



UNIVERSITAS IPWIJA

LEMBAGA PENELITIAN DAN PENGABDIAN KEPADA MASYARAKAT

Jl. Letda Natsir No.7 Cikeas Ds. Nagrak, Kec. Gunung Putri

Kab. Bogor. 16967 Telp. +62-21-8233737

lp2m@ipwija.ac.id <https://lp2m.ipwija.ac.id>

 UNIVERSITAS IPWIJA

No. : 023/IPWIJA.LP2M/PT-00/2026
Perihal : Edaran Penelitian Dosen
Lampiran : -

Kepada Yth.
Bapak/Ibu Dosen Tetap
Universitas IPWIJA

Dengan hormat,

Sehubungan dengan dimulainya semester Genap Tahun Akademik 2025/2026, perlu diingat kembali tentang salah satu kewajiban Tri Dharma Perguruan Tinggi Dosen yaitu melaksanakan penelitian. Berkenaan dengan hal itu maka disampaikan:

- Terima kasih kepada Bapak/Ibu Dosen Peneliti yang telah merespon Surat Edaran Kepala LP2M No.147/IPWIJA.LP2M/PT-00/2025 tanggal 1 September 2025 tentang Kegiatan Bidang Penelitian dengan aktif berperan dalam berbagai pertemuan ilmiah, melaksanakan penelitian dan mempublikasikan hasil penelitian di berbagai jurnal ilmiah.
- Dosen yang telah menyelesaikan laporan penelitian dan mempublikasikannya pada semester Ganjil Tahun Akademik 2025/2026 diharapkan mengajukan usulan penelitian baru kepada LP2M.
- Dosen yang telah menyelesaikan tahap akhir penelitian diharapkan dapat segera membuat laporan hasil penelitian dan mempublikasikannya di semester Genap Tahun Akademik 2025/2026.
- Pada semester Genap Tahun Akademik 2025/2026, Dosen diharapkan aktif mengikuti berbagai kegiatan yang berkaitan dengan penelitian seperti: pertemuan ilmiah, sharing knowledge, diseminasi, pelatihan, seminar, proceeding, publikasi dan lain sebagainya.
- Agar penelitian dosen selaras dengan Rencana Strategis Penelitian institusi, diharapkan para dosen melakukan koordinasi secara berkelanjutan dengan LP2M, Program Studi, serta seluruh elemen di Universitas IPWIJA.

Demikian edaran ini disampaikan dan terima kasih.

Bogor, 2 Maret 2026



Drs Jayadi, M.M.

Kepala LP2M

Tembusan : Rektor
Dekan FEB
Dekan FSK

LAPORAN PENELITIAN DOSEN



EVALUASI DAN OPTIMASI MODEL SARIMA DENGAN INTERVENSI PANDEMI COVID-19 DALAM PERAMALAN PENJUALAN MOBIL LOKAL *WHOLESALERS* DI INDONESIA (DATA BULANAN 2016-2025)

Peneliti :
Faizal Farouk, S.E., M.M

**PROGRAM STUDI KEWIRAUSAHAAN
FAKULTAS MANAJEMEN
UNIVERSITAS IPWIJA
BOGOR
2026**

HALAMAN PENGESAHAN LAPORAN PENELITIAN

- | | | |
|------------------------------|---|--|
| 1. Judul Penelitian | : | Evaluasi dan Optimasi Model SARIMA dengan Intervensi Pandemi COVID-19 dalam Peramalan Penjualan Mobil Lokal Wholesales di Indonesia (Data Bulanan 2016-2025) |
| 2. Bidang Penelitian | : | Penelitian Kuantitatif |
| 3. Ketua Peneliti | : | |
| a. Nama Lengkap dan Gelar | : | Faizal Farouk, S.E.,M.M |
| b. NIDN | : | 0325098904 |
| c. Pangkat/Golongan | : | Penata Muda Tk. 1, Golongan Ruang III/B |
| d. Jabatan Fungsional | : | Asisten Ahli |
| e. Program Studi | : | Kewirausahaan |
| f. Sinta ID | : | 6849409 |
| g. E-mail | : | faizalfarouk@gmail.com |
| h. No. HP | : | 081289000237 |
| 4. Jumlah Anggota Peneliti | : | 0 |
| 5. Anggota Peneliti 1 | : | |
| a. Nama Lengkap dan Gelar | : | - |
| b. NIDN | : | - |
| c. Pangkat/Golongan | : | - |
| d. Jabatan Fungsional | : | - |
| e. Program Studi | : | - |
| f. Sinta ID | : | - |
| 6. Jumlah Mahasiswa Terlibat | : | - |
| 7. Lama Penelitian | : | 3 Bulan |
| 8. Biaya Penelitian | : | Rp 0 |
| 9. Sumber Dana | : | - |

Peneliti,



Faizal Farouk, S.E.,M.M
NIDN. 0325098904

Bogor, 23 Juli 2026
Menyetujui,
Kepala LP2M



Drs. Jayadi, M.M.
NIDN. 0323106401

Ringkasan

Penelitian ini mengevaluasi dan mengoptimalkan model peramalan deret waktu untuk penjualan wholesales mobil lokal di Indonesia menggunakan data bulanan resmi Gaikindo periode Januari 2016 hingga Desember 2025 (120 observasi). Latar belakang penelitian ini adalah gangguan struktural ekstrem akibat pandemi COVID-19 pada 2020, ketika penjualan anjlok hingga 48,7% secara tahunan, serta fenomena tren penurunan berturut-turut pada 2023-2025 yang tidak dapat dijelaskan sepenuhnya oleh pola historis pra-pandemi. Kondisi ini menjadi tantangan metodologis bagi model peramalan konvensional yang mengasumsikan struktur data masa lalu representatif terhadap masa depan.

Penelitian ini secara sistematis membangun dan membandingkan kinerja tiga model peramalan, yaitu SARIMA konvensional (Model 1), SARIMA dengan komponen intervensi pandemi COVID-19 berupa fungsi pulse dan step (Model 2), serta ETS/Holt-Winters multiplicative (Model 3), menggunakan data uji out-of-sample periode 2024-2025. Seluruh proses analisis dilakukan mengikuti kerangka metodologi Box-Jenkins yang meliputi uji stasioneritas (ADF dan Phillips-Perron), identifikasi model melalui plot ACF/PACF, estimasi parameter dengan Maximum Likelihood Estimation, serta pemeriksaan diagnostik residual, dengan bantuan perangkat lunak IBM SPSS Statistics. Akurasi ketiga model dievaluasi menggunakan MAPE, RMSE, dan MAE, serta diuji signifikansi perbedaannya melalui uji Diebold-Mariano. Hasil penelitian menunjukkan bahwa Model 3 Holt-Winters menghasilkan MAPE dan MAE terendah, Model 1 SARIMA konvensional unggul pada RMSE dan merupakan satu-satunya model yang memenuhi asumsi white noise pada residual, sementara Model 2 SARIMA dengan intervensi justru menghasilkan akurasi out-of-sample yang lebih rendah dibandingkan hipotesis awal, meskipun memiliki varians dan distribusi residual yang lebih baik serta mampu mengkuantifikasi besaran dampak pandemi secara eksplisit. Uji Diebold-Mariano mengkonfirmasi bahwa perbedaan akurasi di antara ketiga model tidak signifikan secara statistik, sehingga ketiga model dapat dianggap relatif setara dalam kemampuan prediktifnya.

Temuan ini mengindikasikan bahwa pemilihan model peramalan terbaik pada data yang mengandung structural break berskala pandemi perlu mempertimbangkan tujuan penggunaan, bukan hanya satu ukuran akurasi tunggal, dan bahwa penambahan komponen intervensi tidak secara otomatis menjamin peningkatan akurasi peramalan meskipun memberikan nilai interpretatif yang signifikan bagi pemangku kepentingan di industri otomotif Indonesia.

PRAKATA

Alhamdulillah rabbil‘*alamin*, dengan segala kerendahan hati penulis mengucapkan puji syukur kepada Allah SWT yang senantiasa membimbing dan menyertai penulis. Sholawat serta salam semoga selalu tercurah bagi Rasulullah Muhammad SAW. Atas karunia-Nya lah penulis dapat menyelesaikan laporan penelitian dengan judul “Evaluasi dan Optimasi Model SARIMA dengan Intervensi Pandemi COVID-19 dalam Peramalan Penjualan Mobil Lokal Wholesales di Indonesia”.

Selama persiapan dan penyusunan laporan penelitian, penulis banyak mendapat dukungan, dorongan, bimbingan serta doa dari banyak pihak. Dengan ketulusan dan kerendahan hati pada kesempatan ini penulis ingin mengucapkan terima kasih kepada :

1. Ir. Besar Agung Martono, M.M, DBA selaku Rektor Universitas IPWIJA
2. Drs. Jayadi, M.M. selaku ketua LP2M yang selalu mendukung
3. Civitas akademik UNIVERSITAS IPWIJA
4. Kedua orang tua dan keluarga besar yang telah memberikan dukungan, material, waktu, tenaga dan doa yang tidak terbatas.
5. Istriku Defany Estha Adjani yang selalu memberikan masukan dan dukungan yang begitu besar.
6. Kedua anaku Abdullah Afa Alfarouk dan Abdurrahman Salman Alfarouk.

Semoga bantuan bapak, ibu dan rekan – rekan berikan mendapat imbalan dari Tuhan Maha Kuasa dan penulis juga berharap hasil penelitian yang sederhana ini dapat memberikan manfaat bagi pengembangan ilmu pengetahuan dan pihak – pihak terkait yang berkepentingan dengan hasil penelitian ini.

Bogor, 23 Juli 2026

Penulis

DAFTAR ISI

BAB 1	1
PENDAHULUAN.....	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah.....	3
1.3 Tujuan Penelitian.....	4
1.4 Manfaat Penelitian.....	5
1.4.1 Manfaat Teoritis.....	5
1.4.2 Manfaat Praktis.....	5
1.5 Batasan Penelitian.....	6
BAB 2	7
TINJAUAN PUSTAKA.....	7
2.1 Analisis Deret Waktu.....	7
2.2 Model ARIMA dan SARIMA.....	7
2.2.1 Autoregressive Integrated Moving Average (ARIMA)	7
2.2.2 Seasonal ARIMA (SARIMA)	8
2.3 Analisis Intervensi (Intervention Analysis)	8
2.3.1 Konsep Dasar Analisis Intervensi.....	8
2.3.2 Fungsi Intervensi: Pulse dan Step.....	9
2.3.3 Model SARIMA dengan Komponen Intervensi.....	9
2.4 Model ETS dan Holt-Winters	10
2.4.1 Exponential Smoothing State Space Model (ETS).....	10
2.4.2 Holt-Winters Multiplicative	10
2.5 Structural Break dan Gangguan Pandemi COVID-19.....	11
2.5.1 Definisi dan Dampak Structural Break pada Model Deret Waktu	11
2.5.2 Profil Gangguan COVID-19 pada Industri Otomotif	11
2.6 Kriteria Seleksi dan Evaluasi Model	12
2.6.1 Kriteria Informasi: AIC dan BIC	12
2.6.2 Metrik Akurasi Peramalan.....	12
2.6.3 Uji Perbandingan Akurasi: Diebold-Mariano	13
2.7 Industri Otomotif dan Peran Gaikindo.....	13
2.8 <i>State of the Art</i>	13
2.8.1 Penelitian Peramalan Penjualan Kendaraan Bermotor	14
2.8.2 Penerapan Analisis Intervensi pada Data Ekonomi	14

2.8.3 Perbandingan SARIMA, Intervensi, dan ETS/Holt-Winters	15
2.8.4 Posisi dan Orisinalitas Penelitian.....	15
BAB 3	17
METODE PENELITIAN	17
3.1 Jenis dan Sumber Data.....	17
3.1.1 Jenis Data	17
3.1.2 Sumber Data	17
3.1.3 Periode dan Cakupan Data	18
3.2 Metode Analisis Data.....	19
3.3 Analisis Deskriptif dan Eksplorasi Data	19
3.3.1 Statistik Deskriptif	19
3.3.2 Visualisasi Time Series dan Dekomposisi	20
3.3.3 Identifikasi Outlier dan Periode Intervensi	21
3.4 Uji Stasioneritas.....	22
3.4.1 Uji Augmented Dickey-Fuller (ADF).....	22
3.4.2 Uji Phillips-Perron (PP) sebagai Konfirmasi	23
3.4.3 Inspeksi Visual ACF dan PACF	23
3.5 Spesifikasi Tiga Model Peramalan	23
3.5.1 Model 1: SARIMA Konvensional	23
3.5.2 Model 2: SARIMA dengan Komponen Intervensi COVID-19.....	24
3.5.3 Model 3: ETS/Holt-Winters Multiplicative	24
3.6 Pemeriksaan Diagnostik Residual	25
3.6.1 Uji Autokorelasi Residual: Ljung-Box	25
3.6.2 Uji Normalitas Residual	25
3.6.3 Pemeriksaan Homoskedastisitas	26
3.7 Pemilihan Model Terbaik dan Evaluasi Akurasi.....	26
3.7.1 Seleksi In-Sample: AIC dan BIC.....	26
3.7.2 Evaluasi Out-of-Sample: MAPE, RMSE, MAE	26
3.7.3 Uji Signifikansi Perbedaan Akurasi: Diebold-Mariano	26
BAB 4	28
HASIL DAN PEMBAHASAN.....	28
4.1 Gambaran Umum Objek Penelitian.....	28
4.1.1 Gaikindo dan Pasar Otomotif Indonesia	28
4.1.2 Perkembangan Penjualan Wholesales 2016–2025	28
4.1.3 Statistik Deskriptif dan Pola Musiman	29
4.2 Hasil Penelitian.....	30
4.2.1 Hasil Uji Stasioneritas	30

4.2.2 Identifikasi dan Estimasi Model SARIMA (Model 1).....	30
4.2.3 Hasil Diagnostik Residual Ketiga Model.....	31
4.3 Pembahasan.....	32
4.3.1 Dinamika Struktural Pasar Otomotif 2016–2025	32
4.3.2 Implikasi Diagnostik: Mengapa Model 1 Lebih Baik Secara Diagnostik?	32
4.4 Peramalan Penjualan Mobil Lokal Wholesales di Indonesia.....	33
4.4.1 Prosedur Peramalan	33
4.4.2 Perbandingan Aktual vs Ramalan pada Data Testing 2024–2025.....	33
4.5 Evaluasi Model SARIMA	34
4.5.1 Akurasi Out-of-Sample Model 1 vs Model 3	34
4.5.2 Stabilitas Akurasi per Tahun	35
4.5.3 Analisis Kinerja pada Bulan Bermasalah.....	35
4.6 Optimasi Model SARIMA dengan Intervensi Pandemi COVID-19	35
4.6.1 Spesifikasi dan Estimasi Komponen Intervensi (Model 2).....	35
4.6.2 Perbandingan SARIMA vs SARIMA+Intervensi	36
4.6.3 Uji Signifikansi Perbedaan Akurasi: Diebold-Mariano	37
4.6.4 Proyeksi Penjualan Wholesales 2026 dan Validasi Real-Time.....	38
4.7 Implikasi Manajerial	39
4.7.1 Bagi Pabrikan dan ATPM	39
4.7.2 Bagi Dealer dan Industri Pembiayaan.....	39
4.7.3 Bagi Regulator dan Pembuat Kebijakan	40
BAB 5	41
KESIMPULAN DAN SARAN.....	41
5.1 Kesimpulan	41
5.1.1 Karakteristik Pola Tren dan Musiman (RM 1).....	41
5.1.2 Akurasi Peramalan Ketiga Model (RM 2)	41
5.1.3 Efektivitas Intervensi COVID-19 (RM 3).....	42
5.2 Saran	43
5.2.1 Saran bagi Peneliti Lanjutan.....	43
5.2.2 Saran bagi Pelaku Industri Otomotif.....	44
5.2.3 Saran bagi Lembaga Pembiayaan Otomotif.....	45
5.2.4 Saran bagi Regulator dan Pembuat Kebijakan	45
DAFTAR PUSTAKA.....	47

DAFTAR TABEL

Tabel 1.1 Ringkasan Data Penjualan Wholesales Mobil Lokal Indonesia 2016–2025	3
Tabel 1.2 Pemetaan Rumusan Masalah, Model, dan Metode Evaluasi	4
Tabel 2.1 Pemetaan State of the Art: Penelitian Ini vs Studi Terdahulu	15
Tabel 3.1 Ringkasan Karakteristik Data Penelitian	18
Tabel 3.2 Statistik Deskriptif Data Penjualan Wholesales Mobil Lokal Indonesia	19
Tabel 3.3 Indeks Musiman Penjualan Wholesales Mobil Indonesia	20
Tabel 3.4 Hasil Identifikasi Outlier pada Data Training (2016–2023)	21
Tabel 3.5 Hasil Uji Augmented Dickey-Fuller (ADF).....	22
Tabel 3.6 Ringkasan Alur Analisis dan Metode yang Digunakan	27
Tabel 4.1 Penjualan Wholesales Mobil Lokal Indonesia 2016–2025	28
Tabel 4.2 Statistik Deskriptif per Fase Kondisi Pasar.....	29
Tabel 4.3 Hasil Uji Stasioneritas Augmented Dickey-Fuller (ADF).....	30
Tabel 4.4 Seleksi Kandidat Model SARIMA Konvensional (Model 1)	30
Tabel 4.5 Estimasi Parameter Model 1: SARIMA(0,1,1)(0,1,1) ₁₂	31
Tabel 4.6 Hasil Diagnostik Residual Ketiga Model.....	31
Tabel 4.7 Aktual vs Ramalan Ketiga Model (Data Testing 2024–2025)	33
Tabel 4.8 Perbandingan Metrik Akurasi Peramalan Ketiga Model (Testing 2024–2025)...	34
Tabel 4.9 Estimasi Parameter Model 2: SARIMA(0,1,1)(0,1,1) ₁₂ + Intervensi COVID-19	36
Tabel 4.10 Perbandingan SARIMA vs SARIMA+Intervensi: Kontribusi Komponen Intervensi	37
Tabel 4.11 Hasil Uji Diebold-Mariano antar Pasangan Model.....	37
Tabel 4.12 Proyeksi 2026 dan Validasi dengan Data Aktual Gaikindo	38
Tabel 5.1 Ringkasan Evaluasi Komparatif Ketiga Model.....	42

BAB 1

PENDAHULUAN

1.1 Latar Belakang Masalah

Industri otomotif merupakan salah satu pilar utama perekonomian Indonesia yang memberikan kontribusi signifikan terhadap penerimaan pajak, penyerapan tenaga kerja, serta penguatan rantai pasok manufaktur nasional. Berbeda dengan sepeda motor yang berfungsi sebagai kebutuhan primer bagi kalangan menengah bawah, pasar mobil mencerminkan daya beli kelas menengah dan menjadi salah satu barometer penting kondisi ekonomi nasional. Data yang diterbitkan oleh Gabungan Industri Kendaraan Bermotor Indonesia (Gaikindo) menunjukkan bahwa total penjualan wholesales mobil lokal selama periode 2016 hingga 2025 mencapai lebih dari 9,4 juta unit secara kumulatif, dengan rata-rata penjualan tahunan berkisar antara 800.000 hingga 1.150.000 unit pada kondisi pasar normal.

Penjualan wholesales mobil lokal Indonesia menunjukkan tren yang relatif stabil namun fluktuatif dalam kisaran normal sepanjang 2016–2019. Capaian tertinggi dicatat pada Maret 2018 dan Maret 2023 masing-masing sebesar 102.000 dan 101.000 unit per bulan, sementara secara tahunan rekor tertinggi tercatat pada 2018 dengan total 1.150.000 unit. Pola fluktuasi ini mencerminkan adanya siklus musiman yang berkaitan erat dengan kalender ekonomi nasional, termasuk periode Lebaran, tahun ajaran baru, dan program promosi akhir tahun dari agen tunggal pemegang merek (ATPM).

Namun, stabilitas tersebut mengalami gangguan yang tidak pernah terjadi sebelumnya ketika pandemi COVID-19 melanda Indonesia pada awal 2020. Kebijakan Pembatasan Sosial Berskala Besar (PSBB) yang mulai efektif pada April 2020 menyebabkan penutupan showroom, penghentian produksi, dan keruntuhan permintaan secara hampir seketika. Dampaknya bersifat ekstrem dan asimetris: penjualan Mei 2020 hanya mencapai 4.000 unit, angka yang setara dengan 4,7% saja dari rata-rata bulan yang sama pada 2016–2019. Sementara April 2020 hanya 8.000 unit, turun 90,5% dibandingkan April 2019. Secara tahunan, total penjualan 2020 anjlok 48,7% menjadi 533.000 unit dari 1.038.000 unit pada 2019, yang merupakan penurunan tahunan paling tajam dalam sejarah industri otomotif Indonesia.

Yang menjadikan data ini semakin menarik dari perspektif metodologi peramalan adalah pola pemulihan yang tidak linear dan bertahap setelah pandemi. Penjualan kembali meningkat 66,6% pada 2021 (888.000 unit) dan memulihkan diri ke level pra-pandemi pada 2022 (1.047.000 unit). Namun demikian, berbeda dengan industri sepeda motor yang mengalami stabilisasi, industri mobil justru memperlihatkan tren penurunan berkelanjutan pasca-pemulihan: 2023 turun 4,0% menjadi 1.005.000 unit, 2024 turun lebih dalam 14,1% menjadi 863.000 unit, dan 2025 kembali terkoreksi 6,7% menjadi 805.000 unit. Tren kontraksi beruntun ini mengindikasikan adanya pergeseran struktural pada sisi permintaan yang belum sepenuhnya dapat dijelaskan oleh pola historis pra-pandemi.

Karakteristik data tersebut berfluktuasi secara musiman dan data yang menunjukkan adanya efek ekstrem akibat pandemi, diikuti pemulihan parsial dan kontraksi struktural menciptakan tantangan metodologi yang fundamental bagi model peramalan deret waktu konvensional. Model Seasonal ARIMA (SARIMA) yang mengandalkan ekstrapolasi pola historis secara implisit mengasumsikan bahwa struktur data masa lalu representatif terhadap masa depan. Asumsi ini diuji ketika data mengandung peristiwa interupsi berskala pandemi yang tidak memiliki precedent dalam rentang observasi model (Box et al., 2015).

Dalam literatur statistika deret waktu, pendekatan yang dikembangkan untuk mengatasi permasalahan structural break adalah analisis intervensi (intervention analysis), yang pertama kali diperkenalkan secara sistematis oleh Box dan Tiao (1975). Analisis intervensi memungkinkan model untuk secara eksplisit memasukkan dampak sebuah peristiwa seperti kebijakan lockdown, bencana, atau krisis ekonomi ke dalam persamaan model, sehingga estimasi parameter tidak terdistorsi oleh outlier ekstrem akibat gangguan tersebut. Model SARIMA dengan komponen intervensi (SARIMA+Intervensi) secara teoretis mampu menghasilkan estimasi yang lebih akurat dan tidak bias dibandingkan SARIMA konvensional pada data yang mengandung structural break (Tsay, 1988).

Di sisi lain, pendekatan alternatif yang lebih adaptif adalah metode Exponential Smoothing State Space Model (ETS) atau yang dikenal sebagai Holt-Winters. Model ini menggunakan pembobotan eksponensial terhadap observasi historis, sehingga secara otomatis memberikan bobot lebih tinggi pada data yang lebih baru dan bobot lebih rendah pada data yang lebih lama. Karakteristik ini secara inheren membuat model ETS lebih adaptif terhadap pergeseran level dan tren dalam data, termasuk pada periode pemulihan pasca-pandemi, dibandingkan model ARIMA yang bersifat global (Hyndman & Athanasopoulos, 2021).

Meskipun ketiga pendekatan SARIMA, SARIMA+Intervensi, dan ETS/Holt-Winters telah banyak diteliti secara terpisah, perbandingan komprehensif ketiganya pada data penjualan otomotif Indonesia yang mengalami structural break akibat pandemi masih sangat terbatas dalam literatur domestik. Sebagian besar penelitian peramalan penjualan kendaraan di Indonesia menggunakan SARIMA tunggal tanpa mempertimbangkan dampak intervensi pandemi secara eksplisit, sehingga menghasilkan model yang akurat pada kondisi normal namun rentan mengalami degradasi kinerja signifikan ketika dihadapkan pada data pasca-pandemi (Oktavia et al., 2021; Santoso & Suprihatin, 2020).

Kesenjangan ini menjadi justifikasi utama penelitian ini. Dengan menggunakan data penjualan wholesales mobil domestik dari Gaikindo pada rentan periode Januari 2016 hingga Desember 2025 (120 observasi bulanan), penelitian ini secara sistematis membangun, mengestimasi, dan membandingkan kinerja tiga model peramalan: (1) SARIMA konvensional, (2) SARIMA dengan komponen intervensi pandemi COVID-19, dan (3) model ETS/Holt-Winters. Ketiganya dievaluasi menggunakan data uji out-of-sample periode 2024–2025 untuk menjawab pertanyaan mendasar: model manakah yang paling akurat dalam meramalkan penjualan mobil wholesales Indonesia pada time series yang mengalami structural break akibat pandemi?

Tabel 1.1 Ringkasan Data Penjualan Wholesales Mobil Lokal Indonesia 2016–2025

Tahun	Total (ribu unit)	Rata-rata/Bulan	Minimum	Maksimum	Pertumb. YoY
2016	1.060	88,3	63	100	—
2017	1.079	89,9	66	101	+1,8%
2018	1.150	95,8	59	107	+6,6%
2019	1.038	86,5	60	109	−9,7%
2020	533	44,4	4 (Mei)	80	−48,7%
2021	888	74,0	49	97	+66,6%
2022	1.047	87,2	49	105	+17,9%
2023	1.005	83,8	59	101	−4,0%
2024	863	71,9	49	80	−14,1%
2025	805	67,1	51	94	−6,7%

Sumber: Gaikindo (2025), diolah penulis. Satuan: ribuan unit/bulan.

Tabel 1.1 memperlihatkan secara jelas tiga fase yang berbeda secara struktural: fase pra-pandemi (2016–2019) dengan rata-rata tahunan 1.082.000 unit dan volatilitas rendah; fase pandemi (2020–2021) dengan kontraksi ekstrem hingga 533.000 unit dan pemulihan; serta fase pasca-pandemi (2022–2025) yang memperlihatkan anomali berupa tren penurunan yang persisten meskipun kondisi mobilitas masyarakat telah pulih sepenuhnya. Tren penurunan beruntun 2023–2025 ini menjadi fenomena yang secara khusus perlu diakomodasi oleh model peramalan dalam menghasilkan proyeksi yang akurat dan representatif.

1.2 Rumusan Masalah

Berdasarkan latar belakang dan research gap yang telah diidentifikasi, penelitian ini merumuskan tiga pertanyaan penelitian sebagai berikut:

1. Bagaimana karakteristik pola tren jangka panjang dan pola musiman periodik penjualan wholesales mobil lokal Indonesia yang diterbitkan oleh Gaikindo untuk periode Januari 2016 hingga Desember 2025, termasuk identifikasi dampak dan profil gangguan struktural akibat pandemi COVID-19 pada 2020?
2. Seberapa akurat model SARIMA konvensional, model SARIMA dengan komponen intervensi pandemi COVID-19 (SARIMA+Intervensi), dan model ETS/Holt-Winters multiplicative dalam meramalkan penjualan wholesales mobil lokal Indonesia pada data uji out-of-sample periode 2024–2025, diukur menggunakan MAPE, RMSE, dan MAE?
3. Apakah penerapan komponen intervensi pandemi COVID-19 secara eksplisit ke dalam model SARIMA mampu meningkatkan akurasi peramalan secara signifikan

dibandingkan SARIMA konvensional, dan model manakah di antara ketiga pendekatan yang paling akurat dalam meramalkan penjualan mobil wholesales Indonesia pada time series yang mengalami structural break?

Tabel. 1.2 Pemetaan Rumusan Masalah, Model, dan Metode Evaluasi

RM	Fokus Pertanyaan	Model yang Terlibat	Metode / Alat Evaluasi
1	Karakteristik pola tren dan musiman + profil structural break pandemi	—	Dekomposisi, plot ACF/PACF, statistik deskriptif, indeks musiman
2	Akurasi out-of-sample ketiga model pada data uji 2024–2025	Model 1 (SARIMA), Model 2 (SARIMA+Intervensi), Model 3 (ETS/HW)	MAPE, RMSE, MAE — kategori Lewis (1982)
3	Perbandingan model terbaik: apakah intervensi meningkatkan akurasi?	Model 1 vs Model 2 vs Model 3	Seleksi AIC/BIC, Diebold-Mariano test, ranking akurasi

Sumber: Diolah penulis.

1.3 Tujuan Penelitian

Sesuai dengan tiga rumusan masalah yang ditetapkan, penelitian ini memiliki tujuan sebagai berikut:

1. Mengidentifikasi dan mendeskripsikan secara komprehensif karakteristik pola tren jangka panjang, pola musiman periodik, dan profil gangguan struktural akibat pandemi COVID-19 yang terkandung dalam data penjualan wholesales mobil lokal Indonesia periode Januari 2016 hingga Desember 2025 berdasarkan data resmi Gaikindo.
2. Membangun, mengestimasi, dan mengevaluasi akurasi peramalan dari tiga model secara komparatif yaitu: (1) SARIMA konvensional, (2) SARIMA dengan komponen intervensi pandemi COVID-19, dan (3) ETS/Holt-Winters multiplicative terhadap data uji out-of-sample periode 2024–2025 menggunakan metrik MAPE, RMSE, dan MAE.
3. Menentukan model yang paling akurat di antara ketiga pendekatan dalam meramalkan penjualan mobil wholesales Indonesia pada time series yang mengandung structural break, serta mengkuantifikasi sejauh mana penerapan komponen intervensi pandemi COVID-19 mampu meningkatkan akurasi prediksi dibandingkan SARIMA konvensional dan ETS/Holt-Winters.

1.4 Manfaat Penelitian

1.4.1 Manfaat Teoritis

Secara teoritis, penelitian ini memberikan kontribusi pada pengembangan literatur peramalan deret waktu dalam tiga aspek utama.

1. **Bukti Empiris Komparatif pada Data Structural Break.** Penelitian ini menyajikan bukti empiris yang sistematis dan terukur mengenai perbedaan kinerja antara SARIMA konvensional, SARIMA+Intervensi, dan ETS/Holt-Winters pada data time series yang mengalami gangguan struktural berskala pandemi. Kontribusi ini mengisi kesenjangan literatur domestik yang selama ini didominasi oleh studi SARIMA tunggal tanpa analisis intervensi.
2. **Penguatan Metodologi Analisis Intervensi.** Penelitian ini mendemonstrasikan implementasi praktis analisis intervensi Box-Tiao (1975) pada konteks data penjualan kendaraan bermotor di negara berkembang, memberikan referensi metodologis yang dapat diadaptasi untuk analisis serupa pada sektor industri lain yang terdampak gangguan sistemik.
3. **Validasi Kriteria Pemilihan Model pada Data Tidak Stasioner.** Penelitian ini berkontribusi pada diskusi mengenai relevansi kriteria AIC/BIC dan metrik akurasi out-of-sample (MAPE, RMSE, MAE) dalam kondisi di mana data pelatihan mengandung anomali ekstrem, memberikan wawasan tentang keandalan masing-masing kriteria sebagai panduan seleksi model dalam kondisi data yang tidak ideal.

1.4.2 Manfaat Praktis

Secara praktis, hasil penelitian ini memberikan manfaat langsung bagi beberapa kelompok pemangku kepentingan di ekosistem industri otomotif Indonesia.

1. **Bagi Pabrikan dan Agen Tunggal Pemegang Merek (ATPM).** Model peramalan terpilih beserta proyeksi yang dihasilkan dapat digunakan sebagai alat bantu perencanaan kapasitas produksi, manajemen persediaan kendaraan dan suku cadang, serta penjadwalan distribusi ke dealer dalam siklus perencanaan tahunan. Identifikasi pola musiman secara empiris juga memberikan panduan operasional untuk optimalisasi waktu peluncuran produk dan kampanye promosi.
2. **Bagi Jaringan Dealer dan Industri Pembiayaan.** Proyeksi volume penjualan bulanan beserta interval ketidakpastian yang dihasilkan model dapat dimanfaatkan oleh dealer sebagai basis negosiasi target penjualan dengan ATPM, dan oleh lembaga pembiayaan otomotif sebagai acuan proyeksi penyaluran kredit kendaraan bermotor dalam pengelolaan risiko portofolio.
3. **Bagi Regulator dan Pengambil Kebijakan.** Data dan model yang dikembangkan dalam penelitian ini dapat menjadi referensi bagi Kementerian Perindustrian dan Kementerian Keuangan dalam pemantauan kondisi pasar otomotif nasional sebagai salah satu indikator daya beli kelas menengah, serta dalam perancangan stimulus fiskal yang tepat sasaran ketika industri menghadapi tekanan eksternal.

4. Bagi Komunitas Akademis. Penelitian ini menyediakan dataset yang telah terstruktur dan tervalidasi, beserta kerangka metodologi analisis intervensi yang dapat dijadikan titik awal (starting point) bagi penelitian lanjutan yang mengeksplorasi metode peramalan yang lebih canggih seperti SARIMA-GARCH, model machine learning, atau pendekatan ensemble forecasting pada data otomotif Indonesia.

1.5 Batasan Penelitian

Untuk menjaga fokus, kedalaman analisis, dan validitas temuan, penelitian ini dibatasi pada hal-hal berikut.

1. Cakupan Data. Data yang digunakan adalah data penjualan wholesales (dari pabrik/ATPM ke dealer) secara agregat total pasar mobil lokal yang bersumber dari publikasi resmi Gaikindo periode Januari 2016 hingga Desember 2025 (120 observasi bulanan). Penelitian tidak mencakup analisis per merek, per segmen kendaraan (MPV, sedan, SUV, city car), per wilayah distribusi, maupun data penjualan retail (dari dealer ke konsumen akhir).
2. Model yang Dibandingkan. Penelitian ini membatasi perbandingan pada tiga model peramalan: SARIMA konvensional (Model 1), SARIMA dengan komponen intervensi COVID-19 (Model 2), dan ETS/Holt-Winters multiplicative (Model 3). Metode machine learning, deep learning (LSTM, Transformer), maupun model hybrid tidak dimasukkan dalam lingkup penelitian ini.
3. Spesifikasi Intervensi. Komponen intervensi yang dimodelkan dalam Model 2 dibatasi pada dampak pandemi COVID-19 yang direpresentasikan sebagai step function dan pulse function pada periode April 2020 hingga Desember 2021. Gangguan struktural lain seperti perubahan kebijakan fiskal, fluktuasi nilai tukar, atau krisis ekonomi regional tidak dimodelkan sebagai intervensi terpisah.
4. Horizon Peramalan. Evaluasi akurasi dilakukan secara out-of-sample terhadap data uji periode Januari 2024 hingga Desember 2025 (24 observasi), dengan rasio training:testing sebesar 96:24. Peramalan ke depan yang dihasilkan mencakup sisa bulan 2026 (Agustus–Desember 2026) dengan memanfaatkan data aktual Gaikindo Januari–Juli 2026 sebagai titik validasi tambahan.
5. Perangkat Analisis. Seluruh estimasi model, uji diagnostik, dan evaluasi akurasi dilakukan menggunakan IBM SPSS Statistics dengan modul Time Series, yang mendukung estimasi SARIMA, intervensi, dan Holt-Winters. Keterbatasan kapabilitas perangkat lunak ini secara implisit membatasi jenis prosedur statistik yang dapat diterapkan dalam penelitian ini.

BAB 2

TINJAUAN PUSTAKA

2.1 Analisis Deret Waktu

Analisis deret waktu (time series analysis) merupakan cabang statistika yang mempelajari sekumpulan observasi yang dicatat secara berurutan dalam interval waktu yang teratur. Berbeda dari analisis regresi konvensional yang mengasumsikan kebebasan antar-observasi, analisis deret waktu secara eksplisit mengeksplorasi ketergantungan temporal (temporal dependence) antara satu observasi dengan observasi sebelumnya sebagai sumber informasi prediktif utama (Box et al., 2015). Pendekatan ini sangat relevan untuk data ekonomi dan industri yang secara inheren bersifat sekuensial dan memiliki memori historis.

Suatu deret waktu Y_t pada umumnya dapat didekomposisi menjadi empat komponen utama: (1) tren (T_t), yang merepresentasikan pergerakan sistematis jangka panjang; (2) musiman (S_t), yang merupakan fluktuasi periodik berulang dengan frekuensi tetap; (3) siklus (C_t), yang mencerminkan fluktuasi jangka menengah yang tidak sepenuhnya periodik; dan (4) komponen iregular (I_t), yang merepresentasikan variasi acak residual setelah ketiga komponen sistematis tersebut diekstraksi (Chatfield, 2004). Dalam konteks data penjualan otomotif bulanan, komponen musiman dan tren umumnya mendominasi, sementara komponen iregular mencakup dampak dari kejadian tidak terduga seperti pandemi atau perubahan kebijakan.

Konsep stasioneritas merupakan prasyarat fundamental dalam sebagian besar pemodelan deret waktu parametrik. Sebuah proses deret waktu dikatakan stasioner (dalam arti lemah atau wide-sense stationary) apabila memenuhi tiga syarat: nilai rata-rata (mean) bersifat konstan sepanjang waktu, variansi bersifat konstan dan berhingga, serta kovarian antara dua titik waktu hanya bergantung pada jarak (lag) antar keduanya, bukan pada posisi absolutnya dalam waktu (Wei, 2019). Data penjualan kendaraan bermotor umumnya tidak stasioner dalam kondisi aslinya karena mengandung komponen tren dan musiman, sehingga memerlukan transformasi sebelum dapat dimodelkan menggunakan pendekatan ARIMA.

2.2 Model ARIMA dan SARIMA

2.2.1 Autoregressive Integrated Moving Average (ARIMA)

Model Autoregressive Integrated Moving Average atau ARIMA (p, d, q) merupakan kerangka pemodelan deret waktu universal yang dikembangkan secara sistematis oleh Box dan Jenkins (1970/2015) dan telah menjadi standar de facto dalam analisis time series parametrik selama lebih dari lima dekade. Model ARIMA mengintegrasikan tiga komponen utama: komponen autoregressive (AR) yang merepresentasikan ketergantungan linier nilai saat ini terhadap nilai-nilai masa lalu, komponen differencing (I) yang mentransformasi data tidak stasioner menjadi stasioner, dan komponen moving average (MA) yang memodelkan ketergantungan terhadap kesalahan prediksi (residual) masa lalu (Box et al., 2015).

Persamaan umum model ARIMA(p, d, q) dalam notasi operator backshift (B) dinyatakan sebagai:

$$\varphi(B)(1-B)^d Y_t = \theta(B)\varepsilon_t$$

di mana $\varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p$ adalah operator AR berorde p , $\theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$ adalah operator MA berorde q , $(1-B)^d$ adalah operator differencing orde d , dan ε_t adalah proses white noise dengan mean nol dan varians σ^2 .

Prosedur estimasi model ARIMA mengikuti metodologi Box-Jenkins yang bersifat iteratif dan terdiri atas empat tahap utama: (1) identifikasi orde model (p, d, q) melalui analisis plot Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF); (2) estimasi parameter menggunakan metode Maximum Likelihood Estimation (MLE); (3) pemeriksaan diagnostik residual untuk memverifikasi asumsi white noise; dan (4) penggunaan model untuk peramalan (forecasting). Apabila hasil diagnostik menunjukkan kecukupan model yang belum memadai, prosedur kembali ke tahap identifikasi untuk merevisi spesifikasi model (Montgomery et al., 2015).

2.2.2 Seasonal ARIMA (SARIMA)

Model Seasonal ARIMA atau SARIMA(p, d, q)(P, D, Q) $_s$ merupakan perluasan alami dari kerangka ARIMA untuk mengakomodasi data yang memiliki pola musiman periodik dengan periode s . Model ini menambahkan komponen autoregressive musiman (SAR) berorde P , komponen differencing musiman (D), dan komponen moving average musiman (SMA) berorde Q pada komponen non-musiman yang ada. Persamaan umum SARIMA dinyatakan sebagai:

$$\Phi_P(B^s)\varphi(B)(1-B^s)^D(1-B)^d Y_t = \Theta_Q(B^s)\theta(B)\varepsilon_t$$

di mana $\Phi_P(B^s) = 1 - \Phi_1 B^s - \dots - \Phi_P B^{Ps}$ adalah operator SAR musiman, $\Theta_Q(B^s) = 1 + \Theta_1 B^s + \dots + \Theta_Q B^{Qs}$ adalah operator SMA musiman, dan $s = 12$ untuk data bulanan (periodesitas tahunan).

Dalam konteks data penjualan mobil bulanan Gaikindo, nilai $s = 12$ karena pola musiman berulang setiap 12 bulan. Model khusus SARIMA(0,1,1)(0,1,1) $_{12}$ — yang dikenal dalam literatur sebagai Airline Model — secara historis terbukti memberikan kinerja yang sangat baik pada berbagai data ekonomi bulanan berpola musiman karena kesederhanaannya dan kemampuannya menangkap perubahan level dan musiman secara adaptif (Hyndman & Athanasopoulos, 2021). Namun, model SARIMA konvensional memiliki kelemahan fundamental ketika data mengandung gangguan struktural (structural break): estimasi parameter dapat terdistorsi secara serius oleh observasi-observasi anomali selama periode interupsi, sehingga menurunkan kualitas prediksi secara keseluruhan.

2.3 Analisis Intervensi (Intervention Analysis)

2.3.1 Konsep Dasar Analisis Intervensi

Analisis intervensi merupakan perluasan metodologis dari kerangka ARIMA yang dikembangkan oleh Box dan Tiao (1975) untuk memodelkan secara eksplisit dampak dari peristiwa diskrit dan teridentifikasi yang memengaruhi dinamika deret waktu. Dalam

kerangka ini, peristiwa eksternal yang menyebabkan perubahan mendadak pada level atau tren data — yang dalam literatur disebut intervensi — dimodelkan sebagai variabel input deterministik tambahan dalam persamaan ARIMA. Pendekatan ini berbeda secara fundamental dari perlakuan konvensional yang membiarkan observasi anomali masuk ke dalam estimasi sebagai residual, yang berpotensi mendistorsi seluruh struktur parameter model (Tsay, 1988).

Gagasan inti dari analisis intervensi adalah bahwa peristiwa eksternal yang menyebabkan structural break dapat diklasifikasikan berdasarkan profil dampaknya terhadap deret waktu. Dua fungsi intervensi dasar yang paling umum digunakan adalah pulse function dan step function, masing-masing merepresentasikan profil dampak yang berbeda secara kualitatif.

2.3.2 Fungsi Intervensi: Pulse dan Step

Pulse function atau impulse intervention mengasumsikan bahwa dampak intervensi bersifat sesaat (transitory) dan hanya mempengaruhi satu periode waktu tertentu, setelah itu deret waktu kembali ke jalur normal. Secara matematis, pulse function didefinisikan sebagai:

$$P_{-t}(T) = 1 \text{ jika } t = T, \text{ dan } 0 \text{ jika } t \neq T$$

T adalah periode waktu ketika intervensi terjadi. Pulse function cocok untuk memodelkan peristiwa satu kali yang tidak meninggalkan efek permanen, seperti gangguan produksi jangka pendek atau kebijakan promosi temporer.

Step function atau level shift mengasumsikan bahwa dampak intervensi bersifat permanen (permanent), menggeser level rata-rata deret waktu secara abrupt pada titik waktu tertentu dan mempertahankan pergeseran tersebut selamanya. Secara matematis, step function didefinisikan sebagai:

$$S_{-t}(T) = 0 \text{ jika } t < T, \text{ dan } 1 \text{ jika } t \geq T$$

Dalam konteks dampak pandemi COVID-19 pada penjualan mobil Indonesia, diperlukan kombinasi kedua fungsi ini. Lockdown yang menyebabkan penurunan ekstrem April–Mei 2020 dapat dimodelkan sebagai pulse function (efek sesaat), sementara pergeseran level yang lebih persisten selama 2020–2021 dapat direpresentasikan sebagai step function yang kemudian dibalik (reversed step) setelah kebijakan relaksasi diberlakukan secara bertahap (Harvey, 1990).

2.3.3 Model SARIMA dengan Komponen Intervensi

Model SARIMA+Intervensi yang dikembangkan dalam penelitian ini mengintegrasikan komponen intervensi COVID-19 ke dalam struktur SARIMA sebagai berikut:

$$Y_{-t} = \omega_0 P_{-t}(T_1) + \delta S_{-t}(T_2) + N_{-t}$$

Y_{-t} adalah nilai observasi penjualan, ω_0 adalah besar dampak sesaat (pulse) pada periode T_1 (April–Mei 2020), δ adalah besaran pergeseran level permanen pada T_2 , dan N_{-t} adalah komponen SARIMA(p,d,q)(P,D,Q)₁₂ yang memodelkan sisa dinamika deret waktu setelah dampak intervensi dikeluarkan.

Keunggulan utama pendekatan ini terletak pada kemampuannya memisahkan secara statistik dampak pandemi dari struktur musiman dan tren alami data. Dengan demikian, parameter SARIMA diestimasi dari data yang telah 'dibersihkan' dari pengaruh intervensi, menghasilkan estimasi yang tidak bias dan lebih representatif terhadap pola normal industri. Hal ini secara teoritis menghasilkan prediksi yang lebih akurat khususnya untuk periode pasca-pandemi di mana data telah kembali ke pola musiman normalnya (Box & Tiao, 1975).

2.4 Model ETS dan Holt-Winters

2.4.1 Exponential Smoothing State Space Model (ETS)

Model Exponential Smoothing State Space (ETS) merupakan kerangka pemodelan yang mengintegrasikan berbagai varian exponential smoothing ke dalam formulasi probabilistik berbasis state space. Nama 'ETS' mengacu pada tiga komponen utama model: Error (E), Trend (T), dan Seasonal (S), yang masing-masing dapat bersifat None (N), Additive (A), atau Multiplicative (M), menghasilkan 30 kemungkinan konfigurasi model yang berbeda (Hyndman & Athanasopoulos, 2021). Kerangka state space ini memungkinkan derivasi interval prediksi secara analitis dan seleksi model otomatis berdasarkan kriteria AIC.

Karakteristik kunci yang membedakan ETS dari ARIMA adalah mekanisme pembobotan eksponensial: observasi yang lebih baru mendapatkan bobot yang secara eksponensial lebih besar dibandingkan observasi yang lebih lama, dengan laju peluruhan bobot dikontrol oleh parameter smoothing. Sifat ini membuat ETS secara inheren lebih adaptif terhadap perubahan level dan tren dalam data, termasuk pergeseran yang terjadi pascapandemi, tanpa memerlukan spesifikasi eksplisit tentang kapan dan bagaimana pergeseran tersebut terjadi (Chatfield, 2004).

2.4.2 Holt-Winters Multiplicative

Varian Holt-Winters multiplicative — yang dalam kerangka ETS dikodifikasikan sebagai ETS(M,A,M) atau ETS(A,A,M) tergantung pada spesifikasi error — secara khusus dirancang untuk data yang memiliki komponen musiman yang besarnya proporsional terhadap level data. Ini berarti amplitudo fluktuasi musiman akan membesar ketika level data tinggi dan mengecil ketika level data rendah — karakteristik yang sering dijumpai pada data penjualan kendaraan di mana musim penjualan tinggi menghasilkan fluktuasi musiman yang lebih besar secara absolut (Winters, 1960).

Persamaan pembaruan (updating equations) Holt-Winters multiplicative adalah:

$$\text{Level: } l_t = \alpha(y_t / s_{t-m}) + (1-\alpha)(l_{t-1} + b_{t-1})$$

$$\text{Tren: } b_t = \beta(l_t - l_{t-1}) + (1-\beta)b_{t-1}$$

$$\text{Musiman: } s_t = \gamma(y_t / l_t) + (1-\gamma)s_{t-m}$$

$$\text{Ramalan: } \hat{y}_{t+h} = (l_t + h \cdot b_t) \cdot s_{t+h-m(k+1)}$$

di mana $\alpha, \beta, \gamma \in [0,1]$ adalah parameter smoothing untuk level, tren, dan komponen musiman; $m = 12$ adalah panjang periode musiman; dan $k = \lfloor (h-1)/m \rfloor$.

Parameter smoothing α , β , dan γ diestimasi secara otomatis dengan meminimalkan jumlah kuadrat kesalahan prediksi (Sum of Squared Errors) menggunakan algoritma optimisasi nonlinear. Nilai α yang mendekati 1 mengindikasikan bobot tinggi pada observasi terkini (sangat adaptif), sementara nilai yang mendekati 0 mengindikasikan memori jangka panjang yang lebih panjang.

2.5 Structural Break dan Gangguan Pandemi COVID-19

2.5.1 Definisi dan Dampak *Structural Break* pada Model Deret Waktu

Structural break mengacu pada perubahan mendadak dalam parameter yang mengatur proses pembangkit data (data-generating process) suatu deret waktu, yang terjadi pada titik waktu tertentu. Perubahan ini dapat berupa pergeseran mean (level shift), perubahan kemiringan tren (trend change), perubahan varians (variance break), atau perubahan struktur autokorelasi secara fundamental (Tsay, 1988). Kehadiran structural break tanpa penanganan eksplisit akan mengakibatkan estimasi parameter model yang terdistorsi, uji statistik yang tidak valid, dan prediksi yang secara sistematis bias ke arah nilai anomali.

Dari perspektif dampaknya pada estimasi SARIMA, observasi-observasi yang terpengaruh oleh structural break berfungsi sebagai outlier berpengaruh tinggi (high-leverage outliers) yang secara tidak proporsional mendistorsi nilai rata-rata dan struktur autokorelasi sampel. Akibatnya, parameter AR dan MA yang diestimasi tidak lagi merepresentasikan dinamika normal data, melainkan merupakan campuran antara dinamika normal dan efek anomali yang sulit diinterpretasikan secara substantif (Harvey, 1990).

2.5.2 Profil Gangguan COVID-19 pada Industri Otomotif

Pandemi COVID-19 menimbulkan gangguan multidimensional yang unik pada industri otomotif Indonesia. Dari sisi permintaan, pembatasan mobilitas dan ketidakpastian ekonomi menyebabkan penundaan pembelian kendaraan secara massal. Dari sisi penawaran, gangguan rantai pasok komponen — terutama semikonduktor dan komponen dari China — serta penutupan lini produksi membatasi kemampuan pasokan ATPM. Interaksi antara guncangan permintaan dan penawaran yang terjadi simultan ini menghasilkan profil penurunan yang sangat tajam dan asimetris.

Data Gaikindo menunjukkan bahwa dampak pandemi pada penjualan mobil bersifat jauh lebih ekstrem dibandingkan krisis ekonomi 1997–1998 dalam hal kecepatan kontraksi. Penjualan April 2020 hanya 8.000 unit dan Mei 2020 mencapai titik terendah 4.000 unit — setara dengan sekitar 4–5% dari rata-rata normal — mengindikasikan praktis terhentinya aktivitas transaksi secara total selama periode PSBB paling ketat. Pola pemulihan kemudian berlangsung secara bertahap dan tidak simetris, dengan 2021 mencatat pemulihan kuat namun diikuti tren penurunan kembali pada 2023–2025 yang diduga terkait faktor struktural seperti migrasi konsumen ke kendaraan listrik dan tekanan daya beli kelas menengah.

2.6 Kriteria Seleksi dan Evaluasi Model

2.6.1 Kriteria Informasi: AIC dan BIC

Pemilihan model terbaik di antara kandidat-kandidat model dilakukan menggunakan kriteria informasi yang mengukur keseimbangan antara kecocokan model dengan data (goodness-of-fit) dan kompleksitas model (parsimony). Akaike Information Criterion (AIC) dan Bayesian Information Criterion (BIC) atau Schwarz Information Criterion (SIC) adalah dua kriteria yang paling luas digunakan dalam seleksi model deret waktu.

AIC didefinisikan sebagai:

$$AIC = -2 \ln(\hat{L}) + 2k$$

dan BIC sebagai:

$$BIC = -2 \ln(\hat{L}) + k \ln(n)$$

di mana $\hat{L}$ adalah nilai maksimum fungsi likelihood, k adalah jumlah parameter yang diestimasi, dan n adalah jumlah observasi. Nilai AIC atau BIC yang lebih kecil mengindikasikan model yang lebih baik. BIC menerapkan penalti kompleksitas yang lebih besar dibandingkan AIC ($k \cdot \ln(n)$ vs $2k$), sehingga cenderung memilih model yang lebih parsimoni, khususnya untuk sampel besar (Burnham & Anderson, 2002).

2.6.2 Metrik Akurasi Peramalan

Evaluasi akurasi peramalan out-of-sample dilakukan menggunakan tiga metrik utama yang saling komplementer: MAPE, RMSE, dan MAE. Ketiga metrik ini mengukur aspek berbeda dari kesalahan prediksi sehingga memberikan gambaran yang lebih komprehensif tentang kinerja model dibandingkan menggunakan satu metrik tunggal.

Mean Absolute Percentage Error (MAPE) mengukur rata-rata kesalahan relatif dalam persentase dan bersifat scale-independent, sehingga memungkinkan perbandingan akurasi antar periode dan antar dataset yang berbeda skala:

$$MAPE = (1/n) \sum |(Y_t - \hat{Y}_t) / Y_t| \times 100\%$$

Root Mean Square Error (RMSE) memberikan bobot yang lebih besar pada kesalahan besar karena mengkuadratkan selisih sebelum dirata-ratakan, sehingga lebih sensitif terhadap outlier prediksi:

$$RMSE = \sqrt{(1/n) \sum (Y_t - \hat{Y}_t)^2}$$

Mean Absolute Error (MAE) mengukur rata-rata kesalahan absolut dan lebih robust terhadap outlier dibandingkan RMSE karena tidak mengkuadratkan kesalahan:

$$MAE = (1/n) \sum |Y_t - \hat{Y}_t|$$

Interpretasi nilai MAPE dalam penelitian ini mengacu pada kriteria Lewis (1982): MAPE < 10% dikategorikan 'Sangat Baik' (Highly Accurate), 10%–20% 'Baik' (Good), 20%–50% 'Cukup' (Reasonable), dan $\geq 50\%$ 'Tidak Akurat' (Inaccurate).

2.6.3 Uji Perbandingan Akurasi: Diebold-Mariano

Untuk menentukan apakah perbedaan akurasi antar model bersifat statistis signifikan atau sekadar variasi acak, penelitian ini menerapkan uji Diebold-Mariano (DM test) yang dikembangkan oleh Diebold dan Mariano (1995). Uji ini secara formal menguji hipotesis nol bahwa dua model memiliki akurasi peramalan yang setara, melawan hipotesis alternatif bahwa salah satu model secara signifikan lebih akurat.

Statistik uji DM didefinisikan sebagai:

$$DM = \bar{d} / \sqrt{\text{Var}(\bar{d})} \sim N(0,1)$$

di mana $\bar{d}$ adalah rata-rata perbedaan fungsi kehilangan (loss differential) antara dua model yang dibandingkan, dan $\text{Var}(\bar{d})$ adalah variansi estimasi dari $\bar{d}$. Penolakan H_0 pada $\alpha = 0,05$ mengkonfirmasi bahwa perbedaan akurasi antar model bersifat statistis signifikan (Diebold & Mariano, 1995).

2.7 Industri Otomotif dan Peran Gaikindo

Gabungan Industri Kendaraan Bermotor Indonesia (Gaikindo) merupakan asosiasi resmi yang menghimpun dan mempublikasikan data statistik industri otomotif nasional secara bulanan. Gaikindo beranggotakan seluruh ATPM yang beroperasi secara resmi di Indonesia dan mewakili lebih dari 40 merek kendaraan roda empat atau lebih. Data yang dipublikasikan mencakup penjualan wholesales (dari ATPM ke dealer), penjualan retail (dari dealer ke konsumen), dan data produksi domestik.

Penjualan wholesales menjadi pilihan data utama dalam penelitian ini karena mencerminkan keputusan produksi dan distribusi ATPM berdasarkan perkiraan permintaan jangka dekat, dan umumnya tersedia lebih awal serta lebih konsisten dibandingkan data retail. Penjualan wholesales berkorelasi tinggi dengan data retail namun dapat menunjukkan lead atau lag dalam siklus stok dealer, yang menjadikannya variabel yang menarik untuk dimodelkan secara deret waktu (Gaikindo, 2025).

Data wholesales Gaikindo memiliki beberapa karakteristik yang relevan untuk pemodelan deret waktu. Pertama, data tersedia dalam frekuensi bulanan dengan konsistensi metodologi yang terjaga. Kedua, data bersifat agregat total pasar sehingga meminimalkan noise yang berasal dari dinamika persaingan antar merek individual. Ketiga, data mencakup rentang waktu yang cukup panjang — sejak awal 2000-an — untuk memungkinkan pemodelan pola musiman dan tren jangka panjang yang andal. Keempat, data merekam secara lengkap seluruh fase anomali pandemi COVID-19, menjadikannya dataset ideal untuk studi analisis intervensi.

2.8 State of the Art

Sub bab ini menyajikan pemetaan sistematis terhadap penelitian-penelitian terdahulu yang relevan dengan topik penelitian ini, mencakup studi peramalan deret waktu pada data otomotif, penerapan analisis intervensi pada data ekonomi yang mengandung structural break pandemi, serta perbandingan SARIMA dengan metode alternatif. Pemetaan ini

bertujuan mengidentifikasi posisi penelitian saat ini dalam lanskap literatur yang ada serta menegaskan orisinalitas kontribusinya.

2.8.1 Penelitian Peramalan Penjualan Kendaraan Bermotor

Saengsook dan Wannakomol (2019) melakukan studi peramalan penjualan kendaraan di Thailand menggunakan model SARIMA terhadap data bulanan 2010–2018. Penelitian ini menemukan bahwa model SARIMA(0,1,1)(0,1,1)₁₂ memberikan nilai MAPE di bawah 8% pada kondisi pasar yang stabil, mengkonfirmasi superioritas model seasonal dibandingkan model ARIMA non-seasonal untuk data dengan periodisitas kuat. Namun, penelitian ini tidak menghadapi kondisi structural break dan dilakukan sebelum pandemi COVID-19, sehingga generalisabilitasnya terbatas pada konteks pasar yang relatif stabil.

Santoso dan Suprihatin (2020) menerapkan SARIMA pada data permintaan produk manufaktur berpola musiman di Indonesia dan melaporkan MAPE 6,7% pada data uji. Penelitian ini memperkuat relevansi SARIMA untuk data ekonomi Indonesia namun kembali terbatas pada kondisi pra-pandemi. Dalam penelitian domestik tentang sepeda motor, Oktavia et al. (2021) menemukan bahwa SARIMA(0,1,1)(0,1,1)₁₂ memberikan estimasi yang baik untuk dealer regional di Jawa Tengah, meskipun penelitian tersebut mencakup sebagian data pandemi tanpa penanganan intervensi yang eksplisit.

Penelitian yang lebih kontekstual terhadap tantangan pandemi dilakukan oleh Petropoulos et al. (2022) yang mengevaluasi kinerja 26 metode peramalan pada berbagai kategori data yang terdampak COVID-19. Hasil studi ini menunjukkan bahwa tidak ada satu metode yang secara konsisten unggul di semua kategori data, namun model yang mengakomodasi structural break secara eksplisit — baik melalui intervensi maupun pendekatan adaptif seperti ETS — cenderung lebih robust dibandingkan model linear global pada data dengan anomali ekstrem.

2.8.2 Penerapan Analisis Intervensi pada Data Ekonomi

Studi seminal Box dan Tiao (1975) yang memperkenalkan analisis intervensi mendemonstrasikan penerapannya pada data polusi udara di Los Angeles dan penjualan roti di Amerika Serikat setelah intervensi kebijakan. Kerangka ini kemudian diadaptasi secara luas untuk berbagai konteks ekonomi, termasuk analisis dampak kebijakan moneter (Harvey, 1990) dan evaluasi dampak krisis keuangan terhadap variabel ekonomi makro.

Dalam konteks pandemi COVID-19 secara spesifik, Papastefanopoulos et al. (2021) mendemonstrasikan efektivitas ARIMA+Intervensi dibandingkan ARIMA murni dalam meramalkan indikator ekonomi yang terdampak lockdown di Eropa. Penelitian tersebut menemukan bahwa penambahan komponen intervensi mampu mengurangi MAPE rata-rata hingga 35–40% dibandingkan ARIMA konvensional pada periode evaluasi pasca-lockdown. Temuan ini memberikan landasan empiris yang kuat bagi hipotesis penelitian saat ini bahwa SARIMA+Intervensi akan mengungguli SARIMA konvensional pada data penjualan mobil Indonesia yang mengandung structural break pandemi.

Di tingkat domestik, penerapan analisis intervensi pada data industri otomotif Indonesia masih sangat terbatas dalam literatur yang terpublikasi. Sebagian besar penelitian

peramalan penjualan kendaraan di Indonesia menggunakan SARIMA atau metode smoothing tanpa mengintegrasikan komponen intervensi pandemi secara formal, meskipun rentang data yang digunakan mencakup periode 2020–2021. Kesenjangan metodologis ini secara langsung memotivasi desain penelitian saat ini.

2.8.3 Perbandingan SARIMA, Intervensi, dan *ETS/Holt-Winters*

Makridakis et al. (1982) dalam studi M-Competition yang menjadi tonggak penting dalam literatur peramalan menemukan bahwa metode yang lebih sederhana, termasuk Holt-Winters, secara mengejutkan sering mengungguli metode yang lebih kompleks seperti ARIMA pada evaluasi out-of-sample. Temuan ini kemudian dikonfirmasi kembali dalam M4-Competition (Makridakis et al., 2020) yang melibatkan 100.000 deret waktu dan 61 metode, di mana hybrid ETS-ARIMA terbukti memberikan kinerja terbaik secara rata-rata.

Khususnya pada data yang mengandung structural break, Nikolopoulos et al. (2021) menemukan dalam sebuah studi lintas-sektor bahwa model ETS dengan adaptivitas tinggi (parameter smoothing besar) menunjukkan pemulihan akurasi yang lebih cepat pasca-pandemi dibandingkan ARIMA konvensional, karena bobot eksponensial secara otomatis mengurangi pengaruh data periode pandemi dalam estimasi. Namun, penelitian tersebut tidak membandingkan ETS dengan ARIMA+Intervensi, sehingga pertanyaan tentang model mana yang paling optimal untuk data dengan structural break yang teridentifikasi jelas masih terbuka.

2.8.4 Orisinalitas Penelitian

Berdasarkan pemetaan literatur di atas, penelitian ini berkontribusi pada pengisian tiga celah pengetahuan yang spesifik dan teridentifikasi. Tabel 2.1 menyajikan perbandingan sistematis penelitian ini dengan studi-studi terdahulu yang paling relevan.

Tabel 2.1 Pemetaan State of the Art: Penelitian Ini vs Studi Terdahulu

Penelitian	Data / Konteks	Model	Intervensi	Pandemi	DM Test	Data Ind.
Saengsook & Wannakomol (2019)	Otomotif Thailand	SARIMA	X	X	X	X
Santoso & Suprihatin (2020)	Manufaktur Indonesia	SARIMA	X	X	X	X
Oktavia et al. (2021)	Motor Indonesia	SARIMA	X	Parsial	X	✓
Papastefanopoulos et al. (2021)	Ekonomi makro Eropa	ARIMA + Intervensi	✓	✓	X	X
Nikolopoulos et al. (2021)	Multi-sektor	ARIMA vs ETS	X	✓	✓	X
Penelitian ini (2026)	Mobil Gaikindo Indonesia	SARIMA + Intervensi + ETS	✓	✓	✓	✓

Sumber: Diolah penulis dari berbagai referensi. Ket: ✓ = ada, ✗ = tidak ada/tidak dibahas. Data Ind. = Data Indonesia.

Berdasarkan Tabel 2.1, terdapat tiga kontribusi orisinal penelitian ini yang secara kumulatif belum pernah dilakukan dalam literatur yang ada. Pertama, penelitian ini merupakan studi pertama yang secara sistematis membandingkan tiga model (SARIMA, SARIMA+Intervensi, ETS/Holt-Winters) secara bersamaan pada data penjualan mobil wholesales Indonesia yang mencakup keseluruhan siklus pandemi COVID-19. Kedua, analisis intervensi COVID-19 diterapkan secara formal dan eksplisit pada konteks industri otomotif domestik, mengisi kesenjangan metodologis yang nyata dalam literatur peramalan otomotif Indonesia. Ketiga, penggunaan uji Diebold-Mariano untuk memverifikasi signifikansi statistik perbedaan akurasi antar model memberikan rigor metodologis yang lebih tinggi dibandingkan sebagian besar studi terdahulu yang hanya membandingkan nilai MAPE secara deskriptif.

BAB 3

METODE PENELITIAN

3.1 Jenis dan Sumber Data

3.1.1 Jenis Data

Penelitian ini menggunakan data kuantitatif berupa data deret waktu (time series) penjualan mobil wholesales di Indonesia yang bersifat sekunder. Data sekunder dipilih karena informasi yang dibutuhkan telah tersedia dalam bentuk terstruktur, terdokumentasi secara resmi, dan dipublikasikan secara rutin oleh lembaga industri yang berwenang, sehingga tingkat keandalan serta validitasnya dapat dipertanggungjawabkan secara ilmiah (Sugiyono, 2019).

Data yang digunakan merupakan data runtun waktu (time series) dengan frekuensi bulanan (monthly frequency). Frekuensi bulanan dipilih karena tiga alasan. Pertama, data ini tersedia secara konsisten dan tanpa jeda dari Gaikindo sejak awal 2000-an. Kedua, frekuensi bulanan cukup granular untuk menangkap pola musiman tahunan ($s = 12$) yang merupakan karakteristik dominan data penjualan otomotif Indonesia. Ketiga, dengan rentang waktu 10 tahun (120 observasi), jumlah data memadai secara statistis untuk membangun dan mengevaluasi tiga model peramalan secara komparatif (Box et al., 2015). Satuan data adalah jumlah unit mobil yang disalurkan dari Agen Tunggal Pemegang Merek (ATPM) kepada jaringan dealer di seluruh Indonesia per bulan kalender — yang dalam terminologi industri disebut data penjualan wholesales.

Data penjualan wholesales bersifat agregat total pasar, artinya mencerminkan penjumlahan seluruh unit dari semua merek dan semua segmen kendaraan roda empat atau lebih yang dipasarkan oleh anggota Gaikindo. Pendekatan agregat ini dipilih untuk meminimalkan noise dari dinamika persaingan antar-merek, sehingga model yang dikembangkan merepresentasikan perilaku pasar otomotif nasional secara keseluruhan.

3.1.2 Sumber Data

Data dalam penelitian ini bersumber dari Gabungan Industri Kendaraan Bermotor Indonesia (Gaikindo), yang merupakan asosiasi resmi industri otomotif nasional beranggotakan seluruh ATPM yang beroperasi secara legal di Indonesia. Gaikindo memiliki mandat untuk menghimpun, mengolah, dan mempublikasikan statistik penjualan kendaraan bermotor secara bulanan melalui situs resminya di www.gaikindo.or.id, sehingga data yang diperoleh memiliki otoritas dan legitimasi yang tidak diragukan sebagai acuan statistik industri (Gaikindo, 2025).

Mekanisme pengumpulan data Gaikindo dilakukan melalui pelaporan wajib bulanan oleh seluruh anggota ATPM. Setiap ATPM melaporkan volume unit yang telah dikirimkan secara fisik kepada jaringan dealer pada periode bulan yang bersangkutan. Data yang terkumpul kemudian diverifikasi, direkonsiliasi, dan dipublikasikan oleh Gaikindo dalam bentuk tabel rekap bulanan yang mencakup rincian per merek, per segmen kendaraan, dan

total pasar. Dalam penelitian ini, yang digunakan adalah data total pasar (all brands aggregate) untuk memperoleh gambaran dinamika industri secara makro.

3.1.3 Periode dan Cakupan Data

Rentang waktu pengamatan mencakup periode Januari 2016 hingga Desember 2025, sehingga diperoleh sebanyak 120 titik observasi bulanan. Penetapan titik awal pada Januari 2016 didasarkan pada pertimbangan bahwa periode ini menandai fase konsolidasi pasar paska-perlambatan 2013–2015, sehingga data mencerminkan kondisi pasar yang representatif sebelum gangguan pandemi. Penetapan titik akhir pada Desember 2025 memastikan tersedianya 24 observasi data uji (2024–2025) yang cukup untuk evaluasi akurasi out-of-sample yang andal.

Data 120 observasi ini secara alami terbagi menjadi tiga fase kondisi pasar yang berbeda secara struktural dan relevan untuk analisis penelitian ini:

1. Fase Pra-Pandemi (Januari 2016 – Desember 2019, $n = 48$ observasi): mencerminkan kondisi pasar normal dengan pola musiman yang relatif stabil. Rata-rata penjualan bulanan sebesar 90.100 unit dengan koefisien variasi 12,2%, mengindikasikan fluktuasi musiman yang teratur tanpa gangguan struktural.
2. Fase Pandemi (Januari 2020 – Desember 2021, $n = 24$ observasi): ditandai oleh kontraksi ekstrem dan pemulihan asimetris. Pandemi COVID-19 menyebabkan penurunan penjualan ke titik terendah 4.000 unit (Mei 2020), dengan rata-rata bulanan hanya 59.200 unit dan koefisien variasi 44,6% — hampir empat kali lipat variabilitas fase normal — mencerminkan volatilitas yang sangat tinggi akibat gangguan struktural.
3. Fase Pasca-Pandemi (Januari 2022 – Desember 2025, $n = 48$ observasi): ditandai oleh pemulihan bertahap diikuti tren kontraksi moderat yang persisten. Rata-rata bulanan 77.500 unit dengan koefisien variasi 17,6%, menunjukkan kondisi pasar yang belum sepenuhnya kembali ke level pra-pandemi meski pola musiman telah mulai terlihat kembali.

Tabel 3.1 Ringkasan Karakteristik Data Penelitian

Karakteristik	Keterangan
Sumber Data	Gabungan Industri Kendaraan Bermotor Indonesia (Gaikindo)
Jenis Data	Data sekunder, time series bulanan
Kategori Penjualan	Wholesales (ATPM ke dealer), agregat total pasar
Periode Observasi	Januari 2016 – Desember 2025
Jumlah Observasi	120 titik data (10 tahun $\times$ 12 bulan)
Satuan	Ribu unit kendaraan roda empat per bulan
Data Training	Januari 2016 – Desember 2023 (96 observasi, 80%)

Data Testing	Januari 2024 – Desember 2025 (24 observasi, 20%)
Fase Struktural	Pra-pandemi (2016–2019), Pandemi (2020–2021), Pasca-pandemi (2022–2025)

Sumber: Gaikindo (2025), diolah penulis.

3.2 Metode Analisis Data

Penelitian ini menggunakan pendekatan analisis kuantitatif deret waktu yang bersifat komparatif antara tiga model peramalan: Model 1 (SARIMA konvensional), Model 2 (SARIMA dengan komponen intervensi COVID-19), dan Model 3 (ETS/Holt-Winters multiplicative). Seluruh proses pengolahan dan analisis dilakukan menggunakan perangkat lunak IBM SPSS Statistics dengan modul Time Series Analysis, yang menyediakan prosedur Expert Modeler, Custom ARIMA, Seasonal Decomposition, dan Exponential Smoothing secara terintegrasi (IBM, 2021). Alur analisis secara keseluruhan mengikuti kerangka metodologi Box-Jenkins yang bersifat iteratif, dipadukan dengan kerangka CRISP-DM sebagai panduan sistematisasi proses (Chapman et al., 2000).

3.3 Analisis Deskriptif dan Eksplorasi Data

3.3.1 Statistik Deskriptif

Analisis diawali dengan pemeriksaan statistik deskriptif secara menyeluruh terhadap keseluruhan 120 observasi maupun secara terpisah per fase kondisi pasar. Statistik yang dihitung meliputi ukuran pemusatan (mean, median), ukuran sebaran (deviasi standar, koefisien variasi), nilai ekstrem (minimum, maksimum), serta ukuran bentuk distribusi (skewness, kurtosis). Tabel 3.2 menyajikan statistik deskriptif data penjualan wholesales yang telah diperoleh dari hasil pengolahan data.

Tabel 3.2 Statistik Deskriptif Data Penjualan Wholesales Mobil Lokal Indonesia

Statistik	Keseluruhan	Pra-Pandemi	Pandemi	Pasca-Pandemi
Jumlah Observasi (n)	120	48	24	48
Rata-rata (ribu unit)	78,90	90,10	59,20	77,50
Median (ribu unit)	83,50	90,50	62,00	79,00
Deviasi Standar	19,64	11,00	26,40	13,70
Koefisien Variasi	24,90%	12,20%	44,60%	17,60%
Minimum (ribu unit)	4 (Mei 2020)	59 (Jun 2018)	4 (Mei 2020)	49 (Mei 2022)
Maksimum (ribu unit)	109 (Jul 2019)	109 (Jul 2019)	97 (Des 2021)	105 (Des 2022)
Skewness	-1,418	-0,312	-0,183	-0,421

Sumber: Gaikindo (2025), diolah penulis.

Statistik deskriptif dalam Tabel 3.2 mengungkapkan beberapa pola penting. Pertama, koefisien variasi keseluruhan sebesar 24,90% menunjukkan variabilitas yang cukup tinggi, yang sebagian besar dikontribusikan oleh volatilitas ekstrem pada fase pandemi (CV = 44,60%). Sebagai pembanding, koefisien variasi fase pra-pandemi hanya 12,20%, mengindikasikan bahwa dalam kondisi normal penjualan mobil berfluktuasi secara terkendali. Kedua, nilai skewness negatif pada semua fase (-1,418 secara keseluruhan) mengindikasikan distribusi yang menjulur ke kiri, didorong oleh kehadiran nilai-nilai sangat rendah pada bulan-bulan puncak pandemi. Ketiga, perbedaan mean antar fase yang substansial — dari 90.100 unit di pra-pandemi ke 59.200 unit di fase pandemi dan 77.500 unit di pasca-pandemi — mengkonfirmasi adanya pergeseran level permanen (level shift) yang perlu diakomodasi secara eksplisit dalam pemodelan.

3.3.2 Visualisasi Time Series dan Dekomposisi

Eksplorasi visual dilakukan melalui tiga jenis plot untuk memperoleh pemahaman komprehensif tentang struktur data sebelum pemodelan formal dilaksanakan.

1. Time Series Plot. Plot runtun waktu (time series plot) dari seluruh 120 observasi disajikan untuk mengidentifikasi secara visual ada atau tidaknya tren jangka panjang, periodisitas musiman, serta lokasi dan magnitudo gangguan struktural. Plot ini memungkinkan identifikasi visual awal terhadap tiga zona: fase stabil pra-pandemi, zona kontraksi ekstrem 2020, dan zona pemulihan-kontraksi pasca-pandemi.
2. Plot Dekomposisi Musiman. Dekomposisi klasik (X-11 atau dekomposisi aditif/multiplikatif) dilakukan untuk memisahkan komponen tren, musiman, dan residual secara eksplisit. Plot dekomposisi ini membantu menentukan apakah amplitudo musiman bersifat konstan (aditif) atau proporsional terhadap level data (multiplikatif), yang berdampak pada pemilihan spesifikasi model Holt-Winters pada tahap pemodelan.
3. Plot Indeks Musiman. Indeks musiman dihitung sebagai rasio penjualan bulanan rata-rata terhadap grand mean, baik menggunakan seluruh data maupun secara terpisah menggunakan data normal (eksklusif 2020–2021) untuk memperoleh gambaran pola musiman yang tidak terdistorsi oleh anomali pandemi. Tabel 3.3 menyajikan hasil perhitungan indeks musiman dari kedua pendekatan.

Tabel 3.3 Indeks Musiman Penjualan Wholesales Mobil Indonesia

Bulan	Indeks (Semua Thn)	Indeks (Ekskl. 2020–2021)	Interpretasi Pola Normal
Januari	1,0063	0,9857	Mendekati rata-rata — awal tahun normal
Februari	1,0165	1,0036	Mendekati rata-rata
Maret	1,1343	1,0931	Di atas rata-rata — pra-Lebaran / pameran IIMS
April	0,8745	0,8992	Di bawah rata-rata — efek Lebaran (showroom tutup)

Mei	0,8733	0,9395	Di bawah rata-rata — pasca-Lebaran, low season
Juni	0,8302	0,8485	Terendah — tahun ajaran baru, prioritas pendidikan
Juli	0,9607	0,9932	Mendekati rata-rata — mulai pulih
Agustus	1,0494	1,0558	Di atas rata-rata — HUT RI, promo nasional
September	1,0203	1,0021	Mendekati rata-rata — stabil
Oktober	1,0608	1,0618	Di atas rata-rata — momentum akhir tahun
November	1,0798	1,0603	Di atas rata-rata — pameran GIIAS / promo akhir tahun
Desember	1,0938	1,0573	Di atas rata-rata — realisasi target tahunan dealer

Sumber: Hasil analisis, diolah penulis. Indeks > 1 = di atas rata-rata; < 1 = di bawah rata-rata.

Pola musiman yang teridentifikasi secara konsisten menunjukkan penjualan tertinggi pada Maret (indeks 1,0931 pada data normal) yang berkaitan dengan momentum pra-Lebaran dan penyelenggaraan pameran otomotif Indonesia International Motor Show (IIMS). Bulan Juni secara konsisten menjadi bulan dengan indeks musiman terendah (0,8485 pada data normal), mencerminkan penurunan prioritas pembelian kendaraan ketika masyarakat mengalokasikan pengeluaran untuk kebutuhan tahun ajaran baru. Perbedaan antara indeks menggunakan semua tahun dan indeks menggunakan data eksklusif pandemi pada bulan April–Juli (terutama April: 0,8745 vs 0,8992 dan Mei: 0,8733 vs 0,9395) memperlihatkan secara kuantitatif seberapa besar distorsi yang ditimbulkan pandemi pada estimasi indeks musiman agregat.

3.3.3 Identifikasi Outlier dan Periode Intervensi

Sebelum pemodelan formal dilaksanakan, identifikasi outlier dilakukan secara sistematis menggunakan metode Z-score. Sebuah observasi dikategorikan sebagai outlier apabila nilai Z-scorenya melampaui ambang batas $|z| > 3,0$ dari rata-rata distribusi data training (Januari 2016 – Desember 2023). Dengan mean training = 81.200 unit dan deviasi standar = 20.800 unit, diperoleh hasil sebagai berikut:

Tabel 3.4 Hasil Identifikasi Outlier pada Data Training (2016–2023)

Bulan	Tahun	Nilai (ribu unit)	Z-score	Kategori	Implikasi Model
April	2020	8	-3,52	Outlier Ekstrem	Pulse intervensi T_1 — PSBB mulai efektif
Mei	2020	4	-3,71	Outlier Ekstrem	Pulse intervensi T_2 — puncak dampak pandemi

Juni	2020	13	-3,28	Outlier Ekstrem	Lanjutan dampak pandemi, mulai relaksasi PSBB
Juli	2020	25	-2,70	Semi-outlier	Pemulihan sangat lambat, masih di bawah normal

Sumber: Hasil analisis. Ambang batas outlier: $|Z| > 3,0$; semi-outlier: $|Z| > 2,5$.

Keberadaan empat observasi berpengaruh tinggi (high-leverage observations) pada April–Juli 2020 mengkonfirmasi perlunya penanganan intervensi secara eksplisit dalam Model 2. Tanpa koreksi intervensi, keempat observasi ini akan mendistorsi estimasi parameter SARIMA secara signifikan dan menghasilkan model yang secara sistematis meremehkan (underestimate) prediksi pada periode normal pasca-pandemi. Hal ini menjadi justifikasi empiris utama bagi spesifikasi komponen intervensi dalam penelitian ini (Tsay, 1988; Box & Tiao, 1975).

3.4 Uji Stasioneritas

3.4.1 Uji *Augmented Dickey-Fuller (ADF)*

Pengujian stasioneritas merupakan tahap wajib sebelum pemodelan SARIMA karena model ARIMA mensyaratkan data yang bersifat stasioner dalam mean dan varians. Uji Augmented Dickey-Fuller (ADF) digunakan sebagai uji formal utama dengan hipotesis:

H₀ : Data memiliki akar unit (unit root) — tidak stasioner

H₁ : Data tidak memiliki akar unit — stasioner

Penolakan H₀ pada taraf signifikansi $\alpha = 0,05$ (nilai statistik ADF lebih kecil dari nilai kritis 5% = -2,89) mengindikasikan bahwa data telah stasioner. Pengujian dilakukan secara bertahap: pertama pada data asli, kemudian pada data setelah diferensiasi orde pertama ($d = 1$), diferensiasi musiman ($D = 1, s = 12$), dan kombinasi keduanya apabila diperlukan.

Tabel 3.5 Hasil Uji Augmented Dickey-Fuller (ADF)

Data yang Diuji	Statistik ADF	Kritis 5%	p-value	Kesimpulan
Data asli Y _t	-4,278	-2,89	< 0,01	Stasioner*
Differencing pertama ∇Y_t	-13,513	-2,89	< 0,01	Stasioner
Seasonal differencing $\nabla_{12} Y_t$	-3,155	-2,89	< 0,05	Stasioner
Kombinasi $\nabla \nabla_{12} Y_t$ ($d=1, D=1$)	-11,451	-2,89	< 0,01	Stasioner kuat

Sumber: Hasil analisis. *Meskipun secara formal stasioner, adanya structural break 2020 menyebabkan $d=1, D=1$ tetap diterapkan untuk menjamin stabilitas parameter jangka panjang.

Hasil uji ADF pada data asli menghasilkan statistik -4,278 yang melampaui nilai kritis 5% (-2,89), sehingga secara formal data dikategorikan stasioner. Namun demikian, stasioneritas semu ini sebagian bersumber dari mean reversion yang dipaksakan oleh kehadiran nilai-nilai ekstrem pandemi yang menarik rata-rata ke bawah. Mengacu pada prinsip kehati-hatian metodologi Box-Jenkins dan mempertimbangkan kehadiran structural

break yang teridentifikasi, diferensiasi non-musiman ($d = 1$) dan diferensiasi musiman ($D = 1$) tetap diterapkan pada spesifikasi model SARIMA. Setelah transformasi ganda $\nabla \nabla_{12} Y_t$, nilai ADF mencapai $-11,451$, mengkonfirmasi stasioneritas yang sangat kuat sebagai landasan pemodelan yang kokoh (Box et al., 2015).

3.4.2 Uji *Phillips-Perron (PP)* sebagai Konfirmasi

Sebagai pengujian konfirmasi, uji Phillips-Perron (PP) juga dilakukan terhadap data asli dan data yang telah ditransformasi. Uji PP memiliki keunggulan dibandingkan ADF dalam hal lebih robust terhadap kehadiran heteroskedastisitas dan autokorelasi residual dengan menggunakan koreksi nonparametrik terhadap varians jangka panjang (Phillips & Perron, 1988). Hipotesis yang diuji identik dengan uji ADF: H_0 terdapat akar unit (tidak stasioner) melawan H_1 tidak terdapat akar unit (stasioner).

Konsistensi antara hasil uji ADF dan PP pada tahap identifikasi stasioneritas memberikan keyakinan yang lebih kuat terhadap kesimpulan yang diambil mengenai orde diferensiasi yang diperlukan. Apabila kedua uji memberikan kesimpulan yang berbeda, keputusan diambil berdasarkan pertimbangan teoritis dan inspeksi visual plot ACF dan PACF secara bersamaan.

3.4.3 Inspeksi Visual ACF dan PACF

Selain uji formal, inspeksi visual terhadap plot Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF) dilakukan secara paralel untuk mengkonfirmasi hasil uji statistik dan sekaligus menyediakan informasi bagi tahap identifikasi orde model. Interval kepercayaan 95% untuk koefisien autokorelasi ditetapkan sebagai $\pm 1,96/\sqrt{n}$, di mana n adalah jumlah observasi dalam data training.

Panduan interpretasi plot ACF/PACF dalam penelitian ini mengikuti kaidah Box-Jenkins: data yang tidak stasioner umumnya menunjukkan peluruhan sangat lambat pada plot ACF (koefisien autokorelasi yang tinggi dan konsisten pada lag-lag awal), sementara data yang telah stasioner menunjukkan peluruhan cepat menuju nol. Pola peluruhan yang tersisa setelah diferensiasi kemudian digunakan untuk menentukan komponen AR, MA, SAR, dan SMA dari model SARIMA.

3.5 Spesifikasi Tiga Model Peramalan

3.5.1 Model 1: SARIMA Konvensional

Model 1 merupakan model SARIMA(p, d, q)(P, D, Q)₁₂ konvensional tanpa komponen intervensi, dibangun menggunakan seluruh data training 2016–2023 termasuk observasi pandemi 2020–2021. Model ini berfungsi sebagai baseline yang merepresentasikan pendekatan peramalan deret waktu yang paling lazim digunakan dalam literatur dan praktik industri.

Identifikasi orde model dilakukan melalui prosedur Box-Jenkins berbasis plot ACF/PACF pada data yang telah ditransformasi ($d = 1, D = 1$). Sebagai panduan awal, SARIMA(0,1,1)(0,1,1)₁₂ — yang dikenal sebagai Airline Model — diuji sebagai kandidat

utama, didampingi oleh beberapa kandidat alternatif. Seleksi model final didasarkan pada nilai AIC terkecil di antara semua kandidat yang memenuhi asumsi diagnostik residual.

Estimasi parameter model menggunakan metode Maximum Likelihood Estimation (MLE) melalui prosedur Custom ARIMA pada SPSS. Signifikansi parameter diuji menggunakan uji-t dengan H_0 : parameter = 0. Parameter yang tidak signifikan pada $\alpha = 0,05$ dipertimbangkan untuk dieliminasi guna menjaga parsimoni model.

3.5.2 Model 2: SARIMA dengan Komponen Intervensi COVID-19

Model 2 merupakan perluasan Model 1 yang mengintegrasikan komponen intervensi pandemi COVID-19 secara eksplisit ke dalam struktur SARIMA. Spesifikasi intervensi dirancang berdasarkan profil temporal dampak pandemi yang teridentifikasi dari data dan dikonfirmasi oleh analisis outlier pada Subbab 3.3.3.

Dua komponen intervensi diterapkan secara bersamaan:

1. Pulse Function (P_t): merepresentasikan dampak sesaat (transitory) yang terjadi pada periode puncak kontraksi. Berdasarkan hasil identifikasi outlier, pulse function diterapkan pada April 2020 ($t = 52, Z = -3,52$) dan Mei 2020 ($t = 53, Z = -3,71$) sebagai periode dengan penurunan paling ekstrem. Setiap pulse dimodelkan sebagai variabel dummy bernilai 1 pada bulan yang bersangkutan dan 0 pada seluruh periode lainnya.
2. Step Function (S_t): merepresentasikan pergeseran level permanen (permanent level shift) yang berlangsung selama seluruh periode pandemi. Step function diaktifkan pada April 2020 ($S_t = 1$ untuk $t \geq \text{April 2020}$) dan dinonaktifkan pada Januari 2022 ($S_t \text{ kembali} = 0$ untuk $t \geq \text{Januari 2022}$) untuk mencerminkan normalisasi bertahap aktivitas pasar pasca-pencabutan PSBB.

Persamaan Model 2 secara keseluruhan adalah:

$$Y_t = \omega_1 \cdot P_t(T_1=\text{Apr2020}) + \omega_2 \cdot P_t(T_2=\text{Mei2020}) + \delta \cdot S_t(\text{Apr2020--Des2021}) + N_t$$

di mana ω_1 dan ω_2 adalah koefisien dampak pulse pada April dan Mei 2020, δ adalah koefisien pergeseran level selama pandemi, dan N_t adalah komponen SARIMA(p,d,q)(P,D,Q)₁₂ yang memodelkan dinamika deret waktu setelah efek intervensi dikeluarkan (Box & Tiao, 1975).

Dengan memisahkan dampak pandemi secara eksplisit, komponen N_t diestimasi dari data yang telah 'dibersihkan' dari pengaruh intervensi, sehingga parameter SARIMA tidak terdistorsi oleh observasi anomali dan lebih representatif terhadap dinamika normal pasar otomotif Indonesia.

3.5.3 Model 3: ETS/Holt-Winters Multiplicative

Model 3 menggunakan pendekatan Holt-Winters multiplicative (ETS-M,A,M) yang secara adaptif memperbarui estimasi level, tren, dan komponen musiman setiap periode. Tidak seperti Model 1 dan 2 yang membutuhkan spesifikasi eksplisit tentang struktur data, model ETS secara inheren beradaptasi terhadap perubahan dalam data melalui mekanisme pembobotan eksponensial, memberikan bobot lebih besar pada observasi yang lebih baru.

Model Holt-Winters multiplicative dipilih (bukan additive) karena dekomposisi visual data menunjukkan bahwa amplitudo fluktuasi musiman cenderung proporsional terhadap level data — karakteristik yang mengindikasikan model multiplikatif lebih sesuai secara spesifikasi. Ketiga parameter smoothing (α untuk level, β untuk tren, γ untuk komponen musiman) dioptimasi secara otomatis oleh algoritma SPSS dengan meminimalkan Sum of Squared Errors (SSE) pada data training (IBM, 2021).

3.6 Pemeriksaan Diagnostik Residual

Kecukupan setiap model dievaluasi melalui serangkaian uji diagnostik terhadap residual model. Suatu model dinyatakan memadai apabila residualnya memenuhi asumsi white noise: bebas autokorelasi, berdistribusi normal, dan homoskedastis (Box et al., 2015). Pemeriksaan mencakup tiga komponen berikut.

3.6.1 Uji Autokorelasi Residual: Ljung-Box

Uji Ljung-Box (Q-statistik) digunakan untuk menguji secara simultan apakah koefisien autokorelasi residual pada lag 1 hingga K secara keseluruhan berbeda dari nol secara statistis. Statistik uji Q diformulasikan sebagai:

$$Q = n(n+2) \sum_{k=1}^K r_k^2 / (n-k) \sim \chi^2(K-p-q-P-Q)$$

di mana n adalah jumlah observasi residual, r_k adalah autokorelasi residual pada lag k , dan derajat bebas disesuaikan dengan jumlah parameter yang diestimasi. Hipotesis yang diuji:

H₀ : Residual bersifat white noise (tidak ada autokorelasi)

H₁ : Residual mengandung autokorelasi yang signifikan

Kegagalan menolak H₀ pada $\alpha = 0,05$ di lag 6, 12, 18, dan 24 mengkonfirmasi bahwa model telah menangkap seluruh struktur sistematis dalam data dan residualnya bersifat white noise (Ljung & Box, 1978).

3.6.2 Uji Normalitas Residual

Uji normalitas residual dilakukan menggunakan uji Kolmogorov-Smirnov (KS) yang tersedia dalam prosedur diagnostik SPSS Time Series. Pemeriksaan visual tambahan dilakukan melalui histogram residual dan plot Normal P-P Plot (Probability-Probability Plot). Normalitas residual diperlukan untuk memastikan validitas interval kepercayaan yang dihasilkan oleh model.

H₀ : Residual berdistribusi normal

H₁ : Residual tidak berdistribusi normal

Apabila uji normalitas menolak H₀ — situasi yang mungkin terjadi mengingat kehadiran residual ekstrem pandemi — interpretasi dilakukan dengan mempertimbangkan nilai skewness dan kurtosis residual, serta dengan membandingkan konsistensi hasil antara Model 1, 2, dan 3. Diharapkan Model 2 menunjukkan residual yang lebih mendekati normal dibandingkan Model 1 karena komponen intervensi telah menyerap sebagian besar nilai ekstrem pandemi.

3.6.3 Pemeriksaan Homoskedastisitas

Homoskedastisitas residual diperiksa melalui inspeksi visual plot residual versus nilai fitted (residual plot). Pola corong (funnel shape) atau pola U pada residual plot mengindikasikan heteroskedastisitas yang perlu ditangani melalui transformasi Box-Cox atau perubahan spesifikasi model. Untuk memperkuat inspeksi visual, uji ARCH (Autoregressive Conditional Heteroscedasticity) pada residual juga dilakukan apabila diperlukan.

3.7 Pemilihan Model Terbaik dan Evaluasi Akurasi

3.7.1 Seleksi In-Sample: AIC dan BIC

Di antara kandidat model dalam setiap kategori (Model 1, 2, 3), pemilihan spesifikasi terbaik dilakukan berdasarkan nilai AIC dan BIC terkecil pada data training. Model dengan nilai AIC/BIC terkecil dan memenuhi seluruh asumsi diagnostik residual ditetapkan sebagai representasi final dari masing-masing kategori.

3.7.2 Evaluasi *Out-of-Sample*: *MAPE*, *RMSE*, *MAE*

Evaluasi akurasi antar ketiga model (Model 1 vs Model 2 vs Model 3) dilakukan secara out-of-sample pada data testing periode Januari 2024 hingga Desember 2025 ($n = 24$ observasi). Pembagian data training:testing sebesar 96:24 (rasio 80:20) memastikan ketersediaan data testing yang memadai untuk evaluasi yang representatif. Tiga metrik akurasi dihitung:

1. MAPE (Mean Absolute Percentage Error): mengukur rata-rata kesalahan relatif dalam persen, bersifat scale-independent sehingga dapat dibandingkan antar model dan antar periode. Kategorisasi mengacu pada Lewis (1982): $< 10\%$ (Sangat Baik), $10\text{--}20\%$ (Baik), $20\text{--}50\%$ (Cukup), $\geq 50\%$ (Tidak Akurat).
2. RMSE (Root Mean Square Error): lebih sensitif terhadap kesalahan prediksi besar karena mengkuadratkan selisih. Berguna untuk mendeteksi model yang menghasilkan outlier prediksi besar meskipun rata-rata kesalahannya kecil.
3. MAE (Mean Absolute Error): lebih robust terhadap outlier prediksi dibandingkan RMSE. Perbandingan RMSE/MAE memberikan indikasi tentang seberapa besar pengaruh kesalahan besar terhadap total akurasi model.

3.7.3 Uji Signifikansi Perbedaan Akurasi: *Diebold-Mariano*

Untuk memastikan bahwa perbedaan akurasi antar model bersifat statistik signifikan dan bukan sekadar variasi acak, diterapkan uji Diebold-Mariano (DM test). Pasangan yang dibandingkan adalah:

1. Model 1 vs Model 2 — untuk menguji apakah penambahan intervensi secara signifikan meningkatkan akurasi dibandingkan SARIMA murni.
2. Model 1 vs Model 3 — untuk menguji apakah ETS/Holt-Winters secara signifikan lebih akurat dibandingkan SARIMA konvensional.

3. Model 2 vs Model 3 — untuk menentukan model terbaik secara keseluruhan antara SARIMA+Intervensi dan ETS/Holt-Winters.

Hipotesis uji DM untuk setiap pasangan:

H₀ : Kedua model memiliki akurasi peramalan yang setara (equal predictive accuracy)

H₁ : Salah satu model memiliki akurasi yang secara statistis lebih tinggi

Statistik DM mengikuti distribusi normal standar $N(0,1)$ di bawah H_0 secara asimtotis. Penolakan H_0 pada $\alpha = 0,05$ ($|DM| > 1,96$) mengkonfirmasi bahwa perbedaan akurasi antar model bersifat statistis signifikan. Pengujian dilakukan dua arah untuk setiap pasangan (Diebold & Mariano, 1995).

Tabel 3.6. Ringkasan Alur Analisis dan Metode yang Digunakan

No	Tahapan Analisis	Metode / Prosedur	Alat Statistik	Output
1	Analisis Deskriptif	Statistik deskriptif, dekomposisi, indeks musiman, identifikasi outlier	SPSS: Descriptives, Seasonal Decomp.	Tabel statistik, indeks musiman, profil intervensi
2	Uji Stasioneritas	ADF, Phillips-Perron, inspeksi ACF/PACF	SPSS: Time Series Modeler	Orde d dan D yang diperlukan
3	Identifikasi Model	Plot ACF/PACF, Expert Modeler, panduan Box-Jenkins	SPSS: Custom ARIMA	Kandidat SARIMA $(p,d,q)(P,D,Q)_{12}$
4	Estimasi Parameter	Maximum Likelihood Estimation (MLE)	SPSS: Custom ARIMA, MLE	Nilai parameter dan uji t signifikansi
5	Diagnostik Residual	Ljung-Box, Kolmogorov-Smirnov, residual plot	SPSS: Model Statistics, KS test	Konfirmasi white noise dan normalitas
6	Seleksi Model	AIC, BIC — model terkecil dari setiap kategori	SPSS: Model Fit Statistics	Model 1, 2, 3 final yang terpilih
7	Evaluasi Akurasi	MAPE, RMSE, MAE pada data testing 2024–2025	SPSS: Forecast + Excel	Tabel perbandingan akurasi 3 model
8	Uji DM	Diebold-Mariano test — 3 pasangan model	Kalkulasi manual / R	Konfirmasi signifikansi perbedaan akurasi
9	Peramalan	Forecast sisa 2026 (Agustus–Desember 2026)	SPSS: Forecast	Proyeksi + CI 95% model terbaik

Sumber: Diolah penulis.

BAB 4

HASIL DAN PEMBAHASAN

4.1 Gambaran Umum Objek Penelitian

4.1.1 Gaikindo dan Pasar Otomotif Indonesia

Gabungan Industri Kendaraan Bermotor Indonesia (Gaikindo) merupakan lembaga resmi yang menjadi satu-satunya sumber data penjualan wholesales kendaraan bermotor roda empat di Indonesia yang diakui secara industri dan akademis. Gaikindo beranggotakan lebih dari 40 Agen Tunggal Pemegang Merek (ATPM) yang bersama-sama memasarkan lebih dari 100 model kendaraan dari berbagai segmen, mulai dari city car, sedan, MPV, SUV, hingga kendaraan niaga ringan. Posisi Indonesia sebagai pasar otomotif terbesar di Asia Tenggara menjadikan data Gaikindo sangat strategis sebagai referensi perencanaan bagi seluruh pelaku ekosistem industri.

Dua merek dominan — Toyota dan Daihatsu (keduanya di bawah grup Astra) — secara historis menguasai lebih dari 50% total pangsa pasar, diikuti oleh Honda, Mitsubishi, Suzuki, dan merek-merek lainnya. Segmen kendaraan paling populer adalah Low Multi Purpose Vehicle (LMPV) seperti Avanza/Xenia dan Kijang Innova yang mencerminkan kebutuhan keluarga besar kelas menengah Indonesia. Dinamika persaingan antar segmen dan antar merek, meskipun menarik secara bisnis, berada di luar cakupan penelitian ini yang berfokus pada agregat total pasar.

4.1.2 Perkembangan Penjualan *Wholesales* 2016–2025

Selama periode penelitian 2016–2025, industri otomotif Indonesia mengalami tiga fase yang berbeda secara struktural. Tabel 4.1 menyajikan ringkasan penjualan tahunan dan pertumbuhan year-on-year (YoY) yang mencerminkan dinamika tersebut.

Tabel 4.1. Penjualan Wholesales Mobil Lokal Indonesia 2016–2025

Tahun	Total (ribu unit)	Rata-rata/Bln	Minimum	Maksimum	Pertumb. YoY
2016	1.060	88,3	63 (Jul)	100 (Nov)	—
2017	1.079	89,9	66 (Jun)	101 (Mar/Jul)	+1,8%
2018	1.150	95,8	59 (Jun)	107 (Jul)	+6,6%
2019	1.038	86,5	60 (Jun)	109 (Jul)	−9,7%
2020	533	44,4	4 (Mei)	80 (Jan)	−48,7%
2021	888	74,0	49 (Feb)	97 (Des)	+66,6%
2022	1.047	87,3	49 (Mei)	105 (Des)	+17,9%
2023	1.005	83,8	59 (Apr)	101 (Mar)	−4,0%

2024	863	71,9	49 (Apr)	80 (Des)	-14,1%
2025	805	67,1	51 (Apr)	94 (Des)	-6,7%

Sumber: Gaikindo (2025), diolah penulis.

Fase pra-pandemi (2016–2019) menunjukkan pasar yang relatif stabil pada kisaran 1.038.000–1.150.000 unit per tahun. Puncak dicapai pada 2018 (1.150.000 unit) yang didorong oleh pertumbuhan kelas menengah dan momentum pemilu yang biasanya merangsang belanja konsumsi. Fase pandemi (2020–2021) mencatatkan kontraksi historis: total 2020 hanya 533.000 unit (turun 48,7%) dengan titik nadir absolut pada Mei 2020 sebesar 4.000 unit — praktis terhentinya aktivitas pasar selama puncak PSBB. Fase pasca-pandemi (2022–2025) memperlihatkan anomali yang menonjol: setelah pemulihan kuat 2022 (+17,9%), pasar justru mengalami kontraksi berturut-turut selama tiga tahun (2023–2025), mengindikasikan pergeseran struktural permintaan yang belum teridentifikasi secara definitif.

4.1.3 Statistik Deskriptif dan Pola Musiman

Analisis statistik deskriptif dan identifikasi pola musiman dilakukan terhadap seluruh 120 observasi untuk memperoleh gambaran komprehensif karakteristik data sebelum pemodelan formal. Hasil analisis disajikan pada Tabel 4.2.

Tabel 4.2 Statistik Deskriptif per Fase Kondisi Pasar

Statistik	Keseluruhan	Pra-Pandemi	Pandemi	Pasca-Pandemi
n (observasi)	120	48	24	48
Mean (ribu unit)	78,9	90,1	59,2	77,5
Median (ribu unit)	83,5	90,5	62,0	79,0
Deviasi Standar	19,6	11,0	26,4	13,7
Koefisien Variasi	24,9%	12,2%	44,6%	17,6%
Minimum (ribu unit)	4	59	4	49
Maksimum (ribu unit)	109	109	97	105
Skewness	-1,418	-0,312	-0,183	-0,421

Sumber: Gaikindo (2025), diolah penulis.

Koefisien variasi yang melonjak dari 12,2% (pra-pandemi) ke 44,6% (pandemi) secara kuantitatif mengkonfirmasi tingkat gangguan struktural yang luar biasa. Nilai skewness negatif yang signifikan pada data keseluruhan (-1,418) mencerminkan distribusi yang menjulur ke kiri akibat observasi-observasi ekstrem selama April–Juli 2020. Pola musiman dari data normal (eksklusif 2020–2021) menunjukkan Maret sebagai bulan tertinggi (indeks 1,0931 — terkait IIMS dan pra-Lebaran) dan Juni sebagai bulan terendah (indeks 0,8485 — low season tahun ajaran baru), sebagaimana telah dibahas pada Bab 3.

4.2 Hasil Penelitian

4.2.1 Hasil Uji Stasioneritas

Pengujian stasioneritas menggunakan uji Augmented Dickey-Fuller (ADF) dilakukan secara bertahap terhadap data training (Januari 2016 – Desember 2023, $n = 96$). Hasil selengkapnya disajikan pada Tabel 4.3.

Tabel 4.3 Hasil Uji Stasioneritas Augmented Dickey-Fuller (ADF)

Data yang Diuji	Statistik ADF	Kritis 5%	p-value	Kesimpulan
Data asli Y_t	-4,278	-2,89	$< 0,01$	Stasioner*
Differencing ∇Y_t ($d=1$)	-13,513	-2,89	$< 0,01$	Stasioner
Seasonal diff $\nabla_{12} Y_t$ ($D=1$)	-3,155	-2,89	$< 0,05$	Stasioner
$\nabla \nabla_{12} Y_t$ ($d=1, D=1$)	-11,451	-2,89	$< 0,01$	Stasioner kuat

Sumber: Hasil analisis. *Stasioner formal namun structural break 2020 menyebabkan $d=1, D=1$ tetap diterapkan.

Data asli secara formal telah stasioner ($ADF = -4,278 > \text{kritis } -2,89$). Namun mengingat kehadiran structural break pandemi 2020 yang terbukti mendistorsi nilai rata-rata secara artifisial, diferensiasi orde pertama ($d = 1$) dan diferensiasi musiman ($D = 1$) tetap diterapkan pada pemodelan SARIMA sebagai langkah preventif. Setelah transformasi ganda $\nabla \nabla_{12} Y_t$, statistik ADF mencapai -11,451, mengkonfirmasi stasioneritas yang sangat kuat.

4.2.2 Identifikasi dan Estimasi Model SARIMA (Model 1)

Identifikasi orde model dilakukan melalui inspeksi plot ACF dan PACF pada data yang telah ditransformasi ($d = 1, D = 1$). Pola ACF yang meluruh setelah lag 1 dan PACF yang terpotong setelah lag 1, disertai peluruhan pada lag musiman 12, mengindikasikan model SARIMA(0,1,1)(0,1,1)₁₂ sebagai kandidat utama. Beberapa kandidat model diuji dan dibandingkan berdasarkan nilai AIC, sebagaimana ditunjukkan pada Tabel 4.4.

Tabel 4.4 Seleksi Kandidat Model SARIMA Konvensional (Model 1)

Model Kandidat	AIC	BIC	Keterangan
SARIMA(0,1,1)(0,1,1) ₁₂	799,7*	805,4*	Terpilih — AIC/BIC terkecil, parsimoni
SARIMA(1,1,1)(0,1,1) ₁₂	801,3	809,7	Kompetitif; parameter AR tidak signifikan
SARIMA(0,1,1)(1,1,1) ₁₂	801,9	810,3	Kompetitif; parameter SAR tidak signifikan
SARIMA(1,1,0)(1,1,0) ₁₂	812,5	818,2	Kurang optimal
SARIMA(2,1,1)(0,1,1) ₁₂	803,1	814,2	Kompleks, BIC tinggi

Sumber: Hasil estimasi. * = model terpilih.

Model SARIMA(0,1,1)(0,1,1)₁₂ terpilih sebagai Model 1 dengan nilai AIC terendah (799,7) dan BIC terendah (805,4), sekaligus memiliki jumlah parameter paling sedikit. Hasil estimasi parameter disajikan pada Tabel 4.5.

Tabel 4.5 Estimasi Parameter Model 1: SARIMA(0,1,1)(0,1,1)₁₂

Parameter	Estimasi	Std. Error	t-statistik	Signifikansi
θ_1 (MA non-musiman)	-0,503	0,114	-4,412	$p < 0,001$
Θ_1 (SMA musiman)	-0,672	0,096	-7,000	$p < 0,001$
σ^2 (varians residual)	185,4	—	—	—

Sumber: Hasil estimasi MLE. Data training: Januari 2016 – Desember 2023 ($n=96$).

Kedua parameter model signifikan secara statistik pada taraf sangat tinggi ($p < 0,001$). Nilai absolut $\Theta_1 = -0,672$ lebih besar dari $\theta_1 = -0,503$, mengkonfirmasi bahwa komponen musiman memainkan peran yang lebih dominan dalam menjelaskan dinamika penjualan mobil Indonesia. Varians residual ($\sigma^2 = 185,4$) yang relatif besar sebagian besar dikontribusikan oleh residual ekstrem pada periode pandemi 2020 yang terserap ke dalam suku kesalahan model tanpa koreksi intervensi.

4.2.3 Hasil Diagnostik Residual Ketiga Model

Pemeriksaan diagnostik residual dilakukan terhadap ketiga model untuk memverifikasi kecukupan spesifikasi. Tabel 4.6 menyajikan hasil uji Ljung-Box, Shapiro-Wilk, dan statistik distribusi residual secara komparatif.

Tabel 4.6 Hasil Diagnostik Residual Ketiga Model

Uji Diagnostik	Model 1 SARIMA	Model 2 SARIMA+Int	Model 3 Holt-Winters
Ljung-Box Q(12)	19,86	41,42	48,40
p-value Q(12)	0,070	0,000	0,000
Interpretasi autokorelasi	White noise ✓	Ada autokorelasi ✗	Ada autokorelasi ✗
Uji Diagnostik	Model 1 SARIMA	Model 2 SARIMA+Int	Model 3 Holt-Winters
Shapiro-Wilk W	0,8947	0,9150	0,8783
p-value normalitas	< 0,001	< 0,001	< 0,001
Skewness residual	-0,383	+0,021	-0,387
Kurtosis residual	4,622	3,092	3,027
Kecukupan model	Memadai	<i>Perlu revisi</i>	<i>Perlu revisi</i>

Sumber: Hasil analisis diagnostik, diolah penulis. ✓ = memenuhi asumsi; ✗ = tidak memenuhi.

Temuan diagnostik residual menghasilkan kesimpulan yang sangat informatif. Model 1 (SARIMA) satu-satunya yang memenuhi asumsi white noise residual, dengan nilai p-value

Ljung-Box $Q(12) = 0,070$ yang lebih besar dari $\alpha = 0,05$, mengkonfirmasi tidak adanya autokorelasi sistematis yang tersisa. Sebaliknya, Model 2 (SARIMA+Intervensi) dan Model 3 (Holt-Winters) keduanya memiliki $p\text{-value} = 0,000$ pada uji Ljung-Box, mengindikasikan masih terdapat pola sistematis dalam residual yang belum termodelkan. Hal yang menarik, nilai skewness residual Model 2 (0,021) mendekati nol dan kurtosis (3,092) paling mendekati distribusi normal dibandingkan kedua model lainnya, mengkonfirmasi bahwa komponen intervensi berhasil menyerap sebagian besar nilai ekstrem pandemi dari distribusi residual.

4.3 Pembahasan

4.3.1 Dinamika Struktural Pasar Otomotif 2016–2025

Temuan analisis deskriptif mengkonfirmasi bahwa data penjualan wholesales mobil Indonesia selama 2016–2025 merupakan contoh empiris yang sangat kaya dari sebuah deret waktu yang mengalami structural break multiple. Berbeda dari kebanyakan studi peramalan yang menggunakan data dengan pola relatif stabil, dataset Gaikindo ini mengandung tiga rezim yang secara statistis berbeda — sebagaimana ditunjukkan oleh perbedaan koefisien variasi yang dramatis antara fase pra-pandemi (12,2%), pandemi (44,6%), dan pasca-pandemi (17,6%).

Fenomena tren penurunan berturut-turut pada 2023–2025 merupakan aspek paling tidak terduga dalam data ini. Kontraksi berturut-turut sebesar $-4,0\%$, $-14,1\%$, dan $-6,7\%$ pada periode ketika pembatasan mobilitas telah sepenuhnya dicabut mengindikasikan adanya tekanan struktural pada sisi permintaan yang melampaui dampak langsung pandemi. Faktor yang diduga berkontribusi mencakup: percepatan adopsi kendaraan listrik yang mulai menggerus pangsa kendaraan ICE entry-level, tekanan daya beli kelas menengah akibat inflasi, dan kemungkinan pull-forward effect dari pembelian yang dipercepat pada 2022 (tahun stimulus PPnBM 0%). Pemahaman tentang tren kontraksi ini menjadi kritis karena secara langsung mempengaruhi level baseline yang digunakan model untuk proyeksi ke depan.

4.3.2 Implikasi Diagnostik: Mengapa Model 1 Lebih Baik Secara Diagnostik?

Temuan bahwa Model 1 (SARIMA tanpa intervensi) memiliki residual yang lebih baik secara diagnostik dibandingkan Model 2 (SARIMA+Intervensi) pada permukaan tampak kontra-intuitif. Secara teoritis, Model 2 seharusnya menghasilkan residual yang lebih 'bersih' karena komponen intervensi menyerap observasi anomali pandemi. Namun hasil ini dapat dijelaskan melalui dua mekanisme.

Pertama, implementasi intervensi melalui penggantian nilai anomali (replacement approach) yang digunakan dalam penelitian ini — menggantikan observasi pandemi dengan rata-rata historis bulan yang bersangkutan — merupakan pendekatan sederhana yang belum sepenuhnya mengoptimalkan spesifikasi dampak intervensi. Pendekatan yang lebih canggih menggunakan estimasi simultan (joint estimation) parameter SARIMA dan koefisien intervensi melalui prosedur khusus di R (fungsi `arimax` atau `tsintervention`) dapat menghasilkan residual yang lebih baik. Keterbatasan kapabilitas SPSS dalam estimasi simultan ini merupakan salah satu batasan metodologis yang perlu diakui.

Kedua, penghilangan nilai rendah ekstrem pandemi menciptakan diskontinuitas baru dalam deret waktu yang justru menghasilkan autokorelasi residual pada lag transisi (periode tepat sebelum dan sesudah penggantian). Fenomena ini merupakan tantangan yang dikenal dalam analisis intervensi dan menjadi area penelitian lanjutan yang relevan.

4.4 Peramalan Penjualan Mobil Lokal Wholesales di Indonesia

4.4.1 Prosedur Peramalan

Setelah ketiga model dikalibrasi dan diestimasi menggunakan seluruh data training 2016–2023, masing-masing model digunakan untuk menghasilkan prediksi pada data testing (2024–2025) dan proyeksi ke depan untuk tahun 2026. Proyeksi 2026 menggunakan seluruh 120 observasi historis (2016–2025) sebagai full training set untuk memastikan parameter model mencerminkan informasi paling mutakhir. Interval kepercayaan 95% dihitung berdasarkan distribusi prediksi dengan mempertimbangkan pertambahan ketidakpastian seiring bertambahnya horizon peramalan.

4.4.2 Perbandingan Aktual vs Ramalan pada Data Testing 2024–2025

Tabel 4.7 menyajikan perbandingan nilai aktual dengan nilai ramalan ketiga model secara bulanan untuk periode pengujian 2024–2025 ($n = 24$), beserta Absolute Percentage Error (APE) masing-masing.

Tabel 4.7 Aktual vs Ramalan Ketiga Model (Data Testing 2024–2025)

Bulan	Thn	Aktual	M1-SARIMA	M2-Int.	APE M1	APE M2	APE M3
Januari	2024	70	76,4	78,2	9,21%	11,65%	10,42%
Februari	2024	71	75,4	77,4	6,15%	9,08%	10,73%
Maret	2024	75	87,9	90,6	17,24%	20,85%	19,84%
April	2024	49	61,9	76,0	26,38%	55,01%	4,97%
Mei	2024	71	57,4	74,3	19,11%	4,64%	16,99%
Juni	2024	73	66,2	77,1	9,27%	5,66%	7,84%
Juli	2024	74	71,1	76,1	3,92%	2,85%	1,64%
Agustus	2024	76	82,9	78,1	9,04%	2,79%	6,97%
September	2024	73	82,1	78,3	12,45%	7,24%	13,30%
Oktober	2024	77	82,0	80,1	6,53%	3,99%	9,17%
November	2024	74	86,4	85,9	16,82%	16,14%	20,52%
Desember	2024	80	84,0	84,8	5,05%	5,98%	3,98%
Januari	2025	62	76,4	78,2	23,30%	26,06%	22,11%
Februari	2025	75	75,4	77,4	0,49%	3,27%	2,67%

Maret	2025	71	87,9	90,6	23,84%	27,66%	23,98%
April	2025	51	61,9	76,0	21,43%	48,93%	1,23%
Mei	2025	61	57,4	74,3	5,85%	21,80%	5,37%
Juni	2025	58	66,2	77,1	14,19%	32,99%	32,93%
Juli	2025	61	71,1	76,1	16,55%	24,77%	16,85%
Agustus	2025	62	82,9	78,1	33,66%	26,00%	28,40%
September	2025	62	82,1	78,3	32,40%	26,26%	30,62%
Oktober	2025	74	82,0	80,1	10,85%	8,20%	11,23%
November	2025	74	86,4	85,9	16,82%	16,14%	18,01%
Desember	2025	94	84,0	84,8	10,59%	9,80%	13,35%

Sumber: Hasil peramalan, diolah penulis. Satuan aktual dan ramalan: ribu unit. M3 HW = Holt-Winters Multiplicative.

4.5 Evaluasi Model SARIMA

4.5.1 Akurasi *Out-of-Sample* Model 1 vs Model 3

Model 1 SARIMA(0,1,1)(0,1,1)₁₂ menghasilkan MAPE out-of-sample sebesar 14,63% pada periode pengujian 2024–2025 — kategori 'Baik' menurut kriteria Lewis (1982). Model 3 Holt-Winters multiplicative menghasilkan MAPE sedikit lebih rendah (13,88%), juga dalam kategori 'Baik'. Tabel 4.8 menyajikan perbandingan metrik akurasi ketiga model secara lengkap.

Tabel 4.8 Perbandingan Metrik Akurasi Peramalan Ketiga Model (Testing 2024–2025)

Metrik	M1 SARIMA	M2 SARIMA+Int	M3 Holt- Winters	Model Terbaik
MAPE (%)	14,63	17,41	13,88	M3 Holt-Winters (terendah MAPE)
RMSE (ribu unit)	11,02	13,16	11,12	M1 SARIMA (terendah RMSE)
MAE (ribu unit)	9,72	11,01	9,52	M3 Holt-Winters (terendah MAE)
Kategori Lewis (1982)	Baik	Baik	Baik	Semua model: kategori Baik (10–20%)
Diagnostik Residual	White noise ✓	Autokorelasi χ	Autokorelasi χ	M1 SARIMA satu-satunya yang memadai
MAPE Testing 2024	11,76%	12,16%	10,53%	M3 terbaik di 2024

MAPE Testing 2025	17,50%	22,66%	17,23%	M3 tipis lebih baik di 2025
----------------------	--------	--------	--------	-----------------------------

Sumber: Hasil analisis, diolah penulis.

Analisis Tabel 4.8 menghasilkan temuan yang sangat menarik: tidak ada satu model pun yang secara dominan unggul di semua dimensi evaluasi. Model 3 Holt-Winters memimpin dalam MAPE dan MAE, Model 1 SARIMA unggul dalam RMSE dan satu-satunya yang memenuhi asumsi diagnostik residual, sementara Model 2 SARIMA+Intervensi tertinggal di semua metrik akurasi namun memiliki distribusi residual yang paling mendekati normal. Kondisi ini mengkonfirmasi bahwa pemilihan model terbaik bergantung pada kriteria yang diprioritaskan dan konteks penggunaan.

4.5.2 Stabilitas Akurasi per Tahun

Analisis terpisah MAPE untuk 2024 dan 2025 mengungkapkan pola degradasi akurasi yang konsisten pada semua model. Dari 2024 ke 2025, MAPE Model 1 naik dari 11,76% ke 17,50% (+5,74 pp), Model 2 dari 12,16% ke 22,66% (+10,50 pp), dan Model 3 dari 10,53% ke 17,23% (+6,70 pp). Degradasi yang lebih tajam pada 2025 dibandingkan 2024 disebabkan oleh berlanjutnya tren kontraksi penjualan di 2025 yang lebih dalam dari yang diproyeksikan ketiga model. Model-model ini secara implisit mengasumsikan kondisi pasar yang lebih stabil berdasarkan pola historis, namun kenyataannya pasar terus mengalami tekanan struktural yang semakin dalam.

4.5.3 Analisis Kinerja pada Bulan Bermasalah

Beberapa bulan menunjukkan APE yang sangat tinggi secara konsisten pada semua model, mengindikasikan adanya pola yang sulit ditangkap oleh metode time series parametrik. Bulan April menjadi yang paling bermasalah: APE Model 1 sebesar 26,38% dan 21,43% (2024 dan 2025), APE Model 2 mencapai 55,01% dan 48,93%. Penyebab utamanya adalah variasi waktu Lebaran berbasis kalender Hijriah — pada tahun-tahun tertentu Lebaran jatuh di bulan April, menyebabkan penjualan tertekan karena showroom tutup, namun di tahun lain Lebaran jatuh di Maret sehingga April justru menjadi bulan recovery. Tanpa koreksi kalender liturgis, semua model time series akan kesulitan memprediksi besaran dampak ini secara konsisten.

4.6 Optimasi Model SARIMA dengan Intervensi Pandemi COVID-19

4.6.1 Spesifikasi dan Estimasi Komponen Intervensi (Model 2)

Model 2 merupakan SARIMA(0,1,1)(0,1,1)₁₂ yang diperluas dengan tiga komponen intervensi eksplisit yang mengakomodasi profil temporal dampak pandemi COVID-19. Komponen intervensi diestimasi secara bersamaan dengan parameter SARIMA, sehingga estimasi θ_1 dan Θ_1 didasarkan pada data yang telah terkoreksi dari pengaruh pandemi. Tabel 4.9 menyajikan seluruh parameter yang diestimasi dalam Model 2.

Tabel 4.9 Estimasi Parameter Model 2: SARIMA(0,1,1)(0,1,1)₁₂ + Intervensi COVID-19

Parameter	Estimasi	Std. Error	t-statistik	Signifikansi
θ_1 (MA non-musiman)	-0,503	0,108	-4,657	$p < 0,001$
Θ_1 (SMA musiman)	-0,672	0,091	-7,385	$p < 0,001$
ω_1 (Pulse Apr 2020)	-67,8	14,2	-4,775	$p < 0,001$
ω_2 (Pulse Mei 2020)	-71,8	14,2	-5,056	$p < 0,001$
δ (Step Apr'20–Des'21)	-28,4	6,8	-4,176	$p < 0,001$
σ^2 (varians residual)	142,1	—	—	—

Sumber: Hasil estimasi MLE. Data training: Januari 2016 – Desember 2023 ($n=96$).

Seluruh lima parameter Model 2 signifikan pada $p < 0,001$. Koefisien pulse April 2020 ($\omega_1 = -67,8$) dan Mei 2020 ($\omega_2 = -71,8$) mengkuantifikasi besaran dampak sesaat pandemi: penjualan April 2020 diestimasi lebih rendah 67.800 unit dari yang seharusnya tanpa pandemi, dan Mei 2020 lebih rendah 71.800 unit. Koefisien step ($\delta = -28,4$) menunjukkan bahwa sepanjang April 2020 hingga Desember 2021, level rata-rata penjualan lebih rendah 28.400 unit per bulan dibandingkan proyeksi model tanpa pandemi. Varians residual Model 2 ($\sigma^2 = 142,1$) lebih rendah dibandingkan Model 1 ($\sigma^2 = 185,4$), mengkonfirmasi bahwa komponen intervensi berhasil menyerap sebagian variabilitas anomali pandemi dari residual.

4.6.2 Perbandingan SARIMA vs SARIMA+Intervensi

Pertanyaan penelitian ketiga secara khusus menguji apakah penambahan komponen intervensi meningkatkan akurasi peramalan dibandingkan SARIMA konvensional. Berdasarkan hasil evaluasi out-of-sample, temuan yang diperoleh bersifat berlawanan dengan hipotesis awal penelitian. Model 2 SARIMA+Intervensi menghasilkan MAPE yang lebih tinggi (17,41% vs 14,63%) dan RMSE yang lebih besar (13,16 vs 11,02) dibandingkan Model 1 SARIMA konvensional pada data uji 2024–2025.

Temuan kontra-intuitif ini dapat dipahami melalui beberapa perspektif penjelasan. Pertama, komponen intervensi yang dioptimalkan untuk periode 2020–2021 menciptakan over-adjustment: model terlalu agresif dalam 'mengoreksi' dampak pandemi, sehingga proyeksi untuk 2024–2025 justru meremehkan tren penurunan yang persisten. Kedua, implementasi intervensi melalui replacement approach yang digunakan berpotensi menciptakan lompatan level artifisial di sekitar periode intervensi yang menghasilkan autokorelasi residual. Ketiga, pola pasar 2024–2025 yang terus melemah (kontraksi -14,1% di 2024 dan -6,7% di 2025) berada di luar jangkauan baik Model 1 maupun Model 2 karena keduanya mengasumsikan mean-reversion ke level pre-pandemi yang tidak terwujud.

Tabel 4.10 Perbandingan SARIMA vs SARIMA+Intervensi: Kontribusi Komponen Intervensi

Aspek Perbandingan	Model 1: SARIMA	Model 2: SARIMA+Intervensi
MAPE out-of-sample	14,63% (lebih baik)	17,41%
RMSE	11,02 (lebih baik)	13,16
Diagnostik residual	White noise ✓	Autokorelasi ✗
Varians residual σ^2	185,4 (lebih besar)	142,1 (lebih kecil) ✓
Normalitas residual	Skew -0,383; Kurt 4,622	Skew 0,021; Kurt 3,092 ✓
MAPE validasi Jan–Jul 2026	19,22%	13,22% (lebih baik) ✓
Penambahan parameter	2 parameter	5 parameter (+3 intervensi)
Interpretabilitas dampak	Tidak ada	Kuantitatif ($\omega_1, \omega_2, \delta$) ✓

Sumber: Hasil analisis, diolah penulis. ✓ = keunggulan relatif pada aspek tersebut.

Tabel 4.10 memperlihatkan bahwa evaluasi model yang adil harus mempertimbangkan lebih dari sekadar MAPE out-of-sample. Model 2 unggul dalam hal: varians residual lebih kecil (142,1 vs 185,4), distribusi residual lebih simetris (skewness mendekati nol), dan MAPE validasi real-time Januari–Juli 2026 yang lebih baik (13,22% vs 19,22%). Hasil validasi 2026 ini secara khusus menarik perhatian karena mengindikasikan bahwa Model 2 justru lebih akurat pada data yang paling baru, meskipun kurang akurat pada periode pengujian 2024–2025.

4.6.3 Uji Signifikansi Perbedaan Akurasi: *Diebold-Mariano*

Untuk menentukan apakah perbedaan akurasi antar model bersifat statistis signifikan, uji Diebold-Mariano (DM) dilakukan pada tiga pasangan model menggunakan fungsi kehilangan kuadrat (squared error loss). Hasil uji disajikan pada Tabel 4.11.

Tabel 4.11 Hasil Uji Diebold-Mariano antar Pasangan Model

Pasangan Model	Statistik DM	p-value	$\alpha = 0,05$	Kesimpulan
M1 SARIMA vs M2 SARIMA+Int	-1,24	0,214	Tidak tolak H_0	Perbedaan tidak signifikan secara statistis
M1 SARIMA vs M3 Holt-Winters	0,52	0,603	Tidak tolak H_0	Perbedaan tidak signifikan secara statistis
M2 SARIMA+Int vs M3 Holt-Winters	1,61	0,107	Tidak tolak H_0	Perbedaan tidak signifikan secara statistis

Sumber: Hasil uji Diebold-Mariano, diolah penulis. H_0 : akurasi kedua model setara.

Hasil uji Diebold-Mariano menghasilkan temuan penting: perbedaan akurasi di antara ketiga model tidak signifikan secara statistik pada $\alpha = 0,05$ untuk semua pasangan perbandingan. Ini berarti meskipun Model 3 Holt-Winters memiliki MAPE sedikit lebih rendah dibandingkan Model 1 SARIMA (13,88% vs 14,63%), dan Model 1 lebih baik dari Model 2 (14,63% vs 17,41%), perbedaan-perbedaan tersebut tidak dapat diklaim secara statistik signifikan dengan data uji yang ada. Implikasi praktisnya adalah ketiga model dapat dianggap setara secara statistik dalam kemampuan prediktifnya, dan keputusan pemilihan model sebaiknya mempertimbangkan faktor-faktor lain seperti interpretabilitas, asumsi diagnostik, dan konteks penggunaan.

4.6.4 Proyeksi Penjualan Wholesales 2026 dan Validasi Real-Time

Proyeksi penjualan wholesales mobil lokal Indonesia untuk seluruh tahun 2026 dihasilkan menggunakan ketiga model, dilatih pada full dataset 2016–2025 (120 observasi). Tabel 4.12 menyajikan nilai proyeksi beserta data aktual Gaikindo Januari–Juli 2026 sebagai titik validasi real-time.

Tabel 4.12 Proyeksi 2026 dan Validasi dengan Data Aktual Gaikindo

Bulan	M1	M2	M3	Aktual	APE M1	APE M2	APE M3
Januari	76,4	78,2	77,3	66	15,76%	18,48%	17,12%
Februari	75,4	77,4	78,6	81	6,91%	4,44%	2,96%
Maret	87,9	90,6	89,9	61	44,10%	48,52%	47,38%
April	61,9	76,0	51,4	81	23,58%	6,17%	36,54%
Mei	57,4	74,3	58,9	69	16,81%	7,68%	14,64%
Juni	66,2	77,1	78,7	78	15,13%	1,15%	0,90%
Juli	71,1	76,1	72,8	81	12,22%	6,05%	10,12%
Agustus	82,9	78,1	81,3	—	—	—	—
September	82,1	78,3	82,7	—	—	—	—
Oktober	82,0	80,1	84,1	—	—	—	—
November	86,4	85,9	89,2	—	—	—	—
Desember	84,0	84,8	83,2	—	—	—	—
Total 2026	914	957	928	518*	—	—	—
MAPE Val. 7 bln	19,22%	13,22%	18,52%	—	—	—	—

Sumber: Hasil proyeksi & Gaikindo (2026). Satuan: ribu unit. *Data aktual Jan–Jul 2026 (7 bulan).

Validasi real-time menggunakan data aktual Gaikindo Januari–Juli 2026 menghasilkan temuan yang mengubah peringkat model secara signifikan. Model 2 SARIMA+Intervensi yang pada periode pengujian 2024–2025 tampil paling lemah, justru menghasilkan MAPE validasi 2026 terbaik (13,22%), diikuti Model 3 Holt-Winters

(18,52%) dan Model 1 SARIMA (19,22%). Hal ini mengindikasikan bahwa komponen intervensi dalam Model 2 memberikan koreksi level yang lebih tepat untuk proyeksi jangka menengah melewati periode pandemi, sekalipun pada periode pengujian langsung hasilnya kurang optimal.

Ketiga model memproyeksikan total penjualan 2026 antara 914.000 (Model 1) hingga 957.000 unit (Model 2). Mengingat tren penurunan berturut-turut 2023–2025, proyeksi ini mengimplikasikan stabilisasi atau pemulihan moderat pasar pada 2026. Perbedaan total antara model mencerminkan ketidakpastian inherent dalam proyeksi, dan pengguna disarankan menggunakan rata-rata ketiga proyeksi (± 933.000 unit) sebagai skenario baseline dengan sensitivitas $\pm 2,1\%$.

4.7 Implikasi Manajerial

4.7.1 Bagi Pabrikan dan ATPM

Hasil penelitian ini memberikan beberapa implikasi operasional yang langsung dapat dimanfaatkan oleh Agen Tunggal Pemegang Merek dalam siklus perencanaan produksi dan distribusi tahunan.

1. **Perencanaan Produksi Berbasis Indeks Musiman.** Indeks musiman empiris yang teridentifikasi — Maret tertinggi (1,0931), Juni terendah (0,8485) — sebaiknya diintegrasikan ke dalam sistem Sales & Operations Planning (S&OP) ATPM. Secara konkret, penguatan kapasitas produksi dan stok komponen sebaiknya dilakukan pada Januari–Februari untuk mengantisipasi lonjakan pra-IIMS/pra-Lebaran di Maret. Sebaliknya, penjadwalan maintenance lini produksi dan pengurangan kapasitas sebaiknya dilakukan pada Juni untuk meminimalkan biaya holding cost stok selama low season.
2. **Strategi Rolling Forecast.** Mengingat tidak ada satu model yang secara statistis unggul pada semua dimensi (dikonfirmasi oleh uji Diebold-Mariano), ATPM disarankan untuk menerapkan strategi ensemble forecast — menggunakan rata-rata tertimbang proyeksi ketiga model — sebagai referensi perencanaan yang lebih robust. Bobot dapat disesuaikan berdasarkan kinerja model yang paling mutakhir (rolling window evaluation).
3. **Kalibrasi Ulang Triwulanan.** Temuan degradasi MAPE dari 2024 (rata-rata 11,4%) ke 2025 (rata-rata 19,1%) menunjukkan pentingnya kalibrasi model secara berkala. Direkomendasikan untuk memperbarui model setiap kuartal dengan memasukkan data aktual terbaru, sehingga parameter model senantiasa mencerminkan kondisi pasar terkini dan tren kontraksi yang sedang berlangsung dapat diakomodasi secara adaptif.

4.7.2 Bagi Dealer dan Industri Pembiayaan

Pola musiman yang terdokumentasi dan proyeksi bulanan 2026 memberikan panduan konkret bagi jaringan dealer dan lembaga multifinance dalam perencanaan operasional.

1. **Manajemen Stok Antisipasi Musiman.** Dealer disarankan untuk membangun stok display pada Februari (jelang puncak Maret) dan mengoptimalkan program trade-in

serta cicilan ringan pada Mei–Juni untuk menstimulasi permintaan selama low season. Program insentif akhir tahun sebaiknya diaktifkan pada Oktober (indeks 1,0618) mengingat momentum positif Oktober–Desember yang terkonfirmasi secara historis.

2. Perencanaan Target Penyaluran Kredit. Bagi lembaga pembiayaan otomotif, proyeksi penjualan wholesales 2026 sebesar 914.000–957.000 unit dapat dijadikan acuan proyeksi volume kredit kendaraan baru. Distribusi bulanan dari proyeksi ini (Tabel 4.12) memungkinkan perencanaan kebutuhan likuiditas yang lebih presisi dibandingkan asumsi distribusi rata-rata.

4.7.3 Bagi Regulator dan Pembuat Kebijakan

1. Data Wholesales sebagai Leading Indicator. Penurunan berturut-turut 2023–2025 yang teridentifikasi dalam penelitian ini patut mendapat perhatian Kementerian Perindustrian sebagai indikator tekanan struktural pada daya beli kelas menengah. Penjualan mobil yang melemah secara konsisten — berbeda dari pasar motor yang lebih resilient — dapat menjadi sinyal awal kebutuhan intervensi kebijakan seperti perpanjangan insentif PPnBM atau dukungan skema kredit kendaraan ramah lingkungan.
2. Pentingnya Desain Stimulus yang Tepat Waktu. Pengalaman PPnBM 0% pada 2022 yang berhasil mendorong lonjakan penjualan 17,9% menunjukkan efektivitas stimulus fiskal yang tersinkronisasi dengan siklus musiman industri. Untuk stimulus berikutnya, rekomendasi penelitian ini adalah mendesain program yang diaktifkan pada bulan-bulan low season (Juni–Juli) untuk memaksimalkan efek demand pull dibandingkan mengaktifkannya pada bulan-bulan yang sudah naturally high (Maret, Oktober–Desember).

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini telah melakukan evaluasi dan optimasi model peramalan deret waktu secara komparatif pada data penjualan wholesales mobil lokal Indonesia (Gaikindo) periode 2016–2025, dengan fokus khusus pada penanganan structural break yang ditimbulkan oleh pandemi COVID-19. Berdasarkan keseluruhan analisis yang telah dilaksanakan sesuai dengan tiga rumusan masalah yang ditetapkan, berikut dirumuskan kesimpulan penelitian.

5.1.1 Karakteristik Pola Tren dan Musiman (RM 1)

Data penjualan wholesales mobil lokal Indonesia periode 2016–2025 memperlihatkan karakteristik deret waktu yang kaya dan kompleks, ditandai oleh tiga fase struktural yang berbeda secara statistis. Fase pra-pandemi (2016–2019) menunjukkan pola yang relatif stabil dengan rata-rata 90.100 unit per bulan dan koefisien variasi rendah (12,2%), mencerminkan pasar yang bergerak dalam pola musiman yang teratur. Fase pandemi (2020–2021) mencatatkan guncangan paling ekstrem dalam sejarah industri otomotif Indonesia modern: penjualan Mei 2020 hanya 4.000 unit (koefisien variasi melonjak ke 44,6%), dengan total 2020 anjlok 48,7% menjadi 533.000 unit. Fase pasca-pandemi (2022–2025) ditandai oleh pemulihan parsial yang diikuti kontraksi struktural berturut-turut selama 2023–2025 (–4,0%, –14,1%, –6,7%), mengindikasikan adanya pergeseran permintaan jangka panjang yang melampaui dampak langsung pandemi.

Pola musiman yang teridentifikasi secara konsisten menunjukkan Maret sebagai bulan penjualan tertinggi (indeks musiman 1,0931 pada data normal) yang berkorelasi dengan momentum pra-Lebaran dan pameran IIMS, sementara Juni secara konsisten menjadi bulan terendah (indeks 0,8485) akibat prioritas pengeluaran tahun ajaran baru. Analisis outlier mengidentifikasi empat observasi berpengaruh tinggi pada April–Juli 2020 (Z-score antara –2,70 hingga –3,71) yang menjadi titik intervensi utama dalam Model 2.

5.1.2 Akurasi Peramalan Ketiga Model (RM 2)

Evaluasi akurasi ketiga model pada data uji out-of-sample 2024–2025 ($n = 24$ observasi) menghasilkan temuan yang mencerminkan kompleksitas data yang dianalisis. Ketiga model berada dalam kategori akurasi yang sama — 'Baik' menurut kriteria Lewis (1982) — namun dengan profil kekuatan yang berbeda-beda.

Model 3 Holt-Winters Multiplicative menghasilkan MAPE terkecil (13,88%) dan MAE terkecil (9,52 ribu unit), mengungguli Model 1 SARIMA (MAPE 14,63%, MAE 9,72) dan Model 2 SARIMA+Intervensi (MAPE 17,41%, MAE 11,01). Sebaliknya, Model 1 SARIMA menghasilkan RMSE terkecil (11,02 ribu unit) dan — secara kritis — merupakan satu-satunya model yang memenuhi asumsi white noise residual (Ljung-Box $Q(12) = 19,86$, $p = 0,070$), sedangkan Model 2 dan Model 3 keduanya menunjukkan autokorelasi residual yang signifikan ($p = 0,000$). Uji Diebold-Mariano mengkonfirmasi bahwa perbedaan akurasi

antar semua pasangan model tidak signifikan secara statistik (semua $p\text{-value} > 0,10$), sehingga ketiga model dapat dianggap setara dalam kemampuan prediktifnya.

Tabel 5.1 Ringkasan Evaluasi Komparatif Ketiga Model

Dimensi Evaluasi	M1 SARIMA	M2 SARIMA+Int	M3 Holt- Winters	Model Unggul
MAPE out-of-sample	14,63%	17,41%	13,88%	M3 ✓
RMSE (ribu unit)	11,02	13,16	11,12	M1 ✓
MAE (ribu unit)	9,72	11,01	9,52	M3 ✓
Diagnostik residual	White noise ✓	Autokorelasi ✗	Autokorelasi ✗	M1 ✓
Normalitas residual	Skew -0,38	Skew 0,02 ✓	Skew -0,39	M2 ✓
MAPE validasi Jan–Jul 2026	19,22%	13,22%	18,52%	M2 ✓
Uji Diebold-Mariano	—	—	—	Tidak signifikan (setara)
Kategori Lewis (1982)	Baik	Baik	Baik	Semua setara
Total keunggulan	2×	2×	2×	Seimbang

Sumber: Diolah penulis dari hasil analisis Bab 4.

5.1.3 Efektivitas Intervensi COVID-19 (RM 3)

Pertanyaan penelitian ketiga — apakah penerapan intervensi COVID-19 meningkatkan akurasi SARIMA — menghasilkan jawaban yang bernuansa dan tidak bersifat tunggal. Secara akurasi out-of-sample (MAPE), SARIMA+Intervensi (Model 2) justru menghasilkan nilai yang lebih tinggi (17,41%) dibandingkan SARIMA konvensional (14,63%), bertentangan dengan hipotesis awal. Namun pada dimensi lain, intervensi terbukti memberikan nilai: varians residual Model 2 lebih kecil ($\sigma^2 = 142,1$ vs 185,4), distribusi residual lebih simetris (skewness mendekati nol), dan MAPE validasi real-time Januari–Juli 2026 lebih baik (13,22% vs 19,22%). Koefisien intervensi yang semuanya signifikan — $\omega_1 = -67.800$ unit (pulse April 2020), $\omega_2 = -71.800$ unit (pulse Mei 2020), $\delta = -28.400$ unit/bulan (step pandemi) — memberikan kuantifikasi dampak pandemi yang tidak tersedia dari model tanpa intervensi.

Kesimpulan yang dapat ditarik adalah bahwa komponen intervensi memberikan keunggulan deskriptif dan proyektif jangka menengah yang signifikan, namun tidak selalu menghasilkan akurasi out-of-sample yang lebih baik pada periode evaluasi langsung. Hal ini disebabkan oleh keterbatasan implementasi intervensi melalui replacement approach pada SPSS, dan ketidakmampuan semua model untuk mengakomodasi tren kontraksi struktural 2023–2025 yang bersifat anomali terhadap pola historis. Model terbaik secara keseluruhan

— dengan mempertimbangkan semua dimensi evaluasi termasuk validasi 2026 — adalah SARIMA(0,1,1)(0,1,1)₁₂ dengan komponen intervensi (Model 2), khususnya untuk keperluan proyeksi jangka menengah.

Secara keseluruhan, penelitian ini menyimpulkan bahwa dalam menghadapi data deret waktu yang mengalami structural break berskala pandemi, tidak ada satu model yang secara universal superior. Pemilihan model terbaik bergantung pada tujuan penggunaan: jika prioritas adalah akurasi out-of-sample pada periode dekat, Model 3 Holt-Winters memberikan MAPE terbaik; jika prioritas adalah kepatuhan asumsi statistik, Model 1 SARIMA konvensional lebih unggul; dan jika prioritas adalah proyeksi jangka menengah yang tervalidasi secara real-time, Model 2 SARIMA+Intervensi terbukti lebih andal.

5.2 Saran

Berdasarkan temuan, kesimpulan, dan keterbatasan penelitian yang telah diidentifikasi, berikut disampaikan saran yang ditujukan kepada empat kelompok pemangku kepentingan: peneliti lanjutan, pelaku industri otomotif, lembaga pembiayaan, dan regulator.

5.2.1 Saran bagi Peneliti Lanjutan

Penelitian ini membuka beberapa arah pengembangan metodologis yang substansial dan layak diprioritaskan oleh peneliti berikutnya.

1. Estimasi Simultan Intervensi via R atau Python.

Keterbatasan paling signifikan penelitian ini adalah penggunaan replacement approach dalam implementasi intervensi di SPSS, yang tidak dapat mengoptimalkan koefisien intervensi dan parameter SARIMA secara simultan. Peneliti lanjutan sangat disarankan menggunakan paket *tseries* atau *TSA* di R, atau library *statsmodels* di Python, yang mendukung prosedur joint MLE estimation untuk ARIMAX dengan komponen intervensi. Estimasi simultan akan menghasilkan koefisien yang lebih efisien dan residual yang memenuhi asumsi white noise.

2. Eksplorasi Model SARIMA-GARCH untuk Heteroskedastisitas

Data penjualan otomotif Indonesia menunjukkan varians yang berubah secara dramatis antar fase (CV 12,2% vs 44,6%), mengindikasikan kemungkinan conditional heteroscedasticity. Model GARCH (Generalized Autoregressive Conditional Heteroscedasticity) yang digabungkan dengan SARIMA dapat menangkap volatilitas yang berubah-ubah ini secara eksplisit, berpotensi menghasilkan interval prediksi yang lebih akurat khususnya pada periode transisi struktural.

3. Model SARIMAX dengan Variabel Eksogen.

Tren kontraksi 2023–2025 yang tidak terprediksi oleh semua model mengindikasikan adanya faktor-faktor eksogen yang belum dimodelkan. Penelitian lanjutan disarankan mengintegrasikan variabel seperti: tingkat suku bunga kredit kendaraan (KPM), harga BBM, Indeks Keyakinan Konsumen (IKK) Bank Indonesia, nilai tukar rupiah, dan data penjualan kendaraan listrik (EV) sebagai regressors dalam kerangka SARIMAX. Hal ini berpotensi

meningkatkan MAPE secara signifikan, khususnya untuk data 2023–2025 yang memperlihatkan anomali struktural.

4. Pendekatan Hybrid SARIMA-Machine Learning.

M4-Competition (Makridakis et al., 2020) membuktikan bahwa model hybrid yang menggabungkan statistik klasik dengan machine learning secara konsisten mengungguli masing-masing pendekatan secara terpisah. Penelitian lanjutan dapat mengeksplorasi kombinasi SARIMA+Intervensi (untuk komponen linear dan musiman) dengan LSTM atau XGBoost (untuk komponen non-linear dan interaksi kompleks), menggunakan data Gaikindo yang sama sebagai benchmark perbandingan.

5. Analisis Granular Per Segmen dan Per Merek.

Penelitian ini menggunakan data agregat total pasar yang menyembunyikan heterogenitas antar segmen. Penelitian lanjutan disarankan melakukan pemodelan SARIMA+Intervensi secara terpisah untuk segmen LCGC, LMPV, SUV, dan kendaraan listrik (EV), karena setiap segmen memiliki profil structural break dan pola pemulihan yang berbeda secara substantif. Analisis per merek juga dapat memberikan wawasan tentang dampak asimetris pandemi terhadap pemain yang berbeda.

6. Koreksi Kalender Lebaran (Trading Day Adjustment).

Identifikasi bulan April sebagai bulan dengan APE tertinggi (hingga 55%) pada semua model mengkonfirmasi perlunya penanganan efek kalender Hijriah secara eksplisit. Penelitian lanjutan disarankan menerapkan metode X-13ARIMA-SEATS (dikembangkan oleh US Census Bureau) yang secara otomatis mengkoreksi efek hari perdagangan dan hari libur variabel, atau mengintegrasikan variabel dummy Lebaran berbasis kalender Hijriah sebagai regressor musiman.

7. Perluasan Validasi Real-Time hingga Akhir 2026.

Penelitian ini hanya memiliki data aktual Gaikindo untuk Januari–Juli 2026 (7 titik validasi). Setelah data 2026 tersedia lengkap, sangat disarankan untuk memperpanjang validasi ke seluruh 12 bulan 2026 guna mendapatkan evaluasi kinerja model yang komprehensif pada cakrawala proyeksi penuh, dan untuk mengkonfirmasi apakah keunggulan Model 2 pada validasi parsial Jan–Jul 2026 (MAPE 13,22%) bertahan sepanjang tahun.

8. Studi Komparatif Lintas Negara ASEAN.

Temuan penelitian ini tentang profil structural break yang asimetris dan pemulihan yang tidak sempurna pasca-pandemi menarik untuk dibandingkan dengan negara ASEAN lain seperti Thailand, Malaysia, dan Vietnam yang memiliki industri otomotif signifikan. Studi komparatif ini akan memberikan wawasan tentang apakah pola yang ditemukan di Indonesia bersifat idiosinkratik atau merupakan fenomena regional.

5.2.2 Saran bagi Pelaku Industri Otomotif

Temuan empiris penelitian ini mengandung implikasi operasional yang dapat langsung diterapkan oleh ATPM dan jaringan dealer.

1. Adopsi Ensemble Forecasting dalam S&OP. Mengingat uji Diebold-Mariano mengkonfirmasi ketiga model setara secara statistik, ATPM disarankan mengadopsi pendekatan ensemble: menghitung rata-rata tertimbang proyeksi ketiga model sebagai angka referensi perencanaan (Sales & Operations Planning). Bobot dapat disesuaikan secara rolling berdasarkan MAPE tiga bulan terakhir masing-masing model, sehingga model yang lebih akurat secara situasional mendapatkan bobot lebih besar secara otomatis.
2. Pemanfaatan Indeks Musiman untuk Optimasi Operasional. Indeks musiman yang terdokumentasi secara empiris (Tabel 4.3) sebaiknya dijadikan acuan baku dalam: (a) penjadwalan shutdown maintenance lini produksi pada Juni (indeks 0,8485 — titik paling tepat untuk downtime produksi); (b) penentuan waktu optimal peluncuran model baru (idealnya Agustus–September untuk memanfaatkan momentum Oktober–November); dan (c) negosiasi target distribusi dealer per bulan yang proporsional dengan indeks musiman, bukan target flat bulanan yang tidak realistis.
3. Sistem Deteksi Dini Anomali Penjualan. Berdasarkan pengalaman pandemi, ATPM disarankan membangun sistem early warning berbasis Z-score bulanan: apabila penjualan aktual menyimpang lebih dari 2,5 standar deviasi dari proyeksi model, sistem secara otomatis memicu review darurat terhadap faktor penyebab dan penyesuaian rencana produksi. Threshold ini didasarkan pada analisis outlier penelitian ini yang mengidentifikasi Z-score $-2,70$ sebagai batas semi-outlier pertama pada Juli 2020.

5.2.3 Saran bagi Lembaga Pembiayaan Otomotif

1. Skenario Proyeksi Berlapis untuk Manajemen Risiko. Lembaga multifinance otomotif disarankan menggunakan tiga skenario proyeksi kredit kendaraan baru yang didasarkan pada tiga model dalam penelitian ini: skenario konservatif (berbasis Model 1 SARIMA: proyeksi 2026 ~914.000 unit), skenario moderat (Model 3 Holt-Winters: ~928.000 unit), dan skenario optimistis (Model 2 SARIMA+Intervensi: ~957.000 unit). Rentang ini memberikan batas bawah dan atas yang realistis untuk perencanaan likuiditas dan penetapan target penyaluran kredit tahunan.
2. Penyesuaian Kebijakan Kredit Berbasis Musiman. Pola musiman penjualan yang terdokumentasi (bulan Maret dan Oktober–Desember sebagai peak season) sebaiknya diintegrasikan ke dalam kebijakan operasional lembaga pembiayaan: meningkatkan kuota approval kredit pada bulan-bulan peak, dan mengoptimalkan program retensi dan cross-selling pada Juni–Juli (low season) untuk menjaga produktivitas tim sales tanpa mengandalkan volume aplikasi baru yang memang secara musiman lebih rendah.

5.2.4 Saran bagi Regulator dan Pembuat Kebijakan

1. Desain Stimulus Berbasis Siklus Musiman. Penelitian ini menunjukkan bahwa stimulus PPnBM 0% yang diterapkan sepanjang 2022 menghasilkan pertumbuhan 17,9%, namun diikuti oleh pull-forward effect yang turut berkontribusi pada kontraksi 2023–2025. Untuk stimulus berikutnya, disarankan mendesain program yang lebih tersegmentasi secara temporal: mengaktifkan stimulus pada bulan-bulan low season (Mei–Juli) dengan durasi terbatas (3 bulan), sehingga demand stimulation

terjadi saat pasar paling membutuhkan dorongan tanpa menciptakan pull-forward yang mendistorsi pola permintaan jangka panjang.

2. Pemantauan Tren Kontraksi sebagai Indikator Makroekonomi. Tren penurunan penjualan mobil 2023–2025 yang teridentifikasi dalam penelitian ini patut mendapat perhatian serius Kementerian Perindustrian dan Bank Indonesia sebagai indikator daya beli kelas menengah. Pemantauan bulanan data Gaikindo dalam dashboard ekonomi nasional, dilengkapi dengan peringatan otomatis ketika penjualan menyimpang lebih dari 15% dari baseline proyeksi model, dapat menjadi early warning system yang efektif untuk respons kebijakan yang lebih tepat waktu.
3. Penguatan Kualitas dan Aksesibilitas Data Gaikindo. Penelitian ini hanya dapat mengakses data agregat total pasar. Pemerintah disarankan mendorong Gaikindo untuk mempublikasikan data yang lebih terperinci: disagregasi per segmen kendaraan, per wilayah distribusi, dan — seiring pertumbuhan EV — pemisahan eksplisit antara kendaraan ICE dan kendaraan listrik/hybrid. Data yang lebih granular ini akan memungkinkan penelitian peramalan yang jauh lebih presisi dan berguna bagi semua pemangku kepentingan.

Penelitian ini membuktikan bahwa baik SARIMA konvensional, SARIMA dengan intervensi pandemi, maupun Holt-Winters Multiplicative, masing-masing memiliki keunggulan komparatif pada dimensi evaluasi yang berbeda ketika dihadapkan pada data time series yang mengalami structural break. Tidak ada silver bullet dalam pemilihan model peramalan pada kondisi data yang tidak ideal, yang diperlukan adalah pemahaman mendalam tentang karakteristik data, tujuan penggunaan proyeksi, dan kesadaran terhadap keterbatasan inheren dari setiap pendekatan. Kontribusi terbesar penelitian ini bukan pada model mana yang 'menang', melainkan pada kerangka evaluasi multi-dimensi yang disajikan untuk membantu pengambil keputusan memilih model yang paling sesuai dengan konteks spesifik mereka.

DAFTAR PUSTAKA

- Box, G. E. P., & Tiao, G. C. (1975). Intervention analysis with applications to economic and environmental problems. *Journal of the American Statistical Association*, 70(349), 70–79. <https://doi.org/10.2307/2285379>
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control* (5th ed.). John Wiley & Sons.
- Burnham, K. P., & Anderson, D. R. (2002). *Model selection and multimodel inference: A practical information-theoretic approach* (2nd ed.). Springer.
- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). *CRISP-DM 1.0: Step-by-step data mining guide*. SPSS Inc.
- Chatfield, C. (2004). *The analysis of time series: An introduction* (6th ed.). Chapman and Hall/CRC Press.
- Diebold, F. X., & Mariano, R. S. (1995). Comparing predictive accuracy. *Journal of Business & Economic Statistics*, 13(3), 253–263. <https://doi.org/10.1080/07350015.1995.10524599>
- Gabungan Industri Kendaraan Bermotor Indonesia (Gaikindo). (2025). *Data penjualan wholesales mobil lokal nasional Januari 2016 – Desember 2025*. <https://www.gaikindo.or.id>
- Gabungan Industri Kendaraan Bermotor Indonesia (Gaikindo). (2026). *Data penjualan wholesales Januari–Juli 2026*. <https://www.gaikindo.or.id>
- Harvey, A. C. (1990). *Forecasting, structural time series models and the Kalman filter*. Cambridge University Press.
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts. <https://otexts.com/fpp3/>
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- IBM. (2021). *IBM SPSS statistics 28 algorithms*. IBM Corp.
- Lewis, C. D. (1982). *Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting*. Butterworth Scientific.
- Ljung, G. M., & Box, G. E. P. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297–303. <https://doi.org/10.1093/biomet/65.2.297>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2020). The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1), 54–74. <https://doi.org/10.1016/j.ijforecast.2019.04.014>

- Makridakis, S., Wheelwright, S. C., & McGee, V. E. (1982). *Forecasting: Methods and applications* (2nd ed.). John Wiley & Sons.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2015). *Introduction to time series analysis and forecasting* (2nd ed.). John Wiley & Sons.
- Nikolopoulos, K., Punia, S., Schäfers, A., Tsinopoulos, C., & Vasilakis, C. (2021). Forecasting and planning during a pandemic: COVID-19 growth rates, supply chain disruptions, and governmental decisions. *European Journal of Operational Research*, 290(1), 99–115. <https://doi.org/10.1016/j.ejor.2020.08.001>
- Oktavia, R., Santoso, T., & Wibowo, H. (2021). Penerapan model Seasonal ARIMA dalam peramalan penjualan sepeda motor di dealer regional Jawa Tengah. *Jurnal Statistika dan Komputasi*, 4(2), 87–98.
- Papastefanopoulos, V., Linardatos, P., & Kotsiantis, S. (2021). COVID-19: A comparison of time series methods to forecast percentage of active cases per population. *Applied Sciences*, 10(1), 2–21. <https://doi.org/10.3390/app10082365>
- Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Taieb, S. B., & Ziel, F. (2022). *Forecasting: Theory and practice*. *International Journal of Forecasting*, 38(3), 705–871. <https://doi.org/10.1016/j.ijforecast.2021.11.001>
- Phillips, P. C. B., & Perron, P. (1988). Testing for a unit root in time series regression. *Biometrika*, 75(2), 335–346. <https://doi.org/10.1093/biomet/75.2.335>
- Saengsook, A., & Wannakomol, A. (2019). Forecasting automobile sales in Thailand using SARIMA model. *International Journal of Business and Economics Research*, 8(4), 231–239.
- Santoso, D., & Suprihatin, T. (2020). Model SARIMA untuk peramalan permintaan produk manufaktur berpola musiman. *Jurnal Teknik Industri*, 21(1), 45–54.
- Sugiyono. (2019). *Metode penelitian kuantitatif, kualitatif, dan R&D* (edisi ke-2). Alfabeta.
- Tsay, R. S. (1988). Outliers, level shifts, and variance changes in time series. *Journal of Forecasting*, 7(1), 1–20. <https://doi.org/10.1002/for.3980070102>
- Wei, W. W. S. (2019). *Multivariate time series analysis and applications*. John Wiley & Sons.
- Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management Science*, 6(3), 324–342. <https://doi.org/10.1287/mnsc.6.3.324>