


BAB III

3.1. Prosedur Penelitian

Penelitian ini menggunakan kerangka kerja *Cross-Industry Standard Process for Data Mining* (CRISP-DM) sebagai prosedur penelitian. Kerangka ini dipilih karena inti dari penelitian ini adalah pembangunan model klasifikasi berbasis data sinyal getaran, sehingga tahapannya lebih relevan mengikuti siklus pengembangan model *machine learning* dibanding kerangka pengembangan perangkat lunak pada umumnya. CRISP-DM terdiri atas enam tahap, yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment*. Alur keenam tahap tersebut ditunjukkan pada Gambar 3.1.



Gambar 3.1 Metode CRISP-DM

3.1.1. *Business Understanding*

Tahap ini diawali dengan memahami permasalahan operasional yang terjadi di CV. Mutiara Samudera Indonesia (MSI), yaitu belum tersedianya sistem pemantauan kondisi mesin kompresor truk berpendingin secara *real-time*, pengecekan yang masih dilakukan secara manual oleh teknisi, serta pernah terjadinya kerusakan mesin pendingin yang baru diketahui setelah berdampak nyata. Dari pemahaman terhadap kondisi tersebut, ditetapkan tujuan penelitian, yaitu merancang sistem deteksi anomali getaran kompresor yang bekerja secara *real-time* dan sepenuhnya *on-device* pada ESP32-S3 tanpa bergantung pada konektivitas internet. Pada tahap ini juga ditentukan batasan penelitian, target kelas klasifikasi (Normal, *Imbalance*, dan *Bearing*), serta kebutuhan perangkat keras dan perangkat lunak yang akan digunakan sebagai acuan pada tahap-tahap berikutnya.

3.1.2. *Data Understanding*

Tahap ini bertujuan memahami karakteristik data yang akan digunakan sebelum masuk ke proses pengolahan. Data yang dikumpulkan berasal dari dua sumber. Pertama, data kondisi Normal merupakan gabungan hasil perekaman langsung menggunakan sensor MPU6050 yang dipasang pada mesin kompresor truk berpendingin di CV. MSI, dan data yang bersumber dari *dataset* publik MAFAULDA. Kedua, data kondisi *Imbalance* dan *Bearing* seluruhnya bersumber

dari *dataset* MAFAULDA, karena perekaman sinyal pada kondisi kerusakan nyata tidak dapat dilakukan langsung di lapangan demi menjaga keselamatan armada dan kelangsungan operasional perusahaan. Pada tahap ini juga dilakukan pemeriksaan awal terhadap format sinyal, jumlah sampel per kelas, serta rentang nilai akselerasi tiga sumbu, untuk memastikan data yang akan diolah pada tahap berikutnya sudah sesuai dengan kebutuhan sistem yang dirancang.

3.1.3. *Data Preparation*

Tahap ini mengubah sinyal akselerasi mentah menjadi representasi fitur spektral yang siap digunakan sebagai masukan model. Sinyal dari MAFAULDA dan CV. MSI diproses menggunakan teknik *sliding window* berukuran 128 sampel dengan *overlap* 50%, kemudian difilter menggunakan *bandpass filter* Butterworth orde 4 pada rentang 5–90 Hz untuk mengeliminasi *noise* di luar rentang karakteristik getaran kompresor. Setiap *window* yang telah difilter selanjutnya melalui transformasi *Fast Fourier Transform* (FFT) dengan penerapan fungsi jendela Hann untuk mengurangi *spectral leakage*. Dari hasil transformasi tersebut diekstraksi tiga fitur spektral per sumbu akselerasi, yaitu RMS, *Peak Amplitude*, dan *Spectral Energy*, sehingga menghasilkan vektor fitur berdimensi 9. Vektor fitur tersebut kemudian dinormalisasi menggunakan *StandardScaler* agar setiap fitur memiliki skala yang sebanding,

sebelum akhirnya dibagi menjadi data latih dan data uji dengan rasio 80:20.

3.1.4. *Modeling*

Tahap pemodelan dilakukan dengan membangun model klasifikasi menggunakan arsitektur *Multi-Layer Perceptron* (MLP) yang terdiri atas *input layer* 9 neuron, dua *hidden layer* (32 dan 16 neuron dengan aktivasi ReLU), serta *output layer* 3 neuron dengan aktivasi *Softmax*. Pelatihan model dilakukan menggunakan *framework TensorFlow/Keras* dengan mempertimbangkan keterbatasan sumber daya ESP32-S3 sebagai target akhir *deployment*. Setelah model dasar (V1 *Base Float32*) diperoleh, dilakukan optimasi lanjutan menggunakan teknik *pruning* dan *Quantization INT8*, sehingga menghasilkan tiga varian model tambahan (V2, V3, dan V4) yang akan dibandingkan pada tahap evaluasi.

3.1.5. *Evaluation*

Keempat varian model (V1–V4) dievaluasi secara sistematis untuk menentukan konfigurasi paling optimal. Evaluasi dilakukan dalam dua bagian. Pertama, evaluasi performa klasifikasi meliputi akurasi, *Precision*, *Recall*, dan *F1-Score* pada data uji. Kedua, evaluasi teknis yang dilakukan langsung pada perangkat ESP32-S3, mencakup latensi inferensi, penggunaan memori (*Flash* dan *Tensor arena*), serta konsumsi daya menggunakan sensor INA219. Apabila performa belum optimal, penelitian kembali ke tahap *Data*

Understanding, *Data Preparation*, atau *Modeling* untuk dilakukan penyesuaian sebelum tahap *Deployment*.

3.1.6. *Deployment*

Tahap akhir ini merupakan penerapan model terpilih ke perangkat keras secara nyata. Model dikonversi ke format *TFLite* dan dikompilasi menjadi *header C++* agar dapat di-*Flash* ke mikrokontroler ESP32-S3 menggunakan *TensorFlow Lite Micro*. Selain model, *firmware* yang diimplementasikan turut mencakup seluruh alur pemrosesan sinyal secara *on-device*, mulai dari akuisisi data sensor MPU6050, *bandpass filter*, transformasi FFT, ekstraksi fitur spektral, hingga mekanisme *majority voting* untuk menghasilkan keputusan klasifikasi akhir. Hasil klasifikasi beserta metadata selanjutnya dikirimkan ke server melalui protokol MQTT. Pengujian pada kondisi operasional nyata di sistem *cold chain* terintegrasi dilakukan pada tahap ini untuk memastikan sistem yang dirancang dapat bekerja sesuai dengan tujuan penelitian yang telah ditetapkan pada tahap *Business Understanding*.

3.2. Metode Pengumpulan Data

Pengumpulan data merupakan langkah penting dalam penelitian ini untuk memperoleh informasi yang valid dan akurat terkait sistem yang dikaji. Data yang diperoleh digunakan sebagai dasar dalam memahami permasalahan di lapangan serta sebagai landasan teknis dan teoritis dalam

tahapan penelitian selanjutnya. Metode pengumpulan data yang digunakan dalam penelitian ini dirancang agar selaras dengan tujuan penelitian yang telah dirumuskan pada subbab 1.4, dan meliputi:

3.2.1. Observasi

Observasi dilakukan secara langsung di CV. Mutiara Samudera Indonesia (MSI) yang berlokasi di Kota Tegal. Pengamatan difokuskan pada dua aspek utama: (1) kondisi operasional nyata sistem distribusi “*cold chain*” komoditas cumi-cumi, termasuk karakteristik mesin kompresor truk berpendingin yang digunakan; dan (2) perekaman data sinyal akselerasi menggunakan sensor MPU6050 yang dipasang langsung pada mesin kompresor dalam kondisi operasional normal. Dari hasil observasi, diperoleh data sinyal akselerasi tiga sumbu kondisi Normal yang selanjutnya dikombinasikan dengan data kelas Normal dari *dataset* MAFAULDA untuk membentuk *Training dataset* yang representatif terhadap kondisi mesin kompresor yang sesungguhnya digunakan. Temuan observasi ini dijadikan acuan dalam merancang sistem deteksi anomali yang bekerja secara *real-time* dan *on-device* (Tujuan Penelitian pertama), serta menentukan alur pra-pemrosesan sinyal berbasis FFT dan ekstraksi fitur spektral (Tujuan Penelitian kedua).

3.2.2. Wawancara

Wawancara dilaksanakan dengan Bapak Wahyu selaku sopir sekaligus teknisi perawatan truk pendingin di CV. Mutiara Samudera

Indonesia, menggunakan pendekatan semi-terstruktur di mana peneliti menyusun panduan pertanyaan inti secara sistematis namun tetap memberi ruang bagi narasumber untuk menjelaskan pengalaman lapangan secara lebih mendalam. Wawancara difokuskan pada tiga hal: (1) gejala awal dan pola kerusakan yang umum terjadi pada mesin kompresor truk berpendingin, (2) kendala teknis serta mekanisme pengecekan kondisi mesin yang selama ini diterapkan, dan (3) masukan bagi pengembangan sistem pemantauan yang dirancang dalam penelitian ini. Dari hasil wawancara, ditemukan bahwa pengecekan kondisi mesin masih dilakukan secara manual dan berkala, sehingga gejala awal kerusakan sering kali tidak terdeteksi tepat waktu. Temuan ini memperkuat urgensi permasalahan yang melandasi Tujuan Penelitian pertama, yaitu perancangan sistem deteksi anomali otomatis sebagai pengganti inspeksi manual.

3.2.3. Studi Literatur

Studi literatur dilakukan dengan mengkaji *dataset Machinery Fault Database* (MAFAULDA) yang dikembangkan oleh *Universidade Federal do Rio de Janeiro* sebagai basis data publik untuk penelitian sistem pemantauan kondisi mesin berputar. *Dataset* ini memuat rekaman sinyal akselerasi tiga sumbu dari kondisi mesin Normal, *Imbalance*, dan *Bearing Fault* yang direkam menggunakan sensor akselerometer pada berbagai kecepatan putar. *Dataset* MAFAULDA digunakan sebagai referensi utama dalam pembentukan


label kelas *Normal*, *Imbalance*, dan *Bearing* pada proses pelatihan model, di mana karakteristik spektral tiap kondisi pada dataset ini menjadi acuan dalam menentukan rentang frekuensi filter dan fitur spektral yang diekstraksi pada tahap pra-pemrosesan sinyal. Selain itu, studi literatur juga mencakup penelaahan jurnal dan *prosiding* dari *Google Scholar* terkait metode transformasi FFT, ekstraksi fitur spektral, arsitektur *Multi-Layer Perceptron* (MLP), serta teknik optimasi model melalui *pruning* dan *Quantization* INT8, dan dokumentasi teknis resmi meliputi *datasheet* mikrokontroler ESP32-S3 dan sensor MPU6050, serta dokumentasi *TensorFlow Lite Micro* sebagai acuan dalam implementasi model pada perangkat dengan sumber daya terbatas.

3.3. Tempat dan Waktu Penelitian

3.3.1. Tempat Penelitian

Tempat penelitian ini dilaksanakan di CV. Mutiara Samudera Indonesia (MSI) yang berlokasi di Jl. Bali No. 34, Mintaragen, Kecamatan Tegal Timur, Kota Tegal, Jawa Tengah 52121. Lokasi ini dipilih karena CV. Mutiara Samudera Indonesia bergerak di bidang pengolahan dan distribusi hasil perikanan, sehingga sangat relevan dengan objek penelitian yang berfokus pada pemantauan kondisi distribusi komoditas perikanan. Melalui pelaksanaan penelitian di lingkungan operasional perusahaan, sistem yang dikembangkan dapat

diuji secara langsung sesuai dengan kondisi nyata di lapangan. Lokasi penelitian pada CV. Mutiara Samudera Indonesia ditunjukkan pada Gambar 3.2.



Gambar 3.2 Peta Lokasi Penelitian

3.3.2. Waktu Penelitian

Penelitian ini dilaksanakan selama 8 bulan, dimulai dari bulan Desember 2025 hingga Juni 2026, dengan tahapan yang disusun mengikuti alur kerangka kerja CRISP-DM (*Cross-Industry Standard Process for Data Mining*) sebagaimana dijelaskan pada Sub-bab 3.1. Pada bulan pertama (Desember 2025), dilakukan tahap *Business Understanding*, yaitu identifikasi permasalahan operasional di CV. MSI, penetapan tujuan dan batasan penelitian, penentuan target kelas klasifikasi (*Normal*, *Imbalance*, dan *Bearing*), serta studi literatur yang mencakup kajian konsep IoT, *edge computing*, *TinyML*, metode FFT, serta teknik ekstraksi fitur dan MLP. Pada bulan kedua (Januari 2026), dilakukan tahap *Data Understanding*, yaitu pengumpulan data

yang meliputi perekaman sinyal akselerasi kondisi Normal dari mesin kompresor truk berpendingin di CV. MSI serta pengunduhan dan seleksi data kondisi *Imbalance* dan *Bearing* dari *dataset* publik MAFAULDA, dilanjutkan dengan pemeriksaan karakteristik data untuk memastikan kesesuaiannya dengan kebutuhan sistem. Pada bulan ketiga (Februari 2026), dilakukan tahap *Data Preparation* dan *Modeling*, yang mencakup pra-pemrosesan sinyal, transformasi FFT, ekstraksi fitur spektral, serta pembangunan dan pelatihan model MLP sehingga menghasilkan empat varian model (V1-V4). Pada bulan keempat (Maret 2026), dilakukan tahap *Evaluation*, yaitu pengujian dan evaluasi performa klasifikasi (akurasi, *Precision*, *Recall*, dan *F1-Score*) terhadap empat varian model (V1-V4) untuk menentukan varian model yang paling optimal. Apabila hasil evaluasi belum optimal, dilakukan iterasi kembali ke tahap *Data Understanding*, *Data Preparation*, atau *Modeling* sebelum melanjutkan ke tahap berikutnya. Pada bulan kelima (April 2026), dilakukan tahap *Deployment*, yaitu konversi model terpilih ke format *TFLite* dan *header C++*, implementasi *firmware* pada mikrokontroler ESP32-S3, integrasi seluruh alur pemrosesan sinyal secara *on-device*, serta pengujian performa teknis (latensi inferensi, penggunaan memori, dan konsumsi daya) pada kondisi operasional nyata. Pada bulan keenam sampai bulan kedelapan (Mei 2026 sampai Juli 2026), dilakukan penyelesaian penulisan laporan tugas akhir.