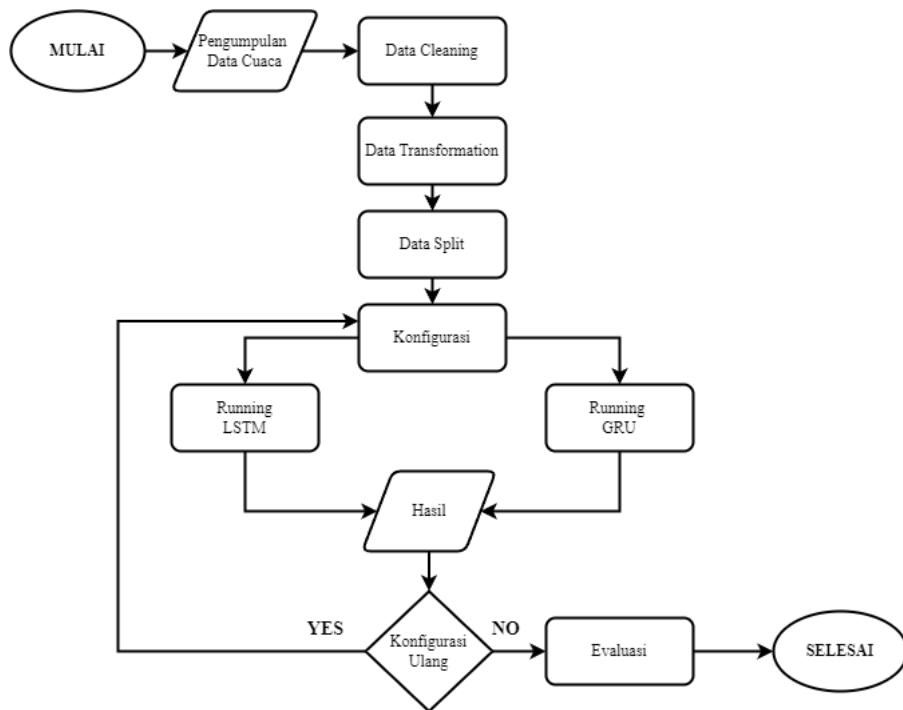


3.1 Alur Penelitian

Tahapan proses yang akan dikerjakan pada penelitian ini ditampilkan pada gambar 3.1, dimana langkah awal ada mengumpulkan data pengamatan cuaca, selanjutnya melakukan *preprocessing* data dengan melakukan *data cleaning*, *data transformation*, *data split* dan *data scaling*. Setelah itu masuk pada tahap konfigurasi dan running model LSTM dan GRU, jika hasil *running* belum sesuai maka dapat dilakukan konfigurasi ulang, pada tahap terakhir hasil running algoritma di evaluasi menggunakan perhitungan MSE, MAD, RMSE dan confusion matrix sehingga kemudian dapat diambil kesimpulan dari hasil analisis tersebut.

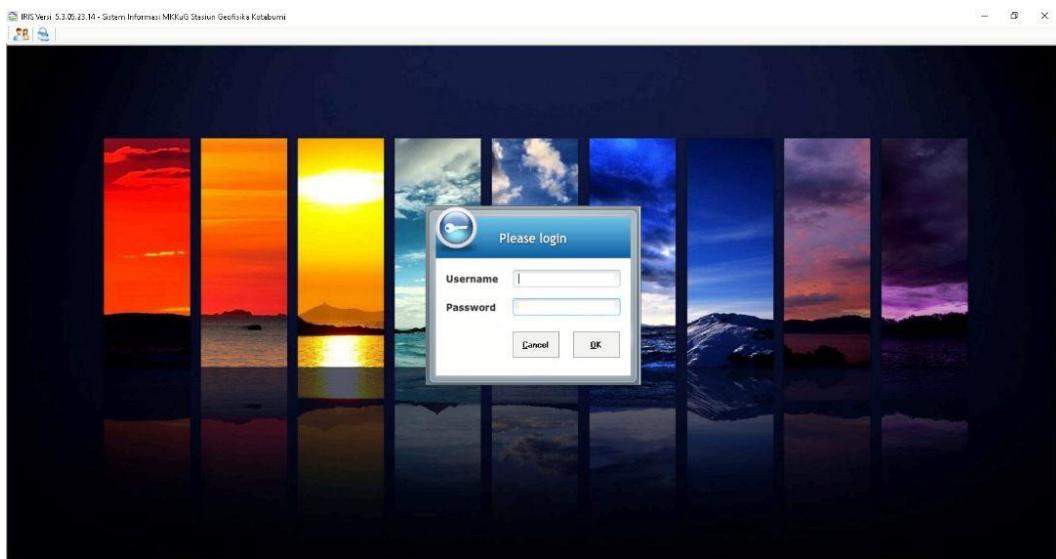


Gambar 3. 1 Diagram alir penelitian

3.2 Pengumpulan Data Cuaca

Pada Penelitian ini data yang digunakan adalah data cuaca harian yang terdiri 10 atribut data yaitu : penyinaran matahari, kelembaban (jam 07.00, 13.00, 18.00),

tekanan, suhu (maksimum, minimum), kecepatan angin, curah hujan dan keadaan cuaca. Data didapatkan dari aplikasi IRIS yang merupakan sistem database di Stasiun Geofisika Lampung Utara.



Gambar 3. 2 Tampilan Antar Muka Aplikasi IRIS

Jumlah data yang digunakan sebanyak 18260 data selama 5 tahun dari tahun 2018-2022.

	Tanggal	07.00	13.00	18.00	Rata-rata	Max	Min	Cuaca	Hujan	Dates	User	07.00	13.00	18.00	Rata-rata	Kecepatan	Arah	Kecepatan	Arah	Id	Date
▶	9/3/2023	21.4	35	33.2	27.8	36	21	0	91.2	-	1010	57	54	60	77	4	188	5	170	18800	10/3/2023 11:45
	9/4/2023	22.5	36	34	28.8	37	20.8	0	100	-	1009.7	91	48	60	70	4	130	7	140	18800	10/3/2023 11:45
	9/5/2023	21.4	36.8	33	28.1	37.6	21.4	0	100	-	1009.1	88	46	56	68	4	140	7	140	18800	10/3/2023 11:45
	9/7/2023	21.4	31.2	33.2	26.8	36.8	21.4	0	90	-	1008.4	93	61	96	95	4	20	6	20	18800	10/3/2023 11:45
	9/8/2023	21.8	35.6	33.2	26.1	37.2	21	0	95.2	-	1009.5	90	50	56	71	3	160	5	220	18800	10/3/2023 11:45
	9/9/2023	22.4	35.9	33.2	26.4	36.6	22.4	0	88.0	-	1007.6	92	49	48	70	5	150	7	130	18800	10/3/2023 11:45
	9/10/2023	23.6	35	33	26.8	36	23	0	65	-	1008.8	90	51	56	72	3	130	5	120	18800	10/3/2023 11:45
	9/12/2023	24.6	35.2	32.4	25.2	36.8	19.8	0	91.2	-	1008.4	77	52	60	66	4	130	6	140	18800	10/3/2023 11:45
	9/12/2023	24.6	34.8	31.6	28.9	36	24.6	0	100	-	1008.1	81	53	62	69	5	180	8	190	18800	10/3/2023 11:45
	9/13/2023	25.1	31.2	32.6	26.9	36.2	25.6	0	92.5	-	1008.1	92	77	61	80	4	180	7	190	18800	10/3/2023 11:45
	9/13/2023	25.6	34.2	33	29.6	36.4	25	0	71.2	-	1008.2	23	61	58	41	3	140	6	120	18800	10/3/2023 11:45
	9/15/2023	25	33.4	20.4	26.4	34.2	23.6	0	95.5	-	1007.6	92	63	73	88	3	140	6	130	18800	10/3/2023 11:45
	9/15/2023	24.8	34.8	21.6	29	36	34.2	0	65	-	1007.8	90	51	68	75	4	150	6	130	18800	10/3/2023 11:45
	9/17/2023	24	33.4	32.4	26.4	34.8	22	1	70	Ra	1008.5	92	61	64	77	3	170	5	170	18800	10/3/2023 11:45
	9/18/2023	22.8	34.2	30.2	27.5	34.4	22.8	0	60	-	1008.7	95	61	67	79	3	170	6	170	18800	10/3/2023 11:45
	9/18/2023	22.8	33.8	32	27.9	35	22	3	71.2	Ra	1008.4	95	63	62	78	4	140	6	140	18800	10/3/2023 11:45
	9/14/2023	25.2	33.2	28.2	27.8	34	25.2	0	48.8	-	1008.6	92	58	50	63	2	150	4	180	18800	10/3/2023 11:45
	9/14/2023	22.8	35.2	33.2	26.5	36.8	22.6	0	100	-	1009.5	92	52	60	74	2	190	4	100	18800	10/3/2023 11:45
	9/15/2023	27.4	35.4	32.0	30.6	36.4	22.2	0	91.8	-	1009.7	75	52	63	64	4	180	6	60	18800	10/3/2023 11:45
	9/17/2023	22.4	34.6	33.2	26.1	35.4	22.4	0	95.2	-	1009.9	92	51	55	73	3	160	5	360	18800	10/3/2023 11:45
	9/19/2023	24	32.9	29.9	27.8	33.8	22.2	0	70	Ra	1009.9	97	50	63	74	5	190	7	140	18800	10/3/2023 11:45
	9/9/2023	23.8	33.9	32.2	28.4	36.6	23.8	0	73.8	-	1008.3	93	60	68	78	2	120	4	160	18800	10/3/2023 11:45
	9/8/2023	24	33.9	32	28.4	36.4	23.7	0	68.8	-	1009.6	93	64	70	80	3	130	7	70	18800	10/3/2023 11:45
	9/7/2023	24.8	32.2	30.6	28.1	33	22.2	0	28.8	-	1009.5	92	67	68	80	2	80	5	80	18800	10/3/2023 11:45
	9/6/2023	24	34	32.6	27.9	34.4	20.4	0	83.8	-	1009.8	99	57	61	73	4	110	5	150	18800	10/3/2023 11:45
	9/5/2023	23	33.4	31	27.6	34.4	21.2	0	75	-	1007.8	90	53	60	75	4	270	6	270	18800	10/3/2023 11:45
	9/4/2023	21.6	33	32.2	27.1	34.8	20.6	0	62.5	-	1006.4	99	56	62	76	3	100	5	150	18800	10/3/2023 11:45
	9/3/2023	22	34	31.4	27.4	35	22	0	100.8	-	1007.5	95	52	64	76	3	190	5	190	18800	10/3/2023 11:45
	9/2/2023	23	33.6	32	27.9	35	21	0	90	-	1008.3	97	54	60	77	1	190	6	190	18800	10/3/2023 11:45
	9/1/2023	21	33.8	33.2	27.2	35	21	0	95	-	1008.4	95	59	58	77	2	100	4	130	18800	10/3/2023 11:45
	8/30/2023	23	34.5	32.2	28.2	35.8	22.6	0	82.5	-	1009.2	98	55	68	84	2	190	5	160	18800	5/7/2023 9:58
	8/30/2023	22.6	33.6	33	27.9	34.8	22.4	0	78.8	-	1007.6	95	59	67	76	2	220	6	60	18800	5/7/2023 9:58

Gambar 3. 3 Hasil pengamatan data cuaca yang sudah di input pada Aplikasi IRIS

Data di ekstrak dengan format .xls dengan memilih atribut cuaca yang telah dipilih ditampilkan pada gambar 3.4, selanjutnya data disusun secara berurutan dari tanggal 1 Januari 2018 sampai 31 Desember 2022.

date	sun	lb7	lb13	lb18	tekanan	Tmax	Tmin	kec	ch	ket
2018-01-01	0	98	70	79	1004.2	33.6	24	7	0	0
2018-01-02	68.7	97	62	76	1004	32.8	23.8	2	0	0
2018-01-03	85	96	64	89	1004.4	34.2	24.2	5	0.6	1
2018-01-04	25	97	68	89	1005.5	34.2	25	4	9.5	1
2018-01-05	31.2	98	63	97	1005.5	32	24.2	4	3	1
2018-01-06	50	98	72	96	1005.9	32.6	23.4	6	68	1
2018-01-07	0	98	72	82	1006.7	32.6	22.2	2	47	1
2018-01-08	80	98	68	70	1007.3	34	23	4	15	1
2018-01-09	25	97	73	87	1007.4	34	25	6	0	0
2018-01-10	0	98	69	77	1008.1	32	23	8	2.5	1
2018-01-11	0	90	69	76	1007.6	32	22.6	4	6.4	1
2018-01-12	40	98	56	70	1006.2	32.4	23	6	0	0
2018-01-13	8.7	89	64	70	1006.4	32.4	22.6	6	0	0
2018-01-14	62.5	87	58	79	1007.2	31.4	24.2	6	0	0
2018-01-15	67.5	94	60	89	1005.9	32.8	23.6	7	0	0
2018-01-16	20	98	61	72	1005.7	31.4	23.8	4	19	1
2018-01-17	30	98	58	79	1004.4	32	23.4	4	0	0
2018-01-18	63.7	96	70	78	1005	31	19.2	7	3.5	1
2018-01-19	0	98	77	85	1005.8	31	24.4	8	15	1
2018-01-20	7.5	96	60	69	1004.7	32.2	24	3	0	0
2018-01-21	66.2	96	57	61	1003.4	34	19.4	5	0	0

Gambar 3. 4 Hasil ekstrak data pengamatan cuaca

3.3 Data cleaning

Pada penelitian ini jika pada dataset terdapat pengukuran hujan dengan keterangan tidak terukur (TTU) maka nilai curah hujan akan dianggap bernilai 0, dan keterangan “-“ yang berarti curah hujan 0 (tidak ada hujan).

	A	B	C	D	E
1	DATE	CH	CH1		
2	01/11/2021	3.6	3.6		
3	02/11/2021	5.5	5.5		
4	03/11/2021	-	0		
5	04/11/2021	TTU	0		
6	05/11/2021	1.0	1.0		
7	06/11/2021	3.0	3.0		
8	07/11/2021	28.0	28.0		
9	08/11/2021	13.2	13.2		
10	09/11/2021	-	0		
11	10/11/2021	-	0		
12	11/11/2021	-	0		
13	12/11/2021	-	0		
14	13/11/2021	1.8	1.8		
15	14/11/2021	23.7	23.7		
16	15/11/2021	-	0		
17	16/11/2021	-	0		
18	17/11/2021	-	0		
19	18/11/2021	-	0		
20	19/11/2021	-	0		
21	20/11/2021	-	0		

Gambar 3. 5 Menghilangkan komponen yang bukan angka pada data

3.4 Data Transformation

Pada tahap ini data pada kolom “DATE” memiliki format mm/dd/yyyy kemudian di konversi menjadi format yyyy-mm-dd, format data yang sebelumnya menggunakan .xls diubah menjadi format .csv dengan menyisipkan tanda „,” (koma) sebagai pemisah antara nilai curah hujan dan tanggal, tujuan *data transformation* ini agar data dapat dibaca oleh model yang akan digunakan.

```

1 | date,sun,lb7,lb13,lb18,tekanan,Tmax,Tmin,kec,ch,ket
2 | 2018-01-01,0,98,70,79,1004.2,33.6,24.7,0,0
3 | 2018-01-02,68.7,97,62,76,1004,32.8,23.8,2,0,0
4 | 2018-01-03,85,96,64,89,1004.4,34.2,24.2,5,0.6,1
5 | 2018-01-04,25,97,68,89,1005.5,34.2,25,4,9.5,1
6 | 2018-01-05,31.2,98,63,97,1005.5,32,24.2,4,3,1
7 | 2018-01-06,50,98,72,96,1005.9,32.6,23.4,6,68,1
8 | 2018-01-07,0,98,72,82,1006.7,32.6,22.2,2,47,1
9 | 2018-01-08,80,98,68,70,1007.3,34,23,4,15,1
10 | 2018-01-09,25,97,73,87,1007.4,34,25,6,0,0
11 | 2018-01-10,0,98,69,77,1008.1,32,23,8,2.5,1
12 | 2018-01-11,0,90,69,76,1007.6,32,22.6,4,6.4,1
13 | 2018-01-12,40,98,56,70,1006.2,32.4,23,6,0,0
14 | 2018-01-13,8.7,89,64,70,1006.4,32.4,22.6,6,0,0
15 | 2018-01-14,62.5,87,58,79,1007.2,31.4,24.2,6,0,0
16 | 2018-01-15,67.5,94,60,89,1005.9,32.8,23.6,7,0,0
17 | 2018-01-16,20,98,61,72,1005.7,31.4,23.8,4,19,1
18 | 2018-01-17,30,98,58,79,1004.4,32,23.4,4,0,0
19 | 2018-01-18,63.7,96,70,78,1005,31,19.2,7,3.5,1
20 | 2018-01-19,0,98,77,85,1005.0,31,24,4,0,1

```

Gambar 3. 6 Konversi data .xls ke .csv

3.5 Data Split

Pada pembelajaran sebuah *machine learning* ataupun *deep learning* semakin besar data *training* maka akan semakin baik pengklasifikasian, dan semakin besar data *test* maka akan semakin akurat perkiraan kesalahan. Sebuah dataset yang dibagi menjadi data *training* dan *test* disebut metode *holdout*, pembagian 50:50 data training dan test umumnya tidak ideal untuk digunakan, akan lebih baik jika data training digunakan lebih dari setengahnya. *Threefold cross validation* adalah pembagian dataset 2/3 untuk data training dan 1/3 untuk test yang kemudian dilakukan pengulangan sebanyak 3 (tiga) kali [26].

Penelitian yang telah dilakukan oleh Supriyadi pada tahun 2019 disebutkan bahwa data split *training* dan *test* menggunakan perbandingan 9:1, nilai 1 (satu) untuk *test* sudah dapat mewakili sifat dari seluruh data [13], Namun, dalam penelitian ini, data dibagi menjadi tiga bagian dengan perbandingan 7:3, 8:2, dan 9:1.

```

df1=pd.read_csv("/kaggle/input/datasetdevidupdate1/datasetnewupdate1.csv")
df2=df1[['date','sun','lb7','lb13','lb18','tekanan','Tmax','Tmin','kec','ch',]]
#df2.index=pd.to_datetime(df2['date'])
df2_date=df1[['date']]
df2_train=df2.iloc[0:1278,1:]
df2_train.head()

```

Gambar 3. 7 Contoh Konfigurasi data train 7 : test 3

3.6 Konfigurasi LSTM dan GRU

Pada penerapan metode LSTM dan GRU dalam *coding*, terdapat beberapa konfigurasi yang dilakukan. Berikut adalah konfigurasi yang terlihat pada proses *coding* yang akan dijalankan:

1. Jumlah Epoch dan Batch Size: Menggunakan konfigurasi epoch sebanyak 50 dan batch size sebesar 32 pada model LSTM dan GRU. Epoch menentukan jumlah kali iterasi yang dilakukan saat melatih model, sedangkan batch size menentukan jumlah sampel yang digunakan dalam setiap iterasi saat melatih model.
2. Jumlah Layer LSTM: Menggunakan empat layer LSTM berturut-turut pada model. Setiap layer LSTM memiliki jumlah unit sebesar 50. Layer LSTM bertanggung jawab untuk melakukan pemrosesan dan pemahaman pola jangka panjang dalam data sequence.
3. Dropout: Menggunakan dropout dengan nilai 0.2 pada setiap layer LSTM. Dropout digunakan untuk mencegah overfitting pada model dengan secara acak mengabaikan beberapa unit saat melakukan *training*, sehingga mendorong model untuk menjadi lebih umum dan robust.

4. Output Layer: Menambahkan output layer dengan menggunakan Dense layer yang memiliki satu unit. Output layer bertugas untuk menghasilkan prediksi curah hujan.
5. Optimizer: Menggunakan optimizer Adam pada model LSTM. Optimizer ini digunakan untuk mengoptimalkan proses pelatihan dengan memperbarui bobot model berdasarkan perhitungan gradien.
6. Loss Function: Menggunakan loss function berupa mean squared error (MSE). Loss function ini digunakan untuk mengukur kesalahan prediksi model terhadap nilai yang sebenarnya.

```

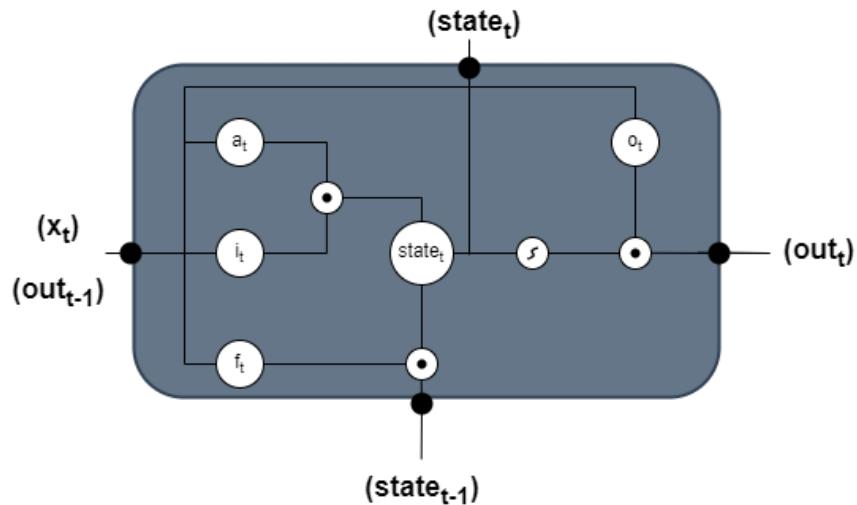
# The LSTM architecture
model=Sequential()
# First LSTM layer with Dropout regularisation
model.add(LSTM(units=50, return_sequences=True, input_shape=(30,9)))
model.add(Dropout(0.2))
# Second LSTM layer
model.add(LSTM(units=50, return_sequences=True))
model.add(Dropout(0.2))
# Third LSTM layer
model.add(LSTM(units=50, return_sequences=True))
model.add(Dropout(0.2))
# Fourth LSTM layer
model.add(LSTM(units=50))
model.add(Dropout(0.2))
# The output layer
model.add(Dense(1))

# Compiling the RNN
model.compile(optimizer='adam', loss='mean_squared_error')
# Fitting to the training set
model.fit(X_train.shape,y_train,epochs=50,batch_size=32)

```

Gambar 3. 8 Konfigurasi Layer, epoch, batch size, loss function

3.7 Perhitungan manual pada satu cell LSTM



Gambar 3. 9 Modul diagram LSTM

$x_{Hujan}(t)$: Input hujan

h_{t-1} : Hidden state vektor

f_t : Forget gate

i_t : Input/Update gate

o_t : Output gate

C_t/a_t : Cell state vektor

$U_{a,i,f,o}, W_{a,i,fo}, b_{a,i,f,o}$: Pembobotan matriks

Input data :

$$x_{Hujan0} = \begin{bmatrix} 1 \\ 2 \end{bmatrix} \text{ dengan label : } 0.5$$

$$x_{Hujan1} = \begin{bmatrix} 0.5 \\ 3 \end{bmatrix} \text{ dengan label : } 1.25$$

Dan pembobotan matriks $U_{a,i,f,o}, W_{a,i,f,o}, b_{a,i,f,o}$:

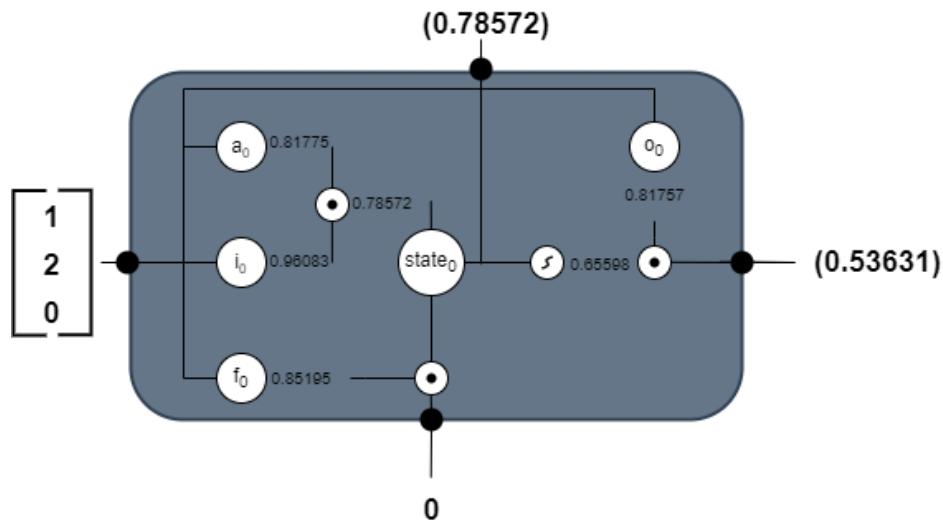
$$W_a = \begin{bmatrix} 0.45 \\ 0.25 \end{bmatrix}, U_a = [0.15], b_a = [0.2]$$

$$W_i = \begin{bmatrix} 0.95 \\ 0.8 \end{bmatrix}, U_i = [0.8], b_i = [0.65]$$

$$W_f = \begin{bmatrix} 0.7 \\ 0.45 \end{bmatrix}, U_f = [0.1], b_f = [0.15]$$

$$W_o = \begin{bmatrix} 0.6 \\ 0.4 \end{bmatrix}, U_o = [0.25], b_o = [0.1]$$

Forward t = 0



Gambar 3. 10 Forward t = 0

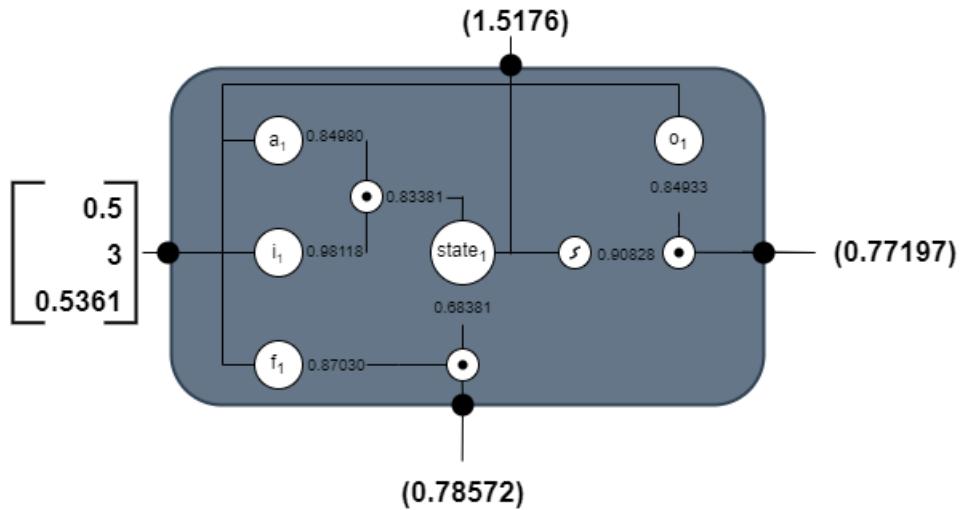
$$a_0 = \tanh (W_a \cdot x_{hujan0} + U_a \cdot out_{prediksi-1} + b_a)$$

$$= \tanh ([0.45 \quad 0.25] \begin{bmatrix} 1 \\ 2 \end{bmatrix} + [0.15][0] + [0.2] = 0.81775$$

$$\begin{aligned}
i_0 &= \sigma (W_i \cdot x_{hujan0} + U_i \cdot out_{prediksi-1} + b_i) \\
&= \sigma ([0.95 \quad 0.8] \begin{bmatrix} 1 \\ 2 \end{bmatrix} + [0.8][0] + [0.65] = 0.96083 \\
f_0 &= \sigma (W_f \cdot x_{hujan0} + U_f \cdot out_{prediksi-1} + b_f) \\
&= \sigma ([0.7 \quad 0.45] \begin{bmatrix} 1 \\ 2 \end{bmatrix} + [0.1][0] + [0.15] = 0.85195 \\
o_0 &= \sigma (W_o \cdot x_{hujan0} + U_o \cdot out_{prediksi-1} + b_o) \\
&= \sigma ([0.45 \quad 0.25] \begin{bmatrix} 1 \\ 2 \end{bmatrix} + [0.15][0] + [0.2] = 0.81775
\end{aligned}$$

$$\begin{aligned}
state_0 &= a_0 \odot i_0 + f_0 \odot state_{-1} \\
&= 0.81775 \times 0.96083 + 0.85195 \times 0 = 0.78572 \\
out_{prediksi0} &= \tanh(state_0) \odot o_0 \\
&= \tanh(0.78572) \times 0.81757 = 0.53631
\end{aligned}$$

Forward t=1



Gambar 3. 11 Forward t = 1

$$\begin{aligned}
a_1 &= \tanh (W_a \cdot x_{hujan1} + U_a \cdot out_{prediksi0} + b_a) \\
&= \tanh ([0.45 \quad 0.25] \begin{bmatrix} 0.5 \\ 3 \end{bmatrix} + [0.15][0.53631] + [0.2] = 0.84980
\end{aligned}$$

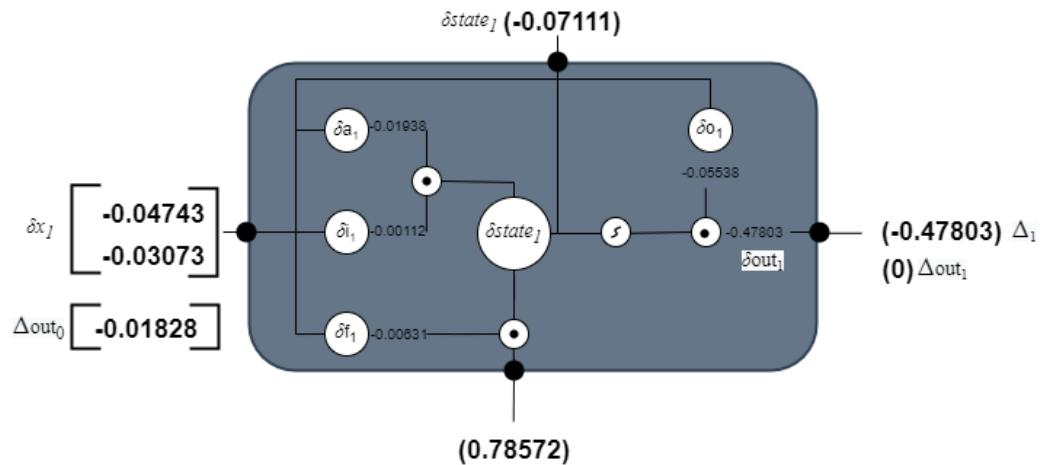
$$\begin{aligned}
i_1 &= \sigma (W_i \cdot x_{hujan1} + U_i \cdot out_{hujan0} + b_i) \\
&= \sigma ([0.95 \quad 0.8] \begin{bmatrix} 0.5 \\ 3 \end{bmatrix} + [0.8][0.53631] + [0.65] = 0.98118
\end{aligned}$$

$$\begin{aligned}
f_1 &= \sigma (W_f \cdot x_{hujan1} + U_f \cdot out_{prediksi0} + b_f) \\
&= \sigma ([0.7 \quad 0.45] \begin{bmatrix} 0.5 \\ 3 \end{bmatrix} + [0.1][0.53631] + [0.15] = 0.87030
\end{aligned}$$

$$\begin{aligned}
o_1 &= \sigma (W_o \cdot x_{hujan1} + U_o \cdot out_{prediksi0} + b_o) \\
&= \sigma ([0.6 \quad 0.4] \begin{bmatrix} 0.5 \\ 3 \end{bmatrix} + [0.25][0.53631] + [0.1] = 0.84993
\end{aligned}$$

$$\begin{aligned}
state_1 &= a_1 \odot i_1 + f_1 \odot state_0 \\
&= 0.84980 \times 0.98118 + 0.87030 \times 0.78572 = 1.5176 \\
out_{prediksi1} &= \tanh(state_1) \odot o_1 \\
&= \tanh(1.5176) \times 0.84933 = 0.77197
\end{aligned}$$

Backward t = 1



Gambar 3. 12 Backward t = 1

Menggunakan Rumus L2 loss untuk meminimalisir kesalahan yang merupakan jumlah dari semua perbedaan kuadrat antara nilai sebenarnya dan nilai prediksi.

$$E(x, \hat{x}) = \frac{(x - \hat{x})^2}{2}$$

Diturunkan w.r.t.x :

$$\partial_x E(x, \hat{x}) = x - \hat{x}$$

Menjadi

$$\Delta_1 = \partial_x E = 0.77197 - 1.25 = -0.47803$$

$\Delta out_1 = 0$ karena tidak ada time step selanjutnya

$$\begin{aligned} \delta out_{prediksi1} &= \Delta_1 + \Delta out_{prediksi1} \\ &= -0.47803 + 0 = -0.47803 \\ \delta state_1 &= \delta out_{prediksi1} \odot o_1 \odot (1 - \tanh^2(state_1)) + \delta state_2 \odot f_2 \\ &= -0.47803 \times 0.84993 \times (1 - \tanh^2(1.5176)) + 0 \times 0 = -0.07111 \\ \delta a_1 &= \delta state_1 \odot i_1 \odot (1 - a_1^2) \\ &= -0.07111 \times 0.98118 \times (1 - 0.84980^2) = -0.01938 \\ \delta i_1 &= \delta state_1 \odot a_1 \odot i_1 \odot (1 - i_1) \\ &= -0.07111 \times 0.4980 \times 0.98118 \times (1 - 0.98118) \\ &= -0.00112 \\ \delta f_1 &= \delta state_1 \odot state_0 \odot f_1 \odot (1 - f_1) \\ &= -0.07111 \times 0.78572 \times 0.87030 \times (1 - 0.87030) \\ &= -0.00631 \\ \delta o_1 \delta out_{prediksi1} &= \tanh \odot (state_1) \odot o_1 \odot (1 - o_1) \\ &= -0.47803 \times \tanh(1.5176) \times 0.84993 \times (1 - 0.84993) \\ &= -0.05538 \end{aligned}$$

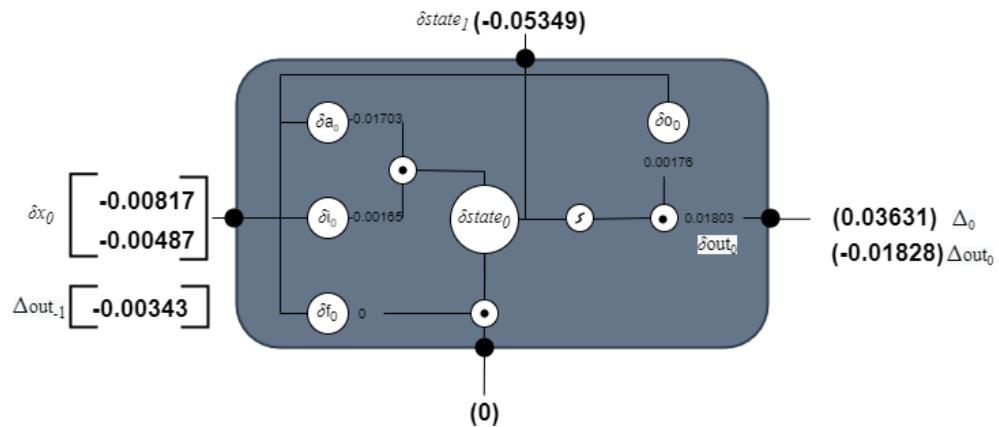
$$\delta x_1 = W^T \cdot \delta gates_1$$

$$= \begin{bmatrix} 0.45 & 0.95 & 0.70 & 0.60 \end{bmatrix} \begin{bmatrix} -0.01938 \\ -0.00112 \\ -0.00631 \\ -0.05538 \end{bmatrix} = \begin{bmatrix} -0.04743 \\ -0.03073 \end{bmatrix}$$

$$\Delta out_{prediksi1} = U^T \cdot \delta gates_1$$

$$= [0.15 \ 0.80 \ 0.10 \ 0.25] \begin{bmatrix} -0.01938 \\ -0.00112 \\ -0.00631 \\ -0.05538 \end{bmatrix} = [-0.01828]$$

Backward t = 0



Gambar 3. 13 Backward $t = 0$

$$\Delta_0 = \partial_x E = 0.53631 - 0.5 = 0.03631$$

$\Delta out_{prediksi0} = -0.01828$, kembali dari $T = 1$

$$\begin{aligned} \delta out_{prediksi0} &= \Delta_0 + \Delta out_{prediksi0} \\ &= 0.03631 + -0.01828 = 0.01803 \end{aligned}$$

$$\begin{aligned} \delta state_0 &= \delta out_{prediksi0} \odot o_0 \odot (1 - \tanh^2(state_0)) + \delta state_1 \odot f_1 \\ &= 0.01803 \times 0.81757 \times (1 - \tanh^2(0.78572)) \pm 0.07111 \times 0.87030 \\ &= -0.05349 \end{aligned}$$

$$\begin{aligned} \delta a_0 &= \delta state_0 \odot i_0 \odot (1 - a_0^2) \\ &= -0.05349 \times 0.96083 \times (1 - 0.81775^2) = -0.01703 \end{aligned}$$

$$\begin{aligned}
\delta i_0 &= \delta state_0 \odot a_0 \odot i_0 \odot (1 - i_0) \\
&= -0.05349 \times 0.81775 \times 0.96083 \times (1 - 0.96083) = -0.00165 \\
\delta f_0 &= \delta state_0 \cdot state_{-1} \odot f_0 \odot (1 - f_0) \\
&= -0.05349 \times 0 \times 0.85195 \times (1 - 0.85195) = 0 \\
\delta o_0 \delta out_{prediksi0} &= \tanh \odot (state_0) \odot o_0 \odot (1 - o_0) \\
&= 0.01803 \times \tanh(0.78572) \times 0.81757 \times (1 - 0.81757) \\
&= 0.00176
\end{aligned}$$

$$\begin{aligned}
\delta x_0 &= W^T \cdot \delta gates_0 \\
&= [0.45 \ 0.95 \ 0.70 \ 0.60] \begin{bmatrix} -0.01703 \\ -0.00165 \\ 0 \\ 0.00176 \end{bmatrix} = [-0.00817 \ -0.00487] \\
\Delta out_{-1} &= U^T \cdot \delta gates_1 \\
&= [0.15 \ 0.80 \ 0.10 \ 0.25] \begin{bmatrix} -0.01703 \\ -0.00165 \\ 0 \\ 0.00176 \end{bmatrix} = [-0.00343]
\end{aligned}$$

selanjutnya *updating* parameter internal menggunakan *simple stochastic gradient descent* (SGD) dengan menggunakan learning rate : $\lambda = 0.1$

$$\begin{aligned}
\delta W &= \sum_{t=0}^T \delta gates_t \otimes x_t \\
&= \begin{bmatrix} -0.01703 \\ -0.00165 \\ 0 \\ 0.00176 \end{bmatrix} [1.0 \ 2.0] + \begin{bmatrix} -0.01938 \\ -0.00112 \\ -0.00631 \\ -0.05538 \end{bmatrix} [0.5 \ 3.0] = \begin{bmatrix} -0.02672 & -0.0922 \\ -0.00221 & -0.00666 \\ -0.00316 & -0.01893 \\ -0.02593 & -0.16262 \end{bmatrix}
\end{aligned}$$

$$\delta U = \sum_{t=0}^{T-1} \delta gates_{t+1} \otimes out_t$$

$$= \begin{bmatrix} -0.01938 \\ -0.00112 \\ -0.00631 \\ -0.05538 \end{bmatrix} [0.53631] = \begin{bmatrix} -0.01039 \\ -0.00060 \\ -0.00338 \\ -0.02970 \end{bmatrix}$$

$$\delta U = \sum_{t=0}^T \delta gates_{t+1}$$

$$= \begin{bmatrix} -0.01703 \\ -0.00165 \\ 0 \\ 0.00176 \end{bmatrix} + \begin{bmatrix} -0.01938 \\ -0.00112 \\ -0.00631 \\ -0.05538 \end{bmatrix} = \begin{bmatrix} -0.03641 \\ -0.00277 \\ -0.00631 \\ -0.05362 \end{bmatrix}$$

Kemudian updating parameter berdasarkan fungsi SGD

$$W^{new} = W^{old} - \lambda * \delta W^{old}$$

$$W_a = \begin{bmatrix} 0.45276 \\ 0.25922 \end{bmatrix}, U_a = [0.15104], b_a = [0.20364]$$

$$W_i = \begin{bmatrix} 0.95022 \\ 0.80067 \end{bmatrix}, U_i = [0.8006], b_a = [0.65028]$$

$$W_f = \begin{bmatrix} 0.70031 \\ 0.45189 \end{bmatrix}, U_f = [0.10034], b_f = [0.15063]$$

$$W_o = \begin{bmatrix} 0.60259 \\ 0.41626 \end{bmatrix}, U_o = [0.25297], b_o = [0.10536]$$

Penyelesaian satu iterasi pada satu cell LSTM [27].

3.7 Perhitungan Evaluasi

Pada penelitian ini nilai prediksi dari data train dan test akan di evaluasi menggunakan MSE, MAD dan akurasi berikut penggunaan rumus yang akan diterapkan pada penelitian ini :

a. *Mean Square Error* (MSE)

$$MSE = \frac{(123 - 122)^2 - (127 - 127.5)^2 + \dots + (12 - 12.2)^2}{7671} = 12.32$$

b. *Mean Absolute Deviation (MAD)*

$$MAD = \frac{|123 - 122| - |127 - 127.5| - \dots - |12 - 12.2|}{7671} = 18.88$$

c. *Confusion Matrix*

Tabel 3. 1 Contoh hasil prediksi cuaca

Tanggal	Real cuaca	Prediksi cuaca
01-01-2022	Tidak Hujan	Tidak Hujan
02-01-2022	Tidak Hujan	Tidak Hujan
03-01-2022	Tidak Hujan	Tidak Hujan
04-01-2022	Tidak Hujan	Hujan
05-01-2022	Tidak Hujan	Hujan
06-01-2022	Hujan	Tidak Hujan
07-01-2022	Hujan	Hujan
08-01-2022	Hujan	Hujan
09-01-2022	Hujan	Hujan
10-01-2022	Hujan	Hujan

Tabel 3. 2 Confusion matriks

TP (4)	FP (2)
FN (1)	TN (3)

$$Accuracy = \frac{(4 + 3)}{(4 + 2 + 1 + 3)} = 0.7 = 70\%$$

$$Precision = \frac{4}{(4 + 2)} = \frac{4}{6} = 67\%$$

$$Recall = \frac{4}{(4+1)} = \frac{4}{5} = 80\%$$

$$F1\ Score = \frac{2 \times (80\% \times 67\%)}{(80\% \times 67\%)} = 72.93\%$$