

***RECURRENT NEURAL NETWORK (RNN) BERBASIS LONG-SHORT  
TERM MEMORY (LSTM) UNTUK PERAMALAN INFLASI DI  
INDONESIA***

**(Skripsi)**

**Oleh**

**AJENG PUJA KUSUMA**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG  
2023**

## **ABSTRACT**

### **RECURRENT NEURAL NETWORK (RNN) BASED ON LONG-SHORT TERM MEMORY (LSTM) FOR INFLATION FORECASTING IN INDONESIA**

**By**

**Ajeng Puja Kusuma**

Long-Short Term Memory (LSTM) is a development of Recurrent Neural Network (RNN) which can overcome the weakness of RNN which is unable to store information in the long term. In the LSTM, there are 3 types of gates, namely input gates, forget gates, and output gates which allow the LSTM to store information for a long time. This study aims to apply the LSTM-based RNN in forecasting inflation in Indonesia. This study uses three data sharing scenarios, namely 70% training and 30% testing, 80% training and 20% testing, and 90% training and 10% testing. The data used in this study are Indonesian inflation data from January 1980 to December 2022. The results show that the best data sharing is 90% training and 10% testing and the best parameters are 16 neurons, 0.2 dropouts, 2000 epochs, and 1000 batch sizes with RMSE value of 0.3729 and an accuracy of 96.56%. Based on the forecasting results, it was found that the inflation rate in Indonesia experienced increases and decreases or fluctuated with the highest inflation rate, namely in the April 2023 period of 0.6281 and the lowest inflation rate occurred in the August 2023 period of -0.0062.

**Keywords:** Forecasting, Recurrent Neural Network, Long-Short Term Memory, Inflation.

## ABSTRAK

### **RECURRENT NEURAL NETWORK (RNN) BERBASIS LONG-SHORT TERM MEMORY (LSTM) UNTUK PERAMALAN INFLASI DI INDONESIA**

Oleh

**Ajeng Puja Kusuma**

*Long-Short Term Memory (LSTM)* merupakan perkembangan dari *Recurrent Neural Network (RNN)* yang dapat mengatasi kelemahan dari RNN yang tidak mampu menyimpan informasi dalam jangka panjang. Dalam LSTM, terdapat 3 jenis *gate* yaitu *input gate*, *forget gate*, dan *output gate* yang memungkinkan LSTM untuk menyimpan informasi dalam jangka waktu yang lama. Penelitian ini bertujuan untuk menerapkan RNN berbasis LSTM dalam meramalkan inflasi di Indonesia. Penelitian ini menggunakan tiga skenario pembagian data yaitu 70% *training* dan 30% *testing*, 80% *training* dan 20% *testing*, serta 90% *training* dan 10% *testing*. Data yang digunakan pada penelitian ini adalah data inflasi Indonesia pada Januari 1980 sampai Desember 2022. Hasil penelitian menunjukkan bahwa pembagian data terbaik yaitu 90% *training* dan 10% *testing* dan diperoleh parameter terbaik 16 *neuron*, 0.2 *dropout*, 2000 *epoch*, dan 1000 *batch size* dengan nilai RMSE sebesar 0.3729 dan akurasi sebesar 96.56%. Berdasarkan hasil peramalan, diperoleh bahwa nilai inflasi di Indonesia mengalami kenaikan dan penurunan atau berfluktuasi dengan nilai inflasi tertinggi yaitu pada periode April 2023 sebesar 0.6281 dan nilai inflasi terendah terjadi pada periode Agustus 2023 sebesar  $-0.0062$ .

**Kata Kunci:** Peramalan, *Recurrent Neural Network*, *Long-Short Term Memory*, Inflasi.

***RECURRENT NEURAL NETWORK (RNN) BERBASIS LONG-SHORT  
TERM MEMORY (LSTM) UNTUK PERAMALAN INFLASI DI  
INDONESIA***

Oleh  
**AJENG PUJA KUSUMA**  
**1917031050**

**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  
2023**

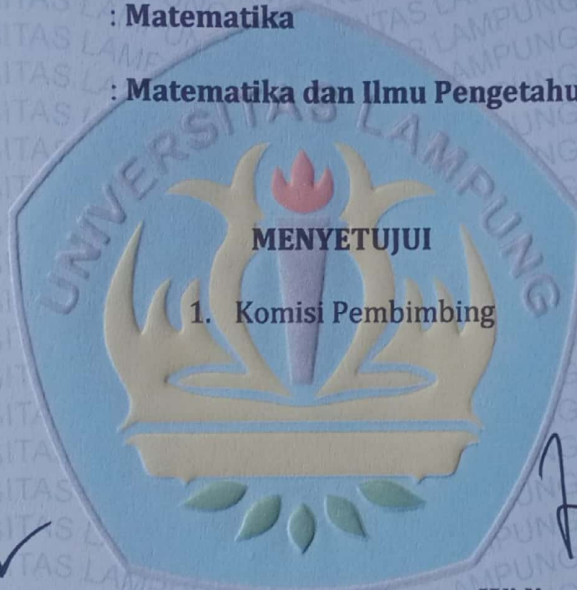
Judul : **RECURRENT NEURAL NETWORK (RNN)  
BERBASIS LONG-SHORT TERM MEMORY (LSTM)  
UNTUK PERAMALAN INFLASI DI INDONESIA**

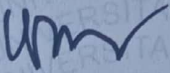
Nama : **Ajeng Puja Kusuma**

NPM : **1917031050**

Jurusan : **Matematika**


Fakultas : **Matematika dan Ilmu Pengetahuan Alam**



  
**Ir. Warsono, M.S., Ph.D.**  
NIP. 19630216 198703 1 003

  
**Widiarti, S.Si., M.Si.**  
NIP 19800502 200501 2 003

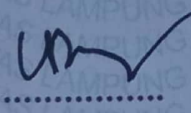
2. **Ketua Jurusan Matematika FMIPA**

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

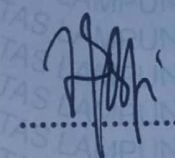
**MENGESAHKAN**

1. Tim Penguji


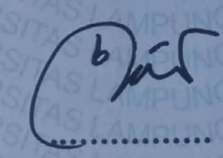
Ketua : **Ir. Warsono, M.S., Ph.D.**



Sekretaris : **Widiarti, S.Si, M.Si**



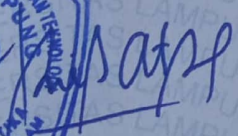
Penguji  
Bukan Pembimbing : **Drs. Eri Setiawan, M.Si.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Lampung



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



Tanggal Lulus Ujian Skripsi : **29 Mei 2023**

## PERNYATAAN SKRIPSI MAHASISWA

Saya yang bertanda tangan di bawah ini:

Nama : **Ajeng Puja Kusuma**  
Nomor Pokok Mahasiswa : **1917031050**  
Jurusan : **Matematika**  
Judul Skripsi : ***Recurrent Neural Network (RNN) Berbasis  
Long-Short Term Memory (LSTM) untuk  
Peramalan Inflasi Di Indonesia***

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri dan semua tulisan yang tertuang dalam skripsi ini telah mengikuti kaidah karya penulisan ilmiah Universitas Lampung.

Bandar Lampung, 29 Mei 2023

Penulis



**Ajeng Puja Kusuma**  
**NPM. 1917031050**

## **RIWAYAT HIDUP**

Penulis memiliki nama lengkap Ajeng Puja Kusuma, dilahirkan di Sridadi pada 15 Oktober 2001. Penulis merupakan anak kelima dari lima bersaudara dari pasangan Bapak Sugeng Prayitno dan Ibu Kunisah. Alamat tempat tinggal penulis di Desa Kalisari, Wonosobo, Tanggamus, Lampung.

Penulis menempuh pendidikan Sekolah Dasar di SDN 2 Banjar Negoro lulus pada tahun 2013. Kemudian melanjutkan ke Sekolah Menengah Pertama di SMPN 2 Wonosobo lulus pada tahun 2016. Sekolah Menengah Atas di SMAN 1 Kota Agung lulus pada tahun 2019. Pada tahun yang sama penulis terdaftar sebagai mahasiswa S1 Jurusan Matematika Fakultas Matematika dan Pengetahuan Alam Universitas Lampung melalui jalur Seleksi Bersama Masuk Perguruan Tinggi Negeri (SBMPTN).

Selama kuliah, penulis aktif menjadi anggota organisasi kampus, antara lain menjadi Sekretaris Biro Sirkulasi dan Periklanan UKMF Natural Periode 2020 dan menjadi Pemimpin Usaha UKMF Natural Periode 2021. Bulan Januari hingga Februari 2022 penulis mengikuti Kuliah Kerja Nyata (KKN) di Desa Dadisari, Kecamatan Wonosobo, Kabupaten Tanggamus. Pada bulan Juni hingga Juli 2022 penulis melaksanakan Kerja Praktik di Badan Pusat Statistik Kabupaten Tanggamus.



## **PERSEMBAHAN**

Dengan mengucapkan Alhamdulillah dan syukur kepada Allah SWT atas nikmat serta hidayah-Nya sehingga skripsi ini dapat terselesaikan dengan baik dan tepat pada waktunya. Dengan rasa syukur dan Bahagia, saya persembahkan rasa terimakasih saya kepada:

### **Ayah dan Ibuku Tercinta**

Terimakasih kepada orang tuaku atas segala pengorbanan, motivasi, doa dan ridho serta dukungannya selama ini. Terimakasih telah memberikan pelajaran berharga kepada anakmu ini tentang makna perjalanan hidup yang sebenarnya sehingga kelak bisa menjadi orang yang bermanfaat bagi banyak orang.

### **Dosen Pembimbing dan Pembahas**

Terimakasih kepada dosen pembimbing dan pembahas yang sudah sangat membantu, memberikan motivasi, memberikan arahan serta ilmu yang berharga.

### **Sahabat-sahabatku**

Terimakasih kepada semua orang-orang baik yang telah memberikan pengalaman, semangat, motivasinya, serta doa-doanya dan senantiasa memberikan dukungan dalam hal apapun.

### **Almamater Tercinta**

Universitas Lampung

## **KATA INSPIRASI**

“Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya”

**(QS. Al-Baqarah: 286)**

“Sesungguhnya Allah tidak adakan mengubah keadaan suatu kaum hingga mereka mengubah keadaan yang ada pada diri mereka sendiri”

**(QS. Ar-Ra'd: 11)**

“Sesungguhnya sesudah kesulitan itu ada kemudahan”

**(QS. Al-Insyirah: 6)**

“Balas dendam terbaik adalah menjadikan dirimu lebih baik”

**(Ali bin Abi Thalib)**

## SANWACANA

Puji syukur kehadirat Allah SWT, atas segala rahmat dan karunianya sehingga penulis dapat menyelesaikan Skripsi dengan judul “***Recurrent Neural Network (RNN) Berbasis Long-Short Term Memory (LSTM) untuk Peramalan Inflasi di Indonesia***”. Skripsi ini disusun sebagai salah satu syarat memperoleh gelar Sarjana Matematika (S.Mat) pada Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

Dalam menyelesaikan skripsi ini, penulis mendapat dukungan, bimbingan dan bantuan dari beberapa pihak. Oleh karena itu, penulis berterima kasih kepada :

1. Bapak Ir. Warsono, M.S., Ph.D. selaku dosen pembimbing utama atas kesediaan waktu, pemikiran dalam memberikan evaluasi, arahan, dan saran yang membangun dalam proses penyusunan skripsi ini.
2. Ibu Widiarti, S.Si., M.Si. selaku dosen pembimbing kedua sekaligus dosen pembimbing akademik atas kesediaan waktu, arahan, dan saran yang membangun dalam proses penyusunan skripsi ini.
3. Bapak Drs. Eri Setiawan, M.Si. selaku dosen penguji atas kesediaan waktu, saran, dan masukan yang membangun 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 civitas akademika, dosen, serta staf Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

7. Bapak, Ibu, Kakak-kakak, Andre, dan Rico beserta keluarga besar yang selalu memberikan semangat, dukungan, dan doa yang terbaik agar penulis diberikan kelancaran serta kemudahan dalam menyelesaikan skripsi ini.
8. Sahabatku Maji, Sinta, Dini, Aldi, Wiranto, dan Fazri yang selalu menyemangati, memotivasi, mendukung, serta selalu ada di waktu senang maupun sedih selama menjalani perkuliahan serta selama proses penyusunan skripsi ini.
9. Terimakasih kepada Fikri, Bang Desfan, Bang Robby, Bang Syahrul, Bang Ferzy, Sandi, Muhtarom, dan Huda yang telah mendukung dan memotivasi dalam menyelesaikan skripsi ini.
10. Teman-teman Matematika 2019 dan Abang Yunda yang telah membantu selama perkuliahan selama ini.
11. Seluruh pihak terkait yang membantu dalam menyelesaikan skripsi ini yang tidak dapat penulis sebutkan satu per satu.

Penulis menyadari skripsi ini masih jauh dari kata sempurna dan masih terdapat banyak kekurangan. Oleh sebab itu, saran dan kritikan yang membangun senantiasa penulis harapkan demi menyempurnakan skripsi ini dan semoga bermanfaat bagi pihak yang membutuhkan.

Bandar Lampung, 29 Mei 2023

Penulis

**Ajeng Puja Kusuma**

NPM. 1917031050

## DAFTAR ISI

	Halaman
<b>DAFTAR TABEL</b> .....	<b>xv</b>
<b>DAFTAR GAMBAR</b> .....	<b>xvi</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 <i>Data Mining</i> .....	5
2.3 <i>Machine Learning</i> .....	6
2.4 <i>Deep Learning</i> .....	7
2.5 Normalisasi dan Denormalisasi Data .....	8
2.6 <i>Recurrent Neural Network (RNN)</i> .....	9
2.7 Fungsi Aktivasi.....	10
2.8 <i>Long-Short Term Memory (LSTM)</i> .....	12
2.9 Evaluasi Model.....	16
2.10 Inisialisasi Parameter.....	17
2.11 Inflasi.....	17
<b>III. METODELOGI PENELITIAN</b> .....	<b>19</b>
3.1 Waktu dan Tempat Penelitian.....	19
3.2 Data Penelitian.....	19
3.3 Metode Penelitian.....	19

<b>IV. HASIL DAN PEMBAHASAN.....</b>	<b>22</b>
4.1 Proses <i>Long-Short Term Memory</i> (LSTM) .....	22
4.2 <i>Preprocessing Data</i> .....	24
4.3 Pembagian Data <i>Training</i> dan Data <i>Testing</i> .....	26
4.4 Inisialisasi Parameter Model .....	26
4.5 Membangun Model <i>Long-Short Term Memory</i> (LSTM) .....	28
4.6 Pengujian Model.....	31
4.7 Denormalisasi Data.....	33
4.8 Hasil Prediksi Model LSTM Pada Data <i>Testing</i> .....	34
4.9 Evaluasi Model LSTM .....	39
4.10 Peramalan .....	40
4.11 Evaluasi Program.....	42
<b>V. KESIMPULAN .....</b>	<b>45</b>
<b>DAFTAR PUSTAKA .....</b>	<b>46</b>
<b>LAMPIRAN.....</b>	<b>51</b>

## DAFTAR TABEL

Tabel	Halaman
1. Data Awal Inflasi Indonesia.....	23
2. Hasil Normalisasi Data.....	25
3. Kombinasi Pembagian Data.....	26
4. Parameter <i>Epoch</i> dan <i>Batch Size</i> .....	27
5. <i>Hypertuning</i> Parameter LSTM 70% <i>Training</i> dan 30% <i>Testing</i> .....	29
6. <i>Hypertuning</i> Parameter LSTM 80% <i>Training</i> dan 20% <i>Testing</i> .....	30
7. <i>Hypertuning</i> Parameter LSTM 90% <i>Training</i> dan 10% <i>Testing</i> .....	30
8. Parameter Terbaik Model <i>Long-Short Term Memory</i> .....	31
9. Perbandingan Hasil Prediksi dan Data Aktual Inflasi Indonesia .....	37
10. Perbandingan Hasil Prediksi dan Data Aktual Inflasi Indonesia .....	38
11. Perbandingan Hasil Prediksi dan Data Aktual Inflasi Indonesia .....	39
12. Evaluasi Model.....	39
13. Hasil Peramlaan.....	41

## DAFTAR GAMBAR

Gambar	Halaman
1. Arsitektur <i>Recurrent Neural Network</i> .....	9
2. Fungsi Aktivasi <i>Sigmoid</i> .....	11
3. Fungsi Aktivasi <i>Tangen Hiperbolik</i> .....	11
4. Arsitektur <i>Long-Short Term Memory</i> .....	12
5. Diagram Alir Metode LSTM .....	21
6. Plot Data Inflasi Indonesia (Januari 1980 - Desember 2022) .....	24
7. Plot Hasil Normalisasi Data Inflasi Indonesia .....	25
8. Grafik <i>Loss</i> 70% <i>Data Training</i> dan 30% <i>Data Testing</i> .....	32
9. Grafik <i>Loss</i> 80% <i>Data Training</i> dan 20% <i>Data Testing</i> .....	32
10. Grafik <i>Loss</i> 90% <i>Data Training</i> dan 10% <i>Data Testing</i> .....	33
11. Plot Hasil Prediksi dan Data Aktual Inflasi Indonesia .....	34
12. Plot Hasil Prediksi dan Data Aktual Inflasi Indonesia .....	35
13. Plot Hasil Prediksi dan Data Aktual Inflasi Indonesia .....	36
14. Plot Hasil Peramalan .....	40
15. Plot Hasil Peramalan Inflasi Indonesia .....	41
16. Grafik <i>Loss</i> Harga Minyak Mentah Dunia .....	43
17. Plot Hasil Prediksi dan Aktual Harga Minyak Mentah Dunia .....	43
18. Plot Hasil Peramalan Harga Minyak Mentah Dunia .....	44



## I. PENDAHULUAN

### 1.1 Latar Belakang dan Masalah

Peramalan adalah upaya untuk memprediksi kejadian di masa depan berdasarkan data masa lalu. Tujuannya adalah untuk menghasilkan prediksi yang akurat. Karakteristik yang harus dimiliki oleh peramalan yang baik adalah tingkat keakuratan yang tinggi dan kemampuan untuk meniru perilaku data deret waktu historis (Ruhiat & Suwanda, 2019).

Ada dua jenis metode peramalan deret waktu, yaitu metode statistik (*statistical time series*) dan metode *machine learning* atau *computational intelligence* (Putra & Hendry, 2022). Metode statistik yang umum digunakan adalah *moving average* dan *exponential smoothing*. Namun metode ini memerlukan data yang bersifat linear. Sedangkan untuk data yang bersifat *nonlinear* metode *deep learning* memiliki kemampuan lebih baik.

Salah satu algoritma yang termasuk dalam keluarga *deep learning* adalah *Recurrent Neural Network* (RNN). RNN adalah bagian dari *Artificial Neural Network* (ANN), dimana *output* dari *hidden layer* digunakan kembali sebagai *input* pada proses selanjutnya (Tian, *et al.*, 2018). Kelemahan dari metode RNN adalah tidak dapat menampung memori jangka panjang sehingga sulit mengingat informasi sebelumnya atau disebut dengan *vanishing gradient*.

Masalah *vanishing gradient* diatasi dengan menggunakan metode *Long-Short Term Memory* (LSTM). LSTM adalah algoritma yang berbasis pada deret waktu

dan efektif dalam melakukan prediksi serta dapat menyimpan informasi untuk waktu yang lama dengan menggunakan tiga jenis *gate*, yaitu *input gate*, *forget gate*, dan *output gate*. Arsitektur LSTM memiliki kompleksitas yang cukup tinggi karena menggunakan 3 *sigmoid* dan 2 *tanh* (Hastomo, dkk., 2021).

Beberapa penelitian telah menggunakan metode RNN berbasis LSTM untuk berbagai tujuan. Wiranda dan Sadikin (2019) menggunakan LSTM untuk memprediksi penjualan produk PT Metiska Farma dan menemukan bahwa model tersebut menghasilkan hasil yang paling optimal ketika data dibagi menjadi 90% untuk *training* dan 10% untuk *testing*, berdasarkan nilai RMSE dan MAPE pada data *testing*. Aldi, dkk. (2018) menggunakan LSTM untuk memprediksi harga *bitcoin* dan mendapatkan hasil terbaik dengan akurasi rata-rata 95.36% pada data *training* dan 93.5% pada data *testing*. Putra dan Hendry (2022) menggunakan *Recurrent Neural Network* dengan LSTM dan GRU untuk memprediksi penjualan *retail* dan menemukan bahwa algoritma LSTM memiliki performa yang terbaik. Penelitian lain yang pernah dilakukan menggunakan data inflasi adalah Analisa prediksi tingkat inflasi di Kota Samarinda, Kalimantan Timur dengan menggunakan metode *Backpropagation Neural Network* oleh Wong, dkk. (2019). Selain itu, Hauriza, dkk. (2021) memprediksi tingkat inflasi bulanan di Indonesia menggunakan metode Jaringan Saraf Tiruan dan mendapatkan nilai MSE yang rendah yaitu 0,026191302.

LSTM merupakan metode yang baik dalam meramalkan data deret waktu. Salah satu fenomena ekonomi yang berbentuk deret waktu adalah inflasi. Inflasi adalah kondisi dimana harga-harga secara umum terus meningkat secara berkelanjutan yang dapat disebabkan oleh berbagai faktor. Dengan kata lain, inflasi juga dapat diartikan sebagai proses penurunan nilai mata uang secara kontinu (BPS, 2009). Berdasarkan uraian diatas, pada penelitian ini akan menerapkan metode *Recurrent Neural Network* (RNN) khususnya *Long-Short Term Memory* (LSTM) untuk meramalkan nilai inflasi di Indonesia.

## 1.2 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah sebagai berikut:

1. Membentuk model peramalan berdasarkan nilai parameter terbaik dari proses *hypertuning* data inflasi di Indonesia dengan metode RNN-LSTM.
2. Mengetahui pengaruh presentase terbaik berdasarkan akurasi tertinggi dalam pembagian *training* dan *testing* dengan metode RNN-LSTM.
3. Meramalkan nilai inflasi di Indonesia menggunakan model terbaik dari metode RNN-LSTM.

## 1.3 Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah :

1. Mendapatkan model terbaik yang digunakan untuk meramalkan data inflasi di Indonesia.
2. Dapat meramalkani nilai inflasi dengan *Recurrent Neural Network* (RNN) berbasis *Long-Short Term Memory* (LSTM).

## **II. TINJAUAN PUSTAKA**

### **2.1 Peramalan**

Menurut Febrina, dkk. (2013), peramalan adalah suatu perkiraan terhadap permintaan yang akan datang berdasarkan pada beberapa variabel peramal, yaitu berdasarkan data deret waktu historis. Selain itu, menurut Lusiana & Yuliarty (2020), peramalan merupakan proses untuk menduga atau memprediksi kejadian di masa yang akan datang dengan penyusunan perencanaan terlebih dahulu. Tujuan dari peramalan adalah untuk mendapatkan prediksi yang akurat terhadap permintaan di masa yang akan datang dengan hasil prediksi yang diperoleh mendekati keadaan yang sebenarnya (Sayuti, 2014).

Terdapat dua teknik peramalan yaitu kualitatif dan kuantitatif. Menurut Purba (2015), teknik peramalan kualitatif dilakukan dengan mengandalkan pendapat orang yang terkait dengan pengambilan keputusan. Sedangkan teknik peramalan kuantitatif dilakukan dengan menggunakan berbagai metode statistik dan dapat dibagi menjadi dua jenis yaitu model deret waktu yang berdasarkan pada nilai masa lalu dari variabel yang akan diramalkan dan model kausal yang bertujuan untuk meramalkan nilai yang akan datang dari suatu variabel.

## 2.2 Data Mining

Data *mining* ialah proses yang menggunakan teknik-teknik statistik, matematika, kecerdasan buatan, dan *machine learning* untuk mendapatkan dan mengidentifikasi informasi serta pengetahuan yang bermanfaat dari berbagai database besar (Gunadi & Sensuse, 2012). Menurut Utomo & Mesran (2020), istilah lain yang terkait data *mining* adalah *Knowledge Discovery in Database* (KDD) yang memiliki arti dan tujuan yang sama dengan data *mining* yaitu memproses data yang tersedia dalam basis data untuk mendapatkan informasi baru yang bermanfaat.

Menurut Mardi (2017), proses KDD secara garis besar dapat dijelaskan sebagai berikut.

### 1. *Data Selection*

Seleksi atau pemilihan data dari sekumpulan data operasional perlu dilakukan sebelum tahap penggalian informasi dalam KDD dimulai. Data hasil seleksi yang akan digunakan untuk proses data mining disimpan dalam suatu berkas dari basis data operasional.

### 2. *Pre-processing / Cleaning*

Sebelum dilaksanakan proses data *mining*, perlu dilakukan proses *cleaning* pada data yang menjadi fokus KDD. Proses *cleaning* yaitu membuang duplikasi data, memeriksa data yang inkonsisten, dan memperbaiki kesalahan pada data seperti kesalahan cetak. Kemudian dilakukan juga proses *enrichment*, yaitu proses memperkaya data yang sudah ada dengan data atau informasi lain yang relevan dan diperlukan untuk KDD seperti data atau informasi eksternal lainnya yang diperlukan.

### 3. *Transformation*

Proses transformasi pada data yang telah dipilih sehingga data tersebut sesuai untuk proses data *mining* disebut dengan *coding*. Proses *coding* dalam KDD adalah proses kreatif dan sangat tergantung pada jenis atau pola informasi yang akan dicari dalam basis data.

#### 4. *Data Mining*

*Data mining* merujuk pada proses penggalian informasi yang bermanfaat dari data menggunakan berbagai teknik, metode, atau algoritma yang beragam. Pemilihan metode atau teknik data *mining* yang tepat harus disesuaikan dengan tujuan dan proses dari KDD yang dilakukan.

#### 5. *Interpretation / Evaluation*

*Interpretation* merupakan tahap dimana pola atau informasi yang ditemukan dalam proses data *mining* diperiksa dan dianalisis apakah sesuai dengan fakta atau hipotesis yang ada sebelumnya atau tidak. Tujuan dari interpretasi adalah untuk memastikan keakuratan dan kebenaran dari informasi yang telah ditemukan, serta untuk menjelaskan pola atau informasi tersebut secara jelas dan mudah dimengerti oleh pihak yang berkepentingan.

### 2.3 *Machine Learning*

*Machine learning* adalah bagian dari kecerdasan buatan (*artificial Intelligence*) berbentuk sistem atau algoritma yang mempunyai kemampuan untuk mengolah banyak data dan mempelajari polanya untuk membuat prediksi di masa depan berbasis matematika dan statistika komputasi (Yunardi & Dina, 2022).

Sedangkan menurut Kusuma (2020), *machine learning* merupakan algoritma yang bertujuan untuk menemukan dan mengaplikasikan pola-pola didalam data menggunakan teknik-teknik statistik dan mengonversi data tersebut dalam suatu model. *Machine learning* memiliki ciri khas yaitu adanya proses pelatihan atau *training*, sehingga dalam *machine learning* data latih (*training set*) dibutuhkan untuk proses pelatihan (Puteri & Silvanie, 2020).

Menurut Sidik & Ansawarman (2022), secara garis besar *machine learning* dibagi menjadi 2 yaitu :

1. *Supervised Learning*

Pembelajaran terarah atau *supervised learning* adalah suatu teknik dalam *machine learning* dimana proses pembelajarannya dibawah pengawasan. Menurut Roihan, dkk. (2020), metode *supervised learning* didasarkan pada kumpulan sampel data yang memiliki label. Contoh algoritma *supervised learning* yang umum digunakan adalah *neural network*.

2. *Unsupervised Learning*

Pembelajaran tidak terarah atau *unsupervised learning* adalah algoritma *machine learning* dimana proses pembelajarannya tanpa pengawasan. Jenis pembelajaran *unsupervised learning* tidak memiliki target *output* yang ditetapkan (Aditya, dkk., 2020). Oleh karena itu, diperlukan proses kategorisasi agar algoritma dapat membedakan data dengan benar.

## 2.4 *Deep Learning*

*Deep Learning* adalah cabang ilmu dari *machine learning* yang memanfaatkan jaringan saraf tiruan sebagai dasar pengolahannya (Ilahiyah & Nilogiri, 2018). Sedangkan menurut Openg, dkk. (2022) *deep learning* bertujuan untuk membuat representasi data secara bertingkat menggunakan sejumlah *layer* pengolahan data. Beberapa algoritma yang termasuk dalam *Deep learning* yaitu *Convolution Neural Network* (CNN) dan *Recurrent Neural Network* (RNN). Algoritma *deep learning* yang dapat digunakan untuk mengolah data *time series* adalah RNN.

## 2.5 Normalisasi dan Denormalisasi Data

Normalisasi data merupakan suatu proses mengubah data ke dalam bentuk yang sesuai untuk proses dalam data *mining*. Dalam penelitian ini digunakan teknik normalisasi *min-max* normalization. Teknik ini merupakan cara untuk *re-scale* data dari suatu *range* ke *range* baru. Dalam teknik ini data akan diubah menjadi rentang nilai antara 0 dan 1, sehingga data dapat diolah dengan lebih mudah dan akurat (Chamidah, dkk., 2012). *Min-max normalization* dirumuskan sebagai berikut.

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

dimana:

$x'$  : Nilai baru hasil normalisasi

$x$  : Nilai pada variabel  $x$  yang akan dinormalisasi

$x_{max}$  : Nilai maksimal variabel  $x$

$x_{min}$  : Nilai minimal variabel  $x$

Denormalisasi data adalah proses mengembalikan nilai data yang sudah ternormalisasi menjadi nilai data asli (Bode, 2017). Denormalisasi dirumuskan sebagai berikut.

$$x = x'(x_{max} - x_{min}) + x_{min} \quad (2.2)$$

dimana:

$x'$  : Nilai hasil normalisasi

$x_{max}$  : Nilai maksimal variabel  $x$

$x_{min}$  : Nilai minimal variabel  $x$




## 2.6 Recurrent Neural Network (RNN)

RNN merupakan salah satu jenis dari ANN yang dapat melihat hubungan tersembunyi pada data dalam aplikasi, seperti pengenalan suara, pemrosesan bahasa alami, dan prediksi deret waktu (Tian, *et al.*, 2018). Dalam memodelkan masalah urutan, RNN sangat baik digunakan karena dapat mengoprasikan informasi *input* serta jejak informasi yang diperoleh sebelumnya melalui koneksi berulang.

RNN dikatakan jaringan saraf berulang karena *output* dari *hidden layer* sebelumnya digunakan kembali sebagai data *input* pada pemrosesan selanjutnya (Rizal & Soraya, 2018). RNN memiliki ciri yaitu dalam melakukan prediksi yaitu tidak hanya menggunakan *input* pada satu waktu saja namun membutuhkan masukan dari *input* sebelumnya, sehingga antar *input* saling berhubungan dan dapat memberikan informasi ke *hidden layer* (Sen, dkk., 2020).

Menurut Yin, *et al.* (2017), RNN terdiri dari *input layer*, *hidden layer*, dan *output layer*. Model RNN memiliki informasi satu arah dari *input layer* ke *hidden layer*, dan sintesis informasi satu arah dari *hidden layer* sementara ke *hidden layer* saat ini. Adapun model arsitektur dari RNN adalah sebagai berikut.



Gambar 1. Arsitektur *Recurrent Neural Network*

(Sumber: Tian, *et al.*, 2018)

Seperti yang ditunjukkan pada Gambar 1 pemetaan  $S_t$  dan  $O_t$  dapat direpresentasikan sebagai berikut.

$$S_t = f(U \times X_t + W \times S_{t-1}) \quad (2.3)$$

$$O_t = g(V \times S_t) \quad (2.4)$$

dimana:

$S_t$  : Memori jaringan pada waktu ke-t  
 $U, V$ , dan  $W$  : Matriks bobot di setiap *layer*  
 $X_t$  dan  $O_t$  : *Input* dan *output* pada waktu ke-t  
 $f(\dots)$  dan  $g(\dots)$  : Fungsi nonlinear

## 2.7 Fungsi Aktivasi


Fungsi aktivasi pada jaringan saraf digunakan untuk mengaktifkan atau tidak mengaktifkan *neuron* (Julpan, dkk. 2015). Fungsi aktivasi yang sering digunakan adalah fungsi aktivasi *sigmoid* dan fungsi aktivasi *tangen hiperbolik*.

### 1. Fungsi Aktivasi *Sigmoid*

Fungsi aktivasi *sigmoid* adalah fungsi *nonlinear* yang memiliki rentang nilai antara 0 sampai 1. Fungsi *sigmoid* ditunjukkan pada persamaan berikut.

$$\sigma(x) = \frac{1}{(1 + e^{-x})} \quad (2.5)$$

Berikut merupakan grafik dari fungsi *sigmoid*.




Gambar 2. Fungsi Aktivasi *Sigmoid*

## 2. Fungsi Aktivasi *Tangen Hiperbolik*

Fungsi Aktivasi *Tangen Hiperbolik* atau disebut juga dengan fungsi *tanh* adalah fungsi alternatif dari lapisan *sigmoid*. Fungsi *tanh* memiliki *range* antara -1 sampai 1. Menurut Walid, dkk. (2018), fungsi *tanh* dirumuskan sebagai berikut.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.6)$$

Berikut merupakan grafik dari fungsi *tangen hiperbolik*.



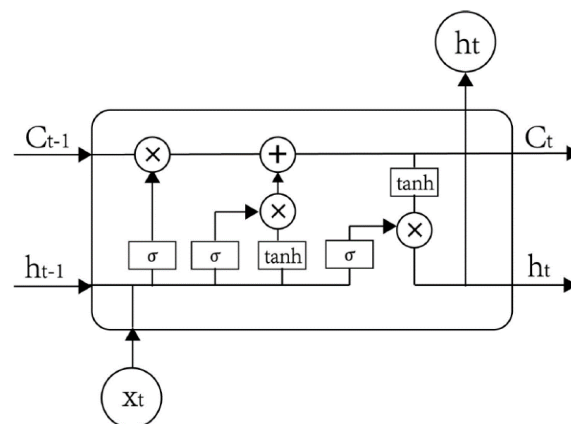
Gambar 3. Fungsi Aktivasi *Tangen Hiperbolik*

## 2.8 Long-Short Term Memory (LSTM)

LSTM pertama kali diusulkan oleh Sepp Hochreiter dan Juergen Schmidhuber pada tahun 1997. LSTM merupakan perkembangan dari model RNN untuk mengatasi masalah *vanishing gradient* saat pemrosesan data sekuensial jangka panjang (Husada & Toba, 2020). Arsitektur RNN memiliki keterbatasan dalam menangani ketergantungan jangka panjang karena tidak menyimpan informasi sebelumnya dengan baik, memori lama yang tersimpan akan semakin tidak berguna dan tertimpa dengan memori baru sehingga menyebabkan masalah gradien yang menghilang atau *vanishing gradient*. LSTM dapat mengurangi masalah ini dengan menggunakan *memory cell* untuk menyimpan informasi selama interval waktu dan menggunakan *gate units* untuk mengatur aliran informasi masuk dan keluar dari *cell* sehingga dapat mengatasi ketergantungan jangka panjang dengan lebih baik.

Menurut Qiu, *et al.* (2020), model LSTM terdiri dari serangkaian *memory cell* unik dan menggantikan neuron pada *hidden layer* dari RNN. Model LSTM melakukan penyaringan informasi melalui struktur gerbang untuk mempertahankan dan memperbaharui keadaan *memory cell*. Satu *memory cell* terdiri dari tiga *gates*, yaitu *forget gate*, *output gate*, dan *input gate*.

Struktur LSTM disajikan pada gambar sebagai berikut.



Gambar 4. Arsitektur *Long-Short Term Memory*

(Sumber: Qiu, *et al.*, 2020)

### 1. *Forget Gate*

*Forget Gate* adalah sebuah gerbang pada model LSTM yang memiliki fungsi untuk menentukan apakah informasi pada *cell state* akan dihapus atau tidak. Perhitungan ini menggunakan data *output* sebelumnya  $h_{t-1}$  dan  $x_t$  sebagai data *input*. Persamaan *forget gate* dirumuskan sebagai berikut.

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (2.7)$$

dimana:

- $f_t$  : *Forget gate*
- $\sigma$  : Fungsi *sigmoid*
- $W_f$  : Nilai *weight* untuk *forget gate*
- $h_{t-1}$  : Nilai *output* sebelum orde ke-t
- $x_t$  : Nilai *input* pada orde ke-t
- $b_f$  : Nilai bias pada *forget gate*

Nilai *weight* dirumuskan sebagai berikut.

$$W = \left( -\frac{1}{\sqrt{d}}, \frac{1}{\sqrt{d}} \right) \quad (2.8)$$

dimana:

- $W$  : *Weight*
- $d$  : Jumlah data

### 2. *Input Gate*

*Input gate* merupakan gerbang yang menggunakan dua jenis fungsi aktivasi (*sigmoid* dan *tanh*) dan bertujuan untuk memilih bagian yang akan diperbaharui. Persamaan *input gate* dirumuskan sebagai berikut.

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (2.9)$$

dimana:

- $i_t$  : *Input gate*
- $\sigma$  : Fungsi *sigmoid*
- $W_i$  : Nilai *weight* untuk *input gate*
- $h_{t-1}$  : Nilai *output* sebelum orde ke-t
- $x_t$  : Nilai *input* pada orde ke-t
- $b_i$  : Nilai bias pada *input gate*

Persamaan kandidat baru dirumuskan sebagai berikut.

$$\tilde{C}_t = \tanh(W_C * [h_{t-1}, x_t] + b_C) \quad (2. 10)$$

dimana:

- $\tilde{C}_t$  : Nilai baru yang ditambahkan ke *cell state*
- $\tanh$  : Fungsi *tangen hiperbolik*
- $W_C$  : Nilai *weight* untuk *cell state*
- $h_{t-1}$  : Nilai *output* sebelum orde ke-t
- $x_t$  : Nilai *input* pada orde ke-t
- $b_C$  : Nilai bias pada *cell state*

Setelah itu, *cell state* yang lama akan diperbaharui menjadi *cell state* yang baru dengan mengalikan *state* yang lama dengan *forget gate* ( $f_t$ ) untuk menghapus informasi yang telah ditentukan pada *forget gate* selanjutnya nilai tersebut akan ditambahkan dengan  $i_t * \tilde{C}_t$  yang merupakan nilai baru untuk memperbaharui *state*, sehingga menghasilkan persamaan *cell state* sebagai berikut.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (2. 11)$$

dimana:

- $C_t$  : *Cell state*
- $f_t$  : *Forget gate*
- $C_{t-1}$  : *Cell state* sebelum orde ke-t
- $i_t$  : *Input gate*
- $\tilde{C}_t$  : Nilai baru yang dapat ditambahkan ke *cell state*

### 3. *Output Gate*

*Output gate* berfungsi untuk menentukan informasi apa yang akan dihasilkan berdasarkan *input* dan memori blok. *Output* dari *cell state* dimasukkan ke dalam *layer tanh* kemudian dikalikan dengan *sigmoid gate* agar *output* yang dihasilkan sesuai dengan yang diputuskan sebelumnya. Persamaan *output gate* dirumuskan sebagai berikut.

$$o_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (2. 12)$$

dimana:

- $o_t$  : *Output gate*
- $\sigma$  : Fungsi *sigmoid*
- $W_o$  : Nilai *weight* untuk *output gate*
- $h_{t-1}$  : Nilai *output* sebelum orde ke-t
- $x_t$  : Nilai *input* pada orde ke-t
- $b_o$  : Nilai bias pada *output gate*

Setelah mendapatkan nilai dari *output gate* maka *cell state* ditempatkan melalui *tanh*. Kemudian dikalikan dengan *output gate* dan *sigmoid layer*. Persamaan *output* orde ke-t dirumuskan sebagai berikut.

$$h_t = o_t * \tanh(C_t) \quad (2. 13)$$

dimana:

- $h_t$  : Nilai *output* orde ke-t  
 $o_t$  : *Output gate*  
 $\tanh$  : Fungsi *tangen hiperbolik*  
 $C_t$  : *Cell state*

## 2.9 Evaluasi Model

Menurut Budiman (2016), untuk mengukur akurasi prediksi model deret waktu dapat melihat nilai *Root Mean Square Error* (RMSE).

RMSE merupakan suatu ukuran untuk menghitung selisih antara nilai prediksi dan nilai aktual. RMSE diperoleh dengan menghitung kuadrat *error* atau selisih antara nilai sebenarnya (aktual) dan nilai prediksi, jumlah tersebut kemudian dibagi dengan banyaknya waktu data peramalan dan menarik akarnya. RMSE dirumuskan sebagai berikut:

$$RMSE = \sqrt{\frac{\sum(Y_i - \hat{Y}_i)^2}{n}} \quad (2. 14)$$

dimana:

- $Y_i$  : Nilai data aktual  
 $\hat{Y}_i$  : Nilai akhir data prediksi  
 $n$  : Banyaknya data



## 2.10 Inisialisasi Parameter

Untuk membuat model yang baik, perlu dilakukan *hypertuning parameter* pada jumlah jumlah *neuron* unit dan *dropout*. *Dropout* digunakan untuk mencegah *overfitting* dan mempercepat proses *learning* (Faishol, dkk., 2020). *Overfitting* merupakan kondisi dimana hampir semua data yang telah melalui proses *training* mencapai presentase yang baik, tetapi terjadi ketidaksesuaian pada proses prediksi. *Dropout* menghilangkan sementara *neuron* yang berupa *hidden layer* yang berada dalam jaringan. Selain itu, parameter lain yang digunakan adalah *epoch* dan *batch size*. Menurut Putra, dkk. (2022), *epoch* menentukan berapa kali *neural network* melakukan proses pelatihan terhadap seluruh data. Satu *epoch* artinya ketika seluruh data sudah melalui proses pelatihan pada *neural network* sampai kembali lagi ke data awal. Satu *epoch* terlalu besar pada proses *training* karena memerlukan waktu yang cukup lama. Sehingga untuk mempercepat proses *training* dilakukan pembagian per *batch* yang disebut dengan *batch size*. *Batch size* merupakan jumlah sampel yang dimasukkan ke dalam *neural network* sebelum bobot disesuaikan.

## 2.11 Inflasi

Inflasi merupakan kondisi dimana terjadi kenaikan harga barang secara terus menerus atau inflasi juga dapat diartikan sebagai suatu keadaan perekonomian yang menunjukkan adanya kecenderungan kenaikan harga secara umum (Indriyani, 2016). Jika harga barang dan jasa meningkat, maka inflasi juga akan mengalami kenaikan. Kenaikan harga barang dan jasa tersebut menyebabkan turunnya nilai uang. Sehingga inflasi dapat juga diartikan sebagai penurunan nilai uang terhadap nilai barang dan jasa secara umum.

Menurut Badan Pusat Statistik (2009), inflasi dihitung berdasarkan Indeks Harga Konsumen (IHK) atau *Consumer price Index* (CPI). Persentase kenaikan IHK

dikenal dengan inflasi, sedangkan penurunannya disebut deflasi. Inflasi/deflasi tersebut dapat dihitung menggunakan rumus sebagai berikut:

$$INF_t = \left( \frac{IHK_t - IHK_{t-1}}{IHK_{t-1}} \right) \times 100 \quad (2. 15)$$

dimana:

$INF_t$  : Inflasi (atau deflasi) pada waktu (bulan atau tahun)  $t$

$IHK_t$  : Indeks Harga Konsumen pada waktu (bulan atau tahun)  $t$

### **III. METODELOGI PENELITIAN**

#### **3.1 Waktu dan Tempat Penelitian**

Penelitian ini dilakukan pada Semester Ganjil/Genap tahun akademik 2022/2023 dengan melakukan penelitian secara studi pustaka di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung

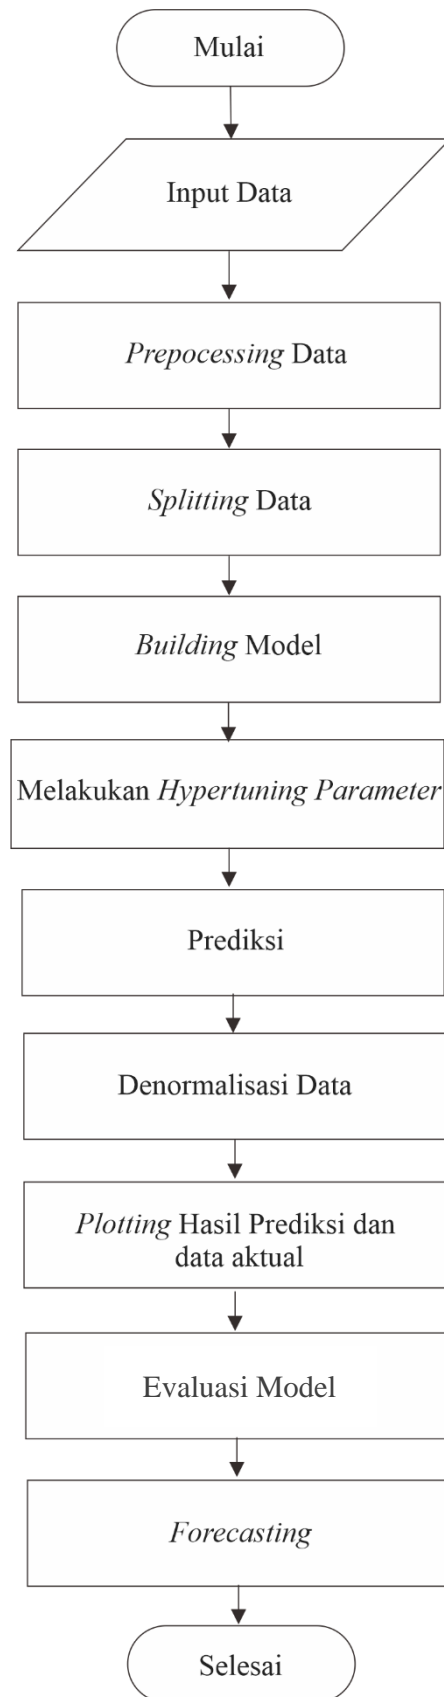
#### **3.2 Data Penelitian**

Data yang digunakan pada penelitian ini adalah data sekunder, yaitu data inflasi dalam skala bulanan di Indonesia dari Januari 1980 sampai Desember 2022 berjumlah 516 data yang diperoleh dari *website* Badan Pusat Statistik (BPS) Indonesia (<https://www.bps.go.id/site/resultTab>). Data berjumlah 516 berbentuk tabel yang memiliki kolom Periode dan Inflasi.

#### **3.3 Metode Penelitian**

Analisis pada penelitian ini akan menampilkan model terbaik LSTM untuk meramalkan Inflasi di Indonesia menggunakan metode *Recurrent Neural Network* (RNN) berbasis *Long-Short Term Memory* (LSTM) yang dilakukan dengan bantuan *software Python* yang didukung oleh *Google Colab*. Berikut adalah tahapan analisis dari penelitian ini.

1. Melakukan analisis deskriptif data dengan membuat grafik *time series* untuk melihat pola data.
2. Melakukan *preprocessing* data yaitu dengan melakukan *scaling* data atau normalisasi data.
3. Melakukan *splitting* data dengan membagi data menjadi data *training* dan data *testing*. Dalam penelitian ini terdapat 3 skenario dalam *splitting* data yaitu yang pertama data akan dibagi menjadi 70% data *training* dan 30% data *testing*, yang kedua data akan dibagi menjadi 80% data *training* dan 20% data *testing*, dan yang ketiga data akan dibagi menjadi 90% data *training* dan 10% data *testing*.
4. Melakukan *building model* RNN-LSTM dengan inisialisasi parameter-parameter yang dibutuhkan yaitu *neuron*, *dropout*, *batch size*, dan *epoch* menggunakan *hypertuning parameter*.
5. Melakukan prediksi data.
6. Melakukan proses denormalisasi data.
7. Membandingkan data hasil prediksi dan aktual dengan *plotting*.
8. Melakukan evaluasi model menggunakan RMSE.
9. Melakukan peramalan untuk nilai Inflasi di Indonesia pada bulan Januari 2023 - Desember 2023.



Gambar 5. Diagram Alir Metode LSTM.

## V. KESIMPULAN

Berdasarkan hasil analisis dan pembahasan diperoleh kesimpulan sebagai berikut.

1. Model LSTM untuk kombinasi pembagian data 70% *training* 30% *testing* dengan parameter terbaik dimana *neuron* 128, *dropout* 0.2, *epoch* 3000 dan *batch size* 1000. Untuk kombinasi pembagian data 80% *training* 20% *testing* dengan parameter terbaik dimana *neuron* 64, *dropout* 0.1, *epoch* 3000 dan *batch size* 2000. Dan untuk kombinasi pembagian data 90% *training* 10% *testing* dengan parameter terbaik dimana *neuron* 16, *dropout* 0.2, *epoch* 2000 dan *batch size* 1000.
2. Ketepatan dalam meramalkan inflasi Indonesia kombinasi pembagian data 70% *training* 30% *testing* memiliki nilai RMSE 0.5750 dan akurasi sebesar 94.18%. Kombinasi pembagian data 80% *training* 20% *testing* memiliki nilai RMSE 0.5355 dan akurasi sebesar 96.30%. Dan kombinasi pembagian data 90% *training* 10% *testing* memiliki nilai RMSE 0.3729 dan akurasi sebesar 96.56%. Sehingga kombinasi pembagian data 90% *training* 10% *testing* merupakan kombinasi pembagian data terbaik karena memiliki nilai RMSE terkecil dengan akurasi tertinggi.
3. Hasil peramalan inflasi Indonesia 12 periode kedepan yaitu Januari 2023 sampai Desember 2023 diperoleh hasil bahwa inflasi Indonesia akan mengalami kenaikan dan penurunan atau berfluktuasi dengan nilai inflasi tertinggi terjadi pada periode April 2023 sebesar 0.6281 dan nilai inflasi terendah terjadi pada periode Agustus 2023 sebesar -0.0062.

## DAFTAR PUSTAKA

- Aditya, M.A., Mulyana, R.D., Eka, I.P., & Widiyanto, S.R. 2020. Penggabungan Teknologi Untuk Analisa Data Berbasis Data Science, hlm. 51-56. Prosiding Seminar Nasional Teknologi Komputer & Sains, Bandung.
- Aldi, M.W.P., Jondri, & Aditsania, A. 2018. Analisis dan Implementasi Long Short Term Memory Neural Network untuk Prediksi Harga Bitcoin. *e-Proceeding of Engineering*. 5(2).
- Badan Pusat Statistik (BPS). 2009. *Data Strategis BPS*. Badan Pusat Statistik, Jakarta.
- Bode, A. 2017. K-Nearest Neighbor dengan Feature Selection Menggunakan Backward Elimination untuk Prediksi Harga Komoditi Kopi Arabika. *Jurnal Ilmiah*. 9(2): 188-195.
- Budiman, H. 2016. Analisis dan Perbandingan Akurasi Model Prediksi Rentet Waktu Suport Vector Machines dengan Support Vector Machines Particle Swarm Optimization untuk Arus Lalu Lintas Jangka Pendek. *SYSTEMIC*. 2(1): 19-24.
- Chamidah, N., Wiharto., Salamah, U. 2012. Pengaruh Normalisasi Data pada Jaringan Syaraf Tiruan Backpropagasi Gradient Descent Adaptive Gain (BPGDAG) untuk Klasifikasi. *Jurnal ITSMART*. 1(1): 28-33.
- Faishol, M.A., Endroyono, & Irfansyah, A.N. 2020. Prediksi Polusi Udara Perkotaan di Surabaya Menggunakan Recurrent Neural Network–Long Short Term Memory. *Jurnal Ilmiah Teknologi Informasi*. 18(2): 102-114.

- Febrina, M., Arina, F., & Ekawati, R. 2013. Peramalan Jumlah Permintaan Produksi Menggunakan Metode Jaringan Syaraf Tiruan (JST) Backpropagation. *Jurnal Teknik Industri*. **1**(2): 174-179.
- Gunadi, G., & Sensuse, D.I. 2012. Penerapan Metode Data Mining Market Basket Analysis Terhadap Data Penjualan Produk Buku dengan Menggunakan Algoritma Apriori dan Frequent Pattern Growth (FP-GROWTH) : Studi Kasus Percetakan PT. Gramedia. *Jurnal TELEMATIKA MKOM*. **4**(1): 118-132.
- Hastomo, W., Karno, A.S.B., Kalbuana, N., Nisfiani, E. & Lussiana. 2021. Optimasi Deep Learning untuk Prediksi Shaman di Masa Pandemi Covid-19. *Jurnal Edukasi dan Penelitian Informatika*. **7**(2): 133-140.
- Hauriza, B., Muladi, & Wirawan, I.M. 2021. Prediksi Tingkat Inflasi Bulanan Indonesia Menggunakan Metode Jaringan Saraf Tiruan. *Jurnal Teknologi dan Informasi*. **11**(2): 152-167.
- Husada, I.N., & Toba, H. 2020. Pengaruh Metode Penyeimbang Kelas Terhadap Tingkat Akurasi Analisis Sentimen pada Tweets Berbahasa Indonesia. *Jurnal Teknik Informatika dan Sistem Informasi*. **6**(2): 400-413.
- Ilahiyah, S., & Nilogiri, A. 2018. Implementasi Deep Learning Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network. *Jurnal Sistem & Teknologi Informasi Indonesia*. **3**(2): 49-56.
- Indriyani, S.N. 2016. Analisis Pengaruh Inflasi dan Suku Bunga Terhadap Pertumbuhan Ekonomi di Indonesia Tahun 2005-2015. *Jurnal Manajemen Bisnis Krisnadwipayana*. **4**(2).
- Julpan., Nababan, E.B., & Zarlis, M. 2015. Analisis Fungsi Aktivasi Sigmoid Biner dan Sigmoid Bipolar dalam Algoritma Backpropagation pada Prediksi Kemampuan Siswa. *Jurnal Teknovasi*. **2**(1): 103-116.
- Kusuma, P.D. 2020. *Machine Learning Teori, Program, dan Studi Kasus*. Deepublish, Yogyakarta.



- Lusiana, A., & Yuliarty, P. 2020. Penerapan Metode Peramalan (Forecasting) pada Permintaan Atap di PT X. *Jurnal Teknik ndustri ITN Malang*. **10**(1): 11-20.
- Mardi, Y. 2017. Data Mining: Klasifikasi Menggunakan Algoritma C4.5. *Jurnal Edik Informatika*. **2**(2): 213-2019.
- Openg, J.B.J.R., Endah, M.H., & Hamzah. 2022. Klasifikasi Unggas Ordo Anseriformes Berdasarkan Citra Menggunakan Metode Deep Learning dengan Algoritma Convolutional Neural Network (CNN). *Seminar Nasional Teknik Elektro, Informatika dan Sistem Informasi*. **1**(1).
- Purba, A. 2015. Perancangan Aplikasi Peramalan Jumlah Calon Mahasiswa Baru yang Mendaftar Menggunakan Metode Single Exponential Smoothing (Studi Kasus: Fakultas Agama Islam UISU). *Jurnal Riset Komputer*. **2**(6): 8-12.
- Puteri, K., & Silvanie, A. 2020. Machine Learning untuk Prediksi Harga Sembako dengan Metode Regresi Linear Berganda. *Jurnal Nasional Informatika*. **1**(2): 82-94.
- Putra, R.B.R., & Hendry. 2022. Multivariate Time Series Forecasting pada Penjualan Barang Retail dengan Recurrent Neural Network. *Jurnal Inovtek Polbeng-Seri Informatika*. **7**(1): 71-82.
- Putra, T.I.Z.M., Suprpto, Bukhori, A.F. 2022. Model Klasifikasi Berbasis Multiclass Classification dengan Kombinasi Indobert Embedding dan Long Short-Term Memory untuk Tweet Berbahasa Indonesia. *Jurnal Ilmu Siber dan Teknologi Digital*. **1**(1): 1-28.
- Qiu, J., Wang, B., & Zhou, C. 2020. Forecasting Stock Prices With Long-Short Term Memory Neural Network Based on Attention Mechanism. *PLOS ONE*. **15**(1): 1-15.
- Rizal, A.A., & Soraya, S. 2018. Multi Steps Prediction dengan Recurrent Neural Network Long Short Term Memory. *Jurnal MATRIK*. **18**(1): 115-124.

- Roihan, A., Sunarya, P.A., & Rafika, A.S. 2020. Pemanfaatan Machine Learning dalam Berbagai Bidang: Review Paper. *Indonesian Journal on Computer and Information Tecnology*. **5**(1): 75-82.
- Ruhiat, D., & Suwanda, C. 2019. Peramalan Data Deret Waktu Berpola Musiman Menggunakan Metode Regresi Spektral (Studi Kasus: Debit Sungai Citarum-Nanjung). *Jurnal Teori dan Riset Matematika*. **4**(1): 1-12.
- Sayuti, M. 2014. Aplikasi Perhitungan Metode Peramalan Produksi Pada CV. X. *Jurnal Teknovasi*. **1**(1): 35-43.
- Sen, S., Sugiarto, D., & Rochman, A. 2020. Komparasi Metode Multilayer Perception (MLP) dan Long Short Term Memory (LSTM) dalam Peramalan Harga Beras. *ULTIMATICS*. **12**(1): 35-41.
- Sidik, A.D., & Ansawarman, A. 2022. Prediksi Jumlah Kendaraan Bermotor Menggunakan Machine Learning. *Formosa Journal of Multidisciplinary Research*. **1**(3): 559-568.
- Tian, C., Ma, J., Zhang, C., & Zhan, P. 2018. A Deep Neural Network Model for Short-Term Load Forecast Based on Long Short-Term Memory Network and Convolutional Neural Network. *Energies*. **11**(12): 1-13.
- Utomo, D.P., & Mesran. 2020. Analisis Komparasi Metode Klasifikasi Data Mining dan Reduksi Atribut pada Data Set Penyakit Jantung. *Jurnal Media Informatika Budidarma*. **4**(2): 437-444.
- Walid., Sugiman., Sunarmi., & Wiyanti, D.T. 2018. Analisis Produktivitas Kinerja Dosen dan Tenaga Kependidikan dalam Mewujudkan Tahun Reputasi Universitas Negeri Semarang (UNNES) Menggunakan Jaringan Saraf Tiruan, hlm 919-927. Prosiding Seminar Nasional Matematika, Semarang.
- Wiranda, L., & Sadikin, M. 2019. Penerapan Long Short Term Memory pada Data Time Series untuk Memprediksi Penjualan Produk PT. Metiska Farma. *JANAPATI*. **8**(3): 184-196.

Wong, K., Wibawa, A.P., Pakpahan, H.S., & Prafanto, A. 2019. Prediksi Tingkat Inflasi dengan Menggunakan Metode Backpropagation Neural Network. *Sains, Aplikasi, Komputasi dan Teknologi Informasi*. **1**(2): 8-13.

Yin, C., Zhu, Y., Fei, J., & He, X. 2017. A Deep Learning Approach for Intrusion Detection Using Recurrent Neural Networks. *Ieee Access*. **5**: 21954-21961.

Yunardi, R.T., & Dina, N.Z. 2022. *Data Mining dan Machine Learning dengan Orange3 Tutorial dan Aplikasinya*. Airlangga University Press, Surabaya.