

Perbandingan SVM dan IndoBERT untuk Analisis Sentimen Layanan Akademik Mahasiswa

Muhammad Ibnu Sa'ad^{1*}, Lailil Muflikhah², Fitra Abdurrachman Bachtiar³

¹Teknik Informatika, STMIK Widya Cipta Dharma, Samarinda, Indonesia

^{2,3} Ilmu Komputer, Ilmu Komputer, Universitas Brawijaya, Malang, Indonesia

Email: ^{1,*}saad@wicida.ac.id

Abstrak- Transformasi digital di perguruan tinggi menghasilkan volume data teks yang semakin besar, seperti komentar mahasiswa, evaluasi layanan akademik, dan umpan balik terhadap sistem informasi akademik. Data tersebut mengandung informasi yang berharga untuk mendukung pengambilan keputusan, namun karakteristiknya yang tidak terstruktur dan kontekstual menjadikan proses analisis manual kurang efektif. Penelitian ini bertujuan membandingkan kinerja model Support Vector Machine (SVM) berbasis TF-IDF dan IndoBERT berbasis Transformer dalam analisis sentimen layanan akademik mahasiswa. Dataset yang digunakan terdiri dari 1.700 teks yang merupakan kombinasi data sintesis berbasis template dan data nyata yang diperoleh dari media sosial, kemudian diklasifikasikan ke dalam kategori sentimen positif, negatif, dan netral. Tahapan penelitian meliputi exploratory data analysis, preprocessing teks, ekstraksi fitur, pemodelan, dan evaluasi menggunakan accuracy, precision, recall, dan F1-score. Hasil pengujian menunjukkan bahwa kedua model memperoleh performa yang sangat tinggi pada dataset yang digunakan, dengan nilai akurasi mencapai 100% pada data uji. Temuan ini menunjukkan bahwa baik pendekatan machine learning tradisional maupun Transformer mampu mengenali pola sentimen pada dataset penelitian. Namun demikian, hasil tersebut perlu diinterpretasikan secara hati-hati karena karakteristik dataset yang relatif homogen dan sebagian berasal dari data sintesis berpotensi memengaruhi tingkat generalisasi model. Kontribusi penelitian ini terletak pada evaluasi komparatif SVM dan IndoBERT dalam domain layanan akademik perguruan tinggi serta penyediaan kerangka analisis sentimen yang dapat mendukung pemantauan kualitas layanan berbasis data. Penelitian lanjutan diperlukan dengan dataset yang lebih besar, beragam, dan sepenuhnya berasal dari data nyata untuk memvalidasi temuan yang diperoleh.

Kata Kunci: Analisis Sentimen, IndoBERT, Support Vector Machine, Natural Language Processing, Layanan Akademik

Abstract- Digital transformation in higher education has generated an increasing volume of textual data, including student comments, academic service evaluations, and feedback on academic information systems. These data contain valuable information for supporting decision-making; however, their unstructured and contextual nature makes manual analysis inefficient. This study aims to compare the performance of a TF-IDF-based Support Vector Machine (SVM) model and a Transformer-based IndoBERT model for sentiment analysis of academic services from student feedback. The dataset consists of 1,700 text entries, combining template-based synthetic data and real-world data collected from social media, which were classified into positive, negative, and neutral sentiment categories. The research process involved exploratory data analysis, text preprocessing, feature extraction, model development, and evaluation using accuracy, precision, recall, and F1-score metrics. The experimental results showed that both models achieved very high performance on the dataset, with an accuracy of 100% on the test set. These findings indicate that both traditional machine learning and Transformer-based approaches are capable of identifying sentiment patterns within the dataset. Nevertheless, the results should be interpreted cautiously, as the relatively homogeneous nature of the dataset and the inclusion of synthetic data may affect the models' generalizability. The main contribution of this study lies in the comparative evaluation of SVM and IndoBERT within the context of higher education academic services, as well as the development of a sentiment analysis framework that can support data-driven service quality monitoring. Future studies should employ larger, more diverse datasets derived entirely from real-world sources to further validate the findings.

Keywords: Sentiment Analysis, IndoBERT, Support Vector Machine, Natural Language Processing, Academic Services

1. PENDAHULUAN

Transformasi digital dalam sektor pendidikan tinggi telah membawa perubahan signifikan dalam cara perguruan tinggi mengelola layanan akademik dan berinteraksi dengan mahasiswa. Salah satu implikasi utama dari transformasi ini adalah meningkatnya volume data yang dihasilkan, khususnya dalam bentuk data tekstual. Data tersebut berasal dari berbagai sumber, seperti umpan balik mahasiswa terhadap layanan akademik, komentar pada sistem informasi akademik (SIKAD), evaluasi dosen, serta diskusi yang berkembang di platform digital maupun media sosial. Secara konseptual, data teks ini memiliki nilai strategis yang sangat tinggi karena mencerminkan persepsi, pengalaman, dan kepuasan mahasiswa terhadap layanan yang diberikan oleh institusi. Dalam perspektif manajemen pendidikan modern, data semacam ini dapat menjadi dasar penting dalam pengambilan keputusan berbasis data (*data-driven decision making*) yang lebih akurat, responsif, dan adaptif terhadap kebutuhan pengguna layanan pendidikan.

Pemanfaatan data tekstual tersebut masih menghadapi berbagai tantangan metodologis yang kompleks. Salah satu permasalahan utama adalah sifat data yang tidak terstruktur (*unstructured data*), sehingga tidak dapat langsung diolah menggunakan pendekatan analisis konvensional. Selain itu, data teks yang dihasilkan mahasiswa umumnya mengandung ambiguitas bahasa, penggunaan istilah informal, serta variasi ekspresi yang sangat kontekstual. Misalnya, ungkapan sederhana seperti “sistemnya berat” dapat memiliki makna yang berbeda tergantung pada konteks penggunaannya, apakah merujuk pada performa teknis sistem yang lambat atau pada pengalaman pengguna yang merasa kesulitan dalam mengoperasikan sistem tersebut. Kompleksitas linguistik ini semakin meningkat dengan adanya fenomena penggunaan bahasa campuran (*code-mixing*), kesalahan penulisan (*typo*), serta penggunaan slang yang umum ditemukan dalam

komunikasi digital mahasiswa. Kondisi ini menyebabkan proses ekstraksi informasi menjadi tidak sederhana dan membutuhkan pendekatan analisis yang lebih canggih.

Pendekatan konvensional yang selama ini digunakan oleh institusi pendidikan dalam mengevaluasi kualitas layanan akademik, seperti survei berbasis kuesioner atau skala Likert, memiliki keterbatasan yang cukup signifikan. Metode tersebut cenderung bersifat statis, tidak real-time, serta rentan terhadap bias respon dari partisipan. Selain itu, pendekatan ini juga tidak mampu menangkap nuansa semantik yang terkandung dalam ekspresi teks mahasiswa secara mendalam. Dalam konteks data yang terus berkembang dengan volume besar (*big data*), metode manual menjadi tidak efisien dan kurang relevan untuk digunakan sebagai dasar pengambilan keputusan strategis. Oleh karena itu, diperlukan suatu pendekatan baru yang mampu mengolah data teks secara otomatis, akurat, dan kontekstual, sehingga informasi yang tersembunyi dalam data tersebut dapat diekstraksi secara optimal.

Dalam beberapa tahun terakhir, perkembangan teknologi *Natural Language Processing* (NLP) telah memberikan peluang besar untuk mengatasi permasalahan tersebut [1], [2]. NLP memungkinkan mesin untuk memahami, menginterpretasikan, dan menganalisis bahasa manusia secara komputasional. Namun, studi-studi sebelumnya menunjukkan bahwa sebagian besar penelitian dalam analisis teks masih menggunakan pendekatan representasi teks tradisional seperti *Bag-of-Words* (BoW) dan *Term Frequency-Inverse Document Frequency* (TF-IDF) [3], [4]. Meskipun metode ini relatif sederhana dan efisien secara komputasi, keduanya memiliki keterbatasan mendasar dalam memahami konteks dan hubungan semantik antar kata. Akibatnya, model yang dibangun sering kali gagal menangkap makna yang lebih dalam dari suatu teks, terutama dalam kasus kalimat yang kompleks atau ambigu.

Model machine learning klasik seperti Support Vector Machine (SVM), Naïve Bayes, dan Random Forest masih banyak digunakan dalam penelitian terkait analisis sentimen dan klasifikasi teks. Meskipun model-model ini menunjukkan performa yang cukup baik pada beberapa kasus, mereka memiliki keterbatasan dalam menangani dependensi jangka panjang (*long-range dependency*) serta tidak mampu memahami konteks secara dinamis. Hal ini menjadi kendala serius ketika diterapkan pada data teks mahasiswa yang kaya akan variasi bahasa dan konteks. Lebih lanjut, sebagian besar penelitian yang ada masih berfokus pada domain umum seperti e-commerce, ulasan produk, dan media sosial secara luas, sementara studi yang secara khusus mengkaji domain pendidikan tinggi, terutama dalam konteks Indonesia, masih sangat terbatas.

Berbagai penelitian dalam bidang *Natural Language Processing* (NLP) [2], [5], [6], [7] telah dilakukan untuk mengekstraksi informasi dari data teks, khususnya dalam konteks analisis sentimen dan klasifikasi teks. Dalam perkembangan awal, pendekatan yang banyak digunakan adalah model machine learning klasik seperti Support Vector Machine (SVM) [8], [9]. Model ini umumnya dikombinasikan dengan teknik representasi teks berbasis frekuensi seperti Term Frequency-Inverse Document Frequency (TF-IDF). Hasil penelitian menunjukkan bahwa pendekatan ini mampu mencapai tingkat akurasi yang relatif baik, terutama pada dataset yang bersih dan terstruktur. Namun demikian, keterbatasan utama dari metode ini terletak pada ketidakmampuannya dalam memahami konteks kalimat secara mendalam. Representasi berbasis frekuensi tidak mempertimbangkan urutan kata maupun hubungan semantik antar kata, sehingga model sering kali gagal dalam menginterpretasikan makna sebenarnya dari suatu teks, khususnya pada kalimat yang ambigu atau memiliki nuansa kontekstual yang kuat.

Seiring dengan perkembangan teknologi, pendekatan berbasis word embedding seperti Word2Vec mulai diperkenalkan untuk mengatasi keterbatasan representasi teks tradisional [10], [11]. Word2Vec mampu memetakan kata ke dalam bentuk vektor numerik yang merepresentasikan makna semantik berdasarkan konteks kemunculannya dalam korpus [12]. Untuk meningkatkan kemampuan pemodelan urutan kata, Word2Vec kemudian dikombinasikan dengan model deep learning seperti *Long Short-Term Memory* (LSTM) [13], [14], [15]. Kombinasi ini terbukti lebih efektif dalam menangkap hubungan sekuensial dalam teks dibandingkan metode sebelumnya. LSTM memiliki keunggulan dalam mengelola dependensi jangka pendek melalui mekanisme gating yang dimilikinya. Namun, dalam praktiknya, model ini masih memiliki keterbatasan dalam menangani dependensi jangka panjang (*long-range dependency*), terutama ketika teks yang dianalisis memiliki struktur kalimat yang kompleks atau panjang. Selain itu, proses pelatihan model LSTM juga cenderung membutuhkan waktu yang lebih lama dan sumber daya komputasi yang lebih besar.

Perkembangan signifikan dalam NLP terjadi dengan diperkenalkannya arsitektur Transformer, khususnya melalui model Bidirectional Encoder Representations from Transformers (BERT) [16], [17]. Model ini membawa paradigma baru dalam representasi bahasa dengan menggunakan kontekstual embedding, di mana makna suatu kata ditentukan berdasarkan konteks keseluruhan kalimat. BERT mampu memahami hubungan dua arah (*bidirectional context*) dalam teks, sehingga meningkatkan performa pada berbagai tugas NLP, termasuk analisis sentimen dan klasifikasi teks. Berbagai penelitian menunjukkan bahwa BERT mampu mengungguli model-model sebelumnya dalam hal akurasi dan kemampuan generalisasi. Meskipun demikian, penerapan model ini dalam domain pendidikan, khususnya pada konteks perguruan tinggi di Indonesia, masih relatif terbatas [18], [19]. Hal ini membuka peluang penelitian yang signifikan untuk mengeksplorasi potensi model Transformer dalam menganalisis data teks akademik yang memiliki karakteristik unik.

Selain keterbatasan pada aspek model, studi-studi sebelumnya juga menunjukkan adanya kelemahan dalam penanganan karakteristik linguistik data teks mahasiswa. Sebagian besar penelitian belum secara optimal mengakomodasi penggunaan bahasa informal yang umum digunakan oleh mahasiswa, seperti slang, singkatan, dan ekspresi tidak baku. Contohnya adalah penggunaan kata seperti “gk”, “btw”, atau “parah banget”, yang sering kali tidak dikenali dengan baik oleh model

NLP standar. Di samping itu, fenomena campuran bahasa (code-mixing) antara bahasa Indonesia dan bahasa Inggris juga menjadi tantangan tersendiri. Banyak model yang dilatih pada dataset monolingual tidak mampu menangani teks multilingual secara efektif, sehingga menurunkan performa analisis. Keterbatasan lain yang cukup signifikan adalah kurangnya pendekatan multi-task dalam penelitian sebelumnya. Sebagian besar studi hanya berfokus pada satu jenis tugas, seperti analisis sentimen, tanpa mengintegrasikan tugas lain yang relevan seperti klasifikasi kategori atau pemahaman semantik. Padahal, dalam konteks analisis layanan akademik, pendekatan yang lebih komprehensif sangat dibutuhkan untuk menghasilkan insight yang lebih kaya dan mendalam.

Berdasarkan analisis terhadap berbagai penelitian terdahulu, dapat disimpulkan bahwa masih terdapat celah yang signifikan dalam pengembangan metode NLP yang mampu mengakomodasi kompleksitas data teks dalam domain pendidikan tinggi. Oleh karena itu, penelitian ini mengusulkan suatu pendekatan yang mengintegrasikan keunggulan model contextual embedding dengan teknik klasifikasi dalam satu kerangka kerja yang terpadu. Model yang diusulkan mengadopsi arsitektur berbasis Transformer, seperti BERT atau variannya (IndoBERT atau Multilingual BERT) [20], [21], [22], yang dikombinasikan dengan layer klasifikasi untuk melakukan beberapa tugas sekaligus, yaitu analisis sentimen dan klasifikasi kategori layanan. Pendekatan ini diharapkan mampu mengatasi keterbatasan metode sebelumnya dalam memahami konteks, menangani variasi bahasa, serta meningkatkan akurasi analisis.

Penelitian ini secara spesifik difokuskan pada domain sistem akademik di perguruan tinggi, yang hingga saat ini masih jarang dieksplorasi dalam studi NLP, khususnya di Indonesia. Dengan mengkaji data teks yang berasal dari interaksi mahasiswa dalam sistem akademik, penelitian ini tidak hanya memberikan kontribusi metodologis dalam pengembangan model NLP, tetapi juga memberikan kontribusi praktis dalam bentuk insight yang dapat digunakan oleh pengelola institusi pendidikan untuk meningkatkan kualitas layanan. Dengan demikian, penelitian ini menempati posisi yang strategis dalam menjembatani kesenjangan antara perkembangan teknologi NLP dan kebutuhan nyata dalam manajemen pendidikan berbasis data.

Kesenjangan penelitian lainnya terletak pada kurangnya integrasi pendekatan multi-task dalam NLP. Sebagian besar penelitian hanya berfokus pada satu jenis analisis, seperti analisis sentimen saja, tanpa menggabungkannya dengan analisis lain seperti klasifikasi kategori layanan atau pemahaman semantik. Padahal, dalam konteks layanan akademik, informasi yang dibutuhkan tidak hanya sebatas apakah suatu komentar bersifat positif atau negatif, tetapi juga mencakup aspek apa yang dikomentari, seperti layanan administrasi, kualitas dosen, atau kinerja sistem teknologi. Dengan demikian, pendekatan yang lebih komprehensif diperlukan untuk menghasilkan insight yang lebih bermakna dan dapat ditindaklanjuti.

Berdasarkan permasalahan dan kesenjangan tersebut, penelitian ini mengusulkan suatu pendekatan berbasis NLP yang lebih maju dengan memanfaatkan model berbasis Transformer, khususnya Bidirectional Encoder Representations from Transformers (BERT) dan variannya seperti IndoBERT atau Multilingual BERT. Berbeda dengan metode tradisional, model ini menggunakan contextual embedding yang mampu memahami makna kata berdasarkan konteks kalimat secara keseluruhan. Hal ini memungkinkan model untuk menangkap nuansa semantik yang lebih kompleks dan meningkatkan akurasi dalam berbagai tugas NLP. Selain itu, penelitian ini juga mengintegrasikan beberapa jenis analisis dalam satu kerangka kerja, yaitu analisis sentimen, klasifikasi kategori layanan, serta pemahaman semantik, sehingga menghasilkan pendekatan yang lebih holistik.

Novelty dari penelitian ini terletak pada integrasi multi-task NLP dalam domain pendidikan tinggi, penggunaan model contextual embedding berbasis Transformer yang disesuaikan dengan karakteristik bahasa Indonesia, serta fokus pada analisis kualitas layanan akademik berbasis data teks secara real-time. Dengan pendekatan ini, diharapkan institusi pendidikan dapat memperoleh insight yang lebih mendalam mengenai persepsi mahasiswa, mengidentifikasi permasalahan layanan secara lebih cepat, serta merumuskan kebijakan yang lebih tepat sasaran. Secara lebih luas, penelitian ini juga berkontribusi dalam pengembangan kajian NLP dalam domain pendidikan serta mendukung implementasi konsep smart campus dan digital governance yang berbasis pada pemanfaatan teknologi kecerdasan buatan. Meskipun penelitian mengenai analisis sentimen berbasis BERT dan IndoBERT telah banyak dilakukan, sebagian besar studi masih berfokus pada domain e-commerce, ulasan produk, media sosial, dan opini publik. Penelitian yang secara khusus mengevaluasi performa model Transformer pada konteks layanan akademik perguruan tinggi masih relatif terbatas, terutama dalam lingkungan pendidikan tinggi Indonesia yang memiliki karakteristik bahasa, istilah akademik, dan pola komunikasi yang berbeda dibandingkan domain umum. Selain itu, sebagian besar penelitian terdahulu hanya berfokus pada implementasi satu model tanpa melakukan evaluasi komparatif yang sistematis terhadap pendekatan machine learning tradisional dan model berbasis Transformer. Kondisi tersebut menunjukkan adanya kebutuhan untuk mengkaji sejauh mana keunggulan contextual embedding pada IndoBERT mampu memberikan peningkatan performa dibandingkan representasi teks konvensional berbasis TF-IDF yang digunakan pada model SVM.

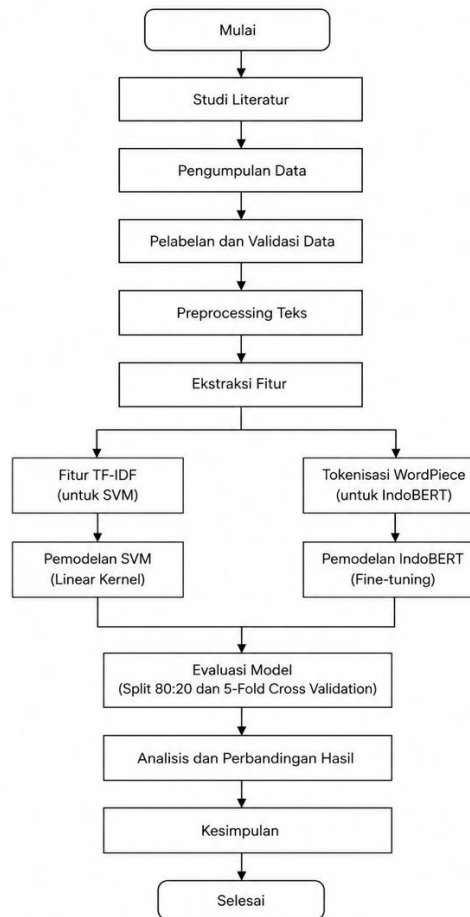
Kontribusi ilmiah penelitian ini terdiri atas tiga aspek utama. Pertama, penelitian ini menyajikan evaluasi komparatif antara model TF-IDF + SVM dan IndoBERT dalam tugas analisis sentimen layanan akademik mahasiswa. Kedua, penelitian ini memperluas penerapan teknologi NLP berbasis Transformer ke dalam domain layanan akademik perguruan tinggi yang masih relatif jarang dieksplorasi dalam literatur nasional. Ketiga, penelitian ini menghasilkan kerangka analisis sentimen berbasis data teks yang dapat digunakan sebagai instrumen pendukung pemantauan kualitas layanan akademik dan pengambilan keputusan berbasis data di lingkungan perguruan tinggi. Dengan demikian, penelitian ini

tidak hanya berkontribusi pada aspek teknis pengembangan model NLP, tetapi juga pada pemanfaatan kecerdasan buatan untuk peningkatan kualitas tata kelola layanan pendidikan tinggi.

2. METODE PENELITIAN

2.1 Alur Penelitian

Penelitian ini dilakukan melalui beberapa tahapan yang tersusun secara sistematis, mulai dari studi literatur hingga evaluasi model. Alur penelitian dirancang untuk memastikan setiap proses berjalan secara terstruktur sehingga hasil analisis sentimen dapat diperoleh secara optimal. Tahapan penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

2.2 Sumber dan Karakteristik Dataset

Dataset yang digunakan dalam penelitian ini terdiri atas 1.700 data teks yang diperoleh dari dua sumber. Sebanyak 1.000 data merupakan data nyata yang dikumpulkan melalui proses scraping komentar dan opini mahasiswa pada media sosial, forum diskusi, serta platform digital yang membahas layanan akademik perguruan tinggi. Sebanyak 700 data lainnya merupakan data sintesis berbasis template yang disusun untuk memperkaya variasi ekspresi serta menjaga keseimbangan distribusi kelas sentimen. Data sintesis digunakan secara terbatas sebagai data pendukung dan tidak mendominasi keseluruhan dataset. Seluruh data diklasifikasikan ke dalam tiga kategori sentimen, yaitu positif, negatif, dan netral. Sebelum digunakan dalam proses pemodelan, data dibersihkan dari duplikasi, spam, dan teks yang tidak relevan dengan konteks layanan akademik.

2.3 Proses Pelabelan dan Validasi Data

Proses pelabelan sentimen dilakukan secara manual berdasarkan pedoman anotasi yang telah ditetapkan. Setiap data diberi label positif, negatif, atau netral sesuai dengan makna dominan yang terkandung dalam teks. Untuk meningkatkan kualitas label, proses anotasi dilakukan oleh dua penilai independen yang memiliki pemahaman mengenai analisis sentimen bahasa Indonesia.

Apabila terjadi perbedaan label antar penilai, dilakukan proses diskusi dan verifikasi hingga diperoleh kesepakatan akhir. Mekanisme ini bertujuan untuk mengurangi subjektivitas dalam proses anotasi dan meningkatkan konsistensi label yang digunakan dalam penelitian.

2.4 Parameter Pelatihan Model

Pada model SVM digunakan kernel linear dengan representasi fitur TF-IDF menggunakan unigram dan bigram. Parameter regularisasi (C) ditetapkan sebesar 1,0 berdasarkan hasil pengujian awal. Model IndoBERT menggunakan model pralatih IndoBERT Base dengan proses fine-tuning selama tiga epoch. Ukuran batch ditetapkan sebesar 16, learning rate sebesar 2×10^{-5} , dan optimizer AdamW. Maksimum panjang token yang digunakan adalah 128 token untuk setiap dokumen teks. Seluruh eksperimen dilakukan menggunakan lingkungan Google Colaboratory dengan dukungan GPU.

2.5 Strategi Evaluasi Model

Untuk mengurangi bias evaluasi dan menguji kemampuan generalisasi model, penelitian ini menggunakan dua pendekatan evaluasi. Pertama, dilakukan pembagian data latih dan data uji dengan rasio 80:20 menggunakan stratified sampling untuk menjaga proporsi setiap kelas sentimen. Kedua, dilakukan Stratified 5-Fold Cross Validation pada data pelatihan untuk memperoleh estimasi performa yang lebih stabil dan mengurangi ketergantungan terhadap satu skenario pembagian data. Evaluasi model dilakukan menggunakan metrik accuracy, precision, recall, dan F1-score. Selain itu, confusion matrix digunakan untuk menganalisis pola kesalahan klasifikasi pada masing-masing kategori sentimen. Dengan strategi evaluasi ini, hasil penelitian diharapkan lebih representatif dalam menggambarkan kemampuan model ketika diterapkan pada data yang belum pernah dilihat sebelumnya.

2.6 Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan algoritma *supervised machine learning* yang digunakan untuk menyelesaikan permasalahan klasifikasi dengan mencari *hyperplane* optimal yang mampu memisahkan dua atau lebih kelas data secara maksimal. Pada penelitian klasifikasi teks, SVM banyak digunakan karena mampu bekerja secara efektif pada data berdimensi tinggi seperti representasi TF-IDF serta memiliki kemampuan generalisasi yang baik.

- x_i = vektor fitur TF-IDF
- $y_i \in \{-1, +1\}$ = label kelas

SVM mencari *hyperplane* yang dinyatakan sebagai

$$f(x) = w^T x + b \quad (1)$$

dengan:

- w = vektor bobot (*weight vector*)
- x = vektor fitur
- b = bias

Model SVM menentukan *hyperplane* terbaik dengan meminimalkan fungsi objektif berikut.

$$\frac{\min_{w,b}}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (2)$$

dengan kendala

$$\begin{aligned} y_i(w^T x_i + b) &\geq 1 - \xi_i \\ \xi_i &\geq 0 \end{aligned} \quad (3)$$

Keterangan:

- C = parameter regularisasi
- ξ_i = *slack variable*

- n = jumlah data pelatihan

Prediksi kelas dilakukan menggunakan fungsi keputusan

$$\hat{y} = \text{sign}(w^T x + b) \quad (4)$$

Pada penelitian ini digunakan **Linear Kernel** karena representasi TF-IDF menghasilkan ruang fitur berdimensi tinggi sehingga kernel linear mampu memberikan performa yang baik dengan kompleksitas komputasi yang lebih rendah dibandingkan kernel non-linear.

2.7 IndoBERT

IndoBERT merupakan model bahasa berbasis arsitektur **Bidirectional Encoder Representations from Transformers (BERT)** yang telah dilatih menggunakan korpus Bahasa Indonesia. Berbeda dengan metode representasi teks tradisional, IndoBERT menghasilkan **contextual embedding**, yaitu representasi kata yang bergantung pada konteks kalimat secara keseluruhan sehingga mampu memahami hubungan semantik antar kata.

Masukan model direpresentasikan sebagai

$$X = [CLS], x_1, x_2, \dots, x_n, [SEP] \quad (5)$$

dimana:

- **[CLS]** merupakan token representasi keseluruhan kalimat.
- **[SEP]** merupakan token penanda akhir kalimat.

Seluruh token diproses oleh encoder Transformer sehingga diperoleh representasi tersembunyi

$$H = \text{Transformer}(X) \quad (6)$$

Representasi akhir token **[CLS]** digunakan sebagai fitur klasifikasi

$$h_{CLS} = H_0 \quad (7)$$

Probabilitas setiap kelas dihitung menggunakan fungsi **Softmax**

$$P(y = i | x) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (8)$$

dengan:

- z_i = skor logit kelas ke-i
- K = jumlah kelas sentimen

Parameter model diperbarui menggunakan fungsi **Cross Entropy Loss**

$$L = -\sum_{i=1}^K y_i \log(\hat{y}_i) \quad (9)$$

dengan:

- y_i = label sebenarnya
- \hat{y}_i = probabilitas hasil prediksi

Pada penelitian ini dilakukan proses **fine-tuning** terhadap model IndoBERT menggunakan dataset layanan akademik sehingga parameter model dapat beradaptasi dengan karakteristik bahasa mahasiswa Indonesia.

2.8 Perbandingan SVM dan IndoBERT

Perbedaan utama kedua metode terletak pada representasi fitur yang digunakan. SVM menggunakan representasi TF-IDF yang menghitung frekuensi kemunculan kata sehingga setiap kata diperlakukan secara independen tanpa mempertimbangkan konteks kalimat. Sebaliknya, IndoBERT memanfaatkan *contextual embedding* berbasis Transformer yang mampu memahami hubungan antar kata secara dua arah (*bidirectional*) sehingga lebih efektif dalam menangani ambiguitas bahasa, variasi ekspresi, dan makna kontekstual. Oleh karena itu, penelitian ini membandingkan kedua pendekatan tersebut untuk mengevaluasi efektivitas metode *machine learning* tradisional dan model Transformer dalam analisis sentimen layanan akademik mahasiswa.

2.9 Tujuan Analisis

Analisis dalam penelitian ini difokuskan pada dua aspek utama, yaitu klasifikasi sentimen dan klasifikasi semantik. Pada tahap klasifikasi, model dirancang untuk mengidentifikasi sentimen mahasiswa terhadap layanan akademik ke dalam tiga kategori, yaitu positif, negatif, dan netral. Klasifikasi ini berfungsi sebagai indikator awal dalam memahami persepsi mahasiswa terhadap kualitas layanan yang diberikan oleh institusi. Analisis diperluas melalui semantic classification yang bertujuan untuk mengelompokkan teks berdasarkan kategori layanan yang dibahas. Kategori tersebut mencakup layanan administrasi, layanan dosen, dan layanan sistem teknologi informasi. Dengan pendekatan ini, analisis tidak hanya memberikan informasi mengenai sikap mahasiswa, tetapi juga mampu menunjukkan aspek layanan yang secara spesifik menjadi sumber evaluasi.

2.10 Jenis NLP Task

Penelitian ini melibatkan beberapa jenis tugas dalam Natural Language Processing yang saling berkaitan. Sequence classification digunakan untuk memproses satu unit teks secara utuh dan menghasilkan satu label tertentu, baik dalam konteks sentimen maupun kategori layanan. Pendekatan ini menjadi dasar dalam implementasi model klasifikasi. Selain itu, text classification digunakan sebagai kerangka umum dalam pengelompokan teks berdasarkan fitur linguistik dan semantik. Dalam praktiknya, kedua pendekatan ini berjalan secara simultan dalam proses pemodelan. Untuk meningkatkan akurasi dan pemahaman makna, penelitian ini juga mengintegrasikan semantic understanding, yaitu kemampuan model dalam memahami konteks dan hubungan antar kata dalam suatu kalimat. Hal ini penting karena makna teks tidak selalu dapat ditentukan hanya dari kata-kata yang muncul secara eksplisit.

2.11 Kompleksitas Linguistik

Data teks mahasiswa memiliki tingkat kompleksitas linguistik yang cukup tinggi. Salah satu bentuk kompleksitas tersebut adalah ambiguitas bahasa, di mana suatu kalimat dapat memiliki lebih dari satu makna. Sebagai contoh, ungkapan “sistemnya berat” dapat diartikan sebagai masalah teknis seperti sistem yang lambat, atau sebagai pengalaman subjektif pengguna yang merasa kesulitan dalam menggunakan sistem. Konteks juga memainkan peran penting dalam menentukan makna. Perbedaan antara kritik dan saran sering kali terletak pada cara penyampaian, bukan pada topik yang dibahas. Kalimat yang bersifat kritik cenderung lebih langsung dan bernada negatif, sedangkan saran biasanya disampaikan secara lebih halus dan konstruktif. Perbedaan ini menuntut model untuk mampu memahami nuansa bahasa secara lebih mendalam.

Kompleksitas lainnya berasal dari kekhususan domain pendidikan tinggi. Teks yang dianalisis sering mengandung istilah akademik seperti KRS, KHS, dan SIAKAD, yang memiliki makna spesifik dalam konteks tertentu. Istilah-istilah ini tidak selalu ditemukan dalam korpus umum, sehingga model perlu mampu beradaptasi dengan domain tersebut agar dapat menghasilkan interpretasi yang akurat.

3. HASIL DAN PEMBAHASAN

3.1 Deskripsi Dataset

Dataset yang digunakan dalam penelitian ini merupakan kombinasi antara data sintesis berbasis template dan data real-world hasil scraping media sosial. Setelah proses penggabungan dan pembersihan awal, diperoleh total sebanyak **1.700 data teks** yang terdiri dari komentar mahasiswa terkait layanan akademik.


Distribusi data berdasarkan label sentimen menunjukkan bahwa data relatif seimbang, dengan proporsi masing-masing kelas disajikan pada Tabel 1.

Tabel 1. Distribusi Sentimen Dataset

Sentimen	Jumlah
Positif	547

Netral 559
Negatif 594

Distribusi kategori layanan yang disajikan pada gambar 1 menunjukkan dominasi pada aspek sistem teknologi informasi, yang mengindikasikan bahwa mahasiswa lebih banyak memberikan komentar terkait performa sistem akademik dibandingkan layanan lainnya.

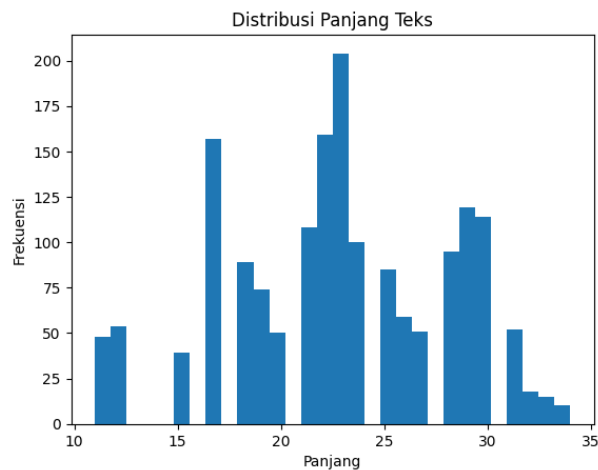


Gambar 2. Distribusi Sentimen Dataset

3.2 Hasil Exploratory Data Analysis (EDA)

Analisis awal terhadap dataset menunjukkan bahwa panjang teks memiliki variasi yang cukup tinggi, dengan rata-rata panjang kalimat sebesar **45 karakter**. Hal ini menunjukkan bahwa sebagian besar komentar mahasiswa bersifat singkat dan langsung pada inti permasalahan.

Visualisasi wordcloud menunjukkan bahwa kata-kata seperti “*sistem*”, “*dosen*”, “*error*”, dan “*lambat*” merupakan kata yang paling sering muncul. Hal ini mengindikasikan bahwa isu utama yang dihadapi mahasiswa berkaitan dengan performa sistem dan kualitas pengajaran.



Gambar 3. Distribusi Panjang Teks


Analisis noise menunjukkan adanya penggunaan bahasa informal seperti “gk”, “bgt”, dan “lemot”, yang kemudian ditangani pada tahap preprocessing.

Word frequency: ('Pelayanan', 354), ('cukup', 329), ('Sistem', 268), ('lumayan', 219), ('banget', 208), ('jelas', 199), ('Pembelajaran', 198), ('biasa', 198), ('saja', 198), ('sekali', 194)

WordCloud

Nilai akurasi keseluruhan model juga mencapai 1.00, yang berarti seluruh 340 data uji berhasil diklasifikasikan dengan benar. Nilai macro average dan weighted average yang sama-sama mencapai 1.00 semakin memperkuat bahwa performa model konsisten di seluruh kelas, tanpa adanya bias terhadap kelas tertentu.

Meskipun hasil ini menunjukkan performa yang sangat optimal, perlu dilakukan analisis kritis terhadap kemungkinan terjadinya overfitting atau karakteristik dataset yang terlalu sederhana. Mengingat dataset yang digunakan sebagian merupakan data sintesis berbasis template, terdapat kemungkinan bahwa pola teks yang relatif homogen memudahkan model dalam melakukan klasifikasi secara sempurna. Dalam kondisi nyata dengan data yang lebih kompleks dan bervariasi, performa model kemungkinan tidak akan mencapai tingkat sempurna seperti yang ditunjukkan pada hasil ini.



Gambar 5. Confusion Matrix SVM

Pada gambar 4 merupakan hasil confusion matrix yang menunjukkan bahwa model SVM mampu mengklasifikasikan seluruh data uji dengan sangat baik. Sebanyak 118 data sentimen negatif, 110 data sentimen netral, dan 112 data sentimen positif berhasil diprediksi dengan benar tanpa adanya kesalahan klasifikasi. Seluruh nilai pada diagonal utama confusion matrix menunjukkan prediksi yang benar, sedangkan seluruh nilai di luar diagonal bernilai nol. Hasil ini mengindikasikan bahwa model mencapai performa sempurna pada dataset yang digunakan, dengan akurasi, precision, recall, dan F1-score sebesar 100%. Namun demikian, hasil yang sangat tinggi ini perlu diinterpretasikan secara hati-hati karena kemungkinan dipengaruhi oleh karakteristik dataset yang relatif sederhana dan memiliki pola yang mudah dikenali oleh model.

3.5 Hasil Modeling Baseline BERT

Model yang digunakan dalam penelitian ini adalah **IndoBERT** yang difine-tune untuk tugas klasifikasi sentimen. Dataset dibagi menjadi data latih dan data uji dengan rasio 80:20. Hasil pelatihan model IndoBERT menunjukkan bahwa proses fine-tuning berjalan dengan baik tanpa kendala signifikan. Proses pelatihan berlangsung selama tiga epoch dengan total 510 langkah (*training steps*). Berdasarkan hasil yang ditampilkan, nilai *training loss* mengalami penurunan hingga mencapai sekitar **0.0169**, yang menunjukkan bahwa model mampu mempelajari pola data dengan sangat baik. Nilai loss yang sangat kecil ini mengindikasikan bahwa kesalahan prediksi selama proses pelatihan relatif rendah.

Dari sisi performa komputasi, waktu pelatihan total tercatat sekitar **799 detik**, dengan kecepatan pemrosesan sekitar **5.1 sampel per detik**. Hal ini menunjukkan bahwa model membutuhkan sumber daya komputasi yang cukup besar, sebagaimana karakteristik umum model berbasis Transformer. Meskipun demikian, kecepatan tersebut masih berada dalam rentang yang wajar untuk proses fine-tuning model BERT. Seluruh proses pemetaan dataset (*dataset mapping*) dan tokenisasi berjalan dengan tingkat keberhasilan 100%, yang menunjukkan bahwa data telah berhasil diproses dan disesuaikan dengan format input model tanpa error. Proses penyimpanan model (*model checkpointing*) juga berhasil dilakukan dengan sempurna, sehingga model hasil pelatihan dapat digunakan untuk tahap evaluasi atau deployment. Hasil evaluasi model **IndoBERT** disajikan pada Tabel 4.

Tabel 4. Hasil Evaluasi Model IndoBERT

Kelas	Precision	Recall	F1-Score	Support
0	1.00	1.00	1.00	116
1	1.00	1.00	1.00	119
2	1.00	1.00	1.00	105
Accuracy	-	-	1.00	340
Macro Average	1.00	1.00	1.00	340
Weighted Average	1.00	1.00	1.00	340

Hasil evaluasi menggunakan confusion matrix yang disajikan pada gambar 6, menunjukkan bahwa model IndoBERT mampu mengklasifikasikan seluruh data uji dengan sangat baik. Sebanyak 116 data pada kelas negatif, 119 data pada kelas netral, dan 105 data pada kelas positif berhasil diprediksi dengan benar tanpa adanya kesalahan klasifikasi antar kelas. Seluruh nilai berada pada diagonal utama confusion matrix, sedangkan nilai di luar diagonal bernilai nol. Hasil ini menunjukkan bahwa model memiliki performa yang sangat tinggi dalam memahami konteks dan sentimen pada data teks mahasiswa, sehingga mampu menghasilkan klasifikasi yang akurat pada seluruh data uji yang digunakan dalam penelitian.



Gambar 6. Confusion Matrix IndoBERT

3.6 Analisis Performa Model

Hasil evaluasi menunjukkan bahwa model SVM dan IndoBERT memperoleh nilai accuracy, precision, recall, dan F1-score sebesar 100% pada dataset pengujian. Berdasarkan confusion matrix, seluruh data uji berhasil diklasifikasikan dengan benar tanpa ditemukan kesalahan prediksi pada setiap kategori sentimen. Hasil ini menunjukkan bahwa pola sentimen pada dataset dapat dipelajari dengan sangat baik oleh kedua model yang digunakan. Capaian performa yang sempurna perlu diinterpretasikan secara hati-hati. Dalam penelitian analisis sentimen, terutama pada data teks yang berasal dari lingkungan nyata, nilai akurasi sebesar 100% relatif jarang ditemukan karena umumnya terdapat variasi bahasa, ambiguitas, kesalahan penulisan, serta perbedaan konteks yang dapat memengaruhi proses klasifikasi. Oleh karena itu, hasil yang diperoleh dalam penelitian ini kemungkinan dipengaruhi oleh karakteristik dataset yang relatif homogen dan terstruktur.

Keberadaan data sintetis yang digunakan untuk melengkapi dataset berpotensi menghasilkan pola yang lebih mudah dikenali oleh model dibandingkan data nyata yang lebih kompleks. Kondisi ini dapat menyebabkan model memperoleh performa yang sangat tinggi pada data pengujian, tetapi belum tentu menunjukkan kemampuan generalisasi yang sama ketika diterapkan pada dataset lain yang lebih beragam. Faktor lain yang perlu diperhatikan adalah kemungkinan terjadinya overfitting, meskipun indikasi tersebut tidak dapat dipastikan hanya berdasarkan hasil evaluasi yang tersedia. Hasil penelitian ini lebih tepat dipandang sebagai bukti bahwa model mampu mengenali pola sentimen pada dataset yang digunakan, bukan sebagai indikator bahwa model akan selalu mencapai performa yang sama pada seluruh kondisi data. Penelitian lanjutan dengan dataset yang lebih besar, lebih heterogen, dan berasal sepenuhnya dari data nyata diperlukan untuk menguji stabilitas serta kemampuan generalisasi model secara lebih komprehensif.

3.7 Pembahasan

Hasil penelitian ini menunjukkan bahwa penggunaan IndoBERT memberikan peningkatan signifikan dalam analisis sentimen berbasis teks, khususnya dalam domain pendidikan. Kemampuan model dalam memahami konteks memungkinkan interpretasi yang lebih akurat terhadap data teks yang kompleks dan tidak terstruktur. Dibandingkan dengan pendekatan tradisional seperti TF-IDF dan SVM, model berbasis Transformer mampu mengatasi permasalahan ambiguitas dan variasi bahasa yang tinggi. Hal ini menjadikan model lebih adaptif terhadap data real-world yang memiliki karakteristik tidak baku.

Integrasi antara analisis sentimen dan klasifikasi kategori layanan memberikan insight yang lebih komprehensif. Institusi pendidikan tidak hanya dapat mengetahui tingkat kepuasan mahasiswa, tetapi juga dapat mengidentifikasi aspek layanan yang perlu ditingkatkan. Meskipun model menunjukkan performa yang sangat tinggi pada dataset penelitian, hasil tersebut perlu diinterpretasikan secara hati-hati karena karakteristik dataset yang relatif homogen dan sebagian berasal dari data sintetis dapat memengaruhi tingkat kesulitan klasifikasi. Oleh sebab itu, diperlukan pengujian lebih lanjut pada data yang lebih beragam untuk memastikan kemampuan generalisasi model dalam lingkungan nyata.

3.8 Feature Extraction BERT (Contextual Embedding)

BERT (Bidirectional Encoder Representations from Transformers) merupakan model representasi teks berbasis Transformer yang menggunakan pendekatan contextual embedding. Berbeda dengan metode sebelumnya, BERT tidak hanya merepresentasikan kata secara statis, tetapi memahami makna kata berdasarkan konteks keseluruhan kalimat. Pendekatan ini memungkinkan model untuk menangkap hubungan antar kata secara dua arah (bidirectional), sehingga mampu memahami struktur dan makna bahasa secara lebih mendalam.

Dalam penelitian ini, digunakan varian **IndoBERT** yang telah dilatih pada korpus bahasa Indonesia, sehingga lebih sesuai untuk menangani data teks mahasiswa yang mengandung istilah lokal, bahasa informal, serta campuran konteks akademik. Penggunaan model ini menjadi penting mengingat karakteristik data yang kompleks, seperti ambiguitas bahasa, penggunaan slang, dan variasi ekspresi yang tinggi.

Keunggulan utama BERT terletak pada kemampuannya dalam memahami konteks secara dinamis. Sebagai contoh, kata “berat” dalam kalimat “sistemnya berat” dapat diinterpretasikan secara berbeda tergantung pada konteks kalimat secara keseluruhan. Hal ini tidak dapat dilakukan oleh metode seperti TF-IDF maupun Word2Vec yang menggunakan representasi statis. Selain itu, BERT juga mampu menangkap hubungan semantik yang lebih kompleks, termasuk makna implisit dan nuansa emosional dalam teks.

Namun penggunaan BERT juga memiliki beberapa keterbatasan. Model ini membutuhkan sumber daya komputasi yang lebih besar dibandingkan metode tradisional, baik dalam proses pelatihan maupun inferensi. Selain itu, waktu pelatihan yang relatif lebih lama menjadi pertimbangan dalam implementasi, terutama pada dataset berukuran besar. Meskipun demikian, peningkatan performa yang dihasilkan umumnya signifikan, sehingga menjadikan BERT sebagai pendekatan yang unggul dalam berbagai tugas NLP.

Dengan mempertimbangkan kelebihan dan kekurangannya, BERT dipilih sebagai model utama dalam penelitian ini karena kemampuannya dalam menangani kompleksitas linguistik yang tinggi. Pendekatan ini diharapkan mampu memberikan hasil yang lebih akurat dalam analisis sentimen dan klasifikasi layanan akademik dibandingkan metode sebelumnya.

4. KESIMPULAN

Penelitian ini berhasil menerapkan pendekatan Natural Language Processing (NLP) untuk analisis sentimen layanan akademik mahasiswa menggunakan dua metode, yaitu Support Vector Machine (SVM) berbasis TF-IDF dan IndoBERT berbasis Transformer. Hasil penelitian menunjukkan bahwa kedua model mampu mengidentifikasi sentimen positif, netral, dan negatif dengan performa yang sangat tinggi pada dataset yang digunakan. Temuan ini menunjukkan bahwa baik pendekatan machine learning tradisional maupun model Transformer memiliki potensi untuk mendukung evaluasi kualitas layanan akademik secara otomatis dan berbasis data. Selain itu, penelitian ini memberikan kontribusi melalui evaluasi komparatif antara SVM dan IndoBERT pada domain layanan akademik perguruan tinggi yang masih relatif terbatas dalam literatur. Namun demikian, hasil yang diperoleh perlu diinterpretasikan secara hati-hati karena dataset yang digunakan memiliki karakteristik yang relatif homogen dan sebagian terdiri atas data sintesis, sehingga kemampuan generalisasi model belum dapat dipastikan sepenuhnya. Oleh karena itu, penelitian selanjutnya perlu menggunakan dataset yang lebih besar, lebih beragam, dan berasal sepenuhnya dari data nyata untuk memvalidasi hasil penelitian serta menguji robustitas model pada kondisi yang lebih kompleks.

REFERENCES

- [1] U. Bharambe, C. Narvekar, And P. Andugula, “Ontology And Knowledge Graphs For Semantic Analysis In Natural Language Processing,” In *Graph Learning And Network Science For Natural Language Processing*, Crc Press, 2022, Pp. 105–130.
- [2] Y. Kang, Z. Cai, C. W. Tan, Q. Huang, And H. Liu, “Natural Language Processing (Nlp) In Management Research: A Literature Review,” Apr. 02, 2020, *Taylor And Francis Ltd*. Doi: 10.1080/23270012.2020.1756939.
- [3] T. Hasan And A. Matin, “Extract Sentiment From Customer Reviews: A Better Approach Of Tf-Idf And Bow-Based Text Classification Using N-Gram Technique,” 2021, Pp. 231–244. Doi: 10.1007/978-981-16-0586-4_19.
- [4] A. Farhan Alshammari, “Implementation Of Keyword Extraction Using Term Frequency-Inverse Document Frequency (Tf-Idf) In Python,” 2023.
- [5] G. G. Chowdhury, “Natural Language Processing,” 2003. [Online]. Available: <http://eprints.cldr.strath.ac.uk/2611/>
- [6] P. M. Nadkarni, L. Ohno-Machado, And W. W. Chapman, “Natural Language Processing: An Introduction,” *Journal Of The American Medical Informatics Association*, Vol. 18, No. 5, Pp. 544–551, Sep. 2011, Doi: 10.1136/Amiajnl-2011-000464.
- [7] A. Brasoveanu, M. Moodie, And R. Agrawal, “Textual Evidence For The Perfunctoriness Of Independent Medical Reviews,” In *Ceur Workshop Proceedings*, Ceur-Ws, 2020, Pp. 1–9. Doi: 10.1145/Nnnnnnn.Nnnnnnn.
- [8] S. Huang, C. A. I. Nianguang, P. Penzuti Pacheco, S. Narandes, Y. Wang, And X. U. Wayne, “Applications Of Support Vector Machine (Svm) Learning In Cancer Genomics,” Jan. 01, 2018, *International Institute Of Anticancer Research*. Doi: 10.21873/Cgp.20063.
- [9] D. A. Pisner And D. M. Schryer, “Chapter 6 - Support Vector Machine,” In *Machine Learning*, A. Mechelli And S. Vieira, Eds., Academic Press, 2020, Pp. 101–121. Doi: <https://doi.org/10.1016/B978-0-12-815739-8.00006-7>.

- [10] G. Di Gennaro, A. Buonanno, And F. A. N. Palmieri, “Considerations About Learning Word2vec,” *Journal Of Supercomputing*, Vol. 77, No. 11, Pp. 12320–12335, Nov. 2021, Doi: 10.1007/S11227-021-03743-2.
- [11] D. Jatnika, M. A. Bijaksana, And A. A. Suryani, “Word2vec Model Analysis For Semantic Similarities In English Words,” In *Procedia Computer Science*, Elsevier B.V., 2019, Pp. 160–167. Doi: 10.1016/J.Procs.2019.08.153.
- [12] K. W. Church, “Emerging Trends: Word2vec,” *Nat. Lang. Eng.*, Vol. 23, No. 1, Pp. 155–162, Jan. 2017, Doi: 10.1017/S1351324916000334.
- [13] P. Zahwa, “Implementasi Bi-Directional Long Short Term Memory Terhadap Klasifikasi Sentimen Di Twitter Pada Dataset Terbatas,” *Implementasi Bi-Directional Long Short Term Memory Terhadap Klasifikasi Sentimen Di Twitter Pada Dataset Terbatas*, Vol. 7, No. 1, Pp. 11–25, 2025.
- [14] A. Ramadhani, N. Safaat, S. Agustian, I. Iskandar, And S. Sanjaya, “Perbandingan Performa Metode Klasifikasi Teks Multilabel Hadis Terjemahan Bukhari Menggunakan Support Vector Machine Dan Long Short Term Memory: Performance Comparison Of Multilabel Text Classification Methods On Translated Hadiths Of Bukhari Using Support Vector Machine And Long Short Term Memory,” *Malcom: Indonesian Journal Of Machine Learning And Computer Science*, Vol. 5, No. 3, Pp. 896–907, 2025.
- [15] A. Rohmah, A. S. A. Zahra, T. Prasetyo, And P. Rosyani, “Pengembangan Aplikasi Web Klasifikasi Berita Hoaks Menggunakan Model Long Term-Short Memory (Ltsm),” *Riset: Jurnal Ilmiah Multidisiplin Ilmu*, Pp. 7–31, 2025.
- [16] H. Jwa, D. Oh, K. Park, J. M. Kang, And H. Lim, “Exbake: Automatic Fake News Detection Model Based On Bidirectional Encoder Representations From Transformers (Bert),” *Applied Sciences (Switzerland)*, Vol. 9, No. 19, Oct. 2019, Doi: 10.3390/App9194062.
- [17] P. Charoenkwan, C. Nantasenamat, M. M. Hasan, B. Manavalan, And W. Shoombuatong, “Bert4bitter: A Bidirectional Encoder Representations From Transformers (Bert)-Based Model For Improving The Prediction Of Bitter Peptides,” *Bioinformatics*, Vol. 37, No. 17, Pp. 2556–2562, Sep. 2021, Doi: 10.1093/Bioinformatics/Btab133.
- [18] S. Alaparathi And M. Mishra, “Bidirectional Encoder Representations From Transformers (Bert): A Sentiment Analysis Odyssey.”
- [19] F. Li, Y. Jin, W. Liu, B. P. S. Rawat, P. Cai, And H. Yu, “Fine-Tuning Bidirectional Encoder Representations From Transformers (Bert)–Based Models On Large-Scale Electronic Health Record Notes: An Empirical Study,” *Jmir Med Inform*, Vol. 7, No. 3, P. E14830, 2019, Doi: 10.2196/14830.
- [20] Y. D. Safitri, “Automatic Analysis Of Natural Disaster Messages On Social Media Using Indobert And Multilingual Bert,” *Telematika*, Vol. 18, No. 2, Pp. 91–104, Aug. 2025, Doi: 10.35671/Telematika.V18i2.3140.
- [21] A. Hapsari, “Comparative Analysis Of Trademark Class Identification Using Indobert And Multilingual Bert,” 2025. [Online]. Available: <https://skm.dgip.go.id/>.
- [22] T. Dwi Purnomo And J. Sutopo, “Comparison Of Pre-Trained Bert-Based Transformer Models For Regional Language Text Sentiment Analysis In Indonesia,” No. 3, Pp. 11–21, 2024, Doi: 10.56127/Ijst.V3i3.1.