

## BAB VI

### Penutup

#### 6.1 Kesimpulan

Pada penelitian tugas akhir ini telah dilakukan implementasi prosedur untuk pemodelan dan mengidentifikasikan peformansi dari model untuk memprediksi. Sehingga analisis yang detail telah dilakukan pada masing-masing observasi dari data dan model. Dengan membentuk sebuah skenario berdasarkan variasi antara *dataset* dan arsitektur pada masing-masing model sehingga dapat diuraikan secara detail. Berikut kesimpulan yang di dapat :

1. Proses pelatihan menggunakan arsitektur LSTM memiliki pola pembelajaran yang lebih stabil di bandingkan dengan arsitektur RNN.
2. Proses pelatihan menggunakan LSTM membutuhkan waktu komputasi lebih lama dan kompleks.
3. Hasil prediksi menunjukkan proses prediksi menggunakan skenario 4, 5, 7, 8, 13, 14, 16, dan 17 menghasilkan nilai prediksi yang lebih baik dan tidak menemui *overfitting*.
4. Hasil prediksi juga menunjukkan semakin besar ukuran data *training sample* pada proses pelatihan, maka semakin kecil nilai RMSE, dengan nilai RMSE terkecil yaitu 3,7 pada model LSTM dan 4,2 pada model RNN menggunakan *dataset* harian.
5. Menambah lebih dari satu *unit* pada *hidden layer* dapat meningkatkan kemampuan belajar pada model, namun model memiliki potensi menemui *overfitting* jika menambahkan lebih dari satu unit pada *output layer*.
6. Penerapan metode *lag time* pada *sample* data dapat meningkatkan kemampuan pada model untuk mempelajari pola pada data deret waktu, dengan *lag time* terbaik yaitu tujuh *lag* pada *feature* dan satu *lag* pada *label*.

## 6.2 Saran

Pada penelitian tugas akhir ini masih banyak terdapat kekurangan dan perlu di kembangkan agar dapat membantu menyelesaikan permasalahan dunia nyata. Peramalan deret waktu (*time series forecasting*) memiliki tantangan yang sangat banyak namun memiliki berbagai jenis metode peramalan dari berbagai cabang ilmu yang dapat di gabungkan dan di variasikan. Berikut ini saran yang dapat di berikan untuk pengembangan lebih lanjut :

1. Untuk meningkatkan akurasi pada model dapat menggunakan jumlah *dataset* yang lebih banyak lagi.
2. Menerapkan *dropout regulatazion* pada bias, bobot, dan *unit* pada masing-masing *layer*.
3. Menggunakan beberapa variasi *activation function* lain pada *layer*.
4. Menerapkan analisis *multivariate time series*, menambah jumlah variabel terhadap deret waktu yang lebih banyak lagi. Seperti *independent variabel google index searching*, data cuaca, data jumlah kedatangan wisatawan pada masing-masing jalur pendakian dan jumlah hari libur atau *long week-end*.
5. Menerapkan variasi model *deep learning* lain seperti *deep RNN/LSTM*, *bidirectional RNN/LSTM*, *Gating Recurrent Units (GRU)* dan gabungan antara *convlutional neural network (CNN)* dan RNN atau LSTM.
6. Menerapkan dan membangun secara langsung sebuah sistem untuk pihak, atau *deploy* hasil pembangunan suatu model untuk TNGMb agar dapat menerapkan *real-time prediction* dan membantu manajemen pengelolaan Tamana Nasional Gunung Merbabu.

## DAFTAR PUSTAKA

- [1] Y. Li and H. Cao, "Prediction for Tourism Flow based on LSTM Neural Network," *Procedia Comput. Sci.*, vol. 129, pp. 277–283, 2018.
- [2] F. Chollet, *Deep Learning with Python*, 1st ed. Manning Publications Co., 2018.
- [3] J. P. Mueller and L. Mueller, *Deep Learning for Dummies*. New Jersey: John Wiley & Sons, Inc., 2019.
- [4] A. Rahman, V. Srikumar, and A. D. Smith, "Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks," *Appl. Energy*, vol. 212, no. October 2017, pp. 372–385, 2018.
- [5] N. C. Chen, W. Xie, R. E. Welsch, K. Larson, and J. Xie, "Comprehensive Predictions of Tourists' Next Visit Location Based on Call Detail Records Using Machine Learning and Deep Learning Methods," *Proc. - 2017 IEEE 6th Int. Congr. Big Data, BigData Congr. 2017*, pp. 1–6, 2017.
- [6] R. Soelaiman, A. Martoyo, Y. Purwananto, and M. H. Purnomo, "Implementation of recurrent neural network and boosting method for time-series forecasting," *Int. Conf. Instrumentation, Commun. Inf. Technol. Biomed. Eng. 2009, ICICI-BME 2009*, 2009.
- [7] J. Xu, R. Rahmatizadeh, and D. Turgut, "Real-Time Prediction of Taxi Demand Using Recurrent Neural Networks," *IEEE Trans. Intell. Transp. Syst.*, pp. 1–10, 2017.
- [8] A. A. Rizal and S. Hartati, "Recurrent neural network with Extended Kalman Filter for prediction of the number of tourist arrival in Lombok," *2016 Int. Conf. Informatics Comput. ICIC 2016*, no. Icic, pp. 180–185, 2017.
- [9] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. LJUNG, "Time Series Analysis: Forecasting and Control," in *Wiley Series in Probability and Statistics*, 5th ed., D. J. Balding, N. A. C. Cressie, G. M. Fitzmaurice, G. H. Givens., H. Goldstein, G. Molenberghs, D. W. Scott, A. F. M. Smith, R. S. Tsay, and S. Weisberg, Eds. New Jersey: John Wiley & Sons, Inc., 2016, p. 1.
- [10] B. Render, R. M. Stair, and M. E. Hanna, *Quantitative Analysis For Management ELEVENTH EDITION*, 11th ed. New Jersey: Pearson Education, Inc., 2012.
- [11] R. H. Shumway and D. S. Stoffer, "Time Series Analysis and Its

- Applications With R Examples,” in *Springer Texts in Statistics*, 3rd ed., G. Casella, S. Fienberg, and I. Okin, Eds. New York: Springer, 2011, p. 11.
- [12] D. C. Montgomery, C. L. Jennings, and M. Kulahci, *INTRODUCTION TO TIME SERIES ANALYSIS AND FORECASTING*, 2nd ed. New Jer: John Wiley & Sons, Inc., 2015.
- [13] R. J. Hyndman and G. Athanasopoulos, *Forecasting: principles and practice*, 2nd ed. Melbourne: OTexts, 2018.
- [14] S. Bisgaard and M. Kulahci, *Time series analysis and forecasting by example*, vol. 49, no. 06. New Jersey: John Wiley & Sons, Inc, 2011.
- [15] Rusdi, “Uji Akar-Akar Unit dalam Model Runtun Waktu Autoregresif,” *J. Stat.*, vol. 11, no. 2, pp. 67–78, 2011.
- [16] J. G. Mackinnon, “Approximate asymptotic distribution functions for unit-root and cointegration tests,” *J. Bus. Econ. Stat.*, vol. 12, no. 2, pp. 167–176, 1994.
- [17] A. A. Rizal and S. Soraya, “Multi Time Steps Prediction dengan Recurrent Neural Network Long Short Term Memory,” *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 18, no. 1, pp. 115–124, 2018.
- [18] A. Nielsen, *Practical Time Series Analysis: Prediction with Statistics and Machine Learning*, 1st ed. O’Reilly Media, Inc., 2019.
- [19] E. Supriyanto, “Interpolasi Cubic Spline,” 2006.
- [20] A. Triyono, A. J. Santoso, and Pranowo, “Penerapan Metode Jaringan Syaraf Tiruan Backpropagation Untuk Meramalkan Harga Saham (IHSG),” *J. Sist. DAN Inform.*, vol. 11, no. 1, pp. 165–172, 2016.
- [21] S. Zheng, Y. Liu, and Z. Ouyang, “A machine learning-based tourist path prediction,” *Proc. 2016 4th IEEE Int. Conf. Cloud Comput. Intell. Syst. CCIS 2016*, pp. 38–42, 2016.
- [22] Y. W. Chang and C. Y. Tsai, “Apply deep learning neural network to forecast number of tourists,” *Proc. - 31st IEEE Int. Conf. Adv. Inf. Netw. Appl. Work. WAINA 2017*, pp. 259–264, 2017.
- [23] A. Géron, “Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow, 2nd Edition.” O’Reilly Media, Inc., 2019.
- [24] S. Kostadinov, *Recurrent Neural Networks with Python Quick Start Guide*. Birmingham: Packt Publishing Ltd., 2018.
- [25] A. Amidi and S. Amidi, “CS 230-Deep Learning VIP Cheatsheet: Recurrent Neural Networks,” pp. 1–5, 2018.
- [26] I. Sutskever, “Training Recurrent Neural Networks,” University of Toronto, Ont., 2013.

- [27] D. P. Kingma and J. L. Ba, “Adam: A method for stochastic optimization,” *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–15, 2015.
- [28] S. Hochreiter and J. Schmidhuber, “Long Short-Term Memory,” *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [29] Z. Pololikashvili, “Walking Tourism Promoting Regional Development,” *World Tourism Organization (WTO)*, Madrid, Spain, 2019.
- [30] A. Sagheer and M. Kotb, “Time series forecasting of petroleum production using deep LSTM recurrent networks,” *Neurocomputing*, vol. 323, pp. 203–213, 2019.



## LAMPIRAN

