

**PERBANDINGAN KINERJA ALGORITMA LSTM, BILSTM, DAN
LSTM-AM DALAM PREDIKSI HARGA SAHAM SYARIAH**

(Skripsi)

Oleh

**MUHAMAD RAMADHAN KAMAL
2157051001**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

ABSTRAK

PERBANDINGAN KINERJA ALGORITMA LSTM, BiLSTM, DAN LSTM-AM DALAM PREDIKSI HARGA SAHAM SYARIAH

Oleh

Muhamad Ramadhan Kamal

Perkembangan pasar saham syariah yang pesat menciptakan kebutuhan akan metode prediksi harga yang akurat untuk membantu investor dalam pengambilan keputusan investasi. Penelitian ini bertujuan untuk membandingkan kinerja tiga algoritma *deep learning* yaitu *Long Short-Term Memory* (LSTM), *Bidirectional LSTM* (BiLSTM), dan LSTM dengan *Attention Mechanism* (LSTM-AM) dalam memprediksi harga saham syariah. Data penelitian menggunakan harga penutupan harian dari lima emiten saham syariah (ANTM, ERAA, KLBF, SMGR, dan WIKA) periode Desember 2016 hingga Desember 2021 yang diperoleh dari *Yahoo Finance*. Metodologi penelitian meliputi tahapan *preprocessing* data menggunakan *Robust Scaling*, pembentukan *time series* dengan time steps 60 hari, *hyperparameter tuning* menggunakan Keras Tuner, dan evaluasi model menggunakan *window cross-validation* dengan 5-fold. Evaluasi kinerja model dilakukan menggunakan metrik *Mean Absolute Percentage Error* (MAPE), *Root Mean Squared Error* (RMSE), dan *R-squared* (R^2). Hasil penelitian menunjukkan bahwa BiLSTM memberikan performa terbaik dengan nilai MAPE rata-rata 9,41%, diikuti oleh LSTM dengan 11,87%, sedangkan LSTM-AM memiliki nilai MAPE tertinggi yaitu 19,58%. Model BiLSTM mampu menangkap pola temporal dari dua arah (maju dan mundur) sehingga memberikan prediksi yang lebih akurat, terutama pada saham dengan karakteristik stabil seperti KLBF (MAPE 1,49%), SMGR (MAPE 1,90%), dan WIKA (MAPE 2,86%). Sebaliknya, LSTM-AM menunjukkan performa yang kurang optimal karena mekanisme *Attention* yang diterapkan tidak sesuai dengan karakteristik data harga saham yang memerlukan pertimbangan menyeluruh terhadap seluruh urutan historis. Penelitian ini merekomendasikan penggunaan BiLSTM sebagai metode prediksi harga saham syariah yang paling efektif.

Kata Kunci: saham syariah, LSTM, BiLSTM, LSTM-AM, *deep learning*, prediksi harga saham, *time series*

ABSTRACT

PERFORMANCE COMPARISON OF LSTM, BILSTM, AND LSTM-AM ALGORITHMS IN ISLAMIC STOCK PRICE PREDICTION

By

Muhamad Ramadhan Kamal

The rapid development of the Islamic stock market creates a need for accurate price prediction methods to assist investors in making investment decisions. This study aims to compare the performance of three deep learning algorithms: Long Short-Term Memory (LSTM), Bidirectional LSTM (BiLSTM), and LSTM with Attention Mechanism (LSTM-AM) in predicting Islamic stock prices. The research data uses daily closing prices from five Islamic stock issuers (ANTM, ERAA, KLBF, SMGR, and WIKA) from December 2016 to December 2021 obtained from Yahoo Finance. The research methodology includes data preprocessing stages using Robust Scaling, time series formation with 60-day time steps, *hyperparameter tuning* using Keras Tuner, and model evaluation using window cross-validation with 5 folds. Model performance evaluation was conducted using Mean Absolute Percentage Error (MAPE), Root Mean Squared Error (RMSE), and R-squared (R^2) metrics. The results show that BiLSTM provides the best performance with an average MAPE value of 9.41%, followed by LSTM with 11.87%, while LSTM-AM has the highest MAPE value of 19.58%. The BiLSTM model can capture temporal patterns from two directions (forward and backward), providing more accurate predictions, especially for stocks with stable characteristics such as KLBF (MAPE 1.49%), SMGR (MAPE 1.90%), and WIKA (MAPE 2.86%). Conversely, LSTM-AM shows suboptimal performance because the applied Attention mechanism is not suitable for stock price data characteristics that require comprehensive consideration of the entire historical sequence. This study recommends using BiLSTM as the most effective method for predicting Islamic stock prices.

Keywords: Islamic stocks, LSTM, BiLSTM, LSTM-AM, deep learning, stock price prediction, time series

**PERBANDINGAN KINERJA ALGORITMA LSTM, BILSTM, DAN
LSTM-AM DALAM PREDIKSI HARGA SAHAM SYARIAH**

Oleh

MUHAMAD RAMADHAN KAMAL

Skripsi

**Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA ILMU KOMPUTER**

Pada

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



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

Judul Skripsi

**PERBANDINGAN KINERJA
ALGORITMA LSTM, BILSTM, DAN
LSTM-AM DALAM PREDIKSI HARGA
SAHAM SYARIAH**

Nama Mahasiswa

Muhamad Ramadhan Kamal

Nomor Pokok Mahasiswa

2157051001

Program Studi

S1 Ilmu Komputer

Jurusan


Ilmu Komputer

Fakultas


Matematika dan Ilmu Pengetahuan Alam

MENYETUJUI

1. Komisi Pembimbing




Rahman Taufik, S.Pd, M. Kom.
NIP. 199306272022031007



Ridho Sholehurrohman, M. Mat.
NIP. 232111970128101

2. Ketua Jurusan Ilmu Komputer



Dwi Sakethi, S.Si., M.Kom.
NIP. 196806111998021001

MENGESAHKAN

1. Tim Penguji

Ketua : Rahman Taufik, S.Pd, M. Kom.

Sekretaris : Ridho Sholehurrohman, M. Mat.

Penguji Utama : Tristiyanto, S.Kom., M.I.S., Ph.D.

Rph

Ridho Sholehurrohman

Tristiyanto

2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam

Heri Satria

Dr. Eng. Heri Satria, S.Si., M.Si.

NIP. 197110012005011002

Tanggal Lulus Ujian Skripsi: 8 Juli 2025

PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Muhamad Ramadhan Kamal

NPM : 2157051001

Dengan ini menyatakan bahwa skripsi saya yang berjudul “**Perbandingan Kinerja Algoritma LSTM, BiLSTM, dan LSTM-AM dalam Prediksi Harga Saham Syariah**” merupakan karya saya sendiri dan bukan karya orang lain. Semua tulisan yang tertuang di skripsi ini telah mengikuti kaidah penulisan karya tulis ilmiah Universitas Lampung. Apabila di kemudian hari terbukti skripsi saya merupakan hasil jiplakan atau dibuat orang lain, maka saya bersedia menerima sanksi berupa pencabutan gelar yang saya terima.

Bandar Lampung, 16 Juli 2025

Penulis,



Muhamad Ramadhan Kamal
NPM. 2157051001

RIWAYAT HIDUP



Penulis lahir di Pemalang pada tanggal 13 November 2003 sebagai anak pertama dari pasangan Bapak Sukamto dan Ibu Jamalah. Penulis telah menyelesaikan Pendidikan formal di SDN Kubang Sepat 1 pada tahun 2015. Kemudian SMP Madani Islamic School pada tahun 2018 dan SMAN 5 Cilegon pada tahun 2021. Penulis terdaftar sebagai mahasiswa studi S1 Ilmu Komputer, Universitas Lampung, melalui jalur mandiri atau SMM PTN-Barat pada tahun 2021.

Selama menjadi mahasiswa di Ilmu Komputer, penulis aktif di dalam berbagai kegiatan baik di dalam maupun di luar Universitas Lampung. Kegiatan yang dilakukan adalah sebagai berikut:

1. Menjadi Asisten Dosen untuk mata kuliah Sistem Operasi di Jurusan Ilmu Komputer pada tahun 2022.
2. Menjadi Asisten Dosen untuk mata kuliah Komunikasi Data dan Jaringan Komputer di Jurusan Ilmu Komputer pada tahun 2023.
3. Menjadi Asisten Dosen untuk mata kuliah *Internet of Things* di Jurusan Ilmu Komputer pada tahun 2024.
4. Menjadi Anggota organisasi Himpunan Mahasiswa Jurusan Ilmu Komputer (HIMAKOM) pada tahun 2023.
5. Melaksanakan Kerja Praktik (KP) di SMAN 4 Metro pada tahun 2024.
6. Melaksanaakan Kuliah Kerja Nyata (KKN) Periode II Universitas Lampung di Desa Labuhan Ratu pada tahun 2024.

PERSEMBAHAN

Segala puji saya panjatkan kepada Allah Subhanahu Wa Ta'ala atas segala rahmat dan karunia-Nya. Shalawat serta salam semoga senantiasa tercurah kepada Nabi Muhammad Shallallahu 'alaihi wa sallam sehingga penulis dapat menyelesaikan skripsi ini.

Skripsi ini saya persembahkan kepada:

Kedua orang tua saya atas kasih sayang, doa, dan dukungan yang telah diberikan dan seluruh rekan yang telah kebersamai serta membantu dalam proses penyelesaian skripsi ini. Juga untuk diri saya sendiri atas keberhasilan dan ketekunan dalam menuntaskan pendidikan di Program Studi S1 Ilmu Komputer Universitas Lampung.

MOTTO

"Dan Dialah yang menurunkan hujan sesudah mereka berputus asa dan menyebarkan rahmat-Nya."

(QS. Ash-Shura: 28)

"The way to get started is to quit talking and begin doing."

(Walt Disney)

"Belajar dari kemarin, bekerja untuk hari ini, berharap untuk besok."

(Muhamad Ramadhan Kamal)

SANWACANA

Puji syukur penulis panjatkan kehadirat Allah Subhanahu wa Ta'ala yang telah melimpahkan rahmat, hidayah, dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi ini dengan baik. Shalawat serta salam senantiasa tercurah kepada Nabi Muhammad Shallallahu 'alaihi wa sallam, sang teladan terbaik yang telah membawa umat manusia dari zaman kegelapan menuju zaman yang penuh dengan ilmu pengetahuan.

Skripsi dengan judul "**Perbandingan Kinerja Algoritma LSTM, BiLSTM, dan LSTM-AM dalam Prediksi Harga Saham Syariah**" ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana pada Program Studi S1 Ilmu Komputer Universitas Lampung.

Pada kesempatan ini penulis mengucapkan terima kasih kepada semua pihak yang telah berkontribusi dalam penyusunan skripsi ini, yaitu:

1. Kedua orang tua penulis, Bapak Sukamto dan Ibu Jamalah yang telah memberikan dukungan moral, material, dan doa yang tiada henti kepada penulis dalam penyelesaian skripsi ini.
2. Bapak Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
3. Bapak Dwi Sakethi, S.Si., M.Kom., selaku Ketua Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
4. Ibu Yunda Heningtyas, M.Kom., selaku Sekretaris Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Bapak Tristiyanto, S.Kom., M.I.S., Ph.D., selaku Dosen Pembahas yang telah memberikan masukan dan evaluasi yang bermanfaat untuk perbaikan skripsi

ini dan Ketua Program Studi S1 Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

6. Bapak Rahman Taufik, S.Pd, M. Kom., selaku Dosen Pembimbing Utama yang telah memberikan bimbingan, arahan, dan masukan yang bermanfaat kepada penulis dalam penyelesaian skripsi ini.
7. Bapak Ridho Sholehurrohman, M. Mat., selaku Dosen Pembimbing Pembantu yang telah memberikan saran dan kritik yang bermanfaat dan membantu untuk penyempurnaan skripsi ini.
8. Bapak Dr. Aristoteles, S.Si., M.Si., selaku Dosen Pembimbing Akademik penulis.
9. Bapak/Ibu Dosen dan seluruh Staf Jurusan Ilmu Komputer FMIPA Universitas Lampung yang telah memberikan ilmu pengetahuan dan membantu dalam berbagai urusan akademik maupun administratif.
10. Teman-teman dekat yang selalu memberikan semangat dan dukungan.
11. Seluruh teman-teman Jurusan Ilmu Komputer 2021 yang telah berjuang bersama dan saling mendukung selama perkuliahan.

Penulis menyadari bahwa skripsi ini masih jauh dari sempurna. Oleh karena itu, penulis mengharapkan kritik dan saran yang membangun untuk perbaikan di masa mendatang. Semoga skripsi ini dapat memberikan manfaat bagi semua pihak.

Bandar Lampung, 16 Juli 2025
Penulis,

Muhamad Ramadhan Kamal
NPM. 2157051001

DAFTAR ISI

Halaman

DAFTAR TABEL	v
DAFTAR GAMBAR.....	vii
I. PENDAHULUAN	1
1.1. Latar Belakang.....	1
1.2. Rumusan Masalah	3
1.3. Tujuan.....	4
1.4. Manfaat.....	4
1.5. Batasan Masalah.....	4
II. TINJAUAN PUSTAKA.....	6
2.1. Penelitian Terdahulu.....	6
2.2. Saham Syariah	8
2.3. <i>Deep Learning</i>	9
2.4. <i>Long Short-Term Memory</i> (LSTM).....	10
2.5. <i>Bidirectional Long Short-Term Memory</i> (BiLSTM).....	17
2.6. LSTM dengan <i>Attention Mechanism</i> (LSTM-AM).....	19
2.7. <i>Error Metrics for Time series Forecasting</i>	23
2.7.1. <i>Mean Absolute Percentage Error</i> (MAPE).....	23
2.7.2. <i>Root Mean Squared Error</i> (RMSE)	24
2.8. <i>R-squared</i> (R^2).....	25
III. METODOLOGI PENELITIAN	27
3.1. Waktu dan Tempat	27
3.1.1. Waktu Penelitian	27
3.1.2. Tempat Penelitian	27
3.2. Alat dan Bahan Penelitian	27
3.2.1. Perangkat Keras	28
3.2.2. Perangkat Lunak	28

3.2.3. Bahan Penelitian.....	29
3.3. Metode.....	29
3.4. Tahapan Penelitian	30
IV. HASIL DAN PEMBAHASAN.....	35
4.1. Proses <i>Build Deep Learning</i>	35
4.1.1. <i>Import Library</i>	35
4.1.2. <i>Data Loading</i>	36
4.1.3. <i>Exploratory Data Analysis (EDA)</i>	36
4.1.4. <i>Data Preprocessing</i>	51
4.1.5. <i>Build Model (LSTM)</i>	52
4.1.6. <i>Build Model (BiLSTM)</i>	57
4.1.7. <i>Build Model (LSTM-AM)</i>	65
4.2. Hasil <i>Training</i> dan <i>Testing</i>	72
4.2.1. <i>Training</i>	73
4.2.2. <i>Testing</i>	83
4.2.3. Ilustrasi Perhitungan Manual Metrik Evaluasi.....	84
4.2.4. Pengujian 1: Prediksi Tanpa Pembulatan.....	89
4.2.5. Pengujian 2: Prediksi dengan Pembulatan	90
4.3. Pembahasan dan Analisis	92
V. SIMPULAN DAN SARAN.....	98
5.1. Kesimpulan.....	98
5.2. Saran	99
DAFTAR PUSTAKA	100

DAFTAR TABEL

Tabel	Halaman
1. Penelitian terdahulu.....	6
2. Arti nilai MAPE untuk kemampuan prediksi model	24
3. <i>Hyperparameter</i> LSTM emiten ANTM.....	53
4. <i>Hyperparameter</i> LSTM emiten ERAA.....	53
5. <i>Hyperparameter</i> LSTM emiten KLBF	54
6. <i>Hyperparameter</i> LSTM emiten SMGR	54
7. <i>Hyperparameter</i> LSTM emiten WIKA.....	54
8. <i>Trial Hyperparameter</i> LSTM keseluruhan	55
9. <i>Hyperparameter</i> BILSTM emiten ANTM.....	59
10. <i>Hyperparameter</i> BILSTM emiten ERAA.....	59
11. <i>Hyperparameter</i> BILSTM emiten KLBF	59
12. <i>Hyperparameter</i> BILSTM emiten SMGR	60
13. <i>Hyperparameter</i> BILSTM emiten WIKA.....	60
14. <i>Trial Hyperparameter</i> BILSTM keseluruhan	61
15. <i>Hyperparameter</i> LSTM-AM emiten ANTM.....	66
16. <i>Hyperparameter</i> LSTM-AM emiten ERAA.....	67
17. <i>Hyperparameter</i> LSTM-AM emiten KLBF	67
18. <i>Hyperparameter</i> LSTM-AM emiten SMGR	68
19. <i>Hyperparameter</i> LSTM-AM emiten WIKA.....	68
20. <i>Hyperparameter</i> LSTM-AM keseluruhan	68
21. Hasil <i>hyperparameter tuning</i> LSTM	73
22. Hasil <i>hyperparameter tuning</i> Bi-LSTM	74
23. Hasil <i>hyperparameter tuning</i> LSTM-AM.....	74
24. Data contoh prediksi vs aktual untuk model LSTM.	85
25. Data contoh prediksi vs aktual untuk model BILSTM.	85

26. Data contoh prediksi vs aktual untuk model LSTM-AM.....	85
27. Ringkasan hasil perhitungan manual metrik evaluasi.....	88
28. Evaluasi prediksi model LSTM	89
29. Evaluasi prediksi model BiLSTM.....	90
30. Evaluasi prediksi model LSTM-AM.....	90
31. Evaluasi prediksi dengan pembulatan model LSTM	91
32. Evaluasi prediksi dengan pembulatan model BiLSTM	91
33. Evaluasi prediksi dengan pembulatan model LSTM-AM	91
34. Perbandingan pengujian 1 dan 2	92
35. Rata-rata nilai evaluasi prediksi model.....	95
36. Perbandingan nilai MAPE antar model (LSTM terdahulu, LSTM penelitian ini, BiLSTM, dan LSTM-AM) pada lima saham syariah.	96

DAFTAR GAMBAR

Gambar	Halaman
1. Perulangan pada RNN dengan satu layer.....	10
2. Arsitektur LSTM.....	11
3. Cell state pada LSTM.	12
4. Alur forget gate pada LSTM.	13
5. Alur input gate pada LSTM.	14
6. Alur memperbarui cell state pada LSTM.	15
7. Alur output pada LSTM.....	16
8. Model BiLSTM.....	18
9. Long and short-term memory Network LSTM model.....	20
10. Diagram alur tahapan penelitian.	30
11. Dataset penelitian.....	31
12. Snapshot code import library.....	35
13. Snapshot code data loading.....	36
14. Plot pergerakan harga saham ANTM.....	37
15. Plot pergerakan harga saham ERAA.	38
16. Plot pergerakan harga saham KLBF.	38
17. Plot pergerakan harga saham SMGR.	39
18. <i>Plot</i> pergerakan harga saham WIKA.	39
19. Plot pergerakan harga saham (rata-rata per bulan) ANTM.....	40
20. Plot pergerakan harga saham (rata-rata per bulan) ERAA.	40
21. Plot pergerakan harga saham (rata-rata per bulan) KLBF.	41
22. Plot pergerakan harga saham (rata-rata per bulan) SMGR.	41
23. Plot pergerakan harga saham (rata-rata per bulan) WIKA.	42
24. Uji stasioner dataset saham ANTM.	42
25. Uji stasioner dataset saham ERAA.	43

26. Uji stasioner dataset saham KLBF.....	43
27. Uji stasioner dataset saham SMGR.....	44
28. Uji stasioner dataset saham WIKA.....	45
29. Uji linearitas dataset saham ANTM.....	46
30. Uji linearitas dataset saham ERAA.....	47
31. Uji linearitas dataset saham KLBF.....	48
32. Uji linearitas dataset saham SMGR.....	49
33. Uji linearitas dataset saham WIKA.....	50
34. Snapshot code normalisasi data.....	51
35. Snapshot code data Preprocessing.....	52
36. Arsitektur model LSTM.....	52
37. Arsitektur model BiLSTM.....	58
38. Snapshot code Attention layer.....	65
39. Arsitektur model LSTM-AM.....	66
40. Pembagian data untuk window cross-validation pada keseluruhan tahap training.....	73
41. Grafik harga saham aktual vs prediksi model LSTM pada dataset ANTM... ..	75
42. Grafik harga saham aktual vs prediksi model LSTM pada dataset ERAA....	75
43. Grafik harga saham aktual vs prediksi model LSTM pada dataset KLBF.....	76
44. Grafik harga saham aktual vs prediksi model LSTM pada dataset SMGR. ..	76
45. Grafik harga saham aktual vs prediksi model LSTM pada dataset WIKA....	77
46. Grafik harga saham aktual vs prediksi model Bi-LSTM pada dataset ANTM.	78
47. Grafik harga saham aktual vs prediksi model Bi-LSTM pada dataset ERAA.	78
48. Grafik harga saham aktual vs prediksi model Bi-LSTM pada dataset KLBF.	79
49. Grafik harga saham aktual vs prediksi model Bi-LSTM pada dataset SMGR.	79
50. Grafik harga saham aktual vs prediksi model Bi-LSTM pada dataset WIKA.	80

51. Grafik harga saham aktual <i>vs</i> prediksi model LSTM-AM pada dataset ANTM.....	80
52. Grafik harga saham aktual <i>vs</i> prediksi model LSTM-AM pada dataset ERAA.	81
53. Grafik harga saham aktual <i>vs</i> prediksi model LSTM-AM pada dataset KLBF.	82
54. Grafik harga saham aktual <i>vs</i> prediksi model LSTM-AM pada dataset SMGR.	82
55. Grafik harga saham aktual <i>vs</i> prediksi model LSTM-AM pada dataset WIKI.	83
56. Hasil akhir prediksi model tanpa pembulatan dan dengan pembulatan.....	90

I. PENDAHULUAN

1.1. Latar Belakang

Perkembangan dunia keuangan dan investasi semakin pesat, terutama dengan meningkatnya minat masyarakat terhadap investasi di pasar modal, termasuk pasar saham syariah. Saham syariah menjadi salah satu instrumen investasi yang menarik karena prinsip-prinsipnya yang berlandaskan syariah Islam, sehingga menghindari unsur riba, gharar, dan maysir. Saham Islam berfungsi sebagai kendaraan investasi alternatif yang selaras dengan hukum Islam, memperkenalkan dimensi investasi etis (Akram et al., 2024). Perkembangan pasar saham syariah terus menunjukkan tren positif, dan penting bagi para investor, terutama yang tertarik dengan nilai-nilai syariah, untuk dapat memprediksi pergerakan harga saham dengan akurat. Penerapan investasi saham syariah menjadi nyata dan aplikatif untuk diikuti seiring perkembangan teknologi. Prediksi harga saham yang baik dapat membantu investor dalam pengambilan keputusan investasi yang tepat. Namun, Pergerakan saham menunjukkan volatilitas dan perilaku dinamis karena sifatnya yang tidak stasioner dan tidak teratur, sehingga membuat prediksi menjadi tantangan yang kompleks di pasar keuangan (Khuwaja et al., 2020).

Algoritma *Long Short-Term Memory* (LSTM) telah menjadi metode populer dalam pemodelan data saham sekuensial (Pham, 2021). LSTM adalah versi *Recurrent Neural Network* (RNN) yang diperkuat memori yang dapat memproses data sekuensial jangka panjang dengan tingkat gradien menghilang yang rendah (Cho & Kim, 2022). Kemampuannya mengingat pola jangka panjang menjadikannya efektif untuk prediksi data *time series* seperti harga saham. Penelitian (Budiprasetyo et al., 2023) menerapkan LSTM untuk memprediksi saham syariah dengan hasil yang

baik. Nilai MAPE bervariasi untuk berbagai emiten: PT Aneka Tambang Tbk (2,64%), Erajaya Swasembada Tbk (2,24%), Kalbe Farma (1,51%), Semen Indonesia (1,83%), dan Wijaya Karya (2,66%). Meski kinerjanya baik, masih ada ruang peningkatan dalam membedakan informasi penting dari data historis. Penelitian ini akan membandingkan kinerja LSTM dengan dua varian lainnya, yaitu BiLSTM dan LSTM dengan *Attention Mechanism* (LSTM-AM), untuk mengevaluasi metode mana yang paling efektif dalam meningkatkan akurasi prediksi harga saham syariah.

Bidirectional LSTM (BiLSTM) juga menarik perhatian dalam prediksi data *Time series*. Model ini terdiri dari dua LSTM yang memproses *input* secara maju dan mundur (Mahajan & Mansotra, 2021). BiLSTM meningkatkan informasi dan konteks yang tersedia bagi algoritma (Mahajan & Mansotra, 2021), potensial memberikan wawasan tambahan dalam prediksi harga saham syariah dengan mempertimbangkan tren jangka panjang dan pendek secara bersamaan.

Penelitian (Puteri, 2023) mendemonstrasikan efektivitas BiLSTM dalam prediksi harga saham syariah. Hasilnya menjanjikan dengan nilai MAPE: PT. Aneka Tambang Tbk (2,59%), PT. Unilever Indonesia Tbk (1,77%), dan PT. Indofood Sukses Makmur Tbk (1,05%). Berdasarkan nilai MAPE ini, model BiLSTM dinilai sangat akurat untuk prediksi harga saham syariah.

Salah satu perkembangan terbaru dalam jaringan saraf adalah pengenalan *Attention Mechanism*. *Attention Mechanism* awalnya dikembangkan dalam *Natural Language Processing* (NLP) untuk menangkap keterkaitan antar kata dalam kalimat, sehingga model dapat fokus pada bagian tertentu dari *input* yang paling relevan. *Attention Mechanism* terinspirasi oleh mekanisme perhatian manusia, di mana orang cenderung mengamati dan memperhatikan bagian-bagian informasi tertentu secara selektif sambil mengabaikan sisanya, sesuai kebutuhan (Lu et al., 2023). Dalam konteks prediksi harga saham, *Attention Mechanism* memungkinkan model untuk menetapkan bobot yang berbeda untuk *input* yang berbeda, sehingga menekankan informasi penting daripada data yang kurang relevan (Fang et al., 2022).

Penggunaan LSTM dengan *Attention Mechanism*, yang dikenal dengan LSTM-AM (LSTM with *Attention Mechanism*), diharapkan mampu meningkatkan akurasi prediksi harga saham dibandingkan dengan LSTM. Dalam penelitian oleh (Zou et al., 2024), LSTM yang ditingkatkan dengan *Attention Mechanism* diterapkan dalam konteks memprediksi latensi jaringan dan menunjukkan peningkatan kinerja dibandingkan LSTM. Hasil ini menjadi motivasi untuk menguji apakah peningkatan serupa dapat dicapai dalam konteks prediksi harga saham syariah.

Telah disebutkan bahwa metode-metode *deep learning* telah banyak dikembangkan di bidang investasi dan prediksi saham seperti LSTM, Bi-LSTM, dan LSTM-AM. Oleh karena semakin berkembangnya metode-metode yang telah disebutkan di atas dan mengingat pentingnya prediksi pasar saham, penerapan prediksi harga saham syariah serta potensi yang semakin berkembang untuk penerapan investasi di bidang keuangan, maka dapat diaplikasikan pengembangan metode *deep learning* secara inovatif dan mencari pemodelan efektif sebagai solusi untuk prediksi harga saham syariah. Dengan menganalisis dan membandingkan kinerja LSTM, BiLSTM, dan LSTM-AM dalam prediksi harga saham syariah, penelitian ini bertujuan untuk mengeksplorasi metode yang paling efektif dalam memodelkan dan memprediksi pergerakan harga saham yang dinamis dan kompleks. Diharapkan penelitian ini dapat menemukan metode yang lebih optimal dalam memodelkan dan memprediksi pergerakan harga saham syariah yang dinamis dan kompleks.

1.2. Rumusan Masalah

Berdasarkan latar belakang, rumusan masalah pada penelitian ini adalah sebagai berikut:

1. Bagaimana membangun model LSTM, BiLSTM, dan LSTM-AM dalam memprediksi harga saham syariah?
2. Bagaimana kinerja algoritma LSTM, BiLSTM, dan LSTM-AM dalam memprediksi harga saham syariah?
3. Metode mana yang dapat menghasilkan akurasi prediksi yang lebih baik dibandingkan lainnya dalam konteks prediksi harga saham syariah?

1.3. Tujuan

Adapun tujuan dari penelitian ini adalah sebagai berikut:

1. Membangun model prediksi harga saham syariah menggunakan metode LSTM, BiLSTM, dan LSTM-AM.
2. Menganalisis kinerja algoritma LSTM, BiLSTM, dan LSTM-AM dalam memprediksi harga saham syariah.
3. Membandingkan akurasi prediksi LSTM, BiLSTM, dan LSTM-AM dalam konteks prediksi harga saham syariah.

1.4. Manfaat

Adapun manfaat dari penelitian ini antara lain sebagai berikut:

1. Memberikan wawasan tentang potensi metode prediksi harga saham syariah yang lebih akurat, yang dapat membantu dalam pengambilan keputusan investasi.
2. Menyediakan informasi tentang efektivitas kinerja algoritma LSTM, BiLSTM, dan LSTM-AM yang dapat digunakan dalam pengembangan sistem prediksi harga saham yang lebih canggih.
3. Menyediakan dasar untuk penelitian lebih lanjut dalam pengembangan dan penerapan teknik *deep learning* pada analisis keuangan syariah.

1.5. Batasan Masalah

Adapun batasan masalah pada penelitian ini antara lain adalah sebagai berikut:

1. Penelitian ini fokus pada perbandingan analisis kinerja LSTM, BiLSTM, dan LSTM-AM dalam prediksi harga saham syariah.

2. Prediksi harga saham hanya mencakup harga penutupan (*closing price*) saham syariah harian.
3. Data yang digunakan adalah data harian harga saham syariah dari lima emiten yang terdaftar dalam indeks saham syariah, yaitu PT Aneka Tambang Tbk (ANTM), Erajaya Swasembada Tbk (ERAA), Kalbe Farma Tbk (KLBF), Semen Indonesia (Persero) Tbk (SMGR), dan Wijaya Karya (Persero) Tbk (WIKA). Data tersebut diperoleh dari *Yahoo Finance* (<https://finance.yahoo.com>) dengan rentang waktu 5 tahun, mulai dari 1 Desember 2016 hingga 1 Desember 2021.
4. Penelitian tidak mempertimbangkan faktor-faktor eksternal seperti berita, kebijakan pemerintah, atau kondisi ekonomi global dalam model prediksi.
5. Evaluasi kinerja akan didasarkan pada metrik-metrik tertentu menggunakan *Mean Absolute Percentage Error* (MAPE), *Root Mean Squared Error* (RMSE), dan *R-squared* (R^2).

II. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Bab ini membahas penelitian terdahulu terkait prediksi harga saham syariah menggunakan metode *deep learning*, khususnya LSTM, BiLSTM, dan LSTM-AM. Penelitian-penelitian ini menjadi landasan dan konteks untuk penelitian saat ini yang dapat dilihat dalam Tabel 1.

Tabel 1. Penelitian terdahulu

Penulis	Judul	Hasil Peneltian
Budiprasetyo <i>et al.</i> (2023)	Prediksi Harga Saham Syariah Menggunakan Algoritma <i>Long Short-Term Memory</i> (LSTM)	LSTM menunjukkan performa yang cukup baik dalam memprediksi harga saham syariah dengan nilai MAPE: • ANTM (2,64%), • ERAA (2,24%), • KLBF (1,51%), • SMGR (1,83%), • WIKA (2,66%). Metode yang digunakan termasuk: • <i>Preprocessing</i> data, • <i>tuning hyperparameter</i>, dan • pembagian data menjadi <i>train-test split</i>.

Penulis	Judul	Hasil Penelitian
Puteri (2023)	Implementasi <i>Long Short-Term Memory</i> (LSTM) dan <i>Bidirectional LSTM</i> (BiLSTM) dalam Prediksi Harga Saham Syariah	BiLSTM menunjukkan hasil yang lebih akurat dibandingkan LSTM dengan nilai MAPE lebih rendah: • ANTM (2,59%), • UNVR (1,77%), • INDF (1,05%). Tahapan penelitian meliputi: • <i>Preprocessing</i>, • <i>tuning hyperparameter</i>, • dan penggunaan model BiLSTM Untuk menangkap pola data yang lebih kompleks.
Zou et al. (2024)	<i>Attention Mechanism Enhanced LSTM Networks for Latency Prediction in Deterministic MEC Networks</i>	LSTM-AM (<i>Attention Mechanism</i>) yang diusulkan menunjukkan peningkatan akurasi prediksi mendekati 0.9, sementara metode konvensional seperti CNN hanya mencapai sekitar 0.75, dan metode <i>deep learning</i> dasar mencapai sekitar 0.65. Tahapan penelitian termasuk: • data <i>Preprocessing</i>, • penambahan <i>Attention Mechanism</i>, dan • pengujian akurasi.

Berdasarkan penelitian terdahulu diatas dapat dikatakan bahwa penggunaan LSTM sebagai model baseline dalam prediksi data *time series*, termasuk harga saham syariah, menunjukan adanya manfaat. Dengan adanya LSTM, untuk menangkap

dan mengingat pola jangka panjang, dirancang khusus untuk mengatasi tantangan *vanishing gradient* yang sering terjadi pada *Recurrent Neural Network* (RNN) tradisional. Model ini efektif dalam menangani data sekuensial yang memiliki keterkaitan temporal yang kompleks

Namun, meskipun LSTM dapat menangkap pola data jangka panjang, algoritma ini masih memiliki beberapa keterbatasan, seperti ketidakmampuan untuk secara optimal memprioritaskan informasi penting dalam dataset yang sangat bervariasi. Oleh karena itu, dalam penelitian ini, LSTM digunakan sebagai acuan untuk memahami seberapa baik model dasar mampu memprediksi harga saham syariah sebelum membandingkannya dengan model yang lebih canggih seperti BiLSTM dan LSTM-AM (Budiprasetyo et al., 2023).

2.2. Saham Syariah

Saham adalah sertifikat yang menunjukkan bukti kepemilikan suatu perusahaan, dan pemegang saham memiliki hak atas penghasilan dan aktiva perusahaan. Menurut Fatwa Dewan Syariah Nasional saham syariah merupakan bukti kepemilikan atas suatu perusahaan yang memenuhi kriteria tidak bertentangan dengan prinsip-prinsip syariah (Fauzi et al., 2022). Munculnya produk syariah di pasar modal pada mulanya berawal dari berubahnya pola pikir dan keinginan umat Islam untuk berinvestasi secara syariah. Saham syariah merupakan salah satu bentuk dari saham biasa yang memiliki karakteristik khusus yang berupa kontrol ketat dalam kehalalan ruang lingkup kegiatan usaha (Zamaluddin et al., 2023).

Praktik saham syariah dalam dunia pasar modal harus senantiasa sejalan dengan prinsip saham syariah yang telah dirumuskan oleh (Samsuduha & Herawati, 2023) beberapa prinsip dasar saham syariah, antara lain:

1. saham harus bersifat musyarakah sehingga dalam proses penawarannya dilakukan secara terbatas.

2. prinsip saham bersifat mudharabah sehingga dalam penyelenggaraannya haruslah ditawarkan kepada publik artinya terbuka secara umum untuk siapa saja.
3. resiko saham harus ditanggung oleh semua pihak sehingga tidak membedakan jenis saham tertentu.
4. sistem penerapan saham berdasarkan pada bagi hasil raba rugi.
5. saham tidak bisa dicairkan terkecuali apa yang disebut dilikuidasi.

(Wardani, 2021) menyebutkan bahwa dalam penerapannya seleksi saham syariah terdiri atas dua kriteria utama, yaitu jenis usaha dan cara perusahaan mengelola usahanya. Jenis usaha dapat dilihat dari segi produk yang dihasilkan oleh perusahaan tersebut halal atau haram. Sedangkan cara perusahaan mengelola usahanya dilihat dari segi perbandingan riba yang terdapat pada keuangan perusahaan. Ketentuan seleksi saham syariah ini diatur dalam peraturan OJK Nomor 35 /POJK.04/2017 tentang kriteria dan penerbitan daftar efek syariah. Indeks saham syariah adalah variabel yang menunjukkan kinerja saham syariah atau pasar saham syariah. Indeks saham syariah merujuk pada kinerja saham syariah sebagai indikator dalam membandingkan serta mengukur kinerja portofolio saham syariah.

2.3. *Deep Learning*


Deep learning adalah jenis pembelajaran mesin yang membuat komputer memiliki kemampuan seperti manusia untuk belajar dari pengalaman mereka sendiri. Teknik pembelajaran mendalam baru-baru ini mendapat banyak perhatian penelitian karena hasil yang positif. Pembelajaran yang dirancang menggunakan pemahaman mendalam tentang cara menyusun gambar, teks, atau suara secara bertahap. Dalam beberapa kasus, pembelajaran mendalam mengungguli skala manusia dalam hal akurasi. Model memanfaatkan arsitektur jaringan saraf multilapisan dan banyak data (Wahyudi, 2023).

Deep learning telah menjadi pendekatan yang sangat efektif untuk menganalisis data *time series* yang kompleks, termasuk dalam prediksi harga saham syariah. Model-model seperti LSTM (*Long Short-Term Memory*), BiLSTM, dan metode yang lebih canggih seperti LSTM-AM (LSTM dengan *Attention Mechanism*) telah terbukti menangani pola non-linear dan hubungan jangka panjang dalam data yang sulit ditangani oleh metode tradisional (Li & Law, 2024).

2.4. Long Short-Term Memory (LSTM)

LSTM adalah versi *Recurrent Neural Network* (RNN) yang diperkuat memori yang dapat memproses data sekuensial jangka panjang dengan tingkat gradien menghilang yang rendah (Cho & Kim, 2022). LSTM meningkatkan retensi memori jangka panjang melalui struktur gerbangnya, secara efektif mengatasi masalah hilangnya gradien yang sering muncul pada RNN (*Recurrent Neural Networks*) tradisional, membuatnya cocok untuk berbagai tugas data sekuensial (Chen, 2024).

LSTM dikatakan pengembangan dari RNN karena pada dasarnya mereka memiliki struktur yang sama yakni terdiri dari *input layer*, *hidden layer*, dan *output layer*. Perbedaannya terdapat pada susunan jaringan yang terdapat pada *hidden layer*. Pada RNN, *hidden layer* hanya terdiri dari satu *layer* sederhana dengan fungsi aktivasi *tanh* seperti Gambar 1 berikut.




Gambar 1. Perulangan pada RNN dengan satu *layer* (Wardani, 2021).

Pada Gambar 1 diatas adalah perulangan pada RNN yang hanya terdiri dari satu *layer* yakni *tanh layer* yang akan dijabarkan pada persamaan berikut.

$$\tanh(x) = 2\sigma(2x) - 1 \quad (1.1)$$

Keterangan: σ = fungsi *sigmoid*
 x = data *input*


Sedangkan pada LSTM terdiri dari dua fungsi aktivasi yakni fungsi *sigmoid* dan *tanh*. Pada LSTM juga terdapat *memory cell* dan *gates* yang mana *gates* tersebut tersusun dari tiga *gates* yakni *forget gate*, *input gate*, dan *output gate*. Berikut adalah ilustrasi dari arsitektur LSTM pada gambar. Arsitektur LSTM dapat dilihat pada Gambar 2 berikut.



Gambar 2. Arsitektur LSTM (Hanafiah *et al.*, 2023).

Pada arsitektur LSTM terdiri dari sel memori dan tiga gerbang yaitu, gerbang *input*, gerbang *forget*, dan gerbang *output*. Gerbang-gerbang ini mengontrol aliran informasi ke dalam, di dalam, dan keluar dari sel memori, memungkinkan jaringan untuk mempertahankan informasi penting selama periode waktu yang panjang (Ravikumar & Sriraman, 2024). *Forget gate* (f_t) berfungsi untuk menghapus informasi dari *cell state*. *Input gate* (i_t) berfungsi dalam memutuskan informasi baru yang masuk ke dalam *cell state*, sedangkan *output gate* (O_t) berfungsi dalam memilah informasi yang berguna dari arus *cell state* dan menampilkannya sebagai *output* (D. Puteri, 2023).

Langkah-langkah LSTM seperti Gambar 2 akan diuraikan satu per satu pada bagaian ini. *Cell state* adalah kunci utama di dalam metode LSTM. *Cell state* adalah garis horizontal yang melewati bagian atas diagram yang menghubungkan semua *output layer* pada LSTM seperti terlihat pada Gambar 3 berikut.



Gambar 3. *Cell state* pada LSTM (Wardani, 2021).


LSTM memiliki *gates* yang terdiri dari *sigmoid layer* dan *pointwise operation*. Dimana *gates* ini dapat menambah ataupun menghapus informasi yang mana informasi tersebut akan diteruskan atau diberhentikan. *Sigmoid layer* ini akan memadatkan hasil *output* menjadi *range* $[0,1]$. Angka 0 menunjukkan informasi akan diberhentikan, sedangkan angka 1 menunjukkan akan diteruskan. Persamaan *sigmoid* diuraikan pada persamaan berikut:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (1.2)$$

Keterangan: x = data *input*

e = konstanta matematika (2,71828 18284 59045 23536 02874 71352)

Adapun panduan jalannya metode LSTM yakni sebagai berikut. Langkah pertama berada pada *forget gate*. *Forget gate* ini akan memutuskan informasi apa yang akan di hilangkan dari *cell state*. Ini terjadi karena adanya *sigmoid layer* yang menghasilkan *output* angka antara 0 dan 1. *Forget gate* dihitung dengan menggunakan data *output* sebelumnya h_{t-1} dan data *input* X_t saat ini seperti pada Gambar 4 berikut.



Gambar 4. Alur forget gate pada LSTM (Wardani, 2021).

Persamaan *forget gate* diuraikan pada persamaan berikut:

$$f_t = \sigma (W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1.3)$$

Keterangan: f_t = forget gate

σ = fungsi *sigmoid*

W_f = nilai *weight* untuk *forget gate*

h_{t-1} = nilai *output* sebelum orde ke-t

x_t = nilai *input* pada orde ke-t

b_f = nilai bias pada *forget gate*

Persamaan (1.3) menunjukkan bagaimana *forget gate* menggunakan fungsi *sigmoid* dari persamaan (1.2) untuk menghasilkan nilai antara 0 dan 1. Nilai *weight* W_f dirumuskan dengan persamaan berikut:

$$W = \left(-\sqrt{\frac{1}{d}}, \sqrt{\frac{1}{d}} \right) \quad (1.4)$$


Keterangan: W = *weight*

d = jumlah variabel

Inisialisasi *weight* pada persamaan (1.4) penting untuk menjaga stabilitas training. Nilai *weight* yang terlalu besar dapat menyebabkan gradien exploding, sedangkan nilai yang terlalu kecil dapat menyebabkan gradien vanishing. Rentang nilai ini

memastikan bahwa gradien tetap dalam rentang yang stabil selama proses pembelajaran.

Tahap selanjutnya adalah *input gate* diilustrasikan pada Gambar 5 berikut.



Gambar 5. Alur *input gate* pada LSTM (Wardani, 2021).

Input gate menentukan informasi baru apa yang akan disimpan dalam *cell state*. Input gate terdiri dari dua bagian yang saling berkaitan. Pertama, *sigmoid layer* (input gate) yang menentukan nilai mana yang akan diperbarui:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (1.5)$$

Keterangan : i_t = *input gate*

σ = fungsi *sigmoid*

W_i = nilai *weight* untuk *input gate*

h_{t-1} = nilai *output* sebelum orde ke-t

x_t = nilai *input* pada orde ke-t

b_i = nilai *bias* pada *input gate*

Kedua, *tanh layer* yang membuat vektor kandidat baru $\tilde{C}_t$ yang dapat ditambahkan ke *cell state*:

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (1.6)$$

Keterangan : $\tilde{C}_t$ = nilai baru yang dapat ditambahkan ke *cell state*

$\tanh$ = fungsi *tanh*


W_c = nilai *weight* untuk *cell state*

h_{t-1} = nilai *output* sebelum orde ke-t

x_t = nilai *input* pada orde ke- t

b_c = nilai bias pada *cell state*

Persamaan (1.5) menggunakan fungsi *sigmoid* yang sama dengan persamaan (1.2) untuk menghasilkan nilai antara 0 dan 1 yang menentukan seberapa banyak informasi baru yang akan disimpan. Sementara persamaan (1.6) menggunakan fungsi *tanh* yang berkaitan dengan persamaan (1.1) untuk membuat kandidat nilai baru yang akan ditambahkan ke *cell state*.



Gambar 6. Alur memperbarui *cell state* pada LSTM (Ilmiah, 2022).

Setelah menentukan informasi apa yang akan dilupakan (*forget gate*) dan informasi baru apa yang akan disimpan (*input gate*), langkah selanjutnya adalah memperbarui *cell state* lama C_{t-1} menjadi *cell state* baru C_t seperti yang diilustrasikan pada Gambar 6 dengan persamaan sebagai berikut:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (1.7)$$

Keterangan : C_t = *cell state*

f_t = *forget gate*


C_{t-1} = *cell state* sebelum orde ke- t

i_t = *input gate*

$\tilde{C}_t$ = nilai baru yang dapat ditambahkan ke *cell state*

Persamaan (1.7) menunjukkan bagaimana hasil dari *forget gate* (persamaan 1.3) dan *input gate* (persamaan 1.5 dan 1.6) dikombinasikan untuk memperbarui *cell state*.

Operasi perkalian titik (*element-wise multiplication*) memastikan bahwa informasi lama yang tidak relevan dihapus ($f_t * C_{t-1}$) dan informasi baru yang relevan ditambahkan ($i_t * \tilde{C}_t$).



Gambar 7. Alur *output* pada LSTM (Ilmiah, 2022).

Langkah terakhir metode LSTM ini yakni menentukan hasil *output* seperti yang diilustrasikan pada Gambar 7. Lapisan *sigmoid* (output gate) memutuskan bagian mana dari *cell state* yang akan dihasilkan menjadi *output*. *Output gate* dituliskan pada persamaan berikut:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (1.8)$$

Keterangan : o_t = output gate

σ = fungsi *sigmoid*

W_o = nilai *weight* untuk output gate

h_{t-1} = nilai *output* sebelum orde ke-t

x_t = nilai *input* pada orde ke-t

b_o = nilai bias pada output gate

Dalam proses komputasi LSTM, model memproses data sekuensial dari $t = 1$ hingga $t = T$, dimana T adalah orde terakhir atau panjang total dari sekuens data input yang diproses oleh model. Nilai T menentukan berapa banyak langkah waktu (*time steps*) yang akan diproses dalam satu sekuens, sehingga menjadi parameter penting dalam menentukan kemampuan model untuk menangkap dependensi temporal dalam data *time series*.

Setelah didapatkan nilai dari *output gate* pada persamaan (1.8), kemudian menempatkan *cell state* melalui *tanh* untuk mendapatkan nilai dengan range -1 hingga 1. Kemudian, hasilnya dikalikan dengan *output gate* dari *sigmoid layer*. Persamaan nilai *output* orde t dirumuskan pada persamaan berikut:

$$h_t = o_t * \tanh(C_t) \quad (1.9)$$

Keterangan : h_t = nilai *output* orde t

o_t = *output gate*

tanh = fungsi *tanh*

C_t = *cell state*

Persamaan (1.8) menggunakan fungsi *sigmoid* dari persamaan (1.2) untuk menentukan bagian mana dari *cell state* yang akan dikeluarkan. Kemudian persamaan (1.9) mengalikan hasil *output gate* dengan *tanh* dari *cell state* yang telah diperbarui persamaan (1.7) untuk menghasilkan *hidden state final*.


2.5. *Bidirectional Long Short-Term Memory (BiLSTM)*

RNN konvensional hanya dapat menggunakan konteks sebelumnya (satu arah). Dalam model jaringan saraf berulang tradisional (RNN) dan model LSTM, informasi hanya dapat disebarkan ke depan (maju), sehingga keadaan waktu t hanya bergantung pada informasi sebelum waktu t (Xu et al., 2019). Untuk mengatasi kekurangan tersebut, RNN dua arah (Bi-RNN) diperkenalkan oleh (Schuster & Paliwal, 1997). Jenis arsitektur ini dapat dilatih di kedua arah waktu secara bersamaan, dengan lapisan tersembunyi (*hidden layer*) yang terpisah (lapisan maju dan lapisan mundur). Selanjutnya, (Graves & Schmidhuber, 2005) menggabungkan Bi-RNN dengan LSTM dan mengusulkan LSTM dua arah (*Bidirectional Long Short-Term Memory*).

Bidirectional Long Short-Term Memory (BiLSTM) adalah jenis *Recurrent Neural Network* (RNN) yang meningkatkan pembelajaran data berurutan dengan

memproses informasi dalam arah maju dan mundur (Feng et al., 2023). Kemampuan pemrosesan ganda ini memungkinkan BiLSTM untuk menangkap ketergantungan jangka panjang secara lebih efektif, sehingga sangat berguna dalam berbagai aplikasi seperti pengenalan bahasa isyarat, prediksi deret waktu, dan pemrosesan bahasa alami (Renjith et al., 2024).

Arsitektur BiLSTM terdiri dari dua lapisan LSTM yang terpisah: satu memproses *input* dari awal ke akhir (*forward layer*), dan yang lainnya memproses *input* dari akhir ke awal (*backward layer*). *Output* dari kedua lapisan ini kemudian digabungkan untuk menghasilkan representasi yang lebih komprehensif dari data *input* (Mahajan & Mansotra, 2021). Jalur forward menggunakan persamaan (1.3) hingga (1.8), berjalan dari $t = 1$ hingga T , menghasilkan $\vec{h}_t$, kemudian Jalur backward menggunakan rumus yang sama, tetapi memproses dari $t = T$ hingga 1. Berikut Gambar 8 yang menunjukkan koneksi internal lapisan berulang LSTM dua arah.



Gambar 8. Model BiLSTM (Ilmiah, 2022).

Forward dan *backward* selanjutnya akan dihubungkan dan membentuk nilai keluaran dengan perhitungan seperti pada persamaan berikut:

$$y_t = U_y \cdot \vec{h}_t + W_y \cdot \overleftarrow{h}_t + b_y \quad (2)$$

Keterangan: y_t = *Output gate* Bi-LSTM

U_y = nilai bobot untuk *output gate* pada $\vec{h}_t$

$\vec{h}_t$ = nilai keluaran pada LSTM *forward*

W_y = nilai bobot untuk *output gate* pada $\overleftarrow{h}_t$

$$\overleftarrow{h}_t = \text{nilai keluaran pada LSTM backward}$$

Isi informasi terdapat dalam bentuk vektor, di mana vektor ini merepresentasikan setiap langkah waktu dalam data harga saham syariah. Dalam konteks data *Time series* harga saham syariah, harga penutupan pada hari sebelumnya dapat dikorelasikan dengan harga penutupan pada hari berikutnya. Metode BiLSTM mampu mengekstraksi fitur urutan dengan lebih baik, karena memproses data dalam dua arah, yakni maju dan mundur, sehingga dapat menangkap pola jangka pendek dan panjang secara lebih efektif. Hal ini membuat BiLSTM sangat cocok untuk memodelkan fluktuasi harga saham syariah yang dipengaruhi oleh berbagai faktor ekonomi dan pasar (D. I. Puteri et al., 2024).

2.6. LSTM dengan *Attention Mechanism* (LSTM-AM)


LSTM dengan *Attention Mechanism* (LSTM-AM) adalah pengembangan lebih lanjut dari LSTM yang menggabungkan *Attention Mechanism* untuk meningkatkan kemampuan model dalam memfokuskan pada bagian-bagian penting dari data *input*. Meskipun LSTM dan BiLSTM mampu menyimpan informasi jangka panjang, keduanya tetap memiliki keterbatasan dalam memilih bagian informasi mana yang paling relevan untuk setiap prediksi. Untuk mengatasi hal tersebut, diperkenalkan *Attention Mechanism* (Bahdanau et al., 2016) ke dalam struktur LSTM, sehingga lahirlah model LSTM-AM (LSTM dengan *Attention Mechanism*). LSTM-AM meningkatkan prediksi urutan dengan memungkinkan model untuk fokus pada bagian-bagian yang relevan dari urutan masukan, meningkatkan akurasi dalam perkiraan deret waktu (Han et al., 2023). LSTM-AM meningkatkan kinerja model dengan secara otomatis memberi bobot pada fitur-fitur masukan, memungkinkan identifikasi yang lebih baik dari faktor-faktor utama yang mempengaruhi perkiraan limpasan jangka panjang (Wen & Li, 2023).

Menurut penelitian (Wen & Li, 2023) LSTM-AM, atau LSTM-*Attention*-LSTM, adalah model prediksi *Time series* yang menggabungkan arsitektur *Long Short-*

Term Memory (LSTM) dalam struktur *encoder-decoder* dengan tambahan mekanisme perhatian (*Attention Mechanism*) di antaranya. Model ini dirancang untuk mengatasi kelemahan dari model *encoder-decoder* tradisional, di mana *decoder* seringkali tidak dapat sepenuhnya memanfaatkan informasi dari data sekuensial panjang yang diberikan oleh *encoder*.

Mekanisme perhatian di LSTM-AM berfungsi untuk menghitung hubungan antar data sekuensial dan memungkinkan model untuk memberikan bobot lebih besar pada informasi yang relevan. Hal ini membuat model lebih efisien dalam menangani data *Time series* yang memiliki rentang waktu panjang dan kompleks. Dengan memprioritaskan informasi penting, LSTM-AM mampu meningkatkan akurasi prediksi dibandingkan model-model dominan lainnya, karena dapat menangkap keterkaitan yang panjang dan kompleks di antara data *Time series*.

Dalam konteks prediksi harga saham, LSTM-AM dapat membantu model untuk fokus pada periode waktu atau fitur tertentu yang lebih relevan untuk prediksi, potensial meningkatkan akurasi dibandingkan dengan LSTM standar (Lu et al., 2023). berikut struktur LSTM-AM model pada Gambar 9.



Gambar 9. Long and short-term memory Network LSTM model (Aldi et al., 2019).

Struktur LSTM-AM mengikuti pendekatan *encoder-decoder*, dengan *encoder* berupa LSTM yang menghitung *hidden state* berdasarkan persamaan (1.3) hingga (1.9) pada Subbab 2.4, dan *decoder* dilengkapi dengan *Attention* untuk menghasilkan *output* prediktif yang lebih informatif. *Attention Mechanism* dalam LSTM-AM terdiri dari beberapa tahap sebagai berikut:

Persamaan skor perhatian (Alignment Score):

$$e_{t,k} = S_t^T h_k \quad (3.1)$$

Keterangan: $e_{t,k}$ = skor perhatian antara *hidden state decoder* pada waktu ke- t dan *hidden state encoder* pada waktu ke- k .

S_t = *hidden state decoder* pada waktu ke- t .

h_k = *hidden state encoder* pada waktu ke- k .

$S_t^T h_k$ = *dot product*, digunakan untuk mengukur seberapa cocok konteks *input* h_k terhadap kebutuhan *output* saat ini S_t .

Hidden state h_k berasal dari hasil komputasi LSTM *encoder* (menggunakan rumus (1.8)). Jadi *Attention mechanism* mengambil hasil dari LSTM biasa sebagai *input*. Selanjutnya memberikan bobot perhatian (*Attention Weight*) dengan persamaan sebagai berikut:

$$\alpha_{t,k} = \frac{\exp(e_{t,k})}{\sum_{j=1}^T \exp(e_{t,j})} \quad (3.2)$$

Keterangan: $\alpha_{t,k}$ = bobot perhatian untuk h_k pada waktu t .

T = panjang urutan *input*.

Fungsi softmax memastikan bobot α terdistribusi antara 0 hingga 1 dan totalnya 1.

Bobot perhatian ini dihitung langsung dari skor $e_{t,k}$ pada rumus (3.1). Semakin tinggi skor $e_{t,k}$, semakin besar bobot perhatian $\alpha_{t,k}$. Kemudian menghitung vektor konteks (*Context Vector*) dengan persamaan sebagai berikut:

$$C_t = \sum_{k=1}^T \alpha_{t,k} h_k \quad (3.3)$$

Keterangan: C_t = vektor konteks pada waktu t .

Kombinasi linier dari seluruh *hidden state encoder* h_k ,
ditimbang dengan bobot perhatian $\alpha_{t,k}$.

Vektor konteks ini merupakan hasil penggabungan seluruh *hidden state encoder* yang sudah diberi bobot oleh *Attention* pada rumus (3.2). Setelah menghitung vektor konteks, dilanjutkan dengan gabungan antara kontekstual dan *state decoder* dengan persamaan sebagai berikut:

$$\tilde{h}_t = \tanh(W_c[C_t; S_t]) \quad (3.4)$$

Keterangan: $\tilde{h}_t$ = representasi gabungan antara konteks dan *hidden state decoder*.

W_c = bobot gabungan.

$C_t; S_t$ = konkatenasi (penggabungan vektor) antara konteks dan *state decoder*.

Fungsi aktivasi *tanh* digunakan untuk menjaga non-linearitas.

Gabungan antara C_t dari rumus (3.3) dan S_t dari proses *decoding*. Di sinilah informasi penting dari *encoder* dikombinasikan dengan status *decoding* saat ini. Setelah itu menghasilkan *output* akhir prediksi dengan persamaan sebagai berikut:

$$y_t = W_y \cdot \tilde{h}_t + b_y \quad (3.5)$$

Keterangan: y_t = *output* prediksi pada waktu ke- t .

W_y = bobot *output*.

b_y = bias.

$\tilde{h}_t$ = hasil gabungan dari informasi kontekstual dan status *decoding*.

Output akhir dihasilkan dari hasil proses atensi, bukan hanya dari *hidden state* h_t seperti pada LSTM (1.9). Hal ini memungkinkan LSTM-AM untuk membuat

prediksi dengan mempertimbangkan keseluruhan konteks *input*, bukan hanya informasi lokal.

2.7. Error Metrics for Time series Forecasting

Dalam memprediksi data *Time series*, khususnya harga saham syariah, pemilihan metrik evaluasi yang tepat sangat penting untuk mengukur akurasi model. Dua metrik yang umum digunakan untuk mengukur performa model prediksi *Time series* adalah *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Squared Error* (RMSE). Pemilihan MAPE dan RMSE sebagai metrik utama didasarkan pada keunggulan masing-masing dalam memberikan informasi mengenai kesalahan prediksi dan sensitivitas terhadap perbedaan yang besar antara prediksi dan nilai aktual. Adapun MAPE dipilih karena metrik ini menyajikan kesalahan prediksi dalam bentuk persentase, yang mudah dipahami dan memungkinkan perbandingan akurasi model di berbagai rentang harga saham dan RMSE dipilih karena metrik ini memberikan bobot lebih besar pada kesalahan yang lebih besar (*outlier*), yang sangat berguna untuk meminimalkan dampak kesalahan besar dalam prediksi harga saham yang rentan terhadap fluktuasi signifikan.

2.7.1. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) adalah nilai persentase dari kesalahan/*error* yang didapatkan berdasarkan nilai aktual dan nilai hasil prediksi. Rumus MAPE dituliskan sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|\hat{y}_t - y_t|}{y_t} \times 100\% \quad (4)$$

Keterangan: y_t = Hasil prediksi
 $\hat{y}_t$ = data aktual
 n = banyak data

Nilai MAPE dikatakan baik dalam suatu peramalan apabila memiliki hasil yang rendah atau persentasenya mendekati nol. MAPE memiliki range nilai yang dapat dijadikan tolak ukur dalam mengambil kesimpulan apakah peramalan tersebut dalam kategori baik maupun tidak. MAPE digunakan jika ukuran variabel peramalan merupakan faktor penting dalam mengevaluasi akurasi peramalan tersebut. Serta MAPE memiliki tabel pengelompokan yang jelas untuk persentase hasil yang didapat. Sehingga dapat mudah dalam menyimpulkan hasil tersebut masuk kedalam kategori apa (Ilmiah, 2022).

Tabel 2. Arti nilai MAPE untuk kemampuan prediksi model

Skala MAPE	Kemampuan Model dalam Prediksi
<10%	Sangat baik
10-20%	Baik
20-50 %	Cukup Baik
>50%	Buruk

2.7.2. *Root Mean Squared Error (RMSE)*

Root Mean Squared Error (RMSE) adalah salah satu metrik yang digunakan untuk mengukur seberapa baik model prediktif memperkirakan nilai keluaran yang diharapkan. RMSE menghitung akar dari rata-rata kesalahan kuadrat antara nilai yang diprediksi dan nilai aktual. Metrik ini sangat berguna untuk menilai performa model regresi dan memberikan indikasi

seberapa jauh prediksi model dari nilai yang sebenarnya (Normah et al., 2022).

Root Mean Square Error (RMSE) merupakan besarnya tingkat kesalahan hasil prediksi, dimana semakin kecil (mendekati 0) nilai RMSE maka hasil prediksi akan semakin akurat (Hodson, 2022). Nilai RMSE dapat dihitung dengan persamaan sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

Keterangan : n = jumlah data uji

y_i = nilai aktual pada data ke- i

$\hat{y}_i$ = nilai prediksi pada data ke- i

RMSE memberikan bobot lebih besar pada kesalahan yang lebih besar karena kesalahan dikuadratkan sebelum dirata-ratakan. Semakin kecil nilai RMSE, semakin baik performa model dalam memprediksi nilai yang sebenarnya. RMSE sering digunakan dalam evaluasi model prediksi harga saham karena sensitivitasnya terhadap perbedaan yang besar antara prediksi dan realitas.

2.8. *R-squared* (R^2)

R-squared (R^2), atau koefisien determinasi, adalah metrik statistik yang digunakan untuk mengukur seberapa baik model prediksi merepresentasikan variasi dalam data aktual. R^2 memberikan indikasi seberapa besar proporsi variabilitas dalam data yang dapat dijelaskan oleh model. Nilai R^2 berkisar antara 0 hingga 1 (Azubuike, 2019), dari penjelasan di atas dapat dijabarkan bahwa $R^2 = 1$ menunjukkan bahwa model sepenuhnya menjelaskan variasi data. $R^2 = 0$ menunjukkan bahwa model

tidak dapat menjelaskan variasi data sama sekali. Adapun rumus *R-squared* (R^2) sebagai berikut:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \tilde{y})^2} \text{ atau } R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (6)$$

Keterangan: y_i = nilai aktual pada data ke-i

$\hat{y}_i$ = nilai prediksi pada data ke-i

$\tilde{y}$ = rata-rata dari semua nilai aktual

n = jumlah data.

SS_{res} = *Sum of Squares of Residuals* = $\sum (y_i - \hat{y}_i)^2$.

SS_{tot} = *Total Sum of Squares* = $\sum (y_i - \tilde{y})^2$.

Nilai R^2 yang mendekati 1 menunjukkan bahwa model memiliki kemampuan yang sangat baik untuk menjelaskan variasi dalam data. Sebaliknya, nilai R^2 yang mendekati 0 mengindikasikan bahwa model memiliki kemampuan yang lemah dalam menjelaskan variasi data. Meskipun R^2 merupakan indikator yang penting dalam evaluasi kinerja model, perlu diingat bahwa nilai R^2 yang tinggi tidak selalu menjamin model yang sempurna, terutama jika data mengandung *outlier* atau variabilitas yang tidak dapat ditangkap oleh model (Azubuike, 2019).

III. METODOLOGI PENELITIAN

3.1. Waktu dan Tempat

3.1.1. Waktu Penelitian

Penelitian ini dilaksanakan pada semester ganjil tahun akademik 2024/2025, yang dimulai pada Agustus 2024.

3.1.2. Tempat Penelitian

Penelitian ini dilaksanakan di Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung, yang berlokasi di Jl. Prof. Dr. Ir. Sumantri Brojonegoro No.1, Gedong Meneng, Kec. Rajabasa, Kota Bandar Lampung, Lampung, 35.

3.2. Alat dan Bahan Penelitian

Penelitian ini memerlukan berbagai alat dan bahan untuk mendukung proses pengolahan data dan implementasi model prediksi. Alat yang digunakan mencakup perangkat keras serta perangkat lunak, sedangkan bahan penelitian terdiri dari data historis harga saham syariah yang diambil dari sumber terpercaya.

3.2.1. Perangkat Keras

Perangkat keras memiliki peran penting dalam menunjang kelancaran proses penelitian, terutama dalam hal komputasi data yang membutuhkan sumber daya tinggi. Pada penelitian ini, jaringan internet dan laptop yang memadai digunakan untuk mendukung proses pengolahan data, pelatihan model, serta analisis hasil. Adapun spesifikasi laptop yang digunakan sebagai berikut:

- A. Manufacture : Asus
- B. Model : TUF Dash F15 FX517ZC
- C. Processor : Intel(R) Core(TM) i7-12650H
- D. GPU : NVIDIA GeForce RTX 3050 Laptop GPU
- E. RAM : 16 GB DDR4
- F. Storage : NVMe SAMSUNG 1TB

3.2.2. Perangkat Lunak

Penelitian ini memanfaatkan beberapa aplikasi perangkat lunak untuk mendukung proses pengolahan data, pengembangan model, dan penyimpanan hasil penelitian. Perangkat lunak ini digunakan pada berbagai tahap penelitian, mulai dari penulisan kode, penyimpanan data, hingga pengujian model. Berikut adalah perangkat lunak yang digunakan:

- A. Sistem Operasi *Windows* 11 Home
- B. Web Browser (Microsoft edge)
- C. Google Colab
- D. Google Drive
- E. Python 3.10


3.2.3. Bahan Penelitian

Dataset yang digunakan dalam penelitian ini berasal dari yahoo finance. Data merupakan harga penutupan (*closing price*) dari lima emiten saham syariah dalam rentang waktu lima tahun, dari Desember 2016 sampai Desember 2021. Berikut lima emiten pada penelitian ini: PT Aneka Tambang Tbk (ANTM), Erajaya Swasembada Tbk (ERAA), Kalbe Farma Tbk (KLBF), Semen Indonesia (Persero) Tbk (SMGR), Wijaya Karya (Persero) Tbk (WIKA). Data diunduh dalam format CSV dan akan diproses lebih lanjut untuk keperluan analisis.

3.3. Metode

Penelitian ini merupakan studi kuantitatif dengan metode pendekatan eksperimen yang bertujuan untuk membandingkan kinerja algoritma *Long Short-Term Memory* (LSTM), *Bidirectional LSTM* (BiLSTM), dan LSTM dengan *Attention Mechanism* (LSTM-AM) dalam memprediksi harga saham syariah. Penelitian ini mencakup proses pelatihan model, evaluasi, dan analisis hasil prediksi berdasarkan data historis. Dalam penelitian kuantitatif, yang dilandasi pada suatu asumsi bahwa suatu gejala itu dapat diklasifikasikan, dan hubungan gejala bersifat kausal (sebab akibat). Adapun desain penelitian diartikan sebagai cara ilmiah yang dilakukan peneliti untuk mendapatkan data dengan tujuan dan kegunaan tertentu. Desain penelitian ini mencakup rencana, struktur, dan *strategi* yang dirancang untuk menemukan jawaban dari pertanyaan penelitian (Sugiyono, 2020).


3.4. Tahapan Penelitian



Gambar 10. Diagram alur tahapan penelitian.

Adapun tahapan penelitian ini dilaksanakan mengikuti langkah-langkah dalam diagram alur pada sebagai berikut:

1. Pengumpulan Data: Penelitian diawali dengan perumusan masalah dan tujuan, yaitu membandingkan kinerja algoritma LSTM, BiLSTM, dan LSTM-AM dalam memprediksi harga saham syariah. Pada tahap ini, data historis harga saham syariah dikumpulkan dari sumber yang relevan.



Gambar 11. Dataset penelitian.

2. *Exploratory Data Analysis*: Analisis awal dilakukan untuk memahami karakteristik data yang dikumpulkan dengan identifikasi pola yakni melihat pola musiman dan siklus pada harga saham syariah, yang dapat membantu ketiga model dalam menangkap karakteristik unik dari saham syariah. Kemudian identifikasi trend untuk mendeteksi tren naik atau turun yang terjadi pada harga saham selama periode tertentu, untuk membantu model memahami arah pergerakan harga.
3. *Preprocessing*: Data mentah diolah melalui beberapa langkah untuk memastikan kualitas dan kesesuaian data sebelum dimasukkan ke dalam model. Adapun tahapan *Preprocessing* sebagai berikut:
 - a. *Data Splitting*/Pembagian Data: Data dibagi menjadi data latih (75%), data validasi (8.33%), dan data uji (16.66%) untuk memastikan bahwa model diuji pada data yang belum pernah dilihat sebelumnya.
 - b. *Scaling*/Penyesuaian Skala: Menggunakan metode *Robust Scaling* untuk mengurangi pengaruh *outlier* dan menjaga konsistensi data, yang penting untuk ketiga algoritma prediksi. Terdapat banyak metode *Scaling* data yang dapat mempengaruhi performa model pada *training*, salah satunya yaitu *MinMax Scaling* yang dapat mengcover seluruh range nilai data sehingga performa menjadi sangat akurat, akan tetapi hanya pada data yang diketahui. *Robust Scaling* adalah metode yang dapat menghasilkan performa hasil

training yang lebih aktual karena prediksi dilakukan pada data yang terjaga kondisi aslinya. *Robust Scaling* dilakukan dengan menskala data berdasarkan median dan IQR data. *Scaling* dapat dijabarkan pada persamaan berikut.

$$X_{scaled} = \frac{(X - median(x))}{IQR(X)} \quad (7)$$

Keterangan: X = keseluruhan data.

$median(x)$ = nilai median dari X .

$IQR(X)$ = nilai IQR dari X .

- c. *Time series Formatting* / Pembentukan Data *Time series*: Data dikonversi ke format *Time series* agar ketiga model (LSTM, BiLSTM, dan LSTM-AM) dapat memahami pola temporal dalam data. Pada penelitian ini *time series* dibuat dengan mengambil data n -hari yang lalu dengan target prediksi harga saham hari esok $t + 1$, sebagai *hyperparameter*, *time steps* = n (data input adalah X_{t-n+1} hingga X_t dan target adalah X_{t+1}).
4. *Modeling Data* / Pelatihan Model (LSTM, BiLSTM, LSTM-AM): Data yang telah diproses kemudian digunakan untuk melatih tiga model *deep learning*, yaitu LSTM, BiLSTM, dan LSTM-AM. Setiap model akan dilatih menggunakan konfigurasi *hyperparameter* yang sesuai untuk mengoptimalkan kinerjanya. Berikut tahapan dalam pelatihan model:
 - a. LSTM (*Long Short-Term Memory*): Melatih model LSTM untuk menangkap pola jangka panjang dalam data *time series* saham syariah. LSTM dipilih karena kemampuannya dalam mengingat informasi dari urutan data yang panjang.
 - b. BiLSTM (*Bidirectional LSTM*): Melatih model BiLSTM untuk menangkap pola dari dua arah waktu (maju dan mundur), sehingga memungkinkan analisis yang lebih komprehensif dari hubungan temporal.
 - c. LSTM-AM (LSTM dengan *Attention Mechanism*): Melatih model LSTM-AM yang menggunakan mekanisme perhatian (*Attention Mechanism*) untuk

memberikan bobot lebih pada data yang lebih relevan, membantu model memfokuskan perhatian pada poin data yang penting.

- d. *Hyperparameter Tuning*: Menyempurnakan parameter, seperti *learning rate*, jumlah epoch, dan ukuran batch, untuk ketiga model, sehingga dapat memberikan hasil optimal pada setiap algoritma yang diuji. Pada proses training jumlah epoch menentukan durasi training. Ini dapat dipersingkat dengan menambahkan fungsi callback yaitu *early_stopping*, dimana *early_stopping* dapat menghentikan proses training pada suatu epoch saat *val_loss* tidak dapat menghasilkan nilai yang lebih baik lagi, yaitu mencapai suatu minimum dan tidak dapat mengurangi *loss* lagi.
 - e. *Window Cross-validation*: *Cross-validation* bertujuan untuk mengetahui kemampuan model beradaptasi pada data yang belum terlihat, sehingga training dilakukan beberapa kali pada sebagian data saja secara berturut-turut. Untuk beradaptasi pada data yang bergantung waktu, urutan data berpengaruh, sehingga digunakan metode *Window Cross-validation*. Pemrosesan data untuk training dilakukan dengan pembagian data sebesar 16.66%, 33.33%, 50%, 66.66%, dan 83.33% untuk data training+validation, sedangkan untuk data *testing* sebesar 16.66% sehingga didapat 5 *fold* untuk training sebuah dataset untuk model. Pada praktiknya pemilihan jumlah *fold* ini sesuai dengan aturan yang umum digunakan, yaitu 5-10 *fold*. Semakin besar jumlah *fold* semakin baik untuk konsistensi hasil training, dengan menyesuaikan jumlah data yang ada untuk training dan *testing*. Maka, membagi data sebanyak 5 kali secara umum cukup untuk hasil training yang stabil dan konsisten.
5. *Evaluating Model*: Setelah melatih ketiga model, kinerjanya dibandingkan menggunakan metrik evaluasi. Adapun tahapannya yakni:
- a. RMSE (*Root Mean Squared Error*): Digunakan untuk mengukur kesalahan rata-rata kuadrat dari prediksi model, berguna untuk mengukur akurasi prediksi secara umum.
 - b. MAPE (*Mean Absolute Percentage Error*): Digunakan untuk mengukur persentase kesalahan rata-rata absolut, sangat cocok untuk melihat kesalahan relatif dalam prediksi saham.

- c. *R-squared* (R^2): Digunakan sebagai metrik measure of accuracy untuk mengukur seberapa besar variasi dalam data yang dapat dijelaskan oleh model.

Setiap metrik ini diterapkan untuk menguji dan membandingkan kinerja tiga model (LSTM, BiLSTM, dan LSTM-AM) dalam prediksi harga saham syariah, sehingga memungkinkan evaluasi yang lebih komprehensif terhadap akurasi dan kemampuan prediksi masing-masing model.

- 6. *Comparing Model*: Hasil evaluasi kinerja dari ketiga algoritma dibandingkan dan dianalisis untuk menentukan algoritma yang memberikan hasil prediksi terbaik. Analisis ini mencakup diskusi mengenai keunggulan dan kelemahan masing-masing algoritma dalam konteks prediksi harga saham syariah.

V. SIMPULAN DAN SARAN

5.1. Kesimpulan

Penelitian ini bertujuan untuk membangun dan membandingkan kinerja tiga algoritma *deep learning Long Short-Term Memory* (LSTM), *Bidirectional LSTM* (BiLSTM), dan LSTM dengan *Attention Mechanism* (LSTM-AM) dalam memprediksi harga saham syariah berdasarkan data historis dari lima emiten syariah: ANTM, ERAA, KLBF, SMGR, dan WIKA. Berdasarkan proses eksperimen yang telah dilakukan, diperoleh beberapa kesimpulan sebagai berikut:

- A. Model prediksi harga saham syariah berhasil dibangun menggunakan ketiga metode: LSTM, BiLSTM, dan LSTM-AM. Proses pembangunan melibatkan tahapan data *Preprocessing* (cleaning, *Scaling*, *time series* formatting), pelatihan model menggunakan *window cross-validation* dengan pembagian data *training*, *validation*, dan *testing* sebanyak 5 *fold* untuk masing-masing sekali proses pembagian data dan tahap *training*, dengan 4 kali *training* menggunakan *fixed hyperparameter* dan *training* akhir menggunakan *hyperparameter tuning*, serta evaluasi berdasarkan metrik RMSE, MAPE, dan R^2 .
- B. Model LSTM dan BiLSTM menunjukkan hasil yang baik dan memuaskan. Dari rata-rata performansi yang didapatkan, model LSTM dapat mencapai nilai MAPE dengan rata-rata 11.87%, sedangkan model BiLSTM mampu mencapai nilai MAPE yang lebih baik lagi yaitu dengan rata-rata 9.41%. Sementara itu, model LSTM-AM belum dapat mencapai performansi yang setara dengan LSTM maupun BiLSTM yaitu dengan MAPE rata-rata

14.58%. Dari nilai rata-rata performansi yang lebih tertinggal daripada model lainnya, diketahui model LSTM-AM masih belum dapat mencapai akurasi yang diinginkan dan performansi LSTM-AM masih belum sebaik model LSTM dan BiLSTM.

5.2. Saran

Berdasarkan hasil dan kesimpulan yang diperoleh, berikut adalah beberapa saran yang dapat menjadi masukan bagi penelitian selanjutnya:

- A. Model LSTM-AM tidak direkomendasikan untuk prediksi harga saham syariah. Model ini hanya mengambil bagian dengan bobot tertinggi mungkin tidak sesuai dengan karakteristik data harga saham yang memerlukan pertimbangan menyeluruh terhadap seluruh urutan historis.
- B. Untuk menangani volatilitas ekstrem pada harga saham, disarankan untuk menambahkan fitur eksternal seperti volume perdagangan, indeks pasar global, atau indikator ekonomi makro sebagai *input* tambahan ke dalam model prediksi.
- C. Penelitian ini hanya menggunakan closing price sebagai variabel prediksi. Untuk hasil yang lebih komprehensif, penelitian mendatang dapat memasukkan open, high, low, dan volume (OHLCV) agar model dapat menangkap lebih banyak dinamika pasar.
- D. Melakukan generalisasi model, yaitu dengan menguji model pada data baru yang belum pernah dilihat sebelumnya (*out-of-sample data*). Hal ini bertujuan untuk menilai apakah model mampu mempertahankan performa prediksi di luar data yang digunakan, sehingga model benar-benar andal untuk diterapkan pada data dunia nyata.
- E. Perlu dilakukan eksperimen lanjutan dengan algoritma lain yang lebih kompleks seperti Transformer, Temporal Fusion Transformer (TFT), atau hybrid models (misal LSTM-ARIMA) untuk dibandingkan dengan performa LSTM, BiLSTM, dan LSTM-AM.

DAFTAR PUSTAKA

- Akram, H. M., Fitri, R., Hasanah, Q., Irfany, M. I., & Haq, D. A. (2024). The Fundamental Analysis of Indonesian Islamic Stocks and Its Impact on Stock Prices. *Islamic Capital Market*, 2(1). <https://doi.org/10.58968/icm.v2i1.484>
- Azubuike, M. (2019). On the Misconception of R^2 for $(r)^2$ in a Regression Model. *International Journal of Research and Scientific Innovation (IJRSI)* |, VI(Xii), 71–76.
- Bahdanau, D., Cho, K., & Bengio, Y. (2016). *Neural Machine Translation by Jointly Learning to Align and Translate*. <http://arxiv.org/abs/1409.0473>
- Budiprasetyo, G., Hani'ah, M., & Aflah, D. (2023a). Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM). *Jurnal Nasional Teknologi Dan Sistem Informasi*, 8, 164–172. <https://doi.org/10.25077/TEKNOSI.v8i3.2022.164-172>
- Budiprasetyo, G., Hani'ah, M., & Aflah, D. Z. (2023b). 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>
- Chen, N. (2024). Exploring the development and application of LSTM variants. *Applied and Computational Engineering*, 53(1), 103–107. <https://doi.org/10.54254/2755-2721/53/20241288>
- Cho, K., & Kim, Y. (2022). Improving streamflow prediction in the WRF-Hydro model with LSTM networks. *Journal of Hydrology*, 605, 127297. <https://doi.org/10.1016/j.jhydrol.2021.127297>
- Fang, W., Zhuo, W., Yan, J., Song, Y., Jiang, D., & Zhou, T. (2022). Attention meets long short-term memory: A deep learning network for traffic flow forecasting. *Physica A: Statistical Mechanics and Its Applications*, 587, 126485. <https://doi.org/https://doi.org/10.1016/j.physa.2021.126485>
- Fauzi, R., Nasution, A. A., & Arifa, P. (2022). Analisis Saham Syariah. *Jurnal Kajian Ekonomi Syariah*, 2(2), 107–120.

- Feng, Z., Hu, X., Tian, Z., Jiang, B., Zhang, H., & Zhang, W. (2023). Bi-LSTM-Based Dynamic Prediction Model for Pulling Speed of Czochralski Single-Crystal Furnace. *Journal of Computing and Information Science in Engineering*, 23(4). <https://doi.org/10.1115/1.4056138>
- Graves, A., & Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural Networks*, 18(5), 602–610. <https://doi.org/https://doi.org/10.1016/j.neunet.2005.06.042>
- Han, D., Liu, P., Xie, K., Li, H., Xia, Q., Cheng, Q., Wang, Y., Yang, Z., Zhang, Y., & Xia, J. (2023). An attention-based LSTM model for long-term runoff forecasting and factor recognition. *Environmental Research Letters*, 18(2), 024004. <https://doi.org/10.1088/1748-9326/acaedd>
- Hodson, T. O. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. *Geoscientific Model Development*, 15(14), 5481–5487. <https://doi.org/10.5194/gmd-15-5481-2022>
- Ilmiah, M. (2022). *Implementasi Metode Bidirectional Long Short-Term Memory (Bi-LSTM) untuk Prediksi Kasus Positif Covid-19 di Indonesia*. UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA.
- Khuwaja, P., Khowaja, S. A., Khoso, I., & Lashari, I. A. (2020). Prediction of stock movement using phase space reconstruction and extreme learning machines. *Journal of Experimental & Theoretical Artificial Intelligence*, 32(1), 59–79. <https://doi.org/10.1080/0952813X.2019.1620870>
- Lu, S., Liu, M., Yin, L., Yin, Z., Liu, X., & Zheng, W. (2023). The multi-modal fusion in visual question answering: a review of attention mechanisms. *PeerJ Computer Science*, 9, e1400. <https://doi.org/10.7717/peerj-cs.1400>
- Mahajan, R., & Mansotra, V. (2021). Predicting Geolocation of Tweets: Using Combination of CNN and BiLSTM. *Data Science and Engineering*, 6(4), 402–410. <https://doi.org/10.1007/s41019-021-00165-1>
- Normah, Rifai, B., Vambudi, S., & Maulana, R. (2022). Analisa Sentimen Perkembangan Vtuber Dengan Metode Support Vector Machine Berbasis SMOTE. *Jurnal Teknik Komputer AMIK BSI*, 8(2), 174–180. <https://doi.org/10.31294/jtk.v4i2>
- Pham, T. D. (2021). Time–frequency time–space LSTM for robust classification of physiological signals. *Scientific Reports*, 11(1), 6936. <https://doi.org/10.1038/s41598-021-86432-7>
- Puteri, D. (2023). Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah. *Euler : Jurnal Ilmiah Matematika, Sains Dan Teknologi*, 11, 35–43. <https://doi.org/10.34312/euler.v11i1.19791>

- Puteri, D. I. (2023). Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah. *Euler: Jurnal Ilmiah Matematika, Sains Dan Teknologi*, 11(1), 35–43. <https://doi.org/10.34312/euler.v11i1.19791>
- Puteri, D. I., Darmawan, G., & Ruchjana, B. N. (2024). Prediksi Harga Saham Syariah menggunakan Bidirectional Long Short Term Memory (BiLSTM) dan Algoritma Grid Search. *Jambura Journal of Mathematics*, 6(1), 39–45. <https://doi.org/10.37905/jjom.v6i1.23297>
- Ravikumar, A., & Sriraman, H. (2024). A Deep Understanding of Long Short-Term Memory for Solving Vanishing Error Problem: LSTM-VGP. In P. Baby Maruthi, S. Prasad, & A. K. Tyagi (Eds.), *Machine Learning Algorithms Using Scikit and TensorFlow Environments* (pp. 74–90). IGI Global. <https://doi.org/10.4018/978-1-6684-8531-6.ch004>
- Renjith, S., Manazhy, R., & Suresh, M. S. S. (2024). Sign Language Recognition using BiLSTM model. *2024 IEEE 9th International Conference for Convergence in Technology (I2CT)*, 1–5. <https://doi.org/10.1109/I2CT61223.2024.10543543>
- Samsuduha, S., & Herawati, A. (2023). Konsep Investasi Pasar Modal dan Saham Syariah di Indonesia. *Journal of Islamic Law*, 4(1).
- Schuster, M., & Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE Transactions on Signal Processing*, 45(11), 2673–2681. <https://doi.org/10.1109/78.650093>
- Sugiyono. (2020). *Metode Penelitian Kuantitatif Kualitatif dan R&D* (Dr. Ir. Soetopo, Ed.; Issue August). Alfabeta.
- Wahyudi, A. (2023). *PENERAPAN METODE DEEP LEARNING UNTUK IDENTIFIKASI WAYANG INDONESIA*. Universitas Medan Area.
- Wardani, W. W. K. (2021). *Prediksi Harga Saham Syariah Menggunakan Metode Recurrent Neural Network-Long Short Term Memory*.
- Wen, X., & Li, W. (2023a). Time Series Prediction Based on LSTM-Attention-LSTM Model. *IEEE Access*, 11, 48322–48331. <https://doi.org/10.1109/ACCESS.2023.3276628>
- Wen, X., & Li, W. (2023b). Time Series Prediction Based on LSTM-Attention-LSTM Model. *IEEE Access*, 11, 48322–48331. <https://doi.org/10.1109/ACCESS.2023.3276628>
- Xu, G., Meng, Y., Qiu, X., Yu, Z., & Wu, X. (2019). Sentiment analysis of comment texts based on BiLSTM. *IEEE Access*, 7, 51522–51532. <https://doi.org/10.1109/ACCESS.2019.2909919>
- Zamaluddin, Abdul Rochim, Mabururi Andatu, & Rifki Saputra. (2023). Hukum Jual Beli Saham BRIS di Komunitas Syariah Saham dalam Perspektif Hukum

Islam dan Positif. *Mandub : Jurnal Politik, Sosial, Hukum Dan Humaniora*, 1(4), 333–351. <https://doi.org/10.59059/mandub.v1i4.718>

Zou, Z., Yan, X., Yuan, Y., You, Z., & Chen, L. (2024). Attention mechanism enhanced LSTM networks for latency prediction in deterministic MEC networks. *Intelligent Systems with Applications*, 23, 200425. <https://doi.org/https://doi.org/10.1016/j.iswa.2024.200425>