

SENTIMENT ANALYSIS OF ICT SERVICE USER USING NAIVE BAYES CLASSIFIER AND SVM METHODS WITH TF-IDF TEXT WEIGHTING

Wulan Trisnawati^{*1}, Arief Wibowo²

^{1,2}Master of Computer Science, Faculty of Information Technology, Universitas Budi Luhur, Indonesia
Email: 2111601361@student.budiluhur.ac.id, arief.wibowo@budiluhur.ac.id

(Article received: January 25, 2024; Revision: February 10, 2024; published: May 27, 2024)

Abstract

Pusintek is one of the government units in Indonesia responsible for managing Information and Communication Technology (ICT), providing various ICT services to users in central and regional offices through the ICT Service Catalog. The level of service fulfillment in Pusintek's IT Service Catalog significantly influences the effectiveness and efficiency in meeting service agreements, providing accurate information, and handling disruptions promptly. User satisfaction is measured through surveys to plan improvements to ICT services, but there is currently no method to classify sentiment from survey comment data. This research aims to classify sentiment and understand customer opinions and satisfaction trends regarding ICT services. The study applies the Naïve Bayes Classifier and Support Vector Machine (SVM) methods to classify positive and negative comments in user satisfaction surveys of ICT services. The data used consists of comments from the 2022 ICT user satisfaction survey results. Based on the test results, it is observed that the SVM algorithm provides higher accuracy compared to the Naïve Bayes algorithm. Utilizing the existing dataset with established opinion values, classification modeling using Naïve Bayes Classifier and Support Vector Machine (SVM) proves capable of classifying ICT user sentiment into 3 sentiment classes: Positive, Neutral, and Negative. From the data above, it is concluded that the SVM algorithm achieves the highest accuracy of 88.76%, highest precision of 89.68%, recall of 88.76%, and an f1-score of 89.12%.

Keywords: Data Mining, Naïve Bayes Classifier, Sentiment Analysis, Services, Support Vector Machine.

ANALISIS SENTIMEN PENGGUNA LAYANAN TIK MENGGUNAKAN METODE NAIVE BAYES CLASSIFIER DAN SVM DENGAN PEMBOBOTAN TEKS TF-IDF

Abstrak

Pusintek adalah salah satu unit pemerintahan di Indonesia yang bertanggung jawab atas pengelolaan Teknologi Informasi dan Komunikasi (TIK), menyediakan beragam layanan TIK kepada pengguna di kantor pusat maupun daerah melalui Katalog Layanan TIK. Tingkat pemenuhan layanan di IT Service Catalog Pusintek sangat berpengaruh pada efektivitas dan efisiensi dalam memenuhi perjanjian layanan, memberikan informasi yang akurat, serta menangani gangguan dengan tepat waktu. Tingkat kepuasan pengguna diukur melalui survei untuk merencanakan peningkatan layanan TIK, namun belum ada metode untuk mengklasifikasikan sentimen dari data komentar survei. Penelitian ini bertujuan untuk mengklasifikasikan sentimen serta mengetahui kecenderungan pendapat serta kepuasan pelanggan akan layanan TIK. Penelitian ini menerapkan metode *Naïve Bayes Classifier* (NBC) dan *Support Vector Machine* (SVM) dengan mengklasifikasikan komentar positif dan negatif pada komentar pada survei pengguna layanan TIK. Data yang digunakan adalah komentar yang ada pada hasil survei layanan pengguna TIK tahun 2022. Berdasarkan hasil uji coba, dapat diketahui bahwa algoritma SVM memberikan nilai akurasi lebih tinggi jika dibandingkan dengan algoritma *Naïve Bayes*. Dengan menggunakan dataset yang ada dan telah memiliki nilai opini, pemodelan klasifikasi menggunakan *Naïve Bayes Classifier* dan SVM terbukti mampu mengklasifikasikan sentimen pengguna TIK ke dalam 3 kelas klasifikasi, yaitu kelas sentimen Positif, Netral dan Negatif. Dari data diatas didapat hasil bahwa algoritma SVM memiliki nilai akurasi tertinggi yang didapatkan sebesar 88,76%, nilai presisi tertinggi sebesar 89,68%, *recall* sebesar 88,76%, dan *f1-score* sebesar 89,12%.

Kata kunci: Analisis Sentimen, Data Mining, Layanan, Naïve Bayes Classifier, Support Vector Machine.

1. PENDAHULUAN

Layanan Teknologi Informasi dan Komunikasi (TIK) memainkan peran utama bagi Pusat Informasi dan Teknologi Keuangan, Sekretariat Jenderal, Kementerian Keuangan (Pusintek Kemenkeu) selaku Pusat Unit Pengelolaan TIK. *IT service catalog* yang senantiasa dimuthakirkan dengan mengikuti perkembangan teknologi informasi dan berfokus pada kebutuhan pengguna. Pada saat ini terdapat pertumbuhan pesat dalam literatur ilmiah yang didedikasikan untuk memprediksi tingkat kepuasan layanan TIK menggunakan teknik *Data Mining* [1]. Saat ini *Big Data* menjadi isu yang relevan bagi dunia, minat terhadap *Data Science* dan *Machine Learning* semakin berkembang [2].

Kepuasan merujuk pada tanggapan pengguna terhadap pemenuhan layanan [3]. Jika ada keluhan dari pengguna terkait pelayanan yang diterima, hal ini mengindikasikan adanya masalah dalam kualitas pelayanan dari penyedia yang bersangkutan [4]. Dalam penelitian ini, fokus utama adalah pada indikator kualitas layanan, yaitu kepuasan pengguna dan persepsi pengguna. Suatu kebijakan untuk peningkatan kualitas layanan secara menyeluruh diperoleh salah satunya dari hasil pengukuran kualitas layanan [5]. *Text mining* adalah cabang dari *data mining* yang melibatkan analisis data teks, baik yang terstruktur maupun tidak, dengan tujuan untuk menghasilkan informasi yang berharga [6][7].

Tingkat kepuasan pengguna sangat penting bagi Pusat Unit Pengelolaan TIK sebagai evaluasi, acuan dan rencana peningkatan mutu serta layanan TIK di Pusintek Kemenkeu. Tujuan utama pengelola layanan TIK adalah untuk memberikan efektifitas dan efisiensi dalam pemenuhan layanan, hal ini mencakup kepatuhan perjanjian tingkat layanan, menyediakan informasi yang tepat, dan merespon permintaan layanan serta menangani gangguan dengan tepat waktu. Diperlukan *tools* untuk dapat mengukur kualitas layanan yang diberikan untuk mengevaluasi dan sebagai rencana peningkatan layanan, para pengguna layanan memberikan umpan balik terhadap layanan TIK dengan mengisi survei kepuasan layanan TIK.

Hasil survei penggunaan layanan TIK tahun 2022 pada *service desk* sebesar 4,62 mengalami penurunan jika dibandingkan dengan hasil survei yang dilakukan pada tahun 2021 yaitu 4,69. Dalam hasil survey berisi banyak tanggapan, diantaranya berbagai komentar [8]. Banyak komentar yang bersifat kritik dan saran, namun tidak sedikit pula ulasan atau komentar negatif pada layanan TIK yang diberikan karena kualitas yang belum memenuhi harapan pengguna. Pada hasil survei yang dilakukan data yang berisi berbagai komentar tersebut belum dapat menunjukkan informasi yang lebih spesifik, sehingga pemilik layanan kesulitan dalam memantau sentimen pengguna terhadap layanan TIK yang diberikan.

Dengan adanya ulasan yang dituliskan oleh para pengguna, dampak yang ditimbulkan cukup signifikan untuk keputusan penggunaan layanan TIK bagi pegawai [9]. Ulasan juga akan mempengaruhi reputasi suatu layanan, hingga apabila ulasan dan/atau rating yang diberikan buruk, maka akan berdampak buruk bagi penyedia layanan [10]. Komentar negatif dari pengguna layanan memiliki dampak buruk bagi penyedia layanan [11][12]. Oleh karena itu, pengumpulan dan analisis data ulasan survei yang efisien diperlukan untuk membantu penyedia layanan TIK meningkatkan layanan mereka. Studi empiris menunjukkan bahwa ulasan panjang yang mudah dibaca, terutama yang mencerminkan ketidakpuasan, dapat mendorong perbaikan layanan di masa depan [13].

Melakukan analisis sentimen merupakan sebuah tantangan karena bahasa memiliki ranah pengartian yang cukup luas [14]. Perbedaan penggunaan semiotika berupa penanda misalnya, dapat merubah arti kata baik secara semantik maupun pragmatik. Penggunaan sarkasme dalam berkomunikasi bisa menjadi batasan, suatu kalimat bisa mendapatkan label sentimen yang berbanding terbalik dengan yang dimaksudkan jika tidak disertai dengan konteks dan pengartian sesungguhnya [15].

Penelitian yang membahas topik opini atau sentimen terhadap sesuatu, dikenal dengan Analisis Sentimen. Sebuah studi analisis sentimen telah dilakukan pada ulasan pengguna di bidang *e-commerce* pangan, dengan fokus pada aplikasi *Google Play* yaitu *Review Sayurbox* dan *Tanihub*. Metode yang dipakai dalam analisa ini ialah *Support Vector Machine* dengan pembobotan TF-IDF (*Term Frequency-Invers Document Frequency*) dan kernel linear. Data ulasan yang dianalisis mencakup periode Februari 2020 hingga Januari 2021.


Hasil dari analisis menunjukkan bahwa akurasi tertinggi yang dicapai adalah sebesar 91,4% untuk data *Review Sayurbox*, dengan mayoritas sentimen yang diekspresikan yaitu sentimen positif sejumlah 738 (70%). Sementara itu, akurasi total yang diperoleh pada data review *Tanihub* senilai 88,8% dengan mayoritas sentimen positif yang mencapai 348 (65%) [16]. Penelitian oleh [17] membahas pemakaian *E-Wallet* selama pandemi dengan menerapkan *Naïve Bayes Classifier* dan *Information Gain* sebagai fitur untuk meningkatkan akurasi.

Hasil analisis menunjukkan bahwa pendekatan mencapai tingkat *precision* senilai 92%, *recall* senilai 100%, dan akurasi senilai 92%. Sementara itu, penelitian oleh [18] berfokus pada analisa sentimen tingkat kepuasan pemakai jasa telekomunikasi seluler melalui Twitter di Indonesia. Penelitian ini bertujuan untuk membandingkan metode *Support Vector Machine* dengan *Naïve Bayes Classifier* serta mengevaluasi tingkat kepuasan pemakai terhadap penyedia pelayanan telekomunikasi seluler. Dalam penelitian ini, juga digunakan *Lexicon Based*

Features sebagai tambahan dalam metode *Support Vector Machine*. Hasil dari penelitian menyimpulkan bahwa penggunaan *Lexicon Based Features* dalam metode *Support Vector Machine* dapat meningkatkan akurasi, dengan nilai akurasi mencapai 79%, *f-measure* senilai 78%, presisi senilai 65%, dan *recall* senilai 97%.

Penggunaan metode *Naive Bayes Classifier* (NBC) dan SVM dengan pembobotan TF-IDF diharapkan dapat membantu membaca komentar pada hasil survei kepuasan pengguna layanan TIK Pusintek Kemenkeu yang selama ini belum dikorelasikan dengan hasil survei yang telah dilakukan sebelumnya. Pengukuran tingkat kepuasan pengguna sebelumnya dilakukan secara kuantitatif menggunakan skala *likert*.

2. METODE PENELITIAN



Gambar 1. Tahapan Penelitian

Berikut ini merupakan penjelasan merupakan penjelasan tahapan penelitian pada Gambar 1.

1. Identifikasi Masalah

Penulis mengadakan *research experiment* bagaimana mengevaluasi kinerja metode *Naive Bayes Classifier* dan SVM dengan pembobotan TF-IDF dalam penelitian analisis sentimen terhadap kepuasan pengguna layanan TIK.

2. Studi Pustaka

Penelitian ini melakukan tinjauan pustaka terhadap penelitian-penelitian sebelumnya yang terdapat dalam buku, jurnal, dan literatur terkait analisis sentimen. Tujuannya adalah untuk mencari topik-topik yang berkaitan dengan analisis sentimen dan kajian literatur serupa.

3. Pengumpulan Data

Penelitian ini melakukan pengumpulan data berupa komentar dari hasil survei kepuasan pengguna

layanan TIK. Data yang dipergunakan adalah survei yang dilakukan pada tahun 2022.

4. Data Preprocessing

Penelitian ini melakukan tahapan dari proses *preprocessing* sebagai berikut:

- a. *Case folding*
Tahap ini bertujuan merubah setiap kalimat yang terkandung huruf kapital menjadi huruf kecil seperti “Sudah” menjadi “sudah”.
- b. *Cleansing*
Tahap ini diadakan guna menghilangkan tanda baca yang tidak dibutuhkan dalam teks seperti [%^^%*&^#*>””}{[=@], dan sebagainya. Ini bertujuan agar dataset dapat diolah dan mengurangi *data noise* yang terdapat didalamnya.
- c. *Text Transformation*
Tahap ini untuk memperbaiki kata singkatan atau kata yang penulisannya tidak tepat/*typo*, tahap ini juga merubah kata yang tidak baku menjadi bentuk kata dasar. Pada kalimat yang tidak terstruktur biasanya banyak kata yang disingkat dan/atau tidak baku, serta kesalahan saat pengetikan (*typo*), *text transformation* adalah tahap memperbaiki kata tersebut.
- d. *Stop Removal*
Proses pemeriksaan kata per kata, tahap ini dilakukan pada kata yang mempunyai imbuhan seperti kata ganti, kata sambung, kata depan, yang tidak berkaitan dengan analisis sentimen akan dihilangkan. Pada penelitian ini, penulis menggunakan kamus *stopward* Sastrawi yang telah banyak digunakan untuk membuang kata-kata tidak penting pada Bahasa Indonesia.
- e. *Tokenization*
Tahap ini adalah proses memecah kalimat yang terdapat pada dataset menjadi kata-perkata. Pada *text mining* proses ini berperan penting dalam melakukan penilaian terhadap kata yang terdapat pada dataset, setelah proses *tokenizing* kita dapat menghitung frekuensi distribusinya. Frekuensi distribusi adalah jumlah kemunculan setiap kata dalam teks atau dokumen sehingga dengan mengetahui frekuensi tersebut kita dapat menghitung seberapa sering kata tersebut muncul dalam teks.
- f. *Stemming*
Proses yang diadakan pada tahap ini ialah pengubahan kata menjadi kata dasar atau root dari tiap kata hasil *stopward removal*
- g. Pelabelan
Setelah tahap *preprocessing* selesai, data diberi label secara otomatis menggunakan kamus *InSet Lexicon*, yang mengandung kata-kata dan bobotnya untuk menentukan arah kata tersebut. Polaritas dihitung dengan menjumlahkan bobot kata dalam setiap ulasan, lalu hasilnya digunakan sebagai penanda positif atau negatif untuk tiap ulasan. Ulasan dianggap positif

apabila polaritasnya positif, dan negatif jika polaritasnya negatif.

5. Pembobotan TF-IDF

TF-IDF (*Term Frequency Inverse Document Frequency*) adalah teknik yang digunakan untuk mengukur seberapa sering suatu kata muncul dalam suatu dokumen atau artikel, serta seberapa umum kata tersebut dalam seluruh koleksi dokumen. Metode ini membantu menilai relevansi sebuah kata dalam suatu dokumen [19]. TF-IDF adalah algoritma yang sering digunakan dalam analisis data besar. Algoritma ini memberikan bobot pada setiap kata kunci dalam setiap kategori untuk menemukan kesesuaian antara kata kunci dan kategori yang ada. Sebelum memberikan bobot, dilakukan lima langkah *preprocessing* teks, termasuk pemecahan kalimat, penurunan huruf besar ke kecil, tokenisasi, penyaringan, dan stemming. Setelah itu, dilakukan perhitungan 18 bobot TF-IDF, serta bobot relevansi *query* dan kesamaan[20].

6. Klasifikasi

Dalam penelitian ini, penulis menggunakan metode Naive Bayes *Classifier* dan SVM untuk menemukan probabilitas tertinggi dalam mengklasifikasikan dataset. Persamaan teorema Bayes bisa diamati pada persamaan berikut:

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)} \tag{1}$$

Dimana:

- P(A) : Probabilitas hipotesis A.
- B : Data klasifikasi yang belum diketahui.
- A : Kelas spesifik pada data hipotesis
- P(A|B) : Probabilitas hipotesis A menurut keadaan B.
- P(B) : Probabilitas B.
- P(B|A) : Probabilitas B atas dasar keadaan hipotesis A.

7. Evaluasi dan Validasi

Tahapan ini diadakan penilaian dan validasi dengan memanfaatkan bahasa *python* sehingga didapatkan nilai hasil akurasi dari pengujian.

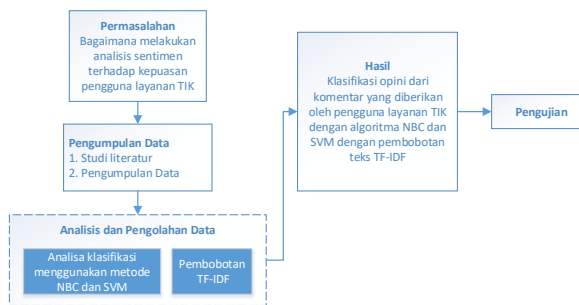
8. Deployment (Prototyping)

Langkah akhir dari metodologi *Naive Bayes Classifier* dan SVM adalah tahap *Deployment*. Dalam tahapan ini, menyusun laporan hasil dari seluruh kegiatan yang sudah dilaksanakan. Hasil ini diharapkan bisa diperoleh model dengan angka akurasi yang baik sehingga diimplementasikan dalam bentuk *prototype* yang selanjutnya dapat memberikan rekomendasi kepada organisasi dalam rangka menyusun *improvement plan* layanan TIK.

3. HASIL DAN PEMBAHASAN

Bab ini menjelaskan langkah-langkah ekstraksi data yang digunakan untuk mengklasifikasi kata-kata sebagai positif, negatif, atau netral. Studi kasus dalam penelitian ini menggunakan data yang diambil adalah opini pengguna layanan TIK pada Pusat Unit Pengelolaan TIK Sekretariat Jenderal, Kementerian

Keuangan (Pusintek Kemenkeu). Dengan kerangka konsep sebagai mana pada Gambar 2.



Gambar 2 Kerangka Konsep Penelitian

3.1. Pengumpulan Data

Pengumpulan data dilakukan dengan cara mengambil pada hasil survei kepuasan layanan pengguna layanan TIK. Survei kepuasan pengguna layanan TIK dilakukan dengan pendekatan kuantitatif dan kualitatif yang dilaksanakan melalui kuisioner *online*, dataset diambil dalam rentang waktu tahun 2022 sebanyak 1.244 data ulasan.

Tabel 1. Data

No	sd_saran
1.	Service desk diharapkan secara berkala memberikan status atas permasalahan pegawai yang dimintakan layanan ke pusintek service desk
2.	Secara umum layanan Service Desk sudah bagus. Semoga ke depannya semakin bagus lagi dengan mengedepankan aspek kemudahan, aspek kecepatan dan aspek keamanan. Terima kasih
3.	dipertahankan dan kalau bisa ditingkatkan lagi layanannya
4.	Sangat terbantu dengan profesionalitas petugas dalam melayanani
5.	sejauh ini layanan service desk kemenkeu sudah sangat baik
6.	secara umum sudah baik, namun terkadang kurang cepat menanggapi keluhan, mohon ditingkatkan lagi
7.	Mungkin untuk semua penanganan masalah terkait semua aplikasi kemenkeu dapat dijadikan satu pintu, sehingga pegawai tidak bingung harus konsultasi kemana dan harus kirim tiket lewat mana
8.	sangat responsif, perlu dijaga dan terus dtingkatkan kualitas pelayanannya
9.	service desk telah bagus, dapat dihubungi kapan pun,
10.	sejauh ini layanan service desk kemenkeu sudah sangat baik

Pada Tabel 1 diketahui data yang diperoleh masih lengkap dengan beragam karakter, sehingga perlu diolah untuk menghilangkan karakter yang tidak diperlukan. Hal ini bertujuan agar data yang diolah menjadi lebih bersih dan siap diproses pada tahap selanjutnya.

3.1.1. Preprocessing

Tahap pengolahan data asli yang sudah diakuisi berupa data *text* dari sentimen layanan TIK. *Preprocessing* bertujuan untuk mengurangi gangguan, memperjelas ciri-ciri, serta menyesuaikan data asli dengan kebutuhan. Berikut ini adalah tahapan dalam *preprocessing*:

a. *Cleansing*

Pada langkah ini, data yang diperoleh akan disaring untuk menghapus karakter-karakter seperti tanda baca dan karakter khusus ("!"#\$%&()*+,-./:;<=>?@[^_`{|}~\n,). Tujuan dari cleansing ini adalah mengurangi noise dengan dilakukan pembersihan (*cleansing*) dari karakter-karakter yang tidak diperlukan. Pada Tabel 2 merupakan hasil data yang telah memalalui tahap *cleansing*.

Tabel 2. *Cleansing* Dokumen

No	Kalimat
1.	Service desk diharapkan secara berkala memberikan status atas permasalahan pegawai yang dimintakan layanan ke pusintek service desk
2.	Secara umum layanan Service Desk sudah bagus Semoga ke depannya semakin bagus lagi dengan mengedepankan aspek kemudahan aspek kecepatan dan aspek keamanan Terima kasih
3.	dipertahankan dan kalau bisa ditingkatkan lagi layanannya
4.	Sangat terbantu dengan profesionalitas petugas dalam melayanani
5.	sejauh ini layanan service desk kemenkeu sudah sangat baik
6.	secara umum sudah baik namun terkadang kurang cepat menanggapi keluhan mohon ditingkatkan lagi
7.	Mungkin untuk semua penanganan masalah terkait semua aplikasi kemenkeu dapat dijadikan satu pintu sehingga pegawai tidak bingung harus konsultasi kemana dan harus kirim tiket lewat mana
8.	sangat responsif perlu dijaga dan terus dtingkatkan kualitas pelayanannya
9.	service desk telah bagus dapat dihubungi kapan pun
10.	sejauh ini layanan service desk kemenkeu sudah sangat baik

b. *Case Folding*

Tahap *case folding* ini mencakup standarisasi huruf dalam dokumen di mana huruf kapital akan diubah menjadi huruf kecil, dan seluruh karakter selain huruf akan dihapus karena dianggap sebagai pembatas. Pada Tabel 3. dapat dilihat data-data dalam dokumen sudah diproses *case folding* sehingga huruf-huruf sudah diseragamkan.

Tabel 3. Proses *Case Folding*

No	Kalimat
1.	service desk diharapkan secara berkala memberikan status atas permasalahan pegawai yang dimintakan layanan ke pusintek service desk
2.	secara umum layanan service desk sudah bagus semoga ke depannya semakin bagus lagi dengan mengedepankan aspek kemudahan aspek kecepatan dan aspek keamanan terima kasih
3.	dipertahankan dan kalau bisa ditingkatkan lagi layanannya
4.	sangat terbantu dengan profesionalitas petugas dalam melayanani
5.	sejauh ini layanan service desk kemenkeu sudah sangat baik
6.	secara umum sudah baik namun terkadang kurang cepat menanggapi keluhan mohon ditingkatkan lagi
7.	mungkin untuk semua penanganan masalah terkait semua aplikasi kemenkeu dapat dijadikan satu pintu sehingga pegawai tidak bingung harus konsultasi kemana dan harus kirim tiket lewat mana
8.	sangat responsif perlu dijaga dan terus dtingkatkan kualitas pelayanannya
9.	service desk telah bagus dapat dihubungi kapan pun

10.	sejauh ini layanan service desk kemenkeu sudah sangat baik
-----	------------------------------------------------------------

c. *Normalisasi Kalimat*

Normalisasi kalimat bertujuan untuk mengubah kalimat informal menjadi kalimat formal. Proses ini melibatkan penggantian kata-kata slang dan penghapusan huruf yang berulang, misalnya mengubah "adaaa" menjadi "ada". Pada Tabel 4 dapat dilihat data-data dalam dokumen sudah dilakukan normalisasi kalimat sehingga kalimat gaul telah diproses menjadi kalimat normal.

Tabel 4. Proses Normalisasi Kalimat

No	Kalimat
1.	service desk diharapkan secara berkala memberikan status atas permasalahan pegawai yang dimintakan layanan ke pusintek service desk
2.	secara umum layanan service desk sudah bagus semoga ke depannya semakin bagus lagi dengan mengedepankan aspek kemudahan aspek kecepatan dan aspek keamanan terima kasih
3.	dipertahankan dan kalau bisa ditingkatkan lagi layanannya
4.	sangat terbantu dengan profesionalitas petugas dalam melayanani
5.	sejauh ini layanan service desk kemenkeu sudah sangat baik
6.	secara umum sudah baik namun terkadang kurang cepat menanggapi keluhan mohon ditingkatkan lagi
7.	mungkin untuk semua penanganan masalah terkait semua aplikasi kemenkeu dapat dijadikan satu pintu sehingga pegawai tidak bingung harus konsultasi kemana dan harus kirim tiket lewat mana
8.	sangat responsif perlu dijaga dan terus dtingkatkan kualitas pelayanannya
9.	service desk telah bagus dapat dihubungi kapan pun
10.	sejauh ini layanan service desk kemenkeu sudah sangat baik

d. *Tokenizing*

Pada langkah *tokenizing* ini, dilakukan pemisahan *string* masukan menjadi potongan-potongan berdasarkan kata-kata yang membentuknya. Intinya, proses ini adalah membagi setiap kata yang membentuk sebuah dokumen. Pada Tabel 5 dapat dilihat kalimat dalam dokumen telah di pecah menjadi kata-kata kemudian menganalisa kumpulan data dengan memisahkan kata tersebut.

Tabel 5. Proses *Tokenizing*

No	Kalimat
1.	['service', 'desk', 'diharapkan', 'secara', 'berkala', 'memberikan', 'status', 'atas', 'permasalahan', 'pegawai', 'yang', 'dimintakan', 'layanan', 'ke', 'pusintek', 'service', 'desk']
2.	['secara', 'umum', 'layanan', 'service', 'desk', 'sudah', 'bagus', 'semoga', 'ke', 'depannya', 'semakin', 'bagus', 'lagi', 'dengan', 'mengedepankan', 'aspek', 'kemudahan', 'aspek', 'kecepatan', 'dan', 'aspek', 'keamanan', 'terima', 'kasih']
3.	['dipertahankan', 'dan', 'kalau', 'bisa', 'ditingkatkan', 'lagi', 'layanannya']
4.	['sangat', 'terbantu', 'dengan', 'profesionalitas', 'petugas', 'dalam', 'melayanani']
5.	['sejauh', 'ini', 'layanan', 'service', 'desk', 'kemenkeu', 'sudah', 'sangat', 'baik']
6.	['secara', 'umum', 'sudah', 'baik', 'namun', 'terkadang', 'kurang', 'cepat', 'menanggapi', 'keluhan', 'mohon', 'ditingkatkan', 'lagi']

	['mungkin', 'untuk', 'semua', 'penanganan', 'masalah', 'terkait', 'semua', 'aplikasi', 'kemenkeu', 'dapat', 'dijadikan', 'satu', 'pintu', 'sehingga', 'pegawai', 'tidak', 'bingung', 'harus', 'konsultasi', 'kemana', 'dan', 'harus', 'kirim', 'tiket', 'lewat', 'mana']
7.	
8.	['sangat', 'responsif', 'perlu', 'dijaga', 'dan', 'terus', 'ditingkatkan', 'kualitas', 'pelayanannya']
9.	['service', 'desk', 'telah', 'bagus', 'dapat', 'dihubungi', 'kapan', 'pun']
10.	['sejauh', 'ini', 'layanan', 'service', 'desk', 'kemenkeu', 'sudah', 'sangat', 'baik']

e. *Filtering*

Pada langkah *filtering* ini, dilakukan pengambilan kata-kata penting dari hasil tokenisasi dengan menggunakan algoritma *stoplist*. *Stoplist* atau *stopword* adalah kata-kata non-deskriptif yang diabaikan dalam pendekatan *bag-of-words*, seperti "di", "yang", dan "dan". Pada tabel 6 dapat dilihat proses menghilangkan kata-kata yang tidak penting berdasarkan kamus *stopword* bahasa indonesia.

Tabel 6. Proses *Filtering*

No	Kalimat
1.	['service', 'desk', 'diharapkan', 'berkala', 'memberikan', 'status', 'atas', 'permasalahan', 'pegawai', 'dimintakan', 'layanan', 'pusintek', 'service', 'desk']
2.	['umum', 'layanan', 'service', 'desk', 'bagus', 'semoga', 'depannya', 'semakin', 'bagus', 'dengan', 'mengedepankan', 'aspek', 'kemudahan', 'aspek', 'kecepatan', 'aspek', 'keamanan', 'terima', 'kasih']
3.	['dipertahankan', 'kalau', 'ditingkatkan', 'layanannya']
4.	['sangat', 'terbantu', 'profesionalitas', 'petugas', 'melayanani']
5.	['sejauh', 'layanan', 'service', 'desk', 'kemenkeu', 'sangat', 'baik']
6.	['umum', 'baik', 'terkadang', 'kurang', 'cepat', 'menanggapi', 'keluhan', 'mohon', 'ditingkatkan']
7.	['mungkin', 'semua', 'penanganan', 'masalah', 'terkait', 'semua', 'aplikasi', 'kemenkeu', 'dijadikan', 'satu', 'pintu', 'pegawai', 'bingung', 'konsultasi', 'dan', 'kirim', 'tiket', 'lewat', 'mana']
8.	['sangat', 'responsif', 'perlu', 'dijaga', 'terus', 'ditingkatkan', 'kualitas', 'pelayanannya']
9.	['service', 'desk', 'bagus', 'dihubungi', 'kapan']
10.	['sejauh', 'layanan', 'service', 'desk', 'kemenkeu', 'sangat', 'baik']

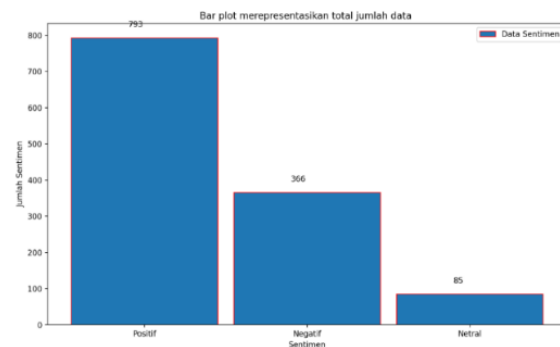
f. Pelabelan Data *Lexicon*

Setelah pra-pengolahan selesai, dilanjutkan ke tahap analisis sentimen untuk mengklasifikasikan data dari survei pengguna layanan TIK. Metode pendekatan berbasis leksikal menggunakan kamus sebagai sumber bahasa. Tahap ini terdiri dari 3 proses: mengimpor kamus kata leksikon positif dan negatif, memecah teks menjadi bagian kata untuk memudahkan penilaian skor positif, negatif, dan netral, serta menghitung skor sentimen dengan menggunakan metode berbasis leksikon. Dari total 1.244 data dalam dataset, akan diberi label menggunakan metode berbasis leksikon dengan tiga kelas atribut: positif, negatif, dan netral. Berikut contoh hasil pelabelan sebagaimana Tabel 7.

Pada Gambar 3 merupakan hasil pelabelan data berdasarkan proses *filtering*.

Tabel 7. Proses Pelabelan

No	Kalimat	Label
1.	['service', 'desk', 'diharapkan', 'berkala', 'memberikan', 'status', 'atas', 'permasalahan', 'pegawai', 'dimintakan', 'layanan', 'pusintek', 'service', 'desk']	Negatif
2.	['umum', 'layanan', 'service', 'desk', 'bagus', 'semoga', 'depannya', 'semakin', 'bagus', 'dengan', 'mengedepankan', 'aspek', 'kemudahan', 'aspek', 'kecepatan', 'aspek', 'keamanan', 'terima', 'kasih']	Positif
3.	['dipertahankan', 'kalau', 'ditingkatkan', 'layanannya']	Negatif
4.	['sangat', 'terbantu', 'profesionalitas', 'petugas', 'melayanani']	Positif
5.	['sejauh', 'layanan', 'service', 'desk', 'kemenkeu', 'sangat', 'baik']	Positif
6.	['umum', 'baik', 'terkadang', 'kurang', 'cepat', 'menanggapi', 'keluhan', 'mohon', 'ditingkatkan']	Netral
7.	['mungkin', 'semua', 'penanganan', 'masalah', 'terkait', 'semua', 'aplikasi', 'kemenkeu', 'dijadikan', 'satu', 'pintu', 'pegawai', 'bingung', 'konsultasi', 'dan', 'kirim', 'tiket', 'lewat', 'mana']	Negatif
8.	['sangat', 'responsif', 'perlu', 'dijaga', 'terus', 'ditingkatkan', 'kualitas', 'pelayanannya']	Positif
9.	['service', 'desk', 'bagus', 'dihubungi', 'kapan']	Positif
10.	['sejauh', 'layanan', 'service', 'desk', 'kemenkeu', 'sangat', 'baik']	Positif



Gambar 3. Pelabelan *Lexicon* Based

3.1.2. *Feature Extraction*

Tahapan *feature extraction* ini bertujuan untuk mengekstraksi data teks ke dalam matiks data numerik, karena beberapa algoritma *machine learning* tidak dapat memproses data berupa teks secara langsung. Dalam penelitian ini, peneliti menggunakan *library TfidfVectorizer* dari modul *scikit learn* untuk melakukan proses ekstraksi fitur dan pembobotan. *Term Frequency-Inverse Document Frequency (TF-IDF)* adalah suatu pendekatan menghitung seberapa penting sebuah kata dalam suatu dokumen atau korpus berdasarkan seberapa sering kata muncul dan seberapa umum kata tersebut dalam keseluruhan dokumen atau korpus. Tujuan utama TF-IDF adalah menemukan kata-kata yang paling penting dalam suatu dokumen. TF-IDF adalah hasil kombinasi dari proses TF yang mengutamakan kata-kata yang sering muncul dalam dokumen tertentu dengan memberikan bobot yang lebih tinggi, dan IDF yang memberikan bobot yang lebih tinggi pada kata-kata yang jarang muncul dalam seluruh dokumen.

Setelah dilakukan pembobotan dengan *TF-IDF*, dataset yang awalnya berupa *text message* diubah menjadi matriks data numerik seperti pada Gambar 4.

	155	156	157	158	159	160	161	162	163	164	165
absen	0	0	0	0	0	0	0	0	0	0	0
ada	0	0	0	0	0	0	0	0	0	0	0
adanya	0	0	0	0	0	0	0	0	0	0	0
admin	0	0	0	0	0	0	0	0	0	0	0
administratif	0	0	0	0.1842	0	0	0	0	0	0	0
aduan	0	0	0	0.1531	0	0	0	0	0	0	0
agak	0	0	0	0	0	0	0	0	0	0	0
agar	0	0	0	0	0	0	0	0	0	0	0
agen	0	0	0	0	0	0	0	0	0	0	0
agent	0	0	0	0	0	0	0	0	0	0	0

Gambar 4. Data Tabular Setelah Proses Pembobotan dengan *TF-IDF*

Dalam matriks data numerik hasil *TF-IDF*, dapat dilihat bahwa setiap kata (*term*) telah memiliki skor, dimana skor tertinggi diberikan pada kata (*term*) yang jarang muncul di seluruh dokumen tetapi sering muncul pada satu dokumen tertentu, sehingga membantu mengidentifikasi kata yang lebih penting dalam dokumen-dokumen tersebut. Tabel 8 merupakan tabel peringkat skor *TF-IDF* dari setiap kata.

Tabel 8. Peringkat skor *TF-IDF*

Kata (<i>term</i>)	Skor <i>TF-IDF</i>
Bantu	2,888768
Terima	2,268851
Kasih	2,265949
Mohon	1,667443
Layan	1,39645
Selesai	1,199689
Respon	0,908025
Admin	0,809657
...	...
Profesional	0,173702
Baik	0,173702
Perintah	0,173702

Dari tabel skor *TF-IDF* pada Tabel 8, setiap kata (*term*) telah memiliki skor masing-masing. Kata yang memiliki skor tertinggi merupakan kata yang penting dalam proses identifikasi sebuah kalimat. Kata “bantu” memiliki skor paling tinggi yakni sebesar 2,888768 dan kata “perintah” memiliki skor paling rendah yakni sebesar 0,173702. Skor inilah yang berikutnya akan dipakai untuk mengidentifikasi sebuah kalimat masukan baru.

3.2. Pemodelan

Dalam tahap ini, sebuah model *machine learning* dibuat dari dataset sampel yang telah dipilih dan diproses sebelumnya. Metode pemilihan sampel menggunakan pengambilan data langsung dari sumber asli. Total sampel yang digunakan adalah 1.244 data sentimen dengan rating yang telah tersedia, dengan sebaran data pada Tabel 9.

Tabel 9. Sebaran Data Sampel Sentimen

Sentimen	Jumlah
2 (negatif)	366
0 (netral)	85
1 (positif)	793
Jumlah Total	1.244

Selanjutnya, terhadap data sampel tersebut dilakukan proses *text preprocessing* berupa *case folding*, *word normalization*, *stopwords removal*, *stemming*, pembobotan *TF-IDF* dan *feature selection* dengan *SelectKBest*. Kemudian, dataset yang telah melalui proses *text processing*, dilakukan uji coba pembuatan model klasifikasi menggunakan algoritma *Naïve Bayes* dan *SVM* menggunakan aplikasi *python streamlit*. Data sampel tersebut dibagi menjadi data training dan data testing dengan beberapa kombinasi. Hal ini dilakukan untuk memilih algoritma mana yang dapat menghasilkan nilai akurasi tertinggi.

Hasil dari tahap ujicoba dua algoritma klasifikasi menggunakan aplikasi *python streamlit*, dapat dilihat pada tabel 10 berikut:

Tabel 10. Perbandingan Akurasi Algoritma NBC dan SVM

Kombinasi Data Training:	Akurasi		
	Testing	Naïve Bayes	SVM
90:10		81.45%	88.00%
80:20		79.84%	88.76%
70:30		80.38%	88.24%

Berdasarkan data pada tabel akurasi algoritma tersebut dapat dilihat bahwa, algoritma *SVM* memperoleh nilai akurasi tertinggi dari algoritma NBC yang dipakai dalam uji coba, yakni 88,00%. Untuk kombinasi pembagian data *training* dan data *testing* diperoleh kombinasi yang mendapatkan akurasi tertinggi adalah 90% data *training* dan 10% data *testing*.

Tahap selanjutnya adalah pembuatan model *machine learning* klasifikasi menggunakan algoritma *SVM* yang terpilih, karena mendapatkan nilai akurasi tertinggi. Langkah-langkah pembuatan model menggunakan bahasa pemrograman *python* adalah sebagai berikut:


- Persiapan Data**
Langkah awal adalah menyiapkan data untuk proses klasifikasi. Dalam penelitian ini, data dimuat ke dalam *Python* menggunakan *library Pandas* dan *Numpy*. Selanjutnya, dataset teks dibersihkan, dipilih fitur-fitur terbaik, diubah menjadi matriks numerik, dan dibagi menjadi data fitur dan data label.
- Pemilihan Algoritma**
Langkah selanjutnya adalah pembuatan model *machine learning* klasifikasi menggunakan algoritma *SVM*. Dalam penelitian ini, peneliti menggunakan *library* model *SVM* dari modul *sci-kit learn* dengan kernel *linear*.
- Pembagian Data**
Langkah selanjutnya adalah membagi data menjadi data training dan data testing. Data training digunakan untuk melatih model klasifikasi yang telah dibuat, sementara data

testing digunakan untuk menguji kinerja model yang telah dibuat. Dalam penelitian ini, data training dan data testing dibagi dengan rasio 90:10, 80:20, dan 70:30. Pembagian data dilakukan menggunakan fungsi *train_test_split* dari modul *sci-kit learn*.

- d. **Evaluasi Model**
 Pada tahap evaluasi model menggunakan data uji, nilai akurasi, presisi, *recall*, dan *f1-score* dibandingkan. Metrik-metrik ini dihitung menggunakan fungsi-fungsi seperti *accuracy_score*, *precision_score*, *recall_score*, dan *f1_score* dari library *scikit-learn*.
- e. **Prediksi**
 Pada langkah ini, setelah model dilatih dan dikonfigurasi dengan baik, model digunakan untuk melakukan prediksi pada data baru. Metode *predict* digunakan untuk memproyeksikan label berdasarkan ciri-ciri dari data yang belum diketahui.
- f. **Validasi Silang (Cross-validation)**
 Untuk memastikan keandalan model pada langkah ini dilakukan validasi silang dengan membagi dataset menjadi beberapa lipatan dan melatih serta menguji model pada setiap lipatan. Hal ini dilakukan untuk membantu menghindari *overfitting* dan memberikan perkiraan yang lebih realistis tentang performa model pada data baru.
- g. **Interpretasi Hasil**
 Setelah melakukan prediksi langkah selanjutnya adalah menginterpretasikan hasilnya dan mengambil tindakan yang sesuai berdasarkan kebutuhan.


Pada tahapan pemodelan ini dilakukan inisiasi terhadap dua algoritma klasifikasi yaitu NBC dan SVM. Dataset yang digunakan sejumlah 1.244 setelah melalui tahapan *preprocessing text*. Selanjutnya dataset dipisah antara data latih dan data uji dengan uji coba perbandingan 90:10; 80:20, dan 70:30 untuk setiap algoritma.

Pada gambar 5 di bawah adalah visualisasi hasil klasifikasi sentiment dengan metode NBC, yang telah diberikan label positif, negatif dan netral.



Gambar 5. Pemodelan Algoritma NBC

Pada gambar 6 berikut adalah visualisasi hasil klasifikasi sentimen dengan metode SVM, yang telah diberikan label positif, negatif dan netral.



Gambar 6. Pemodelan Algoritma SVM

3.3. Evaluasi

3.3.1. Pengujian dengan Confusion Matrix

Pada tahap ini, dilakukan eksperimen dengan membagi data menjadi dua subset: data untuk pembelajaran dan data untuk validasi. Di bawah ini adalah tabel hasil dari data pembelajaran yang akan diklasifikasikan menggunakan NBC dan SVM, dengan total 1.244 data. Eksperimen ini menggunakan beberapa perbandingan komposisi data untuk mencari nilai perbandingan terbaik antara data latih dan data uji, dengan tujuan mencapai akurasi tertinggi untuk penelitian yang dilakukan.

1. Pengujian dengan komposisi 90:10

a. Metode NBC

Pada Tabel 11 merupakan hasil pengujian menggunakan metode NBC dengan komposisi data latih dan data uji 90:10.

Tabel 11. Confusion Matrix NBC 90:10

		Confusion Matrix		
		0	1	2
Aktual Negatif	Negatif (0)	6	3	0
	Netral (1)	5	26	4
	Positif (2)	5	6	69

Pada Tabel 12 merupakan nilai akurasi, presisi, *recall*, dan *f1-score*.

Tabel 12. Nilai Akurasi NBC 90:10

	Precision	Recall	F1-Score	Support
Negatif	37.50%	66.67%	48.00%	9
Netral	74.29%	74.29%	74.29%	35
Positif	94.52%	86.25%	90.20%	80
Accuracy			81.45%	
Macro avg	68.77%	75.73%	70.83%	124
Weighted avg	84.67%	81.45%	82.64%	

b. Metode SVM

Pada Tabel 13 merupakan pengujian menggunakan metode SVM dengan komposisi data latih dan data uji 90:10.

Tabel 13. Confusion Matrix SVM 90:10

		Confusion Matrix		
		0	1	2
Aktual Negatif	Negatif (0)	3	1	1
	Netral (1)	4	29	4
	Positif (2)	0	5	78

Pada Tabel 14 merupakan nilai akurasi, presisi, *recall*, dan *f1-score*.

Tabel 14. Nilai Akurasi SVM 90:10

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Negatif	42.86%	60.00%	50.00%	5
Netral	82.86%	78.38%	80.56%	37
Positif	93.98%	93.98%	93.98%	83
Accuracy			88.00%	
Macro avg	73.23%	77.45%	74.84%	125
Weighted avg	88.64%	88.00%	88.24%	

Hasil percobaan pertama dengan komposisi 90:10 diperoleh hasil bahwa untuk tingkat akurasi yang tertinggi dihasilkan oleh algoritma SVM dengan nilai akurasi sebesar 88,00%, yang kedua adalah algoritma NBC dengan nilai akurasi sebesar 81,45%.

2. Pengujian dengan komposisi 80:20

a. Metode NBC

Pada Tabel 15 merupakan hasil pengujian menggunakan metode NBC dengan komposisi data latih dan data uji 80:20.

Tabel 15. Confusion Matrix NBC 80:20

		<i>Confusion Matrix</i>		
		0	1	2
Aktual Negatif	Negatif (0)	13	5	0
	Netral (1)	9	46	12
	Positif (2)	10	14	139

Pada Tabel 16 merupakan nilai akurasi, presisi, recall, dan *f1-score* dari NBC dengan data uji 80:20.

Tabel 16. Nilai Akurasi NBC 80:20

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Negatif	40.63%	72.22%	52.00%	18
Netral	70.77%	68.66%	69.70%	67
Positif	92.05%	85.28%	88.54%	163
Accuracy			79.84%	
Macro avg	67.82%	75.39%	70.08%	248
Weighted avg	82.57%	79.84%	80.79%	

b. Metode SVM

Pada Tabel 17 merupakan hasil pengujian metode SVM dengan komposisi data latih dan data uji 80:20.

Tabel 17. Confusion Matrix SVM 80:20

		<i>Confusion Matrix</i>		
		0	1	2
Aktual Negatif	Negatif (0)	9	3	1
	Netral (1)	8	61	5
	Positif (2)	1	10	151

Pada Tabel 18 merupakan nilai akurasi, presisi, recall, dan *f1-score*.

Tabel 18. Nilai Akurasi SVM 80:20

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Negatif	50.00%	69.23%	58.06%	13
Netral	82.43%	82.43%	82.43%	74
Positif	96.18%	93.21%	94.67%	162
Accuracy			88.76%	
Macro avg	76.20%	81.62%	78.39%	249
Weighted avg	89.68%	88.76%	89.12%	

Hasil percobaan kedua dengan komposisi 80:20 diperoleh hasil bahwa untuk tingkat akurasi yang tertinggi dihasilkan oleh algoritma SVM dengan nilai akurasi sebesar 88,76%, yang kedua adalah algoritma NBC dengan nilai akurasi sebesar 79,84%.

3. Pengujian dengan komposisi 70:30

a. Metode NBC

Pada Tabel 19 merupakan pengujian metode NBC dengan komposisi data latih dan data uji 70:30.

Tabel 19. Confusion Matrix NBC 70:30

		<i>Confusion Matrix</i>		
		0	1	2
Aktual Negatif	Negatif (0)	20	7	0
	Netral (1)	12	70	21
	Positif (2)	14	19	209

Pada Tabel 20 merupakan nilai akurasi, presisi, recall, dan *f1-score*.

Tabel 20. Nilai Akurasi NBC 70:30

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Negatif	43.48%	74.07%	54.79%	27
Netral	72.92%	67.96%	70.35%	103
Positif	90.87%	86.36%	88.56%	242
Accuracy			80.38%	
Macro avg	69.09%	76.13%	71.24%	372
Weighted avg	82.46%	80.38%	81.07%	

b. Metode SVM

Pada Tabel 21 merupakan hasil pengujian menggunakan metode SVM dengan komposisi data latih dan data uji 70:30.

Tabel 21. Confusion Matrix SVM 70:30

		<i>Confusion Matrix</i>		
		0	1	2
Aktual Negatif	Negatif (0)	16	4	2
	Netral (1)	13	92	5
	Positif (2)	2	18	222

Pada Tabel 22 merupakan nilai akurasi, presisi, recall, dan *f1-score*.

Tabel 22. Nilai Akurasi SVM 70:30

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Negatif	51.61%	72.73%	60.38%	22
Netral	80.70%	83.64%	82.14%	110
Positif	96.94%	91.74%	94.27%	242
Accuracy			88.24%	
Macro avg	76.42%	82.70%	78.93%	374
Weighted avg	89.50%	88.24%	88.71%	

Hasil percobaan kedua dengan komposisi 70:30 diperoleh hasil bahwa untuk tingkat akurasi yang tertinggi dihasilkan oleh algoritma SVM dengan nilai akurasi sebesar 88,24%, yang kedua adalah algoritma NBC dengan nilai akurasi sebesar 80,38%.

4. DISKUSI

4.1. Analisis Hasil Pengujian

Pada Tabel 23 merupakan hasil eksperimen perbandingan komposisi antara data latih dan data uji tersebut, terlihat bahwa algoritma SVM memberikan tingkat akurasi yang lebih tinggi daripada algoritma NBC dan Decision Tree.

Tabel 23. Hasil Percobaan Perbandingan Data

Percobaan Perbandingan Data	Nilai Akurasi	
	Naïve Bayes	SVM
90:10	81.45%	88.00%
80:20	79.84%	88.76%

70:30	80.38%	88.24%
-------	--------	--------

Dari ketiga pengujian diatas dapat diketahui bahwa algoritma yang terbaik adalah SVM dengan komposisi data latih dan data uji 80:20. Pada Tabel 24 merupakan hasil perbandingan dilihat dari nilai presisi, *recall*, dan *f1-score*.

Tabel 24. Hasil Pengujian Terbaik

Algoritma		Percobaan Perbandingan Data		
		90:10	80:20	70:30
Naïve Bayes	<i>Precision</i>	84.67%	82.57%	82.46%
	<i>Recall</i>	81.45%	79.84%	80.38%
	<i>F1-Score</i>	82.64%	80.79%	81.07%
SVM	<i>Precision</i>	88.64%	89.68%	89.50%
	<i>Recall</i>	88.00%	88.76%	88.24%
	<i>F1-Score</i>	88.24%	89.12%	88.71%

Dari hasil pengujian pada Tabel 24, didapat hasil bahwa algoritma SVM memiliki nilai akurasi tertinggi sebesar 88,76%, nilai presisi tertinggi sebesar 89,68%, *recall* sebesar 88,76%, dan *f1-score* sebesar 89,12%. Jika hasil dari studi ini dibandingkan dengan penelitian sebelumnya yang dilakukan oleh Cahyana dan Siregar (2023), NBC menghasilkan akurasi 86,94% dengan nilai presisi rata-rata 96,24% dan *recall* 86,66%. Di sisi lain, penggunaan SVM menghasilkan akurasi lebih tinggi sebesar 90,81% [21]. Hermanto, dkk (2020) mempelajari algoritma klasifikasi Naïve Bayes dan SVM dalam menangani Keluhan Mahasiswa, dengan akurasi mencapai 69,75% untuk NBC dan lebih tinggi sebesar 84,45% untuk SVM [22]. Dari kedua penelitian tersebut memperoleh hasil yang sama dengan yang dilakukan oleh peneliti bahwa algoritma SVM lebih baik untuk mengklasifikasi objek yang diteliti.

5. KESIMPULAN

Dengan menggunakan dataset yang tersedia dan telah memiliki penilaian, pemodelan klasifikasi menggunakan NBC dan SVM telah terbukti mampu mengklasifikasikan sentimen pengguna TIK menjadi tiga kelas: positif, netral, dan negatif. Selanjutnya, model klasifikasi yang dihasilkan dapat digunakan sebagai masukan bagi pengambil keputusan. Berdasarkan hasil percobaan dengan menggunakan 3 model perbandingan data training dan data testing, diperoleh nilai akurasi SVM lebih baik dari pada Naïve Bayes.

DAFTAR PUSTAKA

- [1] F. Valentinus, F. Sujono, I. Ariansyah, and D. A. H. Capah, "Implementation Of Data Mining With Classification And Forecasting Method Use Model Gaussian Naïve Bayes For Building Store (Studi Case: TB Sinar Jaya)," *J. Tek. Inform.*, vol. 4, no. 2, pp. 413–420, 2023, doi: 10.52436/1.jutif.2023.4.2.701.
- [2] M. I. P. Hant and H. Hendry, "Data Mining Technique Using Naïve Bayes Algorithm To Predict Shopee Consumer Satisfaction Among Millennial Generation," *J. Tek. Inform.*, vol. 3, no. 4, pp. 829–838, 2022, doi: 10.20884/1.jutif.2022.3.4.295.
- [3] Y. Jumaryadi, M. Fajri, and B. Priambodo, "Evaluasi Kualitas Sistem Informasi Akademik Dengan Webqual dan IPA," *J. Inf. Syst.*, vol. 7, no. 2, pp. 99–106, 2022, doi: 10.33633/joins.v7i2.6187.
- [4] M. P. Cendana, H. Syafwan, and Rohminatin, "Application of Customer Relationship Management (CRM) To Increase Sales at UD Ulong Pian," *J. Tek. Inform.*, vol. 3, no. 3, pp. 543–552, 2022, doi: 10.20884/1.jutif.2022.3.3.238.
- [5] D. Fatmawati, W. Trisnawati, Y. Jumaryadi, and G. Triyono, "Klasifikasi Tingkat Kepuasan Penggunaan Layanan Teknologi Informasi Menggunakan Decision Tree," *KLIK Kaji. Ilm. Inform. dan Komput.*, vol. 3, no. 6, pp. 1056–1062, 2023, doi: 10.30865/klik.v3i6.803.
- [6] V. K. S. Que, A. Iriani, and H. D. Purnomo, "Analisis Sentimen Transportasi Online Menggunakan Support Vector Machine Berbasis Particle Swarm Optimization," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 9, no. 2, pp. 162–170, 2020, doi: 10.22146/jnteti.v9i2.102.
- [7] A. Nursalim and R. Novita, "Sentiment Analysis of Comments on Google Play Store, Twitter and Youtube To the Mypertamina Application With Support Vector Machine," *J. Tek. Inform.*, vol. 4, no. 6, pp. 1305–1312, 2023, doi: 10.52436/1.jutif.2023.4.4.801.
- [8] D. Taluke, R. S. M. Lakat, A. Sembel, E. Mangrove, and M. Bahwa, "Analisis Preferensi Masyarakat Dalam Pengelolaan Ekosistem Mangrove Di Pesisir Pantai Kecamatan Loloda Kabupaten Halmahera Barat," *Spasial*, vol. 6, no. 2, pp. 531–540, 2019.
- [9] M. Ramzy and B. Ibrahim, "User satisfaction with Arabic COVID-19 apps: Sentiment analysis of users' reviews using machine learning techniques," *Inf. Process. Manag.*, vol. 61, no. 3, p. 103644, 2024, doi: 10.1016/j.ipm.2024.103644.
- [10] M. P. Yuliani and I. N. Suarmanayasa, "Pengaruh Harga Dan Online Consumer Review terhadap Keputusan Pembelian Poduk pada Marketplace Tokopedia," *Prospek J. Manaj. dan Bisnis*, vol. 3, no. 2, pp. 146–154, 2021.
- [11] R. Puspitasari, Y. Findawati, and M. A. Rosid, "Sentiment Analysis Of Post-Covid-19 Inflation Based On Twitter Using The K-Nearest Neighbor And Support Vector

- Machine Classification Methods,” *J. Tek. Inform.*, vol. 4, no. 4, pp. 1–11, 2023, doi: 10.52436/1.jutif.2023.4.4.801.
- [12] L. N. K. Pasi and B. Sudaryanto, “Analisis Pengaruh Online Customer Reivews Dan Kualitas Pelayanan Terhadap Keputusan Pembelian Dengan Kepercayaan Sebagai Variabel Intervening (Studi Pada Konsumen Shopee Di Kota Semarang),” *Diponegoro J. Manag.*, vol. 10, no. 3, pp. 1–12, 2021.
- [13] N. Colmekcioglu, R. Marvi, P. Foroudi, and F. Okumus, “Generation, susceptibility, and response regarding negativity: An in-depth analysis on negative online reviews,” *J. Bus. Res.*, vol. 153, no. August, pp. 235–250, 2022, doi: 10.1016/j.jbusres.2022.08.033.
- [14] A. Muzaki and A. Witanti, “Sentiment Analysis of the Community in the Twitter To the 2020 Election in Pandemic Covid-19 By Method Naive Bayes Classifier,” *J. Tek. Inform.*, vol. 2, no. 2, pp. 101–107, 2021, doi: 10.20884/1.jutif.2021.2.2.51.
- [15] Y. Yunitasari, A. Musdholifah, and A. K. Sari, “Sarcasm Detection For Sentiment Analysis in Indonesian Tweets,” *IJCCS (Indonesian J. Comput. Cybern. Syst.)*, vol. 13, no. 1, p. 53, 2019, doi: 10.22146/ijccs.41136.
- [16] G. Manik, I. Ernawati, and I. Nurlaili, “Analisis Sentimen Pada Review Pengguna E-Commerce Bidang Pangan Menggunakan Metode Support Vector Machine (Studi Kasus: Review Sayurbox dan Tanihub pada Google Play),” in *Prosiding Seminar Nasional Mahasiswa Bidang Ilmu Komputer dan Aplikasinya*, 2021, vol. 2, no. 2, pp. 64–74.
- [17] A. Isnanda, Y. Umidah, and J. H. Jaman, “Implementasi Naïve Bayes Classifier Dan Information Gain Pada Analisis Sentimen Penggunaan E-Wallet Saat Pandemi,” *J. Teknol. Inform. dan Komput.*, vol. 7, no. 2, pp. 144–153, 2021, doi: 10.37012/jtik.v7i2.648.
- [18] R. Kusnadi, Y. Yusuf, A. Andriantony, R. Ardian Yaputra, and M. Caintan, “Analisis Sentimen Terhadap Game Genshin Impact Menggunakan Bert,” *Rabit J. Teknol. dan Sist. Inf. Univrab*, vol. 6, no. 2, pp. 122–129, 2021, doi: 10.36341/rabit.v6i2.1765.
- [19] D. Septiani and I. Isabela, “Analisis Term Frequency Inverse Document Frequency (Tf-Idf) Dalam Temu Kembali Informasi Pada Dokumen Teks,” *SINTESIA J. Sist. dan Teknol. Inf. Indones.*, vol. 1, no. 2, pp. 81–88, 2022.
- [20] S. M. Fani, R. Santoso, and S. Suparti, “Penerapan Text Mining Untuk Melakukan Clustering Data Tweet Akun Bibli Pada Media Sosial Twitter Menggunakan K-Means Clustering,” *J. Gaussian*, vol. 10, no. 4, pp. 583–593, 2021, doi: 10.14710/j.gauss.v10i4.30409.
- [21] Y. Cahyana and A. Mutoi Siregar, “Analisis Sentimen Pindah Ibu Kota Negara (IKN) Baru pada Twitter Menggunakan Algoritma Naive Bayes dan Support Vector Machine (SVM),” *Fakt. Exacta*, vol. 16, no. 3, pp. 1979–276, 2023, doi: 10.30998/faktorexacta.v16i3.16703.
- [22] H. Hermanto, A. Mustopa, and A. Y. Kuntoro, “Algoritma Klasifikasi Naive Bayes Dan Support Vector Machine Dalam Layanan Komplain Mahasiswa,” *JITK (Jurnal Ilmu Pengetah. dan Teknol. Komputer)*, vol. 5, no. 2, pp. 211–220, 2020, doi: 10.33480/jitk.v5i2.1181.