

BAB V PENUTUP

5.1. Kesimpulan

Hasil yang didapatkan setelah penelitian ini mencakup hal-hal berikut, yaitu:

1. Berdasarkan data historis, kenaikan jumlah tugas dapat dimodelkan menggunakan pendekatan *time series forecasting* dengan algoritma *Recurrent Neural Network* (RNN) dan *Long Short-Term Memory* (LSTM). Hasil prediksi menunjukkan adanya pola kenaikan tugas pada beberapa Task Group ID. Dengan demikian, model prediktif ini dapat digunakan sebagai alat bantu dalam perencanaan kapasitas kerja guna mengurangi risiko *overload* pada tim.
2. Evaluasi kinerja model dengan metrik *Mean Squared Error* (MSE) dan *Mean Absolute Error* (MAE) menunjukkan bahwa *Recurrent Neural Network* (RNN) dan *Long Short-Term Memory* (LSTM) memiliki akurasi prediksi yang cukup baik, dengan perbedaan kecil dalam hasilnya. Dengan skema pembagian data 80% untuk *data testing* 20% untuk *data training* selama 20 epoch, model RNN memperoleh nilai MSE sebanyak 0.0184 dan MAE sebanyak 0.0349, sementara LSTM mencatat MSE sebanyak 0.0184 dan MAE sebanyak 0.0355. Hasil ini menunjukkan bahwa RNN sedikit lebih unggul dalam meminimalkan kesalahan prediksi dibandingkan LSTM.
3. Prediksi jumlah tugas memungkinkan perusahaan melakukan perencanaan kapasitas kerja yang lebih efektif. Dengan memanfaatkan informasi prediksi, tugas dapat didistribusikan lebih seimbang, sumber daya dialokasikan secara tepat, dan langkah antisipatif dapat disusun untuk menjaga stabilitas produktivitas tim. Hal ini memungkinkan organisasi untuk lebih siap dalam menghadapi perubahan volume tugas yang dapat mempengaruhi kinerja operasional.
4. Berdasarkan hasil prediksi yang dihasilkan, beberapa Task Group ID mengalami peningkatan jumlah tugas yang lebih signifikan dibandingkan yang lain. Task Group seperti Event Monitoring-IBM dan Event

Monitoring-Ctl-M menunjukkan lonjakan yang lebih tajam dalam enam bulan ke depan, yang mengindikasikan potensi peningkatan beban kerja dalam kategori tersebut.

5. Model *Long Short-Term Memory* (LSTM) cenderung menghasilkan perkiraan kenaikan jumlah tugas yang lebih tinggi dibandingkan *Recurrent Neural Network* (RNN) pada beberapa kategori tugas, yang menunjukkan bahwa kedua model menangkap pola temporal dengan cara yang berbeda.

5.2. Saran

Berdasarkan hasil penelitian ini, didapatkan beberapa saran untuk studi selanjutnya, termasuk yang berikut:

1. Penelitian selanjutnya dapat menambahkan perbandingan performa dengan model lain dalam *time series forecasting*, seperti *Gated Recurrent Unit* (GRU), *Temporal Convolutional Networks* (TCN), atau *Extreme Gradient Boosting* (XGBOOST). Pendekatan ini bertujuan untuk mengidentifikasi model yang lebih baik dalam menangkap pola temporal data.
2. Penelitian selanjutnya dapat mempertimbangkan faktor eksternal, seperti tren bisnis atau kalender operasional perusahaan, guna meningkatkan kemampuan model dalam memprediksi fluktuasi beban kerja dengan lebih baik.
3. Penelitian selanjutnya dapat berfokus pada *tuning hyperparameter* menggunakan teknik seperti *Bayesian Optimization* atau *Grid Search* untuk mengoptimalkan performa model. Selain itu, eksperimen dengan berbagai arsitektur jaringan dan jumlah *hidden layers* dapat dilakukan untuk meningkatkan generalisasi model terhadap berbagai dataset.