

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian mengenai analisis performa *optimizer* algoritma pembelajaran mesin untuk prediksi iradiasi matahari, dapat ditarik tiga kesimpulan utama yang menjawab rumusan masalah penelitian:

1. Penerapan algoritma pembelajaran mesin untuk prediksi iradiasi matahari berhasil dilakukan melalui serangkaian tahapan sistematis. Proses ini meliputi pra-pemrosesan data (penanganan *missing values*, konversi *lux* ke W/m^2 , dan normalisasi), perancangan arsitektur *Stacked Long Short-Term Memory* (LSTM), serta segmentasi data menjadi format deret waktu univariat dengan teknik *sliding window* berukuran 7 *timesteps*.
2. Terdapat perbedaan performa yang signifikan antara ketiga *optimizer* yang diuji (SGD, RMSprop, dan Adam). Selama fase pelatihan, Adam menunjukkan kecepatan konvergensi dan stabilitas terbaik. Pada tahap pengujian, model yang menggunakan *optimizer* SGD dan RMSprop cenderung mengalami *underfitting* dan gagal menangkap fluktuasi data secara efektif. Sebaliknya, model yang menggunakan *optimizer* Adam terbukti paling mampu mengikuti pola dinamis dari data aktual.
3. *Optimizer* yang paling optimal untuk kasus prediksi iradiasi matahari dalam penelitian ini adalah Adam. Konfigurasi terbaik diraih pada Percobaan 12, yang dipilih bukan hanya karena metrik *error*-nya yang kompetitif, tetapi karena kemampuannya yang unggul secara kualitatif

dalam menangkap volatilitas data pada data uji. Model ini menghasilkan performa akhir pada data uji dengan nilai MAE 248.26, RMSE 315.35, dan MAPE 68.60%.

5.2 Saran

Berdasarkan temuan dan keterbatasan dalam penelitian ini, berikut adalah beberapa saran untuk pengembangan di penelitian selanjutnya:

1. Mengingat model dengan *optimizer* SGD dan RMSprop menunjukkan kecenderungan *underfitting*, penelitian selanjutnya disarankan untuk mengeksplorasi arsitektur *deep learning* yang lebih kompleks. Beberapa alternatif yang dapat diuji antara lain menambah jumlah lapisan atau unit pada model LSTM, atau menggunakan arsitektur sekuensial lain seperti *Gated Recurrent Unit* (GRU).
2. Penelitian ini sengaja difokuskan pada model univariat untuk menguji kemampuan prediksi berdasarkan data *lux* saja. Untuk meningkatkan akurasi prediksi, penelitian mendatang dapat mengembangkan model multivariat dengan menyertakan kembali fitur cuaca (setelah melalui proses *encoding*) atau menambahkan data meteorologi relevan lainnya seperti suhu udara, kelembapan, dan kecepatan angin.
3. Proses pencarian *hyperparameter* dalam penelitian ini dilakukan secara manual. Untuk menemukan kombinasi yang lebih optimal, disarankan untuk menggunakan teknik optimasi *hyperparameter* otomatis seperti Grid Search, Random Search, atau Bayesian Optimization.

4. Penelitian ini menggunakan ukuran *batch* 1 untuk seluruh percobaan.

Penelitian selanjutnya dapat mengeksplorasi pengaruh penggunaan ukuran *batch* yang lebih besar (*mini-batch*), misalnya 8, 16, atau 32.

Ukuran *batch* yang berbeda dapat memengaruhi kecepatan konvergensi, stabilitas proses pelatihan, dan efisiensi komputasi, sehingga analisis ini dapat memberikan wawasan tambahan dalam menemukan konfigurasi pelatihan yang paling efisien.

5. Model terbaik yang dihasilkan dari penelitian ini (Percobaan 12) memiliki potensi untuk dikembangkan lebih lanjut menjadi sistem prediksi praktis. Sistem ini dapat diintegrasikan dengan *Energy Management System* (EMS) pada instalasi panel surya untuk membantu optimasi penjadwalan penggunaan dan penyimpanan energi.