

BAB II

LANDASAN TEORI

2.1 Penelitian Terdahulu

Penelitian analisis sentimen pada fitur LAKSA aplikasi Tangerang LIVE yang dilakukan diperkuat oleh tinjauan literatur yang terfokus pada 10 jurnal referensi utama yang relevan, yang dipublikasikan dalam kurun waktu 5 tahun terakhir (2021-2025). Analisis terhadap referensi-referensi kunci ini menunjukkan adanya dua fokus utama dalam penelitian terkait. Lima jurnal secara spesifik melakukan studi komparatif untuk membandingkan secara langsung kinerja algoritma *Random Forest* dan *Support Vector Machine* (SVM) dalam menentukan model terbaik. Sementara itu, lima jurnal lainnya menunjukkan penerapan praktis analisis sentimen di berbagai domain penting, seperti layanan pemerintah, ulasan e-commerce, dan kepuasan pelanggan.

Tabel 2.1 10 Penelitian terdahulu

Jurnal 1 [16]	
Nama Jurnal	Informatics
Volume	10
Nomor	4
Tahun	2023
Judul	Classifying Crowdsourced Citizen Complaints through Data Mining: Accuracy Testing of k-Nearest Neighbors, Random Forest, Support Vector Machine, and AdaBoost
Penulis	Evaristus D. Madyatmadja, Corinthias P. M. Sianipar, Cristofer Wijaya, David J. M. Sembiring
Permasalahan	Kesulitan pemerintah dalam mengklasifikasikan data keluhan warga yang besar dan tidak terstruktur.
Hasil penelitian	<ol style="list-style-type: none"> 1. Menggunakan beberapa algoritma, diantaranya : <ol style="list-style-type: none"> 1) SVM (Linear (89,2%), Polynomial (88,4%), Sigmoid (88,4%), RBF (88,1%)) 2) <i>Random Forest</i> (86,2%) 3) kNN (85,5%) 4) AdaBoost (83,1%) 2. Algoritma SVM dengan kernel Linear memiliki akurasi tertinggi dikarenakan karakteristik data keluhan teks yang telah diproses melalui TF-IDF cenderung memiliki dimensi tinggi, sehingga pola antar kategori lebih mudah dipisahkan secara linear. Kernel ini bekerja lebih efektif dalam

	menemukan batas keputusan yang tegas dibandingkan kernel lainnya, serta mampu memberikan hasil prediksi yang lebih stabil dan akurat tanpa mengalami <i>overfitting</i> pada dataset tersebut.
Faktor pendukung	Penggunaan dataset dunia nyata berupa data keluhan publik yang dikumpulkan dari aplikasi LAKSA dalam rentang waktu satu tahun (Mei 2021 s.d April 2022).
Research gap	<ol style="list-style-type: none"> 1. Periode data yang digunakan dari Mei 2022 hingga April 2022 2. Setelah melewati tahap filtrasi, total distribusi data yang digunakan sebanyak 5.056 rows data pengaduan
Jurnal 2 [17]	
Nama Jurnal	Jurnal TEKNO KOMPAK
Volume	20
Nomor	1
Tahun	2021
Judul	Klasifikasi Sentimen Ulasan Pengguna Aplikasi Layanan Publik Google Play Store Menggunakan NLP dan ML
Penulis	Evaristus Dwi Shafira Akbar Rizki, Muhammad Syaiful Khabib, Novita Rahmayuna, dan Victor Gayuh Utomo. D. Madyatmadja, Corinthias P. M. Sianipar, Cristofer Wijaya, David J. M. Sembiring
Permasalahan	Desakan mengevaluasi layanan publik digital di Indonesia (studi kasus: aplikasi MyICON+) secara berbasis data.
Hasil penelitian	<ol style="list-style-type: none"> 1. Support Vector Machine (SVM) memberikan performa terbaik dengan akurasi 97% dan macro F1-score 0,87. 2. Random Forest berada di posisi kedua dengan akurasi 95% (F1-score 0,80),
Faktor pendukung	Metodologi kuantitatif eksperimental dengan desain komparatif dimana penelitian ini menggunakan dataset 2.000 ulasan berbahasa Indonesia yang dikumpulkan dari Google Play Store melalui <i>web scraping</i> . Alur kerja teknisnya mencakup pra-pemrosesan teks (seperti <i>stemming</i> menggunakan pustaka Sastrawi) dan penggunaan TF-IDF sebagai metode representasi fitur, sebelum akhirnya membagi data 80% latih dan 20% uji untuk dievaluasi dengan berbagai metrik (Akurasi, <i>Precision</i> , <i>Recall</i> , F1-score).
Research gap	Pengaduan berasal dari aplikasi layanan BUMN (MyICON+)
Jurnal 3 [18]	
Nama Jurnal	Jurnal MNEMONIC

Volume	7
Nomor	1
Tahun	2024
Judul	ANALISIS SENTIMEN TERHADAP LAYANAN SAMSAT DIGITAL NASIONAL (SIGNAL) MENGGUNAKAN METODE SVM
Penulis	Slamet Kacung, Caesare Pamungkas Putra Bagyana, Dwi Cahyono
Permasalahan	Kegagalan verifikasi wajah, KTP, OTP, dan <i>bug</i> aplikasi yang berujung pada kegagalan transaksi merupakan kendala yang dialami pengguna aplikasi layanan publik Samsat Digital Nasional (SIGNAL).
Hasil penelitian	SVM dengan kernel Linear menghasilkan akurasi tertinggi, yaitu 96.19% (pada rasio 70:30). Menariknya, saat dievaluasi menggunakan <i>K-Fold Cross Validation</i> , kernel RBF menunjukkan akurasi rata-rata yang sedikit lebih tinggi dan stabil, yaitu 97.86% , dibandingkan dengan kernel Linear (97.65%). Kernel Polynomial menunjukkan kinerja terendah.
Faktor pendukung	Berfokus pada satu algoritma yakni SVM dan membandingkan tiga <i>kernel</i> utama (Linear, RBF, dan Polynomial)
Research gap	<ol style="list-style-type: none"> 1. Hanya berfokus pada SVM 2. Hanya sampai tahap rekomendasi <i>kernel</i> terbaik
Jurnal 4 [19]	
Nama Jurnal	Applied Science
Volume	12
Nomor	5547
Tahun	2022
Judul	An Improved Sentiment Classification Approach for Measuring User Satisfaction toward Governmental Services' Mobile Apps Using Machine Learning Methods with Feature Engineering and SMOTE Technique
Penulis	M. Hadwan, M. Al-Sarem, F. Saeed, dan M.A. Al-Hagery.
Permasalahan	Sebagian besar penelitian ASA yang ada berfokus pada data Twitter, sementara sangat sedikit perhatian diberikan pada data ulasan (<i>review</i>) untuk aplikasi seluler pemerintah di Google Play atau App Store.
Hasil penelitian	SVM berhasil mencapai akurasi 94.38%
Faktor pendukung	Mengkombinasikan teknik <i>oversampling</i> SMOTE dengan penggunaan fitur gabungan dari berbagai metode <i>feature engineering</i> .
Research gap	Fokus linguistik dan domain jurnal pada Analisis Sentimen Arab (ASA) di Arab Saudi
Jurnal 5 [20]	

Nama Jurnal	ILKOM Jurnal Ilmiah
Volume	15
Nomor	3
Tahun	2023
Judul	Sentiment Analysis of Shopee App Reviews Using Random Forest and Support Vector Machine
Penulis	Suswadi, Moh. Erkamim
Permasalahan	Kebutuhan untuk mengevaluasi fitur dan layanan aplikasi <i>e-commerce</i> (Shopee) yang penggunaannya meningkat secara signifikan pasca pandemi sehingga lebih memahami persepsi positif dan negatif masyarakat
Hasil penelitian	<ol style="list-style-type: none"> 1. SVM dengan akurasi 84.71% 2. Melalui analisis frekuensi kata ditemukan sentimen negatif yang banyak dikeluhkan adalah “ongkir” (biaya pengiriman) dan “aplikasi” (<i>error</i> pada sistem atau aplikasi)
Faktor pendukung	Tahap eksplorasi data melalui frekuensi kata untuk mengidentifikasi topik utama keluhan dan pujian
Research gap	Domain penelitian merupakan <i>e-commerce</i> (Shopee)
Jurnal 6 [21]	
Nama Jurnal	Algorithms
Volume	17
Nomor	459
Tahun	2024
Judul	From conflicts and confusion to doubts: Examining review inconsistency for fake review detection
Penulis	Deepali Goyal Dev dan Vishal Bhatnagar.
Permasalahan	Penyebaran informasi palsu (<i>fake news</i>) dan rumor yang sangat mudah melalui komunitas internet, yang memberikan dampak sangat buruk bagi masyarakat. Sehingga dalam penelitian diupayakan untuk mengatasi tantangan dalam mendeteksi berita palsu di media sosial secara otomatis, yang merupakan topik penelitian yang sedang berkembang pesat.
Hasil penelitian	model hibrida yang menggabungkan Random Forest dan SVM secara signifikan mengungguli model-model murni lainnya (termasuk RF, SVM, <i>Naive Bayes</i> , dan XGBoost). Peningkatan kinerja yang dicapai oleh model hibrida dilaporkan sangat besar, yaitu sekitar 8% hingga 16% dalam hal <i>accuracy</i> , <i>precision</i> , <i>recall</i> , dan <i>F1-score</i> .
Faktor pendukung	Metodologi hibridisasi algoritma
Research gap	<ol style="list-style-type: none"> 1. Berfokus pada deteksi berita palsu 2. Berfokus pada berita palsu di Internet 3. Berbahasa inggris
Jurnal 7 [22]	

Nama Jurnal	International Journal of Information Management Data Insights
Volume	1
Nomor	100019
Tahun	2021
Judul	Sentiment analysis and classification of Indian farmers' protest using twitter data
Penulis	Ashwin Sanjay Neogi, Kirti Anilkumar Garga, Ram Krishn Mishraa, Yogesh K Dwivedi b
Permasalahan	Kebutuhan untuk memahami sentimen dan opini publik di media sosial (X) mengenai isu sosial-politik yang penting mengenai protes petani di India.
Hasil penelitian	Random Forest (RF) memberikan akurasi klasifikasi tertinggi dibandingkan dengan algoritma lain yang diuji (SVM, <i>Naive Bayes</i> , <i>Decision Trees</i>). Selain itu, dalam hal <i>feature engineering</i> , <i>Bag of Words</i> (BoW) ditemukan memiliki kinerja yang lebih baik daripada TF-IDF. Secara kontekstual, analisis menemukan bahwa sentimen mayoritas dari tweet adalah Netral (46%), diikuti oleh Positif (29%) dan Negatif (17%).
Faktor pendukung	Penggunaan dataset dunia nyata yang dikumpulkan dari X
Research gap	<ol style="list-style-type: none"> 1. Sumber data dan domain yang berbeda 2. Penelitian hanya sampai pada tahap analisis dan rekomendasi model
Jurnal 8 [23]	
Nama Jurnal	Electrical and Electronics Engineers (IEEE) Access
Volume	9
Nomor	-
Tahun	2021
Judul	Emotion Recognition by Textual Tweets Classification Using Voting Classifier (LR-SGD)
Penulis	Anam Yousaf, Muhammad Umer, Saima Sadiq, Saleem Ullah, Seyedali Mirjalili, Vaibhav Rupapara, Michele Nappi
Permasalahan	<ol style="list-style-type: none"> 1. Sulit melakukan <i>opinion mining</i> pada X karena besarnya volume 2. Kebutuhan untuk mengklasifikasikan tweet sebagai tweet “<i>happy</i>” atau “<i>unhappy</i>”
Hasil penelitian	<i>Voting Classifier</i> (VC) baru yang menggabungkan <i>Logistic Regression</i> (LR) dan <i>Stochastic Gradient Descent</i> (SGD). Model <i>custom</i> VC(LR-SGD) ini terbukti mencapai hasil paling optimal dengan akurasi 79% dan <i>F1-score</i> 81% (menggunakan TF-IDF), mengungguli enam model standar lainnya termasuk SVM dan <i>Random Forest</i> .

Faktor pendukung	metodologi perbandingan yang sangat menyeluruh. Studi ini secara sistematis menguji dan membandingkan kinerja tujuh model <i>machine learning</i> yang berbeda (termasuk SVM dan <i>Random Forest</i>), serta dua teknik <i>feature representation</i> (TF dan TF-IDF). Proposal dan validasi model <i>ensemble</i> (<i>Voting Classifier</i>) baru menjadi kontribusi metodologis utama yang mengarah pada hasil penelitian.
Research gap	<ol style="list-style-type: none"> 1. Tujuan penelitian untuk mengklasifikasikan sentimen “<i>happy</i>” dan “<i>unhappy</i>” 2. Penelitian berfokus ke pengembangan model <i>ensemble</i>
Jurnal 9 [24]	
Nama Jurnal	Journal of Applied Data Sciences
Volume	6
Nomor	1
Tahun	2025
Judul	Deep Learning-based Text Classification: A Comprehensive Review
Penulis	Irfan Santiko, Tri Retnaningsih Soeprbowati, Bayu Surarso, Imam Tahyudin, Zainal Arifin Hasibuan, dan Ahmad Naim Che Pee.
Permasalahan	pola penilaian prestasi belajar di pendidikan tinggi yang dinilai kurang fokus. Hal ini disebabkan oleh kompleksitas komponen penilaian yang ada saat ini, yang mencakup berbagai elemen seperti VARK, kondisi lingkungan, dan efektivitas pengajar. Penelitian ini berupaya mengatasi masalah tersebut dengan menawarkan kerangka kerja penilaian inovatif yang lebih sederhana (disebut “3M”) namun tetap multidimensional (disebut “TEMUS”).
Hasil penelitian	<i>Random Forest</i> (RF) memberikan hasil yang paling optimal secara keseluruhan, dengan nilai Akurasi 0.86, <i>R-Square</i> 0.99, dan MSE 0.46, mengungguli SVM, <i>Decision Tree</i> , dan KNN.
Faktor pendukung	<ol style="list-style-type: none"> 1. Metodologi studi komparatif 2. Penggunaan dataset primer
Research gap	<ol style="list-style-type: none"> 1. Berfokus pada klasifikasi gaya belajar pendidikan tinggi 2. Hanya sampai perbandingan model
Jurnal 10 [25]	
Nama Jurnal	Literatur Informatika & Komputer (LINIER)
Volume	2
Nomor	2
Tahun	2025

Judul	Analisis Sentimen Pengguna Gojek Berdasarkan Ulasan pada App Store dengan Metode KNN, Naive Bayes, dan SVM
Penulis	Arif Kurniaa, Harlinda, dan Herdianti Darwis.
Permasalahan	Adanya kebutuhan untuk mengevaluasi dan meningkatkan layanan <i>on-demand</i> Gojek yang memiliki jutaan ulasan pengguna di <i>App Store</i> . Ulasan dalam jumlah besar merupakan informasi penting yang sulit diolah secara manual sehingga dilakukan penelitian untuk menemukan metode <i>machine learning</i> yang paling efektif untuk menganalisis dan mengklasifikasikan sentimen pengguna Gojek secara otomatis ke dalam lima kelas sentimen dari mulai “sangat puas” hingga “sangat buruk”
Hasil penelitian	<i>Support Vector Machine</i> (SVM) secara konsisten mengungguli metode lain. Secara spesifik, SVM dengan kernel Linear terbukti mencapai akurasi tertinggi (79.00%), sementara SVM dengan kernel RBF mencatatkan presisi tertinggi (83.85%). Kinerja ini melampaui <i>Naive Bayes</i> (akurasi 78.00%) dan KNN (akurasi 69.25%). Hasil ini menegaskan bahwa SVM adalah metode yang paling andal untuk klasifikasi sentimen multi-kelas pada ulasan aplikasi layanan.
Faktor pendukung	Metodologi studi komparatif yang membandingkan tiga algoritma <i>machine learning</i> (KNN, <i>Naive Bayes</i> , dan SVM). Keunikan dari penelitian ini adalah pendekatannya pada klasifikasi multi-kelas (lima kelas sentimen), bukan hanya biner. Kinerja model dievaluasi secara komprehensif menggunakan berbagai metrik (<i>accuracy</i> , <i>precision</i> , <i>recall</i> , <i>F1-score</i>) dan didukung oleh analisis eksplorasi data (EDA) seperti <i>word cloud</i> untuk mengidentifikasi topik yang paling sering dibahas pengguna (misal: “ <i>driver</i> ”, “ <i>aplikasi</i> ”).
Research gap	Domain penelitian merupakan data layanan komersial

Dari penelitian-penelitian sebelumnya, telah disusun kerangka penelitian untuk menganalisis sentimen pada aplikasi pemerintah daerah. Berbagai studi yang telah diulas menunjukkan bahwa analisis sentimen merupakan alat yang sangat berguna untuk memahami opini publik di berbagai domain. Sejumlah penelitian secara konsisten menunjukkan bahwa meskipun ada banyak metode, algoritma *machine learning* seperti *Support Vector Machine* (SVM) secara signifikan dan berulang kali mengungguli *Random Forest* dalam hal akurasi pada berbagai jenis dataset. Temuan ini memberikan wawasan berharga bahwa pemilihan algoritma yang tepat

sangat krusial untuk menghasilkan analisis yang andal dan dapat digunakan untuk pengambilan keputusan yang lebih baik.

Pembeda utama dari penelitian-penelitian sebelumnya terletak pada data pengaduan yang digunakan yakni dari aplikasi terpusat milik pemerintah daerah, Tangerang LIVE khususnya fitur LAKSA. Selain itu, periode dan jumlah data yang digunakan juga menjadi pembeda penelitian ini dengan penelitian sebelumnya. Jika penelitian lain berfokus pada ulasan suatu aplikasi atau analisis pada domain umum, studi ini bertujuan untuk memberikan bukti berbasis data secara langsung kepada Diskominfo. Kontribusi berharga dari penelitian ini adalah menguji SVM dan *Random Forest* tetap berlaku pada korpus data pengaduan layanan publik yang unik, serta menyediakan model terbaik yang siap digunakan. Dengan demikian, penelitian ini memberikan pemahaman yang lebih dalam dan solusi yang terfokus untuk meningkatkan responsivitas layanan publik di Kota Tangerang.

2.2 Teori yang berkaitan

2.2.1 Teori *Smart City*

Kota pintar (*smart city*) akan memanfaatkan teknologi informasi dan komunikasi (TIK) untuk membantu peningkatan manajemen perkotaan, memperbaiki layanan publik, dan meningkatkan keterlibatan warga [26]. Konsep kota pintar kini berevolusi dari solusi berbasis TIK hingga menjadi cakupan tata kelola, keberlanjutan, dan urbanisasi yang layak [27]. Tata kelola di kota pintar dapat diprogramkan ke dalam struktur algoritma, sehingga menciptakan bentuk baru dari "tata kelola oleh teknologi pintar" [28]. Karakteristik utama kota pintar meliputi ekonomi pintar (*smart economy*), masyarakat pintar (*smart people*), tata kelola pintar (*smart governance*), mobilitas pintar (*smart mobility*), lingkungan pintar (*smart environment*), dan gaya hidup pintar (*smart living*) [29].

2.2.2 Teori *e-Government*

e-government di implementasikan untuk membantu meningkatkan layanan publik, transparansi, dan keterlibatan warga melalui platform digital. Aplikasi Tangerang Live di Indonesia menunjukkan implementasi yang sukses, dengan

mencapai tingkat kepuasan pengguna dan penyelesaian pengaduan yang tinggi [30]. Namun, *e-government* menghadapi berbagai tantangan seperti infrastruktur yang tidak memadai, risiko keamanan siber, dan resistansi dari sisi organisasi [31]. Pembangunan *e-government* di Indonesia tertinggal dibandingkan negara-negara ASEAN lainnya karena adanya hambatan regulasi, infrastruktur, dan budaya [32]. Untuk meningkatkan efektivitas *e-government*, integrasi teknologi baru seperti media sosial, layanan seluler, dan e-participation (partisipasi elektronik) sangatlah penting [33].

2.2.3 Teori Super app

Super App adalah aplikasi seluler yang mengintegrasikan berbagai layanan yang tidak saling berhubungan ke dalam satu *platform*, yang menawarkan kemudahan dan efisiensi bagi pengguna [34]. Adopsi *Super App* dipengaruhi oleh manfaat hedonis, utilitarian, dan sosial, dengan kepuasan dan keterlibatan pengguna memainkan peran mediasi [34]. *Super App Transportasi (Transport Super Apps* atau TSA) di Indonesia telah berevolusi dengan menambahkan berbagai fungsi di luar transportasi, di mana layanan belanja dan pembayaran menjadi populer di kalangan pengguna [35].

2.2.4 Teori Analisis Sentimen

Analisis sentimen, sebuah cabang dari *Natural Language Processing* (NLP), berfokus pada ekstraksi dan kuantifikasi opini dari data teks [36]. Analisis ini bertujuan untuk menentukan polaritas opini yang diekspresikan, apakah positif, negatif, atau netral [37]. Teknik analisis sentimen mendapatkan perhatian besar dalam menganalisis konten media sosial, khususnya data Twitter, untuk memahami opini publik tentang berbagai topik [38].

2.2.5 Teori Positif

Menurut Kamus Besar Bahasa Indonesia (KBBI), kata "positif" didefinisikan sebagai keadaan yang bersifat nyata dan membangun, serta menunjukkan adanya kepastian atau ketegasan dalam suatu pernyataan. Dalam konteks linguistik dan komunikasi, istilah positif sering diasosiasikan dengan kalimat yang mengandung persetujuan, dukungan, atau optimisme, yang

ditandai dengan tidak adanya penyangkalan. Relevansi kata positif dalam penelitian analisis sentimen pada fitur LAKSA berada pada bagian kategori sentimen positif yang merepresentasikan laporan masyarakat yang berisi apresiasi, kepuasan, atau dukungan konstruktif terhadap kinerja pemerintah dan layanan publik. Kata-kata seperti "terima kasih", "bagus", "cepat", dan "puas" menjadi indikator leksikal utama yang mencerminkan makna membangun sesuai definisi tersebut, menandakan bahwa layanan yang diterima masyarakat telah memenuhi atau melampaui ekspektasi

2.2.6 Teori Negatif

Dalam Kamus Besar Bahasa Indonesia (KBBI) mendefinisikan kata "negatif" sebagai sesuatu yang kurang baik, menyimpang dari ukuran umum, atau menunjukkan ketidakpastian. Definisi ini juga mencakup keadaan yang tidak pasti atau tanpa pernyataan tegas yang mendukung. Dalam kerangka penelitian analisis sentimen pengaduan publik, sentimen negatif diterjemahkan sebagai ekspresi ketidakpuasan, kekecewaan, atau kritik masyarakat terhadap kondisi layanan yang dianggap menyimpang dari standar yang diharapkan. Laporan yang diklasifikasikan ke dalam kategori ini umumnya mengandung keluhan mengenai kerusakan infrastruktur, keterlambatan respons, atau kegagalan sistem, yang ditandai dengan penggunaan kata-kata berkonotasi buruk seperti "rusak", "lambat", "kecewa", atau "tidak". Pemahaman definisi ini menjadi landasan penting dalam proses pelabelan data untuk membedakan antara kritik yang memerlukan penanganan (negatif) dan apresiasi (positif).

2.2.7 Teori Netral

kata "netral" dalam KBBI dimaknai sebagai sikap tidak berpihak, tidak ikut membantu salah satu pihak, atau posisi yang berada di tengah-tengah. Definisi ini juga memiliki analogi dalam bidang kimia yang menunjukkan sifat tidak asam dan tidak basa. Jika ditarik ke dalam konteks analisis sentimen pada data pengaduan LAKSA, kategori sentimen netral merepresentasikan jenis laporan yang bersifat objektif, datar, dan tidak mengandung muatan emosional yang dominan. Laporan yang diklasifikasikan ke dalam kategori ini umumnya berupa pertanyaan administratif, penyampaian fakta lapangan tanpa disertai opini

subjektif, atau informasi umum yang tidak memihak pada spektrum kepuasan (positif) maupun kekecewaan (negatif). Keberadaan kelas netral ini sangat penting untuk menampung data yang bersifat ambiguitas atau informatif murni, sehingga tidak dipaksakan masuk ke dalam polaritas sentimen yang salah.

2.2.8 Teori *Natural Language Processing* (NLP) dan *Text Preprocessing*

Text preprocessing adalah langkah krusial dalam *Natural Language Processing* (NLP) yang secara signifikan memengaruhi kinerja analisis sentimen [39]. Metode *preprocessing* yang umum meliputi tokenisasi, *stopword removal*, *stemming*, dan *lemmatization* [40]. Dalam klasifikasi sentimen, berbagai model *deep learning*, metode *embedding*, dan pendekatan tokenisasi telah dianalisis untuk mengetahui [41]. Penggunaan kata mentah atau yang telah melewati tahap *preprocessing*, *stemming*, dan tokenisasi telah memberikan hasil yang menjanjikan dalam tugas analisis sentimen [41].

2.2.9 Teori *Machine Learning*

Teknik *machine learning* khususnya pendekatan *supervised learning* banyak diterapkan untuk analisis sentimen ulasan pelanggan di berbagai domain [42]. Berbagai studi telah membandingkan kinerja algoritma yang berbeda, termasuk *Naïve Bayes*, *Support Vector Machine* (SVM), *Random Forest*, dan model *deep learning* seperti *Long Short-Term Memory* (LSTM) dan *Convolutional Neural Networks* (CNN) [42]. Metode-metode ini telah menunjukkan hasil yang menjanjikan dalam mengklasifikasikan sentimen sebagai positif, negatif, atau netral. Sebagai contoh, LSTM mencapai akurasi 97% dalam menganalisis ulasan produk Amazon, sementara regresi logistik mengungguli metode lain dalam ulasan produk asuransi [42][43].

1.2.7 Teori Hybrid

Pendekatan hybrid dalam *machine learning* muncul sebagai metode yang paling tangguh untuk tugas klasifikasi, meskipun komponennya berasal dari pendekatan yang berbeda secara fundamental [43]. Studi komparatif mengungkapkan bahwa metode gabungan ini secara konsisten memberikan kinerja yang lebih unggul dibandingkan pendekatan tunggal, terutama dalam

lingkungan yang kompleks, sehingga menonjol dalam hal ketangguhan dan akurasi [43]. Dalam aplikasi analisis sentimen, model berbasis hibrida mencapai skor kinerja tertinggi dan menunjukkan keunggulan yang jelas atas pendekatan konvensional lainnya [43]. Sifat saling melengkapi dari teknik-teknik dalam kerangka hibrida telah menghasilkan metode gabungan yang sukses, dengan model hibrida dilaporkan memberikan peningkatan 8–16% dalam akurasi, presisi, recall, dan F1-score dibandingkan penggunaan metode individual [44]. Dalam klasifikasi data spasial dan aplikasi perencanaan wilayah, pendekatan berbasis hibrida juga diidentifikasi sebagai pilihan yang paling sesuai untuk analisis data penginderaan bumi [45].

1.2.8 Teori *Confusion Matrix*

Evaluasi kinerja model klasifikasi merupakan tahapan krusial untuk mengukur sejauh mana model *machine learning* mampu memprediksi kelas target dengan benar. Salah satu metode evaluasi yang paling umum digunakan adalah Confusion Matrix. Confusion Matrix adalah sebuah tabel representasi visual yang membandingkan nilai prediksi yang dihasilkan oleh model dengan nilai aktual (label sebenarnya) dari data uji. Tabel ini memberikan informasi detail mengenai jumlah prediksi yang benar dan salah untuk setiap kelas, yang memungkinkan analisis kinerja model secara lebih mendalam daripada sekadar melihat tingkat akurasi semata [44][45]. terdapat empat istilah dasar yang merepresentasikan hasil prediksi, diantaranya :

- 1) *True Positive* (TP) : jumlah data positif yang diprediksi dengan benar sebagai positif oleh model
- 2) *True Negative* (TN) : jumlah data negatif yang diprediksi dengan benar sebagai negatif oleh model
- 3) *False Positive* (FP) : jumlah data negatif yang secara salah diprediksi sebagai positif
- 4) *False Negative* (FN) : jumlah data positif yang secara salah diprediksi sebagai negatif

Berdasarkan keempat komponen yang disebutkan, kinerja model dapat diukur dengan beberapa metrik evaluasi standar yakni *Accuracy*, *Precision*, *Recall*, dan *F1-Score* yang dijelaskan secara detail sebagai berikut :

1) *Accuracy* (Akurasi)

Akurasi merupakan rasio prediksi benar (baik positif maupun negatif) terhadap keseluruhan data. Metrik ini memberikan gambaran umum tentang seberapa sering model membuat prediksi yang tepat. Namun, akurasi bisa menjadi bias jika digunakan pada dataset yang tidak seimbang. Rumus akurasi didefinisikan sebagai berikut :

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Rumus 2.1 Rumus Accuracy [45]

2) *Precision* (Presisi)

Presisi mengukur tingkat ketepatan antara informasi yang diminta dengan jawaban yang diberikan oleh sistem. Dalam konteks klasifikasi, presisi adalah rasio dari prediksi positif yang benar dibandingkan dengan keseluruhan hasil yang diprediksi positif. Nilai presisi yang tinggi mengindikasikan bahwa model memiliki tingkat kesalahan yang rendah dalam memberikan label positif palsu (*False Positive*). Rumus presisi adalah :

$$Precision = \frac{TP}{TP + FP}$$

Rumus 2.2 Rumus Precision [45]

3) *Recall* (Sensitivitas)

Recall, atau yang sering disebut sebagai *Sensitivity*, mengukur keberhasilan model dalam menemukan kembali informasi yang relevan. Metrik ini menghitung proporsi data positif yang berhasil diprediksi dengan benar dibandingkan dengan keseluruhan data yang sebenarnya positif. *Recall* sangat penting ketika tujuan utama adalah meminimalisir kesalahan prediksi negatif palsu (*False Negative*). Rumus *Recall* adalah :

$$Recall = \frac{TP}{TP + FN}$$

Rumus 2.3 Rumus Recall [45]

4) *F1-Score*

F1-Score adalah rata-rata harmonik (*harmonic mean*) dari *Precision* dan *Recall*. Bagian *F1-Score* ini memberikan gambaran tunggal yang menyeimbangkan kedua metrik tersebut. *F1-Score* menjadi indikator yang sangat penting ketika terdapat ketidakseimbangan distribusi kelas pada data, atau ketika kita ingin mencari keseimbangan optimal antara presisi dan *recall*. Nilai *F1-Score* terbaik adalah 1 (sempurna) dan terburuk adalah 0. Rumusnya didefinisikan sebagai berikut :

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Rumus 2.4 Rumus F1-Score [45]

2.3 Framework/Algoritma yang digunakan

2.3.1 CRISP-DM



Gambar 2. 1 Metode CRISP-DM

Cross-Industry Standard Process for Data Mining (CRISP-DM) tetap menjadi kerangka kerja yang banyak digunakan untuk proyek penambangan

data (*data mining*) dan *machine learning*, dengan menyediakan alur kerja terstruktur yang terdiri dari enam fase utama [46]. CRISP-DM efektif untuk proyek yang berorientasi pada tujuan dan berbasis proses, upaya-upaya ilmu data yang lebih bersifat eksploratif mungkin memerlukan pendekatan berbasis lintasan (*trajectory-based*) yang lebih fleksibel [46]. Hal ini membuat *Cross-Industry Standard Process for Data Mining* (CRISP-DM) tetap menjadi standar yang diadopsi secara luas untuk proyek-proyek penambangan data (*data mining*), meskipun telah berusia lebih dari dua decade [46]. Fleksibilitas model ini memungkinkan penerapannya dalam berbagai konteks seperti mengekstraksi tujuan bisnis [47]. Meskipun relevansinya tetap bertahan, CRISP-DM menghadapi tantangan dalam memandu organisasi dengan pengalaman penambangan data yang terbatas, terutama pada fase awal yang krusial, yaitu Business Understanding (Pemahaman Bisnis) [47]. CRISP-DM terdiri dari enam fase utama yang saling berhubungan :

1. *Business Understanding (Pemahaman Bisnis)*

Berguna untuk memahami tujuan dan kebutuhan proyek dari sudut pandang bisnis, lalu mengubahnya menjadi definisi masalah penggalan data.

2. *Data Understanding (Pemahaman Data)*

Pengumpulan data awal dan membiasakan diri dengan data tersebut, mengidentifikasi masalah kualitas, dan menemukan wawasan pertama.

3. *Data Preparation (Persiapan Data)*

Fase yang mencakup semua aktivitas untuk pemodelan, seperti pembersihan data, integrasi, dan transformasi.

4. *Modeling (Pemodelan)*

Dilakukan teknik pemodelan dan parameter dari model tersebut disesuaikan untuk mendapatkan hasil yang optimal.

5. *Evaluation (Evaluasi)*

Evaluasi dilakukan untuk memastikan model mencapai tujuan bisnis.

6. *Deployment*

Hasil dari model dan wawasan yang didapat diorganisir dan disajikan dalam bentuk yang dapat digunakan oleh pemangku kepentingan, baik dalam bentuk laporan maupun implementasi sistem.

2.3.2 Random Forest

Random Forest menggunakan metodologi *bagging* dan telah menunjukkan kemampuan luar biasa dalam menangani kumpulan data yang beragam [48]. Selain metodologi *bagging*, *random forest* menggunakan teknik *ensemble learning* yang telah menunjukkan efektivitas yang signifikan di berbagai aplikasi *machine learning* dengan menggabungkan prediksi dari beberapa model dasar untuk mencapai kinerja yang lebih unggul dibandingkan dengan *classifier* tunggal [48]. Dalam memprediksi, *random forest* memiliki rumus sebagai berikut :

$$y = \frac{1}{N} \sum_{i=1}^N h_{i(x)}$$

Rumus 2.5 Rumus Random Forest [49]

Dalam memprediksi, y merupakan prediksi akhir, N merupakan jumlah *decision tree* dalam hutan, $h_{i(x)}$ menjadi prediksi dari *decision tree* ke i untuk input x [49]. Beberapa penelitian menunjukkan bahwa di antara metode *ensemble* seperti *bagging*, *boosting*, *stacking*, dan *voting*, metode *stacking* secara konsisten menunjukkan akurasi tertinggi dalam tugas prediksi penyakit, meskipun pendekatan *bagging* pada *random forest* juga menunjukkan kinerja yang kuat di domain spesifik seperti prediksi penyakit ginjal [50]. Adaptabilitas algoritma ini telah ditingkatkan melalui *Adaptive Random Forest* (ARF) untuk aplikasi data *streaming*, di mana usulan ukuran efektivitas *resampling* menunjukkan peningkatan yang cukup besar dalam memproses dataset besar, termasuk analisis sentimen pada konten media sosial [51]. kinerja *Random Forest* dalam analisis sentimen dapat ditingkatkan secara signifikan melalui langkah-langkah *preprocessing* dan teknik *random minority oversampling* untuk mengatasi masalah ketidakseimbangan kelas atau yang dikenal *class imbalance* pada data media sosial [52].

2.3.3 Support Vector Machine (SVM)

Algoritma *Support Vector Machine* (SVM) adalah algoritma *supervised learning* andal yang diimplementasikan jika memiliki tujuan untuk menemukan *hyperplane* optimal dengan margin terbesar di antara kelas-kelas, yang ditentukan oleh support vector [53]. Permasalahan optimasi dalam SVM untuk menemukan garis pemisah terbaik dengan mempertimbangkan *soft margin* yakni toleransi kesalahan dalam klasifikasi dimasukkan kedalam rumus sebagai berikut :

$$\min \frac{1}{2} ||w||^2 + c \sum_{i=1}^N \xi_i$$

Rumus 2.6 Rumus SVM [54]

Dimana $||w||^2$ adalah bobot vektor yang meminimalkan margin, c adalah parameter regulasi yang mengontrol *trade-off* antara margin terbesar dan kesalahan klasifikasi, serta ξ_i adalah variabel *slack* yang mengukur tingkat kesalahan klasifikasi data ke- i . Kekuatan SVM terletak pada kemampuannya untuk melakukan klasifikasi non-linear menggunakan *kernel trick*, dengan memetakan data ke ruang berdimensi lebih tinggi agar dapat dipisahkan secara linear[53]. SVM telah banyak diterapkan di berbagai bidang, termasuk pengenalan wajah, diagnostik penyakit, dan analisis teks, dan sering kali mencapai akurasi tinggi [53]. Berdasarkan karakteristik data, terdapat beberapa fungsi kernel yang banyak digunakan dan diuji dalam penelitian, diantaranya :

1. Kernel Linear

Kernel linear merupakan fungsi kernel paling sederhana yang digunakan ketika data dapat dipisahkan secara linear yakni garis lurus maupun bidang datar [55]. Linear memetakan data berdasarkan koordinat asli data dan direkomendasikan untuk data jenis teks dengan jumlah fitur yang banyak, berdimensi tinggi seperti hasil TF-IDF, dan klasifikasi teks [55]. Hal ini dikarenakan data teks sudah tersebar secara linear sehingga pemisahan kompleks yang seringkali tidak diperlukan dan menyebabkan *overfitting* banyak terjadi dalam ruang berdimensi tinggi [55]. Linear

kernel juga memiliki keunggulan dari segi sisi komputasi yang lebih tinggi dibanding kernel lainnya [55].

2. Kernel Polynomial

Kernel polynomial merupakan fungsi kernel yang memungkinkan model untuk mempelajari pola pemisahan yang lebih kompleks yakni dengan garis lengkung atau batas non-linear [56]. Polynomial bekerja dengan memproyeksikan data ke dimensi baru dengan cara mengkombinasikan fitur-fitur berdasarkan derajat polynomial tertentu [56]. Semakin tinggi penggunaan derajat, maka akan semakin kompleks batas keputusan hasil model [56]. Kernel polynomial berguna ketika hubungan antar data tidak bisa dipisahkan secara linear, namun kekurangannya merupakan waktu komputasi yang lebih lama seiring meningkatnya derajat kompleksitas [56].

3. Kernel Radial Basis Function (RBF)

Kernel RBF atau yang dikenal dengan gaussian merupakan kernel yang terkenal dalam menangani permasalahan klasifikasi dengan pola data acak dan non-linear [56][57]. RBF memiliki konsep dimana data akan dipetakan dalam ruang dengan dimensi tak terhingga [57]. Kernel RBF bekerja dengan membuat batas keputusan tertutup di sekitar kelompok data yang mirip atau berdasarkan jarak layaknya lingkaran-lingkaran disekitar *cluster* data [57].

2.4 Tools/software yang digunakan

2.4.1 Python

Python telah muncul sebagai bahasa pemrograman yang dominan dalam komputasi ilmiah (scientific computing), ilmu data (data science), dan *machine learning* berkat keterbacaan, keserbagunaan, dan ekosistem pustakanya yang kaya [58]. Popularitas python meluas ke berbagai bidang ilmiah, termasuk kimia dan elektrokimia, di mana bahasa ini memfasilitasi analisis data, simulasi, dan otomasi laboratorium [59]. Pustaka Python yang luas, seperti NumPy, Pandas, dan scikit-learn, menyediakan alat yang andal untuk manipulasi data, visualisasi, dan implementasi *machine learning* [60].

2.4.2 Visual Studio Code

Visual Studio Code (VS Code) adalah editor kode sumber (*source-code editor*) populer yang dapat diperluas (*extensible*), yang mengintegrasikan kemampuan AI modern melalui *AI-Driven Development Environments* (AIDE) [61]. Hal ini meningkatkan efisiensi pemrograman, tetapi juga memunculkan tantangan seperti bias dan masalah keamanan [61]. Sebagai perangkat lunak sumber terbuka (*open-source*), VS Code sejalan dengan meningkatnya minat mahasiswa sehingga banyak digunakan karena mendapat manfaat dari aksesibilitas dan dukungannya untuk pembelajaran [62]. Sifat VS Code yang dapat diperluas memungkinkan berbagai penerapan pengodean, termasuk dalam metode penelitian kualitatif di mana pengodean (*coding*) merupakan proses yang krusial namun sering kali menantang [63]. Fleksibilitas editor ini meluas hingga ke teknik visualisasi canggih, seperti *CodeCity*, yang dapat merepresentasikan sistem perangkat lunak sebagai kota 3D [63]. Studi-studi terkini menunjukkan bahwa penerapan *CodeCity* dalam *virtual reality* (VR) dapat secara signifikan meningkatkan waktu penyelesaian tugas dibandingkan versi tradisional di layar, yang menunjukkan potensi antarmuka inovatif dalam penyuntingan dan analisis kode [63].

2.4.3 Jupyter Notebook

Jupyter Notebook telah diadopsi secara luas di komunitas ilmiah dan industri, dengan menawarkan platform terintegrasi untuk eksekusi kode, visualisasi data, dan dokumentasi [64]. Strukturnya yang berbasis sel memungkinkan alur kerja yang interaktif dan eksploratif, menjadikannya berharga untuk analisis data, machine learning, dan penelitian ilmiah [64]. Namun, berbagai studi telah mengidentifikasi tantangan dalam reproduktifitas dan kualitas notebook, yang mendorong usulan praktik terbaik (*best practices*) dan alat bantu seperti Jupyter untuk meningkatkan aspek-aspek ini [65]. Penelitian juga telah mengeksplorasi bug dan tantangan yang dihadapi oleh para praktisi Jupyter, yang menyoroti perlunya pemahaman dan penanganan yang lebih baik terhadap isu-isu ini [66]. Di bidang pendidikan, Jupyter Notebook telah muncul sebagai alat pedagogis yang efektif, terutama di bidang

seperti robotika seluler (*mobile robotics*), di mana ia menjembatani kesenjangan antara konsep teoretis dan implementasi praktis [67]. Secara keseluruhan, Jupyter Notebook telah menjadi perangkat esensial untuk penelitian berbasis data, pembuatan prototipe (prototyping), dan komunikasi hasil analisis di berbagai disiplin ilmu.



UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA