

BAB 5

PENUTUP

5.1 KESIMPULAN

1. Penggunaan arsitektur DenseNet dengan jumlah parameter yang lebih sedikit dibandingkan model CNN lainnya memberikan keuntungan dalam hal efisiensi dan akurasi. DenseNet mampu mempertahankan aliran informasi dengan baik dan meningkatkan efisiensi pelatihan model. Struktur DenseNet-121 yang digunakan dalam penelitian ini terdiri dari lapisan-lapisan konvolusi yang saling terhubung, lapisan transisi untuk mengontrol ukuran jaringan, dan lapisan pooling serta normalisasi yang membantu dalam pengurangan dimensi dan stabilitas pelatihan. Lapisan klasifikasi pada DenseNet memastikan pemanfaatan fitur yang lebih baik dan efisiensi parameter, yang pada akhirnya meningkatkan kinerja dalam mengklasifikasikan modulasi QAM. Model DenseNet yang dirancang dan dilatih dalam penelitian ini menunjukkan hasil yang memuaskan dengan nilai training loss menurun dari 0.5174 pada *epoch* 15 menjadi 0.2122 pada *epoch* 80 dan training accuracy meningkat dari 0.7277 menjadi 0.916 pada *epoch* 80. Nilai validation loss juga menunjukkan penurunan dari 0.594 pada *epoch* 15 menjadi 0.8646 pada *epoch* 80, dan validation accuracy meningkat dari 0.686 menjadi 0.7671, menunjukkan model telah dilatih dengan baik dan mencapai performa yang optimal.
2. Penggunaan *DenseNet* yang merupakan jenis dari CNN, dalam klasifikasi jenis modulasi pada sinyal radio menunjukkan hasil yang bervariasi tergantung pada nilai SNR. Pada SNR -20 dB memiliki akurasi yang rendah dengan nilai sekitar 30%, untuk *Recall* sekitar 0.1, *Presisi* berada di kisaran 0.3, dan *F1-Score* sekitar 0.2. Saat SNR meningkat ke 0 dB, kinerja model membaik dengan akurasi mencapai sekitar 60%, *Recall* serta *Presisi* meningkat menjadi sekitar 0.6, sementara *F1-Score* naik ke sekitar 0.7. Pada SNR 10 dB dan lebih tinggi, model menunjukkan kinerja maksimal dengan akurasi, *Recall*, *Presisi*, dan *F1-Score* mencapai nilai sempurna (1.0). Secara keseluruhan, model *DenseNet* menunjukkan peningkatan kinerja yang signifikan dengan peningkatan SNR. Pada kondisi SNR yang rendah,

kinerja untuk evaluasi model memiliki nilai yang lebih rendah. Pada SNR yang lebih tinggi, model mencapai kinerja yang lebih baik yaitu pada nilai 100%.

5.2 SARAN

1. Disarankan untuk memperluas variasi dataset dengan menambahkan lebih banyak jenis modulasi dan skenario yang berbeda. Hal ini akan membantu model untuk belajar dan mengenali berbagai karakteristik sinyal yang lebih kompleks dan meningkatkan generalisasi model terhadap data baru.
2. Mengingat kinerja model menurun pada kondisi SNR rendah, penelitian lebih lanjut diperlukan untuk mengembangkan metode yang dapat meningkatkan akurasi klasifikasi pada kondisi tersebut. Teknik seperti denoising, augmentasi data, atau penggunaan model yang lebih kompleks dapat dipertimbangkan.
3. Melakukan optimasi lebih lanjut pada hyperparameter model, seperti learning rate, *batch* size, dan jumlah *epoch* , dapat membantu meningkatkan kinerja model. Penggunaan teknik seperti grid search atau random search dapat membantu menemukan kombinasi hyperparameter yang optimal.