

## **BAB III**

### **METODOLOGI PENELITIAN**

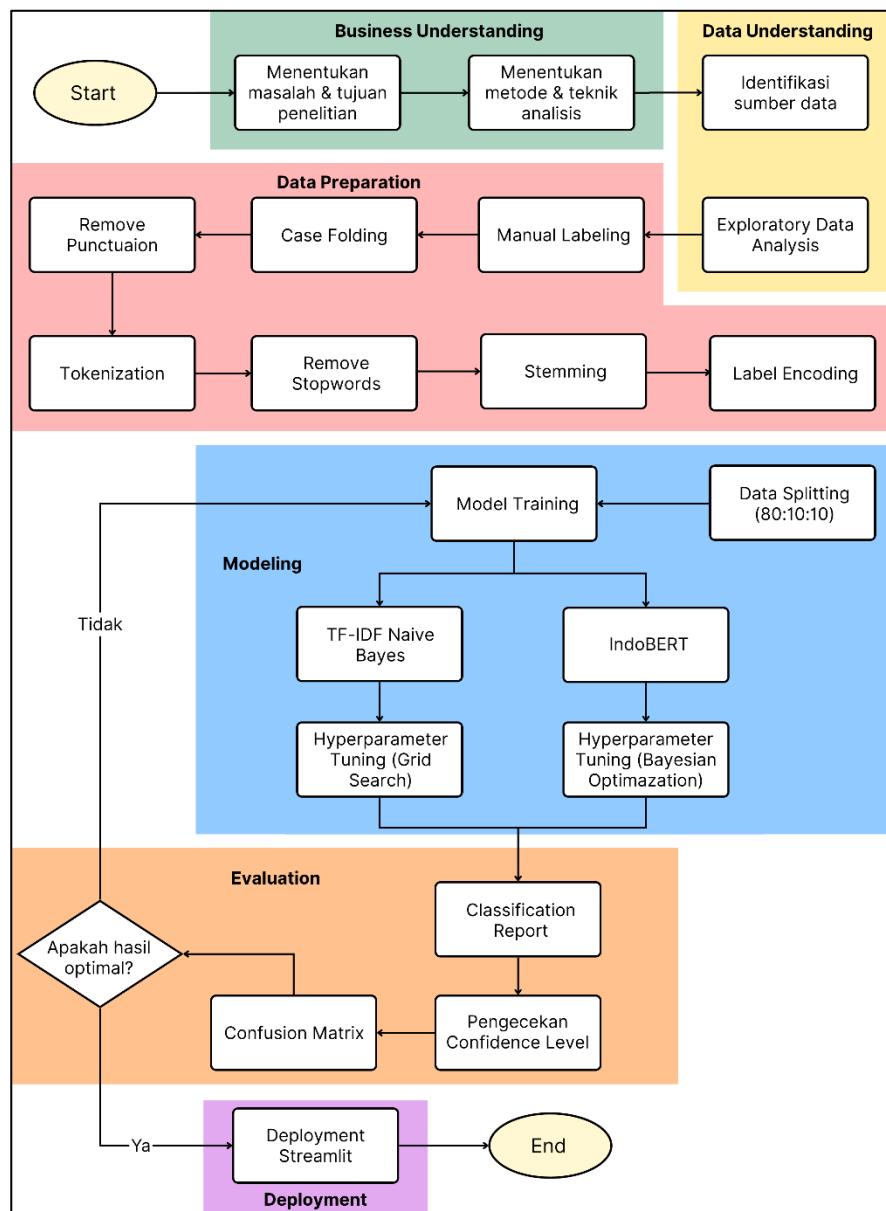
#### **3.1 Gambaran Umum Objek Penelitian**

Objek penelitian ini berfokus pada memberikan pemahaman mengenai *feedback* nasabah terhadap pengalaman mereka selama melakukan berbagai transaksi dan interaksi di Kantor Cabang Utama (KCU) dan Kantor Cabang Pembantu (KCP) PT Bank XYZ. Data yang digunakan berasal dari tabel survei nasabah yang dikumpulkan melalui lingkungan *development* Data Warehouse PT Bank XYZ yang terdiri dari beberapa field, seperti SURVEY\_ID, SURVEY\_DT, BRANCH\_CD, BRANCH\_NM, BRANCH\_CITY, dan CUST\_FEEDBACK dari nasabah. Data survei ini digunakan untuk menggali persepsi dan sentimen nasabah terhadap pengalaman layanan di masing-masing cabang bank. Proses analisis dilakukan dengan pendekatan analisis sentimen berbasis teks menggunakan pelabelan manual untuk menentukan *ground truth*, serta model Naive Bayes berbasis TF-IDF dan IndoBERT. Model Naive Bayes yang dioptimalkan dengan TF-IDF digunakan sebagai *baseline machine learning* sedangkan IndoBERT diterapkan untuk meningkatkan akurasi klasifikasi dengan memanfaatkan kemampuan model *transformer* dalam memahami konteks teks. Hasil dari analisis ini diharapkan dapat memberikan gambaran mendalam mengenai tingkat kepuasan dan persepsi nasabah sehingga menjadi bahan evaluasi bagi pihak bank untuk meningkatkan kualitas layanan di KCU dan KCP tertentu.

#### **3.2 Metode Penelitian**

##### **3.2.1 Alur Penelitian**

Secara garis besar, metode penelitian yang dilakukan dalam penelitian ini dapat digambarkan melalui diagram alur proses penelitian berikut.



Gambar 3.1 Diagram Alur Penelitian

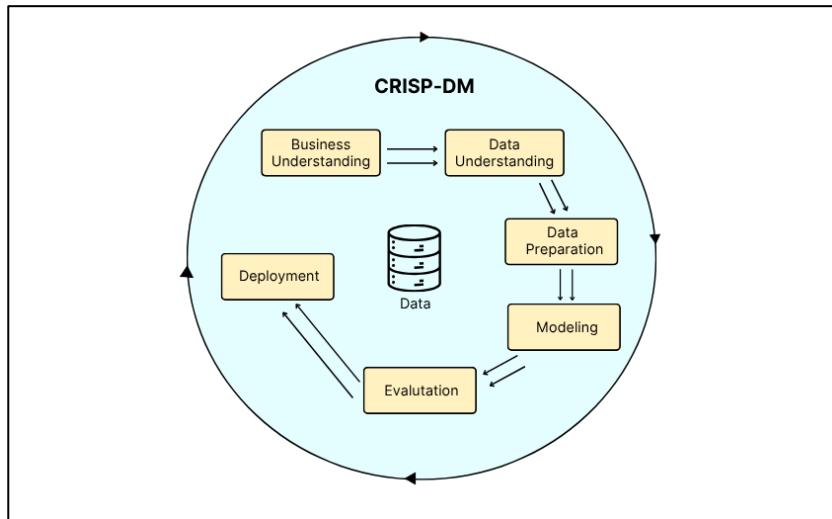
Gambar 3.1 menunjukkan diagram alur keseluruhan penelitian yang dilakukan dalam proses analisis sentimen terhadap pengalaman nasabah di Kantor Cabang Utama (KCU) dan Kantor Cabang Pembantu (KCP) Bank XYZ. Penelitian ini diawali dengan tahap identifikasi

masalah dan penentuan tujuan penelitian, yaitu untuk memahami opini serta persepsi nasabah terhadap layanan yang diberikan melalui pendekatan analisis sentimen berbasis teks. Setelah itu, ditentukan metode dan teknik analisis yang akan digunakan, termasuk pemilihan model TF-IDF Naive Bayes dan IndoBERT sebagai dasar analisis sentimen berdasarkan *research gap* penelitian terdahulu. Tahap selanjutnya adalah pengumpulan data untuk mendukung penelitian ini. Setelah data terkumpul, dilakukan Exploratory Data Analysis (EDA) untuk mendapatkan pemahaman awal terhadap karakteristik data.

Sebelum data digunakan untuk pelatihan model, perlu dilakukan proses *text preprocessing* yang mencakup beberapa tahapan, antara lain *manual labeling*, *case folding*, *tokenization*, *remove stopwords*, *stemming*, serta *label encoding*. Setelah label dikodekan ke dalam format numerik (*label encoding*), maka data akan dibagi menjadi 80% untuk *training*, 10% untuk *testing*, serta 10% untuk *validation*. Pada tahap modeling, dilakukan pelatihan model Naive Bayes berbasis TF-IDF yang dioptimalkan menggunakan teknik GridSearchCV untuk mencari konfigurasi parameter terbaik. Sementara itu, pada model kedua, yaitu IndoBERT, dioptimalkan menggunakan teknik Bayesian Optimization untuk penyesuaian *hyperparameter*. Kedua model tersebut kemudian dievaluasi menggunakan metrik *classification report* dan *confusion matrix* untuk menilai performa dari hasil klasifikasi sentimen. Jika model yang dihasilkan menunjukkan performa yang baik, maka proses akan dilanjutkan ke tahap *deployment* dengan membangun *web application* berbasis Streamlit. Namun, apabila hasil evaluasi belum memenuhi kriteria yang diharapkan, maka proses akan kembali ke tahap *model training* untuk dilakukan penyesuaian parameter hingga diperoleh model dengan performa optimal.

### 3.2.2 Metode Data Mining

Metode *data mining* yang digunakan dalam penelitian ini didasarkan pada kerangka kerja Cross Industry Standard Process for Data Mining atau CRISP-DM. Pendekatan ini dipilih karena bersifat sistematis, terstruktur, dan fleksibel untuk berbagai jenis penelitian berbasis analisis data.



**Gambar 3.2 Metode Data Mining CRISP-DM**

Gambar 3.2 menunjukkan kerangka kerja CRISP-DM (Cross Industry Standard Process for Data Mining) yang menjadi acuan utama dalam penelitian ini. Metode CRISP-DM terdiri atas enam tahapan, yaitu *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment*. Adapun tabel perbandingan antara metode CRISP-DM, KDD, dan SEMMA.

**Tabel 3.1 Perbandingan Metode Data Mining [72]**

Aspek	SEMMA	KDD	CRISP-DM
<b>Kepanjangan</b>	Cross Industry Standard Process for Data Mining	Knowledge Discovery in Database	Sample, Explore, Modify, Model, Assess
<b>Tujuan Utama</b>	Memberikan kerangka kerja <i>end-to-end</i> dari pemahaman bisnis hingga implementasi.	Menemukan pola dan pengetahuan baru dari basis data.	Memberikan panduan proses analisis data berbasis statistik menggunakan <i>software SAS</i> .

Aspek	SEMMA	KDD	CRISP-DM
<b>Tahapan</b>	<i>Business understanding, data understanding, data preparation, modeling, evaluation, deployment.</i>	<i>Selection, pre-processing, transformation, data mining, evaluation, knowledge.</i>	<i>Sample, explore, modify, model, assess.</i>
<b>Kelebihan</b>	<ul style="list-style-type: none"> <li>- Terstruktur, terdokumentasi baik, dan dapat diimplementasikan di berbagai industri.</li> <li>- Mencakup enam tahap siklus tanpa urutan kaku serta memperhatikan tujuan bisnis sejak awal.</li> </ul>	<ul style="list-style-type: none"> <li>- Menekankan penemuan pengetahuan baru dari data besar.</li> <li>- Bersifat interaktif dan iteratif membuat metode menjadi lebih fleksibel.</li> </ul>	<ul style="list-style-type: none"> <li>- Praktis, efisien, dan sangat cocok untuk analisis berbasis perangkat lunak SAS.</li> </ul>
<b>Keterbatasan</b>	<ul style="list-style-type: none"> <li>- Membutuhkan pemahaman bisnis yang kuat dan waktu lebih lama dalam dokumentasi.</li> <li>- Sering menggabungkan <i>tools</i> dan <i>techniques</i> dalam satu kategori sehingga dapat menimbulkan bias.</li> </ul>	<ul style="list-style-type: none"> <li>- Belum mampu menangani permasalahan krusial terkait pemahaman konteks bisnis, domain aplikasi, serta masukan yang diperlukan untuk memahami tujuan dari pengguna akhir.</li> <li>- Tidak fokus pada tahap implementasi hasil.</li> </ul>	<ul style="list-style-type: none"> <li>- Sangat terikat dengan perangkat lunak SAS.</li> <li>- Tidak dapat diterapkan di luar sistem tersebut.</li> </ul>

Berdasarkan Tabel 3.2 di atas yang membandingkan ketiga metode *data mining* yaitu CRISP-DM, KDD, dan SEMMA, dapat disimpulkan bahwa CRISP-DM merupakan metode yang paling komprehensif karena mencakup seluruh tahapan proses *data mining* secara *end-to-end*, mulai dari pemahaman bisnis (*business understanding*) hingga satu-satunya

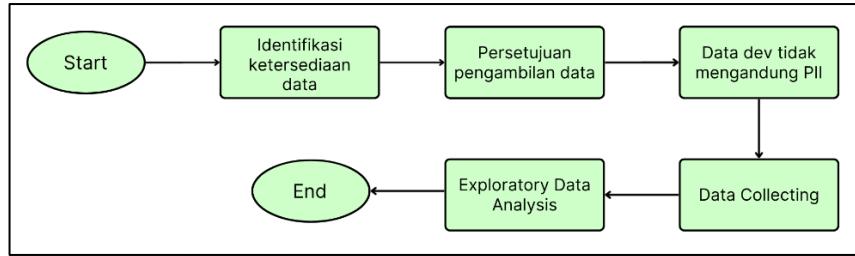
metode yang menerapkan tahap implementasi atau *deployment* hasil model. Keenam tahapan tersebut saling terhubung secara iteratif sehingga membentuk proses analisis yang menyeluruh dari awal hingga akhir. Metode tidak hanya berfokus pada aspek teknis pemodelan, tetapi juga mempertimbangkan tujuan bisnis, kebutuhan organisasi, serta strategi penerapan hasil analisis. Meskipun memiliki beberapa keterbatasan, namun secara keseluruhan CRISP-DM tetap dianggap sebagai kerangka kerja paling kuat karena mampu memberikan panduan yang terstruktur. Hal tersebut membuat CRISP-DM lebih fleksibel untuk penelitian maupun proyek industri. Berikut tahap-tahap pada metodologi CRISP-DM akan dijelaskan secara lebih mendetail sesuai konteks penelitian terkait.

### 1.) Business Understanding

Tahap *business understanding* berfungsi untuk melakukan identifikasi awal terhadap masalah dan tujuan dari penelitian *data mining* yang akan dilakukan. Dalam penelitian ini sendiri, tujuan utamanya adalah untuk menganalisis pengalaman nasabah selama berinteraksi dan melakukan aktivitas kegiatan transaksi di Kantor Cabang Utama (KCU) maupun Kantor Cabang Pembantu (KCP) PT Bank XYZ. Melalui analisis sentimen terhadap *feedback* nasabah, penelitian ini diharapkan dapat memberikan gambaran menyeluruh mengenai persepsi nasabah terhadap kualitas layanan yang diberikan oleh setiap cabang. Hasil analisis tersebut diharapkan dapat menjadi kontribusi bagi pihak manajemen bank dalam mengidentifikasi cabang-cabang yang membutuhkan perhatian atau evaluasi lebih lanjut, baik dalam aspek pelayanan, kecepatan proses, maupun kenyamanan nasabah.

## 2.) Data Understanding

Tahap berikutnya yaitu *data understanding*, dilakukan setelah mendapatkan pemahaman yang jelas mengenai tujuan bisnis dan arah penelitian yang ingin dicapai.



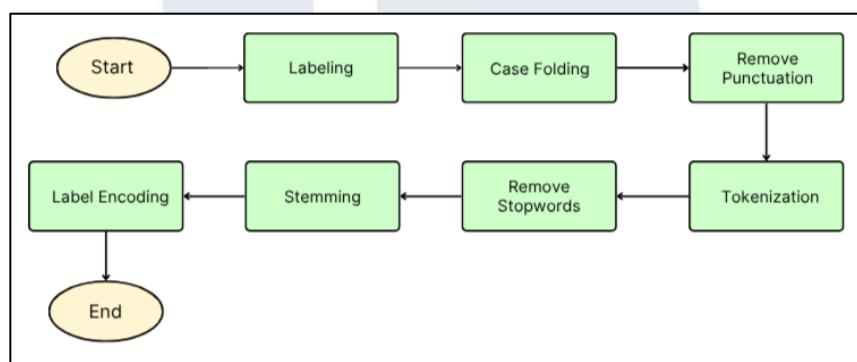
Gambar 3.3 Diagram Alur Data Understanding

Pada tahap ini, seperti pada Gambar 3.3, langkah awal yang dilakukan adalah mengidentifikasi ketersediaan data terkait untuk mendukung proses analisis sentimen terhadap opini nasabah di KCU dan KCP Bank XYZ. Setelah dipastikan data yang diperlukan tersedia, proses dilanjutkan dengan permintaan pengambilan data dengan pihak terkait. Dikarenakan data perbankan bersifat sangat sensitif dan tidak dapat dibawa keluar dari lingkungan internal, maka penelitian ini merujuk pada penggunaan data yang tidak mengandung informasi PII (Personally Identifiable Information). Oleh karena itu, data yang digunakan merupakan data *development* yang diambil dari salah satu tabel di *environment* Data Warehouse Bank XYZ, di mana seluruh informasi sensitif telah dilakukan proses *masking* sesuai kebijakan keamanan data perusahaan. Pada *environment* ini, data sengaja disusun dengan distribusi sentimen yang relatif seimbang untuk kebutuhan *testing* dan simulasi. Hal ini dilakukan agar sistem siap menghadapi berbagai skenario yang mungkin akan terjadi di lingkungan *production*. Adapun data yang diperoleh, yakni data survei kepuasan nasabah dengan *field*, seperti CUST\_SURVEY\_ID, CUST\_SURVEY\_DT, BRANCH\_CD, BRANCH\_NM, BRANCH\_CITY, dan CUST\_FEEDBACK. Data

survei yang digunakan dalam penelitian ini dikumpulkan dalam rentang waktu Januari 2025 hingga Agustus 2025. Setelah data berhasil dikumpulkan, dilakukan Exploratory Data Analysis (EDA) untuk memahami karakteristik data secara lebih mendalam. EDA mencakup analisis awal terhadap jumlah data, tipe data, dan lain sebagainya.

### 3.) Data Preparation

Setelah dilakukan *data understanding*, data yang telah dipahami karakteristik dan kualitasnya akan dipersiapkan untuk masuk ke tahap pemodelan.



Gambar 3.4 Diagram Alur Data Preparation

#### A. Labeling

Pada tahap pengumpulan data, *customer feedback* yang diperoleh dari survei nasabah di PT Bank XYZ belum memiliki label kategori yang jelas terkait dengan sentimen di dalam dalam teks. Oleh karena itu, diperlukan proses untuk memberikan kategori sentimen seperti positif, negatif, atau netral pada setiap feedback nasabah. Untuk memastikan akurasi dan objektivitas dalam pelabelan data, metode pelabelan manual digunakan dalam penelitian ini. Pelabelan dilakukan oleh dua annotator, yakni individu peneliti dan satu orang lain yang memiliki pemahaman mengenai konteks sentimen yang

dianalisis. Untuk meminimalkan bias dan memastikan konsistensi dalam proses pelabelan, setiap *feedback* yang dilabeli dilakukan melalui voting. Kedua *annotator* akan saling sepakat bahwa sebelum memberikan label, mereka terlebih dahulu berdiskusi dan memverifikasi apakah label yang diberikan sesuai dengan konteks teks tersebut. Berikut gambaran proses pelabelan pada *dataset*. Pelabelan data secara manual dilakukan dalam kurun waktu dua minggu (14 hari). Adapun gambaran proses manual *labeling*, seperti pada Tabel 3.2.

**Tabel 3.2 Gambaran Proses Manual Labeling**

CUST_FEEDBACK	LABEL
Pengalaman saya di cabang ini sangat menyenangkan. Nomor antrian bergerak cepat sehingga saya tidak menunggu lama. Proses yang biasanya memakan waktu terasa lebih singkat dari perkiraan. Saya merasa dihargai sebagai nasabah karena pelayanan yang konsisten.	positif
Cuma mau ganti buku tabungan atau urus kartu ATM yang rusak, diminta bermacam-macam syarat dan isi formulir yang banyak. Ribet amat untuk hal yang seharusnya simpel.	negatif
Pelayanan yang saya terima standar, tidak ada yang terlalu menonjol. Customer service menjawab pertanyaan saya dengan sopan dan ringkas. Untuk kebutuhan sederhana, cabang ini sudah memadai.	netral

## B. Case Folding

Setelah dilakukan proses pelabelan menggunakan teknik manual, tahap awal yang dilakukan adalah *text preprocessing* ringan, dimulai dengan *case folding*. Tahapan ini bertujuan untuk menyeragamkan seluruh huruf dalam teks menjadi huruf kecil, misalnya kata seperti “Bagus”, “BAGUS”, dan “bagus” akan dianggap sama. Secara implementasi, *case folding* dilakukan dengan menggunakan fungsi bawaan Python untuk tipe data *string*, yaitu `lower()`.

## C. Remove Punctuation

Setelah dilakukan *case folding*, tahap selanjutnya adalah *remove punctuation*. Tahap ini bertujuan untuk menghapus seluruh tanda baca seperti titik (.), koma (,), tanda seru (!), tanda tanya (?), serta simbol lainnya yang tidak memiliki makna semantik dalam analisis sentimen. Secara implementasi, *remove punctuation* dilakukan dengan menggunakan *library* pendukung, yaitu *re* (regular expression) pada Python. *Library* tersebut dapat menghapus seluruh tanda baca serta karakter non-huruf.

## D. Tokenization

Tahap selanjutnya yaitu *tokenization* yang berfungsi untuk memecah kalimat menjadi satuan kata (token) agar dapat dianalisis secara lebih mendalam pada tahap berikutnya. Dengan melakukan tokenisasi, sistem dapat memahami setiap kata secara individual serta mempermudah proses pencocokan terhadap kamus sentimen saat tahap pelabelan. Secara implementasi, proses ini menggunakan fungsi bawaan Python, yaitu `.split()` yang akan memisahkan teks berdasarkan spasi.

Berikut merupakan gambaran hasil proses *text preprocessing* ringan, seperti pada Tabel 3.3.

**Tabel 3.3 Gambaran Proses Text Preprocessing Ringan**

Proses	Teks	Hasil
<b>Case Folding</b>	Proses di cabang ini berlangsung sesuai prosedur. Transaksi selesai tanpa masalah, hanya perlu sedikit waktu. Jika tidak sedang ramai, kemungkinan proses bisa lebih cepat.	proses di cabang ini berlangsung sesuai prosedur. transaksi selesai tanpa masalah, hanya perlu sedikit waktu. jika tidak sedang ramai, kemungkinan proses bisa lebih cepat.
<b>Remove Punctuation</b>	proses di cabang ini berlangsung sesuai prosedur. transaksi selesai tanpa masalah, hanya perlu sedikit waktu. jika tidak sedang ramai, kemungkinan proses bisa lebih cepat.	proses di cabang ini berlangsung sesuai prosedur transaksi selesai tanpa masalah hanya perlu sedikit waktu jika tidak sedang ramai kemungkinan proses bisa lebih cepat
<b>Tokenization</b>	proses di cabang ini berlangsung sesuai prosedur transaksi selesai tanpa masalah hanya perlu sedikit waktu jika tidak sedang ramai kemungkinan proses bisa lebih cepat	[proses, di, cabang, ini, berlangsung, sesuai, prosedur, transaksi, selesai, tanpa, masalah, hanya, perlu, sedikit, waktu, jika, tidak, sedang, ramai, kemungkinan, proses, bisa, lebih, cepat]

#### E. Remove Stopwords

Selanjutnya, terdapat proses *remove stopwords*, di mana proses ini sudah termasuk ke dalam *text preprocessing* lanjutan yang mulai mengubah makna teks secara keseluruhan. Tujuannya adalah untuk menghapus kata-kata umum yang tidak memiliki makna penting dalam analisis sentimen, seperti “yang”, “dan”, “di”, “ke”, atau “dengan”. Secara implementasi, proses ini

menggunakan *library* Python NLTK (Natural Language Toolkit), khususnya modul nltk.corpus.stopwords yang menyediakan daftar kata umum dalam bahasa Indonesia untuk dihapus dari teks.

#### F. Stemming

Tahap selanjutnya adalah *stemming*, yaitu proses untuk mengembalikan setiap kata ke dalam bentuk dasar (*root word*) guna mengurangi variasi kata akibat penggunaan imbuhan. Pada penelitian ini, proses *stemming* dilakukan menggunakan *library* Python Sastrawi melalui modul Sastrawi.Stemmer.StemmerFactory yang dirancang secara khusus untuk menangani morfologi Bahasa Indonesia.

Sastrawi mampu mengurangi kata berimbuhan (*inflected words*) dalam Bahasa Indonesia ke bentuk dasarnya (*stem*) dengan mengenali berbagai pola imbuhan, termasuk awalan, sisipan, dan akhiran, seperti *me-*, *ber-*, *-kan*, dan *-i*. Penggunaan Sastrawi membantu menormalkan representasi teks sehingga kata-kata yang memiliki makna sama tetapi bentuk berbeda dapat diperlakukan sebagai satu fitur yang sama. Adapun gambaran hasil proses dari *text preprocessing* lanjutan ini, seperti pada Tabel 3.4.

**Tabel 3.4 Gambaran Proses Text Preprocessing Lanjutan**

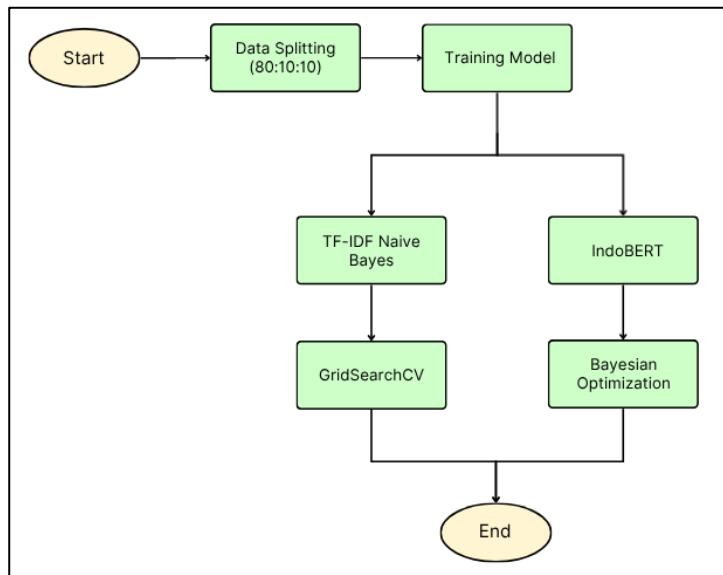
Proses	Teks	Hasil
<b>Remove Stopwords</b>	[proses, di, cabang, ini, berlangsung, sesuai, prosedur, transaksi, selesai, tanpa, masalah, hanya, perlu, sedikit, waktu, jika, tidak, sedang, ramai, kemungkinan, proses, bisa, lebih, cepat]	[proses,cabang,berlangsung, sesuai,prosedur,transaksi, selesai,masalah,perlu,sedikit, waktu,ramai,kemungkinan, proses,cepat]
<b>Stemming</b>	[proses,cabang,berlang sung,sesuai,prosedur, transaksi,selesai, masalah,perlu,sedikit, waktu,ramai, kemungkinan,proses, cepat]	[proses,cabang,langsung, sesuai,prosedur,transaksi, selesai,masalah,perlu, sedikit,waktu,ramai, mungkin,proses,cepat]

#### G. Label Encoding

Tahap terakhir dari proses *data preparation* adalah *label encoding* untuk mengubah label sentimen menjadi bentuk numerik agar dapat digunakan dalam model *transformer*. Pada penelitian ini, label sentimen diubah sebagai berikut: positif = 2, netral = 1, dan negatif = 0. Implementasi ini dilakukan menggunakan *function .map()* pada Python.

#### 4.) Modeling

Setelah proses *data preparation* selesai dilakukan, tahap selanjutnya adalah *modeling*. Pada tahap ini, data yang telah dipersiapkan digunakan untuk membangun dan melatih model analisis sentimen sesuai dengan metode yang telah ditentukan.



**Gambar 3.5 Diagram Alur Modeling**

Gambar 3.5 menunjukkan diagram alur tahap *modeling* penelitian ini, di mana data yang telah melalui tahap *data preparation* siap untuk dimasukkan ke dalam model. Pertama, dilakukan *data splitting* dengan pembagian 80% untuk *training*, 10% *testing*, dan 10% *validation* [73]. Setelah data terbagi, dilakukan proses *training* model yang mencakup dua pendekatan berbeda. Pendekatan pertama menggunakan model TF-IDF Naive Bayes, di mana pembobotan TF-IDF diterapkan sebagai representasi fitur teks sebelum diklasifikasikan dengan algoritma *machine learning* Naive Bayes. Model ini kemudian dioptimalkan melalui GridSearchCV untuk mencari kombinasi *hyperparameter* terbaik di dalam model. Pendekatan kedua menggunakan IndoBERT yang dilatih menggunakan arsitektur *transformer* dari indobenchmark sebagai *backbone*. Untuk memperoleh kinerja optimal, dilakukan pula metode *hyperparameter tuning* menggunakan Bayesian Optimization yang memungkinkan pencarian parameter secara lebih efisien dibanding pencarian *grid*. Kemudian, kedua model selanjutnya siap digunakan dalam evaluasi performa untuk melihat model mana yang memberikan

hasil paling optimal. Adapun gambaran *hyperparameter tuning*, seperti pada Tabel 3.5.

**Tabel 3.5** Gambaran Hyperparameter Tuning Kedua Model

Metode	Hyperparameter	Value
GridSearchCV	tfidf_ngram_range	(1,1), (1,2)
	tfidf_min_df	1, 2, 3
	tfidf_max_df	0.75, 0.9, 1.0
	nb_alpha	0.1, 0.5, 1.0
Bayesian Optimization	learning_rate	1e-5 hingga 5e-3
	batch_size	4, 8, dan 16
	weight_decay	0.001 hingga 0.1
	num_train_epochs	1 hingga 5

### 5.) Evaluation

Tahap *evaluation* bertujuan untuk mengevaluasi kinerja model IndoBERT dalam mengklasifikasikan sentimen nasabah. Evaluasi dilakukan dengan menggunakan *classification report* dan *confusion matrix* yang disediakan oleh *library* sklearn.metrics. *Classification report* akan menampilkan penilaian penting seperti akurasi, presisi, *recall*, dan *F1-score*.

### 6.) Deployment

Tahap *deployment* merupakan tahap terakhir dalam metode *data mining* berbasis CRISP-DM, di mana hasil dari model terbaik antara TF-IDF Naive Bayes atau IndoBERT yang telah dilatih dan dievaluasi akan diimplementasikan ke dalam sebuah *website* sederhana berbasis Streamlit. Dengan *deployment* ini, pengguna dapat mengunggah data ulasan nasabah secara langsung dan mendapatkan klasifikasi sentimen secara *real-time*, baik positif, netral, maupun negatif. Implementasi ini bertujuan agar hasil

analisis sentimen dapat dimanfaatkan secara praktis oleh pihak bank untuk memonitor dan mengevaluasi pengalaman nasabah di berbagai KCU dan KCP Bank XYZ sehingga mempermudah pengambilan keputusan terkait peningkatan layanan.

Dalam pengembangan aplikasi, model pengembangan sistem yang digunakan adalah Waterfall. Pemilihan model Waterfall didasarkan pada karakteristik pengembangan sistem yang bersifat terencana dan memiliki kebutuhan yang telah didefinisikan secara jelas sejak awal, baik dari sisi fungsionalitas sistem maupun alur penggunaan aplikasi. Kebutuhan sistem seperti fitur unggah data, pemfilteran berdasarkan cabang dan periode waktu, visualisasi distribusi sentimen, serta tampilan hasil analisis telah ditentukan sebelum proses implementasi dimulai. Selain itu, penggunaan Streamlit sebagai *framework* pengembangan aplikasi telah familiar di lingkungan perusahaan dan mendukung pengembangan aplikasi yang sederhana dan terstruktur. Karena pengembangan aplikasi ini merupakan inisiatif mandiri dengan ruang lingkup yang terbatas dan tidak memerlukan perubahan kebutuhan secara dinamis di tengah proses pengembangan, model Waterfall dinilai sesuai untuk memastikan proses implementasi berjalan sistematis dan efisien hingga tahap *deployment*.

Setelah tahap implementasi dan *deployment*, dilakukan evaluasi terhadap aplikasi untuk memastikan seluruh fungsionalitas sistem berjalan sesuai dengan kebutuhan yang telah ditetapkan. Metode pengujian yang digunakan adalah *black box testing*, yaitu pengujian yang berfokus pada keluaran sistem berdasarkan masukan yang diberikan tanpa memperhatikan struktur internal program. Pengujian dilakukan pada fitur-fitur utama aplikasi, seperti proses unggah *file* data survei, pemfilteran data berdasarkan BRANCH\_CD dan periode waktu, proses

prediksi sentimen menggunakan model terpilih, visualisasi distribusi sentimen, serta ekstraksi kata kunci sentimen negatif. Proses pengujian ini dilakukan secara langsung bersama Product Owner dari Survey Gallup melalui sesi *call meeting*

### 3.3 Teknik Pengumpulan Data

Teknik pengumpulan data dalam penelitian ini dilakukan melalui koordinasi langsung dengan tim Data Warehouse (DWH) Bank XYZ. Peneliti mengajukan permintaan resmi (*data request*) untuk memperoleh *dataset* yang relevan, yaitu data *customer experience* atau umpan balik nasabah yang berasal dari seluruh KCU dan KCP Bank XYZ. Proses pengambilan data mengikuti prosedur internal bank yang baik, memastikan bahwa data yang diberikan telah melalui proses *masking* dan tidak mengandung informasi pribadi (Personally Identifiable Information/PII) sehingga aman digunakan untuk kebutuhan penelitian. *Dataset* yang diterima terdiri dari 10.000 baris data dengan 6 atribut utama, meliputi ID survei, tanggal survei, kode cabang, nama cabang, kota, serta kolom komentar yang berisi *feedback* nasabah mengenai layanan yang mereka terima. Data yang diberikan mencakup informasi non-sensitif dan telah disesuaikan dengan kebijakan privasi serta keamanan data Bank XYZ. Dengan demikian, seluruh data yang digunakan dalam penelitian ini bersifat aman (*secure*) untuk proses analisis sentimen tanpa menimbulkan risiko pelanggaran terhadap kerahasiaan maupun privasi nasabah.

### 3.4 Variabel Penelitian

Variabel dependen merupakan variabel terikat yang dipengaruhi (menjadi akibat) karena adanya variabel bebas [63]. Dalam penelitian ini, variabel dependen atau target ialah label sentimen dari ulasan nasabah yang dikategorikan menjadi tiga kelas, yaitu positif, netral, dan negatif. Label sentimen ini menjadi fokus utama penelitian karena mencerminkan persepsi dan pengalaman nasabah terhadap layanan yang diberikan di KCU dan KCP

serta sangat dipengaruhi oleh isi teks ulasan yang diberikan. Sementara itu, variabel independen merupakan faktor yang memengaruhi variabel dependen (menjadi sebab) [70]. Variabel independen dalam penelitian ini, yaitu teks *feedback* atau ulasan nasabah terhadap KCU dan KCP yang diberikan melalui survei. Teks menjadi sumber informasi utama dalam analisis sentimen karena melalui kata-kata, frasa, dan kalimat yang terkandung di dalamnya, model dapat mengekstrak pola dan menentukan apakah sentimen yang tersirat bersifat positif, negatif, atau netral. Dengan kata lain, teks *feedback* nasabah berperan sebagai variabel input yang akan digunakan oleh model TF-IDF Naïve Bayes dan IndoBERT untuk memprediksi label sentimen.

### 3.5 Teknik Analisis Data

#### 3.5.1 Bahasa Pemrograman yang Digunakan

Bahasa pemrograman yang digunakan dalam penelitian ini adalah Python. Python dipilih karena memiliki dukungan yang sangat kuat untuk pengembangan berbasis *machine learning*, *deep learning*, ataupun *transformer-based models* seperti IndoBERT dalam penelitian ini. Python menyediakan berbagai *library* dan *framework*, seperti TensorFlow, PyTorch, Transformers, NLTK, dan Scikit-learn yang memudahkan proses *data mining* mulai dari *preprocessing* data, pelatihan model, hingga evaluasi dan *deployment*. Selain itu, sintaksis Python yang sederhana dan mudah dibaca membuatnya sangat efisien untuk eksperimen. Sementara itu, bahasa seperti R lebih banyak digunakan untuk penelitian berbasis statistik dan probabilitas, serta analisis data eksploratif. Hal ini membuat R memiliki keterbatasan dalam melakukan model *deep learning* dan *transformer* yang kompleks. Oleh karena itu, Python menjadi pilihan utama dalam penelitian ini karena kemampuannya dalam mendukung seluruh tahapan *pipeline machine learning*, mulai dari pengolahan teks hingga pembangunan model berbasis *transformer*.

### 3.5.2 Tools yang Digunakan

**Tabel 3.6 Perbandingan Tools** [74] [65] [75]

Aspek	Jupyter Notebook	RStudio	Google Colab
<b>Platform</b>	Dijalankan secara lokal di komputer pengguna dan bersifat <i>open source</i> .	Aplikasi <i>desktop</i> dan <i>server</i> , terintegrasi penuh dengan bahasa R	<i>Cloud-based</i> sepenuhnya, diakses melalui <i>browser</i> , tidak memerlukan instalasi.
<b>Kemampuan Analisis Data</b>	Kuat untuk eksplorasi data, <i>data wrangling</i> , dan visualisasi interaktif.	Unggul dalam analisis statistik, regresi, dan eksplorasi data berbasis statistik.	Eksperimen <i>machine learning</i> dan <i>deep learning</i> skala besar.
<b>Bahasa Pemrograman</b>	Mendukung banyak bahasa seperti Python, R, Julia, dan Scala melalui <i>kernel</i> .	Berfokus pada bahasa R	Python
<b>Kelebihan</b>	<ul style="list-style-type: none"> <li>- Mendukung berbagai bahasa pemrograman</li> <li>- Antarmuka interaktif dan mudah digunakan</li> </ul>	<ul style="list-style-type: none"> <li>- Terintegrasi dengan bahasa R secara penuh.</li> <li>- Kuat dalam analisis statistik dan visualisasi data dengan <i>package</i>, seperti <i>ggplot2</i> dan <i>dplyr</i>.</li> </ul>	<ul style="list-style-type: none"> <li>- <i>Cloud-based</i> (tidak perlu instalasi lokal).</li> <li>- Dapat menggunakan GPU/TPU untuk <i>training</i> model besar.</li> <li>- Terintegrasi langsung dengan Google Drive</li> </ul>
<b>Keterbatasan</b>	<ul style="list-style-type: none"> <li>- Tidak memiliki GPU.</li> <li>- Bergantung pada konfigurasi lokal.</li> </ul>	<ul style="list-style-type: none"> <li>- Terbatas pada bahasa R.</li> <li>- Kurang fleksibel untuk model <i>machine learning</i> modern.</li> </ul>	<ul style="list-style-type: none"> <li>- Bergantung pada koneksi internet.</li> <li>- Memiliki watu sesi <i>runtime</i> yang terbatas (12 jam).</li> </ul>

Berdasarkan Tabel 3.6 di atas yang menunjukkan perbandingan antara beberapa *tools* analisis data, seperti Jupyter Notebook, RStudio, dan Google Colab, penelitian ini memilih untuk menggunakan Google

Colab sebagai *tools* pendukung utama. Pemilihan ini didasarkan pada karakteristik penelitian yang berfokus pada pemodelan berbasis *transformer*, khususnya penggunaan model IndoBERT yang dikembangkan melalui bahasa pemrograman Python. Model tersebut memiliki kompleksitas tinggi dan memerlukan sumber daya komputasi besar selama proses *training* maupun *fine-tuning*. Google Colab sendiri menyediakan dukungan GPU dan TPU melalui *cloud computing* sehingga mampu mempercepat waktu eksekusi. Selain itu, Google Colab mengurangi beban pada perangkat lokal yang memiliki keterbatasan memori serta kapasitas pemrosesan. Colab menjadi suatu *platform* yang mudah diakses melalui *browser* tanpa memerlukan instalasi tambahan. Oleh karena itu, penggunaan Google Colab dinilai paling sesuai untuk mendukung penelitian analisis sentimen berbasis model IndoBERT ini.

