

SKRIPSI

**PEMODELAN *TIME SERIES* MENGGUNAKAN METODE
LONG SHORT TERM MEMORY (LSTM) UNTUK
MEMPREDIKSI SUHU UDARA
(Studi Kasus: Stasiun Meteorologi Maritim Paotere Makassar)**



**HANDAYANI
E0220304**

**PROGRAM STUDI STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS SULAWESI BARAT
TAHUN 2024**

ABSTRAK

Prediksi merupakan proses memperkirakan sesuatu yang terjadi di masa depan berdasarkan data historis yang berupa data *time series*. Analisis dalam prediksi data *time series* ini menggunakan metode *Long Short Term Memory* (LSTM). LSTM merupakan pengembangan dari RNN, dimana LSTM mampu menyimpan informasi dalam jangka panjang. Penelitian ini bertujuan untuk memodelkan data *time series* dalam prediksi suhu udara di Stasiun Meteorologi Maritim Paotere Makassar. Pengujian akurasi model ini menggunakan berbagai metrik, seperti *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE), dimana model yang memiliki nilai terkecil merupakan model terbaik. Hasil penelitian menunjukkan bahwa model LSTM terbaik dalam memprediksi suhu udara berada pada pembagian data *training* 90% dan data *testing* 10% dengan jumlah *neuron* 50, *epoch* 150, dan *batch size* 128. Adapun akurasi suhu udara *minimum* berada pada nilai MAE, RMSE, dan MAPE berturut-turut sebesar 0,53; 0,67; dan 2,07%. Suhu udara maksimum nilai akurasi MAE, RMSE dan MAPE berturut-turut sebesar 0,70; 0,90; dan 2,14%. Suhu udara rata-rata nilai akurasi MAE, RMSE, dan MAPE berturut-turut sebesar 0,50; 0,64; dan 1,75%. Hal ini menunjukkan bahwa model sangat baik untuk memprediksi suhu udara di Stasiun Meteorologi Maritim Paotere Makassar.

Kata kunci: *time series*, LSTM, prediksi suhu udara, suhu udara

BAB I PENDAHULUAN

1.1. Latar Belakang

Cuaca adalah faktor yang sangat penting bagi kehidupan manusia. Cuaca mempunyai peran besar terhadap kehidupan. Cuaca memiliki beberapa unsur penting salah satunya yaitu suhu udara (Sundari, 2020). Menurut BMKG (2023) bahwa Suhu udara saat ini mengalami perubahan yang meningkat tiap tahunnya, Kepala Meteorologi, Klimatologi dan Geofisika (BMKG) Dwikorita Karnawati menyebut cuaca panas dialami Indonesia dan juga menyerang banyak tempat di seluruh belahan dunia bahkan tahun 2023 menjadi tahun penuh rekor *temperature*, sehingga untuk mengatasi permasalahan tersebut perlu dilakukan prediksi, oleh karena itu prediksi suhu udara di tahun berikutnya perlu diperhatikan.

Prediksi merupakan upaya untuk memperkirakan sesuatu yang akan terjadi di masa yang akan datang dengan menggunakan berbagai informasi yang mempunyai hubungan dengan masa lalu (historis). Prediksi juga dapat menerka nilai masa depan berdasarkan masa lalu yang dianalisis secara ilmiah, terutama menggunakan metode statistik. *Data time series* atau data deret waktu merupakan sekumpulan data yang berurutan pada periode tertentu (Arumsari dkk., 2021). Mengingat betapa pentingnya banyak yang melakukan prediksi ataupun peramalan diantaranya penelitian Machmudin & Ulama (2012) tentang peramalan temperatur udara di kota Surabaya dengan menggunakan ARIMA dan *artificial network* didapatkan model terbaik yang dapat diterapkan dalam peramalan temperatur udara kota Surabaya adalah model *feedforward network* (FFNN) dengan nilai (5,10,1) menggunakan *artificial network*, model ARIMA dari hasil penelitian belum baik sehingga penelitian selanjutnya dapat memperbaiki model, adapun untuk ANN *backpropagation* memberikan model yang cukup baik dan dapat dikembangkan pada model ANN. Penelitian Dewi (2020) Peramalan harga emas dunia menggunakan metode *recurrent*

network (RNN) didapat bahwa Model peramalan harga emas dengan faktor ekonomi makro (harga minyak dunia) mampu menangkap akurasi harga yang lebih tajam dibandingkan model tanpa faktor ekonomi makro. disarankan penelitian selanjutnya menggunakan metode LSTM dan GRU. Penelitian lainnya yaitu penelitian Nurashila dkk. (2023) tentang perbandingan kinerja *recurrent* (RNN) dan *long short term memory* (LSTM) dengan studi kasus prediksi kemacetan lalu lintas jaringan PT. XYZ, didapat kesimpulan bahwa model dengan algoritma LSTM yang terdapat pada *deep learning* dapat digunakan untuk melakukan prediksi kemacetan lalu lintas jaringan yang terjadi di PT XYZ.

Adapun penelitian dengan menggunakan metode LSTM telah banyak dilakukan sebelumnya diantaranya yaitu, penelitian Lattifia dkk. (2022) tentang model prediksi cuaca menggunakan metode LSTM, didapat bahwa terdapat 2 *hyperparameter* yang mempengaruhi hasil prakira model pada penelitian yang dilakukan yaitu *epoch* dan *batch size*, model prediksi cuaca menggunakan LSTM dengan akurasi rata-rata diperoleh dengan menggunakan *batch size* 100 serta *epoch* 50 dan nilai RMSE dan MAPE terbaik diperoleh yaitu 1,744 dan 1,9499%. Penelitian Hamzar dkk. (2023) tentang dampak ukuran dataset penelitian terhadap performa LSTM *network* dalam konteks harga saham, didapat bahwa model terbaik berada pada *training* 90% dan *testing* 10% dengan nilai RMSE paling kecil, pada penelitian ini disarankan menggunakan nilai *epoch* yang lebih besar seperti 100 *epoch* atau 200 *epoch*. Penelitian Rizki dkk. (2020) tentang implementasi *deep learning* menggunakan LSTM untuk prediksi curah hujan kota malang didapat bahwa jumlah *neuron hidden layer* berada pada 256 yang memiliki tingkat *error* paling rendah dengan hasil paling optimal yaitu komposisi data *train* 50% dan data *test* 50% memiliki tingkat *error* paling rendah yaitu data *train* 12,079 dan data *test* sebesar 11,288; disarankan untuk menggunakan lebih banyak data dan jumlah parameter.

LSTM merupakan modifikasi dari RNN yang dirancang untuk mengatasi kelemahan RNN yang mudah melupakan informasi lama. Model LSTM terdiri dari sel-sel berulang yang saling terhubung, setiap sel memiliki empat gerbang yang mengontrol aliran informasi yaitu *forget gate*, *input gate*, *cell state* dan

output gate (Raharjo, 2022). LSTM merupakan metode yang cocok digunakan di pemodelan *time series* dengan keunggulannya dalam memahami pola-pola jangka panjang dalam historis.

Dalam konteks ini Makassar merupakan salah satu wilayah di Indonesia yang membutuhkan prediksi suhu udara yang akurat. Dengan memiliki model prediksi suhu udara menggunakan metode LSTM, dapat membantu dalam mengambil keputusan yang lebih baik. Dalam memprediksi suhu udara, LSTM dapat mempelajari pola musiman, *trend* jangka panjang dan fluktuasi harian suhu udara. Dengan menggunakan data historis suhu udara yang telah dikumpulkan dari stasiun meteorologi maritim paotere, model LSTM dapat dilatih untuk mengidentifikasi dan memprediksi pola-pola ini. Oleh karena itu, penulis ingin melakukan penelitian mengenai pemodelan *time series* menggunakan metode LSTM untuk memprediksi suhu udara dengan studi kasus stasiun meteorologi maritim paotere di Makassar. Variabel suhu udara yang akan dianalisis meliputi suhu *minimum*, maksimum dan rata-rata dengan membandingkan model LSTM yang dibentuk dari berbagai *hyperparameter* dalam model LSTM yaitu, *neuron*, *batch size*, dan *epoch*. Model LSTM yang mempunyai nilai MAE, MAPE dan RMSE terkecil merupakan model LSTM yang terbaik dalam memprediksi suhu udara.

1.2. Rumusan masalah

Berdasarkan latar belakang yang dibahas maka rumusan masalah dalam penelitian ini yaitu:

1. Bagaimana model terbaik LSTM berdasarkan data *time series* pada suhu udara di Stasiun Meteorologi Maritim Paotere di Makassar menggunakan metode LSTM?
2. Bagaimana hasil prediksi suhu udara di Stasiun Meteorologi Maritim Paotere yang menggunakan model LSTM terbaik?

1.3. Tujuan Penelitian

1. Untuk mengetahui model terbaik LSTM pada suhu udara di Stasiun Meteorologi Maritim Paotere menggunakan metode LSTM.

2. Untuk mengetahui hasil prediksi suhu udara di Stasiun Meteorologi Maritim Paotere menggunakan model LSTM yang terbaik.

1.4. Manfaat penelitian

1. Meningkatkan wawasan mengenai implementasi metode LSTM dalam suhu udara di Makassar.
2. Sarana pengembangan ilmu pengetahuan mahasiswa dan masyarakat dibidang peramalan.

1.5. Batasan Masalah

Pada penelitian ini, masalah dibatasi berdasarkan sumber data yang digunakan yaitu dari BMKG 2016-2023 sehingga pemilihan variabelnya terbatas pada suhu udara di Stasiun Meteorologi Maritim Paotere Makassar.

BAB II

TINJAUAN PUSTAKA

2.1. Prediksi (*Prediction*)

Prediksi merupakan upaya untuk memperkirakan sesuatu yang akan terjadi di masa yang akan datang dengan menggunakan berbagai informasi yang mempunyai hubungan dengan masa lalu (historis). Prediksi juga dapat menerka nilai masa depan berdasarkan masa lalu yang dianalisis secara ilmiah, terutama menggunakan metode statistik (Meychael dkk., 2018). Menunjukkan apa yang akan terjadi sebagai perkiraan di waktu yang mendatang dan dapat dijadikan sebagai dasar pengambilan keputusan merupakan bentuk lain dari prediksi. Menurut Eddy Herjanto dalam kutipan Kurnia (2022) yang mengartikan beberapa kesimpulan dari para ahli, prediksi merupakan prosedur atau cara peramalan berdasarkan perbandingan pengalaman, dalam memprediksi sesuatu dengan menggunakan data kuantitatif sebagai acuan dalam proses peramalan. Sedangkan arti prakiraan merupakan prosedur atau cara peramalan yang akan datang bersumber dari data di waktu lampau atau sebelumnya.

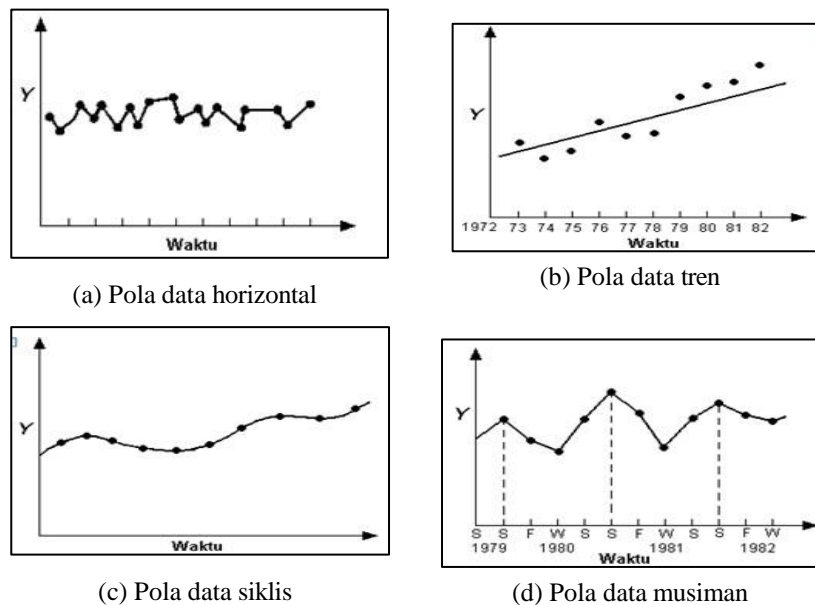
Tujuan prediksi sama dengan peramalan adalah *error* atau kesalahan, karena semakin sedikit kesalahan maka hasil prediksi semakin baik atau mendekati data aktualnya (Wei, 2006). Menurut Rachman dkk. (2018), Peramalan dapat dikelompokkan dalam tiga bagian, yaitu peramalan jangka pendek, peramalan jangka menengah dan peramalan jangka panjang:

1. Peramalan jangka pendek ialah peramalan dengan jangka waktu umumnya kurang dari 3 bulan hingga 1 tahun.
2. Peramalan jangka menengah ialah peramalan mencakup waktu 3 tahun.
3. Peramalan jangka panjang ialah peramalan dengan jangka waktu 3 tahun atau lebih.

2.2. Deret waktu (*time series*)

Data rentang waktu, juga dikenal sebagai "deret waktu", adalah sekumpulan data yang dikumpulkan dari pengamatan atau tindakan yang dilakukan selama periode waktu tertentu dan direkam secara berurutan dalam interval waktu yang

tetap, periode waktu, seperti harian, mingguan, bulanan, tahunan, dan lain-lain, terdiri dari satu objek (Wei, 2006). Menurut Hanke, J. E dan Wichern, D. W. dikutip oleh Garini & Anbiya (2022) pada data *time series* terdapat empat macam pola yaitu *horizontal*, musiman, siklis dan *trend*. Pola *horizontal*, terjadi jika nilai data fluktuasi di sekitar rata-rata konstan dan membentuk suatu garis *horizontal*. Pola musiman terjadi ketika suatu deret dipengaruhi oleh faktor musiman (misalnya kuartal tahun tertentu, bulanan, atau hari-hari pada minggu tertentu), pola siklis terjadi ketika data dipengaruhi oleh fluktuasi jangka panjang dan pola *trend* terjadi ketika mengalami kenaikan atau penurunan selama periode jangka panjang dalam data.



Sumber: (Arumsari dkk., 2021)

Gambar 2.1 Pola data *time series*

2.3. *Processing data*

Preprocessing data merupakan sebuah proses yang sangat penting sebelum dilakukan proses pelatihan (Arief dkk., 2023). Tujuan utama dari *processing* ini adalah untuk meningkatkan kualitas data dan mengoptimalkan data sehingga algoritma pembelajaran dapat bekerja secara efektif dan efisien. Dengan *processing* yang tepat, model yang dihasilkan akan lebih akurat.

2.3.1. Data Cleaning

Data *Cleaning* atau pembersihan data adalah proses melakukan penanganan pada data yang terjadi *missing value* atau *noise* (Lazuardy dkk., 2019). Pembersihan data merupakan langkah awal yang penting dalam membangun model prediksi yang akurat. Dengan data yang bersih, model dapat lebih baik dalam mengidentifikasi pola dan *trend* dalam data.

2.3.2. Normalisasi Data

Normalisasi merupakan proses penskalaan nilai data agar nilai data berada dalam rentang tertentu. Bentuk normalisasi datanya adalah normalisasi *Min-Max*, proses normalisasi ini menggunakan metode transformasi linier pada data asli (Sugiartawan dkk., 2018).

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2.1)$$

Keterangan:

x' : Data hasil normalisasi


x : Data asli

x_{\max} : Nilai maksimum dari x

x_{\min} : Nilai *minimum* dari x

2.3.3. Segmentasi Data

Segmentasi merupakan pengelompokan data mentah yang kemudian menjadi data yang dibutuhkan oleh sistem (Pradana, 2023). Adapun ilustrasinya sebagai berikut:



Gambar 2.2 Ilustrasi pola *time series*

Pada Gambar 2.2, apabila dilakukan pengelompokan yang terdiri dari 40 *time step* maka *time step* 1 hingga *time step* 40 merupakan bagian dari *input*. Sedangkan pada *time step* 41 merupakan bagian target. Begitu seterusnya, apabila *input* terdiri dari *time step* ke-2 hingga *time step* ke-41, maka targetnya merupakan *time step* ke-42.

2.4. Pembagian Data *Training* dan Data *Testing*.

Pada proses ini data akan dibagi menjadi dua bagian yaitu data *training* dan *testing*, data *training* digunakan untuk pelatihan model sedangkan data *testing* digunakan untuk menguji keakuratan dan performa model LSTM yang dibentuk pada pelatihan sebelumnya (Sugiartawan dkk., 2018).

2.5. *Machine Learning*

Machine learning merupakan serangkaian teknik yang membantu memproses dan memprediksi data dalam jumlah yang sangat besar dengan mempresentasikan data tersebut menggunakan algoritma pembelajaran seperti ANN, RNN, LSTM (Roihan dkk., 2020). Dalam pembelajaran terdapat dua metode yaitu metode *supervised learning* dan *unsupervised learning* yaitu:

1. *Supervised learning*

Supervised learning (pembelajaran terawasi), sistem ini menerima sekumpulan data pelatihan berupa data *input* dan *output* yang diinginkan sehingga sistem belajar data pelatihan yang telah diberikan. Sistem mencari pola pada kumpulan data, kemudian menggunakan pola tersebut sebagai acuan untuk kumpulan data berikutnya.


2. *Unsupervised learning*

Unsupervised learning (pembelajaran tak terawasi), pembelajaran ini bersifat deskriptif dan tidak mendapatkan *training* data karena tidak bersifat prediktif atau tidak membutuhkan adanya target.

2.6. *Artificial Network* (ANN)

Pada pembelajaran jaringan saraf tiruan terdapat *system* pengolah data komputer yang mempunyai sistem operasi yang sama dengan jaringan saraf

tiruan, ANN memiliki sistem operasi yang sama dengan otak manusia, dimana ia memiliki *neuron-neuron* yang saling terhubung pada lapisan jaringan yang berbeda. Dalam ANN terdiri dari tiga jenis lapisan yang sangat penting dalam pembentukan model yaitu lapisan *input*, *hidden* dan *output* (Krismantoro, 2023). Secara sederhana adapun ilustrasinya sebagai berikut.



sumber : (Hamdina dkk., 2020)

Gambar 2.3 Arsitektur *artificial network*

1. *Input layer* merupakan lapisan yang terdiri dari beberapa lapisan *neuron* yang menerima sinyal dari luar dan kemudian mengirimnya ke *neuron* lain dalam jaringan sesuai dengan cara kerja *neuron* sensorik.
2. *Hidden layer* merupakan lapisan tiruan penghubung *neuron* pada jaringan saraf biologis. Lapisan tersembunyi meningkatkan kemampuan jaringan dalam memecahkan masalah.
3. *Output layer* merupakan lapisan yang dirancang untuk mendistribusikan sinyal keluaran yang dihasilkan selama pemrosesan jaringan. Lapisan ini juga terdiri dari beberapa *neuron*. Lapisan keluaran merupakan tiruan *neuron* motorik dalam jaringan saraf biologis.

2.7. *Recurrent Network (RNN)*

Recurrent network (RNN) merupakan jaringan saraf berulang yaitu suatu jenis jaringan saraf tiruan yang dirancang khusus untuk mengolah data sekuensial, sehingga dapat digunakan untuk mengolah data deret waktu, RNN dikatakan jaringan saraf tiruan berulang karena nilai pada *hidden layer* sebelumnya digunakan kembali sebagai data *input* bagi pemrosesan selanjutnya. Berdasarkan

arsitektur RNN, metode ini secara teoritis dapat menyelesaikan masalah ketergantungan dalam jangka panjang saat digunakan, RNN tidak dapat menyimpan informasi masa lalu dengan benar karena adanya masalah dengan gradien yang hilang (Tian dkk., 2018).

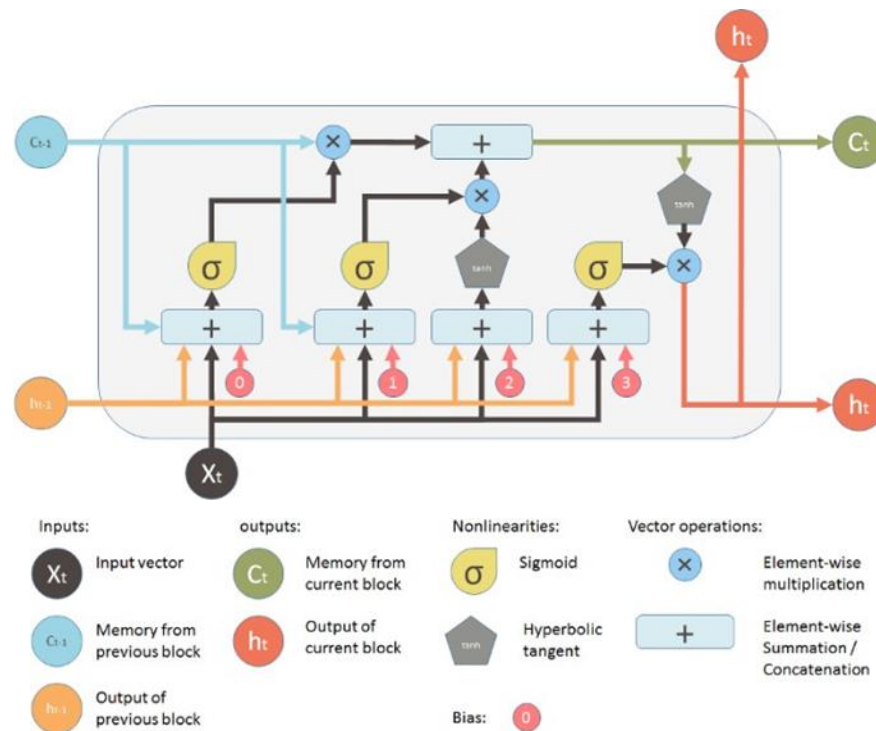
2.8. Long Short Term Memory (LSTM)

LSTM adalah pengembangan dari RNN yang pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997 (Sofi dkk., 2021). LSTM dirancang untuk menangani masalah hilangnya gradien di RNN saat menggunakan data sekuensial yang panjang pada masalah hilangnya gradien menyebabkan RNN gagal menangkap dependensi jangka panjang sehingga mengurangi keakuratan prediksi menggunakan RNN (Hanifa dkk., 2021).

LSTM memiliki gerbang (*gate*) yang mengatur informasi apa saja yang boleh masuk ke dalam memori sel. LSTM sangat berguna untuk mengatasi kesulitan dalam mengingat informasi penting dari data yang sudah lama bermasalah. Selain itu, LSTM memiliki kemampuan untuk mengingat informasi sebelumnya, sehingga dapat memahami hubungan antara data-data yang muncul secara berurutan. Dengan kata lain, LSTM tidak hanya melihat data saat ini saja, tetapi juga mempertimbangkan konteks dari data-data sebelumnya (Raharjo, 2022). Sehingga dapat disimpulkan bahwa LSTM merupakan alat yang sangat ampuh untuk menangani data sekuensial dengan kemampuannya mengingat informasi penting dalam mengatasi hilangnya gradien.

2.8.1. Arsitektur Long Short Term Memory

Pada proses perhitungan LSTM yang dilakukan secara bertahap, terdapat 3 *gate* (gerbang) yaitu *input gate*, *forget gate* dan *output gate*. Pada *memory cell* setiap *gate* dapat membaca, menyimpan dan memperbarui data sebelumnya (Hanifa dkk., 2021).



Sumber : (Rizki dkk., 2020)

Gambar 2.4 Arsitektur *long short term memory*

Pada Gambar 2.4 menunjukkan isi lapisan tersembunyi LSTM yaitu *memory cell*. *Memory cell* LSTM menyimpan nilai dalam waktu lama atau singkat. Berikut ini penjelasan *gate* atau gerbang satu sel *memory* LSTM.

1. *Forget gate* merupakan gerbang pertama dalam LSTM pada *forget gate* informasi yang tidak dibutuhkan akan dihilangkan menggunakan fungsi *sigmoid*, *forget gate* menerima h_{t-1} dan x_t untuk menghasilkan nilai 0 atau 1 pada C_{t-1} saat *forget gate* bernilai 1 maka informasi akan disimpan di dalam *cell state*, namun jika bernilai 0 maka informasi akan di buang (Wati & Pramatha, 2022).

Persamaan *forget gate* diuraikan sebagai berikut:

$$f_t = \sigma(W_f \times x_t + W_f \times h_{t-1} + b_f) \quad (2.2)$$

Keterangan :

f_t : *Forget gate*

σ : Fungsi aktivasi *sigmoid*

W_f : Nilai *weight* untuk *forget gate*

h_{t-1} : Nilai *output* periode ke t-1

x_t : Nilai *input* periode ke t

b_f : Nilai bias pada *forget gate*

2. *Input gate* merupakan informasi dipilih sebelum dibawa ke *cell state* menggunakan fungsi aktivasi *sigmoid*. Selain itu, kandidat vektor baru ditentukan menggunakan fungsi *tanh* yang dibawa ke dalam bagian *cell state* (Wati & Pramatha, 2022).

Persamaan *input gate* diuraikan sebagai berikut:

$$i_t = \sigma(W_i \times x_t + W_i \times h_{t-1} + b_i) \quad (2.3)$$

Keterangan :

i_t : *Input gate*

σ : Fungsi aktivasi *sigmoid*

W_i : Nilai *weight* untuk *input gate*

h_{t-1} : Nilai *output* period eke t-1

x_t : Nilai *input* periode ke t

b_i : Nilai bias pada *input gate*

Persamaan kandidat vektor baru diuraikan sebagai berikut:

$$\bar{c}_t = \tanh(W_c \times x_t + W_c \times h_{t-1} + b_c) \quad (2.4)$$

Keterangan :

\bar{c}_t : Kandidat vektor baru

\tanh : Fungsi tangen hiperbolik

W_c : Nilai *weight* untuk *cell state*

h_{t-1} : Nilai *output* periode ke t-1

x_t : Nilai *input* periode ke t

b_c : Nilai bias pada *cell state*

3. *Cell state*, nilai *state* lama c_{t-1} akan diperbarui ke nilai *state* baru c_t dengan mengalikan nilai *cell state* lama dengan f_t untuk menghapus nilai dari *forget gate* sebelumnya dan menambahkan *input gate* yang dikalikan dengan \bar{c}_t sebagai nilai baru yang digunakan untuk memperbarui nilai *cell state* (Wati & Pramatha, 2022).

Persamaan *cell state* dapat diuraikan sebagai berikut:

$$c_t = f_t \times c_{t-1} + i_t \times \bar{c}_t \quad (2.5)$$

Keterangan :

c_t : Nilai *memory* sel baru

f_t : *Forget gate*

c_{t-1} : Nilai *memory* sel sebelumnya

i_t : *Input gate*

\bar{c}_t : Kandidat vektor baru

4. *Output gate* merupakan gerbang terakhir LSTM yang menentukan keluaran keadaan sel, lapisan *sigmoid* menentukan bagian *cell state* yang akan dicetak. Kemudian hasil keadaan sel diungkapkan ke lapisan *tanh* dan dikalikan dengan keluaran dari lapisan *sigmoid* (Arief dkk., 2023).

Persamaan *output gate* diuraikan sebagai berikut:

$$o_t = \sigma(W_o \times x_t + W_o \times h_{t-1} + b_o) \quad (2.6)$$

$$h_t = \tanh(c_t) \times o_t \quad (2.7)$$

Keterangan:

o_t : *Output gate*

h_t : Nilai *output* periode ke t

σ : Fungsi aktivasi *sigmoid*

\tanh : Fungsi tangen hiperbolik

W_o : Nilai *weight* untuk *output gate*

h_{t-1} : Nilai *output* periode ke t-1

x_t : Nilai *input* periode ke t

b_o : Nilai bias pada *output gate*

Fungsi aktivasi menentukan hubungan antara *input* dan *output* dari *neuron* dan jaringan saraf tiruan, fungsi aktivasi pada dasarnya mengubah nilai *input* yang disalurkan menjadi *output* (Setiawan dkk., 2022). Fungsi aktivasi yang digunakan adalah sebagai berikut:

1. Fungsi *sigmoid* adalah fungsi aktivasi non-linier yang menghasilkan nilai *range* antara 0 hingga 1. Fungsi *sigmoid* didefinisikan sebagai berikut:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.8)$$

Keterangan :

$\sigma(x)$: Fungsi *sigmoid*

e : Bilangan euler

2. Fungsi *tanh* adalah fungsi aktivasi *non-linier* yang keluarannya berkisar antara -1 hingga 1. Fungsi *tanh* didefinisikan sebagai berikut:

$$\tanh(x) = 2\sigma(2x) - 1 \quad (2.9)$$

Keterangan :

$\tanh(x)$: Fungsi tangen hiperbolik

e : Bilangan euler

2.8.2. Membangun *Model Long Short Term Memory*

1. *Hidden* dan *nodes layer*

Jumlah *hidden layer* yang digunakan mempengaruhi perubahan hasil pelatihan, terlalu sedikit *neuron* akan memberikan hasil yang buruk, sedangkan terlalu banyak *neuron* akan memperlambat pelatihan dan dapat terjadi pelatihan yang tidak terbatas, maka dari itu untuk menentukan *hidden layer* dalam jaringan

backpropagation, satu *hidden layer* cukup untuk mengevaluasi setiap pemetaan (Heaton, 2013).

2. *Epoch* dan *batch size*

Epoch adalah jumlah iterasi selama pelatihan yang menghasilkan *output* dari jaringan dan juga memperbarui bobot jaringan. Dalam proses pelatihan satu *epoch* membutuhkan waktu yang cukup lama sehingga dilakukan pembagian per *batch* untuk mempercepat proses pelatihan, proses ini disebut *batch size* (Rochmawati dkk., 2021).

3. Optimizer Adam

Adam (*Adaptive Moment Estimation*) adalah optimasi yang banyak digunakan dalam *deep learning*. Keunggulan utama adam adalah kemampuannya untuk secara otomatis menyesuaikan bobot dan *learning rate* selama proses pelatihan, sehingga proses pelatihan menjadi lebih efektif (Asy Syifa & Amelia Dewi, 2022).

2.9. Denormalisasi

Sebelum melakukan perhitungan akurasi nilai, hasil prediksi yang diperoleh perlu dilakukan denormalisasi yaitu data perlu diubah kembali ke bentuk semula karena data prediksi masih berupa *interval* pada saat data dinormalisasikan. Tujuan denormalisasi adalah agar data mudah dibaca (Lattifia dkk., 2022). Adapun rumus denormalisasi adalah sebagai berikut:

$$y_t = y'(x_{\max} - x_{\min}) + x_{\min} \quad (2.10)$$

Keterangan :

- y_t : Nilai hasil denormalisasi
- y' : Nilai *output* data setelah dihasilkan
- x_{\max} : Nilai maksimum pada data aktual
- x_{\min} : Nilai *minimum* pada data aktual

2.10. Evaluasi Model

Evaluasi model adalah proses untuk menguji keakuratan pada performa model tersebut pada data yang belum pernah dilihat sebelumnya, ini penting untuk mengetahui seberapa baik model telah belajar dari data latih (Ihzaniah, 2023). Dalam melakukan keakuratan performa model, terdapat beberapa cara yang digunakan yaitu: *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percent Error* (MAPE) (Ihzaniah dkk., 2023).

2.10.1. Mean Absolute Error (MAE)

MAE merupakan rata-rata nilai aktual dan nilai prediksi yang bernilai mutlak positif. Adapun rumus MAE sebagai berikut:

$$MAE = \frac{\sum_{t=1}^n |\hat{y}_t - y_t|}{n} \quad (2.11)$$

Keterangan :

- y_t : Data suhu udara pada periode t
- \hat{y}_t : Data prediksi suhu udara pada periode t
- n : Banyaknya periode data suhu udara

2.10.2. Root Mean Squared Error (RMSE)

RMSE merupakan akar kuadrat dari rata-rata kuadrat nilai aktual dan nilai prediksi. Nilai RMSE yang diperoleh dari selisi data aktual suhu udara keseluruhan dikurangi data prediksi suhu udara, yang dikuadratkan dibagi jumlah prediksi suhu udara dan kemudian dilakukan pengakaran. Adapun rumusnya sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (2.12)$$

Keterangan :

- y_t : Data suhu udara pada periode t
- \hat{y}_t : Data prediksi suhu udara pada periode t
- n : Banyaknya periode data suhu udara

2.10.3. Mean Absolute Percent Error (MAPE)

MAPE merupakan rata-rata antara nilai peramalan dan nilai aktual yang dinyatakan sebagai persentase. Adapun rumusnya sebagai berikut:

$$MAPE = \frac{\sum_{t=1}^n \frac{|\hat{y}_t - y_t|}{y_t}}{n} \times 100\% \quad (2.13)$$

Keterangan :

- y_t : Data suhu udara pada periode t
- \hat{y}_t : Data prediksi suhu udara pada periode t
- n : Banyaknya periode data suhu udara

Jika nilai MAPE model LSTM semakin kecil maka merupakan model LSTM terbaik untuk prediksi suhu udara. Menurut (Warmansyah & Hilpiah, 2019) ada beberapa kriteria tentang nilai MAPE yaitu :

Tabel 2.1 Kriteria nilai MAPE

Range MAPE	Penjelasan Nilai
<10%	Sangat baik
10-20%	Baik
20-50%	Sedang
>50%	Buruk

BAB III METODE PENELITIAN

3.1. Waktu dan Tempat Penelitian

Penelitian dilakukan pada semester genap tahun akademik 2023/2024, bertempat di Laboratorium Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Sulawesi Barat.

3.2. Data Penelitian

Data yang digunakan pada penelitian ini merupakan data sekunder yang di dapat dari https://dataonline.bmkg.go.id/data_iklim mengenai data historis suhu udara di Makassar. Data tersebut merupakan data suhu udara pada periode 1 januari 2016 sampai 31 Desember 2023 dengan jumlah data sebanyak 2922. Struktur data penelitian yang digunakan dapat dilihat pada tabel berikut:

Tabel 3.1 Data suhu udara

Tanggal	Tn	Tx	Tavg
01-01-2016	26	32,8	29
02-01-2016	26,4	32,4	28,9
03-01-2016	26,2	33,2	29,3
04-01-2016	26	32,8	29,4
05-01-2016	24	33,7	29,3
...

Keterangan :

1. Tn : suhu *minimum* (°C) merupakan suhu harian terendah yang terekam selama 24 jam sebanyak 2922 hari dimulai dari tanggal 1 Januari sampai 31 Desember 2023
2. Tx : suhu maksimum(°C) merupakan suhu harian tertinggi yang terekam selama 24 jam sebanyak 2922 hari dimulai dari tanggal 1 Januari sampai 31 Desember 2023
3. Tavg : suhu rata-rata (°C) merupakan rata-rata suhu yang terekam selama 24 jam sebanyak 2922 hari dimulai dari tanggal 1 Januari sampai 31 Desember 2023.

3.3. Jadwal Penelitian

Berikut ini adalah jadwal penelitian yang telah dilakukan

Tabel 3.2 Jadwal penelitian

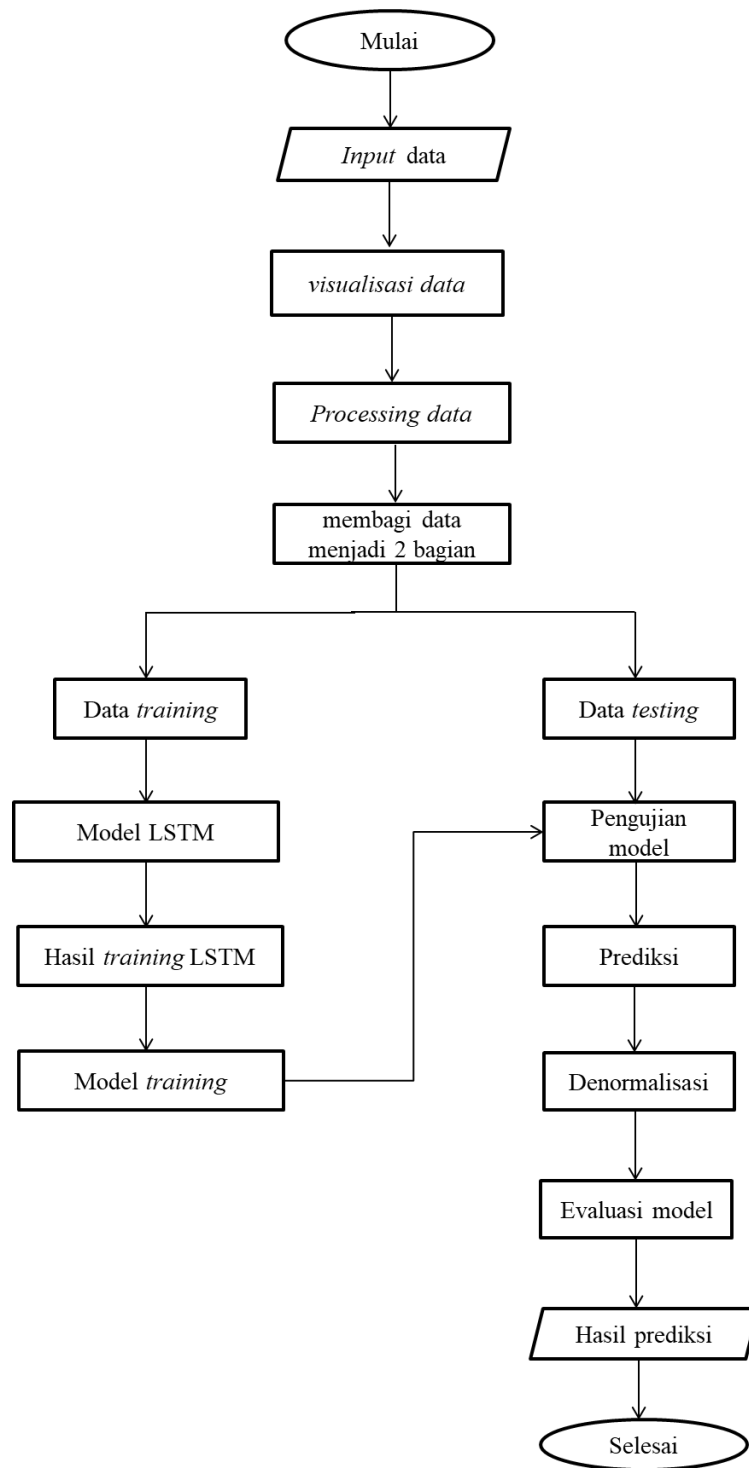
No	Kegiatan	Tahun 2023/2024								
		Nov-23	Dec-23	Jan-24	Feb-24	Mar-24	Apr-24	May-24	Jun-24	Jul-24
1.	Pengajuan Judul	■	■							
2.	Pengambilan Data			■	■					
3.	Pengajuan Proposal					■	■			
4.	Analisis Data							■	■	
5.	Penyusunan Skripsi									■

3.4. Metode Penelitian

Pada penelitian ini menggunakan metode LSTM untuk memprediksi suhu udara dengan memberikan variasi nilai parameter yang berbeda (*neuron*, *batch size*, dan *epoch*). Metode pengujian menggunakan *software python* yang didukung oleh *google colab*. Berikut ini adalah metode penelitian atau langkah-langkah dalam pengujian metode LSTM sebagai berikut:

1. *Input* data historis suhu udara ke dalam *google colab*
2. Menampilkan visualisasi data melalui *plot time series*
3. Melakukan *processing data* yang meliputi:
 - a. *Data cleaning* tujuannya untuk membersihkan data karena adanya *missing value* atau data yang hilang.
 - b. Menormalisasikan data dengan menggunakan metode *Min-Max Scaling*
4. Melakukan segmentasi data lalu membagi data menjadi data *training* 60%, 70%, 80%, 90% dan data *testing* 40%, 30%, 20%, 10%
5. Membangun model LSTM menggunakan data *training*.
6. Menentukan model prediksi suhu udara dari model yang terbentuk
7. Melakukan denormalisasi atau mengubah data hasil normalisasi ke bentuk data aslinya

8. Melakukan evaluasi model menggunakan data *training* dan *testing* sehingga didapatkan nilai MAE, RMSE, dan MAPE.
9. Membandingkan kinerja model yang dibentuk untuk beberapa variasi jumlah *neuron*, *batch size*, dan *epoch* serta berbagai komposisi pembagian data *training* dan *testing*. Model LSTM dengan nilai MAE, RMSE dan MAPE yang terkecil adalah model terbaik.
10. Menampilkan visualisasi hasil prediksi suhu udara dari model LSTM yang terbaik
11. Memaparkan kesimpulan berdasarkan hasil yang diperoleh.



Gambar 3.1 Diagram alir metode penelitian

DAFTAR PUSTAKA

- Arief, B., Kholifatullah, H., & Prihanto, A. (2023). Penerapan Metode Long Short Term Memory Untuk Klasifikasi Pada Hate Speech. *Journal of Informatics and Computer Science*, 04.
- Arumsari, M., Tri, A., & Dani, R. (2021). Peramalan Data Runtun Waktu menggunakan Model Hybrid Time Series Regression-Autoregressive Integrated Moving Average. In *Jurnal Siger Matematika* (Vol. 02, Issue 01).
- Asy Syifa, S., & Amelia Dewi, I. (2022). MIND (Multimedia Artificial Intelligent Networking Database Arsitektur Resnet-152 dengan Perbandingan Optimizer Adam dan RMSProp untuk Mendeteksi Penyakit Paru-Paru. *Journal MIND Journal | ISSN*, 7(2), 139–150.
<https://doi.org/10.26760/mindjournal.v7i2.139-150>
- BMKG.(2023).<https://www.bmkg.go.id/berita/?p=2023-jadi-tahun-terpanas-bmkg-cuaca-panas-tidak-hanya-menyerang-indonesia&lang=ID&tag=press-release>
- Dewi, L. R. (2020). Peramalan Harga Emas Dunia Menggunakan Metode Recurrent Neural Network (RNN). *Institut Teknologi Sepuluh Nopember*.
- Garini, F. C., & Anbiya, W. (2022). Application of GARCH Forecasting Method in Predicting The Number of Rail Passengers (Thousands of People) in Jabodetabek Region. *Jurnal Matematika, Statistika Dan Komputasi*, 18(2), 198–223. <https://doi.org/10.20956/j.v18i2.18382>
- Hamdina, H., Rahmat, Z., & S, W. (2020). Analisis Penilaian Kinerja Pegawai Untuk Mengetahui Kualitas Kelayakan Kerja Menggunakan Jaringan Syaraf Tiruan Backpropagation. *Movere Journal*, 2(1), 12–24. <https://doi.org/10.53654/mv.v2i1.87>
- Hamzar, R. A., Setyaningsih, F. A., Rekayasa, J., & Komputer, S. (2023). Dampak Ukuran Dataset Pelatihan Terhadap Performa LSTM Network dalam Konteks Harga Saham. *Jurnal Komputer Dan Aplikasi*, 11(02), 238–247.
- Hanifa, A., Fauzan, S. A., Hikal, M., & Ashfiya, M. B. (2021). Perbandingan Metode LSTM dan GRU (RNN) untuk Klasifikasi Berita Palsu Berbahasa Indonesia. *Dinamika Rekayasa*, 17(1), 33. <https://doi.org/10.20884/1.dr.2021.17.1.436>
- Heaton, J. (2013). *Do not make illegal copies of this ebook* (Vol. 99).
- Ihzaniah, L. S., Setiawan, A., & Wijaya, R. W. N. (2023). Perbandingan Kinerja Metode Regresi K-Nearest Neighbor dan Metode Regresi Linear Berganda pada Data Boston Housing. *Jambura Journal of Probability and Statistics*, 4(1), 17–29. <https://doi.org/10.34312/jjps.v4i1.18948>
- Krismantoro, T. (2023). *Analisis Penerapan ANN dan RNN dengan Inisialisasi Nguyen-Widrow pada Aplikasi Monitoring Banjir dan Gempa*. 10(5), 4396.

- Kurnia Ahadan, M. N. (2022). Implementasi Metode Triple Exponential Smoothing (Brown) Untuk Prediksi Penjualan Barang Liquid Freebase Dan Salt Di Cv. Gressvape Balongpanggung. *Indexia*, 4(1), 17. <https://doi.org/10.30587/indexia.v4i1.3028>
- Lattifia, T., Wira Buana, P., & Rusjyanthi, N. K. D. (2022). Model Prediksi Cuaca Menggunakan Metode LSTM. *JITTER Jurnal Ilmiah Teknologi Dan Komputer*, 3(1), 994–1000.
- Lazuardy, A. G., Setiaji, H., Kom, S., & Eng, M. (2019). *Data Cleansing Pada Data Rumah Sakit*.
- Machmudin, A., & Ulama, B. S. S. (2012). Peramalan Temperatur Udara di Kota Surabaya dengan Menggunakan ARIMA dan Artificial Neural Network. *Jurnal Sains Dan Seni ITS*, 1(1), 118–123.
- Meychael, P. H., Muhamat, Z., & Wanto3, A. (2018). *Padi Sawah Menurut Kabupaten / Kota. July*.
- Neural, R., Rnn, N., & Long, D. A. N. (2024). *Skripsi prediksi curah hujan menggunakan*.
- Nurashila, S. S., Hamami, F., & Kusumasari, T. F. (2023). Perbandingan Kinerja Algoritma Recurrent Network (Rnn) Dan Long Short-Term Memory (Lstm): Studi Kasus Prediksi Kemacetan Lalu Lintas Jaringan Pt Xyz. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 8(3), 864–877. <https://doi.org/10.29100/jupi.v8i3.3961>
- Pradana, B. S. D. (2023). *Peramalan Data Time Series pada Harga Komoditas Pangan Menggunakan Metode Long Short-Term Memory (LSTM)*. 10–11.
- Rachman, R., Nusa, S., & Jakarta, M. (2018). 211~220 Diterima Maret 21. *Jurnal Informatika*, 5(1).
- Raharjo, B. (2022). *Deep Learning dengan Python*.
- Rizki, M., Basuki, S., & Azhar, Y. (2020). Implementasi Deep Learning Menggunakan Arsitektur Long Short Term Memory(LSTM) Untuk Prediksi Curah Hujan Kota Malang. *Jurnal Repositor*, 2(3), 331–338. <https://doi.org/10.22219/repositor.v2i3.470>
- Rochmawati, N., Hidayati, H. B., Yamasari, Y., Tjahyaningtijas, H. P. A., Yustanti, W., & Prihanto, A. (2021). Analisa Learning Rate dan Batch Size pada Klasifikasi Covid Menggunakan Deep Learning dengan Optimizer Adam. *Journal of Information Engineering and Educational Technology*, 5(2), 44–48. <https://doi.org/10.26740/jieet.v5n2.p44-48>
- Roihan, A., Sunarya, P. A., & Rafika, A. S. (2020). *Pemanfaatan Machine Learning dalam Berbagai Bidang : Review paper*. 5(April), 75–82.
- Setiawan, Y., Tarno, T., & Kartikasari, P. (2022). Prediksi Harga Jual Kakao Dengan Metode Long Short-Term Memory Menggunakan Metode Optimasi

Root Mean Square Propagation Dan Adaptive Moment Estimation Dilengkapi Gui Rshiny. *Jurnal Gaussian*, 11(1), 99–107. <https://doi.org/10.14710/j.gauss.v11i1.33994>

Sugiartawan, P., Jiwa Permana, A. A., & Prakoso, P. I. (2018). Forecasting Kunjungan Wisatawan Dengan Long Short Term Memory (LSTM). *Jurnal Sistem Informasi Dan Komputer Terapan Indonesia (JSIKTI)*, 1(1), 43–52. <https://doi.org/10.33173/jsikti.5>

Sundari, L. (2020). *Pemodelan Time Series Untuk Peramalan Suhu Udara Menggunakan Metode Long Short Term Memory (LSTM) (Studi Kasus: Stasiun Klimatologi Lampung)*. July, 1–23.

Sofi, K., Sunge, A.S., Riady, S.R., & Kamalia, A.Z. (2021). Perbandingan Algoritma Linear Regression, Lstm, Dan Gru Dalam Memprediksi Harga Saham Dengan Model Time Series. *Seminastika*, 3(1), 39–46. <https://doi.org/10.47002/seminastika.v3i1.275>

Tian, C., Ma, J., Zhang, C., & Zhan, P. (2018). A deep network model for short-term load forecast based on long short-term memory network and convolutional network. *Energies*, 11(12). <https://doi.org/10.3390/en11123493>

Warmansyah, J., & Hilpiah, D. (2019). Penerapan metode fuzzy sugeno untuk prediksi persediaan bahan baku. *Teknois : Jurnal Ilmiah Teknologi Informasi Dan Sains*, 9(2), 12–20. <https://doi.org/10.36350/jbs.v9i2.58>

Wati, N. P. S., & Pramarta, C. (2022). Penerapan Long Short Term Memory dalam Mengklasifikasi Jenis Ujaran Kebencian pada Tweet Bahasa Indonesia. *Jurnal Nasional Teknologi Informasi Dan Aplikasinya (JNATIA)*, 1(1), 755–762.

Wei, W. W. S. (2006). *Writing a Book on Multivariate Time Series Analysis and its Applications View project*. <https://www.researchgate.net/publication/236651810>