

# Implementasi Prediksi Autoregressive Integrated Moving Average untuk Sistem Peringatan Dini Pemantauan Sedimen Berbasis IoT

Ryan Yudha Adhitya<sup>1</sup>, Diego Pratama Umarrela<sup>2</sup>, Lilik Subiyanto<sup>3</sup>,  
dan Zindhu Maulana Ahmad Putra<sup>4</sup>

<sup>1,2,3</sup> Program Studi Teknik Otomasi, Jurusan Teknik Kelistrikan Kapal, Politeknik Perkapalan Negeri Surabaya  
Kampus ITS Sukolilo Jl. Teknik Kimia, Keputih Sukolilo, Surabaya, Indonesia

<sup>4</sup> Program Studi Teknik Kelistrikan Kapal, Jurusan Teknik Kelistrikan Kapal, Politeknik Perkapalan Negeri Surabaya  
Kampus ITS Sukolilo Jl. Teknik Kimia, Keputih Sukolilo, Surabaya, Indonesia

[ryanyudhaadhitya@ppns.ac.id](mailto:ryanyudhaadhitya@ppns.ac.id)<sup>1</sup>, [diegoprutama08@student.ppns.ac.id](mailto:diegoprutama08@student.ppns.ac.id)<sup>2</sup>, [llksubiyanto@ppns.ac.id](mailto:llksubiyanto@ppns.ac.id)<sup>3</sup>, [zindhu@ppns.ac.id](mailto:zindhu@ppns.ac.id)<sup>4</sup>

## Abstrak

Sedimentasi yang terjadi secara terus-menerus di wilayah perairan seperti muara dan pelabuhan dapat mengganggu aktivitas pelayaran serta mempercepat pendangkalan. Penumpukan sedimen ini berisiko menghambat pergerakan kapal dan meningkatkan kemungkinan kecelakaan. Oleh karena itu, diperlukan sistem yang mampu memantau kondisi sedimen secara real-time serta memberikan peringatan dini apabila terjadi perubahan signifikan. Penelitian ini bertujuan untuk merancang dan mengimplementasikan sistem pemantauan kondisi sedimen berbasis Internet of Things (IoT) yang dilengkapi fitur prediksi menggunakan metode Autoregressive Integrated Moving Average (ARIMA). Sistem ini menggunakan sensor echosounder untuk mengukur kedalaman, sensor arus laut, serta sensor pengukur tinggi muka air laut. Data dari sensor dikirim secara otomatis ke platform berbasis website dan ditampilkan dalam bentuk grafik interaktif. Model ARIMA dibangun berdasarkan data deret waktu kedalaman laut yang diperoleh dari sensor. Evaluasi dilakukan dengan membandingkan hasil prediksi dengan data aktual pada periode pengujian. Hasil menunjukkan bahwa model ARIMA mampu menangkap pola umum data historis dan memberikan prediksi yang cukup akurat dalam kondisi yang stabil. Nilai Mean Absolute Error (MAE) sebesar 17,81 meter dan Mean Absolute Percentage Error (MAPE) sebesar 0,88% menunjukkan tingkat kesalahan yang rendah. Kesimpulannya, sistem ini efektif untuk memantau dan memprediksi kondisi sedimen, serta dapat digunakan sebagai dasar pengambilan keputusan dalam menentukan waktu pengerukan yang optimal. Solusi ini diharapkan dapat meningkatkan efisiensi operasional dan menjaga kelancaran aktivitas pelabuhan.

**Kata kunci:** Sedimentasi, Internet of Things, ARIMA, Peringatan dini, Echosounder, Pemantauan perairan

## Abstract

*Continuous sedimentation in water areas such as estuaries and ports can disrupt shipping activities and accelerate siltation. The accumulation of sediment poses a risk of obstructing ship movement and increasing the likelihood of accidents. Therefore, a system capable of monitoring sediment conditions in real-time and providing early warnings in case of significant changes is needed. This research aims to design and implement a sediment condition monitoring system based on the Internet of Things (IoT) equipped with prediction features using the Autoregressive Integrated Moving Average (ARIMA) method. This system uses an echosounder sensor to measure depth, an ocean current sensor, and a sea surface height sensor. Data from the sensors are automatically sent to a web-based platform and displayed in the form of interactive graphs. The ARIMA model is built based on time series data of ocean depth obtained from the sensor. Evaluation was conducted by comparing the prediction results with actual data during the testing period. The results show that the ARIMA model is capable of capturing the general patterns of historical data and providing fairly accurate predictions under stable conditions. The Mean Absolute Error (MAE) value of 17.81 meters and the Mean Absolute Percentage Error (MAPE) value of 0.88% indicate a low level of error. In conclusion, this system is effective for monitoring and predicting sediment conditions, and can be used as a basis for decision-making in determining the optimal dredging time. This solution is expected to improve operational efficiency and maintain the smoothness of port activities.*

**Keywords:** Sedimentation, Internet of Things, ARIMA, Early Warning, Echosounder, Water Monitoring

---

<sup>1</sup>\* Penulis korespondensi

## 1. Pendahuluan

Indonesia merupakan negara maritim dengan 2/3 wilayahnya berupa perairan. Wilayah-wilayah perairan ini, seperti muara sungai, kawasan pesisir, dan perlintasan kapal, memiliki peran penting dalam mendukung aktivitas transportasi, perikanan, dan ekonomi maritim nasional. Namun, banyak dari kawasan ini menghadapi permasalahan sedimentasi yang menyebabkan pendangkalan. Akumulasi sedimen di dasar perairan dapat mengganggu jalur pelayaran, merusak ekosistem, serta meningkatkan kebutuhan pengerukan yang memerlukan biaya besar (Salam et al., 2022).

Sedimentasi terjadi akibat pengaruh berbagai faktor alam, seperti arus laut, gelombang, serta pasang surut. Bila tidak dipantau dan dikelola dengan baik, proses ini dapat mengganggu fungsi perairan secara keseluruhan dan menurunkan efisiensi operasional wilayah pesisir (Javier et al., 2024). Di wilayah sungai, pendangkalan akibat sedimentasi juga dapat menurunkan kapasitas aliran air, menyebabkan banjir, dan mengganggu kegiatan transportasi air lokal. Oleh karena itu, diperlukan adanya ambang batas aman sedimentasi yang menjadi acuan dalam pengambilan keputusan. Misalnya, pada sungai dengan kedalaman operasional 2 meter, akumulasi sedimen lebih dari 0,5–1 meter sudah dapat dikategorikan sebagai kondisi yang mengganggu dan perlu penanganan. Penetapan batas aman ini sangat penting dalam mendukung sistem peringatan dini yang responsif dan akurat.

Sayangnya, metode pemantauan sedimentasi yang masih banyak digunakan saat ini bersifat manual dan tidak mampu memberikan data secara real-time, sehingga kurang efektif dalam mendukung pengambilan keputusan yang cepat dan tepat. Oleh karena itu, pemanfaatan teknologi Internet of Things (IoT) memberikan solusi alternatif dalam pemantauan kondisi sedimen (Syekha Sasmita et al., 2021). Dengan mengintegrasikan berbagai sensor dan sistem komunikasi berbasis website, data pengukuran dapat dikumpulkan secara otomatis, terus menerus, dan dikirim untuk dianalisis secara daring.

Untuk memperkuat sistem prediksi dalam pemantauan ini, digunakan metode Autoregressive Integrated Moving Average (ARIMA), yang terbukti efektif dalam menganalisis data deret waktu dan memproyeksikan tren perubahan kedalaman sedimen. Dengan memadukan teknologi IoT dan analisis ARIMA, sistem tidak hanya dapat memantau kondisi sedimen secara real-time, tetapi juga memprediksi potensi penumpukan sedimen sebelum mencapai tingkat kritis.

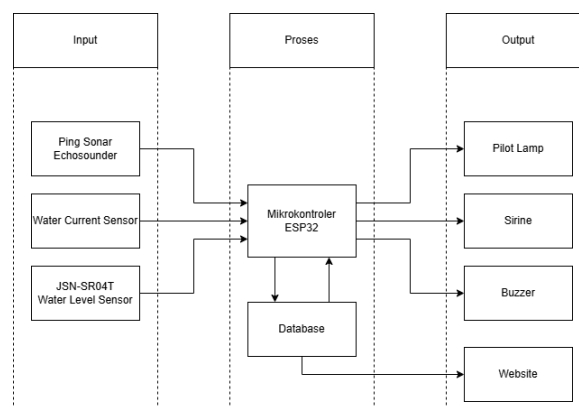
Penelitian ini bertujuan untuk merancang dan mengimplementasikan sistem peringatan dini berbasis IoT yang dilengkapi dengan model prediktif ARIMA guna memantau kondisi sedimentasi di wilayah perairan secara real-time. Dengan adanya sistem ini, diharapkan pengelolaan sedimen di perairan dapat dilakukan secara lebih efisien dan berkelanjutan, serta mampu mendukung keselamatan dan aktivitas masyarakat yang bergantung pada wilayah tersebut.

## 2. Metode Penelitian

Pada bagian ini menjelaskan mengenai konsep penelitian yang akan menjadi dasar penelitian. Konsep penelitian digunakan sebagai acuan atau landasan bagi desain dan pengembangan sistem yang akan dilakukan oleh peneliti.

### 2.1. Perancangan Sistem

Pada sub bab perancangan sistem meliputi diagram blok dan flowchart sistem.



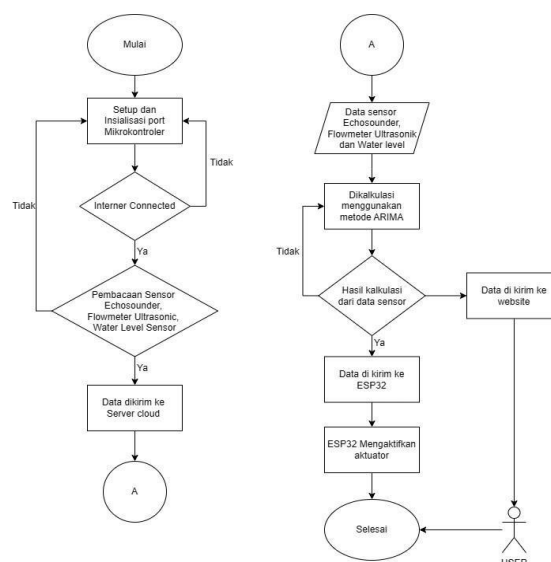
Gambar 2. 1 Diagram Blok Sistem

Pada dasarnya diagram blok sistem dibagi menjadi 3, yaitu *input*, *proses*, *output*. Penjelasan untuk masing masing bagian seperti berikut. Sistem ini dirancang untuk memantau kondisi perairan secara real-time dengan memanfaatkan beberapa sensor sebagai input utama. Sensor Ping Sonar Echosounder digunakan untuk membaca kedalaman perairan, yang menjadi indikator utama dalam mendeteksi penumpukan sedimen di dasar laut atau sungai. Sensor Water Current ( arus laut) berfungsi untuk mengukur kecepatan dan arah arus perairan, yang penting dalam analisis penyebaran sedimen.

Sedangkan sensor JSN-SR04T, yaitu sensor ultrasonik tahan air, digunakan untuk mengukur ketinggian muka air, memberikan gambaran dinamika permukaan air yang juga berpengaruh terhadap proses sedimentasi.

Data dari ketiga sensor tersebut kemudian masuk ke tahap proses, yang dikendalikan oleh mikrokontroler ESP32. ESP32 berfungsi sebagai otak sistem yang mengolah data dari echosounder, sensor arus, dan sensor ketinggian air. Mikrokontroler ini juga dilengkapi dengan modul WiFi sehingga dapat mengirimkan data secara langsung ke database server menggunakan protokol HTTP (Nova et al., 2024). Database ini berfungsi sebagai tempat penyimpanan seluruh data sensor, yang kemudian bisa digunakan untuk analisis lebih lanjut, termasuk visualisasi data di website monitoring dan penerapan algoritma prediksi seperti ARIMA.

Hasil dari pemrosesan data ini akan menghasilkan output dalam bentuk sistem peringatan dini. Buzzer digunakan sebagai indikator suara dengan intensitas rendah untuk memberikan notifikasi peringatan awal kepada petugas jika terjadi peningkatan sedimentasi yang belum mencapai batas kritis. Apabila kondisi semakin parah dan melebihi ambang batas yang telah ditentukan, maka sistem akan mengaktifkan sirine sebagai indikator suara utama yang keras dan mencolok. Sirine ini berfungsi untuk memberikan peringatan darurat agar petugas segera mengambil tindakan, seperti pengerukan sedimen. Selain itu, terdapat lampu indikator atau pilot lamp yang memberikan isyarat visual dengan tiga warna: hijau menunjukkan kondisi normal, kuning menandakan peningkatan sedimentasi yang harus dipantau, dan merah sebagai sinyal bahwa sedimentasi sudah dalam kondisi kritis dan membutuhkan penanganan segera.



Gambar 2. 2 Flowchart Sistem

Pada Gambar 2.2 merupakan flowchart sistem yang berisi alur pengujian dari penelitian ini. Pada Kondisi awal adalah setup dan insialisasi port mikrokontroler untuk memastikan mikrokontroler bekerja dengan baik dan terkoneksi internet dengan benar. Setelah itu sensor melakukan pembacaan sesuai dengan fungsinya, data pembacaan akan dikirim ke ESP32, apabila data sensor sudah terbaca maka ESP32 sebagai controller akan menerima data tersebut kemudian mengirim ke database melalu protocol HTTP. Selanjutnya data yang sudah berada pada database akan dikalkulasi dan dianalisis menggunakan metode ARIMA untuk memprediksi tinggi sedimentasi serta data dari sensor di ditampilkan pada website. Jika hasil dari analisis data sensor tadi sudah sesuai maka data akan dikirim kembali ke ESP32 dan ditampilkan pada website untuk dimonitoring oleh user. Sebaliknya, jika data analisis sensor belum sesuai maka data akan diolah kembali. Data yang dikirim kembali ke ESP32 akan digunakan untuk memberi perintah ke aktuator (Sirine, Buzzer dan Pilot Lamp). Aktuator akan aktif dan memberikan sinyal sesuai dengan hasil data yang sudah dianalisis. Jika hasil analisis data menunjukkan tinggi sedimen sudah berada pada ambang batas aman yaitu pada jalur sungai yang memiliki kedalaman operasional 2 meter, ambang batas sedimentasi bisa ditetapkan sebesar 1,5 meter maka sirine akan berbunyi untuk memberi tahu bahwa perlu dilakukan pengerukan pada daerah yang memiliki ketinggian sedimen.

## 2.2 Penerapan Metode Autoregressive Integrated Moving Avergae (ARIMA)

Model Autoregressive Integrate Moving (ARIMA) adalah salah satu metode yang digunakan untuk peramalan data yang bersifat time series. Model ARIMA adalah model yang secara penuh mengabaikan independen variabel dalam membuat prediksi (Catur Putri et al., 2022). ARIMA menggunakan nilai masa lalu dan sekarang dari variabel dependen untuk menghasilkan prediksi jangka pendek yang akurat. ARIMA sangat baik ketepatannya untuk prediksi jangka pendek,

sedangkan untuk prediksi jangka panjang prediksinya kurang baik. Biasanya akan cenderung flat (mendatar/konstan) untuk periode yang cukup Panjang. Tahapan dari pemodelan dan peramalan ARIMA (p, d, q) yaitu sebagai berikut. Langkah pertama dalam analisis data deret waktu (time series) adalah melakukan plot data time series. Visualisasi ini penting untuk memahami pola umum data seperti tren jangka panjang, fluktuasi musiman, dan kemungkinan adanya outlier atau perubahan struktur. Plot ini memberikan gambaran awal mengenai karakteristik data yang akan dianalisis.

Setelah data divisualisasikan, langkah selanjutnya adalah melakukan uji stasioneritas terhadap ragam dan rata-rata. Stasioneritas adalah syarat utama dalam penerapan model ARIMA. Uji ini bertujuan untuk memastikan bahwa nilai rata-rata dan varians data tidak berubah terhadap waktu. Pengujian dilakukan dengan menggunakan metode seperti Augmented Dickey-Fuller (ADF) test untuk rata-rata, dan transformasi data (seperti differencing atau log) untuk menstabilkan ragam.

Langkah ketiga adalah mengidentifikasi orde ARIMA dengan menggunakan plot ACF (Autocorrelation Function) dan PACF (Partial Autocorrelation Function). ACF digunakan untuk melihat korelasi antar lag data, sedangkan PACF untuk mengidentifikasi kontribusi langsung antar lag terhadap nilai sekarang. Pola yang terbentuk dari plot ini membantu menentukan nilai parameter p (autoregressive) dan q (moving average) yang sesuai.

Selanjutnya adalah melakukan pendugaan dan pengujian signifikansi parameter. Dalam tahap ini, model ARIMA dengan parameter (p, d, q) yang telah ditentukan akan diestimasi, dan setiap parameter dalam model diuji signifikansinya terhadap data. Tujuan dari tahap ini adalah memastikan bahwa parameter yang digunakan memang berpengaruh terhadap model dan layak dipertahankan.

Setelah model terbentuk, dilakukan pengujian diagnostik residual model ARIMA (p, d, q). Residual merupakan selisih antara nilai observasi dengan nilai prediksi model. Uji diagnostik dilakukan untuk memastikan bahwa residual bersifat acak (white noise), tidak memiliki autokorelasi, dan terdistribusi normal. Jika residual tidak memenuhi asumsi ini, maka model harus diperbaiki atau dimodifikasi.

Pemilihan model terbaik kemudian dilakukan dengan menggunakan kriteria Akaike Information Criterion (AIC). AIC adalah ukuran statistik yang memperhitungkan tingkat kesesuaian model terhadap data dan jumlah parameter yang digunakan. Model dengan nilai AIC terendah dianggap sebagai model terbaik karena memberikan keseimbangan antara kompleksitas dan ketepatan.

Langkah terakhir adalah melakukan peramalan (forecasting) menggunakan model terbaik yang telah dipilih. Model ARIMA terbaik digunakan untuk meramalkan nilai masa depan dari data time series. Hasil peramalan ini dapat digunakan sebagai dasar pengambilan keputusan atau antisipasi terhadap kondisi yang mungkin terjadi di waktu mendatang.

Bentuk umum persamaan model ARIMA dapat dituliskan sebagai berikut:

$$Y_t = (1 - B) d X_t \quad (1)$$

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2)$$

$$\text{Atau } \phi(B)(1 - B) d Y_t = \theta(B) a_t \quad (3)$$

Dimana :

$$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p \quad (4)$$

$$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q \quad (5)$$

Keterangan :

$\phi$  : Parameter Autoregressive

$\theta$  : Parameter Moving Average

$a_t$  : nilai error ke-t

$Y_t$  : series yang stasioner

$(1 - B) d$  : Operator pembeda dengan orde d

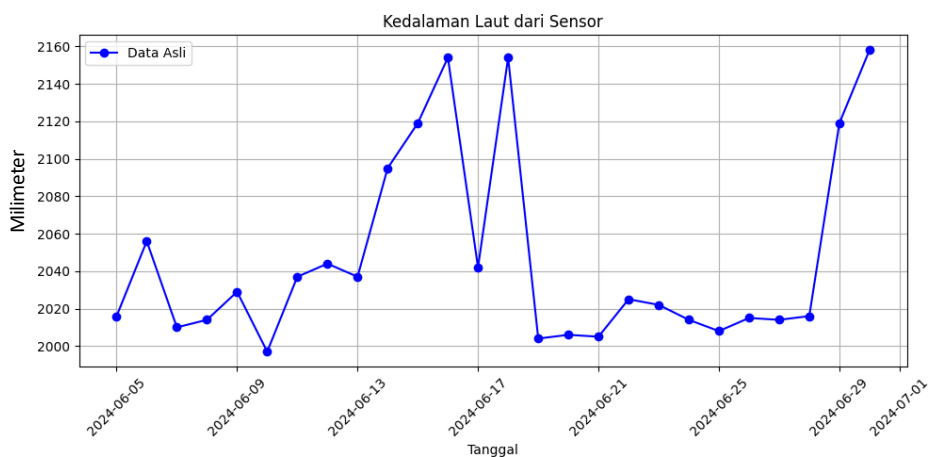
ARIMA dapat digunakan untuk memprediksi perubahan ketinggian sedimen, kecepatan arus air, dan variasi tinggi muka air, sehingga membantu dalam menentukan waktu optimal untuk pengerukan (dredging) dan mengidentifikasi

anomali yang berpotensi mengganggu navigasi di pelabuhan. Dengan kemampuannya dalam menangani data time series yang stasioner maupun tidak stasioner, ARIMA menjadi model yang tepat untuk mendukung sistem pemantauan berbasis cloud dalam proyek ini, memungkinkan analisis berbasis data untuk pengambilan keputusan yang lebih efisien dan akurat (Rawat et al., 2022).

### 3. Hasil dan Diskusi

Pada bagian ini menjelaskan hasil dari penelitian yang berupa hasil dari prediksi model ARIMA untuk memprediksi pendangkalan akibat sedimen untuk sistem peringatan dini. ARIMA ( $p=1, d=1, q=1$ ) diterapkan untuk memprediksi tren kedalaman air di daerah aliran sungai berdasarkan data selama periode pengujian, dengan hasil yang divisualisasikan dalam grafik prediksi kedalaman air.

#### 3.1. Plot Data Time Series



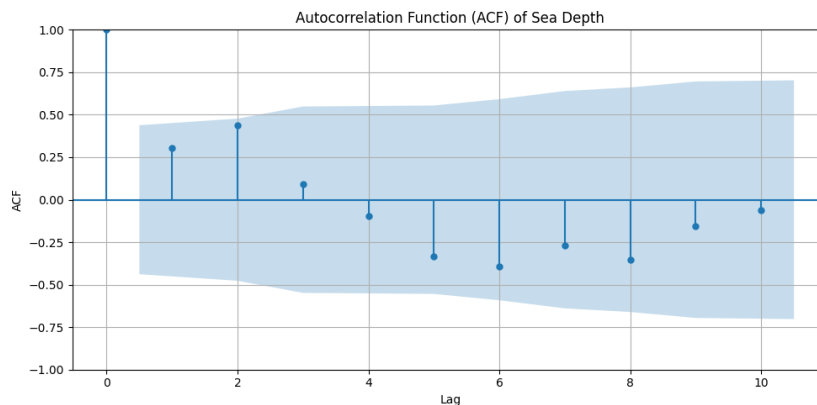
Gambar 3.1 Data Aktual Dari Sensor

Gambar 3.1 memperlihatkan grafik perubahan kedalaman laut yang diperoleh dari simulasi sensor selama periode observasi mulai tanggal 5 Juni hingga 30 Juni 2024. Data kedalaman laut diukur dalam satuan milimeter dan disajikan dalam bentuk deret waktu untuk mengamati dinamika vertikal permukaan dasar laut secara berkala. Berdasarkan grafik tersebut, terlihat bahwa nilai kedalaman laut mengalami fluktuasi yang cukup signifikan. Nilai kedalaman tertinggi terjadi pada tanggal 16 dan 30 Juni 2024, dengan nilai melebihi 2150 milimeter. Sebaliknya, nilai terendah tercatat pada kisaran tanggal 10 Juni, mendekati angka 1995 meter. Pola ini menunjukkan adanya variasi kedalaman yang tidak bersifat statis, melainkan dinamis dan berubah-ubah dalam jangka waktu pendek. Menariknya, terdapat penurunan yang sangat tajam setelah puncak pertama (16 Juni), yang kemudian diikuti oleh fase stabil pada periode 20 hingga 27 Juni.

Pada fase ini, kedalaman laut cenderung konstan di sekitar 2000–2025 meter, mengindikasikan kemungkinan tidak adanya gangguan besar dari faktor eksternal seperti arus kuat atau aktivitas sedimentasi. Namun, pada akhir bulan, terjadi lonjakan yang kembali signifikan hingga mencapai kedalaman maksimum lebih dari 2160 meter. Fluktuasi tersebut dapat diinterpretasikan sebagai hasil dari dinamika oseanografi seperti pasang surut, pergerakan massa air, hingga perubahan kontur dasar laut akibat sedimentasi ataupun pengerukan. Selain itu, anomali ekstrem seperti lonjakan mendadak juga dapat menjadi indikator penting terhadap kejadian alam atau perubahan lingkungan setempat. Oleh karena itu, pola ini mendukung pentingnya pemantauan kedalaman laut secara kontinu dan real time, terutama dalam konteks perencanaan pengerukan, navigasi kapal, dan mitigasi risiko lingkungan. Data ini juga sangat relevan untuk digunakan dalam pemodelan prediktif menggunakan metode deret waktu seperti ARIMA.

#### 3.2. Pengujian Plot ACF dan PACF

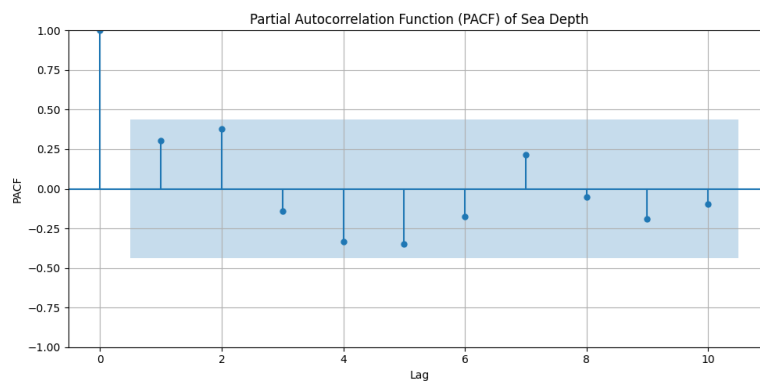
Gambar 3.2 menunjukkan hasil analisis fungsi autokorelasi (Autocorrelation Function/ACF) terhadap data kedalaman laut yang dikumpulkan dalam periode observasi tertentu. Fungsi ACF digunakan untuk mengukur korelasi antara observasi data dengan nilai-nilai sebelumnya (lag) dalam deret waktu. Dalam konteks ini, ACF memberikan gambaran seberapa besar pengaruh nilai kedalaman laut di masa lalu terhadap nilai saat ini. Pada lag ke-0, nilai ACF bernilai 1, yang merupakan karakteristik umum karena data selalu berkorelasi sempurna dengan dirinya sendiri. Nilai ACF kemudian menurun seiring bertambahnya lag.



**Gambar 3. 2** Grafik Plot ACF

Pada lag ke-1 hingga lag ke-3, nilai ACF masih positif, dengan lag ke-2 menunjukkan nilai autokorelasi yang cukup tinggi dan berada di luar batas interval kepercayaan 95%. Hal ini menunjukkan bahwa terdapat autokorelasi positif yang signifikan secara statistik, yang berarti kedalaman laut saat ini masih dipengaruhi oleh nilai pada 1–3 periode sebelumnya. Mulai dari lag ke-4 hingga lag ke-10, nilai ACF menunjukkan pola negatif, di mana beberapa lag (khususnya lag ke-5 hingga ke-9) berada di luar batas bawah interval kepercayaan. Ini menunjukkan adanya autokorelasi negatif yang signifikan, yang mengindikasikan kemungkinan adanya siklus atau pola berulang dalam data, di mana peningkatan nilai pada suatu waktu cenderung diikuti oleh penurunan pada waktu tertentu setelahnya.

Pola ini mendukung hipotesis bahwa kedalaman laut mengalami perubahan yang tidak acak, melainkan mengikuti dinamika tertentu yang dapat dimodelkan secara statistik. Oleh karena itu, hasil analisis ACF ini menjadi dasar penting dalam pemilihan model deret waktu seperti ARIMA, yang membutuhkan informasi tentang keberadaan dan jenis autokorelasi dalam data.



**Gambar 3. 3** Grafik Plot PACF

Gambar 3.3 menunjukkan hasil analisis Partial Autocorrelation Function (PACF) terhadap data deret waktu kedalaman laut. PACF digunakan untuk mengukur tingkat hubungan antara observasi dengan lag-nya setelah menghilangkan pengaruh dari lag-lag sebelumnya. Berbeda dengan ACF yang mengukur korelasi total, PACF hanya mempertimbangkan korelasi parsial, yang berguna untuk menentukan ordo dari komponen autoregressive (AR) pada model deret waktu seperti ARIMA.

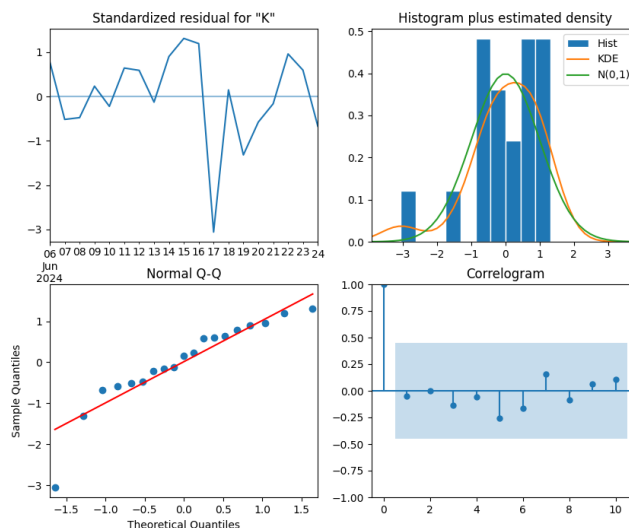
Pada lag ke-0, nilai PACF adalah 1, yang mencerminkan korelasi sempurna data dengan dirinya sendiri. Selanjutnya, PACF menunjukkan nilai yang signifikan positif pada lag ke-1 dan lag ke-2, karena kedua batang tersebut berada di luar batas interval kepercayaan 95%. Hal ini mengindikasikan adanya pengaruh langsung yang kuat dari dua periode sebelumnya terhadap nilai kedalaman laut saat ini. Pada lag ke-3 hingga lag ke-10, sebagian besar nilai PACF berada dalam batas interval kepercayaan, yang menunjukkan bahwa pengaruh langsung dari lag-lag tersebut terhadap nilai saat

ini tidak signifikan secara statistik. Meskipun beberapa lag (seperti lag ke-4 dan ke-6) menunjukkan nilai negatif, pengaruhnya relatif kecil dan dapat dianggap tidak signifikan dalam pembentukan model AR.

Hasil PACF ini memperkuat indikasi bahwa data kedalaman laut memiliki komponen autoregressive yang signifikan pada lag 1 dan 2. Oleh karena itu, untuk membentuk model ARIMA yang optimal, komponen AR dapat dimulai dengan ordo  $p = 2$ . Hal ini juga sejalan dengan hasil analisis ACF sebelumnya yang menunjukkan adanya autokorelasi positif pada lag-lag awal dan negatif di lag-lag menengah. Dengan demikian, analisis PACF memberikan dasar yang kuat dalam menentukan struktur model prediksi deret waktu, serta menunjukkan bahwa kedalaman laut memiliki ketergantungan jangka pendek yang signifikan terhadap nilai masa lalunya.


### 3.3. Pengujian Diagnostik Residual Model ARIMA (p, d, q)

Pengujian diagnostik residual model ARIMA (p, d, q) dilakukan untuk memastikan bahwa residual (selisih antara nilai aktual dan hasil prediksi model) bersifat acak atau white noise. Hal ini menunjukkan bahwa model telah menangkap seluruh pola dalam data. Pengujian biasanya mencakup uji Ljung-Box untuk melihat ada tidaknya autokorelasi, serta pemeriksaan visual melalui plot residual dan histogram untuk memastikan distribusi normal dan varians yang stabil. Jika residual tidak acak, maka model perlu diperbaiki.



Gambar 3. 4 Grafik Diagnostik Model ARIMA

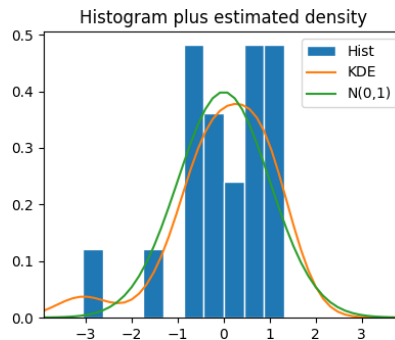
Gambar 3.4 di atas merupakan hasil analisis diagnostik dari model ARIMA yang telah diterapkan pada data deret waktu kedalaman laut. Evaluasi diagnostik dilakukan untuk menilai sejauh mana asumsi-asumsi klasik dari model terpenuhi, khususnya terkait dengan sifat residual yang dihasilkan. Terdapat empat subplot utama, masing-masing menjelaskan karakteristik residual dari model:



Gambar 3. 5 Grafik Residual Plot

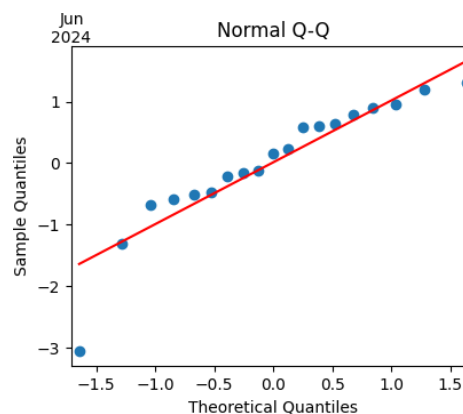
Pada Gambar 3.5 *Standardized Residual Plot* Plot memperlihatkan residual model yang telah dinormalisasi terhadap waktu. Secara umum, residual berfluktuasi secara acak di sekitar nol tanpa pola yang sistematis, yang menunjukkan bahwa model tidak menyisakan informasi terstruktur (tidak ada autokorelasi yang tersisa). Namun,

terdapat satu titik outlier pada tanggal 17 Juni 2024 dengan nilai residual ekstrem di bawah  $-3$ , yang dapat mengindikasikan anomali lokal atau noise pada data sensor.




Gambar 3.6 Grafik Histogram

Pada Gambar 3.6 *Histogram plus Estimated Density Plot* menunjukkan histogram distribusi residual dibandingkan dengan estimasi kepadatan kernel (KDE) dan distribusi normal standar  $N(0,1)$ . Bentuk histogram dan kurva KDE menunjukkan bahwa distribusi residual mendekati bentuk distribusi normal, meskipun terdapat sedikit asimetri. Hal ini menunjukkan bahwa asumsi normalitas residual sebagian besar terpenuhi, sehingga model memiliki performa yang dapat diterima dalam hal kesalahan prediksi.



Gambar 3.7 Grafik Normal Q-Q

Gambar 3.7 Normal Q-Q Plot Q-Q digunakan untuk mengevaluasi sejauh mana distribusi residual mengikuti distribusi normal. Titik-titik data sebagian besar berada di sepanjang garis diagonal merah, yang menunjukkan kesesuaian dengan distribusi normal. Beberapa deviasi kecil pada ujung distribusi menunjukkan adanya potensi outlier, namun secara keseluruhan model tetap menunjukkan perilaku residual yang mendekati normalitas.

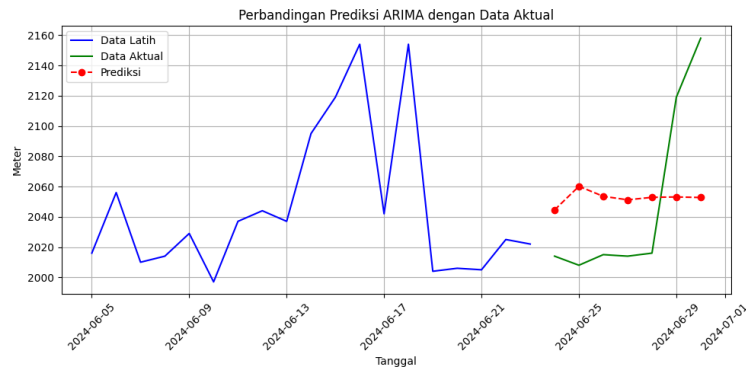


Gambar 3.8 Grafik Correlogram

Gambar 3.8 *Correlogram of Residuals (ACF Residual)* adalah correlogram yang menunjukkan autokorelasi residual hingga lag ke-10. Seluruh batang berada dalam batas kepercayaan 95%, yang berarti tidak ada autokorelasi signifikan yang tersisa dalam residual. Hal ini mengindikasikan bahwa model ARIMA yang dibangun telah cukup mampu

menangkap pola dalam data deret waktu dan residual bersifat acak (white noise), yang merupakan syarat penting dalam validasi model deret waktu.

### 3.4. Hasil Peramalan Dengan Menggunakan Model Terbaik



**Gambar 3.9** Hasil Forecast Ketinggian Sedimen

Gambar 3.5 di atas menyajikan visualisasi perbandingan antara data historis (data latih), data aktual (data uji), dan hasil prediksi model ARIMA pada data kedalaman laut. Grafik ini bertujuan untuk mengukur kinerja prediktif model serta mengevaluasi sejauh mana model ARIMA mampu merepresentasikan pola dari data deret waktu yang diamati.

Garis biru menggambarkan data latih yang digunakan untuk membangun model ARIMA. Data ini mencakup rentang tanggal dari awal pengamatan hingga sebelum masa prediksi. Terlihat bahwa nilai kedalaman laut mengalami fluktuasi yang cukup signifikan, dengan lonjakan tajam pada pertengahan Juni 2024. Model ARIMA dibangun dengan mempertimbangkan pola, tren, dan autokorelasi pada bagian data ini.

Garis hijau menunjukkan data aktual yang tidak dimasukkan ke dalam proses pelatihan model, dan digunakan sebagai pembandingan untuk mengevaluasi performa prediksi. Pada bagian ini, terlihat bahwa nilai kedalaman laut mengalami peningkatan tajam menjelang akhir Juni 2024, yang kemungkinan disebabkan oleh anomali alami atau gangguan pengukuran dari sensor. Hal ini dapat terjadi karena ARIMA bekerja optimal pada pola data yang stabil dan linear. Oleh karena itu, disarankan untuk mempertimbangkan penggunaan metode prediksi lain yang lebih adaptif terhadap perubahan non-linier atau anomali, seperti LSTM (Long Short-Term Memory) yang berbasis deep learning atau model hybrid ARIMA-ML. Pendekatan ini dapat membantu meningkatkan akurasi prediksi terutama saat terjadi anomali alami atau gangguan sensor, yang tidak dapat ditangkap secara baik oleh ARIMA konvensional. Model hybrid juga memungkinkan pemanfaatan keunggulan ARIMA dalam menangani pola linier dan ML dalam mengenali pola non-linier secara simultan.

Garis merah putus-putus dengan penanda titik menunjukkan hasil prediksi dari model ARIMA terhadap rentang data uji. Secara umum, model ARIMA berhasil memberikan prediksi yang cukup stabil dan mendekati rata-rata dari data aktual, khususnya pada tanggal-tanggal awal masa prediksi. Namun, model kurang mampu menangkap lonjakan tajam yang terjadi menjelang akhir periode. Hal ini dapat dijelaskan karena model ARIMA sangat bergantung pada pola historis, dan tidak memiliki mekanisme eksplisit untuk menangani anomali mendadak atau perubahan struktural yang tidak terdeteksi sebelumnya.

## 4. Kesimpulan

Berdasarkan hasil analisis deret waktu terhadap data kedalaman laut yang diperoleh dari sensor, model ARIMA telah berhasil dibangun dan diujikan dalam konteks prediksi jangka pendek. Evaluasi dilakukan menggunakan data aktual dan hasil prediksi model pada periode pengujian, dengan fokus pada kestabilan prediksi dan akurasi kesalahan.

Hasil visualisasi menunjukkan bahwa model ARIMA mampu menangkap pola umum data historis dan memberikan prediksi yang cukup akurat pada periode yang stabil. Namun, pada bagian akhir data uji, terjadi lonjakan nilai kedalaman laut yang tidak sepenuhnya berhasil diantisipasi oleh model. Hal ini menunjukkan bahwa model ARIMA, yang bersifat linier dan bergantung pada pola masa lalu, memiliki keterbatasan dalam merespons perubahan mendadak atau anomali. Oleh karena itu, disarankan untuk mempertimbangkan integrasi model lain yang lebih adaptif terhadap perubahan non-linier, seperti LSTM (Long Short-Term Memory) atau model hybrid ARIMA-ML, yang dapat memperkuat keakuratan sistem prediksi. Model tersebut dapat membantu meningkatkan sensitivitas sistem terhadap gangguan atau fluktuasi ekstrem yang mungkin terjadi akibat faktor alami maupun kesalahan sensor.

Untuk mengukur akurasi model secara kuantitatif, digunakan dua metrik evaluasi utama:

Mean Absolute Error (MAE) = 17.81 meter

→ Mengindikasikan bahwa secara rata-rata, hasil prediksi menyimpang sebesar  $\pm 17.81$  meter dari data aktual.

Mean Absolute Percentage Error (MAPE) = 0.88%

→ Menunjukkan bahwa persentase kesalahan prediksi terhadap data aktual secara umum sangat kecil, yakni di bawah 1%, yang tergolong sangat baik untuk aplikasi pemantauan lingkungan.

Dapat disimpulkan bahwa model ARIMA merupakan pendekatan yang efektif dan cukup andal dalam memodelkan serta memprediksi kedalaman laut dalam kondisi yang relatif stabil. Nilai MAE yang rendah dan MAPE di bawah 1% membuktikan bahwa model mampu menghasilkan prediksi dengan tingkat kesalahan yang dapat diterima.

## 5. Ucapan Terima Kasih

Penulis dapat menuliskan ucapan terima kasih terutama kepada pihak yang secara tidak langsung membantu penelitian atau lembaga yang membantu pendanaan penelitian. Apabila menuliskan ucapan terima kasih kepada pemberi hibah harap mencantumkan nomor hibah risetnya. Bagian ini ditulis dalam bentuk paragraf dan tidak diperbolehkan ditulis dalam poin-poin.

## 6. Daftar Pustaka

- Catur Putri, S. R., & Junaedi, L. (2022). Penerapan Metode Peramalan Autoregressive Integrated Moving Average Pada Sistem Informasi Pengendalian Persediaan Bahan Baku. *Jurnal Ilmu Komputer Dan Bisnis*, 13(1), 164–173. <https://doi.org/10.47927/jikb.v13i1.293>
- Javier, J., Zahrina, N., Yanfeto, B., & Agassi, R. N. (2024). Pemodelan Pola Sedimentasi di Perairan Pelabuhan Kuala Tanjung untuk Mendukung Pemeliharaan Kedalaman Perairan Pelabuhan Menggunakan Mike 21. *Jurnal Hidrografi Indonesia*, 5(1), 31–36. <https://doi.org/10.62703/jhi.v5i1.18>
- Nova, C., Ridwan, P., Sinun, M., & Malaiga, H. A. (2024). PERKEMBANGAN DALAM PROTOKOL HTTP: MENGATASI TANTANGAN PERFORMA DAN KEAMANAN DI ERA INTERNET YANG TERUS BERKEMBANG. In *Jurnal Ilmiah Sain dan Teknologi* (Vol. 2985, Issue 8).
- Rawat, G., Patel, D., Khapare, P., & Deshpande, S. (2022). ARIMA Based Weather Prediction Model using IoT and Open Source Data. *International Research Journal of Engineering and Technology*. [www.irjet.net](http://www.irjet.net)
- Salam, R., WPandoe, W., Program Studi, M. S., dari Balai teknologi Survei Kelautan, P., dari Fakultas Ilmu dan Teknologi Kebumihan, D., & Pengajar Prodi, D. S. (2022). *ANALISA LAJU SEDIMENTASI DAN TRANSPOR SEDIMEN PADA PEMBANGUNAN BREAKWATER DERMAGA LANTAMAL III PONDOKDAYUNG DI TANJUNGPRIOK JAKARTA*.
- Syekha Sasmita, S., Teknik Elektro, J., & Negeri Lhokseumawe, P. (2021). *RANCANG BANGUN SISTEM MONITORING LEVEL AIR DAN TINGGI SEDIMENTASI PADA SALURAN IRIGASI BERBASIS INTERNET OF THINGS* (Vol. 18, Issue 1).