

BAB II

TINJAUAN PUSTAKA DAN LANDASAN TEORI

2.1. Tinjauan Pustaka

Penelitian ini dilakukan untuk mencari model *ARCH/GARCH* terbaik dalam meramalkan harga saham Netflix. Dalam penelitian terdahulu dengan konteks yang sama menunjukkan bahwa metode *ARCH/GARCH* cocok diterapkan pada data volatilitas seperti harga saham. Menurut penelitian [18], model paling optimal untuk melakukan peramalan adalah model *GARCH* (1,1) yang memiliki nilai *RMSE* terkecil dengan persamaan *Conditional Mean dan Conditional Variance*.

Penelitian [14] menunjukkan bahwa model yang tepat untuk dijadikan model peramalan harga saham PT. Cowell Development adalah *ARCH* (1) yang memiliki nilai *AIC* dan *BIC* terkecil dengan nilai *MAPE* sebesar 0,043%. Penelitian lainnya [19] menunjukkan model *ARCH* (1) menghasilkan nilai *MAPE* 8,06% yang artinya model ini sudah cukup baik dalam meramalkan harga saham sektoral karena nilai *MAPE* kurang dari 10%. Penelitian [20] dalam meramalkan kinerja perbankan di Indonesia menghasilkan rata-rata standar deviasi model *ARIMA* sebesar 0,222794 dan rata-rata rasio standar deviasi model *ARCH-GARCH* sebesar 0,0289236. Pada penelitian [21] dalam meramalkan harga saham Netflix menggunakan *Recurrent Neural Network (RNN)* dan *Long Short Term Memory (LSTM)* menghasilkan *RMSE* sebesar 17,13325. Penelitian [22] saham Kimia Farma cocok dengan model *ARIMA* (0,1,1) dan diramalkan cenderung mengalami kenaikan sedangkan harga saham Netflix cocok menggunakan model *ARIMA* (1,1,1). Penelitian [23] dalam meramalkan harga cabai rawit yang sering mengalami fluktuasi menggunakan metode *ARIMA ARCH-GARCH* dengan *MAPE* kurang dari 15%.

Pada penelitian ini, metode evaluasi yang digunakan adalah *MAE*, *MAPE*, dan *RMSE*. Ketiga metode tersebut memiliki kelebihan yang dapat menjelaskan seberapa besar kesalahan atau *error* yang dihasilkan oleh model peramalan. Pada penelitian [24] yang bertujuan untuk membuktikan pengaruh pembulatan pada

RMSE dan *MAE* sebagai metrik evaluasi model menunjukkan bahwa pembulatan diperlukan dalam *preprocessing* peringkat yang diprediksi dan meningkatkan kinerja kualitas rekomendasi. Penelitian [25] membahas tentang perlunya prediksi yang akurat untuk mengembangkan model yang lebih baik sehingga dapat mengurangi risiko kerentanan dan *MAPE* adalah metode yang dapat digunakan.

Berdasarkan penelitian sebelumnya, metode *ARCH/GARCH* cocok untuk meramalkan harga saham terutama dalam menangani data yang memiliki heteroskedastisitas dan volatilitas. Secara keseluruhan, metode *ARCH/GARCH* memberikan hasil evaluasi yang cukup rendah dan dapat diandalkan dalam konteks peramalan harga saham. Metode evaluasi *RMSE*, *MAE*, dan *MAPE* dapat menjelaskan kesalahan atau *error* hasil peramalan untuk meningkatkan kinerja dan kualitas model. Tabel 2.1 menunjukkan penelitian-penelitian sebelumnya mengenai peramalan harga saham, peramalan saham Netflix, dan metode evaluasi *RMSE*, *MAE*, dan *MAPE*.

Tabel 2.1. Penelitian terdahulu

No	Judul Penelitian	Penulis	Masalah Penelitian	Metode	Hasil
1.	Perbandingan Akurasi Model <i>ARCH/GARCH</i> pada Peramlaan Harga Saham Berbantuan Matlab [18]	Sunarti, Scolastika Mariani, Sugiman	Bagaimana mendapatkan model peramalan yang akurat untuk memprediksi harga saham Unilever Indonesia Tbk. dengan menggunakan model <i>ARCH/GARCH</i> ?	<i>ARCH-GARCH</i>	RMSE <i>ARCH</i> (3) = 830,8 RMSE <i>GARCH</i> (1,1) = 795,4
2.	Estimasi Tingkat Inflasi Nasional Menggunakan <i>ARCH-GARCH</i> Filter Kalman [26]	Radisha Fanni Sianti, Sentot Didik Surjanto, dan Erna Apriliani	Bagaimana cara kerja Filter Kalman dalam memperbaiki performa model <i>ARCH</i> (1)?		MAPE yang sebelumnya sangat besar, yaitu 34,662% menjadi 1,0035%
3.	Perbandingan Model <i>ARCH</i> (1) dan Model <i>GARCH</i> (1,1) pada Peramalan Runtun Waktu (Studi Kasus pada PT. Cowell Development Tbk) [14]	Rosna Ningsih Bilondatu, 2018	Mencari model peramalan yang mampu memberikan prediksi yang akurat terhadap pergerakan harga saham PT. Cowell Development Tbk?	<i>ARCH-GARCH</i>	<i>MAPE</i> = 0,043%.
4.	<i>Netflix Stock Price Trend Prediction Using Recurrent Neural Network</i> [21]	Irani Hoeronis, 2022	Bagaimana cara meramalkan nilai saham Netflix selama lima tahun terakhir melalui pendekatan deret waktu?	<i>RNN</i>	<i>loss function</i> = 0,0012 <i>RMSE</i> = 17,13325.
5.	Prediksi Harga Saham Kimia Farma dan Saham Netflix di Era <i>New Normal</i> Menggunakan Model <i>Autoregressive Integrated Moving Average (ARIMA)</i> [22]	Gerral Mokosolang, Yohanes A. R. Langi, Mans L. Mananohas, 2022	Bagaimana menggunakan model <i>ARIMA</i> untuk melakukan peramalan harga saham PT. Kimia Farma, Tbk dan Netflix, Inc?	<i>ARIMA</i>	Saham Kimia Farma menunjukkan tren kenaikan berdasarkan model <i>ARIMA</i> (0,1,1), sementara model <i>ARIMA</i> (1,1,1) cocok dalam memprediksi harga saham Netflix..
6.	Penerapan Metode <i>ARCH/GARCH</i> Dalam Peramalan Indeks Harga	Ari Pani Desvina, Nadyatul Rahmah,	Bagaimana penanganan eteroskedastisitas dalam data <i>time</i>	<i>ARCH-GARCH</i>	MAPE = 8,06%.

No	Judul Penelitian	Penulis	Masalah Penelitian	Metode	Hasil
	Saham Sektoral [19]	2016	<i>series</i> , di mana varians dari Data bersifat dinamis dan mengalami fluktuasi dari satu periode ke periode berikutnya?		
7.	Peramalan Kinerja Perbankan Indonesia dengan <i>ARCH-GARCH</i> [20]	Ahmad Sonjaya, 2021	Apa model prediksi yang akurat terkait dengan kinerja keuangan bank?	<i>ARCH-GARCH</i>	σ ARIMA = 0,222794, σ ARCH-GARCH = 0,0289236
8.	Peramalan Harga Cabai Dengan Metode <i>Arima ArchGarch</i> Dan <i>Single Moving Average</i> Di Kota Semarang [23]	Kartini Puspatika, Yupie Kusumawati, 2018	Apa metode yang sesuai untuk menangani ketidakstabilan harga cabai dan fluktuasi tinggi yang menyertainya?	<i>Arima ArchGarch</i> Dan <i>Single Moving Average</i>	MAPE AAG = 0,289% dan MAD = 6764,76. MAPE SMA = 0,340% dan MAD = 8308,28.
9.	<i>Analysis of the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE) in Assessing Rounding Model</i> [24]	Weijie Wang, Yanmin Lu, 2018	Bagaimana dan mengapa pembulatan mempengaruhi nilai MAE dan RMSE?	<i>Collaborative Filtering (CF)</i>	Pembulatan diperlukan dalam pasca-pemrosesan peringkat yang diprediksi dan meningkatkan kinerja dan kualitas rekomendasi
10.	<i>A Systematic Review of Statistical and Machine Learning Methods for Electrical Power Forecasting with Reported MAPE Score</i> [25]	Eliana Vivas, Héctor Allende-Cid, and Rodrigo Salas, 2020	Apa model yang dapat mencapai presisi terbaik dalam meramalkan konsumsi listrik dalam konteks sistem tenaga listrik?	<i>Machine Learning (ML)</i> dan <i>Statistical or Mathematical</i>	Model peramalan terbaik untuk energi listrik adalah model hybrid, model multivariate dependency, dan model berbasis machine learning.

2.2. Landasan Teori

2.2.1. Investasi dan Saham

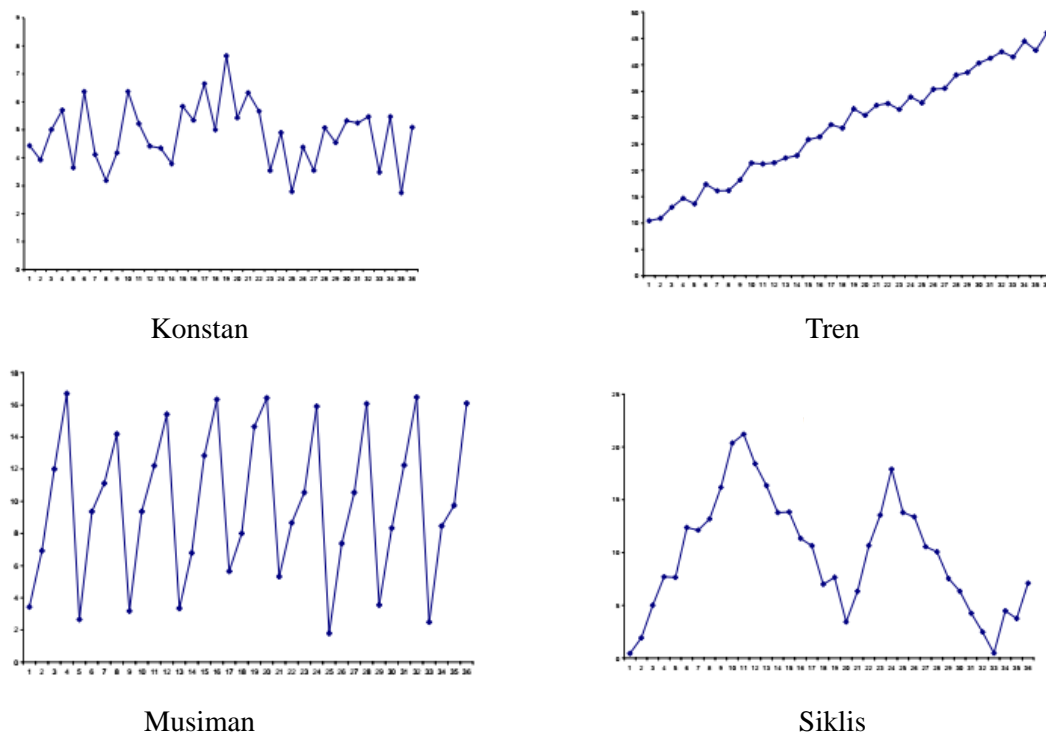
Investasi telah menjadi hal yang penting bagi sebagian orang karena sangat membantu dalam mempersiapkan kebutuhan masa depan, terutama saat menghadapi masa pensiun yang membatasi pemasukan mereka. Menabung secara rutin sering dijadikan opsi tetapi dengan semakin meningkatnya inflasi yang sering terjadi di negara berkembang seperti Indonesia, dapat mengurangi daya beli uang dalam jangka waktu yang lebih lama dan tak menentu [27]. Tidak sedikit orang yang mulai mempertimbangkan investasi sebagai alternatif menabung. Terdapat dua opsi investasi, yaitu aset nyata (tanah, bangunan, dan mesin) dan aset keuangan yang dikenal sebagai sekuritas (obligasi, saham, dan reksa dana). Investasi aset keuangan dapat memberikan manfaat dari pasar saham dan investasi pasar uang bahkan bagi investor dengan dana terbatas melalui investasi reksa dana.

Dalam bukunya, Andy Porman Tambuhan menggambarkan saham sebagai bentuk konfirmasi atas partisipasi pendanaan perusahaan dengan pembelian saham oleh individu yang berarti memberikan modal atau dana yang dapat digunakan oleh manajemen untuk mendukung kegiatan operasional perusahaan [28]. Saham merupakan sumber dana yang berharga bagi perusahaan. Semakin banyak penanam saham pada sebuah perusahaan maka semakin besar potensi perusahaan untuk berkembang. Namun, keuntungan yang didapat dari saham juga dibarengi oleh risiko kerugian seperti penurunan harga saham yang drastis. Salah satu pencegahan yang dapat dilakukan atas risiko yang bisa saja terjadi adalah dengan melakukan peramalan harga saham agar mendapat keuntungan dan menghindari kerugian.

2.2.2. Deret Waktu (*Time Series*)

Time series atau deret waktu didefinisikan sebagai seperangkat pengamatan kuantitatif yang disusun dalam urutan kronologis yang selalu digunakan di bidang ekonometrika [29]. Deret waktu adalah serangkaian data yang disusun secaraurut dan umumnya titik waktu memiliki jarak yang sama. Tujuan utama dari analisis

deret waktu adalah untuk memprediksi nilai masa depan dari suatu parameter berdasarkan data masa lalu [30]. Dalam buku yang ditulis oleh Hanke, J. E. Dan Wichers, D. W. pada tahun 2005, data deret waktu memiliki empat pola data, yaitu konstan, tren, musiman, dan siklis [31]. Pola konstan memiliki peristiwa acak yang tak terduga tetapi berpengaruh pada perubahan atau fluktuasi runtun waktu. Pola tren menunjukkan kecenderungan arah data dalam jangka panjang dan dapat berupa peningkatan atau penurunan. Pola musiman adalah fluktuasi (perubahan nilai) yang terjadi secara berkala dengan pola tertentu dalam rentang waktu satu tahun, seperti hari, minggu, bulan, kuartal, atau triwulan. Pola siklik ada pada data yang dipengaruhi oleh fluktuasi jangka panjang yang berkaitan dengan siklus ekonomi dan umumnya dipengaruhi oleh faktor-faktor eksternal. Perbedaan pola dalam data deret waktu dapat diamati pada Gambar 2.1 [32].



Gambar 2.1. Pola data deret waktu

2.2.3. Peramalan (*Forecasting*)

Peramalan adalah kegiatan yang dilakukan untuk mendapatkan pengelihatan atas sesuatu atau suatu nilai di masa depan. Dasar dari teori peramalan adalah keyakinan bahwa informasi yang tersedia saat ini serta catatan masa lampau dapat

dimanfaatkan untuk membuat estimasi terhadap kejadian di masa yang akan datang [33]. Nasution dan Prasetyawan menjelaskan peramalan dalam bukunya sebagai proses untuk mengestimasi kebutuhan baik dalam jumlah, mutu, jangka waktu, maupun lokasi dengan tujuan memenuhi permintaan atas barang atau layanan di masa yang akan datang [34]. Menurut Herjanto [35], peramalan berdasarkan periode waktu dibagi menjadi tiga jenis, yaitu:

- a. Peramalan dengan periode kurang dari tiga bulan dikenal sebagai peramalan jangka pendek. Peramalan ini biasa digunakan untuk merencanakan pembelian material, mengatur jadwal kerja, dan menetapkan tugas karyawan.
- b. Peramalan dengan periode antara 3 hingga 18 bulan yang disebut peramalan jangka menengah. Jangka waktu peramalan ini biasa digunakan untuk merencanakan penjualan, produksi, dan penggunaan tenaga kerja yang tidak permanen.
- c. Peramalan yang melampaui 18 bulan disebut sebagai peramalan jangka panjang. Penggunaan peramalan jangka panjang mencakup meramalkan kondisi ekonomi, perencanaan ekspansi lokasi fasilitas, alokasi dana investasi jangka panjang, serta inisiatif penelitian dan pengembangan.

Peramalan saham adalah kegiatan penting dalam bursa saham di dunia yang berkaitan dengan prediksi yang akurat baik dari tren dan/atau harga saham agar mendapat keuntungan yang lebih tinggi melalui perdagangan (*trading*). Namun, untuk mendapatkan prediksi yang akurat merupakan tugas yang menantang dan cukup sulit karena sifat bursa saham yang nonlinear dan fluktuatif. Sebagai pilihan intuitif, banyak model statistik dikembangkan untuk memperkirakan harga saham menggunakan data masa lalu dan sekarang seperti model dari metode *time series* [36].

2.2.4. ARIMA

Metode *Autoregressive Integrated Moving Average (ARIMA)* umum digunakan dalam menyesuaikan data deret waktu untuk membantu mendapatkan pemahaman yang lebih baik tentang data atau untuk membuat prediksi. Model *ARIMA* digunakan untuk memodelkan data deret waktu yang menunjukkan

perilaku stasioner atau yang dapat dibuat stasioner dengan *differencing* yang dinotasikan sebagai *ARIMA*(p, d, q) dengan penjelasan sebagai berikut:

- a) *Autoregressive (AR)* adalah bagian yang menjelaskan bahwa nilai saat ini dari deret waktu (Y_t) bergantung pada nilai-nilai sebelumnya. Model *AR*(p) dinyatakan dalam persamaan (2.1):

$$Y_t = \alpha_0 + \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \varepsilon_t \quad (2.1)$$

Keterangan:

- α_0 : Konstanta
 $\alpha_1, \alpha_2, \dots, \alpha_p$: Koefisien *AR*
 ε_t : Residual pada waktu t

- b) *Differencing (I)* adalah proses mengurangi deret waktu dengan nilai sebelumnya untuk membuat data menjadi stasioner. Deret waktu yang didiferensiasi d kali akan digunakan dalam model *ARIMA*.

- c) *Moving Average (MA)* adalah bagian yang menjelaskan bahwa ilai saat ini dari deret waktu bergantung pada *error* residual dari periode sebelumnya. Model *MA*(q) dinyatakan pada persamaan (2.2):

$$Y_t = \mu + \varepsilon_t + \alpha_1 \varepsilon_{t-1} + \alpha_2 \varepsilon_{t-2} + \dots + \alpha_q \varepsilon_{t-q} \quad (2.2)$$

Keterangan:

- μ : Rata-rata deret waktu
 $\alpha_1, \alpha_2, \dots, \alpha_q$: Koefisien *MA*
 ε_t : Residual pada waktu t

Model *ARIMA* menggabungkan ketiga komponen tersebut untuk menangkap pola dalam data deret waktu baik yang bersifat autoregresif, *differenced*, maupun *moving average* yang dinyatakan dalam persamaan (2.3):

$$Y_t = \alpha_0 + \alpha_1 Y_{t-1} + \dots + \alpha_p Y_{t-p} + \varepsilon_t - \beta_1 \varepsilon_{t-1} - \dots - \beta_p \varepsilon_{t-p} \quad (2.3)$$

Keterangan:

- α_0 : konstanta
 Y_t : nilai aktual pada waktu t
 Y_{t-1} : nilai sebelumnya pada waktu t

2.2.5. ARCH/GARCH

Model ini pertama kali dikemukakan oleh Engle pada tahun 1982. *ARCH* adalah model yang cocok untuk permasalahan volatilitas dan data ekonomi terutama apabila residual dari data *time series* dipengaruhi oleh variabel independen dan nilai residual variabel yang diteliti [37]. Artinya, ada kemungkinan bahwa variabel lain yang tidak dimasukkan ke dalam model utama (misalnya, faktor ekonomi atau keuangan lainnya) dapat mempengaruhi sisa-sisa atau kekurangan dari model yang digunakan. Dengan menggunakan model *ARCH*, pola heteroskedastisitas yang tersembunyi dalam data dapat ditangkap, di mana variabilitas kondisional dari data tidak hanya bergantung pada nilai-nilai sebelumnya tetapi juga mungkin dipengaruhi oleh faktor-faktor eksternal atau variabel independen yang tidak dimodelkan secara eksplisit. Model ini dirancang untuk mengatasi heteroskedastisitas kondisional, yaitu fluktuasi (perubahan nilai atau harga) volatilitas yang bervariasi seiring waktu. Volatilitas adalah ukuran peningkatan atau penurunan harga suatu aset atau instrumen keuangan dalam suatu periode waktu tertentu [38]. Fluktuasi volatilitas merujuk pada perubahan yang tidak stabil atau tidak teratur dalam tingkat atau ukuran volatilitas dari waktu ke waktu. Dalam metode *ARCH*, varian suatu data bergantung pada tingkat volatilitas di periode sebelumnya sehingga fluktuasi besar yang terjadi sebelumnya akan mempengaruhi fluktuasi di periode berikutnya.

Model *ARCH* kemudian dikembangkan dan dimodifikasi oleh Bollerslev pada tahun 1986 menjadi *Generalized Autoregressive Conditional Heteroscedasticity (GARCH)*. Model ini memiliki struktur yang lebih fleksibel dan dapat mengatasi masalah heteroskedastisitas kondisional dengan lebih baik [39]. *GARCH* menggabungkan komponen autoregresif dan *moving average* dalam model varians sehingga memungkinkan untuk memodelkan hubungan yang lebih kompleks antara volatilitas di berbagai periode waktu. Secara sistematis, model *ARCH* dapat dijelaskan pada persamaan (2.4):

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 \quad (2.4)$$

Keterangan:

σ_t^2 : varians volatilitas pada waktu t

ε_t^2 : residual atau sisa pada waktu t yang dikuadratkan

$\alpha_0, \alpha_1, \dots, \alpha_i$: parameter model yang diestimasi

Dalam konteks model *ARCH*, residual digunakan untuk mengetahui apakah model dapat memprediksi nilai yang sebenarnya dengan baik sedangkan *error* digunakan untuk mengetahui apakah model dapat memprediksi nilai sebenarnya dalam data populasi. Pada uji *white noise*, residual digunakan untuk mengetahui apakah residual memiliki distribusi yang acak dan tidak terdapat pola tertentu.

Model *GARCH* adalah pengembangan dari model *ARCH* dengan tambahan komponen yang mempertimbangkan fluktuasi pada varians sebelumnya, yaitu perubahan dalam nilai varians dari satu periode waktu ke periode waktu berikutnya yang dipengaruhi oleh nilai varians pada periode-periode sebelumnya dalam seri waktu tersebut. Rumus umumnya dinyatakan dalam persamaan (2.5):

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (2.5)$$

Keterangan:

σ_t^2 : varians volatilitas pada waktu t

ε_t^2 : residual atau sisa pada waktu t yang dikuadratkan

$\alpha_0, \alpha_1, \dots, \alpha_i$: parameter pengendali kontribusi fluktuasi dari residual sebelumnya

$\beta_0, \beta_1, \dots, \beta_i$: parameter pengendali kontribusi fluktuasi dari varians sebelumnya

Jika uji heteroskedastisitas signifikan pada suatu deret waktu maka model *ARCH* dapat diestimasi dan variabilitas atau varians (σ_t) yang diperoleh diestimasi berdasarkan informasi masa lalu. Dalam praktiknya, seringkali didapati jumlah *lag* yang cukup banyak sehingga jumlah parameter yang diestimasi dalam model juga cukup banyak. Apabila hal tersebut terjadi maka dapat menggunakan model *GARCH*. Pemilihan model peramalan perlu diperhatikan agar mendapatkan model terbaik.

2.2.6. Uji Signifikansi Parameter Model

Uji signifikansi parameter adalah prosedur statistik yang digunakan untuk mengetahui apakah suatu parameter dalam model peramalan memiliki pengaruh signifikan terhadap variabel independen, yaitu parameter memiliki efek nyata dan tidak disebabkan oleh kebetulan atau variabilitas acak. Hal ini menunjukkan bahwa nilai parameter tersebut berbeda dari nol yang artinya parameter benar-benar mempengaruhi variabel independen dalam model [40]. Uji signifikansi dilakukan menggunakan uji t dengan rumus sebagai yang dinyatakan pada persamaan (2.6):

$$t = \frac{\hat{\vartheta}_1}{\sqrt{\text{Var}(\hat{\vartheta}_1)}} \quad (2.6)$$

Keterangan:

$\hat{\vartheta}_1$: Estimasi parameter yang akan diuji

$\text{Var}(\hat{\vartheta}_1)$: Varian estimasi parameter yang akan diuji

2.2.7. Metriks Evaluasi

Melakukan evaluasi pada hasil peramalan merupakan hal yang peting dalam memprediksi suatu nilai di masa depan [41]. Dalam studi ini, beberapa metode evaluasi digunakan untuk mengukur tingkat ketepatan hasil peramalan, diantaranya:

- a. *Mean Absolute Error (MAE)* yang merupakan nilai rata-rata dari selisih mutlak antara prediksi dan nilai sebenarnya. *MAE* digunakan untuk mengukur sejauh mana rata-rata kesalahan tanpa mempertimbangkan apakah kesalahan tersebut melebihi atau kurang dari nilai sebenarnya. *MAE* dihitung dengan menjumlahkan kesalahan absolut dan membaginya dengan jumlah pengamatan. Hasil *MAE* yang lebih rendah menandakan bahwa model tersebut memiliki kemampuan yang lebih baik dalam meramalkan nilai sebenarnya. Rumus umum *MAE* dinyatakan pada persamaan (2.5):

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (2.7)$$

Keterangan:

n : Jumlah observasi

Y_i : Nilai sebenarnya ke-i

\hat{Y}_i : Nilai prediksi ke-i

- b. *Mean Absolute Percentage Error (MAPE)* merupakan nilai rata-rata dari selisih persentase mutlak antara nilai yang diprediksi dan nilai yang sebenarnya. *MAPE* digunakan untuk mengukur rata-rata persentase perbedaan antara prediksi dan nilai aktual. *MAPE* dihitung dengan menjumlahkan persentase kesalahan absolut dan membaginya dengan jumlah pengamatan. Rumus umum *MAPE* dinyatakan pada persamaan (2.6):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{Y_i} \times 100\% \quad (2.8)$$

Keterangan:

n : Jumlah observasi

Y_i : Nilai sebenarnya ke-i

\hat{Y}_i : Nilai prediksi ke-i

- c. *Root Mean Squared Error (RMSE)* adalah nilai akar dari rata-rata dari perbedaan kuadrat antara prediksi dan nilai sebenarnya. *RMSE* mengukur akar kuadrat dari kesalahan kuadrat rata-rata, memberikan bobot lebih pada kesalahan yang lebih besar. *RMSE* dihitung dengan mengekstrak akar kuadrat dari nilai rata-rata dari kuadrat kesalahan. Rumus umum *RMSE* dinyatakan pada persamaan (2.7):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (2.9)$$

Keterangan:

n : Jumlah observasi

Y_i : Nilai sebenarnya ke-i

\hat{Y}_i : Nilai prediksi ke-i