



Nama Formulir:

**Lembar  
Pengesahan  
Karya Ilmiah**

No. FR-003/PR-003/KB-02-  
01/MMP/UPM/2021

Issue/Revisi \_\_\_\_\_

Tgl Berlaku 10 Juli 2021

Halaman \_\_\_\_\_

Yang bertanda tangan di bawah ini:

1. Nama Lengkap Dr. Harry T.Y. Achsan M.Kom  
Jabatan \_\_\_\_\_  
Program Studi \_\_\_\_\_  
NIP 198090005

Telah melakukan penelaahan karya ilmiah berjudul:

Analisis Timeseries Arima Pada Forecasting Mata Uang Dolar Untuk Perhitungan CKPN  
Pada Pelaporan PSAK 71.


Dan menyatakan bahwa karya ilmiah tersebut sudah memenuhi kaidah penulisan ilmiah dan oleh karenanya layak diajukan untuk keperluan unggah karya ilmiah di Universitas Paramadina, atas nama:

Nama Lengkap Husni Melia Rezki  
Jenjang S1  
Program Studi Teknik Informatika  
NIM 119203006

Demikian hasil penelaahan atas karya ilmiah ini dibuat dengan sesungguhnya untuk dapat dipergunakan bilamana diperlukan.

Jakarta, 11 September 2023

Penelaah,

  
NIP: 198090005

# ANALISIS TIMESERIES ARIMA PADA FORECASTING MATA UANG DOLAR UNTUK PERHITUNGAN CKPN PADA PELAPORAN PSAK 71

Husni Melia Rezki

Program Studi Teknik Informatika

Universitas Paramadina

[husni.rezki@students.paramadina.ac.id](mailto:husni.rezki@students.paramadina.ac.id)

*Abstrak*— Penelitian ini membahas tentang Analisis timeseries Arima pada Forecasting mata uang dolar untuk perhitungan CKPN pada pelaporan PSAK71, dimana data ini diperlukan untuk perhitungan komponen CKPN. Saat ini ketersediaan data makro ekonomi terbatas pada data Historical, sementara itu untuk mendapatkan nilai CKPN yang akurat dibutuhkan data forecasting dengan komponen-komponen factor makro ekonomi. Beberapa Bank mendapatkan data forecasting dari data BI maupun sumber yang lain, namun dari pihak Bank kesulitan untuk menemukan sumber data forecasting dengan format timeseries. Sehingga pihak Bank membutuhkan perhitungan menggunakan machine learning dengan model Autoregressive Integrated Moving Average (Arima) untuk ketersediaan data yang akurat.

*Kata kunci*— Forecasting, Arima, CKPN, PSAK71.

## I. PENDAHULUAN

Pernyataan Standar Akutansi Keuangan (PSAK 71) merupakan bagian dari Instrumen Keuangan yang sudah mulai efektif diterapkan oleh perbankan Di Indonesia, PSAK 71 sendiri merupakan perhitungan Cadangan Kerugian Penurunan Nilai (CKPN). Cadangan yang harus dipersiapkan oleh pihak bank, yang berfungsi sebagai bentuk dalam menghadapi risiko kerugian penurunan nilai dari asset, diantaranya nilai asset seperti kredit, bank garansi maupun surat berharga. Setiap dari asset yang terdaftar di perbankan salah satunya asset kredit, memiliki risiko kerugian dalam penurunan nilai. Penurunan nilai ini disebabkan oleh debitur-debitur yang tidak bisa membayar pinjaman sesuai dengan waktu yang sudah di sepakati antara pihak bank dan nasabah.

Metode yang digunakan untuk menghitung CKPN adalah metode *expected credit loss (ECL)*, metode ini bersifat *forwardlooking*, menurut Ikatan Akuntan Indonesia atau disingkat dengan sebutan IAI, metode dari *expected credit loss* ini mewajibkan pihak bank untuk memperkirakan estimasi risiko dari instrumen keuangan sejak awal pengakuan terdaftar di bank. Dan

mengestimasi risiko menggunakan informasi *forwardlooking* seperti memproyeksikan pertumbuhan ekonomi, inflansi, mata uang kurs, suku bunga Bi, tingkat pengangguran harga minyak dan indeks harga komoditas disetiap tanggal pelaporan (Indramawan, 2019).

Merujuk kepada PSAK 71, CKPN pada perbankan dihitung menggunakan dua metode, metode pertama ECL 12-month dan metode ECL lifetime, untuk ECL lifetime perhitungannya dengan menggunakan proyeksi kondisi dari makroekonomi (*forward-looking adjustment*). Bank juga diharuskan memperkirakan *probability weighted* untuk kemungkinan terjadinya sebuah skenario makroekonomi (Indramawan, 2019).

Saat ini ketersediaan data makro ekonomi terbatas pada data Historical, sementara itu untuk mendapatkan nilai CKPN yang akurat dibutuhkan data forecasting dengan komponen-komponen factor makro ekonomi. Beberapa Bank mendapatkan data *forecasting* dari data BI maupun sumber yang lain, namun dari pihak Bank kesulitan untuk menemukan sumber data forecasting dengan format timeseries.

Timeseries adalah suatu metode yang digunakan untuk perencanaan yang lebih efektif dan efisien, timeseries merupakan segala sesuatu yang perlu diamati secara berurutan dari kurung waktu ke waktu dengan interval regular seperti jam, harian, mingguan, bulanan mau pun triwulanan, timeseries menjadi penting saat akan memprediksi sesuatu hal yang berubah dari waktu ke waktu, timeseries sangat membutuhkan data masa lalu salah satunya di data makro ekonomi.

Data Timeseries juga perlu di Analisa, Analisis timeseries merupakan proses yang digunakan untuk mengolah data timeseries, dimana pada tahapan ini akan melibatkan dalam penggunaan data masa lalu untuk membuat model yang akan digunakan sebagai dasar dari model peramalan, dengan analisis dapat mengetahui apa yang meyebabkan terjadinya suatu data trend, yang bisa disebabkan karena sentiment tertentu atau karena factor lain. Dan hal ini yang dapat dijadikan pertimbangan dalam pembuatan keputusan. Sehingga pihak Bank membutuhkan perhitungan menggunakan machine learning dengan model *Autoregressive Integrated Moving Average* (Arima) untuk ketersediaan data yang akurat. Model perhitungan Arima digunakan oleh pihak bank karena dinilai lebih tepat dan akurat dan menjawab kebutuhan data forecasting timeseries makro ekonomi.

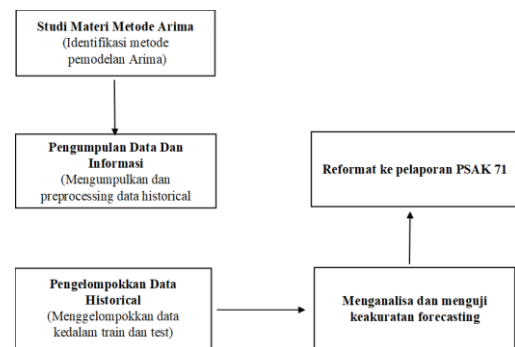
## II. METODE PENELITIAN

Metodologi penelitian dan langkah-langkah yang digunakan dalam penulisan tulisan akhir adalah:

Penelitian ini menggunakan metode penelitian kuantitatif yaitu suatu metode penelitian yang menggunakan data berupa angka untuk kemudian diolah dan dianalisis untuk mendapatkan suatu informasi ilmiah dibalik angka-angka tersebut (Nanang, 2012). Data yang digunakan dalam penelitian ini adalah data berkala (time series).

Tahapan dalam penelitian skripsi ini dilakukan secara berurut disusun secara sistematis dengan tujuan

mendapatkan keterhubungan antara data dan informasi yang diperoleh dengan hasil yang didapat. Secara garis besar diagram alir analisis dapat digambarkan seperti berikut:

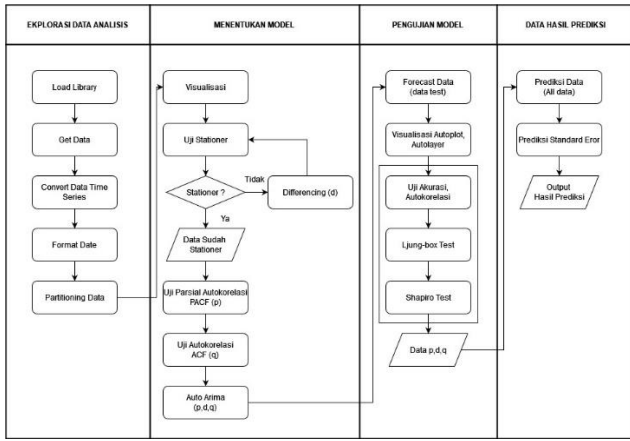


Gambar 2.1 Tahapan Analisis

- a. Studi materi metode arima  
Metode yang digunakan adalah metode penelitian kuantitatif yaitu suatu metode penelitian yang menggunakan data berupa angka untuk kemudian diolah dan dianalisis untuk mendapatkan suatu informasi ilmiah dibalik angka-angka tersebut. Dan mempelajari materi – materi yang terkait dengan model Arima pada Bahasa R.
- b. Pengumpulan data dan Informasi  
Mengumpulkan dan preprocessing data historical masing masing makro ekonomi.
- c. Pengelompokkan data historical  
Mengelompokkan data historical kedalam data *train* dan data *test*.
- d. Menganalisa dan menguji keakuratan hasil forecasting  
Analisa keakuratan data sudah stationer.
- e. Reformat data berdasarkan kebutuhan pelaporan PSAK 71

## III. HASIL DAN PEMBAHASAN

Pembahasan forecasting mata uang dolar dolar tersebut akan dilakukan proses sebagaimana pada flow diagram berikut:



Gambar 3. 1 Flow ARIMA

### 3.1 EKSPOLARASI DATA ANALISIS

Pada tahapam ekspolarsi data analisis ini merupakan proses untuk menyiapkan data sumber sehingga data yang akan digunakan menjadi layak untuk diproses dan dianalisis lebih lanjut, Dalam ekspolarasi data analisis terdapat tahapan preparation yang mana mencakupi pengumpulan data dari berbagai sumber makroekonomi terkait, reformat data dan pelabelan data mentah kedalam bentuk yang cocok sebelum melakukan algoritma forecasting di machine learning.

#### a. Load Library

```
1 #load library
2 library(tseries)
3 library(forecast)
4 library(MLmetrics)
5 library(lmtest)
6 library(xlsx)
7
```

Gambar 3. 2 Load Library

#### b. Get Data

```
##### 1. EKSPLOKASI DATA ANALISIS#####
#get data
allData <- read.csv("D:/PROJEK BANK/BANK GANESA/MAKRO KIKI/kurs.csv", header=TRUE)
allData
summary(allData)
class(allData)
```

Gambar 3. 3 Script R Get Data Kurs

	Posisi	Kurs
1	5/31/2013	9802
2	6/30/2013	9929
3	7/31/2013	10278
4	8/31/2013	10924
5	9/30/2013	11613
6	10/31/2013	11234
7	11/30/2013	11977
8	12/31/2013	12189
9	1/31/2014	12226
10	2/28/2014	11634
11	3/31/2014	11404
12	4/30/2014	11532
13	5/31/2014	11611
14	6/30/2014	11969
15	7/31/2014	11591
16	8/31/2014	11717
17	9/30/2014	12212
18	10/31/2014	12082

Gambar 3. 3 Output Script R Get Data Kurs

#### c. Convert Data ke Time Series

```
15 #convert to time series data
16 tsAllData <- ts(allData[,2], start = c(1,1), frequency = 12)
17 tsAllData
18 summary(tsAllData)
19 class(tsAllData)
```

Gambar 3. 4 Convert Data Kurs

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec
1	9802	9929	10278	10924	11613	11234	11977	12189	12226	11634	11404	11532
2	11611	11969	11591	11717	12212	12082	12196	12440	12625	12863	13084	12937
3	13211	13332	13481	14027	14657	13639	13840	13795	13846	13395	13276	13204
4	13615	13180	13094	13300	12998	13051	13563	13436	13343	13347	13321	13327
5	13321	13319	13323	13351	13492	13572	13514	13548	13413	13707	13756	13877
6	13951	14404	14413	14711	14929	15227	14339	14481	14072	14062	14244	14215
7	14385	14141	14026	14237	14174	14008	14102	13901	13662	14234	16367	15157
8	14733	14302	14653	14554	14918	14690	14128	14105	14084	14229	14572	14453
9	14292	14542	14462	14306	14321	14171	14320	14278	14392	14369	14337	14480
10	14592	14882	14860	14853	15232	15596	15742	15592	14992	15240	14977	14661
11	15003	14943										

```
> summary(tsAllData)
Min. 1st Qu. Median Mean 3rd Qu. Max.
9802 13282 13980 13687 14443 16367
```

Gambar 3. 5 Hasil Convert Data Kurs

#### d. Replace Sequence Data ke Format Date

```
21 #replace sequence to date value
22 tsAllData = ts(tsAllData, start = c(2013, 5), frequency = 12)
23 tsAllData
24 summary(tsAllData)
25 class(tsAllData)
```

Gambar 3. 6 Replace Sequence Data Kurs

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec
2013					9802	9929	10278	10924	11613	11234	11977	12189
2014	12226	11634	11404	11532	11611	11969	11591	11717	12212	12082	12196	12440
2015	12625	12863	13084	12937	13211	13332	13481	14027	14657	13639	13840	13795
2016	13846	13395	13276	13204	13615	13180	13094	13300	12998	13051	13563	13436
2017	13343	13347	13321	13327	13321	13319	13323	13351	13492	13572	13514	13548
2018	13413	13707	13756	13877	13951	14404	14413	14711	14929	15227	14339	14481
2019	14072	14062	14244	14215	14385	14141	14026	14237	14174	14008	14102	13901
2020	13662	14234	16367	15157	14733	14302	14653	14554	14918	14690	14128	14105
2021	14084	14229	14572	14453	14292	14542	14462	14306	14321	14171	14320	14278
2022	14392	14369	14357	14480	14592	14882	14860	14853	15232	15596	15742	15592
2023	14992	15240	14977	14661	15003	14943						

```
> summary(tsAllData)
Min. 1st Qu. Median Mean 3rd Qu. Max.
9802 13282 13980 13687 14443 16367
> class(tsAllData)
[1] "ts"
```

Gambar 3. 7 Hasil Replace Sequence Data Kurs

#### e. Partitioning Data

Membagi data menjadi dua kategori, yaitu kategori data train dan data test.

Data train dan test dibagi menjadi 3 Pengelompokan, yaitu:

### 3.2 Menentukan Model

Menentukan model dimulai dari tahapan untuk

pengecekan visualisasi dan stasioneritas data baik dalam mean maupun vaian, untuk nilai pengujian koefien dengan melihat nilai P-Value  $> \alpha = 0,05$ .

**a. Visualisasi**

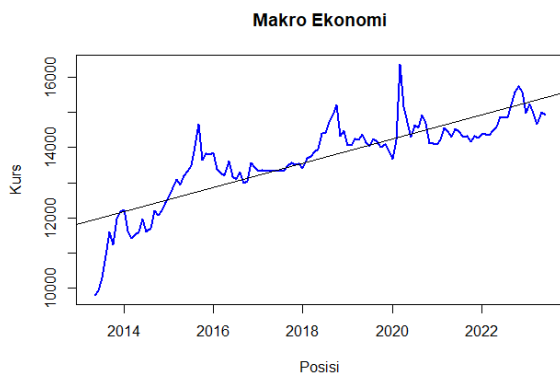
No	Makro Ekonomi	Train/Test	Tanggal Data
1	Kurs	Train 90	31/05/2013 - 30/06/2022
2	Kurs	Test 10	31/07/2022 - 30/06/2023
3	Kurs	Train 80	31/05/2013 - 30/06/2021
4	Kurs	Test 20	31/07/2021 - 30/06/2023
5	Kurs	Train 70	31/05/2013 - 31/05/2020
6	Kurs	Test 30	30/06/2020 - 30/06/2023
7	Inflansi	Train 90	31/01/2009 - 31/12/2021
8	Inflansi	Test 10	31/01/2022 - 31/05/2023
9	Inflansi	Train 80	31/01/2009 - 30/06/2020
10	Inflansi	Test 20	31/07/2020 - 31/05/2023
11	Inflansi	Train 70	31/01/2009 - 31/01/2019
12	Inflansi	Test 30	28/02/2019 - 31/05/2023
13	CPI	Train 90	31/07/2019 - 28/02/2023
14	CPI	Test 10	31/03/2023 - 31/07/2023
15	CPI	Train 80	31/07/2019 - 09/30/2022
16	CPI	Test 20	31/10/2022 - 31/07/2023
17	CPI	Train 70	31/07/2019 - 30/04/2022
18	CPI	Test 30	31/05/2022 - 31/07/2023

**Gambar 3. 8 Visualisasi Data**

Menentukan model arima yang digunakan, dengan melihat stasioneritas data yaitu Stasionarity time series memiliki arti bahwa pada data time series yang kita miliki tidak memiliki trend maupun seasonal dan memiliki variansi konstan. Apabila data yang kita miliki belum stasioner, maka kita bisa melakukan differencing.

```
##### VISUALISASI #####
#step 1 - visualization
#plot & linearity
plot(tsAllData, col="blue", xlab="Posisi", ylab="kurs", main="Makro Ekonomi", lwd=2)
linearModel = lm(tsAllData ~ time(tsAllData))
abline(reg = linearModel) # fit in a Linear Model (Intercept & Slope), and plot the line
```

**Gambar 3. 9 Script Visualisasi Data Kurs Train 90**



**Gambar 3. 10 Kurva Script Visualisasi Data Kurs Train 90**

**b. Uji Stasioner**

Metode yang digunakan adalah *augmented dickey fuller*

```
##### Pengujian Stasioner dan Memeriksa Best Model #####
#step 2 - stationary test
cekadf <- adf.test(tsTrainData)
cekadf
resultcekadf <- ifelse(cekadf$p.value > 0.05, 'not stationary', 'stationary')
head(resultcekadf)
```

**Gambar 3. 11 Uji Stasioner Data Kurs Train 90**

```
Augmented Dickey-Fuller Test
data: tsTrainData
Dickey-Fuller = -2.806, Lag order = 4, p-value = 0.2422
alternative hypothesis: stationary
> resultcekadf <- ifelse(cekadf$p.value > 0.05, 'not stationary', 'stationary')
> head(resultcekadf)
[1] "not stationary"
```

**Gambar 3. 12 Hasil Uji Stasioner Data Kurs Train 90**

Dari hasil tes ADF, apabila data tidak stasioner maka perlu dilakukan differencing untuk mendapatkan data yang stasioner. Stasioner adalah data yang bergerak disekitar rata-rata globalnya.

**c. Differencing**

Menentukan pada differencing ke berapa data menjadi stasioner. Untuk membuat datanya stasioner, cara yang paling umum digunakan adalah dengan melakukan differencing diff, yaitu mengurangi data saat ini dengan data sebelumnya. Terkadang, tergantung pada kompleksitas data, jumlah differencing bisa lebih dari 1 kali.

Ide utama melakukan differencing adalah agar ketika melakukan prediksi, tidak ada multicollinearity terhadap data-data sebelumnya.

```
#if failed then use differencing
diffTsAllData = diff(tsTrainData, differences = 1)
cekadf2 <- adf.test(diffTsAllData)
cekadf2
```

**Gambar 3. 13 Differencing Data Kurs Train 90**

```
Augmented Dickey-Fuller Test
data: diffTsAllData
Dickey-Fuller = -5.7318, Lag order = 4, p-value = 0.01
alternative hypothesis: stationary
```

**Gambar 3. 14 Hasil Differencing Data Kurs Train 90**


Data sudah stasioner di differencing 1 kali. Setelah dilakukan *differencing* data, kemudian dilakukan pengecekan visualisasi setelah data stasioner.

```

70 # visualisasi after stationer
71 plot(diffTsAllData, col="blue", xlab="posisi", ylab="kurs", main="Makro Ekonomi", lwd=2)
72 linearModel = lm(diffTsAllData ~ time(diffTsAllData))
73 abline(reg = linearModel) # fit in a Linear Model (Intercept & Slope), and plot the line
74

```

Gambar 3.15 Visualisasi Differencing Data Kurs Train 90



Gambar 3.16 Hasil Visualisasi Differencing Data Kurs Train 90

Namun hasil visualisasi data setelah differencing 1 masih belum stabil

```

75 #if failed then use differencing
76 diffTsAllData = diff(tsTrainData, differences = 2)
77 cekadf2 <- adf.test(diffTsAllData)
78 cekadf2

```

Gambar 3.17 Visualisasi Differencing 2 Data Kurs Train 90

Augmented Dickey-Fuller Test

```

data: diffTsAllData
Dickey-Fuller = -9.3173, Lag order = 4, p-value = 0.01
alternative hypothesis: stationary

```

Gambar 3.18 Hasil Visualisasi Differencing 2 Data Kurs Train 90

Data BiRate perlu dilakukan differencing 2x hingga data tersebut stasioner. ARIMA(p,d,q) d -> diperoleh dari hasil berapa kali melakukan differencing = 2 Artinya nilai d pada ARIMA(p,d,q) = 2

#### d. Uji Parsial Autokorelasi

Pengujian ini menggunakan metode PACF, dengan keterangan untuk kode ini sebagai berikut:


- p = melihat lag yang keluar dari plot PACF (partial autocorrelation function)
- Parameter AR(p) = 0 dan 1 (hasil uji PACF menunjukkan cut-off pada Lag ke 0 dan 1)

```

79 diffTsAllData %>% tsdisplay()
80 # pacf test, the order form AR - Auto Regressive is 0,1,2 (p param)
81 #pacf(tsTraindata)
82 pacf(diffTsAllData)

```

Gambar 3.19 Uji Parsial Autokorelasi Data Kurs Train 90



Gambar 3.20 Hasil Uji Parsial Autokorelasi Data Kurs Train 90

Keterangan:

- AR(p) = 0,1,2,3,5
- Nilai p pada ARIMA(p,d,q) = 0,1,2,3,5

#### e. Uji Autokorelasi

Metode yang digunakan untuk pengujian autokorelasi ini ialah metode ACF. Dengan keterangan sebagai berikut:


- Parameter MA(q) = 0 (hasil uji ACF menunjukkan cut-off pada Lag ke 0)

```

83 # acf test, the order form MA - Moving Average is 0,1,6,7,8,13,14,15 (q param)
84 acf(tsAllData)
85 acf(diffTsAllData)

```

Gambar 3.21 Uji Autokorelasi Data Kurs Train 90



Gambar 3.22 Hasil Uji Autokorelasi Data Kurs Train 90

Keterangan:

- MA(q): 0,1,2
- Nilai q pada ARIMA(p,d,q) = 0,1,2

#### f. Auto Arima

Auto arima untuk memilih model terbaik, dengan AIC terkecil

```

86 # AUTO ARIMA
87 xarima_model = auto.arima(tsTrainData, start.p = 0, d = 2, start.q = 0, max.p = 5, max.q = 5,
88 seasonal = 0, trace = TRUE, stepwise = FALSE, ic = "aic")
89

```

Gambar 3.23 Auto Arima Data Kurs Train 90

```

ARIMA(0,2,0) : 1676.251
ARIMA(0,2,1) : Inf
ARIMA(0,2,2) : 1596.508
ARIMA(0,2,3) : 1596.472
ARIMA(0,2,4) : 1597.504
ARIMA(0,2,5) : 1598.688
ARIMA(1,2,0) : 1647.406
ARIMA(1,2,1) : Inf
ARIMA(1,2,2) : Inf
ARIMA(1,2,3) : 1597.757
ARIMA(1,2,4) : 1597.978
ARIMA(2,2,0) : 1635.332
ARIMA(2,2,1) : 1597.197
ARIMA(2,2,2) : 1597.904
ARIMA(2,2,3) : 1599.395
ARIMA(3,2,0) : 1619.421
ARIMA(3,2,1) : 1597.215
ARIMA(3,2,2) : 1598.339
ARIMA(4,2,0) : 1617.844
ARIMA(4,2,1) : 1599.086
ARIMA(5,2,0) : 1608.566

```

Best model: ARIMA(0,2,3)

**Gambar 3. 24** Hasil Auto Arima Data Kurs Train 90

Best model Arima dengan AIC terkecil = 0,2,3

### 3.3 Pengujian Model

Pengujian dari model arima yang sudah didapatkan dari proses diatas akan di lihat hasil visualisasi data hasil forecast, melihat akurasi data dan test data hasil forecast.

#### a. Forecast Data

Data yang di forecast adalah data test, Forecast data test menggunakan model terpilih dari auto arima

```

#forecast
length(tsTestData)
arima_forecast <- forecast(xarima_model, h =24)
arima_forecast

```

**Gambar 3. 25** Forecast Data Kurs Train 90

Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jul 2022	14846.94	14363.83	15330.05	14108.09	15585.80
Aug 2022	14835.45	14199.64	15471.27	13863.06	15807.85
Sep 2022	14862.83	14132.37	15593.28	13745.68	15979.97
Oct 2022	14890.20	14071.91	15708.48	13638.74	16141.65
Nov 2022	14917.57	14016.19	15818.95	13539.02	16296.11
Dec 2022	14944.94	13963.90	15925.97	13444.57	16445.30
Jan 2023	14972.31	13914.20	16030.41	13354.07	16590.54
Feb 2023	14999.68	13866.48	16132.87	13266.61	16732.75
Mar 2023	15027.05	13820.31	16233.79	13181.50	16872.60
Apr 2023	15054.42	13775.35	16333.50	13098.24	17010.60
May 2023	15081.79	13731.34	16432.25	13016.45	17147.14
Jun 2023	15109.16	13688.08	16530.25	12935.80	17282.53
Jul 2023	15136.53	13645.40	16627.66	12856.05	17417.02
Aug 2023	15163.90	13603.19	16724.62	12776.99	17550.82
Sep 2023	15191.28	13561.31	16821.24	12698.46	17684.09
Oct 2023	15218.65	13519.69	16917.60	12620.32	17816.97
Nov 2023	15246.02	13478.25	17013.78	12542.45	17949.58
Dec 2023	15273.39	13436.92	17109.86	12464.75	18082.03
Jan 2024	15300.76	13395.64	17205.88	12387.13	18214.39
Feb 2024	15328.13	13354.36	17301.90	12309.51	18346.74
Mar 2024	15355.50	13313.05	17397.95	12231.85	18479.15
Apr 2024	15382.87	13271.67	17494.07	12154.07	18611.67

**Gambar 3. 26** Hasil Forecast Data Kurs Train 90


#### b. Visualisasi menggunakan autoplot dan autolayer

```

# visualisasi menggunakan autoplot dan autolayer
tsTrainData %>%
autoplot()+
autolayer(tsTestData)+
autolayer(arima_forecast$mean)

```

**Gambar 3. 27** Visualisasi Forecast Data Kurs Train 90



**Gambar 3. 28** Hasil Visualisasi Forecast Data Kurs Train 90


#### c. Uji akurasi dan Autokorelasi

```

# uji akurasi
tsTrainData %>%
autoplot()+
autolayer(tsTestData)+
autolayer(arima_forecast$fitted)

```

**Gambar 3. 29** Uji Forecast Data Kurs Train 90




**Gambar 3. 30** Kurva Hasil Uji Forecast Data Kurs Train 90

Melihat hasil uji forecast diatas, dapat disimpulkan dengan Arima pdq= 0,2,3 hasil data jika dikalkulasi dapat dinilai kurs mendekati, karena selisih antara kurva dan warna merah sangat sedikit.

```
plot(arima_forecast)
```

**Gambar 3. 31** Plot Uji Forecast Data Kurs Train 90



**Gambar 3. 32** Hasil Plot ARIMA Forecast Data Kurs Train 90



### Akurasi data train dan test

```
139 # accuracy
140 accuracy(xarima_model$fitted, tsTrainData)
141
142 accuracy(arima_forecast$mean, tsTestData)
143
```

Gambar 3. 33 Akurasi Data Forecast Data Kurs Train 90

```
Test set ME RMSE MAE MPE MAPE ACF1 Theil's U
Test set -61.57854 368.2821 241.8391 -0.5041855 1.780614 -0.02259591 0.9691221
>
> accuracy(arima_forecast$mean, tsTestData)
Test set ME RMSE MAE MPE MAPE ACF1 Theil's U
Test set 179.0553 406.4637 293.793 1.132984 1.908782 0.6306344 1.369438
>|
```

Gambar 3. 34 Hasil Akurasi Data Forecast Data Kurs Train 90

Data train memiliki tingkat eror 1.7, dan data test memiliki tingkat eror 1.9 persen tingkat eror data dilihat dari MAPE. Semakin kecil MAPE maka semakin akurat sebuah model dalam melakukan peramalan. Hal ini berarti sebuah model yang memiliki nilai MAPE sebesar 5% merupakan model yang lebih baik dalam melakukan peramalan dibandingkan model lain yang memiliki MAPE sebesar 10%.

Interpretasi nilai MAPE dapat dilihat dari interval nilainya sebagai berikut.

Nilai MAPE	Interpretasi
≤ 10	Hasil peramalan sangat akurat
10 - 20	Hasil peramalan baik
20 - 50	Hasil peramalan layak (cukup baik)
> 50	Hasil peramalan tidak akurat

Gambar 3. 35 Nilai MAPE Forecast Data Kurs Train 90

### d. Ljung-Box Test

```
# menggunakan Ljung-Box test
Box.test(xarima_model$residuals, type = "Ljung-Box")
#pada Ljung-Box test diatas, p-value > alpha, dimana 0.79 > 0.05 artinya gagal tolak H0,
#artinya residual/eror pada data tidak terdapat autocorrelation
```

Gambar 3. 36 Ljung-Box Test

```
Box-Ljung test
data: xarima_model$residuals
X-squared = 0.057709, df = 1, p-value = 0.8102
```

Gambar 3. 37 Hasil Ljung-Box Test

Pada Ljung-Box Test,  $p\text{-value} > \alpha$ , dimana  $0.81 > 0.05$ . Dengan menggunakan function Ljung-Box didapatkan hasil nilai  $p\text{-value}$  sebesar 0.81, nilai ini  $> \alpha$  yang artinya Terima  $H_0$ , dapat disimpulkan bahwa sisaan model

memenuhi asumsi *white noise* dan model layak digunakan untuk tahap peramalan data.

### e. Shapiro Test

```
153 #shapiro test
154 shapiro.test(xarima_model$residuals)
155 #karena p-value < alpha, dimana 0.01 < 0.05, maka residual tidak berdistribusi normal
156
```

Gambar 3. 38 Shapiro Test

```
shapiro-wilk normality test
data: xarima_model$residuals
W = 0.85125, p-value = 3.943e-09
```

Gambar 3. 39 Hasil Shapiro Test


Hasil  $p\text{-value} < \alpha$ , dimana  $0,00000000394 < 0.05$ , maka residual berdistribusi normal.

### 3.4 Data Hasil Prediksi

#### a. KURS PARTITON 90/10

```
> arima_predict$pred
      Jan      Feb      Mar      Apr      May      Jun      Jul      Aug      Sep
2022 14972.31 14999.68 15027.05 15054.42 15081.79 15109.16 15136.53 15163.90 15191.28
2023 15300.76 15328.13 15355.50 15382.87 15410.24 15437.61 15464.98 15492.35 15519.73
2024 15629.21 15656.58 15683.95 15711.32 15738.69 15766.06 15793.43 15820.81 15848.18
2026 15957.68 15985.03 16012.40 16039.77 16067.14 16094.51
      Oct      Nov      Dec
2022 14890.20 14917.57 14944.94
2023 15218.65 15246.02 15273.39
2024 15547.10 15574.47 15601.84
2025 15875.55 15902.92 15930.29
2026
```

Gambar 3. 40 Data Hasil Prediksi Kurs Train 90



Gambar 3. 41 Kurva Data Hasil Prediksi Kurs Train 90

#### Output Hasil Prediksi

	Point.Forecast	Lo.80	Hi.80	Lo.95	Hi.95
Apr 2024	15382.87153	13271.67247	17494.07059	12154.07119	18611.67186
May 2024	15410.24239	13230.18681	17590.29797	12076.13511	18744.34968
Jun 2024	15437.61325	13188.56927	17686.65723	11997.9973	18877.2292
Jul 2024	15464.98411	13146.79532	17783.17291	11919.6203	19010.34793
Aug 2024	15492.35497	13104.8433	17879.86665	11840.97096	19143.73898
Sep 2024	15519.72583	13062.69404	17976.75763	11762.01997	19277.43169
Oct 2024	15547.09669	13020.33051	18073.86287	11682.74129	19411.45209
Nov 2024	15574.46755	12977.73758	18171.19752	11603.11177	19545.82334
Dec 2024	15601.83841	12934.90175	18268.77508	11523.11076	19680.56607
Jan 2025	15629.20928	12891.81097	18366.60759	11442.71983	19815.69872
Feb 2025	15656.58014	12848.45445	18464.70582	11361.92251	19951.23776
Mar 2025	15683.951	12804.82257	18563.07943	11280.70404	20087.19795
Apr 2025	15711.32186	12760.90668	18661.73704	11199.05122	20223.59249
May 2025	15738.69272	12716.69903	18760.68641	11116.9522	20360.43324
Jun 2025	15766.06358	12672.19267	18859.93449	11034.39635	20497.73081
Jul 2025	15793.43444	12627.38138	18959.4875	10951.37413	20635.49475
Aug 2025	15820.8053	12582.25956	19059.35104	10867.877	20773.7336
Sep 2025	15848.17616	12536.82219	19159.53013	10783.89729	20912.45504
Oct 2025	15875.54702	12491.06478	19260.02927	10699.4281	21051.66595
Nov 2025	15902.91788	12444.98329	19360.85248	10614.46328	21191.37248
Dec 2025	15930.28875	12398.57412	19462.00337	10528.99732	21331.58017
Jan 2026	15957.65961	12351.83404	19563.48517	10443.02529	21472.29392

Gambar 3. 43 Hasil Prediksi Kurs Train 90



#### IV.KESIMPULAN DAN SARAN

##### 4.1 Kesimpulan

Dari tahapan proses memprediksi makro ekonomi untuk perhitungan PSAK71 yang telah dilakukan dapat diambil kesimpulan

1. Sebelum melakukan pengolahan data terlebih dahulu ditentukan format data dan kolom yang diperlukan untuk penyeragaman data, yaitu data yang diambil adalah data perbulan untuk setiap makro ekonomi yang diamati.
2. Penerapan metode arima dalam peneliatian ini menggunakan data Makro ekonomi, Nilai Tukar (Kurs) sebagai data sumber, setiap data di pecah menjadi Train/ Test 90/10, 80/20 dan 70/30. Untuk kemuadian diolah mencari parameter pdq.
3. Nilai pdq pada ARIMA dilakukan uji Ljung-Box dan Shapiro test untuk menilai kelayakan hasil dari
4. masing-masing model, setelah itu masing masing nilai pdq akan digunakan untuk memprediksi data makroekonomi, dan dipilih untuk masing-masing makro satu nilai pdq yang paling akurat, ditandai dengan nilai MAPE yang paling mendekati 0. Yaitu:  
Kurs : p,d,q = 0,2,3 dengan MAPE = 1,7

##### 4.2 Saran

1. Data makroekonomi yang digunakan untuk prediksi menggunakan metode ARIMA disarankan memiliki datahistorical yang cukup, untuk mrndapatkan hasil prediksi yang lebih akurat.
2. Keakuratan hasil prediksi dengan ARIMA akan bagus jika digunakan untuk memprediksi data dalam jangka pendek.

#### REFERENSI

- [1] Box, G. E. P., Jenkins G. M., dan Reinsel G. C., Time Series Analysis, Prentice Hall, Englewood Cliffs, 1994.
- [2] Halim. 2006. Diktat Time Series. Universitas Kristen Petra. Surabaya.
- [3] Hendrawan,Bambang. 2012. “Penerapan Model ARIMA Dalam Memprediksi IHSG”. Politeknik Batam. Jurnal. Diakses pada 25 Februari 2023.  
<https://jurnal.polibatam.ac.id/index.php/JI/article/view/231>
- [4] Indramawan, Dendy. 2019. Implementasi PSAK 71 Pada Perbankan. Jakarta: IBI
- [5] Makridarkis, S., & Wheelwright, S. (1999). “Metode dan Aplikasi Peramalan Edisi ke-2”. Diterjemahkan oleh Untung Sus Andriyanto dan Abdul Basith. Jakarta: Erlangga.
- [6] *Makridakis, S. et al. (1998). Forecasting: Methods and Applications. Third edition. New York: Jhon Wiley & sons, inc.*
- [7] Purnomo, Febi Setya. 2015. “Penggunaan Metode Arima (Autoregressiveintegrated Moving Average) Untuk Prakiraan Beban Konsumsi Listrik Jangka Pendek (Short Term Forecasting)”. Universitas Negeri Semarang.
- [8] Sarvina, Yeli. 2017. “Pemanfaatan Software Open Source “R” Untuk Penelitian Agroklimat”. Jurnal. Diakses Pada 26 Februari 2023.  
<https://media.neliti.com/media/publications/178397-ID-none.pdf>
- [9] Spiegel, M. R., & Stephens, L. J. (1999). “Statistik”. Diterjemahkan Oleh Wiwit Kastawan dan Irzam Harmein. Jakarta: Erlangga
- [10] Sundara, Vinny Yuliani, dkk. 2020. Pemograman R dasar. Jambi. Forum Pemuda Aswaja.  
[https://bookdown.org/moh\\_rosidi2610/Metode\\_Numerik/intro.html](https://bookdown.org/moh_rosidi2610/Metode_Numerik/intro.html)

