiasa, and Kadek Yota Ernanda Aryanto, "Pengukuran Tingkat Kapabilitas Tata Kelola SION menggunakan Framework COBIT 5 pada Institut Teknologi dan Bisnis STIKOM Bali," *Jurnal Sistem dan Informatika (JSI)*, vol. 15, no. 2, pp. 144–154, May 2021, doi: 10.30864/jsi.v15i2.365.
- [2] Septiana and Juhaini Alie, "Pengaruh Tangible, Reliability, Responsiveness, Assurance, dan Emphaty Terhadap Kepuasan Pelanggan Perempuan Pada Osbond Gym Palembang," *Journal Management, Business, and Accounting*, vol. 22, no. 2, pp. 325–339, Aug. 2023, doi: <https://doi.org/10.33557/mbia.v22i2.2620>.
- [3] P. Kumala Sari and R. Randy Suryono, "Komparasi Algoritma Support Vector Machine Dan Random Forest Untuk Analisis Sentimen Metaverse," *Jurnal MNEMONIC*, vol. 7, no. 1, pp. 31–39, Feb. 2024.
- [4] B. Liu, "Sentiment Analysis: A Fascinating Problem," in *Sentiment Analysis and Opinion Mining*, Cham: Springer International Publishing, 2012, pp. 1–8. doi: 10.1007/978-3-031-02145-9_1.
- [5] I. Bagus Nyoman Wijana Manuaba, G. Rasben Dantes, and G. Indrawan, "Analisis Sentimen Data Provider Layanan Internet Pada Twitter Menggunakan Support Vector Machine (SVM) Dengan Penambahan Algoritma Levenshtein Distance," *Jurnal Sistem Komputer dan Kecerdasan Buatan*, vol. 5, Mar. 2022.
- [6] K. W. Trisna and H. J. Jie, "Deep Learning Approach for Aspect-Based Sentiment Classification: A Comparative Review," *Applied Artificial Intelligence*, vol. 36, no. 1, 2022, doi: 10.1080/08839514.2021.2014186.
- [7] N. M. K. Sedana, I. N. S. Wijaya, and I. K. R. Artana, "Analisis Sentimen Berbahasa Inggris Dengan Metode Lstm Studi Kasus Berita Online Pariwisata Bali English Sentiment Analysis Using The Lstm Method Case Study Of Bali Tourism Online News," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, no. 6, pp. 1325–1334, 2024, doi: 10.25126/jtiik.2024118792.
- [8] U. Fayyad, G. Piatetsky-Shapiro, and P. Smyth, "The KDD process for extracting useful knowledge from volumes of data," *Commun ACM*, vol. 39, no. 11, pp. 27–34, 1996.
- [9] I. P. Dedy, W. Darmawan, G. Aditra Pradnyana, I. Bagus, and N. Pascima, "Optimasi Parameter Support Vector Machine Dengan Algoritma Genetika Untuk Analisis Sentimen Pada Media Sosial Instagram," *SINTECH JOURNAL*, vol. 6, Apr. 2023, [Online]. Available: <https://doi.org/10.31598>
- [10] J. W. G. Putra, "Pengenalan konsep pembelajaran mesin dan deep learning," *Tokyo. Jepang*, 2019.
- [11] I. K. J. Arta, G. Indrawan, and G. R. Dantes, "Data Mining Rekomendasi Calon Mahasiswa Berprestasi Di Stmik Denpasar Menggunakan Metode Technique For Others Reference By Similarity To Ideal Solution," *Jurnal Sains & Teknologi*, vol. 5, no. 2, pp. 2303–3142, Oct. 2016.
- [12] L. Hermawan and M. B. Ismiati, "Pembelajaran Text Preprocessing berbasis Simulator Untuk Mata Kuliah Information Retrieval," *TRANSFORMATIKA*, vol. 17, no. 2, pp. 188–199, Jan. 2020, doi: 10.26623/transformatika.v17i2.1705.
- [13] N. M. A. J. Astari, Dewa Gede Hendra Divayana, and Gede Indrawan, "Analisis Sentimen Dokumen Twitter Mengenai Dampak Virus Corona Menggunakan Metode Naive Bayes Classifier," *Jurnal Sistem dan Informatika (JSI)*, vol. 15, no. 1, pp. 27–29, Nov. 2020, doi: 10.30864/jsi.v15i1.332.
- [14] C. Fan, M. Chen, X. Wang, J. Wang, and B. Huang, "A Review on Data Preprocessing Techniques Toward Efficient and Reliable Knowledge Discovery From Building Operational Data," Mar. 29, 2021, *Frontiers Media S.A.* doi: 10.3389/fenrg.2021.652801.
- [15] A. Sasmita, G. A. Pradnyana, and D. G. H. Divayana, "Pengembangan Sistem Analisis Sentimen Untuk Evaluasi Kinerja Dosen Universitas Pendidikan Ganesha Dengan Metode Naive Bayes," *JST (Jurnal Sains dan Teknologi)*, vol. 11, no. 2, pp. 451–462, Sep. 2022, doi: 10.23887/jstundiksha.v11i2.44384.
- [16] H. D. Abubakar and M. Umar, "Sentiment Classification: Review of Text Vectorization Methods: Bag of Words, Tf-Idf, Word2vec and Doc2vec," *SLU Journal of Science and Technology*, vol. 4, no. 1 & 2, pp. 27–33, Aug. 2022, doi: 10.56471/slujst.v4i.266.
- [17] D. E. Cahyani and I. Patasik, "Performance comparison of tf-idf and word2vec models for emotion text classification," *Bulletin of Electrical Engineering and Informatics*, vol. 10, no. 5, pp. 2780–2788, Oct. 2021, doi: 10.11591/eei.v10i5.3157.
- [18] Y. Widyarningsih, G. P. Arum, and K. Prawira, "Aplikasi K-Fold Cross Validation Dalam Penentuan Model Regresi Binomial Negatif Terbaik," *Barekeng: Jurnal Ilmu Matematika dan Terapan*, vol. 15, no. 2, pp. 315–322, Jun. 2021, doi: 10.30598/barekengvol15iss2pp315-322.
- [19] M. Kuhn and K. Johnson, *Applied predictive modeling*, vol. 26. Springer, 2013.
- [20] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-sampling Technique," 2002.
- [21] C. Ayunda *et al.*, "Analisis Komparasi Algoritma Machine Learning untuk Sentiment Analysis (Studi Kasus: Komentar YouTube 'Kekerasan Seksual')," *Jurnal Informatika: Jurnal pengembangan IT (JPIT)*, vol. 7, no. 2, pp. 80–84, May 2022.
- [22] L. Breiman, "Random Forests," *Mach Learn*, vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: 10.1023/A:1010933404324.
- [23] C. Cortes and V. Vapnik, "Support-vector networks," *Mach Learn*, vol. 20, no. 3, pp. 273–297, 1995, doi: 10.1007/BF00994018.
- [24] M. I. Fikri, T. S. Sabrila, and Y. Azhar, "Perbandingan Metode Naive Bayes dan Support Vector Machine pada Analisis Sentimen Twitter," *SMATIKA Jurnal*, vol. 10, pp. 71–76, Dec. 2020.
- [25] R. A. Raharjo, I. Made, G. Sunarya, D. Gede, and H. Divayana, "Perbandingan Metode Naive Bayes Classifier Dan Support Vector Machine Pada Kasus Analisis Sentimen Terhadap Data Vaksin Covid-19 Di Twitter," *Jurnal Ilmiah Elektronika Dan Komputer*, vol. 15, no. 2, pp. 456–464, Dec. 2022, [Online]. Available: <http://journal.stekom.ac.id/index.php/elkom/page456>
- [26] I. K. W. Dananjaya and I. G. A. A. D. Indradewi, "Perbandingan Metode Pembobotan TF-RF Dan TF-ABS Pada Kategorisasi Berita Di BDI Denpasar," *Sintech Journal*, vol. 6, no. 1, Apr. 2023.
- [27] N. K. T. A. Saputri, I. G. A. Gunadi, and I. M. G. Sunarya, "Analisis Sentimen Pelayanan Daring di Fakultas Teknik dan Kejuruan Universitas Pendidikan Ganesha Menggunakan Algoritma Naive Bayes dan LSTM," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 3, pp. 1120–1129, Jul. 2024, doi: 10.57152/malcom.v4i3.1336.
- [28] K. Pearson, *On the theory of contingency and its relation to association and normal correlation*, vol. 1. London, Dulau and Co., 1904.
- [29] J. Setyanto and T. B. Sasongko, "Sentiment Analysis of Sirekap Application Users Using the Support Vector Machine Algorithm," *Journal of Applied Informatics and Computing (JAIC)*, vol. 8, no. 1, pp. 2548–6861, Jul. 2024, [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [30] T. Rosandy, "Perbandingan Metode Naive Bayes Classifier Dengan Metode Decision Tree (C4.5) Untuk Menganalisa Kelancaran Pembiayaan (Studi Kasus : Kspps / Bmt Al-Fadhila)," *Jurnal TIM Darmajaya*, vol. 02, pp. 52–62, May 2016.
- [31] J. N. Mandrekar, "Receiver Operating Characteristic Curve in Diagnostic Test Assessment," *Journal of Thoracic Oncology*, vol. 5, no. 9, pp. 1315–1316, Sep. 2010, doi: <https://doi.org/10.1097/JTO.0b013e3181ec173d>.