

# Eksplorasi Sentimen Pengguna Media Sosial Terhadap Layanan Seabank: Pendekatan Dengan Algoritma Bert

Riska Kurnia Septiani<sup>1\*</sup>, Windu Gata<sup>2</sup>

Ilmu Komputer, Universitas Nusa Mandiri, Jakarta, Indonesia

\*e-mail *Corresponding Author*: 14220021@nusamandiri.ac.id

## Abstract

*Bank SeaBank is a digital bank that has social media accounts on Twitter (X) and YouTube with thousands of followers. These platforms are often used to express opinions or comments on various topics. This research aims to provide a benchmark for Bank SeaBank to improve its services based on positive and negative user reviews. The data analyzed consists of 500 comments on Twitter (X) and YouTube with the keyword "Bank SeaBank." The methods used include machine learning algorithms such as SVM, Naïve Bayes, k-NN, Decision Tree, Logistic Regression, as well as the deep learning algorithm pre-trained BERT. The analysis results show the highest accuracy for SVM at 84%, followed by Naïve Bayes at 81%, k-NN at 80%, and both Decision Tree and Logistic Regression at 77%. The deep learning algorithm BERT achieved an accuracy of 86% with 3 epochs and a training-to-testing data ratio of 80:20.*

**Kata kunci:** *SeaBank; Social media; BERT algorithm*

## Abstrak

Bank SeaBank adalah salah satu bank digital yang memiliki media sosial *Twitter (X)* dan *YouTube* dengan ribuan pengikut. Kedua platform ini sering digunakan untuk menyampaikan pendapat atau komentar tentang berbagai topik. Penelitian ini bertujuan untuk memberikan tolak ukur bagi Bank SeaBank dalam meningkatkan layanan berdasarkan ulasan positif dan negatif dari pengguna. Data yang dianalisis terdiri dari 500 komentar di *Twitter (X)* dan *YouTube* dengan kata kunci "Bank SeaBank". Metode yang digunakan mencakup algoritma *machine learning* seperti SVM, *Naïve Bayes*, *k-NN*, *Decision Tree*, *Logistic Regression*, serta algoritma *deep learning pre-trained BERT*. Hasil analisis menunjukkan akurasi tertinggi pada SVM sebesar 84%, diikuti oleh *Naïve Bayes* sebesar 81%, *k-NN* sebesar 80%, *Decision Tree* dan *Logistic Regression* masing-masing sebesar 77%. Algoritma *deep learning BERT* mencapai akurasi 86% dengan 3 epoch dan proporsi data latih dan uji sebesar 80:20

**Kata Kunci:** *SeaBank; Media Sosial; Algoritma BERT*

## 1. Pendahuluan

Evaluasi kinerja sistem perbankan sangat penting karena bank memegang peran krusial dalam stabilitas dan pertumbuhan ekonomi sebuah negara. Sebagai lembaga yang menangani transaksi finansial, simpanan, dan pemberian kredit, sistem perbankan yang efisien dan efektif berkontribusi pada keamanan finansial individu dan bisnis. Dengan sistem yang berjalan optimal, bank dapat menjaga kepercayaan nasabah, meminimalisir risiko keuangan, dan meningkatkan efisiensi operasional. Evaluasi kinerja perbankan memungkinkan identifikasi kelemahan dalam proses operasional dan layanan yang diberikan, serta mendeteksi area yang memerlukan perbaikan. Proses evaluasi ini juga menyediakan data yang sangat berguna untuk pengambilan keputusan strategis, baik dalam hal pengembangan produk, pelayanan nasabah, maupun kebijakan internal. Dengan hasil evaluasi yang akurat, bank dapat merancang strategi yang lebih baik untuk meningkatkan layanan, mengurangi risiko operasional, dan akhirnya meningkatkan kepuasan nasabah. Hal ini berkontribusi pada stabilitas ekonomi yang lebih luas, mendorong pertumbuhan ekonomi yang berkelanjutan, dan memastikan integritas sistem keuangan secara keseluruhan.

Kemajuan teknologi telah mengubah cara kerja sebagian besar bisnis, baik komersial maupun non-komersial, termasuk layanan perbankan. Kehadiran Bank Digital memperkenalkan cara inovatif untuk menyediakan berbagai layanan keuangan kepada nasabah, sebagai bentuk inovasi dalam dunia perbankan. Bank digital memungkinkan nasabah untuk melakukan transaksi

perbankan kapan saja dan di mana saja, menggantikan pertemuan tatap muka. Selain itu, berbagai operasi perbankan seperti transfer dana, investasi, pembayaran, dan pemeriksaan rekening rutin dapat dilakukan secara online, menawarkan alternatif yang lebih cepat dan efisien dibandingkan dengan mengunjungi kantor cabang [1].

Bank SeaBank adalah salah satu bank digital yang berkembang pesat dengan ribuan pengikut di platform media sosial seperti *Twitter (X)* dan *YouTube*. Mengingat banyaknya interaksi nasabah melalui media sosial, penting untuk melakukan evaluasi terhadap kinerja layanan bank ini. Ulasan dan komentar dari nasabah di media sosial dapat mencerminkan pengalaman nyata pengguna dengan layanan SeaBank. Oleh karena itu, evaluasi terhadap ulasan ini dianggap perlu untuk memahami persepsi nasabah dan mengidentifikasi area yang memerlukan peningkatan. Hal ini akan membantu SeaBank dalam memperbaiki kualitas layanan dan mempertahankan kepercayaan nasabah di pasar yang kompetitif. SeaBank Indonesia memiliki akun resmi di berbagai platform media sosial, termasuk YouTube dengan username SeaBank Indonesia, *TikTok* dengan username @seabank\_id, dan *Instagram* dengan username @seabank.id, serta akun *Twitter (X)* dengan username @SeabankID yang memiliki 50,1 ribu pengikut.



Gambar 1. Akun *Twitter (X)* SeaBank Indonesia

Solusi yang diusulkan adalah melakukan analisis ulasan pelanggan dari platform media sosial untuk memahami persepsi nasabah terhadap layanan SeaBank. Pendekatan ini memungkinkan identifikasi area perbaikan berdasarkan umpan balik langsung. Penelitian sebelumnya mendukung efektivitas metode ini; misalnya penelitian [2] menunjukkan akurasi tinggi pada analisis sentimen dengan SVM. Dengan menerapkan analisis ulasan, SeaBank dapat memperoleh wawasan berharga yang akan membantu dalam perbaikan layanan dan pengambilan keputusan yang lebih baik.

Penelitian ini bertujuan untuk mengklasifikasikan atau menggabungkan ulasan positif dan negatif pengguna Bank SeaBank di *YouTube* dan *Twitter (X)*. Bank SeaBank dapat menggunakan penelitian ini sebagai tolak ukur untuk meningkatkan layanan pelanggan mereka berdasarkan ulasan positif dan negatif.

## 2. Tinjauan Pustaka

Beberapa penelitian telah dilakukan terkait analisis sentimen, di mana para peneliti telah menggunakan sejumlah metode klasifikasi yang beragam untuk menangani permasalahan ini.

Penelitian ini dilakukan oleh Ratna Andini Husen dan kawan-kawan yang di publikasikan pada tahun 2023 dengan judul "Analisis Sentimen Opini Publik pada Twitter Terhadap Bank BSI Menggunakan Algoritma Pembelajaran Mesin". Mengumpulkan data tweet dari situs *Kaggle*, sebanyak 24.401 data tweet tentang ulasan komentar pengguna tentang *ransomware* pada Bank BSI. Hasil percobaan menunjukkan bahwa SVM memiliki akurasi 0,88%, *naive bayes* 0,76%, dan

*logistic regression* 0,86%. Ini menunjukkan bahwa SVM memiliki kinerja yang lebih baik daripada kedua algoritma *naive bayes* dan *logistic regression* [3].

Penelitian ini dilakukan oleh Indriya Dewi Onantya dan kawan - kawan yang di publikasikan pada tahun 2019 dengan judul "Analisis Sentimen Pada Ulasan Aplikasi BCA Mobile Menggunakan BM25 dan *Improved K-Nearest Neighbor*", penelitian ini menggunakan 500 data BCA Mobile, yang dibagi menjadi 400 data latihan dan 100 data uji. Hasil evaluasi dari pengujian lima kali ganda menunjukkan nilai k terbaik sebesar 10, dengan ketepatan sebesar 0,946, recall sebesar 0,934, nilai f sebesar 0,939, dan ketepatan sebesar 0,942 [4].

Penelitian ini dilakukan oleh Alun Sujjada dan kawan - kawan yang di publikasikan pada tahun 2023 dengan judul "Analisis Sentimen Terhadap *Review* Bank Digital Pada *Google Play Store* Menggunakan Metode *Support Vector Machine* (SVM)". Penelitian ini mengumpulkan 1500 data ulasan dari tiga aplikasi bank digital berbeda; data ulasan dibagi menjadi 80% data latihan dan 20% data uji. Hasil pengujian dengan metode *Support Vector Machine* menunjukkan bahwa bank digital Seabank mendapatkan rata-rata akurasi sebesar 91%. Dari penelitian ini dapat diketahui bahwa bank digital Seabank memiliki presentase tanggapan positif lebih banyak diantara yang lainnya [5].

Penelitian ini dilakukan oleh Nanda Fibriyanti Arminda dan kawan - kawan yang di publikasikan pada tahun 2023 dengan judul "Implementasi Algoritma *Multinomial Naïve Bayes* pada Analisis Sentimen Terhadap Ulasan Pengguna Aplikasi BRIMO". Hasilnya menunjukkan bahwa, dari 1011 data dalam dataset total, 670 data dikategorikan sebagai sentimen negatif dan 341 data dikategorikan sebagai sentimen positif. Dengan demikian, dapat disimpulkan bahwa hasil ulasan pengguna aplikasi BRIMO didominasi oleh sentimen negatif, dengan hasil evaluasi dari algoritma *Naïve bayes* dalam mengklasifikasikan sentimen ulasan pengguna BRIMO mendapatkan hasil terbaik pada fold-2 dengan nilai akurasi 98,02%, presisi 97,06%, recall 97,06%, dan f1-score 97,06% [6].

Penelitian ini dilakukan oleh Kurnia dan kawan - kawan yang di publikasikan pada tahun 2022 dengan judul "Analisis Sentimen dengan Metode *Naïve Bayes*, *SMOTE* dan *Adaboost* pada Twitter Bank BTN." Hasil penelitian menunjukkan bahwa kombinasi *SMOTE*, *Naïve Bayes*, dan *Adaboost* memberikan hasil pemodelan terbaik dengan akurasi sebesar 87.05%, presisi sebesar 90.63%, recall sebesar 83.00%, dan AUC sebesar 0.909 [7].

Penelitian ini akan menggunakan berbagai algoritma pembelajaran mesin seperti *Support Vector Machine*, *Naive Bayes*, KNN, *Decision Tree*, dan *Logistic Regression*. Selain itu, akan digunakan algoritma *deep learning* seperti BERT (*Bidirectional Encoder Representations from Transformers*). Untuk mendapatkan pemahaman yang lebih baik tentang efektivitas masing-masing algoritma dalam konteks yang diteliti, penelitian ini akan membandingkan kinerja algoritma-algoritma tersebut dengan menggunakan metrik evaluasi yang relevan seperti akurasi, presisi, *recall*, skor F1, dan mungkin juga AUC-ROC.

### 3. Metodologi

BERT (*Bidirectional Encoder Representations from Transformers*) digunakan sebagai metode klasifikasi dalam penelitian ini. Proses pengumpulan data, pelabelan data, dan *preprocessing* adalah semua langkah yang diperlukan untuk mencapai hasil yang optimal. Ini adalah langkah-langkah yang dapat diamati.

#### 3.1. *Crawling Data*

Pada tahap awal penyelidikan, peneliti menemukan pertanyaan *YouTube* dan *tweet* untuk kumpulan data. Data untuk penelitian ini diperoleh dari Bank SeaBank's *Twitter (X)* dan layanan berbagi video *YouTube*. *Crawler* data dilakukan melalui *Application Programming Interface* (API).

#### 3.2. Analisa atau Labeling Data


Proses menganotasikan kumpulan data yang dikategorikan menjadi kelas sentimen negatif dan positif. Ini akan dilakukan dengan melalui tiga metode: manual, VADER, dan Text Blob.

#### 3.3. *Data Preprocessing*

*Preprocessing* data adalah metode perubahan data yang mencakup imputasi data dan validasi untuk mengevaluasi kelengkapan dan akurasi data untuk digunakan dalam proses

analisis berikutnya. Proses *preprocessing* mencakup pembersihan, pembongkaran case, tokenisasi, *stemming*, dan penghapusan *stopword* [8].

- 1) *Cleansing*  
Proses menghapus kata-kata yang tidak relevan dari data untuk meminimalkan gangguan.
- 2) *Case Folding*  
Semua kata dalam teks diubah menjadi huruf kecil, dan karakter selain huruf dihilangkan selama proses ini.
- 3) *Tokenizing*  
Kalimat dipecah menjadi token atau kata-kata tunggal dengan menggunakan spasi sebagai pembatas.
- 4) *Stemming*  
Kata-kata diubah kembali ke bentuk dasarnya atau bentuk baku.
- 5) *Stopword Removal*  
Kata-kata yang dianggap tidak penting dihapus dari data.



Gambar 2. Metode Penelitian

### 3.4. TF-IDF

Dalam pemrosesan bahasa alami, TF-IDF (*term frekuensi inversi dokumen frekuensi*) adalah skema pembobotan yang biasa digunakan untuk membedakan term dalam dokumen berdasarkan kepentingan atau keinformatifannya. Ini dapat dihitung sebagai hasil dari kedua *term frekuensi* (TF) dan *inverse document frekuensi* (IDF) [9]. *Inverse Document Frequency*, yang mengukur pentingnya sebuah istilah di seluruh kumpulan dokumen, dihitung dengan mengambil logaritma dari rasio antara total jumlah dokumen dengan jumlah dokumen yang mengandung istilah tersebut. *Term Frequency* mengukur seberapa penting sebuah istilah dalam sebuah dokumen tertentu, dan dihitung dengan membagi jumlah kemunculan istilah tersebut dengan total jumlah kata dalam dokumen tersebut.

### 3.5. Classification Model

Tahap klasifikasi sentiment publik menggunakan beberapa algoritma *machine learning* seperti SVM, *naive bayes*, KNN, *Decision Tree* dan *logistic regresion*.

1) Algoritma SVM (*Support Vector Machine*)

Algoritma pembelajaran SVM yaitu sebuah model *Supervised Learning* yang masih berkaitan dengan pengajaran algoritma yang melakukan analisis data untuk tujuan analisis regresi dan klasifikasi; dalam praktiknya, SVM banyak digunakan untuk masalah pengklasifikasian [10].

$$f(x) = \text{sign}(w \cdot x + b) \quad (1)$$

$w$  adalah vektor bobot  
 $x$  adalah vektor fitur *input*  
 $b$  adalah bias (*intercept*)  
 $\text{sign}$  menentukan kelas dari input

2) Algoritma *Naïve Bayes*

*Teorema Bayes*, yang diperkenalkan pertama kali oleh Thomas Bayes, merupakan konsep dasar yang digunakan dalam klasifikasi *Naïve Bayes*. *Naïve Bayes* merupakan metode klasifikasi yang menggunakan probabilitas yang sederhana, berakar pada *Teorema Bayes*, dan menganggap bahwa setiap kondisi atau kejadian memiliki tingkat ketidak tergantungan yang tinggi [11].

$$P(y|X) = \frac{P(X|y) \cdot P(y)}{P(x)} \quad (2)$$

$P(y|X)$  adalah probabilitas *posterior* dari kelas  $y$  yang diberikan fitur  $X$   
 $P(X|y)$  adalah probabilitas *likelihood* dari fitur  $X$  yang diberikan kelas  $y$   
 $P(y)$  adalah probabilitas *prior* dari kelas  $y$   
 $P(X)$  adalah probabilitas *evidence* dari fitur  $X$

## 3) Algoritma K-NN

*K-Nearest Neighbor* (K-NN) dilakukan dengan mencari kelompok  $k$  objek dalam data *training* yang paling dekat (mirip) dengan objek pada data baru atau data *testing*, diperlukan suatu sistem klasifikasi sebagai sebuah sistem yang mampu mencari informasi [12].

$$y = \text{mode}(y_{i1}, y_{i2}, \dots, y_{ik}) \quad (3)$$

$y$  adalah kelas prediksi  
 $y_{i1}, y_{i2}, \dots, y_{ik}$  adalah kelas dari  $k$  tetangga terdekat

4) Algoritma *Decision Tree*

Sebuah pohon adalah struktur data yang terdiri dari simpul-simpul (*nodes*) dan rusuk-rusuk (*edges*). Pada pohon, terdapat tiga jenis simpul: simpul akar (*root node*), simpul internal atau percabangan (*branch/internal node*), dan simpul daun (*leaf node*) [13].

$$G(S) = 1 - \sum_i^c = 1 - \left( P_i^2 \right) \quad (4)$$

$G(S)$  adalah gini *impurity* dari node  $S$   
 $c$  adalah jumlah kelas  
 $p_i$  adalah proporsi dari kelas  $i$  dalam node  $S$

5) Algoritma *Logistic Regression*

Ketika variable *dependen* (respon) adalah variabel dikotomi, analisis regresi logistik digunakan. Variabel dikotomi biasanya terdiri dari dua nilai, masing-masing menunjukkan kemunculan atau tidak adanya kejadian, dan biasanya diberi angka 0 atau 1 [14].

$$\begin{aligned} P(y = 1|x) &= \sigma(w \cdot x + b) \\ P(y = 0|x) &= 1 - \sigma(w \cdot x + b) \end{aligned} \quad (5)$$

$P(y = 1|x)$  adalah probabilitas bahwa *instance*  $x$  masuk ke dalam kelas positif  
 $P(y = 0|x)$  adalah probabilitas bahwa *instance*  $x$  masuk ke dalam kelas negatif

### 3.6. Bidirectional Encoder Representations from Transformers (BERT)

BERT dirancang untuk melatih representasi dalam dua arah teks tanpa label (*unsupervised*). Model BERT yang dilatih dapat dikonfigurasi dengan lapisan output tambahan untuk membuat model *multi-tasking* yang canggih. Model BERT juga dapat melakukan klasifikasi data berlabel (*supervised*). Mengacu pada Jacob Devlin, Ming-Wei Chang, Kenton Lee, dan Kristina Toutanova, algoritma BERT dirancang berdasarkan arsitektur *encoder Transformers* karena arsitektur *encoder* dapat menyelesaikan berbagai tugas seperti *Neural Machine Translation*, *Question Answering*, *Sentiment Analysis*, dan *Text Summarization* [15].

Untuk menilai performa, metrik yang digunakan adalah skor F1, akurasi, presisi, dan ingatan. Skor F1 secara definisi adalah *mean harmonik* dari akurasi dan ingatan, dan metrik yang menggabungkan presisi dan perolehan.

$$1 \text{ Score} = 2 \times \frac{\text{recall} \times \text{precision}}{\text{recall} + \text{precision}} \tag{6}$$

*Precision* adalah perbandingan antara jumlah observasi positif yang diprediksi dengan benar dan total prediksi positif. Untuk *precision*, berikut rumusnya:

$$\text{Precision} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}} \tag{7}$$

$$\text{Precision} = \frac{\text{True Positive}}{\text{Total Predicted Positive}} \tag{8}$$

Sensitivitas atau spesifisitas adalah istilah untuk perbandingan antara hasil yang diprediksi dengan benar dan total semua prediksi. Persamaan 9 dan 10 menjelaskan perumusan recall.

$$\text{Recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \tag{9}$$

$$\text{Recall} = \frac{\text{True Positive}}{\text{Total Actual Positive}} \tag{10}$$

Selanjutnya, tingkat keakuratannya dinilai untuk mengetahui hasil yang baik. Akurasi dapat dihitung dengan membagi presisi dengan perolehan atau dengan mengurangi tingkat negatif palsu (FNR) dibagi dengan tingkat positif palsu (FPR). Persamaan 11 menunjukkan cara menghitung akurasi.

$$\text{Accuracy} = \frac{(TP + TN)}{(TP + FN + TN + FN)} \tag{11}$$

## 4. Hasil dan Pembahasan

Hasil penelitian analisis akan menentukan desain sistem analisis sentimen.

### 4.1. Crawling Data

Data komentar ini dikumpulkan dari kedua media sosial, *Twitter (X)* dan *YouTube*. Pada media sosial *Twitter (X)*, *python* pada *google collab* dengan kata kunci "Bank SeaBank" digunakan, dan pada media sosial *YouTube*, kata kunci "Bank SeaBank" juga digunakan. Sebanyak lima ratus data komentar dikumpulkan melalui proses ini.

Table 1. Hasil *Crawling* Data Komentar

Username	Komentar
evercluest	@ssefnun Line bank bisa debit, seabank engga bisa. Kalo digital enak seabank. (Banyak promo)

Username	Komentar
Chet__2202	@cagyuu__ lagiannn lu ngapaiin nabung di seabank wkwk di bank beneran aja njir aman duit lu
Heiraaa3	Selain bunga tabungan juga free biaya admin (alias gaada potongan tiap bulan). Seabank juga ada gratis transfer ke semua rekening bank 100x/bulan. Untuk topup e-wallet juga sama gratisnya ya. Top up tagihan lainnya jg bisa (listrik, internet, dll), dan sudah dilengkapi dgn QRIS. <a href="https://t.co/Uzo5k34fDw">https://t.co/Uzo5k34fDw</a>
nowyseen	Struggle gw tf duit dari bank lokal ke seabank gagal trus knpa dah bikin kesel aja
ilhamazhar8624	jelas seabank sih kalo menurut saya.. kalo flip cuman gimmick, bilangny gratis tapi masih tetep bayar beberapa ratus rupiah.. kalo seabank fix nol rupiah..


#### 4.2. Analisa atau Labeling Data

Ada tiga metode yang dapat digunakan untuk menganalisis kumpulan data atau dataset menjadi kelas sentimen positif dan negatif: VADER, Text Blob, dan manual.

Table 2. Hasil Labeling

Username	Komentar	Label
evercluest	@sfeffnum Line bank bisa debit, seabank engga bisa. Kalo digital enak seabank. (Banyak promo)	Positif
Chet__2202	@cagyuu__ lagiannn lu ngapaiin nabung di seabank wkwk di bank beneran aja njir aman duit lu	Negatif
Heiraaa3	Selain bunga tabungan juga free biaya admin (alias gaada potongan tiap bulan). Seabank juga ada gratis transfer ke semua rekening bank 100x/bulan. Untuk topup e-wallet juga sama gratisnya ya. Top up tagihan lainnya jg bisa (listrik, internet, dll), dan sudah dilengkapi dgn QRIS. <a href="https://t.co/Uzo5k34fDw">https://t.co/Uzo5k34fDw</a>	Positif
nowyseen	Struggle gw tf duit dari bank lokal ke seabank gagal trus knpa dah bikin kesel aja	Negatif
ilhamazhar8624	jelas seabank sih kalo menurut saya.. kalo flip cuman gimmick, bilangny gratis tapi masih tetep bayar beberapa ratus rupiah.. kalo seabank fix nol rupiah..	Positif

Terdapat 306 data komentar positif dan 144 data komentar negatif dari 500 data komentar dari media sosial *Twitter (X)* dan *YouTube* melalui proses labeling manual.



Gambar 3. Grafik Hasil Proses Labeling

#### 4.3. Data Preprocessing

Pada tahapan ini, data akan melalui proses *cleansing*, *case folding*, *tokenizing*, *stemming* dan *Stopword Removal*.

##### 1) *Cleansing*

Proses membersihkan data dari kata—kata yang tidak memberikan penjelasan apa pun tentang cara menghilangkan gangguan dari data.

Table 3. Setelah Proses *Cleansing*

Sebelum <i>Cleansing</i>	Sesudah <i>Cleansing</i>
Selain bunga tabungan juga free biaya admin (alias gaada potongan tiap bulan). Seabank juga ada gratis transfer ke semua rekening bank 100x/bulan. Untuk topup e-wallet juga sama gratisnya ya. Top up tagihan lainnya jg bisa (listrik, internet, dll), dan sudah dilengkapi dgn QRIS. <a href="https://t.co/Uzo5k34fDw">https://t.co/Uzo5k34fDw</a> Struggle gw tf duit dari bank lokal ke seabank gagal trus knpa dah bikin kesel aja	Selain bunga tabungan juga free biaya admin alias gaada potongan tiap bulan Seabank juga ada gratis transfer ke semua rekening bank xbulan Untuk topup ewallet juga sama gratisnya ya Top up tagihan lainnya jg bisa listrik internet dll dan sudah dilengkapi dgn QRIS Struggle gw tf duit dari bank lokal ke seabank gagal trus knpa dah bikin kesel aja

2) *Case Folding*

Kata dalam teks diubah menjadi huruf kecil selama proses ini, dan karakter lain selain huruf dihilangkan.

Table 4. Setelah Proses *Case Folding*

Sebelum <i>Case Folding</i>	Sesudah <i>Case Folding</i>
Selain bunga tabungan juga free biaya admin (alias gaada potongan tiap bulan). Seabank juga ada gratis transfer ke semua rekening bank 100x/bulan. Untuk topup e-wallet juga sama gratisnya ya. Top up tagihan lainnya jg bisa (listrik, internet, dll), dan sudah dilengkapi dgn QRIS. <a href="https://t.co/Uzo5k34fDw">https://t.co/Uzo5k34fDw</a> Struggle gw tf duit dari bank lokal ke seabank gagal trus knpa dah bikin kesel aja	selain bunga tabungan juga free biaya admin alias gaada potongan tiap bulan seabank juga ada gratis transfer ke semua rekening bank xbulan untuk topup ewallet juga sama gratisnya ya top up tagihan lainnya jg bisa listrik internet dll dan sudah dilengkapi dgn qris struggle gw tf duit dari bank lokal ke seabank gagal trus knpa dah bikin kesel aja

3) *Tokenizing*

Proses pembagian kalimat menjadi token atau kata tunggal dengan tanda spasi.

Table 5. Setelah Proses *Tokenizing*

Sebelum <i>Tokenizing</i>	Sesudah <i>Tokenizing</i>
Selain bunga tabungan juga free biaya admin (alias gaada potongan tiap bulan). Seabank juga ada gratis transfer ke semua rekening bank 100x/bulan. Untuk topup e-wallet juga sama gratisnya ya. Top up tagihan lainnya jg bisa (listrik, internet, dll), dan sudah dilengkapi dgn QRIS. <a href="https://t.co/Uzo5k34fDw">https://t.co/Uzo5k34fDw</a> Struggle gw tf duit dari bank lokal ke seabank gagal trus knpa dah bikin kesel aja	['selain', 'bunga', 'tabungan', 'juga', 'free', 'biaya', 'admin', 'alias', 'gaada', 'potongan', 'tiap', 'bulan', 'seabank', 'juga', 'ada', 'gratis', 'transfer', 'ke', 'semua', 'rekening', 'bank', 'xbulan', 'untuk', 'topup', 'ewallet', 'juga', 'sama', 'gratisnya', 'ya', 'top', 'up', 'tagihan', 'lainnya', 'jg', 'bisa', 'listrik', 'internet', 'dll', 'dan', 'sudah', 'dilengkapi', 'dgn', 'qris'] ['struggle', 'gw', 'tf', 'duit', 'dari', 'bank', 'lokal', 'ke', 'seabank', 'gagal', 'trus', 'knpa', 'dah', 'bikin', 'kesel', 'aja']

4) *Stemming*

Mengembalikan kata ke kata baku atau kata dasarnya.

Table 6. Setelah Proses *Stemming*

Sebelum <i>Stemming</i>	Sesudah <i>Stemming</i>
Selain bunga tabungan juga free biaya admin (alias gaada potongan tiap bulan). Seabank juga ada gratis transfer ke semua rekening bank 100x/bulan. Untuk topup e-wallet juga sama gratisnya ya. Top up tagihan lainnya jg bisa (listrik, internet, dll), dan sudah dilengkapi dgn QRIS. <a href="https://t.co/Uzo5k34fDw">https://t.co/Uzo5k34fDw</a> Struggle gw tf duit dari bank lokal ke seabank gagal trus knpa dah bikin kesel aja	['selain', 'bunga', 'tabung', 'juga', 'free', 'biaya', 'admin', 'alias', 'gaada', 'potong', 'tiap', 'bulan', 'seabank', 'juga', 'ada', 'gratis', 'transfer', 'ke', 'semua', 'rekening', 'bank', 'xbulan', 'untuk', 'topup', 'ewallet', 'juga', 'sama', 'gratis', 'ya', 'top', 'up', 'tagih', 'lain', 'jg', 'bisa', 'listrik', 'internet', 'dll', 'dan', 'sudah', 'dilengkapi', 'dgn', 'qris']

Sebelum <i>Stemming</i>	Sesudah <i>Stemming</i>
bisa (listrik, internet, dll), dan sudah dilengkapi dgn QRIS. <a href="https://t.co/Uzo5k34fDw">https://t.co/Uzo5k34fDw</a> Struggle gw tf duit dari bank lokal ke seabank gagal trus knpa dah bikin kesel aja	'internet', 'dll', 'dan', 'sudah', 'lengkap', 'dgn', 'qris'] ['struggle', 'gw', 'tf', 'duit', 'dari', 'bank', 'lokal', 'ke', 'seabank', 'gagal', 'trus', 'knpa', 'dah', 'bikin', 'kesel', 'aja']

#### 5) *Stopword Removal*

Menghapus kata yang dianggap tidak relevan.

Table 7. Setelah Proses *Stopword Removal*

Sebelum <i>Stopword Removal</i>	Sesudah <i>Stopword Removal</i>
Selain bunga tabungan juga free biaya admin (alias gaada potongan tiap bulan). Seabank juga ada gratis transfer ke semua rekening bank 100x/bulan. Untuk topup e-wallet juga sama gratisnya ya. Top up tagihan lainnya jg bisa (listrik, internet, dll), dan sudah dilengkapi dgn QRIS. <a href="https://t.co/Uzo5k34fDw">https://t.co/Uzo5k34fDw</a> Struggle gw tf duit dari bank lokal ke seabank gagal trus knpa dah bikin kesel aja	bunga tabung free biaya admin alias gaada potong seabank gratis transfer rekening bank xbulan topup ewallet gratis ya top up tagih jg listrik internet dll lengkap dgn qris struggle gw tf duit bank lokal seabank gagal trus knpa dah bikin kesel aja

#### 4.4. TF - IDF

Salah satu algoritma yang dapat digunakan untuk menghitung bobot setiap kata adalah TF-IDF, yang juga dikenal sebagai Dokumen Frekuensi Kata Terbalik. Gambar 7 menampilkan proses TF-IDF.

```
#Training Testing - TF-IDF (menampilkan kata yg paling banyak muncul)
vectorizer = TfidfVectorizer(min_df = 5,
                             max_df = 0.8,
                             sublinear_tf = True,
                             use_idf = True)
vectorizer.fit_transform(df['stopword removal'])
Train_X_Tfidf = vectorizer.transform(Train_X)
Test_X_Tfidf = vectorizer.transform(Test_X)
print(Train_X_Tfidf)
```

Gambar 4. Proses *TF-IDF*

#### 4.5. Accuracy Machine Learning

Tabel berikut menunjukkan nilai akurasi yang diperoleh dari proses validasi. Perbandingan antara prediksi yang benar dari seluruh prediksi yang dibuat oleh algoritma dikenal sebagai akurasi. Persamaan 12 dapat digunakan untuk menghitung akurasi yaitu membagi hasil dari presisi dengan hasil akurasi atau dengan membagi 1 dikurangi tingkat negatif palsu (FNR) dibagi dengan tingkat positif palsu (FPR).


$$Accuracy = \frac{(TP + TN)}{(TP + FN + TN + FP)} \quad (12)$$

Table 8. Hasil *Accuracy*

Algoritma	Accuracy
<i>Logistic Regresion</i>	77%
<i>Super Vector Machine (SVM)</i>	84%
<i>Decision Tree</i>	77%
<i>Naïve Bayes – GausiyanNB</i>	81%
K-NN	80%
<i>Naïve Bayes – MultinomialNB</i>	81%

#### 4.6. Pre-Trained BERT Model

Model ini menetapkan uji coba dataset tiga *epoch*, *batch size* 8 dengan proporsi data latihan dan data uji sebanding 80 : 20. Metrik kinerja yang umum digunakan untuk mengevaluasi performa algoritma seperti BERT biasanya mencakup beberapa hal seperti *Accuracy* (Akurasi), *Precision* (Presisi), *Recall* (Sorotan), *F1 Score*.



Gambar 5. Ilustrasi *pre-training* dan *fine-tuning* BERT

*Accuracy* (Akurasi) adalah persentase dokumen atau kalimat yang dikategorikan secara akurat oleh model. *Precision* (Presisi) adalah persentase dari hasil yang relevan yang diprediksi secara benar oleh model dari semua hasil yang diprediksi positif. *Recall* (Sorotan) adalah persentase dari hasil yang relevan yang berhasil diidentifikasi oleh model dari semua hasil yang relevan sebenarnya. *F1-Score* adalah rata-rata harmonik presisi dan *recall*. Berguna ketika ada keseimbangan antara presisi dan *recall* yang diinginkan.

- 1) Epoch 1/3  
*Avg. Train Loss* : 0.62  
*Avg. Val. Loss* : 0.51  
*Acc Val.* : 0.80

Table 9. Hasil Epoch 1

	Precision	Recall	F1-Score	Support
0	1.00	0.05	0.09	21
1	0.80	1.00	0.89	79
<i>Acc.</i>			0.80	100
<i>Mac. avg</i>	0.90	0.52	0.49	100
<i>Weight. avg</i>	0.84	0.80	0.72	100

- 2) Epoch 2/3  
*Avg. Train Loss* : 0.54  
*Avg. Val. Loss* : 0.39  
*Acc. Val.* : 0.82

Table 10. Hasil Epoch 2


	Precision	Recall	F1-Score	Support
0	0.80	0.19	0.31	21
1	0.82	0.99	0.90	79
<i>Acc.</i>			0.82	100
<i>Mac. avg</i>	0.81	0.59	0.60	100
<i>Weight. avg</i>	0.82	0.82	0.77	100

- 3) Epoch 3/3  
*Avg. Train Loss* : 0.39  
*Avg. Val. Loss* : 0.33  
*Acc. Val.* : 0.86

Table 11. Hasil Epoch 3

	Precision	Recall	F1-Score	Support
0	0.65	0.71	0.68	21
1	0.92	0.90	0.91	79
<i>Acc.</i>			0.86	100
<i>Mac. avg</i>	0.79	0.81	0.80	100
<i>Weight. avg</i>	0.87	0.86	0.86	100

Untuk mengevaluasi kinerja sistem dengan matriks konfusi, parameter kinerja dianalisis. Hasil matriks konfusi ditunjukkan dalam Gambar 8, yang didasarkan pada akurasi kinerja tertinggi dalam pengujian kami.

Gambar 6. Hasil *Confusion Matrix*

*Confusion matrix* yaitu alat evaluasi kinerja yang sangat berguna dalam pembelajaran mesin, terutama dalam konteks klasifikasi. Pada *Confusion Matrix* terdapat 4 istilah utama yang digunakan yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Dengan matriks ini, kita dapat menghitung berbagai metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score*, yang semuanya memberikan wawasan tambahan tentang kinerja model dalam memprediksi kelas tertentu.

Pada gambar 6, *True Positive* (TP) adalah jumlah di mana model dengan benar memprediksi kelas sebanyak 71. *True Negative* (TN) adalah jumlah di mana model dengan benar memprediksi kelas negatif sebanyak 15. *False Positive* (FP) adalah jumlah di mana model salah memprediksi kelas positif sebanyak 8. *False Negative* (FN) adalah jumlah di mana model salah memprediksi kelas negatif sebanyak 6.

## 5. Simpulan

Ada beberapa kesimpulan yang didukung oleh hasil pengujian dan analisis. Dengan analisis sentimen yang ditulis oleh penulis, diketahui bahwa dari 500 data di *Twitter* (X) dan *YouTube*, 306 data menunjukkan sentimen positif dan 144 menunjukkan sentimen negatif. Algoritma pembelajaran mesin yang menggunakan algoritma SVM memiliki akurasi sebesar 84%, *Naïve Bayes* sebesar 81%, K-NN sebesar 80%, *Decision Tree* sebesar 77% dan *Logistic Regresion* sebesar 87%. Nilai akurasi tertinggi pada algoritma *machine learning* diperoleh oleh SVM sebesar 84%. Sedangkan nilai akurasi yang dihasilkan *deep learning* BERT yaitu 86% dengan epoch 3. Akurasi tertinggi diperoleh pada model algoritma *deep learning* BERT.

## Daftar Referensi

- [1] Devi Fitriana and Dedy Kurniawan, "Analisis Faktor-Faktor yang Memengaruhi Niat Penggunaan Bank Digital SeaBank menggunakan Modifikasi UTAUT2 dengan Security, Privacy, dan Trust," *Indones. J. Comput. Sci.*, vol. 12, no. 6, pp. 3986–4002, 2023, doi: 10.33022/ijcs.v12i6.3538.
- [2] F. A. Girnanfa and A. Susilo, "Studi Dramaturgi Pengelolaan Kesan Melalui Twitter Sebagai Sarana Eksistensi Diri Mahasiswa di Jakarta," *J. New Media Commun.*, vol. 1, no. 1, pp. 58–73, 2022, doi: 10.55985/jnmc.v1i1.2.
- [3] R. A. Husen, R. Astuti, L. Marlia, R. Rahmaddeni, and L. Efrizoni, "Analisis Sentimen Opini Publik pada Twitter Terhadap Bank BSI Menggunakan Algoritma Machine Learning,"

- MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 3, no. 2, pp. 211–218, 2023, doi: 10.57152/malcom.v3i2.901.
- [4] I. D. Onantya and P. P. Adikara, "Analisis Sentimen Pada Ulasan Aplikasi BCA Mobile Menggunakan BM25 Dan Improved K-Nearest Neighbor," *J-Ptiik.Ub.Ac.Id*, vol. 3, no. 3, pp. 2575–2580, 2019.
- [5] Alun Sujjadaa, Somantri, Juwita Nurfazri Novianti, and Indra Griha Tofik Isa, "Analisis Sentimen Terhadap Review Bank Digital Pada Google Play Store Menggunakan Metode Support Vector Machine (Svm)," *J. Rekayasa Teknol. Nusa Putra*, vol. 9, no. 2, pp. 122–135, 2023, doi: 10.52005/rekayasa.v9i2.345.
- [6] N. Fibriyanti Arminda, N. Sulistiyowati, and T. Nur Padilah, "Implementasi Algoritma Multinomial Naive Bayes Pada Analisis Sentimen Terhadap Ulasan Pengguna Aplikasi Brimo," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 7, no. 3, pp. 1817–1822, 2023, doi: 10.36040/jati.v7i3.7012.
- [7] Kurnia, I. Purnamasari, and D. D. Saputra, "Analisis Sentimen Dengan Metode Naïve Bayes, SMOTE Dan Adaboost Pada Twitter Bank BTN," *J. JTİK (Jurnal Teknol. Inf. dan Komunikasi)*, vol. 7, no. 2, pp. 235–242, 2023, doi: 10.35870/jtik.v7i3.707.
- [8] Syafii Imam Muhamad, "Sentimen Analisis Pada Media Sosial Menggunakan Metode Naive Bayes Classifier (Nbc)," *Teknologipintar.org*, vol. 3, no. 2, p. 1, 2023.
- [9] L. Annisa, A. D. Kalifia, B. Humaniora, and U. T. Yogyakarta, "Gudang Jurnal Multidisiplin Ilmu Analisis Teknik TF-IDF Dalam Identifikasi Faktor-Faktor Penyebab Depresi Pada Individu," vol. 2, pp. 302–307, 2024.
- [10] A. Ahmad and W. Gata, "Sentimen Analisis Masyarakat Indonesia di Twitter Terkait Metaverse dengan Algoritma Support Vector Machine," *J. JTİK (Jurnal Teknol. Inf. dan Komunikasi)*, vol. 6, no. 4, pp. 548–555, 2022, doi: 10.35870/jtik.v6i4.569.
- [11] N. Riyanah and F. Fatmawati, "Penerapan Algoritma Naive Bayes Untuk Klasifikasi Penerima Bantuan Surat Keterangan Tidak Mampu," *JTIM J. Teknol. Inf. dan Multimed.*, vol. 2, no. 4, pp. 206–213, 2021, doi: 10.35746/jtim.v2i4.117.
- [12] D. Cahyanti, A. Rahmayani, and S. A. Husniar, "Analisis performa metode Knn pada Dataset pasien pengidap Kanker Payudara," *Indones. J. Data Sci.*, vol. 1, no. 2, pp. 39–43, 2020, doi: 10.33096/ijodas.v1i2.13.
- [13] R. Fatmasari, R. K. Septiani, T. H. Pinem, D. Fabiyanto, and W. Gata, "Implementasi Algoritma BERT Pada Komentar Layanan Akademik dan Non Akademik Universitas Terbuka di Media Sosial," *Sains, Apl. Komputasi dan Teknol. Inf.*, vol. 5, no. 2, pp. 96, 2024, doi: 10.30872/jsakti.v5i2.13915.
- [14] D. Y. Utami, E. Nurlelah, and F. N. Hasan, "Comparison of Neural Network Algorithms, Naive Bayes and Logistic Regression to predict diabetes," *J. Informatics Telecommun. Eng.*, vol. 5, no. 1, pp. 53–64, 2021, doi: 10.31289/jite.v5i1.5201.
- [15] M. F. Abdussalam, D. Richasdy, and M. A. Bijaksana, "BERT Implementation on News Sentiment Analysis and Analysis Benefits on Branding," *J. Media Inform. Budidarma*, vol. 6, no. 4, pp. 2064, 2022, doi: 10.30865/mib.v6i4.4579.