

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan penelitian tentang optimasi empat parameter antenna mikrostrip fraktal Sierpinski Gasket menggunakan empat algoritma *machine learning* untuk Wi-Fi 7 frekuensi 2,4 GHz, dapat ditarik beberapa kesimpulan sebagai berikut:

1. Proses optimasi empat parameter antenna mikrostrip fraktal Sierpinski Gasket menggunakan integrasi algoritma *machine learning* dengan metode *Random Search* berbasis sistem pembobotan telah berhasil menemukan desain antenna optimal yang memenuhi spesifikasi Wi-Fi 7 frekuensi 2,4 GHz. Antena hasil optimasi, yaitu model ke-1 dengan substrat RT/duroid 5880, beresonansi pada frekuensi 2,4086 GHz, *return loss* minimum -41,65 dB, *bandwidth* 166,4 MHz, VSWR 1,01 dan *gain* 4,56 dBi. Peningkatan signifikan pada S11 dan VSWR menunjukkan transformasi dari antenna yang tidak fungsional menjadi sangat efisien, meskipun terdapat sedikit penurunan pada *gain* yang masih dalam rentang spesifikasi Wi-Fi 7.
2. Analisis performa empat algoritma *machine learning* dalam memprediksi parameter antenna menunjukkan algoritma terbaik untuk setiap parameter sebagai berikut:
 - Untuk prediksi *return loss*, *K-Nearest Neighbor* dengan $n_neighbors = 1$ mencapai MSE sebesar 0,4396, MAE sebesar 0,2355, dan R^2 sebesar 0,9837.
 - Untuk prediksi *bandwidth*, *Random Forest* dengan $n_estimators = 50$ dan $min_samples_split = 2$ mencapai MSE sebesar 0,00100, MAE sebesar 0,0183, dan R^2 sebesar 0,7042.
 - Untuk prediksi VSWR, *Support Vector Regression* dengan $gamma = 1$, $epsilon = 0,01$, dan $C = 100$ mencapai MSE sebesar 0,0031, MAE sebesar 0,0135, dan R^2 sebesar 0,9986.
 - Untuk prediksi *gain*, *Random Forest* dengan $n_estimators = 100$, $min_samples_split = 2$, dan $max_depth = 10$ menghasilkan MSE sebesar 0,2668, MAE sebesar 0,2416, dan R^2 sebesar 0,8701.

5.2 Saran

Berdasarkan penelitian yang telah dilakukan, berikut adalah beberapa saran untuk pengembangan selanjutnya:

1. Melakukan fabrikasi antena hasil optimasi dan pengukuran langsung untuk memvalidasi performa di dunia nyata serta membandingkan dengan hasil simulasi dan prediksi *machine learning*.
2. Menjelajahi metode optimasi lain seperti algoritma genetik atau optimasi berbasis *swarm* untuk membandingkan efisiensi dan efektivitas dalam menemukan solusi optimal.