

BAB VI

KESIMPULAN DAN SARAN

6.1. Simpulan

1. Sistem deteksi anomali getaran berhasil dirancang dan diimplementasikan secara *real-time* dan sepenuhnya *on-device* pada ESP32-S3 dengan pemakaian RAM 17,9% dan *Flash* 32,3%, tanpa ketergantungan pada konektivitas internet untuk proses inferensi. Validasi pada sistem *cold chain* terintegrasi membuktikan sistem mampu menghasilkan keputusan klasifikasi yang konsisten dengan waktu inferensi 586–794 mikrodetik per *window*.
2. Pra-pemrosesan FFT dengan *filter bandpass* dan *windowing* Hann berhasil mengekstraksi fitur spektral (RMS, *Peak Amplitude*, dan *Spectral Energy*) yang secara kuantitatif memisahkan tiga kondisi kompresor, ditunjukkan oleh nilai RMS yang meningkat secara konsisten dari kondisi Normal (0,3296), *Imbalance* (0,3766), hingga *Bearing* (0,4392).
3. Model MLP dengan dua *hidden layer* (32 dan 16 neuron) mampu mengklasifikasikan tiga kondisi kompresor dengan akurasi 85,01%, performa terbaik pada kelas *Bearing* (F1-Score 0,89), sementara kelas Normal mencatat *Recall* terendah (79,6%) akibat tumpang tindih karakteristik fitur spektral dengan kelas *Imbalance*.

4. *Pruning* dengan *sparsity* 50% tidak memberikan keuntungan ukuran model namun hanya menurunkan akurasi sebesar 0,08%, sementara *Quantization* INT8 mengurangi ukuran model sebesar 37,6% namun disertai penurunan akurasi 3,22–3,45% serta peningkatan latensi dan konsumsi energi akibat tidak adanya akselerasi SIMD INT8 pada ESP32-S3. Berdasarkan evaluasi multi-metrik, varian V1 (*Base Float32*) ditetapkan sebagai varian final yang diimplementasikan pada sistem.

6.2. Saran

Berdasarkan keterbatasan yang ditemukan selama penelitian, berikut beberapa saran untuk pengembangan lebih lanjut.

1. Penelitian selanjutnya disarankan menambahkan mekanisme deteksi kondisi kendaraan sedang bergerak melalui sensor kecepatan atau *filtering* berbasis data GPS, guna mengurangi risiko kesalahan klasifikasi akibat getaran tambahan dari permukaan jalan. Selain itu, sinyal getaran jalan dapat dijadikan kelas tambahan dalam pelatihan model agar sistem mampu membedakannya secara otomatis dari kondisi anomali kompresor yang sesungguhnya.
2. Nilai *final sparsity pruning* 50% yang digunakan dalam penelitian ini tidak menghasilkan pengurangan ukuran model karena format *sparse* tidak didukung secara *native* oleh *TensorFlow Lite Micro*. Penelitian selanjutnya disarankan mengeksplorasi nilai *sparsity* yang lebih tinggi (70–90%) serta mengevaluasi teknik *Knowledge Distillation* sebagai

alternatif kompresi yang lebih efektif untuk skenario *deployment* pada ESP32-S3.

3. Pengujian konsumsi daya pada penelitian ini masih terbatas pada perbandingan antar varian model saat inferensi. Penelitian selanjutnya disarankan mengukur konsumsi daya sistem secara menyeluruh pada mode `MODE_ON` dan `MODE_SLEEP` menggunakan INA219, serta menerapkan *Quantization-Aware Training* (QAT) sebagai pengganti *Post-Training Quantization* untuk mempertahankan akurasi model INT8 sekaligus tetap menghasilkan ukuran model yang lebih kecil.
4. Validasi *real-time* pada penelitian ini baru dilakukan pada satu skenario operasional dalam durasi terbatas. Penelitian selanjutnya disarankan melakukan pemantauan jangka panjang pada kondisi lapangan yang lebih bervariasi, serta mengeksplorasi mekanisme *continual learning* agar model dapat beradaptasi terhadap perubahan karakteristik getaran kompresor akibat penuaan mesin tanpa harus melakukan pelatihan ulang secara penuh.
5. Penelitian selanjutnya disarankan menambah variasi data lapangan riil, mengeksplorasi fitur spektral tambahan seperti *Spectral Centroid* atau *Crest Factor*, serta membandingkan arsitektur CNN 1D sebagai alternatif untuk melihat apakah representasi yang lebih dalam dapat mengurangi tumpang tindih antar kelas. Penerapan SMOTE juga dapat dieksplorasi untuk mengatasi ketidakseimbangan distribusi fitur antar kelas.