

BAB V

PENUTUP

5.1 Kesimpulan

Sektor bangunan saat ini menjadi salah satu penyumbang terbesar konsumsi energi di dunia. Konsumsi energi bangunan untuk sistem pendinginan menunjukkan laju peningkatan yang jauh lebih cepat dibandingkan konsumsi energi lainnya. Tanpa strategi efisiensi energi dan kebijakan yang tepat, fenomena konsumsi energi pendinginan yang terus meningkat berpotensi menimbulkan ketergantungan yang tinggi terhadap energi listrik, peningkatan emisi gas rumah kaca, serta kenaikan biaya operasional bangunan.

Pengembangan model untuk peramalan atau prediksi konsumsi energi menjadi salah satu strategi utama dalam mengurangi konsumsi energi jangka panjang. Penelitian ini bertujuan untuk mengembangkan model prediksi konsumsi energi pendinginan pada bangunan menggunakan model CatBoost yang dioptimasi dengan algoritma Self-Adaptive Emperor Penguin Optimizer (SA-EPO). Optimasi yang dilakukan berfokus untuk memperoleh kombinasi hyperparameter terbaik sehingga model CatBoost mampu menghasilkan prediksi yang lebih akurat. Berdasarkan hasil penelitian yang telah dilakukan, dapat ditarik kesimpulan-kesimpulan sebagai berikut :

1. Model CatBoost standar yang digunakan dalam penelitian ini menunjukkan performa prediksi yang cukup baik sebelum dilakukan proses optimasi. Pada skema validasi Hold-Out, model menghasilkan RMSE sebesar 0.2957, MAE 0.1770, MSE 0.0874, dan R^2 0.9350. Sementara itu, pada skema Time Series Split Cross Validation, model memperoleh RMSE 0.2717, MAE 0.1676, MSE 0.0738, dan R^2 0.947. Nilai RMSE, MSE, dan MAE yang relatif rendah menunjukkan bahwa kesalahan prediksi model berada pada tingkat yang kecil dan stabil. Selain itu, nilai R^2 di atas 0.93 menunjukkan bahwa model CatBoost standar mampu menjelaskan sebagian besar variasi data dengan sangat baik. Secara keseluruhan, hasil tersebut menunjukkan bahwa CatBoost memiliki performa yang kuat meskipun tanpa optimasi hyperparameter.

2. Optimasi hyperparameter pada model CatBoost menggunakan algoritma metaheuristik seperti SA-EPO dan beberapa algoritma metaheuristik lain sebagai pembanding SA-EPO (AO dan EPO) terbukti mampu meningkatkan performa prediksi konsumsi energi pendinginan bangunan dibandingkan model CatBoost dengan hyperparameter default. Dua variasi parameter untuk ukuran populasi dan jumlah iterasi (30 populasi dengan 20 iterasi dan 20 populasi dengan 50 iterasi) yang diatur guna melihat pengaruh hasil yang diberikan setiap algoritma optimasi juga menunjukkan bahwa perubahan ukuran populasi dan jumlah iterasi tetap memberikan peningkatan performa prediksi meskipun dengan tingkat peningkatan yang berbeda.
3. Berdasarkan hasil pengujian menggunakan validasi Hold-Out, model CatBoost standar menghasilkan nilai RMSE sebesar 0.2957, MAE 0.1770, MSE 0.0874, dan R^2 0.9350. Setelah dilakukan optimasi, algoritma SA-EPO berhasil menurunkan nilai error dan meningkatkan akurasi model. Model CatBoost-SAEPO dengan konfigurasi 30 populasi dan 20 iterasi memberikan hasil terbaik pada skema Hold-Out, yaitu RMSE 0.2858, MAE 0.1649, MSE 0.0817, dan R^2 0.9393. Hasil ini menunjukkan adanya peningkatan performa yang konsisten dibandingkan model tanpa optimasi. Pada skema validasi Time Series Split Cross Validation, model CatBoost standar memperoleh RMSE 0.2717, MAE 0.1676, MSE 0.0738, dan R^2 0.947. Setelah dioptimasi, algoritma SA-EPO kembali menunjukkan hasil terbaik, khususnya pada skenario populasi 20 dan 50 iterasi dengan nilai RMSE 0.2659, MAE 0.1641, MSE 0.0707, dan R^2 0.9492. Perbaikan ini membuktikan bahwa penerapan algoritma SA-EPO memberikan pengaruh signifikan dalam meningkatkan kualitas prediksi melalui pemilihan hyperparameter yang lebih tepat.
4. Di antara ketiga algoritma optimasi yang digunakan dalam penelitian ini (SA-EPO, EPO, dan AO), SA-EPO memberikan performa paling unggul. Model CatBoost-SAEPO menghasilkan nilai RMSE dan MAE paling rendah serta nilai R^2 paling tinggi dibandingkan model hasil optimasi lainnya, baik pada validasi Hold-Out maupun Time Series Split CV. Hal ini

menunjukkan bahwa mekanisme adaptif pada SA-EPO mampu menghasilkan kombinasi hyperparameter yang lebih optimal dan stabil.

5.2 Saran

Berdasarkan hasil penelitian yang diperoleh, beberapa saran yang dapat dipertimbangkan untuk penelitian selanjutnya adalah sebagai berikut :

1. Data yang digunakan dalam penelitian ini masih terbatas pada periode musim panas sehingga model hanya mempelajari pola konsumsi energi pada rentang kondisi tertentu. Penelitian selanjutnya disarankan untuk mengumpulkan data dengan rentang waktu yang lebih panjang agar model dapat mengenali perbedaan pola konsumsi energi pada situasi seperti peralihan musim atau musim dingin. Selain itu, penambahan variabel terkait kondisi operasional bangunan seperti tingkat hunian, jadwal penggunaan HVAC, atau pengaturan suhu serta variabel cuaca tambahan seperti radiasi matahari dapat membantu meningkatkan kemampuan model dalam memahami lebih dalam terkait faktor-faktor yang memengaruhi konsumsi energi pendinginan.
2. Meskipun CatBoost menunjukkan performa yang cukup baik, penelitian selanjutnya dapat menambahkan model lain seperti LightGBM, XGBoost, Random Forest, maupun model deep learning berbasis deret waktu seperti LSTM, GRU, atau TCN. Perbandingan yang lebih luas dapat memberikan gambaran yang menyeluruh mengenai model mana yang paling efektif untuk dataset konsumsi energi dengan karakteristik tertentu.
3. Penelitian selanjutnya disarankan untuk menerapkan teknik pra-pemrosesan data seperti seleksi fitur, penanganan outlier, serta teknik reduksi dimensi. Penerapan teknik-teknik tersebut berpotensi meningkatkan kualitas input model dan mengurangi risiko overfitting.
4. Selain algoritma SA-EPO, algoritma metaheuristik lain seperti Meerkat Optimization Algorithm (MOA), Starfish Optimization Algorithm (SFOA), dan algoritma lainnya dapat dieksplorasi sebagai alternatif. Penelitian lanjutan dapat membandingkan algoritma tersebut untuk melihat apakah terdapat metode yang dapat memberikan hasil lebih stabil, waktu komputasi lebih efisien, atau performa yang lebih baik.