

Analisis Perbandingan Pelabelan Inset Lexicon dan MBERT pada Sentimen Danantara Menggunakan SVM dengan Kernel Trick

Rusmini*, Heliawati Hamrul, A. Amirul Asnan Cirua

Fakultas Teknik, Program Studi Teknik Informatika, Universitas Sulawesi Barat, Majene, Indonesia
Email: ^{1*}rusmini140702@gmail.com, ²heliawatyhamrul@unsulbar.ac.id, ³amirulasnancirua@unsulbar.ac.id
Email Penulis Korespondensi: rusmini140702@gmail.com

Submitted 27-02-2026; Accepted 06-04-2026; Published 28-04-2026

Abstrak

Penelitian ini bertujuan membandingkan metode pelabelan Inset Lexicon dan MBERT untuk menganalisis sentimen terkait isu Danantara menggunakan Support Vector Machine (SVM) dengan kernel Linear, RBF, Polynomial, dan Sigmoid. Masalah utama dalam penelitian ini belum optimalnya metode pelabelan sentimen pada data berbahasa Indonesia yang mampu menangkap konteks linguistik secara akurat, serta ketidakjelasan metode pelabelan terbaik ketika dikombinasikan dengan variasi kernel SVM berbasis TF-IDF. Evaluasi model menggunakan metrik seperti Accuracy, Precision, Recall, F1-score, serta Cross-validation (CV). Hasil menunjukkan metode pelabelan Inset Lexicon, kernel Linear memberikan Accuracy tertinggi 81% dengan nilai CV 78%, Precision 87%, Recall 92%. Kernel RBF mencapai Accuracy 78% dengan CV 76%, diikuti kernel Sigmoid mencapai akurasi 79% dengan CV 76%, dan kernel Polynomial dengan Accuracy 65% dengan nilai CV 65%. F1-score tertinggi pada kelas negatif menggunakan kernel Linear mencapai 89%. Sedangkan pada pelabelan MBERT, Accuracy tertinggi diperoleh kernel RBF yaitu 72% dengan CV 71%, dilanjut kernel Linear dengan Accuracy 71%, kemudian kernel Polynomial dengan Accuracy 68%, serta Sigmoid dengan Accuracy 67%. F1-score tertinggi terdapat pada kelas negatif dengan nilai 79% menggunakan kernel RBF. Secara keseluruhan, kelas negatif menunjukkan performa paling konsisten, sedangkan kelas netral memiliki nilai Recall dan F1-score yang terendah pada hampir semua jenis kernel. Temuan ini menegaskan bahwa analisis komparatif yang mendalam antara pendekatan leksikon dan berbasis deep learning, serta menunjukkan bahwa metode seperti Inset Lexicon dapat memberikan performa lebih baik dan stabil dalam data berbahasa Indonesia.

Kata Kunci: Inset Lexicon; MBERT; Support Vector Machine; Analisis Sentimen; Danantara

Abstract

This study aims to compare the Inset Lexicon and MBERT sentiment labeling methods for analyzing sentiment related to the Danantara issue using a Support Vector Machine (SVM) with Linear, RBF, Polynomial, and Sigmoid kernels. The main issues in this study are the suboptimal sentiment labeling methods for Indonesian-language data that can accurately capture linguistic context, as well as the uncertainty regarding the best labeling method when combined with various TF-IDF-based SVM kernels. Model evaluation uses metrics such as Accuracy, Precision, Recall, F1-score, and Cross-validation (CV). The results show that the Inset Lexicon labeling method with a Linear kernel yields the highest Accuracy of 81% with a CV of 78%, Precision of 87%, and Recall of 92%. The RBF kernel achieved an Accuracy of 78% with a CV of 76%, followed by the Sigmoid kernel at 79% Accuracy with a CV of 76%, and the Polynomial kernel at 65% Accuracy with a CV of 65%. The highest F1-score for the negative class using the Linear kernel reached 89%. Meanwhile, in MBERT labeling, the highest accuracy was achieved by the RBF kernel at 72% with a CV of 71%, followed by the Linear kernel with an accuracy of 71%, then the Polynomial kernel with an accuracy of 68%, and the Sigmoid kernel with an accuracy of 67%. The highest F1-score was found in the negative class at 79% using the RBF kernel. Overall, the negative class showed the most consistent performance, while the neutral class had the lowest Recall and F1-score values for almost all kernel types. These findings confirm that an in-depth comparative analysis between lexicon-based and deep learning-based approaches demonstrates that methods such as the Inset Lexicon can deliver better and more stable performance on Indonesian-language data.

Keywords: Inset Lexicon; MBERT; Support Vector Machine; Sentiment Analysis; Danantara

1. PENDAHULUAN

Badan Pengelola Investasi Daya Anagata Nusantara merupakan lembaga memiliki peran penting dalam mengelola aset keuangan negara. Fungsi utamanya adalah mengoptimalkan investasi pemerintah serta mendorong pertumbuhan ekonomi nasional. Dalam uraiannya disebutkan, diperlukan pembagian tanggung jawab yang tegas, khususnya dalam menghadapi berbagai risiko kerugian yang mungkin terjadi dalam investasi dana negara. Keterbukaan akan jadi fondasi penting untuk manajemen keuangan negara dapat bergerak optimal sekaligus memperkuat kepercayaan masyarakat. Untuk itu, BPI Danantara diharapkan mampu mengimplementasikan standar transparansi yang tinggi dalam setiap lini operasionalnya, sehingga investasi negara dapat dikelola secara profesional, bertanggung jawab, serta memberikan dampak nyata bagi kemajuan perekonomian Indonesia [1].

Klasifikasi sentimen atau yang sering disebut analisis teks merupakan pendekatan yang digunakan untuk mengidentifikasi, mengekstraksi, serta mengolah data tekstual secara otomatis guna mengetahui sudut pandang atau perasaan yang diungkapkan seseorang terhadap topik atau objek tertentu, baik itu bersifat positif maupun negatif [2]. Sebelum dianalisis, data tekstual tersebut perlu melalui tahap pra-pengolahan yang meliputi pembersihan data, seperti menghilangkan atribut yang tidak penting serta penerapan teknik menghapus untuk memperoleh bentuk awal dari setiap kata. Setelah itu, data yang sudah bersih akan diolah menggunakan metode algoritma tertentu sehingga sentimen yang terkandung dalam keseluruhan teks dapat diidentifikasi dengan akurat. Hasil dari analisis ini dapat dimanfaatkan di berbagai sektor, seperti penelitian pasar, penilaian produk, pengembangan aplikasi, dan peningkatan citra merek [3].

Berbagai metode pelabelan dalam machine learning yang biasa digunakan untuk analisis sentimen yaitu *Lexicon-based*, *Inset Lexicon*, *Lexicon based features*, *IndoBert*, *Model mBERT*, *VADER*, dan *Rating-based*. Teknik *Lexicon-*

based memiliki tingkat akurasi yang lebih baik dalam pelabelan manual [4]. Dalam dataset yang menggunakan bahasa Indonesia, metode *Inset Lexicon* sudah valid menghasilkan akurasi yang unggul dalam klasifikasi emosi [5]. Kelebihan *Lexicon based features* ada pada kemampuannya dalam memberikan penilaian dan mengambil fitur emosi secara semantik dengan menggunakan metode berbasis kamus [6]. *IndoBERT* lebih efisien dalam mengelola teks yang ditulis dalam bahasa Indonesia [7]. Model MBERT yang dapat memahami banyak bahasa dan memberikan solusi dengan kemampuan untuk belajar dari satu bahasa dan menerapkannya pada bahasa lain [8]. Fitur deteksi polaritas *VADER* memiliki kelebihan karena telah dilengkapi dengan kamus yang memberikan nilai untuk setiap kata [9]. Berbeda dengan pendekatan di atas, teknik *Rating-based* hanya menetapkan kelas emosi menurut nilai tingkat yang sudah tersedia pada dataset [5].

Beberapa penelitian terdahulu seperti Studi oleh [4] membandingkan *VADER* dan *Lexicon-based* dengan algoritma SVM dan Naïve bayes, Secara keseluruhan teknik *Lexicon based* pada model SVM memberikan hasil yang paling baik dalam memprediksi data berbahasa Indonesia dan bahasa Inggris. Di sisi lain, penelitian ini [5] melakukan pembedaan antara dua teknik pelabelan, yaitu *Rating-based* dan *Inset Lexicon*, yang kemudian diuji memanfaatkan algoritma SVM. Dari pengujian diraih bahwasanya pelabelan *Rating-based* menghasilkan akurasi sebesar 87% dengan presisi 86,7%, recall 87,1%, dan f1-score 86,8%. Sebaliknya, pelabelan *Inset Lexicon* menunjukkan performa yang lebih tinggi dengan akurasi 89,7%, presisi 89%, recall 89,8%, dan f1-score 89,3%. Pada penelitian lain oleh [10] dilakukan perbandingan antara pelabelan manual, *IndoBERT*, *IndoBERTweet*, *RoBERTa*, dan *InSet Lexicon*. Hasil yang didapat menunjukkan bahwa metode pelabelan otomatis menggunakan *IndoBERTweet* memperoleh nilai F1-Score tertinggi yaitu 0,9802, namun terdapat dominasi pada kelas netral yang mengindikasikan adanya *overfitting*. Di sisi lain, pelabelan manual berhasil menciptakan distribusi kelas yang lebih merata walaupun nilai F1-Score yang lebih rendah, yakni 0,8684. Sementara itu, *RoBERTa* menampilkan keseimbangan optimal antara kinerja model dan sebaran penanda. Untuk *InSet Lexicon* dan *IndoBERT*, keduanya cenderung menampilkan kecenderungan pada jenis khusus. Menurut studi [11] *IndoBERT* terbukti lebih baik dibandingkan MBERT untuk mengidentifikasi berita hoax, kinerja yang optimal diseluruh parameter penilaian.

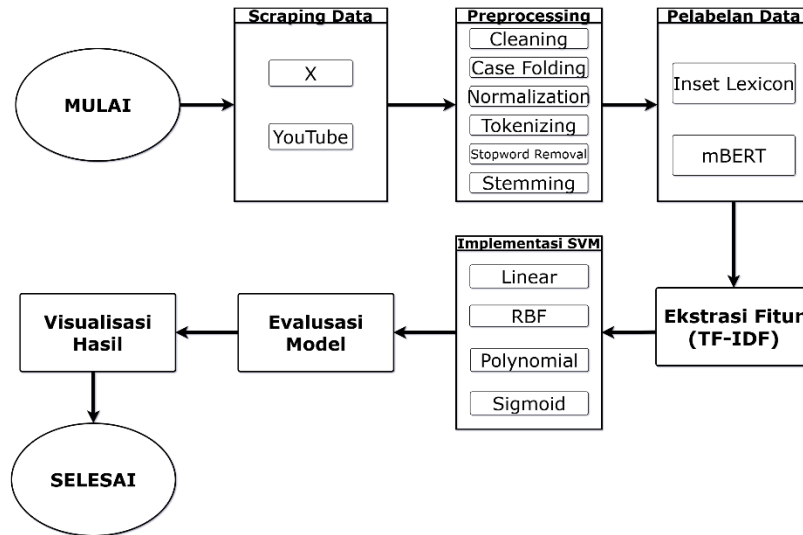
Meskipun berbagai penelitian terdahulu menunjukkan bahwa terdapat beberapa kekurangan dalam studi ini yang perlu diatasi. Kebanyakan penelitian yang membandingkan beberapa contoh pelabelan dengan model klasik biasanya hanya menitik beratkan pada satu tipe dataset atau satu bahasa, yang menyebabkan kemampuan kinerjanya dalam berbagai situasi yang masih terbatas. Disisi lain, masih sedikit studi yang membandingkan secara sistematis yang melibatkan aneka jenis kernel seperti Linear, RBF, Polynomial, dan Sigmoid. Penilaian kinerja di bawah kondisi data yang tidak seimbang, yang sering dijumpai dalam review di kehidupan sesungguhnya terutama untuk data berbahasa Indonesia, dan sering kali belum banyak mendapat perhatian, sehingga pemilihan metrik evaluasi yang luas dan menggambarkan kinerja sesungguhnya pada data yang tercantum menjadi sangat penting, mengingat terdapat hal perbedaan dalam akurasi [12].

Menurut latar belakang di atas, studi ini bertujuan untuk melakukan perbandingan antara Pelabelan *Inset lexicon* dan *Model Multilingual BERT* (MBERT), dengan memanfaatkan Algoritma Support Vector Machine yang dilengkapi Kernel Trick yaitu Linear, RBF, Polynomial, dan Sigmoid [13]. Analisis difokuskan pada sentimen terkait Danantara yang dibahas di media sosial X dan Youtube. Tujuannya adalah mengidentifikasi pendekatan yang memberikan kinerja klasifikasi paling optimal. Adanya analisis ini diharapkan dapat memperdalam pemahaman mengenai efektivitas algoritma dan efisiensi metode pelabelan otomatis dalam konteks analisis sentimen, serta bagaimana karakteristik bahasa mempengaruhi hasil analisis tersebut.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini melalui serangkaian langkah metodologis: Pertama dimulai dengan pengumpulan data tweet atau komentar tentang Danantara yang diperoleh melalui teknik *Scraping Data* (X dan YouTube). Kemudian, langkah *Preprocessing* terdiri dari *Cleaning*, *Case Folding*, *Normalization*, *Tokenizing*, *Stopword Removal*, dan *Stemming* [14]. Ini dilakukan untuk memastikan kualitas teks yang akan dipakai. Selanjutnya dilakukan Pelabelan data menggunakan *Inset Lexicon* dan mBERT. Selanjutnya, Ekstraksi fitur dengan metode *Term Frekuensi-Inverse Document Frekuensi* (TF-IDF) yang mengubah teks menjadi bentuk angka. Setelah itu, tahap implementasi algoritma klasifikasi *Support Vector Machine* dengan mengeksplorasi melalui ke empat kernel Trick, yaitu Linear, RBF, Polynomial, dan Sigmoid [15]. Pada akhir proses, dilakukan Evaluasi model setiap pelabelan dengan algoritma yang digunakan, dievaluasi memanfaatkan *confusion matrix* terdiri dari *Accuracy*, *Precision*, *Recall*, dan *F1-Score* serta *Cross-validation* untuk mendapatkan gambaran lengkap tentang kinerja yang lebih baik. Visualisasi hasil menggunakan *Wordcloud*. Secara keseluruhan, langkah-langkah utama dalam studi ini bisa dilihat pada Gambar 1 yang menunjukkan alur proses penelitian dari awal sampai akhir.



Gambar 1. Alur Penelitian

2.1.1 Scraping Data

Scraping data menggunakan teknik *web scraping* yaitu cara yang diterapkan untuk memperoleh atau mengekstraksi informasi dari berbagai sumber data. Informasi yang didapatkan bisa berupa teks, gambar, atau video, dan biasanya diubah ke dalam format yang sesuai dengan kebutuhan yang ditentukan [16]. Dengan menggunakan *Search API* di platform Twitter dan Youtube Data yang dikumpulkan berupa sekumpulan tweet yang mengandung kata kunci “Danantara” Pengumpulan data dilakukan dengan bantuan tools *Google Collabs*, sehingga memudahkan pengambilan data secara otomatis dari X dan YouTube [17]. Data penelitian dikumpulkan dengan teknik *scraping* di X pada bulan Maret 2025 dengan 1438 tweet, sedangkan *scraping* melalui YouTube pada bulan oktober 2025 dengan 4680 komentar menggunakan *library* di *Python*. Komentar berjumlah 6.118 Rentang waktu ulasan dari 9 Maret 2025 hingga 17 Oktober 2025.

2.1.2 Preprocessing

Tahapan *Preprocessing* data merupakan komponen krusial pada analisis sentimen yang berfokus pada pemurnian dan penataan awal data tekstual mentah. Data ulasan diambil langsung biasanya tidak terstruktur secara rapi. Di dalamnya bisa terdapat kesalahan pengetikan, penggunaan tanda baca yang tidak tepat, serta beberapa kata yang sebenarnya tidak memiliki makna signifikan. Tahap *preprocessing* ini secara dasar merupakan proses membersihkan dan menyusun kembali data tersebut sebelum dilakukan pengolahan lebih lanjut. Tujuannya adalah menyiapkan data yang bersih agar model dapat belajar secara efektif dan menghasilkan analisis yang lebih akurat [18]. Penelitian ini mengimplementasikan beberapa tahapan *Preprocessing* data, meliputi *Cleaning*, *Case Folding*, *Normalization*, *Tokenizing*, *Stopword Removal*, dan *Stemming*. Untuk memaksimalkan hasil dari penelitian sebelumnya, beberapa tahap *preprocessing* yang diadopsi dalam studi ini mencakup:

a. Cleaning

Cleaning merupakan tahapan prapemrosesan yang bertujuan untuk menghapus elemen-elemen tertentu yang terdapat pada data Twitter, seperti *Uniform Resource Locator* (URL), nama pengguna (*username*), penanda retweet (RT), karakter berbasis HTML, serta tagar (*hashtag*). Tahap ini dilakukan untuk menghapus komponen yang tidak relevan terhadap analisis isi teks maka mencapai repositori data yang lebih terorganisir dan siap untuk dilanjutkan tahap pengolahan berikutnya [19].

b. Case Folding

Proses *Case Folding* merupakan prosedur standardisasi tekstual dengan cara mengonversi semua karakter menjadi huruf kecil (*lowercase*). Tahap ini tujuannya untuk menghilangkan variasi representasi kata yang muncul hasil variasi penggunaan huruf besar dan huruf kecil dalam dokumen teks, sehingga konsistensi data dapat dipertahankan [20].

c. Normalization

Setiap tweet atau komentar yang dikirim oleh pengguna dapat dipastikan mengandung kata-kata yang menggunakan bahasa informal, disingkat, atau bahkan diperpanjang. Tahap ini dilakukan untuk memodifikasi korpus ke dalam struktur standar secara ketentuan yang berlaku. Dengan demikian, proses analisis selanjutnya dapat dilakukan secara lebih akurat dan sistematis agar dapat diproses lebih lanjut secara akurat [21].

d. Tokenizing

Tokenizing adalah proses memisahkan teks atau string menjadi beberapa bagian yang memiliki makna, yang disebut token. Token dapat dipandang sebagai bagian dari suatu keseluruhan, proses ini merupakan bagian penting dalam pemrosesan bahasa alami serta analisis teks [22].

e. Stopword Removal

Stopword Removal adalah menghilangkan kata-kata umum yang tidak memiliki kontribusi penting dalam konteks analisis, dengan menghilangkan kata-kata tersebut analisis dapat difokuskan pada istilah-istilah yang memiliki bobot informasi lebih tinggi, sehingga meningkatkan kekuatan informasi dalam data yang dianalisis [23].

f. Stemming

Proses berikutnya adalah *stemming*, yaitu proses mengubah kata-kata menjadi bentuk dasarnya dengan menghilangkan imbuhan atau akhiran yang tidak penting. Tujuan dari proses ini adalah menyederhanakan kata-kata sehingga berbagai variasi bentuk dari kata yang sama dapat dikelompokkan secara bersamaan, serta memudahkan analisis terhadap teks [24].

2.1.3 Pelabelan Data

Setelah melakukan *preprocessing* data, maka selanjutnya dilakukan pelabelan data untuk mengelompokkan data menjadi tiga jenis, yaitu opini positif, negatif, dan netral. Pelabelan data dijalankan secara otomatis menggunakan kamus *Inset Lexicon* dan *Bidirectional Encoder Representations from Transformers* atau biasa disebut BERT dengan model *nlpTown/bert-base-multilingual-uncased-sentimen* [25].

2.1.4 Ekstraksi Fitur TF-IDF

Tahap selanjutnya adalah pembobotan kata menggunakan metode *Term Frequency–Inverse Document Frequency* (TF-IDF). Proses ini ditujukan untuk mendistribusi bobot numerik yang mencerminkan frekuensi kemunculannya dalam sebuah dokumen serta signifikansinya dalam distribusi pada keseluruhan korpus teks. Bobot yang dihasilkan kemudian dimanfaatkan sebagai fitur masukan dalam tahapan klasifikasi [17].

2.1.5 Implementasi SVM

Dalam tahap klasifikasi, studi ini memanfaatkan metode *Support Vector Machine* (SVM), yaitu satu di antara algoritma *supervised learning* yang banyak diterapkan untuk analisis teks karena memiliki tingkat ketepatan yang relatif tinggi. SVM bekerja dengan membangun model dari data pelatihan (*Training Data*) untuk mengidentifikasi *hyperplane* optimal mampu memilah jenis-jenis emosi secara maksimal. Pola yang terbentuk selanjutnya dimanfaatkan dalam memprediksi kategori pada data uji (*Testing Data*) yang sebelumnya belum pernah diproses [26]. Selain itu, SVM juga mampu menyelesaikan masalah klasifikasi dan regresi baik yang bersifat linear maupun nonlinear [27].

2.1.6 Evaluasi Model

Proses evaluasi dilakukan untuk memahami sejauh mana kinerja dan akurasi model yang telah dilatih. Mengelompokkan sentimen ke dalam kategori yang sudah ditentukan berdasarkan hasil yang diperoleh dari proses pelatihan model. Dalam proses evaluasi model, *Confusion matrix* digunakan untuk memahami kinerja model klasifikasi. Melalui matriks ini, berbagai metrik penilaian kinerja seperti *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. *Accuracy* menampilkan tingkat keseringan pola menghasilkan prediksi yang benar, yaitu tingkat kebenaran prediksi yang dikeluarkannya. *Precision* menunjukkan tingkat akurasi dalam memprediksi kelas positif, sementara *Recall* mengukur kemampuannya untuk mengidentifikasi seluruh masalah positif yang sesungguhnya, dan *F1-score* adalah nilai tengah harmonik mulai *precision* dan *recall*, menunjukkan pandangan seimbang pada kinerja pola [28].

2.1.7 Visualisasi Hasil

Word Cloud merupakan representasi visual dari kumpulan kata, di mana ukuran kata-kata tersebut mencerminkan seberapa sering mereka muncul dalam suatu teks atau dataset. Dalam proses pembuatan *Word Cloud*, kata-kata yang lebih sering muncul akan ditampilkan dengan ukuran yang lebih besar, menciptakan tampilan visual yang memberikan gambaran umum tentang kata-kata yang paling umum atau dominan dalam konteks tertentu. Proses pembuatan *Word Cloud* biasanya melibatkan beberapa langkah, antara lain: tokenisasi, perhitungan frekuensi, pemilihan kata, penyesuaian bobot, dan pembentukan *Word Cloud* itu sendiri [29].

3. HASIL DAN PEMBAHASAN

3.1 Scraping Data

Komentar berjumlah 6.118 seluruh data tersebut selanjutnya disimpan dalam bentuk file CSV untuk dilanjutkan ke tahap pemrosesan berikutnya bisa dilihat pada Tabel 1.

Tabel 1. Dataset

No	At	Username	Text
1	09/03/2025 14:15	Muhamma89363435	@Indos_transfer Tapi plotwist nya kartu merah tersebut Dibanding jadi kartu kuning. Apapun masih bisa terjadi.
2	09/03/2025 14:15	matajambi93	Prabowo Bergerak Cepat! Danantara Siap Kelola Aset Negara Ini Dampaknya untuk Ekonomi RI https://t.co/r2ySkJv5Ky

3	09/03/2025 14:13	Ika_Iskandar64	@detikcom Sama potensi korupsi besar di Danantara.
...
6116	17/05/2025 11:18	bedadung	I love this guy Pandu Sjahrir.
6117	17/05/2025 11:00	reno9005	So surprised WIUI Podcast is Mentioned here! Shout out to Andovi Da Lopez and Abigail Limuria for making it ðŸŽ‰
6118	17/05/2025 05:01	faiq026	insane project

Pada Tabel 1, tercantum hasil pengumpulan data menampilkan kolom At yang mencantumkan tanggal dan waktu, kolom Username adalah pengguna yang mengirim Komentar, serta kolom Text yang berisi komentar dari pengguna X dan YouTube.

3.2 Preprocessing

Tahap ini bertujuan untuk membersihkan dataset dari gangguan untuk memudahkan proses *machine learning* dan juga memastikan mutu serta ketepatan data. Berikut ini adalah tahapan yang umumnya dilakukan dalam *preprocessing*:

3.2.1 Cleaning

Tahap awal adalah proses *cleaning* data, dilakukan Sebanyak 6.118 komentar telah dibersihkan dari berbagai jenis karakter yang dapat mengganggu akurasi dalam pengelompokan, karena di dalam data ulasan sering kali terdapat karakter seperti angka, emoji, dan simbol yang menghalangi proses pengelompokan. Pada penelitian ini, hanya kolom text yang digunakan karena kolom tersebut menyimpan sentimen publik yang akan di analisis dalam proses analisis sentimen. Berikut adalah Tabel 2 yang menampilkan hasil dari langkah *cleaning*.

Tabel 2. Hasil Cleaning

Sebelum	Sesudah
@Indos_transfer Tapi plotwist nya kartu merah tersebut Dibanding jadi kartu kuning. Apapun masih bisa terjadi. Prabowo Bergerak Cepat! Danantara Siap Kelola Aset Negara Ini Dampaknya untuk Ekonomi RI https://t.co/r2ySkJv5Ky	Tapi plotwist nya kartu merah tersebut Dibanding jadi kartu kuning Apapun masih bisa terjadi Prabowo Bergerak Cepat Danantara Siap Kelola Aset Negara Ini Dampaknya untuk Ekonomi RI
@detikcom Sama potensi korupsi besar di Danantara.	Sama potensi korupsi besar di Danantara
...	...
I love this guy Pandu Sjahrir.	I love this guy Pandu Sjahrir
So surprised WIUI Podcast is Mentioned here! Shout out to Andovi Da Lopez and Abigail Limuria for making it ðŸŽ‰	So surprised WIUI Podcast is Mentioned here Shout out to Andovi Da Lopez and Abigail Limuria for making it
insane project	insane project

Pada Tabel 2, terdapat hasil dari proses *cleaning* yang mencakup kolom sebelum dan sesudah, yang berisi komentar dari pengguna. Kolom sesudah, yang menunjukkan hasil komentar setelah diproses dan dibersihkan dari angka, emoji, simbol, URL serta karakter khusus, dan spasi ganda.

3.2.2 Case Folding

Langkah berikutnya *Case folding*, yaitu semua teks terdapat huruf besar (*uppercase*) diubah menjadi huruf kecil (*lower case*).

Tabel 3. Hasil Case Folding

Sebelum	Sesudah
Tapi plotwist nya kartu merah tersebut Dibanding jadi kartu kuning Apapun masih bisa terjadi. Prabowo Bergerak Cepat Danantara Siap Kelola Aset Negara Ini Dampaknya untuk Ekonomi RI Sama potensi korupsi besar di Danantara	tapi plotwist nya kartu merah tersebut dibanding jadi kartu kuning apapun masih bisa terjadi prabowo bergerak cepat danantara siap kelola aset negara ini dampaknya untuk ekonomi ri sama potensi korupsi besar di danantara
...	...
I love this guy Pandu Sjahrir	i love this guy pandu sjahrir
So surprised WIUI Podcast is Mentioned here Shout out to Andovi Da Lopez and Abigail Limuria for making it	so surprised wiui podcast is mentioned here shout out to andovi da lopez and abigail limuria for making it
insane project	insane project

Pada Tabel 3, hasil dari teks yang sudah diubah menjadi huruf kecil menunjukkan perubahan agar penggunaan huruf besar disamakan, sehingga kata atau teks dalam sistem menjadi lebih konsisten.

3.2.3 Normalization

Tahap ini bertujuan untuk mengganti korpus yang tidak sesuai atau tidak standar menjadi teks yang mengikuti kaidah ejaan yang benar. Proses ini berkontribusi untuk hasil akhir dari data tersebut. Tabel 4 menggambarkan hasil dari langkah *normalization*.

Tabel 4. Hasil Normalization

Sebelum	Sesudah
tapi plotwist nya kartu merah tersebut dibanding jadi kartu kuning apapun masih bisa terjadi prabowo bergerak cepat danantara siap kelola aset negara ini dampaknya untuk ekonomi ri sama potensi korupsi besar di danantara	tapi alur cerita nya kartu merah tersebut dibanding jadi kartu kuning apapun masih bisa terjadi prabowo bergerak cepat danantara siap kelola aset negara ini dampaknya untuk ekonomi ri sama potensi korupsi besar di danantara
...	...
i love this guy pandu sjahrir so surprised wiui podcast is mentioned here shout out to andovi da lopez and abigail limuria for making it insane project	saya suka banget sama bapak pandu sjahrir sangat terkejut podcast wiui disebutkan di sini teriakkan kepada andovi da lopez dan abigail limuria karena telah membuatnya projek gila

Pada tabel 4, hasil dari tahap normalisasi menampilkan perubahan pada hasil *normalization* yang memanfaatkan hasil dari proses *case folding* sebelumnya. Tahap ini menstandarisasi dan menerjemahkan kata atau teks ke dalam bahasa indonesia agar konsisten. Misalnya, pada komentar pertama, kata "plotwist" diterjemahkan menjadi "alur cerita", dan kata "i love this guy" ditranslate dan dinormalisasi menjadi kata (saya suka banget sama bapak). Begitu pula dengan kalimat lain juga diubah dengan cara yang sama dalam komentar-komentar lainnya.

3.2.4 Tokenizing

Proses yang digunakan mengonversi deretan kalimat menjadi unit-unit atau token individual sebagai representasi teks [24][24]. *Tokenizing* mempermudah analisis narasi dan identifikasi susunan yang tidak biasa. Tabel 5 menampilkan hasil langkah *tokenizing*.

Tabel 5. Hasil Tokenizing

Sebelum	Sesudah
tapi alur cerita nya kartu merah tersebut dibanding jadi kartu kuning apapun masih bisa terjadi	['tapi', 'alur', 'cerita', 'nya', 'kartu', 'merah', 'tersebut', 'dibanding', 'jadi', 'kartu', 'kuning', 'apapun', 'masih', 'bisa', 'terjadi']
prabowo bergerak cepat danantara siap kelola aset negara ini dampaknya untuk ekonomi ri sama potensi korupsi besar di danantara	['prabowo', 'bergerak', 'cepat', 'danantara', 'siap', 'kelola', 'aset', 'negara', 'ini', 'dampaknya', 'untuk', 'ekonomi', 'ri'] ['sama', 'potensi', 'korupsi', 'besar', 'di', 'danantara']
...	...
saya suka banget sama bapak pandu sjahrir sangat terkejut podcast wiui disebutkan di sini teriakkan kepada andovi da lopez dan abigail limuria karena telah membuatnya projek gila	['saya', 'suka', 'banget', 'sama', 'bapak', 'pandu', 'sjahrir'] ['sangat', 'terkejut', 'podcast', 'wiui', 'disebutkan', 'di', 'sini', 'teriakkan', 'kepada', 'andovi', 'sudah', 'lopez', 'dan', 'abigail', 'limuria', 'karena', 'telah', 'membuatnya'] ['projek', 'gila']

Pada tabel 5, menampilkan hasil dari proses *tokenizing* yang diperoleh berdasarkan hasil koreksi kata terdahulu. Dalam proses *tokenizing*, spasi digunakan sebagai pemisah antar token.

3.2.5 Stopword Removal

Proses untuk menghilangkan kata-kata yang sering muncul tetapi tidak mengandung banyak informasi [23].[23] *Stopword* biasanya terdiri dari kata penghubung dan kata depan. Tabel 6 menunjukkan hasil tahap *stopword removal*.

Tabel 6. Hasil Stopword Removal

Sebelum	Sesudah
['tapi', 'alur', 'cerita', 'nya', 'kartu', 'merah', 'tersebut', 'dibanding', 'jadi', 'kartu', 'kuning', 'apapun', 'masih', 'bisa', 'terjadi']	['alur', 'cerita', 'kartu', 'merah', 'dibanding', 'kartu', 'kuning', 'apapun']

['prabowo', 'bergerak', 'cepat', 'danantara', 'siap', 'kelola', 'aset', 'negara', 'ini', 'dampaknya', 'untuk', 'ekonomi', 'ri']	['prabowo', 'bergerak', 'cepat', 'danantara', 'kelola', 'aset', 'negara', 'dampaknya', 'ekonomi', 'ri']
['sama', 'potensi', 'korupsi', 'besar', 'di', 'danantara']	['potensi', 'korupsi', 'danantara']
['saya', 'suka', 'banget', 'sama', 'bapak', 'pandu', 'sjahrir']	['suka', 'banget', 'pandu', 'sjahrir']
['sangat', 'terkejut', 'podcast', 'wiui', 'disebutkan', 'di', 'sini', 'teriakkan', 'kepada', 'andovi', 'sudah', 'lopez', 'dan', 'abigail', 'limuria', 'karena', 'telah', 'membuatnya']	['terkejut', 'podcast', 'wiui', 'teriakkan', 'andovi', 'lopez', 'abigail', 'limuria', 'membuatnya']
['projek', 'gila']	['projek', 'gila']

Pada tabel 6, proses ini menghapus kata yang dianggap tidak memberikan pengaruh atau makna yang berarti. Seperti kata “tapi”, “nya”, “tersebut”, “jadi”, “masih”, “bisa”, “terjadi” dan begitu juga dengan kalimat yang mengalami perubahan serupa pada komentar lainnya.

3.2.6 Stemming

Langkah-langkah merubah korpus menjadi *format basic*. Mendukung agar memahami sebuah kata dapat mengekspresikan definisi dan pandangan yang serupa walaupun tampak dalam variasi format yang berlainan. Tabel 7 menampilkan hasil langkah *stemming*.


Tabel 7. Hasil Stemming

Sebelum	Sesudah
['alur', 'cerita', 'kartu', 'merah', 'dibanding', 'kartu', 'kuning', 'apapun']	alur cerita kartu merah banding kartu kuning apa
['prabowo', 'bergerak', 'cepat', 'danantara', 'kelola', 'aset', 'negara', 'dampaknya', 'ekonomi', 'ri']	prabowo gerak cepat danantara kelola aset negara dampak ekonomi ri
['potensi', 'korupsi', 'danantara']	potensi korupsi danantara
['suka', 'banget', 'pandu', 'sjahrir']	suka banget pandu sjahrir
['terkejut', 'podcast', 'wiui', 'teriakkan', 'andovi', 'lopez', 'abigail', 'limuria', 'membuatnya']	kejut podcast wiui teriak andovi lopez abigail limuria buat
['projek', 'gila']	projek gila


Pada tabel 7, hasil dari *stopword removal* sebelumnya kemudian melalui proses *stemming* yang menampilkan perubahan korpus ke *format basic*. Semisal, komentar pertama, kata (dibanding) diganti jadi(banding) demikian pula pada korpus yang menjalani transformasi sejenis dalam komentar lainnya.

3.3 Pelabelan

Pelabelan data dalam penelitian ini merupakan langkah yang sangat krusial sebab masalah ini menentukan jenis sentimen yang dimiliki oleh setiap data ulasan yang akan digunakan sebagai bahan latihan data. Dari total 6.118 Komentar yang dikumpulkan, setelah *preprocessing* dihasilkan data 6.046, kemudian langkah selanjutnya membandingkan hasil pelabelan menggunakan model otomatis kamus *Inset Lexicon* dan BERT dengan model *nlptown/bert-base multilingual-uncased-sentiment*, yang menghasilkan label pada skala bintang (1–5). Dalam penelitian ini, ulasan dengan label '1 star' dan '2 stars' diklasifikasikan menjadi emosi negatif, label '3' menjadi emosi netral, sedangkan '4 stars' dan '5 stars' dikategorikan sebagai sentimen positif. Gambar 2 dan 3 menunjukkan pembagian total data pada masing-masing jenis opini setelah proses pelabelan selesai dilakukan.



Gambar 2. Labeling dengan Inset Lexicon



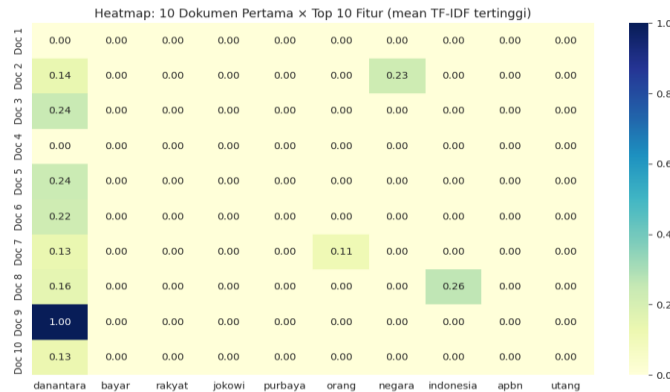
Gambar 3. Labeling dengan mBERT

Berdasarkan Gambar 2 dan 3, terdapat perbedaan distribusi kelas sentimen yang cukup signifikan antara penggunaan Inset Lexicon dan MBERT sebagai metode pelabelan. Pelabelan menggunakan inset lexicon menghasilkan distribusi sentiment yang lebih seimbang, yaitu 45,12% sentiment negatif, 29,54% netral, dan 25,34% positif. Sebaliknya, hasil pelabelan MBERT menunjukkan bahwa kelas negatif mendominasi dengan persentase sebesar 53,52%, sedangkan

kelas netral mengalami penurunan signifikan menjadi 16,54%, dan kelas positif berada pada 29,94%. Perbedaan ini menunjukkan bahwa Inset Lexicon lebih menjaga kategori netral, sementara MBERT lebih cenderung memberikan penilaian yang lebih tegas terhadap opini yang tidak jelas. Perbedaan distribusi kelas dalam proses pelabelan MBERT dapat berdampak pada hasil klasifikasi berikutnya.

3.4 Ekstraksi TF-IDF

Pada data asli, akan diterapkan proses pemberian bobot pada setiap istilah dan hasil akhir diperoleh dalam bentuk nilai *Term Frequency-Inverse Document Frequency* atau TF-IDF. Metode ini memungkinkan akan menilai frekuensi kemunculan sebuah kata pada sebuah dokumen. Hasil pemberian bobot ini untuk dimanfaatkan pada langkah pengklasifikasian.



Gambar 4. Hasil TF-IDF

Gambar 4, menunjukkan Heatmap 10 kata dengan Rata-rata Skor TF-IDF Tertinggi dari 10 Komentar di X dan YouTube. Masing-masing sel dalam tabel merepresentasikan nilai TF-IDF untuk kata tertentu dalam suatu dokumen. Semakin gelap warnanya, semakin tinggi bobot TF-IDF yang mengindikasikan sejauh pentingnya kata tersebut dalam dokumen yang dimaksud.

3.5 Implementasi SVM

Setelah melalui langkah-langkah *preprocessing*, pelabelan data, dan pembobotan TF-IDF, selanjutnya langkah penerapan support vector machine guna membangun model dengan mencari garis pemisah atau *hyperplane* yang akan memisahkan masing-masing kategori, baik itu positif, negatif, maupun netral. Untuk menemukan presentase akurasi pengujian tertinggi, data dibagi jadi data training dan data testing pada rasio 80% data training dan 20% data testing. Kemudian menghasilkan data training dan data testing disusun lalu diteruskan ke tahap klasifikasi.

3.5.1 Hasil Klasifikasi menggunakan Labeling Inset Lexicon

Berikut ini tabel hasil klasifikasi svm menggunakan labeling inset Lexicon dengan 4 Kernel yaitu, Linear, RBF, Polynomial, dan Sigmoid.

Tabel 8. Hasil klasifikasi menggunakan Labeling Inset Lexicon

Kernel	Acc	Precision			Recall			F1-Score			Cv mean
		Negatif	Positif	Netral	Negatif	Positif	Netral	Negatif	Positif	Netral	
Linear	0.81	0.87	0.80	0.72	0.92	0.81	0.65	0.89	0.81	0.68	0.78
RBF	0.78	0.85	0.85	0.65	0.84	0.72	0.75	0.85	0.78	0.69	0.76
Polynomial	0.65	0.59	0.90	0.71	0.96	0.38	0.40	0.73	0.54	0.50	0.65
Sigmoid	0.79	0.89	0.80	0.65	0.84	0.80	0.71	0.86	0.80	0.68	0.76

Berdasarkan Tabel 8, hasil klasifikasi sentimen berdasarkan kamus Inset Lexicon menunjukkan bahwa kernel Linear memiliki performa terbaik dibandingkan jenis kernel lainnya dengan tingkat akurasi sebesar 0,81 dan rata-rata validasi silang sebesar 0,78. Diikuti oleh kernel Sigmoid dengan akurasi 0,79 dan kernel RBF dengan akurasi 0,78, sedangkan kernel Polynomial memiliki performa terendah dengan akurasi sebesar 0,65. Secara per kelas, sentimen negatif terus-menerus menunjukkan performa terbaik, khususnya pada kernel Linear dengan presisi 0,87, recall 0,92, serta F1-score 0,89 menandakan kemampuan pola untuk mengetahui emosi negatif dengan akurat dan stabil. Sebaliknya, kelas netral menunjukkan performa terendah pada semua kernel, dengan skor recall antara 0,40 sampai 0,75 dan F1-score antara 0,50 sampai 0,69, yang membuktikan kalau pola mengalami kendala pada mengidentifikasi ekspresi netral yang cenderung kurang jelas. Kernel Polynomial menunjukkan ketidakseimbangan yang cukup besar dalam performa, yang ditandai dengan nilai recall negatif yang sangat tinggi yaitu 0,96, sementara recall positif dan netral relatif rendah, yang mengarah pada adanya bias dalam proses klasifikasi. Secara umum, hasil penelitian menunjukkan bahwa pendekatan

representasi fitur berbasis Inset Lexicon lebih efektif ketika dimodelkan menggunakan kernel Linear, yang mampu menghasilkan akurasi dan stabilitas yang lebih baik dibandingkan dengan kernel non-linear lainnya.

3.5.2 Hasil Klasifikasi menggunakan Labeling MBERT

Berikut ini tabel hasil klasifikasi svm menggunakan labeling MBERT dengan 4 Kernel yaitu, Linear, RBF, Polynomial, dan Sigmoid.

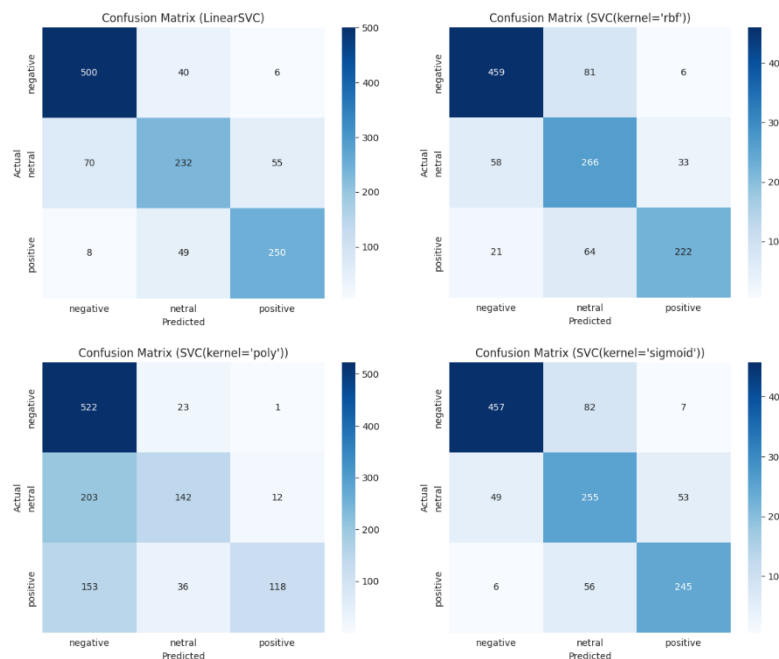
Tabel 9. Hasil klasifikasi menggunakan Labeling MBERT

Kernel	Acc	Precision			Recall			F1-Score			Cv mean
		Negatif	Positif	Netral	Negatif	Positif	Netral	Negatif	Positif	Netral	
Linear	0.71	0.78	0.73	0.46	0.80	0.70	0.46	0.79	0.72	0.46	0.71
RBF	0.72	0.75	0.76	0.52	0.83	0.67	0.43	0.79	0.71	0.47	0.71
Polynomial	0.68	0.64	0.89	0.66	0.97	0.43	0.19	0.77	0.58	0.29	0.67
Sigmoid	0.67	0.79	0.72	0.38	0.69	0.67	0.59	0.74	0.70	0.46	0.67

Berdasarkan Tabel 9, hasil klasifikasi sentimen menggunakan representasi MBERT menunjukkan bahwa performa model berada pada rentang accuracy 0,67 hingga 0,72, dengan kernel RBF menghasilkan nilai tertinggi 0,72 dan cross-validation 0,71, diikuti oleh kernel Linear dengan accuracy 0,71, sementara kernel Polynomial dan Sigmoid menunjukkan performa yang buruk 0,68 dan 0,67. Secara per kelas, sentimen negatif kembali menjadi kelas dengan performa paling konsisten, terutama pada kernel RBF dengan Recall 0,83 dan F1-Score 0,79 yang menampilkan kinerja pola pada identifikasi sentimen negatif secara relatif baik. Sebaliknya, kelas netral menunjukkan performa terendah pada hampir seluruh kernel, dengan recall yang cenderung rendah, bahkan pada kernel Polynomial memperoleh 0,19 dengan F1-Score 0,29 mengindikasikan kesulitan pola jika membedakan sentimen netral yang ambigu dan memiliki kedekatan distribusi dengan kelas lain. Kernel Polynomial juga menunjukkan ketidakseimbangan performa antar kelas, ditandai dengan recall negatif yang sangat tinggi (0,97) namun rendah pada kelas positif dan netral, sehingga mengindikasikan potensi bias klasifikasi. Secara keseluruhan, kombinasi MBERT dengan kernel RBF memberikan hasil paling optimal dalam konfigurasi ini, meskipun peningkatan performa yang dihasilkan relatif moderat dan belum menunjukkan keunggulan signifikan dibandingkan konfigurasi lainnya.

3.6 Evaluasi Model

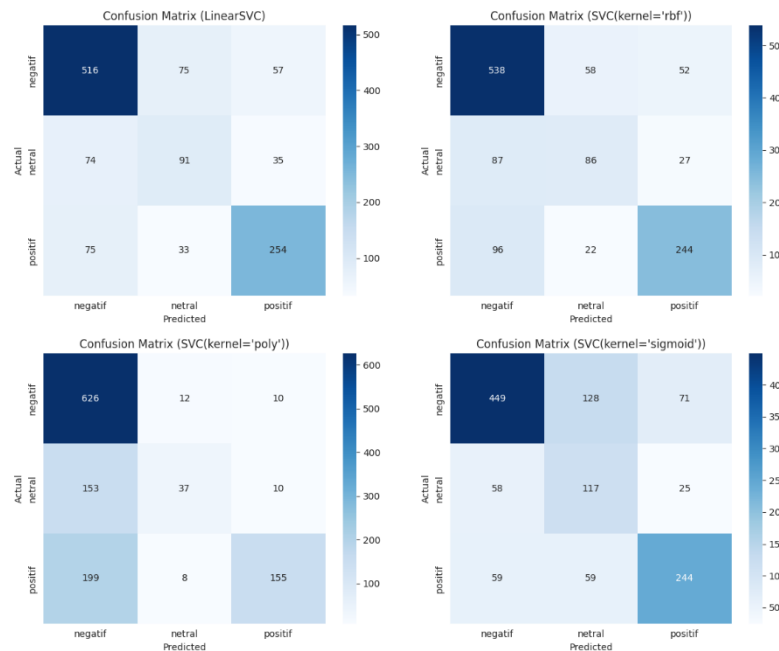
Hasil dari pengujian ini akan digambarkan melalui confusion matrix berguna untuk menghitung metrik evaluasi seperti Akurasi, Presisi, Recall, dan F-1 score untuk masing-masing jenis emosi. Fungsi confusion matrix adalah untuk mengidentifikasi seberapa akurat model klasifikasi dalam mengetahui setiap kelas dan tingkat kesalahan yang terjadi antara kelas. Matriks ini memaparkan tambahan detail mengenai bagaimana pola klasifikasi bekerja untuk memberikan label sentimen dengan tepat.



Gambar 5. Confusion Matrix dengan Labeling Inset Lexicon

Gambar 5, menunjukkan hasil dari analisis confusion matrix bahwa kernel Linear memiliki performa paling seimbang dalam mengklasifikasikan ketiga jenis sentimen, yang terlihat dari hasil prediksi benar yang mendominasi pada

diagonal confusion matrix dan nilai F1-score yang relatif stabil pada setiap kelas. Kernel RBF menunjukkan kecenderungan untuk memperluas area pengambilan keputusan untuk kelas netral sehingga menghasilkan recall tinggi pada kategori netral, tetapi precision berkurang karena banyak data negatif dan positif yang salah diidentifikasi sebagai netral. Di sisi lain, kernel Polynomial menunjukkan kinerja terendah karena mengalami overfitting, yang nampak dari dominasi prediksi negatif yang berlebihan sehingga menyebabkan banyak data yang seharusnya netral dan positif terklasifikasi secara salah. Kernel Sigmoid menunjukkan kinerja yang berada di antara keduanya dengan hasil yang lebih konsisten dibandingkan RBF dan Polynomial, namun masih belum mampu mengungguli akurasi serta keseimbangan yang ditawarkan oleh kernel Linear. Secara keseluruhan, analisis confusion matrix menegaskan bahwasanya kernel Linear adalah konfigurasi paling baik untuk klasifikasi sentimen berbasis Lexicon dengan metode TF-IDF, karena mampu menciptakan batas keputusan yang ideal pada data teks yang memiliki dimensi tinggi.



Gambar 6. Confusion Matrix dengan Labeling MBERT

Gambar 6, mengindikasikan hasil dari confusion matriks pada pelabelan MBERT bahwa kernel Linear dan RBF memberikan kinerja yang lebih konsisten bila dibandingkan dengan kernel Polynomial dan Sigmoid, khususnya dalam mengklasifikasikan emosi negatif dan positif. Meskipun demikian, semua jenis kernel masih menghadapi tantangan dalam membedakan kategori netral, yang terlihat dari total perkiraan yang tepat yang rendah dan tingkat kesalahan klasifikasi yang tinggi terhadap kelas negatif atau positif. Kernel Polynomial menunjukkan hasil terburuk dengan cenderung mengklasifikasikan mayoritas data ke dalam kelas negatif, yang menandakan adanya fenomena overfitting. Kernel Sigmoid memberikan hasil yang lebih seimbang dibandingkan dengan Polynomial, tetapi belum mampu melampaui hasil dari kernel Linear dan RBF. Hasil ini menunjukkan bahwa meskipun pelabelan MBERT bersifat kontekstual, kombinasi TF-IDF dan SVM masih memiliki kekurangan dalam memanfaatkan kompleksitas pelabelan MBERT dengan cara yang optimal, terutama pada kelas netral.

3.7 Pembahasan

Hasil studi ini menunjukkan bahwa teknik pelabelan sentimen berperan penting dalam menentukan tingkat performa algoritma SVM untuk analisis sentimen pada kebijakan Danantara. Pendekatan pelabelan berbasis Inset Lexicon terbukti menghasilkan capaian paling optimal, ditunjukkan oleh tingkat akurasi tertinggi sebesar 81% serta nilai rata-rata cross-validation sebesar 78% ketika menggunakan kernel Linear. Temuan tersebut menunjukkan bahwa fitur teks yang direpresentasikan melalui TF-IDF pada bahasa Indonesia cenderung memiliki karakteristik yang dapat dipisahkan secara linear, sehingga kernel Linear mampu membangun hyperplane pemisah yang lebih efektif.

Temuan ini sejajar dengan hasil studi yang dilaporkan oleh [4]. dan [5]. yang menyimpulkan bahwa pelabelan berbasis inset lexicon memberikan performa yang relatif stabil dan lebih akurat saat diintegrasikan dengan algoritma SVM pada korpus teks berbahasa Indonesia. Selain itu, keseimbangan skor precision, recall, dan F1-score di ketiga kategori sentimen mengindikasikan bahwa metode ini cukup andal dalam menghadapi distribusi data yang tidak sepenuhnya seimbang.

Di sisi lain, penerapan pelabelan menggunakan BERT menunjukkan hasil yang lebih rendah, dengan tingkat akurasi maksimum sebesar 72% pada kernel RBF serta rata-rata nilai cross-validation sebesar 71%. Walaupun MBERT dikenal unggul dalam menangkap makna kontekstual, hasil penelitian ini mengindikasikan bahwa keunggulan tersebut belum dapat dimanfaatkan secara maksimal ketika dipadukan dengan representasi fitur TF-IDF dan model SVM. Hal ini sejalan dengan temuan [12]. serta [10]. yang menyatakan bahwa pendekatan pelabelan berbasis MBERT cenderung

menangkap makna kritikan dengan pendekatan semantik daripada hanya merujuk pada teks secara harfiah. Word Cloud dengan sentimen netral dengan labeling MBERT menunjukkan konsistensi dalam kemunculan istilah penting seperti “danantara”, “apbn”, “purbaya”, dan “dukung”. Namun, berbeda dengan Lexicon, MBERT memiliki kemampuan untuk mengkategorikan banyak istilah opini yang halus sebagai netral, berkat konteks kalimat yang lebih kaya informasi dibandingkan dengan yang bersifat emosional.

4. KESIMPULAN

Berdasarkan temuan studi, pelabelan otomatis berbasis Inset Lexicon menunjukkan kinerja yang lebih baik dibandingkan MBERT, terutama ketika digunakan dengan fitur TF-IDF dan kernel Linear. Model SVM dengan Pelabelan Inset Lexicon dan kernel Linear berhasil mencapai akurasi tertinggi sebesar 81% dengan nilai cross-validation 78% serta keseimbangan metrik Precision, Recall, dan F1-score yang relatif baik pada seluruh kelas sentimen. Sebaliknya, pelabelan MBERT menghasilkan performa lebih rendah dengan akurasi maksimum 72%, yang menunjukkan bahwa kompleksitas makna dari labeling MBERT belum dapat dimanfaatkan secara optimal oleh SVM berbasis TF-IDF, khususnya pada kondisi data tidak seimbang dan kelas netral. Kernel Polynomial cenderung mengalami overfitting pada kedua metode pelabelan, sedangkan kernel Linear terbukti paling stabil untuk klasifikasi teks dimensi tinggi dan direkomendasikan sebagai pendekatan utama dalam studi serupa. Analisis Word Cloud turut menunjukkan bahwa opini publik terhadap kebijakan Danantara di media sosial X dan YouTube dipengaruhi oleh sentimen positif maupun kekhawatiran terkait anggaran, utang, dan transparansi. Untuk pengembangan selanjutnya, disarankan pemanfaatan representasi berbasis word embedding seperti Word2Vec, FastText, atau BERT-Embedding serta eksplorasi model deep learning seperti Bi-LSTM dan Transformer, disertai perluasan sumber dan rentang data agar diperoleh pemahaman yang lebih komprehensif mengenai dinamika opini publik terhadap kebijakan pemerintah di ruang digital.

REFERENCES

- [1] P. Ni, E. V. Daniel, M. H. Athallah, S. Rainhard, and L. Gaol, “PENGAWASAN DAN PERTANGGUNGJAWABAN BADAN PENGELOLA INVESTASI DANANTARA DALAM PENGELOLAAN RISIKO KERUGIAN INVESTASI KEUANGAN NEGARA,” *J. Huk. Statut.*, vol. 4 Nomor 2, pp. 129–143, 2025.
- [2] D. M. Kgs M Aria Hidayatullah, Dhamayanti, “Analisis Sentimen Pelanggan Pempek Cek Ida Terhadap Penilaian Produk Menggunakan Layanan GoFood Pada Aplikasi Gojek Dengan Klasifikasi Support Vector Machine (SVM),” *J. Ilm. Inform. Glob.*, vol. 16, no. 2, pp. 264–273, 2025.
- [3] A. Widodo, B. A. Herlambang, and R. Renaldy, “Optimizing Support Vector Machine (SVM) for Sentiment Analysis of Blu by BCA Reviews with Chi-Square,” *J. Appl. informatics Comput.*, vol. 9, no. 5, pp. 2588–2597, 2025.
- [4] P. Sunarko, A. Bijaksana, P. Negara, and R. Septiriana, “Perbandingan Klasifikasi Algoritma Support vector machine dan Naïve Bayes Menggunakan Labeling VADER dan Lexicon based pada Tweets Bahasa Indonesia dan Bahasa Inggris,” *J. Apl. dan Ris. Inform.*, vol. 03, no. 1, pp. 9–19, 2024, doi: 10.26418/juara.v3i1.86468.
- [5] H. Firda *et al.*, “Perbandingan Pelabelan Rating - based dan Inset Lexicon - based Perbandingan Pelabelan Rating - based dan Inset Lexicon - based dalam Analisis Sentimen Menggunakan SVM (Studi Kasus : Ulasan Aplikasi GoBiz di Google Play Store),” *J. Sist. Inf.*, vol. 14, pp. 516–528, 2025.
- [6] N. E. Oktaviana *et al.*, “ANALISIS SENTIMEN TERHADAP KEBIJAKAN KULIAH DARING SELAMA PANDEMI MENGGUNAKAN PENDEKATAN LEXICON BASED FEATURES DAN SUPPORT VECTOR MACHINE,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 2, 2022, doi: 10.25126/jtiik.202295625.
- [7] F. M. Apriansyah, T. I. Ramadhan, C. R. Hidayat, and A. Karta, “Perbandingan IndoBERT dan IndoRoBERTa Untuk Analisis Sentimen Pada Film Dokumenter Dirty Vote,” *J. Pengemb. IT*, vol. 10, no. 3, pp. 593–605, 2025, doi: 10.30591/jpit.v10i3.8607.
- [8] K. Dedes *et al.*, “BERT Sentimen : Fine-Tuning Multibahasa untuk Ulasan Bahasa,” *J. Komput. Teknol. Inf. Sist. Komput.*, vol. 4, no. 2, pp. 1080–1084, 2025.
- [9] Y. Asri, W. N. Suliyanti, D. Kuswardani, and M. Fajri, “Pelabelan Otomatis Lexicon Vader dan Klasifikasi Naive Bayes dalam menganalisis sentimen data ulasan PLN Mobile,” *J. Pengkaj. dan Penerapan Tek. Inform.*, vol. 15, no. 2, pp. 264–275, 2022.
- [10] F. F. R. Agnia Suci Rizkia, Wufron, “Analisis Sentimen Coretax : Perbandingan Pelabelan Data Manual, Transformers-Based, dan Lexicon-Based pada Performa IndoBERT,” *Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. July, pp. 1037–1048, 2025.
- [11] C. J. L. Tobing, I. G. N. L. Wijayakusuma, and Luh Putu Ida, “Perbandingan Kinerja IndoBERT dan MBERT untuk Deteksi Berita Hoaks Politik dalam Bahasa Indonesia,” *J. Sains dan Teknol.*, vol. 14, no. 1, pp. 114–123, 2025.
- [12] A. Ulinuha, E. Majid, and R. Nuari, “PERBANDINGAN KINERJA METRIK BERT DAN MODEL MACHINE LEARNING KLASIK (SVM, NAIVE BAYES) UNTUK ANALISIS SENTIMEN,” *J. Inovtek Polbeng*, vol. 10, no. 2, pp. 741–752, 2025.
- [13] P. Fremmuzar and A. Baita, “Uji Kernel SVM dalam Analisis Sentimen Terhadap Layanan Telkomsel di Media Sosial Twitter,” *J. Sist. Komput.*, vol. 12, no. 148, 2023, doi: 10.34010/komputika.v12i2.9460.
- [14] A. N. Indraini and I. Ernawati, “Analisis Sentimen Terhadap Pembelajaran Daring Di Indonesia Menggunakan Support Vector Machine (SVM),” *J. Ilm. FIFO*, vol. XIV, no. 1, pp. 68–80, 2022.
- [15] L. Rohmatun and A. Baita, “Machine Learning-Based Sentiment Analysis on Twitter (X): A Case Study of the ‘ Kabur Aja Dulu ’ Issue Using SVM,” *J. Appl. informatics Comput.*, vol. 9, no. 4, pp. 1972–1983, 2025.
- [16] F. Wajidi and A. A. A. Cirua, “ANALISIS SENTIMEN ULASAN APLIKASI WONDR BY BNI MENGGUNAKAN ALGORITMA SVM DENGAN OPTIMASI KERNEL TRICK,” *J. Ilm. Tek. dan Ilmu Komput.*, vol. 4, no. 2, pp. 69–81, 2025.
- [17] S. R. Putri, M. Arifin, P. Studi, S. Informasi, F. Teknik, and U. M. Kudus, “Analisis Sentimen Publik terhadap Nadiem Makarim sebagai Mendikbudristek menggunakan Support Vector Machine (SVM),” *Sist. Sist. Inf.*, vol. 14, pp. 826–834, 2025.
- [18] F. R. Andhika, W. Witanti, and P. N. Sabrina, “Analisis Sentimen Menggunakan Metode IndoBERT pada Ulasan Aplikasi Zoom Menggunakan Fitur Ekstrasi GloVe,” *Metik J.*, 2025, doi: 10.47002/metik.v9i2.1098.

- [19] P. Arsi and R. Waluyo, “ANALISIS SENTIMEN WACANA PEMINDAHAN IBU KOTA INDONESIA MENGGUNAKAN ALGORITMA SUPPORT VECTOR MACHINE (SVM),” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 1, pp. 147–156, 2021, doi: 10.25126/jtiik.202183944.
- [20] A. Septini, “Analisis Sentimen Masyarakat di Twitter Mengenai Open AI CHATGPT Menggunakan Metode Support Vector Machine (SVM),” *Bull. Comput. Sci. Res.*, vol. 5, no. 2, pp. 138–149, 2025, doi: 10.47065/bulletincsr.v5i2.475.
- [21] H. Tuhuteru, “Analisis Sentimen Masyarakat Terhadap Pembatasan Sosial Berksala Besar Menggunakan Algoritma Support Vector Machine,” *Inf. Syst. Dev.*, vol. 4, no. 1, 2020.
- [22] M. Lstm-rnn, Y. J. Juliansyah, and A. M. Hilda, “Analisis Sentimen Penggunaan Artificial Intelligence Terhadap Penyelenggaraan Pemilu 2024 Menggunakan Metode LSTM-RNN,” *J. Inf. Syst. Res.*, vol. 6, no. 1, pp. 566–575, 2024, doi: 10.47065/josh.v6i1.6069.
- [23] N. A. Maulana and D. Darwis, “Perbandingan Metode SVM dan Naïve Bayes untuk Analisis Sentimen pada Twitter tentang Obesitas di Kalangan Gen Z,” *J. Pendidik. dan Teknol. Indones.*, vol. 5, no. 3, pp. 655–666, 2025.
- [24] M. H. Arfian *et al.*, “Analisis Sentimen Pada Media Sosial Menggunakan Metode Support Vector Machine,” *JITKOM*, vol. 09, no. 01, pp. 1–6, 2025, doi: 10.22441/jitkom.v9i1.001.
- [25] F. Rachmawati, U. Azmi, and R. Azwarini, “Comparison of Lexicon-based Methods and Bidirectional Encoder Representations for Transformers Models in Sentiment Analysis of Government Debt Market Movements,” *Int. J. Eng. Comput. Sci. Appl.*, vol. 4, no. 1, pp. 13–28, 2025.
- [26] A. Yusupa and V. Tarigan, “PERBANDINGAN ALGORITMA MACHING LEARNING DALAM ANALISIS SENTIMEN MOBIL LISTRIK DI INDONESIA PADA MEDIA SOSIAL TWITTER / X,” *JIP(Jurnal Inform. Polinema)*, vol. 10, edisi, pp. 479–490, 2023.
- [27] A. Maulana, I. K. Afifah, A. Mubarrak, and K. R. Fauzan, “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.
- [28] D. Komalla, R. G. G. Alam, and A. Wijaya, “Analisis Performa Algoritma Naïve Bayes dan SVM Menggunakan Python Pada Ulasan Sentimen Game Roblox,” *J. Ris. Komput.*, vol. 12, no. 6, pp. 1036–1048, 2025, doi: 10.30865/jurikom.v12i6.9396.
- [29] J. A. Wibowo, V. C. Mawardi, and T. Sutrisno, “VISUALISASI WORD CLOUD HASIL ANALISIS SENTIMEN BERBASIS FITUR LAYANAN APLIKASI GOJEK DENGAN SUPPORT VECTOR MACHINE,” *J. Serina Sains, Tek. dan Kedokt.*, vol. 02, no. 01, pp. 61–70, 2024.