

Sentiment Analysis of Cyber Attacks in Bank Syariah Indonesia Using SVM and Indobert Method

Chandra Apriyadi*¹, Styawati²

¹Information System Teknokrat Indonesia, Indonesia

²Computer Engineering, Universitas Teknokrat Indonesia, Indonesia

Email: chandra_apriyadi@teknokrat.ac.id

Received : Aug 8, 2024; Revised : Feb 21, 2025; Accepted : Nov 11, 2024; Published : Apr 26, 2025

Abstract

Bank Syariah Indonesia (BSI) is one of the Islamic banking institutions that operates based on Islamic principles in accordance with Islamic law and has obtained an operational license from the Dewan Syariah Nasional (DSN). The advancement of information technology brings unique risks to the banking industry, including BSI. One example is the ransomware attack experienced by BSI from May 8 to 11, 2023, where 15 million customer data and 1.5 terabytes of internal data were stolen, leading to significant public concern and response across various media platforms. This has the potential to affect public trust in the Islamic banking industry, particularly BSI. This research aims to analyze public sentiment on Twitter regarding the attack to identify the majority sentiment formed, as well as to compare the performance of the SVM and IndoBERT models in classifying sentiments. Additionally, this study reveals the topics present in the negative sentiments based on the classifications of both models through topic modeling using Latent Dirichlet Allocation (LDA). The results indicate that the majority of sentiments are negative, while IndoBERT shows better performance compared to SVM, with an accuracy of 85% and an F1-Score of 82%. The topics present in the negative sentiments classified by SVM include issues related to fund security as well as transfers and withdrawals, whereas the topics present in the negative sentiments classified by IndoBERT are more related to problems with mobile banking and fund withdrawals.

Keywords : BSI, IndoBERT, LDA, sentiment analysis, SVM..

This work is an open access article and licensed under a Creative Commons Attribution-Non Commercial 4.0 International License



1. PENDAHULUAN

Perkembangan perbankan telah menjadi salah satu pusat perhatian di Indonesia, dilihat dari maraknya perbankan yang menawarkan berbagai layanan terbaik mereka, baik dalam segi produk dan jasa, maupun promosi besar-besaran yang diadakan [1]. Perbankan merupakan suatu badan usaha yang menghimpun dana dari masyarakat dalam bentuk simpanan kemudian menyalurkannya kembali kepada masyarakat dalam bentuk kredit ataupun bentuk lainnya dalam rangka meningkatkan taraf hidup masyarakat (UU No. 10 Tahun 1998). Industri perbankan dinilai memiliki peranan besar dalam memajukan perekonomian, hal ini dikarenakan banyak aktivitas ekonomi yang berkaitan erat dengan perbankan, mulai dari aktivitas masyarakat, industri, hingga negara [2]. Setiap layanan keuangan yang diberikan perbankan memiliki tujuan utama untuk memberikan kemudahan nasabah dalam bertransaksi ataupun menabung [3].

Berdasarkan operasionalnya, bank dibedakan menjadi bank konvensional dan bank syariah. Bank konvensional merupakan bank yang kegiatannya memberikan jasa dan layanan keuangan secara umum berdasarkan ketentuan yang telah ditetapkan. Ketentuan tersebut mencakup penggunaan metode penetapan harga sesuai tingkat suku bunga dan menghitung biaya-biaya yang diperlukan. Bank konvensional umumnya beroperasi dengan mengeluarkan produk-produk untuk menyerap dan menyalurkan dana masyarakat [4]. Adapun bank syariah adalah bank yang beroperasi sesuai prinsip-

prinsip syariah Islam yang mengacu kepada ketentuan yang ada dalam Al-Qur'an dan Hadits [5]. *Riba* (bunga) dan kegiatan lain yang bertentangan dengan prinsip syariah dilarang dalam perbankan syariah. Keuntungan bank syariah diperoleh melalui prinsip bagi hasil dan transaksi lainnya yang sesuai dengan prinsip Islam [6]. Indonesia sebagai negara dengan mayoritas penduduk beragama Islam dapat menjadi faktor pendorong minat masyarakat terhadap perbankan syariah menjadi lebih tinggi [7]. Sebagian masyarakat berpendapat bahwa bank syariah hanya diperuntukkan untuk muslim saja, padahal bank syariah tidak eksklusif untuk golongan tertentu, melainkan diperuntukkan bagi seluruh masyarakat, hanya saja ketentuan yang diterapkan berdasarkan pada ajaran Islam [8].

Bank Syariah Indonesia (BSI) merupakan salah satu perbankan syariah yang telah mendapatkan izin operasional dari Dewan Syariah Nasional (DSN) dan dalam pelaksanaannya diawasi oleh Dewan Pengawas Syariah (DPS) [8]. PT Bank Syariah Indonesia Tbk (BSI) secara resmi beroperasi sejak 1 Februari 2021. Menjadi bank syariah terbesar di Indonesia, BSI merupakan hasil penggabungan tiga bank syariah dari himpunan bank milik negara (Himbara), yaitu PT Bank BRI Syariah, PT Bank Syariah Mandiri, dan PT Bank BNI Syariah [9]. Tercatat per September 2023 aset BSI mencapai Rp 329,84 triliun, menjadikannya sebagai bank terbesar ke-7 secara umum dan terbesar ke-1 sebagai bank syariah di Indonesia di atas PT Bank Muamalat Tbk (Rp 66,2 triliun) dan CIMB Niaga Syariah (Rp 216,59 triliun) [10], [11]. BSI menjadi salah satu pilihan perbankan dengan prinsip keuangan syariah, khususnya dalam mendukung industri halal dan perekonomian berbasis syariah [7].

Kemajuan dan penggunaan teknologi informasi membawa risiko tersendiri bagi perbankan. Risiko yang biasanya muncul berupa serangan siber (*cybercrime*) yang dapat mengganggu kinerja teknologi informasi, merusak sistem, hingga mencuri data rahasia perusahaan [12]. Seperti serangan *ransomware* yang dialami BSI pada tahun lalu, yang mengakibatkan layanan BSI seperti ATM dan *internet banking* mengalami gangguan selama 4 hari (8-11 Mei 2023). Pelaku yang menyebut dirinya sebagai grup *LockBit* mengumumkan telah mencuri 15 juta data nasabah, informasi karyawan, dan sekitar 1,5 terabyte data internal. Mereka mengancam akan merilis semua data tersebut di *web* gelap jika negosiasi gagal [13], [14]. Hal tersebut menimbulkan kekhawatiran dan tanggapan publik di berbagai platform media. Salah satunya di media sosial Twitter (saat ini bernama X) dalam bentuk unggahan yang disebut *tweet*. *Tweet* pada Twitter digunakan untuk menginformasikan bahwa pengunggah memiliki pembaruan terbaru, mengungkapkan pendapat, atau mengikuti topik yang sedang hangat [15], [16], [17], [18].

Berdasarkan masalah tersebut, penelitian ini bertujuan untuk menganalisis sentimen publik terhadap serangan siber pada BSI dengan mengklasifikasikan sentimen untuk mengetahui mayoritas kategori sentimen, apakah bersifat positif, negatif, atau netral. Selain itu, penelitian ini menguji dan mengimplementasikan model SVM dan IndoBERT guna mengukur performa kedua model dalam mengklasifikasikan sentimen. SVM merupakan metode pembelajaran mesin terawasi (*supervised machine learning*) yang sangat efektif, metode ini memiliki tingkat keberhasilan yang tinggi saat diterapkan di berbagai bidang, serta memberikan kinerja yang sangat baik dalam berbagai masalah pembelajaran [19][20]. Oleh karena itu, penelitian ini mengimplementasikan algoritma SVM yang akan dibandingkan dengan IndoBERT, model berbasis BERT yang telah dilatih secara khusus untuk bahasa Indonesia. Implementasi IndoBERT menjadi pembeda dari penelitian sebelumnya yang umumnya menggunakan model berbasis *machine learning* umum seperti *Naive Bayes* dan *Logistic Regression* yang tidak dirancang secara spesifik untuk menangani tugas berbahasa Indonesia. Dengan membandingkan akurasi dan keefektifan dari kedua model tersebut, penelitian ini diharapkan dapat memberikan wawasan baru mengenai teknik terbaik untuk analisis sentimen dalam konteks bahasa Indonesia. Sentimen negatif yang dihasilkan dari klasifikasi kedua model tersebut kemudian dianalisis lebih lanjut melalui pemodelan topik menggunakan *Latent Dirichlet Allocation* (LDA) untuk mengetahui topik ataupun kata yang sering muncul pada sentimen negatif, sehingga memungkinkan

peneliti untuk mendapatkan wawasan lebih dalam mengenai isu-isu yang mendasari sentimen negatif. LDA dipilih karena merupakan model probabilistik dengan topik yang mudah diinterpretasikan [21], memiliki kemampuan mengelompokkan data dalam jumlah besar [22], mengekstrak topik tanpa bergantung domain dan bahasa [23], serta memiliki kemampuan untuk menangkap atau menghasilkan banyak topik.

Analisis sentimen juga dikenal sebagai *opinion mining*, adalah proses ekstraksi opini atau pendapat dari dokumen terkait topik tertentu, dengan tujuan untuk mengetahui apakah opini seseorang terhadap suatu peristiwa atau masalah bersifat positif atau negatif [24]. Teknik yang digunakan untuk analisis sentimen adalah *text mining*, yaitu teknik untuk mengekstraksi informasi yang berguna dari data teks yang tidak terstruktur. Dengan *text mining*, kata kunci atau pendapat dapat diekstraksi untuk mendukung pemahaman terhadap opini masyarakat yang terdapat dalam data teks. Pemodelan topik sendiri merupakan salah satu teknik dalam *text mining* yang berfungsi untuk menemukan topik-topik tersembunyi dalam kumpulan data teks yang besar.

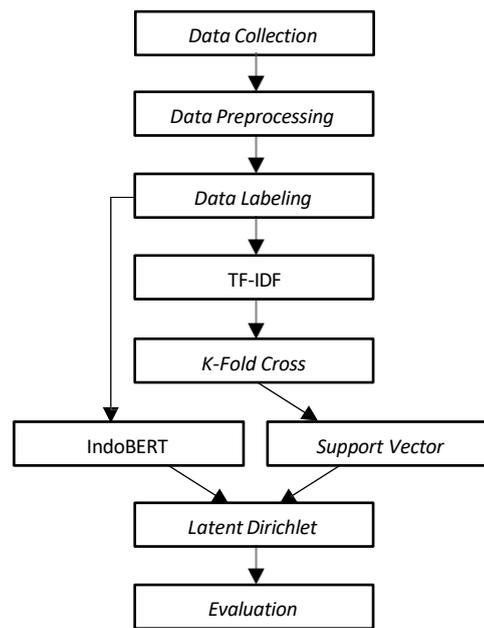
Penelitian sebelumnya terkait analisis sentimen terhadap serangan siber pada BSI dilakukan oleh Mualfah dkk. Penelitian ini bertujuan untuk menganalisis sentimen menggunakan algoritma *Random Forest* dan *Naïve Bayes* guna mengetahui reaksi serta tanggapan masyarakat Indonesia terhadap kasus pembobolan data nasabah pada BSI, dengan mengelompokkan sentimen ke dalam kelas positif, negatif, dan netral. Hasil penelitian ini menunjukkan bahwa metode *Naïve Bayes* memiliki tingkat akurasi 81%, sedangkan metode *Random Forest* memiliki tingkat akurasi 78%. Penelitian ini juga menyajikan *wordcloud* untuk sentimen positif, negatif, dan netral [18].

Penelitian dengan topik serupa juga dilakukan oleh Putra dkk yang mengimplementasikan metode *syuzhet* dan *NRC Lexicon* oleh Saif Mohammad berbahasa Indonesia untuk mengevaluasi sentimen positif dan negatif ke delapan emosi, yaitu *anger*, *anticipation*, *disgust*, *fear*, *joy*, *sadness*, *surprise*, dan *trust*. Implementasi metode tersebut menunjukkan bahwa mayoritas sampel sentimen berupa positif sebesar 42,1% dengan emosi yang dominan adalah rasa kepercayaan (*trust*), kemudian sentimen negatif sebesar 32,3% dengan emosi dominan yaitu rasa takut (*fear*), dan sentimen netral sebesar 25,6% [25].

Penelitian serupa juga dilakukan oleh Husen dkk dengan mengembangkan dan mengimplementasikan algoritma *machine learning* yaitu *Support Vector Machine* (SVM), *Naïve Bayes*, dan *Logistic Regression* untuk menganalisis sentimen publik terhadap Bank BSI yang terdapat dalam *tweet* di Twitter. Berdasarkan penelitian yang dilakukan, SVM menghasilkan performa kinerja yang lebih unggul daripada algoritma *Naïve Bayes* dan *Logistic Regression*, dengan nilai akurasi algoritma SVM sebesar 88%, *Naïve Bayes* sebesar 76%, dan *Logistic Regression* sebesar 86% pada *split dataset* 90:10. Penelitian ini juga menyajikan *wordcloud* untuk mengetahui kata yang sering muncul pada sentimen berlabel negatif [26].

2. METODE

Analisis sentimen yang dilakukan dalam penelitian ini melibatkan beberapa langkah yang termuat dalam **Kesalahan! Sumber referensi tidak ditemukan.**



Gambar 1. Alur penelitian

Berdasarkan Gambar 1, penelitian ini diawali dengan pengumpulan data (data collection) berupa tweet dari Twitter. Dataset yang telah didapat kemudian dilakukan pembersihan data (data preprocessing) sebelum dilakukan proses pemberian kelas sentimen (pelabelan data). Data yang telah diberi label dimasukkan ke dalam model IndoBERT dan SVM, kemudian tweet negatif yang telah dikelompokkan oleh kedua model tersebut dilakukan topic modeling menggunakan LDA, dan terakhir dilakukan evaluasi atau pembahasan terhadap performa dari model IndoBERT dan SVM serta pemodelan topik LDA.

2.1. Data Collection

Langkah awal penelitian ini adalah menyiapkan dataset yang akan digunakan sebagai input model. Dataset yang digunakan merupakan kumpulan *tweet* dari aplikasi Twitter yang diperoleh melalui situs *web* Kaggle. Data tersebut dicrawling pada rentang waktu 9 hingga 17 Mei 2023, yang awalnya terdiri dari 24.400 *tweet*, kemudian menjadi 22.468 *tweet* setelah dilakukan preprocessing. Penggunaan dataset yang telah tersedia di Kaggle dapat menghindari proses pengambilan data (*crawling*) yang memakan waktu cukup lama, sehingga penelitian dapat berjalan lebih cepat dengan langsung melanjutkan ke tahapan berikutnya. Selain itu, penggunaan dataset dari Kaggle juga membantu menghindari masalah pembatasan akses yang ada atau timbul saat melakukan *crawling* menggunakan Twitter API.

2.2. Preprocessing

Preprocessing merupakan langkah awal sebelum data digunakan dalam pemrosesan model. Preprocessing berfokus pada pembersihan data untuk menghilangkan dan mengatasi noisy data, termasuk mengatasi informasi yang hilang atau tidak lengkap sehingga nantinya hasil yang didapatkan akan optimal [27]. Berikut merupakan preprocessing data yang diterapkan dalam penelitian ini:

2.2.1 Filtering dan Data Cleansing

Proses ini merupakan proses penyaringan dan penghapusan tagar, link, *username*, serta *tweet* yang dibuat sendiri oleh Bank Mandiri, BRI, BSI, BNI, dan BI. Proses ini juga menghapus data duplikat, data kosong, dan karakter yang dianggap tidak diperlukan.

2.2.2 Casefolding

Casefolding merupakan tahap untuk mengubah semua huruf kapital atau mengubah teks secara keseluruhan menjadi huruf kecil.

2.2.3 Tokenizing

Tahap ini melakukan pembagian atau pemisahan teks menjadi token-token kata terpisah.

2.2.4 Text Normalization

Normalisasi teks merupakan tahap dimana mengubah atau mengganti kata yang tidak baku (slang) menjadi kata baku. Untuk melakukan normalisasi teks peneliti memanfaatkan dataset bahasa alay oleh Salsabila dkk [28]. Di mana dataset tersebut berisi pasangan kata tidak baku dengan kata bakunya.

2.2.5 Stopwords Removal

Stopwords removal digunakan untuk menghapus kata-kata dalam teks yang tidak diperlukan dalam penerapan algoritma pada penelitian.

2.2.6 Stemming

Stemming digunakan untuk menghilangkan awalan dan akhiran kata dalam teks atau dengan kata lain mengubah setiap kata menjadi bentuk dasarnya [29].

2.3. Data Labeling

Sebelum digunakan untuk pemodelan, dataset yang telah dibersihkan terlebih dahulu diberi label untuk setiap *tweet*. Distribusi label yang digunakan terdiri dari positif, negatif, dan netral. Pelabelan dilakukan secara otomatis menggunakan model *IndoBERT-classification* oleh Afbudiman yang dimuat dari *Hugging Face* dan merupakan penyempurnaan dari model *IndoBERT-base-p1*.

2.4. TF-IDF

Term Frequency-Inverse Document Frequency (TF-IDF) adalah skema pembobotan untuk mengetahui pentingnya suatu kata dalam sebuah dokumen [30]. Term Frequency (TF) menyatakan kemunculan suatu kata pada dokumen. Sehingga, suatu kata dengan nilai TF yang tinggi menandakan bahwa kata tersebut penting untuk suatu dokumen. Sedangkan, IDF menyatakan invers dari DF yang digunakan untuk menentukan seberapa penting suatu kata pada sekumpulan dokumen. Nilai IDF yang tinggi menunjukkan bahwa kemunculan kata tersebut jumlahnya sedikit di seluruh dokumen, sehingga kata tersebut dianggap penting. Untuk suatu kata t pada dokumen d , nilai TF-IDF dapat dihitung melalui persamaan (1), (2), dan (3) [31]

$$TF(t, d) = \frac{\text{jumlah kemunculan kata } t \text{ pada dokumen } d}{\text{jumlah kata pada dokumen } d} \quad (1)$$

$$IDF(t) = \log \left(\frac{\text{jumlah dokumen}}{\text{jumlah dokumen yang mengandung kata } t} \right) \quad (2)$$

$$TF - IDF(t, d) = TF(t, d) \times IDF(t) \quad (3)$$

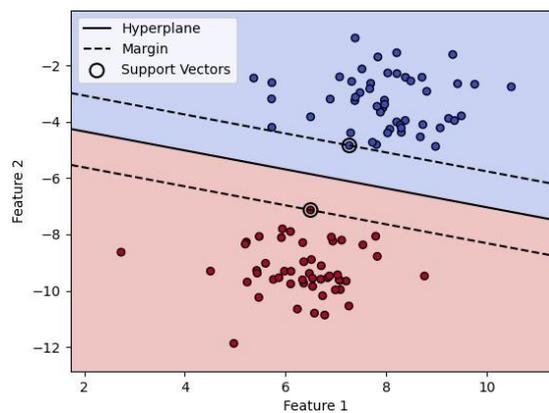
2.5. K-Fold Cross Validation

K-fold cross validation merupakan metode validasi silang yang digunakan untuk menghitung akurasi prediksi suatu sistem. Metode ini mampu mengurangi waktu komputasi dengan tetap menjaga keakuratan estimasi. Dalam *K-fold cross validation*, data (D) dibagi ke dalam k subsets D1, D2, ..., Dk dengan jumlah yang sama. Proses ini diulang sebanyak k subsets dan nilai akurasi merupakan rata-rata dari seluruh akurasi data *training* dan *testing* [20]. Penelitian ini menggunakan *10-fold cross-validation*, karena berdasarkan berbagai percobaan ekstensif dan pembuktian teoritis, *10-fold cross-validation* adalah pilihan terbaik untuk mendapatkan hasil yang akurat [32].

2.6. Pemodelan IndoBERT dan SVM

Penelitian ini menggunakan dua model yaitu IndoBERT dan SVM untuk membandingkan kinerja model IndoBERT yang dibuat khusus untuk bahasa Indonesia dengan model SVM yang merupakan model lama dan dapat digunakan pada data dalam berbagai bahasa.

2.6.1. Support Vector Machine



Gambar 2. Ilustrasi SVM

Support Vector Machine (SVM) adalah metode pembelajaran yang menggunakan fungsi-fungsi linier dalam sebuah ruang fitur (*feature space*) berdimensi tinggi sebagai ruang hipotesis. SVM dilatih dengan algoritma yang didasarkan pada teori optimasi dengan mengimplementasikan *learning bias* yang berasal dari teori pembelajaran statistik. Tujuannya untuk menemukan *hyperplane* (batas keputusan) optimal yang memaksimalkan margin antar kelas. Berikut ilustrasi dari SVM dapat dilihat pada **Kesalahan! Sumber referensi tidak ditemukan..**

Berdasarkan Gambar 2, ide dasar dari SVM adalah memaksimalkan batas hyperplane (maximal margin hyperplane). Secara sederhana konsep SVM dapat dijelaskan sebagai usaha untuk mencari hyperplane terbaik yang berfungsi sebagai pemisah dua buah kelas data pada ruang input. Hyperplane terbaik dapat ditemukan dengan mengukur margin hyperplane dan mencari nilai maksimalnya [33], [34]. Margin merupakan jarak antara hyperplane dengan data terdekat dari masing-masing kelas [35], sedangkan titik data yang paling dekat dengan hyperplane disebut dengan support vector [36]. Rumus hyperplane untuk mendefinisikan kedua sisi margin dapat dilihat pada persamaan (4) dan (5).

$$x_i \cdot w + b \geq +1 \text{ untuk } y_i = +1 \quad (4)$$

$$x_i \cdot w + b \leq -1 \text{ untuk } y_i = -1 \quad (5)$$

Di mana w merupakan normal bidang dan b adalah posisi bidang relatif terhadap pusat koordinat. Sedangkan nilai margin antara hyperplane yang berdasarkan jarak garis ke titik pusat dapat ditemukan dengan persamaan 6.

$$\frac{1-b-(-1-b)}{w} = \frac{2}{|w|} \quad (6)$$

Dengan mengalikan b dan w dengan suatu konstanta, akan menghasilkan nilai margin yang dikalikan dengan konstanta yang sama. Oleh karena itu, persamaan di atas memiliki konstrain yang merupakan scaling constraint dan dapat dipenuhi dengan rescaling b dan w [33].

2.6.2. IndoBERT

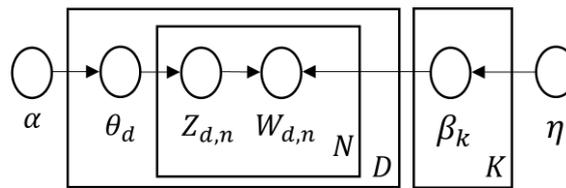
IndoBERT merupakan *pre-trained* model bahasa Indonesia berbasis BERT yang dilatih menggunakan dataset yang besar dan bersih (Indo4B). Di mana dataset Indo4B terdiri dari empat milyar kata mencakup kalimat dalam bahasa Indonesia formal dan bahasa sehari-hari [37]. IndoBERT menerapkan arsitektur *transformer* yang terdiri dari lapisan-lapisan *encoder*. Lapisan tersebut bertugas untuk mengubah token-token input menjadi representasi vektor yang kaya konteks. Setiap lapisan *encoder* memiliki komponen *self-attention* dan *feed-forward neural network*

Dalam pelaksanaannya, IndoBERT melakukan tokenisasi menggunakan *SentencePiece* dengan *byte-pair encoding* (BPE). Proses ini memecah teks input menjadi unit-unit yang lebih kecil yang disebut token. Tokenisasi ini penting untuk menangkap representasi morfologis dari kata-kata bahasa Indonesia yang kompleks. Proses pelatihan model IndoBERT melibatkan penggunaan tugas pemodelan *Masked Language Modeling* (MLM). Di mana sebagian kata dalam kalimat disembunyikan (*masked*) kemudian model dilatih untuk menebak kata yang hilang tersebut berdasarkan konteks sekitarnya. IndoBERT juga melibatkan *Next Sentence Prediction* (NSP) yang digunakan untuk memahami hubungan antar kalimat dan memprediksi apakah kalimat tersebut saling berhubungan.

IndoBERT melibatkan tahap *fine-tuning* setelah *pre-training*. Tahap *fine-tuning* ini menambahkan lapisan pada output IndoBERT dan melatih model dengan dataset yang relevan untuk tugas tersebut. Setelah melewati tahap *fine-tuning*, IndoBERT dapat diimplementasikan pada tugas baru. Terdapat versi *lite* dari IndoBERT yang disebut IndoBERT-lite dan dibangun berdasarkan arsitektur model ALBERT. Secara total IndoBERT terdiri dari 4 jenis, yaitu IndoBERT-base, IndoBERT-large, IndoBERT-lite-base, dan IndoBERT-lite-large. Setiap jenis IndoBERT memiliki *phase 1* dan *phase 2*, serta memiliki jumlah parameter yang berbeda-beda.

2.7. Latent Dirichlet Allocation

Latent Dirichlet Allocation (LDA) merupakan salah satu model probabilistik untuk pemodelan topik dengan prinsip dasar bahwa setiap dokumen direpresentasikan sebagai campuran dari beberapa topik tersembunyi yang belum diketahui, di mana setiap topik terdiri dari distribusi kata-kata dalam dokumen tersebut. LDA dapat diilustrasikan dengan Gambar 3.



Gambar 3. Representasi LDA

$$p(\beta_{1:k}, \theta_{1:D}, Z_{1:D}, W_{1:D}) = \prod_{i=1}^k p(\beta_i) \prod_{d=1}^D p(\theta_d) \left(\prod_{n=1}^N p(z_{d,n} | \theta_d) p(w_{d,n} | \beta_{1:k}, z_{d,n}) \right) \quad (7)$$

Berdasarkan Gambar 3, LDA dapat dituliskan dengan persamaan (7). Dimana D merupakan kumpulan dokumen, K adalah kumpulan topik, N adalah jumlah kata dalam dokumen (Nd), W_{d,n} adalah kata ke-n pada dokumen d, Z_{d,n} adalah topik ke-n pada dokumen d, θ_d adalah jumlah topik yang teridentifikasi per dokumen, β_k adalah distribusi topik pada vocabulary dan α, η adalah parameter dirichlet [38].

2.8. Evaluation

Proses evaluasi dilakukan untuk mengukur kinerja model yang telah diimplementasikan menggunakan *confusion matrix* serta metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-Score*.

3. HASIL DAN PEMBAHASAN

3.1. Dataset

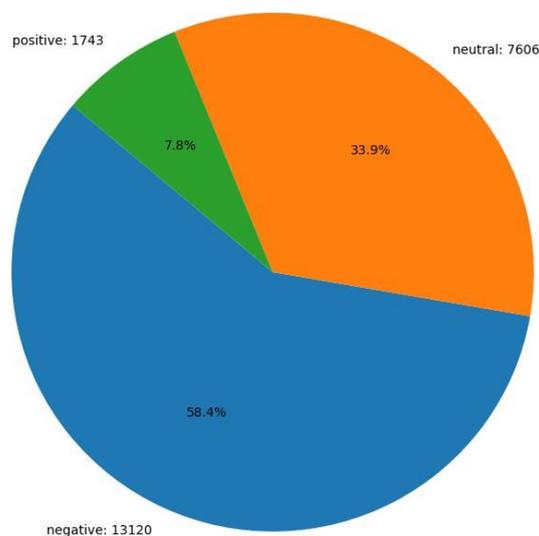
Dataset yang diperoleh dalam penelitian ini memiliki beberapa kolom yaitu kolom *URL*, *Date*, *Tweet*, *ID*, *Username*, *Replies*, *Retweets*, *Likes*, *Quotes*, *ConversationId*, *Language*, *Links*, *Media*, *Retweeted Tweet*, dan *Bookmarks*. Namun, hanya teks yang ada dalam kolom *Tweet* yang digunakan karena berisi komentar dan merupakan sentimen dari masyarakat. Dataset yang telah diseleksi tersebut dilakukan tahap *preprocessing* dengan proses seperti ditunjukkan pada **Kesalahan! Sumber referensi tidak ditemukan.**

Tabel 1 merupakan tahapan *preprocessing* yang dimulai dari text awal sampai ke tahap *stemming*. Pada tahap *stopword removal*, kata “tidak” dikecualikan dari daftar *stopword*. Hal ini dikarenakan kata tersebut dapat memberikan makna negatif dalam sebuah kalimat seperti pada frasa “tidak baik” dan “tidak bisa”.

Setelah melewati tahap *stopword removal*, dilakukan pelabelan tanpa dilakukan *stemming* terlebih dahulu. Hal ini dilakukan karena IndoBERT sendiri mempertahankan bentuk asli sebuah kata untuk menyimpan informasi kontekstualnya. Proses *stemming* hanya diterapkan pada implementasi SVM setelah dilakukan pelabelan. Pelabelan dilakukan secara otomatis menggunakan model yang berasal dari Hugging Face, yaitu IndoBERT-classification oleh Afbudiman yang merupakan penyempurnaan dari model IndoBERT-base-p1 pada kumpulan data IndoNLU. Model tersebut memiliki nilai *loss* 0.3707, akurasi 0.9397, dan *F1-Score* 0.9397, sehingga sangat baik digunakan untuk pelabelan dataset. Proporsi kelas sentimen setelah dilakukan pelabelan ditunjukkan pada Gambar 4.

Tabel 1. Proses Preprocessing

Praproses	Hasil
<i>Text</i>	@bankbsi_id Min @bankbsi_id, kemaren saya isi pulsa kok ngga masuk ya? Padahal saldo sudah kepotong
<i>Data Cleansing</i>	Min kemaren saya isi pulsa kok ngga masuk ya Padahal saldo sudah kepotong
<i>Casefolding</i>	min kemaren saya isi pulsa kok ngga masuk ya padahal saldo sudah kepotong
<i>Tokenizing</i>	[min, kemaren, saya, isi, pulsa, kok, ngga, masuk, ya, padahal, saldo, sudah, kepotong]
<i>Text Normalization</i>	[min, kemarin, saya, isi, pulsa, kok, tidak, masuk, ya, padahal, saldo, sudah, kepotong]
<i>Stopword Removal</i>	[kemarin, isi, pulsa, tidak, masuk, padahal, saldo, sudah, kepotong]
<i>Stemming</i>	kemarin isi pulsa tidak masuk padahal saldo sudah potong



Gambar 4. Proporsi kelas sentiment

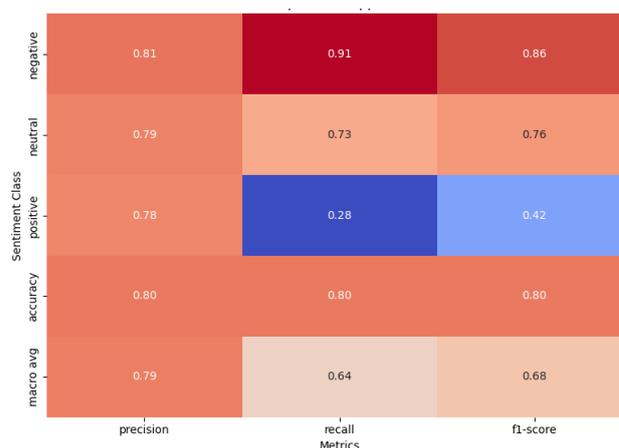
Visualisasi pie chart pada Gambar 4, menunjukkan adanya ketidakseimbangan kelas. Dimana kelas sentiment negatif lebih dominan sebanyak 13.120 tweet atau 58.4% dari keseluruhan dataset, dibandingkan dengan kelas positif sebanyak 1.743 tweet (7.8%), dan kelas netral sebanyak 7.606 tweet (33.9%).

3.2. Klasifikasi Sentimen

Pada bagian ini, kami menjelaskan proses klasifikasi sentimen yang telah dilakukan serta hasil yang diperoleh dengan membandingkan kinerja dua model, yaitu SVM dan IndoBERT, yang dijalankan dalam lingkungan kerja Google Colaboratory.

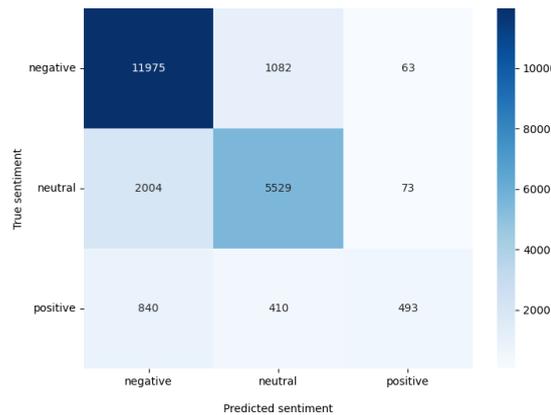
3.2.1. Klasifikasi Sentimen dengan SVM

Dalam klasifikasi sentimen pada penelitian ini, SVM diimplementasikan dengan menambahkan fitur *Term Frequency-Inverse Document Frequency* (TF-IDF) serta pembagian data latih (*data training*) dan data uji (*data testing*) menggunakan *10-fold cross validation*. *10-fold cross-validation* yaitu proses pelatihan akan dilakukan sebanyak 10 iterasi dengan membagi dataset menjadi 10 bagian (*fold*) yang sama besar, di mana setiap 9 *fold* digunakan untuk melatih model dan 1 *fold* digunakan untuk menguji model. Proses ini diulang sebanyak 10 kali, dengan setiap *fold* menjadi data uji sekali, kemudian hasil dari seluruh iterasi dicari rata-ratanya. Berikut merupakan *classification report* dengan SVM yang dapat dilihat pada **Kesalahan! Sumber referensi tidak ditemukan.**



Gambar 5. Classification Report SVM

Berdasarkan *classification report* pada Gambar 5, implementasi SVM dengan TF-IDF menunjukkan akurasi sebesar 80%, yang mengindikasikan bahwa model secara keseluruhan memberikan kinerja yang baik. Namun berdasarkan nilai rata-rata F1-Score (macro average) yang rendah yaitu 68% dengan presisi 79% dan recall 64%, menunjukkan bahwa model memiliki kinerja yang tidak seimbang dalam memprediksi setiap kelas sentimen, terutama kelas positif yang merupakan kelas dengan jumlah paling sedikit. Nilai F1-Score 42% pada kelas positif menandakan SVM sangat lemah dalam melakukan klasifikasi pada kelas tersebut. Secara keseluruhan hasil ini memberikan gambaran bahwa SVM memiliki performa yang cukup baik jika diterapkan pada data yang tidak seimbang, meskipun tetap memiliki nilai metrik yang rendah pada kelas minoritas. Adapun rincian hasil klasifikasi SVM dapat dilihat pada Gambar 6.



Gambar 6. Confusion Matrix SVM

Berdasarkan confusion matrix pada Gambar 6, kesalahan prediksi SVM pada kelas negatif cenderung memprediksi sampel negatif sebagai kelas netral, sebaliknya pada kelas netral, kesalahan prediksi SVM cenderung memprediksi sampel netral sebagai kelas negatif. Adapun pada kelas positif, SVM cenderung memprediksi sampel positif sebagai kelas negatif. Berdasarkan gambar tersebut dapat disimpulkan model SVM baik dalam memprediksi kelas negatif dengan benar, namun masih mengalami kesulitan dalam memprediksi kelas positif dan netral serta cenderung menandainya sebagai negatif. Hal ini mungkin disebabkan oleh keadaan kelas yang tidak seimbang (imbalance data).

3.2.2. Klasifikasi Sentimen dengan IndoBERT

Dalam penelitian ini, implementasi IndoBERT dilakukan tanpa membagi dataset menjadi data latih dan data uji dan tanpa penambahan fitur TF-IDF. Proses klasifikasi sentimen diterapkan melalui Google Colaboratory dengan mengubah akselerasi *runtime* menjadi GPU, hal ini dilakukan karena IndoBERT-base memiliki jumlah parameter yang cukup besar. Berikut adalah informasi GPU yang tersedia dalam lingkungan Colab, yang digunakan dalam penelitian ini, ditunjukkan pada **Kesalahan! Sumber referensi tidak ditemukan..**

```

+-----+-----+-----+-----+-----+-----+-----+-----+
| NVIDIA-SMI 535.104.05 | Driver Version: 535.104.05 | CUDA Version: 12.2 |
+-----+-----+-----+-----+-----+-----+-----+-----+
| GPU  Name | Persistence-M | Bus-Id  | Disp.A | Volatile Uncorr. ECC | | |
| Fan  Temp  Perf | Pwr:Usage/Cap |           |          |           | GPU-Util  Compute M. |
|           | Pwr:/Usage/Cap |           |          |           |           | MIG M. |
+-----+-----+-----+-----+-----+-----+-----+-----+
| 0   Tesla T4      | Off           | 00000000:00:04:0 Off |   0    |           | 0%         Default |
| N/A   43C   P8     | 9W / 70W     |           |          |           |           | N/A     |
+-----+-----+-----+-----+-----+-----+-----+-----+
| Processes: |
| GPU  GI  CI | PID  Type  Process name                        | GPU Memory |
| ID        ID |      |          |                                     | Usage      |
+-----+-----+-----+-----+-----+-----+-----+-----+
| No running processes found |
+-----+-----+-----+-----+-----+-----+-----+-----+
    
```

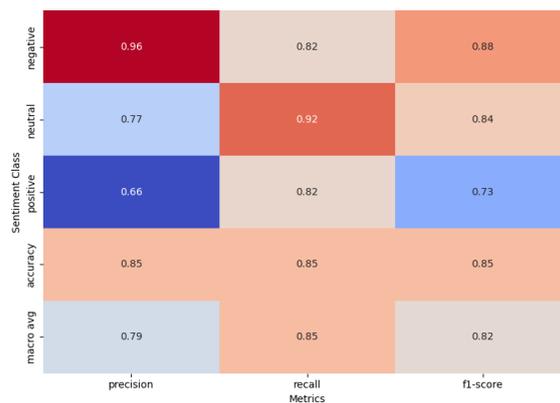
Gambar 7. Informasi GPU

Pada penelitian ini, kami memanfaatkan GPU Tesla T4 yang tersedia dalam lingkungan Google Colaboratory. Informasi lebih rinci mengenai GPU ini dapat dilihat pada Gambar 7. Berdasarkan hasil perintah `!nvidia-smi`, GPU Tesla T4 memiliki spesifikasi driver versi 535.104.05 dan versi CUDA 12.2. GPU ini juga memiliki kapasitas memori sebesar 15.360 MiB.

Sebelum memuat model IndoBERT, dilakukan cloning repository IndoNLU yang berisi fungsi serta dataset yang dibutuhkan untuk proses fine-tuning IndoBERT. Model IndoBERT sendiri dapat dimuat dari Hugging Face menggunakan library transformer. Setelah model diinisialisasi, dilakukan proses fine-tuning menggunakan dataset berlabel yang telah tersedia dalam repository GitHub IndoNLU dan telah dibagi menjadi data uji, data latih, dan data validasi. Fine-tuning dilakukan dengan melatih model sebanyak 5 epoch atau 5 iterasi.

Untuk melatih model IndoBERT, data harus disesuaikan dengan format input yang dapat diterima oleh IndoBERT. Ini mencakup proses tokenisasi teks menggunakan BertTokenizer untuk mengubah teks menjadi urutan token yang dikenali oleh vocabulary IndoBERT. BertTokenizer tidak hanya membagi teks menjadi token, tetapi juga menangani kasus khusus seperti tokenisasi untuk kata-kata yang tidak ada dalam vocabulary, serta menambahkan token khusus seperti token awal [CLS], token pemisah akhir teks [SEP], dan [MASK] yang digunakan untuk menandai padding token dengan memberikan nilai nol pada token yang dipadding sehingga model dapat mengabaikannya selama proses pelatihan. Data kemudian dimuat menggunakan kelas DocumentSentimentDataset yang mengubah teks menjadi token-token subword menggunakan tokenizer BERT. Setiap teks dapat memiliki jumlah token subword yang bervariasi, tergantung pada panjang kalimatnya, maka diperlukan standarisasi panjang menggunakan teknik padding atau pemotongan agar data dapat diproses secara efisien oleh model. Untuk itu diterapkan kelas DocumentSentimentDataLoader untuk memuat data dalam bentuk batch, melakukan padding untuk menyamakan panjang setiap batch, dan menghasilkan mask untuk memberi tahu model mana yang merupakan token data aktual dan mana yang merupakan token padding. Dalam kelas DocumentSentimentDataLoader terdapat beberapa hyperparameter penting yang diatur, yaitu `max_seq_len=512` untuk menetapkan panjang maksimum urutan token yang akan diproses oleh model, `batch_size=32` untuk mengatur jumlah sampel yang akan diproses dalam satu batch, `num_workers=16` untuk menentukan jumlah pekerja yang akan digunakan untuk memuat data secara parallel, dan `shuffle=True` untuk memastikan bahwa data akan diacak setiap kali sebelum dimasukkan ke dalam model selama pelatihan, guna mencegah model dari overfitting.

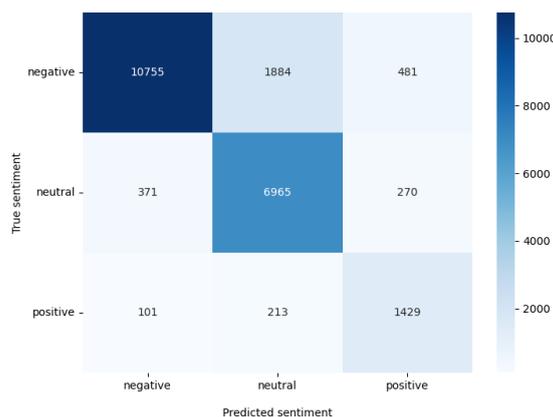
Untuk mencapai hasil yang maksimal, diperlukan proses fine-tuning pada model IndoBERT. Fine-tuning merupakan teknik menggunakan model yang telah dilatih sebelumnya (pre-trained model) dan melanjutkan pelatihan dengan data untuk tugas tertentu. Proses ini memungkinkan model untuk belajar pola yang spesifik terhadap tugas tersebut tanpa harus memulai pelatihan dari awal. Model IndoBERT memproses urutan kata atau kalimat melalui beberapa lapisan encoder. Setiap lapisan encoder menggunakan mekanisme self-attention dan feed-forward neural network untuk menghasilkan output yang diteruskan ke lapisan encoder berikutnya. Model IndoBERT-base memiliki 12 lapisan encoder, dimana setiap token yang dimasukkan ke dalam model menghasilkan vektor dengan ukuran hidden size sebesar 768, menunjukkan dimensi dari vektor representasi yang dihasilkan oleh masing-masing token. Dalam proses ini, token [CLS] digunakan untuk representasi agregat dari seluruh kalimat atau teks, mengumpulkan informasi dari semua token dalam teks dan menghasilkan vektor yang digunakan sebagai input untuk lapisan klasifikasi (classifier layer). Lapisan klasifikasi menggunakan vektor output dari token [CLS] sebagai input untuk menghasilkan logits. Logits merupakan nilai numerik yang menunjukkan seberapa cocok setiap kelas dengan teks yang diberikan. Logits ini kemudian diubah menjadi probabilitas menggunakan fungsi softmax. Fungsi softmax mengonversi logits menjadi distribusi probabilitas dengan menghitung eksponen dari setiap nilai logit, kemudian menormalkannya sehingga total probabilitasnya adalah 1. Nilai probabilitas akan berada di antara 0 dan 1 [39]. Probabilitas ini memberikan estimasi mengenai kemungkinan kalimat tersebut termasuk dalam kelas tertentu. Dalam penelitian ini, pelatihan model IndoBERT dilakukan menggunakan optimizer Adam dengan learning rate $3e-6$. Model dilatih selama 5 epoch dan dieksekusi dalam runtime GPU untuk mempercepat komputasi. Proses pelatihan dan validasi dilakukan dalam batch yang diatur oleh data loader. Setelah melalui proses fine-tuning, IndoBERT dapat langsung diterapkan untuk memprediksi sentimen yang ada dalam dataset tanpa perlu membaginya menjadi data latih dan data uji. Berikut classification report dari IndoBERT dapat dilihat pada Gambar 8.



Gambar 8. Classification Report IndoBERT

Berdasarkan Gambar 8, secara keseluruhan IndoBERT memiliki performa yang baik dalam memprediksi sentimen dengan nilai akurasi sebesar 85%, di mana dalam macro average metrics, nilai presisi 79%, recall 85%, dan F1-Score 82% menunjukkan model IndoBERT memiliki keseimbangan yang baik dalam prediksi setiap kelas sentimen. IndoBERT tidak begitu terpengaruh dengan keadaan data yang tidak seimbang, hal ini disebabkan oleh proses fine-tuning yang dilakukan sebelumnya, di mana model belajar menggunakan dataset yang telah di-clone dari repository GitHub IndoNLU.

Meskipun secara keseluruhan model IndoBERT memiliki performa yang baik, masih ada hal yang bisa dievaluasi. Seperti nilai presisi kelas positif yang masih rendah (66%) menunjukkan model masih memberikan banyak kesalahan prediksi kelas positif, terlepas dari nilai recall yang baik (82%). Ini menunjukkan model masih harus banyak belajar dalam mengenali kelas positif. Begitu juga dengan kelas netral, meskipun model sangat efektif dalam mendeteksi sampel netral, terbukti dengan nilai recall 92%. Namun, model masih memiliki nilai presisi 77%, meskipun cukup baik, model masih harus ditingkatkan dalam mengenali kelas netral. Adapun rincian hasil klasifikasi IndoBERT dapat dilihat dalam confusion matrix pada Gambar 9.



Gambar 9. Confusion Matrix IndoBERT

Berdasarkan Gambar 9, kesalahan prediksi IndoBERT pada kelas negatif cenderung memprediksi sampel negatif sebagai netral, kemudian pada kelas positif, kesalahan prediksi IndoBERT cenderung memprediksi sampel positif sebagai kelas netral. Adapun pada kelas netral, kesalahan prediksi IndoBERT hampir seimbang antara kelas negatif dan positif.

3.3.2. LDA Pada Sentimen Negatif Hasil Klasifikasi IndoBERT

Topik yang berhasil dibentuk menggunakan LDA pada sentimen negatif hasil klasifikasi IndoBERT dapat dilihat pada Gambar 12.



Gambar 12. Wordcloud Topik 1 IndoBERT

Berdasarkan Gambar 12, topik pertama pada sentimen negatif hasil klasifikasi IndoBERT dapat disimpulkan berkaitan dengan masalah dalam penggunaan mobile banking, berdasarkan kata relevan seperti transfer, saldo, transaksi, mobile banking, maintenance, rekening, dan bayar. Kata-kata tersebut dapat menunjukkan adanya penggunaan mobile banking dalam melakukan beberapa transaksi seperti transfer dana serta adanya gangguan ataupun maintenance pada aplikasi tersebut. Adapun topik kedua dapat dilihat pada Gambar 13.



Gambar 13. Worcloud Topik 2 IndoBERT

Berdasarkan Gambar 13, topik kedua dapat disimpulkan adanya masalah tarik tunai yang dihadapi nasabah. Kesimpulan tersebut diperkuat dengan adanya kata yang relevan seperti ATM, eror, tarik tunai, normal, akses, nasabah, dan uang yang dapat menggambarkan aktivitas tarik tunai melalui ATM yang dilakukan oleh nasabah.

Berdasarkan hasil LDA pada sentimen negatif kedua model, terdapat perbedaan pada visualisasi wordcloud topik yang dihasilkan antara SVM dan IndoBERT. Hal ini dapat disebabkan oleh hasil prediksi sentimen negatif kedua model tersebut. Hasil prediksi sentimen negatif SVM memiliki F1-Score 86% dengan presisi 81% dan recall 91%, sedangkan IndoBERT memiliki F1-Score 88% dengan presisi 96% dan recall 82%. Ini menunjukkan bahwa SVM berhasil menemukan lebih banyak sentimen negatif, yaitu sebesar 91%, sementara IndoBERT hanya 81% dari keseluruhan sentimen negatif. Namun, SVM juga melakukan lebih banyak kesalahan prediksi dibandingkan IndoBERT, dengan tingkat kesalahan sebesar 19%, sedangkan IndoBERT hanya 6%.

Dari hasil ini, dapat dikatakan bahwa SVM dan IndoBERT memiliki daftar sentimen negatif yang berbeda, yang tentunya dapat menghasilkan hasil yang berbeda pada wordcloud LDA. Selain itu, dalam

proses prediksi kedua model, sangat mungkin terdapat beberapa sentimen yang sebenarnya positif tetapi diprediksi sebagai negatif oleh SVM, atau sebaliknya oleh IndoBERT. Hal ini juga akan mempengaruhi kata-kata yang muncul dalam analisis topik LDA. Karena LDA bergantung pada distribusi kata dalam kumpulan data, variasi kecil dalam klasifikasi sentimen dapat menyebabkan perbedaan topik yang dihasilkan.

4. DISKUSI

Dalam penelitian ini, kami menggunakan IndoBERT untuk mengklasifikasikan sentimen, yang merupakan model berbasis BERT yang dirancang khusus untuk menangani tugas-tugas dalam bahasa Indonesia. Keunggulan IndoBERT terletak pada kemampuannya untuk memahami konteks dan nuansa bahasa Indonesia yang kompleks, yang sangat penting dalam analisis sentimen. Berbeda dengan model machine learning tradisional seperti SVM, IndoBERT dapat menangkap informasi semantik yang lebih dalam dari teks, berkat arsitektur transformernya. Keunggulan utama *transformer* adalah kemampuannya untuk memahami konteks kata dalam sebuah kalimat secara *bidirectional*, yaitu dari kiri ke kanan dan dari kanan ke kiri, sehingga dapat menangkap makna dan hubungan antar kata yang lebih akurat dibandingkan model tradisional seperti SVM, yang cenderung mengandalkan fitur seperti TF-IDF. Hal ini memungkinkan IndoBERT menghasilkan prediksi sentimen yang lebih akurat.

Dalam proses *preprocessing* kami mempertahankan bentuk kalimat untuk menyimpan informasi kontekstualnya, seperti mempertahankan kata negasi "tidak", meskipun biasanya dianggap sebagai *stopword*. Langkah ini diambil untuk memastikan bahwa makna negatif dalam kalimat tetap terjaga. Kemudian untuk mencapai hasil yang maksimal, IndoBERT diimplementasikan dengan melakukan *fine-tuning* selama 5 *epoch* menggunakan dataset dari *repository* IndoNLU, sementara dataset penelitian ini digunakan sebagai data uji. Sebagai pembandingan, kami juga menerapkan SVM dengan teknik *10-fold cross-validation* guna melihat perbandingan performa kedua model.

Beberapa penelitian sebelumnya yang juga menganalisis sentimen terkait serangan siber pada BSI memberikan dasar untuk membandingkan hasil penelitian kami. Penelitian oleh Mualfah dkk menemukan bahwa algoritma *Naïve Bayes* unggul dengan akurasi 81%, sedangkan *Random Forest* mencatat akurasi 78%. Penelitian serupa dilakukan oleh Husen dkk yang menunjukkan bahwa SVM lebih unggul dari *Naïve Bayes* dan *Logistic Regression*, dengan akurasi tertinggi sebesar 88% menggunakan fitur TF-IDF. Penelitian lainnya dilakukan oleh Putra dkk mengelompokkan sentimen ke dalam delapan emosi, dengan mayoritas sentimen positif (42,1%) dari 13.543 *tweet*. Perbandingan hasil penelitian ini dengan penelitian terdahulu dapat dilihat pada **Kesalahan! Sumber referensi tidak ditemukan.**

Tabel 2. Perbandingan Hasil Penelitian

Penelitian	Metode	Akurasi	Mayoritas Sentimen	Jumlah Data
Penelitian ini	SVM	80%	Negatif (58,4%)	22.468 <i>tweet</i>
	IndoBERT	85%		
Husen dkk	SVM	88%	Negatif (70%)	23.993 <i>tweet</i>
	<i>Logistic Regession</i>	86%		
	<i>Naïve Bayes</i>	76%		
Mualfah dkk	<i>Naïve Bayes</i>	81%	Netral (55,4%)	809 <i>tweet</i>
	<i>Random Forest</i>	78%		

Putra dkk	<i>Syuzhet</i> dan NRC <i>Lexicon</i> (8 emosi)	-	Positif (42,1%)	13.543 <i>tweet</i>
-----------	---	---	-----------------	------------------------

Berdasarkan Tabel 2, penelitian ini menunjukkan bahwa mayoritas sentimen berupa negatif sebesar 58,4% dari 22.468 tweet. Hasil ini serupa dengan temuan Husen dkk, di mana sentimen negatif mendominasi sebesar 70% dari 23.993 tweet. Sebaliknya, penelitian Mualfah dkk dan Putra dkk menemukan sentimen netral dan positif sebagai sentimen yang dominan namun dalam jumlah data yang jauh lebih sedikit. Tingginya tingkat sentimen negatif menandakan adanya persepsi negatif masyarakat terhadap serangan siber yang dialami BSI, yang tentunya dapat berdampak pada kepercayaan nasabah. Dalam hal performa model, IndoBERT menunjukkan akurasi sebesar 85%, lebih tinggi daripada metode sebelumnya yaitu Naïve Bayes (81%) dan Random Forest (78%). Namun, hasil ini masih lebih rendah dibandingkan Logistic Regression (86%) serta SVM dari penelitian Husen dkk yang mencapai 88%. Di sisi lain, SVM yang kami terapkan hanya mencatat akurasi sebesar 80%, hal ini mungkin disebabkan oleh kondisi kelas data yang tidak seimbang sehingga model kurang belajar dalam mengenali kelas minoritas. Kami juga mendapati bahwa IndoBERT dalam penelitian ini memiliki F1-Score sebesar 79%, lebih rendah dibandingkan dengan penelitian oleh Wilie dkk [37], yang merupakan pencipta IndoBERT dan mencatatkan F1-Score sebesar 87% pada model IndoBERT-base. Kami menduga hal ini disebabkan oleh kurangnya relevansi dataset fine-tuning dengan topik yang kami analisis, sehingga ke depannya penting untuk melakukan penyesuaian dataset fine-tuning agar lebih sesuai dengan konteks analisis sentimen tertentu.

Dalam penelitian ini kami juga mengimplementasikan LDA untuk pemodelan topik. Karena tujuan pemodelan topik dalam penelitian ini adalah untuk mengidentifikasi topik dalam sentimen negatif secara umum, penerapan LDA merupakan pilihan yang efisien dalam mencapai tujuan tersebut. LDA mampu menemukan topik tersembunyi berdasarkan distribusi probabilitas kata dalam kumpulan data, dan hasilnya mudah diinterpretasikan. Meskipun metode lain seperti Aspect Based Sentiment Analysis (ABSA) bisa memberikan analisis lebih mendalam, yang merinci aspek-aspek spesifik dalam sentimen, LDA tetap menjadi pilihan yang lebih efisien untuk tugas yang tidak memerlukan informasi mendalam terkait aspek tertentu seperti fitur, layanan, dan kualitas. pada dasarnya IndoBERT sendiri dapat digunakan untuk mengimplementasikan ABSA, namun penerapan ABSA dalam konteks ini akan menambah kompleksitas pemrosesan, termasuk waktu dan sumber daya yang dibutuhkan. Selain itu, data dari tweet sering kali tidak mengandung aspek-aspek spesifik yang jelas, sehingga penerapan ABSA mungkin kurang relevan untuk kasus ini, di mana tanggapan cenderung bersifat umum dan tidak terfokus pada aspek tertentu.

5. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan mengenai analisis sentimen terhadap serangan siber pada Bank Syariah Indonesia menggunakan metode SVM dan IndoBERT, didapatkan hasil bahwa mayoritas sentimen berupa sentimen negatif, sebanyak 13.120 *tweet* atau 58,4% dari keseluruhan sentimen.

Pengujian model menunjukkan bahwa IndoBERT memiliki performa yang lebih baik dibandingkan SVM dalam mengklasifikasikan sentimen. Dengan akurasi 85% dan *F1-Score* 82%, IndoBERT terbukti lebih efektif dalam menangani berbagai jenis sentimen. Meskipun secara keseluruhan memiliki performa yang baik, IndoBERT masih belum maksimal dalam memprediksi kelas positif dan netral. Hal ini mungkin disebabkan oleh dataset yang digunakan dalam proses *fine-tuning* kurang relevan dengan topik penelitian ini.

Di sisi lain, meskipun SVM memiliki akurasi yang cukup baik sebesar 80%, nilai *F1-Score* yang lebih rendah, yaitu 68%, dengan presisi 79% dan *recall* 64%, menunjukkan kinerja model yang kurang optimal, terutama dalam memprediksi kelas positif, yang merupakan kelas dengan jumlah data paling sedikit, dengan *F1-Score* sebesar 42%. Berdasarkan *confusion matrix*, model SVM cukup baik dalam memprediksi kelas negatif, tetapi mengalami kesulitan dalam mengidentifikasi kelas positif dan netral. Ketidakeimbangan kinerja dalam memprediksi sentimen ini kemungkinan besar disebabkan oleh distribusi kelas yang tidak seimbang pada data.

Hasil pemodelan topik menggunakan LDA pada sentimen negatif hasil klasifikasi kedua model, didapatkan masing-masing dua buah topik. Topik dalam sentimen negatif hasil klasifikasi SVM berkaitan dengan isu keamanan dana masyarakat serta masalah dalam transfer dan penarikan dana. Sementara itu, topik dalam sentimen negatif hasil klasifikasi IndoBERT berkaitan dengan masalah penggunaan *mobile banking* dan penarikan dana nasabah.

DAFTAR PUSTAKA

- [1] N. Tambunan *et al.*, “Berita Utama tentang Error Service di Bank Syariah Indonesia (BSI),” *Community Dev. J.*, vol. 4, no. 2, pp. 5096–5098, 2023, Accessed: Mar. 04, 2024. [Online]. Available: <http://journal.universitaspahlawan.ac.id/index.php/cdj/article/view/16340>
- [2] I. Zulfa, R. Septima, and P. Indriani, “Sistem Informasi Data Pinjaman Nasabah Berbasis Web di Bank Syariah Indonesia (BSI),” *KLIK Kaji. Ilm. Inform. dan Komput.*, vol. 3, no. 5, pp. 441–448, 2023, Accessed: Mar. 04, 2024. [Online]. Available: <http://www.djournals.com/klik/article/view/624>
- [3] I. A. Dianta and E. Zusrony, “Analisis Pengaruh Sistem Keamanan Informasi Perbankan pada Nasabah Pengguna Internet Banking,” *INTENSIF J. Ilm. Penelit. dan Penerapan Teknol. Sist. Inf.*, vol. 3, no. 1, pp. 1–9, 2019, doi: 10.29407/intensif.v3i1.12125.
- [4] E. Febriansyah, A. T. Yulinda, and N. Yuniarti, “Analisis Faktor-Faktor yang Mempengaruhi Penyaluran Kredit pada Bank Umum Konvensional yang Terdaftar di Bursa Efek Indonesia Tahun 2014–2018),” *EKOMBIS Rev. J. Ilm. Ekon. dan Bisnis*, vol. 10, no. 1, pp. 249–262, 2022, doi: 10.37676/ekombis.v10i1.1634.
- [5] H. Agustin, “Teori Bank Syariah,” *JPS (Jurnal Perbank. Syariah)*, vol. 2, no. 1, pp. 67–83, 2021, doi: 10.46367/jps.v2i1.279.
- [6] V. Marcelliana *et al.*, “Penerapan Perlindungan Konsumen terhadap Nasabah PT Bank Syariah Indonesia dalam Kasus Kebocoran Data Nasabah,” *Depos. J. Publ. Ilmu Hak.*, vol. 1, no. 2, pp. 180–194, 2023, doi: 10.59581/deposisi.v1i2.562.
- [7] R. M. Muna, E. W. H. Budianto, and N. D. T. Dewi, “Bank Syariah Indonesia (BSI): Studi Pustaka (Library Research) dan Bibliometrik VOSviewer,” *Universitas Islam Negeri Maulana Malik Ibrahim Malang*. pp. 1–16, 2023. doi: 10.5281/zenodo.10078436.
- [8] E. Shiliha, “Pengaruh Pandangan Islam, Pelayanan dan Keamanan terhadap Minat Nasabah untuk Menabung di Bank Syariah Islam (BSI) Cabang Lahat,” *MOTIVASI*, vol. 7, no. 1, pp. 15–24, 2022, doi: 10.32502/mti.v7i1.4497.
- [9] K. K. Utari, Y. Septiyana, Asnaini, and K. Elwardah, “Efisiensi Keputusan Merger Tiga Bank Syariah di Indonesia pada Masa Pandemi Covid-19 (Studi di BSI Kc Bengkulu Panorama),” *EKOMBIS Rev. J. Ilm. Ekon. dan Bisnis*, vol. 10, no. DNU 14 TH, pp. 311–324, 2022, doi: 10.37676/ekombis.v10is1.1922.
- [10] F. A. Burhan, “Deretan Top 10 Bank Terbesar Indonesia, Nomor Satu Asetnya Tembus Rp2.000 Triliun,” *Bisnis.com*. Accessed: Mar. 05, 2024. [Online]. Available: <https://finansial.bisnis.com/read/20231128/90/1718828/deretan-top-10-bank-terbesar-indonesia-nomor-satu-asetnya-tembus-rp2000-triliun>
- [11] F. A. Burhan, “Dominasi BSI di Industri Bank Syariah Indonesia Terlalu Kuat, Ini Buktinya,” *Bisnis.com*. Accessed: Mar. 05, 2024. [Online]. Available: <https://finansial.bisnis.com/read/20231115/231/1714636/dominasi-bsi-di-industri-bank-syariah-indonesia-terlalu-kuat-ini-buktinya>
- [12] OJK, *Cetak Biru Transformasi Digital Perbankan*, vol. 13, no. April. 2020. Accessed: Mar. 06, 2024. [Online]. Available: <https://www.ojk.go.id/id/berita-dan-kegiatan/info-terkini/Pages/Cetak-Biru-Transformasi-Digital-Perbankan.aspx>
- [13] KumparanTECH, “Geng Ransomware LockBit Klaim Serang BSI, Siapa Mereka?,” *kumparan.com*. Accessed: Mar. 07, 2024. [Online]. Available: <https://kumparan.com/kumparantech/geng-ransomware-lockbit-klaim-serang-bsi-siapa-mereka-200XLCKhlgC>
- [14] KumparanTECH, “Viral Data BSI Dibobol Geng Ransomware LockBit, Komut Pastikan Aman,”

- kumparan.com. Accessed: Mar. 07, 2023. [Online]. Available: <https://kumparan.com/kumparanbisnis/viral-data-bsi-dibobol-geng-ransomware-lockbit-komut-pastikan-aman-200UOEPVO16/2>
- [15] Y. N. Prasetya, D. Winarso, and Syahril, "Analisis Sentimen Masyarakat pada Twitter terhadap Isu Covid-19 Menggunakan Metode Lexicon Based," *J. FASILKOM*, vol. 11, no. 2, pp. 97–103, 2021, doi: 10.37859/jf.v11i2.2772.
- [16] S. J. Pipin and H. Kurniawan, "Analisis Sentimen Kebijakan MBKM Berdasarkan Opini Masyarakat di Twitter Menggunakan LSTM," *J. SIFO Mikroskil*, vol. 23, no. 2, pp. 197–208, 2022, doi: 10.55601/jsm.v23i2.900.
- [17] E. R. Lidinillah, T. Rohana, and A. R. Juwita, "Analisis Sentimen Twitter terhadap Steam Menggunakan Algoritma Logistic Regression dan Support Vector Machine," *TEKNOSAINS J. Sains, Teknol. dan Inform.*, vol. 10, no. 2, pp. 154–164, 2023, doi: 10.37373/teknol.v10i2.440.
- [18] D. Mualfah, A. Prihatin, R. Firdaus, and Sunanto, "Analisis Sentimen Masyarakat terhadap Kasus Pembobolan Data Nasabah Bank BSI pada Twitter Menggunakan Metode Random Forest dan Naïve Bayes," *J. FASILKOM*, vol. 13, no. 3, pp. 614–620, 2023, Accessed: Mar. 06, 2024. [Online]. Available: <https://ejournal.umri.ac.id/index.php/JIK/article/view/6478>
- [19] A. Nurkholis, Styawati, and A. Suhartanto, "Firefly Algorithm for SVM Multi-class Optimization on Soybean Land Suitability Analysis," *Int. J. Informatics Vis.*, vol. 8, no. 2, pp. 592–597, 2024, doi: 10.62527/joiv.8.2.1860.
- [20] E. Suryati, Styawati, and A. A. Aldino, "Analisis Sentimen Transportasi Online Menggunakan Ekstraksi Fitur Model Word2vec Text Embedding dan Algoritma Support Vector Machine (SVM)," *J. Teknol. Dan Sist. Inf.*, vol. 4, no. 1, pp. 96–106, 2023, doi: 10.33365/jtsi.v4i1.2445.
- [21] D. Ridhwanulah and D. H. Fudholi, "Pemodelan Topik pada Cuitan tentang Penyakit Tropis di Indonesia dengan Metode Latent Dirichlet Allocation," *J. Ilm. SINUS*, vol. 20, no. 1, pp. 11–22, 2022, doi: 10.30646/sinus.v20i1.589.
- [22] H. Oktafiandi, "Implementasi LDA untuk Pengelompokan Topik Twitter Bertagar #Mypertamina," *J. Ekon. dan Tek. Inform.*, vol. 11, no. 1, pp. 10–16, 2023, Accessed: Oct. 14, 2024. [Online]. Available: <http://e-journal.polsa.ac.id/index.php/jneti/article/view/222>
- [23] S. Mutmainah, D. H. Fudholi, and S. Hidayat, "Analisis Sentimen dan Pemodelan Topik Aplikasi Telemedicine pada Google Play Menggunakan BiLSTM dan LDA," *J. Media Inform. Budidarma*, vol. 7, no. 1, pp. 312–323, 2023, doi: 10.30865/mib.v7i1.5486.
- [24] Styawati, A. Nurkholis, A. A. Aldino, S. Samsugi, E. Suryati, and R. P. Cahyono, "Sentiment Analysis on Online Transportation Reviews Using Word2Vec Text Embedding Model Feature Extraction and Support Vector Machine (SVM) Algorithm," in *2021 International Seminar on Machine Learning, Optimization, and Data Science, ISMODE 2021*, 2022, pp. 163–167. doi: 10.1109/ISMODE53584.2022.9742906.
- [25] T. W. Putra, A. S. Sofyan, S. Sofyan, E. Rusanti, and Wahyudi, "Analisis Sentimen Twitter pada Bank Syariah Indonesia (Studi Kasus: Sistem BSI Down)," *El Mudhorib J. Kaji. Ekon. dan Perbank. Syariah*, vol. 4, no. 2, pp. 128–138, 2023, Accessed: Mar. 08, 2024. [Online]. Available: <http://e-journal.iainfmpapua.ac.id/index.php/elmudhorib/article/view/899>
- [26] 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.
- [27] A. M. Pravina, I. Cholisoddin, and P. P. Adikara, "Analisis Sentimen tentang Opini Maskapai Penerbangan pada Dokumen Twitter Menggunakan Algoritma Support Vector Machine (SVM)," *J. Pengemb. Teknologi Inf. dan Ilmu Komput.*, vol. 3, no. 3, pp. 2789–2797, 2019, Accessed: May 20, 2024. [Online]. Available: <http://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/4793>
- [28] N. A. Salsabila, Y. A. Winatmoko, A. A. Septiandri, and A. Jamal, "Colloquial Indonesian Lexicon," in *Proceedings of the 2018 International Conference on Asian Language Processing, IALP 2018*, Institute of Electrical and Electronics Engineers Inc., Jul. 2018, pp. 226–229. doi: 10.1109/IALP.2018.8629151.
- [29] D. Darwis, E. S. Pratiwi, and A. F. O. Pasaribu, "Penerapan Algoritma SVM untuk Analisis Sentimen pada Data Twitter Komisi Pemberantasan Korupsi Republik Indonesia," *J. Ilm. Edutic Pendidik. dan Inform.*, vol. 7, no. 1, pp. 1–11, 2020, doi: 10.21107/edutic.v7i1.8779.
- [30] A. Maulana, I. K. Afifah, A. Mubarrak, K. R. Fauzan, A. Dwintara, and B. P. Zen, "Comparison of Logistic Regression, Multinomialnb, SVM, and K-NN Methods on Sentiment Analysis of Gojek App Reviews on the Google Play Store," *J. Tek. Inform.*, vol. 4, no. 6, pp. 1487–1494, 2023, doi: 10.52436/1.jutif.2023.4.6.863.
- [31] A. Ikegami and I. D. M. B. A. Darmawan, "Analisis Sentimen dan Pemodelan Topik Ulasan Aplikasi Noice Menggunakan XGBoost dan LDA," *Jnatia*, vol. 1, no. 1, pp. 325–336, 2022, Accessed: May 21, 2024. [Online]. Available: <https://ojs.unud.ac.id/index.php/jnatia/article/download/92679/47046>
- [32] M. F. Arfat, Styawati, A. Nurkholis, and I. Kurniawan, "Analisis Sentimen Masyarakat Indonesia Terkait

- Vaksin Covid-19 pada Media Sosial Twitter Menggunakan Metode Support Vector Machine (SVM),” *J. Inform. J. Pengemb. IT*, vol. 7, no. 2, pp. 96–103, 2022, doi: 10.30591/jpit.v7i2.3549.
- [33] N. S. Syam *et al.*, “Model Support Vector Machine untuk Prediksi pada Penggunaan Energi Listrik di Rumah Hemat Energi,” *J. Inform.*, vol. 1, no. 2, pp. 56–59, 2022, doi: 10.57094/ji.v1i2.360.
- [34] 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.2023.4.6.1059.
- [35] Styawati and K. Mustofa, “A Support Vector Machine-Firefly Algorithm for Movie Opinion Data Classification,” *IJCCS (Indonesian J. Comput. Cybern. Syst.*, vol. 13, no. 3, pp. 219–230, 2019, doi: 10.22146/ijccs.41302.
- [36] Styawati, A. Nurkholis, S. Alim, and N. Safitri, “Study the SVM Kernel for Classification of Covid-19 Vaccine Data on Twitter,” *J. Tekno Kompak*, vol. 17, no. 1, pp. 160–170, 2023, doi: 10.33365/jtk.v17i1.2254.
- [37] B. Wilie *et al.*, “IndoNLU: Benchmark and Resources for Evaluating Indonesian Natural Language Understanding,” in *Proceedings of the 1st Conference of the Asia-Pacific Chapter of the Association for Computational Linguistics and the 10th International Joint Conference on Natural Language Processing*, 2020, pp. 843–857. Accessed: Jul. 31, 2024. [Online]. Available: <https://aclanthology.org/2020.acl-main.85>
- [38] N. L. P. M. Putu, A. Z. Amrullah, and Ismarmiaty, “Analisis Sentimen dan Pemodelan Topik Pariwisata Lombok Menggunakan Algoritma Naive Bayes dan Latent Dirichlet Allocation,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 1, pp. 123–131, 2021, doi: 10.29207/resti.v5i1.2587.
- [39] E. A. Putra, “Sentiment Analysis Using Bidirectional Encoder Representations from Transformers (BERT),” *medium.com*. Accessed: Mar. 12, 2024. [Online]. Available: <https://medium.com/@eza.a.putra/implementasi-bert-untuk-analisis-sentimen-terhadap-ulasan-aplikasi-flip-berbahasa-indonesia-557d691e0440>