

BAB II

LANDASAN TEORI

A. Deskripsi Teori

1. Peramalan (*Forecasting*)

a. Pengertian dan dasar konsep peramalan

Peramalan didefinisikan sebagai *Forecasting is the art of specifying meaningful information about the future*" (Nurulita, 2010). Disisi lain, (Jacobs dan Aquilano, 2004) yang dikutip oleh (Oktavia, 2022) menggambarkan peramalan sebagai upaya untuk memprediksi keadaan masa depan dengan menggunakan data masa lalu dari sebuah variabel atau kumpulan variabel.

Peramalan adalah bagian penting dari setiap bisnis karena dapat menjadi acuan bagi manajemen saat membuat keputusan penting. Peramalan dapat menjadi dasar bagi perencanaan perusahaan baik jangka pendek maupun jangka panjang.

Dalam sistem persediaan dan manajemen produksi, teknik peramalan digunakan secara luas untuk melihat perubahan yang sering terjadi di beberapa bagian. Misalnya, perencanaan keuangan, pemasaran, analisis investasi, perencanaan distribusi, dan kontrol kualitas dan proses (Tjiptadi, 2008).

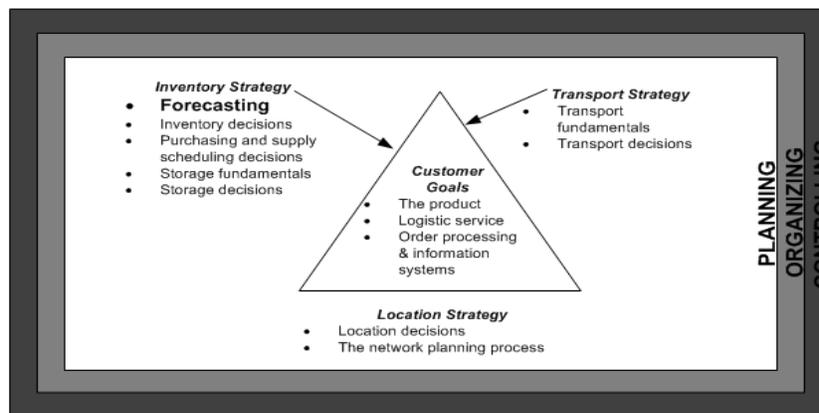
Peramalan adalah bagian dari proses pengambilan keputusan. Proses pengambilan keputusan seharusnya mengambil keputusan pada sesuatu yang telah dibuat berdasarkan hubungan antara variabel yang ada dan kemampuan untuk memprediksi elemen yang tidak dapat dikendalikan. Dengan demikian, sistem manajemen yang berfungsi untuk perencanaan dan pengendalian operasi menggunakan fungsi peramalan menjadi lebih jelas. Berikut adalah contoh penggunaan peramalan dalam suatu perusahaan manufaktur (Nafitri, 2010):

- 1) Dalam mengelola persediaan atau pengadaan komponen, penting untuk memahami jumlah kebutuhan masing-masing komponen guna menentukan ukuran lot yang tepat dalam proses pengadaan.
- 2) Perencanaan produksi melibatkan penyusunan jadwal untuk lini produksi berdasarkan perkiraan permintaan dan jumlah unit yang akan terjual di periode

mendatang. Proses peramalan ini bertujuan untuk memprediksi jumlah produk jadi yang dibutuhkan, namun juga dapat diubah ke dalam jumlah barang setengah jadi, komponen, bahan baku, tenaga kerja, dan elemen lainnya sehingga keseluruhan sistem manufaktur dapat diatur dengan baik.

- 3) **Perencanaan Keuangan (*Financial Planning*)**. Manajer keuangan akan memantau arus kas perusahaan untuk memproyeksikan jumlah aset dan modal yang tersedia serta memperkirakan kapan arus kas akan meningkat atau menurun seiring berjalannya waktu. Ini memberikan informasi penting bagi proses pengambilan keputusan.
- 4) **Penjadwalan Tenaga Kerja (*Staff Scheduling*)**. Dengan memproyeksikan jumlah produk yang akan diproduksi, manajer dapat merencanakan jumlah lini produksi, tenaga kerja, dan peralatan yang diperlukan secara lebih efisien.
- 5) **Perencanaan Fasilitas (*Facilities Planning*)**. Keputusan terkait pengembangan fasilitas baru perlu dipertimbangkan dalam perencanaan jangka panjang berdasarkan perkiraan kebutuhan masa depan atau kondisi saat ini. Hal ini diperlukan untuk merancang fasilitas dan memperkirakan investasi yang dibutuhkan.
- 6) **Pengendalian Proses (*Process Control*)**. Peramalan memainkan peran penting dalam pengendalian proses. Dengan memantau variabel-variabel utama dalam proses dan memproyeksikan perilaku proses di masa mendatang, memungkinkan penentuan waktu optimal serta tindakan pengendalian yang sesuai.

Gambar 2. 1 Peramalan dalam Suatu Strategi Bisnis



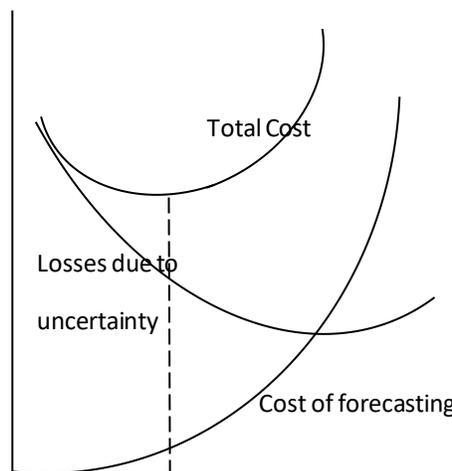
(Sumber: (Memon, 2017))

Tujuan peramalan adalah untuk mengurangi risiko dalam pengambilan keputusan. Meskipun hasil peramalan sering kali tidak sepenuhnya akurat, tingkat kesalahan peramalan (*forecast errors*) dipengaruhi oleh metode peramalan yang digunakan. Dengan memasukkan berbagai aspek dalam proses peramalan, tingkat akurasi seharusnya dapat ditingkatkan, sehingga mengurangi ketidakpastian dalam pengambilan keputusan berdasarkan hasil peramalan tersebut (Memon, 2017).

Konsep ini ditunjukkan dalam gambar 2.1, di mana seiring meningkatnya biaya yang dikeluarkan untuk peramalan, risiko (atau ketidakpastian) cenderung menurun. Pada titik tertentu, biaya peramalan akan mencapai puncaknya, dan nilai tambah dari peramalan mulai menurun. Model konseptual pada gambar 2.1 ini didasarkan pada asumsi bahwa nilai marginal dari peramalan mengalami penurunan. Dalam beberapa situasi, menambahkan lebih banyak variabel ke dalam proses peramalan mungkin hanya berdampak kecil, namun hal ini masih dapat membantu mengurangi kesalahan peramalan.

Karena peramalan tidak sepenuhnya mampu menghilangkan risiko, maka diperlukan proses pengambilan keputusan yang secara eksplisit mempertimbangkan ketidakpastian yang dihasilkan dari kesalahan peramalan (*forecast error*). Konsep peramalan ini dapat dijelaskan melalui persamaan berikut:

Gambar 2. 2 Trade-Off Peramalan



(Sumber: Nurulita, 2010)

Secara ideal, proses peramalan harus menghasilkan prediksi yang menggambarkan probabilitas distribusi variabel yang dapat diperkirakan. Namun, peramalan tidak hanya berhenti pada tahap tersebut. Peramalan merupakan bagian dari sistem manajemen yang lebih besar dan berfungsi sebagai subsistem yang berinteraksi dengan komponen-komponen lain dalam keseluruhan sistem, yang pada gilirannya mempengaruhi kinerja secara keseluruhan.

b. Prinsip Peramalan

Peramalan memiliki empat karakteristik atau prinsip dasar. Dengan memahami prinsip-prinsip ini dapat membantu menghasilkan peramalan yang lebih efektif (Arnold et al., 2014).

- 1) Peramalan sering kali tidak akurat. Hal ini dikarenakan peramalan berusaha memprediksi masa depan yang belum pasti, dan sering kali mengandung kesalahan dalam asumsi atau perkiraan. Kesalahan (*error*) ini harus diperkirakan, karena tidak dapat dihindari.
- 2) Setiap peramalan seharusnya mencakup estimasi kesalahan (*error*). Karena peramalan pasti mengandung kesalahan, pertanyaan yang perlu diajukan adalah “seberapa besar kesalahan tersebut?”. Estimasi kesalahan dalam peramalan harus dapat diukur, misalnya dengan tingkat kepercayaan, yang bisa berupa persentase (*plus* atau *minus*) untuk menunjukkan rentang nilai minimum dan maksimum dari peramalan.
- 3) Peramalan cenderung lebih akurat ketika diterapkan pada kelompok atau grup. Perilaku dari item individual dalam suatu grup bisa bersifat acak, meskipun grup tersebut berada dalam kondisi stabil. Sebagai contoh, meramalkan dengan tepat hasil seorang murid dalam kelas lebih sulit dibandingkan dengan meramalkan rata-rata keseluruhan kelas. Dengan kata lain, peramalan lebih tepat ketika dilakukan pada kelompok atau grup daripada pada item individual.
- 4) Peramalan cenderung lebih tepat untuk periode yang lebih pendek. Semakin jauh waktu yang diramalkan, semakin besar ketidakpastian yang terlibat. Sebagian besar orang merasa lebih yakin memprediksi apa yang akan mereka lakukan dalam waktu dekat, seperti minggu depan, daripada mencoba meramalkan apa yang akan terjadi setahun mendatang. Demikian juga, bagi perusahaan, memprediksi permintaan

jangka pendek lebih mudah dilakukan dibandingkan dengan peramalan untuk jangka panjang.

c. Metode Peramalan

Menurut (Makridakis et al., 2009), terdapat dua pendekatan dalam peramalan, yaitu metode kualitatif dan kuantitatif.

- 1) Teknik peramalan kualitatif lebih mengutamakan penilaian dan intuisi manusia dalam proses peramalan, sehingga data historis tidak dianggap terlalu penting. Dengan kata lain, metode ini bergantung lebih pada pertimbangan dan insting manusia daripada pengolahan data masa lalu.
- 2) Teknik peramalan kuantitatif sangat bergantung pada data historis yang tersedia. Teknik ini umumnya dibagi menjadi dua kategori: teknik statistik dan teknik deterministik.
 - a. Teknik statistik fokus pada pola, perubahan pola, dan faktor gangguan yang disebabkan oleh pengaruh acak. Beberapa metode dalam kategori ini meliputi teknik smoothing, dekomposisi, dan model Box-Jenkins.
 - b. Teknik deterministik berfokus pada identifikasi dan penentuan hubungan antara variabel yang diperkirakan dengan variabel lain yang dapat mempengaruhinya. Teknik dalam kategori ini mencakup regresi sederhana, regresi berganda, autoregresi, dan model input-output.

Pendekatan dalam teknik peramalan kuantitatif terdiri dari tiga jenis, menurut (Makridakis et al., 2009), yaitu:

1. Analisis Deret Waktu (*Time Series Analysis*)

Metode ini menggunakan data deret waktu sebagai dasar peramalan. Data historis yang ada digunakan untuk mengidentifikasi pola yang diperlukan dalam memilih metode peramalan yang tepat. Beberapa metode yang termasuk dalam pendekatan ini antara lain moving average, metode Winter, dekomposisi, exponential smoothing, ARIMAX (*Autoregressive Integrated Moving Average With Variable Exogenous*), Kalman Filter, dan metode Bayesian.

2. Analisis Kausal (*Causal Methods*)

Metode ini berfokus pada hubungan sebab-akibat, dengan tujuan meramalkan keadaan masa depan dengan mengidentifikasi dan mengukur pengaruh beberapa variabel independen terhadap variabel dependen yang akan diprediksi.

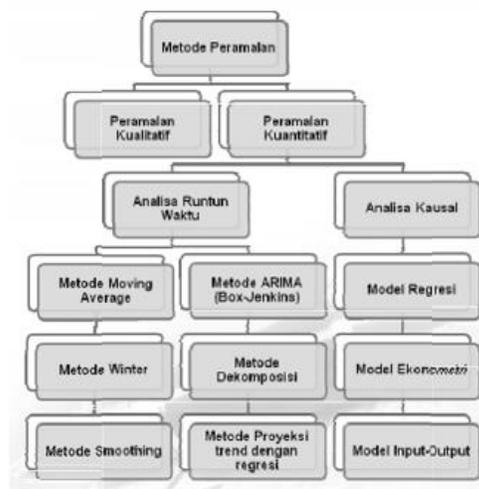
Ada dua metode yang umum digunakan dalam analisis kausal:

- a) Metode regresi dan korelasi, yang menggunakan teknik kuadrat terkecil (*least square*) dan variabel dalam rumus matematisnya, sering digunakan untuk peramalan jangka pendek. Contohnya adalah meramalkan hubungan antara jumlah kredit dengan giro, deposito, dan tabungan masyarakat, atau memprediksi penjualan produk berdasarkan harga.
- b) Metode input-output, biasanya digunakan dalam perencanaan ekonomi nasional jangka panjang. Contohnya adalah meramalkan pertumbuhan ekonomi, seperti PDB (produk domestik bruto), untuk beberapa tahun mendatang (5-10 tahun).

3. Analisis Ekonometri (*Simulation Analysis*)

Metode ekonometri menggunakan persamaan regresi yang dihitung secara simultan. Teknik ini banyak digunakan dalam perencanaan ekonomi baik untuk jangka pendek maupun jangka panjang. Salah satu contohnya adalah meramalkan indikator moneter untuk beberapa tahun mendatang, seperti yang sering dilakukan oleh Bank Indonesia (BI) setiap tahunnya.

Gambar 2. 3 Metode-metode Peramalan



(Sumber: Nafitri, 2010)

c. Tahapan Peramalan

Secara ringkas, terdapat tiga tahapan utama dalam merancang suatu metode peramalan, yaitu:

- 1) Menganalisis data masa lalu. Langkah ini bertujuan untuk memahami pola yang terdapat dalam data tersebut.
- 2) Memilih metode yang sesuai. Berbagai metode tersedia, masing-masing dengan kegunaannya. Setiap metode dapat menghasilkan hasil prediksi yang berbeda meskipun menggunakan data yang sama. Secara umum, metode yang efektif adalah yang menghasilkan selisih (*error*) terkecil antara prediksi dan kenyataan.
- 3) Melakukan transformasi data masa lalu menggunakan metode yang dipilih. Jika diperlukan, perubahan pada data dapat dilakukan sesuai kebutuhan.

Dalam penelitian ini, metode peramalan yang digunakan adalah pendekatan analisis deret waktu. Model yang diterapkan adalah *Autoregressive Integrated Moving Average with Variable Exogenous* (ARIMAX), yang dikembangkan oleh George E. P. Box dan Gwilym M. Jenkins, yang juga dikenal dengan nama Model Box-Jenkins (Box et al., 2016).

2. Analisis Deret Waktu (*Time Series Analysis*)

a. Definisi

Analisis deret waktu adalah metode peramalan yang menggunakan data deret waktu sebagai dasar untuk meramalkan, dengan memanfaatkan data historis yang ada untuk mengidentifikasi pola yang dibutuhkan dalam memilih metode peramalan yang tepat (Makridakis et al., 1984).

Pendekatan ini berusaha untuk memahami dan menjelaskan mekanisme tertentu, meramalkan nilai di masa depan dengan asumsi bahwa data masa lalu dapat memproyeksikan masa depan, serta mengoptimalkan sistem kendali (Iriawan, 2006). Tujuannya adalah untuk memodelkan data yang sudah ada, sehingga memungkinkan untuk memprediksi data yang akan datang yang masih belum diketahui.

Ciri-ciri dari analisis deret waktu yang menonjol adalah bahwa urutan observasi pada suatu variabel diperlakukan sebagai hasil dari variabel acak yang terdistribusi bersama. Artinya, kita menganggap adanya fungsi probabilitas yang menghubungkan variabel acak tersebut.

b. Konsep Dasar dan Persamaan Waktu

Analisis deret waktu diperkenalkan oleh (Box et al., 2016) melalui buku mereka *Time Series Analysis: Forecasting and Control*. Sejak saat itu, metode time series berkembang pesat. Konsep dasar dari time series adalah bahwa pengamatan saat ini (z_t) dipengaruhi oleh satu atau beberapa pengamatan sebelumnya (z_{t-k}). Dengan kata lain, model time series dibangun berdasarkan adanya korelasi (dependensi) antar pengamatan dalam deret waktu. Untuk mengidentifikasi adanya dependensi antar pengamatan, dilakukan uji korelasi antar pengamatan yang dikenal dengan fungsi autokorelasi (ACF) (Montgomery et al., 2008).

Dalam konteks deret waktu, suatu pengamatan yang berurutan dapat dianggap sebagai kombinasi linear dari variabel-variabel acak, seperti $\epsilon_t, \epsilon_{t-1}, \epsilon_{t-2}, \dots$, dan seterusnya. Proses ini digambarkan oleh probabilitas yang terdistribusi stabil dengan rata-rata nol dan variansinya $\sigma\epsilon^2$. Sebagai asumsi, distribusi dari data ϵ_i mengikuti distribusi normal, dengan urutan yang bersifat acak atau yang lebih dikenal dengan istilah white noise. Kombinasi linear dari elemen-elemen ϵ_i ini dapat dinyatakan dalam persamaan berikut.

$$x_t = \mu + \delta_0\epsilon_t + \delta_1\epsilon_{t-1} + \delta_2\epsilon_{t-2} + \dots \quad (2.1)$$

atau

$$x_t = \mu + \sum_{j=0}^{\infty} \delta_j \epsilon_{t-j}$$

Di mana δ merupakan bobot, dan nilai $j = 0, 1, 2, \dots$ adalah konstan, sementara μ adalah konstanta yang menentukan tingkat atau level dari proses tersebut. Sebagai alternatif, persamaan (2.1) dapat didefinisikan dengan menggunakan notasi yang berbeda, yaitu B .

$$B\epsilon_t = \epsilon_{t-1}$$

Secara umum, dituliskan menjadi:

$$B^j\epsilon_t = \epsilon_{t-j} \quad (2.2)$$

Dengan menggunakan persamaan (2.2) maka dapat ditulis menjadi:

$$x_t = \mu + (\delta_0B^0 + \delta_1B^1 + \delta_2B^2 + \dots)\epsilon_t$$

atau

$$x_t = \mu + \prod(B)\epsilon_t \quad (2.3)$$

dimana $\prod(B) = \delta_0 B^0 + \delta_1 B^1 + \delta_2 B^2 + \dots$ dan $\delta_0 = 1$

Persamaan (2.3) sering disebut sebagai *linear filter*. Deret waktu pengamatan yang berurutan dari x_t bersifat dependen, karena nilainya dipengaruhi oleh variabel lain, yaitu ϵ_t . Selanjutnya, jika ϵ_t mengikuti distribusi normal dan ϵ_t juga terdistribusi normal, maka dalam kerangka model *linear filter*, pengamatan tersebut dapat didefinisikan dalam bentuk deret waktu atau sebagai transformasi dari proses white noise ke dalam deret waktu.

Model (2.3) dapat diperoleh dari deret waktu yang bersifat stasioner maupun nonstasioner. Jika deret waktu tersebut stasioner, maka deret tersebut akan berfluktuasi secara acak namun memiliki rata-rata yang konstan. Sebaliknya, jika deret waktu nonstasioner, maka rata-rata tersebut akan memiliki rentang nilai yang cukup besar. Secara umum, bobot δ_j dalam *linear filter* bisa bersifat terbatas (*finite*) atau tak terbatas (*infinite*), dan harus konvergen. Dalam deret waktu x_t yang stasioner dengan rata-rata μ , jika bobot δ_j bersifat tak terbatas dan divergen, maka deret waktu yang terbentuk menjadi nonstasioner, dan μ hanya akan berfungsi sebagai acuan nilai dari proses asli.

Berikut adalah beberapa istilah yang umum dijumpai dalam analisis deret waktu (Nurulita, 2010):

- 1) Stasioneritas. Salah satu asumsi penting dalam analisis deret waktu adalah stasioneritas. Deret pengamatan dikatakan stasioner jika prosesnya tidak berubah seiring waktu. Artinya, rata-rata deret pengamatan tetap konstan sepanjang waktu.
- 2) Fungsi Autokorelasi (*Autocorrelation Function/ACF*). Autokorelasi mengukur korelasi antar pengamatan dalam suatu deret waktu. Fungsi autokorelasi (ACF) adalah grafik yang menunjukkan hubungan korelasi antara nilai-nilai pengamatan dalam deret waktu.
- 3) Fungsi Autokorelasi Parsial (*Partial Autocorrelation Function / PACF*). Seperti halnya ACF, autokorelasi parsial juga mengukur korelasi antar pengamatan dalam deret waktu. Namun, PACF mengukur korelasi yang menghapus pengaruh

pengamatan lainnya, sehingga hanya menunjukkan hubungan langsung antar pengamatan.

- 4) *Cross-Correlation*. Digunakan untuk menganalisis deret waktu multivariat, yang melibatkan lebih dari dua deret waktu. Sama seperti autokorelasi, cross-correlation mengukur korelasi antar deret waktu, tetapi di sini yang diukur adalah korelasi antara dua deret waktu yang berbeda.
- 5) Proses *White Noise*: Merupakan proses stasioner yang terdiri dari deret variabel acak yang bersifat independen, identik, dan terdistribusi dengan cara tertentu.
- 6) Analisis Tren. Digunakan untuk memperkirakan model tren dalam data deret waktu. Beberapa model tren yang umum digunakan adalah model linier, kuadratik, eksponensial, pertumbuhan atau penurunan, dan model kurva S. Analisis tren dilakukan ketika deret waktu tidak mengandung komponen musiman.
- 7) Rata-rata Bergerak (*Moving Average*): Teknik ini digunakan untuk memperhalus data dengan cara menghitung rata-rata berurutan dari kelompok pengamatan dalam periode waktu tertentu.

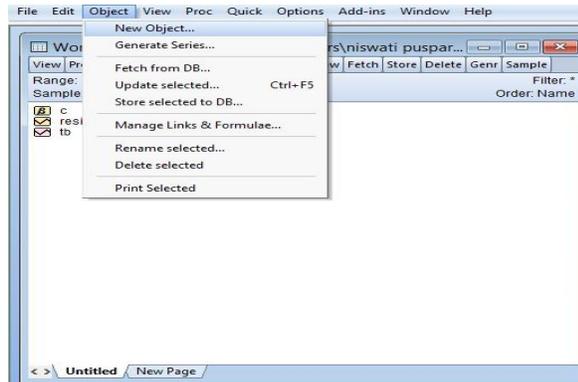
3. Langkah – Langkah ARIMAX Menggunakan Eviews

Berikut adalah penjelasan tahapan-tahapan yang dilakukan dalam membangun dan mengestimasi model ARIMAX (Autoregressive Integrated Moving Average with Exogenous Variables) menggunakan perangkat lunak EViews. Penjelasan ini disusun secara sistematis guna mempermudah pemahaman dan implementasi, dimulai dari tahap persiapan data, identifikasi model, pengujian stasioneritas, penentuan orde model, estimasi parameter, hingga evaluasi hasil dan validasi model (Sihombing, 2022).

A. Transformasi Data

1. Langkah pertama yang perlu dilakukan adalah membuka *Workfile* yang telah berisi data yang akan dianalisis. Setelah itu, pada bagian menu utama EViews, pilih opsi *Object*, kemudian klik *New Object*. Langkah ini bertujuan untuk membuat objek baru dalam *Workfile*, yang nantinya akan digunakan untuk membentuk dan mengestimasi model ARIMAX. Pemilihan "*New Object*" merupakan tahapan awal yang penting karena semua model, grafik, atau analisis dalam EViews dibangun berdasarkan objek-objek yang terdapat dalam *Workfile* tersebut.

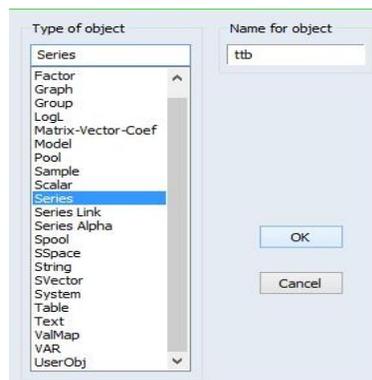
Gambar 2. 4 Tampilan Awal EViews



Sumber : (Sihombing, 2022)

2. Setelah jendela *New Object* muncul, langkah selanjutnya adalah memilih jenis objek yang akan dibuat. Pada bagian *Type of Object*, pilih opsi *Series* karena data yang akan dimasukkan merupakan deret waktu (*time series*) yang akan digunakan dalam pemodelan. Selanjutnya, masukkan nama yang sesuai untuk data tersebut pada kolom yang tersedia, guna memudahkan identifikasi di tahap-tahap analisis berikutnya. Setelah nama data ditentukan, klik tombol OK untuk menyimpan dan membuat objek *Series* tersebut ke dalam *Workfile* yang sedang digunakan.

Gambar 2. 5 Type of Object

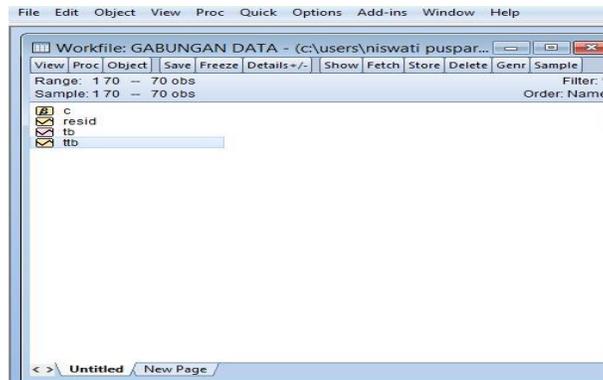


Sumber : (Sihombing, 2022)

3. Setelah proses pembuatan objek *Series* selesai, nama objek baru tersebut secara otomatis akan muncul di jendela *Workfile* yang menampilkan seluruh daftar objek yang telah dibuat dalam proyek analisis saat ini. Objek ini biasanya ditampilkan dalam bentuk daftar dengan ikon yang menunjukkan jenisnya, seperti *Series*, *Equation*, atau lainnya. Untuk

melanjutkan ke tahap pengisian atau pengelolaan data, lakukan klik ganda (*double-click*) pada nama objek *Series* yang baru saja dibuat.

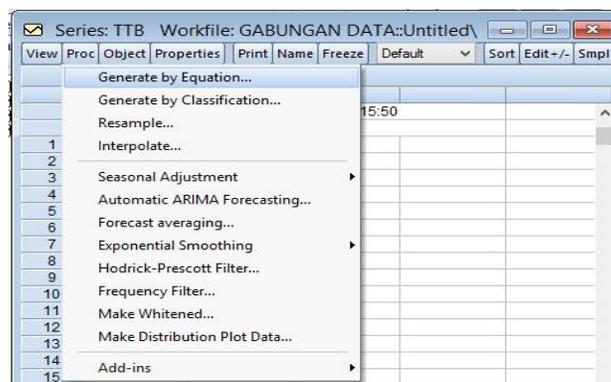
Gambar 2. 6 Nama Objek



Sumber : (Sihombing, 2022)

- Setelah jendela *Series* terbuka, langkah berikutnya adalah memasukkan data ke dalam objek tersebut melalui proses perhitungan atau pemanggilan variabel yang telah tersedia. Untuk melakukan hal ini, pada menu utama *Workfile*, pilih menu *Proc* (yang merupakan singkatan dari *Procedure*), kemudian klik opsi *Generate by Equation*. Opsi ini digunakan untuk menghasilkan nilai-nilai dalam *Series* berdasarkan suatu persamaan atau perintah tertentu yang ditentukan oleh pengguna.

Gambar 2. 7 *Generate by Equation*

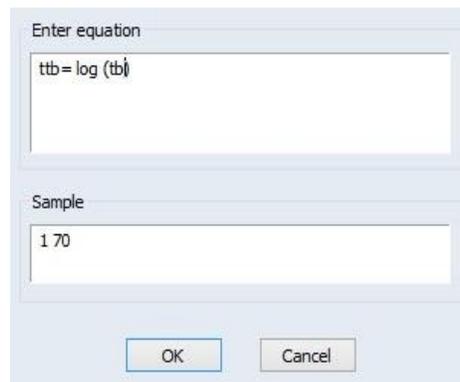


Sumber : (Sihombing, 2022)

- Pada kotak dialog *Generate Series by Equation* yang muncul setelah memilih opsi *Generate by Equation*, langkah selanjutnya adalah memasukkan formula atau persamaan untuk membentuk variabel baru. Ketikkan formula dalam format berikut:

nama_object_baru = log(nama_object_awal), di mana nama_object_baru adalah nama variabel hasil transformasi yang akan dibuat, dan nama_object_awal adalah nama variabel deret waktu asli yang ingin ditransformasikan. Penggunaan fungsi log() dalam formula ini menunjukkan bahwa data akan ditransformasikan menggunakan transformasi logaritmik alami (natural logarithm), yang setara dengan transformasi Box-Cox dengan parameter lambda (λ) = 0.

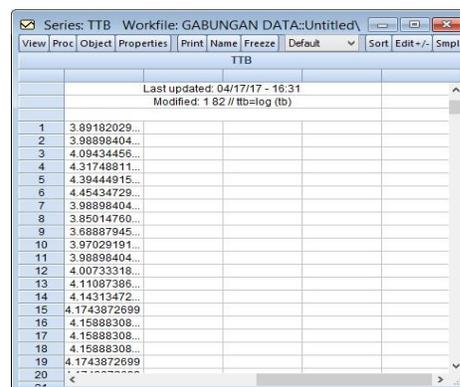
Gambar 2. 8 Persamaan Baru



Sumber : (Sihombing, 2022)

6. Setelah proses transformasi dilakukan dan perintah dijalankan, maka objek *Series* baru yang telah dibuat sebelumnya akan secara otomatis terisi dengan data hasil transformasi logaritmik dari objek awal. Nilai-nilai dalam objek baru tersebut merepresentasikan hasil dari penerapan fungsi logaritma terhadap seluruh observasi dalam variabel asli.

Gambar 2. 9 Objek *Series* Baru



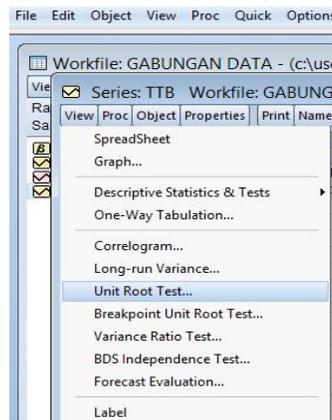
Sumber : (Sihombing, 2022)

A. Uji Stasioner Rataan

Pengujian stasioneritas terhadap rata-rata (*mean*) dalam suatu deret waktu dilakukan untuk memastikan bahwa nilai rata-rata data tidak berubah secara signifikan sepanjang waktu, yang merupakan salah satu syarat utama dalam analisis deret waktu. Dalam penelitian ini, pengujian stasioner rata-rata dilakukan dengan menggunakan perangkat lunak EViews, yang menyediakan fitur uji formal seperti Augmented Dickey-Fuller (ADF) atau Phillips-Perron (PP). Adapun langkah-langkah pelaksanaannya disajikan secara sistematis sebagai berikut:

- Langkah pertama dalam melakukan uji stasioneritas terhadap rata-rata menggunakan EViews adalah dengan memilih objek *Series* yang telah berisi data hasil transformasi, seperti transformasi logaritmik. Setelah objek tersebut dibuka atau dipilih di dalam tampilan *Workfile*, arahkan kursor ke menu bagian atas dan klik tab *View*, kemudian pilih opsi *Unit Root Test*. Opsi ini digunakan untuk mengakses berbagai metode pengujian akar unit (*unit root*), yang merupakan prosedur statistik untuk mengevaluasi apakah suatu deret waktu bersifat stasioner dalam rata-rata atau mengandung komponen tren yang tidak stasioner.

Gambar 2. 10 *Unit Root Test*

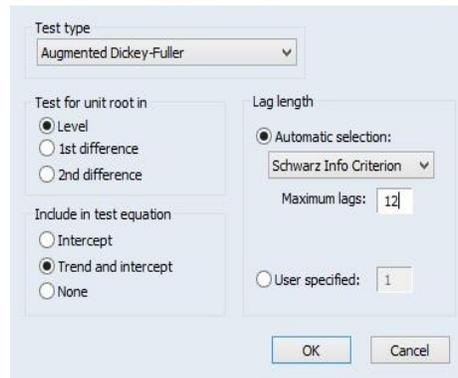


Sumber : (Sihombing, 2022)

- Setelah jendela *Unit Root Test* terbuka, pengguna akan diminta untuk menentukan spesifikasi pengujian yang akan dilakukan. Pada bagian *Test type*, pilih metode *Augmented Dickey-Fuller (ADF)*, yang merupakan salah satu metode paling umum dan terpercaya dalam mendeteksi keberadaan akar unit dalam deret waktu. Selanjutnya, pada bagian *Unit Root in*, pilih opsi "Level" untuk menguji stasioneritas data pada tingkat asalnya (tanpa

diferensiasi). Kemudian, pada bagian *Test Equation*, pilih *Trend and Intercept*, yang berarti model uji akan mempertimbangkan adanya tren deterministik serta intersep (konstanta) dalam data.

Gambar 2. 11 Jendela *Unit Root Test*



Sumber : (Sihombing, 2022)

- Setelah pengujian dijalankan, EViews akan menampilkan hasil output dari uji Augmented Dickey-Fuller (ADF) dalam bentuk tabel yang mencakup nilai probabilitas (*p-value*), statistik uji (*t-statistic*), dan nilai-nilai kritis pada berbagai tingkat signifikansi. Interpretasi terhadap hasil ini menjadi langkah penting dalam menentukan apakah data yang diuji bersifat stasioner dalam rataaan. Secara umum, suatu deret waktu dapat dinyatakan *stasioner dalam rataaan* apabila dua kondisi terpenuhi, yaitu: (1) nilai probabilitas (*p-value*) $\leq 0,05$, yang menunjukkan bahwa hipotesis nol (yang menyatakan adanya akar unit atau data tidak stasioner) dapat ditolak pada tingkat signifikansi 5%, dan (2) nilai absolut dari *t-statistic* lebih besar daripada nilai *t-kritis* pada level signifikansi yang sama, yakni $|t\text{-statistic}| > |t\text{-critical value}|$.

Gambar 2. 12 Uji *Augmented Dickey-Fuller* (ADF)

Null Hypothesis: TTB has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.770705	0.2123
Test critical values:		
1% level	-4.075340	
5% level	-3.466248	
10% level	-3.159780	

*Mackinnon (1996) one-sided p-values.

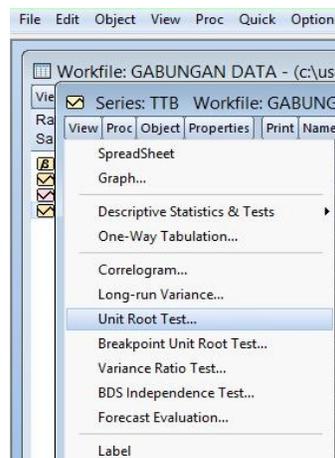
Sumber : (Sihombing, 2022)

B. Differencing

Proses *differencing* atau pembedaan dilakukan sebagai salah satu metode transformasi data untuk mengatasi masalah ketidastasioneran dalam deret waktu, khususnya ketika data menunjukkan pola tren atau fluktuasi yang tidak konstan. Tujuan utama dari proses ini adalah untuk menjadikan data lebih stabil secara statistik, terutama dalam hal rata-rata dan varians, sehingga dapat memenuhi asumsi dasar dalam analisis deret waktu, termasuk dalam pemodelan ARIMAX. Dalam penelitian ini, proses differencing dilakukan menggunakan perangkat lunak EViews, yang menyediakan fitur khusus untuk melakukan pembedaan data secara otomatis. Adapun langkah-langkah pelaksanaannya dijelaskan secara sistematis sebagai berikut:

- Langkah pertama dalam proses pembedaan data (*differencing*) adalah memastikan bahwa deret waktu yang akan diolah merupakan data hasil transformasi sebelumnya (misalnya logaritma atau lainnya), yang belum memenuhi syarat stasioneritas pada tingkat level. Untuk memverifikasi kembali tingkat stasioneritasnya, buka objek *Series* tersebut di dalam *Workfile*. Setelah objek terbuka, klik menu *View*, kemudian pilih opsi *Unit Root Test*. Langkah ini dilakukan untuk menjalankan kembali pengujian akar unit guna memastikan apakah data memang memerlukan proses *differencing*. Melalui pengujian ini, pengguna dapat menentukan apakah diferensiasi orde pertama perlu diterapkan berdasarkan hasil nilai probabilitas dan statistik uji yang dihasilkan.

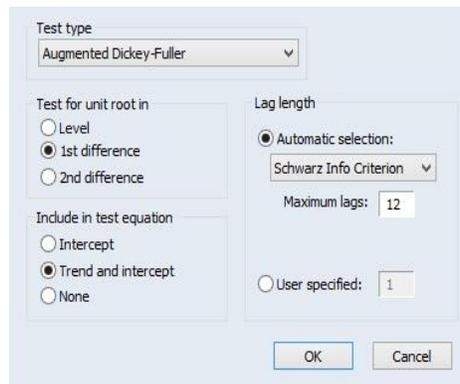
Gambar 2. 13 Proses *Differencing*



Sumber : (Sihombing, 2022)

11. Setelah jendela *Unit Root Test* terbuka, pengguna diminta untuk menentukan parameter-parameter uji yang akan digunakan dalam proses pengujian akar unit. Pada bagian *Test Type*, pilih metode Augmented Dickey-Fuller (ADF) yang merupakan salah satu metode standar dan umum digunakan untuk menguji stasioneritas data deret waktu. Selanjutnya, pada bagian *Unit Root in*, pilih opsi “Level”, karena tujuan pengujian pada tahap ini adalah untuk mengetahui apakah data pada level (tanpa diferensiasi) telah stasioner. Kemudian, pada bagian *Test Equation*, pilih opsi *Trend and Intercept*, agar model pengujian mempertimbangkan adanya komponen tren deterministik dan konstanta (intersep) dalam struktur data

Gambar 2. 14 Jendela *Unit Root Test*



Sumber : (Sihombing, 2022)

12. Setelah pengujian dijalankan, EViews akan menampilkan hasil output dari uji Augmented Dickey-Fuller (ADF) dalam bentuk tabel yang memuat informasi penting seperti nilai probabilitas (*p-value*), *t-statistic*, dan nilai kritis (*critical values*) pada berbagai tingkat signifikansi. Interpretasi terhadap hasil ini sangat penting dalam menentukan apakah data sudah memenuhi asumsi stasioneritas dalam rata-rata. Suatu deret waktu dapat dinyatakan stasioner dalam rata-rata apabila memenuhi dua kriteria utama, yaitu: (1) nilai probabilitas (*p-value*) $\leq 0,05$, yang menunjukkan bahwa hipotesis nol (adanya akar unit atau non-stasioneritas) dapat ditolak pada tingkat signifikansi 5%, dan (2) nilai absolut dari *t-statistic* lebih besar dari nilai kritisnya, yakni $|t\text{-statistic}| > |t\text{-critical value}|$. Berdasarkan tampilan hasil yang diperoleh (sebagaimana ditunjukkan pada gambar di bawah), diketahui bahwa nilai probabilitas lebih kecil dari 0,05 dan *t-statistic* juga melebihi nilai kritisnya. Dengan demikian, dapat disimpulkan bahwa data tersebut telah stasioner dalam

rataan, sehingga tidak diperlukan proses differencing lanjutan (*differencing orde ke-2*). Data pada tingkat diferensiasi saat ini sudah memenuhi asumsi dasar untuk digunakan dalam pemodelan deret waktu, termasuk dalam pengembangan model ARIMAX

Gambar 2. 15 Data Stasioner

Null Hypothesis: D(TTB) has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-7.659400	0.0000
Test critical values: 1% level	-4.076860	
5% level	-3.466966	
10% level	-3.160198	

*MacKinnon (1996) one-sided p-values.

Sumber : (Sihombing, 2022)

C. Pemodelan ARIMA

Seluruh tahapan dalam proses pemodelan *Autoregressive Integrated Moving Average* (ARIMA) dilaksanakan dengan menggunakan perangkat lunak statistik EViews, yang menyediakan fitur lengkap untuk analisis deret waktu secara menyeluruh. Pemodelan ARIMA bertujuan untuk menangkap struktur dinamika dari data deret waktu, termasuk komponen *autoregresif* (AR), *differencing* (I), dan *moving average* (MA), guna memperoleh model yang mampu menggambarkan pola historis sekaligus menghasilkan prediksi yang akurat. Untuk membangun model ARIMA yang tepat, pengguna perlu melalui sejumlah tahapan penting yang mencakup identifikasi, estimasi parameter, diagnostik model, serta validasi asumsi. Adapun langkah-langkah pelaksanaan pemodelan ARIMA menggunakan EViews dijelaskan secara sistematis sebagai berikut:

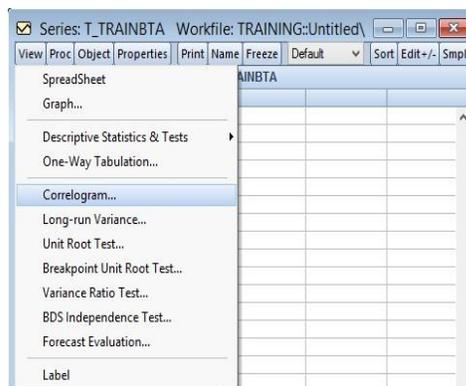
13. Estimasi Parameter

Proses estimasi parameter dalam pemodelan ARIMA dilakukan berdasarkan hasil analisis terhadap pola keterkaitan antar data dalam deret waktu, yang direpresentasikan melalui fungsi *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Analisis ini diterapkan pada data yang sebelumnya telah melalui proses *differencing*, guna memastikan bahwa data telah bersifat stasioner, sesuai dengan syarat

utama dalam pemodelan ARIMA. Fungsi ACF digunakan untuk mengidentifikasi keterkaitan jangka pendek atau pola *moving average (MA)*, sedangkan fungsi PACF digunakan untuk mendeteksi komponen *autoregressive (AR)* dalam data. Dengan mengamati pola kemunculan dan pemotongan (*cut-off*) pada grafik ACF dan PACF, peneliti dapat menentukan ordo terbaik dari parameter AR (p) dan MA (q) yang akan digunakan dalam model. Oleh karena itu, interpretasi terhadap grafik-grafik ini menjadi tahap krusial dalam membangun model ARIMA yang optimal dan representatif terhadap data deret waktu yang dianalisis.

- a. Langkah pertama dalam melakukan analisis struktur keterkaitan data deret waktu adalah dengan menampilkan grafik *Correlogram*, yang memuat informasi tentang pola autokorelasi dan autokorelasi parsial. Untuk melakukannya, buka objek *Series* yang berisi data hasil transformasi dan differencing yang telah memenuhi syarat stasioneritas. Setelah objek terbuka, arahkan kursor ke menu bagian atas, lalu klik tab *View*, kemudian pilih opsi *Correlogram*. Melalui tampilan ini, pengguna dapat mengakses grafik *Autocorrelation Function (ACF)* dan *Partial Autocorrelation Function (PACF)* secara visual. Grafik ini akan membantu dalam mengidentifikasi pola dan struktur lag yang signifikan dalam data, sehingga dapat digunakan sebagai dasar dalam penentuan ordo model ARIMA, khususnya parameter AR (p) dan MA (q).

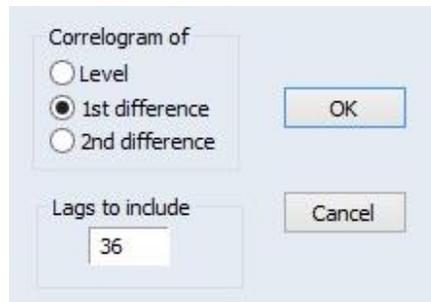
Gambar 2. 16 *Correlogram*



Sumber : (Sihombing, 2022)

- b. Setelah memilih menu *Correlogram*, akan muncul jendela dialog pengaturan tampilan grafik. Pada bagian *Correlogram of*, pastikan untuk memilih opsi *1st difference* atau differensiasi orde pertama dari data yang telah ditransformasi. Pemilihan ini penting karena analisis autokorelasi dan autokorelasi parsial harus dilakukan pada data yang telah bersifat stasioner, yang dalam hal ini diperoleh melalui proses differencing sebelumnya. Dengan memilih *1st difference*, pengguna memastikan bahwa grafik yang dihasilkan mencerminkan pola hubungan antar lag dalam data yang telah memenuhi syarat stasioneritas. Setelah opsi tersebut dipilih dengan benar, klik tombol OK untuk menampilkan grafik ACF dan PACF secara lengkap. Grafik ini akan digunakan sebagai dasar untuk mengidentifikasi nilai parameter AR dan MA dalam model ARIMA yang akan dibentuk.

Gambar 2. 17 Jendela *Correlogram*

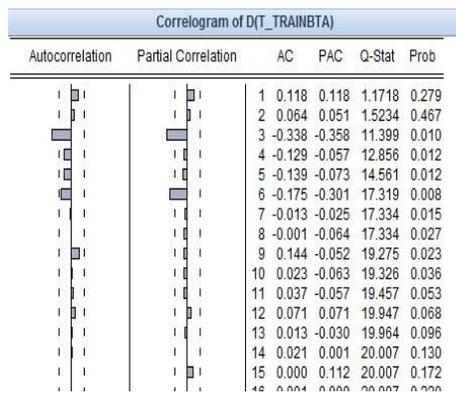


Sumber : (Sihombing, 2022)

- c. Setelah pengguna menekan tombol OK, EViews akan menampilkan grafik *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) dari data hasil *differencing* orde pertama. Grafik ini merupakan alat bantu visual yang sangat penting dalam proses identifikasi awal terhadap struktur model ARIMA. Dari tampilan tersebut, dapat diamati pola-pola signifikan pada sejumlah lag, baik pada grafik ACF maupun PACF. Berdasarkan hasil pengamatan, terlihat bahwa nilai autokorelasi dan autokorelasi parsial menunjukkan signifikansi pada lag ke-0 hingga lag ke-3. Oleh karena itu, nilai kandidat untuk parameter AR (p) dipertimbangkan pada ordo 0 hingga 3, dan demikian pula untuk parameter MA (q), yaitu dari ordo 0 hingga 3. Sementara itu, karena data telah dilakukan pembedaan satu kali (*first differencing*), maka nilai parameter I (d) ditetapkan sebesar 1. Dengan demikian,

model-model ARIMA yang diusulkan untuk tahap estimasi awal dapat mencakup berbagai kombinasi dari parameter-parameter tersebut, antara lain: ARIMA(0,1,1), ARIMA(0,1,2), ARIMA(0,1,3), hingga ARIMA(3,1,3). Seluruh model kandidat ini akan diuji dan dibandingkan berdasarkan kriteria evaluasi model seperti *Akaike Information Criterion* (AIC), *Schwarz Criterion* (SC), serta uji diagnostik residual untuk menentukan model terbaik yang paling sesuai dengan karakteristik data.

Gambar 2. 18 Batang ACF dan PACF



Sumber : (Sihombing, 2022)

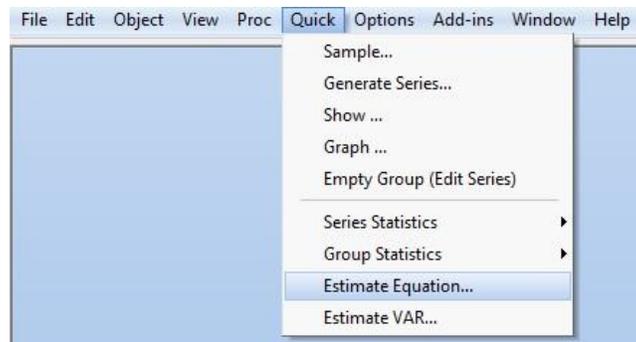
14. Uji Signifikansi

Setelah sejumlah model kandidat ARIMA terbentuk berdasarkan hasil analisis grafik ACF dan PACF, langkah selanjutnya yang sangat penting adalah melakukan pengujian signifikansi parameter untuk masing-masing model yang diusulkan. Tujuan utama dari pengujian ini adalah untuk mengevaluasi apakah parameter-parameter dalam setiap model, baik itu komponen *autoregressive* (AR), *differencing* (I), maupun *moving average* (MA), memiliki kontribusi yang signifikan terhadap pembentukan model secara statistik. Proses pengujian ini dilakukan secara menyeluruh terhadap seluruh kombinasi model tebakan ARIMA, seperti ARIMA(0,1,1), ARIMA(1,1,2), ARIMA(3,1,3), dan seterusnya. Pengujian signifikansi ini dilaksanakan dengan memanfaatkan fasilitas estimasi model dalam *software* EViews, yang secara otomatis akan menampilkan nilai *t-statistic* dan probabilitas (*p-value*) untuk setiap parameter yang diestimasi. Parameter dikatakan signifikan secara statistik jika nilai $p\text{-value} \leq 0,05$, yang berarti parameter tersebut secara nyata berpengaruh dalam membentuk dinamika deret waktu yang dimodelkan. Adapun

langkah-langkah teknis pelaksanaan uji signifikansi pada masing-masing model kandidat ARIMA dalam EViews dijelaskan secara sistematis sebagai berikut:

- d. Langkah pertama dalam melakukan proses estimasi model ARIMA di EViews adalah dengan membuka jendela perintah estimasi. Untuk melakukannya, dari tampilan utama EViews, arahkan kursor ke bagian menu bar, kemudian klik opsi *Quick*, yaitu menu yang menyediakan akses cepat untuk berbagai fungsi analisis. Setelah menu *Quick* terbuka, pilih sub-menu *Estimation Equation*. Opsi ini digunakan untuk memulai proses estimasi parameter berdasarkan model ARIMA yang telah ditentukan sebelumnya. Dengan langkah ini, pengguna akan diarahkan ke jendela input di mana struktur model dan parameter dapat dimasukkan secara manual sesuai dengan bentuk model ARIMA yang ingin diuji.

Gambar 2. 19 Estimasi Model

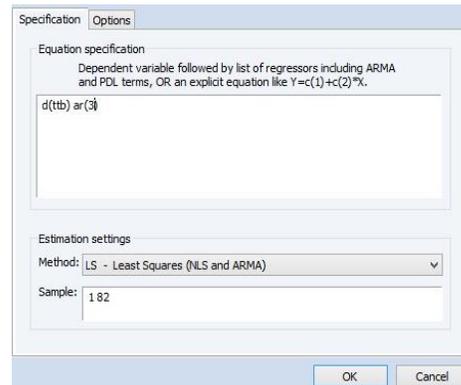


Sumber : (Sihombing, 2022)

- e. Setelah jendela *Estimation Equation* terbuka, langkah selanjutnya adalah memasukkan spesifikasi model ARIMA yang akan diuji. Penulisan persamaan dilakukan dengan format sintaks EViews yang sesuai. Sebagai contoh, jika model yang akan diuji adalah ARIMA(3,1,0), maka penulisannya pada kolom persamaan adalah $d(ttb) ar(3)$, di mana $d(ttb)$ menunjukkan bahwa data telah mengalami differencing satu kali (sesuai dengan nilai $d = 1$), dan $ar(3)$ menunjukkan bahwa model memiliki komponen autoregresif dengan ordo 3 ($p = 3$) serta tidak mengandung unsur moving average ($q = 0$). Setelah memasukkan persamaan dengan benar, pada bagian *Method*, pilih metode estimasi LS – *Least Squares (NLS and ARIMA)*. Metode ini digunakan untuk mengestimasi parameter model ARIMA dengan pendekatan non-

linear least squares yang sesuai untuk analisis deret waktu. Setelah seluruh pengaturan dilakukan dengan tepat, klik tombol OK untuk menjalankan proses estimasi dan menampilkan hasil perhitungan parameter model ARIMA yang bersangkutan.

Gambar 2. 20 *Equation Estimation*



Sumber : (Sihombing, 2022)

- f. Setelah pengguna mengklik tombol OK, EViews akan menampilkan hasil estimasi model dalam bentuk output tabel yang memuat berbagai informasi statistik penting. Output ini mencakup nilai estimasi parameter, t-statistic, serta probabilitas (*p-value*) dari masing-masing parameter dalam model ARIMA yang telah ditentukan sebelumnya. Informasi ini menjadi dasar utama dalam melakukan uji signifikansi parameter, yang bertujuan untuk menilai apakah setiap komponen dalam model berkontribusi secara signifikan terhadap pembentukan struktur model secara keseluruhan. Sebuah model ARIMA dikatakan lolos uji signifikansi apabila seluruh parameter yang diestimasi memenuhi dua kriteria berikut:
- Nilai probabilitas (*p-value*) dari masing-masing parameter $\leq 0,05$, yang menunjukkan bahwa parameter tersebut signifikan secara statistik pada tingkat signifikansi 5%, dan
 - Nilai absolut dari *t-statistic* masing-masing parameter lebih besar dibandingkan dengan nilai t-kritis (*t-critical value*) pada tingkat kepercayaan yang sesuai, yaitu $|t\text{-statistic}| > |t\text{-critical value}|$.

Gambar 2. 21 Uji Signifikansi

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(3)	-0.374215	0.063123	-5.928337	0.0000
SIGMASQ	0.007620	0.000713	10.69258	0.0000

Sumber : (Sihombing, 2022)

15. Uji Diagnostik

Setelah model ARIMA dinyatakan lolos dalam uji signifikansi parameter, tahapan selanjutnya yang tidak kalah penting adalah melaksanakan uji diagnostik model. Uji diagnostik bertujuan untuk mengevaluasi validitas dan kelayakan model secara menyeluruh dengan cara menguji asumsi-asumsi dasar yang harus dipenuhi oleh model deret waktu yang baik. Dalam konteks pemodelan ARIMA, terdapat dua jenis pengujian diagnostik utama yang harus dilakukan, yaitu uji keacakan sisaan (*white noise test*) dan uji homogenitas sisaan (uji varian konstan atau homoskedastisitas). Model ARIMA yang telah diuji hanya dapat dinyatakan lolos uji diagnostik apabila kedua syarat tersebut terpenuhi, yakni:

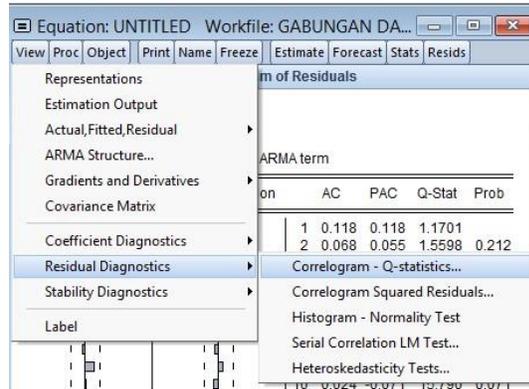
- Sisaan model bersifat acak, yang berarti tidak terdapat pola sistematis yang tertinggal dalam residual; dan
- Sisaan bersifat homogen (homoskedastik), yaitu varian residual konstan dari waktu ke waktu.

Pengujian diagnostik ini hanya diterapkan pada model-model ARIMA yang sebelumnya telah memenuhi kriteria uji signifikansi parameter. Dengan demikian, hanya model yang secara statistik signifikan dan residunya memenuhi asumsi keacakan serta homogenitas yang dapat dipertimbangkan lebih lanjut sebagai model terbaik untuk digunakan dalam proses peramalan (*forecasting*) dan pengambilan keputusan berbasis data deret waktu.

- g. Langkah pertama dalam pelaksanaan uji diagnostik keacakan sisaan (*white noise*) adalah dengan mengakses menu diagnostik residual pada software EViews. Untuk melakukannya, buka terlebih dahulu tampilan hasil estimasi model ARIMA yang telah lolos uji signifikansi. Setelah jendela estimasi terbuka, arahkan kursor ke bagian

atas layar dan klik menu *View*, yang menyediakan berbagai opsi tampilan lanjutan untuk analisis model. Selanjutnya, pada daftar menu yang muncul, pilih opsi *Residual Diagnostics*, yaitu submenu yang digunakan untuk mengevaluasi sifat-sifat statistik dari residual (sisaan) model. Setelah itu, klik pilihan *Correlogram – Q – Statistics*. Opsi ini akan menampilkan grafik autokorelasi dari residual model beserta nilai statistik Q Ljung-Box, yang digunakan untuk menguji apakah residual bersifat acak atau masih mengandung pola korelasi. Langkah ini merupakan bagian penting dalam memastikan bahwa tidak ada pola tersisa dalam sisaan yang dapat mengindikasikan ketidaktepatan spesifikasi model.

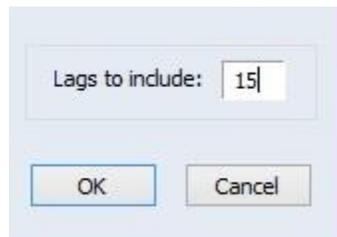
Gambar 2. 22 *Residual Diagnostics*



Sumber : (Sihombing, 2022)

- h. Setelah jendela *Correlogram – Q – Statistics* terbuka, langkah berikutnya adalah menentukan jumlah lag yang akan disertakan dalam pengujian. Isikan nilai lag yang diinginkan pada kolom “*Lags to include*”, sesuai dengan rentang waktu yang dianggap relevan untuk analisis residual. Pemilihan jumlah lag ini penting karena akan memengaruhi sensitivitas pengujian dalam mendeteksi adanya autokorelasi pada sisaan. Setelah nilai lag ditentukan dengan tepat, klik tombol OK untuk mengeksekusi perintah dan menampilkan hasil pengujian dalam bentuk tabel statistik dan grafik autokorelasi residual.

Gambar 2. 23 Lag Specification



Sumber : (Sihombing, 2022)

- i. Berdasarkan hasil yang ditampilkan oleh EViews setelah pengujian dijalankan, dapat diamati bahwa sebagian besar nilai probabilitas (p -value) dari statistik Ljung-Box untuk setiap lag berada di atas ambang signifikansi 0,05. Hal ini menunjukkan bahwa tidak terdapat autokorelasi yang signifikan dalam sisaan model, sehingga residual dapat dianggap bersifat acak (*white noise*). Dengan demikian, model ARIMA yang diuji dapat dinyatakan lolos dalam uji keacakan sisaan, karena tidak ditemukan pola sistematis yang tertinggal dalam residual, yang merupakan salah satu indikator bahwa model telah terestimasi dengan baik dan tidak mengalami masalah spesifikasi.

Gambar 2. 24 Batang ACF dan PACF

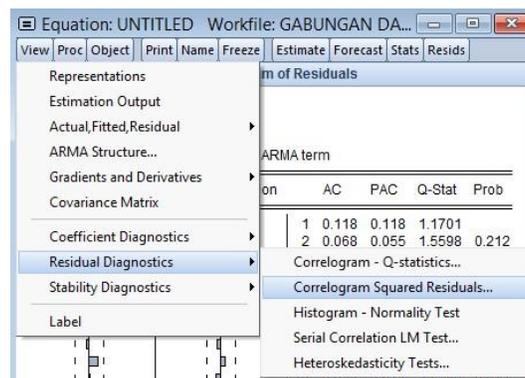
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.118	0.118	1.1701	
		2	0.068	0.055	1.5598	0.212
		3	-0.096	-0.111	2.3466	0.309
		4	-0.117	-0.100	3.5495	0.314
		5	-0.142	-0.108	5.3220	0.256
		6	-0.301	-0.284	13.418	0.020
		7	-0.065	-0.024	13.797	0.032
		8	-0.048	-0.051	14.006	0.051
		9	0.136	0.072	15.737	0.046
		10	0.024	-0.071	15.790	0.071
		11	0.048	-0.043	16.011	0.099
		12	0.131	0.061	17.688	0.089
		13	0.028	-0.007	17.763	0.123
		14	0.042	0.026	17.940	0.160
		15	0.014	0.090	17.959	0.209

Sumber : (Sihombing, 2022)

- j. Untuk melanjutkan proses uji diagnostik, khususnya dalam mengevaluasi homogenitas sisaan (homoskedastisitas), langkah yang perlu dilakukan adalah mengakses fitur pengujian varian residual dalam software EViews. Dari tampilan hasil estimasi model ARIMA yang sedang dianalisis, klik menu *View* di bagian atas jendela. Selanjutnya, arahkan kursor ke opsi *Residual Diagnostics*, yaitu submenu yang berisi berbagai metode untuk menganalisis karakteristik statistik sisaan. Pada

daftar pilihan yang tersedia, pilih opsi *Correlogram Squared Residuals*. Fitur ini digunakan untuk mendeteksi adanya pola autokorelasi pada kuadrat sisaan, yang secara statistik dapat mengindikasikan apakah terdapat ketidakhomogenan varian (heteroskedastisitas). Jika sisaan memiliki varian yang konstan dari waktu ke waktu, maka model dapat dikatakan memenuhi asumsi homoskedastisitas, yang merupakan salah satu syarat penting dalam validasi model ARIMA.

Gambar 2. 25 *Correlogram Squared Residual*



Sumber : (Sihombing, 2022)

- k. Setelah jendela *Correlogram Squared Residuals* terbuka, langkah selanjutnya adalah menentukan jumlah *lag* yang ingin dianalisis dalam pengujian. Isilah nilai lag yang diinginkan pada kolom "*Lags to include*", sesuai dengan jumlah periode yang dianggap relevan untuk mendeteksi potensi adanya autokorelasi dalam kuadrat sisaan. Pemilihan jumlah lag ini penting untuk memastikan sensitivitas pengujian terhadap gejala heteroskedastisitas dalam berbagai horizon waktu. Setelah nilai lag dimasukkan secara tepat, klik tombol OK untuk menjalankan proses analisis. EViews akan secara otomatis menampilkan hasil pengujian dalam bentuk grafik dan tabel statistik yang menggambarkan apakah terdapat autokorelasi signifikan pada kuadrat sisaan. Hasil inilah yang akan menjadi dasar dalam menentukan apakah model telah memenuhi asumsi homogenitas varian residual (homoskedastisitas).

Gambar 2. 26 *Lags to Include*



Sumber : (Sihombing, 2022)

1. Berdasarkan hasil pengujian *Correlogram Squared Residuals* yang ditampilkan oleh EViews, dapat dilihat bahwa sebagian besar nilai probabilitas (*p-value*) dari statistik Ljung-Box terhadap kuadrat sisaan berada di atas tingkat signifikansi 0,05. Hal ini menunjukkan bahwa tidak terdapat autokorelasi signifikan dalam kuadrat residual, sehingga dapat disimpulkan bahwa varian sisaan bersifat konstan dari waktu ke waktu (homoskedastisitas). Dengan demikian, model ARIMA yang diuji dinyatakan lolos dalam uji homogenitas, karena telah memenuhi asumsi dasar mengenai kestabilan variansi residual. Asumsi ini penting untuk memastikan bahwa model memiliki keandalan dalam melakukan estimasi dan peramalan, tanpa dipengaruhi oleh fluktuasi varian yang tidak terkontrol.

Gambar 2. 27 Uji Homogenitas

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.029	0.029	0.0711	0.790
		2 0.064	0.063	0.4174	0.812
		3 0.241	0.238	5.4147	0.144
		4 -0.011	-0.026	5.4251	0.246
		5 -0.021	-0.053	5.4646	0.362
		6 0.267	0.227	11.842	0.066
		7 -0.050	-0.053	12.066	0.098
		8 -0.047	-0.070	12.272	0.139
		9 0.066	-0.032	12.680	0.178
		10 -0.054	-0.017	12.953	0.226
		11 -0.059	-0.024	13.286	0.275
		12 -0.010	-0.086	13.297	0.348
		13 -0.067	-0.024	13.739	0.392
		14 -0.068	-0.018	14.208	0.434
		15 -0.001	0.009	14.208	0.510

Sumber : (Sihombing, 2022)

D. Pemilihan Model Terbaik ARIMA

Pemilihan model ARIMA terbaik menjadi langkah akhir yang sangat krusial dalam proses pemodelan deret waktu, khususnya apabila terdapat lebih dari satu model ARIMA yang telah memenuhi seluruh kriteria evaluasi sebelumnya, yaitu lolos uji signifikansi parameter dan lolos uji diagnostik (keacakan dan homogenitas sisaan). Dalam kondisi tersebut, pemilihan model optimal dilakukan dengan mempertimbangkan nilai dari kriteria informasi, yaitu *Akaike Information Criterion* (AIC) dan *Schwarz Bayesian Criterion* (SBC). Nilai AIC dan SBC masing-masing memberikan ukuran efisiensi model dalam menyeimbangkan kompleksitas (jumlah parameter) dengan tingkat kecocokan model terhadap data. Semakin kecil nilai AIC dan SBC, maka model dianggap semakin baik, karena menunjukkan bahwa model tersebut memiliki keseimbangan terbaik antara kesederhanaan struktur dan ketepatan estimasi. Oleh karena itu, model ARIMA dengan nilai AIC dan SBC terkecil akan dipilih sebagai model terbaik untuk digunakan dalam peramalan maupun analisis lanjutan. Untuk memperoleh nilai AIC dan SBC dari masing-masing model kandidat, langkah-langkah yang dilakukan sama seperti saat melakukan estimasi model ARIMA untuk uji signifikansi, yaitu melalui menu *Quick > Estimate Equation*, kemudian memasukkan spesifikasi model ARIMA yang ingin diuji. Setelah proses estimasi dijalankan, EViews akan menampilkan nilai AIC dan SIC pada bagian output model, yang kemudian dapat dibandingkan antar model untuk menentukan model yang paling optimal.

Gambar 2. 28 Nilai AIC dan SBC

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(3)	-0.374215	0.063123	-5.928337	0.0000
SIGMASQ	0.007620	0.000713	10.69258	0.0000
R-squared	0.126827	Mean dependent var		0.006205
Adjusted R-squared	0.115774	S.D. dependent var		0.094000
S.E. of regression	0.088391	Akaike info criterion		-1.984124
Sum squared resid	0.617225	Schwarz criterion		-1.925002
Log likelihood	82.35702	Hannan-Quinn criter.		-1.960403
Durbin-Watson stat	1.706268			
Inverted AR Roots	.36-.62i	.36+.62i	-.72	

Sumber : (Sihombing, 2022)

E. Pemodelan ARIMAX

Setelah diperoleh model ARIMA terbaik, langkah selanjutnya adalah membangun model ARIMAX (*Autoregressive Integrated Moving Average with Exogenous Variables*) dengan menambahkan variabel-variabel eksogen yang relevan.

1. Estimasi Parameter

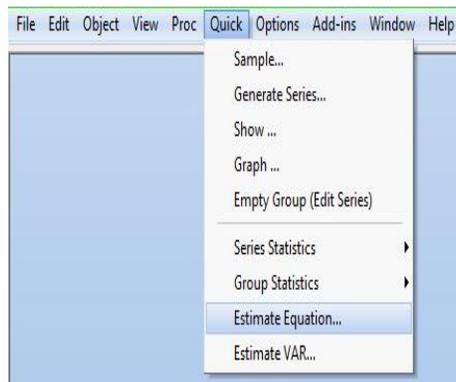
Estimasi parameter ARIMAX dilakukan dengan memasukkan variabel eksogen ke dalam struktur model ARIMA terbaik. Misalnya, jika model ARIMA terbaik adalah ARIMA(3,1,0), maka model dikembangkan menjadi ARIMAX(3,1,0) dengan menambahkan variabel yang berpengaruh. Langkah-langkah di EViews: Pilih *Quick > Estimate Equation*, ketik dalam format `d(variabel_y) c ar(1) ar(2) ar(3) exog1 exog2`, Pilih metode LS – *Least Squares (NLS and ARMA)*, Klik OK untuk melihat hasil estimasi.

2. Uji Signifikansi

Setelah estimasi dilakukan, uji signifikansi digunakan untuk menilai apakah seluruh parameter dalam model (baik ARIMA maupun variabel eksogen) signifikan secara statistik. Parameter dinyatakan signifikan jika nilai probabilitas $\leq 0,05$ atau $|t\text{-statistic}| > |t\text{-critical}|$. Hasil ini menunjukkan bahwa parameter tersebut memiliki kontribusi nyata dalam menjelaskan variabel dependen. Jika semua parameter yang signifikan telah dimasukkan, maka model ARIMAX siap untuk proses evaluasi dan peramalan.

- m. Langkah selanjutnya dalam proses estimasi model ARIMAX adalah membuka jendela estimasi persamaan pada EViews. Untuk melakukannya, pada tampilan utama perangkat lunak EViews, pengguna perlu mengakses menu *Quick*, kemudian memilih opsi *Estimate Equation*. Menu ini digunakan untuk memasukkan spesifikasi model ARIMAX yang akan dianalisis, sekaligus sebagai sarana untuk menjalankan proses estimasi parameter berdasarkan struktur model yang telah ditentukan.

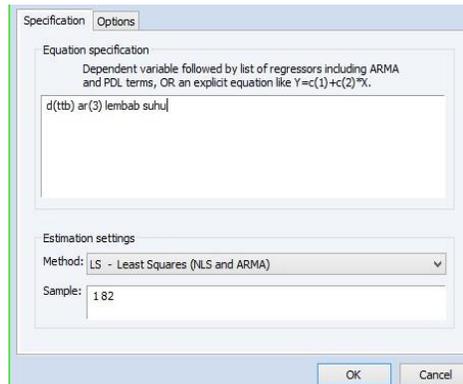
Gambar 2. 29 *Quick > Estimate Equation*



Sumber : (Sihombing, 2022)

- n. Setelah jendela *Estimate Equation* terbuka, langkah selanjutnya adalah menuliskan spesifikasi model ARIMAX yang akan diuji. Penulisan persamaan mengikuti format struktur ARIMA, ditambahkan dengan variabel-variabel eksogen yang relevan. Sebagai contoh, apabila model ARIMA terbaik yang digunakan adalah ARIMA(3,1,0) dan variabel eksogen yang dimasukkan adalah kelembaban dan suhu, maka persamaan ditulis sebagai: $d(ttb) c ar(1) ar(2) ar(3) kelembaban\ suhu$. Dalam format tersebut: $d(ttb)$ menunjukkan bahwa variabel utama (ttb) telah melalui proses differencing ($d=1$), c adalah konstanta model, $ar(n)$ menunjukkan lag autoregresif sesuai dengan model ARIMA terbaik, dan kelembaban, suhu merupakan variabel-variabel eksogen. Selanjutnya, pada bagian *Method*, pastikan memilih LS – *Least Squares* (NLS and ARMA) sebagai metode estimasi. Setelah seluruh komponen dimasukkan dengan benar, klik tombol OK untuk menjalankan proses estimasi model ARIMAX.

Gambar 2. 30 Format *Estimate Equation*



Sumber : (Sihombing, 2022)

- o. Setelah proses estimasi dijalankan, akan muncul tampilan hasil output model ARIMAX yang mencakup berbagai informasi statistik, termasuk nilai koefisien parameter, nilai *t-statistic*, dan probabilitas (*p-value*) untuk masing-masing variabel dalam model. Model dapat dinyatakan lolos dalam uji signifikansi apabila seluruh parameter yang diestimasi memenuhi kriteria statistik, yaitu memiliki nilai probabilitas (*p-value*) $\leq 0,05$, yang menunjukkan bahwa parameter signifikan secara statistik pada tingkat kepercayaan 95%. Selain itu, parameter juga harus memenuhi syarat bahwa nilai absolut $|t\text{-statistic}|$ lebih besar dari $|t\text{-critical value}|$, yang menunjukkan bahwa parameter memiliki pengaruh nyata terhadap variabel dependen. Jika kedua syarat tersebut terpenuhi untuk semua parameter (termasuk variabel eksogen), maka model ARIMAX yang diestimasi dapat dikatakan valid secara statistik dan dapat dilanjutkan ke tahap uji diagnostik atau peramalan.

Gambar 2. 31 Uji Signifikansi

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LEMBAB	0.001462	0.002710	0.539468	0.5911
SUHU	-0.004616	0.009082	-0.508277	0.6127
AR(3)	-0.374632	0.069547	-5.386732	0.0000
SIGMASQ	0.007523	0.000726	10.35617	0.0000

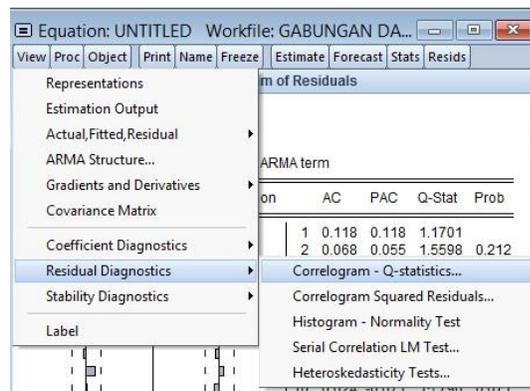
Sumber : (Sihombing, 2022)

3. Uji Diagnostik

Uji diagnostik pada model ARIMAX dilakukan dengan prosedur yang sama seperti pada ARIMA, yaitu mencakup uji keacakan sisaan dan uji homogenitas sisaan. Model dinyatakan lolos uji diagnostik apabila sisaan bersifat acak dan homogen. Pengujian ini hanya dilakukan pada model ARIMAX yang telah lolos uji signifikansi untuk memastikan validitas model sebelum digunakan dalam peramalan.

- p. Di jendela workfile, pilih menu *View*, lalu pilih *Residual Diagnostics*, dan selanjutnya klik *Correlogram – Q- Statistics*.

Gambar 2. 32 *Correlogram- Q-Statistics*



Sumber : (Sihombing, 2022)

- q. Masukkan jumlah lag yang diinginkan pada kolom '*Lag to include*', kemudian klik tombol OK untuk melanjutkan.

Gambar 2. 33 *Lags Specification*



Sumber : (Sihombing, 2022)

- r. Karena rata-rata nilai probabilitas lebih besar dari 0,05, maka residual bersifat acak dan dapat disimpulkan telah memenuhi kriteria dalam uji keacakan residual.

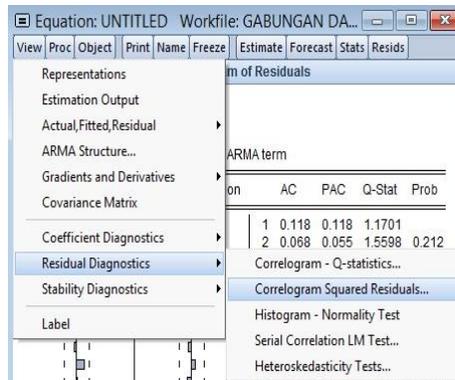
Gambar 2. 34 Uji Keacakan Residual

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob*	
		1	0.121	0.121	1.2325	
		2	0.061	0.047	1.5522	0.213
		3	-0.094	-0.109	2.3218	0.313
		4	-0.109	-0.090	3.3562	0.340
		5	-0.145	-0.114	5.2226	0.265
		6	-0.299	-0.282	13.212	0.021
		7	-0.069	-0.026	13.640	0.034
		8	-0.049	-0.055	13.860	0.054
		9	0.129	0.066	15.406	0.052
		10	0.018	-0.074	15.438	0.080
		11	0.049	-0.042	15.671	0.109
		12	0.130	0.058	17.321	0.099
		13	0.027	-0.015	17.391	0.135
		14	0.041	0.025	17.558	0.175
		15	0.017	0.088	17.588	0.226

Sumber : (Sihombing, 2022)

- s. Dalam rangka melakukan uji homogenitas, pada jendela *workfile* pilih menu *View*, kemudian *Residual Diagnostics*, dan lanjutkan dengan memilih *Correlogram Squared Residual*.

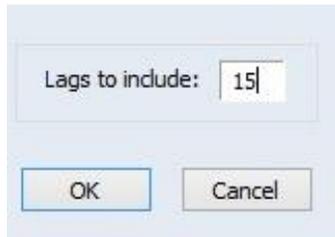
Gambar 2. 35 *Residual Diagnostics*



Sumber : (Sihombing, 2022)

- t. Tentukan jumlah lag yang diinginkan pada bagian '*Lag to include*', kemudian klik tombol OK untuk melanjutkan proses.

Gambar 2. 36 *Lags to Include*



Sumber : (Sihombing, 2022)

- u. Karena rata-rata nilai probabilitas melebihi 0,05, maka model dianggap homogen dan dinyatakan lolos dalam uji homogenitas.

Gambar 2. 37 Lolos Uji Homogenitas

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.036	0.036	0.1064	0.744
		2 0.069	0.068	0.5141	0.773
		3 0.227	0.223	4.9515	0.175
		4 -0.016	-0.034	4.9737	0.290
		5 -0.019	-0.050	5.0057	0.415
		6 0.253	0.220	10.721	0.097
		7 -0.053	-0.056	10.978	0.140
		8 -0.046	-0.070	11.176	0.192
		9 0.047	-0.041	11.380	0.251
		10 -0.053	-0.011	11.647	0.309
		11 -0.056	-0.022	11.950	0.367
		12 -0.010	-0.074	11.960	0.449
		13 -0.061	-0.019	12.331	0.501
		14 -0.063	-0.017	12.724	0.548
		15 -0.009	0.004	12.732	0.623

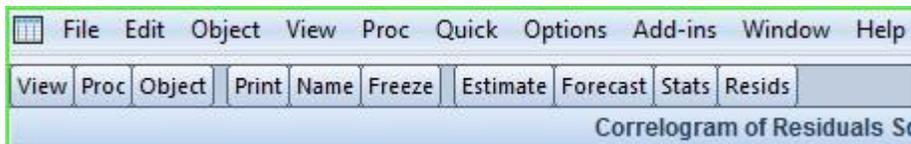
Sumber : (Sihombing, 2022)

4. Peramalan

Proses peramalan dapat dilakukan setelah model ARIMAX dinyatakan memenuhi uji signifikansi dan diagnostik, dengan tahapan sebagai berikut:

- v. Pada jendela workfile, pilih menu Forecast untuk memulai proses peramalan

Gambar 2. 38 Jendela *Workfile*



Sumber : (Sihombing, 2022)

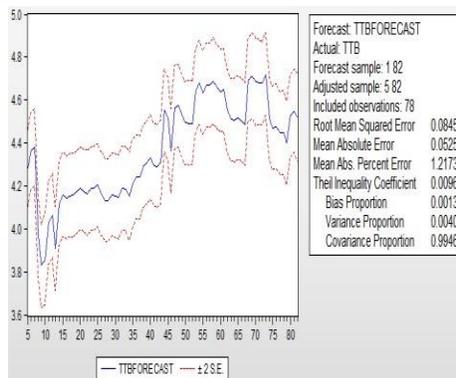
- w. Isikan nama hasil peramalan pada kolom 'Forecast name', lalu pilih opsi 'Static Forecast' pada bagian Method. Selanjutnya, tentukan rentang data yang akan diproyeksikan pada bagian 'Forecast sample', kemudian klik OK untuk melanjutkan.

Gambar 2. 39 Forecast Name

Sumber : (Sihombing, 2022)

- x. Berikut adalah hasil grafik dari peramalan yang dilakukan.

Gambar 2. 40 Grafik Forecasting



Sumber : (Sihombing, 2022)

4. Akurasi Peramalan

Dari beberapa metode yang tersedia untuk mengukur akurasi peramalan, penelitian ini memilih menggunakan *Mean Absolute Percentage Error* (MAPE). Akurasi peramalan sendiri mengacu pada sejauh mana hasil prediksi mendekati nilai aktual. MAPE merupakan salah satu metode pengukuran akurasi yang paling umum digunakan dalam evaluasi model peramalan karena mengukur rata-rata persentase kesalahan antara nilai aktual dan nilai

hasil peramalan. Dengan menggunakan persentase, MAPE memberikan ukuran kesalahan yang mudah dipahami dan memungkinkan perbandingan yang efektif antar model (Hillmer & Wei, 1991). Dibandingkan dengan metode pengukuran tingkat akurasi lainnya seperti *Mean Squared Error* (MSE) atau *Root Mean Squared Error* (RMSE), MAPE dinilai lebih akurat dan informatif karena menyajikan tingkat kesalahan dalam bentuk persentase yang scale-free. Keunggulan ini ditunjukkan oleh penelitian (Fitriyani et al., 2024) yang menggunakan metode Fuzzy Time Series Saxena-Easo untuk memprediksi laju inflasi, dan memperoleh nilai MAPE sebesar 1,029% yang dikategorikan sangat baik. Hal serupa juga dibuktikan oleh (Pramana et al., 2021) dalam studi peramalan ekspor nonmigas di Kalimantan Timur menggunakan *Weighted Fuzzy Time Series Lee*, yang menghasilkan MAPE sebesar 3,62%, menandakan tingkat akurasi tinggi dari model yang digunakan.

Rumus perhitungan MAPE dinyatakan sebagai berikut :

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{X_t - F_t}{X_t} \right| \times 100\% \quad (2.4)$$

Keterangan :

- a. X_t = nilai aktual pada periode ke-t
- b. F_t = nilai hasil peramalan pada periode ke-t
- c. n = jumlah total periode waktu peramalan

MAPE memberikan gambaran sejauh mana kesalahan peramalan secara relatif terhadap nilai aktual. semakin kecil nilai MAPE, maka semakin tinggi tingkat akurasi model dalam melakukan prediksi (Setyowati, 2020).

Menurut kriteria yang dikemukakan oleh (Sumari et al., 2020), tingkat akurasi model berdasarkan nilai MAPE dapat diklasifikasikan pada tabel sebagai berikut :

Tabel 2. 1 Kriteria MAPE

Nilai	Indikator
$X < 10\%$	Prediksi Sangat Akurat
$10\% \leq X \leq 20\%$	Prediksi yang Baik
$20\% < X \leq 50\%$	Prediksi yang Layak
$X > 50\%$	Prediksi yang Tidak Akurat

(Sumber : (Sumari et al., 2020))

5. PT Kino Indonesia Tbk

PT Kino Indonesia Tbk (juga disebut sebagai "Entitas Induk") didirikan dengan nama PT Kinocare Era Kosmetindo pada tanggal 8 Februari 1999, di hadapan Hadi Winata, S.H. Surat Keputusan No. C-7429 HT.01.01-TH.99 tanggal 20 April 1999 oleh Menteri Kehakiman Republik Indonesia, yang diumumkan dalam Berita Negara Republik Indonesia No. 96, Tambahan No. 8015 pada tanggal 30 November 1999 (Ahmad Nabhani, 2021).

Anggaran Dasar Entitas Induk telah beberapa kali diubah. Sebagai contoh, Akta Notaris No. 1 yang dibuat di depan Jose Dima Satria, S.H., M.Kn. pada 11 Januari 2016 mengubah susunan pemegang saham pasal 4 ayat 2 Anggaran Dasar Entitas Induk menjadi PT Kino Investindo sebesar 992.857.100 saham, Harry Sanusi sebesar 150.000.000 saham, dan masyarakat sebesar 285.714.400 saham.

Salah satu bagian dari Anggaran Dasar Entitas Induk, yang dibuat berdasarkan Akta Notaris No. 68 yang dibuat di hadapan Christina Dwi Utami S.H., M.Hum., M.Kn. pada tanggal 23 Mei 2018, mengubah alamat organisasi menjadi Kota Tangerang. Ada juga perubahan pada bagian 3 dari Anggaran Dasar Entitas Induk, yang dibuat berdasarkan Akta Notaris No. 133 yang dibuat di hadapan Dr. Ir. Yohanes Wilion, S.E., S.H

Menurut Pasal 3 Anggaran Dasar Entitas Induk, tujuan, maksud, dan kegiatan Entitas Induk adalah beroperasi dalam industri makanan, minuman, obat-obatan, dan kosmetik, serta menjalankan portal web dan platform digital. Entitas Induk tidak memiliki tujuan komersial. Entitas Induk beroperasi secara komersial pertama kali di tahun 1999.

Entitas Induk berkantor pusat di Kino Tower Lantai 17, Jl. Jalur Sutera Boulevard No. 01 - Alam Sutera, Kota Tangerang. Kabupaten Sukabumi, Serang, Pasuruan, dan Cidahu adalah empat kabupaten di Pulau Jawa yang memiliki pabrik entitas induk.

Entitas Induk langsungnya adalah PT Kino Investindo, yang berbasis di Kota Tangerang. Harry Sanusi adalah pemegang saham utamanya.

Penelitian skripsi yang berjudul "Model Prediksi Laba Bersih Terhadap Beban Operasional Menggunakan ARIMAX pada PT Kino Indonesia Tbk" bertujuan untuk menganalisis hubungan antara laba bersih dan beban operasional perusahaan menggunakan peramalan ARIMAX. Data yang digunakan dalam penelitian ini diambil setiap tiga bulan

sekali (per kuartal) agar analisis dapat mencerminkan dinamika kinerja keuangan perusahaan secara lebih komprehensif dan berkala.

Data keuangan PT Kino Indonesia Tbk dapat diakses secara publik melalui beberapa sumber, termasuk website resmi PT Kino Indonesia Tbk dan Otoritas Jasa Keuangan (OJK). Kedua platform ini menyediakan laporan keuangan perusahaan secara lengkap, yang memungkinkan investor, peneliti, dan pemangku kepentingan lainnya untuk memperoleh informasi yang relevan tentang kondisi keuangan perusahaan.

Namun, dalam penelitian ini, peneliti memutuskan untuk mengambil seluruh data keuangan yang digunakan secara langsung dari website resmi PT Kino Indonesia Tbk. Pemilihan sumber ini bertujuan untuk memastikan bahwa data yang digunakan adalah versi terbaru dan paling lengkap, sesuai dengan laporan resmi perusahaan. Dengan menggunakan data dari sumber utama, penelitian ini diharapkan dapat menghasilkan analisis yang akurat dan relevan terkait model prediksi laba bersih dan beban operasional perusahaan.

6. Laba Bersih

Laba bersih, menurut Simamora (2013) yang dikutip oleh (Hidayanti et al., 2019), adalah laba bersih yang berasal dari pendapatan, beban, keuntungan, dan kerugian. Ini dihasilkan dari perbedaan antara sumber daya masuk (pendapatan dan keuntungan) dan sumber daya keluar (beban dan kerugian) selama periode waktu tertentu.

Pendapatan, beban, keuntungan, dan kerugian membentuk laba bersih, menurut Henry Simamora (2013) yang dikutip oleh (Suhaemi, 2021). Transaksi-transaksi ini digambarkan dalam laporan laba rugi.

Menurut Stice et al. (2009:16) yang dikutip oleh (Puspitasari & Ruchjana, 2022), laba bersih adalah ukuran kinerja operasi bisnis dasar sebuah perusahaan. Ini dihitung dengan mengurangi laba kotor. Beban operasi dapat dilaporkan dalam dua kategori: penjualan dan administrasi dan umum. Secara umum, kecuali pajak penghasilan dan bunga, beban operasi adalah seluruh beban operasi.

Menurut Kasmir (2012:45) yang dikutip oleh (Susilawati & Mulyana, 2018), laba bersih adalah perbedaan antara harta masuk (pendapatan dan keuntungan) dan harta keluar (beban dan kerugian). Dengan kata lain, laba bersih adalah perbedaan antara total

pendapatan dikurangi dengan total biaya, atau total biaya. Dengan kata lain, laba bersih adalah perbedaan antara laba operasi dikurangi dengan biaya bunga dan pajak penghasilan.

Menurut Wild, Subramanyam, dan Halsey (2005:25) yang dikutip oleh (Setiawan & Kurniasih, 2020), laba bersih adalah laba bisnis setelah bunga dan pajak. Namun, menurut Budi Rahardjo (2009:83) yang dikutip oleh (Fathony et al., 2022), laba bersih atau laba bersih sesudah pajak penghasilan diperoleh dengan mengurangi laba atau penghasilan yang harus dibayar oleh perusahaan.

Menurut Hery (2017:267) yang dikutip oleh (Suhaemi, 2021), laba bersih adalah "laba operasi ditambah pendapatan non operasi (seperti pendapatan bunga), dikurangi biaya non operasi (seperti biaya bunga), dan dikurangi pajak penghasilan."

Menurut Sujarweni (2017:197) yang dikutip oleh (Kusumawardani, 2020) mengatakan bahwa laba bersih adalah "angka terakhir perhitungan laba-rugi dimana untuk mencarinya laba operasi ditambahkan ke angka terakhir perhitungan laba-rugi".

Dengan mempertimbangkan ketujuh definisi para ahli di atas, kita dapat mengatakan bahwa laba bersih adalah pendapatan setelah dikurangi biaya, yaitu laba berjalan dikurangi biaya bunga dan pajak.

7. Beban Operasional

Menurut (Ningsih & Epi, 2021), beban yang terjadi selama proses memperoleh pendapatan penjualan dikenal sebagai beban operasional. Sementara itu (Kuswinda et al., 2022) menyatakan bahwa beban operasional adalah beban yang terdiri dari beban administrasi umum dan penjualan, yang sebanding dengan beban operasi perusahaan jasa. total tanggung jawab yang diperlukan untuk menjalankan operasi bisnis. Dalam laporan laba atau rugi, laba operasi dihitung dengan mengurangi beban operasional dengan pendapatan.

Selain biaya yang terkait langsung dengan penjualan, seperti gaji, upah, utilitas, dan perlengkapan, beban operasi adalah biaya yang terus dikeluarkan oleh entitas, menurut Horrison, Walter T. (2011).

Berikut adalah definisi operasional yang lebih rinci untuk beban operasional yang terbagi dalam dua kategori utama: beban penjualan dan beban umum dan administrasi.

Kedua jenis beban ini digunakan untuk menganalisis bagaimana biaya operasional berpengaruh terhadap laba bersih PT Kino Indonesia Tbk.

8. Beban Penjualan

Beban penjualan mencakup semua biaya yang terkait dengan kegiatan pemasaran, distribusi, dan penjualan produk perusahaan kepada konsumen. Komponen-komponen dari beban penjualan meliputi:

- a) Iklan dan Promosi : Pengeluaran yang digunakan untuk mengiklankan dan mempromosikan produk, termasuk iklan media cetak, elektronik, digital, dan biaya kampanye pemasaran.

- b) Gaji, Upah, dan Tunjangan : Biaya untuk membayar tenaga kerja yang terlibat dalam penjualan, termasuk gaji tenaga penjualan, komisi, insentif, dan tunjangan lain.

- c) Pengiriman : Biaya yang mencakup transportasi barang dari gudang ke lokasi pelanggan atau pengecer, termasuk ongkos logistik, bahan bakar, dan jasa ekspedisi.

- d) Sewa : Biaya sewa tempat atau fasilitas yang digunakan untuk mendukung aktivitas penjualan, seperti kantor cabang penjualan atau ruang pameran.

- e) Transportasi : Pengeluaran untuk transportasi yang digunakan oleh tim penjualan dalam rangka operasional dan distribusi produk.

- f) Penyusutan : Biaya depresiasi aset tetap seperti kendaraan distribusi atau peralatan yang digunakan untuk kegiatan penjualan.

- g) Perjalanan dinas : Biaya perjalanan yang dilakukan oleh tim penjualan, termasuk tiket transportasi,

- akomodasi, dan uang harian selama perjalanan dinas.
- h) Pemeliharaan dan perawatan : Biaya untuk menjaga kondisi fasilitas atau aset yang digunakan untuk mendukung aktivitas penjualan, seperti perbaikan kendaraan distribusi atau ruang pameran.
- i) Peralatan dan perlengkapan : Biaya alat tulis kantor, perlengkapan promosi, atau peralatan lainnya yang digunakan oleh tim penjualan.
- j) Jasa profesional : Biaya jasa konsultan atau agen pemasaran yang membantu dalam aktivitas promosi atau penjualan.
- k) Utilitas : Mencakup pengeluaran yang terkait dengan layanan umum seperti listrik, air, gas, atau telekomunikasi yang mendukung operasional penjualan perusahaan.
- l) Perijinan dan keamanan : Pengeluaran yang meliputi biaya untuk memperoleh izin atau lisensi yang diperlukan dalam mendukung aktivitas penjualan, seperti izin distribusi atau sertifikasi produk, serta biaya terkait pengamanan aset perusahaan, fasilitas, atau produk selama proses penjualan, baik dalam bentuk tenaga keamanan maupun perangkat keamanan lainnya.

9. Beban Umum dan Administrasi

Beban umum dan administrasi adalah pengeluaran yang diperlukan untuk menjalankan kegiatan manajerial, administratif, dan pendukung operasional lainnya. Komponen dari beban umum dan administrasi meliputi:

- a) Gaji, Upah, dan Tunjangan : Biaya untuk membayar tenaga kerja di bagian manajemen, administrasi, dan staf pendukung.
- b) Peralatan dan perlengkapan : Pengeluaran untuk pembelian barang atau alat yang digunakan dalam kegiatan operasional kantor, seperti alat tulis, perangkat keras, atau perlengkapan kerja lainnya
- c) Sewa : Biaya untuk menyewa kantor, ruang kerja, atau peralatan yang digunakan dalam operasional administrasi.
- d) Imbalan Kerja Karyawan : Biaya yang berhubungan dengan kompensasi atau tunjangan tambahan bagi karyawan, seperti pensiun, asuransi kesehatan, dan tunjangan lainnya.
- e) Penyisihan penurunan nilai dan persediaan usang : Pencadangan yang dibuat untuk mencatat potensi kerugian akibat penurunan nilai aset atau persediaan yang tidak dapat digunakan atau dijual
- f) Jasa profesional : Biaya yang dikeluarkan untuk membayar layanan dari pihak ketiga, seperti konsultan, pengacara, akuntan, atau tenaga ahli lainnya
- g) Asuransi : Pengeluaran untuk perlindungan terhadap risiko yang mungkin terjadi pada aset, operasional, atau karyawan perusahaan melalui polis asuransi
- h) Penyisihan atas kerugian penurunan nilai piutang usaha : Alokasi biaya untuk mencadangkan kemungkinan kerugian akibat piutang yang tidak tertagih dari pelanggan
- i) Penyusutan : Biaya penyusutan yang terkait dengan aset tetap yang digunakan dalam administrasi,

seperti komputer, furnitur, atau gedung kantor.

- j) Utilitas : Pengeluaran untuk biaya listrik, air, telekomunikasi, dan layanan lainnya yang digunakan dalam operasional administrasi kantor.
- k) Perijinan dan keamanan : Biaya yang dikeluarkan untuk mendapatkan izin operasional, lisensi, serta pengeluaran yang terkait dengan keamanan perusahaan, seperti layanan keamanan atau asuransi.
- l) Transportasi : Biaya yang berkaitan dengan aktivitas transportasi yang mendukung operasional perusahaan, termasuk pengangkutan barang atau perjalanan kerja.
- m) Riset dan Pengembangan : Biaya yang terkait dengan penelitian dan pengembangan produk atau layanan baru, termasuk biaya laboratorium atau pengujian.
- n) Pemeliharaan dan perawatan : Biaya untuk menjaga fasilitas, peralatan, dan aset lainnya agar tetap berfungsi dengan baik
- o) Perjalanan dinas : Pengeluaran yang timbul dari perjalanan kerja pegawai untuk keperluan bisnis
- p) Pajak : Beban yang mencakup pembayaran pajak seperti pajak daerah atau pajak operasional perusahaan
- q) Sumbangan dan jamuan : Biaya yang dikeluarkan untuk kegiatan sosial seperti donasi atau hiburan dalam rangka membangun hubungan dengan pihak eksternal
- r) Amortisasi : Alokasi biaya atas aset tidak berwujud selama masa manfaatnya

- s) Pelatihan : Pengeluaran yang digunakan untuk pengembangan kompetensi dan kemampuan karyawan melalui program pelatihan atau Pendidikan

B. Variabel Penelitian

(Sugiyono, 2016) menyatakan bahwa variabel adalah karakteristik atau nilai dari kegiatan, objek, atau organisasi yang ditetapkan peneliti memiliki karakteristik tertentu yang harus dipelajari. Objek penelitian dan pengamatan adalah variabel, yang sering dianggap sebagai faktor yang berperan dalam penelitian atau fenomena yang diselidiki.

Dalam penelitian ini diambil judul yaitu Model Prediksi Laba Bersih Berdasarkan Beban Operasional Menggunakan ARIMAX pada PT Kino Indonesia TBK. Sehingga peneliti mengidentifikasi beberapa variabel. Variabel penelitian yang dipakai antara lain variabel bebas yaitu beban operasional dan variabel terikat berupa laba bersih.

C. Kerangka Berpikir

Penelitian ini diawali dengan pemahaman bahwa beban operasional merupakan salah satu faktor signifikan yang dapat mempengaruhi laba bersih perusahaan. Beban operasional adalah biaya yang dikeluarkan untuk menjalankan aktivitas sehari-hari perusahaan, yang mencakup biaya seperti gaji karyawan, biaya pemasaran, serta biaya administrasi dan umum. Beban operasional yang terlalu tinggi dapat mengurangi laba bersih, sedangkan pengelolaan beban operasional yang efektif dapat mendukung peningkatan profitabilitas.

Dalam penelitian ini, metode ARIMAX digunakan untuk memodelkan data historis beban operasional dan laba bersih secara deret waktu (*time series*). Data historis pada tahun 2018-2023 beban operasional dan laba bersih ini kemudian digunakan untuk memproyeksikan tren deret waktu (*time series*) selama 5 tahun mendatang, yaitu tahun 2024-2028. Dengan analisis ARIMAX, diharapkan dapat diperoleh model prediksi yang akurat mengenai pengaruh beban operasional terhadap laba bersih di masa mendatang. Melalui pendekatan ini, penelitian ini diharapkan dapat memberikan wawasan strategis yang komprehensif bagi manajemen perusahaan dalam merencanakan pengeluaran

operasional secara lebih efisien dan efektif, dengan mempertimbangkan dinamika biaya operasional serta dampaknya terhadap pencapaian laba bersih. Melalui pemahaman mendalam mengenai pola historis dan proyeksi masa depan yang dihasilkan oleh model ARIMAX, perusahaan dapat mengidentifikasi potensi penghematan biaya operasional, mengoptimalkan alokasi sumber daya, dan merancang strategi keuangan yang lebih terarah. Dengan demikian, hasil penelitian ini tidak hanya mendukung pengambilan keputusan berbasis data, tetapi juga membantu perusahaan dalam menetapkan prioritas strategis untuk mencapai laba bersih yang optimal, meningkatkan daya saing, dan menjaga keberlanjutan kinerja keuangan di tengah tantangan ekonomi yang terus berkembang.