KESATRIA: Jurnal Penerapan Sistem Informasi (Komputer & Manajemen)
Terakreditasi Nomor 204/E/KPT/2022 | Vol. 4, No. 3, Juli (2023), pp. 507-517

Perbandingan Algoritma ARIMA, Prophet, dan LSTM dalam Prediksi Penjualan Tiket Wisata Taman Hiburan (Studi Kasus: Saloka *Theme Park*)

Dienda Rizkya Hayuningtyas Roosaputri[1], Christine Dewi[2]
[1,2]Teknik Informatika, FTI UKSW, Salatiga, Jawa Tengah, Indonesia
E-mail: [1]672019155@student.uksw.edu, [2]christine.dewi@uksw.edu

Abstract

Indonesia has a wide variety of tourism destinations or tourism destinations that are useful as a place to have fun with family or friends, to calm down from various activities as well as an educational place for children to be more interested in learning. PT. Panorama Indah Permai (Saloka Theme Park) is one of the tourist destinations in Indonesia and is currently operating again when the Covid-19 pandemic enters Indonesia and results in changes in visitors coming to amusement park tourism. Therefore, a comparison of ARIMA, Prophet, and Long Short-Term Memory (LSTM) algorithms was made to determine the algorithm that is suitable to be used as a predictive model of amusement park ticket sales. The Data obtained comes from historical data and must go through several processes such as pre-processing and algorithm testing to ensure the accuracy of the data with the algorithm. The results obtained from three forecasting models, it was obtained that the ARIMA algorithm has a value of RMSE of 762,009 and MSE of 580,659,053.

Keywords: *Prediction, Time Series, ARIMA, Prophet, LSTM*

Abstrak

Indonesia memiliki berbagai macam destinasi wisata pariwisata atau daerah tujuan pariwisata yang berguna sebagai tempat bersenang-senang dengan keluarga atau teman-teman, untuk menenangkan diri dari berbagai kegiatan sekaligus sebagai tempat edukasi bagi anak-anak agar lebih tertarik untuk belajar. PT. Panorama Indah Permai (Saloka Theme Park) merupakan salah satu destinasi wisata yang ada di Indonesia dan saat ini telah beroperasi kembali saat pandemi Covid-19 masuk ke Indonesia dan mengakibatkan perubahan pengunjung datang ke wisata taman hiburan. Maka dari itu dibuat sebuah perbandingan algoritma ARIMA, Prophet, dan Long Short-Term Memory (LSTM) untuk menentukan algoritma yang cocok untuk dijadikan model prediksi penjualan tiket wisata taman hiburan. Data yang didapatkan berasal dari data historis serta harus melewati beberapa proses seperti pre-processing dan pengujian algoritma untuk memastikan keakuratan data dengan algoritma tersebut. Hasil yang dididapat dari tiga model forecasting, diperoleh bahwa algoritma ARIMA memiliki nilai RMSE sebesar 762.009 dan MAE sebesar 478.887.

Kata Kunci: *Prediksi, Time Series, ARIMA, Prophet, LSTM*

1. Pendahuluan

Indonesia memiliki berbagai macam destinasi wisata dimana menurut Pasal 1 ayat (6) Undang-Undang Nomor 10 Tahun 2009 menyebutkan bahwa destinasi wisata pariwisata atau daerah tujuan pariwisata adalah kawasan geografis yang berada dalam satu atau lebih wilayah administratif yang di dalamnya terdapat daya tarik wisata, fasilitas umum, fasilitas pariwisata, aksesibilitas, serta masyarakat yang saling terkait dan melengkapi kepariwisataan [1]. Tujuan dari destinasi wisata adalah untuk bersenang-senang dengan keluarga atau teman-teman, untuk menenangkan diri dari berbagai kegiatan sekaligus sebagai tempat edukasi bagi anak-anak agar lebih tertarik untuk belajar. PT. Panorama

ISSN: 2720-992X
Copyright © KESATRIA: Jurnal Penerapan Sistem Informasi (Komputer & Manajemen)

Indah Permai (Saloka *Theme Park*) merupakan salah satu destinasi wisata yang ada di Indonesia dan merupakan sebuah taman rekreasi keluarga terbesar di Jawa Tengah yang mengusung konsep kearifan lokal berdasarkan legenda rakyat Baru Klinthing sebagai salah satu keunikan yang menjadikan keunggulan PT. Panorama Indah Permai (Saloka Theme Park). Di bawah naungan PT. Panorama Indah Permai, Saloka mulai dibangun pada Oktober 2016 dengan mengambil alih kawasan yang dahulu bernama Rawa Permai dan Saloka pertama kali dibuka pada 22 Juni 2019 dengan jam operasional yang berbeda pada *weekdays* maupun *weekend*.

Seiring dengan berjalannya waktu, PT. Panorama Indah Permai (Saloka Theme Park) ingin memanfaatkan data yang dimiliki dalam bentuk *time series* untuk memprediksi fluktasi data penjualan tiket pada bulan yang akan mendatang sehingga PT. Panorama Indah Permai (Saloka *Theme Park*) dapat mengatasi masalah yang terjadi saat terjadi pelonjakan pengunjung saat mengunjungi Saloka *Theme Park* termasuk saat adanya pandemi Covid-19 yang masuk ke Indonesia pada Maret 2020 menyebabkan terjadinya ketidakstabilan pengunjung berdatangan. Sehingga PT. Panorama Indah Permai (Saloka *Theme Park*) mengalami perubahan drastis termasuk saat munculnya pandemi Covid-19 masuk ke Indonesia pada Maret 2020 dan menyebabkan PT. Panorama Indah Permai (Saloka *Theme Park*) menutup sementara wisata taman hiburan untuk mencegah penyebaran Covid-19 berdasarkan peraturan pemerintah. Dengan adanya kasus tersebut, *forecasting* atau prediksi perlu untuk diterapkan dalam sebuah perusahaan guna menganalisis data *time series* dalam mengambil sebuah informasi yang dapat digunakan untuk mengambil keputusan di masa depan berdasarkan kejadian yang terjadi di masa lalu [2][16]. Prediksi dapat diklasifikasikan menjadi prediksi jangka pendek, prediksi jangka menengah, maupun prediksi jangka panjang [20].

Berdasarkan latar belakang tersebut, penulis akan melakukan penelitian untuk membandingkan algoritma ARIMA, *Prophet* serta *Regresi Long Short-Term Memory* (LSTM) untuk mencari algoritma yang cocok digunakan prediksi penjualan tiket pada taman wisata Saloka *Theme Park*. Dengan data historis pada 01 Januari 2020 hingga 24 April 2023 akan dilakukan perbandingan nilai RMSE dan MAE pada ketiga algoritma tersebut.

2. Metodologi Penelitian

2.1. Tinjauan Pustaka

Dalam jurnal penelitian berjudul "Analisis Komparatif ARIMA dan Prophet dengan Studi Kasus Dataset Pendaftaran Mahasiswa Baru" membahas mengenai data mahasiswa baru pada Universitas Kristen Maranatha pada tahun 1993 hingga 2019 akan dilakukan prediksi komparatif antara metode ARIMA dan Prophet dengan menggunakan 26 data dan 5 sampel data deret waktu. Dari hasil yang diperoleh didapat bahwa model *Prophet* menghasilkan kinerja lebih unggul dari ARIMA berdasarkan dari nilai RMSE. Sehingga metode *Prophet* digunakan sebagai membantu tim pemasaran dalam melakukan peramalan jumlah pendaftar mahasiswa baru per kota dan dapat digunakan untuk pengambilan keputusan lainnya [3].

Dalam jurnal penelitian berjudul "Perbandingan Model *Time Series Forecasting* Dalam Memprediksi Jumlah Kedatangan Wisatawan dan Penumpang *Airport*" membahas mengenai perbandingan 3 metode yaitu SARIMA, LSTM, dan *Prophet* dengan dua dataset *time series* jumlah wisatawan dan penumpang di *airport* yang memiliki frekuensi bulanan. Dari ketiga model tersebut didapat bahwa model SARIMA memiliki performa yang bagus dari dua model lainnya dengan nilai RMSE 565 untuk dataset jumlah pengunjung Taiwan dari Indonesia dan nilai RMSE 153.142 untuk dataset jumlah kedatangan penumpang di Changi Airport [4].

Dalam jurnal penelitian berjudul "*Sales Forecasting* pada Dealer Motor X Dengan LSTM, ARIMA, dan *Holt-Winters Exponential Smoothing*" membahas mengenai perbandingan 3 algoritma yaitu, LSTM, ARIMA, dan *Holt-Winters Exponential*

Smoothing dengan data penjualan motor pada tahun 2015 hingga 2021 untuk mencari nilai RMSE dan MAPE terbaik agar bisa diterapkan pada dataset tersebut dalam melakukan prediksi. Berdasarkan ketiga model, model yang paling baik untuk digunakan prediksi yaitu ARIMA dengan nilai RMSE (1.1339-5.8936) terendah untuk semua jenis motor dan juga memili nilai MAPE terendah [5].

Dalam jurnal penelitian berjudul "Peramalan Kunjungan Wisatawan dan Daya Dukung Bee Jay Bakau Resort Probolinggo" membahas peramalan tersebut menggunakan metode penelitian kuantitatif dengan data mulai pada periode Januari 2015-Agustus 2019 yang diolah menggunakan algoritma ARIMA dan *Winter*. Keakuratan peramalan dilihat pada hasil *Mean Absolute Deviation* (MAD), *Mean Squared Error* (MSE), dan *Mean Absolute Percentage Error* (MAPE) dan diperoleh bahwa metode *Winter* menghasilkan kesalahan peramalan lebih kecil dengan rata-rata sebanyak 14.866 wisatawan per bulan atau rata-rata sebanyak 496 wisatawan per hari [6].

Berdasarkan penelitian yang sudah ada maka penulis akan melakukan perbandingan algoritma ARIMA, *Prophet* serta LSTM untuk penelitian prediksi penjualan tiket wisata taman hiburan dengan studi kasus di Saloka *Theme Park* untuk mencari algoritma yang paling tepat serta memiliki tingkat keakuratan yang lebih akurat agar dapat diterapkan dalam sistem PT. Panorama Indah Permai miliki dalam mengatasi pelonjakan pengunjung berdatang ke wisata taman hiburan Saloka *Theme Park.*

2.2. Tahapan Penelitian

Metode penelitian yang digunakan dalam melakukan prediksi tiket dijelaskan dalam *flow chart* yang berisikan data *cleaning*, data *preparation*, *modelling* menggunakan algoritma ARIMA, *Prophet* serta LSTM, evaluasi, dan kesimpulan. Berikut langkah-langkah pada penelitian ini yang ditampilkan gambar 1.

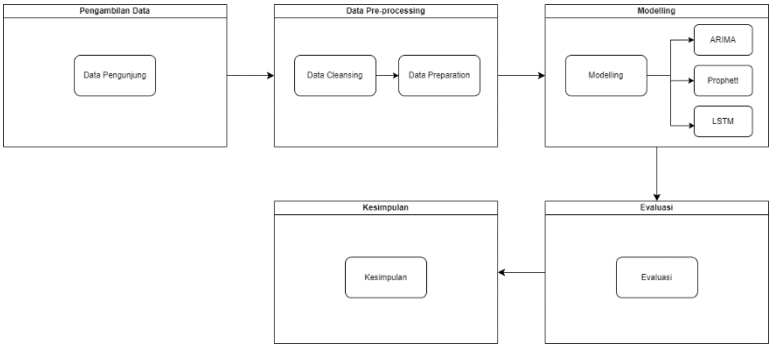

Gambar 1. Metodologi Penelitian

a) Tahap Pengambilan Data

Tahap pengambilan data dilakukan melalui sistem *website* Saloka *Theme Park* yang tercatat mulai 01 Januari 2020 hingga 24 April 2023 berupa file *excel* sebanyak 992 data penjualan tiket serta hanya mengambil 2 kolom saja yaitu kolom tanggal dan juga kolom data penjualan tiket per hari.

b) Tahap Data Pre-processing

Tahap data *pre-processing* dilakukan untuk melakukan pengecekan dari data mentah (*raw data*) tersebut apakah terdapat data yang NULL atau *missing value*. Dari data tersebut, pada bulan Juli 2021 serta data harian pada beberapa bulan tidak lengkap, sehingga perlu dilakukan imputasi yaitu, menggantikan nilai atau data yang hilang *(missing value*, NaN, *blank*) dengan nilai mean atau median. Setelah dilakukan tahap *pre-processing*, didapat data penjualan tiket sebanyak 1179 data.

c) Tahap Modelling

Tahap *modelling* dilakukan jika proses pada *pre-processing* data sudah selesai, maka data tersebut dapat diterapkan dengan ketiga algoritma. Dengan pembagian 80 persen sebagai *data training* dan 20 persen *data validation* yang akan digunakan sebagai tahap evaluasi untuk mengecek performa algoritma ARIMA, *Prophet* serta LSTM dalam keakuratan hasil akhir dengan algoritma tersebut.

1) *Autoregresive Intergrated Moving Average* (ARIMA)

ARIMA atau *Box-Jenkins models* merupakan model yang digunakan untuk menganalisis peramalan dengan data *time series* yang bergerak dengan tepat jika peramalan dapat mengasumsikan jumlah yang diperoleh dengan pola dan tren masa depan yang serupa [19]. ARIMA model memiliki tiga paramater yang dapat dilihat pada grafik dekomposisi dan *plotting* grafik ACF serta PACF yaitu:

a. p (*order of autoregression*) berguna untuk menentukan variabel lag yang diperlukan.
b. d (*order of integration*) berguna untuk menentukan jumlah *differencing*.
c. q (*order of moving average*) berguna untuk menentukan jumlah ukuran *window* untuk MA.

Parameter p dapat dilihat pada grafik dekomposisi dan *plotting* grafik ACF dan PACF, sedangkan parameter d dapat dilihat pada grafik *trend* dan q dilihat dari *seasonality* [10]. Model ARIMA dibagi menjadi 3 kelompok yaitu Model *Autoregresivve* (AR), *Moving Average* (MA), dan model campuran ARIMA (*Autoregressive Integrated Moving Average*) [11].

a) Model *Autoregresivve* (AR)

Dalam model *Autoregresivve* (AR) bentuk umum dengan ordo p(AR(p)) atau model ARIMA (p,0,0) ditunjukan pada persamaan (1):

$$X_t = \mu' + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \cdots + \phi_p X_{t-p} + e_t \quad (1)$$

Dimana:

μ' = Konstanta
ϕ_p = Parameter *Autoregresivve*
e_t = Nilai kesalahan pada saat t

b) *Moving Average* (MA)

Dalam model *Moving Average* (MA) bentuk umum dengan ordo q(MA(q)) atau model ARIMA (0,0,q) ditunjukan pada persamaan (2):

$$X_t = \mu' + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \cdots - \theta_p e_{t-k} \quad (2)$$

Dimana:

μ' = Konstanta
θ_1 dan θ_p = Parameter Moving Average
e_{t-k} = Nilai kesalahan pada saat t-k

c) Model Campuran

a. Proses ARMA

Dalam model untuk campuran proses AR(1) murni dan MA(1) murni, atau ARIMA(1,0,1) ditunjukan pada persamaan (3) atau persamaan (4):

$$X_t = \mu' + \phi_1 X_{t-1} + e_t - \theta_1 e_{t-1} \quad (3)$$

Atau

$$(1 - \phi_1 B) X_t = \mu' + (1 - \phi_1 B) e_t \quad (4)$$

Dimana:

$(1 - \phi_1 B) X_t$ = AR(1)
$(1 - \phi_1 B) e_t$ = MA(1)

b. Proses ARIMA

Jika data non stasioneritas ditambahkan pada campuran proses ARMA, maka persamaan untuk kasus sederhana model umum ARIMA(p,d,q) atau ARIMA (1,1,1) ditunjukan pada persamaan (5):

$$(1-B)(1-\phi_1 B)X_t = \mu' + (1-\varphi_1 B)e_t \quad (5)$$

Dimana:

$(1-B)$ = Pembedaan Pertama

$(1-\phi_1 B)X_t$ = AR (1)

$(1-\varphi_1 B)e_t$ = MA (1)

2) Prophet

Prophet merupakan model prediksi yang dikembangkan oleh Facebook dan dapat digunakan dalam bahasa R dan *Python* [17]. Model *Prophet* melakukan proses prediksi berdasarkan model tambahan (*additive*) dimana *trend non-linier* sesuai dengan pengaruh musim tahunan, mingguan, dan harian, serta ditambah dengan pengaruh musim liburan [4]. Model *Prophet* bagus untuk diterapkan pada data *time series* dengan pengaruh *seasonality* yang kuat karena menghasilkan performa prediksi dengan baik. Model *Prophet* juga mampu mengatasi data dengan *missing value* dan *outliers* dengan baik [5]. Berikut model *Prophet* yang ditunjukan pada persamaan (6):

$$y_{(t)} = g_{(t)} + s_{(t)} + h_{(t)} + \epsilon_{(t)} \quad (6)$$

Dimana:

$g_{(t)}$: Kurva pertumbuhan piecewise linear atau logistic untuk pemodelan perubahan non-periodik dalam seri waktu.

$s_{(t)}$: Perubahan periodik.

$h_{(t)}$: Efek liburan dengan jadwal yang tidak teratur.

$\epsilon_{(t)}$: Kesalahan *account* untuk setiap perubahan yang tidak

3) *Long Short-Term Memory* (LSTM)

LSTM merupakan model turunan dari *Recurrent Neural Network* (RNN) yang dapat digunakan untuk memprediksi data *time series* serta di rancang untuk mengolah data *sequence* (data berurutan) [9][12]. Dalam membuat model yang baik ada beberapa yang harus dipertimbangkan dalam pemrosesan LSTM yaitu, dengan menentukan jumlah *hidden layer* dan menentukan *hyperparameter* input yang sesuai [7]. Arsitektur LSTM berisikan tiga lapisan yaitu, lapisan input, lapisan tersembunyi, dan lapisan output [13]. Berikut adalah gambar arsitektur LSTM yang dapat dilihat pada gambar 2.

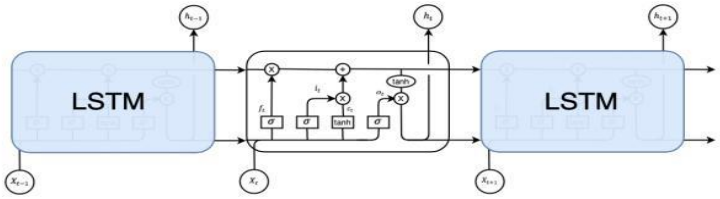

Gambar 2. Arsitektur LSTM

Pada gambar 2 terdapat lapisan tersembunyi pada *memory cell* dan *gates unit* untuk mengatur masing-masing memori pada *neuron*. *Gates unit* terdiri dari *input gate*, *forget gate*, dan *output gate* [15]. Tahapan-tahapan yang dilalui dalam proses model LSTM ditunjukan pada persamaan di bawah.

1) *Forget gate* (f_t)
Forget gate memiliki fungsi untuk menentukan data yang akan dihilangkan dan menentukan waktu latensi yang optimal untuk *input* selanjutnya [14]. Berikut adalah fungsi aktivasi sigmoid yang ditunjukkan pada persamaan (7).

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (7)$$

Dimana:
f_t = *forget gate*
σ = fungsi aktivasi sigmoid
W_f = bobot *forget gate*
h_{t-1} = nilai *hidden state cell* sebelum
x_t = nilai *input*
b_f = bias *foget gate*

2) *Input gate* (i_t)
Input gate memiliki fungsi untuk membawa titik masuk data dari luar dan mengolah data yang masuk [14]. Berikut adalah dua fungsi aktivasi yang ditunjukkan pada persamaan (8) dan (9).

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (8)$$
$$\tilde{C}_t = tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (9)$$

Dimana:
i_t = *input gate*
W_i = bobot *input gate*
b_i = bias *input gate*
$\tilde{C}_t$ = *candidate gate*
$tanh$ = fungsi aktivsi tanh
W_c = bobot *candidate gate*
b_c = bias *candidate gate*

3) *Cell state* (c_t)
Cell state memiliki fungsi untuk menggantikan nilai sebelumnya pada *memory cell* dengan nilai *memory cell* yang baru [15]. Berikut adalah fungsi pada *cell state* yang ditunjukkan pada persamaan (10).

$$c_t = (i_t * \tilde{C}_t + f_t * c_{t-1}) \quad (10)$$

Dimana:
c_t = *cell gate*
i_t = *input gate*
$\tilde{C}_t$ = *candidate gate*
f_t = *forget gate*
c_{t-1} = nilai *cell state* sebelum

4) *Output gate* (o_t)
Output gate untuk melakukan seluruh proses *input* dan *output* perhitungan atau *output* dalam sel LSTM [14]. Berikut adalah fungsi pada *output gate* yang ditunjukkan pada persamaan (11) dan (12).

$$o_t = \sigma(W_o \cdot [h_{t-1}.x_t] + b_o) \quad (11)$$
$$h_t = o_t * \tanh(c_t) \quad (12)$$

Dimana:
o_t = *output gate*
W_o = bobot *output gate*
b_o = bias *output gate*
h_t = *hidden state*

c_t = *cell gate*

d) Tahap Evaluasi

Tahap evaluasi dilakukan untuk mengecek performa algoritma tersebut dalam data yang digunakan. Evaluasi yang akan digunakan yaitu dengan melakukan perbandingan hasil uji nilai *Root Mean Squared Error* (RMSE) dan *Mean Squared Error* (MSE) dari algoritma ARIMA, *Prophet*, serta LSTM.

1) *Mean Square Error* (MSE)

Mean Absolute Error (MAE) adalah nilai rata-rata kesalahan absolute (error) antara hasil prediksi dengan nilai dari data sebenarnya [7]. Semakin rendah nilai MAE yang didapatkan, maka semakin akurat hasil prediksi. MAE menghitung penyimpangan nilai prediksi dari nilai data sebenarnya, untuk setiap pasang nilai prediksi dan nilai sebenarnya [8]. Adapun rumus untuk menghitung MSE yang dapat dilihat pada persamaan (13).

$$MSE = \frac{1}{n}\sum|f_i - y_i| \quad (13)$$

Keterangan:

f_i = nilai hasil *forecasting*

y_i = nilai observasi ke-i

n = banyaknya data

2) *Root Mean Square Error* (RMSE)

Root Mean Square Error (RMSE) digunakan sebagai perbedaan antara nilai yang diprediksi dengan nilai sebenarnya [18]. Semakin tinggi nilai RMSE yang dihasilkan maka tingkat keakuratan yang didapatkan semakin rendah. Jika semakin rendah nilai RMSE yang dihasilkan maka tingkat keakuratan semakin tinggi [7]. Adapun rumus untuk menghitung RMSE yang dapat dilihat pada persamaan (14).

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i - y_i)^2} \quad (14)$$

Keterangan:

$\hat{y}_i$ = nilai hasil *forecasting*

y_i = nilai observasi ke-i

n = banyaknya data

3. Hasil dan Pembahasan

3.1. Pembahasan

Penelitian ini dilakukan pada taman wisata hiburan Saloka *Theme Park* dengan data penelitian penjualan tiket dari periode 01 Januari 2020 hingga 24 April 2023. Berikut adalah data yang digunakan setelah dilakukan proses *pre-processing*:

Tabel 1. Data Penjualan Tiket Saloka *Theme Park*

Tanggal	Jumlah Tiket
01 Januari 2020	194
02 Januari 2020	104
03 Januari 2020	65
04 Januari 2020	417
05 Januari 2020	225
…..	…..
…..	…..
19 April 2023	668
20 April 2023	662

Tanggal	Jumlah Tiket
21 April 2023	413
22 April 2023	667
23 April 2023	1907
24 April 2023	2222

Dari tabel 1 diatas diatas hanya menggunakan dua kolom yaitu kolom tanggal dan kolom jumlah tiket di mana tanpa memperhatikan jenis tiket yang terjual. Dari data tersebut, dibuat grafik untuk melihat pergerakan penjualan tiket taman wisata Saloka *Theme Park* yang dapat dilihat pada gambar 3.

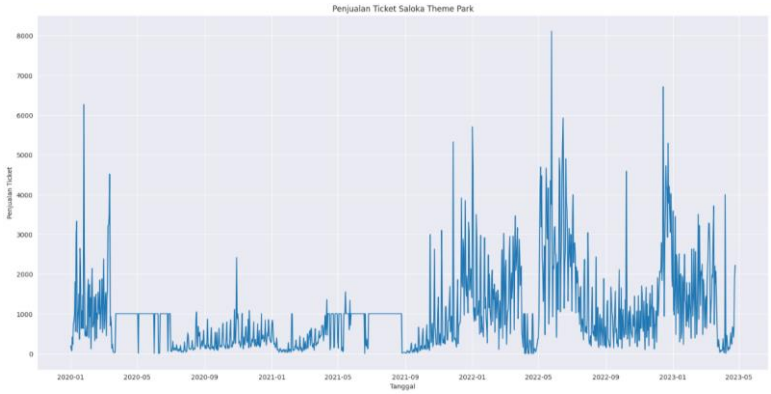

Gambar 3. Grafik Penjualan Tiket Saloka *Theme Park*

Gambar 3 merupakan visualisasi dari data pada tabel 1 yang memiliki pola penjualan turun dikarenakan adanya pandemi Covid-19 dan juga pada periode Januari 2020 hingga April 2023 terlihat pergerakan grafik musiman dengan fluktasi yang tidak teratur. Dari data tersebut akan dilakukan pembagian data sebanyak 80 persen untuk data *training* dan 20 persen untuk data *validation*.

1. *Autoregresive Intergrated Moving Average* (ARIMA)
   Pada model ARIMA yang digunakan pada dataset penelitian ini sudah stasioner dikarenakan hasil dari *Dickey-Fuller test* menunjukan bahwa nilai *p-value* < alpha (0,05) yang dapat dilihat pada gambar 4.

```
Results of Dickey-Fuller Test:
Test Statistic                  -4.103603
p-value                          0.000955
#Lags Used                      22.000000
Number of Observations Used    1156.000000
Critical Value (1%)              -3.436019
Critical Value (5%)              -2.864043
Critical Value (10%)             -2.568103
dtype: float64
```

Gambar 4. *Dickey-Fuller Test* Data Penjualan Tiket Saloka *Theme Park*

Setelah data sudah stationer, akan dilakukan pencarian model ARIMA yang optimal dengan nilai RMSE yang mendekati nol. Berikut adalah hasil pencarian model ARIMA pada gambar 5.

```
ARIMA(0, 0, 0) RMSE=1177.375
ARIMA(0, 0, 1) RMSE=1043.749
ARIMA(0, 1, 0) RMSE=1087.673
ARIMA(0, 1, 1) RMSE=886.844
ARIMA(0, 2, 0) RMSE=1817.244
ARIMA(0, 2, 1) RMSE=1088.189
ARIMA(1, 0, 0) RMSE=970.107
ARIMA(1, 0, 1) RMSE=879.335
ARIMA(1, 1, 0) RMSE=1009.553
ARIMA(1, 1, 1) RMSE=902.694
ARIMA(1, 2, 0) RMSE=1497.537
ARIMA(1, 2, 1) RMSE=1010.097
ARIMA(2, 0, 0) RMSE=951.141
ARIMA(2, 0, 1) RMSE=918.935
ARIMA(2, 1, 0) RMSE=929.173
ARIMA(2, 1, 1) RMSE=899.806
ARIMA(2, 2, 0) RMSE=1283.631
ARIMA(2, 2, 1) RMSE=929.670
Best ARIMA(1, 0, 1) RMSE=879.335
```

Gambar 5. Pencarian *Best Model* ARIMA

Pada pencarian *best model* ARIMA diperoleh bahwa model ARIMA(1,0,1) merupakan *best model* dari seluruh pencarian model. Dari model ARIMA(1,0,1) didapatkan nilai MAE dan RMSE yang dapat ditunjukkan pada tabel 2.

Tabel 2. Hasil Pengujian Model ARIMA

Metode	MAE	RMSE
ARIMA(1,0,1)	478.887	762.009

2. *Prophet*
   Berikut adalah hasil nilai MAE dan RMSE dari percobaan menggunakan dataset yang telah dilakukan proses *pre-processing* yang ditunjukkan pada tabel 3.

Tabel 3. Hasil Pengujian Model Prophet

Metode	MAE	RMSE
Prophet	546.523	771.134

3. *Long Short-Term Memory* (LSTM)
   Sebelum menerapkan metode LSTM pada data tersebut, perlu dilakukan normalisasi untuk mengurangi tingkat nilai *error* dengan cara min-max scalling yaitu, mengubah data sebenarnya menjadi nilai *range interval* [0,1]. Kemudian data yang sudah dilakukan proses normalisasi akan dilakukan percobaan untuk *forecasting* dengan metode LSTM.
   Dengan 1 *hidden layer* yang terdiri 200 layer, serta Epoch = 100 didapatkan hasil MAE dan RMSE yang ditunjukkan pada tabel 4.

Tabel 4. Hasil Pengujian Model LSTM

Metode	MAE	RMSE
LSTM	695.374	972.784

3.2. Evaluasi

Dari hasil pengujian yang didapatkan dari ketiga metode yaitu ARIMA, *Prophet*, dan LSTM dilakukan perbandingan hasil nilai MAE dan RMSE pada tabel 5.

Tabel 5. Komparasi Hasil Tiga Model

Metode	MAE	RMSE
ARIMA(1,0,1)	478.887	762.009
Prophet	546.523	771.134
LSTM	695.374	972.784

Berdasarkan hasil dari ketiga metode, metode ARIMA memiliki kinerja yang baik daripada kedua metode pembanding yang menunjukkan bahwa nilai MAE dan RMSE terendah. Model Prophet dan LSTM kurang cocok untuk digunakan dalam melakukan prediksi dengan data penjualan tiket karena memiliki hasil nilai MAE dan RMSE yang kurang baik.

Setelah melakukan uji evaluasi akurasi terhadap data, selanjutnya adalah melakukan prediksi menggunakan model ARIMA(1,0,1). Berikut adalah data hasil prediksi pada tabel 6.

Tabel 6. Data Hasil Prediksi Penjualan Tiket Saloka *Theme Park*

Metode	Tanggal	Nilai Prediksi	Pembulatan
ARIMA (1,0,1)	25 April 2023	3444.629650	3444
ARIMA (1,0,1)	26 April 2023	5881.804586	5881
ARIMA (1,0,1)	27 April 2023	9525.738780	9525
ARIMA (1,0,1)	28 April 2023	14368.933530	14368
ARIMA (1,0,1)	29 April 2023	20404.166857	20401
ARIMA (1,0,1)	30 April 2023	27624.483293	27624
ARIMA (1,0,1)	01 Mei 2023	36023.184045	36023

4. Kesimpulan

Dari data penjualan tiket dengan melakukan perbandingan antara algoritma ARIMA, *Prophet*, dan LSTM menghasilkan sebuah kesimpulan bahwa algoritma ARIMA dapat bekerja lebih baik dibandingkan algoritma *Prophet* dan LSTM berdasarkan nilai RMSE yang didapatkan yaitu 762.009. Berdasarkan prediksi yang dilakukan menggunakan model ARIMA (1,0,1) dalam 7 hari ke depan yaitu 25 April 2023 hingga 01 Mei 2023 menunjukkan jumlah pengunjung ke Saloka *Theme Park* cenderung peningkatan bertahap.

Dengan melakukan perbandingan antara ketiga metode dalam prediksi sangat direkomendasikan agar dapat mengetahui metode apa yang cocok untuk digunakan. Selain itu, dalam melakukan prediksi dapat menentukan juga jenis tiket apa yang paling banyak dibeli oleh pengunjung maupun penerapan berbagai metode prediksi untuk penelitian selanjutnya.

Daftar Pustaka

[1] Riwukore, Jefirston R., Habaora, Fellyanus & Yustini, T. 2021. Kondisi Eksisting Destinasi Pariwisata Pantai Lasiana Kota Kupang Berdasarkan Atraksi, Aksesibilitas, Fasilitas, Kelembagaan, dan Ekosistem Pariwisata. *Jurnal Kepariwisataan Indonesia*, 15(2), 103-115.

[2] Jange, Beno. 2021. Prediksi Harga Saham Bank BCA Menggunakan Prophet. *Journal of Trends Economics and Accounting Research*, 2(1), 1-5.

[3] Chandra, C. & Budi, S. 2020. Analisis Komparatif ARIMA dan Prophet dengan Studi Kasus Dataset Pendaftaran Mahasiswa Baru. *Jurnal Teknik Informatika dan Sistem Informasi*, 6(2), 278-287.

[4] Ridla, M. A., Azise, N., & Rahman, M. 2023. Perbandingan Model Time Series Dalam Memprediksi Jumlah Kedatangan Wisatawan dan Penumpang Airport. *Jurnal Sistem Informasi dan Sistem Komputer*, 8(1), 1-14.

[5] Soeryawinata, J., Palit, H. N., & Santoso, L. W. 2022. Sales Forecasting Pada Dealer Motor X Dengan LSTM, ARIMA, dan Holt-Winters Exponential Smoothing. *Jurnal Infra*, 10(2), 1-4.
[6] Fattah, M., Utami, T. N., & Sofiati, D. 2020. Peramalan Kunjungan Wisatawan dan Daya Dukung Bee Jay Bakau Resort Probolinggo. *Jurnal Analisis Kebijakan Kehutanan*, 17(2), 153-163.
[7] Sautomo, S. & Pardede, H. F. 2021. Prediksi Belanja Pemerintah Indonesia Menggunakan Long Short-Term Memort (LSTM). *Jurnal Rekayasa Sistem dan Teknologi Informasi*, 5(1), 99-106.
[8] Rosita, A., Puspitasari, N., & Kamila, V. Z. 2022. Rekomendasi Buku Perpustakaan Kampus Dengan Metode Item-Based Collaborative Filtering. *Sebatik*, 26(1), 340-346.
[9] Ashari, M. L. & Sadiki, M. 2020. Prediksi Data Transaksi Penjualan Time Series Menggunakan Regresi LSTM. *Jurnal Nasional Pendidikan Teknik Informatika*, 9(1), 1-10.
[10] Farosanti, L., Mubarok, H., & Indrianto. 2022. Analisa Peramalan Penjualan Alat Kesehatan dan Laboratorium di PT. Tristania Global Indonesia Menggunakan Metode ARIMA. *Jurnal Informatika Merdeka Pasuruan*, 3(1), 14-18.
[11] Waryanto, H., & Wanti, D. A. 2019. Prediksi Penjualan Seragam Sekolah Dengan Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average) (Studi Kasus: Koperasi Karyawan Yayasan Umara Al-Zahra Indonesia). *Jurnal Statistika dan Matematika*, 1(1), 88-102.
[12] Wiranda, L. & Sadikin, M. 2019. Penerapan Long Short-Term Memory Pada Data Time Series Untuk Memprediksi Penjualan Produk PT. Metiska Farma. *Jurnal Nasional Pendidikan Teknik Informatika*, 8(3), 184-196.
[13] Rizkilloh, M. F., & Widiyanesti, S. 2022. Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short-Term Memory (LSTM). *Jurnal Rekayasa Sistem dan Teknologi Informasi*. 6(1):25-31.
[14] Zahara, S., Sugianto, & Ilmiddafiq, M. B. 2019. Prediksi Indeks Harga Konsumen Menggunakan Metode Long Short-Term Memory (LSTM) berbasis Cloud Computing. *Jurnal Rekayasa Sistem dan Teknologi Informasi*, 3(3), 357-363.
[15] Selle, N., Yudistira, N., & Dewi, C. 2022. Perbandingan Prediksi Penggunaan Listrik Dengan Menggunakan Metode Long Short-Term Memory (LSTM) dan Recurrent Neural Network (RNN). *Jurnal Teknologi Informasi dan Ilmu Komputer*. 9(1), 155-162.
[16] Alfani, A. W. P. R., Rozi, F., & Sukmana, F. 2021. Prediksi Penjualan Produk Unilever Menggunakan Metode K-Nearest Neighbor. *Jurnal Ilmiah Penelitian dan Pembelajaran Informatika*, 6(1), 155-160.
[17] Muzakki, M. A., Sabila, M. A., Sundari, S., & Wisnuadhi, B. 2021. Analisis Algoritma Prophet untuk Memprediksi Harga Pangan di Kota Bandung. *Prosiding The 12th Industrial Research Workshop and National Seminar Bandung*.
[18] Baskara, A. K., Nazir, A., Irsyad, M., & Insani, F. 2023. Implementasi Data Mining Memprediksi Penjualan Crude Palm Oil Berdasarkan Kapasitas Tangki Menggunakan Multiple Linear Regression. *Jurnal Sistem Komputer dan Informatika*, 4(3), 493-502.
[19] Sari, Y. & Winarni, E. 2022. Perbandingan Kinerja Peramalan Kurs di Indonesia. *Ekonomis: Journal of Economics and Business*. 6(1):60-68.
[20] Tanuwidjaja, K. & Widjaja, A. 2022. Prediksi dan Analisis Time Series pada Data Covid-19. *Jurnal Strategi*, 4(1), 144-158.