



Implementation of the K-Nearest Neighbors Algorithm for Sentiment Analysis on Aladin Bank Application Reviews

Implementasi Algoritma K-Nearest Neighbors dalam Analisis Sentimen Ulasan Aplikasi Bank Aladin

**Taniya Raisha Dwiva Putri¹, M. Rudi Sanjaya^{2*},
MGS Afriyan Firdaus³, Dwi Rosa indah⁴**

¹Program Studi Sistem Informasi, Fakultas Ilmu Komputer, Universitas Sriwijaya, Indonesia

E-Mail: ¹taniyaraisha@gmail.com, ²m.rudi.sjy@ilkom.unsri.ac.id
³afriyan_firdaus@unsri.ac.id, ⁴indah812@unsri.ac.id

Received Feb 11th 2026; Revised Mar 16th 2026; Accepted Mar 27th 2026; Available Online Apr 19th 2026

Corresponding Author: M. Rudi Sanjaya

Copyright ©2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

The digital transformation of Aladin Bank Syariah has elicited diverse Google Play Store reviews, covering both practical aspects and technical constraints. To comprehend this opinion polarity, this research conducts a user sentiment evaluation using the K-Nearest Neighbors (KNN) classification algorithm. The analysis categorizes reviews into positive, neutral, and negative classes using 80% of the scraped data, with a limit of 6,000 TF-IDF features. The evaluation reveals an accuracy of 86.71%, with the model demonstrating strong capability for identifying positive sentiment (F1-score 0.93) and fair performance on negative sentiment (F1-score 0.68). Despite the suboptimal detection of the neutral class (F1-score 0.08), the overall average score of 0.86 signifies the model's general effectiveness. Bank management can optimize these findings as a basis for evaluating and improving their digital banking service quality.

Keywords: Aladin Bank, K-Nearest Neighbors (KNN), Reviews, Sentiment Analysis

Abstrak

Digitalisasi layanan Aladin Bank Syariah melahirkan variasi ulasan di Google Play Store yang mencakup aspek kepraktisan hingga permasalahan teknis aplikasi. Guna memahami polaritas opini tersebut, penelitian ini melakukan evaluasi sentimen pengguna dengan memanfaatkan metode klasifikasi *K-Nearest Neighbors* (KNN). Proses analisis melibatkan pengelompokan ulasan ke dalam kelas positif, netral, dan negatif menggunakan 80% data hasil *scraping*, yang diproses melalui pembatasan 6.000 fitur pembobotan TF-IDF. Pengujian model mencatatkan tingkat akurasi sebesar 86,71%, di mana algoritma menunjukkan keunggulan signifikan dalam mengidentifikasi sentimen positif (*F1-score* 0,93) dan berkinerja cukup baik pada sentimen negatif (*F1-score* 0,68). Walaupun pengenalan terhadap kelas netral masih belum maksimal (*F1-score* 0.08), perolehan nilai rata-rata keseluruhan adalah 0.86, yang mengindikasikan efektivitas model secara umum. Temuan riset ini dapat dioptimalkan oleh manajemen bank sebagai landasan evaluasi untuk menyempurnakan kualitas layanan perbankan digital mereka.

Kata Kunci: Analisis Sentimen, Bank Aladin, K-Nearest Neighbors (KNN), Ulasan

1. PENDAHULUAN

Pengembangan aplikasi *mobile* adalah salah satu tren yang mengalami perubahan signifikan. Kondisi ini terjadi karena adanya peningkatan penggunaan internet yang cukup pesat. Menurut Badan Pusat Statistik Indonesia (BPS) tahun 2024, persentase penduduk Indonesia yang mengakses layanan internet meningkat menjadi 72,78% dibandingkan dengan tahun 2021 sebesar 62,1% [1]. Hal ini membuat Indonesia menjadi negara dengan penetrasi internet *mobile* tertinggi. Salah satu perusahaan yang ikut serta dalam perkembangan ini adalah PT Bank Aladin Syariah Tbk. yang mengembangkan aplikasi Aladin Bank Syariah Digital berbasis *mobile*. Di industri perbankan nasional, Bank Aladin Syariah tercatat sebagai salah satu inisiator layanan keuangan syariah yang sepenuhnya beroperasi secara digital. Bank Aladin memiliki visi untuk meningkatkan inklusi keuangan dengan menerapkan strategi omnichannel yang mengintegrasikan layanan daring dan

luring, serta mengoptimalkan pemanfaatan teknologi dalam pengembangan pasar ekonomi syariah [2]. Aplikasi Bank Aladin Syariah menyediakan berbagai layanan perbankan secara daring, seperti pembukaan rekening, transaksi keuangan, serta pengelolaan layanan perbankan syariah tanpa memerlukan kunjungan ke kantor cabang. Kemudahan akses dan efisiensi layanan yang ditawarkan menjadikan aplikasi ini banyak digunakan oleh masyarakat. Hal tersebut tercermin dari capaian PT Bank Aladin Syariah yang berhasil memperoleh lebih dari 1 juta pengguna terdaftar hingga 30 September 2022 sejak aplikasi diluncurkan pada awal tahun 2022 [3]. Namun, pemanfaatan teknologi digital dalam layanan perbankan juga memunculkan sejumlah permasalahan, khususnya terkait keamanan data, privasi pengguna, serta keandalan sistem aplikasi. Fenomena tersebut menunjukkan bahwa perkembangan teknologi perbankan digital melalui aplikasi Aladin berbasis *mobile* berpotensi menimbulkan beragam persepsi di kalangan pengguna. Berbagai pandangan dan penilaian terhadap aplikasi Aladin tersebut banyak disampaikan melalui ulasan dan penilaian pengguna di *Google Play Store*. Ulasan dapat berisi pendapat, kesan, atau saran yang berkaitan dengan kualitas, fitur, kinerja produk atau layanan tersebut [4]. Beberapa pengguna menyampaikan keluhan terkait permasalahan teknis, seperti kendala *login*, gangguan transaksi, keterbatasan fitur, tampilan pengalaman pengguna yang kaku, serta pemblokiran akun. Di sisi lain, masih terdapat pengguna yang memberikan ulasan positif karena merasakan kemudahan, kecepatan, dan manfaat layanan perbankan syariah digital yang ditawarkan. Namun, volume data yang sangat besar serta keragaman bahasa membuat analisis manual menjadi tidak efisien [5]. Oleh karena itu, diperlukan analisis sentimen terhadap ulasan pengguna aplikasi Aladin Bank Syariah Digital untuk mengetahui kecenderungan opini pengguna, sehingga hasilnya dapat dimanfaatkan sebagai bahan evaluasi bagi pihak perusahaan serta menjadi referensi bagi calon pengguna dalam mengambil keputusan penggunaan aplikasi tersebut.

Secara teoritis, pendekatan ini mensinergikan teknik *Natural Language Processing* (NLP) dengan algoritma *Machine Learning* (ML) guna mengidentifikasi serta membedah polaritas perasaan yang terkandung dalam dokumen teks [6]. Pendekatan komputasional ini memungkinkan sistem untuk memilah opini ke dalam kelas positif, negatif, maupun netral secara otomatis [7]. Bagi korporasi, wawasan yang digali dari sentimen pelanggan sangat esensial dalam merumuskan strategi bisnis. Sentimen positif yang dominan akan menguatkan citra perusahaan dan memicu pertumbuhan unduhan, sebaliknya, sentimen negatif berisiko menggerus reputasi aplikasi jika tidak segera ditangani. Beberapa riset terdahulu telah membuktikan efektivitas NLP dalam ranah klasifikasi teks. Studi oleh Rizal Chandra Rivaldi, dkk. (2024) mengaplikasikan algoritma *Logistic Regression* pada ulasan produk Zalika Store 88 di Shopee, menghasilkan tingkat akurasi 87% dengan dominasi sentimen positif [8]. Dalam penelitian berbeda yang mengevaluasi ulasan aplikasi Telegram, penggunaan pendekatan *Naïve Bayes* menghasilkan skor akurasi yang cukup signifikan, yakni sebesar 85,31% [9]. Lebih lanjut, studi komparatif pada analisis sentimen aplikasi X mengungkapkan bahwa algoritma *K-Nearest Neighbors* (KNN) memiliki performa klasifikasi yang lebih unggul dibandingkan *Naïve Bayes* [10]. Ketangguhan algoritma ini juga didukung oleh penelitian Depari, Tania, dan Sevtiyuni (2025), di mana KNN bersama SVM, *XGBoost*, dan *Random Forest* mencatatkan skor evaluasi yang sangat baik (0,94) dalam prediksi penyakit diabetes [11]. Fleksibilitas dan ketangguhan KNN dalam ranah analisis sentimen turut dibuktikan dari sebuah riset pada jurnal internasional oleh Benarafa dkk. (2023), yang berhasil meningkatkan performa klasifikasi teks ulasan dengan mengoptimalkan perhitungan jarak (*distance computation*) KNN, menjadikannya lebih adaptif dalam menangani masalah *overfitting* dan *underfitting*. Namun, mengingat karakteristik teks ulasan yang bersifat dinamis, tidak terstruktur, serta memiliki variasi bahasa yang tinggi, pemilihan metode KNN menjadi memiliki urgensi teknis yang lebih relevan dibandingkan *Naive Bayes Classifier* (NBC) dan *Support Vector Machine* (SVM). KNN mampu mengklasifikasikan data berdasarkan kedekatan karakteristik antardokumen, sehingga lebih adaptif terhadap perubahan pola kata, gaya penulisan, maupun konteks makna yang sering muncul dalam ulasan pengguna. Berbeda dengan NBC yang bergantung pada asumsi independensi antarfitur sehingga kurang optimal dalam menangkap hubungan semantik antar kata, serta SVM yang memerlukan proses optimasi parameter dan representasi fitur yang lebih kompleks, KNN menawarkan pendekatan yang lebih fleksibel dan mudah diterapkan pada dataset dengan distribusi yang heterogen. Selain itu, dalam kondisi jumlah data yang tidak terlalu besar namun memiliki keragaman ekspresi bahasa yang tinggi, KNN cenderung mampu memberikan hasil klasifikasi yang lebih kontekstual karena mempertimbangkan kemiripan langsung antar data [12]. Berbekal temuan-temuan tersebut, penelitian ini mengadopsi kerangka NLP dengan memilih algoritma *K-Nearest Neighbors* (KNN) sebagai model klasifikasi sentimen utama.


Berdasarkan uraian di atas, belum ada penelitian yang berfokus pada model algoritma *K-Nearest Neighbors* (KNN) khususnya terhadap ulasan pengguna pada aplikasi Bank Aladin. Sebagian besar studi terdahulu cenderung mengandalkan algoritma *Support Vector Machine* (SVM) atau *Naïve Bayes* dalam proses klasifikasinya. Namun, mengingat karakteristik teks ulasan yang dinamis dan tidak terstruktur, pemilihan KNN memiliki urgensi teknis yang lebih relevan. Algoritma KNN dikenal karena kesederhanaan dan efektivitasnya dalam mengelompokkan data berdasarkan kedekatan antartitik dalam ruang fitur [13]. Kemampuan ini membuat KNN lebih unggul dalam menangkap konteks kalimat secara utuh tanpa terjebak pada asumsi independensi kata seperti pada *Naïve Bayes*, serta menghindari kompleksitas komputasi model

black-box seperti pada SVM. Berangkat dari kondisi tersebut, penelitian ini diarahkan untuk mengimplementasikan algoritma *K-Nearest Neighbors* (KNN) guna membedah sentimen pada ulasan Aladin Bank Syariah Digital di *Google Play Store*, sekaligus menguji sejauh mana tingkat akurasi yang dihasilkan oleh model tersebut. Kebaruan penelitian ini terletak pada evaluasi klasifikasi sentimen ulasan aplikasi Aladin dengan tiga kelas (positif, netral, negatif), penggunaan 80% data dari total keseluruhan data ulasan yang berhasil diambil dengan teknik *scraping*, yaitu sekitar 24.103 dataset ulasan. Peneliti menggunakan pembagian data sebesar 80% untuk data latih dan 20% untuk data uji [14]. Hasil yang didapatkan akan merepresentasikan keseluruhan ulasan yang diberikan oleh pengguna aplikasi Aladin, yang nantinya dapat dimanfaatkan oleh perusahaan dalam meningkatkan kualitas pelayanan, kenyamanan, dan kepercayaan nasabahnya.

2. METODE PENELITIAN

Riset ini mengadopsi desain penelitian kuantitatif deskriptif sebagai landasan utama untuk menjabarkan peta sentimen pengguna terhadap layanan aplikasi Aladin Bank Syariah Digital. Pendekatan ini dipilih karena kemampuannya dalam memberikan gambaran yang terukur dan objektif mengenai kecenderungan opini publik melalui representasi data numerik. Dalam implementasinya, penelitian ini mengintegrasikan ketangguhan algoritma *K-Nearest Neighbors* (KNN) dengan teknik komputasi statistik. Seluruh rangkaian eksperimen dan pemodelan dalam riset ini dieksekusi menggunakan lingkungan pengembangan komputasi berbasis awan, yaitu Google Colaboratory. Sinergi dari algoritma dan infrastruktur tersebut akan sangat efektif untuk memproses volume *dataset* teks yang berskala masif, mengekstraksi informasi dari data ulasan yang tidak terstruktur, serta memilah polaritas sentimen nasabah ke dalam klasifikasi kelas yang telah ditentukan secara sistematis.

Operasionalisasi dari kerangka kerja komputasional tersebut diwujudkan melalui serangkaian alur penelitian yang terstruktur. Pasca penetapan dan identifikasi masalah, tahapan teknis diawali dengan proses pengumpulan data ulasan (*scraping*), yang kemudian dilanjutkan dengan tahap anotasi atau pelabelan kelas sentimen pada setiap dokumen teks. Data mentah tersebut selanjutnya dibersihkan dan dinormalisasi melalui tahapan *preprocessing* agar siap dieksekusi pada fase pemodelan utama menggunakan algoritma KNN. Namun, sebelum masuk ke fase pemodelan menggunakan algoritma KNN, data hasil *preprocessing* akan di bagi terlebih dahulu dengan rasio pembagian yang digunakan dalam penelitian ini adalah 80:20, yaitu 80% untuk data latih dan 20% untuk data uji. Setelah klasifikasi dilakukan, kinerja model divalidasi melalui tahapan evaluasi hasil untuk mengukur tingkat akurasinya. Sebagai bentuk representasi visual pendukung, hasil akhir analisis diekstraksi menggunakan instrumen *wordcloud* guna memudahkan interpretasi terhadap kata-kata yang paling dominan muncul dalam ulasan. Rincian keseluruhan alur tahapan penelitian tersebut direpresentasikan secara komprehensif pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1. Algoritma *K-Nearest Neighbors* (KNN)

Algoritma *K-Nearest Neighbors* (KNN) diimplementasikan untuk menganalisis data [15]. Dalam menentukan label klasifikasi, algoritma KNN bekerja dengan cara mengukur jarak suatu data uji terhadap k buah data latih terdekatnya, di mana kelas dengan proporsi terbanyak akan dipilih sebagai hasil prediksi akhir. *K-Nearest Neighbors* (KNN) melakukan komputasi berdasarkan kedekatan jarak terhadap k observasi terdekat, lalu menetapkan kelas berdasarkan jumlah pola yang paling sering muncul [4]. Jumlah data latih dan nilai k harus ditentukan secara tepat, dimana k harus bernilai ganjil dan lebih dari satu. Untuk

menghitung jarak antara dua objek, digunakan rumus jarak *Euclidean* yang ditunjukkan pada Persamaan 1 [16].

$$d(x, y) = \sum_{i=1}^n (x_i - y_i)^2 \quad (1)$$

Implementasi model KNN pada data ulasan mencakup beberapa tahapan sistematis, diawali dengan transformasi teks melalui teknik pembobotan *Tf-idf*. Setelah proses ekstraksi fitur selesai, data didistribusikan ke dalam dua kelompok utama, yakni data pelatihan untuk membangun model dan data pengujian untuk mengevaluasi performanya.

Persamaan yang digunakan untuk menghitung bobot (*Tf-idf*) masing-masing dokumen terhadap kata kunci ditunjukkan pada Persamaan 2 [17].

$$W_{a,t} = t f_{dt} * IDF \quad (2)$$

Keterangan:

W = bobot dokumen ke - n
d = dokumen kata kunci
t = kata kunci
tf = *terms frequency* (jumlah kemunculan kata)
IDF = *Inverse Document Frequency*

Nilai *tf* diperoleh dari Persamaan 3.

$$t f_d = \frac{\text{Jumlah munculnya kata } t \text{ dalam dokumen}}{\text{Total jumlah seluruh kata dalam dokumen}} \quad (3)$$

Nilai IDF didapatkan dengan Persamaan 4.

$$IDF = \frac{d}{df} \quad (4)$$

Keterangan:

d = total dokumen, dalam hal ini total kalimat yang ada
df = jumlah dokumen yang mengandung kata kunci

Setelah proses *Tf-idf* selesai, dilakukan pemisahan dataset di mana 80% dialokasikan untuk fase pembelajaran model dan 20% untuk fase evaluasi. Pembagian proporsional ini ditujukan agar model yang dikembangkan mampu menghasilkan tingkat akurasi yang optimal, yakni minimal sebesar 70%. Model KNN kemudian dilatih menggunakan porsi data pelatihan tersebut, yang dilanjutkan dengan fase pengujian performa menggunakan data uji. Selama keseluruhan proses pengujian ini, dilakukan proses pencarian parameter terbaik dengan menguji performa model pada rentang nilai *k* ganjil antara 3 sampai dengan 31 untuk menentukan nilai *k* yang paling optimal.

2.2. Evaluasi Model

Evaluasi terhadap performa algoritma klasifikasi dalam penelitian ini diukur menggunakan pendekatan *confusion matrix*. Secara konseptual, metode ini berfungsi sebagai instrumen untuk memvalidasi presisi dan efektivitas sebuah model dalam memprediksi kelas data dengan cara membandingkan antara kelas asli dengan nilai prediksi [4]. Tahap evaluasi performa model klasifikasi dalam penelitian ini diimplementasikan berdasarkan *confusion matrix* dengan meninjau empat indikator utama, yakni *accuracy*, *precision*, *recall*, dan *f1-score* [18]. Evaluasi berbasis *confusion matrix* ini diukur melalui empat metrik representasi kelas, yang terdiri dari *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Berikut rumus dari metrik evaluasi yang digunakan [19]:

1. Accuracy

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (1)$$

2. Precision

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

3. *Recall*

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

4. *F1- score*

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \times 100\% \quad (4)$$

3. HASIL DAN PEMBAHASAN

3.1. *Scrapping*


Tahap pengumpulan data dijalankan menggunakan teknik *scrapping* untuk menghimpun data sekunder berupa ulasan aplikasi Bank Aladin di *Google Play Store* melalui ID “*id.aladinbank.mobile*”. Sistem penarikan data dikonfigurasi untuk membatasi riwayat ulasan hingga batas waktu 28 Februari 2026. Berdasarkan kriteria tersebut, total ulasan mentah yang berhasil dihimpun mencapai 30.129 data. Selanjutnya, penelitian ini memfokuskan penarikan pada 80% ulasan mutakhir dari total populasi tersebut, yang secara otomatis mereduksi ukuran data menjadi 24.103 ulasan siap diolah. Tabel 1 menunjukkan dataset yang berhasil dihimpun dengan teknik *scrapping*.

Tabel 1. Dataset Ulasan Aplikasi Aladin

	Review ID	Score	Waktu	Ulasan	Sentiment
0	2d8b2632-e293-42f7-937	1	2026-02-27 19:33:58	jujur saya karyawan alfa baru kali ini Aladin ...	Negatif
1	5722d29d-6138-4971-ab0f	5	2026-02-27 16:48:33	ok Aladin	Positif
2	f859d459-fb95-4c81-be15	5	2026-02-27 16:19:37	oke	Positif
3	8e5b41b9-9d45-4110-9c9b	3	2026-02-27 15:32:52	mohon penjelasannya dari pihak terkait tentang...	Netral
4	3a854481-fa51-46e6-bb87	1	2026-02-27 14:33:12	sering gangguan	Negatif
...	...	...	...	...	...
24098	8f03be97-6160-424f-8f44	5	2022-06-19 22:45:08	Okee	Positif
24099	fb429b42-62be-4d6d-8bb1	5	2022-06-19 21:36:15	mantap	Positif
24100	28ad40f9-df29-49ec-98f3	2	2022-06-19 19:29:39	Loh ko bonus referal 15000 nya gk masuk sih gm...	Negatif
24101	659f2c72-afd4-4f7f-baad	4	2022-06-19 18:53:50	Gk bisa di buka	Positif
24102	5ebb5470-b6f9-4056-b490	5	2022-06-19 18:52:18	Sangat membantu	Positif

3.2. *Pelabelan Data*

Pelabelan data dilakukan berdasarkan nilai rating yang diberikan oleh pengguna pada ulasan aplikasi Aladin di *Google Play Store*. Sebelum itu, dilakukan analisis distribusi yang diambil dari rating aplikasi untuk mengidentifikasi pola penilaian pengguna aplikasi Aladin, di mana karakteristik dari puluhan ribu data ulasan tersebut dipetakan menggunakan *barchart* sebagaimana diilustrasikan pada Gambar 2. Visualisasi distribusi *rating* ini memiliki peran penting dalam mengukur indikator kepuasan pengguna secara garis besar, serta memvalidasi kesesuaian antara nilai rating dengan kecenderungan sentimen pengguna sehingga penentuan label tidak dilakukan secara spekulatif. Berdasarkan pola distribusi tersebut, teknik pelabelan *rule-based labeling* ini menetapkan *threshold* (ambang batas) sebagai acuan, yaitu rating 1-2 dikategorikan sebagai sentimen negatif, rating 3 sebagai sentimen netral, dan rating 4-5 sebagai sentimen positif. Pendekatan ini memastikan transformasi data dari nilai numerik menjadi label sentimen dilakukan secara konsisten, objektif, dan relevan dengan tingkat kepuasan yang dinyatakan oleh nasabah.



Gambar 2. Distribusi Rating Ulasan Aplikasi Aladin

3.3. Preprocessing Data

Tahap *pre-processing* pada penelitian ini meliputi proses *cleaning*, *case folding*, *normalizing*, *tokenizing*, *stopword*, dan *stemming*. Proses *cleaning* meliputi pembersihan dataset yang berisi karakter non-ASCII dan pembersihan data duplikat sehingga teks ulasan menjadi lebih terstruktur. Total data keseluruhan setelah melalui proses *cleaning* adalah 22.397 data dari 24.037 data ulasan. Proses *case folding* bertujuan untuk mengubah seluruh teks menjadi huruf kecil di kolom teks ulasan yang sudah dilakukan *cleaning*.

Setelah proses tersebut, dilakukan proses untuk membuat kata menjadi lebih terstruktur sesuai dengan ejaan baku, yaitu proses normalisasi. Proses ini menggunakan fungsi *replace_taboo_words* untuk mengubah setiap kolom ulasan yang berisi kata tidak baku menjadi kata baku berdasarkan kamus kata baku. Data seperti kata tidak baku seperti 'gimana' akan diubah menjadi kata bakunya, yaitu 'bagaimana'. Kata tidak baku yang lain seperti 'ngk', 'yg', 'tgl brp', 'pake', dan 'kereceen' juga akan diubah berturut-turut menjadi kata baku 'tidak', 'yang', 'tanggal berapa', 'pakai', dan 'keren' pada proses normalisasi.

Tahap pemrosesan teks setelah normalisasi adalah *tokenizing*, yang bertujuan mengekstraksi setiap kalimat ulasan menjadi entitas kata individual (token). *Stopword* merupakan kata-kata umum yang sering muncul dalam teks, namun tidak memberikan kontribusi signifikan terhadap makna atau analisis sentimen. Dalam penelitian ini, daftar *stopword* diperoleh dari bahasa Indonesia menggunakan *library* NLTK, kemudian ditambahkan beberapa kata yang sering muncul pada ulasan aplikasi, seperti "*aplikasi*", "*bank*", dan "*aladin*", yang dianggap kurang relevan untuk dianalisis lebih lanjut.

Stemming pada penelitian ini menggunakan *library* Sastrawi, yaitu pustaka yang digunakan khusus untuk tahap pemrosesan bahasa Indonesia dalam menyederhanakan variasi kata menjadi bentuk dasar yang memiliki makna sama. Pemakaian kata seperti 'pendaftaran' dan 'menyusahkan' diganti berturut-turut menjadi kata 'daftar' dan 'susah'.

3.4. Pembobotan Kata


Tahap ini memanfaatkan hasil *split* data 80% data latih dan 20% data uji. Data ulasan diketahui masing-masing sekitar 17.843 data digunakan untuk data latih, dan sekitar 4.461 data digunakan untuk data uji. Pembatasan jumlah fitur yang digunakan sebanyak 6.000 kata unik yang paling relevan untuk merepresentasikan numerik teks pada *Tf-idf* sehingga proses analisis lebih efisien. Hasilnya, muncul kata 'mudah' seperti pada Gambar 3 yang memiliki bobot tertinggi, diikuti oleh 'bagus', 'tidak', 'transaksi', dan 'aman'. Hal ini menunjukkan bahwa ulasan pengguna banyak membahas kemudahan penggunaan, kualitas layanan, serta aspek keamanan dan transaksi, dan hanya satu kata yang memiliki bobot tertinggi yang bersifat negatif.

3.5. Implementasi K-Nearest Neighbors (KNN) dan Evaluasi Model


Penelitian ini menggunakan model klasifikasi *K-Nearest Neighbors* (KNN) dan *confusion matrix* sebagai evaluasi model KNN. Penggunaan model algoritma ini dimanfaatkan dengan melakukan *training* pada data latih yang dihasilkan pada tahap sebelumnya. Pengujian nilai *k* bertujuan untuk mencari jarak yang memiliki nilai terbaik untuk proses pemodelan dataset. Nilai *k* terbaik dapat dicari dengan melakukan iterasi pengujian model KNN dalam rentang 1-20. Selisih perbedaan akurasi tertinggi yang akan digunakan menjadi nilai *k* terbaik. Hasil dari pengujian nilai *k* terbaik dapat dilihat pada Gambar 4.

Berdasarkan grafik pada Gambar 4 diatas, terlihat bahwa peningkatan nilai *k* memberikan pengaruh positif terhadap performa model hingga titik tertentu. Nilai *k*=1 memiliki akurasi yang masih berada pada kisaran terendah, kemudian mengalami kenaikan yang sangat signifikan pada nilai *k*=3 yang ditandai sebagai

lonjakan terbesar. Titik ini diidentifikasi sebagai lonjakan akurasi (*accuracy gain*) terbesar, di mana model mulai mampu mengenali pola data dengan lebih baik.



Gambar 3. Hasil Pembobotan Kata



Gambar 4. Pengujian Nilai k Terbaik

Meskipun nilai akurasi terus mengalami peningkatan secara bertahap dan relatif stabil mulai dari $k=5$ sampai $k=19$, namun kenaikannya tidak lagi terlalu tajam dan cenderung melandai. Nilai akurasi tertinggi memang diperoleh pada k lebih besar (sekitar $k=19$), namun hasil akurasinya tidak terlalu jauh dibandingkan k sebelumnya. Fenomena ini menunjukkan bahwa penggunaan nilai k yang terlalu rendah cenderung mengakibatkan pemodelan rentan terhadap gangguan data (*noise*), sementara penggunaan parameter k yang lebih tinggi juga tidak memberikan dampak performa yang sebanding dengan beban komputasi yang dibutuhkan. Oleh karena itu, penelitian ini menetapkan $k=3$ sebagai nilai optimal karena mewakili titik keseimbangan terbaik antara peningkatan akurasi yang tajam, kestabilan prediksi, dan efisiensi komputasi model.

```
from sklearn.neighbors import KNeighborsClassifier

knn = KNeighborsClassifier(
    n_neighbors=3,
    metric='cosine',
    weights='distance'
)

knn.fit(X_train, y_train)
```

Gambar 5. Parameter K -Nearest Neighbors

Pada Gambar 5 tersebut, kode digunakan untuk membangun model kategori opini atau sentimen dengan algoritma KNN. Model diinisialisasi melalui kelas `KNeighborsClassifier` dengan beberapa parameter utama, yaitu `n_neighbors=3`, `metric='cosine'`, dan `weights='distance'`. Parameter `n_neighbors=3` menunjukkan bahwa proses penentuan kelas suatu data dilakukan dengan mempertimbangkan 3 tetangga terdekat. Pemilihan nilai ini bertujuan untuk memperoleh keseimbangan antara bias dan varian dalam model. Metode *cosine* ini digunakan untuk mengukur tingkat kemiripan arah antarvektor dan dinilai sesuai untuk data teks yang telah direpresentasikan dalam bentuk *Tf-idf*, karena mekanisme kerjanya lebih menitikberatkan pada representasi pola kemunculan kata dalam dokumen, dibandingkan dengan hanya mempertimbangkan intensitas nilai absolut secara mentah. Sementara itu, parameter `weights='distance'` memberikan bobot lebih besar kepada tetangga yang jaraknya lebih dekat, sehingga data yang paling mirip memiliki pengaruh lebih dominan dalam proses penentuan kelas.

Evaluasi performa menjadi tahapan esensial setelah model KNN berhasil dilatih menggunakan data latih. Proses ini bertujuan untuk memvalidasi ketangguhan algoritma dalam memprediksi label sentimen pada data uji baru. Melalui penjabaran *confusion matrix*, hasil evaluasi akan merepresentasikan secara spesifik frekuensi ketepatan prediksi dan tingkat kesalahan model untuk tiap-tiap kelas sentimen.

Merujuk pada hasil pemaparan Tabel 2, pengujian model KNN mencatatkan tingkat akurasi keseluruhan di angka 86.71%. Pencapaian ini mengindikasikan bahwa dari total 4.461 sampel data uji, algoritma mampu memprediksi label sentimen secara presisi pada persentase tersebut. Secara garis besar, performa ini dapat dikategorikan memuaskan. Walau demikian, tinjauan yang lebih komprehensif terhadap indikator *precision*, *recall*, serta *F1-score* pada masing-masing kategori kelas tetap krusial untuk membedah kinerja model secara objektif.

Khusus untuk sentimen positif (3.554 data), model memperlihatkan keandalan yang sangat optimal dengan perolehan *precision* 0.93, *recall* 0.94, dan *F1-score* 0.93. Angka *recall* yang tinggi menegaskan ketajaman sistem dalam mengenali hampir seluruh ulasan positif. Di saat yang sama, tingginya *precision* membuktikan bahwa hasil prediksi pada kelas ini terbukti valid. Kesuksesan algoritma dalam menangkap pola teks positif ini sangat erat kaitannya dengan proporsi data latih yang mayoritas merujuk pada kategori tersebut.

Sementara itu, evaluasi pada 762 data bersentimen negatif menghasilkan *precision* 0.69, *recall* 0.66, dan *F1-score* 0.68. Kinerja pada kelas ini terbilang cukup stabil, kendati masih ditemui beberapa kasus misklasifikasi teks ke label yang salah. Berbanding terbalik dengan hal tersebut, kapabilitas prediksi pada kelas netral (145 data) tampak kurang optimal, ditandai dengan *precision* 0.10, *recall* 0.06, dan *F1-score* 0.08. Nilai *recall* yang minim menjadi indikator bahwa model kerap keliru memprediksi ulasan netral ke dalam kelas sentimen yang berbeda. Fenomena ini merupakan konsekuensi logis dari ketimpangan jumlah data (*data imbalance*), di mana minimnya sampel ulasan netral membuat algoritma gagal mempelajari karakteristik teks pada kelas tersebut secara maksimal.

Lebih jauh, perolehan *macro average* pada rentang 0.56 hingga 0.57 merepresentasikan rerata performa model antarkelas tanpa memihak pada kuantitas data. Di sisi lain, skor *weighted average* yang menyentuh angka 0.86 – 0.87 sangat dipengaruhi oleh kuatnya dominasi kelas positif yang memiliki volume data masif. Fakta statistik ini secara gamblang menjawab mengapa akurasi model secara keseluruhan tampak impresif, meskipun keandalannya dalam mendeteksi kelas netral masih sangat terbatas.

Tabel 2. *Classification Report* pada Model KNN

	Precision	Recall	F1-score	Support
Negatif	0.69	0.66	0.68	762
Netral	0.10	0.06	0.08	145
Positif	0.92	0.94	0.93	3554
Macro avg	0.57	0.56	0.56	4461
Weighted avg	0.86	0.87	0.86	4461
Total Accuracy			= 86,71%	4461

Visualisasi pada Gambar 6 menyajikan hasil *confusion matrix* yang diekstraksi dari pemodelan KNN dengan batasan 6.000 fitur pembobotan *Tf-idf*. Melalui penjabaran matriks tersebut, tingkat ketepatan model dalam mengelompokkan tiap kelas sentimen dipetakan secara rinci dengan membandingkan kesesuaian antara label target aktual dan hasil prediksi algoritma. Pada baris pertama (kelas negatif), terlihat bahwa dari 762 data negatif, sebanyak 504 berhasil diprediksi dengan benar sebagai negatif. Namun, terdapat 51 data yang salah diprediksi sebagai netral dan 207 data yang keliru diklasifikasikan sebagai positif. Hal ini terjadi karena adanya penggunaan kosakata yang bersifat ambigu, seperti ulasan yang mengandung kritik namun tetap menggunakan kata sifat positif seperti 'bagus'. Dalam pembobotan *Tf-idf*, kata 'bagus' memiliki bobot tinggi yang dapat mengecoh model KNN untuk menarik data tersebut ke arah kluster positif.

Pada baris kedua (kelas netral), performa model terlihat paling rendah. Dari keseluruhan 145 sampel berlabel netral, algoritma hanya mampu mengidentifikasi 9 data secara akurat. Sebaliknya, terjadi

[illegible]

Pada Gambar 8, kata-kata yang paling mendominasi dengan ukuran terbesar adalah ‘ganggu’, ‘susah’, dan ‘gagal’. Dominasi kata-kata tersebut mengindikasikan adanya hambatan signifikan dalam pengalaman pengguna, terutama terkait aspek fungsionalitas dan reliabilitas sistem. Kata ‘ganggu’ dan ‘gagal’ sering kali merujuk pada kendala teknis saat menjalankan perintah tertentu, sementara kata ‘susah’ mencerminkan tingkat kesulitan atau kompleksitas yang dirasakan pengguna dalam berinteraksi dengan aplikasi. Kehadiran kata-kata spesifik seperti ‘transfer’ dan ‘login’ yang berdampingan dengan kata ‘gagal’ menunjukkan bahwa isu utama sentimen negatif berpusat pada kegagalan transaksi keuangan dan kesulitan akses akun. Hal ini memberikan gambaran yang konsisten mengenai rasa frustrasi pengguna terhadap performa layanan.

Berdasarkan hasil analisis yang ada pada bab sebelumnya, hasil dari penelitian model algoritma *K-Nearest Neighbors* (KNN) untuk menganalisis sentimen ulasan Aplikasi Aladin dikatakan mampu mengklasifikasikan dengan baik. Nilai akurasi yang didapat sebesar 86,71% untuk analisis 80% data ulasan keseluruhan aplikasi. Performa terbaik ditunjukkan pada kelas positif dengan *precision* 0.92, *recall* 0.94, dan *F1-score* 0.93, yang merepresentasikan performa pemodelan yang sangat baik dalam mengenali sentimen positif. Pada kelas negatif, model menghasilkan *precision* 0.69, *recall* 0.66, dan *F1-score* 0.68, sehingga dapat dikatakan cukup mampu mengklasifikasikan data negatif meskipun masih terdapat kesalahan prediksi. Sementara itu, pada kelas netral, performa model tergolong rendah dengan *precision* 0.10, *recall* 0.06, dan *F1-score* 0.08, yang menunjukkan bahwa model masih mengalami kesulitan dalam membedakan sentimen netral dari kelas lainnya. Secara keseluruhan, meskipun nilai *weighted average* menunjukkan hasil yang baik yaitu *precision* 0.86, *recall* 0.87, dan *F1-score* 0.86, ketidakseimbangan performa antarkelas, khususnya pada kelas netral, menjadi aspek yang perlu diperhatikan untuk pengembangan model selanjutnya.

617

REFERENSI

- [1] N. F. A. Syakilah, Adriyani; Maharani, Karmila; Saifullah, *Statistik Telekomunikasi Indonesia 2024*. ©Badan Pusat Statistik, 2025. [Online].
<https://www.bps.go.id/id/publication/2025/08/29/beaa2be400eda6ce6c636ef8/statistik-telekomunikasi-indonesia-2024.html>
- [2] H. Shabri, N. Azlina, and M. Said, “Transformasi digital industri perbankan syariah Indonesia,” *El-Kahfi| J. Islam. Econ.*, vol. 3, no. 02, 2022.
- [3] Bank Aladin Syariah, “Laporan Tahunan,” Aladin Bank. [Online]. Available: <https://aladinbank.id/laporan-tahunan/>
- [4] A. Adiansyah, “Analisis Sentimen Pada Ulasan Aplikasi Home Credit Dengan Metode SVM dan K-NN,” *J. Komput. Antart.*, vol. 1, no. 4, pp. 174–181, 2023.
- [5] M. R. S. Sanjaya, D. R. Indah, and E. L. Ruskan, “Hybrid Fine-Tuning Indobert Dan Hybrid Fine-Tuning Indobert Dan Ensemble Tf-Idf Logistic Regression Untuk Analisis Sentimen Ulasan Aplikasi Zalora,” *Rabit J. Teknol. dan Sist. Inf. Univrab*, vol. 11, no. 1, pp. 324–336, 2026.
- [6] D. Purnamasari *et al.*, *Pengantar Metode Analisis Sentimen*, 1st ed. Gunadarma Penerbit, 2023.
- [7] S. H. Majidah and P. Hendikawati, “Analisis Sentimen Program Makan Bergizi Gratis Menggunakan Svm Dan Knn Dengan Tf-Idf Dan Tf-Abs,” *E-Jurnal Mat.*, vol. 15, no. 1, pp. 1–9, 2026.
- [8] R. C. Rivaldi and T. D. Wismarini, “Analisis Sentimen Pada Ulasan Produk Dengan Metode Natural Language Processing (NLP):(Studi Kasus Zalika Store 88 Shopee),” *Elkom J. Elektron. dan Komput.*, vol. 17, no. 1, pp. 120–128, 2024.
- [9] N. Nurwanda, N. Suarna, and W. Prihartono, “Penerapan Nlp (Natural Language Processing) Dalam Analisis Sentimen Pengguna Telegram Di Playstore,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 8, no. 2, pp. 1841–1846, 2024.
- [10] E. S. Y. P. Pandie and A. F. Fanggidae, “Perbandingan Naïve Bayes dan K-NN dalam Analisis Sentimen Aplikasi X,” *J. Transform.*, vol. 22, no. 2, pp. 97–107, 2025.
- [11] A. D. Sembiring Depari, K. D. Tania, and P. E. Sevtiyuni, “Penerapan Metode Machine Learning Dan Teknik SMOTE untuk Prediksi Diabetes,” *J. Sist. Komput. dan Inform.*, vol. 7, no. 2 SE-Articles, pp. 436–447, Dec. 2025, doi: 10.30865/json.v7i2.9032.
- [12] H. Benarafa, M. Benkhalifa, and M. Akhloufi, “WordNet Semantic Relations Based Enhancement of KNN Model for Implicit Aspect Identification in Sentiment Analysis,” *Int. J. Comput. Intell. Syst.*, vol. 16, no. 1, pp. 1–14, 2023, doi: 10.1007/s44196-022-00164-8.
- [13] M. Febima, U. Solihin, L. Magdalena, M. Hatta, M. Asfi, and S. Christina, “Analisis Sentimen Aplikasi PaDi UMKM dengan Peningkatan Kinerja Algoritma KNN,” *J. Digit Digit. Inf. Technol.*, vol. 15, no. 2, pp. 70–82, 2025.
- [14] B. W. Widagdo, M. R. Fadillah, M. A. Adiguna, S. Wiharjo, and M. Handayani, “Implementation of Split Sampling for Decision Tree and K-Nearest Neighbor Algorithms in the DKI Jakarta Legislative Election,” *J. Penelit. Inov.*, vol. 5, no. 4, pp. 2979–2986, 2025.
- [15] N. Alvionika, S. Faisal, R. Rahmat, and A. F. N. Masruriyah, “Analisis Sentimen Pada Komentar Instagram Provider By. U Menggunakan Metode K-Nearest Neighbors (KNN),” *J. Algoritm.*, vol. 21, no. 2, pp. 50–63, 2024.
- [16] M. I. Mubarak, P. Purwantoro, and C. Carudin, “Penerapan Algoritma K-Nearest Neighbor (Knn) Dalam Klasifikasi Penilaian Jawaban Ujian Esai,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 7, no. 5, pp. 3446–3452, 2023.
- [17] Y. Findawati and R. M. Alfian, *Buku Ajar Text Mining*, Cetakan pe. UMSIDA Press, 2020.
- [18] S. Lestari and S. Febrianti, “Analisis Sentimen Ulasan Produk Shopee di Aplikasi Instagram Menggunakan Algoritma K-Nearest Neighbors,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 4, pp. 1172–1180, 2025.
- [19] W. R. As’ ari, M. Arifin, D. L. Fithri, and P. Setiaji, “Analisis Sentimen Ulasan Pengguna Aplikasi Spotify Di Google Play Store Menggunakan Algoritma Naive Bayes,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 2, pp. 3600–3607, 2025.