

Forecasting Kunjungan Wisatawan Dengan Long Short Term Memory (LSTM)

Putu Sugiartawan^{*1}, Agus Aan Jiwa Permana² Paholo Iman Prakoso³

¹Teknik Informatika, STMIK STIKOM Indonesia, Indonesia

²Manajemen Informatika, Universitas Pendidikan Ganesha, Indonesia

³Information Technology, Computer and Sciences Association (INFOTEKS), Indonesia

e-mail: ^{*1}putu.sugiartawan.85@gmail.com, ²agus.aan@undiksha.ac.id,

³pahalaimanprakoso@gmail.com

Abstrak

Bali merupakan salah satu obyek wisata favorit di Indonesia, dimana jumlah kunjungan wisatwawan yang berkunjung ke Bali sekitar 4 juta lebih wisatawan 2015 (Dispar Bali). Jumlah wisatawan yang berkunjung tersebar diberbagai daerah dan objek wisata yang terdapat dibali. Meskipun kunjungan wisatawan ke Bali dapat dikatakan besar, namun kunjungan tersebut tidaklah merata, terjadi fluktuasi yang cukup signifikan terhadap kunjungan wisatawan tersebut. Teknik peramalan atau forecasting dapat mengetahui pola kunjungan wisatawan.

Teknik forecasting bertujuan untuk memprediksi pola data yang sebelumnya, sehingga dapat diketahui pola data selanjutnya. Pada penelitian ini menggunakan teknik recurrent neural network dalam memprediksi tingkat kunjungan wisatawan. Salah satu teknik recurrent neural network (RNN) yang digunakan dalam penelitian ini adalah Long Short Term Memory (LSTM). Model ini lebih baik dibandingkan dengan model RNN sederhana. Pada penelitian ini meramal tingkat kunjungan wisatawan dengan menggunakan algoritma LSTM, data yang digunakan adalah data kunjungan wisatawan ke salah satu obyek wisata yang ada di Bali. Hasil yang diperoleh dengan menggunakan model LSTM adalah sebesar 15,962. Nilai yang diukur merupakan nilai eror, dengan teknik MAPE. Arsitektur LSTM yang digunakan terdiri dari jumlah unit neuron pada hidden layer sebanyak 16 unit, learning rate sebesar 0,01, windows size sebanyak 3, dan jumlah hidden layer adalah 1.

Kata kunci— RNN, LSTM, forecasting, sliding windows

Abstract

Bali is one of the favorite tourist attractions in Indonesia, where the number of foreign tourists visiting Bali is around 4 million over 2015 (Dispar Bali). The number of tourists visiting is spread in various regions and tourist attractions that are located in Bali. Although tourist visits to Bali can be said to be large, the visit was not evenly distributed, there were significant fluctuations in tourist visits. Forecasting or forecasting techniques can find out the pattern of tourist visits.

Forecasting technique aims to predict the previous data pattern so that the next data pattern can be known. In this study using the technique of recurrent neural network in predicting the level of tourist visits. One of the techniques for a recurrent neural network (RNN) used in this study is Long Short-Term Memory (LSTM). This model is better than a simple RNN model. In this study predicting the level of tourist visits using the LSTM algorithm, the data used is data on tourist visits to one of the attractions in Bali. The results obtained using the LSTM model amounted to 15,962. The measured value is an error value, with the MAPE technique. The LSTM architecture used consists of 16 units of neuron units in the hidden layer, a learning rate of 0.01, windows size of 3, and the number of hidden layers is 1.

Keywords— RNN, LSTM, forecasting, sliding windows

1. PENDAHULUAN

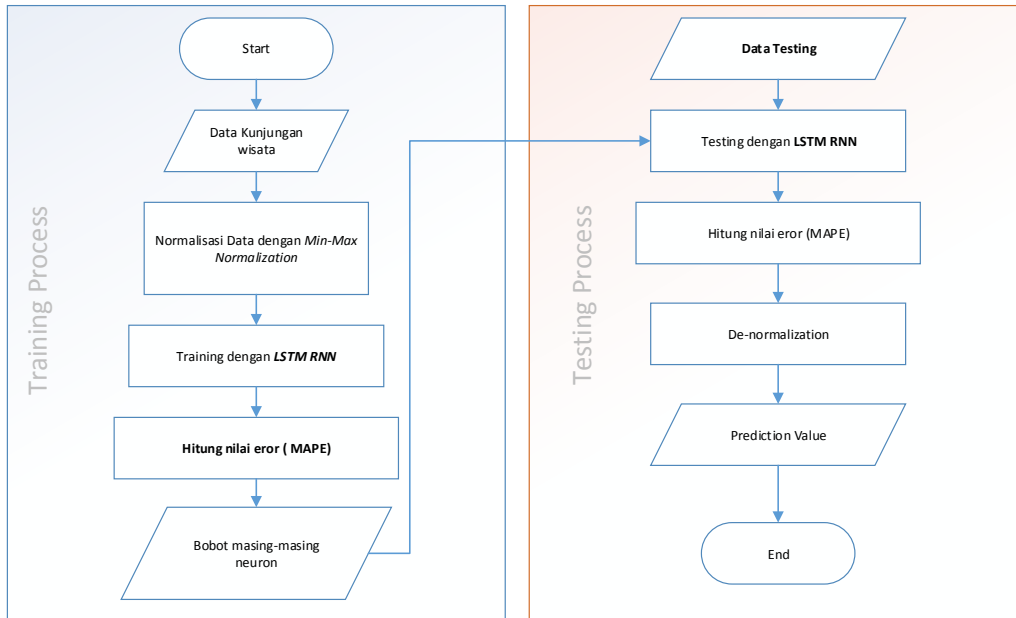
Penerimaan devisa dari masing-masing sektor utama dalam perekonomian di Indonesia, pariwisata menempati posisi ke empat setelah minyak & gas bumi, batu bara, minyak kelapa sawit [1]. Meskipun krisis global terjadi beberapa kali, jumlah perjalanan wisatawan internasional tetap menunjukkan pertumbuhan yang positif, dimana data dari UNWTO *World Tourism Barometer*, menunjukkan jumlah kunjungan wisatawan setiap tahunnya bertambah [2]. Bali merupakan salah satu obyek wisata favorit di Indonesia, dimana jumlah kunjungan wisatawan yang berkunjung ke Bali sekitar 4 juta lebih wisatawan 2015 [3]. Jumlah wisatawan yang berkunjung tersebar diberbagai daerah dan objek wisata yang terdapat di Bali. Meskipun kunjungan wisatawan ke Bali dapat dikatakan besar, namun kunjungan tersebut tidaklah merata, dimana hal ini terbukti dari jumlah kunjungan wisatawan ke obyek wisata yang ada di Bali memiliki perbedaan yang cukup signifikan di setiap kabupaten [3]. Selain jumlah kunjungan wisatawan tingkat *occupancy* hotel di beberapa kabupaten di Bali terdapat perbedaan yang cukup signifikan [4]. Permasalahan yang muncul adalah kesenjangan pendapatan asli daerah (PAD) dari sektor pariwisata di setiap kabupaten yang berbeda-beda [5]. PAD yang berbeda di setiap kabupaten berdampak kepada pembangunan fasilitas publik seperti halnya jalan, trotoar, penerangan jalan, taman terpadu serta yang lainnya. Kabupaten Badung dengan PAD terbesar di Bali [5], hampir setiap tahun melakukan perbaikan dan pembangunan fasilitas publik serta pemberian bantuan sosial ke masyarakat (Bansos) paling banyak di bandingkan kabupaten lainnya yang ada di Bali [6]. Dengan mengetahui jumlah kunjungan wisatawan maka pola kunjungan wisatawan ke obyek wisata dapat diketahui.

Teknik forecasting bertujuan untuk memprediksi pola data yang sebelumnya, sehingga dapat diketahui pola data selanjutnya. Pada penelitian ini menggunakan teknik recurrent neural network dalam memprediksi tingkat kunjungan wisatawan. Salah satu teknik recurrent neural network (RNN) yang digunakan dalam penelitian ini adalah Long Short Term Memory (LSTM). Model ini lebih baik dibandingkan dengan model RNN sederhana [7] [8] [9]. Penelitian yang bertujuan menganalisa bobot jaringan pada metode LSTM [10], untuk meningkatkan dan stabilitas kecepatan pembelajaran menggunakan nguyen dan widrow work untuk jaringan MLP, 2 lapisan jaringan LSTM menghasilkan peningkatan proses pembelajaran. Pendekatan dari penelitian ini adalah mendeteksi aktifitas suara, dimana terdapat noisy speech pada film hollywood, equal error rate sebesar 33,2% dan dari empat buah film dihasilkan err sebesar 9,6 % sebagai data test [11]. Modifikasi untuk model long short time memory RNN yang mengontrol keadaan dari squashing function untuk mendapatkan unit pada masing-masing layer, kecepatan dari model tersebut menghasilkan lebih besar 3 kali lipat pada proses training [12]. Pengenalan suara percakapan mandarin lewat telepon, dimana model LSTM di modifikasi dengan deep feed forward neural network, kemampuan model LSTM untuk model acoustic dapat ditingkatkan dengan menggunakan unit maxouts 2015 [13]. Pengenalan suara dengan menggunakan model, perbandingan CLDNN menghasilkan peningkatan 4-6% bila dibandingkan model lainnya [14]. Pada penelitian ini bertujuan untuk meramal tingkat kunjungan wisatawan dengan menggunakan algoritma LSTM, data yang digunakan adalah data kunjungan wisatawan ke salah satu obyek wisata yang ada di Bali.

2. METODE PENELITIAN

Proses peramalan pada penelitian ini, terdiri dari beberapa tahapan, dimana masing-masing proses terdiri dari perhitungan tersendiri dengan melibatkan beberapa algoritma. Lebih detail flowchart penelitian ditunjukkan pada Gambar 1. Adapun rancangan peramalan ditunjukkan pada Gambar 1, pada rancangan tersebut terdiri dari beberapa proses yang diantaranya.

1. Normalisasi data kunjungan wisatawan
2. Pelatihan dengan menggunakan algoritma LSTM
3. Pengujian data dengan menggunakan nilai kesalahan
4. Denormalisasi data kunjungan wisatawan



Gambar 1 Flowchart forecasting dengan LSTM

2.1 Normalisasi dan denormalisasi

Tujuan dari normalisasi data adalah untuk prose penskalaan nilai atribut dari data sehingga bisa berada pada range tertentu. Salah satu metode normalisasi yang dapat digunakan adalah Min-max normalization [8][15]. Proses normalisasi tersebut merupakan metode dengan melakukan transformasi linier terhadap data aslinya. Adapun persamaan yang digunakan untuk menghitung nilai normalisasi, seperti yang ditunjukkan pada Persamaan 1.

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \tag{1}$$

Keterangan :

- x' = Data hasil normalisasi
- x_i = Data ke i
- x_{min} = Data dengan nilai minimum
- x_{max} = Data dengan nilai maksimum

Proses denormalisasi data yang bertujuan untuk mengembalikan hasil keluaran jaringan agar berada pada *range* sebelumnya. Denormalisasi data dapat dilakukan dengan menggunakan persamaan 2.

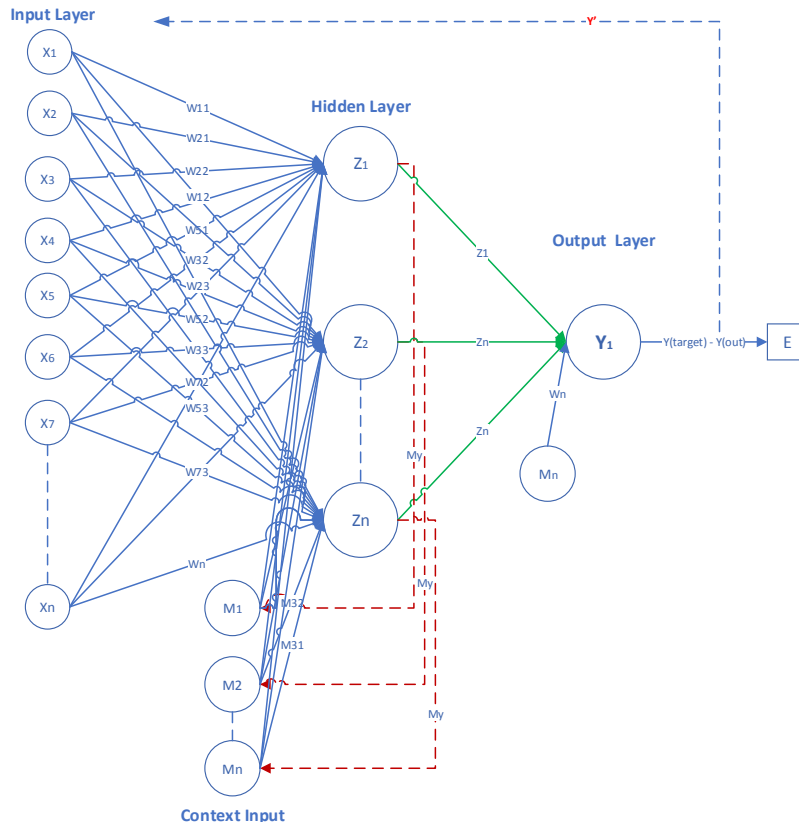
$$x_i = x' (x_{max} - x_{min}) + x_{min} \tag{2}$$

2.2. Recurrent Neural Network (RNN)

Reccurent Neural Network (RNN) adalah jaringan syaraf yang mempunyai koneksi Feedback. Ada dua macam model recurrent Network, yaitu Elman Network dan Hopfield Network. Elman Network adalah jaringan Backpropagation 2 lapis dengan penambahan koneksi Feedback dari output ke input. Feedback ini membuat Elman Network untuk mempelajari,

mengenali, dan membuat pola sementara seperti pola spasial. Hopfield Network digunakan untuk menyimpan satu atau lebih vektor target. Vektor ini dianggap sebagai ingatan yang akan dipanggil ketika terdapat vektor yang mirip dengan Network [16].

Arsitektur recurrent hampir sama dengan feedforward back propagation, namun ditambah dengan layer konteks untuk menampung hasil output dari hidden layer [17]. Feedback dapat menyebabkan proses iterasi akan jauh lebih cepat, sehingga membuat kecepatan update parameter dan konvergensinya menjadi lebih cepat [18]. Metode pelatihan untuk jaringan recurrent mirip dengan aturan pembelajaran Backpropagation, tapi ditambah dengan mengambil juga masukan dari lapisan context unit. Metode pelatihan akan melatih sinyal input menuju ke signal output untuk meminimalkan kesalahan dari output layer.



Gambar 2 Arsitektur *recurrent neural network*

Struktur recurrent neural Network terdiri dari :

1. Elman recurrent neural Network, pada jaringan ini output neuron dari hidden layer di Feedback kembali menjadi input untuk neuron hidden pada time step berikutnya.
2. Jordan recurrent neural Network, pada jaringan ini keluaran neuron output di Feedback sebagai input untuk neuron hidden pada time step berikutnya.
3. Fully recurrent neural Network, pada jaringan ini masing-masing konteks unit untuk hidden layer dan output layer mengalami Feedback pada dirinya sendiri.

Selain kedua arsitektur / model dari RNN, terdapat beberapa arsitektur lainnya.

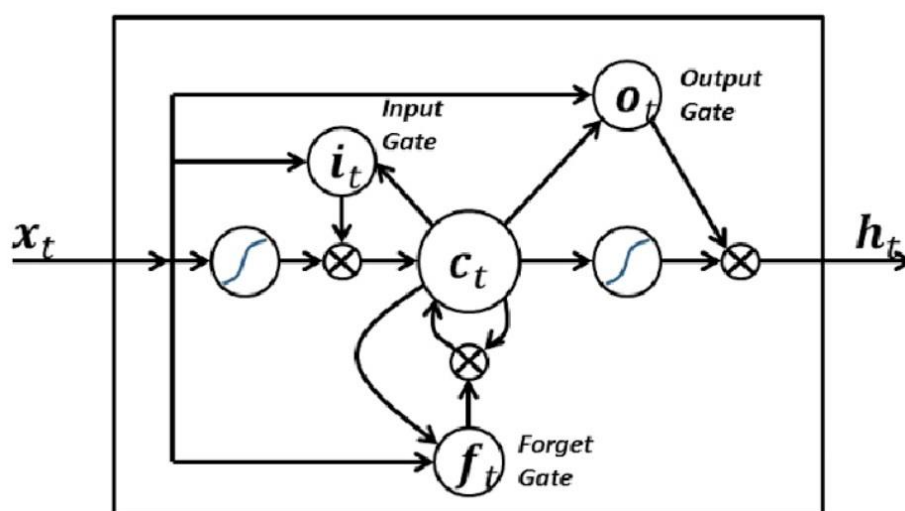
2.3 LSTM recurrent neural network

LSTM merupakan salah satu varian dari model recurrent neural network, yang memiliki isi cell lebih kompleks. Jaringan LSTM, yang dikembangkan [7] pada tahun 1997, adalah struktur jaringan saraf tiruan yang tidak seperti RNN yang tidak memiliki masalah vanishing gradient. Algoritma ini bekerja ketika ada penundaan yang lama, dan dapat menangani sinyal yang memiliki campuran komponen frekuensi rendah dan tinggi. LSTM RNN lebih bagus

dibandingkan metode lain dalam berbagai aplikasi seperti halnya belajar bahasa dan connected handwriting recognition.

LSTM merupakan jaringan saraf (RNN). Seperti halnya jaringan RNNs, lainnya, LSTM bersifat universal dengan kata lain LSTM memberikan unit jaringan cukup untuk dapat menghitung apakah komputer konvensional bisa menghitung, asalkan memiliki weight matrix yang tepat, yang dapat dilihat sebagai program. Tidak seperti RNNs tradisional, jaringan LSTM cocok untuk belajar dari pengalaman untuk mengklasifikasikan, proses dan memprediksi data time series ketika rentan waktunya sangat lama dari ukuran yang diketahui dengan kejadian yang penting. Ini adalah salah satu alasan utama mengapa LSTM menjadi alternatif dari RNNs dan Hidden Markov Model dan metode pembelajaran urutan lainnya dalam berbagai aplikasi. Misalnya, LSTM mencapai hasil terbaik dikenal di handwriting recognition unsegmented, dan pada tahun 2009 memenangkan kompetisi tulisan tangan ICDAR. Jaringan LSTM juga telah digunakan untuk automatic speech recognition, dan komponen utama dari jaringan yang pada tahun 2013 mencapai 17,7% tingkat phoneme error pada TIMIT classic TIMIT natural speech dataset.

Arsitektur LSTM merupakan perkembangan lebih lanjut dari arsitektur RNN, dimana pada RNN terdapat cell sederhana yang hanya berisi 1 layer neuron dengan fungsi aktivasi seperti tanh. Pada arsitektur LSTM terdapat isi cell menjadi lebih kompleks dibandingkan dengan RNN. Banyaknya isi cell pada LSTM menyebabkan model ini mampu mempelajari pola panjang dari data time series karena kondisi vanishing gradient dapat dicegah. dengan kata lain LSTM dan RNN hanya berbeda pada isi cellnya, namun secara teoritis prinsipnya sama.



Gambar 3 Arsitektur LSTM

Pada cell LST terdapat 2 hasil nilai output, yang diantaranya output pertama merupakan keluaran sebenarnya yang dilanjutkan kembali ke sell berikutnya dan menjadi output dari cell itu. Pada sistem LSTM terdapat tiga buah pintu / gates, diantaranya input, forget dan output gate. Pada input gate bertujuan untuk memasukan data baru, sedangkan mengapus informasi yang tidak penting terdapat pada forget gate dan mempengaruhi keluaran pada saat waktu bersamaan merupakan tugas dari output gate. Ilustrasinya ditunjukkan pada Gambar 3.

2. 4 Sliding windows


Formulir Data *time series* adalah *sequence* atau deret nilai harga dari aset nilai pada suatu periode waktu tertentu. Jenis data ini terdiri dari satu objek tetapi meliputi beberapa periode waktu misalnya harian, mingguan, bulanan, tahunan dan lain-lain. Penggunaan *data time series* bermanfaat untuk meramalkan kejadian di masa depan, karena pola yang terbentuk

di masa lalu kemungkinan terulang di masa datang. Pada peramalan data *time series* terdapat duah macam jenis analisa yang digunakan yaitu analisis kualitatif dan analisis kuantitatif. Analisis kualitatif adalah teknik peramalan berdasarkan pendapat suatu pihak, datanya tidak dapat direpresentasikan secara tegas menjadi suatu nilai. Analisis kuantitatif merupakan teknik peramalan yang berdasarkan data pada masa lalu (*data historis*), dapat dibuat dalam bentuk angka yang biasa disebut dengan data *time series* [19]. Data *time series* dapat dinotasikan sebagai sebuah vektor, seperti pada persamaan 3 :

$$x = \{x_t, t = 1, \dots, n\}, \quad (3)$$

Keterangan : x merupakan data observasi yang terurut berdasarkan waktu
 t adalah indeks waktu
 n jumlah observasi / pengamatan

Salah satu pendekatan dari model standar JST dalam melakukan prediksi data *time series* adalah dengan *sliding windows*.



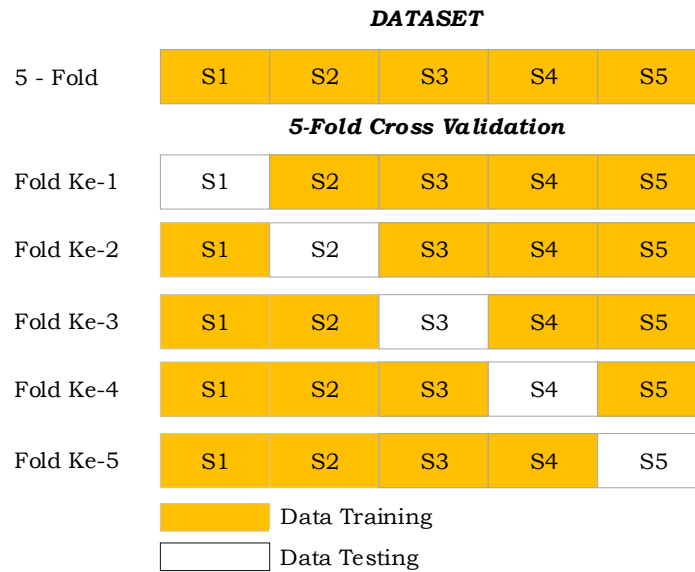
Gambar 4 Ilustrasi *sliding windows*

Teknik ini mendorong fungsi f pada JST dan menggunakan fungsi *feedforward* seperti pada arsitektur MLP, RBF atau korelasi *cascade*, dengan menggunakan satu set N tuple sebagai masukan dan satu *output* sebagai nilai target jaringan. Pada Gambar 4 Menunjukkan teknik standar prediksi data *time series* menggunakan *sliding windows*, pada kasus tersebut menggunakan tiga tahapan waktu. Pada Gambar 4 rentan waktu yang digunakan adalah tiga hari, di mana tiga hari data sebelumnya digunakan untuk memprediksi hasil data kedepannya.

2. 5 *K-fold cross validation*

Cross validation adalah sebuah model statistik yang digunakan untuk mengevaluasi algoritma pembelajaran, dengan cara memisahkan data menjadi dua buah data set. Data set pertama digunakan untuk training data, sedangkan data set kedua digunakan untuk data validasi . Cross validation juga berfungsi untuk memvalidasi keakuratan sebuah model yang dibangun berdasarkan dataset tertentu. Estimasi tingkat kesalahan pada bidang pengenalan pola seperti prediksi dan klasifikasi dapat menggunakan k-fold cross validation, yang merupakan varian dari metode cross validation. Penggunaan model tersebut bertujuan untuk menghilangkan bias pada data, dengan membagi data menjadi k subset / fold yaitu S_1, S_2, \dots, S_k dengan ukuran masing-masing subset kira-kira sama . Jumlah fold standar untuk memprediksi tingkat error dari data adalah dengan menggunakan 10-fold cross validation .

Proses training dan validasi dilakukan sebanyak k kali secara berulang-ulang. Pada iterasi ke-i, partai S_k sebagai data validasi dan partisipasi sisanya digunakan secara bersamaan dan berurutan sebagai data training. untuk interasi kedua, subset S_1, S_2, \dots, S_k akan diuji pada S_2 , dan selanjutnya hingga S_k [15].



Gambar 5 Ilustrasi penyajian data dengan 5-fold

Gambar 5 menjelaskan bahwa nilai fold yang digunakan adalah 5-fold cross validation. Pada gambar tersebut kotak yang berwarna putih melambangkan data uji, sedangkan kotak berwarna orange merupakan data training atau data pelatihan. Data set pada penelitian terlebih dahulu dibagi menjadi 5 bagian selanjutnya salah satu bagian data digunakan untuk pengujian sedangkan sisanya untuk pelatihan, demikian seterusnya sampai dengan lima kali pembagian.

3. HASIL DAN PEMBAHASAN

Hasil yang ditunjukkan dari peramalan kunjungan wisatawan ke salah satu obyek wisata yang ada dibali menggunakan metode LSTM, dijabarkan kedalam beberapa poin berikut.

1. Penentuan parameter untuk pelatihan

Dalam menentukan parameter untuk pelatihan, dilakukan beberapa pengujian untuk masing-masing parameter. Seperti learning rate, jumlah unit neuron, momentum dan lainnya. Pengujian dilakukan untuk nilai-nilai yang memiliki hasil terbaik saat pelatihan dan pengujian dilakukan. Nilai masing-masing parameter dijabarkan pada Tabel 1.

Tabel 1 Parameter pelatihan LSTM

Parameter	Nilai	Keterangan
<i>Learning rate</i>	0,01	Kecepatan pembelajaran sistem
<i>Windows size</i>	3	Jumlah windows size
Jumlah Unit Hidden	16	Banyaknya unit layer
Maksimum <i>epoch</i>	10^5	Jumlah iterasi / maksimum berhenti
Bobot	<i>Random (0,1)</i>	

Nilai yang diperoleh masing-masing parameter didapat dari hasil percobaan, dimana hasil pengujian terbaik selanjutnya digunakan untuk pelatihan. Adapun nilai *learning rate* atau laju pembelajaran sebesar 0,01, jumlah unit neuron sebesar 16, windows size sebesar 3 dan stopping kriteria untuk pengujian sebesar 10^5 .

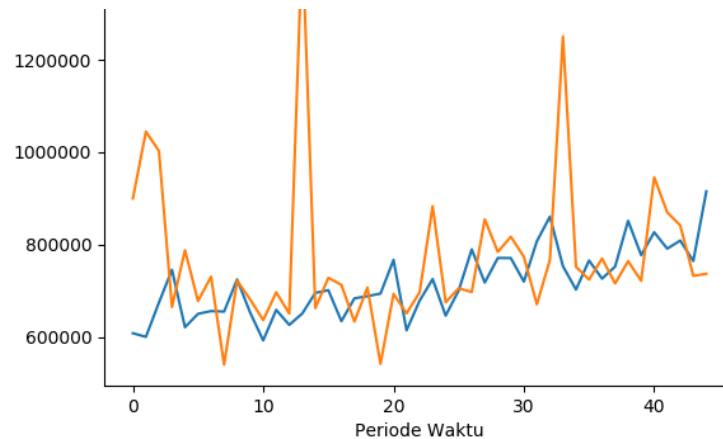
2. Proses pelatihan dan pengujian dengan menggunakan algoritma LSTM.

Pada proses pelatihan tahap pertama menggunakan pembagian data sebesar 80% untuk pelatihan dan 20% untuk pengujian dengan model LSTM. Hasil pengelompokan data dijabarkan

pada Tabel 2. Sedangkan untuk grafik pengujian dijabarkan pada Gambar 6, dimana metode LSTM mampu mengenali pola data dari kunjungan wisatawan.

Tabel 2 Hasil pelatihan dan pengujian

Algoritma Pengujian	Pelatihan
MAPE	15,982



Gambar 6 Grafik hasil pelatihan dengan LSTM

3. Perbandingan dengan menggunakan teknik k-fold.

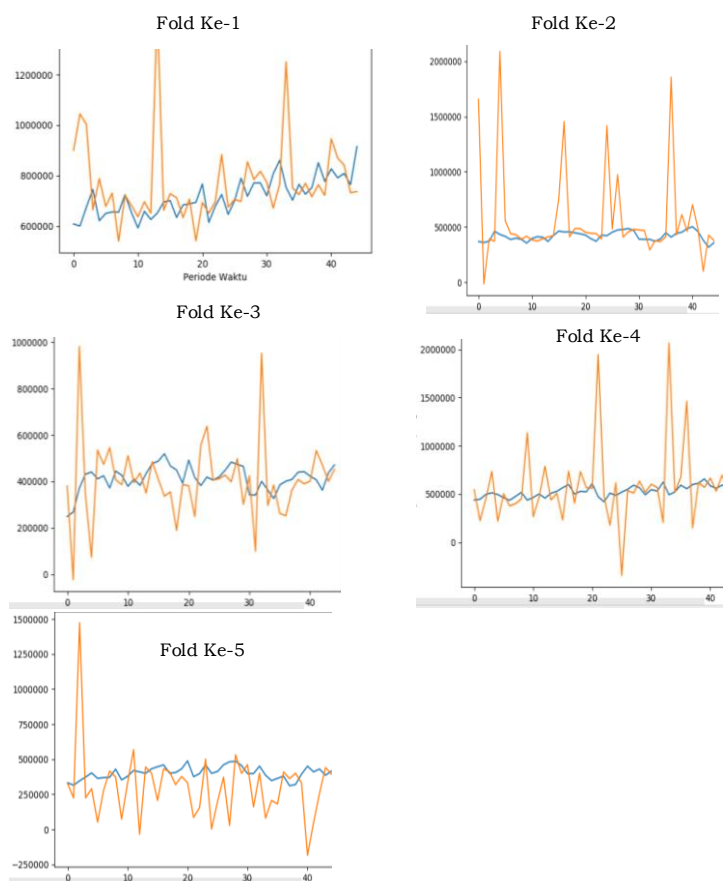
Jumlah data yang digunakan sebanyak 240 record data, dan n yang digunakan sebesar 5 sehingga 5-fold setiap subsetnya menjadi 48 record data. Setiap subset data akan dilakukan proses training dan testing dan selanjutnya hasil tersebut di rata-rata. Seperti yang ditunjukkan pada Tabel 3, sedangkan untuk parameter yang digunakan tetap seperti ditunjukkan pada Tabel 1.

Tabel 3 pelatihan dengan 5-fold

5-fold	Waktu	Pelatihan
Fold ke 1	174	15,982
Fold ke 2	195	51,582
Fold ke 3	181	31,34
Fold ke 4	175	44,93
Fold ke 5	185	44,09
Rata-rata	182	37,58

Dari hasil penelitian dengan menggunakan teknik k-fold di peroleh nilai rata-rata sebesar 37,58 dan waktu yang dibutuhkan sebesar 182, dimana hasil dari ke lima pelatihan subset data menghasilkan nilai yang jauh berbeda dengan pelatihan tanpa k-fold. Pada Gambar 7 di tunjukan grafik dari masing-masing hasil k-fold.

Dari masing-masing subset data dihasilkan nilai pelatihan yang berbeda satu dengan yang lainnya, hal ini disebabkan dari perbedaan data yang digunakan saat pelatihan. Data set pada penelitian ini memiliki nilai yang cukup signifikan untuk beberapa periode sehingga pengenalan data menggunakan metode LSTM menghasilkan perbedaan yang signifikan, namun waktu yang dibutuhkan rata-rata memiliki perbedaan 10 detik lebih. Waktu terlama terjadi pada fold ke 2 dimana waktu yang dibutuhkan sebesar 195 dengan hasil pelatihan sebesar 51,582 (MAPE), hal ini jauh berbeda dari pelatihan pada data set lainnya.



Gambar 7 Grafik hasil pelatihan k-fold

4. KESIMPULAN

Adapun kesimpulan yang dihasilkan dari penelitian dijabarkan dengan beberapa point sebagai berikut, Algoritma LSTM mampu mengenali pola data kunjungan wisatawan, nilai eror yang diukur menggunakan MAPE, menghasilkan nilai sebesar 15,92, Nilai yang dihasilkan dengan menggunakan 5-fold menghasilkan nilai rata-rata sebesar 37,58 dan waktu yang dibutuhkan sebesar 182 detik

5. SARAN

Saran-saran untuk penelitian ini adalah dengan menggunakan data yang lebih banyak sehingga proses pelatihan menghasilkan pengenalan variasi data yang lebih banyak. Perbandingan dengan metode RNN lainnya, sehingga dapat diketahui algoritma terbaik dari kasus pada penelitian ini.

DAFTAR PUSTAKA

- [1] Kemenpar, "Terdapat 3 area kelemahan industri pariwisata indonesia yang harus segera diperbaiki sehingga target 2019 dapat terwujud," 2015.
- [2] UNWTO, "International tourist arrivals up 4% in the first four months of 2015," 2015. [Online]. Available: <http://media.unwto.org/press-release/2015-07-08/internationaltourist-%0Aarrivals-4-first-four-months-2015>. [Accessed: 05-Jan-2017].

- [3] Dispardabali, "Pertumbuhan Kunjungan Wisatawan Nusantara Tahun 2015," 2015. [Online]. Available: <http://www.disparda.baliprov.go.id/id/Statistik3>.
- [4] BPSbali, "Anggaran Penerimaan Pendapatan Asli Daerah (PAD) Kabupaten/Kota di Provinsi Bali dari Tahun 2011-2015 (dalam ribuan rupiah)," 2016.
- [5] B. Dispenda, "PERKEMBANGAN PENDAPATAN ASLI DAERAH (PAD)," 2012. [Online]. Available: <http://www.dispenda.baliprov.go.id/id/PERKEMBANGAN-PENDAPATAN-ASLI-DAERAH--PAD-->.
- [6] W. Purnomowati and Ismini, "Konsep Smart City Dan Pengembangan Pariwisata," *J. JIBEKA*, vol. 8, no. 1, pp. 65–71, 2014.
- [7] S. Hochreiter and J. Urgen Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [8] P. Sugiartawan, R. Pulungan, and A. K. Sari, "Prediction by a Hybrid of Wavelet Transform and Long-Short-Term-Memory Neural Network," *Int. J. Adv. Comput. Sci. Appl.*, vol. 8, no. 2, pp. 326–332, 2017.
- [9] P. Sugiartawan and I. G. S. Arta, "Peramalan Tingkat Kunjungan Wisatawan dengan Metode Average Based Fuzzy Time Series dan Markov Chain Model di Sripahala Resort & Hotel," 2015.
- [10] A. E. Coca, D. C. Correa, and L. Zhao, "Computer-aided music composition with LSTM neural network and chaotic inspiration," *Proc. Int. Jt. Conf. Neural Networks*, 2013.
- [11] F. Eyben, M. Wollmer, B. Schuller, and A. Graves, "From speech to letters-using a novel neural network architecture for grapheme based ASR," *Autom. Speech Recognit. Understanding, 2009. ASRU 2009. IEEE Work.*, pp. 376–380, 2010.
- [12] P. Doetsch, M. Kozielski, and H. Ney, "Fast and Robust Training of Recurrent Neural Networks for Offline Handwriting Recognition," *Proc. Int. Conf. Front. Handwrit. Recognition, ICFHR*, vol. 2014–Decem, pp. 279–284, 2014.
- [13] X. Li and X. Wu, "Constructing Long Short-Term Memory Based Deep Recurrent Neural Networks For Large Vocabulary Speech Recognition," *Icassp*, pp. 4520–4524, 2015.
- [14] G. Chen, C. Parada, and T. N. Sainath, "Query-by-example keyword spotting using long short-term memory networks," *2015 IEEE Int. Conf. Acoust. Speech Signal Process.*, pp. 5236–5240, 2015.
- [15] P. Sugiartawan, S. Hartati, and A. Musdholifah, "Prediction of Multivariat Time Series Data Using Fully Recurrent Neural Network."
- [16] M. . Hagan, H. Demuth, and M. Beale, *Neural Network Design*. USA: PWS Publishing Co., 1996.
- [17] J. B. Habarulema, "A contribution to TEC modelling over Southern Africa using GPS data," no. August, 2010.
- [18] Y. Noorviani, "Penerapan Elman Recurrent Neural Network untuk Diagnosis Gangguan Autis Pada Anak," Universitas Gadjah Mada, Yogyakarta, 2011.
- [19] Jumingan, *Studi Kelayakan Bisnis, Teori dan Proposal Kelayakan*. Jakarta: Bumi Aksara, 2009.