

**IMPLEMENTASI METODE *LONG SHORT TERM MEMORY* PADA  
PERAMALAN HARGA SAHAM BANK DIGITAL DI INDONESIA**

**(Skripsi)**

**Oleh**

**REAJENG AYU AZZAHRA**



**JURUSAN MATEMATIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG  
2025**

## **ABSTRACT**

### **IMPLEMENTATION OF THE LONG SHORT-TERM MEMORY METHOD FOR FORECASTING DIGITAL BANK STOCK PRICES IN INDONESIA**

**By**

**REAJENG AYU AZZAHRA**

The banking industry has undergone significant transformation, one of which is the development of digital banks. Not only modern consumers, but this development has also attracted the attention of stock investors, resulting in fluctuations in stock prices, which pose a challenge for investors. This issue can be handled by forecasting stock price movements based on historical data to minimize the risk of losses. This study uses the closing stock price of Bank Jago (ARTO.JK), Bank Neo (BBYB.JK) and Bank Aladin Syariah (BANK.JK) with *Long Short Term Memory* method. The evaluation model used is *Root Mean Square Error* (RMSE) and *Mean Absolute Percentage Error* (MAPE). The value of RMSE and MAPE obtained are 0.02 and 2.32% for ARTO.JK, 0.02 and 2.87% for BBYB.JK, and 0.03 and 2.84% for BANK.JK.

**Keywords:** Digital Banks, Forecasting, LSTM, RMSE, MAPE

## **ABSTRAK**

### **IMPLEMENTASI METODE *LONG SHORT TERM MEMORY* PADA PERAMALAN HARGA SAHAM BANK DIGITAL DI INDONESIA**

**Oleh**

**REAJENG AYU AZZAHRA**

Industri perbankan telah mengalami transformasi yang signifikan, salah satunya adalah perkembangan bank digital. Bukan hanya konsumen modern, perkembangan ini juga menarik perhatian para investor saham yang mengakibatkan terjadinya fluktuasi pada harga saham, sehingga menjadi tantangan bagi para investor. Permasalahan ini bisa ditangani dengan melakukan peramalan pada pergerakan harga saham berdasarkan data historis untuk meminimalisir resiko kerugian. Dalam penelitian ini menggunakan data tiga bank digital yaitu Bank Jago (ARTO.JK), Bank Neo (BBYB.JK) dan Bank Aladin Syariah (BANK.JK) dengan metode *Long Short-Term Memory*. Evaluasi model yang digunakan adalah *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Nilai RMSE dan MAPE yang diperoleh sebesar 0,02 dan 2.32% untuk data ARTO.JK, 0.02 dan 2.87% untuk data BBYB.JK, dan 0.03 dan 2.85% untuk data BANK.JK.

**Kata Kunci:** Bank digital, Peramalan, LSTM, RMSE, MAPE

**IMPLEMENTASI METODE *LONG SHORT-TERM MEMORY* PADA  
PERAMALAN HARGA SAHAM BANK DIGITAL DI INDONESIA**

Oleh

**Reajeng Ayu Azzahra**

Skripsi

Sebagai Salah Satu Syarat untuk Mencapai Gelar  
**SARJANA MATEMATIKA**

Pada

**Jurusan Matematika  
Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Lampung**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG  
2025**

Judul Skripsi : **IMPLEMENTASI METODE *LONG SHORT-TERM MEMORY* PADA PERAMALAN HARGA SAHAM BANK DIGITAK DI INDONESIA**

Nama Mahasiswa : **Reajeng Ayu Azzahra**

Nomor Pokok Mahasiswa : **1817031092**

Jurusan : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**



**MENYETUJUI**

1. **Komisi Pembimbing**

**Dr. Khoirin Nisa, M.Si.**  
NIP. 19740726 200003 2 001

**Dr. Aang Nuryaman, S.Si., M.Si.**  
NIP. 19740316 200501 1 001

2. **Ketua Jurusan Matematika**

**Dr. Aang Nuryaman, S.Si., M.Si.**  
NIP. 19740316 200501 1 001

**MENGESAHKAN**

**1. Tim Penguji**

**Ketua : Dr. Khoirin Nisa, M.Si.**

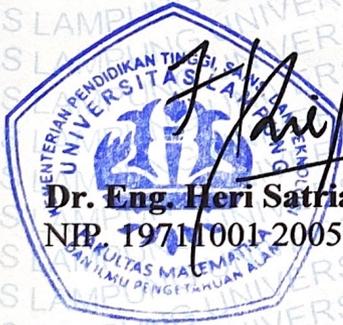
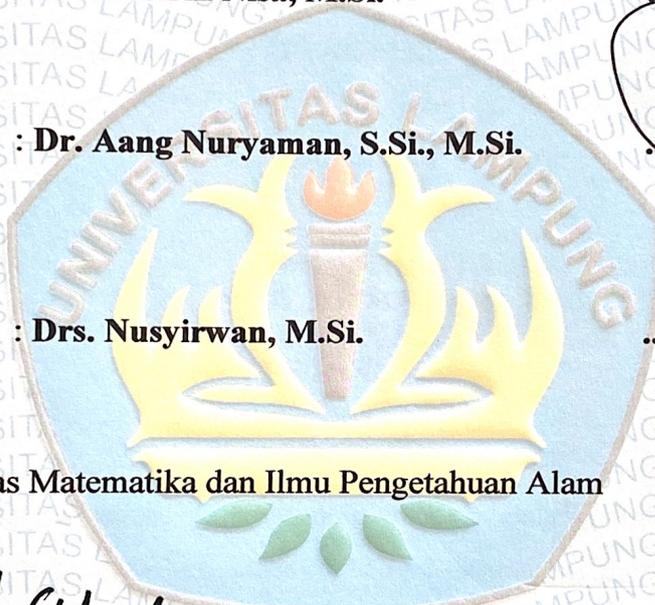
**Sekretaris : Dr. Aang Nuryaman, S.Si., M.Si.**

**Penguji  
Bukan Pembimbing : Drs. Nusyirwan, M.Si.**

**2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam**

**Dr. Eng. Heri Satria, S.Si., M.Si.**  
NIP. 19711001-200501 1 002

**Tanggal Lulus Ujian Skripsi : 31 Januari 2025**



A handwritten signature in blue ink, appearing to be "Khoirin Nisa".

A handwritten signature in black ink, appearing to be "Aang Nuryaman".

A handwritten signature in black ink, appearing to be "Nusyirwan".

## PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : **Reajeng Ayu Azzahra**

Nomor Pokok Mahasiswa : **1817031092**

Jurusan : **Matematika**

Judul Skripsi : **IMPLEMENTASI METODE *LONG SHORT-TERM MEMORY* PADA PERAMALAN HARGA SAHAM BANK DIGITAL DI INDONESIA**

Dengan ini menyatakan bahwa penelitian ini adalah hasil pekerjaan saya sendiri dan apabila kemudian hari terbukti bahwa skripsi ini merupakan salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, 12 Februari 2025

Penulis



Reajeng Ayu Azzahra

## **RIWAYAT HIDUP**

Penulis bernama Reajeng Ayu Azzahra, anak kedua dari dua bersaudara yang lahir di Bandar Lampung pada 16 Februari 2000 dari pasangan Bapak Agus Sutono dan Ibu Sri Lestari.

Penulis menyelesaikan pendidikan sekolah dasar di SD Negeri 1 Sukabumi pada tahun 2006-2012. Selanjutnya, penulis melanjutkan jenjang pendidikannya di SMP Negeri 5 Bandar Lampung pada tahun 2012-2015, dan sekolah menengah atas di SMA Negeri 5 Bandar Lampung pada tahun 2015-2018. Pada tahun 2018 penulis terdaftar sebagai mahasiswa S1 Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung melalui jalur SBMPTN.

Selama menjadi mahasiswa penulis ikut serta dalam organisasi Himpunan Mahasiswa Matematika (HIMATIKA) FMIPA UNILA bagian Biro Dana dan Usaha sebagai Anggota Pengurus periode 2019 dan Sekretaris Biro periode 2020. Pada tahun 2021, Penulis melaksanakan Kuliah Kerja Nyata (KKN) di Kelurahan Sukarame, Kota Bandar Lampung dan Kerja Praktik (KP) di Badan Pendapatan Daerah (BAPENDA) Provinsi Lampung. Selama menjadi mahasiswa, Penulis juga mengikuti Kampus Merdeka yaitu Program Magang dan Studi Independen Bersertifikat (MSIB) di CIAS dan Microsoft Indonesia.

## **KATA INSPIRASI**

*“Allah tidak akan membebani seseorang melainkan dengan kesanggupannya. ..”*  
*(Q.S. Al-Baqarah: 286)*

*“Tuhanmu tidak meninggalkan engkau dan tidak (pula) membencimu”*  
*(Q.S. Ad-Duha: 3)*

*Once this tiresome journey is over, we'll be something the world has never seen*  
*(Lee Chan)*

*Never let anyone, including yourself, belittle your dreams*  
*(Joshua Hong)*

## **PERSEMBAHAN**

Alhamdulillahirabbil'alamin.

Puji dan syukur kehadiran Allah SWT atas rahmat dan hidayah-Nya sehingga skripsi ini dapat terselesaikan dengan baik.

Dengan syukur dan bahagia penulis persembahkan rasa terimakasih ini kepada:

### **Bapak Agus Sutono dan Ibu Sri Lestari.**

Terima kasih kepada kedua orang tua saya yang telah memberikan dukungan, kasih sayang, doa, serta semangat selama ini. Terimakasih telah mempercayai saya bahwa dapat menyelesaikan pendidikan ini.

### **M. Rizky Setiawan**

Terima kasih kepada kakak saya yang selalu memberikan doa, dukungan dan memberikan semangat selama langkah ini.

### **Dosen**

Terima kasih kepada dosen pembimbing dan pembahas yang sudah sangat membantu dalam membimbing, memberikan motivasi, memberikan arahan serta ilmu yang berharga.

### **Rekan dan Sahabat**

Terima kasih kepada para sahabat yang telah memberikan banyak dukungan dan kebersamaannya. Serta para rekan yang telah kebersamai setiap langkah ini.

**Almamater Kebanggaan, Universitas Lampung**

## SANWACANA

Puji dan syukur penulis ucapkan kehadirat Allah SWT yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Implementasi Metode *Long Short Term Memory* Pada Peramalan Harga Saham Bank Digital di Indonesia”.

Penulis menyadari bahwa dalam penulisan skripsi ini tidak terlepas dari bimbingan, dukungan, bantuan dan doa dari berbagai pihak. Oleh karena itu, penulis ingin menyampaikan terimakasih kepada:

1. Ibu Dr. Khoirin Nisa, M.Si., selaku Dosen Pembimbing I yang senantiasa membimbing, memberi masukan, serta arahan kepada penulis dalam menyelesaikan skripsi ini.
2. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Pembimbing II dan Pembimbing Akademik yang telah memberikan motivasi, bimbingan arahan serta masukan kepada penulis sehingga dapat menyelesaikan skripsi ini.
3. Bapak Drs. Nusyirwan, M.Si., selaku dosen penguji yang telah memberikan kritik dan saran selama proses penyusunan skripsi ini.
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Bapak Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Seluruh dosen, staff, serta karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Bapak, Mama, Mas Kiki dan seluruh keluarga besar yang selalu mendoakan dan memberikan dukungan.
8. Sahabat-sahabat seperjuangan, Lutfia, Marisa, Putsal, Elsa, Refi, Amel, Eja, Hanifah, Martha, Riris, Joshua dan Rika yang selalu memberikan bantuan, dukungan, dan motivasi selama masa perkuliahan.

9. Sahabat-sahabat terbaikku, Octa, Lila, Verna, Sayu, Ditya, Ramadhina yang selalu memberikan dukungan, serta menemani selama menyusun skripsi ini.
10. Teman-teman Matematika 2018 atas kebersamaan selama masa perkuliahan hingga akhir.
11. Semua pihak yang telah membantu yang tidak bisa penulis sebutkan satu persatu.

Penulis menyadari masih banyak kekurangan dalam penulisan skripsi ini. Oleh karena itu, kritik dan saran sangat diharapkan agar dapat menjadi pelajaran dan perbaikan untuk kedepannya. Semoga skripsi ini dapat memberikan manfaat baik bagi penulis maupun bagi pihak yang membutuhkan.

Bandar Lampung, 12 Februari 2025  
Penulis,

Reajeng Ayu Azzahra

## DAFTAR ISI

Halaman

<b>DAFTAR GAMBAR</b> .....	<b>xiii</b>
<b>DAFTAR TABEL</b> .....	<b>xiv</b>
<b>I. PENDAHULUAN</b> .....	<b>1</b>
1.1 Latar Belakang dan Masalah .....	1
1.2 Tujuan Penelitian.....	3
1.3 Manfaat Penelitian.....	3
<b>II. TINJAUAN PUSTAKA</b> .....	<b>4</b>
2.1 Peramalan .....	4
2.2 Deret Waktu ( <i>Time Series</i> ) .....	4
2.3 Data Mining.....	5
2.4 <i>Machine Learning</i> .....	6
2.5 <i>Deep learning</i> .....	7
2.6 <i>Recurrent Neural Network</i> (RNN) .....	7
2.7 Fungsi aktivasi sigmoid.....	8
2.8 <i>Long Short-Term Memory</i> (LSTM).....	9
2.9 <i>Hyperparameter Tunning</i> .....	12
2.10 Evaluasi Model.....	12
<b>III. METODOLOGI PENELITIAN</b> .....	<b>14</b>
3.1 Waktu dan Tempat Penelitian .....	14
3.2 Data Penelitian.....	14
3.3 Metode Penelitian.....	15
<b>IV. HASIL DAN PEMBAHASAN</b> .....	<b>17</b>
4.1 Data Awal.....	17
4.2 Analisis Deskriptif.....	18

4.2.1	Statistika Deskriptif.....	18
4.2.2	Visualisasi Data.....	18
4.3	<i>Preprocessing</i> Data .....	20
4.3.1	Missing Value .....	21
4.3.2	Trasformasi Data.....	21
4.4	Pembagian Data <i>Training</i> dan Data <i>Testing</i> .....	22
4.5	Inisialisasi Parameter Model .....	23
4.6	Membangun Model .....	23
4.7	Evaluasi Model LSTM .....	25
4.8	Prediksi .....	26
4.9	Peramalan .....	30
<b>V.</b>	<b>KESIMPULAN .....</b>	<b>34</b>
	<b>DAFTAR PUSTAKA .....</b>	<b>35</b>
	<b>LAMPIRAN</b>	

## DAFTAR GAMBAR

Halaman

Gambar 1. Arsitektur <i>Recurrent Neural Network</i> .....	8
Gambar 2. Arsitektur <i>Long Short-Term Memory</i> .....	9
Gambar 3. Plot Data Historis Harga Penutupan Saham Bank Jago (ARTO.JK) .	19
Gambar 4. Plot Data Historis Harga Penutupan Saham Bank Neo (BBYB.JK)..	19
Gambar 5. Plot Data Historis Harga Saham Bank Aladin Syariah (BANK.JK)..	20
Gambar 6. Plot Prediksi dan Data Aktual ARTO.JK.....	27
Gambar 7. Plot Prediksi dan Data Aktual BBYB.JK.....	27
Gambar 8. Plot Data Prediksi dan Data Aktual BANK.JK.....	27
Gambar 9. Plot Hasil Peramalan ARTO.JK.....	32
Gambar 10. Plot Hasil Peramalan BBYB.JK.....	33
Gambar 11. Plot Hasil Peramalan BANK.JK .....	33

## DAFTAR TABEL

	Halaman
Tabel 1. Data Historis Harga Penutupan Saham Bank Digital (Rp) .....	14
Tabel 2. Data Historis Harga Penutupan Saham Bank Digital (Rp) .....	17
Tabel 3. Statistika Deskriptif.....	18
Tabel 4. Missing Value .....	21
Tabel 5. Hasil Transformasi Data .....	22
Tabel 6. Pembagian Data .....	22
Tabel 7. Inisialisasi Parameter .....	23
Tabel 8. Parameter optimal, RMSE dan MAPE berdasarkan hasil splitting data untuk skema 1 .....	23
Tabel 9. Parameter optimal, RMSE dan MAPE berdasarkan hasil splitting data untuk skema 2 .....	24
Tabel 10. Parameter optimal, RMSE dan MAPE berdasarkan hasil splitting data untuk skema 3 .....	24
Tabel 11. Parameter optimal, RMSE dan MAPE berdasarkan hasil splitting data untuk skema 4 .....	24
Tabel 12. Parameter Optimal Model LSTM .....	25
Tabel 13. Data Testing dan Data Prediksi dalam bentuk Normalisasi.....	25
Tabel 14. Data Prediksi dan Data Aktual Setelah Denormalisasi.....	26
Tabel 15. Evaluasi Model LSTM.....	28

## I. PENDAHULUAN

### 1.1 Latar Belakang dan Masalah

Industri perbankan merupakan bagian dari sektor keuangan yang sangat penting dalam ekonomi suatu negara. Industri ini telah mengalami transformasi yang sangat signifikan. Seiring dengan perkembangan globalisasi dan teknologi, industri ini terdorong membuat beberapa inovasi baru salah satunya berupa bank digital. Bank digital sangat menarik perhatian konsumen modern karena kemudahan akses dan layanan yang lebih efisien dibandingkan bank konvensional, sebab operasinya dilakukan sepenuhnya secara *online* (Sanchez dan Puyol, 2021). Perkembangan ini membuka peluang pertumbuhan, namun hal ini dapat mengakibatkan fluktuasi pada harga saham yang menciptakan ketidakstabilan di pasar saham. Fluktuasi harga saham menjadi tantangan bagi investor untuk mengambil keputusan yang tepat dalam berinvestasi. Oleh karena itu, pendekatan yang tepat sangat diperlukan untuk meminimalkan risiko. Salah satu solusi yang dapat dilakukan adalah dengan melakukan peramalan pada pergerakan harga saham berdasarkan data historis yang tersedia (Viry dan Fandi, 2022).

Peramalan merupakan proses yang digunakan untuk memprediksi nilai atau kejadian yang akan datang menggunakan variabel masa lalu. Deret waktu adalah suatu kumpulan dari observasi kuantitatif yang disusun dalam urutan kronologis. Metode deret waktu yang sering digunakan untuk melakukan peramalan ialah metode statistik seperti ARIMA dan GARCH. Namun, metode ini memiliki keterbatasan dalam menangani data yang bersifat non-linier dan kompleks

dikarenakan asumsi dari model ini bahwa deret waktu bersifat konstan dan linier (Bezzar, dkk., 2022). Maka dari itu, metode ARIMA tidak dapat digunakan untuk melakukan peramalan pada data seperti harga saham karena memungkinkan hasil yang kurang akurat.

Metode yang dapat menangani permasalahan tersebut adalah metode *machine learning*, metode ini memungkinkan untuk melakukan pembelajaran dengan lapisan yang lebih kompleks agar mendapatkan akurasi yang tinggi sehingga memberikan peramalan yang lebih akurat (Arissinta, dkk., 2022). Salah satu metodenya ialah *Recurrent Neural Network* (RNN) yang merupakan jenis jaringan yang dirancang untuk memproses data sekuensial dengan mempertahankan memori dari input sebelumnya, namun metode ini sering menghadapi masalah *vanishing gradient* yang menghambat kemampuannya dalam menangani ketergantungan jangka panjang. Untuk mengatasi masalah ini, *Long Short-Term Memory* (LSTM) dikembangkan sebagai versi lanjutan dari RNN. LSTM menggunakan struktur khusus yang disebut gerbang untuk secara selektif menyimpan atau melupakan informasi, sehingga lebih efektif dalam memproses data yang berjangka panjang seperti peramalan deret waktu.

Berdasarkan penelitian yang telah dilakukan oleh Ananda dan Kurniawan (2024) membandingkan algoritma regresi linier dan *neural network* untuk memprediksi harga saham Bank Jago, di mana hasil pengujian menunjukkan bahwa *neural network* dengan RMSE 180.745 lebih akurat dibandingkan regresi linier dengan RMSE 228.130. Rizki dan Sudianto (2022) mengenai algoritma model LSTM untuk prediksi harga komoditas pangan menghasilkan akurasi RMSE 0.79. Ni Putu Kusuma (2022) melakukan penelitian untuk prediksi harga saham *blue chip* di BEI menggunakan algoritma *neural network* metode LSTM memiliki tingkat akurasi yang tinggi yaitu dengan nilai rata-rata MAPE sebesar 2.6%.

Berdasarkan penjelasan sebelumnya, penelitian ini akan menerapkan metode LSTM pada harga saham bank digital di Indonesia yaitu Bank Jago, Bank Neo dan Bank Aladin Syariah untuk mengetahui seberapa akurat metode ini dalam melakukan prediksi untuk menghasilkan peramalan.

## **1.2 Tujuan Penelitian**

Adapun tujuan dari penelitian ini adalah:

1. Melakukan prediksi harga saham menggunakan metode LSTM untuk mendapatkan model terbaik.
2. Melakukan peramalan harga saham menggunakan model terbaik dari metode LSTM.

## **1.3 Manfaat Penelitian**

Adapun manfaat dari penelitian ini adalah:

1. Dapat memberikan pengetahuan mengenai metode LSTM.
2. Dapat menjadi bahan referensi dan pertimbangan bagi investor dalam menentukan pasar saham yang akan dipilih.

## II. TINJAUAN PUSTAKA

### 2.1 Peramalan

Peramalan merupakan teknik yang digunakan untuk memperkirakan sesuatu yang mungkin terjadi dimasa depan berdasarkan informasi pada masa yang lalu dan masa saat ini. Peramalan tidak selalu memberikan jawaban yang pasti namun berusaha mencoba memberikan jawaban yang sedekat mungkin dengan kejadiannya (kafil, 2019). Metode peramalan dikategorikan menjadi dua, yaitu metode peramalan kualitatif dan metode kuantitatif. Menurut Makridakis, dkk. (1999), metode peramalan kualitatif didasarkan pada pengetahuan dan pengalaman dari pihak yang bersangkutan, sedangkan metode peramalan kuantitatif didasarkan pada data historis bentuk numerik berdasarkan informasi di masa lalu seperti *time series*.

Berdasarkan jangka waktu, peramalan dibagi menjadi tiga kategori, yaitu:

1. Peramalan jangka pendek, yaitu peramalan yang dilakukan untuk jangka waktu kurang dari tiga bulan.
2. Peramalan jangka menengah, yaitu peramalan yang dilakukan untuk jangka waktu tiga bulan sampai tiga tahun.
3. Peramalan jangka panjang, yaitu peramalan yang dilakukan untuk jangka waktu lebih dari tiga tahun.

### 2.2 Deret Waktu (*Time Series*)

Deret waktu merupakan serangkaian pengamatan terhadap suatu peristiwa, atau kejadian yang berlangsung secara berurutan dari waktu ke waktu dengan interval yang sama. Waktu yang digunakan bisa berupa harian, bulanan maupun tahunan

(Pandji, dkk. 2019). Analisis deret waktu dapat membantu melakukan perencanaan ke depan. Oleh karena itu, untuk memilih suatu metode peramalan pada data deret waktu yang tepat harus mempertimbangkan pola data, agar metode yang digunakan dengan pola tersebut dapat diuji. Ada empat jenis pola data yaitu pola data horizontal, musiman, siklis, dan *trend*.

### 2.3 Data Mining

Data mining merupakan proses yang menggunakan teknik statistika, matematika, kecerdasan buatan dan *machine learning* untuk mengidentifikasi informasi yang bermanfaat terkait dengan *database* yang besar (Kusrini dan Emha, 2009). Secara umum, data mining yaitu proses menemukan pola menarik dari jumlah data sangat besar yang berguna sebagai acuan mengambil keputusan (Han, dkk. 2012).

Menurut Suyanto (2017), terdapat dua kelompok data mining, yaitu deskriptif dan prediktif. Deskriptif adalah data mining yang digunakan untuk menemukan pola-pola yang dapat dipahami manusia untuk menjelaskan karakteristik data, sedangkan prediktif adalah data mining yang digunakan untuk membangun model yang akan digunakan untuk melakukan prediksi.

Data mining memiliki beberapa tahapan yang digunakan untuk mendapatkan informasi dari sekumpulan data yang besar. Data *preprocessing* merupakan tahapan penting dalam data mining, dimana data asli diproses terlebih dahulu untuk menangani berbagai masalah, seperti data yang tidak konsisten, data yang hilang, data yang berulang, serta memperbaiki kesalahan pada data (han, dkk., 2012). Proses ini bertujuan untuk memastikan bahwa data yang akan dianalisis memiliki kualitas yang baik, sehingga hasil dari tahap selanjutnya akan lebih akurat. Terdapat teknik dalam data *preprocessing* yaitu data *cleaning* yang digunakan untuk menghilangkan *noise* dan memperbaiki data yang tidak konsisten. Transformasi data yaitu proses yang digunakan untuk meningkatkan akurasi dengan mengubah skala pengukuran data dari bentuk asli kedalam bentuk yang lebih

efisien sehingga dapat digunakan dalam proses data mining. Salah satunya yang sering digunakan adalah normalisasi *Min-Max*. Normalisasi *Min-Max* adalah teknik yang digunakan untuk mengatasi perbedaan nilai yang signifikan antar dataset dengan mengubah nilai data aktual ke dalam skala [0,1] tanpa menghilangkan informasi yang ada. Berikut rumus dari normalisasi *Min-Max* (Wiranda dan Sadikin, 2019):

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

dimana:

- $x'$  : Hasil transformasi data
- $x$  : Nilai yang akan ditransformasi
- $x_{min}$  : Nilai minimum pada data
- $x_{max}$  : Nilai maksimum pada data

## 2.4 Machine Learning

*Machine learning* merupakan salah satu pembelajaran mesin yang masuk ke dalam pendekatan *artificial intelligence* (Russell dan Norvig, 2016). *Machine learning* mampu mengelola data dalam jumlah yang sangat besar dengan melalui algoritma pembelajaran untuk mempresentasikan data tersebut. Ciri khas dalam *Machine learning* adalah proses pembelajaran (*training*) dan proses pelatihan (*testing*). Proses *training* ini melibatkan pembentukan *training set* yang merupakan bagian dataset yang digunakan untuk membentuk algoritma agar dapat menjalankan fungsinya. Sementara itu, proses *testing* dilakukan untuk melihat akurasi atau performa model yang telah dilatih.

*Machine Learning* memiliki dua teknik pembelajaran yaitu, *supervised learning* dan *unsupervised learning*. *Supervised learning* didasarkan pada pelatihan sample data dari sumber data dengan klasifikasi yang sudah ditugaskan. *Unsupervised learning* mengacu pada kemampuan mempelajari dan mengatur informasi tanpa memberikan *error* untuk mengevaluasi solusi. Teknik ini digunakan untuk menemukan pola tersembunyi dalam data input yang tidak memiliki label.

## 2.5 *Deep learning*

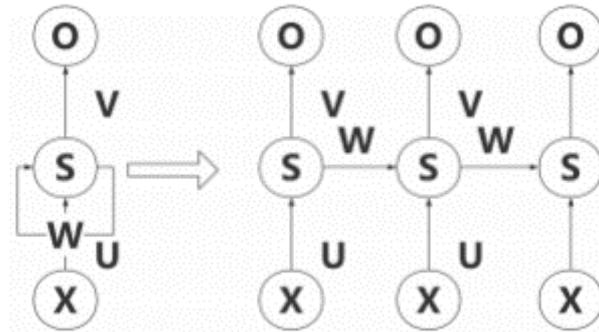
*Deep learning* merupakan cabang dari *machine learning* yang menggunakan jaringan saraf tiruan (*neural network*) dengan lapisan yang banyak untuk menganalisis data dan menghasilkan prediksi atau klasifikasi secara otomatis. Teknologi ini didasarkan pada model arsitektur yang terinspirasi oleh otak manusia, dimana lapisan-lapisan *neuron* saling terhubung dan belajar dari data yang sangat besar.

Salah satu keunggulan *deep learning* adalah kemampuan untuk melakukan pembelajaran fitur otomatis melalui lapisan-lapisan transformasi data yang semakin abstrak. Model seperti CNN dan RNN sedang digunakan secara luas dalam berbagai aplikasi, mulai dari visi komputer hingga memproses deret waktu. Semakin dalam jaringan saraf, semakin baik kemampuannya dalam menangkap pola yang kompleks dalam data.

## 2.6 *Recurrent Neural Network (RNN)*

*Recurrent Neural Network (RNN)* adalah jenis jaringan saraf berulang yang dirancang untuk memproses data sekuensial, sehingga cocok untuk mengelola data *time series*. RNN dikatakan jaringan saraf berulang karena output dari *hidden layer* sebelumnya digunakan kembali sebagai input untuk pemrosesan data berikutnya. RNN bekerja dengan mempertahankan *hidden stage* yang terus diperbarui seiring input baru diterima, sehingga memungkinkan model untuk menyimpan informasi sebelumnya. Namun, RNN sering mengalami masalah *vanishing gradient* ketika menangani ketergantungan jangka panjang.

RNN terdiri dari *input layer*, *hidden layer* dan *output layer*. Dalam melakukan suatu prediksi, tidak hanya menggunakan input satu waktu saja, melainkan juga memerlukan input dari waktu sebelumnya. Dengan demikian, input tersebut saling terhubung dan dapat memberikaan informasi ke *hidden layer* (Sen dkk, 2020).



Gambar 1. Arsitektur *Recurrent Neural Network*

(Sumber: Tian, dkk., 2018)

## 2.7 Fungsi aktivasi sigmoid

Fungsi aktivasi merupakan fungsi yang digunakan dalam jaringan saraf untuk menentukan output dari suatu *neuron* harus diaktifkan atau tidak berdasarkan input yang diterima. Terdapat dua fungsi aktivasi yang digunakan, yaitu:

1. Fungsi aktivasi *sigmoid* adalah fungsi nonlinier yang menghasilkan nilai dalam rentang 0 hingga 1. Fungsi ini memiliki persamaan sebagai berikut.

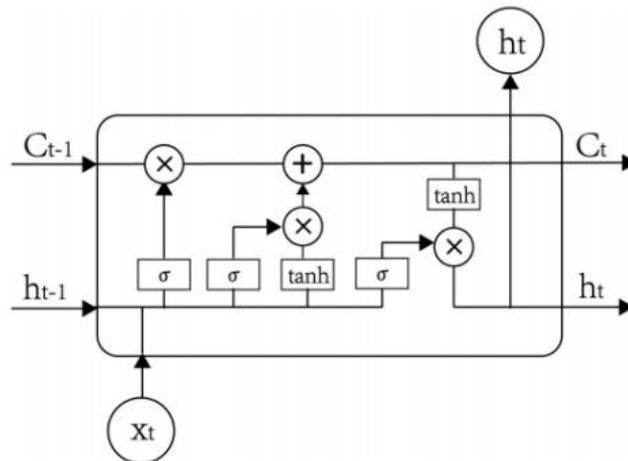
$$\sigma(x) = \frac{1}{(1 + e^{-x})} \quad (2.2)$$

2. fungsi aktivasi *tanh* merupakan fungsi alternatif dari lapisan *sigmoid* yang memiliki rentang -1 sampai 1. Fungsi ini memiliki persamaan sebagai berikut.

$$\text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.3)$$

## 2.8 Long Short-Term Memory (LSTM)

*Long Short-Term Memory* (LSTM) merupakan varian yang lebih kompleks dari RNN yang dirancang untuk mengatasi masalah *vanishing gradient* dan lebih efektif dalam menangani ketergantungan jangka panjang pada data deret waktu. LSTM dapat mengatasi permasalahan tersebut karena memiliki kemampuan untuk mengatur memori pada setiap inputnya dengan menggunakan *memory cells* dan *gate units* (Arfan dan Lusiana, 2019). LSTM mampu mempelajari data mana yang akan disimpan dan mana yang akan dibuang, karena setiap *neuron* LSTM dilengkapi dengan struktur gerbang yang mengatur sel memori dari tiap *neuron* itu sendiri. Qiu, dkk. (2020) menyatakan bahwa struktur gerbang yang mengontrol aliran informasi tersebut tersusun dari tiga gerbang, yaitu *forget gate*, *input gate* dan *output gate* dengan setiap sel memori memiliki tiga lapisan *sigmoid* dan satu lapisan *tanh*.



Gambar 2. Arsitektur *Long Short-Term Memory*  
(Sumber: Qiu, dkk. 2020)

Berikut merupakan gerbang yang ada pada satu sel LSTM.

1. *Forget gate* berfungsi menentukan informasi mana yang perlu dilupakan *cell state* dengan mengatur informasi dari *hidden state* sebelumnya akan disimpan atau dibuang menggunakan fungsi *sigmoid*. Persamaan sebagai berikut.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (2.4)$$

dimana:

- $f_t$  : *forget gate*
- $\sigma$  : fungsi *sigmoid*
- $W_f$  : bobot untuk *forget gate*
- $h_{t-1}$  : *hidden state* sebelumnya
- $x_t$  : input saat ini
- $b_f$  : bias pada *forget gate*

2. *Input gate* berfungsi untuk mengontrol dan menentukan informasi baru yang akan diperbarui dalam *cell state* dengan menggunakan fungsi aktivasi *sigmoid*. Pada langkah ini juga, vektor kandidat baru dibuat menggunakan fungsi *tanh* untuk menghasilkan nilai baru yang akan disimpan dalam *cell state*. Persamaan sebagai berikut.

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2.5)$$

dimana:

- $i_t$  : *input gate*
- $\sigma$  : fungsi *sigmoid*
- $W_i$  : bobot untuk *input gate*
- $h_{t-1}$  : *hidden state* sebelumnya
- $x_t$  : input saat ini
- $b_i$  : *bias input gate*

Persamaan kandidat baru sebagai berikut.

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (2.6)$$

dimana:

- $\tilde{C}_t$  : nilai baru yang akan ditambahkan ke *cell state*
- $\tanh$  : fungsi *tanh*
- $W_c$  : bobot untuk *cell state*
- $h_{t-1}$  : *hidden state* sebelumnya
- $x_t$  : input saat ini
- $b_c$  : *bias* untuk *cell state*

Kemudian *cell state* lama akan diperbarui menjadi *cell state* yang baru dengan persamaan sebagai berikut.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (2.7)$$

dimana:

- $C_t$  : nilai *cell state*
- $f_t$  : *forget gate*
- $C_{t-1}$  : nilai *cell state* sebelumnya
- $i_t$  : *input gate*
- $\tilde{C}_t$  : nilai baru yang ditambahkan ke *cell state*

3. *Output gate* berfungsi untuk mengontrol bagian *cell state* yang akan digunakan untuk menghitung *output* dan menjadi *hidden state* baru. Informasi dari *cell state* disaring menggunakan fungsi *sigmoid*, kemudian dikalikan dengan fungsi *tanh* dari *cell state* untuk menentukan *output* akhir dari sel LSTM. Persamaan sebagai berikut.

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (2.8)$$

dimana:

- $o_t$  : *output gate*
- $\sigma$  : fungsi *sigmoid*
- $W_o$  : bobot untuk *output gate*
- $h_{t-1}$  : *hidden state* sebelumnya
- $x_t$  : input saat ini
- $b_o$  : *bias* untuk *output gate*

Persamaan akhir nilai *output gate* sebagai berikut.

$$h_t = O_t * \tanh(C_t) \quad (2.9)$$

dimana:

- $h_t$  : *hidden state* baru
- $o_t$  : *output gate*
- $\tanh$  : fungsi *tanh*
- $C_t$  : *cell state*

## 2.9 Hyperparameter Tunning

*Hyperparameter tuning* merupakan proses menemukan parameter terbaik dalam sebuah model *machine learning* untuk meningkatkan performa model. parameter yang terdapat dalam suatu model dan telah ditentukan sebelum proses pelatihan dilakukan (Abirawa, dkk., 2017). Kombinasi parameter yang optimal akan menghasilkan model dengan performa yang baik. Kombinasi ini dapat dicari dengan menggunakan *hypertuning*, akan tetapi membutuhkan waktu yang cukup lama. Oleh karena itu, proses ini akan menggunakan *early stopping* untuk menghentikan proses pelatihan yang dilakukan pada model ketika kondisi telah terpenuhi.

Parameter yang digunakan dalam proses ini adalah Jumlah unit, *dropout*, *batch size* dan *epoch*. *Batch size* digunakan untuk menentukan berapa banyak sampel yang diproses sebelum pembaruan bobot dilakukan, serta memengaruhi stabilitas dan kecepatan pelatihan. *Epoch* digunakan untuk membantu mencegah *overfitting* dengan menonaktifkan *neuron* secara acak selama pelatihan.

## 2.10 Evaluasi Model

Evaluasi model merupakan tahap penting dalam proses pemilihan model. Pada bagian ini dilakukan evaluasi model untuk melihat tingkat akurasi dari model yang dibentuk. Ukuran ketepatan model umumnya menggunakan faktor kesalahan (*error*) yang dihitung dari selisih antara data aktual dan hasil prediksi. Untuk menilai tingkat akurasi model, maka akan digunakan ukuran *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE).

RMSE digunakan sebagai parameter untuk mengukur akurasi dan efisiensi dari setiap algoritma. Wang, dkk. (2011) menyatakan bahwa perhitungan RMSE ditujukan untuk melihat seberapa besar *error* yang dihasilkan dari suatu model prediksi yang dibuat sehingga semakin dekat nilai *error* tersebut dengan nilai

persentase 0% maka model yang dibuat akan semakin baik. Nilai RMSE dirumuskan sebagai berikut.

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^n (X_t - \hat{X}_t)^2}{n}} \quad (2.10)$$

dimana:

$X$  : nilai data aktual

$\hat{X}$  : nilai data prediksi

$n$  : jumlah data

Perhitungan untuk pemilihan model terbaik juga dapat dilakukan dengan menggunakan MAPE. Menurut Riyadi (2015), MAPE adalah rata-rata selisih antara nilai peramalan dan nilai aktual, yang dinyatakan dalam bentuk persentase dari nilai aktual. MAPE membantu mengevaluasi apakah model LSTM cukup baik atau perlu diperbaiki. Nilai MAPE yang kecil yaitu kurang dari 10% menunjukkan bahwa prediksi model mendekati nilai aktual dan model memiliki kualitas yang baik.

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{X_t - \hat{X}_t}{X_t} \right| \times 100\% \quad (2.11)$$

dimana:

$X$  : nilai data aktual

$\hat{X}$  : nilai data prediksi

$n$  : jumlah data

### III. METODOLOGI PENELITIAN

#### 3.1 Waktu dan Tempat Penelitian

Penelitian ini dilaksanakan pada semester ganjil tahun akademik 2024/2025 di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung.

#### 3.2 Data Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari *website Yahoo Finance* (<https://yahoo.finance.com/>) mengenai data historis harga saham bank digital yaitu Bank Jago (ARTO.JK), Bank Neo (BBYB.JK) dan Bank Aladin Syariah (BANK.JK). Analisis dilakukan dengan menggunakan satu variabel, yaitu harga penutupan. Data historis yang digunakan mulai dari Februari 2021 hingga Agustus 2024 dalam skala harian dengan total 867 data.

Tabel 1. Data Historis Harga Penutupan Saham Bank Digital (Rp)

Tanggal	ARTO.JK	BBYB.JK	BANK.JK
01-02-2021	5.805	307	124
02-02-2021	5.888	296	166
03-02-2021	5.785	300	224
...	...	...	...
28-08-2024	2.890	284	880
29-08-2024	2.870	278	880
30-08-2024	2.870	282	880

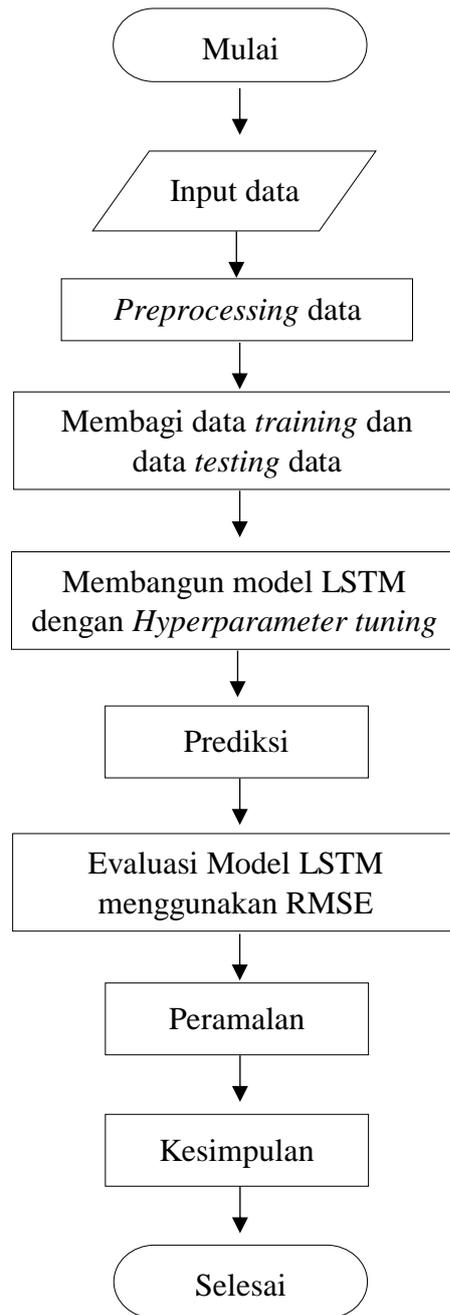
### 3.3 Metode Penelitian

Penelitian ini bertujuan membangun model LSTM terbaik dalam meramalkan harga penutupan saham, menggunakan metode *Long Short-Term Memory* (LSTM) yang dilakukan dengan bantuan *software Python* di *Google Colab*.

Berikut langkah-langkah yang dilakukan pada penelitian ini.

1. Melakukan analisis deskriptif
  1. Statistika deskriptif.
  2. Menampilkan visualisasi data
2. Melakukan *preprocessing* data
  1. Memeriksa *missing value*
  2. Melakukan transformasi data menggunakan normalisasi *Min-Max*.
3. Alternatif penyajian data *training* dan data *testing* jika menggunakan pembagian data kedalam empat skema:  
Skema 1 : 60% data *training* dan 40% data *testing*  
Skema 2 : 70% data *training* dan 30% data *testing*  
Skema 3 : 80% data *training* dan 20% data *testing*  
Skema 4 : 90% data *training* dan 10% data *testing*.
4. Melakukan analisis prediksi model LSTM menggunakan parameter optimal yang diperoleh dari *hyperparameter tuning* dan *early stopping*.
5. Melakukan prediksi data menggunakan model LSTM terbaik yang telah didapatkan.
6. Melakukan evaluasi model LSTM berdasarkan nilai RMSE dan MAPE.
7. Melakukan peramalan menggunakan model LSTM untuk 6 bulan berikutnya.

Berikut merupakan diagram alir dari proses LSTM.



Gambar 3. Diagram Alir Metode Penelitian

## V. KESIMPULAN

Berdasarkan hasil dan pembahasan, maka diperoleh kesimpulan sebagai berikut.

1. Model LSTM terbaik untuk data harga penutupan saham bank digital adalah model dari data *splitting* dengan 90% data *training* dan 10 % data *testing*, dengan parameter terbaik untuk ARTO.JK yaitu LSTM unit 64 dan *batch size* 16, BBYB.JK yaitu LSTM unit 128 dan *batch size* 16, dan BANK.JK yaitu LSTM unit 128 dan *batch size* 32, *dropout* 0.2, dan *epoch* 100.
2. Berdasarkan nilai RMSE dan MAPE yang dihasilkan dari model LSTM yakni untuk ARTO.JK sebesar 2.32% dan 0.02%, BBYB.JK sebesar 2.87% dan 0.02%, dan BANK.JK sebesar 2.84% dan 0.03%. Nilai yang dihasilkan dari ketiga data dalam model ini kurang dari 10% artinya kemampuan prediksi cukup baik. Oleh karena itu, metode LSTM dari parameter yang optimal ini bisa dimanfaatkan sebaik mungkin untuk melakukan peramalan, dikarenakan metode ini menghasilkan nilai *error* yang kecil.
3. Berdasarkan hasil peramalan yang diperoleh untuk periode September 2024 hingga Februari 2025 menunjukkan harga penutupan tiga saham bank digital mengalami naik turun yang sangat kecil atau dapat dikatakan cukup stabil.

## DAFTAR PUSTAKA

- Abirawa, H., Jondri, dan Arfianto, A. 2017. Face Recognition Using Convolution Neural Network. *E-Proceeding Engineering*. 4(3):4907-4961.
- Ananda, M.R.A., dan Kurniawan, R. 2024. Perbandingan Algoritma Regresi Linier Dengan Neural Network Untuk Memprediksi Harga Saham Bank Jago. *Jurnal Mahasiswa Teknik Informatika*. 8(2):1444.
- Arfan, A., dan Lussiana, E.T.P. 2019. Prediksi Harga Saham Di Indonesia Menggunakan Algoritma Long Short-Term Memory. *Prosiding Seminar Nasional Teknologi Informasi dan Komunikasi*, 3(1): 225–230.
- Arissinta, I.O., Sulistiyawati, I.D., dan Kurnianto, D. 2022. Pemodelan Time Series untuk Peramalan Web Traffic Menggunakan Algoritma ARIMA, LSTM, dan GRU. *Prosiding Seminar Nasional Matematika*. 693-700.
- Bezzar, N.E., Laimeche. L., Mearoumia. A., dan Houam L. 2022. Data Analysis Based Time Series Forecast for Managing Household Electricity Consumption. *Demonstratio Mathematica*. 55(1):900-921.
- Han, J., Kamber, M., dan Pei, J. 2012. *Data Mining: Concepts and Techniques*. 3rd Edition. Morgan Kaufmann Publishers, San Francisco.

- Kafil, M. 2019. Penerapan Metode K-Nearest Neighbors untuk Memprediksi Penjualan Berbasis Web pada Boutiq Dealove Bondowoso. *Jurnal Mahasiswa Teknik Informatika*. 3(2): 60-61.
- Kusrini dan Emha, T.L. 2009. *Algoritma Data Mining*. CV Andi Offset, Yogyakarta.
- Kusuma, N.P.N. 2022. Prediksi Harga Saham Blue Chip Pada Indeks IDX30 Menggunakan Algoritma Recurrent Neural Network (RNN). *Jurnal Ekonomi Dan Bisnis*. 23(1): 90-97.
- Qiu, J., Wang, B., dan Zhou, C. 2020. Forecasting Stock Prices with Long-Short Term Memory Neural Network Based on Attention Mechanism. *Advanced Design and Intelligent Computing*. 15(1).
- Riyadi, S. 2015. Aplikasi Peramalan Penjualan Obat Menggunakan Metode Pemulusan (Studi Kasus: Instalasi Farmasi RSUD Dr Murjani). *Open journal system universitas AMIKOM*. (1):1-6.
- Rizki, M.S.A. dan Sudianto. 2022. Prediksi harga komoditas pangan menggunakan algoritma long short-term memory. *Building of Informatics, Technology and Science (BITS)*. 2(4): 1137-1145.
- Russell, S. J. dan Norvig, P. 2016. *Artificial Intelligence: A Modern Approach*. Pearson Education Limited, Malaysia.
- Sanchez-Roger, M., dan Puyol-Anton, E. 2021. *Digital Bank Runs: A Deep Neural Network Approach*. London, UK.
- Sen, S., Sugiarto, D., dan Rochman, A. 2020. Komparasi Metode Multilayer Perceptron (MLP) dan Long-Short Term Memory (LSTM) dalam Peramalan Harga Beras. *Jurnal Teknik Informatika*. 11(1): 35-41.