



TUGAS AKHIR - SS 091324

**PREDIKSI GERAK BERPASANGAN *ROLLING*, *SWAYING*,
DAN *YAWING* PADA *FLOATING PRODUCTION UNIT*
(FPU) DALAM KONDISI *BEAM SEAS* DENGAN MODEL
ARIMA, *VAR*, DAN *HYBRID VAR-ANN***

NOVRI SUHERMI
NRP 1310 100 010

Dosen Pembimbing
Dr. Suhartono, S.Si, M.Sc
Baharuddin Ali, S.T, M.Eng

JURUSAN STATISTIKA
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2014



FINAL PROJECT - SS 091324

**PREDICTION OF COUPLING MOTION ROLLING,
SWAYING, AND YAWING ON A FLOATING
PRODUCTION UNIT (FPU) IN BEAM SEAS CONDITION
BY USING ARIMA, VAR, AND HYBRID VAR-ANN
MODELS**

NOVRI SUHERMI
NRP 1310 100010

Supervisor
Dr. Suhartono, S.Si, M.Sc
Baharuddin Ali, S.T, M.Eng

DEPARTMENT OF STATISTICS
Faculty of Mathematics and Natural Sciences
Institut Teknologi Sepuluh Nopember
Surabaya 2014

**PREDIKSI GERAK BERPASANGAN *ROLLING*,
SWAYING, DAN *YAWING* PADA *FLOATING
PRODUCTION UNIT (FPU)* DALAM KONDISI *BEAM
SEAS* DENGAN MODEL *ARIMA*, *VAR*, DAN *HYBRID
VAR-ANN***

Nama Mahasiswa : Novri Suhermi
NRP : 1310 100 010
Jurusan : Statistika FMIPA-ITS
Dosen Pembimbing : Dr. Suhartono, S.Si, M.Sc
Co-Pembimbing : Baharuddin Ali, S.T, M.Eng

Abstrak

Floating Production Unit (FPU) mempunyai peran penting dalam proses produksi minyak dan gas mentah yang berada di daerah lepas pantai. Oleh karena itu, stabilitas FPU sangat perlu diperhatikan. Stabilitas suatu kapal sangat ditentukan dari perilaku gerak rolling. Gerak kapal dapat dipelajari baik secara individu (uncoupled) maupun secara berpasangan (coupled). Salah satu sistem gerak coupling yang sering diteliti adalah gerak berpasangan rolling-swaying-yawing. Pada penelitian ini, dilakukan peramalan (forecasting) gerak rolling, swaying, dan yawing dalam kondisi beam seas pada FPU dengan menggunakan model ARIMA, VAR, dan Hybrid VAR-ANN. Data yang digunakan adalah data hasil simulasi eksperimen gerak FPU. Data dibagi menjadi 3000 data in-sample dan 1000 data out-of-sample. Kriteria model terbaik didasarkan pada kriteria out-of-sample dengan menggunakan ukuran Root Mean Square Error (RMSE). Dari ketiga model, didapatkan model terbaik yaitu model Hybrid VAR-ANN dengan nilai RMSE terkecil.

Kata Kunci: *ANN, ARIMA, forecasting, FPU, gerak kapal, Hybrid VAR-ANN, RMSE, time series, VAR.*

PREDICTION OF COUPLING MOTION ROLLING, SWAYING, AND YAWING ON A FLOATING PRODUCTION UNIT (FPU) IN BEAM SEAS CONDITION BY USING ARIMA, VAR, AND HYBRID VAR-ANN MODELS

Name of Student : Novri Suhermi
NRP : 1310 100 010
Department : Statistika FMIPA-ITS
Supervisor : Dr. Suhartono, S.Si, M.Sc
Co-Supervisor : Baharuddin Ali, S.T, M.Eng

Abstract

Floating Production Unit (FPU) has an important role in the production of crude oil and gas located in offshore area. Therefore, the stability of the FPU is very noteworthy. The stability of a ship is determined from the behavior of the rolling motion. Ship motion can be studied either in uncoupled system or in coupled system. One of the coupling motion system that is often observed is rolling-swaying-yawing motions. In this study, the rolling, swaying and yawing motions on a FPU are forecasted in beam seas condition by using ARIMA, VAR, and Hybrid VAR-ANN models. The data used are simulation data taken from the experiment. The data are divided into two parts, in-sample and out-of-sample. In-sample data consist of 3000 observations and out-of-sample data consist of 1000 observations. The best model selection is based on out-of-sample criteria. Out-of-sample criteria used is Root Mean Square Error (RMSE). From the three models, Hybrid VAR-ANN model became the best model with the smallest RMSE.

Kata Kunci: ANN, ARIMA, forecasting, FPU, Hybrid VAR-ANN, RMSE, ship motion, time series, VAR.



LEMBAR PENGESAHAN

**PREDIKSI GERAK BERPASANGAN *ROLLING*,
SWAYING, DAN *YAWING* PADA *FLOATING*
PRODUCTION UNIT (FPU) DALAM KONDISI *BEAM*
SEAS DENGAN MODEL *ARIMA*, *VAR*, DAN *HYBRID*
*VAR-ANN***



TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada

Program Studi S-1 Jurusan Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

Oleh :

NOVRI SUHERMI
NRP. 1310 100 010


Disetujui oleh Pembimbing Tugas Akhir :

Dr. Suhartono, S.Si, M.Sc
NIP. 19710929 199512 1 001

Baharuddin Ali, S.T, M.Eng
NIP. 19710816 199703 1 005

Mengotahui
Ketua Jurusan Statistika FMIPA-ITS

Dr. Muhammad Mashuri, M.T
NIP. 19620408 198701 1 001
SURABAYA, 11 JANUARI 2014



KATA PENGANTAR

Segala puji bagi Allah SWT, Tuhan semesta alam. Tiada sekutu bagi-Nya dan kepunyaan-Nya apa yang ada di langit, di bumi dan yang ada di antara keduanya. Tidak akan terjadi suatu peristiwa kecuali atas izin-Nya. Shalawat serta Salam senantiasa tucurahkan kepada Rasulullah SAW, keluarganya dan keturunannya, para sahabat dan pengikutnya yang tetap istiqomah hingga akhir jaman.

Alhamdulillah, Tugas Akhir berjudul **”PREDIKSI GERAK BERPASANGAN *ROLLING*, *SWAYING*, DAN *YAWING* PADA *FLOATING PRODUCTION UNIT (FPU)* DALAM KONDISI *BEAM SEAS* DENGAN MODEL *ARIMA*, *VAR*, DAN *HYBRID VAR-ANN*”** ini dapat terselesaikan dengan baik dan tepat waktu. Terelesainya Tugas Akhir ini, tidak terlepas dari dukungan berbagai pihak yang telah memberikan bimbingan dan bantuan pada penulis. Untuk itu pada kesempatan ini penulis mengucapkan terima kasih sedalam-dalamnya kepada :

1. Bapak Dr. Muhammad Mashuri, M.T selaku Ketua Jurusan Statistika FMIPA ITS dan Bu Dra. Lucia Aridinanti, M.S selaku Koordinator Program Studi S1 Jurusan Statistika FMIPA ITS yang telah memfasilitasi untuk kelancaran penyelesaian Tugas Akhir ini.
2. Pak Prof. Dr. Drs. I Nyoman Budiantara, M.Si selaku dosen wali yang telah membimbing penulis sejak awal masuk kuliah hingga penulis telah menyelesaikan studinya di jenjang S1 ini.
3. Bapak Dr. Suhartono, S.Si, M.Sc selaku dosen pembimbing yang telah memberikan ilmu, motivasi, wawasan, teladan, dan nasihat yang sangat luar biasa berharganya bagi penulis serta kesabaran dan sikapnya yang bijak dalam membimbing penulis menyelesaikan tugas akhir ini.
4. Bapak Baharuddin Ali.S.T, M.Eng selaku co-pembimbing yang telah memberikan ilmu dan wawasannya terutama di bidang perkapalan dan hidrodinamika.

5. Orang tua penulis, Bapak Suhermi dan Ibu Gustinar atas segala doa, dukungan, dan motivasi yang sangat luar biasa besarnya sehingga penulis terus bersemangat hingga akhir penyelesaian tugas akhir ini.
6. Serta pihak-pihak lain yang sangat berjasa dalam kelancaran proses penyelesaian tugas akhir ini.

Penulis mengharapkan Tugas Akhir ini dapat memberikan manfaat bagi pihak-pihak terkait terutama pembaca. Penulis menyadari bahwa Tugas Akhir ini masih jauh dari kesempurnaan. Oleh karena itu penulis sangat menerima apabila ada saran dan kritik yang sifatnya membangun guna perbaikan untuk penelitian-penelitian selanjutnya.

“Statistics is the grammar of science.” (Karl Pearson)

“I hear and I forget. I see and I remember. I do and I understand.”
(Confucius)

“I do not know what I may appear to the world, but to myself I seem to have been only like a boy playing on the seashore, and diverting myself in now and then finding a smoother pebble or a prettier shell than ordinary, whilst the great ocean of truth lay all undiscovered before me.” (Isaac Newton)

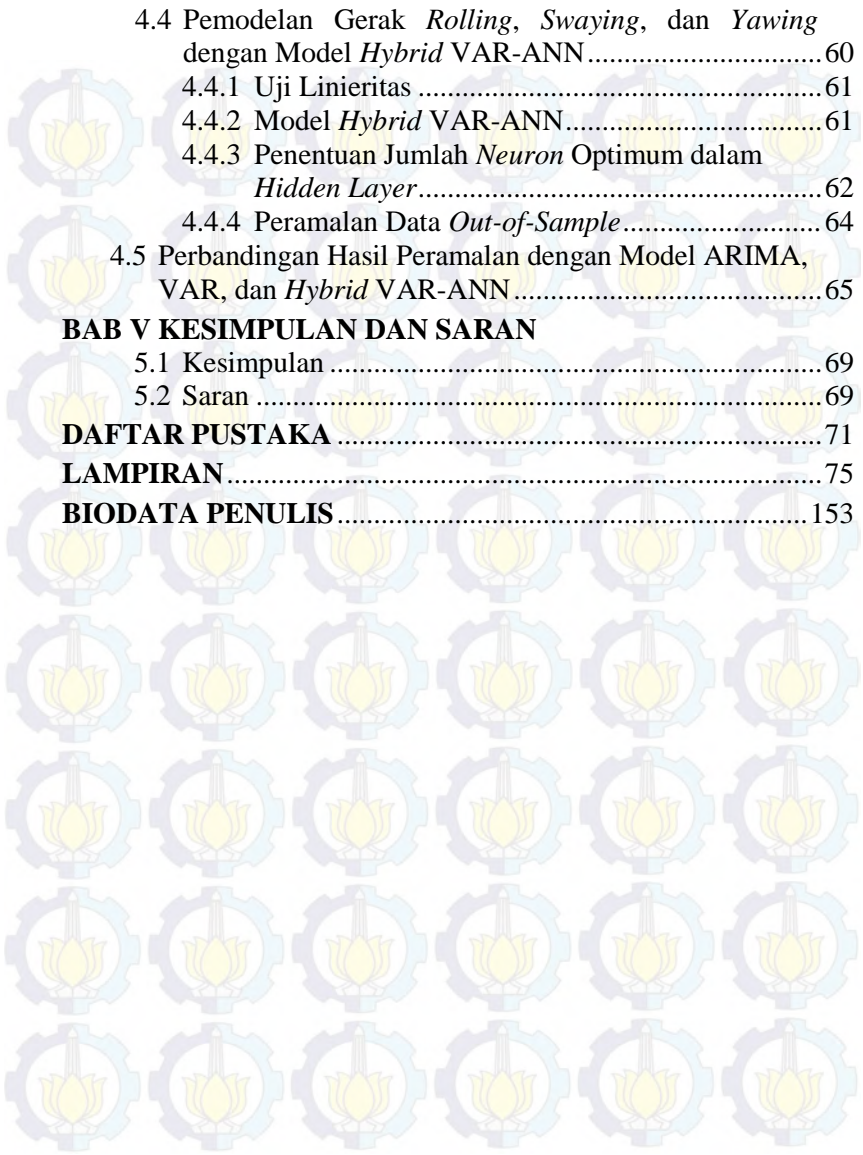
Surabaya, Januari 2014

Penulis


DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xvii
DAFTAR TABEL	xix
DAFTAR LAMPIRAN	xxi
BAB I PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	4
1.3 Tujuan Penelitian	4
1.4 Manfaat Penelitian	5
1.5 Batasan Masalah	5
BAB II TINJAUAN PUSTAKA	
2.1 Analisis <i>Time Series</i>	7
2.2 Bentuk Umum Model ARIMA	8
2.3 Stasioneritas	8
2.4 <i>Autocorrelation Function</i> (ACF)	10
2.5 <i>Partial Autocorrelation Function</i> (PACF).....	11
2.6 Uji <i>Unit Root</i>	11
2.7 Prosedur Box-Jenkins	13
2.7.1 Identifikasi Model ARIMA.....	14
2.7.2 Estimasi dan Pengujian Signfikansi Parameter ...	14
2.7.3 Pemeriksaan Diagnostik.....	16
2.7.3.1 Uji Asumsi <i>White Noise</i>	16
2.7.3.2 Uji Normalitas.....	17
2.7.4 Peramalan Menggunakan Model ARIMA	17
2.8 Bentuk Umum Model VAR	18

2.9	Identifikasi Vektor <i>Time Series</i>	18
2.10	Estimasi Parameter Model VAR	21
2.11	Pemeriksaan Diagnostik Model VAR	23
2.11.1	Uji Portmanteau	23
2.11.2	Uji Normalitas Multivariat Shapiro-Wilk	24
2.12	<i>Lag Length Selection</i>	24
2.13	Peramalan Menggunakan Model VAR.....	25
2.14	Uji Linieritas.....	25
2.15	<i>Artificial Neural Network (ANN)</i>	26
2.15.1	Arsitektur <i>Neural Network</i>	27
2.15.2	Model ANN	28
2.15.3	Model <i>Hybrid VAR-ANN</i>	29
2.16	Seleksi Model Terbaik.....	30
2.17	Gerak Kapal (<i>Ship Motion</i>)	31
2.18	Gelombang Irreguler	33
BAB III METODOLOGI PENELITIAN		
3.1	Sumber Data.....	37
3.2	Variabel Penelitian	37
3.3	Langkah Analisis.....	37
3.4	Diagram Alir	40
BAB IV ANALISIS DAN PEMBAHASAN		
4.1	Karakteristik Gerak <i>Rolling, Swaying, dan Yawing</i>	41
4.2	Pemodelan Gerak <i>Rolling, Swaying, dan Yawing</i> dengan Model ARIMA	43
4.2.1	Identifikasi Model ARIMA	43
4.2.2	Estimasi dan Pengujian Signifikansi Parameter	47
4.2.3	Pemeriksaan Diagnostik.....	50
4.2.4	Peramalan Data <i>Out-of-Sample</i>	53
4.3	Pemodelan Gerak <i>Rolling, Swaying, dan Yawing</i> dengan Model VAR	55
4.3.1	Identifikasi Model VAR.....	55
4.3.2	Estimasi dan Pengujian Signifikansi Parameter	56
4.3.3	Pemeriksaan Diagnostik	57
4.3.4	Peramalan Data <i>Out-of-Sample</i>	58



4.4	Pemodelan Gerak <i>Rolling</i> , <i>Swaying</i> , dan <i>Yawing</i> dengan Model <i>Hybrid</i> VAR-ANN.....	60
4.4.1	Uji Linieritas	61
4.4.2	Model <i>Hybrid</i> VAR-ANN.....	61
4.4.3	Penentuan Jumlah <i>Neuron</i> Optimum dalam <i>Hidden Layer</i>	62
4.4.4	Peramalan Data <i>Out-of-Sample</i>	64
4.5	Perbandingan Hasil Peramalan dengan Model ARIMA, VAR, dan <i>Hybrid</i> VAR-ANN.....	65
BAB V KESIMPULAN DAN SARAN		
5.1	Kesimpulan	69
5.2	Saran	69
DAFTAR PUSTAKA		71
LAMPIRAN		75
BIODATA PENULIS		153



DAFTAR GAMBAR

	Halaman
Gambar 2.1 Contoh <i>Sample Correlation Matrices</i> untuk 2 Data <i>Time Series</i>	2 10
Gambar 2.2 <i>Partial Lag Correlation Matrix Function</i> untuk 2 Data <i>Time Series</i>	21
Gambar 2.3 Contoh Arsitektur ANN.....	28
Gambar 2.4 Gerak Translasi Kapal	32
Gambar 2.5 Gerak Rotasi Kapal.....	33
Gambar 3.1 Diagram Alir Analisis.....	40
Gambar 4.1 Plot <i>Time Series</i> Data Gerak (a) <i>Rolling</i> , (b) <i>Swaying</i> , dan (c) <i>Yawing</i>	42
Gambar 4.2 Plot <i>Time Series</i> Data Gerak (a) <i>Rolling</i> , (b) <i>Swaying</i> , dan (c) <i>Yawing</i>	44
Gambar 4.3 Plot <i>Time Series</i> Data Gerak (a) <i>Rolling</i> , (b) <i>Swaying</i> , dan (c) <i>Yawing</i>	45
Gambar 4.4 Plot <i>Time Series</i> Data Gerak <i>Swaying</i> dan <i>Yawing</i> Hasil <i>Differencing</i>	46
Gambar 4.5 Plot ACF Data Gerak <i>Rolling</i> , <i>Swaying</i> , dan <i>Yawing</i>	46
Gambar 4.6 Plot PACF Data Gerak <i>Rolling</i> , <i>Swaying</i> , dan <i>Yawing</i>	47
Gambar 4.7 RMSE Gerak (a) <i>Rolling</i> , (b) <i>Swaying</i> , (c) <i>Yawing</i> , dan (d) Total	54
Gambar 4.8 Hasil Peramalan Data <i>Out-of-Sample</i> Gerak (a) <i>Rolling</i> , (b) <i>Swaying</i> , dan (c) <i>Yawing</i>	55
Gambar 4.9 <i>Sample Correlation Matrix Function</i>	56
Gambar 4.10 RMSE Peramalan Gerak (a) <i>Rolling</i> , (b) <i>Swaying</i> , (c) <i>Yawing</i> , dan (d) Total	59
Gambar 4.11 Hasil Peramalan Data <i>Out-of-Sample</i> Gerak (a) <i>Rolling</i> , (b) <i>Swaying</i> , dan (c) <i>Yawing</i>	60

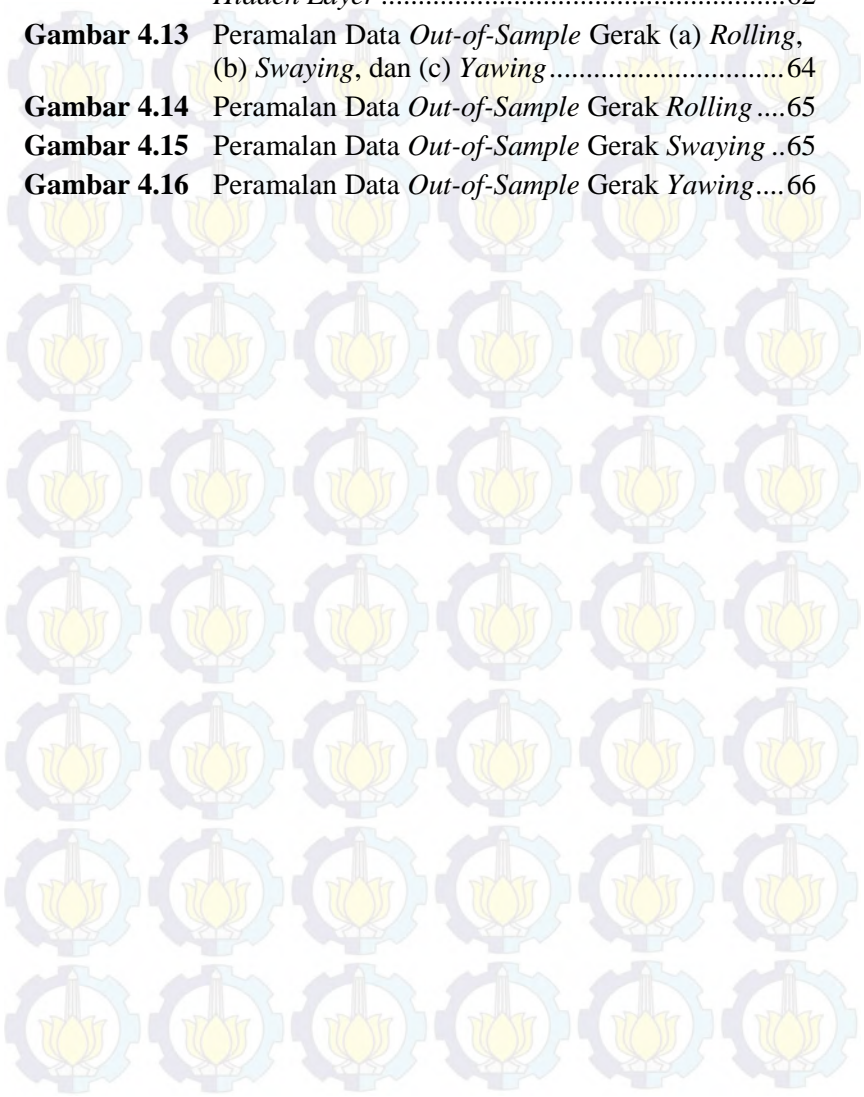
Gambar 4.12 Arsitektur ANN dengan 3 Unit *Neuron* dalam *Hidden Layer*62

Gambar 4.13 Peramalan Data *Out-of-Sample* Gerak (a) *Rolling*, (b) *Swaying*, dan (c) *Yawing* 64

Gambar 4.14 Peramalan Data *Out-of-Sample* Gerak *Rolling*65

Gambar 4.15 Peramalan Data *Out-of-Sample* Gerak *Swaying* ..65


Gambar 4.16 Peramalan Data *Out-of-Sample* Gerak *Yawing*.... 66



DAFTAR TABEL

	Halaman
Tabel 2.1 Nilai dan <i>Power Transformation</i>	10
Tabel 2.2 Karakteristik Plot ACF dan PACF pada Model ARIMA	14
Tabel 3.1 Struktur Data Penelitian.....	37
Tabel 4.1 Statistika Deskriptif Gerak <i>Rolling</i> , <i>Swaying</i> , dan <i>Yawing</i>	41
Tabel 4.2 Hasil Pemeriksaan Stasioneritas dalam Varians	44
Tabel 4.3 Hasil Pengujian <i>ADF Test</i>	45
Tabel 4.4 Model ARIMA untuk Gerak <i>Rolling</i> , <i>Swaying</i> , dan <i>Yawing</i>	47
Tabel 4.5 Estimasi dan Pengujian Signifikansi Parameter Model ARIMA Gerak <i>Rolling</i>	48
Tabel 4.6 Estimasi dan Pengujian Signifikansi Parameter Model ARIMA Gerak <i>Swaying</i>	48
Tabel 4.7 Estimasi dan Pengujian Signifikansi Parameter Model ARIMA Gerak <i>Yawing</i>	49
Tabel 4.8 Pengujian Ljung-Box Gerak <i>Rolling</i>	50
Tabel 4.9 Pengujian Ljung-Box Gerak <i>Swaying</i>	51
Tabel 4.10 Pengujian Ljung-Box Gerak <i>Yawing</i>	51
Tabel 4.11 Uji Normalitas Residual.....	51
Tabel 4.12 Statistik <i>Skewness</i> dan <i>Kurtosis</i> dari <i>Residual</i> Model ARIMA	52
Tabel 4.13 Hasil Peramalan Data <i>Out-of-Sample</i> dengan Model ARIMA	53
Tabel 4.14 Estimasi dan Pengujian Signifikansi Parameter Model VAR (1).....	57
Tabel 4.15 Pengujian Portmanteau	57
Tabel 4.16 Pengujian Normalitas Multivariat <i>Residual</i>	58
Tabel 4.17 RMSE Peramalan Model VAR (1)	59

Tabel 4.18	Pengujian Linieritas	61
Tabel 4.19	RMSE Hasil Peramalan Data <i>Out-of-Sample</i>	62
Tabel 4.20	RMSE Peramalan Data <i>Out-of-Sample</i> Gerak <i>Rolling, Swaying, dan Yawing</i>	66



BAB I PENDAHULUAN

1.1 Latar Belakang

Industri minyak dan gas (migas) telah berkembang dengan pesat karena kebutuhan energi yang terus meningkat. Indonesia merupakan salah satu negara penghasil minyak dan gas bumi. Tentunya Indonesia memiliki banyak blok pengeboran minyak dan gas bumi, termasuk yang berlokasi di daerah lepas pantai. Blok pengeboran minyak dan gas bumi di lepas pantai didukung dengan adanya suatu kapal yang berfungsi sebagai *production unit* untuk memproses minyak atau gas mentah. Kapal ini sering disebut sebagai *Floating Production Unit (FPU)*. Keberadaan FPU menjadi sangat penting dalam proses produksi minyak dan gas bumi. Oleh karena itu, stabilitas FPU sangat perlu diperhatikan. Salah satu studi yang dilakukan untuk mengetahui stabilitas suatu kapal adalah studi gerak kapal (*ship motion study*).

Gerak kapal merupakan salah satu contoh dari *six degrees of freedom (6DoF)*. Gerak kapal terdiri dari 6 macam gerak, yaitu gerak *rolling*, *yawing*, *pitching*, *swaying*, *surging*, dan *heaving*. Salah satu gerak kapal yang paling sering diteliti adalah gerak *rolling*. Gerak *rolling* adalah gerak rotasi yang berputar pada sumbu longitudinal kapal. Gerak *rolling* merupakan gerak yang sangat penting untuk dipelajari dalam mengetahui keamanan suatu kapal (Hu & Fong, 2010). Oleh karena itu, stabilitas suatu kapal sangat ditentukan dari perilaku gerak *rolling*. Gerak kapal dapat dipelajari baik secara individu (*uncoupled*) maupun secara berpasangan (*coupled*). Salah satu sistem gerak *coupling* yang sering diteliti adalah gerak *rolling-swaying-yawing*. Sebuah penelitian tentang gerak *rolling*, *swaying*, dan *yawing* pernah dilakukan oleh Das, Das, dan Sahoo (2010) pada gerak kapal dengan *forward speed* dalam kondisi *flared up* menggunakan pemodelan secara numerik.

Gerak kapal pada beberapa tahap ke depan dapat diprediksi dengan menggunakan analisis *time series*. Zhang dan Ye (2009) telah melakukan studi eksperimen untuk memprediksi gerak kapal dengan menggunakan analisis *time series*. Metode yang sering digunakan dalam *time series forecasting* untuk data univariat adalah metode *Autoregressive Integrated Moving Average* (ARIMA) Box-Jenkins. Beberapa kasus telah menunjukkan adanya hubungan yang dinamis antara suatu *time series* dengan *time series* lainnya, sehingga perlu dilakukan analisis secara multivariat. *Multivariate time series* adalah kumpulan dari beberapa *single time series* yang membentuk suatu komponen *time series* yang multivariat (Tsay, 2010). Metode yang sering digunakan untuk pemodelan dan peramalan pada *multivariat time series* adalah pendekatan proses *Vector Autoregressive* (VAR). Model ARIMA dan model VAR merupakan model yang paling sering digunakan sebagai model *time series* yang linier. Namun, model ARIMA tidak dapat dengan mudah menangkap pola data yang bersifat nonlinier (Pai & Ling, 2004). Begitu juga halnya dengan model VAR, sehingga diperlukan suatu pendekatan dengan menggunakan model lain yang bisa menangkap pola nonlinier dengan baik. Salah satu model nonlinier yang sering digunakan dalam analisis *time series* adalah *Artificial Neural Network* (ANN). ANN atau disebut *Neural Network* (NN) merupakan salah satu contoh model nonlinier yang mempunyai bentuk fungsional fleksibel dan mengandung beberapa parameter yang tidak dapat diinterpretasikan seperti pada model parametrik (Suhartono, 2007).

Khan, Bil, Marion, dan Malcom (2004) telah melakukan penelitian tentang prediksi gerak kapal (*ship motion*) menggunakan model *time series* ARIMA, VARIMA, dan ANN. Model ARIMA digunakan untuk memprediksi gerak *rolling*, sementara model VARIMA digunakan untuk memprediksi gerak *pitching* dan kecepatan angin. Model ARIMA yang didapatkan adalah ARIMA (15,0,1), sementara model VARIMA yang didapatkan adalah VARIMA (10,1,0). Prediksi gerak *rolling* juga

dilakukan dengan menggunakan ANN dan kemudian dibandingkan dengan hasil prediksi dari model ARIMA. Berdasarkan hasil prediksi yang didapatkan dari model ANN, disimpulkan bahwa model ANN lebih unggul dibandingkan model ARIMA dalam memprediksi gerak kapal. Khan, Bil, dan Marion (2005) dalam penelitiannya tentang prediksi gerak *rolling* menggunakan ANN juga menghasilkan kesimpulan bahwa pendekatan ANN memberikan hasil prediksi yang sangat bagus. Hal yang sama juga telah dilakukan oleh Nicolau, Palade, dan Aiordachioaie (2007) di dalam penelitiannya tentang prediksi gerak *rolling* pada kapal konvensional dengan menggunakan *feed-forward neural networks*. *Neural Architecture* dalam penelitiannya dianalisis menggunakan beberapa data *training* dan beberapa kondisi *noise*. Kemampuan pendekatan ANN menghasilkan prediktor yang baik walaupun data *training* dan data *testing* yang digunakan dipengaruhi oleh *noise*. Selain itu, prediktor yang dihasilkan bersifat *robust*, bekerja dengan baik dalam beberapa level *input noise*.

Model ARIMA dan model ANN juga sering dibandingkan dengan model gabungan (*hybrid*) antara ARIMA dan ANN untuk mendapatkan performansi *forecasting* yang lebih unggul. Sementara metode *hybrid* mengombinasikan model ARIMA dan model ANN untuk mendapatkan keunggulan yang dimiliki model ARIMA dan model ANN dalam pemodelan linier dan nonlinier. Zhang (2003) memperkenalkan model *hybrid* ARIMA dan ANN serta menunjukkan bahwa model tersebut lebih unggul dalam menghasilkan ramalan yang akurat. Model *hybrid* mengambil keunggulan dari kedua model dalam menangkap pola yang linier (dari model ARIMA) dan nonlinier (dari model ANN). Penelitian tersebut menghasilkan kesimpulan bahwa model *hybrid* ini dapat meningkatkan akurasi hasil *forecasting* dibandingkan dengan model yang terpisah. Selanjutnya, pada penelitian kali ini dilakukan prediksi gerak berpasangan (*coupled motion*) *rolling*, *swaying*, dan *yawing* pada FPU (*Floating Production Unit*) dalam kondisi *beams seas* secara multivariat dengan membandingkan

hasil *forecasting* antara model VAR dan model *hybrid* VAR-ANN. *Beam seas* adalah kondisi laut di mana gelombang bergerak dari arah 90 terhadap muka kapal.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, maka dalam penelitian “Prediksi Gerak Berpasangan *Rolling*, *Swaying*, dan *Yawing* pada *Floating Production Unit* (FPU) dalam Kondisi *Beam Seas* pada dengan Model *Vector Autoregressive* (VAR) dan *Hybrid* VAR-ANN” didapatkan permasalahan yang dirumuskan dalam perumusan masalah sebagai berikut :

1. Bagaimana model ARIMA dengan order yang sesuai untuk memprediksi gerak berpasangan *rolling*, *swaying*, dan *yawing* pada FPU?
2. Bagaimana model VAR dengan order yang sesuai untuk memprediksi gerak berpasangan *rolling*, *swaying*, dan *yawing* pada FPU?
3. Bagaimana model *Hybrid* VAR-ANN dan *arsitektur* yang sesuai untuk memprediksi gerak berpasangan *rolling*, *swaying*, dan *yawing* pada FPU?
4. Bagaimana perbandingan hasil prediksi gerak berpasangan *rolling*, *swaying*, dan *yawing* pada FPU dengan menggunakan model ARIMA, VAR, dan *Hybrid* VAR-ANN?

1.3 Tujuan Penelitian

Tujuan yang ingin dicapai dari penelitian ini adalah sebagai berikut :

1. Mengetahui model ARIMA dengan *order* yang sesuai untuk memprediksi gerak berpasangan *rolling*, *swaying*, dan *yawing* pada FPU
2. Mengetahui model VAR dengan order yang sesuai untuk memprediksi gerak berpasangan *rolling*, *swaying*, dan *yawing* pada FPU

3. Mengetahui model *Hybrid* VAR-ANN dengan arsitektur yang sesuai untuk memprediksi gerak berpasangan *rolling*, *swaying*, dan *yawing* pada FPU
4. Mengetahui perbandingan hasil prediksi gerak berpasangan *rolling*, *swaying*, dan *yawing* pada FPU dengan menggunakan model ARIMA,VAR, dan *Hybrid* VAR-ANN.

1.4 Manfaat Penelitian

Manfaat dari penelitian ini adalah dapat mengetahui metode mana yang lebih baik dalam memprediksi gerak berpasangan *rolling*, *swaying*, dan *yawing* pada FPU dalam kondisi *beam seas*. Hasil prediksi gerak ini dapat digunakan untuk mengetahui stabilitas dari FPU, sehingga pemilik desain FPU dapat mengetahui kekurangan yang terdapat dalam desain FPU dan dapat dijadikan pertimbangan untuk meningkatkan stabilitas FPU serta mengurangi resiko terjadinya kecelakaan.

1.5 Batasan Masalah

Batasan permasalahan yang digunakan dalam penelitian ini adalah sebagai berikut:

1. Data gerak FPU merupakan hasil simulasi dari eksperimen di Laboratorium Hidrodinamika Indonesia (LHI).
2. Gelombang laut berada pada kondisi *beam seas*.
3. Gelombang yang digunakan adalah gelombang dengan tipe *irregular waves*.



Halaman ini sengaja dikosongkan

BAB II TINJAUAN PUSTAKA

2.1 Analisis *Time Series*

Analisis *time series* adalah analisis observasional data yang terjadi dengan urutan waktu dengan interval waktu yang tetap. Analisis *time series* terdiri dari metode untuk menganalisis data *time series* untuk mengetahui pola dan karakteristik data. Salah satu penggunaannya adalah untuk peramalan (*forecasting*). Peramalan dalam analisis *time series* dilakukan dengan memprediksi nilai masa depan berdasarkan nilai yang pengamatan sebelumnya. Tujuan dari metode peramalan *time series* adalah menemukan pola dalam data historis dan mengekstrapolasi pola tersebut ke masa depan (Makridakis, Wheelwright & Hyndman, 1997).

Ada banyak bentuk model yang dapat diimplementasikan untuk mewakili proses stokastik yang berbeda. Ada dua kelas dasar dalam model linier *time series*, yaitu model *Autoregressive* (AR) dan model *Moving Average* (MA). Kombinasi dari model AR dan MA kemudian menghasilkan model *Autoregressive Moving Average* (ARMA) dan model *Autoregressive Integrated Moving Average* (ARIMA). Model ARIMA selanjutnya dapat digeneralisir menjadi *Autoregressive Fractional Integrated Moving Average* (ARFIMA).

Selanjutnya, model-model *time series* univariat kemudian dikembangkan untuk kasus multivariat. *Multivariate time series* adalah kumpulan dari beberapa *single time series* yang membentuk suatu komponen *time series* yang multivariat (Tsay, 2010). *Multivariate time series* berbentuk vektor *time series* berukuran $(m \times 1)$ yang dinotasikan dengan $\{Y_t\}$ di mana baris ke- i dari $\{Y_t\}$ adalah $\{y_{it}\}$. Maka, untuk sembarang waktu t , $Y_t = (y_{1t}, y_{2t}, \dots, y_{mt})'$. Suatu *time series* tidak hanya memiliki dependensi dengan komponen-komponen di dalamnya, tetapi juga dapat memiliki interdependensi dengan *time series* lainnya

(Brockwell & Davis, 2002). Analisis *multivariate time series* digunakan ketika ingin membuat model yang menjelaskan interaksi dan pergerakan di antara sekelompok *time series*. Metode yang sering digunakan untuk pemodelan dan peramalan pada *multivariate time series* adalah pendekatan proses *Vector Autoregressive* (VAR).

2.2 Bentuk Umum Model ARIMA

Model ARIMA merupakan penggabungan antara model *Autoregressive* (AR) dan *Moving Average* (MA) serta proses *differencing* terhadap data *time series*. Secara umum bentuk model ARIMA (p,d,q) adalah sebagai berikut (Wei, 2006).

$$\phi_p(B)(1-B)^d Y_t = \theta_0 + \theta(B)a_t \quad (2.1)$$

di mana,

$$\theta_0 = \mu(1 - \phi_1 - \phi_2 - \dots - \phi_p)$$

$$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

$$\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

$$(1-B)Y_t = Y_t - Y_{t-1},$$

B adalah operator *backshift*, dan a_t adalah barisan *white noise* dengan rataan (*mean*) nol dan varians konstan ($a_t \sim WN(0, \sigma^2)$).

2.3 Stasioneritas

Suatu proses stokastik dikatakan stasioner jika momen pertama dan momen kedua proses tersebut bersifat invarian dalam waktu (Cryer & Chan, 2008). Ide dasar dari stasioneritas adalah bahwa hukum probabilitas yang mengatur perilaku proses tidak berubah dari waktu ke waktu. Artinya, proses ini berada dalam kesetimbangan statistik. Secara spesifik, suatu proses $\{Y_t\}$ dikatakan *strictly stationary* jika distribusi bersama dari $Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}$ sama dengan distribusi bersama dari $Y_{t_1-k}, Y_{t_2-k}, \dots, Y_{t_n-k}$ untuk setiap titik waktu t_1, t_2, \dots, t_n dan semua waktu dalam lag k (Cryer & Chan, 2008). Akibatnya,

$E(Y_t) = E(Y_{t-k})$, dan $Var(Y_t) = Var(Y_{t-k})$ untuk setiap nilai t dan k sedemikian sehingga fungsi *mean* dan fungsi varians bersifat konstan.

Misalkan $n = 2$, dalam definisi stasioneritas dapat dilihat bahwa distribusi dari Y_t dan Y_s pasti sama dengan Y_{t-k} dan Y_{s-k} , sedemikian sehingga $Cov(Y_t, Y_s) = Cov(Y_{t-k}, Y_{s-k})$ untuk semua nilai t, s , dan k . Jika diambil $k = s$ dan kemudian $k = t$, maka didapatkan

$$\begin{aligned}\gamma_{t,s} &= Cov(Y_t, Y_s) \\ &= Cov(Y_{t-s}, Y_0) \\ &= Cov(Y_0, Y_{s-t}) \\ &= Cov(Y_0, Y_{|t-s|}) \\ &= \gamma_{0,|t-s|}\end{aligned}\tag{2.2}$$

Maka, kovarians antara Y_t dan Y_s hanya bergantung pada waktu yang melalui $|t - s|$. Oleh karena itu, notasi kovarians dan koefisien korelasi dalam proses stasioner dapat ditulis lebih sederhana seperti berikut.

$$\gamma_k = Cov(Y_t, Y_{t-k})\tag{2.3}$$

$$\rho_k = Corr(Y_t, Y_{t-k})\tag{2.4}$$

Selanjutnya, jika suatu proses bersifat *strictly stationary* dan memiliki varians yang berhingga, maka fungsi kovarians hanya bergantung pada *time lag*.

Sebuah definisi yang mirip dengan *strict stationarity* namun lebih lemah secara matematis menjelaskan bahwa suatu proses stokastik $\{Y_t\}$ dikatakan *weakly stationary* jika memenuhi kondisi berikut.

1. Fungsi *mean* konstan.
2. $\gamma_{t,t-k} = \gamma_{0,k}$ untuk setiap waktu t dan lag k .

Suatu *series* yang nonstasioner dapat direduksi menjadi *series* yang stasioner dengan melakukan *differencing* yang sesuai pada *series* tersebut. Dengan kata lain, jika *series* Y_t tidak stasioner, maka *differenced series* dari Y_t , $(1 - B)^d Y_t$ untuk beberapa bilangan bulat $d \geq 1$, bersifat stasioner.

Tidak semua *series* yang nonstasioner dapat ditransformasi menjadi stasioner dengan melakukan *differencing*. Hal ini

disebabkan karena *series* tidak stasioner dalam varians. Maka, dilakukan transformasi untuk menstabilkan varians. Salah satu tranformasi yang bisa digunakan adalah *Power Transformation* (Wei, 2006). Secara umum, *Power Transformation* diberikan sebagai berikut.

$$T(Y_t) = \frac{Y_t^\lambda - 1}{\lambda} \quad (2.5)$$

Berikut adalah nilai λ yang sering digunakan dan bentuk transformasinya.

Tabel 2.1 Nilai λ dan *Power Transformation*

Nilai λ (lambda)	Transformasi
-1.0	$\frac{1}{Y_t}$
-0.5	$\frac{1}{\sqrt{Y_t}}$
0.0	$\ln Y_t$
0.5	$\sqrt{Y_t}$
1.0	Y_t (tidak ditransformasi)

2.4 Autocorrelation Function (ACF)

Koefisien korelasi antara Y_t dan Y_{t-k} disebut autokorelasi pada lag ke- k , dan biasanya dinotasikan dengan ρ_k , di mana di bawah asumsi *weak stationarity*, ρ_k adalah fungsi (hanya) dalam k (Tsay, 2010). Secara spesifik, ρ_k didefinisikan sebagai berikut.

$$\rho_k = \frac{\text{Cov}(Y_t, Y_{t-k})}{\sqrt{\text{Var}(Y_t)\text{Var}(Y_{t-k})}} = \frac{\text{Cov}(Y_t, Y_{t-k})}{\text{Var}(Y_t)} = \frac{\gamma_k}{\gamma_0} \quad (2.6)$$

di mana digunakan salah satu sifat *weakly stationary series*, yaitu $\text{Var}(Y_t) = \text{Var}(Y_{t-k})$. Berdasarkan definisi (2.6), didapatkan $\rho_0 = 1$, $\rho_k = \rho_{-k}$, dan $-1 \leq \rho_k \leq 1$. Selain itu, suatu *weakly stationary series* Y_t tidak berkorelasi secara berurutan jika dan hanya jika $\rho_k = 0$, untuk semua nilai $k > 0$.

Misalkan \bar{Y} adalah *sample mean* di mana $\bar{Y} = \frac{1}{T} \sum_{t=1}^T Y_t$, maka *sample autocorrelation* lag-1 dari Y_t diberikan sebagai berikut.

$$\hat{\rho}_1 = \frac{\sum_{t=2}^T (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=1}^T (Y_t - \bar{Y})^2} \quad (2.7)$$

Secara umum, *sample autocorrelation* lag- k dari Y_t diberikan sebagai berikut.

$$\hat{\rho}_k = \frac{\sum_{t=k+1}^T (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^T (Y_t - \bar{Y})^2}, \quad 0 \leq k < T - 1 \quad (2.8)$$

Jika $\{Y_t\}$ adalah barisan yang bersifat independen dan identik yang memenuhi $E(Y_t^2) < \infty$, maka $\hat{\rho}_k$ berdistribusi normal asimtotik dengan *mean* nol dan varians $1/T$ untuk setiap bilangan bulat positif k .

2.5 Partial Autocorrelation Function (PACF)

Partial Autocorrelation antara Y_t dan Y_{t-k} didefinisikan sebagai korelasi antara Y_t dan Y_{t-k} setelah *mutual linear dependency* dari variabel-variabel *intervening*, yaitu $Y_{t-1}, Y_{t-2}, \dots, Y_{t-(k-1)}$ dihilangkan. *Conditional correlation*,

$$\text{Corr}(Y_t, Y_{t-k} | Y_{t-1}, Y_{t-2}, \dots, Y_{t-(k-1)}) \quad (2.9)$$

inilah yang disebut sebagai *partial autocorrelation* (Wei, 2006).

PACF pada suatu *time series* yang stasioner adalah sebuah fungsi dari ACF yang sangat berguna untuk menentukan order p dari model AR (Tsay, 2010). Perhitungan nilai *sample* PACF dilakukan secara rekursif dengan diawali nilai $\hat{\phi}_{11} = \hat{\rho}_1$ untuk menghitung $\hat{\phi}_{kk}$ dengan cara berikut.

$$\hat{\phi}_{k+1, k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.10)$$

Varians dari $\hat{\phi}_{kk}$ dapat diaproksimasi dengan,

$$\text{Var}(\hat{\phi}_{kk}) \simeq \frac{1}{T}. \quad (2.11)$$

Maka, $\pm 2/\sqrt{T}$ dapat digunakan sebagai *critical limits* pada $\hat{\phi}_{kk}$ untuk menguji hipotesis proses *white noise*.

2.6 Uji Unit Root

Salah satu uji stasioneritas yang sering digunakan adalah uji *unit root* (Gujarati, 2004). Uji *unit root* pertama kali

diperkenalkan oleh David Dickey dan Wayne Fuller. Uji *unit root* didasarkan pada model berikut.

$$Y_t = \rho Y_{t-1} + u_t, \quad -1 \leq \rho \leq 1 \quad (2.12)$$

di mana u_t adalah *error* yang bersifat *white noise*. Pada model persamaan (2.12), jika $\rho = 1$, maka model tersebut merupakan model *random walk* tanpa *drift* dan termasuk dalam proses stokastik nonstasioner. Ide dasar dari uji *unit root* adalah dengan meregresikan Y_t dengan Y_{t-1} dan menguji apakah ρ secara statistik bernilai 1. Jika benar bahwa secara statistik $\rho = 1$, maka Y_t tidak stasioner. Persamaan (2.2) dapat dimanipulasi menjadi

$$\begin{aligned} Y_t - Y_{t-1} &= \rho Y_{t-1} - Y_{t-1} + u_t \\ &= (\rho - 1) Y_{t-1} + u_t \end{aligned} \quad (2.13)$$

dan bisa disederhanakan menjadi

$$\Delta Y_t = \delta Y_{t-1} + u_t \quad (2.14)$$

di mana $\delta = (\rho - 1)$ dan Δ merupakan operator *first-difference* dengan $\Delta Y_t = Y_t - Y_{t-1}$.

Hal yang dilakukan selanjutnya adalah mengestimasi nilai dari δ dan melakukan uji hipotesis apakah $\delta = 0$. Jika $\delta = 0$, maka $\rho = 1$. Model persamaan (2.14) analog dengan model regresi linier sederhana. Pengujian parameter regresi dalam model regresi linier sederhana dapat dilakukan dengan menggunakan uji t . Padahal, di bawah hipotesis $\delta = 0$, nilai statistik uji t pada koefisien Y_{t-1} tidak mengikuti distribusi t dan tidak berdistribusi normal asimtotik, bahkan pada sampel besar. Maka, uji t tidak dapat digunakan untuk menguji hipotesis $\delta = 0$.

Dickey dan Fuller telah memperkenalkan pengujian *unit root* dengan menggunakan statistik uji τ (tau). Nilai kritis (*critical value*) statistik uji τ dihitung menggunakan simulasi Monte Carlo. Berikut adalah uji τ atau sering disebut sebagai uji Dickey-Fuller (DF).

$H_0 : \delta = 0$ (Proses Y_t tidak stasioner)

$H_1 : \delta \neq 0$ (Proses Y_t stasioner)

$$\text{Statistik Uji: } t_{hitung} = \frac{\hat{\delta}}{SE(\hat{\delta})} \quad (2.15)$$

Hipotesis H_0 ditolak jika nilai $|t_{hitung}| > |t_{tabel}|$, dengan nilai t_{tabel} dapat dilihat dalam apendiks D tabel D.7 dalam Gujarati (2004).

Terdapat tiga kemungkinan hipotesis H_0 dalam uji Dickey-Fuller. Ketiga hipotesis tersebut adalah sebagai berikut.

$$Y_t \text{ merupakan } random \text{ walk: } \Delta Y_t = \delta Y_{t-1} + u_t \quad (2.16)$$

Y_t merupakan *random walk* dengan *drift*:

$$\Delta Y_t = \beta_1 + \delta Y_{t-1} + u_t \quad (2.17)$$

Y_t merupakan *random walk* dengan *drift* dan memiliki *trend*:

$$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + u_t. \quad (2.18)$$

Uji DF memiliki asumsi bahwa u_t tidak saling berkorelasi. Pada kasus di mana u_t saling berkorelasi, Dickey dan Fuller telah mengembangkan suatu uji yang didasari pada uji Dickey-Fuller. Uji tersebut sering disebut dengan nama uji *Augmented* Dickey-Fuller (ADF). Model yang digunakan dalam uji ADF adalah sebagai berikut.

$$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + \sum_{i=1}^m \alpha_i \Delta Y_{t-i} + \varepsilon_t \quad (2.19)$$

di mana ε_t merupakan *error* yang bersifat *white noise* murni dan $\Delta Y_{t-i} = (Y_{t-i} - Y_{t-i-1})$. Uji ADF juga menguji hipotesis apakah $\delta = 0$ dan uji ini juga mengikuti distribusi asimtotik yang sama dengan uji DF, sehingga dapat digunakan nilai kritis (*critical value*) yang sama dengan uji DF.

2.7 Prosedur Box-Jenkins

Prosedur Box-Jenkins adalah suatu batu loncatan dalam pendekatan modern untuk analisis *time series*. Tujuan dari prosedur ini adalah untuk membentuk sebuah model ARIMA. Prosedur Box-Jenkins merupakan suatu prosedur dengan pendekatan empirik yang diperlukan untuk mengidentifikasi order dari model ARIMA (p, d, q), mengestimasi dan menguji signifikansi parameter, pemeriksaan diagnostik, menentukan model terbaik, dan peramalan (Box, Jenkins, & Reinsel, 2008).

2.7.1 Identifikasi Model ARIMA

Langkah-langkah dalam identifikasi model ARIMA dalam Wei (2006) terdiri dari empat langkah berikut.

Langkah 1: Plot *time series* data dan pilih transformasi yang sesuai untuk menstabilkan varians.

Langkah 2: Hitung *sample* ACF dan *sample* PACF untuk mengetahui apakah data perlu dilakukan *differencing* sehingga didapatkan data yang telah stasioner.

Langkah 3: Hitung *sample* ACF dan *sample* PACF yang telah dilakukan transformasi dan *differencing* untuk mengetahui order dari p dan q .

Langkah 4: Menguji tren deterministik θ_0 ketika $d > 0$.

Secara teoretis, karakteristik plot ACF dan PACF dari model ARIMA diberikan sebagai berikut.

Tabel 2.2 Karakteristik Plot ACF dan PACF pada Model ARIMA

Proses	ACF	PACF
AR (p)	<i>Tail off</i> sebagai turun secara eksponensial atau gelombang sinus teredam	<i>Cut off</i> setelah lag p
MA (q)	<i>Cut off</i> setelah lag q	<i>Tail off</i> sebagai turun secara eksponensial atau gelombang sinus teredam
ARMA (p, q)	<i>Tail off</i> setelah lag ($q-p$)	<i>Tail off</i> setelah lag ($p-q$)

2.7.2 Estimasi dan Pengujian Signifikansi Parameter

Salah satu metode yang digunakan untuk mengestimasi parameter model ARIMA adalah metode *Least Square* (Cryer & Chan, 2008). Misalkan diberikan model AR (1) di mana,

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

Dengan estimasi *least squares*, selanjutnya dilakukan proses untuk meminimumkan jumlahan kuadrat dari selisih,

$$(Y_t - \mu) - \phi(Y_{t-1} - \mu) \quad (2.21)$$

Karena hanya Y_1, Y_2, \dots, Y_n yang diketahui, maka penjumlahan hanya bisa dilakukan dari $t = 2$ sampai $t = n$. Diberikan suatu fungsi *conditional sum-of-squares* berikut.

$$S_c(\phi, \mu) = \sum_{t=2}^n [(Y_t - \mu) - \phi(Y_{t-1} - \mu)]^2 \quad (2.22)$$

Berdasarkan prinsip *least squares*, parameter ϕ dan μ diestimasi dengan cara meminimumkan nilai $S_c(\phi, \mu)$. Maka, didapatkan persamaan berikut.

$$\frac{\partial S_c}{\partial \mu} = \sum_{t=2}^n 2[(Y_t - \mu) - \phi(Y_{t-1} - \mu)](-1 + \phi) = 0 \quad (2.23)$$

$$\frac{\partial S_c}{\partial \phi} = \sum_{t=2}^n 2[(Y_t - \mu) - \phi(Y_{t-1} - \mu)](Y_{t-1} - \mu) = 0 \quad (2.24)$$

Dengan menyelesaikan persamaan (2.21) dan (2.22), maka didapatkan estimator μ dan ϕ berturut-turut sebagai berikut.

$$\hat{\mu} = \bar{Y} \quad (2.25)$$

$$\hat{\phi} = \frac{\sum_{t=2}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=2}^n (Y_{t-1} - \bar{Y})^2} \quad (2.26)$$

Selanjutnya, jika diberikan model MA(1) berikut.

$$Y_t = e_t - \theta e_{t-1} \quad (2.27)$$

Dengan memperhatikan persamaan (2.27), metode *least squares* cukup sulit diterapkan untuk mendapatkan estimator dari θ . Maka, model MA (1) dapat juga ditulis dalam bentuk model AR dengan order tak hingga.

$$Y_t = -\theta Y_{t-1} - \theta^2 Y_{t-2} - \dots + e_t \quad (2.28)$$

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

$$S_c(\theta) = \sum (e_t)^2 = \sum (Y_t + \theta Y_{t-1} + \theta^2 Y_{t-2} - \dots)^2 \quad (2.29)$$

Selanjutnya, jika diberikan model ARMA(1,1) berikut.

$$Y_t = \phi Y_{t-1} + e_t - \theta e_{t-1} \quad (2.30)$$

Persamaan (2.30) dapat dimodifikasi menjadi sebagai berikut.

$$e_t = Y_t - \phi Y_{t-1} + \theta e_{t-1} \quad (2.31)$$

Maka, metode *least squares* digunakan untuk meminimumkan persamaan berikut.

$$S_c(\phi, \theta) = \sum_{t=2}^n e_t^2 \quad (2.32)$$

Untuk model umum ARMA(p, q), maka langkah awal estimasi adalah dengan mengitung nilai e_t di mana,

$$e_t = Y_t - \phi_1 Y_{t-1} - \dots - \phi_p Y_{t-p} + \theta_1 e_{t-1} + \dots + \theta_p e_{t-p} \quad (2.33)$$

dengan $e_p = e_{p-1} = \dots = e_{p+1-q} = 0$ dan kemudian dilakukan proses perhitungan dengan meminimumkan $S_c(\phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q)$.

Setelah diperoleh estimator dari parameter model ARIMA, kemudian dilakukan pengujian signifikansi parameter. Hipotesis yang digunakan dalam pengujian signifikansi parameter adalah sebagai berikut.

$H_0 : \phi_i = 0$ atau $\theta_j = 0$, di mana $i = 1, 2, \dots, p; j = 1, 2, \dots, q$

$H_1 : \phi_i \neq 0$ atau $\theta_j \neq 0$, di mana $i = 1, 2, \dots, p; j = 1, 2, \dots, q$

Statistik uji yang digunakan adalah sebagai berikut.

$$t = \frac{\hat{\phi}_i}{s.e.(\hat{\phi}_i)} \text{ atau } t = \frac{\hat{\theta}_i}{s.e.(\hat{\theta}_i)} \quad (2.34)$$

H_0 ditolak jika $|t| > t_{\frac{\alpha}{2}, n-k}$ di mana n menunjukkan banyaknya observasi dan k menunjukkan banyaknya parameter model ARIMA.

2.7.3 Pemeriksaan Diagnostik

Terdapat dua asumsi dasar yang harus dipenuhi dalam model ARIMA (p, d, q) , yaitu *residual* yang bersifat *white noise* dan berdistribusi normal.

2.7.3.1 Uji Asumsi White Noise

Residual bersifat *white noise* jika tidak terdapat pola tertentu, tidak terdapat korelasi antar residual, dan dengan *mean nol* dan *varians konstan*. Pengujian asumsi *residual* bersifat *white noise* dapat menggunakan statistik uji Ljung-Box, dengan hipotesis berikut.

$H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0$ (residual bersifat *white noise*)

$H_1 : \exists k, \rho_k \neq 0, k = 1, 2, \dots, K$ (residual tidak bersifat *white noise*)

Statistik uji yang digunakan untuk menguji H_0 adalah sebagai berikut (Cryer & Chan, 2008).

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k \quad (2.35)$$

H_0 ditolak jika $Q \geq \chi_{\alpha, K-p-q}^2$, di mana p dan q adalah order dari model ARIMA(p, d, q).

2.7.3.2 Uji Normalitas

Selain asumsi *white noise*, residual model ARIMA juga harus memenuhi asumsi berdistribusi normal. Pengujian normalitas dapat dilakukan menggunakan uji Kolmogorov-Smirnov. Uji Kolmogorov-Smirnov adalah pengujian normalitas dengan hipotesis berikut.

$H_0 : F(x) = F_0(x)$ atau residual berdistribusi normal

$H_1 : \exists x, F(x) \neq F_0(x)$ atau residual tidak berdistribusi normal

Statistik uji yang digunakan adalah sebagai berikut.

$$D = \sup_x |S(x) - F_0(x)|, \quad (2.36)$$

di mana,

$S(x)$: nilai peluang kumulatif berdasarkan data sampel

$F_0(x)$: nilai peluang kumulatif di bawah H_0

H_0 ditolak jika $D > D_{\alpha, n}$ di mana α adalah taraf signifikansi dan n adalah ukuran sampel (Daniel, 2000).

2.7.4 Peramalan Menggunakan Model ARIMA

Jika diberikan model ARIMA(1,1,1), dengan persamaan berikut.

$$Y_t = (1 + \phi)Y_{t-1} - \phi Y_{t-2} + \theta_0 + e_t - \theta e_{t-1} \quad (2.37)$$

Maka, peramalan k -tahap ke depan dengan model ARIMA(1,1,1) diberikan sebagai berikut (Cryer & Chan, 2008).

$$\hat{Y}_t(1) = (1 + \phi)Y_t - \phi Y_{t-1} + \theta_0 + \theta e_t \quad (2.38)$$

$$\hat{Y}_t(2) = (1 + \phi)\hat{Y}_t(1) - \phi Y_t + \theta_0 \quad (2.39)$$

$$\hat{Y}_t(k) = (1 + \phi)\hat{Y}_t(k-1) - \phi \hat{Y}_t(k-2) + \theta_0 \quad (2.40)$$

2.8 Bentuk Umum Model VAR

Model VAR adalah salah satu model yang baik, fleksibel, dan mudah digunakan dalam analisis *multivariate time series* jika dibandingkan dengan metode lain. Model VAR adalah model *multivariate time series* yang merupakan pengembangan dari model univariat *autoregressive* (AR). Seperti pada kasus univariat, proses AR lebih dapat dipahami dan diinterpretasi daripada proses MA (Chatfield, 2000). Demikian pula dengan proses VAR, maka model VAR menjadi model *multivariate time series* yang sering digunakan. Wei (2006) menjelaskan bentuk umum dari model VAR (p) dapat ditulis sebagai berikut.

$$\dot{Y}_t = \Phi_1 \dot{Y}_{t-1} + \dots + \Phi_p \dot{Y}_{t-p} + \mathbf{a}_t \quad (2.41)$$

Keterangan:

- Φ_p = matriks $m \times m$ dari parameter ke- p
- \mathbf{a}_t = vektor $m \times 1$ dari *residual* pada waktu ke- t
- \dot{Y}_t = vektor $m \times 1$ dari variabel pada waktu ke- t

Persamaan (2.41) dapat dituliskan dalam bentuk matriks sebagai berikut.

$$\begin{bmatrix} \dot{y}_{1,t} \\ \vdots \\ \dot{y}_{m,t} \end{bmatrix} = \begin{bmatrix} \phi_{111} & \dots & \phi_{11m} \\ \vdots & \dots & \vdots \\ \phi_{1m1} & \dots & \phi_{1mm} \end{bmatrix} \begin{bmatrix} \dot{y}_{1,t-1} \\ \vdots \\ \dot{y}_{m,t-1} \end{bmatrix} + \dots + \begin{bmatrix} \phi_{p11} & \dots & \phi_{p1m} \\ \vdots & \dots & \vdots \\ \phi_{pm1} & \dots & \phi_{pmm} \end{bmatrix} \begin{bmatrix} \dot{y}_{1,t-p} \\ \vdots \\ \dot{y}_{m,t-p} \end{bmatrix} + \begin{bmatrix} a_{1,t} \\ \vdots \\ a_{m,t} \end{bmatrix} \quad (2.42)$$

Sebagai contoh, untuk $m = 3$, model VAR(p) dapat dituliskan sebagai berikut.

$$\begin{bmatrix} \dot{y}_{1,t} \\ \dot{y}_{2,t} \\ \dot{y}_{3,t} \end{bmatrix} = \begin{bmatrix} \phi_{111} & \phi_{112} & \phi_{113} \\ \phi_{121} & \phi_{122} & \phi_{123} \\ \phi_{131} & \phi_{132} & \phi_{133} \end{bmatrix} \begin{bmatrix} \dot{y}_{1,t-1} \\ \dot{y}_{2,t-1} \\ \dot{y}_{3,t-1} \end{bmatrix} + \dots + \begin{bmatrix} \phi_{p11} & \phi_{p12} & \phi_{p13} \\ \phi_{p21} & \phi_{p22} & \phi_{p23} \\ \phi_{p31} & \phi_{p32} & \phi_{p33} \end{bmatrix} \begin{bmatrix} \dot{y}_{1,t-p} \\ \dot{y}_{2,t-p} \\ \dot{y}_{3,t-p} \end{bmatrix} + \begin{bmatrix} a_{1,t} \\ a_{2,t} \\ a_{3,t} \end{bmatrix} \quad (2.43)$$

2.9 Identifikasi Vektor *Time Series*

Pada prinsipnya, identifikasi model vektor *time series* mirip dengan identifikasi model *time series* univariat. Jika diberikan vektor *time series* Y_1, Y_2, \dots, Y_n , identifikasi dapat dilakukan dengan melihat pola dari *Correlation Matrix Function* dan *Partial Autoregression Matrices* setelah dilakukan transformasi yang

tepat. Jika diberikan suatu vektor *time series* dengan observasi sebanyak n , Y_1, Y_2, \dots, Y_n , maka *sample correlation matrix function* diberikan oleh:

$$\hat{\rho}(k) = [\hat{\rho}_{ij}(k)] \quad (2.44)$$

dengan $\hat{\rho}_{ij}(k)$ merupakan *sample cross correlation* untuk komponen *series* ke- i dan ke- j yang dinyatakan sebagai berikut.

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k} (Y_{i,t} - \bar{Y}_i)(Y_{j,t+k} - \bar{Y}_j)}{[\sum_{t=1}^n (Y_{i,t} - \bar{Y}_i)^2 \sum_{t=1}^n (Y_{j,t} - \bar{Y}_j)^2]^{1/2}}. \quad (2.45)$$

Matrix autocorrelation function ini sangat berguna untuk mengidentifikasi *order* berhingga dalam model *moving average* (MA) sebagai matriks korelasi adalah 0 (nol) di bawah lag q untuk proses *vector moving average* (VMA). Akan tetapi bentuk matriks dan grafik akan semakin kompleks seiring dengan meningkatnya dimensi vektor. Untuk mengatasinya, digunakan suatu metode yang sesuai untuk meringkas penjelasan *matrix autocorrelation function*, yaitu dengan menggunakan simbol (+), (-), and (.) pada posisi (i, j) dari *sample correlation matrix function*, dimana simbol (+) menotasikan nilai yang lebih besar dari 2 kali estimasi *standard error* dan menunjukkan adanya hubungan korelasi positif, (-) menotasikan nilai yang kurang dari -2 kali estimasi standar error atau adanya hubungan korelasi negatif, sedangkan (.) menotasikan nilai yang berada di antara ± 2 kali estimasi *standard error* yang artinya tidak terdapat hubungan korelasi, di mana *standard error* bernilai $\frac{1}{\sqrt{n}}$ dengan n merupakan ukuran sampel atau banyak observasi. Berikut adalah contoh *sample correlation matrices* dari data *time series* dengan $n = 54$.

$lag(k)$	1	2	3	4
$\hat{\rho}(k)$	$\begin{bmatrix} 0,05 & 0,31 \\ 0,22 & 0,43 \end{bmatrix}$	$\begin{bmatrix} -0,40 & -0,15 \\ -0,14 & 0,10 \end{bmatrix}$	$\begin{bmatrix} -0,09 & 0,07 \\ -0,06 & 0,07 \end{bmatrix}$	$\begin{bmatrix} 0,43 & 0,28 \\ 0,16 & -0,11 \end{bmatrix}$
	$\begin{bmatrix} \cdot & + \\ \cdot & + \end{bmatrix}$	$\begin{bmatrix} - & \cdot \\ \cdot & \cdot \end{bmatrix}$	$\begin{bmatrix} \cdot & \cdot \\ \cdot & \cdot \end{bmatrix}$	$\begin{bmatrix} + & + \\ \cdot & \cdot \end{bmatrix}$
$lag(k)$	5	6	7	8
$\hat{\rho}(k)$	$\begin{bmatrix} 0,04 & 0,19 \\ -0,14 & 0,03 \end{bmatrix}$	$\begin{bmatrix} -0,34 & -0,19 \\ -0,30 & -0,16 \end{bmatrix}$	$\begin{bmatrix} -0,07 & 0,01 \\ 0,03 & -0,14 \end{bmatrix}$	$\begin{bmatrix} 0,16 & 0,09 \\ 0,03 & -0,14 \end{bmatrix}$
	$\begin{bmatrix} \cdot & \cdot \\ \cdot & \cdot \end{bmatrix}$	$\begin{bmatrix} - & \cdot \\ \cdot & \cdot \end{bmatrix}$	$\begin{bmatrix} \cdot & \cdot \\ \cdot & \cdot \end{bmatrix}$	$\begin{bmatrix} \cdot & \cdot \\ \cdot & \cdot \end{bmatrix}$

Gambar 2.1 Contoh *Sample Correlation Matrices* untuk 2 Data *Time Series*

Pada *time series* univariat, *partial autocorrelation function* (PACF) sangat penting untuk menentukan *order* dalam model AR. Generalisasi dari konsep PACF ke dalam bentuk vektor *time series* pada Wei (2006), yang mendefinisikan matriks autoregresi parsial pada lag s dengan notasi $\wp(s)$, sebagai koefisien matriks terakhir ketika data diterapkan ke dalam suatu proses *vector autoregressive* dari orde s . Maka, persamaan untuk matriks autoregresi parsial adalah sebagai berikut (Wei, 2006).

$$\wp(s) = \begin{cases} \Gamma'(1)[\Gamma(0)]^{-1}, & s = 1 \\ \{\Gamma'(s) - c'(s)[A(s)]^{-1}b(s)\}\{\Gamma(0) - b'(s)[A(s)]^{-1}b(s)\}^{-1}, & s > 1 \end{cases} \quad (2.46)$$

Untuk $s \geq 2$, maka nilai $A(s)$, $b(s)$, dan $c(s)$ diberikan oleh:

$$A(s) = \begin{bmatrix} \Gamma(0) & \Gamma'(1) & \dots & \Gamma'(s-2) \\ \Gamma(1) & \Gamma(0) & \dots & \Gamma'(s-3) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma(s-2) & \Gamma(s-3) & \dots & \Gamma(0) \end{bmatrix},$$

$$b(s) = \begin{bmatrix} \Gamma'(s-1) \\ \Gamma'(s-2) \\ \vdots \\ \Gamma'(1) \end{bmatrix}, c(s) = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(s-1) \end{bmatrix}$$

di mana

$$\Gamma(k) = E(\dot{Y}_{t-k}\dot{Y}_t')$$

Jika Y_t merupakan proses VAR(p), maka $\wp(s)$ mempunyai sifat khusus berikut.

$$\wp(s) = \begin{cases} \Phi_p, & s = p \\ 0, & s > p. \end{cases} \quad (2.47)$$

Untuk memudahkan dalam mengidentifikasi data berdasarkan nilai *partial autoregression matrices*, maka nilai-nilai *partial autoregression matrices* juga dinotasikan dalam bentuk simbol (+), (-), dan (.) seperti pada *sample correlation matrix function*. Sama halnya dengan PACF pada kasus univariat, *partial autoregression matrices*, $\wp(s)$, juga memiliki sifat *cut-off* untuk proses vektor AR.

<i>lag</i> (k)	1	2	3
$\hat{P}(k)$	$\begin{bmatrix} 0,05 & 0,31 \\ 0,22 & 0,43 \end{bmatrix}$	$\begin{bmatrix} -0,53 & -0,28 \\ -0,32 & -0,10 \end{bmatrix}$	$\begin{bmatrix} -0,12 & -0,04 \\ 0,21 & 0,09 \end{bmatrix}$
	$\begin{bmatrix} \cdot & + \\ \cdot & + \end{bmatrix}$	$\begin{bmatrix} - & - \\ - & \cdot \end{bmatrix}$	$\begin{bmatrix} \cdot & \cdot \\ \cdot & \cdot \end{bmatrix}$
<i>lag</i> (k)	5	6	7
$\hat{P}(k)$	$\begin{bmatrix} 0,24 & 0,05 \\ 0,21 & -0,01 \end{bmatrix}$	$\begin{bmatrix} -0,11 & -0,32 \\ 0,16 & -0,02 \end{bmatrix}$	$\begin{bmatrix} -0,07 & -0,20 \\ -0,06 & -0,05 \end{bmatrix}$
	$\begin{bmatrix} \cdot & \cdot \\ \cdot & \cdot \end{bmatrix}$	$\begin{bmatrix} \cdot & - \\ \cdot & \cdot \end{bmatrix}$	$\begin{bmatrix} \cdot & \cdot \\ \cdot & \cdot \end{bmatrix}$

Gambar 2.2 *Partial Lag Correlation Matrix Function* untuk 2 Data Time Series

2.10 Estimasi Parameter Model VAR

Ketika model sementara sudah diidentifikasi, dilakukan estimasi parameter model VAR dengan menggunakan metode LS (*Least Square*). Diberikan model VAR(p) sebagai berikut.

$$\mathbf{Y} = \mathbf{BZ} + \mathbf{U} \quad (2.48)$$

atau,

$$\begin{aligned} \text{vec}(\mathbf{Y}) &= \text{vec}(\mathbf{BZ}) + \text{vec}(\mathbf{U}) \\ &= (\mathbf{Z}' \otimes \mathbf{I}_K) \text{vec}(\mathbf{B}) + \text{vec}(\mathbf{U}) \end{aligned} \quad (2.49)$$

atau,

$$\mathbf{y} = (\mathbf{Z}' \otimes \mathbf{I}_K) \boldsymbol{\beta} + \mathbf{u} \quad (2.50)$$

di mana,

$$\begin{aligned} \mathbf{Y} &= (y_1, y_2, \dots, y_T) \\ \mathbf{B} &= (\mathbf{v}, \mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_p) \\ \mathbf{Z} &= (\mathbf{Z}_0, \mathbf{Z}_1, \dots, \mathbf{Z}_{T-1}) \\ \mathbf{Z}_t &= \begin{bmatrix} 1 \\ y_t \\ \vdots \\ y_{t-p+1} \end{bmatrix} \\ \mathbf{U} &= (\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_T) \\ \mathbf{y} &= \text{vec}(\mathbf{Y}) \\ \boldsymbol{\beta} &= \text{vec}(\mathbf{B}) \\ \mathbf{b} &= \text{vec}(\mathbf{B}') \\ \mathbf{u} &= \text{vec}(\mathbf{U}) \end{aligned}$$

dengan matriks kovarians \mathbf{u} sebagai berikut.

$$\Sigma_{\mathbf{u}} = \mathbf{I}_T \otimes \Sigma_{\mathbf{u}}. \quad (2.51)$$

Maka, estimasi LS multivariat dari $\boldsymbol{\beta}$ berarti memilih estimator dengan meminimumkan

$$\begin{aligned} S(\boldsymbol{\beta}) &= \mathbf{u}'(\mathbf{I}_T \otimes \Sigma_{\mathbf{u}})^{-1} \mathbf{u} = \mathbf{u}'(\mathbf{I}_T \otimes \Sigma_{\mathbf{u}}^{-1}) \mathbf{u} \\ &= [\mathbf{y} - (\mathbf{Z}' \otimes \mathbf{I}_K)]' (\mathbf{I}_T \otimes \Sigma_{\mathbf{u}}^{-1}) [\mathbf{y} - (\mathbf{Z}' \otimes \mathbf{I}_K)] \\ &= \text{vec}(\mathbf{Y} - \mathbf{BZ})' (\mathbf{I}_T \otimes \Sigma_{\mathbf{u}}^{-1}) \text{vec}(\mathbf{Y} - \mathbf{BZ}) \\ &= \text{tr}[(\mathbf{Y} - \mathbf{BZ})' \Sigma_{\mathbf{u}}^{-1} (\mathbf{Y} - \mathbf{BZ})]. \end{aligned} \quad (2.52)$$

Untuk mencari nilai minimum dari fungsi (2.52), perhatikan bahwa

$$\begin{aligned} S(\boldsymbol{\beta}) &= \mathbf{y}'(\mathbf{I}_T \otimes \Sigma_{\mathbf{u}}^{-1}) \mathbf{y} + \boldsymbol{\beta}'(\mathbf{Z} \otimes \mathbf{I}_K)(\mathbf{I}_T \otimes \Sigma_{\mathbf{u}}^{-1})(\mathbf{Z}' \otimes \mathbf{I}_K) \boldsymbol{\beta} \\ &\quad - 2\boldsymbol{\beta}'(\mathbf{Z} \otimes \mathbf{I}_K)(\mathbf{I}_T \otimes \Sigma_{\mathbf{u}}^{-1}) \mathbf{y} \\ &= \mathbf{y}'(\mathbf{I}_T \otimes \Sigma_{\mathbf{u}}^{-1}) \mathbf{y} + \boldsymbol{\beta}'(\mathbf{ZZ}' \otimes \Sigma_{\mathbf{u}}^{-1}) \boldsymbol{\beta} - 2\boldsymbol{\beta}'(\mathbf{Z} \otimes \Sigma_{\mathbf{u}}^{-1}) \mathbf{y}. \end{aligned} \quad (2.53)$$

Maka,

$$\frac{\partial S(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}} = 2(\mathbf{ZZ}' \otimes \Sigma_{\mathbf{u}}^{-1}) \boldsymbol{\beta}' - 2(\mathbf{Z} \otimes \Sigma_{\mathbf{u}}^{-1}) \mathbf{y}. \quad (2.54)$$

Fungsi $S(\boldsymbol{\beta})$ minimum ketika $\frac{\partial S(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}} = 0$, sehingga

$$(\mathbf{ZZ}' \otimes \Sigma_{\mathbf{u}}^{-1}) \hat{\boldsymbol{\beta}} = (\mathbf{Z} \otimes \Sigma_{\mathbf{u}}^{-1}) \mathbf{y}. \quad (2.55)$$

Akibatnya, estimator LS adalah

$$\hat{\boldsymbol{\beta}} = ((\mathbf{ZZ}')^{-1} \otimes \Sigma_{\mathbf{u}})(\mathbf{Z} \otimes \Sigma_{\mathbf{u}}^{-1}) \mathbf{y}$$

$$\widehat{\beta} = ((ZZ')^{-1}Z \otimes I_K)y. \quad (2.56)$$

Matriks Hessian $S(\beta)$

$$\frac{\partial^2 S(\beta)}{\partial \beta \partial \beta'} = 2(ZZ' \otimes \Sigma_u^{-1}) \quad (2.57)$$

bersifat definit positif, sehingga menjamin bahwa $\widehat{\beta}$ adalah vektor yang minimum.

2.11 Pemeriksaan Diagnostik Model VAR

Setelah dilakukan estimasi parameter, maka selanjutnya perlu dilakukan pemeriksaan diagnostik. Salah satu pemeriksaan yang dilakukan adalah analisis residual \widehat{a}_t , di mana $\widehat{a}_t = \dot{Y}_t - \widehat{\Phi}_1 \dot{Y}_{t-1} - \dots - \widehat{\Phi}_p \dot{Y}_{t-p}$. Model VAR yang sesuai seharusnya bersifat *white noise* dan berdistribusi multivariat normal. Maka, matriks korelasi dari \widehat{a}_t haruslah tidak signifikan dan tidak memiliki pola (Wei, 2006).

2.13.1 Uji Portmanteau

Uji Portmanteau digunakan untuk menguji signifikansi secara keseluruhan pada autokorelasi residual sampai lag h . Hipotesis yang diuji dalam uji portmanteau adalah sebagai berikut.
 H_0 : vektor residual model VAR (p) memenuhi asumsi *white noise*.

H_1 : vektor residual model VAR (p) tidak memenuhi asumsi *white noise*,

atau secara matematis dapat dituliskan sebagai berikut.

$$H_0: \mathbf{R}_h = (R_1, R_2, \dots, R_h) = 0$$

$$H_1: \mathbf{R}_h \neq 0$$

Statistik uji yang digunakan adalah sebagai berikut.

$$\begin{aligned} Q_h &= T \sum_{i=1}^h \text{tr}(\widehat{R}'_i \widehat{R}_u^{-1} \widehat{R}_i \widehat{R}_u^{-1}) \\ &= T \sum_{i=1}^h \text{tr}(\widehat{R}'_i \widehat{R}_u^{-1} \widehat{R}_i \widehat{R}_u^{-1} \widehat{D}^{-1} \widehat{D}) \\ &= T \sum_{i=1}^h \text{tr}(\widehat{D} \widehat{R}'_i \widehat{D} \widehat{D}^{-1} \widehat{R}_u^{-1} \widehat{D}^{-1} \widehat{D} \widehat{R}_i \widehat{D} \widehat{D}^{-1} \widehat{R}_u^{-1} \widehat{D}^{-1}) \\ &= T \sum_{i=1}^h \text{tr}(\widehat{C}'_i \widehat{C}_0^{-1} \widehat{C}_i \widehat{C}_0^{-1}) \end{aligned} \quad (2.58)$$

di mana T adalah ukuran sampel dan \hat{C}_k adalah matriks autokovarians dari vektor residual $\hat{\mathbf{a}}_t$, di mana $k = 0, 1, 2, \dots, h$. H_0 ditolak jika $Q_h > \chi^2$ (Lutkepohl, 2005).

2.13.2 Uji Normalitas Multivariat Shapiro-Wilk

Jika diberikan $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n$ adalah vektor random yang bersifat independen dan identik dalam \mathbf{R}^p , di mana $p \geq 1$. Misalkan $\mathbf{0}$ adalah vektor nol dengan ukuran p dan \mathbf{I} adalah matriks identitas berukuran $p \times p$, maka $\mathbf{X} \sim \mathbf{N}^p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ jika dan hanya jika $\mathbf{Z} = \boldsymbol{\Sigma}^{-1/2}(\mathbf{X} - \boldsymbol{\mu}) \sim \mathbf{N}^p(\mathbf{0}, \mathbf{I})$. Statistik Shapiro-Wilk digunakan untuk menguji hipotesis berikut.

H_0 : $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n$ adalah sampel yang berasal dari $\mathbf{X} \sim \mathbf{N}^p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$

H_1 : $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n$ bukan sampel yang berasal dari $\mathbf{X} \sim \mathbf{N}^p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$,

di mana $\boldsymbol{\mu}$ dan $\boldsymbol{\Sigma}$ tidak diketahui, maka digunakan statistik Shapiro-Wilk berikut (Alva & Estrada, 2009).

$$W^* = \frac{1}{p} \sum_{i=1}^p W_{Z_i}, \quad (2.59)$$

dengan W_{Z_i} adalah statistik Shapiro-Wilk yang dihitung dari nilai observasi yang ditransformasi ke normal standar $Z_{i1}, Z_{i2}, \dots, Z_{in}$, di mana $i = 1, \dots, p$.

Di bawah hipotesis H_0 , W^* diekspektasi mendekati 1 karena masing-masing W_{Z_i} juga diekspektasi mendekati 1. Dengan ukuran uji α , Hipotesis H_0 ditolak jika $W^* < c_{\alpha;n,p}$, di mana $c_{\alpha;n,p}$ memenuhi persamaan berikut.

$$\alpha = P\{W^* < c_{\alpha;n,p} | H_0\}. \quad (2.60)$$

Jika $p = 1$, maka statistik W^* sama dengan statistik Shapiro-Wilk untuk kasus univariat.

2.12 Lag length Selection

Panjang *lag* untuk model VAR(p) dapat ditentukan dengan menggunakan *model selection criteria*. Pendekatan umum dari metode ini adalah melakukan *fitting* model VAR(p) dengan order $p = 0, 1, \dots, p_{max}$ dan memilih nilai p yang meminimumkan *model selection criteria*. *Model selection criteria* untuk model VAR(p) adalah sebagai berikut.

$$IC(p) = \ln|\bar{\Sigma}(p)| + c_T \varphi(n, p) \quad (2.61)$$

di mana $\bar{\Sigma}(p) = T^{-1} \sum_{t=1}^T \hat{\varepsilon}_t \hat{\varepsilon}_t'$ adalah matriks residual kovarians koreksi derajat bebas dari model VAR(p), c_T adalah suatu barisan dengan ukuran sampel T dan $\varphi(n, p)$ adalah *penalty function* yang untuk model VAR(p). Salah satu *information criteria* yang lazim digunakan yaitu *Akaike Information Criterion* (AIC).

$$AIC(p) = \ln|\bar{\Sigma}(p)| + \frac{2}{T} pn^2 \quad (2.62)$$

2.13 Peramalan Menggunakan Model VAR

Peramalan satu tahap ke depan (*one-step forecast*) untuk model VAR(p), seperti yang dijelaskan oleh Tsay (2010) adalah sebagai berikut.

$$\mathbf{Y}_h(1) = \boldsymbol{\phi}_0 + \sum_{i=1}^p \Phi \mathbf{Y}_{h+1-i} \quad (2.63)$$

dan *error* dari *forecasting* adalah sebagai berikut.

$$\mathbf{e}_h(1) = \mathbf{a}_{h+1} \quad (2.64)$$

Matriks kovarians dari *forecasting error value* adalah Σ . Jika \mathbf{Y}_t bersifat *weakly stationary*, maka *forecasting* untuk l tahap ke depan atau $\mathbf{Y}_h(l)$ adalah konvergen ke vektor rata-rata ($\boldsymbol{\mu}$).

2.14 Uji Linieritas

Uji Linieritas (*Teräsvirta Neural Network Test for Nonlinearity*) adalah adalah uji linieritas yang dikembangkan dari model *neural network* dan termasuk dalam kelompok uji tipe *Lagrange Multiplier* (LM) yang dikembangkan dengan ekspansi Taylor (Teräsvirta, 1993). Uji ini adalah suatu uji linieritas untuk melawan persamaan model nonlinier berikut.

$$y_t = \boldsymbol{\beta}' \mathbf{w}_t + \sum_{j=1}^q \theta_{0j} \left\{ \psi(\boldsymbol{\gamma}'_j \mathbf{w}_t) + \frac{1}{2} \right\} + u_t \quad (2.65)$$

di mana,

$$\mathbf{w}_t = \{y_{t-j}, j > 0; x_{t-i}, i \geq 0\}, t = 1, 2, \dots, n$$

Hipotesis dalam uji ini diberikan sebagai berikut.

$H_0 : \theta_{01} = \theta_{02} = \dots = \theta_{0q} = 0$ (y_t merupakan fungsi linier)

$H_1 : \exists j, \theta_{0j} \neq 0, j = 1, 2, \dots, q$ (y_t merupakan fungsi nonlinier)

Implementasi uji ini dapat dilakukan melalui dua statistik uji, yaitu uji χ^2 dan uji F . Prosedur untuk mendapatkan uji χ^2 adalah sebagai berikut:

1. Regresikan y_t pada $1, y_{t-1}, y_{t-2}, \dots, y_{t-p}$ dan hitung nilai residual $\hat{u}_t = y_t - \hat{y}_t$.
2. Regresikan \hat{u}_t pada $1, y_{t-1}, y_{t-2}, \dots, y_{t-p}$ dan m prediktor tambahan, dan kemudian hitung koefisien determinasi dari regresi R^2 .
3. Hitung statistik $\chi^2 = nR^2$, dengan n adalah banyaknya pengamatan yang digunakan.

Dibawah hipotesis linieritas, χ^2 mendekati distribusi $\chi^2(m)$, dengan m adalah banyaknya prediktor tambahan (Suhartono, 2007).

Sedangkan prosedur uji F untuk uji linieritas tipe LM ini adalah sebagai berikut.

1. Regresikan y_t pada $1, y_{t-1}, y_{t-2}, \dots, y_{t-p}$, dan hitung nilai residual $\hat{u}_t = y_t - \hat{y}_t$ serta jumlah kuadrat residual $SSR_0 = \sum \hat{u}_t^2$.
2. Regresikan \hat{u}_t pada $1, y_{t-1}, y_{t-2}, \dots, y_{t-p}$ dan m prediktor tambahan, dan hitung nilai residual $\hat{v}_t = \hat{u}_t - \hat{\hat{u}}_t$ serta jumlah kuadrat residual $SSR_1 = \sum \hat{v}_t^2$.
3. Hitung statistik $F = \frac{(SSR_0 - SSR_1)/m}{SSR_1/(n-p-1-m)}$ dengan n adalah banyaknya pengamatan yang digunakan.

Di bawah hipotesis linieritas, F mendekati distribusi F dengan derajat bebas m dan $(n - p - 1 - m)$. Penggunaan dari uji F menggantikan uji χ^2 ini didasarkan oleh rekomendasi dari teori asimtotis dalam sampel kecil, yaitu karena uji ini mempunyai sifat-sifat kuasa dan ukuran yang baik.

2.15 Artificial Neural Network (ANN)

Artificial Neural Network (ANN) atau jaringan saraf tiruan adalah sebuah *information-processing system* yang memiliki


karakteristik performa tertentu dalam jaringan saraf biologis (Fausett, 1992). ANN telah dikembangkan sebagai generalisasi model matematis dari kesadaran manusia atau biologi saraf, berdasarkan asumsi-asumsi sebagai berikut.

1. Pemrosesan informasi terjadi pada banyak *simple element* yang disebut *neuron*.
2. Sinyal dilewatkan di antara *neuron* di atas *connection links*.
3. Masing-masing *connection link* memiliki bobot yang dikalikan dengan sinyal yang ditransmisi.
4. Masing-masing *neuron* menggunakan fungsi aktivasi (biasanya nonlinier) pada *net input* (jumlahan sinyal *input* terboboti) untuk menentukan sinyal *output*.

Sebuah *neural network* digolongkan berdasarkan pola *connection* di antara *neuron* (disebut juga arsitektur), metode dalam menentukan bobot dari *connection* (disebut *training, learning, atau algoritma*), dan fungsi aktivasi.

2.17.1 Arsitektur Neural Network

Terdapat beberapa komponen yang harus dipertimbangkan dalam metode ANN *modeling*, yaitu *neuron, layer, fungsi aktivasi, dan bobot*. Komponen-komponen ini akan sangat mempengaruhi dalam menentukan model ANN karena pembentukan model ANN didasarkan pada jumlah *neuron* dalam *input layer, hidden layer, dan output layer* serta fungsi aktivasi. Beberapa fungsi aktivasi yang terkenal adalah *binary, bipolar, linear, saturating linear, symmetric saturating linear, binary sigmoid, dan bipolar sigmoid* (Kusumadewi, 2004). Jika diberikan sebuah model ANN yang menggunakan, 3 *neuron* dalam *input layer, 5 unit* dalam *hidden layer, fungsi aktivasi, dan 3 neuron* dalam *output layer*, maka bentuk arsitektur ANN tersebut diberikan pada Gambar 2.3 Berikut.



Gambar 2.3 Contoh Arsitektur ANN

2.17.2 Model ANN

Model ANN adalah suatu model yang memiliki kemampuan baik dalam memodelkan data yang memiliki pola nonlinier (Zhang, 2003). Model ANN tidak membutuhkan asumsi dalam proses pembentukan model. Karakteristik dari data merupakan hal yang lebih menentukan bentuk dari model ANN. Dalam pemodelan dan peramalan *time series* sering digunakan model *single hidden layer feedforward network* (Zhang, Patuwo, & Hu, 1998). Model ini terdiri dari jaringan dengan tiga lapisan *simple processing units* yang dihubungkan oleh *acyclic link*. Dengan demikian, hubungan antara *output* (y_t) dan *input* ($y_{t-1}, y_{t-2}, \dots, y_{t-p}$) dijelaskan oleh persamaan matematis berikut.

$$y_t = \alpha_0 + \sum_{j=1}^q \alpha_j g(\beta_{0j} + \sum_{i=1}^p \beta_{ij} y_{t-i}) + \varepsilon_t \quad (2.66)$$

di mana α_j ($j = 0, 1, 2, \dots, q$) dan β_{ij} ($i = 1, 2, \dots, p; j = 0, 1, 2, \dots, q$) adalah parameter model yang sering disebut *connection weights*, p adalah banyak *input node* dan q adalah banyaknya *hidden node*. Fungsi logistik yang sering digunakan sebagai *hidden layer transfer function* diberikan sebagai berikut.

$$g(x) = \frac{1}{1 + \exp(-x)}. \quad (2.67)$$

Maka, model ANN dari persamaan (2.66) menampilkan *nonlinear functional mapping* dari nilai observasi-observasi sebelumnya

$(y_{t-1}, y_{t-2}, \dots, y_{t-p})$ terhadap nilai di masa depan y_t , dengan contoh sebagai berikut.

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-p}, \mathbf{w}) + \varepsilon_t, \quad (2.68)$$

di mana \mathbf{w} adalah vektor semua parameter dan f adalah fungsi yang menjelaskan struktur jaringan dan *connection weights*.

Jaringan sederhana yang diberikan oleh persamaan (2.66) ternyata memberikan hasil peramalan yang baik ketika banyaknya *hidden nodes* q cukup besar (Hornik, Stinchcombe, & White, 1990). Namun, dalam praktiknya struktur jaringan yang memiliki *hidden nodes* yang kecil sering bekerja dengan baik dalam peramalan *out-of-sample*. Hal ini kemungkinan terjadi akibat efek *overfitting* yang biasanya ditemukan dalam proses pemodelan *Neural Network*. Model yang *overfitted* memberikan hasil peramalan yang baik terhadap data *in-sample*, tapi memberikan hasil peramalan yang buruk untuk data *out-of-sample*. Oleh karena itu, pemilihan banyaknya *hidden nodes* q bergantung pada pola data tersebut dan tidak ada aturan sistematis dalam menentukan parameter ini.

2.17.3 Model *Hybrid* VAR-ANN

Model *Hybrid* VAR-ANN merupakan model gabungan (*hybrid*) dari komponen linier (model VAR) dan komponen nonlinier (model ANN). Model ARIMA (untuk data univariat) dan VAR (untuk data multivariat) bekerja dengan baik ketika digunakan untuk memodelkan data yang memiliki pola linier, sementara model ANN bekerja dengan baik ketika digunakan untuk memodelkan data yang memiliki pola nonlinier. Meskipun begitu, tidak ada salah satu pun dari model-model tersebut yang dapat bekerja dengan baik untuk memodelkan data dengan pola linier dan pola nonlinier (Zhang, 2003). Oleh karena itu, dibentuk suatu model *time series* dengan komposisi yang terdiri dari komponen linier dan komponen nonlinier sebagai berikut.

$$\mathbf{Y}_t = \mathbf{L}_t + \mathbf{N}_t, \quad (2.69)$$

di mana \mathbf{L}_t menyatakan komponen linier dan \mathbf{N}_t menyatakan komponen nonlinier. Kedua komponen ini didapatkan dari hasil

estimasi data. Pertama, misalkan komponen linier didapatkan dari pemodelan VAR, maka *residual* dari model VAR akan hanya berisi komponen nonlinier. Misalkan \mathbf{e}_t menyatakan vektor *residual* pada waktu ke- t dari model linier VAR, maka didapatkan persamaan berikut.

$$\mathbf{e}_t = \mathbf{Y}_t - \hat{\mathbf{L}}_t, \quad (2.70)$$

di mana $\hat{\mathbf{L}}_t$ menyatakan nilai peramalan dari waktu ke- t dari model linier VAR.

Residual merupakan bagian penting dalam diagnosis sifat *sufficient* suatu model linier. Model linier dikatakan tidak bersifat *sufficient* jika masih ada struktur korelasi linier dalam *residual*. Meskipun begitu, analisis *residual* tidak dapat mendeteksi adanya pola nonlinier pada data. Sampai sekarang masih belum ada metode diagnostik umum untuk mengetahui adanya autokorelasi nonlinier. Oleh karena itu, meskipun model telah melewati pemeriksaan diagnostik, namun model masih belum layak jika hubungan nonlinier di dalam data belum dimodelkan dengan tepat. Dengan adanya pola nonlinier yang signifikan dalam *residual*, hal ini akan membatasi kemampuan model linier VAR. Melalui pemodelan *residual* menggunakan ANN, maka hubungan nonlinier di dalam *residual* dapat ditangkap. Dengan n input node, dibentuk persamaan model ANN *residual* berikut.

$$\mathbf{e}_t = f(\mathbf{e}_{t-1}, \mathbf{e}_{t-2}, \dots, \mathbf{e}_n) + \boldsymbol{\varepsilon}_t, \quad (2.71)$$

di mana f adalah fungsi nonlinier yang ditentukan oleh *neural network* dan $\boldsymbol{\varepsilon}_t$ adalah *random error*. Misalkan $\hat{\mathbf{N}}_t$ menyatakan hasil peramalan dari persamaan (2.71), maka hasil peramalan dari kombinasi model linier dan nonlinier diberikan sebagai berikut.

$$\hat{\mathbf{Y}}_t = \hat{\mathbf{L}}_t + \hat{\mathbf{N}}_t, \quad (2.72)$$

2.16 Seleksi Model Terbaik

Seleksi model *time series* terbaik didasarkan pada kriteria *out-of-sample*. Kriteria *out-of-sample* yang digunakan adalah *Root Mean Square Error* (RMSE). Ukuran RMSE adalah salah satu ukuran yang paling sering digunakan yang besarnya didasarkan pada kuadrat *error*. RMSE menjadi populer karena

memiliki relevansi secara teoritis dalam pemodelan statistik (Hyndman & Koehler, 2006). Formula untuk menghitung RMSE adalah sebagai berikut.

$$\text{RMSE} = \frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2 \quad (2.73)$$

2.17 Gerak Kapal (*Ship Motion*)

Gerak kapal (*ship motion*) memiliki 3 sumbu, yaitu sumbu vertikal, sumbu lateral, dan sumbu longitudinal (Levis, 1989). Sementara gerak kapal (*ship motion*) terdiri dari enam macam gerak. Enam gerak tersebut terbagi menjadi dua tipe, yaitu 3 gerak translasi dan 3 gerak rotasi. Gerak translasi terdiri dari *heaving*, *swaying*, dan *surging*.

1. *Heaving*


Heaving adalah gerakan dengan arah vertikal linier (atas/bawah). Kapal tidak bergerak ketika gerak ke atas dan gerak ke bawah berada pada ekuilibrium dan kapal terapung. Kemampuan mengapung kapal berubah-ubah selama kapal berlayar melewati puncak gelombang dan palung gelombang. Ketika palung gelombang lebih dominan, maka kapal akan “tenggelam”. Ketika puncak gelombang lebih dominan, maka kapal akan naik. Osilasi tersebut akan memberikan pengaruh pada kontainer dan isinya.

2. *Swaying*

Swaying adalah gerakan dengan arah lateral linier (kanan/kiri). Jika badan kapal bagian depan berada pada puncak dan badan kapal lainnya berada di sisi yang lain, maka lambung kapal akan mengalami gaya torsi yang cukup besar.

3. *Surging*

Surging adalah gerakan dengan arah longitudinal linier (depan/belakang).



Gambar 2.4 Gerak Translasi Kapal

Berikut adalah tiga macam gerak rotasi.

1. *Pitching*

Pitching adalah gerakan rotasi kapal terhadap sumbu lateral (depan/belakang). Dalam *pitching*, kapal diangkat di haluan dan diturunkan di buritan atau sebaliknya. Sudut *pitching* bervariasi tergantung panjang kapal. Kapal yang relatif pendek memiliki sudut *pitching* sebesar 5° - 8° dan kadang-kadang bisa lebih dari 8° , sementara kapal yang panjang biasanya memiliki sudut *pitching* kurang dari 5° . Sebuah kapal yang panjangnya 300 m memiliki sudut *pitching* 3° , sehingga jika suatu kontainer yang disimpan di teluk yang paling dekat dengan haluan atau buritan pada jarak kira-kira 140 m dari sumbu *pitching* akan menempuh jarak 29 m dalam siklus *pitching*, diangkat ke atas 7,33 m dari horizontal sebelum turun 14,66 m ke bawah dan akhirnya dibangkitkan 7,33 m lagi dan kemudian begitu seterusnya. Selama gerakan ke atas, tumpukan tekanan meningkat. Sementara kapal jatuh selama gerakan ke bawah.


2. *Rolling*

Rolling adalah gerakan rotasi kapal terhadap sumbu longitudinal (kanan/kiri). Periode *rolling* didefinisikan sebagai waktu yang dibutuhkan untuk osilasi *rolling* penuh dari horizontal

ke kiri, kembali ke horizontal kemudian ke kanan, dan kembali lagi ke horizontal. Pada kapal yang memiliki kapasitas besar, periode *rolling* biasanya sebanyak 10 *rolling* atau di bawahnya. Sudut *rolling* diukur relatif terhadap horizontal. Ketika kapal berada di laut moderat, bahkan kapal-kapal besar memiliki sudut *rolling* sebesar 10° . Dalam kejadian langka, sudut *rolling* juga bisa mencapai 45° atau lebih. Hal ini berarti bahwa kargo kontainer di dalam kapal tersebut tidak cukup aman.

3. *Yawing*

Yawing adalah gerakan rotasi kapal terhadap sumbu vertikal. Hal ini terjadi karena ketidakmungkinan kemudi kapal pada jalur benar-benar lurus. Tergantung pada kondisi laut dan kemudi defleksi, kapal akan berayun sekitar jalur yang diproyeksikan. Tetapi *yawing* bukanlah penyebab kerusakan pada kapal.



Gambar 2.5 Gerak Rotasi Kapal

2.18 Gelombang Irreguler

Gelombang Irreguler (*irregular waves*) merupakan gelombang dengan panjang antara dua puncak atau lembah berurutan dan jarak vertikal antara puncak dan lembah berubah secara kontinu. Beberapa analisis statistik dalam gelombang

irreguler di antaranya adalah periode gelombang rata-rata (*average wave period*), rata-rata tinggi gelombang (*average wave height*), dan tinggi gelombang signifikan (*significant wave height*).

Periode gelombang rata-rata atau *average wave period*, \bar{T} , dapat ditemukan dengan mudah dari periode rata-rata puncak gelombang atau lembah. Cara termudah untuk melakukannya adalah dengan membagi durasi rekaman gerak gelombang dengan jumlah gerakan gelombang ke atas (atau ke bawah) yang melewati titik nol dikurangi satu.

Untuk mendapatkan nilai rata-rata tinggi gelombang atau *average wave height* dibutuhkan perhitungan yang cukup rumit. Tinggi gelombang berturut-turut diukur dan diklasifikasikan ke dalam grup-grup dengan interval tertentu. Informasi statistik dapat diperoleh dari fungsi densitas peluang $f(x)$. Tinggi gelombang dari masing-masing grup kemudian dihitung banyaknya dan dibagi dengan banyaknya tinggi gelombang total untuk mendapatkan nilai dari fungsi densitas peluang $f(x)$. Setelah memperoleh $f(x)$, maka nilai fungsi kumulatif $F(x)$ dapat diperoleh. Informasi statistik dapat diperoleh melalui $f(x)$. Sebagai contoh, peluang dari tinggi gelombang \tilde{H}_w yang melebihi batas (*threshold*) suatu nilai a , diberikan oleh,

$$P\{\tilde{H}_w > a\} = \int_a^{\infty} f(x)dx \quad (2.74)$$

Sementara rata-rata tinggi gelombang, \bar{H} , dapat dengan mudah dihitung menggunakan rumus rata-rata aritmetika biasa.

Selanjutnya, tinggi gelombang signifikan atau *significant wave height*, $H_{1/3}$, didefinisikan sebagai rata-rata dari 1/3 gelombang tertinggi. Tinggi gelombang signifikan mempunyai peran penting dalam analisis statistik gelombang irreguler. Analisis gerak kapal dalam gelombang irreguler memerlukan data gerak kapal dengan lama 15, 20, atau 30 menit. Misalkan diberikan fungsi panjang gelombang pada waktu ke- t , $\zeta(t)$, maka standar deviasi dari tinggi gelombang $\zeta(t)$ diberikan sebagai berikut.

$$S = \sqrt{\frac{1}{N-1} \sum_{t=1}^N (\zeta(t) - \bar{\zeta})^2} \quad (2.75)$$

Standar deviasi tinggi gelombang S juga berhubungan dengan periode gelombang signifikan $\zeta_{a_{1/3}}$ dan panjang gelombang signifikan $H_{1/3}$. Hubungan tersebut dijelaskan dalam persamaan berikut (Journée & Massie, 2001).

$$\zeta_{a_{1/3}} = 2 S \quad (2.76)$$

$$H_{1/3} = 4 S \quad (2.77)$$

Halaman ini sengaja dikosongkan

BAB III METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data eksperimen simulasi gerak rolling, swaying, dan yawing sebuah FPU. Dalam 1 detik, mesin merekam 15 data. Data ini merupakan data sekunder yang diperoleh dari Badan Pengkajian dan Penelitian Teknologi (BPPT).

3.2 Variabel Penelitian

Terdapat 3 (tiga) variabel yang digunakan dalam penelitian ini. Variabel-variabel tersebut adalah sebagai berikut.

1. $Y_{1,t}$ = gerak *rolling* (derajat).
2. $Y_{2,t}$ = gerak *swaying* (m).
3. $Y_{3,t}$ = gerak *yawing* (derajat).

Struktur data dalam penelitian ini ditampilkan dalam tabel berikut.

Tabel 3.1 Struktur Data Penelitian

Waktu (centisecond)	Variabel		
	<i>Rolling</i> (derajat)	<i>Swaying</i> (meter)	<i>Yawing</i> (derajat)
1	$Y_{1,1}$	$Y_{2,1}$	$Y_{3,1}$
2	$Y_{1,2}$	$Y_{2,2}$	$Y_{3,2}$
⋮	⋮	⋮	⋮
n	$Y_{1,n}$	$Y_{2,n}$	$Y_{3,n}$

Ketiga variabel tersebut akan dimodelkan menggunakan model ARIMA, VAR, dan model *Hybrid* VAR-ANN. Data yang digunakan untuk pemodelan adalah data *in-sample* sebanyak 3000. Sementara data yang digunakan untuk peramalan adalah data *out-of-sample* sebanyak 1000.

3.3 Langkah Analisis

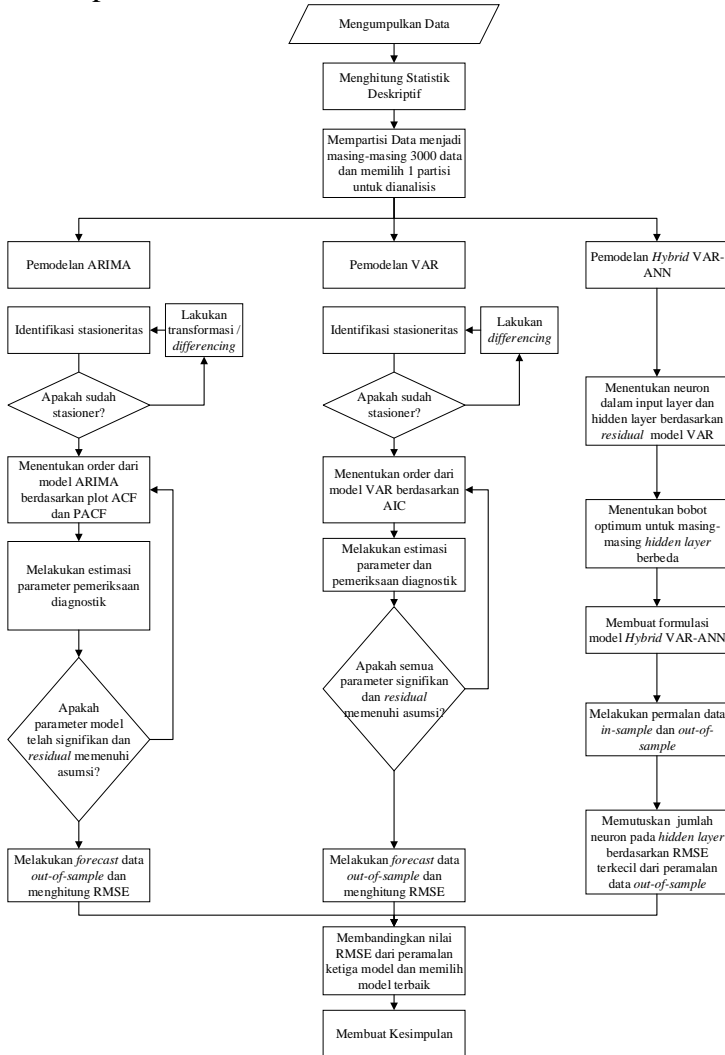
Berikut ini adalah langkah-langkah analisis yang dilakukan untuk mencapai tujuan dari penelitian.

1. Menghitung statistik deskriptif rata-rata, standar deviasi, nilai maksimum, dan nilai minimum dari masing-masing variabel.
2. Mempartisi data menjadi masing-masing 3000 data dan memilih satu partisi untuk dianalisis sebagai data *in-sample*. Sementara 1000 data pada partisi selanjutnya dijadikan data *out-of-sample*.
3. Pemodelan ARIMA dengan langkah-langkah sebagai berikut.
 - i. Mengidentifikasi stasioneritas masing-masing variabel, baik stasioner dalam mean maupun stasioner dalam varians menggunakan plot time series, transformasi Box-Cox, plot ACF, dan uji unit root.
 - ii. Menentukan *order* dari *time series* menggunakan plot ACF dan PACF dari proses yang sudah stasioner.
 - iii. Estimasi dan uji signifikansi parameter model ARIMA.
 - iv. Forecasting data *in-sample* menggunakan model ARIMA.
 - v. Menghitung nilai residual.
 - vi. Melakukan pemeriksaan diagnostik (uji asumsi *residual* bersifat *white noise* dan berdistribusi normal).
 - vii. Forecasting data *out-of-sample* menggunakan model ARIMA yang telah sesuai.
 - viii. Menghitung nilai RMSE data *out-of-sample*.
4. Pemodelan VAR (*Vector Autoregressive*) dengan langkah-langkah sebagai berikut.
 - ix. Mengecek stasioneritas menggunakan *sample correlation matrix function*.
 - x. Menentukan *order* dari model VAR menggunakan *lag length selection criteria* yaitu AIC.
 - xi. Estimasi parameter dan uji signifikansi parameter model VAR.
 - xii. *Forecasting* data *in-sample* menggunakan model VAR.
 - xiii. Menghitung nilai residual.

- xiv. Pemeriksaan diagnostik (uji asumsi *residual* bersifat *white noise* dan berdistribusi multivariat normal).
 - xv. *Forecasting* data *out-of-sample* model VAR yang telah sesuai.
 - xvi. Menghitung nilai RMSE data *out-of-sample*.
5. Pemodelan Hybrid VAR-ANN dengan langkah-langkah sebagai berikut.
 - i. Uji linieritas.
 - ii. Menentukan *neuron* dan *input layer* dan *output layer* berdasarkan *residual* model VAR ke dalam model ANN (*Artificial Neural Network*).
 - iii. Menghitung bobot optimum untuk *hidden layer* yang berbeda.
 - iv. Membuat formulasi model ANN dari *residual*.
 - v. Membuat formulasi model *Hybrid* VAR-ANN dengan menggabungkan formula Model VAR(1) dengan model ANN dari *residual*.
 - vi. Peramalan data *out-of-sample* menggunakan model-model *Hybrid* VAR-ANN yang terbentuk.
 - vii. Memutuskan jumlah neuron pada *hidden layer* yang paling cocok berdasarkan nilai RMSE yang terkecil dari peramalan data *out-of-sample*.
 6. Membandingkan hasil *forecast* antara model ARIMA, VAR dan *Hybrid* VAR-ANN berdasarkan nilai RMSE hasil *forecast* data *out-of-sample*.
 7. Membuat kesimpulan.

3.4 Diagram Alir

Berikut adalah diagram alir dari langkah analisis dalam penelitian ini.



Gambar 3.1 Diagram Alir Analisis

BAB IV ANALISIS DAN PEMBAHASAN

Pada bab ini akan ditampilkan analisis dan pembahasan mengenai peramalan gerak *rolling*, *swaying*, dan *yawing* pada FPU. Metode peramalan yang digunakan adalah metode ARIMA, VAR, dan *Hybrid* VAR-ANN. Hasil peramalan ketiga metode tersebut selanjutnya dibandingkan untuk mendapatkan metode peramalan terbaik berdasarkan kriteria *out-of-sample*.

4.1 Karakteristik Gerak *Rolling*, *Swaying*, dan *Yawing*

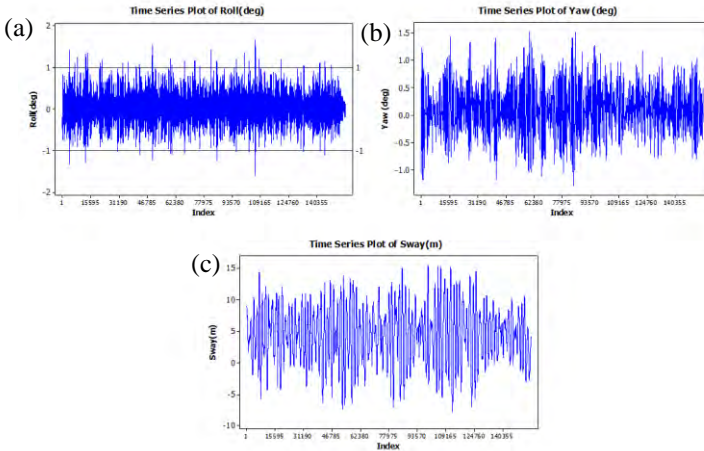
Penelitian ini menggunakan data gerak *rolling*, *swaying*, dan *yawing* pada FPU hasil eksperimen simulasi di laboratorium dengan jumlah observasi sebanyak 155946, di mana setiap detik dihasilkan 15 data. Karakteristik *rolling*, *swaying*, dan *yawing* dapat dilihat berdasarkan statistik deskriptif rata-rata, standar deviasi, maksimum, dan minimum berikut.

Tabel 4.1 Statistika Deskriptif Gerak *Rolling*, *Swaying*, dan *Yawing*

Variabel	Rata-rata	Std Deviasi	Minimum	Maksimum
<i>Rolling</i> (deg)	0,0464	0,3534	-1,6024	1,6699
<i>Swaying</i> (m)	4,5347	4,5731	-7,8672	15,6250
<i>Yawing</i> (deg)	0,1109	0,4306	-1,2887	1,5295

Berdasarkan Tabel 4.1, dapat dilihat bahwa gerak *rolling*, *swaying*, dan *yawing* memiliki nilai standar deviasi yang relatif kecil, sehingga keragaman ketiga data tersebut juga kecil. Namun, nilai minimum dan maksimum gerak *rolling* melebihi gerak yang aman, karena kapal dikatakan stabil jika tidak terdapat gerak *rolling* yang melebihi 1 derajat atau kurang dari -1 derajat. Gerak ini juga dapat dikatakan sebagai gerak ekstrim. Jika terjadi kondisi seperti tersebut, mesin akan mati secara otomatis.

Selanjutnya, berikut adalah plot *time series* dari masing-masing gerak.



Gambar 4.1 Plot *Time Series* Data Gerak (a) *Rolling*, (b) *Swaying*, dan (c) *Yawing*

Berdasarkan Gambar 4.1 (a), dapat dilihat bahwa terdapat beberapa pengamatan pada gerak *rolling* yang nilainya melebihi 1 derajat atau kurang dari -1 derajat. Dari 155946 observasi, didapatkan 1258 gerak ekstrim. Artinya, dalam waktu 3 jam, terjadi gerak ekstrim pada FPU sebanyak 0,8%. Sementara itu, jika terdapat gerak yang berada di luar 1,5 derajat atau -1,5 derajat, maka gerak tersebut tergolong gerak sangat ekstrim. Dari eksperimen ini, ditemukan sebanyak 81 gerak sangat ekstrim. Artinya, dalam waktu 3 jam, terjadi gerak sangat ekstrim pada FPU sebanyak 0,05%. Selain itu, dapat dilihat bahwa ketiga plot tersebut terlihat cukup rapat. Hal ini disebabkan oleh jumlah observasi yang besar. Akibatnya, pemodelan data besar menjadi sangat sulit karena sulit untuk melihat pola dan struktur data tersebut. Maka, data ini selanjutnya dipartisi menjadi 52 bagian, sehingga tiap bagian terdapat 3000 data. Dari 52 bagian tersebut, dipilih 1 bagian yang selanjutnya akan dianalisis menggunakan metode ARIMA, VAR, dan *Hybrid VAR-ANN*. Data dipilih

berdasarkan nilai tinggi gelombang h signifikan. Tinggi gelombang h signifikan yang digunakan dalam eksperimen ini adalah 2,4 meter. Berdasarkan perhitungan tinggi gelombang h signifikan pada masing-masing data hasil partisi, didapatkan hasil bahwa data partisi ke-50 memiliki nilai tinggi gelombang h signifikan sebesar 2,4 meter. Oleh karena itu, data partisi ke-50 digunakan untuk memodelkan dan meramalkan gerak *rolling*, *swaying*, dan *yawing*.

Untuk memperkuat analisis ini, akan ditunjukkan bahwa 52 data partisi tersebut memiliki pola dan struktur yang sama. Berdasarkan plot *time series* data gerak *rolling*, *swaying*, dan *yawing* hasil partisi, dapat dilihat bahwa pola datanya cenderung sama. Struktur ACF dan PACF dari semua data partisi juga cenderung sama. Oleh karena itu, penelitian ini dapat memakai salah satu data hasil partisi saja yang digunakan untuk memodelkan gerak *rolling*, *swaying* dan *yawing*. Maka, peramalan gerak *rolling*, *swaying*, dan *yawing* dapat menggunakan salah satu data hasil partisi. Plot *time series*, plot ACF, dan plot PACF data gerak *rolling*, *swaying*, dan *yawing* secara lengkap dapat dilihat pada lampiran.

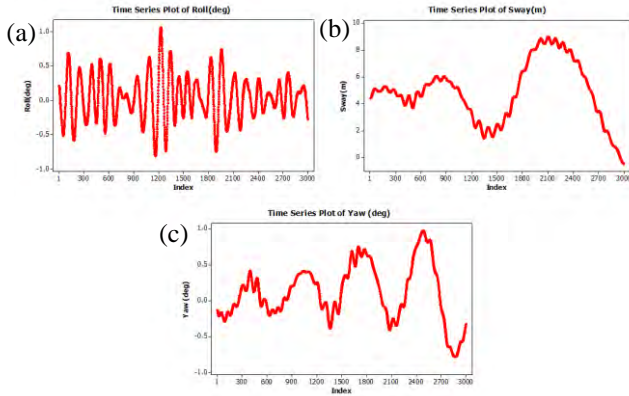
4.2 Pemodelan Gerak *Rolling*, *Swaying*, dan *Yawing* dengan Model ARIMA

Dalam pemodelan ARIMA, dilakukan analisis untuk masing-masing gerak sehingga didapatkan model ARIMA masing-masing gerak. Langkah-langkah pemodelan didasarkan pada prosedur Box-Jenkins.

4.2.1 Identifikasi Model ARIMA

Tahap awal dalam prosedur Box-Jenkins adalah mengidentifikasi model ARIMA. Identifikasi meliputi pengujian stasioneritas dan penentuan order lag dari AR dan MA. Untuk menguji stasioneritas data, dapat dilihat dari plot *time series* dan plot ACF. Selain itu, uji stasioneritas juga dapat menggunakan uji *unit root*. Uji *unit root* yang digunakan ada *Augmented Dickey-*

Fuller (ADF) Test. Berikut adalah plot *time series* dari gerak *rolling*, *swaying*, dan *yawing*.



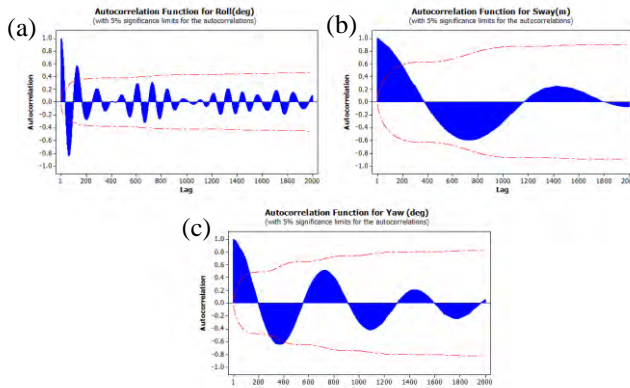
Gambar 4.2 Plot *Time Series* Gerak (a) *Rolling*, (b) *Swaying*, dan (c) *Yawing*

Berdasarkan plot *time series* gerak *rolling*, *swaying*, dan *yawing* pada Gambar 4.2, dapat dilihat bahwa data tidak stasioner dalam *mean*. Ketiga plot tersebut juga memiliki pola perulangan. Tetapi, periode perulangannya tidak teratur. Oleh karena itu, ketiga data tersebut tidak memiliki efek musiman (*seasonal*). Untuk memeriksa stasioneritas dalam varians, digunakan transformasi Box-Cox. Berikut adalah hasil pemeriksaan stasioneritas dalam varians.

Tabel 4.2 Hasil Pemeriksaan Stasioneritas dalam Varians

Gerak	Transformasi	Kesimpulan
<i>Rolling</i>	$Y_{1,t}$ (tidak ditransformasi)	Data stasioner dalam varians
<i>Swaying</i>	$Y_{2,t}$ (tidak ditransformasi)	Data stasioner dalam varians
<i>Yawing</i>	$Y_{3,t}$ (tidak ditransformasi)	Data stasioner dalam varians

Berdasarkan Tabel 4.2, didapatkan hasil bahwa semua data telah stasioner dalam varians, sehingga data tidak perlu ditransformasi. Selanjutnya, stasioneritas data dalam *mean* dilihat berdasarkan struktur ACF. Plot ACF gerak *rolling*, *swaying*, dan *yawing* diberikan oleh Gambar 4.3 berikut.




Gambar 4.3 Plot *Time Series* Gerak (a) *Rolling*, (b) *Swaying*, dan (c) *Yawing*

Berdasarkan plot ACF gerak *rolling*, *swaying*, dan *yawing* pada Gambar 4.3, dapat dilihat bahwa data plot ACF tidak *dies down* atau *tailed off* dan masih banyak lag yang keluar dari batas signifikansi. Hal ini mengindikasikan bahwa ketiga data tersebut tidak stasioner dalam mean. Untuk memperkuat analisis, selanjutnya dilakukan pengujian *unit root* menggunakan ADF *test*. Berikut adalah hasil pengujian menggunakan ADF *test*.

Tabel 4.3 Hasil Pengujian ADF *Test*

Gerak	Dickey-Fuller	Lag	P-value	Kesimpulan
<i>Rolling</i>	-9,1376	30	0,0100	Data stasioner
<i>Swaying</i>	-1,1333	30	0,9172	Data tidak stasioner
<i>Yawing</i>	-3,2930	30	0,0719	Data tidak stasioner

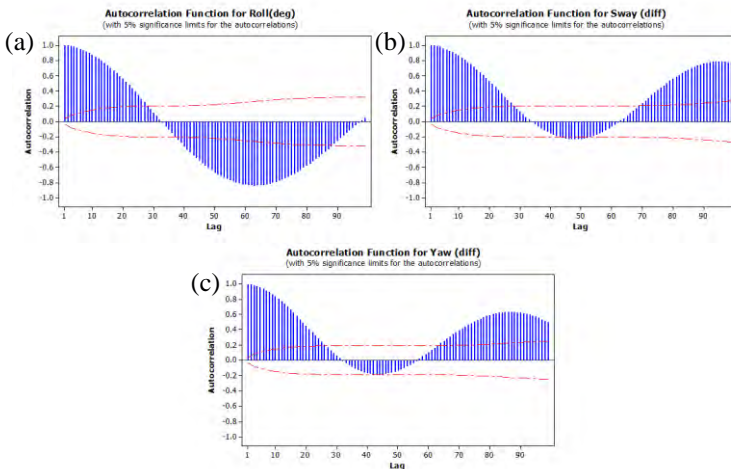
Tabel 4.3 menunjukkan hasil bahwa ternyata data gerak *rolling* stasioner. Sementara gerak *swaying* dan *yawing* tidak stasioner. Dari hasil analisis plot time series, plot ACF, dan ADF *test*, disimpulkan bahwa gerak *rolling* stasioner. Namun, gerak *swaying* dan *yawing* tidak stasioner. Oleh karena itu, dilakukan *differencing* pada gerak *swaying* dan *yawing* pada lag 1. Berikut adalah plot time series data hasil *differencing* gerak *swaying* dan *yawing*.



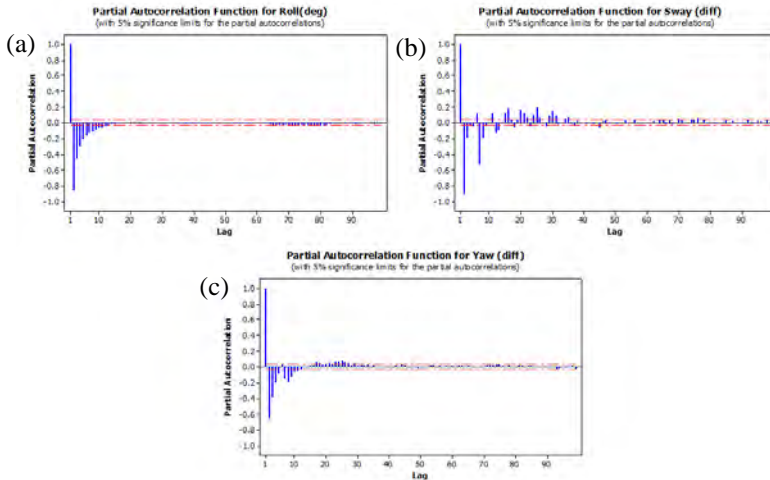
Gambar 4.4 Plot *Time Series* Data Gerak *Swaying* dan *Yawing* Hasil *Differencing* (a) *Swaying* dan (b) *Yawing*

Berdasarkan plot *time series* data gerak *swaying* dan *yawing* hasil *differencing*, dapat dilihat bahwa data memiliki rata-rata yang konstan. Maka, dapat diasumsikan bahwa data sudah stasioner.

Langkah selanjutnya adalah menentukan order lag AR dan MA dari plot ACF dan PACF data yang sudah stasioner. Berikut adalah plot ACF dan PACF gerak *rolling*, *swaying*, dan *yawing* yang sudah stasioner.



Gambar 4.5 Plot ACF Data Gerak *Rolling*, *Swaying* dan *Yawing* (a) *Rolling*, (b) *Swaying*, dan (c) *Yawing*



Gambar 4.6 Plot PACF Data Gerak *Rolling*, *Swaying* dan *Yawing*
(a) *Rolling*, (b) *Swaying*, dan (c) *Yawing*

Berdasarkan plot ACF dan PACF dari ketiga gerak, cukup sulit untuk menentukan order lag AR dan MA. Oleh karena itu, dilakukan metode *backward* dan *trial and error* untuk mendapatkan model ARIMA yang sesuai. Berdasarkan hasil *backward* serta *trial and error*, didapatkan model final masing-masing gerak sebagai berikut.

Tabel 4.4 Model ARIMA untuk Gerak *Rolling*, *Swaying*, dan *Yawing*

Variabel	Model
<i>Rolling</i>	ARIMA([1,2,3,4,9,19,20],0,[19])
<i>Swaying</i>	ARIMA([1,2,4,5,6,8,9,10,11,12,13,14,15,16,17,18,19,21,22,23,24,26,27,28,29,31,34,35],1, [2,35,43])
<i>Yawing</i>	ARIMA([1,3,4,5,6,7,8,17,18,22,29],1,[7,16])

4.2.2 Estimasi dan Pengujian Signifikansi Parameter

Parameter model ARIMA diestimasi menggunakan metode *Conditional Least Square* (CLS) dan pengujian signifikansi

parameter menggunakan uji t. Berikut adalah estimasi dan pengujian signifikansi parameter model ARIMA dari gerak *rolling*, *swaying*, dan *yawing*.

Tabel 4.5 Estimasi dan Pengujian Signifikansi Parameter Model ARIMA Gerak *Rolling*

Parameter	Estimate	Std Error	t	$t_{0,025;2992}$	P-value
θ_{19}	-0,09983	0.0253500	-3.94	1,96076	< 0,0001
ϕ_1	130,286	0.0181800	71.66	1,96076	< 0,0001
ϕ_2	-0,08383	0.0298700	-2.81	1,96076	0,0050
ϕ_3	-0,07943	0.0299100	-2.66	1,96076	0,0080
ϕ_4	-0,08749	0.0218600	-4.00	1,96076	< 0,0001
ϕ_9	-0,0464	0.0081169	-5.72	1,96076	< 0,0001
ϕ_{19}	-0,12946	0.0267100	-4.85	1,96076	< 0,0001
ϕ_{20}	0,11744	0.0239400	4.91	1,96076	< 0,0001

Berdasarkan hasil estimasi pengujian signifikansi model ARIMA gerak *rolling*, didapatkan hasil bahwa semua parameter signifikan, karena statistik uji $|t|$ yang lebih besar dari nilai $t_{0,025;2992}$ atau p -value yang kurang dari taraf signifikansi $\alpha = 0,05$.

Tabel 4.6 Estimasi dan Pengujian Signifikansi Parameter Model ARIMA Gerak *Swaying*

Parameter	Estimate	Std Error	t	$t_{0,025;2968}$	P-value
θ_2	-0,13568	0,02222	-6,11	1,96076	< 0,0001
θ_{35}	0,09684	0,02489	3,89	1,96076	0,0001
θ_{43}	0,05076	0,01925	2,64	1,96076	0,0084
ϕ_1	1,56442	0,01612	97,05	1,96076	< 0,0001
ϕ_2	-0,41761	0,02213	-18,87	1,96076	< 0,0001
ϕ_4	-0,18064	0,03011	-6,00	1,96076	< 0,0001
ϕ_5	-0,75870	0,03475	-21,83	1,96076	< 0,0001
ϕ_6	1,16415	0,02843	40,95	1,96076	< 0,0001
ϕ_8	-0,15375	0,02958	-5,20	1,96076	< 0,0001
ϕ_9	-0,29479	0,04327	-6,81	1,96076	< 0,0001
ϕ_{10}	-0,38931	0,04127	-9,43	1,96076	< 0,0001
ϕ_{11}	0,55579	0,04006	13,87	1,96076	< 0,0001

Tabel 4.6 (Lanjutan) Estimasi dan Pengujian Signifikansi Parameter Model ARIMA Gerak *Swaying*

Parameter	Estimate	Std Error	t	$t_{0,025;2968}$	P-value
ϕ_{12}	0,33710	0,03481	9,69	1,96076	< 0,0001
ϕ_{13}	-0,19661	0,04182	-4,70	1,96076	< 0,0001
ϕ_{14}	-0,40119	0,04294	-9,34	1,96076	< 0,0001
ϕ_{15}	-0,15930	0,03435	-4,64	1,96076	< 0,0001
ϕ_{16}	0,30672	0,04111	7,46	1,96076	< 0,0001
ϕ_{17}	0,44328	0,04210	10,53	1,96076	< 0,0001
ϕ_{18}	-0,24250	0,04394	-5,52	1,96076	< 0,0001
ϕ_{19}	-0,43210	0,03630	-11,91	1,96076	< 0,0001
ϕ_{21}	0,22443	0,03732	6,01	1,96076	< 0,0001
ϕ_{22}	0,40255	0,04189	9,61	1,96076	< 0,0001
ϕ_{23}	-0,27701	0,04274	-6,48	1,96076	< 0,0001
ϕ_{24}	-0,34549	0,03614	-9,56	1,96076	< 0,0001
ϕ_{26}	0,27940	0,03375	8,28	1,96076	< 0,0001
ϕ_{27}	0,18608	0,03422	5,44	1,96076	< 0,0001
ϕ_{28}	-0,14362	0,03486	-4,12	1,96076	< 0,0001
ϕ_{29}	-0,26330	0,03384	-7,78	1,96076	< 0,0001
ϕ_{31}	0,24454	0,02605	9,39	1,96076	< 0,0001
ϕ_{34}	-0,17457	0,02510	-6,96	1,96076	< 0,0001
ϕ_{35}	0,12080	0,01712	7,06	1,96076	< 0,0001

Berdasarkan hasil estimasi pengujian signifikansi model ARIMA gerak *swaying*, didapatkan hasil bahwa semua parameter signifikan, karena statistik uji $|t|$ yang lebih besar dari nilai $t_{0,025;2968}$ atau p -value yang kurang dari taraf signifikansi $\alpha = 0,05$.

Tabel 4.7 Estimasi dan Pengujian Signifikansi Parameter Model ARIMA Gerak *Yawing*

Parameter	Estimate	Std Error	t	$t_{0,025;2986}$	P-value
θ_7	0,15606	0,04747	3,29	1,96076	0,0010
θ_{16}	0,06856	0,01959	3,50	1,96076	0,0005
ϕ_1	1,23515	0,01143	108,07	1,96076	< 0,0001
ϕ_3	-0,10414	0,02437	-4,27	1,96076	< 0,0001
ϕ_4	-0,12952	0,02775	-4,67	1,96076	< 0,0001

Tabel 4.7 (Lanjutan) Estimasi dan Pengujian Signifikansi Parameter Model ARIMA Gerak *Yawing*

Parameter	Estimate	Std Error	t	$t_{0,025;2986}$	P-value
ϕ_4	-0,12952	0,02775	-4,67	1,96076	< 0,0001
ϕ_5	-0,19466	0,02779	-7,00	1,96076	< 0,0001
ϕ_6	0,23869	0,02845	8,39	1,96076	< 0,0001
ϕ_7	0,24318	0,05249	4,63	1,96076	< 0,0001
ϕ_8	-0,26394	0,04814	-5,48	1,96076	< 0,0001
ϕ_{17}	-0,07863	0,01950	-4,03	1,96076	< 0,0001
ϕ_{18}	0,04584	0,02116	2,17	1,96076	0,0303
ϕ_{22}	-0,03334	0,00965	-3,46	1,96076	0,0006
ϕ_{29}	0,03762	0,00419	8,98	1,96076	< 0,0001

Berdasarkan hasil estimasi pengujian signifikansi model ARIMA gerak *yawing*, didapatkan hasil bahwa semua parameter signifikan, karena statistik uji $|t|$ yang lebih besar dari nilai $t_{0,025;2986}$ atau p -value yang kurang dari taraf signifikansi $\alpha = 0,05$.

4.2.3 Pemeriksaan Diagnostik

Pemeriksaan diagnostik yang dilakukan adalah memeriksa apakah residual memenuhi asumsi *white noise* dan berdistribusi normal. Pengujian asumsi *white noise* digunakan statistik uji Ljung-Box. Berikut adalah hasil pengujian asumsi *white-noise*.

Tabel 4.8 Pengujian Ljung-Box Gerak *Rolling*

Sampai Lag	Chi-Square	Derajat Bebas (db)	$\chi^2_{0,05;db}$	P-value
12	7,79	4	9,48773	0,0994
18	9,53	10	18,30700	0,4823
24	10,35	16	26,29620	0,8478
30	13,43	22	33,92440	0,9205
36	15,03	28	41,33710	0,9781
42	15,64	34	48,60240	0,9970
48	17,03	40	55,75850	0,9995

Tabel 4.9 Pengujian Ljung-Box Gerak *Swaying*

Sampai Lag	Chi-Square	Derajat Bebas (db)	$\chi_{0,05;db}^2$	P-value
36	9,29	5	11,0705	0,0979
42	13,85	11	19,6751	0,2417
48	20,91	17	27,5871	0,2305

Tabel 4.10 Pengujian Ljung-Box Gerak *Yawing*

Sampai Lag	Chi-Square	Derajat Bebas (db)	$\chi_{0,05;db}^2$	P-value
18	7,43	5	11,0705	0,1907
24	10,42	11	19,6751	0,4933
30	12,18	17	27,5871	0,7890
36	17,97	23	35,1725	0,7593
42	19,72	29	42,5570	0,9015
48	22,03	35	49,8018	0,9569

Berdasarkan pengujian asumsi *white noise*, didapatkan hasil bahwa asumsi residual *white noise* terpenuhi karena statistik uji *chi-square* lebih besar dari nilai $\chi_{0,05;db}^2$ atau *p-value* yang lebih besar dari taraf signifikansi $\alpha = 0,05$.

Selanjutnya dilakukan pengujian normalitas dari residual. Pengujian normalitas menggunakan statistik uji Kolmogorov-Smirnov. Berikut adalah hasil pengujian normalitas masing-masing residual.

Tabel 4.11 Uji Normalitas Residual

Variabel	Statistik KS	P-value	Kesimpulan
<i>Rolling</i>	0,224834	< 0,0100	Residual tidak normal
<i>Swaying</i>	0,016586	0,0444	Residual tidak normal
<i>Yawing</i>	0,079411	< 0,0100	Residual tidak normal

Berdasarkan hasil pengujian normalitas residual, dapat dilihat bahwa residual model *rolling*, *swaying*, dan *yawing* tidak memenuhi asumsi distribusi normal. Residual yang tidak memenuhi asumsi distribusi normal dapat dilihat penyebabnya

melalui statistik *skewness* dan *kurtosis*. Berikut adalah statistik *skewness* dan *kurtosis* dari residual.

Tabel 4.12 Statistik *Skewness* dan *Kurtosis* dari *Residual* Model
ARIMA

Variabel	Skewness	Kurtosis
<i>Rolling</i>	27,45908790	1381,10078000
<i>Swaying</i>	0,15252827	0,41772602
<i>Yawing</i>	-12,82610300	458,64029200

Berdasarkan nilai statistik *skewness* dan *kurtosis*, dapat dilihat bahwa nilai *skewness* dan *kurtosis* dari residual model *rolling* dan *yawing* bernilai sangat besar. Inilah yang menyebabkan residual tidak memenuhi asumsi distribusi normal. Menurut Kostenko dan Hyndman (2008), uji signifikansi dan asumsi dapat diabaikan dalam kepentingan peramalan. Hal yang lebih penting adalah bagaimana kemampuan model dalam melakukan peramalan. Hal yang sama juga telah dijelaskan sebelumnya oleh Armstrong (2007).

Model ARIMA masing-masing gerak yang diperoleh dapat dituliskan dalam persamaan matematis berikut.

$$\begin{aligned} \hat{Y}_{1,t} = & 130,286Y_{1,t-1} - 0,08383Y_{1,t-2} - 0,07943Y_{1,t-3} - 0,08749Y_{1,t-4} - 0,0464Y_{1,t-9} \\ & - 0,12946Y_{1,t-19} + 0,11744Y_{1,t-20} + 0,09983a_{1,t-1} \\ \hat{Y}_{2,t} = & Y_{2,t-1} + 1,56442(Y_{2,t-1} - Y_{2,t-2}) - 0,41761(Y_{2,t-2} - Y_{2,t-3}) \\ & - 0,18064(Y_{2,t-4} - Y_{2,t-5}) - 0,7587(Y_{2,t-5} - Y_{2,t-6}) \\ & + 1,16415(Y_{2,t-6} - Y_{2,t-7}) - 0,15375(Y_{2,t-8} - Y_{2,t-9}) \\ & - 0,29479(Y_{2,t-9} - Y_{2,t-10}) - 0,38931(Y_{2,t-10} - Y_{2,t-11}) \\ & + 0,55579(Y_{2,t-11} - Y_{2,t-12}) + 0,3371(Y_{2,t-12} - Y_{2,t-13}) \\ & - 0,19661(Y_{2,t-13} - Y_{2,t-14}) - 0,40119(Y_{2,t-14} - Y_{2,t-15}) \\ & - 0,1593(Y_{2,t-15} - Y_{2,t-16}) + 0,30672(Y_{2,t-16} - Y_{2,t-17}) \\ & + 0,44328(Y_{2,t-17} - Y_{2,t-18}) - 0,2425(Y_{2,t-18} - Y_{2,t-19}) \\ & - 0,4321(Y_{2,t-19} - Y_{2,t-20}) + 0,22443(Y_{2,t-21} - Y_{2,t-22}) \\ & - 0,40255(Y_{2,t-22} - Y_{2,t-23}) - 0,27701(Y_{2,t-23} - Y_{2,t-24}) \\ & + 0,2794(Y_{2,t-26} - Y_{2,t-27}) + 0,18608(Y_{2,t-27} - Y_{2,t-28}) \\ & - 0,14362(Y_{2,t-28} - Y_{2,t-29}) - 0,2633(Y_{2,t-29} - Y_{2,t-30}) \\ & + 0,24454(Y_{2,t-31} - Y_{2,t-32}) - 0,17457(Y_{2,t-34} - Y_{2,t-35}) \\ & + 0,12080(Y_{2,t-35} - Y_{2,t-36}) + 0,13568a_{2,t-2} - 0,09684a_{2,t-35} \\ & - 0,05076a_{2,t-43} \end{aligned}$$

$$\begin{aligned}
\hat{Y}_{3,t} = & Y_{3,t-1} + 1,23515(Y_{2,t-1} - Y_{2,t-2}) - 0,12952(Y_{2,t-3} - Y_{2,t-4}) \\
& - 0,12952(Y_{2,t-4} - Y_{2,t-5}) - 0,12952(Y_{2,t-4} - Y_{2,t-5}) \\
& - 0,19466(Y_{2,t-5} - Y_{2,t-6}) + 0,23869(Y_{2,t-6} - Y_{2,t-7}) \\
& + 0,24318(Y_{2,t-7} - Y_{2,t-8}) - 0,26394(Y_{2,t-8} - Y_{2,t-9}) \\
& - 0,07863(Y_{2,t-17} - Y_{2,t-18}) + 0,04584(Y_{2,t-18} - Y_{2,t-19}) \\
& - 0,03334(Y_{2,t-22} - Y_{2,t-23}) + 0,03762(Y_{2,t-29} - Y_{2,t-30}) \\
& - 0,15606a_{2,t-7} - 0,06856a_{2,t-16}
\end{aligned}$$

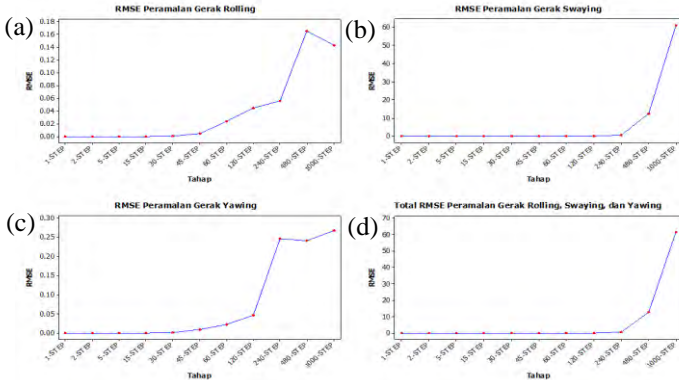
4.2.4 Peramalan Data *Out-of-Sample*

Setelah didapatkan model ARIMA yang sesuai, maka dilakukan peramalan beberapa tahap ke depan. Peramalan menggunakan metode *k-step forecast*. Model ARIMA digunakan untuk meramalkan data *out-of-sample*. Kemudian, dihitung residual masing-masing model dan didapatkan nilai RMSE. Setiap model dievaluasi berdasarkan RMSE. Berikut adalah nilai RMSE dari masing-masing model.

Tabel 4.13 Hasil Peramalan Data *Out-of-Sample* dengan Model ARIMA

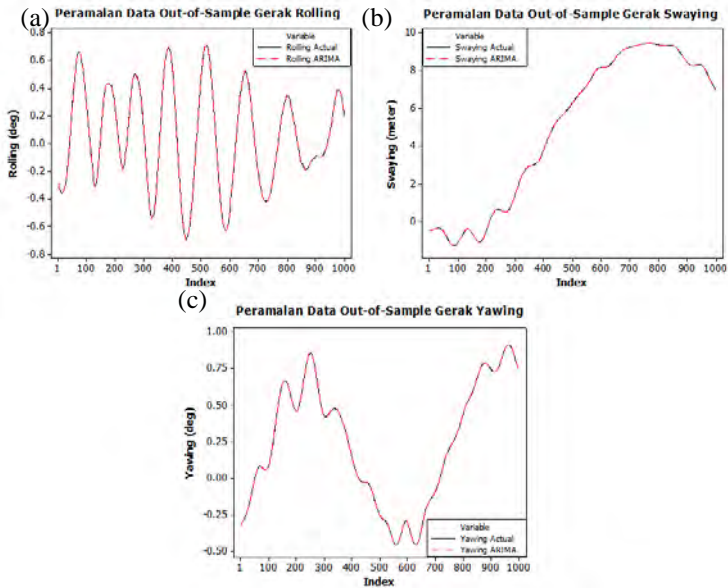
Tahap	RMSE			
	<i>Rolling</i>	<i>Swaying</i>	<i>Yawing</i>	Total
1	3,546 x 10 ⁻⁶	1,232 x 10 ⁻⁷	3,284 x 10 ⁻⁹	0,000003672
2	1,080 x 10 ⁻⁵	2,759 x 10 ⁻⁷	4,827 x 10 ⁻⁹	0,000010000
5	3,741 x 10 ⁻⁵	3,124 x 10 ⁻⁶	1,263 x 10 ⁻⁷	0,000040000
15	4,562 x 10 ⁻⁵	0,0002080	3,797 x 10 ⁻⁵	0,000291544
30	0,0002199	0,0019705	0,0014219	0,003612310
45	0,0047347	0,0037499	0,0087689	0,017253462
60	0,0238753	0,0034576	0,0226311	0,049964015
120	0,0443593	0,0356248	0,0463615	0,126345472
240	0,0553902	0,4649515	0,2469934	0,767335065
480	0,1646284	12,4233520	0,2418495	12,829829390
1000	0,1427497	61,0868400	0,2682941	61,497883520

Berdasarkan Tabel 4.13, didapatkan hasil bahwa nilai RMSE semakin meningkat seiring bertambahnya tahapan peramalan. Peningkatan tersebut dapat dilihat pada Gambar 4.7 berikut.



Gambar 4.7 RMSE Peramalan Gerak (a) *Rolling*, (b) *Swaying*, (c) *Yawing*, dan (d) Total

Berdasarkan Gambar 4.7, dapat dilihat bahwa RMSE meningkat seiring bertambahnya tahapan peramalan. Peningkatan yang paling signifikan secara total ketika peramalan dilakukan sampai 480 tahap. Karena peramalan 1 tahap memiliki RMSE terkecil, maka peramalan model ARIMA selanjutnya menggunakan metode *1-step forecast*. Berikut adalah hasil peramalan data *out-of-sample* menggunakan metode *1-step forecast*.




Gambar 4.8 Hasil Peramalan Data *Out-of-Sample* Gerak
(a) *Rolling*, (b) *Swaying*, dan (c) *Yawing*

4.3 Pemodelan Gerak *Rolling*, *Swaying*, dan *Yawing* dengan Model VAR

Dalam pemodelan VAR, dilakukan analisis gerak *rolling*, *swaying*, dan *yawing* dari secara multivariat.

4.3.1 Identifikasi Model VAR

Langkah awal dalam pemodelan VAR adalah melakukan identifikasi stasioneritas terhadap data gerak *rolling*, *swaying*, dan *yawing*. Identifikasi stasioneritas terhadap data terhadap data gerak *rolling*, *swaying*, dan *yawing* dilihat dari plot *sample correlation matrix function*. Berikut adalah plot *sample correlation matrix function* dari terhadap data gerak *rolling*, *swaying*, dan *yawing*.



Gambar 4.9 *Sample Correlation Matrix Function*

Berdasarkan plot *sample correlation matrix function*, didapatkan hasil bahwa nilai *cross correlation* dari data gerak *rolling*, *swaying*, dan *yawing* masih banyak yang berada di luar batas signifikansi. Akibatnya, data gerak *rolling*, *swaying*, dan *yawing* dapat dikatakan tidak stasioner.

Pada data gerak *rolling*, *swaying*, dan *yawing*, didapatkan bahwa matriks varians-kovarians tidak definit positif atau *full rank*, kecuali pada model VAR(1). Maka, pada penelitian ini model yang digunakan untuk meramalkan gerak *rolling*, *swaying*, dan *yawing* adalah model VAR(1).

4.3.2 Estimasi dan Pengujian Signifikansi Parameter

Parameter model ARIMA diestimasi menggunakan metode *Least Square* (LS) dan pengujian signifikansi parameter menggunakan uji t. Berikut adalah estimasi dan pengujian signifikansi parameter model VAR(1) dari gerak *rolling*, *swaying*, dan *yawing*.

Tabel 4.14 Estimasi dan Pengujian Signifikansi Parameter Model VAR (1)

Parameter	Estimate	Std Error	T ratio	P-value
ϕ_{111}	0,9988300	0,00090010	999,00	0,0001
ϕ_{112}	-0,0000520	0,00005918	-0,88	0,3791
ϕ_{113}	0,0026900	0,00077600	3,47	0,0005
ϕ_{121}	-0,0066500	0,00085680	-7,76	0,0001
ϕ_{122}	0,9999300	0,00005633	999,00	0,0001
ϕ_{123}	-0,0005044	0,00073860	-0,68	0,4947
ϕ_{131}	-0,0034400	0,00026750	-12,86	0,0001
ϕ_{132}	0,0000291	0,00001759	1,66	0,0974
ϕ_{133}	0,9999200	0,00023060	999,00	0,0001

Berdasarkan hasil estimasi pengujian signifikansi model VAR(1) gerak *rolling*, *swaying*, dan *yawing*, didapatkan hasil bahwa ada parameter yang tidak signifikan karena *p-value* yang lebih besar dari taraf signifikansi $\alpha = 0,05$. Parameter yang tidak signifikan adalah ϕ_{112} , ϕ_{123} , dan ϕ_{132} .

4.3.3 Pemeriksaan Diagnostik

Pemeriksaan diagnostik yang dilakukan adalah memeriksa apakah residual memenuhi asumsi *white noise* dan berdistribusi multivariat normal. Pengujian asumsi *white noise* digunakan *Portmanteau Test*. Berikut adalah hasil pengujian asumsi *white noise*.

Tabel 4.15 Pengujian Portmanteau

Sampai Lag	Chi-Square	Derajat Bebas (db)	P-value
2	9999,99	9	< 0,0001
3	9999,99	18	< 0,0001
5	9999,99	36	< 0,0001
6	9999,99	45	< 0,0001
11	9999,99	90	< 0,0001
13	9999,99	108	< 0,0001

Berdasarkan pengujian asumsi *white noise*, didapatkan hasil bahwa asumsi residual *white noise* tidak terpenuhi karena *p-value* yang kurang dari taraf signifikansi $\alpha = 0,05$. Selanjutnya dilakukan pengujian normalitas menggunakan uji Shapiro-Wilk multivariat. Berikut adalah hasil pengujian normalitas multivariat vektor residual.

Tabel 4.16 Pengujian Normalitas Multivariat *Residual*

W	P-value
0,9939	0,0000

Berdasarkan hasil pengujian normalitas multivariat pada vektor residual model VAR (1), didapatkan nilai *p-value* sebesar 0,000. Dengan menggunakan taraf signifikansi $\alpha = 0,05$, maka disimpulkan bahwa vektor residual model VAR(1) tidak memenuhi asumsi distribusi multivariat normal.

Model VAR(1) yang diperoleh dapat dituliskan dalam persamaan matematis berikut.

$$\begin{bmatrix} \hat{Y}_{1,t} \\ \hat{Y}_{2,t} \\ \hat{Y}_{3,t} \end{bmatrix} = \begin{bmatrix} 0,9988300 & -0,0000520 & 0,0026900 \\ -0,0066500 & 0,9999300 & -0,0005044 \\ -0,0034400 & 0,0000291 & 0,9999200 \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix}$$

Persamaan model VAR(1) dapat juga dituliskan seperti berikut.

$$\hat{Y}_{1,t} = 0,99883Y_{1,t-1} - 0,000052Y_{2,t-1} + 0,00269Y_{3,t-1}$$

$$\hat{Y}_{2,t} = -0,00665Y_{1,t-1} + 0,99993Y_{2,t-1} - 0,0005044Y_{3,t-1}$$

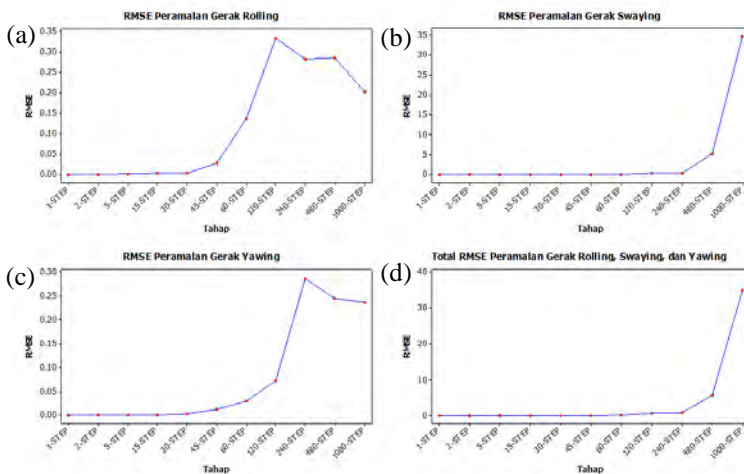
$$\hat{Y}_{3,t} = -0,00344Y_{1,t-1} + 0,0000291Y_{2,t-1} + 0,99992Y_{3,t-1}$$

4.3.4 Peramalan Data *Out-of-Sample*

Peramalan model VAR(1) menggunakan metode *k-step forecast*. Model VAR(1) digunakan untuk meramalkan data *out-of-sample*. Kemudian, dihitung nilai vektor residual sehingga didapatkan nilai RMSE masing-masing variabel. Setiap peramalan dievaluasi berdasarkan RMSE. Berikut adalah nilai RMSE dari masing-masing variabel.

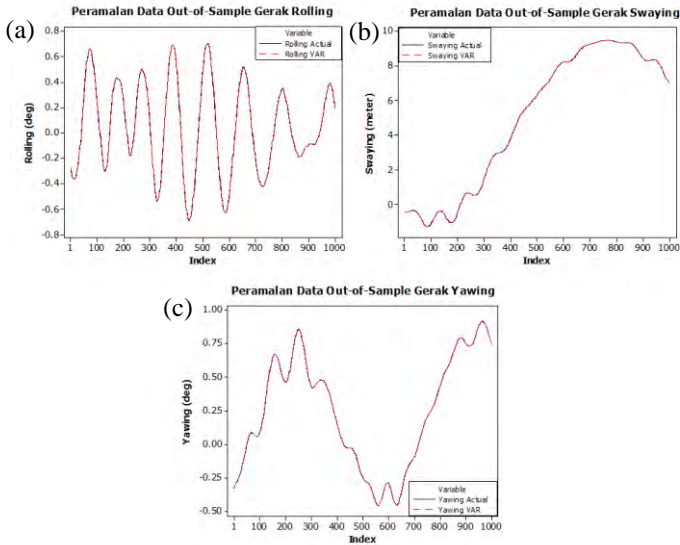
Tabel 4.17 RMSE Peramalan Model VAR (1)

Tahap	RMSE			
	<i>Rolling</i>	<i>Swaying</i>	<i>Yawing</i>	Total
1	0,000146	$1,05 \times 10^{-5}$	$1,32 \times 10^{-5}$	0,000169
2	0,000357	$2,38 \times 10^{-5}$	$3,09 \times 10^{-5}$	0,000411
5	0,001289	$5,94 \times 10^{-5}$	0,000119	0,001468
15	0,003949	$5,59 \times 10^{-5}$	0,000703	0,004708
30	0,002999	0,000739	0,003428	0,007166
45	0,028531	0,000926	0,012288	0,041746
60	0,136725	0,018972	0,029653	0,185350
120	0,333186	0,322247	0,072297	0,727730
240	0,282559	0,338386	0,286169	0,907114
480	0,285497	5,231561	0,244030	5,761088
1000	0,202950	34,642910	0,236448	35,082310



Gambar 4.10 RMSE Peramalan Gerak (a) *Rolling*, (b) *Swaying*, (c) *Yawing*, dan (d) Total

Berdasarkan Gambar 4.10, dapat dilihat bahwa RMSE meningkat seiring bertambahnya tahapan peramalan. Karena peramalan 1 tahap memiliki RMSE terkecil, maka metode peramalan *1-step forecast* digunakan untuk meramalkan data *out-of-sample*. Berikut adalah hasil peramalan data *out-of-sample* menggunakan metode *1-step forecast*.



Gambar 4.11 Hasil Peramalan Data *Out-of-Sample* Gerak (a) *Rolling*, (b) *Swaying*, dan (c) *Yawing*

4.4 Pemodelan Gerak *Rolling*, *Swaying*, dan *Yawing* dengan Model *Hybrid VAR-ANN*

Model *Hybrid VAR-ANN* digunakan untuk memodelkan dan memprediksi gerak *rolling*, *swaying*, dan *yawing*. Dalam model *Hybrid VAR-ANN*, hasil peramalan dari model VAR dijadikan komponen linier. Sementara *residual* dari model VAR dimodelkan menggunakan ANN. Maka, residual dari ketiga gerak tersebut pada waktu ke t dijadikan variabel *output*. Sementara variabel *input* yang digunakan adalah residual ketiga gerak

tersebut pada waktu ke $t-1$. Pemodelan dilakukan dengan menggunakan beberapa unit *neuron* dalam satu *hidden layer*.

4.4.1 Uji Linieritas

Uji linieritas dilakukan dengan menggunakan Uji Teräsvirta. Implementasi pengujian ini menggunakan statistik uji *Chi-Square*. Berikut adalah hasil pengujian masing-masing variabel.


Tabel 4.18 Pengujian Linieritas

Variabel	Statistik <i>Chi-Square</i>	db	$\chi^2_{0,05;16}$	<i>P-value</i>	Kesimpulan
<i>Rolling</i>	55.8579	16	26,2962	0,000	Nonlinier
<i>Swaying</i>	396.2003	16	26,2962	0,000	Nonlinier
<i>Yawing</i>	623.2178	16	26,2962	0,000	Nonlinier

Berdasarkan hasil pengujian linieritas pada masing-masing variabel, dapat disimpulkan bahwa semua variabel memiliki pola yang nonlinier dengan taraf signifikansi $\alpha = 5\%$. Maka, kesimpulan dalam analisis ini memberikan alasan yang kuat untuk melakukan pemodelan menggunakan metode *Hybrid VAR-ANN*. komponen nonlinier pada data ditangkap menggunakan metode ANN, di mana residual model VAR dimodelkan dan diprediksi menggunakan ANN.

4.4.2 Model *Hybrid VAR-ANN*

Dalam pemodelan ini, dibentuk 10 macam arsitektur. Di dalam *output layer*, digunakan 3 *neuron*, yaitu residual dari gerak *rolling*, *swaying*, dan *yawing* pada waktu ke- t $e_{1,t}$, $e_{2,t}$, dan $e_{3,t}$. Sementara pada *hidden layer*, digunakan *neuron* sebanyak 1 sampai 10. Selanjutnya *neuron* yang digunakan pada *input layer* adalah $e_{1,t-1}$, $e_{2,t-1}$, dan $e_{3,t-1}$. Berikut adalah bentuk arsitektur model ANN dengan jumlah *neuron* dalam *hidden layer* sebanyak 1 unit.



Gambar 4.12 Arsitektur ANN dengan 3 Unit *Neuron* dalam *Hidden Layer*

Selanjutnya, 9 arsitektur lainnya dapat dilihat pada lampiran.

4.4.3 Penentuan Jumlah *Neuron* Optimum dalam *Hidden Layer*

Setelah didapatkan bentuk persamaan matematis masing-masing model ANN, selanjutnya dilakukan pemilihan mendapatkan jumlah unit *neuron* dalam *hidden layer* yang optimum. Pemilihan jumlah *neuron* didasarkan pada peramalan data *out-of-sample*. Berikut adalah nilai RMSE hasil peramalan data *out-of-sample* menggunakan metode *1-step forecast*.

Tabel 4.19 RMSE Hasil Peramalan Data *Out-of-Sample*

Jumlah neuron dalam hidden layer	Variabel			
	<i>Rolling</i>	<i>Swaying</i>	<i>Yawing</i>	Total
1	10,2997410	12,2553020	3,2844071	25,8394510
2	0,1642138	0,0855448	3,5466035	3,7963621
3	0,1676446	0,0610970	0,0185859	0,2473275
4	0,1670394	0,0611083	0,0168928	0,2450405
5	0,1668893	0,0611320	0,0168369	0,2448582
6	0,1668117	0,0611320	0,0168217	0,2447654
7	0,1665879	0,0612036	0,0172721	0,2450635
8	0,1668936	0,0611116	0,0169025	0,2449077
9	0,1668714	0,0611038	0,0167849	0,2447601
10	0,1668459	0,0612022	0,0167707	0,2448188

*Semua nilai dikalikan 10^{-5}

Berdasarkan Tabel 4.19, dapat dilihat bahwa nilai total RMSE terkecil adalah pada peramalan dengan menggunakan 9 unit *neuron* di dalam *hidden layer*. Maka, jumlah *hidden layer* optimum yang dipilih adalah 9.

Berikut adalah persamaan matematis dari model *Hybrid VAR-ANN* dengan 9 unit *neuron* dalam *hidden layer*.

a. Gerak *Rolling*

$$\begin{aligned}\hat{Y}_{1,t} = & 0,99883Y_{1,t-1} - 0,000052Y_{2,t-1} + 0,00269Y_{3,t-1} + 0,01 \\ & - 0,11f^h(a_1) + 1,26f^h(a_2) + 0,51f^h(a_3) \\ & - 0,17f^h(a_4) - 0,20f^h(a_5) + 0,60f^h(a_6) \\ & - 0,64f^h(a_7) - 1,12f^h(a_8) - 0,18f^h(a_9)\end{aligned}$$

b. Gerak *Swaying*

$$\begin{aligned}\hat{Y}_{2,t} = & -0,00665Y_{1,t-1} + 0,99993Y_{2,t-1} - 0,0005044Y_{3,t-1} \\ & - 0,36f^h(a_1) + 1,09f^h(a_2) - 0,35f^h(a_3) \\ & - 0,52f^h(a_4) - 0,23f^h(a_5) - 0,26f^h(a_6) \\ & - 0,36f^h(a_7) + 1,37f^h(a_8) - 0,39f^h(a_9)\end{aligned}$$

c. Gerak *Yawing*

$$\begin{aligned}\hat{Y}_{3,t} = & -0,00344Y_{1,t-1} + 0,0000291Y_{2,t-1} + 0,99992Y_{3,t-1} \\ & + 0,34f^h(a_1) + 0,73f^h(a_2) - 0,43f^h(a_3) \\ & + 0,17f^h(a_4) - 0,58f^h(a_5) - 1,04f^h(a_6) \\ & + 1,06f^h(a_7) - 0,58f^h(a_8) + 0,33f^h(a_9)\end{aligned}$$

di mana,

$$f^h(a) = \frac{1}{1 + \exp(-a)}$$

$$a_1 = -0,01 - 0,11e_{1,t-1} - 0,34e_{2,t-1} + 0,35e_{3,t-1}$$

$$a_2 = 1,26e_{1,t-1} + 1,14e_{2,t-1} + 0,68e_{3,t-1}$$

$$a_3 = 0,01 + 0,50e_{1,t-1} - 0,38e_{2,t-1} - 0,41e_{3,t-1}$$

$$a_4 = -0,17e_{1,t-1} - 0,52e_{2,t-1} + 0,19e_{3,t-1}$$

$$a_5 = -0,02 - 0,19e_{1,t-1} - 0,26e_{2,t-1} - 0,56e_{3,t-1}$$

$$a_6 = -0,02 + 0,59e_{1,t-1} - 0,31e_{2,t-1} - 1,02e_{3,t-1}$$

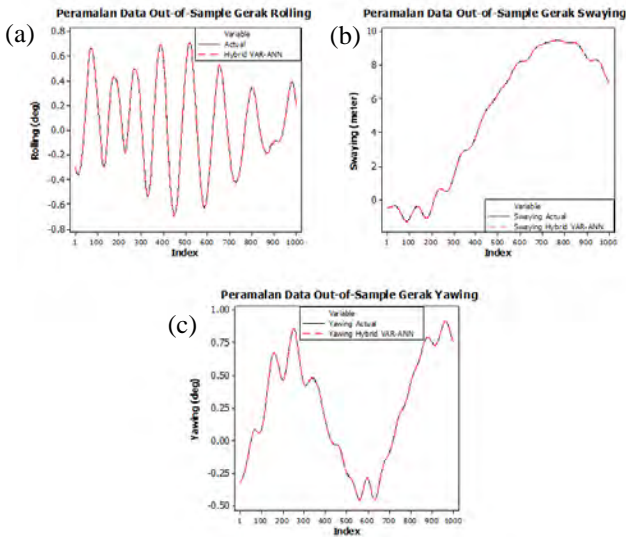
$$a_7 = -0,03 - 0,65e_{1,t-1} - 0,30e_{2,t-1} + 1,08e_{3,t-1}$$

$$a_8 = -1,12e_{1,t-1} + 1,34e_{2,t-1} - 0,65e_{3,t-1}$$

$$a_9 = -0,19e_{1,t-1} - 0,38e_{2,t-1} + 0,35e_{3,t-1}$$

4.4.4 Peramalan Data *Out-of-Sample*

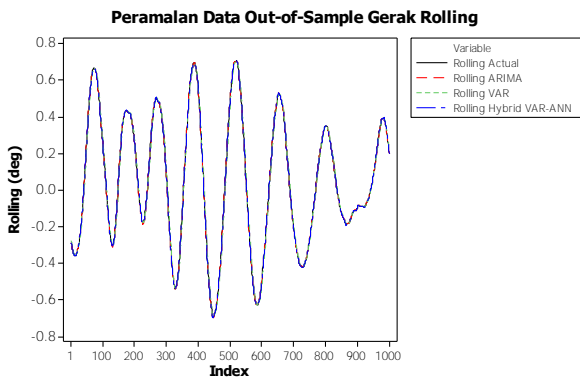
Peramalan data *out-of-sample* dengan model *Hybrid VAR-ANN* menggunakan metode *1-step forecast*. Berikut adalah hasil peramalan masing-masing variabel.



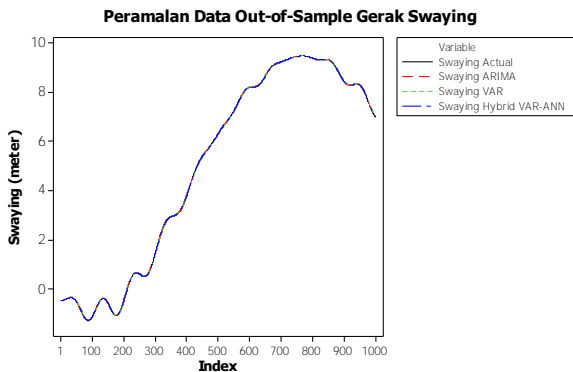
Gambar 4.13 Peramalan Data *Out-of-Sample* Gerak (a) *Rolling*, (b) *Swaying*, dan (c) *Yawing*

4.5 Perbandingan Hasil Peramalan dengan Model ARIMA, VAR, dan *Hybrid* VAR-ANN

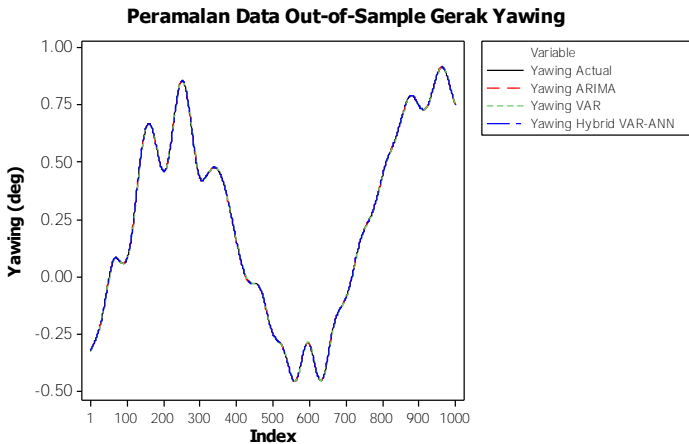
Setelah didapatkan model ARIMA, VAR, dan *Hybrid* VAR-ANN yang sesuai untuk meramalkan gerak *rolling*, *swaying*, dan *yawing*, selanjutnya dilakukan pemilihan model terbaik berdasarkan kriteria *out-of-sample*. Ukuran kriteria yang digunakan adalah RMSE. Berikut adalah hasil peramalan data *out-of-sample* dari masing-masing model.



Gambar 4.14 Peramalan Data *Out-of-Sample* Gerak Rolling



Gambar 4.15 Peramalan Data *Out-of-Sample* Gerak Swaying



Gambar 4.16 Peramalan Data *Out-of-Sample* Gerak Yawing

Nilai RMSE dari peramalan masing-masing model adalah sebagai berikut.

Tabel 4.20 RMSE Peramalan Data *Out-of-Sample* Gerak Rolling, Swaying, dan Yawing

Variabel	RMSE		
	ARIMA	VAR	Hybrid VAR-ANN
Rolling	3,4041	303,6568	1,6687
Swaying	4,8387	409,7134	0,6110
Yawing	0,0250	32,0983	0,1678
Total	8,2678	745,4685	2,4476

*Semua nilai dikalikan 10^{-6}

Berdasarkan Tabel 4.20, dapat dilihat bahwa peramalan dengan total RMSE terkecil adalah peramalan dengan model *Hybrid VAR-ANN*, yaitu sebesar $2,4476 \times 10^{-6}$. Peramalan dengan RMSE terkecil kedua adalah peramalan dengan model *ARIMA*, yaitu sebesar $8,2678 \times 10^{-6}$. Sementara peramalan dengan RMSE

terbesar adalah peramalan dengan model VAR, yaitu sebesar $745,4685 \times 10^{-6}$. Berdasarkan hasil, dapat dilihat bahwa kemampuan peramalan model *Hybrid* VAR-ANN dapat mengungguli model VAR dan Model ARIMA. Hal ini sesuai dengan penelitian yang dilakukan Zhang (2003), di mana hasil peramalan dengan model *hybrid* ARIMA-ANN memiliki nilai RMSE lebih kecil dibandingkan hasil peramalan dengan model linier ARIMA. Dengan demikian, pada penelitian ini dapat disimpulkan bahwa model *Hybrid* VAR-ANN adalah model terbaik berdasarkan kriteria *out-of-sample* untuk meramalkan gerak *rolling*, *swaying*, dan *yawing*.

Halaman ini sengaja dikosongkan

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil dari analisis dan pembahasan, maka didapatkan beberapa kesimpulan sebagai berikut.

1. Model ARIMA yang sesuai untuk meramalkan gerak *rolling* adalah ARIMA $([1,2,3,4,9,19,20],0,[19])$. Sementara untuk gerak *swaying* didapatkan model ARIMA $([1,2,4,5,6,8,9,10,11,12,13,14,15,16,17,18,19,21,22,23,24,26,27,28,29,31,34,35],1,[2,35,43])$ dan model ARIMA untuk gerak *yawing* adalah ARIMA $([1,3,4,5,6,7,8,17,18,22,29],1,[7,16])$.
2. Pembentukan model VAR dalam penelitian ini tidak mendapatkan model VAR yang terbaik karena matriks varians-kovarians tidak definit positif untuk model VAR dengan order lebih dari satu, sehingga hanya bisa memodelkan VAR (1).
3. Model *Hybrid* VAR-ANN yang didapat adalah model dengan 9 unit *neuron* dalam *hidden layer*.
4. Berdasarkan hasil peramalan data *out-of-sample*, didapatkan model *Hybrid* VAR-ANN sebagai model terbaik dibandingkan dengan model ARIMA dan model VAR.

5.2 Saran

Untuk penelitian selanjutnya, sebaiknya menggunakan metode univariat saja untuk memodelkan gerak *rolling*, *swaying*, dan *yawing* karena ketiga gerak tersebut tidak memiliki hubungan korelasi yang kuat sehingga tidak dapat dimodelkan secara multivariat dengan baik. Beberapa metode yang dapat digunakan yaitu *Recurrent Neural Network*, *Hybrid* ARIMA-ANN, ANFIS, atau *Hybrid* ARIMA-ANFIS.



Halaman ini sengaja dikosongkan

DAFTAR PUSTAKA

- Alva, J.A.V., & Estrada E.G. (2009). A Generalization of Shapiro–Wilk's Test for Multivariate Normality. *Communications in Statistics—Theory and Methods*, 38, 1870–1883.
- Armstrong, J.S. (2007). Significance Tests Harm Progress in Forecasting. *International Journal of Forecasting*, 23, 321–327.
- Box, G.E.P., Jenkins, G.M., & Reinsel, G.C. (2008). *Time Series Analysis Forecasting and Control (4th Ed.)*. Oakland: Holden-Day, Inc.
- Brockwell, P.J., & Davis, R.A. (2002). *Introduction to Time Series and Forecasting (2nd Ed.)*. New York: Springer-Verlag.
- Chatfield, C. (2000). *Time-Series Forecasting*. New York: Chapman & Hall.
- Cryer, J.D., & Chan, K. (2008). *Time Series Analysis With Application in R (2nd Ed.)*. New York: Springer.
- Daniel, W.W. (2000). *Applied Nonparametric Statistics (2nd Ed.)*. Boston: Duxbury Press.
- Das, S.K., Das S.N, & Sahoo, P.K. (8-10 November 2006). *Investigation of Sway, Roll and Yaw Motions of a Ship with Forward Speed: Numerical Modeling for Flared Up Conditions*. Paper presented at 5th International Conference on High Performance Marine Vehicles, Launceston.
- Fausett, L. (1994). *Fundamental of Neural Network: Architectures, algorithm and applications*, New Jersey: Prentice Hall Inc.
- Gooijer, J.G.D., & Hyndman, R. J. (2006). 25 Years of Time Series Forecasting. *International Journal of Forecasting*, 22, 443–473.
- Gujarati, D.N. (2004). *Basic Econometrics (4th Ed.)*. New York: McGraw-Hill.

- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer Feedforward Networks are Universal Approximators. *Neural Networks*, 2, 359-366.
- Hui, L.A., & Fong, Y.F. (2010). A Numerical Study of Ship's Rolling Motion, *Proceedings of the 6th IMT-GT Conference on Mathematics, Statistics, and its Applications*, (pp. 843-851). Kuala Lumpur, Malaysia: Universiti Tunku Abdul Rahman.
- Journée, J.M.J., & Massie, W.W. (2001). Offshore Hydromechanics. Delft: Delft University of Technology.
- Khan, A., Bil, C., Marion, K., & Malcolm, M. (29 Agustus-3 September 2004). *Real Time Prediction of Ship Motions and Attitudes using Advanced Prediction Techniques*. Paper presented at 24th International Congress of The Aeronautical Sciences, Yokohama.
- Khan, A., Bil, C., & Marion, K. (2005). Theory and Application of Artificial Neural Networks for the Real Time Prediction of Ship Motion. *Lecture Notes in Computer Science*, 3681, 1064-1069.
- Kostenko, A.V., & Hyndman, R.J. (2008). Forecasting Without Significance Test?. <http://robjhyndman.com/papers/sst2.pdf>.
- Kusumadewi, S. (2004). *Membangun Jaringan Syaraf Tiruan (Menggunakan MATLAB & Excel Link)*. Yogyakarta: Graha ilmu.
- Levis, E.V. (1989). *Principles of Naval Architecture Volume III Motions in Waves and Controllability*. New Jersey: Society of Naval Architects and Marine Engineers (SNAME).
- Lütkepohl, H. (2005). *New Introduction to Multiple Time Series Analysis*. New York: Springer.
- Makridakis, S.G., Wheelwright, S.C., & Hyndman, R.J. (1997). *Forecasting: Methods and Applications (3rd Ed.)*. New York: John Wiley & Sons, Inc.
- Nicolau, V., Palade, V., & Aiordachioaie, D. (2007). Neural Network Prediction of The Roll Motion of a Ship for

Intelligent Course Control. *Lecture Notes in Computer Science*, 4694, 284-291.

Pai, P.F., & Ling, C.S. (2005). A Hybrid ARIMA and Support Vector Machines Models in Stock Price Forecasting. *Omega The International Journal of Management Science*, 33, 497-505.

Suhartono (2007). *Feed Forward Neural Network untuk Pemodelan Runtun Waktu*. Disertasi, Jurusan Matematika, Universitas Gadjah Mada.

Teräsvirta, T., Lin, C.F., & Granger, C.W.J. (1993). Power of The Neural network Linearity Test. *Journal of Time Series Analysis*, 14, 159-171.

Tsay, R.S. (2010). *Analysis of Financial Time Series: Financial Econometrics (3rd Ed.)*. New York: John Wiley & Sons, Inc.

Wei, W.W., (2006). *Time Series Analysis : Univariate and Multivariate Methods (2nd Ed.)*. New York: Pearson.

Zhang, G., Patuwo, B.E., & Hu, M.Y. (1998). Forecasting with Artificial Neural Networks: The State of the Art. *International Journal of Forecasting*, 14, 35-62.

Zhang, G.P. (2003). Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 50, 159-175.

Zhang, X.L., & Ye, J.W. (21-26 Juni 2009). *An Experimental Study on The Prediction of The Ships Motions using Time Series Analysis*. Paper presented at The 9th International Offshore and Polar Engineering Conference, Osaka.



Halaman ini sengaja dikosongkan

BIODATA PENULIS



Penulis, Novri Suhermi lahir di Pekanbaru, pada tanggal 2 November 1992. Penulis merupakan anak kedua dari tiga bersaudara. Jenjang pendidikan yang telah ditempuh penulis adalah TK Ketintang Jaya Surabaya pada tahun 1997-1998. Menempuh Sekolah Dasar di SDN 003 Sail Pekanbaru pada tahun 1998-2004, SMP Negeri 13 Pekanbaru (2004-2007), dan SMA Negeri Plus Provinsi Riau (2007-2010). Setelah lulus SMA penulis melanjutkan studi di Jurusan Statistika ITS melalui seleksi jalur PMDK Reguler dan tercatat sebagai mahasiswa Statistika FMIPA ITS dengan NRP 1310100010 pada tahun 2010. Sejak Tahun 2013 penulis mengikuti Program S2 Fast Track di Jurusan Statistika ITS dan terdaftar sebagai mahasiswa S2 Statistika FMIPA ITS dengan NRP 1313201902. Penulis pernah aktif di organisasi kemahasiswaan HIMASTA-ITS sebagai tim ahli periode 2011-2012 dan 2012-2013 sekaligus memegang amanah sebagai ketua panitia Statistics Competition (STATION) 2012 Tingkat Nasional. Selain itu penulis pernah aktif di BEM FMIPA ITS sebagai Staff Kementerian HUBLU periode 2011-2012, dan menjadi Koordinator Tim Ahli periode 2012-2013. Penulis juga pernah meraih beberapa prestasi di antaranya Juara 2 Lomba Calculus Cup Tingkat Nasional, Juara 1 OSN Pertamina 2012 Bidang Matematika Tingkat Jawa Timur, Finalis 6 Besar OSN Pertamina 2012 Bidang Matematika Tingkat Nasional, dan Mahasiswa Berprestasi 3 Jurusan Statistika ITS Tahun 2013.

Segala saran dan kritik yang membangun selalu penulis harapkan untuk kebaikan ke depannya. Penulis dapat dihubungi melalui alamat e-mail novri.statistika2010@gmail.com atau novri.suhermi10@mhs.statistika.its.ac.id.

DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Data Gerak <i>Rolling</i> , <i>Swaying</i> , dan <i>Yawing</i> dengan SAS.....	75
Lampiran 2 Syntax Pemodelan ARIMA Data Gerak <i>Rolling</i> dengan SAS.....	76
Lampiran 3 Syntax Pemodelan ARIMA Data Gerak <i>Swaying</i> dengan SAS.....	77
Lampiran 4 Syntax Pemodelan ARIMA Data Gerak <i>Yawing</i> dengan SAS	78
Lampiran 5 Syntax Pemodelan VAR (1) dengan SAS	79
Lampiran 6 Syntax Uji Linieritas dengan R	80
Lampiran 7 Syntax Inisialisasi Variabel Model <i>Hybrid</i> VAR-ANN dan Perhitungan Bobot Optimum menggunakan R	81
Lampiran 8 Peramalan Data <i>Out-of-Sample</i> Residual Menggunakan Metode <i>one-step forecast</i> pada model <i>Hybrid</i> VAR-ANN menggunakan R .	82
Lampiran 9 Peramalan Data <i>Out-of-Sample</i> Residual Menggunakan Metode <i>k-step forecast</i> pada model <i>Hybrid</i> VAR-ANN menggunakan R .	83
Lampiran 10 Plot <i>Time Series</i> Data Gerak <i>Rolling</i> Partisi 1 sampai 9.....	84
Lampiran 11 Plot <i>Time Series</i> Data Gerak <i>Rolling</i> Partisi 10 sampai 18.....	85
Lampiran 12 Plot <i>Time Series</i> Data Gerak <i>Rolling</i> Partisi 19 sampai 27	86
Lampiran 13 Plot <i>Time Series</i> Data Gerak <i>Rolling</i> Partisi 28 sampai 36.....	87

Lampiran 14	Plot <i>Time Series</i> Data Gerak <i>Rolling</i> Partisi 37 sampai 45.....	88
Lampiran 15	Plot <i>Time Series</i> Data Gerak <i>Rolling</i> Partisi 46 sampai 52.....	89
Lampiran 16	Plot <i>Time Series</i> Data Gerak <i>Swaying</i> Partisi 1 sampai 9.....	90
Lampiran 17	Plot <i>Time Series</i> Data Gerak <i>Swaying</i> Partisi 10 sampai 18.....	91
Lampiran 18	Plot <i>Time Series</i> Data Gerak <i>Swaying</i> Partisi 19 sampai 27.....	92
Lampiran 19	Plot <i>Time Series</i> Data Gerak <i>Swaying</i> Partisi 28 sampai 36.....	93
Lampiran 20	Plot <i>Time Series</i> Data Gerak <i>Swaying</i> Partisi 37 sampai 45.....	94
Lampiran 21	Plot <i>Time Series</i> Data Gerak <i>Swaying</i> Partisi 46 sampai 52.....	95
Lampiran 22	Plot <i>Time Series</i> Data Gerak <i>Yawing</i> Partisi 1 sampai 9.....	96
Lampiran 23	Plot <i>Time Series</i> Data Gerak <i>Yawing</i> Partisi 10 sampai 18.....	97
Lampiran 24	Plot <i>Time Series</i> Data Gerak <i>Yawing</i> Partisi 19 sampai 27.....	98
Lampiran 25	Plot <i>Time Series</i> Data Gerak <i>Yawing</i> Partisi 28 sampai 36.....	99
Lampiran 26	Plot <i>Time Series</i> Data Gerak <i>Yawing</i> Partisi 37 sampai 45.....	100
Lampiran 27	Plot <i>Time Series</i> Data Gerak <i>Yawing</i> Partisi 45 sampai 52.....	101
Lampiran 28	Plot ACF Data Gerak <i>Rolling</i> Partisi 1 sampai 9.....	102

Lampiran 29	Plot ACF Data Gerak <i>Rolling</i> Partisi 10 sampai 18.....	103
Lampiran 30	Plot ACF Data Gerak <i>Rolling</i> Partisi 19 sampai 27.....	104
Lampiran 31	Plot ACF Data Gerak <i>Rolling</i> Partisi 28 sampai 36.....	105
Lampiran 32	Plot ACF Data Gerak <i>Rolling</i> Partisi 37 sampai 45.....	106
Lampiran 33	Plot ACF Data Gerak <i>Rolling</i> Partisi 46 sampai 52.....	107
Lampiran 34	Plot ACF Data Gerak <i>Swaying</i> Partisi 1 sampai 9.....	108
Lampiran 35	Plot ACF Data Gerak <i>Swaying</i> Partisi 10 sampai 18.....	109
Lampiran 36	Plot ACF Data Gerak <i>Swaying</i> Partisi 19 sampai 27.....	110
Lampiran 37	Plot ACF Data Gerak <i>Swaying</i> Partisi 28 sampai 36.....	111
Lampiran 38	Plot ACF Data Gerak <i>Swaying</i> Partisi 37 sampai 45.....	112
Lampiran 39	Plot ACF Data Gerak <i>Swaying</i> Partisi 46 sampai 52.....	113
Lampiran 40	Plot ACF Data Gerak <i>Yawing</i> Partisi 1 sampai 9.....	114
Lampiran 41	Plot ACF Data Gerak <i>Yawing</i> Partisi 10 sampai 18.....	115
Lampiran 42	Plot ACF Data Gerak <i>Yawing</i> Partisi 19 sampai 27.....	116
Lampiran 43	Plot ACF Data Gerak <i>Yawing</i> Partisi 28 sampai 36.....	117

Lampiran 44	Plot ACF Data Gerak <i>Yawing</i> Partisi 37 sampai 45.....	118
Lampiran 45	Plot ACF Data Gerak <i>Yawing</i> Partisi 46 sampai 52.....	119
Lampiran 46	Plot PACF Data Gerak <i>Rolling</i> Partisi 1 sampai 9.....	120
Lampiran 47	Plot PACF Data Gerak <i>Rolling</i> Partisi 10 sampai 18.....	121
Lampiran 48	Plot PACF Data Gerak <i>Rolling</i> Partisi 19 sampai 27.....	122
Lampiran 49	Plot PACF Data Gerak <i>Rolling</i> Partisi 28 sampai 36.....	123
Lampiran 50	Plot PACF Data Gerak <i>Rolling</i> Partisi 37 sampai 45.....	124
Lampiran 51	Plot PACF Data Gerak <i>Rolling</i> Partisi 46 sampai 52.....	125
Lampiran 52	Plot PACF Data Gerak <i>Swaying</i> Partisi 1 sampai 9.....	126
Lampiran 53	Plot PACF Data Gerak <i>Swaying</i> Partisi 10 sampai 18.....	127
Lampiran 54	Plot PACF Data Gerak <i>Swaying</i> Partisi 19 sampai 27.....	128
Lampiran 55	Plot PACF Data Gerak <i>Swaying</i> Partisi 28 sampai 36.....	129
Lampiran 56	Plot PACF Data Gerak <i>Swaying</i> Partisi 37 sampai 45.....	130
Lampiran 57	Plot PACF Data Gerak <i>Swaying</i> Partisi 46 sampai 52.....	131
Lampiran 58	Plot PACF Data Gerak <i>Yawing</i> Partisi 10 sampai 18.....	132

Lampiran 59	Plot PACF Data Gerak <i>Yawing</i> Partisi 10 sampai 18.....	133
Lampiran 60	Plot PACF Data Gerak <i>Yawing</i> Partisi 19 sampai 27.....	134
Lampiran 61	Plot PACF Data Gerak <i>Yawing</i> Partisi 28 sampai 36.....	135
Lampiran 62	Plot PACF Data Gerak <i>Yawing</i> Partisi 37 sampai 45.....	136
Lampiran 63	Plot PACF Data Gerak <i>Yawing</i> Partisi 46 sampai 52.....	137
Lampiran 64	Output SAS Pemodelan ARIMA Data Gerak <i>Rolling</i>	138
Lampiran 65	Output SAS Pemodelan ARIMA Data Gerak <i>Swaying</i>	139
Lampiran 66	Output SAS Pemodelan ARIMA Data Gerak <i>Yawing</i>	141
Lampiran 67	Hasil Peramalan Data <i>Out-of-Sample</i> Gerak <i>Rolling</i> dengan Model ARIMA Menggunakan Metode <i>k-Step Forecast</i>	142
Lampiran 68	Hasil Peramalan Data <i>Out-of-Sample</i> Gerak <i>Swaying</i> dengan Model ARIMA Menggunakan Metode <i>k-Step Forecast</i>	143
Lampiran 69	Hasil Peramalan Data <i>Out-of-Sample</i> Gerak <i>Rolling</i> dengan Model ARIMA Menggunakan Metode <i>k-Step Forecast</i>	144
Lampiran 70	Output SAS Pemodelan VAR (1).....	145
Lampiran 71	Hasil Peramalan Data <i>Out-of-Sample</i> dengan Model VAR (1) Menggunakan Metode <i>k-Step Forecast</i>	146

Lampiran 72	Arsitektur Model <i>Hybrid</i> VAR-ANN dengan 1 unit <i>neuron</i> dalam <i>Hidden Layer</i>	147
Lampiran 73	Arsitektur Model <i>Hybrid</i> VAR-ANN dengan 2 unit <i>neuron</i> dalam <i>Hidden Layer</i>	147
Lampiran 74	Arsitektur Model <i>Hybrid</i> VAR-ANN dengan 3 unit <i>neuron</i> dalam <i>Hidden Layer</i>	147
Lampiran 75	Arsitektur Model <i>Hybrid</i> VAR-ANN dengan 4 unit <i>neuron</i> dalam <i>Hidden Layer</i>	148
Lampiran 76	Arsitektur Model <i>Hybrid</i> VAR-ANN dengan 5 unit <i>neuron</i> dalam <i>Hidden Layer</i>	148
Lampiran 77	Arsitektur Model <i>Hybrid</i> VAR-ANN dengan 6 unit <i>neuron</i> dalam <i>Hidden Layer</i>	148
Lampiran 78	Arsitektur Model <i>Hybrid</i> VAR-ANN dengan 7 unit <i>neuron</i> dalam <i>Hidden Layer</i>	149
Lampiran 79	Arsitektur Model <i>Hybrid</i> VAR-ANN dengan 8 unit <i>neuron</i> dalam <i>Hidden Layer</i>	149
Lampiran 80	Arsitektur Model <i>Hybrid</i> VAR-ANN dengan 9 unit <i>neuron</i> dalam <i>Hidden Layer</i>	149
Lampiran 81	Arsitektur Model <i>Hybrid</i> VAR-ANN dengan 10 unit <i>neuron</i> dalam <i>Hidden Layer</i>	150
Lampiran 82	Output Nilai Bobot Optimum dalam Model <i>Hybrid</i> VAR-ANN dengan 9 Unit <i>Neuron</i> dalam <i>Hidden Layer</i>	150
Lampiran 83	Hasil Peramalan Data <i>Out-of-Sample</i> dengan Model <i>Hybrid</i> VAR-ANN Menggunakan Metode <i>k-Step Forecast</i>	151

Lampiran 1. Data Gerak *Rolling*, *Swaying*, dan *Yawing* dengan SAS

No	Time (sec)	Wave (m)	Roll (deg)	Sway (m)	Yaw (deg)
1	0	0.6897	-0.1879	9.0531	0.6667
2	0.0718	0.7277	-0.1996	9.0448	0.6653
3	0.1435	0.7633	-0.2109	9.0362	0.664
4	0.2153	0.7945	-0.2224	9.027	0.6626
5	0.2871	0.82	-0.234	9.0168	0.6611
6	0.3588	0.8389	-0.2445	9.0059	0.6596
7	0.4306	0.8518	-0.2543	8.9943	0.6578
8	0.5023	0.8585	-0.2635	8.982	0.6559
9	0.5741	0.8594	-0.2722	8.9688	0.6537
10	0.6459	0.8548	-0.2808	8.9548	0.6511
11	0.7176	0.845	-0.2897	8.9399	0.6482
12	0.7894	0.829	-0.2983	8.9241	0.6451
13	0.8612	0.8075	-0.3071	8.9074	0.6416
14	0.9329	0.7806	-0.316	8.8904	0.6378
...
155941	11190.8	-0.2831	0.1212	3.9466	-0.101
155942	11190.872	-0.2851	0.1282	3.9446	-0.1033
155943	11190.944	-0.2871	0.1336	3.9421	-0.1057
155944	11191.016	-0.2894	0.1384	3.9395	-0.1081
155945	11191.087	-0.2922	0.1428	3.9367	-0.1107
155946	11191.159	-0.2947	0.1459	3.9334	-0.1134

Lampiran 2. Syntax Pemodelan ARIMA Data Gerak *Rolling* dengan SAS

```
data roll;
input y;
datalines;
0.2083
0.1920
0.1759
0.1589
0.1410
....
....
....
-0.2036
-0.2158
-0.2273
-0.2388
-0.2512
-0.2641
-0.2769
;
proc arima data=roll;
identify var=y;
estimate p=(1,2,3,4,9,19,20) q=(19) noconstant method=cls;
forecast out=ramalan lead=1;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\DATA\OUTPUT\residual.xls"
dbms=excel97
replace;
sheet="1";
run;
```

Lampiran 3. Syntax Pemodelan ARIMA Data Gerak *Swaying* dengan SAS

```
data sway;
input y;
datalines;
4.4116
4.4118
4.4136
4.4164
4.4203
...
...
...
-0.4508
-0.4548
-0.4577
-0.4601
-0.4624
-0.4645
-0.4661
;
proc arima data=sway;
identify var=y(1);
estimate
p=(1,2,4,5,6,8,9,10,11,12,13,14,15,16,17,18,19,21,22,23,24,26,27,28,29,
31,34,35) q=(2,35,43)
noconstant method=cls;
forecast out=ramalan lead=1;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\DATA\OUTPUT\residual.xls"
dbms=excel97
replace;
sheet="1";
run;
```

Lampiran 4. Syntax Pemodelan ARIMA Data Gerak *Yawing* dengan SAS

```
data yaw;
input y;
datalines;
-0.1350
-0.1423
-0.1494
-0.1563
-0.1632
...
...
...
-0.3606
-0.3548
-0.3492
-0.3437
-0.3384
-0.3334
-0.3286
;
proc arima data=yaw;
identify var=y(1);
estimate p=(1,3,4,5,6,7,8,17,18,22,29) q=(7,16) noconstant method=cls;
forecast out=ramalan lead=1;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\DATA\OUTPUT\residual.xls"
dbms=excel97
replace;
sheet="1";
run;
```

Lampiran 5. Syntax Pemodelan VAR (1) dengan SAS

```
Data motion;
input roll sway yaw;
datalines;
0.2083  4.4116  -0.1350
0.1920  4.4118  -0.1423
0.1759  4.4136  -0.1494
0.1589  4.4164  -0.1563
0.1410  4.4203  -0.1632
0.1230  4.4253  -0.1697
0.1052  4.4316  -0.1758
0.0861  4.4384  -0.1815
...
...
...
-0.2158 -0.4548 -0.3548
-0.2273 -0.4577 -0.3492
-0.2388 -0.4601 -0.3437
-0.2512 -0.4624 -0.3384
-0.2641 -0.4645 -0.3334
-0.2769 -0.4661 -0.3286;
proc varmax data=motion;
model roll sway yaw/ p=(1) lagmax=72
noint print=(corry parcoef pcorr pccancorr roots);
output lead=1000 out=motion1;
run;
proc export data=WORK.motion1
outfile='E:\DATA\OUTPUT\residual_var.xls'
dbms=excel
replace;
sheet="1";
run;
```

Lampiran 6. Syntax Uji Linieritas dengan R

```
#Memanggil Data
motion=read.table("E://DATA/TA/residual.txt")
mroll=motion[,1]
msway=motion[,2]
myaw=motion[,3]

#Variabel Target
roll=mroll[2:2999]
sway=msway[2:2999]
yaw=myaw[2:2999]

#Variabel Prediktor
roll1=mroll[1:2998]
sway1=msway[1:2998]
yaw1=myaw[1:2998]
motion1=cbind(roll1,sway1,yaw1)

#Loading Library tseries
library(tseries)

#Uji Terasvirta dengan Statistik Uji Chi-Squared data Roll
terasvirta.test(motion1, roll, type = c("Chisq"),scale = TRUE)
terasvirta.test(motion1, sway, type = c("Chisq"),scale = TRUE)
terasvirta.test(motion1, yaw, type = c("Chisq"),scale = TRUE)
```

Lampiran 7. Syntax Inisialisasi Variabel Model *Hybrid VAR-ANN* dan Perhitungan Bobot Optimum menggunakan R

```
#Memanggil library nnet
library(nnet)

#Memanggil Data
motion=read.table("E://DATA/TA/residual.txt")

#Inisialisasi Variabel
mroll=motion$V1
msway=motion$V2
myaw=motion$V3
roll=mroll[2:2999]
sway=msway[2:2999]
yaw=myaw[2:2999]
roll1=mroll[1:2998]
sway1=msway[1:2998]
yaw1=myaw[1:2998]
input=cbind(roll1,sway1,yaw1)
target=cbind(roll,sway,yaw)

#Pemodelan Hybrid VAR-ANN
nn=nnet(input,target,size=1,rang=0.1,linout=TRUE,decay=5e-
4,maxit=10000)
#size is number of units in the hidden layer
```

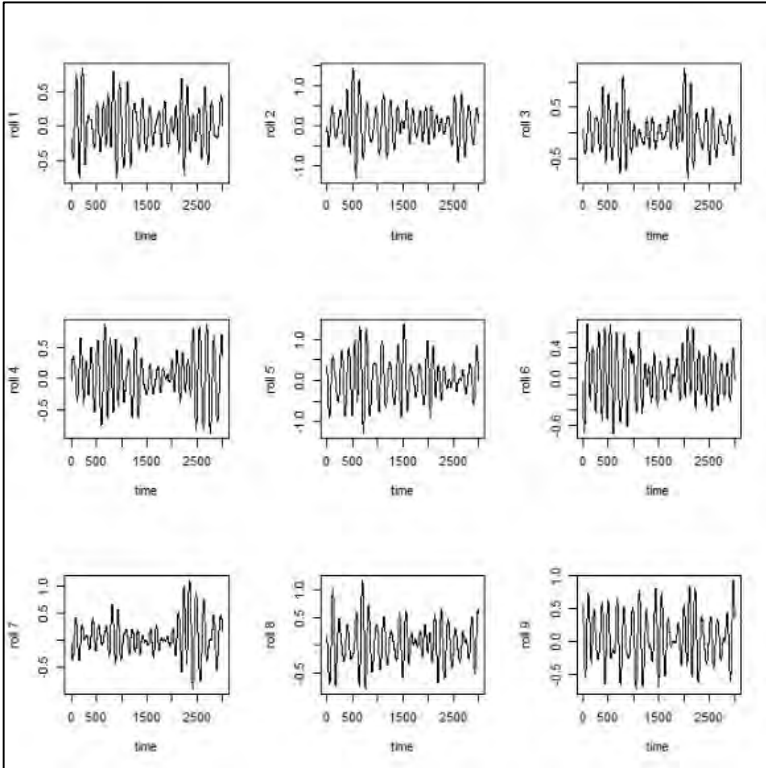
Lampiran 8. Peramalan Data *Out-of-Sample* Residual Menggunakan Metode *one-step forecast* pada model *Hybrid VAR-ANN* menggunakan R

```
#1-step forecast
b=rep(0,1000)
y.forecast=cbind(b,b,b)
for(i in 1:1000)
{
k=2999+i
roll.input=mroll[k-1]
sway.input=msway[k-1]
yaw.input=myaw[k-1]
input=cbind(roll.input, sway.input, yaw.input)
y.forecast[i,]=predict(nn,input)
}
write.table(y.forecast,"E://forecast.csv",sep=";",row.names=FALSE)
```

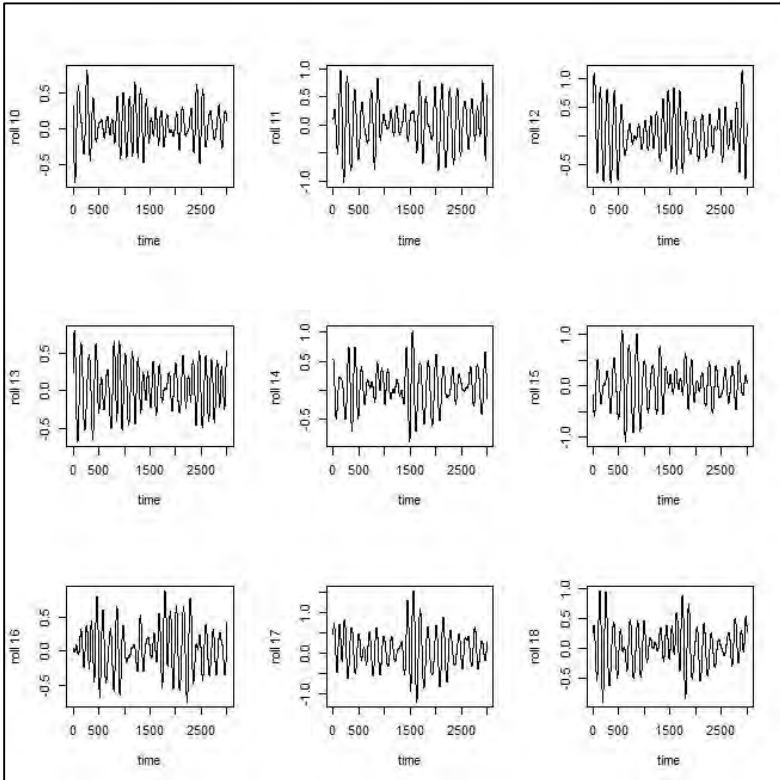

Lampiran 9. Peramalan Data *Out-of-Sample* Residual Menggunakan Metode *k-step forecast* pada model *Hybrid VAR-ANN* menggunakan R

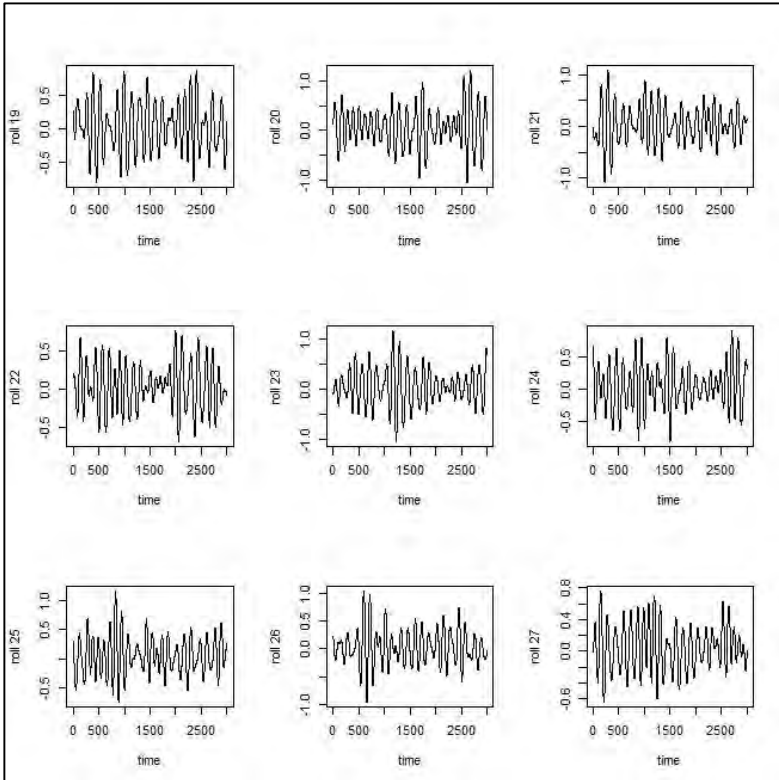
```
#k-step forecast
b=rep(0,1000)
y.forecast=cbind(b,b,b)
roll.input=mroll[2999]
sway.input=msway[2999]
yaw.input=myaw[2999]
for(i in 1:1000)
{
input=cbind(roll.input, sway.input, yaw.input)
y.forecast[i,]=predict(nn,input)
roll.input=y.forecast[i,1]
sway.input=y.forecast[i,2]
yaw.input=y.forecast[i,3]
}
write.table(y.forecast,"E://forecast.csv",sep="," ,row.names=FALSE)
```

Lampiran 10. Plot *Time Series Data Gerak Rolling Partisi 1* sampai 9

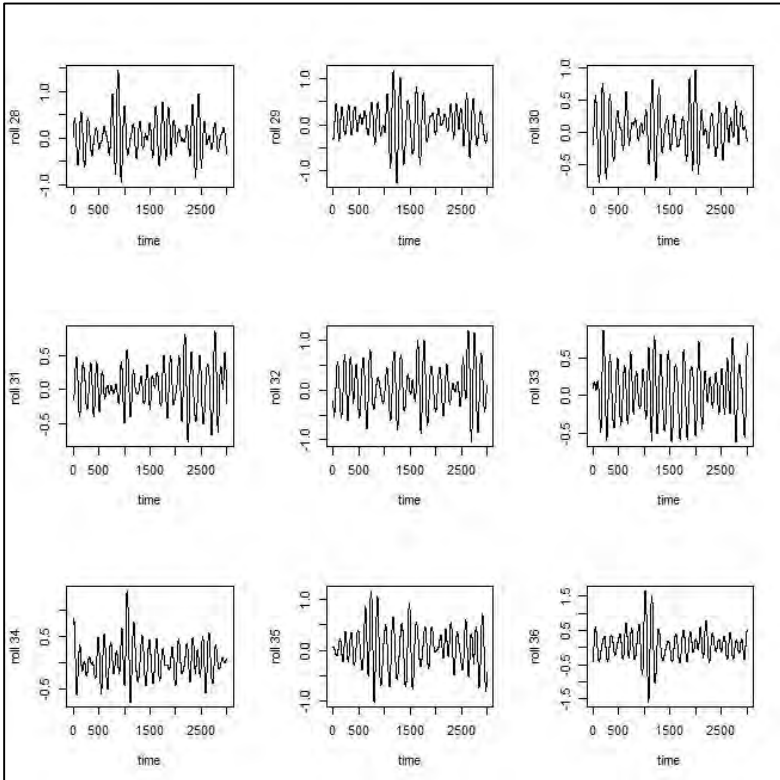


Lampiran 11. Plot *Time Series Data Gerak Rolling Partisi 10* sampai 18

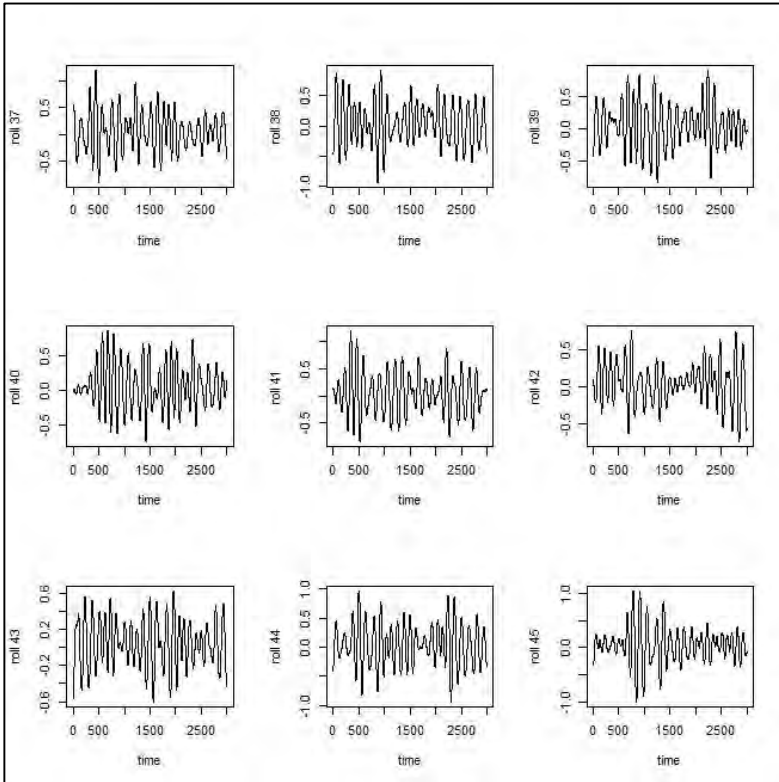


Lampiran 12. Plot *Time Series Data Gerak Rolling Partisi 19* sampai 27

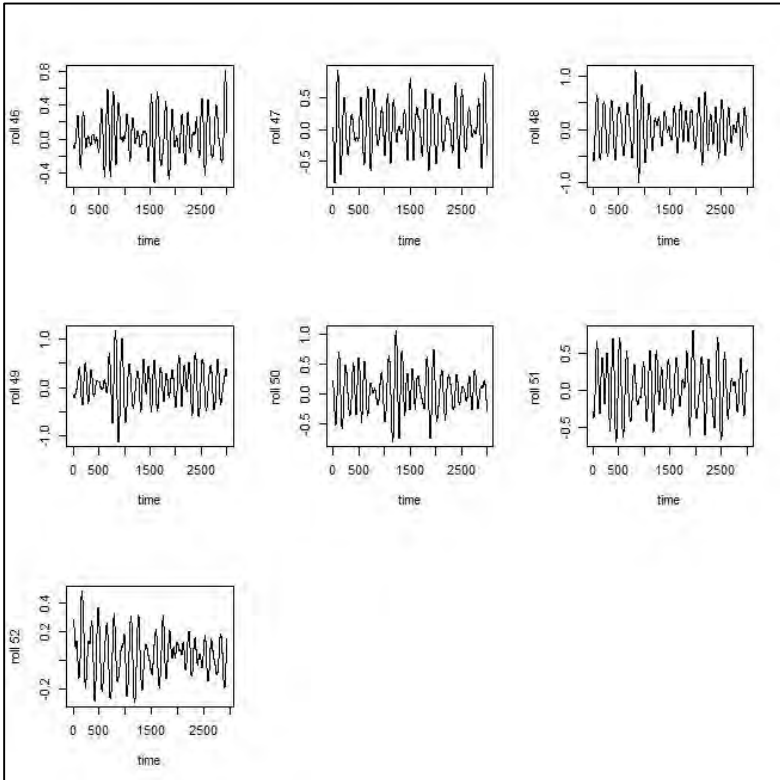
Lampiran 13. Plot *Time Series Data Gerak Rolling Partisi 28* sampai 36




Lampiran 14. Plot *Time Series* Data Gerak *Rolling* Partisi 37 sampai 45

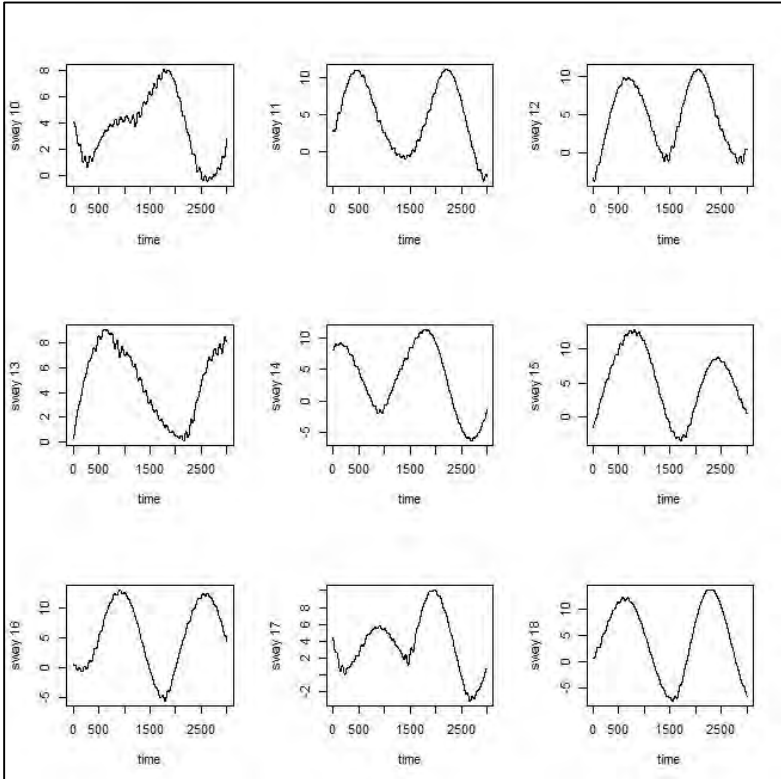


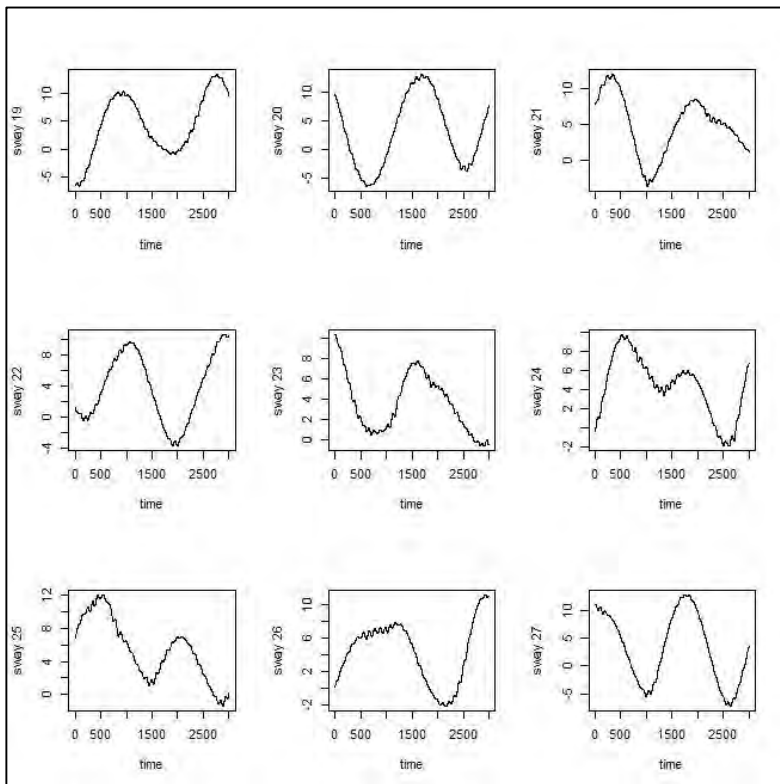
Lampiran 15. Plot *Time Series Data Gerak Rolling Partisi 46* sampai 52



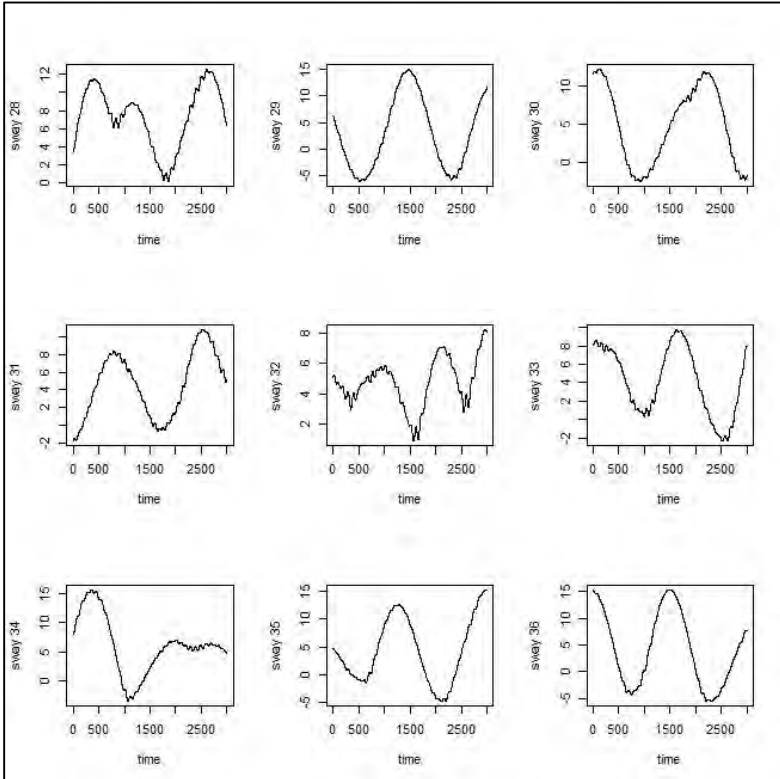
Lampiran 16. Plot *Time Series Data Gerak Swaying Partisi 1* sampai 9

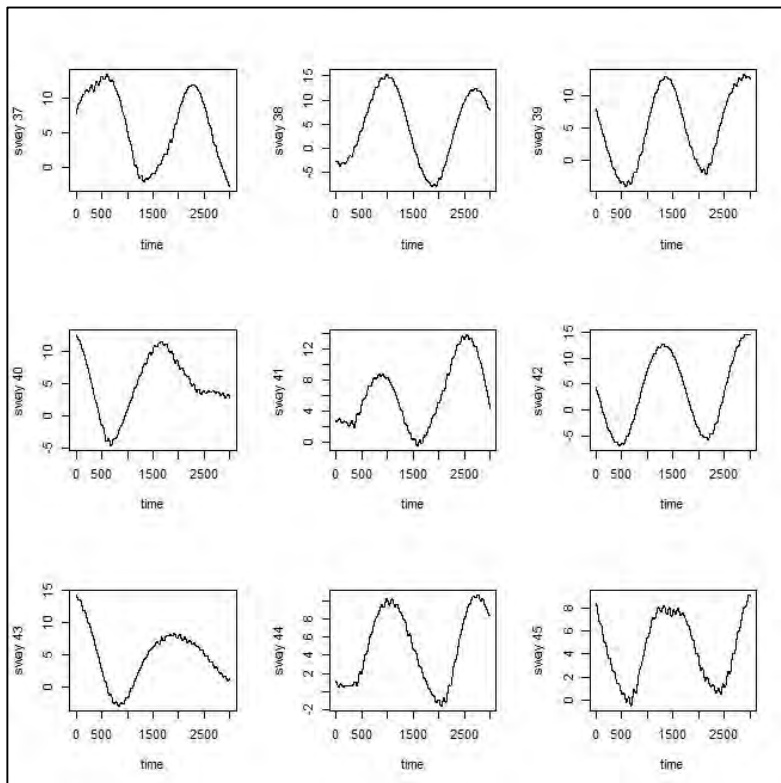
Lampiran 17. Plot *Time Series* Data Gerak Swaying Partisi 10 sampai 18



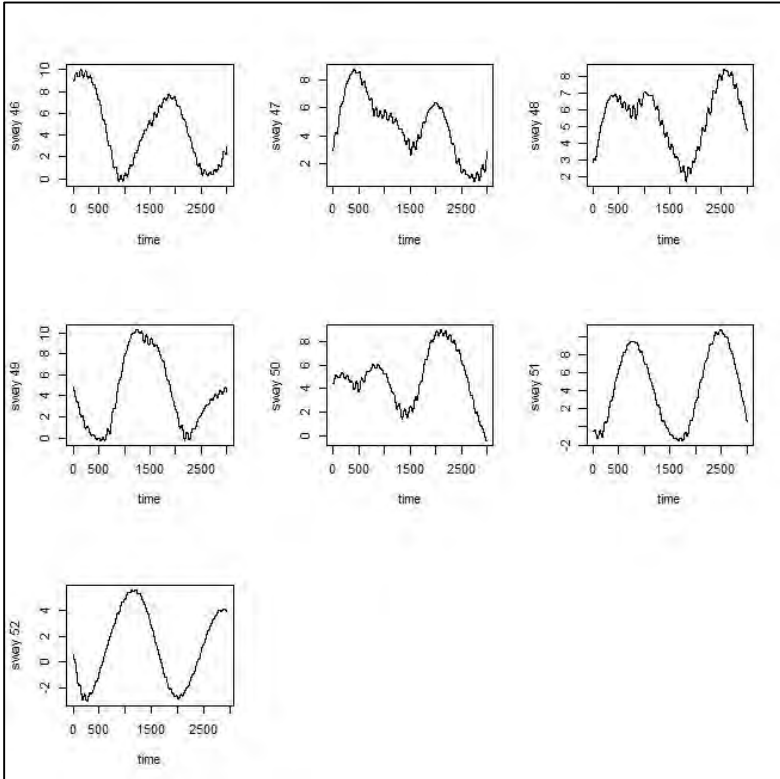
Lampiran 18. Plot *Time Series* Data Gerak Swaying Partisi 19 sampai 27


Lampiran 19. Plot *Time Series Data Gerak Swaying Partisi 28* sampai 36



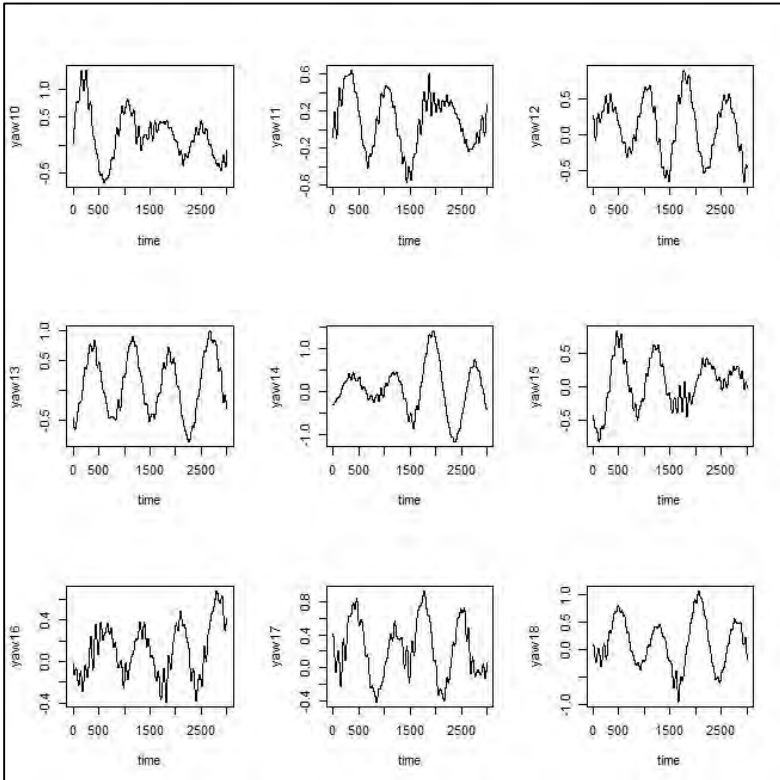
Lampiran 20. Plot *Time Series* Data Gerak Swaying Partisi 37 sampai 45

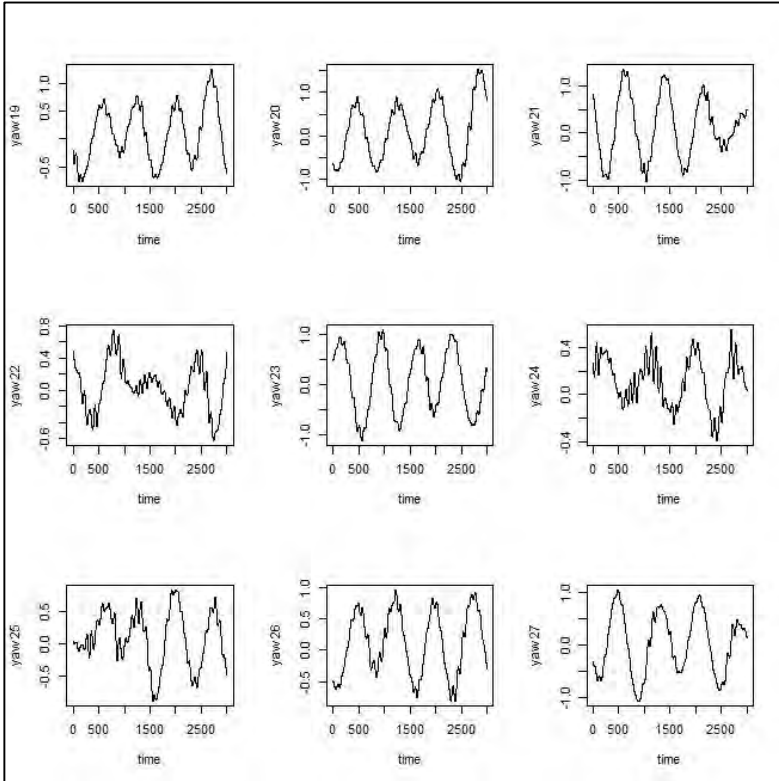
Lampiran 21. Plot *Time Series* Data Gerak *Swaying* Partisi 46 sampai 52



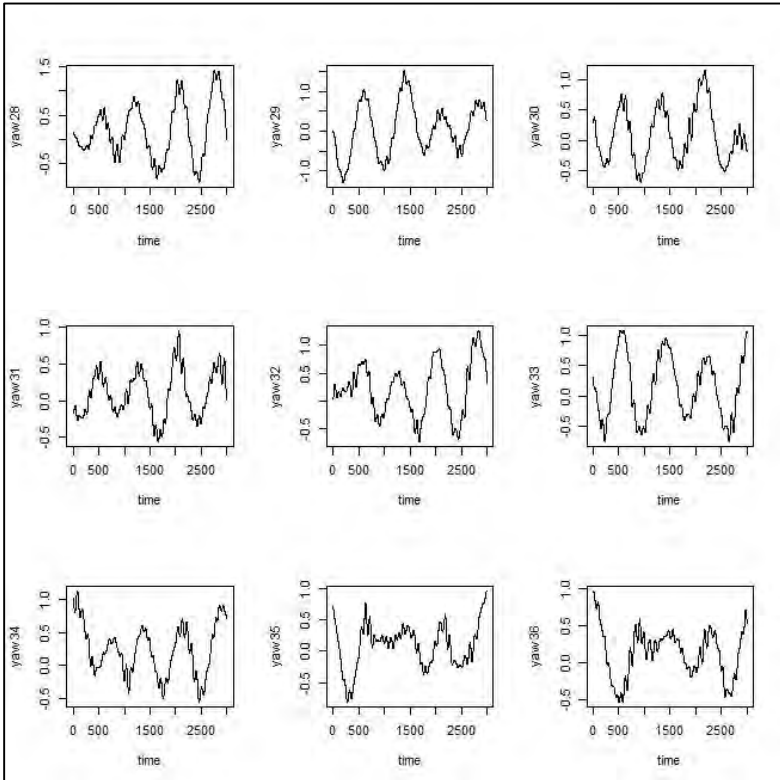
Lampiran 22. Plot *Time Series* Data Gerak Yawing Partisi 1 sampai 9


Lampiran 23. Plot *Time Series* Data Gerak *Yawing* Partisi 10 sampai 18




Lampiran 24. Plot *Time Series* Data Gerak Yawing Partisi 19 sampai 27

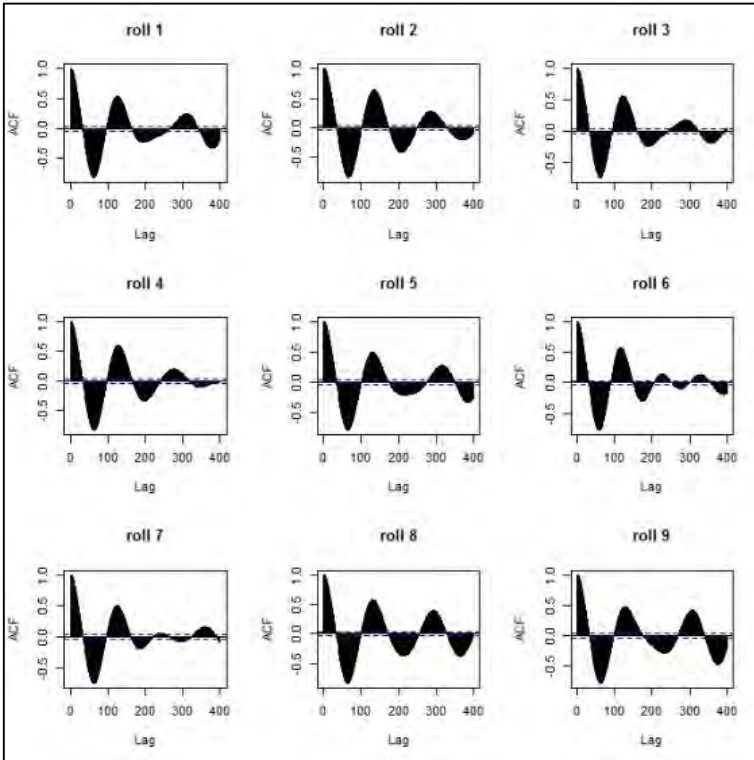
Lampiran 25. Plot *Time Series Data Gerak Yawing Partisi 28* sampai 36



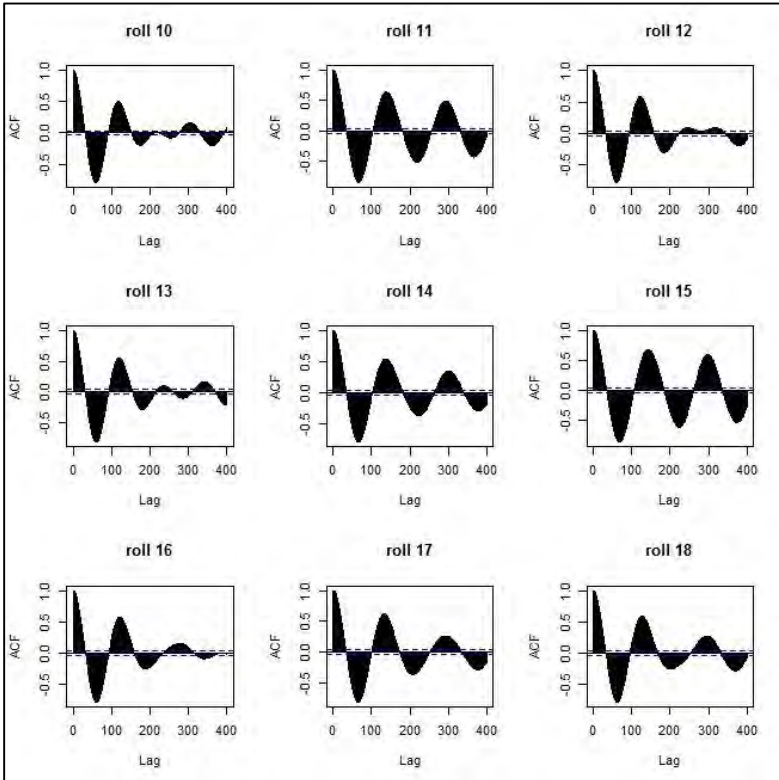
Lampiran 26. Plot *Time Series* Data Gerak Yawing Partisi 37 sampai 45

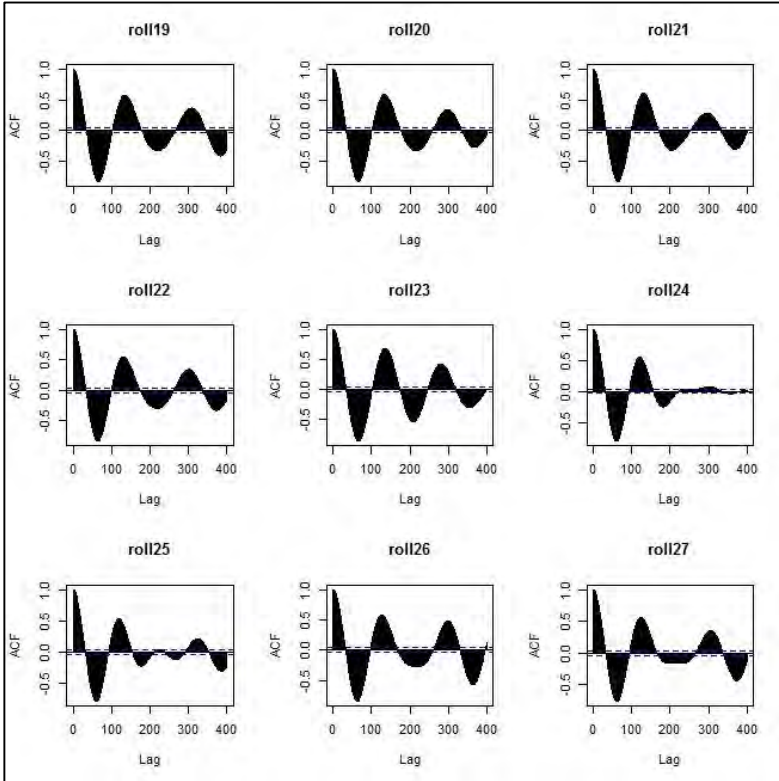
Lampiran 27. Plot *Time Series Data Gerak Yawing Partisi 45* sampai 52



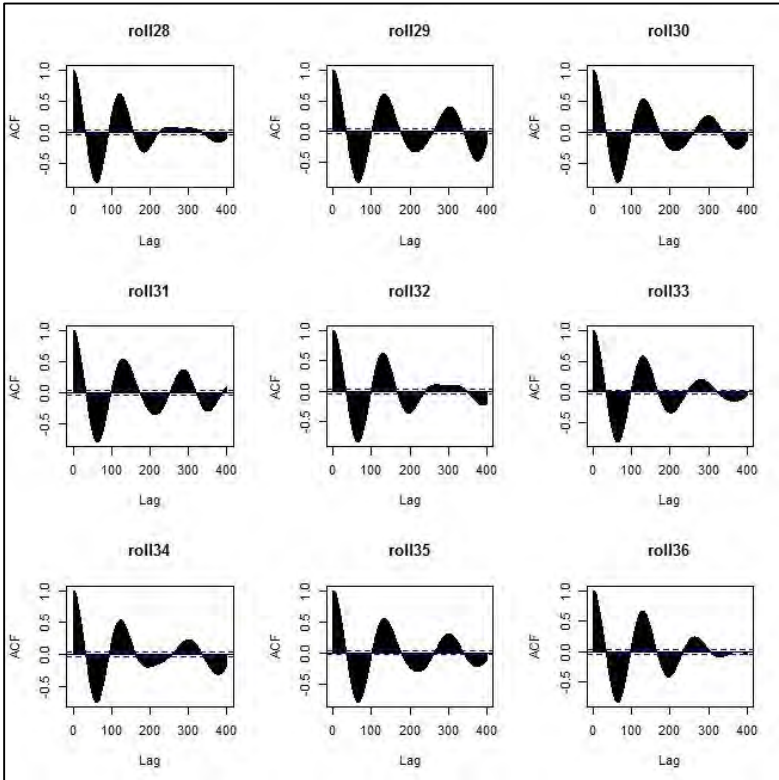
Lampiran 28. Plot ACF Data Gerak *Rolling* Partisi 1 sampai 9

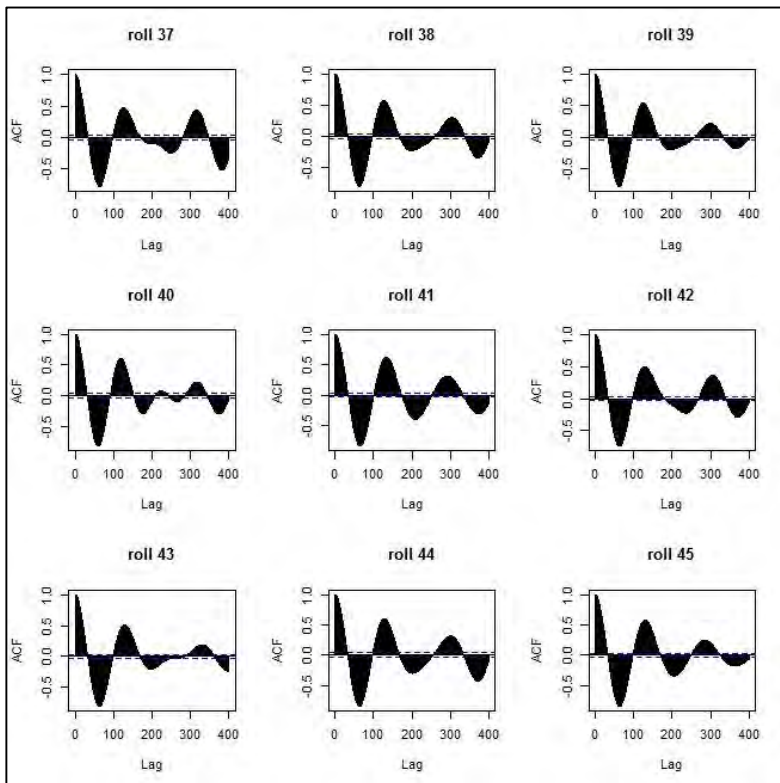
Lampiran 29. Plot ACF Data Gerak *Rolling* Partisi 10 sampai 18



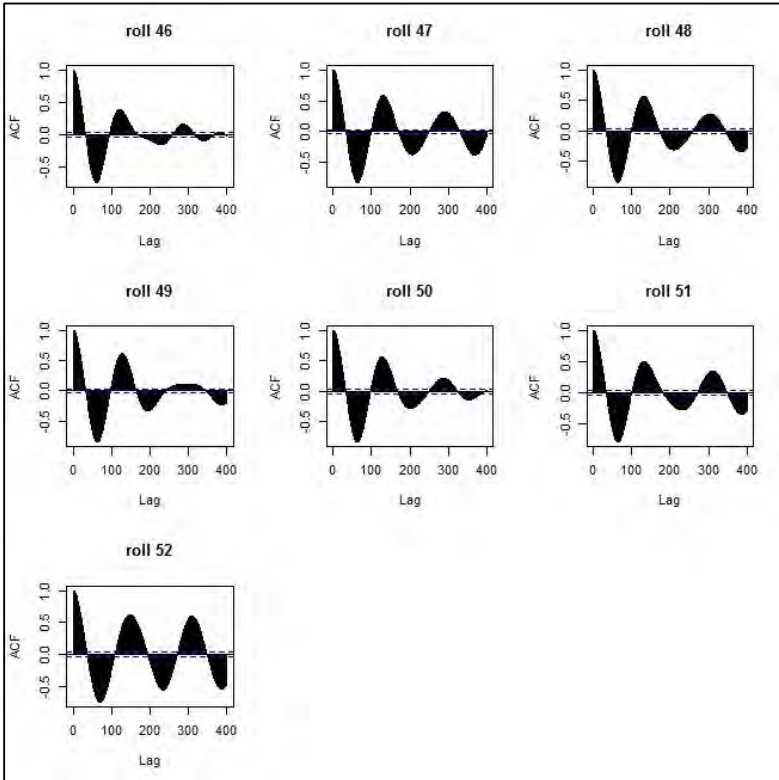
Lampiran 30. Plot ACF Data Gerak *Rolling* Partisi 19 sampai 27

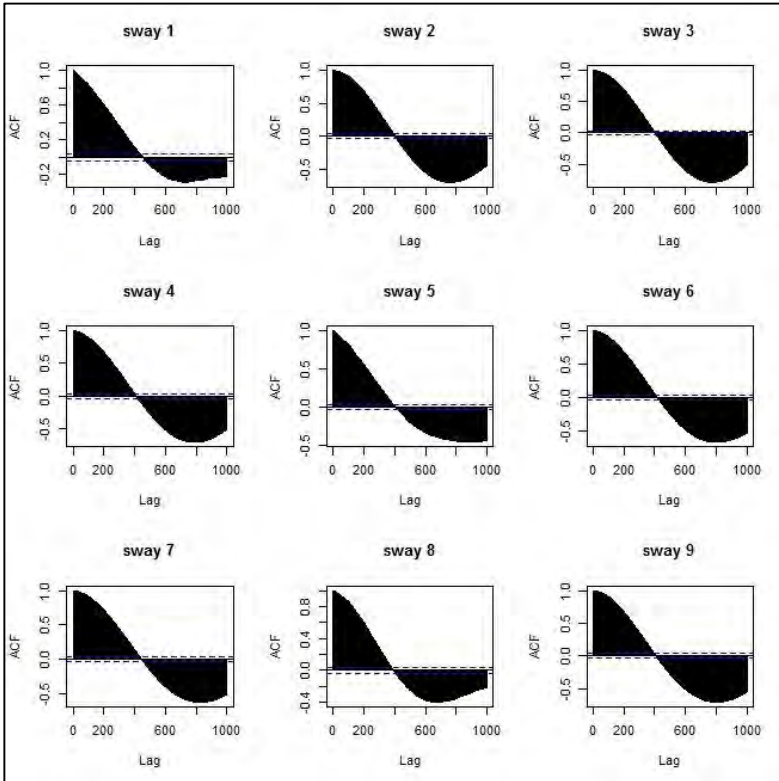
Lampiran 31. Plot ACF Data Gerak *Rolling* Partisi 28 sampai 36



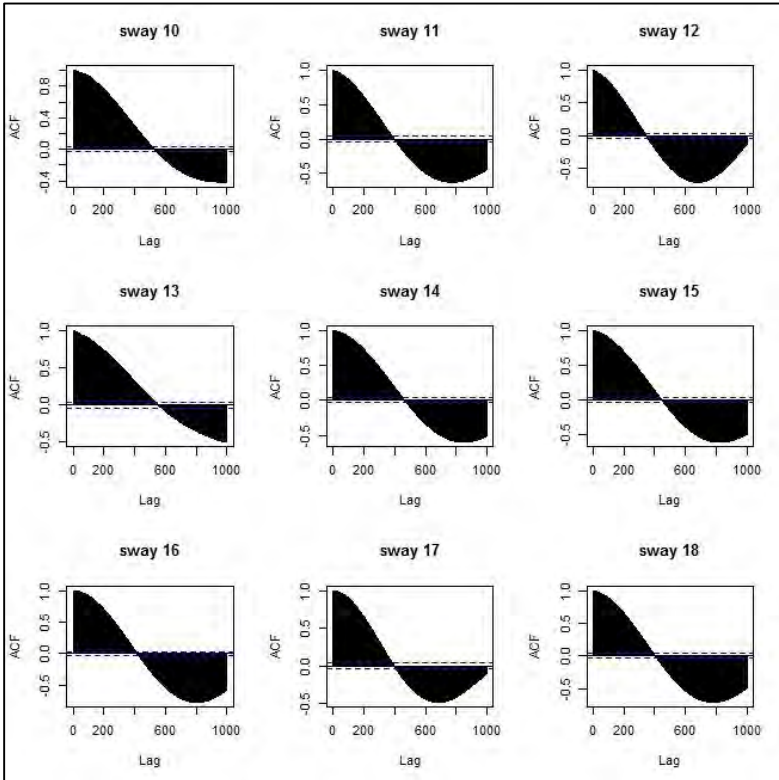
Lampiran 32. Plot ACF Data Gerak *Rolling Partisi 37* sampai 45

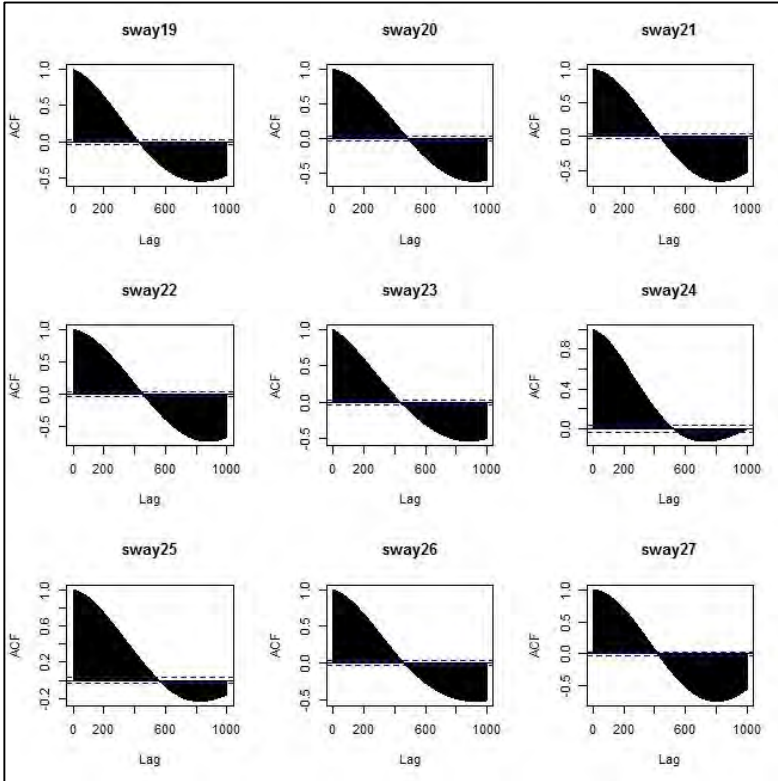
Lampiran 33. Plot ACF Data Gerak *Rolling* Partisi 46 sampai 52



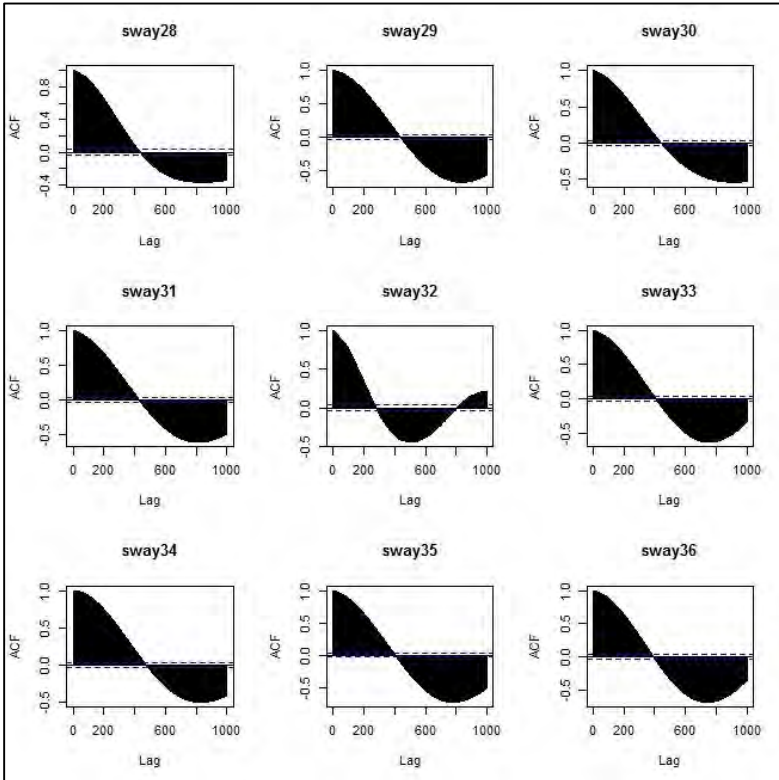
Lampiran 34. Plot ACF Data Gerak *Swaying* Partisi 1 sampai 9

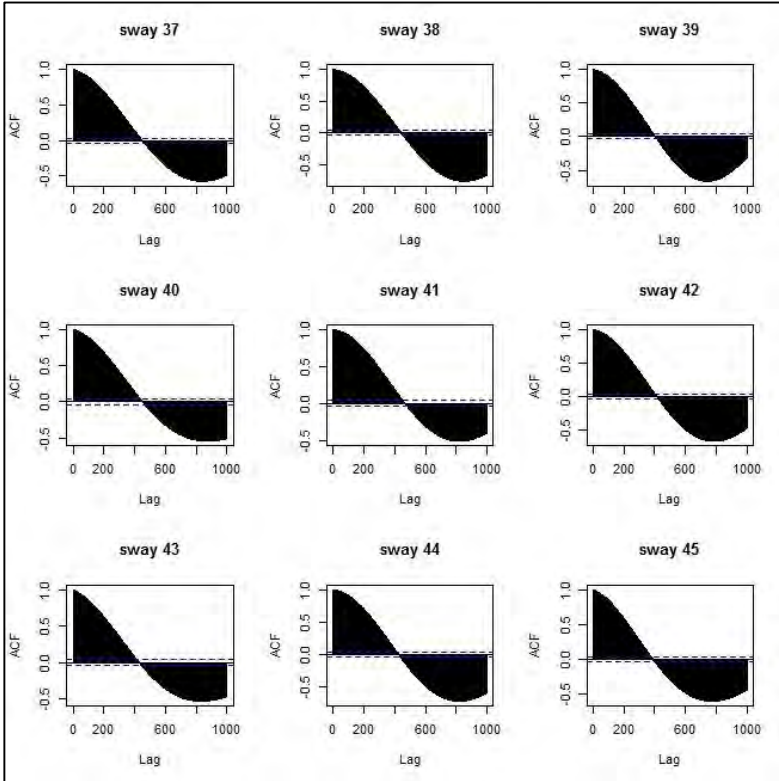
Lampiran 35. Plot ACF Data Gerak Swaying Partisi 10 sampai 18



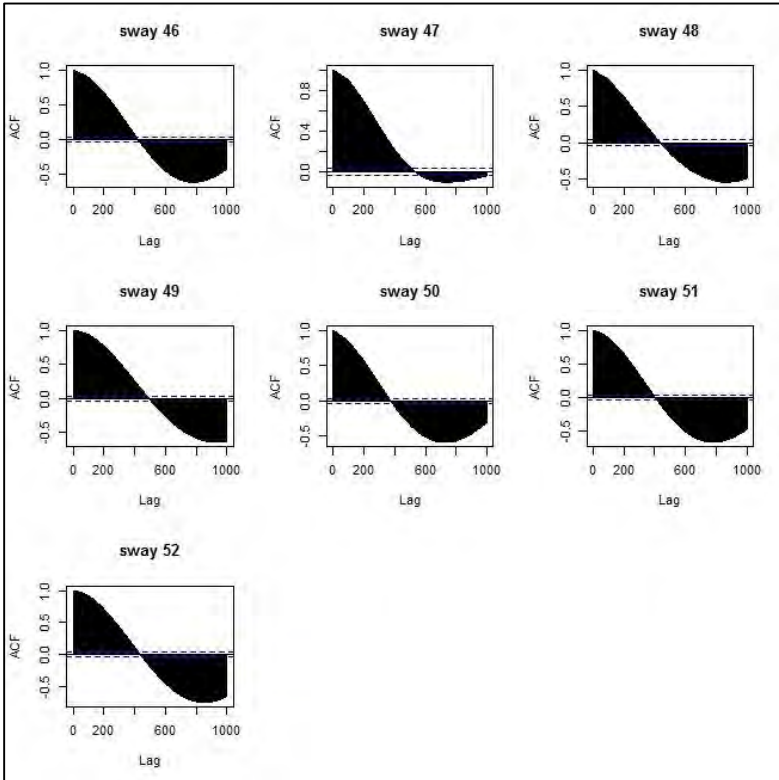
Lampiran 36. Plot ACF Data Gerak *Swaying* Partisi 19 sampai 27

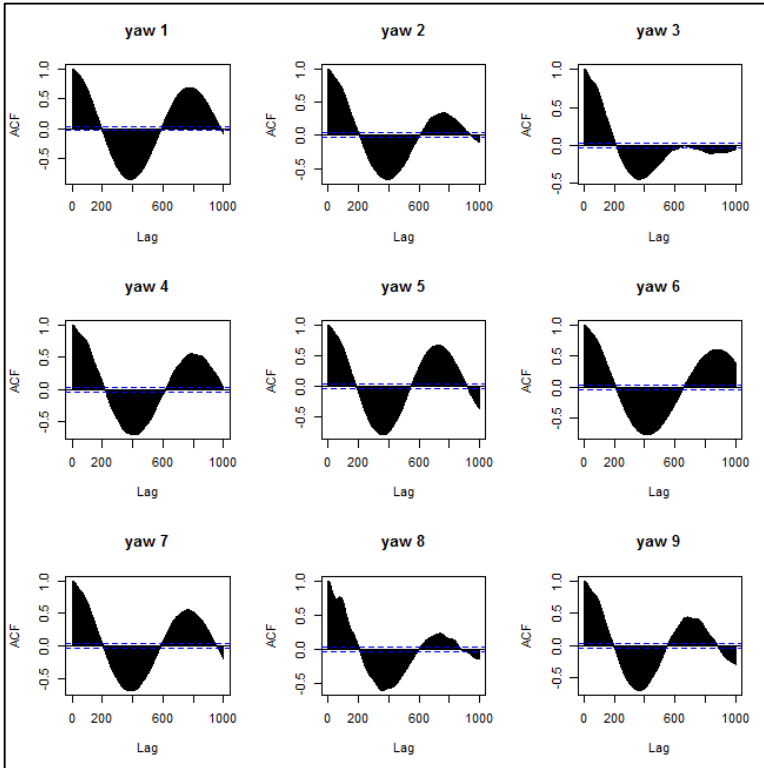
Lampiran 37. Plot ACF Data Gerak *Swaying* Partisi 28 sampai 36



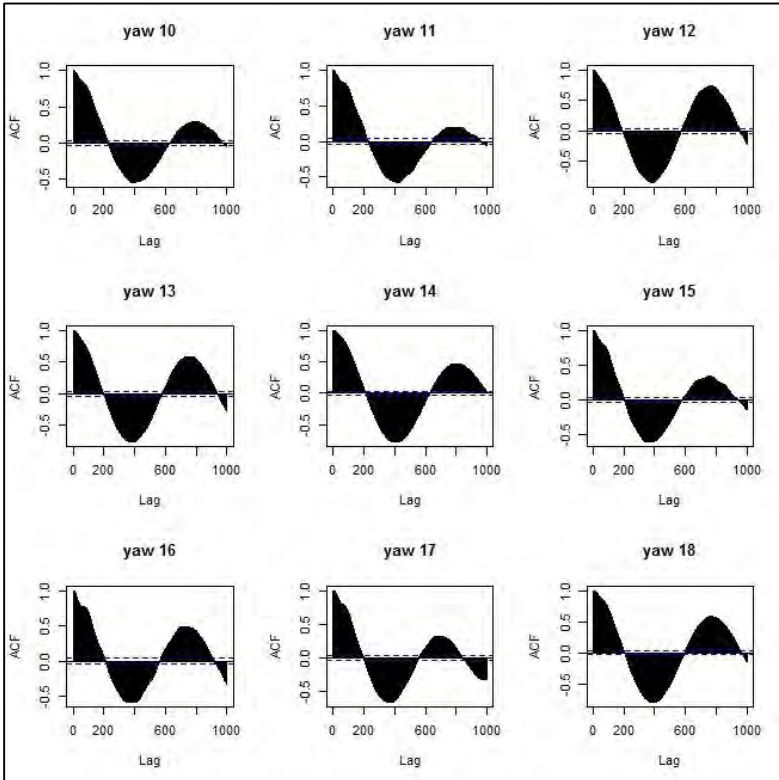
Lampiran 38. Plot ACF Data Gerak *Swaying* Partisi 37 sampai 45

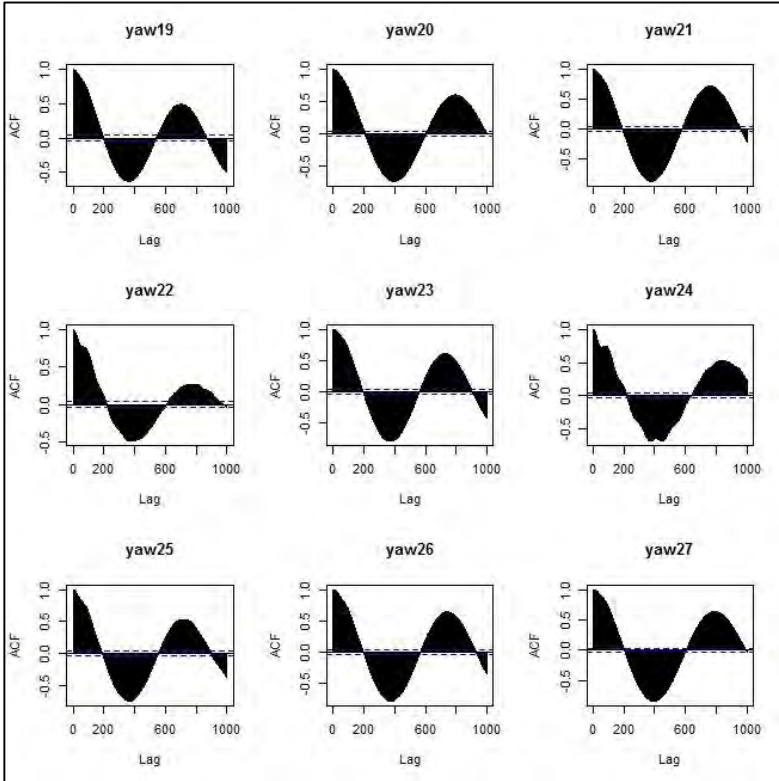
Lampiran 39. Plot ACF Data Gerak *Swaying* Partisi 46 sampai 52



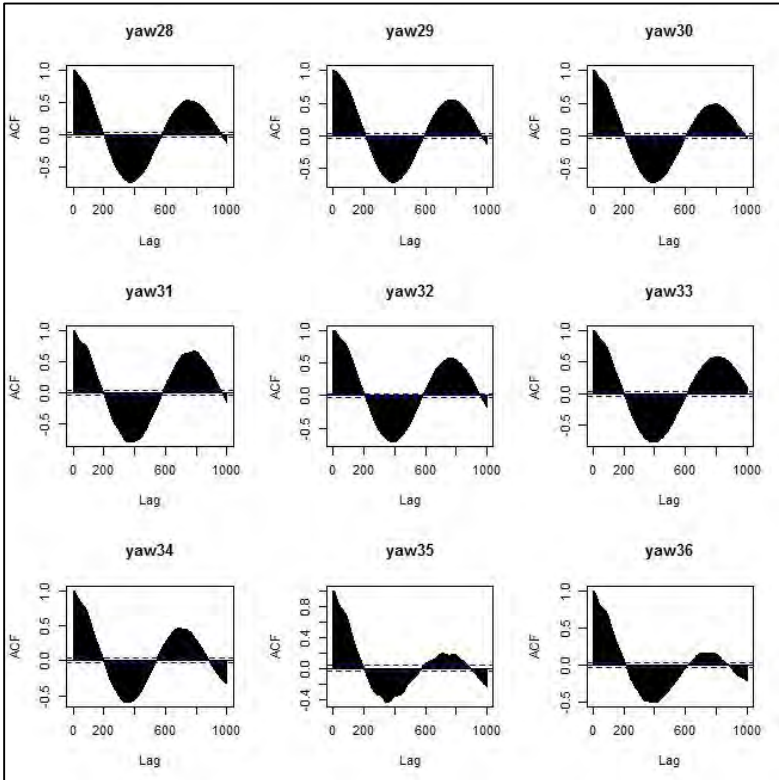
Lampiran 40. Plot ACF Data Gerak *Yawing* Partisi 1 sampai 9

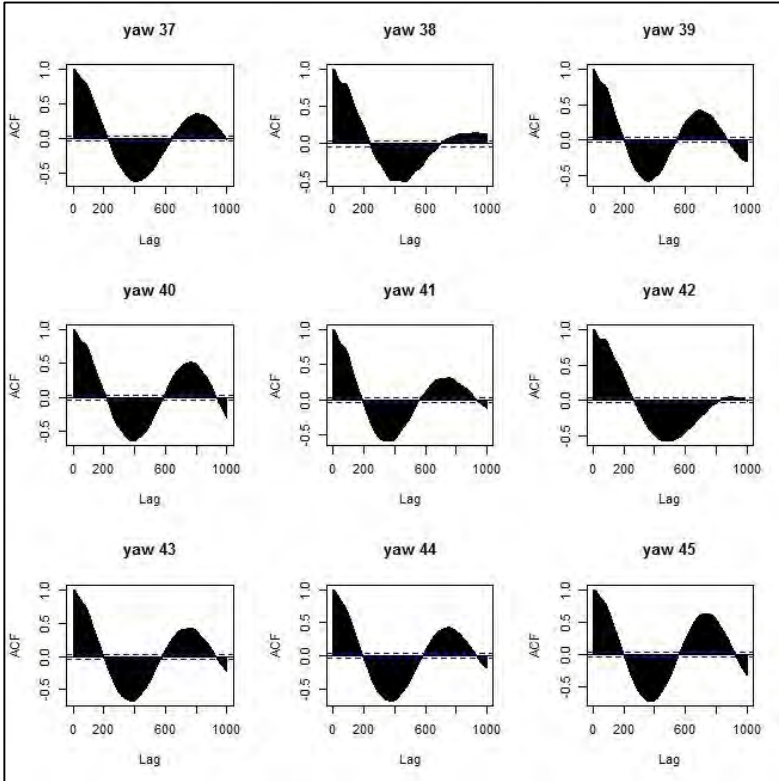
Lampiran 41. Plot ACF Data Gerak *Yawing* Partisi 10 sampai 18



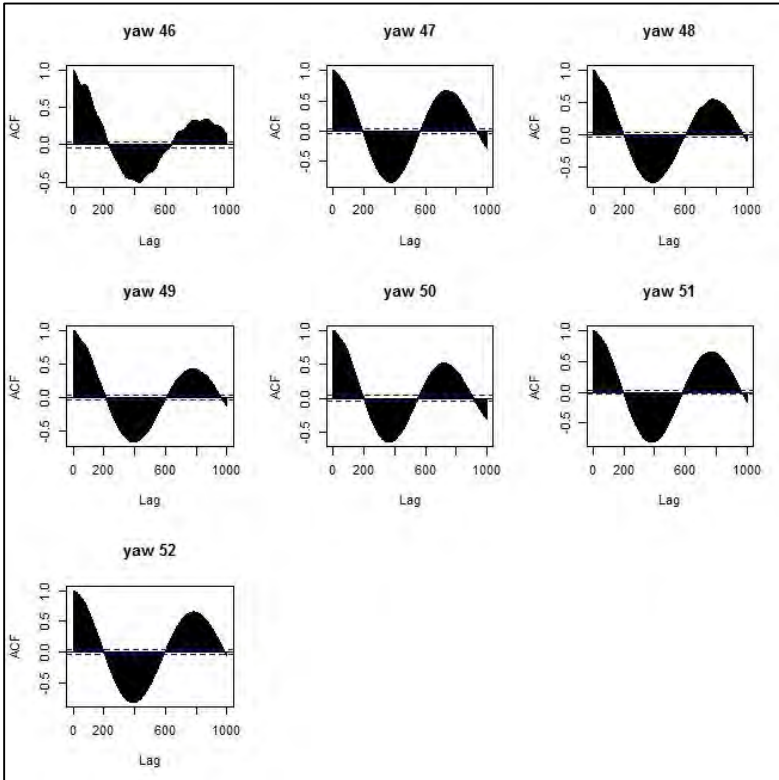
Lampiran 42. Plot ACF Data Gerak *Yawing* Partisi 19 sampai 27


Lampiran 43. Plot ACF Data Gerak *Yawing* Partisi 28 sampai 36



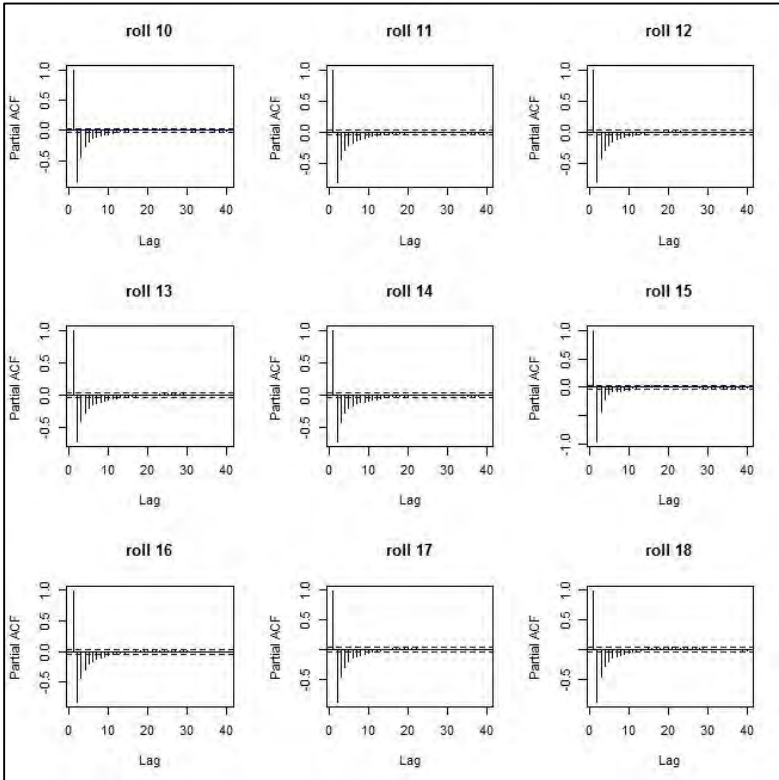
Lampiran 44. Plot ACF Data Gerak *Yawing* Partisi 37 sampai 45

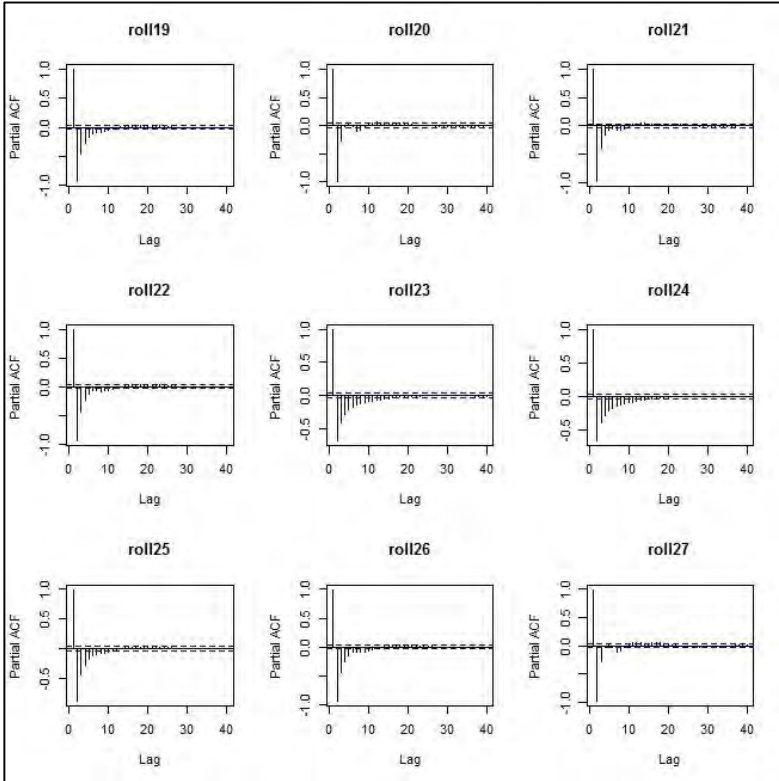
Lampiran 45. Plot ACF Data Gerak *Yawing* Partisi 46 sampai 52



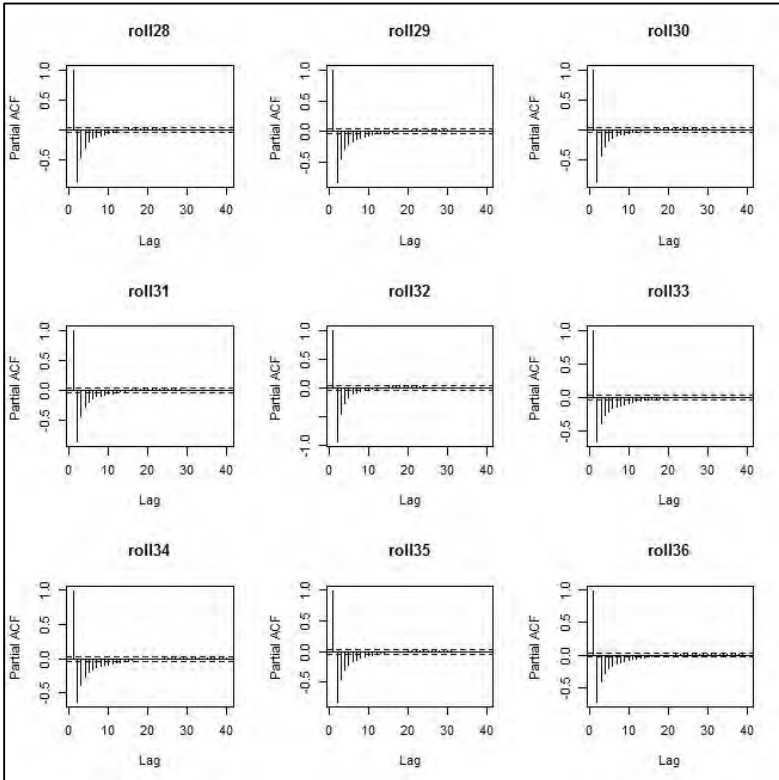
Lampiran 46. Plot PACF Data Gerak *Rolling* Partisi 1 sampai 9


Lampiran 47. Plot PACF Data Gerak *Rolling* Partisi 10 sampai 18



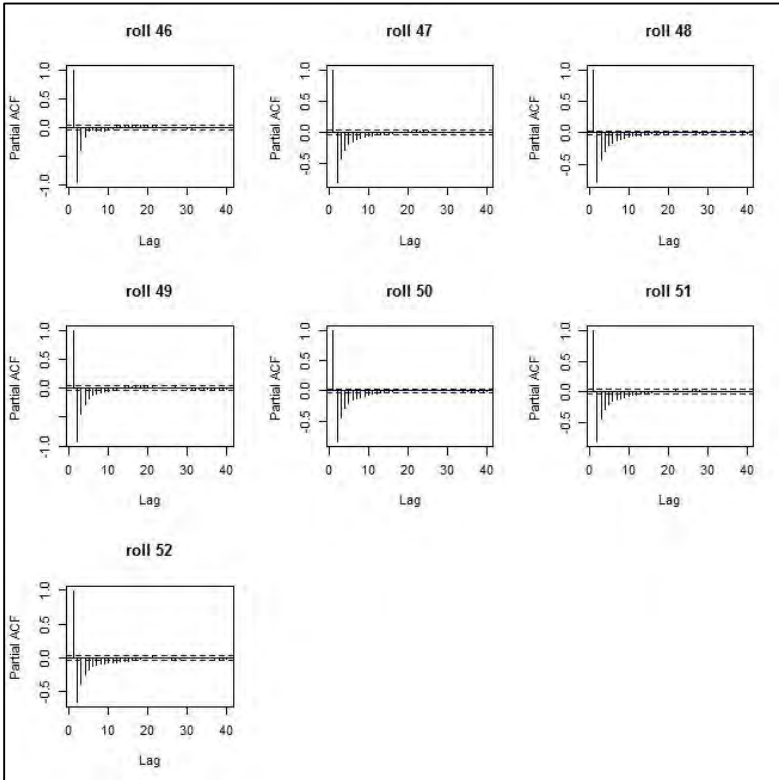
Lampiran 48. Plot PACF Data Gerak *Rolling* Partisi 19 sampai 27

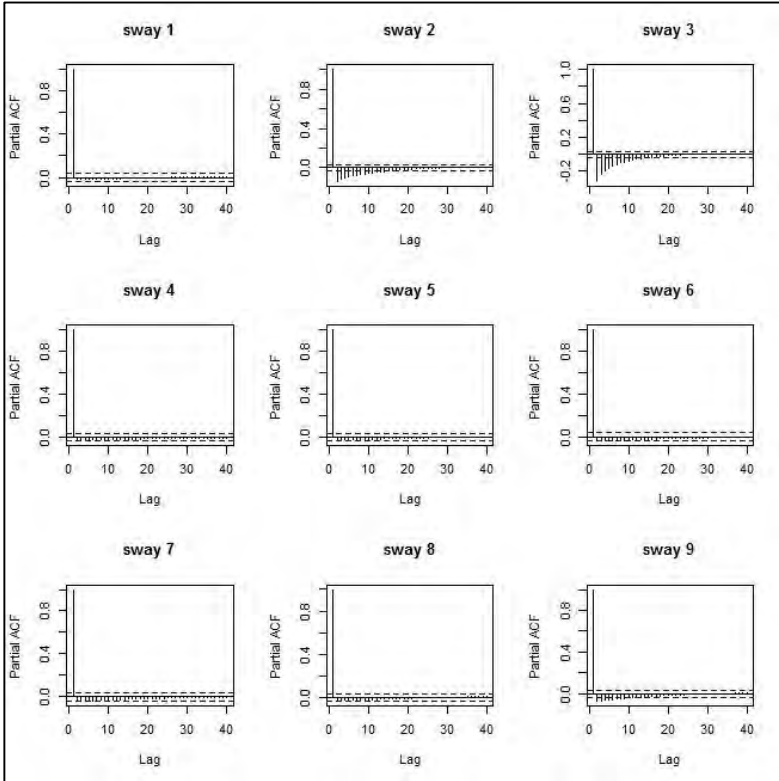
Lampiran 49. Plot PACF Data Gerak *Rolling* Partisi 28 sampai 36

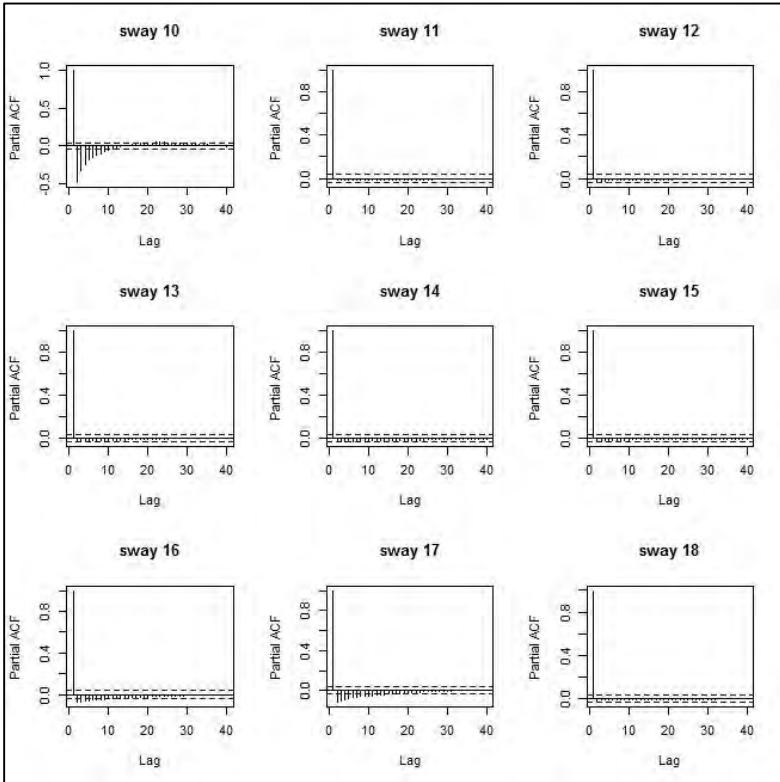


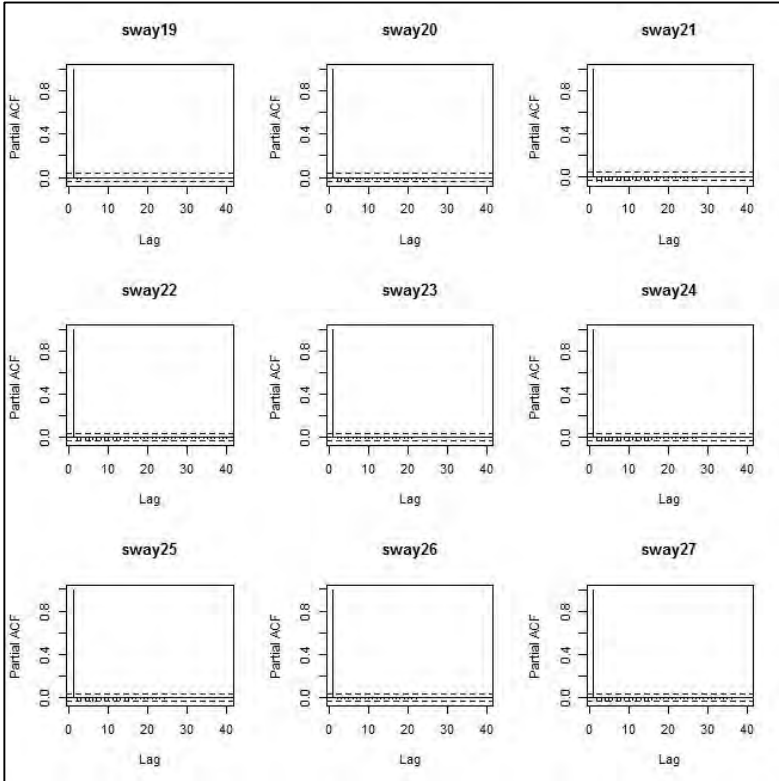
Lampiran 50. Plot PACF Data Gerak *Rolling* Partisi 37 sampai 45

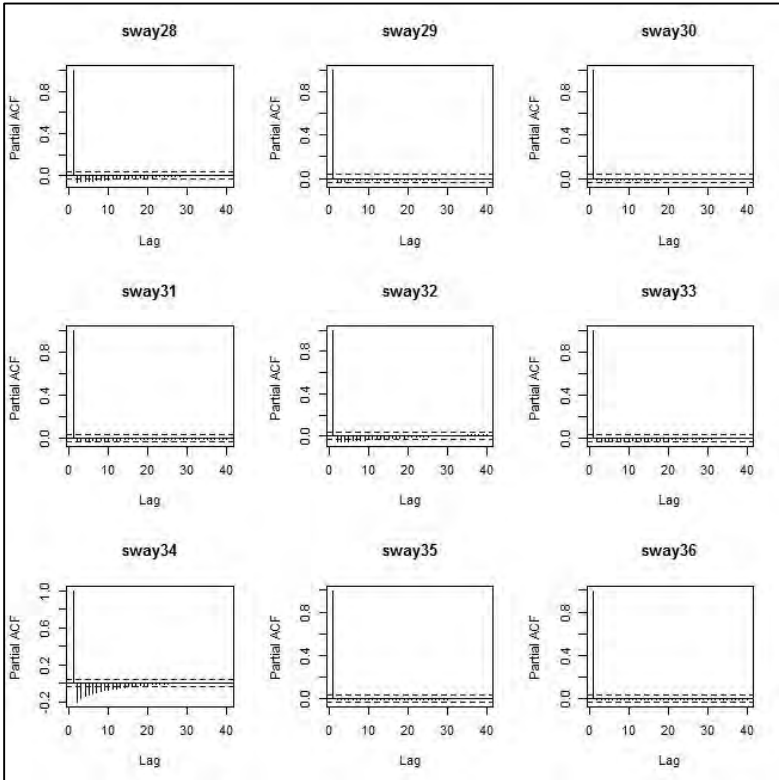
Lampiran 51. Plot PACF Data Gerak *Rolling* Partisi 46 sampai 52

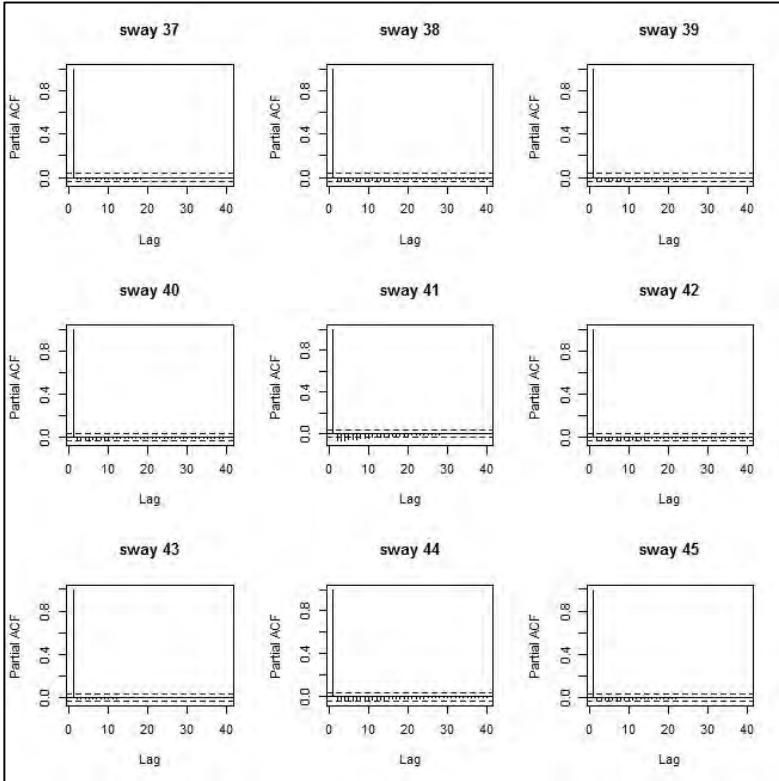


Lampiran 52. Plot PACF Data Gerak *Swaying* Partisi 1 sampai 9

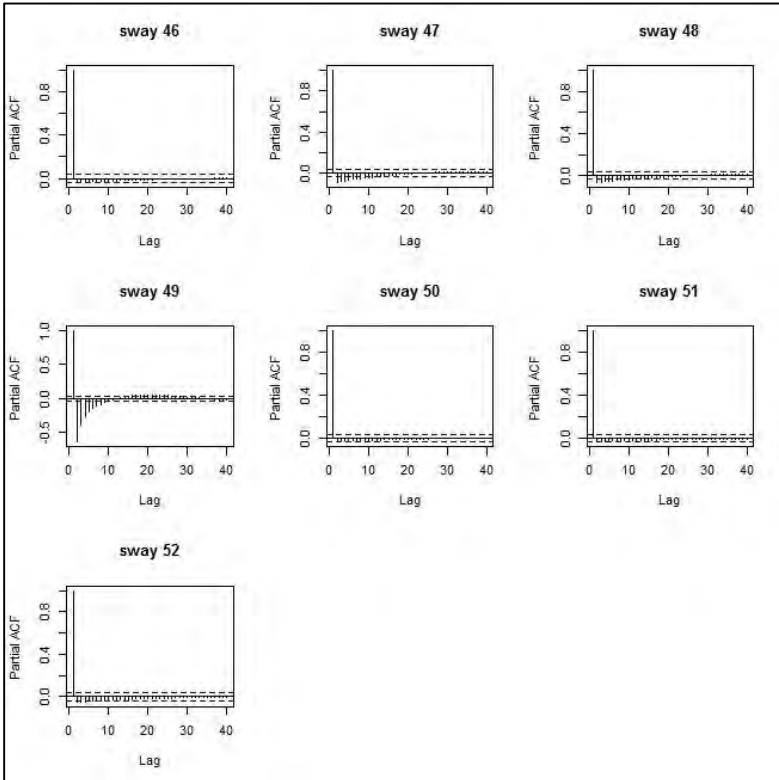
Lampiran 53. Plot PACF Data Gerak *Swaying* Partisi 10 sampai 18

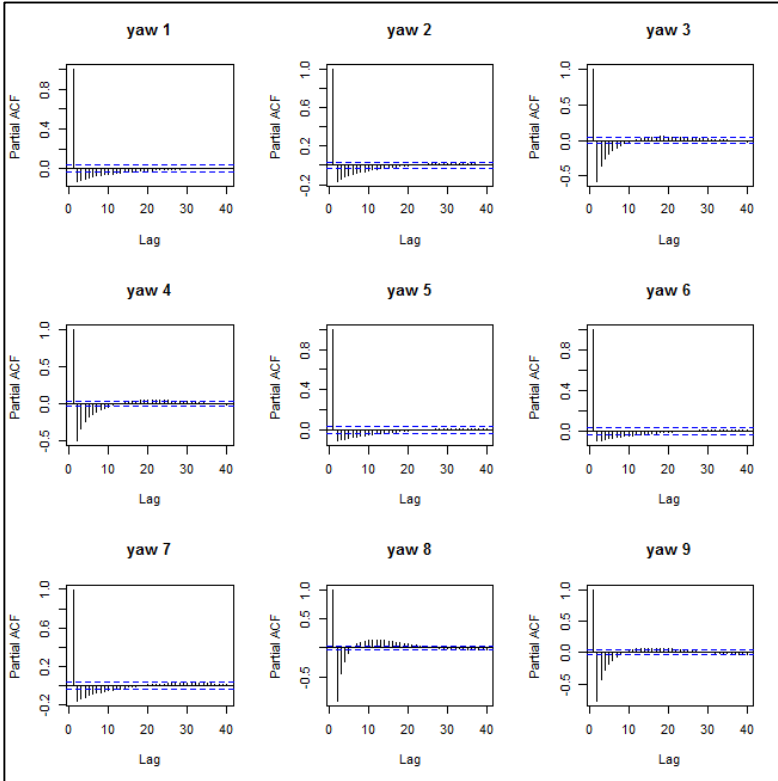
Lampiran 54. Plot PACF Data Gerak *Swaying* Partisi 19 sampai 27

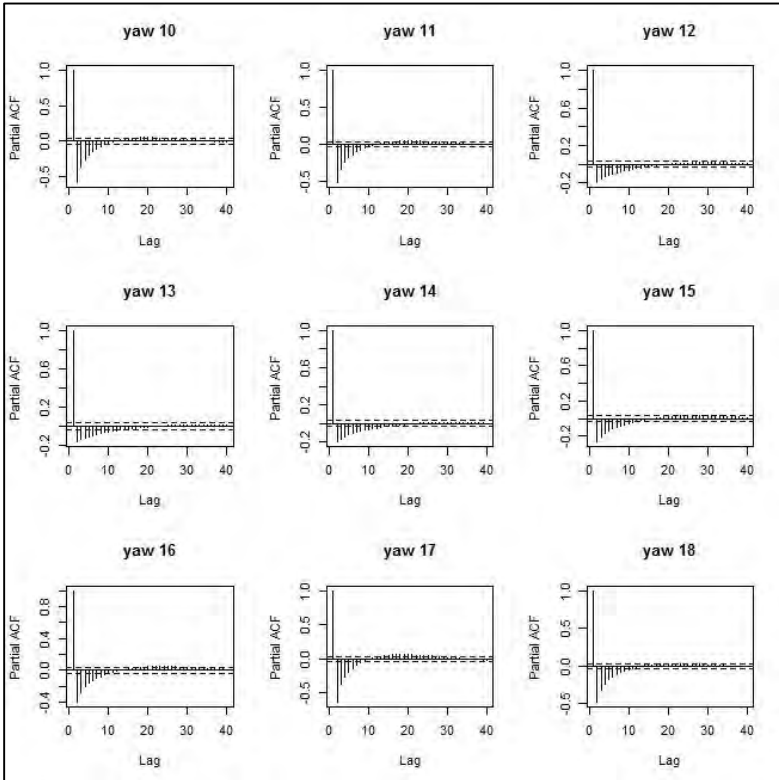
Lampiran 55. Plot PACF Data Gerak *Swaying* Partisi 28 sampai 36

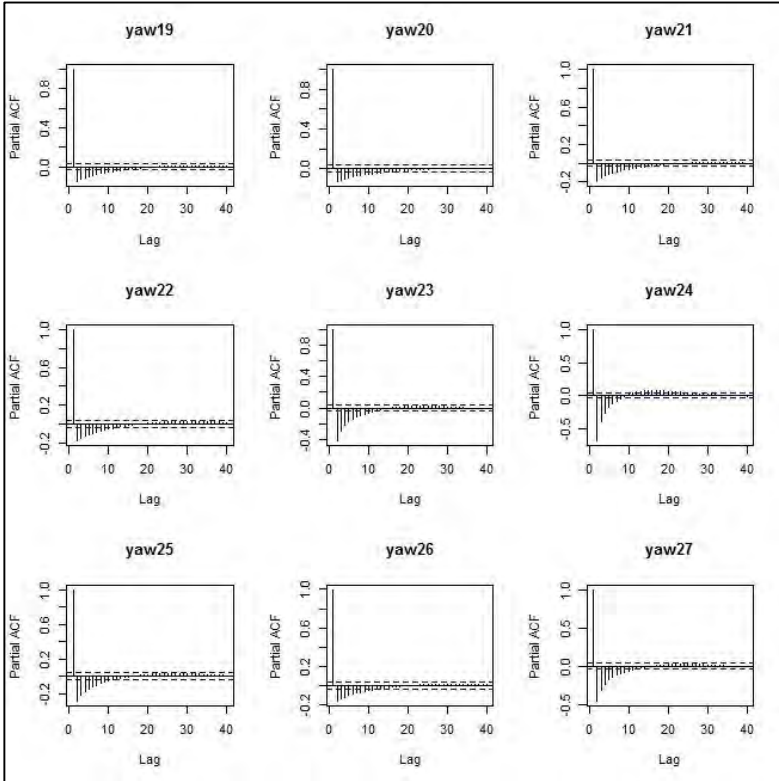
Lampiran 56. Plot PACF Data Gerak *Swaying* Partisi 37 sampai 45

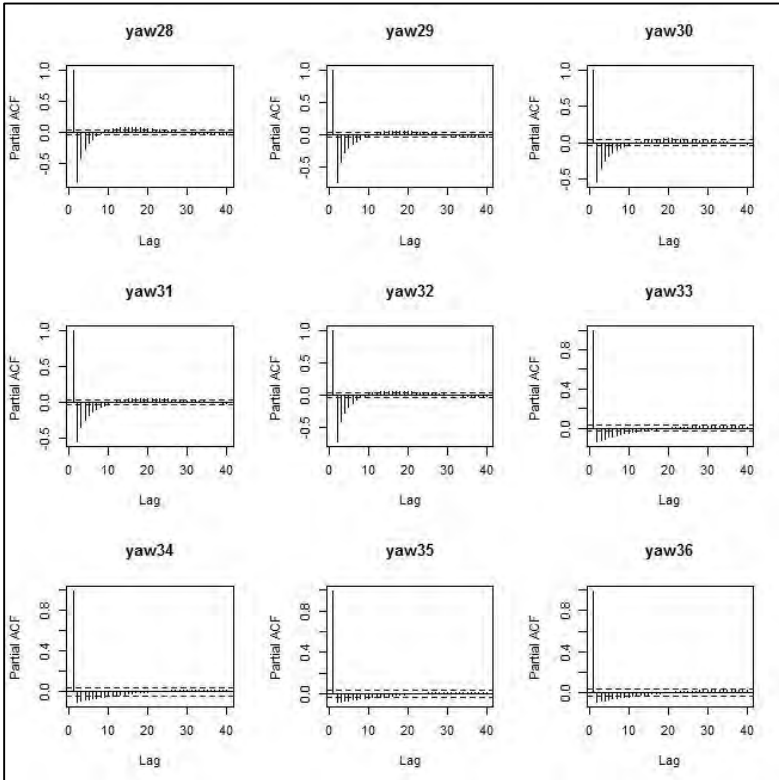
Lampiran 57. Plot PACF Data Gerak *Swaying* Partisi 46 sampai 52

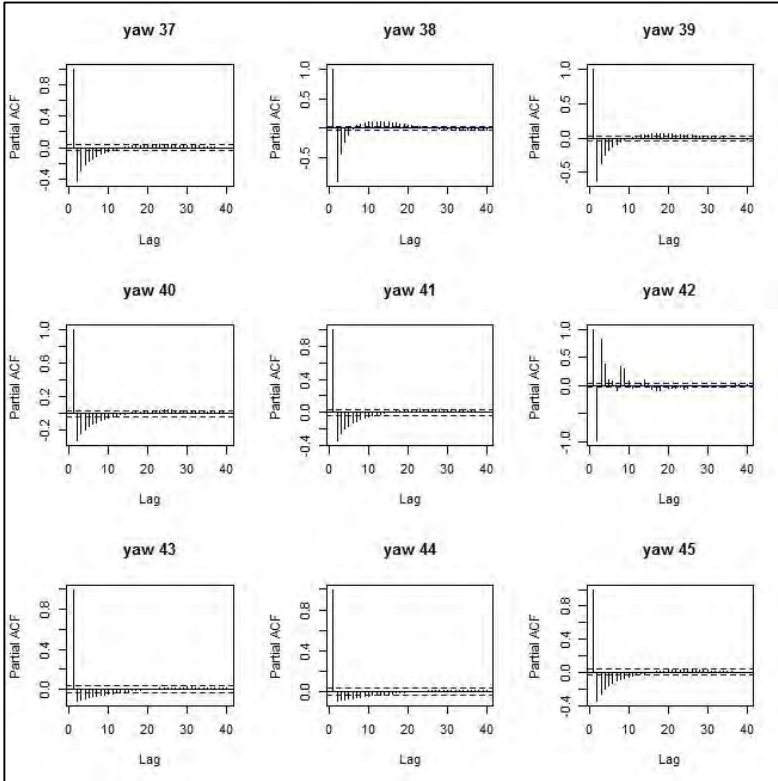


Lampiran 58. Plot PACF Data Gerak *Yawing* Partisi 10 sampai 18

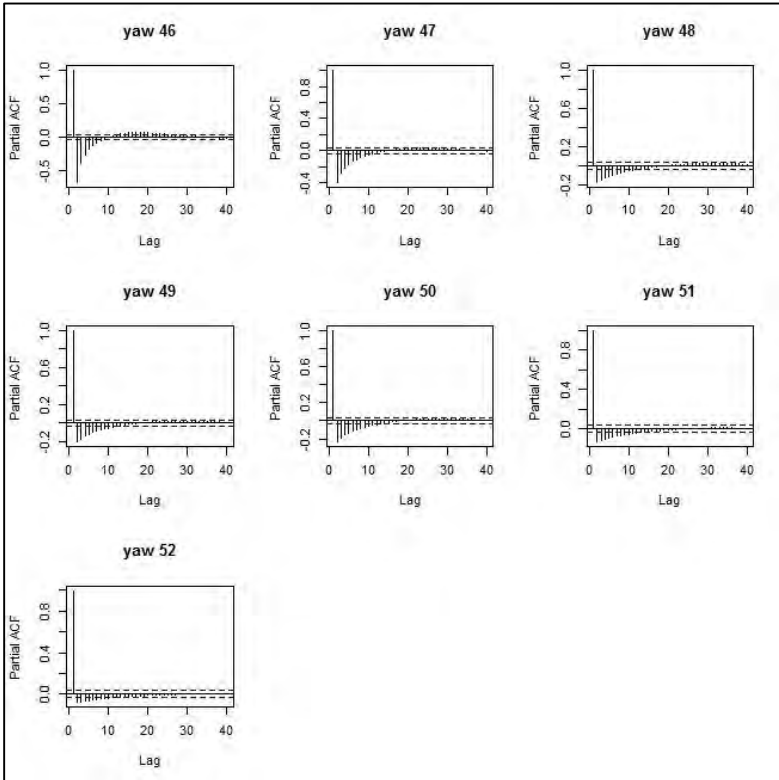
Lampiran 59. Plot PACF Data Gerak *Yawing* Partisi 10 sampai 18

Lampiran 60. Plot PACF Data Gerak *Yawing* Partisi 19 sampai 27

Lampiran 61. Plot PACF Data Gerak *Yawing* Partisi 28 sampai 36

Lampiran 62. Plot PACF Data Gerak *Yawing* Partisi 37 sampai 45

Lampiran 63. Plot PACF Data Gerak *Yawing* Partisi 46 sampai 52



Lampiran 64. Output SAS Pemodelan ARIMA Data Gerak Rolling

```

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter      Estimate      Standard      t Value      Pr > |t|      Lag
                Error
MA1,1          -0.09983      0.02535      -3.94        <.0001        19
AR1,1          1.30286      0.01818      71.66        <.0001         1
AR1,2         -0.08383      0.02987      -2.81        0.0050         2
AR1,3         -0.07943      0.02991      -2.66        0.0080         3
AR1,4         -0.08749      0.02186      -4.00        <.0001         4
AR1,5         -0.04640      0.0081169    -5.72        <.0001         9
AR1,6         -0.12946      0.02671      -4.85        <.0001        19
AR1,7          0.11744      0.02394      4.91         <.0001        20

Variance Estimate      0.000022
Std Error Estimate     0.004655
AIC                    -23696.7
SBC                    -23648.6
Number of Residuals    3000
* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To      Chi-      Pr >
Lag     Square   ChiSq  -----Autocorrelations-----
6       .         0      -0.002 -0.005 -0.007 0.019 -0.007 -0.010
12      7.79     4      0.0994 -0.015 -0.019 0.020 0.023 0.018 0.013
18      9.53    10     0.4823 0.009 0.005 0.002 -0.001 -0.007 -0.020
24     10.35    16     0.8478 0.000 0.011 0.008 0.008 0.004 0.001
30     13.43    22     0.9205 -0.003 -0.005 -0.010 -0.018 -0.018 -0.015
36     15.03    28     0.9781 -0.015 -0.013 -0.004 0.001 0.005 0.009
42     15.64    34     0.9970 0.014 0.003 -0.000 -0.001 -0.000 -0.000
48     17.03    40     0.9995 0.008 0.011 0.009 0.007 0.010 0.008

Model for variable y
No mean term in this model.

Tests for Normality

Test      --Statistic--      ----p Value-----
Kolmogorov-Smirnov  D      0.224834      Pr > D      <0.0100
Cramer-von Mises    W-Sq   69.51558      Pr > W-Sq   <0.0050
Anderson-Darling    A-Sq   394.3711      Pr > A-Sq   <0.0050

```


Lampiran 65. Output SAS Pemodelan ARIMA Data Gerak Swaying

The ARIMA Procedure					
Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	-0.13568	0.02222	-6.11	<.0001	2
MA1,2	0.09684	0.02489	3.89	0.0001	35
MA1,3	0.05076	0.01925	2.64	0.0084	43
AR1,1	1.56442	0.01612	97.05	<.0001	1
AR1,2	-0.41761	0.02213	-18.87	<.0001	2
AR1,3	-0.18064	0.03011	-6.00	<.0001	4
AR1,4	-0.75870	0.03475	-21.83	<.0001	5
AR1,5	1.16415	0.02843	40.95	<.0001	6
AR1,6	-0.15375	0.02958	-5.20	<.0001	8
AR1,7	-0.29479	0.04327	-6.81	<.0001	9
AR1,8	-0.38931	0.04127	-9.43	<.0001	10
AR1,9	0.55579	0.04006	13.87	<.0001	11
AR1,10	0.33710	0.03481	9.69	<.0001	12
AR1,11	-0.19661	0.04182	-4.70	<.0001	13
AR1,12	-0.40119	0.04294	-9.34	<.0001	14
AR1,13	-0.15930	0.03435	-4.64	<.0001	15
AR1,14	0.30672	0.04111	7.46	<.0001	16
AR1,15	0.44328	0.04210	10.53	<.0001	17
AR1,16	-0.24250	0.04394	-5.52	<.0001	18
AR1,17	-0.43210	0.03630	-11.91	<.0001	19
AR1,18	0.22443	0.03732	6.01	<.0001	21
AR1,19	0.40255	0.04189	9.61	<.0001	22
AR1,20	-0.27701	0.04274	-6.48	<.0001	23
AR1,21	-0.34549	0.03614	-9.56	<.0001	24
AR1,22	0.27940	0.03375	8.28	<.0001	26
AR1,23	0.18608	0.03422	5.44	<.0001	27
AR1,24	-0.14362	0.03486	-4.12	<.0001	28
AR1,25	-0.26330	0.03384	-7.78	<.0001	29
AR1,26	0.24454	0.02605	9.39	<.0001	31
AR1,27	-0.17457	0.02510	-6.96	<.0001	34
AR1,28	0.12080	0.01712	7.06	<.0001	35
Variance Estimate			7.545E-8		
Std Error Estimate			0.000275		
AIC			-40641.5		
SBC			-40455.3		
Number of Residuals			2999		
* AIC and SBC do not include log determinant.					

Lampiran 65. (Lanjutan) Output SAS Pemodelan ARIMA Data Gerak *Swaying*

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	0.007	0.003	-0.008	-0.004	-0.008	0.016
12	.	0	.	-0.006	-0.006	-0.008	0.004	0.003	-0.005
18	.	0	.	-0.007	-0.000	0.005	-0.000	-0.006	-0.010
24	.	0	.	-0.004	0.008	-0.002	-0.013	0.001	-0.011
30	.	0	.	0.012	-0.014	-0.004	-0.008	0.011	-0.002
36	9.29	5	0.0979	-0.019	-0.004	-0.013	-0.006	-0.003	-0.028
42	13.85	11	0.2417	-0.018	-0.003	-0.015	-0.007	-0.030	-0.001
48	20.91	17	0.2305	-0.007	0.022	-0.041	-0.008	-0.006	0.005

Model for variable y

Period(s) of Differencing 1

No mean term in this model.


Tests for Normality

Test	--Statistic--	----p Value-----	
Kolmogorov-Smirnov	D 0.016586	Pr > D	0.0444
Cramer-von Mises	W-Sq 0.137673	Pr > W-Sq	0.0367
Anderson-Darling	A-Sq 0.920461	Pr > A-Sq	0.0206


Lampiran 66. Output SAS Pemodelan ARIMA Data Gerak Yawing

The ARIMA Procedure										
Conditional Least Squares Estimation										
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag					
MA1,1	0.15606	0.04747	3.29	0.0010	7					
MA1,2	0.06856	0.01959	3.50	0.0005	16					
AR1,1	1.23515	0.01143	108.07	<.0001	1					
AR1,2	-0.10414	0.02437	-4.27	<.0001	3					
AR1,3	-0.12952	0.02775	-4.67	<.0001	4					
AR1,4	-0.19466	0.02779	-7.00	<.0001	5					
AR1,5	0.23869	0.02845	8.39	<.0001	6					
AR1,6	0.24318	0.05249	4.63	<.0001	7					
AR1,7	-0.26394	0.04814	-5.48	<.0001	8					
AR1,8	-0.07863	0.01950	-4.03	<.0001	17					
AR1,9	0.04584	0.02116	2.17	0.0303	18					
AR1,10	-0.03334	0.0096465	-3.46	0.0006	22					
AR1,11	0.03762	0.0041895	8.98	<.0001	29					
	Variance Estimate		4.58E-8							
	Std Error Estimate		0.000214							
	AIC		-42156							
	SBC		-42077.9							
	Number of Residuals		2999							
	* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals										
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	.	0	.	-0.009	0.005	0.005	-0.002	-0.010	-0.004	
12	.	0	.	0.002	0.017	-0.008	-0.018	0.007	0.020	
18	7.43	5	0.1907	0.001	-0.013	-0.019	0.003	0.000	-0.023	
24	10.42	11	0.4933	-0.007	-0.019	0.020	-0.006	-0.001	-0.012	
30	12.18	17	0.7890	-0.003	-0.015	0.018	-0.001	0.006	0.003	
36	17.97	23	0.7593	-0.017	-0.032	-0.001	-0.021	0.004	-0.010	
42	19.72	29	0.9015	0.000	-0.003	-0.013	0.011	-0.009	0.014	
48	22.03	35	0.9569	-0.017	-0.014	-0.007	-0.008	-0.012	0.004	
	Model for variable y									
	Period(s) of Differencing 1									
	No mean term in this model.									
Tests for Normality										
Test	--Statistic--		----p Value-----							
Kolmogorov-Smirnov	D	0.079411	Pr > D	<0.0100						
Cramer-von Mises	W-Sq	9.104049	Pr > W-Sq	<0.0050						
Anderson-Darling	A-Sq	65.8202	Pr > A-Sq	<0.0050						


Lampiran 67. Hasil Peramalan Data *Out-of-Sample* Gerak *Rolling* dengan Model ARIMA Menggunakan Metode *k-Step Forecast*



Lampiran 68. Hasil Peramalan Data *Out-of-Sample* Gerak *Swaying* dengan Model ARIMA Menggunakan Metode *k-Step Forecast*




Lampiran 69. Hasil Peramalan Data *Out-of-Sample* Gerak *Rolling* dengan Model ARIMA Menggunakan Metode *k-Step Forecast*




Lampiran 70. Output SAS Pemodelan VAR (1)

The VARMAX Procedure						
Type of Model			VAR(1)			
Estimation Method			Least Squares Estimation			
AR Coefficient Estimates						
Lag	Variable	roll	sway	yaw		
1	roll	0.99883	-0.00005206	0.00269		
	sway	-0.00665	0.99993	-0.00050439		
	yaw	-0.00344	0.00002916	0.99992		
Model Parameter Estimates						
Equation	Parameter	Estimate	Std Error	T Ratio	Prob> T	Variable
roll	AR1_1_1	0.99883	0.00090010	999.00	0.0001	roll(t-1)
	AR1_1_2	-0.00005206	0.00005918	-0.88	0.3791	sway(t-1)
	AR1_1_3	0.00269	0.00077596	3.47	0.0005	yaw(t-1)
sway	AR1_2_1	-0.00665	0.00085675	-7.76	0.0001	roll(t-1)
	AR1_2_2	0.99993	0.00005633	999.00	0.0001	sway(t-1)
	AR1_2_3	-0.00050439	0.00073859	-0.68	0.4947	yaw(t-1)
yaw	AR1_3_1	-0.00344	0.00026746	-12.86	0.0001	roll(t-1)
	AR1_3_2	0.00002916	0.00001759	1.66	0.0974	sway(t-1)
	AR1_3_3	0.99992	0.00023057	999.00	0.0001	yaw(t-1)
Information Criteria						
AICC(Corrected AIC)				-27.596500		
HQIC(Hannan-Quinn Criterion)				-27.590000		
AIC(Akaike Information Criterion)				-27.596500		
SBC(Schwarz Bayesian Criterion)				-27.578500		
FPEC(Final Prediction Error Criterion)				1.04E-12		
Portmanteau Test for Residual Cross Correlations						
To Lag	Chi-Square	DF	Prob> ChiSq			
2	9999.99	9	<.0001			
3	9999.99	18	<.0001			
4	9999.99	27	<.0001			
5	9999.99	36	<.0001			
6	9999.99	45	<.0001			
7	9999.99	54	<.0001			
8	9999.99	63	<.0001			
.....			
68	9999.99	603	<.0001			
69	9999.99	612	<.0001			
70	9999.99	621	<.0001			
71	9999.99	630	<.0001			
72	9999.99	639	<.0001			


Lampiran 71. Hasil Peramalan Data *Out-of-Sample* dengan Model VAR (1) Menggunakan Metode *k-Step Forecast*




Lampiran 72. Arsitektur Model *Hybrid VAR-ANN* dengan 1 unit *neuron* dalam *Hidden Layer*




Lampiran 73. Arsitektur Model *Hybrid VAR-ANN* dengan 2 unit *neuron* dalam *Hidden Layer*




Lampiran 74. Arsitektur Model *Hybrid VAR-ANN* dengan 3 unit *neuron* dalam *Hidden Layer*




Lampiran 75. Arsitektur Model *Hybrid VAR-ANN* dengan 4 unit *neuron* dalam *Hidden Layer*




Lampiran 76. Arsitektur Model *Hybrid VAR-ANN* dengan 5 unit *neuron* dalam *Hidden Layer*




Lampiran 77. Arsitektur Model *Hybrid VAR-ANN* dengan 6 unit *neuron* dalam *Hidden Layer*




Lampiran 78. Arsitektur Model *Hybrid VAR-ANN* dengan 7 unit *neuron* dalam *Hidden Layer*




Lampiran 79. Arsitektur Model *Hybrid VAR-ANN* dengan 8 unit *neuron* dalam *Hidden Layer*



Lampiran 80. Arsitektur Model *Hybrid VAR-ANN* dengan 9 unit *neuron* dalam *Hidden Layer*



Lampiran 81. Arsitektur Model *Hybrid VAR-ANN* dengan 10 unit *neuron* dalam *Hidden Layer*




Lampiran 82. Output Nilai Bobot Optimum dalam Model *Hybrid VAR-ANN* dengan 9 Unit *Neuron* dalam *Hidden Layer*

```

a 3-9-3 network with 66 weights
options were - linear output units  decay=5e-04
b->h1 i1->h1 i2->h1 i3->h1
-0.01 -0.11 -0.34 0.35
b->h2 i1->h2 i2->h2 i3->h2
0.00 1.26 1.14 0.68
b->h3 i1->h3 i2->h3 i3->h3
0.01 0.50 -0.38 -0.41
b->h4 i1->h4 i2->h4 i3->h4
0.00 -0.17 -0.52 0.19
b->h5 i1->h5 i2->h5 i3->h5
-0.02 -0.19 -0.26 -0.56
b->h6 i1->h6 i2->h6 i3->h6
-0.02 0.59 -0.31 -1.02
b->h7 i1->h7 i2->h7 i3->h7
-0.03 -0.65 -0.30 1.08
b->h8 i1->h8 i2->h8 i3->h8
0.00 -1.12 1.34 -0.65
b->h9 i1->h9 i2->h9 i3->h9
0.00 -0.19 -0.38 0.35
b->o1 h1->o1 h2->o1 h3->o1 h4->o1 h5->o1 h6->o1 h7->o1 h8->o1 h9->o1
0.01 -0.11 1.26 0.51 -0.17 -0.20 0.60 -0.64 -1.12 -0.18
b->o2 h1->o2 h2->o2 h3->o2 h4->o2 h5->o2 h6->o2 h7->o2 h8->o2 h9->o2
0.00 -0.36 1.09 -0.35 -0.52 -0.23 -0.26 -0.36 1.37 -0.39
b->o3 h1->o3 h2->o3 h3->o3 h4->o3 h5->o3 h6->o3 h7->o3 h8->o3 h9->o3
0.00 0.34 0.73 -0.43 0.17 -0.58 -1.04 1.06 -0.58 0.33

```

Lampiran 83. Hasil Peramalan Data *Out-of-Sample* dengan Model *Hybrid VAR-ANN* Menggunakan Metode *k-Step Forecast*



Halaman ini sengaja dikosongkan