

Rancang Bangun Aplikasi Peramalan Jumlah Penumpang Menggunakan *Long Short-Term Memory* (LSTM)

Muhammad Davi^{1*}, Edi Winarko²

¹Program Studi Teknologi Rekayasa Komputer Jaringan, Politeknik Negeri Lhokseumawe

²Program Studi Ilmu Komputer, Universitas Gadjah Mada

¹Jln. Banda Aceh - Medan KM 280,3 Buketrata, Mesjid Punteut, Blang Mangat, Kota Lhokseumawe, 24301, Indonesia

²Gedung C, Lantai 4 Sekip Utara, Bulaksumur, Yogyakarta, 55281, Indonesia

E-mail: muhammad.davi@pnl.ac.id¹, ewinarko@ugm.ac.id²

Abstrak

Info Naskah:

Naskah masuk: 28 Mei 2023

Direvisi: 5 Juli 2023

Diterima: 8 Juli 2023

Pelayanan publik seperti transportasi publik erat kaitannya dengan kepuasan penggunaannya. Busway DKI Jakarta adalah salah satu transportasi publik yang pertama di Asia Tenggara dan Selatan. Demi menjaga kepuasan penumpang, pihak manajemen Busway terus meningkatkan pelayanan seperti menambah armada dan membuka jalur baru. Membuka jalur baru atau menambah armada tentu harus disesuaikan juga dengan meningkatnya jumlah penumpang. Maka untuk mengetahui jumlah penumpang di masa depan, perlu dilakukan peramalan jumlah penumpang melalui data histori yang telah ada. Data histori yang digunakan adalah data runtun waktu (*time series*) dari Januari 2015 sampai Januari 2016. Metode yang digunakan dalam peramalan adalah *Long Short-Term Memory* (LSTM) salah satu metode *machine learning*. Metode tersebut diukur akurasi dengan menggunakan *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Sebagai pembandingan akurasi LSTM dalam melakukan peramalan, digunakan juga metode *Exponential Smoothing* sebagai *baseline* hasil peramalan. Berdasarkan hasil peramalan metode LSTM hanya pada koridor 3 LSTM tidak dapat memberikan nilai RMSE dan MAPE dibawah nilai *baseline*. Sedangkan koridor 5 LSTM dapat memberikan hasil lebih baik setelah dilakukan proses *data transformation* dengan menggunakan *exponential smoothing*. Namun secara keseluruhan metode LSTM memberikan akurasi paling baik berdasarkan nilai rata-rata RMSE dan MAPE yang paling kecil yaitu RMSE sebesar 2640,53 dan MAPE sebesar 9,14 %.

Abstract

Keywords:

long short-term memory;
exponential smoothing;
machine learning;
forecasting;
time series;

Public services such as public transportation are closely related to user satisfaction. Busway DKI Jakarta is one of the first public transportation services in Southeast and South Asia. In order to maintain passenger satisfaction, the management of Busway continues to improve services such as adding buses and opening a new line. Opening a new lane or adding buses must necessarily be adjusted also with the increasing number of passengers. So to know the number of passengers in the future, it is necessary to forecast the number of passengers through existing historical data. The historical data used is time series data from January 2015 to January 2016. The method used in forecasting is Long Short-Term Memory (LSTM), one of the machine learning methods. The method is measured in accuracy using Root Mean Squared Error (RMSE) and Mean Absolute Percentage Error (MAPE). As a comparison of LSTM accuracy in forecasting, we also use the Exponential Smoothing method. Based on the results of forecasting, the most and least dominant method of producing RMSE and MAPE is the LSTM method. Only in corridor 3 LSTM can not provide RMSE and MAPE values below baseline values. While corridor 5 LSTM can give better results after the data transformation process by using exponential smoothing. However, overall the LSTM method provides the best accuracy based on the lowest average RMSE and MAPE values, namely RMSE of 2640.53 and MAPE of 9.14%.

*Penulis korespondensi:

Muhammad Davi

E-mail: muhammad.davi@pnl.ac.id

1. Pendahuluan

Busway adalah salah satu moda transportasi dengan sistem *Bus Rapid Transit* (BRT). Pada awal mula Busway beroperasi di DKI Jakarta, banyak tantangan yang dihadapi. Salah satunya adalah tingkat kepuasan penumpang (hubungan kinerja dan kualitas pelayanan). Terdapat tujuh indikator yang digunakan, enam indikator menunjukkan bahwa penumpang cenderung kurang puas dan satu indikator menunjukkan cenderung tidak puas. Keenam indikator tersebut adalah pelayanan di loket, pelayanan di halte, pelayanan di dalam bus, kapasitas penumpang, lokasi halte dan rute bus. Sedangkan indikator ketidakpuasan terletak pada jumlah armada yang ada saat itu [1]. Hal ini menunjukkan bahwa ketidakpuasan penumpang diakibatkan oleh meningkatnya pengguna Busway tetapi tidak diiringi dengan peningkatan jumlah armada yang tersedia.

Pada semester I tahun 2016, pengguna Busway mengalami kenaikan setiap bulannya. Jumlah tertinggi terjadi pada bulan Juni yang mencapai 10.206.000 penumpang. Berdasarkan data yang dirilis, jumlah penumpang setiap bulannya pada semester I 2016 adalah Januari (8,15 juta); Februari (8,51 juta); Maret (9,01 juta); April (9,10 juta); Mei (10 juta); dan Juni (10,206 juta). Pada bulan Agustus 2016 Busway mencatat rekor baru dengan jumlah penumpang tertinggi mencapai 11.583.458 penumpang dengan rata-rata 373.659 per hari. Ada beberapa faktor penyebab naiknya jumlah penumpang setiap bulannya. Faktor-faktor tersebut antara lain, penambahan rute baru, kesiapan dan ketersediaan bus, dan sterilisasi Busway yang semakin membaik [2]. Terbukti bahwa dengan penambahan rute baru dan ketersediaan bus (penambahan armada) terjadi peningkatan pengguna Busway rata-rata 4.65% setiap bulannya. Artinya, tingkat kepuasan penumpang Busway meningkat dengan meningkatnya jumlah pengguna Busway.

Setelah pandemi Covid-19 berangsur-angsur pulih, Busway di DKI Jakarta (Transjakarta) kembali beroperasi secara normal mulai tanggal 22 Oktober 2021. Meskipun telah beroperasi secara normal, kritik dan opini masyarakat terkait pelayanan terus disampaikan melalui media sosial. Penelitian [3] melakukan analisis sentimen terhadap pelayanan Busway DKI Jakarta melalui media sosial Instagram. Berdasarkan penelitian tersebut, dari 700 data komentar terdapat 532 komentar yang memiliki label sentimen negatif. Artinya 74,71% komentar tersebut mengandung kritik atau opini negatif terkait pelayanan Busway di DKI Jakarta.

Demi menjaga kualitas pelayanan Busway di DKI Jakarta, tentu pihak manajemen dan pembuat kebijakan perlu merencanakan langkah-langkah yang tepat dalam mengambil keputusan di masa depan. Salah satu bidang ilmu yang dapat membantu dalam pengambilan keputusan di masa depan adalah peramalan (*forecasting*). Hal yang terpenting dalam peramalan adalah peramalan runtun waktu atau *Time Series Forecasting* (TSF) yang melakukan observasi pada data-data masa lalu yang telah dikumpulkan dan dianalisa untuk mengembangkan sebuah model dasar yang saling berhubungan [4].

Time series analysis dan *forecasting* adalah bidang penelitian yang aktif. Artinya, keakuratan dalam *time series*

forecasting menjadi pokok dari proses pengambilan keputusan. Beberapa penelitian tentang *time series forecasting* memilih ARIMA (*Autoregressive Integrated Moving Average*) sebagai metode *forecasting* yang dikombinasikan atau dibandingkan keakuratannya dengan metode-metode lain seperti yang dilakukan oleh [4], [5], [6], dan [7]. Selain menggunakan ARIMA, *exponential smoothing* juga sering digunakan untuk peramalan seperti yang dilakukan oleh [8], [9] dan [10]. Namun, penelitian tentang peramalan atau prediksi masih menjadi bidang penelitian aktif karena belum ada metode yang dapat diterapkan secara universal pada semua kondisi peramalan dengan tingkat akurasi terbaik. Sehingga sebuah metode perlu dicoba pada kasus atau *dataset* yang berbeda untuk mengetahui kecocokan metode tersebut. Beberapa metode yang mulai aktif digunakan pada *time series forecasting* adalah metode-metode *artificial intelligence* atau *machine learning* seperti penelitian [11], [12], [13], [14], [15], dan [7].

Salah satu metode *Neural Network* yang mulai aktif digunakan pada *time series forecasting* adalah *Long Short-Term Memory* (LSTM). Berbeda dengan arsitektur RNN konvensional, LSTM dikembangkan sebagai solusi dari masalah *vanishing/exploding gradients* yang biasa ditemui pada RNN konvensional. Gradien yang semakin mengecil sampai layer terakhir sehingga nilai bobot tidak berubah dan menyebabkan proses *training* tidak pernah konvergen untuk memperoleh hasil yang lebih baik disebut *vanishing gradients*. Sebaliknya gradien yang semakin membesar sehingga nilai bobot pada beberapa layer juga membesar sehingga algoritma optimasi menjadi divergen disebut *exploding gradients* [16].

Pada awalnya LSTM digunakan untuk data berupa text seperti analisis sentimen yang dilakukan oleh penelitian [3] dan [17]. Sering meningkatnya data yang tersedia, metode *artificial intelligence* dan *machine learning* juga mulai digunakan untuk peramalan. Penelitian [5] melakukan peramalan pada jumlah penumpang dan barang di Bandara Udara Internasional Juanda dan Pelabuhan Tanjung Perak menggunakan Model ARIMAX dan *Deep Learning Neural Network* (DLNN). Model DLNN yang digunakan adalah *Feed Forward Neural Network* (FFNN) dengan 2 *hidden layer*. Hasil dari penelitian tersebut adalah model DLNN lebih dominan memberikan akurasi lebih baik dibandingkan ARIMAX atau *hybrid* ARIMAX dengan DLNN. Selanjutnya penelitian [12] yang menggunakan *Neural Network* dan Algoritma Genetika untuk melakukan prediksi nilai tukar rupiah terhadap dolar. Hasil dari penelitian tersebut adalah model kombinasi NN dan Algoritma dapat meningkatkan akurasi dengan berkurangnya nilai RMSE sebesar 0,002.

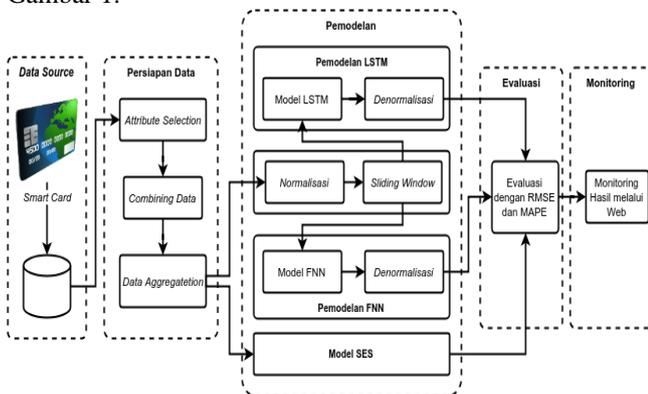
Peramalan produksi pertanian yang dilakukan pada penelitian [14] menggunakan LSTM memberikan hasil yang sangat memuaskan tentang kinerja LSTM dalam melakukan peramalan. Berdasarkan penelitian tersebut, akurasi hasil peramalan yang dihasilkan lebih baik dari akurasi *benchmark* dengan nilai RMSE yang lebih kecil. Selanjutnya penelitian [18] yang melakukan peramalan menggunakan LSTM pada data kasus Covid-19 di Provinsi Jawa Tengah. Terdapat beberapa model LSTM yang digunakan namun

LSTM untuk regresi menggunakan metode window yang paling baik akurasi. Terakhir penelitian yang dilakukan [7] dengan menggunakan LSTM dan ARIMA untuk melakukan peramalan pada *dataset Mulgia Gulf Real Estate* yang terdapat pada *MarketWatch*. Berdasarkan hasil penelitian tersebut model ARIMA memberikan hasil lebih baik dibandingkan dengan model LSTM. Hal ini dapat disebabkan oleh model yang dihasilkan pada LSTM belum sesuai dengan data yang diuji atau perlu dilakukan proses *data transformation* sebelum dilakukan peramalan menggunakan LSTM.

Berdasarkan beberapa penelitian diatas, tujuan utama penelitian ini adalah untuk menguji jumlah penumpang Busway DKI Jakarta dengan menggunakan metode LSTM dengan koneksi *peephole*. Arsitektur LSTM *peephole* dapat meningkatkan kemampuan LSTM dalam melakukan pembelajaran [16]. Selain itu, untuk meningkatkan akurasi LSTM dipilih juga metode *exponential smoothing*. *Exponential smoothing* dapat meningkatkan akurasi *neural network* dalam melakukan peramalan. Penggabungan kedua metode tersebut diharapkan dapat memberikan hasil peramalan yang lebih baik dibandingkan jika kedua metode tersebut berjalan masing-masing.

2. Metode

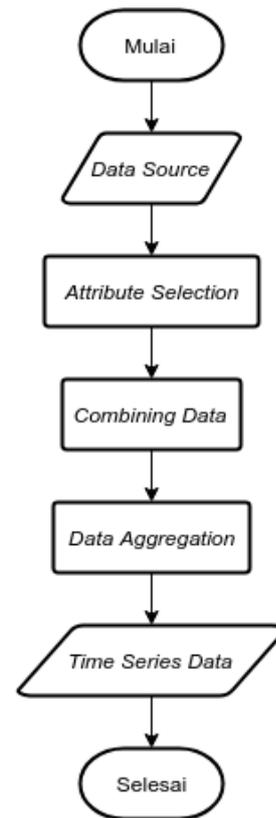
Data yang dikumpulkan dari *smart card* perlu diproses terlebih dahulu (*data preprocessing*) sebelum diproses oleh model. Terdapat 3 model yang digunakan untuk melakukan peramalan. Hasil peramalan tersebut kemudian dievaluasi dengan menggunakan RMSE dan MAPE. Sebagai laporan akhir, hasil tersebut ditampilkan ke halaman web. Tahap-tahap yang dilakukan dalam penelitian ini disajikan pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1 Persiapan Data

Pada tahap persiapan data terdiri dari 3 proses utama, yaitu *attribute selection*, *integrate data* dan *data aggregation*. Ketiga proses tersebut termasuk dalam *data preprocessing*. Artinya data source yang disimpan didalam basis data MongoDB tidak dapat langsung diproses dengan model-model *data mining*. Perlu dilakukan *data preprocessing* untuk mengubah *data source* menjadi *dataset* yang dapat diproses pada tahap pemodelan. Tahap-tahap proses persiapan data disajikan pada Gambar 2.



Gambar 2. Proses Persiapan Data

2.2 Analisis Model

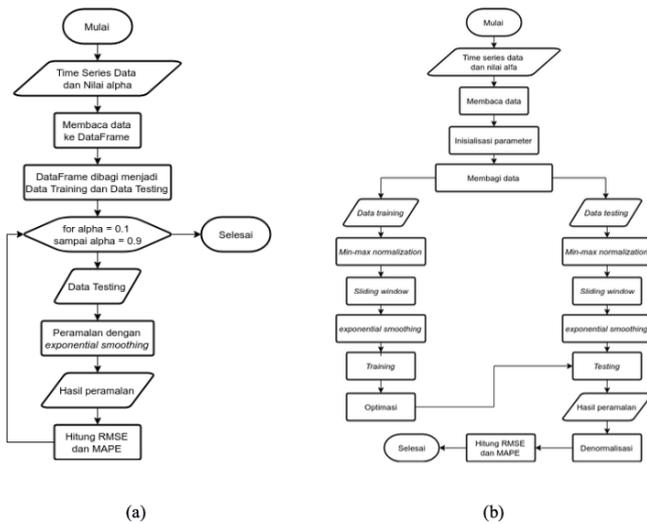
Setelah proses persiapan data diharapkan data telah sesuai untuk diproses pada proses pemodelan. Terdapat 3 macam model yang dibangun untuk melakukan peramalan. Pertama pemodelan dengan menggunakan *exponential smoothing*. Hasil evaluasi peramalan dengan *exponential smoothing* dijadikan sebagai *baseline* untuk mengukur peramalan dengan LSTM. Kedua peramalan dengan LSTM dan yang ketiga peramalan gabungan LSTM dengan *exponential smoothing*.

a) Pembangunan Model Exponential Smoothing

Parameter yang harus ditentukan pada model *exponential smoothing* adalah nilai α . Nilai α yang digunakan adalah 0,1, 0,3, 0,5, 0,7 dan 0,9. Data *time series* yang telah dihasilkan pada tahap persiapan data dibaca ke dalam *DataFrame* yang kemudian dibagi menjadi *data training* dan *data testing* dengan proporsi 80% untuk *data training* dan 20% *data testing*. Berdasarkan nilai α yang telah ditentukan sebanyak 5 nilai maka dilakukan perulangan sebanyak 5 kali untuk masing-masing *data testing* dari setiap koridor. Peramalan dilakukan hanya pada *data testing* karena pada model LSTM dan gabungan LSTM dan *exponential smoothing* model dievaluasi pada saat melakukan *training* dengan *data training*. Dengan demikian, diharapkan perbandingan ketiga model yang dirancang memiliki data yang sama untuk dievaluasi. Langkah-langkah yang dilakukan pada model *exponential smoothing* dapat dilihat pada Gambar 3 (a).

b) Pembangunan Model Long Short-Term Memory

Pada tahap perancangan model LSTM sebelum dilakukan proses *training* dan *testing*, perlu dilakukan inialisasi parameter terlebih dahulu seperti jumlah *neuron*, menentukan variabel *input* dan *output*, dan deklarasi arsitektur LSTM. Selain itu, terdapat 2 proses tambahan pada saat *testing* dan *training*, yaitu proses normalisasi dan *sliding window*. Adapun langkah-langkah yang dilakukan pada tahap membangun model LSTM dapat dilihat pada Gambar 3 (b).



Gambar 3. Model yang digunakan

2.3 Evaluasi Model dan Pengujian

Model yang telah dibangun memiliki beberapa parameter. Parameter-parameter tersebut perlu diuji untuk meningkatkan akurasi model yang dirancang. Melalui pengujian diharapkan parameter-parameter yang dihasilkan adalah parameter yang optimal yang dapat memberikan model yang terbaik. Beberapa parameter yang diuji antara lain:

1. Pengujian nilai α untuk menentukan nilai α yang paling optimal dari semua nilai α yang diuji, yaitu 0,1, 0,3, 0,5, 0,7 dan 0,9.
2. Pengujian *learning rate* dilakukan untuk mengetahui nilai *learning rate* yang tepat agar proses training dapat berjalan optimal. Pengujian *learning rate* juga dilakukan untuk menghindari *overfitting*, dimana model memberikan hasil yang baik pada saat *training* namun pada saat *testing* model memberikan hasil yang buruk. Nilai *learning rate* yang diuji adalah 0,3, 0,1, 0,01, 0,001, dan 0,0001.
3. Ukuran *sliding window* yang digunakan diperkirakan dapat mempengaruhi hasil peramalan. Sehingga perlu diuji beberapa ukuran *sliding window* untuk mendapatkan ukuran *sliding window* yang optimal. Adapun ukuran *sliding window* yang diuji adalah 1, 3, 5, 7, dan 9.
4. Jumlah *neuron* pada *hidden layer* juga diuji untuk mendapatkan jumlah *neuron* yang optimal. Jumlah *neuron* yang diuji adalah 2, 4, 8, 16 dan 32.

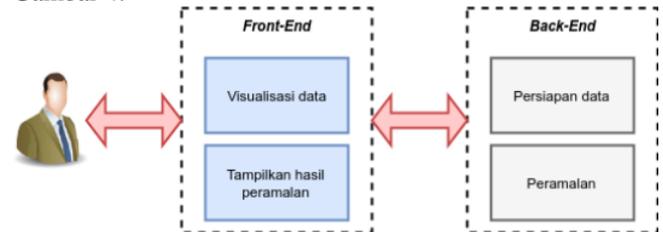
Selain pengujian *hyperparameter*, model yang telah dibangun kemudian dievaluasi kembali melalui nilai *error* dengan menghitung nilai RMSE dan MAPE. Beberapa percobaan sesuai nilai parameter yang telah ditentukan sebelumnya dilakukan untuk menentukan model yang paling baik dengan mencari nilai RMSE dan MAPE paling kecil. Model yang menghasilkan nilai RMSE dan MAPE paling kecil dipilih sebagai model yang digunakan untuk mencari hasil peramalan.

2.4 Analisis dan Perancangan Sistem

Setelah data tersedia dan model dibentuk, tahap selanjutnya adalah membangun sistem. Sistem yang dibangun berdasarkan data dan model yang terbaik dari setiap koridor. Berdasarkan uraian di atas, sistem yang dibangun memiliki beberapa spesifikasi fungsional. Spesifikasi fungsional dari sistem yang dibangun terdiri dari:

- 1) Sistem yang dibangun berbasis *command line* sebagai *back-end* dan berbasis web sebagai *front-end*.
- 2) Pada sisi *back-end* sistem dapat melakukan proses persiapan data dan peramalan dengan tiga model yang telah dirancang sebelumnya.
- 3) Pada sisi *front-end* sistem dapat menampilkan data dalam bentuk grafik dan menampilkan hasil peramalan.

Spesifikasi fungsional secara umum dapat dilihat pada Gambar 4.



Gambar 4. Rancangan sistem yang dibangun

a) Rancangan Sistem Bagian Back-end

Sistem *back-end* berfungsi untuk menangani proses-proses logika dan proses ke basis data. Berdasarkan Gambar 4, sistem *back-end* terdiri dari persiapan data dan peramalan. Sehingga jika dibangun ke dalam sebuah sistem, maka sistem tersebut memiliki 2 modul yang merepresentasikan proses-proses di dalam sistem *back-end*. Apabila modul-modul di dalam sistem *back-end* dijabarkan lebih dalam maka masing-masing modul memiliki fungsi sebagai berikut:

- 1) Persiapan data
 Persiapan data memiliki fungsi koneksi ke basis data MongoDB. Selain itu pada persiapan data juga memiliki fungsi-fungsi untuk melakukan proses *attribute selection*, *integrate data* dan *data aggregation* untuk menghasilkan data *time series* yang disimpan dalam format csv.
- 2) Peramalan
 Pada modul peramalan sistem memiliki fungsi membaca data dari file csv, membagi data, transformasi data dengan *min-max normalization* dan *exponential smoothing*, mengubah data *training* dan data *testing* dengan *sliding*

window, peramalan dengan *exponential smoothing*, peramalan dengan LSTM, peramalan dengan LSTM dan *exponential smoothing* dan menghitung nilai RMSE dan MAPE.

b) Rancangan Sistem Bagian *Front-end*

Pada sisi *front-end* dibangun antarmuka pengguna (*user interface*). Antarmuka berfungsi sebagai alat komunikasi antara pengguna dengan sistem. Pada dasarnya sistem yang dibangun memiliki 2 antarmuka utama, yaitu antarmuka untuk menampilkan data (visualisasi data) dan antarmuka peramalan. Antarmuka visualisasi data berfungsi untuk menampilkan semua data dari masing-masing koridor. Sedangkan antarmuka peramalan berfungsi untuk menampilkan hasil peramalan dari setiap koridor.

1) Rancangan template antarmuka

Pada dasarnya setiap halaman terdiri dari tiga bagian utama, yaitu *header*, *content* dan *footer*. *Header* berisi link ke setiap halaman, *content* menampilkan isi setiap halaman secara dinamis, dan *footer* berisi informasi tentang pembuat dan tahun sistem tersebut dibuat.

2) Rancangan antarmuka visualisasi data

Antarmuka visualisasi data menampilkan data dari masing-masing koridor dalam bentuk grafik. Pengguna dapat melihat grafik data penumpang setiap koridor dengan memilih nama koridor di *dropdown button* dan menekan *Button*. Selanjutnya sistem menampilkan data penumpang dalam bentuk grafik dimana sumbu x berisi tanggal (*datetime*) dan sumbu y berisi jumlah penumpang.

3) Rancangan antarmuka peramalan

Antarmuka peramalan terdiri dari 3 antarmuka. Pertama, antarmuka untuk menampilkan proses dan hasil peramalan awal (*baseline*). Pada antarmuka ini peramalan dilakukan dengan metode *exponential smoothing* sebagai tolak ukur dari hasil peramalan selanjutnya. Kedua, antarmuka untuk menampilkan hasil peramalan yang dilakukan dengan menggunakan metode LSTM. Antarmuka yang ketiga adalah antarmuka yang menampilkan proses dan hasil peramalan dengan metode LSTM dan *exponential smoothing*. Pada dasarnya ketiga antarmuka peramalan sama dengan visualisasi data, yaitu sama-sama memiliki *dropdown button*, *button* dan grafik untuk menampilkan data dan hasil peramalan. Terdapat sedikit penambahan pada antarmuka peramalan, yaitu menampilkan nilai RMSE dan MAPE sebagai evaluasi dan akurasi model peramalan.

3. Hasil dan Pembahasan

Proses adalah pengujian akurasi peramalan jumlah penumpang menggunakan *exponential smoothing*, LSTM dan gabungan *exponential smoothing* dan LSTM

berdasarkan *hyperparameter* pada Tabel 1 pada setiap koridor. Hasil pengujian akurasi peramalan dibandingkan berdasarkan nilai RMSE dan MAPE dari setiap koridor. Peramalan dengan nilai RMSE dan MAPE paling kecil adalah model peramalan yang paling baik.

3.1 Pengujian *Hyperparameter*

Berdasarkan beberapa pengujian diperoleh *hyperparameter* dengan beberapa nilai optimal. *Hyperparameter* dengan nilai optimal tersebut dikombinasikan untuk menguji akurasi model peramalan. Nilai α digunakan pada peramalan dengan *exponential smoothing* dan peramalan gabungan *exponential smoothing* dengan LSTM. Sedangkan ukuran *sliding window* dan jumlah *neuron* digunakan pada peramalan LSTM dan peramalan gabungan *exponential smoothing* dengan LSTM. Nilai *learning rate* pada peramalan LSTM dan gabungan *exponential smoothing* dengan LSTM ditetapkan 0,01 untuk semua koridor. *Hyperparameter* peramalan untuk setiap koridor dapat dilihat pada Tabel 1.

Tabel 1. Penentuan *hyperparameter*

Koridor	Nilai α	<i>Sliding Window</i>	Jumlah Neuron
1	0,1	7	2
2	0,5	5	16
3	0,3	6	4
4	0,1	7	8
5	0,3	6	4
6	0,1	7	16
7	0,1	7	4
8	0,3	7	8
9	0,1	7	16
10	0,1	7	32
11	0,3	7	32
12	0,3	7	2

3.2 Hasil Pengujian Model

Setelah semua proses penentuan *hyperparameter* dilakukan dan menghasilkan beberapa nilai optimal seperti yang ditunjukkan pada Tabel 1. Proses selanjutnya adalah pengujian akurasi peramalan jumlah penumpang menggunakan *exponential smoothing*, LSTM dan gabungan *exponential smoothing* dan LSTM berdasarkan *hyperparameter* pada Tabel 1 pada setiap koridor. Hasil pengujian akurasi peramalan dibandingkan berdasarkan nilai RMSE dan MAPE dari setiap koridor. Peramalan dengan nilai RMSE dan MAPE paling kecil adalah model peramalan yang paling baik.

a. Hasil Peramalan *Exponential Smoothing*

Peramalan *exponential smoothing* digunakan sebagai *baseline* untuk mengukur akurasi hasil peramalan dengan LSTM. Akurasi peramalan diukur berdasarkan nilai RMSE dan MAPE sebagai pembanding dengan peramalan LSTM dan gabungan *exponential smoothing* dengan LSTM. Hasil peramalan *exponential smoothing* seperti disajikan pada Tabel 2. Nilai RMSE tertinggi terdapat pada koridor 1 dengan nilai 9040,13 dan MAPE tertinggi pada koridor 6 dengan nilai 31,27%. Sedangkan untuk nilai RMSE terendah terdapat pada koridor 12 dengan nilai 437,48 dan MAPE terendah pada koridor 2 dengan nilai 5,57%.

Tabel 2. Hasil peramalan dengan *exponential smoothing*

Koridor	Nilai α	RMSE	MAPE (%)
1	0,1	9040,13	14,01
2	0,5	1434,49	5,52
3	0,3	1857,08	5,98
4	0,1	4231,25	26,02
5	0,3	3099,77	9,86
6	0,1	6653,91	31,27
7	0,1	2308,95	9,18
8	0,3	2638,16	10,12
9	0,1	5621,81	15,50
10	0,1	2821,51	19,41
11	0,3	1064,81	14,05
12	0,3	437,48	8,11

b. Hasil Peramalan LSTM

Hasil pengujian pada peramalan LSTM disajikan pada Tabel 3. Berdasarkan Tabel 3 terlihat bahwa hasil peramalan dengan LSTM memiliki nilai RMSE tertinggi pada koridor 1 dengan nilai 7714,96 dan MAPE tertinggi pada koridor 5 dengan nilai 12,99%. Jika dibandingkan dengan hasil peramalan *exponential smoothing* nilai RMSE tertinggi masih berada pada koridor yang sama namun pada peramalan LSTM terjadi penurunan sebesar 1325,17. Sedangkan untuk nilai MAPE tertinggi berpindah dari koridor 6 pada peramalan *exponential smoothing* ke koridor 5 pada peramalan LSTM. Nilai MAPE pada koridor 5 mengalami kenaikan sebesar 3,13%. Untuk nilai RMSE terendah dan MAPE terendah masih berada pada koridor yang sama yaitu koridor 12 dan koridor 2. Nilai RMSE mengalami penurunan sebesar 13,58 akan tetapi nilai MAPE mengalami peningkatan sebesar 0,42%. Hal ini memberi arti bahwa masih ada koridor yang memiliki nilai RMSE dan MAPE lebih tinggi dibandingkan nilai RMSE dan MAPE pada peramalan *exponential smoothing*. Sehingga untuk meningkatkan akurasi pada peramalan LSTM dilakukan *data transformation* dengan (*exponential smoothing*). Setelah proses *data transformation* dengan *exponential smoothing* diharapkan akurasi peramalan LSTM pada koridor-koridor yang memiliki nilai RMSE dan MAPE lebih tinggi dari peramalan *exponential smoothing* mengalami peningkatan.

Tabel 3. Hasil peramalan dengan LSTM

Koridor	Sliding Window	Jumlah Neuron	RMSE	MAPE (%)
1	7	2	7714,96	10,12
2	5	16	1453,70	5,94
3	6	4	2146,03	7,72
4	7	8	2553,92	11,25
5	6	4	3829,34	12,99
6	7	16	2992,79	9,93
7	7	4	1833,24	6,25
8	7	8	2267,70	8,18
9	7	16	3425,19	6,96
10	7	32	2110,88	11,50
11	7	32	934,69	11,00
12	7	2	423,90	7,86

c. Hasil Peramalan LSTM dengan Data Transformation

Hasil peramalan menggunakan *exponential smoothing* dan LSTM dapat dilihat pada Tabel 4. Nilai RMSE tertinggi terdapat pada koridor 6 dengan nilai 13334,02 dan nilai MAPE tertinggi pada koridor 4 dengan nilai 44,45%. Sedangkan nilai RMSE terendah masih pada koridor yang sama dengan peramalan sebelumnya yaitu koridor 12 dengan nilai 441.86 dan nilai MAPE terendah berpindah dari koridor 2 ke koridor 3 dengan nilai 6,20%.

Tabel 4. Hasil peramalan dengan LSTM menggunakan data transformation (*exponential smoothing*)

Koridor	Nilai α	Sliding Window w	Jumlah Neuron	RMSE	MAPE (%)
1	0,1	7	2	8921,73	13,61
2	0,5	5	16	4544,86	22,34
3	0,3	6	4	1891,44	6,20
4	0,1	7	8	9126,35	44,45
5	0,3	6	4	3007,74	9,09
6	0,1	7	16	13334,02	13,42
7	0,1	7	4	3511,97	13,42
8	0,3	7	8	5687,12	21,96
9	0,1	7	16	5647,34	15,48
10	0,1	7	32	2828,40	19,33
11	0,3	7	32	1080,01	14,27
12	0,3	7	2	441,86	8,25

d. Perbandingan Hasil Peramalan

Berdasarkan hasil peramalan sebelumnya, jika dilihat dari nilai RMSE dan MAPE setiap hasil peramalan maka perbandingan ketiga hasil peramalan tersebut dapat dilihat pada Tabel 5.

Tabel 5. Perbandingan Hasil Peramalan

Koridor	RMSE			MAPE (%)		
	ES	LSTM	LSTM+ES	ES	LSTM	LSTM+ES
1	9040,13	7714,96	8921,73	14,01	10,12	13,61
2	1434,49	1453,70	4544,86	5,52	5,94	22,34
3	1857,08	2146,03	1891,44	5,98	7,72	6,20
4	4231,25	2553,92	9126,35	26,02	11,25	44,45
5	3099,77	3829,34	3007,74	9,86	12,99	9,09
6	6653,91	2992,79	13334,02	31,27	9,93	13,42
7	2308,95	1833,24	3511,97	9,18	6,25	13,42
8	2638,16	2267,70	5687,12	10,12	8,18	21,96
9	5621,81	3425,19	5647,34	15,50	6,96	15,48
10	2821,51	2110,88	2828,40	19,41	11,50	19,33
11	1064,81	934,69	1080,01	14,05	11,00	14,27
12	437,48	423,90	441,86	8,11	7,86	8,25
Rata-rata	3434,11	2640,53	5001,90	14,09	9,14	16,82

Berdasarkan Tabel 5 metode LSTM memberikan hasil yang terbaik dengan nilai RMSE dan MAPE paling kecil. Namun jika dilihat di setiap koridor metode LSTM memberikan nilai RMSE dan MAPE lebih besar dari pada *baseline* pada koridor 3 dan 5. Oleh karena itu untuk meningkatkan akurasi LSTM pada koridor 3 dan 5 maka dilakukan *data transformation* dengan *exponential smoothing* sehingga nilai RMSE dan MAPE pada koridor 3 dan 5 mendekati nilai *baseline*.

3.3 Hasil Pengujian Aplikasi

Pengujian aplikasi dilakukan untuk memastikan bahwa sistem dapat berjalan dan mudah digunakan oleh pengguna. Sistem bagian *front-end* dibangun menggunakan *library python* Flask dan Bokeh. Flask dengan *templating* Jinja2 digunakan untuk membuat halaman web lebih rapi dan mudah dikembangkan. Sedangkan Bokeh digunakan untuk menampilkan grafik pada halaman visualisasi data dan hasil peramalan.

a) Hasil Pengujian Visualisasi Data

Halaman visualisasi data terdapat satu buah *dropdown button*, *button* dan grafik untuk menampilkan data. *Dropdown button* berisi nama setiap koridor. Untuk melihat data dari koridor tertentu maka pilih nama koridor dari *dropdown button* kemudian klik *button Show*. Data ditampilkan dalam bentuk grafik dari koridor yang dipilih. Data yang ditampilkan terdiri dari 394 hari yaitu data dari 1 Januari 2015 sampai 29 Januari 2016. Tiga ratus sembilan puluh empat baris data tersebut dibagi menjadi data *training* sebesar 80% (315) dan data *testing* 20% (79). Data *training* direpresentasikan dengan grafik berwarna biru dan data *testing* dengan grafik berwarna hijau. Contoh kedua grafik tersebut dapat dilihat pada Gambar 5.



Gambar 5. Hasil visualisasi data



Gambar 6. Hasil peramalan

b) Hasil Pengujian Peramalan

Tidak jauh berbeda dengan halaman visualisasi data, halaman peramalan memiliki 2 *dropdown button*, *button*, grafik dan *label* untuk menampilkan nilai RMSE dan MAPE. Untuk melihat hasil peramalan dari koridor tertentu, pengguna dapat memilih nama koridor dari *dropdown button* nama koridor kemudian memilih model yang ingin digunakan pada *dropdown button* model dan terakhir klik

button Forecast. Data hasil peramalan akan ditampilkan dalam bentuk grafik dan nilai RMSE dan MAPE dari hasil peramalan tersebut ditampilkan pada *label* pojok kanan atas halaman. Contoh hasil peramalan yang ditampilkan pada sisi *front-end* dapat dilihat pada Gambar 6.

4. Kesimpulan

Berdasarkan pengujian *hyperparameter*, parameter yang optimal ketika diuji secara individu belum tentu dapat memberikan hasil terbaik ketika diterapkan secara bersamaan. Sehingga penentuan nilai pada *hyperparameter* perlu diperhatikan dan dilakukan pengujian kembali ketika hasil peramalan terlalu buruk. Peramalan menggunakan LSTM lebih dominan menghasilkan nilai RMSE dan MAPE lebih kecil dibandingkan peramalan dengan *exponential smoothing* atau gabungan *exponential smoothing* dengan LSTM. Proses *data transformation* dengan menggunakan *exponential smoothing* pada peramalan LSTM dapat memperkecil nilai RMSE dan MAPE sehingga akurasi peramalan meningkat pada koridor yang hasil peramalan LSTM memiliki nilai RMSE dan MAPE lebih tinggi dibandingkan dengan hasil peramalan *exponential smoothing*. Hasil peramalan LSTM memberikan nilai RMSE lebih baik dibandingkan dengan *exponential smoothing* sebesar 76,89%. Dengan demikian peramalan LSTM dapat diterapkan pada data penumpang Busway DKI Jakarta dengan menambahkan proses *data transformation* pada koridor 3 dan 5. Hasil penelitian ini masih perlu pengembangan pada model yang dapat diterapkan pada semua koridor tanpa ada proses yang berbeda pada koridor tertentu seperti yang diterapkan pada koridor 3 dan 5.

Ucapan Terimakasih

Ucapan terimakasih kepada PT Aino Indonesia dan Universitas Gadjah Mada yang telah memberi kesempatan dan dukungan dalam penelitian ini.

Daftar Pustaka

- [1] Chairunnisa, "Hubungan Kinerja Organisasi dan Kualitas Pelayanan Transjakarta Busway dengan Tingkat Kepuasan Pelanggan Pengguna Jasa Transjakarta-Busway (Studi Kasus pada Transjakarta-Busway Koridor IV Pulo Gadung – Dukuh Atas DKI Jakarta)," Skripsi, Fakultas Ilmu Sosial dan Ilmu Politik, Universitas Diponegoro, Semarang, 2008.
- [2] A. Rudi, "Transjakarta Catat Rekor Baru Jumlah Penumpang." 2016. [Online]. Available: <http://megapolitan.kompas.com/read/2016/09/06/07272441/tansjakarta.catat.rekor.-baru.jumlah.penumpang>
- [3] I. Ein, I. Ernawati, and Y. Widiastiwi, "Analisis Sentimen Terhadap Layanan Transjakarta Pada Media Sosial Instagram Menggunakan Naïve Bayes dan Seleksi Fitur Information Gain," *Pros. Semin. Nas. Mhs. Bid. Ilmu Komput. Dan Apl.*, vol. 3, no. 2, pp. 442–451, 2022.
- [4] G. P. Zhang, "Time series forecasting using a hybrid ARIMA and neural network model," *Neurocomputing*, vol. 50, pp. 159–175, 2003.
- [5] B. P. Dewani, S. Suhartono, and M. S. Akbar, "Peramalan Jumlah Penumpang dan Barang di Bandar Udara Internasional Juanda dan Pelabuhan Tanjung Perak Menggunakan Model Hybrid ARIMAX dan Deep Learning Neural Networks," *Inferensi*, vol. 2, no. 1, p. 1, Mar. 2019, doi: 10.12962/j27213862.v2i1.6805.
- [6] S. Hasanah, "Peramalan Jumlah Penumpang di Bandara

- Internasional Juanda Menggunakan Metode ARIMA, Regresi Time Series, TBATS,” *Justek J. Sains Dan Teknol.*, vol. 2, no. 1, p. 27, May 2019, doi: 10.31764/justek.v2i1.3720.
- [7] K. Albeladi, B. Zafar, and A. Mueen, “Time Series Forecasting using LSTM and ARIMA,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 1, 2023, doi: 10.14569/IJACSA.2023.0140133.
- [8] Sofiana, Suparti, A. R. Hakim, and I. T. Utami, “Peramalan Jumlah Penumpang Pesawat Di Bandara Internasional Ahmad Yani dengan Metode Holt Winter’s Exponential Smoothing dan Metode Exponential Smoothing Event Based,” vol. 9, no. 4, 2020.
- [9] W. F. Mujtaba, I. G. A. M. Srinadi, And I. W. Sumarjaya, “Peramalan Jumlah Penumpang Pesawat Bandara I Gusti Ngurah Rai Menggunakan Exponential Smoothing Dan Ruey-Chyn Tsaur,” *E-J. Mat.*, vol. 10, no. 4, p. 222, Nov. 2021, doi: 10.24843/MTK.2021.v10.i04.p346.
- [10] R. Aziz and Helma, “Peramalan Jumlah Penumpang Pesawat di Bandar Udara Soekarno-Hatta dengan Pemulusan Eksponensial Tripel,” 2022.
- [11] L. Wiranda and M. Sadikin, “Penerapan Long Short Term Memory Pada Data Time Series Untuk Memprediksi Penjualan Produk PT. Metiska Farma,” vol. 8, 2019.
- [12] P. Arsi and J. Prayogi, “Optimasi Prediksi Nilai Tukar Rupiah Terhadap Dolar Menggunakan Neural Network Berbasis Algoritma Genetika,” *J. Inform.*, vol. 7, no. 1, pp. 8–14, Apr. 2020, doi: 10.31311/ji.v7i1.6793.
- [13] S. Elsworth and S. Güttel, “Time Series Forecasting Using LSTM Networks: A Symbolic Approach.” arXiv, Mar. 12, 2020. Accessed: Jul. 04, 2023. [Online]. Available: <http://arxiv.org/abs/2003.05672>
- [14] M. Mukhlis, A. Kustiyo, and A. Suharso, “Peramalan Produksi Pertanian Menggunakan Model Long Short-Term Memory,” *BINA INSANI ICT J.*, vol. 8, no. 1, p. 22, Jun. 2021, doi: 10.51211/biict.v8i1.1492.
- [15] Salahuddin, M. Khadafi, Huzaeni, and M. Davi, “Rancang Bangun Aplikasi Machine Learning Prediksi Hasil Panen Buah Pinang (Areca Catechu) Menggunakan Metode Regresi Linier Berganda,” *Proceeding Semin. Nas. Politek. Negeri Lhokseumawe*, vol. 6, no. 1, pp. 181–186, 2022.
- [16] F. A. Gers, J. Schmidhuber, and F. Cummins, “Learning to Forget: Continual Prediction with LSTM,” *1999 Ninth Int. Conf. Artif. Neural Netw. ICANN 99 Conf Publ No 470*, vol. 2, pp. 850–855, 1999, doi: 10.1049/cp:19991218.
- [17] R. Cahyadi, A. Damayanti, and D. Aryadani, “Recurrent Neural Network (RNN) Dengan Long Short Term Memory (LSTM) Untuk Analisis Sentimen Data Instagram,” vol. 5, no. 1, 2020.
- [18] P. A. Qori, D. S. Oktafani, and I. Kharisudin, “Analisis Peramalan dengan Long Short Term Memory pada Data Kasus Covid-19 di Provinsi Jawa Tengah,” vol. 5, 2022.