

## BAB V

### SIMPULAN DAN SARAN

#### 5.1 Simpulan

Penelitian ini telah berhasil membangun sistem *voice conversational AI* berbasis arsitektur *cascaded* yang mengintegrasikan tiga komponen utama secara sequential: Automatic Speech Recognition menggunakan Whisper Small, Small Language Model menggunakan Gemma 3 1B instruction-tuned, dan Text-to-Speech menggunakan VITS MMS Indonesian. Sistem yang dikembangkan mampu memproses *input audio* pengguna menjadi respons *audio* yang relevan dan natural, dengan arsitektur *cascaded* yang memberikan fleksibilitas untuk melakukan optimasi secara independen pada setiap komponen tanpa mempengaruhi komponen lainnya.

Proses optimasi *inference-level* telah berhasil diterapkan pada setiap komponen sistem untuk meningkatkan efisiensi komputasi pada lingkungan *CPU-only* tanpa memerlukan *re-training* model. Optimasi Whisper melalui konversi ke CTranslate2 dengan INT8 *quantization* menghasilkan penurunan *latency* sebesar 19.87% dan reduksi ukuran model sebesar 48.45%. Optimasi Gemma 3 1B melalui konversi ke format GGUF dengan Q8\_0 *quantization* menghasilkan penurunan *latency* sebesar 44.85% dan peningkatan *throughput* sebesar 79.25%. Optimasi VITS melalui konversi ke ONNX *Runtime* dengan *graph optimization* dan INT8 *quantization* menghasilkan *speedup* 1.61x serta penurunan *Real-time Factor* sebesar 38.18%. Kombinasi teknik optimasi ini terbukti efektif dalam meningkatkan performa sistem pada perangkat dengan kapasitas komputasi terbatas.

Evaluasi performa sistem menunjukkan bahwa total *latency end-to-end* berkurang sebesar 30.09% dari 19.76 detik menjadi 13.81 detik, dengan *trade-off* minimal pada kualitas *output*. Akurasi transkripsi mengalami degradasi WER yang sangat minimal yaitu hanya 0.14%, kualitas respons bahasa menunjukkan penurunan *perplexity* sebesar 4.58%, dan *naturalness audio* sintesis tetap terjaga dengan reduksi ukuran model sebesar 22.81%. Hasil ini membuktikan bahwa sistem *voice conversational AI* yang dioptimasi dapat beroperasi secara efisien

pada perangkat dengan daya komputasi terbatas dengan *trade-off* minim, sehingga tetap mempertahankan kualitas *output* yang *acceptable* untuk aplikasi praktis, dan memberikan kontribusi penting bagi implementasi sistem *conversational AI* yang lebih mudah diakses tanpa memerlukan infrastruktur komputasi yang mahal.

## 5.2 Saran

Berdasarkan hasil penelitian yang telah dilaksanakan, peneliti mengajukan beberapa saran dan rekomendasi untuk pertimbangan dalam studi lanjutan, mengingat adanya limitasi dan temuan yang diperoleh dalam penelitian ini. Rekomendasi-rekomendasi tersebut diuraikan sebagai berikut:

1. Komponen ASR (Whisper) teridentifikasi sebagai kontributor *latency* terbesar dengan proporsi 64.59% terhadap total *latency* sistem setelah optimasi. Penelitian selanjutnya dapat mengeksplorasi teknik optimasi tambahan lainnya, atau penggunaan varian Whisper yang lebih kecil seperti Whisper Tiny atau Whisper Base untuk menurunkan *latency* komponen ini secara lebih signifikan sambil tetap mempertahankan akurasi transkripsi yang *acceptable*.
2. Pengembangan lebih lanjut dapat mempertimbangkan implementasi pada *hardware accelerator* seperti Neural Processing Unit, TPU, atau GPU yang tersedia pada *cloud server* maupun perangkat lokal untuk memberikan peningkatan performa yang lebih signifikan. Selain itu, eksplorasi terhadap model-model yang lebih baru dengan arsitektur yang lebih efisien juga dapat memberikan potensi peningkatan performa yang lebih baik.
3. Penelitian lebih lanjut dapat mengeksplorasi pengaplikasian dari sistem *voice conversational AI* yang telah dioptimasi ini dalam berbagai bidang seperti *customer service automation*, *educational assistant*, atau *accessibility tools* untuk individu, sehingga memberikan manfaat praktis dari hasil penelitian ini.