

BAB I PENDAHULUAN

1.1 Latar Belakang

Industri otomotif saat ini mengalami transformasi signifikan yang didorong oleh meningkatnya kompleksitas perangkat lunak dan kebutuhan pengolahan data kendaraan (Panchal & Wang, 2023). Permasalahan utama yang dihadapi mencakup tingginya tarif perbaikan mesin, banyaknya bengkel yang belum memenuhi standar, rendahnya kualitas teknisi, serta maraknya peredaran suku cadang bekas (Adetunla et al., 2022). Tantangan-tantangan ini juga diperparah oleh kebutuhan akan suku cadang yang lebih murah dan tahan lama, serta permintaan pasar terhadap inovasi mesin sepeda motor. Konsekuensinya, produsen dituntut untuk menyediakan mesin yang sesuai dengan ekspektasi pasar, sekaligus membangun sistem perawatan yang efisien dan hemat biaya.

Pendekatan optimisasi perangkat keras (*hardware*) dan perangkat lunak (*software*) untuk penjadwalan perawatan mesin otomotif telah menunjukkan pertumbuhan signifikan dalam pengembangan sistem pemeliharaan berbasis perangkat lunak, yang disesuaikan dengan kendala karakteristik spesifik industri otomotif (Ghammam et al., 2024). Berbagai solusi telah dikembangkan, mulai dari perawatan terjadwal, pengurangan ketergantungan pada teknik non-standar, peningkatan penggunaan alat diagnostik, hingga dukungan kebijakan pemerintah (Adetunla et al., 2024). Inovasi ini dirancang untuk menyederhanakan arsitektur sistem, meningkatkan modularitas, serta memperkuat kemampuan perangkat lunak dalam sistem otomotif (Fernández Blanco et al., 2023). Dengan demikian, industri otomotif mengadopsi arsitektur berbasis perangkat lunak untuk menjawab dinamika kebutuhan sekaligus menjamin keamanan dan integritas sistem kendaraan.

Seiring perkembangan tersebut, sektor otomotif semakin banyak mengadopsi berbagai strategi pemeliharaan guna meningkatkan efisiensi dan menekan pengeluaran. Peralihan dari metode reaktif ke pendekatan preventif dan prediktif telah dikukuhkan oleh berbagai penelitian. Pemeliharaan reaktif dilakukan setelah terjadi kegagalan, sedangkan pemeliharaan preventif mengikuti sifat terjadwal. Sementara itu, pemeliharaan prediktif (*Predictive Maintenance = PdM*) memanfaatkan data sensor *real-time* untuk menilai kondisi peralatan dan memproyeksikan sisa masa pakainya (Einabadi et al., 2023). *Predictive maintenance* menawarkan banyak keuntungan, seperti perencanaan perawatan yang optimal, efisiensi biaya, dan peningkatan ketersediaan peralatan (Singh et al., 2023). Meskipun begitu, penerapannya di sektor otomotif masih terkendala oleh keterbatasan akses sensor yang terbatas dan minimnya ketersediaan data. Dalam konteks tersebut, metode pembelajaran mesin menjadi solusi potensial untuk menganalisis data dan membangun model prediktif, bahkan ketika informasi yang tersedia terbatas (Jain et al., 2022).

Teknologi pembelajaran mesin telah merevolusi praktik perawatan di industri otomotif dengan memungkinkan deteksi kerusakan dan estimasi kebutuhan perawatan melalui analisis data sensor berskala besar (Erkut Yiğit et al., 2020). Pendekatan ini membantu mencegah kerusakan mendadak pada komponen (Ravi Aravind et al., 2022). Meski demikian, tantangan seperti akuisisi data, pemilihan algoritma, dan ketidakpastian kondisi lingkungan masih menjadi hambatan dalam implementasi pemeliharaan prediktif.

Industri otomotif kini bergerak menuju konsep *maintenance-as-a-service* dengan memanfaatkan data waktu nyata dari kendaraan yang terhubung (Ravi Aravind et al., 2022). Teknik pembelajaran mesin, seperti *decision tree* dan algoritma deteksi anomali, telah digunakan untuk menganalisis data historis dalam mengoptimalkan proses operasi dan pemeliharaan (Priyank Singh et al., 2024). Namun, tantangan tetap ada, terutama dalam hal keterbatasan data public dan kebutuhan akan metode *deep learning* yang efisien dan dapat dijelaskan (Andreas Theissler et al., 2021).

Pembelajaran mesin dan pendekatan berbasis data merevolusi praktik perawatan di industri otomotif. Perawatan prediktif yang mengandalkan jaringan saraf tiruan (*artificial neural network*) dan data sensor waktu nyata terbukti mampu mengoptimalkan perawatan sekaligus menekan biaya operasional (Einabadi et al., 2019). Sistem pembelajaran mesin juga memungkinkan analisis data historis untuk menghasilkan rekomendasi strategis bagi proses perawatan (Singh et al., 2024). Strategi perawatan yang tepat sangat krusial dalam meningkatkan kualitas mesin, keandalan sistem, dan produktivitas keseluruhan industri otomotif (Sarjono et al., 2021). Pemilihan strategi perawatan ideal melibatkan pertimbangan multi-dimensi seperti skala operasi, biaya perawatan, dan proses produksi. Pihak industri otomotif harus mempertimbangkan beberapa hal seperti besarnya operasi bisnis, biaya yang terkait dengan kegagalan, implikasi untuk keselamatan, dan proses pemeliharaan dengan pendekatan korektif, preventif dan prediktif (Hamasha et al., 2023). Pemanfaatan teknologi ini memungkinkan respon cepat terhadap dinamika pasar, pengurangan biaya, dan peningkatan kepuasan pelanggan.

Dalam konteks model pembelajaran mesin, algoritma *RandomForest* menunjukkan performa unggul dalam berbagai studi pemeliharaan prediktif. Misalnya, *RandomForest* mencatat akurasi klasifikasi sebesar 100% dalam membedakan kerusakan kondisi kerusakan dan normal (Wu et al., 2024). Serta mencapai akurasi 91,98% dalam prediksi perawatan (Hsu et al., 2020). Model *Artificial Neural Network* (ANN) menghasilkan akurasi 88,98% dalam studi serupa (Hakami, 2024). Namun pada dataset terbatas, *RandomForest* terbukti lebih stabil dan akurat dibanding *Gradient Boosting Machine* (GBM) (Cha et al., 2021). Keunggulan model ini dalam klasifikasi multikelas dan mitigasi *overfitting* menjadikannya pilihan utama untuk pemeliharaan prediktif, meskipun efektivitas tetap bergantung pada karakteristik data dan konteks aplikasi (Wu et al., 2024).

Berdasarkan uraian tersebut, penelitian ini bertujuan mengeksplorasi penerapan sistem pemeliharaan prediktif berbasis teknologi pembelajaran mesin dan data sensor di industri otomotif, khususnya dengan menggunakan model *RandomForest*. Fokus utama penelitian ini adalah mengidentifikasi tantangan, peluang, serta manfaat dari penerapan teknologi tersebut dalam mengoptimalkan kinerja peralatan dan menurunkan biaya operasional. Penelitian ini diharapkan dapat memberikan kontribusi nyata terhadap implementasi pemeliharaan prediktif yang efisien, andal, dan adaptif dalam system manufaktur otomotif yang semakin kompleks.

1.2 Tujuan Penelitian

Adapun tujuan penelitian ini adalah sebagai berikut:

1. Merancang arsitektur sistem pemeliharaan prediktif untuk kendaraan bermotor dengan memanfaatkan parameter suara dan getaran mesin guna memberikan peringatan dini terhadap potensi kerusakan komponen.
2. Menerapkan dan mengintegrasikan model pembelajaran mesin untuk mendeteksi anomali serta memprediksi waktu optimal perawatan dan penggantian komponen berdasarkan parameter suara dan getaran.
3. Mengevaluasi kinerja sistem prediktif dalam hal akurasi deteksi anomali, efisiensi perawatan kendaraan, pengurangan biaya operasional, dan penurunan waktu henti kendaraan.

1.3 Manfaat Penelitian

Adapun manfaat penelitian ini adalah sebagai berikut:

1. Memberikan solusi sistematis dalam deteksi dini kerusakan komponen kendaraan, membantu produsen otomotif dan pengguna kendaraan untuk melakukan perawatan yang lebih tepat waktu serta mencegah kerusakan fatal.
2. Mendorong adopsi teknologi digital dan otomatisasi dalam pengelolaan kendaraan, mendukung transformasi menuju industri otomotif yang cerdas dan berbasis data.
3. Menawarkan alternatif sistem pemantauan mesin motor yang ekonomis dan fleksibel, tanpa memerlukan biaya infrastruktur yang besar.

BAB II

METODE PENELITIAN

2.1 Tempat dan Waktu

Penelitian ini dilaksanakan pada bulan Februari hingga Juni 2025, di Laboratorium Elektronika dan Instrumentasi, Departemen Fisika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Hasanuddin, Makassar.


2.2 Peralatan Penelitian

Peralatan yang digunakan dalam penelitian ini adalah sebagai berikut:

1. ESP32 berfungsi sebagai mikrokontroler utama yang membaca data dari sensor dan mengirimkannya ke sistem model AI yang dikembangkan. Mikrokontroler ini dipilih karena memiliki kemampuan pemrosesan data yang sesuai dengan kebutuhan sensor.
2. Sensor INMP441 merupakan mikrofon digital berbasis I2S yang digunakan untuk mendeteksi suara mesin. Sensor ini memiliki sensitivitas tinggi terhadap gelombang akustik dan menghasilkan rekaman suara dengan tingkat derau (*noise*) yang rendah.
3. Sensor ADXL345 merupakan akselerometer digital tiga sumbu (X, Y, Z) yang digunakan untuk mendeteksi getaran mesin. Sensor ini mampu mendeteksi percepatan dan perubahan posisi dengan ketelitian tinggi serta sensitivitas terhadap perubahan posisi kecil.
4. *Power Supply* untuk menyuplai energi listrik untuk ESP32 dan sensor-sensor yang terhubung.
5. Kabel Jumper berfungsi menghubungkan pin sensor dengan pin ESP32.
6. MicroSD Module berfungsi untuk menyimpan data sensor dalam format CSV.
7. Laptop digunakan untuk memprogram ESP32, membaca data sensor, mengunggah data ke sistem model AI yang dikembangkan, serta mengunggah dataset ke platform pelatihan model AI.
8. Perangkat *Socket Set* digunakan untuk melepas dan mengencangkan baut dan mur yang ada pada sepeda motor.
9. *Tracker/Puller* berfungsi sebagai pelepas komponen *bearing* (lahar) dan *pulley* CVT.
10. *Motorcycle Stand* digunakan untuk menyangga dan menstabilkan sepeda motor selama proses pendeteksian getaran dan kebisingan, serta membantu proses pelepasan kerangka motor.

2.3 Metode Kerja

Penelitian ini terdiri atas beberapa tahapan, sebagaimana ditunjukkan dalam diagram alur pada Gambar 1. Ruang lingkup penelitian dibatasi pada perancangan dan pembuatan sistem pemeliharaan prediktif berbasis kecerdasan buatan.




Gambar 1 Bagan alir penelitian

Langkah awal penelitian adalah melakukan studi literatur untuk mengkaji referensi terkait sistem pemeliharaan prediktif berbasis kecerdasan buatan. Setelah itu, dilakukan identifikasi masalah yang diangkat dan dibahas sebagai tujuan penelitian. Tahap berikutnya meliputi persiapan peralatan dan material, serta perancangan perangkat keras dan perangkat lunak sistem. Dalam perancangan perangkat keras, dilakukan pengujian alat untuk memastikan konektivitas antar komponen. Kemudian, dilakukan proses kalibrasi sensor secara relatif yaitu dengan menggunakan data latihan sebagai acuan guna memastikan akurasi pembacaan. Setelah sensor dikalibrasi, sistem diuji untuk mengevaluasi akurasi deteksi dan kinerja keseluruhan. Jika hasil pembacaan sensor dinyatakan akurat, maka proses pengambilan data dapat dimulai. Data yang diambil adalah data suara dan getaran pada sepeda motor. Pengolahan data dilakukan pembersihan (*data cleaning*) dan pengorganisasian untuk menyiapkan data pelatihan. Perangkat lunak, yang dikembangkan terdiri atas dua bagian: (1) program untuk memberikan instruksi ke mikrokontroler, dan (2) program untuk merancang model AI. Kedua program ini diuji melalui simulasi untuk memastikan fungsionalitasnya. Setelah perangkat lunak dan perangkat keras siap, dilanjutkan dengan pelatihan model AI menggunakan data yang dikumpul. Tujuan pelatihan ini untuk mengoptimalkan kemampuan model dalam mendeteksi kondisi normal dan anomali, serta memprediksi sisa masa pakai. Setelah pelatihan, dilakukan validasi model menggunakan data baru yang belum pernah digunakan pada proses pelatihan. Proses ini penting untuk menguji keandalan model dalam situasi nyata. Akhirnya, hasil pelatihan dan validasi akan dinalisis untuk menarik kesimpulan mengenai efektivitas system pemeliharaan prediktif yang dirancang. Penelitian ini juga akan memberikan rekomendasi untuk perbaikan dan pengembangan system di masa mendatang.

2.3.1 Perancangan *Hardware*


Penelitian ini diawali dengan perancangan perangkat keras yang difokuskan pada sistem prediksi perawatan mesin kendaraan bermotor melalui deteksi anomali pada suara dan getaran. Sistem ini dirancang untuk memantau kondisi secara berkelanjutan dan memberikan peringatan dini terhadap potensi kerusakan. Perancangan perangkat keras terbagi menjadi dua fokus utama: pertama adalah pengumpulan data suara menggunakan sensor mikrofon digital dan kedua pengumpulan data getaran menggunakan sensor akselerometer. Kedua jenis data ini akan diproses oleh mikrokontroler ESP32 yang telah ditanamkan model kecerdasan buatan melalui platform sistem model AI yang dikembangkan. Tahapan perancangan perangkat keras untuk sistem prediksi ditampilkan pada Gambar 2.



Gambar 1. Perancangan perangkat keras sistem pemeliharaan prediktif

Langkah awal dalam perancangan perangkat keras difokuskan pada optimalisasi akusisi suara menggunakan sensor INMP441. Sensor ini dipilih karena kemampuannya menangkap sinyal suara dalam format digital melalui antarmuka I2S, sehingga sangat sesuai untuk aplikasi pemrosesan sinyal akustik yang membutuhkan presisi tinggi (Govilkar et al., 2024). INMP441 dihubungkan langsung ke ESP32 melalui jalur komunikasi digital; data suara yang diterima kemudian diproses dan disimpan dalam format file .csv untuk dianalisis lebih lanjut dalam proses prediksi pemeliharaan. Tahapan selanjutnya adalah perancangan sensor getaran memanfaatkan sensor ADXL345. Sensor ini merupakan akselerometer digital tiga sumbu (x, y dan z) yang juga memiliki fitur giroskop, memungkinkan deteksi perubahan percepatan serta rotasi pada posisi tertentu (Jalal et al., 2020). Dalam penelitian ini, analisis difokuskan pada data percepatan dari satu arah dominan, yaitu arah utama getaran dari mesin yang sedang diamati.

Sistem dirancang untuk memantau kondisi mesin secara langsung dan memberikan peringatan dini apabila terdeteksi malfungsi, yang dapat dikenali melalui analisis pola suara dan getaran yang tidak normal. Dengan mengintegrasikan perekam suara digital dan sensor getaran dalam satu sistem berbasis mikrokontroler, sistem ini diharapkan mampu memberikan solusi prediktif yang efisien dan cerdas sesuai kebutuhan industri. Hasil keluaran dari sistem prediksi ini dapat diintegrasikan lebih lanjut dengan *dashboard* untuk mendukung program pemeliharaan berbasis kondisi secara *real-time*, serta membantu teknisi dalam mengambil keputusan dengan lebih cepat dan akurat. Secara keseluruhan, rancangan sistem perangkat keras untuk pemeliharaan prediktif ini divisualisasikan pada Gambar 3.




Gambar 3. Diagram blok sistem pemeliharaan prediktif

Sistem ini memiliki kemampuan untuk mengidentifikasi potensi kerusakan pada mesin kendaraan melalui analisis variasi kebisingan dan getaran, dengan memanfaatkan sensor akustik INMP441 dan akselerometer ADXL345. Data yang diperoleh akan diarsipkan dan dianalisis oleh model kecerdasan buatan berbasis *RandomForest* yang dirancang khusus untuk mengenali pola dan mendeteksi anomali dalam fluktuasi sinyal mesin. Sistem ini dapat menyajikan hasil deteksi anomali melalui serial monitor dan tampilan diagnosis, memungkinkan pemantauan kondisi peralatan secara berkelanjutan tanpa perlu menghentikan operasional mesin.

2.3.2 Perancangan Software

Perangkat lunak dalam penelitian ini terbagi menjadi 2 bagian yang saling terhubung, yaitu perancangan perangkat lunak untuk konfigurasi mikrokontroler dan sensor, yang kedua perancangan model kecerdasan buatan. Seluruh bagian ini dikembangkan oleh bahasa pemrograman *python* dan C++ melalui Arduino IDE. Perancangan perangkat lunak untuk mikrokontroler menggunakan Arduino IDE karena antarmuka nya yang mudah dipahami dan banyak digunakan untuk pengembangan berbasis mikrokontroler. Arduino IDE memungkinkan pengguna untuk menulis program dalam editor teks mengompilasi menjadi kode mesin, serta mengunggah ke semua versi papan Arduino, termasuk ESP32. ESP32 dihubungkan ke komputer melalui kabel USB dan dikonfigurasi menggunakan Arduino IDE (Валерия Морозова, 2018). Untuk memprogram mikrokontroler, Arduino menyediakan IDE yang mendukung bahasa pemrograman C dan C++ yang umum digunakan dalam pengembangan system tertanam (M. Papoutsidakis, 2018). Melalui integrasi anatara Arduino IDE dan model AI yang dirancang, sistem mampu menampilkan hasil data dan memberikan peringatan dini kepada pengguna mengenai kondisi mesin. Diagram alur perancangan perangkat lunak ditampilkan pada Gambar 4.



Gambar 4. Diagram alur perancangan perangkat lunak


Proses dimulai dari akusisi data dari sensor yang terhubung ke ESP32. Mikrokontroler ESP32 mengirimkan data secara *real-time* ke Arduino IDE, dimana data tersebut ditampilkan melalui *serial monitor* dan direkam dalam format csv untuk memudahkan proses pengolahan lanjutan. Data csv yang telah dikumpulkan kemudian diekspor ke sistem pemrosesan model AI. Tahapan pertama dalam pemrosesan ini adalah ekstraksi fitur penting dari data sensor untuk meningkatkan akurasi model melalui teknik rekayasa fitur (*feature engineering*). Selanjutnya, data dibagi menjadi dua bagian yaitu data latih dan data uji/validasi. Data latih akan melalui proses penskalaan fitur *feature scaling* agar distribusi data baru yang masuk sesuai dengan parameter yang dibentuk data pelatihan. Setelah itu, model dilatih menggunakan data tersebut agar dapat mengenali pola dari data input. Proses pelatihan ini dilanjutkan dengan evaluasi model untuk mengukur kinerja dan akurasinya. Jika hasil evaluasi menunjukkan performa yang memadai, maka model AI siap diimplementasikan dalam sistem pemeliharaan prediktif. Hasil prediksi tersebut akan ditampilkan pada *dashboard* untuk memberikan informasi visual mengenai status mesin dan potensi kerusakan, sehingga pengguna dapat mengambil Tindakan pemeliharaan dengan lebih cepat dan tepat.

2.3.3 Perancangan Model *Artificial Intelligence*

Tujuan utama dari penelitian ini adalah mengembangkan sistem berbasis *artificial intelligence* untuk memprediksi sisa masa pakai dan mendiagnosis jenis kerusakan pada sepeda motor. Metodologi perancangan model mencakup beberapa tahap, dimulai dari identifikasi algoritma yang paling sesuai, perancangan fitur yang relevan, hingga pelatihan dan evaluasi model secara sistematis. Identifikasi algoritma yang tepat merupakan tahap awal yang krusial untuk memastikan bahwa model yang dihasilkan mampu memberikan prediksi yang akurat. Selain itu, rekayasa fitur dilakukan untuk mengelola data sensor mentah menjadi lebih bermakna, sehingga meningkatkan kemampuan model dalam mengenali pola-pola penting yang berkaitan dengan kerusakan mesin. Tahap akhir dari perancangan ini adalah pelatihan dan evaluasi untuk memastikan bahwa sistem yang dibangun mampu menghasilkan prediksi yang valid dan dapat ditindaklanjuti.

Dalam penelitian ini, algoritma *RandomForest* dipilih sebagai dasar model karena kemampuannya yang andal dalam menangani tugas klasifikasi dan regresi. *RandomForest* merupakan metode ansambel yang menggabungkan banyak pohon

keputusan yang bekerja secara independen. Pendekatan ini meningkatkan stabilitas prediksi serta mengurangi resiko *overfitting* yang sering ditemukan pada mode tunggal. Keunggulan utama *RandomForest* terletak pada kemampuannya untuk mengenali pola yang kompleks, seperti sinyal getaran dan suara nonlinear yang berkaitan dengan suara mesin. Selain itu, algoritma ini mampu mengevaluasi signifikansi fitur, yang terbukti sangat bermanfaat untuk menentukan sensor atau parameter mana yang berpengaruh dalam mendeteksi kerusakan sepeda motor. Dalam konteks penelitian ini, digunakan dua jenis model berbasis *RandomForest*: Pertama *RandomForestClassifier* untuk mengklasifikasikan jenis kerusakan dan *RandomForestRegressor* untuk memprediksi sisa masa pakai mesin. Algoritma *RandomForest* ditunjukkan pada Gambar 5.



Gambar 5. Algoritma *RandomForest*

RandomForest bekerja dengan membangun sejumlah pohon keputusan (*decision tree*) yang masing-masing dilatih menggunakan subset acak dari data dan fitur. Setiap pohon menghasilkan prediksi (*Result-1*, *Result-2*, hingga *Result-N*), yang kemudian digabungkan melalui metode *majority voting* (untuk klasifikasi) dan *averaging* (untuk regresi), guna memperoleh hasil akhir yang lebih akurat dan stabil.


Dalam setiap pohon keputusan, algoritma menggunakan metrik pemisahan untuk menentukan split terbaik di setiap node. Salah satu metrik yang umum digunakan adalah *Gini Impurity*, yang mengukur seberapa baik suatu split memisahkan kelas-kelas data. Persamaan untuk menghitung *Gini Impurity* dirumuskan pada persamaan 1.

$$Gini\ Impurity = 1 - \sum_{c=1}^C (P_i)^2 \quad (1)$$

Dimana C adalah jumlah kelas, dan P_i adalah proporsi data pada kelas ke- i di node (cabang pohon keputusan) tersebut. Semakin kecil nilai *Gini Impurity*, semakin homogen data pada node tersebut. *RandomForest* akan memilih pemisahan (*split*) yang meminimalkan nilai *Gini*.

Untuk meningkatkan akurasi model *RandomForest* dilakukan *feature engineering* guna mentransformasikan data mentah menjadi representasi yang lebih informatif dan mudah untuk dipahami oleh model. Verdonck et al.,(2021) menekankan bahwa rekayasa fitur dapat meningkatkan kinerja *machine learning* dengan fokus pada manipulasi data,

bukan sekadar pemilihan algoritma. Beberapa fitur yang penting dan dihasilkan antara lain adalah *Rolling Average* untuk mendeteksi perubahan tren jangka pendek dan menengah pada getaran atau suara. Kedua, *Rolling Standard Deviation* untuk mengukur fluktuabilitas sinyal yang dapat menjadi indikator kondisi abnormal atau kerusakan. Secara keseluruhan, rekayasa fitur terbukti bermanfaat dalam meningkatkan prediksi, mengurangi kebutuhan input, dan meningkatkan efisiensi di berbagai domain. Alur kerja rekayasa fitur seperti pada gambar 6.



Gambar 6. Alur kerja rekayasa fitur

Tahapan ini diawali dengan penggabungan data dari berbagai sumber, dilanjutkan dengan pemeriksaan kualitas data untuk menghindari nilai kosong dan data duplikat. Selain itu dilakukan transformasi data, lalu tahap pembuatan *table fitur*, dimana variabel dibagi menjadi fitur dan target. Dataset akhir ini digunakan untuk membangun model AI.

Setelah perancangan model selesai, proses berikutnya adalah pelatihan (*training*) dan evaluasi untuk menguji performa model saat diimplementasikan. Pertama-tama, dilakukan pembagian data (*data splitting*) menjadi tiga bagian yaitu data pelatihan (70%), validasi (15%), dan tes (15%). Data latih digunakan untuk mempelajari pola dan karakteristik data. Sedangkan, data latih digunakan untuk evaluasi performa model selama proses pelatihan. Data uji hanya digunakan sekali diakhir untuk mengukur akurasi akhir model terhadap data yang belum pernah dilihat sebelumnya.

Setelah pelatihan ini selesai, model diuji menggunakan metrik evaluasi. Untuk konteks klasifikasi, metrik yang digunakan antara lain: akurasi, presisi, *recall*, F1 Score, dan *Confusion Matrix*.. Untuk regresi atau prediksi waktu perbaikan mesin, digunakan *Root Mean Squared Error*, *Mean Absolute Error* dan R^2 Score. Dengan mengikuti tahapan metodologis ini secara sistematis, diharapkan model yang dibangun dapat memberikan prediksi yang akurat dan handal dalam system pemeliharaan prediktif sepeda motor.

2.3.4 Pengujian Alat


Pengujian alat dilakukan terhadap sistem yang telah selesai dirancang untuk memastikan seluruh komponen bekerja dengan baik. Tahap awal pengujian adalah memastikan bahwa mikrokontroler ESP32 telah berhasil terhubung dengan sensor INMP441 dan ADXL345. Pengujian ini dilakukan dengan cara mengunggah program uji sederhana guna memverifikasi bahwa masing-masing sensor memberikan respon yang sesuai. Jika data belum muncul di *Serial Monitor*, maka sambungan kabel dan

konfigurasi pin diperiksa kembali hingga aliran sinyal terekam secara benar dan stabil. Setelah kestabilan koneksi terjamin, dilakukan pembacaan data secara massal dari sensor suara dan getaran untuk merekam respon dari mesin kendaraan bermotor. Data yang direkam akan disimpan sementara dalam *buffer internal*.

Pengujian sensor juga mencakup tahap kalibrasi, yang dilakukan dengan pendekatan kalibrasi data relatif. Dalam pengukuran yang berbasis AI, konsistensi data lebih penting daripada nilai absolut. Oleh karena itu, yang dibutuhkan adalah pembacaan suara dan getaran yang konsisten sehingga model dapat mempelajari pola data dengan efektif. Model *machine learning*, khususnya yang berbasis pohon keputusan seperti *RandomForest*, bekerja dengan mempelajari pola, tren, dan perubahan relatif dalam data. Model ini tidak bergantung pada nilai absolut sensor, melainkan pada keteraturan pola yang muncul dalam variasi data tersebut.

2.3.5 Bagan Alir Sistem Kerja Alat

Bagan alir sistem kerja alat terdiri atas dua bagian utama yaitu: pembacaan sensor suara dan pembacaan sensor getaran. Alur kerja keseluruhan sistem ditunjukkan pada Gambar 7.



Gambar 7. Bagan alir sistem kerja alat

Proses dimulai dengan menginisialisasi seluruh perangkat keras, termasuk sensor suara INMP441 dan sensor getaran ADXL345. Pada tahap ini, konfigurasi pin dan pengaturan protokol komunikasi antar perangkat (I2C digunakan untuk ADXL345 dan I2S digunakan untuk INMP441) guna memastikan konektivitas antar perangkat berjalan dengan baik. Sistem akan memverifikasi apakah semua sensor aktif dan siap membaca data secara *real-time*. Jika terdapat sensor yang belum memberikan respon, system akan terus melakukan pemantauan(*looping*) hingga data berhasil terbaca. Setelah pembacaan berhasil dilakukan, data dari masing-masing sensor akan disimpan dalam format csv. Data dari kedua sensor direkam secara simultan dalam satu file, dengan setiap parameter pengukuran dipisahkan dalam kolom masing-masing. File csv yang dihasilkan kemudian dikirimkan ke sistem model AI untuk diproses lebih lanjut.

Model AI akan melakukan perhitungan terhadap nilai kesalahan rekonstruksi guna menentukan apakah data tersebut termasuk dalam kategori normal atau anomali. Apabila kesalahan melebihi ambang batas tertentu, kondisi tersebut dikategorikan sebagai abnormal atau indikasi kerusakan. Sebaliknya, jika nilai kesalahan berada masih berada di bawah ambang batas, maka data tersebut dianggap normal dan tetap dicatat untuk kebutuhan analisis selanjutnya. Hasil klasifikasi kondisi mesin, baik normal maupun abnormal, akan ditampilkan dalam dashboard visual, dan seluruh data yang telah diukur akan disimpan pada sistem penyimpanan *cloud*. Hal ini memudahkan pengguna dalam memantau hasil prediksi serta menyimpan histori data pemeliharaan secara efisien.