



TUGAS AKHIR - SS 141501

PERAMALAN JUMLAH PERMINTAAN PIPA HOLLOW GALVALUM DI PT. SPINDO, Tbk

TRI AGUNG WIDIYANTO
NRP 1314 105 034

Dosen Pembimbing
Irhamah, M.Si, Ph.D
Dr. Kartika Fitriyasari, M.Si

PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2017



TUGAS AKHIR - SS 141501

PERAMALAN JUMLAH PERMINTAAN PIPA HOLLOW GALVALUM DI PT. SPINDO, Tbk

TRI AGUNG WIDIYANTO
NRP 1314 105 034

Dosen Pembimbing
Irhamah, M.Si, Ph.D
Dr. Kartika Fitriasari, M.Si

PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2017



FINAL PROJECT - SS 141501

FORECASTING THE TOTAL DEMAND OF HOLLOW GALVALUM PIPE IN PT. SPINDO, Tbk

TRI AGUNG WIDIYANTO
NRP 1314 105 034

Supervisor
Irhamah, M.Si, Ph.D
Dr. Kartika Fitriasari, M.Si

Undergraduate Programme
Departement of Statistics
Faculty of Mathematics and Natural Sciences
Institut Teknologi Sepuluh Nopember
Surabaya 2017

LEMBAR PENGESAHAN

PERAMALAN JUMLAH PERMINTAAN PIPA HOLLOW GALVALUM DI PT. SPINDO, Tbk

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada

Program Studi Sarjana Departemen Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

Oleh :

TRI AGUNG WIDIYANTO
NRP.1314 105 034

Disetujui oleh Pembimbing:

Irfamah, M.Si, Ph.D

NIP. 19780406 200112 2 002

(*Irfamah*)

Dr. Kartika Fitriyani, M.Si

NIP. 19691212 199303 2 002

(*Kartika Fitriyani*)

Mengetahui,
Kepala Departemen



PERAMALAN JUMLAH PERMINTAAN PIPA HOLLOW GALVALUM DI PT. SPINDO, Tbk

Nama Mahasiswa : Tri Agung Widiyanto
NRP : 1314 105 034
Departemen : Statistika FMIPA-ITS
Dosen Pembimbing 1 : Irhamah, M.Si, Ph.D
Dosen Pembimbing 2 : Dr. Kartika Fitriyasari, M.Si

Abstrak

PT. Steel Pipe Industry Of Indonesia, Tbk (PT. SPINDO, Tbk) adalah produsen pipa baja dengan kapasitas produksi terbesar di Indonesia dan berpengalaman dalam memproduksi berbagai macam pipa baja/tabung dan berbagai produk terkait lainnya. Pada tahun 2014, PT. SPINDO, Tbk mendirikan pabrik baru di Sidoarjo yang khusus dibentuk untuk memproduksi pipa hollow galvalum. Agar dapat bersaing dengan pesaing lainnya, maka pabrik baru ini harus menyediakan stok yang mencukupi sesuai dengan permintaan pasar. Oleh sebab itu, diperlukan suatu model yang mampu memberi informasi tentang jumlah permintaan pipa hollow galvalum di masa yang akan datang. Model yang digunakan adalah model ARIMA, Moving Average, dan Regresi Time Series. Data yang digunakan untuk meramalkan adalah data jumlah permintaan pipa hollow galvalum dari bulan Januari 2012 sampai bulan Desember 2016. Metode peramalan terbaik untuk pipa hollow galvalum A dan B menggunakan metode Moving Average dengan length 7 sedangkan peramalan jumlah permintaan untuk pipa hollow galvalum C menggunakan model ARIMA (2,1,0) dan D menggunakan model ARIMA ([2,3],0,[3]).

Kata Kunci : *ARIMA, Peramalan, Pipa, Regresi Time Series, Moving Average.*

Halaman ini sengaja dikosongkan

FORECASTING THE TOTAL DEMAND OF HOLLOW GALVALUM PIPE IN PT. SPINDO, Tbk.

Student Name : Tri Agung Widiyanto
Student Number : 1314 105 034
Departement : Statistics FMIPA-ITS
Supervisor 1 : Irhamah, M.Si, Ph.D
Supervisor 2 : Dr. Kartika Fitriasaki, M.Si

Abstract

PT. Steel Pipe Industry of Indonesia, Tbk (PT SPINDO Tbk) is a manufacturer of steel pipe with the largest production capacity in Indonesia and experienced in producing various kinds of steel pipes/tubes and a variety of other related products. In the year 2014, PT SPINDO Tbk. established a new factory in Sidoarjo specially formed to manufacture pipe hollow galvalum. In order to compete with other competitors, then the new plant must provide sufficient stock in accordance with market demand. Therefore, it required a model that able to give information on the total demand of hollow galvalum pipe in the future. The model used is a ARIMA model, Moving Average, and Time Series Regression. The data used for prediction is the total demand of hollow galvalum pipe from January 2012 to December 2016. The best forecasting method for pipe hollow galvalum A and B is Moving Average with a length 7 while forecasting the total demand of hollow galvalum pipe C using ARIMA model (2, 1, 0) and D using ARIMA model ([2,3], 0, [3]).

Keyword : ARIMA, Peramalan, Pipe, Regresi Time Series, Moving Average.

Page is Blank

KATA PENGANTAR

Assalamu'alaikum Warahmatullah Wabarokatuh.

Puji syukur alhamdulillah senantiasa penulis panjatkan kehadiran Allah SWT yang telah melimpahkan rahmat, hidayah dan karunia-Nya sehingga penulis dapat menyelesaikan Tugas Akhir yang berjudul **“Peramalan Jumlah Permintaan Pipa Hollow Galvalum di PT. SPINDO,Tbk”** dengan lancar dan tepat waktu.

Keberhasilan penyusunan Tugas Akhir ini tidak lepas dari partisipasi berbagai pihak yang telah banyak membantu. Oleh karena itu,penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Irhamah, M.Si, Ph.D dan Dr. Kartika Fitriasari, M.Si selaku dosen pembimbing atas semua bimbingan, waktu, semangat, perhatian, dan kesabaran yang telah diberikan sehingga Tugas Akhir ini dapat diselesaikan dengan baik.
2. Dra. Wiwiek Setya Winahju, MS dan Dr. Bambang Wijanarko Otok, M.Si selaku tim penguji yang telah memberikan saran-saran membangun untuk kesempurnaan Tugas Akhir ini.
3. Dr. Suhartono, M.Si selaku Ketua Jurusan Statistika ITS dan Dr. Sutikno, S.Si., M.Si selaku Ketua Prodi S1 Statistika yang telah memfasilitas penulis selama menuntut ilmu di Jurusan Statistika ITS.
4. Dr. Puhadi, M.Sc selaku Dosen wali Penulis, seluruh dosen, dan karyawan Statistika ITS atas ilmu dan pengalaman yang telah diberikan kepada penulis.
5. PT. Steel Pipe Industry of Indonesia (SPINDO),Tbk Unit VI yang bersedia memberikan data sehingga dapat memperlancar keberlangsungan tugas akhir penulis.
6. Ibunda Abilaksita Wida Wardani, kakak penulis Aditya Hidayat Jati dan Wahyuni Kusuma Wardani yang selalu memberikan semangat, bantuan financial, dan mendoakan penulis pada saat kuliah hingga lulus.

7. Teman-teman satu angkatan dan teman-teman satu kantor terima kasih atas dukungannya.
8. Semua pihak yang telah membantu penulis yang tidak dapat disebutkan satu persatu.

Semoga kebaikan dan bantuan yang telah diberikan kepada penulis dibalas dengan kebaikan yang lebih oleh Allah SWT. Amin.

Penulis menyadari bahwa Tugas Akhir ini masih terdapat kekurangan, oleh karena itu kritik dan saran yang bersifat membangun sangat diharapkan. Semoga Tugas Akhir ini dapat memberikan manfaat baik bagi penulis, pembaca, dan semua pihak.

Wassalamu'alaikum Warahmatullah Wabarokatuh.

Surabaya, Juli 2017

Penulis

DAFTAR ISI

	Halaman
JUDUL	i
LEMBAR PENGESAHAN	iii
ABSTRAK	v
ABSTRACT	vii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR GAMBAR	xv
DAFTAR TABEL	xvii
DAFTAR LAMPIRAN	xxi
BAB I PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	3
1.3 Tujuan Penelitian	4
1.4 Manfaat Penelitian	4
1.5 Batasan Masalah Penelitian	4
BAB II TINJAUAN PUSTAKA	
2.1 Analisis Deret Berkala (<i>Time series</i>).....	5
2.2 Stasioneritas <i>Time series</i>	5
2.3 Identifikasi <i>Time series</i>	8
2.4 Model-model ARIMA	9
2.5 Identifikasi Model ARIMA	12
2.6 Estimasi dan Uji Signifikansi Parameter	12
2.7 Cek Diagnosa	15
2.8 Pemilihan Model Terbaik	16
2.9 Metode <i>Moving average</i>	17
2.10 Metode Regresi <i>Time series</i>	18
BAB III METODOLOGI PENELITIAN	
3.1 Sumber Data dan Variabel Penelitian.....	21
3.2 Metode Analisis Data	21
3.3 Diagram Alir.....	23

BAB IV ANALISIS DATA DAN PEMBAHASAN

4.1	Statistika Deskriptif	27
4.2	Pemodelan Jumlah Permintaan Pipa Hollow Galvalum A dengan menggunakan ARIMA	28
4.2.1	Identifikasi Model Permintaan Pipa Galvalum A	29
4.2.2	Estimasi Parameter pada Jumlah Permintaan Pipa Galvalum A	33
4.2.3	Cek Diagnosa Residual Jumlah Permintaan Pipa Galvalum A	33
4.2.4	Pemilihan Model Terbaik Jumlah Permintaan Pipa Galvalum A Dengan Menggunakan Metode ARIMA	35
4.3	Pemodelan Jumlah Permintaan Pipa Hollow Galvalum A Menggunakan Metode Single <i>Moving average</i>	36
4.4	Pemodelan Jumlah Permintaan Pipa Hollow Galvalum A Menggunakan Metode Regresi <i>Time series</i>	37
4.4.1	Estimasi dan Signifikansi Parameter pada Jumlah Permintaan Pipa Hollow Galvalum A dengan Regresi <i>Time series</i>	38
4.4.2	Pengujian Asumsi Residual Data Jumlah Permintaan Pipa Galvalum A	39
4.5	Peramalan Jumlah Permintaan Pipa Galvalum A Dengan Menggunakan Metode Terbaik.....	40
4.6	Pemodelan Jumlah Permintaan Pipa Hollow Galvalum B dengan menggunakan ARIMA	41
4.6.1	Identifikasi Model Permintaan Pipa Galvalum B.....	42
4.6.2	Estimasi Parameter pada Jumlah Permintaan Pipa Galvalum B	45
4.6.3	Cek Diagnosa Residual Jumlah Permintaan Pipa Galvalum B	46

4.6.4	Pemilihan Model Terbaik Jumlah Permintaan Pipa Galvalum B Dengan Menggunakan Metode ARIMA	47
4.7	Pemodelan Jumlah Permintaan Pipa Hollow Galvalum B Menggunakan Metode <i>Moving average</i>	48
4.8	Pemodelan Jumlah Permintaan Pipa Hollow Galvalum B Menggunakan Metode Regresi <i>Time series</i>	49
4.8.1	Estimasi dan Signifikansi Parameter pada Jumlah Permintaan Pipa Hollow Galvalum B dengan Regresi <i>Time series</i>	50
4.8.2	Pengujian Asumsi Residual Data Jumlah Permintaan Pipa Galvalum B	51
4.9	Peramalan Jumlah Permintaan Pipa Galvalum B Dengan Menggunakan Metode Terbaik.....	52
4.10	Pemodelan Jumlah Permintaan Pipa Hollow Galvalum C dengan menggunakan ARIMA	53
4.10.1	Identifikasi Model Permintaan Pipa Galvalum C.....	53
4.10.2	Estimasi Parameter pada Jumlah Permintaan Pipa Galvalum C	57
4.10.3	Cek Diagnosa Residual Jumlah Permintaan Pipa Galvalum C	58
4.10.4	Pemilihan Model Terbaik Jumlah Permintaan Pipa Galvalum C Dengan Menggunakan Metode ARIMA	59
4.11	Peramalan Jumlah Permintaan Pipa Hollow Galvalum C Menggunakan Metode <i>Moving average</i>	60
4.12	Pemodelan Jumlah Permintaan Pipa Hollow Galvalum C Menggunakan Metode Regresi <i>Time series</i>	62
4.12.1	Estimasi dan Signifikansi Parameter pada Jumlah Permintaan Pipa Hollow	

Galvalum C dengan Regresi <i>Time series</i>	62
4.12.2 Pengujian Asumsi Residual Data Jumlah Permintaan Pipa Galvalum C	63
4.13 Peramalan Jumlah Permintaan Pipa Galvalum C Dengan Menggunakan Metode Terbaik.....	64
4.14Pemodelan Jumlah Permintaan Pipa Hollow Galvalum D dengan menggunakan ARIMA	65
4.14.1 Identifikasi Model Permintaan Pipa Galvalum D	66
4.14.2 Estimasi Parameter pada Jumlah Permintaan Pipa Galvalum D	69
4.14.3 Cek Diagnosa Residual Jumlah Permintaan Pipa Galvalum D	70
4.14.4 Pemilihan Model Terbaik Jumlah Permintaan Pipa Galvalum D Dengan Menggunakan Metode ARIMA	71
4.15Peramalan Jumlah Permintaan Pipa Hollow Galvalum D Menggunakan Metode <i>Moving average</i>	72
4.16Pemodelan Jumlah Permintaan Pipa Hollow Galvalum D Menggunakan Metode Regresi <i>Time series</i>	74
4.16.1 Estimasi dan Signifikansi Parameter pada Jumlah Permintaan Pipa Hollow Galvalum D dengan Regresi <i>Time series</i>	74
4.16.2 Pengujian Asumsi Residual Data Jumlah Permintaan Pipa Galvalum B	75
4.17Peramalan Jumlah Permintaan Pipa Galvalum D Dengan Menggunakan Metode Terbaik.....	76
BAB V KESIMPULAN	
5.1 Kesimpulan	79
5.2 Saran	79
DAFTAR PUSTAKA	81
LAMPIRAN	83

DAFTAR GAMBAR

	Halaman
Gambar 3.1	<i>Flow Chart</i> Metode ARIMA Box – Jenkins 23
Gambar 3.2	<i>Flow Chart</i> Metode <i>Moving Average</i> 24
Gambar 3.3	<i>Flow Chart</i> Metode Regresi <i>Time Series</i> 25
Gambar 4.1	<i>Box Plot</i> Jumlah Permintaan Pipa Hollow Galvalum 28
Gambar 4.2	<i>Time Series Plot</i> Pipa Galvalum A 29
Gambar 4.3	Hasil Transformasi Box Cox Pipa Galvalum A . 30
Gambar 4.4	Hasil Transformasi Box Cox Setelah Transformasi Akar Kuadrat Untuk Pipa Galvalum A 31
Gambar 4.5	Plot ACF Permintaan Pipa Galvalum A..... 31
Gambar 4.6	Plot PACF Jumlah Permintaan Pipa Galvalum A 32
Gambar 4.7	Hasil Analisis <i>Moving Average</i> pada Pipa Galvalum 37
Gambar 4.8	Distribusi Normal Residual Pipa Galvalum A 40
Gambar 4.9	<i>Time Series Plot</i> Pipa Galvalum B 42
Gambar 4.10	Hasil Transformasi box cox pipa Galvalum B 43
Gambar 4.11	Hasil Transformasi Box Cox pada permintaan Pipa Galvalum B yang ditransformasi Akar Pangkat 4 43
Gambar 4.12	Plot ACF Permintaan pipa galvalum B 44
Gambar 4.13	Plot PACF Jumlah Permintaan Pipa Galvalum B 45
Gambar 4.14	Hasil Analisis <i>Moving Average</i> pada Pipa Galvalum B 49
Gambar 4.15	Distribusi Normal Residual Pipa Galvalum B..... 52
Gambar 4.16	<i>Time Series Plot</i> Pipa Galvalum Ukuran C 54
Gambar 4.17	Hasil Transformasi Box Cox pipa Galvalum C... 54
Gambar 4.18	Hasil Transformasi Box Cox permintaan Pipa Galvalum C yang ditransformasi

	akar pangkat 4	55
Gambar 4.19	Plot ACF Jumlah Permintaan pipa galvalum C ..	55
Gambar 4.20	Plot ACF Permintaan Pipa Galvalum C setelah Dfferencing.....	55
Gambar 4.21	Plot PACF Jumlah Permintaan Pipa Galvalum C	57
Gambar 4.22	Hasil Analisis MA pada Pipa Galvalum C	61
Gambar 4.23	Distribusi Normal Residual Pipa Galvalum C.....	64
Gambar 4.24	<i>Time Series</i> Plot Pipa Galvalum D	66
Gambar 4.25	Hasil Transformasi Box Cox pipa Galvalum D ..	67
Gambar 4.26	Hasil Transformasi Box Cox pada permintaan Pipa Galvalum D yang ditransformasi akar pangkat 4	67
Gambar 4.27	Plot ACF Permintaan Pipa Galvalum D.....	68
Gambar 4.28	Plot PACF Permintaan Pipa Galvalum D.....	69
Gambar 4.29	Hasil Analisis MA pada Pipa Galvalum D.....	73
Gambar 4.30	Distribusi Normal Residual Pipa Galvalum D	76

DAFTAR TABEL

	Halaman
Tabel 2.1	Transformasi Box-Cox..... 8
Tabel 2.2	Struktur ACF dan PACF..... 12
Tabel 4.1	Statistika Deskriptif Data Jumlah Permintaan Pipa Hollow Galvalum..... 27
Tabel 4.2	Pengujian Parameter Jumlah Permintaan Pipa Galvalum A..... 33
Tabel 4.3	Uji <i>White Noise</i> jumlah permintaan pipa Galvalum A..... 34
Tabel 4.4	Uji Kenormalan Residual Jumlah Permintaan Pipa Galvalum A..... 32
Tabel 4.5	Pemilihan Model Terbaik untuk Jumlah permintaan Pipa Galvalum A berdasarkan In Sampel..... 35
Tabel 4.6	Pemilihan Model Terbaik untuk Jumlah permintaan Pipa Galvalum A berdasarkan Out Sampel..... 36
Tabel 4.7	Pemilihan Length Terbaik Metode MA pada Pipa Galvalum A..... 37
Tabel 4.8	Pengujian Parameter Data Jumlah Permintaan Pipa Hollow Galvalum A Dengan Regresi <i>Time Series</i> 38
Tabel 4.9	Uji Glejser Data Jumlah Permintaan Pipa Galvalum A..... 39
Tabel 4.10	Perbandingan Metode ARIMA, <i>Moving Average</i> , Regresi <i>Time Series</i> pada Jumlah Permintaan Pipa Galvalum A..... 41
Tabel 4.11	Hasil Ramalan Pipa Hollow Galvalum A..... 41
Tabel 4.12	Pengujian Parameter Jumlah Permintaan pipa galvalum B..... 45
Tabel 4.13	Uji <i>White Noise</i> Data jumlah permintaan pipa galvalum B..... 46
Tabel 4.14	Uji Kenormalan Residual Jumlah Permintaan

	Pipa Galvalum B	47
Tabel 4.15	Pemilihan Model Terbaik Jumlah permintaan Pipa Galvalum B berdasarkan In Sampel	47
Tabel 4.16	Pemilihan Model Terbaik Untuk Pipa Galvalum ukuran B berdasarkan Out Sampel.....	48
Tabel 4.17	Pemilihan Length Terbaik Metode MA pada Jumlah Permintaan Pipa Galvalum B	49
Tabel 4.18	Pengujian Parameter Data Jumlah Permintaan Pipa Hollow Galvalum B Dengan Regresi <i>Time Series</i>	50
Tabel 4.19	Uji Glejser Data Permintaan Pipa Galvalum B.....	51
Tabel 4.20	Perbandingan Metode ARIMA, <i>Moving Average</i> , dan Regresi <i>Time Series</i> pada Jumlah Permintaan Pipa Galvalum B	52
Tabel 4.21	Hasil Ramalan Pipa Hollow galvalum B	53
Tabel 4.22	Pengujian Parameter Jumlah Permintaan Pipa Galvalum C	58
Tabel 4.23	Uji <i>White Noise</i> Data Jumlah Permintaan Pipa Galvalum C	58
Tabel 4.24	Uji Kenormalan Residual Data Jumlah Permintaan Pipa Galvalum C	59
Tabel 4.25	Pemilihan Model Terbaik untuk Jumlah permintaan Pipa Galvalum C berdasarkan In Sampel	59
Tabel 4.26	Pemilihan Model Terbaik Jumlah permintaan Pipa Galvalum C berdasarkan Out Sampel	60
Tabel 4.27	Pemilihan Length Terbaik Metode MA pada Jumlah Permintaan Pipa Galvalum C	61
Tabel 4.28	Pengujian Parameter Data Jumlah Permintaan Pipa Hollow Galvalum C Dengan Regresi <i>Time Series</i>	62
Tabel 4.29	Uji Glejser Data Permintaan Pipa Galvalum C.....	63
Tabel 4.30	Perbandingan Metode ARIMA <i>Moving Average</i> , dan Regresi <i>Time Series</i> pada Jumlah	

	Permintaan Pipa Galvalum C	65
Tabel 4.31	Hasil Ramalan Pipa Galvalum C	65
Tabel 4.32	Pengujian Parameter Jumlah Permintaan Pipa Galvalum D.....	69
Tabel 4.33	Uji <i>White Noise</i> Data jumlah permintaan pipa galvalum D.....	70
Tabel 4.34	Uji Kenormalan Residual Data Jumlah Permintaan Pipa Galvalum D.....	71
Tabel 4.35	Pemilihan Model Terbaik untuk Jumlah permintaan Pipa Galvalum D berdasarkan In Sampel	71
Tabel 4.36	Pemilihan Model Terbaik untuk Jumlah permintaan Pipa Galvalum D berdasarkan Out Sampel	72
Tabel 4.37	Pemilihan Length Terbaik Metode <i>Moving Average</i> pada Jumlah Permintaan Pipa Galvalum D	73
Tabel 4.38	Pengujian Parameter Data Jumlah Permintaan Pipa Hollow Galvalum D Dengan Regresi <i>Time Series</i>	74
Tabel 4.39	Uji Glejser Data Permintaan Pipa Galvalum D.....	75
Tabel 4.40	Perbandingan Metode ARIMA, <i>Moving Average</i> , dan Regresi <i>Time Series</i> pada Jumlah Permintaan Pipa Galvalum D.....	76
Tabel 4.41	Hasil Ramalan Pipa Galvalum D	77

Halaman ini sengaja dikosongkan

DAFTAR LAMPIRAN

	Halaman
Lampiran A	Data Jumlah Permintaan Pipa Galvalum A 83
Lampiran B	Data Jumlah Permintaan Pipa Galvalum B 83
Lampiran C	Data Jumlah Permintaan Pipa Galvalum C 84
Lampiran D	Data Jumlah Permintaan Pipa Galvalum D 84
Lampiran E	Output SAS ARIMA 85
Lampiran F	Output Minitab Regresi <i>Time Series</i> 89

Halaman ini sengaja dikosongkan

BAB I

PENDAHULUAN

1.1 Latar Belakang

Pertumbuhan sektor pembangunan properti di Indonesia akan ditentukan oleh ketersediaan bahan bakunya. Ada banyak bahan baku yang dibutuhkan untuk mendukung berbagai program pembangunan itu salah satunya adalah pipa baja, dimana penggunaan pipa tersebut semakin meningkat seiring dengan meningkatnya pembangunan konstruksi di berbagai sektor. Banyak perusahaan yang bersaing pada industri pipa baja, salah satu perusahaan ternama yang melayani kebutuhan pelanggan adalah PT. Steel Pipe Industry of Indonesia, Tbk (PT. SPINDO, Tbk).

PT. SPINDO, Tbk adalah produsen pipa baja dengan kapasitas produksi terbesar di Indonesia dan berpengalaman dalam memproduksi berbagai macam pipa baja/tabung dan berbagai produk terkait lainnya. Didirikan pada tahun 1971 dengan kantor pusat di jalan kalibutih 189-191 Surabaya. Jaminan mutu produk selalu dilakukan perusahaan melalui penerapan suatu program sistem evaluasi mutu yang ketat dan selaras, hal itu dibuktikan dengan telah diterimanya sertifikat internasional ISO 9002 dan API 5L. Sesuai dengan persyaratan mutu internasional PT. SPINDO, Tbk memenuhi standar ASTM, BS, JIS, ISO, AS, dan SNI. Basis pelanggan perseroan meliputi perusahaan domestik Indonesia dan perusahaan-perusahaan multinasional yang beroperasi di Indonesia seperti Total, Chevron, Honda, dan Yamaha, serta perusahaan internasional seperti J Steel Australia Pty, LTd. Saat ini perseroan memiliki 6 fasilitas manufaktur di Indonesia, dengan memiliki total 37 lini produksi yang masing-masing dapat dikalibrasikan untuk menghasilkan berbagai jenis pipa. Berbagai jenis pipa yang diproduksi oleh PT. SPINDO, Tbk adalah pipa hitam, pipa galvanis drat/non drat, pipa stainless, pipa

spiral, pipa hollow galvalum, dan berbagai pipa perabot lainnya (SPINDO, 2015).

Meskipun PT. SPINDO, Tbk terbilang cukup memiliki nama besar, namun masih banyak perusahaan lain yang bersaing ketat untuk merebut pasar dibidang industri pipa baja. Oleh sebab itu, selain dituntut untuk meningkatkan kualitas dari pipa yang telah di produksi, PT. SPINDO, Tbk juga harus menyiapkan strategi untuk memuaskan pelanggan, yaitu dengan meningkatkan layanan pengiriman yang cepat dan sesuai dengan waktu yang telah ditargetkan, Sehingga perusahaan mencoba membuat stok untuk ukuran pipa yang sering dipesan oleh customer. Salah satu jenis pipa yang dirubah strategi produksinya dari *make to order* (produksi setelah ada pemesanan) menjadi *make to stock* (Produk untuk stok) adalah pipa hollow galvalum. Perubahan strategi ini dimaksudkan karena pada tahun 2014, PT. SPINDO, Tbk membangun pabrik baru yaitu unit 6 di jalan pahlawan cemengkalang No.10 Sidoarjo yang khusus untuk menangani produksi pipa hollow galvalum dan pipa perabot lainnya. Pembangunan unit tersebut dirasa perlu karena di jadwal produksi di unit runkut terlalu padat sehingga permintaan pipa perabot hanya diproduksi setelah ada pesanan saja (*Make to order*), padahal untuk jenis pipa hollow galvalum cukup diminati dan banyak permintaan sehingga perlu unit khusus yang menyanggupi permintaan tersebut. Pipa hollow galvalum termasuk pipa yang tahan karat, namun rentan pesok dan mengalami *white rush* jika terlalu lama disimpan digudang. Oleh sebab itu, dibutuhkan peramalan yang tepat agar stok yang ada digudang cepat terkirim ke customer dan bahan baku yang disediakan akan cukup memadai sesuai dengan permintaan pelanggan.

Beberapa penelitian sebelumnya yang berkaitan dengan model peramalan dengan menggunakan metode ARIMA dan model variasi kalender, penelitian yang dilakukan Perdana (2010) mencoba membandingkan regresi *time series* dengan ARIMAX untuk meramalkan data penjualan pakaian di Boyolali, didapatkan hasil bahwa model regresi *time series* dengan variabel dummy

efek variasi kalender memiliki RMSE yang lebih kecil dibandingkan ARIMAX. Penelitian lainnya Cahyaningtyas (2014), melakukan peramalan penjualan motor dari setiap kategori dengan menggunakan metode ARIMAX dan Regresi *time series*, hasil yang didapat adalah untuk motor bebek honda lebih tepat menggunakan model ARIMAX, sedangkan motor matic honda lebih tepat menggunakan regresi *time series*. Penelitian dari Prihandono (2015) mengenai penjualan pipa PT. Bakrie & Brother menggunakan metode ARIMA dan didapatkan hasil ramalannya merupakan model yang musiman

Pipa yang akan diramalkan adalah pipa galvalum yang laris dipasaran. Pipa tersebut diramalkan dengan menggunakan metode ARIMA *Box-Jenkins*, *Moving Average*, dan Regresi *Time Series*. Setelah didapatkan model terbaik dari setiap metode, lalu model dari setiap metode dibandingkan untuk mendapatkan model terbaik dari pipa galvalum yang akan diramalkan.

1.2 Rumusan Masalah

Rumusan masalah yang akan dibahas dalam tugas akhir ini adalah meramalkan jumlah permintaan pipa hollow galvalum yang bergerak naik dan turun secara fluktuatif. Karena pergerakan yang berfluktuatif dan memiliki kenaikan dan penurunan di bulan-bulan tertentu maka peramalan yang digunakan dalam tugas akhir ini adalah metode ARIMA *Box – Jenkins*. Karena data yang didapatkan tidak terlalu banyak (periode 5 tahun), maka pipa tersebut diramalkan dengan metode *Moving Average*. Karena ada dugaan bahwa data dari setiap bulannya memiliki pola tren dan konstan secara terus menerus, maka data juga diramalkan dengan menggunakan metode regresi *time series*. Dari ketiga metode itu dipilih nilai MSE, RMSE dan SMAPE yang lebih kecil sebagai model terbaik yang akan digunakan untuk ramalan 12 periode kedepan pada permintaan pipa sebagai dasar pembelian bahan baku, perencanaan jadwal produksi, dan penataan produk yang sudah jadi didalam gudang.

1.3 Tujuan Penelitian

Tujuan dalam penelitian ini adalah :

1. Mendeskripsikan hasil eksplorasi data jumlah permintaan pipa hollow galvalum dari 4 ukuran produk.
2. Memperoleh model *time series* terbaik untuk jumlah permintaan pipa hollow galvalum dengan metode *time series* dengan menggunakan metode ARIMA *Box-Jenkins*, *Moving Average*, dan Regresi *Time Series* pada setiap ukuran pipa yang laris dipasaran.
3. Memperoleh ramalan 12 periode kedepan dari model terbaik yang telah diperoleh.

1.4 Manfaat Penelitian

Berdasarkan tujuan yang telah dijelaskan, maka manfaat yang dapat diambil dari laporan ini yaitu dengan mengetahui hasil ramalan dari permintaan pipa hollow galvalum, maka dapat memperhitungkan total bahan baku yang diperlukan untuk memproduksi pipa.

1.5 Batasan Penelitian

Batasan masalah dalam penelitian ini adalah pipa hollow galvalum yang akan dibuatkan model peramalan adalah 4 jenis pipa kotak ukuran 35 X 35 mm dengan tebal 0,6 mm sampai tebal 0,9 mm dan panjang 6 meter.

BAB II TINJAUAN PUSTAKA

2.1 Analisis Deret Berkala (*Time series*)

Time series adalah serangkaian pengamatan terhadap suatu variabel yang diambil dari waktu ke waktu, dan dicatat secara berurutan menurut kejadiannya, dengan interval waktu yang tetap (Cryer, 1986). Time series dapat dipandang sebagai suatu rangkaian variabel yang diamati pada interval ruang waktu yang sama ditunjukkan sebagai deret berkala. Secara umum deret berkala pada $t_1, t_2, t_3, \dots, t_i, \dots, t_n$ dari pengamatan $Z_{t1}, Z_{t2}, Z_{t3}, \dots, Z_{ti}, \dots, Z_{tn}$ dapat dinyatakan sebagai fungsi distribusi $F(Z_{t1}, Z_{t2}, Z_{t3}, \dots, Z_{ti}, \dots, Z_{tn})$. (Makridakis, Wheelwright, & Mc Gee, 1999).

2.2 Stasioneritas *Time series*

Suatu data *time series* Z_t bersifat stationer dalam *mean* dan *varians*, maka *mean* dan *varians*nya tidak dipengaruhi oleh waktu pengamatan, dengan demikian:

Mean dari Z_t :

$$E(Z_t) = E(Z_{t+k}) = \mu \quad (2.1)$$

Varians dari Z_t :

$$E(Z_t - \mu)^2 = E(Z_{t+k} - \mu)^2 = \sigma^2 \quad (2.2)$$

Autokovarians = kovarians antara Z_t dan Z_{t+k}

$$\text{Cov}(Z_t, Z_{t+k}) = E[(Z_t - \mu)(Z_{t+k} - \mu)] = \gamma_k \quad (2.3)$$

pada sembarang nilai t dan k .

Pada kasus nyata, banyak ditemui data *time series* yang tidak stasioner. Baik tidak stasioner dalam *mean* maupun *varians*. Untuk mengatasi tidak stasioneran pada suatu data dapat dilakukan pembedaan atau dengan suatu transformasi. Pembedaan (*differencing*) dilakukan jika ada data yang tidak stasioner terhadap *mean*, sedangkan transformasi *Box-cox* dilakukan jika data tidak stasioner terhadap *varians* (Cryer, 1986).

Deret waktu yang tidak stasioner dalam *mean*, berarti ketika datanya diplotkan terhadap sumbu waktu (t) maka series data membentuk trend tertentu terhadap garis sumbu waktu (t). Untuk memastikan adanya suatu trend stokastik pada data series Z_t , digunakan indikator sebagai berikut (Makridakis, Wheelwright, & Mc Gee, 1999):

1. Pola *Autocorrelation Function* (ACF) suatu *time series* Z_t menurun secara lambat (*decays very slowly*), sedangkan pola *Partial Autocorrelation Function* (PACF) terpotong pada *lag* satu (*cut off after lag 1*).
2. *Mean level* yang berubah dalam arah tertentu.
3. Parameter model dari *series* Z_t , tidak memenuhi syarat kestasioneran.

Untuk menguji kestasioneran data terhadap mean dapat dilakukan pengujian *Augmented Dickey Fuller*. Konsep pengujian *Augmented Dickey Fuller Test* adalah jika suatu data *time series* tidak stasioner pada orde nol, $I(0)$, maka stasioneritas data tersebut bisa dicari melalui order berikutnya sehingga diperoleh tingkat stasioneritas pada order ke- n (*first difference*) atau $I(1)$, atau *second difference* atau $I(2)$, dan seterusnya (Purnomo, 2010). Sebelum melakukan uji ADF, perlu memperhatikan plot data yang akan diuji. Jika data mengandung unsur tren, maka digunakan uji ADF tipe tren, dan jika data tidak mengandung unsur tren, dapat diselidiki apakah rata-ratanya sama dengan nol. Jika rata-ratanya tidak sama dengan nol, maka digunakan uji ADF tipe konstanta, dan jika rata-ratanya sama dengan nol, menggunakan uji ADF tipe *null*. Misalkan diberi persamaan regresi berikut :

$$\Delta Z_t = \beta_1 + \beta_2 t + \delta Z_{t-1} + \gamma_i \sum_{i=1}^m \Delta Z_{t-i} + \varepsilon_t \quad (2.4)$$

dimana:

ΔZ_t = *first difference* dari Z

β_1 = nilai konstan atau *intercept*

$\beta_2 t$ = koefisien regresi untuk trend

δ = koefisien regresi untuk *lag* Z

γ = koefisien regresi untuk *difference lagZ*
 ε = *error*
 m = lag
 t = waktu

dengan hipotesis :

$H_0 : \delta = 0$ (Terdapat akar unit, variabel Z tidak stasioner)

$H_1 : \delta \neq 0$ Tidak terdapat akar unit, variabel Z stasioner).

Statistik uji:

$$t_{\hat{\delta}} = \frac{\hat{\delta} - \delta_0}{se(\hat{\delta})} \quad (2.5)$$

Jika $t_{\hat{\delta}}$ lebih besar dari nilai kritis ADF maka gagal tolak hipotesis nol, yang berarti terdapat akar unit (data tidak stasioner). Dan jika $t_{\hat{\delta}}$ lebih kecil dari nilai kritis ADF maka tolak hipotesis nol, tidak terdapat akar unit (data stasioner).

Cara yang dilakukan untuk mengatasi kondisi non-stasioner dalam *mean* adalah dengan melakukan pembedaan (*differencing*) terhadap datanya dengan persamaan berikut (Cryer, 1986) :

$$W_t = Z_t - Z_{t-1} \quad (2.6)$$

dimana W_t merupakan nilai series Z_t setelah dilakukan pembedaan atau *differencing*. Secara umum *differencing* dapat dinyatakan sebagai berikut :

$$W_t = (1 - B)^d Z_t \quad (2.7)$$

keterangan :

d : orde *differencing*

B : operator langkah mundur ($BZ_t = Z_{t-1}$)

Z_t : variabel *time series* pada waktu ke- t

Suatu deret waktu Z_t dikatakan tidak stasioner terhadap *varians*, apabila Z_t berubah sejalan dengan perubahan level $\text{var}(Z_t) = cf(\mu_t)$, dimana c merupakan konstanta. Box dan Cox memberikan suatu ide transformasi terhadap *varians* yang tidak konstan dengan menggunakan *power transformation* sebagai berikut (Wei, 2006) :

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda}, \text{ dimana } \lambda \neq 0 \quad (2.8)$$

λ adalah parameter transformasi, untuk $\lambda = 0$ dilakukan pendekatan berikut :

$$\lim_{\lambda \rightarrow 0} T(Z_t) = \lim_{\lambda \rightarrow 0} Z_t^{(\lambda)} = \lim_{\lambda \rightarrow 0} \frac{Z_t^\lambda - 1}{\lambda} = \ln(Z_t) \quad (2.9)$$

Secara umum nilai λ (lamda) dan transformasi yang digunakan sebagai berikut :

Tabel 2.1 Transformasi Box - Cox

Estimasi λ	Transformasi
-1,0	$1/Z_t$
-0,5	$1/\sqrt{Z_t}$
0	$\text{Ln } Z_t$
0,5	$\sqrt{Z_t}$
1,0	Z_t (tidak ada transformasi)

Sumber : (Wei, 2006)

2.3 Identifikasi Model *Time Series*

Model *Time series* dapat diidentifikasi melalui *Time series Plot*, Fungsi autokorelasi, dan Fungsi autokorelasi parsial.

Time series plot adalah *Scatter plot* antara nilai variabel terhadap sumbu waktu (t). Salah satu kegunaan *time series plot* adalah untuk memeriksa pola dan kestasioneran data, dalam hal ini apabila *time series plot* menunjukkan tidak ada perubahan *mean* terhadap waktu, maka dikatakan telah stasioner terhadap *mean*, dan apabila tidak ada perubahan *varians* terhadap waktu, maka dapat dikatakan telah stasioner terhadap *varians*.

Fungsi autokorelasi (*Autocorrelation Function* = ACF) adalah suatu representasi dari autokorelasi antara Z_t dan Z_{t+k} dari proses yang sama yang hanya terpisah k lag waktu. Dengan mengambil sampel dari populasi maka ACF dapat dihitung dengan persamaan sebagai berikut :

$$\rho_k = \frac{\text{Cov}(Z_t, Z_{t+k})}{\sqrt{\text{Var}(Z_t)}\sqrt{\text{Var}(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (2.10)$$

$k = 0, 1, 2, \dots, K$ ($K < n$) (Wei, 2006).

Standart eror untuk ρ_k adalah :

$$S_{\rho_k} = \sqrt{\frac{1}{n}(1 + 2\rho_1^2 + \dots + 2\rho_m^2)}. \quad (2.11)$$

Besaran statistik lain yang digunakan pada analisis *time series* adalah fungsi Autokorelasi Parsial (*Partial Autocorrelation Function* = PACF). PACF antara Z_t dan Z_{t+k} secara umum akan sama dengan autokorelasi antara $(Z_t - \hat{Z}_t)$ dan $(Z_{t+k} - \hat{Z}_{t+k})$. Oleh karena itu PACF antara Z_t dan Z_{t+k} adalah sebagai berikut (Wei, 2006) :

$$P_k = \frac{\text{cov}[(Z_t - \hat{Z}_t), (Z_{t+k} - \hat{Z}_{t+k})]}{\sqrt{\text{var}(Z_t - \hat{Z}_t)}\sqrt{\text{var}(Z_{t+k} - \hat{Z}_{t+k})}} \quad (2.12)$$

$$\hat{Z}_t = \alpha_1 Z_{t-1} + \alpha_2 Z_{t-2} + \dots + \alpha_k Z_{t-k-1}$$

keterangan :

P_k : *Partial Autocorrelation Function* (PACF)

Z_t : Nilai *time series* pada waktu ke- t

Z_{t+k} : Nilai *time series* pada waktu $t+k$, $k=0, 1, 2, \dots$

\hat{Z}_t : Dugaan dengan model linier

PACF sampel ditulis dengan notasi $\hat{\phi}_{kk}$ dengan $k \geq 1$ didefinisikan sebagai berikut :

$$\hat{\phi}_{kk} = \frac{\hat{\rho}_k - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} \hat{\rho}_{k-1}}{1 - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} \hat{\rho}_j} \quad (2.13)$$

dengan $\hat{\phi}_{kj} = \hat{\phi}_{k-1,j} - \hat{\phi}_{kk} \hat{\phi}_{k-1,k-j}$ untuk $j = 1, 2, \dots, k-1$.

2.4 Model – Model ARIMA

Beberapa model *time series* yaitu model *Autoregressive* (AR), model *Moving Average* (MA), model campuran ARMA,

model ARIMA, model ARIMA musiman dan model ARIMA multiplikatif.

Secara umum untuk model *autoregressive* menunjukkan adanya hubungan antara suatu nilai pada waktu sekarang Z_t dengan nilai pada waktu sebelumnya Z_{t-k} dimana $k=1,2,\dots$ ditambah dengan suatu nilai acak. Model *autoregressive* orde p , dapat ditulis $AR(p)$ secara matematis mempunyai bentuk sebagai berikut :

$$\begin{aligned}
 \dot{Z}_t &= \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + \dots + \phi_p \dot{Z}_{t-p} + a_t \\
 \dot{Z}_t - \phi_1 \dot{Z}_{t-1} - \phi_2 \dot{Z}_{t-2} - \dots - \phi_p \dot{Z}_{t-p} &= a_t \\
 \dot{Z}_t - \phi_1 B \dot{Z}_t - \phi_2 B^2 \dot{Z}_t - \dots - \phi_p B^p \dot{Z}_t &= a_t \quad (2.14) \\
 (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \dot{Z}_t &= a_t \\
 \phi_p(B) \dot{Z}_t &= a_t
 \end{aligned}$$

Model *Moving Average* (MA) menunjukkan adanya hubungan antara nilai pada waktu sekarang Z_t dengan nilai residual pada waktu sebelumnya a_{t-k} , model *Moving Average* orde q yang dapat ditulis $MA(q)$ secara matematis memiliki bentuk sebagai berikut :

$$\begin{aligned}
 \dot{Z}_t &= a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \\
 \dot{Z}_t &= a_t - \theta_1 B a_t - \theta_2 B^2 a_t - \dots - \theta_q B^q a_t \\
 \dot{Z}_t &= (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \quad (2.15) \\
 \dot{Z}_t &= \theta_q(B) a_t
 \end{aligned}$$

Model umum ARMA (p,q) merupakan gabungan dari pola model AR dan pola model MA. Apabila digabung akan menjadi persamaan 2.16. Berikut merupakan sebuah model umum untuk campuran dari model AR (p) dan model MA (q) yang secara matematis dapat ditulis :

$$\begin{aligned}
\dot{Z}_t &= \phi_1 \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \\
\dot{Z}_t - \phi_1 \dot{Z}_{t-1} - \dots - \phi_p \dot{Z}_{t-p} &= a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \\
\dot{Z}_t - \phi_1 B \dot{Z}_t - \dots - \phi_p B^p \dot{Z}_t &= a_t - \theta_1 B a_t - \dots - \theta_q B^q a_t \quad (2.16) \\
(1 - \phi_1 B - \dots - \phi_p B^p) \dot{Z}_t &= (1 - \theta_1 B - \dots - \theta_q B^q) a_t \\
\phi_p(B) \dot{Z}_t &= \theta_q(B) a_t
\end{aligned}$$

Model ARIMA merupakan model *time series* yang tidak stationer terhadap mean dan memerlukan proses *differencing* agar stationer. Sehingga dalam permodelan series $(1-B)^d Z_t$ perlu ditambahkan kedalam model umum ARMA (p,q) sehingga mengikuti proses *differencing* ARIMA (p,d,q) . Persamaannya adalah sebagai berikut :

$$\phi_p(B)(1-B)^d Z_t = \theta_0 + \theta_q(B) a_t \quad (2.17)$$

Model ARIMA musiman merupakan model yang membentuk pola musiman. Bentuk modelnya sebagai berikut:

$$\Phi_P(B^s)(1-B^s)^D Z_t = \Theta_Q(B^s) a_t \quad (2.18)$$

Model ini dinotasikan ARIMA $(P,D,Q)^s$ yang mempunyai faktor musiman dengan periode musim adalah s dalam pengamatan waktu ke- t . Notasi P merupakan lag pada model *Autoregressive* yang mempunyai faktor musiman, Notasi Q merupakan lag pada model *Moving Average* yang mempunyai faktor musiman, dan Notasi D merupakan lag untuk *differencing* yang mempunyai faktor musiman.

Bila pada data ada aspek reguler dan musiman, maka model ARIMA yang terbentuk adalah gabungan pola musiman dan pola reguler yang disebut dengan model ARIMA multiplikatif. Notasi umumnya dapat dinotasikan sebagai ARIMA $(p,d,q)(P,D,Q)^s$ dimana s merupakan periode musiman. Model umum ARIMA musiman multiplikatif menurut (Cryer, 1986) adalah sebagai berikut :

$$\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D\dot{Z}_t = \theta_q(B)\Theta_Q(B^S)a_t \quad (2.29).$$

2.5 Identifikasi Model ARIMA

Pendugaan model ARIMA dilakukan setelah data stasioner dengan melihat pola ACF atupun PACF. Pendugaan model dilakukan dengan memperhatikan hal-hal seperti pada tabel 2.2 berikut.

Tabel 2.2 Struktur ACF dan PACF pada model ARIMA

Model	ACF	PACF
<i>Autoregressive (p)</i>	Turun Eksponensial (<i>dies – down</i>)	Terpotong setelah <i>lag-p (cut off after lag-p)</i>
<i>Moving Average (q)</i>	Terpotong setelah <i>lag-q (cut off after lag-q)</i>	Turun eksponensial (<i>dies down</i>)
<i>Autoregressive-Moving Average (p,q)</i>	Turun eksponensial(<i>dies down</i>)	Turun eksponensial(<i>dies down</i>)

Sumber : (Wei, 2006)

2.6 Estimasi dan Uji Signifikansi Parameter Model ARIMA

Dalam menaksir parameter model ARIMA, ada beberapa metode yang digunakan, salah satu metodenya adalah metode *least square* (Cryer, 1986). Misalkan akan diberikan model AR(1), maka hanya dapat dijumlahkan dari $t = 2$ samapi $t = n$, sehingga diberikan suatu fungsi *conditional sum of squares* sebagai berikut :

$$S_c(\phi, \mu) = \sum_{t=2}^n [(Z_t - \mu) - \phi(Z_{t-1} - \mu)]^2. \quad (2.20)$$

Berdasarkan prinsip dari *least square*, parameter ϕ dan μ dapat diestimasi dengan cara meminimumkan nilai $S_c(\phi, \mu)$ dari nilai observasi Z_1, Z_2, \dots, Z_n yang telah diberikan. Estimator untuk parameter ϕ dan μ sebagai berikut :

$$\hat{\mu} = \bar{Z} \quad (2.21)$$

$$\hat{\phi} = \frac{\sum_{t=1}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2} \quad (2.22)$$

Selanjutnya jika diberikan model MA(1) sebagai berikut :

$$Z_t = a_t - \theta a_{t-1} \quad (2.23)$$

Metode least square cukup sulit diterapkan untuk mendapatkan estimator dari θ . Maka model MA(1) bisa didekati dengan model AR order tak hingga .

$$Z_t = -\theta Z_{t-1} - \theta^2 Z_{t-2} - \dots + a_t \quad (2.24)$$

Maka, metode least square dapat digunakan untuk mengestimasi θ dengan meminimumkan persamaan berikut.

$$S_c(\theta) = \sum_{t=2}^n (a_t)^2 = \sum_{t=2}^n (Z_t + \theta Z_{t-1} + \theta^2 Z_{t-2} - \dots)^2. \quad (2.25)$$

Selanjutnya apabila diberikan model ARMA (1,1) sebagai berikut.

$$Z_t = \phi Z_{t-1} + a_t - \theta a_{t-1} \quad (2.26)$$

Persamaan diatas dapat di modifikasi menjadi model sebagai berikut

$$a_t = Z_t - \phi Z_{t-1} + \theta a_{t-1} \quad (2.27)$$

Maka metode least square digunakan untuk meminimumkan persamaan berikut

$$S_c(\phi, \theta) = \sum_{t=2}^n a_t^2. \quad (2.28)$$

Selanjutnya untuk model umum ARMA (p, q) maka model yang didapat adalah sebagai berikut.

$$a_t = Z_t - \phi_1 Z_{t-1} - \phi_2 Z_{t-2} - \dots - \phi_p Z_{t-p} + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} \quad (2.29)$$

Dengan menggunakan proses *conditional least square* maka diperlukan persamaan $a_p = a_{p-1} = \dots = a_{p+1-q} = 0$ dan meminimumkan $S_c(\phi_1, \phi_2, \dots, \phi_p, \theta_1, \theta_2, \dots, \theta_q)$ sesuai orde untuk mendapatkan estimasi dari semua parameter.

Apabila ϕ adalah suatu parameter AR pada model ARIMA *Box-Jenkins*, sedangkan $\hat{\phi}$ adalah nilai estimasi (taksiran) dari parameternya, maka pengujian untuk signifikansi parameter *autoregressive* adalah :

Hipotesis :

$$H_0 : \phi = 0 \text{ (parameter model tidak signifikan)}$$

$$H_1 : \phi \neq 0 \text{ (parameter model signifikan).}$$

$$\text{Statistik uji : } t_{hitung} = \frac{\hat{\phi}}{SE(\hat{\phi})} \quad (2.30)$$

keputusan akan tolak H_0 jika $|t_{hitung}| > t_{\alpha/2(df=n-n_p)}$ atau $P\text{-value} < \alpha$.
dimana : n adalah banyak observasi dan n_p adalah jumlah parameter AR yang ditaksir (Wei, 2006).

Apabila θ adalah suatu parameter MA pada model ARIMA *Box-Jenkins*, sedangkan $\hat{\theta}$ adalah nilai estimasi (taksiran) dari parameternya, maka pengujian untuk signifikansi parameter *moving average* adalah :

hipotesis :

$$H_0 : \theta = 0 \text{ (parameter model tidak signifikan)}$$

$$H_1 : \theta \neq 0 \text{ (parameter model signifikan)}$$

$$\text{statistik uji : } t_{hitung} = \frac{\hat{\theta}}{SE(\hat{\theta})} \quad (2.31)$$

keputusan akan tolak H_0 jika $|t_{hitung}| > t_{\alpha/2(df=n-n_q)}$ atau $P\text{-value} < \alpha$.
dimana : n adalah banyak observasi dan n_q adalah jumlah parameter MA yang ditaksir (Wei, 2006).

2.7 Cek Diagnosa

Pada tahap ini dilakukan pemeriksaan dan pengujian tentang asumsi residual untuk model ARIMA. Pengujian ini meliputi asumsi residual *white noise*, deteksi outlier, dan uji asumsi kenormalan residual.

Pengujian *white noise* dilakukan untuk mengetahui apakah varian bernilai konstan atau tidak. Untuk menguji apakah residual memenuhi asumsi *white noise* dengan statistik uji yang diberikan oleh Ljung Box (Wei, 2006) menggunakan hipotesis sebagai berikut :

Hipotesis :

$$H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0 \text{ (residual } white \text{ noise)}$$

$$H_1: \text{minimal ada satu } \rho_i \neq 0 \text{ untuk } i = 1, 2, \dots, k \text{ (residual tidak } white \text{ noise)}$$

Statistik uji :

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2 \quad (2.32)$$

keputusan tolak H_0 , jika nilai $Q > \chi^2_{(\alpha; k-(p+q))}$ atau $P\text{-value} < \alpha$

dimana : n = jumlah observasi

p = banyaknya komponen AR

q = banyaknya komponen MA

Jika residual tidak memenuhi syarat *white noise* maka diduga adanya data yang *outlier*. *Outlier* adalah data yang memiliki karakteristik unik yang terlihat sangat berbeda jauh dari observasi-observasi lainnya dan muncul dalam bentuk nilai ekstrim baik sebagai variabel tunggal atau kombinasi. Keberadaan *outlier* dapat mempengaruhi kebaikan model. Salah satu cara untuk mengatasi masalah ini adalah dengan memasukkan variabel dummy ke dalam model. Ada empat jenis *outlier* yang dapat diidentifikasi yaitu *Innovational Outlier* (IO), *Additive Outlier* (AO), *Temporary Change* (TC) dan *Level Shift* (LS).

Untuk mengetahui apakah residual berdistribusi normal digunakan statistik uji *Kolmogorov-Smirnov*. Uji *Kolmogorov-*

Smirnov berpusat pada dua fungsi distribusi kumulatif yaitu $F_0(x)$ sebagai fungsi distribusi yang dihipotesiskan dalam hal ini distribusi normal dan $S(x)$ sebagai fungsi distribusi empiris (Daniel & Wayne, 1989).

Hipotesis :

$$H_0: F(x) = F_0(x), \text{ untuk semua nilai } x$$

$$H_1: F(x) \neq F_0(x), \text{ untuk sekurang-kurangnya sebuah nilai } x$$

Statistik uji :

$$D = \text{Sup} |F_0(x) - S(x)| \quad (2.33)$$

Sup merupakan nilai supremum (maksimum) semua x dari perhitungan $|F_0(x) - S(x)|$. Keputusan akan tolak H_0 , jika nilai dari $D \geq D_{n,(1-\alpha)}$ atau $P\text{-value} < \alpha$.

2.8 Pemilihan Model Terbaik

Peramalan adalah langkah terakhir untuk menentukan nilai-nilai di waktu mendatang setelah langkah-langkah sebelumnya telah dianalisis. Namun untuk melakukan peramalan dengan tepat diperlukan suatu kriteria untuk menentukan model yang paling baik. Untuk menentukan model yang terbaik untuk peramalan, dapat digunakan kriteria dari pendekatan *In-Sample* dan *Out-Sample*

Pendekatan *In-Sample* menggunakan kriteria *Akaike's Information Criterion* (AIC) dan *Schwartz's Bayesian Criterion* (SBC). AIC ialah kriteria pemilihan model terbaik dengan mempertimbangkan banyaknya parameter dalam model. Semakin kecil nilai AIC, maka model semakin baik. Kriteria AIC dapat dirumuskan sebagai berikut (Wei, 2006).

$$AIC(M) = n \ln \hat{\sigma}_a^2 + 2M \quad (2.34)$$

dimana :

M = banyaknya parameter dalam model.

n = banyak observasi.

$\hat{\sigma}_a^2$ = estimasi maksimum Likelihood dari σ_a^2 .

SBC adalah kriteria pemilihan model terbaik dengan mempertimbangkan jumlah parameter dalam model dengan sampel kecil. Nilai SBC dirumuskan sebagai berikut :

$$SBC(M) = n \ln \hat{\sigma}_a^2 + M \ln n \quad (2.35)$$

dimana:

M = banyaknya parameter dalam model.

n = banyak observasi.

$\hat{\sigma}_a^2$ = estimasi maksimum Likelihood dari σ_a^2

Pemilihan model terbaik melalui pendekatan *out-sample* dengan menggunakan MSE (*Mean Square Error*) dan sMAPE (*Symmetric Mean Absolute Percentage Error*). Model terbaik dipilih berdasarkan nilai MSE dan sMAPE terkecil. Adapun rumus MSE dan sMAPE dapat ditulis sebagai berikut. (Hanke & Wichern, 2005)

$$MSE = \frac{1}{R} \sum_{t=1}^R (Z_t - \hat{Z}_t)^2 \quad (2.36)$$

$$sMAPE = \frac{2}{R} \sum_{t=1}^R \frac{|\hat{Z}_t - Z_t|}{\hat{Z}_t + Z_t} \quad (2.37)$$

dimana :

R = Banyaknya residual

Z_t = Data sebenarnya ke- t

\hat{Z}_t = Data hasil peramalan ke- t

2.9 Metode *Moving Average*

Metode *Moving Average* adalah suatu metode peramalan yang dilakukan dengan mengambil sekelompok nilai pengamatan, mencari nilai rata-rata tersebut sebagai ramalan untuk periode yang akan datang. Metode ini disebut rata-rata tersebut bergerak karena setiap kali data observasi baru tersedia, maka angka-angka rata-rata baru dihitung dan digunakan sebagai ramalan. Teknik

peramalan dengan *Moving Average*, secara matematis dapat ditulis sebagai berikut.

$$F_{t+1} = \frac{x_t + x_{t-1} + \dots + x_{t-m+1}}{m} \quad (2.38)$$

dimana,

F_{t+1} = peramalan periode ke t.

x_t = data pada periode ke t.

m = jumlah data yang diperhitungkan.

(Makridakis, Wheelwright, & Mc Gee, 1999)

Dari persamaan diatas bahwa pola hasil peramalan sangat ditentukan oleh data yang diperhitungkan (m) dalam peramalan. Jika dari pengamatan terlihat bahwa perubahan nilai cukup besar setiap periodenya, maka dalam penetapan banyak data yang dikmbangkan dipillah lebih kecil. Demikian juga sebaliknya, jika data pola yang stabil, maka diambil m yang lebih besar.

2.10 Metode Regresi *Time Series*

Regression with Autocorrelated Errors sering disebut juga dengan metode regresi *time series*. Model regresi *time series* merupakan model yang menghubungkan variabel dependen Y dengan fungsi waktu, Model ini bermanfaat saat parameter yang menjelaskan peramaan *time series* berada pada kondisi konstan secara terus menerus (Bowerman & O'Connell, 1993). Berbeda dengan model regresi konvensional regresi *time series* merupakan fungsi antara satu variabel respon (Y) dengan satu atau lebih variabel prediktor (X) dimana kedua variabel tersebut bersyarat pada waktu. Secara umum model regresi *time series* dapat dikatakan (Wei, 2006)

$$Y_t = \beta_1 X_{1,t} + \beta_2 X_{2,t} + \dots + \beta_i X_{i,t} + \varepsilon_t \quad (2.39)$$

Atau

$$\mathbf{Y}_t = \mathbf{X}_t' \boldsymbol{\beta} + \boldsymbol{\varepsilon}_t \quad (2.40)$$

dengan :

- Y_t : Respon regresi *time series*
 β_t : vektor parameter regresi *time series*
 X_t : vektor prediktor regresi *time series*
 ε_t : residual belum iidN $(0, \sigma_n^2)$.

Halaman ini sengaja dikosongkan

BAB III METODOLOGI PENELITIAN

3.1 Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder berupa data bulanan, yang didapat dari PT. SPINDO, Tbk mulai bulan Januari 2012 sampai Desember 2016. Variabel penelitiannya adalah jumlah permintaan pipa hollow galvalum dengan empat ukuran, yaitu :

- 1) 35mm x 35mm x 0,6mm x 6M disimbolkan A
- 2) 35mm x 35mm x 0,7mm x 6M disimbolkan B
- 3) 35mm x 35mm x 0,8mm x 6M disimbolkan C
- 4) 35mm x 35mm x 0,9mm x 6M disimbolkan D

3.2 Metode Analisis

Metode analisis yang digunakan dalam menganalisis data penelitian ini adalah metode ARIMA *Box-jenkins* dan metode *Moving Average*. Hasil yang diperoleh selanjutnya dibandingkan model mana yang terbaik, setelah mendapatkan model yang terbaik, dilakukan peramalan. Untuk menganalisis data, jumlah permintaan pipa hollow galvalum dari setiap ukuran dibagi menjadi dua yaitu data *in sample* merupakan jumlah permintaan pipa hollow galvalum pada bulan Januari 2012-Desember 2015 untuk membuat model dan data *out sample* merupakan jumlah permintaan pipa hollow galvalum bulan Januari 2016-Desember 2016 untuk validasi model. Adapun langkah – langkah dalam menganalisis data *in sample* dengan metode ARIMA *Box-Jenkins* sebagai berikut :

1. Identifikasi Model ARIMA

Pemeriksaan stasioneritas data *in sample*, baik dalam *mean* pada persamaan (2.1) dan *varians* pada persamaan (2.2). Kestasioneran ini dapat dilihat dari pola *time series* dan ACF. Jika tidak stasioner terhadap *varians*, maka data dapat di transformasi *Box – Cox* dengan persamaan (2.9). Jika

tidak stasioner terhadap *mean*, maka perlu dilakukan *differencing* dengan menggunakan persamaan (2.7). Model di identifikasikan melalui plot ACF menggunakan persamaan (2.10) dan PACF menggunakan persamaan (2.12) pada data yang sudah stasioner.

2. Estimasi dengan menggunakan persamaan (2.22) dan uji signifikansi parameter dengan menggunakan statistik uji pada persamaan (2.30) atau (2.31).
3. Cek diagnosa residualnya
Residualnya diuji *white noise* (2.32) dan normalitasnya (2.33).

4. Pemilihan model terbaik

Model dapat dipilih melalui 2 pendekatan, yaitu pendekatan *in sample* dan *out sample*. Model yang dipilih adalah model yang menghasilkan nilai AIC (2.34) atau SBC (2.35) pada *in sample* terkecil dan MSE (2.36) atau sMAPE (2.37) *out sample* terkecil.

5. Peramalan dengan menggunakan metode ARIMA.

Selanjutnya untuk langkah-langkah analisis data *in sample* dengan menggunakan metode *Moving Average* sebagai berikut :

1. Menentukan jumlah m atau jumlah *length* untuk dilakukan rata-rata bergerak.
2. Melakukan perhitungan rata-rata bergernaknya dari *length* yang telah ditentukan dengan persamaan (2.39)
3. Menentukan MSE dan MAPE dari hasil langkah kedua dan data asli.
4. Mencari jumlah *length* yang optimum dengan melihat hasil MSE dan sMAPE terkecil yang selanjutnya digunakan peramalan dari data.


Sedangkan langkah – langkah dalam menganalisis data dengan regresi *time series* sebagai berikut :

1. Menentukan variabel prediktor dari periode data sehingga dapat dibentuk variabel regresi *time series* (2.39)
2. Mengidentifikasi apakah model membentuk pola trend dan seasonal

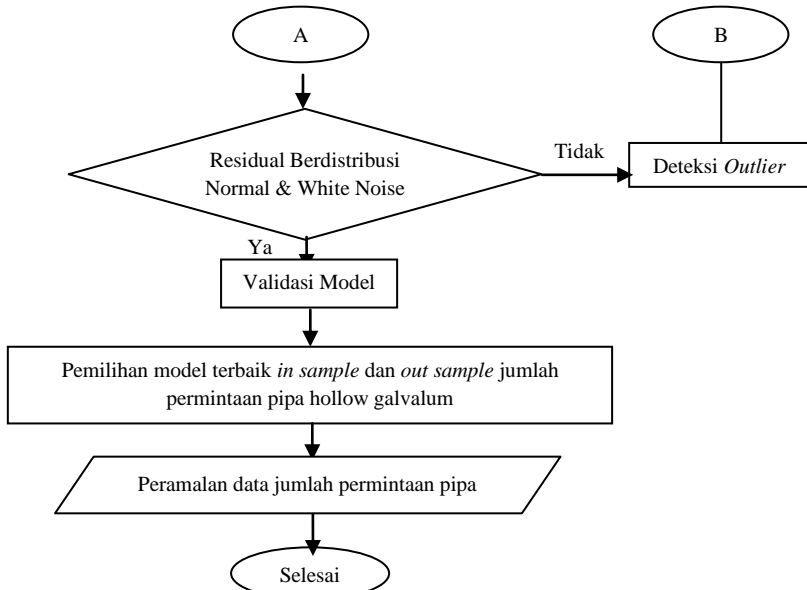
3. Mengestimasi model.
4. Dilakukan pengujian signifikansi baik parsial maupun serentak dari model.
5. Pemeriksaan diagnosis dari residualnya.

3.3 Diagram Alir

Berikut diagram alir untuk peramalan data jumlah permintaan pipa hollow galvalum dari setiap ukuran pipa di PT. SPINDO,Tbk dengan metode ARIMA *Box Jenkins*:




Gambar 3.1 Flow Chart Metode ARIMA Box – Jenkins

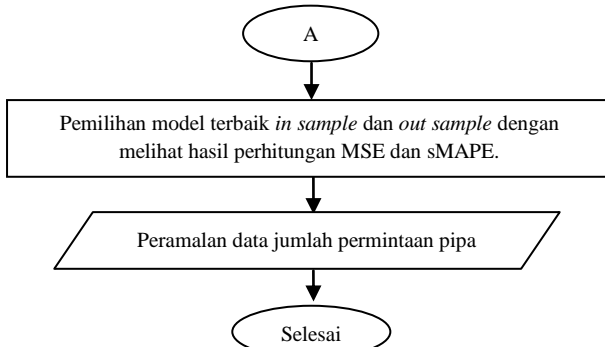


Gambar 3.1 Flow Chart Metode ARIMA Box – Jenkins (Lanjutan)

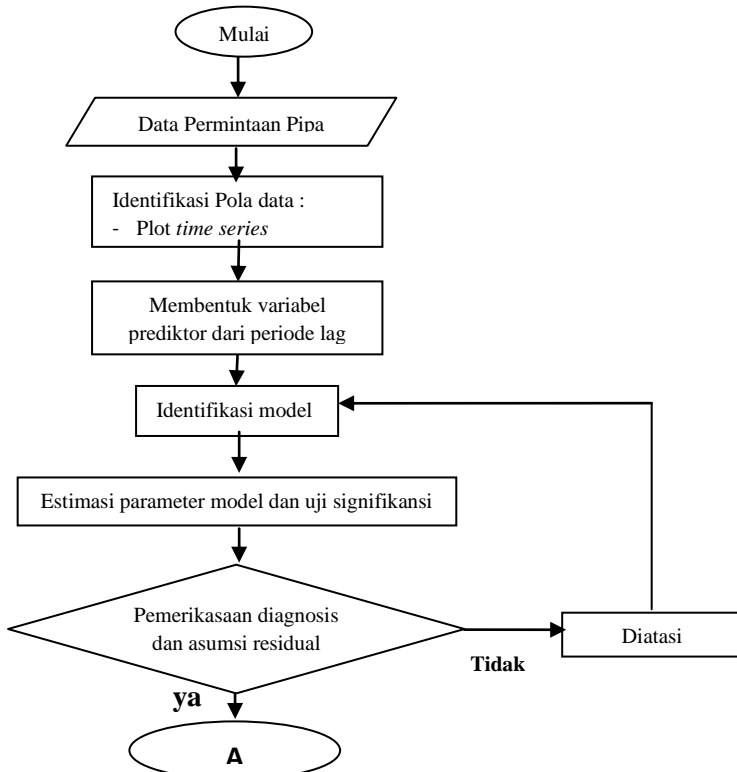
Sedangkan diagram alir untuk data jumlah permintaan pipa hollow galvalum dari setiap ukuran pipa dengan menggunakan metode *Moving Average* sebagai berikut.




Gambar 3.2 Flow Chart Metode *Moving Average*



Gambar 3.2 Flow Chart Metode *Moving Average* (Lanjutan)



Gambar 3.3 Flow Chart Metode Regresi *Time Series*



Gambar 3.3 *Flow Chart* Metode Regresi *Time Series* (Lanjutan)

BAB IV ANALISIS DATA DAN PEMBAHASAN

Dalam bab ini akan dijelaskan mengenai model ramalan yang sesuai pada enam jenis pipa yang ada di PT. SPINDO, Tbk Unit 6. Data yang digunakan adalah jumlah permintaan pipa yang masuk pada bulan Januari 2012-Desember 2016. Data permintaan pipa tiap ukuran tersebut dianalisis dengan menggunakan metode ARIMA Box Jenkin, *Moving Average*, dan Regresi *Time Series*.

4.1 Statistika Deskriptif


Statistika deskriptif dari ke empat jenis pipa periode Januari 2012 sampai Desember 2016 terlihat pada tabel 4.1 berikut.

Tabel 4.1 Statistika Deskriptif Data Jumlah Permintaan Pipa Hollow Galvalum

Variabel	N	Mean	Standart Deviasi	Minimum	Maksimum
P.Galvalum A	60	22676	21854	10	87610
P.Galvalum B	60	25461	28253	10	139210
P.Galvalum C	60	22631	28637	10	129810
P.Galvalum D	60	14928	20062	10	97610

Pada tabel diatas terlihat bahwa ukuran pipa yang memiliki jumlah permintaan yang paling tinggi adalah pipa galvalum B dengan nilai rata – ratanya sebesar 25461 pcs dan jumlah permintaan paling banyak sebesar 139210 pcs. Sedangkan ukuran pipa yang paling rendah dari tabel diatas adalah pipa galvalum D dengan nilai rata – ratanya sebesar 14928 pcs dan jumlah permintaan paling tinggi sebesar 97610 pcs. Untuk melihat variabilitas dari setiap ukuran dan setiap bulannya dapat disajikan dalam bentuk box plot pada Gambar 4.1. Pada Gambar tersebut dijelaskan bahwa pipa galvalum A pada bulan Januari memiliki varia-

bilitas yang lebih lebar dibanding bulan lainnya. Hal tersebut menunjukkan bahwa pada bulan Januari memiliki jumlah permintaan yang bermacam – macam disetiap tahunnya. Sedangkan Jumlah permintaan pipa galvalum B pada bulan Maret memiliki variabilitas yang paling lebar dibandingkan bulan lainnya. Hal ini menunjukkan bahwa pada bulan Maret memiliki jumlah permintaan pipa berbeda-beda di setiap tahunnya.



Gambar 4.1 Box Plot Jumlah Permintaan Pipa Hollow Galvalum

Jumlah permintaan pipa galvalum C pada bulan Maret memiliki nilai variabilitas yang lebih lebar dibandingkan dengan bulan – bulan lainnya. Sedangkan jumlah permintaan pipa galvalum D pada bulan Maret memiliki variabilitas yang paling lebar dibandingkan bulan lainnya.

Setelah mengetahui eksplorasi data dan variabilitas dari setiap dimensi pipa, selanjutnya dibentuk pemodelan dari data tersebut.


4.2 Pemodelan Jumlah permintaan Pipa Galvalum A dengan menggunakan Metode ARIMA

Langkah awal dalam melakukan analisis peramalan dengan menggunakan metode ARIMA Box Jenkins adalah membagi data menjadi data training dan data testing. Data training untuk mem-

bentuk model sedangkan data testing untuk validasi model. Berikut merupakan penjelasan untuk membentuk model. Data training untuk pipa galvalum A adalah jumlah permintaan pipa pada bulan Januari 2012 sampai Desember 2015. Sedangkan data testing untuk pipa galvalum A adalah jumlah permintaan pipa pada bulan Januari 2016 sampai Desember 2016.

4.2.1 Identifikasi Model Permintaan Pipa Galvalum A

Identifikasi model disini adalah dengan melihat time series plot dari data permintaan pipa galvalum A untuk melihat karakteristik data. Time series plot dari pipa galvalum A dapat dilihat dalam bentuk Gambar 4.2 berikut.




Gambar 4.2 Time Series Plot Pipa Galvalum A

Pada gambar diatas, terlihat bahwa terjadi peningkatan permintaan pipa pada bulan ke 30,37, dan 51. Selain itu dari time series plot diatas terlihat bahwa tidak adanya pengulangan order kenaikan order di setiap bulannya. Pada tahun 2012 terjadi peningkatan order pada bulan Mei, tahun 2013 terjadi peningkatan pada bulan November, tahun 2014 terjadi peningkatan pada bulan juni. Pada tahun 2015 terjadi peningkatan pada bulan Januari dan September. Sedangkan pada tahun 2016 terjadi peningkatan pada bulan Januari dan bulan November. Sehingga dapat dikatakan bahwa data mengalami peningkatan pada setiap

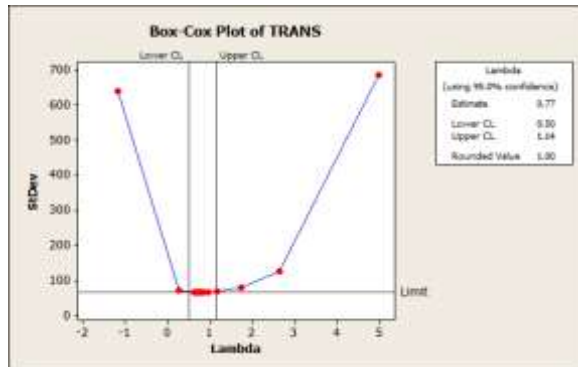
tahunnya namun tidak mengalami order musiman pada bulan yang sama disetiap tahunnya.

Dilihat dari Gambar 4.2, data sudah stasioner terhadap mean karena terlihat data berjalan di sekitar rata – ratanya namun belum stasioner terhadap varians karena terlihat terjadi peningkatan order di beberapa bulan.. Hal ini bisa dilihat dari nilai lambda pada hasil transformasi *box-cox*. Hasil transformasi *box – cox* dapat dilihat dalam bentuk Gambar 4.3 berikut.



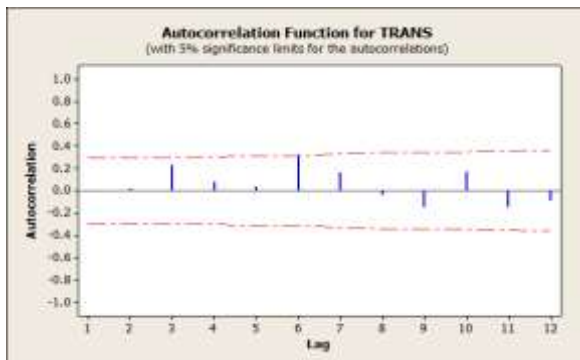
Gambar 4.3 Hasil Transformasi Box Cox Pipa Galvalum A

Pada gambar diatas, terlihat bahwa *rounded value* atau nilai lambda memiliki nilai 0,5 yang berarti bahwa data tidak stasioner terhadap varians dengan nilai lambda bernilai 1. Selain itu juga dapat dilihat dari nilai *lower* dan *upper* juga tidak melewati nilai 1 sehingga dapat dikatakan bahwa data tidak stasioner terhadap varians. Oleh sebab itu, agar data stasioner terhadap varians, maka data di lakukan transformasi akar kuadrat. Setelah data ditransformasi akar kuadrat, lalu diperiksa nilai *lambda* dari data transformasi tersebut. Apabila nilai *lambda* belum bernilai angka 1 dapat dilihat nilai *lower* dan *upper* jika sudah melewati angka 1 maka dapat dikatakan bahwa data telah stasioner terhadap varians sehingga tidak perlu dilakukan transformasi lagi. Nilai Lambda setelah data jumlah permintaan pipa hollow galvalum A ditransformasi akar kuadrat terlihat pada Gambar 4.4 berikut.



Gambar 4.4 Hasil Transformasi Box Cox Setelah Transformasi Akar Kuadrat Untuk Pipa Galvalum A

Pada Gambar 4.4 diatas, terlihat bahwa *rounded value* atau nilai lambda sudah bernilai 1, sehingga dapat dikatakan bahwa data sudah stasioner terhadap varians. selanjutnya untuk melihat kestasioneran data terhadap mean, dapat dilihat dari plot ACF dari data yang sudah di transformasikan. Plotnya sebagai berikut.



Gambar 4.5 Plot ACF Permintaan Pipa Galvalum A

Dari gambar ACF diatas terlihat bahwa plot sudah berada didalam batas ACF sehingga dapat dikatakan bahwa data sudah

stasioner terhadap mean. Untuk lebih memastikan lagi, maka dilakukan uji Augmented Dickey Fuller.

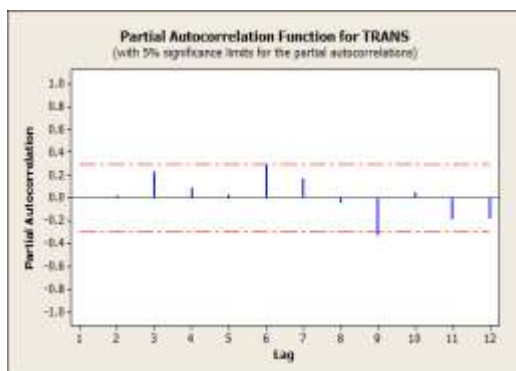
Hipotesis :

$H_0 : \delta = 0$ (Terdapat akar unit, variabel Z tidak stasioner)

$H_1 : \delta \neq 0$ (Tidak terdapat akar unit, variabel Z stasioner).

Tingkat Signifikan : 5%

Dari hasil analisis menunjukkan bahwa nilai t_{δ} sebesar -6,705094 dengan *P_Value* sebesar 0,000. *P_value* memiliki nilai kurang dari 0,05 dapat diputuskan tolak H_0 . Sehingga dapat disimpulkan bahwa data permintaan pipa telah stasioner terhadap mean. Untuk membentuk model, perlu diketahui juga plot PACF nya dari jumlah permintaan pipa galvalum. Plot PACF sebagai berikut.



Gambar 4.6 Plot PACF Jumlah Permintaan Pipa Galvalum A

Plot ACF dan PACF pada Gambar 4.5 dan 4.6 merupakan plot pada data transformasi. Pada Gambar 4.5 terlihat bahwa lag yang signifikan dari plot tersebut adalah lag 3 dan 6. Sedangkan pada plot PACF, lag yang signifikan adalah lag 3, 6, dan 9. Sehingga model dugaan sementara yang terbentuk adalah AR ([6,9]), MA ([6]), ARIMA ([3],0,[6]), ARIMA ([3],0,[3]), dan ARIMA ([6],0,[3]).

4.2.2 Estimasi Parameter pada Jumlah Permintaan Pipa Galvalum A

Setelah diidentifikasi model pada data training, maka didapatkan 5 model dugaan. Maka langkah selanjutnya adalah melakukan estimasi parameter dan uji signifikansi parameter. Hasil estimasi dan uji signifikansi disajikan dalam bentuk tabel 4.2 berikut.

Tabel 4.2 Pengujian Parameter Jumlah Permintaan Pipa Galvalum A

Model	Parameter	Estimate	P-value	Kesimpulan
AR ([6,9])	ϕ_6	0,86228	<0,0001	Signifikan
	ϕ_9	0,003	0,9860	Tidak Signifikan
MA ([6])	θ_6	-0,79390	<0,0001	Signifikan
ARIMA ([3],0,[6])	θ_6	-0,48794	<0,0001	Signifikan
	ϕ_3	0,7986	<0,000	Signifikan
ARIMA ([3],0,[3])	θ_3	0,39820	<0,038	Signifikan
	ϕ_3	0,95557	<0,000	Signifikan
ARIMA ([6],0,[3])	θ_3	-0,54943	0,0003	Signifikan
	ϕ_6	0,81071	<0,000	Signifikan

Dari kelima model diatas, terlihat bahwa nilai *P_value* lebih kecil dari tingkat signifikan 0,05 yang berarti tolak H_0 . Namun ada satu parameter yang tidak signifikan yaitu ϕ_9 pada model AR ([6,9]) karena *P_Value* lebih dari 0,05. Sehingga dapat dikatakan bahwa terdapat 4 model dugaan yang telah signifikan terhadap model.

4.2.3 Cek Diagnosa Residual Jumlah Permintaan Pipa Holow Galvalum A.

Setelah dilakukan estimasi parameter dan pengujian signifikansi parameter, maka dilanjutkan untuk pengujian pada residualnya dari ketiga model tersebut. Pengujian ini dilakukan untuk

mengetahui apakah residual telah memenuhi asumsi *white noise* dan asumsi normal. Berikut merupakan pengujian asumsi *white noise* pada data jumlah permintaan pipa galvalum A.

Tabel 4.3 Uji *White Noise* jumlah permintaan pipa Galvalum A

Model	Lag	P-value	Kesimpulan
AR ([6,9])	6	0,0043	Tidak <i>White Noise</i>
	12	0,0107	Tidak <i>White Noise</i>
	18	0,0710	<i>White noise</i>
	24	0,1423	<i>White noise</i>
MA ([6])	6	<0,0001	Tidak <i>White Noise</i>
	12	<0,0001	Tidak <i>White Noise</i>
	18	<0,0001	Tidak <i>White Noise</i>
	24	<0,0001	Tidak <i>White Noise</i>
ARIMA ([3],0,[6])	6	0,4782	<i>White noise</i>
	12	0,5086	<i>White noise</i>
	18	0,7412	<i>White noise</i>
	24	0,5892	<i>White noise</i>
ARIMA ([3],0,[3])	6	0,1763	<i>White noise</i>
	12	0,2441	<i>White noise</i>
	18	0,5975	<i>White noise</i>
	24	0,5290	<i>White noise</i>
ARIMA ([6],0,[3])	6	0,4761	<i>White noise</i>
	12	0,5882	<i>White noise</i>
	18	0,9022	<i>White noise</i>
	24	0,8800	<i>White noise</i>

Pada Tabel 4.3 diatas, terlihat bahwa terdapat tiga model yang telah memenuhi asumsi residual *White Noise*. Hal tersebut bisa dibuktikan karena pada lag 6,12,18, dan 24 memiliki P-Value lebih dari nilai tingkat signifikan 5% semua yang berarti gagal tolak H_0 .

Pengujian selanjutnya adalah uji asumsi pengujian kenormalan residual. Pengujian kenormalan residual dilakukan pada tiga model yang telah memenuhi asumsi residual *White Noise* dengan menggunakan uji kolmogorov-smirnov. Berikut hasil dari uji kolmogorov smirnov.

Tabel 4.4 Uji Kenormalan Residual Jumlah Permintaan Pipa Galvalum A

Model	P-value	Kesimpulan
ARIMA ([3],0,[6])	>0,150	Berdistribusi Normal
ARIMA ([3],0,[3])	>0,150	Berdistribusi Normal
ARIMA ([6],0,[3])	>0,150	Berdistribusi Normal

Dari Tabel 4.4 diatas, terlihat bahwa P-value dari ketiga model diatas memiliki nilai lebih dari nilai tingkat signifikan yang berarti gagal tolak H_0 . Sehingga dapat disimpulkan bahwa ketiga model pada Tabel 4.4 telah memenuhi asumsi residual normal.

4.2.4 Pemilihan Model Terbaik Jumlah Permintaan Pipa Galvalum A dengan menggunakan Metode ARIMA

Langkah selanjutnya adalah memilih model terbaik dari ketiga model dugaan. Model terbaik dipilih berdasarkan data In Sampel dan Out Sampel.

Memilih model terbaik berdasarkan data In Sampel dengan membandingkan nilai AIC dan SBC dari ketiga model. Hasilnya dapat dilihat dari tabel 4.5 berikut.

Tabel 4.5 Pemilihan Model Terbaik untuk Jumlah permintaan Pipa Galvalum A berdasarkan In Sampel

Model	AIC	SBC
ARIMA ([3],0,[6])	554,66	558,40
ARIMA ([3],0,[3])	558,26	562,00
ARIMA ([6],0,[3])	552,95	556,92

Dari tabel diatas, terlihat bahwa model terbaiknya adalah ARIMA ([6],0,[3]) dengan nilai AIC sebesar 552,95 dan nilai SBC 556,92.

Memilih model terbaik berdasarkan data out sampel dengan membandingkan nilai MSE dan sMAPE dari ketiga model yaitu model ARIMA ([3],0,[6]), ARIMA ([3],0,[3]), dan ARIMA ([6],0,[3]). Hasil dari perhitungan MSE dan SMAPE disajikan dalam bentuk Tabel 4.6 sebagai berikut.

Tabel 4.6 Pemilihan Model Terbaik untuk Jumlah permintaan Pipa Galvalum A berdasarkan Out Sampel

Model	MSE	sMAPE
ARIMA ([3],0,[6])	1501234761	1,71
ARIMA ([3],0,[3])	1287698939	1,23
ARIMA ([6],0,[3])	1380215705	1,41


Dari perbandingan nilai pada 3 kriteria tersebut, terlihat bahwa model terbaiknya adalah ARIMA ([3],0,[3]) karena memiliki nilai MSE dan sMAPE paling kecil dibanding model yang lainnya. Sehingga dapat disimpulkan bahwa model terbaik dipilih berdasarkan hasil *Out Sampel* yang berfungsi sebagai validasi model. Model ARIMA terbaik untuk pipa galvalum A adalah ARIMA ([3],0,[3]). Berikut penjabaran model ARIMA ([3],0,[3])

$$Z_t = 0,956Z_{t-3} + a_t - 0,398a_{t-3}$$

Model diatas menjelaskan bahwa jumlah permintaan pipa galvalum A pada bulan ke-t adalah 0,956 kali dari jumlah permintaan pada (t-3) ditambah jumlah kesalahan perkiraan pada bulan ke-t dikurangi 0,398 kali dari jumlah kesalahan perkiraan pada (t-3).

4.3 Pemodelan Jumlah Permintaan Pipa Hollow Galvalum A Menggunakan Metode *Moving Average*.

Langkah awal dalam menggunakan metode *moving average* adalah menentukan *length* atau jumlah m sebagai sekelompok data yang akan di rata – rata bergerak. Setelah dilakukan *trial and error* dari *length* 1 sampai *length* 12, maka didapatkan 2 jumlah *length* yang memiliki nilai MAPE dan MSD yang bernilai kecil dibandingkan nilai *length* lainnya. *Length* tersebut bernilai 6 dan 7. Hasil plot dan nilai MAPE serta MSD dapat dilihat pada Gambar 4.7. Dari gambar tersebut terlihat bahwa nilai fit mengikuti gerak dari data asli dan didapatkan nilai MSD pada *length* 7 sebesar 370575036 sedangkan pada *length* 6 sebesar 381396514.



Gambar 4.7 Hasil Analisis *Moving Average* pada Pipa Galvalum A

Untuk melihat model dengan *length* yang terbaik, dapat dilihat dari perhitungan MAPE dan MSD dari data out sampel. Hasil perhitungannya sebagai berikut.

Tabel 4.7 Pemilihan *Length* Terbaik Metode MA pada Pipa Galvalum A

Length	MSE	sMAPE
6	974973898,3	0,900153
7	951445289,3	0,892271

Dari Tabel 4.7 diatas terlihat bahwa jumlah *length* yang paling baik adalah *length* 7 karena memiliki nilai MSE dan nilai sMAPE lebih kecil dibandingkan dengan *length* 6. Maka selanjutnya metode *Moving Average* dengan menggunakan *length* 7 yang digunakan sebagai pembanding dengan metode ARIMA untuk mendapatkan model peramalan yang terbaik.

4.4 Pemodelan Jumlah Permintaan Pipa Hollow Galvalum A Menggunakan Metode Regresi *Time Series*.

Regresi *Time Series* menggunakan data transformasi akar kuadrat agar data memenuhi asumsi residual. Selanjutnya membentuk variabel prediktor dengan mengkombinasikan variabel t dan variabel Y yang telah diberi lag dari lag ke-1 sampai lag ke-30 sehingga didapatkan beberapa variabel prediktor yang signifikan terhadap model. Model yang terbentuk dan berpengaruh terhadap model adalah variabel t , Y_{t-6} , Y_{t-9} , dan Y_{t-11} .

4.4.1 Estimasi dan Signifikansi Parameter Data Jumlah Permintaan Pipa Hollow Galvalum A dengan Regresi Time Series.

Setelah didapatkan dugaan variabel prediktor, maka terbentuk model dugaan sebagai berikut.

$$Y_t = 114 + 2,54T + 0,385Y_{t-6} - 0,468Y_{t-9} - 0,4Y_{t-11}$$

Selanjutnya parameter dari model regresi *time series* diatas, dilakukan pengujian parameter untuk mengetahui apakah parameter tersebut signifikan terhadap model. Pengujiannya sebagai berikut.

Hipotesis :

$$H_0 : \beta_i = 0 \text{ (parameter tidak signifikan)}$$

$$H_1 : \beta_i \neq 0 \text{ (parameter signifikan)}$$

$$\text{Statistik Uji : } T_{hitung} = \frac{\beta_i}{Se(\beta_i)}$$

Taraf Signifikan : $\alpha = 0,05$

Daerah Kritis : Tolak H_0 jika *P-value* < 0,05

Tabel 4.8 Pengujian Parameter Data Jumlah Permintaan Pipa Hollow Galvalum A Dengan Regresi *Time Series*.

Parameter	Estimate	T	P-value	Kesimpulan
Konstanta	114,28	3,39	0,002	Signifikan
<i>T</i>	2,543	2,07	0,046	Signifikan
Y_{t-6}	0,3848	2,29	0,029	Signifikan
Y_{t-9}	-0,4678	-2,85	0,008	Signifikan
Y_{t-11}	-0,4000	-2,42	0,022	Signifikan

Dari Tabel 4.8, dapat dilihat bahwa parameter konstanta, *t*, Y_{t-6} , Y_{t-9} , dan Y_{t-11} sudah signifikan karena *P-Value* memiliki nilai kurang dari 0,05 yang berarti tolak H_0 . Sehingga dapat dikatakan bahwa seluruh paramater telah signifikan terhadap model Regresi *Time Series*. Namun sebelum digunakan untuk peramalan, resi-

dual dari model tersebut harus memenuhi asumsi identik, independen, dan normal.

4.4.2 Pengujian Asumsi Residual Data Jumlah Permintaan Pipa Hollow Galvalum A.

Asumsi yang harus terpenuhi dalam analisis regresi adalah identik, independen, dan distribusi normal. Asumsi homoskedastisitas adalah variansi residual bersifat identik. Berikut adalah pengujian dengan menggunakan uji Glejser.

Hipotesis:

H_0 : Tidak ada kasus heteroskedastisitas (Identik)

H_1 : Ada kasus heteroskedastisitas


Tabel 4.9 Uji Glejser Data Jumlah Permintaan Pipa Galvalum A

Parameter	P-value
Konstanta	0,032
T	0,909
Y_{t-6}	0,867
Y_{t-9}	0,924
Y_{t-11}	0,919

berdasarkan Tabel 4.9 menjelaskan bahwa nilai P_value pada seluruh variabel prediktor tersebut $> \alpha$ (0,05) yang berarti terjadi sudah memenuhi asumsi identik dengan kata lain varians residual bersifat konstan.

Pendeteksian adanya otokorelasi salah satunya dapat menggunakan uji Durbin Watson. Seperti yang terlihat pada Lampiran, diketahui bahwa nilai durbin watson sebesar 2,21931 sedangkan nilai d_u sebesar 1,6231 dan d_L sebesar 1,4500 pada tingkat signifikansi $\alpha = 0,05$ maka hasil Durbin watson dapat diputuskan tidak adanya autokorelasi karena d_u (1,6231) $< d(2,21931) < 4-d_u$ (2,3769). Hal ini menunjukkan bahwa residual tidak ada autokorelasi atau independen.

Uji asumsi normalitas harus terpenuhi untuk mengetahui residual dari data berdistribusi normal. Pengujian normalitas dilakukan dengan menggunakan uji *Kolmogorov-Smirnov*. Berikut hasil uji *Kolmogorov-Smirnov* dapat dilihat dibawah ini.



Gambar 4.8 Distribusi Normal Residual Pipa Galvalum A

Berdasarkan Gambar 4.8 hasil uji *Kolmogorov-Smirnov* diketahui bahwa nilai P_value sebesar 0,150 maka $P_value (0,150) > \alpha (0,05)$ jadi keputusannya gagal tolak H_0 sehingga kesimpulannya residual pada data jumlah permintaan pipa Hollow Galvalum A sudah berdistribusi normal.

Karena model regresi sudah memenuhi asumsi residual identik, independen, dan distribusi normal, maka model dugaan sudah bisa digunakan sebagai model peramalan yang bisa dibandingkan dengan metode lainnya untuk mendapatkan metode terbaik sebagai nilai peramalan pada pipa hollow galvalum A.

4.5 Peramalan Jumlah Permintaan Pipa Galvalum A dengan Menggunakan Metode yang Terbaik.

Sebelum melakukan peramalan pada jumlah permintaan pipa galvalum A sebanyak 12 periode kedepan, hal yang perlu dilakukan adalah membandingkan metode peramalan yang terbaik antara metode *ARIMA Box-Jenkins*, metode *Moving*

Average, dan metode regresi time series dengan melihat nilai MSE, RMSE dan sMAPE dari nilai data Outsampel kedua metode. Hasil perhitungannya sebagai berikut

Tabel 4.10 Perbandingan Metode ARIMA, *Moving Average*, Regresi *Time Series* pada Jumlah Permintaan Pipa Galvalum A

Metode	MSE	sMAPE
ARIMA ([3],0,[3])	1287698939	1,23
Moving Average Length 7	951445289,3	0,892
Regresi <i>Time Series</i>	1482834651	0,941

Dari Tabel 4.10 diatas terlihat bahwa metode peramalan yang terbaik untuk jumlah permintaan pipa galvalum A adalah dengan menggunakan metode *Moving Average* dengan Length 7. Hasil ramalan dari pipa hollow galvalum A adalah.

Tabel 4.11 Hasil Ramalan Pipa Hollow Galvalum A

Bulan	Jumlah Permintaan	Bulan	Jumlah permintaan
Januari	21724	Juli	21724
Februari	21724	Agustus	21724
Maret	21724	September	21724
April	21724	Oktober	21724
Mei	21724	Nopember	21724
Juni	21724	Desember	21724


4.6 Pemodelan Jumlah permintaan Pipa Galvalum B dengan menggunakan Metode ARIMA

Langkah awal dalam melakukan analisis peramalan dengan menggunakan metode ARIMA Box Jenkins adalah membagi data menjadi data traing dan data testing. Selanjutnya dibentuk model dengan menggunakan data training dan model divalidasi dengan menggunakan data testing. Tahapan dalam pembentukan model adalah identifikasi model, signifikansi parameter, dan cek diagnosis dari residual model apakah telah memenuhi asumsi atau

belum. Setelah didapatkan beberapa model dugaan, model dugaan tersebut divalidasi dengan membandingkan nilai sMAPE dari data outsample atau data testing. Berikut merupakan tahapan dalam pembentukan model ARIMA dengan menggunakan data training.


4.6.1 Identifikasi Model Permintaan Pipa Galvalum B

Identifikasi model disini adalah dengan melihat time series plot dari data permintaan pipa galvalum B untuk melihat pola data yang selanjutnya melihat plot ACF dan PACF nya untuk membentuk modelnya. Namun sebelum membentuk model, data harus stasioner terhadap means dan varian. Berikut adalah time series plot dari pipa galvalum B.




Gambar 4.9 Time Series Plot Pipa Galvalum B.

Pada Gambar 4.9 diatas, terlihat bahwa data telah stasioner terhadap mean. Dalam time series plot tersebut terlihat bahwa terjadi peningkatan permintaan pipa pada bulan September tahun 2015 dan bulan Februari pada tahun 2016, dilihat dari pola datanya, data tidak mengalami gejala musiman yaitu terjadi pengulangan order pada bulan yang sama disetiap tahunnya. Dengan melihat pola data tersebut dapat dikatakan bahwa data jumlah permintaan pipa hollow galvalum B belum stasioner terhadap varians. Hal ini bisa dilihat dari nilai lambda dari hasil transformasi box-cox pada Gambar 4.10 berikut.



Gambar 4.10 Hasil Transformasi box cox pipa Galvalum B

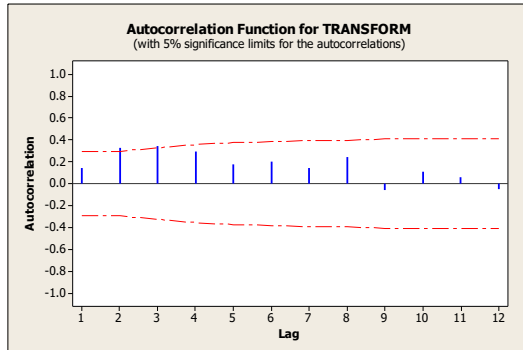
Pada Gambar 4.10 diatas, terlihat bahwa nilai lambda senilai 0,32 yang berarti bahwa data belum stasioner terhadap varians. Oleh sebab itu, data di transformasi akar pangkat 4 agar data stasioner terhadap varians. nilai lambda setelah data permintaan pipa tersebut di ditransformasi sebagai berikut.



Gambar 4.11 Hasil Transformasi Box Cox pada permintaan Pipa Galvalum B yang ditransformasi Akar Pangkat 4

Dari gambar diatas terlihat bahwa nilai rounded value sudah bernilai 1. Sehingga dapat dikatakan bahwa data sudah stasioner terhadap varians. Selanjutnya untuk melihat kestasioneran data terhadap mean, dapat dilihat dari plot ACF dari data yang

sudah di transformasikan. Plot dari ACF ditampilkan dalam bentuk Gambar 4.12 berikut.



Gambar 4.12 Plot ACF Permintaan pipa galvalum B

Dari Gambar ACF diatas terlihat bahwa plot sudah berada didalam batas ACF sehingga dapat dikatakan bahwa data sudah stasioner terhadap mean. Untuk lebih memastikan lagi, maka dilakukan uji Augmented Dickey Fuller.


Hipotesis :

H_0 : $\delta = 0$ (Terdapat akar unit, variabel Z tidak stasioner)

H_1 : $\delta \neq 0$ (Tidak terdapat akar unit, variabel Z stasioner).

Tingkat Signifikan : 5%

Dari hasil analisis didapatkan hasil $t_{\hat{\delta}}$ senilai $-6,051964$ dengan P_value sebesar $0,000$ sehingga dapat diputuskan tolak H_0 karena P_Value lebih kecil dari $0,05$. Sehingga dapat disimpulkan bahwa data permintaan pipa telah stasioner terhadap mean. Untuk membentuk model, perlu diketahui juga plot PACF nya dari jumlah permintaan pipa galvalum. Plot PACF pada Gambar 4.13. Plot ACF dan PACF pada gambar 4.12 dan 4.13 merupakan plot pada data transformasi. Pada gambar 4.12 terlihat bahwa lag yang signifikan dari plot tersebut adalah lag 2 dan 3. Sedangkan pada plot PACF, lag yang signifikan adalah lag 2 dan 3. Sehingga model dugaan sementara yang terbentuk adalah AR ([2,3]), AR ([2]), ARIMA ([2],0,[3]), dan ARIMA ([3],0,[2]).



Gambar 4.13 Plot PACF Jumlah Permintaan Pipa Galvalum B

4.6.2 Estimasi Parameter pada Jumlah Permintaan Pipa Galvalum B

Setelah diidentifikasi model pada data training, maka didapatkan 3 model dugaan yaitu AR([2]), AR([2,3]), ARIMA([2],0,[3]) dan ARIMA([3],0,[2]). Maka langkah selanjutnya adalah melakukan estimasi parameter dan uji signifikansi parameter. Hasil estimasi dan uji signifikansi disajikan dalam bentuk tabel 4.12 berikut.

Tabel 4.12 Pengujian Parameter Jumlah Permintaan pipa galvalum B

Model	Parameter	Estimate	P-value	Kesimpulan
AR ([2,3])	ϕ_2	0,43249	0,0006	Signifikan
	ϕ_3	0,55783	<0,0001	Signifikan
AR ([3])	ϕ_3	0,93813	<0,0001	Signifikan
ARIMA ([2],0,[3])	ϕ_2	0,85041	<0,0001	Signifikan
	θ_3	-0,39648	0,0141	Signifikan
ARIMA ([3],0,[2])	ϕ_3	0,90776	<0,0001	Signifikan
	θ_2	-0,22662	0,1271	Tidak Signifikan

Dari keempat model diatas, terlihat bahwa seluruh paramter pada model memiliki *P_value* lebih kecil dari tingkat signifikan 0,05 sehingga dapat dikatakan bahwa paramter signifikan terhadap model.

4.6.3 Cek Diagnosa Residual Data Jumlah Permintaan Pipa Galvalum B.

Setelah dilakukan estimasi parameter dan pengujian signifikansi parameter, maka dilanjutkan untuk pengujian pada residualnya dari keempat model tersebut. Pengujian ini dilakukan untuk mengetahui apakah residual telah memenuhi asumsi *white noise* dan asumsi normal. Berikut merupakan pengujian asumsi *white noise* pada data jumlah permintaan pipa galvalum B.

Tabel 4.13 Uji *White Noise* Data jumlah permintaan pipa galvalum B.

Model	Lag	P-value	Kesimpulan
AR ([2,3])	6	0,4379	<i>White noise</i>
	12	0,3429	<i>White noise</i>
	18	0,6075	<i>White noise</i>
	24	0,2087	<i>White noise</i>
AR ([3])	6	0,0643	<i>White noise</i>
	12	0,0968	<i>White noise</i>
	18	0,2948	<i>White noise</i>
	24	0,2236	<i>White noise</i>
ARIMA ([2],0,[3])	6	0,1171	<i>White noise</i>
	12	0,0609	<i>White noise</i>
	18	0,1189	<i>White noise</i>
	24	0,0072	Tidak <i>White noise</i>
ARIMA ([3],0,[2])	6	0,4285	<i>White noise</i>
	12	0,3545	<i>White noise</i>
	18	0,6395	<i>White noise</i>
	24	0,5046	<i>White noise</i>

Pada Tabel 4.13 diatas, terlihat bahwa dari keempat model memenuhi asumsi residual *White Noise* yaitu model AR([3]),

AR([2,3]), ARIMA ([2],0,[3]), dan ARIMA ([3],0,[2]). Hal tersebut bisa dibuktikan karena pada lag 6,12,18, dan 24 memiliki *P-Value* lebih dari nilai tingkat signifikan 5% semua yang berarti gagal tolak H_0 . Pengujian selanjutnya adalah uji asumsi pengujian kenormalan residual daalam bentuk Tabel 4.14 berikut.

Tabel 4.14 Uji Kenormalan Residual Jumlah Permintaan Pipa Galvalum B

Model	P-value	Kesimpulan
AR ([2,3])	0,0214	Tidak Berdistribusi Normal
AR ([3])	0,1024	Berdistribusi Normal
ARIMA ([2],0,[3])	>0,1500	Berdistribusi Normal
ARIMA ([3],0,[2])	0,0598	Berdistribusi Normal

Dari Tabel 4.14, terlihat bahwa model AR ([2,3]) tidak berdistribusi normal karena *P-Value* kurang dari 0,05. Sehingga model yang telah memenuhi asumsi distribusi normal adalah AR ([3]). ARIMA ([2],0,[3]) dan ARIMA ([3],0,[2]).

4.6.4 Pemilihan Model terbaik untuk Jumlah Permintaan Pipa Galvalum B dengan metode ARIMA

Langkah selanjutnya adalah memilih model terbaik dari ketiga model dugaan. Model terbaik dipilih berdasarkan data In Sampel dan Out Sampel.

Memilih model terbaik berdasarkan data In Sampel dengan membandingkan nilai AIC dan SBC. Berikut merupakan perbandingan nilai dari 2 kriteria tersebut.

Tabel 4.15 Pemilihan Model Terbaik Jumlah permintaan Pipa Galvalum B berdasarkan In Sampel

Model	AIC	SBC
AR ([3])	283,9141	285,785
ARIMA ([2],0,[3])	286,4173	290,1597
ARIMA ([3],0,[2])	282,979	286,7214

Dari Tabel 4.15 diatas, terlihat bahwa model terbaik jika ditinjau dari nilai AIC maka model terbaiknya adalah ARIMA ([3],0,[2]) namun jika ditinjau dari nilai SBC maka model terbaiknya adalah AR ([3]). Untuk memastikannya lagi, dapat dilihat dari data outsamplel.

Memilih model terbaik berdasarkan data out sampel dengan membandingkan nilai MSE dan sMAPE dari ketiga model. Berikut merupakan perbandingan nilai dari kedua kriteria tersebut.

Tabel 4.16 Pemilihan Model Terbaik Untuk Pipa Galvalum ukuran B berdasarkan Out Sampel

Model	MSE	sMAPE
AR ([3])	2639510066	1,242
ARIMA ([2],0,[3])	3168828210	1,631
ARIMA ([3],0,[2])	2824678118	1,390

Dari perbandingan nilai pada 2 kriteria tersebut, dapat disimpulkan bahwa model terbaik dipilih berdasarkan hasil *Out Sampel* yang berfungsi sebagai validasi model. Model ARIMA terbaik untuk pipa galvalum B adalah AR ([3]). Berikut penjabaran model AR ([3]) :


$$Z_t = 0,93813Z_{t-3} + a_t$$

Model diatas menjelaskan bahwa jumlah permintaan pipa galvalum B pada bulan ke-t adalah 0,93813 kali dari jumlah permintaan pada (t-3) ditambah jumlah kesalahan perkiraan pada bulan ke-t.

4.7 Pemodelan Jumlah Permintaan Pipa Hollow Galvalum B Menggunakan Metode *Moving Average*.

Langkah awal dalam menggunakan metode *moving average* adalah menentukan length atau jumlah m sebagai sekelompok data yang akan di rata – rata bergerak. Setelah dilakukan *trial and error* dari beberapa nilai m, maka didapatkan 2 jumlah m yang memiliki nilai MAPE dan MSD yang bernilai kecil dibandingkan

nilai m lainnya. m tersebut bernilai 3 dan 7 seperti digambarkan dalam plot berikut.



Gambar 4.14 Hasil Analisis *Moving Average* pada Pipa Galvalum B

Dari gambar 4.14 diatas terlihat bahwa nilai fit mengikuti gerak dari data asli dan didapatkan nilai MSD pada length 3 sebesar 419449016 sedangkan pada length 7 sebesar 427761232. Untuk melihat model dengan length yang terbaik, dapat dilihat dari perhitungan MSE dan sMAPE dari data out sampel. Hasil perhitungannya sebagai berikut.

Tabel 4.17 Pemilihan Length Terbaik Metode MA pada Jumlah Permintaan Pipa Galvalum B

LENGTH	MSE	sMAPE
3	2017397339	0,722098
7	1432183391	0,654132

Dari Tabel 4.17 diatas terlihat bahwa jumlah *length* yang paling baik adalah length 7 karena memiliki nilai MSE dan nilai sMAPE lebih kecil dibandingkan dengan length 3.

4.8 Pemodelan Jumlah Permintaan Pipa Hollow Galvalum B Menggunakan Metode Regresi *Time Series*.

Regresi *Time Series* menggunakan data transformasi akar pangkat 4 agar data memenuhi asumsi residual. Selanjutnya untuk membentuk variabel prediktor yang signifikan sehingga dugaan

variabel prediktor yang akan mempengaruhi variabel respon adalah variabel Y_{t-4} .

4.8.1 Estimasi Model dan Signifikansi Parameter Data Jumlah Permintaan Pipa Hollow Galvalum B dengan Regresi Time Series.

Setelah didapatkan dugaan variabel prediktor, maka terbentuk model dugaan sebagai berikut.

$$Y_t = 6,918 + 0,3595Y_{t-4}$$

Selanjutnya parameter dari model regresi *time series* diatas, dilakukan pengujian parameter untuk mengetahui apakah parameter tersebut signifikan terhadap model. Pengujiannya sebagai berikut.

Hipotesis :

$$H_0 : \beta_i = 0 \text{ (parameter tidak signifikan)}$$

$$H_1 : \beta_i \neq 0 \text{ (parameter signifikan)}$$

Taraf Signifikan : $\alpha = 0,05$

Daerah Kritis : Tolak H_0 jika $P\text{-value} < 0,05$

Tabel 4.18 Pengujian Parameter Data Jumlah Permintaan Pipa Hollow Galvalum B Dengan Regresi *Time Series*.

Parameter	Estimate	T	P-value	Kesimpulan
Konstanta	6,918	4,49	0,000	Signifikan
Y_{t-4}	0,3595	2,48	0,017	Signifikan

Dari Tabel 4.18, dapat dilihat bahwa seluruh variabel prediktor dan konstanta sudah signifikan karena P_Value memiliki nilai lebih dari 0,05. Sehingga dapat dikatakan variabel tersebut berpengaruh terhadap model. Dengan kata lain, jumlah permintaan pipa hollow galvalum B sekarang ditentukan oleh 6,918 ditambah 0,3595 kali data transformasi jumlah permintaan pada 4 bulan sebelumnya.

4.8.2 Pengujian Asumsi Residual Data Jumlah Permintaan Pipa Hollow Galvalum B.

Asumsi yang harus terpenuhi dalam analisis regresi adalah identik, independen, dan distribusi normal. Berikut merupakan pengujiannya.

Asumsi homoskedastisitas adalah variansi residual bersifat identik. Berikut adalah pengujian dengan menggunakan uji Glejser.

Hipotesis:

H_0 : Tidak ada kasus heteroskedastisitas (Identik)

H_1 : Ada kasus heteroskedastisitas

Tabel 4.19 Uji Glejser Data Permintaan Pipa Galvalum B

Parameter	P-value
Konstanta	0,044
Y_{t-4}	0,956


Berdasarkan Tabel 4.19 menjelaskan bahwa nilai P_value pada seluruh variabel prediktor tersebut $> \alpha$ (0,05) yang berarti terjadi sudah memenuhi asumsi identik dengan kata lain varians residual bersifat konstan.

Pendeteksian adanya otokorelasi salah satunya dapat menggunakan uji Durbin Watson. Seperti yang terlihat pada Lampiran, diketahui bahwa nilai durbin watson sebesar 2,23053 sedangkan nilai d_u sebesar 1,6231 dan d_L sebesar 1,4500 pada tingkat signifikansi $\alpha = 0,05$ maka hasil Durbin watson gagal tolak H_0 karena d_u (1,6231) $< d(2,23053) < 4-d_u$ (2,3769). Hal ini menunjukkan bahwa residual tidak ada autokorelasi.

Uji asumsi normalitas harus terpenuhi untuk mengetahui residual dari data berdistribusi normal. Pengujian normalitas dilakukan dengan menggunakan uji *Kolmogorov-Smirnov*. Berikut hasil uji *Kolmogorov-Smirnov* dapat dilihat dibawah ini.

Berdasarkan Gambar 4.15 hasil uji *Kolmogorov-Smirnov* diketahui bahwa nilai P_value sebesar 0,086 maka P_value

$(0,086) > \alpha (0,05)$ jadi keputusannya gagal tolak H_0 sehingga kesimpulannya residual pada data jumlah permintaan pipa Hollow Galvalum B sudah berdistribusi normal.



Gambar 4.15 Distribusi Normal Residual Pipa Galvalum B

Karena model regresi sudah memenuhi asumsi residual identik, independen, dan distribusi normal, maka model dugaan sudah bisa digunakan sebagai model peramalan.

4.9 Peramalan Jumlah Permintaan Pipa Galvalum B dengan Menggunakan Metode yang Terbaik.

Sebelum melakukan peramalan pada jumlah permintaan pipa galvalum B sebanyak 12 periode kedepan, hal yang perlu dilakukan adalah membandingkan metode peramalan yang terbaik antara metode *ARIMA Box-Jenkins*, metode *Moving Average*, dan metode Regresi Time Series dengan melihat nilai MSE dan sMAPE dari nilai data Outsampel ketiga metode. Hasil perhitungannya sebagai berikut

Tabel 4.20 Perbandingan Metode *ARIMA*, *Moving Average*, dan Regresi *Time Series* pada Jumlah Permintaan Pipa Galvalum B

Model	MSE	sMAPE
AR ([3])	2639510066	1,242
<i>Moving Average Length 7</i>	1432183391	0,654
Regresi <i>Time Series</i>	2220165181	0,909

Dari Tabel 4.20 diatas terlihat bahwa metode peramalan yang terbaik untuk jumlah permintaan pipa galvalum B adalah dengan menggunakan metode *Moving Average* dengan length 7. Sehingga peramalan untuk jumlah permintaan pipa galvalum B menggunakan metode *Moving Average Length 7*. Hasil ramalannya sebagai berikut.

Tabel 4.21 Hasil Ramalan Pipa Hollow galvalum B

Bulan	Jumlah Permintaan	Bulan	Jumlah Permintaan
Januari	30696	Juli	30696
Februari	30696	Agustus	30696
Maret	30696	September	30696
April	30696	Oktober	30696
Mei	30696	Nopember	30696
Juni	30696	Desember	30696

4.10 Pemodelan Jumlah permintaan Pipa Galvalum C menggunakan Metode ARIMA


Langkah awal dalam melakukan analisis peramalan dengan menggunakan metode ARIMA Box Jenkins adalah membagi data menjadi data training dan data testing.

4.10.1 Identifikasi model permintaan pipa galvalum C

Identifikasi model disini adalah dengan melihat time series plot dari data permintaan pipa galvalum C yang selanjutnya melihat plot ACF dan PACF nya untuk membentuk modelnya. Time series plot dari jumlah permintaan pipa galvalum C dapat dilihat dari Gambar 4.16.

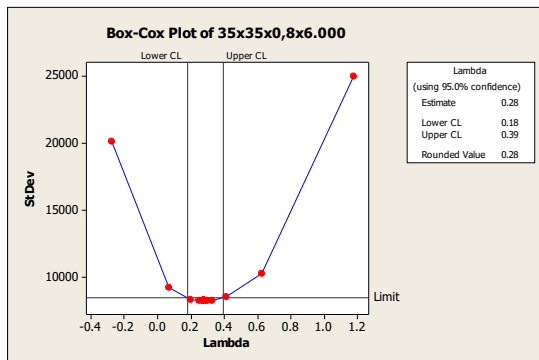
Pada Gambar 4.16, terlihat bahwa data tidak teratur dan tidak memiliki pola tertentu. Pada time series plot tersebut terlihat bahwa terjadi peningkatan permintaan pipa pada bulan September 2015 dan Februari tahun 2016, namun terlihat data tidak bergerak

disekitar nilai rata-ratanya dan juga belum stasioner terhadap varians.



Gambar 4.16 Time Series Plot Pipa Galvalum Ukuran C


Untuk melihat kestasioneran terhadap varians, maka dapat melihat *rounded value* pada transformasi box-cox. Hasil transformasi box-cox dapat dilihat pada Gambar 4.17 berikut.



Gambar 4.17 Hasil Transformasi Box Cox pipa Galvalum C

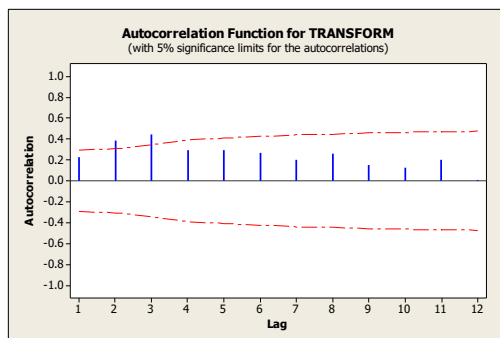
Pada Gambar 4.17 diatas, terlihat bahwa *rounded value* memiliki nilai 0,28 yang berarti data belum stasioner terhadap varians. Oleh sebab itu, data di transformasi akar pangkat empat

agar data stasioner terhadap varians. hasil transformasi sebagai berikut.



Gambar 4.18 Hasil Transformasi Box Cox permintaan Pipa Galvalum C yang ditransformasi akar pangkat 4

Pada Gambar 4.18 diatas, terlihat bahwa rounded value sudah bernilai 1, dapat dikatakan bahwa data sudah stasioner terhadap varians, Selanjutnya untuk melihat kestasioneran data terhadap mean, dapat dilihat dari plot ACF dari data yang sudah di transformasikan. Plotnya sebagai berikut.



Gambar 4.19 Plot ACF Jumlah Permintaan pipa galvalum C

Dari gambar ACF diatas terlihat bahwa plot pada lag ke-2 & 3 ada yang melebihi batas ACF sehingga dapat dikatakan

bahwa data belum stasioner terhadap mean. Untuk lebih memastikan lagi, maka dilakukan uji Augmented Dickey Fuller.


Hipotesis :

$H_0 : \delta = 0$ (Terdapat akar unit, variabel Z tidak stasioner)

$H_1 : \delta \neq 0$ (Tidak terdapat akar unit, variabel Z stasioner).

Tingkat Signifikan : 5%

Dari hasil analisis didapatkan nilai $t_{\hat{\delta}}$ sebesar -1,952546 dengan P_value sebesar 0,3061 memiliki nilai lebih dari 0,05 dapat diputuskan gagal tolak H_0 . Sehingga dapat disimpulkan bahwa data permintaan pipa galvalum C belum stasioner terhadap mean. Untuk mengatasinya maka data jumlah permintaan pipa hollow galvalum C di *Differencing* satu kali. Selanjutnya dilihat plot ACF dan uji ADF dari data yang di transformasi dan di differencing sebagai berikut.



Gambar 4.20 Plot ACF Permintaan Pipa Galvalum C setelah Dfferencing

Dari gambar diatas, terlihat bahwa plot cut off setelah lag ke-1, sehingga dapat dikatakan bahwa data telah stasioner terhadap mean. Untuk lebih memastikan bisa dilihat dari uji ADF sebagai berikut.

Hipotesis :


$H_0 : \delta = 0$ (Terdapat akar unit, variabel Z tidak stasioner)

$H_1 : \delta \neq 0$ (Tidak terdapat akar unit, variabel Z stasioner).

Tingkat Signifikan : 5%

Dari uji ADF didapatkan hasil nilai $t_{\hat{\delta}}$ sebesar $-9,761680$ dengan P_value senilai $0,000$, dapat disimpulkan bahwa data telah stasioner terhadap mean karena P_Value kurang dari 5%, sehingga dapat diputuskan tolak H_0 yang berarti data telah stasioner terhadap mean.

Dalam pembentuk model, selain plot ACF yang perlu diketahui juga adalah plot PACF nya dari data jumlah permintaan pipa galvalum yang telah di transformasi kuadrat dan telah di *differencing*. Plot PACF dari data transformasi tersebut ditampilkan dalam bentuk Gambar 4.21 sebagai berikut.



Gambar 4.21 Plot PACF Jumlah Permintaan Pipa Galvalum C

Plot ACF dan PACF pada Gambar 4.20 dan 4.21 merupakan plot pada data transformasi. Pada gambar 4.20 terlihat bahwa lag yang signifikan dari plot ACF tersebut adalah lag 1. Sedangkan pada plot PACF pada Gambar 4.21, lag yang signifikan adalah lag 1 dan 2. Sehingga model dugaan sementara yang terbentuk adalah ARIMA (2,1,0) dan ARIMA (0,1,1).

4.10.2 Estimasi Parameter pada Jumlah Permintaan Pipa Galvalum C

Setelah diidentifikasi model pada data training, maka didapatkan 2 model dugaan yaitu ARIMA (2,1,0) dan ARIMA

(0,1,1). Maka langkah selanjutnya adalah melakukan estimasi parameter dan uji signifikansi parameter. Hasil estimasi dan uji signifikansi disajikan dalam bentuk tabel 4.20 berikut.

Tabel 4.22 Pengujian Parameter Jumlah Permintaan Pipa Galvalum C

Model	Parameter	Estimate	P-value	Kesimpulan
ARIMA (2,1,0)	ϕ_1	-0,88331	<0,0001	Signifikan
	ϕ_2	-0,51630	0,0006	Signifikan
ARIMA (0,1,1)	θ_1	0,77061	<0,0001	Signifikan

Dari kedua model diatas, terlihat bahwa dari kedua model memiliki *P_value* lebih kecil dari tingkat signifikan 0,05 yang berarti tolak H_0 . Sehingga dapat dikatakan bahwa seluruh paramater pada kedua model dugaan tersebut telah signifikan terhadap model.

4.10.3 Cek Diagnosa Residual data Jumlah Permintaan Pipa Galvalum C.

Setelah dilakukan estimasi parameter dan pengujian signifikansi parameter, maka dilanjutkan untuk pengujian pada residualnya dari kedua model tersebut. Pengujian ini dilakukan untuk mengetahui apakah residual telah memenuhi asumsi *white noise* dan asumsi normal. Berikut merupakan pengujian asumsi *white noise* pada data jumlah permintaan pipa galvalum C

Tabel 4.23 Uji *White Noise* Data Jumlah Permintaan Pipa Galvalum C

Model	Lag	P-value	Kesimpulan
ARIMA (2,1,0)	6	0,7810	<i>White noise</i>
	12	0,6303	<i>White noise</i>
	18	0,7228	<i>White noise</i>
	24	0,5481	<i>White noise</i>
ARIMA (0,1,1)	6	0,5225	<i>White noise</i>
	12	0,6227	<i>White noise</i>
	18	0,8771	<i>White noise</i>
	24	0,2164	<i>White noise</i>

Pada Tabel 4.23 diatas, terlihat bahwa dua model diatas memenuhi asumsi residual *White Noise*. Hal tersebut bisa dibuktikan karena pada lag 6,12,18, dan 24 memiliki *P-Value* lebih dari nilai tingkat signifikan 5% semua yang berarti gagal tolak H_0 .

Pengujian kenormalan residual dilakukan dengan menggunakan uji kolmogorov-smirnov. Berikut ditampilkan hasil uji kenormalan residual dalam bentuk Tabel 4.24.

Tabel 4.24 Uji Kenormalan Residual Data Jumlah Permintaan Pipa Galvalum C

Model	P-value	Kesimpulan
ARIMA (2,1,0)	0,0739	Berdistribusi Normal
ARIMA (0,1,1)	>0,1500	Berdistribusi Normal

Dari Tabel 4.24 diatas, terlihat bahwa kedua model telah memenuhi asumsi residual normal. Hal tersebut dapat dibuktikan dengan melihat *P-Value* lebih besar dari tingkat signifikan 0,05 yang berarti gagal tolak H_0 .

4.10.4 Pemilihan Model terbaik Jumlah Permintaan Pipa Galvalum C dengan metode ARIMA

Langkah selanjutnya adalah memilih model terbaik dari kedua model dugaan. Model terbaik dipilih berdasarkan data In Sampel dan Out Sampel Memilih model terbaik berdasarkan data In Sampel dengan membandingkan nilai AIC dan SBC. Berikut merupakan perbandingan nilai dari 2 kriteria tersebut.

Tabel 4.25 Pemilihan Model Terbaik untuk Jumlah permintaan Pipa Galvalum C berdasarkan In Sampel

Model	AIC	SBC
ARIMA (2,1,0)	264,3115	268,0228
ARIMA (0,1,1)	265,5351	267,3852

Dari tabel diatas, terlihat bahwa model terbaik berdasarkan data insampel adalah model ARIMA (2,1,0) karena memiliki nilai AIC lebih kecil dibandingkan model ARIMA (0,1,1). Namun jika ditinjau dari SBC, model terbaiknya adalah ARIMA (0,1,1).. Sehingga perlu dilihat lagi model terbaik berdasarkan kriteria dari data Out sampel.

Memilih model terbaik berdasarkan data out sampel dengan membandingkan nilai MSE dan sMAPE dari kedua model. Berikut merupakan perbandingan nilai dari kedua kriteria tersebut.

Tabel 4.26 Pemilihan Model Terbaik Jumlah permintaan Pipa Galvalum C berdasarkan Out Sampel

Model	MSE	sMAPE
ARIMA (2,1,0)	3131361458	0,606606
ARIMA (0,1,1)	2500058757	0,783311

Dari perbandingan nilai pada 2 kriteria tersebut, terlihat bahwa model terbaiknya adalah model ARIMA (2,1,0) karena memiliki nilai sMAPE lebih kecil dibandingkan model ARIMA (0,1,1).

Penjabaran model ARIMA (2,1,0) sebagai berikut :


$$Z_t = 0,1169Z_{t-1} + 0,36701Z_{t-2} + 0,51630Z_{t-3} + a_t$$

Model diatas menjelaskan bahwa jumlah permintaan pipa galvalum C pada bulan ke-t adalah 0,1169 kali jumlah permintaan pipa pada (t-1) ditambah 0,36701 kali jumlah permintaan pada (t-2) ditambah 0,51630 kali jumlah permintaan pada (t-3) ditambah jumlah kesalahan pada bulan ke t.

4.11 Pemodelan Jumlah Permintaan Pipa Hollow Galvalum C Menggunakan Metode *Moving Average*.

Langkah awal dalam menggunakan metode *moving average* adalah menentukan length atau jumlah m sebagai sekelompok data yang akan di rata – rata bergerak. Setelah dilakukan *trial and error* dari beberapa nilai m, maka didapatkan 2

jumlah m yang memiliki nilai MAPE dan MSD yang bernilai kecil dibandingkan nilai m lainnya. m tersebut bernilai 4 dan 7 seperti pada Gambar 4.22 dalam plot berikut.



Gambar 4.22 Hasil Analisis MA pada Pipa Galvalum C

Dari Gambar 4.22 diatas terlihat bahwa nilai fit mengikuti gerak dari data asli dan didapatkan nilai MSD pada length 4 sebesar 370778514 sedangkan pada length 7 sebesar 363835184. Untuk melihat model dengan length yang terbaik, dapat dilihat dari perhitungan MSE dan sMAPE dari data out sampel. Hasil perhitungannya sebagai berikut.

Tabel 4.27 Pemilihan Length Terbaik Metode MA pada Jumlah Permintaan Pipa Galvalum C

Length	MSE	sMAPE
4	1555733125	0,737053
7	1609297729	0,727739

Dari Tabel 4.27 diatas terlihat bahwa terdapat perbandingan nilai MSE dan sMAPE dari 2 *length* pada metode *Moving Average*. Jumlah *length* yang paling baik dari Tabel 4.27 adalah *length* 7 karena memiliki nilai sMAPE sebesar 0,7278 lebih kecil dibandingkan dengan *length* 4 sebesar 0,737. Maka selanjutnya metode *moving average* dengan menggunakan *length* 7 yang digunakan sebagai pembandingan dengan metode ARIMA dan regresi time series untuk mendapatkan model peramalan yang terbaik.

4.12 Pemodelan Jumlah Permintaan Pipa Hollow Galvalum C Menggunakan Metode Regresi *Time Series*.

Regresi *Time Series* menggunakan data transformasi akar pangkat 4. variabel prediktor yang diduga mempengaruhi variabel respon adalah $Y_{t-1}, Y_{t-5}, Y_{t-15}, Y_{t-18}, Y_{t-20}, Y_{t-24}$, dan Y_{t-29} .

4.12.1 Estimasi Model dan Signifikansi Parameter Data Jumlah Permintaan Pipa Hollow Galvalum C dengan Regresi *Time Series*.

Setelah didapatkan dugaan variabel prediktor, maka terbentuk model dugaan sebagai berikut.

$$Y_t = 22,4 - 0,359Y_{t-1} - 0,445Y_{t-5} + 0,598Y_{t-15} - 0,847Y_{t-18} - 0,549Y_{t-20} + 0,308Y_{t-24} + 0,480Y_{t-29} + \varepsilon_t$$

Selanjutnya parameter dari model regresi *time series* diatas, dilakukan pengujian parameter. Pengujiannya sebagai berikut.

Hipotesis :

$$H_0 : \beta_i = 0 \text{ (parameter tidak signifikan)}$$

$$H_1 : \beta_i \neq 0 \text{ (parameter signifikan)}$$

Taraf Signifikan : $\alpha = 0,05$

Daerah Kritis : Tolak H_0 jika $P\text{-value} < 0,05$

Tabel 4.28 Pengujian Parameter Data Jumlah Permintaan Pipa Hollow Galvalum C Dengan Regresi *Time Series*.

Parameter	Estimate	T	P-value	Kesimpulan
Konstanta	22,427	9,48	0,000	Signifikan
Y_{t-1}	-0,3591	-3,42	0,006	Signifikan
Y_{t-5}	-0,4447	-3,55	0,005	Signifikan
Y_{t-15}	-0,5976	5,02	0,000	Signifikan
Y_{t-18}	-0,8468	-6,31	0,000	Signifikan
Y_{t-20}	-0,5488	-5,42	0,000	Signifikan
Y_{t-24}	0,3078	2,85	0,016	Signifikan
Y_{t-29}	0,4795	3,71	0,003	Signifikan

Dari Tabel 4.28, dapat dilihat bahwa variabel seluruh variabel prediktor dan konstanta sudah signifikan karena *P_Value* memiliki nilai lebih dari 0,05. Sehingga dapat dikatakan bahwa model tersebut bisa digunakan sebagai peramalan.

4.12.2 Pengujian Asumsi Residual Data Jumlah Permintaan Pipa Hollow Galvalum C.

Asumsi yang harus terpenuhi dalam analisis regresi adalah identik, independen, dan distribusi normal. Berikut merupakan pengujiannya. Asumsi homoskedastisitas adalah variansi residual bersifat identik. Berikut adalah pengujian dengan menggunakan uji Glejser.

Hipotesis:

H_0 : Tidak ada kasus heteroskedastisitas (Identik)

H_1 : Ada kasus heteroskedastisitas

Tabel 4.29 Uji Glejser Data Permintaan Pipa Galvalum C


Parameter	P-value	Kesimpulan
Konstanta	0,299	Tidak Signifikan
Y_{t-1}	0,413	Tidak Signifikan
Y_{t-5}	0,914	Tidak Signifikan
Y_{t-15}	0,748	Tidak Signifikan
Y_{t-18}	0,896	Tidak Signifikan
Y_{t-20}	0,062	Tidak Signifikan
Y_{t-24}	0,300	Tidak Signifikan
Y_{t-29}	0,589	Tidak Signifikan

Berdasarkan Tabel 4.29 menjelaskan bahwa nilai *P_value* pada seluruh variabel prediktor tersebut $> \alpha$ (0,05) yang berarti terjadi sudah memenuhi asumsi identik dengan kata lain variansi residual bersifat konstan.

Pendeteksian adanya otokorelasi salah satunya dapat menggunakan uji Durbin Watson. Seperti yang terlihat pada lampiran, diketahui bahwa nilai durbin watson sebesar 1,86455

sedangkan nilai d_u sebesar 1,6231 dan d_L sebesar 1,4500 pada tingkat signifikansi $\alpha = 0,05$ maka hasil Durbin Watson gagal tolak H_0 karena d_u (1,6231) < $d(1,86455)$ < $4-d_u$ (2,3769). Hal ini menunjukkan bahwa residual tidak ada autokorelasi dan bersifat Independen.

Pengujian normalitas dilakukan dengan menggunakan uji *Kolmogorov – Smirnov*. Berikut hasil uji *Kolmogorov – Smirnov* dapat dilihat dibawah ini.



Gambar 4.23 Distribusi Normal Residual Pipa Galvalum C

Berdasarkan Gambar 4.23 hasil uji *Kolmogorov-Smirnov* diketahui bahwa nilai P_value sebesar 0,150 maka P_value (0,150) > α (0,05) jadi keputusannya gagal tolak H_0 sehingga kesimpulannya residual pada data jumlah permintaan pipa Hollow Galvalum C sudah berdistribusi normal.

4.13 Peramalan Jumlah Permintaan Pipa Galvalum C dengan Menggunakan Metode yang Terbaik.

Sebelum melakukan peramalan pada jumlah permintaan pipa galvalum C sebanyak 12 periode kedepan, hal yang perlu dilakukan adalah membandingkan metode peramalan yang terbaik antara metode *ARIMA Box-Jenkins*, metode *Moving Average*, dan *Regresi Time Series* dengan melihat nilai sMAPE dan MSE dari nilai data Outsampel kedua metode. Hasil perhitungannya sebagai berikut

Tabel 4.30 Perbandingan Metode ARIMA Movig Average, dan Regresi *Time Series* pada Jumlah Permintaan Pipa Galvalum C

Model	MSE	sMAPE
ARIMA (2,1,0)	3131361458	0,607
<i>Moving Average Length 7</i>	1609297729	0,728
Regresi <i>Time Series</i>	1799016486	0,835

Dari tabel 4.28 diatas terlihat bahwa metode peramalan yang terbaik untuk jumlah permintaan pipa galvalum C adalah dengan menggunakan model ARIMA (2,1,0). Karena memiliki nilai sMAPE sebesar 0,607 lebih kecil dibandingkan dengan nilai sMAPE dari metode *Moving average* dengan *length 7* dan Rege-si *Time Series*. Hasil ramalannya adalah sebagai berikut.

Tabel 4.31 Hasil Ramalan Pipa Galvalum C

Bulan	Jumlah Permintaan	Bulan	Jumlah Permintaan
Januari	29037	Juli	22626
Februari	23873	Agustus	22033
Maret	19113	September	22225
April	24242	Oktober	22277
Mei	21834	Nopember	22173
Juni	21860	Desember	22235

Dari Tabel 4.31 terlihat bahwa jumlah permintaan untuk pipa galvalum C terrjadi pada bulan April.


4.14 Pemodelan Jumlah permintaan Pipa Galvalum D dengan menggunakan Metode ARIMA

Langkah awal dalam melakukan analisis peramalan dengan menggunakan metode ARIMA Box Jenkins adalah membagi data menjadi data traing dan data testing. Data training sebanyak 48 data digunakan sebagai pembentuk model. Sedangkan data testing

sebanyak 12 data digunakan sebagai validasi model yang telah didapat. Tahapan dalam pembentukan model adalah identifikasi model, estimasi dan signifikansi para meter, serta cek diagnostik residual.

4.14.1 Identifikasi Model Permintaan Pipa Galvalum D


Identifikasi model disini adalah dengan melihat time series plot dari data permintaan pipa galvalum D yang selanjutnya melihat plot ACF dan PACF nya untuk membentuk modelnya. Berikut adalah time series plot dari pipa galvalum D.



Gambar 4.24 Time Series Plot Pipa Galvalum D


Pada gambar diatas, terlihat bahwa data tidak teratur dan tidak memiliki pola tertentu. Pada time series plot tersebut terlihat bahwa terjadi peningkatan permintaan pipa pada bulan September tahun 2015 dan Maret pada tahun 2016, terlihat data bergerak disekitar nilai rata-ratanya namun belum stasioner terhadap varians. Hal ini bisa dilihat dari hasil transformasi box cox pada gambar berikut.

Pada Gambar 4.25 diatas, terlihat bahwa rounded value memiliki nilai 0,26 yang berarti bahwa data belum stasioner terhadap varians. Oleh sebab itu, data di transformasi akar pangkat 4 agar data stasioner terhadap varians.



Gambar 4.25 Hasil Transformasi Box Cox pipa Galvalum D

hasil *lambda* setelah data permintaan pipa tersebut di ditransformasi akar pangkat empat sebagai berikut.




Gambar 4.26 Hasil Transformasi Box Cox pada permintaan Pipa Galvalum D yang ditransformasi akar pangkat 4

Pada Gambar 4.26 diatas, terlihat bahwa nilai rounded value sudah bernilai 1. Sehingga dapat dikatakan bahwa data sudah stasioner terhadap varians dengan transformasi akar pangkat 4. Selanjutnya untuk melihat kestasioneran data terhadap mean, dapat dilihat dari plot ACF dari data yang sudah di transformasikan. Plot ditampilkan dalam Gambar 4.27.

Dari Gambar 4.27 terlihat bahwa plot sudah berada didalam batas ACF dan terdapat 1 lag yang signifikan atau keluar batas yaitu pada lag ke - 3, sehingga dapat dikatakan bahwa data

jumlah permintaan pipa hollow galvalum D telah stasioner terhadap mean.



Gambar 4.27 Plot ACF Permintaan Pipa Galvalum D

Untuk lebih memastikan lagi, maka dilakukan uji Augmented Dickey Fuller.

Hipotesis :

$H_0 : \delta = 0$ (Terdapat akar unit, variabel Z tidak stasioner)


$H_1 : \delta \neq 0$ (Tidak terdapat akar unit, variabel Z stasioner).

Tingkat Signifikan : 5%

Dari hasil analisis didapatkan nilai $t_{\hat{\delta}}$ sebesar -5,154308 dengan P_value sebesar 0,0001. Dapat diputuskan tolak H_0 karena P_value kurang dari 0,05. Sehingga dapat disimpulkan bahwa data permintaan pipa telah stasioner terhadap mean. Selanjutnya untuk mendapatkan model dugaan dapat dilihat dari nilai ACF dan PACF nya.

Nilai ACF sudah digambarkan pada Gambar 4.27 sedangkan nilai PACF digambarkan dalam bentuk Gambar 4.28 yang ada dihalam 69. Dari kedua plot tersebut, menunjukkan hasil bahwa pada plot ACF lag yang signifikan adalah lag ke 2 dan ke 3. Sedangkan plot PACF lag yang signifikan adalah lag ke 2 dan ke 3. Sehingga didapatkan model dugaan sementara yaitu ARIMA ([3],0,0), ARIMA ([3],0,[3]), dan ARIMA ([2,3],0,[3]).

Dari model dugaan yang telah terbentuk, akan diuji signifikansi parameternya dan cek diagnosa.



Gambar 4.28 Plot PACF Permintaan Pipa Galvalum D

4.14.2 Estimasi Parameter pada Jumlah Permintaan Pipa Galvalum D

Setelah diidentifikasi model dari Gambar 4.27 dan Gambar 4.28, maka didapatkan 3 model dugaan yaitu ARIMA ([3],0,0), ARIMA ([3],0,[3]), dan ARIMA (0,0,[3]). Maka langkah selanjutnya adalah melakukan estimasi parameter dan uji signifikansi parameter. Hasil estimasi dan uji signifikansi disajikan dalam bentuk Tabel 4.32.

Tabel 4.32 Pengujian Parameter Jumlah Permintaan Pipa Galvalum D

Model	Parameter	Estimate	P-value	Kesimpulan
ARIMA ([2,3],0,[3])	θ_3	0,60641	0,0098	Signifikan
	ϕ_2	0,29556	0,0296	Signifikan
	ϕ_3	0,70444	0,0001	Signifikan
ARIMA ([3],0,[3])	ϕ_3	1,00000	<0,0001	Signifikan
	θ_3	0,56803	0,0066	Signifikan
AR ([3])	ϕ_3	0,89682	<0,0001	Signifikan

Dari ketiga model diatas, terlihat bahwa ketiga model memiliki P_value lebih kecil dari tingkat signifikan 0,05.

Sehingga model tersebut dapat dipakai untuk peramalan adalah model ARIMA(0,0,[3]), ARIMA([3],0,[3]), dan ARIMA([3],0,0). Agar model tersebut dapat dipakai untuk peramalan, maka model harus memenuhi asumsi residual *White Noise* dan normal.

4.14.3 Cek Diagnosa Residual data Jumlah Permintaan Pipa Galvalum D.

Setelah dilakukan estimasi parameter dan pengujian signifikansi parameter, maka dilanjutkan untuk pengujian pada residualnya dari ketiga model tersebut. Pengujian ini dilakukan untuk mengetahui apakah residual telah memenuhi asumsi *white noise* dan asumsi normal. Berikut merupakan pengujian asumsi *white noise* pada data jumlah permintaan pipa galvalum D.

Tabel 4.33 Uji *White Noise* Data jumlah permintaan pipa galvalum D

Model	Lag	P-value	Kesimpulan
ARIMA ([2,3],0,[3])	6	0,1187	<i>White noise</i>
	12	0,0344	<i>White noise</i>
	18	0,1482	<i>White noise</i>
	24	0,0763	<i>White noise</i>
ARIMA ([3],0,[3])	6	0,4037	<i>White noise</i>
	12	0,1351	<i>White noise</i>
	18	0,4076	<i>White noise</i>
	24	0,2463	<i>White noise</i>
ARIMA ([3],0,0)	6	0,5287	<i>White noise</i>
	12	0,3101	<i>White noise</i>
	18	0,4872	<i>White noise</i>
	24	0,5595	<i>White noise</i>

Pada Tabel 4.33 diatas, terlihat bahwa dari ketiga model, hanya ada satu model yang tidak memenuhi asumsi residual *White Noise* yaitu model ARIMA (0,0,[3]). Hal tersebut bisa dibuktikan karena pada lag 6,12,18, dan 24 memiliki P-Value kurang dari nilai tingkat signifikan 5% semua yang berarti tolak H_0 . Sedangkan untuk model ARIMA ([3],0,[3]) dan ARIMA ([3],0,0) telah memenuhi asumsi residual *White Noise*, hal

tersebut dapat dibuktikan dengan *P-Value* pada lag ke - 6, 12, 18, dan 24 memiliki nilai lebih dari tingkat signifikan 5% yang berarti gagal tolak H_0 .

Pengujian selanjutnya adalah uji asumsi pengujian kenormalan residual. Pengujian kenormalan residual dilakukan dengan menggunakan uji kolmogorov-smirnov.

Tabel 4.34 Uji Kenormalan Residual Data Jumlah Permintaan Pipa Galvalum D

Model	P-value	Kesimpulan
ARIMA ([2,3],0,[3])	0,0705	Berdistribusi Normal
ARIMA ([3],0,[3])	0,1331	Berdistribusi Normal
AR ([3])	>0,1500	Berdistribusi Normal

Dari Tabel 4.34 diatas, terlihat bahwa *P-value* dari kedua model diatas memiliki nilai lebih dari 5% yang berarti gagal tolak H_0 . Sehingga dapat disimpulkan bahwa kedua model pada tabel 4.28 telah memenuhi asumsi residual normal.

4.14.4 Pemilihan Model terbaik Jumlah Permintaan Pipa Galvalum D dengan metode ARIMA

Langkah selanjutnya adalah memilih model terbaik dari ketiga model dugaan. Model terbaik dipilih berdasarkan data In Sampel dan Out Sampel. Memilih model terbaik berdasarkan data In Sampel dengan membandingkan nilai AIC dan SBC. Berikut merupakan perbandingan nilai dari 2 kriteria tersebut.

Tabel 4.35 Pemilihan Model Terbaik untuk Jumlah permintaan Pipa Galvalum D berdasarkan In Sampel

Model	AIC	SBC
ARIMA ([2,3],0,[3])	270,3886	276,0022
ARIMA ([3],0,[3])	275,9614	279,7038
AR ([3])	280,5876	282,4588

Dari tabel diatas, terlihat bahwa model terbaiknya adalah ARIMA ([3],0,[3]) dengan nilai AIC sebesar 486,69 dan nilai SBC 490,44 lebih rendah dibandingkan dengan nilai AIC dan SBC dari model ARIMA ([3],0,0).

Memilih model terbaik berdasarkan data out sampel dengan membandingkan nilai MSE dan sMAPE dari ketiga model. Berikut merupakan perbandingan nilai dari kedua kriteria tersebut.

Tabel 4.36 Pemilihan Model Terbaik untuk Jumlah permintaan Pipa Galvalum D berdasarkan Out Sampel

Model	MSE	sMAPE
ARIMA ([2,3],0,[3])	1212836431	0,64011
ARIMA ([3],0,[3])	1115583052	0,96558
AR([3])	1536678815	1,49709

Dari perbandingan nilai pada 2 kriteria tersebut, dapat disimpulkan bahwa model terbaik dipilih berdasarkan hasil *Out Sampel* yang berfungsi sebagai validasi model. Model ARIMA terbaik untuk pipa galvalum D adalah ARIMA ([2,3],0,[3]). Berikut penjabaran model ARIMA ([2,3],0,[3]) :


$$Z_t = 0,29556Z_{t-2} + 0,70444Z_{t-3} + a_t - 0,60641a_{t-3}$$

Model diatas menjelaskan bahwa jumlah permintaan pipa galvalum D pada bulan ke-t adalah 0,29556 kali jumlah permintaan pada bulan (t-2) ditambah 0,70444 kali jumlah permintaan pada (t-3) ditambah jumlah kesalahan perkiraan pada bulan ke-t dikurangi 0,60641 kali dari jumlah kesalahan perkiraan pada (t-3).

4.15 Pemodelan Jumlah Permintaan Pipa Hollow Galvalum D Menggunakan Metode *Moving Average*.

Setelah dilakukan *trial and eror* dari nilai *length* 1 sampai dengan *length* 12, maka didapatkan 2 *length* yang memiliki nilai MAPE dan MSD bernilai kecil dari data *insampel* dibandingkan nilai *Length* lainnya. *Length* tersebut bernilai 5 dan 6 ditampilkan

dalam bentuk Gambar 4.26. Pada gambar tersebut terdapat plot dari data dan nilai taksiran dari data. Selain itu juga terdapat nilai MAPE dan MSD dari data *insampel*. Hasil dari analisis *Moving Average* sebagai berikut.



Gambar 4.29 Hasil Analisis MA pada Pipa Galvalum D

Dari Gambar 4.29 diatas terlihat bahwa nilai fit mengikuti gerak dari data asli dan didapatkan nilai MSD pada length 5 sebesar 156502767 sedangkan pada length 6 sebesar 161275907. Untuk melihat model dengan length yang terbaik, dapat dilihat dari perhitungan MSE dan sMAPE dari data out sampel. Hasil perhitungannya sebagai berikut.

Tabel 4.37 Pemilihan Length Terbaik Metode *Moving Average* pada Jumlah Permintaan Pipa Galvalum D

Length	MSE	sMAPE
5	742506566,7	0,677403
6	771510805,7	0,665282

Dari Tabel 4.37 diatas, terdapat 2 *Length* yang digunakan untuk *Moving Average*. Didapatkan hasil bahwa *Length* yang memiliki nilai eror lebih kecil adalah *Length* 6 karena Nilai sMAPE lebih kecil yaitu sebesar 0,665. Selanjutnya dengan *Length* 6 tersebut digunakan sebagai pembandingan dengan metode peramalan lainnya yaitu dibandingkan dengan metode ARIMA Box – Jenkins dan Regresi *Time Series*.

4.16 Pemodelan Jumlah Permintaan Pipa Hollow Galvalum D Menggunakan Metode Regresi *Time Series*.

Regresi *Time Series* menggunakan data transformasi akar pangkat 4 agar data memenuhi asumsi residual. variabel prediktor yang diduga mempengaruhi variabel respon adalah Y_{t-11} .

4.16.1 Estimasi Model dan Signifikansi Parameter Data Jumlah Permintaan Pipa Hollow Galvalum D dengan Regresi *Time Series*.

Setelah didapatkan dugaan variabel prediktor, maka terbentuk model dugaan sebagai berikut.

$$Y_t = 5,350 - 0,4751 Y_{t-11} + \varepsilon_t$$

Selanjutnya parameter dari model regresi *time series* diatas, dilakukan pengujian parameter untuk mengetahui apakah parameter tersebut signifikan terhadap model. Pengujiannya sebagai berikut.

Hipotesis :

$$H_0 : \beta_i = 0 \text{ (parameter tidak signifikan)}$$

$$H_1 : \beta_i \neq 0 \text{ (parameter signifikan)}$$

Taraf Signifikan : $\alpha = 0,05$

Daerah Kritis : Tolak H_0 jika *P-value* < 0,05

Tabel 4.38 Pengujian Parameter Data Jumlah Permintaan Pipa Hollow Galvalum D Dengan Regresi *Time Series*.

Parameter	Estimate	T	P-value	Kesimpulan
Konstanta	5,350	4,02	0,000	Signifikan
Y_{t-11}	0,4751	2,76	0,009	Signifikan

Dari Tabel 4.38, dapat dilihat bahwa variabel seluruh variabel prediktor dan konstanta sudah signifikan karena *P-Value* memiliki nilai lebih dari 0,05. Sehingga dapat dikatakan bahwa model tersebut bisa digunakan sebagai peramalan. Atau dengan kata lain bahwa nilai jumlah permintaan ditentukan oleh 5,350

dari data transformasi ditambah 0,4751 kali data transformasi dari 11 bulan sebelumnya.

4.16.2 Pengujian Asumsi Residual Data Jumlah Permintaan Pipa Hollow Galvalum D.

Asumsi yang harus terpenuhi dalam analisis regresi adalah identik, independen, dan distribusi normal. Berikut merupakan pengujiannya. Asumsi homoskedastisitas adalah variansi residual bersifat identik. Berikut adalah pengujian dengan menggunakan uji Glejser.

Hipotesis:

H_0 : Tidak ada kasus heteroskedastisitas (Identik)

H_1 : Ada kasus heteroskedastisitas


Tabel 4.39 Uji Glejser Data Permintaan Pipa Galvalum D

Parameter	P-value	Kesimpulan
Konstanta	0,018	Tidak Signifikan
Y_{t-11}	0,318	Tidak Signifikan

Berdasarkan Tabel 4.39 menjelaskan bahwa nilai *P-value* pada seluruh variabel prediktor tersebut $> \alpha$ (0,05) yang berarti terjadi sudah memenuhi asumsi identik dengan kata lain varians residual bersifat konstan.

Pendeteksian adanya otokorelasi salah satunya dapat menggunakan uji Durbin Watson. Seperti yang terlihat pada Lampiran, diketahui bahwa nilai durbin watson sebesar 2,31878 pada tingkat signifikansi $\alpha = 0,05$ maka hasil Durbin watson gagal tolak H_0 karena d_u (1,6231) $< d$ (2,31878) $< 4-d_u$ (2,3769). Hal ini menunjukkan bahwa residual tidak ada autokorelasi dan bersifat Independen.

Pengujian normalitas pada residual dari regresi *time series* dilakukan dengan menggunakan uji *Kolmogorov-Smirnov*. Hasil dari pengujian *Kolmogorov-Smirnov* dapat dilihat dalam bentuk Gambar 4.30 sebagai berikut.



Gambar 4.30 Distribusi Normal Residual Pipa Galvalum D

Berdasarkan Gambar 4.30 hasil uji *Kolmogorov-Smirnov* diketahui bahwa nilai P_value sebesar 0,150 maka P_value (0,097) $>$ α (0,05) jadi keputusannya gagal tolak H_0 sehingga kesimpulannya residual pada data jumlah permintaan pipa Hollow Galvalum D sudah berdistribusi normal.

Karena model regresi sudah memenuhi asumsi residual, maka model dugaan sudah bisa digunakan sebagai model peramalan yang bisa dibandingkan dengan metode lainnya.

4.17 Peramalan Jumlah Permintaan Pipa Galvalum D dengan Menggunakan Metode yang Terbaik.

Sebelum melakukan peramalan pada jumlah permintaan pipa galvalum D sebanyak 12 periode kedepan, hal yang perlu dilakukan adalah membandingkan metode peramalan yang terbaik antara metode *ARIMA Box-Jenkins* dan metode *Moving Average* dengan melihat nilai MSE dan sMAPE dari nilai data Outsampel kedua metode. Hasil perhitungannya sebagai berikut

Tabel 4.40 Perbandingan Metode *ARIMA*, *Moving Average*, dan Regresi *Time Series* pada Jumlah Permintaan Pipa Galvalum D

Model	MSE	sMAPE
ARIMA ([2,3],0,[3])	1212836431	0,6411
Moving Average Length 6	771510805,7	0,665
Regresi <i>Time Series</i>	1172275260	0,836

Dari Tabel 4.40 diatas terlihat bahwa metode peramalan yang terbaik untuk jumlah permintaan pipa galvalum D adalah dengan menggunakan model ARIMA $((2,3),0,[3])$. Dipilih sebagai hasil peramalan yang terbaik karena memiliki nilai sMAPE lebih kecil dibandingkan dengan model lainnya yaitu sebesar 0,6411. Sedangkan nilai sMAPE untuk metode *Moving Average* dengan *Length* 6 sebesar 0,665 dan nilai sMAPE untuk regresi *time series* sebesar 0,836. Hasil ramalan untuk pipa hollow galvalum D ditampilkan dalam bentuk gambar 4.41 berikut.

Tabel 4.41 Hasil Ramalan Pipa Galvalum D

Bulan	Jumlah Permintaan	Bulan	Jumlah Permintaan
Januari	30156	Juli	25698
Februari	22206	Agustus	21552
Maret	19691	September	22902
April	27635	Oktober	24426
Mei	21445	Nopember	21941
Juni	21813	Desember	23341

Dari Tabel 4.41 diatas terlihat bahwa jumlah permintaan pipa yang tertinggi terjadi pada bulan Januari sedangkan jumlah permintaan yang paling sedikit terjadi pada bulan Maret.

Halaman ini sengaja dikosongkan

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berikut beberapa kesimpulan yang diperoleh dari pembahasan yang telah dilakukan :

1. Hasil eksplorasi data dari keempat jenis pipa dari periode Januari 2012 sampai Desember 2016 adalah pipa yang memiliki jumlah permintaan paling tinggi adalah pipa galvalum B sedangkan pipa yang memiliki jumlah permintaan paling rendah adalah pipa galvalum D. Pipa galvalum B, C, dan D memiliki nilai variabilitas yang tinggi pada bulan Maret sedangkan pipa galvalum A memiliki nilai variabilitas tinggi pada bulan Januari.
2. Metode yang terbaik yang digunakan untuk meramalkan pipa hollow galvalum selama 12 periode kedepan yaitu untuk jumlah permintaan pipa hollow galvalum A dan B diramalkan menggunakan metode *Moving Average* dengan *Length* 7. Jumlah permintaan pipa hollow galvalum C diramalkan dengan model ARIMA (2,1,0) sedangkan jumlah permintaan pipa hollow galvalum D diramalkan dengan model ARIMA ([2,3],0,[3]).

5.2 Saran

Saran kepada pihak perusahaan, menggunakan hasil ramalan dibandingkan dengan data yang sudah berjalan. Jika erornya kecil bisa digunakan untuk ramalan dibulan-bulan selanjutnya. Kepada peneliti sebaiknya mencoba menggunakan metode-metode lainnya agar bisa mendapatkan eror yang lebih kecil lagi.

Halaman ini sengaja dikosongkan

DAFTAR PUSTAKA

- Bowerman, B., & O'Connell, R. (1993). *Forecasting and Time Series: An Applied Approach, 3rd edition*. Belmont, California: Duxbury Press.
- Cahyaningtyas, A. (2014). *Pemodelan dan Peramalan Penjualan Sepeda Motor di Surabaya Dengan ARIMAX Variasi Kalender*. Surabaya: Institut Teknologi Sepuluh Nopember.
- Cryer, D. (1986). *Time Series Analysis*. Boston: PWS-KENT Publishing Company.
- Daniel, & Wayne, W. (1989). *Statistika Non Parametrik Terapan*. Diterjemahkan oleh : Alex Tri Kantjono W. Jakarta: PT. Gramedia.
- Ermayanthi, N. M. (2012). *Permalan Penjualan Buah di Moena Fresh Bali dengan Menggunakan Model Variasi Kalender*. Surabaya: Institut Teknologi Sepuluh Nopember.
- Hanke, J. E., & Wichern, D. W. (2005). *Business Forecasting*. New Jersey: Prentice Hall.
- Makridakis, S., Wheelwright, S., & Mc Gee, V. (1999). *Metode dan Aplikasi Peramalan*. Edisi ke 1. Diterjemahkan oleh : Ir. Untung Sus Ardiyanto, M.Sc. & Ir. Abdul Basith, M.Sc. Jakarta: Erlangga.
- Perdana, A. S. (2010). *Perbandingan Metode Time Series Regression dan ARIMAX Pada Pemodelan Data Penjualan Pakaian di Boyolali*. Surabaya: Institut Teknologi Sepuluh Nopember.
- Prihandono, M. N. (2015). *Analisis Time Series Penjualan Pipa PT. Bakrie dan Brothers Kantor Perwakilan Surabaya*. Surabaya: Institut Teknologi Sepuluh Nopember.
- SPINDO. (2015). *Annual Report PT. Steel Pipe Industry of Indonesia, Tbk*. Surabaya
- Walpole, R. (1995). *Pengantar Statistika*. Edisi ke 3. Diterjemahkan oleh : Ir. Bambang Sumantri. Jakarta: Gramedia Pustaka Utama.

Wei, W. W. (2006). *Time Series analysis : Univariate and Multivariate. 2nd edition.* USA: Pearson Education, Inc.

LAMPIRAN A. Data Jumlah Permintaan Pipa Galvalum A

Bulan	2012	2013	2014	2015	2016
Januari	18140	13656	10	84030	71010
Februari	28010	25284	11410	2010	41378
Maret	10	7010	24488	34410	87610
April	9454	9010	2010	30510	23210
Mei	37010	8100	38554	17810	210
Juni	13610	3210	86010	24010	2610
Juli	26610	16422	12010	25010	18310
Agustus	12668	15586	12010	5110	35910
September	2010	4010	27254	50010	16010
Oktober	6010	10	36410	10	9210
Nopember	7410	30124	51010	22210	65410
Desember	12390	36988	42010	4010	4610

LAMPIRAN B. Data Jumlah Permintaan Pipa Galvalum B

Bulan	2012	2013	2014	2015	2016
Januari	10	22010	10	58810	96510
Februari	5854	14738	25010	13010	74110
Maret	10	6516	28238	19010	139210
April	2348	21382	5010	49410	31010
Mei	1074	12	11610	19610	6910
Juni	3010	5020	33346	28210	14010
Juli	10	5010	5010	57410	30610
Agustus	13738	26960	50610	44010	59210
September	4510	5210	11464	108410	31810
Oktober	9010	10	52010	10	26810
Nopember	3204	20140	56010	47810	42010
Desember	14986	4610	32010	19610	10410

LAMPIRAN C. Data Jumlah Permintaan Pipa Galvalum C

Bulan	2012	2013	2014	2015	2016
Januari	10	14010	10	34010	92610
Februari	6168	10	19010	17610	94910
Maret	10	4010	2010	38410	129810
April	12578	3010	3110	23110	23810
Mei	1010	10	27410	21810	16710
Juni	10	1210	21210	36010	9410
Juli	10	1210	3410	27410	20810
Agustus	2078	16520	36010	39410	75310
September	6182	1210	14010	108910	34410
Oktober	3062	10	46610	10	23310
Nopember	11410	16010	61870	47610	58210
Desember	8810	5810	20010	6610	8610

LAMPIRAN D. Data Jumlah Permintaan Pipa Galvalum D

Bulan	2012	2013	2014	2015	2016
Januari	1236	7882	1646	13610	62210
Februari	1792	10	10	10	54910
Maret	10	1118	3532	31010	97610
April	10	2258	1010	25610	13210
Mei	10	12	19610	10010	13210
Juni	1878	1210	15010	27110	9010
Juli	10	1210	4010	16410	16210
Agustus	3422	8510	28210	30410	49810
September	6046	4162	5610	72010	20010
Oktober	2510	10	37010	10	16610
Nopember	10	6010	30610	31610	48610
Desember	1416	5638	12010	7610	14210

LAMPIRAN E. OUTPUT SAS ARIMA

1. ARIMA ([3],0,[3]) Pada Pipa Hollow Galvalum A

The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	0.39820	0.18681	2.13	0.0384	3				
AR1,1	0.95557	0.06849	13.95	<.0001	3				
Variance Estimate			6321.935						
Std Error Estimate			79.5106						
AIC			558.2607						
SBC			562.0031						
Number of Residuals			48						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.32	4	0.1763	0.108	0.085	-0.048	0.131	0.146	0.233
12	12.65	10	0.2441	0.080	0.017	-0.258	0.159	0.040	-0.043
18	14.02	16	0.5975	0.006	-0.075	-0.084	-0.011	0.049	0.056
24	20.87	22	0.5290	-0.109	-0.127	0.032	0.145	0.153	0.047
Tests for Normality									
Test	--Statistic--		-----p Value-----						
Shapiro-Wilk	W	0.977158	Pr < W	0.4665					
Kolmogorov-Smirnov	D	0.087819	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.056	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.370512	Pr > A-Sq	>0.2500					

2. AR ([3]) Pada Pipa Hollow Galvalum B

The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value		Approx Pr > t		Lag	
AR1,1	0.93813		0.06325	14.83		<.0001		3	
Variance Estimate				21.25065					
Std Error Estimate				4.609843					
AIC				283.9141					
SBC				285.7853					
Number of Residuals				48					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	10.41	5	0.0643	-0.115	0.262	-0.215	0.167	-0.102	0.166
12	17.39	11	0.0968	0.073	0.288	-0.115	0.112	-0.031	0.004
18	19.61	17	0.2948	-0.089	0.055	-0.075	0.089	0.054	0.052
24	27.80	23	0.2236	-0.054	-0.046	0.001	0.129	-0.027	0.248
Tests for Normality									
Test	--Statistic--		-----p Value-----						
Shapiro-Wilk	W	0.972006	Pr < W	0.3026					
Kolmogorov-Smirnov	D	0.116019	Pr > D	0.1024					
Cramer-von Mises	W-Sq	0.091937	Pr > W-Sq	0.1427					
Anderson-Darling	A-Sq	0.485407	Pr > A-Sq	0.2242					

3. ARIMA (2,1,0) Pada Pipa Hollow Galvalum C

The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value		Approx Pr > t		Lag	
MA1,1	0.60641		0.22497	2.70		0.0098		3	
AR1,1	0.29556		0.13152	2.25		0.0296		2	
AR1,2	0.70444		0.16678	4.22		0.0001		3	
Variance Estimate				15.406					
Std Error Estimate				3.925048					
AIC				270.3886					
SBC				276.0022					
Number of Residuals				48					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.86	3	0.1187	0.140	-0.064	0.152	0.191	0.157	-0.022
12	18.07	9	0.0344	0.150	0.226	-0.012	0.162	0.272	0.142
18	20.65	15	0.1482	-0.037	0.051	0.162	0.037	-0.061	-0.003
24	30.84	21	0.0763	0.095	0.148	0.167	0.086	0.088	0.192
Tests for Normality									
Test	--Statistic--		-----p Value-----						
Shapiro-Wilk	W	0.924453	Pr < W	0.0043					
Kolmogorov-Smirnov	D	0.122679	Pr > D	0.0705					
Cramer-von Mises	W-Sq	0.127237	Pr > W-Sq	0.0471					
Anderson-Darling	A-Sq	0.927912	Pr > A-Sq	0.0185					

4. ARIMA ([2,3],0,[3]) Pada Pipa Hollow Galvalum D

The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
AR1,1	-0.88331	0.13093	-6.75	<.0001	1				
AR1,2	-0.51630	0.13979	-3.69	0.0006	2				
Variance Estimate		15.5514							
Std Error Estimate		3.943526							
AIC		264.3115							
SBC		268.0118							
Number of Residuals		47							
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.75	4	0.7810	-0.047	-0.070	-0.080	-0.029	-0.124	-0.055
12	7.99	10	0.6303	0.091	0.158	0.052	0.047	0.135	-0.207
18	12.30	16	0.7228	-0.169	-0.079	0.135	-0.028	-0.084	-0.023
24	20.56	22	0.5481	0.085	-0.118	0.110	-0.007	-0.122	0.199
Tests for Normality									
Test	--Statistic--		-----p Value-----						
Shapiro-Wilk	W	0.959311	Pr < W	0.1010					
Kolmogorov-Smirnov	D	0.123204	Pr > D	0.0739					
Cramer-von Mises	W-Sq	0.075195	Pr > W-Sq	0.2383					
Anderson-Darling	A-Sq	0.488358	Pr > A-Sq	0.2207					

LAMPIRAN F. OUTPUT MINITAB Regresi *Time Series*

1. Pipa Hollow Galvalum A

The regression equation is
 $TRANS = 114 + 0.385 YT-6 - 0.468 yt-9 - 0.400 yt-11 + 2.54 T$

37 cases used, 11 cases contain missing values

Predictor	Coef	SE Coef	T	P
Constant	114.28	33.66	3.39	0.002
YT-6	0.3848	0.1683	2.29	0.029
yt-9	-0.4678	0.1641	-2.85	0.008
yt-11	-0.4000	0.1655	-2.42	0.022
T	2.543	1.227	2.07	0.046

S = 61.3942 R-Sq = 35.4% R-Sq(adj) = 27.3%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	4	66000	16500	4.38	0.006
Residual Error	32	120616	3769		
Total	36	186616			

Source	DF	Seq SS
YT-6	1	23089
yt-9	1	16397
yt-11	1	10320
T	1	16193

Durbin-Watson statistic = 2.21931

2. Pada Pipa Hollow Galvalum B

The regression equation is
 $BTRANS = 6.92 + 0.359 B-4$

44 cases used, 4 cases contain missing values

Predictor	Coef	SE Coef	T	P
Constant	6.918	1.540	4.49	0.000
B-4	0.3595	0.1447	2.48	0.017

S = 3.90625 R-Sq = 12.8% R-Sq(adj) = 10.7%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	94.16	94.16	6.17	0.017
Residual Error	42	640.87	15.26		
Total	43	735.03			

Unusual Observations

Obs	B-4	BTRANS	Fit	SE Fit	Residual	St Resid
17	12.2	1.861	11.297	0.680	-9.435	-2.45R
22	8.4	1.778	9.944	0.623	-8.166	-2.12R
25	8.5	1.778	9.972	0.620	-8.194	-2.12R
46	13.0	1.778	11.577	0.743	-9.799	-2.56R

R denotes an observation with a large standardized residual.

Durbin-Watson statistic = 2.23053

3. Pada Pipa Hollow Galvalum C

The regression equation is
 $C55 = -1.32 + 0.0458 C-1 - 0.0071 C-5 + 0.0201 C=15 + 0.0092 C-18 + 0.107 C-20$
 $+ 0.0602 C-24 + 0.0368 C-29$

19 cases used, 29 cases contain missing values

Predictor	Coef	SE Coef	T	P
Constant	-1.321	1.211	-1.09	0.299
C-1	0.04577	0.05376	0.85	0.413
C-5	-0.00706	0.06413	-0.11	0.914
C=15	0.02013	0.06098	0.33	0.748
C-18	0.00922	0.06865	0.13	0.896
C-20	0.10738	0.05180	2.07	0.062
C-24	0.06017	0.05530	1.09	0.300
C-29	0.03684	0.06622	0.56	0.589

S = 0.700367 R-Sq = 35.7% R-Sq(adj) = 0.0%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	7	2.9894	0.4271	0.87	0.557
Residual Error	11	5.3957	0.4905		
Total	18	8.3850			

Source	DF	Seq SS
C-1	1	0.3859
C-5	1	0.0196
C=15	1	0.0374
C-18	1	0.0094
C-20	1	1.8729
C-24	1	0.5123
C-29	1	0.1519

Durbin-Watson statistic = 1.80923

4. Pada Pipa Hollow Galvalum D

The regression equation is
 $dtrans = 5.35 + 0.475 d-11$

37 cases used, 11 cases contain missing values

Predictor	Coef	SE Coef	T	P
Constant	5.350	1.331	4.02	0.000
d-11	0.4751	0.1719	2.76	0.009

S = 3.71969 R-Sq = 17.9% R-Sq(adj) = 15.6%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	105.64	105.64	7.64	0.009
Residual Error	35	484.26	13.84		
Total	36	589.90			

Unusual Observations

Obs	d-11	dtrans	Fit	SE Fit	Residual	St Resid
46	13.2	1.778	11.634	1.252	-9.856	-2.81R

R denotes an observation with a large standardized residual.

Durbin-Watson statistic = 2.31878

BIODATA PENULIS



Penulis dilahirkan pada tanggal 1 Oktober 1991 di Jember, Jawa Timur, Indonesia dengan nama lengkap Tri Agung Widiyanto dan nama panggilannya adalah Wiwid. Sebelum memasuki dunia perkuliahan, penulis juga telah menempuh pendidikan formal sebelum kuliah. Pendidikan formal yang telah ditempuh oleh penulis sebelum memasuki dunia perkuliahan yaitu SDN Kapatihan 17 Jember, SMP Negeri 2 Jember

dan SMA Negeri 2 Jember. Pada tahun 2010, penulis mengikuti Seleksi Penerimaan Mahasiswa Baru Diploma dan dinyatakan sebagai mahasiswa jurusan Statistika FMIPA Institut Teknologi Sepuluh Nopember Surabaya dengan nomer induk mahasiswa NRP 1310 030 040. Pada tahun 2014 penulis mengikuti seleksi lintas jalur dan dinyatakan sebagai mahasiswa lintas jalur S1 Statistika FMIPA ITS. Dengan motto hidup, "*Don't be average, be the outliers !*". Selama perkuliahan di Lintas jalur, penulis juga sudah bekerja di PT. SPINDO, Tbk. Apabila pembaca ingin berdiskusi mengenai tugas akhir ini dan/atau materi lain yang berhubungan yang berhubungan dengan pekerjaan di PT. SPINDO, Tbk, penulis dapat dihubungi melalui email: triagungwidiyanto@gmail.com