



TUGAS AKHIR – SS141501

**ANALISIS JUMLAH PERMINTAAN DARAH
JENIS PACKED RED CELL DI PMI SURABAYA
MENGGUNAKAN ARIMA, ARTIFICIAL NEURAL
NETWORK DAN HYBRID ARIMA-ANN**

**FAHRIZAL ANDRYANSYAH
NRP 1315 105 018**

**Dosen Pembimbing
Dr. Dra. Kartika Fithriasari, M.Si
Dra. Wiwiek Setya Winahju, MS**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**



TUGAS AKHIR – SS141501

**ANALISIS JUMLAH PERMINTAAN DARAH
JENIS PACKED RED CELL DI PMI SURABAYA
 MENGGUNAKAN ARIMA, ARTIFICIAL NEURAL
 NETWORK DAN HYBRID ARIMA-ANN**

**FAHRIZAL ANDRYANSYAH
NRP 1315 105 018**

**Dosen Pembimbing
Dr. Dra. Kartika Fithriasari, M.Si
Dra. Wiiek Setya Winahju, MS**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**



FINAL PROJECT – SS141501

**ANALYSIS OF PACKED RED CELL DEMAND
IN PMI SURABAYA USING ARIMA, ARTIFICIAL
NEURAL NETWORK AND HYBRID ARIMA-ANN**

**FAHRIZAL ANDRYANSYAH
NRP 1315 105 018**

Supervisors
Dr. Dra. Kartika Fithriasari, M.Si
Dra. Wiwiek Setya Winahju, MS

**UNDERGRADUATE PROGRAM
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS AND NATURAL SCIENCES
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**

LEMBAR PENGESAHAN

ANALISIS JUMLAH PERMINTAAN DARAH JENIS PACKED RED CELL DI PMI SURABAYA MENGGUNAKAN ARIMA, ARTIFICIAL NEURAL NETWORK DAN HYBRID ARIMA-ANN

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada

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

Oleh :

FAHRIZAL ANDRYANSYAH

NRP. 1315 105 018

Disetujui oleh Pembimbing:

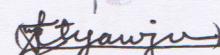
Dr. Dra. Kartika Fithriasari, M.Si

NIP. 19691212 199303 2 002

Dra. Wiwiek Setya Winahju, MS

NIP. 19560424198303 2 001

()



Mengetahui,
Kepala Departemen

Dr. Suhartono

NIP. 19710929 199512 1 001

SURABAYA, JULI 2017

ANALISIS JUMLAH PERMINTAAN DARAH JENIS PACKED RED CELL DI PMI SURABAYA MENGGUNAKAN ARIMA, ARTIFICIAL NEURAL NETWORK DAN HYBRID ARIMA-ANN

Nama Mahasiswa : Fahrizal Andryansyah
NRP : 1315 105 018
Departemen : Statistika
**Dosen Pembimbing 1 : Dr. Dra. Kartika Fithriasari,
M.Si**
Dosen Pembimbing 2 : Dra. Wiwiek Setya Winahju, MS

Abstrak

Pentingnya kebutuhan akan darah membuat PMI menjaga stok persediaan darah yang ada. Data yang dihimpun oleh Unit Transfusi Darah Cabang (UTDC) PMI Surabaya tercatat bahwa untuk stok jenis darah Packed Red Cell (PRC) atau darah merah pekat mencapai 1848 kantong, sementara untuk darah lengkap atau Whole Blood (WB) mencapai 812 kantong dan untuk Trombocyt Concentrad (TC) sebanyak 754 kantong. Mengetahui banyaknya stok persediaan pada PRC, memberikan informasi bahwa permintaan darah jenis PRC lebih tinggi dibandingkan dengan jenis lainnya. Oleh karena itu analisis peramalan pada permintaan darah PRC akan membuat PMI Surabaya dapat mengontrol stok persediaan. Hasil penelitian menunjukkan model terbaik yang digunakan yaitu Model Feed Forward Neural Network (FFNN) untuk setiap Golongan Darah kecuali pada Golongan Darah AB. Sedangkan model terbaik untuk Golongan Darah AB adalah Hybrid ARIMA-ANN.

Kata Kunci: ARIMA, FFNN, Hybrid ARIMA-ANN, PRC.

(Halaman ini sengaja dikosongkan)

ANALYSIS OF PACKED RED CELL DEMAND IN PMI SURABAYA USING ARIMA, ARTIFICIAL NEURAL NETWORK AND HYBRID ARIMA-ANN

Student Name	: Fahrizal Andryansyah
NRP	: 1315 105 018
Department	: Statistics
Supervisor 1	: Dr. Dra. Kartika Fithriasari, M.Si
Supervisor 2	: Dra. Wiwiek Setya Winahju, MS

Abstract

The importance of blood demand makes Indonesia Red Cross Blood Donation called as PMI keep the stock of blood supply. Data collected by Surabaya Blood Transfusion Unit (UTDC) recorded that for packed red cell (PRC) blood stock reached 1848 bags, while for Whole Blood (WB) have reached 812 bags and for Trombocyt Concentrad (TC) of 754 bags. Knowing the amount of inventory stock in the PRC, providing from information before that we know if the blood demand for PRC is higher than any other type. Therefore, forecasting on PRC blood demand will make Surabaya UTDC PMI able to control inventory stock. The results show that the best model is Feed Forward Neural Network Model (FFNN) for each blood group except group AB. The best model for group AB is Hybrid ARIMA-ANN.

Keywords: ARIMA, FFNN, Hybrid ARIMA-ANN, PRC.

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur kehadirat Allah SWT atas rahmat dan karunia-Nya, penulis dapat menyelesaikan Tugas Akhir yang berjudul “**Analisis Jumlah Permintaan Darah Jenis Packed Red Cell Di PMI Surabaya Menggunakan ARIMA, Artificial Neural Network dan Hybrid ARIMA-ANN**” dengan lancar dan tepat waktu.

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

1. Dr. Dra. Kartika Fithriasari, M.Si dan Dra. Wiwiek Setya Winahju, MS selaku dosen pembimbing yang telah banyak meluangkan waktunya untuk memberikan ilmu, bimbingan, dan arahannya dalam penyelesaian Tugas Akhir ini.
2. Dr. Irhamah, S.Si, M.Si dan Bapak Dr. Suhartono M.Sc selaku dosen penguji yang telah memberikan kritik dan saran demi kesempurnaan tugas akhir ini.
3. Dr. Suhartono, S.Si, M.Sc selaku Kepala Departemen Statistika ITS yang telah memberikan fasilitas dalam kelancaran Tugas Akhir ini
4. Dr. Sutikno, M.Si dan Dr. Santi Wulan Purnami, M.Si selaku Ketua Program Studi S1 dan Sekretaris Program Studi S1 yang mengawal proses berjalannya Tugas Akhir Mahasiswa S1 dengan bimbingan serta fasilitas yang diberikan.
5. Dr. Suhartono M.Sc selaku Dosen Wali penulis, seluruh dosen, dan karyawan Statistika ITS atas ilmu dan pengalaman yang telah diberikan kepada penulis.
6. Ibunda Siti Andayani serta Ayahanda Purnomo, yang telah memberikan dukungan, kasih sayang dan doa yang tidak pernah putus kepada penulis.
7. Teman-teman tercinta Mawanda, Alfan, Mas Bagas, Romy, Suprianto, Mbak Fasha, Reni, Rafika, dan Bapak Fajar yang tidak pernah berhenti memberi perhatian kepada penulis.

8. Mahasiswa Jurusan Statistika Lintas Jalur Angkatan 2015 atas semangat yang diberikan pada penulis.
9. Semua pihak yang telah membantu penulis yang tidak dapat disebutkan satu persatu.

Semoga kebaikan dan bantuan yang telah diberikan kepada penulis dibalas dengan kebaikan yang lebih oleh Tuhan Yang Maha Esa.

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

Surabaya, Juli 2017
Penulis

Fahrizal Andryansyah

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xv
DAFTAR TABEL	xvii
DAFTAR LAMPIRAN	xxi
BAB I PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian.....	3
1.4 Manfaat Penelitian.....	4
1.5 Batasan Masalah.....	5
BAB II TINJAUAN PUSTAKA	
2.1 Darah	7
2.2 Pengujian Linearitas	7
2.3 ARIMA Box-Jenkins	8
2.3.1 Stasionaleritas Data	9
2.3.2 ACF dan PACF	11
2.3.3 Identifikasi Model ARIMA	12
2.3.4 Estimasi Parameter	13
2.3.5 Signifikansi Parameter.....	19
2.3.6 Asumsi Residual	20
2.3.7 Pemilihan Model	21
2.4 Artificial Neural Network	22
2.5 Hybrid ARIMA-NN	26
BAB III METODOLOGI PENELITIAN	
3.1 Sumber Data.....	27
3.2 Variabel Penelitian	27
3.3 Langkah Analisis.....	27

3.4	Diagram Alir	28
BAB IV ANALISIS DAN PEMBAHASAN		
4.1	Karakteristik data permintaan darah	31
4.2	Model ARIMA	33
4.2.1	Golongan Darah A	33
4.2.2	Golongan Darah B.....	35
4.2.3	Golongan Darah AB	37
4.2.4	Golongan Darah O	40
4.3	Model FFNN	42
4.3.1	Golongan Darah A	42
4.3.2	Golongan Darah B.....	46
4.3.3	Golongan Darah AB	49
4.3.4	Golongan Darah O	52
4.4	Model Hybrid ARIMA- NN	56
4.4.1	Golongan Darah A	56
4.4.2	Golongan Darah B.....	60
4.4.3	Golongan Darah AB	62
4.4.4	Golongan Darah O	63
4.5	Pemilihan Model Terbaik	65
4.5.1	Golongan Darah A	65
4.5.2	Golongan Darah B.....	68
4.5.3	Golongan Darah AB	71
4.5.4	Golongan Darah O	74
4.6	Peramalan Permintaan Darah Jenis PRC	78
4.6.1	Golongan Darah A	78
4.6.2	Golongan Darah B.....	82
4.6.3	Golongan Darah AB	83
4.6.4	Golongan Darah O	88
BAB V KESIMPULAN DAN SARAN		
5.1	KESIMPULAN	89
5.2	SARAN	90
DAFTAR PUSTAKA		91
LAMPIRAN.....		95

DAFTAR GAMBAR

	Halaman	
Gambar 2.1	Arsitektur FFNN.....	23
Gambar 3.1	Diagram Alir	29
Gambar 4.1	Rata-rata Permintaan Darah per Hari.....	31
Gambar 4.2	Plot Time Series untuk (a),(b),(c) dan (d)	32
Gambar 4.3	Box-Cox Golongan Darah A	33
Gambar 4.4	ACF dan PACF Golongan Darah A.....	34
Gambar 4.5	Box-Cox Golongan Darah B	35
Gambar 4.6	ACF dan PACF Golongan Darah B.....	36
Gambar 4.7	Plot Outsample Golongan Darah B.....	37
Gambar 4.8	Box-Cox Golongan Darah AB.....	38
Gambar 4.9	ACF dan PACF Golongan Darah AB	38
Gambar 4.10	Plot Outsample Golongan Darah AB.....	39
Gambar 4.11	Box-Cox Golongan Darah O	40
Gambar 4.12	ACF dan PACF Golongan Darah O.....	41
Gambar 4.13	Plot Outsample Golongan Darah O	42
Gambar 4.14	Plot Outsample FFNN Golongan Darah A ...	45
Gambar 4.15	Plot Outsample FFNN Golongan Darah B....	49
Gambar 4.16	Plot Outsample FFNN Golongan Darah AB.	51
Gambar 4.17	Plot Outsample FFNN Golongan Darah O ...	55
Gambar 4.18	PACF Residual Golongan Darah A	56
Gambar 4.19	Plot Outsample Hybrid Golongan Darah A ..	60
Gambar 4.20	PACF Residual Golongan Darah B	61
Gambar 4.21	PACF Residual Golongan Darah AB	62
Gambar 4.22	PACF Residual Golongan Darah O	64
Gambar 4.23	Plot Outsample Model Terbaik Golongan Darah A	66
Gambar 4.24	Aristektur FFNN Golongan Darah A.....	68
Gambar 4.25	Plot Outsample Model Terbaik Golongan Darah B	69
Gambar 4.26	Aristektur FFNN Golongan Darah B	71
Gambar 4.27	Plot Outsample Model Terbaik Golongan Darah AB	72

Gambar 4.28	Arsitektur Model Hybrid Golongan Darah AB	74
Gambar 4.29	Plot Outsample Model Terbaik Golongan Darah O	75
Gambar 4.30	Arsitektur Model Hybrid Golongan Darah O	77

DAFTAR TABEL

	Halaman
Tabel 2.1	Transformasi Box-Cox.....
Tabel 2.2	Karakteristik ACF dan PACF.....
Tabel 4.1	Rata-rata Permintaan Darah per Bulan.....
Tabel 4.2	Model ARIMA Golongan Darah A
Tabel 4.3	Model ARIMA Golongan Darah B
Tabel 4.4	Akurasi Peramalan Golongan B
Tabel 4.5	Model ARIMA Golongan Darah AB
Tabel 4.6	Akurasi Peramalan Golongan AB
Tabel 4.7	Model ARIMA Golongan Darah O
Tabel 4.8	Akurasi Peramalan Golongan O
Tabel 4.9	Uji Teraesvirta Golongan Darah A.....
Tabel 4.10	Akurasi Model FFNN Golongan Darah A.....
Tabel 4.11	Uji Teraesvirta Golongan Darah B
Tabel 4.12	Akurasi Model FFNN Golongan Darah B
Tabel 4.13	Uji Teraesvirta Golongan Darah AB
Tabel 4.14	Akurasi Model FFNN Golongan Darah AB
Tabel 4.15	Uji Teraesvirta Golongan Darah O.....
Tabel 4.16	Akurasi Model FFNN Golongan Darah O.....
Tabel 4.17	Uji Teraesvirta Residual Golongan Darah A.....
Tabel 4.18	Akurasi Model FFNN Residual Golongan Darah A.....
Tabel 4.19	Akurasi Model Hybrid Golongan Darah A
Tabel 4.20	Uji Teraesvirta Residual Golongan Darah B
Tabel 4.21	Akurasi Model FFNN Residual Golongan Darah B
Tabel 4.22	Uji Teraesvirta Residual Golongan Darah AB ...
Tabel 4.23	Akurasi Model FFNN Residual Golongan Darah AB
Tabel 4.24	Uji Teraesvirta Residual Golongan Darah AB ...
Tabel 4.25	Akurasi Model NN Residual Golongan Darah AB
Tabel 4.26	Perbandingan Model Terbaik Golongan Darah A.....

Tabel 4.27	Perbandingan Model Terbaik Golongan Darah B	68
Tabel 4.28	Perbandingan Model Terbaik Golongan Darah AB	72
Tabel 4.29	Perbandingan Model Terbaik Golongan Darah O.....	75
Tabel 4.30	Hasil Peramalan Model Terbaik Golongan Darah A.....	81
Tabel 4.31	Hasil Peramalan Model Terbaik Golongan Darah B	82
Tabel 4.32	Hasil Peramalan Model Terbaik Golongan Darah AB	87
Tabel 4.33	Hasil Peramalan Model Terbaik Golongan Darah O.....	88

DAFTAR LAMPIRAN

	Halaman	
Lampiran 1	Struktur Data Permintaan Darah Jenis PRC	95
Lampiran 2	Syntax ARIMA di R	95
Lampiran 3	Estimasi Parameter ARIMA Golongan Darah A	97
Lampiran 4	Estimasi Parameter ARIMA Golongan Darah B	97
Lampiran 5	Estimasi Parameter ARIMA Golongan Darah AB	98
Lampiran 6	Estimasi Parameter ARIMA Golongan Darah O	98
Lampiran 7	Estimasi Parameter ARIMA Golongan Darah AB untuk peramalan Hybrid.....	98
Lampiran 8	Residual Normal ARIMA.....	99
Lampiran 9	Residual White Noise ARIMA	99
Lampiran 10	Uji Teraesvirta.....	101
Lampiran 11	Syntax FFNN 10 input di SPSS.....	102
Lampiran 12	Struktur Data FFNN Golongan Darah A	104
Lampiran 13	Standardized Golongan Darah A	105
Lampiran 14	Hasil Ramalan Golongan Darah A	105
Lampiran 15	Hasil Ramalan Model ARIMA Golongan Darah AB	106
Lampiran 16	Residual Model ARIMA Golongan arah AB	107
Lampiran 17	Estimasi Parameter Model Terbaik Golongan Darah A.....	108
Lampiran 18	Estimasi Parameter Model Terbaik Golongan Darah B	109
Lampiran 19	Estimasi Parameter Model Terbaik Golongan Darah AB	110
Lampiran 20	Estimasi Parameter Model Terbaik Golongan Darah B	111
Lampiran 21	Komponen Darah di PMI Surabaya.....	112
Lampiran 22	Surat Pengambilan Data di PMI Kota Surabaya	113

(Halaman Ini Sengaja Dikosongkan)

BAB I

PENDAHULUAN

1.1 Latar Belakang

Darah merupakan bagian penting dari tubuh manusia, salah satu manfaatnya adalah mengirimkan zat-zat dan oksigen yang dibutuhkan oleh jaringan tubuh, mengangkut bahan-bahan kimia hasil metabolisme, dan juga sebagai pertahanan tubuh terhadap virus atau bakteri. Dalam beberapa kasus sering terjadi orang – orang yang kehilangan darah (hemmorage), salah satunya disebabkan oleh luka luar. Jika tidak dengan segera mendapatkan penanganan yang tepat seperti transfusi darah, maka gejala yang paling parah yaitu dapat merenggut nyawa. Sehingga donor darah akan sangat diperlukan di Rumah Sakit ataupun saat terjadi kasus Bencana Alam yang akan merenggut banyak korban. Salah satu organisasi yang bergerak dalam bidang sosial kemanusiaan adalah Palang Merah Indonesia (PMI). Adapun beberapa kegiatan utama yang dilakukan PMI yaitu manajemen bencana, kesehatan dan donor darah. Seiring bertambahnya permintaan darah maka untuk menjaga stok persediaan darah, PMI gencar melakukan sosialisasi akan manfaat donor darah, sehingga diharapkan masyarakat lebih memahami pentingnya donor darah bagi kesehatan tubuh (PMI, 2013).

Pentingnya kebutuhan akan darah membuat PMI menjaga stok persediaan darah yang ada. Data yang dihimpun oleh Unit Transfusi Darah Cabang (UTDC) PMI Surabaya tercatat bahwa untuk darah merah padat atau *Packed Red Cell* (PRC) golongan darah A sebanyak 531 kantong ,sedangkan untuk golongan darah B sebanyak 631 kantong, untuk golongan darah AB sebanyak 193 kantong, dan golongan darah O sebanyak 493 kantong. Persediaan darah tersebut dapat dikatakan cukup melimpah, melimpahnya persediaan darah tidak lain dikarenakan gencarnya penggalangan donor darah yang dilakukan oleh PMI Surabaya. Menurut Humas UTDC PMI Surabaya, persediaan darah yang stabil tersebut digunakan untuk mengantisipasi menipisnya persediaan darah di

waktu mendatang, khususnya setelah lebaran. Sehingga untuk dapat menuhi permintaan darah, PMI Surabaya sudah melakukan aktivitas dengan mendatangi sekolah-an, perusahaan serta masjid yang ada di kota Surabaya (Nurwawati, 2016).

Pada informasi sebelumnya juga diketahui bahwa stok persediaan darah jenis PRC merupakan yang terbanyak daripada stok jenis darah lainnya. Pada bagian PRC terdapat *Hemoglobin* (Hb) yang berfungsi untuk mengatur pertukaran O₂ dengan CO₂ pada seluruh jaringan yang ada di dalam tubuh. Sehingga jika tubuh kekurangan Hb maka akan berdampak terhadap mudah letihnya tubuh seseorang, hal tersebut dikarenakan kurangnya oksigen di dalam tubuh (Sari M.Si, 2015). Anemia adalah suatu kondisi tubuh yang terjadi ketika sel darah merah atau Hb yang sehat dalam darah berada dibawah nilai normal (kurang darah). Acuan nilai normal untuk dewasa yaitu perbandingan sel darah merah dengan volume darah untuk pria sekitar 38,8 – 50 % sedangkan untuk wanita sebesar 34,9 – 44,5 % serta kadar Hb dalam darah untuk pria sekitar 13,5 – 17,5 gr/dl dan untuk wanita sekitar 12 – 15,5 gr/dl (Muhlisin, 2017).

Indonesia termasuk salah satu negara dengan jumlah penderita anemia yang masih banyak. Menurut survei yang dilakukan oleh *World Health Organization* (WHO) di tahun 2005 terdapat 4 kategori untuk jumlah masyarakat di suatu negara yang terjangkit penyakit Anemia yaitu kategori normal (< 5 %), ringan (5-19,9%) sedang (20 – 39,9 %) dan berat ($\geq 40\%$). Informasi yang diperoleh dari WHO menunjukkan Indonesia pada usia balita termasuk kedalam kategori berat, kemudian pada wanita hamil termasuk kedalam kategori berat dan untuk wanita tidak hamil di usia produktif (15 – 49,99 tahun) termasuk kategori sedang (Benoist & McLean, 2008). Satu dari lima penduduk di Indonesia mengalami anemia. Hal tersebut lantaran banyak masyarakat yang tidak menyadari bahwa dirinya mengalami anemia. Berdasarkan data yang dihim-pun oleh Riset Kesehatan Dasar (Riskesdas) tahun 2013, jumlah penderita anemia di Indonesia terdiri dari 26,4 persen anak-anak, 12,4 persen laki-laki usia 13-18 tahun, 16,6

persen laki-laki di atas 15 tahun, 22,7 persen perempuan usia 13-18 tahun, 22,7 persen wanita usia 15-49 tahun dan 37,1 persen pada ibu hamil (Riskesdas, 2013).

Mengetahui semakin banyaknya penderita anemia yang ada di Indonesia membuat kebutuhan darah jenis PRC meningkat, oleh karena itu peningkatan sukarelawan donor darah dari masyarakat membuat persediaan darah dapat terkontrol. Aktivitas donor darah dapat memberikan manfaat bagi para pendonor, salah satu alasan yang paling sederhana untuk menjadi pendonor darah, tentu saja bukan hanya karena sekedar mengikuti tren, namun dapat meningkatkan kesehatan dan menjauhkan tubuh berbagai macam serangan penyakit berbahaya. *The American Journal of Epidemiology* mencatat bahwa 88% pendonor darah memiliki peluang untuk terhindar dari serangan jantung dan 33% terhindar dari gangguan pembuluh darah. (Marganti, 2016).

Penelitian tugas akhir sebelumnya tentang analisis banyaknya permintaan darah pernah dilakukan oleh Febriana (2010). Pada penelitian tersebut diperoleh hasil Model VARIMA lebih baik daripada Model ARIMA. *Artificial Neural Network* telah banyak digunakan sebagai metode yang menjanjikan untuk peramalan *time series* (Kristianda & Fithriasari, 2016). Meskipun terdapat banyak model *Artificial Neural Network* (ANN) yang telah diusulkan, namun yang paling populer adalah model atau arsitektur *Feed Forward Neural Network* (FFNN) (Zhang & Qi, 2005). Penelitian menggunakan model FFNN pernah dilakukan oleh Fithriasari, Iriawan, Ulama dan Sutikno (2013) yang menyimpulkan bahwa peramalan dengan menggunakan *Time Delay Neural Network* (TDNN) lebih baik daripada FFNN. Penelitian serupa juga dilakukan oleh Fithriasari, Iriawan, Ulama, Sutikno dan Kuswanto (2013) yang memperoleh hasil bahwa model *Bayesian Neural Network* (BNN) dengan prosedur *adjusting* lebih baik daripada model FFNN. Zahrati, Fithriasari, dan Irhamah (2016) juga melakukan penelitian dengan menggunakan model FFNN dan diperoleh hasil bahwa model FFNN lebih baik daripada model VAR.

Akan tetapi pada faktanya tidak ada satupun model tunggal terbaik dalam berbagai situasi, oleh karena itu penggabungan dari pendekatan linear pada ARIMA dan nonlinear pada ANN dapat diterapkan. Keuntungan yang diperoleh dari penggabungan kedua model tersebut adalah dapat menggunakan karakteristik yang unik dari masing-masing model dan kekuatan, serta dapat menangkap lebih baik suatu pola dalam data dan meningkatkan hasil peramalan (Zhang, 2004).

Sehingga pada penelitian ini akan ditambahkan metode *Artificial Neural Network* (ANN) untuk dapat menangkap pola nonlinear serta menggunakan metode *Hybrid ARIMA-ANN* untuk melakukan peramalan permintaan darah jenis PRC pada setiap golongan darah. Oleh karena itu penelitian ini akan memberikan kesimpulan dari suatu model terbaik, yang dapat digunakan sebagai hasil ramalan permintaan darah di PMI Kota Surabaya.

1.2 Rumusan Masalah

Mengetahui banyaknya permintaan darah sangatlah penting jika tidak dapat memenuhi permintaan atau stok persediaan darah habis maka dapat berakibat tidak tertolongnya seseorang yang membutuhkan transfusi darah. Oleh karena itu pada penelitian ini akan dilakukan analisis peramalan untuk permintaan darah di PMI Surabaya pada periode yang akan datang dengan menggunakan metode ARIMA untuk menangkap pola linear dan ANN untuk menangkap pola non linear serta *Hybrid ARIMA-ANN*.

1.3 Tujuan Penelitian

Tujuan dilakukan penelitian ini adalah untuk memodelkan dan meramalkan banyaknya permintaan darah pada setiap golongan darah di PMI Surabaya pada periode yang akan datang.

1.4 Manfaat Penelitian

Manfaat yang ingin diperoleh dari penelitian ini adalah dapat memberikan masukan dan informasi kepada pihak PMI kota Surabaya untuk dapat mengontrol stok persediaan darah. Serta da-

pat membantu PMI untuk menentukan berapa jumlah donor darah yang diperlukan.

1.5 Batasan Masalah

Pada penelitian ini, data yang diteliti adalah permintaan darah Jenis *Packed Red Cell* (PRC) untuk setiap Golongan Darah selama tahun 2016.

(Halaman Ini Sengaja Dikosongkan)

BAB II

TINJAUAN PUSTAKA

2.1 Darah

Darah yang diambil dari para pendonor merupakan darah lengkap atau Whole Blood (WB), yang memiliki komposisi dengan sel darah merah sekitar 45%, sel darah putih dan trombosit sekitar <1% dan plasma darah sekitar 55%. Darah lengkap tersebut dapat dipisahkan menjadi beberapa jenis, yaitu sel darah merah atau Packed Red Cel (PRC), jenis trombosit atau Thrombocyte Concentrate (TC) dan jenis plasma darah beku atau Fresh Frozen Plasma (FFP). Pembagian jenis darah tersebut dikarenakan saat ini pasien yang memerlukan darah tidak harus menggunakan WB namun dapat menggunakan jenis darah yang lebih spesifik sesuai dengan kondisi pasien (Red Cross Blood, 2016).

Meskipun komposisi pada darah manusia sama namun faktanya terdepat perbedaan pada tipe golongan darah yang ditentukan oleh ada atau tidaknya antigen tertentu serta zat yang dapat memicu sistem imun pada tubuh. Sehingga jika melakukan transfusi dengan tipe golongan darah yang salah maka akan dapat menyerang sistem kekebalan tubuh (Red Cross Blood, 2016). Untuk tipe golongan darah manusia terdiri dari 4 jenis yaitu golongan darah A, B, AB dan O. Sedangkan donor darah adalah proses pengambilan darah dari seseorang secara sukarela atau pengganti untuk disimpan di bank darah sebagai stok darah untuk kemudian digunakan untuk transfusi darah (PMI, 2015).

2.2 Pengujian Linearitas

Pengujian linearitas di time series telah diperkenalkan berdasarkan konsep dari neural network teori. Secara umum perhitungan. Model neural network yang digunakan adalah sebagai berikut.

$$y_t = \pi' w_t + \sum_{j=1}^q \theta_{0j} \left\{ \psi(\gamma_j' w_t) - \frac{1}{2} \right\} + \mu_t$$

dengan θ adalah banyaknya unit neuron pada hidden layer. Hipotesis yang digunakan dalam uji ini adalah sebagai berikut (Terasvirta, et al., 1993).

$$H_0 : \theta_{01} = \dots = \theta_{0q} = 0$$

$$H_1 : \text{minimal ada satu } \theta_{0j} \neq 0 \text{ dengan } j = 1, 2, \dots, q$$

Untuk mendapatkan statistik uji dapat dilakukan dalam 3 tahapan berikut ini.

1. Regresikan Y_t dengan $1, Y_{t-i}, \dots, Y_{t-p}$. Kemudian hitung residual

$$\hat{\mu}_t \text{ dan jumlah kuadrat error } SSR_0 = \sum \hat{\mu}_t^2$$

2. Regresikan $\hat{\mu}_t$ dengan $1, Y_{t-i}, \dots, Y_{t-p}$. Hitung residual $\hat{\nu}_t$ dan

$$\text{jumlah kuadrat error } SSR = \sum \hat{\nu}_t^2$$

3. Melakukan perhitungan untuk uji F sebagai berikut.

$$F = \frac{(SSR_0 - SSR)/m}{SSR/(n - p - 1 - m)}$$

dengan n adalah banyaknya pengamatan, sedangkan m adalah variabel prediktor tambahan dan p adalah banyaknya lag yang digunakan. Untuk mendapatkan daerah penolakan yaitu tolak H_0 jika F lebih besar daripada F tabel dengan derajat bebas m dan $(n - p - 1 - m)$.

2.3 ARIMA Box-Jenkins

Analisis *Time Series* adalah serangkaian pengamatan terhadap suatu variabel yang diamati secara berurutan dari waktu ke waktu menurut urutan waktu kejadian dan dengan interval waktu yang tetap (Wei, 2006). ARIMA Box-Jenkins merupakan salah satu metode yang sering digunakan dalam meramalkan data *time series*. Tujuan dari metode peramalan tersebut adalah untuk dapat melihat pola data *time series* yaitu pada permintaan darah dan menggunakan pola tersebut ke periode yang akan datang.

Ada beberapa hal yang harus diperhatikan dalam melakukan analisis data *time series* yaitu dengan metode ARIMA Box-Jenkins, yaitu stasioneritas data, fungsi autokorelasi (ACF) dan

fungsi autokorelasi parsial (PACF). Setelah melakukan pemeriksaan tersebut kemudian dapat melakukan penaksiran model ARIMA Box-Jenkins. Prosedur ini meliputi identifikasi model, estimasi parameter, pemeriksaan asumsi residual dan melakukan peramalan.

2.3.1 Stasioneritas Data

Proses Stokastik adalah himpunan dari indeks waktu dengan variabel random $Y(\omega, t)$, dimana ω adalah semua nilai yang mungkin untuk Y_t (*sample space*) dan t adalah kumpulan indeks waktu. Suatu proses dikatakan orde pertama stasioner jika satu ukuran fungsi distribusi adalah invariant terhadap waktu, dengan contoh $F_{Y_t}(X_1) = F_{Y_{t_1+k}}(X_1)$ dimana t_1, k dan $t_1 + k$ adalah semua bilangan integer. Untuk orde kedua stasioner jika $F_{Y_{t_1}, t_2}(x_1, x_2) = F_{Y_{t_1+k}, t_2+k}(x_1, x_2)$ dimana $t_1, t_2, k, t_1 + k$ dan $t_2 + k$ adalah semua bilangan integer. Sedangkan untuk orde ke-n dikatakan stasioner jika

$$F_{Y_{t_1}, \dots, Y_{t_n}}(x_1, \dots, x_n) = F_{Y_{t_1+k}, \dots, Y_{t_n+k}}(x_1, \dots, x_n)$$

dimana untuk semua n dan k adalah bilangan integer ($n = 1, 2, 3, \dots$). Sebuah proses *real-valued* dengan $\{Y_t : t = 0, \pm 1, \pm 2, \dots\}$, memiliki fungsi mean dan fungsi varians dari proses seperti pada persamaan 2.1.

$$\mu_t = E(Y_t) \quad (2.1)$$

$$\sigma_t^2 = E(Y_t - \mu_t)^2$$

Untuk suatu proses dikatakan stasioner, jika fungsi distribusinya sama untuk setiap nilai t. Sehingga pada persamaan (2.1), untuk fungsi mean dan fungsi varians dapat dirubah sebagai berikut ini (Wei, 2006).

$$\mu_t = \mu \quad ; \quad E(Y_t) < \infty \quad (2.2)$$

$$\sigma_t^2 = \sigma^2 \quad ; \quad E(Y_t^2) < \infty$$

Stasioneritas dalam data time series ditunjukkan apabila rata-rata dan variansnya konstan setiap waktu. Untuk melakukan

stasioner data terhadap varians maka dapat digunakan transformasi Box-Cox sebagai berikut.

$$T(Y_t) = \frac{Y_t^\lambda - 1}{\lambda} ; \text{ untuk } \lambda \neq 0 \quad (2.3)$$

Untuk melihat $\lambda = 0$ agar sesuai logaritma transformasi, maka dengan menggunakan rumus pada persamaan (2.3) diperoleh hasil berikut.

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

dimana λ merupakan parameter transformasi dari transformasi Box-Cox. Beberapa nilai λ yang sering digunakan serta hasil transformasinya dapat dilihat pada Tabel 2.1 (Wei, 2006).

Transformasi Box-Cox hanya berlaku untuk data yang bernilai positif. Jika pada suatu data pengamatan terdapat beberapa nilai negatif atau 0, maka suatu bilangan konstanta yang bernilai positif dapat ditambahkan pada seluruh nilai data pengamatan, sehingga sehingga seluruh data akan bernilai positif dan transformasi Box-Cox dapat dilakukan (Cryer, 2008).

Tabel 2.1 Transformasi Box-Cox

Nilai λ	Transformasi
-1.0	$\frac{1}{Y_t}$
-0.5	$\frac{1}{\sqrt{Y_t}}$
0.0	$\ln Y_t$
0.5	$\sqrt{Y_t}$
1.0	Y_t

Selanjutnya dapat dilakukan identifikasi kestasioneran data terhadap mean. Identifikasi stasioner data terhadap mean dapat menggunakan plot ACF. Jika pada *time series plot* berfluktiasi disekitar nilai rata-rata maka data tersebut sudah stasioner dalam mean. Apabila data time series tidak stasioner dalam mean, maka

dapat dilakukan *differencing*. Sedangkan rumus yang digunakan untuk melakukan *differencing* adalah sebagai berikut (Wei, 2006).

$$W_t = (1 - B)^d Y_t$$

dimana:

W_t : Data hasil *differencing*

Y_t : Data *time series* pada waktu ke-t

d : Orde *differencing*

2.3.2 ACF dan PACF

ACF digunakan untuk menunjukkan hubungan linear antar pengamatan Y_t dengan Y_{t+k} . Untuk sebuah proses dapat dikatakan stasioner $\{Y_t\}$ jika diperoleh bahwa mean dan variance adalah konstan seperti pada persamaan (2.2). Sedangkan pada covariance yaitu $Cov(Y_t, Y_s)$, dimana fungsi tersebut hanya memiliki perbedaan pada waktu yaitu $|t-s|$. Oleh karena itu covariance diantara Y_t dan Y_{t+k} adalah sebagai berikut.

$$\gamma_k = Cov(Y_t, Y_{t+k}) = E(Y_t - \mu)(Y_{t+k} - \mu) \quad (2.4)$$

Merujuk dari fungsi autokovarians pada persamaan (2.4), dapat diperoleh bahwa korelasi diantara Y_t dan Y_{t+k} memiliki rumus sebagai berikut.

$$\rho_k = \frac{Cov(Y_t, Y_{t+k})}{\sqrt{Var(Y_t)} \sqrt{Var(Y_{t+k})}} = \frac{\gamma_k}{\gamma_0}$$

dimana :

$$\gamma_0 = Var(Y_t) = Var(Y_{t+k})$$

γ_k = fungsi autokovarians pada *lag* ke-k

ρ_k = fungsi autokorelasi (ACF) pada *lag* ke-k

Syarat yang harus terpenuhi oleh fungsi autokorelasi dan autokovarians pada proses kestasioneran sebagai berikut (Wei, 2006).

1. $\gamma_0 = Var(Y_t)$; $\rho_0 = 1$
2. $|\gamma_k| \leq \gamma_0$; $|\rho_k| \leq 1$
3. $\gamma_k = \gamma_{-k}$; $\rho_k = \rho_{-k}$

PACF digunakan untuk mengukur tingkat keeratan korelasi antara pengamatan Y_t dengan Y_{t+k} , kemudian hubungan linear dependensi dalam variabel $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$ telah dihilangkan, maka korelasinya sebagai berikut.

$$\text{Corr}(Y_t, Y_{t+k} | Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}) \quad (2.5)$$

Dari persamaan (2.5), secara umum *partial* autokorelasi diantara Y_t dengan Y_{t+k} dapat dirumuskan sebagai berikut (Wei, 2006).

$$P_k = \frac{\text{Cov}(Y_t, \hat{Y}_t), (Y_{t+k}, \hat{Y}_{t+k})}{\sqrt{\text{Var}(Y_t - \hat{Y}_t)} \sqrt{\text{Var}(Y_{t+k} - \hat{Y}_{t+k})}}$$

dimana :

P_k = fungsi parsial autokorelasi

Y_t = nilai pada waktu ke- t

\hat{Y}_t = nilai taksiran pada waktu ke- t

2.3.3 Identifikasi Model ARIMA

Mengidentifikasi suatu Model ARIMA dapat dapat didasarkan dengan pendekatan pola ACF dan PACF, karakteristik kedua pola tersebut dapat ditabelkan seperti pada Tabel 2.2.

Tabel 2.2 Karakteristik plot ACF dan PACF

	AR(p)	MA(q)	ARMA(p,q) $p>0$ dan $q>0$
ACF	Turun cepat secara eksponensial atau sinusoidal	Cuts off setelah lag q	Turun cepat
PACF	Cuts off setelah lag p	Turun cepat secara eksponensial atau sinusoidal	Turun cepat

Pola dari ACF dan PACF lebih efektif digunakan untuk mengidentifikasi model *Autoregresif* (AR) dan model *Moving Average* (MA). Namun untuk model gabungan *Autoregressive Moving Average* (ARMA), secara teoritis ACF dan PACF memiliki banyak nilai selain nol yang tidak terbatas, sehingga akan lebih sulit untuk mengidentifikasi model jika dilihat dari plot ACF dan PACF (Cryer, 2008).

Untuk model *Autoregresif* (AR) menunjukkan nilai suatu variabel yang dipengaruhi oleh variabel tersebut pada periode sebelumnya. Model AR(p) dapat dituliskan sebagai berikut (Wei, 2006).

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + a_t$$

Model *Moving Average* (MA) menunjukkan bahwa nilai suatu variabel dipengaruhi oleh residual pada waktu ke t sampai waktu ke $t-q$ (Makridakis, 1999). Model MA (q) dapat dituliskan sebagai berikut.

$$Y_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

Time series non stasioner dapat dikatakan sebagai proses *Autoregressive Integrated Moving Average* (ARIMA) yang merupakan gabungan model AR dan model MA dengan *differencing* orde d . Sehingga bentuk umum dari model ARIMA (p,d,q) dapat dituliskan sebagai berikut (Wei, 2006).

$$\phi_p(B)(1-B)^d Y_t = \theta_0 + \theta_q(B)a_t \quad (2.6)$$

jika $d = 0$ maka model berdasarkan data stasioner menjadi ARMA (p,q). Sehingga persamaan (2.6) berubah menjadi model ARMA (p,q) atau dapat dituliskan sebagai berikut (Wei, 2006).

$$\phi_p(B)Y_t = \theta_q(B)a_t \quad (2.7)$$

dimana :

$$\phi_p(B) = \text{koefisien AR orde } p \quad (\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p))$$

$$\theta_q(B) = \text{koefisien MA orde } q \quad (\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q))$$

Y_t = variabel Y pada waktu ke- t

a_t = residual pada waktu ke- t

d = orde *differencing*

2.3.4 Estimasi Parameter

Perhitungan estimasi parameter dapat menggunakan estimasi *least square*, *moment*, *maximum likelihood estimation* dan *unconditional least square*. Perhitungan menggunakan metode *moment* tidak sesuai untuk beberapa model, oleh karena itu harus

dipertimbangkan untuk menggunakan metode estimasi lainnya. Salah satu metode estimasi yang sering digunakan yaitu metode *least square*. Penelitian ini menggunakan metode estimasi *least square*, yang bertujuan untuk meminimumkan jumlah kuadrat residual. Secara umum perhitungan metode *least square* untuk model AR(1) sebagai berikut (Cryer, 2008).

$$Y_t - \mu = \phi(Y_{t-1} - \mu) + a_t \quad (2.8)$$

Persamaan 2.8 sama seperti model regresi dengan variabel prediktor Z_{t-1} dan variabel respon Z_t . Estimasi *Least Square* dilakukan dengan meminimumkan jumlah kuadrat residual.

$$a_t = (Y_t - \mu) - \phi(Y_{t-1} - \mu)$$

Karena hanya Y_1, Y_2, \dots, Y_n yang diamati, maka yang hanya dapat dijumlahkan yaitu $t=2$ hingga $t=n$ seperti persamaan berikut.

$$S_c(\phi, \mu) = \sum_{t=2}^n [(Y_t - \mu) - \phi(Y_{t-1} - \mu)]^2 \quad (2.9)$$

Persamaan diatas biasanya sering disebut *Conditional sum-of-square function*. Menurut prinsip dari *least square* yaitu meminimumkan jumlah kuadrat residual, maka untuk mengestimasi nilai μ dan ϕ dilakukan dengan cara menurunkan persamaan 2.9 terhadap μ dan ϕ , diperoleh hasil sebagai berikut.

$$\frac{\partial S_c}{\partial \mu} = \sum_{t=2}^n 2[(Y_t - \mu) - \phi(Y_{t-1} - \mu)](-1 + \phi) = 0 \quad (2.10)$$

Dapat diperoleh persamaan μ sebagai berikut.

$$\mu = \frac{1}{(n-1)(1-\phi)} \left[\sum_{t=2}^n Y_t - \phi \sum_{t=2}^n Y_{t-1} \right] \quad (2.11)$$

Sekarang untuk nilai n besar, dapat ditaksir sebagai berikut.

$$\frac{1}{(n-1)} \sum_{t=2}^n Y_t \approx \frac{1}{(n-1)} \sum_{t=2}^n Y_{t-1} \approx \bar{Y}$$

Sehingga persamaan 2.11 dapat disederhanakan sebagai berikut.

$$\hat{\mu} = \frac{1}{1-\phi} (\bar{Y} - \phi \bar{Y}) = \bar{Y} \quad (2.12)$$

Pada persamaan diatas dapat juga dinyatakan bahwa $\hat{\mu} = \bar{Y}$, maka dengan cara yang sama persamaan 2.10 menjadi sebagai berikut.

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

Sehingga diperoleh persamaan ϕ sebagai berikut.

$$\hat{\phi} = \frac{\sum_{t=2}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=2}^n (Y_{t-1} - \bar{Y})^2} \quad (2.13)$$

Kecuali ada salah satu kondisi yang hilang pada penyebut di persamaan 2.13 yaitu, $(Y_n - \bar{Y})^2$ membuat $\hat{\phi} = r_1$. Penyebut yang hilang tersebut dapat diabaikan selama proses stasioner, oleh karena itu estimasi *least square* dan *moment* hampir identik, khususnya untuk sample yang berjumlah besar.

Selanjutnya untuk model AR(2) sesuai dengan persamaan 2.11 dan 2.12 maka $\hat{\mu} = \bar{Y}$ sehingga diperoleh persamaan AR(2) sebagai berikut.

$$Y_t - \bar{Y} = \phi_1(Y_{t-1} - \bar{Y}) + \phi_2(Y_{t-2} - \bar{Y}) + a_t,$$

Sehingga diperoleh *Conditional sum-of-square function* sebagai berikut.

$$S_c(\phi_1, \phi_2, \bar{Y}) = \sum_{t=3}^n [(Y_t - \bar{Y}) - \phi_1(Y_{t-1} - \bar{Y}) - \phi_2(Y_{t-2} - \bar{Y})]^2 \quad (2.14)$$

Kemudian dilakukan penurunan terhadap persamaan 2.14, diperoleh hasil sebagai berikut.

$$\frac{\partial S_c}{\partial \phi_1} = -2 \sum_{t=3}^n [(Y_t - \bar{Y}) - \phi(Y_{t-1} - \bar{Y}) - \phi_2(Y_{t-2} - \bar{Y})](Y_{t-1} - \bar{Y}) = 0$$

Persamaan diatas dapat disederhanakan, kemudian ditulis ulang sebagai berikut.

$$\sum_{t=3}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y}) = \left(\sum_{t=3}^n (Y_{t-1} - \bar{Y})^2 \right) \phi_1 + \left(\sum_{t=3}^n (Y_{t-1} - \bar{Y})(Y_{t-2} - \bar{Y}) \right) \phi_2$$

Jumlahan dari $\sum_{t=3}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})$ merupakan pembilang dari r_1 , kemudian kedua sisi dari persamaan diatas dapat dibagi dengan $\sum_{t=3}^n (Y_{t-1} - \bar{Y})^2$ diperoleh hasil sebagai berikut.

$$\frac{\sum_{t=3}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=3}^n (Y_{t-1} - \bar{Y})^2} = \frac{\sum_{t=3}^n (Y_{t-1} - \bar{Y})^2}{\sum_{t=3}^n (Y_{t-1} - \bar{Y})^2} \phi_1 + \frac{\sum_{t=3}^n (Y_{t-1} - \bar{Y})(Y_{t-2} - \bar{Y})}{\sum_{t=3}^n (Y_{t-1} - \bar{Y})^2} \phi_2$$

$$r_1 = \phi_1 + r_1 \phi_2 \quad (2.15)$$

Kemudian diturunkan terhadap ϕ_2 .

$$\frac{\partial S_c(\phi_1, \phi_2, \bar{Y})}{\partial \phi_2} = 0$$

$$-2 \sum_{t=3}^n [(Y_t - \bar{Y}) - \phi(Y_{t-1} - \bar{Y}) - \phi_2(Y_{t-2} - \bar{Y})](Y_{t-2} - \bar{Y}) = 0$$

$$\sum_{t=3}^n (Y_t - \bar{Y})(Y_{t-2} - \bar{Y}) = \left(\sum_{t=3}^n (Y_{t-1} - \bar{Y})(Y_{t-2} - \bar{Y}) \right) \phi_1 + \left(\sum_{t=3}^n (Y_{t-2} - \bar{Y})^2 \right) \phi_2$$

Selanjutnya kedua sisi dibagi dengan $\sum_{t=3}^n (Y_{t-2} - \bar{Y})^2$, diperoleh

hasil sebagai berikut.

$$\frac{\sum_{t=3}^n (Y_t - \bar{Y})(Y_{t-2} - \bar{Y})}{\sum_{t=3}^n (Y_{t-2} - \bar{Y})^2} = \frac{\sum_{t=3}^n (Y_{t-1} - \bar{Y})(Y_{t-2} - \bar{Y})}{\sum_{t=3}^n (Y_{t-2} - \bar{Y})^2} \phi_1 + \frac{\sum_{t=3}^n (Y_{t-2} - \bar{Y})^2}{\sum_{t=3}^n (Y_{t-2} - \bar{Y})^2} \phi_2$$

$$r_2 = r_1 \phi_1 + \phi_2 \quad (2.16)$$

Akan tetapi persamaan 2.15 dan 2.16 hanyalah contoh dari persamaan *Yule-Walker* untuk model AR(2). Hasil yang serupa juga

berlaku pada AR(p), estimasi *least square* untuk $\phi_1, \phi_2, \dots, \phi_p$ diperoleh dari memecahkan persamaan *Yule-Walker*.

$$\begin{aligned}\phi_1 + r_1\phi_2 + r_2\phi_3 + \dots + r_{p-1}\phi_p &= r_1 \\ r_1\phi_1 + \phi_2 + r_1\phi_3 + \dots + r_{p-2}\phi_p &= r_2 \\ &\vdots \\ r_{p-1}\phi_1 + r_{p-2}\phi_2 + r_{p-3}\phi_3 + \dots + \phi_p &= r_p\end{aligned}\tag{2.17}$$

Kemudian untuk mendapatkan estimator $\hat{\phi}_1, \hat{\phi}_2, \dots, \hat{\phi}_p$ dapat diperoleh dengan menyederhanakan sistem persamaan 2.17. Sehingga diperoleh matriks estimator berikut ini.

$$\begin{bmatrix} \hat{\phi}_1 \\ \hat{\phi}_2 \\ \vdots \\ \hat{\phi}_p \end{bmatrix} = \begin{bmatrix} 1 & r_1 & r_2 & \dots & r_{p-1} \\ r_1 & 1 & r_1 & \dots & r_{p-2} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ r_{p-1} & r_{p-2} & r_{p-3} & \dots & 1 \end{bmatrix}^{-1} \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_p \end{bmatrix}$$

Selanjutnya untuk model MA(1) memiliki persamaan sebagai berikut (Cryer, 2008).

$$Y_t = a_t - \theta a_{t-1}\tag{2.18}$$

Bentuk pada persamaan 2.18 juga memiliki bentuk *invertible* model MA(1) yang dapat ditulis sebagai berikut.

$$Y_t = -\theta Y_{t-1} - \theta^2 Y_{t-2} - \theta^3 Y_{t-3} - \dots + a_t$$

Sehingga memiliki bentuk jumlah kuadrat residual dari Model MA(1) sebagai berikut.

$$S_c(\theta) = \sum (a_t)^2 = \sum [Y_t + \theta Y_{t-1} + \theta^2 Y_{t-2} + \theta^3 Y_{t-3} + \dots]^2\tag{2.19}$$

Persamaan 2.19 merupakan kelemahan dari metode *least square*, karena persamaan tersebut memiliki parameter yang tidak linier. Sehingga meminimumkan $S_c(\theta)$ dengan $\partial S_c(\theta) / \partial \theta = 0$ tidak dapat dilakukan. Jadi bahkan model MA(1) untuk mendapatkan estimasi parameter perlu dilakukan optimisasi numerik. Masalah lainnya yaitu tidak diketahui batas dari jumlahan pada persamaan 2.19, maupun cara menangani deret tak hingga dibawah tanda jumlahan.

Untuk mengatasi masalah tersebut, pertimbangkan untuk mengevaluasi $S_c(\theta)$ sebagai nilai tunggal yang diberikan untuk θ . Selanjutnya data pengamatan yang dimiliki yaitu Y_1, Y_2, \dots, Y_n maka nilai residual yang diperoleh pada persamaan 2.18 dapat ditulis ulang sebagai berikut.

$$a_t = Y_t + \theta a_{t-1}$$

Menggunakan persamaan diatas dapat dihitung secara rekursif, jika *initial value* diketahui. Pendekatan secara umum dilakukan dengan cara membuat $a_0 = 0$ sebagai suatu nilai ekspektasi, sehingga diperoleh hasil sebagai berikut.

$$\begin{aligned} a_1 &= Y_1 \\ a_1 &= Y_2 + \theta a_1 \\ a_3 &= Y_3 + \theta a_2 \\ &\vdots \\ a_n &= Y_n + \theta a_{n-1} \end{aligned}$$

Kemudian menghitung $S_c(\theta) = \sum(a_t)^2$, dengan nilai kondisional $a_0 = 0$, sebagai nilai tunggal dari θ . Untuk kasus sederhana dengan satu parameter, nilai θ terletak diantara (-1, +1) untuk menemukan jumlah kuadrat minimum.

Untuk Model MA(q) secara umum diperlukan algoritma optimasi dengan pendekatan numerik seperti Gauss-Newton atau Nelder-Mead. Sehingga untuk Model MA(q) dengan menggunakan gagasan yang sama dapat dihitung $a_t = a_t(\theta_1, \theta_2, \dots, \theta_q)$ secara rekursif dari persamaan berikut ini.

$$a_t = Y_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q}$$

Dengan $a_0 = a_{-1} = \dots = a_{-q} = 0$. Jumlah kuadrat diminimumkan secara bersama-sama menggunakan metode pendekatan numerik secara multivariat.

Persamaan Model ARMA(1,1) adalah sebagai berikut.

$$Y_t = \phi Y_{t-1} + a_t - \theta a_{t-1} \quad (2.20)$$

Seperti dalam kasus MA, mempertimbangkan $a_t = a_t(\phi, \theta)$ dan meminimumkan $S_c(\theta) = \sum (a_t)^2$, persamaan 2.20 dapat ditulis ulang sebagai berikut.

$$a_t = Y_t - \phi Y_{t-1} + \theta a_{t-1}$$

Dalam memperoleh a_1 , terdapat tambahan masalah baru yaitu dalam menentukan nilai Y_0 . Salah satu pendekatan yang dilakukan yaitu dengan cara menentukan $Y_0 = 0$ atau $Y_0 = \bar{Y}$, jika model terdiri dari nilai rata-rata bukan nol. Akan tetapi, pendekatan yang lebih baik yaitu dengan memulai rekursi pada $t = 2$, sehingga dapat menghindari Y_0 sama sekali dan secara sederhana dapat meminimumkan $S_c(\theta) = \sum_{t=2}^n a_t^2$. Untuk Model umum ARMA (p,q), dapat dihitung residual sebagai berikut.

$$\begin{aligned} a_t &= Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \dots - \phi_p Y_{t-p} \\ &\quad + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} \end{aligned}$$

Dengan $a_p = a_{p-1} = \dots = a_{p+1-q} = 0$ dan kemudian meminimumkan $S_c(\phi_1, \phi_2, \dots, \phi_p, \theta_1, \theta_2, \dots, \theta_p)$ secara numerik untuk memperoleh estimasi *conditional least square* pada semua parameter. Untuk parameter $\theta_1, \theta_2, \dots, \theta_q$ yang sesuai dengan model *invertible*, nilai awal $a_p = a_{p-1} = \dots = a_{p+1-q}$ akan sangat kecil pengaruhnya terhadap hasil akhir estimasi untuk semua parameter dengan sample yang besar.

2.3.5 Pengujian Signifikansi Parameter

Dilakukan pengujian untuk signifikansi parameter menggunakan uji t . Hipotesis yang digunakan dalam pengujian parameter model AR (p) adalah sebagai berikut:

$$H_0 : \phi_i = 0, \forall i$$

$$H_1 : \phi_i \neq 0, \exists_i \text{ untuk } i = 1, 2, \dots, p$$

Statistik uji parameter yang digunakan sebagai berikut.

$$t = \frac{\hat{\phi}_i}{SE(\hat{\phi}_i)} , \quad (2.11)$$

Daerah penolakan adalah tolak H_0 apabila $|t| > t_{(\alpha/2, n-p)}$

atau $P_{Value} < \alpha$ yang menunjukkan bahwa parameter ϕ dalam model telah signifikan. Untuk model MA(q) memiliki hipotesis yang sama dengan model AR(p) namun memiliki perbedaan pada parameter yaitu menggunakan parameter θ dan indeks $i = 1, 2, \dots, q$. Sedangkan untuk statistik uji sama seperti persamaan (2.11) namun menggunakan parameter θ , sehingga pada daerah penolakan juga sama seperti pada model AR(p), hanya saja mengganti indeks p dengan q (Bowerman, O'connell, & Koehler, 2005).

2.3.6 Pengujian Asumsi Residual

Untuk mendapatkan model ARIMA terbaik setelah melakukan estimasi parameter dan pengujian signifikansi parameter, masih terdapat beberapa asumsi yang harus dipenuhi yaitu uji *white noise* dan uji distribusi normal.

1. Uji Asumsi *White Noise*

Untuk menguji asumsi *white noise* dapat dilakukan dengan menggunakan uji *Box-Pierce* atau *Ljung-Box* (Box & Jenkins, 2015). Adapun hipotesis yang digunakan untuk uji *Box-Pierce* seperti berikut.

$$H_0 : \rho_k = 0, \forall k$$

$$H_1 : \rho_k \neq 0, \exists k \text{ untuk } k = 1, 2, \dots, K$$

Statistik uji yang digunakan dalam pengujian ini sebagai berikut.

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

Dengan n merupakan banyak pengamatan dan $\hat{\rho}_k^2$ merupakan autokorelasi residual lag ke- k . Daerah penolakan H_0 adalah jika nilai $Q > \chi^2_{\alpha;(K-p-q)}$ atau $P_{Value} < \alpha$ yang menunjukkan bahwa residual tidak memenuhi asumsi *white noise*.

2. Uji Asumsi Distribusi Normal

Uji distribusi normal dilakukan untuk mengetahui apakah *residual* telah berdistribusi normal atau tidak. Secara visual pengujian distribusi normal bisa dilakukan dengan *normal probability plot residual*. Cara lain yang dapat dilakukan yaitu dengan uji Kolmogorov-Smirnov (Allen & Rheinboldt, 1978).

$H_0 : F_0(x) = F(x)$ atau residual mengikuti sebaran distribusi normal

$H_1 : F_0(x) \neq F(x)$ atau residual tidak mengikuti sebaran distribusi normal

Statistik uji yang digunakan adalah sebagai berikut.

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

dimana:

$S(x)$ = fungsi peluang kumulatif yang dihitung dari data sampel

$F_0(x)$ = fungsi peluang kumulatif distribusi normal

Sup_x = Nilai maksimum dari $|S(x) - F_0(x)|$

2.3.7 Pemilihan Model Terbaik

Pemilihan model ARIMA terbaik dapat dilakukan dengan beberapa kriteria yaitu kriteria insample dan kriteria outsample. Untuk kriteria insample dan outsample dapat menggunakan *Root Mean Square Error* (RMSE), diperoleh rumus RMSE untuk insample sebagai berikut (Parag, Mousumi, & Parimal, 2016).

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_t - \hat{y}_t)^2}$$

y_t adalah variabel y pada waktu ke- t , sedangkan \hat{y}_t adalah hasil peramalan pada waktu ke- t dan n adalah banyaknya observasi pada insample. Kemudian untuk rumus RMSE pada outsample adalah sebagai berikut.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{m} \sum_{k=1}^m (y_{n+k} - \hat{y}_n(k))^2}$$

y_{n+k} adalah variabel y dan $\hat{y}_n(k)$ adalah variabel hasil ramalan pada waktu ke- $n+k$, untuk k adalah hasil ramalan untuk langkah kedepan dan m merupakan banyaknya observasi pada outsample.

2.4 Artificial Neural Network

Artificial Neural Network (ANN) atau Jaringan Syaraf Tiruan adalah sistem komputasi dimana arsitektur dan operasi diilhami dari pengetahuan tentang sel syaraf didalam otak dan merupakan model cara kerja jaringan neural biologis. ANN merupakan salah satu contoh model non linear yang memiliki bentuk fungsional flexibel dan mengandung beberapa parameter yang tidak dapat diinterpretasikan, seperti pada model parametrik namun hal inilah yang membuat ANN mampu menyelesaikan persoalan yang tidak terstruktur dan sulit didefinisikan. Proses pada ANN dimulai dari *input* yang diterima oleh *neuron*, dimana *neuron-neuron* ini dikelompokkan dalam *layer*. Informasi yang diterima dari *layer input* dilanjutkan ke *layer-layer* dalam ANN secara berurutan hingga mencapai *layer output*. *Layer* yang berbeda diantara *input* dan *output* disebut *hidden layer*. *Neural Network* ditentukan oleh tiga hal diantaranya yaitu pola hubungan antar unit (arsitektur jaringan), metode untuk melakukan *update* bobot dalam *link* koneksi (metode pelatihan atau algoritma) dan fungsi aktivasi (Zhang, 2004).

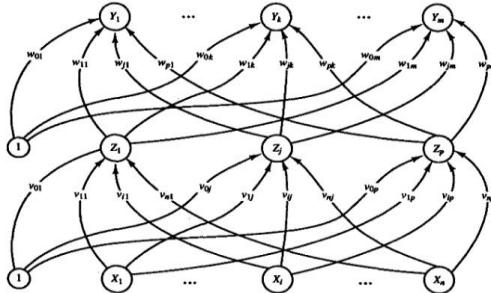
Backpropagation merupakan algoritma yang paling sering digunakan pada ANN khususnya *multilayer perceptron* untuk mengubah bobot-bobot yang terhubung dengan banyak lapisan *layer*. Algoritma ini termasuk metode *supervise training* dimana terdapat pasangan *input* dan target sebagai “guru” dalam pelatihan serta didesain untuk operasi jaringan *feed forward* multilapis.

Gambar 2.1 menunjukkan arsitektur FFNN dengan menggunakan 2 unit *input* ditambah sebuah bias kemudian unit *hidden layer* yang ditambah satu unit bias dan terakhir satu buah unit untuk *output*. Berikut adalah keterangan dari gambar tersebut.

X = unit *input*

Z_j = unit *hidden*, dengan $i=1,2$

- Y = unit *output*
 V_{lj} = bobot dari unit *input* menuju unit *hidden*, dengan $j=1,2$
 W_{ji} = bobot dari unit *hidden* menuju unit *output*, dengan $j=1,2$



Gambar 2.1 Arsitektur FFNN

Berdasarkan arsitektur FFNN pada gambar 2.1, algoritma yang digunakan terdiri dari tiga proses yaitu *feed forward*, *backpropagation*, serta *update* bobot dan bias yang akan dijelaskan sebagai berikut (Fausett, 1994).

1. Inisialisasi bobot dan bias dengan bilangan acak yang bernilai kecil.
2. Ketika kondisi *stop* belum terpenuhi, maka dilakukan langkah sebagai berikut.

Tahap *Feed Forward*

- A. Setiap unit *input* menerima sinyal *input* x_i dan meneruskan sinyal tersebut ke unit *hidden layer*.
- B. Untuk setiap unit *hidden* ($Z_j, j=1, \dots, p$) menjumlahkan sinyal *input* yang terboboti termasuk bias dalam *input*. Dapat dihitung dengan rumus berikut.

$$z_in_j = v_{0j} + \sum_{i=1}^n x_i v_{ij}$$

Kemudian menggunakan fungsi aktivasi yang telah ditentukan untuk menghitung sinyal *output*, diperoleh rumus sebagai berikut.

$$z_j = f(z_in_j) \quad (2.12)$$

Fungsi aktivasi yang digunakan pada *hidden layer* adalah log sigmoid, didapatkan rumus sebagai berikut.

$$f(z) = \frac{1}{1 + e^{-z}} \quad (2.13)$$

- C. Setiap unit output ($Y_k, k = 1, \dots, m$) menjumlahkan sinyal input yang terboboti termasuk bias dari *hidden layer*, diperoleh rumus sebagai berikut.

$$y_in_1 = w_{01} + \sum_{j=1}^p z_j w_{j1}$$

Kemudian menggunakan fungsi aktivasi untuk menghitung sinyal output, diperoleh rumus sebagai berikut.

$$y = f(y_in)$$

Tahap *Backpropagation*

- D. Setiap unit *output* (y) dengan target (t) dapat dihitung informasi residual dengan rumus sebagai berikut.

$$\delta_1 = (t - y) f'(y_in)$$

kemudian menghitung koreksi bobot *output* w_{j1} dan bobot bias *output* w_{01} dengan *learning rate* α , mempunyai rumus sebagai berikut.

$$\Delta w_{j1} = \alpha \delta_1 z_j$$

$$\Delta w_{01} = \alpha \delta_1$$

- E. Setiap unit *hidden* ($Z_j, j = 1, \dots, p$) menjumlahkan *input* δ (delta) dari unit *layer* sebelumnya.

$$\delta_in_j = \sum_{j=1}^2 \delta_1 w_{j1} \quad (2.14)$$

Kemudian hasil yang diperoleh pada persamaan (2.14) dikalikan dengan turunan dari fungsi aktivasi yaitu pada

persamaan (2.12), sehingga diperoleh informasi residual yang baru sebagai berikut.

$$\delta_j = \delta_{in_j} f'(z_{in_j})$$

Selanjutnya dihitung perubahan dari koreksi bobot v_{1j} dan bobot bias v_{0j} dengan *learning rate* yaitu α .

$$\Delta v_{1j} = \alpha \delta_j x$$

$$\Delta v_{0j} = \alpha \delta_j$$

Tahap *update* bobot dan bias

- F. Setiap unit *output* (y) mengupdate bias dan bobotnya dengan $j = 0,1,2$ dan $k = 1$.

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk}$$

Dan setiap unit *hidden* ($Z_j, j = 1, \dots, p$) dapat mengupdate bias dan bobotnya dengan $i = 0,1, \dots, j = 1,2$.

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij}$$

- G. Uji saat kondisi *stop*
 H. Untuk menentukan kondisi *stop* dapat dilakukan dengan dua cara yaitu dengan membatasi jumlah *epoch* atau nilai MSE $< \epsilon$ (dimana ϵ adalah suatu nilai yang sangat kecil dan ditetapkan sebesar 10^{-5}).

Setelah kondisi *stop* terpenuhi maka selanjutnya adalah membentuk model ANN. Bentuk umum model ANN adalah sebagai berikut.

$$\hat{Y} = f^0 \left[w_0 + \sum_{j=1}^J (w_{j1} f^h(v_{01} + \sum_{i=1}^I v_{ij} x_i)) \right]$$

perlu diketahui bahwa terdapat beberapa fungsi aktivasi yang dapat digunakan dalam pelatihan *backpropagation* antara lain fungsi pureline, tangen sigmoid, log sigmoid, hardlims. Pada penelitian ini fungsi aktivasi yang digunakan dalam *hidden layer* adalah log sigmoid dan pada *output layer* adalah pureline. Rumus dari fungsi aktivasi log sigmoid sama seperti persamaan (2.13).

2.5 Hybrid ARIMA dan Artificial Neural Network (ANN)

Pada penelitian ini juga mengguankan gabungan dari pendekatan linear ARIMA dan nonlinear ANN. Ide ini berdasarkan pada fakta bahwa tidak ada satupun model tunggal terbaik dalam berbagai situasi. Oleh karena itu keuntungan yang diperoleh yaitu dapat menggunakan karakteristik yang unik dari masing-masing model dan kekuatan, serta dapat menangkap lebih baik suatu pola dalam data dan juga meningkatkan hasil peramalan. Model Hybrid dapat dituliskan sebagai berikut.

$$Y_t = L_t + NL_t + a_t$$

dengan L_t adalah komponen linear dengan menggunakan ARIMA untuk NL_t adalah komponen nonlinear dengan menggunakan ANN dan a_t adalah random error.

Ide dasar dari pendekatan model hybrid ini adalah melakukan model ARIMA pada data juga melakukan model ANN dan kemudian melakukan kombinasi dari hasil kedua model linear dan nonlinear. Proses pembentukan model melibatkan 3 hal sebagai berikut. Pertama, model ARIMA dibentuk berdasarkan data pengamatan untuk mengestimasi komponen linear. Residual yang didapatkan dari model ARIMA seharusnya terdiri dari beberapa nonlinearitas (suatu data selalu terdiri dari banyak atau sedikit hubungan nonlinear). Kedua mengaplikasikan model ANN terhadap residual untuk mengestimasi komponen nonlinear. Ketiga, mengkombinasikan kedua bagian tersebut untuk melakukan peramalan. Sehingga Model hybrid menjadi sebagai berikut.

$$\hat{Y}_t = \hat{L}_t + \hat{NL}_t$$

dengan

\hat{L}_t = estimasi komponen linear dari ARIMA

\hat{NL}_t = estimasi komponen non-linear dari ANN

\hat{Y}_t = kombinasi peramalan

BAB III

METODOLOGI PENELITIAN

3.1 Sumber Data

Sumber data pada penelitian ini menggunakan data sekunder dari hasil permintaan darah Jenis PRC yang diperoleh dari PMI Kota Surabaya per bulan pada periode 1 Januari 2016 sampai 31 Desember 2016.

3.2 Variabel Penelitian

Data persediaan darah diramalkan berdasarkan dengan golongan darah, yaitu A, B, AB dan O, serta volume untuk PRC yaitu sekitar 200 – 300 ml. Sehingga model dari hasil peramalan terdiri dari empat model. Variabel penelitian yang digunakan dalam penelitian ini adalah sebagai berikut.

$Y_{A,t}$ = permintaan golongan darah A pada waktu ke- t

$Y_{B,t}$ = permintaan golongan darah B pada waktu ke- t

$Y_{AB,t}$ = permintaan golongan darah AB pada waktu ke- t

$Y_{O,t}$ = permintaan golongan darah O pada waktu ke- t

Data permintaan darah untuk masing - masing golongan terbagi menjadi 2 yaitu, sebagai insample dan outsample. Untuk data insample diambil pada periode 1 Januari 2016 sampai 30 Nopember 2016. Sedangkan data outsample diambil pada periode 1 Desember 2016 sampai 31 Desember 2016.

3.3 Langkah Analisis

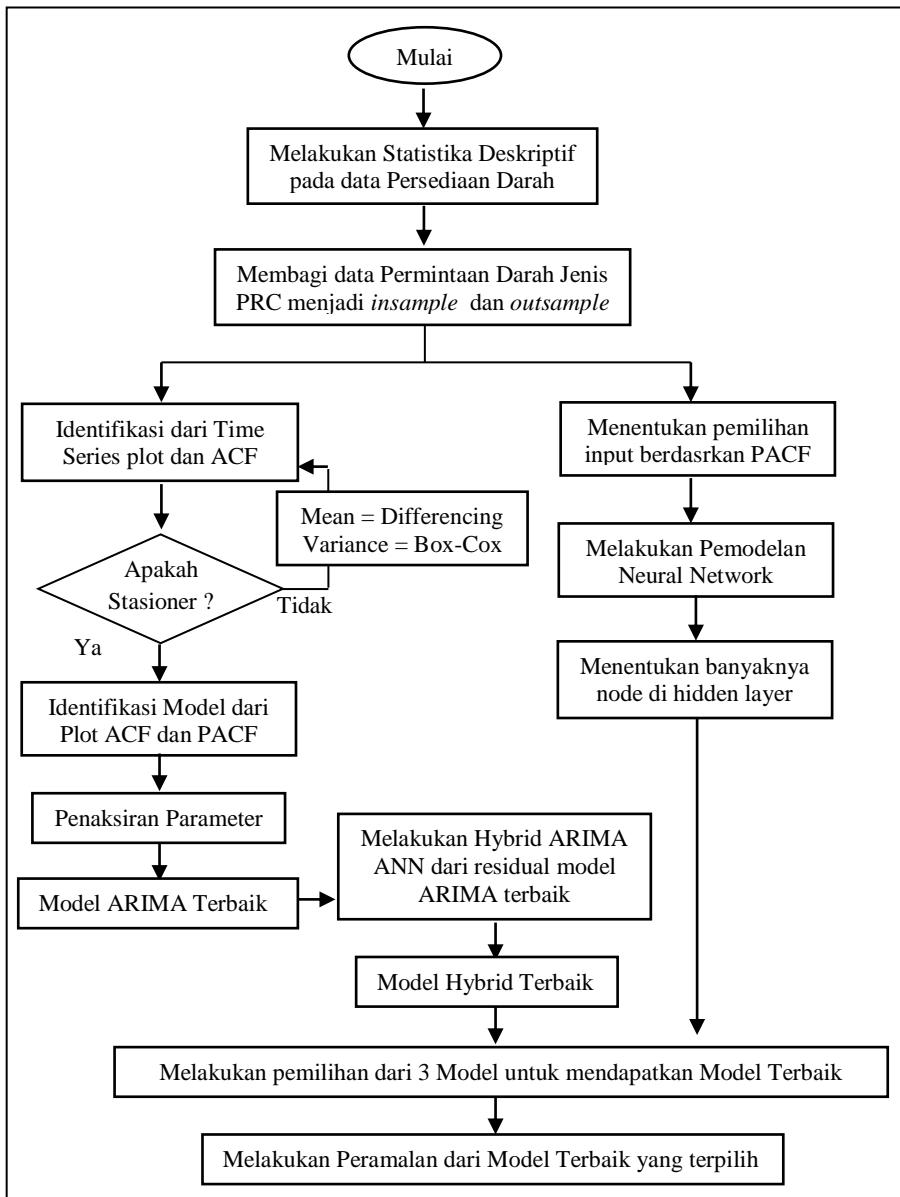
Langkah analisis yang digunakan pada penelitian ini adalah sebagai berikut.

1. Membagi data pada setiap variabel golongan darah menjadi 2 bagian yaitu data *in-sample* dan *out-sample*.
2. Melakukan identifikasi model ARIMA dengan cara melihat kestasioneran data melalui *time series plot* atau *ACF plot*. Pengamatan pertama melihat stasioner dalam varians, apabila ditemukan bahwa data tidak stasioner dalam

- varians maka dapat digunakan transformasi *Box-Cox*. Kemudian dilihat kestasioneran data dalam *mean*, jika ditemukan bahwa data tidak stasioner dalam mean maka dapat digunakan *differencing*.
3. Melakukan pendugaan model awal ARIMA dengan melihat plot ACF dan PACF.
 4. Melakukan penaksiran beserta pengujian parameter.
 5. Melakukan pengujian *residual*.
 6. Melakukan seleksi model melalui kriteria yang diperoleh pada *in-sample* dan *out-sample*.
 7. Memperoleh Model ARIMA terbaik
 8. Melakukan uji linearitas pada data permintaan darah untuk menetahui apakah terdapat pola non linear pada data.
 9. Setelah melakukan uji linearitas, kemudian dapat memodelkan menggunakan *feed forward neural network* (FFNN).
 10. Melakukan pemilihan input berdasarkan PACF pada data.
 11. Menentukan banyaknya *node* terbaik di *hidden layer*, dengan kriteria jumlah node antara 1 sampai 25.
 12. Memperoleh model terbaik FFFNN berdasarkan kriteria RMSE pada *insample* dan *outsample*.
 13. Mendapatkan residual dari Model ARIMA terbaik.
 14. Menentukan pemilihan input berdasarkan PACF pada data.
 15. Melakukan peramalan dengan menggunakan *Hybrid* ARIMA-ANN untuk mengkombinasikan model linear dan nonlinear.
 16. Melakukan pemilihan model terbaik dari ketiga metode peramalan yaitu ARIMA, ANN dan *Hybrid* ARIMA-ANN berdasarkan kriteria RMSE pada *insample* dan *outsample*.
 17. Melakukan peramalan untuk bulan Januari 2017 berdasarkan model terbaik yang terpilih.

3.4 Diagram Alir

Pada langkah analisis yang telah diuraikan sebelumnya dapat dilihat pada diagram alir yang ditampilkan pada gambar berikut ini.

**Gambar 3.1** Diagram Alir

(Halaman Ini Sengaja Dikosongkan)

BAB IV

ANALISIS DAN PEMBAHASAN

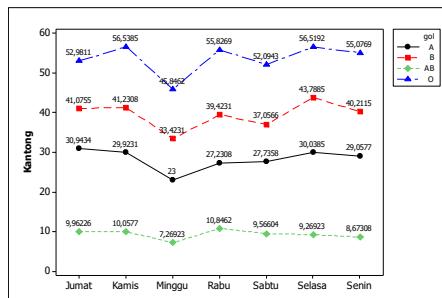
4.1 Karakteristik Data Permintaan Darah

Karakteristik data permintaan darah untuk jenis PRC yang diamati setiap hari mulai pada 1 Januari 2016 – 31 Desember 2016 dapat dilihat dari analisis statistika deskriptif. Hal ini dilakukan untuk dapat mengetahui gambaran umum dari permintaan masyarakat akan kebutuhan darah jenis PRC selama tahun 2016. Analisis statistika deskriptif dapat dilihat pada Tabel 4.1.

Tabel 4.1 Rata-rata Permintaan Darah per Bulan

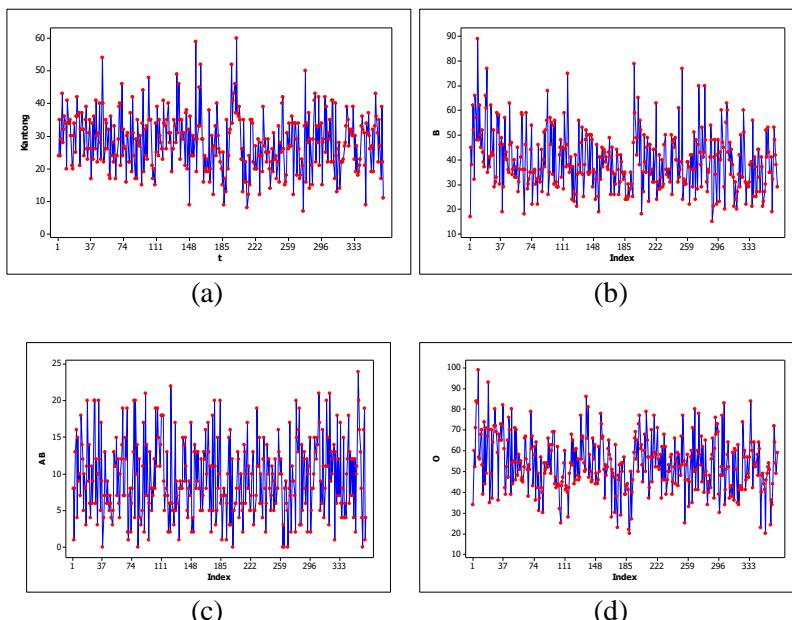
Gol	Jan	Feb	Mar	Apr	Mei	Jun	Jul	Aug	Sep	Okt	Nop	Des
A	31,4	30	27,6	29,3	30,3	28,3	28,5	24,2	26,1	28,7	27,9	27,1
B	48,4	40,7	38,2	42,9	37,6	36,8	38,8	38	39,5	39,6	36,9	36,1
AB	10,1	8,4	9,6	10,4	8,3	10,2	7,4	9,3	7,9	10,1	11,2	9,7
O	62,5	58,5	51,7	49,8	56,1	51,2	51,8	54,3	53,6	53,3	51,2	48,7

Berdasarkan Tabel 4.1 dapat diperoleh informasi bahwa rata-rata permintaan darah golongan A yang paling banyak terdapat pada bulan Januari 2016 dengan rata-rata 31 kantong darah. Untuk rata-rata permintaan golongan darah B yang paling banyak juga terdapat pada bulan Januari dengan rata-rata sebanyak 48 kantong darah. Hal serupa juga diperoleh untuk rata-rata permintaan golongan darah O yang memiliki rata-rata permintaan terbanyak pada bulan Januari sebesar 63 kantong darah. Sedangkan untuk golongan darah AB rata-rata permintaan terbanyak terdapat pada bulan November dengan rata-rata sebesar 11 kantong darah.



Gambar 4.1 Rata-rata Permintaan Darah per Hari

Berdasarkan gambar 4.1 terlihat bahwa untuk semua jenis golongan darah yang memiliki rata-rata permintaan darah paling kecil yaitu pada hari Minggu. Sehingga informasi yang dapat diperoleh yaitu pada hari libur yaitu Minggu memiliki rata-rata permintaan darah yang kecil jika dibandingkan dengan hari kerja (Senin sampai Jumat). Untuk golongan darah O rata-rata permintaan darah terbanyak berada pada hari Kamis dengan rata-rata sebesar 57 kantong, sedangkan untuk golongan darah B terdapat di hari Selasa dengan rata-rata 44 kantong, untuk golongan darah A terletak pada hari Jum'at dengan rata-rata 31 kantong dan rata-rata permintaan darah terbanyak untuk golongan AB terletak pada hari Rabu dengan rata-rata 11 kantong darah.



Gambar 4.2 Plot Time Series untuk (a) Golongan Darah A, (b) Golongan Darah B, (c) Golongan Darah (AB) dan (d) Golongan Darah O

Gambar 4.2 menunjukkan pola data permintaan golongan darah A stabil pada 30 kantong darah, artinya rata-rata permintaan

darah selama tahun 2016 adalah 30 kantong darah. Melihat *time series* plot tersebut mengindikasikan bahwa data stasioner dalam mean, namun belum stasioner dalam variance. Pada *time series plot* golongan darah B terlihat bahwa pola data stasioner terhadap mean, yang diindikasikan dengan plot menyebar disekitar rata-rata 40 permintaan kantong darah.

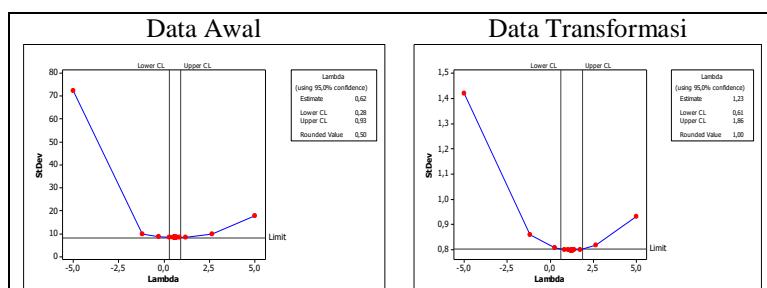
Hal serupa juga terjadi pada plot *time series* permintaan golongan darah AB yang stasioner dalam mean, karena plot menyebar di rata-rata 10 kantong darah per hari. Untuk permintaan golongan darah O juga diduga stasioner dalam mean, karena plot menyebar di sekitar rata-rata 60 kantong per hari.

4.2 Model ARIMA

Salah satu metode yang digunakan untuk dapat meramalkan data permintaan darah jenis PRC adalah menggunakan Model ARIMA. Data permintaan darah terdiri dari 4 jenis golongan darah yaitu golongan darah A, B, AB dan O, sehingga dapat terbentuk Model ARIMA sebanyak 4 Model. Berikut adalah hasil Model ARIMA untuk setiap jenis golongan darah.

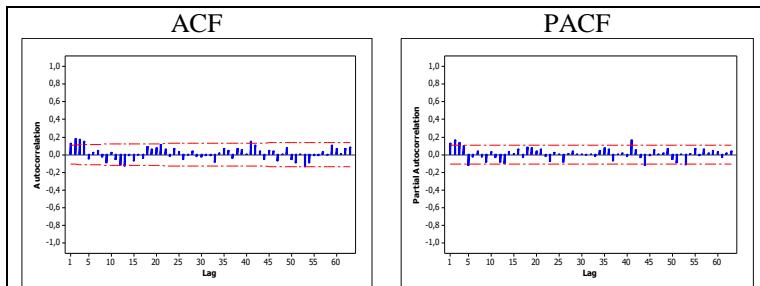
4.2.1 Golongan Darah A

Sebelum mendapatkan Model ARIMA, maka kondisi yang harus terpenuhi adalah stasioner dalam mean dan variance. Oleh karena itu untuk melihat apakah data sudah stasioner dalam *variance* dapat melakukan transformasi *Box-Cox* sebagai berikut.



Gambar 4.3 Box-Cox Golongan Darah A

Pada Gambar 4.3 untuk data awal pengamatan dapat dilihat bahwa data belum stasioner dalam variance. Hal tersebut disebabkan nilai *Lower CL* sebesar 0,28 dan *Upper CL* sebesar 0,93 tidak melewati angka 1 atau nilai *rounded value* belum bernilai 1 sehingga perlu dilakukan transformasi *Box-Cox*. *Rounded Value* yang diperoleh sebesar 0,5, maka transformasi yang digunakan untuk permintaan golongan darah A adalah $\sqrt{Y_t}$. Kemudian pada Gambar 4.3 untuk data transformasi menunjukkan bahwa nilai *Lower CL* sebesar 0,61 dan *Upper CL* sebesar 1,86 telah melewati angka 1 sehingga data permintaan golongan darah A sudah memenuhi stasioneritas dalam mean dan variance, oleh karena itu dapat dilanjutkan pada identifikasi Model ARIMA menggunakan ACF dan PACF.



Gambar 4.4 ACF dan PACF Golongan Darah A

Pada Gambar 4.4 terlihat untuk plot ACF data permintaan golongan darah A, terlihat bahwa terdapat 4 lag yang signifikan kemudian cut-off pada lag ke-5. Oleh karena itu dugaan Model ARIMA untuk *Moving Average* (MA) yaitu MA 4, MA 3 , MA 2 dan MA 1. Berdasarkan plot PACF terdapat 3 lag yang signifikan yaitu lag ke 1,2 dan 3. Maka model ARIMA untuk AR diduga AR 1, AR 2, dan AR 3. Akan tetapi dengan melihat lag yang paling signifikan, diperoleh dugaan yang paling kuat yaitu model AR 1 dan model AR 2.

Setelah meakukan identifikasi Model ARIMA didapatkan beberapa dugaan yaitu ARIMA (2,0,1) , ARIMA (1,0,2), ARIMA

(1,0,1) dan ARIMA ([2],0,[2]). Pemilihan tersebut berdasarkan lag PACF maupun ACF yang paling signifikan.

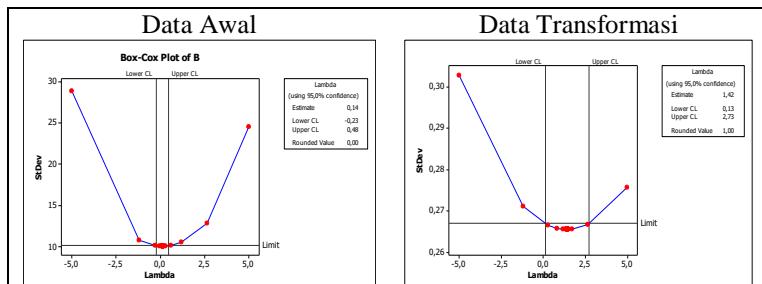
Tabel 4.2 Model ARIMA Golongan A

Model	ARIMA	Parameter	White Noise	Normality
1	(2,0,1)	Terpenuhi	Tidak	Terpenuhi
2	(1,0,2)	Terpenuhi	Tidak	Terpenuhi
3	(1,0,1)	Terpenuhi	Tidak	Terpenuhi
4	([2],0,[2])	Terpenuhi	Tidak	Terpenuhi

Berdasarkan Tabel 4.2 dapat diperoleh bahwa semua parameter model ARIMA telah signifikan. Sedangkan untuk pengujian asumsi residual, semua Model ARIMA memenuhi distribusi normal tetapi tidak memenuhi asumsi *white noise*. Sehingga semua model untuk ARIMA tidak dapat dilanjutkan untuk akurasi peramalan, oleh karena itu residual dari keempat model tersebut dilanjutkan ke Hybrid ARIMA-ANN.

4.2.2 Golongan Darah B

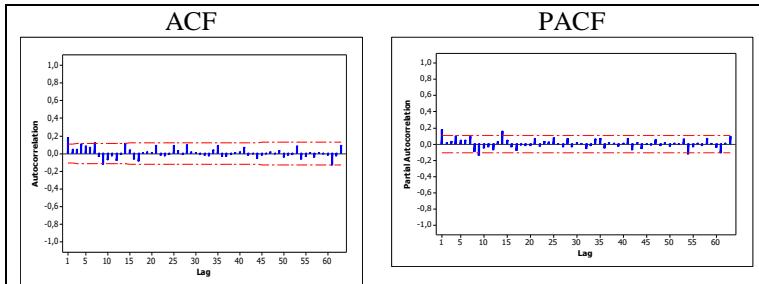
Untuk melihat data permintaan golongan darah B telah memenuhi kondisi stasioner dalam variance, maka dilakukan pengujian Box-Cox untuk melihat stasioneritas dalam variance.



Gambar 4.5 Box-Cox Golongan Darah B

Berdasarkan Gambar 4.5 terlihat data permintaan golongan darah B masih belum stasioner dalam variance, karena nilai LCL dan UCL belum melewati angka 1. Nilai *rounded value* sebesar 0 maka dilakukan transformasi dengan $\ln(Y_t)$ pada data permintaan golongan darah B. Setelah dilakukan transformasi data, kemudian

diuji kembali dengan pengujian Box-Cox untuk memastikan data telah stasioner dalam variance. Terlihat untuk data hasil transformasi telah menunjukkan bahwa data telah memenuhi kondisi stasioner dalam variance yang dibuktikan dari nilai UCL dan LCL melewati angka 1 atau *rounded value* sebesar 1, kemudian dapat dilanjutkan ke plot ACF dan PACF untuk melakukan identifikasi untuk model ARIMA serta melihat data telah memenuhi kondisi stasioner dalam mean.



Gambar 4.6 ACF dan PACF Golongan Darah B

Plot gambar 4.6 menunjukkan bahwa data telah memenuhi kondisi stasioner dalam mean, dan terdapat 1 lag yang signifikan yaitu lag ke 1. Kemudian untuk PACF terlihat bahwa lag ke 1 signifikan kemudian *cut off* di lag 2, sehingga dugaan model AR yang terbentuk adalah AR1, MA 1, akan tetapi tidak menutup kemungkinan untuk dilakukan subset pada lag ke 1, 9 dan 14. Dilakukan pemodelan ARIMA sebagai berikut.

Tabel 4.3 Model ARIMA Golongan B

Model	ARIMA	Parameter	White Noise	Normality
1	(1,0,1)	Terpenuhi	Tidak	Terpenuhi
2	(1,0,0)	Terpenuhi	Terpenuhi	Terpenuhi
3	(0,0,1)	Terpenuhi	Terpenuhi	Terpenuhi
4	([1,9,14],0,0)	Terpenuhi	Tidak	Terpenuhi

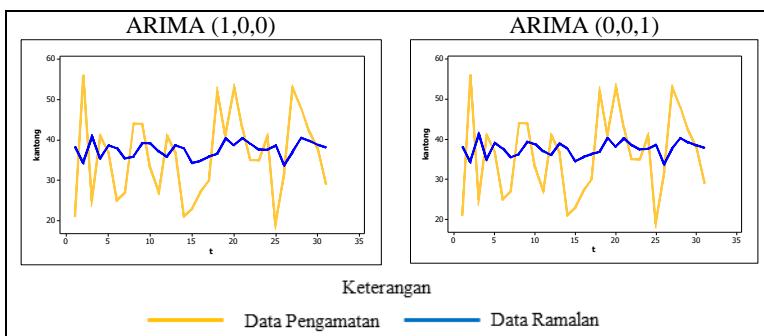
Tabel 4.3 terlihat bahwa semua parameter Model ARIMA terpenuhi atau signifikan dalam model begitu juga untuk asumsi residual berdistribusi normal. Akan tetapi untuk asumsi residual *white noise* di model ARIMA (1,0,1) dan ARIMA ([1,9,14],0,0)

tidak terpenuhi. Oleh karena itu model ARIMA yang dilanjutkan untuk mendapatkan akurasi peramalan adalah ARIMA (1,0,0) dan ARIMA (0,0,1).

Tabel 4.4 Akurasi Peramalan Golongan Darah B

ARIMA	RMSE	
	In Sample	Out Sample
(1,0,0)	11,744	10,384
(0,0,1)	11,836	10,356

Akurasi peramalan permintaan golongan darah B terlihat bahwa model ARIMA (0,0,1) memiliki akurasi peramalan dengan nilai RMSE terkecil pada outsample. Kemudian dari hasil tersebut dilakukan plot hasil ramalan dengan data asli untuk outsample sebagai berikut.



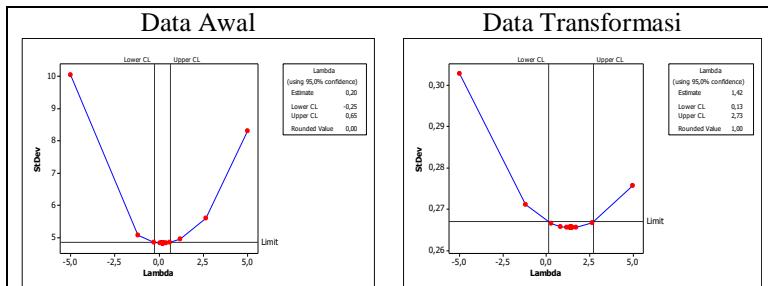
Gambar 4.7 Plot Outsample Golongan Darah B

Gambar 4.7 menunjukkan bahwa hasil ramalan dari kedua model tidak terlalu berbeda jauh. Oleh karena itu dipilih Model ARIMA terbaik berdasarkan RMSE outsample terkecil yaitu 10,356 yang didapat dari model ARIMA (0,0,1).

4.2.3 Golongan Darah AB

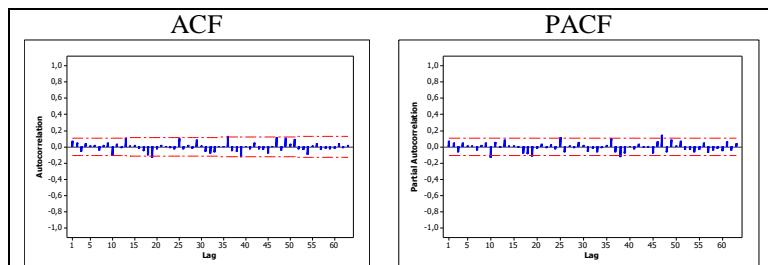
Pada permintaan golongan darah AB terdapat nilai 0 atau dapat diartikan sebagai tidak adanya permintaan darah pada hari tertentu selama tahun 2016. Sehingga untuk melakukan uji stasioneritas dalam Box-Cox dapat ditambahkan konstanta 10 pada data permintaan golongan darah AB.

Gambar 4.8 menunjukkan bahwa data belum memenuhi kondisi stasioner dalam variance, karena UCL dan LCL tidak melewati nilai lambda 1. Nilai *rounded value* sebesar 0 maka dilakukan transformasi dengan $\ln(Y_t)$ pada data permintaan golongan darah AB.



Gambar 4.8 Box-Cox Golongan Darah AB

Setelah dilakukan transformasi data, terlihat bahwa data telah memenuhi kondisi stasioner dalam variance, kemudian dapat dilanjutkan ke plot ACF dan PACF yang digunakan untuk melakukan identifikasi pada model ARIMA serta melihat data telah memenuhi kondisi stasioner dalam mean.



Gambar 4.9 ACF dan PACF Golongan Darah AB

Pada Gambar 4.9 untuk ACF pada lag ke 1 sampai 5 tidak terdapat satupun lag yang signifikan, sehingga dugaan Model MA yaitu MA 0. Kemudian untuk PACF terlihat bahwa *cut off* pada lag ke 1, sehingga dugaan untuk model AR yang terbentuk adalah subset pada lag ke 10, 19 dan 25. Kemudian dilakukan pemodelan ARIMA sebagai berikut.

Tabel 4.5 Model ARIMA Golongan Darah AB

Model	ARIMA	Parameter	White Noise	Normality
1	([10],0,0)	Terpenuhi	Terpenuhi	Terpenuhi
2	([19],0,0)	Terpenuhi	Terpenuhi	Terpenuhi
3	([10,19],0,0)	Tidak	-	-
4	([19,25],0,0)	Terpenuhi	Terpenuhi	Terpenuhi

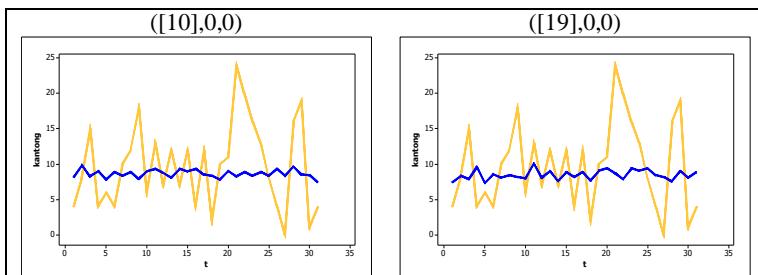
Tabel 4.5 terlihat bahwa 3 parameter model ARIMA telah terpenuhi atau signifikan dalam model begitu juga untuk asumsi residual berdistribusi normal dan residual *white noise*. Kemudian ketiga model ARIMA yang terbentuk dilakukan akurasi peramalan RMSE untuk insample dan outsample sebagai berikut.

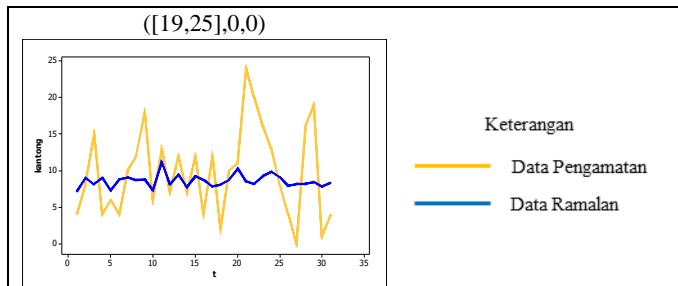
Tabel 4.6 Akurasi Peramalan Golongan AB

ARIMA	RMSE	
	In Sample	Out Sample
([10],0,0)	4,991	6,061
([19],0,0)	4,887	5,948
([19,25],0,0)	4,831	5,838

Tabel 4.6 menunjukkan bahwa Model ARIMA dengan nilai RMSE terkecil pada insample dan out sample terletak pada Model ARIMA ([19,25],0,0). Kemudian dilakukan plot hasil ramalan terhadap data asli untuk outsample sebagai berikut.

Gambar 4.10 menunjukkan bahwa plot hasil ramalan dari ketiga model menunjukkan bahwa Model ARIMA. Oleh karena itu dipilih Model ARIMA([19,25],0,0) yang paling mirip dengan plot data asli. Oleh karena itu model ARIMA terbaik yang digunakan adalah ARIMA([19,25],0,0).

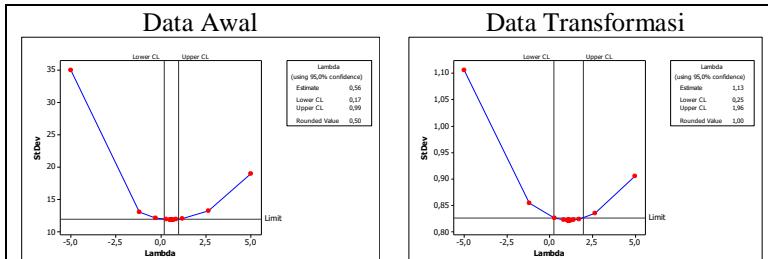
**Gambar 4.10** Plot Outsample Golongan Darah AB



Gambar 4.10 Plot Outsample Golongan Darah AB (*lanjutan*)

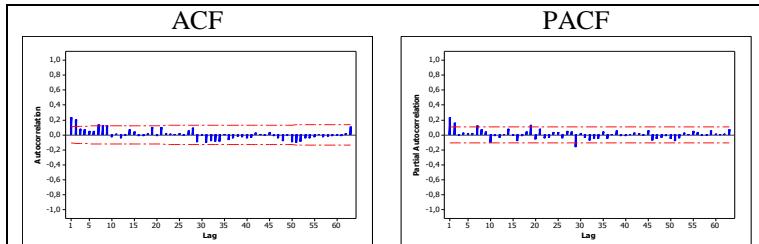
4.2.4 Golongan Darah O

Kondisi yang harus terpenuhi sebelum melakukan Model ARIMA yaitu stasioner dalam variance dan mean. Untuk melihat data permintaan golongan darah O telah memenuhi kondisi stasioner dalam variance, maka dilakukan pengujian Box-Cox untuk melihat stasioneritas dalam variance.



Gambar 4.11 Box-Cox Golongan Darah O

Gambar 4.11 menunjukkan bahwa data belum memenuhi kondisi stasioner dalam variance, karena nilai pada UCL dan LCL belum melewati nilai lambda 1. Kemudian untuk nilai *rounded value* sebesar 0,5 maka dilakukan transformasi dengan $\sqrt{Y_t}$ pada data permintaan golongan darah O. Data dari hasil transformasi menunjukkan telah memenuhi kondisi stasioner dalam variance, kemudian dapat dilanjutkan ke ACF dan PACF untuk melakukan identifikasi model ARIMA serta melihat data telah memenuhi kondisi stasioner dalam mean.



Gambar 4.12 ACF dan PACF Golongan Darah O

Pada Gambar 4.12 menunjukkan plot ACF untuk golongan darah O, lag ke 1 sampai 2 signifikan kedalam model, kemudian *cut-off* pada lag ke 3, sehingga dugaan Model MA yaitu MA 1 atau MA2. Kemudian untuk PACF diketahui bahwa lag ke 1 dan lag ke 2 signifikan dalam model, kemudian *cut-off* pada lag ke 3 sehingga dugaan Model AR yaitu AR 1 atau AR2.

Setelah melakukan identifikasi plot melalui ACF & PACF kemudian dilakukan pemodelan ARIMA dengan dugaan 4 Model yang terbentuk. Diperoleh hasil sebagai berikut.

Tabel 4.7 Model ARIMA Golongan Darah O

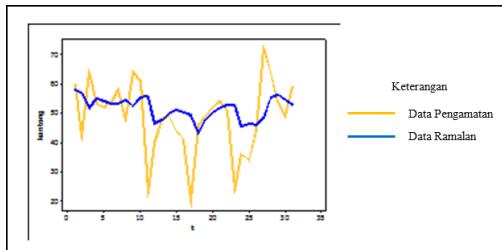
Model	ARIMA	Parameter	White Noise	Normality
1	(2,0,1)	Terpenuhi	Tidak	Terpenuhi
2	(1,0,2)	Tidak	-	-
3	(1,0,1)	Terpenuhi	Terpenuhi	Terpenuhi
4	(2,0,2)	Tidak	-	-

Berdasarkan Tabel 4.7 diperoleh bahwa hanya terdapat 2 parameter pada model ARIMA yang signifikan. Untuk pengujian asumsi residual pada kedua model tersebut diperoleh hasil bahwa residual distribusi normal telah terpenuhi sedangkan untuk *white noise* hanya model ARIMA (1,0,1) yang terpenuhi. Oleh karena itu model ARIMA (1,0,1) dilanjutkan ke akurasi peramalan.

Tabel 4.8 Akurasi Peramalan Golongan Darah O

ARIMA	RMSE	
	In Sample	Out Sample
(1,0,1)	12,821	12,052

Setelah mendapatkan Model ARIMA terbaik dapat dilakukan plot hasil ramalan terhadap data asli pada outsample untuk melihat apakah plot dari hasil ramalan mengikuti data asli. Diperoleh hasil sebagai berikut.



Gambar 4.13 Plot Outsample Golongan Darah O

Gambar 4.13 menunjukkan bahwa pada data hasil ramalan outsample cukup mengikuti pola dari data asli, oleh karena itu model ARIMA (1,0,1) layak digunakan.

4.3 Model *Feed Forward Neural Network* (FFNN)

4.3.1 Golongan Darah A

Pemilihan input berdasarkan lag pada PACF yang paling signifikan yaitu Y_{t-2} , Y_{t-41} , Y_{t-44} , Y_{t-3} , Y_{t-1} , Y_{t-5} , Y_{t-26} . Untuk mengetahui lag yang memiliki pola nonlinear dapat dilakukan Uji Terasvirta. Diperoleh hasil Uji Terasvirta sebagai berikut.

Tabel 4.9 Uji Terasvirta Golongan Darah A

Input	χ^2	df	P-value	F	df	P-value
$Y_{t-1} - Y_{t-10}$	692,13	275	0,00000	1,3476	50	0,1016
Y_{t-1} , Y_{t-2} , Y_{t-3} , Y_{t-5} , Y_{t-26} , Y_{t-41} , Y_{t-44}	153,56	112	0,00560	1,0674	172	0,3476
Y_{t-1} , Y_{t-2}	4,5572	7	0,7138	0,6378	326	0,7245
Y_{t-2} , Y_{t-41}	12,599	7	0,08249	1,7825	282	0,0906
Y_{t-41} , Y_{t-44}	18,517	7	0,00984	2,6469	282	0,0115

Pada pengujian terasvirta dapat diperoleh bahwa terdapat 3 pilihan input yang memiliki hasil uji paling signifikan yaitu 10 input dengan Y_{t-1} sampai Y_{t-10} kemudian 7 input yang terdiri dari

Y_{t-1} , Y_{t-2} , Y_{t-3} , Y_{t-5} , Y_{t-26} , Y_{t-41} , Y_{t-44} dan 2 input yang terdiri dari Y_{t-41} , Y_{t-44} . Pemodelan FFNN yang digunakan yaitu dengan menggunakan jumlah node di hidden layer sebanyak 1 sampai 25 node. Didapatkan hasil akurasi peramalan pada insample dan outsample pemodelan FFNN sebagai berikut.

Tabel 4.10 Akurasi Model FFNN Golongan Darah A

10 Input			7 input		
Node	InSample	OutSample	Node	InSample	OutSample
1	8,902133	8,176402	1	8,597282	7,874174
2	8,861361	8,16434	2	8,785308	7,889787
3	8,777698	8,264445	3	8,576736	7,930247
4	8,819154	8,165911	4	8,5612	7,95871
5	8,786982	7,940631	5	8,629132	7,95892
6	8,800533	8,03557	6	8,688928	8,017835
7	8,851275	8,145732	7	8,906981	7,87991
8	8,752852	8,037445	8	8,833839	7,879317
9	9,129635	8,223415	9	8,842762	7,88261
10	8,98016	7,901965	10	8,653986	7,964569
11	8,93474	7,824388	11	8,657837	8,014655
12	8,658213	8,04892	12	8,535936	8,07535
13	8,735868	8,153303	13	8,921076	7,95422
14	8,93533	8,137344	14	8,555784	8,077329
15	8,701366	7,966762	15	8,812983	7,883931
16	8,829998	8,160182	16	8,961238	8,037915
17	8,952763	8,072937	17	8,625193	7,961321
18	8,801288	8,090134	18	8,642055	8,083628
19	8,852692	7,751837	19	8,765603	8,003486
20	9,079908	8,062172	20	8,532872	8,061882
21	8,361905	8,216677	21	8,281442	7,709506
22	8,973879	8,020831	22	8,812174	7,878959

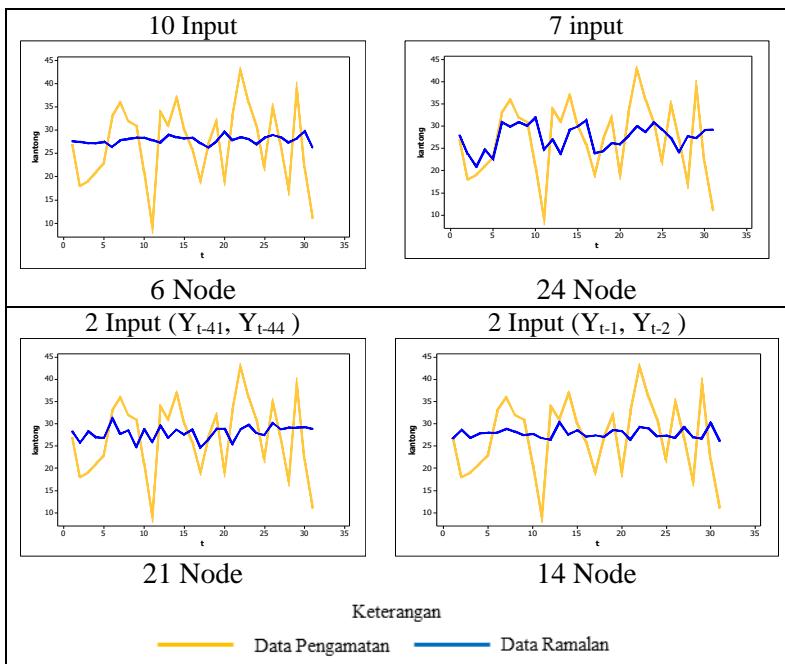
Tabel 4.10 Akurasi Model FFNN Golongan Darah A (*lanjutan*)

10 Input			7 input		
Node	InSample	OutSample	Node	InSample	OutSample
23	8,906446	8,172007	23	9,369767	7,791537
24	8,503455	8,342076	24	8,079717	7,553348
25	8,940636	8,112059	25	8,595794	8,018939
2 Input (Y_{t-41}, Y_{t-44})			2 Input (Y_{t-1}, Y_{t-2})		
Node	InSample	OutSample	Node	InSample	OutSample
1	8,953296	7,953638	1	8,737857	8,176654
2	8,947775	7,940884	2	8,725292	8,176909
3	8,954076	7,913344	3	8,838476	8,132488
4	8,957581	7,956215	4	8,811899	8,112822
5	8,854685	7,869591	5	8,73081	8,112907
6	8,952055	7,956431	6	8,83066	8,130321
7	8,937593	7,934021	7	8,80394	8,117188
8	8,940403	7,952657	8	8,819849	8,133097
9	8,905862	7,877316	9	8,725134	8,158508
10	8,924515	7,900164	10	8,769877	8,11814
11	8,946479	7,974709	11	8,791937	8,132977
12	8,971142	7,953867	12	8,762888	8,14316
13	8,906397	7,886689	13	8,749415	8,207647
14	8,975615	7,917336	14	8,98963	7,97018
15	8,948782	7,92902	15	8,690619	8,225534
16	8,907808	7,907687	16	8,803364	8,075639
17	8,90637	7,951847	17	8,829561	8,081316
18	8,93295	7,935672	18	8,910431	8,185815
19	8,917236	7,852118	19	8,948211	8,118179
20	8,890961	7,932833	20	8,755023	8,153115
21	9,037547	7,8457	21	8,750296	8,137251

Tabel 4.10 Akurasi Model NN Golongan Darah A (*lanjutan*)

2 Input (Y_{t-41}, Y_{t-44})			2 Input (Y_{t-1}, Y_{t-2})		
Node	InSample	OutSample	Node	InSample	OutSample
22	8,927144	7,919921	22	8,775017	8,052094
23	8,855076	7,883793	23	8,799593	8,120562
24	8,856356	7,922793	24	8,818008	8,206001
25	8,906765	7,953689	25	8,931506	8,051772

Pada Tabel 4.12 dapat disimpulkan bahwa model NN terbaik berdasarkan kriteria RMSE insample dan outsample terkecil yaitu pada 7 input dengan jumlah node di hidden layer sebanyak 24. Kemudian dilakukan plot untuk hasil ramalan pada masing – masing model FFNN terhadap data pengamatan di outsample, diperoleh hasil sebagai berikut.

**Gambar 4.14** Plot Outsample FFNN Golongan Darah A

Pada Gambar 4.14 terlihat bahwa hasil peramalan yang mengikuti pola dari data asli adalah model FFNN dengan 7 input dan jumlah node di hidden layer sebanyak 24, sehingga model NN terbaik untuk golongan darah A adalah FFNN (7,24,1).

4.3.2 Golongan Darah B

Pemilihan input berdasarkan lag pada PACF yang paling signifikan yaitu Y_{t-1} , Y_{t-14} , Y_{t-9} , Y_{t-7} , Y_{t-4} . Untuk mengetahui lag yang memiliki pola nonlinear, dapat dilakukan Uji Terasvirta. Diperoleh hasil Uji Terasvirta sebagai berikut.

Tabel 4.11 Uji Terasvirta Golongan Darah B

Input	χ^2	Df	P-value	F	df	P-value
$Y_{t-1} - Y_{t-10}$	705,69	275	0,0000	1,412	50	0,0703
Y_{t-1} , Y_{t-4} , Y_{t-7} , Y_{t-9} , Y_{t-14}	69,825	50	0,0334	1,292	266	0,1039
Y_{t-1} , Y_{t-4} , Y_{t-9} , Y_{t-14}	44,01	30	0,0475	1,405	287	0,0831
Y_{t-1} , Y_{t-9} , Y_{t-14}	32,751	16	0,0079	2,027	302	0,0115
Y_{t-1}	0,8369	2	0,6581	0,415	332	0,6605

Pada pengujian Terasvirta dapat diperoleh terdapat 3 pilihan input yang memiliki hasil uji paling signifikan yaitu 10 input dengan Y_{t-1} sampai Y_{t-10} , 4 input yang terdiri dari Y_{t-1} , Y_{t-4} , Y_{t-9} , Y_{t-14} serta 3 input yang terdiri dari Y_{t-1} , Y_{t-9} , Y_{t-14} . Kemudian juga dikutsertakan lag yang signifikan dalam pemodelan ARIMA yaitu Y_{t-1} . Maka pemodelan FFNN yang digunakan yaitu dengan menggunakan jumlah node di hidden layer sebanyak 1 sampai 25 node. Didapatkan hasil akurasi peramalan insample dan outsample pada pemodelan FFNN sebagai berikut.

Tabel 4.12 Akurasi Model FFNN Golongan B

10 Input			4 Input		
Node	InSample	OutSample	Node	InSample	OutSample
1	11,36941	10,34306	1	11,41451	10,52625
2	11,31901	10,27265	2	11,47817	10,43879
3	11,5151	10,57566	3	11,31376	10,41922

Tabel 4.12 Akurasi Model FFNN Golongan Darah B (*lanjutan*)

10 Input			4 Input		
Node	InSample	OutSample	Node	InSample	OutSample
4	11,63256	10,139	4	11,3701	10,47025
5	11,54185	10,41528	5	11,34536	10,42954
6	11,25285	10,53503	6	12,37138	10,10417
7	11,46551	10,42399	7	11,28748	10,58527
8	11,4069	10,27954	8	11,37653	10,3976
9	11,5602	10,46403	9	11,24846	10,37047
10	11,39159	10,38624	10	11,32512	10,45726
11	11,49818	10,55602	11	11,68788	10,1786
12	11,42391	10,68127	12	11,52474	10,53583
13	11,31928	10,29969	13	11,35814	10,36306
14	11,76184	10,3277	14	11,27609	10,5408
15	11,45896	10,44171	15	11,34687	10,44708
16	11,65985	10,31954	16	11,30902	10,28175
17	11,59759	10,22574	17	11,43422	10,17185
18	11,76368	10,38537	18	11,64145	10,05076
19	12,0942	10,00838	19	11,28367	10,49334
20	11,40601	10,65775	20	12,06687	10,45647
21	11,77868	10,32988	21	11,33126	10,40878
22	11,98655	10,25602	22	11,79585	10,43067
23	11,21696	10,85764	23	11,63877	10,29494
24	10,82327	10,89361	24	12,28588	10,06938
25	11,37625	10,68618	25	11,6046	10,25325
3 Input ($Y_{t-1}, Y_{t-9}, Y_{t-14}$)			1 Input (Y_{t-1})		
Node	InSample	OutSample	Node	InSample	OutSample
1	11,31986	10,56878	1	11,64512	10,70768
2	11,33922	10,46573	2	11,64364	10,66248

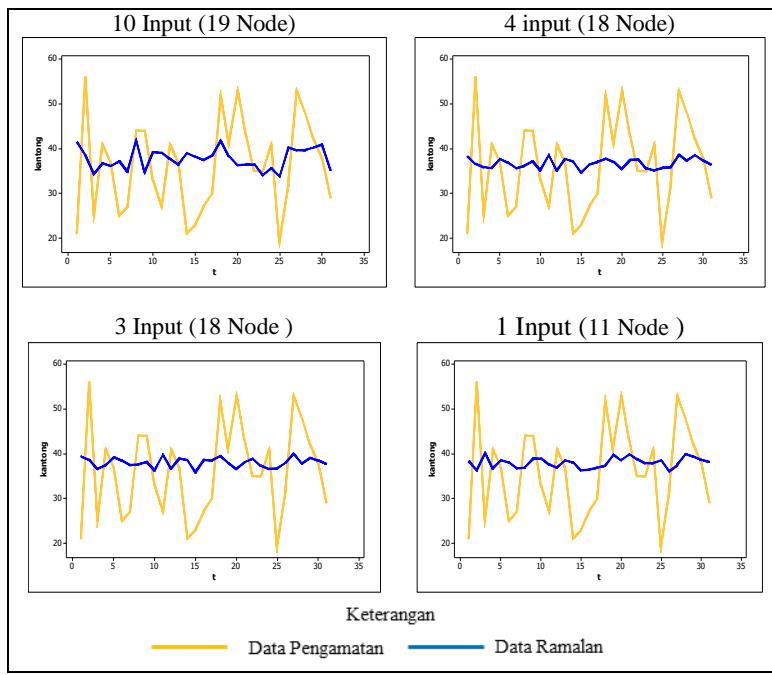
Tabel 4.12 Akurasi Model FFNN Golongan Darah B (*lanjutan*)

3 Input ($Y_{t-1}, Y_{t-9}, Y_{t-14}$)			1 Input (Y_{t-1})		
Node	InSample	OutSample	Node	InSample	OutSample
3	11,30361	10,49353	3	11,71863	10,68217
4	11,28082	10,38763	4	11,7909	10,49498
5	11,33233	10,41037	5	11,65945	10,65793
6	11,26271	10,44903	6	11,70028	10,6474
7	11,29288	10,34481	7	11,7338	10,57009
8	11,45831	10,29564	8	11,78696	10,64892
9	11,46673	10,31803	9	11,70283	10,506
10	11,19058	10,49956	10	11,71196	10,63937
11	11,41668	10,46545	11	11,78209	10,34857
12	11,17437	10,56548	12	11,69737	10,69118
13	11,29576	10,30663	13	11,88405	10,63028
14	11,31368	10,47603	14	11,94703	10,3764
15	11,1866	10,66593	15	11,67253	10,54109
16	11,50708	10,26858	16	11,67261	10,62833
17	11,66182	10,45442	17	11,94385	10,52243
18	11,55629	10,21925	18	11,7377	10,49229
19	11,39612	10,37126	19	11,86037	10,43837
20	11,78579	10,21082	20	11,74878	10,50766
21	11,20431	10,56455	21	11,84343	10,49179
22	11,52009	10,41938	22	11,6537	10,68871
23	11,23636	10,47483	23	11,71823	10,4176
24	11,32384	10,45622	24	11,81616	10,54182
25	11,31914	10,49024	25	11,65429	10,68582

Pada Tabel 4.12 dapat disimpulkan bahwa model FFNN terbaik yaitu pada 10 input dengan jumlah node di hidden layer sebanyak 19, karena pada model tersebut memiliki nilai RMSE

pada outsample yang paling kecil. Untuk melihat apakah pada model tersebut memiliki hasil ramalan yang mengikuti pola dari data pengamatan, maka dapat dilakukan plot pada outsample sebagai berikut.

Pada Gambar 4.15 dapat terlihat bahwa hasil peramalan yang mengikuti pola dari data asli adalah model FFNN dengan 10 input dan jumlah node di hidden layer sebanyak 19, sehingga model NN terbaik untuk golongan darah B yaitu FFNN (10,19,1).



Gambar 4.15 Plot Outsample FFNN Golongan Darah B

4.3.3 Golongan Darah AB

Pemilihan input berdasarkan lag pada PACF yang paling signifikan yaitu Y_{t-47} , Y_{t-10} , Y_{t-38} , Y_{t-19} , Y_{t-25} . Untuk mengetahui lag yang memiliki pola nonlinear dapat dilakukan Uji Terasvirta. Diperoleh hasil Uji Terasvirta seperti pada Tabel 4.13. Pada pengujian Teraesvirta dapat diperoleh hanya terdapat 1 pilihan input

yang memiliki hasil uji signifikan yaitu 10 input dengan lag Y_{t-1} sampai Y_{t-10} . Diperoleh hasil uji sebagai berikut.

Tabel 4.13 Uji Teraesvirta Golongan Darah AB

Input	χ^2	df	P-value	F	df	P-value
$Y_{t-1} - Y_{t-10}$	729	275	0,0000	1,531	50	0,035
$Y_{t-10}, Y_{t-19}, Y_{t-25}, Y_{t-38}, Y_{t-47}$	43,673	50	0,7238	0,763	233	0,873
$Y_{t-10}, Y_{t-19}, Y_{t-25}$	17,139	16	0,3766	1,031	269	0,424
Y_{t-47}	4,4194	2	0,1097	2,203	285	0,112

Maka pemodelan FFNN berdasarkan hasil uji Teraesvirta yaitu dengan menggunakan 10 input dan jumlah node di *hidden layer* sebanyak 1 sampai 25 node. Sehingga didapatkan hasil untuk akurasi peramalan insample dan outsample pemodelan FFNN sebagai berikut.

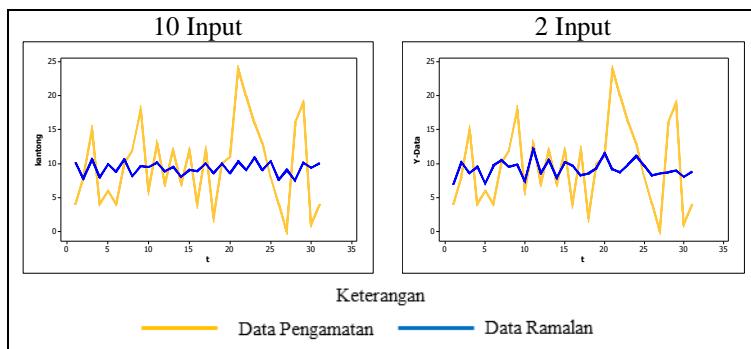
Tabel 4.14 Akurasi Model FFNN Golongan Darah AB

10 Input			2 Input (Y_{t-19}, Y_{t-25})		
Node	InSample	OutSample	Node	InSample	OutSample
1	4,990845	5,834123	1	4,979901	5,714831
2	4,88289	5,695047	2	4,992555	5,69856
3	4,999225	5,861158	3	4,988391	5,699304
4	4,981898	5,733144	4	4,990785	5,688809
5	5,060854	5,801562	5	4,994555	5,682624
6	4,973688	5,804374	6	4,989055	5,688855
7	4,968549	5,712991	7	4,986621	5,711758
8	5,029463	5,772115	8	4,984376	5,703387
9	4,911069	5,505764	9	4,989239	5,686711
10	4,925921	5,604137	10	4,981897	5,708766
11	5,182911	5,737638	11	4,978796	5,711359
12	4,913789	5,733852	12	4,981803	5,712307
13	4,963316	5,806434	13	4,981635	5,706958
14	4,949472	5,783526	14	4,980735	5,712052

Tabel 4.14 Akurasi Model FFNN Golongan AB (*lanjutan*)

10 Input			2 Input (Y_{t-19} , Y_{t-25})		
Node	InSample	OutSample	Node	InSample	OutSample
15	5,176488	5,73696	15	4,97985	5,717224
16	5,001012	5,839532	16	4,9821	5,711138
17	4,796398	5,680618	17	4,982317	5,721569
18	4,923244	5,723993	18	4,980272	5,718556
19	4,950041	5,787678	19	4,980759	5,723239
20	4,994353	5,704323	20	4,986524	5,719117
21	5,168585	5,623355	21	4,982646	5,723506
22	4,925921	5,604137	22	4,988333	5,719886
23	5,182911	5,737638	23	4,983489	5,71441
24	4,913789	5,733852	24	4,985683	5,702302
25	4,963316	5,806434	25	4,981688	5,712023

Pada Tabel 4.14 dapat disimpulkan bahwa model NN terbaik yaitu pada 10 input dengan jumlah node di hidden layer sebanyak 21, karena pada model FFNN (10,9,1) mempunyai nilai RMSE pada insample maupun outsample yang paling kecil.

**Gambar 4.16** Plot Outsample FFNN Golongan Darah AB

Pada Gambar 4.16 dapat dilihat hasil peramalan cenderung stabil di rata-rata permintaan golongan darah AB yaitu disekitar

10 kantong setiap harinya. Namun jika diperhatikan model FFNN (2,5,1) memiliki plot hasil ramalan yang lebih mengikuti data pengamatan daripada model FFNN (10,9,1), sehingga model NN yang digunakan adalah FFNN (2,5,1).

4.3.4 Golongan Darah O

Pemilihan input berdasarkan lag pada PACF yang paling signifikan. Untuk mengetahui lag yang memiliki pola nonlinear dapat dilakukan Uji Terasvirta. Diperoleh hasil Uji Terasvirta sebagai berikut.

Tabel 4.15 Uji Teraesvirta Golongan Darah O

Input	χ^2	df	P-value	F	df	P-value
$Y_{t-1} - Y_{t-10}$	599,1	275	0,0000	0,966	50	0,5814
$Y_{t-1}, Y_{t-2}, Y_{t-7}, Y_{t-10}, Y_{t-14}, Y_{t-16}, Y_{t-19}, Y_{t-29}$	205,38	156	0,0049	0,871	142	0,8012
$Y_{t-1}, Y_{t-7}, Y_{t-10}, Y_{t-16}$	40,593	30	0,0938	1,286	272	0,1523
Y_{t-1}, Y_{t-2}	2,5032	7	0,9269	0,349	326	0,9305
Y_{t-1}	1,5703	2	0,456	0,779	332	0,4593

Pada pengujian teraesvirta dapat diperoleh bahwa terdapat 2 pilihan input yang memiliki hasil uji paling signifikan yaitu 10 input dengan Y_{t-1} sampai Y_{t-10} dan untuk 8 input yang terdiri dari $Y_{t-1}, Y_{t-2}, Y_{t-7}, Y_{t-10}, Y_{t-14}, Y_{t-16}, Y_{t-19}, Y_{t-29}$. Maka pemodelan NN yang digunakan yaitu dengan menggunakan jumlah node di *hidden layer* sebanyak 1 sampai 25 node. Didapatkan hasil akurasi peramalan untuk insample dan outsample pemodelan neural network sebagai berikut.

Tabel 4.16 Akurasi Model FFNN Golongan Darah O

10 Input			8 Input		
Node	InSample	OutSample	Node	InSample	OutSample
1	12,47715	12,01269	1	12,28645	11,99939
2	12,42254	11,99754	2	11,95806	12,18764
3	12,44224	12,00917	3	11,86457	12,20911
4	12,56263	11,74172	4	11,67554	11,74785

Tabel 4.16 Akurasi Model FFNN Golongan O (*lanjutan*)

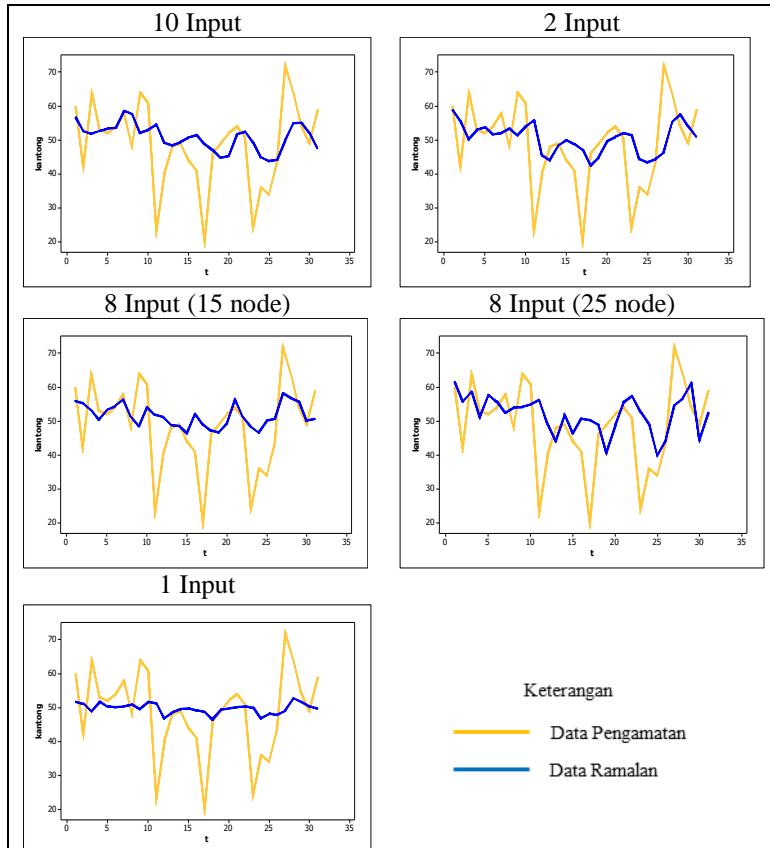
10 Input			8 Input		
Node	InSample	OutSample	Node	InSample	OutSample
5	12,3632	11,69649	5	12,38138	12,09119
6	12,40865	11,84023	6	12,52963	12,04294
7	12,34844	11,73135	7	11,92507	11,80078
8	12,30023	11,84866	8	11,95584	11,84566
9	12,24394	12,00519	9	11,75975	12,14694
10	12,32716	11,8921	10	11,85061	11,58229
11	12,29622	11,81606	11	11,81719	12,14203
12	12,36449	11,78433	12	12,43466	12,06806
13	12,2927	11,87989	13	11,70138	11,94548
14	12,48251	11,85863	14	11,88578	11,85221
15	12,40955	11,76488	15	12,70007	11,1925
16	12,27545	11,91082	16	11,81468	12,02795
17	12,45795	11,85236	17	12,81223	11,79759
18	12,20284	11,90149	18	12,50236	11,87205
19	12,43325	11,95183	19	11,66596	12,1918
20	12,40107	11,92563	20	12,36611	11,75634
21	12,32888	11,72615	21	11,50845	11,90211
22	12,20763	11,91805	22	11,93629	11,87253
23	12,34285	11,79914	23	11,86812	12,13594
24	12,052	11,86232	24	13,05514	11,36516
25	12,40619	11,86923	25	11,3971	11,82437
2 Input			1 Input		
Node	InSample	OutSample	Node	InSample	OutSample
1	12,81715	12,2856	1	12,93865	12,31589
2	12,89009	12,35379	2	12,955	12,24785
3	12,76903	12,36927	3	12,97013	12,21687

Tabel 4.16 Akurasi Model FFNN Golongan Darah O (*lanjutan*)

2 Input			1 Input		
Node	InSample	OutSample	Node	InSample	OutSample
4	12,74847	12,37829	4	12,95735	12,20914
5	12,92021	11,92712	5	12,97799	12,05754
6	12,90517	12,30103	6	12,97225	12,09331
7	12,75997	12,40292	7	12,9472	12,25193
8	12,76	12,3453	8	12,96626	12,07468
9	12,76476	12,33949	9	12,94171	12,23164
10	12,75926	12,35094	10	12,94075	12,25491
11	12,75011	12,3919	11	12,94973	12,12023
12	12,75048	12,39814	12	12,93912	12,25412
13	13,04628	12,0247	13	12,95196	12,21512
14	12,76506	12,31639	14	12,93789	12,27024
15	12,79936	12,33607	15	12,92952	12,28208
16	12,75489	12,36054	16	12,93615	12,28891
17	12,76219	12,33266	17	12,94548	12,22513
18	12,7682	12,28548	18	13,50883	11,78628
19	13,32785	12,00606	19	12,93633	12,26688
20	12,75503	12,38608	20	12,93601	12,30161
21	12,90506	12,04613	21	13,34619	11,84461
22	12,75928	12,31579	22	13,10861	12,26985
23	12,75094	12,41748	23	13,03087	11,99555
24	12,77238	12,27952	24	12,93997	12,18343
25	12,77816	12,28331	25	12,93413	12,29488

Pada Tabel 4.16 dapat disimpulkan bahwa model FFNN terbaik yaitu pada 8 input dengan jumlah node di hidden layer sebanyak 15, karena pada model FFNN (8,15,1) mempunyai nilai RMSE pada outsample yang paling kecil jika dibandingkan input pada model FFNN yang lain. Akan tetapi jika diperhatikan FFNN

(8,25,1) memiliki akurasi peramalan di insample dan outsample yang relatif lebih kecil dari lainnya. Oleh karena itu model FFNN (8,25,1) dapat diikutkan pada plot hasil ramalan terhadap data pengamatan.



Gambar 4.17 Plot Outsample FFNN Golongan Darah O

Pada gambar 4.17 terlihat bahwa untuk pemilihan 8 input dengan 25 node di *hidden layer* memiliki hasil ramalan yang mengikuti pola data pengamatan. Meskipun pada hasil outsample nilai RMSE pada variabel 8 input dengan 25 node lebih besar jika

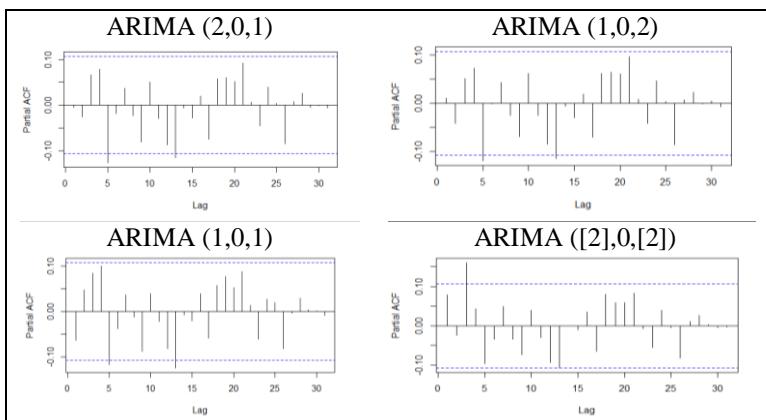
dibandingkan dengan menggunakan 15 node namun memiliki plot yang lebih mengikuti data pengamatan. Berdasarkan pertimbangan tersebut maka model FFNN terbaik adalah FFNN (8,25,1).

4.4 Hybrid ARIMA - Neural Network

Pemodelan Hybrid ARIMA-NN digunakan dengan menggabungkan model ARIMA terbaik dan model FFNN terbaik. Hasil residual yang diperoleh dari model ARIMA terbaik, dapat dimodelkan dengan FFNN .

4.4.1 Golongan Darah A

Melanjutkan dari Model ARIMA terbaik yang terpilih pada subbab 4.2.1, maka residual dari model ARIMA tersebut dilakukan plot PACF untuk menentukan pemilihan input yang akan digunakan pada model FFNN.



Gambar 4.18 PACF Residual Golongan Darah A

Pada Gambar 4.18 dapat dilihat lag yang paling signifikan yaitu lag a_{t-1} , a_{t-5} dan a_{t-13} . Dari beberapa lag tersebut akan dilakukan kombinasi antar lag untuk mengetahui adanya pola nonlinear dalam data. Maka dilakukan Uji Terasvirta sebagai berikut.

Pada Tabel 4.17 diperoleh bahwa semua model ARIMA memiliki hasil uji yang signifikan pada 10 input atau dengan lag a_{t-1} sampai a_{t-10} .

Tabel 4.17 Uji Teraesvirta Residual Golongan Darah A

ARIMA	Input	χ^2	df	P-value	F	df	P-value
(2,0,1)	$a_{t-1} - a_{t-10}$	679,63	275	0,0000	1,2899	50	0,1392
	$a_{t-1} - a_{t-5}$	44,162	50	0,7057	0,8018	280	0,826
	a_{t-1}, a_{t-2}	8,3401	7	0,3036	1,1811	326	0,313
	a_{t-5}, a_{t-13}	4,7683	7	0,6882	0,6671	313	0,699
(1,0,2)	$a_{t-1} - a_{t-10}$	680,32	275	0,0000	1,293	50	0,1369
	$a_{t-1} - a_{t-5}$	45,26	50	0,6637	0,823	280	0,7949
	a_{t-1}, a_{t-2}	8,1388	7	0,3205	1,1523	326	0,3301
	a_{t-5}, a_{t-13}	4,895	7	0,6728	0,6849	313	0,6848
(1,0,1)	$a_{t-1} - a_{t-10}$	688,87	275	0,0000	1,332	50	0,1106
	$a_{t-1} - a_{t-5}$	42,063	50	0,7801	0,7612	280	0,8777
	a_{t-1}, a_{t-2}	8,2841	7	0,3082	1,1731	326	0,3177
	a_{t-5}, a_{t-13}	3,993	7	0,7806	0,5579	313	0,7898
[2],0,[2]	$a_{t-1} - a_{t-10}$	734,08	275	0,0000	1,5583	50	0,0298
	$a_{t-1} - a_{t-5}$	41,727	50	0,7911	0,7548	280	0,885
	$a_{t-1} - a_{t-3}$	10,198	16	0,8561	1,2071	316	0,8708
	a_{t-3}	1,0408	2	0,5943	0,5165	329	0,5971

Maka model neural network yang digunakan yaitu dengan menggunakan jumlah node di hidden layer sebanyak 1 sampai 25 node. Didapatkan hasil akurasi peramalan untuk insample dan outsample sebagai berikut.

Tabel 4.18 Akurasi Model NN Residual Golongan Darah A

ARIMA (2,0,1)			ARIMA (1,0,2)		
Node	InSample	OutSample	Node	InSample	OutSample
1	8,598167	8,504681	1	8,54304	8,487654
2	8,636707	8,480952	2	8,544519	8,388077
3	8,748553	8,491405	3	8,579999	8,498646
4	8,636184	8,389644	4	8,637242	8,383797
5	8,621517	8,59797	5	8,54406	8,410684
6	8,233457	8,234634	6	8,566638	8,475895
7	8,506897	8,375534	7	8,487644	8,453241
8	8,635731	8,537064	8	8,39471	8,3696

Tabel 4.18 Akurasi Model NN Residual Golongan Darah A (*lanjutan*)

ARIMA (2,0,1)			ARIMA (1,0,2)		
Node	InSample	OutSample	Node	InSample	OutSample
9	8,427021	8,387964	9	8,653022	8,222276
10	8,570613	8,370856	10	8,622288	8,321444
11	8,421447	8,38168	11	8,697721	8,221215
12	8,521587	8,427142	12	8,346451	8,194857
13	8,698428	8,272837	13	8,551113	8,46751
14	8,522257	8,345115	14	8,635294	8,4267
15	8,528099	8,465309	15	8,636138	8,154834
16	8,721632	8,392485	16	8,557189	8,463267
17	8,470504	8,401457	17	8,373587	8,400827
18	8,174847	8,314993	18	8,381725	8,406349
19	8,776829	8,414415	19	8,786268	8,258188
20	8,534801	8,358051	20	8,391016	8,389505
21	8,610498	8,251426	21	8,61723	8,217021
22	8,345683	8,466868	22	8,174798	8,227443
23	8,33436	8,184461	23	8,757522	8,211678
24	8,522164	8,336349	24	8,490455	8,521269
25	8,979356	8,518897	25	8,750582	8,284064
ARIMA (1,0,1)			ARIMA ([2],0,[2])		
Node	InSample	OutSample	Node	InSample	OutSample
1	8,595431	8,28795	1	8,637791	8,44128
2	8,594538	8,332304	2	8,717826	8,44677
3	8,775567	8,258046	3	8,542234	8,358525
4	8,703916	8,194144	4	8,675483	8,402273
5	8,762862	8,342778	5	8,394051	8,335194
6	8,622258	8,204124	6	8,531578	8,406085
7	8,683641	8,211354	7	8,399299	8,36556

Tabel 4.18 Akurasi Model NN Residual Golongan Darah A (*lanjutan*)

ARIMA (1,0,1)			ARIMA ([2],0,[2])		
Node	InSample	OutSample	Node	InSample	OutSample
8	8,660816	8,343473	8	8,60452	8,277428
9	8,759864	8,103561	9	8,525718	8,54268
10	8,708767	8,230896	10	8,762397	8,421064
11	8,65913	8,354336	11	8,403163	8,17418
12	8,660606	8,214475	12	8,517638	8,496829
13	8,7563	8,313691	13	8,52796	8,374105
14	8,586647	8,203982	14	8,365719	8,194792
15	8,54044	8,422193	15	8,099726	8,355969
16	8,867124	8,136755	16	8,561383	8,360374
17	8,498732	8,35171	17	8,743082	8,420029
18	8,945817	8,04678	18	8,378993	8,29493
19	8,38581	8,226467	19	8,439365	8,159355
20	8,674433	8,304905	20	8,745656	8,499082
21	8,195537	8,45244	21	9,086463	8,355599
22	8,698561	8,330538	22	8,603768	8,264752
23	8,902401	8,136851	23	8,613328	8,522247
24	8,874835	8,258306	24	8,592352	8,372004
25	9,012316	8,331844	25	9,241535	8,342698

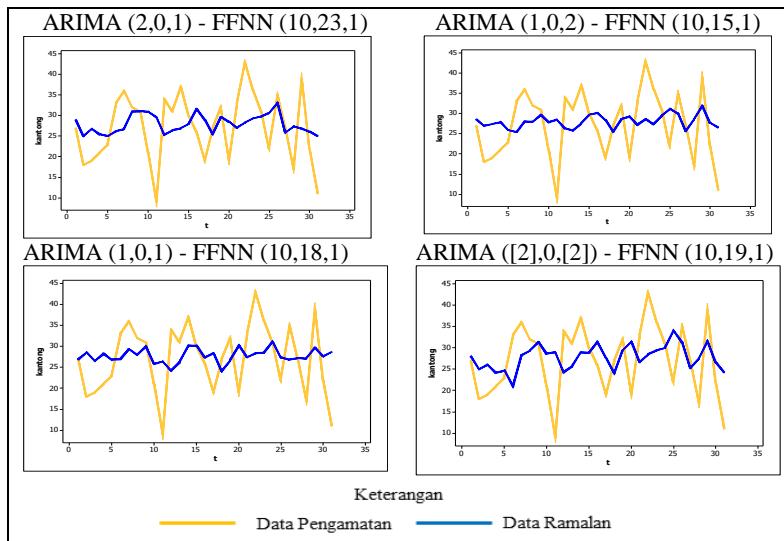
Pada Tabel 4.18 dapat diketahui bahwa nilai RMSE terkecil untuk outsample pada masing masing model dengan kombinasi 10 input residual yang terdiri dari a_{t-1} sampai a_{t-10} dengan jumlah node di *hidden layer* sebanyak 23, 15, 18, dan 19 node.

Setelah mengetahui jumlah node terbaik yang digunakan di *hidden layer* maka kemudian menghitung akurasi peramalan pada model *Hybrid* yang ditunjukkan di tabel 4.19. Terlihat nilai dari RMSE terkecil terletak pada ARIMA (1,0,1) - FFNN (10,18,1). Kemudian melakukan plot hasil ramalan terhadap data asli untuk melihat kesesuaian pola.

Tabel 4.19 Akurasi Model Hybrid Golongan Darah A

Model Hybrid	RMSE	
	In Sample	Out Sample
ARIMA (2,0,1) - FFNN (10,23,1)	8,29005	8,17812
ARIMA (1,0,2) - FFNN (10,15,1)	8,59436	8,16124
ARIMA (1,0,1) - FFNN (10,18,1)	8,90047	8,048
ARIMA ([2],0,[2]) - FFNN (10,19,1)	8,39559	8,16262

Pada Gambar 4.19 terlihat bahwa model *Hybrid* ARIMA (1,0,1) - FFNN (10,19,1) memiliki hasil peramalan yang lebih mengikuti pola dari data asli dibandingkan dengan model *Hybrid* ARIMA (1,0,1) - FFNN (10,18,1).

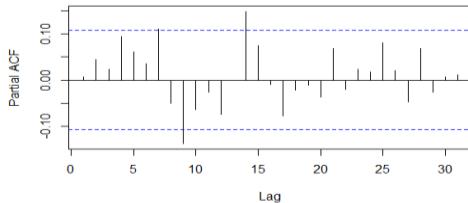
**Gambar 4.19** Plot Outsample Hybrid Golongan Darah A

Oleh karena itu model *Hybrid* ARIMA-ANN terbaik untuk golongan darah A, berdasarkan pada plot outsample terdapat pada ARIMA (1,0,1) - FFNN (10,19,1).

4.4.2 Golongan Darah B

Melanjutkan dari model ARIMA terbaik yang terpilih pada subbab 4.2.2, maka residual model ARIMA (0,0,1) dilakukan plot

PACF untuk menentukan pemilihan input yang akan digunakan pada model NN.



Gambar 4.20 PACF Residual Golongan Darah B

Pada Gambar 4.20 dapat dilihat lag yang paling signifikan yaitu lag a_{t-14} a_{t-9} , a_{t-7} . Dari beberapa lag tersebut akan dilakukan kombinasi antar lag untuk mengetahui adanya pola nonlinear dalam data. Maka dilakukan Uji Terasvirta sebagai berikut.

Tabel 4.20 Uji Teraesvirta Residual Golongan Darah B

Input	χ^2	df	P-value	F	df	P-value
$a_{t-1} - a_{t-10}$	685,85	275	0,0000	1,318	50	0,1194
$a_{t-1} - a_{t-5}$	58,008	50	0,204	1,076	280	0,348
$a_{t-7}, a_{t-9}, a_{t-14}$	20,637	16	0,1929	1,253	302	0,2265
a_{t-7}, a_{t-9}	11,422	7	0,1212	1,614	312	0,1305

Pada pengujian teraesvirta dapat diperoleh bahwa terdapat 1 pilihan input yang memiliki hasil uji paling signifikan yaitu 10 input dengan a_{t-1} sampai a_{t-10} . Pemodelan neural network yang digunakan yaitu dengan menggunakan jumlah node di hidden layer sebanyak 1 sampai 25 node. Didapatkan hasil akurasi peramalan untuk insample dan outsample sebagai berikut.

Tabel 4.21 Akurasi Model FFNN Residual Golongan Darah B

10 Input					
Node	InSample	OutSample	Node	InSample	OutSample
1	11,19958	10,57152	14	11,39752	10,34503
2	11,26719	10,51529	15	11,51872	10,53009
3	11,2932	10,56862	16	11,53319	10,50275

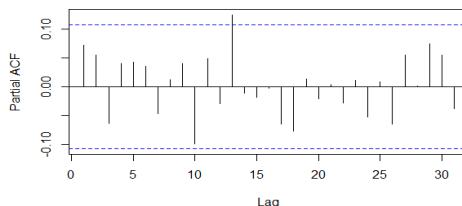
Tabel 4.21 Akurasi Model FFNN Residual Golongan Darah B (*lanjutan*)

10 Input					
Node	InSample	OutSample	Node	InSample	OutSample
4	11,55578	10,2527	17	11,46391	10,17449
5	11,34104	10,46372	18	11,9403	10,4111
6	11,61894	10,48024	19	11,78264	10,01576
7	11,34977	10,39575	20	11,20275	10,68232
8	11,27572	10,46412	21	11,6035	10,44362
9	11,35555	10,57666	22	11,31179	10,43196
10	11,27112	10,5549	23	11,6051	10,35555
11	11,45074	10,55126	24	11,5983	10,67117
12	11,29024	10,68656	25	11,35683	10,66896
13	11,27873	10,49738			

Pada Tabel 4.21 diatas dapat diketahui bahwa nilai RMSE terkecil pada kriteria outsample sebesar 10,259 dengan kombinasi 7 input yang terdiri dari a_{t-1} , a_{t-7} , a_{t-9} , a_{t-10} , a_{t-11} , a_{t-12} , a_{t-14} dengan jumlah node di *hidden layer* sebanyak 19 node. Jadi Model Hybrid yang terbentuk adalah ARIMA ([1,9,14],0,0) - FFNN (10,19,1).

4.4.3 Golongan Darah AB

Melanjutkan dari Model ARIMA terbaik yang terpilih pada subbab 4.2.3, maka residual model ARIMA ([19,25],0,0) dilakukan plot PACF untuk menentukan pemilihan input yang akan digunakan pada model NN.

**Gambar 4.21** PACF Residual Golongan Darah AB

Pada Gambar 4.21 dapat dilihat lag yang paling signifikan yaitu lag a_{t-13} dan a_{t-10} . Dari beberapa lag tersebut akan dilakukan kombinasi antar lag untuk mengetahui adanya pola nonlinear dalam data. Maka dilakukan Uji Terasvirta sebagai berikut.

Tabel 4.22 Uji Teraesvirta Residual Golongan Darah AB

Input	χ^2	df	P-value	F	df	P-Value
$a_{t-1} - a_{t-10}$	812,67	275	0,0000	2,034	50	0,0015
$a_{t-1} - a_{t-5}$	58,314	50	0,1962	1,082	280	0,3381
a_{t-10}, a_{t-13}	10,016	7	0,1877	1,412	313	0,1994
a_{t-13}	1,0888	2	0,5802	0,541	319	0,5831

Pada Tabel 4.22 dapat diperoleh hanya terdapat 1 pilihan input yang memiliki hasil uji paling signifikan yaitu 10 input dengan a_{t-1} sampai a_{t-10} . Pemodelan FFNN yang digunakan yaitu dengan 10 input dan jumlah node di hidden layer sebanyak 1 sampai 25 node. Diperoleh hasil sebagai berikut.

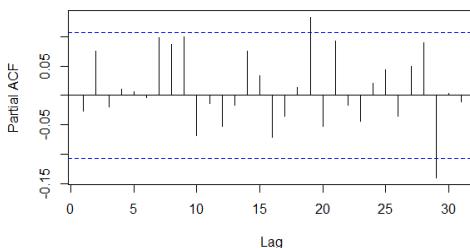
Tabel 4.23 Akurasi Model FFNN Residual Golongan Darah AB

10 Input					
Node	InSample	OutSample	Node	InSample	OutSample
1	4,880195	5,624037	14	5,021091	5,427591
2	4,887643	5,632603	15	4,798013	5,498719
3	4,922908	5,692086	16	4,920334	5,598018
4	4,865453	5,64891	17	4,906019	5,645572
5	4,870467	5,623806	18	4,819048	5,6582
6	4,902996	5,622971	19	5,170658	5,579267
7	4,843424	5,593083	20	4,875768	5,684257
8	4,905506	5,589662	21	4,7271	5,591267
9	4,816471	5,424021	22	5,01388	5,427657
10	4,890217	5,525818	23	4,788714	5,60557
11	5,030546	5,489483	24	4,875142	5,56082
12	4,809352	5,245301	25	5,023019	5,397891
13	5,045972	5,666921			

Pada tabel diatas dapat diketahui bahwa nilai RMSE terkecil pada kriteria outsample sebesar 5,245 dengan kombinasi 10 input yang terdiri dari a_{t-1} sampai a_{t-10} , dengan jumlah node pada *hidden layer* sebanyak 12 node. Jadi Model Hybrid yang terbentuk adalah ARIMA ([19,25],0,0) - FFNN (10,12,1).

4.4.4 Golongan Darah O

Melanjutkan dari model ARIMA terbaik yang terpilih pada subbab 4.2.4, maka residual model ARIMA (1,0,1) dilakukan plot PACF untuk menentukan pemilihan input yang akan digunakan pada model FFNN.



Gambar 4.22 PACF Residual Golongan Darah O

Pada Gambar diatas dapat dilihat lag yang paling signifikan yaitu lag a_{t-29} dan a_{t-19} . Dari lag tersebut dapat dilakukan kombinasi antar lag untuk mengetahui adanya pola nonlinear dalam data. Maka dilakukan Uji Terasvirta sebagai berikut.

Tabel 4.24 Uji Teraesvirta Residual Golongan Darah AB

Input	χ^2	Df	P-value	F	df	P-value
$a_{t-1} - a_{t-10}$	570,42	275	0,0000	0,869	50	0,7582
$a_{t-1} - a_{t-5}$	51,248	50	0,4245	0,941	280	0,5901
a_{t-19}, a_{t-29}	5,2251	7	0,6325	0,731	297	0,6461
a_{t-19}	0,9371	12	0,6259	0,464	303	0,6288

Pada pengujian Teraesvirta dapat diperoleh hanya terdapat 1 pilihan input yang memiliki hasil uji paling signifikan yaitu 10 input dengan a_{t-1} sampai a_{t-10} . Pemodelan neural network yang digunakan yaitu dengan menggunakan jumlah node di hidden layer

sebanyak 1 sampai 25 node. Didapatkan hasil akurasi peramalan untuk insample dan outsample sebagai berikut.

Tabel 4.25 Akurasi Model FFNN Residual Golongan Darah AB

10 Input					
Node	InSample	OutSample	Node	InSample	OutSample
1	12,39959	11,92228	14	12,93124	11,27885
2	12,39059	11,73215	15	12,53918	11,66631
3	12,36606	11,80632	16	12,56017	11,76237
4	12,32099	11,782	17	12,91607	11,7971
5	12,38527	11,74093	18	12,22186	11,93507
6	12,37191	11,80131	19	12,71241	11,38326
7	12,57177	11,83529	20	12,32231	11,73976
8	12,45117	11,64032	21	12,34622	11,61319
9	12,198	11,96189	22	11,83127	11,52113
10	11,72946	11,45571	23	12,4835	11,69266
11	12,10658	11,7174	24	12,31822	11,82261
12	12,55485	11,21013	25	12,44312	11,82953
13	12,36482	11,91378			

Pada tabel diatas dapat diketahui bahwa nilai RMSE terkecil pada kriteria outsample sebesar 11,2101 dengan kombinasi 10 input yang terdiri dari a_{t-1} sampai a_{t-10} dengan jumlah node di *hidden layer* sebanyak 13 node. Jadi Model Hybrid yang terbentuk adalah ARIMA (1,0,1) - FFNN (10,12,1).

4.5 Pemilihan Model Terbaik

Untuk memperoleh model terbaik yang digunakan sebagai peramalan maka dapat dilakukan perbandingan dari ketiga model terbaik yang sudah didapatkan.

4.5.1 Golongan Darah A

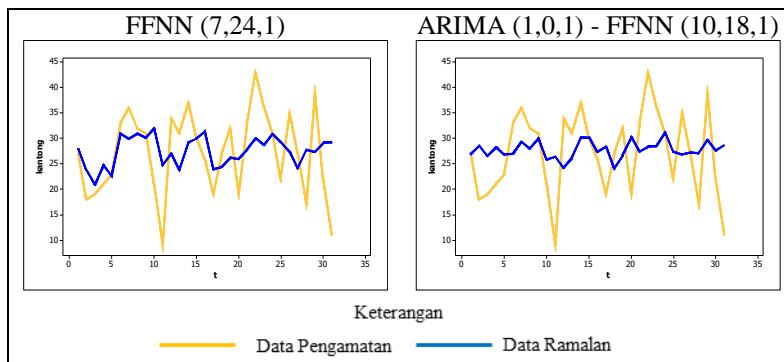
Ketiga Model yang sudah terbentuk untuk permintaan pada golongan darah A yaitu model ARIMA, model FFNN dan model

Hybrid ARIMA-ANN, dapat dilakukan pemilihan atau seleksi dari ketiga model tersebut untuk mendapatkan Model terbaik dari ketiga Model tersebut .

Tabel 4.26 Perbandingan Model Terbaik Golongan Darah A

Model	RMSE	
	In Sample	Out Sample
FFNN (7,24,1)	8,079	7,553
ARIMA (1,0,1) - FFNN (10,18,1)	8,90047	8,048

Pada tabel 4.26 terlihat bahwa Model *Neural Network* merupakan model terbaik dibandingkan model hybrid, karena memiliki nilai RMSE terkecil pada insample dan outsample, yaitu sebesar 8,079 dan outsample sebesar 7,553.



Gambar 4.23 Plot Outsample Model Terbaik Golongan Darah A

Pada gambar 4.23 terlihat bahwa untuk FFNN (7,24,1) memiliki hasil peramalan mengikuti pola dari data asli lebih baik jika dibandingkan dengan ARIMA (1,0,1) - FFNN (10,18,1). Jadi pemilihan model peramalan terbaik untuk golongan darah A terdapat pada model FFNN (7,24,1).

Bentuk model FFNN (7,24,1) terdiri dari variabel input sebanyak 7 yaitu Y_{t-1} , Y_{t-2} , Y_{t-3} , Y_{t-5} , Y_{t-26} , Y_{t-41} , Y_{t-44} menggunakan *preprocessing standardized* dan terdapat 24 node di *hidden layer* dengan fungsi aktivasi log sigmoid. Persamaan pada model FFNN (7,24,1) dapat ditulis sebagai berikut.

$$\begin{aligned}
Y_t = S[& 0,244 + 0,054f(x_{1,t}) + 0,015f(x_{2,t}) + 1,099f(x_{3,t}) + 0,919f(x_{4,t}) \\
& + 0,121f(x_{5,t}) - 0,552f(x_{6,t}) - 0,147f(x_{7,t}) + 0,041f(x_{8,t}) \\
& - 0,254f(x_{9,t}) + 0,081f(x_{10,t}) - 0,078f(x_{11,t}) + 0,174f(x_{12,t}) \\
& - 0,416f(x_{13,t}) - 0,965f(x_{14,t}) + 0,222f(x_{15,t}) - 0,174f(x_{16,t}) \\
& + 0,261f(x_{17,t}) - 0,163f(x_{18,t}) + 0,269f(x_{19,t}) - 0,119f(x_{20,t}) \\
& - 0,034f(x_{21,t}) - 0,653f(x_{22,t}) - 0,131f(x_{23,t}) - 0,767f(x_{24,t})] + \bar{Y}
\end{aligned}$$

dimana

$$f(x_{j,t}) = \frac{1}{1 + e^{-(x_{j,t})}} ; j=1,2,3,...,24.$$

$$\begin{aligned}
x_{1,t} = & -0,269 + 0,208Z_{t-1} + 0,181Z_{t-2} + 0,205Z_{t-3} - 0,007Z_{t-5} + 0,322Z_{t-26} \\
& - 0,606Z_{t-41} + 0,405Z_{t-44}
\end{aligned}$$

$$\begin{aligned}
x_{2,t} = & -0,143 - 0,322Z_{t-1} - 0,033Z_{t-2} + 0,298Z_{t-3} + 0,224Z_{t-5} - 0,007Z_{t-26} \\
& + 0,092Z_{t-41} - 0,395Z_{t-44}
\end{aligned}$$

$$\begin{aligned}
x_{3,t} = & 0,776 + 0,250Z_{t-1} - 0,632Z_{t-2} - 0,106Z_{t-3} - 0,139Z_{t-5} - 0,130Z_{t-26} \\
& + 1,404Z_{t-41} - 0,166Z_{t-44}
\end{aligned}$$

⋮

$$x_{22,t} = -0,309 + 0,657Z_{t-1} - 0,917Z_{t-2} + 0,391Z_{t-3} - 0,358Z_{t-5} + 0,019Z_{t-26}$$

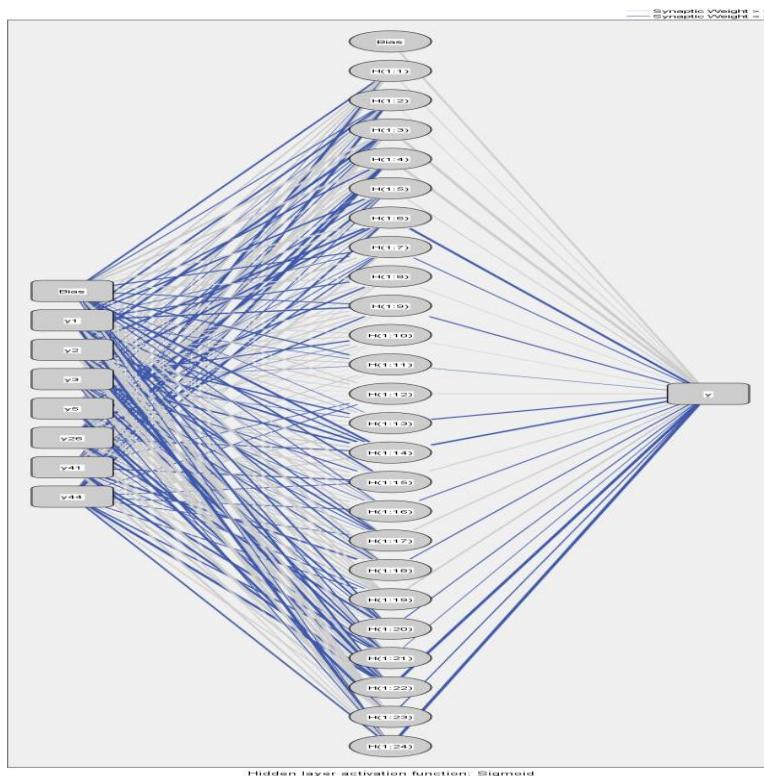
$$- 0,409Z_{t-41} - 0,236Z_{t-44}$$

$$\begin{aligned}
x_{23,t} = & 0,562 + 0,624Z_{t-1} + 0,707Z_{t-2} + 0,412Z_{t-3} - 0,551Z_{t-5} + 1,058Z_{t-26} \\
& + 0,34Z_{t-41} + 0,151Z_{t-44}
\end{aligned}$$

$$\begin{aligned}
x_{24,t} = & -0,068 - 0,595Z_{t-1} + 0,677Z_{t-2} - 0,096Z_{t-3} + 0,01Z_{t-5} + 0,103Z_{t-26} \\
& + 0,299Z_{t-41} - 0,221Z_{t-44}
\end{aligned}$$

$$\text{dengan } Z_{t-k} = \frac{Y_{t-k} - \bar{Y}}{S} ; k = 1,2,3,5,26,41,44$$

Bentuk arsitektur model FFNN (7,24,1) yang terdapat 7 variabel input dengan jumlah node di *hidden layer* sebanyak 24. Didapatkan gambar arsitektur seperti pada Gambar 4.23. Pada gambar tersebut dapat terlihat juga untuk nilai bobot yang kurang dari nol memiliki garis tebal sedangkan nilai bobot yang lebih dari nol memiliki garis yang dicetak tipis.



Gambar 4.24 Aristekturn FFNN Golongan Darah A

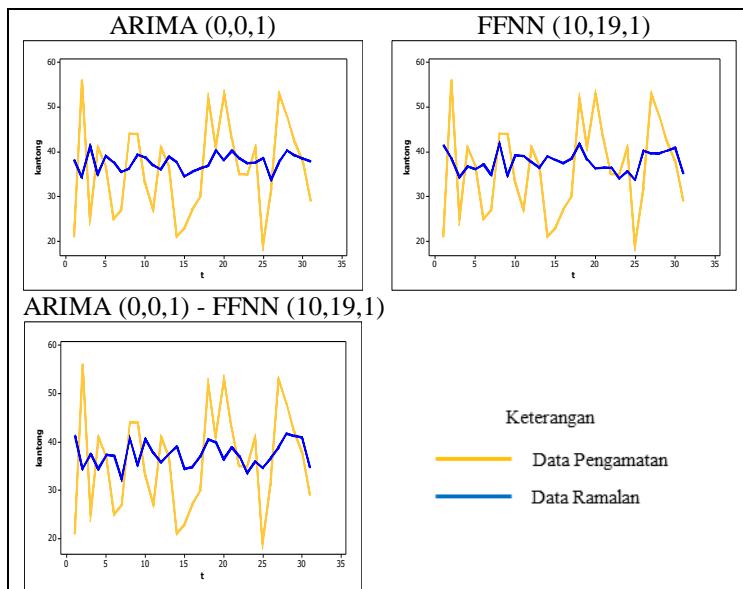
4.5.2 Golongan Darah B

Ketiga Model yang terbentuk untuk permintaan golongan darah B yaitu Model ARIMA, ANN dan Hybrid ARIMA-ANN, dapat dilakukan pemilihan untuk mendapatkan Model terbaik dari ketiga Model tersebut.

Tabel 4.27 Perbandingan Model Terbaik Golongan Darah B

Model	RMSE	
	In Sample	Out Sample
ARIMA (0,0,1)	11,836	10,356
FFNN (10,19,1)	12,094	10,008
ARIMA (0,0,1) - FFNN (10,19,1)	12,227	10,015

Pada Tabel 4.27 terlihat bahwa model FFNN merupakan model terbaik yang terpilih berdasarkan kriteria RMSE terkecil pada outsample yaitu sebesar 10,008.



Gambar 4.25 Plot Outsample Model Terbaik Golongan Darah B

Pada Gambar 4.25 terlihat bahwa semua model kurang menunjukkan hasil ramalan yang mengikuti pola data asli pada outsample. Akan tetapi jika dibandingkan dari ketiga model yang terbentuk model FFNN (10,19,1) yang paling mengikuti pola dari data asli. Sehingga pemilihan model terbaik yang digunakan untuk melakukan peramalan pada periode yang akan datang yaitu dengan menggunakan FFNN (10,19,1).

Bentuk model FFNN (10,19,1) terdiri dari variabel input sebanyak 10 input yang terdiri dari lag antara Y_{t-1} - Y_{t-10} serta menggunakan *pre-processing standardized* dan terdapat 19 node di *hidden layer* dengan fungsi aktivasi log sigmoid pada *hidden layer*. Sehingga dapat diperoleh bentuk persamaan seperti berikut ini.

$$\begin{aligned}
Y_t = & S[0,635 + 0,199f(x_{1,t}) + 0,098f(x_{2,t}) - 1,164f(x_{3,t}) - 0,035f(x_{4,t}) \\
& - 1,058f(x_{5,t}) + 1,539f(x_{6,t}) - 1,039f(x_{7,t}) - 1,598f(x_{8,t}) \\
& - 0,230f(x_{9,t}) - 1,842f(x_{10,t}) + 1,006f(x_{11,t}) + 1,425f(x_{12,t}) \\
& - 0,757f(x_{13,t}) + 0,142f(x_{14,t}) - 0,999f(x_{15,t}) + 0,635f(x_{16,t}) \\
& - 0,05f(x_{17,t}) - 0,382f(x_{18,t}) + 1,251f(x_{19,t})] + \bar{Y} + \alpha_t
\end{aligned}$$

dimana

$$f(x_{j,t}) = \frac{1}{1 + e^{-(x_{j,t})}} ; j=1,2,3,\dots,19.$$

$$\begin{aligned}
x_{1,t} = & 0,035 - 0,246Z_{t-1} - 0,287Z_{t-2} + 0,193Z_{t-3} + 0,42Z_{t-4} + 0,079Z_{t-5} \\
& - 0,152Z_{t-6} - 0,124Z_{t-7} - 0,043Z_{t-8} + 0,159Z_{t-9} - 0,474Z_{t-10}
\end{aligned}$$

$$\begin{aligned}
x_{2,t} = & -0,044 + 0,084Z_{t-1} + 0,017Z_{t-2} - 0,218Z_{t-3} + 0,074Z_{t-4} + 0,277Z_{t-5} \\
& + 0,012Z_{t-6} - 0,102Z_{t-7} + 0,293Z_{t-8} - 0,063Z_{t-9} - 0,251Z_{t-10}
\end{aligned}$$

$$\begin{aligned}
x_{3,t} = & 0,6 - 0,694Z_{t-1} + 0,106Z_{t-2} - 0,641Z_{t-3} - 0,7Z_{t-4} - 0,227Z_{t-5} \\
& - 1,65Z_{t-6} - 0,378Z_{t-7} + 0,031Z_{t-8} + 0,261Z_{t-9} - 0,834Z_{t-10}
\end{aligned}$$

$$\begin{aligned}
x_{4,t} = & 0,007 + 0,56Z_{t-1} - 0,39Z_{t-2} - 0,309Z_{t-3} + 0,143Z_{t-4} - 0,3Z_{t-5} \\
& + 3,343Z_{t-6} + 0,157Z_{t-7} - 0,132Z_{t-8} - 0,299Z_{t-9} - 0,087Z_{t-10}
\end{aligned}$$

⋮

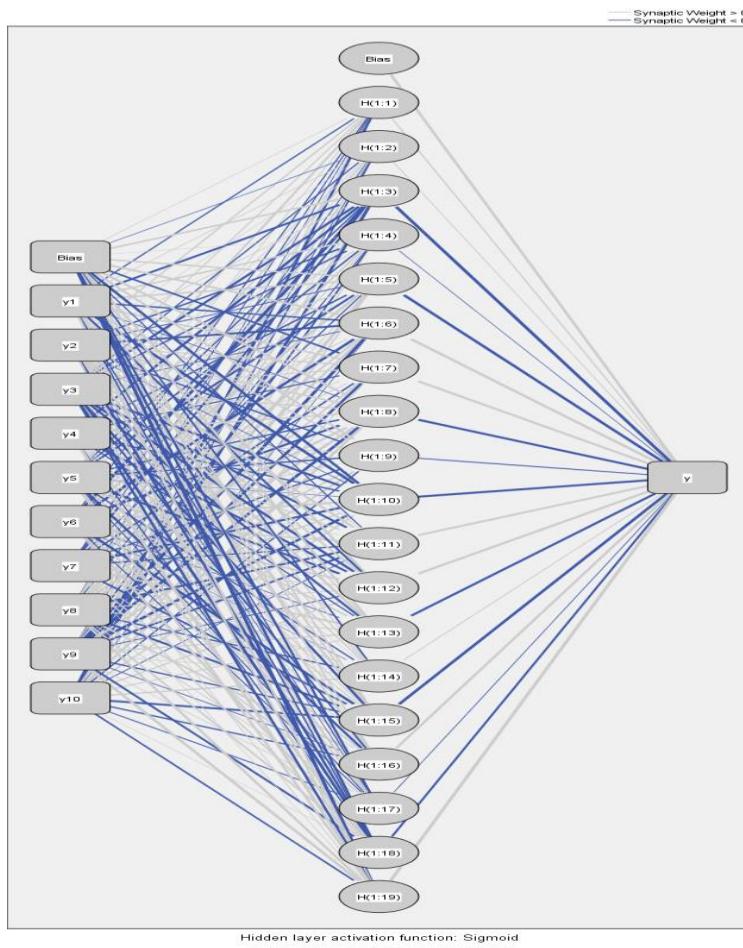
$$\begin{aligned}
x_{17,t} = & -0,388 - 0,158Z_{t-1} - 0,024Z_{t-2} + 0,456Z_{t-3} + 0,266Z_{t-4} - 0,135Z_{t-5} \\
& - 1,42Z_{t-6} + 0,254Z_{t-7} + 0,123Z_{t-8} + 0,082Z_{t-9} - 0,192Z_{t-10}
\end{aligned}$$

$$\begin{aligned}
x_{18,t} = & -0,515 - 0,227Z_{t-1} - 0,494Z_{t-2} - 0,686Z_{t-3} - 0,167Z_{t-4} + 0,317Z_{t-5} \\
& + 0,599Z_{t-6} + 0,283Z_{t-7} + 0,361Z_{t-8} - 0,496Z_{t-9} + 0,016Z_{t-10}
\end{aligned}$$

$$\begin{aligned}
x_{19,t} = & -0,978 + 0,445Z_{t-1} + 0,348Z_{t-2} - 0,479Z_{t-3} + 0,85Z_{t-4} + 0,522Z_{t-5} \\
& + 0,065Z_{t-6} + 0,023Z_{t-7} + 0,619Z_{t-8} + 0,977Z_{t-9} - 0,334Z_{t-10}
\end{aligned}$$

$$\text{dengan } Z_{t-k} = \frac{Y_{t-k} - \mu}{\sigma} ; k = 1,2,3,\dots,10.$$

Pada Gambar 4.26 menunjukkan Arsitektur Model FFNN (10,19,1) terlihat bahwa terdapat 10 input yaitu gambar persegi panjang di bagian kiri dan 19 node di *hidden layer* yaitu gambar oval yang berada di tengah serta 1 output yaitu persegi panjang yang ada di sebelah kanan.



Gambar 4.26 Aristekturn FFNN Golongan Darah B

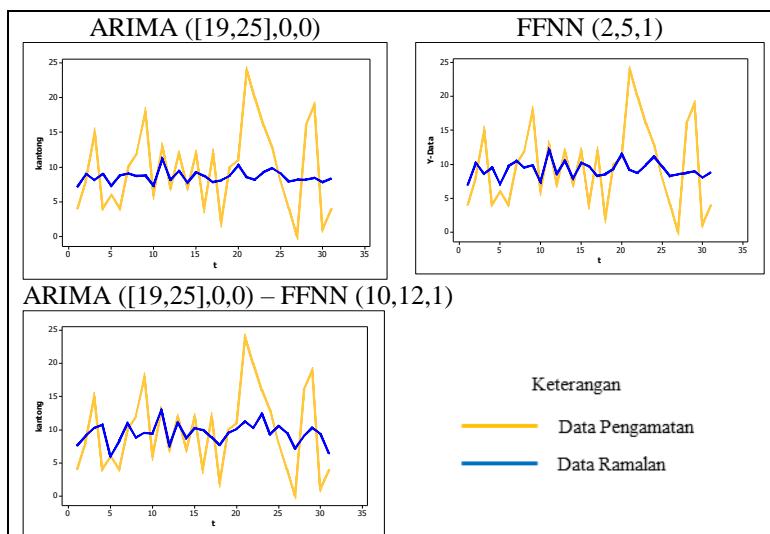
4.5.3 Golongan Darah AB

Ketiga Model yang terbentuk untuk permintaan golongan darah AB yaitu Model ARIMA, ANN dan Hybrid ARIMA-ANN, dapat dilakukan pemilihan untuk mendapatkan Model terbaik dari ketiga Model tersebut. Diperoleh hasil perbandingan dari ketiga Model Terbaik untuk golongan darah AB sebagai berikut.

Tabel 4.28 Perbandingan Model Terbaik Golongan Darah AB

Model	RMSE	
	In Sample	Out Sample
ARIMA ([19,25],0,0)	4,831	5,838
FFNN (10,9,1)	4,911	5,505
ARIMA ([19,25],0,0) – FFNN (10,12,1)	4,705	5,247

Pada tabel diatas terlihat bahwa Model Hybrid ARIMA dengan *Neural Network* merupakan model terbaik yang terpilih berdasarkan kriteria RMSE terkecil pada insample yaitu sebesar 4,705 dan outsample sebesar 5,247. Kemudian dapat melakukan plot hasil ramalan terhadap data asli untuk setiap model, hal tersebut dapat bertujuan untuk mengetahui plot hasil ramalan yang paling mengikuti data asli.

**Gambar 4.27** Plot Outsample Model Terbaik Golongan Darah AB

Gambar 4.27 menunjukkan bahwa setiap model memiliki hasil ramalan yang cenderung stabil di rata – rata permintaan darah golongan AB. Untuk model Hybrid ARIMA ([19,25],0,0) – FFNN (10,12,1) memiliki plot hasil ramalan yang lebih baik jika dibandingkan dengan model lainnya. Oleh karena itu model

terbaik yang terpilih yaitu ARIMA ([19,25],0,0) – FFNN (10,12,1).

Jadi model terbaik yang diperoleh yaitu Model *Hybrid* ([19,25],0,0) - (10,12,1). Bentuk model ARIMA ([19,25],0,0) – FFNN (10,12,1) terdiri dari variabel input pada ARIMA sebanyak 2 yaitu pada lag ke 19 dan lag ke 25 sedangkan untuk FFNN variabel input yang digunakan yaitu residual sebanyak 10 yaitu a_{t-1} sampai a_{t-10} dengan menggunakan *pre-processing standardized* dan terdapat 12 node di *hidden layer* serta fungsi aktivasi log sigmoid adalah sebagai berikut.

$$\begin{aligned} Y_t = & 3,0166 - 0,155Y_{t-19} + 0,1249Y_{t-19} + [S[0,075 + 1,941f(x_{1,t}) \\ & 0,914f(x_{2,t}) - 0,443f(x_{3,t}) - 0,301f(x_{4,t}) - 1,386f(x_{5,t}) \\ & + 0,230f(x_{6,t}) - 1,359f(x_{7,t}) + 0,061f(x_{8,t}) + 1,033f(x_{9,t}) \\ & - 1,207f(x_{10,t}) - 1,695f(x_{11,t}) + 1,752f(x_{12,t})] + \bar{a}] + a_t \end{aligned}$$

dimana

$$f(x_{j,t}) = \frac{1}{1 + e^{-(x_{j,t})}} ; j=1,2,3,...,12.$$

$$\begin{aligned} x_{1,t} = & 0,114 - 0,840Z_{t-1} - 1,233Z_{t-2} + 0,161Z_{t-3} - 0,069Z_{t-4} - 1,832Z_{t-5} \\ & - 1,806Z_{t-6} - 1,169Z_{t-7} - 1,124Z_{t-8} + 1,087Z_{t-9} + 0,793Z_{t-10} \end{aligned}$$

$$\begin{aligned} x_{2,t} = & 0,156 - 0,031Z_{t-1} + 0,242Z_{t-2} + 0,192Z_{t-3} - 0,101Z_{t-4} + 1,078Z_{t-5} \\ & - 1,347Z_{t-6} - 1,132Z_{t-7} + 0,086Z_{t-8} - 0,415Z_{t-9} + 0,061Z_{t-10} \end{aligned}$$

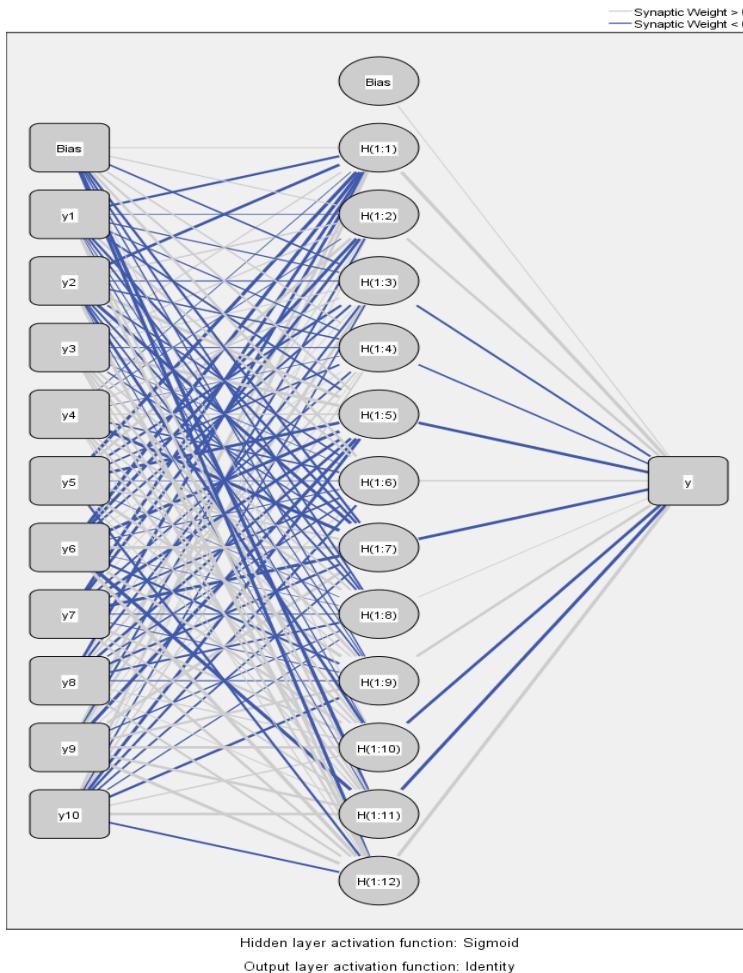
⋮

$$\begin{aligned} x_{11,t} = & -1,831 + 0,444Z_{t-1} - 0,113Z_{t-2} + 0,253Z_{t-3} - 0,679Z_{t-4} + 0,144Z_{t-5} \\ & - 2,62Z_{t-6} + 0,348Z_{t-7} + 0,113Z_{t-8} + 1,143Z_{t-9} + 1,148Z_{t-10} \end{aligned}$$

$$\begin{aligned} x_{12,t} = & -1,366 + 1,064Z_{t-1} + 1,507Z_{t-2} + 0,497Z_{t-3} + 0,11Z_{t-4} - 0,564Z_{t-5} \\ & + 2,632Z_{t-6} + 0,849Z_{t-7} + 0,51Z_{t-8} + 1,413Z_{t-9} - 0,458Z_{t-10} \end{aligned}$$

$$\text{dengan } Z_{t-k} = \frac{a_{t-k} - \bar{Y}}{S} ; k = 1,2,3,...,10.$$

Gambar 4.28 menunjukkan Arsitektur Model FFNN (10,12,1) terlihat bahwa terdapat 10 input yang terdiri dari lag residual Model ARIMA ([19,25],0,0) yaitu a_{t-1} sampai a_{t-10} . dan 12 node di *hidden layer*.



Gambar 4.28Arsitektur Model Hybrid Golongan Darah AB

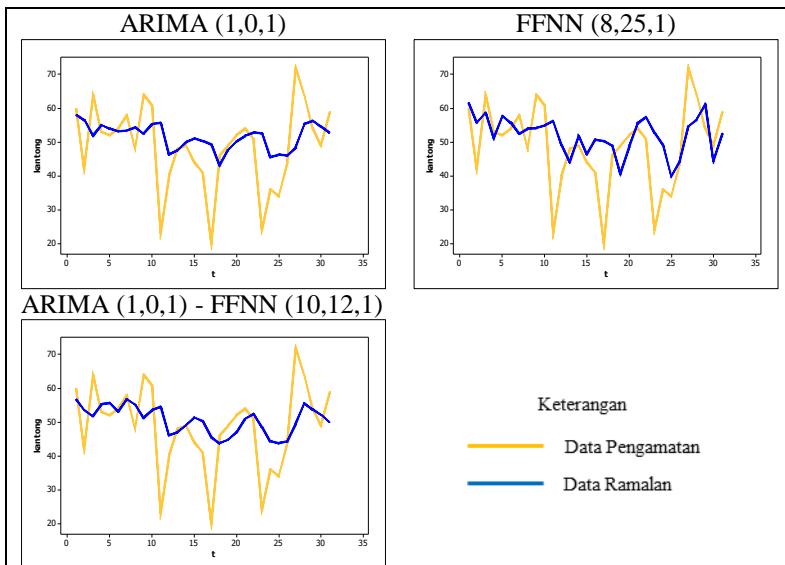
4.5.4 Golongan Darah O

Ketiga model yang terbentuk untuk permintaan golongan darah O yaitu model ARIMA, FFNN dan Hybrid ARIMA-ANN, dapat dilakukan pemilihan untuk mendapatkan Model terbaik dari ketiga Model tersebut.

Tabel 4.29 Perbandingan Model Terbaik Golongan Darah O

Model	RMSE	
	In Sample	Out Sample
ARIMA (1,0,1)	12,821	12,052
FFNN (8,25,1)	11,397	11,824
ARIMA (1,0,1) - FFNN (10,12,1)	12,788	11,286

Pada Tabel 4.29 terlihat bahwa Model Hybrid ARIMA dengan *Neural Network* merupakan model terbaik yang terpilih berdasarkan kriteria nilai RMSE terkecil pada outsample yaitu sebesar 11,286 dan outsample sebesar 11,824. Sedangkan nilai RMSE terkecil pada insample terletak pada FFNN (8,25,1). Maka dapat dilakukan plot pada hasil ramalan terhadap data pengamatan untuk melihat plot manakah yang paling mengikuti data pengamatan.

**Gambar 4.29** Plot Outsample Model Terbaik Golongan Darah O

Gambar 4.29 menunjukkan bahwa meskipun model *Hybrid* ARIMA (1,0,1) - FFNN (10,12,1) memiliki nilai RMSE untuk outsample yang terkecil, namun hasil plot ramalan terhadap data

pengamatan menunjukkan bahwa model FFNN (8,25,1) lebih mengikuti data pengamatan. Serta hasil akurasi pada insample dan outsample yang relatif kecil, menghasilkan keputusan bahwa pada model FFNN (8,25,1) yang akan digunakan untuk meramalkan periode yang akan datang.

Jadi model peramalan terbaik yang diperoleh yaitu Model FFNN (8,25,1). Model yang dihasilkan FFNN (8,25,1) terdiri dari variabel input sebanyak 8 yaitu Y_{t-1} , Y_{t-2} , Y_{t-7} , Y_{t-10} , Y_{t-14} , Y_{t-16} , Y_{t-19} , Y_{t-29} menggunakan *preprocessing standardized* dan terdapat 25 node di *hidden layer* dengan fungsi aktivasi log sigmoid adalah sebagai berikut.

$$\begin{aligned} Y_t = & S[-0,555 + 0,639f(x_{1,t}) - 0,011f(x_{2,t}) - 0,514f(x_{3,t}) + 0,476f(x_{4,t}) \\ & - 0,122f(x_{5,t}) - 0,059f(x_{6,t}) + 0,084f(x_{7,t}) - 0,347f(x_{8,t}) \\ & - 0,141f(x_{9,t}) - 0,423f(x_{10,t}) + 0,078f(x_{11,t}) - 0,221f(x_{12,t}) \\ & + 0,781f(x_{13,t}) - 0,421f(x_{14,t}) - 0,404f(x_{15,t}) + 0,305f(x_{16,t}) \\ & - 0,183f(x_{17,t}) - 0,438f(x_{18,t}) - 0,065f(x_{19,t}) - 0,002f(x_{20,t}) \\ & 0,219f(x_{21,t}) + 0,262f(x_{22,t}) + 0,447f(x_{23,t}) - 0,754f(x_{24,t}) \\ & + 0,37f(x_{25,t})] + \bar{Y} + \alpha_t \end{aligned}$$

dimana

$$f(x_{j,t}) = \frac{1}{1 + e^{-(x_{j,t})}} ; j=1,2,3,\dots,25.$$

$$\begin{aligned} x_{1,t} = & -0,386 + 0,2Z_{t-1} + 0,73Z_{t-2} + 0,331Z_{t-7} - 0,136Z_{t-10} + 0,256Z_{t-14} \\ & + 0,217Z_{t-16} + 0,684Z_{t-19} + 0,265Z_{t-29} \end{aligned}$$

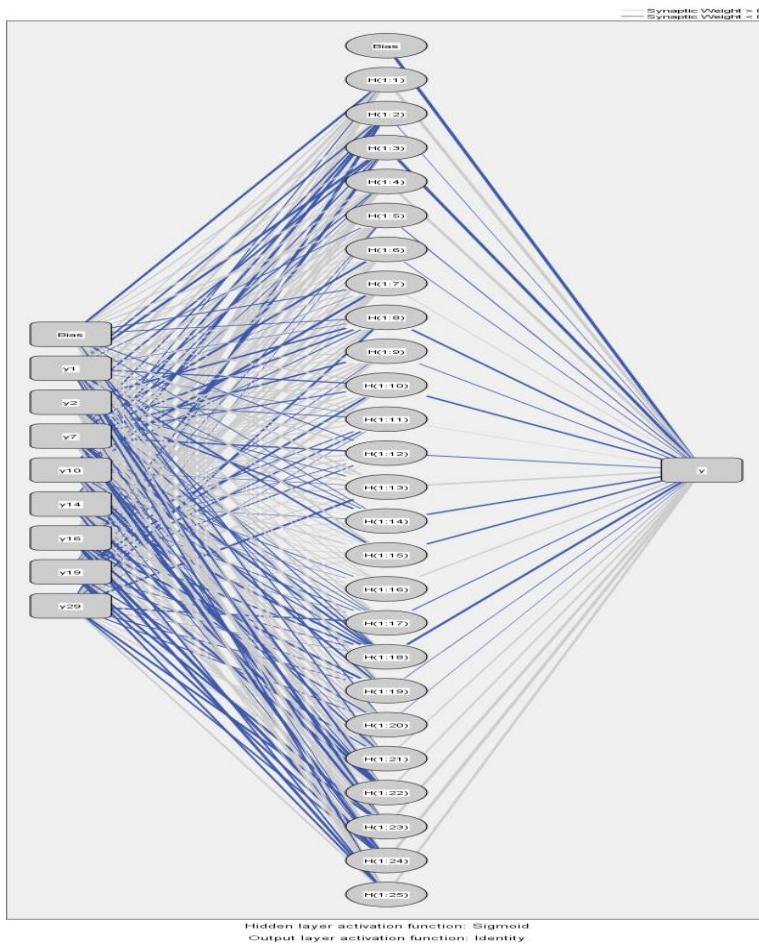
$$\begin{aligned} x_{2,t} = & 0,232 - 0,278Z_{t-1} + 0,026Z_{t-2} - 0,205Z_{t-7} - 0,322Z_{t-10} - 0,433Z_{t-14} \\ & + 0,004Z_{t-16} + 0,072Z_{t-19} - 0,528Z_{t-29} \end{aligned}$$

⋮

$$\begin{aligned} x_{24,t} = & 0,023 + 0,567Z_{t-1} - 0,058Z_{t-2} - 0,526Z_{t-7} - 0,098Z_{t-10} + 0,282Z_{t-14} \\ & - 0,623Z_{t-16} - 0,325Z_{t-19} - 0,263Z_{t-29} \end{aligned}$$

$$\begin{aligned} x_{25,t} = & 0,216 - 0,226Z_{t-1} + 0,37Z_{t-2} + 0,616Z_{t-7} + 0,12Z_{t-10} - 0,238Z_{t-14} \\ & - 0,437Z_{t-16} - 0,295Z_{t-19} + 0,292Z_{t-29} \end{aligned}$$

$$\text{dengan } Z_{t-k} = \frac{Y_{t-k} - \mu}{\sigma} ; k = 1,2,3,\dots,10.$$



Gambar 4.30 Arsitektur Model Hybrid Golongan Darah O

Gambar 4.30 menunjukkan arsitektur di model FFNN $(8, 25, 1)$ terlihat bahwa terdapat 8 input yaitu gambar persegi panjang di bagian kiri dan 25 node di *hidden layer* yaitu gambar oval yang berada di tengah serta 1 output yaitu persegi panjang yang ada di sebelah kanan. Dapat dilihat juga bahwa garis tebal merupakan bobot atau estimasi parameter

dengan nilai kurang dari nol, sedangkan garis tipis merupakan nilai estimasi parameter lebih besar dari nol. Sehingga telah didapatkan model terbaik untuk setiap golongan darah.

4.6 Peramalan Permintaan Darah Jenis PRC

Setelah mendapatkan hasil model terbaik untuk masing – masing golongan darah pada subbab 4.5, maka dapat dilakukan peramalan untuk periode yang akan datang.

4.6.1 Golongan Darah A

Untuk permintaan Golongan Darah A Model Terbaik yang terpilih yaitu *Feed Forward Neural Network* dengan 7 input yang terdiri dari $Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-5}, Y_{t-26}, Y_{t-41}, Y_{t-44}$ dan jumlah node di *hidden layer* sebanyak 24. Struktur data pengujian FFNN dapat dilihat pada lampiran 12. Sedangkan untuk nilai Z_{t-i} dengan $i = 1, 2, 3, 5, 26, 41, 44$ dapat dilihat di lampiran 13. Berikut adalah hasil nilai peramalan pada insample untuk $t = 45$ seperti yang ditunjukkan pada lampiran 14.

$$\begin{aligned}
 - x_{1,45} &= -0,269 + 0,208(0,225) + 0,181(1,443) + 0,205(-0,223) \\
 &\quad -0,007(-0,563) + 0,322(0,654) - 0,606(0,072) + 0,405(-0,48) \\
 &= -0,03 \\
 - x_{2,45} &= -0,143 - 0,322(0,225) - 0,033(1,443) + 0,298(-0,223) \\
 &\quad +0,224(-0,563) - 0,007(0,654) + 0,092(0,072) - 0,395(-0,48) \\
 &= -0,265 \\
 &\vdots \\
 - x_{23,45} &= 0,562 + 0,624(0,225) + 0,707(1,443) + 0,412(-0,223) \\
 &\quad -0,551(-0,563) + 1,058(0,654) + 0,34(0,072) + 0,151(-0,48) \\
 &= 2,586 \\
 - x_{24,45} &= -0,068 - 0,595(0,225) + 0,677(1,443) - 0,096(-0,223) \\
 &\quad +0,01(-0,563) + 0,103(0,654) + 0,299(0,072) - 0,221(-0,48) \\
 &= 0,985
 \end{aligned}$$

$$f(x_{1,45}) = \frac{1}{1+e^{-(-0,03)}} = 0,492$$

$$f(x_{2,45}) = \frac{1}{1+e^{(-0,265)}} = 0,434$$

⋮

$$f(x_{23,45}) = \frac{1}{1+e^{-(2,586)}} = 0,929$$

$$f(x_{24,45}) = \frac{1}{1+e^{-(0,985)}} = 0,728$$

Maka ramalan untuk data ke 25 dalam skala *preprocessing* adalah sebagai berikut.

$$\begin{aligned} -Y_{45}^* &= 0,244 + 0,054(0,492) + \dots - 0,131(0,929) - 0,767(0,728) \\ &= 0,353 \end{aligned}$$

Sehingga ramalan dalam satuan data awal (*post-processing*) adalah sebagai berikut.

$$\begin{aligned} -\hat{Y}_{45} &= (Y_t^* S_y) + \bar{Y} \\ &= (0,353 \cdot 9,01) + 27,922 \\ &= 31,103 \end{aligned}$$

Kemudian peramalan untuk periode $t = 367$ dan saat $t = 368$ dengan menggunakan cara *k-step ahead* diperoleh hasil sebagai berikut.

$$\begin{aligned} -x_{1,367} &= -0,269 + 0,208(-1,895) + 0,181(-0,672) + 0,205(1,227) \\ &\quad - 0,007(-0,117) + 0,322(0,542) - 0,606(0,742) + 0,405(-0,033) \\ &= -0,822 \\ -x_{2,367} &= -0,143 - 0,322(-1,895) - 0,033(-0,672) + 0,298(1,227) \\ &\quad + 0,224(-0,117) - 0,007(0,542) + 0,092(0,742) - 0,395(-0,033) \\ &= 0,906 \\ &\vdots \\ -x_{23,367} &= 0,562 + 0,624(-1,895) + 0,707(-0,672) + 0,412(1,227) \\ &\quad - 0,551(-0,117) + 1,058(0,542) + 0,34(0,742) + 0,151(-0,033) \\ &= 0,295 \\ -x_{24,367} &= -0,068 - 0,595(-1,895) + 0,677(-0,672) - 0,096(1,227) \\ &\quad + 0,01(-0,117) + 0,103(0,542) + 0,299(0,742) - 0,221(-0,033) \end{aligned}$$

$$-x_{24,367} = 0,772$$

$$f(x_{1,367}) = \frac{1}{1+e^{-(0,822)}} = 0,305$$

$$f(x_{2,367}) = \frac{1}{1+e^{-(0,906)}} = 0,712$$

⋮

$$f(x_{23,367}) = \frac{1}{1+e^{-(0,295)}} = 0,573$$

$$f(x_{24,367}) = \frac{1}{1+e^{-(0,772)}} = 0,684$$

Maka ramalan untuk data ke 367 dalam skala *pre-processing* adalah sebagai berikut.

$$\begin{aligned}-Y_{367}^* &= 0,244 + 0,054(0,305) + 0,015(0,712) + \dots - 0,767(0,684) \\ &= 0,343\end{aligned}$$

Sehingga ramalan dalam satuan data awal (*post-processing*) adalah sebagai berikut.

$$\begin{aligned}\hat{Y}_{367} &= (0,343 \cdot 9,01) + 27,922 \\ &= 31,015\end{aligned}$$

Kemudian untuk $t = 368$ dapat diperoleh hasil sebagai berikut ini.

$$\begin{aligned}-x_{1,368} &= -0,269 + 0,208(0,338) + 0,181(-1,897) + 0,205(-0,669) \\ &\quad - 0,007(-1,233) + 0,322(0,878) - 0,606(-0,151) + 0,405(0,525) \\ &= -0,083\end{aligned}$$

$$\begin{aligned}-x_{2,368} &= -0,143 - 0,322(0,338) - 0,033(-1,897) + 0,298(-0,669) \\ &\quad + 0,224(-1,233) - 0,007(0,878) + 0,092(-0,151) - 0,395(0,525) \\ &= -0,892\end{aligned}$$

⋮

$$\begin{aligned}-x_{23,368} &= 0,562 + 0,624(0,338) + 0,707(-1,897) + 0,412(-0,669) \\ &\quad - 0,551(-1,233) + 1,058(0,878) + 0,34(-0,151) + 0,151(0,525) \\ &= 0,793\end{aligned}$$

$$\begin{aligned}-x_{24,368} &= -0,068 - 0,595(0,338) + 0,677(-1,897) - 0,096(-0,669) \\ &\quad + 0,01(-1,233) + 0,103(0,878) + 0,299(-0,151) - 0,221(0,525)\end{aligned}$$

$$-x_{24,368} = -1,572$$

$$f(x_{1,368}) = \frac{1}{1 + e^{-(0,083)}} = 0,479$$

$$f(x_{2,368}) = \frac{1}{1 + e^{-(0,892)}} = 0,291$$

⋮

$$f(x_{23,368}) = \frac{1}{1 + e^{-(0,793)}} = 0,688$$

$$f(x_{24,368}) = \frac{1}{1 + e^{(-1,572)}} = 0,172$$

Maka ramalan untuk data ke 368 dalam skala *preprocessing* adalah sebagai berikut.

$$\begin{aligned} -Y_{368}^* &= 0,244 + 0,054(0,479) + 0,015(0,291) + \dots - 0,767(0,172) \\ &= -0,362 \end{aligned}$$

Sehingga ramalan dalam satuan data awal (*post-processing*) adalah sebagai berikut.

$$\begin{aligned} \hat{Y}_{368} &= (-0,362 \cdot 9,01) + 27,922 \\ &= 24,659 \end{aligned}$$

Berikut adalah hasil peramalan permintaan golongan darah A jenis PRC dari Model FFNN (7,24,1) pada periode 1 Januari 2017 sampai 31 Januari 2017.

Tabel 4.30 Hasil Peramalan Model Terbaik Golongan Darah A

Tanggal	Ramalan	Tanggal	Ramalan	Tanggal	Ramalan
01-Jan-17	31,01	08-Jan-17	28,30	15-Jan-17	30,65
02-Jan-17	24,66	09-Jan-17	29,20	16-Jan-17	32,20
03-Jan-17	22,64	10-Jan-17	24,26	17-Jan-17	32,17
04-Jan-17	28,23	11-Jan-17	30,48	18-Jan-17	32,07
05-Jan-17	30,20	12-Jan-17	26,03	19-Jan-17	30,09
06-Jan-17	27,36	13-Jan-17	28,43	20-Jan-17	26,83
07-Jan-17	29,97	14-Jan-17	28,03	21-Jan-17	26,11

Tabel 4.30 Hasil Peramalan Model Terbaik Golongan A (*lanjutan*)

Tanggal	Ramalan	Tanggal	Ramalan	Tanggal	Ramalan
22-Jan-17	28,51	26-Jan-17	30,21	30-Jan-17	28,73
23-Jan-17	30,53	27-Jan-17	26,20	31-Jan-17	30,57
24-Jan-17	33,55	28-Jan-17	28,62		
25-Jan-17	28,91	29-Jan-17	29,82		

4.6.2 Golongan Darah B

Untuk permintaan Golongan Darah B Model Terbaik yang terpilih yaitu *Feed Forward Neural Network* dengan 10 input terdiri dari Y_{t-1} sampai Y_{t-10} dan jumlah node di *hidden layer* sebanyak 19. Berikut adalah model Terbaik yang terbentuk untuk Golongan Darah B.

Cara yang digunakan dalam melakukan peramalan pada data insample maupun untuk periode yang akan datang pada permintaan darah Golongan Darah B sama seperti pada Golongan Darah A. Oleh karena itu diperoleh hasil ramalan pada periode 1 Januari 2017 sampai 31 Januari 2017. Diperoleh hasil seperti tabel dibawah ini.

Tabel 4.31 Hasil Peramalan Model Terbaik Golongan Darah B

Tanggal	Ramalan	Tanggal	Ramalan	Tanggal	Ramalan
01-Jan-17	30,78	12-Jan-17	39,43	23-Jan-17	36,43
02-Jan-17	34,39	13-Jan-17	35,81	24-Jan-17	36,93
03-Jan-17	40,97	14-Jan-17	37,69	25-Jan-17	35,67
04-Jan-17	33,24	15-Jan-17	37,55	26-Jan-17	37,56
05-Jan-17	37,3	16-Jan-17	36,45	27-Jan-17	35,24
06-Jan-17	35,25	17-Jan-17	37,56	28-Jan-17	37,89
07-Jan-17	34,37	18-Jan-17	35,69	29-Jan-17	35,62
08-Jan-17	37	19-Jan-17	38,31	30-Jan-17	37,09
09-Jan-17	37,3	20-Jan-17	35,04	31-Jan-17	36,59
10-Jan-17	39,14	21-Jan-17	37,73		
11-Jan-17	35,26	22-Jan-17	36,13		

4.6.3 Golongan Darah AB

Untuk permintaan Golongan Darah AB Model Terbaik yang terpilih yaitu *Hybrid ARIMA-ANN* dengan Model ARIMA ([19,25],0,0) dan *Feed Forward Neural Network* dengan 10 input residual dari Model ARIMA ([19,25],0,0) yaitu a_{t-1} sampai a_{t-10} dengan jumlah node di *hidden layer* sebanyak 12. Berikut adalah model Terbaik yang terbentuk untuk Golongan Darah AB.

Untuk bentuk Model ARIMA diperoleh sebagai berikut.

$$(Y_t - \mu) = \phi_{19}(Y_{t-19} - \mu) + \phi_{25}(Y_{t-25} - \mu) + a_t$$

$$Y_t = (\mu - \phi_{19}\mu - \phi_{25}\mu) + \phi_{19}Y_{t-19} + \phi_{25}Y_{t-25} + a_t$$

$$\begin{aligned} - Y_t &= (2,928 - (-0,1553 \cdot 2,928) - (0,1249 \cdot 2,928)) - 0,1553 Y_{t-19} \\ &\quad + 0,1249 Y_{t-25} \\ &= 3,0166 - 0,1553 Y_{t-19} + 0,1249 Y_{t-25} + a_t \end{aligned}$$

Peramalan pada Model ARIMA dimulai pada $t = 26$ dengan data yang digunakan adalah hasil transformasi dari $\ln(Y_t)$ kemudian dikembalikan ke data awal dengan $\exp(Y_t^*)$.

$$\begin{aligned} - L_{26}^* &= 3,0166 - 0,1553 Y_7 + 0,1249 Y_1 \\ &= 3,0166 - 0,1553 (3,128) + 0,1249 (2,89) \\ &= 2,877 \end{aligned}$$

$$\begin{aligned} - \hat{L}_{26} &= \exp(L_{26}^*) \\ &= \exp(2,877) \end{aligned}$$

Selanjutnya setelah dikembalikan ke data awal dikurangi dengan konstanta sebesar 10 dan diperoleh hasil sebagai berikut atau seperti pada lampiran 15.

$$- \hat{L}_{26} = \exp(2,877) - 10$$

$$- \hat{L}_{26} = 7,774$$

Selanjutnya untuk Model *Hybrid ARIMA-ANN* peramalan diawali pada $t = 36$, hal tersebut dilakukan karena nilai residual pada saat $t = 26$ dijadikan 10 lag untuk variabel input yang terdiri dari a_{t-1} sampai a_{t-10} seperti yang terlihat pada lampiran 16.

$$- L_{36}^* = 3,0166 - 0,1553 Y_{17} + 0,1249 Y_{11}$$

$$- L_{36}^* = 3,0166 - 0,1553(2,565) + 0,1249(3,332)$$

$$= 3,034$$

$$- \hat{L}_{36} = \exp(3,034) - 10$$

$$= 10,789$$

Hasil residual yang diperoleh dari Model ARIMA kemudian dilakukan peramalan untuk insample dengan 10 input yaitu $a_{t-1} - a_{t-10}$, sehingga data residual yang digunakan adalah residual saat $t = 36$.

$$- x_{1,36} = 0,114 - 0,840(-0,829) - 1,233(0,551) + 0,161(2,002)$$

$$- 0,069(0,105) - 1,832(-0,994) - 1,806(0,623) - 1,169(-0,822)$$

$$- 1,124(2,194) + 1,087(2,375) + 0,793(0,121)$$

$$= 2,315$$

$$- x_{2,36} = 0,156 - 0,031(-0,829) + 0,242(0,551) + 0,192(2,002)$$

$$- 0,101(0,105) + 1,078(-0,994) - 1,347(0,623) - 1,132(-0,822)$$

$$+ 0,086(2,194) - 0,415(2,375) + 0,061(0,121)$$

$$= -1,08$$

$$\vdots$$

$$- x_{11,36} = -1,831 + 0,444(-0,829) - 0,113(0,551) + 0,253(2,002)$$

$$+ 0,679(0,105) + 0,144(-0,994) - 2,62(0,623) + 0,348(-0,822)$$

$$+ 0,113(2,194) + 1,143(2,375) + 1,148(0,121)$$

$$= -0,641$$

$$- x_{12,36} = -1,366 + 1,064(-0,829) + 1,507(0,551) + 0,497(2,002)$$

$$+ 0,11(0,105) - 0,564(-0,994) + 2,632(0,623) + 0,849(-0,822)$$

$$+ 0,51(2,194) + 1,413(2,375) - 0,458(0,121)$$

$$= 5,512$$

$$f(x_{1,36}) = \frac{1}{1 + e^{-(2,315)}} = 0,91$$

$$f(x_{2,36}) = \frac{1}{1 + e^{(-1,08)}} = 0,254$$

$$\vdots$$

$$f(x_{11,36}) = \frac{1}{1 + e^{(-0,641)}} = 0,345$$

$$f(x_{12,36}) = \frac{1}{1+e^{-(5,512)}} = 0,996$$

$$\begin{aligned} -NL_{36}^* &= 0,075 + 1,941(0,91) + 0,914(0,254) + \dots + 1,752(0,996) \\ &= 0,069 \\ -\bar{NL}_{36} &= ((NL_{36}^* S_a) + \bar{a}) \\ &= (0,069 \cdot 5,006) + 0,576 \\ &= 0,925 \end{aligned}$$

Kemudian menjumlahkan hasil peramalan yang didapatkan dari model ARIMA (\hat{L}_t) dan residual dari model *neural network* ($N\hat{L}_t$) dengan arsitektur FFNN .

$$\begin{aligned} -\hat{Y}_{36} &= \hat{L}_{36} + \bar{NL}_{36} \\ &= 10,789 + 0,925 \\ &= 11,714 \end{aligned}$$

Dilakukan peramalan untuk periode yang akan datang yaitu pada saat $t = 367$ dan $t = 368$, diperoleh hasil sebagai berikut.

$$\begin{aligned} -L_{367}^* &= 3,0166 - 0,1553 Y_{348} + 0,1249 Y_{342} \\ &= 3,0166 - 0,1553(3,091) + 0,1249(2,996) \\ &= 2,911 \\ -\hat{L}_{367} &= \exp(2,911) - 10 \\ &= 8,37 \end{aligned}$$

Kemudian untuk peramalan pada residual $t = 367$

$$\begin{aligned} -x_{1,367} &= 0,114 - 0,840(-0,973) - 1,233(-1,473) + 0,161(1,982) \\ &= -0,069(1,449) - 1,832(-1,761) - 1,806(-0,899) - 1,169(-0,36) \\ &= -1,124(0,464) + 1,087(1,199) + 0,793(2,239) \\ &= 10,795 \\ \vdots \\ -x_{12,367} &= -1,366 + 1,064(-0,973) + 1,507(-1,473) + 0,497(1,982) \\ &= +0,11(1,449) - 0,564(-1,761) + 2,632(-0,899) + 0,849(-0,36) \\ &= +0,51(0,464) + 1,413(1,199) - 0,458(2,239) \\ &= -4,2464 \end{aligned}$$

$$f(x_{1,367}) = \frac{1}{1+e^{-(10,795)}} = 0,999$$

⋮

$$f(x_{12,367}) = \frac{1}{1+e^{(-4,246)}} = 0,014$$

$$\begin{aligned} -NL_{367}^* &= 0,075 + 1,941(0,999) + \dots + 1,752(0,014) \\ &= 0,069 \end{aligned}$$

$$-\hat{NL}_{367} = (0,069 \cdot 5,006) + 0,576 = -9,19$$

Kemudian menjumlahkan hasil ramalan yang diperoleh dari Model ARIMA dan residual dari *neural network*.

$$\begin{aligned} -\hat{Y}_{367} &= \hat{L}_{367} + \hat{NL}_{367} \\ &= 8,37 + (-9,19) \\ &= -0,819 \end{aligned}$$

Selanjutnya untuk $t = 368$ diperoleh hasil sebagai berikut.

$$\begin{aligned} -L_{368}^* &= 3,0166 - 0,1553 Y_{349} + 0,1249 Y_{343} \\ &= 3,0166 - 0,1553(2,833) + 0,1249(3,091) \\ &= 2,963 \end{aligned}$$

$$\begin{aligned} -\hat{L}_{368} &= \exp(2,963) - 10 \\ &= 9,349 \end{aligned}$$

Untuk peramalan pada residual $t = 368$ dengan menggunakan *Neural Network* diperoleh hasil sebagai berikut.

$$\begin{aligned} -x_{1,368} &= 0,114 - 0,840(-1,952) - 1,233(-0,982) + 0,161(-1,473) \\ &\quad - 0,069(1,992) - 1,832(1,452) - 1,806(-1,766) - 1,169(-0,896) \\ &\quad - 1,124(-0,363) + 1,087(0,457) + 0,793(1,215) \\ &= 6,036 \end{aligned}$$

⋮

$$\begin{aligned} -x_{12,368} &= -1,366 + 1,064(-1,952) + 1,507(-0,982) + 0,497(-1,473) \\ &\quad + 0,11(1,992) - 0,564(1,452) + 2,632(-1,766) + 0,849(-0,896) \\ &\quad + 0,51(-0,363) + 1,413(0,457) - 0,458(1,215) \end{aligned}$$

$$- x_{12,368} = -11,759$$

$$f(x_{1,368}) = \frac{1}{1+e^{-(6,036)}} = 0,998$$

⋮

$$f(x_{12,368}) = \frac{1}{1+e^{-(-11,759)}} = 0,000$$

$$\begin{aligned} - NL_{368}^* &= 0,075 + 1,941(0,998) + \dots + 1,752(0,000) \\ &= 1,151 \end{aligned}$$

$$\begin{aligned} - \hat{NL}_{368} &= ((a_{367}^* S) + \bar{a}) \\ &= (1,151 \cdot 5,006) + 0,576 = 6,338 \end{aligned}$$

Kemudian menjumlahkan hasil ramalan yang diperoleh dari Model ARIMA dan residual dari *neural network*.

$$\begin{aligned} - \hat{Y}_{368} &= \hat{L}_{368} + \hat{NL}_{368} \\ &= 9,349 + (6,338) = 15,687 \end{aligned}$$

Tabel 4.32 Hasil Peramalan Model Terbaik Golongan Darah AB

Tanggal	Ramalan	Tanggal	Ramalan	Tanggal	Ramalan
01-Jan-17	0	12-Jan-17	7,12	23-Jan-17	10,01
02-Jan-17	15,69	13-Jan-17	11,70	24-Jan-17	10,23
03-Jan-17	7,98	14-Jan-17	9,17	25-Jan-17	8,38
04-Jan-17	10,79	15-Jan-17	14,69	26-Jan-17	10,61
05-Jan-17	5,45	16-Jan-17	9,74	27-Jan-17	9,37
06-Jan-17	12,53	17-Jan-17	9,32	28-Jan-17	8,45
07-Jan-17	7,68	18-Jan-17	10,42	29-Jan-17	8,97
08-Jan-17	7,28	19-Jan-17	7,68	30-Jan-17	8,45
09-Jan-17	7,92	20-Jan-17	8,69	31-Jan-17	11,17
10-Jan-17	3,78	21-Jan-17	6,67		
11-Jan-17	8,72	22-Jan-17	11,58		

Tabel 4.33 menunjukkan hasil untuk peramalan pada saat $t = 369$ sampai dengan $t = 397$ atau hasil peramalan untuk periode 1 Januari 2017 sampai 31 Januari 2017.

4.6.4 Golongan Darah O

Untuk permintaan Golongan Darah B Model Terbaik yang terpilih yaitu *Feed Forward Neural Network* dengan 8 input terdiri dari Y_{t-1} , Y_{t-2} , Y_{t-7} , Y_{t-10} , Y_{t-14} , Y_{t-6} , Y_{t-19} , Y_{t-29} dan jumlah node di *hidden layer* sebanyak 25.

Cara yang digunakan dalam melakukan peramalan pada data insample maupun untuk periode yang akan datang pada permintaan darah Golongan Darah O sama seperti pada Golongan Darah A ataupun Golongan Darah B. Oleh karena itu didapatkan hasil ramalan pada periode 1 Januari 2017 sampai 31 Januari 2017 seperti Tabel 4.33.

Tabel 4.33 Hasil Peramalan Model Terbaik Golongan Darah O

Tanggal	Ramalan	Tanggal	Ramalan
01-Jan-17	49,14	17-Jan-17	56,95
02-Jan-17	56,57	18-Jan-17	54,95
03-Jan-17	55,82	19-Jan-17	53,79
04-Jan-17	56,41	20-Jan-17	49,65
05-Jan-17	49,41	21-Jan-17	53,78
06-Jan-17	44,03	22-Jan-17	54,77
07-Jan-17	43,28	23-Jan-17	57,85
08-Jan-17	46,38	24-Jan-17	56,9
09-Jan-17	52,77	25-Jan-17	51,3
10-Jan-17	55,43	26-Jan-17	48,59
11-Jan-17	52,52	27-Jan-17	47,29
12-Jan-17	47,51	28-Jan-17	49,63
13-Jan-17	45,38	29-Jan-17	50,96
14-Jan-17	48,09	30-Jan-17	53,28
15-Jan-17	54,76	31-Jan-17	51,55
16-Jan-17	55,47		

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis dan pembahasan pada penelitian mengenai peramalan permintaan darah jenis PRC di PMI Kota Surabaya adalah sebagai berikut.

1. Rata-rata permintaan darah jenis PRC di tahun 2016 menunjukkan bahwa bulan Januari memiliki rata-rata permintaan terbanyak sedangkan rata-rata permintaan harian terbanyak selama tahun 2016 terdapat pada hari Minggu..
2. Model NN merupakan model terbaik yang digunakan untuk melakukan peramalan pada permintaan darah jenis PRC pada setiap Golongan Darah kecuali Golongan Darah AB. Model *Hybrid* merupakan model terbaik untuk Golongan Darah AB.
3. Pada Golongan Darah A Model yang terbaik yaitu Model FFNN (7,24,1) dengan 7 variabel input yang terdiri dari Y_{t-1} , Y_{t-2} , Y_{t-3} , Y_{t-5} , Y_{t-26} , Y_{t-41} dan Y_{t-44} dengan jumlah node sebanyak 24 di *hidden layer* serta output *layer* sebanyak 1.
4. Pada Golongan Darah B Model yang terbaik yaitu Model FFNN (10,19,1) dengan 10 variabel input yang terdiri dari Y_{t-1} sampai Y_{t-10} dengan jumlah node sebanyak 19 di *hidden layer* serta output *layer* sebanyak 1.
5. Pada Golongan Darah AB Model yang terbaik yaitu Model *Hybrid ARIMA*([19,25],0,0)-FFNN(10,12,1). Model FFNN dengan 10 variabel input yang diperoleh dari residual Model ARIMA([19,25],0,0) terdiri dari a_{t-1} sampai a_{t-10} dengan jumlah node sebanyak 12 di *hidden layer* serta output *layer* sebanyak 1
6. Pada Golongan Darah O Model yang terbaik yaitu Model FFNN (8,25,1) dengan 7 variabel input yang terdiri dari Y_{t-1} , Y_{t-2} , Y_{t-7} , Y_{t-10} , Y_{t-14} , Y_{t-16} , Y_{t-19} dan Y_{t-29} dengan jumlah node sebanyak 25 di *hidden layer* serta output *layer* berjumlah 1.

5.2 Saran

Saran yang dapat diberikan peneliti yaitu dalam melakukan pemilihan input Neural Network, sebaiknya dapat mencoba melakukan pemilihan lag yang lain, serta mencoba melakukan transformasi data selain *standardized*. Sedangkan untuk pihak PMI, dalam melakukan peramalan untuk periode yang akan datang dapat menggunakan model yang diperoleh dari masing-masing golongan darah. Saran yang diberikan untuk mahasiswa yang akan melakukan analisis peramalan yaitu lebih baik meminta data *real* pada data yang akan diramalkan sejak awal pengambilan data. Sehingga dapat melakukan pengecekan antara data *real* terhadap data hasil ramalan.

DAFTAR PUSTAKA

- Allen, A. O., & Rheinboldt, W. (1978). *Probability, Statistics, and Queueing Theory*. New York: Academic Press, Inc.
- Benoist, B. d., & McLean, E. (2008). *Worldwide prevalence of Anemia 1993–2005 : who Global database on anaemia*. Spain: WHO Press.
- Bowerman, B., O'connell, R., & Koehler, A. (2005). *Forecasting, Time Series, and Regression (Fourth Edition)*. USA: Thomson Brooks/Cole.
- Box, G. E., & Jenkins, G. M. (2015). *Time Series Analysis Forecasting and Control* (5th ed.). New Jersey: John Wiley & Sons, Inc .
- Fajar, R. (2016, Maret 16). *Kurangi Angka Anemia Dengan Kampanye Indonesia Bebas Anemia*. Retrieved from 1 Health: <http://www.1health.id/id/article/category/sehat-a-z/kurangi-angka-anemia-dengan-kampanye-indonesia-bebas-anemia.html>
- Fausett, L. (1994). *Fundamental of Neural Network: Architectures, Algorithm and Appcalions*. USA: Prantice Hall.
- Febriana, W. E. (2010). *Analisis Banyaknya Perminta-an Darah di Surabaya menggunakan metode ARIMA Box-Jenkins*. Surabaya: ITS.
- Fithriasari, K., Iriawan, N., Ulama, B. S., & Sutikno. (2013). On The Multivariate Time Series Rainfall Modeling Using Time Delay Neural Network. International Journal of Applied Mathematics and Statistics, 44(14), 193-201.
- Fithriasari, K., Iriawan, N., Ulama, B. S., Sutikno, & Kuswanto, H. (2013). Prediction of Hourly Rainfall using Bayesian Neural with Adjusting Procedure. The Third Basic Science International Conference, 1-5.
- Kristianda, F., & Fithriasari, K. (2016). Peramalan Curah Hujan di Wilayah Surabaya Timur dengan Vector

- Autoregressive Neural. *Jurnal Sains dan Seni ITS*, 5, 175-180.
- Makridakis, S., Wheelwright, S. C., & McGee, V. E. (1999). *Metode dan Aplikasi Peramalan*. Alih Bahasa: Untung Sus Andriyanto, & Abdul Basith, Jakarta: PT. Gelora Aksara Pratama.
- Marganti, M. (2016, Maret 22). *Alasan Pentingnya Donor Darah*. Retrieved Oktober 8, 2016, from <http://www.1health.id/id/article/category/healthy-life/alasan-di-balik-pentingnya-donor-darah-84.html>
- Muhlisin, D. (2017). *Penyakit Anemia – Pengertian, Penyebab, dan Gejala*. Retrieved from Mediskus: <https://mediskus.com/penyakit/anemia-pengertian-penyebab-dan-gejala-anemia>
- Nurwawati, R. (2016, Juni 8). *Berita Surabaya : PMI Surabaya Jaga Stok Darah dengan Datangi Sekolah, Perusahaan dan Masjid*. Retrieved November 1, 2016, from <http://surabaya.tribunnews.com/2016/06/08/pmi-surabaya-jaga-stok-darah-dengan-datangi-sekolah-perusahaan-dan-masjid>
- Parag, S., Mousumi, R., & Parimal, P. (2016). Application of ARIMA for forecasting energy consumption and GHG. *Elsevier*, 1032 - 1038. doi:10.1016/j.energy.2016.10.068
- PMI. (2013, September 8). *Palang Merah Indonesia*. Retrieved from <http://www.pmi.or.id/index.php/aktivitas/pelayanan/donor-darah/donor-sekarang.html?showall=&limitstart=1>
- PMI. (2015, September 20). *Donor Darah*. Retrieved Oktober 25, 2016, from Wikipedia: https://id.wikipedia.org/wiki/Donor_darah
- Red Cross Blood. (2016). *American Red Cross : Blood Components*. Retrieved November 1, 2016, from <http://www.redcrossblood.org/learn-about-blood/blood-components>
- Riskesdas. (2013). *Riset Kesehatan Dasar*. Jakarta: Badan Litbangkes, Depkes RI.

- Sari M.Si, Y. (2015, November 25). *Fungsi Hemoglobin Pada Sel Darah Merah*. Retrieved from <http://dosenbiologi.com/manusia/fungsihemoglobin>
- Sarle, W. S. (1994). Neural Networks and Statistical Models. *Proceedings of the Nineteenth Annual SAS Users Group International Conference*, 13. doi:10.1.1.27. 699
- Terasvirta, T., Lin, C.-F., & Granger, W. C. (1993). Power of the Neural Network Linearity Test. *Journal of Time Series Analysis*, 14(2), 209-220. doi:10.1111/j.14679892.1993.tb00139.x
- Wei, W. W. (2006). *Time Series Analysis : Univariate and Multivariate Methods*. Boston : Pearson: Addison Wesley.
- Zahrati, Z., Fithriasari, K., & Irhamah. (2016). Multi-output neural network for the temperature forecasting in Semarang. American Institute of Physics, 1-7. doi:10.1063/1.4953965
- Zhang, G. P. (2004). *Neural Networks in Business Forecasting*. Hershey USA: Idea Group Inc.
- Zhang, G. P., & Qi, M. (2005). Neural network forecasting for seasonal and trend time series. *European Journal of Operational Research*, 501-514. doi:10.1016/j.ejor.2003.08.037

(Halaman Ini Sengaja Dikosongkan)

LAMPIRAN

Lampiran 1. Struktur Data Permintaan Darah Jenis PRC

t	tanggal	A	B	AB	O
1	01-Jan	24	17	8	34
2	02-Jan	35	45	1	60
3	03-Jan	24	38	8	52
4	04-Jan	29	62	13	71
5	05-Jan	43	52	16	84
6	06-Jan	28	32	4	83
7	07-Jan	32	66	15	99
:	:	:	:	:	:
360	25-Des	22	19	8	34
361	26-Des	35	32	4	44
362	27-Des	27	53	0	72
363	28-Des	17	48	16	64
364	29-Des	39	42	19	54
365	30-Des	22	38	1	49
366	31-Des	11	29	4	59

Lampiran 2. Syntax ARIMA di R

```
data =read.csv("darah.csv")
datatrans=read.csv("darahtrans.csv")
datatrans1=read.csv("darahtrans1.csv")
data1=as.ts(data[,5])
data2=as.ts(datatrans[,4])
data3=as.ts(datatrans1[,4])
data.train=data1[1:335]
data.test=data1[336:366]
#tanpa subset
aa=arima(data2,c(2,0,2),include.mean = FALSE, method =
```

Lampiran 2. Syntax ARIMA di R (*lanjutan*)

```
c("CSS"))
#(subset)
aa=arima(data2,c(14,0,0),include.mean = FALSE, method =
c("CSS"),fixed=c(NA,0,0,0,0,0,0,NA,0,0,0,0,NA))
#insample
fits=(data2-aa$residuals)^2
rmse.in = sqrt(mean((data.train-fits)^2))
#outsample
newfit <- Arima(c(data2,data3), model=aa)
onestep.for <- fitted(newfit)[336:366]
ramal=predict(aa,n.ahead=31)
ramal2=(ramal$pred)^2
rmse.out=sqrt(mean((data.test-ramal2)^2))
aa
cbind(rmse.in,rmse.out)
(1-pnorm(abs(aa$coef)/sqrt(diag(aa$var.coef))))*2
ks.test(aa$residuals,"pnorm",mean(aa$residuals),
sd(aa$residuals))
Box.test((data.train-fits), lag=48)
pacf((data.train-fits),lag=31)
pacf(aa$residuals,lag=70)
(1-pnorm(abs(aa$coef)/sqrt(diag(aa$var.coef))))*2
#manual
(1-pnorm(0.3514/0.0522))*2
#save data
pred=c(fits,ramal2)
residual=c((data.train-fits),(data.test-ramal2))
write.csv(pred,file="predgolonew(1,0,1).csv")
write.csv(residual,file="resigolonew(1,0,1).csv")
```

Lampiran 3. Estimasi Parameter ARIMA Golongan Darah A

ARIMA	Parameter	Coef	SE Coef	P-value
(2,0,1)	Intercept	5,2558	0,0747	0,0000
	AR 1	0,5447	0,1504	0,0003
	AR 2	0,1323	0,0634	0,0369
	MA 1	-0,4625	0,1454	0,0015
(1,0,2)	Intercept	5,2606	0,0735	0,0000
	AR 1	0,6610	0,1111	0,0000
	MA 1	-0,5980	0,1149	0,0000
	MA 2	0,1549	0,0640	0,0156
(1,0,1)	Intercept	5,2606	0,0732	0,0000
	AR 1	0,7619	0,0872	0,0000
	MA 1	-0,6149	0,0996	0,0000
([2],0,[2])	Intercept	5,2583	0,0621	0,0000
	AR 2	0,5147	0,1580	0,0011
	MA 2	-0,3350	0,1687	0,0471
([2],0,[1,2])	Intercept	5,2580	0,0728	0,0000
	AR 2	0,5514	0,1377	0,0000
	MA 1	0,1082	0,0494	0,0285
	MA 2	-0,3828	0,1428	0,0073

Lampiran 4. Estimasi Parameter ARIMA Golongan Darah B

ARIMA	Parameter	Coef	SE Coef	P-value
(1,0,1)	AR 1	1,0000	0,0011	0,0000
	MA 1	-0,7624	0,0397	0,0000
(1,0,0)	Intercept	3,6418	0,0194	0,0000
	AR 1	0,1783	0,0532	0,0007
(0,0,1)	Intercept	3,6384	0,0188	0,0000
	MA 1	0,1688	0,0517	0,0011
	Intercept	3,6286	0,0187	0,0000
([1,9,14],0,0)	AR1	0,1590	0,0531	0,0027
	AR9	-0,1222	0,0523	0,0194
	AR14	0,1354	0,0517	0,0088

Lampiran 5. Estimasi Parameter ARIMA Golongan Darah AB

ARIMA	Parameter	Coef	SE Coef	P-value
([10],0,0)	Intercept	2,9282	0,0129	0,0000
	AR 10	-0,1145	0,0545	0,0356
([19],0,0)	Intercept	2,9252	0,0126	0,0000
	AR 19	-0,1413	0,0544	0,0009
([10,19],0,0)	Intercept	2,9254	0,0115	0,0000
	AR10	-0,1025	0,0539	0,0572
	AR19	-0,1380	0,0542	0,0108
([19,25],0,0)	Intercept	2,9264	0,0138	0,0000
	AR19	-0,1420	0,0545	0,0009
	AR25	0,1081	0,0542	0,0046

Lampiran 6. Estimasi Parameter ARIMA Golongan Darah O

ARIMA	Parameter	Coef	SE Coef	P-value
(2,0,1)	AR 1	1,1525	0,0532	0,0000
	AR 2	-0,1528	0,0532	0,0041
	MA 1	-0,9494	0,0000	0,0000
(1,0,2)	AR 1	1,0001	0,0012	0,0000
	MA 1	-0,7442	0,0504	0,0000
	MA 2	-0,0798	0,0516	0,1218
(1,0,1)	Intercept	7,3017	0,0753	0,0000
	AR 1	0,6030	0,1293	0,0000
	MA 1	-0,3812	0,1412	0,0000
(2,0,2)	AR 1	1,1994	0,1191	0,0000
	AR 2	-0,1997	0,1191	0,0935
	MA 1	-0,9988	0,1149	0,0000
	MA 2	0,0520	0,1183	0,6601

Lampiran 7. Estimasi Parameter ARIMA Golongan Darah AB untuk peramalan Hybrid

ARIMA	Parameter	Coef	SE Coef	P-value
([19,25],0,0)	Intercept	2,9276	0,0134	0,0000
	AR19	-0,1553	0,0527	0,0009
	AR25	0,1249	0,0524	0,0046

Model yang terbentuk

$$(y_t - \mu) = \phi_{19}(y_{t-19} - \mu) + \phi_{25}(y_{t-25} - \mu) + a_t$$

$$y_t = (\mu - \phi_{19}\mu - \phi_{25}\mu) + \phi_{19}y_{t-19} + \phi_{25}y_{t-25} + a_t$$

Lampiran 8. Residual Normal ARIMA

Golongan Darah	ARIMA	KS	P-value	Keputusan
A	(2,0,1)	0,036	0,7914	Normal
	(1,0,2)	0,036	0,7901	Normal
	(1,0,1)	0,039	0,6636	Normal
	([2],0,[2])	0,036	0,7715	Normal
B	([2],0,[1,2])	0,038	0,7083	Normal
	(1,0,1)	0,026	0,9737	Normal
	(1,0,0)	0,028	0,9485	Normal
	(0,0,1)	0,029	0,9367	Normal
AB	([1,9,14],0,0)	0,032	0,8681	Normal
	([10],0,0)	0,033	0,8481	Normal
	([19],0,0)	0,036	0,7547	Normal
O	([19,25],0,0)	0,042	0,59	Normal
	(2,0,1)	0,037	0,7277	Normal
	(1,0,1)	0,027	0,9671	Normal
	(2,0,2)	0,038	0,7050	Normal

Lampiran 9. Residual White Noise ARIMA

Golongan	ARIMA	Lag	X ²	df	P-value	Keputusan
A	(2,0,1)	6	9,5491	2	0,008	Tidak White Noise
		12	20,335	8	0,009	
		24	37,393	20	0,011	
		36	50,017	32	0,022	
		48	74,751	44	0,002	
	(1,0,2)	6	8,3246	2	0,015	Tidak White Noise
		12	18,533	8	0,017	
		24	35,792	20	0,016	
		36	48,399	32	0,031	
		48	73,446	44	0,003	

Lampiran 9. Residual White Noise ARIMA (*lanjutan*)

		6	11,921	3	0,007	
		12	21,516	9	0,011	
	(1,0,1)	24	39,946	21	0,007	Tidak
		36	50,09	33	0,028	White Noise
		48	72,699	45	0,005	
A		6	15,166	3	0,001	
		12	27,803	9	0,001	
	([2],0,[2])	24	46,193	21	0,001	Tidak
		36	58,642	33	0,003	White Noise
		48	84,136	45	0,000	
		6	4,6461	4	0,325	
		12	22,939	10	0,011	
	(1,0,1)	24	39,178	22	0,013	Tidak
		36	50,715	34	0,032	White Noise
		48	58,256	46	0,106	
B		6	6,077	4	0,193	
		12	17,724	10	0,059	
	(1,0,0)	24	32,757	22	0,065	White Noise
		36	47,741	34	0,059	
		48	54,104	46	0,192	
		6	6,0797	4	0,193	
		12	18,184	10	0,051	
	(0,0,1)	24	31,027	22	0,095	White Noise
		36	43,994	34	0,117	
		48	48,792	46	0,361	
		6	6,1697	2	0,045	
		12	16,767	8	0,032	
	([1,9,14],0,0)	24	26,255	20	0,157	White Noise
		36	42,154	32	0,108	
		48	50,666	44	0,227	
AB		6	5,1533	4	0,271	
		12	8,2449	10	0,604	
	([10],0,0)	24	23,524	22	0,372	White Noise
		36	39,928	34	0,223	
		48	56,929	46	0,129	

Lampiran 9. Residual White Noise ARIMA (*lanjutan*)

	6	4,8802	4	0,299	
	12	9,5889	10	0,477	
([19],0,0)	24	19,385	22	0,621	White Noise
	36	35,582	34	0,393	
AB	48	55,135	46	0,167	
	6	5,7898	3	0,122	
	12	9,9602	9	0,353	
([19,25],0,0)	24	20,877	21	0,466	White Noise
	36	34,047	33	0,417	
	48	52,488	45	0,206	
	6	4,8705	3	0,181	
	12	16,191	9	0,063	
(2,0,1)	24	27,759	21	0,147	Tidak
	36	49,908	33	0,029	White Noise
O	48	54,917	45	0,147	
	6	2,5307	3	0,469	
	12	14,906	9	0,093	
(1,0,1)	24	27,256	21	0,162	
	36	46,342	33	0,061	White Noise
	48	51,19	45	0,243	

Lampiran 10. Uji Teraesvirta

```
library (tseries)
data = read.csv("darah.csv")
j=10
y=data[1:335,5]
Yt=y[(j+1):335]
a=matrix(0,nrow=335-j,ncol=j)
#untuk input 10
for (i in 1:j){
  yti=y[(j-i+1):(335-i)]
  a[,i]=yti
}
uji=terasvirta.test(a,Yt)
uji
```

Lampiran 10. Uji Teraesvirta (*lanjutan*)

```
#untuk beberapa input
Yt=y[(29+1):335]
Yt1=y[29:334]
Yt2=y[(29-2+1):(335-2)]
Yt7=y[(29-7+1):(335-7)]
Yt10=y[(29-10+1):(335-10)]
Yt14=y[(29-14+1):(335-14)]
Yt16=y[(29-16+1):(335-16)]
Yt19=y[(29-19+1):(335-19)]
Yt29=y[1:(335-29)]
X=cbind(Yt1,Yt2,Yt7,Yt19,Yt29,Yt10,Yt14,Yt16)
uji=terasvirta.test(X,Yt)
uji
```

Lampiran 11. Syntax FFNN 10 input di SPSS

```
set seed 1.
DATASET ACTIVATE DataSet0.
*Multilayer Perceptron Network.
MLP y (MLEVEL=S) WITH y1 y2 y3 y4 y5 y6 y7 y8 y9 y10
/RESCALE COVARIATE=STANDARDIZED
DEPENDENT=STANDARDIZED
/PARTITION VARIABLE=kode
/ARCHITECTURE AUTOMATIC=NO HIDDENLAYERS=1
(NUMUNITS=1) HIDDENFUNCTION=SIGMOID
    OUTPUTFUNCTION=IDENTITY
/CRITERIA TRAINING=BATCH
OPTIMIZATION=SCALEDCONJUGATE
LAMBDAINITIAL=0.0000005
    SIGMAINITIAL=0.00005 INTERVALCENTER=0
INTERVALOFFSET=0.5 MEMSIZE=1000
/PRINT CPS NETWORKINFO SUMMARY SOLUTION
/PLOT NETWORK /SAVE PREDVAL
```

Lampiran 11. Syntax FFNN 10 input di SPSS (*lanjutan*)

```
/STOPPINGRULES ERRORSTEPS= 1 (DATA=AUTO)
TRAININGTIMER=ON (MAXTIME=15)
MAXEPOCHS=AUTO
    ERRORCHANGE=1.0E-4 ERRORRATIO=0.0010
/MISSING USERMISSING=EXCLUDE .
:
set seed 1.
MLP y (MLEVEL=S) WITH y1 y2 y3 y4 y5 y6 y7 y8 y9 y10
/RESCALE COVARIATE=STANDARDIZED
DEPENDENT=STANDARDIZED
/PARTITION VARIABLE=kode
/ARCHITECTURE AUTOMATIC=NO HIDDENLAYERS=1
(NUMUNITS=25) HIDDENFUNCTION=SIGMOID
    OUTPUTFUNCTION=IDENTITY
/CRITERIA TRAINING=BATCH
OPTIMIZATION=SCALEDCONJUGATE
LAMBDAINITIAL=0.000005
    SIGMAINITIAL=0.00005 INTERVALCENTER=0
INTERVALOFFSET=0.5 MEMSIZE=1000
/PRINT CPS NETWORKINFO SUMMARY SOLUTION
/PLOT NETWORK /SAVE PREDVAL
/STOPPINGRULES ERRORSTEPS= 1 (DATA=AUTO)
TRAININGTIMER=ON (MAXTIME=15)
MAXEPOCHS=AUTO
    ERRORCHANGE=1.0E-4 ERRORRATIO=0.0010
/MISSING USERMISSING=EXCLUDE .
```

Lampiran 12. Struktur Data FFNN Golongan Darah A

t	Y	Y _{t-1}	Y _{t-2}	Y _{t-3}	Y _{t-5}	Y _{t-26}	Y _{t-41}	Y _{t-44}
1	24							
2	35	24						
3	24	35	24					
4	29	24	35	24				
5	43	29	24	35				
6	28	43	29	24				
7	32	28	43	29	24			
8	36	32	28	43	35			
⋮	⋮	⋮	⋮	⋮	⋮			
44	30	41	26	36	34	30	24	
45	22	30	41	26	23	34	29	24
46	31	22	30	41	36	25	43	35
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
365	22	39	17	27	22	21	33	23
366	11	22	39	17	35	23	39	27
367	31,015	11	22	39	27	33	35	28
368		31,015	11	22	17	36	27	33

Data yang digunakan untuk pengujian FFNN adalah saat $t = 45$ sampai $t = 366$. Sedangkan untuk $t = 367$ dan $t = 368$ digunakan sebagai peramalan untuk periode Januari 2017.

Lampiran 13. Standardized Golongan Darah A

t	Z _{t-1}	Z _{t-2}	Z _{t-3}	Z _{t-5}	Z _{t-26}	Z _{t-41}	Z _{t-44}
11	0,225	1,443	-0,223	-0,563	0,654	0,072	-0,480
12	-0,668	0,218	1,451	0,888	-0,354	1,635	0,749
13	0,337	-0,672	0,223	-0,229	0,878	-0,039	-0,480
14	1,341	0,329	-0,669	1,446	1,551	0,407	0,078
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
366	-0,668	1,220	-1,227	0,776	-0,578	1,189	-0,145
367	-1,895	-0,672	1,227	-0,117	0,542	0,742	-0,033
368	0,339	-1,897	-0,669	-1,233	0,878	-0,151	0,525

Lampiran 14. Hasil Ramalan Golongan Darah A

t	Y	\hat{Y}
45	22	31,10
46	31	29,42
47	40	30,32
⋮	⋮	⋮
365	22	30,30
366	11	27,91
367		31,01
368		24,66

Lampiran 15. Hasil Ramalan Model ARIMA Golongan Darah AB

t	Y	\hat{Y}	a _t
1	8	8	
2	1	1	
3	8	8	
4	13	13	
⋮	⋮	⋮	
24	11	11	
25	6	6	
26	9	7,774	1,225
27	20	7,44	12,558
28	20	8,401	11,599
29	6	9,458	-3,458
30	12	8,285	3,715
31	3	7,335	-4,335
32	10	8,89	1,109
⋮	⋮	⋮	⋮
363	16	8,196	7,804
364	19	8,462	10,538
365	1	7,743	-6,743
366	4	8,289	-4,288

Lampiran 16. Residual Model ARIMA Golongan Darah AB

t	a _t	a _{t-1}	a _{t-2}	a _{t-3}	a _{t-4}	a _{t-5}	a _{t-6}	a _{t-7}	a _{t-8}	a _{t-9}	a _{t-10}
1											
2											
⋮											
26	1,23										
27	12,6	1,23									
28	11,6	12,6	1,23								
29	-3,46	11,6	12,6	1,23							
30	3,71	-3,46	11,6	12,6	1,23						
31	-4,33	3,71	-3,46	11,6	12,6	1,23					
32	1,11	-4,33	3,71	-3,46	11,6	12,6	1,23				
33	10,6	1,11	-4,33	3,71	-3,46	11,6	12,6	1,23			
34	3,36	10,6	1,11	-4,33	3,71	-3,46	11,6	12,6	1,23		
35	-3,57	3,36	10,6	1,11	-4,33	3,71	-3,46	11,6	12,6	1,23	
36	6,21	-3,57	3,36	10,0	1,11	-4,33	3,71	-3,46	11,6	12,6	1,23
37	0,07	6,21	-3,57	3,36	10,60	1,11	-4,33	3,71	-3,46	11,6	12,6
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
365	-6,74	10,5	7,80	-8,13	-3,83	-1,17	2,96	6,69	11,8	15,4	0,,45
366	-4,29	-6,74	10,50	7,80	-8,13	-3,83	-1,17	2,96	6,69	11,80	15,40
367	-9,19	-4,29	-6,74	10,50	7,80	-8,13	-3,83	-1,17	2,96	6,69	11,80
368		-9,19	-4,29	-6,74	10,50	7,80	-8,13	-3,83	-1,17	2,96	6,69

Lampiran 17. Estimasi Parameter Model Terbaik Golongan Darah A

Lampiran 18. Estimasi Parameter Model Terbaik Golongan Darah B

Punkt	Name	Lage	Höhe	Wert		Bemerkung
				Wert	Einheit	
1	1551					
	1552					
	1553					
	1554					
	1555					
	1556					
	1557					
	1558					
	1559					
	1560					
	1561					
	1562					
	1563					
	1564					
	1565					
	1566					
	1567					
	1568					
	1569					
	1570					
	1571					
	1572					
	1573					
	1574					
	1575					
	1576					
	1577					
	1578					
	1579					
	1580					
	1581					
	1582					
	1583					
	1584					
	1585					
	1586					
	1587					
	1588					
	1589					
	1590					
	1591					
	1592					
	1593					
	1594					
	1595					
	1596					
	1597					
	1598					
	1599					
	1600					
	1601					
	1602					
	1603					
	1604					
	1605					
	1606					
	1607					
	1608					
	1609					
	1610					
	1611					
	1612					
	1613					
	1614					
	1615					
	1616					
	1617					
	1618					
	1619					
	1620					
	1621					
	1622					
	1623					
	1624					
	1625					
	1626					
	1627					
	1628					
	1629					
	1630					
	1631					
	1632					
	1633					
	1634					
	1635					
	1636					
	1637					
	1638					
	1639					
	1640					
	1641					
	1642					
	1643					
	1644					
	1645					
	1646					
	1647					
	1648					
	1649					
	1650					
	1651					
	1652					
	1653					
	1654					
	1655					
	1656					
	1657					
	1658					
	1659					
	1660					
	1661					
	1662					
	1663					
	1664					
	1665					
	1666					
	1667					
	1668					
	1669					
	1670					
	1671					
	1672					
	1673					
	1674					
	1675					
	1676					
	1677					
	1678					
	1679					
	1680					
	1681					
	1682					
	1683					
	1684					
	1685					
	1686					
	1687					
	1688					
	1689					
	1690					
	1691					
	1692					
	1693					
	1694					
	1695					
	1696					
	1697					
	1698					
	1699					
	1700					
	1701					
	1702					
	1703					
	1704					
	1705					
	1706					
	1707					
	1708					
	1709					
	1710					
	1711					
	1712					
	1713					
	1714					
	1715					
	1716					
	1717					
	1718					
	1719					
	1720					
	1721					
	1722					
	1723					
	1724					
	1725					
	1726					
	1727					
	1728					
	1729					
	1730					
	1731					
	1732					
	1733					
	1734					
	1735					
	1736					
	1737					
	1738					
	1739					
	1740					
	1741					
	1742					
	1743					
	1744					
	1745					
	1746					
	1747					
	1748					
	1749					
	1750					
	1751					
	1752					
	1753					
	1754					
	1755					
	1756					
	1757					
	1758					
	1759					
	1760					
	1761					
	1762					
	1763					
	1764					
	1765					
	1766					
	1767					
	1768					
	1769					
	1770					
	1771					
	1772					
	1773					
	1774					
	1775					
	1776					
	1777					
	1778					
	1779					
	1780					
	1781					
	1782					
	1783					
	1784					
	1785					
	1786					
	1787					
	1788					
	1789					
	1790					
	1791					
	1792					
	1793					
	1794					
	1795					
	1796					
	1797					
	1798					
	1799					
	1800					
	1801					
	1802					
	1803					
	1804					
	1805					
	1806					
	1807					
	1808					
	1809					
	1810					
	1811					
	1812					
	1813					
	1814					
	1815					
	1816					
	1817					
	1818					
	1819					
	1820					
	1821					
	1822					
	1823					
	1824					
	1825					
	1826					
	1827					
	1828					
	1829					
	1830					
	1831					
	1832					
	1833					
	1834					
	1835					
	1836					
	1837					
	1838					
	1839					
	1840					
	1841					
	1842					
	1843					
	1844					
	1845					
	1846					
	1847					
	1848					
	1849					
	1850					
	1851					
	1852					
	1853					
	1854					
	1855					
	1856					
	1857					
	1858					
	1859					
	1860					
	1861					
	1862					
	1863					
	1864					
	1865					
	1866					
	1867					
	1868					
	1869					
	1870					
	1871					
	1872					

Lampiran 19. Estimasi Parameter Model Terbaik Golongan Darah AB

Lampiran 20. Estimasi Parameter Model Terbaik Golongan Darah O

Lampiran 21. Komponen Darah di PMI Surabaya

**Komponen darah yang telah diproduksi di UTD PMI
Kota Surabaya adalah :**

1. WHOLE BLOOD (WB)/DARAH LENGKAP

Spesifikasi :

- | | |
|---------------------|--|
| 1. Volume | 350 - 450 mL |
| 2. Suhu Penyimpanan | 2°C s/d 6°C |
| 3. Masa simpan | ± 35 hari |
| 4. Hb | > 45 g/Unit |
| 5. Hemolisis | < 0,8% |
| 6. Perlakuan | Di luar suhu tersebut, maksimal 30 menit harus segera ditransfusikan |
| 7. Tujuan pemberian | Menggantikan volume darah yang hilang akibat perdarahan masif |



2. PACKED RED CELL (PRC)/SEL DARAH MERAH

Spesifikasi :

- | | |
|---------------------|--|
| 1. Volume | 200 - 300 mL |
| 2. Suhu Penyimpanan | 2°C s/d 6°C |
| 3. Masa simpan | ± 35 hari |
| 4. Hb | > 45 g/Unit |
| 5. HCT | 65% - 75% |
| 6. Hemolisis | < 0,8% |
| 7. Perlakuan | Di luar suhu tersebut, maksimal 30 menit harus segera ditransfusikan |
| 8. Tujuan pemberian | Meningkatkan jumlah eritrosit dan haemoglobin pada anemia |



3. PRC LEUKOREDUCED (PRC dengan jumlah lekosit yang minim)

Spesifikasi :

- | | |
|---------------------|--|
| 1. Volume | 200 - 300 mL |
| 2. Suhu Penyimpanan | 2°C s/d 6°C |
| 3. Masa simpan | ± 35 hari |
| 4. Hb | > 43 g/Unit |
| 5. HCT | 50% - 70% |
| 6. Jumlah Lekosit | < $1,2 \times 10^9$ / unit |
| 7. Perlakuan | Di luar suhu tersebut, maksimal 30 menit harus segera ditransfusikan |
| 8. Tujuan pemberian | Meningkatkan jumlah eritrosit dan haemoglobin pada anemia |
| 9. Keunggulan | Telah melalui pengurangan leukosit sehingga mengurangi risiko reaksi transfusi |



4. PRC LEUKODEPLETED (PRC dengan filter lekosit)

Spesifikasi :

- | | |
|---------------------|--|
| 1. Volume | 200 - 300 mL |
| 2. Suhu Penyimpanan | 2°C s/d 6°C |
| 3. Masa simpan | ± 35 hari |
| 4. Hb | > 45 g/Unit |
| 5. HCT | 50% - 75% |
| 6. Jumlah Lekosit | < 1×10^6 / unit |
| 7. Perlakuan | Di luar suhu tersebut, maksimal 30 menit harus segera ditransfusikan |
| 8. Tujuan pemberian | Meningkatkan jumlah eritrosit dan haemoglobin pada anemia |
| 9. Keunggulan | Telah melalui proses filtrasi untuk menghilangkan |



Lampiran 22. Surat Pengambilan Data di PMI Surabaya



Surabaya , 10 Juli 2017

No : 1387/UTD.PMI/DIKLAT/VII//2017

Lamp :

Hal : Surat Keterangan.

Kepada Yth :

Kepala Departemen Fakultas Matematika dan

Ilmu Pengetahuan Alam Institut Teknologi

Sepuluh Nopember Surabaya

Di -

Surabaya

Yang bertanda tangan dibawah ini :

Nama : Dr. Hj. Budi Arifah

Jabatan : Kepala

Menerangkan :

Nama : Fahrizal Andriyansyah

NIM : 1315105018

telah melaksanakan pengambilan data untuk tugas akhir di Unit Transfusi Darah PMI Kota Surabaya mulai tanggal 01 Maret – 30 April 2017.

Demikian , Surat keterangan ini dibuat untuk dipergunakan sebagaimana mestinya .



Dr. Hj. BUDI ARIFAH

Unit Transfusi Darah PMI Kota Surabaya

Jl. Embong Ploso No. 7 - 15 Surabaya Telp.: 031-5313289, 5323994, Fax : 031-5313288
Email : utdsby@yahoo.com Facebook : UDD PMI Kota Surabaya



(Halaman Ini Sengaja Dikosongkan)

BIODATA PENULIS



Penulis bernama lengkap Fahrizal Andryansyah, yang biasa disapa Fahrizal atau Andry. Penulis merupakan anak tunggal yang lahir di Surabaya 4 Juni 1994. Pendidikan formal yang pernah ditempuh penulis adalah TK Nurul Huda, kemudian SD pada kelas 1 sampai 3 di SDN Kupang Krajan 1, sedangkan pada kelas 4 sampai 6 bersekolah di SDN Manukan Wetan 1/114, SMPN 3 Surabaya, SMAN

4 Surabaya. Pada tahun 2012 diterima menjadi mahasiswa di perguruan tinggi Institut Teknologi Sepuluh Nopember Surabaya (ITS) sebagai mahasiswa baru Jurusan Statistika jalur tes DIII Reguler. Kemudian pada Tahun 2015 melanjutkan pendidikan Lintas Jalur atau Program Studi Sarjana Departemen Statistika ITS. Selama masa perkuliahan DIII pernah melaksanakan Kerja Praktek di PT. PAL Indonesia (PERSERO). Sedangkan saat Lintas Jalur melaksanakan Kerja Praktek di PT Pembangkitan Jawa-Bali Kantor Pusat yang berlokasi di Jalan Ketintang Baru 11 Surabaya, Jawa Timur. Segala kritik dan saran dari pembaca untuk penulis bisa disampaikan melalui email f_saiyan@yahoo.co.id.