

TESIS

**ANALISIS PREDIKSI CURAH HUJAN DI WILAYAH KOTA SORONG
MENGGUNAKAN METODE TIME SERIES FORCASTING**



Disusun oleh :

Nama : Muhammad Yusuf

NIM : 19.77.1175

Konsentrasi : Informatics Technopreneurship

**PROGRAM STUDI PJJ S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2022

TESIS

**ANALISIS PREDIKSI CURAH HUJAN DI WILAYAH KOTA SORONG
MENGGUNAKAN METODE TIME SERIES FORCASTING**

**RAINFALL PREDICTION ANALYSIS IN SORONG CITY AREA USING
THE TIME SERIES FORCASTING METHOD**

Diajukan untuk memenuhi salah satu syarat memperoleh gelar Magister Komputer



Disusun oleh :

Nama : Muhammad Yusuf

NIM : 19.77.1175

Konsentrasi : Informatics Technopreneurship

**PROGRAM STUDI PJJ S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2022**

HALAMAN PENGESAHAN

ANALISIS PREDIKSI CURAH HUJAN DI WILAYAH KOTA SORONG MENGGUNAKAN METODE TIME SERIES FORCASTING

RAINFALL PREDICTION ANALYSIS IN SORONG CITY AREA USING THE TIME SERIES FORCASTING METHOD

Dipersiapkan dan Disusun oleh

MUHAMMAD YUSUF

19.77.1175

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Rabu, tanggal 03 Agustus 2022

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 03 Agustus 2022
Rektor

Prof. Dr. M. Suyanto, M.M.
NIK. 190302001

HALAMAN PERSETUJUAN

ANALISIS PREDIKSI CURAH HUJAN DI WILAYAH KOTA SORONG MENGGUNAKAN METODE TIME SERIES FORCASTING

RAINFALL PREDICTION ANALYSIS IN SORONG CITY AREA USING THE TIME SERIES FORCASTING METHOD

Dipersiapkan dan Disusun oleh

MUHAMMAD YUSUF

19.77.1175

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Rabu, tanggal 03 Agustus 2022

Pembimbing Utama

Anggota Tim Penguji

Dr. Arief Setyanto, S.Si., M.T.
NIK. 190302036

Prof. Dr. Kusrini, M.Kom.
NIK. 190302106

Pembimbing Pendamping

Dr. Andi Sunyoto, M.Kom.
NIK. 190302052

Komang Aryasa, S.Kom, M.T.
NIK. 190302567

Dr. Arief Setyanto, S.Si., M.T.
NIK. 190302036

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 03 Agustus 2022
Direktur Program Pascasarjana

Prof. Dr. Kusrini, M.Kom.
NIK. 190302106

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

**Nama mahasiswa : Muhammad Yusuf
NIM : 19.77.1175
Konsentrasi : Informatics Technopreneurship**

Menyatakan bahwa Tesis dengan judul berikut:

Analisis Prediksi Curah Hujan Di Wilayah Kota Sorong Menggunakan Metode Time Series Forcasting

Dosen Pembimbing Utama : Dr. Arief Setyanto, S.Si., M.T.
Dosen Pembimbing Pendamping : Komang Aryasa. S.Kom, M.T.

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis, dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta.
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, 03 Agustus 2022

Yang Menyatakan,



Muhammad Yusuf

HALAMAN PERSEMBAHAN

Tesis ini dipersembahkan untuk kedua orang tua saya yaitu Ayah saya Sahabuddin Ismail dan Ibu saya Maryati Latief, serta istri saya Nur Afiah, A.Md. dan anak-anak saya Muhammad Alfin Zulfikrah Yusuf, Muhammad Abizar Nurfattah Yusuf dan Athiyya Naira Salsabila **atas** pengertian, dukungan serta kesabaran kepada saya dalam proses perkuliahan dan penyelesaian tesis. Banyak waktu keluarga yang dikorbankan tapi saya yakin semua ini untuk kebaikan kita bersama dan berguna pada waktu yang akan datang.



HALAMAN MOTTO

"Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya. Dia mendapat (pahala) dari (kebijakan) yang dikerjakannya dan dia mendapat (siksa) dari (kejahatan) yang diperbuatnya."

(Al Quran Surat Al Baqarah : 286)

"Terus berpikiran positif, tidak peduli seberapa keras kehidupan yang dijalani."

(Ali bin Abi Thallib)



KATA PENGANTAR

Pertama, penulis mengucapkan terima kasih kepada Allah, SWT, Tuhan Yang Maha Kuasa, atas rahmat dan hidayah yang diberikan sehingga penelitian ini bisa diselesaikan. Terima kasih yang sebesar-besarnya kepada Direktur Program Pascasarjana Ibu Prof. Dr. Kusrini, M.Kom, Dosen Pembimbing Bapak Dr. Arief Setyanto, S.Si., M.T. dan Bapak Komang Aryasa, S.Kom, M.T.. Terima kasih atas saran dan koreksi dari dosen penguji Ibu Prof. Dr. Kusrini, M.Kom, Bapak Dr. Andi Sunyoto, M.Kom., Bapak Dhani Ariatmanto, M.Kom, Ph.D. dan Bapak Dr. Arief Setyanto, S.Si., M.T. dalam proses penyempurnaan tesis ini.

Ucapan terima kasih juga kepada Orang Tua dan Istri Nur Afiah, A.Md atas dukungan dalam penyelesaian tesis ini. Terima kasih juga kepada PT. Biro Klasifikasi Indonesia (Persero) Cabang Pratama Klas Sorong dan Universitas Muhammadiyah Sorong (Unamin) yang telah memberikan kesempatan dan ijin untuk mengikuti perkuliahan sampai pada proses penyelesaian tesis ini. Akhir kata, tidak ada gading ya tak retak, tidak ada yang sempurna dari setiap usaha yang telah dilakukan, namun setiap kerja keras akan membawa hasil berupa kesuksesan dan kebahagiaan yang merupakan anugerah terbesar dalam hidup.

Yogyakarta, 03 Agustus 2022

Penulis

DAFTAR ISI

HALAMAN JUDUL.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERSETUJUAN.....	iv
HALAMAN PERNYATAAN KEASLIAN TESIS	v
HALAMAN PERSEMBAHAN	vi
HALAMAN MOTTO.....	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	ix
DAFTAR TABEL.....	xii
DAFTAR GAMBAR	xiii
INTI SARI.....	xv
<i>ABSTRACT</i>	xvi
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah.....	6
1.3 Batasan Masalah	6
1.4 Tujuan Penelitian	7
1.5 Manfaat Penelitian	7
BAB II LANDASAN TEORI	9
2.1 Tinjauan Pustaka.....	9
2.2 Landasan Teori.....	13

2.2.1	Peramalan.....	13
2.2.2	<i>Time Series Datamining</i>	14
2.2.3	Curah Hujan.....	14
2.2.4.	<i>Long Short Term Memory (LSTM)</i>	15
2.2.5	<i>Facebook Prophet</i>	18
2.2.6	Root Mean Square Error (RMSE).....	19
2.2.7	Mean Absolute Error (MAE).....	20
2.3	Keaslian Penelitian.....	21
BAB III METODE PENELITIAN		28
3.1	Jenis, Sifat, dan Pendekatan Penelitian.....	28
3.2	Alur Penelitian	28
3.3	Alur Pengolahan Data.....	29
3.3.1	Metode Pengumpulan Data.....	31
3.3.2	Metode Preprocessing Data	31
3.3.3	Metode Pemodelan Analisis Data	32
3.3.4	Algoritma <i>Long Short Term Memory</i>	33
3.3.5	Algoritma <i>FB Prophet</i>	36
3.3.6	Evaluasi Algoritma	37
3.3.7	Kesimpulan dan Saran	38
BAB IV HASIL DAN PEMBAHASAN		39
4.1	Hasil Preprocessing Data	39
4.2	Hasil Model Analisis Data	42
4.2.1	Mengimpor Library.....	42

4.2.2	Melihat Penyebaran Dataset	43
4.2.3	<i>Exploratory Data Analysis (EDA)</i>	44
4.2.4	Visualisasi Data dengan Rekayasa Fitur.....	46
4.2.5	Visualisasi Data dengan Pengujian Stasioneritas ADF	47
4.2.6	Visualisasi Data dengan ACF dan PACF	48
4.2.7	Pemodelan Data	50
4.2.7.1	Skenario 1 : 70% data latih dan 30% data uji	51
4.2.7.2	Skenario 2 : 80% data latih dan 20% data uji	52
4.2.7.3	Skenario 3 : 85% data latih dan 15% data uji	52
4.2.7.4	<i>Long Short Term Memory (LSTM)</i>	53
4.2.7.5	<i>Facebook Prophet</i>	55
4.3	Evaluasi Algoritma	56
4.4	Perbandingan Hasil dengan Penelitian Sebelumnya.....	57
BAB V PENUTUP	61
5.1.	Kesimpulan	61
5.2.	Saran	62
DAFTAR PUSTAKA	63
LAMPIRAN	67

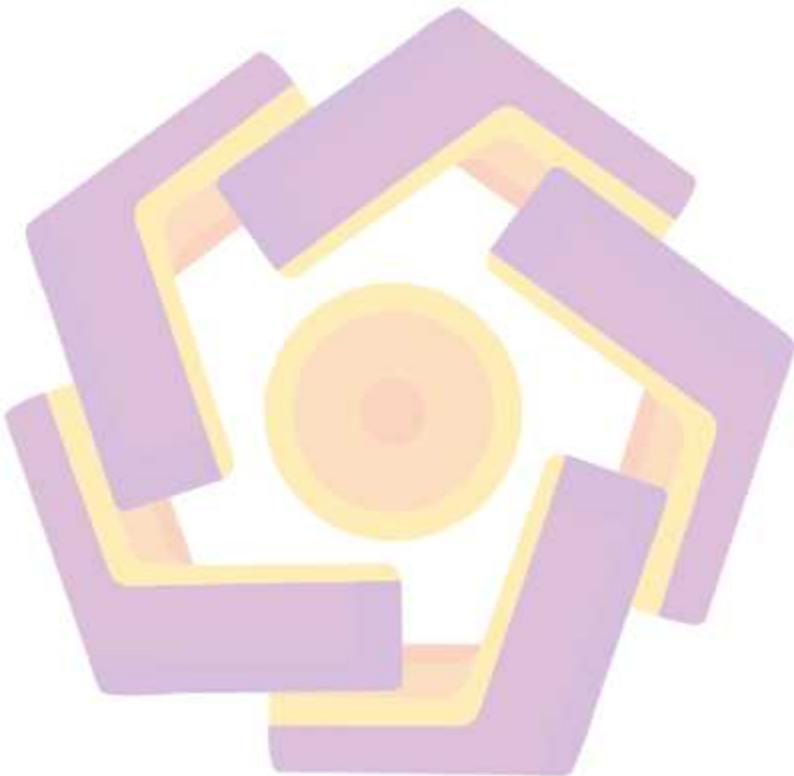
DAFTAR TABEL

Tabel 2.1 Matriks literatur review dan posisi penelitian.....	21
Tabel 4.1 Hasil evaluasi pengukuran tingkat kesalahan pada algoritma LSTM dan FB Prophet.....	57
Tabel 4.2 Perbandingan nilai tingkat pengukuran kesalahan pada algoritma LSTM dengan penelitian sebelumnya.....	59
Tabel 4.3 Perbandingan nilai tingkat pengukuran kesalahan pada algoritma LSTM menggunakan dataset penelitian sebelumnya.....	59
Tabel 4.4 Perbandingan nilai tingkat pengukuran kesalahan pada algoritma LSTM menggunakan teknik preprocessing dataset penelitian sebelumnya ..	60

DAFTAR GAMBAR

Gambar 3.1 Alur Penelitian.....	29
Gambar 3.2 Alur Pengolahan Data	30
Gambar 3.3 Sell Memory LSTM	29
Gambar 3.4 Arsitektur LSTM Permalan Curah Hujan Kota Sorong.....	30
Gambar 3.5 Skema pendekatan <i>forecasting at scale</i> pada FB Prophet	29
Gambar 4.1 Tampilan nilai tabel kosong pada dataset di excel.....	40
Gambar 4.2 Tampilan jumlah data terisi.....	40
Gambar 4.3 Tampilan jumlah data yang hilang.....	41
Gambar 4.4 Tampilan proses pengisian nilai median	41
Gambar 4.5 Tampilan hasil pengisian nilai median.....	42
Gambar 4.6 Penyimpanan file dataset baru.....	42
Gambar 4.7 Tampilan penyebaran nilai dataset yang dimiliki	43
Gambar 4.8 Tampilan penyebaran nilai dataset curah hujan.....	43
Gambar 4.9 Tampilan <i>EDA Non Graphical</i>	44
Gambar 4.10 Tampilan fitur curah hujan Kota Sorong.....	45
Gambar 4.11 Tampilan Transformasi ADF dan Density	47
Gambar 4.12 Tampilan <i>autocorrelation</i> curah hujan Kota Sorong	48
Gambar 4.13 Tampilan ACF dan PACF	48
Gambar 4.14 <i>Cross validation of dataset</i>	51
Gambar 4.15 Tampilan hasil pembagian data Skenario 1.....	52
Gambar 4.16 Tampilan hasil pembagian data Skenario 2.....	52

Gambar 4.17 Tampilan hasil pembagian data Skenario 3.....	53
Gambar 4.18 Model loss data pada LSTM	54
Gambar 4.19 Grafik hasil peramalan, nilai RMSE dan MAE pada LSTM	55
Gambar 4.20 Grafik hasil peramalan, nilai RMSE dan MAE pada FB Prophet. .	56



INTI SARI

Dampak negatif dari perubahan iklim (*climate change*) adalah meningkatnya kejadian bencana alam (*natural disaster*) di seluruh dunia termasuk Indonesia terutama bencana banjir (*flooding*), tanah longsor (*land slide*) dan kekeringan (*drought*). Kejadian serupa pun sering terjadi di Provinsi Papua Barat khususnya wilayah Kota Sorong yang merupakan salah satu kota yang memiliki iklim hutan hujan tropis, dengan curah hujan bulanan rata-rata 262,41 mm. Jumlah hari hujan dalam setiap bulan berkisar antara 9 hingga 29, sehingga menyebabkan Kota Sorong rentan terhadap banjir yang disebabkan oleh naiknya permukaan air laut serta curah hujan yang berlebihan. Oleh sebab itu pentingnya dilakukan penelitian terkait prediksi curah hujan menggunakan algoritma *time series forecasting* pada *machine learning*. Tujuan penelitian ini adalah untuk melakukan pemodelan prediksi curah hujan menggunakan metode *time series forecasting* dengan data *univariate time series* menggunakan algoritma *Long Short Term Memory (LSTM)* dan *FB Prophet* sehingga mendapatkan nilai pengukuran tingkat kesalahan menggunakan evaluasi berupa nilai *Root Mean Squar Error (RMSE)* dan *Mean Absolute Error (MAE)*.

Dataset diambil dari data iklim harian Statsium Meteorologi DEO Sorong yang ada pada web resmi BMKG yaitu dataonline.bmkg.go.id, selama 5 (lima) tahun mulai dari Januari tahun 2017 hingga Desember 2021. Setelah melakukan pemodelan *time series forecasting* menggunakan algoritma *Long Short Term Memory (LSTM)* dan *FB Prophet* dengan melakukan pengujian pembagian data (*split*) dimana skenario 1 sebanyak 70% data latih (*training*) dan 30% data uji (*testing*), skenario 2 sebanyak 80% data latih (*training*) dan 20% data uji (*testing*), dan skenario 1 sebanyak 85% data latih (*training*) dan 15% data uji (*testing*), maka didapatkan hasil evaluasi pengukuran tingkat kesalahan dengan menggunakan skenario 2 adalah nilai *RMSE* pada *LSTM* sebesar 16,09 sedangkan pada *FB Prophet* sebesar 16,32 sehingga terdapat selisih sebesar 0,23 dan nilai *MAE* pada *LSTM* sebesar 11,76 sedangkan pada *FB Prophet* sebesar 12,12 sehingga terdapat selisih sebesar 0,36. Dari selisih hasil yang didapatkan pada *RMSE* dan *MAE* tersebut maka metode *time series forecasting* dengan algoritma *LSTM* lebih baik digunakan dalam melakukan peramalan curah hujan Kota Sorong dibandingkan algoritma *FB Prophet*. Namun selisih nilai evaluasi pengukuran tingkat kesalahan pada *LSTM* dan *FB Prophet* tersebut tidak terlalu signifikan.

Kata kunci: *Curah Hujan, Forecasting, LSTM, Prophet*.

ABSTRACT

The negative impact of climate change is the increasing incidence of natural disasters throughout the world, including Indonesia, especially floods, land slides and droughts. Similar incidents often occur in West Papua Province, especially the Sorong City area, which is one of the cities that has a tropical rain forest climate, with an average monthly rainfall of 262.41 mm. The number of rainy days in each month ranges from 9 to 29, making Sorong City vulnerable to flooding caused by rising sea levels and excessive rainfall. Therefore, it is important to conduct research related to rainfall prediction using time series forecasting algorithms in machine learning. The purpose of this study was to model rainfall predictions using the time series forecasting method with univariate time series data using the Long Short Term Memory (LSTM) and FB Prophet algorithms so that the error rate measurement value was obtained using a metric evaluation in the form of the Root Mean Squar Error (RMSE) value, and Mean Absolute Error (MAE).

The dataset is taken from the daily climate data of the DEO Sorong Meteorological Station which is available on the official BMKG website, namely dataonline.bmkg.go.id, for 5 (five) years starting from January 2017 to December 2021. After modeling time series forecasting using the Long Short algorithm Term Memory (LSTM) and FB Prophet by testing data sharing (split) where scenario 1 is 70% training data and 30% test data, scenario 2 is 80% training data and 20% data test (testing), and scenario 1 as much as 85% of training data (training) and 15% of test data (testing), then the results of the evaluation of the error rate measurement using scenario 2 are the RMSE value on the LSTM of 16,09 while on the FB Prophet of 16,32 so there is a difference of 0,23 and the MAE value on the LSTM is 11,76 while on the FB Prophet it is 12,12 so there is a difference of 0,36. From the difference in the results obtained on the RMSE and MAE, the time series forecasting method with the LSTM algorithm is better used in forecasting rainfall in Sorong City than the FB Prophet algorithm. However, the difference in the evaluation value of the error rate measurement on the LSTM and FB Prophet is not too significant.

Keyword: Rainfall, Forecasting, LSTM, Prophet.

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Suhu bumi yang semakin memanas (*global warming*) mengakibatkan terjadinya perubahan iklim (*climate change*) yang tidak menentu. Dampak negatif dari perubahan iklim (*climate change*) ini adalah meningkatnya kejadian bencana alam (*natural disaster*) di seluruh dunia termasuk Indonesia terutama bencana banjir (*flooding*), tanah longsor (*land slide*) dan kekeringan (*drought*). Kejadian serupa pun sering terjadi di Provinsi Papua Barat khususnya wilayah Kota Sorong.

Kota Sorong merupakan salah satu kota di Provinsi Papua Barat yang letaknya tidak jauh dari Pantai. Iklim wilayah ini adalah hutan hujan tropis, dengan curah hujan bulanan rata-rata 262,41 mm. Jumlah hari hujan dalam setiap bulan berkisar antara 9 hingga 29, dengan kelembaban rata-rata 84 persen. Suhu udara terendah di Kota Sorong sekitar 23,1°C, dan suhu udara tertinggi sekitar 33,7°C (Arief et al., 2019).

Karena curah hujan yang tinggi dan lokasi Kota Sorong yang berada pada koordinat Garis Lintang 00°51' Selatan dan Garis Bujur 131°15' Timur, sehingga sangat rentan terhadap banjir yang disebabkan oleh naiknya permukaan air laut serta curah hujan yang berlebihan. Adapun dampak terparah yang pernah terjadi di Kota Sorong akibat adanya curah hujan berlebih yaitu pada tahun 2020 lalu, dimana mengakibatkan bencana longsor yang menyebabkan 3 (tiga) orang meninggal dunia dan bencana banjir yang

merendam 3 (tiga) kecamatan di Kota Sorong yaitu Kecamatan Sorong (Kelurahan Klademak, Kelurahan Remu Utara), Kecamatan Sorong Utara (Kelurahan Malangkedi) dan Sorong Manoi (Kelurahan Malabutor) – sumber: bnpb.go.id (Jati, 2020).

Kondisi cuaca yang tidak menentu dan fluktuatif membuat peramalan curah hujan di Indonesia menjadi sulit, termasuk di Kota Sorong. Hal ini yang mendasari pentingnya dilakukan penelitian terkait peramalan curah hujan menggunakan algoritma *time series forecasting* pada *machine learning* yaitu selain untuk melakukan tindakan antisipasi dalam mengatasi dampak buruk kejadian bencana alam (*natural disaster*) juga dapat dimanfaatkan untuk bidang yang lain seperti pertanian dan perikanan yang erat kaitannya dengan prakiraan cuaca dan membutuhkan peramalan cuaca berupa curah hujan yang akurat dan cepat untuk melakukan berbagai kegiatan oleh nelayan atau petani. Masih banyak bidang pekerjaan lainnya yang membutuhkan peramalan cuaca dan curah hujan seperti pariwisata, jalur penerbangan udara dan pelayaran laut, perkebunan, kehutanan, konstruksi bangunan, perencanaan wilayah, kesehatan, bahkan olahraga.

Penelitian terkait peramalan dan memprediksi Curah Hujan menggunakan algoritma *time series forecasting* telah dilakukan oleh beberapa peneliti, antara lain oleh (Papacharalampous et al., 2018), yang melakukan penelitian prediktabilitas suhu dan curah hujan bulanan dengan perbandingan metode peramalan deret waktu otomatis (*automatic time series forecasting*) antara lain menggunakan algoritma ARFIMA (*AutoRegressive Fractionally*

*Integrated Moving Average), BATS (Box-Cox transformation, ARMA errors, Trend and Seasonal components), Prophet, dan beberapa algoritma deret waktu lainnya seperti Naive, Random Walk, Simple Exponential Smoothing (SES), dan Theta, didapatkan hasil penelitian yaitu adanya kesalahan ramalan yang dihasilkan oleh metode tertentu sangat tergantung pada nilai yang akan diramalkan dan dari hasil perbandingan melalui nilai RMSE yang didapatkan maka prakiraan untuk setiap kelompok stasioneritas presipitasi untuk daerah *Globe* kinerja ARFIMA lebih baik dengan nilai RMSE 41,67, untuk daerah *North America* kinerja ARFIMA juga lebih baik dengan nilai RMSE 45,16, untuk daerah *North Europe* kinerja SES dan Theta lebih baik dengan nilai RMSE 36,30, untuk daerah *North Africa* kinerja BATS lebih baik dengan nilai RMSE 45,15 namun SES dan Theta mendapatkan nilai tidak terlalu jauh berbeda dengan nilai yang didapatkan BATS tersebut yaitu nilai RMSE 45,17, untuk daerah *South Africa* kinerja ARFIMA lebih baik dengan nilai RMSE 48,20, untuk daerah *East Asia* kinerja Prophet lebih baik dengan nilai RMSE 47,08 dan untuk daerah *Australia* kinerja SES dan Theta lebih baik dengan nilai RMSE 36,16. Hasil kesimpulan penelitian ini bahwa: semua metode yang diperiksa selain dari metode Niave dan Random Walk cukup akurat untuk digunakan dalam aplikasi jangka panjang, selain itu metode Prophet bersifat kompetitif, terutama jika dikombinasikan dengan dekomposisi musiman klasik yang diterapkan secara eksternal.*

Penelitian tentang perubahan iklim juga pernah dilakukan untuk memprediksi kekeringan di bidang pertanian menggunakan metode *Support*

Vector Regression (SVR) oleh (Tian et al., 2018), penelitian ini mengamati hubungan antara kelembapan tanah dan indeks kekeringan pertanian dengan skala yang berbeda di DAS Xiangjiang. Berdasarkan analisis pengaruh WPSH dan ENSO terhadap kekeringan, metode SVR yang menggabungkan indeks kekeringan pertanian dengan indeks iklim untuk mendapatkan prediksi kekeringan pertanian, dimana SPEI dengan skala enam bulan dapat mencerminkan kelembapan tanah lebih baik dalam menentukan prediksi kekeringan. Hasil yang didapatkan bahwa metode SVR yang menggabungkan indeks iklim dapat meningkatkan akurasi prediksi dibandingkan dengan menggunakan indeks kekeringan saja. Metode SVR terbukti efektif dan fleksibel dalam melakukan prediksi indeks kekeringan pertanian.

Penelitian Prediksi Iklim juga pernah dilakukan oleh (Jagannathan & Divya, 2021) menggunakan analisis deret waktu dengan metode *enhanced multivariate prophet*. Dalam penelitian ini dilakukan prediksi iklim dengan dataset suhu menggunakan algoritma deret waktu yaitu *Enhanced Multivarite Prophet*. Data historis iklim telah diambil dengan dataset suhu, kecepatan angin, kelembaban, curah hujan dan tekanan. Dalam proses pemodelan, data telah dilatih dan diuji dengan berbagai algoritma deret waktu antara lain dengan Auto *ARIMA*, *LSTM*, *Prophet* dan *Enhanced Multivariate Prophet (EMP)*, didapatkan hasil evaluasi model algoritma EMP memberikan akurasi yang sangat baik sebesar 99,9% dibandingkan dengan algoritma prediksi deret waktu lainnya, dimana nilai MAE dan RMSE algoritma EMP adalah 0,02.

Penelitian Prediksi Iklim yaitu Suhu Udara pernah dilakukan oleh (Toharudin et al., 2020) menggunakan metode *Long Short Term Memory (LSTM)* dan *Facebook Prophet*. Dalam penelitian ini penulis menggunakan dua model dataset suhu udara, proses pelatihan dan pengujian data dimana komposisi 80% untuk data latih dan 20% untuk data uji. Pada LSTM, inisialisasi parameter dilakukan secara *trial and error*. Didapatkan hasil RMSE suhu udara minimum untuk LSTM dengan nilai 0,94 dan Prophet dengan nilai 1,04 dan hasil RMSE suhu udara maksimum untuk LSTM dengan nilai 1,23 dan Prophet dengan nilai 1,03. Model terbaik untuk suhu udara maksimum adalah menggunakan algoritma Prophet sedang model terbaik untuk suhu udara minimum adalah menggunakan algoritma LSTM.

Oleh karena itu dalam penelitian ini penulis akan melakukan pemodelan peramalan deret waktu pada curah hujan menggunakan metode *univariate time series forecasting* pada *machine learning* yaitu menggunakan algoritma *Long Short Term Memory (LSTM)* dan *FB Prophet*. Pemodelan yang dilakukan menggunakan algoritma *Long Short Term Memory (LSTM)* dan *FB Prophet* oleh penulis diharapkan dapat digunakan dalam memprediksi curah hujan di wilayah Kota Sorong dengan menggunakan dataset harian curah hujan pada stasiun meteorologi Domine Edward Osok (DEO) diambil dari web dataonline.bmkg.go.id.

Berdasarkan hal tersebut maka penulis mengangkat judul penelitian: ***“Analisis Prediksi Curah Hujan Di Wilayah Kota Sorong Menggunakan Metode Time Series Forcasting”***.

1.2 Rumusan Masalah

Berdasarkan latar belakang diatas, maka perumusan masalah yang ada pada penelitian ini yaitu:

1. Apa yang baik digunakan dalam memodelkan peramalan curah hujan di wilayah Kota Sorong antara algoritma *Long Short Term Memory (LSTM)* dan *FB Prophet*?
2. Bagaimana melakukan perbandingan metode *time series forecasting* menggunakan *Long Short Term Memory (LSTM)* dan *FB Prophet* dalam memodelkan peramalan (*forecasting*) curah hujan di wilayah Kota Sorong?
3. Berapa nilai hasil mengukur tingkat kesalahan menggunakan evaluasi metrik pada metode *time series forecasting* dengan algoritma *Long Short Term Memory (LSTM)* dan *FB Prophet* dalam melakukan peramalan curah hujan di Kota Sorong?

1.3 Batasan Masalah

Adapun batasan masalah dalam penelitian ini yaitu:

1. Penggunaan data parameter curah hujan yang diambil berupa data harian selama 5 (lima) tahun dari Januari tahun 2017 sampai dengan Desember tahun 2021.
2. Dataset Curah Hujan Kota Sorong pada stasiun Meteorologi Domine Edward Osok (DEO) diambil dari web dataonline.bmkg.go.id
3. Metode *Time Series Forecasting* yang digunakan adalah *univariate time series* dengan algoritma *Long Short Term Memory (LSTM)* dan *Prophet*.

4. Evaluasi berupa nilai pengukuran tingkat kesalahan yang digunakan adalah *Root Mean Square Error (RMSE)* dan *Mean Absolute Error (MAE)*.
5. Pada algoritma *Long Short Term Memory (LSTM)*, *Hyperparameter tuning* yang dilakukan adalah menggunakan teknik *epoch* dengan perintah *early stopping epoch*.

1.4 Tujuan Penelitian

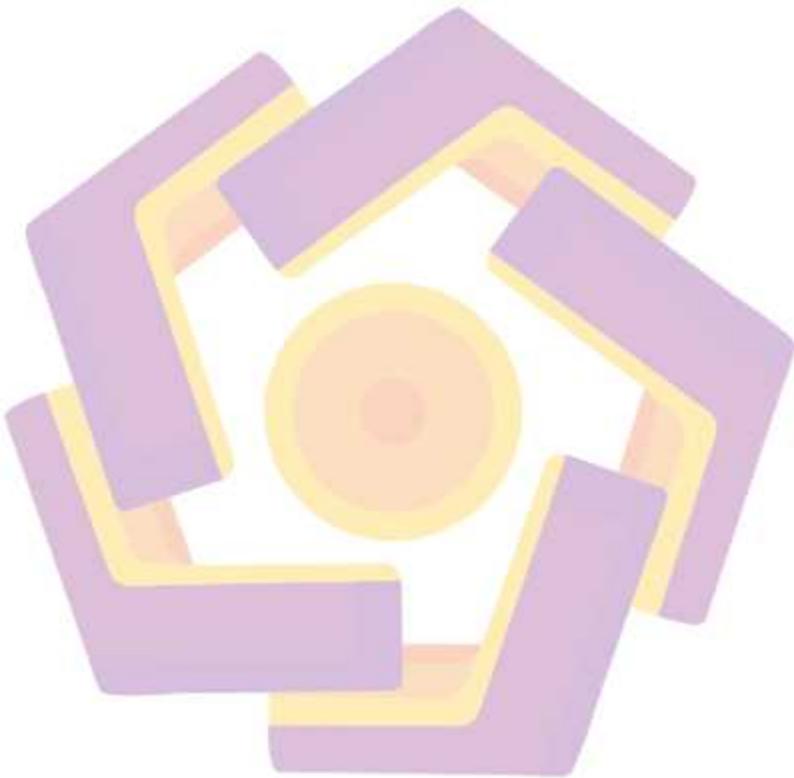
Tujuan dari pelaksanaan penelitian ini sebagai berikut:

1. Mendapatkan perbandingan model mana lebih baik antara algoritma *Long Short Term Memory (LSTM)* dan *FB Prophet*.
2. Melakukan perbandingan pemodelan peramalan (*forecasting*) curah hujan menggunakan metode *time series forecasting* dengan data *univariate time series* pada algoritma *Long Short Term Memory (LSTM)* dan *FB Prophet*, menggunakan skenario pembagian data latih dan data training pada dataset.
3. Mendapatkan nilai pengukuran tingkat kesalahan menggunakan evaluasi metrik pada metode *time series forecasting* dengan algoritma *Long Short Term Memory (LSTM)* dan *FB Prophet* yaitu nilai *Root Mean Square Error (RMSE)* dan *Mean Absolute Error (MAE)*.

1.5 Manfaat Penelitian

Berikut adalah manfaat yang diharapkan dapat diperoleh dari penelitian ini yaitu:

1. Dapat menghasilkan peramalan (*forecasting*) curah hujan di Kota Sorong dengan metode deret waktu untuk harian, bulanan bahkan tahunan.
2. Dapat mengetahui metode deret waktu (*time series forecasting*) dalam memprediksi curah hujan di Kota Sorong.



BAB II

LANDASAN TEORI

2.1 Tinjauan Pustaka

Penelitian terkait analisis peramalan (*forecasting*) dan prediksi curah hujan telah dilakukan oleh beberapa peneliti sebelumnya, diantaranya oleh (Freecenta et al., 2022) yang melakukan prediksi curah hujan di Kabupaten Malang menggunakan *Long Short Term Memory* (LSTM), data yang digunakan adalah dataset curah hujan pada daerah di Kabupaten Malang dari mulai Januari 2010 sampai dengan 25 Januari 2021, dalam proses model menggunakan algoritma LSTM dilakukan skenario uji coba pertama dengan 4 layer LSTM dimana masing-masing layer terdapat 100 neuron, skenario uji coba kedua dengan 2 layer LSTM dimana masing-masing layer terdapat 50 neuron, pada skenario 1 didapatkan akurasi sebesar 54,31% dimana hasil terbaik didapat pada epoch 100 karena mendapatkan nilai paling kecil dari epoch lainnya dengan nilai MAE sebesar 7,55, RMSE sebesar 14,07, dan MSE sebesar 197,97. Pada skenario 2 didapatkan hasil akurasi sebesar 58,54 dimana hasil terbaik di dapat pada epoch 150 karena mendapatkan nilai paling kecil dari epoch lainnya dengan nilai MAE sebesar 7,90, RMSE sebesar 10,16, dan MSE sebesar 103,37.

Penelitian lainnya untuk prediksi curah hujan menggunakan metode LSTM telah dilakukan juga oleh (Poornima & Pushpalatha, 2019), pada penelitian ini dilakukan prediksi curah hujan menggunakan *Intensified LSTM Based Recurrent Neural Network (RNN)*. Dataset yang digunakan adalah data

curah hujan wilayah Hyderabad mulai tahun 1980 sampai dengan tahun 2014. Dari data ini dilakukan model pembagian data latih dan data uji dimana data curah hujan tiga puluh empat tahun dari tahun 1980 hingga 2013 digunakan sebagai dataset untuk pelatihan model RNN berbasis LSTM dan dataset tahun 2014 digunakan sebagai dataset untuk pengujian, dimana variabel eksperimen yang digunakan adalah suhu maksimum, suhu minimum, kelembaban relatif maksimum, kelembaban relatif minimum, kecepatan angin, sinar matahari dan evapotranspirasi dan varibel hasil adalah curah hujan. Dari hasil perbandingan kinerja didapatkan model *Intensified LSTM* memiliki akurasi yang lebih baik sebesar 88% dari model lainnya *ARIMA*, *ELM*, *RNN* dan *LSTM*, dimana nilai RMSE dari *Intensified LSTM* adalah 0,33 namun nilai RMSE dari *LSTM* tidak terlalu jauh dengan nilai RMSE dari *Intensified LSTM* yaitu sebesar 0,35.

Penelitian lainnya untuk prediksi curah hujan menggunakan metode *Prophet* telah dilakukan juga oleh (Papacharalampous et al., 2018), penelitian ini melakukan prediktabilitas suhu dan curah hujan bulanan dengan perbandingan metode peramalan dengan deret waktu otomatis (*automatic time series forecasting*) antara lain menggunakan Algoritma *ARFIMA* (*AutoRegressive Fractionally Integrated Moving Average*), *BATS* (*Box-Cox transformation, ARMA errors, Trend and Seasonal components*), *Prophet*, dan beberapa algoritma deret waktu lainnya seperti *Naive*, *Random Walk*, *Simple Exponential Smoothing (SES)*, dan *Theta*. Pada penelitian ini didapatkan hasil penelitian bahwa kinerja *Prophet* memiliki hasil nilai RMSE

yang lebih baik pada wilayah stasionari *East Asia* dengan nilai RMSE 47,08. Hasil kesimpulan penelitian ini bahwa semua metode yang diperiksa selain dari metode *Niave* dan *Random Walk* cukup akurat untuk digunakan dalam aplikasi jangka panjang, selain itu metode *Prophet* bersifat kompetitif, terutama jika dikombinasikan dengan dekomposisi musiman klasik yang diterapkan secara eksternal.

Penelitian lainnya telah dilakukan oleh (Toharudin et al., 2020) untuk melakukan prediksi iklim yaitu suhu udara menggunakan metode *Long Short Term Memory (LSTM)* dan *Facebook Prophet*. Dalam penelitian ini penulis menggunakan dua model dataset suhu udara, proses pelatihan dan pengujian data dimana komposisi 80% untuk data latih dan 20% untuk data uji. Pada LSTM, inisialisasi parameter dilakukan secara *trial and error*. Didapatkan hasil RMSE suhu udara minimum untuk *LSTM* dengan nilai 0,94 dan *Prophet* dengan nilai 1,04 dan hasil RMSE suhu udara maksimum untuk *LSTM* dengan nilai 1,23 dan *Prophet* dengan nilai 1,03. Model terbaik untuk suhu udara maksimum adalah menggunakan algoritma *Prophet* sedangkan model terbaik untuk suhu udara minimum adalah menggunakan algoritma *LSTM*.

Selain penelitian terkait prediksi iklim dan curah hujan menggunakan metode *LSTM* dan *Prophet* yang telah dijelaskan sebelumnya, terdapat pula penelitian menggunakan pendekatan metode *hybrid LSTM – Prophet* untuk melakukan prediksi indeks kualitas udara oleh (Zhoul et al., 2020), penggunaan model *hybrid LSTM – Prophet* untuk mengoptimalkan akurasi prediksi model *Prophet*. Data yang digunakan oleh penulis adalah data rata-

rata harian stasiun pemantauan kualitas udara Nanjing dari 01 Juni 2014 hingga 30 April 2020. Pada proses pemodelan dataset digunakan sejumlah 1811 set data mulai 01 Juni 2014 hingga 31 Mei 2019 sebagai data set latih dan 334 set data dari 01 Juni 2019 hingga 30 April 2020 sebagai data set uji untuk menguji efektifitas model. Didapatkan hasil bahwa model *hybrid Prophet – LSTM* memiliki kinerja terbaik, dimana akurasi prediksinya lebih tinggi yaitu memiliki nilai RMSE 10,56 dan MAE 5,47 daripada model tunggal *LSTM* yang memiliki nilai RMSE 13,47 dan MAE 6,13, dan *Prophet* yang memiliki nilai RMSE 26,15 dan MAE 18,47.

Penelitian menggunakan metode *ARIMA*, *LSTM* dan *Prophet* juga telah dilakukan oleh (Ning et al., 2022) dalam memprediksi penurunan produksi minyak dari sebuah sumur yang terletak di Denver-Julesburg (DJ) Basin, Colorado. Dataset diambil berupa dataset deret waktu stasioner dari data produksi minyak pada bulan September 2013 hingga September 2020. 70% data yang terdiri dari 60 data penting selama enam tahun pertama, digunakan sebagai dataset latih sementara sisanya 30% dari data produksi dua tahun digunakan untuk prediksi. Didapatkan hasil evaluasi data RMSE untuk model *ARIMA* sebesar 4,97, model *LSTM* sebesar 2,96 dan model *Prophet* sebesar 2,32. Hal ini menunjukkan bahwa model *Prophet* mampu memprediksi tren penurunan produksi minyak dengan RSME terendah dari model lainnya, model *Prophet* juga mampu mengungkapkan potensi efek musiman yang akan sangat membantu operator untuk mencegah kemungkinan guncangan suhu yang telah terjadi dan mungkin terjadi lagi.

Berdasarkan beberapa penelitian diatas, maka penulis mencoba melakukan Analisis Prediksi Curah Hujan di Kota Sorong menggunakan metode *Time Series Forecasting* yaitu *Long Short Term Memory (LSTM)* dan *FB Prophet*.

2.2 Landasan Teori

2.2.1 Peramalan

Peramalan adalah tindakan memprediksi secara metodis sesuatu yang paling mungkin terjadi di masa depan berdasarkan pengetahuan sebelumnya dan saat ini sehingga kesalahan (selisih antara apa yang terjadi dan apa yang diharapkan) dapat dikurangi. Prediksi tidak harus menawarkan jawaban secara pasti melainkan berusaha untuk mencari jawaban sedekat mungkin terhadap sesuatu yang akan terjadi (Kafil, 2019). Prediksi atau peramalan dalam *data mining* bisa dilakukan dengan metode *time series* dimana data dikumpulkan selama periode waktu tertentu seperti harian, mingguan, bulanan, triwulan, tahunan (Aftab et al., 2018), sehingga data ini bisa memprediksi berbagai domain termasuk bidang klimatologi diantaranya prediksi curah hujan. Prediksi curah hujan merupakan aspek penting dari prakiraan iklim, dimana hasil akurat dan tepat waktu akan membantu untuk perencanaan dan pengelolaan sumber daya air, peringatan banjir, kegiatan konstruksi, operasi penerbangan, dan lain sebagainya.

2.2.2 Time Series Datamining

Deret waktu (*Time Series*) adalah seperangkat nilai yang diturunkan dari pengukuran berturut-turut yang diambil dari waktu ke waktu. Kebutuhan untuk menegaskan kembali kapasitas alami manusia dalam memvisualisasikan bentuk data mendorong penambangan data deret waktu (*time series datamining*). Tujuan dari penambangan data deret waktu adalah untuk mencoba mengekstrak semua pengetahuan yang bermakna dari bentuk data yang memiliki deret waktu. Penambangan data deret waktu telah menjadi bidang studi yang terus berkembang dan merangsang para peneliti untuk terus-menerus melakukan penelitian dan memecahkan masalah penelitian terhadap penambangan data deret waktu selama dekade terakhir (Esling & Agon, 2012). Teknik penambangan data deret waktu saat ini diterapkan pada berbagai bidang yaitu ekonomi, pengawasan medis, prakiraan iklim, biologi, hidrologi, genetika, atau musik.

2.2.3 Curah Hujan

Curah hujan merupakan parameter iklim yang perilaku atau gejalanya tampak jelas akibat anomali iklim. Anomali iklim sering kali terjadi berulang berdasarkan ketergantungan dari dinamika atmosfer. Indikator dominan yang dapat digunakan untuk melihat gejala terjadinya suatu anomali iklim yaitu kelembapan udara dan Suhu Udara (Putramulyo & Alaa, 2018). Curah hujan dapat diukur menggunakan

alat penakar hujan dengan satuan millimeter (mm). Curah hujan dengan ukuran satu mm setara dengan jumlah satu liter/m² (Binternagel, 2009).

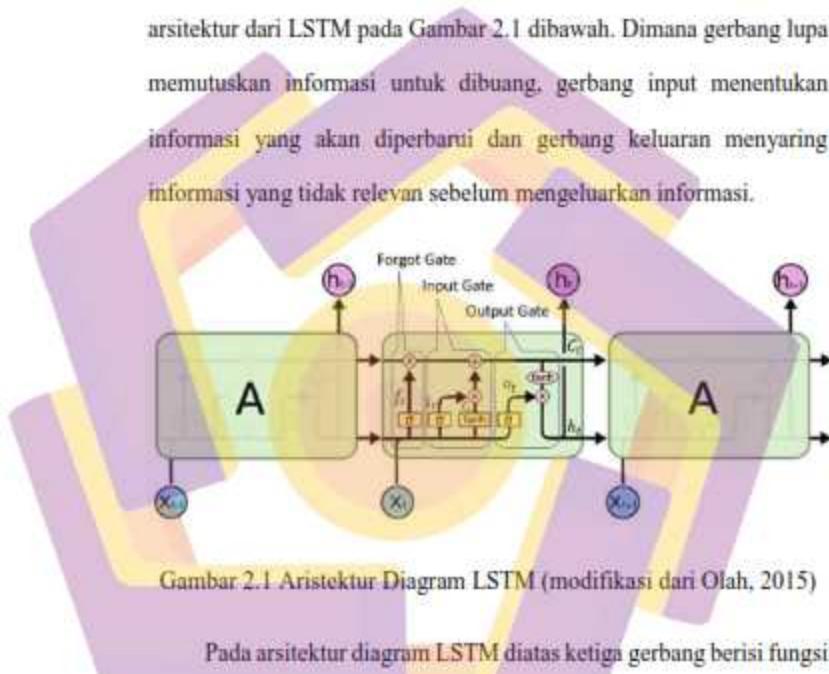
2.2.4 Long Short Term Memory (LSTM)

Long Short Term Memory (LSTM) atau jaringan syaraf *LSTM* merupakan varian baru dari model jaringan syaraf berulang (*RNN*) yang diusulkan oleh Sepp Hochreiter dan Jurgen Schmidhuber pada tahun 1997 (Sepp Hochreiter, 1997) untuk memecahkan masalah hilangnya gradien atau ledakan yang disebabkan oleh kelebihan panjang set pelatihan dalam jaringan saraf berulang (*RNN*), dimana *LSTM* dapat mempertimbangkan ketergantungan jangka panjang dan jangka pendek dengan baik. *RNN* meneruskan informasi pada waktu t ke waktu t+1 melalui lingkaran. Namun, itu akan mengekspos ketidakmampuan menggunakan informasi masa lalu secara efektif ketika deret waktu terlalu panjang. Berdasarkan pada ide arsitektur *RNN*, *LSTM* menambahkan gerbang lupa, gerbang input, dan gerbang output, untuk memilih informasi, menyimpan informasi penting dan menyaring informasi yang tidak relevan pada hasil prediksi. (Zhou et al., 2020).

Long Short Term Memory (LSTM) atau jaringan syaraf *LSTM* merupakan varian baru dari model jaringan syaraf berulang (*RNN*). Sebuah jaringan saraf berulang (*RNN*) adalah jaringan saraf yang sangat terkait menggunakan pola periodik untuk menganalisis masukan. Biasanya, *RNN* mengalami kesulitan gradien menghilang dan

mengembang, membuat pembelajaran ketergantungan jangka panjang menjadi sulit.

Untuk mengatasi masalah ini, *LSTM* menggabungkan unit atau sel memori ke dalam jaringan. Seperti yang ditunjukkan dalam diagram arsitektur dari *LSTM* pada Gambar 2.1 dibawah. Dimana gerbang lupa memutuskan informasi untuk dibuang, gerbang input menentukan informasi yang akan diperbarui dan gerbang keluaran menyaring informasi yang tidak relevan sebelum mengeluarkan informasi.



Pada arsitektur diagram LSTM diatas ketiga gerbang berisi fungsi aktivasi seperti sigmoid (σ) atau fungsi $tanh$, memutuskan berapa banyak informasi yang akan diteruskan ke rantai urutan.

Gerbang pertama adalah gerbang lupa (f) memutuskan informasi apa yang akan dibuang dari keadaan sel sebelumnya C_{t-1} . Seperti persamaan berikut:

gerbang lupa mempertimbangkan keadaan tersembunyi dari sel *LSTM* sebelumnya (h_{t-1}) dan masukan dari langkah waktu saat ini (x_t), maka aktifasi *sigmoid* (σ) menekan nilai antara 0 dan 1. Kalikan nilai apa pun dengan nol, menyebabkan nilai ini “dilupakan”. Angka berapa pun dikalikan satu, menyebabkan nilai ini “disimpan”.

Gerbang kedua adalah gerbang input (i_i) menentukan informasi apa yang akan mengalir ke dalam dan disimpan dalam keadaan sel (C_i). Ini mencakup dua bagian. Lapisan *sigmoid* (σ) seperti pada persamaan berikut:

memutuskan nilai mana yang akan diperbarui, sedangkan lapisan *tanh* pada persamaan berikut:

mendorong nilai antara -1 dan 1 dan menciptakan nilai kandidat baru \hat{C}_i yang dapat ditambahkan ke status sel.

Langkah selanjutnya adalah melakukan perhitungan keadaan sel baru C_1 menggunakan persamaan berikut:

dimana informasi tertentu dari keadaan sel lama (C_{t-1}) dihilangkan dan informasi baru ditambahkan (C_t).

Gerbang ketiga adalah gerbang keluaran (o_3), memutuskan informasi apa yang akan diteruskan ke prediktor. Fungsi sigmoid (σ) pada persamaan berikut:

$$o_t = \sigma(W_\theta \cdot [h_{t-1}, x_t]) + b_\theta \dots \quad (5)$$

menjelaskan berapa banyak informasi yang akan dilewatkan, sedangkan fungsi \tanh pada persamaan berikut:

$$h_t = o_t * \tanh(C_t) \dots \quad (6)$$

memastikan nilai keadaan tersembunyi selalu dalam interval $(-1, 1)$. Karena tiga gerbang dalam setiap unit memori, *LSTM* dapat belajar ketergantungan yang lama. Dan pada akhirnya, keadaan tersembunyi terakhir yang diperoleh dari lapisan tersembunyi diteruskan ke lapisan keluaran untuk mendapatkan nilai prediksi. (Ning et al., 2022)

2.2.5 Facebook Prophet

FB Prophet adalah model peramalan otomatis yang bersifat *open source* yang dikembangkan oleh *Facebook* pada tahun 2017. Model ini mengkhususkan diri dalam pemodelan data deret waktu nonlinier dengan efek musiman dan hari libur tahunan/mingguan/harian. *Prophet* juga menangani data dan outlier yang hilang, yang membuat proses pencocokan hampir otomatis dan berkinerja lebih baik daripada pendekatan model lain (Ning et al., 2022). Model peramalan *Prophet* bisa dilihat pada persamaan berikut:

dimana $g(t)$ adalah kurva pertumbuhan linier atau logistik dari perubahan non-periodik, $s(t)$ adalah perubahan periodik seperti musiman tahunan, $h(t)$ adalah efek dari hari libur dan α adalah istilah kesalahan yang tidak diakomodasi oleh model-model lainnya.

2.2.6 Root Mean Square Error (RMSE)

RMSE merupakan metode evaluasi yang digunakan untuk mengetahui perbedaan antara nilai-nilai prediksi, antara model dengan nilai kebenaran yang diamati (Dewi et al., 2019). Melalui RMSE dapat diketahui besarnya penyimpangan yang terjadi antara nilai prediksi curah hujan dengan nilai curah hujan sebenarnya (*actual*). Semakin besar nilai RMSE maka semakin jauh nilai data total hujan prediksi terhadap total hujan sebenarnya. Semakin kecil nilai RMSE maka semakin baik prediksi total hujan terhadap total hujan sebenarnya. Tingkat kesalahan yang dapat diminimalisir dapat meningkatkan akurasi prediksi (Rumahorbo, 2020). Berikut adalah persamaan Root Mean Squar Error (RMSE):

$$RMSE = \left[\frac{1}{N} \sum_{n=1}^N (f_n - r_n)^2 \right]^{\frac{1}{2}} \quad (8)$$

Dimana:

r_n adalah data curah hujan hasil obeservasi

f_n adalah data curah hujan hasil prediksi

n adalah jumlah data

2.2.7 Mean Absolute Error (MAE)

Mean Absolute Error (MAE) merupakan salah satu pendekatan yang digunakan untuk menilai akurasi model peramalan. Angka MAE adalah rata-rata kesalahan absolut antara hasil prakiraan/prediksi dan nilai sebenarnya. (Suryanto, 2019). Berikut adalah persamaan Mean Absolute Error (MAE):

Dimana

f_t adalah nilai hasil peramalan

v, adalah nilai sebenarnya

n adalah jumlah data

2.3 Keaslian Penelitian

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian

“Analisis Prediksi Curah Hujan di Wilayah Kota Sorong Menggunakan Metode *Time Series Forecasting*”

No.	Judul	Peneliti, Media Publikasi, dan Tahun	Metode Penelitian	Kesimpulan	Perbandingan
1.	<i>Prediksi Curah Hujan di Kab. Malang Menggunakan LSTM (Long Short Term Memory)</i>	Helna Freccenta, Eva Yulla Puspaningrum, Hendra Maulana. Jurnal Informatika dan Sistem Informasi (JIFoSI) Vol.3, No.1, e-ISSN : 2772-130, UPN “Veteran” Jatim. April 2022	Penulis melakukan prediksi curah hujan di Kab. Malang menggunakan model LSTM (Long Short Term Memory) dengan dataset yang digunakan penulis adalah data iklim curah hujan dari Januari 2010 s/d 25 Desember 2021 yang diperoleh dari https://dataonline.bmkg.go.id/data_iklim Penulis melakukan dua skenario pengujian, yaitu skenario pertama dengan 4 layer LSTM dengan masing-masing layer terdapat 100	Nilai ukurasi model LSTM tertinggi yang didapatkan penulis selama penelitian adalah nilai MAE sebesar 7,90, nilai RMSE sebesar 10,16 dan nilai MSE sebesar 103,37.	Penelitian yang akan dilakukan sama yaitu akan memprediksi curah hujan, namun terdapat perbedaan metode yang digunakan dimana pada penelitian ini menggunakan metode LSTM sedangkan pada penelitian yang akan dilakukan oleh penulis adalah menggunakan metode LSTM dan FB Prophet.

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian (Lanjutan)

No.	Judul	Peneliti, Media Publikasi, dan Tahun	Metode Penelitian	Kesimpulan	Perbandingan
			neuron, dan skenario kedua dengan 2 layer LSTM dimana pada masing-masing layer terdapat 50 neuron.		
2.	<i>Prediction of Rainfall Using Intensified LSTM based Recurrent Neural Network with Weighted Linear Units.</i>	S. Poornima, M. Pushpalatha. Jurnal Atmosphare, Vol. 10, Issue 11. 2019	Penulis melakukan prediksi curah hujan menggunakan <i>intensified</i> LSTM berbasis RNN. RNN dilatih dan diuji menggunakan dataset standar curah hujan. Jaringan yang dilatih akan menghasilkan atribut prediksi curah hujan. Dataset yang digunakan penulis adalah dataset curah hujan wilayah Hyderabad mulai tahun 1980 s/d tahun 2014	Prediksi curah hujan menggunakan <i>intensified</i> LSTM berbasis RNN menunjukkan peningkatan prediksi curah hujan dibandingkan dengan metode lain seperti ARIMA, ELM, RNN dan LSTM. Dimana nilai RMSE yang didapatkan dalam penelitian ini adalah 0.33.	Penelitian yang akan dilakukan sama yaitu memprediksi curah hujan namun terdapat perbedaan metode yang digunakan dimana pada penelitian ini menggunakan metode <i>intensified</i> LSTM berbasis RNN sedangkan pada penelitian yang akan dilakukan oleh penulis adalah menggunakan metode LSTM dan FB Prophet.

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian (Lanjutan)

No.	Judul	Peneliti, Media Publikasi, dan Tahun	Metode Penelitian	Kesimpulan	Perbandingan
3.	<i>Predictability of Monthly Temperature and Precipitation Using Automatic Time Series Forecasting Methods.</i>	Georgia Papacharalampous, Hristos Tyralis, Demetris Koutsoyiannis. Jurnal Acta Geophysica, Vol. 66, Issue 4, Pages 807-831. https://doi.org/10.1007/s11600-018-0120-7 . 2018	Penulis melakukan prediktabilitas suhu dan curah hujan bulanan menggunakan metode <i>automatic time series forecasting</i> yaitu Naïve, Random Walk, ARFIMA, BATS, SES, Theta, dan Prophet. Dataset yang digunakan sebanyak 480 bulan dari tahun 1950 s/d 1989.	Hasil penelitian menunjukkan bahwa (a.) semua metode yang diperiksa selain dari metode naïve dan random walk cukup akurat untuk digunakan dalam aplikasi jangka panjang. (b.) suhu dan curah hujan bulanan dapat diramalkan ke tingkat akurasi yang hampir tidak dapat ditingkatkan dengan metode lain. (c.) dekomposisi musiman klasik yang diterapkan secara eksternal sebagian besar menghasilkan prakiraan yang lebih baik dibandingkan dengan dekomposisi musiman	Penelitian yang akan dilakukan sama yaitu memprediksi curah hujan namun terdapat perbedaan dimana pada penelitian ini menggunakan multivariate time series dimana menggunakan variabel suhu dan curah hujan sedangkan penelitian yang akan dilakukan oleh penulis hanya menggunakan univariate time series yaitu hanya curah hujan. Kelebihan dari penelitian yang akan dilakukan oleh penulis dibandingkan penelitian ini adalah penulis menggunakan dataset harian sedangkan penelitian ini

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian (Lanjutan)

No.	Judul	Peneliti, Media Publikasi, dan Tahun	Metode Penelitian	Kesimpulan	Perbandingan
				otomatis yang digunakan oleh metode BATS dan Prophet; (d.) Prophet bersifat kompetitif, terutama jika dikombinasikan dengan dekomposisi musiman klasik yang diterapkan secara eksternal.	menggunakan dataset bulanan.
4.	<i>Employing Long Short Term Memory and Facebook Prophet Model in Air Temperature Forecasting.</i>	Toni Toharudin, Resa Septiani Pontoh, Rczzy Eko Caraka, Solichatus Zahroh, Youngjo Lee, Rung Ching Chen. Communications in Statistics: Simulation and Computation https://doi.org/10.1080/03610918.2020.1854302 2020	Penulis melakukan peramalan suhu udara menggunakan metode LSTM dan Prophet. Dataset yang digunakan adalah variabel suhu udara maksimum dan minimum harian Kota Bandung dari tanggal 01 Januari 2014 sampai dengan 30 Juni 2019	Hasil penelitian menunjukkan Prophet bekerja lebih baik pada suhu udara maksimum sedangkan LSTM bekerja lebih baik pada suhu udara minimum. Namun perbedaan nilai RMSE yang didapatkan tidak terlalu signifikan dimana suhu udara maksimum nilai RMSE pada LSTM adalah	Penelitian yang dilakukan berbeda dimana pada penelitian ini menggunakan variabel suhu udara maksimum dan suhu udara minimum sedangkan penelitian yang akan dilakukan oleh penulis hanya menggunakan variabel curah hujan. Namun metode pemodelan

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian (Lanjutan)

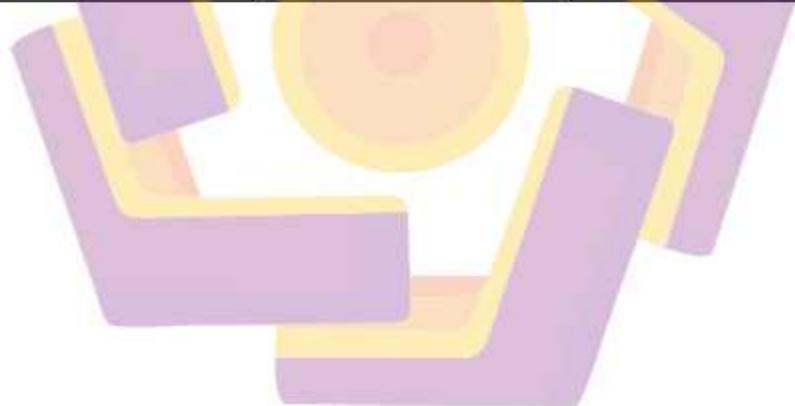
No.	Judul	Peneliti, Media Publikasi, dan Tahun	Metode Penelitian	Kesimpulan	Perbandingan
				1,23 dan Prophet adalah 1,03, sedangkan suhu udara minimum nilai RMSE pada LSTM adalah 0,94 dan Prophet 1,04.	peramalan yang digunakan sama yaitu LSTM dan FB Prophet.
5.	<i>Hybrid Prophet-LSTM Model for Prediction of Air Quality Index.</i>	Landi Zhou, Ming Chen, Qingjian Ni 2020 IEEE Symposium Series on Computational Intelligence (SSCI 2020), Pages : 595-601 2020	Penulis melakukan prediksi indeks kualitas udara menggunakan model Prophet-LSTM untuk mengoptimalkan akurasi prediksi model Prophet. Pada penelitian ini penulis menggunakan data dari China National Environmental Monitoring Center berupa data rata-rata harian stasiun pemantauan kualitas udara Nanjing dari 01 Juni 2014 hingga 30 April 2020 dengan total jumlah data adalah 2.145. Penulis membagi data latih sebanyak 1811 data mulai 01 Juni	Hasil penelitian menunjukkan bahwa model hybrid Prophet-LSTM memiliki kinerja terbaik, akurasi prediksinya lebih tinggi yaitu mendapatkan nilai RMSE 10,56 daripada model tunggal dimana nilai RMSE model tunggal Prophet adalah 26,15 dan LSTM adalah 13,47	Penelitian yang dilakukan berbeda dimana pada penelitian ini melakukan prediksi indeks kualitas udara sedangkan penelitian yang akan dilakukan adalah prediksi curah hujan. Metode yang digunakan pada penelitian ini adalah menggabungkan model Prophet dan LSTM sehingga menjadi menjadi model baru Hybrid Prophet-LSTM sedangkan pada

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian (Lanjutan)

No.	Judul	Peneliti, Media Publikasi, dan Tahun	Metode Penelitian	Kesimpulan	Perbandingan
			2014 hingga 31 Mei 2019 dan data uji sebanyak 334 data dari 01 Juni 2019 hingga 30 April 2020 untuk menguji efektivitas model.		penelitian yang akan dilakukan penulis adalah hanya melakukan pemodelan peramalan menggunakan metode LSTM dan Prophet secara tunggal.
6.	<i>A Comparative Machine Learning Study for Time Series Oil Production Forecasting ARIMA, LSTM and Prophet.</i>	Yanru Ning, Hossein Kazemi, Pejman Tahmasebi. Elsevier, Computers and Geosciences, Vol.164 2022	Penulis memprediksi penurunan produksi minyak yang abnormal dari sebuah sumur yang terletak di Denver-Julesburg (DJ) Basin, Colorado. Dataset diambil berupa dataset deret waktu stasioner dari data produksi minyak pada bulan September 2013 hingga September 2020. 70% data yang terdiri dari 60 data penting selama enam tahun pertama, digunakan sebagai dataset latih.	Hasil penelitian mendapatkan evaluasi data RMSE untuk model ARIMA sebesar 4,97, model LSTM sebesar 2,96 dan model Prophet sebesar 2,32. Hal ini menunjukkan bahwa model Prophet mampu memprediksi tren penurunan produksi minyak dengan RSME terendah dari model lainnya, model Prophet juga	Penelitian yang dilakukan berbeda dimana pada penelitian ini melakukan prediksi penurunan produksi minyak sedangkan penelitian yang akan dilakukan adalah prediksi curah hujan. Metode yang digunakan juga berbeda dimana pada penelitian ini menggunakan metode ARIMA, LSTM dan

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian (Lanjutan)

No.	Judul	Peneliti, Media Publikasi, dan Tahun	Metode Penelitian	Kesimpulan	Perbandingan
			sementara sisanya 30% dari data produksi dua tahun digunakan untuk prediksi.	mampu mengungkapkan potensi efek musiman yang akan sangat membantu operator untuk mencegah kemungkinan guncangan suhu yang telah terjadi dan mungkin terjadi lagi.	Prophet sedangkan pada penelitian yang akan dilakukan penulis hanya menggunakan metode LSTM dan Prophet.



BAB III

METODE PENELITIAN

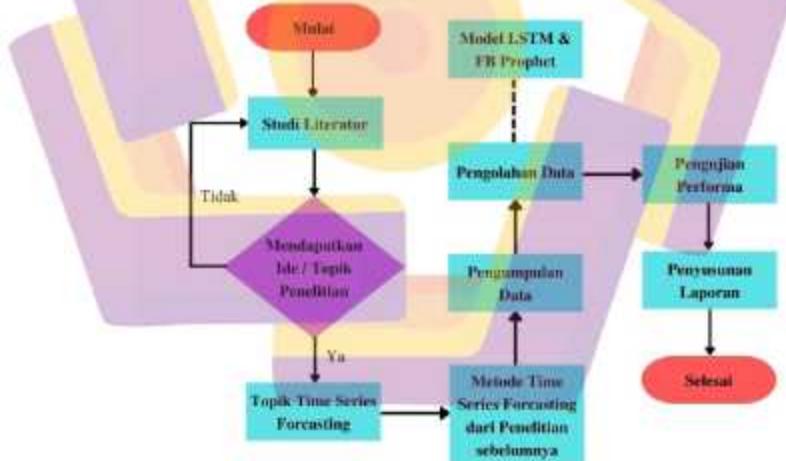
3.1 Jenis, Sifat dan Pendekatan Penelitian

Jenis penelitian yang digunakan dalam penelitian ini adalah eksperimen, penulis menerapkan pengambilan peramalan deret waktu menggunakan metode evaluasi RMSE untuk mengetahui perbedaan antara nilai-nilai prediksi model dengan nilai-nilai kebenaran yang diamati. Selanjutnya sifat dari penelitian ini adalah deskriptif karena penulis mendeskripsikan metode *univariate time series* untuk melakukan peramalan deret waktu pada curah hujan, sehingga akan dipilih metode *time series forecasting* mana yang akan digunakan dalam model analisis data. Terakhir, pendekatan yang digunakan dalam penelitian ini adalah pendekatan kuantitatif karena penulis melakukan observasi pencarian data secara mandiri di web *dataonline.bmkg.go.id* dan melakukan evaluasi peramalan deret waktu berdasarkan nilai *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE).

3.2 Alur Penelitian

Alur penelitian yang dilakukan oleh penulis yaitu seperti yang terlihat pada Gambar 3.1, dimulai dengan melakukan studi literatur lewat artikel-artikel untuk mencari metode-metode peramalan deret waktu (*time series forecasting*) dan saran dari penelitian sebelumnya. Topik penelitian ditemukan yaitu *time series* pada peramalan curah hujan menggunakan

algoritma *LSTM* dan *Prophet*. Pemilihan algoritma ini didasarkan pada penelitian-penelitian sebelumnya dimana *LSTM* dan *Prophet* mengungguli dari segi nilai akurasi maupun nilai RMSE yang baik dibandingkan dengan algoritma *machine learning* untuk metode *time series forecasting* lainnya. Selanjutnya dilakukan pengumpulan data yang diperoleh dengan metode kuantitatif berupa observasi data di web dataonline.bmkg.go.id, dan dilakukan proses pengolahan data seperti yang akan dijelaskan pada alur pengolahan data yang terlihat pada Gambar 3.2. Setelah didapatkan hasil pengujian performa maka langkah selanjutnya adalah penyusunan laporan yang akan memberikan kesimpulan dan saran atas penelitian yang telah dilakukan.

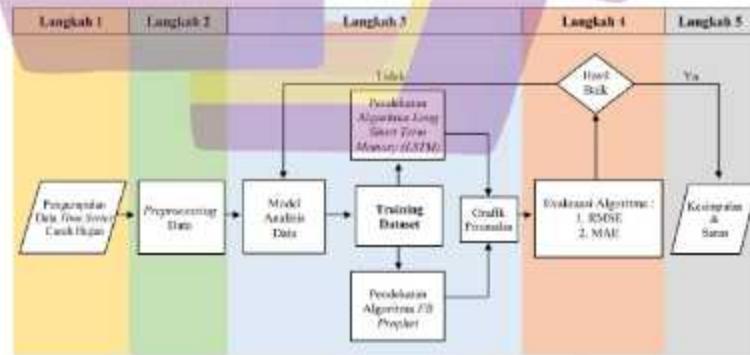


Gambar 3.1 Alur Penelitian

3.3 Alur Pengolahan Data

Tahapan penelitian selanjutnya setelah mendapatkan topik dari penelitian berupa kasus peramalan deret waktu (*time series forecasting*) curah

hujan di wilayah Kota Sorong dan pemilihan metode yang akan dilakukan berdasarkan penelitian sebelumnya maka proses selanjutnya adalah pengolahan data yang alurnya terlihat pada gambar 3.2, dimulai dari langkah pertama yaitu pengumpulan dataset. Selanjutnya dilakukan langkah 2 yaitu *preprocessing dataset*, data-data yang tidak diperlukan dalam penelitian dihilangkan dan data-data yang hilang diperbaiki dengan melakukan transformasi data. Kemudian dilanjutkan dengan langkah 3 yaitu pembuatan model analisis data menggunakan metode *univariate time series* dengan algoritma *Long Short Term Memory (LSTM)* dan *Prophet*, pada langkah ini dilakukan proses *training* terhadap dataset. Selanjutnya di langkah 4 didapatkan hasil evaluasi dari model yang dibuat. Langkah terakhir atau langkah 5 adalah penarikan kesimpulan dan saran dari hasil penelitian yang dilakukan apabila hasil evaluasi yang didapatkan sudah dianggap baik, namun apabila belum dianggap baik dapat dilakukan pengulangan kembali pada proses *training* data di langkah 3.



Gambar 3.2 Alur Pengolahan Data

3.3.1 Metode Pengumpulan Data

Metode pengumpulan data dalam penelitian ini adalah menggunakan teknik observasi. Penulis mengambil dataset dari data iklim harian Statisium Meteorologi DEO Sorong yang ada pada web resmi BMKG yaitu *dataonline.bmkg.go.id*, selama 5 (lima) tahun mulai dari Januari tahun 2017 hingga Desember 2021, berupa data *multivariate* yang terdiri dari: Data rerata kelembaban udara harian, data rerata suhu udara harian, data rerata kecapatan angin harian, dan data total curah hujan harian. Namun dalam proses analisis data dilakukan metode *univariate time series* yaitu variabel independen menggunakan data waktu (tanggal/bulan/tahun) dan variabel dependen menggunakan data curah hujan.

3.3.2 Metode Preprocessing Data

Salah satu tahapan penting *data mining* adalah *preprocessing* data, dimana seringkali data yang didapatkan cenderung tidak lengkap, *noise*, dan tidak konsisten. Adanya nilai variabel yang hilang terlihat jelas dalam kumpulan data, untuk itu penting dilakukan *preprocessing* data dengan mengisi nilai yang hilang, menghaluskan *noise* data, dan memperbaiki inskonsistensi data (Somasundaram & Nedunchezhian, 2011).

Dalam penelitian ini pada tahapan preprocessing data, penulis melakukan pembersihan data dan normalisasi data. Hal ini dilakukan dengan tujuan memfilter data-data yang digunakan dan menambahkan data-data yang hilang pada data curah hujan dimana data yang didapatkan dari data *online* BMKG adalah data mentah, pengisian data yang hilang / kosong dengan

menggunakan nilai tengah (*median*) dari perhitungan nilai data keseluruhan. Penulis mengisi angka kosong dengan nilai median karena strategi ini baik untuk data yang heterogen (sangat beragam) dan tidak terpengaruh oleh data ekstrim atau adanya nilai ekstrim (nilai yang terlalu kecil atau terlalu besar jika dibandingkan dengan nilai lainnya).

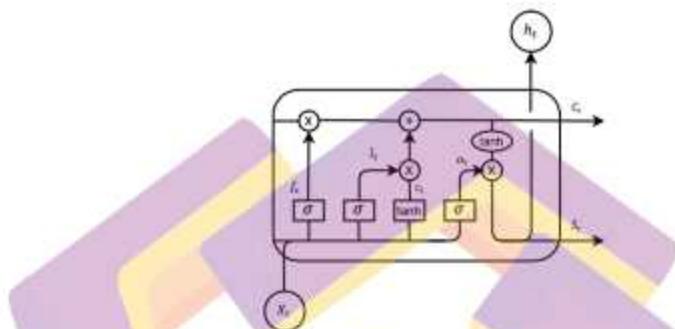
3.3.3 Metode Pemodelan Analisis Data

Pada tahapan ini dalam membangun model *time series forecasting* dengan algoritma *data mining* menggunakan data yang telah di *preprocessing* harus melakukan analisis data. Untuk melakukan pemodelan analisis data, langkah yang dilakukan penulis adalah:

1. Melakukan *Exploratory Data Analysis* (EDA) untuk mengidentifikasi pola, menemukan anomali, menguji hipotesis, dan memeriksa asumsi melalui statistik ringkas dan representasi grafis (*visual*). Namun dalam penelitian ini penulis menggunakan EDA *Non Graphical*.
2. Membuat model *time series forecasting* menggunakan metode *univariate time series* yaitu dengan algoritma *Long Short Term Memory (LSTM)* dan *FB Prophet*. Di tahap ini dilakukan proses *training dataset* dengan membagi (*split*) data yang akan di latih (*training*) dan data yang akan di uji (*test*), variabel independen menggunakan data Waktu (tanggal/bulan/tahun) dan variabel dependen menggunakan data Curah Hujan.

3.3.4 Algoritma Long Short Term Memory (LSTM)

Pada proses pemodelan menggunakan algoritma *Long Short Term Memory (LSTM)* memiliki cara kerja seperti berikut:



Gambar 3.3 Self Memory LSTM

Pada *LSTM*, sel memori menyimpan nilai atau status (*cell state*) untuk waktu yang lama atau singkat. Penjelasan untuk gerbang-gerbang yang ada pada satu sel memori *LSTM* yaitu:

- #### 1. Input Gate (i_t)

Input gate berperan mengambil *output* sebelumnya dan *input* baru serta melewatkannya melalui lapisan *sigmoid*. Gate ini mengembalikan nilai 0 atau 1. Persamaan dari i_t adalah:

Dengan,

W_i = Bobot dari *input gate*

S_{t-1} = State sebelumnya atau state pada waktu t-1

X_t = Input pada waktu t

σ = Fungsi aktivasi *sigmoid*

Nilai gerbang input dikalikan dengan output dari lapisan kandidat (\tilde{C}).

Persamaan dari (\tilde{C}) adalah:

$$C_t = \tanh(W_c S_{t-1} + W_c X_t) \dots \dots \dots (11)$$

Dengan,

\tilde{C} = *Intermediate cell state*

W_c = Bobot dari *cell state*

S_{t-1} = *State* sebelumnya atau *state* pada waktu t-1

X_t = *Input* pada waktu t

\tanh = Fungsi aktivasi *tanh*

Lapisan ini menerapkan tangen hiperbolik ke campuran *input* dan *output* sebelumnya. Mengembalikan vektor kandidat yang akan ditambahkan ke *state*. *State* diperbarui dengan persamaan:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \dots \dots \dots (12)$$

State sebelumnya dikalikan dengan *forget gate* dan kemudian ditambahkan ke fungsi kandidat baru yang diizinkan oleh *output gate*.

2. Forgate Gate (f_t)

Forget gate adalah lapisan *sigmoid* yang mengambil *output* pada waktu t - 1 dan *input* pada waktu t dan menggabungkannya serta menerapkan fungsi aktivasi *sigmoid*. Karena *sigmoid*, *output* dari gate ini adalah 0 atau 1. Jika $f_t = 0$ maka keadaan (*state*) sebelumnya akan dilupakan, sementara jika $f_t = 1$ maka *state* sebelumnya tidak berubah. Persamaan dari f_t adalah:

Dengan.

W_f = Bobot dari *forgate gate*

S_{t-1} = State sebelumnya atau state pada waktu t-1

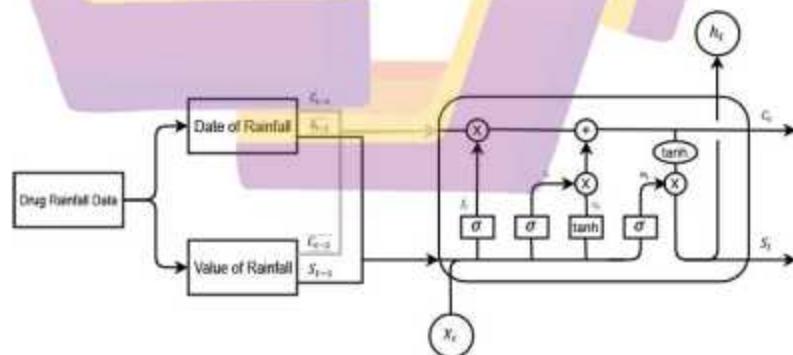
X_t = Input pada waktu t

σ = Fungsi aktivasi *sigmoid*

3. Output Gate (O_t)

Output gate mengontrol seberapa banyak *state* yang lewat ke *output* dan bekerja dengan cara yang sama dengan *gate* lainnya. Dan terakhir menghasilkan *cell state* yang baru (h_t). Persamaan dari O_t dan h_t adalah:

Arsitektur *LSTM* untuk meramalkan curah hujan di Kota Sorong dapat dilihat pada gambar 3.4 berikut:



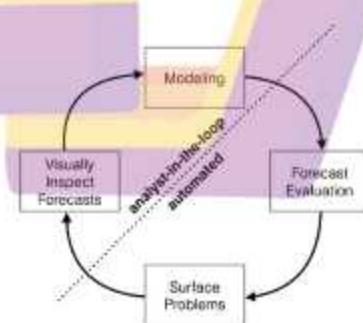
Gambar 3.4 Arsitektur *LSTM* Peramalan Curah Hujan Kota Sorong

Dimana atribut yang digunakan dalam penelitian ini ada dua yaitu tanggal curah hujan dan nilai atau *value* dari curah hujan Kota Sorong.

Namun dalam penelitian ini penulis memanfaatkan *library* yang telah disediakan oleh bahasa pemrograman python pada *frame work deep learning* yaitu *Keras*. Dimana dalam melakukan *hyperparameter tuning* penulis menggunakan metode *epoch* dengan perintah *early stopping epoch*. Epoch adalah jumlah training pada data yang akan dilakukan dimana ketika seluruh dataset sudah melalui proses *training* pada *LSTM* sampai dikembalikan ke awal untuk sekali putaran.

3.3.5 Algoritma FB Prophet

Pada proses pemodelan menggunakan algoritma *FB Prophet* memiliki cara kerja otomatis dimana menggunakan pendekatan peramalan berskala yang telah dibahas dalam paper (Taylor & Letham, 2017) seperti gambar 3.5 berikut :



Gambar 3.5 Skematic pendekatan *forecasting at scale* pada FB Prophet

Model yang digunakan oleh *FB Prophet* adalah *decomposable time series model* dengan tiga model komponen, yaitu *trend*, *seasonal*, dan *irregular components*.

Namun pada proses pemodelan menggunakan algoritma *FB Prophet*, dalam penelitian ini pemodelan dilakukan penulis secara otomatis dimana *FB Prophet* memiliki dua model tren untuk analisis yaitu model pertumbuhan jenuh (*saturating-growth model*) dan model linier sepotong-sepotong (*piecewise-linear model*). Penulis menggunakan model pertumbuhan jenuh (*saturating-growth model*) dengan memanfaatkan *library FB Prophet* dari *Facebook* yang disediakan oleh bahasa pemrograman python.

3.3.6 Evaluasi Algoritma

Setelah didapatkan model *time series forecasting* dari hasil pengolahan data menggunakan algoritma *Long Short Term Memory (LSTM)* dan *FB Prophet*, kemudian dilakukan evaluasi. Evaluasi algoritma dilakukan untuk menguji kelayakan serta relevansi keterkaitan berupa pengukuran atau metrik tingkat kesalahan (*error*) antara variable independen dan variable dependen. Evaluasi algoritma yang digunakan dalam penelitian ini adalah *Root Mean Square Error (RMSE)* dan *Mean Absolute Error (MAE)*.

Penggunaan RMSE dan MAE diambil karena merupakan pengukuran yang umum digunakan untuk memprediksi *error* pada analisis *time series forecasting* dimana perbedaannya adalah RMSE menghitung besarnya tingkat kesalahan dengan cara mengkuadratkan *error* (selisih antara nilai prediksi dan nilai sebenarnya), kemudian dicari rata-ratanya dengan menjumlahkan

error kuadrat lalu dibagi dengan banyaknya data (n), terakhir dilakukan operasi akar agar satuan dari RMSE sama dengan satuan nilai sebenarnya, sedangkan MAE menghitung rata-rata kesalahan (*error*) absolut antara hasil peramalan/prediksi dan nilai sebenarnya.

Apabila ditemukan perbedaan antara nilai RMSE dan MAE pada perbandingan model dengan skenario pembagian (*split*) data latih dan data uji, maka diambil nilai RMSE yang terkecil dari hasil skenario tersebut.

3.3.7 Kesimpulan dan Saran

Tahapan pengambilan kesimpulan atas penelitian yang dilakukan oleh penulis dan memberikan gambaran hasil penelitian ini untuk dijadikan acuan penelitian selanjutnya dalam pengembangan penelitian terkait metode *time series forecasting*, serta memberikan saran untuk proses pengembangan penelitian selanjutnya dengan metode dan model algoritma yang berbeda.

BAB IV

HASIL DAN PEMBAHASAN

Pada Bab ini penulis menyajikan hasil uji yang telah dilakukan dan pembahasannya.

4.1 Hasil Preprocessing Data

Sebelum melakukan uji coba dengan menggunakan algoritma *Long Short Term Memory (LSTM)* dan *Prophet*, maka langkah pertama yang dilakukan adalah prapemrosesan data (*preprocessing data*) yang telah didapatkan dari web resmi BMKG yaitu di dataonline.bmkg.go.id, berupa data harian selama 5 (lima) tahun mulai dari Januari tahun 2017 hingga Desember 2021, yang terdiri dari: data rerata kelembaban udara harian, data rerata suhu udara harian, data rerata kecapatan angin harian, dan data total curah hujan harian. Jumlah data keseluruhan yang didapatkan berjumlah 1826 baris data. Data yang didapatkan tersebut memiliki kendala berupa nilai kolom kosong, nilai tertulis 8888 yang berarti data tidak terukur, dan nilai tertulis 9999 yang berarti tidak ada data (tidak dilakukan pengukuran) hal ini mungkin disebabkan kondisi alat pencatat otomatis BMKG yang mengalami kendala teknis dilapangan pada hari tersebut.

Untuk mengatasi ketidaknormalan dataset yang didapatkan maka dilakukan prapemrosesan dataset. Dalam menormalisasikan dataset tersebut langkah-langkah prapemrosesan dataset dilakukan sebagai berikut:

1. Penghapusan tabel data secara manual di excel untuk tabel data yang kosong (NaN) pada semua variabel seperti yang terlihat pada Gambar

4.1, hal ini merupakan langkah yang diambil secara subjektif untuk menangani anomali pada data, sehingga dari 1826 jumlah baris data menjadi 1813 jumlah baris data.

1353	13-09-2020	26,5	88	23,5	2
1354	14-09-2020	25,8	94	22,9	3
1355	15-09-2020				
1356	16-09-2020				
1357	17-09-2020				
1358	18-09-2020				
1359	19-09-2020				
1360	20-09-2020				
1361	21-09-2020				
1362	22-09-2020				
1363	23-09-2020				
1364	24-09-2020				
1365	25-09-2020				
1366	26-09-2020				
1367	27-09-2020				
1368	28-09-2020	26,8	86	16,2	2
1369	29-09-2020	27,1	81	3	2
1370	30-09-2020	26,7	86	6,3	2

Gambar 4.1 Tampilan nilai tabel kosong pada dataset di excel

- Mengganti nilai 8888 dan 9999 yang merupakan *missing values* pada tabel data secara manual di excel sehingga data yang awalnya terisi nilai 8888 dan 9999 menjadi nilai 0. Selanjutnya dataset tersebut dimasukkan di bahasa pemrograman python dan terlihat jumlah data terisi di setiap variabel seperti yang tampak pada Gambar 4.2.

```
df.info()
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 1813 entries, 0 to 1812
Data columns (total 5 columns):
 #   column      non-null count  Dtype  
 0   tanggal     1813 non-null    object  
 1   Tavg        1810 non-null    float64 
 2   RH_avg      1809 non-null    float64 
 3   RH          1448 non-null    float64 
 4   ff_avg      1812 non-null    float64 
dtypes: float64(4), object(1)
memory usage: 29.9+ kB
```

Gambar 4.2 Tampilan jumlah data terisi

- Pengisian nilai pada tabel data yang kosong menggunakan bahasa pemrograman python dengan menggunakan nilai median, hal ini merupakan pendekatan statistik untuk menangani nilai yang hilang atau kosong.

```
df.isna().sum()
Tanggal      0
Tavg       123
Rtg_AVG     123
RR        365
ff_avg       1
dtype: int64
```

Gambar 4.3 Tampilan jumlah data yang hilang atau kosong

Terlihat pada Gambar 4.3, bahwa jumlah data yang hilang untuk curah hujan (RR) sebesar 365 data.

```
- PREPROCESSING DATA
[1]: df = pd.read_csv('https://raw.githubusercontent.com/ardifitrianto/Indah/main/Indah.csv')
[2]: df['RR'].fillna(0, inplace=True)
[3]: df['RR'].isna().sum()
[4]: df['RR'].isna().sum()
[5]: df['RR'].isna().sum()

[1]: df
[2]:
```

Gambar 4.4 Tampilan proses pengisian nilai median

Terlihat pada Gambar 4.4, bahwa pengisian nilai median di tabel kosong telah sukses dengan nilai data kosong untuk curah hujan (RR) telah bernilai 0. Dan pada gambar 4.5, terlihat tampilan data sebelum dilakukan pengisian nilai curah hujan (RR) tertulis NaN dan setelah dilakukan pengisian tertulis angka 4.5 yang merupakan nilai median.

	Tanggal	Tavg	RH_avg	RR	ff_avg
0	01-01-2017	26.1	81.0	3.6	2.0
1	02-01-2017	26.9	82.0	15.6	2.0
2	03-01-2017	26.8	87.0	3.6	2.0
3	04-01-2017	27.2	86.0	1.0	1.0
4	05-01-2017	27.1	89.0	1.2	1.0

Gambar 4.5 Tampilan hasil pengisian nilai median

4. Data baru memperlihatkan bahwa tidak ada lagi kolom yang tertulis NaN dan telah terisi dengan nilai median. Data baru tersebut kemudian disimpan dengan format file .xlsx menggunakan nama *dataset_median_CurahHujan_sorong.xlsx* seperti terlihat pada Gambar 4.6 untuk menjadi file dataset baru yang siap digunakan dalam proses pengolahan data selanjutnya.

```
[24]: df.to_excel('C:/Users/08147003/Downloads/dataset_median_CurahHujan_sorong.xlsx')
```

Gambar 4.6 Penyimpanan file dataset baru

4.2 Hasil Pemodelan Analisis Data

Dataset yang telah dinormalisasikan lewat prapemrosesan (*preprocessing*) data kemudian dilakukan langkah-langkah pemodelan analisa data.

Dataset yang telah dinormalisasikan lewat prapemrosesan data kemudian dilakukan langkah-langkah pemodelan analisa data.

4.2.1 Mengimpor Library

```
import numpy as np
import pandas as pd # data processing, CSV file I/O (e.g. pd.read_csv/excel)
import seaborn as sns # Visualization
```

```

import matplotlib.pyplot as plt # Visualization
from colorama import Fore

from sklearn.metrics import mean_absolute_error, mean_squared_error
import math

import warnings # Suppress warnings
warnings.filterwarnings('ignore')

np.random.seed(4)

```

Langkah pertama yang dilakukan penulis adalah mengimpor perpustakaan (*library*) yang diperlukan untuk membangun model. Bahasa pemrograman python memberi fleksibilitas untuk mengimpor perpustakaan di mana saja. Pada tahap ini penulis mengimpor perpustakaan pandas, numpy, matplotlib, dan seaborn.

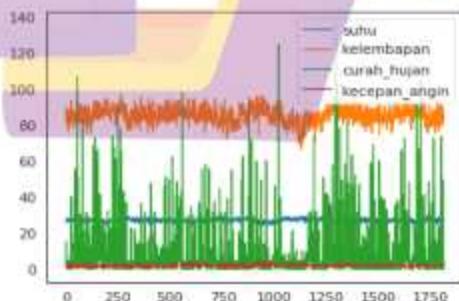
4.2.2 Melihat Penyebaran Dataset

```

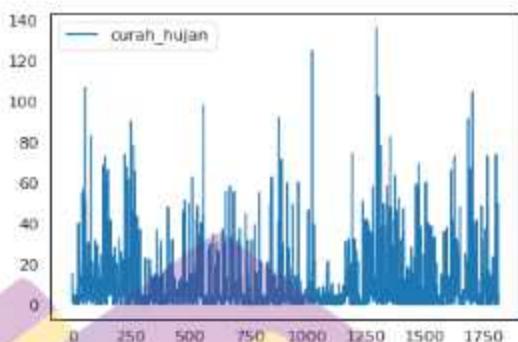
# load and plot dataset
from pandas import read_excel
from matplotlib import pyplot
# load data
path = '/content/drive/MyDrive/dataset/data_new_medium.xlsx'
df = read_excel(path, header=0)
# plot the time series
df.plot()
pyplot.show()

```

Langkah selanjutnya menampilkan grafik penyebaran data curah hujan Kota Sorong seperti yang terlihat pada Gambar 4.7.



Gambar 4.7 Penyebaran nilai dataset yang dimiliki



Gambar 4.8 Penyebaran nilai dataset curah hujan Kota Sorong

4.2.3 *Exploratory Data Analysis (EDA)*

Exploratory Data Analysis (EDA) dilakukan penulis guna mengidentifikasi pola dan menemukan anomali data dengan melakukan pengujian hipotesis terhadap kumpulan data yang ada seperti yang terlihat pada Gambar 4.7 dan Gambar 4.8. EDA juga dapat membantu mendeteksi kesalahan lebih awal, mengidentifikasi *outlier* dalam kumpulan data dan menemukan pola dalam data.

Pada proses EDA ini penulis menggunakan teknik *Univariate Non Graphical* dimana hanya data Curah Hujan saja yang akan menjadi prioritas pengolahan data walaupun tampilan pada EDA seperti yang terlihat pada Gambar 4.9 adalah *Multivariate Non Graphical*.



Gambar 4.9 Tampilan EDA Non Graphical

Pada Gambar 4.9, dapat dilihat pada deskripsi data curah hujan

adalah jumlah data yang terhitung sebanyak 1813 data dengan nilai *mean* adalah 9,256 dan nilai standar deviasi adalah 15,187. Nilai standard deviasi merupakan suatu nilai yang digunakan dalam menentukan persebaran data pada suatu sampel data dan melihat seberapa dekat data-data tersebut dengan nilai *mean*. Dari hasil nilai

standar deviasi yang didapat sebesar 15,187 menandakan bahwa nilai tersebut baik dan bisa dikatakan dekat dengan nilai *mean* pada kumpulan data.

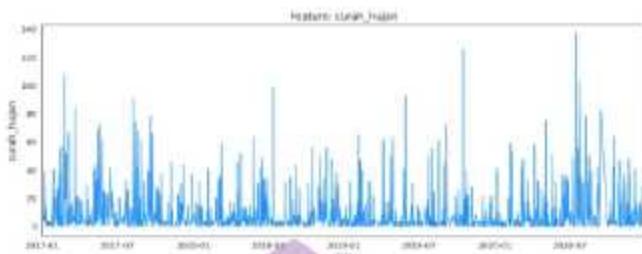
Dari hasil tampilan EDA pada Gambar 4.9 di atas juga terlihat bahwa tidak ada data curah hujan yang *missing values* dan *null* hal ini dikarenakan telah dilakukan *pre-processing* data terlebih dahulu.

4.2.4 Visualisasi Data dengan Rekayasa Fitur

Pada langkah proses visualisasi data, penulis melakukan rekayasa fitur. Rekayasa fitur adalah proses menggunakan pengetahuan domain untuk mengekstrak fitur dari data mentah melalui teknik data mining. Untuk model ini penulis mengambil gambar fitur untuk kolom curah hujan seperti yang terlihat pada Gambar 4.10. Penskalaan fitur pada dasarnya membantu menormalkan data dalam rentang tertentu. Di tahap ini penulis memberikan rentang data dari 01 Januari 2017 sampai dengan 30 Desember 2020.

```
F, ax = plt.subplots(nrows=4, ncols=1, figsize=(15, 25))

for i, column in enumerate(df.drop('date', axis=1).columns):
    sns.lineplot(x=df['date'], y=df[column].fillna(method='ffill'),
                 ax=ax[i], color='dodgerblue')
    ax[i].set_title('Feature: {}'.format(column), fontsize=14)
    ax[i].set_ylabel(label='column', fontsize=14)
    ax[i].set_xlim([date(2017, 1, 1), date(2020, 12, 30)])
```



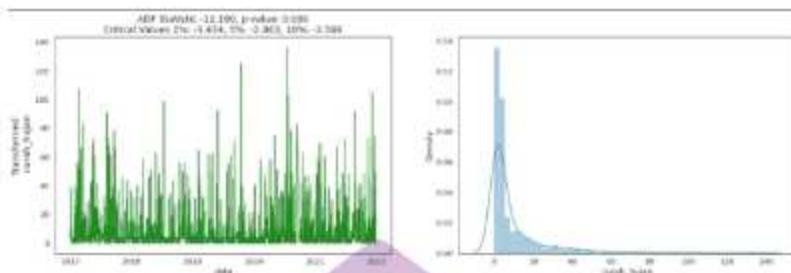
Gambar 4.10 Tampilan Fitur Curah Hujan Kota Sorong

4.2.5 Visualisasasi Data dengan Pengujian Stasioneritas ADF

Pada tahap ini Penulis melakukan uji stasioneritas menggunakan *Augmented Dickey-Fuller* (ADF) yang merupakan pengujian terhadap data deret waktu (*time series*) untuk mengetahui apakah data deret waktu yang dimiliki stasioner atau tidak.

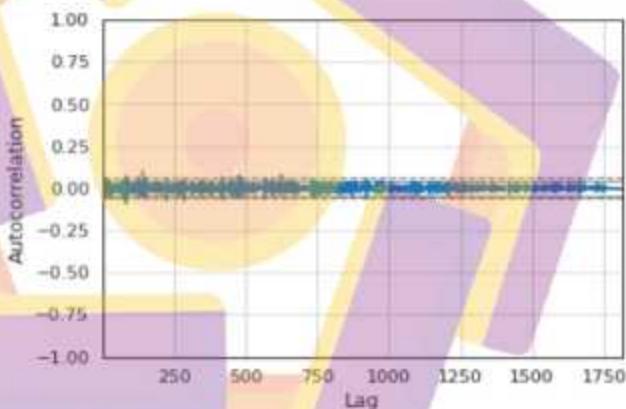
Seperti pada Gambar 4.11, terlihat transformasi data curah hujan Kota Sorong sudah stasioner dengan nilai ADF Statistic adalah -12.190 dan p-value adalah 0.000. Pada nilai *critical* yang diuji mendapatkan nilai -3.434 pada *critical values* 1%, nilai -2.863 pada *critical values* 5%, dan nilai -2.568 pada *critical values* 10%.

Dari plot grafik histogram *density* juga menunjukkan bentuk kurva distribusi data yang normal.



Gambar 4.11 Tampilan Transformasi ADF dan Density Curah Hujan Kota Sorong

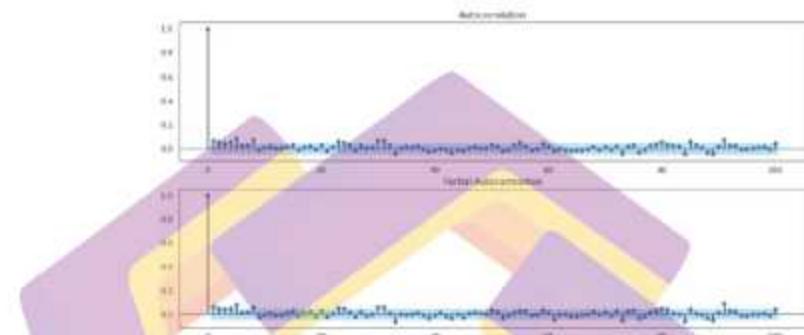
4.2.6 Visualisasi Data dengan ACF dan PACF



Gambar 4.12 Tampilan Autocorrelation Dataset

Sebelum menentukan model yang akan digunakan untuk melakukan peramalan maka yang harus dilakukan terlebih dahulu adalah menentukan *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) dimana data *autocorrelation* yang dimiliki dapat dilihat pada Gambar 4.12. Kemudian dilakukan

penentuan ACF dan PACF untuk melihat penurunan nilai autokorelasi secara eksponensial menuju 0 (nol). Sehingga dapat ditentukan apakah data tersebut stasioner atau tidak stasioner (*non stasioner*).



Gambar 4.13 Tampilan ACF dan PACF

Pada bentuk pola grafik ACF dan PACF seperti yang terlihat pada Gambar 4.13 dapat dijelaskan bahwa plot ACF *des down* (turun cepat secara sinusoidal) pada Lag 2 dan (nol) pada Lag 10, sedangkan plot PACF menunjukkan *des down* (turun cepat secara sinusoidal) pada Lag 2 dan mendekati 0 (nol) pada Lag 7. Melihat pola pada plot PACF maka dapat dikatakan bahwa nilai autokorelasi secara eksponensial menuju 0 (nol) pada Lag 96 sehingga data curah hujan Kota Sorong yang dimiliki sudah stasioner.

Berdasarkan data ACF dan PACF tersebut maka akan dilakukan penggunaan algoritma *LSTM* dan *Prophet* untuk mendapatkan model peramalan curah hujan Kota Sorong.

4.2.7 Pemodelan Data

Pada tahap pemodelan data, langkah yang dilakukan adalah dengan melakukan skenario validasi dengan membagi data latih (*training*) dan data uji (*testing*) berdasarkan banyaknya data yang dimiliki. Skenario pertama penulis membagi data (*split*) sebanyak 70% untuk data latih (*training*) dan 30% untuk data uji (*testing*), skenario kedua penulis membagi data (*split*) sebanyak 80% untuk data latih (*training*) dan 20% untuk data uji (*testing*), dan skenario ketiga penulis membagi (*split*) sebanyak 85% untuk data latih (*training*) dan 15% untuk data uji (*testing*). Sebelum dilakukan pembagian data (*split*) tersebut penulis melakukan proses validasi silang (cross-validation) pada dataset untuk melihat setiap iterasi data yang dilatih dan diuji berdasarkan waktu yang ditentukan seperti terlihat pada Gambar 4.14 dimana jarak dari setiap window adalah 1.

```
from sklearn.model_selection import TimeSeriesSplit
n_splits = 2
x = df['date']
y = df['curah_hujan']
folds = TimeSeriesSplit(n_splits=n_splits)
f, ax = plt.subplots(nrows=n_splits, ncols=2, figsize=(16, 9))
for i, (train_index, valid_index) in enumerate(folds.split(x)):
    X_train, X_valid = x[train_index], x[valid_index]
    y_train, y_valid = y[train_index], y[valid_index]
    sns.lineplot(
        x=X_train,
        y=y_train,
        ax=ax[i, 0],
        color='dodgerblue',
        label='train'
    )
    sns.lineplot(
        x=X_train[len(X_train) - len(X_valid) : (len(X_train) -
len(X_valid) + len(X_valid))],
        y=y_train[len(X_train) - len(X_valid) : (len(X_train) -
len(X_valid) + len(X_valid))],
        ax=ax[i, 1],
        color='red',
        label='test'
    )
```

```

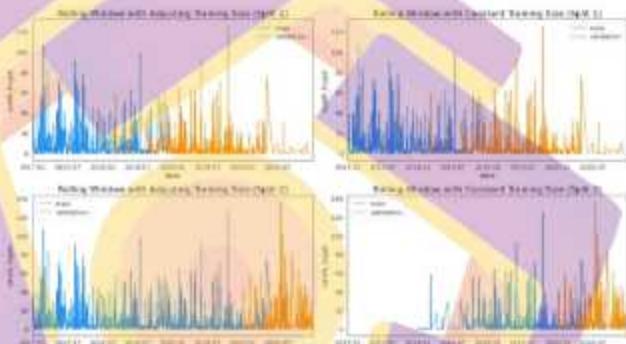
        color='dodgerblue',
        label='train'
    )

    for j in range(2):
        axns.lineplot(x= X_valid, y= y_valid, ax=ax[i, j],
        color='darkorange', label='validation')
        ax[i, 0].set_title(f"Rolling Window with Adjusting Training Size
(Split {i+1})", fontsize=16)
        ax[i, 1].set_title(f"Rolling Window with Constant Training Size
(Split {i+1})", fontsize=16)

for i in range(N_SPLITS):
    ax[i, 0].set_xlim([date(2017, 1, 1), date(2020, 12, 30)])
    ax[i, 1].set_xlim([date(2017, 1, 1), date(2020, 12, 30)])

plt.tight_layout()
plt.show()

```



Gambar 4.14 Cross-Validation of dataset.

4.2.7.1 Skenario 1 : 70% data latih dan 30% data uji

Pengambilan data yang dilatih adalah sebanyak 1.269 data dan sisanya 544 data merupakan data yang diuji, Gambar 4.15 memperlihatkan jumlah pembagian data *training* dan data *testing*-nya.

```

train_size = int(0.70 * len(df))
test_size = len(df) - train_size

df = df[['date', 'curah_hujan']].copy()
df.columns = ['ds', 'y']

train = df.iloc[:train_size, :]
x_train, y_train = pd.DataFrame(df.iloc[:train_size, 0]),
pd.DataFrame(df.iloc[:train_size, 1])

```

```
x_valid, y_valid = pd.DataFrame(df.iloc[train_size:, 0]),
pd.DataFrame(df.iloc[train_size:, 1])
print(len(train), len(x_valid))
```

1269 544

Gambar 4.15 Tampilan Hasil Pembagian Data Skenario 1

4.2.7.2 Skenario 2 : 80% data latih dan 20% data uji

Pengambilan data yang dilatih adalah sebanyak 1.450 data dan sisanya 363 data merupakan data yang diuji, Gambar 4.16 memperlihatkan jumlah pembagian data *training* dan data *testing*-nya.

```
train_size = int(0.80 * len(df))
test_size = len(df) - train_size

df = df[['date', 'curah_hujan']].copy()
df.columns = ['ds', 'y']

train = df.iloc[:train_size, :]

x_train, y_train = pd.DataFrame(df.iloc[:train_size, 0]),
pd.DataFrame(df.iloc[:train_size, 1])
x_valid, y_valid = pd.DataFrame(df.iloc[train_size:, 0]),
pd.DataFrame(df.iloc[train_size:, 1])
print(len(train), len(x_valid))
```

1450 363

Gambar 4.16 Tampilan Hasil Pembagian Data Skenario 2

4.2.7.3 Skenario 3 : 85% data latih dan 15% data uji

Pengambilan data yang dilatih adalah sebanyak 1.541 data dan sisanya 272 data merupakan data yang diuji, Gambar 4.15 memperlihatkan jumlah pembagian data *training* dan data *testing*-nya.

```
train_size = int(0.85 * len(df))
test_size = len(df) - train_size

df = df[['date', 'curah_hujan']].copy()
df.columns = ['ds', 'y']

train = df.iloc[:train_size, :]
```

```

x_train, y_train = pd.DataFrame(df.iloc[:train_size, 0]),
pd.DataFrame(df.iloc[:train_size, 1])
x_valid, y_valid = pd.DataFrame(df.iloc[train_size:, 0]),
pd.DataFrame(df.iloc[train_size:, 1])
print(len(train), len(x_valid))

```

1450 363

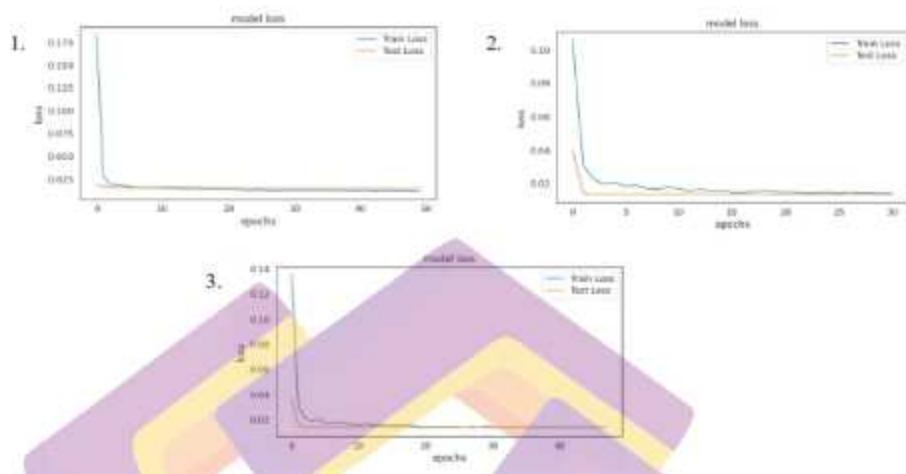
Gambar 4.17 Tampilan Hasil Pembagian Data Skenario 3

4.2.7.4 Long Short Term Memory (*LSTM*)

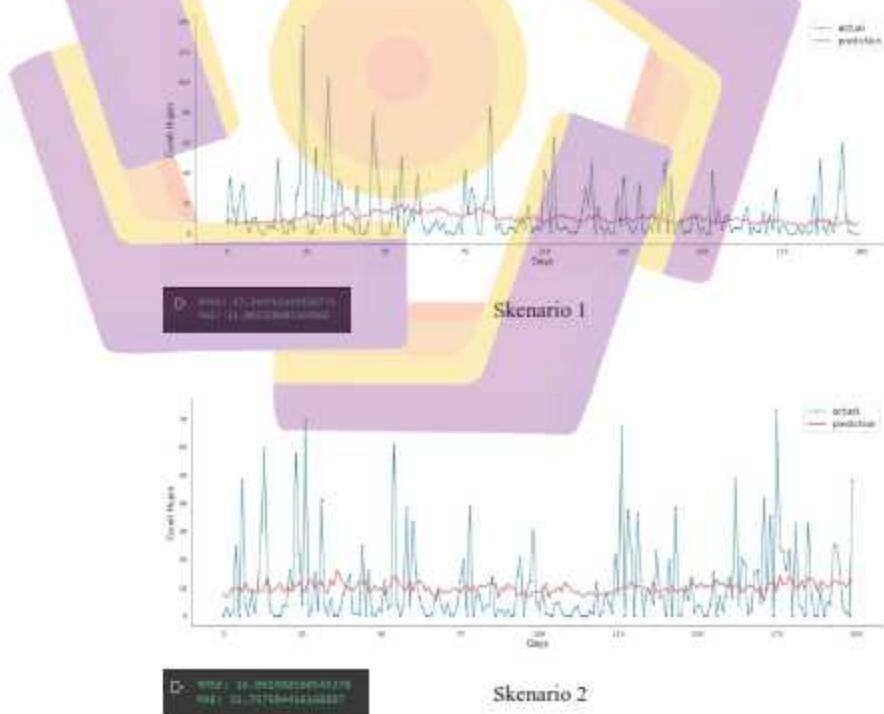
Terdapat dua parameter yang mempengaruhi hasil peramalan pada metode *LSTM*, yaitu menggunakan metode *epoch* dan *batch*.

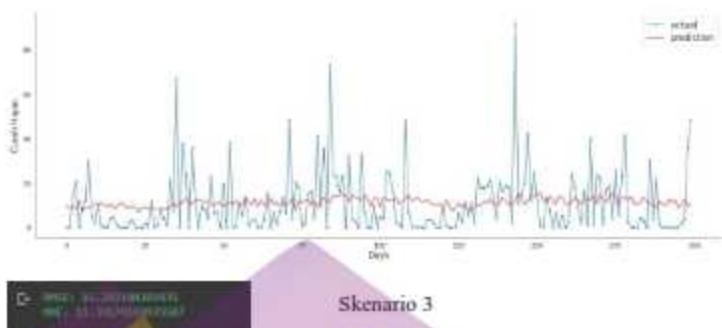
Pada penelitian ini penulis menggunakan metode *epoch*., pada penelitian ini penulis menggunakan epoch 50 dengan perintah *early stopping epoch*.

Pada skenario 1 mendapatkan epoch ke 50, pada skenario 2 mendapatkan epoch ke 30 dan skenario 3 mendapatkan epoch ke 48 data *lost train* dan *lost test* sudah mendekati 0. Hasil grafik model loss data berdasarkan epoch dapat dilihat pada gambar 4.18. Dan untuk hasil peramalan curah hujan Kota Sorong dengan menggunakan algoritma *LSTM* sesuai skenario dapat dilihat seperti pada Gambar 4.19 dimana pada hasil pengukuran tingkat kesalahan, skenario 2 mendapatkan nilai RMSE 16,09 dan MAE 11,76 dibandingkan skenario 1 dan 3 yang mendapatkan nilai RMSE dan MAE lebih besar.



Gambar 4.18 Model Loss Data pada LSTM

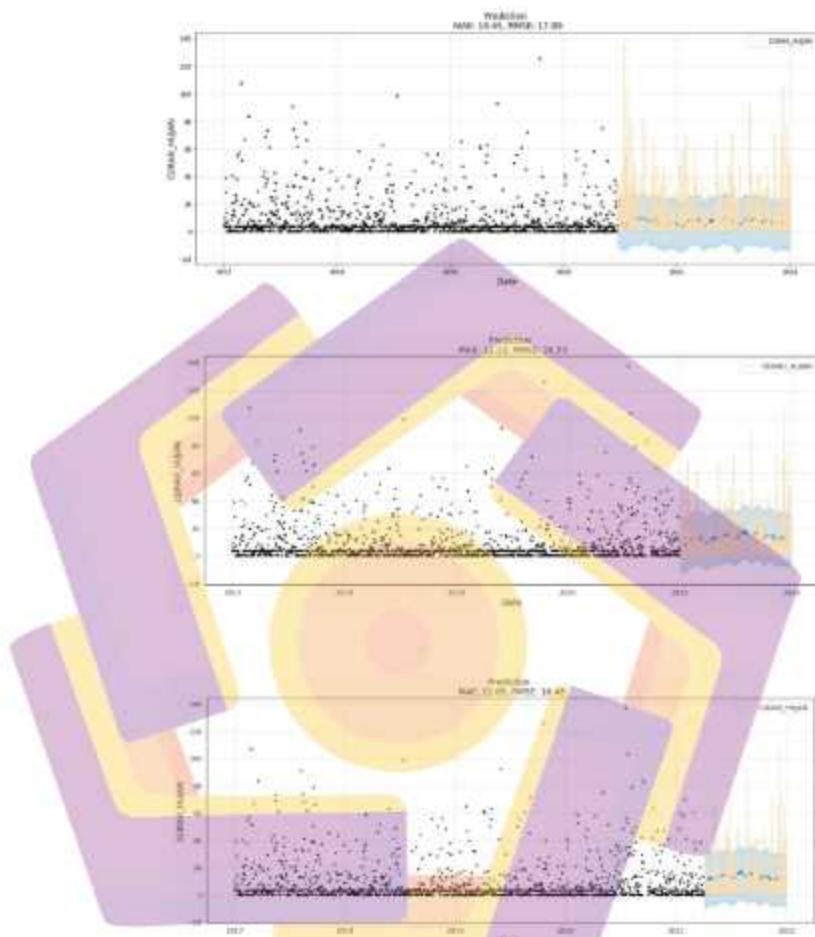




Gambar 4.19 Grafik Hasil Peramalan, Nilai RMSE dan MAE pada LSTM

4.2.7.5 Facebook Prophet

Dari hasil peramalan menggunakan metode *FB Prophet* didapatkan grafik prediksi curah hujan Kota Sorong dengan warna biru dan grafik aktual warna jingga (*orange*) seperti yang terlihat pada Gambar 4.20. Model *FB Prophet* yang ditampilkan merupakan analisis model pertumbuhan-jenuh (*saturating-growth model*), dimana pada skenario 2 didapatkan nilai RMSE 16,32 dan MAE adalah 12,12. Hasil ini lebih baik dari skenario 1 dan 2.



Gambar 4.20 Grafik Hasil Peramalan, Nilai RMSE dan MAE pada FB Prophet

4.3 Evaluasi Algoritma

Dari hasil pemodelan peramalan deret waktu (*time series forecasting*) yang telah dilakukan penulis maka didapatkan evaluasi berupa pengukuran

tingkat kesalahan berdasarkan nilai RMSE dan MAE pada algoritma *LSTM* dan *FB Prophet* adalah sesuai Tabel 4.1 berikut:

Tabel 4.1 Hasil Evaluasi Pengukuran Tingkat Kesalahan pada Algoritma *LSTM* dan *FB Prophet*

Skenario	Pembagian Dataset	LSTM		<i>FB Prohet</i>	
		RMSE	MAE	RMSE	MAE
1	70% latih, 30% uji	17,33	11,08	17,89	10,44
2	80% latih, 20% uji	16,09	11,76	16,32	12,12
3	85% latih, 15% uji	16,20	11,39	16,48	12,08

Dari hasil pengukuran tingkat kesalahan pada tabel diatas didapatkan bahwa skenario 2 memiliki nilai RMSE lebih baik dari skenario 1 dan 3 namun untuk nilai MAE skenario 1 memiliki nilai lebih baik dari nilai yang didapatkan skenario 2 dan 3.

Untuk perbandingan algoritma antara *LSTM* dan *FB Prophet* didapatkan bahwa peramalan menggunakan metode *LSTM* memiliki nilai tingkat kesalahan (RMSE dan MAE) lebih baik dibandingkan *FB Prophet*.

4.4 Perbandingan Hasil dengan Penelitian Sebelumnya

Berdasarkan nilai RMSE dan MAE yang didapatkan pada evaluasi algoritma tersebut maka penulis akan membandingkan hasil RMSE dan MAE yang didapatkan oleh penelitian sebelumnya yang juga memprediksi curah hujan dan menjadi rujukan dalam laporan tesis ini yaitu penelitian yang dilakukan oleh (Freecenta et al., 2022).

Perbedaan penelitian ini dibandingkan penelitian yang dilakukan oleh (Freecenta et al., 2022) adalah sebagai berikut :

1. Dataset yang digunakan oleh penelitian sebelumnya adalah data curah hujan Kab. Malang yang diambil dari Januari tahun 2010 sampai dengan 25 Desember 2021, sedangkan dataset pada penelitian ini adalah data curah hujan Kota Sorong yang diambil dari Januari tahun 2017 sampai dengan Desember 2021.
2. Metode pemodelan yang digunakan oleh penelitian sebelumnya hanya menggunakan algoritma *LSTM* saja sedangkan pada penelitian ini menggunakan algoritma *LSTM* dan *FB Prophet*.
3. Hasil pengukuran tingkat kesalahan pada pemodelan *LSTM* di penelitian sebelumnya dan penelitian ini menggunakan RMSE dan MAE. Penelitian sebelumnya mendapatkan nilai pengukuran tingkat kesalahan terbaik pada skenario 2 dengan melakukan preprocessing dataset dimana nilai 9999, 8888, dan kolom NaN yang terdapat pada parameter curah hujan diganti dengan nilai 0, dalam proses pemodelan *LSTM* menggunakan *epoch* 150 dan mendapatkan nilai RMSE 10,16 dan MAE 7,90 sedangkan penelitian ini mendapatkan nilai pengukuran tingkat kesalahan terbaik dengan menggunakan skenario 2 dengan melakukan preprocessing dataset dimana nilai 9999 dan 8888 diganti dengan nilai 0 dan kolom NaN yang terdapat pada parameter curah hujan diganti dengan nilai median (nilai tengah), dalam proses pemodelan *LSTM* melakukan pembagian dataset 80 : 20, epoch 50 dan berhenti pada epoch 30 dengan

perintah *early stopping epoch*, mendapatkan nilai RMSE 16,09 dan MAE 11,76.

- Perbedaan nilai RMSE dan MAE bisa terjadi karena adanya perbedaan dalam teknik preprocessing, teknik eksplorasi data, dan teknik validasi data dalam penelitian. Perbandingan hasil dapat dilihat pada tabel 4.2 berikut:

Tabel 4.2 Perbandingan Nilai Tingkat Pengukuran Kesalahan pada Algoritma LSTM dengan Penelitian Sebelumnya

Evaluasi	Penelitian Sebelumnya	Penelitian oleh Penulis
RMSE	10,16	16,09
MAE	7,90	11,76

Penulis selanjutnya akan membandingkan hasil pengukuran tingkat kesalahan dengan menggunakan skenario 2 dan teknik *preprocessing dataset* pada penelitian penulis menggunakan dataset dari penelitian sebelumnya yaitu data curah hujan Kab. Malang yang diambil dari Januari tahun 2010 sampai dengan 25 Desember 2021. Didapatkan hasil sesuai yang terlihat pada tabel 4.3 berikut:

Tabel 4.3 Perbandingan Nilai Tingkat Pengukuran Kesalahan pada Algoritma LSTM menggunakan dataset Penelitian Sebelumnya

Penelitian	Teknik <i>Preprocessing</i>	RMSE	MAE
Penelitian Penulis	Skenario 2 : Mengubah Nilai 8888, 9999 menjadi 0 dan mengisi baris yang kosong dengan Nilai Median	12,66	8,47
Penelitian sebelumnya	Skenario 2 : Mengubah Nilai 8888, 9999 menjadi 0 dan mengisi baris kosong dengan Nilai 0	10,16	7,90

Penulis selanjutnya akan membandingkan hasil pengukuran tingkat kesalahan menggunakan teknik *preprocessing* dan dataset dari penelitian sebelumnya yaitu data curah hujan Kab. Malang yang diambil dari Januari tahun 2010 sampai dengan 25 Desember 2021, namun tetap menggunakan skenario 2 pada pemodelan algoritma LSTM yang telah penulis. Didapatkan hasil sesuai yang terlihat pada tabel 4.4 berikut:

Tabel 4.4 Perbandingan Nilai Pengukuran Tingkat Kesalahan pada Algoritma LSTM menggunakan Teknik *Preprocessing* dataset Penelitian Sebelumnya

Penelitian	Teknik <i>Preprocessing</i>	RMSE	MAE
Penelitian Penulis	Mengubah Nilai 8888, 9999 menjadi 0 dan mengisi baris kosong dengan Nilai 0	13,34	10,43
Penelitian sebelumnya	Skenario 2 : Mengubah Nilai 8888, 9999 menjadi 0 dan mengisi baris kosong dengan Nilai 0	10,16	7,90

BAB V

PENUTUP

5.1 KESIMPULAN

Pemodelan peramalan curah hujan Kota Sorong menggunakan metode *time series forecasting* dengan algoritma *Long Short Term Memory (LSTM)* dan *Facebook Prophet*, jumlah dataset curah hujan Kota Sorong sebanyak 1813 baris data yang diambil dari 01 Januari tahun 2017 hingga 31 Desember tahun 2021, maka didapatkan hasil evaluasi pengukuran tingkat kesalahan sesuai skenario pembagian data latih dan data uji yang telah dilakukan yaitu model skenario 2 (80% data latih dan 20% data uji) dapat dianggap lebih baik untuk digunakan dalam peramalan curah hujan di wilayah Kota Sorong karena memiliki nilai RMSE lebih kecil dari skenario 1 dan 3.

Dari hasil evaluasi pengukuran tingkat kesalahan pada skenario 2 tersebut didapatkan nilai RMSE pada *LSTM* sebesar 16,09 sedangkan pada *FB Prophet* sebesar 16,32 sehingga terdapat selisih sebesar 0,23. Dan nilai MAE pada *LSTM* sebesar 11,76 sedangkan pada *FB Prophet* sebesar 12,12 sehingga terdapat selisih sebesar 0,36.

Terlihat bahwa nilai RMSE dan MAE menggunakan metode *time series forecasting* dengan algoritma *LSTM* lebih baik digunakan dalam melakukan peramalan curah hujan di wilayah Kota Sorong dibandingkan algoritma *FB Prophet*. Namun selisih nilai evaluasi pengukuran tingkat kesalahan pada *LSTM* dan *FB Prophet* tersebut tidak terlalu signifikan sehingga kedua model ini bisa digunakan dalam peramalan curah hujan jangka panjang.

Walaupun model LSTM memiliki kinerja lebih baik dari FB Prophet, namun model LSTM masih memiliki kekurangan yaitu terkait lambatnya model dalam mencapai konvergensi dibandingkan FB Prophet yang bekerja secara otomatis dalam mencapai konvergensi.

5.2 SARAN

1. Pada penelitian ini penulis hanya menggunakan pemodelan dataset *univariate time series* dengan variabel tanggal dan curah hujan. Namun dataset yang digunakan adalah *multivariate time series* dimana memiliki variabel curah hujan, suhu, kelembapan udara, dan kecepatan angin. Saran untuk penelitian selanjutnya dapat melakukan pemodelan peramalan metode *time series forecasting* dengan dataset *multivariate time series* dan menambahkan penggunaan beberapa algoritma *time series forecasting* lainnya seperti SARIMA (*Seasonal ARIMA*), GRU, BATS dan LSTM *Bidirectional* untuk mendapatkan hasil terbaik pada setiap variabel dataset tersebut.
2. Model *Long Short Term Memory* (LSTM) yang digunakan penulis merupakan salah satu model yang banyak digunakan untuk memprediksi/meramalkan aktivitas berdasarkan data histori, namun model LSTM masih memiliki kekurangan terkait lambatnya model dalam mencapai konvergensi. Saran untuk penelitian selanjutnya adalah dengan membandingkan beberapa algoritma *metode time series forecasting* lainnya seperti SARIMA, GRU, BATS dan LSTM *Bidirectional* sehingga didapatkan algoritma mana yang lebih cepat dalam memodelkan.

DAFTAR PUSTAKA

- Aftab, S., Ahmad, M., Hameed, N., Bashir, M. S., Ali, I., & Nawaz, Z. (2018). Rainfall prediction in Lahore City using data mining techniques. *International Journal of Advanced Computer Science and Applications*, 9(4), 254–260. <https://doi.org/10.14569/IJACSA.2018.090439>
- Arief, S. M., Siburian, R. H., & Wahyudi, W. (2019). Tingkat Kerentanan Banjir Kota Sorong Papua Barat. *Median : Jurnal Ilmu Ilmu Eksakta*, 11(2), 23. <https://doi.org/10.33506/md.v11i2.456>
- Binternagel, N. (2009). *Adaptasi dan Mitigasi Perubahan Iklim Global*. October.
- Dewi, E., Mulyani, S., Septianingrum, I., Nurjanah, N., Rahmawati, R., Nurhasani, S., Milky, K., & Tasikmalaya, S. (2019). Predksi Curah Hujan Di Kabupaten Majalengka Dengan Menggunakan Algoritma Regresi Rainfall Prediction in Majalengka District Using Regression Algorithm. *Informasi*, 67(1).
- Esling, P., & Agon, C. (2012). Time-series data mining. *ACM Computing Surveys*, 45(1). <https://doi.org/10.1145/2379776.2379788>
- Freecenta, H., Puspaningrum, E. Y., & Maulana, H. (2022). *PREDIKSI CURAH HUJAN DI KAB. MALANG MENGGUNAKAN LSTM (Long Short Term Memory)*. 3(1), 51–55.
- Jagannathan, J., & Divya, C. (2021). Time series analysis and prediction of climate using enhanced multivariate prophet. *International Journal of*

- Engineering Trends and Technology*, 69(10), 89–96.
<https://doi.org/10.14445/22315381/IJETT-V69I10P212>
- Jati, R. (2020). *Banjir dan Longsor Kota Sorong Akibatkan Tiga Orang Meninggal Dunia*. <https://bnpb.go.id/berita/Banjir dan Longsor Kota Sorong Akibatkan Tiga Orang Meninggal Dunia>
- Kafil, M. (2019). Penerapan Metode K-Nearest Neighbors Untuk Prediksi Penjualan Berbasis Web Pada Boutiq Dealove Bondowoso. *JATT (Jurnal Mahasiswa Teknik Informatika)*, 3(2), 59–66.
<https://doi.org/10.36040/jati.v3i2.860>
- Ning, Y., Kazemi, H., & Tahmasebi, P. (2022). Computers and Geosciences A comparative machine learning study for time series oil production forecasting: ARIMA , LSTM , and Prophet. *Computers and Geosciences*, 164(May), 105126. <https://doi.org/10.1016/j.cageo.2022.105126>
- Papacharalampous, G., Tyralis, H., & Koutsoyiannis, D. (2018). Predictability of monthly temperature and precipitation using automatic time series forecasting methods. *Acta Geophysica*, 66(4), 807–831.
<https://doi.org/10.1007/s11600-018-0120-7>
- Poornima, S., & Pushpalatha, M. (2019). Prediction of rainfall using intensified LSTM based recurrent Neural Network with Weighted Linear Units. *Atmosphere*, 10(11). <https://doi.org/10.3390/atmos10110668>
- Putramulyo, S., & Alaa, S. (2018). Prediksi Curah Hujan Bulanan Di Kota

- Samarinda Menggunakan Persamaan Regresi Dengan Prediktor Data Suhu dan Kelembapan Udara. *Eigen Mathematics Journal*, 2(2), 13.
<https://doi.org/10.29303/emj.v2i2.20>
- Rumahorbo, I. R. (2020). Persamaan Regresi Prediksi Curah Hujan Bulanan Menggunakan Data Suhu dan Kelembapan Udara di Bengkulu. *Prosiding Seminar Pendidikan Matematika Dan ...*, 2(2721), 1–11.
- Sepp Hochreiter, J. S. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Somasundaram, R. S., & Nedunchezhian, R. (2011). Evaluation of Three Simple Imputation Methods for Enhancing Preprocessing of Data with Missing Values. *International Journal of Computer Applications*, 21(10), 14–19.
<https://doi.org/10.5120/2619-3544>
- Suryanto, A. A. (2019). Penerapan Metode Mean Absolute Error (Mea) Dalam Algoritma Regresi Linear Untuk Prediksi Produksi Padi. *Saintekbu*, 11(1), 78–83. <https://doi.org/10.32764/saintekbu.v11i1.298>
- Taylor, S. J., & Letham, B. (2017). Business Time Series Forecasting at Scale. *PeerJ Preprints* 5:E3190v2, 35(8), 48–90.
<https://peerj.com/preprints/3190/> <http://ezproxy.bangor.ac.uk/login?url=http://search.ebscohost.com/login.aspx?direct=true&db=c8h&AN=108935824&site=ehost-live%0Ahttps://peerj.com/preprints/3190/%0Ahttps://peerj.com/preprints/3190.pdf>

- Tian, Y., Xu, Y. P., & Wang, G. (2018). Agricultural drought prediction using climate indices based on Support Vector Regression in Xiangjiang River basin. *Science of the Total Environment*, 622–623, 710–720.
<https://doi.org/10.1016/j.scitotenv.2017.12.025>
- Toharudin, T., Pontoh, R. S., Caraka, R. E., Zahroh, S., Lee, Y., & Chen, R. C. (2020). Employing long short-term memory and Facebook prophet model in air temperature forecasting. *Communications in Statistics: Simulation and Computation*, 0(0), 1–24. <https://doi.org/10.1080/03610918.2020.1854302>
- Zhou, L., Chen, M., & Ni, Q. (2020). A hybrid Prophet-LSTM Model for Prediction of Air Quality Index. *2020 IEEE Symposium Series on Computational Intelligence, SSCI 2020*, 595–601.
<https://doi.org/10.1109/SSCI47803.2020.9308543>

LAMPIRAN

1. Tabel Dataset setelah Preprocessing

Tabel Dataset Curah Hujan Kota Sorong (2017 s.d. 2021)

Tanggal	Curah Hujan	Jumlah data	Tahun
01-01-2017	4,5	365	2017
02-01-2017	15,6		
03-01-2017	4,5		
04-01-2017	1		
05-01-2017	1,2		
06-01-2017	1,1		
07-01-2017	4,5		
08-01-2017	4,5		
09-01-2017	4,5		
10-01-2017	4,5		
11-01-2017	4,5		
12-01-2017	0,1		
13-01-2017	4,5		
14-01-2017	4,5		
15-01-2017	4,5		
16-01-2017	0,6		
17-01-2017	4,5		
18-01-2017	3,1		
19-01-2017	1,5		
20-01-2017	4,5		
21-01-2017	0,1		
22-01-2017	0,3		
23-01-2017	0,3		
24-01-2017	8,5		
25-01-2017	4,5		
26-01-2017	11,9		
27-01-2017	21		
28-01-2017	40,3		
29-01-2017	1		
30-01-2017	0,1		
31-01-2017	20,8		
01-02-2017	9,6		
02-02-2017	14,4		
03-02-2017	11,9		
04-02-2017	2		
05-02-2017	4,5		
06-02-2017	4,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
07-02-2017	4,5		
08-02-2017	4,5		
09-02-2017	4,5		
10-02-2017	4,5		
11-02-2017	1,7		
12-02-2017	4,5		
13-02-2017	54,9		
14-02-2017	0,3		
15-02-2017	7,2		
16-02-2017	4,5		
17-02-2017	4,5		
18-02-2017	8,8		
19-02-2017	57,1		
20-02-2017	4,5		
21-02-2017	4,5		
22-02-2017	4,5		
23-02-2017	4,5		
24-02-2017	107,2		
25-02-2017	19,7		
26-02-2017	19,7		
27-02-2017	51,5		
28-02-2017	0,4		
01-03-2017	6,2		
02-03-2017	11,4		
03-03-2017	0,6		
04-03-2017	18,6		
05-03-2017	1,9		
06-03-2017	5,1		
07-03-2017	4,5		
08-03-2017	12,9		
09-03-2017	12,4		
10-03-2017	12,5		
11-03-2017	16,6		
12-03-2017	30,8		
13-03-2017	2,3		
14-03-2017	4,5		
15-03-2017	16,5		
16-03-2017	4,5		
17-03-2017	4,5		
18-03-2017	6,8		
19-03-2017	4,5		
20-03-2017	4,5		
21-03-2017	83,3		
22-03-2017	4,5		
23-03-2017	20,4		

Tanggal	Curah Hujan	Jumlah data	Tahun
24-03-2017	0,4		
25-03-2017	4,5		
26-03-2017	8,4		
27-03-2017	21,4		
28-03-2017	4,5		
29-03-2017	1		
30-03-2017	4,5		
31-03-2017	4,5		
01-04-2017	4,5		
02-04-2017	4,5		
03-04-2017	2,8		
04-04-2017	2,8		
05-04-2017	4,5		
06-04-2017	14,1		
07-04-2017	4,5		
08-04-2017	3,8		
09-04-2017	31,8		
10-04-2017	29,3		
11-04-2017	0		
12-04-2017	4,5		
13-04-2017	4,5		
14-04-2017	2,6		
15-04-2017	4,5		
16-04-2017	4,5		
17-04-2017	1		
18-04-2017	4,5		
19-04-2017	29,3		
20-04-2017	2		
21-04-2017	18,9		
22-04-2017	0		
23-04-2017	4,5		
24-04-2017	2,4		
25-04-2017	7,5		
26-04-2017	1,4		
27-04-2017	4,5		
28-04-2017	4,5		
29-04-2017	4,5		
30-04-2017	12,8		
01-05-2017	4,5		
02-05-2017	4,5		
03-05-2017	0		
04-05-2017	7,3		
05-05-2017	4,5		
06-05-2017	24,6		
07-05-2017	3,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
08-05-2017	0		
09-05-2017	4,5		
10-05-2017	4,5		
11-05-2017	4,5		
12-05-2017	4,5		
13-05-2017	32,5		
14-05-2017	4		
15-05-2017	68,9		
16-05-2017	35,3		
17-05-2017	12,6		
18-05-2017	3,9		
19-05-2017	0,8		
20-05-2017	73,2		
21-05-2017	38,3		
22-05-2017	7,4		
23-05-2017	8,4		
24-05-2017	8,7		
25-05-2017	4,5		
26-05-2017	60,9		
27-05-2017	0,1		
28-05-2017	14,1		
29-05-2017	0,8		
30-05-2017	25		
31-05-2017	6,1		
01-06-2017	38,9		
02-06-2017	26,3		
03-06-2017	66,6		
04-06-2017	5		
05-06-2017	40		
06-06-2017	6,5		
07-06-2017	20		
08-06-2017	4,5		
09-06-2017	4,5		
10-06-2017	5,1		
11-06-2017	4,5		
12-06-2017	15,7		
13-06-2017	29,8		
14-06-2017	42		
15-06-2017	35,5		
16-06-2017	19,8		
17-06-2017	11,8		
18-06-2017	5,2		
19-06-2017	24,4		
20-06-2017	14,5		
21-06-2017	15,3		

Tanggal	Curah Hujan	Jumlah data	Tahun
22-06-2017	15,5		
23-06-2017	0		
24-06-2017	9,4		
25-06-2017	3		
26-06-2017	2		
27-06-2017	0		
28-06-2017	9,8		
29-06-2017	4,5		
30-06-2017	4,5		
01-07-2017	28,3		
02-07-2017	1		
03-07-2017	23,5		
04-07-2017	18,1		
05-07-2017	4,5		
06-07-2017	13		
07-07-2017	20,5		
08-07-2017	12,6		
09-07-2017	9,8		
10-07-2017	0,2		
11-07-2017	0,7		
12-07-2017	10		
13-07-2017	4,8		
14-07-2017	6,8		
15-07-2017	2,7		
16-07-2017	7,3		
17-07-2017	1,6		
18-07-2017	4,1		
19-07-2017	6,9		
20-07-2017	18,4		
21-07-2017	21,1		
22-07-2017	32,7		
23-07-2017	6,4		
24-07-2017	16,9		
25-07-2017	4,5		
26-07-2017	4,5		
27-07-2017	25,9		
28-07-2017	4,5		
29-07-2017	0,1		
30-07-2017	1,1		
31-07-2017	0,5		
01-08-2017	4,5		
02-08-2017	4,5		
03-08-2017	4,5		
04-08-2017	4,5		
05-08-2017	3,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
06-08-2017	22,3		
07-08-2017	4,5		
08-08-2017	4,5		
09-08-2017	6,2		
10-08-2017	26,4		
11-08-2017	14,9		
12-08-2017	14,6		
13-08-2017	4,5		
14-08-2017	74,1		
15-08-2017	32,5		
16-08-2017	0,2		
17-08-2017	12,8		
18-08-2017	4,5		
19-08-2017	41,2		
20-08-2017	4,5		
21-08-2017	68,1		
22-08-2017	8,3		
23-08-2017	0,5		
24-08-2017	0		
25-08-2017	15,1		
26-08-2017	21,1		
27-08-2017	0,7		
28-08-2017	61,8		
29-08-2017	4,2		
30-08-2017	4,5		
31-08-2017	0,1		
01-09-2017	13,8		
02-09-2017	22,4		
03-09-2017	1,8		
04-09-2017	0		
05-09-2017	0,3		
06-09-2017	11,9		
07-09-2017	2,4		
08-09-2017	90,7		
09-09-2017	2,6		
10-09-2017	2,6		
11-09-2017	45,6		
12-09-2017	43,6		
13-09-2017	39,3		
14-09-2017	38,8		
15-09-2017	12,6		
16-09-2017	8		
17-09-2017	17,9		
18-09-2017	3,4		
19-09-2017	50,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
20-09-2017	78,6		
21-09-2017	4,5		
22-09-2017	38,4		
23-09-2017	0		
24-09-2017	66,1		
25-09-2017	24,6		
26-09-2017	13,7		
27-09-2017	9,3		
28-09-2017	0,5		
29-09-2017	4,3		
30-09-2017	9,7		
01-10-2017	7,1		
02-10-2017	37,6		
03-10-2017	14,6		
04-10-2017	5,4		
05-10-2017	43,6		
06-10-2017	0,4		
07-10-2017	4,5		
08-10-2017	33,4		
09-10-2017	0,9		
10-10-2017	6,2		
11-10-2017	1,3		
12-10-2017	4,5		
13-10-2017	0,1		
14-10-2017	5		
15-10-2017	0,3		
16-10-2017	37,1		
17-10-2017	6,5		
18-10-2017	1,5		
19-10-2017	4,5		
20-10-2017	4,5		
21-10-2017	3		
22-10-2017	0		
23-10-2017	4,5		
24-10-2017	4,5		
25-10-2017	4,5		
26-10-2017	4,5		
27-10-2017	4,5		
28-10-2017	0		
29-10-2017	4,5		
30-10-2017	4,5		
31-10-2017	4,5		
01-11-2017	0		
02-11-2017	0		
03-11-2017	0,8		

Tanggal	Curah Hujan	Jumlah data	Tahun
04-11-2017	4,5		
05-11-2017	4,5		
06-11-2017	4,5		
07-11-2017	4,5		
08-11-2017	0		
09-11-2017	0,2		
10-11-2017	23		
11-11-2017	9,4		
12-11-2017	2,3		
13-11-2017	1		
14-11-2017	0,8		
15-11-2017	0,2		
16-11-2017	0,7		
17-11-2017	0,4		
18-11-2017	4,5		
19-11-2017	0,5		
20-11-2017	4,5		
21-11-2017	0		
22-11-2017	2,2		
23-11-2017	2,9		
24-11-2017	4,5		
25-11-2017	4,5		
26-11-2017	22,4		
27-11-2017	4,5		
28-11-2017	4,5		
29-11-2017	1,3		
30-11-2017	17,1		
01-12-2017	4,5		
02-12-2017	4,5		
03-12-2017	4,5		
04-12-2017	4,5		
05-12-2017	4,5		
06-12-2017	4,5		
07-12-2017	3,8		
08-12-2017	4,5		
09-12-2017	1,6		
10-12-2017	14,3		
11-12-2017	11,5		
12-12-2017	2		
13-12-2017	4,5		
14-12-2017	4,5		
15-12-2017	0,1		
16-12-2017	5,5		
17-12-2017	4,5		
18-12-2017	4,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
19-12-2017	15		
20-12-2017	15,1		
21-12-2017	4,5		
22-12-2017	4,5		
23-12-2017	0,4		
24-12-2017	4,5		
25-12-2017	4,5		
26-12-2017	4,5		
27-12-2017	1,7		
28-12-2017	8,7		
29-12-2017	36,9		
30-12-2017	3,3		
31-12-2017	4,5		
01-01-2018	4,5	365	2018
02-01-2018	4,5		
03-01-2018	4,5		
04-01-2018	0,6		
05-01-2018	13,4		
06-01-2018	12,7		
07-01-2018	0,8		
08-01-2018	0,2		
09-01-2018	4,3		
10-01-2018	0,4		
11-01-2018	28,5		
12-01-2018	4,5		
13-01-2018	14,5		
14-01-2018	11,7		
15-01-2018	5		
16-01-2018	32		
17-01-2018	1,2		
18-01-2018	0		
19-01-2018	4,5		
20-01-2018	15,1		
21-01-2018	0,2		
22-01-2018	13,3		
23-01-2018	4,5		
24-01-2018	2,7		
25-01-2018	0,8		
26-01-2018	1,6		
27-01-2018	2		
28-01-2018	4,5		
29-01-2018	4,5		
30-01-2018	0		
31-01-2018	2		
01-02-2018	4,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
02-02-2018	1		
03-02-2018	0,8		
04-02-2018	17,5		
05-02-2018	4,5		
06-02-2018	0,2		
07-02-2018	0		
08-02-2018	2,5		
09-02-2018	4		
10-02-2018	0		
11-02-2018	4,5		
12-02-2018	48,1		
13-02-2018	13,1		
14-02-2018	1,2		
15-02-2018	4,3		
16-02-2018	2,1		
17-02-2018	4		
18-02-2018	1		
19-02-2018	1		
20-02-2018	4,5		
21-02-2018	4,5		
22-02-2018	4,5		
23-02-2018	4,5		
24-02-2018	4,5		
25-02-2018	4,5		
26-02-2018	20,4		
27-02-2018	4,8		
28-02-2018	4,5		
01-03-2018	4,5		
02-03-2018	1,2		
03-03-2018	32		
04-03-2018	0,2		
05-03-2018	4,5		
06-03-2018	4,5		
07-03-2018	14,6		
08-03-2018	4,5		
09-03-2018	8,1		
10-03-2018	4,5		
11-03-2018	4,5		
12-03-2018	4,5		
13-03-2018	4,5		
14-03-2018	12,8		
15-03-2018	4,5		
16-03-2018	0,3		
17-03-2018	4,5		
18-03-2018	4,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
19-03-2018	4,5		
20-03-2018	1,2		
21-03-2018	3,1		
22-03-2018	1,8		
23-03-2018	2,4		
24-03-2018	7,6		
25-03-2018	4,5		
26-03-2018	0		
27-03-2018	5,8		
28-03-2018	4,8		
29-03-2018	1,4		
30-03-2018	4,5		
31-03-2018	6,4		
01-04-2018	9		
02-04-2018	11,9		
03-04-2018	9,2		
04-04-2018	5,3		
05-04-2018	3		
06-04-2018	4,5		
07-04-2018	4,5		
08-04-2018	4,5		
09-04-2018	0,5		
10-04-2018	0,6		
11-04-2018	7,6		
12-04-2018	13,4		
13-04-2018	10,4		
14-04-2018	0,4		
15-04-2018	1,9		
16-04-2018	0		
17-04-2018	9,8		
18-04-2018	4,6		
19-04-2018	4,5		
20-04-2018	24,7		
21-04-2018	4,5		
22-04-2018	4,5		
23-04-2018	4,5		
24-04-2018	0,3		
25-04-2018	4,5		
26-04-2018	51,6		
27-04-2018	4,5		
28-04-2018	4,5		
29-04-2018	4,5		
30-04-2018	7,1		
01-05-2018	4,5		
02-05-2018	4,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
03-05-2018	4,5		
04-05-2018	3,7		
05-05-2018	11,2		
06-05-2018	4		
07-05-2018	4,9		
08-05-2018	0,3		
09-05-2018	4,7		
10-05-2018	4,5		
11-05-2018	50		
12-05-2018	4,5		
13-05-2018	7,8		
14-05-2018	4,8		
15-05-2018	0,5		
16-05-2018	4,1		
17-05-2018	7,5		
18-05-2018	9		
19-05-2018	15		
20-05-2018	0,5		
21-05-2018	6,6		
22-05-2018	4,5		
23-05-2018	6,5		
24-05-2018	2,9		
25-05-2018	4,5		
26-05-2018	8,3		
27-05-2018	63		
28-05-2018	19,8		
29-05-2018	0,3		
30-05-2018	10		
31-05-2018	0,8		
01-06-2018	1,4		
02-06-2018	0,1		
03-06-2018	15,3		
04-06-2018	9,6		
05-06-2018	13,5		
06-06-2018	4,5		
07-06-2018	4,5		
08-06-2018	4,5		
09-06-2018	3,1		
10-06-2018	1,4		
11-06-2018	5,8		
12-06-2018	19,4		
13-06-2018	1,2		
14-06-2018	41,4		
15-06-2018	0,2		
16-06-2018	0		

Tanggal	Curah Hujan	Jumlah data	Tahun
17-06-2018	48,8		
18-06-2018	3,6		
19-06-2018	23,6		
20-06-2018	1,5		
21-06-2018	33,6		
22-06-2018	4,5		
23-06-2018	5,7		
24-06-2018	18,3		
25-06-2018	4,5		
26-06-2018	21,8		
27-06-2018	5,3		
28-06-2018	28,7		
29-06-2018	34,3		
30-06-2018	4,5		
01-07-2018	17,5		
02-07-2018	40,2		
03-07-2018	35,5		
04-07-2018	3,5		
05-07-2018	12,9		
06-07-2018	28,4		
07-07-2018	4,5		
08-07-2018	4,5		
09-07-2018	43,7		
10-07-2018	0,1		
11-07-2018	4,5		
12-07-2018	4,5		
13-07-2018	2,1		
14-07-2018	98,7		
15-07-2018	0,2		
16-07-2018	4,5		
17-07-2018	0,4		
18-07-2018	0,5		
19-07-2018	1,4		
20-07-2018	4,5		
21-07-2018	4,5		
22-07-2018	0,3		
23-07-2018	3,9		
24-07-2018	0,8		
25-07-2018	0,1		
26-07-2018	4,5		
27-07-2018	4,5		
28-07-2018	2,3		
29-07-2018	0,4		
30-07-2018	3,8		
31-07-2018	0,3		

Tanggal	Curah Hujan	Jumlah data	Tahun
01-08-2018	4,5		
02-08-2018	10,5		
03-08-2018	27,2		
04-08-2018	4,5		
05-08-2018	0		
06-08-2018	4,5		
07-08-2018	4,5		
08-08-2018	4,5		
09-08-2018	1,8		
10-08-2018	30		
11-08-2018	18,5		
12-08-2018	4,5		
13-08-2018	4,5		
14-08-2018	4,5		
15-08-2018	4,5		
16-08-2018	4,5		
17-08-2018	0		
18-08-2018	4,5		
19-08-2018	4,5		
20-08-2018	4,5		
21-08-2018	4,2		
22-08-2018	0,5		
23-08-2018	4,5		
24-08-2018	0,3		
25-08-2018	35		
26-08-2018	1,2		
27-08-2018	4,5		
28-08-2018	4,5		
29-08-2018	0,3		
30-08-2018	0,1		
31-08-2018	19		
01-09-2018	4,5		
02-09-2018	0,1		
03-09-2018	4,5		
04-09-2018	12,7		
05-09-2018	0,6		
06-09-2018	30,5		
07-09-2018	1,3		
08-09-2018	0,6		
09-09-2018	4,4		
10-09-2018	4,5		
11-09-2018	13		
12-09-2018	4,5		
13-09-2018	4,5		
14-09-2018	8		

Tanggal	Curah Hujan	Jumlah data	Tahun
15-09-2018	26,7		
16-09-2018	2,1		
17-09-2018	4,5		
18-09-2018	7,5		
19-09-2018	4,5		
20-09-2018	4,5		
21-09-2018	4,5		
22-09-2018	4,5		
23-09-2018	4,5		
24-09-2018	0		
25-09-2018	4,5		
26-09-2018	4,5		
27-09-2018	4,5		
28-09-2018	4,5		
29-09-2018	1,6		
30-09-2018	0		
01-10-2018	0,2		
02-10-2018	2,3		
03-10-2018	37,3		
04-10-2018	17,5		
05-10-2018	12,6		
06-10-2018	1		
07-10-2018	5,9		
08-10-2018	0,2		
09-10-2018	0,6		
10-10-2018	4,5		
11-10-2018	6		
12-10-2018	30,5		
13-10-2018	7		
14-10-2018	10,8		
15-10-2018	11,2		
16-10-2018	2		
17-10-2018	55,9		
18-10-2018	3		
19-10-2018	4,5		
20-10-2018	2,5		
21-10-2018	13,3		
22-10-2018	8,8		
23-10-2018	4,3		
24-10-2018	4,5		
25-10-2018	4,5		
26-10-2018	4,5		
27-10-2018	4,5		
28-10-2018	4,5		
29-10-2018	4,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
30-10-2018	4,5		
31-10-2018	4,5		
01-11-2018	1,1		
02-11-2018	1,4		
03-11-2018	58,7		
04-11-2018	3,1		
05-11-2018	0,4		
06-11-2018	0		
07-11-2018	1,7		
08-11-2018	1		
09-11-2018	1		
10-11-2018	0		
11-11-2018	0		
12-11-2018	1,8		
13-11-2018	4,5		
14-11-2018	33,8		
15-11-2018	10,3		
16-11-2018	3		
17-11-2018	16,3		
18-11-2018	5,2		
19-11-2018	6,4		
20-11-2018	56		
21-11-2018	4,5		
22-11-2018	4,5		
23-11-2018	4,5		
24-11-2018	4,5		
25-11-2018	3,1		
26-11-2018	4,5		
27-11-2018	0		
28-11-2018	4,5		
29-11-2018	4,5		
30-11-2018	11,5		
01-12-2018	0,2		
02-12-2018	0		
03-12-2018	0,2		
04-12-2018	0		
05-12-2018	0,3		
06-12-2018	1,4		
07-12-2018	0,4		
08-12-2018	31,8		
09-12-2018	8,2		
10-12-2018	9,1		
11-12-2018	1,4		
12-12-2018	4,5		
13-12-2018	4,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
14-12-2018	4,9		
15-12-2018	37,7		
16-12-2018	6,2		
17-12-2018	17,9		
18-12-2018	29,2		
19-12-2018	4,5		
20-12-2018	4,5		
21-12-2018	4,5		
22-12-2018	13,4		
23-12-2018	9,3		
24-12-2018	0		
25-12-2018	0,5		
26-12-2018	5,2		
27-12-2018	4,5		
28-12-2018	0		
29-12-2018	4,5		
30-12-2018	4,5		
31-12-2018	2,2		
01-01-2019	4,5	365	2019
02-01-2019	0		
03-01-2019	4,5		
04-01-2019	0,2		
05-01-2019	4,5		
06-01-2019	4,5		
07-01-2019	4,5		
08-01-2019	0,9		
09-01-2019	45		
10-01-2019	4,5		
11-01-2019	0		
12-01-2019	4,5		
13-01-2019	0,5		
14-01-2019	0		
15-01-2019	1,9		
16-01-2019	31,6		
17-01-2019	6,2		
18-01-2019	16,6		
19-01-2019	6,1		
20-01-2019	0		
21-01-2019	0		
22-01-2019	4,5		
23-01-2019	4,5		
24-01-2019	0		
25-01-2019	0		
26-01-2019	0		
27-01-2019	7,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
28-01-2019	0		
29-01-2019	8,3		
30-01-2019	6		
31-01-2019	4,5		
01-02-2019	6,8		
02-02-2019	17,8		
03-02-2019	31,9		
04-02-2019	0		
05-02-2019	0		
06-02-2019	0		
07-02-2019	0,2		
08-02-2019	0,2		
09-02-2019	1,2		
10-02-2019	0		
11-02-2019	0,6		
12-02-2019	0		
13-02-2019	0		
14-02-2019	8		
15-02-2019	39,6		
16-02-2019	0		
17-02-2019	4,5		
18-02-2019	2,1		
19-02-2019	11,3		
20-02-2019	8		
21-02-2019	0		
22-02-2019	16		
23-02-2019	0		
24-02-2019	2		
25-02-2019	0,7		
26-02-2019	1,6		
27-02-2019	0,2		
28-02-2019	0		
01-03-2019	3,9		
02-03-2019	8,3		
03-03-2019	4,5		
04-03-2019	7,9		
05-03-2019	2,5		
06-03-2019	4,5		
07-03-2019	10,4		
08-03-2019	55,4		
09-03-2019	4,8		
10-03-2019	4,5		
11-03-2019	0		
12-03-2019	0		
13-03-2019	21,7		

Tanggal	Curah Hujan	Jumlah data	Tahun
14-03-2019	0,7		
15-03-2019	0		
16-03-2019	4,5		
17-03-2019	5		
18-03-2019	4,5		
19-03-2019	4,5		
20-03-2019	4,5		
21-03-2019	4,5		
22-03-2019	4,5		
23-03-2019	0		
24-03-2019	0		
25-03-2019	0		
26-03-2019	0		
27-03-2019	4,5		
28-03-2019	4,5		
29-03-2019	4,5		
30-03-2019	4,5		
31-03-2019	1,4		
01-04-2019	0		
02-04-2019	4,5		
03-04-2019	0		
04-04-2019	0		
05-04-2019	4,5		
06-04-2019	4,5		
07-04-2019	4,5		
08-04-2019	4,5		
09-04-2019	4,5		
10-04-2019	0		
11-04-2019	0		
12-04-2019	21,1		
13-04-2019	0,7		
14-04-2019	4,5		
15-04-2019	4,5		
16-04-2019	4,5		
17-04-2019	1,3		
18-04-2019	0,3		
19-04-2019	17,5		
20-04-2019	7,8		
21-04-2019	4,5		
22-04-2019	4,5		
23-04-2019	12,2		
24-04-2019	4,5		
25-04-2019	50,2		
26-04-2019	1,4		
27-04-2019	5,8		

Tanggal	Curah Hujan	Jumlah data	Tahun
28-04-2019	4,3		
29-04-2019	55,4		
30-04-2019	63		
01-05-2019	4,5		
02-05-2019	1		
03-05-2019	0		
04-05-2019	0,2		
05-05-2019	0		
06-05-2019	4,5		
07-05-2019	4,5		
08-05-2019	0		
09-05-2019	0		
10-05-2019	4,5		
11-05-2019	14,7		
12-05-2019	0		
13-05-2019	0		
14-05-2019	4,5		
15-05-2019	0,4		
16-05-2019	1		
17-05-2019	4,5		
18-05-2019	0		
19-05-2019	0		
20-05-2019	8		
21-05-2019	4,5		
22-05-2019	0		
23-05-2019	4,5		
24-05-2019	0		
25-05-2019	4,5		
26-05-2019	40,6		
27-05-2019	14,8		
28-05-2019	5,1		
29-05-2019	4,5		
30-05-2019	0,1		
31-05-2019	92,5		
01-06-2019	15,3		
02-06-2019	65		
03-06-2019	0		
04-06-2019	61,5		
05-06-2019	1,6		
06-06-2019	0		
07-06-2019	1,6		
08-06-2019	25		
09-06-2019	71,7		
10-06-2019	26,1		
11-06-2019	6,2		

Tanggal	Curah Hujan	Jumlah data	Tahun
12-06-2019	6,4		
13-06-2019	15,3		
14-06-2019	4,2		
15-06-2019	13,7		
16-06-2019	0,9		
17-06-2019	30		
18-06-2019	6,5		
19-06-2019	0,8		
20-06-2019	3,3		
21-06-2019	4,5		
22-06-2019	4,5		
23-06-2019	4,5		
24-06-2019	4,5		
25-06-2019	4,5		
26-06-2019	4,5		
27-06-2019	4,5		
28-06-2019	0,4		
29-06-2019	14,4		
30-06-2019	1,5		
01-07-2019	7,2		
02-07-2019	2,3		
03-07-2019	32		
04-07-2019	60,2		
05-07-2019	10,9		
06-07-2019	4,5		
07-07-2019	4,5		
08-07-2019	18,2		
09-07-2019	11		
10-07-2019	6,8		
11-07-2019	27,9		
12-07-2019	0,1		
13-07-2019	4,5		
14-07-2019	4,5		
15-07-2019	4,5		
16-07-2019	4,5		
17-07-2019	13		
18-07-2019	12,4		
19-07-2019	4,5		
20-07-2019	0,4		
21-07-2019	1		
22-07-2019	11,6		
23-07-2019	17,9		
24-07-2019	4,9		
25-07-2019	1,1		
26-07-2019	49,8		

Tanggal	Curah Hujan	Jumlah data	Tahun
27-07-2019	4,5		
28-07-2019	0,6		
29-07-2019	7		
30-07-2019	0		
31-07-2019	4,1		
01-08-2019	4,5		
02-08-2019	0		
03-08-2019	1,1		
04-08-2019	1,2		
05-08-2019	1,3		
06-08-2019	0,1		
07-08-2019	4,5		
08-08-2019	4,5		
09-08-2019	14,4		
10-08-2019	8,5		
11-08-2019	0		
12-08-2019	0		
13-08-2019	0,3		
14-08-2019	4,5		
15-08-2019	0		
16-08-2019	4,5		
17-08-2019	1,3		
18-08-2019	19,2		
19-08-2019	60,6		
20-08-2019	17,8		
21-08-2019	0,4		
22-08-2019	0,2		
23-08-2019	0,2		
24-08-2019	2		
25-08-2019	4,5		
26-08-2019	4,5		
27-08-2019	0,2		
28-08-2019	1		
29-08-2019	11,7		
30-08-2019	4,5		
31-08-2019	0,1		
01-09-2019	0		
02-09-2019	4,5		
03-09-2019	4,5		
04-09-2019	3,2		
05-09-2019	0,3		
06-09-2019	4,5		
07-09-2019	4,5		
08-09-2019	4,5		
09-09-2019	4,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
10-09-2019	4,5		
11-09-2019	4,5		
12-09-2019	0,1		
13-09-2019	4,5		
14-09-2019	4,5		
15-09-2019	0		
16-09-2019	4,5		
17-09-2019	4,5		
18-09-2019	4,5		
19-09-2019	4,5		
20-09-2019	7,5		
21-09-2019	6,3		
22-09-2019	4,5		
23-09-2019	4,5		
24-09-2019	4,5		
25-09-2019	4,5		
26-09-2019	8,4		
27-09-2019	4,5		
28-09-2019	2,4		
29-09-2019	6,6		
30-09-2019	21,1		
01-10-2019	0,8		
02-10-2019	46,8		
03-10-2019	0,7		
04-10-2019	16,8		
05-10-2019	4,5		
06-10-2019	4,5		
07-10-2019	0,2		
08-10-2019	3,5		
09-10-2019	4,5		
10-10-2019	2,7		
11-10-2019	4,5		
12-10-2019	11,3		
13-10-2019	4,5		
14-10-2019	1,5		
15-10-2019	8,8		
16-10-2019	4,5		
17-10-2019	125,4		
18-10-2019	5,3		
19-10-2019	4,5		
20-10-2019	4,5		
21-10-2019	19		
22-10-2019	0,5		
23-10-2019	23,2		
24-10-2019	2,6		

Tanggal	Curah Hujan	Jumlah data	Tahun
25-10-2019	39,7		
26-10-2019	0,8		
27-10-2019	0,3		
28-10-2019	18,9		
29-10-2019	22		
30-10-2019	0,7		
31-10-2019	4,5		
01-11-2019	5		
02-11-2019	7,2		
03-11-2019	4,5		
04-11-2019	1,5		
05-11-2019	4,5		
06-11-2019	4,5		
07-11-2019	4,5		
08-11-2019	4,5		
09-11-2019	4,5		
10-11-2019	7,5		
11-11-2019	4,5		
12-11-2019	4,5		
13-11-2019	4,5		
14-11-2019	0,5		
15-11-2019	4,5		
16-11-2019	8,4		
17-11-2019	4,5		
18-11-2019	4,5		
19-11-2019	4,5		
20-11-2019	0		
21-11-2019	4,5		
22-11-2019	4,5		
23-11-2019	4,5		
24-11-2019	4,5		
25-11-2019	4,5		
26-11-2019	0,8		
27-11-2019	0		
28-11-2019	4,5		
29-11-2019	4,5		
30-11-2019	4,5		
01-12-2019	4,5		
02-12-2019	0		
03-12-2019	1,4		
04-12-2019	9		
05-12-2019	0,3		
06-12-2019	4,5		
07-12-2019	4,5		
08-12-2019	0		

Tanggal	Curah Hujan	Jumlah data	Tahun
09-12-2019	4,5		
10-12-2019	4,3		
11-12-2019	4,5		
12-12-2019	3,2		
13-12-2019	4,5		
14-12-2019	0		
15-12-2019	0		
16-12-2019	4,5		
17-12-2019	4,5		
18-12-2019	6,6		
19-12-2019	5,8		
20-12-2019	16,2		
21-12-2019	0,1		
22-12-2019	0		
23-12-2019	1,4		
24-12-2019	21,5		
25-12-2019	0		
26-12-2019	3,6		
27-12-2019	5		
28-12-2019	4,5		
29-12-2019	3,3		
30-12-2019	0		
31-12-2019	4,5		
01-01-2020	4,5	352	2020
02-01-2020	4,5		
03-01-2020	4,5		
04-01-2020	5,9		
05-01-2020	4,5		
06-01-2020	6,3		
07-01-2020	9		
08-01-2020	4,5		
09-01-2020	0,5		
10-01-2020	0		
11-01-2020	4,5		
12-01-2020	10,8		
13-01-2020	1,4		
14-01-2020	1,5		
15-01-2020	0		
16-01-2020	4,5		
17-01-2020	4,5		
18-01-2020	4,5		
19-01-2020	4,5		
20-01-2020	0		
21-01-2020	4,5		
22-01-2020	0,2		

Tanggal	Curah Hujan	Jumlah data	Tahun
23-01-2020	4,5		
24-01-2020	0		
25-01-2020	0		
26-01-2020	0		
27-01-2020	4,5		
28-01-2020	0		
29-01-2020	0		
30-01-2020	4,5		
31-01-2020	4,5		
01-02-2020	0		
02-02-2020	4,5		
03-02-2020	0		
04-02-2020	0		
05-02-2020	0		
06-02-2020	4,5		
07-02-2020	10,3		
08-02-2020	0		
09-02-2020	0		
10-02-2020	0		
11-02-2020	0		
12-02-2020	0		
13-02-2020	4,5		
14-02-2020	4,5		
15-02-2020	4,5		
16-02-2020	0		
17-02-2020	0,4		
18-02-2020	4,5		
19-02-2020	2,6		
20-02-2020	5,7		
21-02-2020	0,1		
22-02-2020	4,5		
23-02-2020	0,8		
24-02-2020	0,1		
25-02-2020	4,5		
26-02-2020	5,7		
27-02-2020	9,6		
28-02-2020	2,5		
29-02-2020	4,5		
01-03-2020	4,5		
02-03-2020	6,4		
03-03-2020	3,4		
04-03-2020	4,5		
05-03-2020	0,7		
06-03-2020	3,4		
07-03-2020	2,6		

Tanggal	Curah Hujan	Jumlah data	Tahun
08-03-2020	31,1		
09-03-2020	4,5		
10-03-2020	4,5		
11-03-2020	4,5		
12-03-2020	4,5		
13-03-2020	4,5		
14-03-2020	17,4		
15-03-2020	4,5		
16-03-2020	4,5		
17-03-2020	4,5		
18-03-2020	4,5		
19-03-2020	7,4		
20-03-2020	4,5		
21-03-2020	32,5		
22-03-2020	6,5		
23-03-2020	9		
24-03-2020	17,7		
25-03-2020	0,2		
26-03-2020	9,2		
27-03-2020	4,5		
28-03-2020	6,7		
29-03-2020	4,7		
30-03-2020	0		
31-03-2020	4,5		
01-04-2020	6,9		
02-04-2020	20,4		
03-04-2020	4,5		
04-04-2020	0		
05-04-2020	75		
06-04-2020	0		
07-04-2020	0		
08-04-2020	0		
09-04-2020	7		
10-04-2020	4,5		
11-04-2020	0		
12-04-2020	4,5		
13-04-2020	0,2		
14-04-2020	0		
15-04-2020	32,3		
16-04-2020	11,5		
17-04-2020	0,6		
18-04-2020	0,2		
19-04-2020	0		
20-04-2020	4,5		
21-04-2020	6,8		

Tanggal	Curah Hujan	Jumlah data	Tahun
22-04-2020	0		
23-04-2020	26,8		
24-04-2020	4,7		
25-04-2020	1,7		
26-04-2020	3,6		
27-04-2020	4		
28-04-2020	4,5		
29-04-2020	12,7		
30-04-2020	21,4		
01-05-2020	1		
02-05-2020	4,5		
03-05-2020	0		
04-05-2020	0		
05-05-2020	4,5		
06-05-2020	0		
07-05-2020	0		
08-05-2020	0		
09-05-2020	0		
10-05-2020	1,4		
11-05-2020	0,2		
12-05-2020	0		
13-05-2020	1,9		
14-05-2020	0		
15-05-2020	0		
16-05-2020	0		
17-05-2020	4,5		
18-05-2020	12,1		
19-05-2020	2,2		
20-05-2020	8,8		
21-05-2020	51,2		
22-05-2020	0		
24-05-2020	4,5		
25-05-2020	3,3		
26-05-2020	14,5		
27-05-2020	0		
28-05-2020	32		
29-05-2020	3,6		
30-05-2020	0		
31-05-2020	5,8		
01-06-2020	41,3		
02-06-2020	5,8		
03-06-2020	42,3		
04-06-2020	4,4		
05-06-2020	0		
06-06-2020	0		

Tanggal	Curah Hujan	Jumlah data	Tahun
07-06-2020	5,1		
08-06-2020	0,6		
09-06-2020	42		
10-06-2020	5,9		
11-06-2020	24,6		
12-06-2020	40,6		
13-06-2020	28,8		
14-06-2020	37		
15-06-2020	18,1		
16-06-2020	0,9		
17-06-2020	17,8		
18-06-2020	21,7		
19-06-2020	4,5		
20-06-2020	34		
21-06-2020	9,8		
22-06-2020	4,6		
23-06-2020	6,9		
24-06-2020	35,9		
25-06-2020	15,6		
26-06-2020	6,2		
27-06-2020	24,5		
28-06-2020	32,2		
29-06-2020	7,1		
30-06-2020	1,3		
01-07-2020	34		
02-07-2020	4,5		
03-07-2020	19,6		
04-07-2020	58,1		
05-07-2020	17,5		
06-07-2020	3,3		
07-07-2020	4,1		
08-07-2020	12		
09-07-2020	13		
10-07-2020	9,7		
11-07-2020	5,7		
12-07-2020	8,1		
13-07-2020	8,4		
14-07-2020	2		
15-07-2020	25,9		
16-07-2020	34		
17-07-2020	136,8		
18-07-2020	12		
19-07-2020	0,1		
20-07-2020	0,8		
21-07-2020	56		

Tanggal	Curah Hujan	Jumlah data	Tahun
22-07-2020	6,6		
23-07-2020	9,6		
24-07-2020	53		
25-07-2020	103,1		
26-07-2020	29,1		
27-07-2020	1,4		
28-07-2020	34,9		
29-07-2020	30,3		
30-07-2020	5,7		
31-07-2020	4,1		
01-08-2020	38,4		
02-08-2020	0,2		
03-08-2020	0,2		
04-08-2020	0,1		
05-08-2020	0,5		
06-08-2020	12,5		
07-08-2020	3,8		
08-08-2020	78,6		
09-08-2020	29,4		
10-08-2020	3,5		
11-08-2020	36,8		
12-08-2020	15,5		
13-08-2020	0,3		
14-08-2020	12,9		
15-08-2020	32,3		
16-08-2020	5,3		
17-08-2020	49,8		
18-08-2020	0,1		
19-08-2020	6,4		
20-08-2020	14,2		
21-08-2020	8,4		
22-08-2020	38,7		
23-08-2020	13,4		
24-08-2020	3		
25-08-2020	4,5		
26-08-2020	1,7		
27-08-2020	5,5		
28-08-2020	8,2		
29-08-2020	3		
30-08-2020	5,9		
31-08-2020	0,4		
01-09-2020	1,2		
02-09-2020	58,7		
03-09-2020	26,7		
04-09-2020	4,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
05-09-2020	8,5		
06-09-2020	1,2		
07-09-2020	48,4		
08-09-2020	45,9		
09-09-2020	24		
10-09-2020	17,8		
11-09-2020	7,4		
12-09-2020	2,1		
13-09-2020	23,5		
14-09-2020	82,9		
28-09-2020	16,2		
29-09-2020	3		
30-09-2020	6,3		
01-10-2020	4,5		
02-10-2020	1,5		
03-10-2020	47,9		
04-10-2020	7,5		
05-10-2020	4,5		
06-10-2020	1,9		
07-10-2020	11		
08-10-2020	29,1		
09-10-2020	0		
10-10-2020	1,1		
11-10-2020	4,5		
12-10-2020	11		
13-10-2020	2,5		
14-10-2020	41,7		
15-10-2020	33,5		
16-10-2020	0,8		
17-10-2020	63,7		
18-10-2020	4		
19-10-2020	2		
20-10-2020	4,5		
21-10-2020	4		
22-10-2020	1,2		
23-10-2020	0,2		
24-10-2020	0,8		
25-10-2020	4,8		
26-10-2020	15		
27-10-2020	29,7		
28-10-2020	17,2		
29-10-2020	46,6		
30-10-2020	0		
31-10-2020	16,8		
01-11-2020	0,2		

Tanggal	Curah Hujan	Jumlah data	Tahun
02-11-2020	52,5		
03-11-2020	4,1		
04-11-2020	12,7		
05-11-2020	0		
06-11-2020	4,5		
07-11-2020	0		
08-11-2020	0		
09-11-2020	4,5		
10-11-2020	3,5		
11-11-2020	4,5		
12-11-2020	11,8		
13-11-2020	32		
14-11-2020	2		
15-11-2020	0		
16-11-2020	5,2		
17-11-2020	1,7		
18-11-2020	17,1		
19-11-2020	1,1		
20-11-2020	13,7		
21-11-2020	47,5		
22-11-2020	0,8		
23-11-2020	36,4		
24-11-2020	0		
25-11-2020	4,9		
26-11-2020	9,2		
27-11-2020	0,1		
28-11-2020	1,6		
29-11-2020	1,8		
30-11-2020	12,8		
01-12-2020	9,8		
02-12-2020	7,1		
03-12-2020	0		
04-12-2020	0		
05-12-2020	4,5		
06-12-2020	0		
07-12-2020	0,8		
08-12-2020	4,5		
09-12-2020	19		
10-12-2020	4,5		
11-12-2020	3,4		
12-12-2020	1,2		
13-12-2020	4,5		
14-12-2020	4,5		
15-12-2020	3,5		
16-12-2020	11,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
17-12-2020	17,1		
18-12-2020	0		
19-12-2020	4,5		
20-12-2020	0,9		
21-12-2020	1,4		
22-12-2020	14		
23-12-2020	0,2		
24-12-2020	12		
25-12-2020	3,3		
26-12-2020	28,5		
27-12-2020	0,6		
28-12-2020	5,8		
29-12-2020	4,1		
30-12-2020	0		
31-12-2020	0		
01-01-2021	0	365	2021
02-01-2021	15,3		
03-01-2021	3,6		
04-01-2021	1,7		
05-01-2021	11,8		
06-01-2021	1,3		
07-01-2021	23,4		
08-01-2021	0		
09-01-2021	12		
10-01-2021	0		
11-01-2021	0		
12-01-2021	9,3		
13-01-2021	1		
14-01-2021	10		
15-01-2021	30,3		
16-01-2021	59,5		
17-01-2021	12,1		
18-01-2021	1,5		
19-01-2021	0,2		
20-01-2021	0		
21-01-2021	0		
22-01-2021	4,5		
23-01-2021	4,5		
24-01-2021	16,2		
25-01-2021	9,3		
26-01-2021	57,5		
27-01-2021	21,8		
28-01-2021	4,1		
29-01-2021	69,6		
30-01-2021	0		

Tanggal	Curah Hujan	Jumlah data	Tahun
31-01-2021	2,2		
01-02-2021	4,5		
02-02-2021	1,9		
03-02-2021	38,4		
04-02-2021	4,5		
05-02-2021	0		
06-02-2021	4,5		
07-02-2021	0		
08-02-2021	8,4		
09-02-2021	0,6		
10-02-2021	0		
11-02-2021	0		
12-02-2021	0		
13-02-2021	0,8		
14-02-2021	0,7		
15-02-2021	0,4		
16-02-2021	25		
17-02-2021	0		
18-02-2021	15,9		
19-02-2021	0,7		
20-02-2021	0		
21-02-2021	2,5		
22-02-2021	1,6		
23-02-2021	12,9		
24-02-2021	2,5		
25-02-2021	3,6		
26-02-2021	60,5		
27-02-2021	4,5		
28-02-2021	0		
01-03-2021	0		
02-03-2021	41,2		
03-03-2021	3,4		
04-03-2021	2		
05-03-2021	1,3		
06-03-2021	4,5		
07-03-2021	32,4		
08-03-2021	0,6		
09-03-2021	0,3		
10-03-2021	0		
11-03-2021	0		
12-03-2021	39,7		
13-03-2021	4,5		
14-03-2021	0,6		
15-03-2021	4,4		
16-03-2021	0		

Tanggal	Curah Hujan	Jumlah data	Tahun
17-03-2021	0,5		
18-03-2021	4,5		
19-03-2021	12,3		
20-03-2021	20,1		
21-03-2021	0		
22-03-2021	38,8		
23-03-2021	4,5		
24-03-2021	6,9		
25-03-2021	7,8		
26-03-2021	1,8		
27-03-2021	4,5		
28-03-2021	3,4		
29-03-2021	13,5		
30-03-2021	0		
31-03-2021	2,1		
01-04-2021	2,8		
02-04-2021	4,5		
03-04-2021	33,4		
04-04-2021	0		
05-04-2021	8,2		
06-04-2021	0		
07-04-2021	3,5		
08-04-2021	4,5		
09-04-2021	13,5		
10-04-2021	4,5		
11-04-2021	6,4		
12-04-2021	20,5		
13-04-2021	1,9		
14-04-2021	9,8		
15-04-2021	0,8		
16-04-2021	0,3		
17-04-2021	0		
18-04-2021	4,3		
19-04-2021	4,8		
20-04-2021	1,3		
21-04-2021	0		
22-04-2021	0		
23-04-2021	4,5		
24-04-2021	2,4		
25-04-2021	3,5		
26-04-2021	0		
27-04-2021	0		
28-04-2021	4,5		
29-04-2021	1,6		
30-04-2021	0,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
01-05-2021	0		
02-05-2021	0,4		
03-05-2021	15,1		
04-05-2021	0,3		
05-05-2021	4,2		
06-05-2021	0,1		
07-05-2021	3		
08-05-2021	0		
09-05-2021	8		
10-05-2021	3		
11-05-2021	0		
12-05-2021	0,3		
13-05-2021	0		
14-05-2021	36,1		
15-05-2021	12,8		
16-05-2021	4,5		
17-05-2021	9,6		
18-05-2021	8,2		
19-05-2021	4,3		
20-05-2021	23,1		
21-05-2021	6,2		
22-05-2021	7,3		
23-05-2021	0		
24-05-2021	19,6		
25-05-2021	4,5		
26-05-2021	38,4		
27-05-2021	4,5		
28-05-2021	0,4		
29-05-2021	10,8		
30-05-2021	5,6		
31-05-2021	13,5		
01-06-2021	0,9		
02-06-2021	6,1		
03-06-2021	6,7		
04-06-2021	14,3		
05-06-2021	0,9		
06-06-2021	3,6		
07-06-2021	0		
08-06-2021	0,3		
09-06-2021	0		
10-06-2021	0		
11-06-2021	4,5		
12-06-2021	66,4		
13-06-2021	6,6		
14-06-2021	48,6		

Tanggal	Curah Hujan	Jumlah data	Tahun
15-06-2021	4,5		
16-06-2021	20,5		
17-06-2021	18,1		
18-06-2021	0,7		
19-06-2021	2		
20-06-2021	15,3		
21-06-2021	16,2		
22-06-2021	4,3		
23-06-2021	41,5		
24-06-2021	9,4		
25-06-2021	35,4		
26-06-2021	4,5		
27-06-2021	73,2		
28-06-2021	23,7		
29-06-2021	22,9		
30-06-2021	16,2		
01-07-2021	24,5		
02-07-2021	0,2		
03-07-2021	3		
04-07-2021	20,9		
05-07-2021	21,4		
06-07-2021	15,3		
07-07-2021	32,7		
08-07-2021	6,4		
09-07-2021	6,5		
10-07-2021	30,6		
11-07-2021	10		
12-07-2021	14,8		
13-07-2021	4,8		
14-07-2021	4		
15-07-2021	25,2		
16-07-2021	24,4		
17-07-2021	15,8		
18-07-2021	2,2		
19-07-2021	1,2		
20-07-2021	0,1		
21-07-2021	48,2		
22-07-2021	7		
23-07-2021	0,8		
24-07-2021	4,5		
25-07-2021	0,5		
26-07-2021	0		
27-07-2021	0		
28-07-2021	4,5		
29-07-2021	4,5		

Tanggal	Curah Hujan	Jumlah data	Tahun
30-07-2021	2		
31-07-2021	0		
01-08-2021	0		
02-08-2021	0		
03-08-2021	0		
04-08-2021	0		
05-08-2021	7,6		
06-08-2021	4,5		
07-08-2021	7		
08-08-2021	2,8		
09-08-2021	0		
10-08-2021	3,5		
11-08-2021	8,7		
12-08-2021	25,1		
13-08-2021	22,2		
14-08-2021	17,6		
15-08-2021	17,8		
16-08-2021	18,4		
17-08-2021	21,4		
18-08-2021	14,9		
19-08-2021	3,6		
20-08-2021	20,3		
21-08-2021	16,4		
22-08-2021	19,1		
23-08-2021	17,6		
24-08-2021	1,9		
25-08-2021	91,9		
26-08-2021	10,6		
27-08-2021	15,5		
28-08-2021	19,9		
29-08-2021	42,3		
30-08-2021	12,2		
31-08-2021	24,9		
01-09-2021	48,2		
02-09-2021	2,2		
03-09-2021	0		
04-09-2021	9		
05-09-2021	67		
06-09-2021	7		
07-09-2021	0		
08-09-2021	11,2		
09-09-2021	5,5		
10-09-2021	21,6		
11-09-2021	8,6		
12-09-2021	105,2		

Tanggal	Curah Hujan	Jumlah data	Tahun
13-09-2021	17,9		
14-09-2021	9,1		
15-09-2021	2,3		
16-09-2021	16,5		
17-09-2021	1,1		
18-09-2021	40		
19-09-2021	1,1		
20-09-2021	23,8		
21-09-2021	22,3		
22-09-2021	1,8		
23-09-2021	17,1		
24-09-2021	18,5		
25-09-2021	4,3		
26-09-2021	25,6		
27-09-2021	5,2		
28-09-2021	23		
29-09-2021	41,8		
30-09-2021	2,3		
01-10-2021	3,8		
02-10-2021	7,8		
03-10-2021	0,4		
04-10-2021	12,3		
05-10-2021	0		
06-10-2021	1,4		
07-10-2021	0		
08-10-2021	5,6		
09-10-2021	4,5		
10-10-2021	1,1		
11-10-2021	0		
12-10-2021	4,5		
13-10-2021	0,3		
14-10-2021	0		
15-10-2021	4,5		
16-10-2021	0		
17-10-2021	2		
18-10-2021	4,5		
19-10-2021	36,1		
20-10-2021	48,6		
21-10-2021	0,2		
22-10-2021	3,2		
23-10-2021	0,6		
24-10-2021	31,7		
25-10-2021	0,6		
26-10-2021	3,7		
27-10-2021	0		

Tanggal	Curah Hujan	Jumlah data	Tahun
28-10-2021	15,2		
29-10-2021	4,6		
30-10-2021	0		
31-10-2021	4,7		
01-11-2021	4,5		
02-11-2021	10,4		
03-11-2021	5,6		
04-11-2021	30,2		
05-11-2021	37,5		
06-11-2021	7,3		
07-11-2021	9,7		
08-11-2021	11		
09-11-2021	2,2		
10-11-2021	0,1		
11-11-2021	1,8		
12-11-2021	1,5		
13-11-2021	73,3		
14-11-2021	0,2		
15-11-2021	45,4		
16-11-2021	0,5		
17-11-2021	0		
18-11-2021	0		
19-11-2021	4,5		
20-11-2021	0		
21-11-2021	16,9		
22-11-2021	2,5		
23-11-2021	9,2		
24-11-2021	0		
25-11-2021	4,6		
26-11-2021	12,2		
27-11-2021	1,6		
28-11-2021	1,3		
29-11-2021	0		
30-11-2021	2		
01-12-2021	8,4		
02-12-2021	14,7		
03-12-2021	8,4		
04-12-2021	5		
05-12-2021	23,5		
06-12-2021	13,5		
07-12-2021	4,5		
08-12-2021	1,9		
09-12-2021	23,8		
10-12-2021	0,2		
11-12-2021	0		

Tanggal	Curah Hujan	Jumlah data	Tahun
12-12-2021	5,6		
13-12-2021	11,9		
14-12-2021	8		
15-12-2021	2,6		
16-12-2021	18,7		
17-12-2021	0		
18-12-2021	22,3		
19-12-2021	8		
20-12-2021	4,5		
21-12-2021	74,2		
22-12-2021	0		
23-12-2021	39		
24-12-2021	31,6		
25-12-2021	0		
26-12-2021	24,3		
27-12-2021	2,2		
28-12-2021	7,1		
29-12-2021	49,9		
30-12-2021	0		
31-12-2021	4,5		
Total Data		1812	2017 s.d. 2021

CATATAN REVISI UJIAN TESIS

NIM : 19.77.1175
Nama mahasiswa : Muhammad Yusuf
Pembimbing I : Dr. Arief Setyanto, S.Si., M.T.
Pembimbing II : Komang Aryasa, S.Kom, M.T
Judul Tesis : Analisis Prediksi Curah Hujan di Wilayah Kota Sorong Menggunakan Metode Time Series Forecasting

Kegiatan : Ujian Tesis
Hari, tanggal : Rabu, 3 Agustus 2022

Penguji 1 : Prof. Dr. Kusrini, M.Kom.

Revisi :
1. Penulisan sub bab pakai proper text
2. Rumusan masalah terkait apa yang dicari
Skenario
3. Perbandingan dengan penelitian lain... apa yang beda skenarionya
4. Cara kerja LSTM dan FB Prophet
5. RMSE dan MAE bedanya apa, kenapa digunakan keduanya, jika ada hasil berbeda bagaimana?
6. Saran lengkap di <http://www.youtube.com/watch?v=bGaQEhtu2gM>

Rekomendasi : Lulus dengan revisi

Penguji 2 : Dr. Andi Sunyoto, M.Kom.

Revisi :
- Tuliskan apa kelemahan dari model yang diusulkan.
- Tuliskan saran berdasarkan kelemahan yang ada.

Rekomendasi : LULUS dengan revisi minor.

Penguji 3 : Dr. Arief Setyanto, S.Si., M.T.

Revisi : tambahan rumusan masalah membandingkan pre-processing tambahan kesimpulan

Rekomendasi : lulus dengan revisi

Persetujuan atas revisi ujian tesis adalah tanggung jawab Dosen Penguji yang bersangkutan.

Kepada Yth. Dosen Pengaji

Bersama ini saya menyampaikan catatan Hasil Revisi Ujian Tesis atas nama saya Muhammad Yusuf (NIM 19.77.1175) pada hari Rabu, 03 Agustus 2022 adalah sebagai berikut:

1. Pertama dapat saya sampaikan permohonan maaf saya yang sebesar-besarnya karena pada saat ujian tesis terdapat kesalahan codingan pada python yang saya lakukan, dimana data yang diambil sebagai target untuk pemodelan adalah data Suhu dan bukan data Curah Hujan.



Codingan di python sebelum Ujian Tesis

Codingan di python setelah Ujian Tesis

2. Karena adanya perubahan codingan tersebut maka hasil evaluasi pengukuran tingkat kesalahan (RMSE dan MAE) mendapatkan nilai yang berbeda pada saat Ujian Tesis.
3. Dalam Revisi ini saya melakukan perbandingan pembagian dataset dan tidak melakukan perbandingan pra-preprocessing kecuali pada bagian perbandingan dengan penelitian sebelumnya..

Berikut Hasil Perbaikan sesuai catatan revisi dari Tim Pengaji di Ujian Tesis :

Pengaji 1 : Ibu Prof. Dr. Kusrini, M.Kom.

1. Penulisan sub bab pakar proper text
Revisi : Sudah dilakukan perbaikan penulisan.
2. Rumusan masalah terkait apa yang dicari Skenario
Revisi : Sudah dilakukan perbaikan, dimana pada Rumusan Masalah dan Tujuan telah ditambahkan point yaitu melakukan Skenario berupa perbandingan hasil evaluasi nilai tingkat kesalahan (RMSE & MAE) berdasarkan pembagian (split) datanya.
3. Cara kerja LSTM dan FB Prophet.
Revisi : Sudah dilakukan perbaikan, dimana telah ditambahkan langkah-langkah dan cara kerja LSTM dan FB Prophet di BAB III Metodologi (halaman 32 s/d 36)
4. RMSE dan MAE bedanya apa, kenapa digunakan keduanya, jika ada hasil berbeda bagaimana?
Revisi : Sudah dilakukan perbaikan, dimana telah ditambahkan penjelasan terkait perbedaan antara RMSE dan MAE dan apa yang dilakukan jika ada hasil yang berbeda di BAB III Metodologi (halaman 36 s/d 37)

Pengaji 2 : Bpk. Dr. Andi Sunyoto M. Kom.

1. Tuliskan apa kelemahan dari model yang diusulkan

Revisi : Sudah dilakukan perbaikan dengan menambahkan kelemahan model LSTM di Kesimpulan.

2. Tuliskan saran berdasarkan kelemahan yang ada

Revisi : Sudah dilakukan perbaikan dengan menambahkan kelemahan model LSTM di Kesimpulan.

Pengaji 2 : Bpk. Dr. Arlef Setyanto, S.Si, M.T.

1. Tambahkan rumusan masalah

Revisi : Sudah dilakukan perbaikan dengan menambahkan pada rumusan masalah perbandingan pembagian (split) data pada model LSTM dan FB Prophet.

2. Tambahkan kesimpulan

Revisi : Sudah dilakukan perbaikan pada Kesimpulan.

Hasil Revisi yang saya lakukan telah saya blok Kuning pada Naskah Laporan Tesis.

Demikian catatan hasil revisi saya, atas perhatian dan masukan dari Bpk/Ibu Dosen Pengaji saya ucapan terimakasih.

