

PEMODELAN ARIMA UNTUK PREDIKSI PEMESANAN ES BATU KRISTAL PADA DATA HISTORIS AGEN

Abel Amanda Ardalia, Faulinda Ely Nastiti, Afu Ichsan Pradana

Teknik Informatika, Universitas Duta Bangsa Surakarta

Jalan Bhayangkara No 55 Surakarta, Indonesia

220103042@mhs.udb.ac.id

ABSTRAK

Es batu kristal merupakan komoditas yang banyak digunakan pada sektor kuliner, perhotelan, dan rumah tangga sehingga permintaannya berfluktuasi dari waktu ke waktu. Kondisi tersebut menyulitkan agen distribusi dalam menentukan jumlah stok yang tepat dan berpotensi menyebabkan kelebihan maupun kekurangan persediaan. Penelitian ini bertujuan membangun model peramalan permintaan es batu kristal pada Agen Mas Bowil menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA) untuk mendukung pengambilan keputusan pemesanan yang lebih akurat. Data yang digunakan berupa data historis pemesanan harian periode Mei–Oktober 2025 sebanyak 184 observasi yang terdiri atas Shift 1, Shift 2, Shift 3, dan total pemesanan harian. Tahapan penelitian meliputi pra-pemrosesan data, pengujian stasioneritas menggunakan *Augmented Dickey-Fuller* (ADF), proses *differencing*, identifikasi parameter model, serta evaluasi menggunakan MAE, RMSE, dan MAPE. Hasil penelitian menunjukkan bahwa model ARIMA(0,1,1) pada data total harian menghasilkan performa terbaik dengan nilai MAPE sebesar 19,12%, sedangkan performa terbaik pada data per shift diperoleh Shift 3 dengan nilai MAPE sebesar 19,89%. Hasil tersebut menunjukkan bahwa agregasi data harian mampu menghasilkan prediksi yang lebih stabil dibandingkan pemodelan per shift. Meskipun demikian, pola prediksi yang terbentuk masih menunjukkan indikasi *underfitting* sehingga diperlukan data historis yang lebih panjang pada penelitian selanjutnya.

Kata kunci : ARIMA, peramalan, time series, es batu kristal, pemesanan, shift operasional

1. PENDAHULUAN

Es batu kristal merupakan komoditas yang banyak dimanfaatkan dalam berbagai sektor, termasuk industri kuliner, pengawetan bahan pangan, dan kebutuhan rumah tangga. Permintaan terhadap komoditas ini cenderung berfluktuasi karena dipengaruhi oleh karakteristik pelanggan yang beragam, mulai dari usaha mikro hingga sektor perhotelan dan restoran berskala besar. Variasi kebutuhan tersebut menyebabkan jumlah permintaan harian tidak selalu konstan sehingga menimbulkan tantangan dalam pengelolaan persediaan.

Pengelolaan permintaan yang berfluktuasi menjadi aspek penting bagi keberlangsungan operasional agen distribusi. Ketidaksesuaian antara stok yang tersedia dan kebutuhan aktual pelanggan dapat menyebabkan kerugian operasional, baik akibat kelebihan stok yang berpotensi menurunkan kualitas produk maupun kekurangan stok yang menghambat proses distribusi dan menurunkan tingkat kepuasan pelanggan[1]. Permasalahan tersebut juga dialami oleh Toko Es Batu Kristal Mas Bowil sebagai agen distributor yang memperoleh pasokan dari PT. Jembar Amerta Wening. Fluktuasi permintaan yang sulit diprediksi menyebabkan proses penentuan jumlah pemesanan masih dilakukan berdasarkan perkiraan, sehingga berpotensi menimbulkan ketidakefisienan operasional dan memengaruhi stabilitas ekonomi agen [2].

Salah satu pendekatan yang dapat digunakan untuk mengatasi permasalahan tersebut adalah

peramalan berbasis data historis. Metode *Autoregressive Integrated Moving Average* (ARIMA) merupakan metode analisis deret waktu yang mampu memodelkan data non-stasioner melalui proses *differencing* sehingga dapat menghasilkan prediksi jangka pendek yang stabil dan konsisten[3]. Selain itu, keandalan model ini juga sering kali digunakan pada berbagai penelitian peramalan karena memiliki kemampuan yang baik dalam menangkap pola data historis serta menghasilkan tingkat akurasi yang kompetitif [4].

Beberapa penelitian terdahulu telah mengimplementasikan metode ARIMA pada berbagai studi peramalan. Akan tetapi, penerapan metode tersebut pada sistem distribusi es batu kristal dengan pendekatan berbasis shift operasional masih terbatas. Padahal, pengelompokan data berdasarkan shift operasional berpotensi menghasilkan informasi yang lebih detail terkait pola fluktuasi permintaan pada periode waktu tertentu, sehingga dapat membantu pengambilan keputusan operasional secara lebih tepat.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk membangun model peramalan permintaan es batu kristal menggunakan metode ARIMA dengan mendistribusikan variabel data ke dalam tiga *shift* operasional (Shift 1, Shift 2, dan Shift 3) beserta akumulasi total harian. Model prediktif yang dihasilkan diharapkan mampu memandu agen dalam mengambil keputusan pemesanan yang akurat guna mendukung efisiensi pengelolaan persediaan.

2. TINJAUAN PUSTAKA

2.1. Forecasting (Peramalan)

Forecasting atau peramalan merupakan suatu proses analisis untuk memprediksi kemungkinan yang akan terjadi di masa mendatang dengan memanfaatkan data historis sebagai dasar pengambilan keputusan. Pendekatan peramalan dapat dilakukan secara kuantitatif maupun kualitatif guna mengurangi tingkat ketidakpastian dalam perencanaan operasional dan manajerial[5]. Selain itu, peramalan juga digunakan sebagai bentuk estimasi terhadap kemungkinan terjadinya suatu peristiwa di masa depan sehingga dapat membantu proses pengendalian dan penyusunan strategi operasional secara lebih efektif[6].

2.2. Time Series (Data Runtun Waktu)

Time series merupakan sekumpulan data yang tersusun berdasarkan urutan periode pengamatan tertentu, sehingga setiap observasi memiliki keterkaitan dengan nilai pada waktu sebelumnya. Analisis terhadap data jenis ini umum digunakan untuk mengidentifikasi pola pergerakan dari waktu ke waktu, sekaligus mendukung proses peramalan pada periode mendatang[7]. Analisis ini mengasumsikan adanya korelasi antar observasi guna mengidentifikasi pola historis seperti tren dan variasi musiman untuk memproyeksikan nilai di masa mendatang[5]. Implementasi peramalan pada data ini mencakup pendekatan statistik konvensional maupun algoritma cerdas yang bekerja melalui teknik pemulusan (*smoothing*) atau dekomposisi komponen data guna membagi struktur data ke dalam aspek tren, siklus, dan fluktuasi acak[8].

2.3. Metode ARIMA

ARIMA atau *Autoregressive Integrated Moving Average* merupakan pendekatan statik pada analisis *time series* yang berfungsi untuk membentuk model prediksi berdasarkan pola historis data. Metode ini bekerja dengan memprediksi nilai variabel pada periode waktu selanjutnya berdasarkan pola korelasi pada data historis. Dasar pemikiran dari model ARIMA adalah bahwa pengamatan saat ini (Z_t) sangat bergantung pada satu atau beberapa pengamatan sebelumnya Z_{t-k} .

Model ARIMA (p, d, q) secara matematis dapat dinyatakan dalam persamaan berikut[9] :

$$B_p(B) (1 - B)^d Z_t = b_0 + C_q(B)e_t \quad (1)$$

Dengan :

Z_t adalah Data time series sebagai variabel dependen pada waktu ke- t .

B_p adalah $b_1, b_2, \dots, b_p$ (parameter model AR).

C_q adalah $c_1, c_2, \dots, c_q$ (parameter model MA)

e_t adalah Nilai kesalahan pada kurun waktu ke- ($t-q$)

2.4. Evaluasi Akurasi Peramalan

Ketepatan hasil proyeksi dari model yang dibangun wajib dievaluasi menggunakan metrik kesalahan standar. Pengukuran ini berfungsi sebagai indikator objektif apakah model tersebut layak

digunakan. Tiga metrik yang umum diaplikasikan dalam evaluasi prediksi runtun waktu meliputi:

a. Mean Absolute Error (MAE)

Mean absolute error (MAE) digunakan untuk mengukur rata-rata besarnya kesalahan absolut antara nilai aktual dan nilai prediksi yang dihasilkan oleh model. Metrik ini menunjukkan seberapa jauh prediksi model dari nilai aktual secara umum, tanpa memperhatikan arah kesalahan. MAE sering dipilih karena interpretasinya yang sederhana dan langsung merepresentasikan satuan data aslinya [10].

$$MAE = \frac{\sum_{i=1}^n |Y_{aktual,i} - Y_{prediksi,i}|}{n} \quad (2)$$

Keterangan :

n = Jumlah total data pengamatan pada data uji (testing set).

$Y_{aktual,i}$ = Nilai aktual pada pengamatan ke- i .

$Y_{prediksi,i}$ = Nilai prediksi model pada pengamatan ke- i

b. Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) merupakan metode evaluasi untuk mengukur tingkat kesalahan prediksi model berdasarkan akar kuadrat dari rata-rata error kuadrat. Metode ini memberikan bobot kesalahan yang lebih tinggi pada error berukuran besar sehingga sering digunakan untuk menilai performa model peramalan. Semakin kecil nilai RMSE, semakin baik pula kemampuan model dalam menghasilkan prediksi yang mendekati data aktual[11].

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (f_i - y_i)^2}{n}} \quad (3)$$

c. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) menyajikan persentase tingkat kesalahan prediksi secara relatif terhadap data aktual. Metrik ini sangat populer karena mudah diinterpretasikan dalam bentuk persentase[10]

$$MAPE = \frac{100\%}{n} \sum_{i=0}^n \left| \frac{Y_{aktual,i} - Y_{prediksi,i}}{Y_{aktual,i}} \right| \quad (4)$$

Keterangan :

n = Jumlah total data pengamatan pada data uji (testing set).

$Y_{aktual,i}$ = Nilai aktual pada pengamatan ke- i .

$Y_{prediksi,i}$ = Nilai prediksi model pada pengamatan ke- i

2.5. Penelitian Terdahulu

Penelitian mengenai metode peramalan deret waktu (*time series*) telah banyak diterapkan pada berbagai bidang untuk memprediksi pola data berdasarkan historis. Metode ARIMA banyak digunakan karena mampu menangkap pola data berdasarkan nilai masa lalu, tren, dan error. Fauzani dan Rahmi [2] menerapkan metode ARIMA untuk meramalkan harga produksi karet di Provinsi Riau dan menunjukkan bahwa model ARIMA mampu digunakan untuk memprediksi data berdasarkan pola historis yang terbentuk. Hasil penelitian tersebut

menunjukkan bahwa ARIMA dapat menjadi alternatif yang efektif dalam mendukung proses pengambilan keputusan.

Penelitian lain juga menunjukkan bahwa karakteristik data sangat mempengaruhi performa model peramalan. Fadillah dan Hendrastuty [3] menggunakan pendekatan time series analysis untuk memprediksi stok barang pada toko retail dan menemukan bahwa tingginya fluktuasi data dapat meningkatkan nilai kesalahan prediksi sehingga menurunkan performa model. Hal ini menunjukkan bahwa stabilitas data menjadi faktor penting dalam akurasi peramalan.

Umam [4] melakukan perbandingan metode ARIMA dan Long Short-Term Memory (LSTM) pada prediksi jumlah pengunjung perpustakaan. Hasil penelitian menunjukkan bahwa ARIMA mampu memberikan hasil yang baik pada data dengan pola yang relatif linear, namun memiliki keterbatasan dalam menangkap pola yang lebih kompleks dibandingkan metode berbasis deep learning.

Selain itu, Widiyanto dan Mayasari [6] menerapkan Seasonal ARIMA pada data penjualan kendaraan dan menunjukkan bahwa pendekatan time series dapat digunakan untuk mengidentifikasi pola historis data serta menghasilkan prediksi yang dapat digunakan sebagai dasar perencanaan. Asrirawan dkk. [7] juga menjelaskan bahwa model univariate time series memiliki keterbatasan dalam menghadapi data dengan nilai ekstrem dan fluktuasi tinggi, yang dapat mempengaruhi akurasi prediksi.

Rizquallah [9] menggunakan metode ARIMA untuk peramalan permintaan produk dan menemukan bahwa kualitas serta karakteristik data sangat berpengaruh terhadap performa model. Data yang lebih stabil cenderung menghasilkan akurasi yang lebih baik dibandingkan data yang memiliki volatilitas tinggi.

Berdasarkan penelitian terdahulu tersebut, metode ARIMA terbukti efektif dalam berbagai kasus peramalan deret waktu. Namun, sebagian besar penelitian masih menggunakan satu tingkat agregasi data dan belum banyak yang membandingkan performa model berdasarkan perbedaan granularitas data operasional. Selain itu, penelitian terkait penerapan ARIMA pada data permintaan es batu kristal dengan segmentasi waktu operasional berdasarkan tiga shift kerja dan data total harian masih terbatas.

Oleh karena itu, penelitian ini berfokus pada analisis perbandingan performa model ARIMA pada data permintaan es batu kristal berdasarkan tiga shift operasional dan data total harian untuk mengetahui pengaruh tingkat granularitas data terhadap akurasi peramalan.

3. METODE PENELITIAN

3.1. Pengumpulan dan Pra-pemrosesan Data

Penelitian ini menggunakan metode kuantitatif berbasis data historis sekunder yang diperoleh melalui

dokumentasi pencatatan pemesanan harian pada Agen Es Batu Kristal Mas Bowil. Observasi dilakukan selama enam bulan, selama periode 1 Mei 2025 hingga 31 Oktober 2025, menghasilkan 184 baris data. Dataset ini memuat variabel tanggal dan rincian volume pesanan yang didekomposisi ke dalam tiga shift operasional beserta akumulasi total harian. Observasi dan wawancara dengan pengelola agen juga dilakukan sebagai validasi silang terhadap kondisi operasional di lapangan. Contoh struktur dataset yang digunakan dalam penelitian ditunjukkan pada Tabel 1.


Tabel 1. Dataset

Tanggal	Shift 1	Shift 2	Shift 3	Total Harian
2025-05-01	120	95	80	295
2025-05-02	140	110	90	340
2025-05-03	100	85	70	255

Tahap awal penelitian dilakukan melalui proses pra-pemrosesan data untuk memastikan kualitas dataset sebelum pemodelan. Proses tersebut meliputi penanganan *missing values* dan identifikasi *outlier*. Selanjutnya, data dipartisi berdasarkan urutan waktu dengan komposisi 80% sebagai data pelatihan (*training*) dan 20% sebagai data pengujian (*testing*) untuk mendukung proses pembentukan dan evaluasi model ARIMA.

3.2. Tahapan Pemodelan ARIMA

Arsitektur penelitian ini mengikuti tahapan analisis deret waktu sistematis yang di ilustrasikan melalui Gambar 1.



Gambar 1. Diagram Alir Tahapan ARIMA

Pada tahap awal, dilakukan melalui pra-pemrosesan data dengan menangani data yang hilang dan membagi dataset berdasarkan urutan waktu menjadi data latih dan data uji dengan rasio 80:20. Setelah itu, stasioneritas data diuji menggunakan metode ADF atau *Augmented Dickey-Fuller*. Apabila data bersifat non-stasioner, proses *differencing* diterapkan hingga mencapai kondisi konstan. Identifikasi parameter model ARIMA (p, d, q) ditentukan melalui observasi visual pada plot ACF dan PACF. Setelah model terbentuk, parameter diestimasi menggunakan pendekatan MLE atau *Maximum Likelihood Estimation*, sedangkan evaluasi performa model diukur menggunakan parameter evaluasi seperti MAE, RMSE, dan MAPE untuk mengetahui akurasi dari hasil prediksi harian.

4. HASIL DAN PEMBAHASAN


4.1. Pra-pemrosesan Data

Pada penelitian ini, tahap awal difokuskan pada pembersihan dan penyiapan dataset untuk menjamin validitas model. Hasil pengecekan *missing values* pada setiap variabel ditampilkan pada Tabel 1. Berdasarkan hasil pemeriksaan tersebut, seluruh variabel tidak memiliki data kosong sehingga seluruh data dapat digunakan pada tahap analisis.

Tabel 2. Hasil pemeriksaan missing values


Variabel	Jumlah Missing Values
Tanggal	0
Shift 1	0
Shift 2	0
Shift 3	0
Total Harian	0

Selain pemeriksaan *missing values*, dilakukan pula identifikasi nilai ekstrem (*outliers*) menggunakan visualisasi boxplot seperti yang diperlihatkan pada Gambar 2. Berdasarkan hasil visualisasi, ditemukan beberapa nilai ekstrem pada data pemesanan. Namun demikian, nilai tersebut tetap dipertahankan karena dinilai mampu merepresentasikan kondisi fluktuasi permintaan yang terjadi secara nyata di lapangan.



Gambar 2. Visualisasi outlier menggunakan boxplot


Pada tahap berikutnya, dataset dibagi secara kronologis menjadi data training dan data testing dengan perbandingan 80:20. Pendekatan tersebut diterapkan untuk menjaga urutan waktu pada analisis *time series* agar pola historis data tetap terpelihara. Berdasarkan visualisasi pola data pemesanan pada Gambar 3, terlihat bahwa data memiliki fluktuasi yang cukup tinggi sehingga proses identifikasi dan penentuan parameter model ARIMA menjadi lebih kompleks.



Gambar 3. Pola Data Pemesanan (Time Series)

4.2. Pemodelan Shift 1

Pada tahap ini, pengujian dilakukan menggunakan metode ADF atau *Augmented Dickey-Fuller* pada data Shift 1 menghasilkan nilai *p-value* sebesar 0,0769 ($p > 0,05$), sehingga data dinyatakan tidak stasioner. Sehingga dilakukan proses *differencing* orde pertama ($d = 1$) untuk mencapai kondisi stasioner seperti pada Gambar 4.



Gambar 4. Data Setelah Differencing Shift 1

Berdasarkan Gambar 4, pola data setelah *differencing* menunjukkan fluktuasi yang lebih stabil di sekitar nilai rata-rata, sehingga data memenuhi asumsi stasioneritas dan layak digunakan pada tahap pemodelan ARIMA. Tahap pemilihan model dilakukan dengan mengevaluasi beberapa model menggunakan indikator *Akaike Information Criterion* (AIC). Model yang menghasilkan nilai AIC terendah dianggap memiliki performa terbaik dan dipilih sebagai model yang paling optimal. Ringkasan hasil perbandingan model dapat dilihat pada Tabel 3.

Tabel 3. Perbandingan nilai AIC model Shift 1


Model ARIMA	Nilai AIC
ARIMA(1,1,0)	1162,61
ARIMA(0,1,1)	1145,56
ARIMA(1,1,1)	1147,82

Hasil perbandingan pada Tabel 3 menunjukkan bahwa model ARIMA(0,1,1) memberikan performa terbaik berdasarkan nilai AIC terendah dibandingkan alternatif model lainnya. Untuk mengukur tingkat akurasi prediksi, dilakukan evaluasi menggunakan parameter MAE, RMSE, dan MAPE.

Hasil pengujian menunjukkan nilai MAE sebesar 10,54, RMSE sebesar 14,32, dan MAPE sebesar 196,49%. Tingginya nilai MAPE ini mengindikasikan bahwa model memiliki tingkat akurasi yang rendah dalam memprediksi data Shift 1. Kondisi ini dipengaruhi secara signifikan oleh volatilitas data yang tinggi serta adanya lonjakan nilai yang ekstrem pada beberapa periode pengamatan. Visualisasi pola prediksi terhadap data aktual pada data pengujian disajikan pada Gambar 5.

Berdasarkan Gambar 5, hasil prediksi menunjukkan pola yang lebih landai dibandingkan data aktual sehingga model belum mampu mengikuti fluktuasi permintaan secara optimal. Perbedaan yang cukup besar antara nilai aktual dan nilai prediksi menunjukkan bahwa performa model pada Shift 1

masih kurang baik dan mengindikasikan adanya *underfitting*.



Gambar 5. Perbandingan Data Prediksi Shift 1 dan Aktual


4.3. Pemodelan Shift 2

Berbeda dengan shift sebelumnya, hasil uji stasioneritas menunjukkan bahwa data Shift 2 dinyatakan stasioner tanpa proses *differencing* ($p\text{-value} = 1,14 \times 10^{-23} < 0,05$). Model optimal yang diperoleh adalah ARIMA(0,0,1). Oleh karena itu, orde *differencing* yang digunakan adalah $d=0$. Pada tahap identifikasi, beberapa kandidat model dianalisis menggunakan indikator AIC untuk menentukan model yang paling sesuai ARIMA(p, 0, q) yang paling sesuai sebagaimana ditunjukkan pada Tabel 4.

Tabel 4. Perbandingan nilai AIC model Shift 2

Model ARIMA	Nilai AIC
ARIMA(1,0,0)	1215,02
ARIMA(0,0,1)	1215,01
ARIMA(1,0,1)	1216,07

Berdasarkan Tabel 4, model ARIMA(0,0,1) dipilih karena memiliki nilai AIC terendah yang menunjukkan bahwa model tersebut optimal. Model ini kemudian digunakan untuk melakukan proyeksi pada data pengujian. Hasil evaluasi menghasilkan tingkat kesalahan prediksi berupa MAE sebesar 12,62, RMSE sebesar 16,95, dan MAPE sebesar 396,04% yang dinilai kurang memuaskan.



Gambar 6. Perbandingan Data Aktual dan Prediksi Shift 2


Tingginya nilai kesalahan ini mengindikasikan bahwa model belum mampu menangkap pola data secara akurat. Hal ini disebabkan oleh volatilitas data yang sangat tinggi serta banyaknya lonjakan nilai yang tidak beraturan pada periode pengamatan, yang secara visual dapat dilihat pada Gambar 6.

Gambar 6 menunjukkan bahwa hasil prediksi cenderung membentuk pola yang lebih halus

dibandingkan data aktual. Model belum mampu mengikuti perubahan data yang bersifat ekstrem sehingga menghasilkan tingkat kesalahan prediksi yang tinggi. Kondisi ini mengindikasikan adanya *underfitting* pada model.

4.4. Pemodelan Shift 3

Berdasarkan hasil uji stasioneritas, data Shift 3 memperoleh nilai $p\text{-value}$ sebesar 0,5282 ($> 0,05$) yang membuat data awal dikategorikan belum stasioner. Oleh sebab itu, proses *differencing* orde pertama ($d = 1$) dilakukan untuk menstabilkan data. Setelah proses tersebut, nilai $p\text{-value}$ menurun menjadi $3,43 \times 10^{-7}$ sehingga data yang dihasilkan telah memenuhi asumsi stasioneritas dan selanjutnya dapat digunakan ke tahap pemodelan ARIMA. Pola data setelah proses *differencing* ditampilkan pada Gambar 7.



Gambar 7. Data Setelah Differencing Shift 3

Proses identifikasi model dilakukan dengan membandingkan beberapa kandidat model ARIMA(p,1,q) berdasarkan nilai AIC. Tabel 5 menunjukkan hasil perbandingan nilai AIC dari masing-masing kandidat model.


Tabel 5. Perbandingan nilai AIC model Shift 3

Model ARIMA	Nilai AIC
ARIMA(1,1,0)	1227,95
ARIMA(0,1,1)	1203,59
ARIMA(1,1,1)	1205,58

Berdasarkan Tabel 5, model ARIMA(0,1,1) ditetapkan sebagai model terbaik karena memiliki nilai paling rendah di antara model kandidat lainnya. Evaluasi performa model pada data pengujian menghasilkan nilai MAE 17,78, RMSE 23,33, dan MAPE 19,89%. Berbeda signifikan dengan Shift 1 dan Shift 2 yang memiliki tingkat kesalahan sangat tinggi, performa model pada Shift 3 tergolong baik karena nilai MAPE berada di bawah 20%. Hal ini mengindikasikan bahwa pola data pada Shift 3 memiliki stabilitas yang lebih tinggi dibandingkan *shift* operasional lainnya.

Berdasarkan Gambar 8, model ARIMA(0,1,1) menghasilkan performa yang lebih baik dibandingkan model pada Shift 1 dan Shift 2. Meskipun demikian, garis prediksi masih cenderung membentuk pola yang landai dan belum mampu mengikuti fluktuasi data aktual secara optimal. Kondisi tersebut mengindikasikan adanya *underfitting*, yaitu model


belum mampu mempelajari pola permintaan secara menyeluruh.



Gambar 8. Perbandingan Data Aktual dan Prediksi Shift 3


4.5. Pemodelan Total Harian

Analisis pada data total pemesanan harian memperoleh p-value sebesar 0,1426 ($p > 0,05$), yang menunjukkan bahwa data deret waktu masih bersifat non-stasioner. Oleh karena itu, diterapkan differencing tingkat pertama ($d = 1$) untuk memperoleh pola data yang lebih stabil. Karakteristik data setelah proses differencing disajikan pada Gambar 9, yang menunjukkan fluktuasi data yang telah stabil di sekitar nilai rata-rata.



Gambar 9. Data setelah differencing total harian

Sebelum melakukan perbandingan nilai *Akaike Information Criterion* (AIC), dilakukan identifikasi orde model secara visual menggunakan plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) sebagaimana ditunjukkan pada Gambar 9. Plot ACF menunjukkan pola *cut-off* setelah lag pertama, sementara plot PACF cenderung *tails off*, yang memberikan indikasi awal penggunaan orde *Moving Average* ($q=1$).



Gambar 10. Plot *Autocorrelation Function* (a) dan *Partial Autocorrelation Function* (b) pada data total harian.

Selanjutnya tahap identifikasi model optimal dilakukan perbandingan melalui nilai AIC dari


beberapa kandidat model $ARIMA(p,1,q)$. Hasil perbandingan tersebut dirangkum dalam Tabel 6.

Tabel 6. Perbandingan nilai AIC model Total Harian

Model ARIMA	Nilai AIC
ARIMA(1,1,0)	1402,40
ARIMA(0,1,1)	1374,96
ARIMA(1,1,1)	1376,90

Berdasarkan Tabel 6, model menunjukkan performa terbaik dengan skor AIC terendah sebesar 1374,96. Hasil evaluasi model pada data pengujian menunjukkan peningkatan performa yang sangat signifikan dibandingkan pemodelan berbasis *shift*. Model ARIMA(0,1,1) pada data total harian menghasilkan nilai MAE sebesar 30,93, RMSE sebesar 36,74, dan MAPE sebesar 19,12%."

Berdasarkan kriteria penilaian Lewis (1982), nilai MAPE di bawah 20% menunjukkan bahwa kemampuan peramalan model berada dalam kategori baik. Perbandingan visual antara data hasil serta data aktual prediksi pada Gambar 9 memperlihatkan bahwa garis prediksi mampu mengikuti tren dan pola data aktual sehingga model menunjukkan performa prediksi yang lebih optimal dibandingkan model sebelumnya.



Gambar 11. Perbandingan Data Aktual dan Prediksi Total Harian

Berdasarkan perbandingan data aktual dan hasil prediksi pada total harian, model ARIMA mampu menghasilkan performa yang lebih baik dibandingkan pemodelan per *shift*. Agregasi data harian membantu mengurangi fluktuasi ekstrem sehingga pola permintaan menjadi lebih mudah dipelajari oleh model. Meskipun demikian, garis prediksi masih menunjukkan kecenderungan yang lebih halus dibandingkan data aktual. Hal ini mengindikasikan bahwa model masih memiliki keterbatasan dalam mengikuti perubahan permintaan yang terjadi secara tiba-tiba. Dengan demikian, meskipun hasil prediksi total harian relatif lebih baik, indikasi *underfitting* masih terlihat pada hasil visualisasi model.

4.6. Pembahasan

Berdasarkan hasil eksperimen, terdapat perbedaan performa model ARIMA pada data per *shift* dan data total harian. Rekapitulasi hasil evaluasi seluruh model disajikan pada Tabel 7.

Tabel 7. Rekapitulasi Perbandingan Performa Model ARIMA

Data	Model Terpilih	MAE	RMSE	MAPE(%)	Kategori Akurasi
Shift 1	ARIMA(1,1,1)	10,54	14,32	196,49	Tidak dapat diterima
Shift 2	ARIMA(0,0,1)	12,62	16,95	396,04	Tidak dapat diterima
Shift 3	ARIMA(0,1,1)	17,78	23,33	19,89	Baik
Total Harian	ARIMA(0,1,1)	30,93	36,74	19,12	Baik (Terbaik)

Berdasarkan Tabel 7, model ARIMA pada data Shift 1 dan Shift 2 menghasilkan tingkat kesalahan yang tinggi dengan nilai MAPE masing-masing sebesar 196,49% dan 396,04%. Sementara itu, model pada Shift 3 dan Total Harian menghasilkan nilai MAPE sebesar 19,89% dan 19,12% yang termasuk kategori baik. Hasil tersebut menunjukkan bahwa agregasi data ke tingkat harian mampu mengurangi fluktuasi ekstrem sehingga model dapat menghasilkan akurasi yang lebih baik. Temuan ini sejalan dengan penelitian Rizqullah [9] yang menyatakan bahwa karakteristik dan granularitas data berpengaruh terhadap performa model ARIMA.

Pada data per shift, fluktuasi yang tinggi menyebabkan model kesulitan dalam menangkap pola permintaan secara konsisten. Kondisi ini juga ditemukan oleh Fadillah dan Hendrastuty [3] yang menyatakan bahwa data dengan tingkat volatilitas tinggi cenderung menghasilkan kesalahan prediksi yang lebih besar pada model deret waktu.

Meskipun Shift 3 dan Total Harian menghasilkan nilai MAPE yang tergolong baik, hasil visualisasi menunjukkan bahwa garis prediksi pada seluruh model cenderung membentuk pola yang lebih landai (*smooth*) dibandingkan data aktual. Model belum mampu mengikuti lonjakan maupun penurunan permintaan yang terjadi secara tiba-tiba. Kondisi ini mengindikasikan adanya *underfitting*, yaitu model belum mampu mempelajari pola data permintaan secara optimal.

Fenomena *underfitting* tersebut diduga dipengaruhi oleh jumlah data historis yang relatif terbatas serta tingginya volatilitas data pemesanan. Selain itu, data Shift 2 yang telah memenuhi asumsi stasioneritas justru menghasilkan nilai MAPE tertinggi sebesar 396,04%. Kondisi ini menunjukkan bahwa stasioneritas bukan satu-satunya faktor yang menentukan keberhasilan model ARIMA. Temuan tersebut sejalan dengan penelitian Asrirawan dkk. [7] yang menyatakan bahwa model univariat memiliki keterbatasan ketika dihadapkan pada data dengan pola yang kompleks dan berfluktuasi tinggi.

Secara praktis, model ARIMA(0,1,1) pada data Total Harian tetap dapat digunakan sebagai acuan dalam pengambilan keputusan pemesanan karena menghasilkan performa terbaik dibandingkan model lainnya dengan nilai MAPE sebesar 19,12%. Namun demikian, hasil prediksi perlu digunakan sebagai estimasi dasar karena model masih memiliki keterbatasan dalam merespons perubahan permintaan yang ekstrem.

Keterbatasan model dalam mempelajari pola data yang kompleks juga telah ditemukan pada penelitian

Prasetyo dkk. [8]. Hasil penelitian ini menunjukkan bahwa meskipun beberapa model menghasilkan nilai MAPE yang baik, pola prediksi yang terbentuk masih cenderung *smooth* dan belum mampu mengikuti fluktuasi data aktual secara optimal. Oleh karena itu, penelitian selanjutnya disarankan menggunakan data historis yang lebih panjang serta menerapkan teknik K-Fold Cross Validation untuk meningkatkan kemampuan model dalam mempelajari pola data dan mengurangi gejala *underfitting*.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian, metode ARIMA menghasilkan performa yang berbeda pada masing-masing kelompok data. Pemodelan pada Shift 1 dan Shift 2 menghasilkan nilai MAPE sebesar 196,49% dan 396,04%, sedangkan Shift 3 dan Total Harian menghasilkan nilai MAPE sebesar 19,89% dan 19,12%. Hasil tersebut menunjukkan bahwa penggunaan data Total Harian memberikan performa terbaik dibandingkan pemodelan per shift karena mampu mengurangi fluktuasi ekstrem pada data. Meskipun demikian, hasil visualisasi menunjukkan bahwa garis prediksi pada seluruh model cenderung membentuk pola yang lebih landai (*smooth*) dibandingkan data aktual, sehingga mengindikasikan adanya kondisi *underfitting* yang menyebabkan model belum mampu mempelajari pola permintaan secara optimal. Keterbatasan tersebut diduga dipengaruhi oleh jumlah data historis yang relatif sedikit serta tingginya volatilitas data pemesanan. Oleh karena itu, penelitian selanjutnya disarankan menggunakan data historis yang lebih panjang serta menerapkan teknik K-Fold Cross Validation untuk meningkatkan kemampuan model dalam mempelajari pola data dan mengurangi gejala *underfitting* yang ditemukan pada penelitian ini.

DAFTAR PUSTAKA

- [1] N. Y. Setiawan and D. E. Ratnawati, "Prediksi penjualan makanan restoran menggunakan metode ARIMA: studi kasus Waroeng Marisukakoi," J. Pengemb. Teknol. Inf. dan Ilmu Komput., vol. 9, no. 5, pp. 1–10, 2025.
- [2] S. P. Fauzani and D. Rahmi, "Penerapan Metode ARIMA Dalam Peramalan Harga Produksi Karet di Provinsi Riau," Jurnal Teknologi dan Manajemen Industri Terapan (JTMIT), vol. 2, no. 4, pp. 269–277, 2023.
- [3] B. D. Fadillah and N. Hendrastuty, "Prediksi Stok Barang di Toko Eko Helm Menggunakan Metode Time series Analysis," Jurnal Informatika: Jurnal Pengembangan IT, vol. 10,

- no. 2, pp. 278–291, Apr. 2025, doi: 10.30591/jpit.v10i2.8584.
- [4] K. Umam, “MIND (Multimedia Artificial Intelligent Networking Database Perbandingan Metode ARIMA dan LSTM pada Prediksi Jumlah Pengunjung Perpustakaan,” *Journal MIND Journal | ISSN*, vol. 8, no. 2, pp. 119–129, 2023, doi: 10.26760/mindjournal.v8i2.119-129.
- [5] C. Jesselyn and S. Dewi, “Implementasi Metode Peramalan (Forecasting) Pada Penjualan Kuas di PT ABC,” *Jurnal Teknik Mesin, Industri, Elektro dan Informatika*, vol. 3, no. 1, pp. 83–100, Mar. 2024, doi: 10.55606/jtmei.v3i1.3222.
- [6] M. Heru Widiyanto and R. Mayasari, “Implementasi Time Series Pada Data Penjualan di GAIKINDO Menggunakan Algoritma Seasonal ARIMA,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 3, pp. 1501–1506, Oct. 2023, doi: 10.36040/jati.v7i3.6879.
- [7] A. Asrirawan, S. U. Permata, and M. I. Fauzan, “Pendekatan Univariate Time Series Modelling untuk Prediksi Kuartalan Pertumbuhan Ekonomi Indonesia Pasca Vaksinasi COVID-19,” *Jambura Journal of Mathematics*, vol. 4, no. 1, pp. 86–103, Jan. 2022, doi: 10.34312/jjom.v4i1.11717.
- [8] H. R. Prasetyo, I. Palupi, and B. A. Wahyudi, “Prediksi Menggunakan Model Fuzzy Time Series Studi Kasus Curah Hujan di Kabupaten Bandung,” *LOGIC: Jurnal Penelitian Informatika*, vol. 1, no. 1, p. 8, Sep. 2023, doi: 10.25124/logic.v1i1.6405.
- [9] M. A. Rizqullah, “ANALISIS FORECASTING PERMINTAAN PRODUK MENGGUNAKAN METODE ARIMA (AUTOREGRESSIVE INTEGRATED MOVING AVERAGE) PADA PT MANDIRI JOGJA INTERNASIONAL,” *Jurnal Multidisiplin Ilmu Akademik*, vol. 2, no. 6, pp. 806–817, 2025, doi: 10.61722/jmia.v2i6.7312.
- [10] A. Amirudin, S. A. Prasetyo, and G. Triyono, “Implementasi Hybrid ARIMA-Prophet untuk Prediksi Harga Beras Nasional,” *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 10, no. 4, pp. 3837–3850, 2025.
- [11] T. A. D. Kurniawan, A. Setiawan, and F. Tita, “Perbandingan Kinerja Metode Support Vector Regression dan Metode Regresi Linier Berganda dalam Memprediksi BMI pada Dataset ASTHMA,” *Jurnal Sains dan Edukasi Sains*, vol. 8, no. 2, pp. 133–142, Aug. 2025, doi: 10.24246/juses.v8i2p133-142