

**IMPLEMENTASI METODE *LONG SHORT TERM MEMORY* DALAM
MEMPREDIKSI SUKU BUNGA BANK INDONESIA**

SKRIPSI

Oleh:
HELMY DIANTY PUTRI
NIM. 200605110143



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

**IMPLEMENTASI METODE *LONG SHORT TERM MEMORY* DALAM
MEMPREDIKSI SUKU BUNGA BANK INDONESIA**

SKRIPSI

Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh :
HELMY DIANTY PUTRI
NIM. 200605110143

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

HALAMAN PERSETUJUAN

**IMPLEMENTASI METODE *LONG SHORT TERM MEMORY* DALAM
MEMPREDIKSI SUKU BUNGA BANK INDONESIA**

SKRIPSI

Oleh:
HELMY DIANTY PUTRI
NIM. 200605110143

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 21 Mei 2024

Pembimbing I,



Dr. Muhammad Faisal, M.T
NIP. 19740510 200501 1 007

Pembimbing II,



Prof. Dr. Suhartono, S.Si., M.Kom
NIP. 19680519 200312 1 001

Mengetahui,

Ketua Program Studi Teknik Informatika

Fakultas Sains dan Teknologi

Universitas Islam Negeri Maulana Malik Ibrahim Malang



Dr. Fachrul Kurniawan, M.MT, IPM
NIP. 19771020 200912 1 001

HALAMAN PENGESAHAN

**IMPLEMENTASI METODE *LONG SHORT TERM MEMORY* DALAM
MEMPREDIKSI SUKU BUNGA BANK INDONESIA**

SKRIPSI

Oleh:
HELMY DIANTY PUTRI
NIM. 200605110143

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 21 Mei 2024

Susunan Dewan Penguji

Ketua Penguji : Dr. Ririen Kusumawati, S.Si, M.Kom
NIP. 19720309 200501 2 002

Anggota Penguji I : Hani Nurhayati, M.T
NIP. 19780625 200801 2 006

Anggota Penguji II : Dr. Muhammad Faisal, M.T
NIP. 19740510 200501 1 007


Anggota Penguji III : Prof. Dr. Suhartono, S.Si., M.Kom
NIP. 19680519 200312 1001

()
()
()
()

Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi

Universitas Islam Negeri Maulana Malik Ibrahim Malang




Deonochrul Kurniawan, M.MT, IPM
NIP. 19771020 200912 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Helmy Dianty Putri

NIM : 200605110143

Fakultas / Jurusan : Sains dan Teknologi / Teknik Informatika

Judul Skripsi : Implementasi Metode *Long Short Term Memory* dalam
Memprediksi Suku Bunga Bank Indonesia

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut

Malang, 21 Mei 2024
Yang membuat pertanyaan



Helmy Dianty Putri
NIM. 200605110143

MOTTO

“Don't worry about other people's views or opinions about you.

It is not other people's views about you that shape you,

but your own views that shape you.”

HALAMAN PERSEMBAHAN

Skripsi ini penulis persembahkan kepada kedua orang tua tercinta penulis, Ayah Hermanto dan Ibu Hawindati, serta kakak penulis yang tersayang, Nirwana Hadi Susanto. Terimakasih atas segala bentuk pengorbanan dan dukungan baik moril ataupun materiil, serta doa yang tidak terputus dari ibu, ayah, dan kakak sehingga penulis dapat menyelesaikan perkuliahan saya selama empat tahun ini.

KATA PENGANTAR

Assalamualaikum Warahmatullahi Wabarakatuh.

Alhamdulillah, penulis hanturkan segala puji syukur kehadiran Allah Subhanahu wa Ta'ala yang telah melimpahkan rahmat serta hidayah-Nya, sehingga penulis dapat menyelesaikan studi Teknik Informatika di Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang serta menyelesaikan skripsi dengan baik. Penulis haturkan ucapan terima kasih yang sebesar-besarnya kepada semua pihak yang telah membantu penulis dalam menyelesaikan skripsi ini. Ucapan terima kasih ini penulis sampaikan kepada:

1. Prof. Dr. HM. Zainuddin MA, selaku rektor UIN Maulana Malik Ibrahim Malang
2. Prof. Dr. Sri Harini, M.Si selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Dr. Fachrul Kurniawan, M.MT., IPM selaku Ketua Program Studi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Dr. Muhammad Faisal, M.T selaku Dosen Pembimbing I dan Prof. Dr. Suhartono, S.Si, M.Kom selaku Dosen Pembimbing II, yang telah banyak memberikan arahan serta bimbingan, dalam menyelesaikan skripsi.
5. Dr. Ririen Kusumawati, S.Si, M.Kom Dosen Penguji I dan Hani Nurhayati, M.T selaku Dosen Penguji II, yang telah banyak memberikan uilmu, saran, dan arahan dalam menyelesaikan skripsi.

6. Seluruh civitas akademik Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang, terutama seluruh dosen, yang telah memberikan bimbingan dan ilmu yang bermanfaat.
7. Kedua orang tua dan kakak penulis yang selalu memberikan dukungan serta mendoakan penulis agar dapat menyelesaikan skripsi dengan baik dan tepat waktu .
8. Teman-teman INTEGER 2020 yang sama-sama sedang berjuang, terimakasih atas semangat serta dukungan dalam menyelesaikan skripsi ini.
9. RIIZE yang musiknya selalu menjadi moodbooster dan hiburan kepada penulis saat lelah.
10. Seluruh teman dan sahabat yang tidak dapat penulis tuliskan satu per satu termakasih atas segala doa, dukungan, saran, dan semangat yang diberikan selama menyusun skripsi.

Penulis menyadari bahwa dalam penyusunan skripsi ini masih terdapat kekurangan dan penulis berharap semoga skripsi ini dapat memberikan manfaat kepada pembaca termasuk penulis sendiri, *Amin Ya Rabbal Alamin*.

Waasalamu'alaikum Wr. Wb

Malang, 21 Maret 2024

Penulis

DAFTAR ISI

HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN.....	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	x
DAFTAR TABEL	xii
DAFTAR GAMBAR.....	xiii
ABSTRAK	xiv
ABSTRACT	xv
المخلص	xvi
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Pernyataan masalah	6
1.3 Tujuan Penelitian.....	6
1.4 Batasan Masalah.....	6
1.5 Manfaat Penelitian.....	7
BAB II STUDI PUSTAKA	8
2.1 Prediksi	8
2.2 Suku Bunga Bank Indonesia	8
2.3 <i>Long Short Term Memory</i>	13
2.4 Mean Squared Error (MSE)	23
2.5 <i>Mean Absolute Percentage Error</i>	24
2.6 Optimasi Adam	25
BAB III METODOLOGI PENELITIAN	27
3.1 Pengumpulan Data	27
3.2 Desain Sistem	28
3.3 <i>Preprocessing</i> Data	30
3.4 Proses <i>Training</i> LSTM.....	33
3.5 Arsitektur Jaringan	35
BAB IV UJI COBA DAN PEMBAHASAN.....	38
4.1 Skenario Uji.....	38
4.2 Hasil Uji Coba.....	40
4.2.1 Hasil Pengujian Rasio 70:30	40
4.2.2 Hasil Pengujian Rasio 80:20	42
4.2.3 Hasil Pengujian Rasio 90:10	44
4.3 Pembahasan	46
4.4 Integrasi Islam	53

BAB V KESIMPULAN DAN SARAN	57
5.1 Kesimpulan.....	57
5.2 Saran	57
DAFTAR PUSTAKA	
LAMPIRAN	

DAFTAR TABEL

Tabel 2.1 Penelitian Terdahulu yang Telah Dilakukan.....	13
Tabel 2.2 Perbandingan Penelitian Relevan Berdasarkan Metode	22
Tabel 2.3 Evaluasi Nilai MAPE.....	25
Tabel 3.1 <i>Dataset</i> Penelitian	27
Tabel 3.2 Data Sebelum Dinormalisasi.....	31
Tabel 3.3 Hasil Normalisasi	31
Tabel 4.1 Rata-rata nilai MAPE dari uji <i>neuron</i> pada rasio 70:30	40
Tabel 4.2 Rata-rata nilai MAPE dari uji <i>learning rate</i> pada rasio 70:30.....	40
Tabel 4.3 Rata-rata nilai MAPE dari uji <i>epoch</i> pada rasio 70:30	41
Tabel 4.4 Rata-rata nilai MAPE dari uji <i>batch</i> pada rasio 70:30.....	41
Tabel 4.5 Rata-rata nilai MAPE dari uji <i>neuron</i> pada rasio 80:20	42
Tabel 4.6 Rata-rata nilai MAPE dari uji <i>learning rate</i> pada rasio 80:20.....	42
Tabel 4.7 Rata-rata nilai MAPE dari uji <i>epoch</i> pada rasio 80:20	43
Tabel 4.8 Rata-rata nilai MAPE dari uji <i>batch</i> pada rasio 80:20.....	43
Tabel 4.9 Rata-rata nilai MAPE dari uji <i>neuron</i> pada rasio 90:10	44
Tabel 4.10 Rata-rata nilai MAPE dari uji <i>learning rate</i> pada rasio 90:10.....	44
Tabel 4.11 Rata-rata nilai MAPE dari uji <i>epoch</i> pada rasio 90:10	45
Tabel 4.12 Rata-rata nilai MAPE dari uji <i>batch</i> pada rasio 90:10.....	45
Tabel 4.13 Tabel hasil pengujian MAPE terendah dari masing-masing rasio.	51
Tabel 4.14 Hasil prediksi dengan kombinasi parameter terbaik	52

DAFTAR GAMBAR

Gambar 2.1 Struktur Sel LSTM.....	14
Gambar 2.2 <i>Forge gate</i> pada LSTM.....	15
Gambar 2.3 <i>Input gate</i> pada LSTM.....	16
Gambar 2.4 Memperbarui <i>Cell state</i> pada LSTM.....	18
Gambar 2.5 <i>Output gate</i> pada LSTM.....	19
Gambar 3.1 Desain Sistem.....	29
Gambar 3.2 Hasil Pengecekan Tipe Data.....	30
Gambar 3.3 <i>Source Code</i> Implementasi Normalisasi Data.....	31
Gambar 3.4 Proses Windowing.....	32
Gambar 3.5 <i>Source Code</i> Implementasi <i>Windowing</i>	32
Gambar 3.6 <i>Flowchart</i> dari Operasi LSTM.....	33
Gambar 3.7 <i>Flowchart</i> Proses <i>Training Model</i>	34
Gambar 3.8 Arsitektur Sistem Prediksi.....	36
Gambar 4.1 <i>Source Code</i> Denormalisasi.....	39
Gambar 4.2 Grafik hasil pengujian jumlah <i>neuron</i>	46
Gambar 4.3 Grafik hasil pengujian nilai <i>learning rate</i>	47
Gambar 4.4 Grafik hasil pengujian nilai <i>epoch</i>	48
Gambar 4.5 Grafik hasil pengujian jumlah <i>batch</i>	49
Gambar 4.6 Grafik hasil pengujian rasio data <i>training</i> dan <i>testing</i>	50
Gambar 4.7 Model dengan parameter terbaik.....	52

ABSTRAK

Putri, Helmy Dianty. 2024. **Implementasi Metode *Long Short Term Memory* dalam Memprediksi Suku Bunga Bank Indonesia**. Skripsi. Jurusan Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Muhammad Faisal, M.T. (II) Prof. Dr. Suhartono, S.Si, M.Kom.

Kata kunci: *Prediksi, BI Rate, Long Short Term Memory, MAPE*

Permasalahan jatuhnya harga saham berbagai perusahaan teknologi memicu kekhawatiran investor karena salah satu perusahaan teknologi terbesar Indonesia GoTo, harga sahamnya jatuh lebih dari 50% karena kenaikan suku bunga Bank Indonesia (BI Rate). Suku bunga Bank Indonesia digunakan sebagai rujukan penting kegiatan perekonomian. BI Rate akan memengaruhi perputaran keuangan perbankan, pergerakan mata uang, investasi, dan inflasi suatu negara. Oleh karena itu, dilakukan penelitian prediksi suku bunga Bank Indonesia untuk membantu dalam pengambilan keputusan keuangan yang paling menguntungkan bagi pelaku ekonomi. Metode yang digunakan dalam penelitian ini adalah *Long Short Term Memory* (LSTM), yang dipilih karena kemampuan “mengingat” dan “melupakan” informasi berdasarkan relevansinya untuk memungkinkannya menangkap pola data jangka Panjang. Data yang digunakan adalah data Jumlah Uang Beredar (JUB), Indeks Harga Saham Gabungan (IHSG) dan BI Rate yang bersumber dari website Badan Pusat Statistik (BPS), nilai tukar rupiah (kurs Dollar Amerika) yang di ambil dari situs Investing.com, serta data inflasi yang bersumber dari website Bank Indonesia. Datanya adalah data bulanan mulai Januari 2010 hingga Juni 2023. Model terbaik didapatkan dengan nilai MAPE terendah sebesar 4.760%, dengan rasio data *training* dan *testing* 80:20, *neuron* 3, *learning rate* 0.01, *epoch* 150, dan *batch size* 8.

ABSTRACT

Putri, Helmy Dianty. 2024. **Implementation of the *Long Short Term Memory Method* in Predicting Bank Indonesia Interest Rates**. Undergraduate Thesis. Informatics Engineering Study Program, Faculty of Science and Technology, State Islamic University of Maulana Malik Ibrahim Malang. Advisor. Pembimbing: (I) Dr. Muhammad Faisal, M.T. (II) Prof. Dr. Suhartono, S.Si, M.Kom.

Keywords: *Prediction, BI Rate, Long Short Term Memory, MAPE*

The problem of falling share prices of various technology companies has sparked investor concern because one of Indonesia's largest technology companies, GoTo, saw its share price fall by more than 50% due to the increase in Bank Indonesia's interest rate (*BI Rate*). Bank Indonesia interest rates are used as an important reference for economic activity. The *BI Rate* will influence banking financial turnover, currency movements, investment and inflation in a country. Therefore, Bank Indonesia interest rate prediction research was carried out to assist in making financial decisions that are most profitable for economic actors. The method used in this research is *Long Short Term Memory* (LSTM), which was chosen because of its ability to “remember” and “forget” information based on its relevance to enable it to capture long-term data patterns. The data used is data on the Money Supply (JUB), Composite Stock Price Index (IHSG) and *BI Rate* which are sourced from the website of the Central Statistics Agency (BPS), the rupiah exchange rate (US Dollar exchange rate) which is taken from the Investing.com site, as well as inflation data sourced from the Bank Indonesia website. The data is monthly data from January 2010 to June 2023. The best model was obtained with the lowest MAPE value of 4.760%, with a training and testing data Rasio of 80:20, 3 neurons, learning rate 0.01, epoch 150, and batch size 8.

الملخص

،بوتري، حلمي دياني 2024 تنفيذ طريقة الذاكرة طويلة المدى في التنبؤ بأسعار فائدة بنك إندونيسيا. قسم الهندسة المعلوماتية ،كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية، مالانج. المشرف: (أنا) د. محمد فيصل م.ت. (الثاني) البروفيسور دكتور. سوهارتونو، إس.سي، إم.كوم

الكلمات المفتاحية: التنبؤ، معدل BI، الذاكرة طويلة المدى، MAPE

أثارت مشكلة انخفاض أسعار أسهم شركات التكنولوجيا المختلفة قلق المستثمرين لأن إحدى أكبر شركات التكنولوجيا في إندونيسيا، GoTo، شهدت انخفاض سعر سهمها بأكثر من 50% بسبب الزيادة في سعر الفائدة في بنك إندونيسيا. (BI Rate) تُستخدم أسعار الفائدة لدى بنك إندونيسيا كمرجع مهم للنشاط الاقتصادي. سيؤثر معدل BI على معدل الدوران المالي المصرفي، وتحركات العملة، والاستثمار، والتضخم في بلد ما. ولذلك، تم إجراء بحث للتنبؤ بأسعار الفائدة من بنك إندونيسيا للمساعدة في اتخاذ القرارات المالية الأكثر ربحية للجهات الاقتصادية الفاعلة. الطريقة المستخدمة في هذا البحث هي الذاكرة طويلة المدى (LSTM)، والتي تم اختيارها بسبب قدرتها على "تذكر" و"نسيان" المعلومات بناءً على أهميتها لتمكينها من التقاط أنماط البيانات طويلة المدى. البيانات المستخدمة هي بيانات عن عرض النقود (JUB)، ومؤشر أسعار الأسهم المركب (IHSG) ومعدل BI التي يتم الحصول عليها من الموقع الإلكتروني لوكالة الإحصاء المركزية (BPS)، وسعر صرف الروبية (سعر صرف الدولار الأمريكي) وهو مأخوذة من موقع Investing.com، بالإضافة إلى بيانات التضخم المستمدة من موقع بنك إندونيسيا. البيانات عبارة عن بيانات شهرية من يناير 2010 إلى يونيو 2023. تم الحصول على أفضل نموذج بأقل قيمة MAPE تبلغ 4.760% مع نسبة بيانات تدريب واختبار 80:20، 3 خلايا عصبية، معدل التعلم 0.01، العصر 150، والدفعة حجم 8.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Produk Domestik Bruto (PDB) merupakan salah satu indikator penting untuk mengukur status perekonomian suatu negara pada periode tertentu. Semakin tinggi tingkat PDB maka semakin baik pula tingkat pertumbuhan ekonomi negara. Pertumbuhan ekonomi Indonesia pada tahun 2020–2022 mengalami peningkatan sebesar USD 0.23 Triliun (World Bank, 2022). Sebagaimana tercantum dalam pasal 7 Undang-Undang No. 3 Tahun 2004 tentang Bank Indonesia selaku Bank Sentral yang bertugas dalam menjaga dan mendukung stabilitas pertumbuhan ekonomi. Dalam mencapai tugasnya yaitu memelihara stabilitas perekonomian negara, Bank Indonesia menetapkan suku bunga acuan yang kemudian dikenal dengan *BI Rate* yang kemudian dijadikan tolok ukur penting kinerja perekonomian suatu negara. *BI Rate* nantinya akan memengaruhi perputaran keuangan perbankan, pergerakan mata uang, investasi, dan inflasi dalam suatu negara.

Dalam beberapa tahun terakhir, kenaikan suku bunga global telah menjadi salah satu masalah ekonomi yang paling dibahas. Bank sentral di berbagai negara, termasuk Amerika Serikat, Inggris, Eropa, dan Indonesia telah menaikkan suku bunga untuk melawan tingginya inflasi. Kenaikan suku bunga ini juga berdampak pada perekonomian Indonesia, khususnya perusahaan teknologi. Kenaikan suku bunga akan berdampak negatif pada perusahaan teknologi karena perusahaan teknologi seringkali menggunakan pinjaman untuk mendanai ekspansi dan pertumbuhan mereka. Kenaikan suku bunga akan membuat biaya pinjaman menjadi

lebih mahal, sehingga dapat menurunkan keuntungan perusahaan teknologi. Selain itu, kenaikan suku bunga akan menguatkan rupiah dan mengakibatkan perusahaan teknologi Indonesia akan kehilangan daya saing di pasar global. Fakta empiris yang menunjukkan dampak negatif dari kenaikan suku bunga acuan, yaitu jatuhnya harga saham perusahaan teknologi global di tahun 2022 hingga 2023. Bahkan, perusahaan teknologi global sekelas Meta, Alphabet, dan Netflix mengambil tindakan pemangkasan karyawan dan pengurangan biaya untuk mengantisipasi dampak negatif dari kenaikan suku bunga.

Berdasarkan data Otoritas Jasa Keuangan (OJK), saat ini terdapat 43 perusahaan teknologi yang terdaftar di Bursa Efek Indonesia (BEI). Namun kenaikan suku bunga acuan berdampak buruk pada sektor ini. Hal ini dibuktikan dengan jatuhnya harga saham berbagai perusahaan teknologi, termasuk salah satu perusahaan teknologi terbesar Indonesia, yaitu GoTo yang harga sahamnya jatuh hingga lebih dari 50% dibanding tahun sebelumnya. Penurunan drastis ini memunculkan kekhawatiran investor terhadap dampak kenaikan suku bunga acuan atau *BI Rate* terhadap kinerja perusahaan teknologi di Indonesia. Pada situasi seperti ini, memahami dan memprediksi bagaimana suku bunga acuan akan bergerak menjadi hal yang penting.

Metode LSTM merupakan perkembangan dari metode *Recurrent Neural Networks* (RNN), algoritmanya dapat dipakai dalam perhitungan data bertipe *time series*. Keunggulan utama dari LSTM adalah struktur sel memorinya yang memungkinkannya “mengingat” dan “melupakan” informasi berdasarkan relevansinya, sehingga memungkinkannya menangkap pola data jangka panjang

dengan lebih akurat daripada metode lainnya. Dengan mempertimbangkan variabel historis dan faktor lain yang dapat memengaruhi suku bunga acuan, LSTM diharapkan dapat memberikan gambaran ke depan tentang bagaimana suku bunga Bank Indonesia mungkin bergerak, sehingga membantu *stakeholder*, termasuk investor dan perusahaan teknologi di Indonesia, dalam membuat keputusan *strategis* dan bertindak dengan lebih cepat.

Al-Qur'an telah menyebutkan pentingnya perencanaan dan pengendalian, yaitu sejalan dengan firman Allah Subhanahu wa Ta'ala dalam Al-Qur'an khususnya Surah Al-Luqman Ayat 34 yang berbunyi:

انَّ اللّٰهَ عِنْدَهُ عِلْمُ السَّاعَةِ وَيُنزِلُ الْغَيْثَ وَيَعْلَمُ مَا فِي الْرَحَامِ ۗ وَمَا تَدْرِي نَفْسٌ مَّاذَا تَكْسِبُ غَدًا ۗ
وَمَا تَدْرِي نَفْسٌ بِأَيِّ أَرْضٍ تَمُوتُ ۗ إِنَّ اللّٰهَ عَلِيمٌ خَبِيرٌ

“Sesungguhnya Allah memiliki pengetahuan tentang hari kiamat, menurunkan hujan, dan mengetahui apa yang ada dalam rahim. Tidak ada seorang pun yang dapat mengetahui (dengan pasti) apa yang akan dia kerjakan besok. (Begitu pula,) tidak ada seorang pun yang dapat mengetahui di bumi mana dia akan mati. Sesungguhnya Allah Maha Mengetahui lagi Mahateliti.” (Q.S. Al Luqman: 34).

Menurut tafsir Wajiz, surah Al-Luqman ayat 34 mengungkapkan lima hal gaib yang pada dasarnya hanya diketahui oleh Allah Subhanahu wa Ta'ala. Hal gaib yang pertama yang dijelaskan adalah terkait kapan datangnya hari kiamat yang hanya diketahui oleh Allah Subhanahu wa Ta'ala. Hal gaib yang kedua adalah Allah Subhanahu wa Ta'ala saja yang dapat menentukan kapan, dimana, dan seberapa banyak hujan yang turun. Hal gaib ketiga adalah apa yang ada di dalam rahim, termasuk jenis kelaminnya, karakternya, dan sifat-sifatnya yang hanya dapat diketahui oleh Allah Subhanahu wa Ta'ala saja. Keempat, tidak ada satupun

mahluk ciptaan-Nya yang dapat mengetahui secara pasti apa yang akan terjadi atau diperolehnya esok hari. Walaupun demikian, sebagai mahluk ciptaan-Nya, manusia harus tetap berusaha. Salah satu bentuk dari "usaha" adalah menebak atau memprediksi sesuatu berdasarkan kejadian di masa lalu sesuai dengan catatan yang ada. Dan yang kelima, tidak satupun mahluk mengetahui dimana dia akan menghembuskan napas terakhirnya (Lajnah Pentashihan Mushaf Al-Qur'an, 2016). Semua itu menegaskan bahwa di balik kuasa dan pengetahuan Allah Subhanahu wa Ta'ala yang mutlak, manusia hanya bisa berusaha dan berdoa atas hasil usahanya.

Firman Allah Subhanahu wa Ta'ala dalam surat Al-Luqman Ayat 34, mengajarkan pentingnya berusaha, salah satu upayanya adalah dengan persiapan serta mengantisipasi kemungkinan perubahan di masa depan. Dari surat Al-Luqman Ayat 34 dapat dipahami bahwa pelaku ekonomi harus memperhatikan dan mempersiapkan perencanaan sebelum mengambil keputusan agar tidak mengalami kerugian ataupun penyesalan di akhir. Membantu masyarakat dalam mencegah kerugian ekonomi dapat dipandang sebagai bentuk tolong menolong sekaligus ladang mencari pahala karena hasilnya dapat digunakan oleh berbagai lapisan masyarakat, termasuk pemerintah maupun swasta, serta masyarakat umum. Hal ini sesuai dengan sabda Rosulullah shallallahu 'alaihi wa sallam dalam sebuah hadits yang diriwayatkan dalam kitab shahih muslim oleh Abu Hurairah Radhiyallahu anhu:

مَنْ نَفَسَ عَنْ مُؤْمِنٍ كُرْبَةً مِنْ كُرْبِ الدُّنْيَا ، نَفَسَ اللَّهُ عَنْهُ كُرْبَةً مِنْ كُرْبِ يَوْمِ الْقِيَامَةِ ، وَمَنْ يَسَّرَ عَلَى مُعْسِرٍ ، يَسَّرَ اللَّهُ عَلَيْهِ فِي الدُّنْيَا وَالْآخِرَةِ ، وَمَنْ سَتَرَ مُسْلِمًا ، سَتَرَهُ اللَّهُ فِي الدُّنْيَا وَالْآخِرَةِ ، وَاللَّهُ فِي عَوْنِ الْعَبْدِ مَا كَانَ الْعَبْدُ فِي عَوْنِ أَخِيهِ

“Barangsiapa yang meringankan satu kesulitan seorang mukmin yang lain dari kesulitannya di dunia, niscaya Allah akan menghilangkan darinya satu kesulitan di hari Kiamat. Barang siapa memudahkan (urusan) orang yang kesulitan, maka Allah memudahkan baginya (dari kesulitan) di dunia dan akhirat. Siapa menutupi (aib) seorang Muslim, maka Allâh akan menutup (aib)nya di dunia dan akhirat. Allah senantiasa menolong seorang hamba selama hamba tersebut menolong saudaranya” (HR Muslim)

Hadits ini mengarahkan orang-orang beriman untuk saling membantu sesama karena sesungguhnya Allah Subhanahu wa Ta'ala selalu menolong hambanya yang saling membantu antar sesama.

Penelitian yang telah dilakukan Alim et al. (2023) menunjukkan keefektifan LSTM dalam memprediksi data *time series*. Peneliti membandingkan performa LSTM dengan metode ARIMA dan RNN ketika memprediksi saham dari LQ45. Hasil penelitiannya menunjukkan bahwa akurasi LSTM lebih tinggi dibandingkan dengan akurasi ARIMA dan RNN, dengan nilai MAE, MAPE dan RMSE yang lebih baik. Selain itu, metode neural network menunjukkan proses latihan yang lebih cepat daripada ARIMA.

Beberapa kelebihan yang dimiliki algoritma LSTM membuat penulis memilih metode tersebut sebagai algoritma memprediksi suku bunga Bank Indonesia. Oleh karena itu, dilakukan penelitian dengan judul “Implementasi Metode *Long Short Term Memory* dalam Memprediksi Suku Bunga Bank Indonesia” untuk membantu dan mendukung pemangku kepentingan dalam pengambilan keputusan yang paling menguntungkan berdasarkan hasil prediksi suku bunga Bank Indonesia.

1.2 Pernyataan masalah

Berdasarkan latar belakang pembahasan yang telah diuraikan sebelumnya, maka diperoleh rumusan masalah untuk diangkat pada penelitian ini, yaitu seberapa efektif pengimplementasian metode LSTM dalam memprediksi suku bunga Bank Indonesia ditinjau dari nilai *Mean Absolute Percentage Error* (MAPE) yang diperoleh ketika menggunakan metode tersebut?

1.3 Tujuan Penelitian

Tujuan dari penelitian sesuai dengan pernyataan masalah yang diambil yaitu untuk mengukur nilai MAPE dalam pengimplementasian metode LSTM saat memprediksi suku bunga Bank Indonesia.

1.4 Batasan Masalah

Sebelum masuk ke pembahasan pokok dalam penelitian ini, perlu diketahui ruang lingkup dan batasan yang mendasari penelitian. Pemberian batasan permasalahan ini dimaksudkan untuk memberikan kejelasan dan fokus pada penelitian, sehingga tidak terjadi penyimpangan dari tujuan semula. Dengan demikian, pembaca lebih mudah memahami konteks dan ruang lingkup yang diambil peneliti. Berikut adalah batasan yang diidentifikasi pada penelitian ini:

1. Data yang digunakan untuk penelitian ini adalah data Jumlah Uang Beredar (JUB), data Indeks Harga Saham Gabungan (IHSG) dan data BI *Rate* yang bersumber dari website Badan Pusat Statistik (BPS), data nilai tukar rupiah (kurs Dollar Amerika) yang di ambil dari situs Investing.com, serta data inflasi yang bersumber dari website Bank Indonesia.

2. Data yang digunakan yaitu data bulanan yang dimulai dari Januari 2010 hingga Juni 2023.
3. Parameter yang digunakan untuk penelitian ini adalah kurs, JUB, IHSG, dan inflasi.
4. Penelitian ini mengabaikan faktor-faktor lain seperti pandemi COVID-19, perang, bencana dan lain sebagainya yang berpotensi mempengaruhi *BI Rate*.

1.5 Manfaat Penelitian

Penelitian ini diharapkan memberikan banyak manfaat yang berguna diantaranya, yaitu:

1. Memberikan pendekatan baru yang dapat dijadikan acuan oleh pelaku usaha dan investor dalam menyesuaikan *strategi* perdagangan atau investasinya.
2. Menambah wawasan pembaca terkait pengaplikasian metode LSTM dalam memprediksi *BI Rate*.
3. Hasil dari penelitian ini dapat dijadikan sebagai acuan dalam penelitian selanjutnya yang menerapkan metode *Long Short Term Memory* untuk memprediksi *BI Rate*.

BAB II

STUDI PUSTAKA

2.1 Prediksi

Prediksi adalah suatu proses yang sistematis dalam memperkirakan kemungkinan-kemungkinan yang terjadi di masa depan berdasarkan data histori masa lalu dan masa kini. Tujuannya adalah untuk meminimalisir kesalahan prediksi atas sesuatu yang benar-benar terjadi. Prediksi tidak selalu memberikan jawaban pasti terhadap peristiwa yang akan terjadi, melainkan upaya untuk menemukan jawaban yang mendekati peristiwa tersebut (Orpa et al., 2019).

Menurut Kamus Besar Bahasa Indonesia (KBBI), prediksi didefinisikan sebagai hasil atau keluaran dari kegiatan memperkirakan, meramalkan, dan memprediksikan nilai-nilai di masa depan berdasarkan data histori dari masa lalu. Prediksi merupakan upaya dalam memperkirakan kejadian di masa mendatang dengan menggunakan data yang relevan dari masa lalu (historis) yang diperoleh dengan perhitungan metode ilmiah. Prediksi akan mengeksplorasi kemungkinan apa yang terjadi di masa depan. Prediksi merupakan suatu metode peramalan yang dapat diterapkan secara kualitatif maupun kuantitatif berdasarkan proses perhitungan matematis (Sianturi et al., 2023).

2.2 Suku Bunga Bank Indonesia

BI Rate merupakan suku bunga dasar atau acuan yang nilainya ditetapkan Bank Indonesia sebagai acuan dalam sektor perbankan Indonesia. Fungsi utamanya adalah sebagai acuan suku bunga untuk mengendalikan kebijakan moneter,

khususnya terhadap inflasi (Zen Kemu α & Syahrir Ika α , 2016). Suku bunga BI yang diumumkan oleh dewan gubernur pada setiap rapat bulanan Dewan Gubernur (RDG) mencerminkan arah kebijakan moneter dan dilaksanakan melalui langkah-langkah kebijakan moneter dari Bank Indonesia, khususnya dalam pengelolaan likuiditas pasar uang untuk mencapai tujuan kebijakan moneter.

Naik atau turunnya nilai dari BI *Rate*, seringkali dipengaruhi oleh variabel inflasi. Inflasi dapat diartikan sebagai peningkatan harga barang dan jasa secara terus-menerus dalam jangka waktu tertentu dan biasanya diukur dengan perubahan nilai Indeks Harga Konsumen (IHK) pada suatu tahun dibandingkan tahun lainnya (Bank Indonesia, 2016). Inflasi berpengaruh positif terhadap keuntungan hasil pasar. Ketika inflasi meningkat, harga produksi juga meningkat, sehingga tingkat pinjaman bank akan meningkat. Hal ini mengakibatkan peningkatan jumlah uang beredar di Indonesia sehingga nilai tukar rupiah melemah. Seperti yang dijelaskan Fisher, teori kuantitas uang menunjukkan bahwa perubahan jumlah uang beredar sebanding dengan perubahan harga. Dalam konteks ini, jumlah uang beredar adalah jumlah total uang dalam perekonomian, termasuk mata uang dan giro (M1) serta uang penjualan (M2).

Nilai tukar sendiri menunjukkan perbandingan antara harga mata uang suatu negara dengan harga mata uang negara lain dan ditentukan oleh kekuatan penawaran serta permintaan di pasar valuta asing (Herania et al., 2022). Menariknya, permintaan terhadap mata uang dari suatu negara dapat mempengaruhi harga mata uang negara tersebut. Peningkatan jumlah uang beredar dapat menaikkan suku bunga dalam negeri, mendorong investasi asing dan

menurunkan permintaan mata uang dalam negeri sehingga menyebabkan devaluasi nilai tukar. Namun devaluasi nilai tukar dapat meningkatkan ekspor dan menyebabkan apresiasi mata uang sehingga dapat menyebabkan inflasi.

IHSG adalah alat ukur yang dapat menunjukkan tren dan pergerakan saham di pasar modal . IHSG dikenal juga sebagai *composite stock price index*, dapat memberikan gambaran tentang bagaimana kinerja keseluruhan saham yang terdaftar di bursa efek tertentu, sesuai dengan penjelasan dari. Harga keluaran produksi yang tinggi mengakibatkan investor lebih memilih untuk menginvestasikan modal mereka di pasar modal, sehingga harga saham jatuh yang mengakibatkan IHSG menurun. Kemudian Bank Indonesia akan menaikkan BI *Rate* sebagai respon atau tindakan dari kebijakan moneter yang diambil. Namun, ketika inflasi telah menurun maka jumlah uang yang beredar juga menurun, nilai rupiah dan ISHG akan menguat, sehingga respons kebijakan moneter Bank Indonesia adalah menurunkan nilai BI *Rate*. Dengan kata lain, beberapa faktor yang sangat penting dalam menentukan BI *Rate* adalah tingkat inflasi dan JUB, nilai tukar Rupiah atau kurs, dan IHSG.

Penelitian yang pernah dilakukan oleh Siregar (2021) terkait menganalisis tingkat inflasi di Indonesia untuk memprediksi tingkat BI *Rate*. Dalam penelitian ini digunakan metode analisis regresi linier sederhana untuk melakukan prediksi dan meramalkan perubahan nilai variabel yang diteliti. Penelitian dilakukan dengan menggunakan parameter inflasi sebagai variabel atau faktor dalam penentuan nilai suku bunga Bank Indonesia dan mengabaikan factor-faktor lain yang dapat mempengaruhi nilai suku bunga Bank Indonesia. Data yang digunakan pada

penelitian ini adalah data suku bunga Bank Indonesia dan data tingkat inflasi dari tahun 2003 hingga 2016. Dari penelitian yang dilakukan diperoleh persamaan regresi linier sederhana $Y = 4.4292 + 0.479694X$ dengan nilai korelasi sebesar 0.830618 yang berada pada rentang 0.76–1.00, dimana Y adalah variabel terikat yaitu *BI Rate* dan inflasi sebagai variabel bebas atau X. Namun, model penelitian ini memiliki kekurangan dimana adanya keterbatasan data karena penelitian ini berfokus pada data dari tahun 2003 hingga 2016 yang membuat penelitian ini menjadi kurang relevan untuk periode setelahnya. Selain itu, penelitian ini hanya menggunakan satu variabel independent yang dalam kenyataannya tingkat suku bunga bisa dipengaruhi oleh faktor lainnya.

Penelitian tentang prediksi suku bunga acuan menggunakan metode *Extreme Learning Machine* (ELM) yang bertujuan membantu dan memudahkan dalam perencanaan pengambilan keputusan oleh *stakeholder* (Putri et al., 2019). Proses yang dipakai pada penelitian ini, yaitu normalisasi data kemudian inisialisasi bobot *input* dan bias, selanjutnya dilakukan proses *training*, dan terakhir proses *testing*. Berdasarkan penelitian yang telah dilakukan, diperoleh nilai *Mean Absolute Percentage Error* 1% dengan waktu proses tercepat 0.125 detik. Penelitian dilakukan menggunakan data sebanyak 96 data dengan 50 *hidden neuron* dan fungsi aktivasi *sigmoid*.

Dalam penelitian Adli et al. (2018) menggunakan *Adaptive Neuro Fuzzy Inference System* (ANFIS) sebagai metode untuk melakukan prediksi. Proses pembelajarannya menggunakan penggabungan dua metode yaitu algoritma dari *backpropagation steepest descent* dengan algoritma *Least Square Estimator* (LSE).

Target penelitian ini adalah *BI Rate* tetapi penulis tidak memberikan detail informasi terkait pemilihan penggunaan parameter. Selain itu, jumlah data awal yang digunakan pada penelitian ini sebanyak 90 data untuk data latih dan 25 data digunakan sebagai data uji. Namun, diperoleh nilai RMSE terbaik sebesar 0.0019165 dengan menggunakan 46 data latih dan 35 data uji yang tidak disebutkan sebelumnya. Hal tersebut menimbulkan pertanyaan terkait pemilihan parameter serta kesesuaian metode pada penelitian karena adanya tidak konsistensi pembagian dalam pembagian data.

Penelitian lain dilakukan oleh Sovia et al. (2019) yang melakukan prediksi Suku Bunga Bank Indonesia dengan menggunakan fitur kurs Dolar Amerika, JUB, inflasi, dan IHK. Kemudian proses perhitungan dilakukan dengan menggunakan algoritma *backpropagation neural network* dengan arsitektur jaringan yang digunakan terdiri dari 4 lapisan *input*, 2 lapisan tersembunyi, dan 1 lapisan keluaran serta target yang diinginkan adalah angka suku bunga. Berdasarkan penelitian yang dilakukan diperoleh nilai akurasi rata-rata sebesar 99.73%.

Penelitian terdahulu memiliki peranan penting dalam pengembangan ilmu pengetahuan. Untuk memperoleh pemahaman yang lebih mendalam mengenai topik penelitian, maka penting untuk mengetahui dan menganalisis penelitian yang telah dilakukan sebelumnya. Oleh karena itu, dalam tabel 2.1 peneliti menyajikan perbandingan penelitian *BI Rate* sebelumnya yang pernah dilakukan dengan penelitian saat ini.

Tabel 2.1 Penelitian Terdahulu yang Telah Dilakukan

No	Peneliti	Objek	Metode	Input	Hasil
1	Siregar (2021)	Analisis hubungan dan prediksi BI Rate dengan inflasi	<i>Simple Linear Regression Analysis</i>	Inflasi	Persamaan regresi linier sederhana $Y = 4.4292 + 0.479694X$ dengan nilai korelasi sebesar 0,830618
2	Putri et al. (2019)	Prediksi Suku Bunga Acuan	<i>Extreme Learning Machine (ELM)</i>	Inflasi, jumlah uang beredar, dan nilai tukar rupiah	MAPE sebesar 1% dengan waktu 1,125 detik
3	Sovia et al. (2019)	Prediksi pergerakan BI Rate	<i>Backpropagation Neural Network</i>	Inflasi, jumlah uang beredar, nilai tukar rupiah, dan indeks harga saham gabungan	Akurasi rata-rata sebesar 99,73% dari arsitektur 4-2-1
4	Adli et al. (2018)	Prediksi BI Rate	<i>Adaptive Neuro Fuzzy Inference System (ANFIS)</i>	Ekonomi makro(tidak dijelaskan detailnya), <i>learning rate</i> , <i>minimum error</i> dan jumlah iterasi maksimal	RMSE = 0.0019165 dengan 46 data latih dan 35 data uji
5	Penelitian ini	Prediksi BI Rate	<i>Long Short Term Memory</i>	Inflasi, jumlah uang beredar, nilai tukar rupiah, dan indeks harga saham gabungan	Nilai MAPE dari pengimplementasian metode LSTM saat memprediksi suku bunga Bank Indonesia


Pada tabel 2.1 terkait membandingkan penelitian dengan menggunakan objek berupa BI Rate, terlihat bahwa keterbaruan penelitian (novelty) dari penelitian ini terletak pada metode yang digunakan yaitu *Long Short Term Memory*.

2.3 Long Short Term Memory

Long Short Term Memory merupakan variasi khusus dari algoritma RNN yang dirancang dengan kemampuan mempelajari keterkaitan dalam jangka waktu panjang. Dibandingkan dengan RNN konvensional, LSTM akan lebih mampu

menangani masalah keterkaitan pada jangka waktu yang panjang karena memiliki mekanisme internal yang memungkinkan informasi disimpan dalam jangka waktu yang panjang.

Meskipun, LSTM dan RNN memiliki struktur sama yaitu seperti rantai tetapi keduanya memiliki perbedaan dalam modul berulangnya. Jika RNN konvensional umumnya memiliki modul berulang dengan konfigurasi sederhana, seperti lapisan *tanh*, LSTM menawarkan pendekatan yang lebih kompleks. Pada LSTM, perulangan modulnya terdiri dari empat lapisan jaringan saraf yang berfungsi berbeda dari RNN konvensional.




Gambar 2.1 Struktur Sel LSTM
Sumber: Olah (2015)

Pada Gambar 2.1, setiap jalur mewakili vektor transmisi lengkap dari *output* suatu *node* ke *input node* lainnya. Operasi *pointwise* diwakili oleh lingkaran berwarna merah jambu, contoh operasinya yaitu penambahan vektor. Sedangkan kotak berwarna kuning mewakili lapisan atau *layer* dari jaringan syaraf tiruan yang memiliki kemampuan pembelajaran. Kemudian garis gabungan menunjukkan bahwa vektor-vektor tersebut telah digabungkan (*concatenation*). Adapun garis yang terbelah atau bercabang menunjukkan bahwa informasi pada aliran tersebut telah disalin kemudian dipindahkan ke berbagai tempat (Olah, 2015). Komponen utama

dari algoritma LSTM adalah *cell state* yang dapat dilihat sebagai garis horizontal yang melintasi bagian atas diagram. Fungsi *cell state* mirip dengan jalur transportasi (*conveyor belt*). Dia melewati seluruh struktur jaringan dengan interaksi linier yang sedikit. Hal ini memungkinkan informasi untuk bergerak sepanjang jalur dengan sedikit perubahan.

LSTM dilengkapi dengan mekanisme untuk penambahan atau penghapusan informasi pada *cell state*, yang dikelola secara teliti oleh entitas yang dikenal dengan sebutan *gates*. Struktur ini dibentuk oleh lapisan jaringan saraf dengan fungsi aktivasi dan operasi *pointwise*. Berikut adalah proses yang terjadi pada LSTM

- a. Memutuskan informasi mana yang akan dihapus atau dilupakan dari *cell state*



Gambar 2.2 *Forget gate* pada LSTM
Sumber: Olah (2015)

Gambar 2.2 mengilustrasikan proses dari *forget gate*, yang bertanggung jawab dalam menentukan informasi mana saja dari *cell state* sebelumnya (C_{t-1}) yang harus dilupakan. Garis h_{t-1} dan x_t menggambarkan *inputan* yang diterima *forget gate* Dimana x_t sebagai *inputan* saat ini dan h_{t-1} sebagai *hidden state* sebelumnya. Kedua *input* tersebut digabungkan menjadi satu. Penggabungannya


digambarkan dengan dua garis *input* yang bergabung menjadi satu garis. Kemudian *input* masuk ke kotak berwarna kuning dengan simbol σ di dalamnya, kotak tersebut menunjukkan adanya proses dari fungsi aktivasi sigmoid dengan *output* nilai antara 0 dan 1, yang disebut sebagai (f_t), nilai 1 berarti menyimpan memori, sedangkan nilai 0 berarti menghapus memori. Adapun rumus yang digunakan untuk *forget gate* dapat dilihat pada persamaan (2.1).

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.1)$$

Keterangan:

- f_t = *forget gate*
- σ = *sigmoid function*
- W_f = bobot pada *forget gate*
- h_{t-1} = hasil *output* pada *time step t-1*
- x_t = *input* pada *time step t*
- b_f = bias pada *forget gate*

b. Memutuskan informasi yang harus diteruskan pada *cell state*



Gambar 2.3 *Input gate* pada LSTM
Sumber: Olah (2015)

Gambar 2.3 menunjukkan proses yang terjadi di *input gate*. Gate ini mengidentifikasi *input* baru yang perlu diperbarui ditambahkan pada *cell state*.

Input yang digunakan pada forget gate juga digunakan sebagai *input* pada *input gate*. *Input* diproses pada lapisan sigmoid dan lapisan tanh. Lapisan tanh ditunjukkan oleh kotak kuning dengan kata tanh di dalamnya. Lapisan tanh menghasilkan vektor nilai kandidat baru yang dapat ditambahkan ke dalam *cell state* yang disebut \tilde{C}_t . Sedangkan lapisan sigmoid atau *input gate* ditunjukkan oleh kotak berwarna kuning dengan simbol σ menghasilkan nilai antara 0 dan 1 dan disebut sebagai i_t . Nilai i_t atau hasil *input gate* menunjukkan seberapa penting informasi baru. Informasi baru dikatakan relevan dan harus dimasukkan ke dalam *cell state* apabila nilai i_t mendekati 1, sementara informasi baru dikatakan tidak relevan dan dapat diabaikan apabila nilainya mendekati 0. Memastikan informasi penting dan relevan diproses serta disimpan dalam keadaan sel merupakan fungsi *input gate* sebagai filter informasi baru. Persamaan (2.2) digunakan untuk menghitung *input gate* dan persamaan (2.3) untuk calon kadidat baru.


$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.2)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (2.3)$$

Keterangan:

- i_t = *input gate*
- W_i = bobot pada *Input gate*
- b_i = bias pada *Input gate*
- \tilde{C}_t = kandidat yang ditambah ke \tilde{C}_{t-1}
- tanh = fungsi tanh
- W_C = bobot pada sel aktivasi
- h_{t-1} = hasil dari *hidden state* sebelumnya
- x_t = *input* ke-t
- b_C = bias pada sel aktivasi

c. Penambahan Informasi Baru



Gambar 2.4 Memperbarui *Cell state* pada LSTM
Sumber: Olah (2015)

Gambar 2.4 menunjukkan proses pembaruan *cell state* atau C_t dari LSTM. Operasi penjumlahan atau penggabungan nilai f_t , hasil forget gate, dengan nilai i_t , hasil *input gate*, ditunjukkan dalam lingkaran dengan simbol +. Nilai i_t akan mengontrol jumlah informasi baru (\tilde{C}_t) yang harus ditambahkan, dan nilai f_t akan mengontrol informasi apa saja dari *cell state* sebelumnya (C_{t-1}) yang akan dilupakan. Selain penjumlahan, terdapat juga operasi perkalian antara nilai f_t dengan C_{t-1} dan nilai i_t dengan \tilde{C}_t yang ditunjukkan oleh lingkaran dengan tanda x. *Cell state* diperbarui dengan cara mengabungkan informasi sebelumnya yang masih relevan dengan informasi baru yang berbobot penting, perhitungan untuk dapat dilihat pada persamaan (2.4).

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (2.4)$$


Keterangan:

C_t = *Cell state* pada *time step* t

f_t = *forget gate*

C_{t-1} = *Cell state* pada *time step* sebelumnya

\tilde{C}_t = nilai *cell state* baru pada hasil perhitungan *gate input*

d. Mencari *Output*

Gambar 2.5 *Output gate* pada LSTM
 Sumber: Olah (2015)

Gambar 2.5 merepresentasikan *output gate* pada LSTM tentang bagaimana mengatur informasi yang akan dijadikan sebagai *output*. *Output gate* menerima dua *input* yang telah digabungkan sama seperti dengan forget gate dan *input gate* serta diproses melalui fungsi aktivasi sigmoid untuk menghasilkan nilai o_t . *Input* lain yang juga diterima *output gate* adalah *cell state* yang telah diperbarui sebelumnya, yaitu C_t yang kemudian diproses dengan fungsi aktivasi tanh untuk menghasilkan vektor baru. *Output* dari fungsi tanh nantinya akan dikalikan dengan o_t untuk menghasilkan hidden *state* baru yaitu h_t yang berperan sebagai *output* dari LSTM. Proses perkaliannya digambarkan oleh lingkaran merah muda dengan simbol x yang berada diantara tanh dan o_t , tujuannya untuk memastikan *output* yang dikeluarkan hanya berisi informasi yang penting serta relevan dengan konteks saat ini. Perhitungannya ditunjukkan oleh persamaan (2.5) dan persamaan (2.6).

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.5)$$

$$h_t = o_t * \tanh(C_t) \quad (2.6)$$

Keterangan:

- o_t = fungsi *gate output*
- σ = fungsi *sigmoid*
- W_o = bobot pada *gate output*
- h_{t-1} = hasil *output* pada *time step t-1*
- x_t = *input* pada *time step t*
- b_o = bias pada *gate output*
- h_t = *output* pada *time step* ke t
- \tanh = fungsi *tanh*

Penelitian menggunakan metode LSTM telah dilakukan oleh Chandranegara et al. (2023) untuk memprediksi data yang bergantung waktu atau bersifat *time dependent* data. Data yang dipakai pada penelitian ini adalah data historis harga saham dari Jakarta Islamic Index per satu hari yang di mulai dari 1 januari 2019 hingga 31 Maret 2022. Menurut peneliti karakteristik dari metode LSTM cocok digunakan dalam melakukan prediksi harga saham. Tujuan dilakukan penelitian ini yaitu untuk memudahkan para investor dalam menganalisa harga saham serta meminimalkan resiko di masa depan pada saat investasi. Dari penelitian yang dilakukan, diperoleh hasil RMSE terendah mencapai 5.20877667554 dengan MAPE terendah sebesar 0.08658576985.

Penelitian lain dengan menggunakan metode LSTM juga dilakukan oleh Cahyani et al. (2023) yang dalam penelitiannya digunakan untuk prediksi harga bahan pokok nasional. Alasan penulis memilih menggunakan metode LSTM dibanding dengan metode RNN (*Recurrent Neural Network*) karena LSTM mampu mengatasi permasalahan yang dimiliki oleh RNN, yaitu *vanishing gradient* atau bisa diartikan sebagai hilangnya nilai gradient dalam melakukan pembaruan bobot. Peneliti membandingkan tiga metode optimasi pada penelitiannya diantaranya

adalah *Adaptive Gradient* (ADAGRAD), *Adaptive Moment Gradient* (ADAM), *Root Mean Square Error* (RMSProp). Berdasarkan pengujian dengan tiga metode optimasi, diperoleh model harga beras kualitas rendah II dengan performa terbaik menggunakan ADAM, memiliki RMSE sebesar 0.0492 dan skor R^2 sebesar 0.8852. Untuk harga ayam model optimasi didapatkan dengan menggunakan ADAM dengan RMSE 0.0937 dan R^2 Score 0.5949. Sedangkan harga minyak goreng mendapatkan hasil terbaik dengan menggunakan optimasi RMSProp dengan RMSE sebesar 0.0313 dan skor R^2 sebesar 0.7492. Kemudian untuk harga minyak goreng curah, metode ADAM menjadi metode optimasi terbaik dengan RMSE sebesar 0.0531 dan R^2 Score sebesar 0.5308.

Penelitian yang telah dilakukan Zahara et al. (2017) terkait prediksi nilai IHK dengan metode LSTM dengan tujuh algoritma optimasi berbeda, yaitu *Adaptive Gradient* (AdaGrad), *Stochastic Gradient Descent* (SGD), *Adaptive Moment Estimation with Delta Decay* (Adadelata), *Root Mean Square Propagation* (RMSProp), *Adaptive Moment* (Adam), *Nesterov Adam* (Nadam) dan Adamax. Penelitian yang dilakukan menggunakan 34 jenis harga bahan pokok makanan sebagai *input*, data tersebut di ambil dari website Dinas Perindustrian dan Perdagangan Provinsi Jawa Timur. Kemudian untuk data *target* merupakan data nilai indeks IHK yang diperoleh dari BPS. Data yang dipakai adalah data dari tahun 2014 sampai 2018. Hasil terbaik untuk prediksi IHK diperoleh dari optimasi *Nestrov Adam* dengan nilai RMSE sebesar 4.088.

Akbar et al. (2023) dalam penelitiannya juga memilih LSTM sebagai metode untuk melakukan prediksi. Penelitian dilakukan dengan menggunakan data harian mulai tanggal 1 Januari 2019 hingga 31 Desember 2021. Datanya terbagi menjadi dua variabel, yaitu variabel terikat dan variabel bebas. Data tingkat temperatur dijadikan sebagai variabel terikat dan data durasi penyinaran matahari, curah hujan, kecepatan angin rata-rata, kelembaban rata-rata, temperatur minimum, temperatur maksimum, kecepatan angin maksimum, serta arah angin dijadikan sebagai variabel bebas. *Loss function* terkecil yaitu 0.013 didapatkan dengan konfigurasi 70% data latih, 128 unit LSTM, 800 *epochs*, 16 *batch size*, dan 0.009 *learning rate*.

Tabel 2. 2 Perbandingan Penelitian Relevan Berdasarkan Metode

No	Peneliti	Objek	Metode	Input	Target	Arsitektur Jaringan	Hasil
1	Chandra negara et al. (2023)	Prediksi Harga Saham Jakarta Islamic Index	<i>Long Short Term Memory</i>	Harga saham saat <i>close</i>	Prediksi harga saham 30 hari kedepan	1-4-1, 1-5-1, 1-7-1, 1-8-1, 1-9-1, 1-10-1, 1-11-1, 1-12-1, 1-15-1, 1-16-1	RMSE = 5.20877667554 dan MAPE = 0.08658576985.
2	Cahyani et al. (2023)	Prediksi Harga Bahan Pokok Nasional	<i>Long Short Term Memory</i>	Harga bahan pokok	Harga bahan pokok untuk 5 hari kedepan	5-15-5-5-1, 5-10-5-5-1, 5-7-5-5-1	Perbandingan nilai RMSE dan R2 dari empat harga bahan pokok yang berbeda
3	Zahara et al. (2017)	Prediksi Indeks Harga Konsumen	<i>Long Short Term Memory</i>	34 Jenis harga bahan pokok	IHK	34-50-1	RMSE = 4.088

Lanjutan Tabel Perbandingan Penelitian Relevan Berdasarkan Metode

No	Peneliti	Objek	Metode	Input	Target	Arsitektur Jaringan	Hasil
4	Akbar <i>et al.</i> (2023)	Prediksi temperatur Kota Semarang	<i>Long Short Term Memory</i>	Lama penyinaran matahari, curah hujan, kecepatan angin rata-rata, kelembapan rata-rata, temperatur minimum, temperatur maksimum, kecepatan angin maksimum, dan arah angin	Temperatur untuk 14 hari kedepan	8-32-1, 8-64-1, 8-128-1	MAPE = 1.896016 dan RMSE = 0.725.
5	Penelitian ini	Prediksi BI Rate	<i>Long Short Term Memory</i>	Inflasi, jumlah uang beredar, nilai tukar rupiah, dan IHSG	BI Rate	4-50-1, 4-100-1, 4-150-1, 4-200-1	Nilai MAPE dari pengimplementasian metode LSTM saat memprediksi suku bunga Bank Indonesia

2.4 Mean Squared Error (MSE)

Mean Squared *Error* (MSE) merupakan salah satu fungsi loss yang umum digunakan pada prediksi dan pembelajaran mesin. Sebagai fungsi loss MSE berperan dalam pengukuran seberapa baik model memprediksi nilai sebenarnya dibandingkan dengan hasil prediksi saat pelatihan (Wang & Bovik, 2009). MSE mengukur kesalahan dalam prediksi dengan cara menghitung rata-rata dari kuadrat selisih antara nilai aktual dengan nilai prediksi (Lewis, 1982). Dimana MSE dapat dihitung dengan menggunakan persamaan 2.7.

$$MSE = \frac{1}{n} \sum_{t=0}^{n-1} (d_t - f_t)^2 \quad (2.7)$$

Keterangan:

- n = Jumlah total data
- d_t = Data aktual
- f_t = Hasil prediksi

2.5 Mean Absolute Percentage Error

MAPE (*Mean Absolute Percentage Error*) merupakan nilai absolut persentase kesalahan data dari mean (Lewis, 1982). Persamaannya ditulis dalam bentuk persamaan (2.8):

$$MAPE = \frac{1}{n} \sum_{t=0}^{n-1} \frac{|d_t - f_t|}{d_t} \times 100 \quad (2.8)$$

Keterangan:

- d_t = Nilai aktual di periode t
- f_t = Prediksi pada periode t
- n = Jumlah total data

Nilai MAPE dikatakan sangat baik dalam melakukan prediksi jika hasilnya rendah atau persentasenya kurang dari 10% (Bodapati et al., 2020). MAPE mempunyai rentang nilai yang dapat dijadikan acuan untuk mengambil kesimpulan apakah prediksi tersebut masuk dalam kategori prediksi yang baik atau buruk. MAPE digunakan ketika pengukuran prediktif merupakan faktor penting dalam menilai keakuratan perkiraan. dan MAPE mempunyai pengelompokan yang jelas mengenai persentase hasil yang diperoleh. Oleh karena itu, mudah untuk menentukan hasil kinerja model prediksi.

Tabel 2.3 Evaluasi Nilai MAPE

Evaluasi	MAPE(%)
<i>Highly Accurate</i>	$MAPE \leq 10\%$
<i>Good</i>	$10\% < MAPE \leq 20\%$
<i>Reasonable</i>	$20\% < MAPE \leq 50\%$
<i>Inaccurate</i>	$MAPE > 50\%$

Sumber: (Anggrainingsih et al., 2015)

Tabel 2.3 menunjukkan kategori evaluasi nilai MAPE untuk menilai akurasi suatu model. Berdasarkan kategori tabel 2.3, nilai MAPE kurang dari atau sama dengan 10% termasuk ke dalam akurasi *highly accurate* yang berarti model sangat akurat. Sedangkan nilai MAPE lebih dari 10% hingga 20% termasuk kategori *good* yang berarti model cukup baik. Kemudian nilai MAPE lebih dari 20% hingga 50% termasuk kategori *reasonable* yang artinya model cukup akurat. Terakhir nilai MAPE lebih dari 50% termasuk ke dalam kategori *inaccurate* yang berarti model tidak akurat.

2.6 Optimasi Adam

Pengoptimal Adam adalah pengoptimal *deep learning* yang dikembangkan dari *stochastic gradient descent*. Adam adalah kependekan dari estimasi momen *Adaptive Moment Estimation* (Kingma & Lei Ba, 2015). Pengoptimal Adam bekerja dengan memanfaatkan keunggulan AdaGrad (*Adaptive Gradient Algorithm*) dengan mempertahankan *learning* tiap parameter yang berkelanjutan, yang berdampak pada peningkatan performa model. Selanjutnya, Adam juga memanfaatkan kelebihan RMSProp (*Root Mean Square Propagation*), yang juga bekerja dengan mempertahankan kecepatan pembelajaran (*learning rate*) untuk setiap parameter berdasarkan besaran rata-rata gradien bobot model.

1. Menghitung nilai gradient

$$g_t = \nabla_{\theta} f_t(\theta_{t-1}) \quad (2.9)$$

2. Menghitung nilai estimasi bias momen pertama

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (2.10)$$

3. Menghitung estimasi bias momen kedua

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (2.11)$$

4. Memperbaiki bias first moment

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (2.12)$$

5. Memperbaiki bias momen kedua

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (2.13)$$

6. Memperbaiki parameter

$$\theta_{t+1} = \theta_t - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}} \quad (2.14)$$

Keterangan:

- g_t = gradient pada t
- m = estimasi *first moment*
- v_t = estimasi *second moment*
- β_1, β_2 = *exponential decay rate* atau laju peluruhan exponential
- α = *step size* atau *learning rates*
- θ = parameter yang akan diperbaiki (bobot)

BAB III

METODOLOGI PENELITIAN

Penelitian ini memiliki beberapa tahapan yang dilakukan secara terorganisir dan sistematis untuk memudahkan penulis dalam mencapai hasil yang diharapkan. Dalam mencapai tujuan penelitian dibutuhkan suatu rancangan atau desain sistem yang sesuai dengan kondisi penelitian .

3.1 Pengumpulan Data

Pada penelitian ini, peneliti menggunakan data JUB, data IHSG, data nilai tukar rupiah (kurs Dollar Amerika), dan data *BI Rate*. Data penelitian ini diperoleh dari tiga situs website resmi yaitu website BPS untuk pengambilan data JUB, IHSG, dan *BI Rate*. Kemudian website Bank Indonesia untuk pengambilan data inflasi, dan terakhir situs web Investing.com untuk pengambilan data kurs Dollar Amerika. Data yang digunakan adalah data dari Januari 2010 hingga Juni 2023. Dataset yang akan digunakan dalam penelitian dapat dilihat pada tabel 3.1.

Tabel 3.1 *Dataset* Penelitian

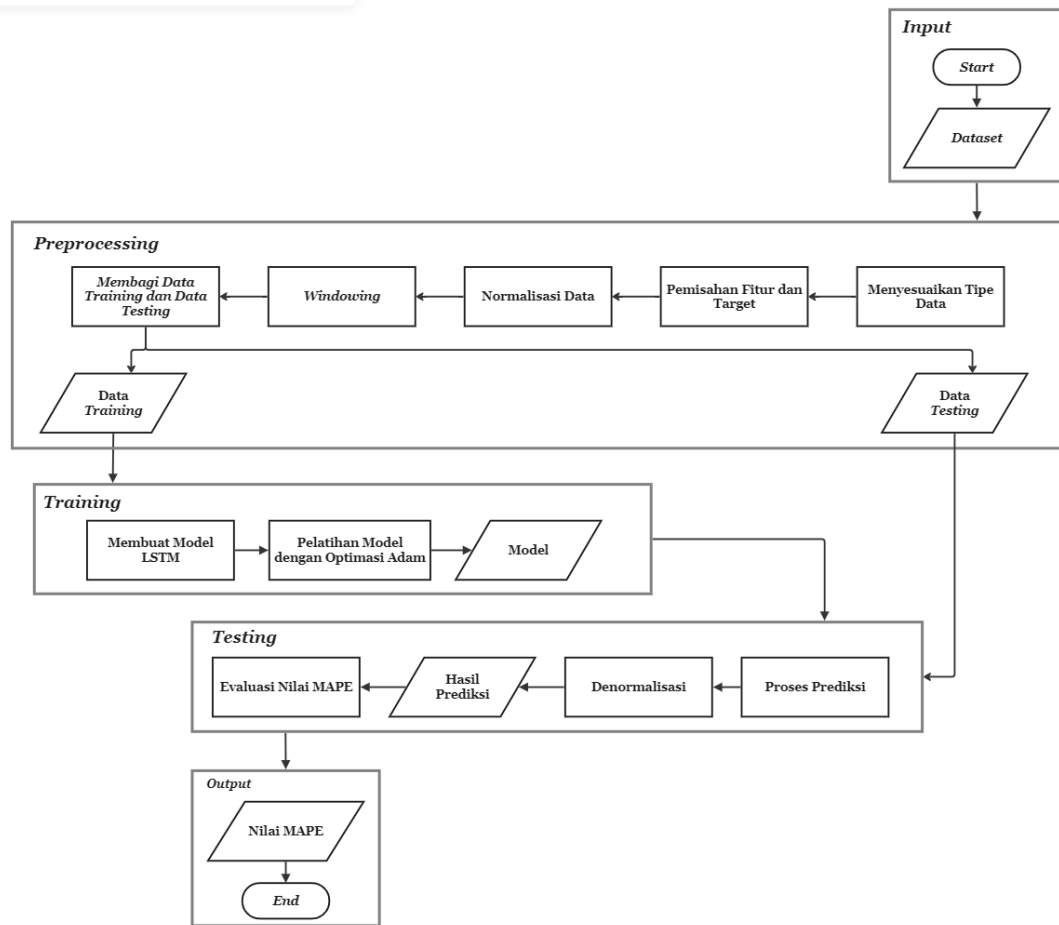
	Periode	Inflasi	JUB	Kurs	IHSG	BI Rate
2010	Januari	9350	2066480.99	3.72	2610.8	6.5
	Februari	9337	2112082.7	3.81	2549.03	6.5
	Maret	9090	2116023.54	3.43	2777.3	6.5
	April	9012	2143234.05	3.91	2971.25	6.5
	Mei	9175	2231144.33	4.16	2796.96	6.5
	Juni	9060	2217588.81	5.05	2913.68	6.5
	Juli	8940	2236459.45	6.22	3069.28	6.5
	Agustus	9035	2274954.57	6.44	3081.88	6.5
	September	8925	2308845.97	5.8	3501.3	6.5
	Oktober	8935	2347806.86	5.67	3635.32	6.5
	November	9029	2471205.79	6.33	3531.21	6.5
	Desember	9005	2877219.57	6.96	3703.51	6.5

Lanjutan Tabel *Dataset* Penelitian

	Periode	Inflasi	JUB	Kurs	IHSG	BI Rate
2011	Januari	9043	2436678.95	7.02	3409.17	6.5
	Februari	8818	2420191.14	6.84	3470.35	6.75
	Maret	8705	2451356.92	6.65	3678.67	6.75
	April	8563	2434478.39	6.16	3819.62	6.75
	Mei	8532	2475285.98	5.98	3836.97	6.75
	Juni	8573	2522783.81	5.54	3888.57	6.75
	Juli	8495	2564556.13	4.61	4130.8	6.75
	Agustus	8528	2621345.74	4.79	3841.73	6.75
	September	8780	2643331.45	4.61	3549.03	6.75
	Oktober	8850	2677205.02	4.42	3790.85	6.5
	November	9105	2729538.27	4.15	3715.08	6
	Desember	9060	2877219.57	3.79	3821.99	6
.....						
2023	Januari	14985	8271838.1	5.28	6839.34	5.75
	Februari	15245	8300648.37	5.47	6843.24	5.75
	Maret	14990	8293283.23	4.97	6805.28	5.75
	April	14665	8352349.68	4.33	6915.72	5.75
	Mei	14985	8336170.79	4	6633.26	5.75
	Juni	14990	8372606.83	3.52	6661.88	5.75

3.2 Desain Sistem

Desain sistem adalah gambaran alur dari sistem yang akan dibentuk. Sistem dimulai dengan *input* data berupa jumlah uang beredar, kurs, inflasi, dan indeks harga saham gabungan. Kemudian, dilakukan proses *preprocessing* untuk menghasilkan data yang siap pakai pada proses selanjutnya. *Preprocessing* menghasilkan dua *output*, yaitu data untuk *training* dan data untuk *testing*. Setelah itu, dilakukan proses *training*, proses dimana model dibangun dan dilatih menggunakan data *training*. Kemudian model yang sudah dilatih tadi di uji menggunakan data yang belum digunakan sebelumnya, yaitu data *testing*. Hasil dari pengujian ini kemudian dibandingkan dengan data akuratnya untuk menentukan keakuratan hasil prediksi. Desain sistem dari penelitian ini dapat dilihat pada gambar 3.1.



Gambar 3.1 Desain Sistem

Pada gambar 3.1, desain sistem dimulai dari tahapan *input* yaitu proses memuat dataset. Setelah dataset berhasil dimuat masuk ke tahapan preprocessing, yaitu penyesuaian tipe data, pemisahan fitur dan target, normalisasi data, windowing, serta membagi dataset training. Prosesnya dilakukan secara berurutan, kemudian dilanjutkan tahapan training menggunakan metode LSTM dan optimasi adam. Model yang telah dilatih, masuk ke tahapan testing untuk pengujian dengan data testing kemudian dilakukan evaluasi nilai MAPE.

3.3 Preprocessing Data

Dataset yang diperoleh memiliki range nilai yang berbeda-beda. Oleh karena itu, dibutuhkan *preprocessing* data untuk menyiapkan data yang sesuai dengan kebutuhan dari sistem. *Preprocessing* data yang dilakukan diantaranya yaitu, yang pertama adalah menyesuaikan tipe data, karena saat dilakukan pengecekan *dataset* terdapat data yang tipe datanya tidak sesuai.

```

RangeIndex: 162 entries, 0 to 161
Data columns (total 6 columns):
 #   Column      Non-Null Count  Dtype
---  -
 0   periode    162 non-null    object
 1   kurs        162 non-null    int64
 2   jub         162 non-null    float64
 3   inflasi     162 non-null    float64
 4   ihsg        162 non-null    float64
 5   bi_rate     162 non-null    float64
dtypes: float64(4), int64(1), object(1)

```

Gambar 3.2 Hasil Pengecekan Tipe Data

Pada gambar 3.2 terdapat dua tipe data yang tidak sesuai, yaitu *periode* dan *kurs*. Karena tipe data dari *kurs* adalah integer maka harus diubah terlebih dahulu menjadi tipe data *float* dan tipe data dari *periode* yang berupa *object* diubah menjadi tipe data *datetime*. Setelah tipe data sesuai, tahapan *preprocessing* selanjutnya adalah memisahkan fitur dengan target. Data fitur ada empat variabel, yaitu *kurs*, *JUB*, *inflasi*, dan *IHSG*. Sedangkan target hanya ada satu yaitu *BI Rate* sebagai variabel yang ingin diprediksi. Setelah diisahkan, tahapan selanjuteenya adalah tahapan normalisasi data dengan fungsi *min-max scaling*, yang digunakan untuk menangani perbedaan nilai yang besar di antara *dataset*. Algoritma dari penggunaan rumus *min-max scaling* dapat dilihat pada persamaan (3.1) :

$$x' = (x - x_{min}) / (x_{max} - x_{min}) \quad (3.1)$$

Keterangan:

x' = setelah normalisasi
 x = sebelum normalisasi
 x_{min} = nilai terendah sebelum dinormalisasi
 x_{max} = nilai terbesar sebelum dinormalisasi

```
# fungsi untuk melakukan min-max scaling (normalisasi data)
def min_max_scaling(df, column_name):
    column = df[column_name].copy()
    min_val = min(column)
    max_val = max(column)

    df[column_name] = [(x - min_val) / (max_val - min_val) for x in column]
    return df, min_val, max_val
```

Gambar 3.3 Source Code Implementasi Normalisasi Data

Tabel 3.2 Data Sebelum Dinormalisasi

Periode	Inflasi	JUB	IHSG	Kurs
Januari 2010	3.72	2066480.99	2610.80	9350
Februari 2010	3.81	2112082.70	2549.03	9337
Maret 2010	3.43	2116023.54	2777.30	9090
MIN	1.32	2066480.99	2549.03	8495
MAX	8.79	8528022.31	7228.91	16300

Perhitungan normalisasi pada data Inflasi Januari 2010

$$x' = (x - x_{min}) / (x_{max} - x_{min})$$

$$x' = (3.72 - 1.32) / (8.79 - 1.32)$$

$$x' = 2.4 / 7.47$$


$$x' = 0.32$$

Hasil normalisasi data inflasi, JUB, IHSG, dan kurs mulai dari Januari 2010 hingga Maret 2010 dapat dilihat pada tabel 3.3.

Tabel 3.3 Hasil Normalisasi

Periode	Inflasi	JUB	IHSG	Kurs
Januari 2010	0.32	0.00	0.01	0.11
Februari 2010	0.33	0.01	0.00	0.11
Maret 2010	0.28	0.01	0.05	0.08

Setelah dilakukan normalisasi, tahapan selanjutnya adalah *sliding window* atau *windowing* yaitu teknik menggunakan *window* yang digeser sejauh ukuran perpindahannya dengan tujuan mempermudah dan memperkecil komputasi.



Gambar 3.4 Proses Windowing

```
# Fungsi untuk membuat dataset dengan windowing
def create_dataset(X, y, time_steps=1):
    Xs, ys = [], []
    for i in range(len(X) - time_steps):
        v = X.iloc[i:(i + time_steps)].values
        Xs.append(v)
        ys.append(y.iloc[i + time_steps])
    return np.array(Xs), np.array(ys)

# Membuat dataset dengan windowing
TIME_STEPS = 3
X, y = create_dataset(features_normalized, target_normalized, TIME_STEPS)
```

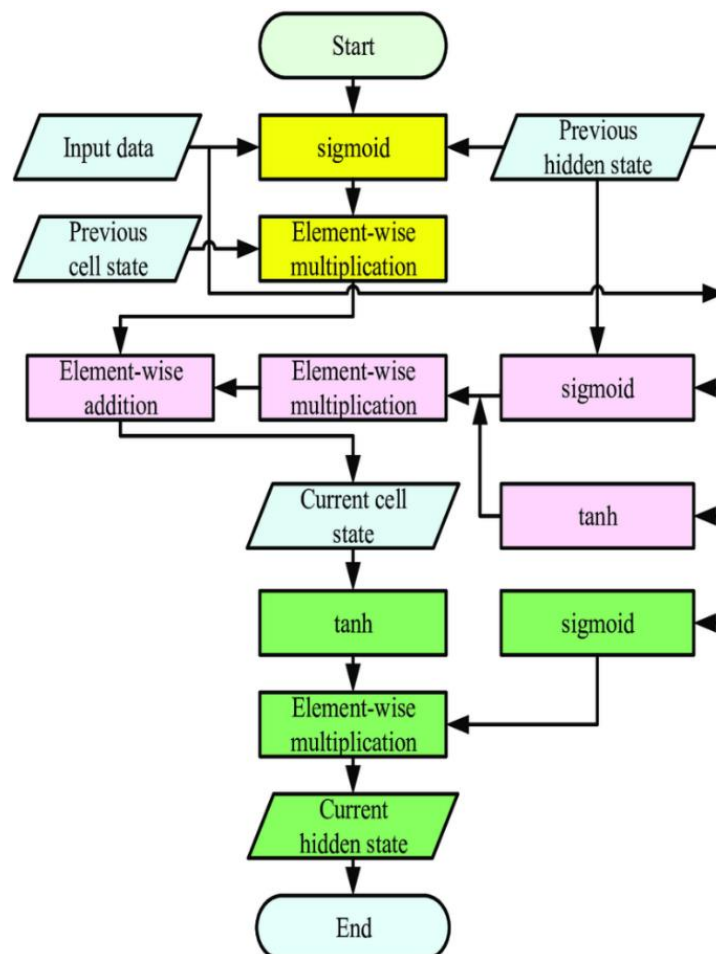
Gambar 3.5 Source Code Implementasi Windowing

Dari Gambar 3.4 dapat dilihat ilustrasi dari proses *sliding window* dengan ukuran perpindahan tiga. T₁ hingga T₆ merupakan unit observasi pada data *time series*. Misalkan T₁ menggambarkan data pada bulan pertama, T₂ menggambarkan data pada bulan kedua dan seterusnya. *Window* pertama akan dimulai dari data T₁ hingga data T₃ yang digunakan untuk melakukan prediksi pada data T₄. Segmen berikutnya dimulai dari data T₂ hingga T₄ yang digunakan untuk melakukan prediksi pada data T₅. Proses tersebut terus dilanjutkan hingga semua data habis tersegmentasi (Wahyuni et al., 2021).

Setelah melalui tahapan *windowing*, langkah selanjutnya adalah membagi data menjadi dua bagian yaitu data latih dan data uji. Pembagiannya dilakukan dengan dua perbandingan berbeda. Perbandingan pertama menggunakan 80% dari keseluruhan data sebagai data latih kemudian sisanya 20% digunakan sebagai data uji. Perbandingan kedua membagi *dataset* dengan perbandingan 90% sebagai data latih dan 10% sebagai data uji.

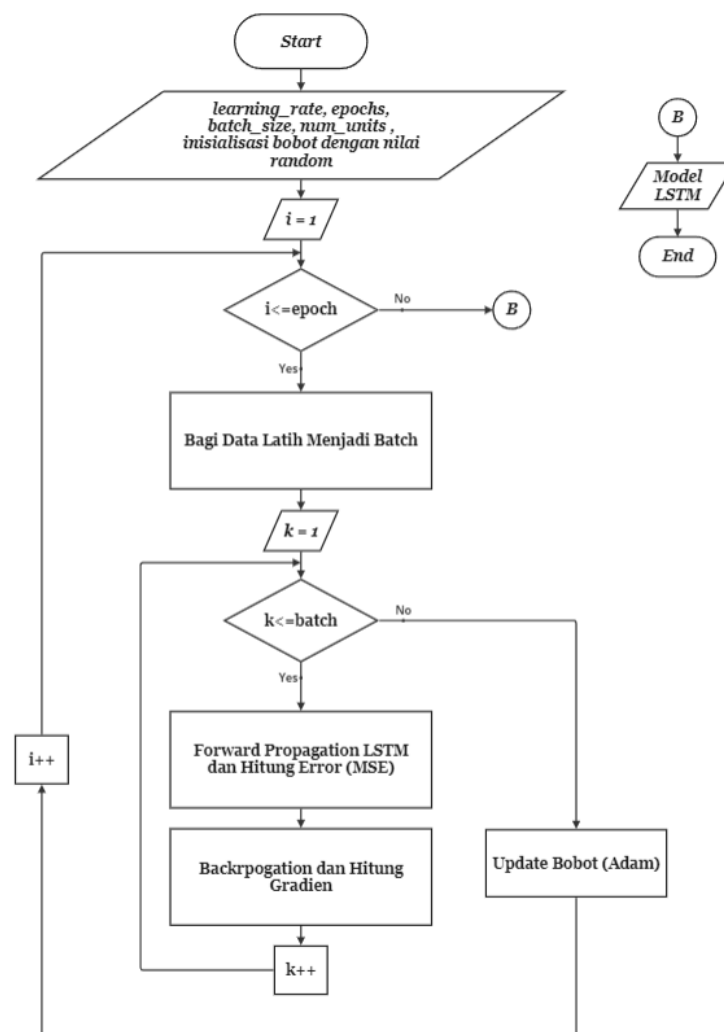
3.4 Proses *Training* LSTM

Setelah melalui tahap *preprocessing*, data latih akan digunakan untuk *training* jaringan LSTM.



Gambar 3. 6 *Flowchart* dari Operasi LSTM
Sumber: Khan et al. (2023)

Flowchart operasi LSTM yang digambarkan oleh gambar 3.6, menunjukkan langkah demi langkah operasi LSTM. Dimulai dari blok kuning yang menunjukkan *forget gate* yang bertugas menentukan bagian mana yang harus di lupakan dari *cell state*, kemudian dilanjutkan blok pink yang menunjukkan *Input gate* yang bertugas menentukan informasi baru untuk disimpan pada *cell state*. Setelah itu, melalui blok hijau yang merupakan *forget gate*, LSTM akan menentukan informasi mana dari *cell state* yang akan menjadi *output*(Khan et al., 2023).



Gambar 3.7 *Flowchart* Proses Training Model


Gambar 3.7 menunjukkan proses *training* jaringan LSTM yang dilakukan dengan menggunakan algoritma optimisasi Adam untuk memperbarui bobot jaringan selama proses *training*. Berikut penjelasan proses dari pelatihannya:

1. Siapkan data latih dalam bentuk pasangan *input* dan *output* sesuai urutan langkah waktu.
2. Dilakukan langkah perhitungan forward propagation untuk mendapatkan *output* jaringan LSTM.
3. Gunakan nilai *output* dari hasil jaringan LSTM dan nilai sebenarnya untuk menghitung error dengan menggunakan MSE.
4. Dilakukan langkah perhitungan backpropagation untuk menghitung gradien loss terhadap bobot.
5. Gradien yang telah dihitung, kemudian digunakan untuk memperbarui bobot menggunakan optimisasi adam.

Langkah-langkah tersebut di atas diulangi hingga seluruh *batch* data selesai, kemudian proses tersebut diiterasi hingga tercapai jumlah *epoch* yang telah ditentukan.

3.5 Arsitektur Jaringan

Pembangunan model prediksi BI *Rate* dilakukan menggunakan bahasa pemrograman python dengan arsitektur model prediksi empat *layer* yaitu *input layer*, dua *hidden layer*, dan satu *output layer*.



Gambar 3.8 Arsitektur Sistem Prediksi

Menurut Gambar 3.8, data pada lapisan *input* kemudian diproses pada lapisan jaringan LSTM dengan 2 lapisan *hidden layer* yang terdiri dari *neuron* sejumlah n , dan kemudian data diteruskan ke *output layer* dengan satu variabel *output*.

Dense *layer* atau dikenal juga dengan sebutan *fully connected layer* adalah lapisan *neuron* sederhana di mana setiap *neuron* menerima *input* dari semua *neuron* di lapisan sebelumnya. Dengan kata lain, lapisan ini terhubung secara dalam, yang menunjukkan bahwa setiap *neuron* pada lapisan padat tersebut memiliki hubungan langsung dengan setiap *neuron* pada lapisan sebelumnya (Tania Emanuella & Armin Lawi, 2021). Fungsi utama lapisan ini adalah untuk mengubah *output* lapisan sebelumnya menjadi nilai hasil prediksi (Budiprasetyo et al., 2023),

Model untuk prediksi dipisahkan ke dalam dua tahap. Tahap pertama *input* masuk ke proses LSTM dan menghasilkan *output* h atau disebut *hidden state*. Kemudian *output*nya diteruskan ke persamaan prediksi yang mengambil satu lapisan dari LSTM, yaitu lapisan *output*. Perhitungannya dapat dilihat pada persamaan (3.8).

$$Y = W_y \cdot [h] + b_y \quad (3.8)$$

Keterangan:

- Y = Nilai prediksi
- W_y = bobot pada model prediksi
- h = hasil proses LSTM
- b_y = bias pada model prediksi

BAB IV

UJI COBA DAN PEMBAHASAN

4.1 Skenario Uji

Skenario pengujian merupakan langkah evaluasi yang dilakukan untuk mengetahui tingkat kesalahan model yang dibangun. Sebelum akhirnya mendapatkan nilai *error* dari model yang diuji, ada beberapa langkah yang harus diselesaikan. Langkah pertama adalah mencari *ground truth*, yaitu data atau informasi yang digunakan untuk membandingkan hasil prediksi dari model yang dibangun. Sebelum masuk proses *training*, data yang telah melewati tahap *preprocessing* dibagi menjadi dua bagian, yaitu data pelatihan dan data uji. Adapun variasi rasio pembagian data yang digunakan pada penelitian ini yaitu 70:30, 80:20, dan 90:10. Tujuannya untuk mengetahui proporsi mana yang paling sesuai digunakan dalam memprediksi *BI Rate*.

Setelah mendapatkan nilai sebenarnya (*ground truth*) maka dilakukanlah proses *training*. Kemudian dilanjutkan *testing* dengan model yang telah di *training* dan membandingkan hasil prediksi dengan data aktualnya. Selain itu, proses ini melibatkan pengukuran tingkat *error*. Dalam memahami tingkat kesalahan relatif pada pengujian, hasil prediksi dinormalisasi terlebih dahulu sebelum dilakukan perhitungan MAPE. Setelah hasil prediksi dikembalikan ke skala aslinya, MAPE memberikan informasi tambahan dalam bentuk persentase kesalahan relatif. Sedangkan perhitungan dinormalisasi dapat dilakukan menggunakan persamaan (4.2) (Rahmat et al., 2023).

$$x = x' (x_{max} - x_{min}) + x_{min} \quad (4.2)$$

Keterangan:

x' = *output* yang masih dalam bentuk normalisasi
 x = sebelum normalisasi
 x_{min} = nilai terendah sebelum dinormalisasi
 x_{max} = nilai terbesar sebelum dinormalisasi

```
# Fungsi untuk membalikkan normalisasi
def inverse_min_max_scaling(norm_data, min_val, max_val):
    return [x * (max_val - min_val) + min_val for x in norm_data]
```

Gambar 4.1 *Source Code* Denormalisasi

Pada proses *training*, dilakukan uji coba berbagai parameter untuk memantau pergerakan tingkat *error* atau kesalahan. Parameter yang terlibat adalah *learning rate*, jumlah *epoch*, jumlah *batch size*, dan jumlah *neuron* LSTM. Hal ini dilakukan untuk mencari model dengan kombinasi parameter terbaik untuk memberikan nilai bobot dan bias yang paling tepat untuk membuat prediksi pada sesi pengujian menggunakan data pengujian, dan tercerminkan dari rendahnya tingkat *error* yang dihasilkan. Berikut ini variasi parameter *learning rate*, jumlah *epoch*, jumlah *batch size*, dan jumlah *neuron* LSTM pada proses *training* yang akan dilakukan:

1. Variasi penggunaan jumlah *neuron* LSTM dengan jumlah *neuron* 3, 6, 12, dan 24
2. Variasi penggunaan *learning rate* dengan nilai *learning rate* 0.009, 0.01, dan 0.02
3. Variasi penggunaan *epoch* dengan nilai *epoch* 50, 100, 150, dan 200
4. Variasi penggunaan *batch size* dengan nilai *batch size* 4, 8, dan 16.

Berdasarkan kombinasi dari variasi parameter tersebut, model yang diujikan ada sebanyak 144 model, seperti yang sudah terlampir dalam lampiran berupa tabel kombinasi parameter dari model yang akan diujikan.

4.2 Hasil Uji Coba

4.2.1 Hasil Pengujian Rasio 70:30

Berikut ini adalah rata-rata nilai MAPE hasil pengujian penggunaan variasi parameter pada rasio data 70:30, dimana 70% dari data digunakan sebagai data latih dan 30% sisanya digunakan sebagai data uji.

Tabel 4.1 Rata-rata nilai MAPE dari uji *neuron* pada rasio 70:30

<i>Neuron</i>	MAPE
3	45.40%
6	45.67%
12	49.33%
24	48.08%

Pada tabel 4.1 disajikan hasil rata-rata nilai MAPE dari penggunaan jumlah *neuron* 3, 6, 12, dan 24. Hasilnya menunjukkan bahwa pengujian dengan jumlah *neuron* 3 menghasilkan rata-rata nilai MAPE paling rendah dibandingkan jumlah *neuron* lainnya.

Tabel 4.2 Rata-rata nilai MAPE dari uji *learning rate* pada rasio 70:30

<i>Learning rate</i>	MAPE
0.009	45.93%
0.01	47.03%
0.02	48.41%

Pada tabel 4.2 disajikan hasil rata-rata nilai MAPE dari penggunaan jumlah *learning rate* 0.009, 0.01, dan 0.02. Hasilnya menunjukkan bahwa pengujian dengan *learning rate* 0.009 menghasilkan rata-rata nilai MAPE paling rendah dibandingkan dengan *learning rate* lainnya.

Tabel 4.3 Rata-rata nilai MAPE dari uji *epoch* pada rasio 70:30

<i>Epoch</i>	MAPE
50	43.69%
100	47.15%
150	48.33%
200	49.33%

Kemudian pada tabel 4.3 disajikan hasil rata-rata nilai MAPE dari penggunaan jumlah *epoch* 50, 100, 150, dan 200. Hasilnya menunjukkan bahwa pengujian dengan *epoch* 50 menghasilkan rata-rata nilai MAPE paling rendah dibandingkan dengan *epoch* lainnya.

Tabel 4.4 Rata-rata nilai MAPE dari uji *batch* pada rasio 70:30

<i>Batch</i>	MAPE
4	46.69%
8	49.30%
16	45.38%

Dalam tabel 4.4 disajikan hasil rata-rata nilai MAPE dari penggunaan jumlah *batch* 4, 8, dan 16. Hasilnya menunjukkan bahwa pengujian dengan *batch* 16 menghasilkan rata-rata nilai MAPE paling rendah dibandingkan dengan *batch* lainnya.

Dari pengujian yang telah dilakukan, seperti yang terlampir dalam lampiran 2, berupa tabel hasil pengujian perlakuan pada model dengan rasio 70:30, diperoleh kombinasi dari variasi parameter yang menghasilkan tingkat eror paling

rendah ditunjukkan oleh model dengan kombinasi jumlah *neuron* 3, *learning rate* 0.009, *epoch* 50, dan *batch size* 16 dengan memperoleh nilai MAPE 22.019%.

4.2.2 Hasil Pengujian Rasio 80:20

Berikut ini adalah rata-rata nilai MAPE hasil pengujian penggunaan variasi parameter pada rasio data 80:20, dimana 80% dari data digunakan sebagai data latih dan 20% sisanya digunakan sebagai data uji.

Tabel 4.5 Rata-rata nilai MAPE dari uji *neuron* pada rasio 80:20

<i>Neuron</i>	MAPE
3	16.24%
6	19.57%
12	19.14%
24	18.66%

Dalam tabel 4.5 disajikan hasil rata-rata nilai MAPE dari penggunaan jumlah *neuron* 3, 6, 12, dan 24. Hasilnya menunjukkan bahwa pengujian dengan jumlah *neuron* 3 menghasilkan rata-rata nilai MAPE paling rendah dibandingkan jumlah *neuron* lainnya.

Tabel 4.6 Rata-rata nilai MAPE dari uji *learning rate* pada rasio 80:20

<i>Learning rate</i>	MAPE
0.009	18.18%
0.01	17.87%
0.02	19.16%

Dalam tabel 4.6 di bawah disajikan hasil rata-rata nilai MAPE dari penggunaan jumlah *learning rate* 0.009, 0.01, dan 0.02. Hasilnya menunjukkan bahwa pengujian dengan *learning rate* 0.01 menghasilkan rata-rata nilai MAPE paling rendah dibandingkan dengan *learning rate* lainnya.

Tabel 4.7 Rata-rata nilai MAPE dari uji *epoch* pada rasio 80:20

<i>Epoch</i>	MAPE
50	24.11%
100	16.82%
150	16.53%
200	16.14%

Pada tabel 4.7 disajikan hasil rata-rata nilai MAPE dari penggunaan jumlah *epoch* 50, 100, 150, dan 200. Hasilnya menunjukkan bahwa pengujian dengan *epoch* 200 menghasilkan rata-rata nilai MAPE paling rendah dibandingkan dengan *epoch* lainnya.

Tabel 4.8 Rata-rata nilai MAPE dari uji *batch* pada rasio 80:20

<i>Batch</i>	MAPE
4	17.98%
8	18.99%
16	18.23%

Dalam tabel 4.8 disajikan hasil rata-rata nilai MAPE dari penggunaan jumlah *batch* 4, 8, dan 16. Hasilnya menunjukkan bahwa pengujian dengan *batch* 4 menghasilkan rata-rata nilai MAPE paling rendah dibandingkan dengan *batch* lainnya.

Dari pengujian yang telah dilakukan, seperti yang terlampir dalam lampiran 3, berupa tabel hasil pengujian perlakuan pada model dengan rasio 80:20, diperoleh kombinasi dari variasi parameter yang menghasilkan tingkat eror paling rendah pada rasio data 80:20 ditunjukkan oleh model dengan kombinasi jumlah *neuron* 3, *learning rate* 0.01, *epoch* 150, dan *batch size* 8 dengan memperoleh nilai MAPE 4.760%.

4.2.3 Hasil Pengujian Rasio 90:10

Berikut ini adalah rata-rata nilai MAPE hasil pengujian penggunaan variasi parameter pada rasio data 90:10, dimana 90% dari data digunakan sebagai data latih dan 10% sisanya digunakan sebagai data uji.

Tabel 4.9 Rata-rata nilai MAPE dari uji *neuron* pada rasio 90:10

<i>Neuron</i>	MAPE
3	13.15%
6	17.00%
12	16.53%
24	16.53%

Dalam tabel 4.9 disajikan hasil rata-rata nilai MAPE dari penggunaan jumlah *neuron* 3, 6, 12, dan 24. Hasilnya menunjukkan bahwa pengujian dengan jumlah *neuron* 3 menghasilkan rata-rata nilai MAPE paling rendah dibandingkan jumlah *neuron* lainnya.

Tabel 4.10 Rata-rata nilai MAPE dari uji *learning rate* pada rasio 90:10

<i>Learning rate</i>	MAPE
0.009	16.60%
0.01	16.33%
0.02	14.52%

+

Dalam tabel 4.10 disajikan hasil rata-rata nilai MAPE dari penggunaan jumlah *learning rate* 0.009, 0.01, dan 0.02. Hasilnya menunjukkan bahwa pengujian dengan *learning rate* 0.02 menghasilkan rata-rata nilai MAPE paling rendah dibandingkan dengan *learning rate* lainnya.

Tabel 4.11 Rata-rata nilai MAPE dari uji *epoch* pada rasio 90:10

<i>Epoch</i>	MAPE
50	14.41%
100	17.27%
150	16.20%
200	15.40%

Dalam tabel 4.11 disajikan hasil rata-rata nilai MAPE dari penggunaan jumlah *epoch* 50, 100, 150, dan 200. Hasilnya menunjukkan bahwa pengujian dengan *epoch* 50 menghasilkan rata-rata nilai MAPE paling rendah dibandingkan dengan *epoch* lainnya.

Tabel 4.12 Rata-rata nilai MAPE dari uji *batch* pada rasio 90:10


<i>Batch</i>	MAPE
4	14.31%
8	15.73%
16	17.42%

Dalam tabel 4.12 disajikan hasil rata-rata nilai MAPE dari penggunaan jumlah *batch* 4, 8, dan 16. Hasilnya menunjukkan bahwa pengujian dengan *batch* 4 menghasilkan rata-rata nilai MAPE paling rendah dibandingkan dengan *batch* lainnya.

Dari pengujian yang telah dilakukan, seperti yang terlampir dalam lampiran 4, berupa tabel hasil pengujian perlakuan pada model dengan rasio 90:10, diperoleh kombinasi dari variasi parameter yang menghasilkan tingkat eror paling rendah pada rasio data 90:10 ditunjukkan oleh model dengan kombinasi jumlah *neuron* 3, *learning rate* 0.02, *epoch* 100, dan *batch size* 16 dengan memperoleh nilai MAPE 7.984%.

4.3 Pembahasan

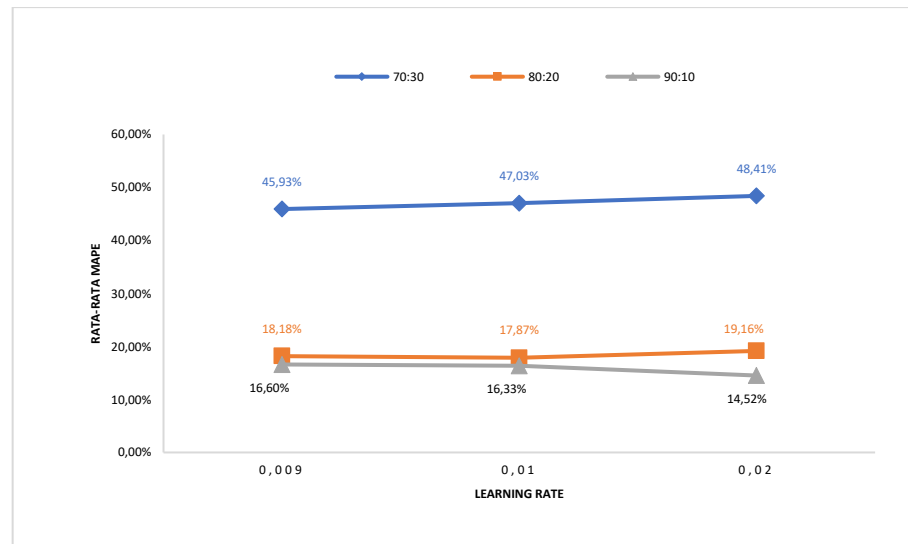
Grafik pada gambar 4.2 merupakan hasil rata-rata nilai MAPE yang dihasilkan dari pengujian jumlah *neuron* pada Rasio 70:30, 80:20, dan 90:10.



Gambar 4. 2 Grafik hasil pengujian jumlah *neuron*

Pada gambar 4.2 warna biru mewakili rata-rata nilai MAPE dari pengujian jumlah *neuron* pada rasio 70:30, sedangkan warna jingga mewakili rata-rata nilai MAPE dari pengujian jumlah *neuron* pada rasio 80:20, dan warna abu-abu mewakili rata-rata nilai MAPE dari pengujian jumlah *neuron* pada rasio 90:10. Pengujian terhadap jumlah *neuron* LSTM pada *hidden layers* menunjukkan bahwa jumlahnya mempengaruhi hasil dan kinerja algoritma. Jumlah unit LSTM yang semakin sedikit akan mempercepat proses *training* algoritma tetapi semakin banyak jumlah unit pada *hidden layers*, maka waktu yang dibutuhkan untuk proses pelatihan akan meningkat karena proses *training* yang harus diselesaikan semakin banyak dan membuat model menjadi rentan terjadi *overfitting*.


Grafik pada gambar 4.3 merupakan hasil rata-rata nilai MAPE yang dihasilkan dari pengujian *learning rate* pada Rasio 70:30, 80:20, dan 90:10.



Gambar 4.3 Grafik hasil pengujian nilai *learning rate*

Pada gambar 4.3 warna biru mewakili rata-rata nilai MAPE dari pengujian *learning rate* pada rasio 70:30, sedangkan warna jingga mewakili rata-rata nilai MAPE dari pengujian *learning rate* pada rasio 80:20, dan warna abu-abu mewakili rata-rata nilai MAPE dari pengujian *learning rate* pada rasio 90:10. Hasil pengujian *learning rate* menunjukkan bahwa semakin tinggi *learning rate* dan semakin sedikit data *train* yang dipakai membuat MAPE yang dihasilkan menjadi semakin tinggi. Sedangkan pada data *train* yang lebih banyak dengan *learning rate* yang semakin rendah, membuat rata-rata nilai MAPE menurun.

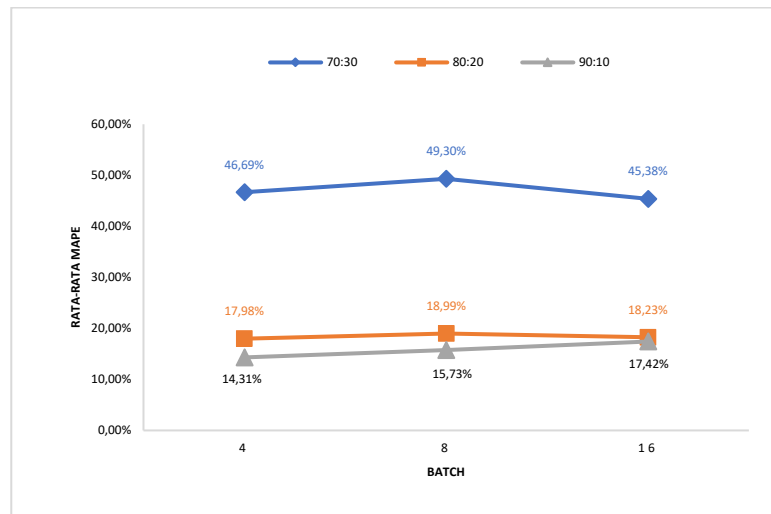
Grafik pada gambar 4.4 merupakan hasil rata-rata nilai MAPE yang dihasilkan dari pengujian jumlah *epoch* pada Rasio 70:30, 80:20, dan 90:10.



Gambar 4.4 Grafik hasil pengujian nilai *epoch*

Pada gambar 4.4 warna biru mewakili rata-rata nilai MAPE dari pengujian jumlah *epoch* pada rasio 70:30, sedangkan warna jingga mewakili rata-rata nilai MAPE dari pengujian jumlah *epoch* pada rasio 80:20, dan warna abu-abu mewakili rata-rata nilai MAPE dari pengujian jumlah *epoch* pada rasio 90:10. Hasil pengujian jumlah *epoch* menunjukkan bahwa semakin banyak iterasi dan semakin sedikit data *train* yang dipakai membuat MAPE yang dihasilkan menjadi semakin tinggi. Sedangkan pada data *train* yang lebih banyak dengan *epoch* yang semakin meningkat, membuat rata-rata nilai MAPE menurun.

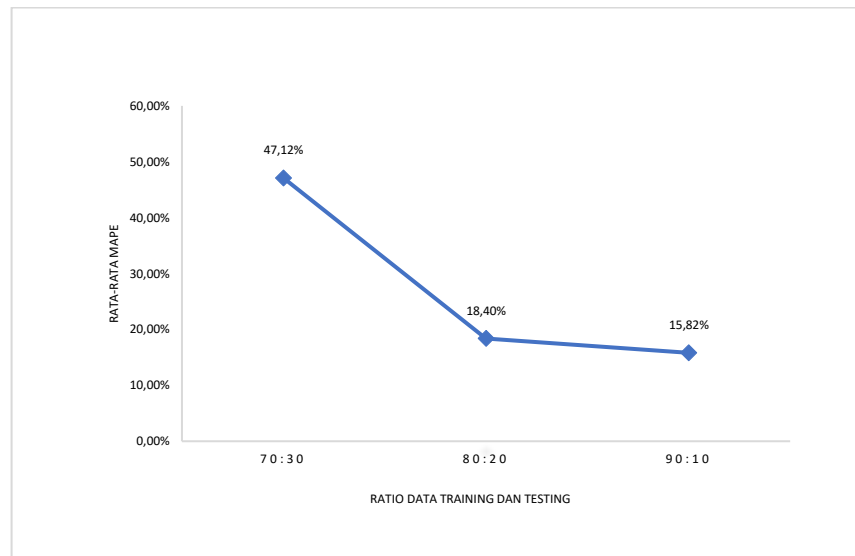
Grafik pada gambar 4.5 merupakan hasil rata-rata nilai MAPE yang dihasilkan dari pengujian jumlah ukuran *batch* pada Rasio 70:30, 80:20, dan 90:10.



Gambar 4.5 Grafik hasil pengujian jumlah *batch*

Pada gambar 4.5 warna biru mewakili rata-rata nilai MAPE dari pengujian ukuran *batch* pada rasio 70:30, sedangkan warna jingga mewakili rata-rata nilai MAPE dari pengujian ukuran *batch* pada rasio 80:20, dan warna abu-abu mewakili rata-rata nilai MAPE dari pengujian ukuran *batch* pada rasio 90:10. Hasil pengujian ukuran *batch* menunjukkan bahwa semakin besar ukuran *batch* dan semakin sedikit data *train* yang dipakai membuat MAPE yang dihasilkan menjadi semakin tinggi. Sedangkan pada data *train* yang lebih banyak dengan ukuran *batch* yang semakin kecil, membuat rata-rata nilai MAPE menurun.

Grafik pada gambar 4.6 merupakan hasil rata-rata nilai MAPE yang dihasilkan dari pengujian rasio data *training* dan *testing*.



Gambar 4.6 Grafik hasil pengujian rasio data *training* dan *testing*

Berdasarkan gambar 4.6 rata-rata MAPE terbaik didapatkan dari rasio data *training* dan *testing* sebesar 90:10. Nilai rata-rata MAPE tersebut menunjukkan bahwa semakin banyak data yang digunakan dalam *training* model LSTM maka semakin banyak pola yang dapat diidentifikasi oleh model untuk dipelajari. Akan tetapi semakin sedikit data yang dipelajari oleh model maka semakin sedikit juga pola data yang dapat dipelajari oleh model sehingga mengakibatkan model kesulitan dalam mengenali pola pada data baru dan membuat model rentan mengalami *underrfitting*.

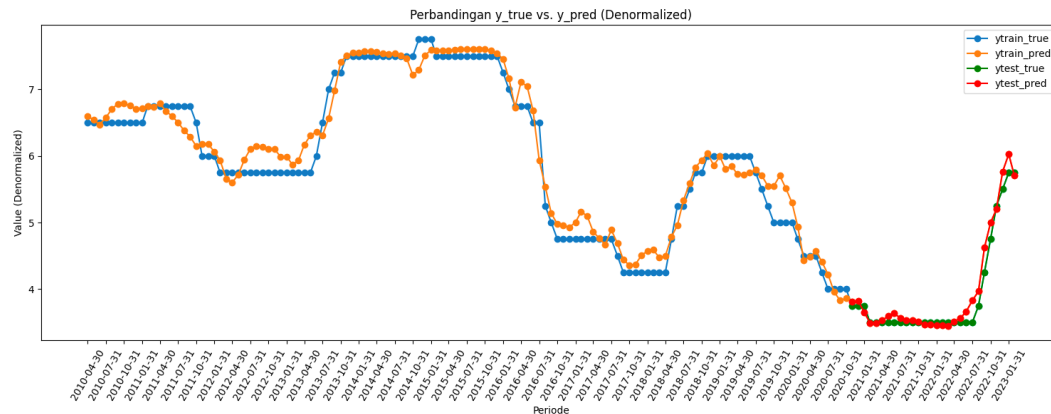
Berbagai perlakuan yang telah dilakukan, terlampir dalam lampiran 2, 3, dan 4, berupa tabel perlakuan dan hasil pengujian pada Rasio 70:30, 80:20, dan 90:10. Untuk merangkum keseluruhan percobaan, pada tabel 4.13 ditampilkan hasil MAPE teratas dari masing perlakuan pada rasio 70:30, 80:20, dan 90:10.

Tabel 4.13 Tabel hasil pengujian MAPE terendah dari masing-masing rasio

Rasio	Neuron	Learning Rate	Epoch	Batch Size	MAPE
70:30	3	0.009	50	16	22.019%
80:20	3	0.01	150	8	4.760%
90:10	3	0.02	100	16	7.984%

Dari tabel 4.13 dapat dilihat bahwa pada pengujian dengan rasio 70:30, didapatkan nilai MAPE terbaik yaitu sebesar 22,019%. Peningkatan rasio data *training* sejalan dengan penurunan nilai MAPE, hal ini menunjukkan kemungkinan bahwa sebelumnya data belum cukup belajar sehingga kesulitan untuk mengenali pola data baru sehingga pada rasio 80:20 didapatkan nilai MAPE terbaik sebesar 4.760%. Namun, pada peningkatan jumlah data *training* yang lebih banyak nilai MAPE kembali turun, hal ini menunjukkan bahwa model mungkin mengalami kesulitan dalam mengeneralisasi pola data baru karena terlalu fokus belajar pada pola data *training* sehingga pada rasio data 90:10 diperoleh nilai MAPE terbaik sebesar 7,984%.

Dari semua perlakuan yang diujikan, didapatkan model prediksi terbaik ada pada rasio 80:20 dengan kombinasi pada *neuron* 3, *learning rate* 0,01, *epoch* 150, dan *batch size* 8. Dari kombinasi tersebut diperoleh nilai MAPE sebesar 4.760%. Dalam kriteria evaluasi model dengan nilai MAPE 4,76001611811051% termasuk ke dalam kategori *highly accurate* yang berarti model sangat akurat karena berada di bawah 10%. Pada gambar 4.7, ditampilkan hasil prediksi dari model terbaik.



Gambar 4.7 Model dengan parameter terbaik

Untuk menggambarkan hasil prediksi dan data aktual ditunjukkan dengan grafik pada gambar 4.7 yang menampilkan empat warna yaitu warna biru untuk menampilkan data aktual dari data latih, warna jingga menampilkan hasil prediksi dari data latih, warna hijau menampilkan data aktual dari data testing, dan warna merah menampilkan hasil prediksi dari data *testing*. Pada gambar 4.7 terlihat bahwa hasil prediksi dibandingkan nilai sebenarnya pada data testing tidak jauh berbeda karena titik keduanya banyak yang berhimpit. Hal ini menunjukkan bahwa model memiliki akurasi yang tinggi pada *testing*.

Tabel 4.14 Hasil prediksi dengan kombinasi parameter terbaik

Periode	Data Aktual	Hasil Prediksi
2020-11-30	3,75	3,816050
2020-12-31	3,75	3,822088
2021-01-31	3,75	3,650133
2021-02-28	3,5	3,493188
2021-03-31	3,5	3,486108
2021-04-30	3,5	3,528623
2021-05-31	3,5	3,594761
2021-06-30	3,5	3,637228
2021-07-31	3,5	3,569538
2021-08-31	3,5	3,532440
2021-09-30	3,5	3,531421
2021-10-31	3,5	3,510390
2021-11-30	3,5	3,469959

Lanjutan tabel hasil prediksi dengan kombinasi parameter terbaik

Periode	Data Aktual	Hasil Prediksi
2021-12-31	3,5	3,469103
2022-01-31	3,5	3,458035
2022-02-28	3,5	3,460271
2022-03-31	3,5	3,446100
2022-04-30	3,5	3,517037
2022-05-31	3,5	3,562854
2022-06-30	3,5	3,665990
2022-07-31	3,5	3,827945
2022-08-31	3,75	3,968755
2022-09-30	4,25	4,620858
2022-10-31	4,75	4,997036
2022-11-30	5,25	5,202088
2022-12-31	5,5	5,762945
2023-01-31	5,75	6,028200
2023-02-28	5,75	5,709997
2023-03-31	5,75	5,029129
2023-04-30	5,75	4,633301
2023-05-31	5,75	4,699506
2023-06-30	5,75	3,990341

4.4 Integrasi Islam

Dengan adanya prediksi suku bunga bank Indonesia ini merupakan salah satu wujud dari muamalah ma'a An-Nas yaitu dalam wujud membantu satu sama lain sebagai bentuk saling tolong-menolong sesama umat manusia, yakni memudahkan pelaku ekonomi baik investor maupun perusahaan dalam merencanakan pengambilan tindakan yang lebih tepat untuk meminimalisasi risiko kerugian dan mengoptimalkan keuntungan muamalah ma'a An-Nas dalam bisnis mereka. Hal tersebut sejalan dengan ajaran agama, sebagaimana yang disebutkan dalam Al-Qur'an Surah Al-Baqarah ayat 195.

وَأَنْفِقُوا فِي سَبِيلِ اللَّهِ وَلَا تُلْقُوا بِأَيْدِيكُمْ إِلَى التَّهْلُكَةِ وَأَحْسِنُوا إِنَّ اللَّهَ يُحِبُّ الْمُحْسِنِينَ

“Dan belanjakanlah (harta bendamu) di jalan Allah, dan janganlah kamu menjatuhkan dirimu sendiri ke dalam kebinasaan, dan berbuat baiklah, karena sesungguhnya Allah menyukai orang-orang yang berbuat baik.”(Q.S. Al-Baqarah: 195).

Menurut Tafsir Al-Muyassar, Ayat tersebut menekankan betapa pentingnya bagi orang-orang mukmin untuk saling tolong-menolong dalam kebaikan. Tolong menolong tidak selalu berwujud bantuan materi, tetapi juga dukungan moral dan spiritual. Penolakan untuk berinfak dan membantu sesama dapat menguatkan orang-orang kafir dan menimbulkan ancaman terhadap agama Islam. Oleh karena itu, umat Muslim diminta untuk selalu siap membantu sesama dengan hati yang tulus dan ikhlas, sebagai bentuk bukti penghormatan terhadap ajaran Allah Subhanahu wa Ta'ala dan sebagai kesempatan untuk mendapatkan pahala dan ridha-Nya (Kojin Mashudi, 2020).

Dengan dilakukannya penelitian ini, diharapkan dapat mengungkapkan tingkat *error* dari penggunaan algoritma LSTM dalam memberikan prediksi nilai *BI Rate*. Hasil penelitian ini diharapkan dapat memberikan pertimbangan yang berguna bagi para pengambil keputusan dan peneliti, baik dalam pengelolaan keuangan maupun penelitian terkait prediksi *BI Rate* atau bidang lainnya.

Sebagai bentuk pengamalan dari muamalah ma'a Allah, manusia diarahkan untuk selalu bertaqwa kepada Allah Subhanahu wa Ta'ala serta merenungi tindakan yang telah diperbuat dan diikuti penyusunan perencanaan yang bijaksana untuk masa depan, sebagaimana yang tertera dalam surat Al-Hasyr ayat 18.

يَا أَيُّهَا الَّذِينَ آمَنُوا اتَّقُوا اللَّهَ وَلْتَنْظُرْ نَفْسٌ مَّا قَدَّمَتْ لِغَدٍ وَاتَّقُوا اللَّهَ ۚ إِنَّ اللَّهَ خَبِيرٌ بِمَا تَعْمَلُونَ

“Wahai orang-orang yang beriman, bertakwalah kepada Allah dan hendaklah setiap orang memperhatikan apa yang telah diperbuatnya untuk hari esok (akhirat). Bertakwalah kepada Allah. Sesungguhnya Allah Mahateliti terhadap apa yang kamu kerjakan.” (Q.S. Al-Hasyr: 18).

Allah Subhaanahu wa Ta'aala telah menekankan kepada hamba-Nya yang beriman untuk mengikuti kehendak-Nya serta menerima tanggung jawab dari iman mereka. yaitu dengan menjaga takwa kepada Allah Subhaanahu wa Ta'aala dalam segala situasi. Umat manusia diperintahkan untuk mematuhi perintah Allah Subhanahu wa Ta'ala dan menjauhi larangan-Nya, serta diperingatkan untuk memperhatikan baik dan buruk dari tindakan mereka beserta konsekuensinya. Umat yang beriman menanamkan fokus pada kehidupan akhirat penting bagi mereka, baik dalam pikiran maupun perasaan, sehingga dapat berusaha dengan sungguh-sungguh untuk meningkatkan amal perbuatan yang memberikan kebahagiaan di akhirat. Umat beriman menyadari bahwa Allah Subhaanahu wa Ta'aala selalu melihat setiap tindakan mereka dan tidak ada yang tersembunyi dari-Nya sehingga semua amal perbuatan tidak ada yang sia-sia karena tidak ada yang akan luput dari perhatian-Nya. Kesadaran ini mendorong umat beriman untuk lebih gigih dalam melakukan amal perbuatan yang benar dan bermanfaat di hari Kiamat (Ghoffar, 2004).

Dari tafsir Ibnu Katsir, ditekankan pentingnya introspeksi diri serta muhasabah. Setiap individu ditekankan untuk selalu menilai dirinya sendiri. Ketika umat beriman melakukan kesalahan, mereka diharapkan segera memperbaikinya dengan cara mengakui dosa, bertaubat dengan sungguh-sungguh, serta menjauhi

segala perilaku yang memungkinkan membawa mereka kembali mengulangi kesalahan tersebut. Ketika orang beriman menyadari bahwa mereka belum cukup berusaha dalam menjalankan perintah Allah Subhanahu wa Ta'ala, mereka diminta untuk berusaha lebih keras, memohon pertolongan-Nya guna memperbaiki diri, serta selalu membandingkan anugerah dan kebaikan yang diberikan Allah Subhanahu wa Ta'ala dengan tingkat kemalasan mereka, sehingga mereka merasa malu atas kekurangan mereka.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini berfokus pada penggunaan metode LSTM untuk memprediksi suku bunga Bank Indonesia dengan mempertimbangkan berbagai rasio pembagian data yaitu 70:30, 80:20, dan 90:10. Hasil penelitian menunjukkan bahwa nilai MAPE bervariasi tergantung pada rasio data *training* dan *testing* serta parameter yang digunakan. Model terpilih dari penelitian yang dilakukan adalah model dengan rasio data *training* dan *testing* sebesar 80:20 serta kombinasi parameter *neuron* 3, *learning rate* 0,01, *epoch* 150, dan *batch size* 8. Model ini dipilih, karena dari seluruh perlakuan yang telah dilakukan, model ini mendapatkan nilai MAPE paling rendah yaitu 4.760%. Menurut evaluasi nilai MAPE model terpilih tersebut termasuk ke dalam kategori *highly accurate* yang berarti model sangat akurat karena nilai MAPE yang dihasilkan kurang dari 10%. Semakin kecil nilai MAPE yang dihasilkan maka semakin baik pula akurasi prediksi yang dihasilkan oleh model.

5.2 Saran

Peneliti menyadari bahwa penelitian ini masih mempunyai kekurangan, sehingga diharapkan pada penelitian selanjutnya terdapat peningkatan juga perbaikan untuk menyempurnakan hasil yang lebih baik. Berikut beberapa saran dari peneliti yang diharapkan dapat memberikan kontribusi pada penelitian selanjutnya:

1. Mencoba skenario nilai parameter yang lebih bervariasi untuk *learning rate*, *batch size*, *epoch*, dan jumlah *neuron* atau menambahkan metode regulasi seperti dropout pada hidden layer agar mendapatkan nilai MAPE yang semakin mendekati 0.
2. Penelitian selanjutnya dapat mencoba menggunakan metode optimasi yang berbeda.
3. Menambahkan fitur pada penelitian sesuai dengan dataset yang didapatkan.

DAFTAR PUSTAKA

- Adli, N., Darmawand, A., Ratnawati, D. E., & Perdana, R. S. (2018). Prediksi Suku Bunga Acuan (BI Rate) Menggunakan Metode Adaptive Neuro Fuzzy Inference System (ANFIS). *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(1), 2548–2964. <http://j-ptiik.ub.ac.id>
- Akbar, R., Santoso, R., & Warsito, B. (2023). Prediksi Tingkat Temperatur Kota Semarang Menggunakan Metode Long Short-Term Memory (LSTM). *Jurnal Gaussian*, 11(4), 572–579. <https://doi.org/10.14710/j.gauss.11.4.572-579>
- Alim, M. A., Cnn-Lstm, C., & Arima, D. (2023). Pemodelan Time Series Data Saham LQ45 dengan Algoritma LSTM, RNN, dan Arima. *Prosiding Seminar Nasional Matematika*, 6, 694–701. <https://journal.unnes.ac.id/sju/index.php/prisma/>
- Al-Quran Kementerian Agama RI. (2015). *Alquran dan Terjemahannya*. Latjnah Pentashihan Mushaf Al-Quran.
- Anggrainingsih, R., Aprianto, G. R., & Sihwi, S. W. (2015). Time Series Forecasting Using Exponential Smoothing To Predict The Number of Website Visitor of Sebelas Maret University. *IEEE*.
- Bank Indonesia. (2016). *Inflasi*. Bank Indonesia. <https://www.bi.go.id/id/fungsi-utama/moneter/inflasi/default.aspx>
- Bodapati, S., Bandarupally, H., & Trupthi, M. (2020). COVID-19 Time Series Forecasting of Daily Cases, Deaths Caused and Recovered Cases using Long Short Term Memory Networks. *2020 IEEE 5th International Conference on Computing Communication and Automation, ICCCA 2020*, 525–530. <https://doi.org/10.1109/ICCCA49541.2020.9250863>
- Budiprasetyo, G., Hani'ah, M., & Aflah, D. Z. (2023). Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM). *Jurnal Nasional Teknologi Dan Sistem Informasi*, 8(3), 164–172. <https://doi.org/10.25077/teknosi.v8i3.2022.164-172>
- Cahyani, J., Mujahidin, S., & Fiqar, T. P. (2023). Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional. *Jurnal Sistem Dan Teknologi Informasi (JustIN)*, 11(2), 346. <https://doi.org/10.26418/justin.v11i2.57395>
- Chandranegara, D. R., Afif, R. A., Aditya, C. S. K., Suharso, W., & Wibowo, H. (2023). Prediksi Harga Saham Jakarta Islamic Index Menggunakan Metode

Long Short-Term Memory. *JEPIN (Jurnal Edukasi Dan Penelitian Informatika)*.

Ghoffar, M. A. (2004). *Tafsir Ibnu Katsir Jilid 8*. Pustaka Imam asy-Syafi'i.

Herania, E., Ekonomi dan Bisnis, F., Herania Fakultas Ekonomi dan Bisnis, E., Brawijaya, U., & Ghozali Maski, I. (2022). Pengaruh Jumlah Uang Beredar, Suku Bunga Dan Nilai Tukar Terhadap Tingkat Inflasi Di Indonesia Menggunakan Pendekatan Analisis Jalur Periode 2010Q1 2020Q4. *CONTEMPORARY STUDIES IN ECONOMIC, FINANCE AND BANKING*. <https://doi.org/10.21776/csefb.2022.01.2.05>

HR Muslim. (n.d.). *Hadits Riwayat Muslim*.

Khan, A., Fouda, M. M., Do, D. T., Almaleh, A., & Rahman, A. U. (2023). Short-Term Traffic Prediction Using Deep Learning Long Short-Term Memory: Taxonomy, Applications, Challenges, and Future Trends. *IEEE Access*, *11*, 94371–94391. <https://doi.org/10.1109/ACCESS.2023.3309601>

Kingma, D. P., & Lei Ba, J. (2015). Adam: A Method For Stochastic Optimization. *Conference Paper at the 3rd International Conference for Learning Representations, San Diego, 2015*. <https://arxiv.org/abs/1412.6980>

Kojin Mashudi, H. (2020). *Jilid I Juz: 1-5 AL-MUYASSAR* (1st ed.). Inteligencia Media.

Lajnah Pentashihan Mushaf Al-Qur'an. (2016). *Tafsir Wajiz Jilid II, Bagian 1* (2nd ed.). Lajnah Pentashihan Mushaf Al-Qur'an.

Lewis, C. D. (1982). *Industrial and Business Forecasting Methods: A Practical Guide to Exponential Smoothing and Curve Fitting*. Butterworth Scientific.

Olah, C. (2015). *Understanding LSTM Networks*. <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

Orpa, E. P. K., Ripanti, E. F., & Tursina. (2019). Model Prediksi Awal Masa Studi Mahasiswa Menggunakan Algoritma Decision tree c4.5. *JUSTIN (Jurnal Sistem Dan Teknologi Informasi)*, *7*.

Putri, Y. Y., Adikara, P. P., & Adinugroho, S. (2019). Prediksi Suku Bunga Acuan (BI 7-Day Repo Rate) Menggunakan Metode Extreme Learning Machine (ELM). *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, *3*(5), 4251–4258. <http://j-ptiik.ub.ac.id>

Rahmat, W. M., Hidayat, N., & Soebroto, A. A. (2023). Prediksi Penjualan Ponsel Pintar menggunakan Metode Jaringan Syaraf Tiruan Backpropagation

- Kombinasi Particle Swarm Optimization. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 7(1), 439–445. <http://j-ptiik.ub.ac.id>
- Sianturi, T. B., Cholissodin, I., & Yudistira, N. (2023). *Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum* (Vol. 7, Issue 3). <http://j-ptiik.ub.ac.id>
- Siregar, D. I. (2021). Prediction of Bank Indonesia Interest Rates By Analyzing Inflation Rate in Indonesia From 2003 – 2016. *Journal of Accounting & Marketing*.
- Sovia, R., Yanto, M., Gema, R. L., & Fernando, R. (2019). Bank Indonesia Interest Rate Prediction and Forecast With Backpropagation Neural Network. *IEEE*. <https://doi.org/10.1109/ICITSI.2018.8695914>
- Tania Emanuella, C., & Armin Lawi, dan. (2021). Konferensi Nasional Ilmu Komputer (KONIK) 2021 Klasifikasi Suara Kucing dan Anjing Menggunakan Convolutional Neural Network. *Konferensi Nasional Ilmu Komputer (KONIK)*.
- Wahyuni, R. E., Provinsi, B., & Tengah, J. (2021). Optimasi Prediksi Inflasi Dengan Neural Network Pada Tahap Windowing: Adakah Pengaruh Perbedaan Window Size? In *Technologia* (Vol. 12, Issue 3).
- Wang, Z., & Bovik, A. C. (2009). Mean squared error: Lot it or leave it? A new look at signal fidelity measures. *IEEE Signal Processing Magazine*, 26(1), 98–117. <https://doi.org/10.1109/MSP.2008.930649>
- World Bank. (2022). *GDP(current US\$) - Indonesia*. The World Bank. <https://data.worldbank.org/indicator/NY.GDP.MKTP.CD?locations=ID>
- Zahara, S., Sugianto, & Bahril Ilmiddafiq, M. (2017). Prediksi Indeks Harga Konsumen Menggunakan Metode Long Short Term Memory (LSTM) Berbasis Cloud Computing. *Masa Berlaku Mulai*, 1(3), 357–363.
- Zen Kemu α , S., & Syahrir Ika α . (2016). Transmisi BI Rate sebagai Instrumen untuk Mencapai Sasaran Kebijakan Moneter Transmission of BI Rate as an instrument to achieve monetary policy goals. *Kajian Ekonomi & Keuangan*, 20(3). <http://fiskal.kemenkeu.go.id/ejournal>

LAMPIRAN-LAMPIRAN

Lampiran 1. Tabel Kombinasi Parameter dari Model yang Diujikan

No	Neuron	Learning rate	Epoch	Batch Size
1	3	0.009	50	4
2	3	0.009	50	8
3	3	0.009	50	16
4	3	0.009	100	4
5	3	0.009	100	8
6	3	0.009	100	16
7	3	0.009	150	4
8	3	0.009	150	8
9	3	0.009	150	16
10	3	0.009	200	4
11	3	0.009	200	8
12	3	0.009	200	16
13	3	0.02	50	4
14	3	0.02	50	8
15	3	0.02	50	16
16	3	0.02	100	4
17	3	0.02	100	8
18	3	0.02	100	16
19	3	0.02	150	4
20	3	0.02	150	8
21	3	0.02	150	16
22	3	0.02	200	4
23	3	0.02	200	8
24	3	0.02	200	16
25	3	0.01	50	4
26	3	0.01	50	8
27	3	0.01	50	16
28	3	0.01	100	4
29	3	0.01	100	8
30	3	0.01	100	16
31	3	0.01	150	4
32	3	0.01	150	8
33	3	0.01	150	16
34	3	0.01	200	4
35	3	0.01	200	8

Lanjutan Lampiran Tabel Kombinasi Parameter dari Model yang Diujikan

No	Neuron	Learning rate	Epoch	Batch Size
36	3	0.01	200	16
37	6	0.009	50	4
38	6	0.009	50	8
39	6	0.009	50	16
40	6	0.009	100	4
41	6	0.009	100	8
42	6	0.009	100	16
43	6	0.009	150	4
44	6	0.009	150	8
45	6	0.009	150	16
46	6	0.009	200	4
47	6	0.009	200	8
48	6	0.009	200	16
49	6	0.02	50	4
50	6	0.02	50	8
51	6	0.02	50	16
52	6	0.02	100	4
53	6	0.02	100	8
54	6	0.02	100	16
55	6	0.02	150	4
56	6	0.02	150	8
57	6	0.02	150	16
58	6	0.02	200	4
59	6	0.02	200	8
60	6	0.02	200	16
61	6	0.01	50	4
62	6	0.01	50	8
63	6	0.01	50	16
64	6	0.01	100	4
65	6	0.01	100	8
66	6	0.01	100	16
67	6	0.01	150	4
68	6	0.01	150	8
69	6	0.01	150	16
70	6	0.01	200	4
71	6	0.01	200	8
72	6	0.009	200	16
73	12	0.009	50	4

Lanjutan Lampiran Tabel Kombinasi Parameter dari Model yang Diujikan

No	Neuron	Learning rate	Epoch	Batch Size
74	12	0.009	50	8
75	12	0.009	50	16
76	12	0.009	100	4
77	12	0.009	100	8
78	12	0.009	100	16
79	12	0.009	150	4
80	12	0.009	150	8
81	12	0.009	150	16
82	12	0.009	200	4
83	12	0.009	200	8
84	12	0.009	200	16
85	12	0.02	50	4
86	12	0.02	50	8
87	12	0.02	50	16
88	12	0.02	100	4
89	12	0.02	100	8
90	12	0.02	100	16
91	12	0.02	150	4
92	12	0.02	150	8
93	12	0.02	150	16
94	12	0.02	200	4
95	12	0.02	200	8
96	12	0.02	200	16
97	12	0.01	50	4
98	12	0.01	50	8
99	12	0.01	50	16
100	12	0.01	100	4
101	12	0.01	100	8
102	12	0.01	100	16
103	12	0.01	150	4
104	12	0.01	150	8
105	12	0.01	150	16
106	12	0.01	200	4
107	12	0.01	200	8
108	12	0.01	200	16
109	24	0.009	50	4
110	24	0.009	50	8
111	24	0.009	50	16

Lanjutan Lampiran Tabel Kombinasi Parameter dari Model yang Diujikan

No	Neuron	Learning rate	Epoch	Batch Size
112	24	0.009	100	4
113	24	0.009	100	8
114	24	0.009	100	16
115	24	0.009	150	4
116	24	0.009	150	8
117	24	0.009	150	16
118	24	0.009	200	4
119	24	0.009	200	8
120	24	0.009	200	16
121	24	0.02	50	4
122	24	0.02	50	8
123	24	0.02	50	16
124	24	0.02	100	4
125	24	0.02	100	8
126	24	0.02	100	16
127	24	0.02	150	4
128	24	0.02	150	8
129	24	0.02	150	16
130	24	0.02	200	4
131	24	0.02	200	8
132	24	0.02	200	16
133	24	0.01	50	4
134	24	0.01	50	8
135	24	0.01	50	16
136	24	0.01	100	4
137	24	0.01	100	8
138	24	0.01	100	16
139	24	0.01	150	4
140	24	0.01	150	8
141	24	0.01	150	16
142	24	0.01	200	4
143	24	0.01	200	8
144	24	0.01	200	16

Lampiran 2. Tabel Perlakuan dan Hasil Pengujian pada Rasio 70:30

No	Neuron	Learning Rate	Epoch	Batch Size	MAPE
1	3	0.009	50	4	37.146%
2	3	0.009	50	8	27.050%
3	3	0.009	50	16	22.019%
4	3	0.009	100	4	37.669%
5	3	0.009	100	8	47.919%
6	3	0.009	100	16	37.010%
7	3	0.009	150	4	54.927%
8	3	0.009	150	8	60.826%
9	3	0.009	150	16	45.012%
10	3	0.009	200	4	54.617%
11	3	0.009	200	8	60.218%
12	3	0.009	200	16	50.228%
13	3	0.02	50	4	38.471%
14	3	0.02	50	8	36.298%
15	3	0.02	50	16	26.812%
16	3	0.02	100	4	45.432%
17	3	0.02	100	8	49.413%
18	3	0.02	100	16	49.528%
19	3	0.02	150	4	42.924%
20	3	0.02	150	8	57.289%
21	3	0.02	150	16	59.380%
22	3	0.02	200	4	40.603%
23	3	0.02	200	8	55.934%
24	3	0.02	200	16	57.175%
25	3	0.01	50	4	39.481%
26	3	0.01	50	8	27.906%
27	3	0.01	50	16	22.772%
28	3	0.01	100	4	40.239%
29	3	0.01	100	8	48.296%
30	3	0.01	100	16	38.793%
31	3	0.01	150	4	56.015%
32	3	0.01	150	8	62.336%
33	3	0.01	150	16	41.185%
34	3	0.01	200	4	52.608%
35	3	0.01	200	8	60.075%
36	3	0.01	200	16	50.961%
37	6	0.009	50	4	47.532%
38	6	0.009	50	8	36.082%
39	6	0.009	50	16	24.808%
40	6	0.009	100	4	50.323%

Lanjutan Lampiran Tabel Perlakuan dan Hasil Pengujian pada Rasio 70:30

No	Neuron	Learning Rate	Epoch	Batch Size	MAPE
41	6	0.009	100	8	44.155%
42	6	0.009	100	16	36.122%
43	6	0.009	150	4	40.349%
44	6	0.009	150	8	52.478%
45	6	0.009	150	16	47.983%
46	6	0.009	200	4	44.916%
47	6	0.009	200	8	52.587%
48	6	0.009	200	16	49.772%
49	6	0.02	50	4	50.693%
50	6	0.02	50	8	56.382%
51	6	0.02	50	16	41.829%
52	6	0.02	100	4	39.387%
53	6	0.02	100	8	52.920%
54	6	0.02	100	16	54.501%
55	6	0.02	150	4	44.826%
56	6	0.02	150	8	50.233%
57	6	0.02	150	16	51.842%
58	6	0.02	200	4	45.928%
59	6	0.02	200	8	47.551%
60	6	0.02	200	16	51.403%
61	6	0.01	50	4	49.086%
62	6	0.01	50	8	37.758%
63	6	0.01	50	16	27.226%
64	6	0.01	100	4	50.567%
65	6	0.01	100	8	45.318%
66	6	0.01	100	16	37.054%
67	6	0.01	150	4	41.336%
68	6	0.01	150	8	49.896%
69	6	0.01	150	16	48.376%
70	6	0.01	200	4	43.667%
71	6	0.01	200	8	51.289%
72	6	0.01	200	16	48.094%
73	12	0.009	50	4	55.638%
74	12	0.009	50	8	53.997%
75	12	0.009	50	16	43.112%
76	12	0.009	100	4	52.952%
77	12	0.009	100	8	53.412%
78	12	0.009	100	16	52.807%
79	12	0.009	150	4	43.565%
80	12	0.009	150	8	47.890%
81	12	0.009	150	16	45.141%

Lanjutan Lampiran Tabel Perlakuan dan Hasil Pengujian pada Rasio 70:30

No	Neuron	Learning Rate	Epoch	Batch Size	MAPE
82	12	0.009	200	4	49.368%
83	12	0.009	200	8	49.182%
84	12	0.009	200	16	45.233%
85	12	0.02	50	4	54.568%
86	12	0.02	50	8	55.441%
87	12	0.02	50	16	51.077%
88	12	0.02	100	4	50.570%
89	12	0.02	100	8	43.985%
90	12	0.02	100	16	50.830%
91	12	0.02	150	4	41.446%
92	12	0.02	150	8	46.817%
93	12	0.02	150	16	49.304%
94	12	0.02	200	4	45.275%
95	12	0.02	200	8	47.981%
96	12	0.02	200	16	50.799%
97	12	0.01	50	4	55.659%
98	12	0.01	50	8	55.379%
99	12	0.01	50	16	53.353%
100	12	0.01	100	4	52.040%
101	12	0.01	100	8	48.814%
102	12	0.01	100	16	52.250%
103	12	0.01	150	4	43.512%
104	12	0.01	150	8	47.111%
105	12	0.01	150	16	43.373%
106	12	0.01	200	4	50.154%
107	12	0.01	200	8	47.974%
108	12	0.01	200	16	45.862%
109	24	0.009	50	4	51.814%
110	24	0.009	50	8	50.352%
111	24	0.009	50	16	25.533%
112	24	0.009	100	4	48.056%
113	24	0.009	100	8	46.282%
114	24	0.009	100	16	51.738%
115	24	0.009	150	4	44.358%
116	24	0.009	150	8	49.587%
117	24	0.009	150	16	49.844%
118	24	0.009	200	4	30.940%
119	24	0.009	200	8	50.073%
120	24	0.009	200	16	52.105%
121	24	0.02	50	4	52.182%
122	24	0.02	50	8	58.973%

Lanjutan Lampiran Tabel Perlakuan dan Hasil Pengujian pada Rasio 70:30

No	Neuron	Learning Rate	Epoch	Batch Size	MAPE
123	24	0.02	50	16	56.117%
124	24	0.02	100	4	46.909%
125	24	0.02	100	8	45.176%
126	24	0.02	100	16	50.406%
127	24	0.02	150	4	43.517%
128	24	0.02	150	8	42.256%
129	24	0.02	150	16	50.431%
130	24	0.02	200	4	45.272%
131	24	0.02	200	8	47.027%
132	24	0.02	200	16	50.365%
133	24	0.01	50	4	51.922%
134	24	0.01	50	8	59.282%
135	24	0.01	50	16	39.026%
136	24	0.01	100	4	49.026%
137	24	0.01	100	8	48.918%
138	24	0.01	100	16	48.423%
139	24	0.01	150	4	43.982%
140	24	0.01	150	8	50.912%
141	24	0.01	150	16	49.525%
142	24	0.01	200	4	49.497%
143	24	0.01	200	8	49.420%
144	24	0.01	200	16	51.772%

Lampiran 3. Tabel Perlakuan dan Hasil Pengujian pada Rasio 80:20

No	Neuron	Learning Rate	Epoch	Batch Size	MAPE
1	3	0.009	50	4	24.197%
2	3	0.009	50	8	25.967%
3	3	0.009	50	16	22.084%
4	3	0.009	100	4	5.344%
5	3	0.009	100	8	8.507%
6	3	0.009	100	16	26.459%
7	3	0.009	150	4	14.529%
8	3	0.009	150	8	6.796%
9	3	0.009	150	16	7.939%
10	3	0.009	200	4	14.067%
11	3	0.009	200	8	9.956%
12	3	0.009	200	16	7.670%
13	3	0.02	50	4	29.437%
14	3	0.02	50	8	24.363%
15	3	0.02	50	16	21.991%
16	3	0.02	100	4	21.399%
17	3	0.02	100	8	14.063%
18	3	0.02	100	16	9.892%
19	3	0.02	150	4	31.435%
20	3	0.02	150	8	15.065%
21	3	0.02	150	16	5.358%
22	3	0.02	200	4	27.456%
23	3	0.02	200	8	15.868%
24	3	0.02	200	16	12.744%
25	3	0.01	50	4	24.284%
26	3	0.01	50	8	27.240%
27	3	0.01	50	16	23.447%
28	3	0.01	100	4	5.470%
29	3	0.01	100	8	8.339%
30	3	0.01	100	16	24.930%
31	3	0.01	150	4	15.180%
32	3	0.01	150	8	4.760%
33	3	0.01	150	16	8.093%
34	3	0.01	200	4	14.288%
35	3	0.01	200	8	16.789%
36	3	0.01	200	16	9.099%
37	6	0.009	50	4	24.926%
38	6	0.009	50	8	23.648%
39	6	0.009	50	16	26.770%
40	6	0.009	100	4	21.083%

Lanjutan Lampiran Tabel Perlakuan dan Hasil Pengujian pada Rasio 80:20

No	Neuron	Learning Rate	Epoch	Batch Size	MAPE
41	6	0.009	100	8	16.945%
42	6	0.009	100	16	17.329%
43	6	0.009	150	4	15.999%
44	6	0.009	150	8	19.024%
45	6	0.009	150	16	21.479%
46	6	0.009	200	4	12.947%
47	6	0.009	200	8	13.344%
48	6	0.009	200	16	19.001%
49	6	0.02	50	4	14.362%
50	6	0.02	50	8	28.759%
51	6	0.02	50	16	26.337%
52	6	0.02	100	4	14.758%
53	6	0.02	100	8	19.288%
54	6	0.02	100	16	16.617%
55	6	0.02	150	4	18.503%
56	6	0.02	150	8	19.894%
57	6	0.02	150	16	18.708%
58	6	0.02	200	4	24.773%
59	6	0.02	200	8	16.489%
60	6	0.02	200	16	16.512%
61	6	0.01	50	4	24.875%
62	6	0.01	50	8	23.090%
63	6	0.01	50	16	33.965%
64	6	0.01	100	4	21.777%
65	6	0.01	100	8	16.156%
66	6	0.01	100	16	16.466%
67	6	0.01	150	4	15.698%
68	6	0.01	150	8	19.171%
69	6	0.01	150	16	20.053%
70	6	0.01	200	4	13.750%
71	6	0.01	200	8	13.211%
72	6	0.01	200	16	18.734%
73	12	0.009	50	4	16.341%
74	12	0.009	50	8	30.833%
75	12	0.009	50	16	19.363%
76	12	0.009	100	4	16.383%
77	12	0.009	100	8	19.375%
78	12	0.009	100	16	20.707%
79	12	0.009	150	4	18.433%
80	12	0.009	150	8	18.313%
81	12	0.009	150	16	21.960%

Lanjutan Lampiran Tabel Perlakuan dan Hasil Pengujian pada Rasio 80:20

No	Neuron	Learning Rate	Epoch	Batch Size	MAPE
82	12	0.009	200	4	17.283%
83	12	0.009	200	8	16.470%
84	12	0.009	200	16	22.507%
85	12	0.02	50	4	27.241%
86	12	0.02	50	8	29.433%
87	12	0.02	50	16	23.226%
88	12	0.02	100	4	16.270%
89	12	0.02	100	8	18.946%
90	12	0.02	100	16	14.617%
91	12	0.02	150	4	16.072%
92	12	0.02	150	8	19.248%
93	12	0.02	150	16	16.051%
94	12	0.02	200	4	17.067%
95	12	0.02	200	8	23.207%
96	12	0.02	200	16	15.247%
97	12	0.01	50	4	10.094%
98	12	0.01	50	8	28.242%
99	12	0.01	50	16	20.938%
100	12	0.01	100	4	16.040%
101	12	0.01	100	8	17.349%
102	12	0.01	100	16	18.911%
103	12	0.01	150	4	15.911%
104	12	0.01	150	8	18.817%
105	12	0.01	150	16	17.156%
106	12	0.01	200	4	15.910%
107	12	0.01	200	8	12.745%
108	12	0.01	200	16	22.393%
109	24	0.009	50	4	19.382%
110	24	0.009	50	8	40.246%
111	24	0.009	50	16	16.387%
112	24	0.009	100	4	19.908%
113	24	0.009	100	8	18.171%
114	24	0.009	100	16	16.229%
115	24	0.009	150	4	16.850%
116	24	0.009	150	8	17.354%
117	24	0.009	150	16	17.402%
118	24	0.009	200	4	17.276%
119	24	0.009	200	8	15.771%
120	24	0.009	200	16	13.538%
121	24	0.02	50	4	11.416%
122	24	0.02	50	8	21.790%

Lanjutan Lampiran Tabel Perlakuan dan Hasil Pengujian pada Rasio 80:20

No	Neuron	Learning Rate	Epoch	Batch Size	MAPE
123	24	0.02	50	16	31.151%
124	24	0.02	100	4	21.543%
125	24	0.02	100	8	17.756%
126	24	0.02	100	16	16.363%
127	24	0.02	150	4	17.588%
128	24	0.02	150	8	14.778%
129	24	0.02	150	16	16.618%
130	24	0.02	200	4	18.341%
131	24	0.02	200	8	15.347%
132	24	0.02	200	16	16.212%
133	24	0.01	50	4	14.811%
134	24	0.01	50	8	37.950%
135	24	0.01	50	16	19.518%
136	24	0.01	100	4	17.854%
137	24	0.01	100	8	18.606%
138	24	0.01	100	16	15.666%
139	24	0.01	150	4	20.098%
140	24	0.01	150	8	17.341%
141	24	0.01	150	16	17.483%
142	24	0.01	200	4	14.274%
143	24	0.01	200	8	16.867%
144	24	0.01	200	16	13.823%

Lampiran 4. Tabel Perlakuan dan Hasil Pengujian pada Rasio 90:10

No	Neuron	Learning Rate	Epoch	Batch Size	MAPE
1	3	0.009	50	4	15.660%
2	3	0.009	50	8	14.398%
3	3	0.009	50	16	11.875%
4	3	0.009	100	4	11.382%
5	3	0.009	100	8	14.930%
6	3	0.009	100	16	14.749%
7	3	0.009	150	4	12.213%
8	3	0.009	150	8	12.760%
9	3	0.009	150	16	17.974%
10	3	0.009	200	4	14.622%
11	3	0.009	200	8	12.363%
12	3	0.009	200	16	11.070%
13	3	0.02	50	4	11.471%
14	3	0.02	50	8	11.272%
15	3	0.02	50	16	15.906%
16	3	0.02	100	4	10.557%
17	3	0.02	100	8	10.467%
18	3	0.02	100	16	7.984%
19	3	0.02	150	4	13.922%
20	3	0.02	150	8	13.331%
21	3	0.02	150	16	13.085%
22	3	0.02	200	4	10.638%
23	3	0.02	200	8	12.450%
24	3	0.02	200	16	13.803%
25	3	0.01	50	4	16.890%
26	3	0.01	50	8	14.921%
27	3	0.01	50	16	12.083%
28	3	0.01	100	4	12.585%
29	3	0.01	100	8	12.001%
30	3	0.01	100	16	15.156%
31	3	0.01	150	4	12.482%
32	3	0.01	150	8	13.109%
33	3	0.01	150	16	16.106%
34	3	0.01	200	4	14.284%
35	3	0.01	200	8	14.108%
36	3	0.01	200	16	10.653%
37	6	0.009	50	4	16.879%
38	6	0.009	50	8	19.475%
39	6	0.009	50	16	12.270%
40	6	0.009	100	4	16.239%

Lanjutan Lampiran Tabel Perlakuan dan Hasil Pengujian pada Rasio 90:10

No	Neuron	Learning Rate	Epoch	Batch Size	MAPE
41	6	0.009	100	8	20.026%
42	6	0.009	100	16	21.425%
43	6	0.009	150	4	13.487%
44	6	0.009	150	8	17.407%
45	6	0.009	150	16	20.205%
46	6	0.009	200	4	14.613%
47	6	0.009	200	8	14.969%
48	6	0.009	200	16	22.019%
49	6	0.02	50	4	12.199%
50	6	0.02	50	8	16.491%
51	6	0.02	50	16	23.234%
52	6	0.02	100	4	13.964%
53	6	0.02	100	8	19.366%
54	6	0.02	100	16	20.812%
55	6	0.02	150	4	12.586%
56	6	0.02	150	8	13.158%
57	6	0.02	150	16	19.770%
58	6	0.02	200	4	13.340%
59	6	0.02	200	8	12.546%
60	6	0.02	200	16	17.568%
61	6	0.01	50	4	16.455%
62	6	0.01	50	8	18.593%
63	6	0.01	50	16	13.161%
64	6	0.01	100	4	15.758%
65	6	0.01	100	8	19.509%
66	6	0.01	100	16	21.238%
67	6	0.01	150	4	15.320%
68	6	0.01	150	8	16.726%
69	6	0.01	150	16	21.047%
70	6	0.01	200	4	13.960%
71	6	0.01	200	8	14.163%
72	6	0.01	200	16	22.120%
73	12	0.009	50	4	12.948%
74	12	0.009	50	8	15.250%
75	12	0.009	50	16	11.134%
76	12	0.009	100	4	22.686%
77	12	0.009	100	8	21.886%
78	12	0.009	100	16	20.254%
79	12	0.009	150	4	17.268%
80	12	0.009	150	8	19.520%
81	12	0.009	150	16	22.897%

Lanjutan Lampiran Tabel Perlakuan dan Hasil Pengujian pada Rasio 90:10

No	Neuron	Learning Rate	Epoch	Batch Size	MAPE
82	12	0.009	200	4	15.754%
83	12	0.009	200	8	18.622%
84	12	0.009	200	16	19.853%
85	12	0.02	50	4	10.059%
86	12	0.02	50	8	13.501%
87	12	0.02	50	16	18.007%
88	12	0.02	100	4	12.991%
89	12	0.02	100	8	15.784%
90	12	0.02	100	16	17.715%
91	12	0.02	150	4	13.643%
92	12	0.02	150	8	12.502%
93	12	0.02	150	16	18.148%
94	12	0.02	200	4	10.458%
95	12	0.02	200	8	10.591%
96	12	0.02	200	16	18.722%
97	12	0.01	50	4	11.644%
98	12	0.01	50	8	14.840%
99	12	0.01	50	16	11.625%
100	12	0.01	100	4	20.606%
101	12	0.01	100	8	23.074%
102	12	0.01	100	16	17.999%
103	12	0.01	150	4	14.777%
104	12	0.01	150	8	18.949%
105	12	0.01	150	16	21.758%
106	12	0.01	200	4	15.617%
107	12	0.01	200	8	17.519%
108	12	0.01	200	16	18.850%
109	24	0.009	50	4	14.122%
110	24	0.009	50	8	15.296%
111	24	0.009	50	16	12.820%
112	24	0.009	100	4	16.458%
113	24	0.009	100	8	20.775%
114	24	0.009	100	16	23.650%
115	24	0.009	150	4	16.566%
116	24	0.009	150	8	16.835%
117	24	0.009	150	16	18.919%
118	24	0.009	200	4	13.422%
119	24	0.009	200	8	16.568%
120	24	0.009	200	16	20.362%
121	24	0.02	50	4	11.495%
122	24	0.02	50	8	13.128%

Lanjutan Lampiran Tabel Perlakuan dan Hasil Pengujian pada Rasio 90:10

No	Neuron	Learning Rate	Epoch	Batch Size	MAPE
123	24	0.02	50	16	15.705%
124	24	0.02	100	4	14.345%
125	24	0.02	100	8	15.489%
126	24	0.02	100	16	20.680%
127	24	0.02	150	4	14.068%
128	24	0.02	150	8	14.049%
129	24	0.02	150	16	18.314%
130	24	0.02	200	4	15.182%
131	24	0.02	200	8	13.514%
132	24	0.02	200	16	19.170%
133	24	0.01	50	4	15.371%
134	24	0.01	50	8	15.153%
135	24	0.01	50	16	13.376%
136	24	0.01	100	4	16.317%
137	24	0.01	100	8	20.168%
138	24	0.01	100	16	22.757%
139	24	0.01	150	4	15.536%
140	24	0.01	150	8	16.443%
141	24	0.01	150	16	18.204%
142	24	0.01	200	4	13.889%
143	24	0.01	200	8	17.051%
144	24	0.01	200	16	19.876%