

BAB II LANDASAN TEORI

Bab ini menyajikan tinjauan literatur dan teori yang menjadi dasar konseptual dalam pelaksanaan penelitian. Isi dari bab ini mencakup teori-teori yang relevan dan penelitian terdahulu yang memiliki keterkaitan dengan topik kajian. Setiap bagian dalam bab ini disusun secara sistematis untuk memperkuat dasar ilmiah penelitian, memperjelas konteks permasalahan, serta mengidentifikasi ruang penelitian yang dapat diisi melalui studi ini.

2.1 Penelitian Terdahulu

Penelitian terdahulu yang relevan menunjukkan bahwa penerapan analisis sentimen dengan algoritma klasifikasi seperti *Naïve Bayes* telah digunakan secara luas dalam memahami opini masyarakat dari berbagai sumber teks, terutama dalam bentuk ulasan pengguna pada *platform digital*. Penelitian-penelitian tersebut memberikan gambaran tentang bagaimana metode ini bekerja, keefektifannya, serta batasannya. Tabel 2.1 menyajikan beberapa penelitian terdahulu yang menjadi referensi dan pembanding untuk penelitian:

Tabel 2 1 Referensi dan Pembanding

No	Nama Penulis dan Tahun	Judul Penelitian	Metode	Hasil	Analisis Gap
1	Risqi Wahyudi, Herliyani Hasanah, Faulinda Eli Nastiti (2025)	Implementasi Algoritma <i>Naïve Bayes</i> dalam Sistem Analisis Sentimen Aplikasi Zenius pada Playstore	<i>Naïve Bayes</i>	Akurasi tertinggi 76% (<i>train-test split</i> 20%). Sentimen positif mendominasi, <i>precision</i> 95.4%, <i>recall</i> 88.2%, <i>F1-Score</i> 88.3% untuk kelas positif.	Menggunakan algoritma yang sama dan sumber data dari <i>Play Store</i> , tetapi objek kajian berfokus pada aplikasi Zenius yang berorientasi pada kursus daring, sehingga berbeda dalam jenis layanan dan karakteristik

No	Nama Penulis dan Tahun	Judul Penelitian	Metode	Hasil	Analisis Gap
					interaksi pengguna.
2	Yahya Aliya Rohim, Vihi Atina, Sundari (2024)	Analisis Sentimen terhadap Ulasan Aplikasi Ruangguru Menggunakan Algoritma <i>Naïve Bayes</i>	<i>Naïve Bayes</i>	Sentimen positif 75%, netral 20%, negatif 5%. Akurasi dihitung manual berdasarkan proporsi distribusi.	Sama-sama membahas aplikasi edukasi menggunakan <i>Naïve Bayes</i> , pendekatan evaluasi tidak mencakup metrik klasifikasi seperti <i>confusion matrix</i> dan akurasi model secara empiris. Fokus utama juga tertuju pada layanan pendidikan berbasis video.
3	Depro Winoto, Veven Desta Aditia, dkk. (2024)	Analisis Sentimen Pada Ulasan Pengguna Terhadap Aplikasi Pembelajaran Bahasa Duolingo: Menggunakan Algoritma <i>Naïve Bayes</i> Dan <i>K-Nearest Neighbor</i>	<i>Naïve Bayes</i> , KNN	<i>Naïve Bayes</i> : Akurasi 92%, <i>precision</i> 93%, <i>recall</i> 92%. KNN: Akurasi 88%.	Menggunakan pendekatan komparatif antara dua algoritma klasifikasi. Objek penelitian berupa aplikasi pembelajaran bahasa asing dengan metode gamifikasi, sehingga berbeda dalam jenis konten edukatif dan pengalaman pengguna.
4	Fandhilah & Angga Ardiansyah (2023)	Analisis Sentimen Aplikasi Quizizz pada <i>Google Play</i>	<i>Naïve Bayes</i>	Menggunakan 2000 data ulasan (1000 positif, 1000 negatif) dari	Menggunakan algoritma yang sama namun hanya membedakan

No	Nama Penulis dan Tahun	Judul Penelitian	Metode	Hasil	Analisis Gap
		<i>Store Menggunakan Naïve Bayes</i>		<i>Google Play Store</i> . Hasil akurasi sebesar 79,01%, <i>recall</i> positif 87,4%, <i>recall</i> negatif 70,6%, dan nilai AUC 0,785.	dua kelas sentimen (positif dan negatif) tanpa kelas netral. Selain itu, data diambil dari satu sumber (<i>Google Play Store</i>) dan belum dibandingkan dengan algoritma lain untuk melihat performa model yang lebih optimal.
5	Frencis Matheos Sarimole & Kudrat (2024)	Analisis Sentimen Terhadap Aplikasi Satu Sehat Pada Twitter Menggunakan Algoritma <i>Naïve Bayes</i> dan <i>Support Vector Machine</i>	<i>Naïve Bayes, SVM</i>	Menggunakan ±1080 tweet dengan kata kunci “SatuSehat” dari Twitter. Hasil akurasi <i>Naïve Bayes</i> sebesar 81,65% dan SVM sebesar 87,95%, menunjukkan bahwa SVM lebih unggul dalam klasifikasi sentimen.	Penelitian membandingkan dua algoritma tetapi hanya fokus pada dua label sentimen (positif dan negatif). Tidak dilakukan analisis mendalam terhadap topik atau aspek sentimen tertentu. Selain itu, sumber data terbatas pada Twitter dan periode pengambilan hanya tahun 2023.

2.1.1 Risqi Wahyudi, Herliyani Hasanah, dan Faulinda Eli Nastiti (2025)

Wahyudi, Hasanah, dan Nastiti (2025) melakukan penelitian yang berfokus pada analisis sentimen ulasan pengguna aplikasi Zenius yang diambil dari platform

Google Play Store. Aplikasi Zenius merupakan salah satu aplikasi pendidikan digital yang menyediakan layanan pembelajaran berbasis video dan latihan soal, sehingga ulasan pengguna menjadi indikator penting untuk menilai kualitas layanan dan kepuasan pengguna. Dalam penelitian tersebut, sentimen ulasan diklasifikasikan ke dalam tiga kategori utama, yaitu sentimen positif, netral, dan negatif, yang umum digunakan dalam penelitian analisis sentimen. Metode yang digunakan dalam penelitian ini adalah Naïve Bayes Classifier, yang dikenal sebagai salah satu algoritma klasifikasi berbasis probabilistik yang cukup efektif untuk pengolahan data teks. Peneliti melakukan beberapa skenario pembagian data latih dan data uji (train-test split) untuk mengetahui konfigurasi terbaik dalam menghasilkan performa klasifikasi yang optimal. Dari beberapa percobaan tersebut, diperoleh hasil terbaik pada pembagian 80% data latih dan 20% data uji, dengan tingkat akurasi mencapai 76%. Hasil ini menunjukkan bahwa model Naïve Bayes mampu mengenali pola kata dalam ulasan pengguna Zenius dengan cukup baik, khususnya dalam mengklasifikasikan ulasan bernada positif. Penelitian ini memiliki keterkaitan yang kuat dengan penelitian penulis, terutama dari sisi sumber data yang sama-sama berasal dari Google Play Store serta penggunaan metode Naïve Bayes sebagai algoritma utama dalam klasifikasi sentimen. Namun demikian, terdapat perbedaan mendasar yang membedakan kedua penelitian tersebut. Penelitian Wahyudi dkk. berfokus pada aplikasi Zenius yang menerapkan model pembelajaran satu arah (konten pembelajaran disediakan oleh sistem), sedangkan penelitian penulis berfokus pada aplikasi Brainly, yang memiliki karakteristik berbeda karena berbasis interaksi tanya jawab antar pengguna. Perbedaan karakteristik ini berpotensi menghasilkan pola bahasa dan sentimen yang berbeda, sehingga penelitian penulis diharapkan dapat memberikan kontribusi baru dalam konteks analisis sentimen aplikasi pendidikan berbasis komunitas.

2.1.2 Yahya Aliya Rohim, Vihi Atina, dan Sundari (2024)

Rohim, Atina, dan Sundari (2024) melakukan penelitian untuk mengetahui sentimen pengguna terhadap aplikasi Ruangguru, salah satu aplikasi pendidikan populer di Indonesia. Tujuan utama penelitian ini adalah untuk memperoleh gambaran umum mengenai persepsi dan kepuasan pengguna berdasarkan ulasan yang diberikan di platform digital. Dalam penelitian tersebut, metode Naïve Bayes

digunakan untuk mengelompokkan ulasan ke dalam kategori sentimen positif, netral, dan negatif. Hasil penelitian menunjukkan bahwa sebagian besar ulasan pengguna (sekitar 75%) memiliki sentimen positif, yang mengindikasikan bahwa mayoritas pengguna merasa puas terhadap layanan yang disediakan oleh aplikasi Ruangguru. Temuan ini memberikan informasi yang bermanfaat bagi pengembang aplikasi dalam mempertahankan kualitas layanan serta meningkatkan aspek-aspek yang masih mendapat ulasan negatif. Meskipun penelitian ini relevan dengan penelitian penulis karena sama-sama mengkaji aplikasi pendidikan dan menggunakan metode Naïve Bayes, terdapat perbedaan yang cukup signifikan dalam aspek metodologi evaluasi. Penelitian Rohim dkk. lebih menekankan pada perhitungan persentase sentimen secara deskriptif tanpa melakukan pengujian performa model secara kuantitatif, seperti pengukuran akurasi, precision, recall, atau F1-Score. Dengan kata lain, penelitian tersebut belum sepenuhnya mengevaluasi kemampuan model dalam melakukan klasifikasi secara objektif. Berbeda dengan penelitian tersebut, penelitian penulis tidak hanya menghitung distribusi sentimen, tetapi juga melakukan pengujian model secara terukur dan sistematis, sehingga hasil klasifikasi dapat dipertanggungjawabkan secara ilmiah. Oleh karena itu, penelitian penulis diharapkan dapat melengkapi kekurangan penelitian sebelumnya dengan memberikan analisis performa model yang lebih mendalam pada aplikasi Brainly.

2.1.3 Depro Winoto, Veven Desta Aditia, Cinda Sorisa, Ressa Priskila, dan Viktor H. Pranatawijaya (2024)

Winoto dan tim (2024) melakukan penelitian yang bertujuan untuk membandingkan kinerja dua metode klasifikasi, yaitu Naïve Bayes dan K-Nearest Neighbor (KNN), dalam menganalisis sentimen ulasan pengguna aplikasi Duolingo. Duolingo merupakan aplikasi pembelajaran bahasa asing yang memiliki basis pengguna global, sehingga ulasan pengguna menjadi sumber data yang kaya untuk dianalisis. Dalam penelitian ini, peneliti mengumpulkan ulasan pengguna dan melakukan proses preprocessing teks sebelum menerapkan kedua algoritma klasifikasi. Hasil penelitian menunjukkan bahwa Naïve Bayes memberikan performa yang lebih baik dibandingkan metode KNN, dengan tingkat akurasi mencapai 92%, sedangkan KNN menghasilkan akurasi yang lebih rendah. Temuan

ini mengindikasikan bahwa Naïve Bayes lebih sesuai untuk klasifikasi data teks yang memiliki dimensi tinggi dan jumlah fitur yang besar. Penelitian ini memiliki kesamaan dengan penelitian penulis, khususnya dalam penggunaan Naïve Bayes sebagai metode klasifikasi sentimen dan objek penelitian berupa aplikasi pembelajaran. Namun, terdapat perbedaan pada fokus penelitian. Winoto dkk. lebih menitikberatkan pada perbandingan antar algoritma, sedangkan penelitian penulis berfokus pada analisis sentimen pengguna aplikasi Brainly sebagai forum diskusi pendidikan. Selain itu, Brainly memiliki karakteristik bahasa yang lebih variatif karena berisi pertanyaan, jawaban, dan diskusi antar pengguna, sehingga penelitian penulis diharapkan dapat memperluas penerapan metode Naïve Bayes pada konteks yang berbeda.

2.1.4 Fandhilah dan Ardiansyah (2023)

Fandhilah dan Ardiansyah (2023) melakukan penelitian analisis sentimen terhadap ulasan pengguna aplikasi Quizizz yang diperoleh dari Google Play Store. Penelitian ini menggunakan dataset yang seimbang, yaitu masing-masing 1.000 ulasan positif dan 1.000 ulasan negatif. Penggunaan data seimbang bertujuan untuk mengurangi bias klasifikasi dan meningkatkan performa model. Dalam penelitian ini, peneliti memanfaatkan perangkat lunak RapidMiner sebagai alat bantu dalam proses klasifikasi sentimen dengan metode Naïve Bayes. Hasil pengujian menunjukkan bahwa metode Naïve Bayes mampu mencapai tingkat akurasi sekitar 79%, yang menunjukkan bahwa algoritma tersebut cukup efektif dalam mengklasifikasikan sentimen ulasan pengguna. Persamaan penelitian ini dengan penelitian penulis terletak pada sumber data yang sama-sama berasal dari Google Play Store serta penggunaan metode Naïve Bayes sebagai algoritma utama. Namun, terdapat perbedaan dari segi objek penelitian. Quizizz merupakan aplikasi pembelajaran berbasis permainan kuis (gamifikasi), sedangkan Brainly merupakan platform diskusi berbasis tanya jawab. Perbedaan karakteristik aplikasi ini menyebabkan perbedaan pola bahasa dan ekspresi sentimen, sehingga penelitian penulis memberikan perspektif baru dalam analisis sentimen aplikasi pendidikan non-gamifikasi.

2.1.5 Frencis Matheos Sarimole dan Kudrat (2024)

Penelitian oleh Sarimole dan Kudrat (2024) melakukan penelitian yang bertujuan untuk menganalisis sentimen masyarakat terhadap aplikasi SatuSehat dengan menggunakan data yang diambil dari media sosial Twitter. Penelitian ini membandingkan dua metode klasifikasi yang populer dalam analisis sentimen, yaitu Naïve Bayes dan Support Vector Machine (SVM), untuk mengetahui metode yang menghasilkan performa terbaik. Hasil penelitian menunjukkan bahwa SVM memiliki tingkat akurasi yang lebih tinggi, yaitu sebesar 87,95%, dibandingkan dengan Naïve Bayes. Hal ini menunjukkan bahwa SVM lebih mampu menangani kompleksitas data teks yang bersumber dari media sosial, yang umumnya memiliki bahasa informal, singkatan, dan variasi kata yang tinggi. Penelitian ini sangat relevan dengan penelitian penulis karena memiliki kesamaan dalam tujuan metodologis, yaitu membandingkan performa Naïve Bayes dan SVM. Namun, terdapat perbedaan yang signifikan pada jenis data dan konteks penelitian. Sarimole dan Kudrat menggunakan data Twitter dengan topik kesehatan masyarakat, sedangkan penelitian penulis menggunakan data ulasan Google Play Store dengan topik pendidikan, khususnya aplikasi Brainly. Perbedaan konteks ini memungkinkan adanya perbedaan hasil dan memberikan kontribusi ilmiah baru dalam penerapan metode klasifikasi sentimen pada bidang pendidikan digital.

2.2 Landasan Teori

Landasan teori berfungsi sebagai fondasi konseptual yang menopang implementasi dan analisis dalam sebuah riset. Penelitian ini secara khusus memanfaatkan beberapa konsep krusial seperti analisis sentimen, algoritma *Naïve Bayes*, aplikasi *Brainly*, data teks serta ulasan pengguna, *text preprocessing*, dan evaluasi model klasifikasi. Kumpulan teori ini memiliki peran sentral dalam membentuk kerangka kerja konseptual dan pendekatan teknis untuk menganalisis sentimen dari ulasan pengguna aplikasi *Brainly*. Pemahaman mendalam terhadap masing-masing teori ini menjadi esensial untuk menjamin validitas metode dan ketajaman analisis yang dihasilkan.

2.2.1 Aplikasi *Brainly*

Perkembangan teknologi digital telah mendorong pemanfaatan aplikasi pembelajaran daring sebagai sarana pendukung proses belajar. Aplikasi

pembelajaran daring memungkinkan siswa untuk mengakses sumber belajar secara fleksibel serta berinteraksi dengan pengguna lain tanpa dibatasi oleh ruang dan waktu. Salah satu aplikasi pembelajaran berbasis komunitas yang banyak digunakan oleh pelajar adalah Brainly. Brainly menyediakan layanan tanya jawab yang memungkinkan pengguna untuk saling membantu dalam menyelesaikan permasalahan akademik. Keberadaan Brainly sebagai platform pembelajaran daring menjadikannya relevan untuk dibahas dalam kajian landasan teori penelitian ini.

2.2.1.1 Pengertian Aplikasi Pembelajaran Daring

Perkembangan teknologi informasi dan komunikasi telah mendorong terjadinya transformasi dalam berbagai bidang kehidupan, salah satunya dalam bidang pendidikan. Proses pembelajaran yang sebelumnya didominasi oleh metode tatap muka secara langsung kini mulai beralih ke arah pembelajaran berbasis digital melalui pemanfaatan aplikasi dan platform daring. Aplikasi pembelajaran daring merupakan perangkat lunak yang dirancang untuk mendukung proses belajar mengajar dengan memanfaatkan jaringan internet sebagai media utama penyampaian informasi. Aplikasi jenis ini memungkinkan pengguna untuk mengakses materi pembelajaran, berdiskusi, serta melakukan aktivitas belajar lainnya tanpa dibatasi oleh ruang dan waktu. Aplikasi pembelajaran daring memiliki karakteristik utama berupa fleksibilitas akses, interaktivitas, serta ketersediaan sumber belajar yang beragam. Fleksibilitas akses memungkinkan pengguna untuk belajar kapan saja dan di mana saja sesuai dengan kebutuhan masing-masing. Interaktivitas ditunjukkan melalui adanya fitur komunikasi dua arah antara pengguna, baik dalam bentuk diskusi, tanya jawab, maupun kolaborasi. Selain itu, aplikasi pembelajaran daring juga menyediakan berbagai sumber belajar yang dapat berasal dari pengembang aplikasi maupun dari kontribusi pengguna itu sendiri. Dengan karakteristik tersebut, aplikasi pembelajaran daring berperan sebagai sarana pendukung pembelajaran formal maupun nonformal. Konteks pendidikan modern, aplikasi pembelajaran daring tidak dimaksudkan untuk menggantikan sepenuhnya proses pembelajaran di kelas, melainkan berfungsi sebagai media pendukung yang melengkapi pembelajaran konvensional. Aplikasi ini membantu siswa dalam memahami materi pelajaran secara lebih mendalam,

mengerjakan tugas, serta memperluas wawasan melalui diskusi dengan pengguna lain. Salah satu aplikasi pembelajaran daring yang banyak digunakan oleh pelajar adalah Brainly.

2.2.1.2 Profil Umum Aplikasi Brainly

Brainly merupakan sebuah platform pembelajaran daring yang dikembangkan dengan pendekatan berbasis komunitas, di mana pengguna dapat saling membantu dalam menyelesaikan permasalahan akademik melalui mekanisme tanya jawab. Aplikasi ini berfungsi sebagai forum diskusi terbuka yang memungkinkan pelajar untuk mengajukan pertanyaan terkait materi pelajaran tertentu, kemudian memperoleh jawaban dari pengguna lain yang memiliki pemahaman terhadap topik tersebut. Brainly dirancang untuk menciptakan lingkungan belajar kolaboratif yang mendorong partisipasi aktif antar pengguna. Aplikasi Brainly ditujukan untuk pelajar dari berbagai jenjang pendidikan, mulai dari Sekolah Dasar (SD), Sekolah Menengah Pertama (SMP), hingga Sekolah Menengah Atas (SMA). Selain itu, Brainly juga dapat dimanfaatkan oleh mahasiswa maupun tenaga pendidik sebagai sarana berbagi pengetahuan. Materi pembelajaran yang tersedia di dalam aplikasi ini mencakup berbagai mata pelajaran yang umum diajarkan di sekolah, seperti Matematika, Bahasa Indonesia, Bahasa Inggris, Ilmu Pengetahuan Alam, dan Ilmu Pengetahuan Sosial. Keberagaman mata pelajaran tersebut menjadikan Brainly sebagai aplikasi yang dapat digunakan oleh siswa dengan latar belakang kebutuhan belajar yang berbeda-beda. Brainly tersedia dalam bentuk aplikasi berbasis Android serta platform berbasis web, sehingga dapat diakses melalui berbagai perangkat. Kemudahan akses ini menjadi salah satu faktor yang mendorong tingginya tingkat penggunaan Brainly di kalangan pelajar. Dengan antarmuka yang relatif sederhana dan mudah digunakan, pengguna dapat dengan cepat mengajukan pertanyaan maupun memberikan jawaban tanpa memerlukan keahlian teknis khusus.

2.2.1.3 Mekanisme Kerja dan Fitur Aplikasi Brainly

Platform pembelajaran berbasis komunitas, Brainly mengandalkan kontribusi pengguna dalam menyediakan konten pembelajaran. Seluruh pertanyaan dan jawaban yang tersedia di dalam aplikasi berasal dari pengguna itu sendiri, sehingga aktivitas belajar tidak hanya bersifat satu arah, tetapi melibatkan partisipasi aktif

antar anggota komunitas. Pengguna dapat mengajukan pertanyaan terkait materi pelajaran yang belum dipahami, kemudian pengguna lain dapat memberikan jawaban sesuai dengan pengetahuan yang dimiliki. Brainly menyediakan berbagai fitur pendukung yang dirancang untuk meningkatkan kualitas interaksi antar pengguna. Salah satu fitur utama adalah sistem tanya jawab yang memungkinkan pengguna untuk mengajukan pertanyaan secara spesifik sesuai mata pelajaran yang dipilih. Selain itu, terdapat fitur penilaian jawaban, di mana pengguna dapat memberikan tanggapan atau penilaian terhadap jawaban yang dianggap membantu. Fitur ini berfungsi sebagai mekanisme umpan balik untuk menilai kualitas jawaban yang diberikan. Sistem tanya jawab, Brainly juga menerapkan sistem gamifikasi berupa poin dan peringkat pengguna. Pengguna yang aktif memberikan jawaban berkualitas akan memperoleh poin yang dapat meningkatkan reputasi mereka di dalam komunitas. Sistem ini bertujuan untuk mendorong partisipasi aktif serta memotivasi pengguna agar memberikan jawaban yang relevan dan bermanfaat. Dengan adanya mekanisme tersebut, Brainly berupaya menciptakan ekosistem belajar yang kolaboratif dan berkelanjutan.

2.2.1.4 Peran Aplikasi Brainly Dalam Pembelajaran

Brainly dirancang sebagai sarana pendukung kegiatan belajar siswa di luar proses pembelajaran formal di kelas. Aplikasi ini sering dimanfaatkan untuk membantu siswa dalam mengerjakan pekerjaan rumah, menyelesaikan tugas sekolah, maupun memahami materi yang belum sepenuhnya dipahami saat pembelajaran berlangsung. Dengan adanya Brainly, siswa dapat memperoleh bantuan belajar secara cepat tanpa harus menunggu penjelasan langsung dari guru. Dalam konteks pembelajaran mandiri, Brainly memberikan kesempatan kepada siswa untuk belajar secara aktif dengan cara mencari solusi atas permasalahan yang dihadapi. Proses bertanya dan menjawab di dalam aplikasi ini dapat melatih kemampuan berpikir kritis serta mendorong siswa untuk memahami konsep, bukan sekadar menyalin jawaban. Selain itu, interaksi dengan pengguna lain memungkinkan terjadinya pertukaran sudut pandang yang dapat memperkaya pemahaman siswa terhadap suatu materi. Berdasarkan penelitian yang dilakukan oleh (Nugroho, 2021), Brainly tercatat sebagai salah satu aplikasi pembelajaran yang banyak digunakan oleh siswa dalam mendukung aktivitas belajar mereka. Aplikasi ini dianggap mampu

membantu siswa dalam memenuhi berbagai kewajiban akademik, terutama yang berkaitan dengan penyelesaian tugas dan latihan soal. Temuan tersebut menunjukkan bahwa Brainly memiliki peran yang cukup signifikan sebagai media pembelajaran tambahan yang dikenal luas di kalangan pelajar.

2.2.1.5 Kelebihan dan Keterbatasan Aplikasi Brainly

Aplikasi pembelajaran daring berbasis komunitas, Brainly memiliki sejumlah kelebihan yang menjadikannya populer di kalangan pelajar. Salah satu kelebihan utama Brainly adalah kemudahan akses dan fleksibilitas penggunaan. Pengguna dapat mengakses aplikasi ini kapan saja dan di mana saja selama terhubung dengan jaringan internet. Selain itu, keberagaman materi dan banyaknya pengguna memungkinkan siswa untuk memperoleh berbagai alternatif jawaban terhadap satu permasalahan. Brainly juga memiliki sejumlah keterbatasan yang perlu diperhatikan. Karena seluruh konten berasal dari kontribusi pengguna, kualitas jawaban yang tersedia tidak selalu terjamin kebenarannya. Terdapat kemungkinan jawaban yang diberikan kurang tepat, tidak lengkap, atau bahkan menyesatkan. Selain itu, beberapa pengguna cenderung memanfaatkan Brainly hanya untuk memperoleh jawaban secara instan tanpa berusaha memahami konsep yang mendasarinya. Keterbatasan lainnya berkaitan dengan adanya perbedaan kualitas bahasa dan penyampaian jawaban. Ulasan dan jawaban yang ditulis oleh pengguna sering kali menggunakan bahasa informal, singkatan, atau struktur kalimat yang kurang baku. Kondisi ini dapat mempengaruhi pemahaman pengguna lain serta menimbulkan ambiguitas dalam penafsiran makna. Oleh karena itu, diperlukan evaluasi terhadap kualitas konten yang tersedia di dalam aplikasi Brainly.

2.2.1.6 Ilustrasi Aplikasi Brainly

Gambar 2.1 menampilkan logo resmi aplikasi Brainly yang berfungsi sebagai identitas visual dari platform pembelajaran daring tersebut. Logo ini merepresentasikan Brainly sebagai media belajar berbasis komunitas yang mengedepankan kolaborasi dan pertukaran pengetahuan antar pengguna.



Gambar 2. 1 Logo Aplikasi Brainly

Selanjutnya, Gambar 2.2 memperlihatkan tampilan antarmuka aplikasi Brainly yang menunjukkan fitur utama berupa sistem tanya jawab. Pada tampilan tersebut, pengguna dapat mengajukan pertanyaan terkait materi pembelajaran, melihat pertanyaan dari pengguna lain, serta memberikan atau menerima jawaban yang relevan. Antarmuka ini dirancang untuk memudahkan interaksi antar pengguna dalam proses belajar.



Gambar 2. 2 Isi Aplikasi Brainly

Ilustrasi pada Gambar 2.1 dan Gambar 2.2 memberikan gambaran umum mengenai bentuk dan fungsi aplikasi Brainly sebagai platform pembelajaran berbasis komunitas. Melalui sistem tanya jawab dan interaksi pengguna, Brainly menjadi sarana pendukung pembelajaran mandiri yang memanfaatkan kontribusi pengetahuan dari komunitas penggunanya.

2.2.2 Data Teks dan Ulasan Pengguna

Data teks merupakan salah satu bentuk data digital yang memiliki peran penting dalam penelitian di bidang pengolahan bahasa alami dan analisis sentimen.

Seiring dengan perkembangan teknologi informasi, data teks semakin mudah diperoleh dari berbagai platform digital yang digunakan oleh masyarakat. Salah satu sumber data teks yang banyak dimanfaatkan dalam penelitian adalah ulasan pengguna, karena secara langsung mencerminkan pendapat dan pengalaman pengguna terhadap suatu produk atau layanan. Ulasan pengguna umumnya mengandung informasi subjektif yang merepresentasikan tingkat kepuasan maupun ketidakpuasan pengguna. Pemahaman terhadap karakteristik data teks dan ulasan pengguna menjadi dasar penting dalam melakukan analisis sentimen secara komputasional.

2.2.2.1 Pengertian Data Teks

Data teks merupakan salah satu bentuk data digital yang banyak digunakan dalam penelitian di bidang pengolahan bahasa alami (Natural Language Processing/NLP) dan analisis sentimen. Data ini tersusun atas rangkaian kata, frasa, atau kalimat yang disajikan dalam bentuk teks bebas, sehingga tidak memiliki struktur baku seperti data numerik atau data tabular. Berbeda dengan data terstruktur yang tersimpan dalam baris dan kolom, data teks bersifat tidak terstruktur (unstructured data), sehingga membutuhkan pendekatan dan teknik khusus agar dapat diolah dan dianalisis secara komputasional. Ketidakteraturan struktur pada data teks menjadikannya memiliki tingkat kompleksitas yang tinggi. Informasi yang terkandung di dalam data teks tidak dapat langsung diproses oleh mesin tanpa melalui tahapan transformasi tertentu. Mesin atau algoritma pembelajaran mesin tidak mampu memahami makna kata atau kalimat secara langsung sebagaimana manusia, sehingga diperlukan proses representasi data teks ke dalam bentuk numerik sebelum dilakukan analisis lebih lanjut. Oleh karena itu, pemahaman mengenai konsep dasar dan karakteristik data teks menjadi aspek yang sangat penting dalam penelitian yang berfokus pada analisis opini atau sentimen pengguna. Data teks juga memiliki sifat kontekstual, di mana makna suatu kata atau kalimat dapat berubah tergantung pada konteks penggunaannya. Sebuah kata dapat memiliki makna positif dalam satu konteks, namun bermakna negatif dalam konteks yang berbeda. Selain itu, data teks sering kali mengandung unsur subjektivitas, emosi, dan opini pribadi penulis, yang membuat proses analisis menjadi lebih menantang. Dalam penelitian analisis sentimen, data teks menjadi

objek utama karena mengandung informasi yang merepresentasikan sikap, perasaan, dan penilaian individu terhadap suatu objek tertentu.

2.2.2.2 Karakteristik Data Teks

Data teks memiliki sejumlah karakteristik yang membedakannya dari jenis data lainnya. Salah satu karakteristik utama data teks adalah sifatnya yang tidak terstruktur dan heterogen. Data teks dapat terdiri dari kata-kata pendek, kalimat panjang, hingga paragraf yang kompleks, dengan variasi gaya bahasa yang sangat beragam. Hal ini menyebabkan data teks tidak memiliki format baku yang dapat langsung dianalisis menggunakan metode statistik konvensional. Data teks umumnya mengandung ambiguitas makna. Ambiguitas ini dapat muncul akibat penggunaan kata-kata bermakna ganda, ironi, sarkasme, atau ungkapan kiasan. Dalam konteks analisis sentimen, ambiguitas menjadi salah satu tantangan utama karena sebuah kalimat dapat mengandung lebih dari satu emosi atau kecenderungan sentimen. Sebagai contoh, kalimat yang mengandung pujian namun disertai kritik dapat sulit dikategorikan secara tegas sebagai sentimen positif atau negatif. Karakteristik lain dari data teks adalah adanya variasi bahasa yang sangat luas. Data teks yang berasal dari pengguna internet sering kali tidak mengikuti kaidah bahasa formal. Pengguna dapat menuliskan kata dengan singkatan, menggunakan bahasa gaul, mencampurkan bahasa asing, atau melakukan kesalahan penulisan. Kondisi ini menyebabkan data teks mentah (raw text) perlu melalui proses pembersihan dan normalisasi sebelum dapat digunakan sebagai input model analisis sentimen.

2.2.2.3 Ulasan Pengguna Sebagai Sumber Data Teks

Ulasan pengguna merupakan salah satu sumber data teks yang paling banyak dimanfaatkan dalam penelitian analisis sentimen. Ulasan ini biasanya ditemukan pada platform digital seperti media sosial, forum diskusi, situs e-commerce, dan platform distribusi aplikasi. Ulasan pengguna berisi pendapat, pengalaman, serta penilaian subjektif pengguna terhadap suatu produk atau layanan, sehingga sangat relevan untuk dianalisis dalam konteks kepuasan dan persepsi pengguna. Platform distribusi aplikasi seperti Google Play Store, pengguna diberikan kebebasan untuk menuliskan ulasan setelah menggunakan suatu aplikasi. Ulasan tersebut umumnya mencerminkan pengalaman nyata pengguna, baik pengalaman positif maupun negatif. Informasi yang terkandung dalam ulasan pengguna dapat menjadi sumber

masukannya yang berharga bagi pengembang aplikasi maupun peneliti untuk memahami kelebihan, kekurangan, serta permasalahan yang dialami pengguna. Menurut (Nurwanda dkk., 2024), ulasan pengguna pada Google Play Store memiliki karakteristik bahasa yang khas, yaitu cenderung tidak terstruktur, bersifat informal, dan mengandung berbagai variasi gaya penulisan. Pengguna sering kali menuliskan ulasan secara singkat, menggunakan bahasa sehari-hari, serta menyertakan ekspresi emosional secara langsung. Kondisi ini menjadikan ulasan pengguna sebagai data yang kaya informasi, namun sekaligus menantang untuk dianalisis secara otomatis.

2.2.2.4 Karakteristik Bahasa pada Ulasan Pengguna

Bahasa yang digunakan dalam ulasan pengguna memiliki karakteristik yang berbeda dengan bahasa pada teks formal seperti artikel ilmiah atau dokumen resmi. Salah satu ciri utama ulasan pengguna adalah penggunaan bahasa santai dan tidak baku. Pengguna sering menggunakan kata-kata informal, singkatan, serta istilah populer yang berkembang di masyarakat. Ulasan pengguna juga kerap mengandung kesalahan penulisan, baik berupa salah ketik (typo) maupun penggunaan ejaan yang tidak sesuai dengan kaidah bahasa. Penggunaan emotikon, simbol, dan tanda baca berlebihan juga sering ditemukan dalam ulasan pengguna. Unsur-unsur tersebut dapat memengaruhi hasil analisis sentimen apabila tidak ditangani dengan baik pada tahap pra-proses teks. Variasi panjang teks juga menjadi karakteristik lain dari ulasan pengguna. Sebagian pengguna menuliskan ulasan dalam bentuk satu atau dua kata saja, sedangkan pengguna lain menuliskan ulasan yang panjang dan detail. Perbedaan panjang teks ini dapat memengaruhi representasi fitur dan kinerja model klasifikasi sentimen, sehingga perlu diperhatikan dalam proses pengolahan data.

2.2.2.5 Tantangan Pengolahan Data Ulasan Pengguna

Pengolahan data ulasan pengguna menghadapi berbagai tantangan, terutama karena sifat data yang tidak terstruktur dan beragam. Salah satu tantangan utama adalah keberadaan noise pada data, seperti kata-kata tidak relevan, simbol, dan karakter khusus. Noise ini dapat mengganggu proses ekstraksi fitur dan menurunkan akurasi model analisis sentimen. Tantangan lainnya adalah subjektivitas dan ambiguitas sentimen. Sebuah ulasan dapat mengandung lebih dari satu sentimen, misalnya pujian terhadap fitur tertentu namun disertai keluhan

terhadap aspek lain. Kondisi ini menyulitkan proses pelabelan sentimen, terutama jika hanya menggunakan satu label sentimen untuk setiap ulasan. Penggunaan bahasa campuran atau multilingual juga sering ditemukan pada ulasan pengguna di Indonesia. Pengguna dapat mencampurkan bahasa Indonesia dengan bahasa Inggris atau bahasa daerah dalam satu ulasan. Hal ini menambah kompleksitas dalam proses pengolahan teks, terutama pada tahap tokenisasi dan stemming.

2.2.3 Analisis Sentimen

Analisis sentimen merupakan salah satu teknik dalam bidang *Natural Language Processing* yang digunakan untuk mengidentifikasi dan mengklasifikasikan opini atau sikap pengguna yang terkandung dalam data teks. Teknik ini bertujuan untuk mengetahui kecenderungan sentimen suatu teks, apakah bersifat positif, negatif, atau netral terhadap objek tertentu. Seiring meningkatnya penggunaan platform digital, jumlah data teks yang dihasilkan oleh pengguna juga semakin besar dan beragam. Kondisi tersebut menjadikan analisis sentimen sebagai pendekatan yang efektif untuk mengekstraksi informasi subjektif dari data teks secara otomatis. Analisis sentimen banyak dimanfaatkan dalam berbagai bidang, termasuk evaluasi ulasan pengguna terhadap aplikasi berbasis digital.

2.2.3.1 Pengertian Analisis Sentimen

Analisis sentimen merupakan salah satu cabang penting dalam bidang *Natural Language Processing* (NLP) yang berfokus pada pengenalan, pengelompokan, serta interpretasi opini, emosi, dan sikap seseorang yang terkandung dalam suatu teks. Analisis sentimen sering pula disebut sebagai *opinion mining*, yaitu proses penambangan opini dari data tekstual untuk memperoleh informasi mengenai kecenderungan perasaan atau penilaian terhadap suatu objek tertentu, seperti produk, layanan, organisasi, maupun peristiwa. Teknik ini digunakan untuk menentukan kecenderungan sentimen penulis teks, apakah bersifat positif, negatif, atau netral terhadap suatu objek tertentu. Menurut (Prasetyo dkk., 2023), analisis sentimen bertujuan untuk mengekstraksi informasi subjektif dari data teks sehingga dapat dimanfaatkan sebagai dasar dalam proses pengambilan keputusan. Informasi subjektif tersebut mencerminkan persepsi, kepuasan, keluhan, maupun harapan pengguna terhadap suatu layanan atau sistem.

Secara konseptual, analisis sentimen menggabungkan pendekatan linguistik dan komputasional untuk memahami makna emosional dalam bahasa alami. Bahasa yang digunakan manusia bersifat kompleks, ambigu, dan kontekstual, sehingga tidak dapat diproses secara langsung oleh komputer tanpa melalui tahapan transformasi tertentu. Oleh karena itu, analisis sentimen memerlukan metode pemrosesan bahasa alami yang mampu mengubah teks tidak terstruktur menjadi representasi yang dapat diolah secara matematis oleh sistem komputasi. Perkembangan teknologi informasi dan komunikasi mendorong meningkatnya jumlah data teks yang dihasilkan oleh pengguna, khususnya melalui platform digital seperti media sosial, forum diskusi, dan toko aplikasi. Kondisi tersebut menjadikan analisis sentimen sebagai teknik yang semakin relevan dalam mengolah *big data* berbasis teks untuk memperoleh wawasan yang bernilai bagi berbagai pihak.

2.2.3.2 Tujuan dan Manfaat Analisis Sentimen

Analisis sentimen memiliki tujuan utama untuk mengidentifikasi dan mengklasifikasikan opini yang terkandung dalam suatu teks ke dalam kategori sentimen tertentu. Klasifikasi ini umumnya dibagi menjadi tiga kelas utama, yaitu positif, negatif, dan netral. Kategori positif menunjukkan adanya penilaian yang mendukung atau memuaskan, kategori negatif mencerminkan ketidakpuasan atau kritik, sedangkan kategori netral menunjukkan opini yang bersifat informatif atau ambigu tanpa kecenderungan emosional yang jelas.

Selain untuk klasifikasi sentimen, analisis sentimen juga bertujuan untuk:

1. Mengidentifikasi pola persepsi pengguna terhadap suatu produk atau layanan.
2. Menyediakan informasi pendukung bagi pengambilan keputusan strategis.
3. Mengevaluasi kualitas layanan atau sistem berdasarkan umpan balik pengguna.
4. Meningkatkan pemahaman terhadap kebutuhan dan harapan pengguna.

Manfaat analisis sentimen sangat luas dan mencakup berbagai sektor. Dalam bidang bisnis, analisis sentimen digunakan untuk memantau reputasi merek, memahami kepuasan pelanggan, serta mengevaluasi efektivitas strategi pemasaran. Dalam bidang pemerintahan, teknik ini dimanfaatkan untuk mengukur respons masyarakat terhadap kebijakan publik. Sementara itu, dalam bidang teknologi informasi, analisis sentimen digunakan untuk mengevaluasi kualitas aplikasi atau

sistem berdasarkan ulasan pengguna. Penelitian ini, analisis sentimen dimanfaatkan untuk mengkaji ulasan pengguna aplikasi Brainly dengan tujuan memperoleh gambaran mengenai persepsi pengguna terhadap kualitas layanan aplikasi. Informasi tersebut diharapkan dapat memberikan kontribusi dalam memahami kelebihan dan kekurangan aplikasi secara sistematis berdasarkan data empiris.

2.2.3.3 Penerapan Analisis Sentimen dalam Berbagai Bidang

Perkembangan analisis sentimen telah mendorong penerapannya di berbagai sektor, baik di bidang bisnis, layanan publik, pendidikan, maupun pengembangan perangkat lunak. Pada sektor pemasaran digital, analisis sentimen digunakan untuk memahami respons konsumen terhadap produk, merek, atau kampanye promosi yang dilakukan oleh perusahaan. Informasi yang diperoleh dapat digunakan untuk merancang strategi pemasaran yang lebih efektif dan berorientasi pada kebutuhan pelanggan. Bidang layanan publik, analisis sentimen dimanfaatkan untuk mengevaluasi tingkat kepuasan masyarakat terhadap kebijakan, program, maupun pelayanan yang diberikan oleh instansi pemerintah. Melalui analisis terhadap komentar dan keluhan masyarakat, pemerintah dapat mengidentifikasi permasalahan yang perlu diperbaiki serta meningkatkan kualitas pelayanan publik. Dalam bidang pendidikan, analisis sentimen digunakan untuk mengkaji respons siswa terhadap sistem pembelajaran daring, platform edukasi, maupun materi pembelajaran. Evaluasi berbasis opini pengguna menjadi penting untuk meningkatkan efektivitas pembelajaran serta kualitas layanan pendidikan digital. Sementara itu, dalam pengembangan perangkat lunak, analisis sentimen digunakan untuk mengolah ulasan pengguna guna mengidentifikasi kelebihan dan kekurangan suatu aplikasi secara sistematis. Ulasan pengguna yang tersedia di platform seperti Google Play Store dan App Store menjadi sumber data yang kaya untuk mengevaluasi kualitas aplikasi. Melalui analisis sentimen, pengembang dapat memperoleh informasi mengenai aspek yang perlu dipertahankan maupun ditingkatkan. Penerapan analisis sentimen dalam penelitian ini berfokus pada ulasan pengguna aplikasi Brainly. Ulasan tersebut mencerminkan pengalaman pengguna secara langsung dalam menggunakan aplikasi, sehingga memiliki nilai yang penting sebagai dasar evaluasi kualitas layanan aplikasi pendidikan.

2.2.3.4 Karakteristik Data dalam Analisis Sentimen

Data yang digunakan dalam analisis sentimen umumnya berupa teks bebas, seperti komentar, ulasan, atau cuitan di media sosial. Data teks tersebut memiliki karakteristik yang tidak terstruktur dan mengandung unsur subjektivitas yang tinggi. Tidak seperti data numerik yang tersusun rapi dalam bentuk tabel, data teks sering kali mengandung variasi bahasa, kesalahan penulisan, singkatan, emotikon, serta gaya bahasa informal. Karakteristik utama data teks dalam analisis sentimen meliputi:

1. Tidak terstruktur, sehingga memerlukan proses transformasi sebelum dapat dianalisis.
2. Mengandung subjektivitas, karena mencerminkan opini dan perasaan individu.
3. Mengandung ambiguitas, di mana satu kalimat dapat memiliki lebih dari satu makna tergantung konteks.
4. Menggunakan bahasa informal, terutama pada platform digital.

Data ulasan pengguna sering kali memiliki panjang teks yang bervariasi, mulai dari kalimat singkat hingga paragraf panjang. Hal ini menimbulkan tantangan tersendiri dalam proses analisis, karena sistem harus mampu memahami konteks dan makna dari berbagai bentuk ekspresi bahasa. Pendekatan komputasional yang mampu mengolah dan mengklasifikasikan data teks secara efektif. Pendekatan tersebut melibatkan tahapan praproses teks, ekstraksi fitur, serta penerapan algoritma klasifikasi untuk menentukan kategori sentimen.

2.2.4 BERT

Bidirectional Encoder Representations from Transformers (BERT) merupakan salah satu model bahasa berbasis *deep learning* yang banyak digunakan dalam bidang pemrosesan bahasa alami (*Natural Language Processing*). Model ini dikembangkan oleh Google AI untuk menghasilkan representasi teks yang bersifat kontekstual dengan memanfaatkan arsitektur Transformer. BERT banyak diterapkan dalam berbagai tugas NLP, termasuk klasifikasi teks dan analisis sentimen.

2.2.4.1 Pengertian BERT

Bidirectional Encoder Representations from Transformers (BERT) merupakan sebuah model bahasa berbasis *deep learning* yang dikembangkan oleh Google AI dan diperkenalkan pertama kali oleh Devlin et al. pada tahun 2018. BERT dirancang untuk menghasilkan representasi teks yang bersifat kontekstual dengan memanfaatkan arsitektur *Transformer*, khususnya pada bagian *encoder*. Representasi kontekstual yang dihasilkan BERT memungkinkan model memahami makna kata berdasarkan konteks kalimat secara menyeluruh, bukan hanya berdasarkan kata itu sendiri. Berbeda dengan model bahasa sebelumnya yang umumnya memproses teks secara satu arah, BERT menggunakan pendekatan *bidirectional*, yaitu mempelajari konteks kata dari arah kiri dan kanan secara bersamaan. Pendekatan ini memungkinkan BERT menangkap hubungan semantik yang lebih kompleks dalam suatu kalimat. Menurut (Chandradev dkk., 2023), kemampuan memahami konteks dua arah menjadikan BERT unggul dalam berbagai tugas pemrosesan bahasa alami (*Natural Language Processing*), seperti klasifikasi teks, ekstraksi informasi, *question answering*, dan analisis sentimen. Keunggulan utama BERT terletak pada kemampuannya membangun pemahaman bahasa yang lebih mendalam, sehingga model ini banyak diadopsi dalam penelitian dan pengembangan sistem berbasis teks, termasuk dalam analisis ulasan pengguna pada aplikasi digital.

2.2.4.2 Arsitektur Transformer pada BERT

BERT dibangun berdasarkan arsitektur *Transformer* yang diperkenalkan oleh Vaswani et al. Arsitektur Transformer mengandalkan mekanisme *self-attention* untuk memproses urutan kata dalam teks tanpa menggunakan struktur berurutan seperti *Recurrent Neural Network* (RNN). Dalam BERT, hanya bagian *encoder* dari Transformer yang digunakan, sementara bagian *decoder* tidak diterapkan. Setiap *encoder* pada BERT terdiri dari beberapa komponen utama, yaitu *multi-head self-attention* dan *feed-forward neural network*. Mekanisme *self-attention* memungkinkan model untuk menentukan tingkat kepentingan setiap kata terhadap kata lainnya dalam satu kalimat. Dengan demikian, BERT dapat memahami hubungan antar kata secara lebih fleksibel dan efisien, terutama pada kalimat yang panjang dan kompleks. BERT umumnya menggunakan beberapa lapisan *encoder*

yang ditumpuk (*stacked encoders*). Sebagai contoh, model BERT Base menggunakan 12 lapisan encoder, sedangkan BERT Large menggunakan 24 lapisan encoder. Semakin banyak lapisan yang digunakan, semakin dalam pula pemahaman konteks yang dapat dipelajari oleh model, meskipun konsekuensinya adalah meningkatnya kebutuhan sumber daya komputasi.

2.2.4.3 Konsep Bidirectional Encoding

Salah satu karakteristik utama BERT adalah kemampuannya melakukan *bidirectional encoding*. Pada model bahasa satu arah, konteks kata hanya dipahami dari satu sisi, misalnya dari kiri ke kanan. Pendekatan ini menyebabkan keterbatasan dalam memahami makna kata yang sangat bergantung pada kata setelahnya. Pendekatan bidirectional, BERT mempelajari konteks kata dengan mempertimbangkan seluruh kata dalam satu kalimat secara simultan. Sebagai contoh, kata “bank” dalam kalimat dapat memiliki makna yang berbeda tergantung pada konteksnya, apakah berkaitan dengan lembaga keuangan atau tepi sungai. Pendekatan bidirectional memungkinkan BERT memahami perbedaan makna tersebut secara lebih akurat. Kemampuan ini sangat penting dalam pemrosesan bahasa alami, khususnya pada analisis sentimen, karena sentimen suatu kalimat sering kali ditentukan oleh hubungan antar kata secara keseluruhan, bukan oleh satu kata tunggal. Oleh karena itu, penggunaan BERT memberikan keuntungan signifikan dalam memahami nuansa dan konteks emosi dalam teks ulasan pengguna.

2.2.4.4 Proses Pre-Training pada BERT

Membangun pemahaman bahasa yang kuat, BERT dilatih melalui tahap *pre-training* menggunakan data teks dalam jumlah besar. Pada tahap ini, BERT mempelajari pola bahasa secara umum tanpa diarahkan pada tugas tertentu. Proses *pre-training* BERT dilakukan menggunakan dua tugas utama, yaitu *Masked Language Model* (MLM) dan *Next Sentence Prediction* (NSP). *Masked Language Model* (MLM) bertujuan untuk melatih model memprediksi kata yang disembunyikan (*masked*) dalam sebuah kalimat. Sebagian kata dalam kalimat sengaja dihilangkan atau diganti dengan token khusus, kemudian model dilatih untuk menebak kata yang hilang tersebut berdasarkan konteks sekitarnya. Teknik ini memungkinkan BERT memahami hubungan antar kata secara dua arah. *Next*

Sentence Prediction (NSP) digunakan untuk melatih model dalam memahami hubungan antar kalimat. Pada tugas ini, model diberikan sepasang kalimat dan diminta untuk menentukan apakah kalimat kedua merupakan kelanjutan dari kalimat pertama atau tidak. NSP membantu BERT memahami struktur wacana dan hubungan logis antar kalimat, yang penting dalam tugas-tugas seperti klasifikasi teks dan analisis sentimen berbasis konteks kalimat.

2.2.4.5 Proses Fine Tuning pada BERT

Tahap *pre-training*, BERT dapat disesuaikan (*fine-tuning*) untuk tugas-tugas spesifik dalam pemrosesan bahasa alami. Pada tahap *fine-tuning*, model BERT yang telah dilatih sebelumnya digunakan sebagai dasar, kemudian ditambahkan lapisan keluaran (*output layer*) sesuai dengan kebutuhan tugas yang diinginkan. Analisis sentimen, lapisan keluaran biasanya berupa lapisan klasifikasi yang memetakan representasi teks ke dalam kelas sentimen, seperti positif, negatif, dan netral. Proses *fine-tuning* dilakukan dengan melatih ulang model menggunakan dataset berlabel, sehingga BERT dapat menyesuaikan pemahamannya terhadap karakteristik data yang digunakan dalam penelitian.

Keunggulan utama dari pendekatan *fine-tuning* adalah efisiensi dan fleksibilitasnya. Peneliti tidak perlu melatih model dari awal, melainkan cukup menyesuaikan model yang telah memiliki pemahaman bahasa yang kuat. Hal ini menjadikan BERT sangat populer dalam penelitian NLP, termasuk pada analisis ulasan pengguna aplikasi.

2.2.4.6 BERT dalam Analisis Sentimen

Analisis sentimen, BERT digunakan untuk menghasilkan representasi teks yang mampu menangkap konteks dan makna emosional secara lebih akurat. Representasi kontekstual ini sangat berguna dalam memahami ulasan pengguna yang sering kali mengandung bahasa informal, ironi, atau ambiguitas. Penggunaan BERT memungkinkan sistem analisis sentimen untuk menentukan kelas sentimen berdasarkan pemahaman konteks kalimat secara menyeluruh, bukan hanya berdasarkan kemunculan kata-kata tertentu. Hal ini sangat relevan dalam ulasan pengguna aplikasi, di mana satu kalimat dapat mengandung pujian sekaligus kritik. Memanfaatkan BERT, proses pelabelan sentimen dapat dilakukan secara otomatis

dengan tingkat akurasi yang lebih tinggi dibandingkan metode tradisional. Oleh karena itu, BERT sering digunakan sebagai dasar dalam sistem klasifikasi sentimen modern, termasuk dalam penelitian ini sebagai metode pelabelan otomatis data ulasan pengguna.

2.2.4.7 Kelebihan dan Keterbatasan BERT

BERT memiliki sejumlah kelebihan yang menjadikannya unggul dalam pemrosesan bahasa alami. Salah satu kelebihan utamanya adalah kemampuan memahami konteks dua arah, sehingga menghasilkan representasi teks yang lebih kaya dan akurat. Selain itu, BERT bersifat fleksibel karena dapat disesuaikan untuk berbagai tugas NLP melalui proses *fine-tuning*. Namun demikian, BERT juga memiliki keterbatasan. Model ini membutuhkan sumber daya komputasi yang relatif besar, baik dari segi memori maupun waktu pelatihan. Selain itu, proses *fine-tuning* BERT memerlukan dataset yang cukup besar agar model dapat bekerja secara optimal. Keterbatasan ini perlu diperhatikan dalam penerapan BERT, terutama pada lingkungan dengan keterbatasan sumber daya. Performa BERT yang unggul dalam berbagai tugas pemrosesan bahasa alami menjadikannya salah satu model bahasa yang paling banyak digunakan dalam penelitian dan aplikasi analisis sentimen hingga saat ini.

2.2.5 Naïve Bayes

Naïve Bayes merupakan salah satu algoritma klasifikasi berbasis probabilistik yang banyak digunakan dalam bidang *Machine Learning*, khususnya pada pengolahan dan klasifikasi data teks. Algoritma ini bekerja berdasarkan Teorema Bayes dengan pendekatan statistik untuk menentukan probabilitas suatu data termasuk ke dalam kelas tertentu. *Naïve Bayes* dikenal sebagai metode yang sederhana namun efisien karena memiliki proses komputasi yang cepat dan mudah diimplementasikan. Algoritma ini sering digunakan dalam penelitian analisis sentimen sebagai metode dasar dalam klasifikasi teks.

2.2.5.1 Pengertian Algoritma Naïve Bayes

Naïve Bayes merupakan salah satu algoritma klasifikasi yang banyak digunakan dalam bidang *Machine Learning*, khususnya pada pengolahan dan klasifikasi data teks. Algoritma ini termasuk ke dalam metode klasifikasi probabilistik yang bekerja berdasarkan pendekatan statistik. *Naïve Bayes*

memanfaatkan prinsip probabilitas untuk menentukan kemungkinan suatu data termasuk ke dalam kelas tertentu berdasarkan pola yang dipelajari dari data sebelumnya. Algoritma Naïve Bayes didasarkan pada Teorema Bayes, yang menjelaskan hubungan antara probabilitas suatu kejadian dengan probabilitas bersyarat dari kejadian tersebut. Dalam konteks klasifikasi, algoritma ini digunakan untuk menghitung probabilitas sebuah dokumen atau data uji terhadap setiap kelas yang tersedia, kemudian memilih kelas dengan probabilitas tertinggi sebagai hasil prediksi. Naïve Bayes dikenal sebagai metode yang sederhana namun efektif, terutama dalam kasus klasifikasi teks dengan jumlah data yang besar. Kesederhanaan algoritma ini terletak pada pendekatan matematisnya yang relatif mudah dipahami serta proses komputasi yang efisien. Oleh karena itu, Naïve Bayes sering digunakan sebagai *baseline model* dalam penelitian analisis sentimen dan *text classification*.

2.2.5.2 Taroma Bayes sebagai dasar Algoritma Naïve Bayes

Dasar teori utama dari algoritma Naïve Bayes adalah Teorema Bayes, yang dikemukakan oleh Thomas Bayes. Teorema ini menjelaskan bagaimana memperbarui probabilitas suatu hipotesis berdasarkan bukti atau data baru yang diperoleh. Dalam klasifikasi teks, hipotesis yang dimaksud adalah kelas sentimen, sedangkan bukti berupa kata-kata yang muncul dalam sebuah dokumen. Rumus umum Teorema Bayes dapat dituliskan sebagai berikut:

$$P(c|x) = \frac{P(x|c) \times P(c)}{P(x)} \quad (1)$$

Keterangan:

1. $P(c|x)$: Probabilitas posterior untuk kelas c berdasarkan data x
2. $P(c)$: Probabilitas awal (prior) kelas c
3. $P(x|c)$: Probabilitas data x jika diketahui kelas c
4. $P(x)$: Probabilitas awal data x

2.2.5.3 Prinsip Independen Naïve Bayes

Ciri utama yang membedakan Naïve Bayes dengan algoritma klasifikasi lainnya adalah adanya asumsi independensi antar fitur. Dalam konteks data teks, fitur yang dimaksud adalah kata-kata yang terdapat dalam dokumen. Algoritma ini mengasumsikan bahwa setiap kata dalam sebuah dokumen bersifat independen satu

sama lain terhadap kelas yang diprediksi. Asumsi ini disebut sebagai *naïve* atau sederhana karena pada kenyataannya kata-kata dalam sebuah kalimat sering kali saling berkaitan dan membentuk makna tertentu. Sebagai contoh, pada kalimat “*aplikasinya cukup membantu tetapi sering error*”, kata “*membantu*” dan “*error*” memiliki hubungan semantik yang dapat memengaruhi makna keseluruhan kalimat. Asumsi independensi ini tidak sepenuhnya realistis, dalam praktiknya Naïve Bayes tetap mampu menghasilkan performa yang baik. Hal ini disebabkan oleh kemampuannya dalam menangkap pola distribusi kata pada masing-masing kelas, sehingga kesalahan akibat asumsi independensi sering kali dapat ditoleransi oleh model.

2.2.5.4 Naïve Bayes dalam Klasifikasi Teks

Klasifikasi teks, Naïve Bayes bekerja dengan menghitung probabilitas kemunculan setiap kata pada masing-masing kelas. Proses ini diawali dengan tahap pelatihan (*training*), di mana model mempelajari distribusi kata dari data latih yang telah diberi label. Setiap kata akan memiliki probabilitas tertentu untuk muncul pada kelas positif, negatif, atau netral. Ketika sebuah dokumen baru diuji, model akan mengalikan probabilitas kata-kata yang terdapat dalam dokumen tersebut untuk setiap kelas. Hasil perkalian ini kemudian dikombinasikan dengan probabilitas prior dari masing-masing kelas untuk menghasilkan nilai probabilitas akhir. Kelas dengan nilai probabilitas tertinggi akan ditetapkan sebagai hasil klasifikasi. Pendekatan ini menjadikan Naïve Bayes sangat cocok untuk data teks yang berdimensi tinggi, seperti ulasan pengguna, karena mampu menangani jumlah fitur yang besar dengan waktu komputasi yang relatif cepat.

2.2.5.5 Jenis Naïve Bayes yang digunakan dalam Analisis Teks

Terdapat beberapa varian algoritma Naïve Bayes, antara lain *Gaussian Naïve Bayes*, *Bernoulli Naïve Bayes*, dan *Multinomial Naïve Bayes*. Dalam analisis teks, varian yang paling umum digunakan adalah Multinomial Naïve Bayes. Multinomial Naïve Bayes dirancang untuk data yang merepresentasikan frekuensi kemunculan kata. Algoritma ini sangat sesuai digunakan bersama metode ekstraksi fitur seperti *Bag of Words* atau *TF-IDF*, yang menghasilkan nilai numerik berdasarkan frekuensi kata dalam dokumen. Penggunaan Multinomial Naïve Bayes memungkinkan model

untuk menangkap perbedaan distribusi kata antar kelas sentimen secara lebih efektif, sehingga meningkatkan akurasi klasifikasi pada data teks.

2.2.5.6 Kelebihan dan Keterbatasan Algoritma Naïve Bayes

Naïve Bayes memiliki beberapa kelebihan yang menjadikannya populer dalam penelitian analisis sentimen. Menurut (Ramadhani & Wahyudin, 2022), algoritma ini mudah digunakan, cepat dalam proses pelatihan, serta mampu menghasilkan akurasi yang cukup tinggi untuk klasifikasi teks. Kelebihan lain dari Naïve Bayes adalah kebutuhan sumber daya komputasi yang rendah, sehingga cocok digunakan pada dataset berukuran besar. Selain itu, algoritma ini juga relatif stabil terhadap data yang tidak seimbang, terutama jika dilakukan penyesuaian pada probabilitas prior. Banyak kelebihan, Naïve Bayes juga memiliki beberapa keterbatasan. Salah satu kelemahan utama algoritma ini adalah asumsi independensi antar kata, yang tidak selalu sesuai dengan struktur bahasa alami. Hal ini dapat menyebabkan model kurang mampu menangkap konteks dan makna kalimat secara menyeluruh. Naïve Bayes cenderung kurang optimal ketika dihadapkan pada data yang sangat kompleks atau kelas yang jarang muncul (*minority class*). Dalam kondisi tersebut, probabilitas yang dihasilkan bisa menjadi tidak stabil dan memengaruhi hasil klasifikasi.

2.2.5.7 Relevansi Naïve Bayes dalam Penelitian ini

Penelitian ini, algoritma Naïve Bayes digunakan sebagai salah satu metode klasifikasi sentimen terhadap ulasan pengguna aplikasi Brainly. Pemilihan algoritma ini didasarkan pada karakteristik data ulasan yang berupa teks pendek dengan jumlah data yang relatif besar. Naïve Bayes diharapkan mampu memberikan gambaran performa klasifikasi sentimen berbasis probabilistik, serta menjadi pembanding terhadap metode lain yang digunakan dalam penelitian ini, seperti Support Vector Machine. Dengan demikian, hasil evaluasi model dapat memberikan analisis yang lebih komprehensif terhadap efektivitas masing-masing algoritma dalam mengklasifikasikan sentimen ulasan pengguna.

2.2.6 Support Vector Machine

Penelitian analisis sentimen, pemilihan algoritma klasifikasi memegang peranan penting dalam menentukan kualitas hasil klasifikasi. Salah satu algoritma

yang sering digunakan adalah Support Vector Machine (SVM), yang mampu menangani data teks berdimensi tinggi dan memiliki performa yang stabil dalam mengklasifikasikan sentimen pengguna.

2.2.6.1 Pengertian Support Vector Machine

Support Vector Machine merupakan salah satu algoritma pembelajaran mesin yang banyak digunakan dalam permasalahan klasifikasi dan regresi, khususnya pada data berdimensi tinggi seperti data teks. SVM memiliki pendekatan yang berbeda dibandingkan algoritma klasifikasi lainnya karena tidak hanya berfokus pada tingkat kesalahan klasifikasi, tetapi juga pada upaya memaksimalkan batas pemisah antar kelas. Algoritma ini bekerja dengan cara mencari sebuah garis batas pemisah terbaik, yang dikenal sebagai *hyperplane*, untuk memisahkan data ke dalam dua kelas atau lebih secara optimal. Tujuan utama SVM adalah menemukan *hyperplane* dengan margin terbesar, yaitu jarak maksimum antara *hyperplane* dan titik data terdekat dari masing-masing kelas. Titik data yang berada paling dekat dengan *hyperplane* tersebut disebut sebagai *support vector*. *Support vector* memiliki peran yang sangat penting karena posisi *hyperplane* sepenuhnya ditentukan oleh titik-titik ini. Dengan memaksimalkan margin, SVM diharapkan mampu menghasilkan model yang lebih stabil dan memiliki kemampuan generalisasi yang baik terhadap data baru. Analisis sentimen, SVM banyak digunakan karena kemampuannya dalam menangani data teks yang memiliki jumlah fitur sangat besar, terutama setelah proses ekstraksi fitur seperti TF-IDF. Karakteristik ini menjadikan SVM sebagai salah satu algoritma yang efektif untuk mengklasifikasikan opini atau sentimen pengguna ke dalam kategori tertentu seperti positif, netral, dan negatif.

2.2.6.2 Konsep Hyperplane dan Margin

Hyperplane merupakan garis atau bidang pemisah yang digunakan oleh SVM untuk membedakan data antar kelas. Pada data dua dimensi, *hyperplane* direpresentasikan sebagai sebuah garis lurus, sedangkan pada data tiga dimensi berupa sebuah bidang. Namun, pada data berdimensi tinggi seperti data teks, *hyperplane* tidak dapat divisualisasikan secara langsung, melainkan direpresentasikan dalam bentuk persamaan matematis. Margin adalah jarak antara

hyperplane dengan support vector terdekat dari masing-masing kelas. SVM berusaha untuk memaksimalkan margin ini agar pemisahan antar kelas menjadi semakin jelas. Margin yang besar menunjukkan bahwa model memiliki tingkat kepercayaan yang lebih tinggi dalam membedakan data antar kelas, sehingga mengurangi risiko kesalahan klasifikasi pada data uji. Secara matematis, fungsi keputusan SVM dapat dituliskan sebagai berikut:

$$f(x) = w^T x + b \quad (2)$$

Keterangan:

1. w : vektor bobot yang menentukan arah hyperplane
2. x : vektor fitur dari data
3. b : bias (konstanta pergeseran hyperplane)
4. $f(x)$: fungsi keputusan untuk menentukan kelas data

2.2.6.3 Support Vector dan Prinsip kerja Support Vector Machine

Support vector adalah sejumlah kecil data yang berada paling dekat dengan hyperplane dan memiliki pengaruh paling besar terhadap pembentukan model SVM. Tidak seperti algoritma lain yang menggunakan seluruh data latih untuk membangun model, SVM hanya bergantung pada support vector dalam menentukan posisi hyperplane. Hal ini membuat SVM relatif efisien dan tidak terlalu dipengaruhi oleh data yang berada jauh dari batas pemisah. Prinsip kerja SVM dimulai dengan memetakan data ke dalam ruang fitur, kemudian mencari hyperplane yang mampu memisahkan kelas dengan margin maksimum. Proses ini dilakukan melalui optimasi matematis dengan meminimalkan fungsi kesalahan sekaligus memaksimalkan margin. SVM mampu mengatasi permasalahan overfitting dan menghasilkan model yang lebih robust. Analisis sentimen, setiap dokumen teks direpresentasikan sebagai vektor numerik hasil dari proses ekstraksi fitur. SVM kemudian mempelajari pola distribusi vektor tersebut untuk membedakan sentimen positif, netral, dan negatif berdasarkan posisi relatifnya terhadap hyperplane.

2.2.6.4 Kernel Trick pada Support Vector Machine

Salah satu keunggulan utama SVM adalah kemampuannya dalam menangani data non-linear melalui mekanisme yang dikenal sebagai *kernel trick*. Kernel trick

memungkinkan data yang tidak dapat dipisahkan secara linear pada ruang asli diproyeksikan ke ruang berdimensi lebih tinggi, sehingga dapat dipisahkan secara linear. Beberapa jenis kernel yang umum digunakan dalam SVM antara lain:

1. Kernel Linear, digunakan ketika data relatif dapat dipisahkan secara linear.
2. Kernel Polynomial, cocok untuk data dengan hubungan non-linear tingkat tertentu.
3. Kernel Radial Basis Function (RBF), sering digunakan karena fleksibilitasnya dalam memetakan data non-linear.

Pemilihan kernel yang tepat sangat memengaruhi kinerja SVM. Pada data teks, kernel linear sering digunakan karena efisien dan mampu memberikan performa yang baik pada data berdimensi tinggi. Namun, pada kasus tertentu dengan pola yang lebih kompleks, kernel non-linear seperti RBF dapat memberikan hasil yang lebih optimal.

2.2.6.5 Parameter dalam Support Vector Machine

Kinerja SVM sangat dipengaruhi oleh pengaturan parameter yang digunakan. Salah satu parameter utama adalah parameter regularisasi C , yang berfungsi untuk mengontrol trade-off antara margin yang besar dan kesalahan klasifikasi. Nilai C yang besar cenderung menghasilkan margin yang lebih kecil namun kesalahan klasifikasi lebih sedikit, sedangkan nilai C yang kecil menghasilkan margin yang lebih besar dengan toleransi kesalahan yang lebih tinggi. Kernel non-linear terdapat parameter tambahan seperti gamma pada kernel RBF, yang menentukan sejauh mana pengaruh satu data terhadap data lainnya. Pengaturan parameter yang tidak tepat dapat menyebabkan model mengalami overfitting atau underfitting. Oleh karena itu, proses tuning parameter menjadi tahap penting dalam penerapan SVM agar diperoleh performa klasifikasi yang optimal. Setelah memahami parameter utama SVM, penting juga untuk mengetahui kelebihan dan kekurangan algoritma ini agar dapat menilai kecocokannya dalam analisis sentimen.

2.2.6.6 Kelebihan dan Kekurangan Support Vector Machine

Menurut (Choirunnisa dkk., 2021), SVM memiliki beberapa kelebihan, antara lain mampu mengklasifikasikan data secara linear maupun non-linear dengan tingkat akurasi yang baik serta memiliki konsep matematis yang jelas dan sistematis. Selain itu, SVM efektif digunakan pada data berdimensi tinggi dan

relatif tahan terhadap overfitting, terutama pada jumlah data yang terbatas. SVM juga memiliki beberapa kekurangan. Algoritma ini memerlukan proses tuning parameter yang cermat agar dapat bekerja secara optimal. Selain itu, SVM cenderung memiliki waktu komputasi yang lebih lama ketika diterapkan pada dataset berukuran besar. Hasil klasifikasi SVM juga sangat bergantung pada kualitas data dan proses preprocessing, terutama pada data teks yang bersifat tidak terstruktur.

2.2.6.7 Support Vector Machine dalam Analisis Sentimen

Penelitian analisis sentimen, SVM sering digunakan sebagai algoritma pembanding karena performanya yang stabil dan konsisten. Kombinasi antara SVM dan metode ekstraksi fitur seperti TF-IDF terbukti efektif dalam mengklasifikasikan sentimen pada ulasan pengguna aplikasi. SVM mampu mempelajari pola kata dan distribusi fitur yang mencerminkan kecenderungan sentimen pengguna. Penelitian ini, SVM digunakan untuk mengklasifikasikan ulasan pengguna aplikasi Brainly ke dalam kategori sentimen tertentu. Dengan memanfaatkan keunggulan SVM dalam menangani data teks berdimensi tinggi, diharapkan model dapat menghasilkan performa klasifikasi yang baik dan menjadi pembanding yang relevan terhadap algoritma Naïve Bayes. Selain pemilihan algoritma, tahapan text processing juga memegang peranan krusial untuk memastikan data teks siap dianalisis secara efektif.

2.2.7 Text Processing

Text Processing atau praproses teks merupakan tahapan awal yang sangat penting dalam penelitian yang melibatkan data teks, khususnya pada analisis sentimen dan pengolahan bahasa alami. Menurut (Harjanta, 2015), *text processing* adalah proses untuk membersihkan, menormalkan, dan menyederhanakan data teks mentah agar dapat diolah secara efektif oleh sistem komputer.

2.2.7.1 Case Folding

Case folding merupakan tahap awal dalam text processing yang bertujuan untuk menyeragamkan bentuk huruf dalam teks. Pada tahap ini, seluruh huruf dalam dokumen teks diubah menjadi huruf kecil (lowercase). Proses ini dilakukan untuk menghindari perbedaan makna yang disebabkan oleh variasi penulisan huruf besar dan huruf kecil. Sebagai contoh, kata “Bagus”, “bagus”, dan “BAGUS”

secara semantik memiliki makna yang sama, namun tanpa case folding kata-kata tersebut akan dianggap sebagai token yang berbeda oleh sistem. Analisis sentimen, case folding berperan penting untuk menyederhanakan representasi data teks. Ulasan pengguna pada aplikasi Brainly sering kali ditulis secara tidak konsisten, baik dari segi penggunaan huruf kapital di awal kalimat maupun pada kata-kata tertentu untuk menekankan emosi. Dengan menerapkan case folding, variasi penulisan tersebut dapat dinormalisasi sehingga jumlah fitur yang dihasilkan menjadi lebih sedikit dan lebih relevan. Hal ini berdampak positif pada efisiensi komputasi dan akurasi model klasifikasi yang digunakan.

2.2.7.2 Tokenizing

Tokenizing adalah proses memecah teks menjadi unit-unit yang lebih kecil yang disebut token. Token biasanya berupa kata, frasa, atau simbol tertentu tergantung pada kebutuhan analisis. Dalam penelitian analisis sentimen berbasis teks, token umumnya berupa kata tunggal (unigram). Proses tokenizing dilakukan dengan cara memisahkan teks berdasarkan spasi dan tanda baca. Tokenizing memiliki peran penting dalam mengubah teks yang semula berbentuk kalimat panjang menjadi daftar kata yang dapat diproses lebih lanjut oleh algoritma. Pada ulasan pengguna Brainly, satu kalimat dapat mengandung lebih dari satu opini atau ekspresi emosi. Dengan memecah kalimat menjadi token, sistem dapat menganalisis setiap kata secara individual untuk menentukan kontribusinya terhadap sentimen keseluruhan. Proses ini menjadi dasar bagi tahap-tahap lanjutan seperti penghapusan stopword dan pembobotan kata menggunakan metode tertentu.

2.2.7.3 Stopword Removal

Stopword removal merupakan tahap text processing yang bertujuan untuk menghapus kata-kata umum yang sering muncul dalam teks tetapi tidak memiliki makna penting terhadap analisis sentimen. Contoh stopword dalam bahasa Indonesia antara lain “dan”, “yang”, “di”, “ke”, dan “dari”. Kata-kata tersebut berfungsi sebagai penghubung dalam kalimat, namun tidak memberikan informasi emosional atau opini pengguna. Penghapusan stopword dilakukan untuk mengurangi jumlah fitur yang tidak relevan sehingga model klasifikasi dapat lebih fokus pada kata-kata yang memiliki nilai sentimen. Dalam ulasan pengguna aplikasi Brainly, kata-kata yang mencerminkan opini seperti “membantu”, “bagus”, “error”,

atau “sulit” jauh lebih penting dibandingkan kata penghubung. Dengan menghilangkan stopwords, proses analisis menjadi lebih efisien dan risiko noise dalam data dapat diminimalkan. Namun demikian, pemilihan daftar stopwords harus dilakukan dengan hati-hati agar tidak menghilangkan kata yang berpotensi memengaruhi makna sentimen.

2.2.7.4 Stemming

Stemming adalah proses mengubah kata berimbuhan menjadi bentuk kata dasar. Dalam bahasa Indonesia, satu kata dapat memiliki berbagai bentuk akibat penggunaan prefiks, sufiks, infiks, maupun konfiks. Sebagai contoh, kata “membantu”, “dibantu”, dan “bantuan” memiliki akar kata yang sama, yaitu “bantu”. Tanpa stemming, kata-kata tersebut akan dianggap sebagai fitur yang berbeda oleh sistem. Penerapan stemming bertujuan untuk menyatukan variasi kata yang memiliki makna dasar yang sama sehingga representasi data menjadi lebih sederhana dan konsisten. Dalam analisis sentimen bahasa Indonesia, stemming sangat penting karena struktur morfologi bahasa Indonesia yang kaya akan imbuhan. Algoritma stemming yang umum digunakan antara lain algoritma Nazief-Adriani dan library Sastrawi. Dengan melakukan stemming, model klasifikasi dapat lebih mudah mengenali pola sentimen berdasarkan kata dasar, sehingga berpotensi meningkatkan akurasi hasil klasifikasi.

2.2.7.5 Pengaruh Teks processing Terhadap Kinerja Klasifikasi

Tahapan text processing memiliki pengaruh yang signifikan terhadap kinerja algoritma klasifikasi sentimen. Data teks yang telah melalui proses praproses cenderung lebih bersih, konsisten, dan representatif terhadap informasi yang ingin dianalisis. Hal ini memungkinkan algoritma seperti Naïve Bayes dan Support Vector Machine untuk bekerja secara optimal dalam mempelajari pola sentimen dari data latih. Text processing juga berperan dalam mengurangi dimensi fitur dan noise pada data teks. Dengan jumlah fitur yang lebih relevan, proses pelatihan model menjadi lebih efisien dan risiko overfitting dapat diminimalkan. Dalam penelitian ini, text processing menjadi tahap krusial sebelum proses pelabelan otomatis menggunakan BERT dan klasifikasi sentimen menggunakan algoritma Machine Learning. Oleh karena itu, kualitas hasil analisis sentimen sangat bergantung pada ketepatan dan kelengkapan tahapan text processing yang

diterapkan. Setelah data diproses dan model dikembangkan, langkah selanjutnya adalah melakukan evaluasi untuk menilai kinerja algoritma secara kuantitatif.

2.2.8 Evaluasi Model

penelitian analisis sentimen, evaluasi model memegang peranan penting untuk memastikan bahwa model klasifikasi yang dibangun mampu memetakan sentimen pengguna secara tepat. Oleh karena itu, tahap evaluasi dilakukan untuk menilai kinerja model berdasarkan perbandingan antara hasil prediksi dengan label aktual data.

2.2.8.1 Pengertian Evaluasi Model

Evaluasi model merupakan salah satu tahapan yang sangat penting dalam proses Machine Learning, khususnya pada penelitian klasifikasi, karena bertujuan untuk mengukur sejauh mana model yang dibangun mampu melakukan prediksi secara akurat terhadap data yang diuji. Evaluasi model dilakukan setelah proses pelatihan (training) selesai, dengan menggunakan data uji (testing data) yang sebelumnya tidak dilibatkan dalam proses pembentukan model. Melalui tahap evaluasi ini, peneliti dapat mengetahui tingkat keberhasilan algoritma dalam mengklasifikasikan data ke dalam kelas yang sesuai. Menurut (Al Lutfani dkk., 2025), evaluasi model bertujuan untuk mengukur seberapa tepat suatu algoritma dalam mengelompokkan data ke dalam kelas yang benar. Hasil evaluasi model menjadi dasar penting dalam menentukan apakah model yang dikembangkan sudah layak digunakan atau masih memerlukan perbaikan. Dalam konteks penelitian analisis sentimen, evaluasi model berperan untuk menilai kemampuan algoritma dalam memetakan sentimen pengguna ke dalam kategori positif, negatif, atau netral secara tepat. Evaluasi model juga berfungsi sebagai alat pembandingan antar algoritma yang digunakan. Dengan menggunakan metrik evaluasi yang sama, peneliti dapat membandingkan performa beberapa model klasifikasi untuk menentukan model mana yang memiliki kinerja terbaik. Oleh karena itu, tahap evaluasi tidak hanya berfokus pada nilai akurasi semata, tetapi juga mempertimbangkan berbagai metrik lain yang mampu memberikan gambaran kinerja model secara lebih menyeluruh.

2.2.8.2 Confusion Matrix

Penelitian klasifikasi, salah satu metode evaluasi yang paling umum digunakan adalah Confusion Matrix. Confusion Matrix merupakan sebuah tabel yang digunakan untuk menyajikan perbandingan antara hasil prediksi model dengan label aktual dari data yang diuji. Matriks ini memberikan gambaran yang jelas mengenai jumlah prediksi yang benar maupun salah pada setiap kelas yang diuji, sehingga memudahkan peneliti dalam menganalisis kinerja model secara rinci. Confusion Matrix terdiri dari empat komponen utama, yaitu True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Keempat komponen tersebut merepresentasikan berbagai kemungkinan hasil prediksi yang dihasilkan oleh model klasifikasi. Dengan adanya Confusion Matrix, peneliti tidak hanya mengetahui jumlah kesalahan secara keseluruhan, tetapi juga dapat mengidentifikasi jenis kesalahan yang paling sering terjadi. Penggunaan Confusion Matrix sangat relevan dalam penelitian analisis sentimen, karena kesalahan klasifikasi pada satu kelas tertentu, seperti sentimen negatif yang salah diprediksi sebagai positif, dapat memberikan dampak interpretasi yang berbeda terhadap hasil penelitian. Oleh karena itu, Confusion Matrix menjadi dasar utama dalam perhitungan berbagai metrik evaluasi yang digunakan untuk menilai performa model secara kuantitatif.

2.2.8.3 Rumus Perhitungan Metrik Evaluasi

Proses ini menggunakan *Confusion Matrix* sebagai alat utama untuk membandingkan hasil prediksi model dengan data yang sebenarnya. Dari perbandingan tersebut, kinerja model dapat dihitung menggunakan metrik seperti akurasi, presisi, *recall*, dan *F1-Score*. Adapun rumus perhitungan untuk keempat metrik tersebut adalah sebagai berikut:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (3)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (4)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (5)$$

$$F1 - SCORE = \frac{2 \times Precision \times Recall}{Precision + Recall} \times 100\% \quad (6)$$

Keterangan:

1. TP (*True Positive*) : Data positif yang berhasil diprediksi dengan benar.
2. TN (*True Negative*) : Data negatif yang berhasil diprediksi dengan benar.
3. FP (*False Positive*) : Data negatif yang salah diprediksi sebagai positif.
4. FN (*False Negative*) : Data positif yang salah diprediksi sebagai negatif.

Metrik ini penting untuk membandingkan performa model antar klasifikasi. Evaluasi ini sangat penting untuk mengetahui apakah model yang dibangun sudah mampu memetakan sentimen dengan baik dan layak digunakan dalam analisis.

2.2.8.4 Peran Evaluasi Model

Evaluasi model memiliki peran yang sangat penting dalam penelitian analisis sentimen karena hasil evaluasi digunakan untuk menentukan kualitas model dalam memetakan sentimen pengguna. Melalui evaluasi model, peneliti dapat mengetahui apakah model klasifikasi yang dibangun sudah mampu mengenali pola sentimen secara tepat atau masih mengalami kesalahan yang signifikan. Evaluasi model juga digunakan untuk membandingkan performa antar algoritma klasifikasi yang digunakan dalam penelitian. Dengan menggunakan metrik evaluasi yang sama, seperti akurasi, presisi, recall, dan F1-Score, peneliti dapat menentukan algoritma mana yang memiliki performa terbaik dalam mengklasifikasikan sentimen ulasan pengguna. Evaluasi model menjadi dasar penting dalam pengambilan keputusan terkait pemilihan model terbaik yang layak digunakan dalam analisis sentimen. Model dengan nilai evaluasi yang baik menunjukkan bahwa model tersebut memiliki kemampuan yang memadai dalam memetakan sentimen pengguna secara akurat dan dapat digunakan sebagai dasar dalam penarikan kesimpulan penelitian.

2.2.9 Google Colab

Perkembangan teknologi komputasi berbasis cloud telah memberikan kemudahan dalam pelaksanaan penelitian di bidang data science dan Machine Learning. Salah satu platform yang banyak dimanfaatkan dalam kegiatan penelitian dan pembelajaran adalah Google Colaboratory (Google Colab), yang menyediakan lingkungan pemrograman Python secara daring dengan dukungan sumber daya komputasi yang memadai.

2.2.9.1 Pengertian dan Konsep Google Colab

Google Colaboratory, atau yang lebih dikenal dengan sebutan Google Colab, merupakan sebuah platform komputasi berbasis cloud yang dikembangkan oleh Google untuk mendukung penulisan, pengujian, serta eksekusi kode program Python secara daring melalui peramban web. Platform ini dirancang untuk memberikan kemudahan bagi pengguna dalam melakukan kegiatan komputasi tanpa harus melakukan instalasi perangkat lunak maupun konfigurasi lingkungan pemrograman secara lokal. Dengan demikian, Google Colab menjadi solusi yang praktis bagi mahasiswa, peneliti, maupun praktisi yang membutuhkan lingkungan kerja siap pakai untuk keperluan pembelajaran dan penelitian. Google Colab berbasis pada Jupyter Notebook, yaitu sebuah dokumen interaktif yang memungkinkan pengguna untuk menggabungkan kode program, teks naratif, visualisasi data, serta output eksekusi dalam satu berkas yang terstruktur. Konsep ini mendukung pendekatan komputasi interaktif, di mana pengguna dapat menjalankan potongan kode secara bertahap dan langsung melihat hasilnya. Hal tersebut sangat membantu dalam proses eksplorasi data, eksperimen model, serta dokumentasi alur penelitian secara sistematis. Menurut (Octarina dkk., 2025), platform ini dirancang untuk mendukung kebutuhan pendidikan dan penelitian dengan menyediakan akses gratis ke *Graphics Processing Unit* (GPU) yang dapat digunakan hingga 12 jam berturut-turut.

2.2.9.2 Fitur dan Fasilitas Utama Google Colab

Google Colab menyediakan berbagai fitur yang mendukung kegiatan pemrograman dan analisis data, khususnya dalam bidang data science dan Machine Learning. Salah satu fitur unggulan yang ditawarkan adalah ketersediaan sumber daya komputasi tambahan berupa *Graphics Processing Unit* (GPU) dan *Tensor Processing Unit* (TPU) yang dapat digunakan secara gratis dengan batasan waktu tertentu. GPU memiliki kemampuan komputasi paralel yang memungkinkan proses perhitungan matriks dan vektor dilakukan lebih cepat dibandingkan *Central Processing Unit* (CPU) standar. Penggunaan GPU pada Google Colab dapat mempercepat proses pelatihan model serta mengurangi waktu komputasi secara signifikan. Dukungan GPU dan TPU, Google Colab juga menyediakan berbagai library Python yang telah terinstal secara default, seperti NumPy, Pandas, Scikit-

Learn, TensorFlow, dan PyTorch. Ketersediaan library ini memudahkan pengguna untuk langsung melakukan analisis data tanpa perlu melakukan instalasi tambahan. Apabila diperlukan library tertentu yang belum tersedia, pengguna juga dapat menginstalnya secara langsung melalui perintah Python dalam notebook. Fitur lain yang tidak kalah penting adalah kemampuan Google Colab untuk menampilkan visualisasi data secara interaktif. Pengguna dapat menampilkan grafik, tabel, maupun hasil evaluasi model secara langsung dalam notebook. Hal ini mendukung proses analisis dan interpretasi hasil penelitian secara lebih jelas dan terstruktur.

2.2.9.3 Integrasi Google Colab dengan Google Drive

Salah satu keunggulan signifikan dari Google Colab adalah integrasinya dengan layanan Google Drive. Integrasi ini memungkinkan pengguna untuk menyimpan, mengakses, dan mengelola berkas penelitian secara daring tanpa harus memindahkan data secara manual antar perangkat. Dataset, notebook, maupun hasil eksperimen dapat disimpan langsung ke dalam Google Drive dan diakses kapan saja. Integrasi dengan Google Drive memberikan kemudahan dalam pengelolaan data penelitian, terutama ketika berhadapan dengan dataset berukuran besar atau jumlah file yang banyak. Pengguna dapat memanfaatkan struktur folder di Google Drive untuk mengorganisasi dataset, skrip program, serta hasil analisis secara sistematis. Selain itu, data yang tersimpan di Google Drive juga relatif aman karena dilengkapi dengan sistem pencadangan otomatis dari Google. Dari sisi kolaborasi, Google Colab memungkinkan beberapa pengguna untuk mengakses dan mengedit notebook yang sama secara bersamaan. Fitur ini sangat mendukung kerja kolaboratif, baik dalam konteks pembelajaran kelompok maupun penelitian bersama. Setiap perubahan yang dilakukan oleh pengguna dapat langsung terlihat oleh pengguna lain, sehingga memudahkan proses diskusi dan evaluasi hasil kerja. Dalam konteks dokumentasi penelitian, integrasi Google Colab dengan Google Drive juga mempermudah peneliti dalam menyimpan hasil eksperimen secara berkelanjutan. Notebook yang digunakan sebagai media eksperimen dapat dijadikan sebagai catatan digital yang mendokumentasikan seluruh proses penelitian, mulai dari praproses data hingga evaluasi model.

2.2.9.4 Efisiensi Perangkat Keras dan Aksesibilitas

Penggunaan Google Colab memberikan efisiensi yang signifikan dari segi kebutuhan perangkat keras. Peneliti tidak dituntut untuk memiliki komputer dengan spesifikasi tinggi, karena seluruh proses komputasi dijalankan pada server milik Google. Hal ini menjadi solusi yang sangat relevan bagi mahasiswa atau peneliti dengan keterbatasan perangkat, terutama dalam penelitian yang melibatkan pengolahan data besar atau pelatihan model Machine Learning. Memanfaatkan komputasi berbasis cloud, keterbatasan sumber daya lokal seperti kapasitas RAM, kecepatan prosesor, dan ruang penyimpanan tidak lagi menjadi kendala utama. Selama terhubung dengan internet, pengguna dapat menjalankan eksperimen komputasi yang kompleks melalui Google Colab. Kondisi ini mendukung prinsip pemerataan akses terhadap teknologi komputasi, khususnya di lingkungan akademik. Efisiensi perangkat keras, Google Colab juga memiliki tingkat aksesibilitas yang tinggi. Platform ini dapat diakses melalui berbagai sistem operasi, seperti Windows, macOS, maupun Linux, tanpa memerlukan konfigurasi khusus. Pengguna cukup membuka peramban web untuk mengakses lingkungan kerja yang sama, sehingga fleksibilitas penggunaan menjadi lebih optimal.

2.2.9.5 Peran Google Colab dalam Penelitian Analisis Sentimen

Penelitian ini, Google Colab digunakan sebagai lingkungan kerja utama untuk menjalankan seluruh proses analisis sentimen ulasan pengguna aplikasi Brainly. Proses tersebut mencakup tahap praproses data teks, pembentukan fitur, pelatihan model klasifikasi, hingga evaluasi hasil prediksi. Dengan dukungan library Python dan sumber daya komputasi yang memadai, Google Colab memungkinkan seluruh tahapan penelitian dilakukan secara efisien dan terintegrasi. Penggunaan Google Colab sangat mendukung implementasi algoritma Machine Learning seperti Naïve Bayes dan Support Vector Machine, serta pemanfaatan model deep learning berbasis BERT untuk pelabelan otomatis data sentimen. Dukungan GPU pada Google Colab berperan penting dalam mempercepat proses komputasi, khususnya pada tahap yang melibatkan model berbasis transformer. Google Colab juga memudahkan peneliti dalam melakukan eksperimen dan pengujian model secara berulang. Setiap perubahan parameter atau metode dapat langsung diuji dan dievaluasi tanpa harus melakukan konfigurasi ulang lingkungan kerja. Hal ini

meningkatkan efisiensi waktu penelitian serta meminimalkan kendala teknis yang sering muncul pada penggunaan lingkungan komputasi lokal. Pemanfaatan Google Colab dalam penelitian ini diharapkan dapat meningkatkan kualitas dan efektivitas proses analisis sentimen, sekaligus mendukung keterulangan (reproducibility) penelitian melalui dokumentasi notebook yang terstruktur dan mudah diakses.

2.2.10 Bahasa Pemrograman *Python*

Python merupakan bahasa pemrograman tingkat tinggi yang saat ini banyak digunakan dalam berbagai bidang, khususnya data science, kecerdasan buatan, dan pengolahan bahasa alami. Bahasa ini pertama kali dikembangkan oleh Guido van Rossum pada tahun 1991 dengan tujuan menciptakan bahasa pemrograman yang mudah dipelajari, memiliki sintaks sederhana, serta mampu meningkatkan produktivitas pengembang. Sejak awal pengembangannya, *Python* dirancang untuk menekankan keterbacaan kode (readability) sehingga program yang ditulis dapat dengan mudah dipahami, baik oleh penulis kode maupun oleh pengembang lain yang membacanya. Karakteristik ini menjadikan *Python* sangat populer, tidak hanya di kalangan akademisi, tetapi juga di lingkungan industri dan komunitas pengembang perangkat lunak. Kemudahan dalam mempelajari *Python* menjadi salah satu faktor utama meningkatnya popularitas bahasa pemrograman ini. Sintaks *Python* yang sederhana dan menyerupai bahasa manusia memungkinkan pengguna pemula untuk memahami konsep pemrograman dengan lebih cepat dibandingkan dengan bahasa pemrograman lain yang memiliki struktur sintaks lebih kompleks. Selain itu, *Python* bersifat interpreted language, sehingga kode program dapat langsung dijalankan tanpa melalui proses kompilasi yang panjang. Hal ini memberikan fleksibilitas tinggi bagi peneliti dan pengembang dalam melakukan eksperimen, pengujian, serta pengembangan sistem secara bertahap.

Salah satu keunggulan utama *Python* adalah kemampuannya untuk digunakan dalam berbagai kebutuhan komputasi, mulai dari pengolahan data, pengembangan aplikasi berbasis web, otomasi sistem, hingga penelitian ilmiah. Dalam konteks penelitian akademik, *Python* sering dimanfaatkan karena mendukung pendekatan pemrograman prosedural, berorientasi objek, maupun fungsional. Fleksibilitas paradigma pemrograman ini memungkinkan peneliti untuk menyesuaikan gaya

pemrograman dengan kebutuhan penelitian yang dilakukan. Oleh karena itu, Python dianggap sebagai bahasa pemrograman yang adaptif dan efisien untuk berbagai jenis penelitian, termasuk penelitian di bidang analisis data dan pembelajaran mesin. Bidang data science dan Machine Learning, Python memiliki posisi yang sangat dominan. Hal ini disebabkan oleh ketersediaan berbagai pustaka (library) yang dirancang khusus untuk menangani pengolahan data dalam jumlah besar, analisis statistik, serta pembangunan model kecerdasan buatan. Sintaks Python yang ringkas dan mudah dibaca memungkinkan peneliti untuk lebih fokus pada perancangan algoritma dan interpretasi hasil analisis dibandingkan dengan kompleksitas teknis penulisan kode. Dengan demikian, Python mendukung proses penelitian yang lebih efisien dan sistematis.

Python juga memiliki dukungan yang sangat baik dalam pengolahan bahasa alami atau Natural Language Processing (NLP). Pengolahan data teks, khususnya teks tidak terstruktur seperti ulasan pengguna aplikasi, memerlukan bahasa pemrograman yang mampu menangani manipulasi string, tokenisasi, serta pemodelan statistik dengan baik. Python menyediakan berbagai pustaka NLP yang dapat digunakan untuk melakukan praproses teks, ekstraksi fitur, serta analisis sentimen. Kemampuan ini menjadikan Python sebagai pilihan utama dalam penelitian yang berfokus pada analisis sentimen berbasis data teks. Python digunakan sebagai bahasa pemrograman utama untuk menangani seluruh tahapan analisis sentimen terhadap ulasan pengguna aplikasi Brainly. Tahapan yang dilakukan meliputi pengumpulan dan pemrosesan data, praproses teks, ekstraksi fitur, pembangunan model klasifikasi sentimen, serta evaluasi kinerja model. Proses praproses teks dilakukan untuk membersihkan data dari elemen-elemen yang tidak relevan, seperti tanda baca, kata umum (stopword), dan perbedaan huruf kapital. Selanjutnya, ekstraksi fitur dilakukan untuk mengubah data teks menjadi representasi numerik agar dapat diproses oleh algoritma Machine Learning. Tahap pembangunan model, Python digunakan untuk mengimplementasikan algoritma klasifikasi sentimen, yaitu Naïve Bayes dan Support Vector Machine (SVM). Kedua algoritma tersebut memerlukan proses komputasi statistik dan optimasi matematis yang dapat diakomodasi dengan baik oleh Python melalui pustaka pendukung yang tersedia. Dengan menggunakan Python, proses pelatihan dan

pengujian model dapat dilakukan secara terstruktur dan terintegrasi dalam satu lingkungan kerja, sehingga memudahkan peneliti dalam melakukan analisis dan evaluasi hasil.

Keunggulan Python dalam penelitian ini juga terletak pada kemampuannya untuk mengintegrasikan berbagai pustaka dalam satu alur kerja (workflow). Pustaka seperti Pandas digunakan untuk pengolahan dan manipulasi data, NumPy untuk komputasi numerik, serta Scikit-learn untuk implementasi algoritma Machine Learning dan evaluasi model. Integrasi antar pustaka tersebut memungkinkan peneliti untuk membangun sistem analisis sentimen secara end-to-end, mulai dari data mentah hingga hasil evaluasi model, tanpa harus berpindah ke bahasa pemrograman lain. Berdasarkan penelitian yang dilakukan oleh (Alfarizi dkk., 2023), popularitas Python didukung oleh ekosistem pustaka yang sangat lengkap serta dokumentasi yang mudah diakses. Keberadaan pustaka-pustaka tersebut mempercepat proses pengembangan algoritma dan mengurangi kebutuhan untuk membangun fungsi dari awal. Selain itu, Python didukung oleh komunitas pengguna yang sangat luas dan aktif, baik di tingkat nasional maupun internasional. Dukungan komunitas ini memudahkan peneliti dalam menemukan referensi, tutorial, serta solusi atas permasalahan teknis yang dihadapi selama proses penelitian. Sisi teknis, Python juga banyak digunakan dalam dunia akademik karena bersifat open-source. Sifat open-source memungkinkan Python untuk digunakan secara bebas tanpa biaya lisensi, sehingga sangat sesuai digunakan dalam lingkungan pendidikan dan penelitian. Banyak institusi pendidikan dan penelitian yang mengadopsi Python sebagai bahasa pemrograman utama dalam pengajaran dan pengembangan riset, khususnya di bidang ilmu komputer, sistem informasi, dan data science. Hal ini turut mendorong peningkatan jumlah penelitian yang menggunakan Python sebagai alat bantu utama dalam analisis data.

Berbagai keunggulan tersebut, Python dapat dikatakan sebagai bahasa pemrograman yang sangat relevan dan efektif untuk mendukung penelitian analisis sentimen. Kemudahan penggunaan, fleksibilitas, ketersediaan pustaka pendukung, serta dukungan komunitas yang luas menjadikan Python sebagai pilihan yang tepat untuk mengimplementasikan metode klasifikasi sentimen berbasis Machine Learning. Oleh karena itu, penggunaan Python dalam penelitian ini diharapkan

dapat menghasilkan proses analisis yang sistematis, efisien, dan dapat direproduksi dengan baik oleh peneliti lain.

2.2.11 Scikit-Learn

Scikit-learn merupakan salah satu pustaka *Machine Learning* berbasis bahasa pemrograman Python yang banyak digunakan dalam penelitian dan pengembangan sistem analisis data. Library ini menyediakan berbagai algoritma pembelajaran terawasi dan tidak terawasi yang dapat diterapkan secara efisien pada data numerik maupun teks. Penelitian analisis sentimen, Scikit-learn berperan penting dalam proses ekstraksi fitur serta implementasi algoritma klasifikasi. Oleh karena itu, Scikit-learn menjadi alat yang relevan dan efektif dalam mendukung proses pemodelan dan evaluasi kinerja klasifikasi sentimen.

2.2.11.1 Pengertian Scikit Learn

Scikit-learn merupakan salah satu pustaka (library) open-source berbasis bahasa pemrograman Python yang secara luas digunakan dalam pengembangan dan implementasi metode Machine Learning. Pustaka ini dirancang untuk menyediakan berbagai algoritma pembelajaran mesin yang dapat digunakan secara praktis, efisien, dan terstruktur, khususnya untuk keperluan analisis data dan pemodelan prediktif. Scikit-learn mendukung berbagai jenis permasalahan pembelajaran mesin, antara lain klasifikasi, regresi, klusterisasi, reduksi dimensi, serta evaluasi kinerja model. Keunggulan utama Scikit-learn terletak pada antarmuka pemrogramannya yang sederhana dan konsisten. Setiap algoritma disusun menggunakan pola pemrograman yang seragam, seperti penggunaan metode *fit()*, *predict()*, dan *score()*, sehingga memudahkan pengguna dalam memahami alur kerja pemodelan Machine Learning. Hal ini menjadikan Scikit-learn sebagai salah satu pustaka yang paling direkomendasikan bagi peneliti dan praktisi, termasuk bagi pemula yang baru mempelajari konsep Machine Learning. Menurut (Fahmi, 2023), Scikit-learn dibangun di atas fondasi pustaka numerik Python seperti NumPy dan SciPy, yang memungkinkan proses komputasi berjalan secara efisien dan stabil. Integrasi ini menjadikan Scikit-learn mampu menangani dataset berukuran besar dengan performa yang relatif optimal, tanpa mengorbankan kemudahan penggunaan. Oleh karena itu, Scikit-learn banyak dimanfaatkan dalam penelitian akademik, termasuk penelitian di bidang text mining dan analisis sentimen.

2.2.11.2 **Arsitektur dan Komponen Utama**

Arsitektural, Scikit-learn dirancang sebagai pustaka modular yang terdiri atas berbagai komponen utama yang saling terintegrasi. Setiap komponen memiliki fungsi spesifik yang mendukung keseluruhan proses pembelajaran mesin, mulai dari tahap persiapan data hingga evaluasi model. Komponen utama dalam Scikit-learn meliputi modul preprocessing, feature extraction, model learning, dan model evaluation. Modul preprocessing digunakan untuk mempersiapkan data sebelum dilakukan proses pelatihan model. Pada data numerik, preprocessing dapat berupa normalisasi atau standarisasi data, sedangkan pada data teks preprocessing lebih berfokus pada ekstraksi fitur. Selanjutnya, modul feature extraction berfungsi untuk mengubah data mentah menjadi representasi numerik yang dapat diproses oleh algoritma Machine Learning. Komponen model learning menyediakan berbagai algoritma pembelajaran mesin yang siap digunakan, seperti Naïve Bayes, Support Vector Machine, Logistic Regression, dan Decision Tree. Setiap algoritma disediakan dalam bentuk kelas yang memiliki antarmuka yang konsisten, sehingga pengguna dapat dengan mudah mengganti algoritma tanpa harus mengubah struktur program secara keseluruhan. Terakhir, modul model evaluation menyediakan berbagai metrik evaluasi untuk mengukur kinerja model, seperti accuracy, precision, recall, dan F1-Score.

2.2.11.3 **Scikit Learn dalam Pengolahan Data**

Pengolahan data teks, Scikit-learn memiliki peran yang sangat penting karena menyediakan berbagai fasilitas yang mendukung proses text mining dan analisis sentimen. Data teks yang bersifat tidak terstruktur harus terlebih dahulu diubah menjadi bentuk numerik agar dapat diproses oleh algoritma klasifikasi. Scikit-learn menyediakan modul khusus untuk keperluan ini, yaitu *feature extraction* pada data teks. Salah satu metode yang paling umum digunakan dalam Scikit-learn untuk ekstraksi fitur teks adalah *Count Vectorizer*. Metode ini mengubah kumpulan dokumen teks menjadi matriks frekuensi kata berdasarkan kemunculan setiap kata dalam dokumen. Selain itu, Scikit-learn juga menyediakan *Term Frequency–Inverse Document Frequency* (TF-IDF) yang mampu memberikan bobot lebih besar pada kata-kata yang memiliki tingkat kepentingan tinggi dalam suatu dokumen. Penggunaan metode TF-IDF dalam Scikit-learn

sangat relevan untuk penelitian analisis sentimen karena mampu merepresentasikan makna teks secara lebih informatif dibandingkan sekadar frekuensi kata. Dengan demikian, hasil ekstraksi fitur yang dihasilkan dapat meningkatkan performa algoritma klasifikasi dalam membedakan sentimen positif, negatif, maupun netral.

2.2.11.4 Implementasi Algoritma Naïve Bayes pada Scikit Learn

Scikit-learn menyediakan beberapa varian algoritma Naïve Bayes yang dapat digunakan untuk keperluan klasifikasi, khususnya pada data teks. Salah satu varian yang paling umum digunakan dalam analisis sentimen adalah *Multinomial Naïve Bayes*. Algoritma ini dirancang khusus untuk menangani data diskrit, seperti frekuensi kata atau bobot TF-IDF hasil ekstraksi fitur teks. Implementasi Naïve Bayes dalam Scikit-learn dilakukan secara sistematis melalui beberapa tahapan, yaitu pembagian data menjadi data latih dan data uji, pelatihan model menggunakan metode *fit()*, serta pengujian model menggunakan metode *predict()*. Seluruh tahapan tersebut dapat dilakukan dengan kode program yang relatif sederhana, sehingga memudahkan peneliti dalam melakukan eksperimen dan pengujian model. Penelitian ini, Scikit-learn digunakan untuk memfasilitasi penerapan algoritma Naïve Bayes secara terstruktur dan terkontrol. Dengan memanfaatkan pustaka ini, proses pelatihan dan pengujian model analisis sentimen dapat dilakukan secara efisien, sekaligus menghasilkan nilai evaluasi yang terukur dan dapat dipertanggungjawabkan secara ilmiah.

2.2.11.5 Fasilitas Pembagian Data dan Validasi Model

Salah satu keunggulan Scikit-learn adalah tersedianya fasilitas pembagian data latih dan data uji secara otomatis melalui modul *model_selection*. Pembagian data ini sangat penting dalam penelitian Machine Learning untuk memastikan bahwa model yang dibangun mampu melakukan generalisasi terhadap data baru yang belum pernah dilihat sebelumnya. Scikit-learn menyediakan fungsi *train_test_split()* yang memungkinkan peneliti membagi dataset dengan rasio tertentu, misalnya 70% data latih dan 30% data uji. Selain itu, pustaka ini juga mendukung teknik validasi silang (*cross-validation*) yang dapat digunakan untuk mengukur kestabilan performa model pada berbagai subset data. Adanya fasilitas validasi model ini, Scikit-learn membantu peneliti dalam menghindari

permasalahan *overfitting* maupun *underfitting*. Hal ini menjadikan hasil penelitian analisis sentimen lebih reliabel dan memiliki tingkat kepercayaan yang lebih tinggi.

2.2.11.6 Evaluasi Model klasifikasi menggunakan Scikit Learn

Evaluasi kinerja model merupakan tahapan penting dalam penelitian analisis sentimen. Scikit-learn menyediakan berbagai metrik evaluasi yang dapat digunakan untuk mengukur sejauh mana model klasifikasi mampu memprediksi label sentimen secara tepat. Metrik evaluasi yang umum digunakan antara lain accuracy, precision, recall, dan F1-Score. Scikit-learn juga menyediakan *confusion matrix* yang dapat digunakan untuk memvisualisasikan hasil prediksi model terhadap data aktual. Confusion matrix membantu peneliti dalam memahami kesalahan klasifikasi yang terjadi pada setiap kelas sentimen, sehingga dapat dilakukan analisis lebih lanjut terhadap performa model. Penelitian ini, metrik evaluasi yang disediakan oleh Scikit-learn digunakan untuk menilai kinerja algoritma Naïve Bayes dalam mengklasifikasikan sentimen ulasan pengguna aplikasi Brainly. Hasil evaluasi tersebut menjadi dasar dalam menarik kesimpulan mengenai efektivitas model yang dibangun.

2.2.11.7 Peran Scikit Learn dalam Penelitian Analisis Sentimen

Berdasarkan seluruh pemaparan di atas, dapat disimpulkan bahwa Scikit-learn memiliki peran yang sangat signifikan dalam mendukung penelitian analisis sentimen. Pustaka ini tidak hanya menyediakan algoritma klasifikasi yang siap digunakan, tetapi juga menyediakan seluruh komponen pendukung yang diperlukan dalam satu kerangka kerja yang terintegrasi. Penelitian ini, Scikit-learn digunakan sebagai alat utama untuk mengimplementasikan algoritma Naïve Bayes secara sistematis, mulai dari tahap persiapan data, ekstraksi fitur teks, pelatihan model, hingga evaluasi kinerja model. Dengan memanfaatkan Scikit-learn, proses analisis sentimen terhadap ulasan pengguna aplikasi Brainly dapat dilakukan secara efisien, terukur, dan dapat dipertanggungjawabkan secara akademik. Selain itu, Scikit-learn juga memudahkan proses tuning parameter dan penerapan berbagai metrik evaluasi seperti akurasi, presisi, recall, dan F1-Score, sehingga peneliti dapat membandingkan performa model secara objektif. Keunggulan pustaka ini terletak pada kemampuannya untuk menangani data berskala besar dengan waktu komputasi yang relatif cepat serta dokumentasi yang lengkap sehingga

mempermudah implementasi dan reproduksi penelitian. Dengan adanya Scikit-learn, setiap langkah dalam pipeline analisis, mulai dari preprocessing teks hingga visualisasi hasil evaluasi, dapat dilakukan dalam satu kerangka yang konsisten. Hal ini menjadikan penelitian lebih sistematis, efisien, dan memastikan bahwa temuan yang diperoleh dapat dipertanggungjawabkan secara ilmiah.

2.3 Sintesis BAB II

Berdasarkan pembahasan teori-teori utama pada BAB II, dapat disimpulkan bahwa penelitian analisis sentimen memerlukan pemahaman mendalam mengenai algoritma klasifikasi, teknik text processing, metode evaluasi model, dan tools pendukung seperti Scikit-learn. Tahapan text processing, mulai dari case folding, tokenizing, stopwords removal, hingga stemming, sangat penting untuk menghasilkan representasi data teks yang konsisten dan relevan. Algoritma Naïve Bayes dan SVM memiliki karakteristik dan keunggulan masing-masing yang perlu dipertimbangkan dalam pemilihan metode klasifikasi. Evaluasi model menggunakan metrik seperti akurasi, presisi, recall, dan F1-Score menjadi langkah krusial untuk menilai kinerja model dan membandingkan efektivitas kedua algoritma. Implementasi menggunakan Scikit-learn memungkinkan seluruh proses, mulai dari persiapan data hingga evaluasi model, dilakukan secara terintegrasi dan sistematis. Dengan demikian, landasan teori yang telah dibahas memberikan kerangka ilmiah yang kuat untuk mendukung penelitian ini, khususnya dalam mengklasifikasikan ulasan pengguna aplikasi Brainly ke dalam kategori sentimen positif, negatif, dan netral secara akurat dan objektif.