



UNIVERSITAS INDONESIA

**PERBANDINGAN PERAMALAN PERMINTAAN ANTARA
ARTIFICIAL NEURAL NETWORK DAN *SUPPORT VECTOR*
REGRESSION DENGAN METODE TRADISONAL**

SKRIPSI

**RENDRA SATYA WIRAWAN
0706274994**

**FAKULTAS TEKNIK
PROGRAM STUDI TEKNIK INDUSTRI
DEPOK
JUNI 2011**



UNIVERSITAS INDONESIA

**PERBANDINGAN PERAMALAN PERMINTAAN ANTARA
ARTIFICIAL NEURAL NETWORK DAN *SUPPORT VECTOR
REGRESSION* DENGAN METODE TRADISONAL**

SKRIPSI

Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Teknik

**RENDRA SATYA WIRAWAN
0706274994**

**FAKULTAS TEKNIK
PROGRAM STUDI TEKNIK INDUSTRI
DEPOK
JUNI 2011**

ii

HALAMAN PERNYATAAN ORISINALITAS

**Skripsi ini adalah hasil karya saya sendiri,
dan semua sumber baik yang dikutip maupun yang dirujuk
telah saya nyatakan dengan benar.**



Nama : RENDRA SATYA WIRAWAN
NPM : 0706274994
Tanda tangan : *Rendra*
Tanggal : Juni 2011

HALAMAN PENGESAHAN

Skripsi ini diajukan oleh :
Nama : Rendra Satya Wirawan
NPM : 0706274994
Program Studi : Teknik Industri
Judul Skripsi : Perbandingan Peramalan Permintaan Antara
Artificial Neural Network dan *Support Vector
Regression* dengan Metode Tradisional

Telah berhasil dipertahankan di hadapan Dewan Penguji dan diterima sebagai bagian persyaratan yang diperlukan untuk memperoleh gelar Sarjana Teknik pada Program Studi Teknik Industri, Fakultas Teknik, Universitas Indonesia.

DEWAN PENGUJI

Pembimbing : Ir. Amar Rachman, MEIM

Penguji : Armand OM.,ST.,M.Sc.

Penguji : Akhmad Hidayatno ST.,MBT

Penguji : Ir. Yadrifil,MSc

Ditetapkan di : Depok

Tanggal : 21 Juni 2011

KATA PENGANTAR

Puji syukur penulis ucapkan kepada Allah SWT atas rahmat dan karunia-Nya yang melimpah sehingga penulis dapat menyelesaikan skripsi ini tepat waktu. Selain itu penulis juga mau mengucapkan terima kasih kepada :

1. Bapak Ir. Amar Rachman, MEIM, selaku dosen pembimbing skripsi yang telah membimbing dan memberikan masukan selama penulisan.
2. PT. Astra Nippon Gasket Indonesia dan Abang Irwansyah Djohan, yang telah memberikan izin untuk mempergunakan data perusahaan kepada penulis.
3. Bapak Rachmat Nurcahyo, selaku dosen pembimbing akademis, dan dosen-dosen lainnya, yang telah memberikan masukan dan ilmu selama penulis melakukan pembelajaran.
4. Bapak Budi Santosa, mba Eli, mas Hilman, mas Riza, Enrico, dan Wicak yang telah bersedia meluangkan waktu untuk mengajari penulis mengenai metode ANN dan SVR.
5. Renaldy Muhamad, Maolana Hakim, Paulus Bangun, selaku teman satu kos yang telah memberikan bantuan selama penulis berkuliah hingga menyelesaikan tugas akhir ini.
6. Audi Hakim, Indra Nurudin, M. Khairanto, selaku sahabat-sahabat penulis yang selalu memberikan kegembiraan ditengah-tengah kesulitan penulisan.
7. Semua teman-teman, baik teman-teman teknik industri UI, maupun teman-teman departemen lain atas dukungan dan pertemanan selama ini.
8. Mama, teteh, aa, dan akang, selaku keluarga penulis atas dukungan dan dorongan moril yang tak ternilai.
9. Citra Atma Pertiwi, atas dukungan, bantuan, dan doa kepada penulis.

Penulis menyadari bahwa skripsi ini masih jauh dari sempurna. Oleh karena itu, kritik dan saran yang membangun sangat penulis harapkan. Selain itu penulis berharap skripsi ini dapat memberikan manfaat bagi semua pihak yang membacanya.

Depok, Juni 2011

Penulis

**HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI
TUGAS AKHIR UNTUK KEPENTINGAN AKADEMIS**

Sebagai sivitas akademik Universitas Indonesia, saya yang bertanda tangan di bawah ini:

Nama : Rendra Satya Wirawan
NPM : 0706274994
Departemen : Teknik Industri
Fakultas : Teknik
Jenis Karya : Skripsi

demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Indonesia **Hak Bebas Royalti Noneksklusif** (*Non-exclusive Royalty-Free Right*) atas karya ilmiah saya yang berjudul:

Perbandingan Peramalan Permintaan Antara *Artificial Neural Network* dan *Support Vector Regression* dengan Metode Tradisional

beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Noneksklusif ini Universitas Indonesia berhak menyimpan, mengalih media/formatkan, mengelola dalam bentuk pangkalan data (*database*), merawat dan mempublikasikan tugas akhir saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Depok
Pada tanggal : Juni 2011
Yang Menyatakan



(Rendra Satya Wirawan)

ABSTRAK

Nama : Rendra Satya Wirawan
Program Studi : Teknik Industri
Judul : Perbandingan Peramalan Permintaan Antara *Artificial Neural Network* dan *Support Vector Regression* dengan Metode Tradisional

Dengan terus bertambahnya industri pada berbagai bidang, membuat konsumen memiliki banyak pilihan ketika memilih barang atau jasa. Oleh karena itu dibutuhkan suatu cara agar dapat menghasilkan barang dengan tepat. Hal inilah yang menjadi peranan dari sebuah metode peramalan permintaan. Terdapat banyak cara dalam melakukan peramalan, namun cara manakah yang dapat memberikan hasil yang terbaik. ANN dan SVR merupakan salah satu cara yang memberikan hasil peramalan terbaik. Dalam penelitian ini, dibandingkan antara metode ANN dan SVR dengan metode tradisional. Dari enam jenis data yang digunakan empat menunjukkan ANN memberikan peramalan terbaik, dan satu menunjukkan SVR memberikan peramalan terbaik.

Kata kunci:
Peramalan, ANN, SVR, Metode Tradisional

ABSTRACT

Name : Rendra Satya Wirawan
Study Program : Industrial Engineering
Title : Demand Forecasting Comparison Between Artificial Neural Network and Support Vector Regression with Traditional Methods

With the continuous increase of industry in many fields, making consumers to have many choices when choosing goods or services. Because of that, we need some way to produce good with the correct amount. This is the role of a demand forecast method. There are many methods in demand forecast, but which method that give the best result. ANN and SVR are one of many methods that will give the best forecast result. In this research, ANN and SVR method will be compared to the traditional methods. From six kinds of data that is used, four show that ANN give the best forecast result, and one shows SVR give the best forecast result.

Key words:
Forecast, ANN, SVR, Traditional Methods

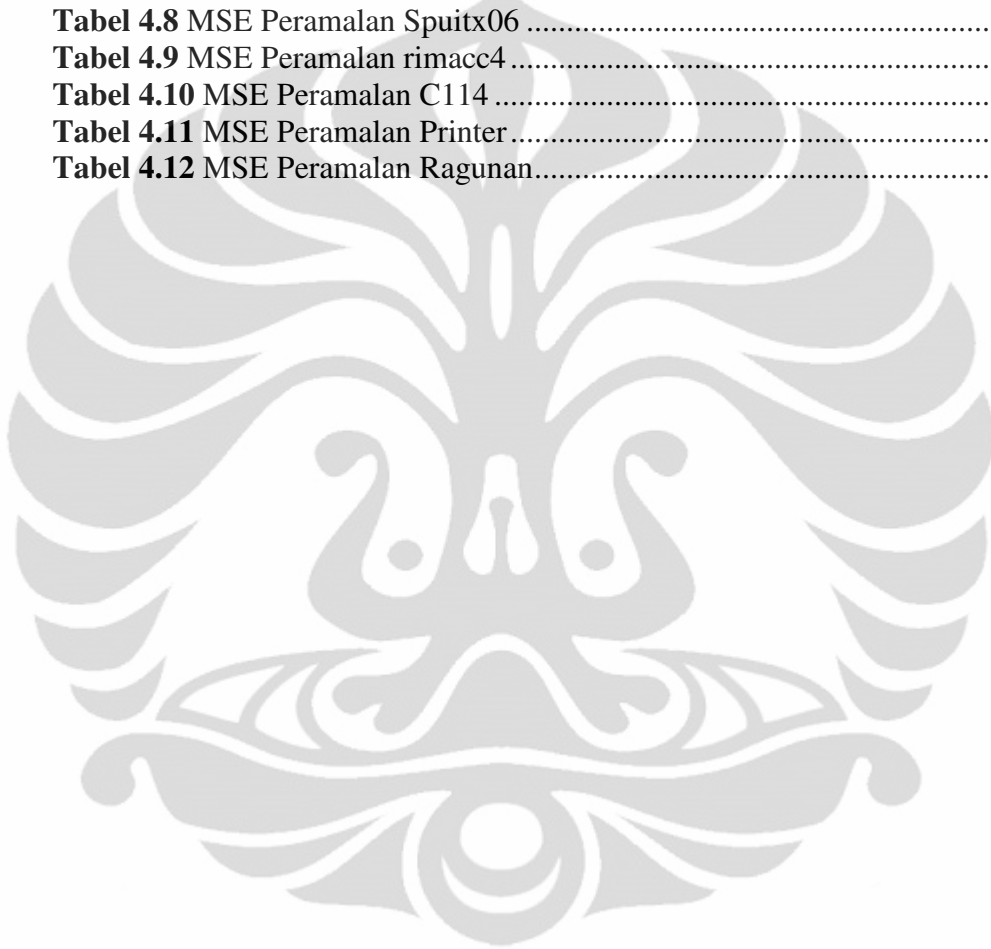
DAFTAR ISI

HALAMAN JUDUL.....	ii
HALAMAN PERNYATAAN ORISINALITAS.....	iii
HALAMAN PENGESAHAN.....	iv
KATA PENGANTAR	v
HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI.....	vi
ABSTRACT	vii
DAFTAR ISI.....	viii
DAFTAR TABEL.....	x
DAFTAR GAMBAR	xi
DAFTAR LAMPIRAN.....	xiii
1. PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Diagram Keterkaitan Masalah.....	2
1.3 Rumusan Masalah	4
1.4 Tujuan Penelitian.....	4
1.5 Ruang Lingkup Penelitian.....	4
1.6 Metodologi Penelitian	4
1.7 Sistematika Penulisan.....	7
2. LANDASAN TEORI.....	8
2.1 Permintaan (<i>Demand</i>).....	8
2.1.1 Pengelolaan Permintaan.....	8
2.1.2 Karakteristik Permintaan	9
2.2 Peramalan (<i>Forecasting</i>)	11
2.2.1 Metode Peramalan <i>Moving Average</i>	13
2.2.2 Metode Peramalan <i>Exponential Smoothing</i>	14
2.2.3 Metode Peramalan Artificial Neural Network.....	17
2.2.3.1 Perhitungan Input ANN.....	17
2.2.3.2 Fungsi aktivasi.....	17
2.2.3.3 Backpropagation Network.....	19
2.2.4 Metode Peramalan Support Vector Regression	21
2.2.4.1 Metode Kernel	24
2.2.5 Langkah-Langkah Peramalan	26
2.2.6 Prinsip Peramalan	26
2.3 Pengukuran Hasil Peramalan.....	27
3. PENGUMPULAN DATA	29
3.1 Data Astra Nippon Gasket Indonesia	29
3.2 Data Penjualan Obat.....	30
3.3 Data Permintaan Pumping Unit.....	31
3.4 Data Penjualan Printer.....	31

3.5 Data Pengunjung Ragunan	32
4. PENGOLAHAN DATA DAN ANALISIS	33
4.1 Pengolahan Data.....	33
4.1.1 Penggunaan ANN dan SVR.....	34
4.1.1.1 Prosedur Penggunaan ANN.....	34
4.1.1.2 Prosedur Penggunaan SVR.....	38
4.1.2 Pengolahan Data Astra Nippon Gasket Indonesia	40
4.1.3 Pengolahan Data Penjualan Obat.....	43
4.1.3.1 Pengolahan Data Penjualan Spuitx06.....	44
4.1.3.2 Pengolahan Data Penjualan Rimacc4.....	46
4.1.4 Pengolahan Data Permintaan Pumping Unit.....	49
4.1.5 Pengolahan Data Penjualan Printer.....	52
4.1.6 Pengolahan Data Pengunjung Ragunan	54
4.2 Analisis.....	57
4.2.1 Analisis Parameter	57
4.2.1.1 Analisis Parameter ANN	57
4.2.1.2 Analisis Parameter SVR	59
4.2.2 Analisis Hasil Peramalan	60
5. KESIMPULAN.....	69
DAFTAR REFERENSI.....	70

DAFTAR TABEL

Tabel 4.1 Hasil Pengujian Parameter ANGI	41
Tabel 4.2 Hasil Pengujian Parameter Spuitx06	44
Tabel 4.3 Hasil Pengujian Parameter Rimacc4	47
Tabel 4.4 Hasil Pengujian Parameter C114	49
Tabel 4.5 Hasil Pengujian Parameter Printer	52
Tabel 4.6 Hasil Pengujian Parameter Ragunan	55
Tabel 4.7 MSE Peramalan ANGI	60
Tabel 4.8 MSE Peramalan Spuitx06	62
Tabel 4.9 MSE Peramalan rimacc4	63
Tabel 4.10 MSE Peramalan C114	65
Tabel 4.11 MSE Peramalan Printer	66
Tabel 4.12 MSE Peramalan Ragunan	67



DAFTAR GAMBAR

Gambar 1.1 Diagram Keterkaitan Masalah.....	3
Gambar 1.2 Diagram Alir Metodologi Penelitian.....	6
Gambar 2.1 Pola Karakteristik Permintaan.....	10
Gambar 2.2 Metode-Metode Peramalan	13
Gambar 2.3 Grafik (a)Fungsi Threshold (b)Fungsi Linear-piecewise (c)Fungsi Sigmoid	18
Gambar 2.4 ϵ -insensitive loss function. Semua titik di luar area berwarna dikenai pinalti.....	22
Gambar 2.5 Data spiral yang menggambarkan ketidaklinearan	25
Gambar 3.1 Permintaan ANGI.....	29
Gambar 3.2 Penjualan Spuitx06.....	30
Gambar 3.3 Penjualan Rimacc4.....	30
Gambar 3.4 Permintaan Pumping Unit	31
Gambar 3.5 Penjualan Printer	32
Gambar 3.6 Pengunjung Ragunan.....	32
Gambar 4.1 Langkah Pengolahan Data.....	33
Gambar 4.1 Langkah Pengolahan Data (sambungan).....	34
Gambar 4.2 Variable Editor	35
Gambar 4.3 Neural Network Training Tool.....	37
Gambar 4.4 Perhitungan Beta Bias SVR	40
Gambar 4.5 Grafik Hasil Peramalan 70% ANGI.....	42
Gambar 4.6 Grafik Hasil Peramalan 80% ANGI.....	42
Gambar 4.7 Grafik Hasil Peramalan 90% ANGI.....	43
Gambar 4.8 Grafik MSE Peramalan ANGI	43
Gambar 4.9 Grafik Hasil Peramalan 70% Spuitx06	45
Gambar 4.10 Grafik Hasil Peramalan 80% Spuitx06	45
Gambar 4.11 Grafik Hasil Peramalan 90% Spuitx06	46
Gambar 4.12 Grafik MSE Peramalan Spuitx06.....	46
Gambar 4.13 Grafik Hasil Peramalan 70% Rimacc4.....	47
Gambar 4.14 Grafik Hasil Peramalan 80% Rimacc4.....	48
Gambar 4.15 Grafik Hasil Peramalan 90% Rimacc4.....	48
Gambar 4.16 Grafik MSE Peramalan Rimacc4	49
Gambar 4.17 Grafik Hasil Peramalan 70% C114.....	50
Gambar 4.18 Grafik Hasil Peramalan 80% C114	50
Gambar 4.19 Grafik Hasil Peramalan 90% C114	51
Gambar 4.20 Grafik MSE Peramalan C114.....	51
Gambar 4.21 Grafik Hasil Peramalan 70% Printer	53
Gambar 4.22 Grafik Hasil Peramalan 80% Printer	53
Gambar 4.23 Grafik Hasil Peramalan 90% Printer	54
Gambar 4.24 Grafik MSE Peramalan Printer	54
Gambar 4.25 Grafik Hasil Peramalan 70% Ragunan.....	55
Gambar 4.26 Grafik Hasil Peramalan 80% Ragunan.....	56
Gambar 4.27 Grafik Hasil Peramalan 90% Ragunan.....	56
Gambar 4.28 Grafik MSE Peramalan Ragunan	57

Gambar 4.29 Pola Permintaan ANGI	61
Gambar 4.30 Pola Penjualan Spuitx06.....	62
Gambar 4.31 Pola Penjualan Rimacc4.....	64
Gambar 4.32 Pola Permintaan C114.....	65
Gambar 4.33 Pola Penjualan Printer	66
Gambar 4.34 Pola Pengunjung Ragunan	68



DAFTAR LAMPIRAN

Lampiran 1. Tabel Hasil Pengujian Parameter MA ANGI	72
Lampiran 2. Tabel Hasil Pengujian Parameter ANN ANGI.....	72
Lampiran 3. Tabel Hasil Pengujian Parameter SVR ANGI.....	72
Lampiran 5. Tabel Hasil Pengujian Parameter DES ANGI.....	73
Lampiran 6. Tabel Hasil Pengujian Parameter TES ANGI	73
Lampiran 7. Tabel Hasil Pengujian Parameter ANN Spuitx06	74
Lampiran 8. Tabel Hasil Pengujian Parameter SVR Spuitx06	74
Lampiran 9. Tabel Hasil Pengujian Parameter MA Spuitx06.....	74
Lampiran 10. Tabel Hasil Pengujian Parameter DES Spuitx06.....	75
Lampiran 11. Tabel Hasil Pengujian Parameter TES Spuitx06.....	75
Lampiran 12. Tabel Hasil Pengujian Parameter ANN Rimacc4.....	75
Lampiran 13. Tabel Hasil Pengujian Parameter SVR Rimacc4.....	76
Lampiran 14. Tabel Hasil Pengujian Parameter MA Rimacc4	76
Lampiran 15. Tabel Hasil Pengujian Parameter DES Rimacc4.....	76
Lampiran 16. Tabel Hasil Pengujian Parameter TES Rimacc4	77
Lampiran 17. Tabel Hasil Pengujian Parameter MA C114	77
Lampiran 18. Tabel Hasil Pengujian Parameter ANN C114	77
Lampiran 19. Tabel Hasil Pengujian Parameter SVR C114	78
Lampiran 20. Tabel Hasil Pengujian Parameter DES C114	78
Lampiran 21. Tabel Hasil Pengujian Parameter TES C114.....	78
Lampiran 22. Tabel Hasil Pengujian Parameter ANN Printer	79
Lampiran 23. Tabel Hasil Pengujian Parameter SVR Printer.....	79
Lampiran 24. Tabel Hasil Pengujian Parameter Sensitifitas SVR Printer	79
Lampiran 25. Tabel Hasil Pengujian Parameter MA Printer	80
Lampiran 26. Tabel Hasil Pengujian Parameter DES Printer	80
Lampiran 27. Tabel Hasil Pengujian Parameter TES Printer.....	80
Lampiran 28. Tabel Hasil Pengujian Parameter ANN Ragunan.....	81
Lampiran 29. Tabel Hasil Pengujian Parameter SVR Ragunan.....	81
Lampiran 30. Tabel Hasil Pengujian Parameter DES Ragunan.....	81
Lampiran 31. Tabel Hasil Pengujian Parameter MA Ragunan	82
Lampiran 32. Tabel Hasil Pengujian Parameter TES Ragunan	82
Lampiran 33. Tabel Hasil Pengujian Data <i>Lumpy</i>	82
Lampiran 34. Data Penjualan Obat <i>Lumpy</i>	83

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Peramalan permintaan (*demand forecast*) merupakan salah satu bagian yang berada dalam rantai suplai (*supply chain*). Peramalan permintaan memainkan peranan penting yang dapat menentukan posisi suatu perusahaan. Dengan tingkat akurasi atau ketepatan yang tinggi, maka pendapatan perusahaan dapat meningkat. Hal ini diakibatkan efek dibelakang yang disebabkan oleh peramalan permintaan.

Peramalan permintaan mempengaruhi jumlah barang/bahan baku yang dipesan oleh perusahaan. Sehingga dengan tingkat akurasi yang tinggi, maka bahan baku yang dipesan pun akan sesuai dengan kebutuhan. Selain itu peramalan permintaan mempengaruhi jumlah barang jadi yang diproduksi. Kedua hal ini mempengaruhi *working capital* dari sebuah perusahaan. Peramalan sangatlah berguna bagi industri yang memiliki pangsa pasar yang besar (Peterson, 1993). Peterson juga menunjukkan bahwa *retailer* besar lebih cenderung menggunakan metode *time series* dan peramalan akan industri sedangkan *retailer* yang lebih kecil lebih sering menggunakan metode peramalan dengan perasaan (*judgemental decision*) dan peramalan terhadap perusahaan.

Dalam melakukan peramalan sangatlah beragam. Salah satu metode yang sering dilakukan dalam peramalan permintaan adalah dengan metode *time series*. Dalam *time series* sendiri terdapat beberapa cara yang sering dipergunakan, seperti metode statistik yaitu *moving average*, dan *exponential smoothing*. Namun seringkali metode ini memberikan hasil yang kurang memuaskan, diakibatkan tingkat akurasi yang masih rendah. Oleh karena itu, dalam tugas akhir ini akan dicoba untuk melakukan peramalan *time series* dengan mempergunakan sebuah metode baru, yaitu *Artificial Neural Network* (ANN) dan *Support Vector Regression* (SVR).

ANN merupakan suatu model matematis yang menyerupai cara kerja otak biologis. ANN berusaha meniru struktur dan cara kerja otak manusia untuk

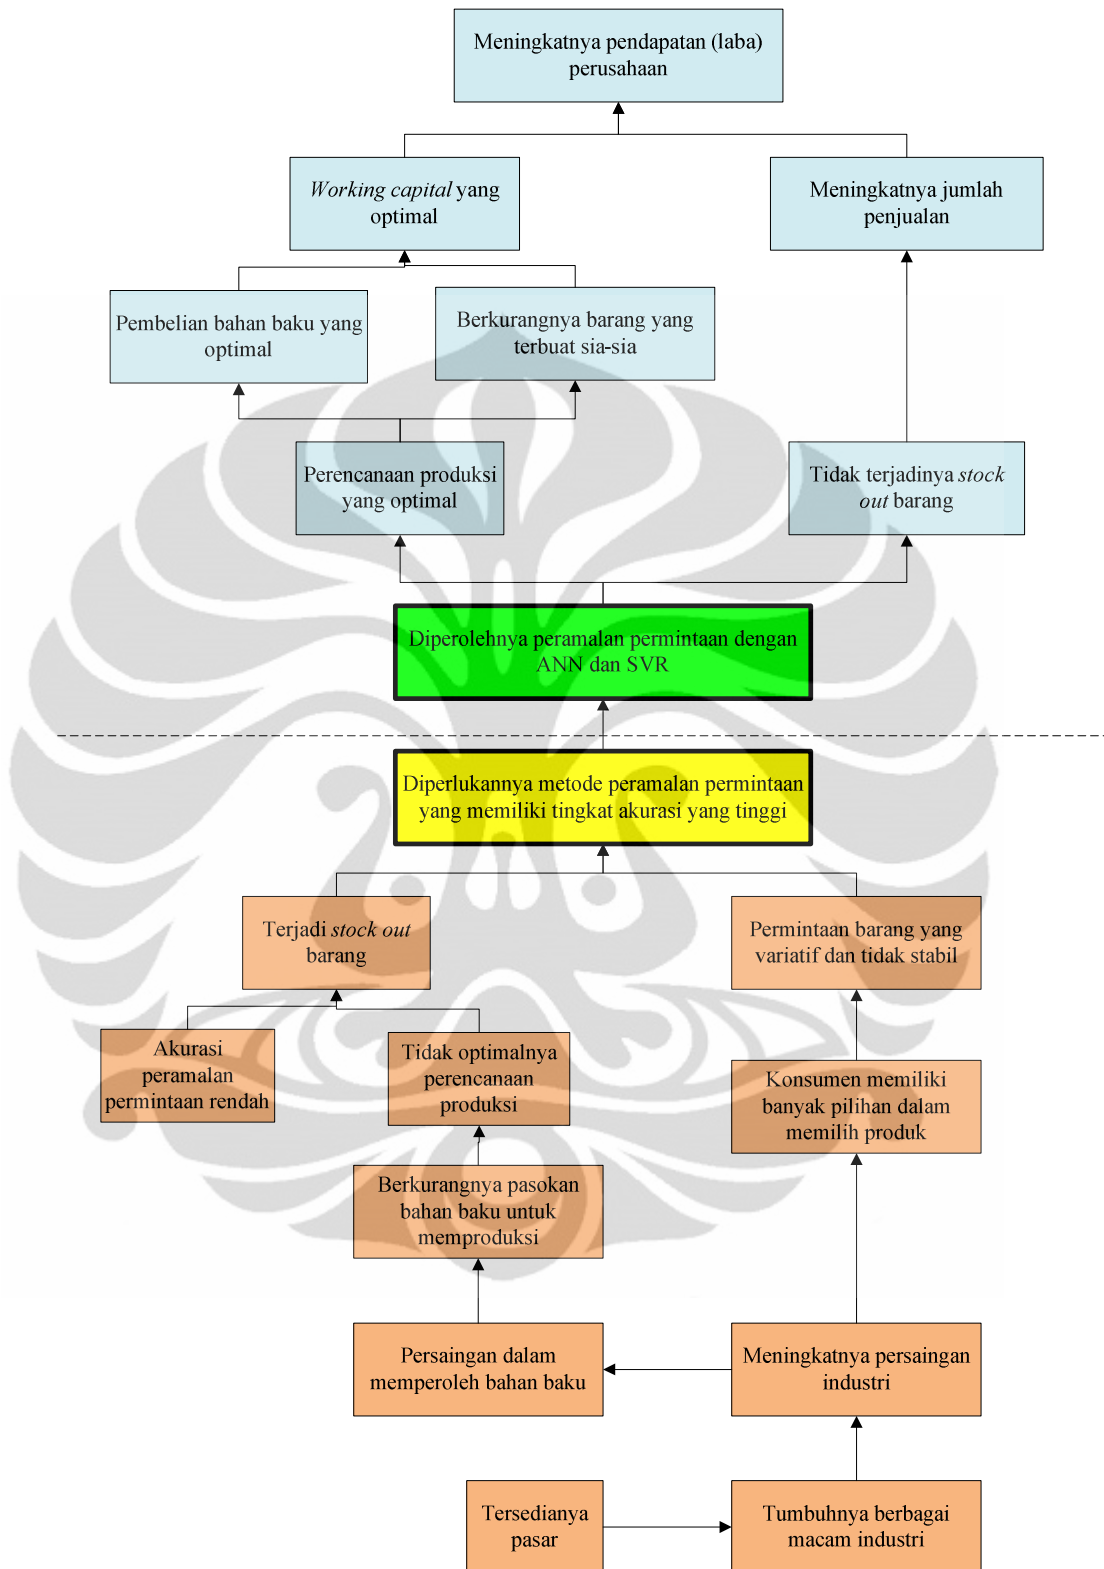
melakukan beberapa pekerjaan seperti mengenali pola, prediksi, klasifikasi, pendekatan fungsi, dan optimasi (Santosa, 2007). Sedangkan SVR merupakan cabang dari *Support Vector Machine* (SVM). SVM merupakan algoritma yang dikembangkan dari teori statistik yang dilakukan oleh Vapnik (1995). SVM umumnya dipergunakan untuk melakukan klasifikasi, namun SVR dipergunakan untuk kasus regresi. Dalam kasus regresi output yang diharapkan adalah bilangan riil dan kontinu. Oleh karena itu SVR dapat dipergunakan untuk melakukan peramalan. Namun secara konseptual SVM dan SVR tidaklah berbeda.

Dalam penelitian yang dilakukan oleh Shahrabi, Mousavi, & Heydar (2009) yang berjudul *Supply Chain Demand Forecasting; A Comparison of Machine Learning Techniques and Traditional Methods*, dibandingkan beberapa metode yang sudah lama dikenal seperti *Moving Average*, *Exponential Smoothing*, dan *Exponential Smoothing with Trend* dengan metode *Machine Learning*, yaitu *Artificial Neural Network (ANN)*, dan *Support Vectors Machine (SVM)*. Menurut penelitian tersebut, disimpulkan bahwa hasil *Mean Absolute Percentage Error (MAPE)* yang dihasilkan oleh metode *Machine Learning* memberikan hasil yang paling baik. Hal ini menandakan baik ANN dan SVM dapat memberikan tingkat akurasi dalam peramalan yang lebih tinggi dibandingkan dengan metode lama.

Selain itu, pada penelitian yang berjudul *Water Demand Prediction using Artificial Neural Networks and Support Vector Regression* yang dilakukan oleh Msiza, Nelwamondo, & Marwala (2008) dikatakan bahwa hasil prediksi yang dihasilkan oleh ANN dan SVR memberikan hasil error yang lebih kecil dibandingkan dengan metode statistik biasa. Dan ketika ANN dan SVR dibandingkan satu sama lain, ANN memberikan hasil yang lebih memuaskan.

1.2 Diagram Keterkaitan Masalah

Diagram keterkaitan masalah merupakan sebuah ulasan yang memberikan gambaran mengenai permasalahan terkait hingga solusi yang diberikan. Berdasarkan apa yang telah dituliskan pada latar belakang, maka berikut ini adalah diagram keterkaitan masalah tersebut pada gambar 1.1:



Gambar 1.1 Diagram Keterkaitan Masalah

1.3 Rumusan Masalah

Seperti yang sudah dijabarkan pada latar belakang, permasalahan yang akan dibahas adalah mengenai diperlukannya metode peramalan permintaan yang memiliki tingkat akurasi yang tinggi.

1.4 Tujuan Penelitian

Adapun tujuan penelitian ini adalah sebagai berikut:

1. Diperoleh hasil peramalan dengan model *Artificial Neural Network* (ANN) dan *Support Vector Regression* (SVR) untuk berbagai jenis data.
2. Perbandingan akurasi peramalan ANN dan SVR dengan metode statistik *Moving Average* (MA), *Double Exponential Smoothing* (DES) dan *Triple Exponential Smoothing* (TES).

1.5 Ruang Lingkup Penelitian

Ruang lingkup penelitian yang akan dilakukan dalam penelitian adalah sebagai berikut ini:

1. Data yang digunakan adalah data historis dari data permintaan PT. Astra Nippon Gasket Indonesia (ANGI), data penjualan obat, data penjualan pumping unit C114, data penjualan printer dan data pengunjung ragunan.
2. Pengolahan data dilakukan dengan membuat model ANN dan SVR hanya dengan menggunakan data *time series*.
3. Hasil model hanya akan dibandingkan dengan metode *Moving Average*, *Double Exponential Smoothing* dan *Triple Exponential Smoothing*.

1.6 Metodologi Penelitian

Dalam melakukan penelitian, dilakukan beberapa langkah untuk mendapatkan hasil. Adapun langkah-langkah yang akan dilakukan adalah sebagai berikut:

1. Penyusunan masalah (*Problem Structuring*)

Dalam memulai sebuah penelitian maka diperlukan penyusunan masalah untuk mengidentifikasi masalah. Dari identifikasi masalah ini, maka dapat disusun keperluan akan data penunjang untuk menyelesaikan masalah. Hal ini penting dilakukan untuk mencari masalah yang sebenarnya terjadi sehingga dapat dilakukan pembatasan masalah sehingga penelitian tidak menjadi kabur.

2. Mencari data (*Build a Data*)

Dalam penelitian ini dipergunakan data *time series* dari berbagai sumber. Data yang dicari merupakan data historis yang dapat dipergunakan dalam peramalan.

3. Mempelajari data (*Explore the Data*)

Tahap selanjutnya adalah mempelajari data. Data akan dianalisis untuk melihat pola dari data dan menganalisis data mana saja yang dapat terpakai, sehingga nantinya dapat disesuaikan dengan metode ANN dan SVR.

4. Menyiapkan data untuk dibuat model (*Prepare Data for Modelling*)

Setelah mempelajari data, maka data akan dipersiapkan untuk dibuat menjadi model. Data akan dibagi menjadi data *training* dan *testing* dengan jumlah yang berbeda-beda.

5. Membuat model (*Build a Model*)

Pada tahap ini, data yang telah dianalisis akan dibuat modelnya dengan mempergunakan metode ANN dan SVR untuk mendapatkan hasil berupa peramalan beberapa periode kedepan. Adapun *software* yang dipergunakan adalah MATLAB dan MINITAB untuk statistik biasa.

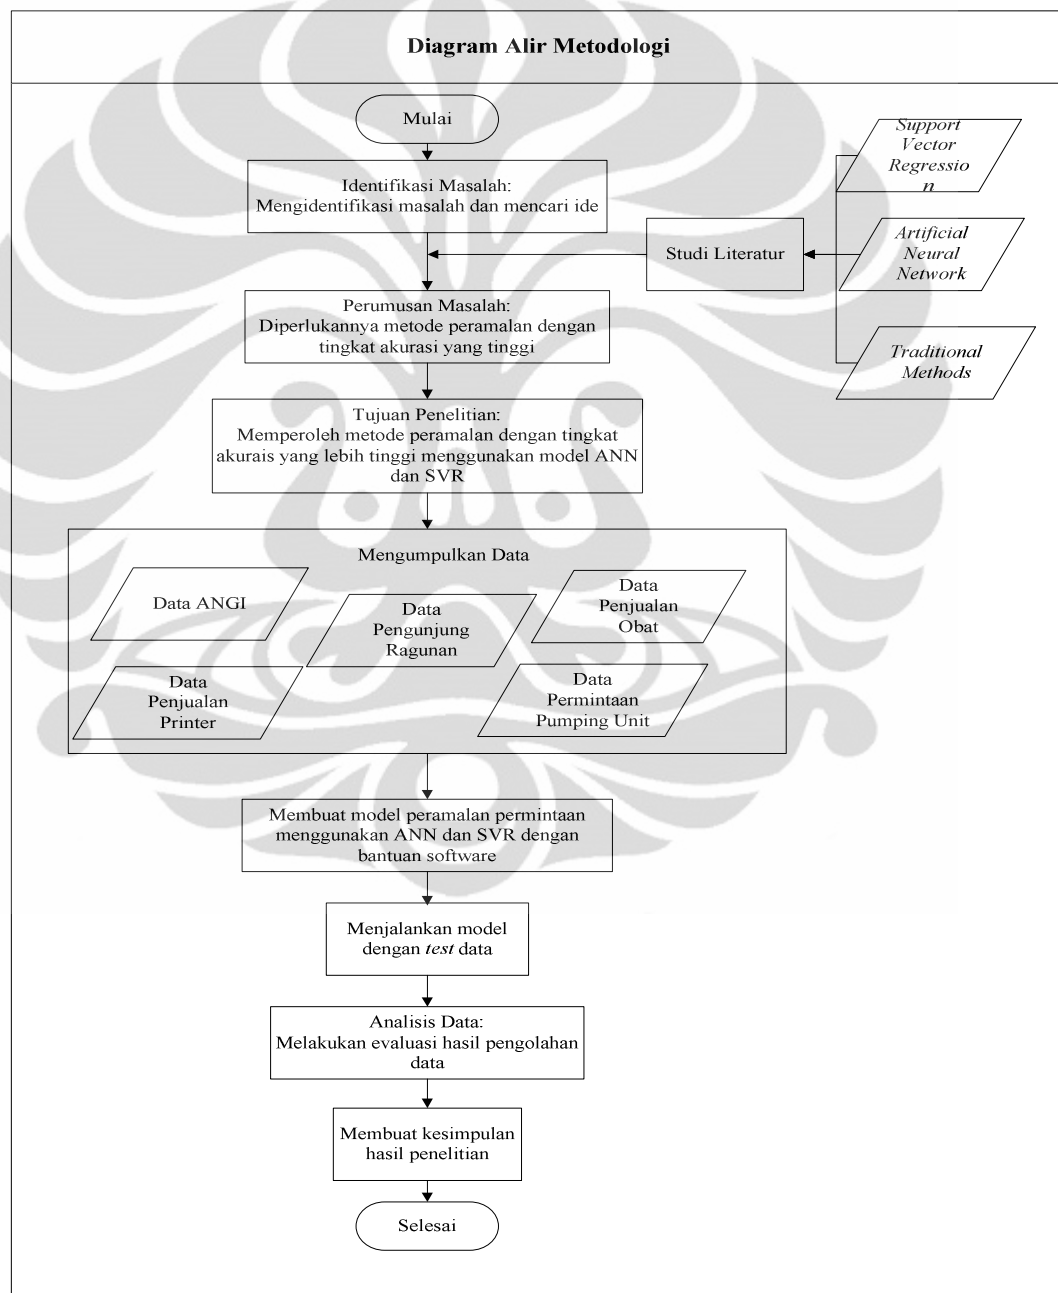
6. Tahap evaluasi hasil (*Evaluate Results*)

Pada tahap ini, dievaluasi hasil dari peramalan permintaan yang dihasilkan oleh model, dan membandingkannya dengan beberapa metode tradisional seperti *Moving Average*, *Double Exponential Smoothing* dan *Triple Exponential Smoothing* dan dengan kenyataan yang terjadi dengan begitu maka akan dapat dilihat seberapa besar *error* dan *accuracy* dari model dalam meramalkan permintaan. *Error* dan *accuracy* dilihat dengan melihat MSE.

7. Penarikan kesimpulan

Kesimpulan akan ditarik berdasarkan tahap evaluasi. Kesimpulan akan memberisikan hasil MSE peramalan yang didapatkan dengan metode ANN dan SVR, MA, dan DES dan TES. Lalu akan disimpulkan jumlah data training yang sebaiknya dipergunakan serta metode terbaik yang dihasilkan.

Gambar dari metodologi penelitian dapat dilihat pada berikut ini:



Gambar 1.2 Diagram Alir Metodologi Penelitian

1.7 Sistematika Penulisan

Sistematika yang digunakan dalam penulisan penelitian ini mengikuti aturan standar baku penulisan tugas akhir mahasiswa. Penulisan tugas akhir ini dibuat dalam lima bab yang memberikan gambaran sistematis sejak awal penelitian hingga tercapainya tujuan penelitian. Adapun penjabaran kelima bab tersebut adalah sebagai berikut ini:

1. Bab 1 Pendahuluan

Bab ini berisikan latar belakang, diagram keterkaitan masalah, rumusan masalah, tujuan penelitian, batasan permasalahan, metodologi penelitian, dan sistematikan penulisan.

2. Bab 2 Landasan Teori

Bab ini berisikan teori dan tinjauan pustaka yang berhubungan dengan penelitian yang dilakukan. Adapun sumber berasal dari buku, penelitian terdahulu dan jurnal-jurnal ilmiah.

3. Bab 3 Pengumpulan Data

Bab ini berisikan data yang dipergunakan oleh dalam melakukan penelitian.

4. Bab 4 Pengolahan Data dan Analisis

Bab ini berisikan mengenai pengolahan akan data yang telah diperoleh beserta analisisnya. Pengolahan dibagi menjadi uji parameter metode, dan peramalan dengan metode yang telah ditentukan. Dari bab ini dapat dilihat hasil analisis atas pengolahan data untuk penarikan kesimpulan sesuai dengan tujuan penelitian.

5. Bab 5 Kesimpulan

Bab ini berisikan kesimpulan dan saran yang diberikan sebagai hasil dari penelitian ini.

BAB 2

LANDASAN TEORI

Pada bab ini akan dijelaskan landasan teori yang dipergunakan dalam menuliskan tugas akhir. Adapun isi dari landasan teori ini adalah mengenai permintaan, peramalan, metode peramalan yang dipergunakan, dan perhitungan kesalahan dari peramalan tersebut.

2.1 Permintaan (*Demand*)

Permintaan merupakan jumlah barang atau jasa yang diinginkan oleh konsumen atau kelompok konsumen dengan harga tertentu (Albert, 1998). Permintaan inilah yang menjadi modal sebuah perusahaan/industri dalam melakukan bisnisnya. Dimana ketika terdapat permintaan, maka terdapat peluang bisnis untuk memenuhi permintaan tersebut.

2.1.1 Pengelolaan Permintaan

Tujuan utama dari sebuah perusahaan yaitu melayani konsumen, dimana tujuan akhir dari perusahaan adalah menjalankan kegiatan perusahaan agar dapat bertemu dengan kebutuhan konsumen (Arnold & Chapman, 2004).

Pengelolaan permintaan merupakan suatu pengaturan akan permintaan konsumen. Kegiatan tersebut dapat berupa manajemen jangka pendek, menengah dan jangka panjang. Dalam jangka panjang, proyeksi permintaan dibutuhkan untuk perencanaan strategi bisnis dimana permintaan ini dapat mempengaruhi langkah strategis yang akan dilakukan oleh perusahaan. Dalam jangka menengah, tujuan dari pengelolaan permintaan adalah untuk memproyeksikan jumlah permintaan sebagai fungsi dari perencanaan produksi. Dan contoh pengelolaan permintaan dalam jangka pendek yaitu pengelolaan dibutuhkan untuk mengkombinasikan permintaan dengan penjadwalan produksi.

Pada umumnya, kegiatan pengelolaan permintaan (*demand management*) terdiri dari empat kegiatan utama, yaitu:

1. Peralamaan permintaan

Peramalan permintaan dilakukan perusahaan untuk memproyeksikan jumlah permintaan yang akan diterima oleh perusahaan kedepannya. Peramalan permintaan merupakan kegiatan yang penting dalam sebuah bisnis industri. Hal ini disebabkan peramalan permintaan dapat mempengaruhi proses kerja lainnya, seperti pembelian bahan baku, dan perencanaan produksi. Oleh karena itu diperlukan suatu cara peramalan yang memiliki tingkat akurasi yang tinggi.

2. Proses pemesanan

Proses pemesanan dimulai dari ketika perusahaan menerima pesanan dari konsumen. Untuk memenuhi pesanan konsumen tersebut dapat dilakukan dengan mengambil ketersediaan barang yang ada atau melakukan proses produksi untuk memenuhi permintaan tersebut. Oleh karena itu, sebuah perusahaan harus mengetahui produk apa yang harus diproduksi, berapa banyak, dan kapan produk tersebut harus diantarkan.

3. Jadwal pengantaran

Penjadwalan pengantaran merupakan suatu kegiatan pengiriman barang yang harus dilakukan atas permintaan konsumen.

4. Konfirmasi antara perencanaan produksi dengan kondisi pasar.

2.1.2 Karakteristik Permintaan

Permintaan terhadap suatu produk tentunya akan berbeda-beda, sehingga permintaan tersebut tentunya akan membentuk sebuah karakteristik tersendiri. Apabila digambarkan dalam sebuah grafik, maka data historis akan menunjukkan berbagai macam bentuk maupun pola dari tingkat permintaan yang ada (Arnold & Chapman, 2004).

Pada umumnya permintaan akan memiliki pola karakteristik seperti berikut ini:

1. Tren (*Trend*)

Pola permintaan tren biasanya dialami oleh produk yang baru mengalami masa kejayaan (*prosperity*) dan masih berkembang dalam suatu siklus hidupnya. Pada masa seperti itu, biasanya produk akan menunjukkan kecenderungan (tren) naik. Dan hal sebaliknya terjadi ketika produk sudah

mencapai masa dewasa (*mature*) dan sudah tidak bisa berkembang lagi, maka lama kelamaan produk tersebut akan mengalami penurunan dan cenderung menunjukkan tren turun.

2. Musiman (*Seasonality*)

Pola musiman biasanya terbentuk oleh permintaan dengan produk yang tingkat permintaannya dipengaruhi oleh cuaca, musim liburan, maupun hari-hari besar. Dasar periode untuk permintaan musiman biasanya dalam rentang waktu tahunan, akan tetapi bulanan dan mingguan juga bias membentuk suatu pola permintaan musiman.


3. Acak (*Random*)

Pola acak biasanya terjadi pada produk yang tingkat permintaannya dipengaruhi oleh banyak faktor dalam suatu periode tertentu. Variasi yang terjadi mungkin akan sangat kecil, namun membentuk pola acak yang tidak menentu.

4. Siklis (*Cycle*)

Pola siklis hampir mirip dengan pola permintaan musiman. Namun, pola permintaan siklis terbentuk dalam satu rentang periode yang lebih panjang, misalnya pola siklis tersebut terbentuk dalam rentang waktu beberapa tahun maupun dekade.

Jika digambarkan secara grafik, pola-pola permintaan tersebut akan memberikan gambaran seperti berikut ini:



Gambar 2.1 Pola Karakteristik Permintaan

2.2 Peramalan (*Forecasting*)

Peramalan adalah proses untuk memperkirakan berapa kebutuhan dimasa mendatang yang meliputi kebutuhan dalam ukuran kuantitas, kualitas, waktu dan lokasi yang dibutuhkan untuk memenuhi permintaan barang atau jasa (Nasution, 1999). Peramalan memiliki peranan yang penting dalam sebuah perusahaan, dikarenakan peramalan merupakan dasar dari sebuah perencanaan, baik perencanaan penjualan, pembelian, maupun produksi. Oleh karena itu, pemilihan cara melakukan peramalan menjadi sangat penting, walaupun cara peramalan bukan satu-satunya faktor yang mempengaruhi akurasi atas pemenuhan permintaan.

Dalam melakukan peramalan terdapat berbagai cara. Jika berdasarkan sifat ramalan yang disusun, maka peramalan dibedakan atas dua macam (Makridakis & Wheelwright, 1999):

1. Peramalan kualitatif

Beberapa model *forecasting* yang digolongkan sebagai model kualitatif adalah :

a. Dugaan Manajemen (*management estimate*)

Merupakan metode *forecasting* dimana *forecasting* semata-mata berdasarkan pertimbangan manajemen. Metode ini cocok dalam situasi yang sangat sensitif terhadap intuisi dari satu atau sekelompok kecil orang yang karena pengalamannya mampu memberikan opini yang kritis dan relevan.

b. Riset Pasar (*market research*)

Merupakan metode *forecasting* berdasarkan hasil *survey* pasar yang dilakukan oleh tenaga pemasar produk atau yang mewakilinya. Metode ini menjangkau informasi dari pelanggan yang berkaitan dengan rencana pembelian produk di masa yang akan datang.

c. Metode Kelompok Terstruktur (*structured groups methods*)

Merupakan metode *forecasting* berdasarkan proses konvergensi dari opini beberapa orang atau ahli secara interaktif dan membutuhkan fasilitator untuk menyimpulkan hasil dari *forecasting*.

d. Analogi Historis (*historical analogy*)

Universitas Indonesia

Merupakan teknik *forecasting* berdasarkan pola data masa lalu dari produk yang disamakan secara analogi.

2. Peramalan kuantitatif

Yaitu peramalan berdasarkan atas dasar kuantitatif pada masa lampau. Metode peramalan kuantitatif sendiri dibedakan menjadi dua, yaitu metode metode deret berkala dan metode kausal.

- Metode deret berkala (*Time Series*), yaitu metode kuantitatif yang didasarkan atas penggunaan analisa pola hubungan antar variabel yang akan diperkirakan dengan variabel waktu. Permintaan dimasa lalu pada analisa deret waktu akan dipengaruhi keempat komponen utama *trend* (tren), *cycle* (siklus), *season* (musiman) dan *random* (acak). Penjelasan tentang komponen-komponen tersebut sudah dijelaskan pada bagian sub bab permintaan.

- Metode kausal

Metode peramalan kausal mengembangkan suatu model sebab-akibat antara permintaan yang diramalkan dengan variabel-variabel lain yang dianggap berpengaruh. Pada metode kausal ini dibagi menjadi tiga bagian yaitu :

1. Metode korelasi regresi

Peramalan ini digunakan untuk :

- Peramalan penjualan
- Peramalan keuntungan
- Peramalan permintaan
- Peramalan keadaan ekonomi

Metode ini sangat cocok digunakan untuk peramalan jangka pendek, data yang digunakan kumpulan dari data beberapa tahun.

2. Metode ekinimetrik

Peramalan ini digunakan untuk :

- Peramalan penjualan menurut kelas produksi
- Peramalan keadaan ekonomi masyarakat yang meliputi permintaan, harga, dan penawaran.

Metode ini sangat cocok untuk peramalan jangka pendek dan panjang. Data yang digunakan merupakan kumpulan data beberapa tahun.

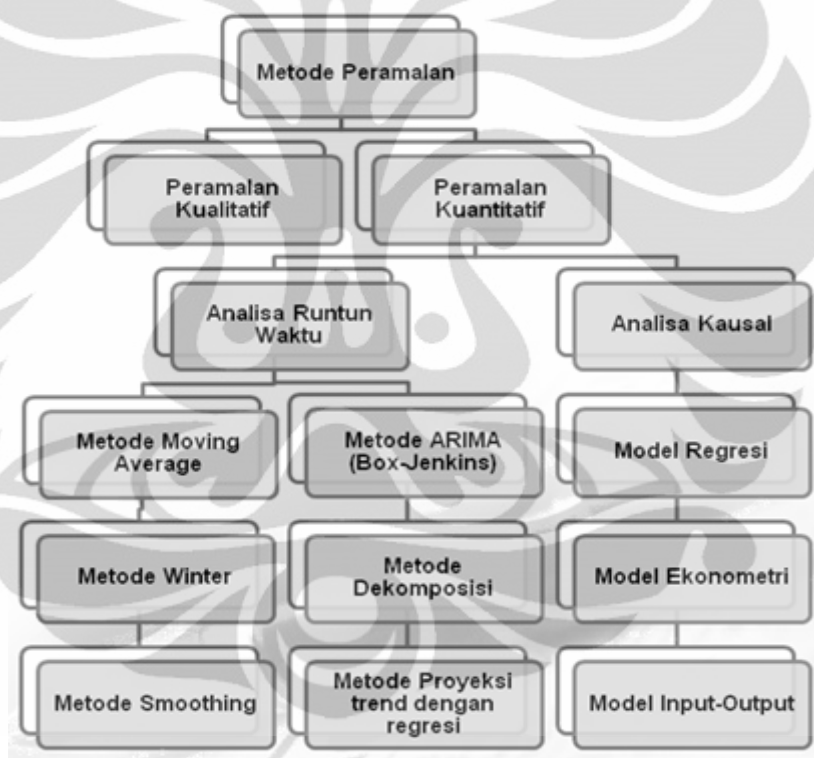
3. Metode input output

Peramalan ini digunakan untuk :

- Peramalan penjualan perusahaan
- Peramalan produksi dari sektor dan sub sektor industri

Metode ini sangat cocok untuk peramalan jangka panjang. Data yang digunakan merupakan kumpulan data 10-15 tahun.

Berikut ini gambaran metode peramalan yang telah disebutkan diatas:



Gambar 2.2 Metode-Metode Peramalan

2.2.1 Metode Peramalan *Moving Average*

Metode yang paling umum dipergunakan dalam peramalan dengan metode deret berkala adalah *moving average*. Metode ini merupakan metode yang paling sederhana dan paling umum dipergunakan. *Moving Average* diperoleh dengan merata-rata permintaan berdasarkan data-data historis yang terbaru. Teknik ini bertujuan untuk mengurangi atau menghilangkan variasi acak permintaan dalam

hubungannya dengan waktu. Secara sistematis, maka MA dinyatakan dalam persamaan sebagai berikut (Makridakis & Wheelwright, 1999):

$$MA = \frac{A_t + A_{t-1} + \dots + A_{t-(N-1)}}{N} \quad (2.1)$$

dimana :

A_t = Permintaan aktual pada periode t

N = Jumlah data permintaan yang dilibatkan dalam perhitungan MA

Karena data aktual yang dipakai untuk perhitungan MA berikutnya selalu dihitung dengan mengeluarkan data yang paling terdahulu, maka :

$$MA_t = MA_{t-1} = \frac{A_t - A_{t-1}}{N} \quad (2.2)$$

2.2.2 Metode Peramalan *Exponential Smoothing*

Metode *exponential smoothing* merupakan metode yang mempergunakan pemulusan, baik untuk *trend*, *level*, maupun *seasonal*. Hal ini tergantung dengan berapa tingkat atau jenis pemulusan yang dipergunakan. Metode *exponential smoothing* terdiri atas :

1. Metode Pemulusan Eksponensial Tunggal (*Single Exponential Smoothing*).

Metode ini melakukan pemulusan *level*. Persamaan dasar dengan metode pemulusan eksponensial adalah sebagai berikut (Makridakis & Wheelwright, 1999) :

$$S_t' = \alpha X_t + (1 - \alpha)S_{t-1}' \quad (2.3)$$

$$S_t'' = \alpha S_t' + (1 - \alpha)S_{t-1}'' \quad (2.4)$$

$$A_t = S_t' + (S_t' - S_t'') = 2S_t' - S_t'' \quad (2.5)$$

$$B_t = \frac{\alpha}{1 - \alpha} (S_t' - S_t'') \quad (2.6)$$

$$F_{t+m} = A_t + B_t \quad (2.7)$$

dimana :

S_t' = Nilai pemulusan eksponensial tunggal

S_t'' = Nilai pemulusan eksponensial ganda

F_{t+m} = Nilai ramalan untuk m periode yang akan datang

A_t = Nilai pemulusan untuk estimasi data

B_t = Nilai pemulusan untuk estimasi level

α = Konstanta pemulusan untuk data

2. Metode Pemulusan Eksponensial Ganda (*Double Exponential Smoothing*).

Pada pemulusan eksponensial ganda, maka dipergunakan pemulusan *level* dan *trend*. Hal ini memungkinkan kita melihat pola data dengan memperhatikan *trend* yang sedang terjadi terhadap permintaan. Persamaan untuk metode pemulusan eksponensial ganda ini adalah sebagai berikut (Makridakis & Wheelwright, 1999):

$$S_t' = \alpha X_t + (1 - \alpha)S_{t-1}' \quad (2.8)$$

$$S_t'' = \alpha S_t' + (1 - \alpha)S_{t-1}'' \quad (2.9)$$

$$A_t = S_t' + (S_t' - S_t'') = 2S_t' - S_t'' \quad (2.10)$$

$$B_t = \frac{\alpha}{1 - \alpha} (S_t' - S_t'') \quad (2.11)$$

$$F_{t+m} = A_t + B_t \quad (2.12)$$

dimana :

S_t' = Nilai pemulusan eksponensial tunggal

S_t'' = Nilai pemulusan eksponensial ganda

X_t = Data aktual pada periode t

α = Konstanta pemulusan

F_{t+m} = Nilai ramalan untuk m periode yang akan datang

A_t = Selisih kedua nilai pemutusan pada periode t

B_t = Komponen kecenderungan pada periode t

m = Jumlah periode yang akan datang, yang akan diramalkan

3. Pemulusan Eksponensial Tripel : Metode Musiman Tiga Parameter dari Winter.

Metode pemulusan eksponensial dari Winter digunakan jika data mempunyai fakta musiman (Makridakis & Wheelwright, 1999).

Persamaan dasar untuk metode Winter adalah sebagai berikut :

- Pemulusan trend :

$$b_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)b_{t-1} \quad (2.13)$$

- Pemulusan musiman

- Pemulusan keseluruhan :

$$S_t = \alpha \frac{X_t}{I_{t-L}} + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (2.14)$$

- Ramalan:

$$F_{t+m} = (S_t + b_t m) I_{t-L+m} \quad (2.15)$$

dimana :

L = panjang musiman

b = komponen tren

I = faktor penyesuaian musiman

F_{t+m} = ramalan untuk m periode kedepan

$\alpha\beta\gamma$ = konstanta pemulusan

2.2.3 Metode Peramalan Artificial Neural Network

Artificial Neural Network (ANN) merupakan model matematis yang menyerupai cara kerja otak biologis. *Neural Network* terdiri dari sejumlah inti syaraf, hubungan antara inti dan aturan-aturan pembelajaran. Pembobotan diberikan terhadap tiap hubungan menurut aturan pembelajaran tertentu. Hasil dari proses pembelajaran dalam jaringan tersimpan dalam bentuk bobot dalam tiap hubungan antara inti syaraf.

ANN berusaha meniru struktur/arsitektur dan cara kerja otak manusia sehingga mampu menggantikan beberapa pekerjaan manusia. Pekerjaan seperti mengenali pola, prediksi, klasifikasi, pendekatan fungsi, optimasi adalah pekerjaan-pekerjaan yang diharapkan bisa diselesaikan dengan ANN (Santosa, 2007).

2.2.3.1 Perhitungan Input ANN

Perhitungan yang diperlukan dalam menghitung nilai input dalam tiap unit i pada jaringan pada waktu t dilakukan dengan persamaan :

$$\text{net}_i(t) = \sum w_{ij}(t) o_j(t) \quad (2.16)$$

dimana :

$\text{net}_i(t)$: jaringan *signal input* pada unit i pada jaringan

$o_j(t)$: output dari unit j dalam jaringan

$w_{ij}(t)$: nilai pembobotan dari unit j ke unit i

n : jumlah input yang terhubung dengan unit i

2.2.3.2 Fungsi aktivasi

Langkah dalam menentukan rangsangan pada input yang diterima untuk suatu unit dikonversikan menjadi nilai input disebut dengan nilai pergerakan/aktivasi. Aktivasi pada suatu unit analog dengan derajat eksitasi dari

unit tersebut, semakin kuat nilai aktivasi suatu unit, semakin kuat pula dalam mengeksitasi unit lain dalam jaringan.

Fungsi aktivasi terdiri dari beberapa bentuk yang spesifik yang tergantung pada beberapa faktor antara lain :


- 1) Tipe jaringan yang digunakan.
- 2) Fungsi yang harus ditunjukkan oleh unit-unit dalam jaringan.
- 3) Interpretasi eksternal dari input jaringan.

Jenis-jenis fungsi aktivasi $\phi(\cdot)$ yang bisa dipakai dalam neural networks adalah seperti berikut ini (Santosa, 2007) :

1. Fungsi Threshold

Untuk fungsi ini kita punya dua output:

$$\phi(v) = \begin{cases} 1 & \text{if } v \geq 1 \\ 0 & \text{if } v < 1 \end{cases} \quad (2.17)$$



Gambar 2.3 Grafik (a)Fungsi Threshold (b)Fungsi Linear-piecewise (c)Fungsi Sigmoid

(sumber: Santosa, 2007)

2. Fungsi Linear Piecewise

$$\varphi(v) = \begin{cases} 1, & v \geq \frac{1}{2} \\ v + \frac{1}{2}, & -\frac{1}{2} < v < \frac{1}{2} \\ 0, & v \leq -\frac{1}{2} \end{cases} \quad (2.18)$$

3. Fungsi Sigmoid

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (2.19)$$

Macam-macam fungsi aktivasi yang sering digunakan dalam ANN adalah:

1. Logistic Sigmoid

$$F(x) = \frac{1}{1 + e^{-ax}} \quad (2.20)$$

2. Tangent Hyperbolic

$$f(x) = \operatorname{atanh}(bx)$$

dimana $(a, b) > 0$ (2.21)

2.2.3.3 Backpropagation Network

Salah satu metode mentraining multilayer *neural networks* adalah algoritma *backpropagation*. Algoritma ini menggunakan aturan pembelajaran *gradient descent*. Algoritma ini sangat bermanfaat, cukup handal dan mudah dipahami (Santosa, 2007).

Backpropagation Network melakukan suatu pemetaan dari pola input ke pola output dengan meminimasi kesalahan diantara output aktual yang diproduksi jaringan dengan output yang diinginkan. Proses pembelajaran dimulai dengan menunjukkan pola input pada *backpropagation network* kemudian pola input dipropagasi keseluruhan jaringan sampai pola output dihasilkan.

Proses pembelajaran *backpropagation network* mengikuti algoritma sebagai berikut :

1. Pilihlah pasangan vektor pertama dari kumpulan vektor pada proses pembelajaran.
2. Gunakan vektor input x sebagai output dari input layer pada elemen proses.
3. Hitung nilai aktivasi pada tiap unit pada layer selanjutnya.
4. Aplikasikan fungsi aktivasi yang cocok dimana $f(\text{net}^k)$ untuk fungsi aktivasi pada layer yang tersembunyi dan $f(\text{net}^o)$ untuk fungsi aktivasi pada layer output.
5. Ulangi tahap 3 dan 4 untuk tiap layer pada jaringan.
6. Hitung nilai kesalahan pada output δ_{pk}^o

$$\delta_{pk}^o = (y_k - o_k) f'(\text{net}^{ok}) \quad (2.22)$$

7. Hitung nilai kesalahan pada semua *hidden layer* dengan menggunakan perumusan

$$\delta_{pj}^o = f'(\text{net}^{kj}) \sum_{k=1}^k \delta_{pk}^o w_{kj} \quad (2.23)$$

8. Perbarui pembobotan yang terhubung pada *hidden layer* dengan menggunakan persamaan:

$$W_{ji}(t+1) = w_{ji}(t) + \eta \delta_{pj}^h w_{kj} \quad (2.24)$$

Dimana η : adalah faktor pembelajaran yang menentukan banyaknya perubahan dalam tiap hubungan unit selama proses pembelajaran.

9. Perbarui pembobotan yang terhubung pada *output layer* dengan menggunakan persamaan:

$$w_{ji}(t+1) = w_{kj}(t) + \eta \delta_{pk}^o f'(\text{net}^{kj}) \quad (2.25)$$

10. Ulangi langkah 2 sampai dengan 9 untuk semua pasangan vektor input selama tahap pembelajaran, pengulangan ini disebut *epoch*.

11. Ulangi langkah 1 sampai dengan 10 sampai *epoch* mencapai tingkat *error* yang diinginkan. Tingkat *error* menggunakan penjumlahan kuadrat kesalahan yang ditunjukkan pada *output layer* untuk semua pembelajaran p :

$$E = \sum_{k=1}^p \sum_{k=1}^k (\delta_{pk}^o)^2 \quad (2.26)$$

2.2.4 Metode Peramalan Support Vector Regression

Support Vector Regression (SVR) merupakan cabang dari *Support Vector Machine* (SVM). SVR merupakan penerapan SVM untuk kasus regresi. Dalam kasus klasifikasi, yang merupakan keahlian SVM, output data berupa bilangan bulat atau diskrit, sedangkan untuk kasus regresi output data berupa bilangan riil atau kontinu. Dengan menggunakan konsep ε -insensitive loss function, yang diperkenalkan oleh Vapnik, SVM bisa digeneralisasi untuk melakukan pendekatan fungsi (*function approximation*) atau regresi (Santosa,2007).

Misalkan kita punya ℓ set data *training*, (x_i, y_i) , $i = 1, \dots, \ell$ dengan data input $x = (x_1, x_2, \dots, x_\ell)$ dan output yang bersangkutan $y = \{y_1, \dots, y_\ell\} \subseteq \mathfrak{R}$. Dengan SVR, kita ingin menemukan suatu fungsi $f(x)$ yang mempunyai deviasi paling besar ε dari target aktual y_i untuk semua data *training*. Maka, dengan SVR kita akan mendapatkan suatu tabung seperti dalam gambar 2.4 Manakala nilai ε sama dengan 0 maka kita dapatkan suatu regresi yang sempurna. Misalkan kita mempunyai fungsi berikut sebagai garis regresi:

$$f(x) = w^T \varphi(x) + b \quad (2.27)$$

dimana $\varphi(x)$ menunjukkan suatu titik di dalam *feature space* F hasil pemetaan x di dalam *input space*. Koefisien w dan b diestimasi dengan cara meminimalkan fungsi resiko (*risk function*) yang didefinisikan dalam persamaan :

$$\min \frac{1}{2} \|w\|^2 + C \frac{1}{\ell} \sum_{i=1}^{\ell} L_{\varepsilon}(y_i, f(x_i)) \quad (2.28)$$

subject to

$$y_i - w\phi(x_i) - b \leq \varepsilon$$

$$w\phi(x_i) - y_i + b \leq \varepsilon, \quad i = 1, \dots, \ell,$$

dimana

$$L_\varepsilon(y_i, f(x_i)) = \begin{cases} |y_i - f(x_i)| - \varepsilon & |y_i - f(x_i)| > \varepsilon \\ 0, & \text{otherwise} \end{cases} \quad (2.29)$$

Faktor $\|w\|^2$ dinamakan *regularisasi*. Meminimalkan $\|w\|^2$ akan membuat suatu fungsi setipis (*flat*) mungkin, sehingga bisa mengontrol kapasitas fungsi (*function capacity*). Faktor kedua dalam fungsi tujuan adalah kesalahan empirik (*empirical error*) yang diukur dengan ε -insensitive loss function. Menggunakan ide ε -insensitive loss function, kita harus meminimalkan norm dari w agar mendapatkan generalisasi yang baik untuk fungsi regresi f . Karena itu kita perlu menyelesaikan problem optimisasi berikut:


$$\text{Min} \frac{1}{2} \|w\|^2 \quad (2.30)$$

subject to

$$y_i - w\phi(x_i) - b \leq \varepsilon$$

$$w\phi(x_i) - y_i + b \leq \varepsilon, \quad i = 1, \dots, \ell \quad (2.31)$$

Kita asumsikan bahwa ada suatu fungsi f yang dapat mengaproksimasi semua titik (x_i, y_i) dengan presisi ε .



Gambar 2.4 ε -insensitive loss function. Semua titik di luar area berwarna dikenai penalti

Dalam kasus ini kita asumsikan bahwa semua titik ada dalam rentang $f \pm \varepsilon$ (*feasible*). Dalam hal ketidaklayakan (*infeasibility*), dimana ada beberapa titik yang mungkin keluar dari rentang $f \pm \varepsilon$, kita bias menambahkan *variable slack* t , t^* untk mengatasi masalah pembatas yang tidak layak (*infeasible constraints*) dalam problem optimisasi. Selanjutnya problem optimisasi di atas bisa diformulasikan sebagai berikut :

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (t_i + t_i^*) \quad (2.32)$$

Subject to

$$y_i - w^T \phi(x_i) - b - t_i \leq \varepsilon, \quad i = 1, \dots, \ell$$

$$w^T \phi(x_i) - y_i + b - t_i^* \leq \varepsilon, \quad i = 1, \dots, \ell$$

$$t_i, t_i^* = 0,$$

Konstanta $C > 0$ menentukan tawar menawar (*trade off*) antara ketipisan fungsi (*flatness of function*) f dan batas atas deviasi lebih dari ε masih ditoleransi. Semua deviasi lebih besar daripada ε akan dikenakan pinalti sebesar C . Dalam SVR, ε ekuivalen dengan akurasi dari aproksimasi kita terhadap data *training*. Nilai ε yang kecil terkait dengan nilai yang tinggi pada variabel *slack* $t^*(*)$ i dan akurasi aproksimasi yang tinggi. Sebaliknya, nilai yang tinggi untuk ε berkaitan dengan nilai $t^*(*)$ i yang kecil dan akurasi aproksimasi yang rendah. Menurut persamaan (2.32), nilai yang tinggi untuk *variabel slack* akan membuat kesalahan empirik mempunyai pengaruh yang besar terhadap faktor regularisasi. Dalam SVR, *support vectors* adalah data *training* yang terletak pada dan di luar batas ε dari fungsi keputusan. karena itu jumlah *support vectors* menurun dengan naiknya nilai ε . Dalam formulasi *dual*, problem optimisasi dari SVR adalah sebagai berikut:

$$\max \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i - \alpha_i') (\alpha_i - \alpha_i') K(x_i, x_j)$$

$$\sum_{i=1}^l y_i (\alpha_i - \alpha'_i) - \varepsilon \sum_{i=1}^l (\alpha_i + \alpha'_i) \quad (2.33)$$

Subject to :

$$\sum_{i=1}^l (\alpha_i - \alpha'_i) = 0$$

$$0 \leq \alpha_i \leq C, i = 1, \dots, l$$

$$0 \leq \alpha'_i \leq C, i = 1, \dots, l$$

dimana C didefinisikan oleh user, $K(x_i, x_j)$ adalah *dot-product kernel* yang didefinisikan sebagai $K(x_i, x_j) = \varphi^T(x_i) \varphi(x_j)$. Dengan menggunakan *Lagrange multiplier* dan kondisi optimalitas, fungsi regresi secara eksplisit dirumuskan sebagai:

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha'_i) K(x_i, x) + b, \quad (2.34)$$

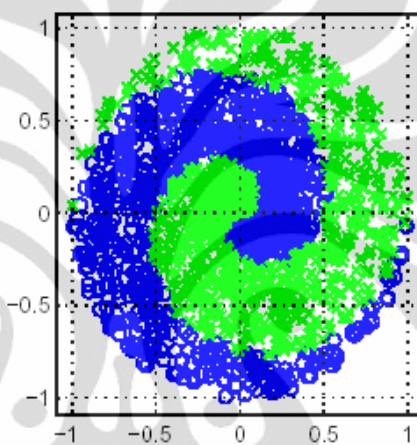
dimana $K(x_i, x)$ didefinisikan melalui fungsi kernel k . Persamaan (2.33) adalah program kuadratik (QP).

2.2.4.1 Metode Kernel

Seperti yang sudah dijelaskan pada sub bab sebelumnya, dikatakan bahwa pada SVR dibutuhkan sebuah metode yang memetakan data kedalam suatu *feature space*. Pemetaan itu dilakukan oleh sebuah metode yaitu metode kernel, atau fungsi kernel.

Secara umum, kasus-kasus di dunia nyata adalah kasus yang tidak linear (Santosa, 2007). Metoda kernel adalah salah satu untuk mengatasinya. Dengan metoda kernel suatu data x di *input space* dimapping ke *feature space* F dengan dimensi yang lebih tinggi melalui *map* φ sebagai berikut $\varphi : x \rightarrow \varphi(x)$. Karena itu data x di *input space* menjadi $\varphi(x)$ di *feature space*.

Sering kali fungsi $\phi(x)$ tidak tersedia atau tidak bisa dihitung, tetapi *dot product* dari dua vektor dapat dihitung baik di dalam *input space* maupun di *feature space*. Dengan kata lain, sementara $\phi(x)$ mungkin tidak diketahui, dot product $\langle \phi(x_1), \phi(x_2) \rangle$ masih bisa dihitung di *feature space*. Untuk bias memakai metoda kernel, pembatas (*constraint*) perlu diekspresikan dalam bentuk *dot product* dari vektor data x_i . Sebagai konsekuensi, pembatas yang menjelaskan permasalahan dalam klasifikasi harus diformulasikan kembali sehingga menjadi bentuk *dot product*.



Gambar 2.5 Data spiral yang menggambarkan ketidaklinearan

Dalam *feature space* ini *dot product* $\langle \cdot, \cdot \rangle$ menjadi $\langle \phi(x), \phi(x') \rangle$. Suatu fungsi kernel, $k(x, x')$, bisa untuk menggantikan *dot product* $\langle \phi(x), \phi(x') \rangle$. Kemudian di *feature space*, kita bisa membuat suatu fungsi pemisah yang linear yang mewakili fungsi non-linear di *input space*. Dalam *input space*, data tidak bisa dipisahkan secara linear, tetapi kita bisa memisahkan di *feature space*. Karena itu dengan memetakan data ke *feature space* menjadikan tugas klasifikasi menjadi lebih mudah.

Fungsi kernel yang biasanya dipakai dalam literatur SVM adalah seperti berikut ini:

- Linear : $x^T x$,
- Polynomial : $(x^T x + 1)^p$,

Fungsi kernel mana yang harus digunakan untuk substitusi *dot product* di *feature space* sangat bergantung pada data. Biasanya metoda *cross-validation* digunakan untuk pemilihan fungsi kernel ini. pemilihan fungsi kernel yang tepat adalah hal yang sangat penting, karena fungsi kernel ini akan menentukan *feature space* di mana kita *set training* akan diklasifikasikan. Sepanjang fungsi kernelnya *legitimate* SVM akan beroperasi secara benar meskipun kita tidak tahu seperti apa *map* yang digunakan. Fungsi kernel yang *legitimate* diberikan oleh teori Mercer dimana fungsi itu harus memenuhi syarat kontinu dan *positive definite*. Lebih mudah menemukan fungsi kernel daripada mencari *map* ϕ seperti apa yang tepat untuk melakukan *mapping* dari input space ke *feature space*.

2.2.5 Langkah-Langkah Peramalan

Dalam melakukan peramalan terdapat beberapa tahapan atau langkah-langkah yang dilakukan. Adapaun tahapan perancangan peramalan secara ringkas terdapat tiga tahapan yang harus dilalui dalam perancangan suatu metode peramalan, yaitu :

1. Melakukan analisa pada data masa lampau. Langkah ini bertujuan untuk mendapatkan gambaran pola dari data bersangkutan.
2. Memilih metode yang akan digunakan. Terdapat bermacam-macam metode yang tersedia dengan keperluannya. Pemilihan metode dapat mempengaruhi hasil ramalan. Hasil ramalan diukur dengan menghitung *error* atau kesalahan terkecil. Oleh karena itu, tidak ada metode peramalan yang pasti baik untuk semua jenis data.
3. Proses transformasi dari data masa lampau dengan menggunakan metode yang dipilih. Apabila diperlukan maka diadakan perubahan sesuai kebutuhannya.

2.2.6 Prinsip Peramalan

Pada dasarnya peramalan merupakan sebuah prediksi yang tentunya tidak memiliki akurasi 100%. Menurut Arnold dan Chapman (2004) terdapat empat karakteristik peramalan. Adapun karakteristik atau prinsip peramalan tersebut adalah sebagai berikut ini:

1. *Peramalan biasanya salah.* Peramalan mencoba untuk melihat masa depan yang belum diketahui dan biasanya salah dalam beberapa asumsi atau perkiraan. Kesalahan (*error*) harus diprediksi dan hal itu tidak dapat dielakan.
2. *Setiap peramalan seharusnya menyertakan estimasi kesalahan (error).* Oleh karena peramalan diprediksikan akan menemui kesalahan, pertanyaan sebenarnya adalah “seberapa besar kesalahan tersebut”. Setiap peramalan seharusnya menyertakan estimasi kesalahan yang dapat diukur sebagai tingkat kepercayaan, dapat berupa persentase (plus atau minus) dari peramalan sebagai rentang nilai minimum dan maksimum.
3. *Peramalan akan lebih akurat untuk kelompok atau grup.* Perilaku dari individual item dalam sebuah grup adalah acak bahkan ketika grup tersebut berada dalam keadaan stabil. Sebagai contoh, meramalkan secara akurat seorang murid dalam suatu kelas lebih sulit daripada meramalkan untuk rata-rata keseluruhan kelas. Dengan kata lain, peramalan lebih akurat untuk dilakukan pada kelompok atau grup daripada individual item.
4. *Peramalan lebih akurat untuk jangka waktu yang lebih dekat.* Peramalan untuk jangka panjang biasanya akan memiliki tingkat kesalahan yang lebih tinggi, dikarenakan tidak diketahui kejadian-kejadian yang akan terjadi dimasa mendatang. Oleh karena itu, lebih baik meramalkan untuk jangka yang lebih pendek dengan melakukan pendekatan situasi yang terjadi pada saat peramalan dilakukan.

2.3 Pengukuran Hasil Peramalan

Seperti yang sudah dijelaskan sebelumnya bahwa tidak ada peramalan yang memiliki tingkat akurasi 100%. Setiap peramalan pasti mengandung kesalahan. Oleh karena itu untuk mengukur sebuah metode peramalan, hal yang diperhitungkan adalah tingkat kesalahan yang terjadi. Semakin kecil kesalahan yang dihasilkan maka semakin baik peramalan tersebut. Berdasarkan Hanke, Reitsch dan Wichern (2001) beberapa cara mengukur *error* dari peramalan adalah sebagai berikut :

1. Rata-rata kuadrat kesalahan (*Mean Square Error = MSE*)

MSE dihitung dengan menjumlahkan kuadrat semua kesalahan peramalan pada setiap periode dan membaginya dengan jumlah periode peramalan. Secara matematis, MSE dirumuskan sebagai berikut:

$$MSE = \frac{\sum_{k=0}^n (A_t - F_t)^2}{n} \quad (2.35)$$

dimana:

A_t = permintaan aktual

F_t = permintaan hasil ramalan

n = jumlah data

2. Rata-rata persentase kesalahan absolute (*Mean Absolute Percentage Error = MAPE*).

MAPE merupakan cara perhitungan dengan melakukan perbandingan presentase perbedaan nilai rata-rata absolut antara nilai peramalan dengan nilai yang sebenarnya terjadi. Secara matematis, MAPE dinyatakan sebagai berikut:

$$MAPE = \left(\frac{1}{n} \right) \sum_{i=1}^n \left| \frac{F_t - A_t}{A_t} \right| \quad (2.36)$$

dimana:

n = jumlah data

F_t = permintaan hasil peramalan

A_t = permintaan aktual

BAB 3


PENGUMPULAN DATA

Pada bab ini akan dijelaskan data apa saja yang dikumpulkan. Adapun data yang dikumpulkan merupakan data sekunder dari berbagai sumber seperti permintaan sparepart, penjualan berbagai jenis barang, dan pengunjung suatu tempat wisata.

3.1 Data Astra Nippon Gasket Indonesia

Data dikumpulkan dari PT. Astra Nippon Gasket Indonesia (ANGI). Perusahaan ini merupakan sebuah perusahaan pemasok sparepart bagi Astra untuk sparepart gasket. Adapun produk utama dari perusahaan ini adalah *cylinder head gasket* dan *exhaust manifold gasket*. Dalam penelitian ini, dipergunakan data permintaan akan produk *exhaust manifold gasket* yang berasal dari tiga perusahaan, yaitu PT. Toyota Astra Motor Manufacturing (TAMM), PT. Astra Daihatsu (AD), dan PT. Toyota Astra Motor Part Centre (TAMPC).

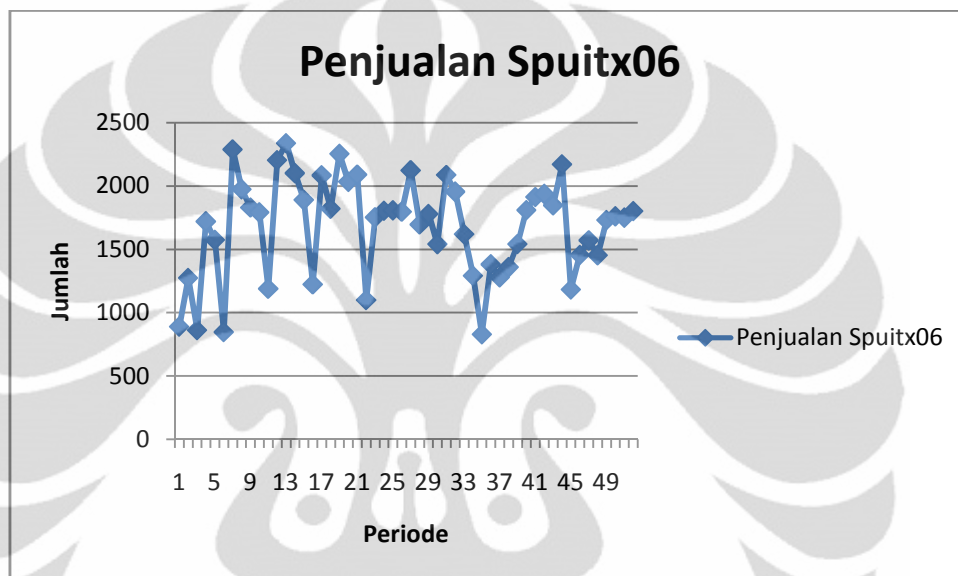
Selanjutnya dijumlahkan permintaan dari ketiga perusahaan tersebut untuk mendapatkan permintaan akan sparepart *exhaust manifold gasket*. Berikut ini adalah data permintaan yang dipergunakan:




Gambar 3.1 Permintaan ANGI

3.2 Data Penjualan Obat

Data selanjutnya yang dikumpulkan adalah data penjualan obat pada sebuah rumah sakit. Dari data penjualan tersebut diambil penjualan untuk dua buah obat selama 52 minggu dari bulan Januari 2009 hingga Desember 2009 dengan mengambil sampel obat yang memiliki dua jenis pola penjualan yang berbeda. Berikut ini adalah data penjualan yang dipergunakan:




Gambar 3.2 Penjualan Spuitx06



Gambar 3.3 Penjualan Rimacc4

3.3 Data Permintaan Pumping Unit


Data yang diambil selanjutnya adalah data permintaan sebuah pumping unit. Kode pumping unit yang dipakai dalam kasus ini adalah C114. Data merupakan data permintaan bulanan selama 44 bulan dari tahun 2008 hingga 2010. Berikut ini adalah data permintaan yang dipakai:



Gambar 3.4 Permintaan Pumping Unit

3.4 Data Penjualan Printer


Data berikutnya yang dipakai adalah data penjualan printer sebuah perusahaan elektronik. Data yang dipergunakan merupakan data penjualan mingguan selama 96 minggu dari bulan April 2008 hingga Maret 2010. Dengan menggunakan data yang banyak, diharapkan dapat terlihat pola data tersebut sehingga nantinya dapat memberikan gambaran yang lebih jelas akan perbedaan metode peramalan yang dipergunakan. Berikut ini adalah data penjualan yang dipergunakan:



Gambar 3.5 Penjualan Printer

3.5 Data Pengunjung Ragunan

Data terakhir yang dipergunakan oleh adalah data pengunjung kebun binatang ragunan. Kebun binatang ragunan merupakan kebun binatang terbesar di Asia Tenggara. Data yang dipergunakan merupakan jumlah data pengunjung bulanan selama dua tahun untuk tahun 2009 dan 2010. Berikut ini adalah data pengunjung ragunan yang dipergunakan:



Gambar 3.6 Pengunjung Ragunan

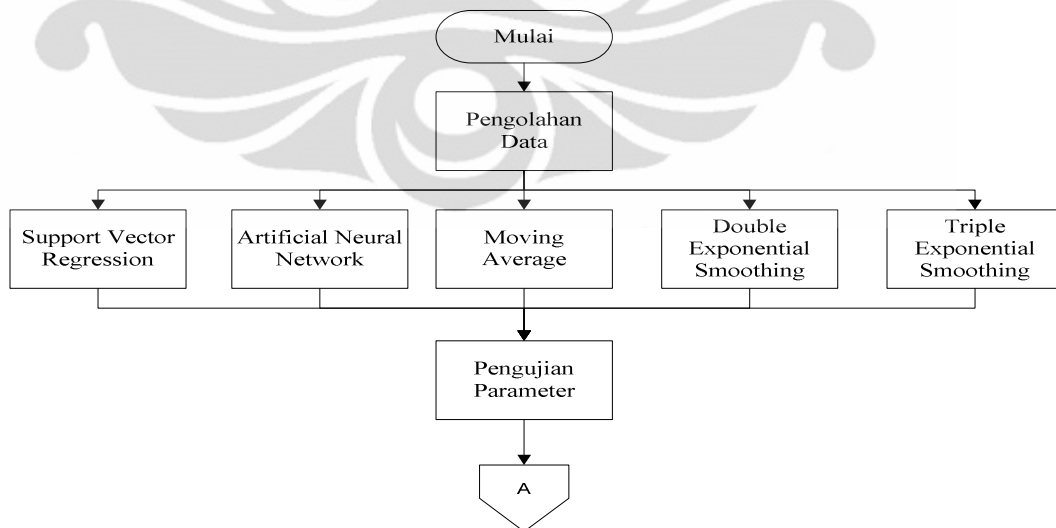
BAB 4

PENGOLAHAN DATA DAN ANALISIS

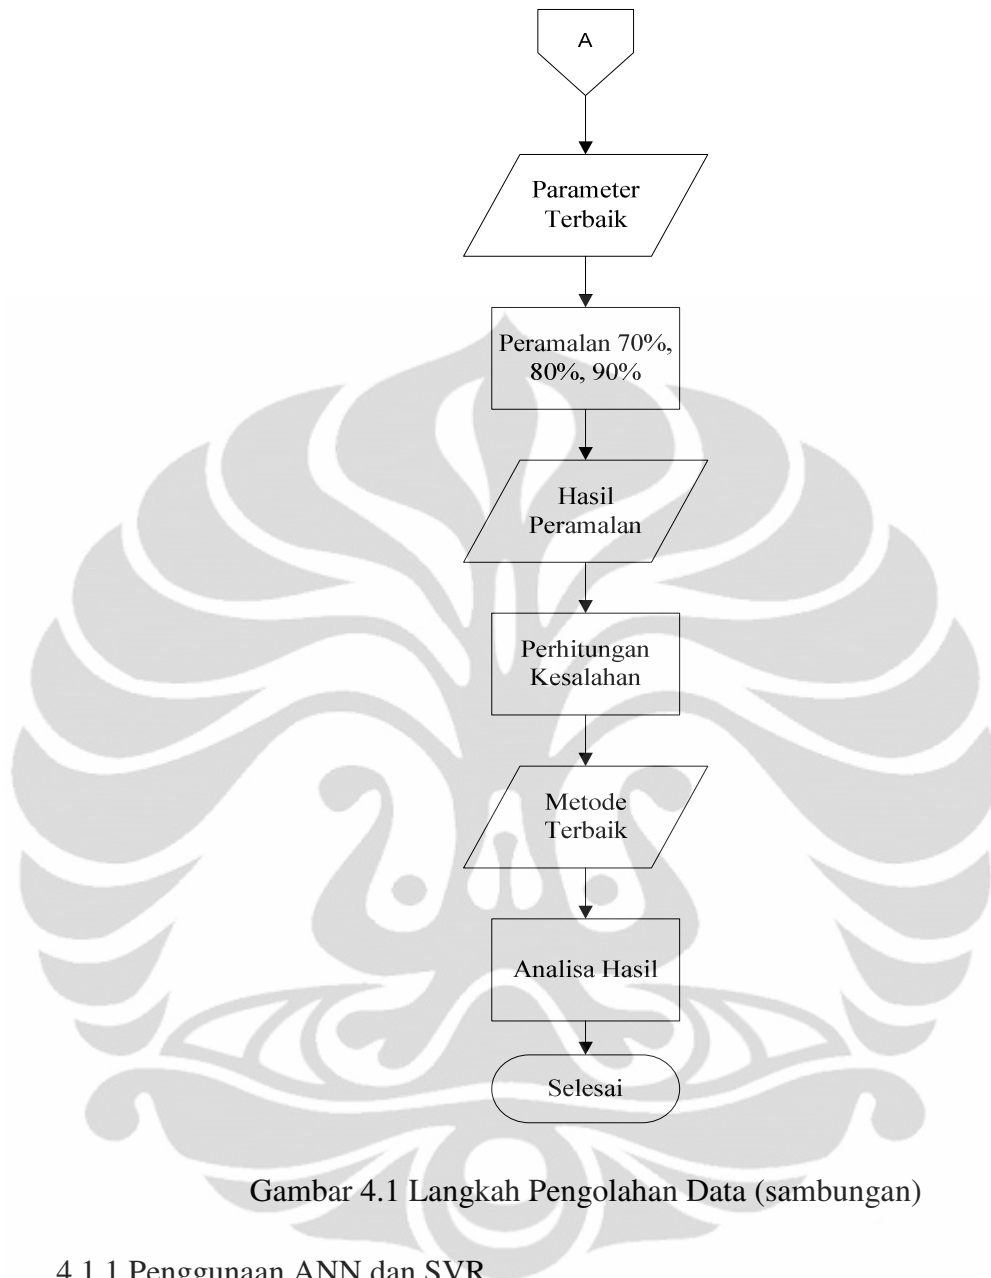
Pada bab ini dijelaskan mengenai cara pengolahan data yang dilakukan dan analisis hasil pengolahan data yang didapatkan. Secara garis besar, terdapat dua pembagian dalam pengolahan data, yaitu pengujian parameter metode peramalan, dan peramalan dengan berbagai jumlah data *training* dan *testing* dengan menggunakan metode yang telah ditentukan beserta perhitungan kesalahannya. Hasil dari kedua pengolahan data tersebut akan dianalisis.

4.1 Pengolahan Data

Seperti yang sudah disebutkan sebelumnya, pengolahan data secara garis besar terbagi menjadi dua bagian, yaitu pengujian parameter dan peramalan dengan metode yang sudah ditentukan. Adapun dalam pengolahan data ini, software yang dipergunakan adalah MATLAB 7.8 untuk metode *Artificial Neural Network* dan *Support Vector Regression* dan MINITAB 14 untuk metode *Moving Average*, *Double Exponential Smoothing* dan *Triple Exponential Smoothing*. Jika digambarkan maka langkah pengolahan data adalah seperti berikut ini:



Gambar 4.1 Langkah Pengolahan Data



Gambar 4.1 Langkah Pengolahan Data (sambungan)

4.1.1 Penggunaan ANN dan SVR

Sebelum menguji parameter akan dijelaskan bagaimana penggunaan metode ANN dan SVR dalam software MATLAB tersebut.

4.1.1.1 Prosedur Penggunaan ANN

Dalam penggunaan ANN di MATLAB kita dapat mempergunakan toolbox atau code yang memang sudah disediakan oleh MATLAB itu sendiri. Dengan begitu akan mempermudah pengerjaan. Pengolahan mempergunakan salah satu jenis *feeding forward* yang dimiliki oleh ANN, yaitu *backpropagasi*.

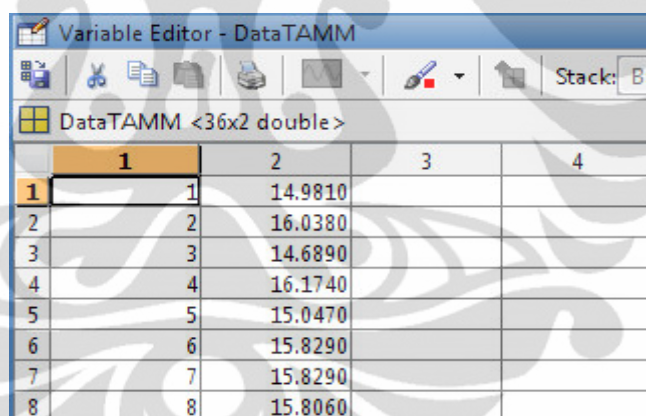
Backpropagasi sendiri sangat bermanfaat dalam penelitian deret waktu dikarenakan kemampuannya dalam melakukan pengenalan pola secara berulang. Berikut ini adalah langkah-langkah penggunaan MATLAB untuk ANN:

- Membuat variabel data
Untuk dapat mempergunakan data yang dimiliki maka kita perlu membuat variabel data yang dikenali oleh MATLAB. Adapun perintahnya adalah sebagai berikut:

```
>> DataANGI=xlsread(filename.xls);
```

Selain menggunakan cara diatas kita juga dapat memasukkan secara manual data kita kedalam variable editor yang tersedia. Hal ini lebih mudah dilakukan apabila kita telah memiliki data yang telah dipersiapkan sebelumnya pada file excel. Dengan begitu data hanya tinggal dimasukkan dengan menyalin dari file excel kedalam variable editor.

Berikut ini adalah gambaran dari variable data yang dikenali matlab:



	1	2	3	4
1	1	14.9810		
2	2	16.0380		
3	3	14.6890		
4	4	16.1740		
5	5	15.0470		
6	6	15.8290		
7	7	15.8290		
8	8	15.8060		

Gambar 4.2 Variable Editor

Dalam kasus deret waktu ini, kolom pertama merupakan periode data, sedangkan kolom kedua merupakan data permintaan/penjualan.

- Membagi data *training* dan *testing*
Data *training* merupakan data yang dipergunakan untuk melakukan pengenalan pola yang nantinya dipakai untuk peramalan. Data *training* memberikan bobot, bias, nilai slope, nilai intercept, dan nilai koefisien korelasi. Data *testing* merupakan data uji yang akan dipakai untuk menghitung hasil ramalan dan kesalahan ramalan. Dalam penelitian ini

dibagi pembagian data *training* dan *testing* menjadi tiga, yaitu 70%-30%, 80%-20% dan 90%-10%, dimana angka awal merupakan jumlah data *training* dan angka kedua merupakan jumlah data yang diramalkan. Berikut ini adalah contoh perintah untuk membagi data tersebut:

```
>>P=DataANGI(1:29,1);
>>T=DataANGI(1:29,2);
>>s=DataANGI(30:36,1);
>>y=DataANGI(30:36,2);
```

dimana P dan T merupakan variabel data *training* sedangkan s dan y merupakan variabel data *testing*. Berdasarkan contoh, kita membuat variabel P,T,s dan y dengan mengambil DataANGI sebagai dasarnya, dimana P dan T mengambil data baris 1 hingga 29, dengan P menggunakan kolom 1, dan T menggunakan kolom 2. Hal serupa juga dilakukan pada variabel s dan y.

- Menormalisasikan data
Agar variabel dapat diolah oleh ANN, maka kita perlu menormalisasikan variabel tersebut sehingga variabel berada dalam range [-1,1]. Selain itu kita perlu merubah vektor dari variabel kita menjadi variabel baris. Berikut ini adalah perintahnya:

```
>>[pn,minp,maxp,tn,mint,maxt]=premnmx(P',T');
>>[an,mina,maxa,sn,mins,maxs]=premnmx(s',y');
```

Perintah pertama berguna untuk membuat variabel-variabel pn, minp, maxp, tn, mint, maxt yang nantinya akan dipergunakan dengan melakukan perintah `premnmx` (normalisasi) variabel P dan T sebagai data *training*. Hal serupa juga dilakukan pada variabel s dan y untuk menormalisasi data *testing*.

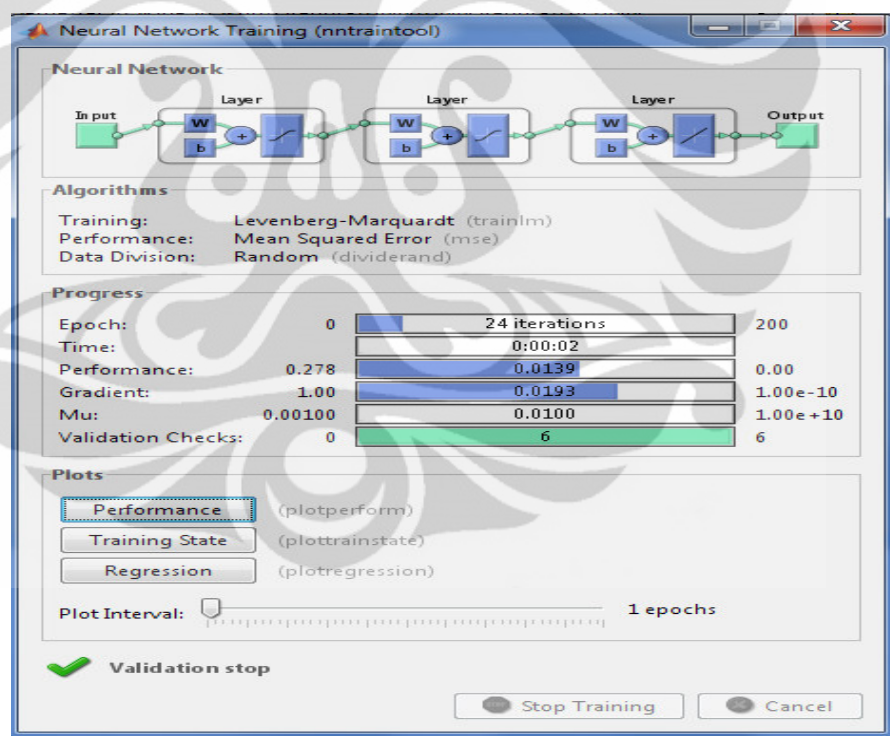
- Memasukkan parameter dan melakukan perhitungan
Dalam ANN terdapat beberapa parameter yang dapat berpengaruh terhadap hasil perhitungan, yaitu jumlah iterasi (epochs), jumlah *hidden neuron*, jumlah *neuron output*, fungsi transfer, fungsi latihan, dan kecepatan pembelajaran. Dalam kasus ini, hanya akan dibedakan penggunaan *hidden neuron*, kecepatan pelatihan dan jumlah maksimum iterasi. Berikut ini contoh untuk memasukkan parameter tersebut:

Universitas Indonesia

```
>>net=newff(minmax(pn),minmax(an),[5 1],{'tansig','tansig'},'trainlm');
>>net.trainParam.epochs=200;
>>net.trainParam.lr=0.3;
>>net=train(net,pn,tn);
```

Perintah pertama berguna untuk melakukan pembelajaran *feeding forward* dengan memasukkan nilai maksimum dan minimum data *training* dan *testing*, jumlah *hidden neuron*, neuron output, fungsi transfer, dan fungsi latih. Perintah kedua adalah untuk memasukkan jumlah maksimum iterasi. Perintah ketiga adalah untuk menentukan kecepatan pembelajaran. Perintah keempat untuk menghasilkan pembaharuan variabel net berdasarkan nilai net yang didapatkan sebelumnya.

Dengan menggunakan langkah diatas maka akan menghasilkan seperti berikut ini:



Gambar 4.3 Neural Network Training Tool

- Mendenormalisasikan data
Data yang dihasilkan setelah melalui proses diatas masih berupa data normalisasi. Oleh karena itu kita harus mendenormalisasikan data tersebut

sehingga memberikan nilai yang sesuai dengan nilai aslinya. Berikut ini adalah perintahnya:

```
>>yt=sim(net,pn);
>>x=postmnmx(yt',mint,maxt);
>>[m,b,r]=postreg(x',T')
>>yt=sim(net,an);
>>x=postmnmx(yt',mins,maxs)
```

Tiga perintah awal adalah untuk melihat hasil nilai slope (m), nilai intercept (r), dan nilai koefisien korelasi yang didapatkan. Sedangkan dua perintah akhir adalah untuk mendapatkan nilai ramalan dimana x merupakan hasil peramalan yang didapatkan.

4.1.1.2 Prosedur Penggunaan SVR

Untuk mempergunakan SVR di MATLAB, tidak bisa secara langsung, dikarenakan MATLAB tidak memberikan toolbox bawaan untuk SVR. Oleh karena itu dipergunakan model SVR yang dibuat oleh Steve Gunn (1998) sebagai dasar untuk membuat model SVR. Setelah membuat matlab code untuk SVR maka kita dapat mempergunakan matlab code yang telah dibuat untuk melakukan peramalan yang diinginkan. Secara garis besar langkah-langkah penggunaan SVR hampir mirip dengan ANN. Berikut ini adalah langkah-langkah penggunaan MATLAB untuk SVR:

- Membuat variabel data
Tahapan ini sama seperti tahapan yang sudah dijelaskan pada penggunaan ANN. Untuk dapat mempergunakan data yang dimiliki maka kita perlu membuat variabel data yang dikenali oleh MATLAB. Adapun perintahnya adalah sebagai berikut:

```
>> DataANGI=xlsread(filename.xls);
```

- Membagi data training dan testing
Sama halnya dengan ANN, SVR juga perlu melakukan pembagian data *training* dan *testing*. Berikut ini adalah perintahnya:

```
>>X=DataTAMM(1:29,1);
```

```
>>Y=DataTAMM(1:29,2);
```

```
>>trnX=X
>>tstX=DataTAMM(30:36,1);
```

dimana X dan Y adalah variabel data *training*, trnX adalah jumlah data *training* dalam kasus ini jumlah data *training* sama dengan variabel *training*, dan tstX adalah jumlah data yang ingin diramalkan atau jumlah data pengujian.

- Memasukkan parameter
Dalam SVR terdapat beberapa parameter yang dapat mempengaruhi hasil dari peramalan. Adapun parameternya adalah *upper bound* (C), *loss function*, *kernel function*, dan parameter untuk kernel itu sendiri (p1 dan p2). Ketika kita mempergunakan *loss function* *einsensitive* maka kita perlu memasukkan parameter sensitifitas (e). Berikut ini adalah contoh perintah untuk memasukkan parameter-parameter tersebut:

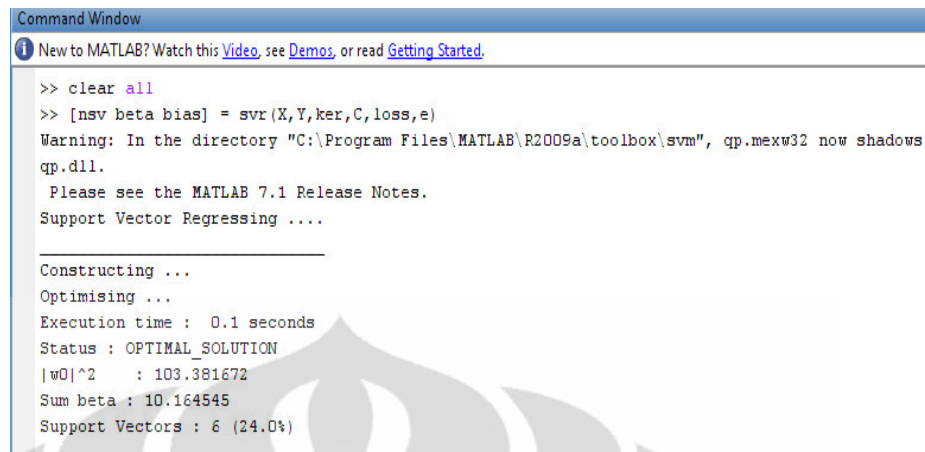
```
>>C=1;
>>loss='einsensitive'
>>ker='linear'
>>p1=1
>>p2=0
>>e=1
```

Fungsi kernel berguna untuk memetakan data kedalam suatu *feature space* yang mana *feature space* itu tidak dapat dihitung secara manual. Hal ini diakibatkan karena tidak diketahuinya data akan dibawa kedalam dimensi berapa.

- Melakukan perhitungan SVR
Selanjutnya adalah melakukan perhitungan dengan mempergunakan model SVR yang telah dibangun. Sebelum mendapatkan hasil akhir kita perlu mencari beta dan bias yang didapatkan berdasarkan data *training*. Berikut ini adalah perintahnya:

```
>>[nsv beta bias] = svr(X,Y,ker,C,loss,e)
```

dan output dari perintah tersebut adalah seperti berikut:



```

Command Window
New to MATLAB? Watch this Video, see Demos, or read Getting Started.

>> clear all
>> [nsv beta bias] = svr(X,Y,ker,C,loss,e)
Warning: In the directory "C:\Program Files\MATLAB\R2009a\toolbox\svm", qp.mexw32 now shadows
qp.dll.
Please see the MATLAB 7.1 Release Notes.
Support Vector Regressing ....

Constructing ...
Optimising ...
Execution time : 0.1 seconds
Status : OPTIMAL_SOLUTION
|w0|^2 : 103.381672
Sum beta : 10.164545
Support Vectors : 6 (24.0%)

```

Gambar 4.4 Perhitungan Beta Bias SVR

Hasil yang didapatkan dari perintah di atas adalah variabel beta dan bias yang akan muncul pada *workspace*. Setelah mendapatkan beta dan bias maka kita dapat mencari output nilai real dari SVR tersebut. Adapun perintahnya adalah seperti berikut ini:

```
>>tstY = svroutput(trnX,tstX,ker,beta,bias)
```

dimana *tstY* merupakan hasil peramalan yang didapatkan.

4.1.2 Pengolahan Data Astra Nippon Gasket Indonesia

Berdasarkan rancangan langkah-langkah penelitian di atas, maka setiap data akan diolah dengan menggunakan lima metode yang sudah disebutkan. Sebelum melakukan peramalan dengan tiga jenis jumlah data *training* perlu dilakukan pengujian parameter untuk menentukan parameter yang akan dipakai. Setelah mendapatkan parameter terbaik, maka kita dapat melakukan peramalan dengan tiga jenis jumlah data *training*.

Pertama dilakukan pengujian parameter untuk kelima metode dengan berbagai kombinasi parameter. Untuk metode ANN, parameter yang diujikan adalah jumlah iterasi, kecepatan pembelajaran, dan *hidden neuron*, dimana jumlah iterasi yang dipergunakan adalah 100 dan 200, kecepatan pembelajaran 0,3 dan 0,7 dan *hidden neuron* 1, 3 dan 5. Untuk metode SVR adalah fungsi kernel, parameter kernel, fungsi loss, sensitifitas dan upperbound. Adapaun fungsi kernel yang digunakan adalah linier dan polynomial dimana untuk kernel linier

parameter kernelnya adalah satu, sedangkan untuk polynomial adalah 1,2 dan 3, fungsi loss kuadratik dan einsensitive, sensitifitas 1 hingga 10 (khusus untuk fungsi loss einsensitive) dan upperbound 1, 10 dan 100. Untuk metode MA adalah penggunaan jumlah data untuk rata-rata bergerak, dimana jumlah ini tergantung data yang digunakan. Untuk data bulanan adalah tiga bulan dan enam bulan, sedangkan untuk mingguan adalah empat minggu dan 12 minggu. Untuk DES adalah angka pemulusan dan untuk TES adalah angka pemulusan dan jumlah musiman yang dipergunakan, dimana pemulusan yang diujikan adalah 0,05, 0,1, 0,15 dan 0,2, sedangkan untuk pola musiman dipergunakan seperti untuk MA. Penggunaan jumlah data *training* dalam pengujian parameter adalah 80%.

Hasil yang ditampilkan merupakan hasil kesimpulan akhir parameter yang akan dipergunakan dimana hasil didapatkan dari perhitungan MSE setiap kombinasi parameter. Berikut ini adalah kelima hasil pengujian parameter dari setiap metode tersebut:


Tabel 4.1 Hasil Pengujian Parameter ANGI

UJI PARAMETER	Metode				
	ANN	SVR	MA	DES	TES
Parameter	Hidden Neuron 1, Maksimum Iterasi 100, Kecepatan Pelatihan 0,3	Fungsi Kernel Poly, Parameter Kernel 1, Fungsi Loss Einsensitive, Upperbound 10, Sensitifitas 9	Rata-rata bergerak tiga bulan	Pemulusan Level 0,2 dan Pemulusan Trend 0,1	Pemulusan Level 0,2, Pemulusan Trend 0,1, Pemulusan Musiman 0,2 dan Pola Musiman 3 Bulan


Untuk melihat hasil pengujian lebih detail dapat melihat pada lampiran 1-6.

Setelah mendapatkan parameter untuk semua metode yang akan dipergunakan, maka selanjutnya adalah melakukan peramalan dengan semua metode tersebut. Seperti yang sudah disebutkan sebelumnya, bahwa peramalan akan dibagi dengan mempergunakan jumlah data *training* yang berbeda. Hal ini dilakukan untuk melihat konsistensi metode peramalan dan melihat kemampuan


metode tersebut dalam melakukan peramalan. Berikut ini adalah hasil ramalan yang dihasilkan untuk penggunaan 70%, 80% dan 90% data *training*:



Gambar 4.5 Grafik Hasil Peramalan 70% ANGI




Gambar 4.6 Grafik Hasil Peramalan 80% ANGI



Gambar 4.7 Grafik Hasil Peramalan 90% ANGI

Setelah mendapatkan hasil peramalan, maka kita dapat menghitung akurasi peramalan. Akurasi dihitung dengan melihat hasil MSE dari peramalan, dimana hasil terkecil menandakan bahwa peramalan semakin baik. Berikut ini adalah hasil perhitungan MSE untuk setiap metode dengan berbagai jumlah data *training*:



Gambar 4.8 Grafik MSE Peramalan ANGI

4.1.3 Pengolahan Data Penjualan Obat

Seperti yang sudah disebutkan pada bab 3, untuk data penjualan obat akan dibagi menjadi dua, yaitu penjualan obat dengan kode spuitx06 dan rimacc4. Kedua pola penjualan obat ini memiliki pola yang sangat berbeda, dimana

sputix06 memiliki pola penjualan yang stabil sedangkan rimacc4 memiliki pola yang variatif dimana penjualan tidak selalu terjadi setiap minggunya.

4.1.3.1 Pengolahan Data Penjualan Spuitx06

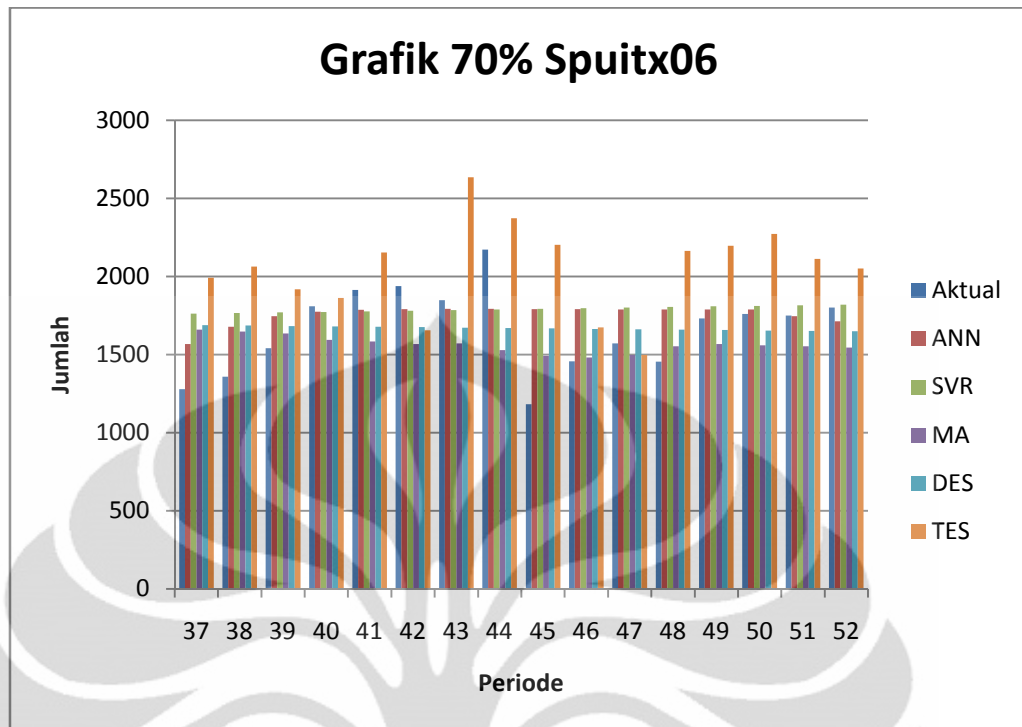
Sama seperti yang dilakukan pada data sebelumnya, dilakukan pengujian parameter untuk data penjualan spuitx06. Hal ini dilakukan untuk mendapatkan parameter-parameter terbaik untuk data spuitx06 ini. Berikut ini adalah hasil pengujian parameter yang dilakukan:

Tabel 4.2 Hasil Pengujian Parameter Spuitx06


UJI PARAMETER	Metode				
	ANN	SVR	MA	DES	TES
Parameter	<i>Hidden Neuoron</i> 1, Maksimum Iterasi 200, Kecepatan Pelatihan 0,7	Fungsi Kernel Linier, Parameter Kernel 1, Fungsi Loss Kuadratik, Upperbound 1, Sensitifitas 1	Rata-rata bergerak 12 minggu	Pemulusan Level 0,1 dan Pemulusan Trend 0,05	Pemulusan Level 0,1, Pemulusan Trend 0,05, Pemulusan Musiman 0,2 dan Pola Musiman 12 minggu

Untuk melihat hasil pengujian lebih detail dapat melihat lampiran 7-11.


Setelah semua parameter didapatkan maka kita dapat melakukan peramalan. Peramalan akan dilakukan sama seperti ANGI yaitu dengan membagi menjadi penggunaan tiga jenis jumlah data *training*. Hasil dari peramalan tersebut dapat dilihat pada gambar 4.9, 4.10 dan 4.11. Setelah mendapatkan hasil ramalan tersebut, maka kita dapat menghitung akurasi dengan melihat hasil MSE yang dihasilkan. Hasil dari perhitungan MSE dapat dilihat pada gambar 4.12




Gambar 4.9 Grafik Hasil Peramalan 70% Spuitx06



Gambar 4.10 Grafik Hasil Peramalan 80% Spuitx06



Gambar 4.11 Grafik Hasil Peramalan 90% Spuitx06



Gambar 4.12 Grafik MSE Peramalan Spuitx06

4.1.3.2 Pengolahan Data Penjualan Rimacc4

Pengolahan data penjualan rimacc4 dilakukan sama seperti dengan spuitx06. Pertama adalah pengujian parameter, lalu selanjutnya adalah melakukan peramalan dengan tiga jenis jumlah data *training* dan yang terakhir adalah


menghitung akurasi atau kesalahan. Berikut adalah hasil pengujian parameter rimacc 4:

Tabel 4.3 Hasil Pengujian Parameter Rimacc4


UJI PARAMETER	Metode				
	ANN	SVR	MA	DES	TES
Parameter	Hidden Neuron 1, Maksimum Iterasi 200, Kecepatan Pelatihan 0,3	Fungsi Kernel Poly, Parameter Kernel 1, Fungsi Loss Kuadratik, Upperbound 1, Sensitifitas 1	Rata-rata bergerak 4 minggu	Pemulusan Level 0,05 dan Pemulusan Trend 0,2	Pemulusan Level 0,05, Pemulusan Trend 0,2, Pemulusan Musiman 0,1 dan Pola Musiman 12 minggu

Untuk melihat lebih detail hasil pengujian dapat melihat lampiran 12-16.


Setelah mendapatkan semua parameter terbaik untuk setiap metode, maka selanjutnya adalah melakukan peramalan dengan berbagai jenis jumlah data *training*. Berikut ini adalah hasil peramalan untuk data penjualan rimacc4 dengan penggunaan data training 70%, 80% dan 90%:



Gambar 4.13 Grafik Hasil Peramalan 70% Rimacc4




Gambar 4.14 Grafik Hasil Peramalan 80% Rimacc4



Gambar 4.15 Grafik Hasil Peramalan 90% Rimacc4

Setelah mendapatkan peramalan untuk ketiga jumlah data *training* maka kita dapat menghitung tingkat akurasi untuk ketiganya. Hasil dari perhitungan MSE dapat dilihat pada gambar 4.16.



Gambar 4.16 Grafik MSE Peramalan Rimacc4

4.1.4 Pengolahan Data Permintaan Pumping Unit


Data selanjutnya yang diolah adalah data permintaan pumping unit pada sebuah perusahaan minyak. Dalam mengolah data ini, diperlakukan hal yang serupa seperti sebelumnya. Berikut ini adalah hasil pengujian parameter dari data permintaan pumping unit C114:

Tabel 4.4 Hasil Pengujian Parameter C114


UJI PARAMETER	Metode				
	ANN	SVR	MA	DES	TES
Parameter	Hidden Neuron 1, Maksimum Iterasi 100, Kecepatan Pelatihan 0,7	Fungsi Kernel Poly, Parameter Kernel 2, Fungsi Loss Kuadratik, Upperbound 1, Sensitifitas 1	Rata-rata bergerak enam bulan	Pemulusan Level 0,2 dan Pemulusan Trend 0,1	Pemulusan Level 0,2, Pemulusan Trend 0,1, Pemulusan Musiman 0,05 dan Pola Musiman 3 Bulan

Untuk melihat lebih detail hasil pengujian, dapat melihat lampiran 17-21.

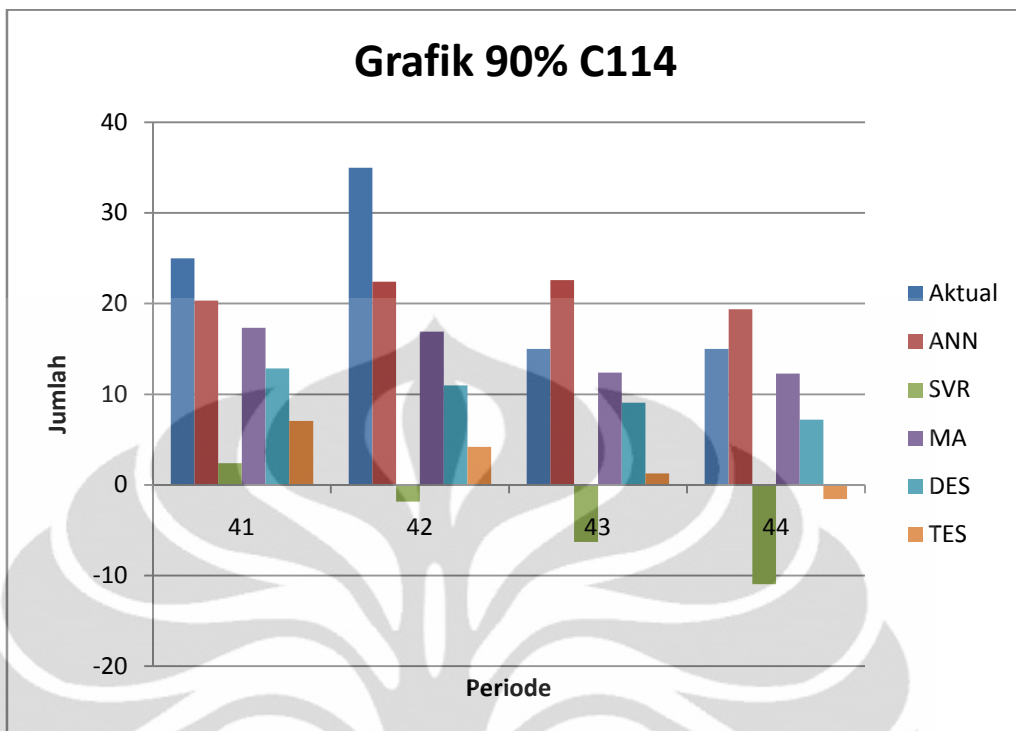
Dengan mendapatkan semua parameter tersebut, maka dapat dilakukan peramalan. Peramalan akan dilakukan dengan membagi tiga jumlah data *training*. Berikut ini adalah hasil peramalan untuk data permintaan pumping unit C114:



Gambar 4.17 Grafik Hasil Peramalan 70% C114




Gambar 4.18 Grafik Hasil Peramalan 80% C114



Gambar 4.19 Grafik Hasil Peramalan 90% C114

Dari hasil peramalan yang telah didapatkan maka kita dapat menghitung tingkat kesalahan dengan mempergunakan perhitungan MSE. Berikut ini adalah hasil perhitungan MSE yang didapatkan dari ketiga hasil peramalan diatas:



Gambar 4.20 Grafik MSE Peramalan C114

4.1.5 Pengolahan Data Penjualan Printer

Pengolahan data selanjutnya adalah pengolahan data penjualan printer. Data penjualan printer cukup banyak, yaitu selama 96 periode. Data yang dipergunakan adalah data penjualan mingguan. Tahapan pertama yang dilakukan dalam pengolahan data ini sama seperti yang lain, yaitu pengujian parameter. Berikut ini adalah hasil pengujian parameter ANN untuk data ini:


Tabel 4.5 Hasil Pengujian Parameter Printer

UJI PARAMETER	Metode				
	ANN	SVR	MA	DES	TES
Parameter	Hidden Neuron 1, Maksimum Iterasi 100, Kecepatan Pelatihan 0,3	Fungsi Kernel Poly, Parameter Kernel 1, Fungsi Loss Einsensitive, Upperbound 10, Sensitifitas 6	Rata-rata bergerak 12 minggu	Pemulusan Level 0,05 dan Pemulusan Trend 0,05	Pemulusan Level 0,05, Pemulusan Trend 0,05, Pemulusan Musiman 0,2 dan Pola Musiman 4 minggu


Untuk melihat lebih detail hasil pengujian dapat melihat lampiran 22-27.

Setelah semua parameter didapatkan untuk data ini, maka kita dapat melakukan peramalan. Hasil dari peramalan dengan tiga jumlah data *training* yang berbeda dapat dilihat pada gambar 4.21, gambar 4.22 dan gambar 4.23. Pada gambar tersebut dapat terlihat perbedaan jumlah data *training* dan pengaruhnya pada hasil peramalan. Selain itu dapat dilihat pula hasil perbedaan hasil peramalan yang dihasilkan oleh setiap metode peramalan.


Pada gambar 4.24 dapat terlihat hasil perhitungan MSE yang didapatkan dari setiap metode pada tiga jumlah data *training*. Dari gambar tersebut dapat dilihat metode mana yang memberikan MSE terkecil pada setiap jumlah data *training*.




Gambar 4.21 Grafik Hasil Peramalan 70% Printer



Gambar 4.22 Grafik Hasil Peramalan 80% Printer



Gambar 4.23 Grafik Hasil Peramalan 90% Printer



Gambar 4.24 Grafik MSE Peramalan Printer

4.1.6 Pengolahan Data Pengunjung Ragunan

Pengolahan data yang terakhir adalah pengolahan data untuk pengunjung ragunan. Data yang dipergunakan adalah data pengunjung bulanan selama dua tahun. Data pengunjung ragunan merupakan data yang mempunyai pola tertentu dimana ketika hari libur pengunjung ragunan akan mengalami peningkatan.


Dalam melakukan pengolahan data ini hal serupa dilakukan seperti apa yang telah dilakukan pada data lainnya. Berikut ini adalah hasil dari pengujian parameter dari data pengunjung ragunan:

Tabel 4.6 Hasil Pengujian Parameter Ragunan


UJI PARAMETER	Metode				
	ANN	SVR	MA	DES	TES
Parameter	<i>Hidden Neuron</i> 5, Maksimum Iterasi 100, Kecepatan Pelatihan 0,7	Fungsi Kernel Poly, Parameter Kernel 1, Fungsi Loss Kuadratik, Upperbound 1, Sensitifitas 1	Rata-rata bergerak tiga bulan	Pemulusan Level 0,05 dan Pemulusan Trend 0,2	Pemulusan Level 0,05, Pemulusan Trend 0,2, Pemulusan Musiman 0,1 dan Pola Musiman 6 Bulan

Untuk melihat hasil pengujian lebih detail dapat melihat lampiran 28-32.


Selanjutnya dilakukan peramalan dengan hasil parameter yang didapatkan. Berikut ini adalah hasil peramalan dari data pengunjung ragunan:



Gambar 4.25 Grafik Hasil Peramalan 70% Ragunan




Gambar 4.26 Grafik Hasil Peramalan 80% Ragunan



Gambar 4.27 Grafik Hasil Peramalan 90% Ragunan

Setelah mendapatkan hasil peramalan, maka kita dapat menghitung MSE dari hasil peramalan yang telah kita lakukan. Hasil perhitungan MSE peramalan dapat dilihat pada gambar 4.28.



Gambar 4.28 Grafik MSE Peramalan Ragunan

4.2 Analisis

Analisis dibagi menjadi dua bagian, yaitu analisis penggunaan parameter metode ANN dan SVR, dan analisis hasil peramalan.

4.2.1 Analisis Parameter

Analisis parameter akan dilakukan untuk parameter ANN dan SVR sebagai sebuah metode yang baru digunakan. Analisis parameter akan memberikan alasan dan gambaran mengapa dipergunakan parameter tersebut serta hasil peramalan yang dihasilkan oleh penggunaan parameter tersebut.

4.2.1.1 Analisis Parameter ANN

Seperti yang sudah dituliskan sebelumnya, bahwa parameter yang berpengaruh pada penggunaan ANN adalah fungsi transfer, fungsi latihan, jumlah iterasi, kecepatan pembelajaran dan jumlah *hidden neuron*. Dalam pengujian parameter ANN, dipergunakan fungsi transfer tansig, dikarenakan fungsi transfer ini cocok untuk data yang memiliki persebaran data yang tidak linier. Sedangkan penggunaan fungsi latihan trainlm dipilih karena fungsi latihan ini memiliki kelebihan dalam membaca pola dimana kemampuan ini tidak dipengaruhi oleh momentum seperti fungsi latihan traindm.

Sedangkan pemilihan parameter untuk *hidden neuron*, jumlah iterasi dan kecepatan pembelajaran dipilih secara acak. Hal ini dikarenakan pemilihan parameter diatas sangat tergantung oleh data (Santosa, 2007). Oleh karena itu perlu dilakukan uji *trial and error* untuk parameter tersebut.

Berdasarkan pengujian parameter ANN untuk keenam data, didapatkan bahwa kombinasi parameter dapat mempengaruhi hasil akhir. Lebih detail dapat dilihat pada bagian lampiran pengujian parameter. Hal ini menandakan bahwa pemilihan parameter sebelum melakukan peramalan sangatlah penting, dikarenakan penggunaan parameter yang tepat akan memberikan hasil peramalan yang semakin baik.

Jika dilihat lebih jauh dari keenam data, lima data dengan penggunaan *hidden neuron 1* memberikan hasil yang lebih memuaskan dibandingkan penggunaan *hiddne neuron* lainnya. Hal ini mungkin diakibatkan semakin banyak *hidden layer* maka pembobotan yang diberikan akan semakin jauh. *Hidden layer* akan menentukan berapa kali dilakukan pembaharuan pembobotan sebelum menghasilkan *ouput*. Hal ini tentunya tidak diinginkan, karena pemberian bobot yang salah akan mengakibatkan hasil pembelajaran yang salah dan mengakibatkan peramalan yang tidak tepat.

Selain *hidden neuron*, jumlah iterasi juga memiliki pengaruh. Pemilihan jumlah iterasi akan mempengaruhi performansi dari neural network (Santosa, 2007). Perlu dicari jumlah iterasi yang meminimumkan kesalahan. Dalam kasus ini dipergunakan dua jumlah iterasi, yaitu 100 dan 200. Pemilihan ini dilakukan secara acak. Berdasarkan penelitian, rata-rata iterasi yang terjadi adalah 50-100. Hal inilah yang mengakibatkan jumlah iterasi 100 lebih sering memberikan hasil yang lebih memuaskan.

Untuk penggunaan kecepatan pembelajaran, dapat dilihat bahwa penggunaan kecepatan pembelajaran tidak terlalu berpengaruh. Hal ini dikarenakan kecepatan pembelajaran hanya mempengaruhi seberapa cepat ANN mempelajari suatu data dan menghasilkan outputnya, apalagi jumlah *hidden layer* yang paling sering dipergunakan dan menghasilkan nilai terbaik hanyalah 1.

4.2.1.2 Analisis Parameter SVR

Pada metode SVR, parameter yang diujikan adalah penggunaan fungsi kernel beserta parameter kernelnya, fungsi loss, dan *upperbound*. Penelitian mempergunakan dua jenis fungsi kernel, yaitu linier dan polynomial. Fungsi kernel tersebut merupakan fungsi kernel yang paling umum dipergunakan, dan memiliki perbedaan satu sama lain yang sangat mendasar, yaitu fungsi kernel linier memetakan data secara linier (garis lurus), sedangkan polynomial akan memetakan data secara tersebar (poly). Untuk fungsi kernel linier, fungsi ini tidak terpengaruh akan penggunaan parameter kernel, sedangkan untuk fungsi kernel polynomial, fungsi ini terpengaruh oleh penggunaan parameter kernel, seperti apa yang telah dituliskan pada sub bab metode kernel pada bab landasan teori.

Selanjutnya berdasarkan pengujian dengan penggunaan fungsi kernel linier, *upperbound* tidak berpengaruh. Hal ini dikarenakan pengaruh yang diberikan *upperbound* sangatlah kecil. Hal ini dapat dilihat pada bagian lampiran pengujian parameter SVR. Oleh karena itu ketika menggunakan fungsi kernel linier, kita dapat mempergunakan *upperbound* berapapun. Hal berbeda terjadi ketika *upperbound* dikombinasikan dengan fungsi kernel polynomial, penggunaan *upperbound* akan mempengaruhi hasil peramalan yang diberikan. Hal ini dikarenakan dengan mempergunakan fungsi kernel poly, persebaran data akan lebih banyak sehingga pembatasan dan penalti yang diberikan *upperbound* akan berpengaruh.

Parameter lain yang perlu diperhatikan adalah penggunaan fungsi loss. Fungsi loss kuadrat akan memberikan batas persebaran data dari fungsi tujuan secara kuadrat, sedangkan dengan penggunaan fungsi *einsensitive*, pembatasan dilakukan tergantung dengan sensitifitas yang dipergunakan. Berdasarkan pengujian, ketika fungsi loss digabungkan dengan fungsi linier, hasil peramalan yang diberikan hanya sedikit mengalami perubahan berapapun *upperbound* yang digunakan, namun ketika fungsi loss ini digabungkan dengan fungsi polynomial, hasil peramalan mengalami perubahan tergantung dengan *upperbound* yang dipakai.

Berdasarkan pengujian parameter pada enam jenis data, didapatkan hasil parameter yang berbeda-beda. Hal ini diakibatkan jenis persebaran data. Dapat dilihat bahwa ketika data memiliki persebaran data dan perubahan yang relatif kecil, contohnya adalah data penjualan printer, maka fungsi kernel yang memberikan hasil terbaik adalah linier. Namun ketika data memiliki persebaran dan perubahan yang relatif variatif, maka fungsi kernel yang cocok digunakan adalah polynomial.

4.2.2 Analisis Hasil Peramalan


Analisis dilakukan berdasarkan hasil MSE peramalan yang didapatkan. Analisis pertama yang dilakukan adalah analisis hasil peramalan ANGI. Berikut ini detail hasil MSE peramalan ANGI:

Tabel 4.7 MSE Peramalan ANGI

Jumlah Data Training		Metode				
		ANN	SVR	MA	DES	TES
25	MSE	1,04,E+07	1,63,E+07	4,19,E+07	7,54,E+07	4,69,E+07
29	MSE	8,27,E+06	3,83,E+07	1,35,E+07	1,91,E+07	1,69,E+07
32	MSE	2,19,E+06	4,45,E+06	1,97,E+07	2,81,E+07	4,22,E+07

Jika melihat gambar 4.8 dan tabel 4.7 dapat dilihat bahwa hasil peramalan yang memberikan nilai MSE terbaik untuk data ANGI adalah dengan menggunakan metode ANN. Dari penggunaan tiga jumlah data *training* ANN selalu memberikan nilai yang terbaik. Hal ini menandakan bahwa ANN secara konsisten dapat memberikan hasil ramalan yang lebih baik dibandingkan metode lainnya, walaupun penggunaan jumlah data *training* yang berbeda-beda.

Untuk melihat mengapa ANN memberikan hasil yang lebih baik dibandingkan yang lain, kita perlu melihat bagaimana persebaran data pada data ANGI ini. Berikut ini adalah gambaran persebaran data ANGI:



Gambar 4.29 Pola Permintaan ANGI

Dapat dilihat bahwa data ANGI memiliki trend yang cenderung naik dengan persebaran data yang tidak terlalu fluktuatif. Hal ini menandakan bahwa ANN berhasil membaca pola data ANGI yang memiliki trend naik namun tidak terlalu tersebar tersebut dan menerjemahkannya untuk melakukan peramalan periode-periode berikutnya.


Selain itu dapat dilihat juga bahwa penggunaan jumlah data *training* akan memberikan hasil kesalahan ramalan yang berbeda. Ketika menggunakan 25 data *training* ANN memberikan hasil terbaik dan kedua adalah SVR. Ketika menggunakan 29 data *training* ANN tetap memberikan hasil terbaik, namun tingkat kesalahan yang dilakukan berkurang, dan kedua adalah metode MA. Ketika menggunakan 32 data *training* ANN tetap memberikan hasil terbaik, dengan tingkat kesalahan yang semakin berkurang dan kedua adalah SVR. Hal ini menandakan bahwa semakin banyak data *training* yang dipergunakan maka ANN akan memberikan hasil yang semakin baik. Perlu diperhatikan juga bahwa SVR mengalami akurasi yang cukup memuaskan dibandingkan dengan metode yang lainnya, dimana ketika penggunaan data *training* 25 dan 32 SVR memberikan hasil yang lebih memuaskan dibandingkan dengan metode lainnya.

Untuk lebih membuktikan kemampuan peramalan ANN dan SVR maka diujikan dengan menggunakan data lainnya. Berikut ini adalah hasil pengujian pada data penjualan obat spuitx06:

Tabel 4.8 MSE Peramalan Spuitx06

Jumlah Data Training		Metode				
		ANN	SVR	MA	DES	TES
36	MSE	6,66,E+04	8,26,E+04	8,14,E+04	6,86,E+04	2,64,E+05
42	MSE	6,61,E+04	6,97,E+04	6,72,E+04	6,67,E+04	1,49,E+05
47	MSE	1,01,E+04	1,54,E+04	1,11,E+04	2,24,E+04	3,84,E+04

Jika melihat tabel diatas, dapat dilihat bahwa metode ANN kembali memberikan hasil yang terbaik dalam melakukan peramalan. Dari penggunaan tiga jumlah data *training* ANN tetap memberikan hasil peramalan terbaik dibandingkan metode lain. Untuk dapat menganalisa lebih dalam, ada baiknya kita melihat pola penjualan spuitx06 ini:



Gambar 4.30 Pola Penjualan Spuitx06

Dari gambar diatas dapat dilihat bahwa pola penjualan spuitx06 tidak memiliki trend. Dapat dikatakan bahwa pola penjualan data ini sangatlah acak. Walaupun dengan pola data yang acak, ANN tetap memberikan hasil yang lebih baik dibandingkan metode yang lain. Hal ini semakin membuktikan kemampuan ANN dalam melakukan peramalan. Selain itu semakin sedikit jumlah data yang akan diramalkan maka semakin baik hasil peramalan yang diberikan. Hal ini terlihat dari berkurangnya kesalahan seiring dengan bertambahnya jumlah data *training* dan berkurangnya data *testing*.

Sedangkan untuk metode SVR, hasil yang didapatkan untuk data ini tidaklah memuaskan. Hal ini diakibatkan kemampuan SVR yang terbatas dalam membaca data. SVR hanya dapat membaca pola secara linier. Oleh karena itulah dengan data yang acak ini, SVR tidak dapat memberikan hasil peramalan yang memuaskan.

Selanjutnya adalah menganalisa hasil peramalan data penjualan obat rimacc4. Berikut ini adalah hasil MSE peramalan penjualan obat rimacc4:


Tabel 4.9 MSE Peramalan rimacc4

Jumlah Data Training		Metode				
		ANN	SVR	MA	DES	TES
36	MSE	2,70,E+02	2,72,E+02	2,77,E+02	2,93,E+02	5,06,E+02
42	MSE	2,65,E+02	3,15,E+02	3,11,E+02	3,08,E+02	5,13,E+02
47	MSE	2,37,E+02	2,52,E+02	2,77,E+02	2,53,E+02	3,37,E+02

Hasil yang diperoleh adalah metode ANN memberikan hasil peramalan yang paling baik. Untuk dapat menganalisa lebih dalam, marilah kita liat pola data dari penjualan obat rimacc4 yang dapat dilihat pada gambar 4.31.

Dapat dilihat pada gambar 4.31 bahwa penjualan obat rimacc4 ini tidaklah selalu terjadi dalam setiap minggu. Hal ini dapat berakibat pembacaan pola data yang sulit sehingga akan mempersulit dalam melakukan peramalan. Dengan kondisi seperti ini, terdapat kemungkinan bahwa data ini memiliki standar deviasi

penjualan yang lebih besar dibandingkan dengan rata-rata penjualan yang terjadi. Hal ini dapat mengakibatkan data dikategorikan data *lumpy*. Untuk itu diujikan apakah data termasuk dalam data *lumpy* atau tidak. Setelah dihitung, data ini memiliki standar deviasi sebesar 18,7 sedangkan rata-rata penjualan sebesar 9,1. Dengan begitu data ini dapat dikatakan merupakan data *lumpy*.



Gambar 4.31 Pola Penjualan Rimacc4


Setelah mendapatkan fakta bahwa data penjualan rimacc4 adalah data *lumpy* dan ternyata menurut tabel 4.9 hasil peramalan yang paling baik untuk data ini adalah metode ANN. Untuk lebih memastikan kemampuan ANN dalam melakukan peramalan data *lumpy* dilakukan pengujian untuk data *lumpy* lainnya. Data yang dipergunakan adalah data penjualan obat yang juga merupakan data *lumpy*. Hasil pengujian dapat dilihat pada lampiran 33 sedangkan data yang digunakan dapat dilihat pada lampiran 34. Hasil menunjukkan bahwa pada data *lumpy*, metode ANN memberikan hasil terbaik. Hal ini semakin menguatkan bahwa metode ANN ini memiliki kemampuan peramalan yang sangat baik dan bahkan dapat digunakan untuk jenis data *lumpy*

Data selanjutnya yang akan dianalisa adalah data permintaan pumping unit C114. Hasil MSE Peramalan C114 dapat dilihat pada tebl 4.10:

Tabel 4.10 MSE Peramalan C114

Jumlah Data Training		Metode				
		ANN	SVR	MA	DES	TES
31	MSE	1,96,E+02	2,20,E+02	5,41,E+02	6,62,E+02	6,64,E+02
35	MSE	1,28,E+02	6,17,E+02	1,36,E+02	1,48,E+02	1,51,E+02
40	MSE	6,43,E+01	7,49,E+02	1,00,E+02	2,06,E+02	4,34,E+02

Didapatkan bahwa hasil peramalan dengan metode ANN memberikan hasil peramalan yang paling baik dibandingkan dengan yang lainnya. Terlihat juga bahwa semakin sedikit data yang akan diramalkan maka ANN akan memberikan hasil MSE yang lebih baik. Hal ini juga terjadi pada hampir semua metode yang lainnya. Sedangkan pada metode SVR justru terjadi kebalikannya. Untuk menganalisa lebih dalam, maka perlu dilihat pola data dari permintaan C114. Berikut ini adalah pola permintaan tersebut:



Gambar 4.32 Pola Permintaan C114

Jika dilihat pola permintaan C114 memiliki pola yang cukup acak. Pola data ini mirip dengan pola data spuitx06. Dengan melihat pola data ini, dan dengan yang hasil yang didapatkan, semakin menguatkan bahwa metode ANN memberikan hasil yang paling baik untuk data yang memiliki pola acak dan fluktuatif. Sedangkan untuk SVR, didapatkan bahwa SVR tidak memberikan hasil yang


memuaskan untuk data ini. Hal ini semakin menguatkan bahwa SVR memiliki pola yang linier dalam membaca data dan meramalkannya.

Berikutnya adalah menganalisis hasil peramalan dari data penjualan printer. Berikut ini adalah hasil perhitungan MSE peramalan tersebut:

Tabel 4.11 MSE Peramalan Printer

Jumlah Data Training		Metode				
		ANN	SVR	MA	DES	TES
67	MSE	6,38,E+08	2,56,E+07	3,65,E+07	2,62,E+07	3,75,E+07
77	MSE	3,72,E+07	2,48,E+07	2,77,E+07	3,35,E+07	2,50,E+07
86	MSE	2,34,E+07	8,51,E+06	1,10,E+07	1,96,E+07	2,29,E+07

Didapatkan bahwa metode peramalan yang memberikan hasil terbaik adalah metode SVR. Hasil peramalan metode ini semakin baik seiring bertambahnya jumlah data *training*. Untuk dapat menganalisa mengapa SVR menghasilkan peramalan yang lebih baik dibandingkan ANN, kita perlu melihat jenis pola data penjualan printer ini. Berikut ini adalah pola datanya:



Gambar 4.33 Pola Penjualan Printer

Dilihat dari gambar diatas data penjualan printer ini memiliki pola trend turun, dimana persebaran data mendekati dengan garis linier trend. Hal ini menandakan bahwa persebaran data berada pada garis linier.

Sesuai dengan apa yang sudah disebutkan sebelumnya metode SVR sangat cocok untuk data yang memiliki pola trend dan persebaran data mendekati garis trend. Hal inilah yang menyebabkan metode SVR ini menghasilkan MSE terkecil pada data ini.


Analisis yang terakhir adalah analisis hasil peramalan data pengunjung ragunan. Berikut ini adalah MSE peramalan pengunjung ragunan:

Tabel 4.12 MSE Peramalan Ragunan

Jumlah Data Training		Metode				
		ANN	SVR	MA	DES	TES
17	MSE	4,53,E+10	4,23,E+10	5,12,E+10	4,25,E+10	2,03,E+10
19	MSE	5,72,E+10	5,92,E+10	5,89,E+10	5,94,E+10	1,81,E+10
21	MSE	5,11,E+09	1,79,E+10	3,32,E+10	1,46,E+10	4,13,E+09

Didapatkan bahwa metode peramalan terbaik yang diperoleh adalah menggunakan metode TES dengan peringkat kedua adalah ANN. Metode TES sangatlah cocok dipergunakan untuk meramalkan data yang memiliki pola musiman. Untuk dapat memahami lebih dalam hasil ini, maka kita perlu melihat pola data pengunjung ragunan tersebut. Pola data dapat dilihat pada gambar 4.34.

Jika dilihat berdasarkan gambar 4.34, ternyata data ini memiliki pola musiman. Hal ini sesuai dengan kenyataan bahwa pengunjung ragunan akan meningkat secara drastis dikala musim liburan, yaitu pada periode 1, 7, 13, dan 19. Dengan melihat kondisi seperti ini, sangatlah wajar apabila metode TES akan memberikan hasil yang paling baik. Namun jika diperhatikan kembali, metode kedua terbaik untuk data ini adalah metode ANN. Hal ini menandakan bahwa ANN sebenarnya sudah dapat membaca pola tersebut, hanya saja tidak lebih baik dibandingkan hasil pembacaan pola yang dilakukan TES.



Gambar 4.34 Pola Pengunjung Ragunan

BAB 5

KESIMPULAN

Sesuai dengan tujuan penelitian dan berdasarkan hasil pengolahan data, berikut ini adalah kesimpulan yang dihasilkan:

1. Dari enam data yang diujikan, empat data memperoleh hasil ramalan terbaik melalui metode ANN, yaitu data PT. ANGI, data penjualan obat spuitx06, data penjualan obat rimacc4 dan data permintaan pumping unit C114. Satu data memperoleh hasil ramalan terbaik melalui metode SVR, yaitu data penjualan printer dan satu data memperoleh hasil terbaik melalui metode TES, yaitu data pengunjung ragunan.
2. Metode ANN memberikan hasil peramalan paling baik saat dipergunakan untuk data *lumpy* dibandingkan metode lainnya.
3. Metode ANN terbukti cocok dipergunakan untuk data yang memiliki pola acak atau bersifat non linier.
4. Metode SVR terbukti cocok dipergunakan untuk data yang memiliki pola trend atau bersifat linier.
5. Penggunaan jumlah data *training* mempengaruhi hasil peramalan. Semakin banyak data *training* yang digunakan, semakin baik hasil yang diberikan.
6. Peramalan jangka pendek memberikan hasil yang lebih akurat dibandingkan peramalan jangka panjang.

DAFTAR REFERENSI

- Arnold, J. R., & Chapman, N. S. (2004). *Introduction to Material Management*. New Jersey: Prentice-Hall Inc.
- Gunn, S. R. (1998). *Support Vector Machines for Classification and Regression*. University of Southampton .
- Hanke, J. E., Reitsch, A. G., & Wichern, D. W. (2001). *Business Forecasting* (7 ed.). New Jersey: Prentice Hall.
- Makridakis, S., & Wheelwright, S. C. (1999). *Forecasting Methods for Management*. New York: John Wiley & Sons.
- Msiza, I. S., Nelwamondo, F. V., & Marwala, T. (2008). Water Demand Prediction using Artificial Neural Networks and Support Vector Regression. *Journal of Computer* , 3.
- Nasution, A. H. (1999). *Metode dan Aplikasi Peramalan* (2 ed., Vol. 1). Binarupa Aksara.
- Nugraha, R. (2007). Peramalan Dengan Menggunakan Artificial Neural Network dan Support Vector Regression.
- Nurulita. (2010). Strategi Penetapan Tingkat Safety Stock Melalui Pendekatan Kesalahan Peramalan dengan Metode ARIMA.
- Peterson, R. T. (1993). Forecasting Practices in The Retail Industry. Dalam *J. Business Forecast* (Vol. 12, hal. 11-14).
- Rahayu, A. V. (2010). Perencanaan Pengadaan Obat-obatan dalam Instalasi Farmasi Rumah Sakit dengan Periodic Review Model.
- Rengga. (2010). Perancangan Model Optimasi Perencanaan Produksi & Persediaan dengan Memperhitungkan Perubahan Permintaan Menggunakan metode Integer Programming pada Produsen Pumping Unit.
- Santosa, B. (2007). *Data Mining: Teknik Pemanfaatan Data untuk Keperluan Bisnis*. Yogyakarta: Graha Ilmu.
- Shahrabi, J., Mousavi, S. S., & Heydar, M. (2009). Supply Chain Demand Forecasting; A Comparison of Machine Learning Techniques and Traditional Methods. *Journal of Applied Science* , 521-527.

Vapnik, V. (1995). *The Nature of Statistical Learning Theory* (1 ed.). New York: Springer.



Lampiran 1. Tabel Hasil Pengujian Parameter MA ANGI

UJ I MA ANGI	Moving Length	
	3	6
MS E	1,35,E +07	2,28,E +07

Lampiran 2. Tabel Hasil Pengujian Parameter ANN ANGI

UJI ANN ANGI			Epoch			
			100		200	
			learning rate			
			0,3	0,7	0,3	0,7
Hidden Neuron	1	MSE	8,27,E+06	1,35,E+07	1,15,E+07	1,30,E+07
	3	MSE	1,06,E+07	1,07,E+07	9,16,E+06	1,38,E+07
	5	MSE	1,03,E+07	1,16,E+07	1,10,E+07	1,09,E+07

Lampiran 3. Tabel Hasil Pengujian Parameter SVR ANGI

UJI SVR ANGI				Kernel Function				
				Linear		Poly		
				Parameter				
				1	1	2	3	
Loss Function	Quadratic	Upperbound	1	MSE	5,87,E+07	4,07,E+07	3,99,E+07	1,35,E+09
			10	MSE	5,87,E+07	5,65,E+07	9,85,E+07	7,84,E+08
			100	MSE	5,87,E+07	5,85,E+07	1,08,E+08	7,18,E+08
	Einsensitive	Upperbound	1	MSE	6,73,E+07	5,48,E+07	6,07,E+07	3,40,E+09
			10	MSE	6,73,E+07	3,83,E+07	6,60,E+07	1,81,E+09
			100	MSE	6,73,E+07	6,31,E+07	1,37,E+08	4,39,E+08

Lampiran 4. Tabel Hasil Pengujian Parameter Sensitifitas SVR ANGI

UJI E	Sensitifitas				
	1	2	3	4	5
MSE	3,83,E+07	3,59,E+07	4,14,E+07	3,99,E+07	3,27,E+07
UJI E	6	7	8	9	10
MSE	2,09,E+07	2,74,E+07	3,00,E+07	1,87,E+07	2,25,E+07

Lampiran 5. Tabel Hasil Pengujian Parameter DES ANGI

UJI DES ANGI			Beta			
			0,05	0,1	0,15	0,2
Alpha	0,05	MSE	6,05,E+07	6,69,E+07	7,40,E+07	8,05,E+07
	0,1	MSE	4,88,E+07	5,05,E+07	4,83,E+07	4,26,E+07
	0,15	MSE	3,26,E+07	2,85,E+07	2,40,E+07	2,55,E+07
	0,2	MSE	2,18,E+07	1,91,E+07	2,37,E+07	4,15,E+07

Lampiran 6. Tabel Hasil Pengujian Parameter TES ANGI

UJI TES ANGI			Alpha			
			0,2			
			Beta			
			0,1			
			Delta			
			0,05	0,1	0,15	0,2
Season	3	MSE	1,91,E+07	1,79,E+07	1,72,E+07	1,69,E+07
	6	MSE	2,34,E+07	2,14,E+07	1,98,E+07	1,86,E+07

Lampiran 7. Tabel Hasil Pengujian Parameter ANN Spuitx06

UJI ANN Spuitx06			Epoch			
			100		200	
			Learning Rate			
			0,3	0,7	0,3	0,7
Hidden Neuron	1	MSE	8,05,E+04	9,07,E+04	7,45,E+04	6,61,E+04
	3	MSE	1,06,E+05	1,13,E+05	7,62,E+04	9,14,E+04
	5	MSE	1,38,E+05	9,61,E+04	1,44,E+05	1,08,E+05

Lampiran 8. Tabel Hasil Pengujian Parameter SVR Spuitx06

UJI SVR Spuitx06				Kernel Function				
				Linear		Poly		
				Parameter				
				1	1	2	3	
Loss Function	Quadratic	Upperbound	1	MSE	6,97,E+04	7,90,E+04	6,02,E+05	9,98,E+05
			10	MSE	6,97,E+04	7,04,E+04	4,82,E+05	7,74,E+05
			100	MSE	6,97,E+04	6,98,E+04	4,69,E+05	7,49,E+05
	Einsensitive		1	MSE	8,40,E+04	6,61,E+05	9,66,E+05	2,30,E+05
			10	MSE	8,40,E+04	1,28,E+06	2,98,E+06	2,46,E+06
			100	MSE	8,40,E+04	2,29,E+05	2,45,E+06	2,27,E+06

Lampiran 9. Tabel Hasil Pengujian Parameter MA Spuitx06

UJI MA Spuitx06	Moving Length	
	4	12
MSE	1,05,E+05	6,72,E+04

Lampiran 10. Tabel Hasil Pengujian Parameter DES Spuitx06

UJI DES Spuitx06			Double Exponential Smoothing			
			Beta			
			0,05	0,1	0,15	0,2
Alpha	0,05	MSE	6,88,E+04	6,81,E+04	6,70,E+04	7,51,E+04
	0,1	MSE	6,67,E+04	8,14,E+04	1,27,E+05	1,89,E+05
	0,15	MSE	6,97,E+04	9,11,E+04	1,16,E+05	1,17,E+05
	0,2	MSE	6,77,E+04	7,62,E+04	7,62,E+04	6,95,E+04

Lampiran 11. Tabel Hasil Pengujian Parameter TES Spuitx06

UJI TES Spuitx06			Alpha			
			0,1			
			Beta			
			0,05			
			Delta			
			0,05	0,1	0,15	0,2
Season	4	MSE	3,49,E+05	2,84,E+05	2,42,E+05	2,15,E+05
	12	MSE	1,82,E+05	1,71,E+05	1,60,E+05	1,49,E+05

Lampiran 12. Tabel Hasil Pengujian Parameter ANN Rimacc4

UJI ANN Rimacc4			Epoch			
			100		200	
			Learning Rate			
			0,3	0,7	0,3	0,7
Hidden Neuron	1	MSE	2,97,E+02	2,88,E+02	2,65,E+02	3,05,E+02
	3	MSE	3,08,E+02	3,57,E+02	3,18,E+02	2,78,E+02
	5	MSE	3,37,E+02	3,24,E+02	3,36,E+02	2,96,E+02

Lampiran 13. Tabel Hasil Pengujian Parameter SVR Rimacc4

UJI SVR Rimacc4				Kernel Function				
				Linear		Poly		
				Parameter				
				1	1	2	3	
Loss Function	Quadratic	Upperbound	1	MSE	3,154,E+02	3,151,E+02	3,212,E+02	9,744,E+02
			10	MSE	3,154,E+02	3,153,E+02	3,206,E+02	1,077,E+03
			100	MSE	3,154,E+02	3,154,E+02	3,205,E+02	1,090,E+03
	Einsensitive		1	MSE	5,030,E+02	5,048,E+02	5,048,E+02	5,048,E+02
			10	MSE	5,048,E+02	5,048,E+02	5,048,E+02	5,048,E+02
			100	MSE	5,048,E+02	5,048,E+02	5,048,E+02	5,048,E+02

Lampiran 14. Tabel Hasil Pengujian Parameter MA Rimacc4

UJI MA Rimacc4	Moving Length	
	4	12
MSE	3,11,E+02	3,65,E+02

Lampiran 15. Tabel Hasil Pengujian Parameter DES Rimacc4

UJI DES Rimacc4			Double Exponential Smoothing			
			Beta			
			0,05	0,1	0,15	0,2
Alpha	0,05	MSE	3,15,E+02	3,13,E+02	3,11,E+02	3,08,E+02
	0,1	MSE	3,17,E+02	3,17,E+02	3,23,E+02	3,48,E+02
	0,15	MSE	3,20,E+02	3,29,E+02	3,58,E+02	4,11,E+02
	0,2	MSE	3,19,E+02	3,30,E+02	3,52,E+02	3,71,E+02

Lampiran 16. Tabel Hasil Pengujian Parameter TES Rimacc4

UJI TES Rimacc4			Alpha			
			0,05			
			Beta			
			0,2			
			Delta			
			0,05	0,1	0,15	0,2
Season	4	MSE	1,25,E+03	1,16,E+03	9,32,E+02	9,30,E+02
	12	MSE	1,15,E+03	5,13,E+02	2,70,E+05	3,08,E+03

Lampiran 17. Tabel Hasil Pengujian Parameter MA C114

UJI MA C114	Moving Length	
	3	6
MSE	1,61,E+02	1,36,E+02

Lampiran 18. Tabel Hasil Pengujian Parameter ANN C114

UJI ANN C114			Epoch			
			100		200	
			Learning Rate			
			0,3	0,7	0,3	0,7
Hidden Neuron	1	MSE	2,05,E+02	1,28,E+02	1,60,E+02	1,71,E+02
	3	MSE	1,86,E+02	2,02,E+02	1,76,E+02	1,88,E+02
	5	MSE	2,21,E+02	2,06,E+02	1,81,E+02	2,19,E+02

Lampiran 19. Tabel Hasil Pengujian Parameter SVR C114

UJI SVR C114				Kernel Function				
				Linear		Poly		
				Parameter				
				1	1	2	3	
Loss Function	Quadratic	Upperbound	1	MSE	7,53,E+02	7,99,E+02	6,17,E+02	3,48,E+03
			10	MSE	7,54,E+02	7,58,E+02	6,28,E+02	3,73,E+03
			100	MSE	7,54,E+02	7,54,E+02	6,29,E+02	3,76,E+03
	Einsensitive	Upperbound	1	MSE	7,36,E+02	1,21,E+03	7,91,E+02	1,51,E+03
			10	MSE	7,36,E+02	7,64,E+02	7,92,E+02	2,03,E+03
			100	MSE	7,36,E+02	7,36,E+02	7,96,E+02	2,33,E+03

Lampiran 20. Tabel Hasil Pengujian Parameter DES C114

UJI DES C114			Double Exponential Smoothing			
			Beta			
			0,05	0,1	0,15	0,2
Alpha	0,05	MSE	7,68,E+02	8,38,E+02	8,85,E+02	8,86,E+02
	0,1	MSE	5,62,E+02	4,90,E+02	3,53,E+02	2,20,E+02
	0,15	MSE	3,51,E+02	2,25,E+02	1,52,E+02	2,13,E+02
	0,2	MSE	2,31,E+02	1,48,E+02	1,83,E+02	3,22,E+02

Lampiran 21. Tabel Hasil Pengujian Parameter TES C114

UJI TES C114			Alpha			
			0,2			
			Beta			
			0,1			
			Delta			
			0,05	0,1	0,15	0,2
Season	3	MSE	1,51,E+02	1,52,E+02	1,53,E+02	1,52,E+02
	6	MSE	1,79,E+02	1,81,E+02	1,82,E+02	1,82,E+02

Lampiran 22. Tabel Hasil Pengujian Parameter ANN Printer

UJI ANN Printer			Epoch			
			100		200	
			Learning Rate			
			0,3	0,7	0,3	0,7
Hidden Neuron	1	MSE	3,72,E+07	4,94,E+07	5,40,E+07	4,74,E+07
	3	MSE	4,98,E+07	5,33,E+07	5,54,E+07	4,46,E+07
	5	MSE	4,52,E+07	5,20,E+07	4,85,E+07	5,40,E+07

Lampiran 23. Tabel Hasil Pengujian Parameter SVR Printer

UJI SVR Printer				Kernel Function				
				Linear		Poly		
				Parameter				
				1	1	2	3	
Loss Function	Quadratic	Upperbound	1	MSE	2,09,E+09	2,10,E+09	9,96,E+09	2,50,E+10
			10	MSE	2,09,E+09	2,09,E+09	1,02,E+10	2,43,E+10
			100	MSE	2,09,E+09	2,09,E+09	1,03,E+10	2,53,E+10
	Einsensitive		1	MSE	2,83,E+07	2,82,E+07	1,52,E+08	3,04,E+08
			10	MSE	2,84,E+07	2,48,E+07	4,88,E+07	2,81,E+07
			100	MSE	2,81,E+07	2,84,E+07	3,90,E+07	2,53,E+07

Lampiran 24. Tabel Hasil Pengujian Parameter Sensitifitas SVR Printer

UJI E	Sensitifitas				
	1	2	3	4	5
MSE	2,51,E+07	2,51,E+07	2,363,E+07	2,37,E+07	2,41,E+07
UJI E	6	7	8	9	10
MSE	2,357,E+07	2,39,E+07	2,80,E+07	3,52,E+07	4,70,E+07

Lampiran 25. Tabel Hasil Pengujian Parameter MA Printer

UJI MA Printer	Moving Length	
	4	12
MSE	4,12,E+07	2,77,E+07

Lampiran 26. Tabel Hasil Pengujian Parameter DES Printer

UJI DES Printer			Double Exponential Smoothing			
			Beta			
			0,05	0,1	0,15	0,2
Alpha	0,05	MSE	3,35,E+07	3,96,E+07	4,48,E+07	4,59,E+07
	0,1	MSE	4,32,E+07	5,21,E+07	6,10,E+07	7,36,E+07
	0,15	MSE	5,31,E+07	6,86,E+07	8,67,E+07	1,06,E+08
	0,2	MSE	6,38,E+07	8,76,E+07	1,18,E+08	1,60,E+08

Lampiran 27. Tabel Hasil Pengujian Parameter TES Printer

UJI TES Printer			Alpha			
			0,05			
			Beta			
			0,05			
			Delta			
			0,05	0,1	0,15	0,2
Season	4	MSE	3,85,E+07	2,96,E+07	2,62,E+07	2,50,E+07
	12	MSE	3,25,E+07	3,20,E+07	3,15,E+07	3,11,E+07

Lampiran 28. Tabel Hasil Pengujian Parameter ANN Ragunan

UJI ANN Ragunan			Epoch			
			100		200	
			Learning Rate			
			0,3	0,7	0,3	0,7
Hidden Neuron	1	MSE	6,47,E+10	6,28,E+10	7,17,E+10	6,30,E+10
	3	MSE	7,10,E+10	6,13,E+10	6,04,E+10	6,26,E+10
	5	MSE	6,02,E+10	5,57,E+10	6,64,E+10	6,74,E+10

Lampiran 29. Tabel Hasil Pengujian Parameter SVR Ragunan

UJI SVR Ragunan					Kernel Function			
					Linear		Poly	
					Parameter			
					1	1	2	3
Loss Function	Quadratic	Upperbound	1	MSE	5,96,E+10	5,92,E+10	9,84,E+10	6,17,E+10
			10	MSE	5,96,E+10	5,95,E+10	8,89,E+10	6,12,E+10
			100	MSE	5,96,E+10	5,96,E+10	8,78,E+10	6,13,E+10
	Einsensitive	Upperbound	1	MSE	7,10,E+10	1,66,E+11	6,93,E+10	7,83,E+10
			10	MSE	7,02,E+10	1,43,E+11	7,41,E+10	9,14,E+10
			100	MSE	8,58,E+10	6,13,E+10	6,46,E+10	9,33,E+10

Lampiran 30. Tabel Hasil Pengujian Parameter DES Ragunan

UJI DES Ragunan			Double Exponential Smoothing			
			Beta			
			0,05	0,1	0,15	0,2
Alpha	0,05	MSE	5,96,E+10	5,95,E+10	5,944,E+10	5,938,E+10
	0,1	MSE	5,97,E+10	5,96,E+10	5,96,E+10	5,96,E+10
	0,15	MSE	5,99,E+10	6,00,E+10	6,02,E+10	6,06,E+10
	0,2	MSE	6,03,E+10	6,06,E+10	6,12,E+10	6,23,E+10

Lampiran 31. Tabel Hasil Pengujian Parameter MA Ragunan

UJI MA Ragunan	Moving Length	
	3	6
MSE	5,89,E+10	6,36,E+10

Lampiran 32. Tabel Hasil Pengujian Parameter TES Ragunan

UJI TES Ragunan			Alpha			
			0,05			
			Beta			
			0,2			
			Delta			
			0,05	0,1	0,15	0,2
Season	3	MSE	7,80,E+10	2,03,E+13	3,30,E+11	3,01,E+11
	6	MSE	1,810,E+10	1,809,E+10	1,82,E+10	1,84,E+10

Lampiran 33. Tabel Hasil Pengujian Data *Lumpy*

Data		Metode				
		ANN	SVR	MA	DES	TES
AVAND	MSE	1,88,E+01	1,90,E+01	1,96,E+01	1,92,E+01	1,96,E+01
MDCAL	MSE	2,08,E+02	1,69,E+03	3,88,E+02	1,09,E+03	8,02,E+03
UNASYT	MSE	1,26,E+01	1,30,E+01	1,47,E+01	1,29,E+01	1,78,E+01
PHISIB	MSE	4,63,E+00	5,84,E+00	5,98,E+00	6,04,E+00	7,72,E+00

Lampiran 34. Data Penjualan Obat *Lumpy*