



**ITS**  
Institut  
Teknologi  
Sepuluh Nopember

TUGAS AKHIR - KS 141501

# **PERBANDINGAN METODE HOLT-WINTER, *GREY* HOLT-WINTER, DAN *HYBRID* HOLT-WINTER *ARTIFICIAL NEURAL NETWORK* PADA PERAMALAN DATA INTERMITEN**

## ***THE COMPARISON OF HOLT-WINTER, GREY HOLT-WINTER, AND HYBRID HOLT-WINTER ARTIFICIAL NEURAL NETWORK METHOD IN INTERMITTENT DATA FORECASTING***

JWALITA GALUH GARINI  
NRP 5214100067

Dosen Pembimbing :  
Wiwik Anggraeni, S.Si., M.Kom.

DEPARTEMEN SISTEM INFORMASI  
Fakultas Teknologi Informasi dan Komunikasi  
Institut Teknologi Sepuluh Nopember  
Surabaya 2018





TUGAS AKHIR - KS 141501

# PERBANDINGAN METODE HOLT-WINTER, *GREY* HOLT-WINTER, DAN *HYBRID* HOLT-WINTER ARTIFICIAL NEURAL NETWORK PADA PERAMALAN DATA INTERMITEN

JWALITA GALUH GARINI  
NRP 5214100067

Dosen Pembimbing :  
Wiwik Anggraeni, S.Si., M.Kom.

DEPARTEMEN SISTEM INFORMASI  
Fakultas Teknologi Informasi dan Komunikasi  
Institut Teknologi Sepuluh Nopember  
Surabaya 2018



**ITS**  
Institut  
Teknologi  
Sepuluh Nopember

**FINAL PROJECT - KS 141501**

***THE COMPARISON OF HOLT-WINTER, GREY HOLT-WINTER, AND HYBRID HOLT-WINTER ARTIFICIAL NEURAL NETWORK METHOD IN INTERMITTENT DATA FORECASTING***

**JWALITA GALUH GARINI**  
NRP 5214100067

**SUPERVISOR:**  
Wiwik Anggraeni, S.Si., M.Kom.

**DEPARTMENT OF INFORMATION SYSTEMS**  
Faculty of Information Technology and Communication  
Institut Teknologi Sepuluh Nopember  
Surabaya 2018

## LEMBAR PENGESAHAN

### PERBANDINGAN METODE HOLT-WINTER, *GREY* HOLT-WINTER, DAN *HYBRID* HOLT-WINTER *ARTIFICIAL NEURAL NETWORK* PADA PERAMALAN DATA INTERMITEN

#### TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Komputer  
pada

Departemen Sistem Informasi  
Fakultas Teknologi Informasi dan Komunikasi  
Institut Teknologi Sepuluh Nopember

Oleh:

**JWALITA GALUH GARINI**

**NRP. 5214100067**

Surabaya, 16 Januari 2018

**PLH KEPALA  
DEPARTEMEN SISTEM INFORMASI**

**Edwin Riksakomara, S.Kom., M.T.**

**NIP. 19690725 200312 1 001**



## LEMBAR PERSETUJUAN

### PERBANDINGAN METODE HOLT-WINTER, *GREY* HOLT-WINTER, DAN *HYBRID* HOLT-WINTER ARTIFICIAL NEURAL NETWORK PADA PERAMALAN DATA INTERMITEN

#### TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Komputer  
pada  
Departemen Sistem Informasi  
Fakultas Teknologi Informasi dan Komunikasi  
Institut Teknologi Sepuluh Nopember  
Oleh :

**JWALITA GALUH GARINI**  
**NRP. 0521144000067**

Disetujui Tim Penguji : Tanggal Ujian : 12 Januari 2018  
Periode Wisuda : Maret 2018

**Wiwik Anggraeni, S.Si., M.Kom.**

**Ahmad Mukhlason, S.Kom., M.Sc.**

**Faizal Mahananto, S.Kom., M.Eng., Ph.D.**

  
(Pembimbing I)

  
(Penguji I)

  
(Penguji II)

**PERBANDINGAN METODE HOLT-WINTER, *GREY*  
HOLT-WINTER, DAN *HYBRID* HOLT-WINTER  
ARTIFICIAL NEURAL NETWORK PADA  
PERAMALAN DATA INTERMITEN**

**Nama Mahasiswa** : Jwalita Galuh Garini  
**NRP** : 5214100067  
**Jurusan** : Sistem Informasi FTIK-ITS  
**Pembimbing 1** : Wiwik Anggraeni, S.Si., M.Kom.

**ABSTRAK**

*Peramalan menjadi hal yang dibutuhkan dalam banyak situasi. Tiap peramalan memiliki tingkat kesulitan yang berbeda, bergantung pada beberapa faktor, salah satunya adalah data. Pada banyak kasus nyata, data deret waktu untuk peramalan tidak selalu bagus, misalnya data bersifat intermiten yaitu memiliki proporsi nilai nol yang besar. Ini menjadi masalah yang biasanya dihadapi oleh banyak bidang penelitian dan perusahaan. Sehingga penting untuk mengetahui metode peramalan yang bekerja baik untuk data intermiten mengingat data jenis ini sering ditemui pada kasus nyata seperti pada data persediaan, penjualan, pengiriman, impor, dan data lainnya dimana permintaan untuk item tertentu bersifat tidak teratur.*

*Metode yang banyak digunakan pada penelitian peramalan data intermiten adalah Exponential Smoothing. Metode tersebut banyak digunakan pada industri karena dianggap cepat, murah, dan menghasilkan peramalan yang mendekati kenyataan. Kombinasi metode peramalan secara luas dapat menguntungkan, menghasilkan perkiraan yang lebih akurat, sekaligus mengurangi varians dari residu. Untuk itu, dalam tugas akhir ini digunakan Holt-Winter dan modifikasi Holt-Winter berupa Grey Holt-Winter dan Holt-Winter Artificial Neural Network untuk meramalkan data yang bersifat intermiten.*

*Hasil uji coba yang dilakukan menunjukkan bahwa penggunaan kombinasi transformasi serta perbandingan data pelatihan dan pengujian yang berbeda dapat memberikan pengaruh pada akurasi model. Berdasarkan nilai MAD, MAPE, MSE terkecil didapatkan model terbaik Holt-Winter Artificial Neural Network dengan menggunakan transformasi data serta perbandingan data pelatihan dan pengujian sebesar 50:50. Metode ini dapat memberikan akurasi yang lebih tinggi dibandingkan dengan metode Holt-Winter biasa dan Grey Holt-Winter. Berdasarkan nilai MDA, metode ini dapat mendeteksi pola atau arah deret waktu yang benar antara hasil peramalan dan data aktual.*

***Kata kunci: Peramalan, Data Intermiten, Data Nol, Holt-Winter, Grey Holt-Winter, Artificial Neural Network***

**THE COMPARISON OF HOLT-WINTER, GREY HOLT-WINTER, AND HYBRID HOLT-WINTER ARTIFICIAL NEURAL NETWORK METHOD IN INTERMITTENT DATA FORECASTING**

**Student Name : Jwalita Galuh Garini**  
**NRP : 5214100067**  
**Department : Sistem Informasi FTIK-ITS**  
**Supervisor 1 : Wiwik Anggraeni, S.Si., M.Kom.**

**ABSTRACT**

*Forecasting becomes necessary in many situations. Each forecast has a different level of difficulty, depending on several factors, one of which is data. In many real cases, deret waktu data for forecasting are not always good, for example intermittent data that has a large proportion of zero values. This is a problem that is usually faced by many research and corporate fields. So it is imporant to know forecasting methods that work well for intermittent data considering that this type of data is often encountered in real cases such as inventory, sales, delivery, impors, and other data where the demand for certain items is irregular.*

*A widely used method of intermittent data forecasting research is Exponential Smoothing. The method is widely used in industry because it is considered fast, cheap, and produce a near-reality prediction. The combination of forecasting methods can be widely advantageous, yielding more accurate estimates, while reducing the variance of residuals. For that, in this final project used Holt-Winter and Holt-Winter modification, that are Grey Holt-Winter and Holt-Winter Artificial Neural Network, to forecast data that is intermittent.*

*The experimental results show that the use of a combination of transformations and the comparison of different*

*training and test data can have an effect on the accuracy of the model. Based on the value of the smallest MAD, MAPE, and MSE obtained the best model Holt-Winter Artificial Neural Network using data transformation and comparison of training and test data of 50:50. This method can provide a higher accuracy than the usual Holt-Winter and Gray Holt-Winter methods. Based on MDA values, this method can detect the correct or direction between forecasting and actual data.*

***Keywords: Forecasting, Intermittent Data, Missing Data, Holt-Winter, Gray Holt-Winter, Artificial Neural Network***

## **KATA PENGANTAR**

Puji dan syukur penulis tuturkan ke hadirat Allah SWT, Tuhan Semesta Alam yang telah memberikan kekuatan dan hidayah-Nya kepada penulis sehingga penulis mendapatkan kelancaran dalam menyelesaikan tugas akhir dengan judul:

### **PERBANDINGAN METODE HOLT-WINTER, *GREY* HOLT-WINTER, DAN *HYBRID* HOLT-WINTER *ARTIFICIAL NEURAL NETWORK* PADA PERAMALAN DATA INTERMITEN**

yang merupakan salah satu syarat kelulusan pada Departemen Sistem Informasi, Fakultas Teknologi Informasi dan Komunikasi, Institut Teknologi Sepuluh Nopember Surabaya.

Terima kasih penulis sampaikan kepada pihak-pihak yang telah mendukung, memberikan saran, motivasi, semangat, dan bantuan baik berupa materiil maupun moril demi tercapainya tujuan pembuatan tugas akhir ini. Tugas akhir ini tidak akan pernah terwujud tanpa bantuan dan dukungan dari berbagai pihak yang sudah melauangkan waktu, tenaga dan pikirannya. Secara khusus penulis akan menyampaikan ucapan terima kasih yang sebanyak-banyaknya kepada:

- 1) Orang tua penulis, Bapak Muhammad Munir dan Ibu Istiatin, serta keluarga yang telah memberikan motivasi, semangat, keyakinan, kasih sayang, serta doa sehingga penulis mampu menyelesaikan pendidikan S1 di Departemen Sistem Informasi ini dengan baik.
- 2) Ibu Wiwik Anggraeni, S.Si., M.Kom. selaku dosen pembimbing yang telah dengan sabar dan telaten memberikan ilmu, petunjuk, dan motivasi sehingga penulis dapat menyelesaikan tugas akhir ini.
- 3) Bapak Faisal Johan Atletiko, S.Kom., M.T. selaku dosen wali penulis selama menempuh pendidikan di Departemen Sistem

Informasi yang telah memberikan pengalaman serta nasehat kepada penulis selama ini.

- 4) Bapak Ahmad Mukhlason, S.Kom., M.Sc., Ph.D. dan Bapak Faizal Mahananto, S.Kom., M.Eng., Ph.D. selaku dosen penguji yang telah memberikan kritik, saran, serta masukan yang berharga sehingga dapat menyempurnakan tugas akhir ini.
- 5) Seluruh dosen pengajar beserta staf dan karyawan di Departemen Sistem Informasi, Fakultas Teknologi Informasi dan Komunikasi ITS Surabaya yang telah memberikan ilmu dan pengalaman yang berharga kepada penulis selama ini.
- 6) Rekan-rekan mahasiswa Departemen Sistem Informasi OSIRIS serta anggota Lab Rekayasa Data dan Intelegensi Bisnis (RDIB) atas semua bantuan yang diberikan selama penulis berkuliah di Departemen Sistem Informasi.
- 7) Teman seperjuangan dalam menyelesaikan tugas akhir, Ria Widiya, Niken Dwi, Trishna Fadea, Rika Nurlaili, Zuhriya Firda, dan Rima Ika, yang selalu mengingatkan dan memotivasi satu sama lain.
- 8) Teman-teman yang telah menemani dan mendukung penulis menjalani kehidupan kampus hingga dapat menyelesaikan tugas akhir ini, Mutiara Ratna, Aprilia Rizki, Aldifiati Arfiani, Anugrah D. Putra, Dhimas Dwijo, dan Iqbal Tawakkal.
- 9) Serta semua pihak yang telah membantu dalam pengerjaan tugas akhir ini yang belum mampu penulis sebutkan diatas.

Terima kasih atas segala bantuan, dukungan, serta doa yang telah diberikan. Penulis menyadari bahwa tugas akhir ini masih belum sempurna dan memiliki banyak kekurangan di dalamnya. Oleh karena itu, penulis juga memohon maaf atas segala kesalahan penulis buat dalam buku tugas akhir ini. Penulis membuka pintu selebar-lebarnya bagi pihak yang ingin memberikan kritik maupun saran, serta penelitian selanjutnya yang ingin menyempurnakan

karya dari tugas akhir ini. Semoga buku tugas akhir ini bermanfaat bagi seluruh pembaca.

Surabaya, Januari 2018

Penulis

## DAFTAR ISI

ABSTRAK .....	v
ABSTRACT .....	vii
KATA PENGANTAR.....	ix
DAFTAR ISI .....	xii
DAFTAR GAMBAR.....	xv
DAFTAR TABEL .....	xvii
BAB I PENDAHULUAN .....	1
1.1. Latar Belakang Masalah .....	1
1.2. Perumusan Masalah .....	3
1.3. Batasan Masalah .....	4
1.4. Tujuan Penelitian .....	4
1.5. Manfaat Penelitian .....	4
1.6. Relevansi .....	5
BAB II TINJAUAN PUSTAKA .....	7
2.1. Penelitian Sebelumnya.....	7
2.2. Dasar Teori .....	11
2.2.1. Data Intermiten .....	11
2.2.2. Peramalan .....	12
2.2.3. <i>Bootstrap</i> .....	13
2.2.4. <i>Exponential Smoothing Holt-Winter</i> .....	15
2.2.5. <i>Grey Holt-Winter</i> .....	17
2.2.6. <i>Artificial Neural Network</i> .....	20
2.2.7. <i>Holt-Winter Artificial Neural Network</i> .....	25
2.2.8. <i>Windowing</i> .....	27
2.2.9. <i>Grid Search</i> .....	28
2.2.10. Akurasi.....	30
BAB III METODOLOGI PENELITIAN .....	35
3.1. Identifikasi masalah .....	36
3.2. Studi literatur .....	36
3.3. Pengumpulan data.....	36
3.4. Persiapan data .....	37
3.5. Pembuatan model untuk peramalan.....	38
3.5.1. Pembuatan Model Holt-Winter.....	38
3.5.2. Pembuatan Model <i>Grey Holt-Winter</i> .....	38
3.5.3. Pembuatan Model <i>Holt-Winter Artificial Neural Network</i> .....	39

3.6. Pengukuran akurasi .....	40
3.7. Pemilihan model terbaik.....	40
3.8. Analisis hasil dan penarikan kesimpulan .....	40
3.9. Penyusunan buku tugas akhir .....	41
BAB IV PERANCANGAN .....	43
4.1. Pengumpulan Data .....	43
4.2. Persiapan Data .....	43
4.3. Perancangan Model .....	44
4.3.1. Perancangan Model Holt-Winter.....	44
4.3.2. Perancangan Model <i>Grey</i> Holt-Winter.....	45
4.3.3. Perancangan Model Holt-Winter <i>Artificial Neural Network</i> .....	47
4.4. Peramalan Data.....	49
BAB V IMPLEMENTASI.....	51
5.1. Pengisian Nilai Nol .....	51
5.2. Pembagian Data Pelatihan dan Pengujian .....	56
5.3. Pemodelan Holt-Winter.....	57
5.3.1. Inisialisasi .....	57
5.3.2. Pemilihan Nilai Parameter Optimal.....	58
5.3.3. Melakukan Peramalan dengan Holt-Winter .	59
5.4. Pemodelan <i>Grey</i> Holt-Winter.....	61
5.4.1. Pengubahan ke Baris r-AGO .....	61
5.4.2. Inisialisasi .....	63
5.4.3. Pemilihan Nilai Parameter Optimal.....	64
5.4.4. Melakukan Peramalan dengan Holt-Winter .	67
5.4.5. Pengubahan ke Baris IAGO .....	67
5.5. Pemodelan Holt-Winter <i>Artificial Neural Network</i> .	70
5.5.1. Inisialisasi .....	70
5.5.2. Pemilihan Nilai Parameter Optimal.....	71
5.5.3. Melakukan Peramalan dengan Holt-Winter .	72
5.5.4. Pelatihan <i>Artificial Neural Network</i> pada RapidMiner.....	74
5.5.5. Pengujian <i>Artificial Neural Network</i> pada RapidMiner.....	81
5.5.6. Melakukan Peramalan dengan Holt-Winter <i>Artificial Neural Network</i> .....	83
5.6. Pemilihan Model Terbaik.....	84

5.7. Peramalan Data dengan Model Terbaik.....	88
<b>BAB VI HASIL DAN PEMBAHASAN.....</b>	<b>89</b>
6.1. Hasil Performa Model.....	89
6.1.1. Analisa MAD pada Model.....	89
6.1.2. Analisa MAPE pada Model.....	91
6.1.3. Analisa MSE apada Model.....	93
6.1.4. Analisa MDA pada Model.....	95
6.2. Pemilihan Model Terbaik.....	99
6.3. Peramalan Periode Selanjutnya.....	102
<b>BAB VII KESIMPULAN DAN SARAN.....</b>	<b>107</b>
7.1. Kesimpulan.....	107
7.2. Saran.....	108
<b>DAFTAR PUSTAKA.....</b>	<b>109</b>
<b>BIODATA PENULIS.....</b>	<b>113</b>
<b>LAMPIRAN A.....</b>	<b>A-1</b>
<b>LAMPIRAN B.....</b>	<b>B-1</b>
<b>LAMPIRAN C.....</b>	<b>C-1</b>
<b>LAMPIRAN D.....</b>	<b>D-1</b>
<b>LAMPIRAN E.....</b>	<b>E-1</b>
<b>LAMPIRAN F.....</b>	<b>F-1</b>

## DAFTAR GAMBAR

Gambar 2.1 Flow Chart Model <i>Grey Holt-Winter</i> .....	20
Gambar 2.2 Model Nonlinear Neuron.....	21
Gambar 2.3 Single-Layer Feedforward Networks .....	23
Gambar 2.4 Multilayer Feedforward Networks .....	24
Gambar 2.5 Recurrent Networks.....	25
Gambar 2.6 Mekanisme Holt-Winter <i>Artificial Neural Network</i> .....	26
Gambar 2.7 Penggunaan <i>Windowing</i> pada Data Deret Waktu .....	28
Gambar 2.8 Proses Optimasi <i>Grid Search</i> .....	29
Gambar 2.9 Proses Peramalan dengan Optimasi Parameter Menggunakan <i>Grid Search</i> .....	30
Gambar 3.1 Bagan Metodologi .....	35
Gambar 5.1 Jumlah Impor Beras Aktual.....	52
Gambar 5.2 <i>Script</i> Pengisian Data Nol Menggunakan MICE	53
Gambar 5.3 Contoh Isi File CSV untuk <i>Input</i> MICE.....	53
Gambar 5.4 Contoh Isi File CSV <i>Output</i> Pengisian Data Nol	54
Gambar 5.5 Hasil <i>Bootstrapping</i> Tanpa Transformasi .....	55
Gambar 5.6 Hasil <i>Bootstrapping</i> Tanpa Transformasi .....	55
Gambar 5.7 <i>Script</i> untuk Mengubah ke Baris r-AGO.....	62
Gambar 5.8 Contoh Isi File CSV untuk Diubah Menjadi Deret r-AGO .....	63
Gambar 5.9 Perbandingan Penggunaan Operator Transformasi (r) pada Data Pelatihan Tanpa Transformasi.....	65
Gambar 5.10 Perbandingan Penggunaan Operator Transformasi (r) pada Data Pelatihan Dengan Transformasi .....	66
Gambar 5.11 <i>Script</i> untuk Mengubah ke Baris IAGO .....	68
Gambar 5.12 Contoh Isi File CSV Hasil Pengubahan Mejadi Deret IAGO.....	69
Gambar 5.13 Proses Pelatihan secara Keseluruhan.....	74
Gambar 5.14 Sub-Proses Pelatihan pada Operator <i>Optimize Parameter (Grid)</i> .....	74
Gambar 5.15 Operator <i>Retrieve</i> dan <i>Set Role</i> .....	75
Gambar 5.16 Operator <i>Windowing</i> .....	75

Gambar 5.17 Contoh <i>Example Set</i> yang Dihasilkan oleh Operator <i>Windowing</i> .....	76
Gambar 5.18 Operator <i>Optimize Parameters (Grid)</i> .....	76
Gambar 5.19 Pengaturan pada Opetaror <i>Optimize Parameters (Grid)</i> .....	77
Gambar 5.20 Opetaror <i>Neural Net</i> .....	77
Gambar 5.21 Pengaturan pada Opetaror <i>Neural Net</i> .....	78
Gambar 5.22 Operator Performance, Apply Model, dan Log	78
Gambar 5.23 Perbandingan Penggunaan Hidden Layer pada Data Pelatihan Tanpa Transformasi .....	79
Gambar 5.24 Perbandingan Penggunaan Hidden Layer pada Data Pelatihan Dengan Transformasi .....	80
Gambar 5.25 Proses Pengujian secara Keseluruhan.....	81
Gambar 5.26 Operator <i>Retrieve</i> dan <i>Set Role</i> .....	81
Gambar 5.27 Operator <i>Windowing</i> .....	82
Gambar 5.28 Operator Read Model, Apply Model, dan Performance.....	82
Gambar 6.1 Perbandingan Nilai Absolut Error.....	90
Gambar 6.2 Perbandingan Nilai Absolute Percentage Error ..	92
Gambar 6.3 Perbandingan Nilai Kuadrat Error .....	94
Gambar 6.4 Perbandingan Data Aktual dan Peramalan Model 1 .....	96
Gambar 6.5 Perbandingan Data Aktual dan Peramalan Model 2 .....	97
Gambar 6.6 Perbandingan Data Aktual dan Peramalan Model 3 .....	98
Gambar 6.7 Arsitektur <i>Neural Network</i> .....	100
Gambar 6.8 Hasil Peramalan Periode Selanjutnya.....	103
Gambar 6.9 Perbandingan Data Aktual dan Peramalan Periode Selanjutnya .....	104
Gambar 6.10 Hasil Peramalan Periode Selanjutnya.....	106
Gambar 6.11 Perbandingan Data Aktual dan Peramalan Periode Selanjutnya .....	106

## DAFTAR TABEL

Tabel 2.1 Penelitian Sebelumnya .....	7
Tabel 2.2 Tingkat Signifikansi MAPE.....	32
Tabel 4.1 Rancangan Model Holt-Winter .....	45
Tabel 4.2 Rancangan Model <i>Grey</i> Holt-Winter .....	46
Tabel 4.3 Rancangan Model Holt-Winter <i>Artificial Neural Network</i> .....	48
Tabel 5.1 Panjang Gap Data Nol Pada Jumlah Impor Beras Jawa Timur .....	51
Tabel 5.2 Pembagian Data Pelatihan dan Data Pengujian .....	57
Tabel 5.3 Model Terbaik Setiap Skenario untuk Holt-Winter.....	58
Tabel 5.4 Tingkat Akurasi Data Pelatihan Model Holt-Winter .....	60
Tabel 5.5 Tingkat Akurasi Data Pengujian Model Holt-Winter .....	60
Tabel 5.6 Model Terbaik Setiap Skenario untuk <i>Grey</i> Holt-Winter.....	66
Tabel 5.7 Tingkat Akurasi Data Pelatihan Model <i>Grey</i> Holt-Winter.....	70
Tabel 5.8 Tingkat Akurasi Data Pengujian Model <i>Grey</i> Holt-Winter.....	70
Tabel 5.9 Model Terbaik Setiap Skenario untuk Holt-Winter.....	72
Tabel 5.10 Tingkat Akurasi Data Pelatihan Model Holt-Winter .....	73
Tabel 5.11 Tingkat Akurasi Data Pengujian Model Holt-Winter .....	73
Tabel 5.12 Model Terbaik Setiap Skenario untuk <i>Artificial Neural Network</i> .....	80
Tabel 5.13 Tingkat Akurasi Data Pelatihan Model <i>Artificial Neural Network</i> .....	83
Tabel 5.14 Tingkat Akurasi Data Pelatihan Model Holt-Winter <i>Artificial Neural Network</i> .....	83
Tabel 5.15 Tingkat Akurasi Data Pengujian Model Holt-Winter <i>Artificial Neural Network</i> .....	84
Tabel 5.16 Tingkat Akurasi Data Pelatihan .....	85
Tabel 5.17 Tingkat Akurasi Data Pengujian .....	86

Tabel 5.18 Tiga Model Tingkat Akurasi Terbaik Berdasarkan Data Pelatihan.....	87
Tabel 5.19 Tiga Model Tingkat Akurasi Terbaik Berdasarkan Data Pengujian.....	87
Tabel 6.1 Perbandingan Nilai MAD Model Terbaik Data Pelatihan .....	89
Tabel 6.2 Perbandingan Nilai MAD Model Terbaik Data Pengujian.....	91
Tabel 6.3 Perbandingan Nilai MAPE Model Terbaik Data Pelatihan .....	91
Tabel 6.4 Perbandingan Nilai MAPE Model Terbaik Data Pengujian.....	93
Tabel 6.5 Perbandingan Nilai MSE Model Terbaik Data Pelatihan .....	93
Tabel 6.6 Perbandingan Nilai MSE Model Terbaik Data Pengujian.....	95
Tabel 6.7 Perbandingan Nilai MDA Model Terbaik Data Pelatihan .....	95
Tabel 6.8 Perbandingan Nilai MDA Model Terbaik Data Pengujian.....	98
Tabel 6.9 Hasil Peramalan 2 Tahun Mendatang dengan HW-ANN .....	102
Tabel 6.10 Hasil Peramalan 2 Tahun Mendatang dengan GHW .....	105

*Halaman ini sengaja dikosongkan*

*Halaman ini sengaja dikosongkan*

# BAB I PENDAHULUAN

Pada bab ini akan dibahas mengenai latar belakang masalah, perumusan masalah, batasan masalah, tujuan tugas akhir, dan manfaat kegiatan tugas akhir. Berdasarkan uraian pada bab ini, diharapkan mampu memberi gambaran umum permasalahan dan pemecahan masalah pada tugas akhir.

## 1.1. Latar Belakang Masalah

Peramalan menjadi suatu hal yang dibutuhkan dalam banyak situasi, baik dalam kehidupan individu maupun pada bisnis dan pemerintahan. [1] [2] Dengan melakukan peramalan, seseorang atau organisasi dapat memperkirakan kondisi di masa depan yang berada diluar kendali dengan seakurat mungkin berdasarkan informasi yang dimiliki. Contoh situasi dimana peramalan dibutuhkan antara lain dalam memutuskan pembangunan pembangkit tenaga listrik berdasarkan perkiraan permintaan di masa depan, penjadwalan staf *call center* untuk minggu selanjutnya berdasarkan perkiraan volume panggilan, penyimpanan persediaan berdasarkan perkiraan kebutuhan stok, dan lain sebagainya [1]. Dapat dilihat bahwa semua situasi tersebut mengarah pada pengambilan keputusan selanjutnya. Dalam peramalan, beberapa hal dapat lebih mudah untuk diperkirakan dibanding yang lain. Tingkat kesulitan masing-masing peramalan bergantung pada beberapa faktor, salah satunya adalah data yang tersedia untuk peramalan [1].

Pada banyak kasus nyata, data deret waktu yang digunakan dalam peramalan tidak selalu bagus, data bisa saja bersifat intermiten atau tidak teratur. Hal ini menjadi masalah yang biasanya dihadapi oleh banyak bidang penelitian dan perusahaan. Intermiten sendiri dapat diartikan sebagai kondisi dimana data memiliki proporsi nilai nol yang besar [1]. Istilah ini sebenarnya mencakup beberapa sub kelompok pola data yang berbeda. Data yang memiliki sifat intermiten juga sering disebut bersifat '*lumpy*' yang artinya terdapat variabilitas yang besar di antara nilai nol tersebut [3].

Data deret waktu yang memuat banyak nilai nol biasanya dapat ditemukan pada data persediaan, penjualan, pengiriman, impor, dan data lainnya dimana permintaan untuk item tertentu bersifat intermiten atau tidak teratur [4]. Beberapa penelitian sebelumnya menunjukkan bahwa data yang bersifat intermiten dapat ditemui dalam berbagai kasus. Misalnya Willemain dkk [3] yang mengidentifikasi data intermiten pada permintaan suku cadang untuk mesin berat, pesawat terbang, elektronik, mesin dan alat kelautan, serta Syntetos dkk [5] [6] yang menemukan data intermiten pada permintaan suku cadang di industri otomotif, perhiasan, dan elektronik. Sementara Tratar [7] meneliti data intermiten pada data kunjungan wisatawan domestik dan asing. Data intermiten juga dapat berupa item lain dalam kisaran produk yang ditawarkan oleh semua organisasi pada setiap tingkat rantai pasokan [4].

Berdasarkan uraian sebelumnya, penting untuk mengetahui metode peramalan yang bekerja dengan baik pada data intermiten mengingat data jenis ini sering ditemui dalam berbagai kasus nyata dan menjadi masalah yang biasa dihadapi dalam banyak penelitian. Salah satu kelas metode yang dapat digunakan pada untuk meramalkan data intermiten adalah *Exponential Smoothing*. Meskipun metode peramalan terus mengalami perkembangan untuk menyesuaikan dengan data intermiten, pada praktiknya, banyak industri masih mengandalkan *Exponential Smoothing* sebagai alat untuk meramal karena dianggap cepat, murah, dan menghasilkan peramalan yang mendekati kenyataan [7].

Metode *Simple Exponential Smoothing* merupakan metode peramalan pertama yang diaplikasikan pada data intermiten. Namun menurut Croston [8], metode *Simple Exponential Smoothing* tidak cocok digunakan untuk data intermiten karena terdapat bias dalam hasil ramalan pada periode setelah data nol muncul. Salah satu pengembangan dari *Exponential Smoothing* yang dapat menangkap faktor *level*, *trend*, dan *seasonal* adalah Holt-Winter. Tratar [7] dalam penelitiannya menunjukkan bahwa metode Holt-Winter dapat

digunakan untuk meramalkan data deret waktu yang mengandung nilai nol.

Kombinasi metode peramalan secara luas dianggap menguntungkan [9], menghasilkan perkiraan yang lebih akurat, sekaligus mengurangi varians dari residu [10]. Banyak penelitian dilakukan untuk meningkatkan akurasi dari kelas metode *Exponential Smoothing*. Contohnya dengan melakukan kombinasi pada Holt-Winter dengan metode lain, seperti Holt-Winter dan *Artificial Neural Network* atau Holt-Winter dan *Grey* untuk menangani deret data yang acak dan tidak teratur [11] [12].

Untuk itu, dalam tugas akhir ini diusulkan penerapan metode Holt-Winter dan modifikasi Holt-Winter untuk meramalkan data yang bersifat intermiten. Tujuannya adalah untuk mengetahui model terbaik yang dapat digunakan untuk meramalkan data intermiten serta mengetahui perbandingan tingkat akurasi peramalan yang dihasilkan antar metode yang diterapkan. Sehingga nantinya dapat membantu peneliti maupun perusahaan dalam pengambilan keputusan terkait peramalan pada data intermiten agar hasil peramalannya menjadi lebih baik.

## 1.2. Perumusan Masalah

Berdasarkan latar belakang yang telah dipaparkan di atas, maka berikut ini merupakan rumusan masalah yang diangkat pada penelitian ini:

1. Bagaimana model terbaik dari metode Holt-Winter dan modifikasi Holt-Winter yang dapat digunakan untuk meramalkan data intermiten.
2. Bagaimana hasil dan tingkat akurasi peramalan data intermiten dengan menggunakan metode Holt-Winter dan modifikasi Holt-Winter.

### **1.3. Batasan Masalah**

Pada penyelesaian tugas akhir ini memiliki beberapa batasan masalah. Berikut batasan masalah yang harus diperhatikan:

1. Data yang digunakan dalam tugas akhir ini adalah data jumlah impor beras di wilayah Jawa Timur yang memiliki proporsi nilai nol yang besar dalam data.
2. Data yang diambil dalam bentuk periode bulanan sejak Januari 2002 hingga Desember 2016.
3. Peramalan untuk periode bulanan selanjutnya diimplementasikan untuk dua tahun berikutnya, yaitu tahun 2017 hingga 2018.

### **1.4. Tujuan Penelitian**

Dari rumusan masalah yang disebutkan sebelumnya, tujuan yang ingin dicapai melalui tugas akhir ini adalah:

1. Mengetahui model terbaik dari metode Holt-Winter dan modifikasi Holt-Winter yang dapat digunakan untuk meramalkan data intermiten.
2. Mengetahui hasil dan tingkat akurasi peramalan data intermiten dengan menggunakan metode Holt-Winter dan modifikasi Holt-Winter.

### **1.5. Manfaat Penelitian**

Manfaat yang diberikan dengan adanya tugas akhir ini adalah untuk memberikan sumbangan pemikiran pada peneliti maupun perusahaan agar dapat memudahkan dalam pengambilan keputusan terkait peramalan pada data intermiten. Selain itu, juga dapat menambah sumber pengetahuan dan pembelajaran mengenai peramalan data intermiten untuk dijadikan acuan dalam penelitian selanjutnya dengan permasalahan yang serupa.

## 1.6. Relevansi

Data deret waktu untuk peramalan pada banyak kasus nyata tidak selalu bagus, salah satunya data bersifat intermiten atau memiliki proporsi nilai nol yang besar. Data seperti ini dapat ditemukan pada data persediaan, penjualan, pengiriman, impor, dan data lainnya dimana permintaan untuk item tertentu bersifat intermiten. Adanya nilai nol tersebut menjadi masalah yang biasanya dihadapi oleh banyak penelitian dalam meramalkan data deret waktu. Untuk itu dibutuhkan metode peramalan yang sesuai untuk diterapkan pada data intermiten. Contoh metode yang dapat digunakan untuk meramalkan data intermiten adalah *Exponential Smoothing* dimana metode ini masih banyak digunakan pada industri sebagai alat untuk meramal karena dianggap cepat, murah, dan menghasilkan peramalan yang mendekati kenyataan [7].

Kombinasi metode peramalan secara luas dianggap menguntungkan [9], menghasilkan perkiraan yang lebih akurat, sekaligus mengurangi varians dari residu [10]. Banyak penelitian dilakukan untuk meningkatkan akurasi dari kelas metode *Exponential Smoothing*. Contohnya dengan melakukan kombinasi pada Holt-Winter dengan metode lain, seperti Holt-Winter dan Artificial Neural Network atau Holt-Winter dan Grey untuk menangani deret data yang acak dan tidak teratur [11] [12]. Penggunaan metode Holt-Winter dan modifikasi Holt-Winter pada tugas akhir ini dapat membantu meramalkan data yang bersifat intermiten, sehingga dapat memberikan sumbangan pemikiran pada peneliti maupun perusahaan agar dapat memudahkan dalam pengambilan keputusan terkait peramalan pada data intermiten.

Penyusunan tugas akhir bertujuan memenuhi syarat kelulusan tahap sarjana serta sebagai bentuk implementasi disiplin ilmu yang telah didapatkan selama pendidikan perkuliahan di Jurusan Sistem Informasi ITS. Topik yang diangkat dalam penelitian tugas akhir adalah peramalan yang memiliki relevansi dengan mata kuliah yang dipelajari

6

sebelumnya yaitu Teknik Peramalan dan berkaitan dengan Lab Rekayasa Data dan Inteligensi Bisnis.

## BAB II TINJAUAN PUSTAKA

Pada bab ini akan dibahas mengenai penelitian sebelumnya dan dasar teori yang akan dijadikan sebagai acuan atau landasan dalam pengerjaan tugas akhir ini.

### 2.1. Penelitian Sebelumnya

Beberapa penelitian sebelumnya yang terkait dengan tugas akhir ini disajikan dalam Tabel 2.1.

**Tabel 2.1 Penelitian Sebelumnya**

<b>Penelitian 1</b>	
Judul Paper	<i>Improved Holt-Winter Method: A Case of Overnight Stays of Tourist in Republic of Slovenia</i> [7]
Penulis; Tahun	Liljana Ferbar Tratar; 2014
Deskripsi Umum Penelitian	Pada penelitian ini diperkenalkan metode peramalan yang akan memberikan hasil yang baik seperti Holt-Winter multiplikatif serta dapat digunakan untuk data deret waktu dengan banyak nilai nol. Dalam penelitian ini digunakan data wisatawan domestik dan asing yang menginap semalam di Republik Slovenia antara tahun 2000 dan 2009. Data yang dipilih hanya komunitas yang mewakili deret waktu dengan musiman dan/atau <i>trend</i> serta variasi data yang tinggi, sehingga selanjutnya ditangani 10 deret waktu tanpa nol dan 6 deret waktu intermiten untuk komunitas Slovenia yang dipilih. Peramalan dihitung dengan menggunakan Holt-Winter aditif, Holt-Winter multiplikatif, dan <i>improved</i> Holt-Winter untuk kemudian dibandingkan hasilnya satu sama lain. Pada penelitian ini ditunjukkan bahwa metode <i>improved</i> Holt-Winter tidak hanya mencapai

	hasil metode Holt-Winter multiplikatif namun dalam artian pengukuran MSE dapat memberikan hasil yang lebih baik.
Keterkaitan Penelitian	Peramalan terhadap data intermiten pada penelitian ini akan dilakukan dengan menggunakan Holt-Winter. Metode Holt-Winter pada penelitian ini akan dikombinasikan dengan <i>bootstrap</i> untuk memperbaiki data dengan melakukan pengisian pada data yang bernilai nol.
<b>Penelitian 2</b>	
Judul Paper	<i>Choosing Smoothing Parameters for Exponential Smoothing: Minimizing Sums of Squared Versus Sums of Absolute Errors</i> [13]
Penulis; Tahun	Terry E. Dielman; 2006
Deskripsi Umum Penelitian	Penelitian ini membahas tentang perbandingan ukuran akurasi yang dihasilkan dari pemilihan parameter pemulusan dalam <i>Exponential Smoothing</i> dengan cara meminimalkan SSE ( <i>Sums of Squared Errors</i> ) atau SAE ( <i>Sums of Absolute Errors</i> ). Metode <i>Exponential Smoothing</i> yang diteliti adalah <i>Simple Exponential Smoothing</i> , <i>Borwn's Double Exponential Smoothing</i> , dan <i>Holt's Two Parameter Exponential Smoothing</i> . Parameter pemulusan dari tiap metode akan dipilih dengan melakukan <i>grid search</i> pada kisaran 0.01-0.99 yang akan meminimalkan SSE atau SAE. Hasilnya menunjukkan pada sebagian besar distribusi dengan <i>outlier</i> , ukuran akurasi dengan meminimalkan SAE akan lebih kecil daripada dengan meminimalkan SSE.
Keterkaitan Penelitian	Penggunaan <i>grid search</i> untuk menentukan parameter yang optimal juga akan diterapkan pada penelitian ini, yaitu untuk menentukan

	nilai <i>training cycle</i> , <i>learning rate</i> , dan <i>momentum</i> pada metode <i>Artificial Neural Network</i> yang akan digunakan bersamaan dengan metode Holt-Winter.
<b>Penelitian 3</b>	
Judul Paper	<i>Using Grey Holt–Winters Model to Predict The Air Quality Index for Cities in China</i> [12]
Penulis; Tahun	Lifeng Wu, Xiaohui Gao, Yanli Xiao, Sifeng Liu, Yingjie Yang; 2017
Deskripsi Umum Penelitian	Penelitian ini membahas tentang peningkatan akurasi Holt-Winter dengan menggunakan penggabungan Holt-Winter dan <i>Grey accumulated generating</i> untuk menangani deret data yang acak dan tidak teratur. Dalam penelitian ini digunakan data indeks kualitas udara pada dua kota di China, yaitu Shijiazhuang dan Handan. Data yang digunakan merupakan data deret waktu dalam bentuk periode bulanan mulai Januari 2014 hingga November 2016. Data selanjutnya diramalkan menggunakan Holt-Winter dan <i>Grey Holt-Winter</i> untuk dibandingkan. Hasil penelitian ini menunjukkan bahwa <i>Grey Holt-Winter</i> dapat memberikan hasil peramalan yang lebih akurat jika dibandingkan dengan Holt-Winter biasa.
Keterkaitan Penelitian	Penggunaan <i>Grey Holt-Winter</i> juga akan diterapkan pada penelitian ini untuk meramalkan data intermiten. Tingkat akurasi yang diperoleh dari penggunaan <i>Grey Holt-Winter</i> akan dibandingkan dengan metode Holt-Winter biasa.
<b>Penelitian 4</b>	
Judul Paper	<i>Combined Holt-Winters and GA Trained ANN Approach for Sensor Validation and Reconstruction: Application to Water Demand Flowmeters</i> [11]

Penulis; Tahun	Hector Rodriguez, Vicenc Puig, Juan J. Flores, Rodrigo Lopez; 2016
Deskripsi Umum Penelitian	<p>Penelitian ini membahas tentang peningkatan akurasi Holt-Winter dengan menggunakan penggabungan Holt-Winter dan <i>Artificial Neural Network</i>. Dimana <i>Artificial Neural Network</i> digunakan untuk melakukan peramalan terhadap residu yang dihasilkan dari model Holt-Winter. Sehingga penggunaan <i>Artificial Neural Network</i> akan melengkapi dan memperbaiki peramalan yang dihasilkan oleh Holt-Winter. Dalam penelitian ini digunakan data deret waktu meteran arus kebutuhan air di Barcelona. Panjang data deret waktu tersebut adalah satu bulan dengan skala per jam sehingga terdapat 720 data. Data selanjutnya diramalkan menggunakan Holt-Winter biasa berupa <i>Double Seasonal Holt-Winter</i>, kombinasi Holt-Winter dan <i>Artificial Neural Network</i>, serta ARIMA. Berdasarkan penelitian ini, kombinasi Holt-Winter dan <i>Artificial Neural Network</i> dapat memberikan tingkat akurasi yang lebih baik dibandingkan dengan dua metode lain yang digunakan dalam penelitian.</p>
Keterkaitan Penelitian	<p>Penggunaan kombinasi Holt-Winter dan <i>Artificial Neural Network</i> juga akan diterapkan pada penelitian ini untuk meramalkan data intermiten. Tingkat akurasi yang diperoleh dari penggunaan Holt-Winter dan <i>Artificial Neural Network</i> akan dibandingkan dengan metode Holt-Winter biasa.</p>

## 2.2. Dasar Teori

### 2.2.1. Data Intermiten

Permintaan intermiten atau juga dikenal dengan istilah *sporadic* muncul pada saat item pada data deret waktu mengalami beberapa periode permintaan nol. Seringkali dalam situasi ini, ketika permintaan terjadi ukurannya kecil dan terkadang sangat bervariasi. Croston [8] berpendapat permintaan intermiten sebagai pola permintaan yang menunjukkan banyak periode dengan nilai nol, diselingi oleh periode dengan permintaan yang tidak beraturan dan tidak nol.

Namun, hal ini membatasi definisi atribut intermiten atau *sporadic*. Silver [14] mengusulkan sebuah definisi untuk permintaan intermiten sebagai permintaan yang jarang terjadi dalam arti waktu rata-rata antar transaksi berurutan jauh lebih besar daripada periode waktu unit. Sementara Johnston dkk [15] mengusulkan bahwa jika interval rata-rata antara permintaan bukan nol adalah 1.25 kali lebih besar dari periode tinjauan persediaan, maka rangkaian permintaan dapat dianggap sebagai intermiten.

Pada banyak penelitian terkini, istilah seperti permintaan intermiten, *lumpy*, dan *erratic* sering digunakan secara bergantian. Tidak ada pendekatan sistematis untuk menentukan pola permintaan yang berbeda atau mengklasifikasikan pola permintaan ke dalam kategori tertentu.

Syntetos menggambarkan *erratic* sebagai pola permintaan dengan variabilitas tinggi tanpa permintaan nol. Syntetos [16] mendasarkan definisinya pada ukuran permintaan dan mengabaikan kejadian permintaan, begitu juga dengan Silver [14]. Sementara *lumpy* didefinisikan oleh Syntetos [16] sebagai pola permintaan dengan beberapa permintaan nol dan dengan permintaan bukan nol yang memiliki variabilitas tinggi. Syntetos menganggap semua permintaan yang bersifat *lumpy* sebagai permintaan intermiten. Namun tidak semua permintaan intermiten adalah permintaan *lumpy*. Ward [17] juga menggunakan istilah permintaan intermiten dan permintaan *lumpy* secara bergantian.

Menurut Silver [18], peramalan permintaan intermiten merupakan hal yang sulit dan tidak pasti karena permintaan intermiten tidak beraturan dengan proporsi nilai nol yang besar.

### **2.2.2. Peramalan**

Menurut Makridaris [19], peramalan adalah prediksi nilai-nilai sebuah peubah berdasarkan pada nilai yang diketahui dari peubah tersebut atau peubah yang berhubungan. Sementara menurut Elwood [20], peramalan diartikan sebagai penggunaan teknik-teknik statistik dalam bentuk gambaran masa depan berdasarkan pengolahan angka-angka historis. Sedangkan Biegel [21] berpendapat bahwa peramalan adalah kegiatan memperkirakan tingkat permintaan produk yang diharapkan untuk suatu produk atau beberapa produk dalam periode waktu tertentu di masa yang akan datang.

Menurut Heizer [22] berdasarkan jangka waktunya, peramalan dapat dikelompokkan menjadi tiga kategori, yaitu:

1. Peramalan jangka pendek adalah peramalan untuk jangka waktu kurang dari tiga bulan.
2. Peramalan jangka menengah adalah peramalan untuk jangka waktu antara tiga bulan sampai tiga tahun.
3. Peramalan jangka panjang adalah peramalan untuk jangka waktu lebih dari tiga tahun.

Sementara berdasarkan pendekatannya, peramalan diklasifikasikan menjadi dua, yaitu pendekatan kualitatif dan kuantitatif [19]. Metode kualitatif merupakan metode peramalan yang tidak menggunakan data historis masa lalu atau lebih didasarkan pada intuisi. Sementara metode kuantitatif merupakan metode peramalan yang menggunakan data historis masa lalu, memanipulasi data historis yang tersedia secara memadai dan tanpa intuisi, metode ini umumnya didasarkan pada analisis statistik. Menurut Makridakis dkk [19], peramalan kuantitatif dapat diterapkan bila tiga kondisi terpenuhi, yaitu informasi mengenai keadaan waktu yang lalu tersedia, informasi itu dapat dikuantitatifkan dalam bentuk data numerik,

dan dapat diasumsikan bahwa beberapa aspek dari pola di waktu yang lalu akan berlanjut ke waktu yang akan datang.

Metode peramalan kuantitatif sendiri terbagi atas dua jenis model peramalan yang utama, yaitu model deret waktu (*time series*) dan model kausal. Model deret waktu adalah peramalan yang didasarkan atas penggunaan analisis pola hubungan antara variabel yang akan diperkirakan dengan variabel waktu, yang merupakan deret waktu. Sebaliknya, model kausal merupakan metode peramalan yang didasarkan atas penggunaan analisis pola hubungan antara variabel lain yang mempengaruhinya, yang bukan waktu yang disebut metode korelasi atau sebab akibat.

Dalam melakukan proses peramalan, secara umum terdapat lima langkah tahapan peramalan yang dilakukan menurut Hanke dkk [23], yaitu:

1. Formulasi masalah dan pengumpulan data
2. Manipulasi dan pembersihan data
3. Pembentukan dan evaluasi model
4. Implementasi model (peramalan sebenarnya)
5. Evaluasi peramalan

Render dan Heizer [22] menyatakan bahwa prinsip dari peramalan adalah peramalan akan selalu mengandung eror, kesalahan harus terukur, ramalan suatu famili produk akan lebih teliti daripada produk akhir, dan peramalan jangka pendek akan lebih teliti daripada peramalan jangka panjang.

### **2.2.3. Bootstrap**

Metode *bootstrap* adalah prosedur *resampling* umum diperkenalkan pertama kali oleh Bradley Efron pada tahun 1979. Metode *bootstrap* pada dasarnya adalah melakukan pengambilan sampel dengan pengembalian dari sampel hasil observasi dengan replikasi B kali dengan n adalah ukuran sampel. Metode ini dapat bekerja tanpa membutuhkan asumsi distribusi, karena sampel data asli digunakan sebagai populasi [24].

Dalam Sahinler & Topuz [25], Efron menyatakan bahwa *bootstrap* adalah teknik *resampling* nonparametrik yang bertujuan untuk menentukan estimasi *standard error* dan interval konfidensi dari parameter populasi seperti rata-rata, rasio, median, proporsi tanpa menggunakan asumsi distribusi.

*Bootstrap* dapat digunakan untuk mengatasi permasalahan dalam statistika baik masalah data yang sedikit, data yang menyimpang dari asumsinya maupun data yang tidak memiliki asumsi dalam distribusinya. *Bootstrap* adalah suatu metode yang berbasis komputer yang sangat potensial untuk dipergunakan pada masalah keakurasian. [24]

Berdasarkan uraian metode *resampling bootstrap* menurut Efron dan Tibshirani [26], prosedur *resampling bootstrap* dapat dituliskan sebagai:

1. Mengonstruksi distribusi empiris  $\hat{F}_n$  dari suatu sampel dengan memberikan probabilitas  $1/n$  pada setiap  $x_i$  dimana  $i = 1, 2, \dots, n$ .
2. Mengambil sampel *bootstrap* berukuran  $n$  secara acak dengan pengembalian dari distribusi empiris  $\hat{F}_n$ , sebut sebagai sampel *bootstrap* pertama  $X^{*1}$ .
3. Menghitung statistik  $\hat{\theta}$  yang diinginkan dari sampel *bootstrap*  $X^{*1}$ , sebut sebagai  $\hat{\theta}_1^*$ .
4. Mengulangi langkah 2 dan 3 hingga  $B$  kali, sehingga diperoleh  $\hat{\theta}_1^*, \hat{\theta}_2^*, \dots, \hat{\theta}_B^*$ .
5. Mengonstruksi suatu distribusi probabilitas dari  $\hat{\theta}_B^*$  dengan memberikan probabilitas  $1/B$  pada setiap  $\hat{\theta}_1^*, \hat{\theta}_2^*, \dots, \hat{\theta}_B^*$ . Distribusi tersebut merupakan estimator *bootstrap* untuk distribusi sampling  $\hat{\theta}$  dan dinotasikan dengan  $\hat{F}^*$ .
6. Pendekatan estimasi *bootstrap* untuk  $\hat{\theta}$  adalah rata-rata dari distribusi  $\hat{F}^*$  seperti yang ditampilkan pada persamaan (2.1).

$$\hat{\theta}^* = \sum_{b=1}^B \hat{\theta}_b^* \frac{1}{B} \quad (2.1)$$

### 2.2.4. *Exponential Smoothing Holt-Winter*

Metode *Exponential Smoothing* merupakan prosedur perbaikan terus-menerus pada peramalan terhadap objek pengamatan terbaru [19]. Metode peramalan ini menitik-beratkan pada penurunan prioritas secara eksponensial pada objek pengamatan yang lebih lama. Metode *Exponential Smoothing* adalah kelas metode yang menghasilkan perkiraan dengan formula sederhana, dengan mempertimbangkan *trend* dan efek musiman dari data. Prosedur ini banyak digunakan sebagai teknik peramalan dalam manajemen persediaan dan peramalan penjualan. [7]

Metode Holt-Winter merupakan salah satu variasi dari *Exponential Smoothing*. Metode ini berawal dari Holt (1957) dan Winter (1960) yang memperluas metode Holt untuk menangkap pola musiman dalam data. Metode ini memungkinkan data dimodelkan dengan *mean* lokal, *trend* lokal, dan faktor musiman lokal yang semuanya diperbarui dengan perataan eksponensial. Dalam metode Holt-Winter digunakan persamaan peramalan ( $F_t$ ) dan tiga persamaan pemulusan yang terdiri dari persamaan untuk *level* ( $L_t$ ), *trend* ( $b_t$ ), dan komponen *seasonal* ( $S_t$ ) dengan parameter pemulusan berupa  $\alpha$ ,  $\beta$ , dan  $\gamma$  [27].

Terdapat dua jenis Holt-Winter berdasarkan tipe musimannya, yaitu multiplikatif dan aditif. Hal ini dapat digambarkan seperti operasi dasar penambahan dan perkalian dalam matematika. Untuk penerapannya sendiri metode aditif digunakan apabila komponen musiman bersifat konstan sementara metode multiplikatif digunakan apabila ukuran komponen musiman sebanding dengan tingkat *trend* [28].

Persamaan dasar Holt-Winter dengan tipe musiman multiplikatif [19] seperti ditunjukkan pada persamaan (2.2), (2.3), (2.4), dan (2.5).

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (2.2)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (2.3)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-1} \quad (2.4)$$

$$F_{t+m} = (L_t + b_t m)S_{t-s+m} \quad (2.5)$$

Dimana  $L_t$  adalah *level* pada periode  $t$ ,  $b_t$  adalah *trend* pada periode  $t$ ,  $S_t$  adalah komponen *seasonal* periode  $t$ , dan  $F_{t+m}$  adalah peramalan pada periode  $t+m$ . Sementara  $\alpha$ ,  $\beta$ ,  $\gamma$  menunjukkan parameter pemulusan yang harus bernilai pada interval 0 hingga 1,  $m$  menunjukkan jumlah ramalan ke depan,  $s$  menunjukkan panjang musiman misalnya jumlah bulan atau kuartal dalam setahun, dan  $Y_t$  mewakili data yang diamati pada titik waktu  $t$ .

Untuk menginisiasi *level*, *trend*, dan komponen *seasonal* dapat digunakan rumus pada persamaan (2.6), (2.7), dan (2.8).

$$L_s = \frac{1}{s} \times (Y_1 + Y_2 + \dots + Y_s) \quad (2.6)$$

$$b_s = \frac{1}{s} \times \left( \frac{Y_{s+1} - Y_1}{s} + \frac{Y_{s+2} - Y_2}{s} + \dots + \frac{Y_{s+s} - Y_s}{s} \right) \quad (2.7)$$

$$S_p = \frac{Y_p}{L_s}; \text{ dengan } p = 1, 2, 3, \dots, s \quad (2.8)$$

Sementara untuk persamaan dasar Holt-Winter dengan tipe musiman aditif tidak jauh berbeda dengan persamaan sebelumnya [19] seperti pada persamaan (2.9), (2.10), (2.11), dan (2.12).

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (2.9)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (2.10)$$

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-1} \quad (2.11)$$

$$F_{t+m} = L_t + b_t m + S_{t-s+m} \quad (2.12)$$

Inisiasi nilai *level* dan *trend* pada aditif dilakukan dengan menggunakan rumus yang sama dengan metode multiplikatif. Sementara untuk menginisiasi indeks musiman digunakan rumus pada persamaan (2.13).

$$S_p = Y_p - L_s ; \text{ dengan } p = 1, 2, 3, \dots, s \quad (2.13)$$

Persamaan (2.5) dan (2.12) digunakan untuk menghitung peramalan  $m$  periode ke depan. Persamaan ini hanya berlaku untuk  $m = 1, 2, \dots, s$ . Sementara untuk meramalkan  $m = s + 1, s + 2, \dots, 2s$ , komponen *seasonal* pada persamaan tersebut seharusnya  $S_{t-2s+m}$  [29].

### 2.2.5. Grey Holt-Winter

Perbedaan antara Holt-Winter biasa dan *Grey Holt-Winter* terletak pada *accumulated generating operator*. Pada *Grey Holt-Winter* yang diramalkan merupakan deret yang telah ditransformasi dengan menggunakan *accumulated generating operator*.

*Accumulated generating operator* yang memainkan peran penting dalam teori sistem *Grey*, adalah metode yang digunakan untuk memutihkan proses *Grey*. Melalui akumulasi dapat ditemukan kecenderungan yang ada sehingga karakteristik yang tersembunyi dalam data asli yang kacau dapat diungkap [30]. *Grey generating operator* digunakan untuk memuluskan efek dari gangguan acak pada sistem [31]

Untuk memuluskan keacakan data asli, definisi pada persamaan (2.14) hingga persamaan (2.20).

#### 1. Definisi 1 [30]

Untuk deret waktu asli  $X^{(0)} = \{x^{(0)}_1, x^{(0)}_2, \dots, x^{(0)}_n\}$ , dapat dihasilkan deret *r-order accumulated generating* (r-AGO)  $X^{(r)} = \{x^{(r)}_1, x^{(r)}_2, \dots, x^{(r)}_n\}$  dengan  $r \in R_+$  seperti ditunjukkan pada persamaan (2.14).

$$x^{(r)}_k = \sum_{i=1}^k \frac{k-i+r-1}{k-1} x^{(0)}_i \quad (2.14)$$

Dimana  $k = 1, 2, \dots, n$ , dan  $\frac{r-1}{0} = 1, \frac{k-1}{k} = 0, \frac{k-i+r-1}{k-1} = \frac{(r+k-i-1)(r+k-i-2)\dots(r+1)(r)}{(k-1)!}$ . Sementara *inverse* dari r-AGO

yang disebut *r-order inverse accumulated generating operator* (IAGO) diformulasikan seperti pada persamaan (2.15).

$$\begin{aligned} X^{(-r)} &= ([-r])X^{([r]-r)} \\ &= \{ ([-r])x^{([r]-r)}_1, \\ &\quad ([-r])x^{([r]-r)}_2, \\ &\quad \dots, ([-r])x^{([r]-r)}_n \} \end{aligned} \quad (2.15)$$

Dimana  $[r] = \min \{n \in Z | r \leq n\}$  dan  $([-r])X^{([r]-r)}_k = ([-r])X^{([r]-r)}_k - ([-r])X^{([r]-r)}_{k-1}$ . Secara umum, ketika  $0 < r < 1$ , maka  $r$ -IAGO dari  $X^{(r)}$  dapat dihitung seperti ditunjukkan pada persamaan (2.16).

$$\begin{aligned} X^{(-r)} &= (1)X^{(1-r)} \\ &= \{ (1)x^{(1-r)}_1, (1)x^{(1-r)}_2, \\ &\quad \dots, (1)x^{(1-r)}_n \} \end{aligned} \quad (2.16)$$

Dimana  $(1)x^{(1-r)}_k = (1)x^{(1-r)}_k - (1)x^{(1-r)}_{k-1}$ .

AGO banyak digunakan dalam model *Grey* karena kemampuannya untuk memuluskan keacakan data asli. Dengan menggunakan IAGO, nilai prediksi dapat diubah kembali ke deret semula. Melalui AGO, data yang kacau dapat diubah menjadi bentuk *trend* regular [31]. Contoh  $X^{(0)} = \{6, 4, 7, 5, 6, 4, 10, 9, 11, 10\}$  memiliki deret 0.6-AGO  $X^{(0.6)} = \{6, 7.6, 12.28, 13.61, 16.27, 16.48, 23.29, 26.8, 32.02, 35.18\}$ .

Kemudian peramalan deret dengan *trend* dan musiman dapat menggunakan metode Holt-Winter. [12] Dengan demikian, diberikan definisi kedua.

## 2. Definisi 2 [12]

Untuk deret waktu asli  $X^{(0)} = \{x^{(0)}_1, x^{(0)}_2, \dots, x^{(0)}_n\}$  dan  $r$ -AGO yang diberikan pada definisi 1, maka *Grey Holt-Winter* dapat diformulasikan seperti ditunjukkan pada persamaan (2.17), (2.18), (2.19), dan (2.20).

$$L_t = \alpha \frac{x^{(r)}_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (2.17)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (2.18)$$

$$S_t = \gamma \frac{x^{(r)}_t}{L_t} + (1 - \gamma)S_{t-1} \quad (2.19)$$


$$F^{(r)}_{t+m} = (L_t + b_t m)S_{t-s+m} \quad (2.20)$$

Dimana  $L_t$  adalah *level* pada periode  $t$ ,  $b_t$  adalah *trend* pada periode  $t$ ,  $S_t$  adalah komponen *seasonal* periode  $t$ , dan  $F^{(r)}_{t+m}$  adalah peramalan pada periode  $t+m$ . Sementara  $\alpha$ ,  $\beta$ ,  $\gamma$  menunjukkan parameter pemulusan yang harus bernilai pada interval 0 hingga 1,  $m$  menunjukkan jumlah ramalan ke depan,  $s$  menunjukkan panjang musiman misalnya jumlah bulan atau kuartal dalam setahun, dan  $x^{(r)}_t$  mewakili data yang diamati pada titik waktu  $t$ .

Secara umum, proses penggunaan *Grey Holt-Winter* adalah sebagai berikut [12]:

1. Menentukan nilai operator transformasi ( $r$ ) dan menggunakan persamaan (2.27) untuk memperoleh deret  $r$ -AGO
2. Menghitung parameter  $\alpha$ ,  $\beta$ , dan  $\gamma$  dengan menggunakan definisi 2.
3. Memperoleh nilai yang diramalkan dengan menggunakan peramalan.
4. Mengubah nilai ramalan dari  $F^{(r)}_{t+m}$  menjadi deret original  $\hat{X}^{(0)}$  dengan menggunakan IAGO.

Pada Gambar 2.1 ditampilkan bagan yang menunjukkan mekanisme kerja dari *Grey Holt-Winter*.



**Gambar 2.1 Flow Chart Model *Grey Holt-Winter***

### **2.2.6. *Artificial Neural Network***

*Artificial Neural Network* atau dapat diterjemahkan ke dalam Bahasa Indonesia sebagai Jaringan Saraf Tiruan merupakan merupakan sebuah model yang mengadopsi cara kerja neuron secara biologi dengan fokus pada cara kerja saraf otak [32].


Menurut Haykin [33], *Artificial Neural Network* didefinisikan sebagai sebuah prosesor yang terdistribusi paralel yang mempunyai kecenderungan untuk menyimpan pengetahuan yang didapatkan dari pengalaman dan membuatnya tetap tersedia untuk digunakan. Hal ini

menyerupai kinerja otak asli dalam dua hal, yaitu pengetahuan diperoleh melalui suatu proses belajar, kekuatan hubungan antar sel saraf yang dikenal dengan sinapsis digunakan untuk menyimpan pengetahuan.

Neuron merupakan unit pengolah informasi dasar yang penting untuk operasi *Artificial Neural Network*. Terdapat tiga elemen dasar dari model neuron, yaitu [33]:

1. Satu set sinapsis atau penghubung yang masing-masing digolongkan oleh bobot atau kekuatannya.
2. Sebuah penambah untuk menjumlahkan sinyal-sinyal *input* ditimbang dari kekuatan sinapsis masing-masing neuron.
3. Sebuah fungsi aktivasi untuk membatasi amplitudo *output* dari neuron. Fungsi ini bertujuan membatasi jarak amplitudo yang diperbolehkan oleh sinyal *output* menjadi sebuah angka yang terbatas.

Prinsip *Artificial Neural Network* secara sederhana digambarkan pada Gambar 2.2.



Gambar 2.2 Model Nonlinear Neuron

Dalam istilah matematika, neuron  $k$  dapat dideskripsikan dengan menuliskan pasangan persamaan (2.21) dan (2.22).

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j \quad (2.21)$$

$$y_k = \varphi(u_k + b_k) \quad (2.22)$$

Dimana  $x_1, x_2, \dots, x_m$  adalah sinyal *input*,  $w_1, w_2, \dots, w_{km}$  adalah beban dari neuron  $k$ ,  $u_k$  adalah penggabung linear *output* dari sinyal *input*,  $b_k$  adalah bias,  $\varphi(\cdot)$  adalah fungsi aktivasi, dan  $y_k$  adalah sinyal *output* dari neuron.


Pada *Artificial Neural Network*, neuron-neuron akan dikumpulkan dalam sebuah lapisan yang disebut dengan lapisan neuron atau *neuron layers*. Neuron-neuron pada satu lapisan akan dihubungkan dengan lapisan-lapisan lainnya. Informasi yang didapatkan pada sebuah neuron akan disampaikan ke semua lapisan-lapisan yang ada, mulai dari lapisan masukan sampai dengan lapisan keluaran melalui lapisan tersembunyi (*hidden layer*).

Menurut Haykin [33], secara umum ada tiga jenis arsitektur dari *Artificial Neural Network* yaitu:

#### a. *Single-layer feedforward networks*

Di dalam *Artificial Neural Network* dengan satu layer, neuron-neuron diorganisasikan dalam bentuk layer-layer. Dalam bentuk paling sederhana dari *Artificial Neural Network* dengan satu layer terdapat sebuah *input layer* dari *node* sumber di mana informasi diproyeksikan ke *output layer* dari neuron tapi tidak bisa sebaliknya. Dengan kata lain, jaringan ini adalah tipe *feed forward*. *Input layer* dari *node* sumber tidak dihitung karena tidak ada perhitungan yang dilakukan.

Gambar 2.3 menunjukkan contoh arsitektur *single layer Artificial Neural Network* dengan satu *layer* sebagai *input layer* dan satu *layer* sebagai *output layer*.




Gambar 2.3 Single-Layer Feedforward Networks

#### b. *Multilayer feedforward networks*

Jenis kedua dari *Artificial Neural Network* yang bersifat *feedforward* dibedakan dengan adanya keberadaan satu atau lebih *hidden layer*. *Hidden* disini berarti bagian dari *Artificial Neural Network* ini secara langsung tidak terlihat dari *input* atau *output* dari jaringan tersebut. Fungsi dari *hidden layer* adalah untuk mengintervensi antara *input* eksternal dan *output* dari jaringan dalam cara yang berguna. Dengan menambah satu atau lebih *hidden layer*, jaringan dapat mengeluarkan statistik tingkat tinggi dari *input*.

Sumber *node* di *input layer* dari jaringan menyediakan masing-masing elemen dari pola aktivasi (*vector input*), yang merupakan sinyal *input* yang diaplikasikan ke neuron-neuron

di *layer* kedua (*hidden layer* pertama). Sinyal *output* dari *layer* kedua digunakan sebagai *input-input* ke *layer* ketiga, dan seterusnya sampai ke sisa dari jaringan. Gambar 2.4 menunjukkan *multi-layer network* dengan 10 *input layer*, 4 *hidden layer*, dan 2 *output layer*.




**Gambar 2.4 Multilayer Feedforward Networks**

### c. *Recurrent network*

*Recurrent Artificial Neural Network* berbeda dari *Feedforward Artificial Neural Network* lainnya dengan mempunyai paling tidak satu *feedback loop*. Contohnya, sebuah jaringan *recurrent* bisa terdiri dari neuron *single layer* dengan setiap neuron memberi sinyal *output* kembali ke *input* dari neuron-neuron lainnya.

Adanya *feedback loop* mempunyai pengaruh yang sangat besar kepada kemampuan pembelajaran dari jaringan dan juga performanya. *Feedback loop* melibatkan penggunaan dari cabang-cabang yang terbentuk dari elemen *unit-time*

*delay* (dilambangkan dengan  $Z^{-1}$ ). Gambar 2.5 menunjukkan contoh arsitektur *recurrent Artificial Neural Network* dimana setiap neuron memberi sinyal output kembali ke *input* dari neuron-neuron lainnya.




**Gambar 2.5 Recurrent Networks**

### 2.2.7. Holt-Winter Artificial Neural Network

Holt-Winter *Artificial Neural Network* merupakan penggabungan model peramalan Holt-Winter dan *Artificial Neural Network* [11]. Dimana Holt-Winter digunakan untuk peramalan data aktual sementara *Artificial Neural Network* digunakan untuk peramalan error atau residu yang diperoleh dari Holt-Winter. Penggunaan *Artificial Neural Network* untuk memodelkan residu yang dihasilkan model Holt-Winter karena kemampuannya untuk memodelkan rangkaian waktu nonlinear tanpa *trend* [34].

Gambar 2.6 merupakan bagan yang menjelaskan mekanisme Holt-Winter *Artificial Neural Network*. Holt-Winter digunakan pada tahap awal untuk meramalkan data deret waktu aktual  $y_t$  yang ada sehingga dapat diperoleh hasil peramalan data aktual  $\hat{y}'_{t+1}$ . Dari hasil peramalan yang diperoleh dengan menggunakan Holt-Winter dapat dihitung error atau residu  $r_t$  dengan mencari selisih antara data aktual dan hasil peramalan. Residu  $r_t$  yang diperoleh selanjutnya digunakan untuk membuat model pada *Artificial Neural Network* sehingga dapat diperoleh hasil peramalan residu  $\hat{r}_{t+1}$ . Setelah diperoleh hasil peramalan dari Holt-Winter dan hasil peramalan dari *Artificial Neural Network*, maka mereka dapat digunakan untuk membuat peramalan ke depan yang dengan menjumlahkan  $\hat{y}'_{t+1}$  dan  $\hat{r}_{t+1}$ .



**Gambar 2.6** Mekanisme Holt-Winter *Artificial Neural Network*

Untuk menyempurnakan model Holt-Winter dan melatih residu *Artificial Neural Network*, informasi yang dibutuhkan adalah data deret waktu yang dijelaskan oleh  $Y = \{y_1, y_2, y_3, \dots, y_n\}$  dimana  $y_1, y_2, y_3, \dots, y_n$  merupakan elemen dari deret waktu. Sementara residu disimpan dalam vektor yang didefinisikan sebagai  $r = \{r_1, r_2, r_3, \dots, r_n\}$ . Residu ini diperoleh dengan menggunakan model Holt-Winter seperti yang ditunjukkan pada persamaan (2.23) [11].

$$r_{t+1} = y_{t+1} - \hat{y}'_{t+1} \quad (2.23)$$

Dimana prediksi  $\hat{y}'_{t+1}$  dihasilkan dari persamaan (2.24) [11].

$$\hat{y}'_{t+1} = f_{hw}(y_{t-m}, \dots, y_t) \quad (2.24)$$

Residu  $r$  dimodelkan dengan menggunakan *Artificial Neural Network* seperti yang ditunjukkan pada persamaan (2.25) [11].

$$\hat{r}'_{t+1} = f_{ann}(r_{t-m}, \dots, r_t) \quad (2.25)$$

Ketika peramalan Holt-Winter dan *Artificial Neural Network* telah dimiliki, maka mereka dapat digunakan untuk membuat peramalan ke depan dengan menggunakan persamaan (2.26) [11].

$$\hat{y}_{t+1} = \hat{y}'_{t+1} + \hat{r}_{t+1} \quad (2.26)$$

### 2.2.8. *Windowing*

*Windowing* merupakan salah satu teknik yang dapat digunakan untuk menentukan data *input* dan data *output* dalam prediksi data deret waktu dengan tipe data univariat [35]. Data univariat merupakan distribusi data yang hanya melibatkan satu atribut atau variabel [36]. Dengan menggunakan teknik *windowing*, data univariat dapat dipecah menjadi beberapa data *input* dan satu data *output* atau label. *Windowing* memungkinkan data deret waktu untuk diubah ke dalam format *cross-sectional*. Yaitu, data *input* yang merupakan data beberapa periode sebelumnya dan data *output* yang merupakan data 1 periode berikutnya [35].

Pada Gambar 2.7 merupakan contoh penerapan *windowing* pada data deret waktu univariat, dimana *window size* yang digunakan adalah 6.

Original time series		"Windowed" to cross sectional format					
Row No.	Date	input0	input1	input2	input3	input4	input5
17	May 1, 2010	-0.077					
18	Jun 1, 2010	0.613					
19	Jul 1, 2010	1.845					
20	Aug 1, 2010	1.984					
21	Sep 1, 2010	1.861					
22	Oct 1, 2010	0.661					
23	Nov 1, 2010	0.692					
24	Dec 1, 2010	1.108					
25	Jan 1, 2011	1.688					
26	Feb 1, 2011	2.167					
27	Mar 1, 2011	2.295					
28	Apr 1, 2011	1.577					
29	May 1, 2011	0.601					
30	Jun 1, 2011	1.201					
31	Jul 1, 2011	2.466					
32	Aug 1, 2011	2.497					
33	Sep 1, 2011	2.245					
34	Oct 1, 2011	1.179					
35	Nov 1, 2011	1.119					
36	Dec 1, 2011	1.934					
			input5	input4	input3	input2	input1
	Apr 1, 2010	-0.040	1.381	0.761	2.312	1.795	0.586
	May 1, 2010	1.381	0.761	2.312	1.795	0.586	-0.077
	Jun 1, 2010	0.761	2.312	1.795	0.586	-0.077	0.613
	Jul 1, 2010	2.312	1.795	0.586	-0.077	0.613	1.845
	Aug 1, 2010	1.795	0.586	-0.077	0.613	1.845	1.984
	Sep 1, 2010	0.586	-0.077	0.613	1.845	1.984	1.861
	Oct 1, 2010	-0.077	0.613	1.845	1.984	1.861	0.661
	Nov 1, 2010	0.613	1.845	1.984	1.861	0.661	0.692
	Dec 1, 2010	1.845	1.984	1.861	0.661	0.692	1.108
	Jan 1, 2011	1.984	1.861	0.661	0.692	1.108	1.688
	Feb 1, 2011	1.861	0.661	0.692	1.108	1.688	2.167
	Mar 1, 2011	0.661	0.692	1.108	1.688	2.167	2.295
	Apr 1, 2011	0.692	1.108	1.688	2.167	2.295	1.577
	May 1, 2011	1.108	1.688	2.167	2.295	1.577	0.601
	Jun 1, 2011	1.688	2.167	2.295	1.577	0.601	1.201
	Jul 1, 2011	2.167	2.295	1.577	0.601	1.201	2.466
	Aug 1, 2011	2.295	1.577	0.601	1.201	2.466	2.497
	Sep 1, 2011	1.577	0.601	1.201	2.466	2.497	2.245
	Oct 1, 2011	0.601	1.201	2.466	2.497	2.245	1.179
	Nov 1, 2011	1.201	2.466	2.497	2.245	1.179	1.119
	Dec 1, 2011	2.466	2.497	2.245	1.179	1.119	
							Predicted
							Oct
							Nov
							Dec

Gambar 2.7 Penggunaan *Windowing* pada Data Deret Waktu


Setelah deret waktu diubah menjadi format *cross sectional*, maka data dapat digunakan untuk pemodelan prediktif untuk memprediksi nilai masa depan.

## 2.2.9. Grid Search

Metode *grid search* ialah salah satu metode umum yang sering digunakan untuk estimasi parameter agar mendapatkan hasil yang optimum. Dalam Hidayat [37], Rao menyebutkan metode *grid search* melibatkan penyusunan *grid* yang cocok dalam suatu ruang dimensi, mengevaluasi fungsi objektif dari seluruh titik *grid*, dan menemukan titik *grid* yang sesuai dengan fungsi objektif yang memiliki nilai optimum.

Menurut Wang dalam Yao dkk [38], algoritma *grid search* membagi jangkauan pencarian parameter yang akan dioptimalkan ke dalam *grid* dan melintasi semua titik *grid* untuk mendapatkan nilai optimal. Di dalam Hsu dkk [39], sebuah algoritma *grid search* harus dipandu oleh beberapa metrik kinerja, biasanya diukur dengan *cross validation* pada data pelatihan.

Dalam Naufal [40] dijelaskan mengenai alur yang dipergunakan dalam mencari nilai optimum parameter dalam proses optimasi seperti pada Gambar 2.8.



**Gambar 2.8** Proses Optimasi *Grid Search*

Jika digambarkan, proses dari awal hingga menghasilkan luaran dari parameter dapat dilihat pada Gambar 2.9. [40].



**Gambar 2.9** Proses Peramalan dengan Optimasi Parameter Menggunakan *Grid Search*

### 2.2.10. Akurasi

Ukuran akurasi hasil peramalan merupakan ukuran kesalahan peramalan yang menunjukkan tingkat perbedaan antara hasil peramalan permintaan dengan permintaan yang sebenarnya terjadi.

Dalam semua situasi peramalan terdapat derajat ketidakpastian. Sumber penyimpangan dalam peramalan tidak hanya berasal dari unsur error, tapi juga ketidakmampuan suatu model peramalan mengenali unsur lain dalam deret data. Sehingga, besarnya penyimpangan hasil peramalan dapat disebabkan oleh faktor tidak terduga (*outlier*).

Validasi metode peramalan tidak dapat lepas dari indikator-indikator dalam pengukuran akurasi peramalan. Terdapat sejumlah indikator dalam pengukuran akurasi peramalan, tetapi yang paling umum digunakan adalah *mean absolute deviation*, *mean absolute percentage error*, dan *mean squared error*. Akurasi peramalan akan tinggi apabila nilai-nilai tersebut semakin kecil.

Berikut penjelasan untuk masing-masing ukuran ketepatan ramalan yang digunakan pada pengerjaan tugas akhir ini:

**a. Mean Absolute Deviation (MAD)**

MAD merupakan penjumlahan absolut kesalahan peramalan tanpa menghiraukan tanda aljabarnya dibagi dengan banyaknya data yang diamati. Dalam MAD, kesalahan dengan tanda positif atau negatif akan diberlakukan sama, yang diukur hanya besar kesalahan secara absolut [41]. Tujuan pengabaian ini adalah menghindari ukuran yang bernilai sama dengan nol yang secara statistik kurang bermanfaat. Karena nilai positif dan negatif dapat saling menghapuskan satu sama lain [42]. MAD berguna untuk mengukur kesalahan ramalan dalam unit yang sama sebagai deret asli.

Rumus untuk menghitung MAD dinyatakan seperti pada persamaan (2.27) [41].

$$MAD = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad (2.27)$$

Dimana  $Y_t$  adalah nilai aktual hasil observasi,  $\hat{Y}_t$  adalah nilai hasil peramalan, dan  $t$  menunjukkan periode ke- $t$ .

**b. Mean Squared Error (MSE)**

MSE merupakan penjumlahan kesalahan yang telah dikuadratkan dibagi dengan banyaknya data yang diamati. MSE memperkuat pengaruh dari angka-angka kesalahan peramalan yang besar, tetapi memperkecil pengaruh dari angka-angka kesalahan peramalan yang kecil [41]. Hal ini terjadi karena kesalahan yang ada dikuadratkan.

Rumus untuk menghitung MSE dinyatakan seperti pada persamaan (2.28) [41].

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (2.28)$$

Dimana  $Y_t$  adalah nilai aktual hasil observasi,  $\hat{Y}_t$  adalah nilai hasil peramalan, dan  $t$  menunjukkan periode ke- $t$ .

**c. Mean Absolute Percentage Error (MAPE)**

MAPE merupakan rata-rata kesalahan absolut dari peramalan yang dihasilkan dalam bentuk persentasenya terhadap data aktual. Berbeda dengan pengukuran sebelumnya, MAPE merupakan satu-satunya satuan yang dinyatakan dalam bentuk persen [41]. Pendekatan ini berguna ketika ukuran atau besar variabel ramalan tersebut penting dalam mengevaluasi ketepatan ramalan. MAPE mengindikasikan seberapa besar kesalahan dalam meramal yang dibandingkan dengan nilai data aktual pada deret. MAPE juga dapat digunakan untuk membandingkan ketepatan dari teknik yang sama atau berbeda dalam dua deret yang sangat berbeda dan mengukur ketepatan nilai dugaan model yang dinyatakan dalam bentuk rata-rata persentase absolut kesalahan.

Rumus untuk menghitung MAPE dinyatakan seperti pada persamaan (2.29) [41].

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{Y_t} \quad (2.29)$$

Dimana  $Y_t$  adalah nilai aktual hasil observasi,  $\hat{Y}_t$  adalah nilai hasil peramalan, dan  $t$  menunjukkan periode ke- $t$ .

Tingkat akurasi hasil peramalan berdasarkan nilai MAPE dikelompokkan ke dalam rentang signifikansi tertentu yang menunjukkan seberapa baik hasil peramalan [43]. Rentang hasil tersebut dapat dilihat pada Tabel 2.2.

**Tabel 2.2 Tingkat Signifikansi MAPE**

Persentase MAPE	Tingkat Signifikansi
< 10%	<i>Excellent</i> (hasil peramalan sangat baik)
10 – 20%	<i>Good</i> (hasil peramalan baik)
20 – 50%	<i>Reasonable</i> (hasil peramalan cukup)
> 50%	<i>Bad</i> (hasil peramalan buruk)

**d. Mean Directional Accuracy (MDA)**

MDA merupakan penjumlahan arah hasil peramalan yang sama dengan arah data aktual. MDA adalah ukuran akurasi metode peramalan yang membandingkan antara perkiraan arah ramalan terhadap data aktual, apakah naik atau turun [44]. MDA menunjukkan probabilitas bahwa metode peramalan yang dihasilkan dapat mendeteksi arah deret waktu yang benar antara hasil peramalan dan data aktual.

Rumus untuk menghitung MDA dinyatakan seperti pada persamaan (2.30) [45].


$$MDA = \frac{1}{n} \sum_{t=1}^n 1_{\text{sign}(Y_t - Y_{t-1}) == \text{sign}(\hat{Y}_t - \hat{Y}_{t-1})} \quad (2.30)$$

Dimana  $Y_t$  dan  $Y_{t-1}$  adalah nilai aktual hasil observasi,  $\hat{Y}_t$  dan  $\hat{Y}_{t-1}$  adalah nilai hasil peramalan, dan  $t$  menunjukkan periode ke- $t$ .

*Halaman ini sengaja dikosongkan*

### BAB III METODOLOGI PENELITIAN

Pada bab ini akan dibahas mengenai gambaran metode dan alur pengerjaan tugas akhir. Gambar 3.1 merupakan alur metodologi yang digunakan untuk pengerjaan tugas akhir.



Gambar 3.1 Bagan Metodologi

Berikut merupakan penjelasan dari setiap tahapan yang ada pada metodologi yang digunakan, yaitu:

### **3.1. Identifikasi masalah**

Pada tahapan ini dipilih studi kasus yang akan digunakan dalam tugas akhir untuk dilakukan penggalian dan analisa permasalahan yang ada pada studi kasus tersebut. Dari penggalian dan analisa permasalahan tersebut ditemukan topik permasalahan terkait peramalan jumlah impor beras di Jawa Timur dimana data aktual yang ada memuat banyak nilai nol. Topik permasalahan ini selanjutnya akan digunakan sebagai dasar untuk mencari literatur terkait pada tahapan selanjutnya.

### **3.2. Studi literatur**

Dari permasalahan yang ditemukan pada tahapan sebelumnya, dilakukan studi literatur dengan mengumpulkan berbagai referensi seperti buku pustaka, jurnal atau *paper* pada penelitian sebelumnya, maupun dokumen lainnya, yang sesuai dengan topik permasalahan. Studi literatur ini dimaksudkan untuk lebih mengetahui dasar-dasar teori yang mendukung atau berkaitan dengan permasalahan yang ingin diselesaikan. Studi literatur yang dilakukan terkait penggunaan metode Holt-Winter dan beberapa metode modifikasi Holt-Winter, yaitu *Grey Holt-Winter* dan *Holt-Winter Artificial Neural Network*, untuk peramalan. Selain itu, juga dilakukan pencarian informasi mengenai *tools* yang akan digunakan, yaitu R Studio dan RapidMiner, serta bagaimana membangun sebuah model pada *tools* yang digunakan sesuai dengan kebutuhan dalam penelitian tugas akhir ini.

### **3.3. Pengumpulan data**

Setelah menentukan metode berdasarkan studi literatur dan mendapatkan dasar teori yang cukup dari tahap sebelumnya, maka dilakukan tahap selanjutnya yaitu pengumpulan data. Data merupakan pendukung utama dalam

terlaksananya tugas akhir ini. Oleh karena itu dibutuhkan pengumpulan data yang sesuai dengan topik dan batasan permasalahan yang diambil. Pada tugas akhir ini, data yang diperoleh merupakan data jumlah impor beras di Jawa Timur dalam bentuk periode bulanan sejak Januari 2002 hingga Desember 2016 dimana dalam data tersebut memuat banyak nilai nol. Data yang diperoleh ini selanjutnya akan diolah terlebih dahulu dengan menggunakan metode *bootstrap* untuk mengisi data yang kosong pada tahap selanjutnya sebelum data dapat digunakan untuk membuat model peramalan.

### 3.4. Persiapan data

Dari data yang diperoleh pada tahapan sebelumnya dilakukan perbaikan pada data. Perbaikan pada data ini berupa pengisian data yang kosong dengan menggunakan proses *bootstrap* untuk mengatasi permasalahan dimana data mengandung banyak nilai nol. *Bootstrap* dilakukan untuk mengisi nilai nol yang ada pada data aktual dengan distribusi yang diperoleh dari pengambilan sampel dengan pengembalian dari sampel hasil observasi dengan replikasi B kali dan n ukuran sampel. Tahapan dasar melakukan *bootstrap* dijelaskan pada bagian 2.2.3. Sementara untuk membantu menerapkan metode ini dapat digunakan *tools* R Studio.

Penerapan *bootstrap* ini dilakukan dengan menggunakan dua skenario, yaitu dengan langsung menggunakan data asli dan dengan menggunakan data hasil transformasi. Setelah menerapkan proses *bootstrap* akan diperoleh dua set data jumlah impor beras dengan nilai nol yang telah terisi dengan nilai dari distribusi *bootstrap*, sehingga data ini dapat diramalkan dengan menggunakan metode Holt-Winter dan modifikasi Holt-Winter berupa *Grey Holt-Winter* dan *Holt-Winter Artificial Neural Network* pada tahapan selanjutnya.

### 3.5. Pembuatan model untuk peramalan

Dari data hasil proses *bootstrap* dengan data asli dan data transformasi dilakukan pembagian data menjadi data pelatihan dan data pengujian dengan beberapa proporsi berbeda sebagai perbandingan. Proporsi yang digunakan antara lain 85:15, 70:30, dan 50:50. Selanjutnya data akan digunakan untuk membuat model Holt-Winter dan modifikasi Holt-Winter berupa *Grey Holt-Winter* dan *Holt-Winter Artificial Neural Network*.

#### 3.5.1. Pembuatan Model Holt-Winter

Pembuatan model Holt-Winter dilakukan dengan menentukan nilai parameter pemulusan  $\alpha$ ,  $\beta$ , dan  $\gamma$  yang paling optimal. Setelah diperoleh nilai parameter pemulusan paling optimal, maka dapat dilakukan peramalan dengan menggunakan model Holt-Winter untuk periode ke depan. Tahapan dan rumus yang digunakan untuk peramalan dengan Holt-Winter dijelaskan pada bagian 2.2.4. Hasil peramalan yang dihasilkan akan diukur akurasinya pada tahap selanjutnya untuk dibandingkan dengan penggunaan model lainnya.

#### 3.5.2. Pembuatan Model *Grey Holt-Winter*

Pembuatan model *Grey Holt-Winter* dilakukan dengan menentukan nilai  $r$  sebagai operator transformasi untuk membentuk baris data *r-order accumulated generating* ( $r$ -AGO) serta nilai parameter pemulusan  $\alpha$ ,  $\beta$ , dan  $\gamma$  yang paling optimal.

Baris  $r$ -AGO yang diperoleh digunakan sebagai *input* untuk Holt-Winter. Setelah diperoleh nilai parameter pemulusan paling optimal, maka dapat dilakukan peramalan dengan menggunakan model Holt-Winter untuk periode ke depan. Data hasil peramalan yang diperoleh selanjutnya dapat dikembalikan ke baris semula dengan menggunakan *r-order inverse accumulated generating operation* (IAGO). Tahapan dan rumus yang digunakan untuk peramalan dengan *Grey Holt-Winter* dijelaskan pada bagian 2.2.5.

Hasil peramalan yang dihasilkan akan diukur akurasi pada tahap selanjutnya untuk dibandingkan dengan penggunaan model lainnya.

### **3.5.3. Pembuatan Model Holt-Winter *Artificial Neural Network***

Pemodelan Holt-Winter *Artificial Neural Network* merupakan kombinasi peramalan data aktual menggunakan Holt-Winter dan peramalan residu yang diperoleh menggunakan *Artificial Neural Network*. Untuk pembuatan model Holt-Winter dilakukan dengan menentukan nilai parameter pemulusan  $\alpha$ ,  $\beta$ , dan  $\gamma$  yang paling optimal. Setelah diperoleh nilai parameter pemulusan paling optimal, maka dapat dilakukan peramalan dengan menggunakan model Holt-Winter untuk periode ke depan. Tahapan dan rumus yang digunakan untuk peramalan dengan Holt-Winter dijelaskan pada bagian 2.2.4. Hasil peramalan yang dihasilkan akan dihitung erornya. Error atau residu yang diperoleh selanjutnya digunakan sebagai *input* untuk *Artificial Neural Network*.

Pembuatan model *Artificial Neural Network* dilakukan dengan proses pelatihan untuk memperoleh jumlah *hidden layer*, *training cycle*, *learning rate*, dan *momentum* yang paling optimal. Setelah diperoleh model terbaik, maka dapat dilakukan peramalan terhadap eror dengan menggunakan model *Artificial Neural Network* untuk periode ke depan. Tahapan yang digunakan untuk peramalan dengan Holt-Winter *Artificial Neural Network* dijelaskan pada bagian 2.2.7.

Hasil peramalan jumlah impor dengan Holt-Winter dan hasil peramalan eror dengan *Artificial Neural Network* selanjutnya dijumlahkan untuk memperoleh peramalan jumlah impor dengan Holt-Winter *Artificial Neural Network*. Hasil peramalan yang dihasilkan akan diukur akurasi pada tahap selanjutnya untuk dibandingkan dengan penggunaan model lainnya.

### **3.6. Pengukuran akurasi**

Dari tahapan sebelumnya diperoleh hasil peramalan untuk setiap kombinasi penggunaan transformasi, perbandingan data pelatihan dan pengujian, serta penerapan metode yang ada. Hasil peramalan yang telah diperoleh, selanjutnya akan dilakukan perbandingan antara hasil peramalan tersebut dengan data historisnya. Untuk mengetahui ketepatan hasil ramalan yang dihasilkan menggunakan metode yang diusulkan, dilakukan penghitungan tingkat akurasi dan kesalahan dilakukan dengan menggunakan ukuran MAD, MSE, MAPE, dan MDA. Rumus untuk menghitung ukuran akurasi tersebut sesuai dengan yang telah disebutkan pada bagian 2.2.10.

Tingkat akurasi yang diperoleh oleh setiap kombinasi selanjutnya akan dibandingkan untuk memilih model terbaik untuk peramalan 2 tahun ke depan.

### **3.7. Pemilihan model terbaik**

Tingkat akurasi yang telah diperoleh oleh setiap kombinasi selanjutnya dibandingkan untuk mengetahui model yang menghasilkan tingkat kesalahan paling kecil pada data pelatihan. Model yang dipilih selanjutnya akan digunakan untuk meramalkan data 2 tahun ke depan. Hasil peramalan yang diperoleh akan dianalisis pada tahap selanjutnya.

### **3.8. Analisis hasil dan penarikan kesimpulan**

Berdasarkan perbandingan data aktual dan hasil peramalan yang diperoleh serta tingkat akurasi dan kesalahan yang dihasilkan, maka dapat dilakukan analisis untuk membantu dalam penarikan kesimpulan. Kesimpulan ini nantinya dapat membantu memberikan sumbangan pemikiran pada peneliti maupun perusahaan dalam pengambilan keputusan terkait peramalan pada data intermiten agar hasil peramalannya menjadi lebih baik.

### **3.9. Penyusunan buku tugas akhir**

Tahapan terakhir adalah penyusunan buku tugas akhir sebagai bentuk dokumentasi atas terlaksananya tugas akhir ini. Di dalam buku tersebut mencakup:

a. Bab I Pendahuluan

Dalam bab ini dijelaskan mengenai latar belakang masalah, perumusan masalah, batasan masalah, tujuan tugas akhir, dan manfaat kegiatan tugas akhir untuk memberi gambaran umum permasalahan dan pemecahan masalah pada tugas akhir.

b. Bab II Tinjauan Pustaka

Dalam bab ini dijelaskan mengenai penelitian serupa yang telah dilakukan sebelumnya dan dasar teori yang menunjang permasalahan yang dibahas pada tugas akhir sebagai acuan atau landasan dalam pengerjaan tugas akhir ini.

c. Bab III Metodologi

Dalam bab ini dijelaskan mengenai gambaran metode dan alur pengerjaan yang dilakukan pada tugas akhir ini.

d. Bab IV Perancangan

Dalam bab ini dijelaskan mengenai rancangan penelitian tugas akhir untuk membuat model peramalan, mulai dari pengumpulan data, persiapan data, pengolahan data, pemodelan, dan proses peramalan.

e. Bab V Implementasi

Dalam bab ini dijelaskan mengenai proses pelaksanaan penelitian dan pembuatan model yang digunakan untuk peramalan berdasarkan perancangan yang telah dibuat sebelumnya.

f. Bab VI Hasil dan Pembahasan

Dalam bab ini dijelaskan mengenai hasil serta analisis terhadap hasil yang diperoleh dari proses implementasi yang telah dibahas pada bab sebelumnya.

g. Bab VII Kesimpulan dan Saran

Dalam bab ini dijelaskan mengenai kesimpulan dari semua proses yang telah dilakukan dan saran yang dapat diberikan untuk pengembangan yang lebih baik.

## **BAB IV PERANCANGAN**

Pada bab ini akan dibahas mengenai rancangan penelitian tugas akhir untuk membuat model peramalan. Bab ini berisikan proses mulai dari pengumpulan data, persiapan data, pengolahan data, pemodelan, dan proses peramalan.

### **4.1. Pengumpulan Data**

Pada penelitian tugas akhir ini digunakan data jumlah impor beras di wilayah Jawa Timur yang memiliki proporsi nilai nol yang besar atau dapat disebut sebagai data intermiten. Data tersebut diperoleh dari tugas akhir Unsa Rokhiti (Sistem Informasi ITS 2013) yang berjudul “Peramalan Impor Beras Menggunakan Metode Campuran *Autoregressive Integrated Moving Average Exogeneous Input Adaptive Neuro Fuzzy* (ARIMAX-ANFIS) Studi Kasus : Instansi XYZ”.

Data jumlah impor beras tersebut disajikan dalam bentuk periode bulanan dengan kurun waktu mulai dari Januari 2002 hingga Desember 2016, sehingga terdapat sebanyak 180 baris data. Pada data tersebut terdapat atribut yang terdiri dari bulan, tahun, serta jumlah impor beras dalam satuan ton.

### **4.2. Persiapan Data**

Persiapan data bertujuan agar data yang diperoleh dapat digunakan untuk proses pembuatan model peramalan. Pada tahap persiapan data ini dilakukan perbaikan pada data berupa pengisian data yang kosong dengan menggunakan metode *bootstrap*. Penerapan *bootstrap* untuk mengisi data yang kosong dapat dilakukan dengan menggunakan R Studio. Sementara untuk proses penerapannya sendiri digunakan dua skenario, yaitu dengan langsung menggunakan data asli dan dengan menggunakan data hasil transformasi menggunakan fungsi  $\ln(X_t+1)$  [46]. Suatu kumpulan data perlu dilakukan transformasi untuk memperbaiki asumsi normalitas, linearitas, homogenitas varians [47].

### 4.3. Perancangan Model

Dalam perancangan pemodelan, data perlu dibagi menjadi data pelatihan (*training set*) dan data pengujian (*testing set*). Pembagian ini dilakukan dengan menggunakan perbandingan data pelatihan sebesar 85% dan data pengujian sebesar 15% dari total keseluruhan data sebanyak 180 baris data. Sehingga data pelatihan akan berjumlah sebanyak 153 baris data, yaitu data dari Januari 2002 hingga September 2014. Sementara data pengujian akan berjumlah sebanyak 27 baris data, yaitu data dari Oktober 2014 hingga Desember 2016.

Sebagai pembanding lainnya juga dilakukan pembagian dengan menggunakan perbandingan data pelatihan sebesar 70% dan data pengujian sebesar 30% serta perbandingan data pelatihan sebesar 50% dan data pengujian sebesar 50%. Sehingga untuk perbandingan data pelatihan sebesar 70% dan data pengujian sebesar 30% diperoleh data pelatihan berjumlah sebanyak 126 baris data, yaitu data dari Januari 2002 hingga Juni 2012, dan data pengujian berjumlah sebanyak 54 baris data, yaitu data dari Juli 2012 hingga Desember 2016. Sementara untuk perbandingan data pelatihan sebesar 50% dan data pengujian sebesar 50% diperoleh data pelatihan berjumlah sebanyak 90 baris data, yaitu data dari Januari 2002 hingga Juni 2009, dan data pengujian berjumlah sebanyak 90 baris data, yaitu data dari Juli 2009 hingga Desember 2016

Dari beberapa kombinasi antara penggunaan transformasi dan perbandingan data pelatihan dan pengujian, selanjutnya data akan digunakan untuk membuat model Holt-Winter, *Grey Holt-Winter*, dan *Holt-Winter Artificial Neural Network* untuk meramalkan periode ke depan.

#### 4.3.1. Perancangan Model Holt-Winter

Rancangan pemodelan Holt-Winter yang digunakan dalam penelitian tugas akhir ini terdiri dari panjang periode *seasonal* ( $s$ ) dan parameter yang digunakan dalam Holt-Winter, yaitu parameter pemulusan untuk *level* ( $\alpha$ ), parameter

pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ).

Panjang periode *seasonal* ( $s$ ) menunjukkan pola musiman yang terjadi pada data ditentukan sebanyak 12 bulan. Penentuan nilai 12 bulan ini didasarkan pada asumsi pola perulangan musiman yang terjadi pada data. Sementara untuk tiga parameter pemulusan akan ditentukan dengan proses *trial and error* dalam rentang nilai antara 0 hingga 1.

Rincian rancangan model Holt-Winter yang digunakan untuk meramalkan jumlah impor beras di Jawa Timur dapat dilihat pada Tabel 4.1.

**Tabel 4.1 Rancangan Model Holt-Winter**

<b>Parameter</b>	<b>Jumlah</b>	<b>Keterangan</b>
Panjang periode <i>seasonal</i> ( $s$ )	12 periode	Pola musiman pada data berulang setiap 12 periode.
Parameter pemulusan <i>level</i> ( $\alpha$ )	<i>Trial and error</i>	Bernilai antara 0 hingga 1.
Parameter pemulusan <i>trend</i> ( $\beta$ )	<i>Trial and error</i>	Bernilai antara 0 hingga 1.
Parameter pemulusan <i>seasonal</i> ( $\gamma$ )	<i>Trial and error</i>	Bernilai antara 0 hingga 1.

#### 4.3.2. Perancangan Model *Grey Holt-Winter*

Rancangan pemodelan *Grey Holt-Winter* yang digunakan dalam penelitian tugas akhir ini terdiri dari operator transformasi ( $r$ ) untuk membentuk baris data *r-order accumulated generating operation* ( $r$ -AGO), panjang periode *seasonal* ( $s$ ), dan parameter yang digunakan dalam Holt-Winter, yaitu parameter pemulusan untuk *level* ( $\alpha$ ), parameter

pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ).

Operator transformasi ( $r$ ) dapat memiliki nilai pada rentang bilangan real positif. Untuk pemodelan pada tugas akhir ini, nilai operator transformasi ( $r$ ) ditentukan dengan proses *trial and error* dalam rentang nilai antara 0.01 hingga 0.05. Untuk panjang periode *seasonal* ( $s$ ) yang menunjukkan pola musiman yang terjadi ditentukan sebanyak 12 bulan. Penentuan nilai 12 bulan ini didasarkan pada asumsi pola perulangan musiman yang terjadi pada data. Sementara untuk tiga parameter pemulusan akan ditentukan dengan proses *trial and error* dalam rentang nilai antara 0 hingga 1.

Rincian rancangan model *Grey Holt-Winter* yang digunakan untuk meramalkan jumlah impor beras di Jawa Timur dapat dilihat pada Tabel 4.2.

**Tabel 4.2 Rancangan Model *Grey Holt-Winter***

<b>Parameter</b>	<b>Jumlah</b>	<b>Keterangan</b>
Operator transformasi ( $r$ )	<i>Trial and error</i>	Bernilai antara 0.01 dan 0.05.
Panjang periode <i>seasonal</i> ( $s$ )	12 periode	Pola musiman pada data berulang setiap 12 periode.
Parameter pemulusan <i>level</i> ( $\alpha$ )	<i>Trial and error</i>	Bernilai antara 0 hingga 1.
Parameter pemulusan <i>trend</i> ( $\beta$ )	<i>Trial and error</i>	Bernilai antara 0 hingga 1.
Parameter pemulusan <i>seasonal</i> ( $\gamma$ )	<i>Trial and error</i>	Bernilai antara 0 hingga 1.

### 4.3.3. Perancangan Model Holt-Winter *Artificial Neural Network*

Pembuatan model Holt-Winter *Artificial Neural Network* diawali dengan pembuatan model Holt-Winter terlebih dahulu untuk meramalkan data aktual dilanjutkan dengan penghitungan eror atau residu yang diperoleh dari peramalan dengan Holt-Winter untuk digunakan sebagai dalam pemodelan menggunakan *Artificial Neural Network*. Tahapan yang digunakan untuk peramalan dengan Holt-Winter *Artificial Neural Network* dijelaskan pada bagian 2.2.7.

Rancangan pemodelan Holt-Winter *Artificial Neural Network* yang digunakan dalam penelitian tugas akhir ini terdiri dari parameter dari Holt-Winter dan parameter dari *Artificial Neural Network*. Untuk parameter Holt-Winter terdiri dari panjang periode *seasonal* ( $s$ ), dan parameter yang digunakan dalam Holt-Winter, yaitu parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ). Sementara untuk parameter *Artificial Neural Network* terdiri dari *input layer*, *hidden layer*, *output layer*, *training cycle*, *learning rate*, dan *momentum*.

Panjang periode *seasonal* ( $s$ ) yang menunjukkan pola musiman yang terjadi ditentukan sebanyak 12 bulan. Penentuan nilai 12 bulan ini didasarkan pada asumsi pola perulangan musiman yang terjadi pada data. Sementara untuk tiga parameter pemulusan akan ditentukan dengan proses *trial and error* dalam rentang nilai antara 0 hingga 1. Dari model Holt-Winter akan diperoleh selisih antara data aktual dan hasil peramalan yang selanjutnya akan digunakan sebagai *input* dari *Artificial Neural Network*.

*Hidden layer* dari model ditentukan sebanyak satu lapisan dengan jumlah *neuron* pada *hidden layer* ditentukan berdasarkan proses *trial and error* dalam rentang 1 hingga 10 *neuron*. Sementara *output layer* ditentukan sebanyak 1 *neuron output* yaitu ramalan nilai eror.

Rincian rancangan model Holt-Winter *Artificial Neural Network* yang digunakan untuk meramalkan jumlah impor beras di Jawa Timur dapat dilihat pada Tabel 4.3.

**Tabel 4.3 Rancangan Model Holt-Winter *Artificial Neural Network***

<b>Parameter</b>	<b>Jumlah</b>	<b>Keterangan</b>
Panjang periode <i>seasonal</i> ( $s$ )	12 periode	Pola musiman pada data berulang setiap 12 periode.
Parameter pemulusan <i>level</i> ( $\alpha$ )	<i>Trial and error</i>	Bernilai antara 0 hingga 1.
Parameter pemulusan <i>trend</i> ( $\beta$ )	<i>Trial and error</i>	Bernilai antara 0 hingga 1.
Parameter pemulusan <i>seasonal</i> ( $\gamma$ )	<i>Trial and error</i>	Bernilai antara 0 hingga 1.
<i>Input layer</i>	12 neuron	Data yang digunakan merupakan data <i>univariate</i> deret waktu sehingga perlu dilakukan <i>windowing</i> dengan <i>window</i> sebesar 12. Sehingga atribut yang dihasilkan sebagai <i>input</i> sebanyak 12.
<i>Hidden layer</i>	<i>Trial and error</i>	Terdapat 1 <i>hidden layer</i> dengan jumlah neuron di dalamnya

Parameter	Jumlah	Keterangan
		sebanyak 1 hingga 10 neuron.
<i>Output layer</i>	1 neuron	Ramalan nilai eror
<i>Training cycle</i>	<i>Trial and error</i>	100, 300, 500.
<i>Learning rate</i>	<i>Trial and error</i>	Bernilai antara 0.1 hingga 0.9.
<i>Momentum</i>	<i>Trial and error</i>	Bernilai antara 0.1 hingga 0.9.

#### 4.4. Peramalan Data

Dari tahapan sebelumnya, diperoleh model terbaik dari Holt-Winter, *Grey Holt-Winter*, dan *Holt-Winter Artificial Neural Network* untuk meramalkan periode ke depan terhadap masing-masing kombinasi antara penggunaan transformasi serta perbandingan data pelatihan dan pengujian. Masing-masing model dihitung tingkat akurasi dengan menggunakan ukuran MAD, MSE, MAPE, dan MDA untuk data pelatihan dan data pengujian. Sementara untuk mendapatkan model terbaik ditentukan berdasarkan nilai MAD, MSE, dan MAPE yang paling rendah. Model dengan MAD, MSE, dan MAPE paling rendah akan digunakan untuk meramalkan periode selanjutnya.

Model terbaik yang telah dipilih akan digunakan untuk melakukan peramalan terhadap data dengan jangka waktu 2 tahun ke depan. Data aktual dan hasil peramalan yang diperoleh selanjutnya akan digambarkan pada sebuah grafik untuk dilihat perbandingannya dan dianalisa lebih lanjut.

*Halaman ini sengaja dikosongkan*

## **BAB V**

### **IMPLEMENTASI**

Pada bab ini akan dibahas mengenai proses pelaksanaan penelitian dan pembuatan model yang digunakan untuk peramalan berdasarkan perancangan yang telah dibuat sebelumnya.

#### **5.1. Pengisian Nilai Nol**

Dari data jumlah impor beras di wilayah Jawa Timur yang disajikan dalam bentuk periode bulanan dengan kurun waktu mulai dari Januari 2002 hingga Desember 2016, diketahui bahwa data terdiri dari 180 baris data dengan jumlah data bernilai bukan nol sebanyak 55 baris data atau sebesar 30.6% dan data bernilai nol sebanyak 125 baris data atau sebesar 69.4%. Untuk data asli jumlah impor beras di wilayah Jawa Timur dapat dilihat pada LAMPIRAN A.


Pada data diketahui terdapat gap antara data nol dan data bukan nol. Gap tersebut dapat dilihat pada Tabel 5.1.

**Tabel 5.1 Panjang Gap Data Nol Pada Jumlah Impor Beras Jawa Timur**

<b>Gap</b>	<b>Jumlah</b>
1 data nol berturut-turut	2 kali
3 data nol berturut-turut	1 kali
4 data nol berturut-turut	2 kali
5 data nol berturut-turut	2 kali
10 data nol berturut-turut	1 kali
19 data nol berturut-turut	1 kali
34 data nol berturut-turut	1 kali
39 data nol berturut-turut	1 kali

Berdasarkan Tabel 5.1 diketahui bahwa gap data nol terpanjang pada data jumlah impor beras Jawa Timur adalah 39 data nol berturut-turut. Hal ini terjadi pada periode November 2003 hingga Januari 2007.

Pada Gambar 5.1 merupakan grafik yang menampilkan data jumlah impor mentah dalam satuan ton mulai periode Januari 2002 hingga Desember 2016.



**Gambar 5.1 Jumlah Impor Beras Aktual**

Melihat banyaknya nilai yang kosong pada data, maka perlu dilakukan perbaikan pada data. Perbaikan yang dilakukan disini adalah dengan cara melakukan pengisian pada data yang kosong dengan menggunakan metode *bootstrap*.

Pada pengerjaan tugas akhir ini ditentukan dua skenario proses penerapan *bootstrap* sebagai perbandingan, yaitu dengan langsung menggunakan data asli tanpa transformasi dan dengan menggunakan data hasil transformasi fungsi  $\ln(X_t+1)$  [46]. Suatu kumpulan data perlu dilakukan transformasi untuk memperbaiki asumsi normalitas, linearitas, homogenitas varians [47].

Penggunaan dua skenario ini dilakukan untuk mengetahui perbandingan hasil yang diberikan serta untuk mengetahui apakah transformasi memberikan dampak pada hasil peramalan. Untuk transformasi data sendiri dilakukan dengan memanfaatkan *tools* Microsoft Excel.

Penerapan *bootstrap* untuk mengisi data yang kosong dilakukan dengan package menggunakan *tools* R Studio dan memanfaatkan *package* MICE. Dengan menggunakan *package* MICE dapat dilakukan beberapa imputasi untuk data yang hilang. Pada Gambar 5.2 ditunjukkan *script* yang digunakan

untuk melakukan pengisian data nol dengan menggunakan *package* MICE pada R Studio.

```

1 library(mice)
2
3 input <- read.csv('Book1.csv')
4 input$Impor[input$Impor == 0] <- NA
5
6 output <- mice(input, m=50, maxit = 100, method = 'pmm', seed = 500)
7
8 for (i in 1:50) {
9   assign(paste("a", i, sep = ""), complete(output,i))
10 }
11
12 tbls <- list(a1, a2, a3, a4, a5, a6, a7, a8, a9, a10,
13            a11, a12, a13, a14, a15, a16, a17, a18, a19, a20,
14            a21, a22, a23, a24, a25, a26, a27, a28, a29, a30,
15            a31, a32, a33, a34, a35, a36, a37, a38, a39, a40,
16            a41, a42, a43, a44, a45, a46, a47, a48, a49, a50)
17
18 for (i in seq_along(tbls)){
19   names(tbls[[i]])[2] <- i
20 }
21
22 bundle <- Reduce(function(...) merge(..., all = TRUE, by = "Periode"), tbls)
23
24 bundle["Average"] <- rowMeans(subset(bundle, select = c(2:51)), na.rm = TRUE)
25
26 write.csv(bundle, file = "Bootstrap.csv", row.names = FALSE)

```

**Gambar 5.2 Script Pengisian Data Nol Menggunakan MICE**

Berdasarkan Gambar 5.2, diketahui bahwa pada baris 1 dilakukan pemanggilan *package* MICE agar dapat digunakan untuk melakukan pengisian data. Selanjutnya pada baris 3 data dari sebuah file berekstensi CSV (*Comma Separated Values*) dibaca untuk selanjutnya disimpan dan diolah menggunakan R Studio. Dalam File CSV tersebut terdapat 2 buah atribut, yaitu periode dan jumlah impor total seperti yang ditampilkan pada Gambar 5.3.

	A	B
1	Periode	Impor
2	1	0.00
3	2	0.00
4	3	0.00
5	4	0.00
6	5	49700.00
7	6	24793.80
8	7	10600.00
9	8	0.00
10	9	15800.00

**Gambar 5.3 Contoh Isi File CSV untuk Input MICE**


Selanjutnya pada baris 4, data dengan nilai 0 diubah menjadi bernilai NA. Hal ini dilakukan agar MICE dapat melakukan imputasi pada data berdasarkan distribusi data yang ada. Pada baris 6 dilakukan pemanggilan MICE dengan pengaturan seperti yang tertulis pada *script* di Gambar 5.2. *Input* menunjukkan *data frame* yang digunakan yaitu yang memiliki data nol, *m* menunjukkan jumlah imputasi yang dilakukan, *maxit* menunjukkan jumlah iterasi yang dilakukan, *method* menunjukkan metode imputasi yang digunakan, dan *seed* menunjukkan nilai untuk mengimbangi generator bilangan acak. Pada pengerjaan tugas akhir ini digunakan  $m = 50$ ,  $maxit = 100$ ,  $seed = 500$ , dan metode *predictive mean matching*, sehingga nantinya akan dihasilkan 50 data set hasil pengisian data nol berdasarkan iterasi dan metode yang digunakan.

Pada baris 8 hingga 22 dilakukan penggabungan 50 set data hasil imputasi yang telah diperoleh ke dalam satu *data frame*. Sementara pada baris 24 dilakukan penghitungan rata-rata dari dari tiap baris hasil imputasi yang telah digabung. Hasil penghitungan nilai rata-rata ini nantinya merupakan hasil pengisian data nol yang akan digunakan untuk pemodelan peramalan. Selanjutnya pada baris 26, hasil yang telah diperoleh akan disimpan ke dalam sebuah file dengan ekstensi CSV. Contoh isi dari file CSV tersebut ditampilkan pada Gambar 5.4.

	A	B	C	D	E	F	G	H	I	J	K
1	Periode	1	2	3	4	5	6	7	8	9	10
2	1	8500	41275	24793.8	24793.8	49700	10600	10600	21000	10600	8500
3	2	13500	24793.8	24793.8	49700	24793.8	15800	41275	6700	15800	43243
4	3	13500	24793.8	20450	41275	10600	49700	41275	37650	49700	43243
5	4	13500	10600	15800	24793.8	15800	49700	24793.8	37000	41275	8500
6	5	49700	49700	49700	49700	49700	49700	49700	49700	49700	49700
7	6	24793.8	24793.8	24793.8	24793.8	24793.8	24793.8	24793.8	24793.8	24793.8	24793.8
8	7	10600	10600	10600	10600	10600	10600	10600	10600	10600	10600
9	8	13500	20450	43243	10600	41275	41275	49700	37650	24793.8	13500
10	9	15800	15800	15800	15800	15800	15800	15800	15800	15800	15800
11	10	41275	41275	41275	41275	41275	41275	41275	41275	41275	41275


Gambar 5.4 Contoh Isi File CSV *Output* Pengisian Data Nol

Pada Gambar 5.5 ditampilkan grafik perbandingan antara data aktual tanpa transformasi dan hasil pengisian data nol dengan menggunakan data tanpa transformasi.



**Gambar 5.5 Hasil *Bootstrapping* Tanpa Transformasi**

Sementara pada Gambar 5.6 ditampilkan grafik perbandingan antara data aktual dengan transformasi dan data hasil pengisian data nol dengan menggunakan data dengan transformasi.



**Gambar 5.6 Hasil *Bootstrapping* Tanpa Transformasi**

Untuk data lengkap hasil pengisian data kosong dengan menggunakan MICE dapat dilihat pada LAMPIRAN B, baik

dengan menggunakan transformasi maupun tanpa menggunakan transformasi.

## 5.2. Pembagian Data Pelatihan dan Pengujian

Setelah data kosong terisi, data selanjutnya dibagi menjadi menjadi dua, yaitu data pelatihan (*training set*) dan data pengujian (*testing set*). Data pelatihan digunakan untuk membuat model peramalan, sementara data pengujian digunakan untuk menguji model yang telah didapatkan.

Pembagian data pelatihan dan pengujian dilakukan dengan menggunakan perbandingan data pelatihan sebesar 85% dan data pengujian sebesar 15% dari total keseluruhan data sebanyak 180 baris data. Sehingga data pelatihan berjumlah sebanyak 153 baris data, yaitu data dari Januari 2002 hingga September 2014. Sementara data pengujian berjumlah sebanyak 27 baris data, yaitu data dari Oktober 2014 hingga Desember 2016. Sebagai pembanding lainnya juga dilakukan pembagian dengan menggunakan perbandingan data pelatihan sebesar 70% dan data pengujian sebesar 30% serta perbandingan data pelatihan sebesar 50% dan data pengujian sebesar 50%. Hal ini dilakukan untuk mengetahui perbandingan hasil yang diberikan serta untuk mengetahui apakah perbedaan pembagian data memberikan dampak pada hasil peramalan.

Untuk perbandingan data pelatihan sebesar 70% dan data pengujian sebesar 30% diperoleh data pelatihan berjumlah sebanyak 126 baris data, yaitu data dari Januari 2002 hingga Juni 2012, dan data pengujian berjumlah sebanyak 54 baris data, yaitu data dari Juli 2012 hingga Desember 2016. Sementara untuk perbandingan data pelatihan sebesar 50% dan data pengujian sebesar 50% diperoleh data pelatihan berjumlah sebanyak 90 baris data, yaitu data dari Januari 2002 hingga Juni 2009, dan data pengujian berjumlah sebanyak 90 baris data, yaitu data dari Juli 2009 hingga Desember 2016.

Pada Tabel 5.2 ditunjukkan ringkasan pembagian data pelatihan dan pengujian yang dilakukan pada tugas akhir ini.

Tabel 5.2 Pembagian Data Pelatihan dan Data Pengujian

Perbandingan Pembagian Data	Jenis Data	Jumlah	Periode
50 : 50	Pelatihan	90	Januari 2002 - Juni 2009
	Pengujian	90	Juli 2009 - Desember 2016
70 : 30	Pelatihan	126	Januari 2002 - Juni 2012
	Pengujian	54	Juli 2012 - Desember 2016
85 : 15	Pelatihan	153	Januari 2002 - September 2014
	Pengujian	27	Oktober 2014 - Desember 2016

### 5.3. Pemodelan Holt-Winter

Pembuatan model Holt-Winter dalam penelitian tugas akhir ini dilakukan dengan memanfaatkan *tools* Microsoft Excel.

#### 5.3.1. Inisialisasi

Sebelum dapat melakukan peramalan perlu dilakukan inisialisasi nilai awal untuk panjang periode *seasonal*, *level*, *trend*, *seasonal*, parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ). Inisialisasi untuk panjang periode *seasonal* ditentukan sebesar 12 periode. Untuk parameter pemulusan *level* ( $\alpha$ ), parameter pemulusan *trend* ( $\beta$ ), dan parameter pemulusan *seasonal* ( $\gamma$ ) ditentukan bernilai awal 0.1. Sementara untuk inisialisasi *level*, *trend*, dan *seasonal* dilakukan sesuai dengan penjelasan pada bagian 2.2.4.

Setelah semua nilai diinisialisasi selanjutnya dapat dilakukan peramalan untuk periode ke depan terhadap data pelatihan. Dari hasil peramalan yang diperoleh tersebut

selanjutnya dapat dihitung nilai akurasi yang dihasilkan dari data pelatihan.

Namun model Holt-Winter yang diperoleh pada tahap inisialisasi ini belum menjadi model terbaik untuk meramalkan data. Nilai parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ) perlu dioptimalisasi agar mendapatkan model Holt-Winter terbaik untuk peramalan.

### 5.3.2. Pemilihan Nilai Parameter Optimal

Nilai parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ) yang diperoleh dari tahap inisialisasi selanjutnya dioptimalkan dengan memanfaatkan bantuan *add-ins* pada Microsoft Excel, yaitu Solver.

Dengan menggunakan Solver akan dicari nilai parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ) yang dapat meminimalkan nilai MAPE yang dihasilkan. Pada Solver akan diatur batasan untuk nilai parameter pemulusan untuk *level* ( $\alpha$ ) adalah  $0 \leq \alpha \leq 1$ , untuk nilai parameter pemulusan untuk *trend* ( $\beta$ ) adalah  $0 \leq \beta \leq 1$ , dan untuk nilai parameter pemulusan untuk *seasonal* ( $\gamma$ ) adalah  $0 \leq \gamma \leq 1$ .

Berdasarkan proses uji coba dengan menggunakan data pelatihan, didapatkan hasil model terbaik dari setiap skenario untuk Holt-Winter seperti ditampilkan pada Tabel 5.3.

**Tabel 5.3 Model Terbaik Setiap Skenario untuk Holt-Winter**

Trans-formasi	Pemba-gian Data	$\alpha$	$\beta$	$\gamma$	s
Tidak	50:50	$3.409 \times 10^{-1}$	$3.963 \times 10^{-1}$	$9.248 \times 10^{-1}$	12
	70:30	$3.409 \times 10^{-1}$	$3.963 \times 10^{-1}$	$9.248 \times 10^{-1}$	12

Trans-formasi	Pemba-gian Data	$\alpha$	$\beta$	$\gamma$	s
	85:15	$3.409 \times 10^{-1}$	$3.963 \times 10^{-1}$	$9.248 \times 10^{-1}$	12
Ya	50:50	$1.000 \times 10^{-7}$	$3.390 \times 10^{-2}$	$8.005 \times 10^{-3}$	12
	70:30	$1.000 \times 10^{-7}$	$3.390 \times 10^{-2}$	$8.005 \times 10^{-3}$	12
	85:15	$1.000 \times 10^{-7}$	$3.390 \times 10^{-2}$	$8.005 \times 10^{-3}$	12

Pada Tabel 5.3, periode *seasonal* (s), parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ) bernilai sama untuk semua jenis skenario. Hal ini terjadi karena memang nilai-nilai tersebut merupakan nilai paling optimal yang dapat diperoleh. Walaupun nilai parameter yang diperoleh sama, namun hasil tingkat akurasi yang dihasilkan nantinya berbeda karena perbedaan pembagian data pelatihan dan pengujian yang dilakukan.

### 5.3.3. Melakukan Peramalan dengan Holt-Winter

Setelah diperoleh nilai optimal parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ), maka telah diperoleh model Holt-Winter terbaik untuk peramalan. Dengan model tersebut selanjutnya dapat dilakukan peramalan untuk periode ke depan terhadap data pelatihan. Dari hasil peramalan yang diperoleh tersebut dapat dihitung nilai akurasi yang dihasilkan dari data pelatihan.

Model yang diperoleh juga diuji dengan menggunakan data pengujian dengan melakukan peramalan untuk periode ke depan terhadap data pengujian. Dari hasil peramalan yang diperoleh tersebut dapat dihitung nilai akurasi yang dihasilkan dari data pengujian.

Pada Tabel 5.4 ditunjukkan ukuran akurasi yang dihasilkan untuk data pelatihan setiap model Holt-Winter yang diperoleh pada Tabel 5.3.

**Tabel 5.4 Tingkat Akurasi Data Pelatihan Model Holt-Winter**

Trnsformasi	Ukuran Akurasi	Data Pelatihan		
		50%	70%	85%
Tidak	MAD	$9.613 \times 10^3$	$1.173 \times 10^4$	$1.548 \times 10^4$
	MAPE	56.780%	70.160%	77.140%
	MSE	$2.041 \times 10^8$	$3.589 \times 10^8$	$6.972 \times 10^8$
	MDA	$4.416 \times 10^{-1}$	$4.425 \times 10^{-1}$	$4.714 \times 10^{-1}$
Ya	MAD	$1.025 \times 10^4$	$1.615 \times 10^4$	$1.728 \times 10^4$
	MAPE	64.850%	96.260%	95.790%
	MSE	$2.050 \times 10^8$	$6.289 \times 10^8$	$7.344 \times 10^8$
	MDA	$3.377 \times 10^{-1}$	$3.540 \times 10^{-1}$	$3.929 \times 10^{-1}$

Sementara Tabel 5.4 merupakan ukuran akurasi yang dihasilkan untuk data pengujian setiap model Holt-Winter yang diperoleh pada Tabel 5.3.

**Tabel 5.5 Tingkat Akurasi Data Pengujian Model Holt-Winter**

Trnsformasi	Ukuran Akurasi	Data Pengujian		
		50%	30%	15%
Tidak	MAD	$2.370 \times 10^4$	$2.862 \times 10^4$	$2.593 \times 10^4$
	MAPE	116.334%	127.779%	148.939%
	MSE	$1.290 \times 10^9$	$1.688 \times 10^9$	$1.250 \times 10^9$
	MDA	$5.000 \times 10^{-1}$	$5.370 \times 10^{-1}$	$4.815 \times 10^{-1}$
Ya	MAD	$2.571 \times 10^4$	$2.356 \times 10^4$	$2.507 \times 10^4$
	MAPE	126.680%	101.600%	109.370%
	MSE	$1.386 \times 10^9$	$1.278 \times 10^9$	$1.376 \times 10^9$
	MDA	$4.222 \times 10^{-1}$	$4.444 \times 10^{-1}$	$3.333 \times 10^{-1}$

Diketahui bahwa tingkat akurasi terendah berdasarkan data pelatihan dihasilkan oleh model Holt-Winter tanpa transformasi dengan pembagian data pelatihan dan pengujian sebesar 50:50. Sementara berdasarkan data pengujiannya dihasilkan tingkat akurasi terendah oleh model Holt-Winter menggunakan transformasi dengan pembagian data pelatihan dan pengujian sebesar 70:30. Data pelatihan cenderung memberikan ukuran eror yang kecil, sementara ukuran eror

pada data pengujian cenderung lebih tinggi. Hal ini menunjukkan bahwa perbedaan pembagian data pelatihan dan pengujian dapat mempengaruhi tingkat akurasi yang dihasilkan.

#### **5.4. Pemodelan *Grey Holt-Winter***

Pembuatan model *Grey Holt-Winter* dalam penelitian tugas akhir ini dilakukan dengan memanfaatkan R Studio untuk mengubah data menjadi deret r-AGO dan IAGO serta Microsoft Excel untuk pembuatan model Holt-Winter.

##### **5.4.1. Perubahan ke Baris r-AGO**

Data pelatihan yang akan digunakan untuk pembuatan model harus diubah menjadi deret *r-accumulated generating operation* (r-AGO) terlebih dahulu. Hal ini dilakukan untuk memuluskan keacakan data asli sehingga dapat memperjelas *trend* yang ada pada data. Perubahan ke dalam deret r-AGO dilakukan dengan memanfaatkan *tools* R Studio, yaitu dengan menuliskan *script* yang ditunjukkan pada Gambar 5.2. Deret r-AGO yang diperoleh selanjutnya dapat digunakan sebagai *input* untuk membuat model peramalan Holt-Winter.

```

1 ▾ ##### R-AGO #####
2 input <- as.matrix(read.csv('Book1.csv'))
3 a = nrow(input)
4 r = 0.05
5 rago <- matrix(0, a, 1)
6
7 ▾ for (k in 1:a) {
8   i = 1
9 ▾   while (i <= k) {
10 ▾     if ((k-i) >= 0) {
11 ▾       if ((k-i) == 0){
12         rago[k] = rago[k] + 1 * input[i]
13       }
14 ▾     else {
15       j = 1
16       atas = r
17 ▾       while (j < (k-i) ){
18         atas = atas*(r+j)
19         j = j+1
20       }
21       fact = factorial((k-i))
22       rago[k] = rago[k] + (atas / fact * input[i])
23     }
24   }
25   i = i+1
26 }
27 }
28
29 write.csv(rago, file = "rago.csv", row.names = FALSE)

```

**Gambar 5.7 Script untuk Mengubah ke Baris r-AGO**

Berdasarkan Gambar 5.7, diketahui bahwa pada baris 2 dilakukan pengambilan data dari file berekstensi CSV untuk disimpan dan diolah menggunakan R Studio. Dalam file berekstensi CSV tersebut terdapat satu buah atribut, yaitu data jumlah impor total yang akan diubah menjadi baris r-AGO seperti yang ditampilkan pada Gambar 5.8.

	A
1	X
2	27795.84
3	26497.09
4	27772.46
5	26957.86
6	49700
7	24793.8
8	10600
9	24759.42
10	15800

**Gambar 5.8** Contoh Isi File CSV untuk Diubah Menjadi Deret r-AGO

Selanjutnya pada *script* baris ke 3-5 dilakukan inialisasi panjang baris data yang akan diubah menjadi deret r-AGO, nilai operator transformasi ( $r$ ), dan matriks baru untuk menyimpan baris r-AGO yang dihasilkan. Sementara pada baris 7-27 merupakan iterasi yang dilakukan untuk menghasilkan baris r-AGO. Pada baris 29, hasil r-AGO yang akan disimpan ke dalam sebuah file berekstensi CSV.

#### 5.4.2. Inialisasi

Hasil deret r-AGO yang diperoleh sebelumnya selanjutnya akan digunakan untuk membuat model Holt-Winter. Sebelum dapat melakukan peramalan perlu dilakukan inialisasi nilai awal untuk panjang periode *seasonal*, *level*, *trend*, *seasonal*, parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ). Inialisasi untuk panjang periode *seasonal* ditentukan sebesar 12 periode. Untuk parameter pemulusan *level* ( $\alpha$ ), parameter pemulusan *trend* ( $\beta$ ), dan parameter pemulusan *seasonal* ( $\gamma$ ) ditentukan bernilai awal 0.1. Sementara untuk inialisasi *level*, *trend*, dan *seasonal* dilakukan sesuai dengan penjelasan pada bagian 2.2.4.

Setelah semua nilai diinisialisasi selanjutnya dapat dilakukan peramalan untuk periode ke depan terhadap data pelatihan yang berupa baris r-AGO. Dari hasil peramalan yang diperoleh tersebut selanjutnya dapat dihitung nilai akurasi model Holt-Winter yang dihasilkan dari data pelatihan r-AGO.

Namun model Holt-Winter yang diperoleh pada tahap inisialisasi ini belum menjadi model terbaik untuk meramalkan data. Nilai parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ) perlu dioptimalisasi agar mendapatkan model Holt-Winter terbaik untuk peramalan deret r-AGO.

### 5.4.3. Pemilihan Nilai Parameter Optimal


Nilai parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ) yang diperoleh dari tahap inisialisasi selanjutnya dioptimalkan dengan memanfaatkan bantuan *add-ins* pada Microsoft Excel, yaitu Solver.

Dengan menggunakan Solver akan dicari nilai parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ) yang dapat meminimalkan nilai MAPE yang dihasilkan. Pada Solver akan diatur batasan untuk nilai parameter pemulusan untuk *level* ( $\alpha$ ) adalah  $0 \leq \alpha \leq 1$ , untuk nilai parameter pemulusan untuk *trend* ( $\beta$ ) adalah  $0 \leq \beta \leq 1$ , dan untuk nilai parameter pemulusan untuk *seasonal* ( $\gamma$ ) adalah  $0 \leq \gamma \leq 1$ .

Dari proses uji coba dengan menggunakan data pelatihan, diketahui bahwa penggunaan nilai operator transformasi ( $r$ ) pada data jumlah impor beras berpengaruh pada tingkat akurasi model dihasilkan. Untuk data ini, semakin kecil nilai operator transformasi ( $r$ ), semakin kecil nilai MAPE yang diperoleh. Hal ini menunjukkan bahwa penggunaan operator transformasi ( $r$ ) pada data jumlah impor beras tidak memberikan pengaruh yang signifikan, sebab semakin kecil nilai operator transformasi ( $r$ ) menandakan bahwa deret r-AGO akan semakin mirip dengan deret aslinya atau tidak


memberikan perbedaan yang signifikan seperti yang diharapkan, yaitu memuluskan keacakan data asli sehingga dapat memperjelas *trend* yang ada pada data. Penyebabnya bisa jadi karena data yang terlalu fluktuatifnya.

Pada Gambar 5.9 ditampilkan perbandingan MAPE yang diperoleh untuk penggunaan nilai operator transformasi ( $r$ ) pada data pelatihan tanpa transformasi.



**Gambar 5.9 Perbandingan Penggunaan Operator Transformasi ( $r$ ) pada Data Pelatihan Tanpa Transformasi**

Sementara pada Gambar 5.10 ditampilkan perbandingan MAPE yang diperoleh untuk penggunaan nilai operator transformasi ( $r$ ) pada data pelatihan dengan transformasi.



**Gambar 5.10 Perbandingan Penggunaan Operator Transformasi (r) pada Data Pelatihan Dengan Transformasi**

Berdasarkan proses uji coba dengan menggunakan data pelatihan, didapatkan hasil model terbaik dari setiap skenario untuk *Grey Holt-Winter* seperti ditampilkan pada Tabel 5.6. Karena tidak memberikan pengaruh yang signifikan sehingga nilai operator transformasi ( $r$ ) untuk model *Grey Holt-Winter* bernilai sama untuk semua skenario.

**Tabel 5.6 Model Terbaik Setiap Skenario untuk *Grey Holt-Winter***

Transformasi	Pembagian Data	$\alpha$	$\beta$	$\gamma$	s	r
Tidak	50:50	$3.409 \times 10^{-1}$	$3.963 \times 10^{-1}$	$9.248 \times 10^{-1}$	12	$1.000 \times 10^{-2}$
	70:30	$3.409 \times 10^{-1}$	$3.963 \times 10^{-1}$	$9.248 \times 10^{-1}$	12	$1.000 \times 10^{-2}$
	85:15	$3.409 \times 10^{-1}$	$3.963 \times 10^{-1}$	$9.248 \times 10^{-1}$	12	$1.000 \times 10^{-2}$
Ya	50:50	$1.000 \times 10^{-7}$	$3.390 \times 10^{-2}$	$8.005 \times 10^{-3}$	12	$1.000 \times 10^{-2}$
	70:30	$1.000 \times 10^{-7}$	$3.390 \times 10^{-2}$	$8.005 \times 10^{-3}$	12	$1.000 \times 10^{-2}$

Transformasi	Pembagian Data	$\alpha$	$\beta$	$\gamma$	s	r
	85:15	$1.000 \times 10^{-7}$	$3.390 \times 10^{-2}$	$8.005 \times 10^{-3}$	12	$1.000 \times 10^{-2}$

#### 5.4.4. Melakukan Peramalan dengan Holt-Winter

Setelah diperoleh nilai optimal parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ), maka telah diperoleh model Holt-Winter terbaik untuk peramalan. Dengan model tersebut selanjutnya dapat dilakukan peramalan untuk periode ke depan terhadap data pelatihan yang berupa deret r-AGO. Dari hasil peramalan yang diperoleh tersebut dapat dihitung nilai akurasi model Holt-Winter yang dihasilkan dari data pelatihan r-AGO. Sementara untuk menghitung nilai akurasi yang dihasilkan dengan model *Grey* Holt-Winter, hasil peramalan baris r-AGO yang telah diperoleh perlu diubah menjadi baris IAGO terlebih dahulu.

Model yang diperoleh juga diuji dengan menggunakan data pengujian dengan melakukan peramalan untuk periode ke depan terhadap data pengujian. Data pengujian ini juga perlu diubah menjadi deret r-AGO terlebih dahulu seperti yang dijelaskan pada bagian 5.4.1. Dari hasil peramalan yang diperoleh tersebut dapat dihitung nilai akurasi yang dihasilkan dari data pengujian yang berupa deret r-AGO.

#### 5.4.5. Pengubahan ke Baris IAGO

Data hasil peramalan dalam bentuk deret r-AGO harus diubah menjadi deret IAGO terlebih dahulu. Hal ini dilakukan untuk mengembalikan data ke kondisi semula. Pengubahan ke dalam deret IAGO dapat dilakukan dengan memanfaatkan *tools* R Studio, yaitu dengan menuliskan *script* yang ditunjukkan pada Gambar 5.11.

```

31 - ##### IAGO #####
32 input2 <- as.matrix(read.csv('Book2.csv'))
33 a2 = nrow(input2)
34 r2 = 1-r
35 rago2 <- matrix(0, a2, 1)
36 iago <- matrix(0, a2, 1)
37
38 for (k in 1:a2) {
39   i = 1
40   while (i <= k) {
41     if ((k-i) >= 0) {
42       if ((k-i) == 0){
43         rago2[k] = rago2[k] + 1*input2[i]
44       }
45       else {
46         j = 1
47         atas = r2
48         while (j < (k-i) ){
49           atas = atas*(r2+j)
50           j = j+1
51         }
52         rago2[k] = rago2[k] + (atas / factorial((k-i)) * input2[i])
53       }
54     }
55     i = i+1
56   }
57 }
58
59 for (k in 1:a2) {
60   if(k == 1){ iago[k] = rago2[k] }
61   else{ iago[k] = rago2[k] - rago2[k-1] }
62 }
63
64 write.csv(iago, file = "iago.csv", row.names = FALSE)

```

**Gambar 5.11 Script untuk Mengubah ke Baris IAGO**

Berdasarkan Gambar 5.11, diketahui bahwa pada baris 32-57 memiliki fungsi yang sama seperti *script* pada Gambar 5.7 sebelumnya. Perbedaannya terletak pada inisialisasi nilai  $r2$  yang digunakan sebagai operator transformasi ( $r$ ) untuk deret IAGO dan matriks IAGO yang digunakan untuk menyimpan deret IAGO yang dihasilkan. Pada baris 59-62 dilakukan operasi untuk menghasilkan baris IAGO, yaitu dengan mencari selisih antar deret  $r$ -AGO yang dihasilkan dengan nilai operator transformasi ( $r$ ) sebesar  $r2$ . Sementara pada baris 64, hasil deret IAGO yang akan disimpan ke dalam sebuah file berekstensi CSV. Contoh isi dari file CSV tersebut ditampilkan pada Gambar 5.12.

	A
1	X
2	27795.84
3	27886.88
4	29826.95
5	29540.62
6	52632.38
7	29154.96
8	14560.46
9	27979.22
10	19409.29

**Gambar 5.12 Contoh Isi File CSV Hasil Pengubahan Mejadi Deret IAGO**

Deret IAGO yang diperoleh merupakan hasil peramalan dengan menggunakan *Grey Holt-Winter*, dimana datanya telah kembali kondisi data semula. Setelah diperoleh baris IAGO, maka dapat dilakukan penghitungan nilai akurasi yang dihasilkan dengan menggunakan model *Grey Holt-Winter*.

Model yang diperoleh juga diuji dengan menggunakan data pengujian. Hal ini dilakukan dengan mengubah data pengujian menjadi deret r-AGO, melakukan peramalan untuk periode ke depan terhadap deret r-AGO data pengujian dengan model *Holt-Winter*, kemudian mengubah hasil peramalan menjadi deret IAGO untuk mendapatkan hasil peramalan dengan *Grey Holt-Winter*. Dari hasil peramalan yang diperoleh tersebut dapat dihitung nilai akurasi yang dihasilkan dari data pengujian.

Tabel 5.7 merupakan ukuran akurasi yang dihasilkan untuk data pelatihan setiap model *Grey Holt-Winter* yang diperoleh pada Tabel 5.6.

**Tabel 5.7 Tingkat Akurasi Data Pelatihan Model Grey Holt-Winter**

Trnsformasi	Ukuran Akurasi	Data Pelatihan		
		50%	70%	85%
Tidak	MAD	$9.592 \times 10^3$	$1.172 \times 10^4$	$1.550 \times 10^4$
	MAPE	56.940%	72.900%	79.370%
	MSE	$2.047 \times 10^8$	$3.592 \times 10^8$	$6.991 \times 10^8$
	MDA	$4.545 \times 10^{-1}$	$4.513 \times 10^{-1}$	$4.786 \times 10^{-1}$
Ya	MAD	$1.036 \times 10^4$	$1.615 \times 10^4$	$1.723 \times 10^4$
	MAPE	65.990%	102.000%	99.970%
	MSE	$2.070 \times 10^8$	$6.253 \times 10^8$	$7.298 \times 10^8$
	MDA	$3.766 \times 10^{-1}$	$3.805 \times 10^{-1}$	$3.929 \times 10^{-1}$

Sementara Tabel 5.8 merupakan ukuran akurasi yang dihasilkan untuk data pengujian setiap model *Grey Holt-Winter* yang diperoleh pada Tabel 5.6.

**Tabel 5.8 Tingkat Akurasi Data Pengujian Model Grey Holt-Winter**

Trnsformasi	Ukuran Akurasi	Data Pengujian		
		50%	30%	15%
Tidak	MAD	$2.369 \times 10^4$	$2.883 \times 10^4$	$2.634 \times 10^4$
	MAPE	130.290%	212.070%	303.450%
	MSE	$1.288 \times 10^9$	$1.704 \times 10^9$	$1.275 \times 10^9$
	MDA	$5.111 \times 10^{-1}$	$5.185 \times 10^{-1}$	$4.815 \times 10^{-1}$
Ya	MAD	$2.527 \times 10^4$	$2.314 \times 10^4$	$2.465 \times 10^4$
	MAPE	138.220%	105.000%	121.800%
	MSE	$1.366 \times 10^9$	$1.262 \times 10^9$	$1.359 \times 10^9$
	MDA	$4.111 \times 10^{-1}$	$4.259 \times 10^{-1}$	$4.074 \times 10^{-1}$

## 5.5. Pemodelan Holt-Winter Artificial Neural Network

Pembuatan model Holt-Winter *Artificial Neural Network* dalam penelitian tugas akhir ini dilakukan dengan memanfaatkan Microsoft Excel untuk pembuatan model Holt-Winter dan RapidMiner untuk pelatihan model *Artificial Neural Network*.

### 5.5.1. Inisialisasi

Sebelum dapat melakukan peramalan perlu dilakukan inisialisasi nilai awal untuk panjang periode *seasonal*, *level*,

*trend*, *seasonal*, parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ). Inisialisasi untuk panjang periode *seasonal* ditentukan sebesar 12 periode. Untuk parameter pemulusan *level* ( $\alpha$ ), parameter pemulusan *trend* ( $\beta$ ), dan parameter pemulusan *seasonal* ( $\gamma$ ) ditentukan bernilai awal 0.1. Sementara untuk inisialisasi *level*, *trend*, dan *seasonal* dilakukan sesuai dengan penjelasan pada bagian 2.2.4.

Setelah semua nilai diinisialisasi selanjutnya dapat dilakukan peramalan untuk periode ke depan terhadap data pelatihan. Dari hasil peramalan yang diperoleh tersebut selanjutnya dapat dihitung nilai akurasi yang dihasilkan dari data pelatihan.

Namun model Holt-Winter yang diperoleh pada tahap inisialisasi ini belum menjadi model terbaik untuk meramalkan data. Nilai parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ) perlu dioptimalisasi agar mendapatkan model Holt-Winter terbaik untuk peramalan.

### 5.5.2. Pemilihan Nilai Parameter Optimal

Nilai parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ) yang diperoleh dari tahap inisialisasi selanjutnya dioptimalkan dengan memanfaatkan bantuan *add-ins* pada Microsoft Excel, yaitu Solver.

Dengan menggunakan Solver akan dicari nilai parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ) yang dapat meminimalkan nilai MAPE yang dihasilkan. Pada Solver akan diatur batasan untuk nilai parameter pemulusan untuk *level* ( $\alpha$ ) adalah  $0 \leq \alpha \leq 1$ , untuk nilai parameter pemulusan untuk *trend* ( $\beta$ ) adalah  $0 \leq \beta \leq 1$ , dan untuk nilai parameter pemulusan untuk *seasonal* ( $\gamma$ ) adalah  $0 \leq \gamma \leq 1$ .

Berdasarkan proses uji coba dengan menggunakan data pelatihan, didapatkan hasil model terbaik dari setiap skenario untuk Holt-Winter seperti ditampilkan pada Tabel 5.9.

**Tabel 5.9 Model Terbaik Setiap Skenario untuk Holt-Winter**

<b>Trans- formasi</b>	<b>Pemba- gian Data</b>	<b><math>\alpha</math></b>	<b><math>\beta</math></b>	<b><math>\gamma</math></b>	<b>s</b>
Tidak	50:50	$3.409 \times 10^{-1}$	$3.963 \times 10^{-1}$	$9.248 \times 10^{-1}$	12
	70:30	$3.409 \times 10^{-1}$	$3.963 \times 10^{-1}$	$9.248 \times 10^{-1}$	12
	85:15	$3.409 \times 10^{-1}$	$3.963 \times 10^{-1}$	$9.248 \times 10^{-1}$	12
Ya	50:50	$1.000 \times 10^{-7}$	$3.390 \times 10^{-2}$	$8.005 \times 10^{-3}$	12
	70:30	$1.000 \times 10^{-7}$	$3.390 \times 10^{-2}$	$8.005 \times 10^{-3}$	12
	85:15	$1.000 \times 10^{-7}$	$3.390 \times 10^{-2}$	$8.005 \times 10^{-3}$	12

### 5.5.3. Melakukan Peramalan dengan Holt-Winter

Setelah diperoleh nilai optimal parameter pemulusan untuk *level* ( $\alpha$ ), parameter pemulusan untuk *trend* ( $\beta$ ), dan parameter pemulusan untuk *seasonal* ( $\gamma$ ), maka telah diperoleh model Holt-Winter terbaik untuk peramalan. Dengan model tersebut selanjutnya dapat dilakukan peramalan untuk periode ke depan terhadap data pelatihan. Dari hasil peramalan yang diperoleh tersebut dapat dihitung nilai akurasi yang dihasilkan dari data pelatihan.

Model yang diperoleh juga diuji dengan menggunakan data pengujian dengan melakukan peramalan untuk periode ke depan terhadap data pengujian. Dari hasil peramalan yang diperoleh tersebut dapat dihitung nilai akurasi yang dihasilkan dari data pengujian.

Tabel 5.10 merupakan ukuran akurasi yang dihasilkan untuk data pelatihan setiap model Holt-Winter yang diperoleh pada Tabel 5.9.

**Tabel 5.10 Tingkat Akurasi Data Pelatihan Model Holt-Winter**

Trnsformasi	Ukuran Akurasi	Data Pelatihan		
		50%	70%	85%
Tidak	MAD	$9.613 \times 10^3$	$1,173 \times 10^4$	$1.548 \times 10^4$
	MAPE	56.780%	70.160%	77.140%
	MSE	$2.041 \times 10^8$	$3.589 \times 10^8$	$6.972 \times 10^8$
	MDA	$4.416 \times 10^{-1}$	$4.425 \times 10^{-1}$	$4.714 \times 10^{-1}$
Ya	MAD	$1.025 \times 10^4$	$1,615 \times 10^4$	$1.728 \times 10^4$
	MAPE	64.850%	96.260%	95.790%
	MSE	$2.050 \times 10^8$	$6,289 \times 10^8$	$7,344 \times 10^8$
	MDA	$3,377 \times 10^{-1}$	$3,540 \times 10^{-1}$	$3,929 \times 10^{-1}$

Sementara Tabel 5.11 merupakan ukuran akurasi yang dihasilkan untuk data pengujian setiap model Holt-Winter yang diperoleh pada Tabel 5.9.


**Tabel 5.11 Tingkat Akurasi Data Pengujian Model Holt-Winter**

Trnsformasi	Ukuran Akurasi	Data Pengujian		
		50%	30%	15%
Tidak	MAD	$2.370 \times 10^4$	$2.862 \times 10^4$	$2.593 \times 10^4$
	MAPE	116.334%	127.779%	148.939%
	MSE	$1.290 \times 10^9$	$1.688 \times 10^9$	$1.250 \times 10^9$
	MDA	$5.000 \times 10^{-1}$	$5.370 \times 10^{-1}$	$4.815 \times 10^{-1}$
Ya	MAD	$2.571 \times 10^4$	$2.356 \times 10^4$	$2.507 \times 10^4$
	MAPE	126.680%	101.600%	109.370%
	MSE	$1.386 \times 10^9$	$1.278 \times 10^9$	$1.376 \times 10^9$
	MDA	$4,222 \times 10^{-1}$	$4,444 \times 10^{-1}$	$3,333 \times 10^{-1}$

Dari peramalaman dengan Holt-Winter dapat diperoleh eror atau residu yang merupakan selisih antara data aktual dengan data hasil peramalan. Eror yang diperoleh selanjutnya akan digunakan sebagai *input* pelatihan pada *Artificial Neural Network*.


### 5.5.4. Pelatihan *Artificial Neural Network* pada RapidMiner

Proses pelatihan *Artificial Neural Network* pada aplikasi RapidMiner secara keseluruhan dapat dilihat pada Gambar 5.13. Proses pelatihan dilakukan dengan menggunakan eror data pelatihan yang diperoleh dari hasil peramalan dengan Holt-Winter pada tahap sebelumnya. Untuk mendapatkan model terbaik akan dipilih berdasarkan nilai RMSE yang paling minimal.




**Gambar 5.13** Proses Pelatihan secara Keseluruhan

Didalam operator *Optimize Parameter (Grid)* terdapat susunan operator yang dapat dilihat pada Gambar 5.14.




**Gambar 5.14** Sub-Proses Pelatihan pada Operator *Optimize Parameter (Grid)*

Proses pelatihan dimulai dari operator *Retrieve* yang membaca data pelatihan yang sebelumnya telah ditambahkan ke dalam RapidMiner. Setelah itu dilakukan pendeklarasian atribut periode sebagai id dengan menggunakan operator *Set Role*.



**Gambar 5.15** Operator *Retrieve* dan *Set Role*

Selanjutnya dilakukan *windowing* dengan menggunakan operator *Windowing*. Pada operator *Windowing* ini ditentukan *window size* untuk menentukan jumlah data yang perlu dibaca dan *horizon* untuk menentukan jauhnya peramalan dilakukan. Untuk pengerjaan tugas akhir ini digunakan *window size* sebesar 12 dan *horizon* sebesar 1. *Windowing* berguna untuk mengubah susunan data deret waktu sehingga dapat digunakan untuk pelatihan dengan *Artificial Neural Network*. Hal ini dilakukan karena pada data deret waktu ini tidak terdapat kelas label yang dibutuhkan untuk pelatihan dengan *Artificial Neural Network*.



**Gambar 5.16** Operator *Windowing*


Setelah melalui operator *windowing* akan dihasilkan sebuah *Example Set*. Contoh dari *Example Set* ini dapat dilihat pada Gambar 5.17. *Example Set* tersebut selanjutnya akan

digunakan sebagai *input* untuk operator *Optimize Parameter (Grid)*.


...	Periode	label	Error-11	Error-10	Error-9	Error-8	Error-7	Error-6	Error-5	Error-4	Error-3	Error-2	Error-1	Error-0
1	Dec 1 ...	3499	-3594 8...	18645 1...	2732 3...	-2457...	-4144...	20897 ...	29348...	5641 7...	12660...	-3063...	13236...	-3745...
2	Jan 1 ...	-135...	18645...	2732 381	-2457...	-4144...	20897...	29348...	5641 7...	12660...	-30630...	13236...	-3745...	3499...
3	Feb 1 ...	5087...	2732 3...	-24571...	-4144...	20897...	29348...	5641 7...	12660...	-3063...	13236...	-3745...	3499 3...	-1357...
4	Mar 1 ...	1923...	-24571...	-41447...	20897...	29348...	5641...	12660...	-30630...	13236...	-3745 8...	3499...	-13575...	5087...
5	Apr 1, 2...	1317...	-41447...	20897 9...	29348...	5641...	12660...	-30630...	13236...	-3745...	3499 3...	-1357...	5087 8...	19234...
6	May 1 ...	-158...	20897...	29348 3...	5641 7...	12660...	-3063...	13236...	-3745...	3499 3...	-13575...	5087...	19234...	1317...
7	Jun 1 ...	-117...	29348...	5641 741	12660...	-3063...	13236...	-3745...	3499 3...	-1357...	5087 8...	19234...	1317 4...	-1584...
8	Jul 1, 2...	3415...	5641 7...	12660 7...	-3063...	13236...	-3745...	3499 3...	-13575...	5087 8...	19234...	1317...	-15848...	-1178...
9	Aug 1 ...	3396...	12660...	-30630...	13236...	-3745...	3499...	-13575...	5087 8...	19234...	1317 4...	-1584...	-1178...	3415...
10	Sep 1 ...	1105...	-30630...	13236 1...	-3745...	3499...	-1357...	5087 8...	19234...	1317 4...	-15848...	-1178...	3415 7...	3396...

**Gambar 5.17** Contoh *Example Set* yang Dihasilkan oleh Operator *Windowing*

Operator *Optimize Parameter (Grid)* berguna mencari parameter yang paling optimal untuk pelatihan model *Artificial Neural Network*. Pada pengerjaan tugas akhir ini, parameter yang dicari dengan menggunakan operator *Optimize Parameter (Grid)* meliputi *learning rate*, *momentum*, dan *training cycle*. Untuk *learning rate* dan *momentum* nilai yang digunakan berada pada rentang 0.1 hingga 0.9. Sementara untuk *training cycle*, nilai yang digunakan yaitu 100, 300, dan 500. Sedangkan untuk jumlah *hidden layer* dan neuronnya harus dimasukkan secara manual pada pengaturan operator *Neural Net*.




**Gambar 5.18** Operator *Optimize Parameters (Grid)*




**Gambar 5.19** Pengaturan pada Opetaror *Optimize Parameters (Grid)*

Parameter yang diperoleh dari iterasi operator *Optimize Parameter (Grid)* akan digunakan pada operator *Neural Net* untuk implementasi pembelajaran dengan menggunakan *Artificial Neural Network*. Operator *Neural Net* melakukan pembelajaran *Artificial Neural Network* dengan algoritma backpropagation.




**Gambar 5.20** Opetaror *Neural Net*

Parameter *learning rate*, *momentum*, dan *training cycle* pada pengaturan operator *Neural Net* akan dibiarkan *default* karena nilai parameternya telah diatur pada operator *Optimize Parameter (Grid)*. Pengaturan lainnya yang dilakukan adalah memilih centang pada pilihan *normalize* yang menunjukkan bahwa data masukan akan dinormalisasi terlebih dahulu serta menentukan jumlah *hidden layer* dan jumlah neuron yang ada pada *hidden layer*. Pada pengerjaan tugas akhir ini jumlah *hidden layer* yang digunakan adalah 1 dengan jumlah neuron di dalamnya berada pada rentang 1 hingga 10.



**Gambar 5.21** Pengaturan pada Operator *Neural Net*

Setelah semua parameter untuk operator *Neural Net* selesai diatur, maka dilakukan penerapan model *Artificial Neural Network* menggunakan operator *Apply Model* dan dihitung akurasi model dengan menggunakan operator *Performance*. Tiap percobaan yang dilakukan juga akan dicatat dengan menggunakan operator *Log*.




**Gambar 5.22** Operator *Performance*, *Apply Model*, dan *Log*

Setelah mendapatkan model terbaik dengan melihat nilai RMSE yang paling minimal, maka model akan disimpan dengan menggunakan operator *Write Model*. Model ini akan disimpan dalam bentuk file dengan ekstensi *mod* agar dapat


diterapkan untuk proses pengujian dengan menggunakan data pelatihan.

Dari proses uji coba dengan menggunakan data pelatihan, diketahui bahwa penggunaan neuron pada *hidden layer* pada residu data jumlah impor beras berpengaruh pada tingkat akurasi model dihasilkan. Untuk data residu ini, semakin banyak jumlah neuron pada hidden layer, semakin kecil nilai RMSE yang diperoleh. Pada Gambar 5.23 ditampilkan perbandingan RMSE yang diperoleh untuk penggunaan jumlah neuron pada *hidden layer* berbeda terhadap residu data pelatihan tanpa transformasi.



**Gambar 5.23 Perbandingan Penggunaan Hidden Layer pada Data Pelatihan Tanpa Transformasi**

Pada Gambar 5.24 ditampilkan perbandingan RMSE yang diperoleh untuk penggunaan jumlah neuron pada *hidden layer* berbeda terhadap residu data pelatihan dengan transformasi.



**Gambar 5.24 Perbandingan Penggunaan Hidden Layer pada Data Pelatihan Dengan Transformasi**


Sementara Tabel 5.12 merupakan ukuran akurasi model terbaik yang dihasilkan dari proses pembelajaran menggunakan error data pelatihan untuk setiap model Holt-Winter yang diperoleh pada Tabel 5.9.

**Tabel 5.12 Model Terbaik Setiap Skenario untuk *Artificial Neural Network***

Transf ormasi	Pemba gian Data	<i>Hidden Layer</i>	L	M	E	RMSE Pelatihan
Tidak	50:50	7	0.2	0.5	500	$3.701 \times 10^3$
	70:30	8	0.5	0.2	500	$7.224 \times 10^3$
	85:15	6	0.6	0.4	500	$1.048 \times 10^4$
Ya	50:50	10	0.4	0.1	500	$8.801 \times 10^{-2}$
	70:30	6	0.2	0.7	500	$3.789 \times 10^{-1}$
	85:15	10	0.4	0.1	300	$4.226 \times 10^{-1}$


### 5.5.5. Pengujian *Artificial Neural Network* pada RapidMiner

Proses pengujian *Artificial Neural Network* pada aplikasi RapidMiner secara keseluruhan dapat dilihat pada Gambar 5.25. Proses pengujian dilakukan dengan menggunakan eror data pelatihan yang diperoleh dari hasil peramalan dengan Holt-Winter pada tahap sebelumnya.




Gambar 5.25 Proses Pengujian secara Keseluruhan

Proses pengujian dimulai dari operator *Retrieve* yang membaca data pengujian yang sebelumnya telah ditambahkan ke dalam RapidMiner. Setelah itu dilakukan pendeklarasian atribut periode sebagai id dengan menggunakan operator *Set Role*.




Gambar 5.26 Operator *Retrieve* dan *Set Role*

Selanjutnya dilakukan *windowing* dengan menggunakan operator *Windowing* yang memiliki pengaturan yang sama dengan proses pelatihan. *Example Set* hasil proses *windowing* selanjutnya digunakan sebagai *input* operator *Apply Model*.



**Gambar 5.27** Operator *Windowing*

Sementara operator *Read Model* akan membaca model yang telah disimpan. Model tersebut akan diaplikasikan pada *Example Set* dengan menggunakan operator *Apply Model* dan dihitung akurasi model dengan menggunakan operator *Performance*.



**Gambar 5.28** Operator *Read Model*, *Apply Model*, dan *Performance*

Pada proses pengujian dengan menggunakan eror data pengujian, didapatkan ukuran akurasi dari setiap model *Artificial Neural Network* seperti ditampilkan pada Tabel 5.13.

**Tabel 5.13 Tingkat Akurasi Data Pelatihan Model *Artificial Neural Network***

Transf ormasi	Pemba gian Data	<i>Hidden Layer</i>	L	M	E	RMSE Pengujian
Tidak	50:50	7	0.2	0.5	500	$6.631 \times 10^4$
	70:30	8	0.5	0.2	500	$1.461 \times 10^5$
	85:15	6	0.6	0.4	500	$4.857 \times 10^0$
Ya	50:50	10	0.4	0.1	500	$4.905 \times 10^0$
	70:30	6	0.2	0.7	500	$3.128 \times 10^0$
	85:15	10	0.4	0.1	300	$2.110 \times 10^0$

### 5.5.6. Melakukan Peramalan dengan Holt-Winter *Artificial Neural Network*

Dengan menggunakan Holt-Winter dapat dilakukan peramalan terhadap data sementara penggunaan *Artificial Neural Network* digunakan meramalkan eror yang dihasilkan dari model Holt-Winter. Peramalan dengan menggunakan Holt-Winter *Artificial Neural Network* dilakukan dengan menjumlahkan hasil peramalan menggunakan model Holt-Winter dengan peramalan eror menggunakan *Artificial Neural Network*.

Berdasarkan model Holt-Winter dan *Artificial Neural Network* yang telah diperoleh sebelumnya, dilakukan peramalan dengan menggunakan metode Holt-Winter *Artificial Neural Network*. Tabel 5.14 merupakan ukuran akurasi yang dihasilkan untuk data pelatihan.

**Tabel 5.14 Tingkat Akurasi Data Pelatihan Model Holt-Winter *Artificial Neural Network***

Trnsformasi	Ukuran Akurasi	Data Pelatihan		
		50%	70%	85%
Tidak	MAD	$2.246 \times 10^3$	$4.941 \times 10^3$	$7.768 \times 10^3$
	MAPE	9.310%	25.410%	49.740%
	MSE	$1.370 \times 10^7$	$5.218 \times 10^7$	$1.098 \times 10^8$
	MDA	$8.000 \times 10^{-1}$	$6.535 \times 10^{-1}$	$6.094 \times 10^{-1}$
	MAD	$9.645 \times 10^2$	$6.348 \times 10^3$	$7.052 \times 10^3$

Trnsformasi	Ukuran Akurasi	Data Pelatihan		
		50%	70%	85%
Ya	MAPE	6.590%	33.590%	34.720%
	MSE	$1.844 \times 10^6$	$1.241 \times 10^8$	$1.461 \times 10^8$
	MDA	$8.769 \times 10^{-1}$	$6.535 \times 10^{-1}$	$6.56 \times 10^{-1}$

Sementara Tabel 5.15 merupakan ukuran akurasi yang dihasilkan untuk data pengujian.

**Tabel 5.15 Tingkat Akurasi Data Pengujian Model Holt-Winter  
*Artificial Neural Network***

Trnsformasi	Ukuran Akurasi	Data Pengujian		
		50%	30%	15%
Tidak	MAD	$8.074 \times 10^4$	$1.017 \times 10^5$	$3.792 \times 10^4$
	MAPE	2848.540%	1125.270%	3270.590%
	MSE	$3.838 \times 10^9$	$2.005 \times 10^{10}$	$2.713 \times 10^9$
	MDA	$4.556 \times 10^{-1}$	$6.48 \times 10^{-1}$	$4.07 \times 10^{-1}$
Ya	MAD	$2.546 \times 10^4$	$4.834 \times 10^6$	$1.947 \times 10^4$
	MAPE	90.630%	36022.560%	512.050%
	MSE	$1.391 \times 10^9$	$5.989 \times 10^{14}$	$1.478 \times 10^9$
	MDA	$5.111 \times 10^{-1}$	$6.111 \times 10^{-1}$	$5.185 \times 10^{-1}$

## 5.6. Pemilihan Model Terbaik

Dari tahapan sebelumnya, diperoleh model terbaik dari Holt-Winter, *Grey Holt-Winter*, dan Holt-Winter *Artificial Neural Network* untuk meramalkan periode ke depan terhadap masing-masing kombinasi antara penggunaan transformasi dan perbandingan data pelatihan dan pengujian. Masing-masing model dihitung tingkat akurasinya dengan menggunakan ukuran MAD, MSE, MAPE, dan MDA untuk data pelatihan dan data pengujian. Sementara untuk mendapatkan model terbaik ditentukan berdasarkan nilai MAD, MSE, dan MAPE yang paling rendah. Model dengan MAD, MSE, dan MAPE paling rendah akan digunakan untuk meramalkan periode selanjutnya.

Tabel 5.16 merupakan tingkat akurasi masing-masing model yang diperoleh untuk data pelatihan tanpa transformasi dengan perbandingan data pelatihan dan pengujian sebesar 85:15, 70:30, dan 50:50.

Tabel 5.16 Tingkat Akurasi Data Pelatihan

Metode	Ukuran Akurasi	Data Pelatihan		
		50:50	70:30	85:15
<b>Tanpa Transformasi</b>				
HW	MAD	$9.613 \times 10^3$	$1.173 \times 10^4$	$1.548 \times 10^4$
	MAPE	56.780%	70.160%	77.140%
	MSE	$2.041 \times 10^8$	$3.589 \times 10^8$	$6.972 \times 10^8$
	MDA	$4.416 \times 10^{-1}$	$4.42 \times 10^{-1}$	$4.714 \times 10^{-1}$
GHW	MAD	$9.592 \times 10^3$	$1.172 \times 10^4$	$1.550 \times 10^4$
	MAPE	56.940%	72.900%	79.370%
	MSE	$2.047 \times 10^8$	$3.592 \times 10^8$	$6.991 \times 10^8$
	MDA	$4.545 \times 10^{-1}$	$4.513 \times 10^{-1}$	$4.786 \times 10^{-1}$
HW-ANN	MAD	$2.246 \times 10^3$	$4.94 \times 10^3$	$7.768 \times 10^3$
	MAPE	9.310%	25.410%	49.740%
	MSE	$1.370 \times 10^7$	$5.218 \times 10^7$	$1.098 \times 10^8$
	MDA	$8.000 \times 10^{-1}$	$6.535 \times 10^{-1}$	$6.094 \times 10^{-1}$
<b>Dengan Transformasi</b>				
HW	MAD	$1.025 \times 10^4$	$1.61 \times 10^4$	$1.728 \times 10^4$
	MAPE	64.850%	96.260%	95.790%
	MSE	$2.050 \times 10^8$	$6.289 \times 10^8$	$7.344 \times 10^8$
	MDA	$3.377 \times 10^{-1}$	$3.540 \times 10^{-1}$	$3.929 \times 10^{-1}$
GHW	MAD	$1.036 \times 10^4$	$1.615 \times 10^4$	$1.723 \times 10^4$
	MAPE	65.990%	102.000%	99.970%
	MSE	$2.070 \times 10^8$	$6.253 \times 10^8$	$7.298 \times 10^8$
	MDA	$3.766 \times 10^{-1}$	$3.805 \times 10^{-1}$	$3.929 \times 10^{-1}$
HW-ANN	MAD	$9.645 \times 10^2$	$6.348 \times 10^3$	$7.052 \times 10^3$
	MAPE	6.590%	33.590%	34.720%
	MSE	$1.844 \times 10^6$	$1.241 \times 10^8$	$1.461 \times 10^8$
	MDA	$8.769 \times 10^{-1}$	$6.535 \times 10^{-1}$	$6.563 \times 10^{-1}$

Sementara Tabel 5.17 merupakan tingkat akurasi masing-masing model yang diperoleh untuk data pengujian dengan perbandingan data pelatihan dan pengujian sebesar 85:15, 70:30, dan 50:50.

Tabel 5.17 Tingkat Akurasi Data Pengujian

Metode	Ukuran Akurasi	Data Pengujian		
		50:50	70:30	85:15
<b>Tanpa Transformasi</b>				
HW	MAD	$2.370 \times 10^4$	$2.862 \times 10^4$	$2.593 \times 10^4$
	MAPE	116.334%	127.779%	148.939%
	MSE	$1.290 \times 10^9$	$1.688 \times 10^9$	$1.250 \times 10^9$
	MDA	$5.000 \times 10^{-1}$	$5.370 \times 10^{-1}$	$4.815 \times 10^{-1}$
GHW	MAD	$2.369 \times 10^4$	$2.883 \times 10^4$	$2.634 \times 10^4$
	MAPE	130.290%	212.070%	303.450%
	MSE	$1.288 \times 10^9$	$1.704 \times 10^9$	$1.275 \times 10^9$
	MDA	$5.111 \times 10^{-1}$	$5.185 \times 10^{-1}$	$4.815 \times 10^{-1}$
HW-ANN	MAD	$8.074 \times 10^4$	$1.017 \times 10^5$	$3.792 \times 10^4$
	MAPE	2848.540%	1125.270%	3270.590%
	MSE	$3.838 \times 10^9$	$2.005 \times 10^{10}$	$2.713 \times 10^9$
	MDA	$4.556 \times 10^{-1}$	$6.481 \times 10^{-1}$	$4.074 \times 10^{-1}$
<b>Dengan Transformasi</b>				
HW	MAD	$2.571 \times 10^4$	$2.356 \times 10^4$	$2.507 \times 10^4$
	MAPE	126.680%	101.600%	109.370%
	MSE	$1.386 \times 10^9$	$1.278 \times 10^9$	$1.376 \times 10^9$
	MDA	$4.222 \times 10^{-1}$	$4.444 \times 10^{-1}$	$3.333 \times 10^{-1}$
GHW	MAD	$2.527 \times 10^4$	$2.314 \times 10^4$	$2.465 \times 10^4$
	MAPE	138.220%	105.000%	121.800%
	MSE	$1.366 \times 10^9$	$1.262 \times 10^9$	$1.359 \times 10^9$
	MDA	$4.111 \times 10^{-1}$	$4.259 \times 10^{-1}$	$4.074 \times 10^{-1}$
HW-ANN	MAD	$2.546 \times 10^4$	$4.834 \times 10^6$	$1.947 \times 10^4$
	MAPE	90.630%	36022.560%	512.050%
	MSE	$1.391 \times 10^9$	$5.989 \times 10^{14}$	$1.478 \times 10^9$
	MDA	$5.111 \times 10^{-1}$	$6.111 \times 10^{-1}$	$5.185 \times 10^{-1}$

Berdasarkan akurasi pada data pelatihan yang ditampilkan pada Tabel 5.16, dapat diketahui tiga model teratas dengan nilai MAD, MSE, dan MAPE paling rendah. Ketiga model tersebut merupakan model yang dihasilkan oleh metode Holt-Winter *Artificial Neural Network*. Hal ini menunjukkan bahwa penggabungan kedua metode tersebut dapat memberikan peningkatan akurasi terhadap metode Holt-Winter biasa.

Ketiga model dengan tingkat akurasi terbaik berdasarkan data pelatihan tersebut ditampilkan pada Tabel 5.18.

**Tabel 5.18 Tiga Model Tingkat Akurasi Terbaik Berdasarkan Data Pelatihan**

Keterangan	Ukuran Akurasi Data Pelatihan			
	MAD	MAPE	MSE	MDA
HW-ANN Transformasi 50:50	$9.645 \times 10^2$	6.590%	$1.844 \times 10^6$	$8.769 \times 10^{-1}$
HW-ANN Tanpa Transformasi 50:50	$2.246 \times 10^3$	9.310%	$1.370 \times 10^7$	$8.000 \times 10^{-1}$
HW-ANN Tanpa Transformasi 70:30	$4.94 \times 10^3$	25.410%	$5.218 \times 10^7$	$6.535 \times 10^{-1}$

Sebagai perbandingan, pada Tabel 5.19 merupakan tiga model teratas berdasarkan nilai akurasi MAD, MSE, dan MAPE pada data pengujian.

**Tabel 5.19 Tiga Model Tingkat Akurasi Terbaik Berdasarkan Data Pengujian**

Keterangan	Ukuran Akurasi Data Pengujian			
	MAD	MAPE	MSE	MDA
HW-ANN Transformasi 50:50	$2.546 \times 10^4$	90.630%	$1.391 \times 10^9$	$5.111 \times 10^{-1}$
HW Transformasi 70:30	$2.356 \times 10^4$	101.600%	$1.278 \times 10^9$	$4.444 \times 10^{-1}$
GHW Transformasi 70:30	$2.314 \times 10^4$	105.000%	$1.262 \times 10^9$	$4.259 \times 10^{-1}$

### **5.7. Peramalan Data dengan Model Terbaik**

Satu model terbaik yang terpilih akan digunakan untuk melakukan peramalan terhadap data dengan jangka waktu 2 tahun ke depan. Data aktual dan hasil peramalan yang diperoleh selanjutnya akan digambarkan pada sebuah grafik untuk dilihat perbandingannya dan dianalisa lebih lanjut.

## BAB VI HASIL DAN PEMBAHASAN

Pada bab ini akan dijelaskan hasil serta analisis terhadap hasil yang diperoleh dari proses implementasi yang telah dibahas pada bab sebelumnya.

### 6.1. Hasil Performa Model

Sebelumnya telah diidentifikasi tiga model dengan tingkat akurasi terbaik pada Tabel 5.18. Tiga model tersebut terdiri dari kombinasi HW-ANN Transformasi 50:50 (model 1), HW-ANN Tanpa Transformasi 50:50 (model 2), dan HW-ANN Tanpa Transformasi 70:30 (model 3). Tiga model tersebut akan dianalisa performa modelnya berdasarkan nilai MAD, MAPE, MSE, serta MDA.

#### 6.1.1. Analisa MAD pada Model


MAD berguna untuk mengukur kesalahan ramalan dalam unit yang sama sebagai deret asli. Pada Tabel 6.1 ditampilkan nilai MAD pada masing-masing model terpilih berdasarkan akurasi pada data pelatihan. Dari Tabel 6.1 dapat diketahui bahwa model pertama atau HW-ANN Transformasi 50:50 memiliki nilai MAD untuk data pelatihan paling rendah dibanding dua model yang lain, yaitu  $9.645 \times 10^2$  atau tepatnya 964.49. Sementara untuk data pengujiannya memiliki nilai MAD sebesar  $2.546 \times 10^4$  atau tepatnya 25460.57.

**Tabel 6.1 Perbandingan Nilai MAD Model Terbaik Data Pelatihan**

Model Ke	Keterangan	MAD	
		Pelatihan	Pengujian
1	HW-ANN Transformasi 50:50	$9.645 \times 10^2$	$2.546 \times 10^4$
2	HW-ANN Tanpa Transformasi 50:50	$2.246 \times 10^3$	$8.074 \times 10^4$
3	HW-ANN Tanpa Transformasi 70:30	$4.941 \times 10^3$	$1.017 \times 10^5$

Perbandingan absolut eror dari masing-masing model ditampilkan pada Gambar 6.1. Dari grafik tersebut diketahui

bahwa rata-rata model memiliki nilai absolut eror yang rendah pada data pelatihan, kemudian nilai absolut eror ini meningkat pada data pengujian. Model ketiga merupakan model yang memiliki nilai absolut eror yang rata-rata lebih tinggi dibandingkan model lain, terutama pada data pengujiannya. Diketahui bahwa model ketiga ini menggunakan pembagian data pelatihan dan pengujian sebesar 70% dan 30% yang berbeda dengan dua model lain yang memiliki rata-rata nilai absolut eror yang lebih rendah. Hal ini menunjukkan bahwa pada kasus ini pembagian data pelatihan dan pengujian memberikan pengaruh pada tingkat akurasi model yang dihasilkan. Kemungkinan besar hal ini dipengaruhi oleh persebaran nilai yang ada pada data.



**Gambar 6.1 Perbandingan Nilai Absolut Error**

Sebagai perbandingan, pada Tabel 6.2 ditampilkan nilai MAD pada masing-masing model terpilih berdasarkan akurasi pada data pengujian. Dari Tabel 6.2 dapat diketahui bahwa model ketiga atau GHW Transformasi 70:30 memiliki nilai MAD untuk data pengujian paling rendah dibanding dua model yang lain, yaitu  $2.314 \times 10^4$  atau tepatnya 23135.779. Sementara untuk data pelatihannya memiliki nilai MAD sebesar  $1.592 \times 10^4$  atau tepatnya 15924.96.

**Tabel 6.2 Perbandingan Nilai MAD Model Terbaik Data Pengujian**

Model Ke	Keterangan	MAD	
		Pelatihan	Pengujian
1	HW-ANN Transformasi 50:50	$9.645 \times 10^2$	$2.546 \times 10^4$
2	HW Transformasi 70:30	$1.615 \times 10^4$	$2.356 \times 10^4$
3	GHW Transformasi 70:30	$1.592 \times 10^4$	$2.314 \times 10^4$

### 6.1.2. Analisa MAPE pada Model

MAPE mengindikasikan seberapa besar kesalahan dalam meramal yang dibandingkan dengan nilai data aktual pada deret. MAPE juga digunakan untuk membandingkan ketepatan dari teknik peramalan yang dinyatakan dalam bentuk rata-rata persentase absolut kesalahan. Pada Tabel 6.3 ditampilkan nilai MAPE pada masing-masing model terpilih berdasarkan akurasi pada data pelatihan. Dari Tabel 6.3 dapat diketahui bahwa model pertama atau HW-ANN Transformasi 50:50 memiliki nilai MAPE untuk data pelatihan paling rendah dibanding dua model yang lain, yaitu 6.590%. Sementara untuk data pengujianya memiliki nilai MAPE sebesar 90.630%.

**Tabel 6.3 Perbandingan Nilai MAPE Model Terbaik Data Pelatihan**


Model Ke	Keterangan	MAPE	
		Pelatihan	Pengujian
1	HW-ANN Transformasi 50:50	6.590%	90.630%
2	HW-ANN Tanpa Transformasi 50:50	9.310%	2848.540%
3	HW-ANN Tanpa Transformasi 70:30	25.410%	1125.270%

Perbandingan persentase absolut eror dari masing-masing model ditampilkan pada Gambar 6.2. Dari grafik tersebut diketahui bahwa terdapat titik dimana nilai persentase absolut eror sangat tinggi dibandingkan dengan nilai rata-rata

lainnya. Hal ini terjadi pada model kedua dan ketiga. Pada model kedua, nilai persentase absolut eror yang tinggi terjadi pada periode ke-125 atau pada Mei 2012 dan periode ke-175 atau pada Juli 2016. Sementara pada model ketiga hal ini terjadi pada periode ke-175 atau pada bulan Juli 2016.

Diketahui bahwa pada model kedua dan ketiga tidak digunakan transformasi sebelum pengisian data nol dilakukan yang berbeda dengan model pertama yang menggunakan transformasi dan memiliki persentase absolut eror yang rata-rata lebih kecil. Hal ini menunjukkan bahwa pada kasus ini penggunaan transformasi memberikan pengaruh pada tingkat akurasi model yang dihasilkan. Penggunaan transformasi dapat memperbaiki data yang sangat fluktuatif.

Kemungkinan besar munculnya nilai persentase absolut eror yang cukup tinggi ini dikarenakan data aktual pada dua periode tersebut cukup rendah. Pada periode ke-125, data jumlah impor beras yang terjadi sebesar 100.1. sementara pada periode ke-175, data jumlah impor beras yang terjadi sebesar 39.5.



**Gambar 6.2 Perbandingan Nilai Absolute Percentage Error**

Sebagai perbandingan, pada Tabel 6.4 ditampilkan nilai MAPE pada masing-masing model terpilih berdasarkan akurasi pada data pengujian. Dari Tabel 6.4 dapat diketahui bahwa

model pertama atau HW-ANN Transformasi 50:50 memiliki nilai MAPE untuk data pengujian paling rendah dibanding dua model yang lain, yaitu 90.603%. Sementara untuk data pelatihnannya memiliki nilai MAPE sebesar 6.590%.

**Tabel 6.4 Perbandingan Nilai MAPE Model Terbaik Data Pengujian**

Model Ke	Keterangan	MAPE	
		Pelatihan	Pengujian
1	HW-ANN Transformasi 50:50	6.590%	90.630%
2	HW Transformasi 70:30	96.260%	101.600%
3	GHW Transformasi 70:30	102.000%	105.000%


### 6.1.3. Analisa MSE apada Model

MSE memperkuat pengaruh dari angka-angka kesalahan peramalan yang besar, tetapi memperkecil pengaruh dari angka-angka kesalahan peramalan yang kecil. Pada Tabel 6.5 ditampilkan nilai MSE, baik untuk data pelatihan maupun data pengujian, pada masing-masing model. Dari Tabel 6.5 dapat diketahui bahwa model pertama atau HW-ANN Transformasi 50:50 memiliki nilai MSE untuk data pelatihan paling rendah dibanding dua model yang lain, yaitu  $1.844 \times 10^6$  atau tepatnya 1844041.459. Sementara untuk data pengujiannya memiliki nilai MSE sebesar  $1.391 \times 10^9$  atau tepatnya 1391074898.53.

**Tabel 6.5 Perbandingan Nilai MSE Model Terbaik Data Pelatihan**

Model Ke	Keterangan	MSE	
		Pelatihan	Pengujian
1	HW-ANN Transformasi 50:50	$1.844 \times 10^6$	$1.391 \times 10^9$
2	HW-ANN Tanpa Transformasi 50:50	$1.370 \times 10^7$	$3.838 \times 10^9$
3	HW-ANN Tanpa Transformasi 70:30	$5.218 \times 10^7$	$2.005 \times 10^{10}$

Perbandingan kuadrat eror dari masing-masing model ditampilkan pada Gambar 6.3. Dari grafik tersebut diketahui bahwa rata-rata model memiliki kuadrat eror yang rendah pada data pelatihan, kemudian kuadrat eror ini meningkat pada data pengujian. Model ketiga merupakan model yang memiliki nilai kuadrat eror yang rata-rata lebih tinggi dibandingkan model lain, terutama pada data pengujiannya. Diketahui bahwa model ketiga ini menggunakan pembagian data pelatihan dan pengujian sebesar 70% dan 30% yang berbeda dengan dua model lain yang memiliki rata-rata nilai kuadrat eror yang lebih rendah. Hal ini menunjukkan bahwa pada kasus ini pembagian data pelatihan dan pengujian memberikan pengaruh pada tingkat akurasi model yang dihasilkan. Kemungkinan besar hal ini dipengaruhi oleh persebaran nilai yang ada pada data.



**Gambar 6.3 Perbandingan Nilai Kuadrat Error**

Sebagai perbandingan, pada Tabel 6.6 ditampilkan nilai MSE pada masing-masing model terpilih berdasarkan akurasi pada data pengujian. Dari Tabel 6.6 dapat diketahui bahwa model ketiga atau GHW Transformasi 70:30 memiliki nilai MSE untuk data pengujian paling rendah dibanding dua model yang lain, yaitu  $1.262 \times 10^9$  atau tepatnya 1261863680.

Sementara untuk data pelatihannya memiliki nilai MSE sebesar  $6.253 \times 10^8$  atau tepatnya 625322154.7.

**Tabel 6.6 Perbandingan Nilai MSE Model Terbaik Data Pengujian**

Model Ke	Keterangan	MSE	
		Pelatihan	Pengujian
1	HW-ANN Transformasi 50:50	$1.844 \times 10^6$	$1.391 \times 10^9$
2	HW Transformasi 70:30	$6.289 \times 10^8$	$1.278 \times 10^9$
3	GHW Transformasi 70:30	$6.253 \times 10^8$	$1.262 \times 10^9$

#### 6.1.4. Analisa MDA pada Model

Nilai MDA akan menunjukkan probabilitas bahwa metode peramalan yang dihasilkan dapat mendeteksi arah deret waktu yang benar antara hasil peramalan dan data aktual. Hasil peramalan akan dikatakan baik ketika nilai MDA semakin mendekati angka 1.


Pada Tabel 6.7 ditampilkan nilai MDA, baik untuk data pelatihan maupun data pengujian, pada masing-masing model. Dari Tabel 6.7 dapat diketahui bahwa model pertama atau HW-ANN Transformasi 50:50 memiliki nilai MDA untuk data pelatihan yang paling tinggi dibanding model yang lain, yaitu  $8.769 \times 10^{-1}$  atau tepatnya 0.876923077. Sementara untuk data pengujiannya memiliki nilai MDA sebesar  $5.111 \times 10^{-1}$  atau tepatnya 0.511111111.

**Tabel 6.7 Perbandingan Nilai MDA Model Terbaik Data Pelatihan**

Model Ke	Keterangan	MDA	
		Pelatihan	Pengujian
1	HW-ANN Transformasi 50:50	$8.769 \times 10^{-1}$	$5.111 \times 10^{-1}$
2	HW-ANN Tanpa Transformasi 50:50	$8.000 \times 10^{-1}$	$4.556 \times 10^{-1}$


Model Ke	Keterangan	MDA	
		Pelatihan	Pengujian
3	HW-ANN Tanpa Transformasi 70:30	$6.535 \times 10^{-1}$	$6.481 \times 10^{-1}$

Untuk mengetahui perbandingan pola yang dihasilkan oleh data aktual dan hasil peramalan jumlah impor beras di Provinsi Jawa Timur dengan menggunakan model pertama dapat dilihat pada Gambar 6.4. Grafik tersebut menunjukkan bahwa hasil peramalan pada data pelatihan cukup dapat mengikuti pola data aktual. Namun pada data pengujian dapat dilihat bahwa hasil peramalan memiliki nilai yang jauh lebih kecil dari data aktual sehingga sulit untuk dibandingkan pola naik/turunnya data secara grafis.




**Gambar 6.4 Perbandingan Data Aktual dan Peramalan Model 1**

Untuk mengetahui perbandingan pola yang dihasilkan oleh data aktual dan hasil peramalan jumlah impor beras di Provinsi Jawa Timur dengan menggunakan model kedua dapat dilihat pada Gambar 6.5. Grafik tersebut menunjukkan bahwa hasil peramalan pada data pelatihan cukup dapat mengikuti pola data aktual. Namun pada data pengujian dapat dilihat bahwa hasil peramalan memiliki pola yang tidak teratur dan kurang mengikuti pola data aktual.



**Gambar 6.5 Perbandingan Data Aktual dan Peramalan Model 2**

Untuk mengetahui perbandingan pola yang dihasilkan oleh data aktual dan hasil peramalan jumlah impor beras di Provinsi Jawa Timur dengan menggunakan model kedua dapat dilihat pada Gambar 6.6. Grafik tersebut menunjukkan bahwa hasil peramalan pada data pelatihan cukup dapat mengikuti pola data aktual. Namun pada data pengujian dapat dilihat bahwa hasil peramalan memiliki nilai yang jauh lebih besar dari data aktual serta pola yang tidak teratur dan kurang mengikuti pola data aktual.



**Gambar 6.6 Perbandingan Data Aktual dan Peramalan Model 3**

Sebagai perbandingan, pada Tabel 6.8 ditampilkan nilai MDA pada masing-masing model terpilih berdasarkan akurasi pada data pengujian. Dari Tabel 6.8 dapat diketahui bahwa model pertama atau HW-ANN Transformasi 50:50 memiliki nilai MDA untuk data pengujian paling tinggi dibanding dua model yang lain, yaitu  $5.111 \times 10^{-1}$  atau tepatnya 0.511111111. Sementara untuk data pelatihannya memiliki nilai MDA sebesar  $8.769 \times 10^{-1}$  atau tepatnya 0.876923077.

**Tabel 6.8 Perbandingan Nilai MDA Model Terbaik Data Pengujian**

Model Ke	Keterangan	MDA	
		Pelatihan	Pengujian
1	HW-ANN Transformasi 50:50	$8.769 \times 10^{-1}$	$5.111 \times 10^{-1}$
2	HW Transformasi 70:30	$3.540 \times 10^{-1}$	$4.444 \times 10^{-1}$
3	GHW Transformasi 70:30	$3.805 \times 10^{-1}$	$4.259 \times 10^{-1}$

## 6.2. Pemilihan Model Terbaik

Berdasarkan nilai MAD, MAPE, MSE, dan MDA pada data pelatihan ketiga model pada bagian sebelumnya, model pertama atau HW-ANN Transformasi 50:50 lebih unggul dibandingkan model lainnya. Model ini memiliki nilai MAD terkecil, MAPE terkecil, MSE terkecil, dan MDA terbesar pada proses pelatihan. Sehingga model tersebut yang akan digunakan untuk meramalkan jumlah impor beras di wilayah Jawa Timur untuk 2 tahun mendatang.


Model terbaik yang didapatkan merupakan metode Holt-Winter *Artificial Neural Network* dengan menggunakan transformasi data berupa  $\ln(X+1)$  serta perbandingan data pelatihan dan pengujian sebesar 50:50. Dengan rincian panjang periode *seasonal* ( $s$ ) sebanyak 12, parameter pemulusan untuk *level* ( $\alpha$ ) sebesar  $1.000 \times 10^{-7}$ , parameter pemulusan untuk *trend* ( $\beta$ ) sebesar  $3.390 \times 10^{-2}$ , parameter pemulusan untuk *seasonal* ( $\gamma$ ) sebesar  $8.005 \times 10^{-3}$ , *input layer* sebanyak 12, *hidden layer* sebanyak 1 dengan 10 neuron, *output layer* sebanyak 1, *training cycle* sebanyak 500, *learning rate* sebesar 0.2, dan *momentum* sebesar 0.1.

Eror yang diperoleh dari peramalan dengan menggunakan Holt-Winter akan digunakan sebagai data untuk proses pembelajaran. Jumlah *node* pada *input layer* yang telah ditetapkan sebanyak 12 *node*. Penentuan nilai 12 *node* pada *input layer* ini menyesuaikan nilai periode *seasonal* ( $s$ ) yang telah ditentukan pada model Holt-Winter, yang menunjukkan perulangan musiman yang terjadi. Namun nilai 12 ini didasarkan pada asumsi yang bisa jadi nilai lain lebih akurat.

Untuk jumlah *node* pada *output layer* yang telah ditetapkan sebanyak 1 *node*. Penentuan nilai 1 *node* pada *output layer* ini menunjukkan peramalan eror periode selanjutnya yang dilakukan. Sementara *hidden layer* sebanyak 1 *layer* dengan jumlah *node* didalamnya diperoleh berdasarkan uji coba antara 1 hingga 10 *node*. Untuk *learning rate* dan *momentum* diperoleh berdasarkan uji coba antara rentang nilai 0.1 hingga 0.9.

Sedangkan dan *training cycle* digunakan nilai 100, 300, dan 500.

Arsitektur *Artificial Neural Network* yang digunakan pada model ini ditampilkan pada Gambar 6.7. Arsitektur ini diperoleh dari hasil uji coba yang dilakukan pada bagian 5.5.4 dengan menggunakan parameter-parameter yang telah ditentukan pada bagian 4.3.3.



**Gambar 6.7** Arsitektur *Neural Network*

Pada arsitektur *Artificial Neural Network* yang ditunjukkan pada Gambar 6.7 terdapat *input layer* yang terdiri dari 12 *node* untuk data masukan dan 1 *node* untuk *bias*, 1 *hidden layer* yang terdiri dari 10 *node*, dan *output layer* yang terdiri dari 1 *node*.

*Node* pada *input layer* mewakili eror atau residu yang diperoleh dari peramalan dengan menggunakan Holt-Winter, yang berupa eror 0, eror 1, eror 2, hingga eror 11. Eror 0 hingga 11 ini diperoleh dari hasil proses *windowing* data eror hasil peramalan dengan menggunakan Holt-Winter. Berdasarkan proses *windowing* dengan menggunakan ukuran *window* sebesar 12 akan diperoleh data deret waktu yang dipecah menjadi beberapa data *input* serta satu data *output* atau label dan disimpan dalam sebuah *Example Set*. Pada baris pertama *Example Set* akan diperoleh data *input* terdiri dari eror 0 hingga eror 11 yang merupakan eror pada periode 1 hingga 12, sementara data labelnya merupakan eror pada periode 13. Untuk baris data selanjutnya pada *Example Set* akan terdiri dari data *input* berupa eror pada periode 2 hingga 13, dengan labelnya merupakan eror pada periode 14, dan seterusnya.

Sementara *node* pada *output layer* disini mewakili peramalan eror yang diperoleh untuk 1 periode selanjutnya, setelah 12 periode untuk input. Sehingga eror pada periode 1 hingga 12 akan digunakan untuk meramalkan eror pada periode 13, eror pada periode 2 hingga 13 akan digunakan untuk meramalkan eror pada periode 14, dan seterusnya.

Sebagai perbandingan hasil peramalan yang diperoleh, digunakan model terbaik berdasarkan akurasi pada data pengujian. Berdasarkan nilai MAD, MAPE, MSE, dan MDA pada data pengujian ketiga model pada bagian sebelumnya, model pertama atau HW-ANN Transformasi 50:50 unggul dalam MAPE dan MDA, sementara model ketiga atau GHW Transformasi 70:30 unggul dalam MAD dan MSE. Karena model HW-ANN Transformasi 50:50 telah terpilih berdasarkan akurasi terbaik pada data pelatihan, maka sebagai pembandingnya akan digunakan model dari GHW Transformasi 70:30 untuk meramalkan jumlah impor beras di wilayah Jawa Timur untuk 2 tahun mendatang. Dengan rincian operator transformasi ( $r$ ) sebesar 0.01, panjang periode *seasonal* ( $s$ ) sebanyak 12, parameter pemulusan untuk *level* ( $\alpha$ ) sebesar  $1.000 \times 10^{-7}$ , parameter pemulusan untuk *trend* ( $\beta$ )

sebesar  $3.339 \times 10^{-2}$ , parameter pemulusan untuk *seasonal* ( $\gamma$ ) sebesar  $8.005 \times 10^{-3}$ .

### 6.3. Peramalan Periode Selanjutnya


Pada Tabel 6.9 ditampilkan hasil peramalan terhadap jumlah impor di wilayah Jawa Timur untuk 2 tahun mendatang dengan menggunakan model Holt-Winter *Artificial Neural Network* dengan transformasi dan pembagian data 50:50 terpilih sebelumnya.

**Tabel 6.9 Hasil Peramalan 2 Tahun Mendatang dengan HW-ANN**

Periode	Peramalan Jumlah Impor Beras (ton)
Jan-17	17.660
Feb-17	61.150
Mar-17	-0.300
Apr-17	6.660
May-17	6.320
Jun-17	-0.850
Jul-17	-0.390
Aug-17	313.510
Sep-17	528.800
Oct-17	835.310
Nov-17	9.420
Dec-17	7.450
Jan-18	0.650
Feb-18	21.390
Mar-18	5.910
Apr-18	2.260
May-18	1.560
Jun-18	-0.010
Jul-18	17.120
Aug-18	42.700
Sep-18	3.880
Oct-18	0.680

Periode	Peramalan Jumlah Impor Beras (ton)
Nov-18	-0.360
Dec-18	1.970


Gambar 6.8 merupakan grafik yang menunjukkan hasil peramalan jumlah impor beras untuk periode 2 tahun kedepan.



**Gambar 6.8 Hasil Peramalan Periode Selanjutnya**

Berdasarkan hasil peramalan yang diperoleh pada Tabel 6.9, diketahui bahwa peramalan jumlah impor beras yang dihasilkan memiliki nilai tertinggi sebesar 835.31 dan nilai terendah sebesar -0.85. Kedua nilai ini jauh dari nilai tertinggi dan terendah bukan nol yang dimiliki oleh data aktual, yaitu 137046.81 dan 39.50. Sementara rata-rata nilai peramalannya adalah 78.44 dengan standar deviasi sebesar 201.61.

Gambar 6.9 merupakan grafik yang membandingkan data aktual dan hasil peramalan yang dihasilkan dengan menggunakan *Holt-Winter Artificial Neural Network*.



**Gambar 6.9 Perbandingan Data Aktual dan Peramalan Periode Selanjutnya**

Berdasarkan perbandingan antara data aktual dan data hasil peramalan yang diperoleh diketahui bahwa model terpilih kurang mampu mengikuti pola dari data aktual, terutama pada data pengujian. Salah satu penyebabnya bisa saja karena pemodelan baik pada *Holt-Winter* maupun pada *Artificial Neural Network* yang kurang tepat. Pada pemodelan dengan *Holt-Winter*, nilai panjang periode *seasonal* ( $s$ ) telah ditetapkan sebesar 12, hal ini dilakukan berdasarkan asumsi karena pola *seasonal* dari data aktual sulit untuk diidentifikasi. Hal ini dapat mempengaruhi hasil peramalan yang diperoleh.

Sementara pada pembuatan model *Artificial Neural Network*, penggunaan jumlah *node* pada *input layer* mungkin saja mempengaruhi model yang dihasilkan. Karena jumlah *node* pada *input layer* telah ditentukan sebesar 12 *node*, menyesuaikan nilai periode *seasonal* ( $s$ ), bukan berdasarkan hasil uji coba beberapa jumlah *node*. Penggunaan asumsi ini dapat mempengaruhi hasil peramalan yang diperoleh.


Dengan menggunakan model *Grey Holt-Winter* dengan transformasi dan pembagian data 70:30, diperoleh hasil

peramalan terhadap jumlah impor di wilayah Jawa Timur untuk 2 tahun mendatang seperti pada Tabel 6.10.

**Tabel 6.10 Hasil Peramalan 2 Tahun Mendatang dengan GHW**


<b>Periode</b>	<b>Peramalan Jumlah Impor Beras (ton)</b>
Jan-17	284.988
Feb-17	308.083
Mar-17	322.724
Apr-17	306.631
May-17	1118.600
Jun-17	639.139
Jul-17	284.446
Aug-17	288.232
Sep-17	426.425
Oct-17	983.277
Nov-17	529.040
Dec-17	855.339
Jan-18	219.454
Feb-18	237.374
Mar-18	248.761
Apr-18	236.423
May-18	863.350
Jun-18	493.341
Jul-18	219.493
Aug-18	222.477
Sep-18	329.335
Oct-18	759.885
Nov-18	408.838
Dec-18	661.290

Gambar 6.10 merupakan grafik yang menunjukkan hasil peramalan jumlah impor beras untuk periode 2 tahun kedepan dengan menggunakan *Grey Holt-Winter*.



**Gambar 6.10 Hasil Peramalan Periode Selanjutnya**

Sementara Gambar 6.11 merupakan grafik yang membandingkan data aktual dan hasil peramalan yang dihasilkan dengan menggunakan Grey Holt-Winter.



**Gambar 6.11 Perbandingan Data Aktual dan Peramalan Periode Selanjutnya**

## BAB VII KESIMPULAN DAN SARAN

Pada bab ini dibahas mengenai kesimpulan dari semua proses yang telah dilakukan dan saran yang dapat diberikan untuk pengembangan yang lebih baik.

### 7.1. Kesimpulan

Kesimpulan yang didapatkan dari proses pengerjaan tugas akhir yang telah dilakukan antara lain:

1. Berdasarkan pemilihan model terbaik didapatkan metode Holt-Winter *Artificial Neural Network* dengan menggunakan transformasi data serta perbandingan data pelatihan dan pengujian sebesar 50:50. Dengan rincian panjang periode *seasonal* ( $s$ ) sebanyak 12, parameter pemulusan untuk *level* ( $\alpha$ ) sebesar  $1.000 \times 10^{-7}$ , parameter pemulusan untuk *trend* ( $\beta$ ) sebesar  $3.390 \times 10^{-2}$ , parameter pemulusan untuk *seasonal* ( $\gamma$ ) sebesar  $8.005 \times 10^{-3}$ , *input layer* sebanyak 12, *hidden layer* sebanyak 1 dengan 10 neuron, *output layer* sebanyak 1, *training cycle* sebanyak 500, *learning rate* sebesar 0.2, dan *momentum* sebesar 0.1.
2. Model terpilih yang digunakan untuk peramalan periode mendatang merupakan metode yang memiliki nilai MAD, MAPE, dan MSE terkecil serta MDA terbesar untuk data pelatihan dibandingkan model lainnya dengan nilai MAD sebesar  $9.645 \times 10^2$ , MAPE sebesar 6.590%, MSE sebesar  $1.844 \times 10^6$ , dan MDA sebesar  $8.769 \times 10^{-1}$ .
3. Metode Holt-Winter *Artificial Neural Network* memberikan tingkat akurasi yang lebih baik dibandingkan dengan metode Holt-Winter biasa dan *Grey Holt-Winter*. Holt-Winter *Artificial Neural Network* rata-rata dapat menurunkan nilai MAD, MAPE, dan MSE pada data pelatihan sebesar 70%-77% dari metode Holt-Winter biasa dan *Grey Holt-Winter*.
4. Pada kasus ini, penggunaan kombinasi transformasi serta perbandingan data pelatihan dan pengujian yang berbeda memberikan pengaruh terhadap tingkat akurasi yang

dihasilkan oleh model peramalan. Penggunaan transformasi rata-rata dapat menaikkan nilai MAD, MAPE, dan MSE sebesar 2%-24%, sementara pembagian data berpengaruh pada persebaran data yang digunakan untuk pelatihan dan pengujian.

## 7.2. Saran

Berdasarkan hasil penelitian tugas akhir ini, maka saran yang dapat penulis berikan untuk penelitian selanjutnya antara lain:

1. Metode Holt-Winter *Artificial Neural Network* tidak memberikan hasil peramalan yang bagus terhadap data intermiten jumlah impor beras di wilayah Jawa Timur, salah satunya penyebabnya bisa saja karena penggunaan panjang periode *seasonal* (*s*) atau jumlah *node* pada *input layer* yang kurang sesuai. Sehingga dibutuhkan penerapan metode peramalan lain yang sesuai untuk data intermiten agar memberikan hasil akurasi peramalan yang lebih baik
2. Penerapan analisis lebih lanjut tentang variabel-variabel yang mungkin memiliki pengaruh terhadap fluktuatifnya data intermiten, dalam kasus ini adalah jumlah impor beras di wilayah Jawa Timur, perlu dilakukan sehingga dapat diketahui penyebab fluktuatifnya data aktual.
3. Penggunaan data historis yang lebih banyak dalam proses peramalan memungkinkan pembagian data menjadi data pelatihan, pengujian, serta data validasi yang dapat membantu menghasilkan model peramalan yang lebih baik.

## DAFTAR PUSTAKA

- [1] R. J. Hyndman and G. Athanasopoulos, *Forecasting: principles and practice*. OTexts, 2014.
- [2] C. W. J. Granger and P. Newbold, *Forecasting Economic Time Series*, Second Edi. United States of America: Academic Press, Inc., 2014.
- [3] T. R. Willemain, C. N. Smart, and H. F. Schwarz, “A new approach to forecasting intermittent demand for service parts inventories,” *Int. J. Forecast.*, vol. 20, no. 3, pp. 375–387, 2004.
- [4] SAS Institute Inc, “SAS Help Center: Intermittent Time Series.” [Online]. Available: [http://documentation.sas.com/?docsetId=hpflug&docsetTarget=hpflug\\_hpfdet\\_sect029.htm&docsetVersion=14.2&locale=en](http://documentation.sas.com/?docsetId=hpflug&docsetTarget=hpflug_hpfdet_sect029.htm&docsetVersion=14.2&locale=en). [Accessed: 27-Sep-2017].
- [5] A. A. Syntetos, J. E. Boylan, and J. D. Croston, “On the categorization of demand patterns,” *J. Oper. Res. Soc.*, vol. 56, no. 5, pp. 495–503, 2005.
- [6] A. A. Syntetos, M. Zied Babai, and E. S. Gardner, “Forecasting intermittent inventory demands: Simple parametric methods vs. bootstrapping,” *J. Bus. Res.*, vol. 68, no. 8, pp. 1746–1752, 2015.
- [7] L. F. Tratar, “Improved Holt-Winters Method: A Case of Overnight Stays of Tourists in Republic Of Slovenia,” *Econ. Bus. Rev.*, vol. 16, no. 1, pp. 5–17, 2014.
- [8] J. D. Croston, “Forecasting and Stock Control for Intermittent Demands,” *J. Oper. Res. Soc.*, vol. 23, no. 3, pp. 289–303, 1972.
- [9] R. T. Clemen, “Combining forecast: A review and annotated bibliography,” *Int. J. Forecast.*, vol. 5, no. 4, pp. 559–583, 1989.
- [10] F. Petropoulos and N. Kourentzes, “Forecast combinations for intermittent demand,” pp. 1–11, 2014.
- [11] H. Rodriguez, J. J. Flores, and R. Lopez, “Combined Holt-Winters and GA trained ANN Approach for Sensor Validation and Reconstruction : Application to Water

- Demand Flowmeters,” *Conf. Control Fault Toler. Syst.*, vol. 3rd, pp. 202–207, 2016.
- [12] L. Wu, X. Gao, Y. Xiao, and S. Liu, “Using grey Holt – Winters model to predict the air quality index for cities in China,” *Nat. Hazards*, 2017.
- [13] T. E. Dielman and T. Dielman, “Choosing Smoothing Parameters For Exponential Smoothing: Minimizing Sums Of Squared Versus Sums Of Absolute Errors,” vol. 5, no. 1, 2006.
- [14] E. A. Silver, D. F. Pyke, and R. Peterson, *Inventory management and production planning and scheduling*, 3rd editio. New York: Wiley, 1998.
- [15] F. R. Johnston and J. E. Boylan, “Forecasting for Items with Intermittent Demand,” *J. Oper. Res. Soc.*, vol. 47, no. 1, pp. 113–121, 1996.
- [16] A. A. Syntetos, “Forecasting of intermittent demand,” 2001.
- [17] J. B. Ward, “Determining Reorder Points When Demand is Lumpy,” *Manage. Sci.*, vol. 24, no. 6, pp. 623–632, 1978.
- [18] E. A. Silver, “Operations research in inventory management: a review and critique.,” *Oper. Res.*, vol. 29, no. 4, pp. 628–645, 1981.
- [19] S. Makridakis, S. C. Wheelwright, and V. E. McGree, *Forecasting: Methods and applications*, Second Edi. New York: Wiley, 1983.
- [20] B. Elwood, *Manajemen Operasi/Produksi Modern*. Jakarta: Penerbit Binarupa Aksara, 1996.
- [21] J. Biegel, *Pengendalian Produksi Suatu Pendekatan Kuantitatif*. Jakarta: Akademi Presindo, 1999.
- [22] J. H. Heizer and B. Render, *Operations management*, 5th editio. New Jersey: Prentice Hall, 1996.
- [23] J. E. Hanke and D. W. Wicherm, *Business Forecasting*, 8th editio. New Jersey: Pearson Education, Inc, 2005.
- [24] J. Sungkono, “Resampling Bootstrap Pada R,” *Magistra*, no. 84, pp. 47–54, 2013.
- [25] S. Sahinler and D. Topuz, “Bootstrap and Jackknife

- Resampling Algorithms for Estimation of Regression Parameter,” *Stat. Res.*, pp. 188–199, 2007.
- [26] B. Efron and R. J. Tibshirani, *Introduction to the Bootstrap World*. New York: Chapman and Hall, 1993.
- [27] Rob J Hyndman, “Forecasting: Forecasting: Principles & Practice,” no. September, p. 138, 2014.
- [28] C. Chatfield, “The Holt-Winters Forecasting Procedure,” *J. R. Stat. Soc.*, vol. 27, no. 3, pp. 264–279, 1978.
- [29] E. S. Gardner and E. McKenzie, “Seasonal Exponential Smoothing with Damped Trends,” *Manage. Sci.*, vol. 35, no. 3, pp. 372–376, 1989.
- [30] L. Wu, S. Liu, L. Yao, S. Yan, and D. Liu, “Grey system model with the fractional order accumulation,” *Commun. Nonlinear Sci. Numer. Simul.*, vol. 18, no. 7, pp. 1775–1785, 2013.
- [31] L. Wu, S. Liu, and Y. Yang, “Grey double exponential smoothing model and its application on pig price forecasting in China,” *Appl. Soft Comput. J.*, vol. 39, pp. 117–123, 2016.
- [32] Kusrini and E. T. Luthfi, *Algoritma Data Mining*. Yogyakarta: Penerbit Andi, 2009.
- [33] S. Haykin, *Neural Networks: A Comprehensive Foundation*. Canada: Pearson Education, Inc, 1999.
- [34] G. Zhang, B. E. Patuwo, and M. Y. Hu, “Forecasting with artificial neural networks: The state of the art,” *Int. J. Forecast.*, vol. 14, pp. 35–62, 1998.
- [35] I. Suryani and R. S. Wahono, “Penerapan Exponential Smoothing untuk Transformasi Data dalam Meningkatkan Akurasi Neural Network pada Prediksi Harga Emas,” *J. Intell. Syst.*, vol. 1, no. 2, pp. 67–75, 2015.
- [36] J. Han, M. Kambe, and J. Pei, *Data Mining Concepts and Techniques*, 3rd ed. United States of America: Elsevier, 2012.
- [37] R. Hidayat, “Sistem Prediksi Status Gizi Balita Dengan Menggunakan Support Vector Regression,” 2013.

- [38] Y. Yao, L. Zhang, Y. Liu, and X. Chen, "An Improved Grid Search Algorithm and Its Application in PCA and SVM Based Face Recognition," *J. Comput. Inf. Syst.*, 2014.
- [39] C.-W. Hsu, C.-C. Chang, and C.-J. Lin, "A Practical Guide to Support Vector Classification," 2003.
- [40] R. A. Naufal, "Prediksi Jumlah Penderita Demam Berdarah di Kabupaten Malang Menggunakan Grid Search-Support Vector Machine (SVM)," 2016.
- [41] Eddy Herjanto, *Sains Manajemen: Analisis Kuantitatif untuk Pengambilan Keputusan*. Jakarta: Grasindo, 2009.
- [42] R. D. Mason, *Teknik Statistika untuk Bisnis & Ekonomi Edisi 9 Jilid 1*. Jakarta: Erlangga, 1996.
- [43] S. Makridakis and S. C. Wheelwright, *Metode dan Aplikasi Peramalan Edisi Kedua*. Jakarta: Erlangga, 1988.
- [44] M. H. Schnader and H. O. Stekler, "Evaluating Predictions of Change," *J. Bus.*, vol. 63, no. 1, pp. 99–107, 1990.
- [45] O. Blaskowitz and H. Herwartz, "On economic evaluation of directional forecasts," *Int. J. Forecast.*, vol. 27, no. 4, pp. 1058–1065, 2011.
- [46] D. Fletcher, D. MacKenzie, and E. Villouta, "Modelling Skewed Data with Many Zeros: A Simple Approach Combining Ordinary and Logistic Regression," *Environ. Ecol. Stat.*, vol. 12, no. 1, pp. 45–54, 2005.
- [47] B. McCune, J. B. Grace, and D. L. Urban, *Analysis of Ecological Communities*. Mjmm Software Design, 2002.

## BIODATA PENULIS



Penulis bernama lengkap Jwalita Galuh Garini, lahir di Kediri pada tanggal 16 Februari 1996. Merupakan anak pertama dari 2 bersaudara. Penulis telah menempuh beberapa pendidikan formal yaitu: SD Negeri Tulungrejo 2, MTs Negeri 1 Pare, dan SMA Negeri 2 Pare.

Pada tahun 2014 pasca kelulusan SMA, penulis melanjutkan pendidikan dengan jalur SNMPTN di Jurusan Sistem Informasi FTIK – Institut Teknologi Sepuluh Nopember (ITS) Surabaya dan terdaftar sebagai mahasiswa dengan NRP 5214100067. Selama menjadi mahasiswa, penulis mengikuti berbagai kegiatan kemahasiswaan diantaranya beberapa kepanitiaan seperti YES Summit, ITS EXPO, serta Information System Expo, serta pernah menjadi staf Information Media Badan Eksekutif Mahasiswa Fakultas Teknologi Informasi ITS pada tahun kedua. Selain itu, kegiatan seperti Latihan Ketrampilan Manajemen Mahasiswa pun pernah diikuti hingga Tingkat Dasar. Di bidang akademik, penulis aktif menjadi asisten dosen pada beberapa mata kuliah seperti Matematika Diskrit dan Statistika.

Penulis memiliki ketertarikan di bidang Rekayasa Data Dan Intelegensi Bisnis (RDIB), sehingga memilih topik peramalan data sebagai tugas akhir. Penulis dapat dihubungi melalui *email* di [taajwalita@gmail.com](mailto:taajwalita@gmail.com).

*Halaman ini sengaja dikosongkan*

## LAMPIRAN A

Data Aktual Jumlah Impor Beras Jawa Timur Tahun 2002-2016

<b>Periode</b>	<b>Jumlah Impor (Ton)</b>
Jan-02	0.000
Feb-02	0.000
Mar-02	0.000
Apr-02	0.000
May-02	49700.000
Jun-02	24793.800
Jul-02	10600.000
Aug-02	0.000
Sep-02	15800.000
Oct-02	41275.000
Nov-02	20450.000
Dec-02	34600.000
Jan-03	0.000
Feb-03	43243.000
Mar-03	36900.000
Apr-03	12021.000
May-03	8500.000
Jun-03	0.000
Jul-03	0.000
Aug-03	0.000
Sep-03	0.000
Oct-03	13500.000
Nov-03	0.000
Dec-03	0.000
Jan-04	0.000
Feb-04	0.000

<b>Periode</b>	<b>Jumlah Impor (Ton)</b>
Mar-04	0.000
Apr-04	0.000
May-04	0.000
Jun-04	0.000
Jul-04	0.000
Aug-04	0.000
Sep-04	0.000
Oct-04	0.000
Nov-04	0.000
Dec-04	0.000
Jan-05	0.000
Feb-05	0.000
Mar-05	0.000
Apr-05	0.000
May-05	0.000
Jun-05	0.000
Jul-05	0.000
Aug-05	0.000
Sep-05	0.000
Oct-05	0.000
Nov-05	0.000
Dec-05	0.000
Jan-06	0.000
Feb-06	0.000
Mar-06	0.000
Apr-06	0.000
May-06	0.000
Jun-06	0.000
Jul-06	0.000

<b>Periode</b>	<b>Jumlah Impor (Ton)</b>
Aug-06	0.000
Sep-06	0.000
Oct-06	0.000
Nov-06	0.000
Dec-06	0.000
Jan-07	0.000
Feb-07	56100.000
Mar-07	7450.000
Apr-07	21000.000
May-07	6700.000
Jun-07	13489.000
Jul-07	37650.000
Aug-07	37000.000
Sep-07	34100.000
Oct-07	5000.000
Nov-07	14400.000
Dec-07	7200.000
Jan-08	7175.000
Feb-08	0.000
Mar-08	0.000
Apr-08	0.000
May-08	0.000
Jun-08	0.000
Jul-08	0.000
Aug-08	0.000
Sep-08	0.000
Oct-08	0.000
Nov-08	0.000
Dec-08	0.000

<b>Periode</b>	<b>Jumlah Impor (Ton)</b>
Jan-09	0.000
Feb-09	0.000
Mar-09	0.000
Apr-09	0.000
May-09	0.000
Jun-09	0.000
Jul-09	0.000
Aug-09	0.000
Sep-09	0.000
Oct-09	0.000
Nov-09	0.000
Dec-09	0.000
Jan-10	0.000
Feb-10	0.000
Mar-10	0.000
Apr-10	0.000
May-10	0.000
Jun-10	0.000
Jul-10	0.000
Aug-10	0.000
Sep-10	0.000
Oct-10	0.000
Nov-10	0.000
Dec-10	12945.000
Jan-11	41609.930
Feb-11	26099.280
Mar-11	58114.838
Apr-11	97544.318
May-11	2997.060

<b>Periode</b>	<b>Jumlah Impor (Ton)</b>
Jun-11	0.000
Jul-11	0.000
Aug-11	0.000
Sep-11	52449.834
Oct-11	92089.125
Nov-11	60737.552
Dec-11	101598.926
Jan-12	34934.204
Feb-12	44501.889
Mar-12	82830.120
Apr-12	45009.852
May-12	100.100
Jun-12	0.000
Jul-12	0.000
Aug-12	0.000
Sep-12	0.000
Oct-12	0.000
Nov-12	6980.835
Dec-12	51355.609
Jan-13	112036.000
Feb-13	110716.000
Mar-13	9677.000
Apr-13	0.000
May-13	0.000
Jun-13	0.000
Jul-13	0.000
Aug-13	0.000
Sep-13	0.000
Oct-13	0.000

<b>Periode</b>	<b>Jumlah Impor (Ton)</b>
Nov-13	0.000
Dec-13	0.000
Jan-14	0.000
Feb-14	0.000
Mar-14	0.000
Apr-14	0.000
May-14	0.000
Jun-14	0.000
Jul-14	0.000
Aug-14	0.000
Sep-14	0.000
Oct-14	0.000
Nov-14	46248.000
Dec-14	23387.000
Jan-15	0.000
Feb-15	0.000
Mar-15	0.000
Apr-15	0.000
May-15	0.000
Jun-15	0.000
Jul-15	0.000
Aug-15	0.000
Sep-15	0.000
Oct-15	0.000
Nov-15	22654.266
Dec-15	18269.120
Jan-16	57287.714
Feb-16	70092.617
Mar-16	137046.814

<b>Periode</b>	<b>Jumlah Impor (Ton)</b>
Apr-16	56918.773
May-16	1749.563
Jun-16	13541.150
Jul-16	39.500
Aug-16	0.000
Sep-16	0.000
Oct-16	0.000
Nov-16	0.000
Dec-16	0.000

A-8

*Halaman ini sengaja dikosongkan*

## LAMPIRAN B

### Hasil Proses Persiapan Data

<b>Periode</b>	<b>Aktual Tanpa Transformasi (X)</b>	<b>Data Hasil Imputasi X</b>	<b>Aktual Transformasi (Y)</b>	<b>Data Hasil Imputasi Y</b>
Jan-02	0.000	27795.840	0.000	9.280
Feb-02	0.000	26497.088	0.000	9.262
Mar-02	0.000	27772.456	0.000	9.310
Apr-02	0.000	26957.864	0.000	9.226
May-02	49700.000	49700.000	10.814	10.814
Jun-02	24793.800	24793.800	10.118	10.118
Jul-02	10600.000	10600.000	9.269	9.269
Aug-02	0.000	24759.416	0.000	9.224
Sep-02	15800.000	15800.000	9.668	9.668
Oct-02	41275.000	41275.000	10.628	10.628
Nov-02	20450.000	20450.000	9.926	9.926
Dec-02	34600.000	34600.000	10.452	10.452
Jan-03	0.000	24106.876	0.000	9.293
Feb-03	43243.000	43243.000	10.675	10.675
Mar-03	36900.000	36900.000	10.516	10.516
Apr-03	12021.000	12021.000	9.394	9.394
May-03	8500.000	8500.000	9.048	9.048
Jun-03	0.000	25201.304	0.000	9.601
Jul-03	0.000	22794.456	0.000	9.174
Aug-03	0.000	23428.584	0.000	9.437
Sep-03	0.000	24350.752	0.000	9.109
Oct-03	13500.000	13500.000	9.511	9.511
Nov-03	0.000	24612.624	0.000	9.035
Dec-03	0.000	26592.504	0.000	9.689

## B-2

<b>Periode</b>	<b>Aktual Tanpa Transformasi (X)</b>	<b>Data Hasil Imputasi X</b>	<b>Aktual Transformasi (Y)</b>	<b>Data Hasil Imputasi Y</b>
Jan-04	0.000	23359.548	0.000	9.063
Feb-04	0.000	20002.400	0.000	9.099
Mar-04	0.000	24046.756	0.000	8.868
Apr-04	0.000	21590.140	0.000	9.576
May-04	0.000	24403.292	0.000	9.600
Jun-04	0.000	22679.588	0.000	9.420
Jul-04	0.000	22660.220	0.000	9.137
Aug-04	0.000	26158.108	0.000	9.405
Sep-04	0.000	22679.640	0.000	9.017
Oct-04	0.000	21149.672	0.000	9.305
Nov-04	0.000	24378.880	0.000	9.491
Dec-04	0.000	27308.291	0.000	9.856
Jan-05	0.000	23236.955	0.000	9.475
Feb-05	0.000	25882.364	0.000	9.424
Mar-05	0.000	24578.322	0.000	9.229
Apr-05	0.000	25313.937	0.000	9.584
May-05	0.000	22949.111	0.000	8.842
Jun-05	0.000	22520.068	0.000	9.349
Jul-05	0.000	23386.751	0.000	9.455
Aug-05	0.000	27027.216	0.000	9.553
Sep-05	0.000	23894.842	0.000	9.065
Oct-05	0.000	21828.070	0.000	9.137
Nov-05	0.000	25766.888	0.000	9.628
Dec-05	0.000	23488.736	0.000	9.414
Jan-06	0.000	22087.214	0.000	9.524
Feb-06	0.000	25538.068	0.000	9.699
Mar-06	0.000	24204.246	0.000	9.559

<b>Periode</b>	<b>Aktual Tanpa Transformasi (X)</b>	<b>Data Hasil Imputasi X</b>	<b>Aktual Transformasi (Y)</b>	<b>Data Hasil Imputasi Y</b>
Apr-06	0.000	24962.487	0.000	10.117
May-06	0.000	23196.232	0.000	9.300
Jun-06	0.000	28153.222	0.000	9.142
Jul-06	0.000	21255.574	0.000	8.768
Aug-06	0.000	24488.585	0.000	9.082
Sep-06	0.000	25606.523	0.000	9.714
Oct-06	0.000	23153.752	0.000	9.074
Nov-06	0.000	21891.427	0.000	9.090
Dec-06	0.000	27993.887	0.000	9.585
Jan-07	0.000	22072.674	0.000	9.909
Feb-07	56100.000	56100.000	10.935	10.935
Mar-07	7450.000	7450.000	8.916	8.916
Apr-07	21000.000	21000.000	9.952	9.952
May-07	6700.000	6700.000	8.810	8.810
Jun-07	13489.000	13489.000	9.510	9.510
Jul-07	37650.000	37650.000	10.536	10.536
Aug-07	37000.000	37000.000	10.519	10.519
Sep-07	34100.000	34100.000	10.437	10.437
Oct-07	5000.000	5000.000	8.517	8.517
Nov-07	14400.000	14400.000	9.575	9.575
Dec-07	7200.000	7200.000	8.882	8.882
Jan-08	7175.000	7175.000	8.878	8.878
Feb-08	0.000	27467.517	0.000	10.059
Mar-08	0.000	24860.069	0.000	9.370
Apr-08	0.000	29909.751	0.000	10.327
May-08	0.000	28546.049	0.000	9.963
Jun-08	0.000	30175.882	0.000	9.258

<b>Periode</b>	<b>Aktual Tanpa Transformasi (X)</b>	<b>Data Hasil Imputasi X</b>	<b>Aktual Transformasi (Y)</b>	<b>Data Hasil Imputasi Y</b>
Jul-08	0.000	27663.714	0.000	9.238
Aug-08	0.000	26232.910	0.000	9.477
Sep-08	0.000	25219.301	0.000	9.321
Oct-08	0.000	29325.940	0.000	8.926
Nov-08	0.000	32677.399	0.000	9.879
Dec-08	0.000	31775.305	0.000	9.771
Jan-09	0.000	32060.995	0.000	9.580
Feb-09	0.000	26725.410	0.000	9.536
Mar-09	0.000	35731.153	0.000	9.799
Apr-09	0.000	28787.640	0.000	9.657
May-09	0.000	30772.100	0.000	9.657
Jun-09	0.000	30101.531	0.000	9.002
Jul-09	0.000	28184.347	0.000	9.345
Aug-09	0.000	32815.672	0.000	9.714
Sep-09	0.000	31366.471	0.000	9.868
Oct-09	0.000	25924.719	0.000	9.311
Nov-09	0.000	33487.285	0.000	9.760
Dec-09	0.000	35378.263	0.000	9.692
Jan-10	0.000	36379.528	0.000	9.981
Feb-10	0.000	37844.097	0.000	9.551
Mar-10	0.000	38827.257	0.000	10.208
Apr-10	0.000	39165.277	0.000	9.841
May-10	0.000	42934.637	0.000	9.640
Jun-10	0.000	37507.393	0.000	9.641
Jul-10	0.000	30446.534	0.000	10.174
Aug-10	0.000	44771.708	0.000	10.078
Sep-10	0.000	48198.185	0.000	9.569

<b>Periode</b>	<b>Aktual Tanpa Transformasi (X)</b>	<b>Data Hasil Imputasi X</b>	<b>Aktual Transformasi (Y)</b>	<b>Data Hasil Imputasi Y</b>
Oct-10	0.000	44480.470	0.000	9.384
Nov-10	0.000	47432.769	0.000	9.427
Dec-10	12945.000	12945.000	9.469	9.469
Jan-11	41609.930	41609.930	10.636	10.636
Feb-11	26099.280	26099.280	10.170	10.170
Mar-11	58114.838	58114.840	10.970	10.970
Apr-11	97544.318	97544.320	11.488	11.488
May-11	2997.060	2997.060	8.006	8.006
Jun-11	0.000	47569.868	0.000	9.383
Jul-11	0.000	44717.036	0.000	9.385
Aug-11	0.000	43336.497	0.000	9.536
Sep-11	52449.834	52449.830	10.868	10.868
Oct-11	92089.125	92089.130	11.431	11.431
Nov-11	60737.552	60737.550	11.014	11.014
Dec-11	101598.926	101598.930	11.529	11.529
Jan-12	34934.204	34934.200	10.461	10.461
Feb-12	44501.889	44501.890	10.703	10.703
Mar-12	82830.120	82830.120	11.325	11.325
Apr-12	45009.852	45009.850	10.715	10.715
May-12	100.100	100.100	4.616	4.616
Jun-12	0.000	52312.559	0.000	9.958
Jul-12	0.000	34829.147	0.000	9.539
Aug-12	0.000	48105.942	0.000	9.716
Sep-12	0.000	46970.600	0.000	9.686
Oct-12	0.000	47756.820	0.000	9.599
Nov-12	6980.835	6980.840	8.851	8.851
Dec-12	51355.609	51355.610	10.847	10.847

<b>Periode</b>	<b>Aktual Tanpa Transformasi (X)</b>	<b>Data Hasil Imputasi X</b>	<b>Aktual Transformasi (Y)</b>	<b>Data Hasil Imputasi Y</b>
Jan-13	112036.000	112036.000	11.627	11.627
Feb-13	110716.000	110716.000	11.615	11.615
Mar-13	9677.000	9677.000	9.178	9.178
Apr-13	0.000	45387.333	0.000	9.724
May-13	0.000	41645.725	0.000	9.555
Jun-13	0.000	38824.131	0.000	9.230
Jul-13	0.000	41393.616	0.000	9.581
Aug-13	0.000	54301.020	0.000	9.620
Sep-13	0.000	45074.323	0.000	9.288
Oct-13	0.000	45936.810	0.000	9.322
Nov-13	0.000	37530.357	0.000	9.300
Dec-13	0.000	48384.559	0.000	9.895
Jan-14	0.000	43420.905	0.000	10.306
Feb-14	0.000	51155.134	0.000	9.531
Mar-14	0.000	43145.936	0.000	9.528
Apr-14	0.000	45297.008	0.000	9.528
May-14	0.000	43169.692	0.000	9.828
Jun-14	0.000	58035.463	0.000	9.671
Jul-14	0.000	37242.653	0.000	9.355
Aug-14	0.000	48041.034	0.000	9.245
Sep-14	0.000	39843.390	0.000	9.753
Oct-14	0.000	45701.089	0.000	9.985
Nov-14	46248.000	46248.000	10.742	10.742
Dec-14	23387.000	23387.000	10.060	10.060
Jan-15	0.000	41423.894	0.000	9.623
Feb-15	0.000	59170.761	0.000	9.861
Mar-15	0.000	49489.212	0.000	9.633

<b>Periode</b>	<b>Aktual Tanpa Transformasi (X)</b>	<b>Data Hasil Imputasi X</b>	<b>Aktual Transformasi (Y)</b>	<b>Data Hasil Imputasi Y</b>
Apr-15	0.000	41472.686	0.000	9.859
May-15	0.000	50421.251	0.000	9.503
Jun-15	0.000	43424.642	0.000	9.364
Jul-15	0.000	44842.425	0.000	9.693
Aug-15	0.000	45515.553	0.000	9.760
Sep-15	0.000	44990.983	0.000	9.652
Oct-15	0.000	53488.327	0.000	9.650
Nov-15	22654.266	22654.270	10.028	10.028
Dec-15	18269.120	18269.120	9.813	9.813
Jan-16	57287.714	57287.710	10.956	10.956
Feb-16	70092.617	70092.620	11.158	11.158
Mar-16	137046.814	137046.810	11.828	11.828
Apr-16	56918.773	56918.770	10.949	10.949
May-16	1749.563	1749.560	7.468	7.468
Jun-16	13541.150	13541.150	9.514	9.514
Jul-16	39.500	39.500	3.701	3.701
Aug-16	0.000	55206.979	0.000	9.413
Sep-16	0.000	37909.553	0.000	9.387
Oct-16	0.000	49435.741	0.000	9.585
Nov-16	0.000	44341.731	0.000	9.401
Dec-16	0.000	47739.546	0.000	9.469


B-8


*Halaman ini sengaja dikosongkan*

## LAMPIRAN C


Hasil Percobaan Model Terbaik Holt-Winter, *Grey Holt-Winter*, *Holt-Winter Artificial Neural Network*

### A. Grafik Perbandingan Hasil Peramalan Holt-Winter







## B. Grafik Perbandingan Hasil Peramalan *Grey Holt-Winter*




### Perbandingan Hasil Peramalan GHW Dengan Transformasi



### C. Grafik Perbandingan Hasil Peramalan Holt-Winter *Artificial Neural Network*





## LAMPIRAN D

Hasil Percobaan *Artificial Neural Network* Untuk Peramalan Residu Holt-Winter

### A. Tanpa Transformasi Pembagian Data 85:15

<i>Hidden Layer</i>	<i>Learning Rate</i>	<i>Momentum</i>	<i>Training Cycle</i>	<b>RMSE Pelatihan</b>	<b>RMSE Pengujian</b>
1	0.1	0.4	500	18646.914	36542.595
2	0.2	0.5	500	14641.508	37977.685
3	0.4	0.4	500	12797.574	69647.679
4	0.3	0.3	500	12533.972	93511.060
5	0.4	0.3	500	11782.340	67644.144
6	0.6	0.4	500	10477.237	50891.636
7	0.6	0.4	500	11140.359	101649.594
8	0.6	0.4	500	10707.518	95305.287
9	0.7	0.5	500	10655.843	103379.013
10	0.6	0.4	500	10566.437	63090.631

D-1

**B. Tanpa Transformasi Pembagian Data 70:30**

<i>Hidden Layer</i>	<i>Learning Rate</i>	<i>Momentum</i>	<i>Training Cycle</i>	<b>RMSE Pelatihan</b>	<b>RMSE Pengujian</b>
1	0.1	0.6	300	13128.517	43791.900
2	0.3	0.1	300	11153.042	43898.052
3	0.2	0.3	500	9153.238	60030.224
4	0.4	0.1	500	8476.218	117405.573
5	0.5	0.4	500	8038.754	111211.595
6	0.4	0.2	500	7784.749	139650.033
7	0.3	0.3	500	7881.316	82127.721
8	0.5	0.2	500	7223.654	146129.857
9	0.1	0.8	500	7321.459	77617.270
10	0.3	0.3	500	7442.643	100444.836

### C. Tanpa Transformasi Pembagian Data 50:50

<i>Hidden Layer</i>	<i>Learning Rate</i>	<i>Momentum</i>	<i>Training Cycle</i>	<b>RMSE Pelatihan</b>	<b>RMSE Pengujian</b>
1	0.1	0.1	500	8271.961	38184.690
2	0.1	0.4	500	5112.590	50297.641
3	0.4	0.2	500	4643.237	55214.111
4	0.1	0.5	500	4195.391	48194.029
5	0.3	0.4	500	4164.992	57215.616
6	0.1	0.9	300	4316.668	67333.804
7	0.2	0.5	500	3701.337	66305.618
8	0.3	0.1	500	4031.090	52058.940
9	0.2	0.1	500	4404.993	57269.285
10	0.2	0.4	500	4059.357	53700.406

**D. Dengan Transformasi Pembagian Data 85:15**

<i>Hidden Layer</i>	<i>Learning Rate</i>	<i>Momentum</i>	<i>Training Cycle</i>	<b>RMSE Pelatihan</b>	<b>RMSE Pengujian</b>
1	0.1	0.2	300	0.789	1.836
2	0.7	0.1	300	0.657	2.501
3	0.2	0.5	500	0.551	2.024
4	0.3	0.5	500	0.510	1.734
5	0.3	0.5	500	0.446	2.687
6	0.4	0.4	500	0.429	2.005
7	0.3	0.5	500	0.433	2.390
8	0.3	0.7	500	0.434	2.998
9	0.4	0.2	500	0.432	1.885
10	0.2	0.7	300	0.423	2.110

### E. Dengan Transformasi Pembagian Data 70:30


<i>Hidden Layer</i>	<i>Learning Rate</i>	<i>Momentum</i>	<i>Training Cycle</i>	<b>RMSE Pelatihan</b>	<b>RMSE Pengujian</b>
1	0.1	0.2	100	0.729	1.326
2	0.1	0.1	500	0.599	2.556
3	0.2	0.1	500	0.464	1.364
4	0.3	0.3	500	0.440	2.748
5	0.5	0.4	500	0.397	2.118
6	0.2	0.7	500	0.379	3.128
7	0.2	0.5	500	0.381	2.252
8	0.3	0.2	500	0.398	3.562
9	0.2	0.6	500	0.402	3.392
10	0.3	0.5	500	0.409	2.170

**F. Dengan Transformasi Pembagian Data 50:50**

<i>Hidden Layer</i>	<i>Learning Rate</i>	<i>Momentum</i>	<i>Training Cycle</i>	<b>RMSE Pelatihan</b>	<b>RMSE Pengujian</b>
1	0.1	0.3	300	0.503	1.674
2	0.2	0.1	500	0.358	1.448
3	0.2	0.2	500	0.271	3.105
4	0.2	0.2	500	0.230	2.177
5	0.1	0.7	500	0.158	2.084
6	0.2	0.2	500	0.138	2.639
7	0.2	0.3	500	0.122	2.304
8	0.2	0.2	500	0.126	3.048
9	0.3	0.3	500	0.115	5.519
10	0.4	0.1	500	0.088	4.905

## LAMPIRAN E

### Model *Artificial Neural Network* Terbaik Untuk Peramalan Data Residu Tranformasi 50:50



Hidden 1

=====

Node 1 (Sigmoid)

-----

Eror-11: -2.354

Eror-10: 0.012

Eror-9: -0.006

Eror-8: -0.357

Eror-7: 0.888

E-1

Error-6: -2.905  
Error-5: -0.258  
Error-4: 0.062  
Error-3: 0.941  
Error-2: 1.029  
Error-1: 0.616  
Error-0: 2.084  
Bias: -1.636

Node 2 (Sigmoid)

-----  
Error-11: 1.098  
Error-10: 0.232  
Error-9: 0.791  
Error-8: -0.141  
Error-7: -0.799  
Error-6: 0.905  
Error-5: -1.261  
Error-4: -0.803  
Error-3: -0.499  
Error-2: -0.754  
Error-1: 0.173  
Error-0: -1.771  
Bias: -3.018

Node 3 (Sigmoid)

-----  
Error-11: 1.431  
Error-10: 1.093

Error-9: 0.548  
Error-8: 1.392  
Error-7: -0.032  
Error-6: 0.344  
Error-5: -0.355  
Error-4: 1.214  
Error-3: -0.146  
Error-2: 0.314  
Error-1: 0.686  
Error-0: 1.234  
Bias: -2.738

Node 4 (Sigmoid)

-----  
Error-11: 0.843  
Error-10: -0.861  
Error-9: 0.069  
Error-8: 1.140  
Error-7: 0.001  
Error-6: 1.525  
Error-5: -0.153  
Error-4: 1.556  
Error-3: 0.533  
Error-2: -0.392  
Error-1: -0.093  
Error-0: -0.079  
Bias: -2.299

Node 5 (Sigmoid)

-----  
Error-11: 1.247

Error-10: 0.957  
Error-9: -0.004  
Error-8: 0.354  
Error-7: -0.709  
Error-6: 1.044  
Error-5: -0.423  
Error-4: -1.084  
Error-3: -0.097  
Error-2: 0.076  
Error-1: 1.279  
Error-0: -0.915  
Bias: -2.515

Node 6 (Sigmoid)

-----  
Error-11: -0.097  
Error-10: -0.508  
Error-9: 1.356  
Error-8: 1.729  
Error-7: 1.695  
Error-6: -0.649  
Error-5: -3.000  
Error-4: -0.700  
Error-3: 0.657  
Error-2: -1.270  
Error-1: -0.107  
Error-0: 3.053  
Bias: -2.204

## Node 7 (Sigmoid)

-----

Error-11: -1.537

Error-10: -1.739

Error-9: -2.035

Error-8: 0.534

Error-7: 1.168

Error-6: 0.957

Error-5: 1.261

Error-4: -0.479

Error-3: -2.031

Error-2: -0.118

Error-1: -0.518

Error-0: 0.056

Bias: -4.750

## Node 8 (Sigmoid)

-----

Error-11: 0.299

Error-10: -0.200

Error-9: -0.038

Error-8: 0.391

Error-7: -0.117

Error-6: 0.411

Error-5: -0.450

Error-4: 0.111

Error-3: 0.179

Error-2: -0.168

Error-1: 0.264

Error-0: 0.370

Bias: -2.310

Node 9 (Sigmoid)

-----  
Error-11: 0.471  
Error-10: -1.033  
Error-9: -0.377  
Error-8: 0.159  
Error-7: -0.265  
Error-6: 0.649  
Error-5: -0.619  
Error-4: 0.746  
Error-3: 0.291  
Error-2: -0.256  
Error-1: 0.009  
Error-0: -0.052  
Bias: -2.076

Node 10 (Sigmoid)

-----  
Error-11: 3.116  
Error-10: 0.029  
Error-9: 1.197  
Error-8: 1.668  
Error-7: -1.346  
Error-6: 1.335  
Error-5: 2.143  
Error-4: 3.194  
Error-3: -0.323  
Error-2: 1.637

Error-1: 2.159

Error-0: 0.842

Bias: -1.227

*Output*

=====

Regression (Linear)

-----

Node 1: -2.496

Node 2: -1.600

Node 3: -1.787

Node 4: -1.544

Node 5: -1.429

Node 6: 1.915

Node 7: -1.720

Node 8: -0.274

Node 9: -1.026

Node 10: 1.648

Threshold: 0.673

E-8

*Halaman ini sengaja dikosongkan*

## LAMPIRAN F

Hasil Peramalan Holt-Winter *Artificial Neural Network* Tranformasi 50:50

### A. Hasil Peramalan

Periode	Data Aktual Transformasi	Peramalan HW	Error HW	Peramalan Error ANN	Peramalan HW-ANN Transformasi	Peramalan HW-ANN Detransformasi
Jan-02	9.280					
Feb-02	9.262					
Mar-02	9.310					
Apr-02	9.226					
May-02	10.814					
Jun-02	10.118					
Jul-02	9.269					
Aug-02	9.224					
Sep-02	9.668					
Oct-02	10.628					
Nov-02	9.926					

<b>Periode</b>	<b>Data Aktual Transformasi</b>	<b>Peramalan HW</b>	<b>Error HW</b>	<b>Peramalan Error ANN</b>	<b>Peramalan HW-ANN Transformasi</b>	<b>Peramalan HW-ANN Detransformasi</b>
Dec-02	10.452					
Jan-03	9.293	9.26	0.04			
Feb-03	10.675	9.21	1.46			
Mar-03	10.516	9.24	1.28			
Apr-03	9.394	9.13	0.27			
May-03	9.048	10.69	-1.64			
Jun-03	9.601	9.97	-0.37			
Jul-03	9.174	9.09	0.08			
Aug-03	9.437	9.03	0.41			
Sep-03	9.109	9.44	-0.34			
Oct-03	9.511	10.38	-0.87			
Nov-03	9.035	9.65	-0.62			
Dec-03	9.689	10.15	-0.46			
Jan-04	9.063	8.96	0.11	0.118	9.08	8740.527
Feb-04	9.099	8.93	0.17	0.217	9.14	9352.423

<b>Periode</b>	<b>Data Aktual Transformasi</b>	<b>Peramalan HW</b>	<b>Error HW</b>	<b>Peramalan Error ANN</b>	<b>Peramalan HW-ANN Transformasi</b>	<b>Peramalan HW-ANN Detransformasi</b>
Mar-04	8.868	8.95	-0.08	-0.015	8.93	7571.631
Apr-04	9.576	8.83	0.74	0.689	9.52	13629.959
May-04	9.600	10.38	-0.78	-0.796	9.58	14503.563
Jun-04	9.420	9.67	-0.25	-0.427	9.24	10321.709
Jul-04	9.137	8.80	0.34	0.459	9.26	10473.645
Aug-04	9.405	8.73	0.67	0.765	9.50	13302.615
Sep-04	9.017	9.14	-0.13	-0.113	9.03	8359.898
Oct-04	9.305	10.07	-0.77	-0.854	9.22	10109.489
Nov-04	9.491	9.35	0.14	0.172	9.52	13656.541
Dec-04	9.856	9.85	0.00	-0.201	9.65	15538.179
Jan-05	9.475	8.66	0.81	0.763	9.42	12378.074
Feb-05	9.424	8.63	0.79	0.845	9.47	13020.279
Mar-05	9.229	8.65	0.58	0.565	9.21	10033.033
Apr-05	9.584	8.54	1.04	1.035	9.57	14380.619

<b>Periode</b>	<b>Data Aktual Transformasi</b>	<b>Peramalan HW</b>	<b>Error HW</b>	<b>Peramalan Error ANN</b>	<b>Peramalan HW-ANN Transformasi</b>	<b>Peramalan HW-ANN Detransformasi</b>
May-05	8.842	10.07	-1.23	-1.274	8.80	6638.210
Jun-05	9.349	9.37	-0.02	-0.052	9.32	11124.233
Jul-05	9.455	8.50	0.95	0.839	9.34	11399.517
Aug-05	9.553	8.44	1.11	1.029	9.47	12922.940
Sep-05	9.065	8.84	0.22	0.155	9.00	8103.851
Oct-05	9.137	9.77	-0.63	-0.571	9.20	9893.045
Nov-05	9.628	9.05	0.58	0.599	9.65	15552.778
Dec-05	9.414	9.55	-0.14	-0.154	9.40	12095.289
Jan-06	9.524	8.37	1.15	1.105	9.47	13013.864
Feb-06	9.699	8.34	1.36	1.281	9.62	15045.597
Mar-06	9.559	8.36	1.20	1.121	9.48	13049.733
Apr-06	10.117	8.25	1.87	1.892	10.14	25373.629
May-06	9.300	9.77	-0.47	-0.479	9.29	10802.310
Jun-06	9.142	9.07	0.07	0.102	9.17	9625.045
Jul-06	8.768	8.21	0.56	0.548	8.76	6373.953

<b>Periode</b>	<b>Data Aktual Transformasi</b>	<b>Peramalan HW</b>	<b>Error HW</b>	<b>Peramalan Error ANN</b>	<b>Peramalan HW-ANN Transformasi</b>	<b>Peramalan HW-ANN Detransformasi</b>
Aug-06	9.082	8.15	0.93	0.818	8.97	7841.557
Sep-06	9.714	8.55	1.17	1.076	9.62	15125.582
Oct-06	9.074	9.47	-0.39	-0.467	9.00	8111.323
Nov-06	9.090	8.76	0.33	0.157	8.92	7454.428
Dec-06	9.585	9.26	0.33	0.381	9.64	15307.281
Jan-07	9.909	8.08	1.83	1.632	9.71	16526.452
Feb-07	10.935	8.05	2.88	2.793	10.84	51202.293
Mar-07	8.916	8.07	0.85	0.883	8.95	7708.420
Apr-07	9.952	7.97	1.99	2.027	9.99	21871.558
May-07	8.810	9.47	-0.66	-0.625	8.84	6906.032
Jun-07	9.510	8.77	0.74	0.653	9.43	12413.238
Jul-07	10.536	7.92	2.62	2.550	10.47	35197.104
Aug-07	10.519	7.86	2.66	2.661	10.52	37055.828
Sep-07	10.437	8.26	2.18	2.144	10.40	33005.875

<b>Periode</b>	<b>Data Aktual Transformasi</b>	<b>Peramalan HW</b>	<b>Error HW</b>	<b>Peramalan Error ANN</b>	<b>Peramalan HW-ANN Transformasi</b>	<b>Peramalan HW-ANN Detransformasi</b>
Oct-07	8.517	9.17	-0.65	-0.743	8.42	4553.565
Nov-07	9.575	8.46	1.11	1.082	9.55	13996.771
Dec-07	8.882	8.96	-0.08	-0.018	8.94	7644.814
Jan-08	8.878	7.80	1.08	1.060	8.86	7027.300
Feb-08	10.059	7.78	2.28	2.211	9.99	21754.446
Mar-08	9.370	7.78	1.59	1.491	9.27	10587.513
Apr-08	10.327	7.68	2.64	2.666	10.35	31267.398
May-08	9.963	9.16	0.80	0.878	10.04	22926.781
Jun-08	9.258	8.48	0.78	0.561	9.04	8448.701
Jul-08	9.238	7.64	1.60	1.511	9.15	9435.414
Aug-08	9.477	7.58	1.89	1.751	9.33	11308.119
Sep-08	9.321	7.98	1.34	1.156	9.14	9277.994
Oct-08	8.926	8.86	0.06	0.044	8.91	7389.122
Nov-08	9.879	8.18	1.70	1.498	9.67	15889.335
Dec-08	9.771	8.66	1.11	1.109	9.77	17514.940

<b>Periode</b>	<b>Data Aktual Transformasi</b>	<b>Peramalan HW</b>	<b>Error HW</b>	<b>Peramalan Error ANN</b>	<b>Peramalan HW-ANN Transformasi</b>	<b>Peramalan HW-ANN Detransformasi</b>
Jan-09	9.580	7.51	2.07	1.921	9.43	12450.907
Feb-09	9.536	7.50	2.04	2.013	9.51	13486.309
Mar-09	9.799	7.49	2.31	2.226	9.72	16610.056
Apr-09	9.657	7.41	2.25	2.287	9.69	16224.442
May-09	9.657	8.87	0.79	0.833	9.70	16371.606
Jun-09	9.002	8.19	0.81	0.801	8.99	8029.471
Jul-09	9.345	7.36	1.99	2.514	9.87	19357.306
Aug-09	9.714	7.30	2.41	0.656	7.96	2849.157
Sep-09	9.868	7.69	2.18	1.809	9.50	13372.140
Oct-09	9.311	8.57	0.74	1.465	10.03	22721.101
Nov-09	9.760	7.89	1.87	1.808	9.70	16304.809
Dec-09	9.692	8.37	1.32	1.258	9.63	15221.715
Jan-10	9.981	7.23	2.75	0.412	7.64	2076.987
Feb-10	9.551	7.22	2.34	0.812	8.03	3060.422

<b>Periode</b>	<b>Data Aktual Transformasi</b>	<b>Peramalan HW</b>	<b>Error HW</b>	<b>Peramalan Error ANN</b>	<b>Peramalan HW-ANN Transformasi</b>	<b>Peramalan HW-ANN Detransformasi</b>
Mar-10	10.208	7.21	3.00	0.923	8.14	3412.109
Apr-10	9.841	7.13	2.71	1.178	8.31	4045.409
May-10	9.640	8.58	1.06	0.275	8.85	6997.436
Jun-10	9.641	7.90	1.74	-1.451	6.45	630.191
Jul-10	10.174	7.07	3.10	-0.048	7.03	1125.904
Aug-10	10.078	7.02	3.06	-0.674	6.35	570.040
Sep-10	9.569	7.41	2.16	-0.487	6.93	1016.538
Oct-10	9.384	8.27	1.11	-0.653	7.62	2039.495
Nov-10	9.427	7.61	1.82	0.715	8.32	4117.478
Dec-10	9.469	8.09	1.38	-0.563	7.52	1847.312
Jan-11	10.636	6.95	3.69	-1.286	5.67	287.652
Feb-11	10.170	6.94	3.23	0.538	7.47	1759.754
Mar-11	10.970	6.94	4.03	0.667	7.60	2006.615
Apr-11	11.488	6.85	4.64	-0.608	6.24	513.568
May-11	8.006	8.29	-0.28	-0.836	7.45	1725.321

<b>Periode</b>	<b>Data Aktual Transformasi</b>	<b>Peramalan HW</b>	<b>Error HW</b>	<b>Peramalan Error ANN</b>	<b>Peramalan HW-ANN Transformasi</b>	<b>Peramalan HW-ANN Detransformasi</b>
Jun-11	9.383	7.61	1.77	-3.601	4.01	54.315
Jul-11	9.385	6.80	2.58	-1.169	5.63	278.395
Aug-11	9.536	6.75	2.79	-2.075	4.67	105.942
Sep-11	10.868	7.13	3.74	-1.659	5.47	236.995
Oct-11	11.431	7.99	3.45	-0.009	7.98	2910.661
Nov-11	11.014	7.32	3.69	-0.198	7.13	1244.066
Dec-11	11.529	7.80	3.73	-0.267	7.53	1864.627
Jan-12	10.461	6.68	3.78	-1.592	5.09	161.458
Feb-12	10.703	6.66	4.04	-3.092	3.57	34.591
Mar-12	11.325	6.67	4.65	-3.805	2.87	16.600
Apr-12	10.715	6.59	4.12	-1.245	5.35	208.701
May-12	4.616	7.99	-3.37	-3.859	4.13	61.197
Jun-12	9.958	7.33	2.63	-3.728	3.60	35.696
Jul-12	9.539	6.52	3.01	-0.290	6.23	509.257

<b>Periode</b>	<b>Data Aktual Transformasi</b>	<b>Peramalan HW</b>	<b>Error HW</b>	<b>Peramalan Error ANN</b>	<b>Peramalan HW-ANN Transformasi</b>	<b>Peramalan HW-ANN Detransformasi</b>
Aug-12	9.716	6.47	3.24	1.504	7.98	2908.739
Sep-12	9.686	6.86	2.82	-2.357	4.51	89.633
Oct-12	9.599	7.72	1.88	1.413	9.13	9204.300
Nov-12	8.851	7.06	1.79	-2.149	4.91	134.288
Dec-12	10.847	7.53	3.32	-0.005	7.53	1852.844
Jan-13	11.627	6.41	5.21	-3.351	3.06	20.410
Feb-13	11.615	6.40	5.22	-0.137	6.26	523.162
Mar-13	9.178	6.41	2.77	-3.302	3.11	21.410
Apr-13	9.724	6.33	3.40	-1.706	4.62	100.513
May-13	9.555	7.66	1.89	-0.523	7.14	1261.640
Jun-13	9.230	7.05	2.18	-3.854	3.20	23.534
Jul-13	9.581	6.25	3.33	-1.767	4.48	87.585
Aug-13	9.620	6.20	3.42	-2.236	3.96	51.678
Sep-13	9.288	6.59	2.70	0.465	7.05	1155.493
Oct-13	9.322	7.43	1.89	-0.036	7.40	1628.889

<b>Periode</b>	<b>Data Aktual Transformasi</b>	<b>Peramalan HW</b>	<b>Error HW</b>	<b>Peramalan Error ANN</b>	<b>Peramalan HW-ANN Transformasi</b>	<b>Peramalan HW-ANN Detransformasi</b>
Nov-13	9.300	6.77	2.53	0.244	7.02	1114.663
Dec-13	9.895	7.26	2.64	0.809	8.07	3189.415
Jan-14	10.306	6.16	4.15	-2.638	3.52	32.805
Feb-14	9.531	6.14	3.39	-1.068	5.07	158.867
Mar-14	9.528	6.14	3.39	-0.962	5.17	175.622
Apr-14	9.528	6.06	3.47	-0.565	5.49	241.270
May-14	9.828	7.38	2.45	-2.120	5.26	191.877
Jun-14	9.671	6.77	2.90	-2.957	3.82	44.423
Jul-14	9.355	5.98	3.38	-2.091	3.89	47.832
Aug-14	9.245	5.93	3.32	-2.001	3.93	49.823
Sep-14	9.753	6.31	3.44	-0.699	5.61	273.022
Oct-14	9.985	7.15	2.84	-0.817	6.33	561.747
Nov-14	10.742	6.50	4.25	-0.018	6.48	649.201
Dec-14	10.060	6.98	3.08	-1.467	5.52	247.484

<b>Periode</b>	<b>Data Aktual Transformasi</b>	<b>Peramalan HW</b>	<b>Error HW</b>	<b>Peramalan Error ANN</b>	<b>Peramalan HW-ANN Transformasi</b>	<b>Peramalan HW-ANN Detransformasi</b>
Jan-15	9.623	5.89	3.73	-2.034	3.86	46.456
Feb-15	9.861	5.87	3.99	-1.796	4.08	57.866
Mar-15	9.633	5.87	3.77	-1.310	4.56	94.119
Apr-15	9.859	5.79	4.07	-0.825	4.96	141.663
May-15	9.503	7.10	2.40	-3.085	4.02	54.601
Jun-15	9.364	6.50	2.87	-3.061	3.44	30.114
Jul-15	9.693	5.71	3.98	-1.722	3.99	52.897
Aug-15	9.760	5.66	4.10	0.094	5.75	313.737
Sep-15	9.652	6.04	3.61	0.090	6.13	459.250
Oct-15	9.650	6.87	2.78	-2.125	4.75	114.524
Nov-15	10.028	6.23	3.80	-0.796	5.44	228.520
Dec-15	9.813	6.71	3.10	-1.454	5.25	190.459
Jan-16	10.956	5.63	5.33	-2.051	3.58	34.695
Feb-16	11.158	5.61	5.55	-0.376	5.23	185.762
Mar-16	11.828	5.60	6.23	-1.905	3.69	39.148

<b>Periode</b>	<b>Data Aktual Transformasi</b>	<b>Peramalan HW</b>	<b>Error HW</b>	<b>Peramalan Error ANN</b>	<b>Peramalan HW-ANN Transformasi</b>	<b>Peramalan HW-ANN Detransformasi</b>
Apr-16	10.949	5.52	5.43	-3.404	2.12	7.298
May-16	7.468	6.82	0.64	-3.604	3.22	24.045
Jun-16	9.514	6.22	3.29	-4.713	1.51	3.528
Jul-16	3.701	5.44	-1.74	-3.210	2.23	8.324
Aug-16	9.413	5.39	4.02	-4.646	0.75	1.111
Sep-16	9.387	5.77	3.61	-1.523	4.25	69.110
Oct-16	9.585	6.60	2.99	-0.189	6.41	606.994
Nov-16	9.401	5.96	3.44	-0.307	5.66	285.413
Dec-16	9.469	6.44	3.03	-1.549	4.89	131.502

**B. Hasil Peramalan Periode Mendatang**

<b>Periode</b>	<b>Peramalan HW</b>	<b>Peramalan Error ANN</b>	<b>Peramalan HW-ANN Transformasi</b>	<b>Peramalan HW-ANN Detransformasi</b>
Jan-17	5.37	1.378	6.75	852.099
Feb-17	5.35	3.287	8.63	5613.585
Mar-17	5.32	3.487	8.81	6685.371
Apr-17	5.30	2.609	7.91	2710.528
May-17	5.27	-0.684	4.59	97.283
Jun-17	5.25	3.530	8.78	6483.436
Jul-17	5.22	3.445	8.67	5804.269
Aug-17	5.20	5.266	10.46	34987.386
Sep-17	5.17	6.793	11.97	157215.204
Oct-17	5.15	2.879	8.03	3060.572
Nov-17	5.12	2.372	7.49	1797.450
Dec-17	5.10	-0.180	4.92	135.754
Jan-18	5.07	2.619	7.69	2188.881
Feb-18	5.05	4.775	9.82	18452.521
Mar-18	5.02	6.152	11.18	71363.176

<b>Periode</b>	<b>Peramalan HW</b>	<b>Peramalan Error ANN</b>	<b>Peramalan HW-ANN Transformasi</b>	<b>Peramalan HW-ANN Detransformasi</b>
Apr-18	5.00	6.537	11.54	102256.946
May-18	4.97	2.585	7.56	1915.798
Jun-18	4.95	5.165	10.11	24670.430
Jul-18	4.92	2.352	7.28	1444.507
Aug-18	4.90	3.529	8.43	4575.226
Sep-18	4.87	5.127	10.00	22051.554
Oct-18	4.85	4.272	9.12	9150.079
Nov-18	4.82	4.538	9.36	11649.433
Dec-18	4.80	1.843	6.64	766.460

### C. Pengukuran Akurasi

Periode	Aktual	Peramalan HW-ANN	Absolute Error	Abs. % Error	Error <sup>2</sup>	Sign( $Y_t - Y_{t-1}$ )	Sign( $F_t - F_{t-1}$ )	Directional Accuracy
Jan-02	10722.76							
Feb-02	10529.28							
Mar-02	11045.44							
Apr-02	10156.09							
May-02	49700.00							
Jun-02	24793.80							
Jul-02	10600.00							
Aug-02	10137.05							
Sep-02	15800.00							
Oct-02	41275.00							
Nov-02	20450.00							
Dec-02	34600.00							
Jan-03	10865.55							
Feb-03	43243.00							

Periode	Aktual	Peramalan HW-ANN	Absolute Error	Abs. % Error	Error <sup>2</sup>	Sign(Y <sub>t</sub> -Y <sub>t-1</sub> )	Sign(F <sub>t</sub> -F <sub>t-1</sub> )	Directional Accuracy
Mar-03	36900.00							
Apr-03	12021.00							
May-03	8500.00							
Jun-03	14783.77							
Jul-03	9638.10							
Aug-03	12547.33							
Sep-03	9031.63							
Oct-03	13500.00							
Nov-03	8391.22							
Dec-03	16137.56							
Jan-04	8631.26	8740.53	109.263	1.27%	11938.33			
Feb-04	8946.11	9352.42	406.309	4.54%	165087.24	0	0	1
Mar-04	7102.17	7571.63	469.460	6.61%	220392.33	1	1	1
Apr-04	14406.73	13629.96	776.775	5.39%	603378.84	0	0	1

Periode	Aktual	Peramalan HW-ANN	Absolute Error	Abs. % Error	Error <sup>2</sup>	Sign(Y <sub>t</sub> -Y <sub>t-1</sub> )	Sign(F <sub>t</sub> -F <sub>t-1</sub> )	Directional Accuracy
May-04	14769.66	14503.56	266.096	1.80%	70807.01	0	0	1
Jun-04	12325.99	10321.71	2004.280	16.26%	4017139.33	1	1	1
Jul-04	9289.77	10473.65	1183.874	12.74%	1401557.95	1	0	0
Aug-04	12154.01	13302.62	1148.604	9.45%	1319291.22	0	0	1
Sep-04	8238.57	8359.90	121.331	1.47%	14721.32	1	1	1
Oct-04	10991.86	10109.49	882.374	8.03%	778584.33	0	0	1
Nov-04	13234.98	13656.54	421.561	3.19%	177713.68	0	0	1
Dec-04	19074.99	15538.18	3536.808	18.54%	12509011.27	0	0	1
Jan-05	13026.58	12378.07	648.503	4.98%	420555.97	1	1	1
Feb-05	12386.14	13020.28	634.143	5.12%	402137.48	1	0	0
Mar-05	10192.40	10033.03	159.364	1.56%	25396.74	1	1	1
Apr-05	14524.41	14380.62	143.792	0.99%	20676.22	0	0	1
May-05	6916.77	6638.21	278.558	4.03%	77594.38	1	1	1
Jun-05	11485.59	11124.23	361.360	3.15%	130581.06	0	0	1

Periode	Aktual	Peramalan HW-ANN	Absolute Error	Abs. % Error	Error <sup>2</sup>	Sign(Y <sub>t</sub> -F <sub>t</sub> )	Sign(F <sub>t</sub> -F <sub>t-1</sub> )	Directional Accuracy
Jul-05	12769.14	11399.52	1369.625	10.73%	1875873.29	0	0	1
Aug-05	14082.59	12922.94	1159.651	8.23%	1344791.52	0	0	1
Sep-05	8643.86	8103.85	540.012	6.25%	291612.95	1	1	1
Oct-05	9291.51	9893.04	601.532	6.47%	361840.42	0	0	1
Nov-05	15188.54	15552.78	364.235	2.40%	132667.05	0	0	1
Dec-05	12254.07	12095.29	158.778	1.30%	25210.42	1	1	1
Jan-06	13685.18	13013.86	671.315	4.91%	450664.15	0	0	1
Feb-06	16296.40	15045.60	1250.802	7.68%	1564505.19	0	0	1
Mar-06	14165.65	13049.73	1115.917	7.88%	1245270.95	1	1	1
Apr-06	24751.81	25373.63	621.822	2.51%	386663.04	0	0	1
May-06	10936.06	10802.31	133.752	1.22%	17889.57	1	1	1
Jun-06	9334.47	9625.04	290.575	3.11%	84434.06	1	1	1
Jul-06	6423.23	6373.95	49.278	0.77%	2428.29	1	1	1
Aug-06	8795.87	7841.56	954.313	10.85%	910712.91	0	0	1

Periode	Aktual	Peramalan HW-ANN	Absolute Error	Abs. % Error	Error <sup>2</sup>	Sign(Y <sub>t</sub> -Y <sub>t-1</sub> )	Sign(F <sub>t</sub> -F <sub>t-1</sub> )	Directional Accuracy
Sep-06	16544.22	15125.58	1418.636	8.57%	2012527.47	0	0	1
Oct-06	8725.60	8111.32	614.281	7.04%	377340.69	1	1	1
Nov-06	8863.51	7454.43	1409.080	15.90%	1985506.33	0	1	0
Dec-06	14539.23	15307.28	768.048	5.28%	589898.31	0	0	1
Jan-07	20113.34	16526.45	3586.887	17.83%	12865759.52	0	0	1
Feb-07	56100.00	51202.29	4897.707	8.73%	23987533.09	0	0	1
Mar-07	7450.00	7708.42	258.420	3.47%	66780.72	1	1	1
Apr-07	21000.00	21871.56	871.558	4.15%	759612.57	0	0	1
May-07	6700.00	6906.03	206.032	3.08%	42449.27	1	1	1
Jun-07	13489.00	12413.24	1075.762	7.98%	1157263.33	0	0	1
Jul-07	37650.00	35197.10	2452.896	6.51%	6016700.24	0	0	1
Aug-07	37000.00	37055.83	55.828	0.15%	3116.75	1	0	0
Sep-07	34100.00	33005.87	1094.125	3.21%	1197109.91	1	1	1
Oct-07	5000.00	4553.57	446.435	8.93%	199304.04	1	1	1

Periode	Aktual	Peramalan HW-ANN	Absolute Error	Abs. % Error	Error <sup>2</sup>	Sign(Y <sub>t</sub> -Y <sub>t-1</sub> )	Sign(F <sub>t</sub> -F <sub>t-1</sub> )	Directional Accuracy
Nov-07	14400.00	13996.77	403.229	2.80%	162593.69	0	0	1
Dec-07	7200.00	7644.81	444.814	6.18%	197859.85	1	1	1
Jan-08	7175.00	7027.30	147.700	2.06%	21815.23	1	1	1
Feb-08	23358.32	21754.45	1603.870	6.87%	2572398.28	0	0	1
Mar-08	11731.11	10587.51	1143.596	9.75%	1307811.50	1	1	1
Apr-08	30536.68	31267.40	730.718	2.39%	533949.20	0	0	1
May-08	21216.90	22926.78	1709.881	8.06%	2923692.16	1	1	1
Jun-08	10484.61	8448.70	2035.913	19.42%	4144940.24	1	1	1
Jul-08	10275.16	9435.41	839.742	8.17%	705166.04	1	0	0
Aug-08	13050.75	11308.12	1742.634	13.35%	3036774.00	0	0	1
Sep-08	11164.31	9277.99	1886.318	16.90%	3558197.37	1	1	1
Oct-08	7520.52	7389.12	131.398	1.75%	17265.50	1	1	1
Nov-08	19507.69	15889.33	3618.360	18.55%	13092528.58	0	0	1
Dec-08	17519.31	17514.94	4.371	0.02%	19.10	1	0	0

Periode	Aktual	Peramalan HW-ANN	Absolute Error	Abs. % Error	Error <sup>2</sup>	Sign(Y <sub>t</sub> -Y <sub>t-1</sub> )	Sign(F <sub>t</sub> -F <sub>t-1</sub> )	Directional Accuracy
Jan-09	14467.68	12450.91	2016.773	13.94%	4067374.61	1	1	1
Feb-09	13848.93	13486.31	362.625	2.62%	131496.73	1	0	0
Mar-09	18020.69	16610.06	1410.639	7.83%	1989901.33	0	0	1
Apr-09	15627.72	16224.44	596.724	3.82%	356080.06	1	1	1
May-09	15625.64	16371.61	745.965	4.77%	556463.85	1	0	0
Jun-09	8121.00	8029.47	91.532	1.13%	8378.19	1	1	1
Jul-09	11444.19	19357.31	7913.119	69.15%	62617445.35	0	0	1
Aug-09	16550.80	2849.16	13701.640	82.79%	187734939.47	0	1	0
Sep-09	19304.78	13372.14	5932.645	30.73%	35196272.40	0	0	1
Oct-09	11058.29	22721.10	11662.813	105.5%	136021218.69	1	0	0
Nov-09	17332.60	16304.81	1027.791	5.93%	1056354.43	0	1	0
Dec-09	16180.92	15221.72	959.201	5.93%	920067.39	1	1	1
Jan-10	21618.48	2076.99	19541.490	90.39%	381869847.55	0	1	0
Feb-10	14056.64	3060.42	10996.220	78.23%	120916846.61	1	0	0

Periode	Aktual	Peramalan HW-ANN	Absolute Error	Abs. % Error	Error <sup>2</sup>	Sign(Y <sub>t</sub> -F <sub>t-1</sub> )	Sign(F <sub>t</sub> -F <sub>t-1</sub> )	Directional Accuracy
Mar-10	27129.32	3412.11	23717.210	87.42%	562506062.97	0	0	1
Apr-10	18795.35	4045.41	14749.941	78.48%	217560759.92	1	0	0
May-10	15361.43	6997.44	8363.994	54.45%	69956394.46	1	0	0
Jun-10	15379.57	630.19	14749.376	95.90%	217544091.27	0	1	0
Jul-10	26198.84	1125.90	25072.935	95.70%	628652045.14	0	0	1
Aug-10	23813.79	570.04	23243.748	97.61%	540271817.17	1	1	1
Sep-10	14317.98	1016.54	13301.437	92.90%	176928220.21	1	0	0
Oct-10	11891.25	2039.49	9851.758	82.85%	97057132.42	1	0	0
Nov-10	12418.48	4117.48	8300.998	66.84%	68906563.06	0	0	1
Dec-10	12945.00	1847.31	11097.688	85.73%	123158676.43	0	1	0
Jan-11	41609.93	287.65	41322.278	99.31%	1707530670.24	0	1	0
Feb-11	26099.28	1759.75	24339.526	93.26%	592412502.44	1	0	0
Mar-11	58114.84	2006.61	56108.223	96.55%	3148132688.50	0	0	1
Apr-11	97544.32	513.57	97030.750	99.47%	9414966416.33	0	1	0

Periode	Aktual	Peramalan HW-ANN	Absolute Error	Abs. % Error	Error <sup>2</sup>	Sign(Y <sub>t</sub> -Y <sub>t-1</sub> )	Sign(F <sub>t</sub> -F <sub>t-1</sub> )	Directional Accuracy
May-11	2997.06	1725.32	1271.739	42.43%	1617321.31	1	0	0
Jun-11	11887.16	54.31	11832.843	99.54%	140016164.24	0	1	0
Jul-11	11906.70	278.39	11628.301	97.66%	135217379.86	0	0	1
Aug-11	13846.66	105.94	13740.717	99.23%	188807307.98	0	1	0
Sep-11	52449.83	237.00	52212.839	99.55%	2726180519.11	0	0	1
Oct-11	92089.13	2910.66	89178.465	96.84%	7952798555.15	0	0	1
Nov-11	60737.55	1244.07	59493.486	97.95%	3539474840.10	1	1	1
Dec-11	101598.93	1864.63	99734.299	98.16%	9946930435.33	0	0	1
Jan-12	34934.20	161.46	34772.745	99.54%	1209143815.55	1	1	1
Feb-12	44501.89	34.59	44467.298	99.92%	1977340599.95	0	1	0
Mar-12	82830.12	16.60	82813.520	99.98%	6858079085.90	0	1	0
Apr-12	45009.85	208.70	44801.151	99.54%	2007143101.64	1	0	0
May-12	100.10	61.20	38.903	38.86%	1513.42	1	1	1
Jun-12	21114.67	35.70	21078.978	99.83%	444323299.95	0	1	0

Periode	Aktual	Peramalan HW-ANN	Absolute Error	Abs. % Error	Error <sup>2</sup>	Sign(Y <sub>t</sub> -F <sub>t-1</sub> )	Sign(F <sub>t</sub> -F <sub>t-1</sub> )	Directional Accuracy
Jul-12	13888.23	509.26	13378.976	96.33%	178996994.67	1	0	0
Aug-12	16582.37	2908.74	13673.626	82.46%	186968047.91	0	0	1
Sep-12	16092.43	89.63	16002.793	99.44%	256089391.70	1	1	1
Oct-12	14756.16	9204.30	5551.864	37.62%	30823194.58	1	0	0
Nov-12	6980.84	134.29	6846.547	98.08%	46875204.07	1	1	1
Dec-12	51355.61	1852.84	49502.766	96.39%	2450523813.57	0	0	1
Jan-13	112036.00	20.41	112015.590	99.98%	12547492322.56	0	1	0
Feb-13	110716.00	523.16	110192.839	99.53%	12142461752.11	1	0	0
Mar-13	9677.00	21.41	9655.590	99.78%	93230410.93	1	1	1
Apr-13	16715.28	100.51	16614.771	99.40%	276050622.07	0	0	1
May-13	14118.44	1261.64	12856.795	91.06%	165297182.69	1	0	0
Jun-13	10198.06	23.53	10174.523	99.77%	103520926.25	1	1	1
Jul-13	14490.00	87.59	14402.410	99.40%	207429418.12	0	0	1
Aug-13	15065.50	51.68	15013.826	99.66%	225414959.49	0	1	0

Periode	Aktual	Peramalan HW-ANN	Absolute Error	Abs. % Error	Error <sup>2</sup>	Sign(Y <sub>t</sub> -Y <sub>t-1</sub> )	Sign(F <sub>t</sub> -F <sub>t-1</sub> )	Directional Accuracy
Sep-13	10809.94	1155.49	9654.448	89.31%	93208364.90	1	0	0
Oct-13	11178.31	1628.89	9549.417	85.43%	91191356.80	0	0	1
Nov-13	10936.91	1114.66	9822.250	89.81%	96476599.51	1	1	1
Dec-13	19832.25	3189.41	16642.835	83.92%	276983966.58	0	0	1
Jan-14	29915.96	32.80	29883.153	99.89%	893002804.60	0	1	0
Feb-14	13778.89	158.87	13620.026	98.85%	185505120.64	1	0	0
Mar-14	13741.16	175.62	13565.540	98.72%	184023883.63	1	0	0
Apr-14	13743.88	241.27	13502.612	98.24%	182320530.70	0	0	1
May-14	18542.12	191.88	18350.243	98.97%	336731409.01	0	1	0
Jun-14	15850.37	44.42	15805.947	99.72%	249827949.99	1	1	1
Jul-14	11560.23	47.83	11512.401	99.59%	132535365.69	1	0	0
Aug-14	10352.54	49.82	10302.721	99.52%	106146055.65	1	0	0
Sep-14	17199.42	273.02	16926.395	98.41%	286502848.62	0	0	1
Oct-14	21702.10	561.75	21140.356	97.41%	446914640.31	0	0	1

Periode	Aktual	Peramalan HW-ANN	Absolute Error	Abs. % Error	Error <sup>2</sup>	Sign(Y <sub>t</sub> -Y <sub>t-1</sub> )	Sign(F <sub>t</sub> -F <sub>t-1</sub> )	Directional Accuracy
Nov-14	46248.00	649.20	45598.799	98.60%	2079250472.71	0	0	1
Dec-14	23387.00	247.48	23139.516	98.94%	535437188.58	1	1	1
Jan-15	15102.06	46.46	15055.607	99.69%	226671315.07	1	1	1
Feb-15	19164.67	57.87	19106.808	99.70%	365070128.49	0	0	1
Mar-15	15254.27	94.12	15160.146	99.38%	229830036.40	1	0	0
Apr-15	19121.74	141.66	18980.082	99.26%	360243503.86	0	0	1
May-15	13395.59	54.60	13340.989	99.59%	177982000.70	1	1	1
Jun-15	11658.27	30.11	11628.154	99.74%	135213975.14	1	1	1
Jul-15	16207.12	52.90	16154.223	99.67%	260958918.68	0	0	1
Aug-15	17328.61	313.74	17014.870	98.19%	289505789.72	0	0	1
Sep-15	15558.46	459.25	15099.210	97.05%	227986142.11	1	0	0
Oct-15	15526.46	114.52	15411.940	99.26%	237527886.34	1	1	1
Nov-15	22654.27	228.52	22425.746	98.99%	502914073.87	0	0	1
Dec-15	18269.12	190.46	18078.661	98.96%	326837965.56	1	1	1

Periode	Aktual	Peramalan HW-ANN	Absolute Error	Abs. % Error	Error <sup>2</sup>	Sign(Y <sub>t</sub> -Y <sub>t-1</sub> )	Sign(F <sub>t</sub> -F <sub>t-1</sub> )	Directional Accuracy
Jan-16	57287.71	34.69	57253.020	99.94%	3277908278.47	0	1	0
Feb-16	70092.62	185.76	69906.855	99.73%	4886968310.73	0	0	1
Mar-16	137046.81	39.15	137007.666	99.97%	18771100441.98	0	1	0
Apr-16	56918.77	7.30	56911.476	99.99%	3238916080.71	1	1	1
May-16	1749.56	24.05	1725.518	98.63%	2977411.49	1	0	0
Jun-16	13541.15	3.53	13537.622	99.97%	183267209.85	0	1	0
Jul-16	39.50	8.32	31.176	78.93%	971.96	1	0	0
Aug-16	12246.10	1.11	12244.987	99.99%	149939714.02	0	1	0
Sep-16	11933.68	69.11	11864.570	99.42%	140768028.19	1	0	0
Oct-16	14537.51	606.99	13930.514	95.82%	194059222.23	0	0	1
Nov-16	12102.22	285.41	11816.805	97.64%	139636882.23	1	1	1
Dec-16	12946.84	131.50	12815.335	98.98%	164232809.68	0	1	0
Rata-rata Keseluruhan			15096.85	55.07%	803323382.08	0.664516129		
Rata-rata Pelatihan			964.49	7%	1844041.459	0.876923077		

<b>Periode</b>	<b>Aktual</b>	<b>Peramalan HW-ANN</b>	<b>Absolute Error</b>	<b>Abs. % Error</b>	<b>Error<sup>2</sup></b>	<b>Sign( Y<sub>t</sub>-Y<sub>t-1</sub>)</b>	<b>Sign( F<sub>t</sub>-F<sub>t-1</sub>)</b>	<b>Direct ional Accur acy</b>
Rata-rata Pengujian			25460.57	90.63%	1391074898.53	0.511111111		



