

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Sebelumnya

Beberapa penelitian yang sudah dilakukan untuk meramalkan harga komoditas pangan dengan data time series telah menjadi topik yang mendapat banyak perhatian. Sejumlah penelitian sebelumnya berhasil menghasilkan prediksi yang akurat, yang kemudian dapat diterapkan dalam berbagai bidang dan aspek kehidupan sehari-hari kita. Dari pengamatan terhadap penelitian-penelitian sebelumnya, jelas terlihat bahwa peramalan harga komoditas pangan memiliki manfaat yang besar dalam perencanaan, persiapan, dan pengambilan keputusan.

Pertama, penelitian tentang prediksi tingkat perubahan harga (inflasi/deflasi) di tingkat konsumen. Penelitian ini memakai metode LSTM berbasis komputasi awan. Penulis dari penelitian tersebut adalah Soffa Zahara, Sugianto, dan M. Bahril Ilmiddafiq, mereka mengerjakan penelitian ini pada tahun 2021. Tujuan penelitian ini adalah untuk memprediksi tingkat perubahan harga di tingkat konsumen menggunakan metode LSTM. Dalam penelitian ini, digunakan tujuh algoritma optimasi yang berbeda untuk menilai optimasi mana yang terbaik untuk melakukan prediksi indeks harga konsumen. Data yang digunakan bahan pokok sejumlah 28 jenis yang diperoleh dari DISPERINDAG RI. Hasil akhir penelitian menunjukkan bahwa algoritma optimasi paling optimal untuk memprediksi indeks harga konsumen adalah *Nesterov Adam (Nadam)* dengan nilai RMSE terkecil sebesar 4,008 [20].

Kedua, penelitian tentang peramalan harga minyak goreng curah dan kemasan yang dilakukan oleh Lailan Sahrina Hasibuan dan Yanda Novialdi pada tahun 2022. Penelitian ini dilakukan untuk memprediksi harga minyak goreng dengan model LSTM. Dalam penelitian ini, beberapa parameter digunakan, termasuk banyaknya *neuron*, *epochs*, *optimizer*, *batch size*, dan pengaturan awal untuk semua parameter ini dilakukan menggunakan metode *grid search*. Data yang digunakan adalah data harga minyak goreng di pasar

tradisional di Provinsi Jawa Barat. Hasil penelitian berhasil menghasilkan model LSTM yang optimal menghasilkan nilai *Normalized Root Mean Square Error* data minyak goreng curah sebesar 0,019, lalu untuk minyak goreng kemasan sebesar 0,039. Model ini menggunakan jumlah unit dasar sebanyak 50, learning rate sebesar 0,01, jumlah sampel data sebesar 64, dan total epochs sebanyak 1000 [21].

Ketiga, penelitian yang dikerjakan oleh Insyiraah Oxaichiko Arissintaa, Indah Dwi Sulistiyawati, dan Dedy Kurniantoc Iqbal Kharisudin pada tahun 2022 mengenai pembuatan model dari data deret waktu untuk melakukan pemalan *web traffic*. Metode yang dipakai pada penelitian ini adalah *Arima*, *LSTM*, dan *GRU*. Penelitian ini bertujuan untuk melakukan peramalan lalu lintas web menggunakan algoritma tersebut. Penelitian ini membandingkan algoritma tradisional, *ARIMA*, dengan dua pendekatan yang lebih baru, yaitu *LSTM* dan *GRU*, untuk peramalan data deret waktu. Pada penelitian ini menggunakan data web Wikipedia yang berisi lalu lintas halaman web, dataset pelatihan ini berisi sebanyak 145.000 deret waktu. Hasil analisis peramalan menunjukkan bahwa LSTM dan GRU memberikan hasil peramalan yang lebih akurat, sementara ARIMA masih menghasilkan tingkat kesalahan yang cukup besar [22].

Keempat, penelitian yang dikerjakan oleh Nanda Kurnia Agusmawati, Fitwatul Khoiriyah, dan Abu Tholib pada tahun 2023 mengenai prediksi harga emas. Penelitian ini menggunakan metode LSTM dan GRU untuk membangun model prediksi. Algoritma LSTM dan GRU digunakan pada penelitian ini untuk mengerjakan prediksi harga emas. Dataset yang dipakai pada penelitian ini di dapatkan dari web Kaggle, judul dari dataset tersebut adalah *Daily Gold Price Historical Data*. Setelah kedua model dibandingkan dengan metrik evaluasi, penelitian ini menunjukkan model LSTM lebih baik dibandingkan dengan model GRU ketika digunakan untuk melakukan prediksi pada harga emas. Model LSTM memiliki hasil yang lebih baik, dengan nilai *mae* sebesar 0,0389, *rmse* sebesar 0,0475, lalu untuk nilai *mape* sebesar 5,2047%. Untuk model GRU yang dibangun pada penelitian ini mencapai performa terbaiknya

dengan jumlah sampel data sebanyak 32 dan epochs 100. Model tersebut menghasilkan nilai *mae* sebesar 0,0447, *rmse* sebesar 0,0545, dan *mape* sebesar 6,0688% [14].

Kelima, penelitian yang dikerjakan oleh Roby Julian dan Muhammad Rizky Pribadi pada tahun 2021 mengenai prediksi harga saham. Data yang digunakan berasal dari harga saham pertambangan pada Bursa Efek Indonesia (BEI). Metode yang digunakan untuk melakukan penelitian ini adalah pengembangan dari jaringan saraf rekuren yaitu LSTM. Penelitian ini bertujuan untuk memprediksi harga saham pertambangan dengan menggunakan model LSTM. Data yang digunakan adalah data harga saham pertambangan yang diperdagangkan di Bursa Efek Indonesia. Dataset dibagi menjadi dua, untuk data latih dan juga untuk data uji dengan komposisi sebanyak 80% untuk data latih dan 20% untuk data uji. Model LSTM dilatih dengan 50 neuron, 2 hidden layer, batch size sebanyak 50, dan variasi jumlah epoch yaitu 50, 100, 150, dan 200. Hasil penelitian menunjukkan bahwa nilai Root Mean Square Error (RMSE) mengalami penurunan seiring dengan peningkatan jumlah epoch dalam proses prediksi. Namun, penambahan jumlah epoch juga mempengaruhi waktu komputasi yang diperlukan. Hasil RMSE terendah ditemukan pada saham emiten TINS, dengan nilai RMSE sebesar 31,76 saat menggunakan 200 epoch, sedangkan nilai RMSE tertinggi terjadi pada saham emiten INCO, dengan nilai RMSE sebesar 139,67 saat menggunakan 50 epoch [23].

Tabel 2. 1 Ringkasan Penelitian Sebelumnya

Year	Author	Country of the Author	Objective	Contribution	Data	Methodology	Result/Conclusion	Difference
2021	Soffa Zahara, Sugianto, M. Bahril Ilmiddafiq	Indonesia	Memprediksi Indeks Harga Konsumen dengan model LSTM	Penerapan pengembangan dari algoritma <i>RNN</i> yaitu LSTM untuk memprediksi nilai Indeks Harga Konsumen	28 jenis bahan pokok yang didapatkan di Dinas Perdagangan dan Perindustrian	Dalam penelitian ini, digunakan tujuh algoritma optimasi yang berbeda	Hasil akhir penelitian menunjukkan bahwa algoritma optimasi paling optimal dalam memprediksi Indeks Harga Konsumen adalah <i>Nesterov Adam (Nadam)</i> dengan nilai RMSE terkecil sebesar 4,008	Penelitian ini menggunakan algoritma LSTM dan GRU untuk melakukan peramalan harga
2022	Lailan Sahrina Hasibuan,	Indonesia	Prediksi harga minyak goreng	Penerapan pengembangan dari algoritma	Data harga minyak goreng pada pasar	Dalam penelitian ini, beberapa parameter	Hasil penelitian berhasil menghasilkan model <i>LSTM</i> yang optimal	Penelitian ini menggunakan algoritma LSTM dan GRU untuk

	Yanda Novialdi		dengan model LSTM	<i>RNN</i> yaitu LSTM pada prediksi harga kebutuhan pangan	tradisional di Provinsi Jawa Barat	digunakan, termasuk banyaknya neuron, epochs, optimizer, dan batch size, dan pengaturan awal untuk semua parameter ini dilakukan menggunakan metode <i>grid search</i>	menghasilkan nilai <i>Normalized Root Mean Square Normalized Root Mean Square Error</i> data minyak goreng sebesar 0,019, lalu untuk minyak goreng kemasan sebesar 0,039	melakukan peramalan harga
2022	Insyiraah Oxaichiko Arissintaa, Indah Dwi Sulistiyaw	Indonesia	Peramalan web traffic dengan algoritma Arima,	Membandingkan ketiga algoritma untuk melakukan	Data yang digunakan dalam penelitian ini adalah data	Penelitian ini membandingkan algoritma tradisional, <i>ARIMA</i> , dengan	Hasil analisis peramalan menunjukkan bahwa <i>LSTM</i> dan <i>GRU</i> memberikan hasil	Penelitian ini menggunakan skenario riset untuk mendapatkan model

	ati, Dedy Kurnianto, Iqbal Kharisudin		LSTM, GRU	peramalan dengan data time series	web Wikipedia yang berisi lalu lintas halaman web	dua pendekatan yang lebih baru, yaitu <i>LSTM</i> dan <i>GRU</i> , untuk peramalan data deret waktu	peramalan yang lebih akurat, sementara <i>ARIMA</i> masih menghasilkan tingkat kesalahan yang cukup besar	dengan performa tinggi
2023	Nanda Kurnia Agusmawati, Fitwatul Khoiriyah, Abu Tholib	Indonesia	Prediksi harga emas dengan metode LSTM dan GRU	Penerapan algoritma LSTM dan GRU untuk memprediksi harga emas	Dataset yang digunakan diperoleh dari Kaggle, dengan judul Daily Gold Price Historical Data	Penelitian ini menggunakan algoritma LSTM dan GRU untuk melakukan prediksi harga emas	Model LSTM memiliki hasil yang lebih baik, dengan nilai <i>mae</i> sebesar 0,0389, <i>rmse</i> sebesar 0,0475, lalu untuk nilai <i>mape</i> sebesar 5,2047%. Model GRU menghasilkan nilai <i>mae</i> sebesar 0,0447, <i>rmse</i> sebesar	Penelitian ini menggunakan skenario riset untuk mendapatkan model dengan performa tinggi

							0,0545, dan <i>mape</i> sebesar 6,0688%	
2021	Roby Julian, Muhammad Rizky Pribadi	Indonesia	Prediksi harga saham pertambahan dengan model LSTM	Penerapan pengembangan dari algoritma <i>RNN</i> yaitu LSTM untuk memprediksi harga saham pertambahan	Data harga saham pertambahan pada Bursa Efek Indonesia	Dataset dibagi menjadi data latih dan data uji dengan perbandingan 80:20. Model LSTM dilatih dengan 50 neuron, 2 hidden layer, batch size sebanyak 50, dan variasi jumlah epoch yaitu 50, 100, 150, dan 200	nilai Root Mean Square Error (RMSE) mengalami penurunan seiring dengan peningkatan jumlah epoch dalam proses prediksi. Namun, penambahan jumlah epoch juga mempengaruhi waktu komputasi yang diperlukan. Hasil RMSE terendah ditemukan pada saham emiten TINS, dengan nilai	Penelitian ini menggunakan algoritma LSTM dan GRU untuk melakukan peramalan harga

							RMSE sebesar 31.76 saat menggunakan 200 epoch, sedangkan nilai RMSE tertinggi terjadi pada saham emiten INCO, dengan nilai RMSE sebesar 139,67 saat menggunakan 50 epoch	
--	--	--	--	--	--	--	--	--

Penelitian yang sudah dilakukan menggunakan algoritma LSTM dan GRU mendapatkan performa yang sangat baik dalam melakukan prediksi pada data *time series*. Penelitian [13], [14], dan [20] dijadikan sebagai rujukan utama dalam mengerjakan penelitian ini. Penulis menggunakan metode-metode pada penelitian tersebut untuk dijadikan referensi dalam mengembangkan penelitian ini, terutama dalam mengoptimalkan model yang digunakan dengan melakukan skenario riset untuk mendapatkan model yang optimal dalam melakukan peramalan harga komoditas pangan di pasar tradisional Kabupaten Banyumas.

2.2 Landasan Teori

2.2.1 Peramalan

Peramalan merupakan sebuah ilmu untuk memperhitungkan suatu peristiwa yang akan terjadi di masa yang akan datang [24]. Peramalan juga merupakan disiplin ilmu yang digunakan untuk meramal atau memprediksi sesuatu berdasarkan data yang telah ada sebelumnya, dengan pengolahan data yang khusus. Peramalan dapat diterapkan dalam berbagai bidang ilmu dan industri [25]. Secara keseluruhan, peramalan adalah alat yang sangat berharga dalam membantu individu dan organisasi membuat keputusan yang lebih baik dan merencanakan masa depan dengan lebih baik berdasarkan data yang ada.

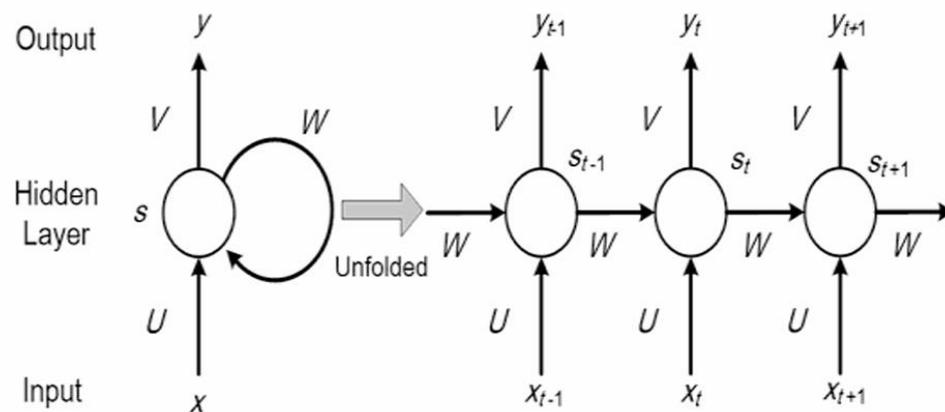
2.2.2 Deep Learning

Deep learning merupakan sub kelas dari machine learning yang memiliki performa jauh lebih baik untuk mengolah data yang tidak terstruktur [26]. Deep learning terdiri dari beberapa prosesor sederhana yang saling terhubung satu sama lainnya yang disebut dengan *neuron*. Setiap neuron akan menghasilkan sebuah runtutan aktivasi yang bernilai nyata. *Neuron* masukan akan diaktifkan melalui sensor yang diterima dari *environment*, lalu neuron-neuron lain akan diaktifkan oleh koneksi dari bobot neuron sebelumnya [27].

2.2.3 Recurrent Neural Network

RNN (Recurrent Neural Network) merupakan jenis jaringan saraf tiruan yang memiliki hubungan berulang atau umpan balik. Hal ini ditandai oleh adanya loop-loop koneksi balik, di mana jalur sinyal membentuk rangkaian

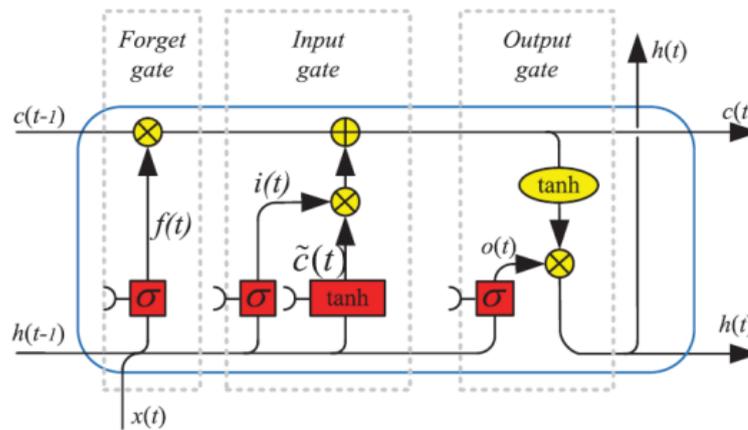
tertutup, memungkinkan informasi untuk bergerak dari neuron kembali ke dirinya sendiri atau ke neuron lain dalam rangkaian [28]. Setiap kali *input* dimasukkan dan menghasilkan *output*, hasil tersebut akan kembali menjadi *input* untuk diproses dalam lapisan tersembunyi atau *hidden layer*. Proses ini berulang, memungkinkan jaringan untuk menghasilkan output yang sesuai dengan target yang ditentukan [29]. Secara garis besar, RNN merupakan salah satu dari jenis jaringan saraf tiruan yang memakai rekurensi yang memanfaatkan data dari masa lalu [30].



Gambar 2. 1 Arsitektur Recurrent Neural Network [30]

2.2.4 Long Short Term Memory

Long Short Term Memory, atau LSTM, adalah salah satu penyempurnaan dari beberapa jenis jaringan saraf tiruan yang dapat digunakan untuk mengembangkan model data deret waktu [31]. Perbedaan utama antara LSTM (Long Short-Term Memory) dan RNN (Recurrent Neural Network) biasa terletak pada kapasitas LSTM untuk mengidentifikasi informasi yang perlu dihapus dan informasi yang harus tetap disimpan dalam sel memori. Kapasitas ini berasal dari sistem unit dasar LSTM yang berbeda dengan unit dasar RNN konvensional, dimana tiap-tiap unit dasar LSTM mempunyai sel memori dan unit pintu (*gate units*) [16].



Gambar 2. 2 Arsitektur Long Short Term Memory [32]

1. Forget Gate

Forget gate, yang direpresentasikan dengan fungsi sigmoid f_t , berperan dalam mendeteksi nilai dari h_{t-1} dan x_t , dan mengeluarkan nilai 0 atau 1 untuk tiap-tiap unsur dalam sel memori C_{t-1} . Informasi yang perlu diabaikan atau dilupakan ditunjukkan dengan nilai 0, sementara informasi yang perlu tetap ada atau diingat ditunjukkan dengan nilai 1 [16].

2. Input Gate

Gerbang ini juga merupakan fungsi sigmoid dan disimbolkan sebagai I_t , berperan dalam menentukan informasi yang akan diperbarui. Setelah input gate memutuskan elemen mana yang akan diperbarui, fungsi tangen hiperbolik (tanh) digunakan untuk menghasilkan vektor baru yang disebut \tilde{C}_t (cell update). Vektor \tilde{C}_t ini adalah hasil dari proses pembaruan informasi yang telah disaring oleh input gate [16].

3. Cell State

Proses berikutnya adalah memperbarui sel memori yang disimbolkan dengan C_{t-1} menjadi C_t . Untuk memperoleh nilai C_t , nilai dari forget gate (f_t) harus dikalikan dengan C_{t-1} , dan nilai dari *input gate* (I_t) dikalikan dengan vektor baru \tilde{C}_t . Setelah itu, dilakukan penjumlahan dari hasil dari kedua operasi perkalian tersebut dijumlahkan untuk menghasilkan nilai baru dari sel memori C_t . Proses ini memungkinkan LSTM untuk mengatur dan memperbarui

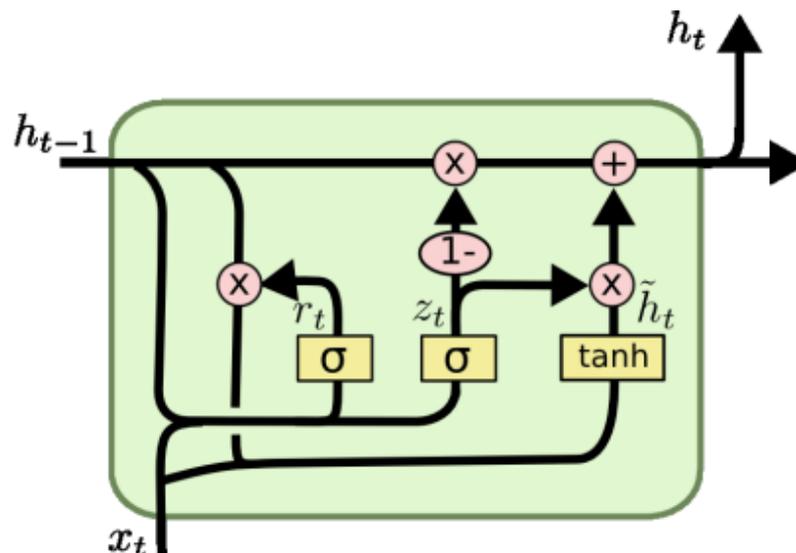
informasi dalam sel memori sesuai dengan keputusan yang diambil oleh *forget gate* dan *input gate* [16].

4. *Output Gate*

Output gate berfungsi untuk mengendalikan sejauh mana informasi dalam sel memori saat ini akan disampaikan sebagai output dari LSTM [32]. Dalam tahap ini, fungsi sigmoid yang disebut sebagai pintu keluar (o_t) akan dijalankan untuk memutuskan bagian-bagian dari sel memori yang akan menjadi output, sedangkan fungsi *tangen hiperbolik* (\tanh) akan memproses nilai sel memori (C_t) untuk menghasilkan nilai yang berada dalam rentang antara -1 dan 1. Untuk menetapkan output, hasil dari pintu kelura (o_t) dan nilai *tangen hiperbolik* (\tanh) akan dikalikan bersama, sehingga output LSTM dapat dihasilkan berdasarkan interaksi antara kedua nilai ini [16].

2.2.5 Gated Recurrent Network

Gated Recurrent Unit (GRU), yang merupakan perkembangan dari Jaringan Saraf Rekuren (RNN), telah diterapkan dalam berbagai penelitian terkait pemrosesan data, video, dan data deret waktu [33]. GRU memiliki struktur model yang lebih sederhana atau tidak terlalu kompleks seperti LSTM. GRU juga dapat menyelesaikan permasalahan yang seringkali muncul ketika kita menggunakan jaringan saraf rekuren (RNN), yaitu *vanishing gradient* [34].



Gambar 2. 3 Arsitektur Gated Recurrent Unit [14]

1. *Reset Gate*

Pada model GRU, *reset gate* menangani pekerjaan untuk menyaring sejauh mana data masa lalu yang akan dipakai dan menghilangkan data yang sudah tidak dibutuhkan [14].

2. *Update Gate*

Update gate di model GRU mempunyai sebuah peran yaitu untuk mengatur seberapa banyak informasi dari masa lalu yang perlu dipertahankan [35].

2.2.6 *Preprocessing*

Preprocessing adalah tahap penting dalam proses analisis data di mana data yang didapatkan dipersiapkan dengan baik sebelum diproses di model machine learning [36]. Pada *preprocessing* berbagai teknik dan metode digunakan untuk memastikan data dalam kondisi optimal untuk kemudian diolah lebih lanjut [37].

2.2.7 *Cubic Spline Interpolation*

Metode ini merupakan sebuah metode untuk melakukan interpolasi atau mengisi data yang kosong dengan membuat kurva halus yang melewati serangkaian titik data yang terdapat pada data. *Cubic spline interpolation* menghasilkan kurva yang dibentuk oleh serangkaian polinomial kubik yang terhubung pada data yang diketahui pada data. Tiap-tiap polinomial kubik ini berlaku pada dua titik data secara berturut-turut yang dirancang sedemikian rupa sehingga menghasilkan transisi yang halus di setiap titik data [38].

2.2.8 *Min-Max Scaler*

Metode ini merupakan sebuah metode untuk mengubah setiap nilai dalam dataset dengan rentang yang sudah ditentukan di awal, misalnya 0 sampai dengan 1. Metode ini dilakukan dengan mengurangi setiap nilai dalam dataset dengan nilai terkecil dalam keseluruhan dataset kemudian dibagi dengan selisih dari nilai terbesar dan terkecil dalam dataset [39]. Persamaan dari metode ini sebagai berikut :

$$X_{scale} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2.1)$$

Keterangan :

X_{scale}	= nilai <i>Min-Max Scaler</i>
X	= nilai data
X_{min}	= nilai terkecil dalam dataset
X_{max}	= nilai terbesar dalam dataset

2.2.9 Mean Squared Error

Metode ini merupakan metode untuk menghitung nilai kesalahan model dengan cara menjumlahkan semua nilai dari selisih antara nilai sebenarnya dan nilai hasil prediksi yang telah dikuadratkan, kemudian dibagi dengan jumlah periode atau banyaknya data yang dipakai untuk melakukan perhitungan [40]. Berikut adalah persamaan yang digunakan untuk menghitung nilai mse :

$$MSE = \frac{\sum(aktual - forecast)^2}{n} \quad (2.2)$$

Keterangan :

aktual	= nilai sebenarnya
forecast	= nilai prediksi model
n	= jumlah data

Metode ini memberikan penalti yang lebih besar untuk kesalahan yang besar karena nilai error dikuadratkan terlebih dahulu sebelum dihitung rata-ratanya. Hal ini sangat berguna dalam konteks data time series karena error besar dapat menunjukkan pola anomali atau ketidaksesuaian model dengan data [41].