
Prediksi Jumlah Kunjungan Wisatawan Di Toraja Utara Menggunakan Metode *Long Short Term Memory*

Fidryani Saladan¹, Aryo Michael², Ferayanti Boas Gallaran³, Marchelin³

^{1,2,3}Program Studi Teknik Informatika, Universitas Kristen Indonesia Toraja, Tana Toraja, Sulawesi Selatan

⁴Program Studi Manajemen, Universitas Kristen Indonesia Toraja, Tana Toraja, Sulawesi Selatan
Email: ^{1*}saladanfitryani@gmail.com

Abstrak

Wisatawan mampu memberikan dampak positif dalam peningkatan kesejahteraan dan perekonomian masyarakat pada suatu daerah tertentu. Terlebih di Toraja Utara merupakan salah satu destinasi daerah yang terkenal akan tradisi adat budaya dan keindahan alam yang masih alami menjadi daya tarik tersendiri bagi wisatawan yang berkunjung ke Toraja Utara. Di dalam dunia pariwisata, memprediksi jumlah kunjungan wisatawan merupakan hal yang perlu dilakukan untuk mengetahui nilai prediksi kunjungan wisatawan dimasa mendatang. Metode *Long Short Term Memory* (LSTM) adalah salah satu metode untuk memprediksi data jumlah kunjungan wisatawan di Toraja Utara. Penelitian ini menggunakan data jumlah kunjungan wisatawan dari bulan Januari 2015 sampai bulan Desember 2021. Tujuan dari penelitian ini adalah untuk menentukan model terbaik dan kinerja model dengan parameter Jumlah Layer (32, 64, 128), *Sliding Window* dengan *size window* (3, 6, 9), *Dropout* (0.01, 0.1, 0.2 dan 0.5) dengan *Max Epoch* 100. Dari hasil training didapatkan model terbaik dengan MSE terendah pada jumlah layer 32 *dropout* 0.01 *epoch* 100 menghasilkan *Mean Square Error* (MSE) sebesar 0.070323934. Model terbaik yang didapatkan pada proses training digunakan untuk pengujian data testing pada jumlah layer 32, *dropout* 0.01 dan *epoch* 100 menunjukkan *Mean Square Error* (MSE) sebesar 110198720. Sehingga dapat dikatakan bahwa hasil *training* dan pengujian model tersebut memiliki kemampuan prediksi yang baik.

Kata kunci : Wisatawan, Prediksi, *Long Short Memory*, *Mean Squera Error*(MSE)

PREDICTING THE NUMBER OF TOURIST VISITS IN NORTH TORAJA USING THE LONG SHORT TERM MEMORY METHOD

Abstract

Tourists are able to have a positive impact in improving the welfare and economy of the community in a certain area. Moreover, North Toraja is one of the regional destinations which is famous for its cultural traditions and unspoiled natural beauty which is the main attraction for tourists visiting North Toraja. In the world of tourism, predicting the number of tourist visits is something that needs to be done to find out the predicted value of tourist visits in the future. The Long Short Term Memory (LSTM) method is a method for predicting data on the number of tourist visits in North Toraja. This study uses data on the number of tourist visits from January 2015 to December 2021. The purpose of this research is to

determine the best model and model performance with the Number of Layers parameter (32, 64, 128), Sliding Window with size window (3, 6, 9), Dropout (0.01, 0.1, 0.2 and 0.5) with a Max Epoch of 100. From the training and testing results, the lowest value was obtained at the number of layers 64, dropout 0.1 with the Mean Square Error (MSE) was 0.06295982 and the results of model testing using data testing were obtained in actual data and predictive data are found in the number of layers 128, dropout 0.2 and epoch 100 with Mean Square Error (MSE) is 219265623. So it can be said that the results of training and testing data testing have good predictive ability.

Keywords : *Travelers, Prediction, Long Short Term Memory, Mean Squera Error (MSE).*

I. PENDAHULUAN

Berwisata merupakan salah satu kebutuhan sekunder yang harus dipenuhi manusia selain kebutuhan utamanya. Pariwisata mampu memberikan dampak positif dalam peningkatan kesejahteraan dan perekonomian masyarakat pada suatu daerah tertentu. Setiap daerah memiliki keanekaragaman tempat wisata yang mampu menarik wisatawan, baik wisatawan lokal maupun mancanegara. Objek wisata merupakan tempat yang menjadi daerah tujuan wisatawan untuk berkunjung karena memiliki daya tarik tersendiri. Dewasa ini kegiatan berwisata lebih mengarah pada jenis wisata yang natural atau kembali ke alam (*back to nature*), hal ini dikarenakan suasana lingkungan wisata berbeda dengan rutinitas wisatawan pada umumnya serta kepedulian masyarakat terhadap konservasi dan pelestarian alam yang lebih meningkat.

Kabupaten Toraja Utara yang beribukota di Rantepao terletak antara 2°-3° Lintang Selatan dan 119°-12° Bujur Timur, dengan luas wilayah 1.151,47 km² atau sebesar 2,5 % dari luas provinsi Sulawesi Selatan (46.350,22 km²). Secara yuridis terbentuk Pada tanggal 21 Juli 2008 dengan terbitnya Undang-Undang Nomor 28 tahun 2008, dimana sebelumnya wilayah ini merupakan bagian dari Kabupaten Tana Toraja. Kabupaten Toraja Utara memiliki potensi untuk dijadikan sebagai destinasi wisata yang menjanjikan. Banyaknya tempat wisata ini membuat pemerintah untuk ikut campur tangan dalam mengelola tempat-tempat wisata yang ada. Semua tempat wisata di Kabupaten

Toraja Utara dikelola oleh Dinas Pariwisata baik itu Dinas Pariwisata tingkat Kabupaten dan Dinas Pariwisata Tingkat Provinsi. Dinas Pariwisata merupakan instansi pemerintah yang mempunyai peranan penting untuk menyediakan layanan informasi wisata serta mengambil kebijakan dalam pengembangan pariwisata terkhusus di Kabupaten Toraja Utara. Di dalam dunia pariwisata, memprediksi jumlah kunjungan wisatawan merupakan hal yang perlu dilakukan untuk mengetahui nilai prediksi kunjungan wisatawan dimasa mendatang.

Namun, karena adanya pandemik Covid19 pada tahun 2020, jumlah kunjungan pariwisata mengalami penurunan, hal ini terjadi karena pemerintah Kabupaten Toraja Utara menerapkan Kebijakan Pembatasan Sosial Berskala Besar (PSBB) dan tempat pariwisata diliburkan sebagai upaya pemutusan penyebaran Covid-19 di Toraja Utara. Oleh karena itu, dalam melakukan prediksi sangat perlu diperhatikan kondisi Pandemi Covid-19 yang berdampak pada penurunan jumlah kunjungan wisatawan di Toraja Utara.

Untuk memprediksi suatu data runtun waktu (*time series*) dilakukan menggunakan metode-metode statistik dan metode-metode kecerdasan buatan, akan tetapi metode-metode statistik memiliki kelemahan yaitu data yang digunakan harus linear. Untuk mengatasi kelemahan yang ada pada metode-metode statistik, maka diterapkan salah satu metode LSTM dipahami sebagai arsitektur alternatif untuk menangani masalah dalam *Recurrent Neural Network* (RNN) konvensional. *Long Short Term Memory* (LSTM) terdiri dari

memory cell, input gate, output gate, dan forget gate. Metode LSTM *neural network* sangat cocok untuk mengklasifikasi, memproses, dan membuat prediksi berdasarkan *time series* karena mungkin ada kelangkaan durasi yang tidak diketahui antara peristiwa penting dalam rangkaian waktu.

II. TINJAUAN PUSTAKA

A. Landasan Teori

1) Wisatawan

Menurut Undang-Undang Nomor 9 tahun 1990 tentang Pariwisata, Wisatawan adalah orang yang melakukan kegiatan wisata, sedangkan Keppres No. 9 tahun 1969 tentang pengembangan pariwisata, wisatawan adalah setiap orang yang berpergian dari tempat tinggalnya untuk berkunjung ke tempat lain dengan menikmati perjalanannya itu. Pada hasil konferensi Perserikatan Bangsa-Bangsa tentang perjalanan dan kepariwisataan tahun 1963 menyebutkan bahwa pengunjung (*visitor*) dibagi atas dua jenis yaitu wisatawan (*tourist*) dan pelancong (*excursionist*). Wisatawan (*tourist*) adalah mereka yang berkunjung paling sedikit 24 jam di negara yang dikunjungi dengan klasifikasi kunjungan untuk pesiar, hubungan dagang, keluarga, konferensi, dan menjalankan suatu misi. Pelancong (*excursionist*) adalah pengunjung sementara yang tinggal kurang dari 24 jam pada destinasi yang dikunjungi dan tidak tinggal untuk menginap melewati malam [7].

Menurut *World Tourism Organization* (WTO) definisi wisatawan adalah sebagai berikut:

1. Pengunjung adalah setiap orang yang berkunjung kesuatu negara lain dimana ia mempunyai tempat kediaman, dengan alasan melakukan pekerjaan yang diberikan oleh negara yang dikunjunginya.
2. Wisatawan adalah setiap orang yang bertempat tinggal disuatu negara tanpa memandang kewarganegaraannya, berkunjung ke suatu tempat pada negara yang sama untuk jangka waktu lebih dari 24 jam yang tujuan perjalanannya dapat diklasifikasikan pada salah satu hal berikut ini. Memanfaatkan waktu luang untuk

rekreasi, liburan kesehatan, pendidikan, keagamaan dan olahraga, bisnis atau mengunjungi keluarga.

3. Darmawisata atau *excursionist* adalah pengunjung sementara yang menetap kurang dari 24 jam dinegara yang dikunjunginya termasuk orang yang berkeliling dengan kapal pesiar, namun tidak termasuk pesiar yang memasuki negara secara legal, contohnya orang yang hanya tinggal diruang transit pelabuhan udara.

2) Artificial Intelligence (AI)

Menurut Stuart J.Russel dan Peter Norvig, *Artificial Intelligence* (AI) adalah sebuah perangkat komputer yang mampu memahami lingkungan disekitarnya, sekaligus memberikan respons yang sesuai dengan tujuan tindakannya tersebut [8].

3) Machine Learning

Machine Learning dilakukan 2 fase, yaitu *fase training* dan *fase application*. *Fase training* adalah proses pemodelan dari algoritma yang digunakan akan dipelajari oleh sistem melalui *training data*, sedangkan *fase application* adalah proses pemodelan yang telah dipeajari sistem melalui *fase training* akan digunakan untuk menghasilkan sebuah keputusan tertentu, dengan menggunakan *testing data*. Dalam *Machine Learning* ada 2 tugas yang umum dilakukan, yaitu *supervised learning* dan *unsupervised learning*. Cara *Unsupervised learning* adalah pemrosesan *simple data* dilakukan tanpa mewajibkan hasil akhir memiliki bentuk yang sesuai dengan bentuk tertentu, dengan menggunakan beberapa *simple data* sekaligus. Sedangkan, *Supervised learning* adalah pemrosesan *sample data x* akan diproses sedemikian rupa, sehingga menghasilkan *ouput* yang sesuai dengan hasil akhir y [9]

4) Data Mining

Data mining merupakan gabungan sejumlah disiplin ilmu komputer yang didefinisikan sebagai proses penemuan pola-pola baru di kumpulan-kumpulan data sangat besar atau *knowlage discovery in databases* yang disingkat KDD, meliputi metode-metode

yang merupakan irisaan dari *artificial intelligence*, *machine Learning*, *statistic*, dan *database system*[10]. Tugas-tugas *data mining* dapat dikelompokkan ke dalam enam kelompok yaitu:

1. Klasifikasi (*classification*): men-generalisasi struktur yang diketahui untuk diaplikasikan pada data-data baru. Misalkan, klasifikasi penyakit ke dalam sejumlah jenis, klasifikasi email ke dalam spam atau bukan.
2. Klasterisasi (*clustering*): mengelompokkan data, yang tidak diketahui label kelasnya, ke dalam sejumlah kelompok tertentu sesuai dengan ukuran kemiripannya.
3. Regresi (*regression*): menemukan suatu fungsi yang memodelkan data dengan galat (kesalahan prediksi) seminimal mungkin.
4. Deteksi anomali (*anomaly detection*): mengidentifikasi data yang tidak umum, bisa berupa *outlier*, perubahan atau deviasi yang mungkin sangat penting dan perlu investigasi lebih lanjut.
5. Pembelajaran aturan asosiasi (*association rule mining*) atau pemodelan kebergantungan (*dependency modeling*): mencari relasi antar variabel.
6. Perangkuman(*summarization*): menyediakan representasi data yang lebih sederhana, meliputi visualisasi dan pembuatan laporan

5) Prediksi

Prediksi adalah suatu proses peramalan secara variabel tentang sesuatu yang mungkin terjadi di masa depan berdasarkan informasi masa lalu dan sekarang, agar kesalahannya (selisih antara sesuatu yang terjadi dengan hasil perkiraan) dapat diperkecil.

6) Neural Network

Neural Network adalah metode *learning* yang bisa digunakan untuk permasalahan *diskrit*, *real*, maupun *vektor*. *Neural Network* dapat melaksanakan tugas tertentu sesuai dengan pemodelan sistem syaraf manusia[9].


7) Recurrent Neural Network

Recurrent Neural Network (RNN) adalah salah satu jenis jaringan syaraf tiruan yang memiliki koneksi berulang pada *cell*

jaringannya dan penerapan *deep learning* yang digunakan. Koneksi berulang memungkinkan RNN untuk memproses deretan *input*. RNN memiliki dua macam model yaitu Elman Network yang memiliki 2 lapisan dengan koneksi *Feedback* dari *output* dan *input*. model yang kedua yaitu *Hopfield Network* yang berfungsi sebagai penyimpanan satu atau lebih *vektor* target. RNN termasuk dalam jenis jaringan pemodelan *Neuron Network* [13].

8) Long Short Term Memory

LSTM merupakan varian dari unit *Recurrent Neural Network* (RNN). LSTM secara umum terdiri dari *cell*, *input gate*, *output gate*, dan *forget gate*. LSTM *neural network* sangat cocok untuk mengklasifikasi, memproses, dan membuat prediksi berdasarkan data *time series* karena mungkin ada kelangkaan durasi yang tidak diketahui di antara peristiwa penting dalam rangkaian waktu [15].




Gambar 1. Arsitektur LSTM

LSTM terdiri dari sel memori, satu sel memori memiliki *tiga gate* yaitu *input gate*, *forget gate*, *output gate*. *Input gate* berfungsi mengontrol berapa banyak informasi yang harus disimpan dalam keadaan sel. Ini mencegah sel dari menyimpan data yang tidak perlu. *Forget gate* berfungsi mengontrol sejauh mana nilai tetap di dalam sel memori. *Output Gate* berfungsi untuk memutuskan berapa banyak konten atau nilai dalam sel memori, digunakan untuk menghitung. Kunci utama pada LSTM adalah *cell state*. *Cell state* adalah garis *horizontal* yang menghubungkan semua *output layer* pada LSTM. Parameter dari model LSTM adalah *epoch*, *hidden layer*, *batch size*, dan *dropout*. Parameter *epoch* adalah satuan yang digunakan ketika seluruh *dataset* sudah melewati model. Parameter *hidden layer* adalah lapisan tersembunyi yang terdiri dari *neuron* yang menerima data dari lapisan masukan.

parameter *batch size* adalah jumlah sampel dari *dataset* yang dimasukkan kedalam model setiap iterasi dan parameter *dropout* berfungsi mengaplikasikan *dropout* pada *input layer* ini.

Pada tahapan LSTM, langkah pertama dimulai melalui komponen *forget gate* (f_t). Pada bagian ini informasi yang kurang dibutuhkan terhadap kasus yang diolah akan dihilangkan menggunakan fungsi *sigmoid*. Data X_t adalah input data (*vektor input x* dalam *timestep t*) dan h_{t-1} adalah *vektor hidden state* dalam *timestep* sebelumnya $t-1$. Persamaan (1) menggambarkan prinsip kerja perhitungan nilai *forget gate*. Sedangkan *input gate* (i_t) menggunakan perhitungan pada persamaan 2, memiliki 2 *gate* yang menggunakan fungsi aktivasi *sigmoid* untuk memperbarui informasi dan menggunakan fungsi aktivasi *tanh* yang akan menyimpan nilai baru di *memory cell* $\sim C_t$ menggunakan perhitungan pada persamaan 3 [14]. Hal ini dapat dilihat pada rumus persamaan (2) dan (3).



Gambar 2. Tahapan Pada LSTM

$$f_t = s(W_f.[h_{t-1}, X_t] + b_f) \quad (1)$$

$$i_t = s(W_i.[h_{t-1}, X_t] + b_i) \quad (2)$$

$$c_t = \tanh(W_c.[h_{t-1}, X_t] + b_c) \quad (3)$$

Persamaan (4) selanjutnya diperbarui nilai *cell state* lama c_{t-1} menjadi *cell state* baru c_t adalah hasil gabungan nilai pada *input gate*. *Forget gate* akan menggantikan nilai *memory cell* oleh *cell gates*. Pada *output gates* juga terdapat 2 *gate* yaitu untuk memutuskan nilai yang akan dikeluarkan dengan fungsi aktivasi *sigmoid* dan menyimpan nilai dengan memakai fungsi aktivasi *tanh* [16]. Hal ini dirumuskan pada persamaan (5) dan (6).

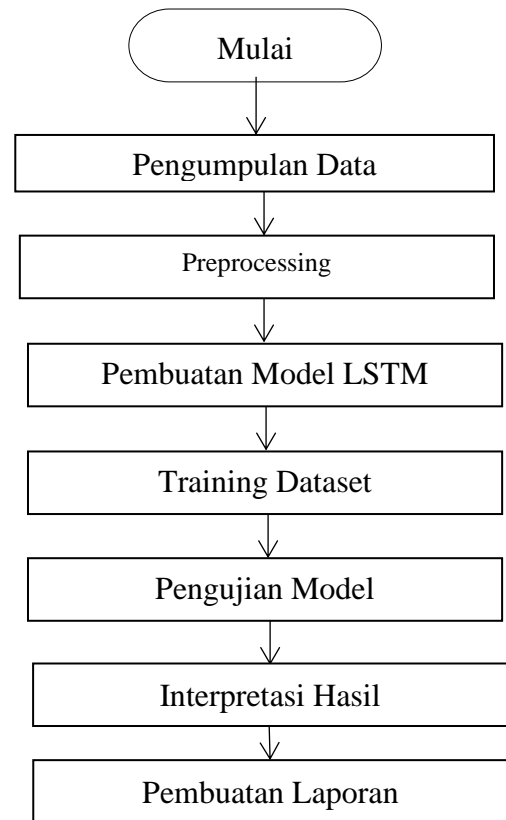
$$C_t = f_t * C_{t-1} + i_t * c_t \quad (4)$$

$$o_t = s(W_o.[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \tanh(c_t) \quad (6)$$

III. METODE PENELITIAN

Tahapan penelitian tentang Prediksi Jumlah Kunjungan Wisatawan Di Toraja Utara Menggunakan Metode Long Short Term Memory 9.



Gambar 3. Tahapan Penelitian

1) Pengumpulan Data yang digunakan dalam penelitian ini yaitu data yang diperoleh langsung dari Kantor Dinas Pariwisata dan Kebudayaan Toraja Utara dari tahun 2015 sampai 2021, data jumlah kunjungan wisatawan yang digunakan memiliki jumlah data sebanyak 84 bulan. Yang dapat dilihat pada tabel 1

Bulan	Jumlah Data
2015-01-01	7333
2015-02-01	5734
2015-03-01	3315
2015-04-01	8894
2015-05-01	10986
...	...

2021-08-01	5497
2021-09-01	12356
2021-10-01	12550
2021-11-01	13856
2021-12-01	33895

2) *Preprocessing*

Proses awal yang dilakukan pada tahap *preprocessing* adalah proses normalisasi dan *sliding window*

a. Normalisasi Data

Pada *Normalisasi data* dilakukan menggunakan *library sklearn* dengan fungsi *Min Max Scaler* atau dengan persamaan sebagai berikut:

$$X^1 = \frac{X - X_{min}}{X_{max} - X_{min}} \tag{7}$$

Dimana :

X^1 = Data setelah dinormalisasi

X = Data aktual

X_{min} = Data minimum dari keseluruhan data

X_{max} = Data maksimum dari keseluruhan data

Tabel 2. Data Hasil Normalisasi

		Tahun						
Bulan		2015	2016	2017	2018	2019	2020	2021
JAN	0.0915966 06	110100 74	0.37002 0429	0.39486 76	0.87575 66	0.63457 6098	0.090241 219	
FEB	0.0601870 04	0.18138 603	0.21566 355	0.22420 76	0.23454 4	0.09992 5356	0.004616 17	
MAR	0.0126699 14	0.20633 2993	0.25237 6837	0.23760 92	0.24943 45	0.03303 9994	0.042959 849	
APR	0.1222597 63	0.04902 9622	0.38956 5491	0.31812 88	0.21778 24	0.63457 6098	0.071658 678	
MEI	0.1633535 337	0.22393 3669	0.33790 84	0.31258 66	0.41506 5356	0.09992 821	0.048302	
JUN	0.1569694 35	0.15103 7165	0.38139 3887	0.41437 51	0.51217 32	0.03303 9994	0.078789 188	
JUL	0.0871768 68	0.23045 4938	0.91421 7805	0.79828 77	0.76899 5	0	0.201402 53	
AGS	0.2648306 75	0.12304 5494	0.49764 2807	0.45772 66	0.56242 38	0.10444 3309	0.055531 547	
SEP	0.0896126 35	0.36424 5305	0.54946 1774	0.54712 24	0.52123 84	0.04058 3012	0.190264 791	
OKT	0.2332835 7	0.33912 1553	0.19004 8715	0.45692 91	0.32395 42	0.06270 1344	0.194075 587	
NOV	0.2208690 19	0.20138 2887	0.19323 0926	0.40529 56	0.86776 52	0.18739 6873	0.219729 708	
DES	0.4418166 1	0.42032 6864	0.68855 5826	0.89516 25	1	0.52604 6987	0.613361 358	

b. *Sliding Window*

Pemrosesan data pada *sliding window* akan diproses menjadi *window size* 3, 6 dan 9, dimana akan digunakan X sebagai input dan y

sebagai output data. Sebagai contoh jika menggunakan *sliding window* = 3 maka data ke-4 merupakan nilai *output*. Proses awal *sliding window* dapat dilihat pada gambar 4.3 dengan contoh inputan *window size* 3. Hasil *sliding window* dapat dilihat pada tabel 3

Tabel 3. *Sliding Window Size* 3

X1	X2	X3	Y
0.091596606	0.060187004	0.012669914	0.122259763
0.060187004	0.012669914	0.122259763	0.1633535
0.012669914	0.122259763	0.1633535	0.156969435

0.1633535	0.156969435	0.087176868	0.1633535
0.156969435	0.087176868	0.060187004	0.156969435
0.012669914	0.060187004	0.012669914	0.122259763

Tabel 3 di atas menunjukkan hasil Y untuk 6 pola *time series*, dimana X1 hingga X6 merupakan nilai input untuk selanjutnya data ke-7 digunakan untuk mendapatkan nilai Y (target) yang akan menjadi nilai *output*.

3) Pembuatan Model

Pembentukan model LSTM dimulai dengan perhitungan manual untuk menentukan bobot dengan menggunakan persamaan sebagai berikut :

$$W = \left[-\frac{1}{\sqrt{d}}, \frac{1}{\sqrt{d}} \right] \tag{8}$$

$$W = \left[-\frac{1}{\sqrt{12}}, \frac{1}{12} \right] \tag{9}$$

$$W = [-0,288,0,288] \tag{10}$$

Nilai bobot tersebut digunakan untuk perhitungan jumlah layer hari ke-1 dan seterusnya, dalam pembentukan model LSTM dilakukan inisialisasi parameter yang akan digunakan dalam pelatihan dan pengujian model LSTM. Dengan menggunakan parameter jumlah layer (32, 64, 128), *sliding window* (3, 6, 9), *dropout* (0.01, 0.1, 0.2, 0.5) *max epoch* 100 pembentukan model dilakukan menggunakan *library tensorflow keras* dengan fungsi *sequential* dengan penambahan layer LSTM.

4) Pelatihan dan Pengujian Model LSTM

Dataset latih yang telah dibuat sebelumnya akan dilakukan pelatihan model LSTM berdasarkan parameter yang telah ditentukan pada pembentukan model LSTM.

Pembentukan model terbaik pada LSTM dan parameter kendali terbaik dalam pelatihan jaringan akan digunakan untuk melakukan pengujian terhadap dataset uji.

5) Evaluasi Kinerja LSTM

Salah satu cara untuk mengukur performa dari kinerja jaringan adalah dengan melihat nilai rata-rata error (MSE). Keluaran yang dihasilkan pada saat pelatihan dan pengujian oleh jaringan akan dibandingkan dengan nilai target. Untuk mendapatkan nilai MSE menggunakan persamaan :

$$MSE = \frac{1}{N} \sum_{n=1}^n (T_i - Y_i) \quad (11)$$

Keterangan:

N adalah jumlah pelatihan, T_i adalah target data ke-i, dan Y_i adalah output jaringan data ke-i.

Y_i = Data sebenarnya.

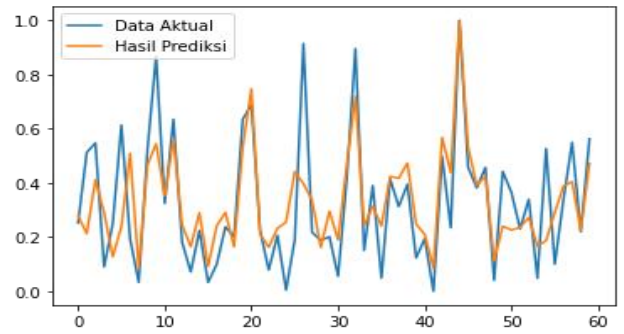
IV. HASIL DAN PEMBAHASAN

A. Hasil

1) Proses *Training*

Pada proses *training* dengan menggunakan parameter terdiri dari mengkombinasikan seluruh jumlah *layer* dan *dropout*. Kemudian *epoch* yang digunakan pada penelitian ini yaitu *epoch* 100 dimana *epoch* merupakan banyaknya proses iterasi atau pengulangan.

pada proses pelatihan menghasilkan nilai rata-rata error (MSE) Terkecil pada jumlah layer 32 dropout 0.01 sebesar 0.070324036. Dimana data aktual dengan data hasil prediksi tidak jauh berbeda. Gambar 4 memperlihatkan hasil training Model terbaik dengan MSE terkecil dengan menggunakan parameter jumlah layer 32 dropout 0.01 epoch 100.

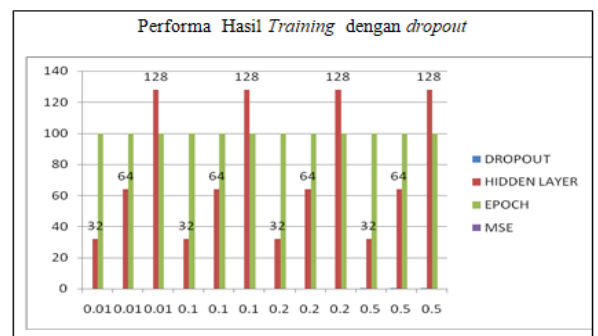


Gambar 4. Grafik Hasil Proses Pelatihan Menggunakan *Epoch* 100

Tabel 4. Data Aktual dan Data Hasil Prediksi

N0	Data Aktual	Data Prediksi
1	0.12225976	0.12891713
2	0.1633535	0.14334956
3	0.15696944	0.4820118
4	0.07165868	0.5874648
5	0.04830282	0.39574105
6	0.07878919	0.35335022
7	0.1633535	0.36711097
8	0.15696944	0.37113914
...
61	0.07165868	0.21787533
62	0.04830282	0.07084703
63	0.18138603	0.57619905
64	0.20633299	0.5335494
65	0.04902962	0.33008236
66	0.09024122	0.42690662
67	0.00461617	0.18180741


Performa hasil *training* yang dilakukan pada data aktual dengan data prediksi berdasarkan jumlah layer 32, 64 dan 128 *dropout* 0.01, 0.1, 0.2 dan 0.5 *epoch* 100 dapat dilihat pada gambar 5.



Gambar 5. Performa Hasil Training Dengan Dropout

2) Pengujian Model LSTM

Hasil pengujian arsitektur model dapat dilihat pada gambar 6 Grafik pengujian Arsitektur model LSTM menggunakan parameter dari model terbaik hasil proses training yaitu jumlah *layer* 32 *dropout* 0.01 *epoch* 100.



Gambar 6. Grafik Hasil Pengujian Jumlah Layer 32 Dropout 0.01

Tabel 6. Data Aktual Dengan Data Hasil Prediksi

Data Aktual	Data Prediksi
19872	21330.229
12922	18375.238
23303	23957.705
2905	13534.556
19934	16045.849
14766	20173.3
33895	13255.363
28744	28766.258
7108	9723.365
2670	15406.783
30523	22138.973
4352	22284.725
29450	7765.675
22772	32268.445
34975	31399.42
31302	27637.309
19872	21330.229
12922	18375.238

Hasil pengujian pada pembentukan model menggunakan jumlah *layer* 32, *dropout* 0.01 dan *epoch* 100. Dengan garis berwarna biru menunjukkan data aktual dan garis berwarna orange sebagai data hasil prediksi,

menunjukkan perbedaan antara data aktual dengan data hasil prediksi tidak jauh berbeda. Dengan menghasilkan nilai hasil prediksi *Mean Square Error* (MSE) sebesar 0.0198720.

B. Pembahasan

Berdasarkan hasil yang didapatkan dengan penentuan model terbaik dengan parameter LSTM dapat disimpulkan bahwa model *Long Short Term Memory* (LSTM) dapat digunakan sebagai metode prediksi berdasarkan pada data sebelum kejadian. Dalam penelitian ini penulis menentukan parameter dengan Jumlah *layer* 32, *layer* 64 dan *layer* 128, *dropout* 0.01, 0.1, 0.2 dan 0.5 *epoch* 100 dalam proses training dan pengujian model. Hasil prediksi dengan proses *training* model LSTM memperlihatkan jumlah jumlah *Layer* dan *dropout* yang berbeda dalam tahap pengujian akan menghasilkan *output* yang berbeda pula pada sistem.

Dari hasil *training* yang dilakukan pada data aktual dengan data hasil prediksi berdasarkan jumlah *layer* 32, 64, 128 *dropout* 0.01, 0.1, 0.2 0.5 *epoch* 100. Penentuan model terbaik berdasarkan nilai terendah MSE, menghasilkan peramlan jumlah *layer* 32 *dropout* 0.2 *epoch* 100 dengan menunjukkan nilai *Mean Square Error* (MSE) sebesar 0.070324036. model terbaik dari hasil traing akan dilakukan pengujian model dengan data testing menggunakan jumlah *layer* 32 *dropout* 0.01 *epoch* 100, dengan hasil pengujian menghasilkan data aktual dengan data hasil prediksi tidak jauh berbeda. Sehingga dapat dikatakan bahwa hasil prediksi mendekati data aktual dengan *Mean Square Error* (MSE) sebesar 110198720 yang dihasilkan pada pengujian model.

V. KESIMPULAN DAN SARAN

A. Kesimpulan

Dari hasil *training* dan pengujian data testing dapat disimpulkan bahwa metode *Long Short Trem Memory* dapat digunakan sebagai metode prediksi berdasarkan data sebelum kejadian. Berdasarkan hasil dan pembahasan mengenai prediksi jumlah

kunjungan wisatawan dari tahun 2015 hingga tahun 2021, pada kasus penelitian ini digunakan jumlah layer 32, 64 dan 128 dropout 0.01, 0.1, 0.2 0.5 epoch 100. Untuk menentukan model terbaik berdasarkan hasil training dengan nilai MSE terendah pada jumlah layer 32 dropout 0.01 epoch 100 dengan Mean Square Error (MSE) sebesar 0.070324036. Pada pengujian model digunakan model terbaik hasil training dengan data testing yang mendekati data aktual dengan data hasil prediksi menggunakan jumlah layer 32, dropout 0.2 dan epoch 100 dengan Mean Squera Error (MSE) sebesar 110198720. Penggunaan data latih dalam jumlah banyak semakin baik dalam proses pelatihan LSTM.

B. Saran

Adapun saran yang diberikan untuk penelitian selanjutnya berdasarkan penelitian yang telah dilakukan yaitu semakin banyak data yang digunakan sebagai sampel maka data yang dihasilkan akan semakin akurat. Penulis juga menyarankan untuk penelitian selanjutnya agar memilih ataupun menggunakan model yang lebih menunjang dengan penelitian yang akan dilakukan.

REFERENSI

- [1] I. R. Julianto and A. A. Rohmawati, "Prediksi Jumlah Kunjungan Wisatawan Di Jawa Barat Dengan Model ARIMAX Dan SARIMAX Menggunakan Data Google Trends," vol. 8, no. 4, pp. 4229–4241, 2021.
- [2] A. Michael and M. Garonga, "Prediksi Kunjungan Wisatawan Toraja Utara Menggunakan Jaringan Syaraf Tiruan Backpropagation," *J. Dyn. Saint*, vol. 5, no. 1, pp. 890–895, 2020, doi: 10.47178/dynamicsaint.v5i1.1069.
- [3] A. A. Rizal and S. Hartati, "Prediksi Kunjungan Wisatawan di Pulau Lombok dengan Menerapkan Recurrent Neural Network dengan Algoritma Training Extended Kalman Filter.," *J. Ilm. ILMU Komput.*, vol. X, no. 1, pp. 7–18, 2017.
- [4] L. Surtiningsih, M. T. Furqon, and S. Adinugroho, "Prediksi Jumlah Kunjungan Wisatawan Mancanegara Ke Bali Menggunakan Support Vector Regression dengan Algoritma Genetika," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 8, pp. 2578–2586, 2018.
- [5] T. Ruliana, Muhammad, "Metode Arima Box-Jenkins Pada Data Kun...jungan Wisatawan Mancanegara Di Indonesia 1,2,3," in *Prosiding Seminar Nasional VARIANSI*, 2020, pp. 223–234.
- [6] M. K. Nengsih and Y. I. Ariska, "Analisis Cluster Pengunjung Tempat Wisata," *J. Ilm. Ekon. Dan Bisnis*, vol. 8, no. 1, pp. 1–8, 2020.
- [7] H. Soleh, "Faktor-Faktor Yang Mempengaruhi Daya Tarik Wisata Air Terjun Aek Martua Di Desa Tangun Kecamatan Bangun Purba Kabupaten Rokan Hulu Provinsi Riau," *Jom FISIP*, vol. 4, no. 1, pp. 1–12, 2017, [Online]. Available: <https://jom.unri.ac.id/index.php/JOMFSIP/article/download/13870/13431>.
- [8] D. Anggraini, "Kecerdasan Buatan (Ai) Dan Nilai Co-Creation Dalam Penjualan B2B (Business-To-Business)," *J. Sist. Informasi, Teknol. Informasi, dan Edukasi Sist. Inf.*, vol. 1, no. 2, pp. 63–69, 2020, doi: 10.25126/justsi.v1i2.7.
- [9] E. K. Adhitya, R. Satria, and H. Subagyo, "Komparasi Metode Machine Learning Dan Metode Non Machine Learning untuk Estimasi Usaha Perangkat Lunak," *IlmuKomputer.com J. Softw. Eng.*, vol. 1, no. 2, pp. 109–113, 2015.
- [10] B. S. Purnomo and P. T. Prasetyaningrum, "Implementasi Data Mining Dalam Klasifikasi Kunjungan

- Wisatawan Di Kota Yogyakarta Menggunakan Algoritma,” *JIFTI - J. Ilm. Teknol. Inf. dan Robot.*, vol. 2, no. 1, pp. 1–5, 2020.
- [11] E. N. G. I. Septian and P. M. S. Tri, “Produksi Pada PT . Agaricus Sido Makmur Sentosa,” vol. 67.
- [12] Y. D. Pristanti and F. Windana, “Pengembangan Metode Neural Networks untuk Menentukan Karakter Seseorang,” *J. STT STIKMA Int.*, vol. 6, no. 1, pp. 9–27, 2015.
- [13] D. E. Tarkus, S. R. U. A. Sompie, and A. Jacobus, “Implementasi Metode Recurrent Neural Network pada Pengklasifikasian Kualitas Telur Puyuh,” *J. Tek. Inform.*, vol. 15, no. 2, pp. 137–144, 2020.
- [14] M. R. Firmansyah, R. Ilyas, and F. Kasyidi, “Klasifikasi Kalimat Ilmiah Menggunakan Recurrent Neural Network,” *Pros. 11th Ind. Res. Work. Natl. Semin.*, vol. 11, no. 1, pp. 488–495, 2020.
- [15] L. Wiranda and M. Sadikin, “Penerapan Long Short Term Memory Pada Data Time Series Untuk Memprediksi Penjualan Produk Pt. Metiska Farma,” *J. Nas. Pendidik. Tek. Inform. JANAPATI*, vol. 8, no. 3, pp. 184–196, 2020, [Online]. Available: <https://ejournal.undiksha.ac.id/index.php/janapati/article/view/19139>.
- [16] I. Habibie, “Identifikasi Judul Berita Clickbait Berbahasa Indonesia dengan Algoritma LSTM RNN,” *Univ. Sumatera Utara*, p. 56, 2018, [Online]. Available: <https://www.usu.ac.id/id/fakultas.html>.
- [17] T. Jpy, “Efisiensi Relatif Estimator Fungsi Kernelgaussian Terhadap Estimator Polinomial dalam Peramalan Usd Terhadap Jpy,” *Unnes J. Math.*, vol. 2, no. 2, 2013, doi: 10.15294/ujm.v2i2.3245.
- [18] P. Sugiartawan, A. A. Jiwa Permana, and P. I. Prakoso, “Forecasting Kunjungan Wisatawan Dengan Long Short Term Memory (LSTM),” *J. Sist. Inf. dan Komput. Terap. Indones.*, vol. 1, no. 1, pp. 43–52, 2018, doi: 10.33173/jsikti.5.
- [19] A. Anshari, “Rancang Bangun Interpreter Bahasa Isyarat Indonesia menggunakan Leap Motion dan Algoritma Naive Bayes dengan Bahasa Pemrograman Python,” 2019, [Online]. Available: <http://repositori.uin-alauddin.ac.id/14533/>.