

Sales Forecasting pada Dealer Motor X Dengan LSTM, ARIMA dan Holt-Winters Exponential Smoothing

Jennifer Soeryawinata, Henry Novianus Palit, Leo Willyanto Santoso

Program Studi Informatika Fakultas Teknologi Industri Universitas Kristen Petra

Jl. Siwalankerto 121 – 131 Surabaya 60236

Telp. (031) – 2983455, Fax. (031) – 8417658

E-mail: soeryawinataj@gmail.com, hnpalit@petra.ac.id, leow@petra.ac.id

ABSTRAK

Dalam dunia dagang, persediaan stok barang menjadi persoalan yang penting. Terkadang, dealer motor X mengalami kehilangan pendapatan akibat kurang persediaan motor serta ruang penyimpanan yang terbuang rugi karena motor yang kurang laris disimpan dalam jumlah banyak. Apabila proses restock mudah dilakukan, maka akan menjawab permasalahan. Persediaan motor pada dealer motor X dikirim dari Jakarta ke Sulawesi Tengah. Jika dealer motor X ingin melakukan restock maka akan memakan waktu yang cukup lama serta biaya pengiriman yang mahal. Untuk mengatasi permasalahan pada dealer motor X, diperlukan sebuah prediksi atau peramalan (forecasting) terhadap penjualan motor. Dengan adanya peramalan ini diharapkan pemilik dealer motor X dapat menentukan jumlah dan tipe motor mana yang harus dikirim dari Jakarta setiap bulannya. Pada penelitian ini akan menggunakan Long-Short Term Memory (LSTM), Autoregressive Integrated Moving Average (ARIMA), dan Holt-Winters Exponential Smoothing untuk melakukan forecasting penjualan motor dan kemudian akan dibandingkan performanya dengan menggunakan evaluation metrics, seperti Root Mean Square Error (RMSE) dan Mean Absolute Percentage Error (MAPE). Dari ketiga model ini, model yang paling baik untuk forecasting yaitu ARIMA dengan nilai RMSE (1.1339-5.8936) terendah untuk semua jenis motor dan memiliki nilai MAPE terendah untuk tiga jenis motor. Apabila model LSTM dibandingkan dengan model Holt-Winters, model LSTM lebih baik dalam melakukan peramalan dengan nilai RMSE dan nilai MAPE yang lebih kecil pada kebanyakan jenis motor.

Kata Kunci: forecasting, sales forecasting, LSTM, ARIMA, Holt-Winters, exponential smoothing

ABSTRACT

In the world of commerce, inventory is an important issue. Occasionally, motorcycle dealer X experience lost revenue due to a lack of motorcycle inventory as well as lost storage space due to under-selling motorcycles being stocked in large quantities. If the restock process is easy to do, it will answer the problem. Inventory of motorcycles at the motorcycle dealer X was sent from Jakarta to Central Sulawesi. If the motorcycle dealer X wants to do a restock, it will take a long time and expensive shipping costs. To overcome the problems at the motorcycle dealer X, a prediction or forecasting of motorcycle sales is needed. With this forecast, it is hoped that the owner of the motorcycle dealer X can determine the number and type of motorbikes that must be sent from Jakarta each month.

In this study, we will use Long-Short Term Memory (LSTM), Autoregressive Integrated Moving Average (ARIMA), and Holt-Winters Exponential Smoothing to forecast motorcycle sales and then compare their performance using evaluation metrics, such as the Root Mean Square Error (RMSE) and Mean Absolute Percentage Error (MAPE). From this third model, the best model

for forecasting is ARIMA with the lowest RMSE (1.1339-5.8936) value for all types of motors and has the lowest MAPE values for three types of motors. If the LSTM model is compared with the Holt-Winters model, the LSTM model is better at forecasting with smaller RMSE and MAPE values for most types of motors.

Keywords: forecasting, sales forecasting, LSTM, ARIMA, Holt-Winters, exponential smoothing

1. PENDAHULUAN

Dalam dunia dagang, persediaan stok barang menjadi persoalan yang penting. Bisnis utama usaha dagang adalah menjual persediaan barang dagang. Dealer motor X adalah sebuah usaha dagang yang bergerak dalam penjualan motor. Dealer motor X mempunyai beberapa kendala, salah satunya yaitu ketika pelanggan ingin membeli motor tetapi motor tidak tersedia. Hal ini menyebabkan dealer motor X kehilangan pendapatan. Kendala lain yang dihadapi ketika ada motor yang di stok berlebihan dan ternyata kurang laris. Hal tersebut akan memakan ruang penyimpanan yang seharusnya bisa diisi dengan motor yang lebih laris. Apabila motor yang kurang laris di stok berlebihan dan disimpan terus menerus, kemudian harga jualnya turun maka dealer motor X akan mengalami kerugian.

Jika proses restock mudah dilakukan, maka akan menjawab permasalahan stok motor. Permasalahan utama dealer motor X yaitu persediaan motor dikirim dari Jakarta ke Sulawesi Tengah. Jika dealer motor X ingin melakukan restock maka akan memakan waktu yang cukup lama serta biaya pengiriman yang mahal, khususnya pengiriman motor. Untuk mengatasi permasalahan pada dealer motor X, diperlukan sebuah prediksi atau peramalan (forecasting) terhadap penjualan motor. Dengan adanya peramalan ini diharapkan pemilik dealer motor X dapat menentukan jumlah dan tipe motor mana yang harus dikirim dari Jakarta setiap bulannya.

Ada berbagai model dalam time series forecasting. Metode yang paling terkenal adalah "Auto-Regressive Integrated Moving Average (ARIMA)" [5]. Selain ARIMA, model time series forecasting yang umum digunakan yaitu Holt-Winters Exponential Smoothing. Model ini dirancang untuk memprediksi hasil, dengan data point mencakup seasonality [7]. Teknik machine learning-based seperti SVM, Random Forests dan algoritma deep learning-based seperti RNN, dan Long Short-Term Memory (LSTM) memperoleh banyak perhatian dalam beberapa tahun terakhir dalam aplikasi termasuk keuangan [5]. Hasil penelitian menunjukkan LSTM meningkatkan prediksi sebesar 85% pada rata-rata dibandingkan dengan ARIMA [5]. Melihat keunggulan dari LSTM, pada penelitian ini digunakan algoritma deep learning-based LSTM yang akan dibandingkan dengan model time series tradisional yaitu ARIMA dan Holt-Winters Exponential Smoothing dalam memprediksi penjualan motor dealer motor X.

2. PENELITIAN SEBELUMNYA

Penelitian akan menggunakan beberapa penelitian lain terkait yang telah dilakukan sebelumnya sebagai tinjauan studi. Penelitian forecasting sebelumnya, terdapat penelitian yang membandingkan model ARIMA dan LSTM. Hasil dari penelitian ini menunjukkan LSTM meningkatkan prediksi sebesar 85% pada rata-rata dibandingkan dengan ARIMA [5]. Selain itu, terdapat penelitian yang menggunakan LSTM untuk memprediksi prakiraan banjir dan menghasilkan kesimpulan bahwa model LSTM memiliki akurasi lebih dari 86% untuk memperkirakan aliran sungai dua hari atau bahkan tiga hari ke depan [2]. Penelitian lainnya melakukan perbandingan ARMA, SARIMA, ARMAX, LSTM untuk memprediksi beban listrik. Hasil penelitian menunjukkan bahwa LSTM adalah metode yang paling unggul dengan nilai MAPE terkecil [3]. Selain LSTM dan ARIMA, penelitian sebelumnya juga menggunakan model Holt-Winters untuk melakukan peramalan NVDI. Dari penelitian didapatkan nilai MAE dan RMSE yang relative kecil, sehingga bisa dikatakan model Holt-Winters melakukan prediksi dengan cukup baik [4]. Oleh karena itu pada penelitian ini akan dilakukan dengan membandingkan beberapa metode yang dianggap bagus berdasarkan penelitian-penelitian terdahulu, yaitu LSTM, ARIMA, dan Holt-Winters.

3. DATASET

Dataset yang digunakan yaitu data penjualan motor tahun 2015 hingga 2021 dalam format file excel. Data penjualan cukup detail hingga memuat data penjualan per hari. Data dikelompokkan dalam tabel per bulan dengan atribut tanggal, nama pembeli, alamat, LSG, jenis motor, nomor rangka, nomor mesin, warna. Pada penelitian ini hanya akan digunakan atribut jenis motor beserta warna. Setelah dilakukan preprocessing data, maka data akan dibagi ke dalam training dataset dan test dataset. Training dataset berisi data penjualan selama 6 tahun dan test dataset berisi data penjualan selama 1 tahun terakhir. Training dataset berjumlah sebanyak 72 data dan test dataset berjumlah sebanyak 12 data.

4. METODE

4.1 Long Short-Term Memory

Long Short-Term Memory (LSTM) adalah jenis arsitektur RNN yang membantu dalam melatih model dalam urutan yang panjang dan dalam retensi memori dari langkah-langkah waktu sebelumnya dari input yang dimasukkan ke model. LSTM memecahkan masalah menghilang atau meledaknya gradien dengan memperkenalkan additional gate, input gate dan forget gate yang memungkinkan kontrol yang lebih baik atas gradien, dengan mengizinkan informasi apa yang harus disimpan dan apa yang harus dilupakan, sehingga mengontrol akses informasi ke keadaan sel saat ini. LSTM juga memiliki struktur chainlike tetapi pada modul yang diulang mempunyai struktur yang berbeda. LSTM dibentuk dengan menggunakan multiple gates yang berfungsi sebagai opsi yang baik untuk mengatur informasi yang masuk. Multiple gates memiliki lapisan sigmoid neural network dimana output pada $[0,1]$ untuk memberikan batasan minimal dari komponen dan sebuah operasi point-wise multiplication [1].

4.2 Autoregressive Integrated Moving Average

Autoregressive Integrated Moving Average (ARIMA) adalah model dari sebuah kelas yang menjelaskan deret waktu tertentu berdasarkan nilai masa lalu. Persamaan yang diturunkan oleh ARIMA dapat digunakan untuk meramalkan nilai-nilai yang akan datang. Secara teoritis, setiap time series nonseasonal yang menunjukkan pola dan tidak beracak dapat dimodelkan dengan

ARIMA. Model ARIMA dapat diklasifikasikan sebagai (p,d,q) model dimana p adalah jumlah orde autoregressive (AR), q adalah jumlah orde rata-rata bergerak (MA) dalam persamaan prediksi, dan d adalah urutan perbedaan yang diperlukan untuk stasioneritas. Rumus untuk menghitung ARIMA adalah sebagai berikut [6]:

$$y_t = C + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (1)$$

Keterangan:

y_t = nilai hasil peramalan

C = nilai konstanta

$\phi_1, \phi_2, \dots, \phi_p$ = parameter model autoregressive

$\theta_1, \theta_2, \dots, \theta_q$ = parameter model moving average

p = gap antara t dan $t - p$

q = gap antara t dan $t - q$

4.3 Holt-Winters Exponential Smoothing

Metode time series biasanya digunakan pada data yang menunjukkan tren atau pola musiman dengan prediksi yang dihasilkan menjadi rata-rata penimbangan dari pengamatan asa lalu dengan bobot yang menurun secara eksponensial sebagai pengamatan. Ada 3 bagian dari exponential smoothing yaitu single, double, dan triple yang biasa diketahui dengan Holt-Winters model. Holt-Winters model berguna menangkap komponen dan musiman tren untuk menghasilkan time series yang di smoothing. Rumus untuk menghitung Holt-Winters adalah sebagai berikut [7]:

$$\text{Level, } l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (2)$$

$$\text{Trend, } b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*) b_{t-1} \quad (3)$$

$$\text{Seasonal, } s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m} \quad (4)$$

$$\text{Forecast, } \hat{y}_{t+h|t} = l_t + hb_t + S_{t+h-m(k+1)} \quad (5)$$

Keterangan:

α = koefisien *smoothing* berdasarkan level

β = koefisien *smoothing* berdasarkan tren

γ = koefisien *smoothing* berdasarkan *seasonality*

k = integer dari $(h - 1)/m$

m = frekuensi dari *seasonality*

t = waktu

$(y_t - s_{t-m})$ = pengamatan yang disesuaikan secara musiman

$(l_{t-1} - b_{t-1})$ = prakiraan non-musiman

$(y_t - l_{t-1} - b_{t-1})$ = indeks musiman saat ini

4.4 Preprocessing Data

Setiap baris data yang akan masuk ke dalam model akan melalui tahap-tahap persiapan, seperti data cleaning dan data integration. Pertama adalah tahap data cleaning. Data cleaning dilakukan dengan menghapus kelebihan spasi pada data, mengubah data dengan ejaan yang tertukar, menambahkan karakter pada data yang kurang karakter. Selanjutnya adalah tahap data integration. Dari tabel penjualan motor per bulan akan dilakukan perhitungan jumlah penjualan per bulan untuk tiap jenis motor yang ada. Setelah itu, data akan dirangkum menjadi satu tabel penjualan per tahun yang memuat atribut tipe motor dan jumlah penjualan setiap bulan. Data per tahun digabungkan menjadi satu tabel dataset yang akan digunakan untuk melakukan peramalan. Kemudian, motor dengan jenis yang sama disatukan menjadi satu baris. Dari proses ini menghasilkan data penjualan 6 jenis motor yang siap digunakan untuk training model.

5. PENGUJIAN

5.1 Pengujian Parameter Tuning

Pemilihan parameter pada model merupakan salah satu hal yang penting untuk meningkatkan performa dari model tersebut. Pengujian parameter tuning akan diberlakukan untuk metode Long Short-Term Memory (LSTM), Autoregressive Integrated Moving Average (ARIMA) dan Holt-Winters Exponential Smoothing. Pengujian parameter tuning ini bertujuan untuk mencari kombinasi parameter yang paling baik. Jenis parameter yang akan diuji pada LSTM adalah epochs, batch size dan hidden layer. Parameter yang diuji pada ARIMA adalah orde p, d, q. Untuk Holt-Winters adalah trend dan seasonality.

5.1.1 Model LSTM

Pada pengujian parameter model LSTM dilakukan secara manual. Hal ini dikarenakan tuning parameter yang diprogram memakan waktu yang lama serta keterbatasan perangkat lunak yang digunakan. Pengujian menggunakan dataset testing penjualan motor selama 1 tahun terakhir. Pengujian parameter dilakukan terhadap data 6 (enam) jenis motor dengan parameter LSTM yang berbeda-beda. Berdasarkan hasil eksperimen yang telah dilakukan dapat disimpulkan bahwa kombinasi parameter LSTM yang paling baik untuk motor JUP-MX KING adalah batch size 1, epochs 50, hidden layer 5 dengan nilai RMSE sebesar 2.8701 dan MAPE 0.8534. Untuk motor JUP-Z, kombinasi parameter LSTM yang paling baik adalah batch size 1, epochs 200, hidden layer 20 dengan nilai RMSE sebesar 1.8577 dan MAPE 0.3962. Kombinasi parameter terbaik untuk motor MIO-M3 adalah batch size 1, epochs 100, hidden layer 10 dengan nilai RMSE sebesar 6.2616 dan MAPE 0.2229. Untuk motor MIO-Z menghasilkan performa terbaik pada batch size 4, epochs 50, hidden layer 2 dengan nilai RMSE sebesar 2.3788 dan MAPE 0.5118. Berdasarkan hasil eksperimen pada data motor VEGA FORCE dapat disimpulkan bahwa kombinasi parameter LSTM yang paling baik adalah batch size 2, epochs 50, hidden layer 20 dengan nilai RMSE sebesar 1.2687 dan MAPE 0.564. Untuk motor VIXION, kombinasi parameter LSTM yang paling baik adalah batch size 1, epochs 50, hidden layer 20 dengan nilai RMSE sebesar 2.4826 dan MAPE 0.8596.

5.1.2 Model ARIMA

Pada pengujian parameter model ARIMA dilakukan grid search dengan fungsi evaluate_models(). Dari hasil eksperimen Tabel 1, pada data motor JUP-MX KING dapat disimpulkan bahwa kombinasi parameter terbaik adalah p=3, d=2, q=7 dengan nilai RMSE sebesar 1.9197 dan MAPE 0.6723. Untuk motor JUP-Z kombinasi parameter ARIMA yang paling baik adalah p=5, d=2, q=5 dengan nilai RMSE sebesar 1.6714 dan MAPE 0.6849. Kombinasi parameter terbaik untuk motor MIO-M3 adalah p=4, d=0, q=7 dengan nilai RMSE sebesar 5.8936 dan MAPE 0.2022. Untuk motor MIO-Z menghasilkan performa terbaik pada p=3, d=1, q=4 dengan nilai RMSE sebesar 2.0125 dan MAPE 0.4648. Dalam Tabel 1 juga memuat kombinasi parameter terbaik untuk motor VEGA FORCE yaitu p=4, d=1, q=3 dengan nilai RMSE sebesar 1.1339 dan MAPE 0.586. Untuk motor VIXION, kombinasi parameter yang paling baik adalah p=4, d=1, q=7 dengan nilai RMSE sebesar 2.312 dan MAPE 0.9701.

Tabel 1. Pengujian Model ARIMA

| Jenis Motor | Parameter | | | RMSE | ARIMA |
|-------------|-----------|---|---|--------|--------|
| | p | d | q | | |
| JUP-MX KING | 3 | 2 | 7 | 1.9197 | 0.6723 |
| JUP-Z | 5 | 2 | 5 | 1.6714 | 0.6849 |
| MIO-M3 | 4 | 0 | 7 | 5.8936 | 0.2022 |

| | | | | | |
|------------|---|---|---|--------|--------|
| MIO-Z | 3 | 1 | 4 | 2.0125 | 0.4648 |
| VEGA FORCE | 4 | 1 | 3 | 1.1339 | 0.586 |
| VIXION | 4 | 1 | 7 | 2.312 | 0.9701 |

5.1.3 Model Holt-Winters

Pada pengujian parameter model Holt-Winters Exponential Smoothing dilakukan grid search dengan iterasi kombinasi parameter trend dan seasonality. Parameter trend dan seasonality memiliki dua nilai yaitu 'add' untuk additive dan 'mul' untuk multiplicative. Pengujian menggunakan dataset testing penjualan motor selama 1 tahun terakhir. Pengujian parameter dilakukan terhadap data 6 (enam) jenis motor dengan parameter Holt-Winters yang berbeda-beda. Berdasarkan hasil eksperimen pada data motor JUP-MX KING dapat dilihat pada Tabel 2 dapat disimpulkan bahwa kombinasi parameter Holt-Winters terbaik adalah trend 'add', seasonality 'mul' dengan nilai RMSE sebesar 2.3659 dan MAPE 0.8104. Untuk motor JUP-Z kombinasi parameter Holt-Winters yang paling baik adalah trend 'add', seasonality 'mul' dengan nilai RMSE sebesar 2.238 dan MAPE 0.92. Kemudian pada Tabel 2 dapat dilihat juga kombinasi parameter terbaik untuk motor MIO-M3 adalah trend 'add', seasonality 'add' dengan nilai RMSE sebesar 7.8853 dan MAPE 0.2805. Untuk motor MIO-Z menghasilkan performa terbaik pada trend 'add', seasonality 'mul' dengan nilai RMSE sebesar 2.8539 dan MAPE 0.6947. Dalam Tabel 2 memuat kombinasi parameter terbaik untuk motor VEGA FORCE yaitu trend 'mul', seasonality 'mul' dengan nilai RMSE sebesar 1.2056 dan MAPE 0.4565. Untuk motor VIXION, kombinasi parameter yang paling baik adalah trend 'mul', seasonality 'mul' dengan nilai RMSE sebesar 2.8551 dan MAPE 1.0309.

Tabel 2. Pengujian Model Holt-Winters

| Jenis Motor | Parameter | | RMSE | MAPE |
|-------------|-----------|-------------|--------|--------|
| | trend | seasonality | | |
| JUP-MX KING | 'add' | 'mul' | 2.3659 | 0.8104 |
| JUP-Z | 'add' | 'mul' | 2.238 | 0.92 |
| MIO-M3 | 'add' | 'add' | 7.8853 | 0.2805 |
| MIO-Z | 'add' | 'mul' | 2.8539 | 0.6947 |
| VEGA FORCE | 'mul' | 'mul' | 1.2056 | 0.4565 |
| VIXION | 'mul' | 'mul' | 2.8551 | 1.0309 |

5.2 Perbandingan Nilai RMSE dan MAPE Model LSTM, ARIMA dan Holt-Winters

Pada Tabel 3 menunjukkan perbandingan nilai RMSE dan MAPE dari metode LSTM, ARIMA, Holt Winters. Pada motor JUP-MX KING, nilai RMSE dan MAPE terbaik dimiliki oleh model ARIMA sebesar 1.9197 dan 0.8104. Untuk motor JUP-Z model ARIMA memiliki nilai RMSE yang paling kecil yaitu 1.6714, sedangkan nilai MAPE paling kecil dimiliki oleh model LSTM sebesar 0.3962. Pengujian pada motor MIO-M3 menghasilkan nilai RMSE dan MAPE terbaik yang dimiliki oleh model ARIMA sebesar 5.8936 dan 0.2022. Dari hasil pengujian dalam Tabel 3 dapat dilihat model dengan nilai RMSE dan MAPE terbaik untuk motor MIO-Z yaitu model ARIMA. Nilai RMSE sebesar 2.0125 dan nilai MAPE sebesar 0.4648. Untuk motor VEGA FORCE model ARIMA memiliki nilai RMSE terkecil sebesar 1.1339, sedangkan nilai MAPE terkecil dimiliki oleh model Holt-Winters sebesar 0.4565.

Pada motor VIXION nilai RMSE terbaik ditunjukkan oleh model ARIMA sebesar 2.312 dan nilai MAPE terbaik ditunjukkan oleh model LSTM sebesar 0.8596.

Apabila hasil uji coba dibandingkan, ternyata model ARIMA dapat melakukan peramalan dengan lebih baik dibandingkan kedua model lainnya. Untuk semua jenis motor, nilai RMSE terkecil dimiliki oleh model ARIMA. Sedangkan untuk nilai MAPE, model ARIMA memiliki nilai MAPE terkecil untuk 3 jenis motor. Nilai MAPE terkecil untuk 3 jenis motor lainnya dimiliki oleh LSTM. Jika model LSTM dibandingkan dengan Holt-Winters, model LSTM memiliki nilai RMSE dan MAPE yang lebih kecil dari model Holt-Winters.

Tabel 3. Perbandingan Model LSTM, ARIMA dan Holt-Winters

| Jenis Motor | RMSE | | | MAPE | | |
|-------------|--------|--------|--------------|--------|--------|--------------|
| | LSTM | ARIMA | Holt-Winters | LSTM | ARIMA | Holt-Winters |
| JUP-MX KING | 2.8701 | 1.9197 | 2.3659 | 0.8534 | 0.6723 | 0.8104 |
| JUP-Z | 1.8577 | 1.6714 | 2.238 | 0.3962 | 0.6849 | 0.92 |
| MIO-M3 | 6.2616 | 5.8936 | 7.8853 | 0.2229 | 0.2022 | 0.2805 |
| MIO-Z | 2.3788 | 2.0125 | 2.8539 | 0.5118 | 0.4648 | 0.6947 |
| VEGA FORCE | 1.2687 | 1.1339 | 1.2056 | 0.564 | 0.586 | 0.4565 |
| VIXION | 2.4826 | 2.312 | 2.8551 | 0.8596 | 0.9701 | 1.0309 |

6. KESIMPULAN

Secara keseluruhan, model terbaik untuk melakukan forecasting penjualan motor adalah ARIMA. ARIMA memiliki nilai RMSE terendah untuk keenam jenis motor dan nilai MAPE terendah pada 3 jenis motor. Jika model LSTM dan Holt-Winters dibandingkan, nilai RMSE dan MAPE LSTM masih lebih kecil dari Holt-Winters pada kebanyakan jenis motor. Dapat disimpulkan bahwa model ARIMA masih lebih baik daripada model deep-learning based LSTM dalam melakukan forecasting pada data *time series* yang berjumlah sedikit (84 data).

7. SARAN

Untuk penelitian selanjutnya, bisa melakukan uji coba model LSTM dengan jumlah training dataset yang lebih banyak. Kemudian, teknik preprocessing juga dibuat secara otomatis tidak dilakukan secara manual. Untuk mendapatkan model terbaik LSTM, kedepannya bisa dilakukan parameter tuning dengan range serta kombinasi parameter yang lebih beragam.

8. REFERENSI

- [1] Goyal, P., Pandey, S., & Jain, K. 2018. Deep Learning for Natural Language Processing: Creating Neural Networks with Python [E-book]. Apress.
- [2] Le, X.-H., Ho, H. V., Lee, G., & Jung, S. 2019. Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting. *Water*, 11(7), 1387. DOI= <https://doi.org/10.3390/w11071387>.
- [3] Muzaffar, S., & Afshari, A. 2019. Short-Term Load Forecasts Using LSTM Networks. *Energy Procedia*, 158, 2922–2927. DOI= <https://doi.org/10.1016/j.egypro.2019.01.952>.
- [4] Omar, M. S., & Kawamukai, H. 2021. Prediction of NDVI using the Holt-Winters model in high and low vegetation regions: A case study of East Africa. *Scientific African*, 14, e01020. DOI= <https://doi.org/10.1016/j.sciaf.2021.e01020>.
- [5] Siami-Namini, S., Tavakoli, N., & Siami Namin, A. 2018. A Comparison of ARIMA and LSTM in Forecasting Time Series. 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA). DOI= <https://doi.org/10.1109/icmla.2018.00227>.
- [6] Sun, J. 2021. Forecasting COVID-19 pandemic in Alberta, Canada using modified ARIMA models. *Computer Methods and Programs in Biomedicine Update*, 1, 100029. DOI= <https://doi.org/10.1016/j.cmpbup.2021.100029>.
- [7] Tuovila, A. 2020. Forecasting Definition. Investopedia. URI= <https://www.investopedia.com/terms/f/forecasting.asp>.