

BAB II

LANDASAN TEORI

2.1 Penelitian Terdahulu

Penelitian-penelitian sebelumnya menjadi fondasi yang berperan dalam membentuk arah dan kerangka konseptual studi ini. Berbagai pendekatan *machine learning* seperti Naïve Bayes, Support Vector Machine (SVM) dan metode *deep learning* seperti Long Short-Term Memory (LSTM) telah banyak diaplikasikan dalam kajian analisis sentimen. Penelitian-penelitian tersebut memberikan gambaran mengenai efektivitas masing-masing metode dalam mengklasifikasikan sentimen dari data teks hingga *research gap* khususnya dalam konteks ulasan pengguna terhadap aplikasi digital. Pada penelitian terdahulu dapat ditemukan celah penelitian, membandingkan pendekatan yang digunakan serta merumuskan metode yang paling tepat untuk diterapkan dalam menganalisis sentimen ulasan pengguna aplikasi Halo BCA. Systematic Literature Review (SLR) dilakukan dengan Pendekatan Kitchenham [8].

1. *Planning the Review*

a. *Research Question*

- i. Apa saja metode yang digunakan dalam analisis sentimen terhadap ulasan aplikasi digital, khususnya aplikasi perbankan?
- ii. Seberapa besar akurasi yang dicapai oleh masing-masing metode dalam berbagai studi?
- iii. Apa saja kekurangan atau *research gap* yang ditemukan dalam penelitian-penelitian sebelumnya?

b. *Search Strategy*

- i. Kata kunci: "Sentiment Analysis", "Mobile Banking", "LSTM", "Naive Bayes", "SVM", "Google Play Store review"
- ii. *Database*: IEEE, ScienceDirect, Scopus, Google Scholar, MDPI, SSRN
- iii. Periode publikasi: 2020–2025

c. *Inclusion Criteria*

- i. Artikel yang membahas metode analisis sentimen
- ii. Studi yang menggunakan dataset dari ulasan pengguna
- iii. Penelitian dengan hasil evaluasi performa model (akurasi, f1-score, dll)

d. *Exclusion Criteria*

- i. Artikel tidak relevan dengan analisis sentimen
- ii. Studi yang tidak menyertakan hasil evaluasi model

2. *Conducting the Review*

Tabel 2. 1 Penelitian Terdahulu

Nama Peneliti	Judul Penelitian	Hasil Penelitian	Research Gap
Li, X.; Zhang, Z.; Stefanidis, K.	A Sentiment-Statistical Approach for Identifying Problematic Mobile App Updates Based on User Reviews	Menggunakan algoritma VADER untuk analisis sentimen pada ulasan aplikasi. Akurasi keseluruhan mencapai 84.2% dalam mendeteksi sentimen positif, negatif, dan netral.	Terletak pada kebutuhan pengembangan metode yang lebih canggih, seperti <i>deep learning</i> , untuk meningkatkan akurasi dan pemahaman konteks sentimen secara lebih mendalam.
Gondhi N; Chaahat; Sharma E; Alharbi A; Verma R; Shah M	Efficient Long Short-Term Memory-Based Sentiment Analysis of E-Commerce Reviews	LSTM dengan Word2Vec menghasilkan akurasi 85.96% untuk ulasan e-commerce. LSTM lebih baik dibandingkan metode tradisional seperti Naive Bayes dan SVM.	Keterbatasan eksplorasi arsitektur model lain yang lebih kompleks, seperti BiLSTM atau model dengan mekanisme <i>attention</i> , serta kurangnya pengujian pada berbagai jenis dataset dan domain yang berbeda

Gupta A; Kamthania D	Study of Sentiment on Google Play Store Applications	Model Logistic Regression telah diterapkan pada analisis sentimen terhadap <i>review</i> aplikasi di Google Play Store, menghasilkan tingkat akurasi sebesar 81,1% . Studi ini berfokus pada kategori aplikasi populer, terutama dalam ranah permainan digital (game), guna mengevaluasi efektivitas metode klasifikasi dalam mengidentifikasi pola sentimen pengguna.	Terbatas pada satu kategori aplikasi dan belum mengeksplorasi metode klasifikasi yang lebih canggih atau teknik <i>pre-processing</i> yang dapat meningkatkan akurasi dan generalisasi model.
Bramanthyo Andrian, Tiarna Simanungkalit, et al.	Sentiment Analysis on Customer Satisfaction of Digital Banking in Indonesia	Penelitian ini bertujuan untuk mengetahui kepuasan pelanggan terhadap digital banking di Indonesia berdasarkan analisis sentimen dari Twitter. Data dikumpulkan dari tiga bank digital di Indonesia, yaitu Jenius, Jago, dan Blu. Temuan penelitian mengindikasikan bahwa Support Vector Machine (SVM) menunjukkan performa terbaik dengan nilai F1-score sebesar	Terbatas pada data Twitter dan tiga bank saja, serta belum mengeksplorasi model <i>deep learning</i> atau data dari platform lain untuk meningkatkan akurasi dan cakupan analisis.

		73,34%. Sementara itu, pendekatan ensemble menggunakan metode soft voting berhasil meningkatkan akurasi klasifikasi dengan mencapai F1-score sebesar 74,89%.	
Kusnawi; Rahardi M; Daarten Pandiangan V.	Sentiment Analysis of Neobank Digital Banking Using Support Vector Machine Algorithm in Indonesia	Penelitian ini bertujuan untuk mengklasifikasikan data ulasan pengguna Neobank, termasuk sentimen positif atau negatif. Penelitian ini menerapkan metode eksperimen menggunakan algoritma Support Vector Machine (SVM) untuk analisis sentimen dengan tingkat akurasi sebesar 82,33%.	Terbatas pada klasifikasi biner dan belum mengeksplorasi metode lain seperti <i>deep learning</i> atau analisis sentimen multi-kelas untuk meningkatkan akurasi dan kedalaman pemahaman sentimen pengguna.
M. Eksa Permana; H. Ramadhan; I. Budi; A. Budi Santoso; P. Kresna Putra	Sentiment Analysis and Topic Detection of Mobile Banking Application Review	Penelitian ini bertujuan untuk menganalisis sentimen pengguna terhadap aplikasi <i>mobile banking</i> serta mengidentifikasi aspek yang perlu diperbaiki guna meningkatkan pengalaman pelanggan. Hasil evaluasi menunjukkan	Terbatas pada satu metode klasik tanpa eksplorasi teknik <i>deep learning</i> atau model <i>hybrid</i> yang berpotensi meningkatkan akurasi dan kemampuan menangkap konteks sentimen yang lebih kompleks.

		bahwa tingkat akurasi metode Naïve Bayes mencapai 86,762% , dengan nilai recall 93,474% dan precision 92,482%.	
N Murthy G; Rao Allu S; Andhavarapu B; Bagadi M; Belusonti M	Text based Sentiment Analysis using LSTM	LSTM mengungguli metode tradisional dengan akurasi 87% pada dataset berbasis teks besar.	Keterbatasan dalam eksplorasi model-model <i>deep learning</i> lain yang lebih mutakhir seperti <i>transformer</i> (misalnya BERT) yang telah terbukti memberikan performa lebih baik dalam berbagai studi, serta kurangnya evaluasi pada variasi dataset yang lebih beragam untuk menguji generalisasi model secara menyeluruh.
Muhammad P; Kusumaningrum R; Wibowo A.	Sentiment Analysis Using Word2vec And Long Short-Term Memory (LSTM) For Indonesian Hotel Reviews	Kombinasi Word2Vec dan LSTM menghasilkan akurasi rata-rata 85.96% untuk ulasan hotel, lebih baik dibandingkan metode lain seperti Naive Bayes dan SVM.	Kurangnya eksplorasi variasi parameter Word2Vec dan LSTM serta belum digunakannya model <i>deep learning</i> terbaru seperti BERT untuk meningkatkan akurasi analisis sentimen pada ulasan berbahasa Indonesia.
K. Dashtipour et al.	Sentiment Analysis of Persian	Menggunakan LSTM dengan akurasi 92% .	Keterbatasan dataset dan belum digunakannya

	Movie Reviews Using Deep Learning	Algoritma SVM dan Logistic Regression (LR) memiliki akurasi lebih rendah, berkisar antara 61.27% hingga 89.37%, tergantung pada fitur yang digunakan.	model <i>transformer</i> seperti BERT untuk meningkatkan akurasi analisis sentimen bahasa Persia.
C. Gökçe Özmen & S. Gündüz	Comparison of Machine Learning Models for Sentiment Analysis of Big Turkish Web-Based Data	Penelitian ini menguji kinerja beberapa algoritma klasifikasi, yaitu K-Nearest Neighbor (K-NN), Support Vector Machine (SVM), Decision Tree (DT), Random Forest (RF), serta Logistic Regression (LR). Evaluasi dilakukan untuk menentukan metode yang paling efektif dalam menganalisis sentimen berdasarkan ulasan pengguna. SVM memberikan akurasi lebih dari 93% , 92% presisi, 93% recall, dan 91% f1-score dalam analisis produk kosmetik dalam bahasa turki.	Belum digunakannya metode <i>deep learning</i> dan model <i>transformer</i> untuk meningkatkan pemahaman konteks dalam analisis sentimen bahasa Turki.
Mola S; Baun D; Nunes I; Sani M	Analisis Sentimen Aplikasi Halo BCA di Google Play	SVM menunjukkan akurasi sebesar 87,55% . Penelitian ini menggunakan	Belum dieksplorasinya metode <i>deep learning</i> seperti LSTM yang

	Store Menggunakan Metode Naive Bayes, Support Vector Machine dan Random Forest	pelabelan sentimen berbasis leksikon dan menemukan bahwa ulasan positif didominasi kepuasan terhadap kemudahan aplikasi, sedangkan ulasan negatif berkaitan dengan masalah teknis.	berpotensi lebih baik dalam menangkap konteks dan urutan kata, serta penggunaan pelabelan berbasis leksikon yang dapat dikembangkan dengan anotasi manual atau model berbasis konteks untuk hasil yang lebih akurat.
Ahmad A; Gata W; Panggabean S	Sentimen Analisis dengan Long Short-Term Memory dan Synthetic Minority Over Sampling Technic Pada Aplikasi Digital Perbankan	Penelitian ini membahas analisis sentimen ulasan pengguna aplikasi perbankan M-BCA dan DbankPro di Google Play Store menggunakan model LSTM dengan penanganan data tidak seimbang melalui SMOTE. Hasil penelitian menunjukkan akurasi LSTM sebesar 91,07% untuk M-BCA dan 89,82% untuk DbankPro.	Belum adanya perbandingan langsung antara LSTM dan metode klasik pada dataset yang sama. Memerlukan eksplorasi lebih lanjut terhadap kombinasi teknik <i>balancing</i> data dan model <i>deep learning</i> .
Bhatara D; Suryono R	Analisis Sentimen Aplikasi BCA Mobile Menggunakan Algoritma Naive Bayes dan Suport Vector Machine	Penelitian ini membandingkan performa dua metode pada ulasan pengguna aplikasi BCA Mobile dengan bantuan teknik SMOTE untuk menyeimbangkan data. Hasil penelitian	Belum diterapkannya metode <i>deep learning</i> seperti LSTM yang berpotensi meningkatkan akurasi serta perlunya eksplorasi lebih lanjut terhadap kombinasi teknik

		menunjukkan SVM mencapai akurasi 85% dan Naïve Bayes 83% , dengan SVM lebih baik dalam mengklasifikasikan sentimen positif (recall 85%) dan Naïve Bayes sedikit unggul pada presisi.	<i>balancing</i> data dan model yang lebih kompleks untuk analisis sentimen pada aplikasi perbankan.
Binti Husna M; Gata W	Analisis Sentimen Terhadap Layanan Aplikasi Jenius di Media Sosial Menggunakan Algoritma Long Short-Term Memory	Penelitian ini menganalisis sentimen pengguna terhadap layanan aplikasi Jenius di YouTube menggunakan algoritma LSTM dan berhasil mencapai akurasi sebesar 93,57% pada data uji, yang menunjukkan keunggulan LSTM dalam menangani data teks sekuensial.	Penerapan LSTM yang lebih efektif dan komprehensif untuk data komentar YouTube, serta penggunaan teknik <i>pre-processing</i> dan penanganan ketidakseimbangan kelas yang belum banyak dioptimalkan pada penelitian sebelumnya.

3. Reporting the Review

Berdasarkan Tabel 2.1 atau tinjauan terhadap 14 penelitian yang relevan, terdapat tiga metode utama yang dominan digunakan dalam analisis sentimen terhadap aplikasi digital, yaitu Long Short-Term Memory (LSTM), Support Vector Machine (SVM), dan Naïve Bayes.

Metode LSTM menunjukkan performa yang konsisten tinggi dengan akurasi berkisar antara 85% hingga 93.57%. Keunggulan LSTM terletak pada kemampuannya dalam menangkap dependensi jangka panjang dan mengolah data sekuensial seperti teks. Namun demikian, sebagian besar penelitian belum mengeksplorasi arsitektur turunan LSTM yang lebih

kompleks seperti BiLSTM maupun penggunaan model *transformer* sebagai pembandingan.

Metode SVM masih menjadi pilihan populer dalam klasifikasi biner dengan performa yang stabil, tercatat memiliki akurasi di atas 80% dalam berbagai studi. Meskipun sederhana dibanding *deep learning*, SVM efektif untuk dataset dengan dimensi tinggi dan dapat memberikan margin klasifikasi yang optimal. Namun, keterbatasannya terlihat pada kasus data yang sangat kompleks atau tidak seimbang.

Metode Naïve Bayes digunakan karena kesederhanaannya dan kecepatan dalam pelatihan, serta cukup efektif dalam berbagai studi dengan akurasi sekitar 83–87%. Meskipun tidak seakurat LSTM, metode ini tetap relevan sebagai *baseline* atau alternatif saat *resources* terbatas.

Secara umum, masih ditemukan beberapa *research gap*, di antaranya:

- Kurangnya eksplorasi model lanjutan seperti *transformer*
- Minimnya evaluasi terhadap pendekatan *hybrid* atau *ensemble deep learning*
- Dataset yang terbatas pada domain tertentu dan belum mencakup data *multi-platform*
- Masih dominannya pendekatan biner dan kurangnya studi klasifikasi multikelas

Mempertimbangkan kekuatan dan kelemahan masing-masing metode serta *research gap* yang ada, penelitian ini menggunakan pendekatan komparatif antara SVM, Naïve Bayes, dan LSTM dalam analisis sentimen terhadap ulasan aplikasi digital perbankan untuk menentukan model yang paling optimal digunakan dalam konteks studi ini.

2.2 Teori Penelitian

2.2.1 Analisis Sentimen

Sentiment analysis merupakan salah satu teknik dalam NLP (Natural Language Processing) yang bertujuan mengenali serta mengelompokkan opini pengguna menjadi kategori seperti positif, negatif, atau netral. Metode ini banyak diterapkan di berbagai sektor, seperti pemasaran, perbankan, dan layanan pelanggan, guna memperoleh wawasan mendalam mengenai tingkat kepuasan serta persepsi pengguna terhadap suatu *brand* atau layanan [9].

2.2.2 Aplikasi Mobile Banking


Aplikasi perbankan digital atau *mobile banking* adalah platform yang memungkinkan pengguna mengakses layanan finansial melalui perangkat seluler, mencakup fitur seperti transfer uang, pembayaran, dan layanan pelanggan yang praktis [10].

2.2.3 Ulasan Pengguna

Ulasan pengguna adalah opini yang diberikan oleh pelanggan terhadap suatu layanan atau produk yang mereka gunakan. Dalam konteks aplikasi perbankan digital, ulasan pengguna dapat menjadi indikator kualitas layanan dan aspek yang perlu ditingkatkan oleh pengembang aplikasi [11].

2.2.4 Metode Support Vector Machine

SVM merupakan algoritma populer dalam *machine learning* yang sering dipakai dalam berbagai tugas klasifikasi, termasuk untuk mengolah data sentimen. Algoritma ini unggul dalam mengolah data berdimensi tinggi serta mampu menghasilkan klasifikasi yang optimal dengan menentukan *hyperplane* terbaik untuk memisahkan kelas data secara efektif [12]. SVM beroperasi dengan menentukan *hyperplane* optimal yang berfungsi sebagai batas pemisah antara berbagai kategori sentimen, seperti positif, negatif, atau netral sehingga memungkinkan klasifikasi lebih akurat [13].



Gambar 2. 1 Gambaran Model SVM (spotintelligence.com)

Gambar 2.1 menggambarkan dasar kerja dari algoritma SVM yang merupakan metode *supervised learning* untuk tugas klasifikasi. SVM beroperasi dengan menentukan sebuah *hyperplane* yang optimal untuk memisahkan dua kelas data secara maksimal. Dalam konteks dua dimensi, *hyperplane* ini berupa garis sedangkan pada dimensi lebih tinggi berbentuk bidang.

Dalam konteks gambar tersebut, terdapat tiga kelompok data yang direpresentasikan dengan warna berbeda (merah, hijau, dan biru), masing-masing menggambarkan kelas yang berbeda. SVM akan membentuk batas (*hyperplane*) sedemikian rupa sehingga jarak antar *hyperplane* dan titik data terdekat dari masing-masing kelas adalah maksimum. Beberapa titik yang berada paling dekat dengan *hyperplane* disebut *support vectors*, dan berperan penting dalam menentukan posisi *hyperplane* tersebut.


Penggunaan SVM dalam klasifikasi sentimen, seperti pada ulasan aplikasi Halo BCA, memungkinkan model untuk membedakan secara tegas antara ulasan dengan sentimen positif dan negatif berdasarkan fitur-fitur numerik dari representasi teks (misalnya menggunakan TF-IDF). Keunggulan SVM adalah kemampuannya dalam menangani data dengan dimensi tinggi dan menghasilkan generalisasi baik terhadap data baru.

Dalam konteks analisis sentimen, teks ulasan diubah dahulu menjadi representasi numerik seperti TF-IDF atau *word embedding* sebelum

diklasifikasikan menggunakan model SVM. Salah satu keunggulan utama SVM adalah kemampuannya dalam mengolah data yang tidak terstruktur serta mempertahankan akurasi tinggi, bahkan ketika menghadapi distribusi data yang tidak seimbang [14].

2.2.5 Metode Naïve Bayes

Naïve Bayes adalah algoritma klasifikasi berbasis probabilistik yang sering diterapkan dalam analisis sentimen karena kesederhanaan serta efisiensinya dalam mengolah data teks berukuran besar [15]. Algoritma ini beroperasi dengan mengadopsi Teorema Bayes untuk menghitung probabilitas suatu kategori sentimen baik positif, negatif, maupun netral berdasarkan distribusi kata yang terdapat dalam teks ulasan [16].



Gambar 2. 2 Gambaran Model Naïve Bayes (pemrogramanmatlab.com)

Pada Gambar 2.2 merupakan visualisasi konsep dasar dari algoritma Naïve Bayes Classifier dalam proses klasifikasi. Naïve Bayes bekerja dengan prinsip probabilitas Bayes yang mengasumsikan bahwa tiap fitur bersifat independen dan menentukan kelas suatu data berdasarkan kemungkinan distribusi fitur tersebut. Pada visualisasi tersebut, terdapat tiga kelompok data yang direpresentasikan dengan warna berbeda: merah (Classifier 1), oranye (Classifier 2), dan biru (Classifier 3). Garis-garis kurva yang memisahkan tiap kelompok merupakan batas keputusan (decision boundary) yang dihasilkan oleh

model Naïve Bayes berdasarkan probabilitas kemunculan fitur pada setiap kelas. Naïve Bayes menghitung peluang suatu titik data berada dalam sebuah kelas, dan menentukan prediksi berdasarkan nilai probabilitas tertinggi.


Dalam konteks penelitian ini yang berkaitan dengan klasifikasi sentimen ulasan aplikasi Halo BCA, Naïve Bayes dimanfaatkan untuk mengklasifikasikan tiap ulasan menjadi salah satu dari dua kategori sentimen, yakni positif atau negatif. Meskipun asumsi independensi antar fitur dalam teks tidak selalu terpenuhi, Naïve Bayes tetap populer dalam analisis sentimen karena kesederhanaan, efisiensi komputasi, dan performa yang cukup baik pada data teks, terutama ketika jumlah fitur besar seperti hasil ekstraksi TF-IDF

Pada penelitian ini, Naïve Bayes digunakan untuk mengklasifikasikan sentimen pada ulasan pengguna Halo BCA yang telah dikonversi menjadi fitur numerik melalui TF-IDF atau *Bag of Words*. Keunggulan algoritma ini terletak pada kecepatannya serta kemampuannya dalam menghasilkan klasifikasi yang cukup baik meskipun berbasis asumsi sederhana [17].

2.2.6 Metode LSTM

LSTM adalah arsitektur jaringan neural yang berasal dari keluarga Recurrent Neural Network (RNN) untuk menangani data sekuensial seperti teks yang digunakan dalam analisis sentimen. Berbeda dengan pendekatan konvensional seperti Naïve Bayes atau SVM, LSTM memiliki mekanisme memori jangka pendek dan jangka panjang yang memungkinkannya menangkap serta mempertahankan konteks kata dalam ulasan dengan lebih efektif. Hal ini menjadikan LSTM lebih unggul dalam memahami pola hubungan antar kata, sehingga

meningkatkan akurasi dalam klasifikasi sentimen [18].



Gambar 2. 3 Gambaran Model LSTM (medium.com)

Gambar 2.3 menampilkan struktur internal LSTM, yang merupakan tipe RNN khusus dalam menangani masalah dependensi jangka panjang dalam data sekuensial, contohnya teks. Tidak seperti RNN standar, LSTM memiliki struktur yang lebih kompleks dengan tiga gerbang utama, yaitu Forget Gate, Input Gate, dan Output Gate, yang memungkinkan model dapat mempertahankan, memperbarui, atau membuang informasi secara selektif dari memori sel.

- Forget Gate (F_t): Gerbang ini menentukan informasi mana yang akan dilupakan dari memori sel sebelumnya (C_{t-1}). Nilai F_t dihitung menggunakan fungsi aktivasi sigmoid (σ) yang menerima masukan dari input saat ini (X_t) dan hidden state sebelumnya (H_{t-1}).
- Input Gate (I_t) dan Candidate Memory ($\tilde{C}_t$): Komponen Input Gate bertugas mengatur informasi baru mana yang layak disimpan dalam unit memori. Nilai I_t juga dihitung menggunakan fungsi sigmoid, sedangkan $\tilde{C}_t$ dihasilkan dari fungsi aktivasi tanh. Perkalian $I_t * \tilde{C}_t$ menghasilkan informasi baru yang akan ditambahkan ke dalam memori sel.

- Memori Sel (C_t): Kombinasi antara $F_t * C_{t-1}$ dan $I_t * \hat{C}_t$ menghasilkan memori sel terkini C_t , yaitu memori yang telah diperbarui sesuai informasi penting.
- Output Gate (O_t) dan Hidden State (H_t): Output Gate berfungsi menentukan bagian informasi dari memori yang akan diteruskan sebagai hasil keluaran ke langkah waktu berikutnya. O_t dihitung menggunakan sigmoid, dan dikalikan dengan $\tanh(C_t)$ untuk menghasilkan H_t , yaitu *hidden state* saat ini yang juga menjadi *output* dari LSTM.

Struktur ini menjadikan LSTM sangat efektif dalam mengolah teks, karena dapat menyimpan konteks jangka panjang dengan stabil. Dalam penelitian ini, arsitektur LSTM digunakan untuk melakukan klasifikasi sentimen ulasan pengguna aplikasi Halo BCA. Meskipun hasil akurasi yang diperoleh tidak sebaik SVM dan Naïve Bayes, LSTM tetap menjadi salah satu metode yang relevan karena kemampuannya dalam menangkap konteks kata dalam kalimat secara berurutan.

Dalam analisis sentimen ulasan aplikasi Halo BCA, LSTM dapat digunakan untuk mengenali pola bahasa dan hubungan antar kata dalam teks ulasan, sehingga menghasilkan klasifikasi sentimen yang lebih akurat. Bantuan teknik Word Embedding seperti Word2Vec atau GloVe, LSTM dapat mempelajari representasi kata yang lebih bermakna, memungkinkan model menangkap sentimen positif, negatif, atau netral dengan lebih baik dibandingkan metode berbasis probabilitas atau pohon keputusan [19].

2.2.7 Teknik Preprocessing Data

Dalam analisis sentimen, proses *preprocessing* data mencakup serangkaian tahapan penting, seperti *case folding*, tokenisasi, penghapusan *stopword*, *stemming*, serta pembobotan menggunakan Term Frequency-Inverse Document Frequency (TF-IDF). Setiap tahapan dalam arsitektur ini dirancang untuk menyaring dan mempertahankan

informasi penting dari teks, sehingga mampu meningkatkan performa klasifikasi sentimen [20].

2.2.8 Synthetic Minority Oversampling Technique (SMOTE)

SMOTE merupakan metode *oversampling* yang digunakan untuk mengatasi masalah ketidakseimbangan data, khususnya ketika jumlah data pada kelas minoritas jauh lebih sedikit dibanding kelas mayoritas. SMOTE bekerja dengan cara membuat data sintetis baru pada kelas minoritas berdasarkan k-nearest neighbors dari data minoritas asli. Proses ini menghasilkan sampel tambahan yang bervariasi, bukan hanya menggandakan data yang ada, sehingga dapat mengurangi risiko *overfitting* [21]. Penyeimbangan distribusi kelas, SMOTE membantu meningkatkan performa model klasifikasi dalam mengenali kelas minoritas secara lebih akurat. Metode ini telah banyak digunakan dalam berbagai penelitian untuk meningkatkan akurasi dan kualitas prediksi pada dataset yang tidak seimbang

2.3 Framework dan Algoritma Penelitian

2.3.1 CRISP-DM (Cross-Industry Standard Process for Data Mining)

CRISP-DM merupakan kerangka kerja standar dalam *data mining*, terdiri dari enam tahapan, yaitu pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, dan implementasi.



Gambar 2. 4 Tahapan CRISP-DM (dicoding.com)

Kerangka pada Gambar 2.4 ini dirancang untuk memastikan bahwa setiap tahapan analisis berjalan secara terstruktur dan sistematis sehingga hasil yang diperoleh dapat diandalkan [22].

2.3.2 Support Vector Machine

SVM adalah algoritma dalam *supervised learning* yang sangat efektif dalam klasifikasi dan regresi. Dalam analisis sentimen, SVM digunakan untuk memisahkan kelas data dengan memaksimalkan margin pada ruang multidimensi. Dalam konteks analisis sentimen, SVM memanfaatkan teknik representasi fitur seperti Term Frequency-Inverse Document Frequency (TF-IDF) untuk mengubah teks ulasan menjadi vektor numerik dan nantinya diklasifikasikan ke dalam kategori sentimen positif, negatif, atau netral. Keunggulan utama SVM terdapat pada kemampuannya dalam menangani data teks kompleks serta memberikan akurasi tinggi, bahkan saat diterapkan pada dataset berskala besar [23]. Pada sebagian besar penelitian terdahulu cenderung hanya membandingkan kinerja SVM dengan satu metode lain, sehingga kurang memberikan gambaran menyeluruh terhadap performa algoritma dalam konteks yang beragam. Selain itu, penelitian sebelumnya juga masih terbatas dalam mengeksplorasi integrasi SVM dengan pendekatan berbasis *deep learning* seperti LSTM, yang memiliki kemampuan menangkap konteks urutan kata dalam teks, serta metode statistik seperti Naive Bayes yang dikenal efektif dalam klasifikasi teks berbasis probabilistik [24]. Oleh karena itu, penelitian ini melakukan perbandingan antara SVM, LSTM, dan Naïve Bayes untuk mengevaluasi seberapa efektif masing-masing metode dalam melakukan analisis sentimen terhadap ulasan pengguna aplikasi.

2.3.3 Naïve Bayes

Algoritma klasifikasi berbasis probabilitas yang bekerja dengan menerapkan Teorema Bayes [15]. Naïve Bayes kerap digunakan dalam pemrosesan data teks berskala besar karena efisien dan mampu menghasilkan hasil klasifikasi yang layak meski didasarkan pada asumsi

fitur yang saling bebas [25]. Kecepatan dalam pelatihan model dan interpretasi sederhana menjadikan Naïve Bayes sebagai pilihan populer dalam berbagai studi awal klasifikasi teks. Pada banyak penelitian terdahulu yang hanya membatasi evaluasi Naïve Bayes terhadap metode sejenis berbasis statistik, tanpa membandingkannya dengan pendekatan yang lebih kompleks seperti LSTM yang berbasis *deep learning* atau metode SVM yang memiliki keunggulan dalam menangani data berdimensi tinggi. Hal ini menciptakan kesenjangan dalam pemahaman mengenai kelebihan dan kekurangan masing-masing algoritma dalam konteks yang sama. Oleh karena itu, penelitian ini mengikutsertakan perbandingan antara Naïve Bayes, LSTM, dan SVM untuk memberikan gambaran menyeluruh terkait performa model dalam melakukan analisis sentimen terhadap data ulasan aplikasi.

2.3.4 Long Short – Term Memory (LSTM)

LSTM adalah jenis Recurrent Neural Network (RNN) untuk mengatasi permasalahan dalam memproses data sekuensial, seperti teks pada analisis sentimen. LSTM memiliki memori jangka panjang dan pendek yang memungkinkan model untuk memahami hubungan antar kata dalam ulasan pengguna secara lebih mendalam. Dalam penelitian ini, LSTM digunakan untuk menganalisis sentimen ulasan aplikasi Halo BCA dengan pendekatan berbasis Word Embedding, seperti Word2Vec atau GloVe, yang memungkinkan model untuk mengenali makna kata dalam berbagai konteks. Keunggulan utama LSTM dibandingkan metode lain adalah kemampuannya dalam menangkap dependensi jangka panjang dalam teks, sehingga dapat menghasilkan klasifikasi sentimen yang lebih akurat [26]. Pada sebagian besar penelitian terdahulu masih terbatas dalam mengimplementasikan LSTM secara komprehensif, atau hanya membandingkan kinerjanya dengan algoritma *non-deep learning* seperti Naïve Bayes atau SVM secara terpisah sehingga memberikan kesenjangan dalam pemahaman mengenai efektivitas relatif ketiga metode tersebut bila diterapkan pada dataset yang sama. Perbandingan

ketiga metode Naïve Bayes, SVM, dan LSTM dalam konteks analisis sentimen ulasan aplikasi maka dapat memberikan evaluasi lebih menyeluruh terhadap kelebihan dan kekurangan masing-masing pendekatan.

Pemilihan ketiga metode ini dilakukan berdasarkan hasil studi literatur terdahulu serta karakteristik data teks ulasan pengguna yang umumnya memiliki bentuk yang tidak terstruktur, panjang yang bervariasi, serta kandungan opini yang kompleks.

Tabel 2. 2 Perbandingan Metode

Algoritma	Kelebihan	Kelemahan	Cocok
LSTM	Mampu menangkap konteks dan urutan kata, akurasi tinggi pada data sekuensial	Butuh komputasi besar, <i>training</i> lama, sensitif terhadap parameter	Teks panjang dan kompleks, opini bernuansa, analisis mendalam
Naive Bayes	Cepat dan ringan, efektif untuk dataset besar, sederhana	Asumsi independensi fitur terlalu kuat, kurang akurat untuk data kompleks	Teks pendek dengan pola yang umum, klasifikasi cepat, <i>baseline</i> model
SVM	Akurat pada data berdimensi tinggi, mampu menangani data dengan margin sempit	Akurat pada data berdimensi tinggi, mampu menangani data dengan margin sempit	Teks sedang hingga panjang, cocok untuk teks berpola atau berstruktur jelas

Pada Tabel 2.2 merangkum perbandingan antara ketiga metode yang digunakan pada penelitian ini dan dengan menggabungkan ketiga pendekatan ini diharapkan penelitian dapat mengevaluasi performa masing-masing metode secara adil dan menyeluruh, serta mengidentifikasi pendekatan terbaik yang dapat digunakan dalam implementasi nyata sistem analisis sentimen.

2.4 Tools dan Software Penelitian

2.4.1 Python

Python adalah bahasa pemrograman yang banyak digunakan dalam analisis data dan pembelajaran mesin. Bahasa ini memiliki berbagai pustaka yang mendukung pemrosesan teks dan analisis sentimen, seperti Scikit-learn, Pandas, dan NLTK [27].

2.4.2 Jupyter Notebook

Jupyter Notebook adalah lingkungan interaktif berbasis web yang digunakan untuk menjalankan kode Python. Alat ini memudahkan eksplorasi data, pembuatan model, serta visualisasi hasil analisis secara langsung dalam satu antarmuka [28].

2.4.3 Scikit-Learn

Scikit-learn merupakan pustaka Python yang umum digunakan dalam pembelajaran mesin, menyediakan beragam algoritma untuk klasifikasi, regresi, dan pengelompokan data. Dalam penelitian ini, pustaka tersebut digunakan untuk menerapkan model SVM dan Naïve Bayes [29].

2.4.4 NLTK (Natural Language Toolkit)

NLTK adalah salah satu *library* Python yang umum digunakan dalam pemrosesan teks, termasuk untuk analisis sentimen, dan menyediakan berbagai *tools* seperti tokenisasi, *stemming*, serta penghapusan *stopword* [30].