

## BAB V PENUTUP

### 5.2. Kesimpulan

Penelitian ini bertujuan untuk mengembangkan sistem prediksi *b-value* gempa bumi di wilayah Pulau Jawa dengan menggunakan pendekatan *deep learning* berbasis *Gated Recurrent Unit* (GRU). Metode tersebut efektif dalam menangani data deret waktu, seperti data gempa bumi, karena kemampuannya untuk memproses ketergantungan temporal dalam data. Wilayah Pulau Jawa, yang terletak di kawasan dengan aktivitas seismik tinggi, memerlukan prediksi yang akurat untuk memitigasi risiko bencana gempa bumi yang dapat terjadi sewaktu-waktu. Salah satu parameter penting dalam mempelajari pola seismik adalah *b-value*, yang menghubungkan frekuensi dan magnitudo gempa bumi. Model prediksi yang akurat untuk *b-value* dapat memberikan informasi yang berharga mengenai potensi terjadinya gempa besar di masa depan. Metode tersebut efektif dalam menangani data deret waktu, seperti data gempa bumi, karena kemampuannya untuk memproses ketergantungan temporal dalam data.

Namun, masih terdapat ruang untuk meningkatkan performa metode ini, performa model ini sangat bergantung pada pemilihan *hyperparameter* yang tepat, seperti jumlah *neuron* pada setiap layer, *learning rate*, dan *dropout rate*. Oleh karena itu, untuk meningkatkan akurasi prediksi, penelitian ini menggunakan optimasi *hyperparameter* berbasis *Particle Swarm Optimization* (PSO). PSO dipilih karena kemampuannya dalam mengeksplorasi ruang parameter yang kompleks secara efisien dan menemukan kombinasi terbaik dari *hyperparameter* model. Proses optimasi ini bertujuan untuk mendapatkan konfigurasi yang optimal, sehingga model GRU dapat memberikan prediksi *b-value* yang lebih akurat dan stabil.

Hasil dari penelitian ini menunjukkan bahwa proses optimasi *hyperparameter* menggunakan algoritma *Particle Swarm Optimization* (PSO) berhasil meningkatkan performa model GRU secara signifikan. Model awal (sebelum optimasi) dibangun dengan konfigurasi dasar berupa dua *layer* GRU dengan jumlah unit masing-masing 64 dan 32, *learning rate* sebesar 0.1, *dropout rate* 0.2, dan pembagian data 70:20:10.

Pada konfigurasi ini, model menghasilkan nilai evaluasi berupa MSE sebesar 0.00465335, RMSE sebesar 0.06821546, dan MAPE sebesar 4.54%.

Setelah dilakukan optimasi menggunakan PSO dengan konfigurasi terbaik yang diperoleh yakni bobot inersia ( $w$ ) sebesar 0.8, koefisien kognitif dan sosial  $C_1 = 1$  dan  $C_2 = 1$ , jumlah partikel sebesar 40, dan jumlah iterasi sebanyak 10, mendapatkan kombinasi *hyperparameter* terbaik dengan jumlah unit GRU pada dua *layer* masing-masing sebesar 211 dan 86 unit, dengan *learning rate* 0.016741 dan *dropout rate* 0.2497. Hasil evaluasi menunjukkan peningkatan performa secara signifikan, nilai MSE turun sebesar 0.00435425 poin menjadi hanya 0.00029910, nilai RMSE berkurang 0.05092096 poin menjadi 0.01729450, dan MAPE menyusut drastis sebesar 3.42% menjadi hanya 1.12%. Selain itu, waktu pelatihan juga lebih efisien, berkurang 24 detik menjadi hanya 33 detik. terjadi peningkatan performa yang signifikan. Nilai MSE menurun drastis menjadi 0.00038981 (selisih penurunan sebesar 0.00426354), RMSE turun menjadi 0.01974371 (selisih 0.04847175), dan MAPE menurun menjadi 1.29% (selisih 3.25%).

Sedangkan hasil optimasi menggunakan metode lain seperti Genetic Algorithm (GA) dengan konfigurasi terbaik yang diperoleh yaitu jumlah unit GRU pada dua *layer* masing-masing sebesar 183 dan 37 unit, *learning rate* sebesar 0.01455033, dan *dropout rate* sebesar 0.1195, hasil evaluasi menunjukkan peningkatan performa yang signifikan dibandingkan model awal. Nilai Mean Squared Error (MSE) menurun dari 0.00465335 menjadi 0.00135722, dengan penurunan sebesar 0.00329613. Nilai Root Mean Squared Error (RMSE) juga berkurang dari 0.06821546 menjadi 0.03684051, atau mengalami penurunan sebesar 0.03137495. Selain itu, Mean Absolute Percentage Error (MAPE) turun dari 4.54% menjadi 2.57%, dengan pengurangan sebesar 1.97%. Waktu pelatihan model GA juga lebih efisien, tercatat hanya 12 detik, yang secara signifikan lebih singkat dibandingkan waktu pelatihan model awal dan model hasil optimasi PSO.

Secara keseluruhan, penelitian ini berhasil mengimplementasikan model prediksi *b-value* menggunakan GRU yang dioptimasi dengan PSO, dan hasilnya menunjukkan perbaikan dalam akurasi prediksi dibandingkan dengan hasil optimasi menggunakan algoritma lain seperti GA, sehingga layak dipertimbangkan sebagai pendekatan yang efektif dalam pengembangan sistem prediksi gempa bumi untuk meningkatkan mitigasi risiko bencana gempa bumi di wilayah Pulau Jawa.

### 5.3. Saran

Berdasarkan hasil penelitian dan analisis yang telah dilakukan, terdapat beberapa saran yang bertujuan untuk meningkatkan akurasi prediksi, memperluas ruang lingkup penelitian, serta memberikan arah yang lebih baik dalam pengembangan sistem prediksi gempa bumi yang lebih efektif dan andal di masa mendatang, antara lain:

1. Penelitian ini menggunakan data gempa bumi yang terbatas pada wilayah Pulau Jawa dalam periode waktu tertentu. Untuk meningkatkan akurasi dan generalisasi model, disarankan untuk menggunakan data yang lebih besar dan mencakup wilayah yang lebih luas. Selain itu, data dengan rentang waktu yang lebih panjang dapat memberikan gambaran yang lebih komprehensif mengenai pola *b-value* gempa bumi, serta meningkatkan kemampuan model dalam memprediksi gempa besar.
2. Meskipun PSO terbukti meningkatkan performa model dalam penelitian ini, metode optimasi lainnya seperti optimasi metaheuristik lainnya, serta optimasi seperti *Bayesian Optimization*, atau *Differential Evolution* dapat dipertimbangkan untuk eksperimen selanjutnya. Metode optimasi lain mungkin dapat memberikan hasil yang lebih optimal atau lebih cepat dalam pencarian *hyperparameter* yang tepat, yang berpotensi meningkatkan akurasi model lebih lanjut.
3. Untuk mendapatkan pemahaman yang lebih baik mengenai performa model, penelitian selanjutnya dapat menguji dan membandingkan beberapa model *deep learning* lainnya, seperti *Long Short-Term Memory (LSTM)* atau *Transformer-based models*. Perbandingan dengan model yang lebih kompleks bisa memberikan wawasan mengenai kelebihan dan kekurangan masing-masing arsitektur dalam memprediksi *b-value* gempa bumi.
4. Penelitian ini sudah menggunakan MSE, RMSE, dan MAPE sebagai metrik evaluasi. Penelitian selanjutnya dapat mempertimbangkan evaluasi dengan metrik lain seperti MAE (*Mean Absolute Error*),  $R^2$  (*koefisien determinasi*), atau menggunakan teknik *cross-validation* untuk memvalidasi kestabilan model pada berbagai subset data. Hal ini penting untuk memastikan bahwa model tidak hanya berfungsi baik pada data pelatihan, tetapi juga dapat menggeneralisasi dengan baik pada data yang tidak terlihat sebelumnya.

5. Meskipun penelitian ini fokus pada prediksi *b-value*, penelitian selanjutnya bisa mengeksplorasi penerapan model yang lebih maju untuk memprediksi waktu dan lokasi gempa bumi, bukan hanya *b-value*. Dengan menggunakan model *deep learning* berbasis GRU, prediksi waktu dan lokasi gempa dapat meningkatkan akurasi mitigasi risiko, sehingga memungkinkan lebih banyak intervensi dini dan kesiapsiagaan masyarakat.