

BAB III

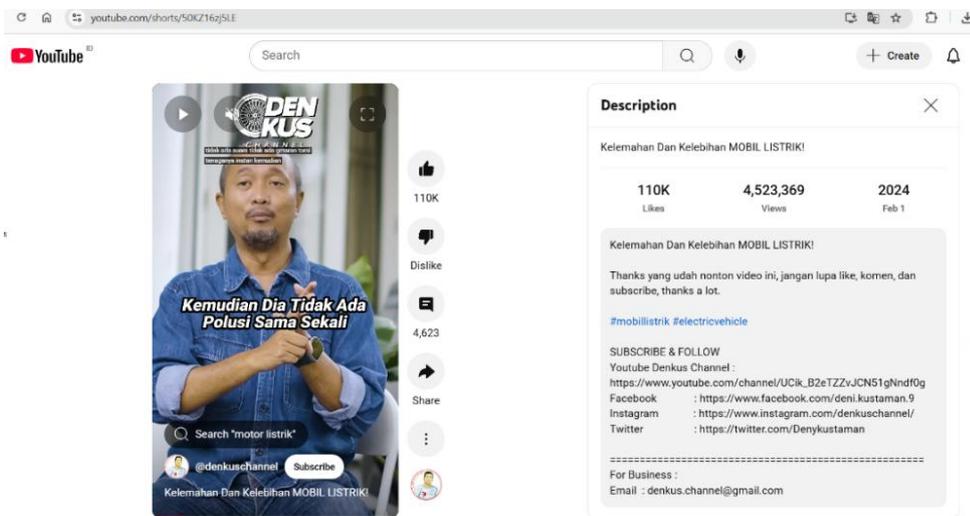
METODOLOGI PENELITIAN

3.1 Gambaran Umum Objek Penelitian

Dalam proses merancang analisis sentimen mengenai persepsi publik terhadap mobil listrik, tahap awal yang dilakukan adalah eksplorasi terhadap berbagai *platform* media sosial sebagai sumber data potensial. *Platform* yang pertama kali dijajaki adalah X, mengingat *platform* ini sering digunakan sebagai ruang diskusi publik yang dinamis dan cepat merespons isu – isu aktual, termasuk perkembangan teknologi dan industri otomotif. Melalui teknik *web scraping*, sejumlah data komentar berhasil dikumpulkan dengan menggunakan kata kunci terkait mobil listrik. Namun, setelah dilakukan proses pembersihan data dan analisis awal, ditemukan bahwa mayoritas data yang terkumpul dari X kurang memenuhi kualitas yang dibutuhkan. Banyak cuitan yang bersifat promosi, berasal dari akun – akun *buzzer*, atau bahkan tidak memiliki konteks langsung dengan topik mobil listrik secara substantif. Selain itu, keterbatasan panjang karakter dalam satu cuitan serta sifat diskusi yang tersebar dan tidak terfokus menjadikan X kurang ideal sebagai sumber utama untuk kajian opini publik yang membutuhkan kedalaman konteks.

Sebagai respons terhadap keterbatasan tersebut, eksplorasi dilanjutkan dengan mempertimbangkan YouTube, khususnya kolom komentar pada video yang relevan, sebagai alternatif yang lebih menjanjikan. YouTube tidak hanya menjadi *platform* berbagi video, tetapi juga merupakan medium interaktif tempat pengguna menyampaikan pendapat dan tanggapan setelah menyaksikan konten tertentu. Pola komentar yang muncul dalam konteks konsumsi video membuat opini yang dituliskan lebih fokus dan relevan terhadap topik. Beberapa kanal YouTube kemudian diseleksi berdasarkan relevansi konten, jumlah interaksi, serta cakupan audiens. Dari hasil seleksi tersebut, dua kanal menonjol, yaitu Pengepul Mobil dan Denkus *Channel*. Kanal Pengepul Mobil memiliki sebuah video yang membahas mobil listrik BYD M6, dengan total penayangan mencapai 460.871 dan jumlah komentar sebanyak 1.181. Meskipun jumlah interaksinya cukup, cakupan topik video ini relatif terbatas, karena hanya menyoroti satu model kendaraan, sehingga

opini yang muncul cenderung spesifik dan tidak mencerminkan pandangan umum terhadap mobil listrik.



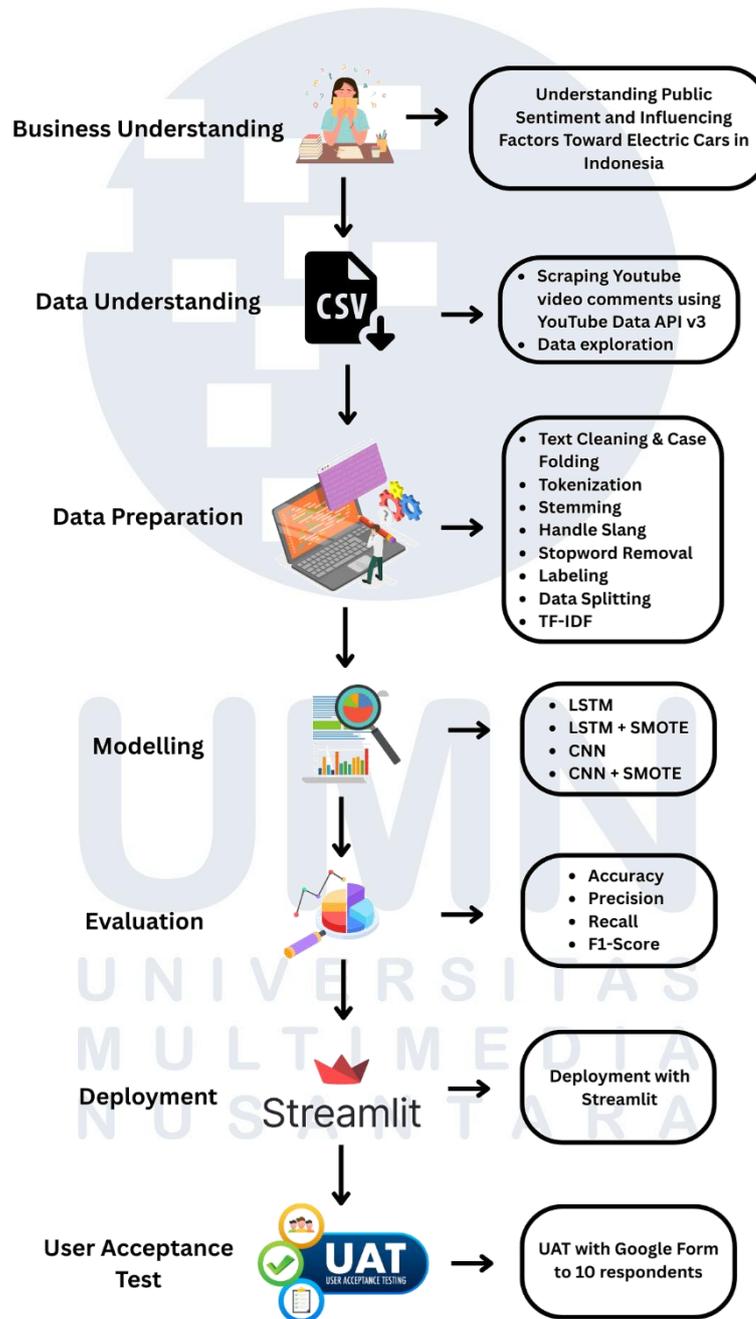
Gambar 3.1 Info Sumber Data Yang Digunakan

Sementara itu, Denkus Channel menayangkan sebuah video YouTube Shorts berjudul “Kelebihan dan Kelemahan Mobil Listrik”, yang menghadirkan narasumber otomotif ternama Fitra Eri, dan membahas topik mobil listrik secara lebih menyeluruh. Video ini mencatatkan penayangan lebih dari 4,5 juta kali, dengan total komentar mencapai 4.622, sebagaimana ditampilkan pada Gambar 3.1. Tidak hanya unggul dari sisi kuantitas interaksi, konten video tersebut juga memiliki daya tarik luas karena membahas *pro* dan *kontra* mobil listrik secara umum, termasuk aspek lingkungan, efisiensi energi, infrastruktur pengisian daya, dan kenyamanan pengguna. Komentar-komentar yang muncul menunjukkan beragam opini, mulai dari dukungan terhadap kendaraan listrik sebagai solusi masa depan hingga kekhawatiran terhadap kesiapan ekosistemnya di Indonesia. Keragaman ini menjadi nilai tambah dalam penyusunan dataset yang representatif, karena mencerminkan sudut pandang dari audiens yang luas dan heterogen.

Dengan mempertimbangkan kuantitas, kualitas, serta cakupan substansi komentar, akhirnya diputuskan untuk menggunakan video dari Denkus Channel sebagai sumber utama dalam pengumpulan data analisis sentimen ini. Meskipun hanya berasal dari satu video, karakteristik konten dan tingginya tingkat partisipasi menjadikannya cukup representatif dalam menangkap dinamika persepsi publik terhadap kendaraan listrik secara lebih komprehensif. Fokus diskusi yang tidak

terbatas pada satu merek atau model mobil menjadikan data yang diperoleh lebih general dan mendalam. Oleh karena itu, dibandingkan dengan data dari X yang cenderung fragmentaris dan data dari kanal YouTube lain yang sempit cakupannya, komentar dari video *Denkus Channel* menawarkan basis data yang paling relevan dan layak untuk dijadikan objek analisis dalam penelitian ini.

3.2 Metode Penelitian



Gambar 3.2 Alur Metode Penelitian

Metode dalam penelitian ini terdiri dari tujuh tahap yang dapat dilihat pada Gambar 3.2.

3.2.1 Business Understanding

Tahap pertama dalam penelitian ini adalah memahami konteks bisnis dari meningkatnya penjualan mobil listrik di Indonesia dalam beberapa tahun terakhir. Peningkatan ini turut diiringi dengan banyaknya opini dan tanggapan dari masyarakat yang terekam melalui berbagai *platform* digital, termasuk YouTube. Oleh karena itu, dilakukan analisis sentimen terhadap komentar publik untuk mengetahui persepsi masyarakat terhadap mobil listrik, baik yang bersifat positif maupun negatif. Hasil dari analisis ini diharapkan dapat memberikan wawasan yang bermanfaat bagi masyarakat umum atau calon konsumen, agar mereka dapat memahami sudut pandang publik lain sebelum mengambil keputusan untuk beralih ke kendaraan listrik dan produsen atau pelaku bisnis otomotif, sebagai dasar untuk menyusun strategi pemasaran, edukasi, maupun pengembangan produk yang lebih sesuai dengan kebutuhan dan harapan pasar di Indonesia.

3.2.2 Data Understanding

Pada tahap ini, data yang digunakan dalam penelitian diperoleh melalui proses data *scraping* dari *platform* YouTube menggunakan YouTube Data API v3, yang disediakan oleh Google Cloud Console. API ini memungkinkan akses ke berbagai elemen data dari video YouTube, termasuk metadata dan komentar pengguna, secara terstruktur dan terprogram. Untuk mengakses API tersebut, terlebih dahulu dibuat proyek pada Google Cloud Console, dilanjutkan dengan aktivasi layanan YouTube Data API v3 dan pembuatan kunci API (*API key*) yang digunakan sebagai otorisasi dalam setiap permintaan (*request*) data. Setelah konfigurasi API berhasil dilakukan, proses pengambilan komentar dilakukan dengan menyusun skrip *scraping* berbasis Python yang memanfaatkan *endpoint commentThreads*, yang dapat mengakses komentar-komentar pada suatu video berdasarkan *videoId* yang ditentukan. Proses *scraping* dilakukan secara bertahap untuk menghindari batas kuota harian yang diterapkan oleh pihak Google. Skrip yang digunakan dirancang untuk mengekstrak atribut penting dari setiap komentar, seperti *comment text*, *author display name*, *published time*, dan *like count*. Dari proses ini, berhasil dikumpulkan sebanyak 3.874 komentar dari video YouTube Shorts berjudul

"Kelemahan dan Kelebihan Mobil Listrik", yang dipublikasikan oleh Denkus Channel dengan Fitra Eri sebagai narasumber. Data komentar ini selanjutnya disimpan dalam format CSV untuk keperluan tahap pra-pemrosesan dan analisis.



Gambar 3.3 Contoh Komen Netral

Komentar-komentar yang terkumpul mencerminkan berbagai persepsi publik mengenai kendaraan listrik, baik yang mendukung maupun mengkritik keberadaan dan implementasinya di Indonesia. Untuk keperluan analisis sentimen, fokus diarahkan hanya pada dua kategori sentimen utama, yaitu positif dan negatif. Keputusan ini didasarkan pada hasil evaluasi awal terhadap kategori netral, yang sebagian besar berisi komentar apresiatif terhadap narasumber tanpa menyentuh substansi isu mobil listrik yang dapat dilihat pada Gambar 3.3. Keberadaan kategori netral dinilai dapat menurunkan efektivitas model klasifikasi. Dalam kasus klasifikasi multi-kelas (positif, negatif, dan netral) model sering kali mengalami kesulitan dalam membedakan komentar netral dari komentar positif atau negatif

yang lemah. Hal ini dapat menyebabkan performa model menurun, baik dari segi akurasi maupun kejelasan interpretasi hasil. Oleh karena itu, dengan menyederhanakan klasifikasi menjadi dua kelas saja, *dataset* menjadi lebih bersih, fokus, dan konsisten, sehingga mendukung proses pelatihan model yang lebih optimal dan menghasilkan hasil analisis yang lebih representatif terhadap persepsi publik terhadap mobil listrik.

3.2.3 Data Preparation

Pada tahap data *preparation*, data yang diperoleh dari komentar-komentar YouTube Shorts mengenai "Kelemahan dan Kelebihan Mobil Listrik" diproses melalui beberapa langkah *preprocessing* untuk memastikan kualitas data yang lebih baik agar dapat dianalisis secara efektif. Proses ini dimulai dengan *text cleaning*, yaitu menghapus elemen-elemen yang tidak relevan dalam teks komentar, seperti HTML *tags*, URL, dan *mention* yang sering kali muncul dalam teks digital namun tidak memberi kontribusi berarti terhadap analisis sentimen. Setelah itu, dilakukan *case folding*, yaitu mengubah semua huruf dalam teks menjadi huruf kecil untuk memastikan konsistensi dan menghindari perbedaan hasil yang disebabkan oleh perbedaan kapitalisasi. Tahap berikutnya adalah *tokenization*, yang memecah teks menjadi unit-unit kata atau token, sehingga teks bisa dianalisis lebih terstruktur. Tokenisasi ini sangat penting untuk memisahkan elemen-elemen teks yang relevan, seperti kata-kata atau frasa yang mengandung sentimen. Setelah itu, dilakukan *stemming*, yaitu proses mengubah kata menjadi bentuk dasarnya atau akarnya. Proses ini penting untuk mengurangi variasi kata yang berasal dari akar kata yang sama, sehingga model dapat menangkap makna umum dari kata tersebut. Setelah *stemming*, langkah berikutnya adalah *slang replacement*. Dalam komentar-komentar yang mengandung bahasa sehari-hari atau *slang*, terdapat banyak singkatan atau penggunaan kata informal yang perlu diubah menjadi bentuk yang lebih baku dan formal.

Tahap berikutnya adalah *stopword removal*, yaitu menghapus kata-kata yang tidak memberikan informasi signifikan dalam analisis sentimen. Jika dibandingkan dengan beberapa penelitian terdahulu yang menggunakan pendekatan lebih konvensional, *preprocessing* dalam penelitian ini dapat dikatakan lebih komprehensif dan kontekstual. Pada studi-studi sebelumnya, proses persiapan data

umumnya terbatas pada langkah-langkah dasar seperti normalisasi huruf, tokenisasi, dan penghapusan *stopword*. Belum banyak yang secara eksplisit mempertimbangkan aspek-aspek khas dari data media sosial, seperti penggunaan bahasa tidak baku, gaya sarkastik, atau ekspresi informal lainnya. Berbeda halnya dengan penelitian ini yang memasukkan langkah seperti *slang replacement* untuk menangani komentar-komentar dengan gaya bahasa kasual, serta merancang *preprocessing* yang lebih adaptif terhadap bentuk-bentuk penyampaian opini yang tidak langsung. Hal ini dilakukan untuk memastikan bahwa setiap komentar yang dianalisis benar-benar mencerminkan sentimen yang terkandung di dalamnya, sekaligus meminimalkan risiko salah tafsir oleh model pembelajaran mesin. Dengan rangkaian *preprocessing* yang lebih kaya dan kontekstual ini, kualitas data yang dihasilkan pun menjadi lebih siap untuk digunakan dalam proses klasifikasi sentimen. Hal ini juga diharapkan dapat meningkatkan akurasi dan validitas hasil analisis, terutama dalam menangkap keragaman ekspresi publik terkait mobil listrik yang disampaikan secara bebas di media sosial.

Setelah tahapan *preprocessing* selesai, proses dilanjutkan ke tahap yang sangat penting dalam siklus analisis sentimen, yaitu pelabelan data (*labeling*). Pada tahap ini, setiap komentar diklasifikasikan ke dalam salah satu dari dua kategori sentimen, yaitu positif atau negatif, berdasarkan isi dan konteksnya. Pemilihan dua kelas sentimen ini bertujuan untuk menyederhanakan struktur data sekaligus meningkatkan fokus analisis terhadap sikap publik yang bersifat mendukung atau menolak terhadap isu mobil listrik. Untuk menunjang efisiensi dan akurasi proses pelabelan, digunakan pendekatan *semi-supervised learning* dengan algoritma *Self-Training XGBoost*. Alasan pemilihan metode ini karena ada 3.874 data serta distribusi data bersifat tidak seimbang dengan dominasi komentar negatif. Selain itu, komentar negatif pada data ini disampaikan secara implisit melalui bahasa sarkastik atau ironi, sehingga menyulitkan klasifikasi jika hanya dilakukan secara manual. Proses pelabelan manual terhadap seluruh data secara penuh juga dinilai tidak efisien, karena membutuhkan waktu dan sumber daya yang besar, terutama jika dilakukan oleh anotator tunggal. Sebaliknya, pelabelan otomatis sepenuhnya tanpa landasan data validasi berisiko tinggi menurunkan akurasi, terutama dalam mengenali sentimen yang tidak eksplisit.

Dengan mempertimbangkan kompleksitas data tersebut, pendekatan *semi-supervised learning* menjadi pilihan yang lebih seimbang. Dalam skema ini, sebanyak 1.105 komentar pertama (sekitar 29,8% dari total 3.703 data) diberi label secara manual sebagai data latih awal (*labeled data*). Data ini kemudian digunakan untuk melatih model awal *XGBoost*. Setelah model terbentuk, model digunakan untuk memprediksi label dari 2.598 komentar sisanya yang belum diberi label (*unlabeled data*), sehingga memungkinkan pemanfaatan data dalam jumlah besar dengan efisiensi waktu dan tenaga labeling yang lebih baik. Komentar yang diprediksi dengan tingkat keyakinan (*confidence score*) minimal 0.7 yang dianggap cukup andal untuk dimasukkan ke dalam pelabelan lanjutan. Penerapan ambang batas *confidence score* sebesar 0.7 memiliki tujuan metodologis yang jelas. Nilai ini merupakan kompromi antara jaminan kualitas dan ketersediaan data tambahan. Jika *threshold* ditetapkan terlalu rendah (misalnya 0.5), maka akan ada lebih banyak data yang dimasukkan, namun dengan risiko besar terhadap ketidakakuratan, terutama dalam konteks komentar dengan ambiguitas tinggi atau ekspresi tidak langsung. Di sisi lain, *threshold* yang terlalu tinggi (seperti 0.9) akan menghasilkan data yang sangat akurat, namun jumlahnya sangat terbatas, sehingga mengurangi manfaat efisiensi dari pendekatan *self-training*. *Threshold* 0.7 dipilih sebagai titik tengah yang memberikan keseimbangan antara volume data dan keandalan prediksi.

Komentar-komentar yang diprediksi dengan *confidence* di bawah 0.7 dikeluarkan dari proses pelabelan lebih lanjut, karena dianggap mengandung ketidakpastian atau potensi *noise* yang dapat menurunkan kualitas model bila dimasukkan dalam pelatihan ulang. Dengan menyaring hanya prediksi yang cukup meyakinkan, proses *self-training* tidak hanya memperluas dataset secara efisien, tetapi juga menjaga keandalan dan stabilitas model dalam mengenali pola sentimen. Secara keseluruhan, strategi *semi-supervised* dengan penguatan melalui *confidence threshold* ini menyediakan solusi optimal terhadap tantangan yang dihadapi dalam pelabelan komentar media sosial yang kompleks, besar, dan tidak seimbang. Kombinasi antara intervensi manual terbatas dan pelabelan otomatis berbasis prediksi terkontrol menjadikan proses ini efisien, akurat, dan relevan untuk digunakan dalam konteks penelitian analisis sentimen publik terhadap mobil listrik.

Setelah tahap labeling data selesai dilakukan, di mana label sentimen positif dan negatif telah dikonversi menjadi format numerik (1 untuk positif dan 0 untuk negatif), langkah selanjutnya adalah membagi *dataset* menjadi data latih dan data uji. Pembagian ini dilakukan menggunakan metode *train_test_split* dari pustaka *sklearn.model_selection*, dengan proporsi 80% untuk data latih dan 20% untuk data uji, memastikan model dapat belajar dari data latih dan dievaluasi menggunakan data yang belum pernah dilihat sebelumnya. Parameter *random_state=42* digunakan agar pembagian data tetap konsisten setiap kali kode dijalankan. Selanjutnya, setelah data dibagi, dilakukan ekstraksi fitur menggunakan metode TF-IDF dengan menggunakan objek *TfidfVectorizer* dari pustaka *sklearn.feature_extraction.text*. Pada tahap ini, data latih (X_{train}) difit dan ditransformasikan menjadi matriks TF-IDF, sementara data uji (X_{test}) hanya ditransformasikan menggunakan *vectorizer* yang telah difit pada data latih. Dengan parameter *ngram_range=(1, 3)*, TF-IDF mempertimbangkan unigram, bigram, dan trigram sebagai fitur, dan *max_features=10000* membatasi jumlah fitur berdasarkan bobot tertinggi.

Pemilihan TF-IDF sebagai metode representasi teks dalam penelitian ini didasarkan pada beberapa pertimbangan. Dibandingkan dengan metode lain seperti *Word2Vec* karena TF-IDF memiliki keunggulan dalam hal kesederhanaan implementasi, efisiensi komputasi, dan interpretabilitas. TF-IDF tidak memerlukan pelatihan vektor kata dari awal, sehingga dapat langsung diterapkan pada dataset teks dengan waktu pemrosesan yang relatif cepat. Hal ini sangat berguna dalam konteks dataset dengan ukuran sedang hingga besar, seperti pada penelitian ini yang melibatkan ribuan komentar. Berbeda dengan *Word2Vec* yang memetakan kata ke dalam ruang vektor berdimensi tinggi berdasarkan konteks sekitarnya, pemrosesan yang lebih kompleks dan sumber daya yang lebih besar. Karena data yang digunakan dalam penelitian ini mengandung banyak komentar panjang dan informal, kemampuan TF-IDF untuk menangkap kata atau frasa kunci secara langsung sudah cukup efektif, tanpa memerlukan representasi semantik yang dalam. Oleh karena itu, TF-IDF dipilih sebagai pendekatan yang paling sesuai dalam kecepatan, efektivitas, dan kesederhanaan teknis yang menjadikannya metode representasi teks yang relevan dan praktis untuk klasifikasi sentimen terhadap komentar YouTube tentang mobil listrik.

3.2.4 Modelling

Pada tahap ini, akan dikembangkan dua model analisis sentimen menggunakan algoritma LSTM (*Long Short-Term Memory*) dan CNN (*Convolutional Neural Networks*). LSTM dipilih karena kemampuannya dalam memproses urutan kata dalam komentar, sehingga dapat mempertimbangkan konteks yang ada dalam urutan kata yang panjang, yang sangat berguna untuk memahami sentimen dalam konteks yang lebih luas. Di sisi lain, CNN akan digunakan untuk mengekstraksi fitur lokal dari teks, yang memungkinkan model untuk mengenali pola-pola penting dalam kalimat dan memberikan hasil yang lebih akurat dalam klasifikasi sentimen. Kedua model ini akan dilatih menggunakan data yang telah diproses dan dibersihkan, dengan memanfaatkan *platform* pengembangan Python dan pustaka *machine learning* seperti TensorFlow untuk membangun dan melatih model. SMOTE (*Synthetic Minority Over-sampling Technique*) diterapkan sebelum pelatihan model untuk mengatasi permasalahan ketidakseimbangan jumlah data antara dua kelas. Seluruh proses pelatihan model dilakukan di Google Colab dengan dukungan GPU T4, yang memungkinkan komputasi yang lebih cepat dan efisien selama proses pelatihan dan evaluasi model. Pendekatan ini diharapkan dapat menghasilkan model klasifikasi sentimen yang optimal dan siap digunakan dalam tahap evaluasi dan *deployment*.

3.2.5 Evaluation

Setelah kedua model dikembangkan dan dilatih, tahap selanjutnya adalah melakukan evaluasi performa model untuk menentukan efektivitas masing-masing algoritma dalam mengklasifikasikan sentimen komentar. Evaluasi dilakukan menggunakan data uji yang telah dipisahkan sebelumnya dari data latih. Beberapa metrik yang digunakan dalam evaluasi meliputi akurasi, presisi, *recall*, dan *F1-score*. Metrik akurasi menunjukkan seberapa sering model memberikan prediksi yang benar secara keseluruhan, sementara presisi dan *recall* memberikan gambaran mengenai kemampuan model dalam mengenali masing-masing kelas sentimen, terutama dalam konteks data yang tidak seimbang. *F1-score* digunakan untuk memberikan penilaian yang seimbang antara presisi dan *recall*, terutama penting dalam menangani kelas minoritas. Hasil dari evaluasi ini akan digunakan untuk membandingkan performa semua model. Model dengan performa terbaik berdasarkan metrik evaluasi tersebut akan dipilih untuk tahap *deployment*, di mana

model tersebut akan diterapkan pada data komentar baru untuk memprediksi sentimen secara otomatis. Dengan demikian, model yang paling efektif dan efisien akan digunakan dalam implementasi analisis sentimen lebih lanjut, baik untuk tujuan praktis maupun penelitian lanjutan.

3.2.6 Deployment

Tahapan selanjutnya dari penelitian ini berfokus pada presentasi hasil evaluasi model serta implementasi sistem analisis sentimen berbasis *web* menggunakan Streamlit. Setelah dilakukan evaluasi terhadap dua model, yaitu LSTM dan CNN, model dengan performa terbaik dipilih dan digunakan untuk mengklasifikasikan sentimen komentar secara otomatis. Model terbaik bersama dengan *vectorizer* disimpan dan dimuat kembali ke dalam aplikasi Streamlit yang dikembangkan di Visual Studio Code dan dijalankan secara lokal melalui *localhost*. Aplikasi ini memungkinkan pengguna untuk memasukkan tautan video YouTube Shorts, yang kemudian akan diproses secara otomatis oleh sistem. Komentar-komentar dari video akan diambil, dibersihkan melalui tahap *preprocessing*, lalu diklasifikasikan ke dalam kategori sentimen positif atau negatif. Hasil analisis ditampilkan dalam bentuk tabel berisi komentar asli dan hasil pembersihannya, distribusi sentimen, *WordCloud* untuk masing-masing sentimen, kata-kata yang sering muncul pada setiap kelas, serta contoh kalimat representatif dari masing-masing kategori. Visualisasi dan hasil ini dirancang agar mudah dipahami oleh pengguna dan dapat memberikan gambaran yang jelas mengenai opini publik terhadap topik tertentu. Sistem ini diharapkan dapat menjadi solusi praktis dan efektif dalam menganalisis sentimen masyarakat secara otomatis, dengan hasil yang informatif dan dapat dimanfaatkan berbagai pihak dalam mendukung pengambilan keputusan yang berbasis data.

3.2.7 User Acceptance Test

Tahapan akhir dari penelitian ini adalah melakukan *User Acceptance Test* (UAT) guna mengevaluasi sejauh mana sistem dapat diterima dan digunakan oleh pengguna sesuai tujuan awal pengembangan. UAT ini dilaksanakan dengan pendekatan gabungan berupa demonstrasi langsung aplikasi, wawancara, dan pengisian kuesioner. Tahapan dimulai dengan melakukan demonstrasi aplikasi kepada para responden. Dalam sesi ini, peneliti memperkenalkan fungsi-fungsi

utama sistem, menjelaskan alur penggunaan, serta memperlihatkan cara kerja sistem klasifikasi dalam menangani data. Demonstrasi dilakukan secara langsung agar responden dapat melihat dan memahami cara sistem berjalan sebelum mencoba sendiri.

Setelah demo, dilakukan sesi wawancara singkat secara individual kepada masing-masing responden. Tujuannya adalah untuk menggali impresi awal mereka terhadap sistem, sejauh mana antarmuka mudah dipahami, serta apakah fitur-fitur yang disediakan sesuai dengan ekspektasi dan kebutuhan pengguna. Wawancara ini juga membantu peneliti menjelaskan lebih lanjut apabila terdapat pertanyaan atau kebingungan dari responden terkait sistem. UAT ini melibatkan sebanyak 10 responden yang dipilih berdasarkan keterkaitannya dengan domain sistem, jumlah ini lebih dari jumlah minimum lima responden sebagaimana disarankan dalam prinsip *5-user rule*. Penambahan jumlah responden bertujuan untuk memperoleh variasi pendapat dan umpan balik yang lebih luas, sehingga hasil evaluasi menjadi lebih komprehensif dan dapat mewakili lebih banyak sudut pandang pengguna.

Sebagai langkah akhir, responden diminta untuk mengisi kuesioner evaluasi yang telah disediakan dalam bentuk Google Form. Kuesioner ini dirancang dengan menggunakan skala Likert 1 hingga 5, di mana 1 berarti sangat tidak setuju dan 5 berarti sangat setuju. Pertanyaan-pertanyaan dalam kuesioner mencakup aspek kemudahan penggunaan, kejelasan antarmuka, kecepatan sistem, akurasi hasil klasifikasi, serta kepuasan secara keseluruhan terhadap aplikasi. Data dari kuesioner ini kemudian dijadikan dasar dalam menganalisis tingkat penerimaan pengguna terhadap sistem yang telah dikembangkan.

UNIVERSITAS
MULTIMEDIA
NUSANTARA

3.3 Teknik Pengumpulan Data



Gambar 3.4 Tampilan Beberapa Komentar Asli

Pengumpulan data dalam penelitian ini difokuskan pada analisis sentimen terhadap mobil listrik, dengan mengambil data komentar dari video YouTube Shorts berjudul "Kelemahan dan Kelebihan Mobil Listrik" yang diunggah oleh kanal Denkus *Channel* dan menampilkan narasumber Fitra Eri. Untuk memperoleh data secara legal dan sistematis, penelitian ini menggunakan YouTube Data API yang disediakan oleh Google Console. Melalui API tersebut, komentar-komentar dari video berhasil diekstraksi dalam jumlah lebih dari 3000, yang mencerminkan berbagai opini publik mengenai mobil listrik selama Februari 2024 hingga Februari

2025. Data yang diperoleh mencakup komentar berbahasa Indonesia yang relevan dengan topik video, dengan tujuan untuk menganalisis sentimen masyarakat terhadap mobil listrik. Gambar 3.4 menunjukkan beberapa contoh komentar asli untuk menggambarkan karakteristik data yang diperoleh. Gambar ini akan mendukung penjelasan mengenai tahap *preprocessing* dan *labeling* yang dilakukan pada data komentar sebelum dilakukan analisis sentimen lebih lanjut.

3.4 Teknik Analisis Data

Penelitian ini menggunakan teknik analisis sentimen dengan mengembangkan dan membandingkan empat model klasifikasi berdasarkan deep learning, yaitu LSTM (*Long Short-Term Memory*), LSTM dengan penerapan SMOTE (*Synthetic Minority Over-sampling Technique*), CNN (*Convolutional Neural Networks*), dan CNN dengan SMOTE. LSTM dipilih karena kemampuannya dalam memproses data sekuensial dan menangkap konteks urutan kata dalam teks, sehingga efektif dalam memahami pola sentimen dalam komentar. Sedangkan CNN digunakan untuk mengekstraksi fitur lokal dari teks, yang membantu dalam mengenali pola-pola penting dalam kalimat yang mendukung klasifikasi sentimen. SMOTE diterapkan pada model LSTM dan CNN untuk mengatasi masalah ketidakseimbangan kelas pada *dataset*, dengan menambah data sintetik pada kelas minoritas sehingga model dapat belajar lebih seimbang dan meningkatkan performa klasifikasi. Keempat model ini dilatih dan diuji menggunakan *dataset* yang telah melalui tahap *preprocessing*, kemudian dievaluasi berdasarkan metrik akurasi, presisi, *recall*, dan *F1-score* untuk menentukan model terbaik dalam menganalisis sentimen komentar.

UNIVERSITAS
MULTIMEDIA
NUSANTARA