

BAB II

STUDI LITERATUR

2.1 Kajian Pustaka

Penelitian terdahulu mengenai peramalan (*forecasting*) menggunakan metode ARIMA dalam berbagai bidang telah dilakukan sebelumnya, untuk itu dalam penelitian tersebut akan digunakan sebagai referensi dan rujukan dalam penelitian ini. Penelitian mengenai peramalan pengguna transportasi kereta api dengan metode ARIMA di Jawa dan Sumatera oleh Bagus W.A tahun 2017. Pada penelitian tersebut data yang digunakan berasal dari data BPS Online dan didapatkan data penumpang transportasi kereta api dari Januari 2010 sampai Desember 2015 dengan 19.376.000 penumpang rata-rata harian di pulau Jawa dan sebanyak 404.780 penumpang di pulau Sumatera. Didapatkan hasil peramalan pengguna transportasi kereta api di pulau Jawa dan Sumatera selama rentang tahun 2017 mendapatkan selang kepercayaan sebesar 95% [5].

Penelitian mengenai tindak kriminalitas yang terjadi di POLRESTA Manado penelitian ini dilakukan oleh Karmelin Mendome dkk tahun 2016 diperoleh model peramalan ARIMA [1,1,0] dengan data bulanan tindak kriminalitas dari bulan Januari 2010 sampai dengan Mei 2016. Menggunakan model peramalan ARIMA ini dilakukan peramalan selama tiga bulan Juni-Agustus 2016 dan didapatkan rentang perbedaan antara hasil aktual dan hasil peramalan sebesar 13,81% [6]. Dengan kata lain akurasi dari peramalan ini sebesar 86,19%.

Kemudian penelitian mengenai analisis prediksi debit sungai Amprong dengan metode ARIMA oleh Wiwin Sri Rahayu dkk tahun 2019. Penelitian mengenai prediksi debit sungai Amprong tersebut dilakukan untuk mengurangi kesalahan dalam pengaturan air irigasi dan penggunaan air irigasi. Data debit air didapatkan dari data debit Bendung Kedungkandang selama 10 periode dari tahun 2008/2009 sampai dengan tahun 2017/2018 yang diperoleh dari UPT PSDA (Unit Pelaksana Daerah Pengelolaan Sumber Daya Air). Pada penelitian ini dilakukan prediksi debit air untuk 10 hari kedepan, model ARIMA dari penelitian ini didapatkan 2 (dua) model ARIMA terbaik [2,0,1] dan [1,2,1] dengan hasil yang tidak terlalu jauh. Dari dua model tersebut didapatkan nilai MAPE = 18,53 [7].

Peramalan menggunakan metode ARIMA dan Holt-Winters's juga pernah dilakukan mengenai hasil produksi ikan oleh Dian Rahman dkk tahun 2018. Penelitian ini menggunakan data sekunder yang didapatkan dari Pangkalan ss

Produksi Ikan (PPI) Kedonganan, Kuta Selatan, Bali. Data yang diambil merupakan data bulanan dari bulan Januari 2011 sampai Februari 2018 di PPI Kedonganan. Dari data tersebut akan dilakukan peramalan untuk 6 (enam) bulan kedepan. Dari kedua metode yang diterapkan untuk peramalan hasil produksi ikan didapatkan hasil MAPE = 0,81% dan RMSE = 89.358 untuk model ARIMA dan untuk model Holt-Winters didapatkan hasil MAPE = 1,14% dan RMSE = 119.158 [8].

Penelitian terkait ARIMA juga pernah dilakukan oleh Agus H. tahun (2018) mengenai frekuensi kemunculan *latchup* pada satelit LAPAN A-1. *Latchup* merupakan fenomena gangguan di sebuah satelit dimana partikel bermuatan berenergi tinggi menumbuk bagian yang sensitif pada mikroelektronik yang menyebabkan kinerja perangkat tersebut mengalami *error*. Data *latchup* didapatkan dari data telemetri. Data telemetri sendiri merupakan kumpulan data-data yang didapatkan satelit, data tersebut merupakan data kondisi satelit seperti temperatur, sistem arus, kecepatan, posisi dan lain-lain. Data telemetri selama 1 (satu) bulan dengan 6803 record dengan 12 atribut digunakan sebagai data untuk penelitian prediksi frekuensi *latchup*. Dari 12 atribut dilakukan pra proses sehingga mendapatkan 3 atribut yang digunakan untuk mendapatkan model ARIMA terbaik untuk melihat frekuensi kemunculan *latchup*. Menggunakan data kemunculan *latchup* 2011 dilakukan prediksi kemunculan *latchup* untuk satu tahun kemudian menggunakan model ARIMA terbaik yang telah didapatkan. Hasil model terbaik didapatkan [4,0,4] dengan nilai RMSE = 0,530 nilai MAE = 0,463 dan nilai MAPE = 9,67 [9].

Tabel 1 Penelitian Terkait

Peneliti	Tahun	Judul	Hasil
Bagus Wicaksono Arianto	2017	Peramalan Jumlah Penumpang Kereta Api Di Pulau Jawa Dan Sumatera Menggunakan Arima Box-Jenkins	Didapatkan hasil peramalan penumpang kereta api di pulau Jawa dan Sumatera selama rentang tahun 2017 dengan selang kepercayaan sebesar 95%
Karmelin Mendome, Nelson	2016	Penerapan Model ARIMA dalam Memprediksi Jumlah	Peramalan selama tiga bulan Juni-Agustus 2016 dan didapatkan rentang

Nainggolan, John Kekenusa		Tindak Kriminalitas di Wilayah POLRESTA Manado Provinsi Sulawesi Utara	perbedaan antara hasil aktual dan hasil peramalan sebesar 13,81%
Wiwin Sri Rahayu, Pitojo Tri Juwono, Widandi Soetopo	2019	Analisis Prediksi Debit Sungai Amprong Dengan Model Arima (Autoregressive Integrated Moving Average) Sebagai Dasar Penyusunan Pola Tata Tanam	Prediksi debit air untuk 10 hari kedepan, model ARIMA dari penelitian ini didapatkan 2 (dua) model ARIMA terbaik [2,0,1] dan [1,2,1] dengan hasil yang tidak terlalu jauh. Dari dua model tersebut didapatkan nilai MAPE = 18,53
Dian Rahman, I Wayan Sumarjaya, I Komang Gde Sukarsa	2018	Perbandingan Peramalan Hasil Produksi Ikan Menggunakan Metode Permulusan Eksponensial Holt-Winters Dan Arima	Peramalan hasil produksi ikan didapatkan hasil MAPE = 0,81% dan RMSE = 89.358 untuk model ARIMA dan untuk model Holt-Winters didapatkan hasil MAPE = 1,14% dan RMSE = 119.158
Agus Herawan	2018	Prediksi Frekuensi Kemunculan Latchup pada Satelit A-1 Menggunakan ARIMA	Hasil model terbaik didapatkan [4,0,4] dengan nilai RMSE = 0,530 nilai MAE = 0,463 dan nilai MAPE = 9,67

2.2 Kejahatan

Peristiwa kejahatan dan perilaku menyimpang sudah tidak asing di kehidupan kita sehari-hari, peristiwa kejahatan ini bisa kita lihat dan dengar melalui media internet, televisi maupun radio. Kejahatan sekarang ini bukan suatu hal yang dihindari atau takuti lagi, cenderung untuk didekati dan digemari [1]. Kejahatan secara etimologis merupakan sebuah perbuatan atau tindakan jahat, di mana suatu perbuatan

dianggap sebagai suatu kejahatan didasarkan pada sifat perbuatan tersebut, di mana perbuatan itu merugikan masyarakat atau perorangan baik secara material maupun secara immateril misalnya mencuri, membunuh, merampok, memperkosa dan lain sebagainya[10]. Kejahatan secara hukum adalah perbuatan melanggar yang telah ditentukan oleh kaidah hukum, melanggar, tidak memenuhi atau melawan perintah-perintah kaidah hukum yang berlaku di dalam masyarakat dimana yang bersangkutan hidup dalam suatu kelompok masyarakat[11].

Menurut Peraturan Kepala Kepolisian Republik Indonesia Nomor 7 Tahun 2009 (PERKAP No 7 Tahun 2009) tentang Sistem Pelaporan Gangguan Keamanan dan Ketertiban Masyarakat disebutkan pada pasal 6 terdapat 5 (lima) Golongan Kejahatan, yakni;

- a. Kejahatan Konvensional
- b. Kejahatan Transnational
- c. Kejahatan Terhadap Kekayaan Negara
- d. Kejahatan Berimplikasi Kontijensi
- e. Pelanggaran Hak Asasi Manusia (HAM)

Penjelasan mengenai golongan kejahatan pada pasal 6 PERKAP No 7 Tahun 2009 sebagaimana yang tertera pada pasal 5 adalah sebagai berikut:

- a. Kejahatan Konvensional/Nasional adalah kejahatan terhadap jiwa, harta benda, dan kehormatan yang menimbulkan kerugian baik fisik maupun psikis baik dilakukan dengan cara-cara biasa maupun dimensi baru, yang terjadi di dalam negeri.
- b. Kejahatan Lintas Batas Negara (*transnational crimes*) adalah kejahatan yang terorganisir, yang wilayah operasinya meliputi beberapa negara, yang berdampak kepada kepentingan politik, pemerintahan, sosial budaya dan ekonomi suatu negara dan bersifat global.
- c. Kejahatan terhadap kekayaan negara adalah kejahatan yang berdampak kepada kerugian negara yang dilakukan oleh perorangan, secara bersama sama,
- d. Kejahatan berimplikasi kontijensi adalah kejahatan yang dapat mengganggu aspek-aspek keamanan, politik, sosial, dan ekonomi serta meresahkan masyarakat yang terjadi secara mendadak dan sulit diprediksi.
- e. Pelanggaran Hak Asasi Manusia adalah setiap perbuatan seseorang atau kelompok orang termasuk aparat negara baik disengaja maupun tidak disengaja, atau kelalaian yang secara melawan hukum mengurangi, menghalangi, membatasi, dan/atau mencabut Hak Asasi Manusia seseorang atau kelompok orang yang dijamin oleh undang-undang, dan tidak akan mendapatkan, atau dikhawatirkan tidak akan memperoleh penyelesaian

hukum yang adil dan benar, berdasarkan mekanisme hukum yang berlaku. dan/atau korporasi (suatu badan).

2.3 Peramalan (Forecasting)

Peramalan merupakan sebuah alat bantu yang digunakan untuk merancang atau mengetahui nilai suatu masa depan berdasarkan nilai historis masa lalu. Data masa lalu digunakan untuk melakukan perhitungan masa depan menggunakan metode peramalan[12].

Model prediksi yang tersedia dapat dikategorikan kedalam 3 kategori utama; yaitu teknik kualitatif, teknik kuantitatif dan teknik jaringan saraf tiruan (*Artificial Neural Network*). Teknik kuantitatif berdasarkan perhitungan matematika seperti *Time Series* atau teknik peramalan kausal. Teknik kausal digunakan untuk mengidentifikasi hubungan antara dependen dan independen variabel. Kualitas tingkat akurasi dari teknik kausal ini bergantung pada akurasi faktor input. Model *time series* mengumpulkan data hasil dari pengamatan selama periode tertentu dan meramal kejadian masa depan berdasarkan data kejadian sebelumnya [13]. Model kausal menguji dan memasukkan variabel-variabel yang diduga akan mempengaruhi variabel dependen, model ini menggunakan analisis regresi untuk menentukan variabel mana yang memungkinkan akan mempengaruhi variabel dependen. Model *time series* merupakan model yang digunakan untuk meramalkan masa depan menggunakan data historis[14].

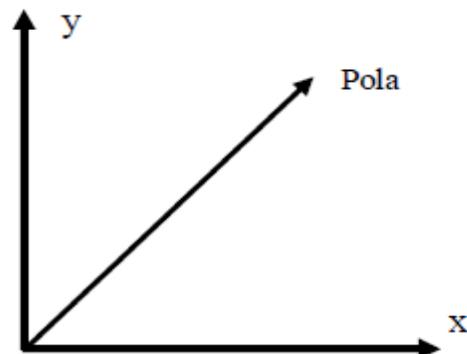
2.4 Time Series

Time series atau deret waktu adalah sekumpulan data hasil pengamatan dengan variabelnya yang diurutkan secara interval dengan kurun waktu tertentu. Data *time series* biasa digunakan dalam melakukan peramalan kejadian yang membutuhkan data lampau sebagai data utamanya.

2.4.1 Pola Time Series

1. Trend

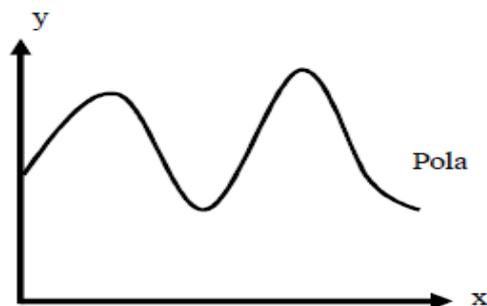
Pola *trend* ini terjadi ketika ada perubahan data baik itu peningkatan atau penurunan jangka panjang dalam data. Kadang-kadang disebut sebagai “perubahan arah” ketika terjadi perubahan data baik meningkat maupun menurun.



Gambar 1 Pola Trend

2. Seasonal

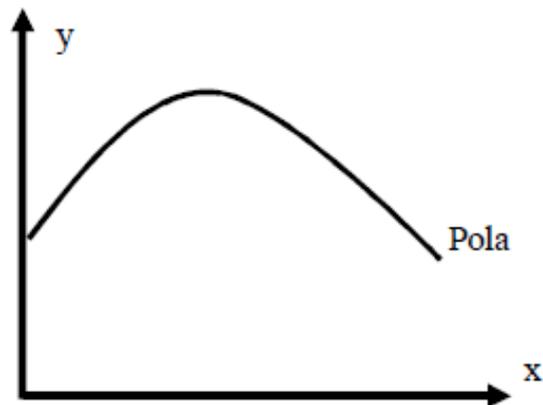
Pola *Seasonal* (Musiman) terjadi ketika dalam rangkaian data waktu dipengaruhi oleh faktor-faktor musiman seperti waktu dalam setahun atau hari dalam seminggu. Frekuensi musiman ini selalu tetap dan diketahui.



Gambar 2 Pola Seasonal

3. Cyclic

Pola *Cyclic* (Siklus) terjadi ketika data dipengaruhi oleh fluktuasi ekonomi jangka panjang yang dapat menyebabkan data naik maupun turun.



Gambar 3 Pola Cyclic

2.4.2 Stasioner dan non-stasioner

Data stasioner merupakan runtut data yang memiliki kecenderungan bergerak menuju rata-rata sehingga tidak ada kenaikan atau penurunan secara ekstrem. Sedangkan non-stasioner merupakan runtut data yang memiliki rata-rata dan varian yang tidak tetap (konstan) di sepanjang runtut waktu.

2.5 Model ARIMA

Model ARIMA (*Autoregressive Integrated Moving Average*) adalah sebuah teknik yang digunakan untuk melakukan peramalan suatu kejadian dalam waktu tertentu [9]. ARIMA dapat melakukan peramalan jangka pendek dengan hasil yang sangat baik, tetapi nilai kepercayaan akan berkurang jika melakukan peramalan dengan jangka panjang[15]. Data minimum yang digunakan untuk model ARIMA idealnya berjumlah 50 data observasi[16]. ARIMA sering juga disebut Box-Jenkins Model. ARIMA merupakan gabungan pemodelan dari *Autoregressive* (AR), *Moving Average* (MA) dan *Autoregressive Moving Average* (*Autoregressive Moving Average* (ARMA)). Model ARIMA dimodelkan dengan (p,d,q) dimana notasi d merupakan banyaknya proses *differencing* untuk menjadikan data stasioner.

2.5.1 Backshift Operator

Backshift operator (B) digunakan untuk meminimalkan penulisan model deret waktu yang terlalu panjang dengan mendefinisikan polinomial untuk setiap modelnya.

$$B^j x_t = x_t - j \quad (2.1)$$

Contoh sebuah persamaan dengan polinomial berikut:

$$C_0 Z_t + C_1 Z_{t-1} + C_2 Z_{t-2} + C_3 Z_{t-3} + C_4 Z_{t-4} + C_5 Z_{t-5} + \dots + C_n Z_{t-n} = e_t \quad (2.2)$$

Dimana model Backshift Operator **B**:

$$C(B) = (1 + C_1 B + C_2 B^2 + \dots + C_n B^n) \quad (2.3)$$

dan dapat kita sederhanakan menggunakan Backshift Operator menjadi:

$$C(B)Z_t = e_t \quad (2.4)$$

2.5.2 AR

Model *Auto Regressive* (AR) merupakan model yang menggambarkan adanya hubungan antara nilai pada waktu sekarang dengan nilai waktu sebelumnya ditambah dengan nilai acak. Fungsi umum persamaan untuk model AR pada orde p atau model ARIMA (p,0,0) [16].

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-p} + a_t \quad (2.5)$$

atau

$$\phi_p(B)\dot{Z}_t = a_t \quad (2.6)$$

dimana:

$$\dot{Z}_t = Z_t - \mu \quad (2.7)$$

dan

$$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p) \quad (2.8)$$

keterangan

Z_t = Nilai aktual waktu ke-t

ϕ_p = Parameter autoregressive ke-p

$a_t = \text{White Noise}$

$\mu = \text{Mean}$

$B = \text{operator Backshift}$

2.5.3 MA

Moving Average (MA) merupakan model yang menjelaskan bahwa suatu fenomena observasi pada waktu t yang dinyatakan sebagai campuran linear dengan penambahan nilai bobot terhadap nilai variabel ke- t . Bentuk umum model MA ordo q atau ARIMA (0, 0, q) [17].

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.9)$$

atau

$$\dot{Z}_t = \theta_q(B) a_t \quad (2.10)$$

dimana

$$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q \quad (2.11)$$

Keterangan

$\theta_q(B)$ = polynomial *moving average* ke- q

B = operator *Backshift*

a_t = *White Noise*

2.5.4 ARMA

Model Autoregressive Moving Average (ARMA) merupakan bentuk model campuran atau gabungan antara model AR (p) dan model MA (q) yang kemudian akan menjadi model ARMA (p, q). Bentuk umum ARMA:

$$\phi_p(B) \dot{Z}_t = \theta_q(B) a_t \quad (2.12)$$

dimana

$$\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p \quad (2.13)$$

dan

$$\theta_p(B) = 1 - \theta_1 B - \dots - \theta_p B^p \quad (2.14)$$

2.6 Tahap Penelitian ARIMA

Guna mendapatkan model ARIMA yang baik dilakukan beberapa tahapan-tahapan untuk mencapai bentuk model terbaik, berikut langkah pencarian model ARIMA:

2.6.1 Identifikasi Model

Identifikasi model adalah sebuah metodologi dalam mengidentifikasi kebutuhan transformasi yang digunakan dalam melakukan pemodelan, seperti transformasi varian dan transformasi *differencing*.

2.6.1.1 Stasioner Time Series

Stasioner Time Series adalah deret waktu yang propertinya tidak bergantung pada waktu yang sedang diamati. Dengan demikian, *time series trend* dan *time series seasonal* tidak stasioner karena terdapat nilai yang mempengaruhi nilai pada suatu waktu[12]. Untuk proses stasioner kondisi mean dan varians yang mana harus konstan [16]. Ketika sebuah data yang akan digunakan belum stasioner maka data harus di stasionerkan menggunakan proses *differencing*, yaitu sebuah cara untuk merubah data yang tidak stasioner menjadi stasioner[12]. *Differencing* dapat digunakan untuk mengurangi time series non stasioner menjadi time series yang stasioner[16]. Tidak semua data non stasioner dapat ditransformasikan ke bentuk stasioner menggunakan *differencing*. Banyak data time series yang stasioner di mean tetapi non stasioner di varians. Transformasi seperti *Box-Cox* digunakan untuk membantu menstabilkan varians dalam time series. Dan *differencing* membantu menstabilkan mean dalam *time series*.

Bentuk umum *differencing*:

$$W_t = Z_t - Z_{t-1} \quad (2.15)$$

dimana

W_t = hasil *differencing*

Z_t = nilai pengamatan ke-t

Z_{t-1} = nilai sebelum pengamatan.

Bentuk umum transformasi Box-Cox:

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda} \quad (2.16)$$

dimana λ adalah parameter transformasi dan memperkirakan nilainya dari data.

Pada proses Box-Cox ini dilakukan pendugaan terhadap λ . Tabel 2 menunjukkan pembagian nilai λ yang sering digunakan.

Tabel 2 Tabel Transformasi

Nilai λ (lambda)	Transformasi
-1.0	$\frac{1}{Z_t}$
-0.5	$\frac{1}{\sqrt{Z_t}}$
0.0	$\ln Z_t$
0.5	$\sqrt{Z_t}$
1.0	Z_t (tidak ada transformasi)

Sumber *Time Series Analysis: Univariate and Multivariate Methods*

2.6.1.2 Autocorrelation Function (ACF)

Autocorrelation Function atau fungsi autokorelasi dalam time series digunakan untuk merepresentasikan korelasi antara Z_t dan Z_{t+k} dari suatu proses yang dipisahkan oleh selang waktu k [16]. ACF juga dapat digunakan untuk mengidentifikasi data *time series* dalam kestasioneran data terhadap mean.

Korelasi antara Z_t dan Z_{t+k}

$$\rho_k = \frac{\text{Cov}(Z_t, Z_{t+k})}{\sqrt{\text{Var}(Z_t)}\sqrt{\text{Var}(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (2.18)$$

2.6.1.3 Partial Autocorrelation Function (PACF)

Partial Autocorrelation Function diperlukan guna memeriksa hubungan antara Z_t dan Z_{t+k} setelah ketergantungan variabel linear $Z_{t+1}, Z_{t+2} \dots Z_{t+k}$ dihapuskan [16].

PACF antara Z_t dan Z_{t+k} :

$$P_k = \frac{\text{Cov}[(Z_t - \hat{Z}_t), (Z_{t+k} - \hat{Z}_{t+k})]}{\sqrt{\text{Var}(Z_t - \hat{Z}_t)}\sqrt{\text{Var}(Z_{t+k} - \hat{Z}_{t+k})}} \quad (2.19)$$

Karakteristik teori ACF dan PACF untuk proses stasioner dapat dilihat di **Tabel 3**

Tabel 3 Karakteristik Proses Stasioner

Proses	ACF	PACF
AR(p)	Penurunan Eksponensial	<i>Cut off</i> setelah lag p
MA(q)	<i>Cut off</i> setelah lag q	Penurunan Eksponensial
ARMA(p, q)	Penurunan lambat setelah lag ($q-p$)	Penurunan lambat setelah lag ($p-q$)

Sumber Time Series Analysis: Univariate and Multivariate Methods [16]

2.6.2 Estimasi Parameter di Time Series

Tahap setelah menentukan model adalah melakukan estimasi parameter. Salah satu metode yang digunakan untuk melakukan estimasi parameter adalah Metode *Least Squares*, pendekatan ini adalah dengan menduga parameter dengan meminimalkan Sum of Squared Error (SSE).

$$Y_t - \mu = \phi(Y_{t-1} - \mu) + e_t \quad (2.20)$$

Setelah melakukan estimasi parameter, langkah selanjutnya adalah melakukan pengujian signifikansi parameter.

Pengujian signifikansi parameter dilakukan untuk mengetahui model parameter yang telah didapatkan telah signifikan atau tidak. Selain itu juga pengujian ini dilakukan untuk mengetahui model parameter tersebut layak masuk kedalam model atau tidak [12]. Menggunakan metode Akaike's Information Criterion (AIC)

$$AIC = -2\log L + 2m \quad (2.20)$$

Dengan menggunakan metode AIC ini apabila hasil perhitungan mendapatkan nilai lebih kecil dari hasil pendugaan parameter maka model dengan nilai AIC terkecil dapat digunakan sebagai pendugaan model yang baik.

2.6.3 Pemeriksaan Asumsi Residual

Pemeriksaan asumsi residual digunakan untuk memilih model yang telah memiliki parameter signifikan. Pemeriksaan asumsi residual ini menggunakan Ljung Box Test.

2.6.3.1 Ljung Box Test

Ljung Box Test adalah pengujian asumsi dimana residual sudah tidak berpola dan acak. Untuk menguji apakah residual memenuhi *white noise* digunakan uji statistik **Ljung Box** dengan menggunakan *null* hipotesis:

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0 \quad (\text{Residual memenuhi syarat } white \text{ noise})$$

Uji statistik:

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2 \quad (2.28)$$

dimana

n = data pengamatan

$\hat{\rho}_k$ = autokorelasi pada lag k

p = komponen AR

q = komponen MA

m = komponen MA

Menggunakan taraf signifikan sebesar $\alpha = 0.05$ maka akan didapatkan daerah penolakan terhadap *null* hipotesis adalah $Q > X^2(K - m)$ atau $P - value < \alpha$.

2.6.4 Pemilihan Model Terbaik

Pemilihan model terbaik dilakukan untuk mendapatkan nilai kesalahan peramalan dari hasil pendugaan model yang telah didapatkan. Dalam hal ini dilakukan pengujian hasil peramalan dengan menggunakan *Root Mean Square Error* (RMSE) [5]. Berikut adalah rumus RMSE:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Z_t - \hat{Z}_t)^2} \quad (2.30)$$

dimana

n : Banyak data observasi

Z_t : Data sebenarnya

\hat{Z}_t : Data hasil peramalan

Selain RMSE dilakukan perhitungan akurasi menggunakan *Mean Absolute Percentage Error* (MAPE). MAPE digunakan untuk mengetahui rata-rata harga mutlak dari persentase kesalahan tiap model [12]. Dengan rumus MAPE sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Z_t - \hat{Z}_t|}{Z_t} \times 100 \quad (2.31)$$

dimana

n : Banyak data observasi

Z_t : Data sebenarnya

\hat{Z}_t : data hasil peramalan