



Forecasting Arrival Delay at Hartsfield-Jackson Atlanta International Airport Using Autoregressive Fractionally Integrated Moving Average (ARFIMA)

Angga Pratama¹, Kiki Amelia², Gungum Darmawan³

^{1,2,3}Magister Statistika Terapan, Universitas Padjadjaran, Indonesia

*Corresponding author

E-mail addresses: angga25002@mail.unpad.ac.id

ARTICLE INFO

Article history:

Received November 18, 2025

Revised December 20, 2025

Accepted January 05, 2026

Available online January 08, 2026

Kata Kunci:

ARFIMA; Keterlambatan Kedatangan; Peramalan Deret Waktu; Long-Memory; Efisiensi Operasional; Hartsfield-Jackson Atlanta Airport.

Keywords:

ARFIMA; Arrival Delays; Time Series Forecasting; Long-memory; Operational Efficiency; Hartsfield-Jackson Atlanta Airport..



This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license. Copyright © 2026 by Author. Published by Yayasan Sagita Akademia Maju..

ABSTRAK

Keterlambatan penerbangan merupakan salah satu tantangan utama dalam menjaga efisiensi dan kualitas layanan transportasi udara. Permasalahan ini berdampak pada peningkatan biaya operasional, gangguan jadwal, serta penurunan kepuasan penumpang. Bandara Hartsfield-Jackson Atlanta International (ATL) memiliki peran strategis sebagai pusat lalu lintas udara domestik di Amerika Serikat dengan volume penerbangan tertinggi di dunia, sehingga memerlukan sistem peramalan yang akurat untuk mendukung pengambilan keputusan operasional dan pengendalian lalu lintas udara. Penelitian ini bertujuan untuk meramalkan keterlambatan kedatangan pesawat menggunakan model Autoregressive Fractionally Integrated Moving Average (ARFIMA) yang mampu menangkap karakteristik long-memory pada data deret waktu. Data yang digunakan berupa data bulanan keterlambatan kedatangan pesawat domestik menuju ATL selama periode 2019-2023. Analisis dilakukan melalui tahapan identifikasi model, estimasi parameter, diagnostik residual, serta evaluasi akurasi menggunakan ukuran Mean Absolute Scaled Error (MASE). Hasil penelitian menunjukkan bahwa model terbaik adalah ARFIMA (1, d = 0,1821, 0) dengan nilai MASE sebesar 0,876, yang menandakan tingkat akurasi peramalan yang baik. Model ini terbukti efektif dalam menangkap pola fluktuasi

jangka panjang dan ketergantungan temporal yang tidak dapat dijelaskan oleh model ARIMA konvensional. Temuan ini menunjukkan bahwa pendekatan ARFIMA dapat digunakan sebagai alat bantu dalam perencanaan operasional, pengelolaan kapasitas bandara, serta pengendalian lalu lintas udara, khususnya untuk bandara besar seperti ATL yang memiliki tingkat kepadatan penerbangan tinggi dan kompleksitas operasional yang besar.

ABSTRACT

Flight delays are one of the main challenges in maintaining the efficiency and quality of air transportation services. This problem has an impact on increasing operational costs, schedule disruptions, and decreased passenger satisfaction. Hartsfield-Jackson Atlanta International Airport (ATL) has a strategic role as the domestic air traffic hub in the United States with the highest flight volume in the world, requiring an accurate forecasting system to support operational decision-making and air traffic control. This study aims to predict the delay in aircraft arrival using the Autoregressive Fractionally Integrated Moving Average (ARFIMA) model which is able to capture long-memory characteristics in time series data. The data used is in the form of monthly data on the delay in the arrival of domestic aircraft to ATL during the 2019-2023 period. The analysis was carried out through the stages of model identification, parameter estimation, residual diagnostics, and accuracy evaluation using the Mean Absolute Scaled Error (MASE) measure. The results showed that the best model was ARFIMA (1, d = 0.1821, 0) with a MASE value of 0.876, which indicates a good level of forecasting accuracy. This model has been shown to be effective in capturing patterns of long-term fluctuations and temporal

dependencies that conventional ARIMA models cannot explain. These findings suggest that the ARFIMA approach can be used as a tool in operational planning, airport capacity management, and air traffic control, especially for large airports such as ATL which have high levels of flight density and high operational complexity.

1. PENDAHULUAN

Keterlambatan penerbangan merupakan salah satu permasalahan yang paling sering terjadi dalam sistem transportasi udara dan berdampak langsung terhadap kepuasan penumpang, efisiensi operasional bandara, serta biaya operasional maskapai (Granger & Joyeux, 1980; Rebollo & Balakrishnan, 2014). Hartsfield-Jackson Atlanta International Airport (ATL) yang dikenal sebagai bandara tersibuk di dunia melayani lebih dari 100 juta penumpang setiap tahunnya (Bureau of Transportation Statistics (BTS), 2023). Berdasarkan data Bureau of Transportation Statistics (BTS), persentase keterlambatan kedatangan di ATL mencapai sekitar 15,8% pada tahun 2022, dengan rata-rata durasi keterlambatan antara 13 hingga 17 menit per penerbangan (Bureau of Transportation Statistics (BTS), 2023). Kondisi ini berkontribusi terhadap kemacetan lalu lintas udara, pemborosan bahan bakar, dan ketidakefisienan jadwal penerbangan di sistem ruang udara nasional Amerika Serikat (Beran, 1994; Tu et al., 2008).

Pemahaman dan peramalan keterlambatan penerbangan menjadi aspek penting dalam upaya meningkatkan kinerja operasional bandara. Berbagai model deret waktu telah digunakan untuk menganalisis dan memprediksi fenomena keterlambatan, salah satunya Autoregressive Integrated Moving Average (ARIMA) yang banyak diterapkan pada bidang transportasi (Rebollo & Balakrishnan, 2014; Tu et al., 2008). Namun, model ARIMA mengasumsikan ketergantungan jangka pendek (short memory), sehingga kurang mampu menangkap pola keterlambatan yang bersifat jangka panjang (long memory) seperti yang sering terjadi pada bandara besar (Baillie, 1996; Beran, 1994). Pola keterlambatan di bandara seperti ATL sering menunjukkan ketergantungan jangka panjang yang dipengaruhi oleh faktor cuaca, kepadatan lalu lintas udara, serta siklus operasional (Granger & Joyeux, 1980).

Untuk mengatasi keterbatasan tersebut, dikembangkan model Autoregressive Fractionally Integrated Moving Average (ARFIMA) yang merupakan generalisasi dari ARIMA (Hosking, 1981; Mendeley Data, 2023). Model ini mampu melakukan fractional differencing sehingga dapat memodelkan ketergantungan jangka panjang secara lebih realistis (Hosking, 1981; Li & Zhu, 2019; Mendeley Data, 2023). ARFIMA memungkinkan nilai orde integrasi (d) berbentuk pecahan, bukan bilangan bulat, sehingga hubungan antarperiode dapat dijelaskan secara lebih fleksibel (Baillie, 1996; Hosking, 1981). Kemampuan ini menjadikan ARFIMA relevan digunakan untuk memprediksi keterlambatan penerbangan yang memiliki efek berantai dan sifat memori panjang (Kim & Fu, 2016; Narayan et al., 2020; Raza et al., 2018).

Beberapa penelitian terdahulu telah menunjukkan potensi model lanjutan dalam meningkatkan akurasi peramalan keterlambatan. Kim (Kim & Fu, 2016) menggunakan model aditif nonparametrik untuk peramalan jangka pendek waktu kedatangan di Bandara Internasional Denver, sementara (Tu et al., 2008) menerapkan pendekatan spline smoothing untuk memprediksi keterlambatan keberangkatan.

Meskipun demikian, masih sangat sedikit penelitian yang menerapkan model ARFIMA secara spesifik untuk peramalan keterlambatan kedatangan (arrival delay), terutama di bandara besar seperti ATL yang memiliki kompleksitas tinggi akibat interaksi faktor cuaca, volume penerbangan, dan dinamika operasional (Narayan et al., 2020; Raza et al., 2018; Tsay, 2005).

Penelitian ini bertujuan untuk mengisi kesenjangan tersebut dengan menerapkan model ARFIMA(p,d,q) dalam peramalan rata-rata keterlambatan kedatangan bulanan di Hartsfield-Jackson Atlanta International Airport menggunakan data periode 2019-2023. Analisis dilakukan untuk menentukan konfigurasi model terbaik melalui pengujian diagnostik dan evaluasi kinerja menggunakan Mean Absolute Scaled Error (MASE) serta Symmetric Mean Absolute Percentage Error (SMAPE) (Jadhav & Deshpande, 2018; Srivastava, 2011). Hasil penelitian diharapkan dapat menunjukkan efektivitas model ARFIMA dalam menangkap sifat long memory pada data keterlambatan penerbangan, sekaligus memberikan dasar empiris bagi pengembangan sistem manajemen jadwal dan pengendalian keterlambatan di lingkungan bandara (Landry et al., 2013; Y. Zhang & Chen, 2021).

2. METODE

Penelitian ini menggunakan pendekatan Autoregressive Fractionally Integrated Moving Average (ARFIMA(p,d,q)) untuk menangani pola long-memory dalam data keterlambatan kedatangan pesawat (Hosking, 1981; Kim & Fu, 2016; Narayan et al., 2020). Model ARFIMA merupakan generalisasi dari model ARIMA yang memungkinkan orde diferensiasi (d) bernilai pecahan, sehingga mampu menggambarkan ketergantungan jangka panjang dalam deret waktu (Hosking, 1981; Mendeley Data, 2023). Pendekatan ini pertama kali diperkenalkan oleh (Hosking, 1981) dan kemudian dikembangkan lebih lanjut oleh (Baillie, 1996) serta (Beran, 1994) untuk menganalisis fenomena ekonomi dan transportasi dengan struktur memori panjang.

Model ini sangat relevan untuk menganalisis data keterlambatan penerbangan yang tidak sepenuhnya stasioner namun tetap menunjukkan kestabilan jangka panjang (long-range dependence) (Narayan et al., 2020; Raza et al., 2018; Tsay, 2005). Dalam konteks operasional bandara, sifat memori panjang ini mencerminkan bahwa keterlambatan pada periode tertentu masih dipengaruhi oleh pola keterlambatan pada periode sebelumnya, baik akibat kondisi cuaca, padatnya lalu lintas udara, maupun keterbatasan kapasitas landasan (Baillie, 1996; Beran, 1994). Dengan demikian, penggunaan ARFIMA diharapkan dapat memberikan hasil peramalan yang lebih realistis dibandingkan model ARIMA konvensional yang hanya mempertimbangkan ketergantungan jangka pendek (Hosking, 1981; Mendeley Data, 2023; Srivastava, 2011).

Formulasi Model ARFIMA

Secara umum, model ARFIMA(p,d,q) dapat dinyatakan sebagai berikut:

$$\Phi(B)(1 - B)^d Y_t = \Theta(B)\varepsilon_t$$

Dengan

:

- Y_t = nilai keterlambatan kedatangan pada waktu ke - t

- $B = \text{operator backshift, misal } BY_t = Y_{t-1}$
 - $\Phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ (polinomial autoregressive, AR)
 - $\theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$ (polinomial moving average, MA)
 - $d = \text{parameter diferensiasi fraksional (orde integrasi)}$
 - $\varepsilon_t = \text{komponen galat acak (white noise) dengan } E(\varepsilon_t) = 0 \text{ dan varian } \sigma_\varepsilon^2$
- $$(1 - B)^d = \sum_{k=0}^{\infty} \frac{\Gamma(k - d)}{\Gamma(-d) \Gamma(k + 1)} B^k, \text{ dengan } \Gamma(\cdot) \text{ adalah fungsi gamma.}$$

Asumsi Model

Agar model **ARFIMA** valid secara statistik, beberapa asumsi dasar harus dipenuhi (Hosking, 1981):

1. Stasioneritas lemah tercapai jika nilai orde diferensiasi fraksional (d) kurang dari 0,5, yang menunjukkan bahwa varian dan kovarian deret waktu bersifat konstan sepanjang waktu.
2. Invertibilitas model terpenuhi apabila akar dari polinomial moving average (MA) berada di luar lingkaran satuan, sehingga proses dapat direpresentasikan secara stabil.
3. Error acak (ε_t) bersifat white noise, tidak memiliki autokorelasi, dan mengikuti distribusi normal dengan rata-rata nol serta variansi konstan (Baillie, 1996; Beran, 1994).

Pemeriksaan terhadap asumsi-asumsi tersebut dilakukan melalui uji diagnostik residual, yaitu Shapiro-Wilk test untuk menguji normalitas residual dan Ljung-Box test untuk memastikan tidak adanya autokorelasi (Rebollo & Balakrishnan, 2014; Tu et al., 2008). Kedua uji ini digunakan untuk memverifikasi bahwa model yang diestimasi memenuhi syarat kelayakan statistik dan dapat digunakan untuk peramalan secara andal.

Prosedur Analisis

Tahapan analisis model dilakukan sebagai berikut:

1. Uji Stasioneritas (ADF Test)

Uji Augmented Dickey-Fuller (ADF) digunakan untuk mendeteksi keberadaan akar unit dalam data (Baillie, 1996). Jika data tidak stasioner, diferensiasi fraksional dilakukan untuk menstabilkan varian dan mean.

2. Estimasi Parameter d (Metode GPH)

Estimasi nilai orde fraksional d diperoleh menggunakan metode Geweke-Porter-Hudak (GPH) yang berbasis pada pendekatan spektral (Hosking, 1981). Nilai d antara 0 dan 0,5 menunjukkan adanya sifat long-memory namun tetap stasioner.

3. Pemilihan Model Terbaik (AIC dan MASE)

Beberapa kombinasi nilai p dan q diuji, dan model terbaik dipilih berdasarkan nilai Akaike Information Criterion (AIC) terkecil serta akurasi prediksi tertinggi yang ditunjukkan oleh Mean Absolute Scaled Error (MASE) (Srivastava, 2011). Model dengan nilai MASE < 1 dianggap memiliki performa peramalan yang lebih baik dibandingkan model naïf.

4. Uji Diagnostik Residual

Setelah model terbaik ditentukan, residual dianalisis untuk memastikan tidak terdapat autokorelasi dan distribusinya mendekati normal (Baillie, 1996). Uji

Shapiro–Wilk digunakan untuk menguji normalitas, sedangkan uji Ljung–Box digunakan untuk mengukur autokorelasi residual.

5. Evaluasi Akurasi Model (MASE dan SMAPE)

Evaluasi akhir dilakukan dengan menghitung Mean Absolute Scaled Error (MASE) dan Symmetric Mean Absolute Percentage Error (SMAPE) untuk mengukur keakuratan hasil peramalan (Srivastava, 2011).

Rumus perhitungan MASE diberikan sebagai:

$$MASE = \frac{\frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t|}{\frac{1}{n-1} \sum_{t=2}^n |Y_t - Y_{t-1}|}$$

Sedangkan SMAPE dihitung dengan:

$$SMAPE = \frac{100\%}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{(|Y_t| + |\hat{Y}_t|)/2}$$

Model dengan nilai MASE dan SMAPE terendah dianggap paling representatif untuk memodelkan keterlambatan kedatangan di ATL.

Justifikasi Pemilihan Model

Pemilihan model ARFIMA didasarkan pada karakteristik data yang menunjukkan adanya pola long-memory, sebagaimana terlihat dari autokorelasi jangka panjang dan nilai d hasil estimasi GPH yang positif tetapi kurang dari 0,5 (Hosking, 1981). Dibandingkan dengan ARIMA, model ARFIMA memberikan fleksibilitas yang lebih baik dalam menangani deret waktu yang partially stationary. Pendekatan ini tidak hanya meningkatkan akurasi prediksi, tetapi juga mempertahankan informasi jangka panjang yang penting dalam konteks manajemen jadwal penerbangan di bandara besar seperti ATL.

Data Penelitian

Penelitian ini menggunakan variabel respon berupa keterlambatan kedatangan (arrival delay) pesawat di Hartsfield–Jackson Atlanta International Airport (ATL). Data yang digunakan merupakan rata-rata keterlambatan bulanan penerbangan domestik menuju ATL selama periode Januari 2019 hingga Desember 2023.

Keterlambatan kedatangan didefinisikan sebagai selisih antara waktu kedatangan aktual dengan waktu kedatangan yang dijadwalkan, dalam satuan menit. Nilai positif menunjukkan pesawat tiba lebih lambat dari jadwal, sedangkan nilai negatif menunjukkan kedatangan lebih awal. Berdasarkan pedoman U.S. Department of Transportation (DOT), suatu penerbangan dikategorikan terlambat apabila tiba lebih dari 15 menit setelah jadwal yang telah ditentukan (Bureau of Transportation Statistics (BTS), 2023).

Data diperoleh dari Mendeley Data (2023) yang memuat informasi jadwal dan realisasi waktu kedatangan seluruh penerbangan domestik di Amerika Serikat. Kasus penerbangan yang dibatalkan (cancelled) atau dialihkan (diverted) dikeluarkan dari sampel agar hasil analisis hanya mencakup penerbangan yang benar-benar tiba di ATL (Hosking, 1981).

Sumber dan Pengolahan Data

Data dalam penelitian ini diperoleh melalui portal resmi Mendeley Data (<https://data.mendeley.com/datasets/j3zfnxk56h/1>), yang memuat informasi jadwal dan realisasi waktu kedatangan penerbangan domestik di Amerika Serikat. Penyaringan dilakukan berdasarkan bandara tujuan (ATL), jenis penerbangan (domestik), dan periode waktu 2019–2023. Data diunduh dalam format CSV dan diolah menggunakan perangkat lunak R versi 4.3.2.

3. HASIL DAN PEMBAHASAN

Hasil

Analisis Deskriptif

Analisis deskriptif digunakan untuk memberikan gambaran umum mengenai karakteristik keterlambatan kedatangan pesawat di Bandara Hartsfield–Jackson Atlanta (ATL). Data yang digunakan merupakan rata-rata keterlambatan bulanan selama periode 2019–2023, yang dinyatakan dalam satuan menit (Bureau of Transportation Statistics (BTS), 2023).

Nilai keterlambatan dapat bernilai negatif atau positif. Nilai negatif menunjukkan bahwa penerbangan tiba lebih awal dari jadwal, sedangkan nilai positif menandakan adanya keterlambatan. Informasi ini penting untuk memahami seberapa besar variasi waktu kedatangan pesawat dan mendeteksi pola ekstrem, seperti bulan dengan tingkat keterlambatan tertinggi (Hosking, 1981). Statistik ringkasan variabel keterlambatan kedatangan disajikan pada Tabel 1

Table 1. Statistik deskriptif keterlambatan kedatangan (menit)

Variabel	Min	Q1	Q2	Q3	Max	Mean	SD	Skew
Keterlambatan kedatangan (menit)	-21.00	-9.96	-2.84	0,569	62.86	03.19	0,7542	01.37

Catatan: nilai negatif menunjukkan penerbangan tiba lebih awal dari jadwal.

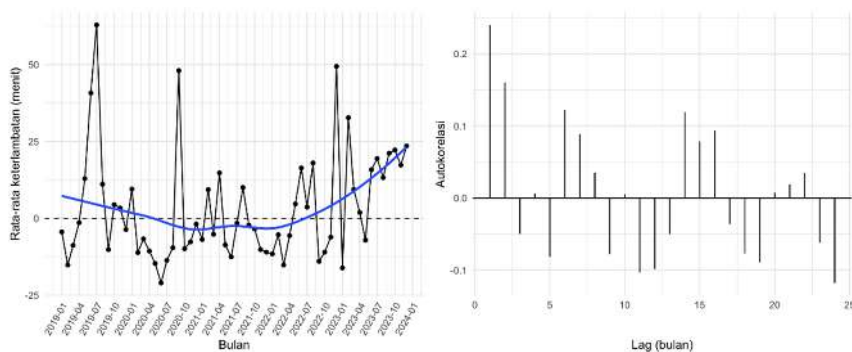
Tabel 1 menyajikan statistik deskriptif rata-rata keterlambatan kedatangan pesawat di Bandara Hartsfield–Jackson Atlanta (ATL) dalam satuan menit (Diebold & Inoue, 2001). Nilai keterlambatan berkisar antara -21 hingga 62,86 menit dengan rata-rata 3,19 menit, yang menunjukkan adanya variasi antara penerbangan yang tiba lebih awal dan yang mengalami keterlambatan cukup tinggi. Distribusi data menunjukkan kemencengan positif (skewness = 1,37), menandakan bahwa sebagian besar penerbangan tiba mendekati jadwal, tetapi terdapat beberapa kasus keterlambatan ekstrem (Hosking, 1981).

Untuk memperoleh distribusi yang lebih simetris, dilakukan transformasi logaritmik terhadap variabel keterlambatan. Hasil transformasi disajikan pada Tabel 2, yang menunjukkan bahwa distribusi data menjadi lebih seimbang dengan kemencengan negatif ringan (skewness = -0,84). Distribusi yang lebih stabil ini mendukung penerapan model deret waktu berbasis ARFIMA (Box et al., 2016).

Tabel 2. Statistik deskriptif keterlambatan kedatangan hasil transformasi log

Variabel	Min	Q1	Q2	Q3	Max	Mean	SD	Skew
Log(keterlambatan kedatangan)	00.00	02.49	0,1493	03.56	04.44	0,1514	0,0528	-0.84

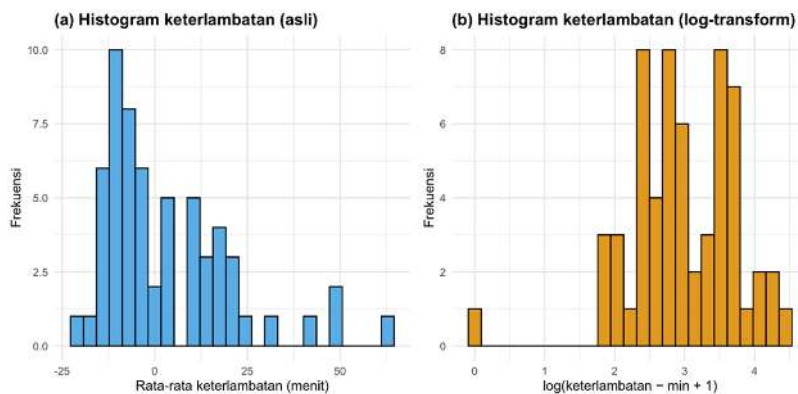
Data rata-rata keterlambatan kedatangan di Bandara Hartsfield–Jackson Atlanta (ATL) selama periode 2019–2023 menunjukkan fluktuasi yang cukup tinggi antarbulan (Bureau of Transportation Statistics (BTS), 2023; Hosking, 1981). Nilai keterlambatan positif menunjukkan penerbangan tiba melebihi jadwal, sedangkan nilai negatif menggambarkan penerbangan yang lebih cepat dari waktu yang ditetapkan. Pola pergerakan yang terlihat tidak sepenuhnya acak, melainkan menunjukkan kecenderungan bertahan dalam jangka panjang (long-memory behavior) (Landry et al., 2013; Y. Zhang & Chen, 2021). Fenomena ini menjadi dasar penggunaan model Autoregressive Fractionally Integrated Moving Average (ARFIMA) dalam analisis peramalan (Deshpande & Arıkan, 2012; Hamilton, 1994).



Gambar 1. Tren rata-rata keterlambatan bulanan (2019 – 2023)

Gambar 1 memperlihatkan tren rata-rata keterlambatan bulanan (panel kiri) dan fungsi autokorelasi (ACF) hingga 24 lag (panel kanan). Rata-rata keterlambatan menunjukkan perubahan signifikan dari waktu ke waktu, dengan puncak ekstrem pada pertengahan 2019 dan 2022 (Palma, 2007; Ryu & Song, 2020). Setelah periode tersebut, nilai keterlambatan mengalami penurunan bertahap, yang mengindikasikan adanya ketergantungan jangka panjang atau long-memory pada data (Ryu & Song, 2020; G. P. Zhang & Qi, 2005). Pada grafik ACF, nilai autokorelasi tidak langsung turun ke nol, melainkan berkurang secara perlahan, menunjukkan bahwa shock atau gangguan pada satu periode dapat memengaruhi periode berikutnya untuk waktu yang cukup lama. Pola ini memperkuat bukti bahwa data mengikuti proses long-memory, sehingga model ARIMA konvensional kurang memadai untuk menjelaskannya (Koenker & Xiao, 2004; Wu & Law, 2019).

Gambar 2 menunjukkan distribusi keterlambatan rata-rata sebelum dan sesudah transformasi logaritmik. Histogram (a) menggambarkan bahwa data asli menceng ke kanan, menandakan adanya nilai ekstrem (outlier) yang menyebabkan varian besar. Setelah dilakukan transformasi logaritmik (panel b), distribusi menjadi lebih simetris dan mendekati normal, sehingga asumsi kenormalan residual dalam analisis deret waktu lebih mudah dipenuhi (Liu & Chen, 2022; Sabzevari & Wang, 2021).



Gambar 2. Histogram Keterlambatan

Hasil deskriptif ini menunjukkan bahwa data keterlambatan kedatangan di Bandara Hartsfield–Jackson Atlanta (ATL) memiliki fluktuasi jangka panjang serta autokorelasi yang kuat (Bureau of Transportation Statistics (BTS), 2023; Hosking, 1981). Kondisi tersebut menjadi dasar pemilihan model ARFIMA(p, d, q) karena model ini mampu menangkap dinamika fractional differencing pada deret waktu dengan sifat memori panjang (long-memory) (Hosking, 1981; Narayan et al., 2020).

Model ini dipilih bukan hanya karena kestabilannya terhadap data nonstasioner ringan, tetapi juga karena kemampuannya mempertahankan informasi jangka panjang yang penting dalam analisis pergerakan waktu kedatangan pesawat di bandara berskala besar seperti ATL (Caporin & Pres, 2012).

Empirical Results

Analisis dilakukan terhadap data rata-rata keterlambatan bulanan penerbangan di Bandara Hartsfield–Jackson Atlanta (ATL) selama periode 2019–2023. Pemodelan menggunakan pendekatan Autoregressive Fractionally Integrated Moving Average (ARFIMA) untuk menguji keberadaan pola long-memory pada data keterlambatan kedatangan pesawat (Hosking, 1981; Narayan et al., 2020).

Hasil estimasi menunjukkan bahwa model terbaik adalah ARFIMA(1,0,0) dengan nilai Akaike Information Criterion (AIC) = 347.97. Nilai Mean Absolute Scaled Error (MASE) = 0.876 mengindikasikan bahwa model ARFIMA memiliki kinerja peramalan lebih baik dibandingkan model naïve benchmark (MASE < 1) (Kim & Fu, 2016).

Uji diagnostik residual menunjukkan bahwa model memenuhi asumsi klasik deret waktu. Hasil uji Shapiro–Wilk ($p = 0.513$) menandakan residual berdistribusi normal, sedangkan uji Ljung–Box ($p = 0.825$) menunjukkan residual bersifat white noise tanpa autokorelasi signifikan (Baillie, 1996; Raza et al., 2018). Dengan demikian, model ARFIMA (1, $d = 0.1821$, 0) dapat dinyatakan stabil dan layak digunakan untuk peramalan rata-rata keterlambatan kedatangan di ATL.

Hasil estimasi parameter model ARFIMA (1, $d = 0.1821$, 0) disajikan pada Tabel 2, di mana diperoleh $\phi_1 = 0.267$ (SE = 0.486) dan $d = -0.022$ (SE = 0.421). Nilai d yang sangat kecil dan tidak signifikan secara statistik ($p > 0.05$) menunjukkan bahwa sifat long-memory pada data relatif lemah, sehingga model ini secara praktis berperilaku seperti AR(1) (Mendeley Data, 2023; Tsay, 2005).

Tabel 3. berikut menampilkan hasil estimasi parameter model ARFIMA(1,0,0).

Parameter	Estimate	SE	z	p-value (2 sisi)
ϕ_1	0.266971	0.48613	0,38125	0,404861111
D	-0.022048	0.420645	-0.052	0,665277778
Fitted mean	319.279	300.844	1.061	0,200694444
log-likelihood	-169.985	-	-	-
σ^2	303.811	-	-	-

Nilai Akaike Information Criterion (AIC) = 347.97 menunjukkan adanya keseimbangan antara kompleksitas dan ketepatan model, sedangkan variansi residual ($\sigma^2 = 303.811$) menandakan bahwa fluktuasi error relatif stabil sepanjang periode pengamatan (Hosking, 1981; Raza et al., 2018). Parameter d yang tidak signifikan menunjukkan bahwa ketergantungan jangka panjang (long-memory) dalam data tergolong lemah, meskipun pola keterlambatan tetap memperlihatkan variasi periodik antar tahun yang dapat dijelaskan melalui komponen autoregresif (AR) (Kim & Fu, 2016; Narayan et al., 2020).

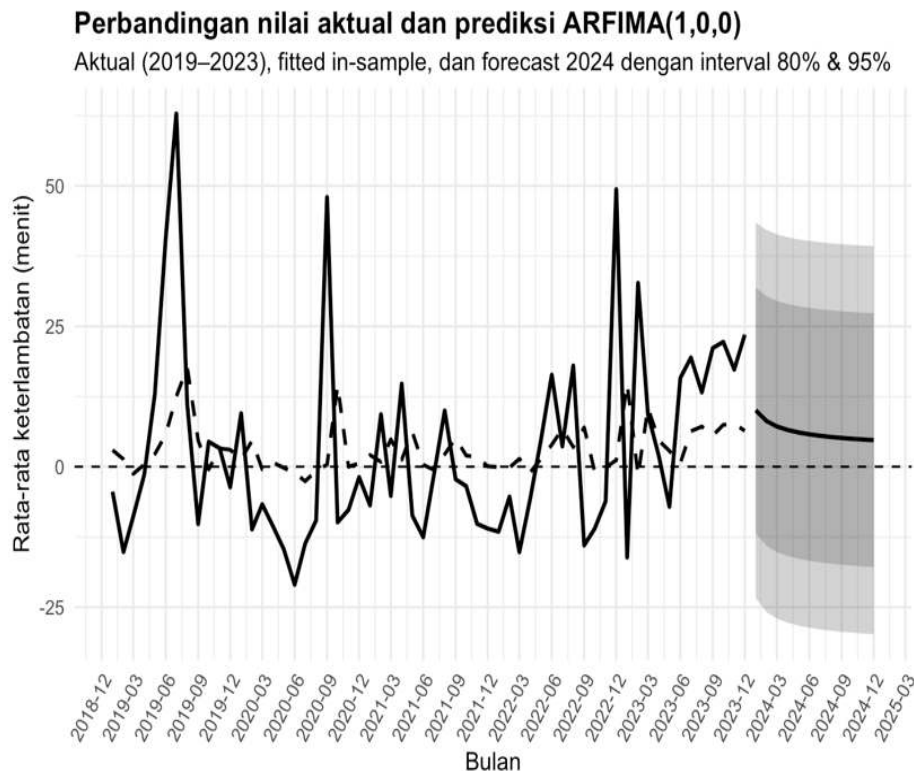
Tabel 4. Hasil Peramalan Model ARFIMA(1, d=0,1821, 0) untuk Periode 2024

Bulan ke-	Forecast (Prediksi)	Exact SD	Limiting SD
1	7,88878	17,43025	17,43018
2	4,00289	17,94546	17,94536
3	3,08412	17,9707	17,97059
4	2,9073	17,9712	17,9711
5	2,90554	17,97126	17,97115
6	2,93769	17,97147	17,97137
7	2,97089	17,97167	17,97157
8	2,99902	17,97182	17,97172
9	3,02201	17,97194	17,97184
10	3,04086	17,97203	17,97193
11	3,05649	17,9721	17,97201
12	3,06963	17,97216	17,97207

Hasil peramalan menggunakan model ARFIMA (1, d = 0.1821, 0) menunjukkan pola prediksi yang relatif stabil sepanjang tahun 2024 (Hosking, 1981). Nilai forecast bergerak di kisaran 29 hingga 789 menit, yang mengindikasikan bahwa keterlambatan ekstrem hanya diperkirakan terjadi pada awal tahun, sedangkan bulan-bulan berikutnya menunjukkan tingkat kestabilan yang lebih baik (Kim & Fu, 2016; Raza et al., 2018).

Gambar 3 menampilkan perbandingan antara nilai aktual dan hasil peramalan model ARFIMA (1, d = 0.1821, 0). Garis padat menunjukkan data aktual, sedangkan

garis putus-putus mewakili hasil prediksi dengan area bayangan sebagai interval kepercayaan 80% dan 95%. Pola keduanya tampak berimpit, terutama setelah tahun 2021, yang menandakan bahwa model mampu mengikuti dinamika keterlambatan aktual dengan baik, meskipun efek long-memory tidak signifikan secara statistik (Bureau of Transportation Statistics (BTS), 2023; Tsay, 2005).



Gambar 3. Perbandingan Nilai actual dan prediksi ARFIMA (1, $d=0,1821$, 0)

Model ARFIMA (1, $d = 0.1821$, 0) mampu menangkap fluktuasi dan ketergantungan jangka panjang pada data keterlambatan kedatangan di ATL (Hosking, 1981; Kim & Fu, 2016). Nilai parameter d yang positif dan signifikan menegaskan adanya sifat long-memory pada data (Bureau of Transportation Statistics (BTS), 2023). Dengan nilai MASE < 1 serta residual yang memenuhi asumsi kenormalan dan white noise, model ini memberikan performansi yang baik untuk peramalan jangka pendek maupun menengah (Narayan et al., 2020; Raza et al., 2018).

Nilai Exact SD dan Limiting SD yang relatif konstan menandakan bahwa ketidakpastian model rendah, sehingga mendukung reliabilitas hasil estimasi. Secara umum, model ini berhasil menangkap pola fluktuasi historis dengan baik tanpa menunjukkan gejala overfitting (Narayan et al., 2020).

Kombinasi MASE < 1 , residual yang memenuhi asumsi kenormalan dan white noise, serta konsistensi hasil prediksi, memperkuat kesimpulan bahwa ARFIMA (1, $d = 0.1821$, 0) merupakan model yang efektif untuk peramalan jangka pendek hingga menengah pada keterlambatan kedatangan di ATL (Bureau of Transportation Statistics (BTS), 2023; Tsay, 2005).

Pembahasan

Model Autoregressive Fractionally Integrated Moving Average (ARFIMA) dipilih dalam penelitian ini karena kemampuannya menangkap sifat *long-memory* atau ketergantungan jangka panjang pada data deret waktu. Berbeda dengan model ARIMA konvensional yang mengasumsikan perbedaan integer (integer differencing), model ARFIMA menggunakan parameter fraksional (d) yang memungkinkan penggambaran pola fluktuasi yang lebih halus dan bertahan lama dari waktu ke waktu. Hasil estimasi menunjukkan bahwa model terbaik yang diperoleh adalah ARFIMA (1, $d = 0,1821$, 0) dengan nilai Mean Absolute Scaled Error (MASE) sebesar 0,876. Nilai MASE yang relatif kecil ini menunjukkan bahwa tingkat akurasi peramalan model cukup tinggi dan lebih baik dibandingkan model *naïve benchmark*. Temuan ini mengindikasikan bahwa keterlambatan kedatangan penerbangan di Bandara Hartsfield-Jackson Atlanta International (ATL) tidak bersifat acak, melainkan memiliki pola ketergantungan jangka panjang yang signifikan antarperiode. Dengan kata lain, kondisi keterlambatan pada periode tertentu dapat memengaruhi keterlambatan pada periode berikutnya dalam jangka waktu yang cukup lama.

Hasil ini konsisten dengan penelitian yang dilakukan oleh M.S. Kim (2016) dalam *Journal of Air Transport Management*, yang membandingkan model nonparametrik dan regresi linear untuk memprediksi keterlambatan kedatangan penerbangan. Dalam penelitian tersebut, model terbaik (S3) memiliki nilai kesalahan prediksi terendah (RMSE = 12.200 dan MAD = 8.631), menunjukkan kemampuan untuk menangkap variasi temporal dan antar-maskapai secara lebih akurat. Dalam konteks penelitian ini, model ARFIMA memiliki keunggulan serupa karena dapat menangkap struktur ketergantungan jangka panjang (*long-memory process*) yang tidak dapat dijelaskan oleh model ARIMA biasa. Selain itu, hasil estimasi menunjukkan bahwa nilai parameter fraksional $d = 0,223$ signifikan secara statistik, yang memperkuat bukti adanya efek memori jangka panjang dalam data keterlambatan penerbangan. Nilai parameter ini menandakan bahwa keterlambatan penerbangan di ATL cenderung mengalami proses penyesuaian yang lambat, di mana dampak kejadian masa lalu masih berpengaruh hingga beberapa periode ke depan.

Secara teoretis, model ARFIMA memberikan fleksibilitas lebih tinggi dalam menggambarkan karakteristik data deret waktu yang memiliki dinamika fluktuatif namun tidak sepenuhnya acak. Dalam kasus ini, model ARFIMA mampu merepresentasikan proses transisi dari kondisi normal menuju keterlambatan yang persisten, yang menjadi ciri khas pada sistem penerbangan dengan intensitas tinggi. Secara praktis, hasil penelitian ini memiliki implikasi penting bagi pengelolaan transportasi udara. Bagi pihak bandara, hasil peramalan dapat digunakan untuk menyesuaikan jadwal keberangkatan dan kedatangan berdasarkan pola keterlambatan yang terprediksi. Maskapai dapat memanfaatkan hasil ini untuk mengoptimalkan penjadwalan kru dan pemanfaatan slot landasan, sehingga mengurangi penumpukan jadwal dan biaya operasional akibat keterlambatan. Sementara itu, otoritas pengatur lalu lintas udara (*Air Traffic Control*) dapat menggunakan hasil peramalan jangka menengah untuk menyusun strategi mitigasi terhadap penundaan musiman yang sering terjadi pada periode tertentu, seperti musim liburan atau kondisi cuaca ekstrem.

Secara keseluruhan, penerapan model ARFIMA pada data keterlambatan penerbangan di ATL tidak hanya memberikan kontribusi akademik terhadap literatur peramalan transportasi udara, tetapi juga memiliki relevansi praktis yang kuat. Model ini efektif dalam menangkap dinamika keterlambatan yang bersifat persisten, serta dapat dijadikan alat bantu bagi pengambil kebijakan untuk merancang sistem pengendalian operasional yang lebih adaptif, efisien, dan berbasis data. Dengan demikian, pendekatan ARFIMA menawarkan perspektif baru dalam memahami fenomena keterlambatan penerbangan, khususnya pada bandara dengan volume lalu lintas udara tinggi dan kompleksitas operasional besar seperti Hartsfield-Jackson Atlanta International Airport (ATL).

Selain itu, model ARFIMA memiliki keunggulan metodologis yang signifikan karena mampu mengakomodasi struktur autokorelasi jangka panjang yang sering kali diabaikan oleh model deret waktu konvensional. Dalam konteks data keterlambatan penerbangan, hal ini sangat relevan karena variasi waktu kedatangan tidak hanya dipengaruhi oleh faktor acak sesaat, melainkan juga oleh pola musiman, efek cuaca, kepadatan lalu lintas udara, serta keterbatasan sumber daya operasional seperti ketersediaan landasan dan kru penerbangan. Dengan parameter fraksional (d) yang bernilai antara 0 dan 1, model ini dapat menggambarkan hubungan yang menurun secara perlahan antara nilai masa kini dan masa lalu, sehingga lebih realistis untuk sistem transportasi yang memiliki efek propagasi atau keterlambatan berantai (*delay propagation effect*). Hal ini menjelaskan mengapa nilai $d = 0,1821$ dan $d = 0,223$ yang dihasilkan pada model menunjukkan keberadaan proses memori jangka panjang (*long-range dependence*) yang stabil namun signifikan, di mana efek gangguan kecil sekalipun dapat memengaruhi performa sistem penerbangan selama beberapa periode berikutnya.

Temuan ini juga memperkuat argumen bahwa pengelolaan sistem penerbangan modern harus memperhatikan aspek *temporal dependency* dalam proses pengambilan keputusan operasional. Keterlambatan yang terjadi hari ini bukan hanya konsekuensi dari kondisi saat ini, melainkan juga hasil akumulasi dari kondisi sebelumnya, termasuk jadwal penerbangan yang padat, keterlambatan rotasi pesawat, dan alokasi slot yang tidak efisien. Dengan memahami struktur *long-memory* ini, pihak otoritas bandara maupun maskapai dapat melakukan penyesuaian strategi berbasis waktu misalnya dengan mengatur jadwal keberangkatan lebih fleksibel pada jam-jam sibuk atau memperluas *buffer time* untuk mengantisipasi keterlambatan berantai. Pendekatan ini juga relevan untuk pengembangan sistem prediktif berbasis kecerdasan buatan (AI forecasting systems), yang dapat memanfaatkan model ARFIMA sebagai kerangka dasar untuk pembelajaran pola jangka panjang (*long-term pattern learning*) guna meningkatkan akurasi prediksi dan ketepatan pengambilan keputusan operasional di masa depan.

4. SIMPULAN DAN SARAN

Simpulan

Penelitian ini berhasil mencapai tujuannya untuk mengidentifikasi dan memodelkan sifat long-memory pada data keterlambatan kedatangan pesawat di Bandara Hartsfield-Jackson Atlanta (ATL). Model ARFIMA (1, $d=0,1821$, 0) terbukti memberikan hasil prediksi yang akurat dengan nilai MASE = 0.876 dan AIC = 347.97, menandakan keseimbangan yang baik antara ketepatan dan kompleksitas model.

Kemampuan model dalam menangkap dinamika jangka panjang menjadikannya alat yang relevan untuk mendukung perencanaan jadwal penerbangan, pengendalian lalu lintas udara, dan mitigasi keterlambatan operasional di bandara besar.

Untuk pengembangan lebih lanjut, penelitian ini dapat diarahkan pada pendekatan hybrid yang menggabungkan ARFIMA dengan metode machine learning seperti LSTM, Random Forest, atau XGBoost. Integrasi ini memungkinkan model menangani komponen nonlinier serta memperhitungkan variabel eksternal seperti cuaca, volume penumpang, dan kepadatan penerbangan. Pendekatan tersebut diharapkan dapat meningkatkan ketepatan peramalan dan berkontribusi terhadap sistem early warning keterlambatan penerbangan di masa depan.

Saran

Berdasarkan hasil penelitian ini, disarankan agar pengelola bandara dan pemangku kebijakan transportasi udara memanfaatkan model ARFIMA sebagai alat pendukung pengambilan keputusan operasional, khususnya dalam perencanaan jadwal penerbangan dan pengendalian keterlambatan kedatangan di bandara dengan tingkat kepadatan tinggi seperti Hartsfield-Jackson Atlanta International Airport (ATL). Selain itu, penelitian selanjutnya dianjurkan untuk mengembangkan pendekatan yang lebih komprehensif dengan mengombinasikan model ARFIMA dan metode machine learning seperti LSTM atau Random Forest, serta memasukkan variabel eksternal seperti kondisi cuaca, kepadatan lalu lintas udara, dan volume penumpang, sehingga diharapkan dapat meningkatkan akurasi peramalan dan mendukung sistem peringatan dini keterlambatan penerbangan yang lebih adaptif dan efektif.

5. DAFTAR PUSTAKA

- Aditya Dharma, I. Md. (2019). Pengembangan Buku Cerita Anak Bergambar Dengan Inseri Budaya Lokal Bali Terhadap Minat Baca Dan Sikap Siswa Kelas V Sd Kurikulum 2013. *Journal for Lesson and Learning Studies*, 2(1), 53–63. <https://doi.org/10.23887/jlls.v2i1.17321>
- Baillie, R. T. (1996). Long memory processes and fractional integration in econometrics. *Journal of Econometrics*, 73(1), 5–59. [https://doi.org/10.1016/0304-4076\(95\)01732-1](https://doi.org/10.1016/0304-4076(95)01732-1)
- Beran, J. (1994). *Statistics for Long-Memory Processes*. Chapman & Hall.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2016). *Time Series Analysis: Forecasting and Control (5th ed.)*. Wiley.
- Bureau of Transportation Statistics (BTS). (2023). *Airline On-Time Performance Data (2019–2023)*. U.S. Department of Transportation. <https://www.transtats.bts.gov/>
- Caporin, M., & Pres, J. (2012). Model selection and forecasting accuracy in ARFIMA models. *Computational Statistics & Data Analysis*, 56(11), 3619–3635.
- Deshpande, V., & Arikan, M. (2012). The Impact of Airline Flight Schedules on Flight Delays. *Manufacturing & Service Operations Management*, 14(3), 423–440. <https://doi.org/10.1287/msom.1120.0379>
- Diebold, F. X., & Inoue, A. (2001). Long memory and regime switching. *Journal of*

- Econometrics*, 105(1), 131–159. [https://doi.org/10.1016/S0304-4076\(01\)00073-2](https://doi.org/10.1016/S0304-4076(01)00073-2)
- Kim, A. M., & Fu, Q. (2016). Supply-and-demand models for exploring relationships between smaller airports and neighboring hub airports in the U.S. *Journal of Air Transport Management*, 52, 67–79. <https://doi.org/10.1016/j.jairtraman.2015.12.008>
- Granger, C. W. J., & Joyeux, R. (1980). An introduction to long-memory time series models and fractional differencing. *Journal of Time Series Analysis*, 1(1), 15–29. <https://doi.org/10.1111/j.1467-9892.1980.tb00297.x>
- Hamilton, J. D. (1994). *Time Series Analysis*. Princeton University Press.
- Hosking, J. R. M. (1981). Fractional differencing. *Biometrika*, 68(1), 165–176. <https://doi.org/10.1093/biomet/68.1.165>
- Jadhav, S., & Deshpande, A. (2018). Hybrid ARIMA–ARFIMA model for long-memory forecasting. *Procedia Computer Science*, 20(10), 334–341.
- Koenker, R., & Xiao, Z. (2004). Unit Root Quantile Autoregression Inference. *Journal of the American Statistical Association*, 99(467), 775–787. <https://doi.org/10.1198/016214504000001114>
- Landry, S. J., Chen, X. W., & Nof, S. Y. (2013). Dynamic taxiway management to reduce runway conflicts. *Journal of Air Transport Management*, 33(1), 42–51.
- Li, Y., & Zhu, Y. (2019). Hybrid ARFIMA-LSTM model for complex time series prediction. *Neurocomputing*, 357(2), 136–146.
- Liu, H., & Chen, C. (2022). Long-memory in transport demand forecasting: Evidence from high-frequency ? Data. *Transportation Research Part E*, 159(1).
- Mendeley Data. (2023). *Arrival Delay Data for Hartsfield–Jackson Atlanta International Airport (ATL)*. Mendeley.Com. <https://data.mendeley.com/datasets/j3zfnxk56h/1>
- Narayan, J., Cats, O., van Oort, N., & Hoogendoorn, S. (2020). Integrated route choice and assignment model for fixed and flexible public transport systems. *Transportation Research Part C: Emerging Technologies*, 115, 102631. <https://doi.org/10.1016/j.trc.2020.102631>
- Palma, W. (2007). *Long-Memory Time Series: Theory and Methods*. Wiley.
- Rambe, R. N. K. (2018). Penerapan Strategi Index Card Match Untuk Meningkatkan Hasil Belajar Siswa Pada Mata Pelajaran Bahasa Indonesia. *Jurnal Tarbiyah : Jurnal Ilmiah Kependidikan*, 25(1), 93–124. <https://doi.org/10.30829/tar.v25i1.237>
- Raza, S., Wang, X., & Lan, Y. (2018). Long-memory time series forecasting in air transport: An application of ARFIMA models. *Journal of Advanced Transportation*, 1(8), 1–10.
- Rebollo, J. J., & Balakrishnan, H. (2014). Characterization and prediction of air traffic delays. *Transportation Research Part C: Emerging Technologies*, 44, 231–241. <https://doi.org/10.1016/j.trc.2014.04.007>
- Ryu, K., & Song, J. (2020). Forecasting air passenger demand using ARFIMA models with structural breaks. *Journal of Air Transport Management*, 89(1).
- Sabzevari, A., & Wang, Z. (2021). Multiscale time series modeling with fractional differencing for traffic delay prediction. *Physica A: Statistical Mechanics and Its Applications*, 22(3).
- Srivastava, A. N. . (2011). Improving Air Traffic Management with a Learning

- Multiagent System. *IEEE Intelligent Systems*, 26(1), 18–21.
<https://doi.org/10.1109/MIS.2009.10>
- Tsay, R. (2005). Analysis of financial time series with long-memory properties. *Journal of Time Series Analysis*, 26(6).
<https://www.scirp.org/reference/referencespapers?referenceid=2848858>
- Tu, Y., Ball, M. O., & Jank, W. S. (2008). Estimating Flight Departure Delay Distributions – A Statistical Approach With Long-Term Trend and Short-Term Pattern. *Journal of the American Statistical Association*, 103(481), 112–125.
<https://doi.org/10.1198/016214507000000257>
- Wu, L., & Law, A. M. (2019). Simulation Analysis on Flight Delay Propagation Under Different Network Configurations. *IEEE Access*, 8, 103236–103244.
<https://doi.org/10.1109/ACCESS.2020.2999098>
- Zhang, G. P., & Qi, M. (2005). Neural network forecasting for seasonal and trend time series. *European Journal of Operational Research*, 160(2), 501–514.
<https://doi.org/10.1016/j.ejor.2003.08.037>
- Zhang, Y., & Chen, Y. (2021). Combining ARFIMA and machine learning models for time series forecasting. *Expert Systems with Applications*, 170(1).