



TUGAS AKHIR - KS141501

**PERAMALAN PERMINTAAN TEPUNG TERIGU DI PT.XYZ
MENGGUNAKAN METODE ARTIFICIAL NEURAL NETWORK**

**FLOUR DEMAND FORECASTING IN PT.XYZ USING
ARTIFICIAL NEURAL NETWORK**

SIGIT TRI BASKORO
NRP 0521 14 4000 0047

Dosen Pembimbing 1
Edwin Riksakomara, S.Kom, M.T

Departemen Sistem Informasi
Fakultas Teknologi Informasi dan Komunikasi
Institut Teknologi Sepuluh Nopember
Surabaya 2018

Halaman ini sengaja dikosongkan



TUGAS AKHIR - KS141501

PERAMALAN PERMINTAAN TEPUNG PT.XYZ MENGGUNAKAN METODE TERIGU DI ARTIFICAL NEURAL NETWORK

SIGIT TRI BASKORO
NRP 05211440000047

Dosen Pembimbing
1. Edwin Riksakomara, S.Kom, M.T

Departemen Sistem Informasi
Fakultas Teknologi Informasi dan Komunikasi
Institut Teknologi Sepuluh Nopember
Surabaya 2018



Halaman ini sengaja dikosongkan



FINAL PROJECT - KS141501

FLOUR DEMAND FORECASTING USING ARTIFICIAL NEURAL NETWORK METHOD

SIGIT TRI BASKORO
NRP 05211440000047
Sepuluh Nopember

Supervisor 1
Edwin Riksakomara, S.Kom, M.T

Departement of Information System
Faculty of Information Technology and Communication
Institut Teknologi Sepuluh Nopember
Surabaya 2018



Halaman ini sengaja dikosongkan

LEMBAR PENGESAHAN

PERAMALAN PERMINTAAN TEPUNG TERIGU DI PT.XYZ MENGGUNAKAN METODE ARTIFICIAL NEURAL NETWORK

TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat

Memperoleh Gelar Sarjana Komputer

pada

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

Oleh:

SIGIT TRI BASKORO

NRP. 0521 14 4000 0047

Surabaya, 19 Juli 2018

**KEPALA
DEPARTEMEN SISTEM INFORMASI**

Dr. Ir. Aris Tjahyanto, M.Kom,
NIP 19650310 199102 1 001

Halaman ini sengaja dikosongkan

LEMBAR PERSETUJUAN

PERAMALAN PERMINTAAN TEPUNG TERIGU DI PT.XYZ MENGGUNAKAN METODE ARTIFICIAL NEURAL NETWORK

TUGAS AKHIR

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

Oleh:
SIGIT TRI BASKORO
NRP. 0521144000047

Disetujui Tim Pengudi: Tanggal Ujian : 10 Juli 2018
Periode Wisuda : September 2018

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

(Pembimbing I)

Ahmad Mukhlason, S.Kom, M.Sc, Ph.D.

(Penguji D)

Wiwik Anggraeni, S.Si, M.Kom.

(Penguiji III)

Halaman ini sengaja dikosongkan

PERAMALAN PERMINTAAN TEPUNG TERIGU DI PT.XYZ MENGGUNAKAN METODE ARTIFICIAL NEURAL NETWORK

Nama Mahasiswa : Sigit Tri Baskoro

NRP : 05211440000047

Departemen : Sistem Informasi FTIK-ITS

Dosen Pembimbing :

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

ABSTRAK

Tepung terigu merupakan salah satu kebutuhan pokok masyarakat Indonesia. Tepung terigu memegang peran penting dalam program pemerintah untuk mempertahankan ketahanan pangan Indonesia. Tepung terigu termasuk dalam 11 jenis bahan pokok yang dijaga ketersediaan dan harganya oleh Pemerintah. Ketersediaan tepung perlu diperhatikan setiap harinya untuk mendukung program pemerintah. Dengan tersedianya produksi tepung terigu, dibutuhkan pula tempat penyimpanan tepung terigu yang telah di produksi. Adanya tempat penyimpanan hasil produksi membuat perusahaan harus dapat memaksimalkan penggunaan tempat penyimpanan. Hal ini disebabkan karena penggunaan tempat penyimpanan merupakan tambahan biaya bagi perusahaan. Peramalan terhadap kebutuhan tepung terigu dapat memberikan gambaran kepada pemerintah atau Industri produksi tepung dalam mempersiapkan produksi tepung terigu yang akan

dihadarkan serta mempersiapkan gudang penyimpanan tepung terigu sehingga dapat menekan biaya operasional gudang.

Artificial Neural Network merupakan tiruan jaringan syaraf manusia yang tersusun atas unit – unit kecil yang memproses data. Arsitektur jaringan syaraf tiruan ini memiliki tiga buah lapisan, yaitu input layer, hidden layer, dan output layer. Dengan mengatur jumlah tiap lapisan, dapat dihasilkan model yang optimal untuk menyelesaikan masalah.

Hasil yang didapatkan dari penelitian ini adalah peramalan permintaan tepung terigu dengan menggunakan model terbaik yang telah didapatkan yaitu dengan nilai MAPE sebesar 22% dan tergolong layak untuk dipakai..

Kata kunci : Peramalan, Permintaan kebutuhan, Artificial Neural Network

FLOUR DEMAND FORECASTING IN PT.XYZ USING ARTIFICIAL NEURAL NETWORK

Nama Mahasiswa : Sigit Tri Baskoro

NRP : 05211440000047

Departemen : Sistem Informasi FTIK-ITS

Dosen Pembimbing :

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

ABSTRACT

. Wheat flour is one of the basic needs of the people of Indonesia. Wheat flour contribute an important role in government programs to maintain Indonesia's food security. Wheat flour is included in 11 types of basic commodities that are kept available and priced by the Government. The availability of flour needs to be addressed daily to support government programs. With the availability of wheat flour production, it is also necessary place of storage of wheat flour that has been in production. The existence of storage place of production makes the company should be able to maximize the use of storage. This is because the use of storage is an additional cost for the company. Forecasting of wheat flour needs can give an idea to the government or flour production industry in preparing the production of wheat flour to be produced as well as preparing the warehouse of flour storage so as to reduce the warehouse operational costs.

Artificial Neural Network is an imitation of human neural network composed of small units that process data. Artificial neural network architecture has three layers, the input layer, hidden layer, and output layer. By adjusting the number of layers, an optimal model can be generated to solve the problem. Artificial Neural Network has been widely used in various fields such as, economics, medicine, engineering, and agriculture. Artificial Neural Network gives users flexibility to suit their needs.

The result obtained from this research is forecasting the demand of wheat flour using the best model that has been obtained has a MAPE value of 22%.

Keywords: Forecasting, Demand Requirement, Artificial Neural Network

KATA PENGANTAR

Puji syukur penulis panjatkan kehadiran Tuhan Yang Maha Esa atas segala berkat dan rahmat-Nya penulis dapat menyelesaikan buku tugas akhir dengan judul "**PERAMALAN PERMINTAAN TEPUNG TERIGU DI PT.XYZ MENGGUNAKAN METODE ARTIFICIAL NEURAL NETWORK**" yang merupakan salah satu syarat kelulusan pada Departemen Sistem Informasi, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember Surabaya.

Secara khusus penulis akan menyampaikan ucapan terima kasih yang sedalam-dalamnya kepada:

1. Tuhan yang Maha Esa yang telah memberikan segala kebaikan-Nya untuk dapat menyelesaikan masa perkuliahan di Sistem Informasi ITS dan telah memberikan kemudahan, kelancaran, serta kesehatan selama pengerjaan tugas akhir ini.
2. Ibu Rina Harini dan Bapak Abdul Latif selaku kedua orang tua, Novi Dyah sebagai kakak yang selalu memberikan dukungan dalam berbagai bentuk, serta segenap keluarga penulis yang selalu memberikan motivasi.
3. Bapak Edwin Riksakomara S.Kom, M.T selaku dosen pembimbing dengan penuh kesabaran dan dedikasi telah membimbing penulis dalam mengerjakan tugas akhir ini hingga selesai. Terima kasih atas kesediaan waktu, dan ilmu yang telah diberikan.
4. Bapak Ahmad Muklason S.Kom, M.Sc, Ph.D dan Ibu Wiwik Anggraeni S.Si., M.Kom selaku penguji yang telah memberikan saran dan pengarahan untuk menyempurnakan tugas akhir ini. Terimakasih atas kesediaan waktu dan ilmu yang telah diberikan
5. Bapak Bekti Cahyo, S.Kom., M.Sc. selaku dosen wali penulis yang selalu memberikan motivasi, nasihat, dukungan, dan saran selama penulis menempuh pendidikan SI.
6. Mas Ricky Asrul Sani selaku admin laboratorium Rekayasa Data dan Intelelegensi Bisnis yang telah membantu dalam hal

administrasi penyelesaian Tugas Akhir.

7. Seluruh dosen pengajar, staff, dan karyawan di Departemen Sistem Informasi FTIK ITS Surabaya yang telah memberikan ilmu dan bantuan kepada penulis selama ini.
8. Serta semua pihak yang telah membantu dalam pengerjaan Tugas Akhir ini yang belum mampu penulis sebutkan diatas.

Terima kasih atas segala bantuan, dukungan, serta doa yang diberikan. Semoga Tuhan yang Maha Esa senantiasa memberikan kesehatan, keselamatan, karunia dan nikmat-Nya. Penulis ingin memohon maaf apabila Tugas Akhir ini masih belum sempurna dengan segala kekurangan di dalamnya.

Surabaya, 20 Juni 2018

DAFTAR ISI

LEMBAR PENGESAHAN....	Error! Bookmark not defined.
LEMBAR PERSETUJUAN	ix
ABSTRAK	xi
ABSTRACT	xiii
KATA PENGANTAR	xv
DAFTAR ISI.....	xvii
DAFTAR GAMBAR	xx
DAFTAR TABEL.....	xxi
DAFTAR SCRIPT	xxiii
1 BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah.....	3
1.3 Batasan Masalah.....	3
1.4 Tujuan	4
1.5 Manfaat	4
1.6 Relevansi	5
2 BAB II TINJAUAN PUSTAKA	7
2.1 Penelitian Sebelumnya	7
Peramalan Kebutuhan Tepung Terigu untuk Produksi Roti Basah pada Perusahaan Roti Ganep's Surakarta.....	7
Comparison of ARIMAA and Artificial Neural Network Models for Stock Price Prediction	10
2.2 Dasar Teori	11
2.2.1 Peramalan.....	11
2.2.2 Data Time Series	13

2.2.1	Matlab.....	14
2.2.3	Artificial Neural Network	15
2.2.4.	Back-Propagation	15
2.2.5	Evaluasi Kinerja Model	19
3	BAB III METODOLOGI	21
3.1	Tahapan Pengerjaan Tugas Akhir	21
3.2	Uraian Metodologi.....	23
3.2.1.	Inisiasi Penelitian.....	23
3.2.2.	Pengolahan Data	23
3.2.3.	Pembuatan Model	23
3.2.5.	Analisa dan Kesimpulan	24
3.2.6.	Penyusunan Buku Tugas Akhir	24
3.3	Bahan dan Alat yang digunakan	25
3.3.1	Bahan yang Digunakan	25
3.3.2.	Alat yang Digunakan	25
4	BAB IV PERANCANGAN.....	27
4.1	Pengumpulan data	27
4.2	Pra-processing Data.....	28
4.3	Pembagian Data.....	31
4.4	Perancangan Model	32
4.4.1	Menentukan Node pada Input Layer	36
4.4.2	Menentukan Transfer Function	36
4.4.3	Menentukan Training Function.....	37
4.4.4	Menentukan Learning Function	37
4.4.5	Menentukan Momentum.....	37
4.4.6	Menentukan Learning Rate.....	37
4.4.7	Menentukan Jumlah Epoch.....	38

4.4.8	Menentukan Jumlah Node pada hidden layer	38
4.5	Eksperimen Model	38
4.6	Processing Data	39
4.7	Analisa Hasil Model.....	40
5	BAB V IMPLEMENTASI	41
5.1	Pembagian Data.....	41
5.2	Setting Parameter	50
5.3	Pembuatan Looping.....	51
5.4	Inisiasi Parameter pada model Network	52
5.5	Pembuatan Output	54
6	BAB VI HASIL DAN PEMBAHASAN	57
6.1	Lingkungan Kerja Penelitian	57
6.2	Hasil Testing Data	58
6.3	Model Terbaik	65
7	BAB VII KESIMPULAN DAN SARAN.....	69
7.1	Kesimpulan	69
7.2	Saran.....	70
	DAFTAR PUSTAKA	71
	Biodata Penulis	73
	Lampiran A	75

Halaman ini sengaja dikosongi

DAFTAR GAMBAR

Gambar 1.1 Permintaan Tepung (kg/hari) dua periode016 - 2017	2
Gambar 2.1 Logo Matlab versi R2015a.....	14
Gambar 2.2 Arsitektur Backpropagation	17
Gambar 2.3 Local Gradient Error	18
Gambar 3.1 Metodologi Pengerjaan Tugas Akhir	22
Gambar 4.1 Permintaan Tepung per kg per hari	28
Gambar 4.2 Permintaan Tepung Terigu setelah Pra Processing	30
Gambar 4.3 Arsitektur Artificial Neural Network	32
Gambar 4.4 Arsitektur sederhana network	36
Gambar 6.1 Grafik Hasil MSE Tiap percobaan pada satu periode.....	59
Gambar 6.2 Grafik Hasil MSE Tiap percobaan pada dua periode	60
Gambar 6.3 Grafik Hasil MSE Tiap Percobaan pada Tiga periode.....	62
Gambar 6.4 Grafik Hasil MSE Tiap Percobaan pada Tiga periode.....	63
Gambar 6.5 Grafik Hasil MSE Tiap Percobaan pada Lima periode.....	64
Gambar 6.6 Grafik Perbandingan nilai MSE setiap model terbaik	65
Gambar 6.7 Grafik Perbandingan antara data aktual dan forecast	67

DAFTAR TABEL

Tabel 2.1 Signifikansi MAPE	19
Tabel 4.1 Data Permintaan Tepung per kg	27
Tabel 4.2 Data mengandung data kosong	29
Tabel 4.3 Data setelah di pra processing	30
Tabel 4.4 Data Pelatihan	31
Tabel 4.5 Data Pengujian	31
Tabel 4.6 Parameter yang digunakan	36
Tabel 4.7 Parameter Model	38
Tabel 4.8 Penjelasan nama file pada model.....	39
Tabel 5.1 Contoh Satu periode	41
Tabel 5.2 Contoh Dua periode.....	42
Tabel 5.3 Data Training satu periode	42
Tabel 5.4 Data Testing Satu periode	43
Tabel 5.5 Data Training dua periode	43
Tabel 5.6 Data Testing dua periode.....	44
Tabel 5.7 Data Training tiga periode	44
Tabel 5.8 Data Testing tiga periode.....	45
Tabel 5.9 Data Training empat periode	46
Tabel 5.10 Data Testing empat periode.....	47
Tabel 5.11 Data Training Lima periode	48
Tabel 5.12 Data Testing lima periode	49
Tabel 5.13 Settingan Parameter.....	50
Tabel 5.14 Penjelasan fungsi script setting parameter	51
Tabel 5.15 Penjelasan fungsi script Pembuatan Looping	52
Tabel 5.16 Fungsi Script pembuatan model ANN.....	53
Tabel 5.17 Penjelasan script pembuatan output.....	55
Tabel 6.1 Perangkat Keras Penelitian.....	57
Tabel 6.2 Perangkat Lunak Penelitian	58
Tabel 6.3 Hasil Model Terbaik Satu periode	59
Tabel 6.4 Hasil Model Terbaik Dua periode	60
Tabel 6.5 Hasil Model Terbaik Tiga periode.....	61
Tabel 6.6 Hasil Model Terbaik empat periode	62
Tabel 6.7 Hasil Model Terbaik lima periode	63
Tabel 6.8 Model Terbaik tiap Periode	65
Tabel 6.9 Struktur Model ANN Terbaik.....	66

Halaman ini sengaja dikosongi

DAFTAR SCRIPT

Script 5.1 Setting Parameter	50
Script 5.2 Pembuatan Looping	52
Script 5.3 Pembuatan model ANN	53
Script 5.4 Pembuatan Output.....	54

Halaman ini sengaja dikosongi

BAB I

PENDAHULUAN

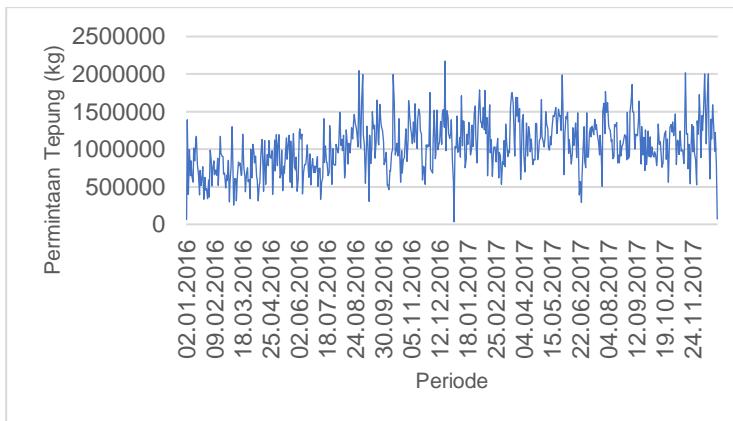
Pada bab ini akan dijelaskan mengenai gambaran umum tugas akhir yang terdiri atas perumusan masalah, batasan masalah, tujuan, manfaat, dan relevansi tugas akhir dengan kondisi sekarang. Dengan adanya bagian ini, diharapkan mampu memberikan gambaran awal tentang tugas akhir yang akan dilakukan.

1.1 Latar Belakang

Permintaan akan tepung terigu setiap hari yang fluktuatif setiap harinya mengakibatkan sulitnya perusahaan penghasil tepung terigu untuk menentukan produksi setiap harinya. Kesulitan dalam menentukan jumlah produksi setiap harinya berdampak kepada penggunaan ruang penyimpanan produk yang tidak efektif. Penggunaan ruang penyimpanan yang kurang efektif, baik itu kelebihan kapasitas maupun produk yang berada terlalu lama didalam ruang penyimpanan mengakibatkan membengkaknya biaya operasional untuk penyimpanan [9]. Selain itu, ketersediaan tepung terigu menjadi sangat penting untuk diperhatikan mengingat keluarnya regulasi yang mengatur tentang program ketahanan pangan nasional. Menurut Peraturan Presiden Republik Indonesia Nomor 48 Tahun 2016 tentang penugasan Perusahaan Umum BULOG dalam rangka ketahanan pangan nasional, tepung terigu merupakan salah satu jenis pangan pokok yang diatur pemerintah untuk menjaga ketahanan pangan nasional, dimana perusahaan umum penghasil tepung terigu maupun BULOG sebagai regulator logistik di Indonesia harus menjaga dan mengatur ketersediaan tepung agar tetap tersedia [2].

PT. XYZ merupakan perusahaan manufaktur yang bergerak dibidang produksi tepung terigu. Perusahaan ini menerima pesanan tepung terigu dari berbagai wilayah di bagian timur

Indonesia. PT. XYZ berperan penting dalam mempertahankan ketahanan pangan nasional khususnya pada komoditas tepung terigu. Dalam memproduksi produk mereka, PT. XYZ perlu memperhatikan stok tepung terigu yang berada di gudang agar selalu tersedia dan tidak melebihi kapasitas gudang. Kesulitan dalam memperkirakan berapa permintaan tepung terigu setiap hari mengakibatkan kurang efektifnya penggunaan gudang penyimpanan tepung terigu. Penyimpanan barang di gudang memiliki biaya penyimpanan yang berdasarkan nilai barang, jumlah barang, dan biaya operasional barang, seperti biaya fasilitas, biaya pajak, dan faktor penunjang lainnya [9].



Gambar 1.1 Permintaan Tepung (kg/hari) dua periode 016 - 2017

Peramalan dapat dilakukan dengan bermacam cara. Salah satunya menggunakan metode *machine learning*. Ada banyak jenis metode yang termasuk dalam *machine learning*, misalnya *Support Vector Machine*, *fuzzy logic*, *generic algorithms*, dan *Nrtificial Neural Network*. Dari beberapa contoh metode *machine learning* tersebut, metode terbaik yang bisa digunakan adalah *Artificial Neural Network*. Dari studi yang pernah dilakukan, metode *Artificial Neural Network* sudah teruji secara

efektif dalam meramalkan untuk tipe data yang tidak memiliki pola dan *non linier* [14]. Dalam studi tersebut, hasil peramalan menggunakan Artificial Neural Network dibandingkan dengan *Auto Regressive Integrated Moving Average* (ARIMA). Hasilnya, Peramalan menggunakan metode Artificial Neural Network lebih akurat daripada metode *Auto Regressive Integrated Moving Average*. Hasil peramalan dari *Artifial Neural Network* cenderung mengikuti trend data sebenarnya, sedangkan hasil peramalan *Regressive Integrated Moving Average* cenderung konstan mengikuti trend [1].

Oleh karena itu, melihat bahwa ketersediaan tepung sangat penting dalam menjaga kestabilan pangan nasional, maka diputuskan tertarik untuk melakukan penelitian dengan judul “Peramalan Permintaan Tepung menggunakan Artificial Neural Network”

1.2 Perumusan Masalah

Berdasarkan latar belakang yang telah dipaparkan diatas, maka rumusan masalah pada penelitian ini adalah :

1. Bagaimana model Artificial Neural Network yang cocok dan terbaik untuk meramalkan kebutuhan tepung terigu di PT.XYZ ?
2. Bagaimana tingkat akurasi dari peramalan kebutuhan tepung terigu di PT.XYZ?

1.3 Batasan Masalah

Batasan masalah pada tugas akhir ini adalah :

1. Studi kasus penelitian ini adalah meramalkan kebutuhan tepung terigu di PT.XYZ untuk daerah Indonesia Timur
2. Penelitian ini berfokus pada pembuatan model peramalan kebutuhan tepung terigu

3. Data yang digunakan adalah data kebutuhan tepung terigu per hari mulai 1 Januari 2016 – 31 Desember 2017.
4. Metode yang digunakan adalah Artificial Neural Network Backpropagation
5. *Software* yang digunakan adalah Matlab R2016a

1.4 Tujuan

Tujuan dari penggerjaan tugas akhir ini adalah:

1. Mengetahui pemodelan yang sesuai untuk mendapatkan hasil peramalan kebutuhan tepung terigu
2. Mengetahui hasil peramalan kebutuhan tepung terigu dengan metode *Artificial Neural Network*
3. Mengetahui akurasi peramalan kebutuhan tepung terigu dengan metode *Artificial Neural Network*

1.5 Manfaat

Manfaat dari penggerjaan tugas akhir ini adalah :

1. Bagi Pengembangan keilmuan :

Manfaat dari tugas akhir ini diharapkan menjadi referensi pengetahuan tentang peramalan kebutuhan tepung terigu menggunakan metode Artificial Neural Network dan menjadi referensi untuk penelitian – penelitian selanjutnya dengan metode berbeda.

2. Bagi Industri tepung :

Dengan adanya tugas akhir ini yang meneliti tentang kebutuhan tepung terigu, dapat dijadikan referensi dalam produksi agar dapat memenuhi kebutuhan tepung terigu masyarakat serta dapat mengatur persediaan gudang dengan baik.

1.6 Relevansi

Tugas akhir ini berhubungan dengan mata kuliah teknik peramalan, dimana tugas akhir ini dilakukan peramalan kebutuhan tepung yang dikirim tiap hari ke masing masing wilayah dari PT XYZ menggunakan metode *Artificial Neural Network*. Tugas akhir ini layak menjadi tugas akhir S1 karena tugas akhir ini merupakan bagian dari penelitian di laboratorium Rekayasa Data dan Intelelegensi Data (RDIB) dikarenakan mata kuliah pilihan Teknik Peramalan berada pada bidang ilmu laboratorium Rekayasa Data dan Intelelegensi Data (RDIB). Penelitian ini juga merupakan penerapan dari mata kuliah Sistem Cerdas.

Kebutuhan tepung terigu yang naik turun juga mempengaruhi industri terkait dalam menangani gudang penyimpanan yang dimiliki dan ketahanan pangan. Oleh sebab itu, apabila dilakukan peramalan, maka pihak terkait mampu mengantisipasi kondisi di masa depan dengan tindakan manajemen dan operasional. Metode Artificial Neural Network yang digunakan dalam peramalan kebutuhan tepung terigu ini cukup relevan karena sudah banyak digunakan dan dikembangkan di berbagai macam bidang. Artificial Neural Network memiliki berbagai macam model, dan cara perhitungan yang bermacam – macam, sehingga mampu digunakan untuk berbagai tujuan.

Halaman ini sengaja dikosongkan

BAB II

TINJAUAN PUSTAKA

Pada bab ini dijelaskan mengenai penelitian sebelumnya yang berhubungan dengan bahasan tugas akhir yang dikerjakan serta menjelaskan tentang dasar teori yang perlu diperhatikan dan dipahami untuk dijadikan landasan dalam mengerjakan tugas akhir.

2.1 Penelitian Sebelumnya

Pada bab ini dijelaskan mengenai penelitian sebelumnya yang memiliki keterkaitan dengan topik tugas akhir yang dibahas dan membahas dasar teori yang perlu dipahami untuk dijadikan acuan dalam pengerjaan tugas akhir.

Penelitian 1 [3]

Judul Penelitian	Peramalan Kebutuhan Tepung Terigu untuk Produksi Roti Basah pada Perusahaan Roti Ganep's Surakarta
Penulis / Tahun Penelitian	Alfin Maulana / 2014
Gambaran Umum	Penelitian tentang peramalan kebutuhan tepung terigu yang dibutuhkan oleh Perusahaan Roti Ganep's di Surakarta. Tujuan dari penelitian ini adalah meramalkan kebutuhan tepung terigu untuk produksi dengan menggunakan metode Single Moving Average, Weight Moving Average dan Eksponensial Smoothing ($\alpha_1 = 0.1$, $\alpha_2 = 0.3$, $\alpha_3 = 0.5$). Hasil yang didapatkan adalah Weight Moving Average lebih baik daripada Single Moving Average dan

	Eksponensial Smoothing karena tingkat kesalahan MAD dan MSE yang lebih kecil dengan nilai MAD sebesar 405,11 kg dan nilai MSE sebesar 185,336 kg
Keterkaitan	Pada penelitian ini sama – sama meramalkan kebutuhan tepung terigu di suatu perusahaan. Penelitian ini menggunakan metode Moving Average dan Eksponensial Smoothing sedangkan penelitian tugas akhir yang akan dilakukan menggunakan metode Artificial Neural Network
	Penelitian 2 [4]
Judul Penelitian	Peramalan Permintaan dan Perencanaan Produk Tepung Segitiga Biru
Penulis / Tahun Penelitian	Ariski / 2016
Gambaran Umum	Penelitian tentang peramalan permintaan tepung terigu dan perencanaan produksi tepung segitiga biru di PT Bogasari Flour Mills. Tujuan dari penelitian ini adalah meramalkan permintaan tepung terigu guna mengurangi ketidakpastian dalam produksi. Metode yang digunakan dalam penelitian ini adalah Holt-Winter Additive Algorithm. Metode ini dipilih karena menghasilkan MAD paling kecil diantara metode lainnya yang telah diuji
Keterkaitan	Pada penelitian ini sama – sama meramalkan permintaan tepung terigu

di suatu perusahaan. Penelitian ini menggunakan metode Holt-Winter Additive Algorithm sedangkan penelitian tugas akhir yang akan dilakukan menggunakan metode Artificial Neural Network

Penelitian 3 [5]

Judul Penelitian	Prediction of Agricultural Commodity Price Using Artificial Neural Networks: Case of Chicken Price in Fars province, Iran
Penulis / Tahun Penelitian	Somayeh Ebrahimi, Shahrokh Shajari, dan Mohammad Hassan Tarazkar / 2012
Gambaran Umum	Penelitian tentang peramalan harga ayam di Iran yang termasuk kedalam bahan pokok yang masuk dalam ketahanan pangan nasional. Tujuan dari penelitian ini adalah untuk meramalkan harga ayam dengan menggunakan metode ARIMA, ARCH, dan ANN. Dimana hasil yang didapatkan ANN lebih baik dibandingkan dengan ARCH dan ARIMA yang dilihat melalui MAPE. MAPE yang dihasilkan oleh ARCH adalah 38,5%, ARIMA adalah 4,7%, dan ANN adalah 2,6%
Keterkaitan	Pada penelitian ini sama – sama meramalkan komoditas ketahanan pangan nasional yaitu ayam dan tepung terigu dengan metode Artificial Neural Network. Penelitian ini meramalkan harga sedangkan penelitian tugas akhir yang akan dilakukan meramalkan

permintaan tepung. Penelitian ini membandingkan antara tiga metode yaotu ARIMA, ARCH, dan Artificial Neural Network sedangkan penelitian tugas akhir yang akan dilakukan hanya menggunakan metode Artificial Neural Network.

Penelitian 4

Judul Penelitian	Comparison of ARIMAA and Artificial Neural Network Models for Stock Price Prediction
Penulis / Tahun Penelitian	Ayodele Ariyo Adebiyi, Aderemi Oluyinka Adewumi, dan Charles Korede Ayo
Gambaran Umum	Penelitian tentang peramalan bursa saham di New York. Tujuan dari penelitian ini adalah membandingkan hasil peramalan antara ARIMA dan ANN. Dari hasil peramalan tersebut, diketahui bahwa peramalan menggunakan metode Artificial Neural Network lebih akurat daripada metode Auto Regressive Integrated Moving Average. Hal ini disebabkan oleh kemampuan ANN dalam mengatasi data tak berpola.
Keterkaitan	Pada penelitian ini sama – sama menggunakan metode Artificial Neural Network. Perbedaannya adalah jenis kasus yang digunakan berbeda. Penelitian ini meramalkan bursa saham sedangkan penelitian yang akan dibuat tentang permintaan tepung terigu.

2.2 Dasar Teori

Pada bab ini dijelaskan mengenai dasar teori yang digunakan sebagai acuan dalam mengerjakan tugas akhir

2.2.1 Peramalan

Peramalan (forecasting) Dalam dunia usaha sangat penting diperlukan hal-hal yang terjadi dimasa depan sebagai dasar untuk pengambilan keputusan. Menurut Gaspersz (2005) Aktivitas peramalan merupakan suatu fungsi bisnis yang berusaha memperkirakan penjualan dan penggunaan produk sehingga produk-produk itu dapat dibuat dalam kuantitas yang tepat [6]. Menurut Taylor (2004) Peramalan yaitu sebuah prediksi mengenai apa yang akan terjadi di masa depan [7]. Kegiatan peramalan dilakukan sebagai dasar pengambilan keputusan guna meminimalkan kemungkinan resiko yang dihadapi akibat pengaruh ketidakpastian dari masa depan [9]. Pada dasarnya, ada tiga langkah penting dalam peramalan, yaitu:

1. Menganalisis data masa lalu
2. Menentukan metode yang digunakan
3. Memproyeksi data dengan menggunakan metode yang digunakan dengan mempertimbangkan beberapa faktor perubahan

Didalam peramalan, terdapat bermacam – macam jenis peramalan. Namun, secara garis besar, peramalan dibagi menjadi 2 jenis, yaitu berdasar aspek waktu dan aspek sifat. Pada peramalan berdasarkan aspek waktu, peramalan dibagi menjadi 3 jenis yaitu:

1. Peramalan jangka pendek, dimana peramalan ini memiliki jangka waktu hingga 1 tahun
2. Peramalan jangka menengah, dimana peramalan ini memiliki jangka waktu 1 sampai 3 tahun

3. Peramalan jangka panjang, dimana peramalan ini memiliki jangka waktu lebih dari tiga tahun

Untuk peramalan berdasarkan aspek sifat, dapat dilakukan pendekatan secara kualitatif maupun kuantitatif. Pendekatan kualitatif merupakan metode peramalan yang digunakan berdasarkan pemikiran yang bersifat intuisi, pengetahuan serta pengalaman. Sementara itu, pendekatan kuantitatif merupakan metode peramalan menggunakan data historis dan diolah dengan model matematis. Pendekatan yang digunakan dalam peramalan memiliki kekurangan dan kelebihannya sendiri, tergantung pula dengan pola data yang dihadapi. Beberapa jenis pola data antara lain:

- a. Pola data *constant*, yaitu data yang rata-rata berfluktuasi stabil dan membentuk pola horizontal. Pola seperti ini muncul dalam jangka waktu yang pendek atau menengah. Oleh karena itu, jarang sekali suatu variabel memiliki pola konstan dalam jangka waktu yang panjang.
- b. Pola data *trend*, yaitu apabila data pada jangka waktu tertentu memiliki kecenderungan meningkat dari waktu ke waktu maupun turun. Pola ini dapat disebabkan oleh beberapa faktor seperti bertambahnya populasi, perubahan pendapatan, dan pengaruh budaya.
- c. Pola data *seasonal*, yaitu data yang memiliki pola gerakan yang berulang-ulang secara teratur dalam periode waktu tertentu, misalnya tahunan, bulanan dan sebagainya. Pola ini berhubungan dengan faktor iklim dan cuaca atau faktor yang dibuat oleh manusia seperti musim liburan dan lain-lain.
- d. Pola data *cyclic*, yaitu data yang dipengaruhi oleh fluktuasi ekonomi jangka panjang, seperti alur hidup bisnis. Hal yang membedakan pola data seasonal dan *cyclic* adalah pola data seasonal memiliki panjang gelombang yang tetap dan terjadi dalam jarak waktu yang tetap, sedangkan pola *cyclic* memiliki durasi yang lebih panjang dan bervariasi.

- e. Pola data residual atau variasi acak, yaitu data yang tidak teratur sama sekali. Data yang bersifat residu tidak dapat digambarkan

2.2.2 Data Time Series

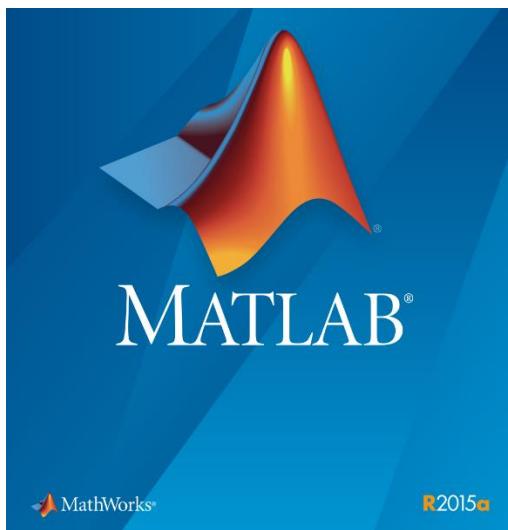
Data time series merupakan data yang dikumpulkan, dicatat atau diobservasi sepanjang waktu secara berurutan. Pada umumnya pengumpulan dan pencatatan itu dilakukan dalam jangka waktu tertentu misalnya tiap hari, tiap bulan, tiap akhir tahun, dan sebagainya. Data *time series* diukur pada suatu interval waktu yang kontinu, memiliki jarak antar dua titik data yang sama dan untuk setiap satuan waktu dalam interval waktu hanya memiliki satu titik data. Data time series ini akan menghasilkan pola data yang dibagi menjadi empat yaitu [11] :

1. Pola *Trend*
 - Kecenderungan data untuk meningkat, menurun atau tetap dalam jangka waktu yang panjang disebut sebagai Trend Sekuler atau hanya Trend. Misalnya, data yang berkaitan dengan pertumbuhan populasi, tingkat kematian, perkembangan suatu penyakit, dan lain - lain
2. Pola Musiman
 - Pola ini terjadi ketika data dipengaruhi oleh faktor musiman. Faktor penting yang menyebabkan variasi musiman adalah: kondisi iklim dan cuaca, adat setempat, dll.
3. Pola Siklik
 - Pola data cenderung dalam keadaan yang berulang dalam sebuah. Durasi siklus biasanya berlanjut dalam jangka waktu yang lebih lama, biasanya dua tahun atau lebih.
4. Pola Tidak Beraturan
 - Pola data tidak teratur sama sekali atau acak dalam rentetan waktu sehingga susah untuk diprediksi.

Pola ini tidak berulang dan tidak biasa terjadi tanpa faktor yang kritis. Contoh faktor kritis yang menghasilkan pola data seperti ini adalah bencana alam, dan perang. Belum ada teknik statistik yang bisa dijadikan acuan untuk meramalkan pola data tidak beraturan.

2.2.1 Matlab

Matlab merupakan suatu platform pemrograman yang didesain secara khusus untuk para ilmuan dan teknisi. Matlab sendiri adalah bahasa pemrograman berdasarkan matrik yang memungkinkan pengguna untuk melakukan perhitungan matematika secara mudah dan fleksibel. Matlab mengkombinasikan lingkungan kerja desktop untuk analisa yang berulang dan desain proses dengan bahasa pemrograman yang berupa matriks dan array.



Gambar 2.1 Logo Matlab versi R2015a

Secara garis besar, Matlab mampu digunakan untuk analisa data, mengembangkan algoritma baru, membuat model dan aplikasi serta melakukan simulasi.

2.2.3 Artificial Neural Network

Artificial Neural Network merupakan tiruan jaringan syaraf manusia yang tersusun atas unit – unit kecil yang memproses data. Arsitektur jaringan syaraf tiruan ini memiliki tiga buah lapisan, yaitu input layer, hidden layer, dan output layer. Menurut Hecth-Nielsen (1989), *Artificial Neural Network* disebut sebagai suatu kesatuan dalam pemrosesan informasi yang tersebar dan bekerja secara bersamaan. Setiap unit memiliki kemampuan pemrosesan yang terhubung dengan satu unit lainnya sehingga menciptakan jaringan lokal yang berjalan searah. Setiap unit pemrosesan memiliki koneksi keluar tunggal yang bercabang ke sejumlah koneksi kolateral dimana tiap koneksi membawa output dari masing – masing unit pemrosesan untuk menghasilkan keluaran yang dapat digunakan sebagai persamaan matematis. [8].

Menurut Haykin, S (1994) jaringan syaraf tiruan didefinisikan sebagai sebuah prosesor yang tersebar secara paralel yang mampu menyimpan pengalaman dan pengetahuan, sehingga menyerupai kinerja otak asli. Pengalaman dan pengetahuan tersebut didapatkan melalui suatu proses belajar, dan kekuatan hubungan antar sel syaraf yang dikenal dengan sinapsis digunakan untuk menyimpan pengetahuan [12].

Dapat disimpulkan bahwa *Artificial Neural Network* merupakan gabungan antara unit – unit pemrosesan informasi yang bekerja secara paralel yang membentuk suatu jaringan mirip otak manusia. *Artificial Neural Network* memiliki sifat adaptif terhadap pengalaman yang didapatkan dari proses belajar, sehingga mampu menyelesaikan masalah yang dihadapi.

2.2.4. Back-Propagation

Backpropagation atau propogasi balik adalah sebuah metode *Artificial Neural Network* yang menggunakan algoritma

Supervised Learning dan biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron yang ada pada hidden layer

Artificial Neural Network Backpropagation terdiri dari beberapa lapisan, yaitu sebagai berikut :

1. Input Layer

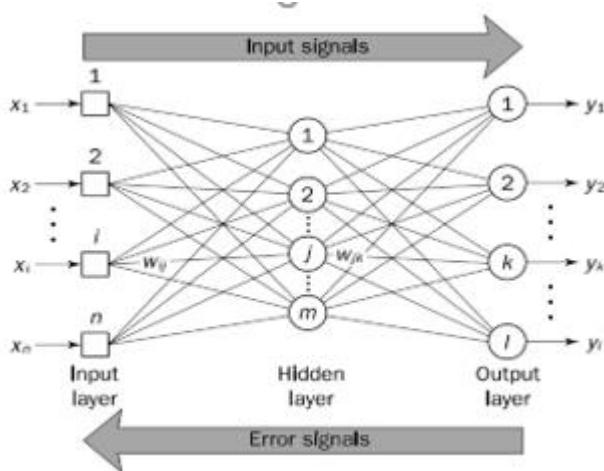
Input layer terdiri atas 1 lapis yang terdiri dari neuron input, mulai dari neuron input pertama sampai neuron input ke- n . *Input layer* mengirimkan sinyal ke *hidden layer* untuk diproses menggunakan fungsi aktifasi.

2. Hidden Layer

Hidden layer bisa terdiri dari lebih dari satu layer. Setiap neuron yang ada pada hidden layer terhubung dengan output layer dan input layer. Pada *Hidden layer* terdapat fungsi aktifasi. Jumlah hidden neuron yang digunakan dapat berjumlah sampai dengan tak berhingga (\sim).

3. Output Layer

Output layer berjumlah satu lapis yang terdiri dari neuron output mulai dari neuron output pertama sampai neuron output ke- n . Jumlah dari neuron output tergantung dari tipe dan performa dari jaringan saraf itu sendiri.



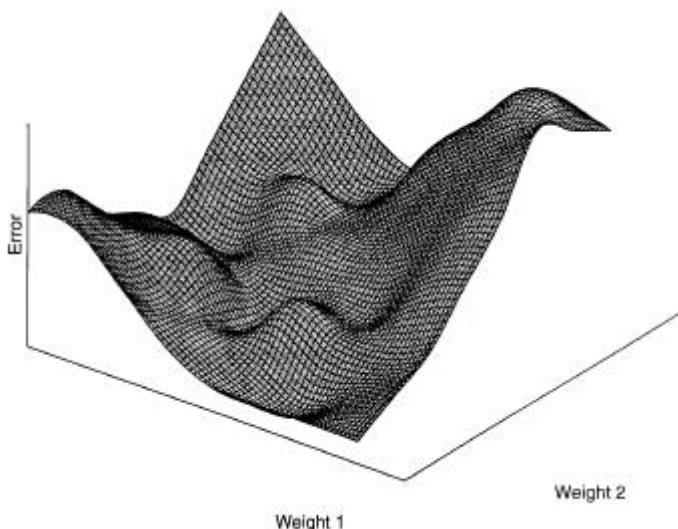
Gambar 2.2 Arsitektur Backpropagation

Pada metode *Artificial Neural Network Backpropagation*, terdapat 3 tahapan dalam proses pelatihannya, yaitu sebagai berikut:

1. Proses umpan maju (*Feedforward*) dari input
2. Perhitungan dan propogasi balik (*Backpropagation*) dari nilai error yang dihasilkan
3. Penyesuaian nilai bobot berdasarkan error output.

Metode pelatihan back-propagation atau dikenal dengan Generalize Delta Rule (GDR) ini merupakan supervised training dimana untuk tiap pola input terdapat pasangan target output untuk masing-masing pola input. Sebenarnya adalah metode *gradient descent* untuk mencari error minimum pada keluaran hasil perhitungan *network*. Ide dasarnya dapat dideskripsikan dengan pola hubungan yang sederhana yaitu : jika output memberikan hasil yang tidak sesuai dengan target yang tidak diinginkan, maka pembobot akan dikoreksi agar

errornya dapat diperkecil dan selanjutnya respon jaringan diharapkan akan lebih mendekati nilai yang sesuai.



Gambar 2.3 Local Gradient Error

Pada umumnya tujuan ANN melakukan proses pelatihan adalah untuk mendapatkan keseimbangan antara kemampuan jaringan untuk menanggapi secara benar pola-pola input pada saat pelatihan (dapat dikatakan kemampuan mengingat) dan kemampuan untuk memberikan penilaian yang layak dari suatu pola masukkan lain yang serupa. Sehingga dari proses pelatihan tersebut akan dibentuk suatu harga pembobot yang akan digunakan sebagai faktor penggali dari pola masukkan yang lain.

Secara sederhana, back-propagation adalah untuk mencari *global loss minimum* dimana setelah rangkaian penyesuaian antara menaikkan dan menurunkan bobot maka ditemukan bobot yang nilai eror nya *minimum* atau terkecil.

2.2.5 Evaluasi Kinerja Model

Peramalan berfokus pada berapa tingkat akurasi dari hasil peramalan. Akurasi dapat menilai seberapa baik sebuah model peramalan yang telah dibuat dan mengolah data ramalan. Oleh karena itu, setelah mendapatkan hasil peramalan dari model *Artificial Neural Network*, perlu dilakukan validitas untuk mengetahui seberapa akurat hasil peramalan dan juga seberapa cocok model yang telah dibuat. Berikut adalah beberapa cara mengetahui berapa akurasi dari model yang telah dibuat:

1. *Mean Squared Error (MSE)*, merupakan rata-rata jumlah kuadrat kesalahan peramalan.

$$\bullet \quad MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - Y_t')^2$$

2. *Root Mean Square Error (RMSE)*, merupakan akar dari nilai yang diperoleh dalam MSE. Semakin kecil nilai RMSE, semakin baik tingkat akurasi prediksinya.

$$\bullet \quad RMSE = \sqrt{MSE}$$

3. *Mean Absolute Percentage Error (MAPE)*, menghitung rata persentase kesalahan pertama dari beberapa periode. Semakin kecil nilai MAPE, semakin baik tingkat akurasi prediksinya.

$$\bullet \quad MAPE = \frac{100}{n} \sum_{t=1}^n \frac{(Y_t - Y_t')}{Y_t}$$

Tabel 2.1 Signifikansi MAPE

MAPE	Signifikansi
<10%	Kemampuan peramalan sangat baik
10-20%	Kemampuan peramalan baik
20-50%	Kemampuan peramalan layak
>50%	Kemampuan peramalan buruk

4. *Mean Absolute Deviation (MAD)*, mengukur dengan mengambil jumlah nilai absolut dari tiap kesalahan peramalan dibagi dengan jumlah periode data. Semakin kecil nilai MAD, semakin baik tingkat akurasi prediksinya.

$$\bullet \quad MAD = \frac{\sum(Y - Y'_{t})}{n}$$

Y_t = nilai observasi

Y'_{t} = nilai peramalan

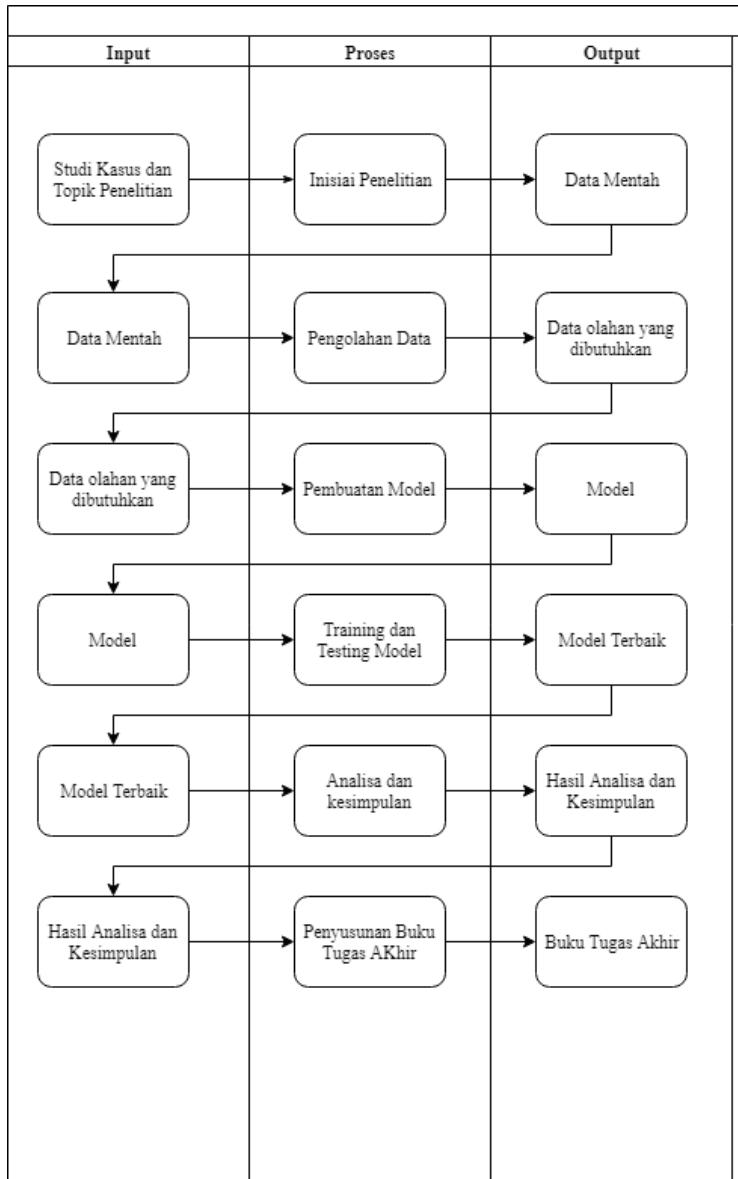
BAB III

METODOLOGI

Pada bab ini dijelaskan mengenai langkah – langkah pengerjaan tugas akhir mulai dari tahap awal sampai akhir. Pada bagian ini juga dijelaskan mengenai jadwal pengerjaan tugas akhir agar proses pengerjaan lebih teratur dan terkontrol.

3.1 Tahapan Pengerjaan Tugas Akhir

Pada penelitian tugas akhir ini terdapat langkah – langkah pengerjaan yang akan dilakukan digambarkan pada gambar 2



Gambar 3.1 Metodologi Penggerjaan Tugas Akhir

3.2 Uraian Metodologi

Pada bagian ini akan dijelaskan lebih detail mengenai langkah – langkah pengerjaan sesuai dengan alur metodologi yang telah dibuat.

3.2.1. Inisiasi Penelitian

Pada tahap ini dilakukan identifikasi masalah yang ada pada studi kasus dan pencarian data. Permasalahan yang diangkat adalah mengenai kebutuhan tepung yang harus tersedia setiap hari sehingga harus dilakukan peramalan. Data yang digunakan untuk penelitian tugas akhir ini adalah data permintaan tepung terigu satu periode Januari 2016 – 31 Desember 2017 yang bersumber dari PT. XYZ.

3.2.2. Pengolahan Data

Pada tahap pengolahan data data, data yang dibutuhkan adalah data permintaan tepung terigu satu periode Januari 2016 – 31 Desember 2017 dengan periode harian. Data yang diperoleh akan diolah agar data siap digunakan. Adapun pengolahan yang dimaksud adalah pembersihan data pada hari minggu dan hari libur nasional serta pengisian data yang kosong menggunakan rata – rata pada periode yang sama [17].

3.2.3. Pembuatan Model

Pada tahap ini dilakukan pemodelan *Artificial Neural Network* yang sesuai dengan penelitian yang akan dilakukan. Penelitian yang dilakukan menggunakan satu buah input dan menghasilkan satu buah output pula. Dari data yang ada tersebut, dapat dibuat pemodelan ANN dengan menentukan jumlah dengan cara menentukan *input layer*, *hidden layer* dan *output layer*. Input layer pada penelitian ini berjumlah 1 dengan

input berjumlah satu pula. Parameter input yang digunakan adalah periode perhari, per tiga hari, dan per minggu. Dari input tersebut didapatkan output dengan menggunakan $Y_{n+1} = f(M_1 M_2 N_1 N_2)$. Variabel Y merupakan output, dan f adalah fungsi sigmoid, sedangkan variabel M dan N merupakan variabel input selama dua periode. Model awal yang akan dibuat menggunakan metode *trial and error* dengan nilai awal 10 nodes dengan satu *hidden layer* yang seiring dilakukannya perhitungan akan bertambah atau berkurang jumlah nodes ataupun *hidden layer*.

3.2.4. Training dan Testing Model

Pada tahap ini dilakukan peramalan dengan menerapkan model *Artificial Neural Network* yang telah dibuat. Dengan menentukan *training function* dan *learning function* dan melakukan pembagian proporsi data training sebesar 80% dan data testing sebesar 20% yang berguna untuk *training* dan *testing data*. Proses ini dilakukan dengan bantuan *software* Matlab [16].

3.2.5. Analisa dan Kesimpulan

Pada tahap ini dilakukan analisa evaluasi terhadap peramalan yang telah dilakukan menggunakan Artificial Neural Network. Tahap evaluasi performa dilakukan dengan cara menghitung *Mean Square Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE). Setelah dilakukan analisa terhadap tingkat akurasi, maka dapat diambil kesimpulan apakah hasil peramalan cocok atau tidak.

3.2.6. Penyusunan Buku Tugas Akhir

Tahap penyusunan buku tugas akhir adalah tahapan terakhir yang dilakukan dengan menyusun buku tugas akhir yang berisi tentang langkah - langkah dan dokumentasi penggerjaan.

3.3 Bahan dan Alat yang digunakan

Pada bab ini dijelaskan tentang bahan dan alat yang akan digunakan dalam pembuatan tugas akhir.

3.3.1 Bahan yang Digunakan

Pada pembuatan tugas akhir ini bahan yang digunakan adalah data permintaan tepung terigu periode harian di PT.XYZ pada 1 Januari 2016 sampai dengan 31 Desember 2017.

3.3.2. Alat yang Digunakan

Pada penelitian ini digunakan alat berupa perangkat lunak Microsoft Excel 2013 untuk melakukan pra processing data dan visualisasi data serta perangkat lunak Matlab versi R2016a untuk melakukan training pada data sehingga dapat dicari model terbaiknya.

Halaman ini sengaja dikosongi

BAB IV

PERANCANGAN

Pada bab ini akan dijelaskan mengenai perancangan yang akan dilakukan untuk mengerjakan tugas akhir mulai dari pengumpulan data, *pra-processing* data, pembagian data, perancangan model, *processing data*, dan analisa hasil model.

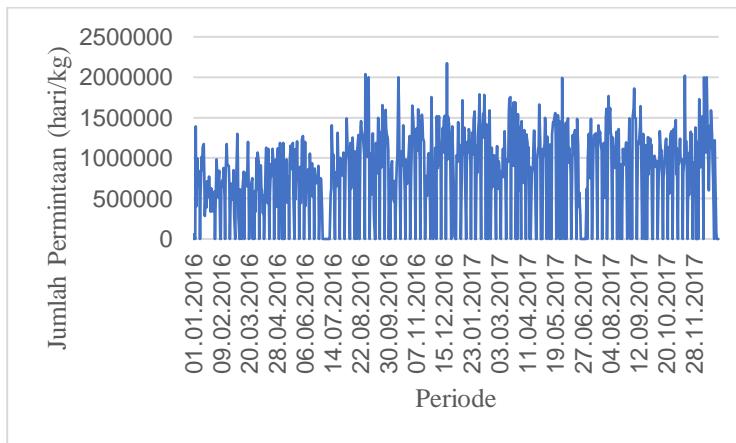
4.1 Pengumpulan data

Data permintaan tepung terigu pada penelitian ini didapatkan dari PT.XYZ. Data didapatkan dengan cara kerja praktek lapangan dengan izin dari manager yang bertanggung jawab. Data yang didapatkan berupa file .xls dengan data permintaan tepung terigu per kg dengan periode harian. Data permintaan tepung terigu bisa dilihat pada tabel 4.3

Tabel 4.1 Data Permintaan Tepung per kg

Tanggal	Permintaan
02.01.2016	62500
04.01.2016	1394300
05.01.2016	399900
06.01.2016	995500
07.01.2016	646800
.....	...
23.12.2017	972786
26.12.2017	1224223
27.12.2017	787642
28.12.2017	73758

Data permintaan tepung terigu secara visual bisa dilihat pada gambar 4.1. Berdasarkan gambar 4.1, dapat dilihat bahwa karakteristik data yang digunakan pada penelitian ini bersifat fluktuatif. Dari studi yang pernah dilakukan, metode *Artificial Neural Network* sudah teruji secara efektif dalam meramalkan untuk tipe data yang tidak memiliki pola dan *non linier* [14]. Dalam studi tersebut, hasil peramalan menggunakan Artificial Neural Network dibandingkan dengan *Auto Regressive Integrated Moving Average* (ARIMA). Hasilnya, Peramalan menggunakan metode Artificial Neural Network lebih akurat daripada metode *Auto Regressive Integrated Moving Average*. Hasil peramalan dari *Artifial Neural Network* cenderung mengikuti trend data sebenarnya, sedangkan hasil peramalan *Regressive Integrated Moving Average* cenderung konstan mengikuti trend [1].



Gambar 4.1 Permintaan Tepung per kg per hari

4.2 Pra-processing Data

Pada tahapan ini akan dilakukan pra-*processing* data yang bertujuan agar data mentah yang didapatkan layak untuk digunakan penelitian. Pra-*processing* data pada penelitian ini yaitu penanganan terhadap data kosong. Data kosong pada

penelitian ini terjadi karena terdapat hari libur, sehingga pada waktu tertentu data menjadi kosong.

Tabel 4.2 Data mengandung data kosong

Tanggal	Jumlah
01.01.2016	0
02.01.2016	62500
03.01.2016	0
04.01.2016	1394300
05.01.2016	399900
06.01.2016	995500
07.01.2016	646800
08.01.2016	847800
09.01.2016	624750
10.01.2016	0

Untuk mengatasi data kosong, terdapat beberapa metode sederhana yang bisa dilakukan, antara lain :

1. Menghapus data

Metode menghapus data bisa digunakan ketika data yang dihapus tidak memengaruhi struktur *time series*. Pada penelitian ini dilakukan metode menghapus data untuk data setiap hari minggu.[17]. Pada penelitian ini, dilakukan penghapusan data yang mengakibatkan perubahan struktur time series. Hal ini berakibat pada tingkat performa yang tergolong jelek. Dapat dilihat pada bab 6 yaitu kesimpulan.

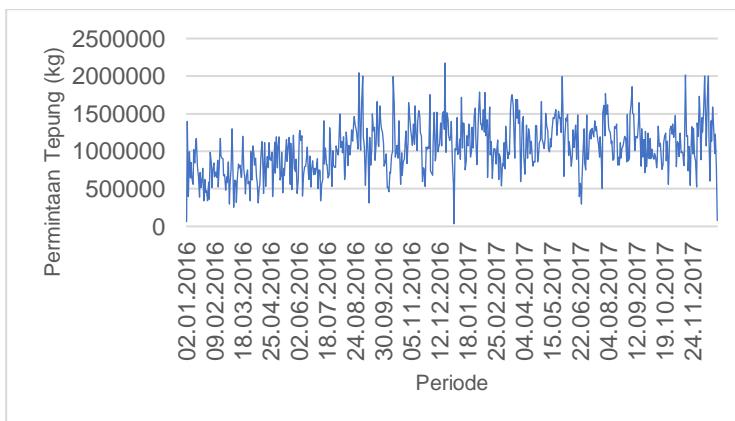
2. Menghitung nilai rata – rata atau modus untuk diisikan ke data kosong

Mengisi data kosong menggunakan rata – rata pada data yang ada dapat menjadi alternatif ketika metode menghapus data tidak bisa dilakukan karena merusak struktur *time series*. Metode ini menghitung nilai rata – rata pada data yang telah ada dan diisikan ke data yang kosong. Pada penelitian ini tidak dilakukan metode ini. [17]

Setelah dilakukan proses penanganan data kosong, maka dihasilkan data pada tabel 4.2

Tabel 4.3 Data setelah di pra processing

Tanggal	Jumlah
02.01.2016	62500
04.01.2016	1394300
05.01.2016	399900
06.01.2016	995500
07.01.2016	646800
08.01.2016	847800
09.01.2016	624750



Gambar 4.2 Permintaan Tepung Terigu setelah Pra Processing

4.3 Pembagian Data

Pada tahapan ini dilakukan pembagian data pelatihan dan data pengujian dengan proporsi 80% untuk data pelatihan dan 20% untuk data pengujian. Sehingga, dari 586 data terbagi menjadi 468 data pelatihan dan 128 data pengujian. Data Pelatihan dapat dilihat pada tabel 4.2 dan data pengujian dapat dilihat pada tabel 4.3.

Tabel 4.4 Data Pelatihan

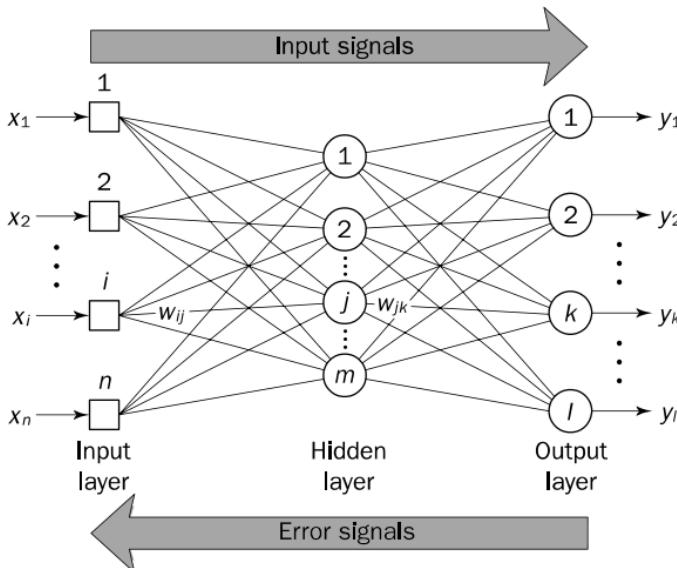
Tanggal	Permintaan
02.01.2016	62500
04.01.2016	1394300
05.01.2016	399900
06.01.2016	995500
07.01.2016	646800
.....	...
03.08.2017	1619450
04.08.2017	1321750
05.08.2017	1278400
07.08.2017	1252200

Tabel 4.5 Data Pengujian

Tanggal	Permintaan
08.08.2017	1100350
09.08.2017	1131930
10.08.2017	875850
11.08.2017	900750
12.08.2017	1324700
21.08.2017	1112700

4.4 Perancangan Model

Pada tahapan ini dilakukan perancangan model ANN yang terdiri dari beberapa parameter yang harus ditentukan. Model ANN yang digunakan adalah model *Multilayered Feed-Forward Backpropagation*. [19]



Gambar 4.3 Arsitektur Artificial Neural Network

Proses pada *Multilayered Feed-Forward Backpropagation* dapat dijelaskan dengan tahapan seperti berikut

1. Setiap unit input ($i = 1, \dots, n$) menerima sinyal input x_i dan menyebarkan sinyal tersebut ke seluruh unit tersembunyi.
2. Pada setiap unit tersembunyi (X_j , $j = 1, \dots, p$), menjumlahkan sinyal-sinyal input yang sudah berbobot (termasuk biasnya)

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

Setelah itu menghitung sinyal output dari unit tersembunyi dengan menggunakan fungsi aktivasi yang telah ditentukan :

$$X_j = f(X_{in_j})$$

Sinyal output ini selanjutnya dikirim ke seluruh unit pada unit atas (unit output).

3. Tiap-tiap unit output (Y_k , $k = 1, \dots, m$), menjumlahkan bobot sinyal input :

$$Y_{in_k} = w_{0k} + \sum_{i=1}^n x_i w_{ik}$$

Selanjutnya menghitung sinyal output dari unit output bersangkutan dengan menggunakan fungsi aktivasi yang telah ditentukan

$$Y_k = f(Y_{in_k}) \quad (2.2.4)$$

Backpropagation of Error (Propagasi Error)

4. Setiap unit output (Y_k , $k = 1, \dots, m$) menerima suatu pola target yang sesuai dengan pola input pelatihan, untuk menghitung kesalahan (error) antara target dengan output yang dihasilkan jaringan.

$$\delta_k = (t_k - y_k)(y_{in_k})$$

Faktor δ_k digunakan untuk menghitung koreksi error (Δ) yang nantinya akan dipakai untuk memperbaiki w_{jk} , dimana :

$$\Delta w_{jk} = \alpha \delta_k$$

Faktor δ_k kemudian dikirimkan ke lapisan yang berada pada langkah ke-7.

5. Setiap unit tersembunyi (Z_j , $j = 1, \dots, p$) menerima input delta (dari langkah ke-6) yang sudah berbobot

$$\delta_{in_j} = \sum_{k=1}^n \delta_k w_{jk}$$

Kemudian hasilnya dikalikan dengan turunan dari fungsi aktivasi yang digunakan jaringan untuk menghitung informasi kesalahan error , dimana :

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

Kemudian hitunglah koreksi bobot untuk memperbaiki

$$v_{ij}$$

$$\Delta v_{ij} = \alpha \delta_j x_1$$

Setelah itu hitung koreksi bias (digunakan untuk memperbaiki v_{0j})

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

Adjustment

6. Setiap unit output (Y_k , $k = 1, \dots, m$) memperbaiki bobot dan bias dari setiap unit tersembunyi ($j = 0, \dots, p$)

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

Demikian pula untuk setiap unit tersembunyi (Z , $j = 1, \dots, p$) akan memperbarui bobot dan bias dari setiap unit input ($i = 0, \dots, n$)

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

7. Tes kondisi berhenti apabila error ditemukan . Jika kondisi stop telah terpenuhi, maka pelatihan jaringan dapat dihentikan.

Keterangan :

x_i ($i=1,2,\dots,n$) : neuron input layer

x_i : sinyal input

Z ($j=1,2,\dots,p$) : neuron hidden layer

Z_j : sinyal hidden layer

Y_k (k =1,2,...,m)	: neuron output layer
y_k	: sinyal output
v_{0j}	: bias dari input layer
v_{ij}	: bobot dari input layer
w_{0k}	: bias dari hidden layer
w_{jk}	: bobot dari hidden layer t
t_k	: target output
δ_k	: informasi error output layer
δ_j	: informasi error hidden layer
α	: laju pembelajaran

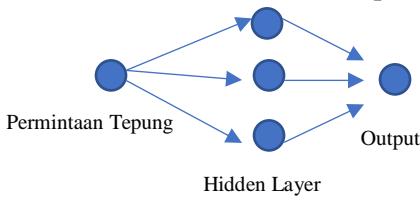
Tahap perancangan model pada penelitian yaitu Menentukan *transfer function*, menentukan *training function*, menentukan *learning function*, menentukan *momentum*, menentukan *learning rate* dan menentukan jumlah *epoch*. Tabel 4.6 merincikan parameter yang akan digunakan dalam penelitian ini.

Tabel 4.6 Parameter yang digunakan

Parameter	
Transfer Function	<i>logsig, tansig, dan purelin</i>
Training Function	<i>trainingdx, trainingda, dan trainlm</i>
Learning Function	<i>learngdm</i>
Momentum	0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, dan 0.9.
Learning Rate	0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, dan 0.9.
Jumlah Epoch	100
Jumlah Node pada Hidden Layer	n sampai dengan 3n. n merupakan periode waktu

4.4.1 Menentukan Node pada Input Layer

Pada tahapan ini dilakukan penentuan node pada input layer. Penentuan Node pada input layer berdasarkan data yang telah didapatkan sebelumnya. Pada penelitian ini node pada input layer adalah permintaan tepung. Output yang akan dihasilkan dari input tersebut adalah Permintaan tepung yang akan datang.



Gambar 4.4 Arsitektur sederhana network

4.4.2 Menentukan Transfer Function

Pada tahap ini dilakukan penentuan parameter Transfer Function yang akan dilakukan pada penelitian ini. Transfer

Function yang akan dipakai adalah *logsig*, *tansig*, dan *purelin* yang didapatkan melalui *trial and error*. *Logsig*, *tansig*, dan *purelin* dipilih karena Transfer Function tersebut sering digunakan pada penelitian terdahulu karena memiliki hasil yang baik [18].

4.4.3 Menentukan Training Function

Pada tahap ini dilakukan penentuan training function yang akan digunakan pada penelitian ini. Training function yang digunakan adalah *trainingdx*, *trainingda*, dan *trainlm* yang didapatkan melalui *trial and error*. *trainingdx*, *trainingda*, dan *trainlm* dipilih karena pada *trainingdx* dan *trainingda* performanya baik saat target kesalahan berkurang, sedangkan untuk *trainlm* berperforma lebih baik saat target kesalahan dikurangi. [19]

4.4.4 Menentukan Learning Function

Pada tahap ini dilakukan penentuan *Learning Function* yang akan digunakan pada penelitian ini, *Learning Function* yang akan digunakan adalah *learngdm* yang didapatkan melalui *trial and error*. *Learning Function* *learngdm* dipilih karena *learngdm* merupakan default learning function yang ada pada toolbox nntool pada Matlab. [20]

4.4.5 Menentukan Momentum

Pada tahap ini dilakukan penentuan Momentum yang akan digunakan pada penlitian ini. Momentum yang akan dipakai berjenis array yaitu 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, dan 0.9. Penentuan Momentum dilakukan dengan cara *trial and error*.

4.4.6 Menentukan Learning Rate

Pada tahap ini dilakukan penentuan learning rata yang akan digunakan pada penelitian ini. Learning rate yang akan dipakai berjenis array yaitu 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, dan 0.9. Penentuan Learning Rate dilakukan dengan cara *trial and error*

4.4.7 Menentukan Jumlah Epoch

Pada tahap ini dilakukan penentuan jumlah epoch yang digunakan pada penelitian ini. Epoch yang akan digunakan berjumlah 100 epoch yang ditentukan dari proses *trial and error*.

4.4.8 Menentukan Jumlah Node pada hidden layer

Pada tahap ini dilakukan penentuan jumlah node pada hidden layer. Penentuan jumlah node pada hidden layer dilakukan dengan memberikan batasan sejumlah $n - 3n$ dengan n merupakan periode waktu.

4.5 Eksperimen Model

Pada tahapan ini dilakukan eksperimen model yang berupa kombinasi antara parameter yang telah dipilih dengan banyaknya jumlah percobaan yang akan dilakukan. Percobaan yang dilakukan sebanyak tiga kali setiap modelnya. Sebuah model didapatkan dari kombinasi atas parameter *transfer function*, *training function*, *learning function*, *momentum*, *learning rate* dan jumlah node yang ditraining dengan *epoch* sebanyak 100. Tabel 4.7 merupakan penjelasan tentang parameter model yang digunakan

Tabel 4.7 Parameter Model

Parameter	
Transfer Function	<i>logsig</i> , <i>tansig</i> , dan <i>purelin</i>
Training Function	<i>trainngdx</i> , <i>trainngda</i> , dan <i>trainlm</i>
Learning Function	<i>learngdm</i>
Momentum	0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, dan 0.9.
Learning Rate	0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, dan 0.9.
Jumlah Epoch	100
Jumlah Node pada Hidden Layer	n sampai dengan $3n$. n merupakan periode waktu

Dari kombinasi parameter tersebut, dapat didapatkan hasil kombinasi $3 \times 3 \times 1 \times 9 \times 9$ sehingga menghasilkan 729 setiap node hidden layernya.

Model yang telah dihasilkan akan disimpan kedalam bentuk file .xls dengan format nama a_b_c_d_e. Penjelasan masing-masing kode dapat dilihat pada tabel 4.8

Tabel 4.8 Penjelasan nama file pada model

Kode	Parameter	Value
a	Transfer Function	1 = logsig 2 = tansig 3 = purelin
b	Training Function	1 = trainingdx 2 = trainingda 3 = trainlm
c	Momentum	1 = 0.1 2 = 0.2 9 = 0.9
d	Learning Rate	1 = 0.1 2 = 0.2 9 = 0.9
e	Node pada hidden layer	Jumlah node (n sampai dengan 3n) dengan n adalah periode

4.6 Processing Data

Pada tahapan ini dilakukan pemrosesan data didalam aplikasi Matlab dengan menjalankan script yang telah dibuat sebelumnya sesuai dengan parameter yang telah ditentukan. Tahap ini dilakukan tiga kali tiap model. Pada tahap ini, akan menghasilkan bermacam – macam kombinasi model dengan

nilai *Mean Square Error* masing – masing serta hasil training dan testing tiap modelnya.

4.7 Analisa Hasil Model

Pada tahapan ini dilakukan analisa pada tiap model yang telah dihasilkan dengan cara melihat tingkat keakuratan tiap model yang berupa *Mean Square Error*. Setiap model akan dibandingkan nilai MSE pada data *testing* dan dicari nilai MSE paling kecil. Model yang memiliki nilai MSE paling kecil merupakan model terbaik selanjutnya akan dicari nilai MAPE nya untuk mengetahui performa dari model.

BAB V

IMPLEMENTASI

Pada bab ini dijelaskan mengenai pelaksanaan dari penelitian yang akan dilakukan yaitu menentukan model terbaik dengan bantuan *script* pada aplikasi Matlab. Pada bab ini akan dijelaskan pula fungsi dari *script* yang telah dibuat mulai dari Setting Parameter, Inisiasi Parameter pada model ANN, Pembuatan Model, Pembuatan Output, dan Menyimpan hasil model

5.1 Pembagian Data

Pada data yang telah didapatkan sebelumnya, dilakukan pr-processing data dengan membagi data menjadi beberapa periode. Data dalam tiap periode tersebut dibagi lagi menjadi data training dan testing dengan perbandingan 80% untuk data training dan 20% untuk data testing. Data yang telah dibagi akan dibagi lagi menjadi beberapa periode. Satu periode adalah data yang ingin didapatkan nilainya, tergantung kepada satu data sebelumnya. Dua Periode adalah data yang ingin didapatkan nilainya, tergantung kepada dua data sebelumnya. Begitupula untuk tiga periode dan seterusnya.

Tabel 5.1 Contoh Satu periode

Input	Target
Data 1	Data 2
Data 2	Data 3
Data 3	Data 4

Tabel 5.2 Contoh Dua periode

Input	Target
Data 1, Data 2	Data 3
Data 2, Data 3	Data 4
Data 3, Data 4	Data 5

Tabel 5.3 dan 5.4 merupakan data input training dan input testing untuk satu periode

Tabel 5.3 Data Training satu periode

Periode	Permintaan
1	1394300
2	399900
3	995500
4	646800
5	847800
.....
463	1489877
464	1619450
465	1321750
466	1278400

Tabel 5.4 Data Testing Satu periode

Periode	Permintaan
1	1131930
2	875850
3	900750
4	1324700
5	1302600
.....
113	1296248
114	972786
115	1224223
116	787642

Tabel 5.5 dan tabel 5.6 merupakan data input training dan input testing untuk dua periode.

Tabel 5.5 Data Training dua periode

Periode	Permintaan
1	62500
2	1394300
3	399900
4	995500
5	646800
.....
463	1768100
464	1489877
465	1619450
466	1321750

Tabel 5.6 Data Testing dua periode

Periode	Permintaan
1	1100350
2	1131930
3	875850
4	900750
5	1324700
.....
113	1591666
114	1296248
115	972786
116	1224223

Tabel 5.7 dan tabel 5.8 merupakan data training dan testing untuk tiga periode

Tabel 5.7 Data Training tiga periode

Periode	Permintaan
1	62500
2	1394300
3	399900
4	995500
5	646800
.....
462	1207200
463	1768100

Tabel 5.8 Data Testing tiga periode

Periode	Permintaan
1	1100350
2	1131930
3	875850
4	900750
5	1324700
6	1302600
7	1359700
8	818300
9	920900
10	813535
11	1112700
12	907650
13	1038573
14	1071550
15	1113075
.....
113	1133084
114	1591666
115	1296248
116	972786

Tabel 5.9 dan 5.10 merupakan data training dan testing untuk empat periode

Tabel 5.9 Data Training empat periode

Periode	Permintaan
1	62500
2	1394300
3	399900
4	995500
5	646800
6	847800
7	624750
8	560200
9	1018100
10	845350
11	1137425
12	1172000
13	798100
14	660300
15	390850
.....
461	1612600
462	1207200
463	1768100
464	1489877

Tabel 5.10 Data Testing empat periode

Periode	Permintaan
1	1100350
2	1131930
3	875850
4	900750
5	1324700
6	1302600
7	1359700
8	818300
9	920900
10	813535
11	1112700
12	907650
13	1038573
14	1071550
15	1113075
.....
111	1402415
112	1133084
113	1591666
114	1296248

Tabel 5.11 dan 5.12 merupakan data training dan testing untuk lima periode.

Tabel 5.11 Data Training Lima periode

Periode	Permintaan
1	62500
2	1394300
3	399900
4	995500
5	646800
6	847800
7	624750
8	560200
9	1018100
10	845350
11	1137425
12	1172000
13	798100
14	660300
15	390850
.....
460	1508725
461	1612600
462	1207200

Tabel 5.12 Data Testing lima periode

Periode	Permintaan
1	1100350
2	1131930
3	875850
4	900750
5	1324700
6	1302600
7	1359700
8	818300
9	920900
10	813535
11	1112700
12	907650
13	1038573
14	1071550
15	1113075
.....
110	601700
111	1402415
112	1133084
113	1591666

5.2 Setting Parameter

Pada tahapan ini dilakukan setting parameter sesuai dengan rancangan yang telah dibuat. Tabel 5.11 menjelaskan tentang parameter yang digunakan.

Tabel 5.13 Settingan Parameter

Transfer Function	Logsig, Tansig, Purelin
Training Function	Traigndx, traingda, trainlm
Momentum	0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9
Learning Rate	0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9
Learning Function	learngdm

Setelah diketahui parameter yang digunakan, maka dilakukan proses pembuatan script dengan script pada script 5.1

```

1 %Setting Parameter
2 - fungsiTransfer={'logsig' 'tansig' 'purelin'};
3 - fungsiTraining={'traingdx' 'traingda' 'trainlm'};
4 - momentum=[0.1,0.2,0.3,0.4,0.5,0.6,0.7,0.8,0.9];
5 - learningRate=[0.1,0.2,0.3,0.4,0.5,0.6,0.7,0.8,0.9];
6 - fungsiPembelajaran={'learngdm'};

7
8
9 - A=numel(fungsiTransfer);
10 - B=numel(fungsiTraining);
11 - C=numel(fungsiPembelajaran);
12 - D=numel(momentum);
13 - E=numel(learningRate);
14 - loopcount = 1;
15

```

Script 5.1 Setting Parameter

Fungsi Script diatas adalah untuk menentukan parameter awal dan membaca parameter yang telah dibuat. Untuk lebih jelas bisa dilihat pada tabel 5.12

Tabel 5.14 Penjelasan fungsi script setting parameter

Script	Fungsi
fungsiTransfer = { }	Menentukan parameter transfer function yang akan digunakan
fungsiTraining = { }	Menentukan paramater training function yang akan digunakan
Momentum = []	Menentukan momentum yang akan digunakan
LearningRate = []	Menentukan learning rate yang akan digunakan
fungsiPembelajaran = { }	Menentukan learning function yang akan digunakan
Numel ()	Membaca dan mengembalikan nilai elemen pada array
loopcount	Variabel untuk menghitung jumlah epoch

5.3 Pembuatan Looping

Pada tahapan ini dilakukan pembuatan looping agar program berjalan secara otomatis tanpa harus melakukan setting lagi. Looping dapat dilakukan dengan membuat *script* seperti gambar script 5.2

```

16 -   for node=9:9
17 -     for a=1:A
18 -       for b=1:B
19 -         for c=1:C
20 -           for d=1:D
21 -             for e=1:E
...

```

Script 5.2 Pembuatan Looping

Adapun penjelasan lebih lengkap fungsi script diatas bisa dilihat pada tabel 5.15

Tabel 5.15 Penjelasan fungsi script Pembuatan Looping

Script	Fungsi
node	Jumlah Node yang akan digunakan pada hidden layer
a=1:A	Transfer function akan dijalankan mulai dari transfer function pertama sampai terakhir
b=1:B	Training Function akan dijalankan mulai dari Training Function pertama sampai terakhir
c=1:C	Learning function akan dijalankan mulai dari learning function pertama sampai terakhir
d=1:D	Momentum akan dijalankan mulai dari momentum pertama sampai terakhir
e=1:E	Learning Rate akan dijalankan mulai dari learning rate pertama sampai terakhir

5.4 Inisiasi Parameter pada model Network

Pada tahap ini dilakukan pembuatan script untuk menjalankan model ANN pada Matlab dengan membaca array pada workbook di matlab yang telah diisi. Script bisa dilihat *script 5.3*

```
%Inisiasi Parameter model ANN
net=newff(inputTraining4, targetTraining4, node, {cell2mat(fungsiTransfer(a)), 'purelin'});
net.trainFcn=cell2mat(fungsiTraining(b));
net.trainParam.lr=learningRate(e);
net.trainParam.mc=momentum(d);
net.trainParam.epochs=100;
net.trainParam.max_fail=100;
net.trainParam.showwindow=false;
%net.trainParam.showcommandline=true;
net.performFcn='mse';
net.layerWeights{1,1}.learnFcn=cell2mat(fungsiPembelajaran(c));
```

Script 5.3 Pembuatan model ANN

Adapun fungsi lebih jelasnya bisa dilihat pada tabel 5.14.

Tabel 5.16 Fungsi Script pembuatan model ANN

Script	Fungsi
net=newff(inputTraining, targetTraining, node, {cell2mat(transferFunc(a)), 'pu relin'});	Membuat model Feed Forward baru dengan input inputTraining dan output targetTraining dengan node tertentu dengan menggunakan function training dan purelin
net.trainFcn=cell2mat(training Func(b));	Menjalankan training function dengan membaca array pada trainingfunc(b)
net.trainParam.lr=learningrate Func(e);	Melakukan training dengan learning rate yang ditentukan pada learningrateFunc(e)
net.trainParam.mc=momen tum(d);	Melakukan training dengan momentum yang ditentukan pada momentum(d)
net.trainParam.epochs=100;	Melakukan training dengan jumlah epoch 100
net.trainParam.max_fail=100;	Melakukan training dengan jumlah kegagalan 100
net.performFcn='mse';	Menggunakan MSE sebagai pengukur performa
net.layerWeights{1,1}.learnFc n=cell2mat(learnFunc(c));	Membaca learning function untuk menghitung output layer selama training dan testing

5.5 Pembuatan Output

Pada tahapan ini dilakukan pembuatan output pada model ANN dengan menghitung nilai MSE yang telah dihasilkan. Script pembuatan output bisa dilihat pada script 5.4

```
'  
%Output training  
outputTraining=netTrain(inputTraining4);  
%Output testing  
outputTesting=sim(netTrain,inputTesting4);  
  
%Error  
errorTraining=outputTraining-targetTraining4;  
errorTesting=outputTesting-targetTesting4;  
  
%mse Training  
mseTrain=mse(errorTraining);  
mseTrain;  
  
%mse Testing  
mseTesting=mse(errorTesting);  
mseTesting;
```

Script 5.4 Pembuatan Output

Penjelasan lebih lengkap untuk script 5.4 diatas bisa dilihat pada tabel 5.17

Tabel 5.17 Penjelasan script pembuatan output

Script	Fungsi
outputTraining=netTrain(inputTraining2);	Menentukan output pada training dengan input berupa input training
outputTesting=sim(netTrain, inputTesting2);	Menentukan output pada testing dengan input berupa input testing
errorTraining=outputTraining-targetTraining2;	Menentukan tingkat error training dengan membandingkan antara output training dengan target training
errorTesting=outputTesting-targetTesting2;	Menentukan tingkat error testing dengan membandingkan antara output testing dengan target testing

BAB VI

HASIL DAN PEMBAHASAN

Pada bagian ini dijelaskan mengenai hasil dan pembahasan dari penelitian yang telah dilakukan. Pada bagian ini terdapat penjelasan mengenai lingkungan kerja penelitian, grafik dan tabel hasil training data, struktur model beserta nilai MSE dan diagramnya, hasil pemilihan model terbaik tiap periode, penjelasan mengenai parameter pada model terbaik terpilih dan performa model.

6.1 Lingkungan Kerja Penelitian

Pada bagian ini dijelaskan tentang lingkungan kerja penelitian yang digunakan baik perangkat keras dan perangkat lunak untuk melakukan penelitian. Adapun perangkat keras yang digunakan adalah laptop dengan spesifikasi pada tabel 6.1.

Tabel 6.1 Perangkat Keras Penelitian

Jenis	Laptop
System Model	ASUS X450JF
Operating System	Windows 8.1
Processor	Core i7-4700HQ @2.40 GHz (8 CPUs)
RAM	8 GB

Perangkat lunak yang digunakan pada penelitian ini beserta fungsinya dapat dilihat pada tabel 6.2.

Tabel 6.2 Perangkat Lunak Penelitian

Matlab R2016a	Melakukan processing data data dan menghasilkan model
Microsoft Excel 2013	Melakukan pra-processing data
Microsoft Word 2013	Menyusun buku laporan tugas akhir
Google Chrome	Alat untuk mencari informasi

6.2 Hasil Testing Data

Pada bagian ini akan ditunjukkan hasil testing yang telah dilakukan. Testing yang dilakukan dilihat dari hasil Mean Square Error pada Testing untuk dapat mencari model terbaiknya setiap periode.

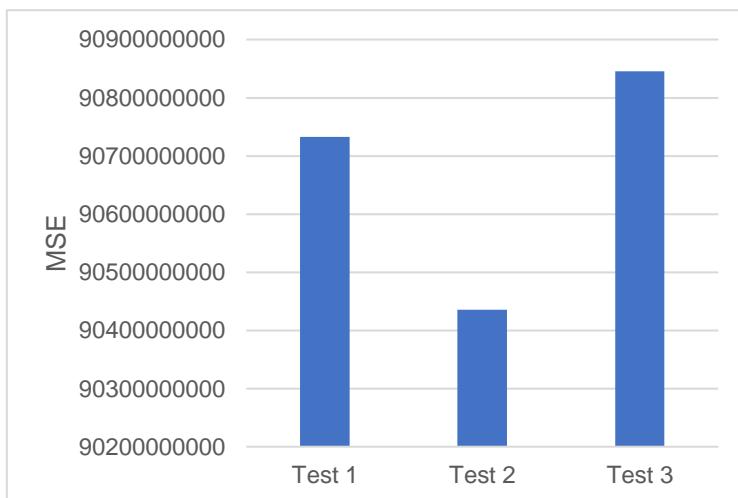
Hasil dari testing data yang telah dilakukan menghasilkan nilai MSE dan MAPE yang digunakan untuk menentukan model terbaik. Model dapat dibaca dengan aturan pada gambar 6.3 dengan urutan parameter adalah TransferFunction_TrainingFunction_Momentum_LearningRate_Node. Sebagai contoh, sebuah model memiliki nama model 1_1_1_3_3, yang berarti model tersebut mempunyai transfer function berupa logsig, training function berupa trainingdx, momentum bernilai 0.1, learning rate bernilai 0.3 dan terdapat pada node 3.

Pada satu periode, jumlah model didapatkan dari kombinasi 3 Transfer Function, 3 Training Function, 9 Momentum, 9 Learning Rate dan 3 node pada hidden layer, sehingga total model yang terbentuk berjumlah 2187 model.

Tabel 6.4 merupakan hasil model terbaik pada satu periode disetiap percobaan selama tiga kali percobaan dengan dipilih model yang memiliki nilai MSE paling kecil pada periode tersebut

Tabel 6.3 Hasil Model Terbaik Satu periode

	MSE	MAPE	Model
Test 1	90733062929	23%	1_3_5_5_3
Test 2	90435700755	22%	2_3_8_9_3
Test 3	90845857427	23%	2_3_7_8_2



Gambar 6.1 Grafik Hasil MSE Tiap percobaan pada satu periode

Dari hasil satu periode, dapat dilihat bahwa model terbaik terdapat pada percobaan kedua dengan model 2_3_8_9_3 dengan nilai MSE sebesar 90435700755. Parameter model terbaik tersebut menggunakan transfer function tansig, training function trainlm, momentum bernilai 0.8, learning rate bernilai 0.9 dan berada pada hidden layer node 3

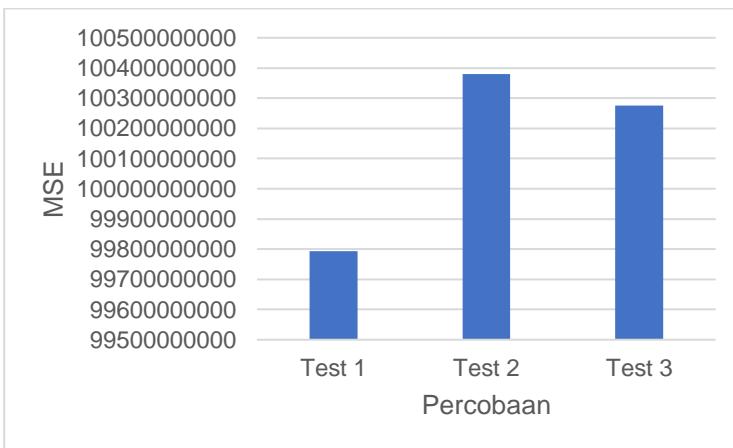
Pada dua periode, jumlah model didapatkan dari kombinasi 3 Transfer Function, 3 Training Function, 9 Momentum, 9

Learning Rate dan 5 node pada hidden layer, sehingga total model yang terbentuk berjumlah 3645 model.

Tabel 6.5 merupakan hasil model terbaik pada dua periode disetiap percobaan selama tiga kali percobaan dengan dipilih model yang memiliki nilai MSE paling kecil pada periode tersebut

Tabel 6.4 Hasil Model Terbaik Dua periode

	MSE	MAPE	Model
Test 1	99794170109.2089	24%	1_3_8_9_6
Test 2	100380104760.2970	25%	1_3_1_2_6
Test 3	100275237652.7730	26%	2_3_7_7_6



Gambar 6.2 Grafik Hasil MSE Tiap percobaan pada dua periode

Dari hasil dua periode, dapat dilihat bahwa model terbaik terdapat pada percobaan kedua dengan mode 1_3_8_9_6

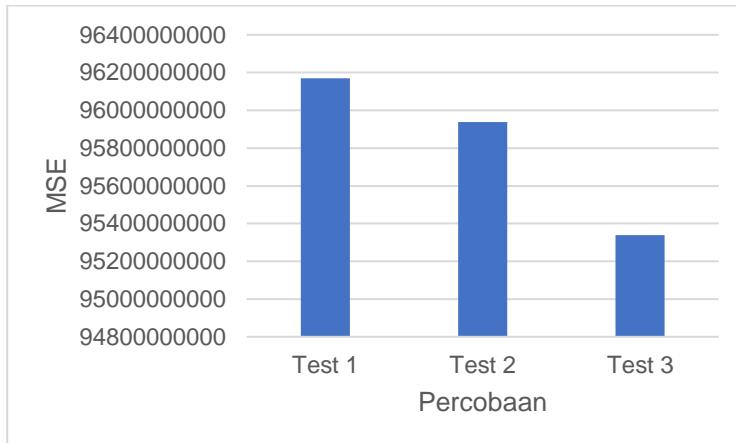
dengan nilai MSE sebesar 99794170109.2089. Parameter model terbaik tersebut menggunakan transfer function logsig, training function trainlm, momentum bernilai 0.8, learning rate bernilai 0.9 dan berada pada hidden layer node 6

Pada tiga periode, jumlah model didapatkan dari kombinasi 3 Transfer Function, 3 Training Function, 9 Momentum, 9 Learning Rate dan 7 node pada hidden layer, sehingga total model yang terbentuk berjumlah 5103 model.

Tabel 6.6 merupakan hasil model terbaik pada tiga periode disetiap percobaan selama tiga kali percobaan dengan dipilih model yang memiliki nilai MSE paling kecil pada periode tersebut

Tabel 6.5 Hasil Model Terbaik Tiga periode

	MSE	MAPE	Model
Test 1	96169208010.4001	23%	2_3_8_5_7
Test 2	95938632799.6305	23%	2_3_7_9_9
Test 3	95338738144.7167	23%	2_3_4_1_9



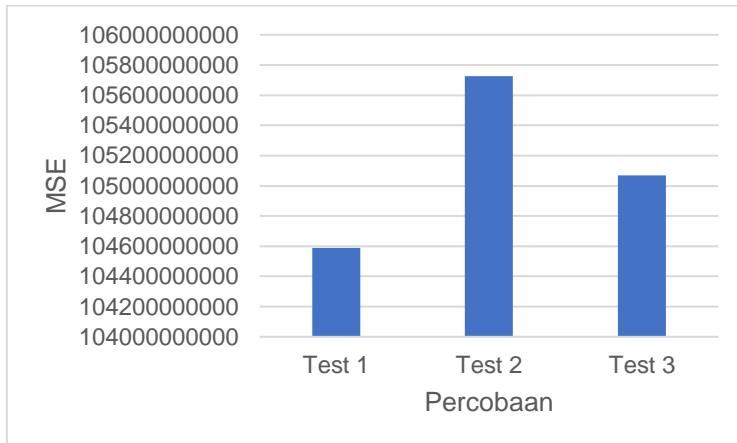
Gambar 6.3 Grafik Hasil MSE Tiap Percobaan pada Tiga periode

Dari hasil tiga periode, dapat dilihat bahwa model terbaik terdapat pada percobaan kedua dengan mode 2_3_4_1_9

dengan nilai MSE sebesar 95338738144.7167. Parameter model terbaik tersebut menggunakan transfer function tansig, training function trainlm, momentum bernilai 0.4, learning rate bernilai 0.1 dan berada pada hidden layer node 9

Tabel 6.6 Hasil Model Terbaik empat periode

	MSE	MAPE	Model
Test 1	104587712814.5350	26%	<u>1_3_4_2_11</u>
Test 2	105727712814.5380	27%	<u>1_3_4_8_10</u>
Test 3	105070409168.3560	27%	<u>2_3_5_3_12</u>



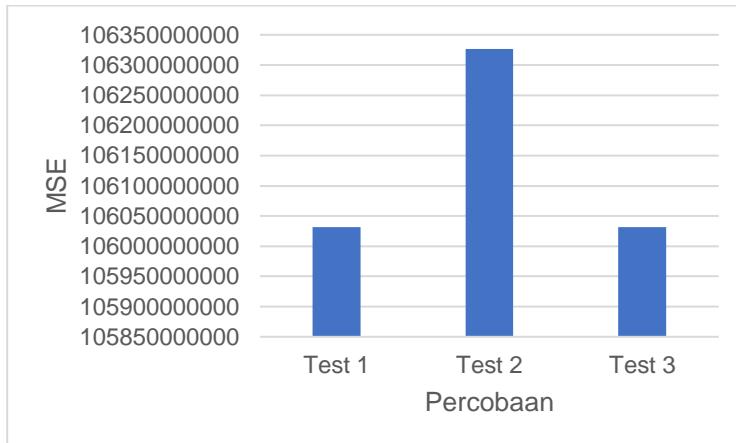
Gambar 6.4 Grafik Hasil MSE Tiap Percobaan pada Tiga periode

Pada empat periode, jumlah model didapatkan dari kombinasi 3 Transfer Function, 3 Training Function, 9 Momentum, 9 Learning Rate dan 9 node pada hidden layer, sehingga total model yang terbentuk berjumlah 6561 model.

Dari hasil empat periode, dapat dilihat bahwa model terbaik terdapat pada percobaan kedua dengan model 1_3_4_2_11 dengan nilai MSE sebesar 104587712814. Parameter model terbaik tersebut menggunakan transfer function logsig, training function trainlm, momentum bernilai 0.4, learning rate bernilai 0.2 dan berada pada hidden layer node 11

Tabel 6.7 Hasil Model Terbaik lima periode

	MSE	MAPE	Model
Test 1	106031293504.0740	27%	2_3_9_9_13
Test 2	106326815047.2360	27%	1_3_1_1_12
Test 3	106031293504.0740	27%	2_3_9_9_13



Gambar 6.5 Grafik Hasil MSE Tiap Percobaan pada Lima periode

Pada lima periode, jumlah model didapatkan dari kombinasi 3 Transfer Function, 3 Training Function, 9 Momentum, 9 Learning Rate dan 11 node pada hidden layer, sehingga total model yang terbentuk berjumlah 8019 model.

Dari hasil lima periode, dapat dilihat bahwa model terbaik terdapat pada percobaan kedua dengan model 2_3_9_9_13

dengan nilai MSE sebesar 106031293504.0740. Parameter model terbaik tersebut menggunakan transfer function tansig, training function trainlm, momentum bernilai 0.9, learning rate bernilai 0.9 dan berada pada hidden layer node 13

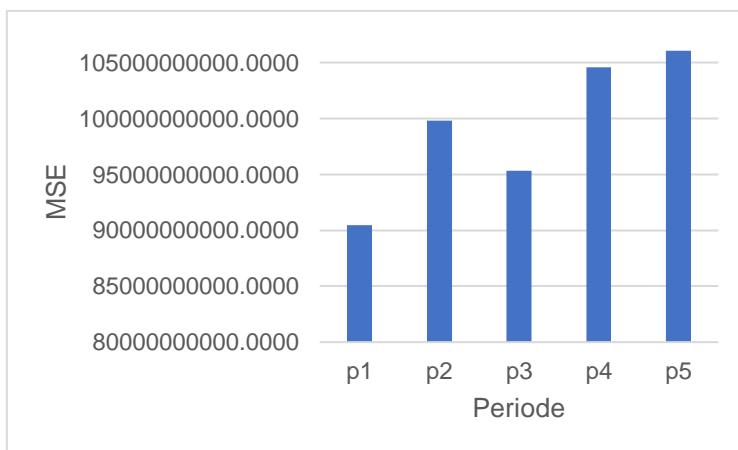
6.3 Model Terbaik

Dari hasil training data tiap periode, dapat diambil model terbaik dari setiap periode. Hasil Model terbaik ini akan dipilih berdasarkan nilai MSE terkecil. Adapun hasil model terbaik tiap periodenya bisa dilihat pada tabel 6.8

Tabel 6.8 Model Terbaik tiap Periode

	MSE	MAPE	Model
p1	90435700755.2866	22%	2_3_8_9_3
p2	99794170109.2089	24%	1_3_8_9_6
p3	95338738144.7167	23%	2_3_4_1_9
p4	104587712814.5350	26%	1_3_4_2_11
p5	106031293504.0740	27%	2_3_9_9_13

Dapat dilihat pada gambar 6.6 perbandingan nilai MSE pada model di tiap periode.



Gambar 6.6 Grafik Perbandingan nilai MSE setiap model terbaik

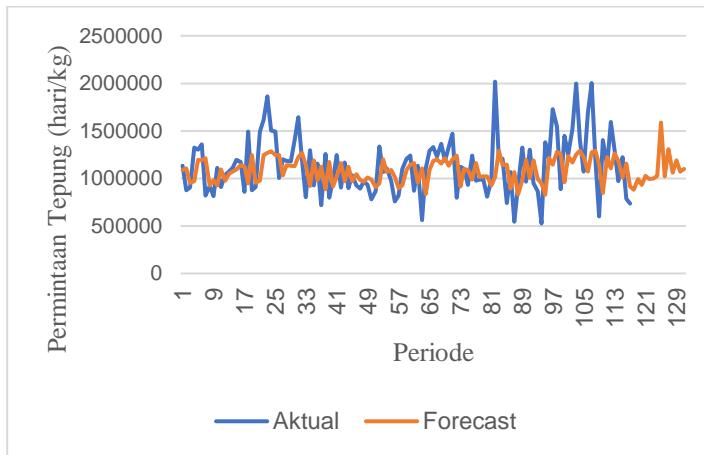
Dari hasil perbandingan antara model terbaik tiap periode, didapatkan model terbaik yang berada pada periode ke tiga karena hasil MSE tiap periode selanjutnya meningkat hingga dua periode kedepan dan tidak mengalami penurunan selama dua periode. Sedangkan satu periode mengalami penurunan pada saat ke tiga periode sehingga masih harus dilakukan sampai lima periode

Model terbaik yang dihasilkan terbentuk dapat dilihat pada tabel 6.9

Tabel 6.9 Struktur Model ANN Terbaik

Parameter	Nilai
Periode	Satu periode
Jumlah Node Input	3
Jumlah Node Hidden Layer	3
Jumlah Node Output Layer	1
Transfer Function	Tansig
Training Function	Trainlm
Momentum	0.8
Learning Rate	0.9

Setelah ditemukan model terbaik, selanjutnya dilakukan evaluasi model dengan menggunakan MAPE. Perhitungan MAPE yang telah dilakukan menghasilkan MAPE sebesar 22%. Gambar 6.7 menunjukkan perbandingan antara data aktual dan forecast.



Gambar 6.7 Grafik Perbandingan antara data aktual dan forecast

Berdasarkan besarnya nilai MAPE yang bernilai 22%, maka dapat disimpulkan bahwa model termasuk kategori layak untuk digunakan sebagai peramalan.

Halaman ini sengaja dikosongi

BAB VII

KESIMPULAN DAN SARAN

7.1 Kesimpulan

Berdasarkan hasil penelitian pada tugas akhir ini, maka dapat disimpulkan bahwa :

1. Model ANN terdapat pada satu periode dengan parameter transfer function menggunakan logsig, training function menggunakan trainlm, momentum bernilai 0,8, learning rate bernilai 0,9 dan berada pada hidden layer node 3,
2. Model ANN terbaik layak untuk digunakan dalam peramalan dengan nilai MAPE sebesar 22%
3. Pada penelitian ini, model yang didapatkan tergolong kurang maksimal, dilihat dari nilai MAPE yang sebesar 22%, dan penggunaan ANN seharusnya memiliki nilai MAPE yang kecil. Hal ini kemungkinan dikarenakan oleh kesalahan pada saat pra processing data dengan cara menghapus data pada hari besar, sehingga merusak struktur time series pada data yang mengakibatkan error yang dihasilkan cukup tinggi. Seharusnya data kosong tersebut tetap dibiarkan nol, atau dilakukan penanganan yang lain, misalnya mengisi data kosong dengan rata – rata data yang telah ada. Dibandingkan dengan sebelumnya, hasil penelitian sebelumnya.

7.2 Saran

Saran yang dapat dilakukan untuk meningkatkan kualitas tugas akhir ini maupun sebagai referensi topik tugas akhir yang akan datang adalah :

1. Meramalkan Kebutuhan tepung terigu dengan ruang lingkup seluruh Indonesia.
2. Menggunakan data yang lebih banyak sehingga hasil peramalan bisa lebih akurat.
4. Menggunakan metode penelitian lain sebagai pembanding agar tahu metode mana yang cocok untuk data yang dimiliki.
5. Menggunakan *Software* selain Matlab untuk mengetahui perbedaan yang akan dihasilkan, contohnya R Studio.

DAFTAR PUSTAKA

- [1] A. A. Adebiyi, A. O. Adewumi, and C. K. Ayo, "Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction," *J. Appl. Math.*, vol. 2014, pp. 1–7, Mar. 2014.
- [2] Perpres nomor 48 Tahun 2016 Tentang Penugasan Kepada Perusahaan Umum (PERUM) BULOG Dalam Rangka Ketahanan Pangan Nasional. (2016), pages 1–8.
- [3] Maulana, A. (2014). Peramalan kebutuhan tepung terigu untuk produksi roti basah pada Perusahaan Roti Ganep's Surakarta.
- [4] Ariski. (2016). Peramalan Permintaan dan Perencanaan Produksi Produk Tepung Segitiga Biru
- [5] Ebrahimi, S., Shajari, S., & Tarazkar, M. H. (2012). Prediction of Agricultural Commodity Price Using Artificial Neural Networks : Case of Chicken Price in Fars province , Iran, 2(11), 11537–11541.
- [6] Gaspersz, Vincent. (2005). Production Planning and Inventory Control. Jakarta : Gramedia Pustaka Utama
- [7] Taylor, Bernand W. (2004). Management Science. Edisi Delapan. Jakarta : Salemba Empat.
- [8] R Hecht-Nielsen, "Theory of the Backpropagation Neural Network," *IJCNN., International Joint Conference*, vol. 1, pp. 593-605, Juni 1989.
- [9] Hani Handoko, 1999, Manajemen, BPFE Yogyakarta, Yogyakarta
- [10] Makridakis, Wheelwright and McGee, (1999). *Metode dan Aplikasi Peramalan* (terjemahan). Jakarta: Binarupa Aksara

- [11] R. Adhikari, “An Introductory Study on Time Series Modeling and Forecasting”.
- [12] Simon S. Haykin, *Neural Networks: A Comprehensive Foundation*. the University of Michigan: Prentice Hall, 1999.
- [13] Claveria, O., & Torra, S. (2014). Forecasting tourism demand to Catalonia: Neural networks vs. time series models. *Economic Modelling*, 36, 220–228.
- [14] Wang, X., Smith-Miles, K., & Hyndman, R. (2009). Rule induction for forecasting method selection: Meta-learning the characteristics of univariate time series. *Neurocomputing*, 72(10–12), 2581–2594.
- [15] Touretzky, D. S. (2006). Backpropagation Learning LMS / Widrow-Hoff Rule. *Artificial Neural Networks*, 486.
- [16] J. Han, M. Kamber, and J. Pei, “Data Mining. Concepts and Techniques, 3rd Edition (The Morgan Kaufmann Series in Data Management Systems),” 2011.
- [17] Humphries, M. (2013). Missing Data & How to Deal: An overview of missing data. *Population Research Center*, 45. Retrieved from <http://www.texaslonghorns1.com/cola/centers/prc/files/cs/Missing-Data.pdf>



Biodata Penulis

Penulis lahir di Surabaya, 10 Agustus 1995, dengan nama lengkap Sigit Tri Baskoro. Penulis merupakan anak ketiga dari tiga bersaudara.

Riwayat pendidikan penulis yaitu SD Negeri Dupak 5, SMP Negeri 2 Surabaya, SMA Negeri 1 Surabaya, dan akhirnya menjadi salah satu mahasiswi Sistem Informasi angkatan 2014 melalui

jalur SNMPTN dengan NRP 5211440000047. Selama kuliah penulis bergabung dalam Unit Kegiatan Mahasiswa, yaitu UKM Catur ITS selama 2 tahun kepengurusan. Penulis juga sering terlibat dalam acara kepanitiaan tingkat jurusan untuk acara nasional, salah satunya adalah dalam acara *big event* milik Sistem Informasi yaitu ISE pada tahun 2014 dan 2015.

Penulis mengambil bidang minat Rekayasa Data dan Intelegrensi Bisnis (RDIB) di Departemen Sistem Informasi ITS. Penulis dapat dihubungi melalui [email sigittribaskoro95@gmail.com](mailto:sigittribaskoro95@gmail.com)

Halaman ini sengaja dikosongi

Lampiran A

Data Aktual

02.01.2016	62500
04.01.2016	1394300
05.01.2016	399900
06.01.2016	995500
07.01.2016	646800
08.01.2016	847800
09.01.2016	624750
11.01.2016	560200
12.01.2016	1018100
13.01.2016	845350
14.01.2016	1137425
15.01.2016	1172000
16.01.2016	798100
18.01.2016	660300
19.01.2016	390850
20.01.2016	715837.5
21.01.2016	515975
22.01.2016	650900
23.01.2016	769850
25.01.2016	336500
26.01.2016	625650
27.01.2016	453600
<u>28.01.2016</u>	479400
29.01.2016	339600
30.01.2016	587750
01.02.2016	363450
02.02.2016	984900
03.02.2016	841350

04.02.2016	514750
05.02.2016	762600
06.02.2016	844000
09.02.2016	658450
10.02.2016	723600
11.02.2016	652300
12.02.2016	877600
13.02.2016	521150
15.02.2016	817900
16.02.2016	1172400
17.02.2016	946000
18.02.2016	909950
19.02.2016	902150
20.02.2016	671350
22.02.2016	685150
23.02.2016	482600
24.02.2016	656350
25.02.2016	582050
26.02.2016	854750
27.02.2016	295750
01.03.2016	552400
02.03.2016	749850
03.03.2016	1298650
04.03.2016	964600
05.03.2016	257750
07.03.2016	613600
08.03.2016	605550
10.03.2016	315800
11.03.2016	652650
12.03.2016	828600
14.03.2016	782350

15.03.2016	817765
16.03.2016	654300
17.03.2016	656100
18.03.2016	1198575
19.03.2016	756800
21.03.2016	631700
22.03.2016	435175
23.03.2016	682850
24.03.2016	750450
26.03.2016	566300
<u>28.03.2016</u>	595125
29.03.2016	338590
30.03.2016	1001900
31.03.2016	617100
01.04.2016	1069050
02.04.2016	957000
04.04.2016	817050
05.04.2016	909850
06.04.2016	630500
07.04.2016	603300
08.04.2016	314600
09.04.2016	533200
11.04.2016	548750
12.04.2016	927750
13.04.2016	1128500
14.04.2016	761150
15.04.2016	441600
16.04.2016	1114050
18.04.2016	534750
19.04.2016	725650
20.04.2016	932400

21.04.2016	778400
22.04.2016	1115660
23.04.2016	896850
25.04.2016	879550
26.04.2016	983650
27.04.2016	395375
<u>28.04.2016</u>	<u>777125</u>
<u>29.04.2016</u>	<u>1121300</u>
<u>30.04.2016</u>	<u>712000</u>
02.05.2016	1189850
03.05.2016	782000
04.05.2016	1038750
07.05.2016	1190000
09.05.2016	616300
10.05.2016	687900
11.05.2016	985350
12.05.2016	447550
13.05.2016	773100
14.05.2016	679500
16.05.2016	944600
17.05.2016	1152850
18.05.2016	866925
19.05.2016	1053400
20.05.2016	1187100
21.05.2016	559050
23.05.2016	1107850
24.05.2016	487700
25.05.2016	1020010
26.05.2016	1209850
27.05.2016	762775
<u>28.05.2016</u>	<u>726850</u>

30.05.2016	892700
31.05.2016	439550
01.06.2016	606450
02.06.2016	1230400
03.06.2016	1273750
04.06.2016	1139650
06.06.2016	1202700
07.06.2016	406500
08.06.2016	688100
09.06.2016	795950
10.06.2016	798250
11.06.2016	866000
13.06.2016	1058680
14.06.2016	709850
15.06.2016	622950
16.06.2016	938500
17.06.2016	522930
18.06.2016	749300
20.06.2016	873310
21.06.2016	687950
22.06.2016	775500
23.06.2016	691350
24.06.2016	775900
25.06.2016	903650
27.06.2016	503400
<u>28.06.2016</u>	749290
29.06.2016	742800
30.06.2016	337150
11.07.2016	560650
12.07.2016	621850
13.07.2016	1406650

14.07.2016	826835
15.07.2016	1044450
16.07.2016	823900
18.07.2016	824650
19.07.2016	644350
20.07.2016	687400
21.07.2016	1313450
22.07.2016	1010550
23.07.2016	531900
25.07.2016	1006450
26.07.2016	813050
27.07.2016	789000
28.07.2016	785800
29.07.2016	1068850
30.07.2016	1004450
01.08.2016	949350
02.08.2016	1063900
03.08.2016	1494700
04.08.2016	1048100
05.08.2016	1127750
06.08.2016	979300
08.08.2016	1188450
09.08.2016	621525
10.08.2016	699050
11.08.2016	1253850
12.08.2016	1070100
13.08.2016	805950
15.08.2016	1080925
16.08.2016	953650
18.08.2016	1115035
19.08.2016	1285250

20.08.2016	1137450
22.08.2016	1383050
23.08.2016	1461425
24.08.2016	1343300
25.08.2016	1276550
26.08.2016	1213600
27.08.2016	1027750
29.08.2016	2041800
30.08.2016	1172750
31.08.2016	1017500
01.09.2016	1650125
02.09.2016	1998400
03.09.2016	1200450
05.09.2016	1057600
06.09.2016	546950
07.09.2016	805750
08.09.2016	1306700
09.09.2016	979650
10.09.2016	308050
13.09.2016	1186200
14.09.2016	812525
15.09.2016	1036050
16.09.2016	1498450
17.09.2016	1268415
19.09.2016	1319000
20.09.2016	881600
21.09.2016	1092975
22.09.2016	1657850
23.09.2016	1093450
24.09.2016	1060650
26.09.2016	1600100

27.09.2016	1365050
28.09.2016	1303000
29.09.2016	1249400
30.09.2016	1099800
01.10.2016	798700
03.10.2016	847500
04.10.2016	961650
05.10.2016	518365
06.10.2016	524850
07.10.2016	460250
08.10.2016	719850
10.10.2016	709800
11.10.2016	942815
12.10.2016	1000450
13.10.2016	1996600
14.10.2016	1627960
15.10.2016	920600
17.10.2016	984550
18.10.2016	1079900
19.10.2016	907110
20.10.2016	1402900
21.10.2016	1017700
22.10.2016	559250
24.10.2016	981500
25.10.2016	682350
26.10.2016	862000
27.10.2016	890450
28.10.2016	1168204
29.10.2016	1271700
31.10.2016	836050
01.11.2016	1131115

02.11.2016	1647550
03.11.2016	1451830
04.11.2016	1267800
05.11.2016	1223050
07.11.2016	1075400
08.11.2016	1363100
09.11.2016	1093450
10.11.2016	1602450
11.11.2016	1227950
12.11.2016	1007750
14.11.2016	1400900
15.11.2016	1536205
16.11.2016	1463825
17.11.2016	1248100
18.11.2016	1199850
19.11.2016	592000
21.11.2016	777003
22.11.2016	759350
23.11.2016	533800
24.11.2016	1056196
25.11.2016	1022300
26.11.2016	1059850
<u>28.11.2016</u>	1037250
29.11.2016	1754700
30.11.2016	740150
01.12.2016	707810
02.12.2016	679400
03.12.2016	1130650
05.12.2016	1520850
06.12.2016	873900
07.12.2016	924500

08.12.2016	1520000
09.12.2016	994590
10.12.2016	1076700
12.12.2016	1086300
13.12.2016	1373250
14.12.2016	1068650
15.12.2016	1464200
16.12.2016	1525500
17.12.2016	1293237
19.12.2016	2173650
20.12.2016	983860
21.12.2016	1512825
22.12.2016	1421252
23.12.2016	1210051
24.12.2016	1141250
26.12.2016	1211450
27.12.2016	1395550
<u>28.12.2016</u>	866000
29.12.2016	562950
30.12.2016	34300
02.01.2017	1035200
03.01.2017	1015915
04.01.2017	1445000
05.01.2017	959675
06.01.2017	983300
07.01.2017	1159750
09.01.2017	896500
10.01.2017	1714800
11.01.2017	1044050
12.01.2017	1378250
13.01.2017	1369947

14.01.2017	749800
16.01.2017	871000
17.01.2017	1202600
18.01.2017	1068550
19.01.2017	1359575
20.01.2017	1310350
21.01.2017	925150
23.01.2017	1004150
24.01.2017	1322850
25.01.2017	1040050
26.01.2017	1475550
27.01.2017	1574250
30.01.2017	1152700
31.01.2017	819704
01.02.2017	1273900
02.02.2017	1484000
03.02.2017	1788620
04.02.2017	1365300
06.02.2017	1365300
07.02.2017	1287250
08.02.2017	1553000
09.02.2017	1254500
10.02.2017	1781600
11.02.2017	1206100
13.02.2017	1418150
14.02.2017	650150
16.02.2017	1203150
17.02.2017	1589900
18.02.2017	948400
20.02.2017	1126150
21.02.2017	638300

22.02.2017	962695
23.02.2017	1033375
24.02.2017	1027500
25.02.2017	831250
27.02.2017	991050
28.02.2017	1146700
01.03.2017	620375
02.03.2017	962350
03.03.2017	915750
04.03.2017	536500
06.03.2017	833950
07.03.2017	798650
08.03.2017	1116650
09.03.2017	768550
10.03.2017	1332250
11.03.2017	1067550
13.03.2017	901650
14.03.2017	983750
15.03.2017	954100
16.03.2017	1559350
17.03.2017	1736450
18.03.2017	1752250
20.03.2017	1612000
21.03.2017	1126551
22.03.2017	906950
23.03.2017	1690805
24.03.2017	1441250
25.03.2017	1689200
27.03.2017	1366800
29.03.2017	1543900
30.03.2017	598162.5

31.03.2017	788600
01.04.2017	1384550
03.04.2017	1459953
04.04.2017	922265
05.04.2017	694500
06.04.2017	1093750
07.04.2017	1348950
08.04.2017	908755
10.04.2017	1296300
11.04.2017	1191200
12.04.2017	964700
13.04.2017	1133250
15.04.2017	889300
17.04.2017	798000
18.04.2017	865300
19.04.2017	861050
20.04.2017	1341950
21.04.2017	1340230
22.04.2017	858650
25.04.2017	982600
26.04.2017	1113900
27.04.2017	1146150
28.04.2017	1661600
29.04.2017	1172200
02.05.2017	1115750
03.05.2017	1032850
04.05.2017	1180200
05.05.2017	1501025
06.05.2017	1331000
08.05.2017	1270500
09.05.2017	1032550

10.05.2017	989904
12.05.2017	1168550
13.05.2017	1058850
15.05.2017	1296000
16.05.2017	1447085
17.05.2017	1432355
18.05.2017	1484200
19.05.2017	1556725
20.05.2017	1210000
22.05.2017	1335700
23.05.2017	1531250
24.05.2017	1438600
26.05.2017	1450250
27.05.2017	1251700
29.05.2017	1990200
30.05.2017	1292000
31.05.2017	662975
02.06.2017	1207160
03.06.2017	1437350
05.06.2017	1406650
06.06.2017	1489675
07.06.2017	944350
08.06.2017	1129750
09.06.2017	1004750
10.06.2017	801050
12.06.2017	951300
13.06.2017	1284600
14.06.2017	1047900
15.06.2017	1247565
16.06.2017	1349075
17.06.2017	890480

19.06.2017	1483925
20.06.2017	1138030
21.06.2017	394500
22.06.2017	572100
23.06.2017	295000
01.07.2017	619300
03.07.2017	985500
04.07.2017	1299820
05.07.2017	845000
06.07.2017	751800
07.07.2017	1482425
08.07.2017	895300
10.07.2017	891900
11.07.2017	1220000
12.07.2017	1287350
13.07.2017	1161440
14.07.2017	1304400
15.07.2017	1236650
17.07.2017	1193300
18.07.2017	1402664
19.07.2017	1267090
20.07.2017	1328250
21.07.2017	1186050
22.07.2017	1091900
24.07.2017	922800
25.07.2017	1189025
26.07.2017	946750
27.07.2017	505700
28.07.2017	1508725
29.07.2017	1612600
31.07.2017	1207200

01.08.2017	1768100
02.08.2017	1489877
03.08.2017	1619450
04.08.2017	1321750
05.08.2017	1278400
07.08.2017	1252200
08.08.2017	1100350
09.08.2017	1131930
10.08.2017	875850
11.08.2017	900750
12.08.2017	1324700
14.08.2017	1302600
15.08.2017	1359700
16.08.2017	818300
18.08.2017	920900
19.08.2017	813535
21.08.2017	1112700
22.08.2017	907650
23.08.2017	1038573
24.08.2017	1071550
25.08.2017	1113075
26.08.2017	1195750
28.08.2017	1170155
29.08.2017	857050
30.08.2017	1492900
31.08.2017	873350
02.09.2017	908400
04.09.2017	1489950
05.09.2017	1616300
06.09.2017	1862175
07.09.2017	1501950

08.09.2017	1492130
09.09.2017	1004400
11.09.2017	1198625
12.09.2017	1184294
13.09.2017	1176762
14.09.2017	1395560
15.09.2017	1643107
16.09.2017	1189142
18.09.2017	801124
19.09.2017	1298356
20.09.2017	923235
22.09.2017	1158380
23.09.2017	719190
25.09.2017	1259578
26.09.2017	796952
27.09.2017	984075
28.09.2017	1243600
29.09.2017	903243
30.09.2017	1166770
02.10.2017	897776
03.10.2017	1030334
04.10.2017	923459
05.10.2017	892560
06.10.2017	968450
07.10.2017	931526
09.10.2017	782755
10.10.2017	861800
11.10.2017	1333061
12.10.2017	1066960
13.10.2017	1104477
14.10.2017	975490

16.10.2017	758684
17.10.2017	820146
18.10.2017	1097292
19.10.2017	1208508
20.10.2017	1242236
21.10.2017	868776
23.10.2017	1133610
24.10.2017	561924
25.10.2017	1106695
26.10.2017	1293144
27.10.2017	1330450
28.10.2017	1228295
30.10.2017	1362018
31.10.2017	1181490
01.11.2017	1329224
02.11.2017	1472362
03.11.2017	796512
04.11.2017	1124300
06.11.2017	1101250
07.11.2017	931804
08.11.2017	1241062
09.11.2017	975173
10.11.2017	989640
11.11.2017	986050
13.11.2017	810620
14.11.2017	981768
15.11.2017	2017512
16.11.2017	1199292
17.11.2017	1204575
18.11.2017	740578
20.11.2017	1063850

21.11.2017	543552
22.11.2017	917638
23.11.2017	1326246
24.11.2017	963228
25.11.2017	1302691
27.11.2017	946359
28.11.2017	861680
29.11.2017	525842
30.11.2017	1379059
02.12.2017	1200462
04.12.2017	1728428
05.12.2017	1541676
06.12.2017	886586
07.12.2017	1448629
08.12.2017	1252192
09.12.2017	1518300
11.12.2017	1999500
12.12.2017	1403462
13.12.2017	1069236
14.12.2017	1695038
15.12.2017	2000534
16.12.2017	1202678
18.12.2017	601700
19.12.2017	1402415
20.12.2017	1133084
21.12.2017	1591666
22.12.2017	1296248
23.12.2017	972786
26.12.2017	1224223
27.12.2017	787642
28.12.2017	737580

