

BAB II

LANDASAN TEORI

2.1 Penelitian Terdahulu

Pada bagian ini, berbagai penelitian dalam bidang analisis sentimen telah menerapkan algoritma *machine learning* untuk mengukur reaksi publik terhadap berbagai platform, baik dalam konteks *e-commerce* maupun media sosial. Tabel 2.1 menyajikan ringkasan artikel-artikel terkait, yang mengidentifikasi metode yang digunakan serta temuan-temuan penting yang diperoleh dari penerapan algoritma pada data besar dan platform digital.

Tabel 2. 1 Tabel Penelitian Terdahulu

Judul Artikel & Penulis		Objek Penelitian	Metodologi	Temuan
1	Filahi et al. (2025), " <i>Enhanced E-commerce decision-making through sentiment analysis using machine learning-based approaches and IoT</i> ," <i>PLOS One Vol 20(6)</i> [26]	Pengambilan keputusan di <i>e-commerce</i>	<i>Logistic Regression, Naïve Bayes, AI, Random Forest, AdaBoost, GRU, LSTM</i>	<i>AdaBoosting</i> akurasi 88%, meningkatkan personalisasi dan efisiensi <i>e-commerce</i> .
2	Tursina Dewi, Asrianda, Yesy Afrillia (2025), " <i>Sentiment Analysis of Customer Satisfaction Towards Shopee and Lazada E-commerce Platform Using the Random Forest Algorithm Classifier</i> ," <i>International Journal of Engineering, Science and Information Technology</i> , Vol. 5, No. 1.[27]	Sentimen kepuasan pelanggan terhadap ulasan produk pada tiga toko skincare (Skintific, Originote, Azarine) di platform	<i>Preprocessing</i> teks dan analisis sentimen menggunakan pendekatan <i>lexicon-based</i> yang dikombinasikan dengan <i>Random Forest</i> sebagai algoritma klasifikasi utama; pembobotan fitur dilakukan dengan <i>Count</i>	<i>Random Forest</i> memberikan hasil sentimen positif yang tinggi untuk ketiga toko, misalnya Skintific 88% positif di Shopee dan 84,1% di Lazada; Originote 82,4% di Shopee dan 91,5% di Lazada; Azarine 87,8% di Shopee dan 77,9% di Lazada.

Judul Artikel & Penulis		Objek Penelitian	Metodologi	Temuan
		e-commerce Shopee dan Lazada (total 4.500 komentar).	<i>Vectorizer</i> dan <i>TF-IDF</i> untuk dibandingkan performanya	
3	Agus Maula Rizki, Bustami, Said Fadlan Anshari (2025), “ <i>Comparison of Support Vector Machine and Naïve Bayes Algorithms in Sentiment Analysis of TikTokShop Application User Reviews</i> ,” <i>Journal of Renewable Energy, Electrical, and Computer Engineering</i> , Vol. 5, No. 1. [28]	Ulasan pengguna aplikasi <i>TikTokShop</i> di <i>Google Play Store</i> yang dikelompokkan menjadi sentimen positif, netral, dan negatif	<i>Preprocessing</i> teks, ekstraksi fitur dengan <i>TF-IDF</i> , lalu klasifikasi sentimen menggunakan algoritma <i>SVM</i> dan <i>Naïve Bayes</i>	<i>SVM</i> menghasilkan akurasi sekitar 68,9% dengan <i>F1-score</i> 68,6%, lebih tinggi dibanding <i>Naïve Bayes</i> yang memiliki akurasi sekitar 64,5% dan <i>F1-score</i> 62,5%, sehingga <i>SVM</i> dinilai lebih efektif untuk klasifikasi sentimen ulasan <i>TikTokShop</i>
4	Haliza, D., Ikhsan, M. (2025). "Sentiment Analysis on Public Perception of the Nusantara Capital on Social Media X Using Support Vector Machine(SVM) and K-Nearest Neighbor (K-NN) Methods," <i>Journal of Applied Informatics and Computing (JAIC)</i> , vol. 9, no. 3[29]	Sentimen publik terkait Ibu Kota Nusantara di media sosial X (Twitter)	Metode <i>Support Vector Machine(SVM)</i> dan <i>K-Nearest Neighbor (K-NN)</i> untuk klasifikasi sentimen	<i>SVM</i> memiliki akurasi 76%, <i>precision</i> 78%, <i>recall</i> 81%, dan <i>f1-score</i> 79%. <i>K-NN</i> memiliki akurasi 65%, <i>precision</i> 62%, <i>recall</i> 98%, dan <i>f1-score</i> 76%. Mayoritas sentimen yang muncul adalah negatif.
5	Amusan, O. O., Udefi, A. M. (2024). "AI-powered sentiment analysis for classifying harmful content on social media: A case study with ChatGPT Integration," <i>World Journal of Advanced Research and Reviews</i> , vol. 24, no. 03 [30]	Klasifikasi konten berbahaya di media sosial menggunakan AI	Menggunakan model <i>sentiment analysis</i> berbasis ChatGPT untuk mengklasifikasikan konten Twitter menjadi <i>Abusive</i> , <i>Neutral</i> , dan <i>Harmless</i>	Akurasi 96%, sensitivitas 90%, dan <i>precision</i> 88%. Model efektif dalam mendeteksi konten berbahaya dengan <i>false positive</i> yang rendah.
6	Anelta Tirta Putri Subandono, Dhani Ariatmanto (2025), “Optimalisasi Seleksi Fitur dalam Analisis Sentimen Bank Saqu: Studi Perbandingan SVM dan Random Forest Menggunakan Information Gain dan Chi-Square,” Sistemasi: Jurnal Sistem Informasi.[31]	Ulasan pengguna terkait layanan Bank Saqu yang dianalisis sentimennya untuk menilai kepuasan	Analisis sentimen menggunakan algoritma <i>Support Vector Machine</i> dan <i>Random Forest</i> dengan delapan skema pengujian: tanpa seleksi fitur, serta dengan seleksi fitur <i>Information Gain</i> ,	<i>SVM</i> dengan seleksi fitur <i>Chi-Square</i> mencapai akurasi tertinggi 93%, sedangkan <i>Random Forest</i> dengan <i>Chi-Square</i> memperoleh akurasi 91%, menunjukkan <i>Chi-Square</i> lebih efektif daripada <i>Information Gain</i> dan <i>SVM</i> sedikit lebih unggul dibanding <i>Random Forest</i> untuk klasifikasi teks.

Judul Artikel & Penulis		Objek Penelitian	Metodologi	Temuan
		dan persepsi pengguna	<i>Chi-Square</i> , dan kombinasi keduanya	
7	Haroon, M., Alam, Z., Kousar, R., Ahmad, J., Nasim, F. (2024). " <i>Sentiment Analysis of Customer Reviews on E-commerce Platforms: A Machine Learning Approach</i> ," Bulletin of Business and Economics, vol. 13, no. 3[32]	Sentimen analisis ulasan pelanggan di platform e-commerce	Perbandingan algoritma <i>machine learning</i> : <i>Logistic Regression</i> , <i>Naïve Bayes</i> , <i>Neural Networks</i> , <i>SVM</i>	<i>Naïve Bayes</i> mencapai akurasi 94%, mengungguli model lain seperti <i>Logistic Regression</i> dan <i>SVM</i> .
8	Naufal Abror, Rice Novita, Mustakim, M. Afdal (2024), " <i>Sentiment Analysis on the Impact of Artificial Intelligence (AI) Development to Determine Technology Needs</i> ," Jurnal Sistem Cerdas.[33]	<i>Tweet</i> pengguna di Platform X tentang dampak perkembangan <i>AI</i> di berbagai bidang di Indonesia.	<i>Scraping tweet</i> , <i>preprocessing</i> teks, lalu klasifikasi sentimen positif, negatif, dan netral menggunakan algoritma <i>Multinomial Naïve Bayes Classifier</i>	Penelitian ini menemukan bahwa sentimen publik terhadap <i>AI</i> bervariasi, dengan sentimen negatif pada keamanan data dan positif pada pendidikan. Akurasi terbaik tercapai pada pendidikan (67%) dan keamanan data (75%), menekankan pentingnya <i>AI</i> yang responsif terhadap kebutuhan masyarakat.
9	Ahmed, A. A., Agarwal, S., Kurniawan, I. G. A., Anantadjaya, S. P. D., Krishnan, C. (2022). " <i>Business boosting through sentiment analysis using Artificial Intelligence approach</i> ," Springer, vol. 5[34]	Sentimen analisis untuk meningkatkan kinerja bisnis menggunakan <i>AI</i>	Analisis sentimen berbasis <i>AI</i> dan <i>machine learning</i>	<i>AI</i> dan <i>ML</i> meningkatkan keputusan bisnis dengan wawasan sentimen pelanggan, tetapi akurasi tidak disebutkan secara eksplisit.
10	Destitus, C., Wella, S., Suryasari (2020), " <i>Support Vector Machine VS Information Gain: Analisis Sentimen Cyberbullying di Twitter Indonesia</i> ," ULTIMA InfoSys, vol. XI, No.2[35]	Sentimen analisis cyberbullying di Twitter Indonesia	<i>Support Vector Machine(SVM)</i> , <i>Information Gain</i>	Akurasi <i>SVM</i> 80%, <i>precision</i> 75.1%, <i>recall</i> 96%, <i>f-measure</i> 85%; <i>Information Gain</i> mencapai akurasi 86%, <i>precision</i> 81%, <i>recall</i> 95%, <i>f-measure</i> 87%.
11	Wilim, N. N., & Oetama, R. S. (2021). " <i>Sentiment Analysis about Indonesian Lawyers Club Television Program Using K-Nearest Neighbor, Naïve Bayes Classifier, and Decision Tree</i> ," International Journal of New Media Technology, Vol. 8, No. 1[36]	Sentimen analisis terkait acara Indonesia Lawyers Club (ILC) di platform Twitter	<i>K-Nearest Neighbor</i> , <i>Naïve Bayes</i> , <i>Decision Tree</i>	Akurasi tertinggi pada 2018 (<i>K-NN</i> 76.94%, <i>Naïve Bayes</i> 76.39%), namun sentimen positif ILC menurun signifikan di 2019, sementara Mata Najwa menunjukkan peningkatan sentimen positif.

Pada Tabel 2.1 Penelitian terdahulu, terlihat bahwa berbagai studi terbaru banyak menerapkan analisis sentimen dengan algoritma *machine learning* klasik, seperti *Naïve Bayes*, *Support Vector Machine (SVM)*, *Random Forest*, *Logistic Regression*, dan *K-Nearest Neighbor (K-NN)* pada data ulasan e-commerce maupun media sosial. Sebagian besar penelitian menggunakan pendekatan ekstraksi fitur berbasis *bag-of-words*, *TF-IDF*, atau seleksi fitur seperti *Information Gain* dan *Chi-Square*, dan menunjukkan bahwa kombinasi representasi teks yang tepat dengan algoritma tersebut mampu menghasilkan akurasi klasifikasi sentimen yang tinggi, misalnya hingga sekitar 93% pada skenario tertentu. Dengan demikian, penelitian terdahulu menegaskan bahwa algoritma *machine learning* tradisional tetap efektif untuk memetakan sentimen positif, negatif, dan netral terhadap produk, layanan, maupun topik terkait AI.

Meskipun demikian, sebagian besar studi tersebut masih berfokus pada ulasan produk *e-commerce* atau aplikasi spesifik dan belum secara khusus menyoroti sentimen pengguna terhadap penerapan AI di *e-commerce* berbasis *tweet* serta pengaruh faktor eksternal seperti kepercayaan terhadap privasi dan keamanan data. Penelitian ini mengisi celah tersebut dengan menerapkan algoritma *Naïve Bayes*, *SVM*, dan *Random Forest* pada dataset *tweet* Platform X tentang AI dalam bisnis dan *e-commerce*, menggunakan pendekatan ekstraksi fitur yang sejalan dengan penelitian terdahulu, sekaligus menganalisis peran faktor eksternal seperti privasi dan kepercayaan terhadap pengelolaan data dalam pembentukan sentimen pengguna.

2.2 Teori yang berkaitan

2.2.1 Sentimen Analisis

Sentimen analisis, yang juga dikenal sebagai analisis opini, adalah cabang dari pemrosesan bahasa alami (NLP) yang bertujuan untuk mengidentifikasi dan mengklasifikasikan sentimen yang terkandung dalam teks[37]. Tujuan utama dari analisis sentimen adalah untuk menentukan apakah suatu teks, seperti ulasan produk, *tweet*, atau komentar pengguna, mengandung sentimen

positif, negatif, atau netral. Dalam konteks penelitian ini, sentimen analisis diterapkan untuk mengevaluasi tanggapan pengguna terhadap implementasi *AI* dalam bisnis dan *e-commerce*, dengan fokus pada Platform X, yang berfungsi sebagai saluran penting bagi konsumen untuk berbagi opini mereka mengenai produk atau layanan berbasis *AI*[38].

Sentimen analisis sangat penting dalam konteks *e-commerce*, karena membantu perusahaan memahami bagaimana produk, layanan, atau teknologi tertentu diterima oleh pengguna. Dengan mengetahui reaksi konsumen terhadap teknologi baru, seperti *AI*, perusahaan dapat membuat keputusan yang lebih tepat dalam mengembangkan produk dan strategi pemasaran[39]. Misalnya, jika analisis sentimen menunjukkan bahwa banyak pengguna merasa tidak puas dengan keakuratan rekomendasi produk yang diberikan oleh sistem *AI*, perusahaan dapat memperbaiki algoritma atau meningkatkan transparansi dalam memberikan rekomendasi tersebut.

Untuk melakukan analisis sentimen, berbagai metode dan algoritma dapat digunakan, tergantung pada kompleksitas data dan tujuan analisis. Berikut adalah beberapa metode yang umum digunakan dalam sentimen analisis:

1) *Lexicon-based Methods*:

Metode berbasis leksikon menggunakan kamus kata-kata yang telah diberi nilai sentimen tertentu. Setiap kata dalam teks yang dianalisis akan diberi skor berdasarkan apakah kata tersebut memiliki konotasi positif, negatif, atau netral. Pendekatan ini cukup sederhana dan bergantung pada daftar kata yang telah dikelompokkan, seperti kamus sentimen *SentiWordNet*. Keunggulannya terletak pada kemudahan implementasi dan efisiensi dalam menganalisis data teks dengan sentimen yang jelas[40]. Namun, metode ini kurang efektif dalam menangani konteks atau nuansa emosional yang kompleks, seperti sarkasme atau ambiguitas.

2) *Machine Learning Methods*:

Metode ini menggunakan algoritma pembelajaran mesin untuk menganalisis dan mengklasifikasikan sentimen dalam teks. Algoritma yang

paling umum digunakan termasuk *Naïve Bayes*, *Support Vector Machine(SVM)*, dan *Random Forest*[41]. Algoritma ini dilatih menggunakan dataset yang sudah diberi label sentimen (positif, negatif, netral), sehingga dapat mempelajari pola dalam data teks untuk melakukan klasifikasi sentimen pada data baru. Metode ini lebih fleksibel dan dapat menangani data besar serta konteks yang lebih kompleks daripada pendekatan berbasis leksikon. Misalnya, dalam analisis ulasan produk atau komentar pengguna mengenai sistem AI di *e-commerce*, algoritma *machine learning* dapat digunakan untuk mengidentifikasi sentimen lebih mendalam, termasuk memahami nuansa emosional yang terkandung dalam teks.

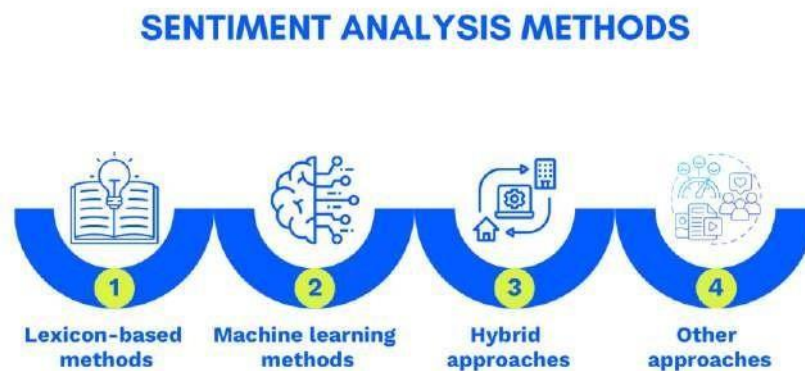
3) *Hybrid Approaches*:

Pendekatan hybrid menggabungkan kedua metode di atas untuk meningkatkan akurasi dan efektivitas analisis sentimen. Misalnya, algoritma *machine learning* dapat digunakan bersama dengan leksikon sentimen untuk memanfaatkan kekuatan kedua metode tersebut. Pendekatan ini sering digunakan untuk mengatasi kekurangan masing-masing metode. Dengan menggabungkan *machine learning* yang lebih fleksibel dengan *lexicon-based methods* yang lebih sederhana, hasil analisis sentimen bisa lebih akurat, terutama dalam menangani data yang lebih kompleks dan ambigu. Pendekatan hibrida ini sangat relevan dalam konteks penelitian ini, di mana data dari Platform X yang terdiri dari komentar dan opini pengguna tentang AI dapat dianalisis menggunakan kombinasi kedua metode ini[42].

4) *Other Approaches*:

Selain tiga metode utama di atas, ada juga pendekatan lain yang digunakan dalam analisis sentimen, seperti pendekatan berbasis *deep learning* atau *neural networks*. Metode ini memungkinkan model untuk belajar lebih dalam tentang struktur dan konteks teks, termasuk nuansa emosional yang lebih halus dalam teks. Teknik *deep learning*, seperti *Long Short-Term Memory (LSTM)* dan *Convolutional Neural Networks (CNN)*, telah terbukti sangat efektif dalam analisis sentimen pada teks yang panjang dan ambigu, seperti *tweet* atau ulasan

yang mengandung sarkasme. Sebagai contoh, dalam konteks *e-commerce*, *deep learning* dapat digunakan untuk menganalisis bagaimana konsumen merespons fitur baru dari *AI* yang diterapkan dalam sistem rekomendasi produk, memperhitungkan aspek-aspek seperti kepuasan, kebingungan, atau bahkan ketidakpercayaan[42].



Gambar 2. 1 Metode Sentimen Analisis

Secara keseluruhan, penggunaan analisis sentimen dalam *e-commerce*, khususnya untuk menilai penerimaan pengguna terhadap implementasi *AI*, dapat memberikan wawasan berharga yang membantu perusahaan dalam meningkatkan kualitas layanan, memahami preferensi pelanggan, dan merancang strategi pemasaran yang lebih efektif. Dengan memilih metode yang tepat untuk data yang ada, perusahaan dapat meningkatkan akurasi analisis dan memperoleh hasil yang lebih relevan dan dapat diandalkan, sehingga memungkinkan mereka untuk mengoptimalkan pengalaman pengguna dan strategi pengembangan produk berbasis *AI*.

2.2.2 Artificial Intelligence

Artificial Intelligence merupakan cabang ilmu komputer yang berfokus pada pengembangan sistem yang dapat meniru atau mensimulasikan kecerdasan manusia dalam menyelesaikan tugas tertentu. Teknologi *AI* memungkinkan mesin atau komputer untuk belajar dari data, mengenali pola, memecahkan masalah, dan membuat keputusan berdasarkan informasi yang ada, tanpa memerlukan instruksi yang eksplisit. Dalam dunia *e-commerce*,

penerapan *AI* memiliki potensi besar untuk meningkatkan efisiensi operasional, memperkaya pengalaman pengguna, dan meningkatkan kepuasan pelanggan melalui berbagai fitur, seperti rekomendasi produk yang lebih tepat sasaran, analisis sentimen, dan agen virtual. *AI* juga memungkinkan platform *e-commerce* untuk memberikan layanan yang lebih personal, serta mengoptimalkan proses bisnis yang kompleks, seperti pengelolaan inventaris, prediksi permintaan, dan analisis perilaku pengguna.

Dalam teori *AI*, terdapat dua jenis utama yang dibedakan berdasarkan kemampuan dan cakupan penerapannya, yaitu *Narrow Artificial Intelligence* (*Narrow AI*) dan *General Artificial Intelligence* (*General AI*). *Narrow AI*, atau *AI* sempit, dirancang untuk melakukan satu tugas atau serangkaian tugas tertentu dengan tingkat akurasi yang sangat tinggi. Sebagai contoh, dalam *e-commerce*, *Narrow AI* digunakan untuk analisis sentimen dan rekomendasi produk, yang bertujuan untuk memahami preferensi pelanggan berdasarkan data transaksi atau interaksi sebelumnya dan memberikan saran produk yang relevan. *Narrow AI* sangat efektif dalam menangani tugas-tugas yang spesifik dan terbatas, karena dapat mengolah data dengan cepat dan akurat. Namun, kekurangan dari *Narrow AI* adalah ketidakmampuannya untuk beradaptasi atau menangani tugas lain di luar ruang lingkup yang sudah ditentukan tanpa membutuhkan pelatihan tambahan atau modifikasi sistem.



Gambar 2. 2 Dua Kategori *AI*

Sementara itu, *General AI* adalah bentuk *AI* yang memiliki kemampuan untuk melakukan berbagai tugas yang biasanya memerlukan kecerdasan manusia, seperti belajar, beradaptasi, memecahkan masalah, dan membuat keputusan dalam berbagai konteks. *General AI* mampu menangani tugas-tugas yang bervariasi, mirip dengan cara manusia berfungsi dalam kehidupan sehari-hari, sehingga memungkinkan sistem untuk berpikir dan bertindak lebih fleksibel. Meskipun demikian, *General AI* masih dalam tahap pengembangan dan belum diterapkan secara luas dalam industri, karena tantangannya yang lebih besar dalam hal kemampuan adaptasi dan sumber daya yang dibutuhkan.

Dalam konteks penelitian ini, *Narrow AI* lebih relevan, karena teknologi yang diterapkan berfokus pada analisis sentimen dan rekomendasi produk dalam platform *e-commerce*. *Narrow AI* digunakan untuk memahami sentimen pengguna terhadap produk atau layanan berbasis *AI* yang diterapkan dalam *e-commerce*. Misalnya, algoritma seperti *Naïve Bayes*, *Support Vector Machine (SVM)*, dan *Random Forest* digunakan untuk mengklasifikasikan sentimen dalam data teks yang tidak terstruktur, seperti komentar atau *tweet* pengguna, menjadi kategori positif, negatif, atau netral. *Narrow AI* mampu memberikan wawasan yang berharga bagi perusahaan untuk mengidentifikasi opini konsumen dan menyesuaikan strategi mereka berdasarkan respons pengguna terhadap fitur-fitur berbasis *AI*.

Selain itu, *Narrow AI* dalam *e-commerce* juga berfungsi untuk meningkatkan pengalaman pengguna dengan memberikan rekomendasi produk yang lebih relevan berdasarkan preferensi pribadi, analisis perilaku pembelian sebelumnya, dan interaksi dengan produk atau layanan yang ditawarkan. Dengan demikian, *AI* membantu perusahaan menciptakan pengalaman berbelanja yang lebih personal, yang pada gilirannya dapat meningkatkan kepuasan pelanggan dan mendorong loyalitas. Selain itu, teknologi *AI* dalam *e-commerce* juga dapat digunakan untuk mempercepat respons pelanggan melalui *chatbot* atau agen virtual berbasis *AI* yang dapat

memberikan solusi otomatis terhadap masalah atau pertanyaan pelanggan tanpa melibatkan tenaga manusia secara langsung.

Sementara *General AI* menawarkan potensi yang lebih besar dalam mengembangkan sistem yang lebih cerdas dan fleksibel, penerapan teknologi *Narrow AI* di *e-commerce* saat ini lebih praktis dan efisien. *Narrow AI* memungkinkan perusahaan untuk fokus pada area-area tertentu dalam operasional mereka, seperti analisis sentimen, rekomendasi produk, dan prediksi tren pasar, tanpa membutuhkan kompleksitas dan sumber daya yang tinggi. Oleh karena itu, penelitian ini berfokus pada penerapan *Narrow AI* dalam platform *e-commerce*, terutama untuk menganalisis sentimen pengguna terhadap penerapan *AI* dan memahami bagaimana respons mereka dapat membantu perusahaan untuk lebih memahami kebutuhan pasar dan meningkatkan pengalaman pelanggan secara lebih efektif.


2.2.3. *Machine Learning*

Machine learning (ML) adalah cabang dari *AI* yang memungkinkan sistem untuk belajar dari data dan meningkatkan performa tanpa perlu diprogram secara eksplisit. Dalam teori *machine learning*, model komputer dibangun untuk mengidentifikasi pola dalam data dan membuat keputusan atau prediksi berdasarkan pola tersebut. Proses ini melibatkan tiga tahap utama: pelatihan, pengujian, dan prediksi. Pada tahap pertama, model dilatih menggunakan data yang sudah memiliki label atau kategori untuk mempelajari hubungan antara data *input* dan *output* yang diinginkan. Pada tahap pengujian, model diuji menggunakan data yang belum pernah dilihat sebelumnya untuk mengevaluasi seberapa baik kinerjanya[43]. Setelah itu, model dapat digunakan untuk membuat prediksi atau keputusan berdasarkan data baru yang masuk.

Dalam konteks analisis sentimen dan penerapan *AI* di *e-commerce*, *machine learning* memainkan peran yang sangat penting. Dengan menggunakan algoritma *machine learning*, perusahaan dapat menganalisis ulasan pengguna, komentar, dan interaksi di platform *e-commerce* untuk memahami sentimen

konsumen terhadap produk atau layanan yang ditawarkan. Sebagai contoh, dalam platform X, algoritma *machine learning* seperti *Naïve Bayes*, *Support Vector Machine(SVM)*, dan *Random Forest* dapat digunakan untuk mengklasifikasikan sentimen pengguna menjadi kategori positif, negatif, atau netral berdasarkan teks yang dihasilkan oleh pengguna. Algoritma ini memproses data teks dan mencari pola dalam kata-kata atau frasa yang digunakan oleh pengguna untuk menyimpulkan perasaan mereka tentang produk atau layanan tersebut[44].

Machine learning dapat dikategorikan menjadi tiga jenis utama: *supervised learning*, *unsupervised learning*, dan *reinforcement learning*. Dalam *supervised learning*, model dilatih menggunakan data yang sudah memiliki label atau kategori yang jelas. Contoh yang paling umum adalah klasifikasi sentimen, di mana model dilatih untuk memetakan kata-kata atau frasa dalam ulasan pengguna menjadi kategori positif atau negatif. *Unsupervised learning*, di sisi lain, digunakan ketika data yang digunakan tidak memiliki label. Metode ini sering digunakan untuk menemukan pola atau struktur tersembunyi dalam data, seperti pengelompokan produk berdasarkan preferensi pengguna yang serupa. *Reinforcement learning* adalah pendekatan di mana model belajar dengan cara berinteraksi dengan lingkungan dan mendapatkan umpan balik berupa penghargaan atau hukuman berdasarkan tindakan yang diambil. Meskipun *reinforcement learning* lebih sering diterapkan dalam konteks pengambilan keputusan atau pengendalian, konsepnya juga dapat digunakan dalam optimasi sistem rekomendasi di *e-commerce*[45].



Gambar 2. 3 Tiga Kategori *Machine learning*

Salah satu tantangan utama dalam *machine learning* adalah memastikan bahwa model yang dibangun tidak hanya belajar dari data pelatihan tetapi juga dapat menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya. Hal ini dapat diatasi dengan teknik seperti *cross-validation* dan *regularization* yang membantu mencegah *overfitting*, yaitu ketika model terlalu "terbiasa" dengan data pelatihan dan gagal mengenali pola pada data baru. Dalam penerapan *machine learning* untuk analisis sentimen, penting untuk menggunakan teknik-teknik ini agar model dapat mengklasifikasikan sentimen dengan akurat, bahkan jika data yang diterima mengandung ambiguitas atau nuansa emosional[45].

Di sektor *e-commerce*, penerapan *machine learning* telah terbukti sangat efektif untuk meningkatkan pengalaman pengguna, mulai dari rekomendasi produk yang lebih personal hingga analisis perilaku pelanggan yang lebih mendalam. Misalnya, dalam analisis sentimen, model *machine learning* dapat membantu perusahaan memahami bagaimana pelanggan merespons produk atau layanan berbasis *AI*, serta mengidentifikasi area-area yang perlu diperbaiki. Dengan menggunakan algoritma seperti *Naïve Bayes*, *SVM*, dan *Random Forest*, perusahaan dapat mengklasifikasikan sentimen yang terkandung dalam komentar atau *tweet*, memberikan mereka wawasan yang

berharga untuk meningkatkan interaksi dengan pelanggan dan pengembangan produk[46].


Machine learning, dengan kemampuannya untuk memproses data dalam jumlah besar dan menemukan pola tersembunyi dalam data, memberikan alat yang kuat untuk perusahaan *e-commerce* dalam merancang strategi pemasaran yang lebih efektif dan memenuhi kebutuhan pelanggan dengan lebih baik[47], [48].

2.3 Framework/Algoritma yang digunakan

2.3.1. CRISP-DM

CRISP-DM (*Cross-Industry Standard Process for Data Mining*) adalah metodologi yang banyak digunakan dalam *data mining* karena sifatnya yang fleksibel, terstruktur, dan berulang, yang memungkinkan perbaikan dan penyesuaian di setiap tahapan proses analisis. CRISP-DM terdiri dari enam tahapan utama yang mendasari seluruh proses analisis data dalam penelitian ini, dimulai dari pemahaman bisnis hingga penerapan model ke dalam dunia nyata[49], [50]. Tahapan ini saling terkait dan sering kali bersifat iteratif, yang memungkinkan penyesuaian di sepanjang jalan berdasarkan hasil yang diperoleh pada setiap tahap.

Pada penelitian ini, CRISP-DM digunakan untuk menganalisis sentimen dari data teks yang diperoleh dari Platform X, yang berkaitan dengan penerapan teknologi *Artificial Intelligence (AI)* dalam *e-commerce*. Berikut adalah penjelasan rinci mengenai enam tahapan dalam *framework* CRISP-DM yang digunakan dalam penelitian ini[51], [52]:



Gambar 2. 4 Tahapan CRISP-DM

1) *Business Understanding*

Tahap pertama dalam CRISP-DM adalah *Business Understanding*, yang bertujuan untuk memahami konteks bisnis dan masalah yang ingin diselesaikan melalui *data mining*. Pada tahap ini, pemahaman yang jelas tentang tujuan bisnis dan kebutuhan yang mendasari penelitian harus didefinisikan dengan baik. Setelah masalah bisnis dipahami, pengetahuan yang diperoleh akan digunakan untuk merumuskan tujuan dan proses yang diperlukan untuk mencapainya. Dalam penelitian ini, tujuan bisnis adalah untuk memahami bagaimana pengguna Platform X merespons penerapan teknologi *AI* dalam dunia *e-commerce*, sehingga analisis sentimen dari data yang diperoleh dapat memberikan wawasan yang berguna bagi perusahaan dalam mengoptimalkan implementasi *AI* di platform mereka.

2) *Data Understanding*

Setelah memahami bisnis, tahap selanjutnya adalah *Data Understanding*, yang berfokus pada pengumpulan dan eksplorasi data untuk memperoleh wawasan awal tentang data yang ada. Data yang relevan dengan masalah yang ingin diselesaikan dikumpulkan, dan dilakukan analisis untuk memahami karakteristiknya, kualitasnya, serta relevansinya. Pada penelitian ini, data yang digunakan berasal dari komentar atau *tweet* pengguna yang membahas penerapan *AI* di Platform X. Proses ini melibatkan pengumpulan data yang relevan serta identifikasi potensi

masalah dalam data, seperti data yang hilang atau tidak terstruktur, yang dapat mempengaruhi kualitas analisis lebih lanjut.

3) Data Preparation

Setelah memahami data yang ada, tahap berikutnya adalah *Data Preparation*, yaitu tahap yang mempersiapkan data untuk analisis lebih lanjut. Data yang dikumpulkan umumnya dalam bentuk yang tidak langsung siap untuk dianalisis. Oleh karena itu, tahap ini melibatkan serangkaian langkah untuk membersihkan, mengolah, dan mengonversi data ke dalam format yang siap digunakan dalam proses modeling. Tahapan ini termasuk pembersihan data (misalnya menghapus *stopwords* dan karakter yang tidak relevan), transformasi data (seperti *stemming* dan *tokenization*), dan encoding data teks menjadi bentuk yang dapat diproses oleh algoritma *machine learning*. Pada penelitian ini, data berupa teks dari komentar atau *tweet* akan diolah agar bisa diterapkan dalam model *machine learning* untuk analisis sentimen.

4) Modeling

Tahap *Modeling* adalah tahap di mana berbagai algoritma *machine learning* diterapkan untuk membangun model yang diinginkan. Pada tahap ini, model akan dibangun dengan menggunakan teknik yang sesuai untuk masalah yang sedang ditangani. Dalam penelitian ini, teknik modeling yang digunakan adalah *Naïve Bayes*, *Support Vector Machine(SVM)*, dan *Random Forest*. Masing-masing algoritma ini akan diterapkan untuk mengklasifikasikan sentimen pengguna menjadi kategori positif, negatif, atau netral, berdasarkan data yang telah dipersiapkan pada tahap sebelumnya. Pemilihan algoritma didasarkan pada kemampuan mereka untuk menangani data teks yang tidak terstruktur serta akurasi dalam klasifikasi sentimen.

5) Evaluation

Setelah model dibangun pada tahap *Modeling*, tahap selanjutnya adalah *Evaluation*. Evaluasi bertujuan untuk menilai kinerja model yang telah dibangun dengan menggunakan berbagai metrik evaluasi yang relevan. Pada tahap ini, hasil dari model yang dibangun akan diuji untuk

memastikan bahwa model dapat memenuhi tujuan awal penelitian. Metrik yang digunakan dalam evaluasi ini meliputi akurasi, *precision*, *recall*, dan *F1-score*. Jika hasil evaluasi menunjukkan bahwa model berhasil memenuhi tujuan, maka model tersebut siap untuk diterapkan pada dunia nyata. Sebaliknya, jika hasilnya tidak sesuai, maka tahap-tahap sebelumnya akan dievaluasi kembali untuk menemukan area perbaikan.

6) Deployment

Tahap terakhir adalah *Deployment*, yang melibatkan penerapan model yang telah dievaluasi dalam konteks dunia nyata. Pada tahap ini, model yang telah dibangun dan diuji akan digunakan untuk memberikan wawasan yang berguna bagi pengambilan keputusan bisnis. Dalam konteks penelitian ini, model analisis sentimen yang telah diterapkan dapat digunakan oleh perusahaan *e-commerce* untuk memahami sentimen pengguna terhadap teknologi *AI* yang diterapkan pada Platform X. Dengan pemahaman yang lebih baik tentang penerimaan pengguna, perusahaan dapat mengambil langkah-langkah untuk meningkatkan pengalaman pengguna dan optimasi penggunaan teknologi *AI* di platform mereka. Tahap ini juga bisa melibatkan pemeliharaan model untuk memastikan bahwa model tetap relevan seiring berjalannya waktu.

Tabel 2. 2 Tabel Perbandingan Framework

Aspek	CRISP-DM[53]	KDD[53]	SEMMA[53]
Struktur Tahapan	6 Tahapan: Pemahaman Bisnis, Data, Persiapan, Modeling, Evaluasi, Deployment	5 Tahapan: <i>Pre-processing, Selection, Transformation, Data Mining, Evaluation</i>	5 Tahapan: <i>Sample, Explore, Modify, Model, Assess</i>
Fleksibilitas	Sangat fleksibel dan iteratif	Kurang fleksibel	Fleksibel, tapi kurang iteratif
Fokus	Kesesuaian dengan bisnis dan penerapan praktis	Penemuan pengetahuan dari data	Pengembangan model statistik
Pendekatan	Terstruktur, namun adaptif	Fokus pada pengetahuan dari data	Fokus pada model dan statistik
Penerapan Model	Menekankan penerapan dunia nyata	Kurang fokus pada penerapan model	Fokus pada model, kurang aplikasi nyata

Aspek	CRISP-DM[53]	KDD[53]	SEMMA[53]
Evaluasi Model	Menggunakan metrik evaluasi yang jelas	Tidak terstruktur terlalu	Fokus pada evaluasi eksplorasi data


Berdasarkan Tabel 2.2, CRISP-DM dipilih dalam penelitian ini karena metodologinya yang terstruktur namun fleksibel, memungkinkan iterasi di setiap tahapan yang sangat berguna untuk memperbaiki dan mengoptimalkan hasil analisis. CRISP-DM juga sangat menekankan pada pemahaman bisnis yang kuat, yang memastikan bahwa hasil yang diperoleh dari model analisis dapat langsung diterapkan untuk pengambilan keputusan yang relevan di dunia nyata. Berbeda dengan KDD, yang lebih fokus pada eksplorasi data tanpa cukup menekankan pada aplikasi praktisnya, atau SEMMA, yang lebih banyak berfokus pada pengembangan model tanpa adanya komponen evaluasi model secara terstruktur.

Dengan demikian, CRISP-DM memberikan kerangka kerja yang lebih holistik, memungkinkan pengerjaan penelitian ini untuk lebih memahami dan menyelesaikan masalah bisnis secara efektif dan mengembangkan model yang dapat diterapkan langsung dalam pengambilan keputusan dunia nyata. Penekanan pada evaluasi model yang komprehensif dan penerapan hasil yang konkret menjadikan CRISP-DM sebagai framework yang ideal untuk penelitian ini.

2.3.2. Support Vector Machine

Support Vector Machine(SVM) adalah algoritma pembelajaran mesin yang digunakan untuk melakukan klasifikasi data dengan cara mencari *hyperplane* optimal yang memisahkan dua kelas data dengan margin terbesar. SVM bekerja dengan mencari garis atau bidang dalam ruang multidimensi yang dapat memisahkan data dari dua kelas yang berbeda, sehingga data dari kelas yang berbeda berada pada sisi yang berbeda dari *hyperplane*. Konsep utama dalam SVM adalah maksimal

margin, yang berarti margin antara *hyperplane* dan titik data terdekat dari setiap kelas harus diperbesar agar hasil klasifikasi lebih akurat dan lebih dapat digeneralisasi. Dalam hal data yang tidak dapat dipisahkan secara linier, *SVM* menggunakan konsep *kernel* untuk memetakan data ke ruang dimensi yang lebih tinggi, memungkinkan pemisahan yang lebih baik. Fungsi *kernel* yang sering digunakan adalah *kernel* linear, *polynomial*, dan *Radial Basis Function* (RBF)[54], [55], [56]Keunggulan *SVM* adalah kemampuannya untuk menangani data berdimensi tinggi dan memberikan akurasi yang baik meskipun dengan data yang lebih sedikit. Namun, *SVM* juga memiliki kelemahan seperti waktu pelatihan yang lama pada dataset yang besar dan ketergantungan yang tinggi pada pemilihan parameter *kernel* yang tepat untuk mendapatkan hasil yang optimal.



Gambar 2. 5 SVM Hyperplane

Rumus Dasar SVM

Algoritma *SVM* mencari *hyperplane* yang memaksimalkan margin antara dua kelas, dengan rumus dasar sebagai berikut:

$$\min_{(w,b)} \frac{1}{2} \|w\|^2$$

Rumus 2. 1 Rumus untuk Optimasi Margin SVM

Dengan syarat :

$$y_i (w \cdot x_i - b) \geq 1, \forall i$$

Rumus 2. 2 Rumus untuk Pembatasan Syarat Kelas (*Constraint*)

Dimana:

- w adalah vektor bobot yang menentukan arah *hyperplane*.
- b adalah bias atau offset dari *hyperplane*.
- x_i adalah titik data.
- y_i adalah label kelas

Hyperplane dan Margin dalam SVM

SVM mencari *hyperplane* dengan margin terbesar yang memisahkan dua kelas data. *Hyperplane* ini didefinisikan oleh rumus:

$$w \cdot x + b = 0$$

Rumus 2. 3 Rumus untuk *Hyperplane SVM*

- ***Hyperplane*** adalah garis atau batas pemisah antara dua kelas.
- ***Support Vectors*** adalah titik data terdekat dari masing-masing kelas yang menentukan posisi *hyperplane*.
- ***Margin*** adalah jarak antara *support vectors* dari kedua kelas, dan *SVM* memaksimalkan margin ini untuk meningkatkan akurasi klasifikasi.

2.3.3. Naïve Bayes

Naïve Bayes adalah algoritma klasifikasi yang berbasis pada teori probabilitas dan menggunakan pendekatan independensi antar fitur untuk menghitung probabilitas suatu kelas berdasarkan data yang ada[57]. Meskipun asumsi independensi antar fitur sering kali tidak sepenuhnya benar dalam data dunia nyata, *Naïve Bayes* tetap efektif dalam tugas-tugas klasifikasi teks, seperti analisis sentimen, karena kemampuannya untuk menangani data besar dan cepat dalam proses pelatihan[58], [59]. Algoritma ini bekerja dengan menghitung probabilitas kelas berdasarkan


distribusi kata-kata dalam setiap kelas, dengan menggunakan rumus *Teorema Bayes* untuk menghitung probabilitas posterior suatu kelas. Dalam klasifikasi teks, *Naïve Bayes* sering digunakan dengan dua model utama: *Multinomial Naïve Bayes* yang menghitung frekuensi kata dalam dokumen, dan *Bernoulli Naïve Bayes* yang mengandalkan adanya atau tidak adanya kata dalam dokumen. Meskipun sederhana, *Naïve Bayes* dapat memberikan hasil yang baik pada dataset besar dengan sedikit pengaturan.

Teorema Bayes

Naïve Bayes didasarkan pada *teorema Bayes*, yang menyatakan:

$$P(A|B) = \frac{P(B|A) * P(A)}{P(B)}$$

Rumus 2. 4 Rumus untuk *Teorema Bayes*



Gambar 2. 6 *Bayesian Theorem Diagram*

Dimana:

- $P(A | B)$ adalah probabilitas A terjadi jika B terjadi (probabilitas posterior).
- $P(B | A)$ adalah probabilitas B terjadi jika A terjadi (probabilitas likelihood).
- $P(A)$ adalah probabilitas terjadinya A (probabilitas prior).
- $P(B)$ adalah probabilitas terjadinya B (normalisasi).


Dalam *Naïve Bayes*, untuk setiap fitur X_1, X_2, \dots, X_n , algoritma menghitung probabilitas gabungan sebagai berikut:

$$P(C|X_1, X_2, \dots, X_n) = \frac{P(C) \prod_{i=1}^n P(X_i | C)}{P(X_1, X_2, \dots, X_n)}$$

Rumus 2. 5 Rumus untuk Probabilitas Gabungan dalam *Naïve Bayes*

2.3.4. Random Forest

Random Forest adalah algoritma *ensemble learning* yang menggunakan banyak pohon keputusan (*decision trees*) untuk menghasilkan prediksi yang lebih stabil dan akurat. Pada *Random Forest*, sejumlah pohon keputusan dibangun dengan cara mengambil sampel acak dari data dan memilih subset acak dari fitur. Setiap pohon keputusan memberikan prediksi, dan hasil akhir diperoleh dengan cara voting (untuk klasifikasi) atau rata-rata (untuk regresi) dari seluruh pohon yang ada. Pendekatan ini mengurangi *overfitting* yang sering terjadi pada pohon keputusan tunggal dan meningkatkan akurasi model secara keseluruhan. *Random Forest* juga memiliki kemampuan untuk menangani data yang hilang, serta bekerja dengan baik pada data besar dan kompleks. Meskipun metode ini dapat menghasilkan model yang sangat akurat, *Random Forest* cenderung lebih lambat dalam pelatihan dan membutuhkan lebih banyak memori, karena melibatkan banyak pohon keputusan[60], [61].



Gambar 2. 7 Algoritma *Random Forest*

Rumus *Random Forest*:

Untuk tugas klasifikasi, prediksi akhir dilakukan dengan voting mayoritas dari semua pohon keputusan:

$$\hat{y} = \text{mode}(T_1(x), T_2(x), \dots, T_N(x))$$

Rumus 2. 6 Rumus untuk *Random Forest*

Dimana :


- \hat{y} adalah kelas yang diprediksi,
- T_1, T_2, \dots, T_N adalah pohon keputusan individu,
- x adalah faktor fitur input.

2.4 Tools/software yang digunakan

2.4.1. Bahasa Pemrograman *Python*

Python adalah bahasa pemrograman tingkat tinggi yang sangat populer di kalangan *data scientist* dan praktisi *machine learning* karena sintaksisnya yang sederhana dan kemampuannya untuk menangani berbagai jenis aplikasi, dari analisis data hingga pembangunan model *machine learning*. *Python* memiliki ekosistem yang luas dengan berbagai *library* yang sangat berguna, seperti *Pandas* untuk manipulasi data, *NumPy* untuk perhitungan numerik, *Matplotlib* dan *Seaborn* untuk visualisasi data, serta *scikit-learn* dan *TensorFlow* untuk pengembangan model *machine learning*. Berkat fleksibilitas dan kemampuannya dalam menangani data besar, *Python* menjadi pilihan utama dalam penelitian ini untuk analisis sentimen menggunakan algoritma *machine learning*[62], [63].

Keunggulan utama *Python* adalah kemudahan dalam pembelajaran dan penggunaannya, membuatnya menjadi alat yang sangat efektif untuk berbagai tugas pemrograman. Selain itu, *Python* didukung oleh komunitas besar yang menyediakan banyak sumber daya dan dokumentasi, serta terus mengembangkan *library* baru yang semakin memperluas kemampuan bahasa ini. Dengan dukungan ini, *Python* tidak hanya digunakan oleh individu untuk analisis data, tetapi juga oleh perusahaan besar dan lembaga akademik untuk penelitian dan pengembangan.



Gambar 2. 8 Bahasa Pemrograman *Python*

2.4.2. *Jupyter Notebook*

Jupyter Notebook adalah lingkungan pengembangan *open-source* berbasis web yang digunakan sebagai *notebook* interaktif, memungkinkan peneliti untuk mengintegrasikan kode *live* (*Python*), visualisasi data, dan teks naratif dalam satu dokumen. Dalam konteks penelitian *analisis sentimen* ini, *Jupyter Notebook* berfungsi sebagai *Integrated Development Environment* (IDE) utama untuk seluruh proses eksperimen[64].

Keunggulan utama *Jupyter Notebook* adalah kemampuannya untuk menjalankan kode secara sel (*cell*) demi sel. Fitur ini sangat krusial untuk

eksplorasi dan *preprocessing* data, seperti *data cleaning*, *tokenization*, dan *feature extraction*, yang memungkinkan peneliti memantau hasil setiap langkah secara langsung dan interaktif. Selain itu, *tools* ini memfasilitasi *prototyping* cepat dan pelatihan model-model *machine learning* (*SVM*, *Naïve Bayes*, dan *Random Forest*) yang efisien, serta memvisualisasikan hasil analisis dan evaluasi model di tempat yang sama, menyederhanakan alur kerja penelitian.



Gambar 2. 9 Jupyter Notebook

2.4.3. *Streamlit*

Streamlit adalah *framework* Python *open-source* yang dirancang untuk membangun aplikasi web interaktif berbasis data dengan cepat dan tanpa memerlukan pengetahuan *front-end* (HTML, CSS, JavaScript). Dalam penelitian ini, *Streamlit* memainkan peran penting sebagai *tools* utama untuk *deployment* model *machine learning*.



Gambar 2. 10 Streamlit

Streamlit digunakan untuk menyajikan model analisis sentimen yang telah dilatih ke dalam antarmuka web yang *user-friendly* dan dinamis. Tujuannya adalah untuk mendemonstrasikan hasil prediksi model secara *real-time* dan interaktif kepada pengguna atau penguji, seperti memasukkan teks baru dan langsung mendapatkan hasil klasifikasi sentimennya. Dengan sintaksis yang sederhana, *Streamlit* memungkinkan proses *prototyping* dan validasi model menjadi sangat efisien, menjadikannya jembatan penting antara fase pengembangan model dan penyajian hasil penelitian.