

Analisis Komparatif Kinerja LSTM, BiLSTM, dan LSTM-AM dalam Prediksi Harga Saham Syariah

Muhamad Ramadhan Kamal ¹⁾, Rahman Taufik ²⁾, Ridho Sholehurrahman ³⁾, Tristiyanto ⁴⁾,
Bita Parga Zen ⁵⁾

^{1,2,3,4)} Ilmu Komputer Universitas Lampung, Indonesia

⁵⁾ Teknik Informatika, Universitas Machung, Indonesia

email : muhamad.ramadhan.kamal21@students.unila.ac.id¹⁾, rahman.taufik@fmipa.unila.ac.id²⁾,
ridho.sholehurrohman@fmipa.unila.ac.id³⁾, tristiyanto.1981@fmipa.unila.ac.id⁴⁾,
bita.parga@machung.ac.id⁵⁾

Abstrak

Pasar saham syariah yang terus berkembang memunculkan kebutuhan mendesak akan pemodelan harga yang lebih akurat, mengingat volatilitas tinggi, perubahan rezim (*regime shift*), dan outlier yang sering mengganggu proses pengambilan keputusan investasi. Studi ini bertujuan membandingkan secara komparatif kinerja tiga algoritma pembelajaran mendalam LSTM (Long Short-Term Memory), BiLSTM (Bidirectional LSTM), dan LSTM-AM (LSTM dengan Attention Mechanism) dalam memprediksi harga saham syariah. Metode penelitian menggunakan data harga penutupan harian dari lima emiten syariah Indonesia (ANTM, ERAA, KLBF, SMGR, dan WIKA) selama periode Desember 2016 hingga Desember 2021. Data diprapemrosesan menggunakan Robust Scaling dan dibentuk menjadi rangkaian waktu dengan window 60 hari. Evaluasi model dilakukan melalui validasi silang berbasis window dengan hasil menunjukkan bahwa BiLSTM memberikan performa terbaik dengan MAPE rata-rata 9.41% dan RMSE 249.956. Kinerja ini diikuti LSTM (MAPE 11.87%) dan LSTM-AM sebagai yang terendah (MAPE 19.58%). Temuan ini memberikan pemahaman jelas mengenai efektivitas arsitektur dalam memprediksi harga saham syariah yang dinamis, menunjukkan bahwa penambahan kompleksitas model (LSTM-AM) tidak selalu menjamin akurasi yang lebih baik dalam domain ini. Dampaknya, BiLSTM dapat dipertimbangkan sebagai model yang lebih unggul untuk prediksi yang lebih stabil.

Kata Kunci :

BiLSTM, LSTM, LSTM-AM, prediksi harga saham, saham syariah

Abstract

The continuously evolving Sharia stock market necessitates more accurate price modeling due to high volatility, regime shifts, and outliers that frequently disrupt investment decision-making processes. This study aims to comparatively evaluate the performance of three deep learning algorithms—LSTM (Long Short-Term Memory), BiLSTM (Bidirectional LSTM), and LSTM-AM (LSTM with Attention Mechanism)—in predicting Sharia stock prices. The research method utilizes daily closing price data from five Indonesian Sharia-compliant issuers (ANTM, ERAA, KLBF, SMGR, and WIKA) spanning the period of December 2016 to December 2021. The data underwent preprocessing using Robust Scaling and was structured into time series with a 60-day window. Model evaluation was conducted via window-based cross-validation with the results show that BiLSTM delivered the best performance with an average MAPE of 9.41% and RMSE of 249.956. This performance was followed by LSTM (MAPE 11.87%) and LSTM-AM as the lowest (MAPE 19.58%). These findings provide a clear understanding of the effectiveness of each architecture in predicting dynamic Sharia stock prices, indicating that increasing model complexity (LSTM-AM) does not always guarantee better accuracy in this domain. Consequently, BiLSTM can be considered the superior model for more stable prediction.

Keywords :

BiLSTM, LSTM, LSTM-AM, stock price prediction, Islamic stocks

1. PENDAHULUAN

Perkembangan pasar saham syariah yang pesat menciptakan kebutuhan akan metode prediksi harga yang akurat untuk membantu investor dalam pengambilan keputusan investasi. Saham

syariah menjadi instrumen investasi yang menarik karena prinsip-prinsipnya yang berlandaskan syariah Islam, menghindari unsur riba, gharar, dan maysir [1][2]. Namun, pergerakan saham syariah menunjukkan volatilitas dan perilaku dinamis yang membuat prediksi menjadi tantangan kompleks [3].

Salah satu metode yang umum digunakan untuk mengatasi kompleksitas pergerakan saham adalah *deep learning*. Metode *deep learning* telah terbukti efektif dalam menganalisis data *time series*, data sekuensial, non-linear, termasuk dalam prediksi harga saham syariah [4][5]. Beberapa studi berhasil memanfaatkan arsitektur *deep learning* seperti *Long Short-Term Memory (LSTM)*, *Bidirectional LSTM (BiLSTM)* [4].

Algoritma *LSTM* merupakan metode populer dalam pemodelan data saham sekuensial karena mampu menangkap pola jangka panjang dalam data *time series* [5][6][7]. Studi sebelumnya menunjukkan *LSTM* dapat memprediksi saham syariah dengan baik, dibuktikan berdasarkan nilai *MAPE* dan beberapa emiten seperti ANTM (2,64%), ERAA (2,24%), KLBF (1,51%), SMGR (1,83%), dan WIKA (2,66%) [8].

Selanjutnya, *BiLSTM* banyak dieksplorasi untuk memproyeksi data *time series* karena mampu memproses *input* secara maju dan mundur, memberikan konteks tambahan dalam prediksi [9][10]. Studi yang dilakukan [11] menunjukkan bahwa *BiLSTM* memiliki performa yang lebih baik daripada *LSTM* dalam memprediksi harga saham, khususnya dalam konteks volatilitas rendah dan sedang, dengan nilai *MAPE* yang lebih baik pada beberapa emiten seperti ANTM (2,59%), UNVR (1,77%), dan INDF (1,05%). Hal ini menunjukkan bahwa pemrosesan dua arah oleh *BiLSTM* dapat meningkatkan kualitas pemodelan terhadap pola data saham yang fluktuatif.

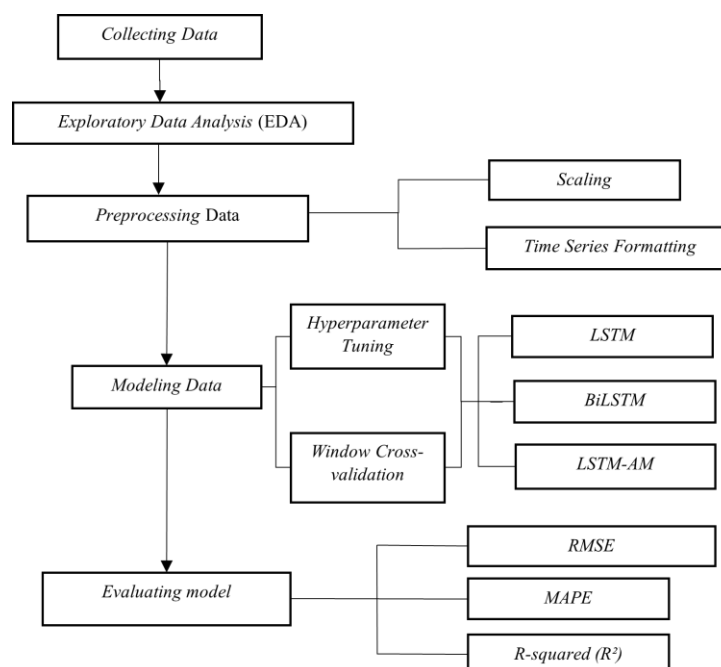
Sementara itu, pendekatan model *hybrid* seperti *LSTM* dengan *Attention Mechanism (LSTM-AM)* telah dieksplorasi untuk data *time series* [12][13][14]. *LSTM-AM* membangun model proyeksi berdasarkan informasi penting dari penetapan bobot yang berbeda pada *input* [12][13]. Studi [14] berhasil menerapkan *LSTM-AM* dalam memprediksi *latency* pada jaringan *Mobile Edge Computing (MEC)* deterministik dengan akurasi prediksi yang superior. Pada kondisi *SNR* 25 dB dengan 3 *server* komputasi tepi, *LSTM-AM* mencapai akurasi prediksi mendekati 100%, secara signifikan mengungguli metode *CNN* konvensional (sekitar 94,28%) dan metode *deep learning* tradisional (sekitar 84,47%). Mekanisme *attention* yang diintegrasikan dengan *LSTM* terbukti efektif dalam menangkap ketergantungan temporal dan menekankan fitur-fitur relevan dalam data *input* sekuensial. Sama halnya dengan data *latency* jaringan, data harga saham juga merupakan data *time series* yang memiliki karakteristik fluktuatif dan ketergantungan temporal yang kompleks [12][13]. Model *LSTM-AM* memiliki karakteristik yang relevan untuk mengatasi data saham yang memiliki volatilitas tinggi dan pola pergerakan yang tidak statis, di mana informasi pada periode waktu tertentu memiliki pengaruh signifikan terhadap harga di masa depan [14][15]. Pendekatan *hybrid* lainnya terbukti mampu meningkatkan akurasi *forecasting*, sebagaimana ditunjukkan pada studi [16]. Studi ini menggabungkan metode *LSTM* dan *Random Forest Regresor (RFR)* untuk mengatasi kesenjangan data dan fluktuasi dalam *forecasting* pendapatan pajak. Meskipun penerapan *RFR* terbatas pada interpolasi data yang bukan harian, tetapi hasil menunjukkan akurasi sebesar 86% dan *MAPE* sebesar 3.49%. Studi-studi [14][16] menunjukkan bahwa model *hybrid* dapat diterapkan di berbagai studi kasus.

Meskipun studi [9–12] telah berhasil melakukan proyeksi harga saham dan studi [14][17] menunjukkan efektivitas pendekatan *hybrid* pada data deret waktu, sebagian besar penelitian tersebut belum mengevaluasi kinerja model dalam kondisi pasar yang ditandai oleh volatilitas tinggi, *regime shift*, serta keberadaan *outlier*, terutama pada emiten saham syariah seperti ANTM, ERAA, KLBF, SMGR, dan WIKA [9]. Selain itu, penelitian sebelumnya cenderung

berfokus pada satu arsitektur model saja sehingga tidak memberikan gambaran komparatif yang menyeluruh, dan proses penentuan *hyperparameter* masih dilakukan secara *trial-and-error* yang berpotensi menghasilkan konfigurasi kurang optimal. Minimnya uji sensitivitas terhadap *window size*, horizon prediksi, serta kondisi pasar yang berubah-ubah juga membuat evaluasi kinerja model menjadi kurang komprehensif, sekaligus meningkatkan risiko *overfitting* pada seluruh emiten yang dianalisis. Berdasarkan ketiadaan studi komparatif yang sistematis serta belum adanya pengembangan model *hybrid* yang mempertimbangkan isu volatilitas, *overfitting*, dan generalisasi pada saham syariah, penelitian ini eksplorasi lebih lanjut model *LSTM-AM*, dan membandingkannya dengan model *LSTM* dan *BiLSTM*. Meskipun pendekatan berbasis *attention* dilaporkan dapat meningkatkan akurasi [14], efektivitasnya dalam konteks prediksi harga saham masih belum tervalidasi secara memadai. Studi ini bertujuan untuk menganalisis dan membandingkan kinerja tiga algoritma deep learning, yaitu *LSTM*, *BiLSTM*, dan *LSTM-AM*, dalam prediksi harga saham syariah. Fokus utama studi adalah untuk mengevaluasi sejauh mana pengembangan model hybrid *LSTM-AM* mampu memberikan hasil dibandingkan model lainnya dalam konteks data saham syariah. Dengan demikian, studi ini diharapkan dapat memberikan kontribusi terhadap pengembangan metode prediktif yang lebih tepat guna bagi pasar saham syariah di Indonesia.

2. METODE PENELITIAN

Studi ini dilakukan berdasarkan tahapan sistematis yang diilustrasikan pada Gambar 1. Tahapan dimulai dari pengumpulan data, analisis eksploratori, pemrosesan awal data, pemodelan, dan evaluasi performa untuk setiap model yang diusulkan. Tahapan ini dirancang untuk memastikan validitas dan keandalan dari model yang diusulkan pada studi ini.



Gambar 1. Diagram alur studi

2.1 Collecting Data

Dataset studi menggunakan harga penutupan harian (*daily price close*) dari lima emiten saham syariah, yakni ANTM, ERAA, KLBF, SMGR, dan WIKA. Pemilihan lima emiten ini didasarkan pada representasi yang baik dari berbagai sektor industri syariah di Indonesia.

Data ini diperoleh dari Yahoo Finance pada periode Desember 2016 hingga Desember 2021 [8].

Tabel 1. Hasil uji stasioner dan linearitas

Emiten	ADF P-Value	Status Stasioner	Korelasi Pearson	Tren Linearitas
ANTM	0.841	Tidak Stasioner	0.681	Tren Naik Kuat
ERAA	0.520	Tidak Stasioner	0.713	Tren Naik Kuat
KLBF	0.016	Stasioner	-0.243	Stabil/Negatif Lemah
SMGR	0.084	Tidak Stasioner	0.061	Sideways (Acak)
WIKA	0.178	Tidak Stasioner	-0.604	Tren Turun Kuat

2.2 Exploratory Data Analysis (EDA)

Tahap EDA dilakukan untuk memahami karakteristik data meliputi pemahaman pola, tren, dan distribusi harga saham. Analisis ini mencakup analisis tren untuk mengidentifikasi pergerakan naik, turun, atau *sideways* setiap saham, uji stasioner menggunakan *Augmented Dickey-Fuller test* (ADF), dan uji linearitas dalam menganalisis korelasi temporal menggunakan korelasi *Pearson*. Analisis yang diusulkan ini memberikan pemahaman yang komprehensif tentang hubungan antar variabel dalam data *time series* [18][17].

Berdasarkan Tabel 1, hasil uji ADF menunjukkan bahwa mayoritas data saham (ANTM, ERAA, SMGR, dan WIKA) memiliki nilai *p-value* > 0.05, yang mengindikasikan data tidak stasioner. Hanya saham KLBF yang memenuhi asumsi stasioneritas dengan *p-value* 0.016.

Selain itu, hasil uji linearitas memperlihatkan karakteristik tren yang berbeda antar emiten. Saham ERAA dan ANTM menunjukkan tren kenaikan yang signifikan dengan korelasi positif masing-masing 0.713 dan 0.681. Sebaliknya, WIKA memiliki tren penurunan yang kuat dengan korelasi -0.604. Adapun SMGR cenderung bergerak sideways tanpa tren yang jelas (korelasi 0.061), dan KLBF menunjukkan stabilitas dengan sedikit kecenderungan negatif.

2.3 Preprocessing Data

Tahap *preprocessing* merupakan langkah dalam mempersiapkan dan meningkatkan kualitas data *time series* untuk pemodelan prediksi harga saham. Salah satu tahapannya yaitu *scaling* atau normalisasi data. Tahapan *scaling* ditujukan untuk menstandarkan nilai fitur ke dalam rentang (0, 1) sehingga model dapat bekerja lebih optimal dan konvergen lebih cepat selama proses *training* [15]. Penerapan *scaling* ini sangat penting dalam konteks data harga saham yang seringkali memiliki volatilitas tinggi dan mengandung *outlier*. Selanjutnya, *robust scaling* dipilih sebagai metode normalisasi karena lebih tahan terhadap *outlier* dibandingkan dengan *standard scaling*, dimana *robust scaling* menggunakan median dan *interquartile range* (IQR) sebagai basis normalisasi sehingga tidak terpengaruh oleh nilai ekstrem dalam data finansial [18]. Sampel data *scaling* dapat dilihat pada Tabel 2.

Selanjutnya *time series formatting* diusulkan untuk mengonversi data ke format *time steps* 60 hari. Teknik ini disesuaikan dengan kebutuhan model dan terbukti efektif dalam prediksi indeks saham, khususnya ketika menggunakan model LSTM maupun model *hybrid* untuk *forecasting time series* [19][20]. Secara proses, *time series formatting* membentuk *sequence data* dimana model dapat mempelajari pola temporal dari 60 hari sebelumnya untuk memprediksi harga saham pada hari berikutnya ($t+1$). Pemilihan *window size* 60 hari mempertimbangkan karakteristik pasar saham yang cenderung menunjukkan pola dalam rentang waktu tersebut. Selain itu, LSTM membutuhkan *input* dengan format tiga dimensi (*samples, timesteps, features*), sehingga data disusun menggunakan teknik *moving window* untuk membentuk urutan 60 hari sebagai satu sampel [21]. Ilustrasi data yang dikonversi ke dalam *time series formatting* dapat dilihat pada Tabel 3 dengan contoh *window size* 3.

Tabel 2. Sampel data setelah scaling

Tanggal	Sebelum Scaling	Sesudah Scaling
01/12/2016	2410.0	0.851724
02/12/2016	2450.0	0.906897
05/12/2016	2460.0	0.920690
06/12/2016	2400.0	0.837931
07/12/2016	2380.0	0.810345

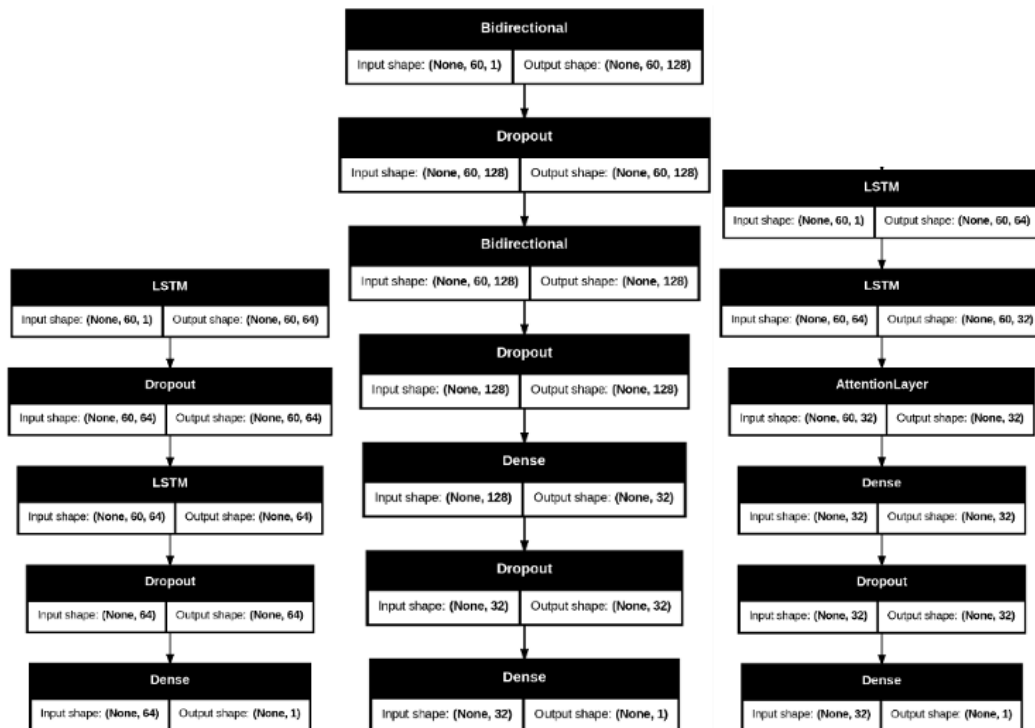
Tabel 3. Ilustrasi time series formatting

Harga (t-2)	Harga (t-1)	Harga (t)	Target(t+1)
2410.0	2450.0	2460.0	2400.0
2450.0	2460.0	2400.0	2380.0
2460.0	2400.0	2380.0	2570.0
2400.0	2380.0	2570.0	2510.0
2380.0	2570.0	2510.0	2480.0

2.4 Modeling Data

Studi ini menggunakan tiga arsitektur model dalam prediksi harga saham syariah, yaitu *LSTM*, *BiLSTM*, dan *LSTM-AM*. Masing-masing model dirancang dengan konfigurasi jaringan tertentu dan dioptimasi menggunakan *hyperparameter*.

Model *LSTM* dibangun dengan dua lapisan *LSTM* berturut-turut yang jumlah unitnya divariasikan dalam rentang 32–256. Untuk mengurangi *overfitting*, digunakan *dropout* antara 0.1–0.5, serta lapisan *Dense* tambahan dengan aktivasi *ReLU*. Proses optimasi dilakukan menggunakan *optimizer* Adam dengan *learning rate* antara 1e-4 hingga 1e-2. Arsitektur akhir model *LSTM* dapat dilihat pada Gambar 2 (a).



Gambar 2. Arsitektur (a) model LSTM (b) BiLSTM (c) LSTM-AM

Sementara itu, arsitektur *BiLSTM* menggunakan kombinasi dua lapisan *Bidirectional* dengan pengaturan unit 32–256, regularisasi L2 antara 0.0001–0.01, dan *dropout* serupa dengan model *LSTM*. Arsitektur akhir model *BiLSTM* dapat dilihat pada Gambar 2 (b).

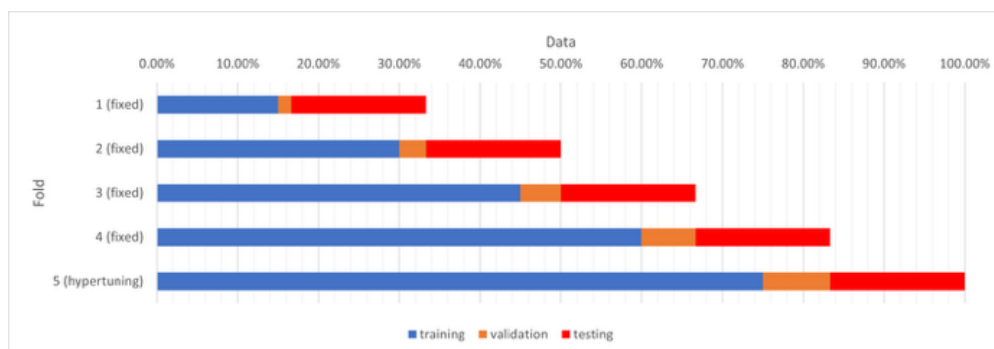
Selanjutnya, arsitektur *LSTM-AM*, yang dapat dilihat pada Gambar 2 (c), dirancang menggunakan dua lapisan *LSTM* sebagai *encoder* dengan jumlah unit yang divariasikan dalam rentang 32–256. Mekanisme *attention* ditempatkan setelah lapisan *LSTM* untuk memberikan bobot pada *time steps*, yang kemudian diteruskan ke lapisan *Dense* sebagai *decoder* untuk menghasilkan prediksi. Guna mencegah *overfitting*, model ini menerapkan *dropout* dengan rentang 0.1–0.5 serta regularisasi L2 antara 0.0001–0.01. Selain itu, terdapat opsi penambahan lapisan *Dense* dengan unit berkisar 16–128, dan *learning rate* dalam rentang $1e-4$ hingga $1e-2$.

Optimasi *hyperparameter* dilakukan menggunakan *Keras Tuner* dengan metode *Randomsearch* untuk memperoleh konfigurasi model yang optimal [22]. *Hyperparameter* yang dioptimasi meliputi jumlah unit pada setiap *layer*, *learning rate*, *dropout rate*, dan *regularization* parameter sesuai dengan karakteristik masing-masing arsitektur model. Proses *tuning* ini melibatkan 20 *trials* untuk setiap model, dengan 3 *executions per trial* untuk memastikan stabilitas hasil. Sedangkan optimasi, digunakan metrik *validation loss* dan *early stopping mechanism* dengan penerapan *patience* 10 *epochs*, hal ini ditujukan untuk mencegah *overfitting* dan mengoptimalkan waktu *training* [23].

2.5 Evaluating Model

Evaluasi model dilakukan menggunakan *Window Cross-validation (WCV)* dengan 5-*fold* untuk mempertahankan karakteristik temporal dari data *time series* finansial. *Window cross-validation* merupakan teknik validasi khusus untuk data *time series* yang membagi data secara berurutan tanpa mengacak urutan temporal [24].

Metode ini memastikan bahwa data *training* selalu mendahului data *testing* secara kronologis, sehingga mencerminkan kondisi prediksi yang realistis dalam praktik *trading* saham. Pembagian data untuk setiap *fold* adalah *Fold 1* (16,66% *training+validation*, 16,66% *testing*), *Fold 2* (33,33% *training+validation*, 16,66% *testing*), *Fold 3* (50% *training+validation*, 16,66% *testing*), *Fold 4* (66,66% *training+validation*, 16,66% *testing*), dan *Fold 5* (83,33% *training+validation*, 16,66% *testing*). Ilustrasi pembagian data dari metode *WCV* dapat dilihat pada Gambar 3.



Gambar 3. Ilustrasi pembagian data *window cross-validation*

Untuk memastikan evaluasi yang komprehensif, kinerja model dievaluasi menggunakan tiga metrik utama yaitu *Mean Absolute Percentage Error (MAPE)*, *Root Mean Square Error (RMSE)*, dan *R-squared (R²)*. Metrik MAPE digunakan untuk mengukur persentase kesalahan

absolut antara nilai aktual dan prediksi, dengan hasil dinyatakan dalam bentuk persentase [20].

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

Sedangkan, metrik RMSE mengukur besarnya tingkat kesalahan hasil prediksi, dimana semakin kecil (mendekati 0) nilai RMSE maka hasil prediksi akan semakin akurat [25].

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

Selanjutnya, R^2 atau koefisien determinasi, adalah metrik statistik yang digunakan untuk mengukur seberapa baik model prediksi merepresentasikan variasi dalam data aktual. Nilai R^2 berkisar antara 0 hingga 1, semakin besar nilai R^2 semakin menunjukkan bahwa model memiliki variasi data [26].

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan Model

Analisis awal terhadap data historis menunjukkan karakteristik dan pola tren yang berbeda pada setiap saham syariah yang dianalisis. Saham ANTM dan ERAA menunjukkan tren dengan volatilitas tinggi. Adapun WIKA menunjukkan tren penurunan disertai volatilitas yang tetap muncul sepanjang periode observasi. Sementara itu, KLBF dan SMGR memperlihatkan fluktuasi harga yang jelas meskipun pergerakannya tidak sekuat emiten lainnya. Secara keseluruhan, seluruh saham mengalami perubahan rezim harga (*regime shift*) pada awal tahun 2020 yang bertepatan dengan munculnya pandemi COVID-19. Setelah penurunan tajam pada periode tersebut, pola pemulihan bertahap mulai terlihat kembali pada awal 2021. Secara visualisasi, pergerakan saham dari tahun 2016 sampai 2021 dapat dilihat pada Gambar 4.



Gambar 4. Pergerakan harga saham ANTM, ERAA, KLBF, SMGR, dan WIKA periode 2016-2021

Selanjutnya, proses pelatihan dilakukan menggunakan tiga arsitektur model, yaitu *LSTM*, *BiLSTM*, dan *LSTM-AM*. Masing-masing model dikonfigurasi dengan arsitektur dan Analisis Komparatif Kinerja LSTM, BiLSTM, dan LSTM-AM dalam Prediksi Harga Saham Syariah

hyperparameter yang sesuai. Seluruh model kemudian dilatih menggunakan data yang telah dinormalisasi dan disusun dalam format *time series* dengan pendekatan *window CV*. Hasil pelatihan pada data *training* menunjukkan bahwa model mampu mempelajari pola historis saham dengan baik, hal ini dapat dilihat pada Tabel 4.

Tabel 4. Hasil training seluruh model

Model	Dataset	Trials	Nilai Validation Loss		
			Terendah	Tertinggi	Rata-rata
LSTM	ANTM	20	0.0088	0.1880	0.0226 ± 0.0385
	ERAA	20	0.0002	0.0007	0.0004 ± 0.0001
	KLBF	20	0.0195	0.0336	0.0241 ± 0.0041
	SMGR	20	0.0027	0.0063	0.0034 ± 0.0011
	WIKA	20	0.0032	0.0088	0.0046 ± 0.0017
BiLSTM	ANTM	20	0.0121	0.0769	0.0296 ± 0.0173
	ERAA	20	0.0030	0.1304	0.0216 ± 0.0314
	KLBF	20	0.0374	0.5282	0.1116 ± 0.1183
	SMGR	20	0.0067	1.8151	0.1777 ± 0.4292
	WIKA	20	0.0070	0.5344	0.0606 ± 0.1148
LSTM-AM	ANTM	20	0.0186	0.2366	0.0889 ± 0.0424
	ERAA	20	0.0133	0.1462	0.0612 ± 0.0433
	KLBF	20	0.0610	0.3560	0.1198 ± 0.0749
	SMGR	20	0.0318	0.2778	0.1174 ± 0.0652
	WIKA	20	0.0139	0.3840	0.0884 ± 0.0817

Berdasarkan Tabel 4, LSTM menjadi model paling unggul karena menghasilkan *validation loss* rata-rata terendah pada seluruh saham—mulai dari 0.0004 (ERAA) hingga 0.0241 (KLBF). Baik BiLSTM maupun LSTM-AM memperoleh *loss* yang lebih tinggi serta menunjukkan ketidakstabilan yang signifikan pada beberapa emiten, seperti SMGR dan WIKA.


3.2 Perbandingan Kinerja Seluruh Model

Tabel 5 menunjukkan evaluasi kinerja ketiga model menggunakan tiga metrik yang berbeda. Berdasarkan MAPE, yang mengukur persentase kesalahan relatif terhadap nilai aktual, BiLSTM menghasilkan error paling rendah dengan rata-rata 9.41%, diikuti oleh LSTM dengan rata-rata 11.87% dan LSTM-AM dengan rata-rata 19.58%. Model BiLSTM juga tampil sangat baik pada saham dengan volatilitas moderat seperti KLBF, SMGR, dan WIKA.

Tabel 5. Hasil evaluasi kinerja model

Model	Dataset Saham					Rata-rata
	ANTM	ERAA	KLBF	SMGR	WIKA	
MAPE (%)						
LSTM	38,54	5,61	2,02	2,56	10,61	11,87
BiLSTM	38,01	2,01	1,49	1,9	2,86	9,41
LSTM-AM	54,9	15,69	4,59	9,6	13,12	19,58
RMSE						
LSTM	934,42	40,62	35,52	309,31	136,09	291,192
BiLSTM	941,09	17,37	27,95	220,3	43,07	249,956
LSTM-AM	1325,75	102,57	77,21	971,59	156,6	526,744
R²						

LSTM	-67,04	-0,63	0,87	0,81	0,42	-13,11
BiLSTM	-68,02	0,7	0,92	0,91	0,94	-12,91
LSTM-AM	-135,97	-9,37	0,39	-0,86	0,23	-29,12




Gambar 5. Grafik harga saham aktual vs prediksi model LSTM untuk setiap dataset

Sementara itu, pada *RMSE*, metrik yang menilai besarnya deviasi absolut dan lebih sensitif terhadap *outlier*, *BiLSTM* kembali menunjukkan kinerja terbaik dengan deviasi rata-rata 249.956, meskipun untuk saham ANTM nilai *RMSE* terendah justru dicapai oleh *LSTM*. Perbedaan pola hasil pada *MAPE* dan *RMSE* ini menunjukkan bahwa *BiLSTM* lebih konsisten dalam mengurangi kesalahan relatif, namun *LSTM* dapat memberikan deviasi absolut yang lebih kecil pada saham dengan volatilitas ekstrem seperti ANTM. Pada metrik R^2 , seluruh model memperoleh nilai negatif, dengan model terendah yaitu *LSTM-AM*. Hal ini menunjukkan bahwa pola fluktuatif dan *regime shift* dalam data masih sulit ditangkap oleh ketiga arsitektur model.

Selanjutnya, visualisasi perbandingan antara data harga saham aktual dan prediksi dari ketiga model (*LSTM*, *BiLSTM*, dan *LSTM-AM*) untuk seluruh emiten dapat dilihat pada Gambar 5–7. Pada Gambar 5, prediksi saham ANTM dengan model *LSTM* mengalami kesulitan signifikan dalam memprediksi lonjakan harga yang terjadi setelah pertengahan 2021, menghasilkan *MAPE* sebesar 38,54%. Hal ini terlihat dari gap yang cukup besar antara garis prediksi dan data aktual pada periode tersebut. Sebaliknya prediksi saham ERAA dengan model *LSTM* menunjukkan performa yang baik dengan *MAPE* 5.61%, di mana garis prediksi mengikuti pola pergerakan harga aktual dengan cukup akurat, terutama pada periode 2019–2021. Sementara itu, saham KLBF model *LSTM* berhasil menangkap tren pergerakan harga yang relatif stabil dengan *MAPE* 2.02%, meskipun terdapat sedikit deviasi pada periode

volatilitas tinggi di awal 2020. Demikian saham SMGR dengan model LSTM menunjukkan akurasi yang baik dengan MAPE 2.56%, dengan prediksi yang mengikuti pola penurunan dan pemulihan harga secara konsisten. Sedangkan untuk saham WIKA, model LSTM menghasilkan MAPE 10.61%, di mana prediksi cukup akurat pada periode stabil namun mengalami kesulitan dalam menangkap fluktuasi tajam yang terjadi pada pertengahan 2020.




Gambar 6. Grafik harga saham aktual vs prediksi model BiLSTM untuk setiap dataset

Pada Gambar 6, meskipun saham ANTM tetap mengalami kesulitan dengan lonjakan harga ekstrem di akhir periode, BiLSTM menunjukkan sedikit perbaikan dibanding LSTM dengan MAPE 38.01%. Keunggulan BiLSTM sangat terlihat pada saham ERAA, di mana model ini berhasil mencapai MAPE 2.01% dengan prediksi yang sangat mengikuti pola pergerakan harga aktual, termasuk pada periode fluktuatif di tahun 2020. Performa superior BiLSTM juga terlihat pada saham KLBF dengan MAPE terendah 1.49%, dimana garis prediksi hampir sempurna mengikuti data aktual bahkan pada periode volatilitas tinggi. Sementara itu, saham SMGR dengan model BiLSTM mencatat MAPE 1.90% dengan kemampuan yang sangat baik dalam menangkap tren penurunan di awal periode dan pemulihan bertahap hingga akhir 2021. Demikian pula pada saham WIKA, model BiLSTM menunjukkan akurasi tinggi dengan MAPE 2.86%, berhasil memprediksi pola pergerakan harga dengan deviasi minimal terhadap data aktual.

Pada Gambar 7, saham ANTM menghasilkan MAPE tertinggi sebesar 54.90%, dengan prediksi yang sangat menyimpang dari data aktual, terutama pada periode lonjakan harga di akhir 2021. Gap yang signifikan antara garis prediksi dan data aktual mengindikasikan bahwa LSTM-AM tidak efektif dalam menangkap pola volatilitas ekstrem pada saham ini.

Sedangkan pada saham ERAA, LSTM-AM mencatat MAPE 15.69%, di mana prediksi menunjukkan ketidakstabilan dengan fluktuasi yang tidak mengikuti pola data aktual secara konsisten. Hal serupa terjadi pada saham KLBF. Meskipun nilai MAPE 4,59%, ini relatif lebih baik dibanding ANTM dan ERAA. Model LSTM-AM masih menunjukkan deviasi yang lebih besar dibanding LSTM dan BiLSTM. Sementara itu, saham SMGR dengan model LSTM-AM menghasilkan MAPE 9.60%. Hasil prediksi ini cenderung deviasi terhadap pergerakan harga aktual. Terakhir, pada saham WIKA, model LSTM-AM mencatat MAPE 13.12% dengan pola prediksi yang kurang stabil dan mengalami kesulitan dalam menangkap *timing* perubahan tren harga.



Gambar 3. Grafik harga saham aktual vs prediksi model LSTM-AM untuk setiap dataset

Semua model mengalami kesulitan pada dataset ANTM yang memiliki volatilitas ekstrem dan kenaikan harga drastis setelah 2021. Hal ini tercermin dari nilai R^2 negatif yang menunjukkan model tidak dapat menjelaskan variasi data dengan baik.

LSTM-AM menunjukkan performa kurang optimal karena mekanisme *Attention* yang diterapkan tidak sesuai dengan karakteristik data harga saham yang memerlukan pertimbangan menyeluruh terhadap seluruh urutan historis, bukan fokus pada bagian tertentu saja.

3.3 Analisis Komparatif Kinerja Model

Berdasarkan Tabel 5 dan visualisasi pada Gambar 5–7 yang menunjukkan perbandingan komprehensif kinerja ketiga arsitektur model. Hasil evaluasi memberikan gambaran

Analisis Komparatif Kinerja LSTM, BiLSTM, dan LSTM-AM dalam Prediksi Harga Saham Syariah

menyeluruh mengenai akurasi relatif, besaran deviasi absolut, dan kemampuan model dalam menjelaskan variabilitas data.

Berdasarkan metrik MAPE, hasil evaluasi menunjukkan bahwa BiLSTM memperoleh performa terbaik dengan rata-rata kesalahan relatif terendah sebesar 9,41%. Model ini konsisten unggul pada emiten dengan pola pergerakan yang relatif lebih terkontrol seperti KLBF (1,49%), SMGR (1,90%), dan WIKA (2,86%). Sementara itu, LSTM menghasilkan MAPE rata-rata 11,87%, memberikan akurasi yang cukup baik namun masih di bawah BiLSTM. Sebaliknya, LSTM-AM mencatat performa terendah dengan MAPE rata-rata 19,58%, mengindikasikan ketidakstabilan model dalam memprediksi persentase perubahan harga.

Tinjauan pada metrik RMSE memperkuat keunggulan BiLSTM. Model ini menghasilkan rata-rata deviasi absolut terendah sebesar 249,96, yang menunjukkan bahwa prediksi BiLSTM memiliki jarak terdekat dengan harga aktual dalam satuan Rupiah, terutama pada saham volatil seperti ERAA (17,37) dan WIKA (43,07). LSTM menyusul dengan rata-rata RMSE 291,19, sedangkan LSTM-AM memiliki rata-rata deviasi terbesar mencapai 526,74, yang menandakan banyaknya prediksi yang meleset jauh dari harga sebenarnya (outlier).

Selanjutnya, pada metrik R^2 (R-squared), seluruh model memperoleh nilai rata-rata negatif, yakni LSTM (-13,11), BiLSTM (-12,91), dan LSTM-AM (-29,12). Nilai negatif ini secara umum disebabkan oleh kegagalan model dalam menangkap lonjakan ekstrem pada saham ANTM (R^2 -67,04 hingga -135,97). Namun, jika melihat per emiten, BiLSTM dan LSTM mampu menghasilkan nilai R^2 yang sangat baik (mendekati 1) pada saham yang lebih stabil seperti KLBF (0,92) dan WIKA (0,94). Hal ini menunjukkan bahwa arsitektur BiLSTM dan LSTM sebenarnya mampu menjelaskan variasi data dengan sangat baik pada kondisi pasar yang wajar, namun seluruh model, termasuk LSTM-AM, mengalami kesulitan signifikan dalam menghadapi perubahan harga pasar yang ekstrem.

Secara keseluruhan, *BiLSTM* terbukti menjadi arsitektur yang paling *robust* dengan konsistensi terbaik di ketiga metrik evaluasi, sementara mekanisme *attention* pada *LSTM-AM* belum memberikan kontribusi positif yang signifikan pada dataset ini.

Temuan ini mengindikasikan bahwa mekanisme *attention* tidak memberikan kontribusi signifikan pada karakteristik data harga saham syariah yang digunakan dalam penelitian ini. Secara analitis, terdapat beberapa alasan yang dapat menjelaskan kinerja LSTM-AM yang kurang optimal. Pertama, *attention mechanism* cenderung bekerja paling efektif ketika pola dependensi jangka panjang sangat menonjol dan non-linier, sedangkan data saham harian lebih dipengaruhi oleh noise pasar dan volatilitas jangka pendek, sehingga sinyal penting sulit dibedakan oleh *attention*. Kedua, struktur hybrid berbasis *attention* berpotensi mengalami *overfitting* ketika ukuran dataset relatif terbatas, dikarenakan model memiliki lebih banyak parameter dibanding LSTM dan BiLSTM. Ketiga, perhatian temporal pada LSTM-AM efektif ketika ada pola dependensi jangka panjang yang konsisten, *attention weighting* dapat menjadi tidak stabil dan gagal memilih informasi relevan, sehingga kontribusinya terhadap peningkatan akurasi menjadi terbatas [13].

Dalam konteks keterbandingan dengan studi terdahulu, hasil penelitian ini juga menunjukkan kontradiksi yang menarik [8][11]. Meskipun penelitian sebelumnya melaporkan nilai MAPE yang jauh lebih rendah, perbedaan tersebut dapat dipengaruhi oleh variasi periode data, tidak digunakannya validasi ketat seperti Window CV, serta potensi *overfitting* akibat tuning manual maupun ketiadaan regularisasi. Sementara itu, temuan pada penelitian ini menunjukkan bahwa penambahan mekanisme *attention* tidak selalu meningkatkan performa, terutama pada data harga saham syariah yang ditandai oleh volatilitas tinggi, keberadaan outlier, dan dominasi pola jangka pendek. Kondisi pasar seperti ini cenderung menyulitkan

attention dalam menonjolkan sinyal relevan secara konsisten, sehingga model dengan kompleksitas lebih tinggi tidak memberikan keuntungan yang berarti.

Perbandingan tiga model dalam studi ini memberikan gambaran yang lebih jelas mengenai situasi di mana arsitektur tertentu bekerja lebih efektif, serta bagaimana variasi struktur jaringan dapat memengaruhi kemampuan generalisasi model pada data saham syariah. Secara keseluruhan, analisis ini memberikan pemahaman yang lebih mendalam mengenai dinamika performa LSTM, BiLSTM, dan LSTM-AM serta faktor-faktor yang memengaruhi keberhasilan masing-masing model dalam memprediksi harga saham syariah.

4. KESIMPULAN

Studi ini membangun dan membandingkan tiga arsitektur *deep learning* untuk prediksi harga saham syariah. Hasil evaluasi menunjukkan bahwa *BiLSTM* memberikan performa terbaik dengan *MAPE* rata-rata 9.41%, diikuti *LSTM* dengan 11.87%. Sementara itu, *LSTM-AM* dengan nilai *MAPE* 19.58% belum menunjukkan kinerja optimal karena mekanisme *attention* kurang efektif pada data dengan volatilitas tinggi, keberadaan *outlier*, dan pola jangka pendek yang dominan.

Temuan ini menegaskan bahwa pemilihan arsitektur memiliki peran penting dalam meningkatkan akurasi prediksi harga saham syariah. *BiLSTM* cenderung lebih adaptif terhadap karakteristik data saham syariah, khususnya pada pola perubahan harga yang cepat, ketidakteraturan jangka pendek, dan pergeseran temporal antarperiode. Meski demikian, penelitian ini masih memiliki keterbatasan, terutama pada saham ANTM yang memiliki volatilitas lebih tinggi dibanding emiten lain, termasuk fluktuasi tajam, pergerakan harga yang tidak stasioner, serta episode lonjakan atau penurunan ekstrem yang memperbesar error relatif pada model.

Penelitian selanjutnya dapat mempertimbangkan pendekatan yang lebih robust terhadap volatilitas pasar atau menambahkan variabel eksternal seperti volume perdagangan atau indikator makroekonomi untuk memperkaya informasi yang diterima model dan meningkatkan kemampuan generalisasinya.

5. REFERENSI

- [1] 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, Vol. 2, No. 1, Indonesia
- [2] Zamaluddin, Rochim, A., Andatu, M., Saputra, R., 2023, Hukum Jual Beli Saham BRIS di Komunitas Syariah Saham dalam Perspektif Hukum Islam dan Positif, Mandub: Jurnal Politik, Sosial, Hukum dan Humaniora, Vol. 1, No. 4, Indonesia
- [3] 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 and Theoretical Artificial Intelligence, Vol. 32, No. 1, Taylor & Francis, United Kingdom
- [4] Kong, X., et al., 2025, Deep Learning for Time Series Forecasting: A Survey, International Journal of Machine Learning and Cybernetics, Springer, Germany
- [5] Cho, K., Kim, Y., 2022, Improving Streamflow Prediction in the WRF-Hydro Model with LSTM Networks, Journal of Hydrology, Vol. 605, Elsevier, Netherlands
- [6] Chen, N., 2024, Exploring the Development and Application of LSTM Variants, Applied and Computational Engineering, Vol. 53, No. 1, United States

- [7] Pham, T. D., 2021, Time–Frequency Time–Space LSTM for Robust Classification of Physiological Signals, *Scientific Reports*, Vol. 11, Nature Publishing Group, United Kingdom
- [8] Budiprasetyo, G., Hani’ah, M., Aflah, D., 2023, Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM), *Jurnal Nasional Teknologi dan Sistem Informasi*, Vol. 8, Indonesia
- [9] Mahajan, R., Mansotra, V., 2021, Predicting Geolocation of Tweets Using Combination of CNN and BiLSTM, *Data Science and Engineering*, Vol. 6, No. 4, Springer, Singapore
- [10] 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*, Vol. 23, No. 4, ASME, United States
- [11] 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*, Vol. 11, Indonesia
- [12] 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*, Vol. 587, Elsevier, Netherlands
- [13] 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*, Vol. 9, United States
- [14] 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*, Vol. 23, Elsevier, Netherlands
- [15] Shen, J., Shafiq, M. O., 2020, Short-Term Stock Market Price Trend Prediction Using a Comprehensive Deep Learning System, *Journal of Big Data*, Vol. 7, Springer, United Kingdom
- [16] Taufik, R., Aristoteles, A., Ilman, I. S., 2025, A Hybrid Model to Mitigate Data Gaps and Fluctuations in Tax Revenue Forecasting, *International Journal of Electrical and Computer Engineering*, Vol. 15, No. 4, Indonesia
- [17] Schechtman, E., Shelef, A., 2018, Correlation and the Time Interval over Which the Variables Are Measured: A Non-Parametric Approach, *PLOS ONE*, Vol. 13, No. 11, United States
- [18] Pratiwi, N., Rosadi, D., Abdurakhman, 2025, Robust Scaling Strategies for Outlier Handling in Orthogonal Projection to Latent Structures Discriminant Analysis (OPLS-DA), *Communications in Statistics Simulation and Computation*, Vol. 54, No. 5, United Kingdom
- [19] Bhandari, H. N., Rimal, B., Pokhrel, N. R., Rimal, R., Dahal, K. R., Khatri, R. K. C., 2022, Predicting Stock Market Index Using LSTM, *Machine Learning with Applications*, Vol. 9, Elsevier, United Kingdom
- [20] Agarwal, S., Sharma, S., Faisal, K. N., Sharma, R. R., 2025, Time-Series Forecasting Using SVM-D-LSTM: A Hybrid Approach for Stock Market Prediction, *Journal of Probability and Statistics*, Vol. 2025, United Kingdom
- [21] Phuoc, T., Anh, P. T. K., Tam, P. H., Nguyen, C. V., 2024, Applying Machine Learning Algorithms to Predict the Stock Price Trend in the Stock Market: The Case of Vietnam, *Humanities and Social Sciences Communications*, Vol. 11, United Kingdom
- [22] Bergstra, J., Bengio, Y., 2012, Random Search for Hyper-Parameter Optimization, *Journal of Machine Learning Research*, Vol. 13, United States

- [23] Vilares F. M., Doval Mosquera, Y., Ribadas P. F. J., Darriba B., V. M., 2023, Early Stopping by Correlating Online Indicators in Neural Networks, Neural Networks, Vol. 159, Elsevier, Netherlands
- [24] Bergmeir, C., Benítez, J. M., 2012, On the Use of Cross-Validation for Time Series Predictor Evaluation, Information Sciences, Vol. 191, Elsevier, Netherlands
- [25] Hodson, T. O., 2022, Root-Mean-Square Error (RMSE) or Mean Absolute Error (MAE): When to Use Them or Not, Geoscientific Model Development, Vol. 15, No. 14, Germany
- [26] Colton, J., Bower, K., 2002, Some Misconceptions about R-Square, Statistical Review, Vol. 3, United States