

Optimalisasi Rekonstruksi Data Hilang untuk Meningkatkan Presisi Prediksi Waktu Salat Berbasis GRU di Wilayah Empat Musim

Optimizing Missing Data Reconstruction to Enhance GRU-Based Prayer Time Prediction Precision in Four-Season Regions

Adelia Khansa Ristiaputri^{a,1}, Aji Prasetya Wibawa^{a,1,*}, Adhelia Wida Khaidir^{a,1}, Dhia Rafifah Thifal^{a,1}, Adelia Desyana Eka Putri^{a,1}, Agung Bella Putra Utama^{a,1}

^aDepartemen Teknik Elektro dan Informatika, Universitas Negeri Malang, Malang, Indonesia

¹adelia.khansa.2205356@students.um.ac.id; ¹aji.prasetya.ft@um.ac.id; ¹adhelia.wida.2205356@students.um.ac.id;

¹dhia.rafifah.2205356@students.um.ac.id; ¹adelia.desyana.2205356@students.um.ac.id;

¹agung.bella.2305349@students.um.ac.id

*corresponding author

Informasi Artikel

Diserahkan : 24 April 2026
Diterima : 12 Mei 2026
Direvisi : 15 Mei 2026
Diterbitkan : 22 Mei 2026

Kata Kunci:

Gated Recurrent Unit
Imputasi Data
Peramalan Deret Waktu
Waktu Sholat
Optimasi Particle Swarm

Keywords:

Gated Recurrent Unit
Data Imputation
Time Series Forecasting
Prayer Times
Particle Swarm Optimization

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



ABSTRAK

Peramalan waktu sholat di wilayah empat musim menghadapi tantangan besar akibat variabilitas musiman ekstrem dan risiko ketidaklengkapan data sensorik yang mengganggu kontinuitas informasi. Penelitian ini bertujuan untuk mengevaluasi pengaruh berbagai metode imputasi terhadap kinerja model peramalan GRU pada data deret waktu yang merepresentasikan dinamika astronomi dan meteorologi. Metodologi penelitian melibatkan pengujian enam teknik imputasi pada tiga dataset dengan karakteristik berbeda, yaitu variabilitas musiman jangka panjang, pola siklik non-linear, dan dinamika jangka pendek resolusi tinggi. Model GRU dioptimasi menggunakan PSO untuk memastikan akurasi parameter yang maksimal. Hasil eksperimen menunjukkan bahwa model GRU secara konsisten mengungguli LSTM, Bi-LSTM, dan RNN, ditunjukkan oleh nilai MAPE dan RMSE yang lebih rendah serta R^2 yang lebih tinggi. Metode imputasi sederhana seperti Mean dan LOCF terbukti lebih efektif dibandingkan KNN dan MICE dalam menjaga struktur temporal data. Pada Dataset 1, kombinasi Mean-GRU menghasilkan MAPE 0,74074, RMSE 3,25932, dan R^2 0,92828; pada Dataset 2, LOCF mencapai kinerja terbaik dengan MAPE 1,36115, RMSE 16,22207, dan R^2 0,93766; sedangkan pada Dataset 3, Median menunjukkan performa optimal dengan MAPE 0,34435, RMSE 1,18365, dan R^2 0,98420. Temuan ini menegaskan bahwa preservasi integritas temporal melalui strategi imputasi yang tepat berperan penting dalam meningkatkan kinerja model peramalan waktu sholat.

ABSTRACT

Prayer time forecasting in four-season regions faces significant challenges due to extreme seasonal variability and the risk of incomplete sensory data, which disrupts information continuity. This study aims to evaluate the impact of various imputation methods on the performance of GRU forecasting models on time-series data representing astronomical and meteorological dynamics. The research methodology involves testing six imputation techniques across three datasets with distinct characteristics: long-term seasonal variability, complex non-linear cyclic patterns, and high-resolution short-term dynamics. The GRU model is optimized using PSO to ensure maximum parameter accuracy. The experimental results showed that the GRU model consistently outperformed LSTM, Bi-LSTM, and RNN, indicated by lower MAPE and RMSE values as well as higher R^2 . Simple imputation methods such as Mean and LOCF have proven to be more effective than KNN and MICE in maintaining the temporal structure of the data. In Dataset 1, the Mean-GRU combination yielded a MAPE of 0.74074, an RMSE of 3.25932, and a R^2 of 0.92828; in Dataset 2, LOCF achieved the best performance with MAPE 1.36115, RMSE 16.22207, and R^2 0.93766; while in Dataset 3, the median showed optimal performance with MAPE 0.34435, RMSE 1.18365, and R^2 0.98420. These findings confirm that the preservation of temporal integrity through proper imputation strategies plays an important role in improving the performance of prayer time forecasting models.

I. Pendahuluan

Perhitungan waktu sholat di wilayah empat musim merupakan tantangan komputasi yang kompleks karena fluktuasi durasi siang dan malam yang sangat kontras [1]. Secara matematis, penentuan waktu ini bergantung pada posisi matahari terhadap garis cakrawala, yang direpresentasikan dalam variabel-variabel astronomi dan meteorologi yang bersifat kontinu [2], [3]. Dalam perspektif syariat, meskipun rukyat diposisikan sebagai metode utama, akurasi perhitungan astronomis memainkan peran esensial sebagai sarana komplementer guna memverifikasi presisi dan memastikan validitas ibadah [4]. Di wilayah dengan lintang ekstrem, tanda alamiah seperti hilangnya cahaya merah (*syafaq*) atau munculnya fajar seringkali mengalami anomali atau tidak muncul sama sekali pada musim tertentu, sehingga memerlukan pemodelan estimasi yang sangat presisi agar tetap sejalan dengan koridor hukum Islam (*fikih*) [5]. Namun, dalam implementasi praktisnya, sistem peramalan berbasis data sering kali menghadapi kendala fundamental [6] terkait ketidakadaan nilai pada sekuen data (*missing values*) [7]. Ketidakadaan nilai pada dataset sensorik atau catatan iklim historis dapat menyebabkan diskontinuitas dalam model prediksi [8], yang mengakibatkan estimasi waktu tidak akurat [9]. Ketidakakuratan ini menciptakan risiko tinggi bagi aplikasi Teknologi Islam yang menuntut presisi tinggi [10], di mana deviasi beberapa menit saja dapat membatalkan atau menyebabkan shalat dilakukan di luar waktunya. Kompleksitas ini menjadikan permasalahan estimasi waktu sholat tidak hanya bersifat deterministik, tetapi juga menuntut pendekatan *forecasting* yang mampu memodelkan dinamika temporal secara adaptif.


Pada wilayah dengan empat musim, perbedaan durasi siang dan malam yang berubah secara signifikan sepanjang tahun menciptakan dinamika temporal yang kompleks [11], [12]. Variasi ini tidak hanya bersifat periodik, tetapi juga menunjukkan pola non-linear dan perubahan yang tidak stasioner, sehingga membentuk struktur deret waktu yang sulit dimodelkan secara sederhana [13]. Hal ini sangat krusial di wilayah utara (seperti Skandinavia atau Kanada) di mana transisi waktu shalat terjadi dengan sangat cepat atau justru sangat lambat (misalnya fenomena matahari tengah malam). Dalam konteks ini, peramalan waktu sholat dapat dipandang sebagai permasalahan *time series forecasting* yang harus mampu menangkap dependensi temporal, tren musiman, serta fluktuasi jangka pendek secara simultan. Namun demikian, keberhasilan proses peramalan tidak hanya ditentukan oleh kemampuan model, tetapi juga oleh kualitas data yang digunakan [14]. Dalam praktiknya, data deret waktu yang merepresentasikan fenomena terkait sering kali mengandung nilai hilang (*missing values*), yang dapat mengganggu kontinuitas urutan data, merusak pola dependensi temporal, serta menurunkan kemampuan model dalam menghasilkan prediksi yang akurat dan konsisten sesuai dengan standar ketetapan syariat.

Pendekatan konvensional berbasis perhitungan astronomi umumnya menggunakan formulasi matematis deterministik tanpa mempertimbangkan variabilitas data historis secara eksplisit, sehingga terbatas dalam menangkap dinamika non-linear [15], [16]. Untuk mengatasi keterbatasan tersebut, pembelajaran mendalam (*deep learning*) melalui arsitektur *rekuren* seperti *Gated Recurrent Unit* (GRU) hadir sebagai alternatif yang adaptif dalam mengekstraksi pola temporal berkat efisiensi mekanisme *gating* [17]. Namun demikian, berbagai studi terdahulu secara konsisten menyoroti kerentanan fundamental arsitektur GRU terhadap kualitas prapemrosesan data [18], [19]. Keberadaan nilai hilang (*missing values*) telah diidentifikasi sebagai kendala krusial yang menginduksi diskontinuitas waktu karena dapat mengganggu kesinambungan deret waktu dan menyebabkan prediksi yang tidak akurat [20]. Literatur lain menegaskan bahwa hilangnya nilai observasi atau penerapan pendekatan konvensional berupa eliminasi data secara langsung mendistorsi integritas mekanisme pembaruan memori jaringan [21]. Sehingga ada akhirnya mengacaukan pemetaan autokorelasi temporal dan menurunkan secara drastis kemampuan model dalam melakukan generalisasi.

Sejalan temuan tersebut, perkembangan literatur menunjukkan kecenderungan utama dalam strategi imputasi dalam menggantikan nilai hilang, yaitu pendekatan berbasis statistik [22] dan pendekatan berbasis pembelajaran mesin [23]. Pada kelompok statistik, metode pemusatan seperti Mean, Median, dan Mode digunakan karena kesederhanaan dan efisiensi komputasi, sedangkan pendekatan seperti *Last Observation Carried Forward* (LOCF) efektif dalam mempertahankan kontinuitas lokal karena memanfaatkan ketergantungan temporal antar observasi berurutan. Di sisi lain, metode berbasis pembelajaran mesin seperti *K-Nearest Neighbors* (KNN) dan *Multiple Imputation by Chained Equations* (MICE) mampu memanfaatkan hubungan antar variabel dalam ruang fitur. Meskipun berbagai metode imputasi tersebut telah banyak dikaji, sebagian besar hanya mengevaluasi performa, tanpa mengaitkan secara langsung dampak terhadap model arsitektur GRU. Oleh karena itu, terdapat celah penelitian dalam memahami perbedaan strategi imputasi memengaruhi kualitas prediksi pada peramalan berbasis data deret waktu. Berdasarkan hal tersebut, penelitian ini berfokus pada evaluasi komprehensif terhadap enam metode imputasi (Mean, Median, Mode, LOCF, KNN, dan MICE) dalam meningkatkan kinerja model GRU pada mekanisme kehilangan data. Melalui pengujian komprehensif ini, penelitian diharapkan dapat memberikan kontribusi teoritis dalam memetakan interaksi fundamental antara kualitas data, teknik imputasi, dan performa peramalan. Secara praktis, penelitian ini bertujuan mendukung pengembangan sistem prediksi waktu salat yang adaptif dan tangguh, guna menjamin akurasi jadwal ibadah sesuai standar syariat khususnya bagi masyarakat Muslim di wilayah dengan durasi siang dan malam ekstrem yang sangat bergantung pada integritas data sensorik dan kontinuitas model prediksi.

II. Metode

Studi ini mengadopsi metodologi yang tersaji pada Gambar 1 untuk secara sistematis mengevaluasi dampak berbagai teknik imputasi terhadap performa peramalan model *Gated Recurrent Unit* (GRU). Secara garis besar, eksperimen diawali dengan pemetaan mekanisme kehilangan data, dilanjutkan dengan rekonstruksi data melalui komparasi metode statistik dan *machine learning*. Data hasil prapemrosesan kemudian digunakan untuk melatih arsitektur GRU yang telah dioptimasi menggunakan *Particle Swarm Optimization* (PSO). Validasi akhir dari seluruh skenario pemulihan data tersebut diukur secara holistik menggunakan metrik MAPE, RMSE, dan R^2 guna mengevaluasi presisi komparatif dan stabilitas model prediksi.



Gambar 1. Metode Penelitian

A. Deskripsi Data

Penelitian ini menggunakan tiga dataset Kaggle dengan karakteristik temporal berbeda untuk menguji ketahanan metode imputasi dan model GRU pada peramalan waktu salat di wilayah bermusim signifikan. Dataset pertama, *Eighty Years of Canadian Climate Data*, merepresentasikan variabilitas musiman jangka panjang yang memengaruhi fluktuasi durasi siang-malam di wilayah empat musim. Dataset kedua, *Daily Sunspot Data*, merepresentasikan pola siklik non-linear kompleks yang serupa dengan dinamika astronomis pergerakan matahari. Sementara itu, dataset ketiga, *Sofia Weather Records*, mencerminkan dinamika jangka pendek beresolusi tinggi untuk menangkap fluktuasi harian dalam estimasi waktu salat. Deskripsi statistik dari ketiga dataset tersebut disajikan pada Tabel 1.

Tabel 1. Deskripsi Statistik Dataset

Statistik	Dataset 1	Dataset 2	Dataset 3
<i>Number of Rows</i>	27.530	73.718	87.599
<i>Mean</i>	- 0.42°C	79.25	1.647
<i>Standard Deviation</i>	12.87	77.47	9.695
<i>Minimum</i>	- 48.1°C	-1	- 36.9
<i>1st Quartile (25%)</i>	- 8.4°C	15	- 3.6
<i>Median (50%)</i>	1.9 °C	58	1.7
<i>3rd Quartile (75%)</i>	10.0°C	125	8.3
<i>Maximum</i>	23.9°C	528	29.1
<i>Missing Value</i>	1.691 (6.15%)	3204 (4.35%)	50 (0.057%)

Berdasarkan Tabel 1, karakteristik seperti volatilitas, struktur temporal, dan tingkat kehilangan data memiliki pengaruh signifikan terhadap kompleksitas proses imputasi dan peramalan [24]. Ketiga dataset dalam penelitian ini dipilih untuk merepresentasikan variasi pola musiman, siklik, dan resolusi tinggi yang serupa dengan dinamika waktu salat. Dataset 1 memiliki variabilitas jangka panjang dan proporsi data hilang tinggi akibat dinamika musiman ekstrem, sehingga berpotensi meningkatkan galat jika kontinuitas temporal terabaikan. Dataset 2 menunjukkan fluktuasi non-linear dan pola siklik kuat khas waktu salat, sehingga memerlukan imputasi yang mempertahankan dinamika periodik tanpa mendistorsi skala data. Sementara itu, Dataset 3 memiliki resolusi temporal tinggi dengan stabilitas statistik yang lebih terkontrol, menjadikannya ideal untuk menangkap variasi jangka pendek dalam estimasi waktu salat. Perbedaan karakteristik ini mendasari perlunya evaluasi terarah guna memahami pengaruh strategi imputasi terhadap rekonstruksi kualitas data dan efektivitas model peramalan GRU pada berbagai kondisi temporal.

B. Karakteristik dan Mekanisme Data Hilang

Berdasarkan Tabel 1, setiap dataset menunjukkan jumlah dan karakteristik nilai hilang yang berbeda pada atribut target. Identifikasi mekanisme kehilangan data ini krusial karena setiap tipe memiliki dampak analitis yang berbeda terhadap struktur deret waktu dan kinerja model peramalan [25]. Dalam sains data, terdapat tiga mekanisme utama data hilang, yaitu *Missing Completely at Random* (MCAR) yang terjadi secara acak murni, *Missing at Random* (MAR) yang dipengaruhi oleh variabel lain yang teramati, dan *Missing Not at Random*

(MNAR) di mana data hilang berkaitan langsung dengan nilai aktual itu sendiri akibat kegagalan sistematis atau kondisi ekstrem.

Hasil analisis menunjukkan bahwa, setiap dataset menunjukkan karakteristik kehilangan data yang berbeda. Dataset 1 merepresentasikan pola MNAR, di mana nilai yang hilang berkaitan dengan kondisi ekstrem dalam data, sehingga diperlukan metode imputasi yang mampu mempertahankan nilai ekstrem dan kontinuitas temporal. Dataset 2 diklasifikasikan sebagai MCAR karena kehilangan data terjadi secara acak tanpa keterkaitan dengan variabel tertentu, sehingga tidak menimbulkan bias yang signifikan. Sementara itu, Dataset 3 menunjukkan pola MAR, di mana kehilangan data dipengaruhi oleh variabel lain, seperti kondisi lingkungan atau performa sensor, sehingga memerlukan pendekatan imputasi yang mempertimbangkan hubungan antar variabel. Perbedaan karakteristik ini menjadi dasar dalam menentukan metode imputasi yang paling sesuai untuk masing-masing dataset guna menjaga kualitas data dan kinerja model peramalan.

C. Penanganan Data Hilang dan Metode Imputasi

Penanganan data hilang merupakan tahap pra-pemrosesan yang krusial dalam peramalan deret waktu, karena keberadaan data hilang dapat mengganggu kontinuitas data serta menurunkan stabilitas proses pembelajaran model [26]. Teknik imputasi diterapkan untuk merekonstruksi nilai yang hilang dengan estimasi yang representatif guna memastikan kesinambungan dataset dan validitas hasil analisis temporal [27]. Mengacu pada analisis mekanisme kehilangan data yang telah diidentifikasi, penelitian ini menerapkan enam metode imputasi yang menggabungkan pendekatan statistik tradisional dan teknik berbasis pembelajaran mesin. Metode statistik sederhana seperti Mean, Median, dan Mode bekerja melalui substitusi tendensi sentral yang menawarkan komputasi cepat dan efisien meskipun berisiko mengurangi varians data atau menghaluskan pola ekstrem, sementara metode sekuensial seperti *Last Observation Carried Forward* (LOCF) diandalkan untuk mempertahankan kontinuitas temporal pada draf deret waktu. Di sisi lain, untuk menangani pola kehilangan data yang lebih kompleks dan terstruktur, diterapkan metode berbasis kemiripan ruang fitur seperti *k-Nearest Neighbors* (k-NN) yang mempertahankan struktur lokal serta *Multivariate Imputation by Chained Equations* (MICE) yang secara iteratif menjaga dependensi multivariat antar variabel melalui regresi kondisional. Dalam penelitian, variasi karakteristik tersebut dievaluasi untuk melihat efektivitasnya dalam merekonstruksi karakteristik pola temporal pada pemodelan waktu sholat, sehingga pendekatan komparatif ini tidak hanya menilai kualitas rekonstruksi data, tetapi juga mengamati dampak langsungnya terhadap stabilitas serta akurasi peramalan model GRU yang dioptimasi.

D. Forecasting

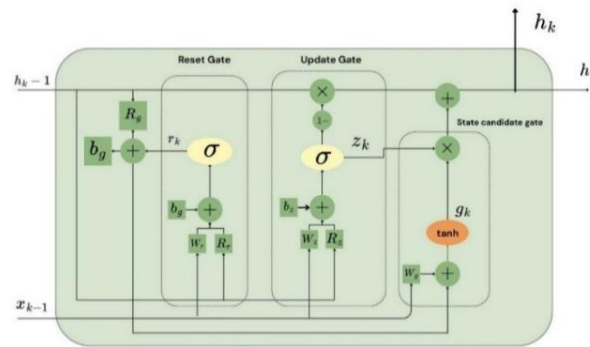
Dalam penelitian peramalan dilakukan menggunakan model *Gated Recurrent Unit* (GRU) untuk menangkap dependensi temporal pada data deret waktu [28]. Model mampu mempelajari hubungan antar waktu, baik dalam jangka pendek maupun jangka panjang, sehingga mampu merepresentasikan pola musiman, siklik, serta dinamika temporal yang kompleks [29], [30]. Implementasi dilakukan menggunakan *Python* dengan pustaka *TensorFlow* dan *Keras*, sementara tahap pra-pemrosesan dan evaluasi memanfaatkan *Scikit-learn* dan *Pandas*. Dataset hasil imputasi dibersihkan sesuai dengan variabel target kemudian dibagi menjadi 80% data pelatihan dan 20% untuk menjadi data pengujian. Pendekatan *sliding window* dengan 24 langkah waktu diterapkan, di mana 24 observasi sebelumnya digunakan untuk memprediksi nilai berikutnya, dan data diubah ke dalam bentuk tiga dimensi agar sesuai dengan input model GRU. Proses pelatihan menggunakan *mini-batch learning*, sedangkan evaluasi kinerja dilakukan menggunakan metrik RMSE, MAPE, dan R^2 sebelum optimasi lebih lanjut menggunakan *Particle Swarm Optimasi* (PSO).

Sebelum proses pelatihan model, proses peramalan diawali dengan tahap normalisasi data menggunakan metode *Min-Max Normalization*. Normalisasi ini bertujuan untuk menskalakan data ke dalam rentang $[0,1]$, sehingga mempercepat proses konvergensi model serta mencegah dominasi variabel dengan skala besar terhadap proses pembelajaran [31]. Secara khusus, normalisasi ini penting dalam model GRU, karena fungsi aktivasi yang digunakan (*sigmoid* dan *tanh*) sangat sensitif terhadap skala input [32]. Rumus Normalisasi *Min-Max* dituliskan melalui persamaan matematis (1).

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Dalam rumus Normalisasi *Min-Max*, Persamaan linier ini mentransformasikan setiap nilai observasi (X) ke dalam rentang $[0, 1]$ berdasarkan nilai minimum x_{min} dan maksimum x_{max} dari deret waktu. Normalisasi

ini penting dalam arsitektur *deep learning* untuk mencegah dominasi fitur berskala besar, menjaga stabilitas *gradien*, dan mempercepat konvergensi model GRU selama pelatihan.



Gambar 2. Arsitektur Model GRU

Arsitektur GRU merupakan pengembangan dari *Recurrent Neural Network* (RNN) yang dirancang untuk menghindari munculnya gradien lokal yang besar pada pemodelan deret waktu jangka panjang, sebagaimana ditunjukkan pada visualisasi Gambar 2 [17], [33] dengan mekanisme operasional gerbang yang secara visual ditunjukkan pada Gambar 2. Penerapan strategi imputasi dalam penelitian ini berfungsi sebagai solusi untuk mengatasi ketidaklengkapan data sebelum masuk ke tahap peramalan, di mana efektivitas rekonstruksi nilai hilang tersebut dievaluasi menggunakan model GRU yang dioptimasi secara otomatis oleh PSO untuk mengeliminasi prosedur *trial-and-error* manual. Alur kalkulasi internal GRU sendiri digerakkan oleh *reset gate* untuk mengevaluasi retensi informasi masa lalu, dan *update gate* untuk menentukan porsi memori baru yang akan diteruskan ke keadaan tersembunyi. Melalui integrasi ini, analisis difokuskan sepenuhnya pada sejauh mana variasi metode imputasi mampu mempertahankan kontinuitas temporal dan meminimalkan bias informasi pada hasil rekonstruksi data waktu salat.

Penyetelan hyperparameter dilakukan melalui PSO guna menemukan kombinasi parameter terbaik pada model GRU. Algoritma PSO memodelkan dinamika pergerakan partikel dalam ruang pencarian melalui mekanisme pembaruan posisi berdasarkan *personal best* dan *global best*. Penyetelan hyperparameter PSO digunakan untuk meminimalkan fungsi kerugian, sehingga memungkinkan eksplorasi ruang parameter berdimensi tinggi secara efisien dan menghasilkan konfigurasi optimal yang meningkatkan konvergensi serta akurasi *time series forecasting* [34]. Representasi konfigurasi hyperparameter yang digunakan dalam penelitian ini disajikan pada Tabel 2.

Tabel 2. Konfigurasi Hyperparameter Model PSO


Hyperparameter	Rentang Nilai	Keterangan
<i>Hidden Layers</i>	2-10	Umumnya < 5 pada konfigurasi optimal
<i>Neurons per Layer</i>	1-100	Titik keseimbangan optimal antara kompleksitas arsitektur dan akurasi prediksi
<i>Activation Function</i>	tanh, ReLU, sigmoid	Stabil untuk <i>time-series forecasting</i>
<i>Optimizer</i>	Adam, rmsprop, SGD	Dipilih berdasarkan konvergensi PSO
<i>Loss Function</i>	MSE, MAE	Mengurangi <i>error</i> prediksi
<i>Batch Size</i>	32-64	Stabil untuk dataset besar
<i>Epochs</i>	50-100	Menghindari <i>overfitting/underfitting</i>
<i>Dropout</i>	0.0-0.5	Mengurangi <i>overfitting</i>
<i>PSO Parameters</i>	$swarm=10, generations=5, velocity=[0,1], pbest=1.5, gbest=2.0$	Mengatur mekanisme eksplorasi dan eksploitasi partikel

Berdasarkan Tabel 2, proses optimasi dievaluasi menggunakan fungsi objektif model sehingga setiap hyperparameter dipilih secara sistematis berdasarkan kinerja yang diamati selama proses pelatihan. Hasil optimasi menghasilkan konfigurasi hyperparameter akhir yang spesifik pada masing-masing dataset, mencerminkan perbedaan karakteristik dan tingkat kompleksitas data. Berdasarkan hasil eksekusi algoritma optimasi, proses penyetelan menghasilkan konfigurasi nilai akhir yang spesifik untuk masing-masing dataset. Mekanisme pencarian yang dilakukan mampu mengurangi redundansi dalam ruang parameter serta mengarahkan model pada arsitektur yang paling efisien sesuai karakteristik data. Dalam konteks ini, konfigurasi yang disajikan merupakan representasi hasil optimasi dengan kinerja terbaik pada tiap dataset. Ringkasan konfigurasi hyperparameter tersebut dirangkum pada Tabel 3.

Tabel 3. Hasil Optimasi Parameter Model Terbaik Pada Tiap Dataset

Dataset	Metode Imputasi Terbaik	Hidden Layer	Neurons	Activation Function	Optimizer	Loss Function	Epochs	Batch Size
Dataset 1	Mean	3	39	relu	adam	mse	67	16
Dataset 2	LOCF	2	33	tanh	rmsprop	mse	74	51
Dataset 3	Mean	3	253	relu	adam	mse	59	34

Berdasarkan Tabel 3 hasil optimasi Parameter Model Terbaik Pada Tiap Dataset menunjukkan bahwa setiap dataset menghasilkan kombinasi hyperparameter optimal yang berbeda. Perbedaan ini mengindikasikan bahwa karakteristik kehilangan data dan pola temporal pada masing-masing dataset secara langsung memengaruhi kebutuhan arsitektur GRU. Variasi pada jumlah lapisan, neuron, fungsi aktivasi, dan dropout mencerminkan kemampuan PSO dalam menyeimbangkan kompleksitas model dan stabilitas pelatihan. Sebagai representasi dari hasil tuning parameter tersebut, arsitektur model GRU secara dapat divisualisasikan pada Gambar 3. Visualisasi ini mengilustrasikan bentuk jaringan yang mengadopsi konfigurasi hyperparameter PSO untuk pemodelan pada Dataset 1 dengan strategi imputasi Mean.



Gambar 3. Arsitektur model GRU untuk hasil optimasi parameter Dataset 1 dengan strategi imputasi Mean.

E. Evaluasi Kinerja Model

Dalam mengevaluasi kinerja model peramalan, digunakan tiga metrik utama yaitu *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), dan koefisien determinasi (R^2) untuk mengukur tingkat akurasi, besar kesalahan prediksi, serta kemampuan model dalam menjelaskan variansi data aktual [35]. Nilai MAPE mengukur rata-rata persentase kesalahan absolut antara nilai aktual dan prediksi, dengan y_i menyatakan nilai aktual, \hat{y}_i nilai prediksi, dan n jumlah observasi. Metrik MAPE dapat dirumuskan pada Persamaan (1).

$$MAPE = \frac{100\%}{n} \sum_{i=0}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \tag{1}$$

Pada Persamaan (2) RMSE digunakan untuk mengukur akar dari rata-rata kuadrat kesalahan yang memberikan penalti lebih besar terhadap deviasi yang signifikan, sehingga sensitif terhadap *outlier*. Metrik ini bekerja dengan dituliskan sebagai Persamaan (2).

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

Sementara itu, pada Persamaan (3), R^2 digunakan untuk mengukur proporsi variansi data aktual yang mampu dijelaskan oleh model, sehingga merepresentasikan tingkat kesesuaian model terhadap data.

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

Pada Persamaan (3) di mana \bar{y} merupakan rata-rata dari nilai aktual. Nilai MAPE yang lebih rendah menunjukkan kesalahan relatif yang kecil [36], RMSE yang rendah mengindikasikan deviasi prediksi yang minimal [37], sedangkan nilai R^2 yang mendekati 1 menunjukkan kemampuan model yang tinggi dalam merepresentasikan pola data [38], sehingga ketiga metrik ini secara bersama memberikan evaluasi yang komprehensif terhadap performa model peramalan.

III. Hasil dan Pembahasan

Kinerja berbagai model GRU dalam peramalan deret waktu dievaluasi secara komprehensif menggunakan metrik MAPE, RMSE, dan R^2 pada berbagai metode imputasi data hilang. Evaluasi ini mencakup perbandingan antar arsitektur model imputasi serta analisis pengaruh teknik imputasi terhadap akurasi dan stabilitas prediksi. Hasil pengujian disajikan secara sistematis pada Tabel 8 hingga Tabel 10 untuk memberikan gambaran yang jelas mengenai pola performa yang dihasilkan, sekaligus menjadi dasar dalam pembahasan lebih lanjut terkait efektivitas masing-masing pendekatan.

Tabel 4. Hasil Evaluasi MAPE

Metode Imputasi	Dataset 1	Dataset 2	Dataset 3
<i>Drop Missing Value</i>	2.34817	8.17138	3.34292
<i>Mean</i>	0.74074	1.54343	0.35973
<i>Median</i>	0.72149	7.70204	0.34435
<i>Mode</i>	1.07071	1.76253	0.50306
<i>KNN</i>	1.22538	6.151503	0.83818
<i>LOCF</i>	0.80216	1.36115	0.56407
<i>MICE</i>	1.25809	6.50112	0.57145

Hasil pengujian MAPE pada Tabel 4 menunjukkan bahwa metode *drop missing value* secara konsisten menghasilkan nilai kesalahan tertinggi pada ketiga dataset, yang mengindikasikan bahwa penghapusan observasi secara langsung mengganggu kesinambungan urutan data. Penerapan imputasi menunjukkan peningkatan performa dengan tingkat efektivitas yang bervariasi tergantung pada karakteristik data. Metode Mean dan Mode menunjukkan performa yang baik pada Dataset 1 (0.74074) dan Dataset 3 (0.34435), namun Mode mengalami penurunan konsistensi pada Dataset 2 dengan nilai MAPE yang relatif tinggi (7.702004). Pada kondisi dengan dinamika yang lebih kompleks seperti Dataset 2, metode LOCF memberikan hasil yang lebih stabil (1.36115) karena kemampuannya mempertahankan kontinuitas nilai berdasarkan observasi sebelumnya. Sementara itu, metode seperti KNN dan MICE menunjukkan performa yang fluktuatif antar dataset. Secara keseluruhan, Mean dan LOCF menunjukkan konsistensi yang lebih baik dalam menekan nilai kesalahan dibandingkan metode lainnya. Dengan demikian, optimasi kinerja peramalan GRU menuntut strategi imputasi yang mampu menjaga korelasi temporal data untuk meminimalisasi distorsi pada memori jangka pendek model GRU.

Tabel 5. Hasil Evaluasi RMSE

Metode Imputasi	Dataset 1	Dataset 2	Dataset 3
<i>Drop Missing Value</i>	3.35600	23.86299	1.49339
<i>Mean</i>	3.25932	21.20911	1.19158
<i>Median</i>	4.80296	21.04623	1.18365
<i>Mode</i>	4.86536	21.70114	1.53354
<i>KNN</i>	4.36676	18.99171	2.77912
<i>LOCF</i>	3.29948	16.22207	1.63199
<i>MICE</i>	4.25299	21.78677	1.76368

Berdasarkan Tabel 5 yang menyajikan hasil evaluasi RMSE, terlihat bahwa metode imputasi berpengaruh signifikan terhadap performa model, di mana *drop missing values* cenderung menghasilkan *error* yang relatif tinggi dan lebih fluktuatif terhadap hasil prediksi. Pendekatan menghapus data yang hilang cenderung menghasilkan *error* yang lebih tinggi, khususnya pada Dataset 2 (23.86299). Metode Mean menunjukkan performa yang relatif stabil pada Dataset 1 (3.25932) dan Dataset 3 (1.19158), sementara LOCF menghasilkan nilai RMSE terendah pada Dataset 2 (16.22207), menunjukkan kemampuannya dalam mempertahankan struktur lokal data. Metode lain seperti Mode, MICE, dan KNN menunjukkan variasi performa yang cukup besar antar dataset. Secara umum, Mean dan LOCF kembali menunjukkan kestabilan performa dibandingkan metode lainnya dalam menjaga nilai *error* tetap rendah. Secara keseluruhan, temuan ini membuktikan bahwa efektivitas tahap imputasi pada peramalan GRU bertumpu pada kemampuan metode tersebut dalam merestorasi kesinambungan struktural deret waktu agar selaras dengan arsitektur memori model.


Tabel 6. Hasil Evaluasi R^2

Metode Imputasi	Dataset 1	Dataset 2	Dataset 3
<i>Drop Missing Value</i>	0.81415	0.85930	0.93486
<i>Mean</i>	0.92828	0.89344	0.98398
<i>Median</i>	0.84416	0.89507	0.98420
<i>Mode</i>	0.83609	0.88844	0.97347
<i>KNN</i>	0.86797	0.91456	0.91312


Metode Imputasi	Dataset 1	Dataset 2	Dataset 3
LOCF	0.9265	0.93766	0.96997
MICE	0.87476	0.88756	0.96526

Berdasarkan Tabel 6 yang menyajikan hasil evaluasi R^2 yang merepresentasikan proporsi variabilitas data yang berhasil ditangkap oleh model. Terlihat bahwa metode *drop missing values* secara umum menghasilkan performa nilai terendah pada Dataset 1 (0.81415) dan Dataset 2 (0.85930). Penurunan kemampuan ini menegaskan bahwa hilangnya sekuens kronologis mendistorsi kapasitas retensi memori GRU dalam memetakan pola pergerakan data. Metode imputasi terbukti mampu mengamplifikasi nilai R^2 , di mana tingkat efektivitasnya bervariasi bergantung pada keselarasan metode dengan distribusi temporal. Metode statis seperti Mean memberikan hasil optimal pada Dataset 1 (0.92828) dan Mode pada Dataset 3 (0.98420), namun kemampuan keduanya dalam menangkap varians terdegradasi pada Dataset 2. Pada kondisi dinamika tinggi seperti Dataset 2, metode LOCF kembali mencatat performa paling superior (0.93766) karena kemampuannya meneruskan observasi terakhir secara efektif melestarikan stabilitas tren fluktuasi. Di sisi lain, algoritma berbasis proksimitas multivariat seperti MICE dan KNN tidak menunjukkan dominasi yang konsisten karena hasil imputasinya bertumpu pada kedekatan ruang fitur, bukan pada autokorelasi temporal. Secara keseluruhan, Mean dan LOCF menunjukkan konsistensi yang lebih baik dalam meningkatkan nilai R^2 di berbagai kondisi dataset. Dengan demikian, temuan ini membuktikan bahwa efektivitas tahap imputasi pada peramalan GRU bertumpu pada kemampuan metode tersebut dalam merestorasi kesinambungan struktural deret waktu agar selaras dengan arsitektur memori model.


Dalam penelitian analisis mengombinasikan evaluasi kuantitatif menggunakan metrik MAPE, RMSE, dan R^2 dengan pemeriksaan visual hasil peramalan deret waktu. Visualisasi digunakan untuk melihat sejauh mana model GRU mampu mengikuti pola data aktual serta menjaga keselarasan nilai prediksi terhadap waktu. Gambar 3 – 5 menampilkan perbandingan nilai aktual dan hasil prediksi pada masing-masing dataset sebagai dasar untuk menilai konsistensi performa model.



Gambar 4. Grafik Hasil Peramalan Imputasi Model GRU pada Dataset 1



Gambar 5. Grafik Hasil Peramalan Imputasi Model GRU pada Dataset 2



Gambar 6. Grafik Hasil Peramalan Imputasi Model GRU pada Dataset 3

Hasil pada Gambar 4 - 6 menunjukkan bahwa imputasi memberikan kinerja yang konsisten pada seluruh dataset. Pendekatan ini mampu mempertahankan kontinuitas temporal dan pola data yang ada, sehingga hasil prediksi tetap mengikuti sinyal aktual, termasuk pada periode dengan fluktuasi maupun perubahan yang cukup signifikan. Temuan visual ini sejalan dengan hasil kuantitatif, di mana penggunaan imputasi menghasilkan nilai MAPE dan RMSE yang lebih rendah serta nilai R^2 yang lebih tinggi dibandingkan metode imputasi lainnya pada berbagai dataset. Dengan mempertahankan nilai observasi terakhir, imputasi membantu menjaga kestabilan pola tanpa menyebabkan penghalusan berlebihan, sehingga hubungan jangka pendek dalam data tetap terjaga. Hal ini menunjukkan bahwa imputasi merupakan pendekatan prapemrosesan yang stabil dalam mendukung proses peramalan pada kondisi data yang memiliki nilai hilang.

Untuk memperkuat interpretasi kuantitatif, dilakukan uji signifikansi statistik menggunakan uji t berpasangan dua arah pada tingkat kepercayaan 95% untuk mengevaluasi pengaruh strategi imputasi terhadap hasil evaluasi setelah penghapusan data. Hasil pengujian menunjukkan bahwa pada Dataset 1 dan Dataset 3 diperoleh nilai p yang sangat kecil ($p = 0,0001$), mengindikasikan bahwa imputasi memberikan pengaruh yang signifikan terhadap kinerja model. Sementara itu, pada Dataset 2 diperoleh nilai p sebesar 0,0200 yang juga masih berada di bawah ambang signifikansi 0,05, sehingga menunjukkan adanya pengaruh yang signifikan, meskipun tidak sekuat pada dua dataset lainnya. Temuan ini mengindikasikan bahwa penerapan imputasi secara umum didukung oleh bukti statistik dalam meningkatkan hasil evaluasi, dengan tingkat pengaruh yang dapat bervariasi tergantung pada karakteristik masing-masing dataset.

Untuk mengatasi keterbatasan penggunaan arsitektur deep learning tunggal, studi ini memperluas analisis dengan membandingkan kinerja peramalan Model GRU dengan model deep learning berbasis rekuren lainnya, yaitu LSTM, Bi-LSTM, dan RNN. Hasil perbandingan untuk setiap dataset disajikan pada Tabel 7.

Tabel 7. Hasil Komparasi Model

Dataset	Method	MAPE	RMSE	R^2
Dataset 1	GRU	0.74074	3.25932	0.92828
	Bi-LSTM	1.37172	4.24730	0.87510
	RNN	1.41796	4.47937	0.86101
	LSTM	1.22256	4.30110	0.86976
Dataset 2	GRU	1.36115	16.22207	0.93766
	Bi-LSTM	3.12413	18.75351	0.82869
	RNN	1.59583	25.92636	0.81366
	LSTM	1.42783	30.34375	0.82804
Dataset 3	GRU	0.35973	1.19158	0.98398
	Bi-LSTM	3.13373	2.69188	0.91849
	RNN	7.46550	8.72610	0.14101
	LSTM	1.85895	4.30110	0.84806

Kinerja model GRU tercermin secara konsisten di seluruh dataset eksperimen, dengan pencapaian nilai MAPE dan RMSE yang jauh lebih rendah serta R^2 yang lebih tinggi dibandingkan arsitektur LSTM, Bi-LSTM, dan RNN. Bukti empiris pada Dataset 1 menunjukkan bahwa sinergi antara imputasi Mean dan GRU menghasilkan presisi tertinggi ($R^2 = 0.92828$). Sementara itu, pada Dataset 2 yang memiliki dinamika fluktuatif, penggunaan LOCF terbukti menjadi strategi paling efektif dengan raihan R^2 sebesar 0.93766. Pada Dataset 3, efektivitas metode Mean kembali terkonfirmasi melalui nilai MAPE terendah (1.54343). Fenomena ini menegaskan bahwa keberhasilan peramalan tidak hanya bertumpu pada arsitektur model, tetapi secara krusial bergantung pada pemetaan sistematis antara mekanisme nilai hilang dan strategi imputasi yang selaras dengan karakteristik dataset.

Selain itu, hasil perbandingan antar model menunjukkan bahwa GRU secara konsisten menghasilkan performa yang lebih baik dibandingkan LSTM, Bi-LSTM, dan RNN pada seluruh dataset. Keunggulan ini dapat dijelaskan dari struktur GRU yang lebih sederhana namun tetap efektif dalam menangkap dependensi temporal, sehingga lebih adaptif terhadap data yang telah melalui proses imputasi. Dibandingkan dengan RNN yang cenderung mengalami kesulitan dalam mempertahankan informasi jangka panjang, serta LSTM dan Bi-LSTM yang memiliki kompleksitas lebih tinggi, GRU mampu mencapai keseimbangan antara efisiensi pembelajaran dan kemampuan representasi pola data. Kombinasi antara imputasi yang tepat dan arsitektur GRU yang adaptif inilah yang menghasilkan performa peramalan yang lebih konsisten. Selain itu, variasi hasil antar dataset menunjukkan bahwa karakteristik data tetap menjadi faktor penentu dalam pemilihan strategi imputasi yang tepat, sehingga pendekatan yang adaptif dan mempertimbangkan sifat data menjadi penting untuk menghasilkan performa peramalan yang optimal.

Perbedaan performa antar metode imputasi yang terjadi berkaitan langsung dengan kemampuan data dalam mempertahankan struktur statistik deret waktu, khususnya distribusi nilai dan autokorelasi temporal. Metode seperti Mean cenderung menjaga stabilitas distribusi global namun berpotensi mengurangi variasi lokal, sedangkan LOCF mempertahankan dependensi jangka pendek dengan mereplikasi nilai sebelumnya sehingga

lebih efektif pada data dengan dinamika tinggi. Sebaliknya, metode seperti KNN dan MICE yang berbasis kedekatan ruang fitur tidak secara eksplisit mempertahankan urutan temporal sehingga menghasilkan performa yang tidak konsisten. Variasi hasil antar dataset juga menunjukkan bahwa efektivitas imputasi dipengaruhi oleh mekanisme kehilangan data, di mana pendekatan sederhana masih efektif pada kondisi yang mendekati acak, sementara pendekatan berbasis kontinuitas lebih sesuai untuk pola kehilangan yang bergantung pada waktu. Dalam konteks ini, kinerja GRU yang konsisten lebih baik dibandingkan model lain menunjukkan bahwa arsitektur yang efisien dalam menangkap dependensi temporal mampu memanfaatkan hasil imputasi secara lebih optimal. Temuan ini menegaskan bahwa keberhasilan peramalan ditentukan oleh keselarasan antara karakteristik data, strategi imputasi, dan mekanisme pembelajaran model.

Penelitian ini menegaskan bahwa strategi prapemrosesan data memiliki implikasi krusial terhadap kualitas estimasi waktu salat. Penentuan waktu ibadah merupakan pemetaan fenomena benda langit yang bersifat periodik dan terstruktur, sehingga pemodelan memerlukan representasi deret waktu yang konsisten. Ketidaklengkapan data akibat hilangnya urutan observasi dapat memutus kontinuitas pola tersebut dan mengganggu stabilitas pembelajaran model. Hasil empiris menunjukkan bahwa teknik imputasi yang mempertahankan keterurutan data, seperti Mean dan LOCF, memberikan kinerja yang lebih stabil dibandingkan metode kompleks (KNN dan MICE) karena lebih efektif dalam menjaga struktur ketergantungan waktu. Dengan demikian, akurasi peramalan tidak hanya ditentukan oleh pemilihan arsitektur model, tetapi juga oleh kemampuan strategi imputasi dalam menjaga konsistensi struktur temporal data sebagai representasi numerik dari dinamika astronomis yang mendasarinya.

Penelitian ini memiliki beberapa keterbatasan dalam interpretasi hasil. Pertama, seluruh eksperimen dilakukan pada deret waktu univariat, sehingga metode imputasi seperti MICE dan KNN belum dapat memanfaatkan hubungan antar variabel secara optimal. Kedua, meskipun beberapa arsitektur rekuren telah dibandingkan, evaluasi belum mencakup model deret waktu mutakhir seperti Temporal Convolutional Networks dan Transformer-based models, sehingga generalisasi hasil masih terbatas. Ketiga, pengujian dilakukan pada tingkat missing value yang tetap tanpa variasi sparsitas, sehingga sensitivitas metode imputasi terhadap ketidaklengkapan data belum dievaluasi secara komprehensif. Oleh karena itu, hasil yang diperoleh perlu diinterpretasikan sesuai dengan karakteristik data yang digunakan. Penelitian selanjutnya diarahkan pada pengembangan pendekatan multivariat untuk mengoptimalkan pemanfaatan hubungan antar variabel, serta eksplorasi model deret waktu mutakhir guna menguji konsistensi temuan di luar arsitektur rekuren. Selain itu, analisis sensitivitas terhadap variasi tingkat sparsitas dan evaluasi pada dataset yang lebih beragam diperlukan untuk memahami ketahanan metode imputasi serta memperkuat generalisasi hasil.

IV. Kesimpulan dan saran

Penelitian ini menyimpulkan bahwa efektivitas peramalan menggunakan *Gated Recurrent Unit* (GRU), khususnya dalam prediksi waktu salat tidak hanya ditentukan oleh arsitektur model, tetapi juga dipengaruhi oleh kemampuan dalam mempertahankan dependensi temporal selama tahap prapemrosesan data. Dalam konteks penentuan waktu salat, aspek ini relevan karena sistem berbasis komputasi astronomi membutuhkan ketelitian tinggi, sehingga gangguan pada kontinuitas observasi dapat berdampak pada perubahan hasil estimasi waktu. Hasil komparasi empiris pada tiga dataset yang merepresentasikan pola siklik harian dan variasi musiman menunjukkan bahwa GRU memberikan kinerja yang konsisten lebih baik dibandingkan model rekuren lainnya (LSTM, Bi-LSTM, dan RNN). Kinerja tersebut didukung oleh penerapan metode imputasi berorientasi kronologis seperti Mean dan *Last Observation Carried Forward* (LOCF), yang cenderung mempertahankan struktur temporal data secara lebih stabil dibandingkan metode berbasis kedekatan ruang fitur seperti KNN dan MICE. Temuan ini menunjukkan bahwa kesesuaian antara strategi imputasi dan karakteristik data deret waktu berpengaruh terhadap stabilitas hasil peramalan waktu salat pada kondisi data tidak lengkap. Secara praktis, hasil ini dapat menjadi pertimbangan dalam pengembangan sistem peramalan berbasis komputasi astronomi yang lebih robust terhadap ketidaklengkapan data. Untuk pengembangan lebih lanjut, penelitian dapat diperluas pada deret waktu multivariat dengan tingkat sparsitas yang bervariasi serta diuji pada arsitektur non-rekuren seperti *Temporal Convolutional Networks* dan *Transformer-based models* guna mengevaluasi konsistensi temuan pada pendekatan pemodelan yang berbeda.

Daftar Pustaka

- [1] L. Salsabila and M. A. K. Hasan, "Ifitirāḍī Mahmud Yunus'S Interpretation of the Phenomenon of Fasting At the Poles in Surah Al-Baqarah: 183—185," *Tanzil J. Stud. Al-Quran*, vol. 6, no. 2, pp. 167–188, 2024, doi: 10.20871/tjsq.v6i2.336.
- [2] A. Fadholi, "Diferensiasi Hisab Waktu Salat (Studi Kitab al-Khulashah al-Wafiyah dan Kontemporer)," *Al-Marshad J. Astron. Islam dan Ilmu-Ilmu Berkaitan*, vol. 8, no. 2, 2022, doi: 10.30596/jam.v8i2.10845.
- [3] I. Eltohamy, M. R. Mahdy, R. Mawad, A. R. Abdul Rahim, A. Ali, and A. H. Owis, "The ground-based navigations and solar incidence angle," *AAPPS Bull.*, vol. 35, no. 1, 2025, doi: 10.1007/s43673-

- 025-00168-4.
- [4] Ronny Mahmuddin, Abdul Munawir, and Muslimin, "Metode Penetapan Waktu Salat Menurut Dewan Syariah Wahdah Islamiyah," *BUSTANUL FUQAHA J. Bid. Huk. Islam*, vol. 1, no. 1, pp. 44–59, 2020, doi: 10.36701/bustanul.v1i1.126.
- [5] Zavitri Galuh Prameswari and Mahsun, "Perspektif Fiqih Minoritas Yusuf Al-Qardhawi Dalam Penentuan Awal Waktu Salat Di Daerah Kutub," *El-Faqih J. Pemikir. dan Huk. Islam*, vol. 10, no. 2, pp. 334–349, 2024, doi: 10.58401/faqih.v10i2.1480.
- [6] B. L. Pradana, "Time Series Forecasting of LQ45 Stock Index Using ARIMA: Insight and Implications," vol. 1, no. 1, pp. 27–40, 2025, doi: <https://doi.org/10.51170/jmabr.v1i1.160>.
- [7] W. Liu, C. Ren, and Y. Xu, "Missing-Data Tolerant Hybrid Learning Method for Solar Power Forecasting," *IEEE Trans. Sustain. Energy*, vol. 13, no. 3, pp. 1843–1852, 2022, doi: 10.1109/TSTE.2022.3173147.
- [8] S. K. V. R. Gimirugan, P. Selvaraju, Prabahar Jeevanandam, M. Vadivukarassi, S. Subhashini, N. Selvam, S. K. Hasane Ahammad, S. Mayakannan, "Application of Deep Learning to the Prediction of Solar Irradiance through Missing Data," *Int. J. Photoenergy*, p. 17 page, 2023, doi: 10.1155/2023/4717110.
- [9] S. S. Kolukula and M. PLN, "Enhancing observations data: A machine-learning approach to fill gaps in the moored buoy data," *Results Eng.*, vol. 26, 2025, doi: 10.1016/j.rineng.2025.104708.
- [10] M. D. Saputra and Hasna Tuddar Putri, "Akurasi Jadwal Salat Digital Menggunakan Aplikasi Khalifah JWS ESP di Kecamatan Banda Sakti Kota Lhokseumawe," *Astroislamica J. Islam. Astron.*, vol. 2, no. 1, pp. 25–46, 2023, doi: 10.47766/astroislamica.v2i1.1519.
- [11] C. Helfrich-Förster and D. Rieger, "A clock for all seasons," *J. Comp. Physiol. A Neuroethol. Sensory, Neural, Behav. Physiol.*, vol. 210, no. 4, pp. 473–480, 2024, doi: 10.1007/s00359-024-01711-8.
- [12] M. Kavaliers and D. M. Ross, "Twilight and day length affects the seasonality of entrainment and endogenous circadian rhythms in a fish, *Couesius plumbeus*," *Can. J. Zool.*, vol. 59, no. 7, pp. 1326–1334, 1981, doi: 10.1139/z81-184.
- [13] H. Han *et al.*, "Time series forecasting model for non-stationary series pattern extraction using deep learning and GARCH modeling," *J. Cloud Comput.*, vol. 13, no. 1, 2024, doi: 10.1186/s13677-023-00576-7.
- [14] T. Zeng *et al.*, "Analysis of Data Quality Impact on Load Forecasting," *Student Conf. Electr. Mach. Syst.*, vol. 7, pp. 1–5, 2024, doi: <https://doi.org/10.1109/SCEMS63294.2024.10756359>.
- [15] R. E. Zeebe and L. J. Lourens, "Geologically constrained astronomical solutions for the Cenozoic era," *Earth Planet. Sci. Lett.*, vol. 592, p. 117595, 2022, doi: 10.1016/j.epsl.2022.117595.
- [16] R. E. Zeebe, I. J., and Kosken, "Applying astronomical solutions and Milanković forcing in the Earth sciences," *Earth-Science Rev.*, vol. 261, no. 104059, 2025, doi: <https://doi.org/10.1016/j.epsl.2022.117595>.
- [17] A. Arwansyah, S. Suryani, H. SY, U. Usman, A. Ahyuna, and S. Alam, "Time Series Forecasting Menggunakan Deep Gated Recurrent Units," *Digit. Transform. Technol.*, vol. 4, no. 1, pp. 410–416, 2022, doi: 10.47709/digitech.v4i1.4141.
- [18] Z. Ke *et al.*, "A stable technical feature with GRU-CNN-GA fusion," *Appl. Soft Comput.*, vol. 187, 2026, doi: 10.1016/j.asoc.2025.114302.
- [19] A. Yunita *et al.*, "Performance analysis of neural network architectures for time series forecasting: A comparative study of RNN, LSTM, GRU, and hybrid models," *MethodsX*, vol. 15, 2025, doi: 10.1016/j.mex.2025.103462.
- [20] K. Thakur, H. Kumar, and Snehamani, "Advancing Missing Data Imputation in Time-Series: A Review and Proposed Prototype," *2023 Int. Conf. Emerg. Trends Networks Comput. Commun. ETNCC 2023 - Proc.*, pp. 53–57, 2023, doi: 10.1109/ETNCC59188.2023.10284970.
- [21] W. M. Hameed and N. A. Ali, "Comparison of Seventeen Missing Value Imputation Techniques," *J. Hunan Univ. Nat. Sci.*, vol. 49, no. 7, pp. 26–36, 2022, doi: 10.55463/issn.1674-2974.49.7.4.
- [22] S. E. Awan, M. Bennamoun, F. Sohel, F. Sanfilippo, and G. Dwivedi, "A reinforcement learning-based approach for imputing missing data," *Neural Comput. Appl.*, vol. 34, no. 12, pp. 9701–9716, 2022, doi: 10.1007/s00521-022-06958-3.
- [23] D. Wan and J. Xiangji Huang, "Missing Value Treatments for Machine Learning-Based Misbehavior Detection Systems: Survey, Evaluation, and Challenges," *IEEE Trans. Intell. Transp. Syst.*, vol. 26, no. 9, pp. 12798–12818, 2025, doi: 10.1109/TITS.2025.3587612.
- [24] F. T. Bahadur, S. R. Shah, and R. R. Nidamanuri, "Geospatial time series forecasting of air quality across Delhi using ARIMA and LSTM models," *J. Atmos. Solar-Terrestrial Phys.*, vol. 279, 2026, doi: 10.1016/j.jastp.2026.106723.
- [25] W. Astuti and R. Govindaraju, "Effect of Data Gaps on Harmful Algal Bloom Prediction Models for Inland Lakes," *J. Hydrol. Eng.*, vol. 31, no. 1, 2026, doi: 10.1061/jhyeff.heeng-6544.

- [26] S. Alam, M. S. Ayub, S. Arora, and M. A. Khan, "An investigation of the imputation techniques for missing values in ordinal data enhancing clustering and classification analysis validity," *Decis. Anal. J.*, vol. 9, 2023, doi: 10.1016/j.dajour.2023.100341.
- [27] M. Afkanpour, E. Hosseinzadeh, and H. Tabesh, "Identify the most appropriate imputation method for handling missing values in clinical structured datasets: a systematic review," *BMC Med. Res. Methodol.*, vol. 24, no. 1, 2024, doi: 10.1186/s12874-024-02310-6.
- [28] Y. Yin, Y. Wu, X. Yang, W. Zhang, and X. Yuan, "SE-GRU: Structure Embedded Gated Recurrent Unit Neural Networks for Temporal Link Prediction," *IEEE Trans. Netw. Sci. Eng.*, vol. 9, no. 4, pp. 2495–2509, 2022, doi: 10.1109/TNSE.2022.3164659.
- [29] K. AL-Attabi and R. P. Singh, "A Study on Time Series Forecasting Using ARIMA, LSTM, and GRU Models," pp. 1–7, 2025, doi: 10.1109/giet65294.2025.11234867.
- [30] J. Ullah, H. Li, H. J. Förster, R. M. Abdalla, M. Ehsan, and M. Faisal, "Harvesting Earth's heat: A deep learning Odyssey for reservoir characterization and sustainable geothermal energy management," *Geoenergy Sci. Eng.*, vol. 238, 2024, doi: 10.1016/j.geoen.2024.212921.
- [31] P. J and M. Ali, "Investigating the Impact of Min-Max Data Normalization on the Regression Performance of K-Nearest Neighbor with Different Similarity Measurements," *ARO-THE Sci. J. KOYA Univ.*, vol. 10.1, pp. 85–91, 2022, doi: <https://orcid.org/0000-0002-0471-5172>.
- [32] A. P. Wibawa *et al.*, "Gated Recurrent Unit (GRU) for Forecasting Hourly Energy Fluctuations," *Front. Energy Syst. Power Eng.*, vol. 5, 2024, doi: 10.17977/um049v5i1p16-25.
- [33] S. H. Noh, "Analysis of gradient vanishing of RNNs and performance comparison," *Inf.*, vol. 12, no. 11, 2021, doi: 10.3390/info12110442.
- [34] R. Zhu, G. Y. Zhong, and J. C. Li, "Forecasting price in a new hybrid neural network model with machine learning," *Expert Syst. Appl.*, vol. 249, 2024, doi: 10.1016/j.eswa.2024.123697.
- [35] S. Lima, A. M. Gonçalves, and M. Costa, "Predictive accuracy of time series models applied to economic data: the European countries retail trade," *J. Appl. Stat.*, vol. 51, no. 9, pp. 1818–1841, 2024, doi: 10.1080/02664763.2023.2238249.
- [36] M. M. Mundu, J. I. Sempewo, A. Goparaju, and D. E. Uti, "Comparative Analysis of Model Evaluation Metrics in Energy Systems, Environmental Modeling, and Sustainability Science," *Int. J. Energy Res.*, vol. 2026, no. 1, 2026, doi: 10.1155/er/6170467.
- [37] Ö. A. Karaman, "Prediction of Wind Power with Machine Learning Models," *Appl. Sci.*, vol. 13, no. 20, 2023, doi: 10.3390/app132011455.
- [38] V. Kumar, N. Kedam, K. V. Sharma, D. J. Mehta, and T. Caloiero, "Advanced Machine Learning Techniques to Improve Hydrological Prediction: A Comparative Analysis of Streamflow Prediction Models," *Water (Switzerland)*, vol. 15, no. 14, 2023, doi: 10.3390/w15142572.