



---

TESIS - PM 092315

**MODEL PENDUKUNG KEPUTUSAN UNTUK  
PERENCANAAN PRODUKSI PIPA BAJA DENGAN  
MENGUNAKAN *NEURAL NETWORK* DI  
PT. STEEL PIPE INDUSTRY OF INDONESIA TBK.**

IDA BAGUS OKA ARI ADNYANA  
NRP 9113205315

DOSEN PEMBIMBING  
PROF. DR. DRS. M. ISA IRAWAN, MT.

PROGRAM MAGISTER MANAJEMEN TEKNOLOGI  
BIDANG KEAHLIAN MANAJEMEN TEKNOLOGI INFORMASI  
PROGRAM PASCA SARJANA  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2015



---

THESIS - PM 092315

**DECISION SUPPORT MODEL TO SUPPORT OF STEEL  
PIPE PRODUCTION PLANNING USING NEURAL  
NETWORK IN PT. STEEL PIPE INDUSTRY OF  
INDONESIA TBK**

IDA BAGUS OKA ARI ADNYANA  
NRP 9113205315

SUPERVISOR  
PROF. DR. DRS. M. ISA IRAWAN, MT.

MASTER OF TECHNOLOGY MANAGEMENT  
INFORMATION TECHNOLOGY MANAGEMENT CONCENTRATION  
MASTER PROGRAM  
SEPULUH NOPEMBER INSTITUTE OF TECHNOLOGY  
SURABAYA  
2015

## LEMBAR PENGESAHAN

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar  
Magister Manajemen Teknologi (M.MT)  
di  
Institut Teknologi Sepuluh Nopember

oleh :

Ida Bagus Oka Ari Adnyana  
NRP. 9113205315

Tanggal Ujian : 29 Juli 2015  
Periode Wisuda : September 2015

Disetujui oleh :

1. Prof. Dr. Drs. M. Isa Irawan, MT  
NIP. 19631225 198903 1 001




(Pembimbing)

2. Prof. Dr. Ir. Joko Lianto Buliali, M.Sc  
NIP. 19670727 199203 1 002



(Penguji)

3. Daniel Oranova S., S.Kom, M.Sc, PDEng  
NIP. 19741123 200604 1 001



(Penguji)

- Direktur Program Pascasarjana,



Prof. Dr. Ir. Adi Soeprijanto, M.T  
NIP. 19640405 199002 1 001

# MODEL PENDUKUNG KEPUTUSAN SEBAGAI PENDUKUNG PERENCANAAN PRODUKSI PIPA BAJA DENGAN MENGUNAKAN NEURAL NETWORK DI PT. STEEL PIPE INDUSTRY OF INDONESIA TBK.

Nama Mahasiswa : Ida Bagus Oka Ari Adnyana  
NRP : 9113205315  
Pembimbing : Prof. Dr. Drs. M. Isa Irawan, MT.

## ABSTRAK

Pembangunan infrastruktur berperan signifikan dalam mendorong pertumbuhan dan pembangunan ekonomi Indonesia. Saat ini, pada PT. Steel Pipe Industry of Indonesia Tbk sering terjadi ketidaksinambungan antara rencana produksi dengan proses produksi. Hal ini menyebabkan biaya yang besar untuk barang-barang yang tidak terjual ke pelanggan yang disimpan pada gudang. Sistem pendukung untuk merencanakan proses produksi yang berkelanjutan pada perusahaan diharapkan dapat melakukan manajemen terhadap perencanaan proses produksi. Metode pemodelan data yang digunakan adalah pemodelan *neural network* untuk meramalkan permintaan produk. Pada penelitian ini dibandingkan antara model peramalan *time series* dengan model multivariabel kemudian dicari model terbaik. Data yang digunakan dalam penelitian ini adalah data permintaan produk bulanan pipa baja pada PT. Steel Pipe Industry of Indonesia Tbk dan beberapa data pendukung lainnya. Hasil permodelan antara model univariabel dan multivariabel didapatkan perbandingan dengan menggunakan statistik RMSE bahwa untuk permintaan produk pipa dalam memprediksi permintaan pipa lebih baik menggunakan model *neural network* dengan multivariabel. Hasil peramalan permintaan pipa baja dengan model *neural network* dalam mendukung perencanaan pada produksi di PT. Steel Pipe Industry of Indonesia Tbk. pada bulan September 2014 di prediksi akan mengalami peningkatan permintaan produk pipa.

Kata kunci: *Neural Network, Time Series, Multivariabel, Decision Support System*

# **DECISION SUPPORT MODEL TO SUPPORT OF STEEL PIPE PRODUCTION PLANNING USING NEURAL NETWORK IN PT. STEEL PIPE INDUSTRY OF INDONESIA TBK**

Student Name : Ida Bagus Oka Ari Adnyana

NRP : 9113205315

Advisor Lecturer : Prof. Dr. Drs. M. Isa Irawan, MT.

## **ABSTRACT**

Infrastructure development as significant role in promoting growth and economic development in Indonesia. Currently, the PT. Steel Pipe Industry of Indonesia Tbk frequent disconnections between the production plan with the production process. This leads to huge costs for items that are not sold to customers that are stored in the warehouse. Support system for planning sustainable production processes in the company are expected to carry out the management of the production process planning. Data modeling method used is the modeling of neural network to forecast product demand. In this study compared the time series forecasting models with multivariable model and then look for the best model. The data used in this study is a demand monthly steel pipe products on the PT. Steel Pipe Industry of Indonesia Tbk and several other supporting data. Modeling results between models obtained univariable and multivariable statistical comparison using RMSE that demand for pipe products in the pipeline better predict demand using neural network models with multivariable. Results of the steel pipe demand forecasting with neural network models to support planning in production at PT. Steel Pipe Industry of Indonesia Tbk. in September 2014 in the prediction will be increased demand for pipe products that are not too high.

Keywords: Neural Network, Time Series, Multivariable, Decision Support System

## KATA PENGANTAR

Puji syukur kepada Tuhan Yang Maha Esa karena berkat karunia-Nya sehingga penulis dapat menyelesaikan Tesis dengan judul **“Model Pendukung Keputusan Sebagai Pendukung Perencanaan Produksi Pipa Baja Dengan Menggunakan Neural Network Di PT. Steel Pipe Industry Of Indonesia Tbk.”**

Selesainya Tesis ini tidak lepas dari bimbingan serta dukungan dari berbagai pihak. Oleh karena itu penulis ingin mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Bapak Prof. DR. Drs. M. Isa Irawan, MT.sebagai pembimbing yang telah sabar membimbing dan mengarahkan penulis selama penyusunan Tesis.
2. Bapak Prof. Dr. Ir. Joko Lianto Buliali, M.Sc dan Bapak Daniel Oranova S., S.Kom, M.Sc, PDEng sebagai penguji yang telah memberikan masukan dan saran selama penyusunan Tesis.
3. Ibu Prof. Dr. Yulinah T, MappSc. selaku Kaprodi MMT ITS.
4. Seluruh dosen MMT ITS yang telah memberikan ilmu-ilmu yang tiada ternilai harganya dan segenap karyawan MMT ITS.
5. Orang Tua tersayang yang telah memberikan motivasi, bimbingan dan doa kepada penulis sehingga bisa menyelesaikan kuliah ini dengan baik.
6. Adik tersayang yang selalu memberikan dorongan semangat selama ini.
7. Teman seperjuangan Tesis atas segala masukan, suka duka, dan kebersamaan dalam penyelesaian Tesis ini.
8. Para sahabat penulis, Achmad Roiyan Fauzi dan M. Afifuddin membantu penulis dalam kesulitan, berbagi tawa dan canda bersama, semoga kebersamaan ini akan tetap terjalin sampai kapanpun.
9. Seluruh pihak yang telah banyak membantu penulis dan tidak dapat disebutkan satu per satu.

Penulis menyadari bahwa Tesis ini masih jauh dari sempurna. Oleh karena itu, kritik dan saran diharapkan dari semua pihak. Semoga Tesis ini dapat bermanfaat untuk menambah wawasan keilmuan bagi pembaca dan semua pihak.

Surabaya, Juli 2015

Penulis

# DAFTAR ISI

Halaman

## HALAMAN JUDUL

ABSTRAK ..... i

KATA PENGANTAR ..... iii

DAFTAR ISI ..... v

DAFTAR TABEL ..... vii

DAFTAR GAMBAR ..... ix

## BAB I PENDAHULUAN

1.1 Latar Belakang ..... 1

1.2 Rumusan Masalah ..... 3

1.3 Tujuan Penelitian ..... 4

1.4 Batasan Penelitian ..... 4

## BAB II TINJAUAN PUSTAKA

2.1 Statistika Deskriptif ..... 5

2.2 Analisis Deret Waktu ..... 5

2.3 Fungsi *Autocorrelation* ..... 6

2.4 Fungsi *Partial Autocorrelation* ..... 7

2.5 Model ARIMA *Box Jenkins* ..... 7

2.6 *Backpropagation Neural Network* ..... 9

2.7 *Decision Support System* ..... 13

2.8 Analisis Regresi ..... 14

2.9 Profile PT. Steel Pipe Industry of Indoneia Tbk. .... 14

## BAB III METODOLOGI PENELITIAN

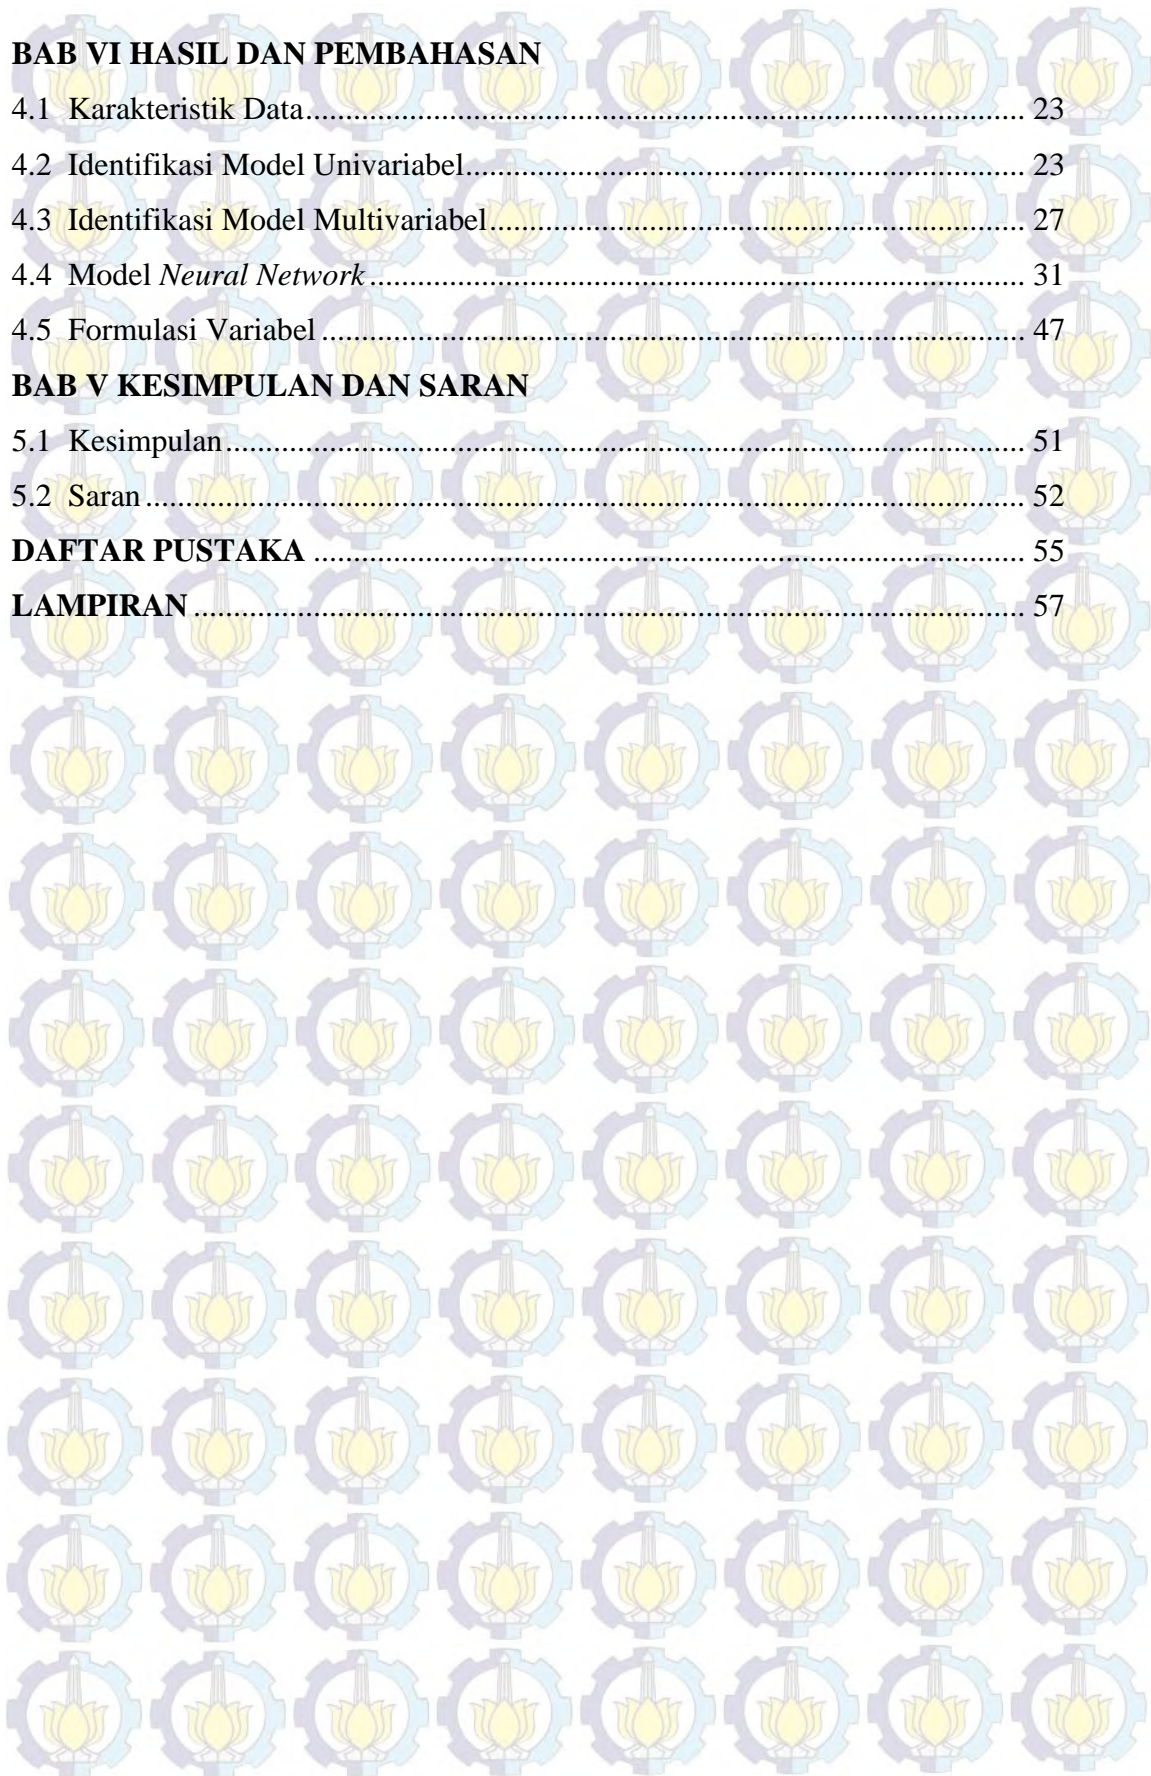
3.1 Sumber Data ..... 17

3.2 Variabel Penelitian ..... 17

3.3 Alur Penelitian ..... 19

3.4 Langkah Penelitian ..... 20

<b>BAB VI HASIL DAN PEMBAHASAN</b>	
4.1 Karakteristik Data.....	23
4.2 Identifikasi Model Univariabel.....	23
4.3 Identifikasi Model Multivariabel.....	27
4.4 Model <i>Neural Network</i> .....	31
4.5 Formulasi Variabel.....	47
<b>BAB V KESIMPULAN DAN SARAN</b>	
5.1 Kesimpulan.....	51
5.2 Saran.....	52
<b>DAFTAR PUSTAKA</b> .....	55
<b>LAMPIRAN</b> .....	57






## DAFTAR TABEL


	Halaman
Tabel 2.1 Nilai $\lambda$ dan Transformasinya.....	6
Tabel 2.2 Karakteristik model ARIMA .....	8
Tabel 3.1 Variabel Penelitian.....	18
Tabel 4.1 Statistika Deskriptif Data Penelitian .....	23
Tabel 4.2 Karakteristik model ARIMA .....	26
Tabel 4.3 Statistika Deskriptif Jenis Pipa .....	29
Tabel 4.4 Korelasi Jenis Pipa terhadap Faktor Eksternal.....	30
Tabel 4.5 Nilai RMSE kedua model .....	31
Tabel 4.6 Bobot <i>Neural Network</i> Model Univariabel.....	32
Tabel 4.7 Bobot <i>Neural Network</i> Model Multivariabel.....	32
Tabel 4.8 Nilai RMSE Model Multivariabel Per Jenis .....	33
Tabel 4.9 Hasil Testing Model Multivariabel Permintaan Produk .....	34
Tabel 4.10 Bobot Model <i>Neural Network</i> Pipa Perabot .....	36
Tabel 4.11 Testing Model Multivariabel Pipa Perabot.....	36
Tabel 4.12 Prediksi Model <i>Neural Network</i> Pipa Perabot.....	37
Tabel 4.13 Bobot Model <i>Neural Network</i> Pipa Hitam .....	37
Tabel 4.14 Testing Model Multivariabel Pipa Hitam .....	38
Tabel 4.15 Prediksi Model <i>Neural Network</i> Pipa Hitam .....	38
Tabel 4.16 Bobot Model <i>Neural Network</i> Pipa Air .....	39
Tabel 4.17 Testing Model Multivariabel Pipa Air.....	40
Tabel 4.18 Prediksi Model <i>Neural Network</i> Pipa Air.....	40
Tabel 4.19 Bobot Model <i>Neural Network</i> Pipa Kotak BJLS.....	41
Tabel 4.20 Testing Model Multivariabel Pipa Kotak BJLS.....	42
Tabel 4.21 Prediksi Model <i>Neural Network</i> Pipa Kotak BJLS.....	42
Tabel 4.22 Korelasi Prediksi Jenis Pipa terhadap Faktor Eksternal.....	43
Tabel 4.23 Hasil Peramalan Model Multivariabel .....	44
Tabel 4.24 Rincian Jenis Pipa Perabot Bulan Juni 2014.....	44

Tabel 4.25 Rincian Jenis Pipa Hitam Bulan Juni 2014 .....	45
Tabel 4.26 Rincian Jenis Pipa Air Bulan Juni 2014 .....	45
Tabel 4.27 Rasio Semua Jenis Pipa Bulan Juni 2014.....	46
Tabel 4.28 Jenis Pipa Model Multivariabel Bulan September 2014 .....	46
Tabel 4.29 Pipa Perabot Model Multivariabel Bulan September 2014.....	46
Tabel 4.30 Pipa Hitam Model Multivariabel Bulan September 2014 .....	47
Tabel 4.31 Pipa Air Model Multivariabel Bulan September 2014.....	47
Tabel 4.32 Bahan Baku Produk Bulan September 2014 – November 2014 .....	48
Tabel 4.33 Utilitas Mesin Produksi September 2014 – November 2014.....	49



## DAFTAR GAMBAR

	Halaman
Gambar 2.1 Arsitektur <i>Backpropagation</i> .....	9
Gambar 2.2 Grafik Fungsi <i>Sigmoid Biner</i> dengan <i>Range</i> (0,1).....	10
Gambar 2.3 Grafik Fungsi <i>Sigmoid Bipolar</i> dengan <i>Range</i> (-1,1).....	11
Gambar 3.1 <i>Flowchat</i> Penelitian.....	19
Gambar 4.1 Permintaan Produk Pipa (Ton).....	24
Gambar 4.2 Permintaan Produk Pipa per Jenis (Ton).....	24
Gambar 4.3 <i>ACF dan PACF</i> Permintaan Produk Pipa.....	25
Gambar 4.4 <i>ACF dan PACF</i> penjualan obat <i>Cortecosteroid</i> di <i>Australian</i> .....	25
Gambar 4.5 Arsitektur <i>Neural Network</i> Model Univariabel.....	27
Gambar 4.6 Data Inflasi Indonesia.....	27
Gambar 4.7 Data Nilai Tukar Rupiah terhadap Dollar Amerika.....	28
Gambar 4.8 Data Nilai Ekspor Indonesia.....	28
Gambar 4.9 Data Harga Baja di Pasar Dunia.....	28
Gambar 4.10 Arsitektur <i>Neural Network</i> Model Multivariabel.....	29
Gambar 4.11 Perbandingan Prediksi dan Aktual Testing.....	35
Gambar 4.12 Prediksi dan Aktual Pipa Perabot.....	37
Gambar 4.13 Prediksi dan Aktual Pipa Hitam.....	39
Gambar 4.14 Prediksi dan Aktual Pipa Air.....	41
Gambar 4.15 Prediksi dan Aktual Pipa Kotak BJLS.....	43
Gambar 4.16 Hasil Prediksi Total Permintaan Pipa.....	44
Gambar 4.17 Bahan Baku dengan Permintaan Produk Pipa.....	48



# BAB I PENDAHULUAN

## 1.1 Latar Belakang

Pembangunan infrastruktur berperan signifikan dalam mendorong pertumbuhan dan pembangunan ekonomi Indonesia. Kedua komponen infrastruktur yakni infrastruktur fisik dan sosial, diharapkan dapat memberikan layanan yang terbaik untuk kepentingan umum. Oleh karena itu, penyediaan dan pemeliharaan infrastruktur yang memadai turut menentukan keberhasilan pembangunan Indonesia terutama dalam upaya untuk menggerakkan sektor perekonomian, meningkatkan produktivitas, mengurangi kemiskinan, serta meningkatkan standar hidup masyarakat

Susilo Bambang Yudhoyono mengemukakan, sampai dengan tahun 2015 mendatang dibutuhkan anggaran sebesar Rp 4.700 triliun guna membangun infrastruktur di Tanah Air. Sekitar 40% dana pembangunan infrastruktur di Tanah Air bisa ditutup dengan melibatkan dana swasta, dimana pemerintah mengutamakan pada swasta dalam negeri dan mengajak swasta dari negara-negara sahabat. Adapun 25% lagi berasal dari BUMN dan sedikit dari itu BUMD, dan 15% lagi baru dari APBN. Jumlah ketiga-tiganya mencapai 80%, masih kurang 20%. Itulah yang kita sebut patungan, paduan dari dana pemerintah, dana BUMN, dan dana swasta (Anonim, 2014)

Prospek industri baja nasional saat ini sedang berumbuh seiring pesatnya pertumbuhan ekonomi dan pembangunan infrastruktur. Pada 2020, penjualan baja domestik diperkirakan mencapai 21 juta ton, dibanding 2013 sebesar 14,5 juta ton. Indonesia sebagai negara komoditas tambang seperti minyak dan gas bumi yang lumayan besar, Indonesia butuh pasokan pipa baja yang besar. Berbagai jenis kebutuhan dari jenis serta ukuran guna menunjang kegiatan eksplorasi, produksi hingga distribusi harus tersedia dalam jumlah memadai.

Di tengah perkembangan Masterplan Percepatan dan Perluasan Pembangunan Ekonomi Indonesia (MP3EI) yang direncanakan selesai pada 2025, permintaan pipa baja untuk konstruksi diperkirakan akan meningkat. Pembangunan

infrastruktur minyak dan gas juga akan meningkatkan permintaan pipa baja. Hal-hal tersebut mendorong perusahaan pipa baja di Indonesia untuk meningkatkan kapasitas produksinya dengan membangun pabrik. Steel Pipe Industry of Indonesia (ISSP) merupakan salah satu perusahaan pipa baja yang diuntungkan. PT. Steel Pipe Industry of Indonesia, Tbk. (SPINDO) merupakan suatu perusahaan dalam negeri yang berpengalaman dalam memproduksi berbagai macam pipa baja/tabung dan berbagai produk terkait lainnya, serta selalu inovatif dalam rangka memenuhi kebutuhan-kebutuhan spesifik para konsumennya. Setelah beroperasi selama lebih dari 40 tahun, Spindo telah menjadi produsen pipa baja terbesar di Indonesia dengan pangsa pasar domestik sebesar 30 persen (per akhir 2013). Perseroan memproduksi berbagai pipa baja dan produk terkait lainnya. Terdapat dua merek utama yang diproduksi oleh Spindo, yaitu Spindo untuk pipa karbon dan Tetsura untuk pipa *stainless*. Semua pipa tersebut diproduksi untuk memenuhi permintaan dari industri konstruksi, infrastruktur, utilitas, minyak & gas, furnitur, dan otomotif. Pada tahun 2013, kontribusi pendapatan perseroan terdiri dari konstruksi, infrastruktur, & utilitas sebesar 62%, minyak&gas sebesar 18%, otomotif sebesar 13%, dan furnitur sebesar 7%.

Pada saat ini sering terjadi ketidaksinambungan akan rencana produksi pipa dengan proses produksi pipa yang terjadi di PT. Steel Pipe Industry of Indonesia, Tbk. Hal ini menyebabkan terjadi gap antara barang yang diproduksi dengan barang yang diminta oleh pelanggan. Sehingga terjadi pembengkakan biaya yang besar untuk barang-barang yang tidak terjual ke pelanggan yang disimpan pada gudang. Model pendukung untuk merencanakan proses produksi yang berkelanjutan pada perusahaan diharapkan dapat melakukan manajemen terhadap perencanaan proses produksi di PT. SPINDO Tbk.

*Forecasting support system* (FSS) merupakan salah satu *decision support system* (DSS) yang membantu dalam merencanakan permintaan dan pemegang kepentingan lain untuk mendapatkan informasi seputar peramalan permintaan produk yang akurat. (Armstrong, 2001; Fildes, Goodwin, & Lawrence, 2006; Makridakis, Wheelwright, & Hyndman, 1998). Ketika FSS dilihat sebagai tipe khusus dari DSS, penggunaan FSS biasanya menggunakan dua tahap (Fildes et al., 2006). Tahap pertama yaitu melihat perhitungan dari peramalan statistik, dan tahap

kedua melibatkan berbagai faktor yang mengarah ke keputusan akhir dari peramalan itu sendiri. Forecasting secara perhitungan memang tidak selalu dapat meramal secara tepat dan akurat. Tetapi dengan tambahan informasi, seperti peningkatan promosi penjualan yang akan datang, maka tingkat akurasi akan semakin tinggi.

Metode yang sering digunakan dalam *forecasting* adalah Autoregressive Integrated Moving Average (ARIMA) dimana pada ARIMA, *future value* atau model persamaan matematisnya diasumsikan sebagai fungsi linier dari beberapa pengamatan di masa lalu dan *random error*. Beberapa studi menunjukkan bahwa ketika model linier menghasilkan tingkat akurasi peramalan yang relatif kecil dan kesalahan dalam prediksi yang besar, kemungkinan model *nonlinier* mampu menjelaskan dan meramalkan time series dengan lebih baik dibandingkan dengan model linier (Zhang, 2003). Salah satu metode yang dapat memodelkan model *nonlinier* untuk *time series forecasting* adalah Artificial Neural Network (ANN). Artificial Neural Network (ANN) atau disebut Neural Networks (NN) merupakan salah satu contoh metode *nonlinier* yang mempunyai bentuk fungsional fleksibel dan mengandung beberapa parameter yang tidak dapat diinterpretasikan seperti pada model parametrik (Suhartono, 2007).

Berdasarkan penjelasan tersebut, perlu adanya model *decision suport system* pada perusahaan manufaktur pipa baja dalam perencanaan produksi. Sehingga model pendukung keputusan guna mendukung perencanaan produksi pada PT. Spindo Tbk. kiranya perlu dianalisis dan ditinjau dengan teori yang ada.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, maka dalam penelitian didapatkan permasalahan yang dirumuskan dalam perumusan masalah sebagai berikut :

1. Bagaimana pemilihan model terbaik dalam peramalan permintaan pipa baja dengan menggunakan metode *neural network* PT. Steel Pipe Industry of Indonesia Tbk.?
2. Bagaimana hasil peramalan permintaan pipa baja dengan model *neural network* dalam mendukung perencanaan pada produksi di PT. Steel Pipe Industry of Indonesia Tbk.?

3. Bagaimana model pendukung keputusan guna mendukung perencanaan produksi di PT. Steel Pipe Industry Indonesia Tbk.?

### 1.3 Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut :

1. Mendapatkan model terbaik dalam peramalan permintaan pipa baja yang terbaik dengan menggunakan metode *neural network* PT. Steel Pipe Industry of Indonesia Tbk.
2. Mengetahui hasil peramalan permintaan pipa baja dengan model *neural network* dalam mendukung perencanaan pada produksi di PT. Steel Pipe Industry of Indonesia Tbk.
3. Mendapatkan model pendukung keputusan guna mendukung perencanaan produksi di PT. Steel Pipe Industry of Indonesia Tbk.

### 1.4 Batasan Masalah

Pada penelitian kali ini dibatasi hanya di lingkup perusahaan manufaktur pipa baja yaitu PT. Steel Pipe Industry of Indonesia Tbk yang berlokasi di Rungkut Industri. Produk pipa pada PT. SPINDO Tbk yang digunakan pada penelitian ini adalah sebagai berikut.

1. Water Pipe (Pipa air)

*Water Pipe* atau pipa air merupakan produk pipa yang kegunaannya adalah sebagai pipa air dengan beberapa jenis dan bahan baku yang berbeda tergantung dari standar yang digunakan. Pipa air dilapisi dengan pelapisan berupa cairan galvanis untuk mengurangi tingkat korosi dari bahan pipa.

2. Furniture (General Structure)

Furniture pipe atau pipa perabot merupakan pipa yang digunakan untuk struktur baja atau kerangka baja secara umum. Pipa ini biasa digunakan sebagai kerangka kendaraan, kerangka bangunan, kerangka meja, kursi, dan lain sebagainya.

3. Black Pipe

Black Pipe atau pipa hitam merupakan pipa setengah jadi yang nantinya akan digunakan pada proses lebih lanjut.



## BAB II TINJAUAN PUSTAKA

Pada bab ini akan dijelaskan terkait kajian teori dari pustaka yang ada dalam pembahasan permasalahan pada penelitian ini antara lain *univariate time series* (ARIMA Box Jenkins), *backpropagation neural network* serta pengertian *decision support system*.

### 2.1 Statistika Deskriptif

Statistika deskriptif adalah metode-metode yang berkaitan dengan pengumpulan dan penyajian data sehingga dapat memberikan informasi yang berguna (Walpole, 1995). Statistika deskriptif yang digunakan dalam penelitian ini antara lain *mean* dan *varians* yang merupakan ukuran pemusatan dari suatu data.

### 2.2 Analisis Deret Waktu

Deret waktu adalah sekelompok nilai-nilai pengamatan yang diperoleh pada titik waktu yang berbeda dengan selang waktu yang sama dan barisan data diasumsikan saling berhubungan satu sama lain. Jadi model deret waktu adalah suatu model runtun waktu dimana observasi yang satu dengan yang lain saling berkorelasi. Menurut Cryer (1986), deret waktu adalah serangkaian data pengamatan yang disusun menurut waktu, dimana data pengamatan tersebut bersifat acak dan saling berhubungan secara statistika.

Makridakis, Wheelwright dan McGee. (1999) menjelaskan bahwa stasioneritas berarti bahwa tidak terdapat pertambahan atau penurunan pada data dari waktu ke waktu. Data secara kasarnya harus horizontal sepanjang sumbu waktu atau fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan ragam dari fluktuasi tersebut tetap konstan sepanjang waktu. Deret waktu stasioner adalah deret yang ciri-ciri statistik dasarnya seperti rata-rata dan ragam tetap konstan sepanjang waktu (Hanke, Reitsch & Wichern, 2003).

Data dikatakan stasioner pada ragam apabila fluktuasi data tidak terlalu besar dari waktu ke waktu. Sebagai upaya perbaikan terhadap data yang tidak stasioner

pada ragam dapat dilakukan transformasi *Box-Cox* dengan bentuk transformasi sebagai berikut.

$$T(Z_t) = Z_t^{(\lambda)} = \frac{Z_t^\lambda - 1}{\lambda} \quad (2.1)$$

dimana  $\lambda$  adalah parameter transformasi.

Beberapa nilai  $\lambda$  dan bentuk transformasi yang berhubungan dapat dilihat pada Tabel 2.1.

**Tabel 2.1** Nilai  $\lambda$  dan Transformasinya

Nilai $\lambda$	-1	-0,5	0	0,5	1
Bentuk Transformasi	$\frac{1}{Z_t}$	$\frac{1}{\sqrt{Z_t}}$	$\ln Z_t$	$\sqrt{Z_t}$	$Z_t$

Hanke, Reitsch dan Wichern (2003) menyatakan apabila datanya tidak stasioner pada rata-rata, maka dapat dikonversikan menjadi deret stasioner melalui *differencing* (pembedaan), yaitu deret asli diganti dengan deret selisih. Jumlah *differencing* yang dilakukan untuk mencapai stasioner dinotasikan sebagai  $d$ . Bentuk pembedaan pertama ( $d = 1$ ) adalah sebagai berikut.

$$\Delta Z_t = Z_t - Z_{t-1}$$

### 2.3 Fungsi Autocorrelation

Proses stasioner  $\{Z_t\}$ , didapat rata-rata  $E(Z_t) = \mu$  dan varian  $Var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$ , yang konstan, dan kovarian  $Cov(Z_t, Z_s)$  yang merupakan fungsi dari perbedaan waktu  $|t - s|$ . Maka dapat ditulis kovarian antara  $Z_t$  dan  $Z_{t+k}$  sebagai berikut.

$$\gamma_k = Cov(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu) \quad (2.2)$$

dan korelasi antara  $Z_t$  dan  $Z_{t+k}$  sebagai berikut.

$$\rho_k = \frac{Cov(Z_t, Z_{t+k})}{\sqrt{Var(Z_t)}\sqrt{Var(Z_{t+k})}} \quad (2.3)$$

dimana diketahui bahwa  $Var(Z_t) = Var(Z_{t+k}) = \gamma_0$ .  $\gamma_k$  disebut fungsi *autocovarian* dan  $\rho_k$  disebut fungsi *autocorrelation* (ACF) pada analisis deret waktu karena dapat menggambarkan kovarian dan korelasi antara  $Z_t$  dan  $Z_{t+k}$  pada proses yang sama, dipisahkan oleh  $k$  lag deret waktu (Wei, 2006).

Hanke dkk. (2003) menyatakan bahwa autokorelasi adalah hubungan deret berkala dengan deret berkala itu sendiri dengan selisih waktu (*lag*) 0,1,2 periode atau lebih. Cryer (1986) menjelaskan bahwa koefisien fungsi autokorelasi  $\rho_k$  dapat diduga dengan rumus sebagai berikut.

$$r_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad (2.4)$$

## 2.4 Fungsi *Partial Autocorrelation*

Autokorelasi Parsial digunakan untuk mengukur tingkat keeratan hubungan linier antara data  $Z_t$  dengan  $Z_{t+k}$  apabila pengaruh dari time lag 1,2,...,k-1 sudah dihilangkan (Makridakis dkk., 1999). Menurut Cryer (1986), taksiran dari PACF adalah berdasarkan koefisien autokorelasi pada persamaan *Yule-Walker* untuk k time lag, yaitu :

$$\rho_1 = \phi_{k1} + \phi_{k2}\rho_1 + \dots + \phi_{kk}\rho_{k-1}$$

$$\rho_2 = \phi_{k1}\rho_1 + \phi_{k2} + \dots + \phi_{kk}\rho_{k-2}$$

$$\rho_k = \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-2} + \dots + \phi_{kk}$$

sehingga didapatkan pendugaan nilai PACF sebagai berikut:

$$\phi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j}\rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j}\rho_j} \quad (2.5)$$

## 2.5 Model ARIMA *Box Jenkins*

Suatu proses dikatakan non-stasioner jika proses tersebut mempunyai rata-rata dan ragam yang tidak konstan untuk sembarang waktu pengamatan. Model deret waktu yang nonstasioner dapat dikatakan sebagai proses *Auto Regressive Integrated Moving Average* ordo  $(p,d,q)$  atau disingkat ARIMA  $(p,d,q)$ , dimana:  $p$  adalah order dari parameter autoregresif,  $d$  adalah besaran yang menyatakan berapa kali dilakukan *differencing* pada proses sehingga menjadi proses yang stasioner, dan  $q$  adalah order dari parameter *moving average*. Pada kenyataannya, tidak semua observasi deret waktu membentuk proses yang stasioner.

Metode ARIMA dapat juga digunakan untuk peramalan yang dikembangkan oleh *Box Jenkins*. Metode ini menggunakan pendekatan iteratif pada identifikasi suatu model yang mungkin dari model umum. Model terpilih kemudian diperiksa terhadap data historis untuk melihat apakah model ini akurat dalam menjelaskan deret data (Hanke, Reitsch & Wichern, 2003).

**Tabel 2.2** Karakteristik model ARIMA

Proses	ACF	PACF
AR(p)	Dies down (turun cepat secara eksponensial / sinusoidal)	Cuts off after lag p (terputus setelah lag p)
MA(q)	Cuts off after lag q (terputus setelah lag q)	Dies down (turun cepat secara eksponensial / sinusoidal)
AR(p) atau MA(q)	Cuts off after lag q (terputus setelah lag q)	Cuts off after lag p (terputus setelah lag p)

Secara umum, bentuk matematis model ARIMA(p,d,q) dapat ditulis sebagai berikut (Cryer, 1986; Wei, 2006).

$$(1 - \phi_1 B - \dots - \phi_p B^p)(1 - B)^d Z_t = \theta_0 + (1 - \theta_1 B - \dots - \theta_q B^q) a_t \quad (2.6)$$

Dengan B adalah operator mundur, Penentuan orde p dan q dari model ARIMA pada suatu data runtun waktu dilakukan dengan mengidentifikasi plot Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF) dari data yang sudah stasioner. Cryer (1986) merumuskan model umum ARIMA (p,d,q) sebagai berikut.

$$W_t = \nabla^d Z_t \quad (2.7)$$

$$W_t = \phi_1 W_{t-1} + \dots + \phi_p W_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.8)$$

Keterangan :

$\phi$  = parameter *autoregressive*

$\theta$  = parameter *moving average*

p = derajat *autoregressive*

q = derajat *moving average*

$a_t$  = galat acak (*white noise*)


Pada prakteknya, nilai p dan q pada model ARIMA (p,d,q) masing-masing jarang menggunakan nilai p dan q melebihi 2 (Hanke, Reitsch & Wichern, 2003). Sedangkan untuk nilai d juga jarang menggunakan nilai selain 0, 1, atau 2, karena pada umumnya stasioneritas dapat dicapai dengan melakukan pembedaan berturut-turut sebanyak satu atau dua kali (Makridakis, dkk.,1999). Pendekatan *Box Jenkins* menggunakan strategi pembentukan iteratif yang terdiri dari pemilihan model awal

(identifikasi model), estimasi koefisien model (pendugaan parameter), dan penganalisaan residual (pemeriksaan model). Jika diperlukan, model awal dimodifikasi dan proses diulangi sampai didapat residual yang memberikan indikasi bahwa tidak ada lagi modifikasi yang diperlukan. Sampai di sini, model yang sesuai dapat digunakan untuk meramal (Hanke, dkk., 2003).

## 2.6 Backpropagation Neural Network

*Backpropagation* merupakan algoritma pembelajaran *neural network* dan biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron pada lapisan tersembunyinya (Kusumadewi, 2004). Pembelajaran dari jaringan *backpropagation* terdiri dari tiga tahapan yaitu menghitung arah maju dari pola *input* pembelajaran, menghitung *error backpropagation* dan menentukan peubah bobot (Fausett, 1994).

Arsitektur dalam *backpropagation* disebut juga dengan *multilayer neural network*. Pada gambar berikut akan ditunjukkan *multilayer neural network* dengan satu *layer* dari *hidden* unit (*Z* unit), unit *output* (*Y* unit) dan juga memiliki unit bias.



**Gambar 2.1.** Arsitektur *Backpropagation*

Gambar 2.1 menunjukkan arsitektur *backpropagation* dengan 3 *input*, ditambah sebuah bias, dan sebuah *layer* tersembunyi yang terdiri dari *p* unit, ditambah sebuah bias, serta 1 buah unit keluaran. Dimana :

$Y_{t-1}, Y_{t-2}, Y_{t-3}$  : Unit *input*

$Y_t$  : Unit *output*

$Z_i$  : Unit *hidden*

$v_{ij}$  : bobot dari unit *input* menuju unit *hidden*

$w_i$  : bobot dari unit *hidden* menuju unit *output*

Fungsi aktivasi merupakan suatu fungsi yang digunakan untuk membandingkan antara hasil penjumlahan nilai-nilai semua bobot yang datang dengan suatu nilai ambang (*threshold*) tertentu pada tiap neuron (Kusumadewi, 2004). Dalam *backpropagation*, fungsi aktivasi yang dipakai harus memenuhi beberapa syarat yaitu :


1. Kontinu.
2. Terdiferensial dengan mudah.
3. Merupakan fungsi yang tidak turun.

Salah satu fungsi yang memenuhi ketiga syarat tersebut adalah fungsi *sigmoid biner* yang memiliki *range* (0,1).

$$f_1(x) = \frac{1}{1 + \exp(-x)} \quad (2.9)$$

dengan turunan  $f_1'(x) = f(x)[1 - f(x)]$  (2.10)

Fungsi *sigmoid biner* dapat diilustrasikan pada gambar berikut.




**Gambar 2.2** Grafik Fungsi *Sigmoid Biner* dengan *Range* (0,1)

Fungsi *sigmoid* memiliki nilai maksimum sebesar 1. Agar semua pola memiliki *range* yang sama seperti *sigmoid* yang dipakai, maka pola yang target nilainya  $> 1$ , pola masukan dan keluaran harus ditransformasikan lebih dulu. Cara lain yang bisa digunakan adalah dengan menggunakan fungsi aktivasi *sigmoid* hanya pada *hidden layer*. Misalkan fungsi *sigmoid bipolar*, dengan *range* (-1,1) seperti berikut.

$$f(x) = \frac{2}{1 + e^{-x}} - 1 \quad (2.11)$$

dengan turunan  $f'(x) = \frac{(1 + f(x))(1 - f(x))}{2} \quad (2.12)$



**Gambar 2.3** Grafik Fungsi Sigmoid Bipolar dengan *Range* (-1,1)

Algoritma pembelajaran backpropagation dalam jaringan dengan satu layer tersembunyi dan dengan fungsi aktivasi logistik biner adalah sebagai berikut.

*Langkah 0* : Inisialisasi bobot dengan bilangan acak kecil.

*Langkah 1* : Dilakukan langkah 2-9, jika kondisi penghentian belum terpenuhi.

*Langkah 2* : Setiap pasang data pelatihan, dilakukan langkah 3-8.

Fase I : Propagansi maju (*Feedforward*)

*Langkah 3* : Tiap unit *input* menerima sinyal dan meneruskannya ke unit tersembunyi di atasnya (unit *hidden*).

*Langkah 4*: Hitung semua sinyal *input* terboboti di unit *hidden* ( $z_j, j=1,2,\dots,p$ ).

$$z\_in_j = v_{j0} + \sum_{i=1}^3 x_i v_{ji} \quad (2.13)$$

gunakan fungsi aktivasi untuk menghitung sinyal *output* yang selanjutnya akan diteruskan menuju *output* unit.

$$z_j = f(z\_in_j) \quad (2.14)$$

*Langkah 5* : Hitung semua sinyal *input* terboboti pada unit *output*  $y$ .

$$y\_in = w_o + \sum_{j=1}^p z_j w_j \quad (2.15)$$

gunakan fungsi aktivasi untuk menghitung sinyal *output*.

$$y = f(y\_in) \quad (2.16)$$

Fase II : Propagansi mundur (*Backpropagation*)

*Langkah 6* : Hitung faktor  $\delta$  unit *output* berdasarkan kesalahan setiap unit keluaran  $y$ .

$$\delta = (t - y) f'(y_{in}) \quad (2.17)$$

Hitung suku perubahan bobot  $w_{kj}$  dengan laju percepatan  $\alpha$ .

$$\Delta w_j = \alpha \delta z_j \quad (2.18)$$

*Langkah 7* : Hitung faktor  $\delta$  unit *hidden* berdasarkan kesalahan pada setiap unit  $z_j$ .

$$\delta_{in_j} = \sum_{k=1}^m \delta w_j \quad (2.19)$$

kalikan dengan turunan dari fungsi aktivasi untuk menghitung errornya

$$\delta_j = \delta_{in_j} f'(z_{in_j}) \quad (2.20)$$

Hitung suku perubahan bobot  $v_{ji}$ .

$$\Delta v_{ji} = \alpha \delta_j x_i \quad (2.21)$$

Fase III : Perubahan bobot (*Update*)

*Langkah 8* : Hitung semua perubahan bobot. Perubahan bobot garis yang menuju ke unit *output* :

$$w_{kj} \text{ baru} = w_{kj} \text{ lama} + \Delta w_{kj} \quad (2.22)$$

Perubahan bobot yang menuju unit *hidden*

$$v_{ji} \text{ baru} = v_{ji} \text{ lama} + \Delta v_{ji} \quad (2.23)$$

*Langkah 9* : Iterasi berhenti pada kondisi tertentu.

Dalam pengenalan pola, hanya langkah pada fase propagasi maju saja yang bisa dipakai untuk menentukan keluaran jaringan.

Bobot pada *neural network* merupakan penghubung antara satu node dengan node yang lain pada layer yang berbeda. Bobot merepresentasikan informasi yang digunakan pada jaringan atau net untuk menyelesaikan suatu permasalahan (Fausett, 1994).

Suatu node atau neuron dapat mengirimkan sinyal ke node yang lain. Sinyal akan dimodifikasi oleh bobot saat suatu node menerima sinyal kiriman. Bobot awal



pada *neural network* diinisialisasi secara random dengan nilai -1 sampai dengan 1 (Kusumadewi, 2004).

## **2.7 Decision Support System**

*Decision support system* (DSS) atau sistem pendukung keputusan didefinisikan sebagai sebuah sistem yang mampu memberikan kemampuan baik dalam pemecahan masalah maupun kemampuan mengkomunikasikan untuk masalah yang tidak terstruktur. Secara khusus, DSS didefinisikan sebagai sebuah sistem yang mendukung kinerja seorang manajer maupun kelompok manajer dalam memecahkan masalah dengan cara memberikan informasi ataupun usulan yang akhirnya didapat suatu keputusan tertentu. (Hermawan, 2005)

*Decision support System* merupakan sistem pendukung keputusan yang memiliki fungsi membantu para pengambil keputusan dengan menyediakan informasi yang penting sebagai dasar pengambilan keputusan (Turban dan McLean, 2002), *Decision support system* (DSS) adalah sistem informasi berbasis computer yang mengkombinasikan model dan data untuk memecahkan permasalahan dengan keiktsertaan dari pengguna sistem. Salah satu fitur yang penting dalam DSS adalah minimal menyertakan satu model keputusan (Ting Peng Liang er, all, 2008). Abstraksi dari sebuah permasalahan yang spesifik di dunia nyata adalah sebuah model.

Sebuah model DSS di dalamnya membutuhkan input, output dan proses tertentu untuk mengubah input menjadi output. (Ting-Peng Liang, er. All 2008). Proses inilah yang terkadang berbentuk model-model matematis yang dapat mengubah input berupa data menjadi output berupa informasi untuk pengambil keputusan. Model pada umumnya menggunakan model matematis yang diturunkan dari sebuah persamaan matematika untuk menyelesaikan permasalahan yang kompleks. Model merupakan penyederhanaan masalah yang ada di dunia nyata sehingga permasalahan yang rumit dan kompleks dapat disimulasikan dalam sebuah model untuk mendapatkan informasi yang penting sebagai dasar pengambilan keputusan.

## 2.8 Analisis Regresi

Analisis regresi adalah suatu metode statistika untuk mengetahui ketergantungan antara variabel tak bebas (*dependent variabel*) dengan satu atau lebih variabel bebas (*independent variabel*). Variabel bebas biasanya dilambangkan dengan x dan variabel tak bebas biasanya dilambangkan dengan y. Apabila terjadi hubungan antara satu variabel tak bebas dengan satu variabel bebas maka disebut regresi sederhana yang dapat dimodelkan sebagai berikut :

$$Y_i = \beta_0 + \beta_1 X_1 + \varepsilon_i \quad (2.24)$$

Apabila ketergantungan antara variabel tak bebas lebih dari satu dengan variabel bebas maka keadaan demikian disebut regresi linear berganda yang dapat dimodelkan sebagai berikut :

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \varepsilon_i \quad (2.25)$$

Dimana  $\varepsilon_i$  menyatakan besarnya galat yaitu selisih antara nilai respon yang sesungguhnya dengan nilai taksiran yang diperoleh dari model.

## 2.9 Profile PT. Steel Pipe Industry of Indonesia Tbk.

PT. Steel Pipe Industry of Indonesia Tbk. atau PT. SPINDO Tbk adalah perusahaan yang bergerak pada bidang industri manufaktur pipa baja, serta selalu inovatif dalam rangka memenuhi kebutuhan-kebutuhan spesifik para konsumennya. Didirikan pada tahun 1971 dengan kantor pusat di jalan Kalibutih 189-191, Surabaya. Serta kantor perwakilan di Jalan Pangeran Jayakarta 55, Jakarta. Saat ini perusahaan memperkerjakan sekitar 1000 karyawan dan mengoperasikan lima unit pabrik yang modern (spindo.com: 2014). Perusahaan ini sudah menjadi perusahaan terbuka pada pencatatan saham di Bursa efek indonesia pada tanggal 22 Feb 2013.

Jaminan mutu produk selalu dilakukan perusahaan dengan penerapan suatu program sistem evaluasi mutu yang ketat dan selaras dengan telah diterimanya sertifikat Internasional ISO 9002 dan API 5L oleh perusahaan ini. Sesuai dengan persyaratan mutu internasional PT.SPINDO memenuhi standar ASTM, BS, JIS,

ISO, API, AS dan SNI. Jaminan mutu produk kami telah dikenal dunia luas seperti Jepang, Singapore, Taiwan, Amerika, Australia (spindo.com: 2014). Utilitas mesin adalah perbandingan interval waktu mesin dibebani (melakukan pemrosesan) dengan jam tersediaan mesin.

Produk pipa pada PT. SPINDO Tbk yang digunakan pada penelitian ini adalah sebagai berikut.

1. Water Pipe (Pipa air)


*Water Pipe* atau pipa air merupakan produk pipa yang kegunaannya adalah sebagai pipa air dengan beberapa jenis dan bahan baku yang berbeda tergantung dari standar yang digunakan. Pipa air dilapisi dengan pelapisan berupa cairan galvanis untuk mengurangi tingkat korosi dari bahan pipa.

2. Furniture (General Structure)

Furniture pipe atau pipa perabot merupakan pipa yang digunakan untuk struktur baja atau kerangka baja secara umum. Pipa ini biasa digunakan sebagai kerangka kendaraan, kerangka bangunan, kerangka meja, kursi, dan lain sebagainya.

3. Black Pipe

Black Pipe atau pipa hitam merupakan pipa setengah jadi yang nantinya akan digunakan pada proses lebih lanjut.



## **BAB III**

### **METODOLOGI PENELITIAN**

Pada bagian ini akan dijelaskan mengenai metode dan tahapan-tahapan dalam melakukan analisis untuk menyelesaikan permasalahan dalam penelitian ini. Metode analisis yang digunakan ialah pemodelan *neural network*.

#### **3.1 Sumber Data**

Data yang digunakan dalam penelitian ini adalah data permintaan produk bulanan pipa baja pada PT. Steel Pipe Industry of Indonesia Tbk. data ini yang nantinya akan diramalkan beberapa periode kedepan. Data permintaan produk bulanan pipa baja ini dari tahun 2010 sampai dengan pertengahan tahun 2014 yaitu bulan Juni. Selain data permintaan dalam pengembangan model pendukung keputusan, digunakan juga data jam kerja mesin (utilitas), yield (reject) dan jumlah bahan baku yang tersedia. Selanjutnya untuk analisis dengan menggunakan multivariabel *neural network* digunakan pula data yang mempengaruhi permintaan dari pelanggan antara lain data inflasi, nilai tukar rupiah terhadap dollar, nilai ekspor impor Indonesia, serta harga baja mentah di pasar dunia.

#### **3.2 Variabel Penelitian**

Variabel yang digunakan dalam penelitian ini adalah variabel permintaan produk pipa baja yang akan dilakukan peramalan. Selain itu, digunakan variabel yang digunakan untuk memformulasikan kebutuhan-kebutuhan yang nantinya akan dipersiapkan untuk proses produksi. Berikut merupakan perincian variabel input yang digunakan pada model.

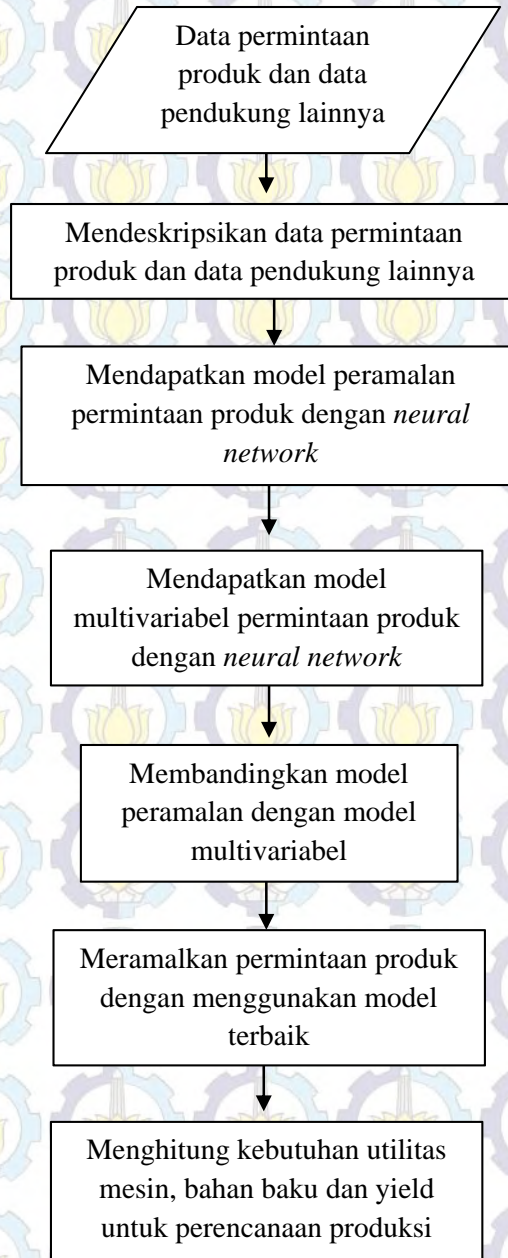
**Tabel 3.1** Variabel Penelitian

<b>Variabel</b>	<b>Satuan</b>	<b>Periode</b>
Permintaan Produk	Ton	2010-2014
Utilitas Mesin	%	2010-2014
Yield	%	2010-2014
Bahan Baku	Ton	2010-2014
Inflasi	%	2010-2014
Nilai Tukar Rupiah	Rp/ US \$	2010-2014
Nilai Ekspor Indonesia	Juta US \$	2010-2014
Harga Baja Pasar Dunia	US \$/ Kg	2010-2014

Variabel untuk pemodelan multivariabel didapat berdasarkan pandangan dan opini ahli pada bidangnya yaitu salah satu staf sales marketing PT. Steel Pipe Industry of Indonesia dan manager produksi PT. Steel Pipe Industry of Indonesia sehingga didapat variabel-variabel yang mempengaruhi penjualan produk pipa.

### 3.3 Alur Penelitian

Berikut ini adalah diagram langkah-langkah penelitian yang dilakukan.



Gambar 3.1. Flowchart Penelitian

### 3.4 Langkah Penelitian

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

1. Melihat *plot time series*.

Plot *time series* berguna untuk menentukan pola dari data yang nantinya berguna untuk menentukan model peramalan yang akan dibangun. Berdasarkan plot *time series* yang didapat nanti bisa ditentukan bahwa model *neural network* mengikuti model linier atau model nonlinier.

2. Melihat *plot ACF* dan *PACF*.

Plot *ACF* dan *PACF* digunakan untuk melihat lag yang signifikan pada data permintaan produk. Pada plot *ACF* dan *PACF*, setelah didapatkan lag yang signifikan, maka akan ditentukan *input layer* yang digunakan pada model peramalan.

3. Menentukan unit *input layer*, *output layer*, dan *hidden layer* model peramalan.

Menentukan *input layer* pada model peramalan berdasarkan lag yang signifikan dari plot *ACF* dan *PACF*. *Output layer* yaitu keluaran yang diinginkan berupa berapa pengamatan ke depan. *Hidden layer* berdasarkan hasil simulasi dari 1 sampai 10 *hidden layer* yang nantinya dipilih yang menghasilkan eror paling kecil.

4. Menghitung bobot *neural network* dengan *backpropagation* model peramalan.

Pada tahap ini merupakan proses estimasi bobot *neural network* yang nantinya menjadi parameter dalam model peramalan. Pada penelitian ini ditentukan untuk maksimum iterasi yang digunakan sebesar 1000 kali iterasi sampai didapat bobot yang menghasilkan kesalahan minimum.

5. Menentukan unit *input layer*, *output layer*, dan *hidden layer* model multivariabel.

Menentukan *input layer* pada model multivariabel berdasarkan variable yang diduga mempengaruhi permintaan produk pipa. *Output layer* yaitu permintaan produk beberapa pengamatan ke depan. *Hidden layer*





berdasarkan hasil simulasi dari 1 sampai 10 *hidden layer* yang nantinya dipilih yang menghasilkan eror paling kecil.

6. Menghitung bobot *neural network* dengan *backpropagation* model multivariabel.

Proses estimasi bobot *neural network* yang nantinya menjadi parameter dalam model multivariabel.

7. Membandingkan model peramalan dengan model multivariabel.


Perbandingan model terbaik dari kedua metode yang digunakan dengan melihat kebaikan model dari masing-masing metode.

8. Meramalkan permintaan produk untuk beberapa periode kedepan dengan model terbaik.

Setelah model terbaik didapatkan maka digunakan untuk meramalkan permintaan produk beberapa periode kedepan.

9. Menghitung kebutuhan utilitas mesin, bahan baku dan yield.

Pada tahap ini, setelah didapatkan peramalan permintaan produk dengan model terbaik, maka dilakukan perhitungan untuk kebutuhan utilitas mesin, bahan baku dan yield yang digunakan untuk merencanakan ketersediaan pada periode-periode tersebut.



## BAB IV HASIL DAN PEMBAHASAN

Pada bab ini akan dipaparkan analisis dan pembahasan terkait dengan estimasi dan pemodelan permintaan produk pipa baja di PT. Steel Pipe Industry Of Indonesia Tbk. Hasil dari pemodelan nantinya akan digunakan untuk pengambilan keputusan terkait dengan perencanaan produksi.

### 4.1 Karakteristik Data


Statistika deskriptif dari data produksi minyak mentah di Indonesia digunakan untuk melihat karakteristik dari data pada penelitian kali ini. Statistika deskriptif variabel yang digunakan pada penelitian ini akan disajikan sebagai berikut.

**Tabel 4.1** Statistika Deskriptif Data Penelitian

Variabel	Satuan	Mean	StDev	Minimum	Maksimum
Permintaan Produk	Ton	2959,60	841,66	1287,75	4527,97
Yield	%	95,21%	0,01	92,77%	96,78%
Utilitas Mesin	%	70,61%	0,13	31,08%	99,05%
Bahan Baku	Ton	3762,00	1018,06	1211,95	5570,33
Inflasi	%	0,47%	0,57%	3,29%	-0,35%
Nilai Tukar Rupiah	Rp/ US \$	9333,7	546,68	11580	8500
NilaiEkspor Indonesia	Juta US \$	15442,04	1936,54	18647,83	11166,45
Harga Baja Pasar Dunia	US \$/ Kg	789.4	74,51	1018.5	671

### 4.2 Identifikasi Model Univariabel


Model peramalan univariabel menggunakan satu variable yaitu permintaan produk yang dilihat pola datanya. Pola data dapat dilihat dari plot time series, ACF dan PACF. Berikut merupakan plot times eries, ACF dan PACF data permintaan produk pipa dari tahun 2010 sampai dengan tahun 2014 di PT. Steel Pipe Industry of Indonesia Tbk.



**Gambar 4.1** Permintaan Produk Pipa (Ton)

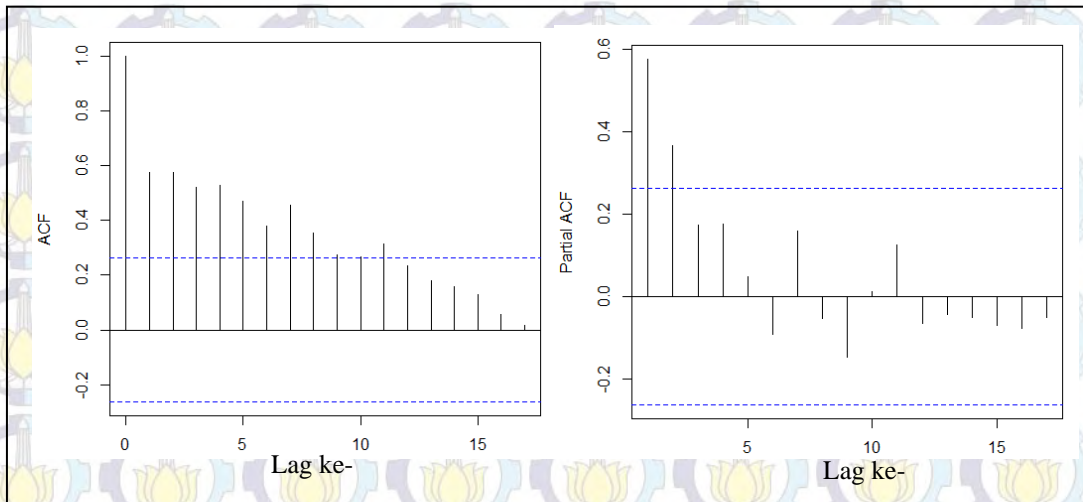
Berdasarkan time series plot di atas, terlihat bahwa data permintaan produk pipa tidak mengikuti pola tertentu, sehingga pola data dapat diasumsikan non linier berdasarkan visualisasi time series plot.

Berikutnya plot data permintaan produk pipa per jenis pipa. Terdapat 4 jenis pipa yang diproduksi yaitu pipa perabot, pipa hitam, pipa air dan pipa kotak BJLS. Grafik permintaan produk pipa per jenis dapat dilihat pada gambar berikut.



**Gambar 4.2** Permintaan Produk Pipa per Jenis (Ton)


Berdasar gambar tersebut terlihat bahwa data permintaan pipa bervariasi satu dengan yang lainnya. Tiap permintaan memiliki pola tersendiri sehingga dimungkinkan dipengaruhi oleh faktor eksternal yang berbeda.



**Gambar 4.3** ACF dan PACF permintaan produk pipa

Berdasarkan plot ACF dan PACF di atas, terlihat bahwa data permintaan produk pipa tidak stasioner dalam mean dan varian, sehingga seharusnya data di diferensiasi terlebih dahulu.

Pada penelitian sebelumnya, (Hyndman, 2010) meneliti penjualan obat Cortecosteroid di Australian. Data yang digunakan 1991 sampai tahun 2008. Kemudian dilakukan forecast kedepan dengan menggunakan ARIMA. Berikut merupakan ACF dan PACF data penjualan obat Cortecosteroid di Australian.



**Gambar 4.4** ACF Dan PACF Penjualan Obat Cortecosteroid Di Australian

Peneliti menyatakan dengan ACF dan PACF di atas menggunakan model ARIMA (3,0,1). Hal ini karena pada plot ACF cuts off pada lag ke 3 dan PACF cuts off pada lag ke 1 (Hyndman, 2010).

Pada penelitian selanjutnya (Caraka,2014) yaitu meneliti data indeks harian Euro 50 periode 2 Januari 2013 sampai dengan 19 Desember 2014, dimana terdapat 501 data indeks yang tercatat. Penelitian ini menggunakan AR (5) dengan

input 5 pengamatan kebelakang untuk meramalkan pengamatan kedepan. (Caraka, 2014)

Penelitian peramalan temperatur udara di Kota Surabaya dengan menggunakan ARIMA dan *neural network*, Jurnal Sains Dan Seni ITS Vol. 1, No. 1, (Sept. 2012) menyatakan bahwa menggunakan input pada lag-1 ( $Z_{t-1}$ ), lag-2 ( $Z_{t-2}$ ), lag-3 ( $Z_{t-3}$ ), lag-4 ( $Z_{t-4}$ ), dan lag-5 ( $Z_{t-5}$ ) sebagai unit input pada meodelan *neural network*. Data yang digunakan temperature udara kota Surabaya dalam satuan celcius dalam periode harian. Model ini dugunakan untuk meramalkan Temperatur Udara di Kota Surabaya (Machmudin, 2012).

**Tabel 4.2** Karakteristik model ARIMA

Proses	ACF	PACF
AR(p)	Dies down (turun cepat secara eksponensial / sinusoidal)	Cuts off after lag p (terputus setelah lag p)
MA(q)	Cuts off after lag q (terputus setelah lag q)	Dies down (turun cepat secara eksponensial )
AR(p) atau MA(q)	Cuts off after lag q (terputus setelah lag q)	Cuts off after lag p (terputus setelah lag p)

Model AR (1)  $y_t = y_{t-1} + a_t$

Model AR (2)  $y_t = y_{t-1} + \phi_1 y_{t-2} + a_t$

Model AR (3)  $y_t = y_{t-1} + \phi_1 y_{t-2} + \phi_2 y_{t-3} + a_t$

Model AR (4)  $y_t = y_{t-1} + \phi_1 y_{t-2} + \phi_2 y_{t-3} + \phi_3 y_{t-4} + \phi_4 + a_t$

Model AR (5)  $y_t = y_{t-1} + \phi_1 y_{t-2} + \phi_2 y_{t-3} + \phi_3 y_{t-4} + \phi_4 y_{t-5} + a_t$

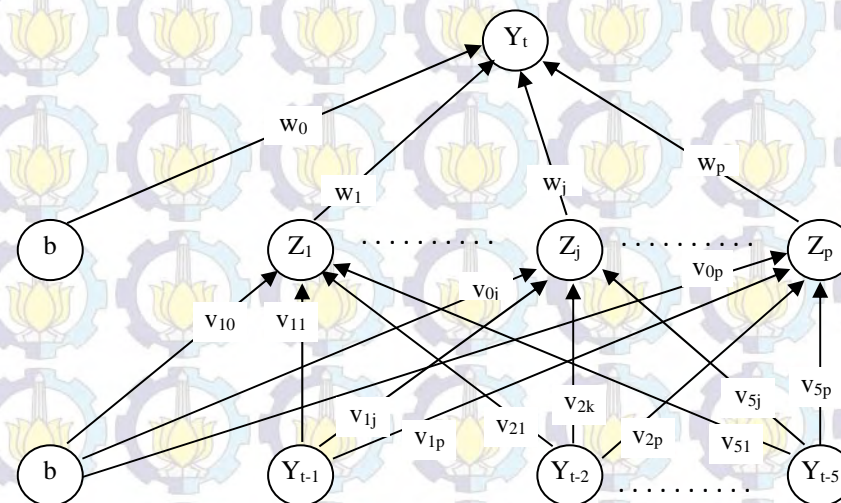
Tetapi model ARIMA yang didapat dari model adalah ARIMA (5,1,0) yang berarti model AR (5) karena pada ACF cuts off pada lag ke 5 dan MA (0) karena PACF dies down pada lag ke 1. Secara umum, bentuk matematis model ARIMA dari data permintaan produk pipa baja dari model ARIMA(p,d,q) dapat ditulis sebagai berikut (Cryer, 1986).

$$(1 - \phi_1 B - \dots - \phi_p B^p)(1 - B)^d Z_t = \theta_0 + (1 - \theta_1 B - \dots - \theta_q B^q) a_t$$

$$y_t = y_{t-1} + \phi_1 y_{t-2} + \phi_2 y_{t-3} + \phi_3 y_{t-4} + \phi_4 y_{t-5} + a_t$$

Sehingga dapat di ambil dugaan bahwa data yang mempengaruhi pengamatan ke -t merupakan data ke t-1, t-2, t-3, t-4, t-5.

Inputan dari neural network peramalan permintaan produk pipa yaitu data ke  $t-1$  sampai dengan data ke  $t-5$ . Kemudian menggunakan hidden layer sebanyak 7, 8, 9, 10, dan 11 layer dan output layer adalah permintaan produk waktu ke  $t$ .




Gambar 4.5 Arsitektur Neural Network Model Univariabel

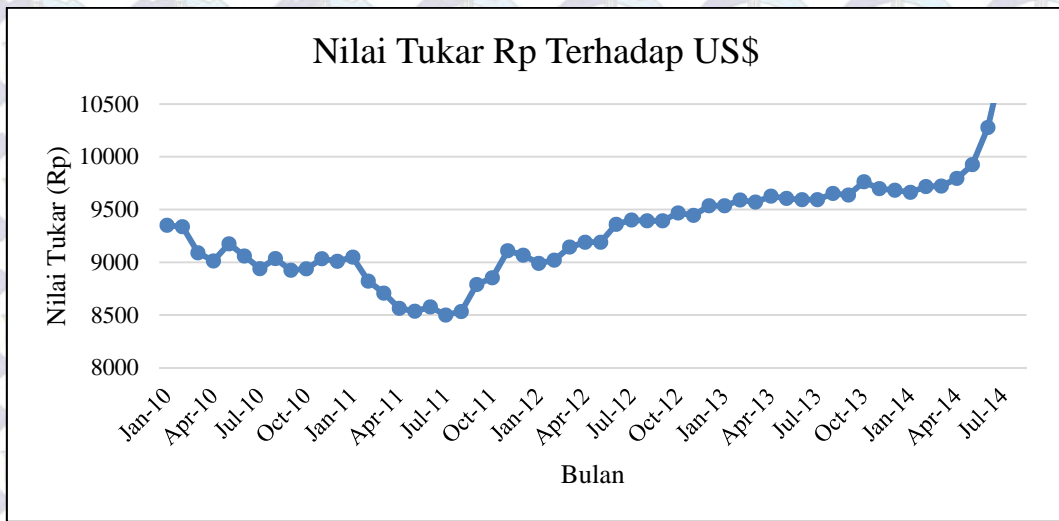
### 4.3 Identifikasi Model Multivariabel

Model peramalan dengan multivariable menggunakan lebih dari satu variabel. Pada penelitian ini, digunakan 4 variabel untuk mendapatkan prediksi jumlah permintaan produk pipa pada beberapa pengamatan kedepan. Selain menggunakan 4 variabel penduga, juga di masukkan pula data pengamatan permintaan produk pipa untuk mendukung hasil prediksi.

Berikut merupakan plot data 4 variabel penduga dan data permintaan produk pipa  $Y_{t-1}$




Gambar 4.6 Data Inflasi Indonesia



**Gambar 4.7** Data Nilai Tukar Rupiah terhadap Dollar Amerika



**Gambar 4.8** Data Nilai Ekspor Indonesia

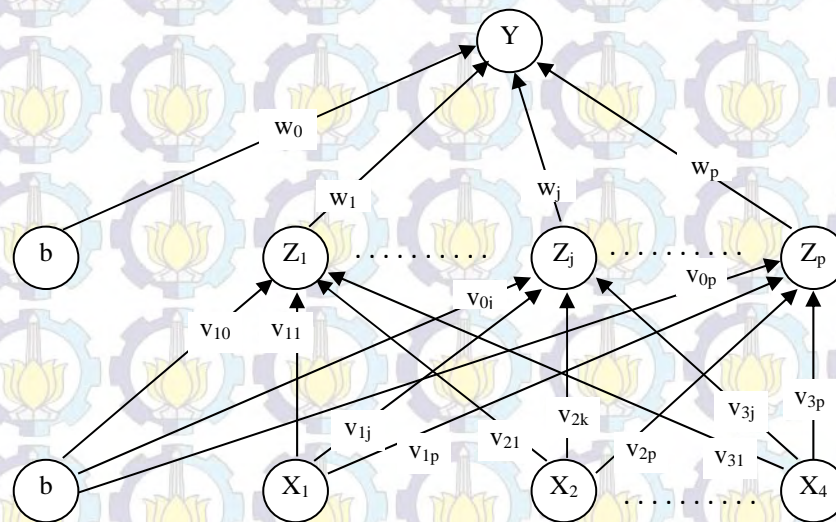


**Gambar 4.9** Data Harga Baja di Pasar Dunia



Berdasarkan gambar tersebut, terlihat bahwa keterkaitan antara permintaan produk pipa tidak terlalu tergambar secara visual.

Inputan dari neural network prediksi permintaan produk pipa yaitu variabel inflasi, nilai tukar rupiah terhadap dolar, nilai ekspor Indonesia, harga baja di pasar dunia dan permintaan produk pipa. Kemudian menggunakan hidden layer sebanyak 8,9 dan 10 layer dan output layer adalah permintaan produk pipa satu pengamatan ke depan. Input pertama (X1) adalah Inflasi, Input kedua (X2) adalah nilai tukar rupiah terhadap dollar, input ketiga (X3) nilai ekspor Indonesia, dan Input ke empat (X4) Harga baja di Pasar dunia.



**Gambar 4.10** Arsitektur Neural Network Model Multivariabel

Berikut merupakan stastistika deskriptif permintaan produksi pipa berdasarkan jenis pipa yang diproduksi dan diminta oleh konsumen.

**Tabel 4.3** Statistika Deskriptif Jenis Pipa

Variabel	Mean	StDev	Minimum	Maksimum
Perabot	373,865	143,979	123,303	776,506
Hitam	509,192	272,626	90,986	1189,590
Air	2018,651	541,549	1049,469	3256,845
Kotak BJLS	49,736	72,988	0	315,522

Berdasarkan tabel di atas, terlihat bahwa pipa air yang diproduksi lebih banyak dibandingkan dengan jenis pipa yang lain. Produksi rata-rata pipa air tiap bulan adalah sebesar 2018,65 ton perbulan. Sedangkan rata-rata paling kecil adalah pada pipa kotak BJLS sebesar 48,736 ton.

Kemudian korelasi antara variabel eksternal terhadap permintaan produksi pipa yang diminta oleh konsumen berdasarkan jenis pipa.

**Tabel 4.4** Korelasi Jenis Pipa terhadap Faktor Eksternal

Variabel	Total Permintaan Produk	Perabot	Hitam	Air	Kotak BJLS
Inflasi	0,009	-0,094	-0,228	0,144	0,064
Nilai Tukar	0,443	0,334	0,238	0,417	0,403
Nilai Ekspor	0,257	0,216	0,282	0,188	0,049
Harga Baja	-0,185	-0,04	0,002	-0,244	-0,225

Berdasarkan hasil korelasi terhadap faktor eksternal tersebut, terlihat bahwa pada tabel korelasi di atas untuk nilai pearson korelasi yang mendekati nilai 1 atau -1 maka dikatakan terdapat korelasi.

1. Total permintaan produk pipa berkorelasi dengan nilai tukar rupiah dengan nilai korelasi sebesar 0,443 kemudian yang kedua berkorelasi terhadap nilai ekspor sebesar 0,257. Sehingga dapat diartikan bahwa ketika nilai tukar rupiah meningkat maka total permintaan produk pipa akan mengalami peningkatan pula. Begitu pula dengan nilai ekspor.
2. Permintaan pipa perabot berpengaruh atau berkorelasi terhadap nilai tukar rupiah dengan nilai korelasi sebesar 0,334 dan nilai ekspor Indonesia sebesar 0,216. Dapat diartikan bahwa ketika nilai tukar rupiah meningkat maka jumlah permintaan pipa perabot akan meningkat, begitu pula dengan nilai ekspor Indonesia.
3. Permintaan pipa hitam berkorelasi positif terhadap nilai tukar rupiah dengan nilai korelasi sebesar 0,238 dan nilai ekspor tetapi berkorelasi negatif terhadap inflasi sebesar -0,228. Ini berarti bahwa ketika nilai tukar rupiah meningkat maka permintaan pipa perabot akan meningkat pula, tetapi ketika inflasi meningkat maka terjadi penurunan terhadap permintaan pipa hitam.

4. Permintaan pipa air berkorelasi positif terhadap nilai tukar rupiah dengan nilai korelasi sebesar 0,417 dan berkorelasi negatif terhadap harga baja dunia sebesar -0,244. Sehingga dapat diartikan bahwa ketika nilai tukar rupiah meningkat maka total permintaan produk pipa air akan mengalami peningkatan pula. tetapi ketika harga baja meningkat maka terjadi penurunan terhadap permintaan pipa air.
5. Permintaan pipa kotak BJLS berkorelasi positif terhadap nilai tukar rupiah dengan nilai korelasi sebesar 0,403 dan berkorelasi negatif terhadap harga baja dunia sebesar -0,225. Dapat diartikan bahwa ketika nilai tukar rupiah meningkat maka total permintaan produk pipa kotak BJLS akan mengalami peningkatan pula. tetapi ketika harga baja meningkat maka terjadi penurunan terhadap permintaan pipa kotak BJLS.

#### 4.4 Model *Neural Network*

Setelah didapatkan model dari masing-masing metode maka dilakukan perhitungan dengan menggunakan neural network untuk mendapatkan bobot yang paling optimum.

Perbandingan kedua metode yaitu dengan model univariabel dan multivariabel dengan beberapa node pada hidden layernya. Hasil yang didapat dengan membandingkan antara node dan antara kedua model terlihat pada tabel berikut.

**Tabel 4.5** Nilai RMSE Kedua Model

	Node = 7	Node = 8	<b>Node = 9</b>	Node = 10	Node = 11
Model Multivariable	0,329173	0,259377	<b>0,2486991</b>	0,268114	0,362614
Model Univariabel	0,349212	0,3468029	<b>0,288561</b>	0,332783	0,371281

Berdasarkan hasil permodelan antara model univariabel dan multivariabel didapatkan perbandingan dengan menggunakan statistik RMSE bahwa nilai RMSE untuk univariabel. Hasil yang didapat adalah dari 5 node pada hidden layer yang dicobakan terlihat bahwa 5 node tersebut paling baik menggunakan model multivariabel. Pada dengan hasil RMSE paling kecil adalah dengan node pada hidden layer sebanyak 9 node.

Berikut merupakan hasil bobot dari neural network untuk data univariabel dan multivariable. Perhitungan neural network dengan input sebanyak 5, hidden layer sebanyak 9 neuron dan output 1 neuron.

**Tabel 4.6** Bobot Neural Network Model Univariabel

Ket,	Bobot	Ket,	Bobot	Ket,	Bobot	Ket,	Bobot
b->z1	-11,39	b->z4	5,85	b->z7	-0,55	b->yt	0,52
yt-1->z1	2,22	yt-1->z4	-0,83	yt-1->z7	0,21	z1->yt	10,97
yt-2->z1	1,06	yt-2->z4	-0,69	yt-2->z7	0,3	z2->yt	-2,73
yt-3->z1	2,55	yt-3->z4	-2,58	yt-3->z7	-2,51	z3->yt	-19,4
yt-4->z1	2,64	yt-4->z4	-1,04	yt-4->z7	-2,59	z4->yt	6,97
yt-5->z1	-3,24	yt-5->z4	3,11	yt-5->z7	4,31	z5->yt	0,74
b->z2	-2,14	b->z5	-2,04	b->z8	-58,86	z6->yt	1,81
yt-1->z2	-5,37	yt-1->z5	-3,22	yt-1->z8	11,97	z7->yt	-7,6
yt-2->z2	-5,46	yt-2->z5	-3,3	yt-2->z8	8,36	z8->yt	2,4
yt-3->z2	-5,29	yt-3->z5	-3,43	yt-3->z8	4,85	z9->yt	-11,7
yt-4->z2	-4,46	yt-4->z5	-3,21	yt-4->z8	-9,26		
yt-5->z2	-4,81	yt-5->z5	-3,45	yt-5->z8	1,66		
b->z3	2,58	b->z6	0,83	b->z9	-6,73		
yt-1->z3	-8,76	yt-1->z6	1,15	yt-1->z9	2,53		
yt-2->z3	2,7	yt-2->z6	3,13	yt-2->z9	-0,82		
yt-3->z3	-6,66	yt-3->z6	0,48	yt-3->z9	2,66		
yt-4->z3	8,6	yt-4->z6	1,02	yt-4->z9	2,51		
yt-5->z3	-1,61	yt-5->z6	1,96	yt-5->z9	-3,48		

Bobot dari data univariabel dapat dilihat pada tabel di atas. Proses perhitungan bobot yang telah konvergen setelah dilakukan perhitungan dengan iterasi sebanyak 10000 didapatkan bobot model *neural network* untuk model univariate.

**Tabel 4.7** Bobot Neural Network Model Multivariabel

Ket,	Bobot	Ket,	Bobot	Ket,	Bobot	Ket,	Bobot
b->z1	-2,47	b->z4	-10,63	b->z7	1,56	b->y	2,69
x1->z1	-10,79	x1->z4	2,78	x1->z7	-9,98	z1->y	3,36
x2->z1	0,03	x2->z4	4,53	x2->z7	5,54	z2->y	-5,25
x3->z1	2,04	x3->z4	-3,51	x3->z7	-5,84	z3->y	4,23
x4->z1	1,05	x4->z4	4,97	x4->z7	-5,91	z4->y	7,15
x5->z1	6,48	x5->z4	1,78	x5->z7	2,56	z5->y	2,83
b->z2	0,7	b->z5	-1,65	b->z8	4,38	z6->y	-1,3
x1->z2	5,87	x1->z5	10,21	x1->z8	-1,59	z7->y	-1,95
x2->z2	-0,23	x2->z5	3,04	x2->z8	-7,36	z8->y	-5,12

x3->z2	-4,1	x3->z5	-9,38	x3->z8	-1,91	z9->y	-2,61
x4->z2	3,42	x4->z5	-5,09	x4->z8	1,04		
x5->z2	0,2	x5->z5	8,01	x5->z8	3,11		
b->z3	-3,81	b->z6	-0,64	b->z9	-10,18		
x1->z3	-8,41	x1->z6	-0,95	x1->z9	-3,62		
Ket,	Bobot	Ket,	Bobot	Ket,	Bobot	Ket,	Bobot
x2->z3	0,75	x2->z6	-7,35	x2->z9	-4,04		
x3->z3	-1,35	x3->z6	-12,47	x3->z9	-10,35		
x4->z3	-5,54	x4->z6	-2,75	x4->z9	0,32		
x5->z3	2,31	x5->z6	6,12	x5->z9	7,94		

Bobot dari data multivariabel dapat dilihat pada tabel di atas. Proses perhitungan bobot telah konvergen setelah dilakukan perhitungan dengan iterasi sebanyak 10000.

Berikut merupakan nilai RMSE hasil simulasi model multivariabel terhadap metode *neural network* dengan menggunakan hidden layer dengan node sebanyak 7,8,9, 10 dan 11 node.

**Tabel 4.8** Nilai RMSE Model Multivariabel Per Jenis

Keterangan	Node = 7	Node = 8	Node = 9	Node = 10	Node = 11
Total Permintaan Pipa	0,279257	0,259377	<b>0,248690</b>	0,268114	0,361214
Pipa Perabot	0,085139	0,065699	<b>0,065614</b>	0,074335	0,094215
Pipa Hitam	0,012284	0,005884	0,029524	<b>0,004657</b>	0,014257
Pipa Air	0,343276	0,241696	0,269818	<b>0,232359</b>	0,272159
Pipa Kotak BJLS	0,074142	0,052442	<b>0,048467</b>	0,054434	0,064434

Berdasarkan hasil tersebut, dapat dilihat bahwa nilai RMSE yang terkecil mengindikasikan bahwa eror yang dikeluarkan juga semakin sedikit artinya model tersebut paling baik dibandingkan model dengan node yang lain.

1. Model *neural network* total permintaan pipa terlihat bahwa nilai RMSE paling kecil terletak pada model dengan hidden layer dengan jumlah node sebanyak 9 node, RMSE dari total permintaan pipa yaitu sebesar 0,248699.
2. Model *neural network* pipa perabot terlihat bahwa nilai RMSE paling kecil terletak pada model dengan hidden layer dengan jumlah node sebanyak 9 node, RMSE dari total permintaan pipa yaitu sebesar 0,065614,
3. Model *neural network* pipa hitam terlihat bahwa nilai RMSE paling kecil terletak pada model dengan hidden layer dengan jumlah node

sebanyak 10 node, RMSE dari total permintaan pipa yaitu sebesar 0,004657.

4. Model *neural network* pipa air terlihat bahwa nilai RMSE paling kecil terletak pada model dengan hidden layer dengan jumlah node sebanyak 10 node, RMSE dari total permintaan pipa yaitu sebesar 0,232359.
5. Model *neural network* pipa kotak BJLS terlihat bahwa nilai RMSE paling kecil terletak pada model dengan hidden layer dengan jumlah node sebanyak 9 node, RMSE dari total permintaan pipa yaitu sebesar 0,048467.


Hasil model multivariabel metode neural network dilakukan pengujian selanjutnya. Pada model tersebut digunakan data pada Bulan Januari 2010 sampai dengan Maret 2014 sebagai training, kemudian data Bulan April 2014 sampai dengan Agustus 2014 sebagai testing untuk menguji kebaikan model yang terbentuk. Berikut hasil testing model yang terbentuk dari data training.

**Tabel 4.9** Hasil Testing Model Multivariabel Permintaan Produk

Bulan	Satuan	Model Multivariabel			
		aktual	prediksi	selisih	persentase
April 2014	Ton/ Bulan	3056,88	3604,761	547,881	17,92%
Mei 2014		2966,50	3885,895	919,395	30,99%
Juni 2014		4119,71	4494,783	375,073	9,10%
Juli 2014		2290,61	2710,701	420,091	18,34%
Agus 2014		3171,88	4263,978	1092,098	34,43%

Berdasarkan tabel 4.8 di atas, terlihat bahwa persentase kesalahan paling besar terletak pada bulan Agustus 2014 yaitu sebesar 34,43% dari nilai sebenarnya. Kemudian yang kedua adalah pada bulan Mei 2014 yaitu sebesar 30,99% dari nilai sebenarnya. Tetapi pada bulan tertentu misalkan bulan Juni prediksi dengan menggunakan neural network model Multivariabel memiliki persentase kesalahan kecil yaitu sebesar 9,10%.

Berikut merupakan gambar plot perbandingan antara hasil prediksi model multivariabel *neural network* terhadap aktual permintaan produk pipa pada bulan April 2014 – Agustus 2014.



**Gambar 4.11** Perbandingan Prediksi dan Aktual Testing

Berdasarkan gambar di atas, terlihat bahwa selisih antara hasil prediksi dan aktual permintaan pipa cukup kecil. Sehingga dapat dikatakan bahwa model cukup baik dalam memprediksi pola perilaku permintaan pipa baja yang terdapat pada PT. Steel Pipe Industry of Indonesia.

Selanjutnya dilakukan peramalan untuk menentukan permintaan produk pipa tiga periode kedepan. Berikut merupakan hasil peramalan permintaan produk pipa tiga periode kedepan yaitu bulan September 2014 sampai dengan bulan November 2014 berdasarkan metode tersebut.

Setiap jenis pipa dilakukan pemodelan kembali dengan menggunakan *neural network* dengan model multivariabel. Node yang digunakan dari masing-masing jenis disesuaikan dengan model terbaik yang telah di hasilkan. Pada Jenis pipa perabot menggunakan hidden layer sebanyak 9 node, untuk jenis pipa hitam menggunakan hidden layer sebanyak 10 node, selanjutnya jenis pipa air menggunakan hidden layer sebanyak 10 node, pipa kotak BJLS menggunakan hidden layer sebanyak 10 node. Berikut merupakan hasil bobot *neural network* yang dihasilkan.

Bobot untuk model neural network multivaribel untuk pipa perabot dengan hidden sebanyak 9 adalah sebagai berikut.

**Tabel 4.10** Bobot Model *Neural Network* Pipa Perabot

Ket,	Bobot	Ket,	Bobot	Ket,	Bobot	Ket,	Bobot
b->z1	-0,26	b->z4	0,85	b->z7	-0,31	b->y	0
x1->z1	-2,72	x1->z4	0,37	x1->z7	2,74	z1->y	-2,09
x2->z1	-3,42	x2->z4	0,94	x2->z7	-0,41	z2->y	1,54
x3->z1	3,71	x3->z4	1,23	x3->z7	-1,39	z3->y	-0,5
x4->z1	-3,8	x4->z4	1,3	x4->z7	5,01	z4->y	0,38
b->z2	-0,66	b->z5	-1,57	b->z8	-1,13	z5->y	1,8
x1->z2	-2,57	x1->z5	0,68	x1->z8	2,54	z6->y	0,26
x2->z2	-1,09	x2->z5	-2,17	x2->z8	1,22	z7->y	-1,96
x3->z2	-1,23	x3->z5	2,49	x3->z8	0,81	z8->y	0,71
x4->z2	1,76	x4->z5	2,31	x4->z8	-1,18	z9->y	-0,53
b->z3	3,31	b->z6	1,32	b->z9	-0,09		
x1->z3	7,68	x1->z6	0,99	x1->z9	-0,84		
x2->z3	4,92	x2->z6	-1,96	x2->z9	-1,55		
x3->z3	-7,47	x3->z6	0,33	x3->z9	-2,04		
x4->z3	0,86	x4->z6	0	x4->z9	0,31		
b->z1	-0,26	b->z4	0,85	b->z7	-0,31		
x1->z1	-2,72	x1->z4	0,37	x1->z7	2,74		
x2->z1	-3,42	x2->z4	0,94	x2->z7	-0,41		

Berdasarkan hasil tersebut menghasilkan RMSE sebesar 0,0656137 lebih kecil dibandingkan dengan jumlah node hidden layer lainnya. Berikut merupakan hasil training dan testing untuk model *Neural Network* Pipa Perabot.

**Tabel 4.11** Testing Model Multivariabel Pipa Perabot

Bulan	Satuan	Model Multivariabel Pipa Perabot			
		aktual	prediksi	selisih	persentase
Apr 2014	Ton/ Bulan	466,8359	419,8286	47,00727	11,20%
Mei 2014		471,6198	465,108	6,51181	1,40%
Juni 2014		455,1038	381,5103	73,59349	19,29%
Juli 2014		330,278	299,8068	30,47117	10,16%
Agus 2014		359,4303	428,3753	68,94502	16,09%

Berdasarkan taabel testing model multivariabel pipa perabot, terlihat bahwa paling besar tingkat kesalahan hasil prediksi terletak pada bulan Juni 2014 yaitu sebesar 19,29% dari nilai aslinya. Kemudian yang paling kecil tingkat kesalahan prediksi terletak pada bulan Mei 2014 yaitu sebesar 1,4%.




Kemudian untuk prediksi permintaan pipa perabot 3 bulan kedepan adalah sebagai berikut.

**Tabel 4.12** Prediksi Model *Neural Network* Pipa Perabot

	Satuan	Hasil Prediksi Pipa Perabot
Sep-14	Ton/ Bulan	555,78
Oct-14		595,73
Nov-14		645,53

Hasil prediksi model multivariabel *neural network* pipa perabot untuk 3 bulan kedepan dapat dilihat pada tabel di atas. Terlihat bahwa setiap bulannya akan mengalami kenaikan jumlah permintaan pipa perabot pada bulan September 2014 sampai dengan bulan November 2014. Selanjutnya gambar perbandingan antara hasil prediksi di tiap bulan dengan aktual permintaan pipa untuk pipa perabot dengan model multivariabel *neural network*.



**Gambar 4.12** Prediksi dan Aktual Pipa Perabot

Bobot untuk model *neural network* multivaribel untuk pipa hitam dengan hidden sebanyak 10 adalah sebagai berikut.

**Tabel 4.13** Bobot Model *Neural Network* Pipa Hitam

Ket,	Bobot	Ket,	Bobot	Ket,	Bobot	Ket,	Bobot
b->z1	5,44	b->z5	0,03	b->z9	-2,2	z10->y	1,11
x1->z1	-1,42	x1->z5	0,75	x1->z9	0,63		
x2->z1	2,23	x2->z5	-0,92	x2->z9	-1,25		
x3->z1	1,51	x3->z5	-4,35	x3->z9	-1,26		
x4->z1	-2,42	x4->z5	3,05	x4->z9	1,74		
b->z2	-1,24	b->z6	-0,02	b->z10	1,95		

Ket,	Bobot	Ket,	Bobot	Ket,	Bobot	Ket,	Bobot
x1->z2	-1,21	x1->z6	-0,07	x1->z10	-1,55		
x2->z2	-0,76	x2->z6	0,04	x2->z10	0,93		
x3->z2	-0,83	x3->z6	-0,55	x3->z10	1,97		
x4->z2	0,12	x4->z6	0,87	x4->z10	0,61		
b->z3	-2,01	b->z7	3,53	b->y	0,05		
x1->z3	2,17	x1->z7	2,28	z1->y	-4,3		
x2->z3	-2,15	x2->z7	3,34	z2->y	-0,03		
x3->z3	-2,89	x3->z7	-15,47	z3->y	2,58		
x4->z3	1,22	x4->z7	9,47	z4->y	2,01		
b->z4	1,28	b->z8	-2,04	z5->y	0,69		
x1->z4	0,08	x1->z8	0,05	z6->y	2,11		
x2->z4	1,45	x2->z8	0,1	z7->y	-9,27		
x3->z4	4,14	x3->z8	0,75	z8->y	1,66		
x4->z4	1,47	x4->z8	1,26	z9->y	1,42		

Berdasarkan hasil tersebut menghasilkan RMSE sebesar 0,004657389 lebih kecil dibandingkan dengan jumlah node hidden layer lainnya. Berikut merupakan hasil traning dan testing untuk model *Neural Network* Pipa Hitam. Kemudian untuk prediksi permintaan pipa hitam 3 bulan kedepan adalah sebagai berikut.

**Tabel 4.14** Testing Model Multivariabel Pipa Hitam


Bulan	Satuan	Model Multivariabel Pipa Hitam			
		aktual	prediksi	selisih	persentase
Apr 2014	Ton/ Bulan	645,2103	644,1117	1,09863	0,17%
Mei 2014		338,6314	338,2609	0,37052	0,11%
Juni 2014		833,7093	831,3957	2,31362	0,28%
Juli 2014		312,849	312,9146	0,06563	0,02%
Agus 2014		442,6306	441,3981	1,23243	0,28%

Berdasarkan taabel testing model multivariabel pipa hitam, terlihat bahwa paling besar tingkat kesalahan hasil prediksi terletak pada bulan Juni 2014 dan Agustus 2014 yaitu sebesar 0,28% dari nilai aslinya. Kemudian yang paling kecil tingkat kesalahan prediksi terletak pada bulan Juli 2014 yaitu sebesar 0,02 %.

**Tabel 4.15** Prediksi Model *Neural Network* Pipa Hitam

	Satuan	Hasil Prediksi Pipa hitam
Sep-14	Ton/ Bulan	345,35
Oct-14		391,63
Nov-14		371,89

Hasil prediksi model multivariabel *neural network* pipa hitam untuk 3 bulan kedepan dapat dilihat pada tabel di atas. Pada bulan Oktober terjadi peningkatan dibandingkan September, tetapi pada bulan November terjadi penurunan dari bulan sebelumnya. Selanjutnya gambar perbandingan hasil prediksi di tiap bulan dengan aktual permintaan pipa untuk pipa hitam dengan model multivariabel *neural network*.



**Gambar 4.13** Prediksi dan Aktual Pipa Hitam

Bobot untuk model neural network multivaribel untuk pipa air dengan hidem sebanyak 10 adalah sebagai berikut.

**Tabel 4.16** Bobot Model *Neural Network* Pipa Air

Ket,	Bobot	Ket,	Bobot	Ket,	Bobot	Ket,	Bobot
b->z1	-18,86	b->z5	5,46	b->z9	-1,59	z10->y	2,61
x1->z1	1,95	x1->z5	-7,88	x1->z9	-2,85		
x2->z1	-14,8	x2->z5	9,62	x2->z9	-12,87		
x3->z1	20,54	x3->z5	6,66	x3->z9	15,01		
x4->z1	-15,69	x4->z5	-4,93	x4->z9	0,98		
b->z2	-1,45	b->z6	-6,29	b->z10	18,97		
x1->z2	2,6	x1->z6	0,38	x1->z10	-8,18		
x2->z2	4,59	x2->z6	1,42	x2->z10	16,13		
x3->z2	4,09	x3->z6	7,77	x3->z10	-13,79		
x4->z2	0,79	x4->z6	3,25	x4->z10	-11,59		
b->z3	6,88	b->z7	6,83	b->y	-3,43		
x1->z3	-2,01	x1->z7	5,88	z1->y	-1,06		
x2->z3	-10,91	x2->z7	-1,52	z2->y	-0,28		
x3->z3	-0,03	x3->z7	-4,85	z3->y	-11,91		
x4->z3	-0,43	x4->z7	0,68	z4->y	2,74		

Ket,	Bobot	Ket,	Bobot	Ket,	Bobot	Ket,	Bobot
b->z4	-16,02	b->z8	-2,89	z5->y	-6,33		
x1->z4	9,56	x1->z8	-14,12	z6->y	0,46		
x2->z4	-13,64	x2->z8	-2,84	z7->y	-1,95		
x3->z4	10,39	x3->z8	3,88	z8->y	-1,15		
x4->z4	12,51	x4->z8	7,52	z9->y	10,79		

Berdasarkan hasil tersebut menghasilkan RMSE sebesar 0.2323592 lebih kecil dibandingkan dengan jumlah node hidden layer lainnya. Berikut merupakan hasil training dan testing untuk model *Neural Network* Pipa Air.

**Tabel 4.17** Testing Model Multivariabel Pipa Air

Bulan	Satuan	Model Multivariabel			
		aktual	prediksi	selisih	persentase
Apr 2014	Ton/ Bulan	1891,925	1845,852	46,07356	2,50%
Mei 2014		2161,822	2052,122	109,6992	5,35%
Juni 2014		3119,433	2810,555	308,8778	10,99%
Juli 2014		1870,083	1641,542	228,5411	13,92%
Agus 2014		2150,901	2302,109	151,2079	6,57%


Berdasarkan taabel testing model multivariabel pipa air, terlihat bahwa paling besar tingkat kesalahan hasil prediksi terletak pada bulan Juli 2014 yaitu sebesar 13,92% dari nilai aslinya. Kemudian yang paling kecil tingkat kesalahan prediksi terletak pada bulan April 2014 yaitu sebesar 2,5 %.

Kemudian untuk prediksi permintaan pipa air 3 bulan kedepan adalah sebagai berikut.

**Tabel 4.18** Prediksi Model *Neural Network* Pipa Air

	Satuan	Hasil Prediksi Pipa air
Sep-14	Ton/ Bulan	3303,53
Oct-14		3609,85
Nov-14		3535,17

Hasil prediksi model multivariabel *neural network* pipa air untuk 3 bulan kedepan dapat dilihat pada tabel di atas. Selanjutnya gambar perbandingan hasil prediksi di tiap bulan dengan aktual permintaan pipa untuk pipa hitam dengan model multivariabel *neural network*.



**Gambar 4.14** Prediksi dan Aktual Pipa Air

Bobot untuk model neural network multivaribel untuk pipa kotak BJLS dengan hidem sebanyak 9 adalah sebagai berikut.

**Tabel 4.19** Prediksi Model *Neural Network* Pipa Kotak BJLS

Ket,	Bobot	Ket,	Bobot	Ket,	Bobot	Ket,	Bobot
b->z1	-1,81	b->z4	-4,76	b->z7	7,99	b->y	-6
x1->z1	4,26	x1->z4	9,24	x1->z7	-10,21	z1->y	-7,6
x2->z1	17,77	x2->z4	-5,12	x2->z7	25,68	z2->y	7,78
x3->z1	-14,44	x3->z4	-1,49	x3->z7	-15,63	z3->y	3,09
x4->z1	-8,72	x4->z4	-2,46	x4->z7	12,36	z4->y	5,4
b->z2	7,63	b->z5	-6,76	b->z8	-4,08	z5->y	-2,78
x1->z2	-0,89	x1->z5	-1,19	x1->z8	-0,49	z6->y	-4,64
x2->z2	3,08	x2->z5	7,41	x2->z8	4,86	z7->y	1,48
x3->z2	5,75	x3->z5	-2,33	x3->z8	-5,16	z8->y	3,77
x4->z2	2,48	x4->z5	1,12	x4->z8	7,51	z9->y	-2,67
b->z3	-18,27	b->z6	10,91	b->z9	15,2		
x1->z3	0,02	x1->z6	-1,03	x1->z9	-17,49		
x2->z3	13,45	x2->z6	-11,95	x2->z9	8,47		
x3->z3	8,19	x3->z6	-0,15	x3->z9	4,24		
x4->z3	-7,05	x4->z6	-4,01	x4->z9	-4,02		

Berdasarkan hasil tersebut menghasilkan RMSE sebesar 0.2593773 lebih kecil dibandingkan dengan jumlah node hidem layer lainnya. Berikut merupakan hasil traning dan testing untuk model *Neural Network* Pipa Kotak BJLS.

**Tabel 4.20** Testing Model Multivariabel Pipa Kotak BJLS

Bulan	Satuan	Model Multivariabel			
		aktual	prediksi	selisih	persentase
Apr 2014	Ton/ Bulan	120,7456	147,0929	26,34735	17,91%
Mei 2014		169,2184	111,0113	58,20713	52,43%
Juni 2014		124,3138	96,24419	28,06956	29,16%
Juli 2014		56,42722	36,34252	20,0847	55,27%
Agus 2014		1,396064	0	1,396064	-

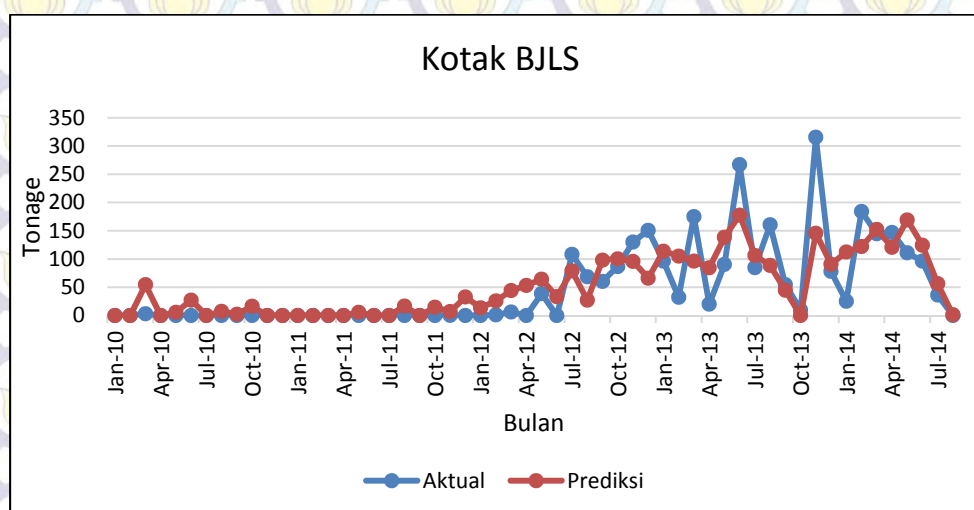
Berdasarkan taabel testing model multivariabel pipa air, terlihat bahwa paling besar tingkat kesalahan hasil prediksi terletak pada bulan Juli 2014 yaitu sebesar 55,27% dari nilai aslinya. Kemudian yang paling kecil tingkat kesalahan prediksi terletak pada bulan April 2014 yaitu sebesar 17,19 %.

Kemudian untuk prediksi permintaan pipa kotak BJLS 3 bulan kedepan adalah sebagai berikut.

**Tabel 4.21** Prediksi Model *Neural Network* Pipa Kotak BJLS

	Satuan	Hasil Prediksi Pipa kotak BJLS
Sep-14	Ton/ Bulan	9,23
Oct-14		26,04
Nov-14		23,80

Hasil prediksi model multivariabel *neural network* pipa air untuk 3 bulan kedepan dapat dilihat pada tabel di atas. Selanjutnya gambar perbandingan hasil prediksi di tiap bulan dengan aktual permintaan pipa untuk pipa hitam dengan model multivariabel *neural network*.



**Gambar 4.15** Prediksi dan Aktual Pipa Kotak BJLS

Berikut merupakan hasil korelasi antara hasil prediksi dengan faktor eksternal yang digunakan pada penelitian ini.

**Tabel 4.22** Korelasi Prediksi Jenis Pipa terhadap Faktor Eksternal

	Perabot	Hitam	Air	Kotak BJLS
Inflasi	-0,134	-0,229	0,156	0,061
Nilai Tukar	0,358	0,238	0,458	0,492
Nilai Ekspor	0,245	0,282	0,193	0,051
Harga Baja	0,189	0,169	0,149	0,153

Berdasarkan hasil prediksi yang telah dijabarkan di atas dapat dinyatakan bahwa.


1. Pengaruh yang paling besar terhadap permintaan pipa perabot adalah dari faktor nilai tukar rupiah terhadap dolar. Hal ini terlihat dari korelasi hasil prediksi dengan nilai tukar rupiah sebesar 0,358. Hal ini berarti ketika nilai tukar rupiah meningkat maka permintaan pipa perabot akan meningkat pula. Karena korelasi keduanya berkorelasi positif.
2. Pengaruh yang paling besar terhadap permintaan pipa hitam adalah dari faktor nilai ekspor Indonesia . Hal ini terlihat dari korelasi hasil prediksi dengan nilai ekspor Indonesia sebesar 0,282. Hal ini menyatakan bahwa ketika nilai ekspor Indonesia meningkat maka permintaan produk pipa hitam akan meningkat pula.
3. Pengaruh yang paling besar terhadap permintaan pipa air adalah dari faktor nilai tukar rupiah terhadap dolar. Hal ini terlihat dari korelasi hasil prediksi dengan nilai tukar rupiah sebesar 0,458. Hal ini menyatakan bahwa ketika nilai tukar rupiah meningkat maka permintaan produk pipa air akan meningkat pula.
4. Pengaruh yang paling besar terhadap permintaan pipa kotak BJLS adalah dari faktor nilai tukar rupiah terhadap dolar. Hal ini terlihat dari korelasi hasil prediksi dengan nilai tukar rupiah sebesar 0,492. Hal ini menyatakan bahwa ketika nilai tukar rupiah meningkat maka permintaan produk pipa kotak BJLS akan meningkat pula.

Berikut merupakan hasil peramalan total permintaan produk pipa pada 3 bulan selanjutnya, yaitu bulan September 2014 sampai bulan November 2014.

**Tabel 4.23** Hasil Peramalan Model Multivariabel

	Satuan	Hasil Prediksi
Sep-14	Ton/ Bulan	3293,959
Oct-14		3221,934
Nov-14		3297,664

Selanjutnya gambar hasil prediksi di tiap bulan permintaan pipa untuk total permintaan produk pipa dengan model multivariabel *neural network*.



**Gambar 4.16** Hasil Prediksi Total Permintaan Pipa

Berikutnya perincian pada masing-masing produk yang diminta oleh konsumen berdasarkan jenis barang yang diminta. Pada bulan sebelumnya yaitu bulan Juni didapat kombinasi permintaan produk pipa dengan total sebesar 4119,70 Ton terdiri dari produk pipa sebagai berikut.

1. Pipa Perabot

Pipa Perabot dengan total permintaan pada bulan Juni 2014 adalah sebesar 400,34 Ton. Berikut merupakan rincian dari jenis-jenis pipa perabot yang dikirimkan ke konsumen pada bulan Juni 2014.

**Tabel 4.24** Rincian Jenis Pipa Perabot Bulan Juni 2014

Diameter (Inci)	Tonase (Ton)	Persentase	Diameter (Inci)	Tonase (Ton)	Persentase
Ø 1"	18,00	4,50%	25x16 (oval)	50,99	12,74%
Ø 1-1/4 "	18,31	4,57%	Ø 3/4"	22,44	5,61%
Ø 1/2 "	18,66	4,66%	40x30 (kotak)	39,24	9,80%
Ø 13/16"	62,41	15,59%	Ø 5/8"	30,42	7,60%
Ø 2"	15,82	3,95%	Ø 7/8"	58,19	14,53%
20x20 (kotak)	20,44	5,11%	Lainnya	45,42	11,35%



## 2. Pipa Hitam

Pipa Hitam dengan total permintaan pada bulan Juni 2014 adalah sebesar 700,18 Ton. Berikut merupakan rincian dari jenis-jenis pipa hitam yang dikirimkan ke konsumen pada bulan Juni 2014.

**Tabel 4.25** Rincian Jenis Pipa Hitam Bulan Juni 2014

Diameter (Inci)	Tonase (Ton)	Persentase	Diameter (Inci)	Tonase (Ton)	Persentase
Ø 1"	356,45	12,74%	Ø 3"	320,86	11,46%
Ø 1-1/2"	249,07	8,90%	Ø 3/4"	434,42	15,52%
Ø 1-1/4"	79,42	2,84%	Ø 4"	396,35	14,16%
Ø 1/2"	210,56	7,52%	Ø 5"	10,93	0,39%
Ø 2"	337,34	12,05%	Ø 6"	271,64	9,71%
Ø 2-1/2"	46,90	1,68%	Ø 8"	84,79	3,03%

## 3. Pipa Air

Pipa Air dengan total permintaan pada bulan Juni 2014 adalah sebesar 2798,73 Ton. Berikut merupakan rincian dari jenis-jenis pipa air yang dikirimkan ke konsumen pada bulan Juni 2014.

**Tabel 4.26** Rincian Jenis Pipa Air Bulan Juni 2014

Diameter (Inci)	Tonase (Ton)	Persentase	Diameter (Inci)	Tonase (Ton)	Persentase
Ø 1"	25,39	3,30%	Ø 3/4"	4,44	0,58%
Ø 1-1/2"	13,65	1,77%	Ø 3/8"	5,20	0,67%
Ø 1-1/4"	6,79	0,88%	Ø 4"	60,65	7,88%
Ø 1/2"	0,01	0,00%	Ø 5"	81,17	10,54%
Ø 1/4"	5,09	0,66%	Ø 6"	10,79	1,40%
Ø 2"	21,35	2,77%	Ø 7"	477,69	62,02%
Ø 2-1/2"	12,70	1,65%	Ø 8"	38,27	4,97%
Ø 3"	6,99	0,91%			

Kemudian untuk produk pipa kotak dengan baja lapis seng (BJLS) yaitu sebesar 150,44 ton.

Berdasarkan data tersebut, maka dapat diambil rasio antara pipa perabot, pipa hitam, pipa air dan pipa kotak BJLS sebagai berikut.

**Tabel 4.27** Rasio Semua Jenis Pipa Bulan Juni 2014

Produk	Tonase (Ton)	Persentase
Pipa perabot	400,34	9.72%
Pipa Hitam	700,18	18.70%
Pipa Air	2798,73	67.94%
Pipa Kotak BJLS	150,44	3.65%
Total	4119,70	100%

Persentase untuk masing-masing produk dan jenis per produk pipa untuk Bulan Juni telah didapat selanjutnya dilakukan perhitungan untuk jumlah produk pipa sampai dengan per produk pipa hasil prediksi pada Bulan September 2014 dengan dua pendekatan model univariat dan multivariabel.

1. Model Multivariabel

Hasil prediksi dengan model multivariabel untuk permintaan produk Bulan September 2014 yaitu 3293.959 Ton. Kemudian dilakukan perhitungan dengan persentase produk pada bulan Juni maka didapat hasil permasing-masing produk pipa pada Bulan September 2014 adalah sebagai berikut.

**Tabel 4.28** Jenis Pipa Model Multivariabel Bulan September 2014

Produk	Tonase (Ton)
Pipa perabot	320.10
Pipa Hitam	615.81
Pipa Air	2237.76
Pipa Kotak BJLS	120.29
Total	3293.959

Berikut merupakan kalkulasi tiap jenis produk pipa yaitu produk pipa perabot, pipa hitam, dan pipa air.

**Tabel 4.29** Pipa Perabot Model Multivariabel Bulan September 2014

Diameter (Inci)	Tonase (Ton)	Diameter (Inci)	Tonase (Ton)
Ø 1"	14.39	25x16 (oval)	40.77
Ø 1 1/4"	14.64	Ø 3/4"	17.94
Ø 1/2"	14.92	40x30	31.38
Ø 13/16"	49.90	Ø 5/8"	24.33
Ø 2"	12.65	Ø 7/8"	46.53
20x20	16.34	Lainnya	36.32

**Tabel 4.30** Pipa Hitam Model Multivariabel Bulan September 2014

Diameter (Inci)	Tonase (Ton)	Diameter (Inci)	Tonase (Ton)
Ø 1"	73.78	Ø 3/4"	12.90
Ø 1-1/2"	39.67	Ø 3/8"	15.10
Ø 1-1/4"	19.73	Ø 4"	176.23
Ø 1/2"	0.04	Ø 5"	235.83
Ø 1/4"	14.79	Ø 6"	31.35
Ø 2"	62.02	Ø 7"	1387.94
Ø 2-1/2"	36.89	Ø 8"	111.19
Ø 3"	20.30		


**Tabel 4.31** Pipa Air Model Multivariabel Bulan September 2014

Diameter (Inci)	Tonase (Ton)	Diameter (Inci)	Tonase (Ton)
Ø 1"	78.43	Ø 3"	70.60
Ø 1-1/2"	54.80	Ø 3/4"	95.59
Ø 1-1/4"	17.47	Ø 4"	87.21
Ø 1/2"	46.33	Ø 5"	2.41
Ø 2"	74.23	Ø 6"	59.77
Ø 2-1/2"	10.32	Ø 8"	18.66

#### 4.5 Formulasi Variabel

Setelah didapatkan hasil peramalan permintaan produk pipa bulan selanjutnya maka dilakukan perhitungan dengan formulasi variabel produk untuk mempersiapkan produk yang akan diproduksi pada bulan selanjut.

Berikut merupakan grafik perbandingan bahan baku yang digunakan untuk produksi pipa dan permintaan produk pada tahun 2010 sampai dengan Juni 2014.



**Gambar 4.17** Bahan Baku dengan Permintaan Produk Pipa

Berdasarkan gambar di atas terlihat bahwa bahan baku yang digunakan dalam proses produksi pada tiap bulannya lebih besar dari jumlah permintaan produk. Hal ini mengakibatkan penumpukan jumlah stok yang cukup besar pada gudang persediaan produk di PT. Spindo Tbk. Hal tersebut mengakibatkan biaya yang keluar bertambah terkait dengan penyimpanan produk pada gudang.

Sehingga berdasarkan hal tersebut maka dilakukan perhitungan untuk mendapatkan bahan baku yang optimal untuk mengurangi pengeluaran biaya terkait dengan penyimpanan produk di gudang. Bahan baku yang optimal didapat dari jumlah permintaan produk pipa ditambahkan dengan rata-rata reject pipa hasil produksi.

Rata-rata reject pipa hasil produksi adalah 100% dikurangi rata-rata yield produksi yaitu 100% - 95,21% atau 4,79% dibulatkan menjadi 5%. Bahan baku yang perlu disediakan untuk melakukan proses produksi pada bulan tertentu adalah permintaan pipa tambahkan dengan 5% dari permintaan pipa.

**Tabel 4.32** Bahan Baku Produk Bulan September 2014 – November 2014

Multivariabel	Permintaan produk	Bahan baku yang disediakan
Sept-2014	3293,959 Ton	$3293,959 + 197,09 = 3458,65$ ton
Okt-2014	3221,934 Ton	$3221,934 + 161,09 = 3383,03$ ton
Nov-2014	3297,664 Ton	$3297,664 + 164,88 = 3462,54$ ton

Berdasarkan hasil tersebut, didapatkan kebutuhan bahan baku untuk bulan September 2014 pada model multivariabel adalah sebesar 3458.65 dengan asumsi 5% dari bahan baku yang nantinya akan menjadi hasil reject atau gagal produk.

Kemudian untuk ketersediaan jam efektif mesin atau utilitas digunakan metode regresi linier sederhana. Berikut merupakan hasil pemodelan data permintaan produk pipa dengan utilitas mesin yang akan digunakan untuk melakukan produksi.

$$\text{Utilitas} = 0,371 + 0,000113 (\text{Permintaan Produk})$$

Berdasarkan model regresi di atas dapat diinterpretasikan sebagai berikut, setiap kenaikan 1 ton permintaan produk pipa maka akan menambah utilitas mesin pada bulan tersebut sebesar 0,000113 atau sebesar 0,013%.

$$R\text{-Sq} = 53,9\% \quad , \quad R\text{-Sq}(\text{adj}) = 53,0\%$$


Selanjutnya untuk kebaikan modelnya Permintaan produk pipa dapat menjelaskan utilitas mesin sebesar 53,9% dari keseluruhan model, dan sisanya dijelaskan oleh variabel lainnya.

Selanjutnya setelah model utilitas terhadap permintaan produk didapat, dilakukan prediksi dengan menggunakan model tersebut untuk mendapat utilitas mesin yang harusnya tersedia pada bulan September 2014 – November 2014 untuk memenuhi kebutuhan permintaan produk pipa.

**Tabel 4.33** Utilitas Mesin Produksi September 2014 – November 2014

Multivariabel	Permintaan produk	Utilitas mesin yang disediakan
Sept-2014	3293,959 Ton	$0,371 + 0,000113 (3293,959) = 74,32\%$
Okt-2014	3221,934 Ton	$0,371 + 0,000113 (3221,934) = 73,51\%$
Nov-2014	3297,664 Ton	$0,371 + 0,000113 (3297,664) = 74,36\%$

Berdasarkan tabel di atas, terlihat bahwa jumlah kebutuhan utilitas mesin untuk memproduksi permintaan produk bulan September 2014 adalah sebesar 74,32%, kemudian untuk bulan Oktober sebesar 73,51%, dan bulan November 2014 adalah sebesar 74,36%.



## BAB V KESIMPULAN DAN SARAN

### 5.1 Kesimpulan

Berdasarkan analisis dan pembahasan diperoleh beberapa kesimpulan yang dapat disimpulkan sebagai berikut:

1. Pemilihan model terbaik dalam peramalan permintaan pipa baja dengan menggunakan metode *neural network* PT. Steel Pipe Industry of Indonesia Tbk. menghasilkan permodelan antara model univariabel dan multivariabel. Perbandingan dengan menggunakan statistik RMSE didapat bahwa nilai RMSE untuk multivariabel lebih kecil dari univariabel pada node yang menghasilkan RMSE paling kecil yaitu 9. RMSE untuk multivariabel adalah 0,248 dibandingkan dengan 0,288. Hal ini menyatakan bahwa, untuk permintaan produk pipa dalam memprediksi permintaan pipa lebih baik menggunakan model *neural network* dengan multivariabel. Terkait pemodelan dengan model *neural network* multivariabel untuk masing-masing produk pipa baja untuk pipa perabot RMSE paling kecil pada jumlah hidden node sebanyak 9 node dengan nilai RMSE 0,0656. Kemudian untuk pipa hitam RMSE paling kecil dengan jumlah hidden node sebanyak 10 node dengan nilai RMSE 0,0046. Pada pipa air jumlah node dengan RMSE paling kecil adalah pada 10 hidden node dengan RMSE sebesar 0,2323. Dan pada pipa kotak BJLS RMSE paling kecil pada hidden node sebanyak 9 node dengan RMSE 0,0484.
2. Hasil peramalan permintaan pipa baja pada PT. Steel Pipe Industry of Indonesia Tbk. dengan model *neural network* dalam mendukung perencanaan pada produksi di PT. Steel Pipe Industry of Indonesia Tbk. pada bulan September 2014 sampai dengan bulan November 2014 di prediksi akan mengalami peningkatan permintaan produk pipa pada bulan September 2014 yaitu sebesar 3293,95 ton dibanding bulan sebelumnya Agustus 2014 yaitu 3171,88 ton. Tetapi pada bulan Oktober akan

mengalami penurunan yaitu 3221,93 ton kemudian pada bulan November terjadi peningkatan kembali yaitu 3297.66 ton. Prediksi produk pipa baja permasing-masing jenis produk menghasilkan hasil prediksi pada bulan September 2014, Oktober 2014 dan November 2014 yaitu untuk pipa perabot sebesar 555,78 ton, 595,73 ton, dan 645,53 ton. Kemudian untuk pipa hitam 345,35 ton, 391,63 ton, dan 371,89 ton. Pada pipa air adalah 3303,53 ton, 3609,8 ton, dan 3535,17 ton. Untuk Pipa kotak BJLS 9,23 ton, 26,04 ton, dan 23,80 ton.

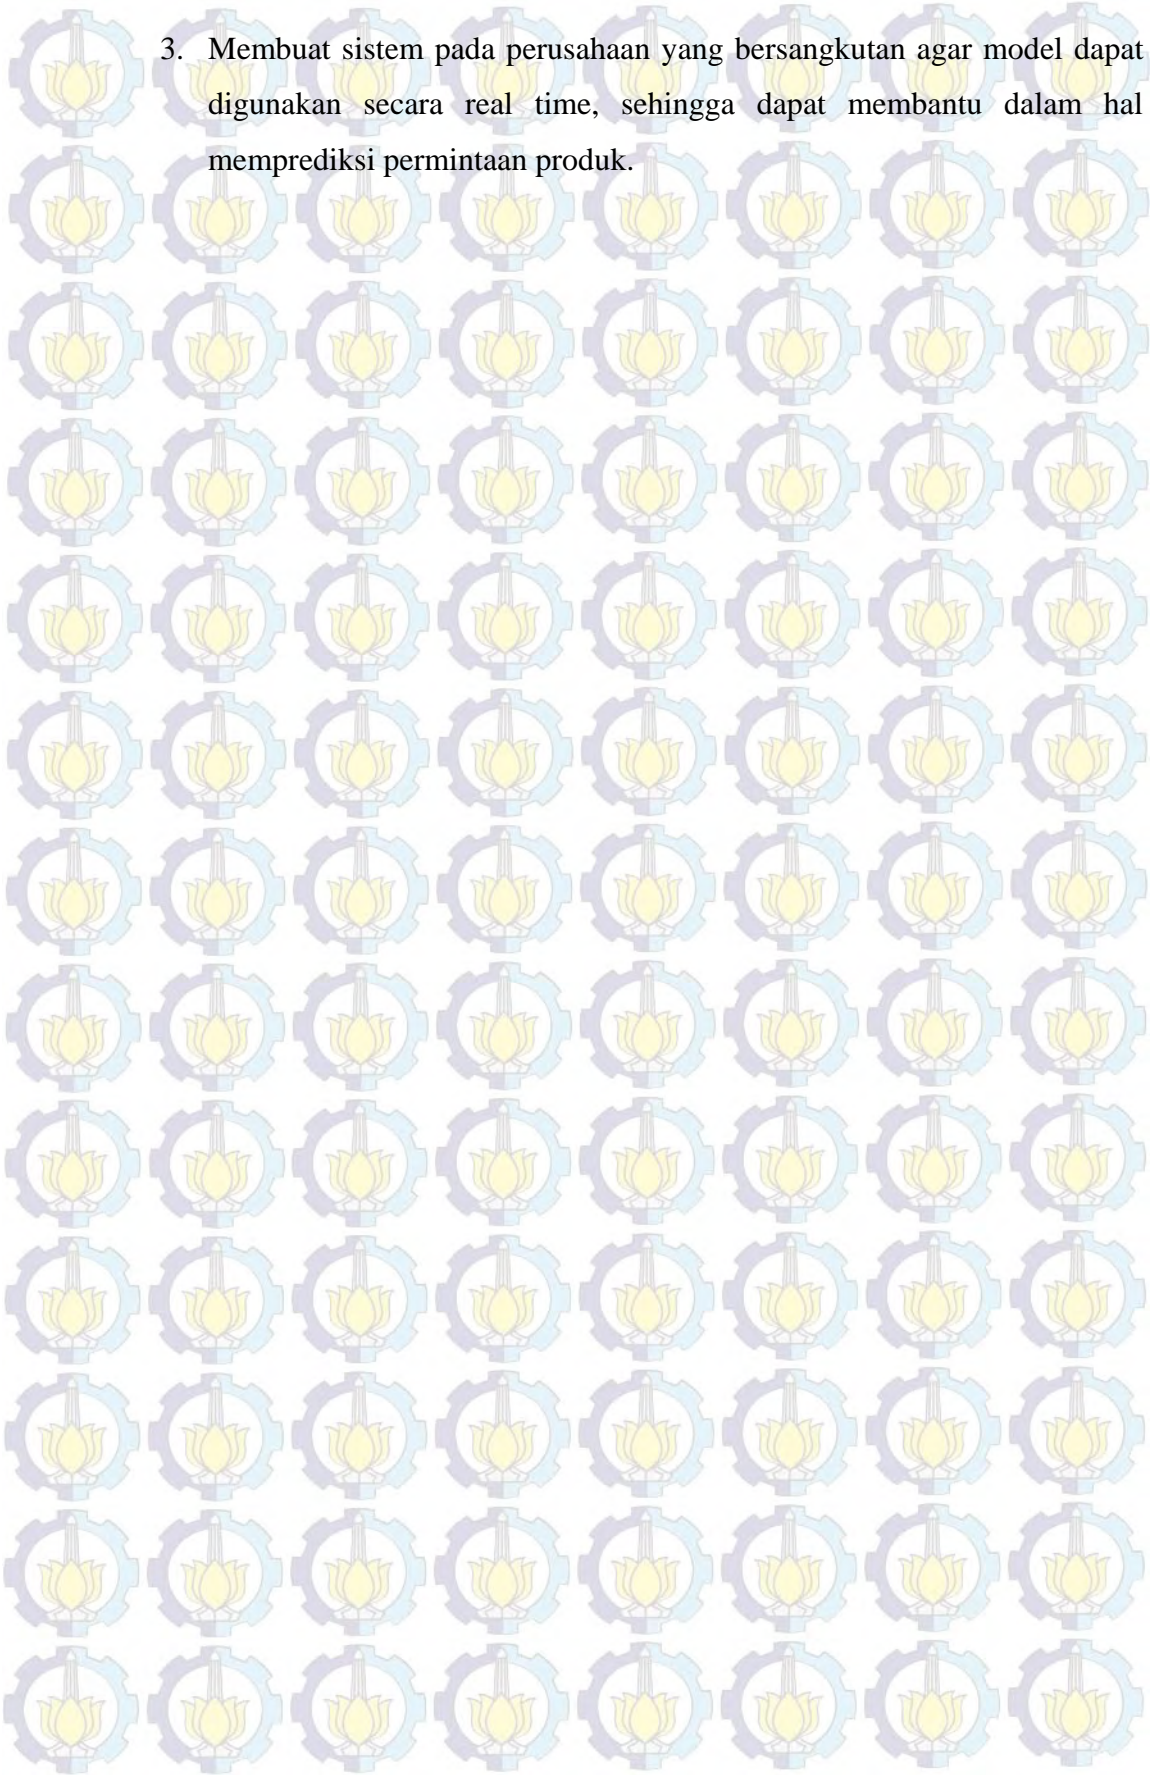
3. Model pendukung keputusan guna mendukung perencanaan produksi di PT. Steel Pipe Industry Indonesia Tbk. menghasilkan kebutuhan bahan baku untuk bulan September 2014 sampai dengan bulan November 2014 pada model multivariabel secara berturut-turut adalah sebesar 3458.65 ton, 3383.03 ton, 3462.54 ton dengan 5% dari bahan baku yang nantinya akan menjadi hasil reject atau gagal produk. Kemudian utilitas mesin untuk memproduksi permintaan produk bulan September 2014 sampai bulan November 2014 secara berturut-turut adalah sebesar 74,32%, 73,51%, dan 74,36%.


## **5.2 Saran**

Berikut merupakan saran untuk penelitian selanjutnya agar dapat menyempurnakan penelitian untuk perencanaan produksi pipa baja.

1. Menambahkan beberapa variabel eksternal dan internal perusahaan untuk menambah variansi dan penjelasan model yang lebih baik lagi. Hal ini diharapkan dapat memperbaiki model yang sudah terbentuk agar lebih memperbesar akurasi dan presisi hasil prediksi.
2. Menambahkan analisis pada bagian tertentu agar penjelasan dan hasil analisis lebih mendalam dan terfokus pada bagian tertentu.



- 
3. Membuat sistem pada perusahaan yang bersangkutan agar model dapat digunakan secara real time, sehingga dapat membantu dalam hal memprediksi permintaan produk.



## DAFTAR PUSTAKA

Anonim (2014). Ekonomi metrotv news, *Pembangunan infrastruktur tak mungkin andalkan APBN* : Metro TV Online <http://ekonomi.metrotvnews.com/read/2014/09/16/292226/pembangunan-infrastruktur-tak-mungkin-andalkan-apbn>. Diakses pada tanggal 12 November 2014.

Armstrong, J. S. (Ed.) (2001). *Principles of forecasting: a handbook for researchers and practitioners*. Boston, MA: Kluwer Academic.

Caraka, Rezy Eko. (2014). *Prediksi Indeks Euro 50 Menggunakan Feed Forward Neural Network (FFNN) Dengan Pelatihan Algoritma Genetika*, Universitas Diponegoro Semarang.

Cryer, J.D. 1986. *Time Series Analysis*. PWS-KENT Publishing Company, Boston.

Fausett, Lauren. 1994. *Fundamental of Neural Network: Architectures, algorithm and applicalions*, Prantice Halt.

Fildes, R., Goodwin, P., & Lawrence, M. (2006). The design features of forecasting support systems and their effectiveness. *Decision Support Systems*, 42(1), 351–361.

Goodwin, P., Lee, W. Y., Fildes, R., Nikolopoulos, K., & Lawrence, M. (2006). *Understanding the use of forecasting systems: an interpretive study in a supply-chain company*. Bath University Management School working paper.


Hanke, J.E., Reitsch, A.G. dan Wichern, D.W. 2003. *Peramalan Bisnis*. Edisi Ketujuh. Alih Bahasa: Devy Anantanur. PT. Prenhallindo. Jakarta.

Hermawan, Julius. 2005. *Membangun Decision Support System*. Yogyakarta: Andi.

Hyndman, Rob J. 2010. *Forecasting: Principles And Practice*. OTexts.Org

Kusumadewi, S. (2004). *Membangun Jaringan Syaraf Tiruan (menggunakan MATLAB & Excel Link)*. Yogyakarta: Graha ilmu.

- Liang, T. P., Lee, C.C., dan Turban, E. (2008), *Model Management and Solver for Decision Support in Handbook of Decision Support System 1*, eds. Burstein, F., dan Holsapple, V.V., Springer-verlag, Berlin, hal. 231-258.
- Machmudin, Ali., Ulama, Brodjol S. S. (2012), Peramalan Temperatur Udara di Kota Surabaya dengan Menggunakan ARIMA dan Artificial Neural Network, *Jurnal Sains Dan Seni Its* Vol. 1, No. 1, (Sept. 2012) ISSN: 2301-928X.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting: methods and applications* (3rd ed.). New York: Wiley & Sons.
- Makridakis, S., Wheelwright, S.C., dan McGee, V. Alih bahasa Ir. Hari Suminto. 1999. *Metode dan Aplikasi Peramalan*. Edisi kedua. Binarupa Aksara, Jakarta.
- Suhartono. 2007. *FeedForward Neural Network untuk Pemodelan Runtun Waktu*. Disertasi, Jurusan Matematika, Universitas Gadjah Mada
- Turban, E., dan McLean, E. (2002), *Information Technology for Management: Transforming Business in The Digital Economy*, 3<sup>rd</sup> Edition, John Wiley and Sons, Inc., New York.
- Universitas Indonesia Online (2014), *Sumbangsih fakultas teknik Universitas Indonesia untuk percepatan pembangunan infrastruktur di Indonesia*, <http://eng.ui.ac.id/csid-fakultas-teknik-universitas-indonesia-sumbangsih-ftui-untuk-percepatan-pembangunan-infrastruktur-di-indonesia/>
- Walpole, Ronald E. 1995. *Pengantar Statistika Edisi Ke-3*. Gramedia Pustaka Utama. Jakarta.
- Wei, W.W., 2006. *Time Series Analysis : Univariate and Multivariate Methods* (2nd ed.), Addison Wesley.
- Zhang, G.P., 2003. A Combined ARIMA and Neural Network Approach for Time Series Forecasting, dalam *Neural Networks in Business Forecasting* (pp. 213-225). New York City: IGI Global



**LAMPIRAN 1. Data Permintaan Produksi, Yield, Utilitas Mesin, Bahan Baku.**

Bulan	Permintaan Produk	Yield %	Utilitas	Bahan Baku
Jan-10	2,334.97	93.79	57%	2,757.43
Feb-10	1,641.64	94.84	52%	2,320.84
Mar-10	2,328.77	93.12	66%	2,762.38
Apr-10	2,152.19	94.93	71%	3,175.03
May-10	2,290.85	94.53	72%	3,109.54
Jun-10	1,561.06	92.98	64%	2,797.15
Jul-10	1,824.49	93.91	66%	2,478.80
Aug-10	2,451.70	93.87	54%	2,148.97
Sep-10	1,287.75	94.53	31%	1,211.95
Oct-10	2,514.76	94.18	57%	2,546.46
Nov-10	2,310.79	93.50	53%	1,595.58
Dec-10	1,767.96	93.26	57%	2,743.88
Jan-11	2,436.42	93.96	60%	2,996.67
Feb-11	2,351.13	94.53	52%	2,500.87
Mar-11	2,852.83	93.79	72%	3,412.16
Apr-11	1,626.73	92.77	62%	2,037.85
May-11	1,672.45	94.55	73%	3,590.30
Jun-11	2,482.30	94.70	61%	3,139.45
Jul-11	2,246.17	94.82	56%	2,908.38
Aug-11	1,729.00	95.33	51%	3,194.03
Sep-11	2,952.85	95.04	53%	2,991.46
Oct-11	3,163.06	94.86	66%	3,811.89
Nov-11	3,313.20	95.19	74%	3,930.97
Dec-11	3,421.27	95.70	76%	4,124.64
Jan-12	3,203.17	96.34	69%	3,937.00
Feb-12	3,269.89	95.72	77%	4,502.74
Mar-12	2,785.95	95.47	75%	4,088.49
Apr-12	3,764.91	95.09	78%	3,954.19
May-12	3,818.10	95.27	78%	4,568.96
Jun-12	3,402.87	96.18	76%	4,701.74
Jul-12	3,407.43	95.73	81%	4,282.08
Aug-12	1,956.63	95.99	55%	3,391.59
Sep-12	3,276.50	95.15	71%	4,183.14
Oct-12	3,394.86	95.52	71%	4,458.45
Nov-12	3,550.62	96.29	74%	4,338.89
Dec-12	3,404.14	95.98	77%	5,496.02
Jan-13	3,409.93	96.44	78%	4,460.18
Feb-13	3,611.90	95.98	71%	4,106.68
Mar-13	3,885.55	96.07	80%	4,378.91

Apr-13	3,666.33	96.02	87%	4,002.47
May-13	3,681.85	96.35	86%	4,337.34
Jun-13	3,568.58	95.80	99%	3,962.97
Jul-13	4,527.97	96.33	71%	5,256.55
Aug-13	2,292.08	95.81	56%	3,771.87
Sep-13	3,985.75	96.50	86%	4,963.42
Oct-13	4,359.31	96.18	84%	4,235.31
Nov-13	4,287.17	96.78	84%	4,975.86
Dec-13	3,798.69	95.58	83%	4,661.44
Jan-14	4,109.90	95.86	85%	5,191.46
Feb-14	3,948.75	96.27	80%	4,882.27
Mar-14	2,592.11	96.10	84%	4,630.37
Apr-14	3,056.88	95.99	89%	4,844.42
May-14	2,966.50	95.68	87%	4,726.37
Jun-14	4,119.71	96.05	82%	5,570.33

**LAMPIRAN 2. Data Inflasi, Nilai Tukar Rupiah terhadap Dollar, Nilai Ekspor, Harga Baja.**

Bulan	Inflasi	Nilai Tukar	Nilai Ekspor	Harga Baja
Jan-10	0.84	9350	11595.87	702
Feb-10	0.3	9337	11166.45	727.5
Mar-10	-0.14	9090	12774.37	786
Apr-10	0.15	9012.5	12035.25	829.5
May-10	0.29	9175	12619.13	821
Jun-10	0.97	9060	12330.11	766.5
Jul-10	1.57	8940	12486.97	699.5
Aug-10	0.76	9035	13726.52	700.5
Sep-10	0.44	8925	12181.63	709.5
Oct-10	0.06	8937.5	14399.64	671
Nov-10	0.6	9034	15633.28	675
Dec-10	0.92	9010	16829.89	806.5
Jan-11	0.89	9048	14606.25	914
Feb-11	0.13	8821.5	14415.28	976.5
Mar-11	-0.32	8707.5	16365.95	1018.5
Apr-11	-0.31	8564	16554.24	998
May-11	0.12	8535.5	18287.44	925
Jun-11	0.55	8576.5	18386.86	887.5
Jul-11	0.67	8500	17418.47	833.5
Aug-11	0.93	8533	18647.83	797.5
Sep-11	0.27	8790	17543.41	821.5
Oct-11	-0.12	8852.5	16957.74	785.5
Nov-11	0.34	9110	17235.46	789
Dec-11	0.57	9067.5	17077.69	832
Jan-12	0.76	8990	14606.25	864.5
Feb-12	0.05	9020	14415.28	838.5
Mar-12	0.07	9144	16365.95	813
Apr-12	0.21	9190	16554.24	808
May-12	0.07	9190.5	18287.44	769.5
Jun-12	0.62	9360	18386.86	724.5
Jul-12	0.7	9400	17418.47	734
Aug-12	0.95	9392.5	18647.83	780
Sep-12	0.01	9392.5	17543.41	748
Oct-12	0.16	9467.5	16957.74	704.5
Nov-12	0.07	9445	17235.46	750.5
Dec-12	0.54	9535.3	17077.69	758
Jan-13	1.03	9535	15375.49	742
Feb-13	0.75	9590	15015.63	731
Mar-13	0.63	9570	15024.58	732.5



Apr-13	-0.1	9626.8	14760.89	716
May-13	-0.03	9605	16133.36	693
Jun-13	1.03	9592.9	14758.82	723.5
Jul-13	3.29	9593.5	15087.86	755
Aug-13	1.12	9652	13083.71	778
Sep-13	-0.35	9637.5	14706.78	771.5
Oct-13	0.09	9763.2	15698.33	784
Nov-13	0.12	9697.5	15938.56	797
Dec-13	0.55	9683.5	16967.8	802.5
Jan-14	1.07	9663.5	14472.29	802
Feb-14	0.26	9717.5	14634.09	778.5
Mar-14	0.08	9722.5	15192.63	772.5
Apr-14	-0.02	9795	14292.47	818.5
May-14	0.16	9925	14823.6	826
Jun-14	0.43	10277.5	15409.45	801
Jul-14	0.93	10920	14124.13	806
Aug-14	0.47	11580	14481.64	808

### LAMPIRAN 3. Syntak Program “R” untuk membangun model Univariate.

```
library (nnet)
datau= read.csv("D://datau.csv",header=TRUE)
sample = cbind(datau$Yt1,datau$Yt2,
datau$Yt3,datau$Yt4, datau$Yt5)
target = datau$Yt
output = nnet(sample, target ,size= 9, linout = TRUE,
maxit=10000)
e=output$residuals
RMSE = sqrt(mean(e^2))
RMSE
samp =rbind(c(2.9665, 3.05688, 2.59211, 3.94875,
4.1099),c(4.11971, 2.9665, 3.05688, 2.59211,
3.94875),c(2.29061, 4.11971, 2.9665, 3.05688,
2.59211))
predict(output, samp)
```

### LAMPIRAN 4. Syntak Program “R” untuk membangun model Multivariate.

```
library (nnet)
datam= read.csv("D://datam.csv",header=TRUE)
sample = cbind(datam$X1, datam$X2, datam$X3, datam$X4,
datam$X5)
target = datam$Y
output = nnet(sample, target ,size= 9, linout = TRUE,
maxit=10000)
e=output$residuals
RMSE = sqrt(mean(e^2))
RMSE
samp=rbind(c(0.16,0.9925,1.482360266,0.826,2.9665),
c(0.43,1.02775,1.540945177,0.801,4.11971),c(0.93,1.092
,1.41241293,0.806,2.29061))
predict(output, samp)
```

**LAMPIRAN 5. Output Minitab Korelasi Pearson.**

	prod	Inflasi	Nilai Tukar	Nilai Ekspor
Inflasi	0.009 0.949			
Nilai Tukar	0.443 0.001	0.101 0.459		
Nilai Ekspor	0.257 0.056	-0.123 0.368	-0.200 0.139	
Harga Baja	-0.185 0.172	-0.245 0.069	-0.274 0.041	0.200 0.139

**Pipa Perabot**

	Perabot	Inflasi	Nilai Tukar	Nilai Ekspor
Inflasi	-0.094 0.492			
Nilai Tukar	0.334 0.012	0.101 0.459		
Nilai Ekspor	0.216 0.109	-0.123 0.368	-0.200 0.139	
Harga Baja	-0.040 0.772	-0.245 0.069	-0.274 0.041	0.200 0.139

**Pipa Hitam**

	Hitam	Inflasi	Nilai Tukar	Nilai Ekspor
Inflasi	-0.228 0.091			
Nilai Tukar	0.238 0.077	0.101 0.459		
Nilai Ekspor	0.282 0.035	-0.123 0.368	-0.200 0.139	
Harga Baja	0.002 0.990	-0.245 0.069	-0.274 0.041	0.200 0.139

**Pipa Air**

	Air	Inflasi	Nilai Tukar	Nilai Ekspor
Inflasi	0.144 0.288			
Nilai Tukar	0.417 0.001	0.101 0.459		
Nilai Ekspor	0.188 0.166	-0.123 0.368	-0.200 0.139	
Harga Baja	-0.244 0.069	-0.245 0.069	-0.274 0.041	0.200 0.139

Pipa Kotak BJLS

	Kotak BJLS	Inflasi	Nilai Tukar	Nilai Ekspor
Inflasi	0.064 0.637			
Nilai Tukar	0.403 0.002	0.101 0.459		
Nilai Ekspor	0.049 0.717	-0.123 0.368	-0.200 0.139	
Harga Baja	-0.225 0.095	-0.245 0.069	-0.274 0.041	0.200 0.139

LAMPIRAN 6. Output Minitab Korelasi Pearson Hasil Prediksi.

Pipa Perabot Hasil Prediksi

	perabot1	X1	X2	X3
X1	-0.134 0.326			
X2	0.358 0.007	0.101 0.459		
X3	0.245 0.069	-0.123 0.368	-0.200 0.139	
X4	0.689 0.000	-0.208 0.124	0.241 0.074	0.216 0.109

Pipa Air Hasil Prediksi

	air1	X1	X2	X3
X1	0.156 0.251			
X2	0.458 0.000	0.101 0.459		
X3	0.193 0.154	-0.123 0.368	-0.200 0.139	
X4	0.449 0.001	-0.208 0.124	0.241 0.074	0.216 0.109


### Pipa Hitam Hasil Prediksi

	hitam1	X1	X2	X3
X1	-0.229 0.090			
X2	0.238 0.077	0.101 0.459		
X3	0.282 0.035	-0.123 0.368	-0.200 0.139	
X4	0.969 0.000	-0.208 0.124	0.241 0.074	0.216 0.109


### Pipa Kotak BJLS Hasil Prediksi

	kotak	bjls1	X1	X2	X3
X1		0.061 0.657			
X2		0.492 0.000	0.101 0.459		
X3		0.051 0.711	-0.123 0.368	-0.200 0.139	
X4		0.353 0.008	-0.208 0.124	0.241 0.074	0.216 0.109

LAMPIRAN 7. Arsitektur Penuh Model Neural Network Univariabel



**LAMPIRAN 8.** Arsitektur Penuh Model Neural Network Multivariabel



**LAMPIRAN 9.** Output Minitab Regresi Utilitas dan Permintaan Produk.

**Regression Analysis: ut versus per**

The regression equation is  
 $ut = 0.371 + 0.000113 \text{ per}$

Predictor	Coef	SE Coef	T	P
Constant	0.37144	0.04462	8.33	0.000
per	0.00011308	0.00001451	7.79	0.000

S = 0.0889085    R-Sq = 53.9%    R-Sq(adj) = 53.0%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	0.48008	0.48008	60.73	0.000
Residual Error	52	0.41105	0.00790		
Total	53	0.89112			

## BIODATA PENULIS



**Ida Bagus Oka Ari Adnyana**, dengan nama panggilan **Oka**, merupakan laki-laki kelahiran Semarang, 7 Agustus 1991. Domisili penulis semenjak lahir sampai sekarang berpindah-pindah karena profesi orang tua. Kota Semarang selama 3 tahun, Kota Jember selama 5 tahun, Kabupaten Sidoarjo selama 8 tahun, Kabupaten Klungkung, Bali selama 3 tahun, dan sekarang kembali ke Sidoarjo. Penulis menempuh pendidikan mulai SDN Kepatihan 16, Jember (1997-1998), SDN Pucang 1, Sidoarjo (1998-

2003), SMPN 4 Sidoarjo (2003-2006), SMAN 1 Dawan, Klungkung, Bali (2006-2009), dan terakhir sebagai mahasiswa S1 Statistika FMIPA ITS, Surabaya(2009-2013).

Ketika penulis mengenyam pendidikan di Statistika ITS, penulis aktif untuk mengembangkan diri tidak hanya dalam akademik, tapi juga aktif mengikuti berbagai macam kegiatan organisasi di kampus. Pada tahun 2010, penulis menduduki posisi sebagai staf Internal Lembaga Minat Bakat ITS dan Staf Departemen PSDM HIMASTA ITS, kemudian pada tahun 2011, penulis menduduki jabatan sebagai Kepala Departemen Internal Lembaga Minat Bakat ITS dan Kepala Biro Kaderisasi PSDM Himasta ITS. Tahun 2012, penulis menjabat sebagai Kepala Departemen Dalam Negeri Lembaga Minat Bakat ITS. Disamping itu, penulis juga dipercaya sebagai Asisten Dosen untuk mata kuliah di Jurusan Statistika ITS yaitu mata kuliah Statistika Non Parametrik, Analisis Multivariat, Pengendalian Kualitas Statistik, Sistem Informasi Manajemen, Pengantar Ilmu Komputer, Program Komputer, dan Teknik Simulasi. Penulis pernah meraih prestasi, antara lain finalis 8 besar lomba Bussiness Plan Competition, BEM FMIPA, Tingkat Institut dan pemenang lomba pengelolaan Resiko Perbankan, Bank Mandiri, Tingkat Nasional.

Keterarikan riset penulis dalam bidang komputasi statistik, mendorong penulis untuk mempelajari *Numerical Method*, *Neural Network* dan *Nonparametric Inference* yang digunakan sebagai metode dalam Tugas Akhir. Segala saran dan kritik dapat dikirimkan melalui email penulis, yakni [idabagus\\_oka@rocketmail.com](mailto:idabagus_oka@rocketmail.com)





## **MODEL PENDUKUNG KEPUTUSAN UNTUK PERENCANAAN PRODUKSI PIPA BAJA DENGAN MENGGUNAKAN NEURAL NETWORK DI PT. XYZ TBK.**

*Ida Bagus Oka Ari Adnyana<sup>1)</sup> dan M. Isa Irawan<sup>2)</sup>*

*1) Program Studi Magister Manajemen Teknologi, Institut Teknologi Sepuluh Nopember  
Jl. Cokroaminoto 12A, Surabaya, 60264, Indonesia  
e-mail : idabagus\_oka@rocketmail.com*

*2) Jurusan Matematika, Institut Teknologi Sepuluh Nopember*

### **ABSTRAK**

Pembangunan infrastruktur berperan signifikan dalam mendorong pertumbuhan dan pembangunan ekonomi Indonesia. Saat ini, pada PT. XYZ Tbk sering terjadi ketidaksinambungan antara rencana produksi dengan proses produksi. Hal ini menyebabkan biaya yang besar untuk barang-barang yang tidak terjual ke pelanggan yang disimpan pada gudang. Sistem pendukung untuk merencanakan proses produksi yang berkelanjutan pada perusahaan diharapkan dapat melakukan manajemen terhadap perencanaan proses produksi. Metode pemodelan data yang digunakan adalah pemodelan *neural network* untuk meramalkan permintaan produk. Pada penelitian ini dibandingkan antara model peramalan *time series* dengan model multivariabel kemudian dicari model terbaik. Data yang digunakan dalam penelitian ini adalah data permintaan produk bulanan pipa baja pada PT. Steel Pipe Industry of Indonesia Tbk dan beberapa data pendukung lainnya. Hasil pemodelan antara model univariabel dan multivariabel didapatkan perbandingan dengan menggunakan statistik RMSE bahwa untuk permintaan produk pipa dalam memprediksi permintaan pipa lebih baik menggunakan model *neural network* dengan multivariabel. Hasil peramalan permintaan pipa baja dengan model *neural network* dalam mendukung perencanaan pada produksi di PT. XYZ Tbk. pada bulan September 2014 di prediksi akan mengalami peningkatan permintaan produk pipa.

Kata kunci : *Neural Network, Time Series, Multivariabel, Decision Support System*

### **PENDAHULUAN**

Pembangunan infrastruktur berperan signifikan dalam mendorong pertumbuhan dan pembangunan ekonomi Indonesia. Kedua komponen infrastruktur yakni infrastruktur fisik dan sosial, diharapkan dapat memberikan layanan yang terbaik untuk kepentingan umum. Susilo Bambang Yudhoyono mengemukakan, sampai dengan tahun 2015 mendatang dibutuhkan anggaran sebesar Rp 4.700 triliun guna membangun infrastruktur di Tanah Air. Sekitar 40% dana pembangunan infrastruktur di Tanah Air bisa ditutup dengan melibatkan dana swasta, dimana pemerintah mengutamakan pada swasta dalam negeri dan mengajak swasta dari negara-negara sahabat. Adapun 25% lagi berasal dari BUMN dan sedikit dari itu BUMD, dan 15% lagi baru dari APBN. Jumlah ketiga-tiganya mencapai 80%, masih kurang 20%. Itulah yang kita sebut patungan, paduan dari dana pemerintah, dana BUMN, dan dana swasta. [1]

Di tengah perkembangan Masterplan Percepatan dan Perluasan Pembangunan Ekonomi Indonesia (MP3EI) yang direncanakan selesai pada 2025, permintaan pipa baja untuk konstruksi diperkirakan akan meningkat. Pembangunan infrastruktur minyak dan gas



juga akan meningkatkan permintaan pipa baja. Hal-hal tersebut mendorong perusahaan pipa baja di Indonesia untuk meningkatkan kapasitas produksinya dengan membangun pabrik. Pada saat ini sering terjadi ketidaksinambungan akan rencana produksi pipa dengan proses produksi pipa yang terjadi di PT. XYZ, Tbk. Hal ini menyebabkan terjadi gap antara barang yang diproduksi dengan barang yang diminta oleh pelanggan. Sehingga terjadi pembengkakan biaya yang besar untuk barang-barang yang tidak terjual ke pelanggan yang disimpan pada gudang. Model pendukung untuk merencanakan proses produksi yang berkelanjutan pada perusahaan diharapkan dapat melakukan manajemen terhadap perencanaan proses produksi di PT. XYZ Tbk.

Berdasarkan penjelasan tersebut, perlu adanya model decision suport system pada perusahaan manufaktur pipa baja dalam perencanaan produksi. Sehingga model pendukung keputusan guna mendukung perencanaan produksi pada PT. XYZ Tbk. kiranya perlu dianalisis dan ditinjau dengan teori yang ada.

## **METODE**

Data yang digunakan dalam penelitian ini adalah data permintaan produk bulanan pipa baja pada PT. XYZ Tbk. data ini yang nantinya akan diramalkan beberapa periode kedepan. Data permintaan produk bulanan pipa baja ini dari tahun 2010 sampai dengan pertengahan tahun 2014 yaitu bulan Juni. Selain data permintaan dalam pengembangan model pendukung keputusan, digunakan juga data jam kerja mesin (utilitas), yield (reject) dan jumlah bahan baku yang tersedia. Selanjutnya untuk analisis dengan menggunakan multivariabel neural network digunakan pula data yang mempengaruhi permintaan dari pelanggan antara lain data inflasi, nilai tukar rupiah terhadap dollar, nilai ekspor impor Indonesia, serta harga baja mentah di pasar dunia.

**Tabel 1.** Variabel Penelitian

<b>Variabel</b>	<b>Satuan</b>	<b>Periode</b>
Permintaan Produk	Ton	2010-2014
Utilitas Mesin	%	2010-2014
Yield	%	2010-2014
Bahan Baku	Ton	2010-2014
Inflasi	%	2010-2014
Nilai Tukar Rupiah	Rp/ US \$	2010-2014
Nilai Ekspor Indonesia	Juta US \$	2010-2014
Harga Baja Pasar Dunia	US \$/ Kg	2010-2014

### **Langkah Penelitian :**

#### **1. Melihat *plot time series*.**

Plot *time series* berguna untuk menentukan pola dari data yang nantinya berguna untuk menentukan model peramalan yang akan dibangun. Berdasarkan plot *time series* yang didapat nanti bisa ditentukan bahwa model *neural network* mengikuti model linier atau model nonlinier.

#### **2. Melihat *plot ACF dan PACF*.**

Plot ACF dan dan PACF digunakan untuk melihat lag yang signifikan pada data permintaan produk. Pada plot ACF dan PACF, setelah didapatkan lag yang signifikan, maka akan ditentukan *input layer* yang digunakan pada model peramalan.



3. **Menentukan unit *input layer*, *output layer*, dan *hidden layer* model peramalan.**  
Menentukan *input layer* pada model peramalan berdasarkan lag yang signifikan dari plot ACF dan PACF. *Output layer* yaitu keluaran yang diinginkan berupa berapa pengamatan ke depan. *Hidden layer* berdasarkan hasil simulasi dari 1 sampai 10 *hidden layer* yang nantinya dipilih yang menghasilkan eror paling kecil.
4. **Menghitung bobot dengan *backpropagation* model peramalan.**  
Pada tahap ini merupakan proses estimasi bobot *neural network* yang nantinya menjadi parameter dalam model peramalan. Pada penelitian ini ditentukan untuk maksimum iterasi yang digunakan sebesar 1000 kali iterasi sampai didapat bobot yang menghasilkan kesalahan minimum.
5. **Menentukan unit *input*, *output*, dan *hidden* model multivariabel.**  
Menentukan *input layer* pada model multivariabel berdasarkan variable yang diduga mempengaruhi permintaan produk pipa. *Output layer* yaitu permintaan produk beberapa pengamatan ke depan. *Hidden layer* berdasarkan hasil simulasi dari 1 sampai 10 *hidden layer* yang nantinya dipilih yang menghasilkan eror paling kecil.
6. **Menghitung bobot dengan *backpropagation* model multivariabel**  
Proses estimasi bobot *neural network* yang nantinya menjadi parameter dalam model multivariabel.
7. **Membandingkan model peramalan dengan model multivariabel.**  
Perbandingan model terbaik dari kedua metode yang digunakan dengan melihat kebaikan model dari masing-masing metode.
8. **Meramalkan permintaan produk untuk beberapa periode kedepan.**  
Setelah model terbaik didapatkan maka digunakan untuk meramalkan permintaan produk beberapa periode kedepan.
9. **Menghitung kebutuhan utilitas mesin, bahan baku dan yield.**  
Pada tahap ini, setelah didapatkan peramalan permintaan produk dengan model terbaik, maka dilakukan perhitungan untuk kebutuhan utilitas mesin, bahan baku dan yield yang digunakan untuk merencanakan ketersediaan pada periode-periode tersebut.

## HASIL DAN PEMBAHASAN

### Karakteristik Data

Statistika deskriptif dari data produksi minyak mentah di Indonesia digunakan untuk melihat karakteristik dari data pada penelitian kali ini. Statistika deskriptif variabel yang digunakan pada penelitian ini akan disajikan sebagai berikut.


Tabel 2. Statistika Deskriptif Data Penelitian

Variabel	Satuan	Mean	StDev	Minimum	Maksimum
Permintaan Produk	Ton	2959,60	841,66	1287,75	4527,97
Yield	%	95,21%	0,01	92,77%	96,78%
Utilitas Mesin	%	70,61%	0,13	31,08%	99,05%
Bahan Baku	Ton	3762,00	1018,06	1211,95	5570,33
Inflasi	%	0,47%	0,57%	3,29%	-0,35%
Nilai Tukar Rupiah	Rp/ US \$	9333,7	546,68	11580	8500
NilaiEkspor Indonesia	Juta US \$	15442,04	1936,54	18647,83	11166,45
Harga Baja Pasar Dunia	US \$/ Kg	789,4	74,51	1018,5	671




### Identifikasi Model

Model peramalan univariabel menggunakan satu variable yaitu permintaan produk yang dilihat pola datanya. Pola data dapat dilihat dari plot time series, ACF dan PACF.




Gambar 1. Permintaan Produk Pipa (Ton)



Gambar 2. Permintaan Produk Pipa per Jenis (Ton)


Berdasar gambar tersebut terlihat bahwa data permintaan pipa bervariasi satu dengan yang lainnya. Tiap permintaan memiliki pola tersendiri sehingga dimungkinkan dipengaruhi oleh faktor eksternal yang berbeda.



Gambar 3. ACF dan PACF permintaan produk pipa

Berdasarkan plot ACF dan PACF di atas, terlihat bahwa data permintaan produk pipa tidak stasioner dalam mean dan varian, sehingga seharusnya data di diferensiasi terlebih dahulu. Tetapi dapat di ambil dugaan bahwa data yang mempengaruhi pengamatan ke  $-t$  merupakan data ke  $t-1, t-2, t-3, t-4, t-5$ .

Model peramalan dengan multivariable menggunakan lebih dari satu variabel. Pada penelitian ini, digunakan 4 variabel untuk mendapatkan prediksi jumlah permintaan produk pipa pada beberapa pengamatan kedepan.



**Gambar 4.** Variabel Eksternal

Inputan dari neural network prediksi permintaan produk pipa yaitu variabel inflasi, nilai tukar rupiah terhadap dolar, nilai ekspor Indonesia, harga baja di pasar dunia dan permintaan produk pipa. Kemudian menggunakan hidden layer sebanyak 8,9 dan 10 layer dan output layer adalah permintaan produk pipa satu pengamatan ke depan. Input pertama (X1) adalah Inflasi, Input kedua (X2) adalah nilai tukar rupiah terhadap dollar, input ketiga (X3) nilai ekspor Indonesia, dan Input ke empat (X4) Harga baja di Pasar dunia.

**Tabel 3.** Korelasi Jenis Pipa terhadap Faktor Eksternal

Variabel	Total Permintaan Produk	Perabot	Hitam	Air	Kotak BJLS
Inflasi	0.009	-0.094	-0.228	0.144	0.064
Nilai Tukar	0.443	0.334	0.238	0.417	0.403
Nilai Ekspor	0.257	0.216	0.282	0.188	0.049
Harga Baja	-0.185	-0.04	0.002	-0.244	-0.225

Berdasarkan hasil korelasi terhadap faktor eksternal tersebut, terlihat bahwa pada tabel korelasi di atas untuk nilai pearson korelasi yang mendekati nilai 1 atau -1 maka dikatakan terdapat korelasi.

1. Total permintaan produk pipa berkorelasi dengan nilai tukar rupiah dengan nilai korelasi sebesar 0,443 kemudian yang kedua berkorelasi terhadap nilai ekspor sebesar 0,257. Sehingga dapat diartikan bahwa ketika nilai tukar rupiah meningkat maka total permintaan produk pipa akan mengalami peningkatan pula. Begitu pula dengan nilai ekspor.
2. Permintaan pipa perabot berpengaruh atau berkorelasi terhadap nilai tukar rupiah dengan nilai korelasi sebesar 0,334 dan nilai ekspor Indonesia sebesar 0,216. Dapat diartikan bahwa ketika nilai tukar rupiah meningkat maka jumlah permintaan pipa perabot akan meningkat, begitu pula dengan nilai ekspor Indonesia.
3. Permintaan pipa hitam berkorelasi positif terhadap nilai tukar rupiah dengan nilai korelasi sebesar 0,282 dan nilai ekspor tetapi berkorelasi negatif terhadap inflasi



sebesar -0,228. Ini berarti bahwa ketika nilai tukar rupiah meningkat maka permintaan pipa perabot akan meningkat pula, tetapi ketika inflasi meningkat maka terjadi penurunan terhadap permintaan pipa hitam.

4. Permintaan pipa air berkorelasi positif terhadap nilai tukar rupiah dengan nilai korelasi sebesar 0,417 dan berkorelasi negatif terhadap harga baja dunia sebesar -0,244. Sehingga dapat diartikan bahwa ketika nilai tukar rupiah meningkat maka total permintaan produk pipa air akan mengalami peningkatan pula. tetapi ketika harga baja meningkat maka terjadi penurunan terhadap permintaan pipa air.
5. Permintaan pipa kotak BJLS berkorelasi positif terhadap nilai tukar rupiah dengan nilai korelasi sebesar 0,403 dan berkorelasi negatif terhadap harga baja dunia sebesar -0,225. Dapat diartikan bahwa ketika nilai tukar rupiah meningkat maka total permintaan produk pipa kotak BJLS akan mengalami peningkatan pula. tetapi ketika harga baja meningkat maka terjadi penurunan terhadap permintaan pipa kotak BJLS.

Perbandingan kedua metode yaitu dengan model univariabel dan multivariabel dengan beberapa node pada hidden layer. Hasil yang didapat dengan membandingkan antara node dan antara kedua model terlihat pada tabel berikut.

**Tabel 4.** Nilai RMSE Kedua Model

	Node = 7	Node = 8	<b>Node = 9</b>	Node = 10	Node = 11
Model Multivariabel	0.329173	0.259377	<b>0.2486991</b>	0.268114	0.362614
Model Univariabel	0.349212	0.3468029	<b>0.288561</b>	0.332783	0.371281

Berdasarkan hasil permodelan antara model univariabel dan multivariabel didapatkan perbandingan dengan menggunakan statistik RMSE bahwa nilai RMSE untuk univariabel. Hasil yang didapat adalah dari 5 node pada hidden layer yang dipercobakan terlihat bahwa 5 node tersebut paling baik menggunakan model multivariabel. Pada dengan hasil RMSE paling kecil adalah dengan node pada hidden layer sebanyak 9 node.

**Tabel 5.** Bobot Neural Network Model Multivariabel

Ket.	Bobot	Ket.	Bobot	Ket.	Bobot	Ket.	Bobot
b->h1	-2.47	b->h4	-10.63	b->h7	1.56	b->o	2.69
i1->h1	-10.79	i1->h4	2.78	i1->h7	-9.98	h1->o	3.36
i2->h1	0.03	i2->h4	4.53	i2->h7	5.54	h2->o	-5.25
i3->h1	2.04	i3->h4	-3.51	i3->h7	-5.84	h3->o	4.23
i4->h1	1.05	i4->h4	4.97	i4->h7	-5.91	h4->o	7.15
i5->h1	6.48	i5->h4	1.78	i5->h7	2.56	h5->o	2.83
b->h2	0.7	b->h5	-1.65	b->h8	4.38	h6->o	-1.3
i1->h2	5.87	i1->h5	10.21	i1->h8	-1.59	h7->o	-1.95
i2->h2	-0.23	i2->h5	3.04	i2->h8	-7.36	h8->o	-5.12
i3->h2	-4.1	i3->h5	-9.38	i3->h8	-1.91	h9->o	-2.61
i4->h2	3.42	i4->h5	-5.09	i4->h8	1.04		
i5->h2	0.2	i5->h5	8.01	i5->h8	3.11		
b->h3	-3.81	b->h6	-0.64	b->h9	-10.18		
i1->h3	-8.41	i1->h6	-0.95	i1->h9	-3.62		
i2->h3	0.75	i2->h6	-7.35	i2->h9	-4.04		
i3->h3	-1.35	i3->h6	-12.47	i3->h9	-10.35		
i4->h3	-5.54	i4->h6	-2.75	i4->h9	0.32		
i5->h3	2.31	i5->h6	6.12	i5->h9	7.94		



Bobot dari data multivariabel dapat dilihat pada tabel di atas. Proses perhitungan bobot telah konvergen setelah dilakukan perhitungan dengan iterasi sebanyak 10000.

Berikut merupakan nilai RMSE hasil simulasi model multivariabel terhadap metode *neural network* dengan menggunakan hidden layer dengan node sebanyak 7,8,9, 10 dan 11 node.

**Tabel 6.** Nilai RMSE Model Multivariabel Per Jenis

Keterangan	Node = 7	Node = 8	Node = 9	Node = 10	Node = 11
Total Permintaan Pipa	0.279257	0.259377	0.248690	0.268114	0.361214
Pipa Perabot	0.085139	0.065699	0.065614	0.074335	0.094215
Pipa Hitam	0.012284	0.005884	0.029524	0.004657	0.014257
Pipa Air	0.343276	0.241696	0.269818	0.232359	0.272159
Pipa Kotak BJLS	0.074142	0.052442	0.048467	0.054434	0.064434

Berdasarkan hasil tersebut, dapat dilihat bahwa nilai RMSE yang terkecil mengindikasikan bahwa eror yang dikeluarkan juga semakin sedikit artinya model tersebut paling baik dibandingkan model dengan node yang lain.

1. Model *neural network* total permintaan pipa terlihat bahwa nilai RMSE paling kecil terletak pada model dengan hidden layer dengan jumlah node sebanyak 9 node. RMSE dari total permintaan pipa yaitu sebesar 0,248699.
2. Model *neural network* pipa perabot terlihat bahwa nilai RMSE paling kecil terletak pada model dengan hidden layer dengan jumlah node sebanyak 9 node. RMSE dari total permintaan pipa yaitu sebesar 0.065614.
3. Model *neural network* pipa hitam terlihat bahwa nilai RMSE paling kecil terletak pada model dengan hidden layer dengan jumlah node sebanyak 10 node. RMSE dari total permintaan pipa yaitu sebesar 0.004657.
4. Model *neural network* pipa air terlihat bahwa nilai RMSE paling kecil terletak pada model dengan hidden layer dengan jumlah node sebanyak 10 node. RMSE dari total permintaan pipa yaitu sebesar 0.232359.

Model *neural network* pipa kotak BJLS terlihat bahwa nilai RMSE paling kecil terletak pada model dengan hidden layer dengan jumlah node sebanyak 9 node. RMSE dari total permintaan pipa yaitu sebesar 0.048467.

Hasil model multivariabel metode neural network dilakukan pengujian selanjutnya. Pada model tersebut digunakan data pada Bulan Januari 2010 sampai dengan Maret 2014 sebagai training, kemudian data Bulan April 2014 sampai dengan Agustus 2014 sebagai testing untuk menguji kebaikan model yang terbentuk. Berikut hasil testing model yang terbentuk dari data training.

**Tabel 7.** Hasil Testing Model Multivariabel Permintaan Produk

Bulan	Satuan	Model Multivariabel		
		aktual	prediksi	selisih
April 2014	Ton/ Bulan	3056.88	3604.761	547.881
Mei 2014		2966.50	3885.895	919.395
Juni 2014		4119.71	4494.783	375.073
Juli 2014		2290.61	2710.701	420.091
Agus 2014		3171.88	4263.978	1092.098

Setiap jenis pipa dilakukan pemodelan kembali dengan menggunakan *neural network* dengan model multivariabel. Node yang digunakan dari masing-masing jenis disesuaikan dengan model terbaik yang telah di hasilkan. Pada Jenis pipa perabot menggunakan hidden layer sebanyak 9 node, untuk jenis pipa hitam menggunakan hidden layer sebanyak 10 node, selanjutnya jenis pipa air menggunakan hidden layer sebanyak 10 node, pipa kotak BJLS



menggunakan hidden layer sebanyak 10 node. Berikut merupakan hasil bobot *neural network* yang dihasilkan.

**Tabel 8.** Prediksi Model *Neural Network* Pipa Perabot

	Satuan	Hasil Prediksi Pipa Perabot
Sep-14	Ton/ Bulan	555.78
Oct-14		595.73
Nov-14		645.53

**Tabel 9.** Prediksi Model *Neural Network* Pipa Hitam

	Satuan	Hasil Prediksi Pipa hitam
Sep-14	Ton/ Bulan	345.35
Oct-14		391.63
Nov-14		371.89

**Tabel 10.** Bobot Model *Neural Network* Pipa Air

	Satuan	Hasil Prediksi Pipa air
Sep-14	Ton/ Bulan	3303.53
Oct-14		3609.85
Nov-14		3535.17

**Tabel 11.** Prediksi Model *Neural Network* Pipa Kotak BJLS

	Satuan	Hasil Prediksi Pipa kotak BJLS
Sep-14	Ton/ Bulan	9.23
Oct-14		26.04
Nov-14		23.80

### Formulasi Variabel

Rata-rata reject pipa hasil produksi adalah 100% dikurangi rata-rata yield produksi yaitu  $100\% - 95,21\%$  atau  $4,79\%$  dibulatkan menjadi  $5\%$ . Bahan baku yang perlu disediakan untuk melakukan proses produksi pada bulan tertentu adalah permintaan pipa tambahkan dengan  $5\%$  dari permintaan pipa.

**Tabel 12.** Bahan Baku Produk Bulan September 2014 – November 2014

Multivariabel	Permintaan produk	Bahan baku yang disediakan
Sept-2014	3293.959 Ton	$3293.959 + 197,09 = 3458.65$ ton
Okt-2014	3221.934 Ton	$3221.934 + 161.09 = 3383.03$ ton
Nov-2014	3297.664 Ton	$3297.664 + 164.88 = 3462.54$ ton

Kemudian untuk ketersediaan jam efektif mesin atau utilitas digunakan metode regresi linier sederhana. Berikut merupakan hasil pemodelan data permintaan produk pipa dengan utilitas mesin yang akan digunakan untuk melakukan produksi.

$$\text{Utilitas} = 0.371 + 0.000113 (\text{Permintaan Produk})$$

Berdasarkan model regresi di atas dapat diinterpretasikan sebagai berikut, setiap 5kenaikan 1 ton permintaan produk pipa maka akan menambah utilitas mesin pada bulan tersebut sebesar  $0,000113$  atau sebesar  $0,013\%$ . Selanjutnya untuk kebaikan modelnya Permintaan produk pipa dapat menjelaskan utilitas mesin sebesar  $53,9\%$  dari keseluruhan model, dan sisanya sebesar  $46,1\%$  dijelaskan oleh variabel lainnya.





**Tabel 13.** Utilitas Mesin Produksi September 2014 – November 2014

Multivariabel	Permintaan produk	Bahan baku yang disediakan
Sept-2014	3293.959 Ton	$0.371 + 0.000113 (3293.959) = 74,32\%$
Okt-2014	3221.934 Ton	$0.371 + 0.000113 (3221.934) = 73,51\%$
Nov-2014	3297.664 Ton	$0.371 + 0.000113 (3297.664) = 74,36\%$

## KESIMPULAN

Berdasarkan analisi dan pembahasan diperoleh beberapa kesimpulan sebagai berikut:

- 1) Pemilihan model terbaik dalam peramalan permintaan pipa baja dengan menggunakan metode neural network PT. XYZ Tbk. menghasilkan permodelan antara model univariabel dan multivariabel. Perbandingan dengan menggunakan statistik RMSE didapat bahwa nilai RMSE untuk multivaribel lebih kecil dari univariabel pada node yang menghasilkan RMSE paling kecil yaitu 9. RMSE untuk multivaribel adalah 0,248 dibandingkan dengan 0,288. Hal ini menyatakan bahwa, untuk permintaan produk pipa dalam memprediksi permintaan pipa lebih baik menggunakan model neural network dengan multivariabel.
- 2) Hasil peramalan permintaan pipa baja dengan model neural network dalam mendukung perencanaan pada produksi di PT. XYZ Tbk. pada bulan September 2014 sampai dengan bulan November 2014 di prediksi akan mengalami peningkatan permintaan produk pipa pada bulan September 2014 yaitu sebesar 3293,95 ton disbanding bulan sebelumnya Agustus 2014 yaitu 3171,88 ton. Tetapi pada bulan Oktober akan mengalami penurunan yaitu 3221,93 ton kemudian pada bulan November terjadi peningkatan kembali yaitu 3297.66 ton.
- 3) Model pendukung keputusan guna mendukung perencanaan produksi di PT. Steel Pipe Industry Indonesia Tbk. menghasilkan kebutuhan bahan baku untuk bulan September 2014 sampai dengan bulan November 2014 pada model multivariabel secara berturut-turut adalah sebesar 3458.65 ton, 3383.03 ton, 3462.54 ton dengan asumsi 5% dari bahan baku yang nantinya akan menjadi hasil reject atau gagal produk. Kemudian utilitas mesin untuk memproduksi permintaan produk bulan September 2014 sampai bulan November 2014 secara berturut-turut adalah sebesar 74,32%, 73,51%, dan 74,36%.

## DAFTAR PUSTAKA

- [1] Anonim (2014). Ekonomi metrotv news, Pembangunan infrastruktur tak mungkin andalkan APBN : Metro TV Online <http://ekonomi.metrotvnews.com/read/2014/09/16/292226/pembangunan-infrastruktur-tak-mungkin-andalkan-apbn>. Diakses pada tanggal 12 November 2014.
- [2] Armstrong, J. S. (Ed.) (2001). Principles of forecasting: a handbook for researchers and practitioners. Boston, MA: Kluwer Academic.
- [3] Cryer, J.D. 1986. Time Series Analysis. PWS-KENT Publising Company, Boston.
- [4] Fausett, Lauren. 1994. Fundamental of Neural Network: Architectures, algorithm and applicalions, Prantice Halt.
- [5] Fildes, R., Goodwin, P., & Lawrence, M. (2006). The design features of forecasting support systems and their effectiveness. Decision Support Systems, 42(1), 351–361.



- [6] Goodwin, P., Lee, W. Y., Fildes, R., Nikolopoulos, K., & Lawrence, M. (2006). Understanding the use of forecasting systems: an interpretive study in a supply-chain company. Bath University Management School working paper.
- [7] Hanke, J.E., Reitsch, A.G. dan Wichern, D.W. 2003. Peramalan Bisnis. Edisi Ketujuh. Alih Bahasa: Devy Anantanur. PT. Prenhallindo. Jakarta.
- [8] Hermawan, Julius. 2005. Membangun Decision Support System. Yogyakarta: Andi.
- [9] Kusumadewi, S. (2004). Membangun Jaringan Syaraf Tiruan (menggunakan MATLAB & Excel Link). Yogyakarta: Graha ilmu.
- [10] Liang, T. P., Lee, C.C., dan Turban, E. (2008), Model Management and Solver for Decision Support in Handbook of Decision Support System 1, eds. Burstein, F., dan Holsapple, V.V., Springer-verlag, Berlin, hal. 231-258.
- [11] Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). Forecasting: methods and applications (3rd ed.). New York: Wiley & Sons.
- [12] Makridakis, S., Wheelwright, S.C., dan McGee, V. Alih bahasa Ir. Hari Suminto. 1999. Metode dan Aplikasi Peramalan. Edisi kedua. Binarupa Aksara, Jakarta.
- [13] Suhartono. 2007. FeedForward Neural Network untuk Pemodelan Runtun Waktu. Disertasi, Jurusan Matematika, Universitas Gadjah Mada
- [14] Turban, E., dan McLean, E. (2002), Information Technology for Management: Transforming Business in The Digital Economy, 3rd Edition, John Wiley and Sons, Inc., New York.
- [15] Universitas Indonesia Online (2014), Sumbangsih fakultas teknik Universitas Indonesia untuk percepatan pembangunan infrastruktur di Indonesia, <http://eng.ui.ac.id/csidi-fakultas-teknik-universitas-indonesia-sumbangsih-ftui-untuk-percepatan-pembangunan-infrastruktur-di-indonesia/>
- [16] Walpole, Ronald E. 1995. Pengantar Statistika Edisi Ke-3. Gramedia Pustaka Utama. Jakarta.
- [17] Zhang, G.P., 2003. A Combined ARIMA and Neural Network Approach for Time Series Forecasting, dalam Neural Networks in Business Forecasting (pp. 213-225). New York City: IGI Global



# MODEL PENDUKUNG KEPUTUSAN UNTUK PERENCANAAN PRODUKSI PIPA BAJA DENGAN MENGUNAKAN *NEURAL NETWORK* DI PT. XYZ TBK.

Ida Bagus Oka Ari Adnyana  
9113205315

Pembimbing  
Prof. Dr. Drs. M. Isa Irawan, MT.

Tesis

# PENDAHULUAN

## Latar Belakang


Meningkatnya pembangunan infrastruktur di Indonesia



1. Mengurangi kemiskinan
2. Menggerakkan perekonomian
3. Meningkatkan standar hidup masyarakat

Sumber : [eng.ui.ac.id](http://eng.ui.ac.id)

## Latar Belakang



Sumber pembiayaan pembangunan infrastruktur di Indonesia

2013 penjualan baja domestik 14,5 juta ton

2020 diperkirakan


**21 juta ton**

Sumber : metrotvnews.com

fppt.com

## Latar Belakang

Salah satu perusahaan swasta industri pipa baja di Indonesia adalah PT. XYZ. Tbk



Sumber : XYZ.com

## Latar Belakang

PT. XYZ. Tbk

Ketidaksinambungan  
antara permintaan produk  
pipa dengan produk pipa  
yang diproduksi.



**MODEL  
PENDUKUNG  
KEPUTUSAN**





# Latar Belakang

## Model Pendukung Keputusan

Peramalan permintaan produk

Jumlah Produksi

Bahan baku

Utilitas mesin

Reject (Yield)



# Latar Belakang

Metode : Neural Network

Model Peramalan  
Time Series

Model Peramalan  
Multivariabel

Model Terbaik

## Rumusan Masalah

1

Bagaimana pemilihan model terbaik dalam peramalan permintaan pipa baja dengan menggunakan metode *neural network*?

2

Bagaimana hasil peramalan permintaan pipa baja dengan model *neural network* dalam mendukung perencanaan pada produksi?

3

Bagaimana model pendukung keputusan guna mendukung perencanaan produksi ?



## Tujuan Penelitian

Mendapatkan model terbaik dalam peramalan permintaan pipa baja yang terbaik dengan menggunakan metode *neural network* PT. XYZ Tbk

Mengetahui hasil peramalan permintaan pipa baja dengan model *neural network* dalam mendukung perencanaan pada produksi di PT. XYZ Tbk.

Mendapatkan model pendukung keputusan guna mendukung perencanaan produksi di PT. XYZ Tbk.

## Batasan Masalah

Pada penelitian kali ini dibatasi hanya di lingkup perusahaan manufaktur pipa baja yaitu PT. Steel Pipe Industry of Indonesia Tbk yang berlokasi di Rungkut Industri. Produk pipa pada PT. XYZ Tbk yang digunakan adalah

1. Water Pipe (Pipa air)
2. Furniture (General Structure)
3. Black Pipe



Tesis

# TINJAUAN PUSTAKA

## KAJIAN PUSTAKA

1. Statistika Deskriptif
2. Analisis Deret Waktu
3. Backpropagation Neural Network
4. Decision Support System
5. Profile PT. Steel Pipe Industry of Indoneia Tbk.

# STATISTIKA DESKRIPTIF

Statistika deskriptif adalah metode-metode yang berkaitan dengan pengumpulan dan penyajian data sehingga dapat memberikan informasi yang berguna (Walpole, 1995).

Mean

St. Deviasi

Maksimum

Minimum



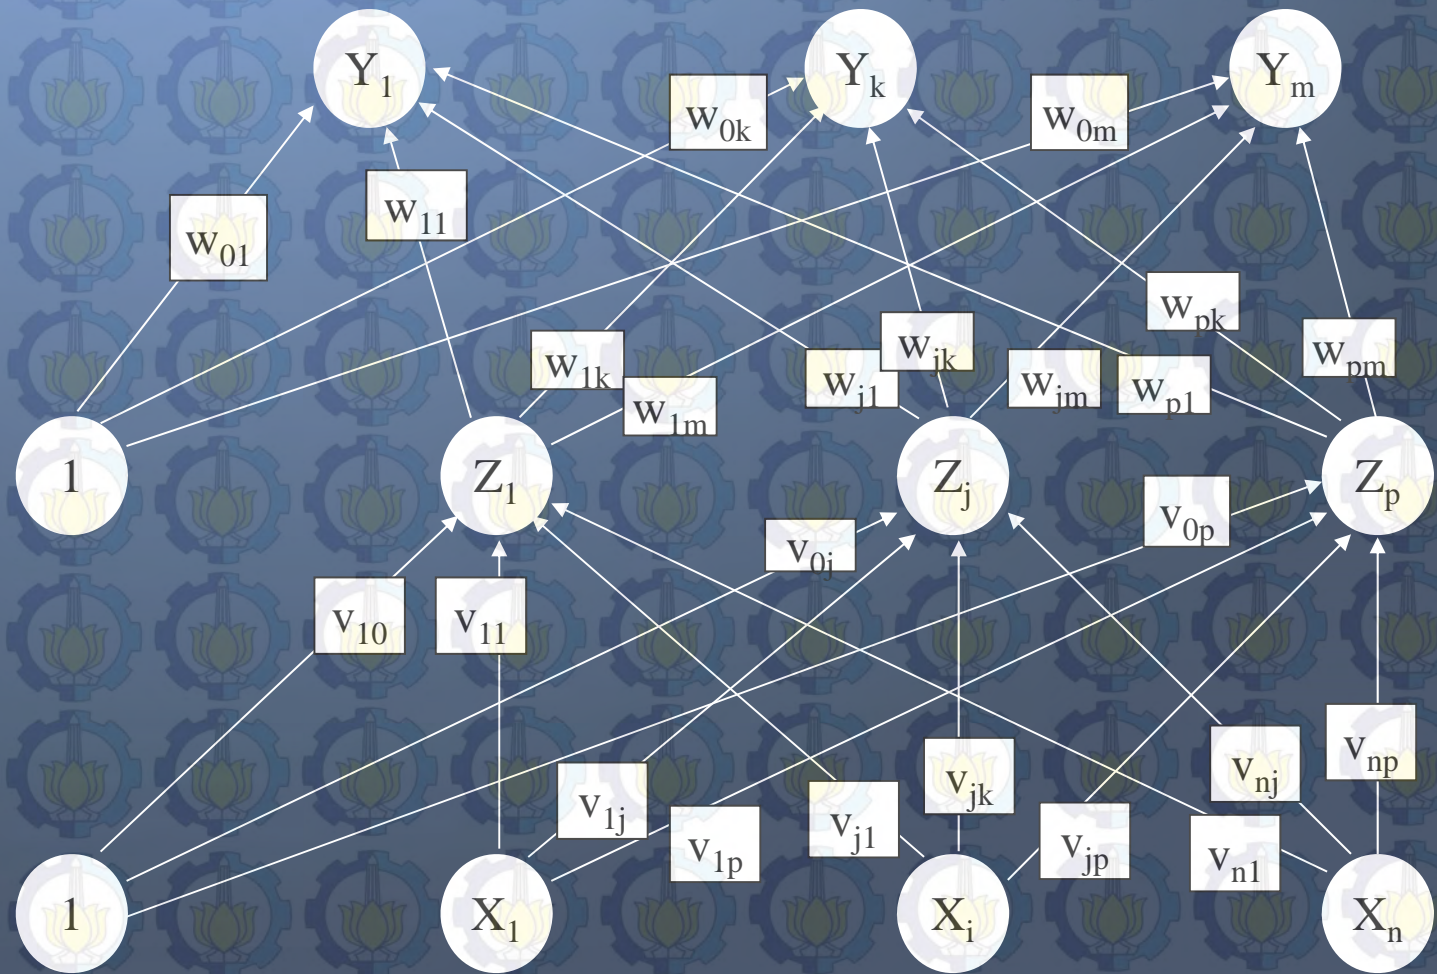
## ANALISIS DERET WAKTU

Deret waktu adalah serangkaian data pengamatan yang disusun menurut waktu, dimana data pengamatan tersebut bersifat acak dan saling berhubungan secara statistika. Deret waktu stasioner adalah deret yang ciri-ciri statistik dasarnya seperti rata-rata dan ragam tetap konstan sepanjang waktu. (Cryer, 1986)

# BACKPROPAGATION NEURAL NETWORK

Backpropagation merupakan algoritma pembelajaran neural network dan biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron pada lapisan tersembunyinya (Kusumadewi, 2004).

# ARSITEKTUR NEURAL NETWORK



# FUNGSI AKTIVASI NEURAL NETWORK

Fungsi aktivasi merupakan suatu fungsi yang digunakan untuk membandingkan antara hasil penjumlahan nilai-nilai semua bobot yang datang dengan suatu nilai ambang (*threshold*) tertentu pada setiap neuron (Kusumadewi, 2004).

Sigmoid  
Biner

$$f(x) = \frac{1}{1 + \exp(-x)}$$

# DECISION SUPPORT SYSTEM

*Decision support system* (DSS) didefinisikan sebagai sebuah sistem yang mampu memberikan kemampuan baik dalam pemecahan masalah maupun kemampuan mengkomunikasikan untuk masalah yang tidak terstruktur (Hermawan, 2005). Sistem pendukung keputusan memiliki fungsi membantu para pengambil keputusan dengan menyediakan informasi yang penting sebagai dasar pengambilan keputusan (Turban dan McLean, 2002)

## Profile PT. Steel Pipe Industry of Indoneia Tbk

PT. XYZ Tbk. atau PT. XYZ Tbk adalah perusahaan yang bergerak pada bidang industri manufaktur pipa baja, serta selalu inovatif dalam rangka memenuhi kebutuhan-kebutuhan spesifik para konsumennya. Didirikan pada tahun 1971 dengan kantor pusat di jalan Kalibutih 189-191, Surabaya.

Tesis

# METODOLOGI

## Sumber Data

Data permintaan produk pipa baja (bulanan) pada PT. XYZ Tbk. dari tahun 2010 sampai dengan pertengahan tahun 2014 bulan Juni.





## Variabel Penelitian

Variabel	Satuan	Periode
Permintaan Produk	Ton	Jan 2010 – Juni 2014
Yield	%	Jan 2010 – Juni 2014
Utilitas Mesin	%	Jan 2010 – Juni 2014
Bahan Baku	Ton	Jan 2010 – Juni 2014
Inflasi	%	Jan 2010 – Juni 2014
Nilai Tukar Rupiah	Rp/ US \$	Jan 2010 – Juni 2014
Nilai Ekspor Indonesia	Juta US \$	Jan 2010 – Juni 2014
Harga Baja Pasar Dunia	US \$/ Kg	Jan 2010 – Juni 2014

# Alur Penelitian

Data permintaan produk dan data pendukung lainnya

Mendeskripsikan data permintaan produk dan data pendukung lainnya

Mendapatkan model peramalan permintaan produk dengan *neural network*

Mendapatkan model multivariabel permintaan produk dengan *neural network*

Membandingkan model peramalan dengan model multivariabel

Meramalkan permintaan produk dengan menggunakan model terbaik

Menghitung kebutuhan utilitas mesin, bahan baku dan yield untuk perencanaan produksi

## Langkah Penelitian

1. Melihat plot time series.
2. Melihat plot ACF dan PACF.
3. Menentukan unit input layer, output layer, dan hidden layer model peramalan.
4. Menghitung bobot neural network dengan backpropagation model peramalan time series.

## Langkah Penelitian

5. Menentukan unit input layer, output layer, dan hidden layer model multivariabel.
6. Menghitung bobot neural network dengan backpropagation model multivariabel.
7. Membandingkan model peramalan dengan model multivariabel.
8. Meramalkan permintaan produk untuk beberapa periode kedepan dengan model terbaik.
9. Menghitung kebutuhan utilitas mesin, bahan baku dan yield.

Tesis

# HASIL DAN PEMBAHASAN


## Karakteristik Data

Statistika deskriptif variabel yang digunakan pada penelitian ini akan disajikan sebagai berikut.

Variabel	Satuan	Mean	StDev	Minimum	Maksimum
Permintaan Produk	Ton	2959,60	841,66	1287,75	4527,97
Yield	%	95,21%	0,01	92,77%	96,78%
Utilitas Mesin	%	70,61%	0,13	31,08%	99,05%
Bahan Baku	Ton	3762,00	1018,06	1211,95	5570,33
Inflasi	%	0,47%	0,57%	3,29%	-0,35%
Nilai Tukar Rupiah	Rp/ US \$	9333,7	546,68	11580	8500
Nilai Ekspor Indonesia	Juta US \$	15442,04	1936,54	18647,83	11166,45
Harga Baja Pasar Dunia	US \$/ Kg	789.4	74,51	1018.5	671


## Karakteristik Data

data permintaan produk pipa tidak mengikuti pola tertentu, sehingga pola data dapat diasumsikan non linier berdasarkan visualisasi time series plot





## Karakteristik Data

Berikutnya plot data permintaan produk pipa per jenis pipa. Terdapat 4 jenis pipa yang diproduksi yaitu pipa perabot, pipa hitam, pipa air dan pipa kotak BJLS.



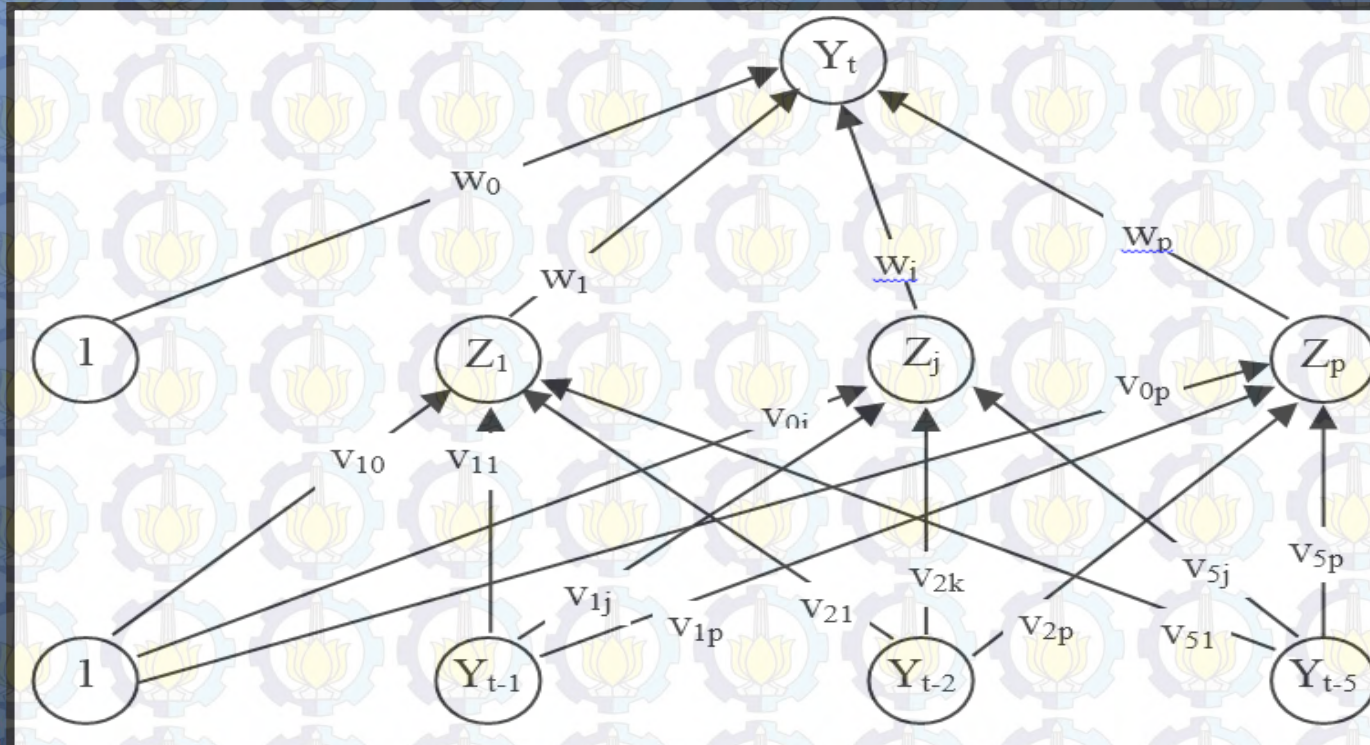


## Identifikasi Model Univariabel





plot ACF dan PACF di atas, terlihat bahwa data permintaan produk pipa tidak stasioner dalam mean dan varian, sehingga seharusnya data di diferensiasi terlebih dahulu. Tetapi dapat di ambil dugaan bahwa data yang mempengaruhi pengamatan ke  $-t$  merupakan data ke  $t-1, t-2, t-3, t-4, t-5$

## Identifikasi Model Univariabel



Inputan dari neural network peramalan permintaan produk pipa yaitu data ke  $t-1$  sampai dengan data ke  $t-5$ . Kemudian menggunakan hidden layer sebanyak 7,8,9,10 dan 11 layer dan output layer adalah permintaan produk waktu ke  $-t$

# Identifikasi Model Multivariabel




# Identifikasi Model Multivariabel

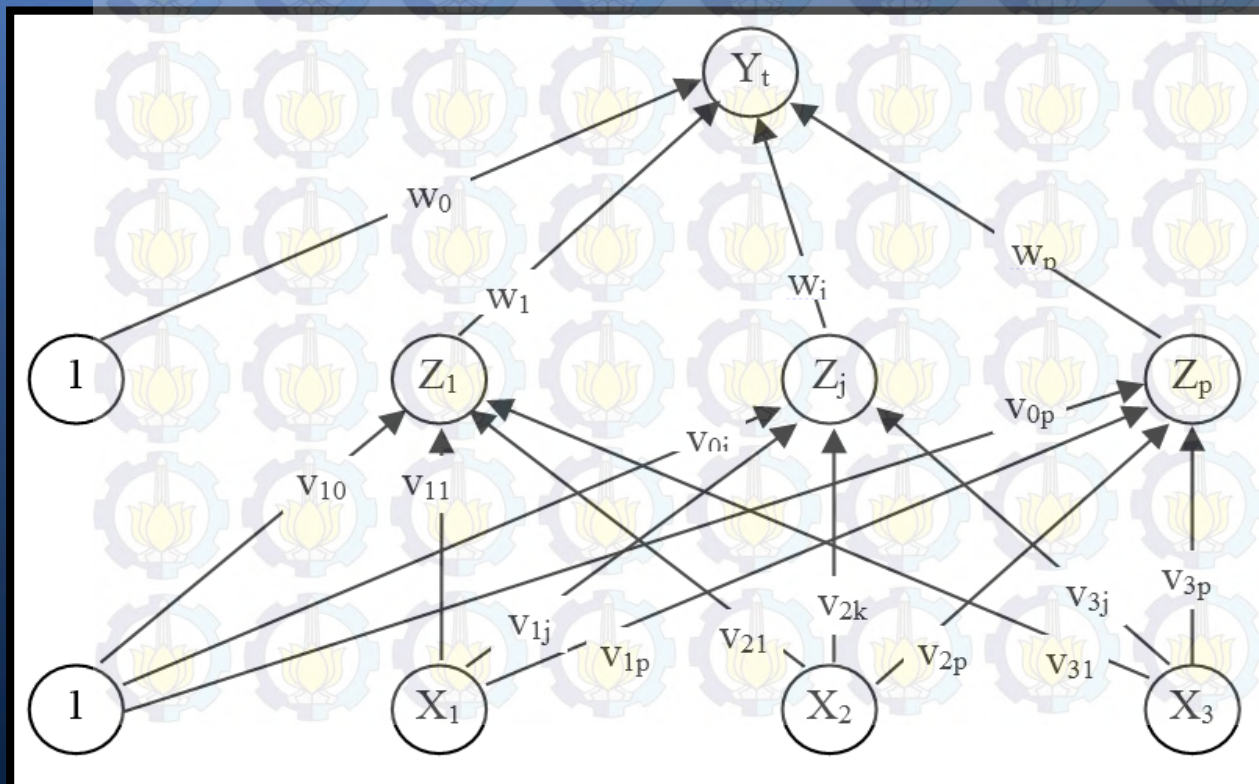
Nilai Ekspor Indonesia



Harga Baja di Pasar Dunia



## Identifikasi Model Multivariabel



Inputan dari neural network prediksi permintaan produk  
multi variabel inflasi, nilai tukar rupiah terhadap

## Karakteristik Data

Berikut merupakan stastistika deskriptif permintaan produksi pipa berdasarkan jenis pipa yang diproduksi dan diminta oleh konsumen

Variabel	Mean	StDev	Minimum	Maksimum
Perabot	373,865	143,979	123,303	776,506
Hitam	509,192	272,626	90,986	1189,590
Air	2018,651	541,549	1049,469	3256,845
Kotak BJLS	49,736	72,988	0	315,522

## Korelasi Data

Variabel	Total Permintaan Produk	Perabot	Hitam	Air	Kotak BJLS
Inflasi	0.009	-0.094	-0.228	0.144	0.064
Nilai Tukar	0.443	0.334	0.238	0.417	0.403
Nilai Ekspor	0.257	0.216	0.282	0.188	0.049
Harga Baja	-0.185	-0.04	0.002	-0.244	-0.225

1. ketika nilai tukar rupiah meningkat maka total permintaan produk pipa akan mengalami peningkatan pula. Begitu pula dengan nilai ekspor.

2. ketika nilai tukar rupiah meningkat maka jumlah

## Korelasi Data

Variabel	Total Permintaan Produk	Perabot	Hitam	Air	Kotak BJLS
Inflasi	0.009	-0.094	-0.228	0.144	0.064
Nilai Tukar	0.443	0.334	0.238	0.417	0.403
Nilai Ekspor	0.257	0.216	0.282	0.188	0.049
Harga Baja	-0.185	-0.04	0.002	-0.244	-0.225

- ketika nilai tukar rupiah meningkat maka permintaan pipa perabot akan meningkat pula, tetapi ketika inflasi meningkat maka terjadi penurunan terhadap permintaan pipa hitam.
- ketika nilai tukar rupiah meningkat maka total permintaan



## Korelasi Data

Variabel	Total Permintaan Produk	Perabot	Hitam	Air	Kotak BJLS
Inflasi	0.009	-0.094	-0.228	0.144	0.064
Nilai Tukar	0.443	0.334	0.238	0.417	0.403
Nilai Ekspor	0.257	0.216	0.282	0.188	0.049
Harga Baja	-0.185	-0.04	0.002	-0.244	-0.225

5. ketika nilai tukar rupiah meningkat maka total permintaan produk pipa kotak BJLS akan mengalami peningkatan pula. tetapi ketika harga baja meningkat maka terjadi penurunan terhadap permintaan pipa kotak BJLS.

## Model Neural Network Terbaik

	Node = 7	Node = 8	Node = 9	Node = 10	Node = 11
Model Multivariable	0.329173	0.259377	0.2486991	0.268114	0.362614
Model Univariabel	0.349212	0.3468029	0.288561	0.332783	0.371281

perbandingan dengan menggunakan statistik RMSE bahwa nilai RMSE untuk univariabel. Hasil yang didapat adalah dari 5 node pada hidden layer yang dipercobakan terlihat bahwa 5 node tersebut paling baik menggunakan model multivariabel. Pada dengan hasil RMSE paling kecil adalah dengan node pada hidden layer sebanyak 9 node.

# Model Neural Network

Bobot	Ket.	Bobot	Ket.	Bobot	Ket.	Bobot
-2.47	b->h4	-10.63	b->h7	1.56	b->o	2.69
-10.79	i1->h4	2.78	i1->h7	-9.98	h1->o	3.36
0.03	i2->h4	4.53	i2->h7	5.54	h2->o	-5.25
2.04	i3->h4	-3.51	i3->h7	-5.84	h3->o	4.23
1.05	i4->h4	4.97	i4->h7	-5.91	h4->o	7.15
6.48	i5->h4	1.78	i5->h7	2.56	h5->o	2.83
0.7	b->h5	-1.65	b->h8	4.38	h6->o	-1.3
5.87	i1->h5	10.21	i1->h8	-1.59	h7->o	-1.95
-0.23	i2->h5	3.04	i2->h8	-7.36	h8->o	-5.12
-4.1	i3->h5	-9.38	i3->h8	-1.91	h9->o	-2.61
3.42	i4->h5	-5.09	i4->h8	1.04		
0.2	i5->h5	8.01	i5->h8	3.11		
-3.81	b->h6	-0.64	b->h9	-10.18		
-8.41	i1->h6	-0.95	i1->h9	-3.62		
0.75	i2->h6	-7.35	i2->h9	-4.04		
1.35	i3->h6	12.47	i3->h9	12.25		

Multivariabel

RMSE dari model

adalah sebesar

**0.2486991**

## Model Perjenis Produk Pipa

Berikut merupakan nilai RMSE hasil simulasi model multivariabel terhadap metode neural network dengan menggunakan hidden layer dengan node sebanyak 7,8,9, 10 dan 11 node.

Keterangan	Node = 7	Node = 8	Node = 9	Node = 10	Node = 11
Total Permintaan Pipa	0.279257	0.259377	0.248690	0.268114	0.361214
Pipa Perabot	0.085139	0.065699	0.065614	0.074335	0.094215
Pipa Hitam	0.012284	0.005884	0.029524	0.004657	0.014257
Pipa Air	0.343276	0.241696	0.269818	0.232359	0.272159
Pipa Kotak BJLS	0.074142	0.052442	0.048467	0.054434	0.064434


## Model *Neural Network*

Hasil model multivariabel metode neural network dilakukan pengujian selanjutnya. Pada model tersebut digunakan data pada Bulan Januari 2010 sampai dengan Maret 2014 sebagai training, kemudian data Bulan April 2014 sampai dengan Agustus 2014 sebagai testing untuk menguji kebaikan model yang terbentuk

Bulan	Satuan	Model Multivariabel			
		aktual	prediksi	selisih	persentase
April 2014	Ton/ Bulan	3056,88	3604,761	547,881	17,92%
Mei 2014		2966,50	3885,895	919,395	30,99%
Juni 2014		4119,71	4494,783	375,073	9,10%
Agustus 2014		3200,61	3710,701	420,091	13,13%

## Model *Neural Network*


- Berikut merupakan gambar plot perbandingan antara hasil prediksi model multivariabel *neural network* terhadap aktual permintaan produk pipa pada bulan April 2014 – Agustus 2014.



# Model Neural Network Pipa Perabot

Bobot	Ket.	Bobot	Ket.	Bobot	Ket.	Bobot
-0.26	b->h4	0.85	b->h7	-0.31	b->o	0
-2.72	i1->h4	0.37	i1->h7	2.74	h1->o	-2.09
-3.42	i2->h4	0.94	i2->h7	-0.41	h2->o	1.54
3.71	i3->h4	1.23	i3->h7	-1.39	h3->o	-0.5
-3.8	i4->h4	1.3	i4->h7	5.01	h4->o	0.38
-0.66	b->h5	-1.57	b->h8	-1.13	h5->o	1.8
-2.57	i1->h5	0.68	i1->h8	2.54	h6->o	0.26
-1.09	i2->h5	-2.17	i2->h8	1.22	h7->o	-1.96
-1.23	i3->h5	2.49	i3->h8	0.81	h8->o	0.71
1.76	i4->h5	2.31	i4->h8	-1.18	h9->o	-0.53
3.31	b->h6	1.32	b->h9	-0.09		
7.68	i1->h6	0.99	i1->h9	-0.84		
4.92	i2->h6	-1.96	i2->h9	-1.55		
-7.47	i3->h6	0.33	i3->h9	-2.04		
0.86	i4->h6	0	i4->h9	0.31		


	Satuan	Hasil Prediksi Pipa Perabot
Sep-14		555.78
Oct-14	Ton/ Bulan	595.73
Nov-14		645.53



# Model Neural Network Pipa Hitam

Bobot	Ket.	Bobot	Ket.	Bobot	Ket.	Bobot
5.44	b->h5	0.03	b->h9	-2.2	h10->o	1.11
-1.42	i1->h5	0.75	i1->h9	0.63		
2.23	i2->h5	-0.92	i2->h9	-1.25		
1.51	i3->h5	-4.35	i3->h9	-1.26		
-2.42	i4->h5	3.05	i4->h9	1.74		
-1.24	b->h6	-0.02	b->h10	1.95		
-1.21	i1->h6	-0.07	i1->h10	-1.55		
-0.76	i2->h6	0.04	i2->h10	0.93		
-0.83	i3->h6	-0.55	i3->h10	1.97		
0.12	i4->h6	0.87	i4->h10	0.61		
-2.01	b->h7	3.53	b->o	0.05		
2.17	i1->h7	2.28	h1->o	-4.3		
-2.15	i2->h7	3.34	h2->o	-0.03		
-2.89	i3->h7	-15.47	h3->o	2.58		
1.22	i4->h7	9.47	h4->o	2.01		
1.28	b->h8	-2.04	h5->o	0.69		

	Satuan	Hasil Prediksi Pipa hitam
Sep-14	Ton/ Bulan	345.35
Oct-14		391.63
Nov-14		371.89






# Model Neural Network Pipa Air

Bobot	Ket.	Bobot	Ket.	Bobot	Ket.	Bobot
-18.86	b->h5	5.46	b->h9	-1.59	h10->o	2.61
1.95	i1->h5	-7.88	i1->h9	-2.85		
-14.8	i2->h5	9.62	i2->h9	-12.87		
20.54	i3->h5	6.66	i3->h9	15.01		
-15.69	i4->h5	-4.93	i4->h9	0.98		
-1.45	b->h6	-6.29	b->h10	18.97		
2.6	i1->h6	0.38	i1->h10	-8.18		
4.59	i2->h6	1.42	i2->h10	16.13		
4.09	i3->h6	7.77	i3->h10	-13.79		
0.79	i4->h6	3.25	i4->h10	-11.59		
6.88	b->h7	6.83	b->o	-3.43		
-2.01	i1->h7	5.88	h1->o	-1.06		
-10.91	i2->h7	-1.52	h2->o	-0.28		
-0.03	i3->h7	-4.85	h3->o	-11.91		
-0.43	i4->h7	0.68	h4->o	2.74		
-16.02	b->h8	-2.89	h5->o	-6.33		


	Satuan	Hasil Prediksi Pipa air
Sep-14	Ton/ Bulan	3303.53
Oct-14		3609.85
Nov-14		3535.17



# Model Neural Network Pipa Kotak BJLS

Bobot	Ket.	Bobot	Ket.	Bobot	Ket.	Bobot
-1.81	b->h4	-4.76	b->h7	7.99	b->o	-6
4.26	i1->h4	9.24	i1->h7	-10.21	h1->o	-7.6
17.77	i2->h4	-5.12	i2->h7	25.68	h2->o	7.78
14.44	i3->h4	-1.49	i3->h7	-15.63	h3->o	3.09
-8.72	i4->h4	-2.46	i4->h7	12.36	h4->o	5.4
7.63	b->h5	-6.76	b->h8	-4.08	h5->o	-2.78
-0.89	i1->h5	-1.19	i1->h8	-0.49	h6->o	-4.64
3.08	i2->h5	7.41	i2->h8	4.86	h7->o	1.48
5.75	i3->h5	-2.33	i3->h8	-5.16	h8->o	3.77
2.48	i4->h5	1.12	i4->h8	7.51	h9->o	-2.67
18.27	b->h6	10.91	b->h9	15.2		
0.02	i1->h6	-1.03	i1->h9	-17.49		
13.45	i2->h6	-11.95	i2->h9	8.47		
8.19	i3->h6	-0.15	i3->h9	4.24		

	Satuan	Hasil Prediksi Pipa kotak BJLS
Sep-14	Ton/ Bulan	9.23
Oct-14		26.04
Nov-14		23.80



## Hasil Prediksi

- Berikut merupakan hasil peramalan total permintaan produk pipa pada 3 bulan selanjutnya, yaitu bulan September 2014 sampai bulan November 2014.

Hasil Prediksi



	Satuan	Hasil Prediksi
Sep-14	Ton/ Bulan	3293.959
Oct-14		3221.934
Nov-14		3297.664

## Model *Neural Network*

Hasil permasing-masing produk pipa pada Bulan September 2014 adalah sebagai berikut untuk model Multivariabel

Produk	Tonase (Ton)
Pipa perabot	320.10
Pipa Hitam	615.81
Pipa Air	2237.76
Pipa Kotak BJLS	120.29
<b>Total</b>	<b>3293.959</b>

## Model *Neural Network*

- Pipa Perabot Model Multivariabel Bulan September 2014

Diameter (Inci)	Tonase (Ton)	Diameter (Inci)	Tonase (Ton)
Ø 1"	14.39	25x16 (oval)	40.77
Ø 1 1/4"	14.64	Ø 3/4"	17.94
Ø 1/2"	14.92	40x30	31.38
Ø 13/16"	49.90	Ø 5/8"	24.33
Ø 2"	12.65	Ø 7/8"	46.53
20x20	16.34	Lainnya	36.32

## Model *Neural Network*

- Pipa Hitam Model Multivariabel Bulan September 2014

Diameter (Inci)	Tonase (Ton)	Diameter (Inci)	Tonase (Ton)
Ø 1"	73.78	Ø 3/4"	12.90
Ø 1-1/2"	39.67	Ø 3/8"	15.10
Ø 1-1/4"	19.73	Ø 4"	176.23
Ø 1/2"	0.04	Ø 5"	235.83
Ø 1/4"	14.79	Ø 6"	31.35
Ø 2"	62.02	Ø 7"	1387.94
Ø 2-1/2"	36.89	Ø 8"	111.19
Ø 3"	20.30		


## Model *Neural Network*

- Pipa Air Model Multivariabel Bulan September 2014

Diameter (Inci)	Tonase (Ton)	Diameter (Inci)	Tonase (Ton)
Ø 1"	78.43	Ø 3"	70.60
Ø 1-1/2"	54.80	Ø 3/4"	95.59
Ø 1-1/4"	17.47	Ø 4"	87.21
Ø 1/2"	46.33	Ø 5"	2.41
Ø 2"	74.23	Ø 6"	59.77
Ø 2-1/2"	10.32	Ø 8"	18.66

## Formulasi Variabel

Perbandingan bahan baku yang digunakan untuk produksi pipa dan permintaan produk pada tahun 2010 sampai dengan Juni 2014.





## Formulasi Variabel

### Bahan Baku Produk Bulan September-November 2014

Multivariabel	Permintaan produk	Bahan baku yang disediakan
Sept-2014	3293.959 Ton	$3293.959 + 197,09 = 3458.65$ ton
Okt-2014	3221.934 Ton	$3221.934 + 161.09 = 3383.03$ ton
Nov-2014	3297.664 Ton	$3297.664 + 164.88 = 3462.54$ ton

Berdasarkan hasil tersebut, didapatkan kebutuhan bahan baku untuk bulan September 2014 pada model multivariabel adalah sebesar 3458.65 dengan asumsi 5% dari bahan baku yang nantinya akan menjadi hasil reject atau gagal produk.

## Formulasi Variabel

Regresi Linier :

$$\text{Utilitas} = 0.371 + 0.000113(\text{Permintaan Produk})$$

Multivariabel	Permintaan produk	Bahan baku yang disediakan
Sept-2014	3293.959 Ton	$0.371 + 0.000113 (3293.959) = 74,32\%$
Okt-2014	3221.934 Ton	$0.371 + 0.000113 (3221.934) = 73,51\%$
Nov-2014	3297.664 Ton	$0.371 + 0.000113 (3297.664) = 74,36\%$

esis

# KESIMPULAN

## Kesimpulan

1. permodelan antara model univariabel dan multivariabel. Perbandingan dengan menggunakan statistik RMSE didapat bahwa nilai RMSE untuk multivariabel lebih kecil dari univariabel pada node yang menghasilkan RMSE paling kecil yaitu 9. RMSE untuk multivariabel adalah 0,248 dibandingkan dengan 0,288. Hal ini menyatakan bahwa, untuk permintaan produk pipa dalam memprediksi permintaan pipa lebih baik menggunakan model neural

## Kesimpulan

2. Hasil peramalan permintaan pipa baja dengan model *neural network* dalam mendukung perencanaan pada produksi di PT. XYZ Tbk. pada bulan September 2014 sampai dengan bulan November 2014 di prediksi akan mengalami peningkatan permintaan produk pipa pada bulan September 2014 yaitu sebesar 3293,95 ton dibanding bulan sebelumnya Agustus 2014 yaitu 3171,88 ton. Tetapi pada bulan Oktober akan mengalami penurunan yaitu 3221,93 ton kemudian pada bulan November terjadi peningkatan kembali yaitu 3297,66 ton

## Kesimpulan

3. Kebutuhan bahan baku untuk bulan September 2014 sampai dengan bulan November 2014 pada model multivariabel secara berturut-turut adalah sebesar 3458.65 ton, 3383.03 ton, 3462.54 ton dengan asumsi 5% dari bahan baku yang nantinya akan menjadi hasil reject atau gagal produk. Kemudian utilitas mesin untuk memproduksi permintaan produk bulan September 2014 sampai bulan November 2014 secara berturut-turut adalah sebesar 74,32%, 73,51%, dan 74,36%,

## Saran

- Saran untuk peneliti selanjutnya untuk menambahkan beberapa variabel eksternal dan internal perusahaan untuk menambah variansi dan penjelasan model yang lebih baik lagi.

esis

# DAFTAR PUSTAKA



## DAFTAR PUSTAKA

- Armstrong, J. S. (Ed.) (2001). Principles of forecasting: a handbook for researchers and practitioners. Boston, MA: Kluwer Academic.
- Cryer, J.D. 1986. *Time Series Analysis*. PWS-KENT Publishing Company, Boston.
- Ekonomi metrotv news (2014) *Pembangunan infrastruktur tak mungkin andalkan APBN* : Metro TV Online <http://ekonomi.metrotvnews.com/read/2014/09/16/292226/pembangunan-infrastruktur-tak-mungkin-andalkan-apbn>.
- Fausett, Lauren. 1994. *Fundamental of Neural Network: Architectures, algorithm and applicalions*, Prantice Halt.
- Fildes, R., Goodwin, P., & Lawrence, M. (2006). The design features of forecasting support systems and their effectiveness. *Decision Support Systems*, 42(1), 351–361.
- Goodwin, P., Lee, W. Y., Fildes, R., Nikolopoulos, K., & Lawrence, M. (2006). Understanding the use of forecasting systems: an

## DAFTAR PUSTAKA

- Hanke, J.E., Reitsch, A.G. dan Wichern, D.W. 2003. *Peramalan Bisnis*. Edisi Ketujuh. Alih Bahasa: Devy Anantanur. PT. Prenhallindo. Jakarta.
- Hermawan, Julius. 2005. *Membangun Decision Support System*. Yogyakarta: Andi.
- Kusumadewi, S. (2004). *Membangun Jaringan Syaraf Tiruan (menggunakan MATLAB & Excel Link)*. Yogyakarta: Graha ilmu.
- Liang, T. P., Lee, C.C., dan Turban, E. (2008), *Model Management and Solver for Decision Support in Handbook of Decision Support System 1*, eds. Burstein, F., dan Holsapple, V.V., Springer-verlag, Berlin, hal. 231-258.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting: methods and applications (3rd ed.)*. New York: Wiley & Sons.

## DAFTAR PUSTAKA

- Suhartono. 2007. FeedForward Neural Network untuk Pemodelan Runtun Waktu. Disertasi, Jurusan Matematika, Universitas Gadjah Mada
- Turban, E., dan McLean, E. (2002), *Information Technology for Management: Transforming Business in The Digital Economy*, 3<sup>rd</sup> Edition, John Wiley and Sons, Inc., New York.
- Universitas Indonesia Online (2014), *Sumbangsih fakultas teknik Universitas Indonesia untuk percepatan pembangunan infrastruktur di Indonesia*, <http://eng.ui.ac.id/csid-fakultas-teknik-universitas-indonesia-sumbangsih-ftui-untuk-percepatan-pembangunan-infrastruktur-di-indonesia/>
- Zhang, G.P., 2003. A Combined ARIMA and Neural Network Approach for Time Series Forecasting, dalam *Neural Networks in Business Forecasting* (pp. 213-225). New York City: IGI Global



**TERIMA KASIH**





**MODEL PENDUKUNG KEPUTUSAN UNTUK  
PERENCANAAN PRODUKSI PIPA BAJA DENGAN  
MENGUNAKAN *NEURAL NETWORK* DI PT. XYZ TBK.**

**Ida Bagus Oka Ari Adnyana**  
**9113205315**

**Pembimbing**  
**Prof. Dr. Drs. M. Isa Irawan, MT.**