

BAB I

PENDAHULUAN

1.1. Latar Belakang

Indonesia, sebagai negara kepulauan terbesar di dunia, menempatkan sektor perikanan sebagai pilar vital kedaulatan pangan nasional [1]. Dengan potensi lestari mencapai 9,3 juta ton per tahun [2], cumi-cumi (*Loligo sp.*) menjadi komoditas strategis dan produk ekspor non-ikan utama setelah udang [3]. Data KKP tahun 2024 mencatat volume produksi cumi-cumi mencapai 251.861 ton [4]. Namun, besarnya angka produksi tersebut tidak sejalan dengan karakteristik biologis cumi-cumi yang sangat mudah rusak (*highly perishable*) [5]. Penurunan mutu segera terjadi pasca-penangkapan, ditambah tekstur fisiknya yang lunak menuntut perlakuan teknis yang presisi selama distribusi [6]. Di lapangan, pasokan ke Unit Pengolahan Ikan (UPI) sering kali terhambat oleh degradasi kualitas akibat durasi pengiriman yang panjang dan kendala logistik di wilayah kepulauan [7]. Tingginya angka kerugian pascapanen hasil perikanan di Indonesia yang diperkirakan mencapai 20% hingga 30% menunjukkan perlunya sistem pemantauan *cold chain* yang lebih ketat untuk menjaga stabilitas nilai ekonomi komoditas tersebut [8]. *Cold chain* merupakan sistem logistik yang menjaga produk sensitif suhu tetap berada pada kondisi temperatur rendah secara menyeluruh mulai dari penyimpanan, transportasi, hingga distribusi ke konsumen [9].

Risiko tersebut turut teridentifikasi pada tingkat operasional CV. Mutiara Samudera Indonesia (MSI), perusahaan yang bergerak di bidang pengolahan dan distribusi hasil perikanan di Kota Tegal, Jawa Tengah, yang menjadi objek observasi dalam penelitian ini. Berdasarkan hasil observasi dan wawancara dengan teknisi perusahaan, ditemukan bahwa CV. MSI belum memiliki sistem pemantauan kondisi mesin kompresor truk berpendingin secara *real-time*. Pengecekan kondisi mesin selama ini masih dilakukan secara manual oleh teknisi, yaitu melalui inspeksi berkala tanpa dukungan sensor atau sistem deteksi otomatis, sehingga potensi kerusakan tidak dapat diketahui sejak dini. Kondisi ini pernah berdampak pada kerusakan parah pada mesin pendingin milik CV. MSI. Meskipun kerusakan tersebut belum sampai menyebabkan pembusukan pada muatan cumi-cumi yang didistribusikan, insiden ini tetap menimbulkan kerugian finansial akibat biaya perbaikan/penggantian unit mesin, serta menunjukkan bahwa risiko kegagalan sistem pendingin di CV. MSI bersifat nyata dan berpotensi meluas ke kerugian yang lebih besar apabila tidak segera diatasi dengan mekanisme deteksi dini yang memadai.

Penerapan *cold chain* menjadi prosedur standar yang tidak bisa ditawar untuk menekan risiko pembusukan tersebut [10], [11]. Suhu rendah secara efektif menghambat laju respirasi dan aktivitas bakteri [12]. Dalam praktiknya, distribusi cumi-cumi mengandalkan truk berpendingin yang efektivitasnya sangat bergantung pada stabilitas suhu dan kelembaban ruang

penyimpanan [13]. Kegagalan dalam menjaga parameter ini, sekecil apa pun, berdampak fatal terhadap kualitas muatan [14].

Kondisi yang dialami CV. MSI tersebut sejalan dengan kelemahan utama yang umum ditemukan dalam logistik *cold chain*, yaitu keterlambatan deteksi kerusakan sistem pendingin yang sering kali baru diketahui saat produk tiba di tujuan dalam kondisi buruk [15], [16]. Metode pemantauan konvensional yang bersifat manual tidak hanya rentan terhadap kelalaian manusia, tetapi juga gagal menyediakan data kondisi penyimpanan secara *real-time* [17]. Selain fluktuasi suhu, kegagalan mekanis pada unit pendingin juga dapat disebabkan oleh anomali vibrasi pada kompresor yang luput dari pengawasan [18]. Anomali pada pola getaran sering digunakan sebagai indikator awal kerusakan komponen atau ketidakseimbangan mekanis pada sistem pendingin [19]. Akibatnya, kerusakan mekanis pada sistem pendingin, seperti yang dialami CV. MSI, sering kali tidak terdeteksi sejak awal, sehingga penanganan insiden selama perjalanan sulit dilakukan secara preventif [20].

Dari segi teknologi, penerapan sistem *Internet of Things* (IoT) yang bergantung penuh pada konektivitas internet (*cloud-centric*) seringkali tidak optimal untuk kondisi infrastruktur Indonesia [21]. Ketidakstabilan sinyal di sepanjang jalur distribusi perikanan meningkatkan risiko kehilangan data (*data loss*) selama proses transmisi [22]. Selain itu, ketergantungan pada pengiriman data ke *cloud* menimbulkan latensi yang menghambat analisis anomali secara *real-time* [23]. Sebagai solusi, diperlukan pendekatan *edge*

computing melalui implementasi *Tiny Machine Learning (TinyML)* yang memungkinkan pemrosesan data dilakukan langsung pada perangkat [24]. Akan tetapi, pemrosesan di perangkat saja belum cukup jika metode deteksinya masih mengandalkan ambang batas (*threshold*). *Threshold* hanya melihat amplitudo sinyal di domain waktu, sehingga tidak bisa menangkap pola frekuensi yang justru menjadi ciri khas tiap jenis kerusakan mesin [25]. Kondisi *Imbalance* dan kerusakan *Bearing* memiliki sidik jari frekuensi yang berbeda, perbedaan ini hanya bisa dikenali melalui analisis spektral dan klasifikasi berbasis *machine learning* [26]. Di sisi lain, menjalankan model kecerdasan buatan di mikrokontroler bukan hal yang mudah karena keterbatasan memori (SRAM) dan daya komputasi yang sangat terbatas [27]. Model *Deep Learning* konvensional yang menggunakan format *Float32* cenderung terlalu besar dan boros memori untuk perangkat *embedded*, sehingga perlu dicari strategi optimasi yang tepat agar model bisa berjalan efisien di perangkat [28].

Berdasarkan tantangan tersebut, penelitian ini merancang sistem deteksi anomali getaran pada kompresor truk berpendingin menggunakan sensor MPU6050 [29], [30], [31]. Sinyal akselerasi yang didapat dari sensor diproses melalui tahap pra-pemrosesan dan transformasi *Fast Fourier Transform* (FFT) untuk mengubahnya dari domain waktu ke domain frekuensi, lalu dilakukan ekstraksi fitur spektral untuk mengambil karakteristik sinyal yang akan digunakan sebagai masukan model [32], [33]. Fitur ini kemudian diklasifikasikan menggunakan model *Multi-Layer*

Perceptron (MLP) yang dikenal mampu berjalan efisien pada mikrokontroler berdaya terbatas [34], [35], dan dalam penelitian ini dijalankan pada ESP32-S3 menggunakan *TensorFlow Lite Micro*. Selain itu, dilakukan juga evaluasi terhadap empat varian model hasil *pruning* dan *Quantization* INT8 untuk melihat perbandingan antara akurasi, ukuran model, latensi, memori, dan konsumsi daya [36], [37].

Urgensi perancangan sistem ini terletak pada kebutuhan pemantauan kompresor truk berpendingin yang bekerja secara cepat, akurat, dan mandiri tanpa bergantung pada konektivitas internet, kebutuhan yang sangat nyata dalam distribusi komoditas perikanan di mana kegagalan sistem pendingin berdampak langsung pada kualitas muatan. Oleh karena itu, dibuatlah sistem deteksi anomali berbasis *TinyML* dengan model *Multi-Layer Perceptron* (MLP) pada mikrokontroler ESP32-S3, yang mampu mengklasifikasikan kondisi kompresor (Normal, *Imbalance*, dan *Bearing*) secara *real-time* melalui transformasi FFT dan ekstraksi fitur spektral, sepenuhnya *on-device* tanpa ketergantungan *cloud*. Sistem yang dibangun terbukti mampu berjalan dengan akurasi 85,01%, latensi inferensi 586–794 μ s, dan hanya menggunakan 17,9% RAM serta 32,3% *Flash* dari kapasitas ESP32-S3, membuktikan bahwa deteksi anomali getaran kompresor dapat dilakukan secara mandiri dan efisien pada perangkat berdaya terbatas.

1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, rumusan masalah dalam penelitian ini adalah:

1. Bagaimana merancang sistem deteksi anomali getaran kompresor yang bekerja secara *real-time on-device*, sebagai pengganti pengecekan manual oleh teknisi, tanpa bergantung konektivitas internet menggunakan ESP32-S3 dan *TinyML*?
2. Bagaimana pra-pemrosesan sinyal FFT dan ekstraksi fitur spektral dapat menangkap karakteristik frekuensi yang membedakan kondisi Normal, *Imbalance*, dan *Bearing*?
3. Bagaimana performa model MLP dari segi akurasi, *Precision*, *Recall*, dan *F1-Score* dalam mengklasifikasikan kondisi kompresor berdasarkan fitur spektral hasil ekstraksi?
4. Bagaimana pengaruh *pruning* dan *Quantization* INT8 terhadap akurasi, ukuran model, latensi, memori, dan konsumsi daya model, serta varian mana yang paling optimal untuk diterapkan pada ESP32-S3?

1.3. Batasan Masalah

Agar penelitian ini tetap fokus pada analisis data dan tidak meluas ke hal teknis lain yang tidak perlu, penulis menetapkan batasan sebagai berikut:

1. Sensor yang digunakan hanya MPU6050 yang dipasang pada kompresor truk berpendingin milik CV. Mutiara Samudera Indonesia, dengan mikrokontroler ESP32-S3 sebagai platform implementasi.

2. Klasifikasi kondisi mesin dibatasi pada tiga kelas yaitu Normal, *Imbalance*, dan *Bearing*, dan tidak mencakup jenis kerusakan mekanis lainnya.
3. Arsitektur model yang digunakan hanya *Multi-Layer Perceptron* (MLP) dan tidak dibandingkan dengan arsitektur lain seperti CNN atau LSTM.
4. Optimasi model dibatasi pada teknik *pruning* dengan *sparsity* 50% dan *Quantization* INT8, tanpa menguji metode optimasi lainnya.
5. Data yang digunakan berasal dari *dataset* publik MAFAULDA dan rekaman lapangan di CV. Mutiara Samudera Indonesia, tanpa mencakup variasi kondisi lingkungan lain.

1.4. Tujuan Penelitian & Manfaat Penelitian

1.4.1. Tujuan Penelitian

1. Merancang sistem deteksi anomali getaran kompresor truk berpendingin yang bekerja secara *real-time* dan sepenuhnya *on-device* pada ESP32-S3 menggunakan pendekatan *TinyML*, sebagai pengganti mekanisme pengecekan manual yang selama ini dilakukan, tanpa bergantung pada konektivitas internet untuk proses inferensi.
2. Merancang alur pra-pemrosesan sinyal akselerasi berbasis FFT dan ekstraksi fitur spektral, serta menganalisis pola perbedaan karakteristik frekuensi pada kondisi mesin Normal, *Imbalance*, dan *Bearing*.

3. Mengevaluasi performa model MLP dari segi akurasi, *Precision*, *Recall*, dan *F1-Score* dalam mengklasifikasikan kondisi kompresor berdasarkan fitur spektral hasil ekstraksi.
4. Mengevaluasi pengaruh teknik *pruning* dan *Quantization* INT8 terhadap akurasi, ukuran model, latensi, memori, dan konsumsi daya, guna menentukan varian model yang paling optimal untuk diimplementasikan pada ESP32-S3.

1.4.2. Manfaat Penelitian

1. Penelitian ini menjadi sarana penerapan teori pengolahan sinyal (*signal processing*) dan kecerdasan buatan (*artificial intelligence*) dalam memecahkan masalah nyata di sektor logistik perikanan.
2. Meningkatkan keahlian dalam merancang sistem *edge computing* dan mengembangkan model *TinyML* pada perangkat dengan sumber daya terbatas.
3. Memberikan referensi teknis dan data empiris mengenai implementasi *Deep Learning* yang dioptimasi (kuantisasi) pada perangkat *resource constrained*, yang dapat menjadi acuan bagi periset di bidang *embedded system*.
4. Membuktikan peran aktif Universitas Harkat Negeri dalam mengembangkan teknologi tepat guna yang dapat dihilirisasi untuk mendukung kedaulatan pangan nasional di sektor perikanan dan kelautan.

5. Memberikan kepastian kualitas dan kesegaran komoditas cumi-cumi bagi konsumen melalui sistem pemantauan yang objektif dan terukur.
6. Membantu distributor atau nelayan menekan angka kerugian pascapanen (*food loss*) akibat kerusakan mesin pendingin yang terlambat dideteksi, sehingga biaya operasional menjadi lebih efisien.

1.5. Sistematika Penulisan Laporan

Sistematika penulisan laporan tugas akhir ini disusun untuk memberikan gambaran mengenai alur pembahasan penelitian yang dilakukan. Laporan ini terdiri dari beberapa bab yang saling berkaitan, dimulai dari pendahuluan hingga kesimpulan dan saran sebagai penutup penelitian.

1. **Bab I Pendahuluan** berisi latar belakang penelitian, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, serta sistematika penulisan laporan tugas akhir.
2. **Bab II Tinjauan Pustaka** memuat penelitian terdahulu yang relevan sebagai landasan komparatif, serta teori-teori pendukung penelitian yang mencakup konsep sistem *cold chain*, IoT, *edge computing*, *TinyML*, metode FFT, teknik ekstraksi fitur spektral, dan arsitektur MLP.

3. **Bab III Metodologi Penelitian** menjelaskan tahapan penelitian yang dilakukan (*prosedur penelitian*), metode pengumpulan data, serta waktu dan tempat pelaksanaan penelitian.
4. **Bab IV Analisa Dan Perancangan Sistem** memuat analisis permasalahan, analisis kebutuhan perangkat keras, perangkat lunak, dan *dataset* penelitian, serta perancangan sistem yang dikembangkan meliputi alur sistem keseluruhan dalam konteks proyek bersama, alur pemrosesan sinyal FFT *on-device*, perancangan ekstraksi fitur spektral, perancangan inferensi dan mekanisme *majority voting*, arsitektur model MLP, strategi optimasi model melalui *pruning* dan *Quantization*, serta proses pelatihan *Offline* menggunakan kombinasi data rekaman sensor MPU6050 dari kondisi operasional nyata dan *dataset* publik MAFAULDA.
5. **Bab V Hasil dan Pembahasan** memaparkan hasil implementasi sistem pada ESP32-S3, mencakup verifikasi inisialisasi komponen, implementasi *firmware* (FFT dan *TinyML*), serta pengujian empat varian model (V1 Base Float32, V2 *Pruned* Float32, V3 *Quantized* INT8, V4 *Pruned+Quantized* INT8) dari sisi akurasi, latensi inferensi, konsumsi daya, dan penggunaan memori, hingga rekapitulasi skor komposit untuk menentukan varian optimal.
6. **Bab VI Kesimpulan Dan Saran** menyajikan simpulan yang diperoleh dari hasil perancangan, implementasi, dan pengujian sistem, serta saran untuk pengembangan penelitian lebih lanjut.