

ANALISIS POLA CUACA EXTREM MENGGUNAKAN *LONG SHORT TERM MEMORY* PADA WILAYAH JAWA BARAT

Muhammad Maulana Yusuf ¹, Martanto ², Umi Hayati ³

^{1,3}Teknik Informatika, ²Manajemen Informatika, STMIK IKMI Cirebon
Jalan Perjuangan No.10B, Karyamulya, Kota Cirebon, Indonesia
Youseuf2802@gmail.com

ABSTRAK

Perubahan alam dipengaruhi oleh berbagai faktor terutama manusia, kegiatan ekonomi yang tidak mungkin terlepas dengan manusia, menjadi faktor utama. Perubahan lingkungan berdampak berubahnya cuaca, seperti pembangunan Gedung, *infrastruktur*, dan *deforestasi*, memengaruhi berubahnya lingkungan, secara langsung mengakibatkan berubahnya *vegetasi alam*, serta cuaca di wilayah tersebut ikut berubah. Perubahan cuaca yang tidak menentu, mengakibatkan munculnya Cuaca ekstrem, yaitu *fenomena* yang tidak biasa terjadi serta dapat menjadi masalah serius. Pada berbagai aspek kehidupan Kondisi seperti banjir dan badai contoh hasil cuaca ekstrem. Cuaca ekstrem mengakibatkan kerugian bagi makhluk hidup. penelitian ini bertujuan menganalisis terjadinya cuaca ekstrem menggunakan *Long Short Term Memory (LSTM)*. Model *LSTM* digunakan untuk mengidentifikasi cuaca ekstrem, meramalkan terjadinya cuaca ekstrem di masa depan, memahami faktor yang memengaruhi munculnya cuaca ekstrem. Model *LSTM* mampu mengenali pola cuaca ekstrem dengan akurasi yang memadai. Penelitian ini mengembangkan model *LSTM* menggunakan 8 kali nilai *threshlod value* yaitu 28, 31, 34, 37, 40, 43, 46, 49, epoch sebanyak 50 dan model akurasi untuk menentukan keadaan cuaca mencapai 100 %. Data diambil dari *website BMKG* untuk digunakan pada penelitian. Dari hasil yang didapat, disimpulkan bahwa perbedaan nilai *threshlod* berpengaruh terhadap nilai prediksi cuaca kedepan selama 7 hari.

Kata kunci : *LSTM (Long Short Term Memory), Extrem, Deforestasi, BMKG*

1. PENDAHULUAN

Teknologi mengalami perkembangan yang sangat pesat, munculnya pengetahuan baru menjadi ilmu yang bermanfaat, baik dibidang Pendidikan, ekonomi, cuaca, dan lainnya. Tujuan perkembangan dan perubahan, untuk memudahkan aktifitas manusia. Kecerdasan buatan muncul, membuat kumpulan data dapat diolah menjadi pengetahuan yang memiliki nilai manfaat. Kecerdasan buatan adalah sebuah system algoritma yang dibuat dan dikembangkan serta memiliki kemampuan berinovasi pada bidang yang dimodelkan baik komputer atau mesin, menjadi mampu berfikir seperti kecerdasan manusia atau bahkan melebihi[1].

Dengan data yang semakin banyak, akurasi juga meningkat. Cuaca adalah kondisi keadaan alam dalam rentang waktu yang terbatas dan sempit [2]. Pemahaman situasi cuaca, memiliki manfaat yang besar, karena memberi pengetahuan untuk pencegahan awal saat cuaca ekstrem. Perkembangan teknologi yang semakin modern memberi peluang meningkatkan akurasi ketepatan prediksi cuaca. Prediksi cuaca adalah Tindakan untuk memahami, bagaimana perkembangan keadaan udara dari masa lalu, saat ini, hingga memprediksi masa depan, untukantisipasi apabila keadaan tidak normal [3].

Memahami analisis dan prediksi cuaca sangat penting, penelitian dalam bidang ini terus mengalami perkembangan. Akurasi yang didapatkan dengan menggunakan *esemble learning* sebesar 81.21% dengan *MSE* 18.79%, dengan metode *decision tree algoritma forest* akurasi yang didapat sebesar 82.38% dengan *MSE* 17.62%, dengan metode *deep learning*

mendapat akurasi sebesar 82.92% dengan *MSE* 17.08%. *MSE (Mean Squared Error)* adalah salah satu metrik, yang digunakan untuk prediksi cara dan mengukur sejauh mana model cocok dengan data pengamatan aktual, serta prediksi cuaca sejauh mana perkiraan model akurat [3]. Selain itu, proses pemantauan integrasi radar cuaca diseluruh wilayah Indonesia secara Bersama, ternyata masih memerlukan waktu yang cukup lama [4].

Memprediksi cuaca ekstrem, menjadi tantangan bagi para ahli pemodelan di Indonesia bahkan dunia. Cuaca ekstrem menjadi permasalahan kompleks karena peluang terjadinya kecil mengakibatkan model yang dikembangkan memiliki akurasi yang rendah [5]. Tujuan utama penelitian ini adalah untuk meningkatkan akurasi yang lebih tinggi, dalam memprediksi dan menganalisis cuaca ekstrem yang lebih akurat untuk masa mendatang.

Penelitian ini menggunakan metode *deep learning* yaitu algoritma *Long Short Term Memory (LSTM)*, mengembangkan lebih lanjut berdasarkan data. *LSTM* merupakan metode jaringan syaraf tiruan, yang menggunakan informasi dari masa lalu, untuk diproses dengan bentuk data berurutan atau sekuensial [6]. Dengan menggunakan algoritma *LSTM*, mampu meningkatkan akurasi analisis cuaca, akan mendukung berbagai sektor untuk mengambil keputusan yang lebih tepat. Akurasi prediksi cuaca ekstrem yang tinggi, dapat memberikan informasi akurat, kemudian mengurangi risiko dampak cuaca ekstrem. Penggunaan teknologi *artificial intelegant* seperti *deep learning*, untuk analisis dan prediksi cuaca, memberikan kemungkinan perencanaan yang lebih baik. hasil

penelitian ini berpotensi besar untuk meningkatkan pemahaman tentang informasi cuaca, serta kontribusi teknologi *artificial intelegent metode deep learning algoritma LSTM*, untuk analisis dan memprediksi di bidang cuaca yang lebih baik.

2. TINJAUAN PUSTAKA

Pada penelitian ini metode yang digunakan adalah *systematic literature review*. Metode *systematic literature review* adalah metode dengan cara melakukan tela'ah dan mengolah sumber tulisan ilmiah yang ada serta telah terpublikasi[7].

2.1. Metode

Pada penelitian ini metode tahapan – tahapan tersebut adalah

- Tahapan identifikasi, melakukan pencarian literatur sesuai dengan judul.
- Tahapan seleksi, mealukan pemilihan dan penelompokan sesuai penelitian yang dilakukan.
- Tahapan verifikasi, pemeriksaan berdasarkan kriteria yang ditetapkan peneliti.
- Tahapan kombinasi dan menyimpulkan, hasil memadukan teori, yang telah ada dengan penelitian ini.

2.2. Hasil

Hasil yang telah dilakukan pada jurnal – jurnal terkait dengan judul penelitian.

- Jurnal berjudul “analisis data time series menggunakan LSTM (Long Short Term Memory) dan ARIMA (Autocorrelation Integrated Moving Average) dalam Bahasa Python” menjelaskan, metode statistik ARIMA (Autocorrelation Integrated Moving Average) memerlukan peningkatan akurasi serta perlu menurunkan nilai Error. Penelitian ini juga, menggunakan metode LSTM (Long Short Term Memory) mendapat kesimpulan metode LSTM lebih akurat,

dibandingkan menggunakan ARIMA. Hasil prediksi penelitian, berupa saham Telkom mencapai tingkat akurasi 99%, RMSE 1 %, setelah data melalui proses *transformasi loging* kemudian EWMA atau *loging* kemudian Moving average[8].

- Jurnal berjudul “implementasi deep learning menggunakan arsitektur Long Short Term Memory untuk prediksi curah hujan kota malang” menjelaskan *deep learning*, yang dilakukan penelitian sebelumnya mencapai akurasi sebesar 85%. *Deep learning* merupakan jaringan, yang memiliki beberapa layer dimana layer – layer tersebut, berasal dari kumpulan node – node. Dengan menggunakan arsitektur LSTM (Long Short Term Memory) dalam kasus yang berbeda, RME dihasilkan kecil, kesimpulannya metode LSTM (Long Short Term Memory) untuk prediksi curah hujan kota malang, memberikan hasil prediksi yang tergolong cukup baik. Oleh karena itu arsitektur LSTM mampu bekerja cukup optimal[9].
- Jurnal berjudul “implementasi Long Short Term Memory (LSTM) untuk perdiksi intensitas curah hujan (studi kasus : kabupaten malang)” menjelaskan, kabupaten malang adalah daerah yang memiliki iklim tropis dan memiliki sumber daya alam yang melimpah, seperti sektor pertanian dan perkebunan, sektor ini memiliki beberapa faktor yang dapat mempengaruhi tingkat produktifitas, salah satunya yaitu curah hujan. Penelitian membahas prediksi curah hujan, di kabupaten malang dengan menggunakan metode LSTM (Long Short Term Memory). Kesimpulannya metode LSTM (Long Short Term Memory) memiliki performa terbaik, dengan parameter yang ditentukan dengan nilai error adalah RMSE sebesar 0.98162 dan MAE sebesar 0.68847[10].

2.3. Tabel

Tabel 1. Ringkasan


Judul	Author	Masalah	Metode
Analisis data time series menggunakan lstm (long short term memory) dan Arima (autocorrelation integrated moving average) dalam bahasa python	Adhitio satyo, bayangkari karno	Memprediksi saham Telkom.	LSTM (Long Short Term Memory) dan ARIMA (Autocorrelation Integrated Moving Average).
Implementasi deep learning menggunakan arsitektur long Short-term memory untuk prediksi curah hujan kota malang	Muhammad Rizki, Setio Basuki, Yufis Azhar	Memprediksi curah hujan di kota malang.	Lstm (long short term memory).
Implementasi long short-term memory (lstm) untuk prediksi intensitas curah hujan (studi kasus: kabupaten malang)	Thoriq Afa Faisal Muhammad, dan Mohammad Isa Irawan	Memprediksi parameter cuaca, yang berpengaruh terhadap lingkungan dimana kabupaten malang adalah daerah yang memiliki iklim tropis dan bergerak pada sektor pertanian dan perkebunan.	Lstm (long short term memory).

Berdasarkan tabel 1. Ringkasan, disimpulkan cuaca sangat mempengaruhi kegiatan manusia, baik itu disektor pertanian, perkebunan, transportasi, bisnis, atau bahkan aktivitas setiap individu. Cuaca ekstrem dapat membuat banyak kerugian seperti yang dijelaskan oleh jurnal yang berjudul “*tipologi kerusakan bangunan akibat cuaca ekstrem studi kasus cuaca ekstrem kabupaten bantul 2019*” menjelaskan, telah terjadi peristiwa bencana sebanyak 2.564 diseluruh wilaya Indonesia, yang menyebabkan banyak kerugian seperti rusaknya bangunan. Oleh karena itu, banyak penelitian yang mencoba untuk memprediksi keadaan cuaca dan menganalisis faktor

-faktor terjadi cuaca ekstrem. Salah satu metode, yang mampu untuk menganalisis dan memprediksi cuaca adalah *algoritma LSTM (Long Short Term Memory)*. Tipe data yang digunakan adalah data *time series* atau urutan waktu, dengan cara melatih data tersebut menggunakan *epoch dan batch size*.

3. METODE PENELITIAN

Penelitian ini, masuk dalam kategori penelitian *kuantitatif*, menggunakan *algoritma Long Short-Term Memory (LSTM)*. *LSTM* merupakan jenis arsitektur jaringan saraf tiruan, yang dirancang khusus untuk menangani pengolahan data urutan waktu.



Gambar 1. metode penelitian

Tabel 1. Metode penelitian

Tahap	Aktifitas	Deskripsi Aktivitas
1.pengambilan data dari BMKG	Download data, dari website BMKG	Mendownload data dari tanggal 1 januari 2019 sampai 31 desember 2022.
2.Analisis Variabel	Melakukan analisis variabel	Analisis variabel, yang akan digunakan, mendukung penelitian dengan google colaboratory.
3.Preprocessing Data	Melakukan Preprocessing, yang telah di analisis.	Melakukan preprocessing agar data sesuai model, yang digunakan dan menentukan sampel
4.Pembuatan Model LSTM (Long Short – Term Memory).	Menerapkan model LSTM.	Menerapkan model LSTM.
5.Analisis dan Prediksi	Melakukan analisis dan prediksi hasil yang didapat	Melakukan analisis, yang didapat dan memprediksi nilai cuaca kedepan.

3.1. Sumber Data

Data cuaca diambil dari website BMKG, stasiun klimatologi jawa barat dengan lintang – 6.50000, bujur 106.75000 dan elevasi 207. Berikut alamat website (<https://dataonline.bmkg.go.id/home>). Pengambilan sampel dilakukan, dengan mengidentifikasi data cuaca yang memenuhi kriteria serta ditelaah ditetapkan dengan google colaboratori.

3.2. Populasi dan Sampel

Populasi data mencakup semua rekaman data cuaca harian, dari tanggal 01/01/2019 sampai 31/12/2022 yang mencapai 1640 data. Sampel data yaitu *Tn (Temperatur minimum)*, *Tx (Temperatur maksimum)*, *Tavg (Temperatur rata - rata)*, *RH_avg (kelembaban rata - rata)*, *RR (Curah Hujan)*, *ss (lamanya penyinaran matahari)*, *ff_x (kecepatan angin maksimum)*, *ddd_x (arah angin saat kecepatan maksimum)*, *ff_avg (kecepatan angin rata - rata)*, *ddd_car (arah angin terbanyak)*.


3.3. Teknik Pengambilan Data

Pengumpulan data secara online, yang diambil dari website resmi dari BMKG (Badan Meteorologi, Klimatologi, dan Geofisika) yang dapat di gunakan

secara legal, dengan mendownload data tersebut secara berkala, per satu bulan dari tanggal 1 januari 2019 sampai tanggal 31 desember 2022. Kemudian data di kumpulkan menjadi 1 file, yang berbentuk excel.

3.4. Teknik Analisis Data

Berikut merupakan gambaran dan penjelasan, dari Teknik analisis data yang akan dilakukan penelitian ini :



Gambar 2. teknik analisis data

Berikut Teknik analisis data penelitian ini :

- Analisis* data awal : untuk memahami kaarektersitik data cuaca.
- Pemrosesan data : memastikan data dalam kondisi baik.
- Analisis unariat* : memahami distribusi antar variabel, termasuk pola dan tren dalam data.
- Analisis bivariat* : memahami korelasi antar variabel.
- Analisis LSTM* : melatih model dengan algortima LSTM.
- Evaluasi model : mengevaluasi mencakup menggunakan metrik seperti *MSE*.
- Intepretasi hasil : memprediksi cuaca kedepan dengan menggunakan model *LSTM*.
- Generalisasi hasil : meninjau Kembali hasil sampel data cuaca ke populasi secara keseluruhan.
- Dokumentasi dan penulisan hasil : membuat kesimpulan dan mendokumentasikan hasil yang telah didapat.

4. HASIL DAN PEMBAHASAN

Dibawah ini uraian hasil dari implementasi yang dilakukan sesuai dengan tahap metode penelitian.

4.1. Pengambilan data BMKG

Data diambil melalui website resmi *BMKG* yang dapat digunakan secara *legal*, berikut alamat websitenya (<https://dataonline.bmkg.go.id/home>). Dengan cara mendownload per satu bulan.

4.2. Analisis variabel

Berikut tahapan Untuk menganalisis variabel yang tidak dibutuhkan pada tahap selanjutnya.

a. Install Library

library yang harus di *install* untuk digunakan, berikut library yang harus di *install*.

```
# Install library yang diperlukan
!pip install tensorflow numpy pandas matplotlib
```

Gambar 3. kode instal librari 1

PIP untuk *install tensorflow*, mengembangkan *machine learning*, *numpy*, *pandas*, dan *matplotlib* untuk manipulasi, analisis, dan visulasasi data.

b. Import Library

```
import pandas as pd
import numpy as np
from numpy import array
from numpy import reshape
from matplotlib.pyplot import plt
import random as r
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import Normalizer, StandardScaler
from keras.preprocessing.sequence import TimesSeriesGenerator
import tensorflow as tf
from tensorflow.keras import Sequential
from keras.layers import Dense
from keras.layers import LSTM
from keras.layers import Dropout
from keras.layers import Bidirectional
from keras.layers import TimeDistributed
from keras.layers import Conv1D
from sklearn.metrics import train_test_split
from sklearn.metrics import R2Score
from tensorflow.keras.callbacks import EarlyStopping
```

Gambar 4.kode install library 2

Import library yang dibutuhkan pengolahan data sesuai fungsinya, Seperti *pandas*, *numpy*, *matplotlib*, *seaborn*, dan lain sebagainya.

c. Mengakses Data

```
[ ] # import google drive
from google.colab import drive
drive.mount('/content/drive')

Mounted at /content/drive

[ ] # import file
data = pd.read_excel('/content/drive/MyDrive/6. TUGAS SEMESTER 8/cuaca/cuaca.xlsx')

# merubah data excel menjadi data frame
df = pd.DataFrame(data)
print(df)
```

	Tanggal	Tn	Tx	Tavg	RH_avg	RR	ss	ff_x	ddd_x	ff_avg	\
0	01-01-2019	22.5	30.4	25.0	89.0	9.3	1.9	10.0	286.0	2.0	
1	02-01-2019	23.4	32.1	26.0	84.0	1.6	1.8	5.0	260.0	1.0	
2	03-01-2019	22.9	32.2	26.8	76.0	2.0	6.8	3.0	240.0	1.0	
3	04-01-2019	21.3	32.8	26.6	77.0	NaN	5.6	4.0	320.0	1.0	
4	05-01-2019	22.0	33.2	26.7	76.0	NaN	11.2	7.0	360.0	1.0	
...	...	...	...	...	...	...	...	...	...	...	...
1455	27-12-2022	20.8	27.9	24.7	85.0	22.9	0.0	5.0	290.0	1.0	

Gambar 5. Mengakses data

Untuk menghubungkan colabatory dengan *google drive* agar dapat memanggil data yang akan digunakan.

d. Analisis Varibel

Beberapa variabel yang tidak dibutuhkan dalam penelitian ini adalah *Tn*, *Tx*, *ddd_x*, *ff_avg*, *ddd_car*. Berikut kode yang digunakan untuk menghapus variabel yang tidak dibutuhkan.

```
# Menghapus kolom-kolom dari DataFrame
drop_cols = ['Tn', 'Tx', 'ddd_x', 'ff_avg', 'ddd_car']
df = df.drop(drop_cols, axis=1)

# Menampilkan DataFrame setelah menghapus kolom
print(df)
```

	Tanggal	Tavg	RH_avg	RR	ss	ff_x
0	01-01-2019	25.0	89.0	9.3	1.9	10.0
1	02-01-2019	26.0	84.0	1.6	1.8	5.0
2	03-01-2019	26.8	76.0	2.0	6.8	3.0
3	04-01-2019	26.6	77.0	NaN	5.6	4.0
4	05-01-2019	26.7	76.0	NaN	11.2	7.0
...	...	...	...	...	...	...
1155	27-12-2022	24.7	85.0	22.9	0.0	5.0
1156	28-12-2022	25.1	85.0	1.0	0.0	0.0
1157	29-12-2022	24.8	80.0	10.7	0.1	1.0
1158	30-12-2022	24.9	80.0	10.7	0.0	1.0
1159	31-12-2022	24.2	81.0	1.5	0.0	12.0

Gambar 6. Kode menghapus variabel dan membaca data

variabel yang memiliki nilai *NaN*, *null*, *9999*, *8888*. Dalam penelitian ini, data *missing value* tersebut akan di atasi dengan *Teknik interpolate*.

```

[7] # Mengganti nilai-nilai NaN, null, 9999, atau 8888 dengan 0 di seluruh DataFrame
df = df.fillna(0) # dari hal dengan 0
df = df.replace(9999, 9999, 0) # dari 9999, 8888, dan null dengan 0

[8] # Interpolasi linear untuk mengisi nilai yang hilang
df.interpolate(method='linear', inplace=True)

[9] # Menampilkan DataFrame setelah mengganti nilai
print(df)

   Tanggal  Tavg  RH_avg  RR  ss  ff_x
0  01-01-2019  25    89    9  1  10
1  02-01-2019  26    84    1  1  5
2  03-01-2019  26    76    2  6  3
3  04-01-2019  26    77    4  5  4
4  05-01-2019  26    76    6  11  7
...
1455 27-12-2022  24    85   22  0  5
1456 28-12-2022  23    92    3  0  4
1457 29-12-2022  24    92   26  0  3
1458 30-12-2022  24    92   18  0  3
1459 31-12-2022  24    92    1  0  12
[1460 rows x 7 columns]

```

Gambar 7. kode teknik interpolate

4.3. Preprocessing data

Hal pertama adalah memanggil data yang telah dibersihkan. Berikut kode yang digunakan, untuk memanggil data dan membacanya.

```

[18] # Import file yang telah dibersihkan
data = pd.read_csv('data/cuaca/cuaca_bersih.csv')

[19] # Membaca data
print(data)

   Tanggal  Tavg  RH_avg  RR  ss  ff_x
0  01-01-2019  25    89    9  1  10
1  02-01-2019  26    84    1  1  5
2  03-01-2019  26    76    2  6  3
3  04-01-2019  26    77    4  5  4
4  05-01-2019  26    76    6  11  7
...
1455 27-12-2022  24    85   22  0  5
1456 28-12-2022  23    92    3  0  4
1457 29-12-2022  24    92   26  0  3
1458 30-12-2022  24    92   18  0  3
1459 31-12-2022  24    92    1  0  12
[1460 rows x 7 columns]

```

Gambar 8. Kode import data bersih 1

Data *bertipe float* perlu dirubah menjadi *integer* agar mempermudah menentukan kondisi cuaca. Berikut kode yang digunakan.

```

[20] # Daftar variabel yang ingin di ubah menjadi integer
str_kondisi_kat = ['Tavg', 'RH_avg', 'RR', 'ss', 'ff_x']

# Mengkonversi metode astype() untuk mengubah tipe data menjadi integer
data[str_kondisi_kat] = data[str_kondisi_kat].astype(int)

# Menampilkan beberapa baris pertama data setelah perubahan
data.head()

   Tanggal  Tavg  RH_avg  RR  ss  ff_x
0  01-01-2019  25    89    9  1  10
1  02-01-2019  26    84    1  1  5
2  03-01-2019  26    76    2  6  3
3  04-01-2019  26    77    4  5  4
4  05-01-2019  26    76    6  11  7

```

Gambar 9. kode merubah data *float* menjadi *integer*

Kemudian memberikan label kondisi sesuai cuaca yang dapat terjadi di Indonesia, dengan membandingkan nilai variabel *RR* (Curah Hujan) dan *ss* (Intensitas Matahari), menggunakan teknik *if else*. Berikut kode yang digunakan.

```

[21] # Fungsi untuk menentukan kondisi cuaca
def tentukan_kondisi_cuaca(row):
    rr = row['RR']
    ss = row['ss']
    if rr >= 50 and ss <= 10:
        return "Hujan"
    elif rr <= 50 and ss <= 10:
        return "Mendung"
    elif rr <= 50 and ss >= 10:
        return "Terang"
    else:
        return "Tidak Diketahui"

# Default jika tidak memenuhi kondisi di atas
return "Tidak Diketahui"

# Menentukan kolom 'Kondisi_Cuaca' ke dalam DataFrame
data['Kondisi_Cuaca'] = data.apply(tentukan_kondisi_cuaca, axis=1)

# Menampilkan DataFrame dengan kolom 'Kondisi_Cuaca'
print("Data cuaca dengan kondisi:")
print(data[['Tanggal', 'Tavg', 'RH_avg', 'RR', 'ss', 'ff_x', 'Kondisi_Cuaca']])

```

Gambar 10. Kode menentukan kondisi cuaca

Kondisi cuaca yaitu hujan, mendung, dan terang. Terjadinya hujan apabila nilai *RR* (Curah Hujan) lebih besar dari nilai *ss* (Intensitas Matahari), mendung apabila nilai *RR* (Curah Hujan) sama dengan nilai *ss* (Intensitas Matahari), dan terang apabila nilai *RR* (Curah Hujan) lebih kecil dari nilai *ss* (Intensitas Matahari). Berikut hasil dari kode diatas.

Data cuaca dengan kondisi:

	Tanggal	Tavg	RH_avg	RR	ss	ff_x	Kondisi_Cuaca
0	01-01-2019	25	89	9	1	10	HUJAN
1	02-01-2019	26	84	1	1	5	MENDUNG
2	03-01-2019	26	76	2	6	3	TERANG
3	04-01-2019	26	77	4	5	4	TERANG
4	05-01-2019	26	76	6	11	7	TERANG
...	...	...	...	...	...	...	...
1455	27-12-2022	24	85	22	0	5	HUJAN
1456	28-12-2022	23	92	3	0	4	HUJAN
1457	29-12-2022	24	92	26	0	3	HUJAN
1458	30-12-2022	24	92	18	0	3	HUJAN
1459	31-12-2022	24	92	1	0	12	HUJAN

[1460 rows x 7 columns]

Gambar 11. hasil kondisi cuaca

Menentukan terjadinya cuaca ekstrem, dengan menghitung nilai rata – rata setiap kolom. Berikut kode untuk membuat rata – rata setiap kolom dan hasilnya.

```

[22] # Membuat kolom baru 'Rata_rata' yang berisi rata-rata dari kolom yang diinginkan
data['Rata_rata'] = data[['Tavg', 'RH_avg', 'RR', 'ss', 'ff_x']].mean(axis=1)

# Menampilkan DataFrame yang telah diperbarui
print(data)

   Tanggal  Tavg  RH_avg  RR  ss  ff_x  Kondisi_Cuaca  Rata_rata
0  01-01-2019  25    89    9  1  10  HUJAN  26.8
1  02-01-2019  26    84    1  1  5  HUJAN  23.4
2  03-01-2019  26    76    2  6  3  TERANG  23.2
3  04-01-2019  26    77    4  5  4  TERANG  23.2
4  05-01-2019  26    76    6  11  7  TERANG  25.2
...
1455 27-12-2022  24    85   22  0  5  HUJAN  24.4
1456 28-12-2022  23    92    3  0  4  HUJAN  24.4
1457 29-12-2022  24    92   26  0  3  HUJAN  29.0
1458 30-12-2022  24    92   18  0  3  HUJAN  27.4
1459 31-12-2022  24    92    1  0  12  HUJAN  25.8
[1460 rows x 8 columns]

```

Gambar 12. kode menentukan nilai rata – rata

Setelah memberikan nilai rata – rata dapat dilihat nilai tertinggi, nilai terendah, dan nilai rata – rata, dari kolom rata-rata, yang digunakan sebagai batas terjadinya cuaca ekstrem. Berikut kode yang digunakan dan hasilnya.

```

[23] # Cari rata-rata tertinggi
rata_rata_tertinggi = data['Rata_rata'].max()

# Tampilkan hasil
print("nilai (Rata-rata) Tertinggi:", rata_rata_tertinggi)

# Cari rata-rata terendah
rata_rata_terendah = data['Rata_rata'].min()

# Tampilkan hasil
print("nilai (Rata-rata) Terendah:", rata_rata_terendah)

# Cari rata-rata dari nilai rata-rata
rata_rata_dari_rata_rata = data['Rata_rata'].mean()

# Tampilkan hasil
print("nilai (Rata-rata) dari nilai rata-rata:", rata_rata_dari_rata_rata)

nilai (Rata-rata) Tertinggi: 56.2
nilai (Rata-rata) Terendah: 20.6
nilai (Rata-rata) dari nilai rata-rata: 26.846986301369867

```

Gambar 13. kode menentukan nilai

Didapat nilai tertinggi adalah 56.2, nilai terendah 20.6, dan rata – rata 26.84. maka nilai cuaca normal di jawa barat sesuai dengan data adalah 26.84 sebagai kondisi nilai cuaca rata – rata harian.

4.4. Pembuatan model Long Short Term Memori

Selanjutnya membuat model *Long Short Term Memory*. Import Kembali data yang telah di proses. Berikut kode yang digunakan untuk memanggil data dan menampilkannya.

```
[24] # import file yang telah dibersihkan
data = pd.read_excel('/content/drive/MyDrive/6. TUGAS SEMESTER 8/cuaca/cuaca_clear_1.xlsx')

# membaca data
print(data)
```

	Tanggal	Tavg	RH_avg	RR	ss	ff_x_Kondisi_Cuaca	Rata_rata	
0	01-01-2019	25	89	9	1	10	Hujan	26.8
1	02-01-2019	26	84	1	1	5	Mendung	23.4
2	03-01-2019	26	76	2	6	3	Terang	22.6
3	04-01-2019	26	77	4	5	4	Terang	23.2
4	05-01-2019	26	76	6	11	7	Terang	25.2
...	...	...	...	...	...	...	...	...
1455	27-12-2022	24	85	22	0	5	Hujan	27.2
1456	28-12-2022	23	92	3	0	4	Hujan	24.4
1457	29-12-2022	24	92	26	0	3	Hujan	29.0
1458	30-12-2022	24	92	18	0	3	Hujan	27.4
1459	31-12-2022	24	92	1	0	12	Hujan	25.8

[1460 rows x 8 columns]

Gambar 14. kode membaca data bersih 2

Kemudian menentukan terjadinya cuaca ekstrem atau cuaca normal, dari nilai rata – rata yang di dapat yaitu 26.84. semakin tinggi nilai rata – rata setiap kolom, kondisi yang terjadi semakin ekstrem dan semakin jarang terjadi. Berikut kode yang digunakan untuk menentukan kondisi cuaca.

```
# Start label berdasarkan 'Rata_rata' lebih dari 27
data['Label'] = data['Rata_rata'].apply(lambda x: 'Normal' if x < 27 else 'Ekstrem')

# Print dataset
print(data)

# Split data menjadi 'Train' (80%) dan 'Test' (20%)
X_train, X_test, y_train, y_test = train_test_split(data[['Tanggal', 'Tavg', 'RH_avg', 'RR', 'ss', 'ff_x_Kondisi_Cuaca', 'Rata_rata']], data['Label'], test_size=0.2, random_state=42)

# Train model menggunakan RandomForestClassifier
model = RandomForestClassifier()
model.fit(X_train, y_train)

# Predict data
y_pred = model.predict(X_test)

# Print hasil prediksi
print('Prediksi label = rata - rata :', y_pred)
```

Gambar 15. Kode Label dan akurasi data

	Tanggal	Tavg	RH_avg	RR	ss	ff_x_Kondisi_Cuaca	Rata_rata	Label	
0	01-01-2019	25	89	9	1	10	Hujan	26.8	Normal
1	02-01-2019	26	84	1	1	5	Mendung	23.4	Normal
2	03-01-2019	26	76	2	6	3	Terang	22.6	Normal
3	04-01-2019	26	77	4	5	4	Terang	23.2	Normal
4	05-01-2019	26	76	6	11	7	Terang	25.2	Normal
...	...	...	...	...	...	...	...	...	...
1455	27-12-2022	24	85	22	0	5	Hujan	27.2	Normal
1456	28-12-2022	23	92	3	0	4	Hujan	24.4	Normal
1457	29-12-2022	24	92	26	0	3	Hujan	29.0	Ekstrem
1458	30-12-2022	24	92	18	0	3	Hujan	27.4	Normal
1459	31-12-2022	24	92	1	0	12	Hujan	25.8	Normal

[1460 rows x 9 columns]
 Akurasi model: 1.0
 Prediksi label = rata - rata : ['Normal' 'Ekstrem' 'Ekstrem']

Gambar 16. Hasil dari kode label

Didapat akurasi dengan model *RandomforestClassifier*, sebagai model untuk melihat akurasi dalam memberikan label dengan state 42, didapat akurasi 1.0 yang memiliki arti 100% akurat dalam menentukan kondisi normal atau ekstrem. Selanjutnya menerapkan model *algoritma Long Short Term Memory* dan melatih model epoch sebanyak 50 kali dengan berbagai nilai *threshlod*, dan nilai 26.84 yang dapat dibulatkan 27 sebagai acuan nilai rata – rata kondisi normal cuaca harian di jawa barat, serta memprediksi nilai cuaca yang terjadi selama 7 hari kedepan. Berikut kode

Tabel 2. Kode Long Short Term Memory

```
# memanggil data yang telah di bersihkan
file_path = '/content/drive/MyDrive/6. TUGAS SEMESTER 8/cuaca/cuaca_clear_1.xlsx'

# Membaca dataset cuaca yang telah dibersihkan
df = pd.read_excel(file_path)

# Menentukan batas nilai 'Rata_rata' untuk diwarnai
threshold_value = (memberikan nilai ke ekstriman yang terjadi dengan dari 27 - 56)

# Menambahkan kolom baru 'Extreme' sebagai penanda cuaca ekstrem
```

```
df['Extreme'] = np.where(df['Rata_rata'] >= threshold_value, 1, 0)

# Menghitung nilai rata-rata dan menormalisasi data
average_value = df['Rata_rata'].mean()
scaler = MinMaxScaler(feature_range=(0, 1))
scaled_data = scaler.fit_transform(df['Rata_rata'].values.reshape(-1, 1))

# Membagi data menjadi set pelatihan dan pengujian
train_size = int(len(scaled_data) * 0.80)
test_size = len(scaled_data) - train_size
train, test = scaled_data[0:train_size, :], scaled_data[train_size:len(scaled_data), :]

# Membuat dataset untuk LSTM
def create_dataset(dataset, time_step=1):
    dataX, dataY = [], []
    for i in range(len(dataset) - time_step):
        a = dataset[i:(i + time_step), 0]
        dataX.append(a)
        dataY.append(dataset[i + time_step, 0])
    return np.array(dataX), np.array(dataY)

# Mengubah nilai time_step agar sesuai dengan kebutuhan prediksi di masa depan
time_step = 7 # menyesuaikan sesuai yang ingin di prediksi perhari/perminggu/perbulan
X_train, y_train = create_dataset(train, time_step)
X_test, y_test = create_dataset(test, time_step)

# Reshape data agar sesuai dengan input LSTM
X_train = X_train.reshape(X_train.shape[0], X_train.shape[1], 1)
X_test = X_test.reshape(X_test.shape[0], X_test.shape[1], 1)

# Membuat model LSTM
model = Sequential()
model.add(LSTM(units=50, return_sequences=True, input_shape=(X_train.shape[1], 1)))
model.add(LSTM(units=50, return_sequences=True))
model.add(LSTM(units=50))
model.add(Dense(units=1))
model.compile(optimizer='adam', loss='mean_squared_error')

# Melatih model
model.fit(X_train, y_train, epochs=50, batch_size=64, verbose=1)
```

4.5. Analisis dan prediksi

Berdasarkan nilai dari proses yaitu 26.84 dibulatkan menjadi 27 sebagai tolak ukur nilai cuaca normal harian pada wilayah jawa barat. berikut grafik kondisi cuaca.

Nilai *threshlod value* 28

Didapat grafik di bawah ini, dengan pola titik merah muncul cukup banyak. Terjadi sebanyak 392 kondisi di atas nilai *threshlod value* 28.

Threshold Values:

	Tanggal	Rata_rata	Tavg	RR_avg	RR	ss	ff_x	Kondisi_Cuaca
115	26-04-2019	51.4	25	88	134	6	4	Hujan
348	15-12-2019	53.4	25	87	141	8	6	Hujan
442	18-03-2020	50.0	26	91	121	8	4	Hujan
1292	16-07-2022	56.2	23	92	155	5	6	Hujan

	Label
115	Ekstrem
348	Ekstrem
442	Ekstrem
1292	Ekstrem

Gambar 22. cuaca extrem

Pada tanggal 26 – 04 – 2019 didapat nilai 51.4 kondisi yang terjadi adalah extrem karena diatas nilai rata – rata cuaca normal yaitu 26.84. Dengan melihat variabel *Tavg* (*temperatur rata - rata*) yang memiliki nilai 25 termasuk nilai normal pada sebuah temperature harian, namun dengan nilai *RR* (*curah hujan*) mencapai 134, curah hujan yang terjadi sangat deras dan dapat mengakibatkan banjir di wilayah yang terjadi hujan.

4.7. Keterkaitan dengan Literatur terdahulu

Penelitian ini menggunakan metode dengan akurasi terbaik menurut penelitian sebelumnya yaitu *algoritma Long Short Term Memori* dengan metode *MSE* sebagai fungsi untuk meminimalkan perbedaan nilai sebenarnya dan nilai prediksi, serta mengembangkan lebih lanjut dalam pengolahan data dengan menggunakan model *RandomForestClassifier*. Dari hasil yang didapat penelitian ini mendukung dan melengkapi penelitian sebelumnya. Hasil yang didapat penelitian sebelumnya hanya menguji metode dan algoritma, pada penelitian ini dihasilkan pola cuaca dengan grafik dan hasil prediksi cuaca selama 7 hari seperti pada Tabel 4. 6 Hasil percobaan berberbagai treshlod.

4.8. Kontribusi terhadap pengetahuan

Dari Teknik yang dilakukan penelitian ini dapat memberi pengetahuan bahwa artificial intelegent mampu untuk memprediksi dan menggambarkan dengan menggunakan grafik pada bidang analisis cuaca. Penelitian ini juga menyumbangkan temuan baru berupa pola – pola yang digambarkan dengan metode *algoritma Long Short Term Memory* menggunakan grafik serta menghasilkan prediksi yang cukup baik

5. KESIMPULAN DAN SARAN

Hasil yang telah didapat dari penelitian ini dan dapat dikembangkan Kembali, sebagai berikut. Kecerdasan buatan dengan *algoritma Long Short Term Memory* dapat digunakan untuk Menerapkan *RandomForestClassifier*, pada data cuaca historis untuk memprediksi cuaca ekstrem telah menghasilkan akurasi 100%. Analisis menggunakan teknik evaluasi model *MSE* dengan 50 epoch dan percobaan 8 kali pada nilai threshold (28, 31, 34, 37, 40, 43, 46, 49) menunjukkan pola yang berbeda, dari rata-rata normal, yaitu 26.84 di wilayah Jawa Barat. Penelitian ini dapat

dikembangkan Kembali menggunakan berbagai sumber lain dan Teknik evaluasi lain seperti *RMSE*, *MAE*, *MAPE*, dan *RMSE*.

DAFTAR PUSTAKA

- [1] D. Manongga, U. Rahardja, I. Sembiring, N. Lutfiani, and A. B. Yadila, "Dampak Kecerdasan Buatan Bagi Pendidikan," *ADI Bisnis Digit. Interdisiplin J.*, vol. 3, no. 2, pp. 41–55, 2022, doi: 10.34306/abdi.v3i2.792.
- [2] R. L. Napitupulu and K. Handoko, "Perancangan Sistem Peramalan Cuaca Berbasis Logika Fuzzy Di Kota Batam," *Comasie*, vol. 6, no. 5, pp. 37–44, 2022.
- [3] A. M. Siregar, "Klasifikasi Untuk Prediksi Cuaca Menggunakan Esemble Learning," *Petir*, vol. 13, no. 2, pp. 138–147, 2020, doi: 10.33322/petir.v13i2.998.
- [4] A. Prakasa and F. D. Utami, "BMKG The Integrated Weather Radar Information System of BMKG," *J. Telecommunication, Electron. Control Eng.*, vol. 1, no. 2, pp. 86–96, 2019.
- [5] J. Journal and O. F. Mathematics, "Peramalan Data Cuaca Ekstrem Indonesia Menggunakan Model ARIMA dan Recurrent Neural Network," vol. 5, no. 1, pp. 230–242, 2023.
- [6] N. M. M. Candra Devi, I. P. A. Bayupati, and N. K. A. Wirdiani, "Prediksi Curah Hujan Dasarian dengan Metode Vanilla RNN dan LSTM untuk Menentukan Awal Musim Hujan dan Kemarau," *J. Edukasi dan Penelit. Inform.*, vol. 8, no. 3, p. 405, 2022, doi: 10.26418/jp.v8i3.56606.
- [7] Setiawan, "Keterampilan Berfikir Kritis Pada Pembelajaran IPA Menggunakan Model Pembelajaran Radece," *Justek J. Sains dan Teknol.*, vol. 5, no. 2, p. 133, 2022.
- [8] A. S. Bayangkari Karno, "Analisis Data Time Series Menggunakan LSTM (Long Short Term Memory) Dan ARIMA (Autocorrelation Integrated Moving Average) Dalam Bahasa Python.," *Ultim. InfoSys J. Ilmu Sist. Inf.*, vol. 11, no. 1, pp. 1–7, 2020, doi: 10.31937/si.v9i1.1223.
- [9] M. Rizki, S. Basuki, and Y. Azhar, "Implementasi Deep Learning Menggunakan Arsitektur Long Short Term Memory(LSTM) Untuk Prediksi Curah Hujan Kota Malang," *J. Repos.*, vol. 2, no. 3, pp. 331–338, 2020, doi: 10.22219/repositor.v2i3.470.
- [10] T. A. Faisal Muhammad and M. I. Irawan, "Implementasi Long Short-Term Memory (LSTM) untuk Prediksi Intensitas Curah Hujan (Studi Kasus: Kabupaten Malang)," *J. Sains dan Seni ITS*, vol. 12, no. 1, 2023, doi: 10.12962/j23373520.v12i1.106892.