

TESIS

**PENERAPAN JARINGAN SYARAF TIRUAN
DENGAN ALGORITMA *BACKPROPAGATION* UNTUK
PERAMALAN PENJUALAN AIR MINUM DALAM KEMASAN**



**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2020**

TESIS

**PENERAPAN JARINGAN SYARAF TIRUAN
DENGAN ALGORITMA BACKPROPAGATION UNTUK
PERAMALAN PENJUALAN AIR MINUM DALAM KEMASAN**

**APPLICATION OF ARTIFICIAL NEURAL NETWORKS
WITH BACKPROPAGATION ALGORITHM FOR
FORECASTING SALES OF BOTTLED WATER**

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister

HALAN DILAKUKAN



Disusun oleh:

Nama : **Nur Fitrianingsih Hasan**
NIM : **18.51.1063**
Konsentrasi : **Business Intelligence**

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2020**

HALAMAN PENGESAHAN

PENERAPAN JARINGAN SYARAF TIRUAN
DENGAN ALGORITMA *BACKPROPAGATION* UNTUK
PERAMALAN PENJUALAN AIR MINUM DALAM KEMASAN

APPLICATION OF ARTIFICIAL NEURAL NETWORKS
WITH BACKPROPAGATION ALGORITHM FOR
FORECASTING SALES OF BOTTLED WATER

Dipersiapkan dan Disusun oleh

Nur Fitrianingsih Hasan

18.51.1063

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Kamis, 09 Januari 2020

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer



HALAMAN PERSETUJUAN

PENERAPAN JARINGAN SYARAF TIRUAN DENGAN ALGORITMA BACKPROPAGATION UNTUK PERAMALAN PENJUALAN AIR MINUM DALAM KEMASAN

APPLICATION OF ARTIFICIAL NEURAL NETWORKS WITH BACKPROPAGATION ALGORITHM FOR FORECASTING SALES OF BOTTLED WATER

Dipersiapkan dan Disusun oleh

Nur Fitrianingsih Hasan

18.51.1063

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Kamis, 09 Januari 2020

Pembimbing Utama

Dr. Kusriini, M.Kom.
NIK. 190302106

Anggota Tim Pengaji

Prof. Dr. Ema Utami, S.Si., M.Kom.
NIK. 190302037

Pembimbing Pendamping

Hafif Al Fatta, M.Kom.
NIK. 190302096

Dr. Wing Wahyu Winarno, MAFIS, Ak.
NIK. 555195

Dr. Kusriini, M.Kom.
NIK. 190302106

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 09 Januari 2020
Direktur Program Pascasarjana

Dr. Kusriini, M.Kom.
NIK. 190302106

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Nur Fitrianingsih Hasan

NIM : 18.51.1063

Konsentrasi : Business Intelligence

Menyatakan bahwa Tesis dengan judul berikut:

Penerapan Jaringan Syaraf Tiruan Dengan Algoritma Backpropagation untuk Peramalan Penjualan Air Minum Dalam Kemasan

Dosen Pembimbing Utama : Dr. Kusrini, M.Kom

Dosen Pembimbing Pendamping : Hanif Al Fatta, M.Kom

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, tanggal ujian tesis

Yang Menyatakan,



Nur Fitrianingsih Hasan

HALAMAN PERSEMBAHAN

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Penelitian tesis ini saya persembahkan kepada Allah Subhanahu wata'ala sebagai bentuk syukur saya terhadap ilmu yang saya dapatkan, saya jabarkan pada laporan ini agar berguna dalam kontribusi ilmu bidang IT. Semoga dapat diterima sebagai suatu amal kebaikan. Selanjutnya karya ini saya persembahkan kepada kedua Orang Tua tersayang Mama dan Bapak untuk segala bentuk dukungan, do'a dan kebaikan yang dilakukan sehingga memberikan saya energi positif dan saya dapat menyelesaikan studi serta penelitian ini dengan baik.

Penelitian ini juga saya persembahkan untuk almamater saya, Universitas AMIKOM Yogyakarta dan juga para pembaca semoga semua yang terdapat dalam naskah laporan penelitian tesis ini dapat memberikan wawasan tambahan dan kontribusi keilmuan yang baik dan bermanfaat.

HALAMAN MOTTO

—“*Prayer and Passion is our strength*”— NFH

“*Pengetahuan yang baik adalah yang memberi manfaat, bukan yang hanya diingat.*” - Imam Al-Safī'i

“*Bila kamu tidak tahan lelahnya belajar, maka kamu harus menanggung perihnya kebodohan*” - Imam Al-Safī'i



KATA PENGANTAR

Al-hamdu lillahi rabbil 'alamin atas berkat, hidayah dan limpahan karuniaNya sehingga penulis dapat menyelesaikan tesis yang merupakan salah satu syarat dalam menyelesaikan jenjang pendidikan S2 Pascasarjana Teknik Informatika Univeristas AMIKOM Yogyakarta yang berjudul "Penerapan Jaringan Syaraf Tiruan dengan Algoritma *Backpropagation* untuk Peramalan Penjualan Air Minum Dalam Kemasan" dengan baik dan tepat waktu. Pada kesempatan ini Penulis ingin menyampaikan ucapan terima kasih kepada:

1. Kedua Orang Tua saya, Bapak Abdul Latif Hasan dan Mama Siswati serta keluarga besar atas do'a dan dukunganya yang tulus.
2. Bapak Prof. Dr. M. Suyanto, M.M., selaku Rektor Universitas AMIKOM Yogyakarta.
3. Ibu Dr. Kusrini, M.Kom., selaku Direktur Pascasarjana Universitas AMIKOM Yogyakarta dan juga selaku dosen pembimbing utama yang telah banyak memberikan ilmu baru dalam menulis juga memberikan masukan yang membangun untuk penelitian ini.
4. Bapak Hanif Al Fatta, M.Kom., selaku dosen pembimbing pendamping yang telah banyak mengarahkan secara teknis dan memberikan saran yang membangun pada penelitian ini.
5. Ibu Prof. Dr. Ema Utami, S.Si., M.Kom., selaku Wakil Direktur Pascasarjana Univeritas AMIKOM Yogyakarta dan anggota tim penguji yang telah memberikan saran dalam perbaikan tesis ini sehingga menjadi lebih baik.

6. Bapak Dr. Wing Wahyu Winarno, MAFIS, Ak., selaku anggota tim penguji yang telah memberikan koreksi dan saran dan dalam tesis ini sehingga menjadi lebih baik.
7. Segenap Dosen dan staff Magister Teknik Informatika Univeritas AMIKOM Yogyakarta yang telah memberikan ilmu, wawasan, bantuan dan pengalaman baru pada penulis selama perkuliahan.
8. Unit bisnis AMDK PDAM Sembada Sleman, selaku objek pada penelitian ini telah berkenan membantu menjadi narasumber.
9. Rekan-rekan seperjuangan MTI Angkatan 20A Vera Wati dan kawan-kawan yang telah memberikan pengalaman baru dan waktu untuk bertukar pikiran dalam perkuliahan maupun penyelesaian tesis ini.
10. Rekan sesama perantauan "Vacum Cleaner" Christin Nandari Dingen, Kak Patmawati Hasan, Kak Elvis Pawan dan Kak Kaharuddin yang telah banyak membantu dalam kegiatan perkuliahan dan penyelesaian tesis ini.

Penulis menyadari bahwa dalam penyusunan tesis ini ada kekurangan. Oleh karena itu penulis dengan senang hati menerima kritik dan saran yang membangun dari pembaca. Akhir kata, penulis berharap semoga tesis ini dapat memberikan kebermanfaatan bagi yang membacanya.

Yogyakarta, 09 Januari 2020

Penulis

DAFTAR ISI

HALAMAN JUDUL.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERSETUJUAN.....	iv
HALAMAN PERNYATAAN KEASLIAN TESIS.....	v
HALAMAN PERSEMBAHAN.....	vi
HALAMAN MOTTO.....	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	x
DAFTAR TABEL.....	xiii
DAFTAR GAMBAR.....	xv
INTISARI.....	xvi
<i>ABSTRACT</i>	xvii
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah.....	11
1.3. Batasan Masalah.....	12
1.4. Tujuan Penelitian.....	12
1.5. Manfaat Penelitian.....	13
BAB II TINJAUAN PUSTAKA.....	14
2.1. Tinjauan Pustaka.....	14
2.2. Keaslian Penelitian.....	19

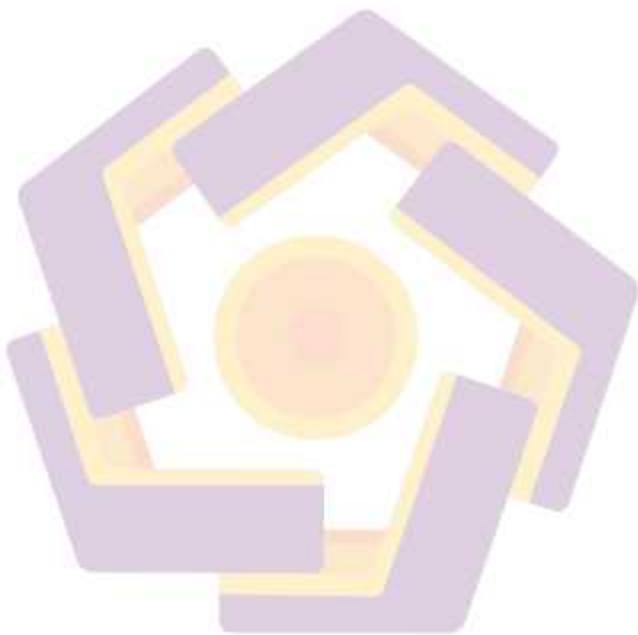
2.3. Landasan Teori.....	26
2.3.1. Air Minum Dalam Kemasan (AMDK).....	26
2.3.2. Peramalan Penjualan.....	28
2.3.3. Menghitung Kesalahan Peramalan.....	29
2.3.4. Jaringan Syaraf Tiruan.....	31
3.3.4.1. Arsitektur JST.....	34
3.3.4.2. Algoritma Pelatihan JST.....	35
3.3.4.3. Fungsi Aktivasi.....	37
3.3.4.4. Istilah-Istilah Dalam Jaringan Syaraf Tiruan.....	38
3.3.4.5. Notasi Dalam Jaringan Syaraf Tiruan.....	39
3.3.4.6. Algoritma Backpropagation.....	39
2.3.5. Algoritma <i>Nguyen-widrow</i>	42
BAB III METODE PENELITIAN.....	44
3.1. Jenis, Sifat, dan Pendekatan Penelitian.....	44
3.2. Metode Pengumpulan Data.....	45
3.3. Metode Analisis Data.....	45
3.4. Alur Penelitian.....	48
BAB IV HASIL PENELITIAN DAN PEMBAHASAN.....	52
4.1. Action Planning.....	52
4.1.1. Pengumpulan Data.....	52
4.1.2. Praproses Data.....	55
4.1.3. Parameter dan Arsitektur JST.....	58

4.2. Action Taking.....	65
4.2.1. Prototype Peramalan JST <i>Backpropagation</i>	66
4.2.2. Pelatihan dan Analisis Data.....	70
4.3. Evaluating.....	89
4.3.1. Pengujian Menggunakan Seluruh Data Aktual (Skenario Uji 1)...	90
4.3.2. Pengujian Menggunakan Data Latih (Skenario Uji 2).....	102
BAB V PENUTUP.....	104
5.1. Kesimpulan.....	104
5.2. Saran.....	104
DAFTAR PUSTAKA.....	106

DAFTAR TABEL

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian Penerapan Jaringan Syaraf Tiruan dengan Algoritma <i>Backpropagation</i> untuk Peramalan Penjualan Air Minum Dalam Kemasan.....	19
Tabel 2.2 Jumlah Produksi AMDK di Indonesia.....	27
Tabel 2.3 Jenis Algoritma Pelatihan JST.....	35
Tabel 2.4 Daftar Istilah Jaringan Syaraf Tiruan.....	38
Tabel 2.5 Notasi Dalam Jaringan Syaraf Tiruan.....	39
Tabel 4.1 Data Aktual Penjualan AMDK DAXU.....	52
Tabel 4.2 Data Kalender.....	53
Tabel 4.3 Data Curah Hujan.....	54
Tabel 4.4 Hasil Integrasi Data.....	55
Tabel 4.5 Inisialisasi Data Hari.....	56
Tabel 4.6 Inisialisasi Data Kegiatan.....	56
Tabel 4.7 Hasil Integrasi Inisialisasi Data.....	57
Tabel 4.8 Hasil Normalisasi Data.....	58
Tabel 4.9 Hasil Bobot Vj.....	63
Tabel 4.10 Bobot Awal dan Bias 1 Lapisan Tersembunyi (10 neuron).....	63
Tabel 4.11 Bobot Awal dan Bias Awal Hidden Layer ke Output Layer.....	64
Tabel 4.12 Bobot dan Bias Baru 1 Lapisan Tersembunyi (10 neuron).....	80
Tabel 4.13 Bobot dan Bias Baru Hidden Layer ke Output Layer.....	81
Tabel 4.14 Hasil Pelatihan Data AMDK DAXU 240ml.....	82

Tabel 4.15 Hasil Pelatihan Data AMDK DAXU 330ml.....	83
Tabel 4.16 Hasil Pelatihan Data AMDK DAXU 600ml.....	85
Tabel 4.17 Hasil Pelatihan Data AMDK DAXU 19 liter.....	86
Tabel 4.18 Hasil Pelatihan Data AMDK DAXU Revil 19 liter.....	87



DAFTAR GAMBAR

Gambar 1.1 Grafik Penjualan AMDK DAXU	3
Gambar 2.1 Arsitektur Single Layer.....	34
Gambar 2.2 Arsitektur Multilayer.....	35
Gambar 3.1 Alur Flowchart Peramalan.....	46
Gambar 3.2 Alur Pencarian Hasil Rumusan Masalah.....	47
Gambar 3.3 Alur Penelitian.....	49
Gambar 4.1 Arsitektur JST Peramalan Penjualan AMDK DAXU.....	65
Gambar 4.2 Gambaran Umum Sistem Peramalan.....	66
Gambar 4.3 Tampilan Antarmuka Prototype.....	67
Gambar 4.4 Flowchart Pelatihan JST Backpropagation dan Nguyen-widrow.....	71
Gambar 4.5 Flowchart Pengujian JST Backpropagation.....	89
Gambar 4.6 Arsitektur JST-BP Peramalan AMDK DAXU 240ml.....	91
Gambar 4.7 Grafik Hasil Peramalan Produk AMDK DAXU 240ml.....	91
Gambar 4.8 Arsitektur JST-BP Peramalan AMDK DAXU 330ml.....	93
Gambar 4.9 Grafik Hasil Peramalan AMDK DAXU 330ml.....	94
Gambar 4.10 Arsitektur JST-BP Peramalan AMDK DAXU 600ml.....	95
Gambar 4.11 Grafik Hasil Peramalan AMDK DAXU 660ml.....	96
Gambar 4.12 Arsitektur JST-BP Peramalan AMDK DAXU 19L.....	97
Gambar 4.13 Grafik Hasil Peramalan AMDK DAXU 19L.....	98
Gambar 4.14 Arsitektur JST-BP Peramalan AMDK DAXU Revil 19L.....	99
Gambar 4.15 Grafik Hasil Peramalan AMDK DAXU Revil 19L.....	100
Gambar 4.16 Ringkasan Hasil Skenario Uji 1.....	101
Gambar 4.17 Ringkasan Perbandingan Hasil Pengujian.....	102

INTISARI

Industri 4.0 dimana AI sebagai kekuatan utama dan AMDK menjadi salah satu fokus implementasi pada industri makanan dan minuman, perusahaan yang bergerak dalam bidang ini dapat mengoptimalkan kinerjanya. Salah satu yang dapat dilakukan pihak manajemen adalah melakukan peramalan jualan (*sales forecasting*). Terdapat banyak metode dalam melakukan peramalan penjualan salah satunya yaitu jaringan syaraf tiruan *backpropagation* (JST-BP). Penelitian ini berjudul Penerapan Jaringan Syaraf Tiruan dengan Algoritma *Backpropagation* untuk Peramalan Penjualan Air Minum Dalam Kemasan. Adapun tujuan dari penelitian ini adalah mendapatkan hasil peramalan penjualan produk AMDK DAXU. Data yang digunakan adalah data penjualan AMDK DAXU sebanyak 229 data latih dan 14 data uji. Metode analisis yang digunakan adalah wawancara, analisa data menggunakan JST-BP dan MSE.

Penelitian menggunakan 24 skenario pelatihan untuk masing-masing produk dalam mencari arsitektur dan parameter JST terbaik, kemudian dilakukan pengujian menggunakan 2 skenario uji. Skenario uji 1 menggunakan data aktual untuk mendapatkan hasil peramalan penjualan, sementara skenario uji 2 menggunakan sebagian data latih sebagai data uji untuk mengetahui konsistensi arsitektur dan akurasi.

Berdasarkan analisa data, variabel yang digunakan untuk peramalan pada penelitian ini yaitu hari, tanggal, kegiatan dan curah hujan. Hasil pengujian, skenario uji 1 digunakan dalam penarikan kesimpulan karena pada penelitian ini tujuannya adalah mencari hasil peramalan aktual pada periode selanjutnya dari data set. Hasil peramalan penjualan produk AMDK DAXU 240ml MSE=17660 dengan akurasi 76,34%, DAXU 330ml MSE=7379,9286 dengan akurasi 74,31%, DAXU 600ml MSE=6637,6429 dengan akurasi 72,56%, DAXU 19L MSE=0,071429 dengan akurasi 99,29% dan DAXU revil 19L MSE=632,7143 dengan akurasi 86,53%.

Kata kunci: jaringan syaraf tiruan (JST), backpropagation, peramalan penjualan, mse

ABSTRACT

Industry 4.0 where AI as the main strength and bottled water become one of the focus of implementation in the food and beverage industry, companies engaged in this field can optimize their performance. One thing management can do is forecast sales. There are many methods of forecasting sales, one of which is the backpropagation neural network (ANN-BP). This study is entitled Application of Artificial Neural Networks with Backpropagation Algorithm for Forecasting Sales of Bottled Water. The purpose of this research is to get the results of forecasting sales of DAXU bottled water products. The data used are DAXU sales data of 229 training data and 14 testing data. The analytical method used is interviews, data analysis using ANN-BP and MSE.

The study uses 24 training scenarios for each product in finding the best architecture and ANN parameters, then testing is done using 2 test scenarios. Test scenario 1 uses actual data to obtain sales forecasting results, while test scenario 2 uses part of the training data as test data to determine architectural consistency and accuracy.

Based on data analysis, the variables used for forecasting in this study are day, date, activity and rainfall. The test results, test scenario 1 is used in drawing conclusions because in this study the aim is to find the actual forecasting results in the next period of the data set. Forecasting of DAXU 240ml MSE = 17660 with 76.34% accuracy, DAXU 330ml MSE = 7379.9286 with 74.31% accuracy, DAXU 600ml MSE = 6637.6429 with 72.56% accuracy, DAXU 19L MSE = 0.071429 with an accuracy of 99.29% and DAXU revil 19L MSE = 632.7143 with an accuracy of 86.53%.

Keyword: *artificial neural networks (ANN), backpropagation, sales forecasting, mse*

BAB I

PENDAHULUAN

1.1.Latar Belakang Masalah

Air merupakan salah satu sumber daya alam dan kebutuhan hidup yang paling penting juga merupakan unsur dasar bagi semua kehidupan di bumi. Tanpa air, berbagai proses kehidupan tidak dapat berlangsung. Kebutuhan masyarakat akan air bersih yang dapat digunakan sebagai air minum harus melalui tahap pengelolaan (Puspitasari, dkk, 2017). Memenuhi kebutuhan akan air, masyarakat pada umumnya mendapatkannya dari dua sumber, yaitu dari Perusahaan Air Minum dan air sumur. Salah satu cara untuk memperoleh air bersih, aman, sehat dan terjamin kebersihannya untuk dikonsumsi, terutama di kota-kota besar adalah melalui produk air minum dalam kemasan (AMDK) yang dibuat produsen minuman untuk memenuhi kebutuhan masyarakat akan air minum sehat (Rohman, 2006).

Sumber air yang digunakan PDAM Tirta Sembada Sleman saat ini salah satunya adalah dari Umbul Wadon. Namun sejak tahun 2018, secara kuantitas terjadi penurunan kapasitas terutama pada periode musim kemarau. Jika musim penghujan debit air sekitar 650 liter/detik namun terjadi peningkatan kekeruhan air, sementara pada musim kemarau debit air menurun menjadi 400 liter/detik. Produksi AMDK kemudian ikut terganggu karena faktor ini. Maka perlu adanya langkah solusi untuk masalah ini baik solusi jangka pendek, maupun jangka panjang.

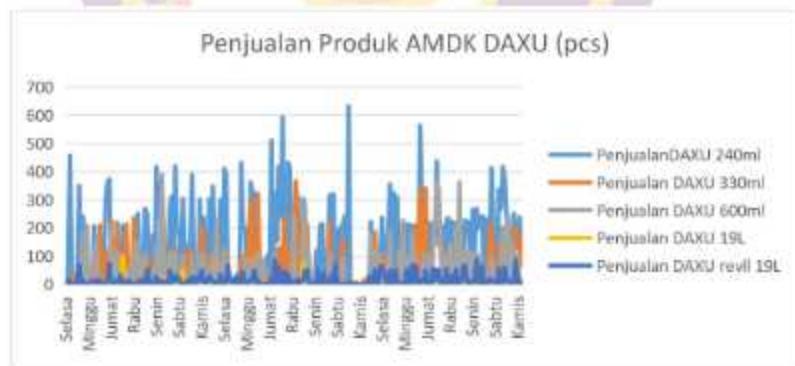
Indonesia sudah menapaki era Industri 4.0, yang antara lain ditandai dengan serba digitalisasi dan otomatisasi. Pada era industri generasi keempat ini, ukuran besar perusahaan tidak menjadi jaminan, namun kelincahan perusahaan menjadi kunci keberhasilan meraih prestasi dengan cepat. Oleh sebab itu, perusahaan harus peka dan melakukan introspeksi diri sehingga mampu mendekripsi posisi di tengah perkembangan ilmu pengetahuan dan teknologi.

Merespon perubahan pada era Industri 4.0, pemerintah telah bersiap dengan merancang peta jalan (*road map*) berjudul *Making Indonesia 4.0*, sebagai strategi Indonesia memasuki era digital saat ini. Saat membuka Indonesia Industrial Summit 2018 di Jakarta Convention Center (JCC) Presiden Ir. H. Joko Widodo mengungkapkan bahwa pemerintah telah mengelompokkan lima industri utama yang disiapkan untuk Revolusi Industri 4.0. "Lima industri yang jadi fokus implementasi Industri 4.0 di Indonesia yaitu industri makanan dan minuman, tekstil, otomotif, elektronik dan kimia" kata Presiden. Menurut Presiden, kelima industri tersebut ditetapkan menjadi tulang punggung guna meningkatkan daya saing di era Industri 4.0 yang sudah menghadirkan kecerdasan buatan atau *Artificial Intelligence (AI)*.

Industri 4.0 dimana AI sebagai kekuatan utama dan AMDK menjadi salah satu fokus implementasi pada industri makanan dan minuman, maka perusahaan yang bergerak dalam bidang makanan dan minuman dapat mengoptimalkan produksi serta kinerjanya, ini karena keuntungan utama untuk industri 4.0 yakni ketabilan distribusi barang dan kebutuhan, sehingga perusahaan dapat memproduksi dengan jumlah yang tepat sesuai kebutuhan. Tentunya secara

ekonomi, hal ini dapat menjaga kestabilan stok dan harga. Secara bisnis, hal ini dapat memperluas pasar.

Persaingan bisnis yang semakin dinamis dan perubahan alam serta iklim ini membuat beberapa perusahaan manufaktur harus peka dan membuka diri terhadap *issues global* terutama yang berkaitan dengan penjualan agar dapat memenuhi target penjualan. Diperlukan banyak strategi guna memenuhi kebutuhan masyarakat yang bervariasi, dengan pola dan gaya hidup yang berbeda-beda pula. Perusahaan harus pandai mencari celah untuk menghadapi para pesaing dan mempertahankan kelangsungan perusahaan. Selain dengan jenis produk yang variatif, kapasitas gudang yang memadai dan penyesuaian harga jual tiap produk juga dibutuhkan manajemen yang baik dalam pelaksanaan seluruh kegiatan perusahaan, salah satunya adalah memaksimalkan penjualan dengan harapan mendapatkan keuntungan yang maksimal.



Gambar 1.1 Grafik Penjualan AMDK DAXU

Gambar 1.1 adalah grafik penjualan salah satu produk DAXU dengan 5 jenis kemasan. Pada gambar 1.1 dapat dilihat penjualan AMDK DAXU yang

tidak pasti membuat perusahaan harus lebih teliti dalam memprediksi penjualan dan kebutuhan pasar dengan tepat. Prediksi penjualan dilakukan bukan hanya untuk satu jenis produk namun untuk keseluruhan produk yang dipasarkan.

Penjualan sangat penting bagi keberlangsungan sebuah perusahaan karena berfungsi untuk menghubungkan antara barang dan jasa dari produsen sampai ke konsumen. Karena tingginya tingkat penjualan pada suatu perusahaan maka dapat mengimbangi dan menutup biaya operasional yang harus dikeluarkan bahkan dapat memberikan keuntungan bagi perusahaan. Namun jika hanya mengandalkan penjualan tanpa memperhatikan proses kebutuhan produk, akan sangat berpengaruh terhadap daya beli masyarakat. Penjualan yang baik tanpa didukung dengan ketersediaan stok produk yang memenuhi kebutuhan permintaan pasar, mengakibatkan ketidakseimbangan. Permintaan barang naik namun stok di gudang kosong, akan mengakibatkan keterlambatan proses pengiriman produk. Maka perusahaan perlu menyediakan stok produk yang sesuai.

Persediaan produk disimpan sebelum dipasarkan, dengan demikian perusahaan yang melakukan kegiatan usaha pada umumnya memiliki ketersediaan produk. Jumlah stok produk selalu berubah tergantung pada jumlah transaksi penjualan. Suatu perusahaan tidak dapat berjalan lancar tanpa adanya persediaan barang yang memadai. Hal lain yang perlu dipertimbangkan adalah jika gudang menyimpan terlalu banyak stok produk padahal permintaan menurun, akan mengakibatkan kerugian bagi perusahaan. Selain itu, permintaan pasar yang tidak pasti membuat perusahaan harus lebih teliti dalam memprediksi penjualan dan dalam memenuhi kebutuhan pasar dengan tepat, jika tidak maka akan

mengakibatkan penumpukan stok yang ada di gudang maupun sebaliknya (Shimbun, 2016).

Salah satu yang dapat dilakukan pihak manajemen adalah melakukan peramalan jualan (*sales forecasting*). Hasil dari peramalan penjualan tersebut dapat menjadi dasar untuk menghitung *budgeting* pembelian di periode berikutnya. Hal tersebut juga dapat menjadi nilai tambah bagi manajemen dalam mengawasi proses penjualan maupun proses perencanaan. Manajemen juga dapat membuat ketetapan-ketetapan dalam mencapai sasaran penjualan dan pengambilan keputusan.

Peramalan adalah seni dan ilmu memprediksi peristiwa-peristiwa yang akan terjadi dengan menggunakan data historis dan memproyeksikannya ke masa depan dengan beberapa bentuk model matematis (Armi, dkk., 2019). Peramalan penjualan merupakan proses aktivitas memperkirakan produk yang akan dijual di masa mendatang dalam keadaan tertentu dan dibuat berdasarkan data yang pernah terjadi dan mungkin akan terjadi (Nafarin, 2007).

Banyak teknik dan metode yang diterapkan dalam peramalan. Dalam melakukan peramalan diperlukan perhitungan yang akurat sehingga didapatkan peramalan yang tepat (Heizer & Render, 2005). Terdapat dua pendekatan untuk melakukan peramalan yaitu dengan pendekatan kualitatif dan pendekatan kuantitatif (Muqtadiroh, dkk., 2015). Metode peramalan kualitatif digunakan ketika data historis tidak tersedia. Metode peramalan kualitatif adalah metode subyektif (intuitif), peramalan yang menggabungkan faktor-faktor seperti instuisi pengambilan keputusan, emosi, pengalaman pribadi dan sistem nilai. Metode ini

didasarkan pada informasi kualitatif. Dasar informasi ini dapat memprediksi kejadian-kejadian di masa yang akan datang. Keakuratan dari metode ini sangat subjektif.

Metode peramalan kuantitatif dapat dibagi menjadi dua tipe, *causal* dan *time series*. Metode peramalan *causal* meliputi faktor-faktor yang berhubungan dengan variabel yang diprediksi seperti analisis regresi. Peramalan *time series* merupakan metode kuantitatif untuk menganalisis data masa lampau yang telah dikumpulkan secara teratur menggunakan teknik yang tepat. Hasilnya dapat dijadikan acuan untuk peramalan nilai di masa yang akan datang menggunakan satu atau lebih model matematis dengan data masa lalu dan variabel sebab akibat untuk meramalkan permintaan. Peramalan *time series* mengalami perkembangan yang maju seiring dengan kemajuan teknologi komputasi dan informasi ditandai dengan penerapan *artificial neural network* atau jaringan syaraf tiruan pada proses peramalan *time series*.

Peramalan dengan pendekatan kuantitatif metode *casual* yang berhubungan dengan variabel yang diprediksi seperti analisis regresi telah terbukti mampu memecahkan banyak perosalan, terbukti dari penelitian terdahulu yang dilakukan oleh Armi, dkk (2019) dimana metode *double exponential* tidak dapat memberikan alternatif pilihan, tidak memberikan informasi keterkaitan antar variabel satu dan lainnya di sebabkan metode *casual* tidak memiliki model pembelajaran. Begitu juga dengan penelitian yang dilakukan oleh Hari & Dewi (2018) dimana hasil prediksi menggunakan *moving average* secara keseluruhan mampu menunjukkan peramalan yang cukup baik namun teknik dengan

pendekatan ini untuk proses yang variasinya dari model *linear*, waktunya terbatas (*bounded*) dan batasannya telah diketahui, sementara banyak sekali proses yang modelnya tidak dapat dinyatakan dengan persamaan *linear* yang tidak tergantung pada waktu. Karena kelemahan pada teknik peramalan *casual* tersebut pengembangan teknik peramalan selanjutnya berangkat dari pendekatan kualitatif yang kemudian salah satunya di kenal sebagai jaringan syaraf tiruan (JST) yang berangkat dari jaringan syaraf biologis (JSB). Teknik JST memiliki kemampuan belajar, *fault tolerant* serta kemampuan generalisasi permasalahan (Kuswadi, 2007).

Pada penerapannya, peramalan biasanya digunakan untuk aplikasi peramalan besamya penjualan, prediksi nilai tukar uang, prediksi cuaca, dan lain lain. Peramalan dapat dilakukan dengan berbagai macam cara, salah satunya adalah dengan mengembangkan teknik pembelajaran (*machine learning*) dalam disiplin ilmu *artificial intelligence* (AI). *Machine learning* menjawab masalah tersebut dengan melakukan proses pembelajaran yang dapat menemukan suatu data atau fakta baru yang berguna bagi perusahaan. Hasil yang diberikan oleh proses pembelajaran *machine learning* berguna untuk mendukung aktivitas *business intelligence* (Santosa, 2007). Informasi dari data baru tersebut dapat membantu perusahaan khususnya manajemen dalam menetapkan keputusan yang akan mendukung keberhasilan bisnis. Terdapat banyak sekali metode dalam *machine learning* salah satunya JST.

Metode dalam *machine learning* untuk pencarian akurasi dari sebuah prediksi dalam hal ini dengan menggunakan JST mampu mengakuisisi

pengetahuan, mampu melakukan generalisasi dan ekstraksi dari suatu pola data tertentu, dapat menciptakan suatu pola pengetahuan melalui pengaturan diri atau kemampuan belajar (*self-organizing*), dan menemukan suatu jawaban terbaik sehingga mampu meminimalisasi fungsi biaya. JST adalah salah satu pemrosesan suatu informasi yang terinspirasi oleh sistem sel saraf biologi, sama seperti otak yang memproses suatu informasi (Pakaja, dkk, 2015).

JST merupakan salah satu representasi buatan dari otak manusia yang selalu mencoba menstimulasi proses pembelajaran pada otak manusia tersebut. JST dibentuk untuk memecahkan suatu masalah tertentu seperti pengenalan pola atau klasifikasi karena proses pembelajaran. Pada proses memecahkan permasalahan, sebuah sistem yang menggunakan JST dilatih terlebih dahulu untuk mengenali pola-pola data yang ada pada permasalahan tersebut. Sistem akan menghasilkan bobot-bobot dan dapat menentukan hasil prediksi serta perbandingan pola data periode selanjutnya (Andrijasa & Mistianingsih, 2010), sehingga metode peramalan JST dapat di pakai untuk meramalkan masa depan baik peramalan jangka pendek ataupun jangka panjang.

JST mempunyai penggunaan tidak terbatas yang dapat dikategorikan dalam beberapa penerapan kasus yaitu (1) Pengelasan, seperti profil pemasaran, diagnosis medis, mengesahkan tanda tangan, penilaian risiko hutang, pengenalan citra dan lain-lain; (2) Peramalan/ prediksi, yakni perkiraan penjualan yang akan datang, indikator perkembangan ekonomi, keperluan produksi, keperluan tenaga, penelitian cuaca dan lain-lain; (3) Pemodelan, untuk pengaturan proses, sistem pengaturan, struktur kimia, pemampatan isyarat, pengaturan robot dan lain-lain

(Priyono & Rahmat, 2013). Pada penelitian terdahulu oleh Gunaryati, dkk (2018) yang membandingkan hasil peramalan menggunakan metode *eksponensial smoothing* dan JST menghasilkan nilai *error* JST lebih kecil yaitu 10263872,07 sementara *eksponensial smoothing* menghasilkan nilai *error* 102895 yang artinya model peramalan JST lebih akurat karena semakin kecil nilai *error* semakin baik tingkat akurasi. Tahun berikutnya (Mithiya, dkk, 2019) melakukan penelitian dan menyimpulkan peramalan untuk produksi minyak biji-bijian hasilnya GMDH-*neural network* memiliki nilai MSE=1833,72 lebih kecil dan akurat dibanding hasil peramalan menggunakan ARIMA yang memiliki MSE=2811,85.

JST memiliki beberapa algoritma pelatihan yaitu (1)*Perceptron*, untuk klasifikasi dengan arsitektur *single layer*; (2)*ML-perceptron*, untuk klasifikasi dengan arsitektur *multilayer*; (3)*Learning Vector Quantization*, untuk klasifikasi maupun prediksi bersifat *unsupervised learning* pada arsitektur kompetitif; (4)*Backpropagation*, untuk prediksi maupun klasifikasi bersifat *supervised learning* pada arsitektur *multilayer*, dan masih banyak lagi algoritma pelatihan JST. Algoritma yang paling sederhana dari JST digunakan untuk pengklasifikasian pola khusus adalah jaringan syaraf *perceptron* (Suyanto, 2014). Jenis JST yang banyak digunakan adalah JST *backporpagation*. Jenis ini sangat baik untuk melakukan perhitungan dan pengelompokan (Priyono & Rahmat, 2013). Jenis JST lainnya adalah jaringan Kohonen yang mempunyai kemampuan dalam menemukan hubungan suatu set data yang rumit dan juga sangat baik untuk mengetahui suatu corak tertentu.

Jaringan perambatan mundur (*backpropagation*) merupakan salah satu algoritma JST yang dapat digunakan dalam menyelesaikan masalah-masalah rumit berkaitan dengan identifikasi, peramalan/prediksi, pengenalan pola dan sebagainya. Pada algoritma *backpropagation* arsitektur jaringan dilatih dengan menggunakan metode belajar terbimbing (*supervised learning*). Pelatihan dilakukan berulang-ulang sampai menghasilkan arsitektur jaringan terbaik dengan MSE paling kecil atau MSE mendekati nilai *goals*, ini menjadi kelebihan dari algoritma *backpropagation*.

Menurut penelitian terdahulu yang dilakukan Marjiyono, dkk (2018), yang membahas tentang penggunaan JST untuk meramal permintaan pada perusahaan retail, penelitian ini menerapkan JST *backpropagation* untuk memprediksi penjualan pada Citramart. Pelatihan dilakukan dengan mengkombinasikan beberapa *learning rate*, lapisan tersembunyi dan node tersembunyi sehingga MSE yang optimal dapat didapatkan. Hasil penelitiannya, terdapat perbedaan arsitektur terbaik untuk setiap item barang. Pada AQUA PET 600ML, mendapatkan akurasi sebesar 86%. Sedangkan pada DJA SPR 16 ECER dapatkan nilai akurasi sebesar 89%. Begitu juga dengan penelitian terdahulu selanjutnya yang dilakukan oleh Aprilianto, dkk (2018) menyimpulkan perbandingan hasil peramalan penjualan menggunakan metode JST *backpropagation* lebih baik dibandingkan dengan metode *times series* konvensional (statistika). Hal ini disebabkan oleh perbedaan *input* dan proses pengolahan data. Pada metode JST *backpropagation* terdapat model arsitektur jaringan yang memungkinkan untuk membuat model peramalan yang optimal sehingga hasil bisa mendekati aktualnya sedangkan pada metode

times series konvensional hanya deret angka yang dijadikan input untuk melakukan peramalan.

Peramalan dengan menggunakan JST *backpropagation* diharapkan dapat memberikan alternatif dalam memperkirakan dan memprediksi penjualan AMDK setiap periodenya yang bertujuan untuk memberikan informasi peramalan penjualan produk AMDK dan alternatif pengambilan keputusan oleh pihak perusahaan dalam menentukan jumlah produksi, sehingga tidak terjadi kekurangan maupun penumpukan stok barang di gudang yang dapat merugikan pihak perusahaan. Karena hasil peramalan sifatnya adalah pendekatan, maka dalam perhitungan hasil peramalan akan dilakukan analisis terhadap nilai *error* atau selisih hasil peramalan dengan data aktual menggunakan *Mean Square Error* (MSE).

1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, maka dapat diketahui bahwa pokok bahasan penelitian yaitu:

- Apa saja variabel yang mempengaruhi penjualan AMDK menurut analisis peramalan menggunakan algoritma *backpropagation*?
- Berapa tingkat akurasi hasil peramalan yang diperoleh dari penggunaan algoritma *backpropagation* untuk penjualan AMDK?

1.3. Batasan Masalah

Agar penelitian ini terarah dan pembahasan relevan maka diberi batasan-batasan dan ruang lingkup sebagai berikut:

- a. Meramal penjualan produk AMDK menggunakan JST *backpropagation*.
- b. Data latih dan uji pada penelitian ini menggunakan data penjualan AMDK DAXU dari PDAM Tirta Sembada Sleman bulan Januari - Agustus 2019 sebanyak 243 data.
- c. Variabel yang digunakan adalah variabel eksternal atau faktor luar yang tidak dapat dicegah oleh perusahaan yang mempengaruhi besarnya penjualan pada unit bisnis AMDK DAXU PDAM Tirta Sembada Sleman
- d. Meramal penjualan menggunakan 229 hari untuk 14 hari ke depan.
- e. Hasil peramalan dapat digunakan untuk periode selanjutnya sesuai kebutuhan perusahaan.
- f. Pengembangan *prototype* menggunakan Matlab untuk memudahkan dalam pelatihan, pengujian dan kebutuhan visualisasi data.
- g. Pengujian sebagai alat ukur peramalan menggunakan MSE dan Akurasi.

1.4. Tujuan Penelitian

Tujuan dari penelitian ini adalah mendapatkan hasil peramalan penjualan produk AMDK DAXU sehingga dapat membantu sebagai dasar dalam menentukan keputusan manager dan pimpinan.

1.5. Manfaat Penelitian

Penelitian ini diharapkan dapat bermanfaat bagi:

- a. Pembaca, menjadi sarana untuk menambah wawasan, sumber bacaan dan bahan untuk penelitian selanjutnya.
- b. Peneliti, dapat mengaplikasikan ilmu-ilmu yang diterima selama perkuliahan serta dapat mengaitkan teori yang diterima selama kuliah dengan penerapan dan kasus di lingkungan daerah khususnya PDAM Tirta Sembada Sleman.
- c. Perusahaan, menjadi solusi dalam meramal penjualan AMDK yang fluaktif.
- d. Perusahaan, dapat menjadi alternatif pertimbangan untuk mengambil keputusan dalam proses produksi maupun marketing.



BAB II

TINJAUAN PUSTAKA

2.1. Tinjauan Pustaka

Beberapa penelitian terdahulu yang dijadikan acuan dan tinjauan pustaka pada penelitian ini diantaranya:

Penelitian oleh Hari & Dewi (2018) menggunakan metode *moving average* untuk peramalan transaksi dan perdagangan saham mendapatkan nilai akurasi 76,7% akan tetapi jika dilakukan interval waktu hasil *moving average* tidak dapat menjadi standart profitabilitas karena volatilitas harga saham begitu juga dengan penelitian dibidang lain yang dilakukan oleh Armi, dkk (2019) yang menggunakan metode *double exponential smoothing* untuk peramalan angka inflasi walaupun mendapatkan peramalan dengan MSE=0,4852394 tetapi karena metode peramalan yang digunakan oleh kedua penelitian adalah statistik dimana data inputan adalah data *linear* (deret angka) hasil peramalan tidak memberikan model alternatif lainnya serta tidak memberikan proses pembelajaran sehingga hasil peramalan jauh dari nilai aktual.

Penggunaan metode peramalan jenis *neural network* dilakukan oleh Marjiyono, dkk (2018), penelitian ini memprediksi penjualan barang pada toko retail Citramart. Data yang digunakan sebagai data prediksi yaitu kegiatan kampus dan data historis penjualan AQUA PET 600 ML dan DJA SPR 16 ECER tahun 2014 dan 2015. Hasil penelitian ini dengan menggunakan 3 variabel input yaitu hari, tanggal dan kegiatan kampus untuk memprediksi penjualan, pada

AQUA PET 600 ML didapatkan nilai MSE pelatihan sebesar 0,0265 dan MSE pengujian sebesar 0.0430 atau akurasi sebesar 86%. Sedangkan pada DJA SPR 16 ECER dapatkan nilai MSE pelatihan sebesar 0,0242 dan MSE pengujian sebesar 0.0265 atau akurasi sebesar 89%. Penelitian tersebut menggunakan metode pembobotan acak. Penelitian selanjutnya sebaiknya dapat mengkolaborasikan dengan metode lain untuk menentukan bobot awal dan meningkatkan nilai aktual.

Penelitian terdahulu yang menggunakan JST selanjutnya dilakukan oleh Chopra, dkk (2019) yang menggunakan metode JST untuk mengetahui dan memprediksi dampak dari harga pasar saham di India sebelum dan setelah demonetisasi, hasilnya demonetisasi tidak memiliki dampak besar terhadap harga saham dalam jangka waktu pendek, peramalan ini menghasilkan MSE=0,999 dari model arsiterturnya, sebaiknya dilakukan penelitian lebih lanjut dengan menggunakan dan atau mengkombinasikan metode lain untuk meramal jangka waktu panjang dimana nilai parameter yang akan digunakan sebaiknya disesuaikan dengan permasalahan dan teori yang ada.

Bidang lainnya yaitu akademik penerapan metode JST dilakukan oleh Windarti & Sulistyowati (2017) untuk mengukur tingkat korelasi nilai UAN dan IP tahun pertama yaitu IP semester 1 dan semester 2 terhadap masa studi mahasiswa menggunakan JST-BP. Kemudian menganalisa apakah atribut tersebut memiliki korelasi positif atau tidak terhadap masa studi yang ditempuh mahasiswa. Hasilnya korelasi antara nilai UAN, IP Semester 1 & 2 terhadap masa studi mahasiswa memiliki korelasi negatif artinya tidak memiliki korelasi, berdasarkan

pada proses pelatihan jaringan menghasilkan nilai akurasi MSE 0.0051721 dan koefisien korelasi sebesar 0.56563. Nilai MSE yang diperoleh sedikit lebih tinggi dari separuh batas maksimal yaitu 0.5 (MSE = 0.56563) sehingga belum menghasilkan kinerja yang maksimal dan proses pelatihan dan pengujian dapat dilakukan kedalam beberapa model atau bentuk dengan mengubah nilai parameter yang digunakan seperti jumlah parameter *epoch*, nilai laju belajar (*learning rate*), batas *error*, fungsi aktivasi, jumlah lapisan pada *hidden layer* dan lain-lain.

Memperkuat studi literatur terkait perbandingan antara metode peramalan statistik (konvensional) dan metode *neural network*, peneliti juga melakukan tinjauan pustaka penelitian yang dilakukan oleh Aprilianto, dkk (2018) yang memodelkan sistem komputasi JST dengan *error output* terkecil sebagai alat peramalan penjualan cokelat di Kabupaten Blitar dan menganalisis tingkat akurasi metode peramalan dengan data *testing* dibandingkan peramalan versi *times series* konvensional. Hasilnya jumlah penjualan terendah yaitu pada bulan Agustus 2017 yaitu sebesar 2306,22. Sedangkan jumlah permintaan tertinggi yaitu terjadi pada bulan Januari 2018 sebesar 2546,93, sehingga pada bulan yang mengalami penurunan penjualan dalam peramalan, perbandingan hasil peramalan penjualan menggunakan metode JST lebih baik dibandingkan dengan metode *times series* konvensional.

Perbandingan metode peramalan *eksponensial smoothing* dan metode JST-BP untuk data pengguna pita lebar (*broadband*) di Indonesia yang diteliti oleh Gunaryati, dkk (2018) bertujuan membandingkan model peramalan dengan metode JST-BP dan *double exponential method* untuk mendapatkan hasil yang

akurat. Hasilnya adalah antara metode brown dan metode holt mencapai nilai yang signifikan. Pada metode brown didapatkan nilai $MSE = 1,02895$, metode holt nilai $MSE = 1,16432$ dan metode JST untuk arsitektur 3 yaitu 8-12-1 dengan nilai $MSE = 10263872,07$. Artinya model peramalan paling cocok serta akurat untuk memprediksi dan meramal data pengguna pita lebar di Indonesia pada tahun yang akan datang (2016-2020) adalah model peramalan dengan JST-BP. Penelitian selanjutnya sebaiknya variabel yang mempengaruhi tingkat akurasi dapat diteliti dan mencoba bereksperimen dengan metode lain agar akurasi lebih optimal.

Penelitian terdahulu selanjutnya yang dilakukan oleh Mithiya, dkk (2019) meramalkan produksi minyak biji-bijian menggunakan metode statistika (ARIMA) dan *neural network* (GMDH-NN) untuk mengatasi kebutuhan dan merumuskan strategi yang tepat untuk memenuhi *demand-supply*. Hasil ARIMA $MSE = 2811,85$, $MAE = 2008,66$ dan $MAPE = 11,71$ sementara GMDH-NN $MSE = 1833,72$, $MAE = 1473,99$, $MAPE = 5,275$. Hasil percobaan kedua model menunjukkan bahwa model GMDH-NN adalah metode yang tempat untuk menangani data deret waktu dan kegiatan peramalan.

Penelitian terdahulu selanjutnya yang melakukan pendekatan peramalan dengan JST dan sistem pakar CF oleh Pakaj, dkk (2015) Peramalan penjualan mobil honda tahun 2015 dengan variabel *input* data penjualan daerah 30,000 unit, penjualan *dealer* 25,000, penjualan tunai 25,000, $CF = 0.5$ dan kredit 19,000 menghasilkan ramalan penjualan sebanyak 29579 unit dengan target *error* 4,205 %. Kelemahan dari penelitian ini, CF sebagai nilai pembanding hasil peramalan

JST kurang akurat, sehingga untuk penelitian dan pengembangan selanjutnya dapat melibatkan seorang pakar untuk membantu memberikan kemungkinan kepastian dan pembobotan awal dikembangkan menggunakan metode pembobotan lain sehingga proses peramalan dapat lebih optimal.

Bidang lain yang menerapkan pendekatan peramalan JST dengan sistem pakar CF diteliti oleh Maharani (2013) dimana CF sebagai basis pengetahuan yang didapat dari pakar yakni dokter. Diagnosa 10 penyakit demam pada anak dengan 40 gejala, hasilnya dengan menggunakan sebanyak 40 gejala sebagai data pelatihan dengan rekam medic dari 30 pasien, didapat nilai MSE=0,000017427 dan hasil pengujian tersebut tingkat keakuratan sebesar 86,67 %.

Keseluruhan penelitian yang telah dibahas dalam bagian ini terdapat beberapa hal yang dapat disimpulkan yaitu penelitian terkait peramalan dan prediksi menggunakan data *time series* namun menggunakan metode yang berbeda yakni metode statistika (konvensional), metode JST dan membandingkan metode statistik dan JST. Penelitian terdahulu memiliki kelemahan dan kekurangan yang sudah dipaparkan pada uraian tinjauan pustaka, kelemahan tersebut yang akan dikembangkan pada penelitian ini.

2.2. Keaslian Penelitian

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian

Penerapan Jaringan Syaraf Tiruan dengan Algoritma *Backpropagation* untuk Peramalan Penjualan Air Minum Dalam Kemasan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	<i>Forecasting System Approach for Stock Trading with Relative Strength Index and Moving Average Indicator</i>	Yulius Hari, Lily Puspita Dewi, Journal of Telecommunication, Electronic and Computer Engineering Vol.10 No.2-3, 2018 e-ISSN: 2289-8131	Menganalisis peramalan transaksi dan stok saham menggunakan RSI untuk mengukur indikator kekuatan saham dan <i>moving average</i> sebagai metode peramalan untuk mengetahui waktu yang baik membeli dan menjual saham agar tidak berisiko tinggi oleh investor.	Berdasarkan pengujian fungsiionalitas, sistem dapat digunakan secara menyeluruh dan mampu menjalankan dan menunjukkan hasil. Kemudahan penggunaan sistem ini hasilnya cukup baik dengan skor 3,85 dari 5. Dari segi keakuratan sistem adalah 76,7%. Sistem juga dapat menganalisis harga data historis pada interval waktu yang dipilih.	Peramalan dengan metode statistik inputanya adalah deret waktu yang tidak dapat memberikan alternatif dari model peramalan sehingga penggunaan metode kecerdasan buatan/ <i>neural network</i> yang dapat memberikan alternatif pilihan dari <i>machine learning</i> membantu memprediksi hasil yang lebih baik.	Penelitian Yulius Hari dan Lily Puspita dewi menggunakan metode statistik yaitu Moving Average untuk meramal indeks saham yang bersumber dari server data Bloomberg dan Yahoo Finance. Sementara penelitian yang akan dilakukan menggunakan metode JST dimana JST <i>backpropagation</i> untuk mencari arsitektur terbaik dari peramalan penjualan AMDK menggunakan data <i>time series</i> dan data eksternal lainnya.
2	Peramalan Angka Inflasi Kota Samarinda Menggunakan Metode Double Exponential	Akmal Erfani Armi, Awang Harsa Kridalaksana dan Zainal Arifin, Jurnal Ilmu	Melakukan peramalan angka inflasi dalam 1 tahun yang terjadi di Kota Samarinda pada tahun 2018	Berdasarkan inflasi tahun 2013 hingga 2017 menghasilkan peramalan angka inflasi untuk tahun 2018 dengan nilai <i>error</i> .	Penelitian tidak menjelaskan faktor-faktor yang tingkat akurasi yang didapat. Hasil peramalan kurang mendekati nilai aktual. Perlu adanya...	Penelitian yang dilakukan oleh Akmal Erfani dkk menggunakan metode <i>double exponential</i> untuk meramalkan inflasi menggunakan data inflasi tahun 2013-2017.

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	Smoothing (Studi Kasus : Badan Pusat Statistik Kota Samarinda)	Komputer Vol. 14 No.1, 2019	mendatang menggunakan metode <i>double exponential smoothing</i>	terkecil pada nilai alfa 0,3 yang di ukur menggunakan $MSE = 0,4852394$.	penelitian dengan metode lain agar hasil peramalan dapat memberikan alternatif pilihan juga model peramalan yang optimal sehingga hasil bisa mendekati aktualnya.	Sementara pada penelitian yang akan dilakukan menggunakan metode JST <i>backpropagation</i> untuk mencari model peramalan terbaik serta faktor yang mempengaruhi tingkat akurasi peramalan AMDK.
3	Penggunaan Jaringan Syaraf Tiruan untuk Meramalkan Permintaan pada Perusahaan Retail	Marjiyono, Bambang Soedijono WA, EMha Taufiq Luthfi, Seminar Nasional Teknologi Informasi dan Multimedia, 2018	Memprediksi penjualan barang pada Citramart menggunakan data kegiatan kampus dan data historis penjualan AQUA PET 600 ML dan DJA SPR 16 ECER tahun 2014 dan 2015.	Pada AQUA PET 600 ML di dapatkan nilai MSE pelatihan sebesar 0,0265 dan MSE pengujian sebesar 0,0430 atau akurasi sebesar 86%. Pada DJA SPR 16 ECER di dapatkan nilai MSE pelatihan sebesar 0,0242 dan MSE pengujian sebesar 0,0265 atau akurasi sebesar 89%.	Penelitian selanjutnya sebaiknya dapat mengkolaborasikan dengan metode lain untuk menentukan bobot awal.	Pada penelitian Marjiyono dkk menggunakan metode <i>backpropagation</i> untuk meramal penjualan barang dengan pembobotan acak. Perbedaan pada penelitian yang akan di lakukan adalah mengkombinasi dengan metode <i>nguyen-widraw</i> untuk pembobotan diawal dan dengan jumlah jenis produk yang lebih banyak.
4	<i>Artificial Neural Networks Based Indian Stock Market Price Prediction: Before and After</i>	Siddheshwar Chopra, Dipti Yadav dan Anu Nagpal Chopra, International Journal of Swarm	Memprediksi pengaruh harga pasar saham di India menggunakan JST <i>Levenberg-Marquardt</i>	Nilai regresi yang ditemukan selama pelatihan adalah 0,999 dari semua model jaringan JST dirancang, divalidasi dengan nilai	Pelatihan dengan metode JST <i>Levenberg-Marquardt backpropagation</i> dapat memberikan hasil kinerja yang baik untuk	Penelitian yang dilakukan Siddheshwar Chopra dkk yaitu memprediksi harga saham dengan <i>data time series</i> menggunakan metode JST <i>Levenberg-Marquardt</i>

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	Demonetization	Intelligence and Evolutionary Computation Vol.8 Issue 1(1-7), 2019	<i>backpropagation</i> sebelum dan setelah demonetisasi. Menggunakan data dari sembilan saham dan indeks CNX NIFTY50 untuk prediksi masa mendatang. Set data untuk pelatihan, pengujian, dan validasi di bawah 8 tahun.	aktual sebelum dan setelah demonetisasi. Hasilnya demetisasi tidak memiliki dampak besar pada harga pasar saham dalam periode jangka pendek.	permasalahan apabila datanya bersifat non-linier. Saran untuk penelitian selanjutnya ialah dalam penentuan nilai parameter yang akan digunakan sebaiknya disesuaikan dengan permasalahan dan teori yang ada.	dengan pembobotan acak. Sementara penelitian kali ini meneliti dengan JST <i>backpropagation</i> dan menggunakan <i>nguyen-widrow</i> untuk pembobotan awal dalam peramalan penjualan AMDK.
5	Korelasi Nilai UN, IP Tahun Pertama Terhadap Masa Studi Dengan Backpropagation	Mariana Windarti, Istri Sulistyowati, Jurnal Ilmiah SISFOTENIKA Vol.9 No.2, 2019	Menganalisa dengan mengukur tingkat korelasi nilai UAN dan IP tahun pertama yaitu IP semester 1 dan semester 2 terhadap masa studi mahasiswa menggunakan JST <i>backpropagation</i> . Menganalisa korelasi atribut positif atau tidak terhadap masa studi yang ditempuh	Korelasi antara nilai UAN, IP Semester 1 & 2 terhadap masa studi mahasiswa memiliki korelasi negatif atau tidak memiliki korelasi berdasarkan pada proses pelatihan jaringan menghasilkan nilai akurasi MSE 0.0051721 dan koefisien korelasi sebesar 0.56563.	Nilai MSE yang diperoleh sedikit lebih tinggi dari separuh batas maksimal yaitu 0.5 (MSE = 0.56563) sehingga belum menghasilkan kinerja yang maksimal dan proses pelatihan dan pengujian dapat dilakukan kedalam beberapa model atau bentuk dengan mengubah nilai parameter yang digunakan seperti jumlah	Penelitian yang dilakukan Mariana & Istri menggunakan algoritma <i>backpropagation</i> dengan pembobotan acak, sementara pada penelitian ini akan menggunakan <i>backpropagation</i> dengan pembobotan awal menggunakan <i>nguyen-widrow</i> untuk meramal penjualan AMDK dan memberikan informasi faktor-faktor yang mempengaruhi penjualan AMDK serta mengimplementasikan sistem

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			mahasiswa.		parameter <i>epoch</i> , nilai laju belajar (<i>learning rate</i>), batas <i>error</i> , fungsi aktivasi, jumlah lapisan pada <i>hidden layer</i> dan lain-lain. Penelitian ini masih dalam skala penelitian sehingga belum ada implementasi dalam bentuk aplikasi <i>prototype</i> .	peramalan dalam bentuk <i>prototype</i> aplikasi.
6	Penerapan Jaringan Syaraf Tiruan untuk Peramalan Penjualan Dalam Mendukung Pengembangan Agroindustri Coklat di Kabupaten Blitar	Hendri Cahya Aprilianto, Sri Kumalaningsih, Imam Santoso, Jurnal Habitat Vol.29 No 3, 2018	Memodelkan sistem komputasi JST dengan <i>error output</i> terkecil sebagai alat peramalan penjualan coklat di Kabupaten Blitar dan menganalisis tingkat akurasi metode peramalan dengan data <i>testing</i> dibandingkan peramalan versi <i>times series</i> .	Perbandingan hasil peramalan penjualan menggunakan metode JST lebih baik dibandingkan dengan metode <i>times series</i> konvensional.	Tidak dijelaskan dalam penelitian berapa tingkat akurasi dari kedua metode, sebaiknya dijelaskan tingkat akurasi persentase untuk masing-masing metode sehingga pembaca dan penelit selanjutnya dapat memahami dengan lebih baik.	Perbandingan metode <i>backpropagation</i> dan <i>time series</i> yang dilakukan oleh Hendri dkk menggunakan 1 metode konvensional dan 1 metode <i>neural network</i> , kedua metode sebatas untuk membandingkan tingkat akurasi, perbedaan dari penelitian Hendri dkk kali ini akan menggunakan metode, <i>backpropagation</i> dan <i>nguye-widraw</i> sebagai pembobatan awal.
7	Perbandingan Metode Peramalan <i>Eksponensial</i>	Aris Gunaryati, Fauziah, Septi Andryana, Jurnal	Membandingkan model peramalan dengan metode JST	Hasilnya adalah antara metode brown dan metode holt mencapai	Saran untuk penelitian selanjutnya sebaiknya faktor yang	Fokus penelitian yang dilakukan oleh Aris Gunaryati dkk adalah

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian (Lanjutan)

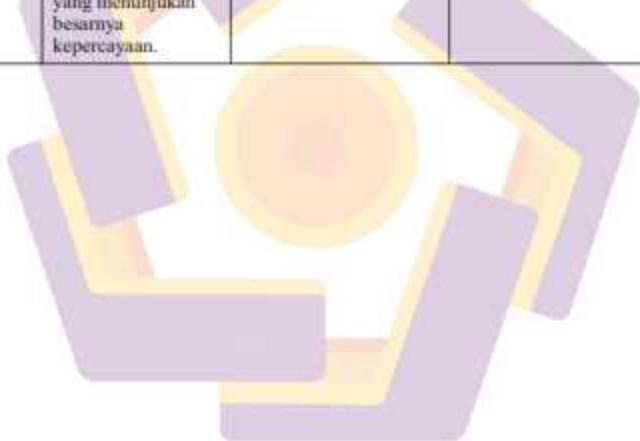
No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	<i>Smoothing dan Metode Jaringan Syaraf Tirum Propagasi Balik untuk Data Pengguna Pita Lebar (Broadband) di Indonesia</i>	Sistem Informasi, Teknologi Informatika dan Komputer Vol.8 No.2, 2018	<i>backpropagation</i> dan <i>double exponential method</i> untuk mendapatkan hasil yang akurat.	nilai yang signifikan. Pada metode brown didapatkan nilai MSE= 1,02895, metode holt nilai MSE=1,16432 dan metode JST untuk arsitektur 3 yaitu 8-12-1 dengan nilai MSE=10263872,07. Artinya model peramalan paling cocok serta akurat untuk memprediksi dan meramal data pengguna pita lebar di Indonesia.	mempengaruhi tingkat akurasi dapat diteliti dan mencoba bereksperimen dengan metode lain agar akurasi lebih optimal,	membandingkan metode apa yang terbaik untuk peramalan penggunaan pita lebar yakni antara metode <i>double exponential smoothing</i> yang merupakan model peramalan statistik dengan model JST. Sementara pada penelitian yang akan dilakukan dalam penelitian ini menggunakan algoritma JST <i>backpropagation</i> untuk dapat mengetahui faktor dan lebih meningkatkan hasil tingkat akurasi peramalan.
8	<i>Time Series Analysis and Forecasting of Oilseeds Production in India: Using Autoregressive Integrated Moving Average and Group Method of Data Handling Neural Network</i>	Debasis Mithiya, Lakshmikanta Datta, Kumarjit Mandal, Asia Journal of Agricultural Extension, Economic & Sociology Vol.30 No.2(1-14), 2019	Meramalkan produksi minyak biji-bijian dengan menggunakan metode statistika (ARIMA) dan <i>neural network</i> GMDH-NN) untuk mengatasi kebutuhan, merumuskan strategi yan tepat untuk menjembatani <i>demand-supply</i> .	Hasil ARIMA MSE=2811,85, MAE=2008,66 dan MAPE=11,71 sementara GMDH-NN MSE=1833,72, MAE=1473,99, MAPE=5,275. Hasil percobaan kedua model menunjukan bahwa model GMDH-NN adalah metode yang tempat untuk menangani data deret	Saran untuk penelitian selanjutnya sebaiknya faktor atau variabel yang mempengaruhi tingkat akurasi dapat diteliti dan mencoba bereksperimen dengan metode lain agar akurasi lebih optimal.	Penelitian yang dilakukan oleh Debasis Mithiya dkk membandingkan antara prediksi menggunakan metode <i>time series</i> statistika ARIMA dan GMDH-NN pada prediksi minyak biji-bijian. Sementara penelitian ini menggabungkan data <i>timeseries</i> dan data luar dari <i>timeseries</i> menggunakan JST <i>backporpagation</i> dan metode <i>nguyen-widraw</i> untuk pembobatan awal dari

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				waktu dan menyediakan teknik yang menjanjikan dalam deret waktu metode peramalan.		peramalan penjualan AMDK.
9	Peramalan Penjualan Mobil Menggunakan Jaringan Syaraf Tiruan dan Certainty Factor	Fachrudin Pakaja, Agus dan Purwanto, Jurnal EECCIS Vol. 6, No. 1, 2015	Memprediksi penjualan mobil 2005-2010. Proses peramalan menggunakan metode <i>certainty factor (CF)</i> sebagai nilai banding pada bobot koreksi yang telah di latih dalam jaringan <i>backpropagation</i> untuk prediksi yang optimal.	Peramalan penjualan mobil honda tahun 2015 dengan variabel input data penjualan daerah 30.000 unit, penjualan <i>dealer</i> 25.000, penjualan tunai 25.000, $CF = 0.5$ dan kredit 19.000 menghasilkan ramalan penjualan sebanyak 29579unit dengan target error 4,205%.	CF sebagai nilai pembanding hasil peramalan JST kurang akurat, sehingga untuk penelitian dan pengembangan selanjutnya dapat melibatkan seorang pakar untuk membantu memberikan kemungkinan kepastian dan keakuratan hasil penjualan sehingga proses peramalan dapat lebih optimal.	Penelitian yang dilakukan oleh Fachrudin dkk tidak secara aktif melibatkan seorang pakar penjualan dari validasi oleh bobot CF yang di kombinasikan, sementara pada penelitian kali ini akan mengkombinasikan dengan bobot <i>nguyen-widraw</i> terhadap setiap data penjualan yang tujuannya mirip dengan bobot CF, sehingga diharapkan hasil peramalan akan lebih optimal.
10	Aplikasi Diagnosa Gejala Demam Pada Balita Menggunakan Metode Certainty Factor (CF) dan Jaringan Syaraf Tiruan (JST). (Study Kasus : RS.	Septya Maharani, Tesis Sistem Informasi Universitas Diponegoro Semarang, 2013	Mengimplementasikan kombinasi metode CF dan JST sebagai nilai parameter demam dengan mengadopsi penyelesaian dari pakar. Metode CF sebagai rule dan	Hasilnya dengan menggunakan sebanyak 40 gejala sebagai data pelatihan dengan rekam medis dari 30 pasien, didapat nilai $MSE=0,000017427$ dan hasil pengujian tersebut tingkat keakuratan	Masih memiliki keterbatasan yang dapat digunakan sebagai dasar untuk pengembangan penelitian lebih lanjut, seperti pengembangan pembelajaran mesin dan menambah basis pengetahuan yang lebih	Penelitian oleh Septya Maharani menggunakan CF dan JST untuk mendiagnosa jenis demam pada balita menggunakan data pelatihan dari rekam medis pasien. Sementara pada penelitian ini akan menggunakan data set penjualan AMDK dan

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	Umum Abdul Wahab Syahranie)		hasil CF tersebut akan membentuk pola JST yang merupakan penggabungan nilai parameter klinis yang menunjukkan besarnya kepercayaan.	sebesar 86,67%.	kompleks, juga parameter yang akan digunakan sebaiknya disesuaikan dengan permasalahan dan teori yang ada.	kombinasi bobot menggunakan <i>nguyen-widrow</i> serta mengetahui faktor yang berpengaruh terhadap nilai penjualan dan akurasi.



2.3. Landasan Teori

Air merupakan salah satu sumber daya alam dan kebutuhan hidup yang paling penting dan merupakan unsur dasar bagi semua kehidupan di bumi. Tanpa air, berbagai proses kehidupan tidak dapat berlangsung. Masyarakat pada umumnya mendapatkannya dari dua sumber, yaitu dari Perusahaan Air Bersih (PAM) dan air sumur. Perusahaan Air Bersih adalah perusahaan yang melakukan kegiatan pengadaan, penjernihan, penyediaan dan penyaluran air bersih secara langsung melalui pipa penyalur atau mobil tangki kepada pelanggan ke rumah tangga, industri dan konsumen lainnya dengan tujuan komersial (Badan Pusat Statistik, 2018).

Perusahaan Daerah Air Minum atau PDAM merupakan salah satu unit usaha milik daerah, yang bergerak dalam distribusi air bersih bagi masyarakat umum. PDAM terdapat di setiap provinsi, kabupaten di seluruh Indonesia. PDAM merupakan perusahaan daerah sebagai sarana penyedia air bersih yang diawasi dan dimonitor oleh aparat eksekutif maupun legislatif daerah. Perusahaan air minum yang dikelola negara secara modern sudah ada sejak tahun 1920an.

2.3.1. Air Minum Dalam Kemasan (AMDK)

Berdasarkan keputusan Menteri Perindustrian Republik Indonesia Nomor 11/M-IND/PER/3/2017 telah memberikan definisi yang jelas mengenai AMDK, yaitu air yang telah diproses tanpa bahan pangan lainnya dan bahan tambahan pangan, dikemas, dan aman untuk diminum (Kemenperin, 2017). Seiring dengan meningkatnya jumlah penduduk dari tahun ke tahun, tentunya kebutuhan AMDK

akan semakin meningkat. Menurut Asosiasi Perusahaan Air Minum dalam Kemasan Indonesia atau ASPADIN (2015), pada tahun 2014 masyarakat Indonesia mengkonsumsi 23,1 miliar liter air minum dalam kemasan untuk dikonsumsi, jumlah tersebut meningkat 11,3% dari permintaan di tahun 2013 yang hanya sebesar 20,48 miliar liter air per tahun (Sifiani & Utomo, 2017).

Pada tahun 2012 produksi air minum dalam kemasan (AMDK) tercatat sebesar 19,86 miliar liter, kemudian pada tahun 2013 produksi naik menjadi sebesar 20,39 miliar liter. Kenaikan tersebut terus berlanjut pada tahun 2014 menjadi sebesar 23,16 miliar liter. Pada tahun 2015 produksi terus tumbuh naik menjadi sebesar 24,78 miliar liter. Sementara pada tahun 2016 sebesar 26,90 miliar liter. Jumlah produksi AMDK di Indonesia dapat dilihat pada Tabel 2.2.

Tabel 2.2 Jumlah Produksi AMDK di Indonesia

Tahun	Jumlah Produksi (miliar liter)	Kenaikan
2012	19,86	-
2013	20,39	3%
2014	23,16	14%
2015	24,78	7%
2016	26,90	9%

Apabila dilihat dari besarnya tingkat konsumsi AMDK di Indonesia perkembangan produksi total AMDK dalam kurun waktu 2012 – 2016, produksi AMDK tumbuh rata-rata sebesar 8%. Hal ini dilihat oleh PDAM Tirta Sembada Sleman sebagai peluang bisnis. PDAM Tirta Sembada Sleman kemudian memproduksi AMDK DAXU sejak tahun 2016 melalui Unit Bisnisnya.

2.3.2. Peramalan Penjualan

Peramalan adalah sebuah perkiraan terhadap sesuatu yang akan terjadi dimasa yang akan datang. Peramalan memang tidak akan tepat 100% karena peramalan bersifat pendekatan dan ketidakpastian. Peramalan merupakan suatu proses memperkirakan peristiwa yang akan terjadi di masa yang akan datang dengan mendasarkan diri pada variabel-variabel tertentu. Artinya suatu peristiwa yang akan terjadi merupakan suatu akibat dari varibel-variabel lain yang secara langsung ataupun tidak langsung mempengaruhinya. Variabel-varibel yang mempengaruhi ini sering disebut variabel *independent*. Manfaat dari hasil peramalan adalah, dapat mengetahui perkiraan yang akan terjadi di masa yang akan datang, akan sangat bermanfaat bagi kita untuk menetapkan berbagai kebijakan. Kebijakan tersebut disesuaikan juga dengan hasil ramalan dan pengaruhnya terhadap pengadaaan bahan baku, jumlah tenaga kerja, kapasitas kerja, armada angkutan, pembelanjaan dan sebagainya (Shimbun, 2016).

Terdapat 2 pendekatan umum untuk jenis metode peramalan yaitu kualitatif dan kuantitatif. Peramalan kualitatif menggabungkan faktor seperti intuisi, emosi, pengalaman pribadi, dan sistem nilai pengambilan keputusan untuk meramal. Metode kuantitatif terdiri dari peramalan deret waktu (*time series*) dan peramalan sebab akibat. Peramalan deret waktu dilakukan berdasarkan data-data yang sudah ada sebelumnya, kemudian data diolah sehingga diketahui *trend* maupun berbentuk siklus. Peramalan sebab akibat dilakukan berdasarkan data sebelumnya tetapi menggunakan data dari variabel lain yang menentukan atau mempengaruhinya di masa yang akan datang (Marjiyon, dkk, 2018).

Menurut (Rohman, 2006) definisi penjualan adalah kegiatan yang bertujuan untuk mencari atau mengusahakan agar ada pembeli atau ada permintaan pasar yang cukup baik atau banyak terhadap barang dan jasa yang dipasarkan pada tingkat harga yang menguntungkan. Dalam sebuah perusahaan, peramalan penjualan mempunyai dampak yang luas terhadap fungsi-fungsi yang ada pada perusahaan seperti produksi, pembelanjaan, personalia, promosi dan keuangan. Hampir semua bagian perusahaan membutuhkan peramalan penjualan, karena itu peramalan penjualan paling strategis pada suatu perusahaan.

Peramalan penjualan jangka panjang dibutuhkan oleh perusahaan dalam keputusan pengembangan produk baru, mengurangi jumlah produk yang dihasilkan atau dipasarkan, penganggaran modal, pembukaan daerah pemasaran baru dan keputusan lainnya. Peramalan penjualan jangka pendek digunakan untuk melakukan jadwal produksi, perencanaan kebutuhan bahan, prediksi arus kas dan keputusan lainnya. Peramalan penjualan merupakan salah satu alat bantu yang penting dalam perencanaan yang efektif dan efisien. Salah satu peramalan yang penting dan sering dilakukan oleh perusahaan adalah peramalan penjualan. Semua kegiatan perusahaan pada intinya adalah menjual AMDK sebanyak-banyaknya dan meminimalkan biaya untuk mendapatkan laba yang maksimal. Peramalan penjualan merupakan bagian paling strategis bagi perusahaan dimana informasi yang diperoleh dari peramalan penjualan AMDK di pasaran.

2.3.3. Menghitung Kesalahan Peramalan

Menurut (Heizer & Render, 2010) beberapa perhitungan yang dapat digunakan untuk menghitung kesalahan peramalan total yaitu deviasi mutlak

rerata (*Mean Absolute Deviation* - *MAD*), kesalahan kuadrat rata-rata (*Mean Squared Error* - *MSE*), dan kesalahan persen mutlak rata-rata (*Mean Absolute Percent Error* - *MAPE*). Perhitungan-perhitungan ini dapat digunakan untuk membandingkan model-model peramalan yang berbeda, mengawasi peramalan, dan untuk memastikan peramalan berjalan dengan baik. Berikut adalah beberapa cara dan rumusan untuk mengukur kesalahan peramalan (Santoso, 2009):

a. Deyiasi Rata-rata Absolut (*Mean Absolute Deviation - MAD*)

MAD adalah ukuran pertama kesalahan peramalan keseluruhan untuk sebuah model. Nilai dihitung dengan mengambil jumlah nilai absolut dari tiap kesalahan peramalan dibagi dengan jumlah periode data n. Rumus persamaan MAD adalah sebagai berikut:

b. Kesalahan Rata-rata Kuadrat (*Mean Square Error - MSE*)

MSE adalah cara kedua untuk mengukur kesalahan peramalan keseluruhan dimana dengan menhitung rata-rata selisih kuadrat antara nilai yang diramalkan dan yang diamati. Kekurangan MSE ini cenderung menonjolkan deviasi yang besar karena adanya pengkuadratan. Rumus persamaan MSE adalah sebagai berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (A_i - F_i)^2 \quad \dots \quad (2.2)$$

c. Kesalahan Persen Rata-rata Absolut (*Mean Absolute Percentage Error* - MAPE)

MAPE dihitung dengan menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata untuk periode itu. MAPE mengindikasi seberapa besar kesalahan dalam meramal di bandingkan dengan nilai nyata. Pendekatan ini berguna ketika ukuran variabel itu penting dalam mengevaluasi ketepatan ramalan. Rumus persamaan MAPE adalah sebagai berikut:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \quad (2.3)$$

Dinman:

A_t = Data aktual pada waktu t

F_t = Data peramalan pada waktu t

n = jumlah data

2.3.4. Jaringan Syaraf Tiruan

Definisi jaringan Syaraf Tiruan Menurut (Kristianto, 2004), Jaringan Syaraf Tiruan (JST) adalah sistem komputasi dimana arsitektur dan operasi dilhami dari pengetahuan tentang sel syaraf biologi di dalam otak. JST dapat digambarkan sebagai model matematis dan komputasi untuk fungsi aproksimasi non-linear, klasifikasi data, *cluster* dan regresi non-parametrik.

JST adalah salah satu representasi buatan dari otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran pada otak manusia tersebut. Istilah buatan digunakan karena jaringan syaraf diimplementasikan dengan menggunakan program komputer yang mampu menyelesaikan sejumlah proses perhitungan selama proses pembelajaran (Febrina, dkk, 2013).

Menurut (Sudarsono, 2016) JST merupakan suatu sistem pemrosesan informasi yang mempunyai karakteristik menyerupai jaringan syaraf biologis (JSB), JST tercipta sebagai suatu generalisasi model matematis dari pemahaman manusia (*human cognition*). JST merupakan pemodelan data yang kuat yang mampu menangkap dan mewakili hubungan *input - output* yang kompleks, karena kemampuannya untuk memecahkan beberapa masalah relatif mudah digunakan, ketahanan untuk menginput data, kecepatan untuk eksekusi, dan menginisialisasikan sistem yang rumit.

Berbeda dengan metode lainnya, algoritma untuk JST beroperasi secara langsung dengan angka sehingga data yang tidak numerik harus diubah menjadi data numerik. JST memiliki sejumlah besar kelebihan dibandingkan dengan metode perhitungan lainnya, yaitu kemampuan mengakuisisi pengetahuan, kemampuan merepresentasikan pengetahuan secara fleksibel, kemampuan untuk memberikan toleransi atas suatu distorsi dan kemampuan memproses pengetahuan secara efisien. Menurut (Hermawan, 2006) dengan kemampuan JST yang sangat baik, beberapa aplikasi JST sangat cocok untuk diterapkan pada kasus predksi, klasifikasi, asosiasi, *self-organizing* dan Optimasi.

Konsep JST menurut (Puspitaningrum, 2006) bisa dilihat dari kerangka kerja JST dimana dapat dilihat dari jumlah lapisan layer dan jumlah node pada setiap lapisan. Lapisan-lapisan penyusun JST dapat dibagi menjadi tiga, yaitu:

1. Lapisan Masukan (*Input*)

Node-node di dalam lapisan *input* disebut unit-unit *input*. Node-node *input* menerima *input* dari luar. *Input* yang dimasukan merupakan penggambaran dari

suatu masalah.

2. Lapisan tersembunyi (*Hidden*)

Node-node di dalam lapisan tersembunyi atau disebut unit-unit tersembunyi. *Output* dari lapisan ini tidak secara langsung dapat diamati. Menentukan jumlah node pada lapisan tersembunyi perlu dilakukan dalam beberapa kali tindakan eksperimen, begitu juga pada jumlah lapisan tersembunyinya.

3. Lapisan Keluaran (*Output*)

Node-node pada lapisan *output* atau disebut unit-unit *output*. Keluaran dari lapisan ini merupakan *output* JST terhadap suatu permasalahan.

Prinsip dasar pelatihan JST dibagi menjadi 2 definisi yaitu bagaimana JST menyimpan pengetahuan (*encode*) dan bagaimana JST memproses data yang masuk (*decode*). Berdasarkan *encode* dibedakan menjadi 2 bagian yaitu *supervised* dan *unsupervised*. Sedangkan berdasarkan *decode* dibedakan menjadi *feedforward* dan *feedback* (umpan balik)(Kristianto, 2004).

JST ditentukan oleh 3 hal (Siang, 2005):

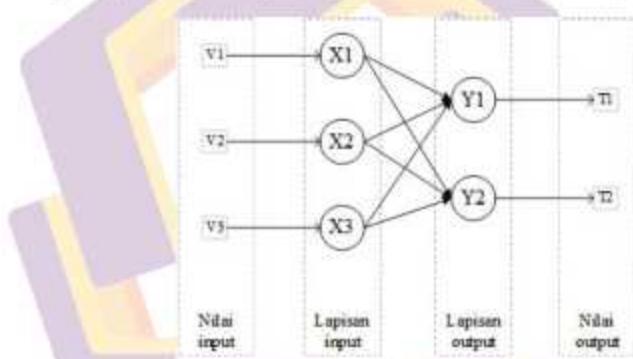
1. Pola hubungan antar neuron (disebut arsitektur jaringan).
2. Metode atau algoritma untuk menentukan bobot penghubung (disebut algoritma pelatihan/*training*).
3. Fungsi aktivasi, yaitu fungsi yang digunakan untuk menentukan keluaran suatu neuron.

3.3.4.1. Arsitektur JST

Arsitektur sebuah jaringan akan menentukan keberhasilan target yang akan dicapai karena tidak semua permasalahan dapat diselesaikan dengan arsitektur yang sama(Hermawan, 2006).

1. Single Layer

Jaringan lapisan tunggal atau *single layer* hanya memiliki satu lapisan dengan bobot terhubung. Jaringan ini menerima *input* kemudian secara langsung akan mengolahnya menjadi *output* tanpa melalui lapisan tersembunyi.

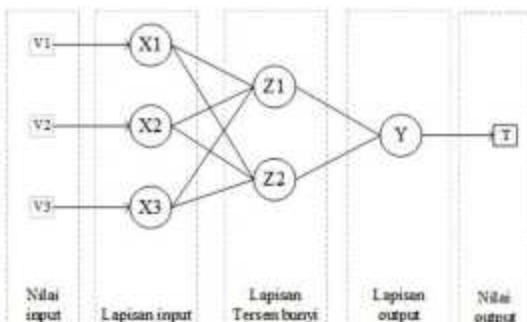


Gambar 2.1 Arsitektur Single Layer

Pada Gambar 2.1 adalah contoh gambaran arsitektur *single layer*. Lapisan *input* memiliki 3 neuron yaitu X1, X2 dan X3. Sedangkan lapisan *output* memiliki 2 neuron yaitu Y1 dan Y2.

2. Multilayer

Jaringan dengan banyak lapisan memiliki satu lapisan atau lebih lapisan yang terletak di antara lapisan *input* dan lapisan *output* yang disebut lapisan tersembunyi (*hidden layer*).



Gambar 2.2 Arsitektur Multilayer

Pada Gambar 2.2 adalah contoh gambaran arsitektur multilayer yang memiliki 1 lapisan tersembunyi. Lapisan *input* memiliki 3 neuron yaitu X₁, X₂ dan X₃, lapisan tersembunyi memiliki 2 neuron yaitu Z₁ dan Z₂ sedangkan lapisan *output* memiliki 1 neuron yaitu Y₁.

3. Competitif layer

Hubungan antar neuron-neuron pada lapisan kompetitif ini tidak diperlihatkan pada diagram arsitektur.

3.3.4.2. Algoritma Pelatihan JST

Banyak sekali algoritma pelatihan JST yang ada karena model dan konfigurasi neuron dalam perhitungan yang berbeda-beda sesuai kebutuhan, antara lain dapat dilihat pada Tabel 2.3.

Tabel 2.3 Jenis Algoritma Pelatihan JST

Algoritma Pelatihan	Keterangan
Hebb/hebbian/hebb rule	Hebb rule adalah algoritma pelatihan yang paling tua (Hermawan, 2006) dan paling sederhana untuk JST secara umum (Yanti & Sutrisna, 2017). Hebbian termasuk dalam <i>unsupervised learning</i> (Kusuma, Suyanto, & Yulianto, 2011). Hebb menggunakan arsitektur <i>single layer</i> yang sangat banyak

Tabel 2.3 Jenis Algoritma Pelatihan JST (Lanjutan)

Algoritma Pelatihan	Keterangan
	diterapkan untuk permasalahan atau kasus klasifikasi (Gapar, Widagdu, & Suarbawa, 2018).
Perceptron	Perceptron merupakan salah satu bentuk algoritma JST yang sederhana. Perceptron biasanya digunakan untuk kasus klasifikasi. Arsitektur yang digunakan adalah arsitektur <i>single layer</i> (David, 2011), type <i>feedforward</i> dengan fungsi yang biasa digunakan adalah hard limit. Perceptron termasuk dalam <i>supervised learning</i> .
Multi-layer Perceptron (MLP)	MLP merupakan salah satu varian algoritma pelatihan dari JST merupakan pengembangan dari algoritma perceptron(Nafiiyah, 2015). Arsitektur yang digunakan MLP adalah arsitektur <i>multi-layer</i> (Purwaningsih, 2016). MLP seringkali digunakan untuk kasus klasifikasi (Nawawi, Rahmat, & Syahputra, 2015).
Adaline	<i>Adaptive Linear Neuron</i> (ADALINE) salah satu algoritma pelatihan dalam JST yang pemakaiannya cocok secara pemakaian memori bila pengembangan sistem memasuki lingkungan waktu nyata(Fadlisyah & Bustami, 2016). Arsitektur yang digunakan pada algoritma ini adalah <i>single layer</i> (Kristianto, 2004).
Madaline	Many Adaline (MADALINE) adalah sebuah JST yang diciptakan dari kombinasi beberapa Adaline yang terhubung satu sama lain (Joses, Suhery, & Midyanti, 2018). Arsitektur yang digunakan adalah <i>multilayer</i> (Kristianto, 2004).
Heteroassociative Memory	<i>Heteroassociative Memory</i> adalah salah satu metode JST yang bobotnya ditentukan sedemikian rupa sehingga jaringan tersebut dapat menyimpulkan kumpulan pengenempukan pola(Jasmir, Skom, 2013). Metode ini diterapkan pada penyelesaian klasifikasi pola-pola seperti pengenalan karakter huruf (Lius, Simarmata, & Herman, 2017).
Hopfield	Arsitektur <i>JST hopfield</i> tersusun atas satu lapis jaringan dengan umpan balik (<i>feedback</i>)(Mubyarto & Susilawati, 2010). Penggunaan algoritma ini sangat banyak diterapkan pada penelitian dengan kasus klasifikasi (Mahendhy, Nasrun, & Latuconsina, 2018) (Budianita, Hustianto, Okfalisa, Syafria, & Nasir, 2018) dan pengenalan pola karakter(Zulfian Azmi & Freizello, 2017).
Bidirectional Associative Memory (BAM)	JST BAM merupakan suatu pengembangan yang lebih maju dari JST hopfield. Arsitektur di jaringan BAM ini terdiri dari dua lapisan neuron dan dihubungkan dengan bobot koneksi secara langsung. BAM sangat sering diterapkan pada kasus seperti klasifikasi seperti mengidentifikasi pola sidik jari manusia(Arifin, 2009).
Hamming	Jaringan hamming digunakan untuk menentukan beberapa vektor contoh yang mirip dengan sebuah vektor <i>input</i> . Metode ini banyak digunakan pada kasus klasifikasi dan pengenalan pola huruf atau angka(Kristianto, 2004).

Tabel 2.3 Jenis Algoritma Pelatihan JST (Lanjutan)

Algoritma Pelatihan	Keterangan
Learning Vector Quantization (LVQ)	LVQ adalah metode yang digunakan dalam melakukan <i>training</i> pada lapisan yang tidak terawasi (<i>unsupervised learning</i>) di arsitektur kompetitif (Meliaawati, Soesanto, & Kartini, 2016). Penerapan metode LVQ sering kali untuk kasus klasifikasi (Budianita & Firdaus, 2016) dan beberapa kasus prediksi (Arisandi, Sitompul, & Batubara, 2015) (Hidayati & Warsito, 2012).
Kohonen self-organizing maps	JST Kohonen SOM merupakan suatu algoritma pelatihan <i>training</i> untuk mempetakan pola suatu ciri pengelompokan (<i>cluster</i>) (Siregar, Lestari, Ermala, Simarmata, & Nainggolan, 2019). Jaringan kohonen memiliki lapisan neuron yang menyusun dirinya sendiri berdasarkan <i>cluster</i> (Nafi'iyah, 2015). JST Kohonen masuk dalam kategori <i>unsupervised learning</i> (E. B. Ginting, Zurlis, & Situmorang, 2014).
Backpropagation	<i>Backpropagation</i> merupakan JST yang masuk pada kategori <i>supervised learning</i> (Hasan, Kusrimi, & Fatta, 2019) untuk digunakan pada arsitektur <i>multilayer</i> (R. Ginting, Tulus, & Nababan, 2014). JST <i>backpropagation</i> sering digunakan dalam menyelesaikan masalah atau kasus klasifikasi dan prediksi (Matodang, 2013).

3.3.4.3. Fungsi Aktivasi

Fungsi aktivasi merupakan bagian penting dalam tahapan perhitungan keluaran dari suatu algoritma. Beberapa fungsi aktivasi yang digunakan dalam JST adalah:

- ## 1. Fungsi identitas

$$f(x) = x, \text{ untuk semua } x. \quad (2.4)$$

2. Fungsi biner dengan *threshold* (dengan batas ambang)

Fungsi ini sering digunakan pada jaringan satu lapis, yaitu untuk mengubah *input* nilai variabel terhadap sebuah unit *output* berupa angka biner 1 atau 0 atau terhadap bipolar 1 atau -1. Adapun persamaan fungsi biner dengan *threshold* dapat dilihat pada permasaan 2.5.

3. Fungsi biner sigmoid

$$f(x) = \frac{1}{1 + \exp(-\alpha x)}, \quad \dots \quad (2.6)$$

$$f'(x) = \sigma f(x)[1 - f(x)] \dots \quad (2.7)$$

Dengan σ :konstanta

4. Fungsi sigmoid bipolar

$$g(x) = 2f(x) - 1 = \frac{2}{1 + \exp(-\sigma x)}, \quad (2.8)$$

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

Dengan σ :konstanta

3.3.4.4. Istilah-Istilah Dalam Jaringan Syaraf Tiruan

Beberapa istilah-istilah jaringan syaraf tiruan yang sering ditemui dapat dilihat pada Tabel 2.4 (Andayani, 2018).

Tabel 2.4 Daftar Istilah Jaringan Syaraf Tiruan

Isitilah	Keterangan
Neuron, node, unit	Sel saraf tiruan yang merupakan elemen pengolahan jaringan syaraf tiruan. Setiap neuron menerima data <i>input</i> , memproses <i>input</i> tersebut (melakukan sejumlah perkalian dengan melibatkan fungsi aktivasi), dan mengirimkan hasilnya berupa sebuah <i>output</i> .
Jaringan	Kumpulan neuron yang saling terhubung dan membentuk lapisan.
Input atau masukan	Berhubungan dengan sebuah atribut tunggal dari sebuah pola atau data lain dari dunia luar. Sinyal-sinyal input ini kemudian diteruskan ke lapisan selanjutnya.
Lapisan tersembunyi (<i>Hidden Layer</i>)	Lapisan yang tidak secara langsung berinteraksi dengan dunia luar. Lapisan ini memperluas kemampuan jaringan syaraf tiruan dalam menghadapi masalah-masalah kompleks.
Bobot	Bobot dalam jaringan syaraf tiruan merupakan nilai matematis dari koneksi, yang mentransfer jaringan dari satu ke lapisan lainnya. Bobot ini digunakan untuk mengatur jaringan sehingga JST bisa menghasilkan <i>output</i> yang diinginkan sekaligus bertujuan membuat jaringan tersebut belajar.
Fungsi aktivasi, fungsi transfer	Fungsi yang menggambarkan hubungan antara tingkat aktivasi yang berbentuk <i>linear</i> atau <i>nonlinear</i> . Beberapa fungsi aktivasi

Tabel 2.4 Daftar Istilah Jaringan Syaraf Tiruan (Lanjutan)

Istilah	Keterangan
JST	JST yaitu Hard limit, Purelin dan Sigmoid. Fungsi yang popular digunakan saat ini adalah fungsi simoid yang memiliki beberapa varian yakni sigmoid logaritma, sigmoid biner, sigmoid bipolar dan sigmoid tangent.
Aturan kerja	Secara umum aturan kerja dari teknik algoritma JST ada 4, yaitu aturan <i>error correcting</i> , aturan Boltzman, aturan Hebbian dan aturan kompetitif.

3.3.4.5. Notasi Dalam Jaringan Syaraf Tiruan

Notasi yang sering dipakai dalam JST menggunakan beberapa notasi yang berguna dalam pembuatan algoritma pembelajaran *backpropagation* antara lain dapat dilihat pada Tabel 2.5.

Tabel 2.5 Notasi Dalam Jaringan Syaraf Tiruan

Notasi	Keterangan
x_i, y_j	Aktivitas dari unit x_i, y_j untuk unit input x_i , x_i = sinyal input, sedangkan unit y_j , $y_j = f(y_{in_j})$
w_{ij}	Bobot koneksi dari unit x_i ke unit y_j
b_i	Biasa unit y_i
y_{in_j}	Input jaringan ke unit y_j $y_{in_j} = b_j + \sum_i x_i w_{ij}$
W	Bobot matriks $W = [w_{ij}]$
w_{ij}	Vector bobot $w_{ij} = (w_{1j}, w_{2j}, \dots, w_{nj})^T$
$ x $	Vector X
θ_j	<i>Threshold</i> untuk aktivasi neuron y_j , jika input yang masuk ke jaringan lebih besar dari nilai <i>threshold</i> , maka fungsi aktivasi = 1, sebaliknya fungsi aktivasi = 0
S	Pelatihan vector input $S = (S_1, S_2, \dots, S_n)$
T	Pelatihan vector output atau target $t = (t_1, t_2, \dots, t_n)$
X	Vector input $x = (x_1, x_2, \dots, x_n)$
w_{ij}^{new}	Perubahan dalam w_{ij} $w_{ij}^{new} = w_{ij}$ baru - w_{ij} lama
α	Tingkat pembelajaran (<i>learning rate</i>). <i>Learning rate</i> akan mengawasi atau mengontrol bobot dalam setiap kali pembelajaran

3.3.4.6. Algoritma Backpropagation

Algoritma pelatihan JST yang digunakan pada penelitian ini yaitu *backpropagation*. *Backpropagation* merupakan algoritma pembelajaran yang terawasi dengan lebih dari 1 lapisan untuk mengubah bobot-bobot yang terhubung

dengan *neuron-neuron* yang ada pada lapisan tersembunyinya (Febrina, dkk, 2013).

Menurut (Marjiyono, dkk, 2018) *backpropagation* menggunakan *error output* untuk mengubah nilai bobot-bobotnya dalam arah mundur (*backward*). Untuk mendapatkan *error* ini, tahap perambatan maju (*feedforward*) harus dikerjakan terlebih dahulu.

Pelatihan *backpropagation* meliputi 3 fase. Fase pertama adalah fase maju. Pola masukan dihitung maju mulai dari layer masukan hingga layer keluaran menggunakan fungsi aktivasi yang ditentukan. Fase kedua adalah fase mundur. Selisih antara keluaran jaringan dengan target yang diinginkan merupakan kesalahan yang terjadi. Kesalahan tersebut dipropagassikan mundur, dimulai dari garis yang berhubungan langsung dengan unit-unit di layar keluaran. Fase ketiga adalah modifikasi bobot untuk menurunkan kesalahan yang terjadi.

Algoritma pelatihan jaringan *backpropagation* terdiri dari 3 tahapan yaitu:

1. Tahapan umpan maju (*feedforward*)
2. Tahapan umpan mundur (*backpropagation*)
3. Tahap pengupdatean bobot dan bias

Sebelum melakukan proses peramalan, maka data yang sudah ada akan dibagi menjadi dua bagian, yaitu data latih (*training*) dan data uji (*testing*). Secara rinci algoritma pelatihan jaringan *backpropagation* dapat diuraikan sebagai berikut:

Langkah 1 : Inisialkan bobot (set ke nilai kecil secara acak)

Langkah 2 : Selama kondisi berhenti bernilai salah, kerjakan:

a. Untuk masing-masing pasangan pelatihan, lakukan *feedforward*

1. Masing-masing unit input (X_i , $i=1,\dots,n$) menerima sinyal input X_i dan menyebarkan sinyal ke semua unit lapisan atas (unit tersembunyi).

- 2....Masing-masing unit tersembunyi (Z_j , $j=1,\dots,p$) menjumlahkan bobot sinyal input $z_{inj} = v_{0j} + \sum_i x_i v_{ij}$(2.11)

dan mengaplikasikan fungsi aktivasi untuk menghitung sinyal output

$$z_j = f(z_{inj}).....(2.12)$$

dan mengirimkan sinyal tersebut ke semua unit pada lapisan atas (unit output)

3. Masing-masing unit output (Y_k , $k=1,\dots,m$) menjumlahkan jumlah sinyal input

$$Y_{in_k} = W_{0k} + \sum_j z_j w_{jk}.....(2.13)$$

dan mengaplikasikan fungsi aktivasi untuk menghitung sinyal output

$$y_k = f(y_{in_k}).....(2.14)$$

- b. Untuk masing-masing pasangan pelatihan, lakukan *backward* (*backpropagation*)

1. Masing-masing unit output (Y_k , $k=1,\dots,m$) menerima sebuah pola target yang bersesuaian dengan pola input pelatihan, menghitung informasi kesalahan,

$$\delta_k = (t_k - y_k) f'(y_{in_k}).....(2.15)$$

kemudian menghitung koreksi bobot (digunakan untuk memperbaiki w_{jk})

$$\Delta w_{jk} = a \delta_k \cdot z_j.....(2.16)$$

dan akhirnya menghitung korelasi bias (digunakan untuk memperbaiki w_{0k})

$$\Delta w_{0k} = a \delta_k(2.17)$$

setelah itu mengirimkan δ_k ke unit dalam lapisan paling atas.

2. Masing-masing unit yang tersebunyi (Z_j , $j=1, \dots, p$) menjumlahkan input delta (dari unit lapisan atas)

$$\delta_{inj} = (x + a)^n = \sum_{k=1}^m \delta_k w_{jk} \dots \quad (2.18)$$

Kalikan nilai ini dengan turunan fungsi aktivasi untuk menghitung informasi kesalahan,

$$\delta_j = (\delta_{inj} f'(Z_{inj})) \dots \quad (2.19)$$

Kemudian hitunglah koreksi bobot (digunakan untuk memperbaiki v_0)

$$\Delta V_{ij} = a\delta_{jxt} \quad \dots \quad (2.20)$$

Setelah itu hitung koreksi bias (digunakan untuk memperbaiki v_0)

c. Perbaiki bobot dan bias

Masing-masing unit output (Y_k , $k=1, \dots, m$) memperbaiki boot dan bias (Z_j , $j=1, \dots, p$)

Masing-masing unit tersembunyi (Z_j , $j=1,\dots,p$) memperbaiki bobot dari bias (X_i , $i=1,\dots,n$)

Tes kondisi berhenti.

2.3.5. Algoritma Nguyen-widrow

Inisialisasi bobot awal dengan algoritma *nguyen-widrow* ini akan melakukan inisialisasi bobot-bobot lapisan dengan nilai antara -0.5 sampai dengan

0.5. Algoritma ini secara sederhana dapat diimplementasikan dengan cara sebagai berikut (Perdana, 2016):

Tetapkan:

n = jumlah neuron (unit) pada lapisan input

p = jumlah neuron (unit) pada lapisan tersembunyi

$$\beta - \text{faktor skala } 0.7\sqrt{p} \dots \quad (2.24)$$

Kerjakan untuk setiap unit pada lapisan tersembunyi ($j=1,2,\dots,p$):

- a. Inisialisasi bobot-bobot dari lapisan input ke lapisan tersembunyi:

V_0 bilangan random antara -0.5 sampai 0.5 (atau antara $-\gamma$ sampai γ).

- b. Hitung $|V_1|$ dimana:

$$\|Vj\| = \sqrt{(V_{1j}^2) + (V_{2j}^2) + \dots + (V_{nj}^2)} \quad (2.25)$$

- c. Inisialisasi ulang bobot-bobot:

$$\|V_\phi\| = \frac{\beta V_\phi}{\|V_\phi\|} \quad \dots \quad (2.26)$$

- d. Set bias:

b1j – bilangan random antara $-\beta$ sampai β .

BAB III

METODE PENELITIAN

3.1. Jenis, Sifat, dan Pendekatan Penelitian

Penelitian ini menggunakan jenis penelitian eksperimental, karena dilakukan dengan serangkaian tindakan dimulai dengan melakukan pencarian variable berpengaruh, pra-proses, normalisasi, kombinasi metode pembobotan dengan *nguyen-widrow*, proses olah data *training* dan proses olah data *testing* menggunakan algoritma *backpropagation*. Adapun sifat penelitian ini dilakukan secara mandiri menggunakan metode deskriptif dan kausal dari data yang diperoleh kemudian dilatih dan dibandingkan dengan data yang diujikan. Kemudian dicari nilai *error* (MSE) terkecil dalam melakukan peramalan penjualan. Pendekatan penelitian ini menggunakan pendekatan kuantitatif, penelitian di lakukan terhadap data variabel eksternal, data *time series* penjualan yang di kumpul yang kemudian dihitung menggunakan beberapa persamaan.

Objek yang diteliti yaitu *history* penjualan yang di peroleh dari perusahaan yang diteliti dan data variabel *input* lainnya dari luar perusahaan yang kemudian diolah dan dihitung dengan algortima *backpropagation*. Hasil perhitungan dengan algoritma *backpropagation* kemudian dihitung data *error* dan di koreksi bobot nilai.

Hasil akhir peramalan kemudian ditampilkan dalam bentuk grafik. Hasil perbandingan dengan MSE terkecil tersebut dapat digunakan sebagai informasi

dasar dalam penambilan keputusan untuk menentukan jumlah produksi periode berikutnya.

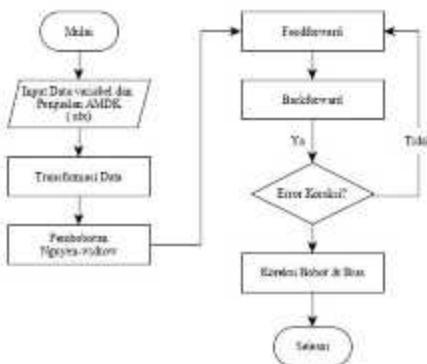
3.2. Metode Pengumpulan Data

Pengumpulan data adalah kegiatan yang dilakukan pertama kali sebelum melakukan kegiatan analisis data. Kegiatan ini bertujuan untuk mengetahui variabel yang digunakan dan tingkat akurasi yang diperoleh pada peramalan AMDK menggunakan algoritma *backpropagation*. Data yang dibutuhkan adalah data penjualan AMDK dari perusahaan, data hari, tanggal dan waktu libur selama satu tahun dan data curah hujan dari BMKG.

Data untuk penelitian ini bersumber dari hasil kegiatan observasi atau wawancara kepada Unit Bisnis AMDK dan internal manajemen perusahaan. Data variabel lain bersumber dari website BMKG.

3.3. Metode Analisis Data

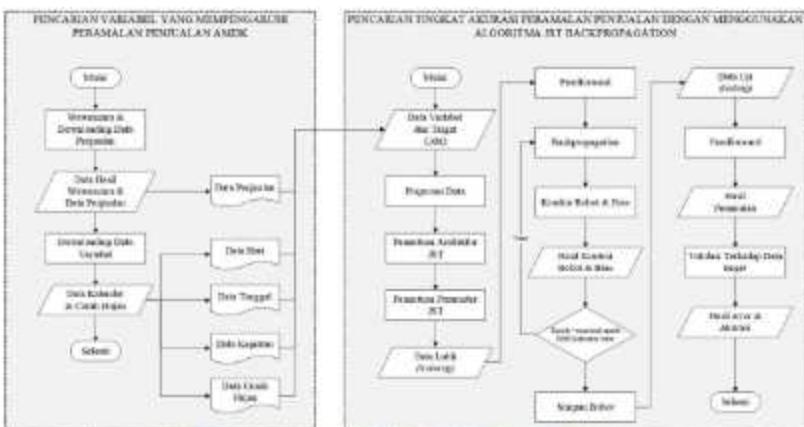
Pada penelitian ini dilakukan analisa peramalan terhadap data-data yang diperoleh pada tahap pengumpulan data. Data kualitatif akan disajikan dalam bentuk narasi atau deskriptif. Sedangkan data kuantitatif akan diolah dengan menggunakan program *Microsoft Excel* dan Matlab yang hasilnya akan disajikan dalam bentuk tabel, grafik dan uraian secara narasi. Secara garis besar proses peramalan penjualan dengan JST *backpropagation* akan dilakukan seperti pada Gambar 3.1.



Gambar 3.1 Alur Flowchart Peramalan

Pada Gambar 3.1 menjelaskan sumber data yang menjadi masukan adalah data variabel *input* dan data penjualan sebagai target dalam bentuk file *excel*. Kemudian dilakukan transformasi data untuk mendapatkan data set. Proses pembelajaran diawali dengan melakukan pembobotan awal menggunakan algoritma *nguyen-widrow*, selanjutnya pelatihan *feedforward* dan peatihan *backward* (*backpropagation*). Setelah proses *backpropagation* ini, akan dilakukan pengcekan apakah nilai target *error* telah dicapai, jika target *error* belum tercapai proses dimulai lagi dari pelatihan *feedforward*, proses ini akan terus berlangsung sampai mendapatkan MSE terkecil atau *epoch* maksimum. Jika sudah didapatkan target *error*, maka proses pembelajaran selesai, kemudian menghasilkan koreksi dari bobot jaringan.

Berangkat dari rumusan masalah penelitian ini, metode analisis yang akan dilakukan dapat dilihat pada Gambar 3.2 *flowchart* untuk mendapatkan hasil dari rumusan masalah yaitu variabel yang digunakan dalam peramalan penjualan dan tingkat akurasi peramalan penjualan *backpropagation*.



Gambar 3.2 Alur Pencarian Hasil Rumusan Masalah

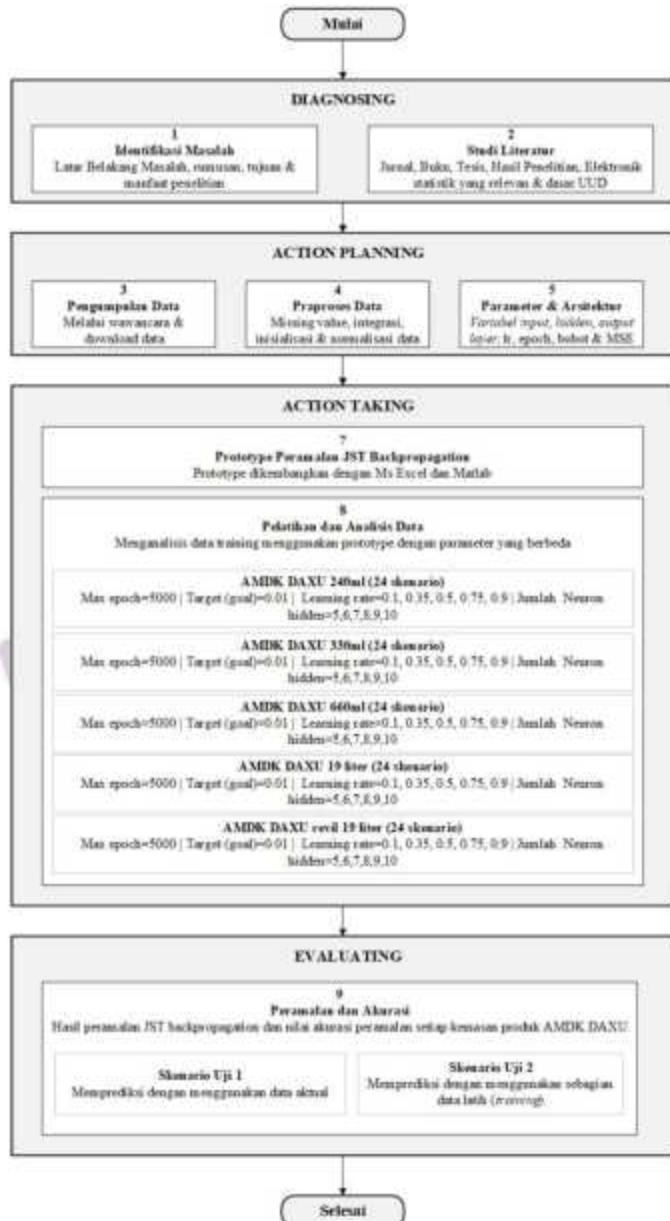
Pada Gambar 3.2 dapat dilihat pencarian variabel yang berpengaruh terhadap penjualan AMDK-DAXU melalui metode analisis dan wawancara diantaranya adalah kalender dimana tanggal, hari dan kegiatannya. Kemudian data curah hujan yang bersumber dari BMKG dan data target yaitu data *time series* penjualan AMDK-DAXU. Variabel-variabel ini kemudian menjadi data *input* yang selanjutnya dilakukan tahap praproses data seperti normalisasi yang dilakukan menggunakan *sigmoid biner* 0-1 untuk dapat selanjutnya diolah dengan JST. Selanjutnya dilakukan inisialisasi bobot awal menggunakan *nguyen-widrow*, setelah itu menentukan inisialisasi dari kebutuhan parameter JST seperti jumlah lapisan neuron tersembunyi, maksimal *epoch*, nilai tolereansi dan lain lain. Semua langkah pada tahap praproses ini keluarannya menghasilkan data *training* yang akan menjadi masukan pada proses *training* JST *backpropagation* untuk mendapatkan arsitektur JST terbaik.

Proses untuk mendapatkan akurasi dengan JST *backpropagation* yaitu dimulai dari memasukan data *training* AMDK yang telah melewati tahap praproses dalam bentuk *excel*. Proses *training* adalah prosedur untuk melakukan pembelajaran terhadap pola-pola yang akan dikenali. Proses ini berhenti jika MSE lebih kecil dari *error* yang ditetapkan, sehingga didapatkan bobot-bobot neuron yang diharapkan atau kesalahan mendekati nilai 0 (nol). Jika belum mencapai *error* yang ditetapkan proses iterasi akan terus berlangsung hingga maksimal *epoch*.

Setelah data dilakukan prosedur peramalan, hasil koreksi bobot dan pemodelan dari proses peramalan dihitung data tahap *feedforward* dengan memvalidasi menggunakan data *testing* (target) yang ada. Setelah memvalidasi dengan data *testing* dicari nilai *error* rata-rata dari peramalan untuk mengetahui tingkat akurasi.

3.4. Alur Penelitian

Penelitian ini menggunakan desain penelitian *action research* menurut *Baskerville* dalam (Lee, 2007) Adapun alur pada penelitian ini ditunjukkan pada Gambar 3.3.



Gambar 3.3 Alur Penelitian

Pada Gambar 3.3 menjelaskan jika pada penelitian ini akan dilakukan dalam 4 tahapan yaitu:

a. *Diagnosing*

Pada tahap diagnosing kegiatan yang dilakukan adalah mengidentifikasi masalah dengan memahami latar belakang masalah dan menentukan tujuan, rumusan serta manfaat dari penelitian ini.

Kegiatan selanjutnya yaitu melakukan studi literatur dengan mencari referensi yang relevan dengan penerapan JST pada kasus peramalan/prediksi dari sumber buku, jurnal penelitian, literatur elektronik seperti publikasi statistik dari BPS, dasar hukum dari putusan Menteri yang sangkut AMDK dan data dari BMKG.

b. *Action Planning*

Pada tahap ini ada tiga kegiatan yaitu pengumpulan data, praproses data dan perencanaan parameter arsitektur JST. Pada kegiatan pengumpulan data dilakukan dengan wawancara dan pengumpulan data pada pihak Unit Bisnis AMDK PDAM Tirta Sembada Sielman terkait penjualan produk AMDK DAXU. Pada kegiatan ini *output* yang dihasilkan yaitu mendapatkan laporan penjualan produk AMDK setiap periodenya dan mendapatkan informasi lainnya terkait penjualan.

Kegiatan praproses data yaitu melakukan pembersihan data terhadap *missing value*, transformasi data dengan memberikan inisialisasi terhadap variabel *input*, inisisialisasi bobot, dan normalisasi pada data. Inisialisasi bobot menggunakan metode pembobotan *nguyen-widrow*. Kemudian sesuai kebutuhan

dalam JST *backpropagation* pemilihan parameter dan arsitektur dipilih dari data penjualan dan hasil wawancara yang telah didapatkan.

c. Action Taking

Tahap ketiga yaitu pembuatan pengembangan *prototype* dan analisis. Data yang sudah dikumpulkan dan sudah diolah pada tahap praproses, selanjutnya dilakukan implementasi untuk model *prototype* sistem. *Prototype* dibuat menggunakan Matlab 2018a. Hasilnya kemudian oleh peneliti di analisis. Kegiatan didalam proses ini adalah melakukan proses pelatihan terhadap data penjualan menggunakan JST *backpropagation* dengan menggunakan parameter JST yang berbeda-beda untuk setiap pelatihan produk AMDK DAXU. Masing-masing produk AMDK DAXU dilakukan sebanyak 24 skenario pelatihan.

d. Evaluation

Tahap terakhir yaitu tahap evaluasi. Pada tahapan ini kegiatan peramalan dan penarikan kesimpulan dilakukan. Ada dua kegiatan pengujian pada tahap ini yaitu pengujian dengan data aktual untuk mengetahui tingkat akurasi arsitektur yang telah dibangun dan juga mengetahui hasil prediksi. Uji skenario 2 dilakukan untuk mengetahui konsistensi arsitektur dan hasil peramalan.

Hasil akurasi dari peramalan akan dihitung dengan persamaan perhitungan kesalahan peramalan menggunakan MSE dan ketepatan sistem peramalan menggunakan akurasi.

BAB IV

HASIL PENELITIAN DAN PEMBAHASAN

4.1. Action Planning

Tahapan yang dilakukan pada *action planning* yaitu penyusunan rencana tindakan yang tepat untuk menyelesaikan masalah. Pada penelitian ini yang dilakukan adalah dengan mencari data yang dibutuhkan, praproses data, menentukan parameter dan arsitektur JST yang digunakan.

4.1.1. Pengumpulan Data

Pengumpulan data dilakukan pada Unit Bisnis AMDK PDAM Tirta Sembada Sleman. Data penjualan yaitu produk AMDK 240ml, 330ml, 600ml, 19liter dan revil 19liter pada bulan Januari-Agustus 2019 dalam bentuk file *excel* atau berformat (.xlx). Jumlah data yang didapat yaitu sebanyak 243 data. Namun untuk penelitian ini data dibagi menjadi dua, data latih sebanyak 229 dan data uji sebanyak 14 data. Proses pengambilan data penjualan per hari tersebut kemudian di rangkum dalam setiap kategori produk seperti dalam Tabel 4.1.

Tabel 4.1 Data Aktual Penjualan AMDK DAXU

Tanggal	Penjualan DAXU 240ml	Penjualan DAXU 330ml	Penjualan DAXU 600ml	Penjualan DAXU 19L	Penjualan DAXU Revil 19L
1-Jan-2019	0	0	0	0	0
2-Jan-2019	27	8	12	2	14
3-Jan-2019	458	2	4	10	10
4-Jan-2019	20	14	13	0	1
5-Jan-2019	7	36	0	0	5
6-Jan-2019	0	0	0	0	0

Tabel 4.1 Data Aktual Penjualan AMDK DAXU (Lanjutan)

Tanggal	Penjualan DAXU 240ml	Penjualan DAXU 330ml	Penjualan DAXU 600ml	Penjualan DAXU 19L	Penjualan DAXU Revil 19L
7-Jan-2019	4	1	8	0	7
---	---	---	---	---	---
---	---	---	---	---	---
31-Aug-2019	101	68	1	1	0

Unit bisnis AMDK PDAM Tirta Sembada Sleman yang berada di Yogyakarta artinya berada dalam lingkungan "kota pelajar" yang memiliki banyak mahasiswa dan juga karena produk AMDK dikonsumsi untuk setiap kegiatan instansi perkantoran pemerintah sehingga kegiatan kalender berpengaruh terhadap penjualan AMDK DAXU. Data kegiatan didapatkan dari kalender tahunan. Data kalender akan digunakan sebagai *input* atau variabel masukan meliputi hari, tanggal dan kegiatan. Data kalender dapat dilihat pada Tabel 4.2.

Tabel 4.2 Data Kalender

Hari	Tanggal	Kegiatan
Selasa	1-Jan-2019	Libur
Rabu	2-Jan-2019	Hari kerja
Kamis	3-Jan-2019	Hari kerja
Jum'at	4-Jan-2019	Hari kerja
Sabtu	5-Jan-2019	Hari kerja
Minggu	6-Jan-2019	Libur
Senin	7-Jan-2019	Hari kerja
---	---	---
---	---	---
Sabtu	31-Agus-2019	Hari kerja

Nilai dari variabel hari adalah seluruh hari yaitu hari senin, selasa, rabu, kamis, jum'at, sabtu dan minggu. Nilai dari variabel tanggal yang di maksud adalah tanggalnya saja, tidak temasuk bulan dan tahun. Sehingga tanggal 1 januari

adalah sama dengan tanggal 1 februari, tanggal 1 maret, tanggal 1 april dan seterusya.

Kegiatan kalender dibagi menjadi 3 kegiatan, yaitu libur, cuti bersama dan hari kerja. Kegiatan libur atau tanggal merah berarti mahasiswa dan karyawan libur, sedangkan cuti bersama berarti beberapa karyawan di perkantoran ada yang masuk sesuai *shift* untuk tetap melayani. Kegiatan hari kerja artinya seluruh kegiatan perkuliahan dan perkantoran berjalan aktif/normal.

Proses pengumpulan data bersamaan dengan proses wawancara dimana saat-saat musim tertentu jumlah air yang diproduksi tidak sama, tergantung debit air yang tersedia. Sehingga artinya curah hujan di daerah Sleman menjadi variabel atau faktor yang mempengaruhi penjualan. Data curah hujan di daerah Sleman per harinya didapat dari data BMKG (BMKG, n.d.). Data curah hujan seperti pada Tabel 4.3.

Tabel 4.3 Data Curah Hujan

Hari	Tanggal	Curah Hujan (mm)
Selasa	1-Jan-2019	1.4
Rabu	2-Jan-2019	12
Kamis	3-Jan-2019	15.2
Jum'at	4-Jan-2019	13.4
Sabtu	5-Jan-2019	7.7
Minggu	6-Jan-2019	0.6
Senin	7-Jan-2019	1
...
...
Sabtu	31-Agus-2019	0

4.1.2. Praproses Data

Agar data dapat dikenali oleh jaringan dan dapat diproses menggunakan perangkat lunak dan fungsi aktifasi sigmoid biner, maka data kemudian harus diubah ke dalam bentuk numerik antara 0 sampai 1.

a. Missing Value

Pada tahap menghilangkan *missing value*, data penjualan yang jauh dari data seharusnya akan dihapus secara manual atau diberikan nilai 0, misalnya data penjualan yang tidak ada tanggalnya, atau data curah hujan yang tidak ada.

b. Integrasi

Setelah data bersih dari *missing value* maka dilakukan integrasi data, yaitu menggabungkan data penjualan dengan data kegiatan kalender dan data curah hujan. Data di integrasikan berdasarkan tanggal yang sama. Integrasi ketiga sumber data ini bertujuan untuk dapat mengetahui jumlah penjualan pada suatu hari, tanggal, kegiatan, dan musim tertentu. Contoh hasil integrasi data produk AMDK DAXU 240ml dapat dilihat pada Tabel 4.4.

Tabel 4.4 Hasil Integrasi Data

Hari	Tanggal	Kegiatan	Curah Hujan (mm)	Penjualan (pcs)
Selasa	1-Jan-2019	Libur	1.4	0
Rabu	2-Jan-2019	Hari kerja	12	27
Kamis	3-Jan-2019	Hari kerja	15.2	458
Jumat	4-Jan-2019	Hari kerja	13.4	20
Sabtu	5-Jan-2019	Hari kerja	7.7	7
Minggu	6-Jan-2019	Libur	0.6	0
Senin	7-Jan-2019	Hari kerja	1	4
...
...
Sabtu	3-Agust-2019	Hari kerja	0	101

c. Inisialisasi

Inisialisasi data perlu dilakukan agar variabel hari, tanggal, kegiatan, dan curah hujan dapat diproses dengan perhitungan JST *backpropagation*. Inisialisasi ini tidak bersifat subjektif, karena kemampuan JST-BP (*supervised learning*) dalam merepresentasikan dan menggeneralisir pengetahuan manusia, maka pemberian inisialisasi tidak berpengaruh besar pada hasil. Inisialisasi hari dimulai dari angka 0, inisialisasi tanggal dilakukan sesuai dengan tanggal itu sendiri.

Inisialisasi data hari dapat dilihat pada Tabel 4.5.

Tabel 4.5 Inisialisasi Data Hari

Hari	Inisial
Minggu	0
Senin	1
Selasa	2
Rabu	3
Kamis	4
Jumat	5
Sabtu	6

Inisialisasi kegiatan kalender juga perlu agar mempermudah proses perhitungan. Kegiatan pada kalender ini dilakukan pengelompokan menjadi 3 kegiatan. Inisialisasi kegiatan dapat dilihat pada Tabel 4.6.

Tabel 4.6 Inisialisasi Data Kegiatan

Kegiatan Kalender	Inisial
Libur/Tanggal merah	0
Cuti bersama	1
Hari kerja	2

Inisialisasi terhadap data tanggal, curah hujan dan data penjualan tidak dilakukan karena data-data tersebut sudah dalam bentuk numerik sehingga sudah

dapat diproses ke tahap perhitungan selanjutnya. Setelah data di inisialisasi, maka semua data telah berubah menjadi bentuk numerik dan siap untuk dilakukan perhitungan. Hasil dari inisialisasi data AMDK DAXU 240ml dapat dilihat Tabel 4.7.

Tabel 4.7 Hasil Integrasi Inisialisasi Data

Hari	Tanggal	Kegiatan	Curah Hujan (mm)	Penjualan (pcs)
2	1	0	1.4	0
3	2	2	12	27
4	3	2	15.2	458
5	4	2	13.4	20
6	5	2	7.7	7
0	6	0	0.6	0
1	7	2	1	4
...
...
6	31	2	0	101

c. Normalisasi

Fungsi aktivasi JST *backpropagation* menggunakan *sigmoid biner* yang memiliki *range* keluaran adalah 0 sampai 1 maka diperlukan normalisasi yaitu dengan mengubah data menjadi 0 sampai 1. Hasil normalisasi dapat dilihat pada tabel 4.2. Mengubah data menjadi antara 0 sampai 1 yaitu dengan menggunakan rumus persamaan berikut (Hasan & Fatta, 2019):

Dimana

x = nilai yang akan dinormalisasikan

Min x = nilai terkecil dari x

Max x = nilai terbesar dari x

Max y = nilai terbesar dari nilai yang baru

Min y = nilai terkecil dari nilai yang baru

Hasil normalisasi data produk AMDK DAXU 240ml dengan menggunakan rumus persamaan (4.1) dapat dilihat pada Tabel 4.8.

Tabel 4.8 Hasil Normalisasi Data

Hari	Tanggal	Kegiatan	Curah Hujan (mm)	Penjualan (pes)
0.333333333	0	0	0.008206331	0
0.5	0.033333333	1	0.070339977	0.042789223
0.666666667	0.066666667	1	0.089097304	0.725832013
0.833333333	0.1	1	0.078546307	0.031695721
1	0.133333333	1	0.045134818	0.011093502
0	0.166666667	0	0.003516999	0
0.166666667	0.2	1	0.005861665	0.006339144
...
...
1	1	1	0	0.1600634

Pada proses normalisasi ini diperlukan nilai terbesar dan terkecil. Nilai terkecil akan bernilai 0 sedangkan nilai terbesar akan bernilai 1, sehingga nilai diantara nilai terbesar dan terkecil akan bernilai diantara 0 sampai 1.

4.1.3. Parameter dan Arsitektur JST

Menurut (Fausett, 1994) sebelum melakukan proses pelatihan, terdapat beberapa parameter jaringan yang harus ditentukan dahulu, yaitu:

- a. Lapisan masukan (*input layer*)

Lapisan masukan (*input layer*) adalah variabel luar atau faktor yang tidak dapat di cegah oleh perusahaan yang mempengaruhi besarnya penjualan pada unit

bisnis AMDK DAXU PDAM Tirta Sembada Sleman. Algoritma JST memiliki prinsip kerja dengan belajar dari pola data yang diberikan, dimana dalam kasus ini lapisan masukan terdiri dari 4 neuron yaitu X1, X2, X4 dan X4 yang didapatkan dari hasil analisis dan wawancara.

Mahasiswa di Yogyakarta berasal dari berbagai macam daerah. Mahasiswa yang berasal dari pulau jawa pada hari-hari tertentu pulang "mudik" untuk bertemu dengan keluarga sehingga secara tidak langsung akan mempengaruhi penjualan AMDK DAXU. Oleh karena itu, variabel hari digunakan sebagai input X1.

Selain mahasiswa, AMDK DAXU juga melayani penjualan kebutuhan pegawai, komunitas dan perkantoran/instansi sehingga potensi penjualan produk AMDK saat akhir bulan atau awal bulan biasanya akan lebih besar dari tanggal-tanggal sebelum itu. Oleh karena itu, variabel tanggal digunakan sebagai input X2.

Unit bisnis AMDK "DAXU" PDAM Sleman di bawah pengawasan Bupati Sleman yang memberikan amanat bahwa seluruh instansi pemerintah untuk setiap kegiatan yang dilakukan yang membutuhkan konsumsi wajib menggunakan produk AMDK DAXU. Kegiatan-kegiatan yang ada di kawasan pemerintahan ini mengikuti kalender digunakan sebagai variabel yang mempengaruhi penjualan. Oleh karena itu, variabel kegiatan digunakan sebagai input X3.

Pada musim tertentu bahan baku yaitu air, mengalami penururan debit air sehingga terjadi penuruan produksi yang *berimpact* pada penjualan. Oleh karena itu, variabel curah hujan digunakan sebagai input X4.

b. Lapisan tersembunyi (*hidden layer*)

Dalam menentukan lapisan tersembunyi ini belum ada aturan untuk menentukan jumlah lapisan dan neuron, maka diperlukan eksperimen dan pengujian beberapa kombinasi jumlah lapisan tersembunyi dan neuron untuk pencarian arsitektur jaringan paling optimal. Pada penelitian ini menggunakan 1 lapisan tersembunyi (Z). Kombinasi neuron pada lapisan tersembunyi yang di analisis yaitu sebanyak 1 sampai 10 neuron.

c. Lapisan keluaran (*output layer*)

Penelitian yang dilakukan bertujuan untuk memprediksi jumlah penjualan produk pada periode atau masa yang akan datang, sehingga jumlah penjualan digunakan sebagai output (Y) pada jaringan.

d. Laju Pembelajaran (*learning rate*)

Parameter *learning rate* yang dilambangkan dengan α (alpha) harus diberikan nilai positif kurang dari 1. Semakin tinggi nilai α maka akan semakin cepat kemampuan jaringan belajar, namun *error* yang dihasilkan tidak merata. Pada penelitian ini akan menganalisis dengan 4 nilai α yaitu 0,1, 0,35, 0,5 dan 0,75.

e. Jumlah Iterasi (*epoch*)

Penelitian ini menggunakan data pelatihan yang merupakan data penjualan selama 229 hari atau 7 bulan 2 minggu dengan data sebanyak 229 data. Data sebanyak 229 ini memerlukan proses pelatihan yang membutuhkan waktu cukup lama sehingga iterasi maksimal untuk mendapatkan target optimal yang digunakan adalah 5000 kali. Semakin banyak iterasi maka semakin banyak waktu

yang dibutuhkan dalam proses pelatihan jaringan, namun kemungkinan untuk mendapatkan *error* terkecil semakin besar.

f. Pembobotan

Pada arsitektur JST pembobotan awal sangat mempengaruhi JST dalam mencapai nilai minimum global atau lokal terhadap nilai *error* serta percepatan waktu proses menuju ke konvergenan. Biasanya bobot awal diinisialisasi secara random dengan nilai antara 0 sampai 1.

Apabila bobot awal terlalu besar maka *input* ke setiap lapisan akan jatuh pada turunan fungsi *sigmoid* yang kecil (Marjiyono, WA Soedijono, et al., 2018), sementara jika bobot awal terlalu kecil maka *input* ke lapisan akan sangat kecil. Hal ini akan menyebabkan proses pelatihan berjalan sangat lambat.

Mengetahui beberapa kekurangan yang ada pada pembobotan acak, maka penelitian ini akan melakukan pembobotan dengan menggunakan metode *nguyen-widrow* sehingga bobot yang dihasilkan mendapatkan bobot optimal dengan proses komputasi pelatihan yang lebih cepat. Inisialisasi bobot menggunakan metode pembobotan *nguyen-widrow* mengikuti jaringan yang akan dibuat. Sebagai contoh jika model yang akan dibangun adalah model jaringan dengan 4 neuron *input*, 10 neuron *hidden* dan 1 neuron output dengan learning rate 0,75 maka contoh inisialisasi bobot awal input sebagai berikut:

$$v_i = \begin{bmatrix} 0.3147 & -0.3424 & 0.1557 & 0.2060 \\ 0.4058 & 0.4706 & -0.4643 & -0.4682 \\ -0.3730 & 0.4572 & 0.3491 & -0.2231 \\ 0.4134 & -0.0146 & 0.4340 & -0.4538 \\ 0.1324 & 0.3003 & 0.1787 & -0.4029 \\ -0.4025 & -0.3581 & 0.2577 & 0.3235 \\ -0.2215 & -0.0782 & 0.2431 & 0.1948 \\ 0.0469 & 0.4157 & -0.1078 & -0.1829 \\ 0.4575 & 0.2922 & 0.1555 & 0.4502 \\ 0.4649 & 0.4595 & -0.3288 & -0.4656 \end{bmatrix}$$

Setelah mendapat angka inisialisasi awal dari bobot maka hitung nilai $\|V_j\|$ dengan persamaan (2.25)

$$v_1 = \sqrt{(0,3147)^2 + (-0,3424)^2 + (0,1557)^2 + (0,2060)^2} = 0,5319$$

$$v_2 = \sqrt{(0,4058)^2 + (0,4706)^2 + (-0,4643)^2 + (-0,4682)^2} = 0,9060$$

$$v_3 = \sqrt{(-0,3730)^2 + (0,4572)^2 + (0,3491)^2 + (-0,2231)^2} = 0,7210$$

$$v_4 = \sqrt{(0,4134)^2 + (-0,0146)^2 + (0,4340)^2 + (-0,4538)^2} = 0,7519$$

$$v_5 = \sqrt{(0,1324)^2 + (0,3003)^2 + (0,1787)^2 + (-0,4029)^2} = 0,5495$$

$$v_6 = \sqrt{(-0,4025)^2 + (-0,3581)^2 + (0,2577)^2 + (0,3235)^2} = 0,6792$$

$$v_7 = \sqrt{(-0,2215)^2 + (-0,0782)^2 + (0,2431)^2 + (0,1948)^2} = 0,3902$$

$$v_8 = \sqrt{(0,0469)^2 + (0,4157)^2 + (-0,1078)^2 + (-0,1829)^2} = 0,4691$$

$$v_9 = \sqrt{(0,4575)^2 + (0,2922)^2 + (0,1555)^2 + (0,4502)^2} = 0,7222$$

$$v_{10} = \sqrt{(0,4649)^2 + (0,4595)^2 + (-0,3288)^2 + (-0,4656)^2} = 0,8673$$

Sehingga didapatkan bobot v_j seperti pada Tabel 4.9.

Tabel 4.9 Hasil Bobot V_j

v1=	0.5319
v2=	0.9060
v3=	0.7210
v4=	0.7519
v5=	0.5495
v6=	0.6792
v7=	0.3902
v8=	0.4691
v9=	0.7222
v10=	0.8673

Setelah itu inisialisasi ulang bobot-bobot *input layer* ke *hidden layer* (V_{ij}) dengan persamaan (2.26). Pada rumus persamaan (2.26) untuk mendapatkan nilai β menggunakan rumus $0.7\sqrt{p}$ sehingga jika dalam kasus ini dimana jumlah neuron input adalah 4 dan neuron tersembunyi sejumlah 10 maka didapatkan nilai adalah $\beta = 0.7(\sqrt{10}) = 1,2448$. Nilai bobot awal yang digunakan dalam penelitian ini dapat dilihat pada Tabel 4.10 dan Tabel 4.11.

Tabel 4.10 Bobot Awal dan Bias 1 Lapisan Tersembunyi (10 neuron)

	v1	v2	v3	v4	b1
z1	0.7364	-0.8013	0.3644	0.4821	-0.1525
z2	0.5575	0.6465	-0.6379	-0.6432	-0.2949
z3	-0.6440	0.7894	0.6027	-0.3852	0.6610
z4	0.6844	-0.0242	0.7185	-0.7512	0.7349
z5	0.2999	0.6803	0.4048	-0.9127	-0.7796
z6	-0.7377	-0.6563	0.4723	0.5929	-0.0255
z7	-0.7067	-0.2495	0.7756	0.6215	-0.1355

Tabel 4.10 Bobot Awal dan Bias 1 Lapisan Tersembunyi (10 neuron) (Lanjutan)

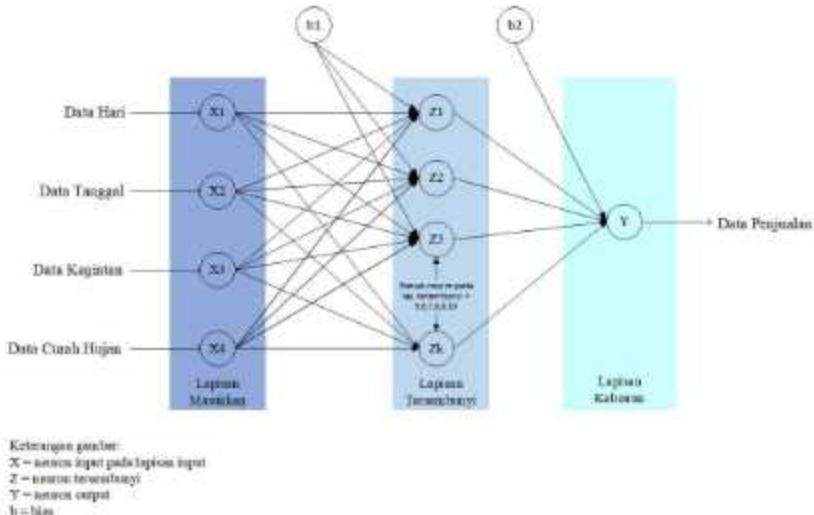
	v1	v2	v3	v4	b1
z8	0.1244	1.1030	-0.2860	-0.4853	0.3643
z9	0.7886	0.5037	0.2680	0.7760	0.5212
z10	0.6673	0.6595	-0.4719	-0.6683	0.6341

Tabel 4.11 Bobot Awal dan Bias Awal Hidden Layer ke Output Layer

	Y
w1	0.2551
w2	0.5060
w3	0.6991
w4	0.8909
w5	0.9593
w6	0.5472
w7	0.1386
w8	0.1493
w9	0.2575
w10	0.8407
b21	0.1000

g. Target MSE (*goal*)

Pada kegiatan peramalan penjualan tentu tidak dapat mencapai nilai *error* 0 sehingga butuh target *error* yang diharapkan. Pada penelitian ini target *error* MSE yang diharapkan adalah 0.01 atau 1%. Arsitektur JST *backpropagation* yang digunakan dalam penelitian ini dapat dilihat pada Gambar 4.12.



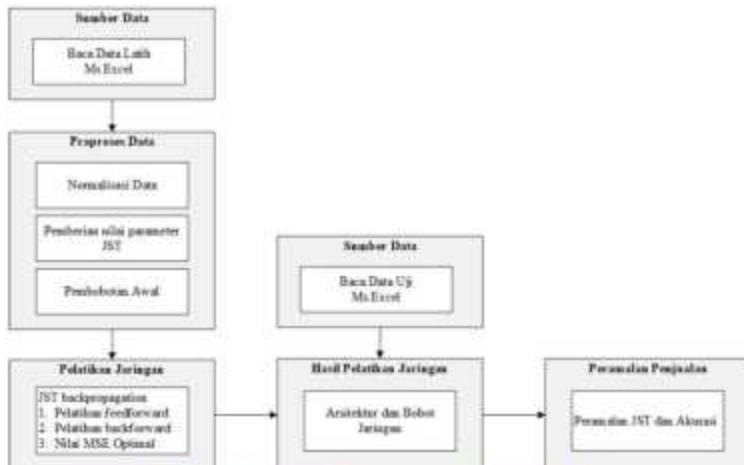
Gambar 4.1 Arsitektur JST Peramalan Penjualan AMDK DAXU

Pada Gambar 4.1 terlihat bahwa arsitektur yang digunakan yaitu pada lapisan *input* terdapat 4 neuron, pada lapisan tersembunyi terdapat 1 sampai 10 neuron dan 1 neuron pada lapisan *output*.

4.2. Action Taking

Pada tahap ini dilakukan pengembangan *prototype* aplikasi untuk melatih dan menguji jaringan yang digunakan. *Prototype* dikembangkan dengan memanfaatkan Matlab 2018a dan Ms. Excel sebagai pendukung. Data penjualan selama 229 hari digunakan untuk melatih arsitektur JST *backpropagation* yang bertujuan agar mendapatkan arsitektur yang paling optimal.

Gambaran umum *prototype* sistem pelatihan dan pengujian JST *backpropagation* AMDK DAXU pada unit bisnis PDAM Tirta Sembada Sleman dapat dilihat pada Gambar 4.2.

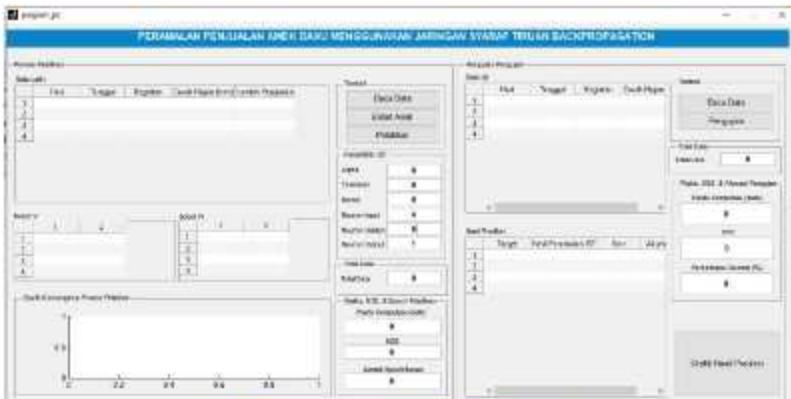


Gambar 4.2 Gambaran Umum Sistem Peramalan

Pada Gambar 4.2 proses pelatihan dimulai dari pembacaan data latih, kemudian dilakukan praproses data sehingga nilai dari data berada diantara 0 sampai 1. Pada langkah ini parameter JST seperti nilai α , toleransi *error*, maksimal epoch dan jumlah neuron lapisan tersembunyi di *input* oleh user. Setelah itu, sistem akan melakukan pelatihan terhadap data dengan JST *backpropagation* sehingga menghasilkan sebuah *output* berupa arsitektur dan bobot terupdate. Hasil pelatihan terbaik akan digunakan pada data uji untuk menhasilkan peramalan JST dan akurasi.

4.2.1. Prototype Peramalan JST *Backpropagation*

Prototype dikembangkan dengan Matlab 2018a. Berikut adalah tampilan antarmuka program “Peramalan Penjualan Air Minum Dalam Kemasan Menggunakan Jaringan Syaraf Tiruan *Backpropagation*” yang dikembangkan menggunakan Matlab GUI 2018a.



Gambar 4.3 Tampilan Antarmuka Prototype

Berdasarkan Gambar 4.3 di atas terlihat bahwa pada antarmuka *prototype* terdapat dua buah panel yaitu penel “Proses Pelatihan” dan panel “Proses Pengujian”. Penel “Proses Pelatihan” berisi kontrol-kontrol yang merepresentasikan tahapan-tahapan yang dilakukan pada proses pelatihan. Adapun pada panel “Proses Pengujian” terdapat kontrol-kontrol yang digunakan untuk melakukan proses prediksi data penjualan AMDK. Berikut adalah perintah yang digunakan untuk melakukan proses pelatihan yang terdapat dalam *Callback* tombol “Pelatihan”.

```
function tombolPelatihan_Callback(hObject, eventdata, handles)
global input
global kode
global label
disp('Bobot awal V dan W');
V=get(handles.uitableBobotV,'Data')
W=get(handles.uitableBobotW,'Data')
[baris kolom]=size(input)
disp('parameter-parameter jst');
n_input=str2num(get(handles.editNeuronInput,'String'))
n_hidden=str2num(get(handles.editNeuronHidden,'String'))
n_output=str2num(get(handles.editNeuronOutput,'String'))
alpha=str2num(get(handles.editAlpha,'String'))
toleransi=str2num(get(handles.editToleransi,'String'))
iterasi=str2num(get(handles.editIterasi,'String'))
target=zeros(baris/n_input,1);
%proses pelatihan
z=[];
```

```

Y=[];
konvergensi=[];
eror=0;
addpath('E:\Muliah          S2_backup2\Bimmillah      THEISI\b');
Matlab\Program\PROGRAM\bp\');
n_iterasi=0;
tic
indexawal=1;
indexakhir=1;
for iter=1:iterasi
    disp(['iterasi ke-',num2str(iter)]);
    for i=1:(baris/n_input)
        if i==1
            indexawal=i;
            indexakhir=n_input;
        else
            indexawal=(i-1)*n_input+1;
            indexakhir=(i-1)*n_input+n_input;
        end
        X=input(indexawal:indexakhir)';
        norm_input=normalisasi(X);
        target(i,:)=max(X);
        disp('Perambatan Maju')
        Z(i,:)
    Y(i,:)=PerambatanMaju(norm_input,V,W,n_hidden,n_output)
    [V
    W]=PerambatanMundur(alpha,Y(i,:),max(norm_input),V,W,Z(i,:),norm_input
    );
    eror=MSE(max(norm_input),Y(i,:));
end
konvergensi(iter)=eror;
n_iterasi=iter;
if eror<toleransi
    break
end
end
waktu=toc
n_iterasi
konvergensi'
set(handles.editWaktu,'String',num2str(waktu))
set(handles.editError,'String',num2str(eror))
set(handlesuitableRobotV,'Data',V);
set(handlesuitableRobotW,'Data',W);
axes(handles.axes3)
plot(konvergensi);
title('Grafik Konvergensi Proses Pelatihan');
ylabel('Eror');
xlabel('Iterasi');
save bobotV_terlatih.mat V;
save bobotW_terlatih.mat W;

```

Setelah dilakukan proses pelatihan, selanjutnya dilakukan proses pengujian dengan menggunakan data uji dan arsitektur yang telah dilatih sebelumnya pada panel "Proses Pengujian". Berikut adalah perintah yang

digunakan untuk melakukan proses pengujian yang terdapat dalam *Callback* tombol “Pengujian”.

```

function tombolPengujian_Callback(hObject, eventdata, handles)
global input2
global hasiljst
global outputsebenarnya

%mengambil bobot v dan w terakhir
disp('Bobot awal V dan W');
V=get(handles.uitableBobotV,'Data')
W=get(handles.uitableBobotW,'Data')
[baris kolom]=size(input2);
datauji=input2
%mengambil parameter-parameter ist
disp('parameter-parameter ist');
n_input=str2num(get(handles.editNeuronInput,'String'))
n_hidden=str2num(get(handles.editNeuronHidden,'String'))
n_output=str2num(get(handles.editNeuronOutput,'String'))
alpha=str2num(get(handles.editAlpha,'String'))
toleransi=str2num(get(handles.editToleransi,'String'))
iterasi=str2num(get(handles.editIterasi,'String'))

%proses pelatihan
z=[];
y=[];
hasil_prediksi1=[];
hasil_prediksi2=[];
data_sebenarnya=[];
konvergensi=[];
error=0;
tic
addpath('ni\Kuliah S2_bacup2\Himmillah THESIS\6
Program\PROGRAM\lp'); %menambahkan path supaya fungsi-fungsi yang
terdapat pada folder lp dikenali
n_iterasi=0;
waktu_komputasi=awal
tic

%Proses Prediksi JST
for i=1:baris
    disp('Perambatan Maju')
    [Z(i,:)]
    Y(i,:)=PerambatanMaju(datauji(i,:),V,W,n_hidden,n_output)
    hasil_prediksi(i,:)=int32(denormalisasi(Y(i,:),outputsebenarnya))
end
error=abs(outputsebenarnya-hasil_prediksi)
%menghitung akurasi tiap hasil prediksi
[baris,kolom]=size(error);
akurasi=zercon(Baris,1);
for i=1:baris
    a=0;
    b=0;
    if outputsebenarnya(i,1)<hasil_prediksi(i,1)
        a=outputsebenarnya(i,1)+100;
        b=hasil_prediksi(i,1)+100;
    else
        a=hasil_prediksi(i,1)+100;
        b=outputsebenarnya(i,1)+100;
    end
end

```

```

akurasi(i,1)=a/b*100
end
%menyimpan hasil jst pada variabel global
hasiljst=[outputsebenarnya hasil_prediksi eror akurasi]

%waktu komputasi akhir
waktustoc;
%menghitung dan menampilkan nilai MSE
MSE=sum(eror.^2)/baris;
set(handles.editMSE,Pengujian,'String',num2str(MSE));

%menghitung dan menampilkan nilai rata2 akurasi
rerataakurasi=sum(akurasi)/baris;
set(handles.editPercentase,'String',num2str(rerataakurasi));

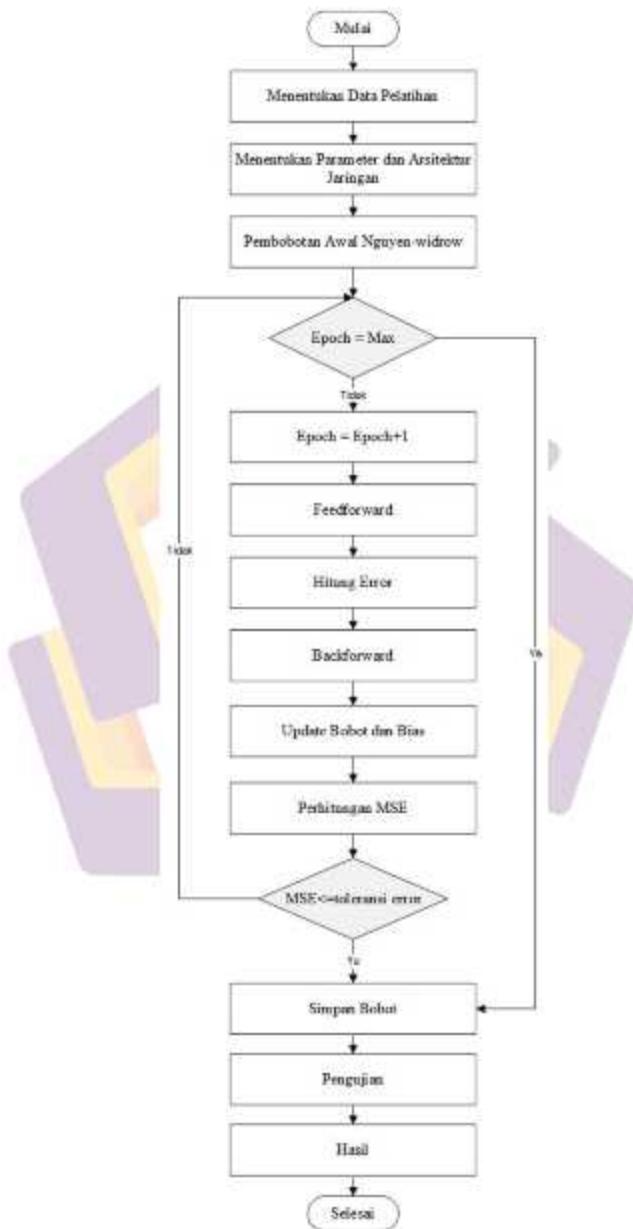
set(handles.tabelHasilPrediksi,'Data',hasiljst);
%menampilkan waktu komputasi prediksi pada kotak teks
set(handles.editWaktuJST,'String',num2str(waktu));

```

4.2.2. Pelatihan dan Analisis Data

Pada tahap ini yaitu mencari arsitektur JST *backpropagation* terbaik dan akurasinya dalam meramal penjualan AMDK pada unit bisnis PDAM Tirta Sembada Sleman. Pelatihan dilakukan pada seluruh produk AMDK DAXU yaitu kemasan 240ml, 330ml, 600ml, 19liter dan revil 19liter. Setiap percobaan pelatihan jaringan dibatasi dengan maksimal iterasi sebanyak 5000 kali dengan target MSE sebesar 0.01.

Pada JST *backpropagation* yang dikombinasikan dengan metode pembobotan *nguyen-widrow* pada penelitian ini proses pelatihan dapat dilihat pada Gambar 4.4.



Gambar 4.4 Flowchart Pelatihan JST Backpropagation dan Nguyen-widrow

Berikut adalah penjelasan untuk Gambar 4.4 yaitu proses pelatihan JST *backpropagation* dan *nguyen-widrow*:

1. Pembacaan Data Latih

Langkah pertama yang dilakukan yaitu memasukan data latih ke dalam sistem. Data telah di bagi 2 yaitu data latih dan data uji. Data latih sebanyak 229 data sementara data uji sejumlah 14 data.

2. Menentukan nilai parameter dan arsitektur

Agar data data dapat diproses dengan baik menggunakan fungsi aktivasi *sigmoid biner* maka dilakukan praproses yaitu antara lain normalisasi, pemberian nilai parameter *alpha* (*a*), toleransi *error*, bobot awal, jumlah *input*, *hidden* dan *output layer*. Pembobotan awal menggunakan metode pembobotan yaitu *nguyen-widrow* yang bertujuan agar proses pelatihan lebih cepat dengan bobot optimal.

Sebagai contoh proses perhitungan manual dengan penjabaran menggunakan persamaan JST, bobot awal telah ditentukan pada pada Tabel 4.10 dan Tabel 4.11 pada pembahasan parameter dan arsitektur.

3. *Feedforward*

Data pelatihan dihitung dengan bobot awal sehingga di dapatkan nilai *output* dari jaringan, nilai *output* akan dibandingkan dengan data penjualan untuk didapatkan nilai *errortnya*. Pada proses *feedforward* artinya mencari nilai untuk nilai Z dan nilai Y. Contoh perhitungan manual dengan menggunakan persamaan (2.11).

$$\begin{aligned}Z_{\text{out}} &= -0,1525 + 0,3333(0,7364) + 0(-0,8013) + 0(0,3644 + 0,0082(0,482)) = 0,0969 \\Z_{\text{out2}} &= -0,2949 + 0,3333(0,5573) + 0(0,6465) + 0(-0,6379 + 0,0082(-0,6432)) = -0,1142\end{aligned}$$

$$\begin{aligned}
 Z_{\text{int}4} &= 0,7349 + 0,3333(0,6844) + 0(-0,0242) + 0(0,7185) + 0,0082(-0,7512) = 0,9569 \\
 Z_{\text{int}5} &= -0,7796 + 0,3333(0,2999) + 0(0,6803) + 0(0,4048) + 0,0082(-0,9127) = -0,6871 \\
 Z_{\text{int}6} &= -0,0255 + 0,3333(-0,7377) + 0(-0,6563) + 0(0,4723) + 0,0082(0,5929) = -0,2665 \\
 Z_{\text{int}7} &= -0,1355 + 0,3333(-0,7067) + 0(-0,2495) + 0(0,7756) + 0,0082(0,6215) = -0,3660 \\
 Z_{\text{int}8} &= 0,3643 + 0,3333(0,1244) + 0(1,030) + 0(-0,2860) + 0,0082(-0,4853) = 0,4018 \\
 Z_{\text{int}9} &= 0,5212 + 0,3333(0,7886) + 0(0,5037) + 0(0,2680) + 0,0082(0,7760) = 0,7904 \\
 Z_{\text{int}10} &= 0,6341 + 0,3333(0,6673) + 0(0,6595) + 0(-0,4719) + 0,0082(-0,6683) = 0,8510
 \end{aligned}$$

Kemudian menggunakan fungsi aktifasi untuk menghitung sinyal *output* menggunakan persamaan (2.12).

$$z_1 = \frac{1}{1 + e^{-0,12551}} = 0,5242$$

$$z_2 = \frac{1}{1 + e^{-0,11401}} = 0,4714$$

$$z_3 = \frac{1}{1 + e^{-0,4432}} = 0,6090$$

$$z_4 = \frac{1}{1 + e^{-0,93101}} = 0,7225$$

$$z_5 = \frac{1}{1 + e^{-0,5877}} = 0,3347$$

$$z_6 = \frac{1}{1 + e^{-0,2065}} = 0,4338$$

$$z_7 = \frac{1}{1 + e^{-0,33001}} = 0,4095$$

$$z_8 = \frac{1}{1 + e^{-0,5881}} = 0,4018$$

$$z_9 = \frac{1}{1 + e^{-0,7004}} = 0,6879$$

$$z_{10} = \frac{1}{1 + e^{-0,81301}} = 0,7008$$

Setelah itu lakukan penjumlahan sinyal-sinyal berbobot *output layer* dengan menggunakan persamaan (2.13).

$$\begin{aligned}
 Y_{\text{int}} &= 0,1000 + (0,5242)(0,2551) + (0,4717)(0,5060) + (0,6090)(0,6991) \\
 &+ (0,7225)(0,8909) + (0,3347)(0,9593) + (0,4338)(-0,2090) + (0,4095)(-0,4984) \\
 &+ (0,5991)(-0,3738) + (0,6879)(0,1209) + (0,7008)(0,8407) \\
 &= 3,0126
 \end{aligned}$$

Gunakan fungsi aktifasi kembali untuk menghitung sinyal *output* dengan menggunakan persamaan (2.14).

$$y_1 = \frac{1}{1 + e^{-3,0126}} = 0,9531$$

Sampai sini proses perhitungan *feedforward* selesai. Selanjutnya lakukan perhitungan *backpropagation*.

4. Backforward (perhitungan *backpropagation*)

Langkah *backforward* menggunakan nilai *error* dari langkah sebelumnya untuk menubah seluruh bobot awal sehingga didapatkan nilai bobot yang baru. Bobot yang baru ini akan digunakan dalam perhitungan dengan data kedua dimana nilai bobot baru dari hasil perhitungan data kedua dipakai untuk perhitungan data selanjutnya sampai semua data sudah digunakan dalam perhitungan, maka akan didapatkan rata-rata *errornya*. Contoh perhitungan manual dimulai dengan menggunakan persamaan (2.15) yaitu hitung informasi *error* (δ) di *output layer*.

$$\delta_{2j} = (0 - 0,9531)(0,9531)(1 - 0,9531) = -0,0426$$

Setelah itu hitung koreksi bobot W_{ij} dengan persamaan (2.16).

$$\Delta W_{11} = (0,75)(-0,0426)(0,5242) = -0,0167$$

$$\Delta W_{21} = (0,75)(-0,0426)(0,4714) = -0,0151$$

$$\Delta W_{31} = (0,75)(-0,0426)(0,6090) = -0,0194$$

$$\Delta W_{41} = (0,75)(-0,0426)(0,7225) = -0,0231$$

$$\Delta W_{51} = (0,75)(-0,0426)(0,3347) = -0,0107$$

$$\Delta W_{61} = (0,75)(-0,0426)(0,4338) = -0,0138$$

$$\Delta W_{71} = (0,75)(-0,0426)(0,4095) = -0,0131$$

$$\Delta W_{81} = (0,75)(-0,0426)(0,5991) = -0,0191$$

$$\Delta W_{91} = (0,75)(-0,0426)(0,6879) = -0,0220$$

$$\Delta W_{101} = (0,75)(-0,0426)(0,7008) = -0,0224$$

$$\Delta b_{21} = (0,75)(-0,0426) = -0,0319$$

Koreksi bias b_{21} yang akan digunakan untuk mengupdate nilai W_{ij} dengan persamaan (2.17).

$$b_{21} = 0,1000 + (-0,0319) = 0,0681$$

$$w_{11} = 0,2551 + (-0,0167) = 0,2384$$

$$w_{21} = 0,5060 + (-0,0151) = 0,4909$$

$$w_{31} = 0,6991 + (-0,0194) = 0,6797$$

$$w_{41} = 0,8909 + (-0,0231) = 0,8678$$

$$w_{51} = 0,9593 + (-0,0107) = 0,9486$$

$$w_{61} = 0,5472 + (-0,0138) = 0,5334$$

$$w_{71} = 0,1386 + (-0,0131) = 0,1255$$

$$w_{81} = 0,1493 + (-0,0191) = 0,1302$$

$$w_{91} = 0,2575 + (-0,0220) = 0,2355$$

$$w_{101} = 0,8407 + (-0,0224) = 0,8183$$

Tiap-tiap neuron tersembunyi menjumlahkan delta inputannya dari neuron-neuron yang berada pada lapisan diatasnya (*neuron hidden*) dengan persamaan (2.18).

$$\delta_{in1} = (-0,0426)(0,2551) = -0,0109$$

$$\delta_{in2} = (-0,0426)(0,5060) = -0,0215$$

$$\delta_{in3} = (-0,0426)(0,6991) = -0,0298$$

$$\delta_{in4} = (-0,0426)(0,8909) = -0,0379$$

$$\delta_{in5} = (-0,0426)(0,9593) = -0,0408$$

$$\delta_{in6} = (-0,0426)(0,5472) = -0,0233$$

$$\delta_{in7} = (-0,0426)(0,1386) = -0,0059$$

$$\delta_{in8} = (-0,0426)(0,1493) = -0,0064$$

$$\delta_{in9} = (-0,0426)(0,2575) = -0,0110$$

$$\delta_{in10} = (-0,0426)(0,8407) = -0,0358$$

Kemudian lakukan perkalian dengan turunan dari fungsi aktifasinya untuk menghitung informasi *error* dengan menggunakan persamaan (2.19).

$$\delta_1 = (-0,0109)(0,5242)(1 - 0,5242) = -0,0027$$

$$\delta_2 = (-0,0215)(0,4714)(1 - 0,4714) = -0,0054$$

$$\delta_3 = (-0,0298)(0,6090)(1 - 0,6090) = -0,0071$$

$$\delta_4 = (-0,0379)(0,7225)(1 - 0,7225) = -0,0076$$

$$\delta_5 = (-0,0408)(0,3347)(1 - 0,3347) = -0,0091$$

$$\delta_6 = (-0,0233)(0,4338)(1 - 0,4338) = -0,0057$$

$$\delta_7 = (-0,0059)(0,4095)(1 - 0,4095) = -0,0014$$

$$\delta_8 = (-0,0064)(0,5991)(1 - 0,5991) = -0,0015$$

$$\delta_9 = (-0,0110)(0,6879)(1 - 0,6879) = -0,0024$$

$$\delta_{10} = (-0,0358)(0,7008)(1 - 0,7008) = -0,0075$$

Lakukan perhitungan untuk koreksi perubahan bobot dan bias *input layer* ke *hidden layer* (V_{ij}) dan bias (b_{l_i}) yang nantinya akan digunakan untuk memperbaiki nilai V_{ij} dengan menggunakan persamaan (2.20) dan (2.21).

$$\Delta b_{l_1} = (0,75)(-0,0027) = -0,0020$$

$$\Delta V_{11} = (0,75)(-0,0027)(0,3333) = -0,0007$$

$$\Delta V_{21} = (0,75)(-0,0027)(0) = 0,0000$$

$$\Delta V_{31} = (0,75)(-0,0027)(0) = 0,0000$$

$$\Delta V_{41} = (0,75)(-0,0027)(0) = 0,0000$$

$$\Delta b_{l_2} = (0,75)(-0,0054) = -0,0040$$

$$\Delta V_{12} = (0,75)(-0,0054)(0,3333) = -0,0013$$

$$\Delta V_{22} = (0,75)(-0,0054)(0) = 0,0000$$

$$\Delta V_{32} = (0,75)(-0,0054)(0) = 0,0000$$

$$\Delta V_{42} = (0,75)(-0,0054)(0) = 0,0000$$

$$\Delta b_{l_3} = (0,75)(-0,0071) = -0,0053$$

$$\Delta V_{13} = (0,75)(-0,0071)(0,3333) = -0,0018$$

$$\Delta V_{23} = (0,75)(-0,0071)(0) = 0,0000$$

$$\Delta V_{33} = (0,75)(-0,0071)(0) = 0,0000$$

$$\Delta V_{43} = (0,75)(-0,0071)(0) = 0,0000$$

$$\begin{aligned}\Delta b l_4 &= (0,75)(-0,0076) = -0,0057 \\ \Delta V_{14} &= (0,75)(-0,0076)(0,3333) = -0,0019 \\ \Delta V_{24} &= (0,75)(-0,0076)(0) = 0,0000 \\ \Delta V_{34} &= (0,75)(-0,0076)(0) = 0,0000 \\ \Delta V_{44} &= (0,75)(-0,0076)(0) = 0,0000\end{aligned}$$

$$\begin{aligned}\Delta b l_5 &= (0,75)(-0,0091) = -0,0068 \\ \Delta V_{15} &= (0,75)(-0,0091)(0,3333) = -0,0023 \\ \Delta V_{25} &= (0,75)(-0,0091)(0) = 0,0000 \\ \Delta V_{35} &= (0,75)(-0,0091)(0) = 0,0000 \\ \Delta V_{45} &= (0,75)(-0,0091)(0) = 0,0000\end{aligned}$$

$$\begin{aligned}\Delta b l_6 &= (0,75)(-0,0057) = -0,0043 \\ \Delta V_{16} &= (0,75)(-0,0057)(0,3333) = -0,0014 \\ \Delta V_{26} &= (0,75)(-0,0057)(0) = 0,0000 \\ \Delta V_{36} &= (0,75)(-0,0057)(0) = 0,0000 \\ \Delta V_{46} &= (0,75)(-0,0057)(0) = 0,0000\end{aligned}$$

$$\begin{aligned}\Delta b l_7 &= (0,75)(-0,0014) = -0,0011 \\ \Delta V_{17} &= (0,75)(-0,0014)(0,3333) = -0,0004 \\ \Delta V_{27} &= (0,75)(-0,0014)(0) = 0,0000 \\ \Delta V_{37} &= (0,75)(-0,0014)(0) = 0,0000 \\ \Delta V_{47} &= (0,75)(-0,0014)(0) = 0,0000\end{aligned}$$

$$\begin{aligned}\Delta b l_8 &= (0,75)(-0,0015) = -0,0011 \\ \Delta V_{18} &= (0,75)(-0,0015)(0,3333) = -0,0004 \\ \Delta V_{28} &= (0,75)(-0,0015)(0) = 0,0000 \\ \Delta V_{38} &= (0,75)(-0,0015)(0) = 0,0000 \\ \Delta V_{48} &= (0,75)(-0,0015)(0) = 0,0000\end{aligned}$$

$$\begin{aligned}\Delta b l_9 &= (0,75)(-0,0024) = -0,0018 \\ \Delta V_{19} &= (0,75)(-0,0024)(0,3333) = -0,0006 \\ \Delta V_{29} &= (0,75)(-0,0024)(0) = 0,0000 \\ \Delta V_{39} &= (0,75)(-0,0024)(0) = 0,0000 \\ \Delta V_{49} &= (0,75)(-0,0024)(0) = 0,0000\end{aligned}$$

$$\Delta b_{10} = (0,75)(-0,0075) = -0,0056$$

$$\Delta V_{110} = (0,75)(-0,0075)(0,3333) = -0,0019$$

$$\Delta V_{210} = (0,75)(-0,0075)(0) = 0,0000$$

$$\Delta V_{310} = (0,75)(-0,0075)(0) = 0,0000$$

$$\Delta V_{410} = (0,75)(-0,0075)(0) = 0,0000$$

Sampai sini proses perhitungan *backpropagation* telah selesai untuk data pertama, selanjutnya lakukan perbaikan (*update*) bobot dan bias.

5. Perbaikan Bobot dan Bias

Memperbaiki nilai bobot W_{kj} dan bias b_{2k} dengan menggunakan persamaan (2.22).

$$b_{2j}(\text{baru}) = (0,1000) + (0,0681) = 0,1681$$

$$w_{11}(\text{baru}) = (0,2551) + (-0,0167) = 0,2384$$

$$w_{21}(\text{baru}) = (0,5060) + (-0,0151) = 0,4909$$

$$w_{31}(\text{baru}) = (0,6991) + (-0,0194) = 0,6797$$

$$w_{41}(\text{baru}) = (0,8909) + (-0,0231) = 0,8678$$

$$w_{51}(\text{baru}) = (0,9593) + (-0,0107) = 0,9486$$

$$w_{61}(\text{baru}) = (0,5472) + (-0,0138) = 0,5334$$

$$w_{71}(\text{baru}) = (0,1386) + (-0,0131) = 0,1255$$

$$w_{81}(\text{baru}) = (0,1493) + (-0,0191) = 0,1302$$

$$w_{91}(\text{baru}) = (0,2575) + (-0,0220) = 0,2355$$

$$w_{101}(\text{baru}) = (0,8407) + (-0,0224) = 0,8183$$

Selanjutnya perbaiki nilai bobot V_{kj} dan bias b_{2k} dengan menggunakan persamaan (2.23).

$$b_{2j}(\text{baru}) = (-0,0020) + (-0,1525) = -0,1545$$

$$V_{11}(\text{baru}) = 0,7364 + (-0,0007) = 0,7358$$

$$V_{21}(\text{baru}) = (-0,8013) + 0,0000 = -0,8013$$

$$V_{31}(\text{baru}) = 0,3644 + 0,0000 = 0,3644$$

$$V_{41}(\text{baru}) = 0,4821 + 0,0000 = 0,4821$$

$$b2_2(\text{baru}) = (-0,2949) + (-0,0040) = -0,2989$$

$$V_{12}(\text{baru}) = 0,5575 + (-0,0013) = 0,5562$$

$$V_{22}(\text{baru}) = 0,6465 + 0,0000 = 0,6465$$

$$V_{32}(\text{baru}) = (-0,6379) + 0,0000 = -0,6379$$

$$V_{42}(\text{baru}) = (-0,6432) + 0,0000 = 0,6027$$

$$b2_3(\text{baru}) = 0,6610 + (-0,0053) = 0,6557$$

$$V_{13}(\text{baru}) = (-0,6440) + (-0,0018) = -0,6458$$

$$V_{23}(\text{baru}) = 0,7894 + 0,0000 = 0,7894$$

$$V_{33}(\text{baru}) = 0,6027 + 0,0000 = 0,6027$$

$$V_{43}(\text{baru}) = (-0,3852) + 0,0000 = -0,3852$$

$$b2_4(\text{baru}) = 0,7349 + (-0,0057) = 0,7292$$

$$V_{14}(\text{baru}) = 0,6844 + 0,0000 = 0,6825$$

$$V_{24}(\text{baru}) = (-0,0242) + 0,0000 = -0,0242$$

$$V_{34}(\text{baru}) = 0,7185 + 0,0000 = 0,7185$$

$$V_{44}(\text{baru}) = (-0,7512) + 0,0000 = -0,7513$$

$$b2_5(\text{baru}) = (-0,7796) + (-0,0068) = -0,7864$$

$$V_{15}(\text{baru}) = 0,2999 + (-0,0023) = 0,2976$$

$$V_{25}(\text{baru}) = 0,6803 + 0,0000 = 0,6803$$

$$V_{35}(\text{baru}) = 0,4048 + 0,0000 = 0,4048$$

$$V_{45}(\text{baru}) = (-0,9127) + (-0,0001) = -0,9127$$

$$b2_6(\text{baru}) = (-0,0255) + (-0,0068) = -0,0298$$

$$V_{16}(\text{baru}) = (-0,7377) + (-0,0014) = -0,7391$$

$$V_{26}(\text{baru}) = (-0,6563) + 0,0000 = -0,6563$$

$$V_{36}(\text{baru}) = 0,4723 + 0,0000 = 0,4723$$

$$V_{46}(\text{baru}) = 0,5929 + 0,0000 = 0,5929$$

$$b2_7(\text{baru}) = (-0,1355) + (-0,0011) = -0,1366$$

$$V_{17}(\text{baru}) = (-0,7067) + (-0,0004) = -0,7071$$

$$V_{27}(\text{baru}) = (-0,2495) + 0,0000 = -0,2495$$

$$V_{37}(\text{baru}) = 0,7756 + 0,0000 = 0,7756$$

$$V_{47}(\text{baru}) = 0,6215 + 0,0000 = 0,6215$$

$$b_{2_8}(\text{baru}) = 0,3643 + (-0,0011) = 0,3632$$

$$V_{18}(\text{baru}) = 0,1244 + (-0,0004) = 0,1241$$

$$V_{28}(\text{baru}) = 1,1030 + 0,0000 = 1,1030$$

$$V_{38}(\text{baru}) = (-0,2860) + 0,0000 = -0,2860$$

$$V_{48}(\text{baru}) = (-0,4853) + 0,0000 = -0,4853$$

$$b_{2_9}(\text{baru}) = 0,5212 + (-0,0018) = 0,5194$$

$$V_{19}(\text{baru}) = 0,7886 + (-0,0006) = 0,7880$$

$$V_{29}(\text{baru}) = 0,5037 + 0,0000 = 0,5037$$

$$V_{39}(\text{baru}) = 0,2680 + 0,0000 = 0,2680$$

$$V_{49}(\text{baru}) = 0,7760 + 0,0000 = 0,7760$$

$$b_{2_{10}}(\text{baru}) = 0,6341 + (-0,0056) = 0,6285$$

$$V_{110}(\text{baru}) = 0,6673 + (-0,0019) = 0,6654$$

$$V_{210}(\text{baru}) = 0,6595 + 0,0000 = 0,6595$$

$$V_{310}(\text{baru}) = (-0,4719) + 0,0000 = -0,4719$$

$$V_{410}(\text{baru}) = (-0,6683) + 0,0000 = -0,6683$$

Sehingga di dapatkan bobot dan bias terlatih (bobot *update*) untuk data ke-1 pada

Tabel 4.12 dan Tabel 4.13.

Tabel 4.12 Bobot dan Bias Baru 1 Lapisan Tersembunyi (10 neuron)

	v1	v2	v3	v4	b1
z1	0.7358	-0,8013	0,3644	0,4821	-0,1545
z2	0.5562	0,6465	-0,6379	0,6027	-0,2989
z3	-0,6458	0,7894	0,6027	-0,3852	0,6557
z4	0,6825	-0,0242	0,7185	-0,7513	0,7292
z5	0,2976	0,6803	0,4048	-0,9127	-0,7864
z6	-0,7391	-0,6563	0,4723	0,5929	-0,0298
z7	-0,7071	-0,2495	0,7756	0,6215	-0,1366
z8	0,1241	1,1030	-0,2860	-0,4853	0,3632
z9	0,7880	0,5037	0,2680	0,7760	0,5194
z10	0,6654	0,6595	-0,4719	-0,6683	0,6285

Tabel 4.13 Bobot dan Bias Baru Hidden Layer ke Output Layer

	Y
w1	0.2384
w2	0.4909
w3	0.6797
w4	0.8678
w5	0.9486
w6	0.5334
w7	0.1255
w8	0.1302
w9	0.2355
w10	0.8183
b21	0.1681

Setelah mendapatkan nilai hasil perbaikan bobot dari data latih ke-1, maka gunakan bobot tersebut untuk perbaikan bobot dan bias pada data latih ke-2. Setelah mendapatkan hasil pada pelatihan ke-2 maka iterasi telah selesai dikerjakan, proses diulangi hingga mencapai nilai *error* terkecil atau *epoch* maksimal yang telah ditentukan.

6. Perhitungan *error*

Jika rata-rata *error* masih lebih besar dari yang diharapkan maka perhitungan akan diulang dari data ke-1 lagi dengan bobot terbaru hingga jumlah perulangan (iterasi) mencapai maksimum. Namun jika rata-rata *error* sudah lebih kecil atau sama dengan target, maka perulangan berhenti kemudian bobot yang terakhir disimpan. Hasil keluaran bobot dan bias pada iterasi yang telah

ditentukan akan di simpan untuk selanjutnya digunakan dalam memvalidasi data target.

Pada penelitian ini akan dilakukan peramalan penjualan terhadap produk AMDK DAXU, berikut adalah hasil pelatihan terhadap sejumlah variasi parameter JST pada data latih AMDK DAXU.

a. Pelatihan AMDK DAXU 240ml

Hasil pelatihan JST *backpropagation* dengan data penjualan AMDK DAXU 240ml dapat dilihat pada Tabel 4.14.

Tabel 4.14 Hasil Pelatihan Data AMDK DAXU 240ml

Hasil Pelatihan data AMDK DAXU 240ml tahun 2019 sebanyak 229 data. Max epoch 5000, target MSE 0,01.				
No	Learning Rate	Neuron Hidden Layer	Waktu Epoch (detik)	MSE Pelatihan
1	0,1	5	118	0,023151
2		6	183	0,023345
3		7	128	0,023257
4		8	133	0,023148
5		9	154	0,02306
6		10	175	0,023199
7	0,35	5	125	0,022672
8		6	128	0,022519
9		7	138	0,022639
10		8	136	0,022546
11		9	132	0,022691
12		10	143	0,022499
13	0,5	5	127	0,022368
14		6	171	0,022363
15		7	137	0,022088
16		8	141	0,022639
17		9	171	0,022649
18		10	150	0,022359
19	0,75	5	127	0,022664
20		6	181	0,02274

Tabel 4.14 Hasil Pelatihan Data AMDK DAXU 240ml (Lanjutan)

Hasil Pelatihan data AMDK DAXU 240ml tahun 2019 sebanyak 229 data, Max epoch 5000, target MSE 0,01.				
No	Learning Rate	Neuron Hidden Layer	Waktu Epoch (detik)	MSE Pelatihan
21	0,75	7	176	0.022392
22		8	176	0.022145
23		9	152	0.021774
24		10	179	0.022216

Pada tabel 4.14 didapatkan nilai MSE terkecil dengan *epoch* maksimal sebanyak 5000 kali adalah sebesar 0.021774. MSE tersebut didapatkan dari proses pelatihan 229 data dengan nilai *learning rate* 0,75, neuron pada lapisan tersembunyi sebanyak 9 neuron. Proses pelatihan dengan arsitektur ini membutuhkan waktu 152 detik pada *epoch* ke 5000 kali.

b. Pelatihan AMDK DAXU 330ml

Hasil pelatihan JST *backpropagation* dengan data penjualan AMDK DAXU 330ml dapat dilihat pada Tabel 4.15.

Tabel 4.15 Hasil Pelatihan Data AMDK DAXU 330ml

Hasil Pelatihan data AMDK DAXU REVIL 330ml tahun 2019 sebanyak 229 data. Max epoch 5000, target MSE 0,01				
No	Learning Rate	Neuron Hidden Layer	Waktu Epoch (detik)	MSE Pelatihan
1	0,1	5	394	0.019191
2		6	403	0.018726
3		7	425	0.018903
4		8	416	0.018702
5		9	447	0.018871
6		10	480	0.019023
7	0,35	5	413	0.01735
8		6	401	0.018338
9		7	425	0.017954

Tabel 4.15 Hasil Pelatihan Data AMDK DAXU 330ml (Lanjutan)

Hasil Pelatihan data AMDK DAXU REVIL 330ml tahun 2019 sebanyak 229 data. Max epoch 5000, target MSE 0.01				
No	Learning Rate	Neuron Hidden Layer	Waktu Epoch (detik)	MSE Pelatihan
10	0,5	8	391	0,017055
11		9	351	0,017704
12		10	339	0,017614
13		5	261	0,01751
14		6	276	0,016504
15		7	280	0,016944
16		8	272	0,016257
17		9	325	0,016455
18		10	328	0,017154
19		5	270	0,017184
20	0,75	6	260	0,016538
21		7	291	0,018542
22		8	307	0,016597
23		9	311	0,015987
24		10	325	0,015759

Pada tabel 4.15 didapatkan nilai MSE terkecil dengan *epoch* maksimal sebanyak 5000 kali adalah sebesar 0,015759. MSE tersebut didapatkan dari proses pelatihan 229 data dengan nilai *learning rate* 0,75, neuron pada lapisan tersembunyi sebanyak 10 neuron. Proses pelatihan dengan arsitektur ini membutuhkan waktu 325 detik pada *epoch* ke 5000 kali.

c. Pelatihan AMDK DAXU 600ml

Hasil pelatihan JST *backpropagation* dengan data penjualan AMDK DAXU 600ml dilihat pada Tabel 4.16.

Tabel 4.16 Hasil Pelatihan Data AMDK DAXU 600ml

Hasil Pelatihan data AMDK-DAXU 600ml tahun 2019 sebanyak 229 data, Max epoch 5000, target MSE 0.01				
No	Learning Rate	Neuron Hidden Layer	Waktu Epoch (detik)	MSE Pelatihan
1	0,1	5	368	0.01580
2		6	378	0.015974
3		7	415	0.015823
4		8	318	0.015628
5		9	339	0.015572
6		10	376	0.015809
7		5	287	0.015297
8		6	311	0.015446
9		7	297	0.015419
10		8	284	0.015349
11	0,35	9	307	0.015371
12		10	308	0.014496
13		5	241	0.015274
14		6	273	0.015233
15		7	277	0.015287
16		8	344	0.015028
17		9	281	0.015158
18		10	363	0.014066
19		5	357	0.015318
20		6	383	0.014803
21	0,5	7	341	0.015101
22		8	417	0.015232
23		9	430	0.014244
24		10	433	0.014228

Pada tabel 4.16 didapatkan nilai MSE terkecil dengan *epoch* maksimal sebanyak 5000 kali adalah sebesar 0.014066. MSE tersebut didapatkan dari proses pelatihan 229 data dengan nilai *learning rate* 0.5, neuron pada lapisan tersembunyi sebanyak 10 neuron. Proses pelatihan dengan arsitektur ini membutuhkan waktu 363detik pada *epoch* ke 5000 kali.

d. Pelatihan AMDK DAXU 19liter

Hasil pelatihan JST *backpropagation* dengan data penjualan AMDK DAXU 19liter dilihat pada Tabel 4.17.

Tabel 4.17 Hasil Pelatihan Data AMDK DAXU 19 liter

Hasil Pelatihan data AMDK DAXU 19liter tahun 2019 sebanyak 229 data. Max epoch 5000, target MSE 0.01				
No	Learning Rate	Neuron Hidden Layer	Waktu Epoch (detik)	MSE Pelatihan
1	0,1	5	0,11	0,007143
2		6	0,13	0,00735
3		7	0,15	0,0080159
4		8	0,16	0,0090226
5		9	0,17	0,0095703
6		10	0,18	0,0059193
7	0,35	5	0,09	0,0057526
8		6	0,10	0,0037211
9		7	0,10	0,0039887
10		8	0,10	0,0029282
11		9	0,11	0,0045617
12		10	0,11	0,0046376
13	0,5	5	0,10	0,0037665
14		6	0,10	0,0039887
15		7	0,10	0,003913
16		8	0,10	0,0031154
17		9	0,11	0,0028072
18		10	0,10	0,0028372
19	0,75	5	0,05	0,0028606
20		6	0,14	0,0024686
21		7	0,09	0,0025269
22		8	0,05	0,0023883
23		9	0,10	0,0092405
24		10	0,11	0,0024733

Pada tabel 4.17 didapatkan nilai MSE terkecil dengan *epoch* maksimal sebanyak 5000 kali adalah sebesar 0,0023883. MSE tersebut didapatkan dari

proses pelatihan 229 data dengan nilai *learning rate* 0.75, neuron pada lapisan tersembunyi sebanyak 8 neuron. Proses pelatihan dengan arsitektur ini membutuhkan waktu 0.05 detik pada *epoch* ke 3 kali.

e. Pelatihan AMDK DAXU revil 19liter

Hasil pelatihan JST *backpropagation* dengan data penjualan AMDK DAXU revil 19liter dapat dilihat pada Tabel 4.18.

Tabel 4.18 Hasil Pelatihan Data AMDK-DAXU Revil 19 liter

Hasil Pelatihan data AMDK DAXU Revil 19liter tahun 2019 sebanyak 229 data. Max epoch 5000, target MSE 0.01				
No	Learning Rate	Neuron Hidden Layer	Waktu Epoch (detik)	MSE Pelatihan
1	0,1	5	229	0.023551
2		6	244	0.023696
3		7	245	0.023599
4		8	336	0.023649
5		9	266	0.02368
6		10	278	0.02355
7		5	230	0.022435
8		6	251	0.023171
9		7	389	0.022298
10		8	494	0.02262
11	0,35	9	511	0.022459
12		10	346	0.023257
13		5	186	0.022408
14		6	165	0.022781
15		7	159	0.022817
16		8	166	0.02277
17		9	179	0.02291
18		10	193	0.022422
19	0,75	5	167	0.022516
20		6	155	0.022166
21		7	184	0.022463
22		8	167	0.022092

Tabel 4.18 Hasil Pelatihan Data AMDK DAXU Revil 19 liter (Lanjutan)

Hasil Pelatihan data AMDK DAXU Revil 19liter tahun 2019 sebanyak 229 data. Max epoch 5000, target MSE 0.01				
No	Learning Rate	Neuron Hidden Layer	Waktu Epoch (detik)	MSE Pelatihan
23		9	175	0.022395
24		10	176	0.023513

Pada tabel 4.18 didapatkan nilai MSE terkecil dengan *epoch* maksimal sebanyak 5000 kali adalah sebesar 0.022092. MSE tersebut didapatkan dari proses pelatihan 229 data dengan nilai *learning rate* 0.75, neuron pada lapisan tersembunyi sebanyak 8 neuron. Proses pelatihan dengan arsitektur ini membutuhkan waktu 167 detik pada *epoch* ke 5000 kali.

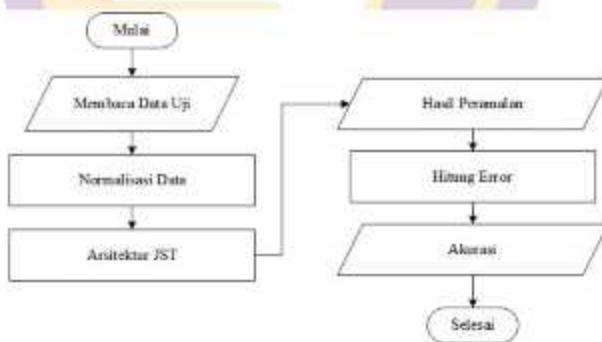
Berbeda dengan beberapa penelitian terdahulu, seperti penelitian oleh Marjiyono, dkk, (2018) MSE optimal terdapat pada arsitektur dengan 3 lapisan masukan, 1 lapisan tersembunyi, 3 neuron tersembunyi dan 1 lapisan keluaran (3-3-1). Penelitian oleh H. Aprilianto, dkk, (2018) MSE optimal terdapat pada lapisan 3 lapisan masukan, 1 lapisan tersembunyi dengan 10 neuron tersembunyi dan 1 lapisan keluaran (3-10-1). Penelitian oleh Gunaryati, dkk, (2018) MSE optimal terdapat pada lapisan 8 lapisan masukan, 1 lapisan tersembunyi dengan 12 neuron tersembunyi dan 1 lapisan keluaran (8-12-1) dan penelitian oleh Pakaja, dkk, (2012) MSE optimal terdapat pada lapisan 3 lapisan masukan, 1 lapisan tersembunyi dengan 4 neuron dan 1 lapisan keluaran (3-4-1). Hal ini menunjukkan bahwa untuk mendapatkan hasil peramalan yang optimal dibutuhkan arsitektur yang berbeda pada setiap kegiatan peramalan. Pada penelitian ini berdasarkan hasil pelatihan, perbedaan jumlah *hidden layer* pada masing-masing produk terjadi karena saat proses pelatihan JST mencari bobot & arsitektur terbaik untuk

model peramalannya. Setiap proses latih jumlah *hidden layer* disimpan dan dibandingkan dengan pelatihan selanjutnya, bobot terbaik akan disimpan dan arsitektur tersebut yang akan dipakai untuk peramalan.

4.3. Evaluating

Pada penelitian ini beberapa arsitektur diterapkan yaitu dengan kombinasi lapisan tersembunyi sebanyak 1 lapis, neuron pada lapisan tersembunyi sebanyak 5 sampai 10 neuron dan learning rate 0.1, 0.35, 0.5 dan 0.75. Arsitektur dengan nilai MSE terkecil akan digunakan dalam proses pengujian. Pengujian dilakukan dengan melakukan peramalan penjualan pada 14 hari mendatang. Hasil dari peramalan akan dibandingkan dengan data aktual penjualan (target) pada 14 hari tersebut sehingga dapat diketahui nilai *error* dari peramalan yang dilakukan.

Flowchart proses pengujian JST *backpropagation* pada peramalan penjualan dapat dilihat pada Gambar 4.5.



Gambar 4.5 Flowchart Pengujian JST Backpropagation

Berdasarkan Gambar 4.5 proses pengujian dimulai dari membaca data uji, kemudian data uji dinormalisasi dengan menggunakan nilai min dan max pada

data uji tersebut. Setelah data di normalisasi kemudian data di cari hasil peramalan dengan menggunakan arsitektur dan parameter yang sudah dilatih pada proses pelatihan sebelumnya. Hasil peramalan JST yang masih berupa angka normalisasi selanjutnya dilakukan denormalisasi menggunakan rumus persamaan (4.2) untuk mengembalikan data sehingga didapatkan nilai *sales forecasting* dari data *training*. Adapun rumus persamaan denormalisasi dalam range [0,1] adalah:

$$X_i = \nu(x_{\text{max}} - x_{\text{min}}) + x_{\text{min}}, \quad (4.2)$$

Dimana-

x_i = nilai data normal

v = hasil output jaringan

X_{\min} = data dengan nilai minimum

X_{\max} = data dengan nilai maximum

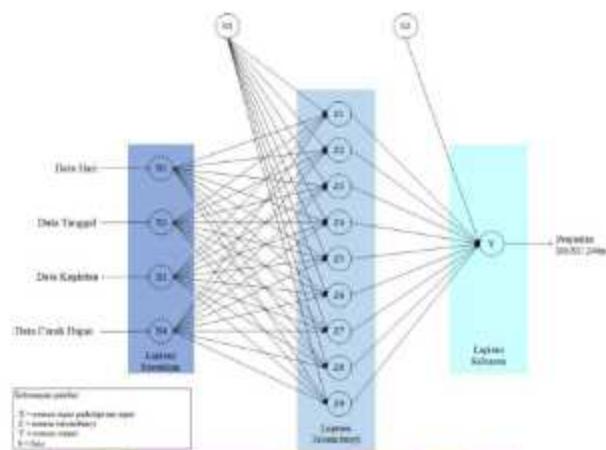
Nilai denormalisasi selanjutnya akan dihitung nilai *errornya* dengan data aktual. Kemudian hasil nilai *error* peramalan akan mendapatkan nilai MSE dan akurasinya. Berikut adalah kegiatan pengujian terhadap arsitektur JST pada data uji AMDK DAXU.

4.3.1. Pengujian Menggunakan Seluruh Data Aktual (Skenario Uji 1)

Pengujian pertama dilakukan terhadap keseluruhan data latih dan data uji, dimana data latih sebanyak 229 dan data uji sebanyak 14 data.

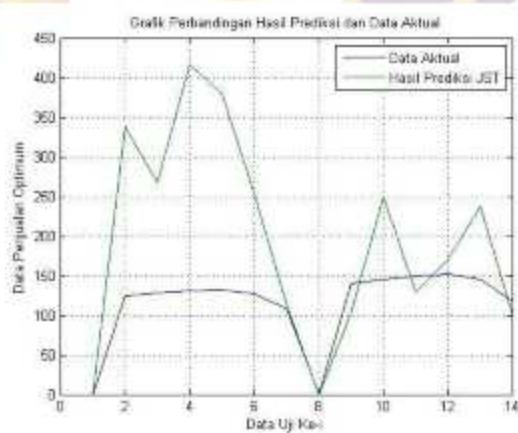
a. Pengujian data AMDK DAXU 240ml

Berdasarkan pada pelatihan data AMDK DAXU 240ml di dapatkan arsitektur terbaik untuk peramalan produk AMDK DAXU kemasan 240ml yaitu pada gambar 4.6.



Gambar 4.6 Arsitektur JST-BP Peramalan AMDK DAXU 240ml

Berdasarkan pada arsitektur Gambar 4.6, pengujian pada data penjualan DAXU 240ml dengan menggunakan arsitektur terbaik yaitu learning rate 0.75, lapisan tersembunyi sebanyak 1 lapis dan neuron pada lapisan tersembunyi sebanyak 9 neuron. Grafik hasil peramalan dapat dilihat pada Gambar 4.7.



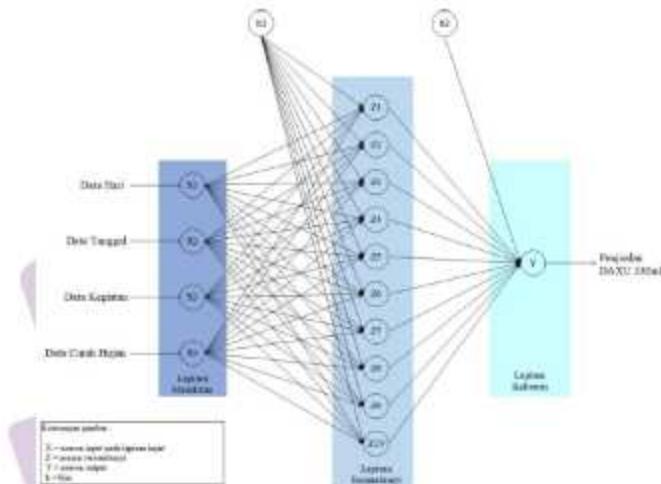
Gambar 4.7 Grafik Hasil Peramalan Produk AMDK DAXU 240ml

Berdasarkan Gambar 4.7 terlihat beberapa data mendekati nilai target artinya beberapa data memiliki *error* mendekati 0 namun tidak banyak. Pada data ke 1 menurut data aktual penjualan pada data uji adalah 0 dan hasil prediksi juga sama yaitu 0 *error* yang didapatkan 0 hasil akurasi 100%. Data ke 2 sejumlah 124 hasil prediksi 337 *error* yang didapatkan 213 hasil akurasi 51,25%, data ke 3 sejumlah 136 hasil prediksi 268 *error* yang didapatkan 132 hasil akurasi 64,13%, data ke 4 sejumlah 134 hasil prediksi 417 *error* yang didapatkan 283 hasil akurasi 45,26%, data ke 5 sejumlah 129 hasil prediksi 379 *error* yang didapatkan 250 hasil akurasi 47,80%, data ke 6 sejumlah 122 hasil prediksi 253 *error* yang didapatkan 131 hasil akurasi 62,88%, data ke 7 sejumlah 111 hasil prediksi 114 *error* yang didapatkan 3 hasil akurasi 98,59%, data ke 8 sejumlah 0 hasil prediksi juga sama 0 *error* yang didapatkan 0 hasil akurasi 100%, data ke 9 sejumlah 143 hasil prediksi 103 *error* yang didapatkan 40 hasil akurasi 83,53%, data ke 10 sejumlah 150 hasil prediksi 250 *error* yang didapatkan 100 akurasinya 71,42%, data ke 11 sejumlah 146 hasil prediksi 130 *error* yang didapat 16 akurasi 93,49%, data ke 12 sejumlah 138 hasil prediksi 170 *error* yang didapat 32 akurasi 88,14%, data ke 13 sejumlah 129 hasil prediksi 237 *error* yang didapat 108 akurasi 67,95%, data ke 14 sejumlah 113 hasil prediksi 101 *error* yang didapat 12 hasil akurasi 94,36%.

Sehingga rata-rata *error* pada peramalan penjualan DAXU 240ml menghasilkan MSE sebesar 17660 atau akurasi sebesar 76,34%.

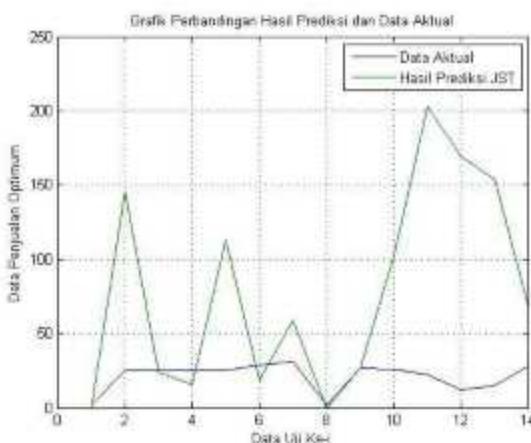
b. Pengujian data AMDK DAXU 330ml

Berdasarkan pada pelatihan data AMDK DAXU 330ml di dapatkan arsitektur terbaik untuk peramalan produk AMDK DAXU kemasan 330ml yaitu pada gambar 4.8



Gambar 4.8 Arsitektur JST-BP Peramalan AMDK DAXU 330ml

Berdasarkan pada arsitektur Gambar 4.8 pengujian pada data penjualan DAXU 330ml dengan menggunakan arsitektur terbaik yaitu learning rate 0.75, lapisan tersembunyi sebanyak 1 lapis dan neuron pada lapisan tersembunyi sebanyak 10 neuron. Grafik hasil peramalan dapat dilihat pada Gambar 4.9.



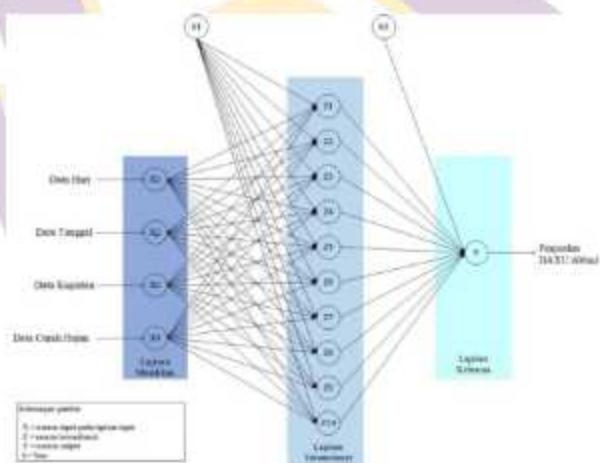
Gambar 4.9 Grafik Hasil Peramalan AMDK DAXU 330ml

Berdasarkan gambar 4.9 terlihat beberapa data mendekati nilai target artinya beberapa data memiliki *error* hampir mendekati 0. Pada data ke 1 menurut data aktual penjualan pada data uji adalah 1 hasil prediksi 1 *error* yang didapatkan 1 hasil akurasi 99%. Data ke 2 sejumlah 23 hasil prediksi 146 *error* yang didapatkan 123 hasil akurasi 50%, data ke 3 sejumlah 24 hasil prediksi 22 *error* yang didapatkan 2 hasil akurasi 98,38%, data ke 4 sejumlah 22 hasil prediksi 16 *error* yang didapatkan 6 hasil akurasi 95,08%, data ke 5 sejumlah 25 hasil prediksi 113 *error* yang didapatkan 88 hasil akurasi 58,68%, data ke 6 sejumlah 33 hasil prediksi 19 *error* yang didapatkan 14 hasil akurasi 89,47%, data ke 7 sejumlah 30 hasil prediksi 59 *error* yang didapatkan 29 hasil akurasi 81,76%, data ke 8 sejumlah 1 hasil prediksi 1 *error* yang didapatkan 1 hasil akurasi 99%, data ke 9 sejumlah 26 hasil prediksi 27 *error* yang didapatkan 1 hasil akurasi 99,21%, data ke 10 sejumlah 24 hasil prediksi 24 *error* yang didapatkan 78 akurasinya 61,38%, data ke 11 sejumlah 23 hasil prediksi 203 *error* yang didapat 180 akurasi

40,59 %, data ke 12 sejumlah 22 hasil prediksi 169 *error* yang didapat 147 akurasi 45,35%, data ke 13 sejumlah 22 hasil prediksi 154 *error* yang didapat 132 akurasi 48,03%, data ke 14 sejumlah 25 hasil prediksi 68 *error* yang didapat 43 hasil akurasi 74,40%. Sehingga rata-rata *error* pada peramalan penjualan DAXU 330ml menghasilkan MSE sebesar 7379,9286 atau akurasi sebesar 74,31%.

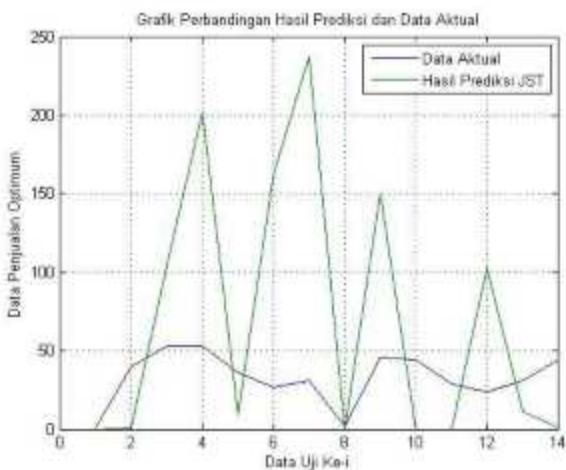
c. Pengujian data AMDK DAXU 600ml

Berdasarkan pada pelatihan data AMDK-DAXU 600ml di dapatkan arsitektur terbaik untuk peramalan produk AMDK-DAXU kemasan 600ml yaitu pada gambar 4.10.



Gambar 4.10 Arsitektur JST-BP Peramalan AMDK DAXU 600ml

Berdasarkan pada Gambar 4.10 pengujian pada data penjualan DAXU 600ml dengan menggunakan arsitektur terbaik yaitu learning rate 0.5, lapisan tersembunyi sebanyak 1 lapis dan neuron pada lapisan tersembunyi sebanyak 10 neuron. Grafik hasil peramalan dapat dilihat pada Gambar 4.11.



Gambar 4.11 Grafik Hasil Peramalan AMDK DAXU 660ml

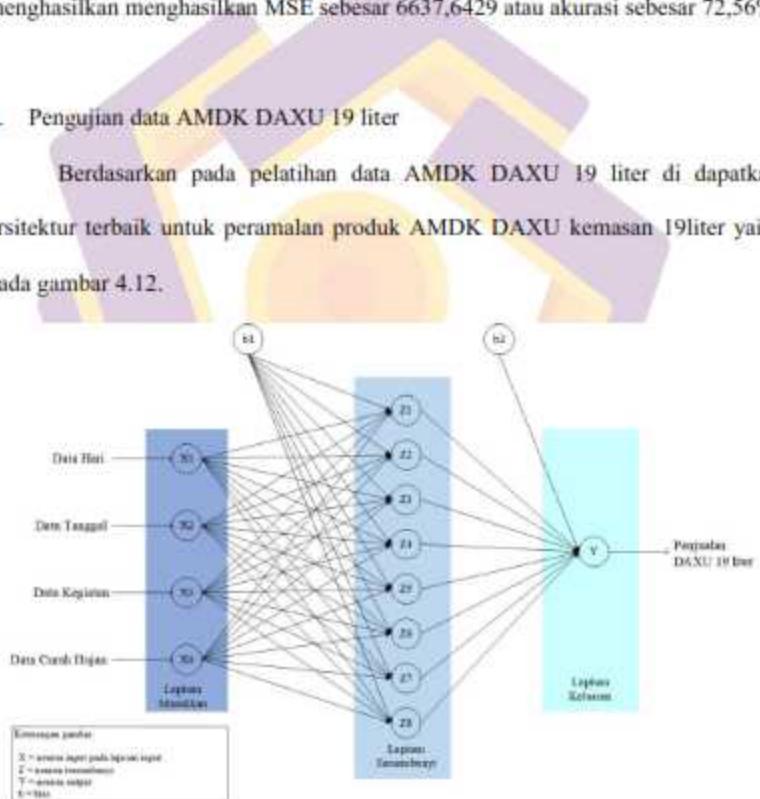
Berdasarkan gambar 4.11 terlihat beberapa data mendekati nilai target artinya beberapa data memiliki *error* bernilai hampir mendekati 0. Pada data ke 1 menurut data aktual penjualan pada data uji adalah 2 hasil prediksi 0 *error* yang didapatkan 2 hasil akurasi 98,03%. Data ke 2 sejumlah 23 hasil prediksi 1 *error* yang didapatkan 22 hasil akurasi 82,11%, data ke 3 sejumlah 43 hasil prediksi 104 *error* yang didapatkan 61 hasil akurasi 70,09%, data ke 4 sejumlah 76 hasil prediksi 202 *error* yang didapatkan 126 hasil akurasi 58,27%, data ke 5 sejumlah 44 hasil prediksi 9 *error* yang didapatkan 35 hasil akurasi 75,69%, data ke 6 sejumlah 35 hasil prediksi 163 *error* yang didapatkan 128 hasil akurasi 51,33%, data ke 7 sejumlah 35 hasil prediksi 237 *error* yang didapatkan 202 hasil akurasi 40,05%, data ke 8 sejumlah 5 hasil prediksi 0 *error* yang didapatkan 5 hasil akurasi 95,23%, data ke 9 sejumlah 76 hasil prediksi 150 *error* yang didapatkan 74 hasil akurasi 70,40%, data ke 10 sejumlah 36 hasil prediksi 0 *error* yang

didapatkan 36 akurasinya 73,52%, data ke 11 sejumlah 24 hasil prediksi 0 *error* yang didapat 24 akurasi 80,64 %, data ke 12 sejumlah 31 hasil prediksi 103 *error* yang didapat 72 akurasi 64,53%, data ke 13 sejumlah 35 hasil prediksi 11 *error* yang didapat 24 akurasi 82,22%, data ke 14 sejumlah 37 hasil prediksi 1 *error* yang didapat 36 hasil akurasi 73,72%.

Sehingga rata-rata *error* pada peramalan penjualan DAXU 600ml menghasilkan menghasilkan MSE sebesar 6637,6429 atau akurasi sebesar 72,56%.

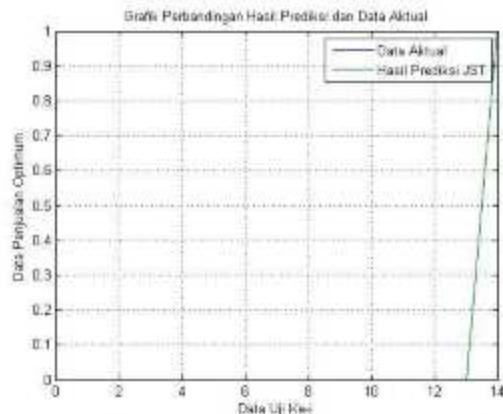
d. Pengujian data AMDK DAXU 19 liter

Berdasarkan pada pelatihan data AMDK DAXU 19 liter di dapatkan arsitektur terbaik untuk peramalan produk AMDK DAXU kemasan 19liter yaitu pada gambar 4.12.



Gambar 4.12 Arsitektur JST-BP Peramalan AMDK DAXU 19L

Berdasarkan pada arsitektur Gambar 4.11 pengujian pada data penjualan DAXU 19liter dengan menggunakan arsitektur terbaik yaitu learning rate 0.75, lapisan tersembunyi sebanyak 1 lapis dan neuron pada lapisan tersembunyi sebanyak 8 neuron. Grafik hasil peramalan dapat dilihat pada Gambar 4.13.



Gambar 4.13 Grafik Hasil Peramalan AMDK DAXU 19L

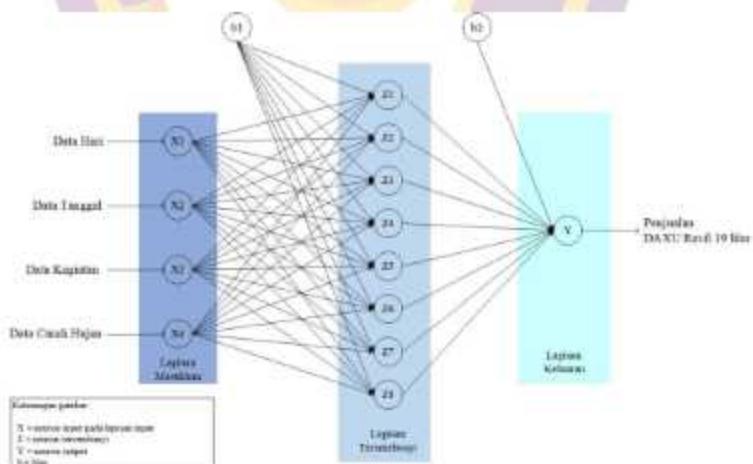
Berdasarkan Gambar 4.13 terlihat semua data mendekati nilai target artinya data memiliki *error* bernilai 0. Pada data ke 1 menurut data aktual penjualan pada data uji adalah 0 hasil prediksi 0 *error* yang didapatkan 0 hasil akurasi 100%. Data ke 2 sejumlah 0 hasil prediksi 0 *error* yang didapatkan 0 hasil akurasi 100%, data ke 3 sejumlah 0 hasil prediksi 0 *error* yang didapatkan 0 hasilakurasi 100%, data ke 4 sejumlah 0 hasil prediksi 0 *error* yang didapatkan 0 hasil akurasi 100%, data ke 5 sejumlah 0 hasil prediksi 0 *error* yang didapatkan 0 hasil akurasi 100%, data ke 6 sejumlah 0 hasil prediksi 0 *error* yang didapatkan 0 hasil akurasi 100%, data ke 7 sejumlah 0 hasil prediksi 0 *error* yang didapatkan 0 hasil akurasi 100%, data ke 8 sejumlah 0 hasil prediksi 0 *error* yang didapatkan 0

hasil akurasi 100%, data ke 9 sejumlah 0 hasil prediksi 0 *error* yang didapatkan 0 hasil akurasi 100%, data ke 10 sejumlah 0 hasil prediksi 0 *error* yang didapatkan 0 akurasinya 100%, data ke 11 sejumlah 0 hasil prediksi 0 *error* yang didapat 0 akurasi 100%, data ke 12 sejumlah 0 hasil prediksi 0 *error* yang didapat 0 akurasi 100%, data ke 13 sejumlah 0 hasil prediksi 0 *error* yang didapat 0 akurasi 100%, data ke 14 sejumlah 1 hasil prediksi 0 *error* yang didapat 1 hasil akurasi 99%.

Sehingga rata-rata *error* pada peramalan penjualan DAXU 19liter menghasilkan MSE sebesar 0,071429 atau akurasi sebesar 99,29%.

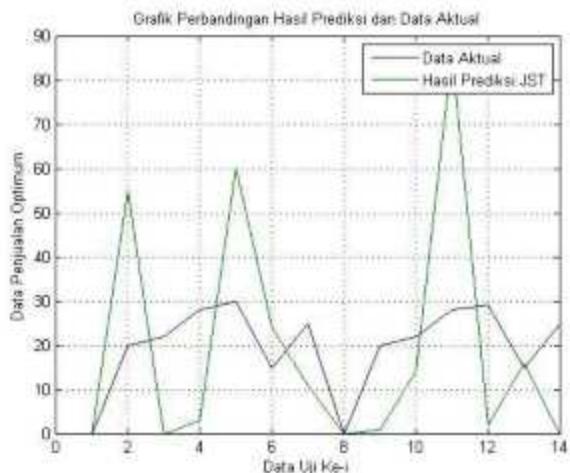
e. Pengujian data AMDK DAXU Revil 19 liter

Berdasarkan pada pelatihan data AMDK DAXU revil 19 liter di dapatkan arsitektur terbaik untuk peramalan produk AMDK DAXU revil 19liter yaitu pada gambar 4.14.



Gambar 4.14 Arsitektur JST-BP Peramalan AMDK DAXU Revil 19L

Berdasarkan pada Gambar 4.14 pengujian pada data penjualan DAXU revil 19liter dengan menggunakan arsitektur terbaik yaitu learning rate 0,75, lapisan tersembunyi sebanyak 1 lapis dan neuron pada lapisan tersembunyi sebanyak 8 neuron. Grafik hasil peramalan dapat dilihat pada Gambar 4.15.



Gambar 4.15 Grafik Hasil Peramalan AMDK DAXU Revil 19L

Berdasarkan Gambar 4.15 terlihat beberapa data mendekati nilai target artinya beberapa data memiliki *error* bernilai 0. Pada data ke 1 menurut data aktual penjualan pada data uji adalah 1 hasil prediksi 0 *error* yang didapatkan 1 hasil akurasi 99%. Data ke 2 sejumlah 19 hasil prediksi 55 *error* yang didapatkan 36 hasil akurasi 76,77%, data ke 3 sejumlah 22 hasil prediksi 0 *error* yang didapatkan 22 hasil akurasi 81,96%, data ke 4 sejumlah 28 hasil prediksi 3 *error* yang didapatkan 25 hasil akurasi 80,46%, data ke 5 sejumlah 29 hasil prediksi 60 *error* yang didapatkan 31 hasil akurasi 80,62%, data ke 6 sejumlah 15 hasil prediksi 24 *error* yang didapatkan 9 hasil akurasi 92,74%, data ke 7 sejumlah 24

hasil prediksi 11 *error* yang didapatkan 13 hasil akurasi 89,51%, data ke 8 sejumlah 1 hasil prediksi 0 *error* yang didapatkan 1 hasil akurasi 99%, data ke 9 sejumlah 20 hasil prediksi 1 *error* yang didapatkan 19 hasil akurasi 84,16%, data ke 10 sejumlah 23 hasil prediksi 14 *error* yang didapatkan 9 akurasinya 92,68%, data ke 11 sejumlah 28 hasil prediksi 86 *error* yang didapat 58 akurasi 68,81%, data ke 12 sejumlah 29 hasil prediksi 2 *error* yang didapat 27 akurasi 79,06%, data ke 13 sejumlah 15 hasil prediksi 16 *error* yang didapat 1 akurasi 99,13%, data ke 14 sejumlah 24 hasil prediksi 0 *error* yang didapat 24 hasil akurasi 80,64%.

Sehingga rata-rata *error* pada peramalan penjualan DAXU revil 19liter menghasilkan MSE sebesar 632,7143 atau akurasi sebesar 86,53%. Berikut pada gambar 4.16 adalah ringkasan hasil pengujian skenario uji 1 untuk memprediksi peramalan periode selanjutnya.



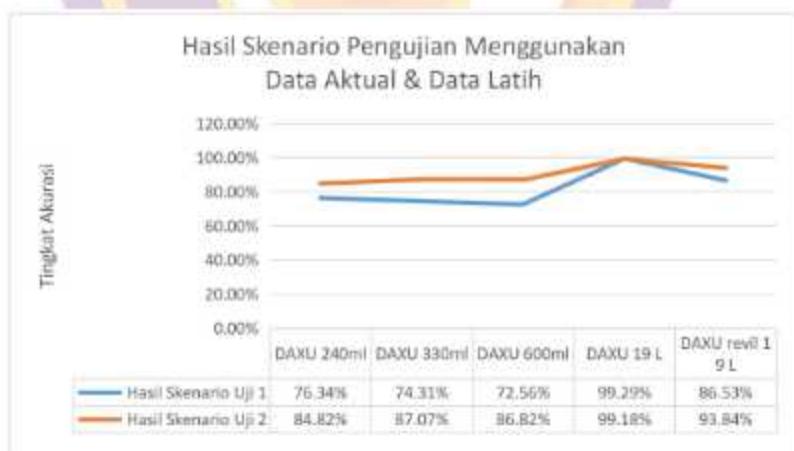
Gambar 4.16 Ringkasan Hasil Skenario Uji 1

Pada keseluruhan hasil prediksi terdapat selisih dari target dan hasil prediksi JST hal ini normal karena dalam kegiatan *forecasting sales* hasil

peramalan tidak bersifat sempurna sesuai dengan bilangan atau data aktual dimana hasil peramalan bersifat pendekatan artinya dapat berbeda dengan data aktual, ini juga bisa terjadi karena faktor datanya sendiri, variabel yang digunakan atau faktor lainnya. Maka perhitungan perenstase selisih kesalahan dapat diketahui dengan menghitung *error* rata-rata dan akurasi(Hasan & Fatta, 2019).

4.3.2. Pengujian Menggunakan Data Latih (Skenario Uji 2)

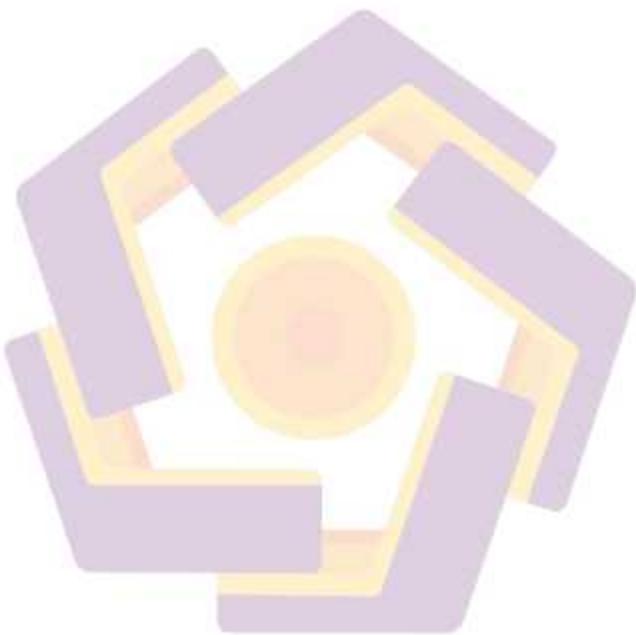
Pada skenario uji 2 pengujian dilakukan dengan mengambil data uji dari data latih itu sendiri untuk melihat konsistensi arsitektur, ketepatan dan akurasi dari model sistem peramalan. Hasil dari skenario uji 2 kemudian di bandingkan dengan skenario uji 1 yang sebelumnya telah dilakukan. Hasilnya dapat dilihat pada Gambar 4.17.



Gambar 4.17 Ringkasan Perbandingan Hasil Pengujian

Pada Gambar 4.17 mengartikan pengujian menggunakan data uji yang di ambil dari data latih memiliki hasil akurasi rata-rata lebih tinggi, artinya model

peramal yang dibangun hasilnya sudah baik karena mendekati nilai sebenarnya. Namun, pada penelitian ini hasil pengujian yang digunakan adalah hasil pada skenario uji 1 hal ini karena sesuai kebutuhan penelitian ini yaitu melihat hasil peramalan pada periode selanjutnya dari data set yang sudah ada saat ini dimana penjualan belum terjadi.



BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan dari hasil penelitian yang telah dilakukan maka dapat disimpulkan bahwa:

- a. Pada penelitian ini terdapat 4 faktor yang mempengaruhi penjualan AMDK DAXU, yang kemudian menjadi variabel *input* dalam JST *backpropagation*. Penggunaan 4 variabel *input* yaitu hari, tanggal, kegiatan dan curah hujan untuk meramal penjualan AMDK DAXU menghasilkan arsitektur, nilai MSE dan akurasi yang berbeda-beda untuk setiap produk.
- b. Perbedaan penggunaan arsitektur yang optimal dilakukan dengan melakukan pelatihan pada data latih penjualan masing-masing produk DAXU yang kemudian di uji. Hasil akurasi untuk produk DAXU 240ml dengan *learning rate* 0,75 arsitektur 4-9-1 sebesar 76,34%, DAXU 330ml dengan *learning rate* 0,75 arsitektur 4-10-1 sebesar 74,31%, DAXU 600ml dengan *learning rate* 0,5 arsitektur 4-10-1 sebesar 72,56%, DAXU 19 liter dengan *learning rate* 0,75 arsitektur 4-8-1 sebesar 99,29% dan DAXU revil 19 liter dengan *learning rate* 0,75 arsitektur 4-8-1 sebesar 86,53%.

5.2. Saran

Adapun beberapa saran bagi pengembangan penelitian ini yaitu:

- a. Pelatihan dan pengujian JST *backpropagation* pada penelitian ini dilakukan

dengan menggunakan data 8 bulan. Pada penelitian selanjutnya disarankan menggunakan data set yang lebih banyak untuk mendapatkan hasil peramalan yang jauh lebih baik.

- b. Menggunakan kombinasi *learning rate*, lapisan tersembunyi, neuron yang lebih banyak dan parameter JST lainnya sehingga dimungkinkan mendapatkan MSE yang lebih baik.
- c. Menggunakan variabel *input* yang lebih banyak.
- d. Selain dengan analisis dari hasil wawancara, penentuan variabel *input* dapat dilakukan terlebih dahulu dengan menganalisis faktor-faktor yang mempengaruhi penjualan menggunakan metode statistik ataupun metode lainnya.
- e. Penelitian selanjutnya sebaiknya melakukan peramalan penjualan produk AMDK pada sebuah daerah dengan menggunakan data produk AMDK lebih dari satu sumber atau banyak brand, sehingga dapat ditarik kesimpulan yang lebih besar.
- f. Hasil akurasi peramalan pada beberapa produk masih rendah, maka disarankan penelitian selanjutnya dapat melakukan peramalan dengan metode *time series* atau metode peramalan lainnya agar dapat membandingkan hasil peramalan dan ditarik kesimpulan yang lebih baik.
- g. Desain *prototype* untuk *end-users* dikembangkan agar lebih *user friendly*.

DAFTAR PUSTAKA

PUSTAKA BUKU

- Fausett, L. (1994). Fundamentals of Neural networks Architectures, Algorithms, and Applications. London: Prentice Hall, Inc.
- Heizer, J., & Render, B. (2005). Operation Management (7th ed.). New Jersey: Prentice Hall.
- Heizer, J., & Render, B. (2010). Manajemen Operasi (Edisi 7). Jakarta: Salemba 4.
- Hermawan, A. (2006). Jaringan Saraf Tiruan Teori dan Aplikasi. Yogyakarta: Penerbit Andi.
- Kristianto, A. (2004). Jaringan Syaraf Tiruan (Konsep Dasar, Algoritma dan Aplikasi). Yogyakarta: Gava Media.
- Kuswadi, S. (2007). Kendali Cerdas, Teori dan Aplikasi Praktisnya. Yogyakarta: C.V ANDI OFFSET (Penerbit ANDI).
- Lee, A. S. (2007). Action Is an Artifact: What Action Research and Design Science Offer Each Other. Texas, USA: Springer.
- Nafarin, M. (2007). Penganggaran Perusahaan (3rd ed.).
- Priyono, A., & Rahmat, R. A. O. (2013). Application of Artificial Intelligent for Urban Traffic Control System. Jakarta: Mitra Wacana Media.
- Puspitaningrum, D. (2006). Pengantar Jaringan Saraf Tiruan. Yogyakarta: Penerbit Andi.
- Santosa, B. (2007). Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis. Yogyakarta: Graha Ilmu.
- Santoso, S. (2009). Business Forecasting: Metode Peramalan Bisnis Masa Kini dengan Minitab dan SPSS. Jakarta: PT. Elex Media Komputindo.
- Suyanto. (2014). Artificial Intelligence Searching, Reasoning, Planning dan Learning. Bandung: Informatika Bandung.

PUSTAKA MAJALAH, JURNAL ILMIAH ATAU PROSIDING

- Andrijasa, M. F., & Mistianingsih. (2010). Jumlah Pengangguran di Provinsi Kalimantan Timur Dengan Menggunakan Algoritma Pembelajaran Backpropagation. *Jurnal Informatika Mulawarna*, 5(1).

- Aprilianto, H., Kumalaningsih, S., & Santoso, L. (2018). Penerapan Jaringan Syaraf Tiruan Untuk Peramalan Penjualan Dalam Mendukung Pengembangan Agroindustri Coklat di Kabupaten Blitar. *Jurnal Habitat*, 29(3), 129–137. <https://doi.org/10.21776/ub.habitat.2018.029.3.16>
- Arifin, Z. (2009). Jaringan Syaraf Tiruan Bidirectional Associative Memory (BAM) Sebagai Identifikasi Pola Sidik jari Manusia. *Jurnal Informatika Mulawarman Program Studi Ilmu Komputer Universitas Mulawarman*, 4(1), 21–26.
- Arisandi, D., Sitompul, O. S., & Batubara, E. A. (2015). Learning Vector Quantization untuk Prediksi Produksi Kelapa Sawit Pada PT. Perkebunan Nusantara I Pulau Tiga. *SENATKOM*, 7(Senatkom), 163–168.
- Armi, A. E., Kridalaksana, A. H., & Arifin, Z. (2019). Peramalan Angka Inflasi Kota Samarinda Menggunakan Metode Double Exponential Smoothing (Studi Kasus : Badan Pusat Statistik Kota Samarinda). 14(1).
- Budianita, E., & Firdaus, M. (2016). Diagnosis Penyakit Kejiwaan Menggunakan Jaringan Syaraf Tiruan Learning Vector Quantization2 (LVQ 2) (Studi Kasus : Rumah Sakit Jiwa Tampan Pekanbaru). *Jurnal Sains, Teknologi Dan Industri*, 13(2).
- Budianita, E., Hustianto, F. R., Okfalisa, O., Syafria, F., & Nasir, M. (2018). Implementasi Algoritma Jaringan Syaraf Tiruan (JST) Hopfield untuk Klasifikasi Kualitas Kesuburan Pria. Seminar Nasional Teknologi Informasi, Komunikasi Dan Industri (SNTIKI-10), (November), 137–142.
- Chopra, S., Yadav, D., & Chopra, A. N. (2019). International Journal of Swarm Intelligence and Evolutionary Computation Artificial Neural Networks Based Indian Stock Market Price Prediction: Before and After Demonetization. *International Journal of Swarm Intelligence and Evolutionary Computation*, 8(1), 1–7. <https://doi.org/10.4172/2090-4908.1000174>
- David, D. (2011). Perancangan Perangkat Lunak Pengenalan Pola Karakter Menggunakan Jaringan Syaraf Tiruan Perceptron. *Jurnal Ilmiah SISFOTENIKA*, 1(1), 10–19.
- Fadlisyah, F., & Bustami, B. (2016). Model Generatif Wajah Berpotensi "Fitnah" Menggunakan Jaringan Syaraf Tiruan Adaline. *Jurnal Penelitian Teknik Informatika*, 8(1), 125–138.
- Febrina, M., Arina, F., & Ekawati, R. (2013). Peramalan Jumlah Permintaan Produksi Menggunakan Metode Jaringan Syaraf Tiruan (JST) Backpropagation. *Jurnal Teknik Industri*, 1(2), 174–179.
- Gapar, I. K. K., Widagda, I. G. A., & Suarabawa, K. N. (2018). Pengenalan Suara Manusia dengan Menggunakan Metode Jaringan Syaraf Tiruan Hebb. *Jurnal Buletin Fisika*, 19(1), 16–22.

- Ginting, E. B., Zarlis, P. D. M., & Situmorang, D. Z. (2014). Kombinasi Algoritma Jaringan Syaraf Tiruan Learning Vector Quantization (LVQ) dan Self Organizing Kohonen pada Kecepatan Pengenalan Pola Tanda Tangan. *TECHSI - Jurnal Penelitian Teknik Informatika*, 6(1), 95–110.
- Ginting, R., Tulus, T., & Nababan, E. B. (2014). Analisis Penggunaan Algoritma Kohonen pada Jaringan Syaraf Tiruan Backpropagation dalam Pengenalan Pola Penyakit Paru. *Jurnal Teknologi*, 01(2), 27–47.
- Gunaryati, A., Fauziah, & Andryana, S. (2018). Perbandingan Metode Peramalan Eksponensial Smoothing dan Metode Jaringan Syaraf Tiruan Propagasi balik untuk Data Pengguna Pita Lebar (broadband) di Indonesia. *Jurnal Sistem Informasi, Teknologi Informatika Dan Komputer*, 8(2).
- Hari, Y., & Dewi, L. P. (2018). Forecasting System Approach for Stock Trading with Relative Strength Index and Moving Average Indicator. *Journal of Telecommunication, Electronic and Computer Engineering*, 10, 2–3.
- Hasan, N. F., & Fatta, H. Al. (2019). Peramalan Jumlah Penjualan Menggunakan Jaringan Syaraf Tiruan Backpropagation Pada Perusahaan Air Minum Dalam Kemasan. 5, 179–188.
- Hasan, N. F., Kusriini, K., & Fatta, H. Al. (2019). Analisis Arsitektur Jaringan Syaraf Tiruan Untuk Peramalan Penjualan Air Minum Dalam Kemasan. *JURTI*, 3(1), 1–10.
- Hidayati, N., & Warsito, B. (2012). Predksi Terjangkitnya Penyakit Jantung Dengan Metode Learning Vector Quantization. *Media Statistika*, 3(1), 21–30. <https://doi.org/10.14710/medstat.3.1.21-30>
- Jasmir, S.kom, M. ko. (2013). Analisis Metode Heteroassociative Memory untuk Mendiagnosa Penyakit Maag. *Jurnal Media Processor*, 8(2), 1–14.
- Joses, S., Suhery, C., & Midyanti, D. M. (2018). Penerapan Madaline Neural Network Untuk Prakiraan Cuaca (Studi Kasus: Kota Pontianak). *Jurnal Coding*, 06(02).
- Kusuma, G. P., Suyanto, S., & Yulianto, F. A. (2011). Nutify: Identifikasi Gambar Manusia untuk Mencegah Pornografi Menggunakan Metode Hebbian Learning dan Back Propagation Network. *Jurnal Teknologi Informasi Politeknik Telkom*, 1(1), 1–8.
- Lius, A., Simarmata, E. R., & Herman, H. (2017). Pengembangan Aplikasi Pengenal Karakter Menggunakan Metode Heteroassociative Memory. *Jurnal Manajemen Informatika & Komputerisasi Akuntansi*, 1(1), 10–21.
- Mahendhy, N. N., Nasrun, M., & Latuconsina, R. (2018). Detektor Kebohongan dengan Analisis Pembesaran Diameter Pupil dan Pergerakan Mata Menggunakan Metode Jaringan Syaraf Tiruan Hopfield Net. *Proceeding of Engineering*, 5(3), 6146.

<https://doi.org/10.1017/CBO9781107415324.004>

- Marjiyono, Bambang Soedijono, & Taufiq, E. L. (2018). Penggunaan Jaringan Syaraf Tiruan Untuk Meramalkan Permintaan pada Perusahaan Retail. Seminar Nasional Teknologi Informasi Dan Multimedia, (2009), 7–12.
- Matodang, Z. A. (2013). Jaringan Syaraf Tiruan Dengan Algoritma Backpropagation Untuk Peneleitian Kelulusan Sidang Skripsi. Pelita Informatika Budi Darma, 4(1), 1–10.
- Meliawati, R., Soesanto, O., & Kartini, D. (2016). Penerapan Metode Learning Vector Quantization (LVQ) Pada Prediksi Jurusan Di SMA PGRI 1 Banjarbaru. Kumpulan Jurnal Ilmu Komputer (KLIK), 04(01), 11–20.
- Mithiya, D., Datta, L., & Mandal, K. (2019). Time Series Analysis and Forecasting of Oilseeds Production in India: Using Autoregressive Integrated Moving Average and Group Method of Data Handling – Neural Network. Asian Journal of Agricultural Extension, Economics & Sociology, 30(2), 1–14. <https://doi.org/10.9734/ajaees/2019/v30i230106>
- Mubyarto, A., & Susilawati, H. (2010). Peningkatan Efisiensi Penggunaan Bahan Bakar Kendaraan Bermotor Dengan Melakukan Pencarian Jarak Terdekat Menggunakan Jaringan Syaraf Tiruan Hopfield Di Wilayah Purwokerto. Dinamika Rekayasa, 6(1), 19–25. <https://doi.org/10.20884/1.dr.2010.6.1.30>
- Muqtadiroh, F. A., Syofiani, A. R., & Ramadhan, T. S. (2015). Analisis Peramalan Penjualan Semen Non-curah (ZAK) PT SEMEN INDONESIA (PERSERO) TBK Pada Area Jawa Timur. 2015(Sentika).
- Nafi'iyah, N. (2015). Algoritma Kohonen dalam Mengubah Citra Graylevel Menjadi Citra Biner. Jurnal Ilmiah Teknologi Informasi Asia, 9(2), 49–55. Retrieved from <https://jurnal.stmikasia.ac.id/index.php/jitika/article/view/125>
- Nawawi, M. Z., Rahmat, R. F., & Syahputra, M. F. (2015). Klasifikasi Telur Fertil dan Infertil Menggunakan Jaringan Saraf Tiruan Multilayer Perceptron Berdasarkan Ekstraksi Fitur Warna dan Bentuk. Jurnal Teknologi Informasi Dan Komunikasi, 4(2), 100–109.
- Pakaja, F., Agus Naba, & Purwanto. (2012). Peramalan Penjualan Mobil Menggunakan Jaringan Syaraf Tiruan dan Certainty Factor. Jurnal EECCIS, 6(1), 23–28.
- Perdana, I. A. (2016). Simulasi dan Prediksi Jumlah Penjualan Air Menggunakan Jaringan Syaraf Tiruan Backpropagation (Study Kasus: PDAM Tirta Kepri). Jurnal Umrah, 1–12.
- Purwaningsih, N. (2016). Penerapan Multilayer Perceptron untuk klasifikasi Jenis Kulit Sapi Tersamak. Jurnal TEKNOIF, 4(1), 1–7.

- Puspitasari, D., Mentari, M., & Faldiansyah, W. R. (2017). Penerapan Metode Single Exponential Smoothing Menggunakan Pendekatan Adaptif Pada Peramalan Jumlah Pelanggan Dan Kebutuhan Air Pada Pdam Kota. *Jurnalti Polinema*, 1–6.
- Siang, J. J. (2005). *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Yogyakarta: Penerbit A
- Silfiani, Y. Y., & Utomo, H. (2017). Pengaruh Citra Merek, Kualitas Produk Dan Strategi Promosi Terhadap Keputusan Pembelian Produk Amdk Java (Studi Kasus Pada Konsumen Mahasiswa STIE AMA, IAIN Dan UKSW Salatiga) (Yen Yen Silfiani, Hardi Utomo). *Among Makarti*, 10(20), 37–54.
- Siregar, S. D., Lestari, L., Ermala, I., Simarmata, D. P., & Nainggolan, A. S. (2019). Pencocokan Foto Berdasarkan Wajah Dengan Menggunakan Metode Kohonen. *Journal of Informatic Pelita Nusantara*, 4(1), 1–7.
- Sudarsono, A. (2016). *Jaringan Syaraf Tiruan untuk Memprediksi Laju Pertumbuhan Penduduk Menggunakan Metode Backpropagation (Studi Kasus di Kota Bengkulu)*. *Jurnal Media Infotama*, 12(1), 61–69.
- Windarti, M., & Sulistyowati, I. (2017). Korelasi Nilai UN, IP Tahun Pertama Terhadap Masa Studi Dengan Backpropagation. *Jurnal Ilmiah SISFOTENIKA*, 9(2), 114–124.
- Yanti, F., & Sutrisna, J. (2017). Perbandingan Saham Hang Seng dan Nikkei Menggunakan Algoritma Hebbian. *Jurnal Informatika Universitas Pamulang*, 2(1), 7. <https://doi.org/10.32493/informatika.v2i1.1499>
- Zulfian Azmi, & Freizello, H. (2017). Implementasi Hopfield Untuk Pengenalan Karakter Hiragana. *Journal of Information System, Informatics and Computing*, 1(1), 1–8.

PUSTAKA LAPORAN PENELITIAN

- Andayani. (2018). *Memprediksi Kualitas Lulusan Mahasiswa Menggunakan Algoritma Jaringan Syaraf Tiruan*. Universitas AMIKOM Yogyakarta.
- Maharani, S. (2013). *Aplikasi Diagnosa Gejala Demam Pada Balita Menggunakan Metode Certainty Factor (CF) dan Jaringan Syaraf Tiruan (JST) (Studi Kasus : RS. Umum Abdul Wahab Syahranie)*. Universitas Diponegoro.
- Marjiyono. (2017). *Penggunaan Jaringan Syaraf Tiruan untuk Meramalkan Permintaan Pada Perusahaan Retail*. Universitas AMIKOM Yogyakatra
- Rohman, A. (2006). *Peramalan Penjualan Air Minum Dalam Kemasan (AMDK)*. PT. TIRTA INVESTAMA Subang, Jawa barat, Institut Pertanian Bogor.

Shimbun, A. F. (2016). Sistem Peramalan Kebutuhan Stok Barang Menggunakan Metode Trend Moment. Stmik AMIKOM Yogyakarta.

PUSTAKA ELEKTRONIK

Badana Pusat Statistik. (2018). *Statistik Air Besih*.

BMKG. (n.d.). Data Curah Hujan Harian Tahun 2019. Retrieved from http://dataonline.bmkg.go.id/ketersediaan_data

Kemenperin. (2017). AMDK.

