

BAB V

SIMPULAN DAN SARAN

5.1 Simpulan

Penelitian ini menjawab rumusan masalah dengan membangun dan membandingkan lima model prediksi *time series* untuk data Gross Written Premium (GWP) perusahaan asuransi, yaitu ARIMA, SARIMA, LSTM, *Hybrid* LSTM-ARIMA, dan *Hybrid* LSTM-SARIMA. Setiap model melalui tahapan preprocessing, pelatihan, evaluasi menggunakan metrik MAE, MSE, dan R^2 , serta diuji pada variasi pembagian data latih dan uji untuk memastikan kestabilan performa.

Hasil evaluasi menunjukkan bahwa model LSTM secara konsisten memberikan performa prediktif terbaik dibandingkan model-model lainnya, khususnya pada rasio data latih dan uji sebesar 80:20. Pada skenario ini, model LSTM mencatat nilai MAE sebesar 191.06, MSE sebesar 67,327.58, dan R^2 sebesar 0.55, yang mencerminkan kemampuannya dalam menangkap pola musiman serta dinamika non-linear dari data Gross Written Premium (GWP) harian. Keunggulan LSTM tercermin dari kesalahan prediksi yang rendah dan daya adaptasi yang tinggi terhadap fluktuasi data. Model SARIMA juga menunjukkan performa yang cukup kompetitif, terutama dalam menangkap pola musiman yang teratur, dengan nilai R^2 sebesar 0.44, MAE sebesar 231.93, dan MSE sebesar 119,982.67. Meskipun demikian, SARIMA relatif kurang fleksibel dalam mengenali pola-pola data yang kompleks dan berubah-ubah secara dinamis seperti yang dimiliki oleh LSTM.

Sementara itu, model Hybrid yang menggabungkan LSTM dengan ARIMA maupun SARIMA belum mampu memberikan performa yang melampaui model LSTM tunggal. Hybrid LSTM-ARIMA hanya memperoleh R^2 sebesar 0.16, sedangkan Hybrid LSTM-SARIMA mencatat R^2 sebesar 0.37. Nilai R^2 yang lebih rendah serta tingginya nilai MAE dan MSE mengindikasikan bahwa pendekatan penggabungan linear antara model statistik dan deep learning belum menghasilkan sinergi yang optimal. Hal ini kemungkinan besar disebabkan oleh

ketidakseimbangan kontribusi prediktif antara masing-masing model atau kurangnya harmonisasi temporal dalam proses kombinasi prediksi.

Model LSTM terbaik tersebut kemudian diimplementasikan dalam *dashboard* interaktif berbasis Streamlit yang menyediakan visualisasi data historis dan prediksi 30 hari ke depan, serta fitur prediksi otomatis. *Dashboard* ini dirancang agar mudah digunakan dan sangat membantu perusahaan asuransi dalam perencanaan penjualan, pengelolaan risiko, dan pengambilan keputusan strategis berbasis data.

Kontribusi ilmiah utama dari penelitian ini adalah pembuktian efektivitas LSTM dalam memodelkan data GWP yang kompleks dan musiman secara lebih baik daripada pendekatan tradisional maupun *Hybrid*. Selain itu, penelitian ini menambah literatur dengan perbandingan sistematis berbagai model dan mengintegrasikan hasil prediksi ke dalam aplikasi praktis yang mendorong pemanfaatan *machine learning* untuk keputusan bisnis di industri asuransi.

5.2 Saran

Berdasarkan hasil penelitian, berikut beberapa saran yang dapat dijadikan pertimbangan untuk pengembangan lebih lanjut:

1. Optimasi Model LSTM

Model LSTM telah menunjukkan performa yang unggul dalam memprediksi data GWP. Namun, kinerjanya masih dapat ditingkatkan lebih lanjut melalui proses *hyperparameter tuning* yang lebih mendalam, seperti eksplorasi jumlah *neurons*, *batch size*, *learning rate*, dan *sequence length*. Selain itu, eksplorasi kombinasi LSTM dengan algoritma lain, seperti GRU, Attention Mechanism, atau model statistik (misalnya SARIMA), dapat membentuk model *Hybrid* yang lebih adaptif terhadap variasi pola data, baik yang bersifat musiman maupun non-linier.

2. Pemanfaatan Model ARIMA dan SARIMA dalam *Hybrid*

Meskipun performa ARIMA dan SARIMA tidak sekompetitif LSTM dalam penelitian ini, model-model tersebut tetap memiliki keunggulan dalam memodelkan komponen tren dan musiman secara eksplisit. Dengan demikian,

kedua model ini masih sangat relevan untuk digunakan sebagai komponen pembentuk dalam model *Hybrid*, khususnya bila dikombinasikan dengan model *machine learning* atau deep learning. Performa ARIMA/SARIMA juga berpotensi meningkat jika didukung oleh data historis yang lebih kaya, baik dari segi kuantitas maupun dimensi.

3. Perluasan Dataset dan Fitur Eksternal

Untuk memperoleh hasil prediksi yang lebih akurat dan meningkatkan kemampuan generalisasi model, disarankan agar dataset yang digunakan mencakup periode waktu yang lebih panjang dan bervariasi. Penambahan fitur atau variabel eksternal seperti jenis produk asuransi, wilayah pemasaran, promosi, inflasi, hari libur, atau bahkan faktor cuaca, dapat memperkaya informasi input dan membantu model menangkap pola yang lebih kompleks serta kontekstual.

4. Pengembangan *Dashboard* dan Integrasi Sistem

Platform Streamlit terbukti efektif dalam menyajikan hasil prediksi secara interaktif dan *user-friendly*. Untuk pengembangan lebih lanjut, disarankan agar *dashboard* mencakup fitur tambahan seperti:

- a) Pemilihan rentang waktu prediksi secara dinamis
- b) Unggah dataset baru oleh pengguna
- c) Visualisasi performa model dari waktu ke waktu
- d) Integrasi dengan sistem manajemen data perusahaan untuk implementasi nyata dalam proses perencanaan penjualan dan pengambilan keputusan strategis berbasis data

UNIVERSITAS
MULTIMEDIA
NUSANTARA