
ANALISIS PERAMALAN CUACA KOTA SURABAYA MENGGUNAKAN PENDEKATAN AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA)

Latisa Alifa Maura^{1*}, Nikmah Handayani², Devina Nadifa Nur Aulia³, M. Al Haris⁴

^{1,2,3,4} Universitas Muhammadiyah Semarang

*e-mail : mauralatisa@gmail.com

Abstract

Erratic weather is a crucial issue that can disrupt activities in all aspects. Weather monitoring needs to be done to avoid adverse consequences. ARIMA is one of the methods that can be used in weather forecasting because it is able to produce high accuracy, especially on short-term data. This research aims to get the best ARIMA model that produces accurate forecasting with the smallest error. Based on the research results, the best models obtained for temperature and humidity variables are (0,0,2) and (1,01) with MAPE values of 2.57% and 6.5%. Thus, the ARIMA model has very accurate forecasting performance

Keywords: ARIMA, Forecasting, Weather, Temperature, Humidity

1. PENDAHULUAN

Cuaca merupakan kondisi dimana perubahan atmosfer dalam jangka waktu yang singkat. Terdapat elemen-elemen penting yang terkandung dalam unsur cuaca yaitu suhu udara, kelembaban udara, tekanan angin, curah hujan, arah angin, tekanan udara, awan, dan kecepatan angin [1], [2]. Pemantauan cuaca adalah hal yang selalu dilakukan di berbagai negara salah satunya Indonesia. BMKG adalah badan yang memiliki tugas untuk memantau perkembangan dan perubahan cuaca di Indonesia. Lembaga pemerintahan ini berfokus pada bidang meteorologi, klimatologi, dan geofisika dengan tugas yang telah diatur pada perundang-undangan. Dengan wilayah Indonesia yang sangat luas, BMKG memiliki banyak cabang stasiun pengamatan cuaca salah satunya di Stasiun Meteorologi Perak 1 Kota Surabaya [3]. Stasiun Meteorologi Perak 1 Surabaya merupakan salah satu stasiun meteorologi yang dimiliki oleh Kota Surabaya yang memiliki fungsi penting dalam memantau cuaca di kota ini.

Surabaya merupakan Ibu kota Provinsi Jawa Timur yang memiliki musim kemarau dengan rentang waktu selama 1,7 bulan dan musim hujan selama 2,7 bulan. Suhu minimal harian rata-rata pada musim kemarau kota ini sebesar 33°C dengan rentang waktu 24 September hingga 16 November. Pada tahun 2023, Surabaya memiliki rata-rata suhu terendah sebesar 34°C dan tertinggi sebesar 25°C. Sedangkan musim hujan berlangsung dari 29 Desember hingga 29 Desember yang memiliki maksimal suhu harian rata-rata sebesar 32°C. Bulan terpanas di Kota Surabaya adalah Oktober dan bulan terdingin adalah Februari [4]. Perubahan cuaca di Surabaya ini menjadikan kota ini rentan terhadap cuaca ekstrem. Hal ini perlu dipertimbangkan terutama oleh Pemerintah setempat apalagi kota ini merupakan pusat ekonomi dan sosial di Jawa Timur.

Bencana akibat cuaca ekstrem seperti banjir, angin kencang, tanah longsor dan gelombang panas merupakan tantangan yang sering dialami masyarakat Surabaya. Dengan tingginya risiko ini, peramalan cuaca sangat krusial dilakukan di lingkup

wilayah Kota Surabaya. Prakiraan atau peramalan cuaca merupakan kegiatan krusial untuk menentukan keputusan yang berkaitan dengan cuaca. Namun, jika terjadi ketidakefektifan dalam kegiatan prakiraan cuaca akan berakibat kerugian dan gangguan dalam aktivitas masyarakat. Dengan demikian, Informasi tentang peramalan cuaca harus tepat waktu dan akurat karena hasil peramalan ini sangat penting dalam keberlangsungan hidup masyarakat dalam berbagai bidang seperti penerbangan, pelayaran atau pertanian [1].

Peramalan yang digunakan untuk mendapatkan informasi tentang cuaca adalah teknik untuk pendugaan nilai pada masa mendatang dengan melihat data saat ini dan masa lalu. Peramalan ini menggunakan model *time series* di mana data historis digunakan karena pengamatan yang dilakukan memiliki urutan waktu [5], [6]. Peramalan ini dilakukan untuk memprediksi suatu nilai di masa mendatang dengan melihat pola deret waktu yang dihasilkan menggunakan data pengamatan sebelumnya dan masa kini. Salah satu metode yang dapat digunakan dalam prediksi *time series* adalah model *Autoregressive Integrated Moving Average* (ARIMA). Metode ini menghasilkan akurasi prediksi yang sangat baik pada peramalan jangka pendek tetapi kurang disarankan melakukan prediksi jangka panjang [7].

Penelitian terdahulu yang memiliki kaitan dengan prediksi atau peramalan yang menggunakan metode ARIMA, salah satunya oleh [7] pada tahun 2018 yang memprediksi cuaca di Kota Surabaya dengan metode ARIMA *Box Jenkins* dan *Kalman Filter*. Penelitian ini menghasilkan model ARIMA untuk variabel suhu dan kecepatan angin adalah ARIMA (1,1,1) dan ARIMA (2,1,10). Nilai *error* terkecil (MAPE) diperoleh sebesar 0.000389 pada variabel kelembaban, 0.000705 pada variabel prediksi suhu, dan 0.0169 pada variabel kecepatan angin. Selanjutnya oleh [8], pada tahun 2023 dengan peramalan curah hujan menggunakan metode ARIMA di daerah Asahan. Penelitian ini menghasilkan model ARIMA (1,1,1) dengan nilai *error* terkecil (MAPE) sebesar 50.195. Peramalan dikatakan cukup akurat pada penelitian ini karena diperoleh nilai akurasi sebesar 50% yang menunjukkan bahwa tingkat kesalahan model ini di atas 10%.

Penelitian ini diadakan dengan sasaran untuk menghasilkan peramalan yang tepat dan terbaik yang bisa digunakan pemerintah Surabaya khususnya di wilayah Pos Hujan Perak I. Hasil peramalan yang didapatkan bisa digunakan untuk melihat potensi bencana akibat perubahan cuaca ke depannya sehingga langkah-langkah pencegahan bisa dilakukan dengan tepat dan cepat [8]. Pencegahan ini dapat mengurangi kerugian dari sisi sosial-ekonomi yang ditimbulkan jika hasil peramalan sesuai dengan realitasnya di masa depan.

2. TINJAUAN PUSTAKA

2.1. ARIMA

Model ARIMA memiliki perbedaan dengan sebagian besar model peramalan karena tidak memperkirakan adanya pola tertentu untuk melakukan prediksi. Pendekatan penggabungan tiga komponen digunakan dalam membangun model ARIMA. Komponen pertama, *autoregressive* memiliki orde p yang mengacu pada korelasi nilai masa lalu dan masa kini. Komponen kedua, *integrated* memiliki orde d yang menunjukkan jumlah prosedur *differencing* yang digunakan untuk mengatasi

ketidakstasioneran data. Komponen ketiga, *moving average* memiliki orde q yang melibatkan residual dari pemodelan di masa lalu. Berikut adalah penjelasan lebih lanjut terkait model-model tersebut [9].

1. Model AR (*Autoregressive*)

Bentuk persamaan model AR dengan orde p dapat dituliskan sebagai berikut.

$$Z_t = \mu + \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + \varepsilon_t \quad (1)$$

Dengan,

μ : konstanta

Φ_k : indikator AR ke- k ; dengan $k = 1, 2, \dots, p$

ε_t : residual ke- t

2. Model MA (*Moving Average*)

Bentuk persamaan model MA orde q dapat dituliskan sebagai berikut.

$$Z_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_p \varepsilon_{t-p} \quad (2)$$

Dengan,

θ_j : indikator MA ke- j ; dengan $j = 1, 2, \dots, q$

3. Model ARMA (*Autoregressive Moving Average*)

Model ARMA adalah kombinasi dari model AR (p) dan model MA (q) yang dituliskan sebagai berikut:

$$Z_t = \mu + \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_p \varepsilon_{t-p} \quad (3)$$

Kemudian, dilakukan proses generalisasi pada model ARMA dengan bertumpu pada konsep differencing yang akan menghasilkan model ARIMA. *Differencing* merupakan proses untuk membuat pengamatan menjadi stasioner. Dengan demikian, persamaan umum model ARIMA (p, d, q) dapat dituliskan sebagai berikut:

$$(1 - \beta \Phi_1 - \beta^2 \Phi_2 - \dots - \beta^p \Phi_p)(1 - B)^d Z_t = \mu - (1 - \beta \theta_1 - \beta^2 \theta_2 - \dots - \beta^q \theta_q) \varepsilon_t \quad (4)$$

2.2. Stasioneritas *Time Series*

Pengasumsian mengenai deret pengamatan yang tidak akan berubah seiring waktu disebut stasioneritas deret waktu. Sehingga bisa dikatakan bahwa data deret waktu dianggap relatif berfluktuasi konstan di sekitar mean [10]. Data yang tidak stasioner ragamnya akan melalui proses transformasi, sedangkan proses *differencing* akan diterapkan saat data tidak stasioner dalam hal mean. Dalam hal mean, uji *Augmented Dickey-Fuller* (ADF) digunakan untuk menguji stasioneritas data [2]. Berikut ini adalah hipotesis Uji ADF:

$H_0: \gamma = 0$ (data tidak stasioner)

$H_1: \gamma < 0$ (data stasioner)

Statistik uji:

$$\tau = \frac{\hat{\gamma} - \gamma}{SE(\hat{\gamma})} \quad (5)$$

Dengan,

$SE(\hat{\gamma})$: kesalahan standar dari $\hat{\gamma}$

$\hat{\gamma}$: penduga metode kuadrat terkecil dari γ

Ketidakstasioneran data observasi dalam hal varians perlu dilakukan transformasi untuk menstabilkan varians. Terdapat banyak metode transformasi yang dapat digunakan untuk mengatasi masalah ini salah satunya adalah *Box-Cox Transformation*. *Box-Cox Transformation* adalah metode transformasi data yang berdasar dari estimasi *maximum likelihood*. Fungsi utama metode ini adalah untuk membuat data yang ditransformasi menjadi atau mendekati distribusi normal [11]. Secara umum, metode ini dapat dirumuskan sebagai berikut.

$$T(Z_t) = \begin{cases} Z_t^\lambda & ; \lambda \neq 0 \\ \frac{Z_t}{\lambda} & ; \lambda = 0 \\ \ln Z_t & ; \lambda = 0 \end{cases} \quad (6)$$

Hasil perhitungan (nilai statistik- t) persamaan 5 dibandingkan dengan nilai kritis DF. Kriteria pengambilan keputusan yang digunakan pada Uji ADF yaitu jika nilai statistik- $t <$ nilai kritis DF, maka H_0 ditolak. Hasil yang diperoleh dapat digunakan sebagai kesimpulan perhitungan Uji ADF.

2.3.ACF dan PACF

Autocorrelation Function (ACF) diterapkan untuk menunjukkan linearitas antara Z_t dan Z_{t+k} atau bisa dikatakan hubungan linieritas antara pengamatan masa kini dan masa lampau dengan representasi plotnya adalah *time series* [10], [12]. Suatu langkah stasioner $[Z_t]$ mempunyai nilai $E(Z_t) = \mu$ sehingga rumus varians yang didapat adalah $\text{Variance}(Z_t) = E(Z_t) - \mu = \sigma^2$, dimana nilai mean dan variansnya selalu konstan [10]. Persamaan umum kovarians dengan korelasi dapat dituliskan sebagai berikut [12]:

$$\rho_k = \frac{\text{Covariance}(Z_t, Z_{t+k})}{\sqrt{\text{variance}(Z_t)}\sqrt{\text{variance}(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (7)$$

Dengan,

γ_k : fungsi autokovarians

ρ_k : fungsi autokorelasi Z_t dan Z_{t+k} yang terpisah oleh lag waktu ke- k

Partial Autocorrelation Function (PACF) memiliki fungsi dalam proses pengukuran tingkat kedekatan hubungan antara Z_t dan Z_{t+k} setelah dampak variabel $Z_{t+1}, Z_{t+2}, Z_{t+3}, \dots, Z_{t+k-1}$ terhadap Z_{t+k} dihilangkan [10]. PACF memiliki korelasi *time series* dengan nilai lag dari PACF itu sendiri dalam urutan waktu tertentu. Persamaan umum autokorelasi parsial dapat dituliskan sebagai berikut.

$$\Phi_{kj} - \Phi_{k+1,k+1}\Phi_{k,k+1-j} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \Phi_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \Phi_{kj} \hat{\rho}_j} \quad (8)$$

2.4.Uji Pendugaan dan Signifikansi Koefisien

Uji signifikansi koefisien adalah metode untuk menduga pengaruh koefisien dalam model ARIMA, sehingga dapat ditemukan variabel mana saja yang berpengaruh pada

Z_t [13]. Pengujian signifikansi koefisien dilakukan melalui uji- t dengan ketentuan sebagai berikut :

1. AR (*Autoregressive*)

Hipotesis:

$H_0 : \phi_p = 0$ (koefisien AR tidak memiliki pengaruh terhadap model ARIMA)

$H_1 : \phi_p \neq 0$ (koefisien AR memiliki pengaruh terhadap model ARIMA)

Statistik uji model AR:

$$t \text{ hitung} = \frac{\widehat{\phi}_p}{se(\widehat{\phi}_p)} \quad (9)$$

2. MA (*Moving Average*)

Hipotesis:

$H_0 : \theta_q = 0$ (koefisien MA tidak memiliki pengaruh terhadap model ARIMA)

$H_1 : \theta_q \neq 0$ (koefisien MA memiliki pengaruh terhadap model ARIMA)

Statistik uji model MA (*Moving Average*) :

$$t \text{ hitung} = \frac{\widehat{\theta}_q}{se(\widehat{\theta}_q)} \quad (10)$$

Daerah penolakan : H_0 ditolak jika $|t\text{-hitung}| > t_{\alpha/2, n-p}$, atau Tolak H_0 jika $P\text{-value} < \alpha$. Dengan α sebagai tingkat signifikansi, p jumlah koefisien AR, q adalah jumlah koefisien MA, dan $se(\widehat{\beta})$ adalah galat baku dari nilai estimasi ϕ atau θ .

2.5. Membandingkan nilai AIC pada model

Analisis lanjutan dengan menggunakan nilai AIC (Akaike Information Criterion) dengan ketentuan memiliki nilai AIC terkecil yang akan dipilih [14]. Metode ini berlandaskan pada metode *maximum likelihood estimation* (MLE) [15]. Pada persamaan 13, dapat dilihat jika $\sum_{t=1}^n e_t^2$ adalah jumlah kuadrat residual (selisih antara nilai aktual dan prediksi), p adalah banyaknya koefisien pada model ARIMA, dan N adalah banyaknya data pengamatan (data *training*). Persamaan umum AIC dapat dilihat sebagai berikut.

$$AIC = \ln\left(\frac{\sum_{t=1}^n e_t^2}{N}\right) + \frac{2p}{N} \quad (11)$$

2.6. Uji diagnostik model

Pengujian diagnostik pada model digunakan untuk mengevaluasi kecocokan dan kelayakan model yang dilakukan dengan dua uji yaitu Uji Ljung Box dan Uji Kolmogorov Smirnov yang dapat dijelaskan sebagai berikut.

1. Uji *Kolmogorov-Smirnov* (Normalitas)

Uji *Kolmogorov-Smirnov* adalah metode yang berfungsi untuk menguji normalitas data. Uji ini menggunakan nilai residual untuk melihat kenormalan data pengamatan. Pada persamaan 13, $F_n(x)$ adalah distribusi frekuensi kumulatif contoh dan $F(x)$ adalah distribusi frekuensi kumulatif empiris. Tolak H_0 jika nilai uji $D < \text{nilai tabel}$ atau $P\text{-value} > \alpha$.

Hipotesis :

H_0 : (nilai residual berdistribusi normal)

H_1 : (nilai residual berdistribusi tidak normal)

Statistik uji :

$$D = \sup_x |F_n(x) - F(x)| \quad (12)$$

2. Uji *Ljung-Box*

Uji *Ljung-Box* adalah metode yang digunakan untuk memeriksa kerandoman data pengamatan [16]. Selain itu, uji ini digunakan untuk menguji independensi pada residual [17]. Proses pengujian uji ini melibatkan nilai pertama dari autokorelasi k . Pemeriksaan dilakukan untuk memeriksa apakah nilainya bernilai 0 (nol) atau tidak [16].

Hipotesis :

H_0 : (tidak terjadi autokorelasi pada nilai residual)

H_1 : (terjadi autokorelasi pada nilai residual)

Statistik uji:

$$Q_{LB} = N(N+2) \sum_{k=1}^K \left(\frac{1}{N-k} \right) r_k^2 \quad (13)$$

Dengan N adalah jumlah observasi data, k adalah lag ke- k , K adalah nilai maksimum dari lag, r_k^2 adalah koefisien autokorelasi antara residual pada lag ke- K . Terima H_0 jika nilai uji $Q_{LB} < \text{nilai } x_{\alpha}^2, k-p-q$. Selain itu, terima H_0 jika nilai probabilitasnya $>$ tingkat signifikansi α .

3. Uji *Breusch-Godfrey*

Uji *Breusch-Godfrey* adalah uji yang digunakan untuk memeriksa autokorelasi antar ketentuan error yang lebih fleksibel. Uji ini mampu mendeteksi autokorelasi pada tingkat yang lebih tinggi [18], [19]. Uji ini juga mampu digunakan baik saat regressornya menyertakan lag maupun tidak. Kriteria keputusan yang diambil adalah tolak H_0 jika P-value $>$ tingkat signifikansi α .

Hipotesis :

H_0 : (tidak terjadi autokorelasi pada nilai residual)

H_1 : (terjadi autokorelasi pada nilai residual)

Statistik uji:

$$(n-p) R^2 \sim X_p^2 \quad (14)$$

2.7. Evaluasi model

Evaluasi model pada data testing dengan menggunakan *Mean Absolute Percentage Error* (MAPE). MAPE dapat mengukur *error* relatif sebagai alat evaluasi ketepatan nilai peramalan pada model terbaik. Hasil perhitungan MAPE dinyatakan dalam persentase dengan membandingkan nilai aktual dan prediksi. Persamaan umum perhitungan nilai MAPE dapat dituliskan sebagai berikut [20], [21]:

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|}{n} \quad (15)$$

Dengan,

y_t : Nilai pengamatan waktu ke- t

$\hat{y}_t$: Nilai dugaan pada waktu ke- t

n : Banyaknya pengamatan

Kinerja model peramalan dievaluasi dengan nilai MAPE dengan asumsi bahwa peramalan semakin baik diiringi dengan persentase nilai MAPE yang semakin kecil. Kriteria kekuatan persentase nilai MAPE untuk evaluasi model terdapat pada Tabel 1.

Tabel 1. Kriteria MAPE

MAPE	Tingkat Kekuatan
< 10%	Sangat Akurat
10% - 20%	Akurat
20% - 50%	Cukup Akurat
> 50%	Lemah/Tidak Akurat

3. METODE PENELITIAN

3.1. Data

Data sekunder digunakan dalam penelitian ini berasal dari satudata.surabaya.go.id yang mencakup 60 data untuk variabel temperatur dan kelembaban selama bulan Januari 2019 hingga Desember 2023 di Pos Hujan Perak 1 Kota Surabaya. Data penelitian ini dipecahkan menjadi dua bagian yaitu data *training* dan data *testing*. Pembagian data *training* dan data *testing* yang digunakan pada sebesar 80% dan 20% atau perbandingan 8:2. Dengan demikian, data *training* terdiri dari 48 data, dimulai dari Januari 2019 hingga Desember 2022 sedangkan data *testing* terdiri dari 12 data, dimulai dari Januari 2023 hingga Desember 2021 [22].

3.2. Langkah Analisis

Berikut ini adalah uraian proses analisis data dengan metode ARIMA.

- 1) Membagi data menjadi dua yaitu data *training* (80%) dan data *testing* (20%).
- 2) Membuat plot pada data *training* yang digunakan untuk mengidentifikasi dan mengeksplorasi pola *time series* data cuaca.
- 3) Membangun model ARIMA untuk identifikasi kestasioneran data.
- 4) Melakukan identifikasi model ARIMA dengan membuat plot ACF dan PACF.
- 5) Melakukan uji pendugaan dan uji signifikansi koefisien.
- 6) Melakukan uji kelayakan model untuk diagnostik model ARIMA.
- 7) Melakukan estimasi model dengan melihat nilai AIC.
- 8) Mengevaluasi model terbaik dengan data *testing* menggunakan nilai MAPE.
- 9) Melakukan peramalan data masa mendatang berdasarkan model ARIMA yang telah dibangun.

4. METODE PENELITIAN


4.1. Eksplorasi dan identifikasi Time Series Data

Pada penelitian ini terdapat dua data yang akan digunakan yaitu data kelembaban dan temperatur. Kedua data ini akan dibagi menjadi data training dan data testing dengan


perbandingan sebesar 8:2 yang bisa dilihat pada gambar 1 dan gambar 2. Statistik deskriptif variabel temperatur data kelembaban terdapat pada Tabel 2.

Tabel 2. Data deskriptif

Variabel	Mean	Min	Max
Temperatur	28,94	27,4	31,2
Kelembaban	73,53	60	83



Gambar 1. Grafik data kelembaban.



Gambar 2. Grafik data temperatur.


4.2. Identifikasi Stasioner Data

Tabel 3. Tabel hasil uji stasioner variabel temperatur dan kelembaban


Variabel	ADF Statistik	<i>Critical Values</i>
Temperatur	-5,58	-2,93
Kelembaban	-4,752	-2,93

Berdasarkan hasil uji pada variabel temperatur, nilai ADF Statistik (-5,58) < nilai *Critical Values* (-2,93). Sedangkan, variabel kelembaban memperoleh nilai ADF Statistik (-4,752) < nilai *Critical Values* (-2,93). Sehingga, dapat disimpulkan bahwa variabel temperatur dan kelembaban adalah stasioner.

4.3. Plot ACF dan PACF



Gambar 3. Plot ACF dan PACF variabel temperatur.



Gambar 4. Plot ACF dan PACF variabel kelembaban.

Kedua variabel temperatur dan kelembaban mendapatkan hasil ordo AR adalah 1 dan ordo MA adalah 2 dengan tidak dilakukan proses *differencing*. Sehingga, model ARIMA yang didapatkan kedua variabel adalah (1, 0, 2).

4.4. Uji Pendugaan dan Uji Signifikansi

Tabel 2 merupakan daftar dugaan sementara koefisien untuk menemukan model ARIMA terbaik.

Tabel 4. Pendugaan koefisien

Variabel	Model ARIMA
Temperatur	ARIMA (0,0,1); ARIMA (0,0,2);
	ARIMA (1,0,1); ARIMA (1,0,0);
	ARIMA (1,0,2);
Kelembaban	ARIMA (0,0,1); ARIMA (0,0,2);
	ARIMA (1,0,1); ARIMA (1,0,0);
	ARIMA (1,0,2);

Tabel 5. Hasil uji signifikansi koefisien

Variabel	Model	Koefisien Signifikan
Temperatur	ARIMA (0,0,1)	Signifikan
	ARIMA (0,0,2)	Signifikan
	ARIMA (1,0,1)	Tidak Signifikan
	ARIMA (1,0,0)	Signifikan
	ARIMA (1,0,2)	Tidak Signifikan
Kelembaban	ARIMA (0,0,1)	Signifikan
	ARIMA (0,0,2)	Tidak Signifikan
	ARIMA (1,0,1)	Signifikan
	ARIMA (1,0,0)	Signifikan
	ARIMA (1,0,2)	Tidak Signifikan

Koefisien dugaan terdapat pada Tabel 4 yang diperoleh dari plot ACF dan PACF kedua variabel yaitu (1,0,2). Selanjutnya, pengujian signifikansi dilakukan dan terdapat 3 model ARIMA yang signifikan pada variabel temperatur yaitu ARIMA (0,0,1), ARIMA (0,0,2), ARIMA (1,0,0). Sedangkan pada variabel kelembaban terdapat 3 model ARIMA yang signifikan yaitu ARIMA (0,0,1), ARIMA (1,0,1), ARIMA (1,0,0).

4.5. Uji Kelayakan Model

Hasil pengujian kelayakan model dengan diagnostik normalitas dan autokorelasi pada kedua variabel dapat dilihat pada Tabel 6. Kedua variabel baik temperatur maupun kelembaban menggunakan Uji *Kolmogorov-Smirnov* untuk deteksi normalitas. Untuk uji autokorelasi variabel temperatur menggunakan Uji *Ljung-Box* sedangkan variabel kelembaban menggunakan Uji *Breusch-Godfrey*. Pengambilan keputusan semua uji kelayakan model menggunakan *P-value* 0,05.

Tabel 6. Hasil uji diagnostik koefisien

Variabel	Model	Uji Autokorelasi	Uji Normalitas	Keterangan
Temperatur	ARIMA (0,0,1)	0,042	0,97	Tidak Lolos
	ARIMA (0,0,2)	0,153	0,77	Lolos
	ARIMA (1,0,0)	0,000	0,73	Tidak Lolos
Kelembaban	ARIMA (0,0,1)	0,001	0,98	Tidak Lolos
	ARIMA (1,0,1)	0,060	0,85	Lolos
	ARIMA (1,0,0)	0,004	0,93	Tidak Lolos

4.6. Estimasi Model

Estimasi model dilakukan untuk memastikan model yang terpilih setelah melewati uji kelayakan model dengan melihat nilai AIC pada Tabel 7. Model terbaik yang didapatkan adalah ARIMA (0,0,2) untuk variabel temperatur dan ARIMA (1,0,1) untuk variabel kelembaban. Hasil ini sesuai dengan model yang terpilih atau lolos pada uji kelayakan model yang mendapatkan nilai AIC terkecil dibandingkan model ARIMA lainnya.

Tabel 7. Hasil uji diagnostik dan nilai AIC

Variabel	Model	Uji Diagnostik	AIC
Temperatur	ARIMA (0,0,1)	Tidak Lolos	103,191
	ARIMA (0,0,2)	Lolos	99,854
	ARIMA (1,0,0)	Tidak Lolos	109,442
Kelembaban	ARIMA (0,0,1)	Tidak Lolos	284,472
	ARIMA (1,0,1)	Lolos	274,689
	ARIMA (1,0,0)	Tidak Lolos	281,035

4.7. Evaluasi Model Terbaik

Model ARIMA terbaik yang didapat pada Tabel 8 dengan variabel temperatur memperoleh MAPE sebesar 2,57%. Sedangkan variabel kelembaban memperoleh MAPE sebesar 2 6,50%. Nilai MAPE ini dikategorikan sangat akurat sesuai pada Tabel 1. Model peramalan variabel temperatur dengan orde (0,0,2) dan variabel kelembaban dengan orde (1,0,1) menghasilkan peramalan yang baik.

Tabel 8. Nilai MAPE model terbaik

Variabel	Model	MAPE
Temperatur	(0,0,2)	2,57%
Kelembaban	(1,0,1)	6,50%

Persamaan matematis yang dibangun oleh model ARIMA variabel temperatur (0,0,2) dapat dilihat pada persamaan 16 dan 17.

$$Z_t = 29,0594 - 0,8233\theta_{t-1} - 0,4175^2\theta_{t-2} + \varepsilon_t \quad (16)$$

Persamaan matematis yang dibangun oleh model ARIMA variabel kelembaban (1,0,1) dapat dituliskan sebagai berikut.



$$Z_t = 73,1167 + 0,5783\phi_{t-1} - 0,5851\theta_{t-1} + \varepsilon_t \quad (17)$$

4.8. Peramalan Model Terbaik

Pada Tabel 9, nilai hasil peramalan pada variabel temperatur memperoleh nilai yang stagnan yang disebabkan data aktual sudah stasioner sehingga hasil peramalan yang didapatkan menjadi stagnan. Pada 12 bulan berikutnya, Kota Surabaya akan mengalami kenaikan temperatur hingga bulan maret 2023 dan stagnan pada angka 28,93 hingga Desember 2023. Sedangkan variabel kelembaban memperoleh hasil yang melandai pada 12 bulan berikutnya terlihat pada Gambar 5. Nilai peramalan pada variabel ini memiliki selisih yang kecil yang juga disebabkan karena data sudah stasioner. Pada 12 bulan berikutnya, Kota Surabaya akan mengalami penurunan kelembaban hingga angka 73,92.

Tabel 9. Nilai hasil peramalan

Data	Variabel	
	Temperatur	Kelembaban
61	28,76	76,80
62	28,91	75,70
63	28,93	75,02
64	28,93	74,60
65	28,93	74,33
66	28,93	74,17
67	28,93	74,07
68	28,93	74,01
69	28,93	73,97
70	28,93	73,94
71	28,93	73,93
72	28,93	73,92



Gambar 5. Visualisasi hasil peramalan.

5. KESIMPULAN

Data temperatur memiliki rata-rata, nilai maksimum dan nilai minimum sebesar 28,94, 27,4, dan 31,2. Sedangkan data kelembaban menghasilkan rata-rata, ilia maksimum, dan nilai minimum sebesar 73,53, 60, dan 83. Hasil analisis model ARIMA terbaik untuk meramalkan temperatur dan kelembaban di Stasiun Perak 1 Surabaya adalah (0,0,2) dan (1,0,1). Kedua model ini memperoleh MAPE sebesar 2,57% dan 6,5%. Peramalan temperatur diperoleh hasil bulan Maret 2023 sebesar 29,3 tetapi bulan selanjutnya angkanya stagnan hingga akhir tahun. Untuk peramalan kelembaban diperoleh nilai tertinggi pada bulan Januari 2023 namun bulan berikutnya terus menurun hingga akhir tahun. Dengan demikian, kedua model ARIMA tersebut memiliki kinerja peramalan yang sangat akurat.

DAFTAR PUSTAKA

- [1] M. I. Qudratullah, Asrizal, and Z. Kamus, "Analisis Unsur – Unsur Cuaca Berdasarkan Hasil Pengukuran Automated Weather System (Aws) Tipe Vaisala Maws 201," *Pillar Phys.*, vol. 9, no. 1, pp. 17–24, 2017.
- [2] R. Soomro *et al.*, "Viable forecasting monthly weather data using time series methods," *Ecol. Quest.*, vol. 34, no. 1, pp. 117–125, 2023, doi: 10.12775/EQ.2023.003.
- [3] M. H. Mubarak *et al.*, "Final Project-SS141501 Forecasting Of Weather In Stasiun Meterologi Klas I Juanda Surabaya Using Arima And Vector Autoregressive (VAR) Methods," 2015.
- [4] Weather Spark, "Iklim dan Cuaca Rata-Rata Sepanjang Tahun di Kota Surabaya," *Weather Spark*, 2023. <https://id.weatherspark.com/y/124626/Cuaca-Rata-rata-pada-bulan-in-Kota-Surabaya-Indonesia-Sepanjang-Tahun>.
- [5] H. F. Ferdy and A. A. Putra, "Peramalan Penjualan Sepeda Motor di PT. Sabena Motor Tahun 2019 Menggunakan Metode ARIMA," *Pros. Semin. Edusainstech FMIPA UNIMUS*, no. 130, pp. 344–353, 2020.
- [6] H. Atman Maulana, "Pemodelan Deret Waktu dan Peramalan Curah Hujan Pada Dua Belas Stasiun Di Bogor," *J. Mat. Stat. dan Komputasi*, vol. 15, no. 1, pp. 50–63, 2018, doi: 10.20956/JMSK.V15I1.4424.
- [7] N. Ulinuha and Y. Farida, "Prediksi Cuaca Kota Surabaya Menggunakan Autoregressive Integrated Moving Average (ARIMA) Box Jenkins dan Kalman Filter," *J. Mat. "MANTIK,"* vol. 4, no. 1, pp. 59–67, 2018, doi: DOI:<https://doi.org/10.15642/mantik.2018.4.1.59-67>.
- [8] I. W. Misshuari, E. Kurniyaningrum, and R. Saily, "Application of Arima Method for Rainfall Forecasting in Asahan Region," *Indones. J. Constr. Eng. Sustain. Dev.*, vol. 6, no. 2, pp. 22–28, 2023, doi: 10.25105/cesd.v6i2.18815.
- [9] P. T. Yamak, L. Yujian, and P. K. Gadosey, "A Comparison Between ARIMA, LSTM, and GRU for Time Series Forecasting," in *ACM International Conference Proceeding Series*, 2019, pp. 49–55, doi: 10.1145/3377713.3377722.
- [10] William W. S. Wei, *Time Series Analysis: Univariate and Multivariate Methods*, 2nd ed. United States of America: Pearson Education Inc, 2006.
- [11] J. Köhler *et al.*, "An agenda for sustainability transitions research: State of the art and future directions," *Environ. Innov. Soc. Transitions*, vol. 31, no. December

- 2018, pp. 1–32, 2019, doi: 10.1016/j.eist.2019.01.004.
- [12] A. Andueza, M. Á. Del Arco-Osuna, B. Fornés, R. González-Crespo, and J. M. Martín-álvarez, “Using the Statistical Machine Learning Models ARIMA and SARIMA to Measure the Impact of Covid-19 on Official Provincial Sales of Cigarettes in Spain,” *Int. J. Interact. Multimed. Artif. Intell.*, vol. 8, no. 1, pp. 73–87, 2023, doi: 10.9781/ijimai.2023.02.010.
 - [13] O. Trisnawati and M. Prastuti, “Peramalan Curah Hujan di Stasiun Juanda Menggunakan Metode ARIMA Box-Jenkins dan Radial Basis Function Neural Network,” *J. Sains dan Seni ITS*, vol. 11, no. 1, 2022, doi: 10.12962/j23373520.v11i1.63165.
 - [14] Y. Zhang and G. Meng, “Simulation of an Adaptive Model Based on AIC and BIC ARIMA Predictions,” in *Journal of Physics: Conference Series*, 2023, vol. 2449, no. 1, doi: 10.1088/1742-6596/2449/1/012027.
 - [15] M. A. Gustiansyah *et al.*, “Aplikasi Model ARIMA dalam Peramalan Data Harga Emas Dunia Tahun 2010-2022,” *J. Stat. dan Apl.*, vol. 7, no. 1, pp. 84–92, 2023, doi: 10.21009/jsa.07108.
 - [16] A. R. Abbasi, M. R. Mahmoudi, and M. M. Arefi, “Transformer Winding Faults Detection Based on Time Series Analysis,” *IEEE Trans. Instrum. Meas.*, vol. 70, 2021, doi: 10.1109/TIM.2021.3076835.
 - [17] L. Wang *et al.*, “Epidemic situation of brucellosis in jinzhou city of china and prediction using the ARIMA Model,” *Can. J. Infect. Dis. Med. Microbiol.*, vol. 2019, 2019, doi: 10.1155/2019/1429462.
 - [18] S. S. Uyanto, “Power comparisons of five most commonly used autocorrelation tests,” *Pakistan J. Stat. Oper. Res.*, vol. 16, no. 1, pp. 119–130, 2020, doi: 10.18187/PJSOR.V16I1.2691.
 - [19] N. Huseynli and Ar, “Econometric Analysis of the Relationship Between Tourism Revenues, Inflation and Economic Growth: The Case of Morocco and South Africa,” *African J. Hosp. Tour. Leis.*, vol. 11, no. 1, pp. 135–146, 2022, doi: 10.46222/ajhtl.19770720.216.
 - [20] Douglas C. Montgomery, C. L. Jennings, and M. Kulahci, *Introduction to Time Series Analysis and Forecasting*. John Wiley & Sons, Inc, 2007.
 - [21] N. H. Hussin, F. Yusof, A. R. Jamaludin, and S. M. Norrulashikin, “Forecasting wind speed in peninsular Malaysia: An application of Arima and Arima-Garch models,” *Pertanika J. Sci. Technol.*, vol. 29, no. 1, pp. 31–58, 2021, doi: 10.47836/pjst.29.1.02.
 - [22] W. H. Lailiyah and D. Manuharawati, “Penerapan Metode Autoregressive Integrated Moving Average (Arima) pada Peramalan Nilai Ekspor Di Indonesia,” *Ilm. Mat.*, vol. 6, no. 3, pp. 45–52, 2018.