

BAB II

LANDASAN TEORI

2.1 Penelitian Terdahulu

Tabel 2.1 memberikan rangkuman penelitian – penelitian yang membahas beberapa topik serupa yang berkaitan dengan penelitian ini.

Tabel 2. 1 Penelitian Terdahulu

Penulis	Judul	Metodologi	Hasil
R. P. Setiawan, B. Irawan, W. Prihartono (2025) [20]	Analisis Sentimen Ulasan Growtopia di Google Play Store Menggunakan Naive Bayes Classifier Untuk Identifikasi Kebutuhan Pengguna	Sebanyak 2.000 ulasan pengguna game Growtopia dari Google Play Store dianalisis dalam penelitian ini, dengan proses klasifikasi dilakukan menggunakan algoritma Multinomial Naïve Bayes Classifier.	Penerapan model Naïve Bayes dalam penelitian ini menghasilkan akurasi sebesar 87% dalam mengklasifikasikan sentimen dari ulasan pengguna.
M. D. Purbolaksono (2024) [21]	Sentiment Analysis of Game Review in Steam Platform using Random Forest	Penelitian ini menerapkan Random Forest untuk klasifikasi sentimen ulasan game di Steam menggunakan ekstraksi fitur TF- IDF dalam format Bigram dan Trigram.	Hasil evaluasi menunjukkan bahwa performa terbaik dicapai menggunakan Bigram TF-IDF tanpa Lemmatization, dengan rata-rata F1-score sebesar 62%.
M.Y. Febrianta, S. Widiyanesti, S. R. Ramadhan (2021) [22]	Analisis Ulasan Indie Video Game Lokal pada Steam Menggunakan Analisis Sentimen dan Pemodelan Topik Berbasis Latent Dirichlet Allocation	Ulasan video game indie lokal di Steam dianalisis dalam penelitian ini melalui pendekatan analisis sentimen dan pemodelan topik menggunakan algoritma Latent Dirichlet	Model Naïve Bayes yang digunakan dalam penelitian ini mampu mengklasifikasikan sentimen ulasan dengan akurasi sebesar 75.45%.

Penulis	Judul	Metodologi	Hasil
		Allocation (LDA).	
B. J. Rizqullah (2024) [23]	Analisis Sentimen Ulasan Game Apex Legends pada Steam Menggunakan Naïve Bayes Classifier	Penelitian ini menganalisis sebanyak 4.332 ulasan Apex Legends. Model analisis sentimen dalam penelitian ini dikembangkan dengan memanfaatkan metode Word2Vec untuk representasi kata dan algoritma Naïve Bayes untuk proses klasifikasinya.	Model analisis sentimen yang dihasilkan dalam penelitian ini memperoleh akurasi sebesar 75%, dengan presisi mencapai 83% dan recall sebesar 82%.
S. R. S. Pratama, D. Arifianto, B. S. Bakti (2024) [24]	Analisis Sentimen Ulasan Video Game My Lovely Daughter Menggunakan Metode Multinomial Naïve Bayes	Penelitian ini menganalisis ulasan game My Lovely Daughter di Steam. Data diklasifikasikan menggunakan algoritma Multinomial Naïve Bayes Classifier.	Penerapan model Naïve Bayes dalam penelitian ini menghasilkan akurasi klasifikasi sentimen sebesar 70%.
F. Wijaya (2024) [25]	Analisa Sentimen Berbasis Teks Permainan Counter Strike 2 dengan Algoritma Klasifikasi	Penelitian ini menganalisis sentimen permainan Counter Strike 2 menggunakan algoritma RF, MNB, LR, dan SVM.	Model terbaik adalah Random Forest dengan tingkat akurasi 87,7%.
N. C. Ramadani (2024) [26]	Analisis Sentimen Untuk Mengukur Ulasan Pengguna Aplikasi Mobile Legend Menggunakan Algoritma Naive Bayes, SVM, Random Forest, Decision Tree,	Sebanyak 10.000 ulasan pengguna aplikasi Mobile Legends dari Google Play Store dianalisis dalam penelitian ini. Analisis sentimen dilakukan	Temuan penelitian ini menunjukkan bahwa algoritma Support Vector Machine (SVM) adalah yang paling efektif dalam menganalisis sentimen ulasan

Penulis	Judul	Metodologi	Hasil
	dan Logistic Regression	menggunakan lima algoritma machine learning, meliputi Naïve Bayes, Support Vector Machine (SVM), Random Forest, Decision Tree, dan Logistic Regression.	pengguna Mobile Legends, dengan tingkat akurasi mencapai 87%.
A. H. Nurdy, A. Rahim, Arbansyah (2024) [27]	Analisis Sentimen Ulasan Game Stumble Guys Pada Playstore Menggunakan Algoritma Naïve Bayes	Penelitian ini menganalisis sentimen permainan Stumble Guys menggunakan algoritma Multinomial Naïve Bayes	Algoritma Naïve Bayes mencapai akurasi 86% dengan. Akurasi tertinggi didapatkan dengan pembagian <i>training</i> dan test set 80:20
N. Sabilly, Khadijah, F. A. Nugroho (2023) [28]	Sentiment Analysis Of League Legends: Wild Rift Reviews On Google Play Using Naive Bayes Classifier	Dalam penelitian ini, algoritma Gaussian Naive Bayes Classifier digunakan untuk melakukan klasifikasi sentimen pada ulasan pengguna game League of Legends: Wild Rift di Google Play Store.	Hasil terbaik mencapai akurasi sebesar 79,3%.
F. I. Wibowo, A. Febriandirza (2024) [29]	Analisis Sentimen Ulasan Pengguna Game PUBG Di Google Play Store Menggunakan Algoritma Naïve Bayes	Sentimen ulasan pengguna game PUBG pada Google Play Store diklasifikasikan menggunakan algoritma Naive Bayes Classifier dalam penelitian ini.	Hasil prediksi mencapai akurasi 83.95%.
M. S. F. J. Al et al. (2023) [30]	Sentiment Analysis of Game Reviews on STEAM using	Penelitian ini mengkombinasikan model BERT, Bi-LSTM, dan CRF	Model terbaik adalah gabungan BERT-BiLSTM-

Penulis	Judul	Metodologi	Hasil
	BERT, BiLSTM, and CRF	untuk melakukan analisis sentimen pada ulasan game di platform Steam	CRF dengan sakurasi 95.2%
I. G. A. N. Lestari et. Al. (2025) [31]	Effectiveness of AdaBoost and XGBoost Algorithms in Sentiment Analysis of Movie Reviews	Studi ini bertujuan untuk mengembangkan model analisis sentimen untuk ulasan film, menggunakan dataset 50.000 ulasan film IMDb dari Kaggle menggunakan AdaBoost dan XGBoost	Studi ini menyimpulkan bahwa model XGBoost menunjukkan kinerja yang lebih baik dengan akurasi 86%
L. Simanihuruk, H. Suparwito (2025) [32]	Long Short-Term Memory and Bidirectional Long Short-Term Memory Algorithms for Sentiment Analysis of Skintific Product Reviews	Penelitian ini menganalisis sentimen ulasan produk skincare merek SKINTIFIC di platform Shopee dengan menggunakan dua model deep learning: Long Short-Term Memory (LSTM) dan Bidirectional LSTM (Bi-LSTM).	Model Bi-LSTM menunjukkan kinerja yang unggul, mencapai akurasi rata-rata 95,91% dan skor F1 rata-rata 95,82%, dibandingkan dengan model LSTM standar.
A. Rolangon, A. Weku, G. A. Sandag (2023) [33]	Perbandingan Algoritma LSTM Untuk Analisis Sentimen Pengguna Twitter Terhadap Layanan Rumah Sakit Saat Pandemi Covid-19	Penelitian ini menganalisis sentimen masyarakat terhadap layanan rumah sakit selama pandemi COVID-19 melalui data Twitter, dengan membandingkan performa empat algoritma deep learning: LSTM, BiLSTM, GRU, dan SimpleRNN.	Model BiLSTM adalah yang paling efektif dalam menganalisis sentimen terhadap layanan rumah sakit di Twitter selama pandemi dengan akurasi 86%.

Berdasarkan penelitian-penelitian terdahulu, beberapa model yang digunakan dalam klasifikasi teks ulasan antara lain Multinomial Naïve Bayes dan Random Forest. Algoritma tersebut terbukti mampu memberikan akurasi yang cukup baik dalam mengklasifikasikan sentimen pada data teks. Oleh karena itu, penelitian ini menggunakan algoritma Multinomial Naïve Bayes dan Random Forest sebagai pembandingan dengan hasil dari studi sebelumnya. Selain itu, penelitian ini juga mengimplementasikan model XGBoost, sebuah algoritma *ensemble* yang dikenal efektif dalam menangani data dengan fitur yang kompleks dan mampu memberikan performa prediksi yang tinggi [34]. Di sisi lain, model *deep learning* Bidirectional Long Short-Term Memory (Bi-LSTM) juga digunakan karena kemampuannya dalam memahami konteks kata secara sekuensial dari dua arah (*forward* dan *backward*), sehingga dapat menangkap makna yang lebih dalam dari teks ulasan pemain [35], [36].

2.2 Teori Penelitian

2.2.1 *Sentiment Analysis*

Sentiment analysis, yang juga dikenal sebagai penambangan opini, adalah subbidang pemrosesan bahasa alami (NLP) yang berfokus pada identifikasi dan kategori opini yang diungkapkan dalam data teks [37], [38]. Proses ini melibatkan penentuan polaritas sentiment positif, negatif, atau netral yang terkait dengan bagian teks tertentu [39], [40]. Pentingnya analisis sentimen telah berkembang dalam beberapa tahun terakhir, terutama dengan munculnya media sosial dan platform online di mana sejumlah besar konten buatan pengguna tersedia untuk dianalisis [41], [42]. *Sentiment analysis* menjadi alat yang penting dalam berbagai industri. *Sentiment analysis* dapat dimanfaatkan untuk riset pasar, analisis umpan balik pelanggan, dan pelacakan sentimen politik, sehingga membantu organisasi dalam proses pengambilan keputusan [43], [44].

Algoritma yang digunakan dalam analisis sentimen secara garis besar dapat dikategorikan menjadi tiga jenis: pendekatan berbasis *lexicon*, berbasis *machine learning*, dan berbasis *deep learning* [45], [46]. Metode berbasis *lexicon* mengandalkan daftar kata-kata yang telah ditentukan sebelumnya terkait dengan nilai-nilai sentimen, yang mungkin efektif namun terbatas dalam menangani konteks dan sarkasme [47], [48]. Teknik *machine learning*, seperti

Support Vector Machines (SVM), Naïve Bayes, dan Random Forest, memanfaatkan kumpulan data berlabel untuk melatih model yang dapat mengklasifikasikan sentimen berdasarkan fitur yang diekstrak dari teks [49], [50]. Pendekatan *deep learning*, khususnya yang menggunakan neural network, telah mendapatkan daya tarik karena kemampuannya menangkap pola kompleks dalam data [51], [52].

2.2.2 Game Marvel Rivals

Marvel Rivals merupakan sebuah *video game* dari pengembang *NetEase* bergenre *hero shooter*, yang menekankan permainan berbasis karakter, di mana pemain memilih dari daftar pahlawan unik, masing-masing dengan kemampuan dan peran berbeda [53], [54]. Genre ini mendapatkan popularitas yang signifikan karena perpaduan mekanisme menembak tradisional dengan elemen kerja tim dan strategi, yang sering terlihat di game seperti *Overwatch* dan *Apex Legends* [55].

Ciri khas *hero shooter* adalah penekanannya pada keragaman karakter dan kemampuan, yang membedakannya dari game FPS tradisional. Dalam game FPS tradisional, pemain biasanya memiliki akses ke serangkaian senjata dan keterampilan yang seragam, sedangkan *hero shooter* memperkenalkan karakter unik dengan kekuatan khusus yang dapat memengaruhi dinamika permainan. Pilihan desain ini tidak hanya meningkatkan keterlibatan pemain tetapi juga mendorong permainan kooperatif, karena pemain harus bekerja sama untuk memaksimalkan kekuatan pahlawan mereka [56].

2.2.3 Large Language Models

Large Language Models (LLM), adalah bagian kecerdasan buatan (AI), yang memiliki kemampuannya dalam pemrosesan bahasa alami (NLP). Model-model ini telah dilatih pada kumpulan data yang sangat besar, sehingga memungkinkan mereka untuk menghasilkan teks seperti manusia dan memahami pola bahasa yang kompleks [57], [58]. Kegunaan LLM tidak hanya terbatas pada pembuatan teks saja; LLM juga dapat mengintegrasikan input multimodal, memproses berbagai jenis data, termasuk teks, gambar, dan format lainnya, sehingga meningkatkan cakupan aplikasinya [59].

2.2.4 Retrieval-augmented Generation

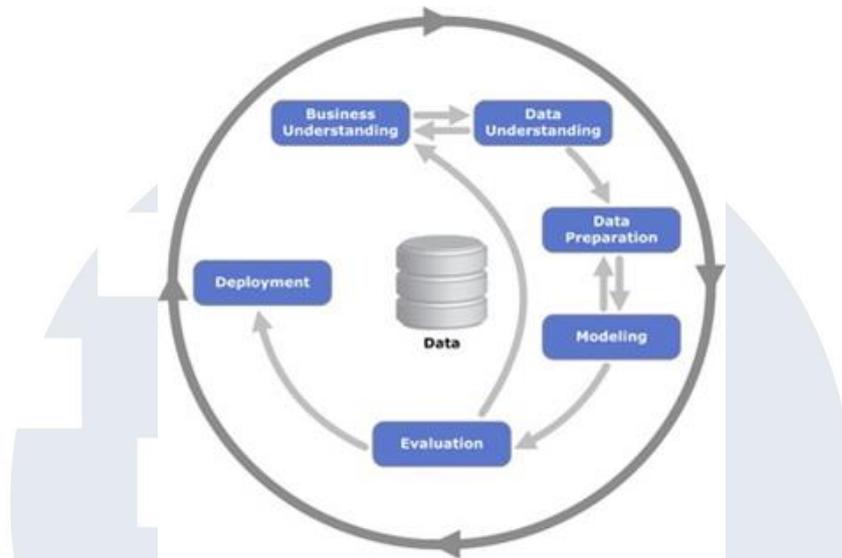
Retrieval-augmented generation (RAG) adalah kerangka kerja inovatif yang meningkatkan kemampuan LLM dengan mengatasi keterbatasan umum LLM, seperti kecenderungan untuk berhalusinasi (membuat jawaban tanpa dasar) atau menggunakan data yang sudah tidak relevan, sehingga meningkatkan akurasi faktual dan koherensi teks yang dihasilkan [60], [61].

Secara umum, Retrieval-Augmented Generation (RAG) adalah metode yang menggabungkan pencarian informasi dengan pembuatan teks oleh Large Language Model (LLM) untuk meningkatkan kualitas jawaban [62]. Saat menerima sebuah pertanyaan, sistem RAG pertama-tama melakukan tahap Retrieval (pengambilan) dengan mencari dokumen yang paling relevan dari sebuah basis pengetahuan eksternal [63]. Informasi yang ditemukan ini kemudian digunakan untuk Augmentation (penambahan), di mana ia digabungkan dengan pertanyaan awal untuk menciptakan sebuah prompt yang kaya akan konteks [64]. Terakhir, prompt yang sudah diperkaya ini diberikan kepada LLM untuk tahap Generation (pembuatan), memungkinkannya menghasilkan jawaban yang didasarkan pada data yang diberikan [65].

2.3 Framework dan Algoritma Penelitian

2.3.1 Framework CRISP-DM

CRISP-DM, yang merupakan singkatan dari Cross-Industry Standard Process for Data Mining, adalah suatu *framework* yang digunakan untuk melaksanakan proyek-proyek data mining. Metode ini menyediakan suatu pendekatan yang terstruktur dan sistematis untuk memandu keseluruhan proses data mining, mulai dari memahami permasalahan hingga menerapkan solusi akhir [66]. Kerangka kerja CRISP-DM terdiri dari enam tahapan: *business understanding, data understanding, data preparation, modeling, evaluation, and deployment* [67]. Visualisasi *framework* CRISP-DM dapat dilihat pada Gambar 2.4.



Gambar 2. 1 Framework CRISP-DM (Sumber: www.djkn.kemenkeu.go.id)

1) Business Understanding

Dalam tahap *business understanding*, tujuan dan kebutuhan proyek didefinisikan, dan sebuah rencana awal disusun. Tahap ini melibatkan pemahaman konteks bisnis, mengidentifikasi tujuan proyek, dan menetapkan kriteria keberhasilan [68].

2) Data Understanding

Tahap *data understanding* terfokus pada pengumpulan dan eksplorasi data yang akan digunakan dalam analisis. Tahap ini melibatkan identifikasi sumber data yang relevan, pengambilan data, serta eksplorasi awal data untuk memahami kualitas dan karakteristik data [69].

3) Data Preparation

Tahap *data preparation* melibatkan proses *cleaning* dan *transformation* untuk membuatnya cocok untuk analisis [67]. *Cleaning* adalah proses menghapus atau memperbaiki bagian data yang tidak relevan sehingga model menjadi lebih akurat [30]. *Transformation* dalam konteks NLP adalah proses mengubah teks mentah menjadi representasi numerik atau format yang bisa digunakan oleh model *machine learning* [30].

4) Modeling

Tahap *modeling* adalah tahap menciptakan model-model prediksi atau deskriptif. Tahap ini melibatkan pemilihan teknik pemodelan yang tepat,

pembangunan dan validasi model, serta pemilihan model terbaik untuk diterapkan [69].

5) Evaluation

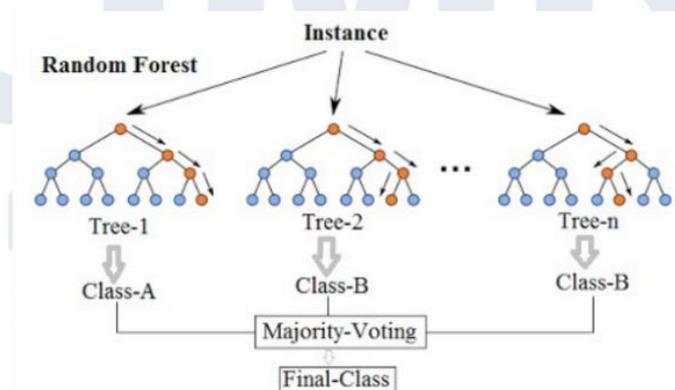
Tahap *evaluation* menilai kualitas dan efektivitas model yang dikembangkan dalam fase sebelumnya. Tahap ini mencakup evaluasi kinerja model, interpretasi hasil, dan penilaian apakah model tersebut memenuhi tujuan bisnis [70].

6) Deployment

Tahap terakhir adalah *deployment*, yang mencakup penerapan model ke dalam lingkungan produksi, pengembangan strategi penggunaan hasil, dan pemantauan performa dari solusi yang telah diimplementasikan [68]. Dalam penelitian ini, *deployment* dilakukan dengan membuat aplikasi berbasis Streamlit untuk menganalisis ulasan pemain secara otomatis.

2.3.2 Random Forest

Random Forest (RF) adalah algoritma pembelajaran mesin yang banyak digunakan dan telah diterapkan dalam berbagai bidang [71], [72]. Algoritma ini bekerja dengan menggabungkan beberapa prediktor pohon [73], [74]. Random Forest adalah suatu metode gabungan yang membangun banyak pohon keputusan untuk mengklasifikasikan instance baru berdasarkan suara mayoritas [75]. Pendekatan ini memungkinkan pembuatan model *ensemble* yang dapat mengatasi dataset yang kompleks dan meningkatkan akurasi prediksi [72]. Visualisasi RF dapat dilihat pada Gambar 2.1.



Gambar 2. 2 Algoritma Random Forest (Sumber: Medium.com)

Sebuah Random Forest terdiri dari sejumlah *decision trees*, dimana Random Forest dinotasikan sebagai [76]:

$$m_{M,n}(x;\theta_1,\dots,\theta_M,Dn) = \frac{1}{M} \sum_{j=1}^M m_n(x;\theta_j,Dn)$$

Rumus 2. 1 Notasi Random Forest

Dalam mengklasifikasi, Random Forest menentukan pilihan melalui mayoritas *voting* setiap *tree* nya, yang dinotasikan dengan [76]:

$$m_{M,n}(x;\theta_1,\dots,\theta_M,Dn) = \begin{cases} 1 & \text{if } \frac{1}{M} \sum_{j=1}^M m_n(x;\theta_j,Dn) > 1/2 \\ 0 & \text{otherwise} \end{cases}$$

Rumus 2. 2 Voting Random Forest

2.3.3 Multinomial Naïve Bayes

Algoritma Multinomial Naive Bayes (MNB) adalah varian dari pengklasifikasi Naive Bayes yang sangat efektif untuk tugas klasifikasi teks [77][78]. Salah satu keunggulan utama algoritma Multinomial Naive Bayes adalah kesederhanaan dan efisiensi komputasinya [79], [80]. Efisiensi ini sangat penting dalam aplikasi seperti deteksi spam, analisis sentimen, dan klasifikasi dokumen, yang volume datanya bisa sangat besar [81].

Multinomial Naïve Bayes merupakan metode yang dirancang untuk analisis teks dokumen dengan cara menghitung frekuensi kemunculan kata-kata di dalamnya. Dengan menghitung *likelihood* (probabilitas) kemunculan suatu kata dalam data teks, maka kategori dari teks tersebut dapat ditentukan. Adapun rumus yang digunakan untuk menghitung probabilitas dokumen dalam suatu kelas adalah sebagai berikut [82]:

$$P(X|c) = \log \frac{N_c}{N} + \sum_{i=1}^n \log \frac{t_i + \alpha}{\sum_{i=1}^n t_i + \alpha}$$

Rumus 2. 3 Probabilitas dokumen dalam suatu kelas

2.3.4 Extreme Gradient Boosting

Extreme Gradient Boosting (XGBoost) memanfaatkan kemampuan pembelajaran *ensemble* untuk meningkatkan akurasi prediksi dan kemampuan

interpretasi. XGBoost beroperasi berdasarkan prinsip *boosting*, yang secara berurutan menerapkan pembelajar yang lemah (biasanya pohon keputusan) untuk memperbaiki kesalahan yang dibuat oleh model sebelumnya [83], [84]. Proses berulang ini memungkinkan XGBoost meminimalkan *loss function* secara efektif, sehingga menghasilkan peningkatan kinerja dalam berbagai aplikasi [34]. Penentuan prediksi XGBoost dapat dinotasikan sebagai berikut [85]:

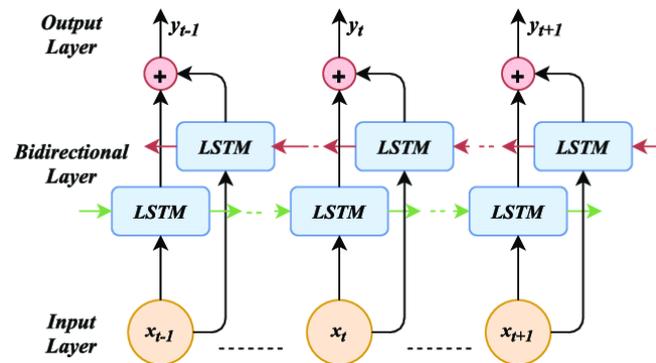
$$\hat{y}_i^t = \sum_{k=1}^t f_k(x_i) = \hat{y}_i^{t-1} + f_t(x_i)$$

Rumus 2. 4 Prediksi XGBoost

2.3.5 Bidirectional Long Short-Term Memory

Jaringan Bidirectional Long Short-Term Memory (Bi-LSTM) merupakan salah satu teknik yang efektif dalam bidang analisis sentimen, karena kemampuan unik ini muncul dari struktur Bi-LSTM, yang mencakup dua lapisan LSTM: satu memproses urutan masukan dari awal hingga akhir (maju) dan yang lainnya dari akhir hingga awal (mundur) [35], [36]. Dengan menggabungkan *output* dari kedua proses ini, Bi-LSTM secara efektif menyimpan informasi tentang kata-kata sebelumnya dan berikutnya, sehingga memungkinkan interpretasi data input yang lebih bernuansa [86]. Karakteristik ini sangat penting dalam tugas pemrosesan bahasa alami (NLP) seperti analisis sentimen, di mana pemahaman konteks sangat penting untuk interpretasi sentimen yang akurat [87], [88]. Dalam bidang analisis sentimen, Bi-LSTM telah menunjukkan kinerja yang unggul dibandingkan dengan metode tradisional, termasuk LSTM lapisan tunggal [89]. Visualisasi Bi-LSTM dapat dilihat pada Gambar 2.2.

U N I V E R S I T A S
M U L T I M E D I A
N U S A N T A R A



Gambar 2. 3 Algoritma Bi-LSTM (Sumber: Medium.com)

2.3.6 Synthetic Minority Oversampling

Teknik Synthetic Minority Oversampling (SMOTE) adalah salah satu teknik untuk mengatasi masalah ketidakseimbangan kelas dalam analisis sentimen [90]. Ketidakseimbangan kelas adalah situasi ketika satu label memiliki jumlah data yang jauh lebih banyak atau sedikit daripada kelas lainnya, yang menyebabkan kinerja model menjadi bias kepada kelas tertentu [91], [92]. SMOTE bekerja dengan menghasilkan sampel sintetis untuk kelas minoritas melalui proses yang mengidentifikasi tetangga terdekat dari contoh minoritas dan kemudian menyisipkan contoh baru di antara titik-titik ini [92]. Beberapa penelitian telah menunjukkan bahwa mengintegrasikan SMOTE dapat menghasilkan peningkatan akurasi dan ketahanan dalam tugas klasifikasi sentimen di berbagai algoritma, seperti Naïve Bayes, Support Vector Machines (SVM), dan Random Forests [93], [94], [95].

2.4 Tools dan Software Penelitian

2.4.1 Bahasa Pemrograman Python

Python merupakan bahasa pemrograman tingkat tinggi yang banyak digunakan dalam bidang *data science*, *machine learning*, dan *natural language processing* (NLP) karena sintaksnya yang sederhana serta ekosistem pustaka yang luas dan aktif. Python menyediakan berbagai library penting seperti scikit-learn untuk *machine learning*, pandas dan numpy untuk manipulasi data, serta Keras dan TensorFlow untuk pengembangan model *deep learning*. Dalam analisis sentimen berbasis teks, Python juga mendukung berbagai pustaka NLP seperti nltk yang memudahkan dalam proses tokenisasi, lemmatization, hingga

vektorisasi data. Karena fleksibilitas dan efisiensinya, Python menjadi pilihan utama dalam berbagai penelitian akademik dan industri, termasuk dalam pengembangan model klasifikasi sentimen seperti yang dilakukan dalam penelitian ini.

2.4.2 Jupyter Notebook

Jupyter Notebook adalah aplikasi open-source berbasis web yang digunakan untuk membuat dan berbagi dokumen yang berisi kode program, visualisasi, serta narasi teks dalam satu antarmuka interaktif. Jupyter mendukung berbagai bahasa pemrograman, namun paling umum digunakan dengan Python dalam bidang analisis data, machine learning, dan penelitian ilmiah. Kelebihannya terletak pada kemampuannya untuk menjalankan kode secara sel dan langsung menampilkan output, grafik, serta dokumentasi dalam satu file terintegrasi, sehingga sangat memudahkan proses eksplorasi data, eksperimen model, dan pelaporan hasil.

2.4.3 Ollama dan LLM Llama3

Ollama adalah sebuah platform yang memungkinkan pengguna untuk menjalankan dan mengelola model bahasa besar (Large Language Models/LLMs) secara lokal dengan mudah dan efisien, tanpa perlu koneksi ke cloud. Salah satu model yang didukung oleh Ollama adalah LLaMA 3 (Large Language Model Meta AI versi 3), yang merupakan model bahasa generatif terbaru dari Meta AI dengan peningkatan dalam pemahaman konteks, efisiensi pemrosesan, dan akurasi jawaban dibanding versi sebelumnya.