



TUGAS AKHIR - KS 141501

PERAMALAN JUMLAH PENJUALAN NOTA DI CV. GEMILANG INDONESIA DENGAN MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN)

RECEIPT SALES FORECASTING AT CV. GEMILANG INDONESIA USING ARTIFICIAL NEURAL NETWORK METHOD (ANN)

ARI DWI NINGSIH
NRP 5212 100 032

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

JURUSAN SISTEM INFORMASI
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember
Surabaya 2016



ITS
Institut
Teknologi
Sepuluh Nopember

TUGAS AKHIR - KS 141501

PERAMALAN JUMLAH PENJUALAN NOTA DI CV. GEMILANG INDONESIA DENGAN MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN)

ARI DWI NINGSIH
NRP 5212 100 032

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

JURUSAN SISTEM INFORMASI
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember
Surabaya 2015



ITS
Institut
Teknologi
Sepuluh Nopember

TUGAS AKHIR - KS 141501

RECEIPT SALES FORECASTING AT CV. GEMILANG INDONESIA USING ARTIFICIAL NEURAL NETWORK METHOD (ANN)

**ARI DWI NINGSIH
NRP 5212 100 032**

**SUPERVISOR:
Edwin Riksakomara, S.Kom, M.T.**

**JURUSAN SISTEM INFORMASI
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember
Surabaya 2015**

LEMBAR PENGESAHAN

PERAMALAN JUMLAH PENJUALAN NOTA DI CV. GEMILANG INDONESIA DENGAN MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN)

TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada

Jurusan Sistem Informasi
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember

Oleh:

ARI DWI NINGSIH
NRP. 5212 100 032

Surabaya, 2016

KETUA JURUSAN SISTEM INFORMASI

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



LEMBAR PERSETUJUAN

PERAMALAN JUMLAH PENJUALAN NOTA DI CV. GEMILANG INDONESIA DENGAN MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN) TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat

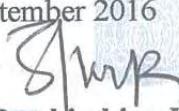
Memperoleh Gelar Sarjana Komputer
pada

Jurusan Sistem Informasi
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember
Oleh :

ARI DWI NINGSIH
NRP. 5212 100 032

Disetujui Tim Penguji : Tanggal Ujian: 2016

Periode Wisuda: September 2016


(Pembimbing I)

Edwin Riksakomara, S.Kom, M.T.


(Penguji I)

Wiwik Anggraeni, S.Si, M.Kom.


(Penguji II)

Radityo Prasetyanto. W, S.Kom, M.kom

LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai mahasiswa Institut Teknologi Sepuluh Nopember Surabaya, yang bertanda tangan di bawah ini saya :

Nama : API Dwi Ningrum

Nrp. : 5212100032

Jurusan / Fak. : SISTEM INFORMASI / FAKULTAS TEKNOLOGI INFORMASI

Alamat kontak :

a. Email : ari.dwiningrum@gmail.com

b. Telp/HP : 08578580277

Menyatakan bahwa semua data yang saya *upload* di Digital Library ITS merupakan hasil final (revisi terakhir) dari karya ilmiah saya yang sudah disahkan oleh dosen pengujii. Apabila dikemudian hari ditemukan ada ketidaksesuaian dengan kenyataan, maka saya bersedia menerima sanksi.

Demi perkembangan ilmu pengetahuan, saya menyetujui untuk memberikan **Hak Bebas Royalti Non-Ekslusif (Non-Exclusive Royalty-Free Right)** kepada Institut Teknologi Sepuluh Nopember Surabaya atas karya ilmiah saya yang berjudul :

PERAMALAH SUMAH PEMERUMAH MATA DI CV. GEMILANG INDONESIA DENGAN
MENGGUNAKAN APIFI CIAL HEUFLA NETWORK (AHN)

Dengan Hak Bebas Royalti Non-Ekslusif ini, Institut Teknologi Sepuluh Nopember Surabaya berhak menyimpan, mengalih-media/format-kan, mengelolanya dalam bentuk pangkalan data (*database*), mendistribusikannya, dan menampilkan/mempublikasikannya di internet atau media lain untuk kepentingan akademis tanpa meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta. Saya bersedia menanggung secara pribadi, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya Ilmiah saya ini tanpa melibatkan pihak Institut Teknologi Sepuluh Nopember Surabaya.

Demikian pernyataan ini saya buat dengan sebenarnya.



Dibuat di : Surabaya
Pada tanggal : 24 JUNI 2016
Yang menyatakan,

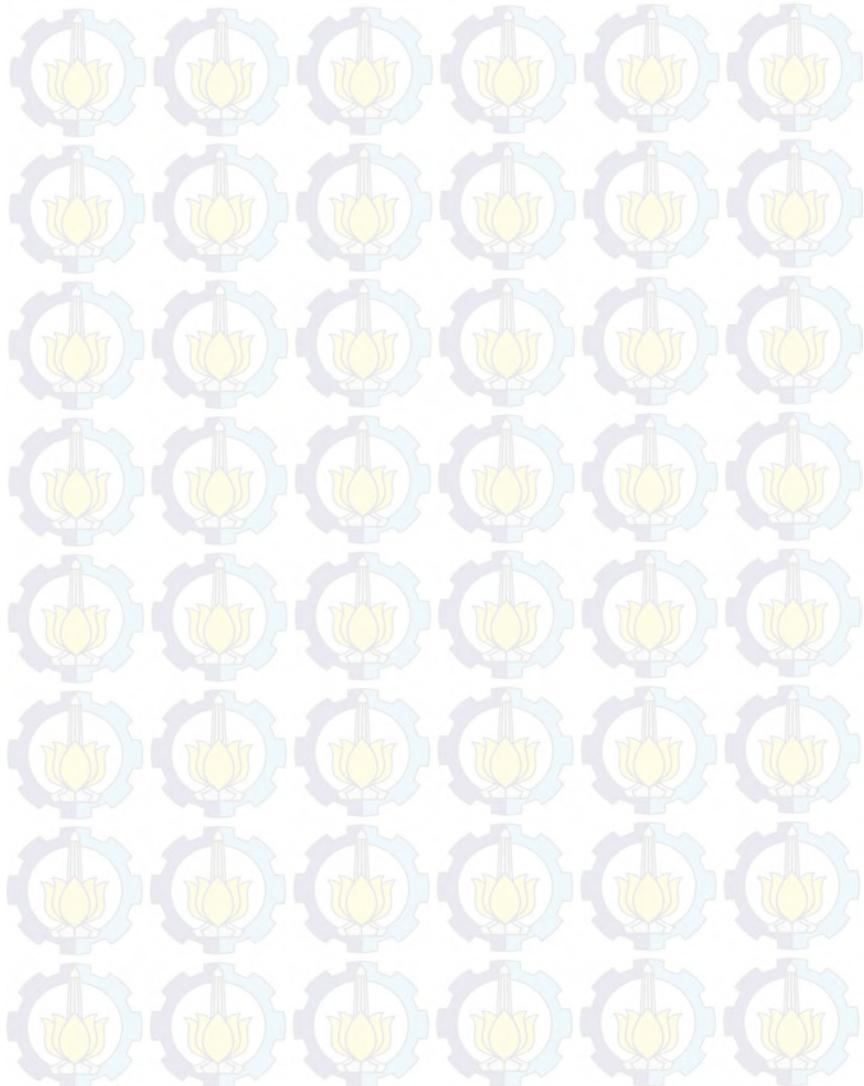
Aji
API Dwi Ningrum
Nrp. 5212100032

KETERANGAN :

Tanda tangan pembimbing wajib dibubuhi stempel jurusan.

Form dicetak dan diserahkan di bagian Pengadaan saat mengumpulkan hard copy TA/Tesis/Disertasi.

Halaman ini sengaja dikosongkan.



PERAMALAN JUMLAH PENJUALAN NOTA DI CV. GEMILANG INDONESIA DENGAN MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN)

Nama Mahasiswa : Ari Dwi Ningsih
NRP : 5212 100 032
Jurusan : Sistem Informasi FTIf-ITS
Pembimbing : Edwin Riksakomara, S.Kom, M.T.

ABSTRAK

Perusahaan harus mendapatkan kepuasaan pelanggan yang maksimal agar dapat meningkatkan keuntungan. Faktor yang sangat mempengaruhi kepuasaan pelanggan yaitu adanya ketersediaan produk yang sesuai dengan keinginan pelanggan. Namun, ketersediaan produk sering kali menjadi permasalahan di perusahaan, hal ini dikarenakan persediaan dan permintaan sering tidak sesuai. Ketidaksesuaian persediaan dan permintaan akan membuat perusahaan harus menanggung biaya tambahan seperti holding cost.

Begitu juga permasalahan yang dialami oleh CV. Gemilang Indonesia, dimana perusahaan tersebut sering mengalami permasalahan ketidaksesuaian persediaan dan permintaan nota. Permasalahan tersebut disebabkan karena CV. Gemilang Indonesia tidak mengetahui secara pasti seberapa banyak produk nota yang harus disediakan, kapan waktu produksi dan kapan waktu pemesanan material. Sehingga, sering terjadi penumpukan barang di gudang (over capacity) dan kekurangan persediaan (out of stock).

Untuk dapat menyelesaikan permasalahan ketersediaan produk di CV. Gemilang Indonesia dapat dilakukan dengan peramalan penjualan menggunakan metode Artificial Neural Network (ANN). Data yang digunakan untuk peramalan yaitu data timeseries penjualan enam produk jenis nota pada periode 2014-2016 per minggu. Data yang telah diperoleh akan dibedakan menjadi data training dan data testing dengan perbandingan 70:30.

Model dengan delapan input layer dengan parameter lr dan mc diatas 0.5 merupakan model dengan prediksi terbaik yang melibatkan data training dan data testing dengan MAPE 0.696% dan RMSE 0,169937802 Dengan demikian metode Artificial Neural Network dapat diterapkan untuk peramalan penjualan nota di CV. Gemilang Indonesia.

Kata Kunci:

Peramalan, Penjualan Nota, ANN

Receipt Sales Forecasting At CV. Gemilang Indonesia Using Artificial Neural Network Method (ANN)

Student Name

: Ari Dwi Ningsih

NRP

: 5212 100 032

Department

: Sistem Informasi FTIf-ITS

Supervisor

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

ABSTRACT

Companies have to obtain maximum customer satisfaction in order to increase profits. Some factors that influence customer satisfaction is products availability that fulfill the customer demand. However, product availability is often become a problem in the company, because the product supply is not meet the demand. Mismatches in supply and demand will make the company should take the additional costs such as holding cost.

Furthermore, CV. Gemilang Indonesia's problems is the supply doesn't meet the demand of product receipt. The problems occur because CV. Gemilang Indonesia unaware about how many products receipt should be provided, the production and material order time. Thus, these problems caused a lot of goods in the warehouse (over capacity) and out of stock.

In order to solve the problems above, the writer used Artificial Neural Network (ANN) to forecast product receipt sales. The data that used in forecasting is sales data of 6 types product receipt from 2014 to 2016 per week. The data will be divided into training and testing data with a 70:30 ratio.

Model with eight input layer parameters and mc above 0.5 is the model with the best predictive involving training and testing data with MAPE 0.696% and RMSE 0,169937802. Thus the method of Artificial Neural Network can be applied to receipt sales forecasting on the CV. Gemilang Indonesia.

Keywords:

Forecasting, Receipt Sales, ANN

KATA PENGANTAR

Alhamdulillahirobbil ‘alamin. Allahuma sholli’ala Muhammad, wa ‘ala aali sayyidina Muhammad. Tiada Dzat yang Maha Perkasa yang mampu menolong selain Allah SWT sehingga penulis dapat menyelesaikan buku tugas akhir dengan judul :

PERAMALAN JUMLAH PENJUALAN NOTA DI CV. GEMILANG INDONESIA DENGAN MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN)

yang merupakan salah satu syarat kelulusan pada Jurusan Sistem Informasi, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember Surabaya.

Dalam penggerjaan tugas akhir yang berlangsung selama satu semester, penulis ingin mengucapkan terima kasih yang sebesar-besarnya kepada yang senantiasa terlibat secara langsung memberikan bantuan dan dukungan dalam penggerjaan tugas akhir ini :

- Allah SWT yang telah memberikan kesehatan, kemudahan, kelancaran dan kesempatan untuk penulis hingga dapat menyelesaikan Tugas Akhir ini.
- Kedua orang tua, kakak, Agiel dan keluarga yang selalu hadir senantiasa mendoakan dan memberikan kasih sayang serta semangat tiada henti untuk menyelesaikan Tugas Akhir ini.
- Bapak Dr. Ir. Aris Tjahyanto, M.Kom, selaku Ketua Jurusan Sistem Informasi ITS, yang telah menyediakan fasilitas terbaik untuk kebutuhan penelitian mahasiswa.
- Bapak Edwin Riksakomara, S.Kom., M.T., selaku dosen pembimbing yang yang telah banyak meluangkan waktu

untuk membimbing, mengarahkan, dan mendukung dalam penyelesaian Tugas Akhir.

- Bapak Arif Wibisono, S.Kom, M.Sc selaku dosen wali yang telah memberikan arahan terkait perkuliahan di Jurusan Sistem Informasi.
- Seluruh dosen pengajar beserta staff dan karyawan di Jurusan Sistem Informasi, FTIf ITS Surabaya yang telah memberikan ilmu dan bantuan kepada penulis selama 7 semester ini.
- Teman-teman seperjuangan Adi, Ariesa, Icha, Tiar, Wemona, Niken, Allan, Ardian, Rafika, Rizky Praditya, Yogha, Echa, Ali Mangsur, Rifqi teman-teman laboratorium RDIB dan SOLA12IS lainnya, yang selalu memberikan semangat positif untuk menyelesaikan Tugas Akhir dengan tepat waktu.

Penulis menyadari bahwa Tugas Akhir ini masih belum sempurna dan memiliki banyak kekurangan di dalamnya. Dan oleh karena itu, penulis meminta maaf atas segala kesalahan yang dibuat penulis dalam buku Tugas Akhir ini. Penulis membuka pintu selebar-lebarnya bagi pihak yang ingin memberikan kritik dan saran, dan penelitian selanjutnya yang ingin menyempurnakan karya dari Tugas Akhir ini. Semoga buku Tugas Akhir ini bermanfaat bagi seluruh pembaca.

Surabaya, 2016

Penulis

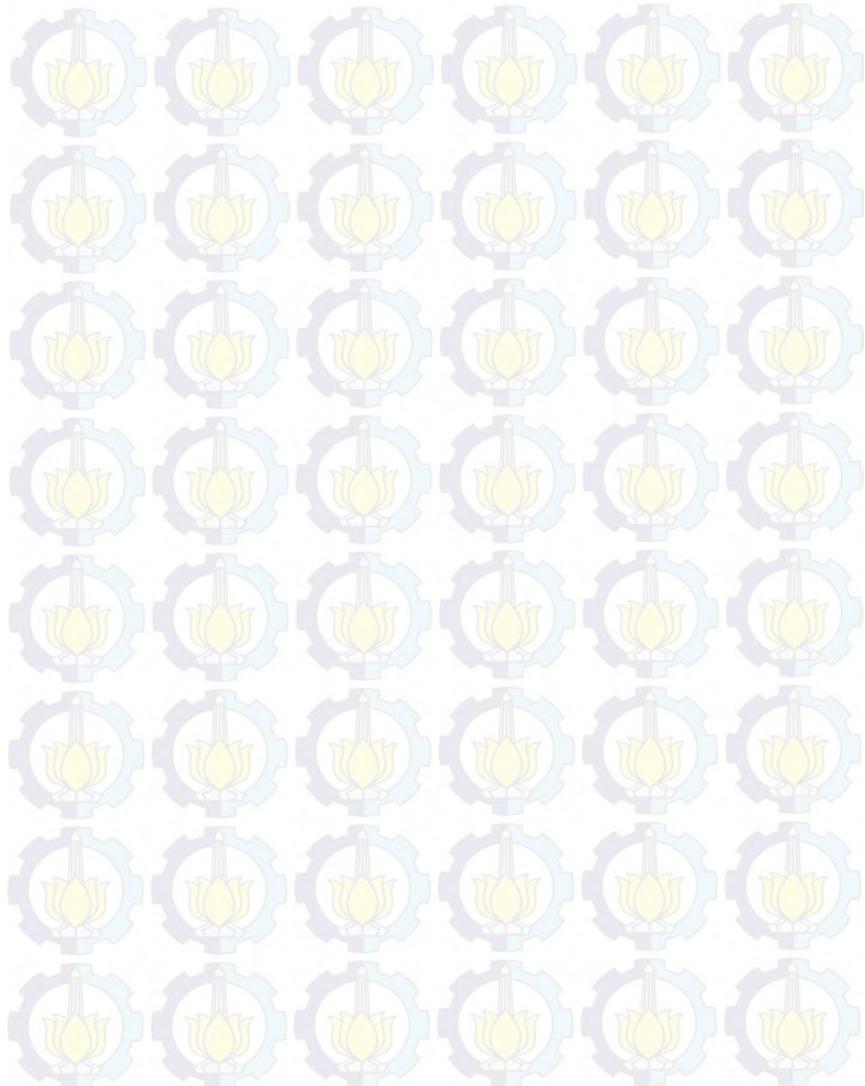
DAFTAR ISI

ABSTRAK.....	vii
ABSTRACT.....	ix
KATA PENGANTAR.....	xi
DAFTAR ISI.....	xi
DAFTAR GAMBAR.....	xvii
DAFTAR TABEL.....	xxi
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah.....	4
1.3. Batasan Tugas Akhir.....	4
1.4. Tujuan Penelitian.....	4
1.5. Manfaat Penelitian.....	4
1.6. Relevansi.....	5
BAB II TINJAUAN PUSTAKA.....	7
2.1. Penelitian Sebelumnya.....	7
2.2. Dasar Teori.....	9
2.2.1 CV. Gemilang Indonesia.....	10
2.2.2. Peramalan.....	13
2.2.3. Perhitungan Error.....	17
2.2.4. Artificial Neural Network.....	18
BAB III METODOLOGI PENELITIAN.....	27
3.1. Diagram Metodologi.....	27
3.2. Uraian Metodologi.....	28
3.2.1. Studi Literatur.....	28
3.2.2. Membuat Model Sistem.....	28
3.2.3. Menentukan Model Penelitian.....	28
3.2.4. Mengumpulkan Data.....	29
3.2.5. Pra-Processing Data.....	30
3.2.6. Memodelkan dengan Backpropagation Neural Network.....	30
3.2.7. Melakukan Peramalan dengan BPNN.....	31
3.2.8. Analisis Hasil Peramalan.....	32
3.2.9. Penyusunan Laporan Tugas Akhir.....	32
BAB IV PERANCANGAN.....	35

4.1.	Pengumpulan Data.....	35
4.1.1.	Gambaran Data Masukan.....	35
4.1.2.	Pra-Processing Data.....	35
4.2.	Model Jaringan Saraf Tiruan.....	38
4.2.1.	Model JST 1.....	38
4.2.2.	Model JST 2.....	39
4.2.3.	Model JST 3.....	40
4.2.4.	Model JST 4.....	41
4.2.5.	Model JST 5.....	42
4.2.6.	Model JST 6.....	43
4.2.7.	Model JST 7.....	44
4.2.8.	Model JST 8.....	45
4.2.9.	Model Pada Produk.....	47
BAB V IMPLEMENTASI.....		49
5.1.	Penentuan Data Masukan.....	49
5.2.	Normalisasi Data.....	49
5.3.	Pembentukan Model Jaringan Saraf Tiruan.....	50
5.4.	Pembentukan Parameter JST.....	51
5.5.	Proses Pelatihan (Training).....	52
5.5.1.	Simulasi Pelatihan (Training).....	52
5.5.2.	Denormalisasi pada Pelatihan (Training).....	53
5.6.	Proses Pengujian (Testing).....	53
5.6.1.	Simulasi Pengujian (Testing).....	54
5.6.2.	Denormalisasi Data Pengujian (Data Testing).....	54
BAB VI HASIL DAN PEMBAHASAN.....		57
6.1.	Hasil Normalisasi.....	57
6.1.1.	Normalisasi Produk Akumalasi.....	57
6.1.2.	Normalisasi Produk K1 (Nota 1 Layer).....	64
6.1.3.	Normalisasi Produk K2 (Nota 2 Layer).....	69
6.1.4.	Normalisasi Produk K3 (Nota 3 Layer).....	75
6.1.5.	Normalisasi Produk K4 (Nota 4 Layer).....	79
6.1.6.	Normalisasi Produk K5 (Nota 5 Layer).....	84
6.1.7.	Normalisasi Produk K6 (Nota 6 Layer).....	89
6.2.	Hasil Pembentukan Model JST dan Training.....	94

6.2.1.	Hasil Pelatihan (Training) Produk Akumalasi.....	95
6.2.2.	Hasil Pelatihan (Training) Produk K1.....	105
6.2.3.	Hasil Pelatihan (Training) Produk K2.....	113
6.2.4.	Hasil Pelatihan (Training) Produk K3.....	121
6.2.5.	Hasil Pelatihan (Training) Produk K4.....	128
6.2.6.	Hasil Pelatihan (Training) Produk K5.....	135
6.2.7.	Hasil Pelatihan (Training) Produk K6.....	142
6.3.	Hasil Uji Coba (Testing).....	149
6.3.1.	Hasil MAPE Uji Coba Produk Akumulasi (KU).....	149
6.3.2.	Hasil MAPE Uji Coba Produk K1.....	149
6.3.3.	Hasil MAPE Uji Coba Produk K2.....	150
6.3.4.	Hasil MAPE Uji Coba Produk K3.....	152
6.3.5.	Hasil MAPE Uji Coba Produk K4.....	153
6.3.6.	Hasil MAPE Uji Coba Produk K5.....	153
6.3.7.	Hasil MAPE Uji Coba Produk K6.....	155
6.3.8.	Perbandingan Antara Aktual dengan Hasil Peramalan.....	156
6.4.	Kesimpulan Hasil Eksperimen.....	160
BAB VII KESIMPULAN DAN SARAN		163
7.1.	Kesimpulan.....	163
7.2.	Saran.....	163
DAFTAR PUSTAKA		165
BIODATA PENULIS		169
LAMPIRAN A.....		A-1
LAMPIRAN B.....		B-1
LAMPIRAN C.....		C-1
LAMPIRAN D.....		D-1
LAMPIRAN E.....		E-1
LAMPIRAN F.....		F-1
LAMPIRAN G.....		G-1
LAMPIRAN H.....		H-1

Halaman ini sengaja dikosongkan.



DAFTAR GAMBAR

Gambar 2. 1. Struktur Organisasi CV. Gemilang Indonesia.....	11
Gambar 2. 2. Struktur Sel Pada Saraf Manusia.....	18
Gambar 2. 3. Arsitektur Backpropagation.....	20
Gambar 2. 4. Gradient Descent.....	22
Gambar 2. 5. Binary Sigmoid.....	23
Gambar 2. 6. Bipolar Sigmoid.....	24
Gambar 2. 7. Linear Sigmoid.....	24
Gambar 3. 1. Metodologi.....	27
Gambar 3. 2. Proses Peramalan BPNN.....	31
Gambar 6.1. Hasil MAPE KUM1.....	95
Gambar 6.2. Hasil RMSE KUM1.....	96
Gambar 6.3. Hasil MAPE KUM2.....	97
Gambar 6.4. Hasil RMSE KUM2.....	97
Gambar 6.5. Hasil MAPE KUM3.....	98
Gambar 6.6. Hasil RMSE KUM3.....	98
Gambar 6.7. Hasil MAPE KUM4.....	99
Gambar 6.8 Hasil RMSE KUM4.....	99
Gambar 6.9. Hasil MAPE KUM5.....	100
Gambar 6.10. Hasil RMSE KUM5.....	100
Gambar 6.11. Hasil MAPE KUM6.....	101
Gambar 6.12. Hasil RMSE KUM6.....	101
Gambar 6.13. Hasil MAPE KUM7.....	102
Gambar 6.14. Hasil RMSE KUM7.....	102
Gambar 6.15. Hasil MAPE KUM8.....	103
Gambar 6.16. Hasil RMSE KUM8.....	103
Gambar 6.17. MAPE Optimal Training Produk Akumulasi.....	104
Gambar 6.18. RMSE Optimal Training Produk Akumulasi.....	105
Gambar 6.19. Hasil MAPE K1M1.....	106
Gambar 6.20. Hasil RMSE K1M2.....	106
Gambar 6.21. Hasil MAPE K1M2.....	107
Gambar 6. 22. Hasil RMSE K1M2.....	107
Gambar 6.23. Hasil MAPE K1M3.....	108

Gambar 6.24. Hasil RMSE K1M3.....	108
Gambar 6.25. Hasil MAPE K1M4.....	109
Gambar 6.26. Hasil RMSE K1M4.....	109
Gambar 6.27. Hasil MAPE K1M5.....	110
Gambar 6.28. Hasil RMSE K1M5.....	110
Gambar 6.29. Hasil MAPE K1M6.....	111
Gambar 6.30. Hasil RMSE K1M6.....	111
Gambar 6. 31. MAPE Training Optimal Produk K1.....	112
Gambar 6. 32. RMSE Training Optimal Produk K1.....	112
Gambar 6.33. Hasil MAPE K2M1	113
Gambar 6.34. Hasil RMSE K2M1	114
Gambar 6.35. Hasil MAPE K2M2	115
Gambar 6.36. Hasil RMSE K2M2	115
Gambar 6.37. Hasil MAPE K2M3	116
Gambar 6.38. Hasil RMSE K2M3	116
Gambar 6.39. Hasil MAPE K2M4	117
Gambar 6.40. Hasil RMSE K2M4	117
Gambar 6.41. Hasil MAPE K2M5	118
Gambar 6. 42. Hasil RMSE K2M5	118
Gambar 6.43. Hasil MAPE K2M6	119
Gambar 6. 44. Hasil RMSE K2M6	119
Gambar 6.45. MAPE Training Optimal Produk K2.....	120
Gambar 6. 46. RMSE Training Optimal Produk K2.....	120
Gambar 6.47. Hasil MAPE K3M1	121
Gambar 6. 48. Hasil RMSE K3M1	121
Gambar 6.49. Hasil MAPE K3M2	122
Gambar 6.50. Hasil RMSE K3M2	122
Gambar 6.51. Hasil MAPE K3M3	123
Gambar 6.52. Hasil RMSE K3M3	123
Gambar 6.53. Hasil MAPE K3M4	124
Gambar 6. 54. Hasil RMSE K3M4	124
Gambar 6.55. Hasil MAPE K3M5	125
Gambar 6.56. Hasil RMSE K3M5	125
Gambar 6. 57. Hasil MAPE K3M6	126
Gambar 6.58. Hasil RMSE K3M6.....	126

Gambar 6. 59. MAPE Training Optimal Produk K3	127
Gambar 6. 60. RMSE Training Optimal Produk K3	127
Gambar 6. 61. Hasil MAPE K4M1	128
Gambar 6. 62. Hasil RMSE K4M1	128
Gambar 6. 63. Hasil MAPE K4M2	129
Gambar 6. 64. Hasil RMSE K4M2	129
Gambar 6.65. Hasil MAPE K4M3	130
Gambar 6.66. Hasil RMSE K4M3	130
Gambar 6.67. Hasil MAPE K4M4	131
Gambar 6.68. Hasil RMSE K4M4	131
Gambar 6.69. Hasil MAPE K4M5	132
Gambar 6.70. Hasil RMSE K4M5	132
Gambar 6.71. Hasil MAPE K4M6	133
Gambar 6.72. Hasil RMSE K4M6	133
Gambar 6. 73. MAPE Training Optimal produk K4	134
Gambar 6. 74. RMSE Training Optimal Produk K4	134
Gambar 6.75. Hasil MAPE K5M1	135
Gambar 6.76. Hasil RMSE K5M1	135
Gambar 6.77. Hasil MAPE K5M2	136
Gambar 6. 78. Hasil RMSE K5M2	136
Gambar 6.79. Hasil MAPE K5M3	137
Gambar 6. 80. Hasil RMSE K5M3	137
Gambar 6.81. Hasil MAPE K5M4	138
Gambar 6. 82. Hasil RMSE K5M4	138
Gambar 6. 83. Hasil MAPE K5M5	139
Gambar 6.84. Hasil RMSE K5M5	139
Gambar 6. 85. Hasil MAPE K5M6	140
Gambar 6. 86. Hasil RMSE K5M6	140
Gambar 6. 87. MAPE Training Optimal Produk K5	141
Gambar 6. 88. RMSE Training Optimal Produk K5	141
Gambar 6. 89. Hasil MAPE K6M1	142
Gambar 6. 90. Hasil RMSE K6M1	142
Gambar 6. 91. Hasil MAPE K6M2	143
Gambar 6. 92. Hasil RMSE K6M2	143
Gambar 6. 93. Hasil MAPE K6M3	144

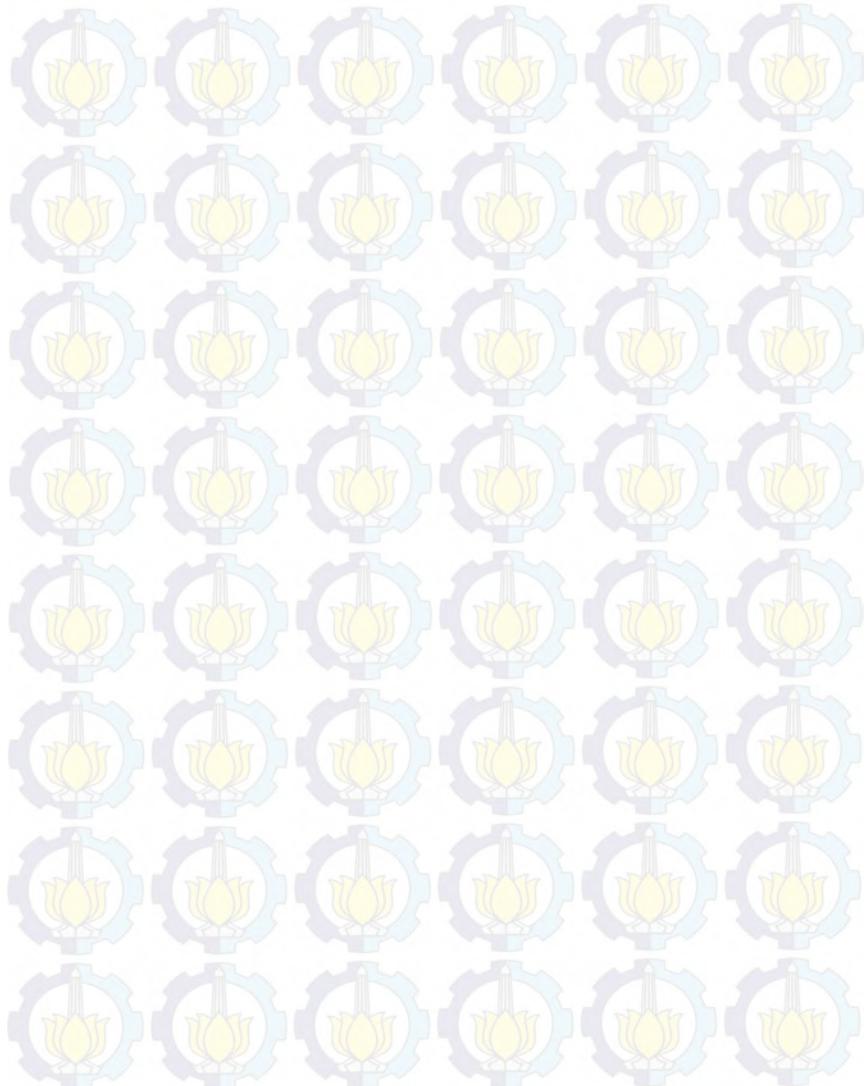
Gambar 6. 94. Hasil RMSE K6M3.....	144
Gambar 6.95. Hasil MAPE K6M4.....	145
Gambar 6. 96. Hasil RMSE K6M4.....	145
Gambar 6. 97. Hasil MAPE K6M5.....	146
Gambar 6. 98. Hasil RMSE K6M5.....	146
Gambar 6. 99. Hasil MAPE K6M6.....	147
Gambar 6. 100. Hasil RMSE K6M6.....	147
Gambar 6. 101. MAPE Optimal Training Produk K6.....	148
Gambar 6. 102. RMSE Optimal Training Produk K6.....	148
Gambar 6. 103. Aktual VS Peramalan Produk Akumulasi.....	156
Gambar 6. 104. Aktual VS Peramalan Produk K1.....	157
Gambar 6. 105. Aktual VS Peramalan Produk K2.....	157
Gambar 6. 106. Aktual VS Peramalan Produk K3.....	158
Gambar 6. 107. Aktual VS Peramalan Produk K4.....	159
Gambar 6. 108. Aktual VS Peramalan Produk K5.....	159
Gambar 6. 109. Aktual VS Peramalan Produk K6.....	160

DAFTAR TABEL

Tabel 6.1. Normalisasi Model KUM1.....	56
Tabel 6.2. Normalisasi Model KUM2.....	58
Tabel 6.3. Normalisasi Model KUM3.....	59
Tabel 6.4. Normalisasi Model KUM4.....	60
Tabel 6.5. Normalisasi Model KUM5.....	61
Tabel 6.6. Normalisasi Model KUM6.....	62
Tabel 6.7. Normalisasi Model KUM7.....	63
Tabel 6.8. Normalisasi Model KUM8.....	64
Tabel 6.9. Normalisasi Model K1M1.....	65
Tabel 6.10. Normalisasi Model K1M2.....	65
Tabel 6.11. Normalisasi Model K1M3.....	66
Tabel 6.12. Normalisasi Model K1M4.....	67
Tabel 6.13. Normalisasi Model K1M5.....	68
Tabel 6.14. Normalisasi Model K1M6.....	69
Tabel 6.15. Normalisasi Model K2M1.....	70
Tabel 6.16. Normalisasi Model K2M2.....	70
Tabel 6.17. Normalisasi Model K2M3.....	71
Tabel 6.18. Normalisasi Model K2M4.....	72
Tabel 6.19. Normalisasi Model K2M5.....	73
Tabel 6.20. Normalisasi Model K2M6.....	74
Tabel 6.21. Normalisasi Model K3M1.....	75
Tabel 6.22. Normalisasi Model K3M2.....	76
Tabel 6.23. Normalisasi Model K3M3.....	76
Tabel 6.24. Normalisasi Model K3M4.....	77
Tabel 6.25. Normalisasi Model K3M5.....	78
Tabel 6.26. Normalisasi Model K3M6.....	79
Tabel 6.27. Normalisasi Model K4M1.....	80
Tabel 6.28. Normalisasi Model K4M2.....	80
Tabel 6.29. Normalisasi Model K4M3.....	81
Tabel 6.30. Normalisasi Model K4M4.....	82
Tabel 6.31. Normalisasi Model K4M5.....	83
Tabel 6.32. Normalisasi Model K4M6.....	84
Tabel 6.33. Normalisasi Model K5M1.....	85

Tabel 6.34. Normalisasi Model K5M2.....	85
Tabel 6.35. Normalisasi Model K5M3.....	86
Tabel 6.36. Normalisasi Model K5M4.....	87
Tabel 6.37. Normalisasi Model K5M5.....	88
Tabel 6.38. Normalisasi Model K5M6.....	89
Tabel 6.39. Normalisasi Model K6M1.....	90
Tabel 6.40. Normalisasi Model K6M2.....	90
Tabel 6.41. Normalisasi Model K6M3.....	91
Tabel 6.42. Normalisasi Model K6M4.....	92
Tabel 6.43. Normalisasi Model K6M5.....	93
Tabel 6.44. Normalisasi Model K6M6.....	94

Halaman sengaja dikosongkan.



BAB I

PENDAHULUAN

Pada bab pendahuluan akan diuraikan proses indentifikasi masalah penelitian yang meliputi latar belakang masalah, perumusan masalah, batasan masalah, tujuan tugas akhir, dan manfaat kegiatan tugas akhir. Berdasarkan uraian pada bab ini, harapannya gambaran umum permasalahan dan pemecahan masalah pada tugas akhir dapat dipahami..

1.1. Latar Belakang Masalah

Perusahaan harus mencoba untuk dapat memperoleh kepuasaan pelanggan yang maksimal untuk dapat menghadapi persaingan sengit di dunia bisnis [1]. Ketersediaan produk menjadi komponen penting untuk menjaga kepuasaan pelanggan dan meningkatkan pendapatan perusahaan [2]. Ketersediaan produk sering menjadi permasalahan yang muncul di perusahaan. Permasalahan tersebut antara lain kehabisan persediaan (out of stock) atau kelebihan persediaan . Hal ini dikarenakan permintaan pelanggan yang tidak menentu dan harus segera terpenuhi. Jika permintaan pelanggan tidak terpenuhi akibat out of stock maka ada kemungkinan pelanggan tersebut dapat berpindah (churn) ke perusahaan lain [2] [3] . Namun, jika persediaan produk berlebihan (over capacity) maka akan menyebabkan penumpukan produk di gudang (inventory) dan perusahaan tidak dapat memproduksi produk yang lain, bahkan akan mengakibatkan perusahaan membayar biaya tambahan yaitu biaya penyimpanan (holding cost) [4].

CV. Gemilang Indonesia merupakan perusahaan yang bergerak dibidang percetakan. CV. Gemilang Indonesia menyediakan jasa percetakan nota, faktur, brosur dan lain sebagainya. Pelanggan yang dimiliki oleh CV. Gemilang Indonesia biasanya adalah perusahaan retail, manufaktur dan toko-toko kelontong. Produk yang diproduksi oleh CV. Gemilang Indonesia tergantung dari pesanan pelanggan karena design (rancangan) produk yang dipesan

oleh pelanggan harus sesuai keinginan pelanggan termasuk material yang akan digunakan.

CV. Gemilang Indonesia sering mengalami out of stock dan sering mengalami penumpukan produk di gudang atau over capacity. Hal ini dikarenakan beberapa pelanggan tetap dari CV. Gemilang Indonesia sering melakukan pemesanan mendadak dengan jumlah yang tidak menentu. Untuk memenuhi permintaan pelanggan tetap nya, maka CV. Gemilang Indonesia sering memproduksi produk pelanggan tetap tersebut dengan jumlah banyak dan menyimpannya di gudang meskipun belum terdapat pemesanan. Namun, CV. Gemilang Indonesia akan kesulitan memenuhi permintaan dari pelanggan lain karena produk yang dipesan menjadi tidak mempunyai tempat penyimpanan. Permasalahan ini disebabkan karena CV. Gemilang Indonesia belum menganalisa trend permintaan pelanggan nya. Sehingga, CV. Gemilang Indonesia kesulitan untuk menentukan jumlah produk yang akan diproduksi dan kapan waktu produksi, seberapa banyak material yang akan dipesan, kapan waktu pemesanan material dan kesulitan mengoptimalkan gudang yang dimiliki untuk penyimpanan [5].

Jumlah ketersedian produk dan gudang (inventory) di CV. Gemilang Indonesia sangat mempengaruhi jumlah penjualan produk dan pendapatan perusahaan. Tujuan adanya ketersedian produk dengan jumlah produk di gudang yang tetap terjaga adalah sebagai tindakan antisipasi dalam ketidakpastian permintaan, serta menjaga kemungkinan risiko yang terjadi, seperti out of stock dan over capacity. Selain itu, juga bertujuan untuk menyeimbangkan antara permintaan dan penawaran produk serta ketersediaan material [6].

Menjaga ketersediaan produk dapat dilakukan dengan meramalkan atau memprediksi jumlah penjualan produk yang akan datang. Peramalan diperlukan untuk memperkirakan penjualan produk

dimasa depan berdasarkan data masa lalu atau historis. Dengan melakukan peramalan penjualan dapat mengetahui pola penjualan yang ada. Peramalan penjualan yang efektif akan dapat membantu perusahaan untuk mengetahui pola penjualan, menentukan seberapa banyak material yang akan dipesan dan produk yang akan dibuat, sehingga dapat menekan biaya penyimpanan dan dapat memenuhi permintaan pelanggan [7].

Pada penelitian yang dilakukan oleh Jian-Zhou Wang (2011) yang memprediksi harga barang yang mempunyai pola non-stasioner dan mempunyai data noise yang tinggi dengan menggunakan Wavelet de-noising Backpropagation (WDBP) Neural Network dan single Backpropagation [8]

Sedangkan penelitian lainnya oleh Linda Stepvanie (2012) mengenai perbandingan hasil peramalan penjualan susu bayi yang memiliki pola data acak dengan menggunakan berbagai metode peramalan. Dari hasil penelitian terbukti bahwa metode Neural Network cocok untuk peramalan penjualan dengan pola data yang tidak menentu (acak) yang menghasilkan peramalan lebih akurat [9]. Begitu hal nya dengan pola data penjualan di CV. Gemilang Indonsia yang memiliki pola data yang cenderung fluktuatif dan acak.

Merujuk dari penelitian-penelitian terdahulu maka untuk mengatasi permasalahan di CV. Gemilang Indonesia maka pada Tugas Akhir ini diusulkan untuk melakukan peramalan jumlah penjualan nota di CV. Gemilang Indonesia dengan menggunakan metode *Artificial Neural Netwok* (ANN) guna mengetahui pola penjualan nota di CV. Gemilang Indonesia dan dapat menentukan persediaan nota di periode berikutnya, sehingga permintaan pelanggan terpenuhi dan level gudang (*inventory*) tetap terjaga, dengan faktor yang memperngaruhi adalah data bulanan penjualan nota jadi selama tahun 2014-2016.

1.2. Rumusan Masalah

Perumusan masalah yang diangkat pada tugas akhir ini adalah :

1. Model seperti apakah yang cocok untuk meramalkan penjualan nota dalam periode waktu ke depan di CV. Gemilang Indonesia ?
2. Bagaimana Backpropagation Neural Network dapat menyelesaikan permasalahan penjualan di CV. Gemilang Indonesia ?
3. Bagaimanakah performa atau kinerja Backpropagation Neural Network dalam melakukan peramalan ?

1.3. Batasan Tugas Akhir

Batasan masalah pada penelitian tugas akhir ini adalah sebagai berikut :

1. Data yang digunakan dalam penelitian tugas akhir ini merupakan data penjualan nota selama, dengan periode waktu (time series) mingguan selama tahun 2014-2016.
2. Metode peramalan yang digunakan yaitu Backpropagation Neural Network
3. Penelitian dilakukan di CV. Gemilang Indonesia.

1.4. Tujuan Penelitian

Penelitian Tugas Akhir ini bertujuan untuk meramalkan jumlah penjualan nota untuk beberapa periode waktu yang akan datang.

1.5. Manfaat Penelitian

Manfaat yang diberikan dengan adanya tugas akhir ini adalah memberikan peramalan yang akurat terkait penjualan nota di CV. Gemilang Indonesia, yaitu sebagai berikut :

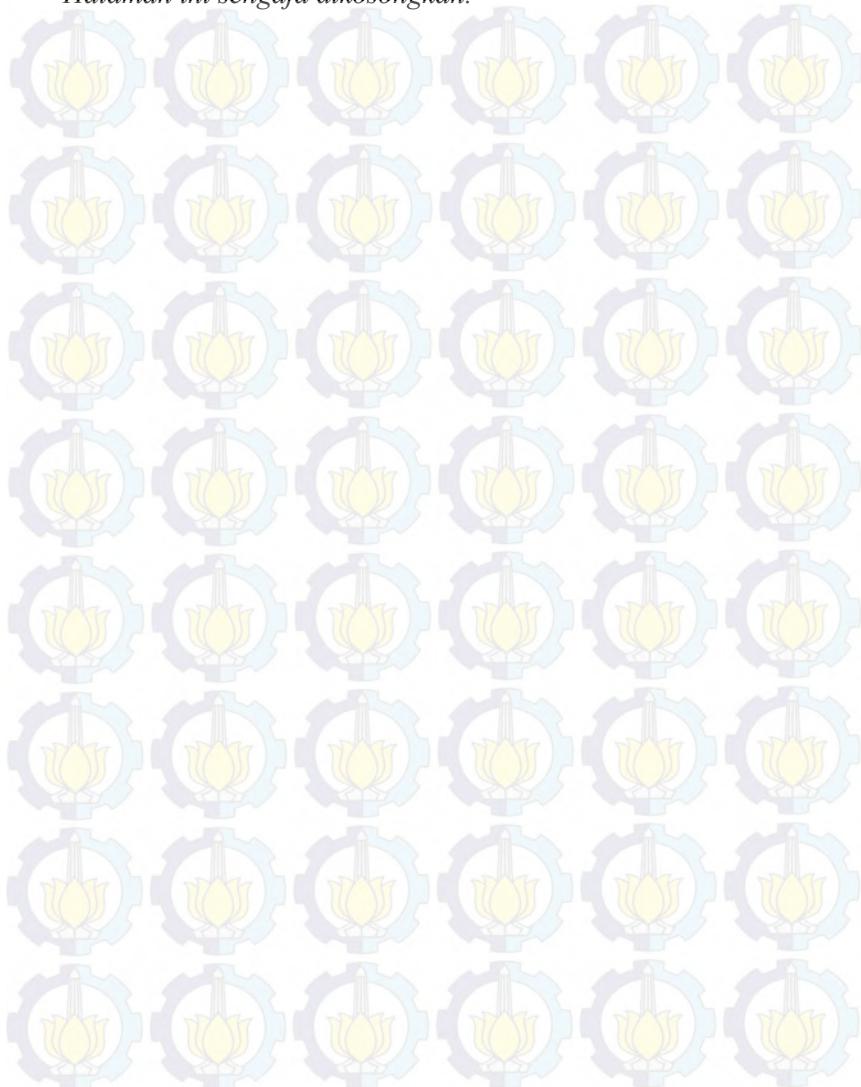
1. Dapat mengetahui pola penjualan nota di CV. Gemilang Indonesia

2. Dapat mengetahui jadwal produksi yang tepat agar produk yang tersedia dapat memenuhi permintaan pelanggan.
3. Dapat mengetahui kebutuhan material untuk setiap produk yang akan diproduksi.
4. Dapat mengetahui jadwal pengadaan material
5. Dapat mengelola stock material maupun produk jadi yang terdapat di gudang (*inventory*)

1.6. Relevansi

Melihat kondisi persaingan antar perusahaan yang semakin ketat, maka setiap perusahaan harus mempunyai strataegi yang dapat menambah dan mempertahankan pelanggannya yaitu dengan memenuhi permintaan pelanggannya. Namun, permintaan pelanggan sering tidak menentu, sehingga diperlukan adanya peramalan stok barang di perusahaan agar perusahaan tetap dapat memenuhi permintaan pelanggan dan memaksimalkan sumber daya yang dimiliki oleh perusahaan.

Halaman ini sengaja dikosongkan.



BAB II

TINJAUAN PUSTAKA

Bab ini menjelaskan mengenai penelitian sebelumnya dan dasar teori yang dijadikan acuan atau landasan dalam penggerjaan tugas akhir ini. Landasan teori akan memberikan gambaran secara umum dari landasan penjabaran tugas akhir ini.

2.1. Penelitian Sebelumnya

Studi yang telah ada sebelumnya dan menjadi pendukung dari penggerjaan tugas akhir ini adalah jurnal dengan topik peramalan atau prediksi menggunakan metode JST dapat dilihat pada Tabel 2.1.

Tabel 2. 1. Penelitian Sebelumnya

Judul	Hasil Penelitian	Kelebihan	Kekurangan
Penerapan Metode Neural Network Dengan Struktur Backpropagation Untuk Prediksi Stok Obat di Apotek (Studi Kasus : Apotek ABC) (Yanti, 2011) [10]	Prediksi stok obat di apotek ABC untuk periode satu tahun ke depan dengan menggunakan Backpropagation Neural Network. Dimana error dari pengujian nilai RMSE kurang dari 0,074	Kesalahan atau error dalam peramalan kecil, sehingga hasil peramalan dapat diterapkan untuk permasalahan di studi kasus.	Untuk mendapatkan hasil yang lebih baik memerlukan data input yang lebih besar
Time Series Sales Forecasting For Short Shelf-Life Food Products Based On Artificial Neural Networks And Evolutionary Computing	Membandingkan hasil prediksi penjualan produk yang mempunyai masa kadaluarsa rendah yaitu susu segar di Atena dan Yunani menggunakan metode <i>Artificial</i>	Memiliki akurasi yang cukup tinggi dengan error rendah dibawah 10%.	

Judul	Hasil Penelitian	Kelebihan	Kekurangan
(Philip Doganis,2006) [11]	<i>Neural Network</i> dan Evolutionary Computing memiliki tingkat akurasi yang cukup tinggi dengan error hanya sekitar 4-10% . Metode paling akurat yaitu Adaptive Neural Network dengan error 4,61%		
Forecasting Stock Indices With Back Propagation Neural Network (Wang, 2011) [8]	Prediksi harga barang yang mempunyai pola non-stasioner dan mempunyai data noise yang tinggi dengan menggunakan Wavelet denoising Backpropagation (WDBP) Neural Network. Selain itu membandingkan hasil WDBP dengan single Backpropagation.	Wavelet denoising menghasilkan prediksi yang lebih efektif.	
Peramalan penjualan Produk Susu Bayi dengan Metode Grey System Theory	Membandingkan hasil peramalan penjualan susu bayi yang memiliki pola data acak dengan	Metode Neural Netwok dapat meramalkan penjualan dengan pola data acak lebih akurat	Besar kecilnya perhitungan error dengan RMSE tergantung

Judul	Hasil Penelitian	Kelebihan	Kekurangan
dan Neural Network [9]	menggunakan berbagai metode peramalan. Dari hasil penelitian terbukti bahwa metode Neural Network cocok untuk peramalan penjualan dengan pola data yang tidak menentu (acak) yang menghasilkan peramalan lebih akurat.	disbanding metode lainnya.	dari perbedaan angka terendah dan terbesar pada data.
Model Prediksi Rentet Waktu Penjualan Minuman Kesehatan Berbasis Neural Network (Hartono, 2013) [12]	Prediksi penjualan minuman kacang hijau pada perusahaan Sari Kacang Hijau D'Bean di Thailand dengan menggunakan metode BPNN dan menghasilkan tingkat RMSE yang rendah yaitu 0,152	Neural network dengan algoritma pembelajaran Backpropagation dapat menghasilkan model rentet waktu untuk prediksi secara akurat.	

2.2. Dasar Teori

Subbab ini berisikan dasar teori yang akan digunakan dalam penelitian tugas akhir ini, mencakup teori dan metode yang digunakan

2.2.1 CV. Gemilang Indonesia

CV. Gemilang Indonesia merupakan perusahaan yang bergerak dibidang percetakan kertas yang tertempat di Sidoarjo. Produk yang dihasilkan oleh CV. Gemilang Indonesia yaitu mencetak Nota, Surat jalan, Stiker, Brosur dan lain sebagainya, dimana produk tersebut akan terus berkembang sesuai dengan inovasi dan permintaan pasar. Hal ini sesuai dengan visi misi dari CV. Gemilang Indonesia yaitu sebagai berikut :

Visi :

“Menjadi perusahaan percetakan yang dapat memenuhi permintaan pelanggan dengan produk yang berkualitas dan senantiasa meningkatkan produktivitas demi kemajuan perusahaan serta menjadi perusahaan ternama di Indonesia”

Misi :

1. Kepuasaan Pelanggan
2. Memenuhi harapan seluruh *stakeholder*
3. Hasil cetakan yang berkualitas dan tepat waktu
4. Meningkatkan kemampuan karyawan
5. Mengikuti perkembangan teknologi

2.2.1.1. Tujuan Perusahaan

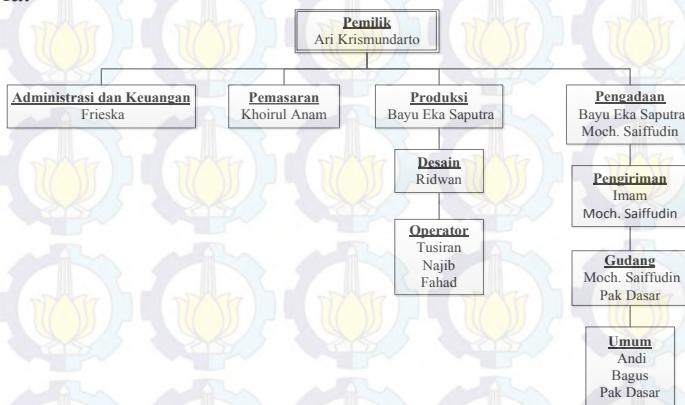
CV. Gemilang Indonesia mempunyai dua jenis tujuan dalam membangun usahanya, yaitu tujuan jangka pendek dan jangka panjang. Uraianya adalah sebagai berikut:

- a. Tujuan Jangka Pendek
 1. Meningkatkan volume penjualan
 2. Memperluas daerah pemasaran
 3. Mendapatkan keuntungan atau laba yang maksimal

- b. Tujuan Jangka Panjang
 - 1. Mengembangkan usaha perusahaan
 - 2. Meningkatkan kesejahteraan karyawan

2.2.1.2. Struktur Organisasi

Dalam mencapai tujuan yang telah ditetapkan, CV. Gemilang Indonesia melakukan pembagian tugas, tanggung jawab, dan wewenang sesuai dengan kemampuan masing-masing karyawannya. Oleh karena itu, untuk menyempurnakan organisasi, perusahaan melakukan perubahan struktur organisasi secara bertahap. Hal ini dilakukan dengan tujuan agar menghasilkan kegiatan organisasi yang fleksibel dan dinamis sehingga mampu menghadapi situasi dan kondisi yang selalu berubah. Gambar 2.1 merupakan gambar struktur organisasi pada CV. Gemilang Indonesia.



Gambar 2. 1. Struktur Organisasi CV. Gemilang Indonesia

Job Description dari masing-masing bagian struktur organisasi pada Gambar 2.1 adalah sebagai berikut:

a. Pemilik

Pemilik adalah seseorang yang memiliki perusahaan dan yang bertanggungjawab atas segala sesuatu yang ada didalam perusahaan.

b. Administrasi dan Keuangan

Bagian administrasi dan keuangan ini merupakan bagian yang menangani semua administrasi dan keuangan keluar serta administrasi dan keuangan masuk di perusahaan.

c. Pemasaran

Bagian pemasaran ini bertugas untuk merencanakan strategi yang bertujuan agar perusahaan memperoleh banyak customer dan untuk memasarkan produk perusahaan kepada customer.

d. Produksi

Bagian produksi memiliki dua bagian yaitu: bagian desain dan operator. Bagian desain bertugas untuk membuat rancangan/desain dan menyesuaikan ukuran sesuai dengan pesanan pelanggan. Tugas dari operator adalah melakukan/menjalankan mesin-mesin cetak yang berada di perusahaan.

e. Pengadaan

Bagian pengadaan memiliki beberapa bagian yaitu: bagian pengiriman bertugas untuk mengirim barang dari perusahaan ke customer. Bagian gudang bertugas yang bertanggungjawab dalam penyimpanan barang dan bahan keperluan produksi perusahaan yang belum terpakai. Dan bagian Umum bertugas membantu seluruh karyawan yang bertugas di perusahaan.

2.2.1.3. Kondisi Kekinian

Pada saat ini pemasaran produk CV. Gemilang Indonesia mencakup daerah Jawa Timur, Bali, Sumatera dan Kalimantan, dengan jenis pelanggan terdiri atas 90% perusahaan dan 10% dari per orang. Jumlah pelanggan CV. Gemilang Indonesia semakin

meningkat seiring dengan meluasnya pangsa pasarnya. Dengan banyaknya jumlah pelanggan dan permintaan yang tidak menentu dari pelanggan-pelanggannya membuat CV. Gemilang Indonesia kesulitan untuk memperkirakan jumlah produk yang harus diproduksi agar sesuai dengan jumlah permintaan, namun tidak mengalami kekurangan ataupun penumpukan di gudang. Selain itu, produk yang diproduksi oleh CV. Gemilang Indonesia tergantung dari pesanan pelanggan karena design (rancangan) produk yang dipesan oleh pelanggan harus sesuai keinginan pelanggan termasuk material yang akan digunakan.

CV. Gemilang Indonesia sering mengalami out of stock dan sering mengalami penumpukan produk di gudang atau over capacity. Hal ini dikarenakan beberapa pelanggan tetap dari CV. Gemilang Indonesia sering melakukan pemesanan mendadak dengan jumlah yang tidak menentu. Untuk memenuhi permintaan pelanggan tetapnya, maka CV. Gemilang Indonesia sering memproduksi produk pelanggan tetap tersebut dengan jumlah banyak dan menyimpannya di gudang meskipun belum terdapat pemesanan. Namun, CV. Gemilang Indonesia akan kesulitan memenuhi permintaan dari pelanggan lain karena produk yang dipesan menjadi tidak mempunyai tempat penyimpanan. Permasalahan ini disebabkan karena CV. Gemilang Indonesia belum menganalisa trend permintaan pelanggannya. Sehingga, CV. Gemilang Indonesia kesulitan untuk menentukan jumlah produk yang akan diproduksi dan kesulitan mengoptimalkan gudang yang dimiliki untuk penyimpanan [5] [12].

2.2.2. Peramalan

Peramalan merupakan perkiraan atau prediksi di masa depan berdasarkan data di masa lalu atau data historis [7]. Sumayang (2003) mendefinisikan peramalan merupakan perhitungan yang objektif dan dengan menggunakan data-data masa lalu untuk menentukan sesuatu di masa yang akan datang. Selain itu,

peramalan menurut Nasution dan Praetyawan (2008) mendefinikan peramalan adalah proses untuk memperkirakan beberapa kebutuhan dimasa datang yang meliputi kebutuhan dalam ukuran kuantitas, kualitas, waktu dan lokasi yang dibutuhkan dalam rangka memenuhi permintaan barang ataupun jasa [13].

Peramalan dibagi menjadi dua bagian, yaitu peramalan kualitatif dan kuantitatif, yang akan dijelaskan sebagai berikut :

- *Kuantitatif*

Digunakan pada saat data masa lalu cukup tersedia. Beberapa teknik kuantitatif yang sering dipergunakan: *Time Series Model* dan *Causal Model*.

- *Kualitatif*

Merupakan peramalan yang melibatkan pendapat para ahli, biasanya menggunakan metode Delphi yang bertujuan untuk mengabungkan seluruh informasi yang diperoleh secara logika, dan sistematis yang dihubungkan dengan faktor ketertarikan pengambil keputusan [14].

Terdapat beberapa macam tipe peramalan menurut Jay Heizer (2005) yaitu sebagai berikut :

- a. *Time Series Model* yaitu metode peramalan secara kuantitatif dengan menggunakan waktu sebagai dasar peramalan
- b. *Causal Model* yaitu metode peramalan yang menggunakan hubungan sebab-akibat sebagai asumsi, bahwa apa yang terjadi di masa lalu akan terulang pada saat ini.
- c. *Judgemental Model* yaitu bila *time series* dan *causal model* bertumpu pada kuantitatif, pada *judgmental* mencakup untuk memasukkan faktor-faktor subjektif ke dalam metode peramalan [15].

Sedangkan metode yang biasa digunakan dalam melakukan peramalan antara lain sebagai berikut :

a. *Metode Smoothing*

Merupakan metode yang digunakan untuk jangka pendek, fungsi dari metode ini adalah untuk mengurangi ketidak teraturan musiman, sehingga mempunyai syarat minimal harus tersedia data dua tahun yang lalu, penggunaan metode ini misalnya untuk perencanaan dan pengendalian produksi dan persedian, serta perencanaan keuntungan.

b. *Metode Box-Jenkins*

Metode peramalan Box Jenkins (ARIMA) adalah suatu metode yang sangat tepat untuk menangani atau mengatasi kerumitan deret waktu dan situasi peramalan lainnya. Dalam metode Box Jenkins (ARIMA) tidak dibutuhkan adanya asumsi tentang suatu pola yang tetap, yang berbeda dengan metode-metode lainnya.

c. *Weight Moving Averages (WMA)*

Model rata-rata bergerak menggunakan sejumlah data aktual permintaan yang baru untuk membangkitkan nilai ramalan untuk permintaan di masa yang akan datang. metode rata-rata bergerak akan efektif diterapkan apabila permintaan pasar terhadap produk diasumsikan stabil sepanjang waktu. Metode rata-rata bergerak terdapat dua jenis, rata-rata bergerak tidak berbobot (Unweight Moving Averages) dan rata-rata bobot bergerak (Weight Moving Averages). Model rata-rata bobot bergerak lebih responsif terhadap perubahan karena data dari periode yang baru biasanya diberi bobot lebih besar [16] .

d. Metode Regresi Linear

Regresi Linear merupakan metode statistic yang bertujuan untuk membentuk sebuah model antara variabel dependen (Y) dengan variabel (X). Regresi Linear yang memiliki satu variabel bebas disebut dengan regresi linear sederhana, sedangkan jika memiliki lebih dari satu variabel disebut dengan regresi linear berganda.

e. Metode Neural Network Forecasting

Nueral Network Forecasting merupakan metode peramalan dengan menggunakan jaringan saraf tiruan (neural netwok) dalam perhitungan ramalannya. Metode ini digunakan untuk model peramalan nonlinear, dimana dalam neural netwok terdapat layer masukan dan keluaran serta terdapat fungsi aktivasi. Dengan rumus sebagai berikut :

$$Y_t = f(Y_{t-1}, \dots, Y_{t-p}) + e_t \quad (1)$$

Keterangan :

Y_t = nilai variabel Y pada waktu ke $-t$

Y_{t-1} = nilai variabel pada lag ke-1, dimana t lebih besar dari 1

Y_{t-p} = nilai variabel Y pada lag ke-p, dimana t lebih besar dari p

e_t = error untuk periode waktu t [17]

Pola-pola yang mempengaruhi Time Series menurut Steven C. Wheelwright (1998) yaitu :

- *Horizontal (H)*

Pola *horizontal* ada atau muncul ketika nilai data muncul secara fluktuatif (berubah-ubah) di sekitar rata-rata konstan yang disebut dengan *stationary*.

- *Seasional (S)*

Pola *seasional* muncul ketika terdapat data selama rentang waktu tertentu (time series) dipengaruhi oleh faktor *seasional* (musiman)

- *Cyclical (C)*

Pola *cyclical* terjadi ketika data *exhibit* mulai naik dan turun tetapi tidak pada periode yang tetap.

- *Trend (T)*

Pola *trend* terjadi ketika ada kenaikan atau penurunan jangka panjang pada data [17].

2.2.3. Perhitungan Error

Menurut Heizer dan Render (2009) terdapat beberapa perhitungan yang digunakan untuk menghitung kesalahan atau *error* dalam peramalan. Metode dalam perhitungan error antara lain sebagai berikut :

1. MSE

Mean Squared Error (MSE) merupakan perhitungan error dengan menggunakan rataan selisih kuadrat antara nilai yang diramalkan dan yang diamati, yaitu sebagai berikut :

$$MSE = \frac{\sum(\text{kesalahan-peramalan})^2}{n} \quad (1)$$

$$MSE = \frac{\sum_{i=1}^n e_t^2}{n} \quad (2)$$

2. RMSE

Root Mean Squared Error (RMSE) merupakan perhitungan error dengan mengakarkan rataan selisih kuadrat antara nilai yang diramalkan dan yang diamati, yaitu sebagai berikut :

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=n}^n (D_t - F_t)^2} \quad (3)$$

3. MAPE

Mean Absolute Percentage Error (MAPE) merupakan perhitungan error dengan menggunakan rataan deferensial absolut antara nilai yang diramalkan dan aktual, dinyatakan sebagai persentase nilai aktual, jika memiliki nilai yang diramalkan untuk *n periode* [15] [18], MAPE dihitung sebagai :

$$MAPE = \frac{\sum \text{Kesalahan persen absolut}}{n} \quad (4)$$

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{e_t}{D_t} \right| 100\%}{n} \quad (5)$$

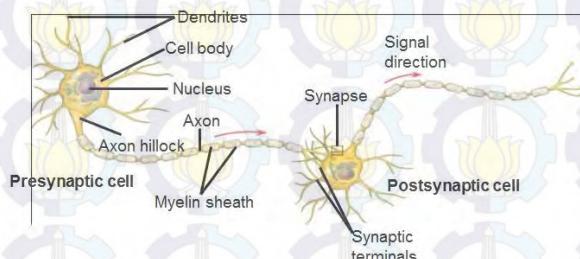
Keterangan :

e_1 = *error untuk periode waktu t*

$e_t = D_t - F_t$, *error* adalah perbedaan hasil ramalan demand dengan demand sebenarnya [19]

2.2.4. Artificial Neural Network

Artificial Neural Network (ANN) merupakan sebuah sistem untuk pemrosesan informasi dengan “meniru” cara kerja sistem saraf biologis. ANN terinspirasi dari sistem kerja saraf manusia yang disebut neuron (seperti pada Gambar 2.2).



Gambar 2.2. Struktur Sel Pada Saraf Manusia

Keterangan :

Dendrit : fasilitator yang menghubungkan neuron dengan axon dari neuron lainnya.

Nukleus : inti sel pengolah informasi

Sinapsis : berfungsi sebagai persimpangan, dimana impuls/informasi dapat megalir dari neuron satu ke yang lain.

Axon : penghubung yang mengirimkan sinyal keluaran neuron menuju neuron lainnya

Neural Network terdiri dari node atau unit yang terhubung dengan penghubung (*link*) dari unit i ke unit j yang berfungsi untuk menyebarluaskan aktivasi a_i dari i ke j. Masing-masing penghubung (*link*) mempunyai nilai bobot tersendiri w_{ij} . Seperti pada sebuah sinapsis, nilai bobot menentukan derajat pengaruh dari neuron ke neuron yang lainnya. Pengaruh dari neuron ke neuron lainnya merupakan hasil kali dari nilai keluaran neuron-neuron yang

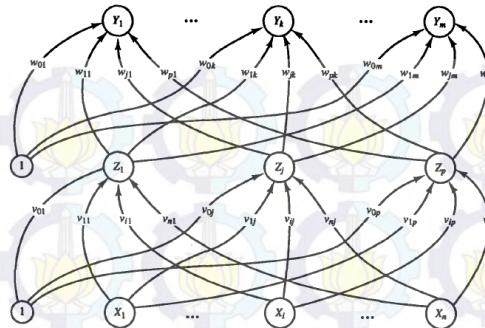
masuk ke neuron (x) dengan nilai bobot (w) yang menghubungkan neuron-neuron tadi.

Tiap neuron dikombinasikan dengan sebuah fungsi aktivasi yang berfungsi sebagai penghubung dari penjumlahan semua nilai masukan dengan nilai keluarannya. Keluaran dari neuron inilah yang akhirnya akan menentukan apakah neuron itu aktif atau tidak. Karakteristik Permasalahan Neural Network :

- Instance direpresentasikan dalam pasangan attribute-value yang banyak
- Target output dapat bermakna diskrit, real, atau vector (diskrit/real)
- Penggunaan representasi simbolik, misalnya decision tree
- Data training bias mengandung error
- Tidak ada batasan waktu pelatihan
- Dibutuhkannya evaluasi yang cepat terhadap proses pembelajaran
- Tidak mementingkan kemampuan manusia untuk mengerti proses pembelajaran

2.2.4.1. Multilayer Network

Single perceptron hanya dapat menyelesaikan permasalahan *linear decision* saja, namun untuk dapat menyelesaikan permasalahan *non-linear decision* digunakan metode multilayer network dengan Algoritma *Backpropagation Neural Network* seperti terlihat pada Gambar 2.3



Gambar 2. 3. Arsitektur Backpropagation

Pelatihan pada Backpropagation Neural Network yaitu sebagai berikut :

- Feedforward pola pelatihan input
 - Setiap unit input (x_1, \dots, x_n) menerima sinyal dari luar unit dan melanjutkan sinyal tersebut pada setiap unit pada hidden layer (z_1, \dots, z_p)
 - Setiap unit pada hidden layer (z_1, \dots, z_p) kemudian melakukan perhitungan berdasarkan pada fungsi aktifasi, dan melanjutkan sinyal tersebut pada setiap unit output (y_1, \dots, y_m)
 - Setiap unit pada output layer (y_1, \dots, y_m) melakukan berhitungan berdasarkan fungsi aktifasi dan menghasilkan sinyal keluaran ANN berdasarkan pola input
- Backpropagation untuk error
 - Selama proses pelatihan setiap output unit (y_1, \dots, y_m) melakukan perbandingan antara sinyal keluaran ANN dengan sinyal yang seharusnya (target sinyal) untuk mendapatkan error pada unit tersebut.
 - Setiap error pada output unit didistribusikan kembali kepada semua unit sebelumnya (hidden layer) untuk

- menghitung perubahan bobot masing-masing unit pada hidden layer terhadap output layer
- Dengan cara yang sama, error dihitung pada semua unit hidden layer
 - Hasil perhitungan error pada hidden layer tidak perlu didistribusikan pada semua unit input layer, tetapi hanya digunakan untuk menghitung perubahan bobot masing-masing unit input layer pada hidden layer
- c. Perubahan bobot
- Setelah semua error pada masing-masing unit (output dan hidden layer) diketahui, secara simultan dilakukan perubahan bobot pada masing-masing unit.
 - Perubahan bobot antara unit hidden layer ke output layer dihitung berdasar error pada unit output layer dan fungsi aktifasi pada unit hidden layer
 - Perubahan bobot antara unit input layer ke hidden layer dihitung berdasar error pada unit hidden layer dan fungsi aktifasi pada unit input layer

Dasar pemikiran Back-propagation yaitu Neural network membutuhkan data training besar dan lengkap termasuk variabel target yang outputnya diproses melalui node-node yang ada pada jaringan. Output akan dibandingkan dengan nilai actual, sehingga error yang terjadi dapat diprediksi dengan rumus :

$$SSE = \sum_{record} \sum_{output\ nodes} (actual - output)^2 \quad (6)$$

Dimana error yang diperkirakan dijumlahkan dengan semua output dari node dan data training. Untuk itu diperlukan model pembobotan yang dapat meminimalkan error yang akan terjadi, karena model sigmoid pada neural network tidak dapat memperkirakan error jika data tersebut non-linear.

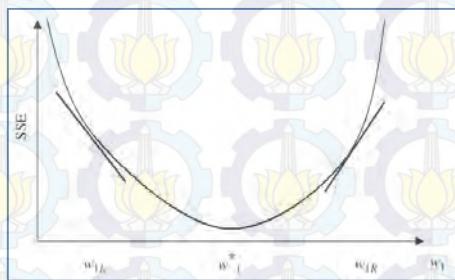
Untuk prinsip kerja yang digunakan yaitu dengan metode *Gradient Descent*. Metode Gradient Descent digunakan untuk mencari nilai setiap bobot yang berupa vektor, dimana bobot

tersebut akan menurunkan error atau SSE pada neural network. Metode yang digunakan yaitu dengan membuat bobot baru dari penjumlahan bobot sekarang dengan selisih dari bobot sekarang.

$$w_{new} = w_{current} + \Delta w_{current} \quad (7)$$

dimana $\Delta w_{current}$ merupakan perubahan dari w .

Jika bobot sekarang = w_{1L} maka harus menaikkan bobot w_{1L} agar mendekati w_1^* , kemiringan kurva w_{1L} menjadi negatif. Namun jika bobot sekarang = w_{1R} maka harus menurunkan bobot untuk mendekati w_1^* , kemiringan kurva w_{1R} menjadi positif. dari kemiringan kurva tersebut akan membentuk η (*learning rate*) yang nilainya antara 0 sampai 1 (seperti pada Gambar 2.4)



Gambar 2. 4. Gradient Descent

Backpropagation menggunakan prediksi error (actual-output) untuk mengurangi error dengan memberikan *partitioned responsibility* di berbagai koneksi dan menyesuaikan bobot tersebut menggunakan *gradient descent*. Rumus dari *back-propagation* yaitu :

$$w_{ij,new} = w_{ij,current} + \Delta w_{ij} \quad (8)$$

$$\text{Dimana } \Delta w_{ij} = \eta \delta_j x_{ij} \quad (9)$$

$$\delta_j = \begin{cases} output_j(1 - output_j)(actual_j - output_j) & \text{output layer} \\ output_j(1 - output_j) \sum_{\text{downstream}} W_{ij} \delta_i & \text{hidden layer} \end{cases} \quad (10)$$

Keterangan :

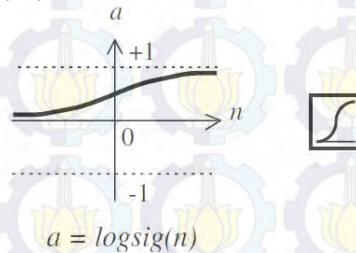
x_{ij} = input dari node i sampai j

δ_j = responsbilit error pada node j

Algoritma backpropagation banyak digunakan untuk melakukan prediksi data baik data yang bersifat fluktuatif maupun data yang non-fluktuatif. Salah satu indikator yang dapat mempengaruhi hasil dari algoritma backpropagation adalah fungsi aktivasi yang bersifat terdefensial yaitu fungsi aktivasi sigmoid. Terdapat beberapa fungsi aktifasi dalam Neural Network antara lain yaitu

- a. Binary Sigmoid (Gambar 2.5) digunakan pada single layer network untuk mengubah masukan (net input) yang merupakan variabel kontinu menjadi keluaran bernilai biner (0 atau 1). Dengan rumus sebagai berikut :

$$f_1(x) = \frac{1}{1 + \exp(-x)} \quad (11)$$



Gambar 2. 5. Binary Sigmoid

- b. Bipolar sigmoid (Gambar 2.6) menggunakan nilai ambang (*Threshold*) atau fungsi Heaviside dimana nilai threshold menjadi garis pemisah antara daerah dengan respon

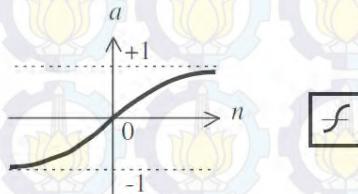
aktivasi positif dan daerah dengan respon aktivasi negatif namun hasilnya berupa nilai 1, 0, -1

$$y = \begin{cases} 1 & \text{jika } x > 0 \\ 0 & \text{jika } x = 0 \\ -1 & \text{jika } x < 0 \end{cases} \quad (12)$$

Dengan rumus :

$$f_2(x) = \frac{2}{1+\exp(-x)} - 1 \quad (13)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (14)$$

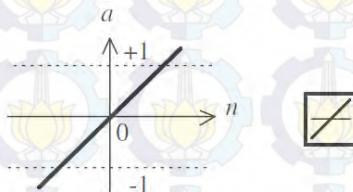


$$a = \text{tansig}(n)$$

Gambar 2. 6. Bipolar Sigmoid

- c. Linear sigmoid (Gambar 2.7) memiliki nilai keluaran sama dengan nilai masukannya. Dengan rumus :

$$f(x) = x \quad (15)$$



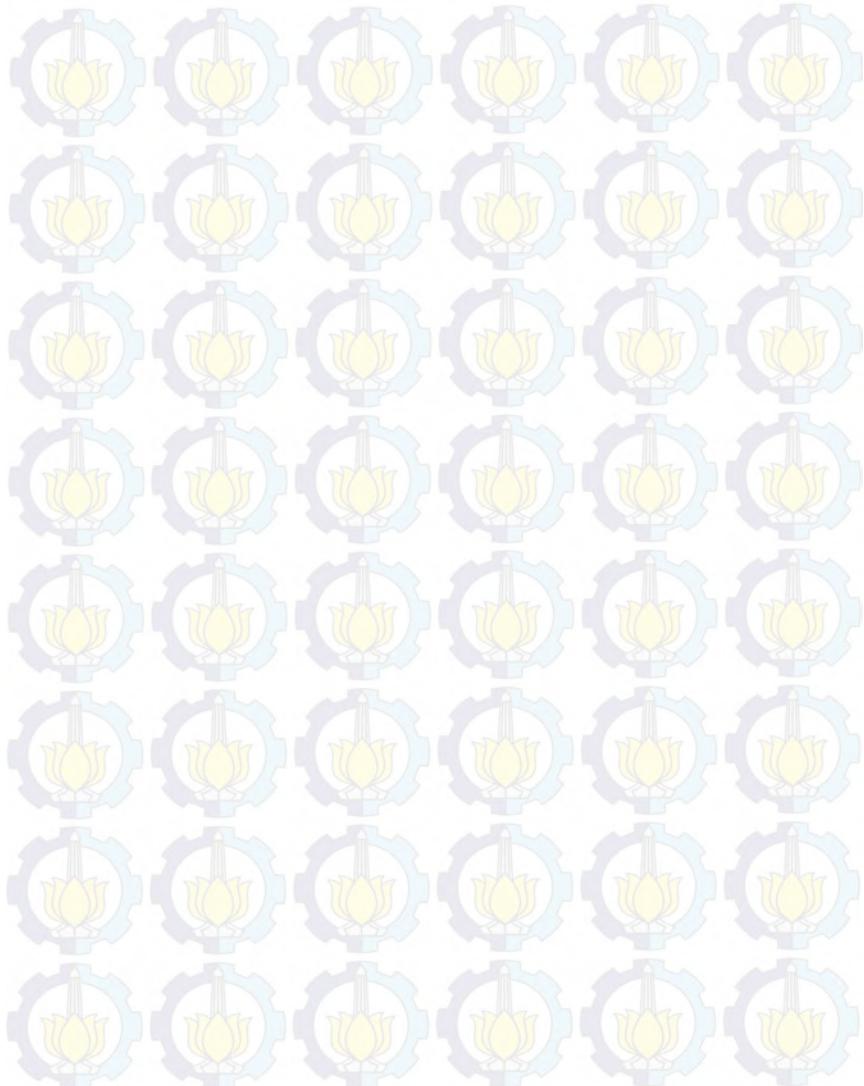
$$a = \text{purelin}(n)$$

Gambar 2. 7. Linear Sigmoid

Proses pembelajaran atau learning dalam Backpropagation perlu adanya pemberhentian, kapan learning berhenti. Untuk itu terdapat beberapa cara pemberhentian pembelajaran neural network yaitu :

- Proses iterasi telah mencapai batas yang telah ditentukan
- Error yang dicapai dapat ditoleransi
- Selisih error pada periode sekarang hanya sedikit dibandingkan dengan error sebelumnya.
- Membuat *global minimum* dari SSE
- Untuk multiple network gunakan inisialisasi data training yang berbeda [20] [21]

Halaman ini sengaja dikosongkan.



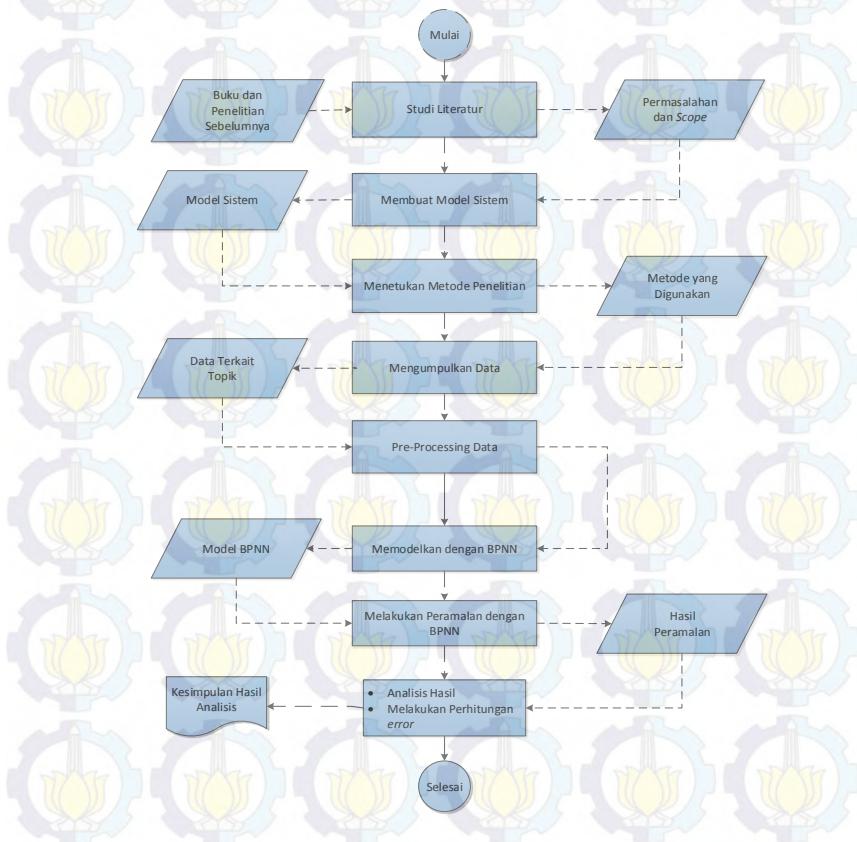
BAB III

METODOLOGI PENELITIAN

Pada bab ini menjelaskan terkait metodologi yang akan digunakan sebagai panduan untuk menyelesaikan penelitian tugas akhir ini.

3.1. Diagram Metodologi

Gambar 3.1 merupakan alir metodologi untuk penelitian tugas akhir menggunakan metode *Artificial Neural Netwok (ANN)*:



Gaambar 3. 1. Metodologi

3.2. Uraian Metodologi

Berdasarkan pada diagram alur metodologi pada sub bab sebelumnya, di bawah ini merupakan penjelasan dari setiap prosesnya.

3.2.1. Studi Literatur

Studi literatur didapatkan dari pengumpulan referensi, diantaranya dari narasumber, buku, penelitian sebelumnya, dan dokumen yang terkait. Namun sebelumnya ditentukan terlebih dahulu topik permasalahan yang diangkat. Pada penelitian tugas akhir ini, penulis mengusulkan topik mengenai peramalan jumlah penjualan nota oleh CV. Gemilang Indonesia dengan menggunakan model peramalan. Selanjutnya, dibutuhkan studi literatur untuk lebih memahami dasar – dasar teori yang berhubungan dengan permasalahan. Studi Literatur dapat berasal dari penelitian-penelitian sebelumnya, buku maupun jurnal ilmiah. Studi literatur dapat membantu peneliti dalam mencari sumber – sumber yang dapat dipercaya dan latar belakang permasalahan yang diangkat dalam penelitian tugas akhir ini.

3.2.2. Membuat Model Sistem

Selanjutnya membuat model sistem yang akan digunakan dalam penelitian ini. Pembuatan model sistem dilakukan dengan cara mencari variabel-variabel terkait yang akan digunakan dalam peramalan penjualan. Variabel tersebut antara lain data penjualan dan time series yang digunakan dalam peramalan.

3.2.3. Menentukan Model Penelitian

Setelah mendapatkan pemasalahan dan batasan dari permasalahan tersebut, hasil dari studi literature yang telah dilakukan dan model sistem, maka akan ditemukan metode-metode yang diusulkan oleh penelitian-penlitian sebelumnya dengan topik yang serupa. Cara untuk menentukan metode penelitian adalah dengan menggali kelebihan dan kelemahan dari metode – metode tersebut, dan kemudian mencari kesesuaian dengan topik permasalahan yang

diangkat dalam penelitian tugas akhir ini. Sesuai dengan yang telah dijelaskan pada bab sebelumnya, penulis mengusulkan salah satu metode peramalan yaitu metode *Artificial Neural Network* dengan menggunakan algoritma *Backpropagation* sebagai metode penelitian.

3.2.4. Mengumpulkan Data

Setelah mendapatkan metode penelitian dan model sistem yang akan digunakan, maka selanjutnya dilakukan pengumpulan data pendukung. Data pendukung tersebut diketahui dari variabel yang telah ditemukan dalam model sistem. Dengan telah ditetapkannya metode penelitian maka mempermudah pengumpulan data-data yang diperlukan untuk mengaplikasikan metode penelitian tersebut. Data yang diperlukan merupakan data penjualan nota dengan time series mingguan selama tahun 2014-2016. Data Penjualan Nota yang dikumpulkan yaitu sebagai berikut :

- a. Jenis Barang
- b. Satuan
- c. Jumlah Pemesanan
- d. Harga
- e. Waktu Pemesanan
- f. Kapasitas produksi
- g. Kapasitas gudang
- h. Material yang diperlukan

Data-data tersebut didapatkan dari hasil wawancara dengan beberapa narasumber CV. Gemilang Indonesia. Narasumber tersebut adalah :

Nama : Ari Krismundarto
Jabatan : Pemilik CV. Gemilang Indonesia
Topik :wawancara mengenai proses bisnis CV. Gemilang Indonesia

Nama : Bayu Eka Saputra
Jabatan : Staf Produksi dan Pengadaan
Topik : pengambilan data penjualan

3.2.5. Pra-Processing Data

Dari data-data yang telah diperoleh, maka selanjutnya akan dilakukan pre-processing data untuk menghindari adanya masalah dalam proses komputasi, untuk memenuhi persyaratan algoritma yang digunakan dan berpengaruh terhadap tingkat akurasi yang dihasilkan. *Preprocessing* data dilakukan dengan menghilangkan noise atau data yang tidak konsisten agar data tersebut dapat diolah sehingga menghasilkan peramalan yang lebih akurat.

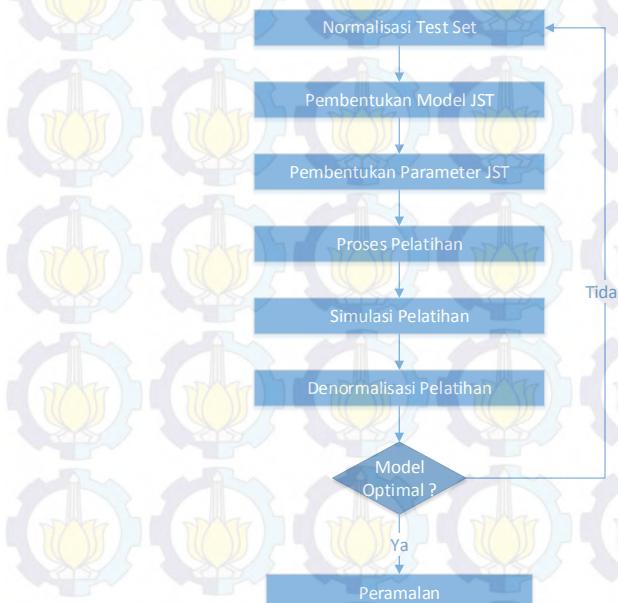
3.2.6. Memodelkan dengan Backpropagation Neural Network

Model *Neural Network* dibangun dari arsitektur *Artificial Nural Network* yang terdiri dari *input layer*, *hidden layer* dan *output layer*. Masing-masing *layer* terdiri dari satu atau lebih *neuron*. Selain itu, parameter lainnya yang harus ditentukan dalam membangun model *Artificial Nueral Network* adalah jenis *backpropagation* dan fungsi aktivasi masing-masing *layer*. Pada *input layer* menggunakan data penjualan nota di CV. Gemilang Indonesia. Sedangkan pada *hidden layer* menggunakan aktifasi sigmoid dan pada *output layer* menggunakan aktifasi linear. Perbedaan aktifasi pada *hidden layer* dan keluaran bertujuan agar hasil peramalan tidak menghasilkan keluaran *biner*.

Untuk mengetahui model *Neural Network* yang terbaik dalam meramalkan penjualan nota CV. Gemilang Indonesia, dilakukan kombinasi percobaan antara jumlah *input layer*, fungsi aktivasi antar neuron, *hidden layer*, dan *output layer* dengan menggunakan *training set* (data pelatihan).

3.2.7. Melakukan Peramalan dengan BPNN

Peramalan dengan menggunakan BPNN terdiri dari beberapa proses yang harus dilakukan, yaitu seperti Gambar 3.2



Gaambar 3. 2. Proses Peramalan BPNN

Setelah diperoleh model neural netwok, tahapan berikutnya yaitu melakukan peramalan dengan menggunakan metode *backpropagation*. Data yang digunakan untuk peramalan yaitu data penjualan nota CV. Gemilang Indonesia. Data test digunakan untuk mengetahui keakuratan kegiatan peramalan terhadap data baru di luar data sampel.

Data set dibagi atas *test* set dan *training* set, yang akan dinormalisasi untuk menyamakan range nya. Setelah dilakukan normalisasi, selanjutnya membentuk model JST dengan inut layer,

hidden layer dan output layer. Selanjutnya menentukan parameter JST yaitu jumlah iterasi (epoch), *learning rate* dan *momentum*. Kemudian dari model-model yang telah dibentuk dilakukan proses pelatihan dan simulasi pelatihan. Tahap berikutnya melakukan denormalisasi untuk mengubah hasil pelatihan sesuai dengan kondisi aslinya. Selanjutnya menentukan model yang paling optimal untuk kemudian dilakukan peramalan.

3.2.8. Analisis Hasil Peramalan

Setelah proses peramalan, langkah selanjutnya yaitu menganalisis hasil peramalan dan menguji ketepatan hasil tersebut dengan melakukan perhitungan *error*. Metode yang digunakan untuk mengevaluasi hasil peramalan, yaitu RMSE. Dari perhitungan error tersebut akan diketahui seberapa akurat hasil peramalan penjualan nota di CV. Gemilang Indonesia.

3.2.9. Penyusunan Laporan Tugas Akhir

Tahapan terakhir adalah pembuatan laporan tugas akhir sebagai bentuk dokumentasi atas terlaksananya penelitian tugas akhir ini. Di dalam laporan tersebut mencakup :

a. Bab I Pendahuluan

Pada bab ini dijelaskan mengenai latar belakang, rumusan dan batasan masalah, tujuan dan manfaat penggerjaan tugas akhir ini.

b. Bab II Dasar Teori

Dijelaskan mengenai teori – teori yang menunjang permasalahan yang dibahas pada penelitian tugas akhir ini.

c. Bab III Metodologi

Pada bab ini dijelaskan mengenai tahapan – tahapan apa saja yang harus dilakukan dalam penggerjaan penelitian tugas akhir.

d. Bab IV Perancangan

Pada bab ini berisi rancangan penelitian, rancangan bagaimana penelitian akan dilakukan, subyek dan obyek penelitian, pemilihan obyek dan subyek penelitian, dan sebagainya.

e. Bab V implementasi

Pada bab ini berisi proses pelaksanaan penelitian, bagaimana penelitian dilakukan, penerapan strategi pelaksanaan, hambatan, dan rintangan dalam pelaksanaan, dan sebagainya.

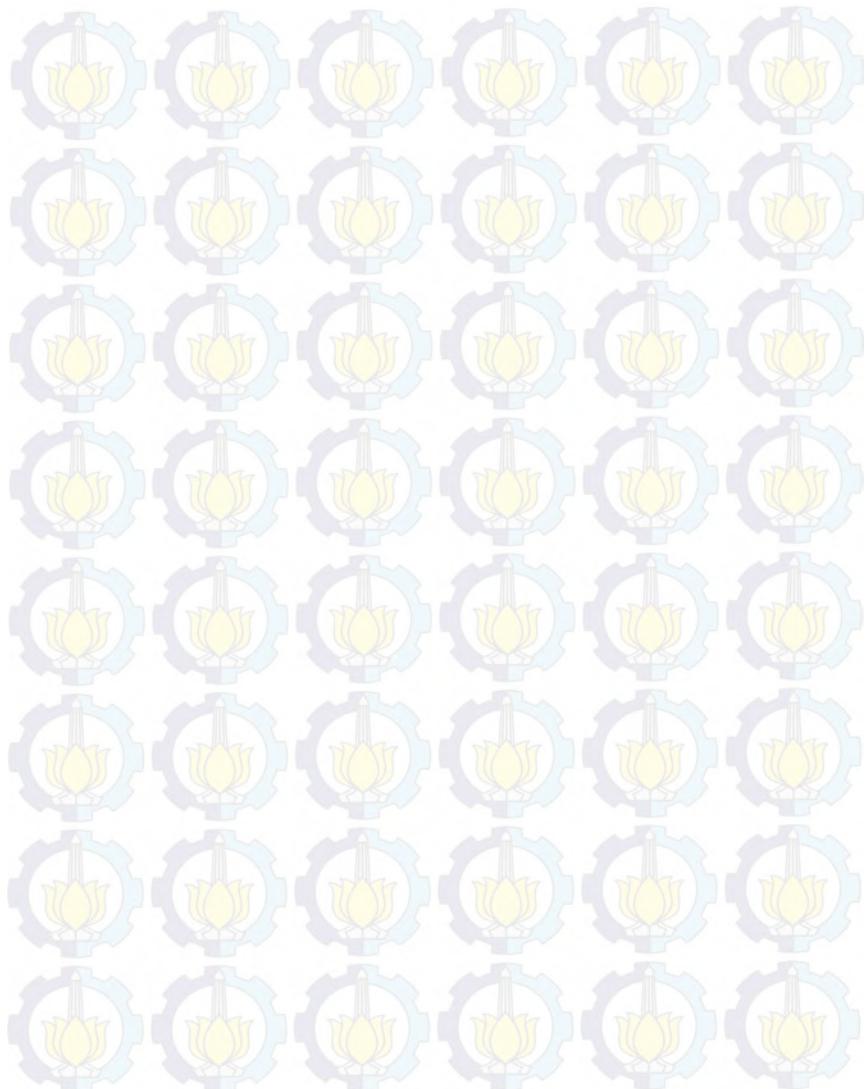
f. Bab VI Analisis dan Pembahasan

Bab yang berisi tentang pembahasan dalam penyelesaian permasalahan yang dibahas pada penggerjaan tugas akhir ini.

g. Bab VII Kesimpulan

Berisi tentang kesimpulan dan saran yang ditujukan untuk kelengkapan penyempurnaan tugas akhir ini.

Halaman ini sengaja dikosongkan.



BAB IV PERANCANGAN

Pada bab ini akan dijelaskan bagaimana rancangan dari penelitian tugas akhir yang meliputi subyek dan obyek dari penelitian, pemilihan subyek dan obyek penelitian dan bagaimana penelitian akan dilakukan.

4.1. Pengumpulan Data

Pada tahapan ini dilakukan pengumpulan data untuk penggerjaan tugas akhir. Pengumpulan data merupakan hal yang harus dilakukan untuk penelitian ini karena seluruh proses peramalan berdasarkan pada data ini. Proses pengumpuan data dilakukan dengan melakukan wawancara langsung terhadap beberapa orang dari CV. Gemilang Indonesia dan didapatkan data penjualan nota dalam bentuk laporan *hardcopy*. Selain untuk pengumpuan data wawancara dilakukan untuk memahami proses bisnis dari perusahaan dan kendala yang selama ini dihadapi perusahaan dalam mengelola produksi dan *inventory* mereka.

4.1.1. Gambaran Data Masukan

Data penjualan nota di CV. Gemilang Indonesia dalam periode harian selama Juni 2014 – Februari 2016. Penjualan nota di CV. Gemilang Indonesia tidak terjadi setiap hari, oleh karena itu data dalam periode harian selama Juni 2014 – Februari 2016 tidak terisi setiap harinya. Sehingga data penjualan periode harian tidak dapat digunakan sebagai data peramalan karena dapat membuat hasil peramalan menjadi tidak valid. Penulis memilih untuk menggunakan data dengan periode mingguan.

4.1.2. Pra-Processing Data

Pra-Processing data diperlukan untuk mengecek ada tidaknya outlier dan nilai yang kosong pada data yang akan digunakan untuk peramalan. Pada data penjualan nota di CV. Gemilang Indonesia dipilih periode mingguan untuk melakukan peramalan penjualan, namun pada minggu 57 terdapat nilai 0 (kosong) yang artinya pada

minggu tersebut tidak terdapat record penjualan). Hal ini dikarenakan pada tanggal minggu tersebut merupakan hari libur lebaran dan perusahaan diliburkan sehingga record penjualan dilaporkan pada minggu berikutnya. Untuk menghilangkan nilai kosong tersebut terdapat beberapa metode yang dapat dilakukan yaitu :

1. Mengabaikan record
2. Mengisi secara manual atau menghilangkan secara manual
3. Menggunakan mean/median
 - Mean dengan melihat rata-rata nilai pada periode yang sama sebelumnya atau dengan mengambil nilai pada periode yang sama sebelumnya
 - Median dengan mencari nilai tengah pada periode yang sama sebelumnya
4. Menggunakan nilai global
5. Mencari Min-Max

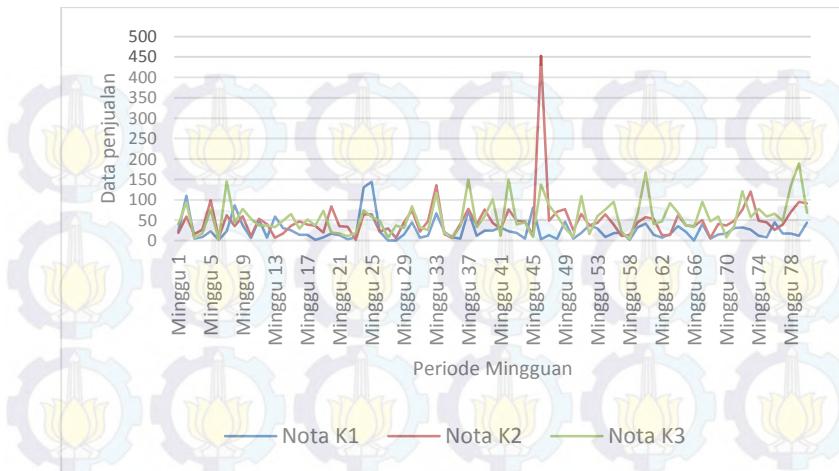
Merupakan metode normalisasi dengan melakukan transformasi linear terhadap data asli

$$Data_{new} = \frac{data_{min} \times (new_{max} - new_{min})}{(max - min) + new_{min}} \quad (16)$$
6. Z-Score

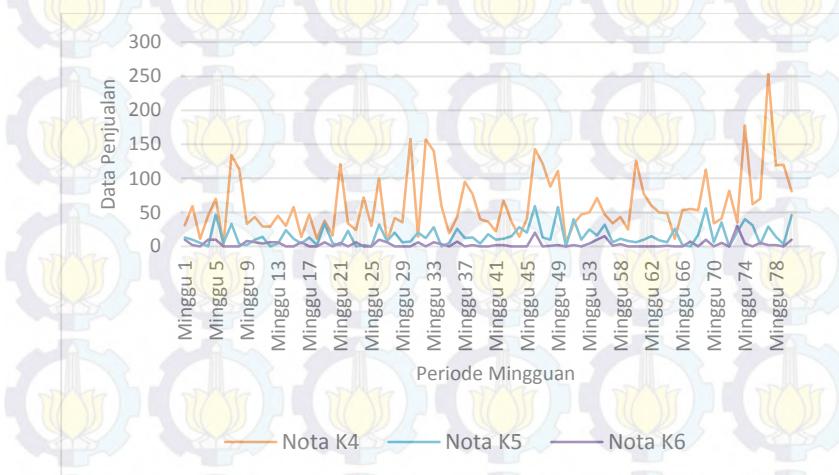
Merupakan metode normalisasi yang berdasarkan mean (nilai rata-rata) dan standard deviation dari data [22]

$$Data_{new} = \frac{data_{mean}}{std} \quad (17)$$

Dari beberapa metode yang tersedia untuk mengisi nilai kosong (missing value), maka penulis memilih menggunakan metode menghilangkan data kosong secara manual dari data penjualan nota. Hal ini dilakukan karena hanya terdapat 1 nilai saja yang kosong yaitu ada Minggu 57 merupakan tanggal 19-25 Juli 2015, sehingga jika data tersebut dihilangkan tidak akan terlalu mempengaruhi pola data. Pola data produk K1 hingga K3 dapat dilihat pada Gambar 4.1, sedangkan pola data produk K4 hingga K6 dapat dilihat pada Gambar 4.2.



Gambar 4. 1. Grafik Penjualan Nota K1, K2 dan K3



Gambar 4. 2. Grafik Penjualan Nota K4, K5 dan K6

Keterangan :

-  : Nota K1 (jenis nota dengan 1 layer)
-  : Nota K2 (jenis nota dengan 2 layer)
-  : Nota K3 (jenis nota dengan 2 layer)
-  : Nota K4 (jenis nota dengan 4 layer)
-  : Nota K5 (jenis nota dengan 5 layer)
-  : Nota K6 (jenis nota dengan 6 layer)

4.2. Model Jaringan Saraf Tiruan

Data penjualan nota di CV. Gemilang Indonesia untuk tugas akhir ini tidak dipengaruhi ataupun memiliki keterkaitan dengan variabel lain, sehingga rancangan model JST yang digunakan dalam tugas akhir ini akan berbentuk time series, yaitu dengan melihat data hingga beberapa hari ke belakang. Model JST pada tugas akhir ini, terdiri dari input layer yang berisi neuron-neuron jumlah penjualan pada masa lampau, *hidden layer* yang terdiri dari satu lapisan (layer) yang terdapat neoran-neuron yang memiliki fungsi aktifasi sigmoid bipolar dengan jumlah neuron yaitu 2 kali jumlah *input* layer, dan output layer terdiri dari satu neuron, yaitu target jumlah [23]. Model-model JST yang digunakan pada tugas akhir ini adalah sebagai berikut :

4.2.1. Model JST 1

Model JST 1 (pada Gambar 4.3) yaitu menggunakan 2 neuron pada *input* layer dengan persamaan sebagai berikut :

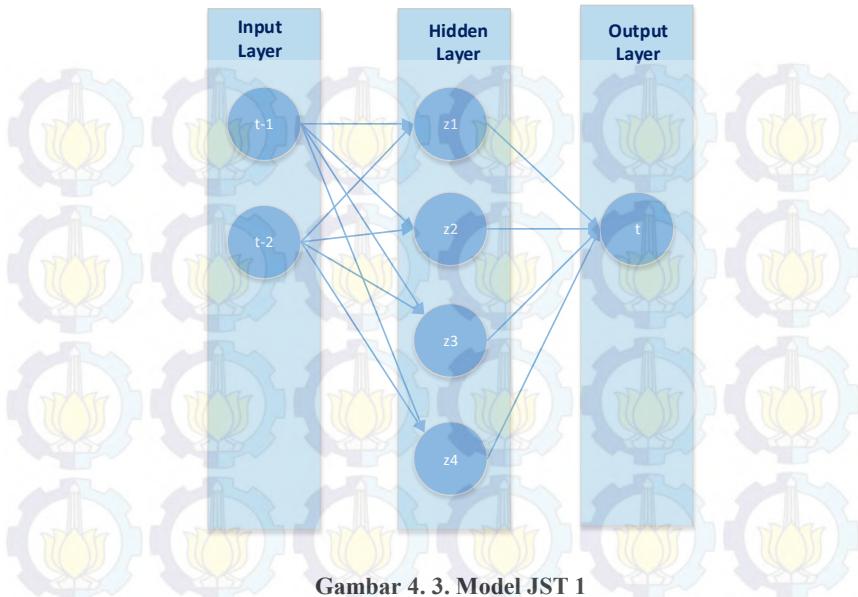
$$\begin{aligned} y(t) &= f(y_{(t-1)}, y_{(t-2)}) \\ \textit{hidden layer} &= 2 * n = 4 \text{ neuron} \end{aligned} \quad (18)$$

keterangan :

$y_{(t-1)}$: data 1 minggu sebelumnya

$y_{(t-2)}$: data 2 minggu sebelumnya

n : jumlah *input* layer, yaitu 2



Gambar 4. 3. Model JST 1

4.2.2. Model JST 2

Model JST 2 (pada Gambar 4.4) yaitu menggunakan 3 neuron pada *input layer* dengan persamaan sebagai berikut :

$$\begin{aligned} y(t) &= f(y_{(t-1)}, y_{(t-2)}, y_{(t-3)}) \\ \textit{hidden layer} &= 2 * n = 6 \textit{neuron} \end{aligned} \quad (19)$$

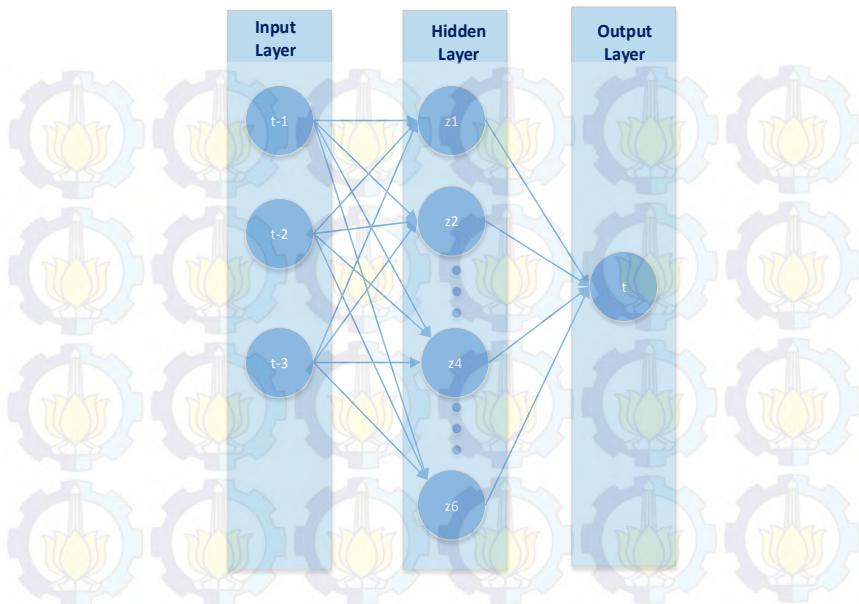
keterangan :

$y_{(t-1)}$: data 1 minggu sebelumnya

$y_{(t-2)}$: data 2 minggu sebelumnya

$y_{(t-3)}$: data 3 minggu sebelumnya

n : jumlah *input layer*, yaitu 3



Gambar 4. 4. Model JST 2

4.2.3. Model JST 3

Model JST 3 (pada Gambar 4.5) yaitu menggunakan 4 neuron pada *input layer* dengan persamaan sebagai berikut :

$$y(t) = f(y_{(t-1)}, y_{(t-2)}, y_{(t-3)}, y_{(t-4)}) \quad (20)$$

hidden layer = $2 * n = 8$ *neuron*

keterangan :

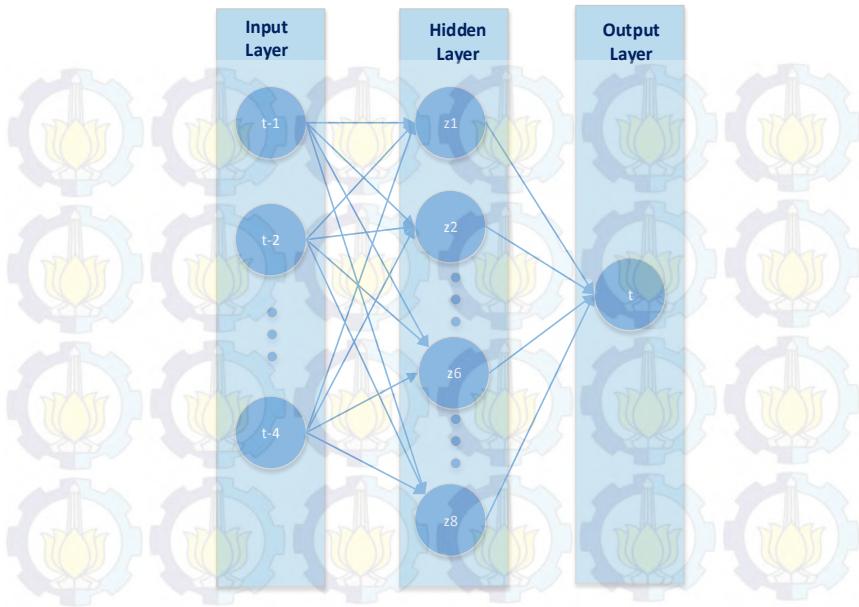
$y_{(t-1)}$: data 1 minggu sebelumnya

$y_{(t-2)}$: data 2 minggu sebelumnya

$y_{(t-3)}$: data 3 minggu sebelumnya

$y_{(t-4)}$: data 4 minggu sebelumnya

n : jumlah *input layer*, yaitu 4



Gambar 4. 5. Model JST 3

4.2.4. Model JST 4

Model JST 4 (pada Gambar 4.6) yaitu menggunakan 5 neuron pada *input layer* dengan persamaan sebagai berikut :

$$y(t) = f(y_{(t-1)}, y_{(t-2)}, y_{(t-3)}, y_{(t-4)}, y_{(t-5)}) \quad (21)$$

hidden layer = $2 * n = 10$ *neuron*

keterangan :

$y_{(t-1)}$: data 1 minggu sebelumnya

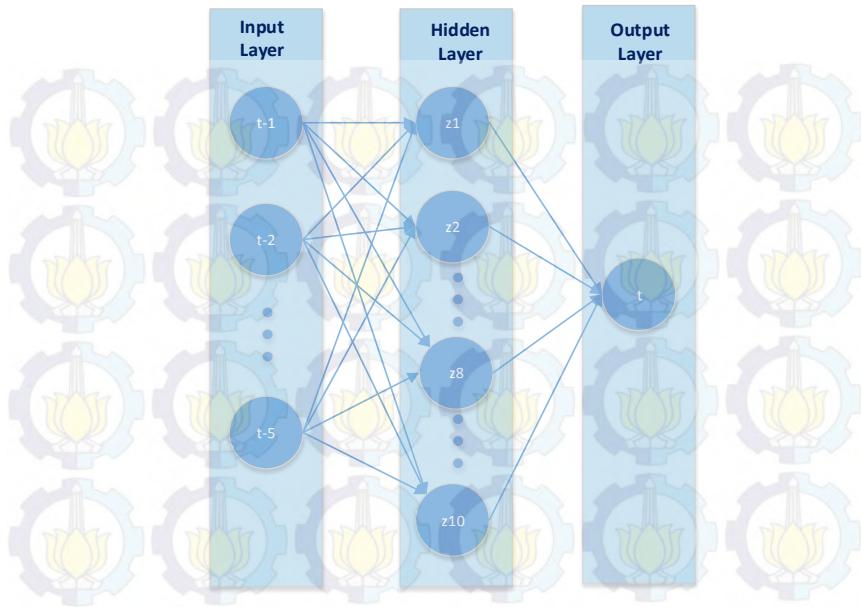
$y_{(t-2)}$: data 2 minggu sebelumnya

$y_{(t-3)}$: data 3 minggu sebelumnya

$y_{(t-4)}$: data 4 minggu sebelumnya

$y_{(t-5)}$: data 5 minggu sebelumnya

n : jumlah *input layer*, yaitu 5



Gambar 4. 6. Model JST 4

4.2.5. Model JST 5

Model JST 5 (pada Gambar 4.7) yaitu menggunakan 6 neuron pada *input layer* dengan persamaan sebagai berikut :

$$y(t) = f(y_{(t-1)}, y_{(t-2)}, y_{(t-3)}, y_{(t-4)}, y_{(t-5)}, y_{(t-6)}) \quad (22)$$

hidden layer = $2 * n = 12$ neuron

keterangan :

$y_{(t-1)}$: data 1 minggu sebelumnya

$y_{(t-2)}$: data 2 minggu sebelumnya

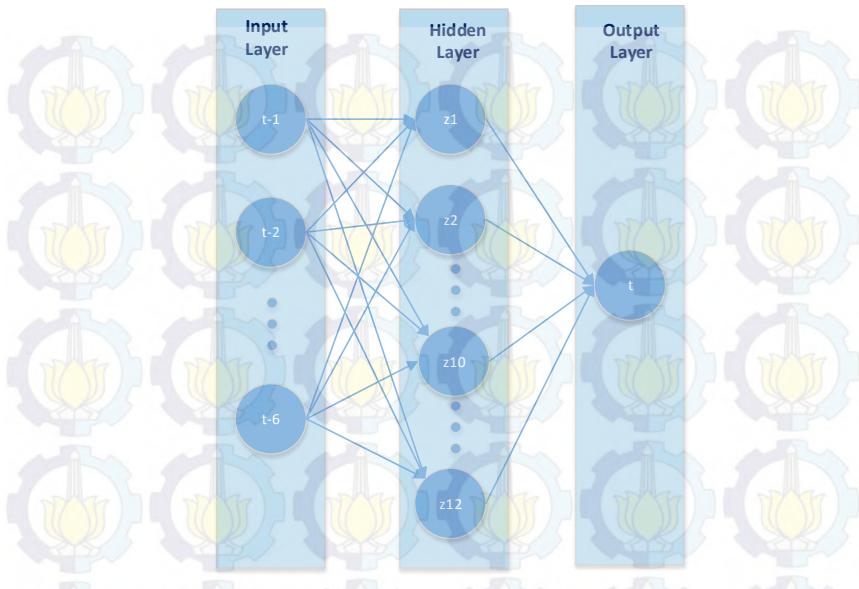
$y_{(t-3)}$: data 3 minggu sebelumnya

$y_{(t-4)}$: data 4 minggu sebelumnya

$y_{(t-5)}$: data 5 minggu sebelumnya

$y_{(t-6)}$: data 6 minggu sebelumnya

n : jumlah *input layer*, yaitu 6



Gambar 4. 7. Model JST 5

4.2.6. Model JST 6

Model JST 6 (pada Gambar 4.8) yaitu menggunakan 7 neuron pada *input layer* dengan persamaan sebagai berikut :

$$y(t) = f(y_{(t-1)}, y_{(t-2)}, \dots, y_{(t-7)}) \quad (23)$$

$$\text{hidden layer} = 2 * n = 14 \text{ neuron}$$

keterangan :

$y_{(t-1)}$: data 1 minggu sebelumnya

$y_{(t-2)}$: data 2 minggu sebelumnya

$y_{(t-3)}$: data 3 minggu sebelumnya

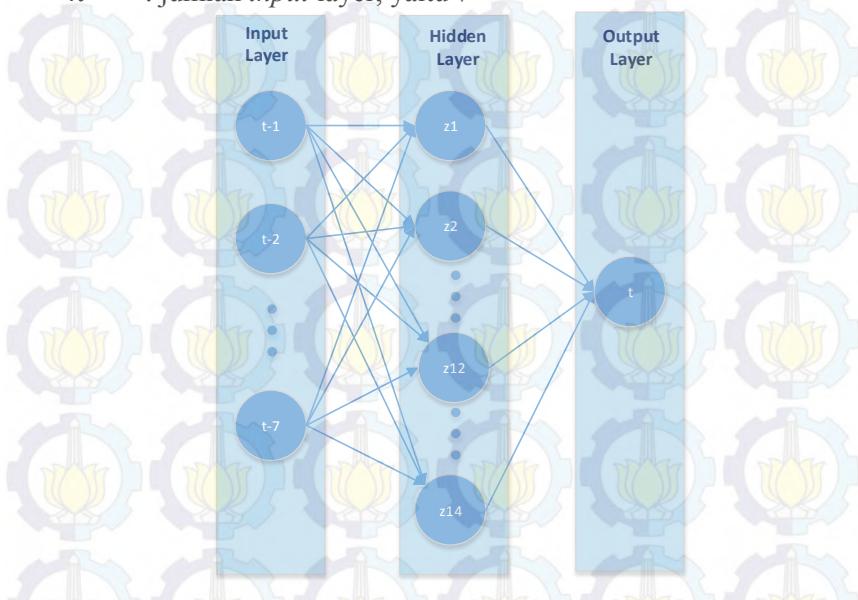
$y_{(t-4)}$: data 4 minggu sebelumnya

$y_{(t-5)}$: data 5 minggu sebelumnya

$y_{(t-6)}$: data 6 minggu sebelumnya

$y_{(t-7)}$: data 7 minggu sebelumnya

n : jumlah *input layer*, yaitu 7



Gambar 4. 8. Model JST 6

4.2.7. Model JST 7

Model JST (pada Gambar 4.9) yaitu menggunakan 8 neuron pada *input layer* dengan persamaan sebagai berikut :

$$y(t) = f(y_{(t-1)}, y_{(t-2)}, \dots, y_{(t-8)}) \quad (24)$$

$$\text{hidden layer} = 2 * n = 16 \text{ neuron}$$

keterangan :

$y_{(t-1)}$: data 1 minggu sebelumnya

$y_{(t-2)}$: data 2 minggu sebelumnya

$y_{(t-3)}$: data 3 minggu sebelumnya

$y_{(t-4)}$: data 4 minggu sebelumnya

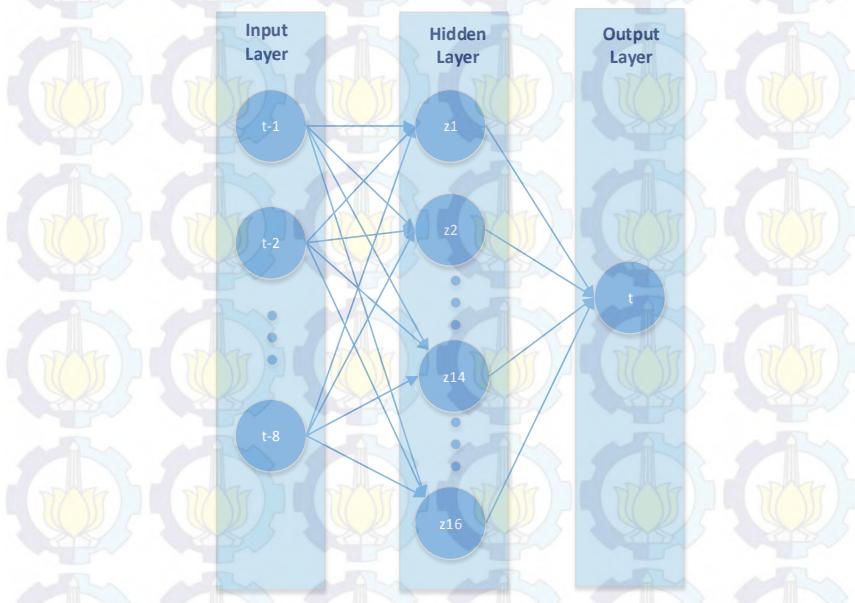
$y_{(t-5)}$: data 5 minggu sebelumnya

$y_{(t-6)}$: data 6 minggu sebelumnya

$y_{(t-7)}$: data 7 minggu sebelumnya

$y_{(t-8)}$: data 8 minggu sebelumnya

n : jumlah *input layer*, yaitu 8



Gambar 4. 9. Model JST 7

4.2.8. Model JST 8

Model JST (pada Gambar 4.10) yaitu menggunakan 8 neuron pada *input layer* dengan persamaan sebagai berikut :

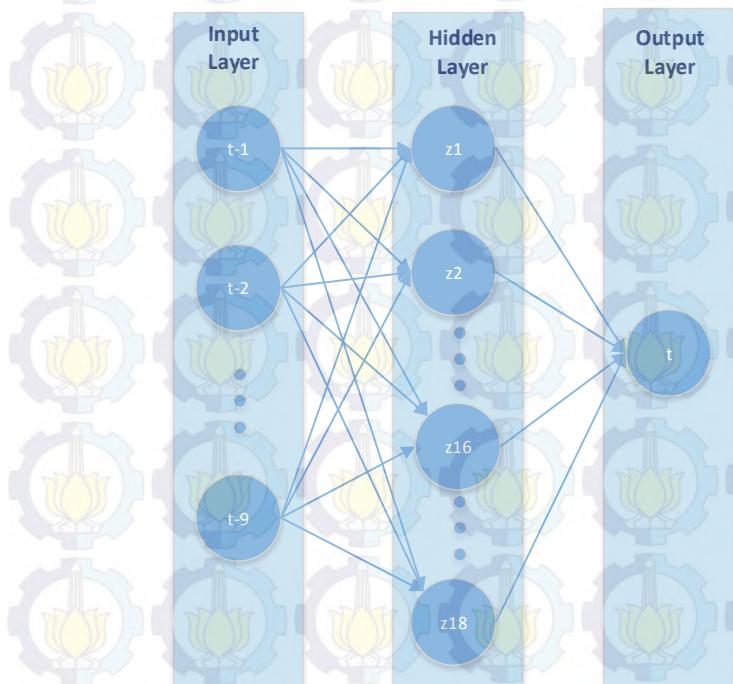
$$\begin{aligned} y(t) &= f(y_{(t-1)}, y_{(t-2)}, \dots, y_{(t-9)}) \\ \text{hidden layer} &= 2 * n = 18 \text{ neuron} \end{aligned} \quad (25)$$

keterangan :

$y_{(t-1)}$: data 1 minggu sebelumnya

$y_{(t-2)}$: data 2 minggu sebelumnya

$y_{(t-3)}$: data 3 minggu sebelumnya
 $y_{(t-4)}$: data 4 minggu sebelumnya
 $y_{(t-5)}$: data 5 minggu sebelumnya
 $y_{(t-6)}$: data 6 minggu sebelumnya
 $y_{(t-7)}$: data 7 minggu sebelumnya
 $y_{(t-8)}$: data 8 minggu sebelumnya
 $y_{(t-9)}$: data 9 minggu sebelumnya
 n : jumlah *input layer*, yaitu 9

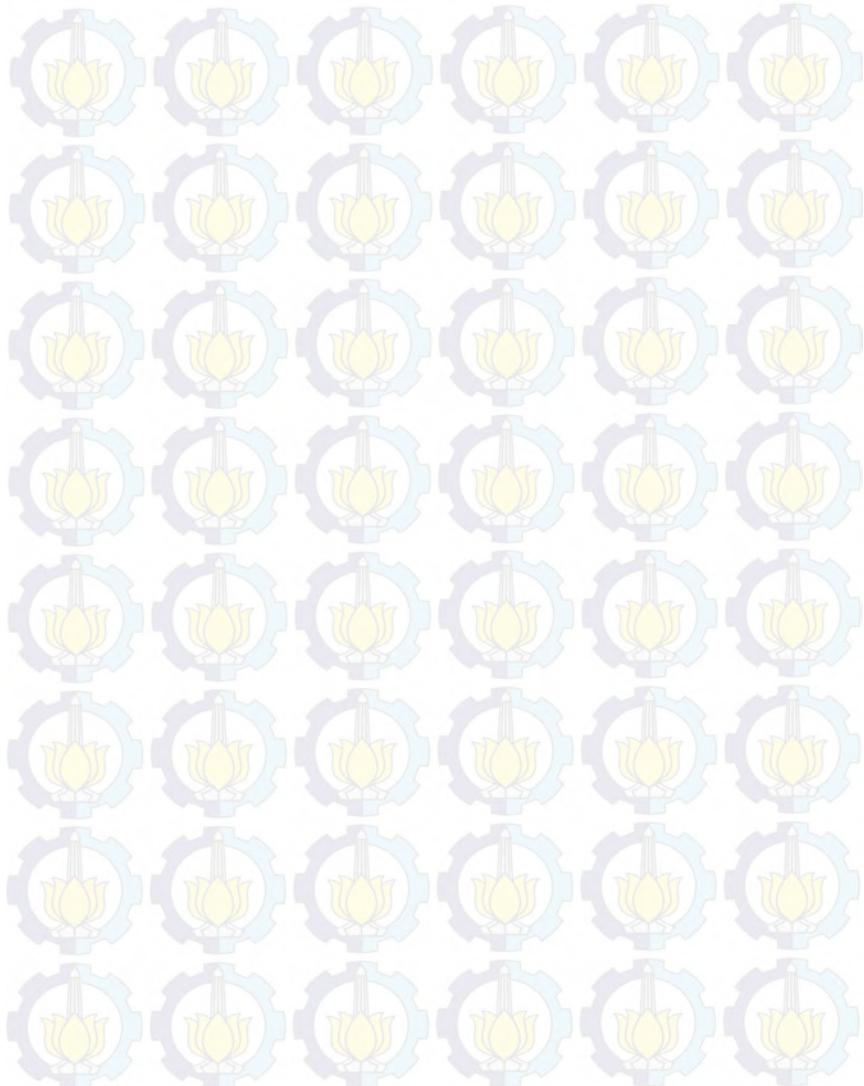


Gambar 4. 10. Model JST 8

4.2.9. Model Pada Produk

Pada tugas akhir ini penulis akan melakukan peramalan penjualan dengan menggunakan satu model produk secara Akumulasi dan enam model produk secara terpisah . model produk Akumulasi merupakan model dengan menggunakan data Akumulasi (keseluruhan) data penjualan semua produk. Sedangkan model produk terpisah yaitu model dengan menggunakan data dari enam jenis produk Di CV. Gemilang Indonesia yaitu K1,K2,K3,K4,K5 dan K6. Ketujuh model tersebut mempunyai pola-pola penjualan yang berbeda , sehingga masing-masing produk akan diramalkan dengan menggunakan model JST yang telah dirancang sebelumnya untuk mengetahui model manakah yang paling optimal .

Halaman ini sengaja dikosongkan.



BAB V IMPLEMENTASI

Pada bab ini menjelaskan mengenai proses tahap implementasi dari rancangan yang dibuat. Pada bagian ini, akan menjalankan apa yang telah dirancang pada bab sebelumnya.

5.1. Penentuan Data Masukan

Data yang akan digunakan untuk penelitian ini yaitu data mingguan pada periode Juni 2014 – Februari 2016 dengan jumlah data entri sebanyak 79 data .

Model Jaringan Saraf Tiruan (JST) mempunyai dua tahapan proses didalamnya, yaitu proses *training* dan proses *testing*. Proses *training* dilakukan untuk mengetahui pola data masukan sedangkan proses *testing* dilakukan untuk menguji parameter dari JST yang telah di dapatkan dalam proses *training*. Untuk proses *training* menggunakan 70% dari data keseluruhan yaitu sebanyak 56 data dan proses *testing* menggunakan 30% dari data keseluruhan yaitu sebanyak 23 data. Komposisi data yang digunakan ini mengacu pada buku panduan Neural Network untuk Matlab [24].

5.2. Normalisasi Data

Normalisasi data diperlukan sebelum melakukan proses *training* yang bertujuan agar nilai input dan target mempunyai range (skala) yang sama, sehingga proses *training* menjadi lebih efisien. Nilai input dan target di normalisasi sehingga berada pada *range* tertentu yang memiliki $mean = 0$ dan standar deviasi = 1 [25]. Tujuan dari normalisasi data input dan target yaitu untuk mentransformasi data supaya kestabilan taburan data dapat dicapai. Menurut Siang (2009), normalisasi berguna untuk menyesuaikan nilai data dengan range fungsi aktivasi yang digunakan dalam jaringan, selain itu normalisasi dapat digunakan untuk meningkatkan keakurasiannya dari hasil output serta memfasilitasi

proses learning dari jaringan syaraf [26]. Pada Matlab normalisasi ini dapat diimplementasikan dengan fungsi prestd, dengan syntax :

```
[pn,meanp,stdp,tn,meant,stdt] = prestd(p,t)
```

Dimana :

p = matriks input training

t = matriks target

pn = matriks input yang ternormalisasi

tn = matriks target yang ternormalisasi

meanp = rata rata pada matriks input (p)

stdp = standard deviasi pada matriks input (p)

meant = rata rata pada matriks target (t)

stdt = standard deviasi pada matriks target (t)

5.3. Pembentukan Model Jaringan Saraf Tiruan

Model jaringan saraf tiruan yang diterapkan pada tugas akhir ini adalah *multi layer perceptron* dengan satu *hidden layer*. Pembentukan jaringan pada proses training dapat dilakukan dengan menggunakan fungsi pada Matlab yaitu newff. Pada pembentukan JST dibutuhkan empat input yaitu input pertama matrix minimum dan maximum dalam vektor input yaitu pn. Input kedua adalah jumlah layer yang dibutuhkan. Input ketiga adalah fungsi aktivasi yang digunakan dalam setiap layer dan input keempat adalah fungsi aktivasi yang akan digunakan dalam proses training, seperti syntax di bawah ini :

```
net=newff(minmax(pn),[x,y],{'logsig','purelin'},'traingdx');
```

Jumlah neuron pada hidden layer [x] tergantung dari jumlah input layer seperti yang telah dijelaskan pada bab sebelumnya, sedangkan output layer [y] selalu bernilai 1. Pada penelitian tugas akhir ini neuron pada hidden layer akan di uji coba dari neuron 2 hingga neuron 16 .

Fungsi `logsig` pada layer pertama merupakan fungsi aktivasi sigmoid bipolar yang digunakan untuk mengirimkan informasi dari input layer melalui bobot ke neuron pada *hidden* layer, sehingga dapat digunakan untuk pengenalan pola. Sedangkan `purelin` merupakan fungsi aktivasi linear yang dipakai untuk menghasilkan nilai output dengan range yang sama dengan nilai inputnya yaitu berupa nilai riil sembarang. Pada input keempat fungsi aktivasi training yang digunakan adalah `traingdx`. Fungsi `traingdx` mengkombinasikan learning rate dengan momentum pada saat training. Syntax tersebut akan membangun jaringan dan sekaligus menginisialisasi nilai bobot dan bias pada jaringan [24].

5.4. Pembentukan Parameter JST

Arsitektur Jaringan Saraf Tiruan juga membutuhkan parameter. Parameter merupakan nilai-nilai yang digunakan untuk mengenali pola data. Uji coba parameter penting dilakukan untuk mengetahui nilai parameter mana yang paling optimal yang dapat digunakan pada Model yang telah ditentukan. Parameter pada *backpropagation* berupa nilai *learning rate* (lr) yang memiliki nilai antara 0 hingga 1, *momentum constant* (mc) yang bernilai antara 0.5 hingga 0.9, dan *epoch* (iterasi) biasanya bernilai antara 500 sampai 3000, namun dapat pula lebih dari itu. Dimana maksimum epochs menjadi kriteria pemberhentian pada proses pembelajaran

Rancangan Model JST pada tugas akhir ini menggunakan parameter berupa lr dengan nilai 0.1 hingga 0.9, sedangkan nilai mc yang digunakan sebesar 0.1 hingga 0.9, serta nilai iterasi yang digunakan adalah 1000. Syntax yang digunakan untuk menerapkan parameter-parameter tersebut untuk membentuk model JST adalah sebagai berikut :

```
net.trainParam.EPOCHS = a;  
net.trainParam.lr = b;  
net.trainParam.mc = c;
```

dimana

- a : diisi dengan jumlah iterasi (epoch)
- b : diisi dengan nilai learning rate (lr)
- c : diisi dengan nilai momentum (mc)

5.5. Proses Pelatihan (*Training*)

Pada proses *training* digunakan sebanyak 56 data sebagai input dan 23 data sebagai *testing*. Matriks input dan target yang digunakan adalah matriks yang telah dinormalisasi. Berikut *syntax* yang digunakan untuk melakukan training :

```
net = train(net,pn,tn);
```

dimana

- net : model jaringan saraf yang sudah dibangun
- pn : matriks input jaringan saraf yang ternormalisasi
- tn : matriks target jaringan saraf yang ternormalisasi

Syntax pelatihan tersebut akan menampilkan *toolbox Neural Network Training* yang berisikan informasi jumlah iterasi yang sedang berlangsung, waktu yang dibutuhkan untuk proses *training*, dan nilai MSE yang didapatkan dari proses *training*. Proses *training* perlu dilakukan berulang kali untuk setiap parameter yang sama karena setiap kali dijalankan bobot pada masing-masing parameter pasti berubah. Maka dari itu akan dilakukan *training* sebanyak 3 kali percobaan di setiap parameter dan kemudian dipilih performa terbaik pada proses pelatihan yang dilihat berdasarkan nilai MAPE terkecil . Hasil pelatihan menunjukkan perbedaan nilai MAPE pada setiap neuoron dan percobaan.

5.5.1. Simulasi Pelatihan (*Training*)

Proses simulasi dilakukan setelah pelatihan pada jaringan yang dibangun . Simulasi bertujuan untuk menghasilkan output jaringan

dari model jaringan dan input matrik. Syntax yang digunakan dalam proses simulasi adalah :

$$s = \text{sim}(\text{net}, \text{pn})$$

dimana

s : output jaringan saraf

net : model jaringan saraf

pn = matriks input jaringan saraf yang ternormalisasi

5.5.2. Denormalisasi pada Pelatihan (Training)

Output yang dihasilkan pada proses simulasi *training* perlu diubah ke bentuk denormalisasi, proses ini disebut *Postprocessing*. Proses *postprocessing* ini sering dianggap proses koreksi. Menurut Kusumadewi (2004), fungsi *poststd* mampu membawa output jaringan sesuai dengan kondisi aslinya sehingga tidak berpengaruh pada hasil selanjutnya [27]. Jika *prestd* digunakan untuk mengubah *range* nilai input dan target, maka nilai output akan menghasilkan rata rata sama dengan nol dan standard deviasi sama dengan satu. Oleh karena itu diperlukan fungsi *post* untuk mengembalikan nilai sesuai dengan data aslinya. Syntax yang dapat digunakan untuk mengembalikan nilai output dari proses simulasi ke nilai aslinya:

$$d = \text{poststd}(s, \text{meant}, \text{stdt})$$

dimana

d : nilai output denormalisasi training

s : nilai output simulasi

meant : rata rata matriks target asli (t)

stdt : standar deviasi pada matriks target asli (t).

5.6. Proses Pengujian (Testing)

Setelah melakukan proses pelatihan , tahap selanjutnya adalah menyiapkan data testing. Data testing di normalisasi terlebih

dahulu dengan fungsi `trastd`. Normalisasi pada data testing ini menggunakan nilai *mean* dan standar deviasi dari proses sebelumnya. Perintah `trastd` melakukan *pre-processing* pada data *input* pada proses *training* (*p*) dengan nilai rata-rata dari data *input* pada proses *training* (*meant*) dan standar deviasi data *input* pada proses *training* (*stdt*). Syntax untuk normalisasi data testing adalah sebagai berikut :

$$qn = \text{trastd}(q, meant, stdt)$$

dimana

qn : data testing ternormalisasi

q : data testing

meant : mean dari proses normalisasi data pelatihan

stdt : nilai standar deviasi dari proses normalisasi data pelatihan

5.6.1. Simulasi Pengujian (*Testing*)

Data testing yang sudah ternormalisasi di simulasi dengan perintah `sim` menggunakan model jaringan pada proses *training* untuk menghasilkan output yang diinginkan. Syntax untuk proses *testing* adalah sebagai berikut :

$$sq = \text{sim}(net, qn)$$

dimana

sq : data output hasil *testing*

net : jaringan pada proses *training*

qn : data testing

5.6.2. Denormalisasi Data Pengujian (Data Testing)

Tahapan denormalisasi untuk data *testing* yang di normalisasi yaitu dengan menggunakan *syntax* berikut:

$$dq = \text{poststd}(sq, meant, stdt)$$

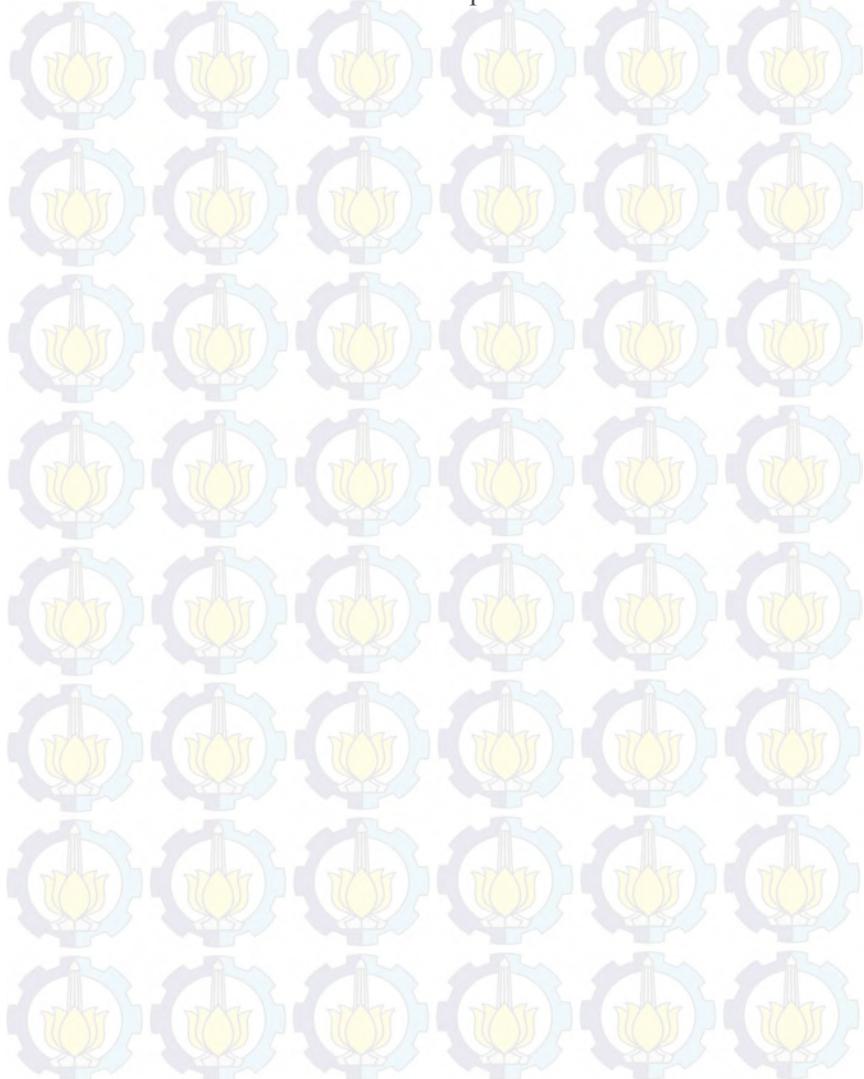
dimana

dq : data output *testing* yang ternormalisasi

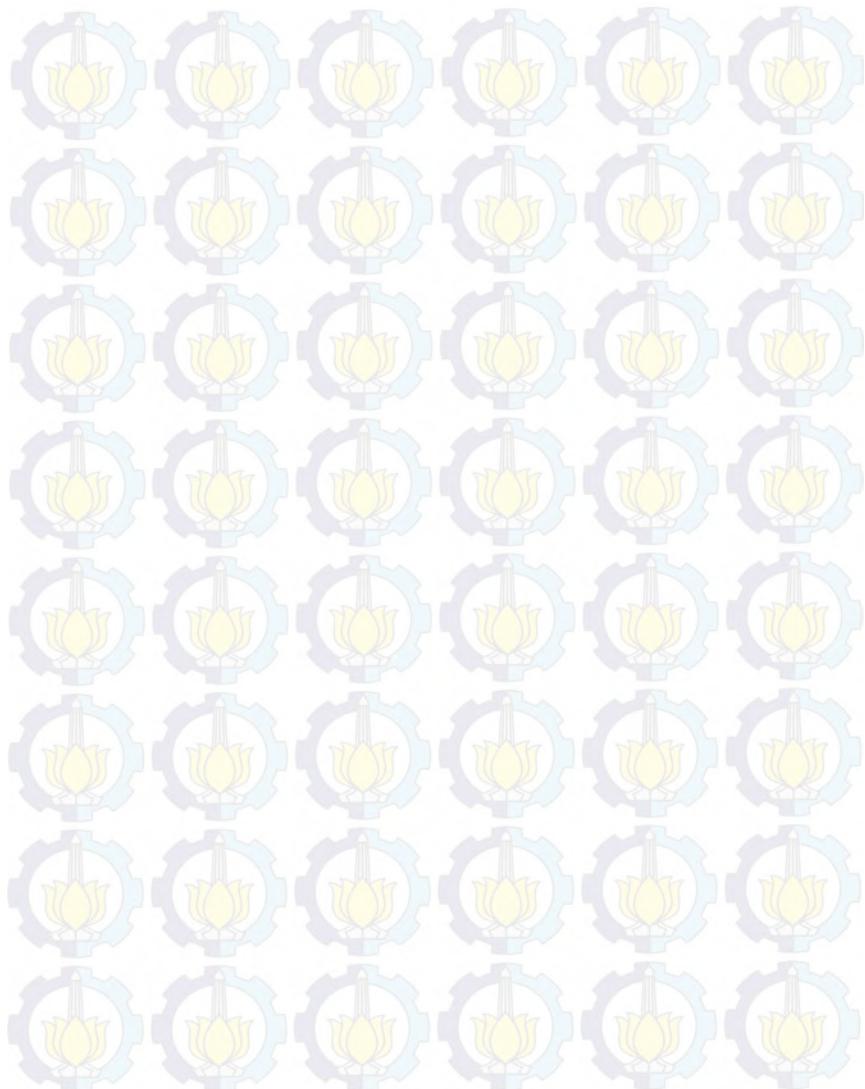
sq : data output hasil *testing*

meant : nilai mean dari proses normalisasi

stdt : nilai standar deviasi dari proses normalisasi



Halaman ini sengaja dikosongkan.



BAB VI

HASIL DAN PEMBAHASAN

Pada bab ini penulis akan menjelaskan hasil dan pembahasan dari perancangan dan implementasi peramalan penjualan nota CV. Gemilang Indonesia menggunakan Artificial Neural Network. Bab ini meliputi hasil eksperimen, Model terbaik, Hasil uji coba penentuan parameter optimal dan hasil peramalan penjualan nota.

6.1. Hasil Normalisasi

Normalisasi yang dilakukan sebelum melakukan proses *training* menghasilkan matriks *input* dan matriks target yang ternormalisasi, nilai *mean* pada matriks *input* (*meanp*) dan target (*meant*), dan nilai standar deviasi pada matriks *input* (*stdp*) dan target (*stdt*) yang merupakan hasil penskalaan data *training* penjualan nota CV. Gemilang Indonesia. Hasil normalisasi pada tiap model JST yang digunakan adalah sebagai berikut.

6.1.1. Normalisasi Produk Akumalasi

Normalisasi Produk Akumalasi dilakukan pada semua model JST yang telah dirancang sebalumnya yaitu sebagai berikut :

6.1.1.1. Normalisasi Model KUM1 (JST 1)

Pada model JST 1 menghasilkan nilai *meanp*, *meant*, *stdp*, *stdt*, dan matriks normalisasi yang dapat dilihat pada Tabel 6.1. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, p_n menunjukkan matriks input yang ternormalisasi dan t_n menunjukkan matriks target yang ternormalisasi.

Tabel 6. 1. Normalisasi Model KUM1

Matrik		Minggu 3	Minggu 4	...	Minggu 56	mean	std
p	t-1	375	46	...	246	211.6481	136.6983
	t-2	147	375	...	257	209.8148	136.8926
t		46	108	...	94	206.4444	135.7075
pn	t-1	1.194981	-1.211178	...	0.251297		
	t-2	-0.45886	1.206677	...	0.344688		
tn		-1.18228	-0.72542	...	-0.82858		

6.1.1.2. Normalisasi Model KUM2 (JST 2)

Pada model JST 2 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.1. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi

Tabel 6.1. Normalisasi Model KUM2

Matrik s		Minggu 4	Minggu 5	...	Minggu 56	mean	std
p	t-1	46	108	...	246	208.566	136.099
	t-2	375	46	...	257	211	137.9226
	t-3	147	375	...	216	208.9245	138.0447
t		108	371	...	94	209.4717	135.1528
pn	t-1	-1.19447	-0.73892	...	0.275049		
	t-2	1.189072	-1.19632	...	0.33352		
	t-3	-0.44858	1.203056	...	0.051255		
tn		-0.75079	1.195153	...	-0.85438		

6.1.1.3. Normalisasi Model KUM3 (JST 3)

Pada model JST 3 menghasilkan nilai mean_p , meant , std_p , stdt , dan matriks normalisasi yang dapat dilihat pada Tabel 6.2. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.2. Normalisasi Model KUM3

Matriks		Minggu 5	Minggu 6	...	Minggu 56	mean	std
P	t-1	108	371	...	246	211.6923	135.4916
	t-2	46	108	...	257	207.8462	137.3249
	t-3	375	46	...	216	210.1154	139.1164
	t-4	147	375	...	150	208.7885	139.3879
t		371	17	...	94	211.4231	135.7154
pn	t-1	-0.7653	1.175775	...	0.253209		
	t-2	-1.17856	-0.72708	...	0.357938		
	t-3	1.185228	-1.1797	...	0.0423		
	t-4	-0.44328	1.192439	...	-0.42176		
tn		1.17582	-1.43258	...	-0.86522		

6.1.1.4. Normalisasi Model KUM4 (JST 4)

Pada model JST 4 menghasilkan nilai mean_p , meant , std_p , stdt , dan matriks normalisasi yang dapat dilihat pada Tabel 6.3. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.3. Normalisasi Model KUM4

Matrik		Minggu 6	Minggu 7	...	Minggu 56	mean	std
p	t-1	371	17	...	246	213.7255	136.0363
	t-2	108	371	...	257	211.0196	136.7521
	t-3	46	108	...	216	206.8824	138.5136
	t-4	375	46	...	150	210	140.4981
	t-5	147	375	...	274	209.9412	140.5244
t		17	398	...	94	208.2941	135.1583
pn	t-1	1.156121	-1.44612	...	0.237249		
	t-2	-0.75333	1.169857	...	0.336232		
	t-3	-1.16149	-0.71388	...	0.065825		
	t-4	1.174393	-1.16728	...	-0.42705		
	t-5	-0.4479	1.174592	...	0.455856		
tn		-1.41533	1.403583	...	-0.84563		

6.1.1.5. Normalisasi Model KUM5 (JST 5)

Pada model JST 5 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.4. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.4. Normalisasi Model KUM5

Matriks		Minggu 7	Minggu 8	...	Minggu 56	mean	std
p	t-1	17	398	...	246	210.58	135.531
	t-2	371	17	...	257	213.08	137.3385
	t-3	108	371	...	216	210.1	137.9811
	t-4	46	108	...	150	206.7	139.9137
	t-5	375	46	...	274	211.2	141.6603
	t-6	147	375	...	48	208.66	141.6498
t		398	284	...	94	212.12	133.7118
pn	t-1	-1.42831	1.382857	...	0.261342		
	t-2	1.149859	-1.42771	...	0.319794		
	t-3	-0.73996	1.166102	...	0.042759		
	t-4	-1.14857	-0.70543	...	-0.40525		
	t-5	1.156287	-1.16617	...	0.443314		
	t-6	-0.4353	1.174304	...	-1.13421		
tn		1.390154	0.537574	...	-0.88339		

6.1.1.6. Normalisasi Model KUM6 (JST 6)

Pada model JST 6 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.5. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.5. Normalisasi Model KUM6

Matriks		Minggu 8	Minggu 9	...	Minggu 56	mean	std
p	t-1	398	284	...	246	214.5306	133.9952
	t-2	17	398	...	257	209.8571	136.8381
	t-3	371	17	...	216	212.1837	138.6139
	t-4	108	371	...	150	209.9796	139.4083
	t-5	46	108	...	274	207.8571	141.1217
	t-6	375	46	...	48	209.9184	142.8351
	t-7	147	375	...	328	211.9388	141.1877
t		284	222	...	94	208.3265	132.3511
pn	t-1	1.369224	0.518447	...	0.234855		
	t-2	-1.40938	1.37493	...	0.344516		
	t-3	1.145746	-1.40811	...	0.027532		
	t-4	-0.73152	1.155027	...	-0.43024		
	t-5	-1.14693	-0.7076	...	0.468694		
	t-6	1.15575	-1.14761	...	-1.1336		
	t-7	-0.45995	1.154925	...	0.822035		
tn		0.571763	0.103312	...	-0.86381		

6.1.1.7. Normalisasi Model KUM7 (JST 7)

Pada model JST 7 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.6. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.6. Normalisasi Model KUM7

Matriks	Minggu 9	Minggu 10	...	Minggu 56	mean	std
p	t-1	284	222	...	246	210.7083
	t-2	398	284	...	257	213.875
	t-3	17	398	...	216	208.875
	t-4	371	17	...	150	212.1042
	t-5	108	371	...	274	211.2292
	t-6	46	108	...	48	206.4792
	t-7	375	46	...	328	213.2917
	t-8	147	375	...	235	209.5208
t	222	132	...	94	206.75	133.2859
pn	t-1	0.552369	0.085101	...	0.265979	
	t-2	1.360526	0.518164	...	0.318657	
	t-3	-1.38928	1.369364	...	0.051589	
	t-4	1.134325	-1.39281	...	-0.44335	
	t-5	-0.73417	1.136302	...	0.446431	
	t-6	-1.1279	-0.69214	...	-1.11384	
	t-7	1.135907	-1.17513	...	0.80576	
	t-8	-0.44137	1.168202	...	0.17987	
tn	0.114416	-0.56082	...	-0.84593		

6.1.1.8. Normalisasi Model KUM8 (JST 8)

Pada model JST 8 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.7. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.7. Normalisasi Model KUM8

Matriks		Minggu 10	Minggu 11	...	Minggu 56	mean	std
p	t-1	222	132	...	246	209.1489	133.6753
	t-2	284	222	...	257	209.9574	134.0175
	t-3	398	284	...	216	212.9574	136.6458
	t-4	17	398	...	150	208.7234	139.6006
	t-5	371	17	...	274	213.4255	141.2914
	t-6	108	371	...	48	209.8936	141.8118
	t-7	46	108	...	328	209.8511	141.868
	t-8	375	46	...	235	210.8511	142.8809
	t-9	147	375	...	288	208.9787	143.1339
t		132	199	...	94	206.4255	134.7077
pn	t-1	0.096136	-0.57714	...	0.275676		
	t-2	0.552484	0.089858	...	0.351018		
	t-3	1.354176	0.519903	...	0.022266		
	t-4	-1.37337	1.355843	...	-0.42065		
	t-5	1.115245	-1.39022	...	0.42872		
	t-6	-0.71848	1.136008	...	-1.14156		
	t-7	-1.15495	-0.71793	...	0.832809		
	t-8	1.148851	-1.15377	...	0.169014		
	t-9	-0.43301	1.159902	...	0.552079		
tn		-0.5525	-0.05512	...	-0.83459		

6.1.2. Normalisasi Produk K1 (Nota 1 Layer)

Normalisasi Produk Nota 1 Layer atau K1 dilakukan pada semua model JST yang telah dirancang sebalumnya

6.1.2.1. Normalisasi Model K1M1 (JST 1)

Pada model JST 1 menghasilkan nilai mean_p , meant , std_p , stdt , dan matriks normalisasi yang dapat dilihat pada Tabel 6.8. Dengan

p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.8. Normalisasi Model K1M1

Matriks		Minggu 3	Minggu 4	...	Minggu 56	mean	std
p	t-1	110	5	...	18	27.94444	32.19599
	t-2	23	110	...	9	28.03704	32.17403
t		5	9	...	20	26.27778	30.13142
pn	t-1	2.548627	-0.71265	...	-0.30887		
	t-2	-0.15656	2.547488	...	-0.59169		
tn		-0.70617	-0.57341	...	-0.20835		

6.1.2.2. Normalisasi Model K1M2 (JST 2)

Pada model JST 2 menghasilkan nilai $mean_p$, $mean_t$, std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.9. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.9. Normalisasi Model K1M2

Matriks		Minggu 4	Minggu 5	...	Minggu 56	mean	std
p	t-1	5	9	...	18	26.39623	30.40707
	t-2	110	5	...	9	28.13208	32.47427
	t-3	23	110	...	30	28.39623	32.37244
t		9	23	...	20	26.67925	30.27361
pn	t-1	-0.70366	-0.57211	...	-0.27613		
	t-2	2.521009	-0.71232	...	-0.58915		
	t-3	-0.16669	2.52078	...	0.049541		
tn		-0.58398	-0.12153	...	-0.22063		

6.1.2.3. Normalisasi Model K1M3 (JST 3)

Pada model JST 3 menghasilkan nilai mean_p , meant , std_p , stdt , dan matriks normalisasi yang dapat dilihat pada Tabel 6.10. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.10. Normalisasi Model K1M3

Matriks		Minggu 5	Minggu 6	...	Minggu 56	mean	std
p	t-1	9	23	...	18	26.80769	30.55438
	t-2	5	9	...	9	26.55769	30.68078
	t-3	110	5	...	30	28.5	32.67937
	t-4	23	110	...	38	28.36538	32.68749
t		23	2	...	20	27.01923	30.46663
pn	t-1	-0.58282	-0.12462	...	-0.28826		
	t-2	-0.70264	-0.57227	...	-0.57227		
	t-3	2.493928	-0.71911	...	0.045901		
	t-4	-0.16414	2.497427	...	0.294749		
tn		-0.13192	-0.8212	...	-0.23039		

6.1.2.4. Normalisasi Model K1M4 (JST 4)

Pada model JST 4 menghasilkan nilai mean_p , meant , std_p , stdt , dan matriks normalisasi yang dapat dilihat pada Tabel 6.11. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.11. Normalisasi Model K1M4

Matriks		Minggu 6	Minggu 7	...	Minggu 56	mean	std
p	t-1	23	2	...	18	27.15686	30.75345
	t-2	9	23	...	9	26.98039	30.83277
	t-3	5	9	...	30	26.90196	30.88447
	t-4	110	5	...	38	28.47059	33.00385
	t-5	23	110	...	19	28.17647	32.98406
t		2	23	...	20	27.09804	30.76443
pn	t-1	-0.13517	-0.81802	...	-0.29775		
	t-2	-0.58316	-0.1291	...	-0.58316		
	t-3	-0.70916	-0.57964	...	0.100311		
	t-4	2.4703	-0.71115	...	0.288736		
	t-5	-0.15694	2.480699	...	-0.27821		
tn		-0.81581	-0.13321	...	-0.23072		

6.1.2.5. Normalisasi Model K1M5 (JST 5)

Pada model JST 5 menghasilkan nilai mean_p, mean_t, std_p, std_t, dan matriks normalisasi yang dapat dilihat pada Tabel 6.12. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.12. Normalisasi Model K1M5

Matriks		Minggu 7	Minggu 8	...	Minggu 56	mean	std
p	t-1	2	23	...	18	27.24	31.05989
	t-2	23	2	...	9	27.34	31.03757
	t-3	9	23	...	30	27.34	31.03757
	t-4	5	9	...	38	26.84	31.19482
	t-5	110	5	...	19	28.28	33.31056
	t-6	23	110	...	5	28.36	33.29262
t		23	86	...	20	27.6	30.86508
pn	t-1	-0.81262	-0.13651	...	-0.29749		
	t-2	-0.13983	-0.81643	...	-0.5909		
	t-3	-0.5909	-0.13983	...	0.085703		
	t-4	-0.70012	-0.57189	...	0.357752		
	t-5	2.453276	-0.69888	...	-0.27859		
	t-6	-0.161	2.452195	...	-0.70166		
tn		-0.14904	1.892106	...	-0.24623		

6.1.2.6. Normalisasi Model K1M6 (JST 6)

Pada model JST 6 menghasilkan nilai mean_p , meant , std_p , stdt , dan matriks normalisasi yang dapat dilihat pada Tabel 6.13. Normalisasi Model K1M6. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.13. Normalisasi Model K1M6

Matriks		Minggu 8	Minggu 9	...	Minggu 56	mean	std
p	t-1	23	86	...	18	27.7551	31.16524
	t-2	2	23	...	9	27.42857	31.35283
	t-3	23	2	...	30	27.71429	31.245
	t-4	9	23	...	38	27.28571	31.35682
	t-5	5	9	...	19	26.61224	31.47606
	t-6	110	5	...	5	28.46939	33.62855
	t-7	23	110	...	46	28.83673	33.46475
t		86	38	...	20	27.69388	31.17772
pn	t-1	-0.15258	1.868906	...	-0.31301		
	t-2	-0.81105	-0.14125	...	-0.58778		
	t-3	-0.15088	-0.82299	...	0.073155		
	t-4	-0.58315	-0.13668	...	0.341689		
	t-5	-0.68662	-0.55954	...	-0.24184		
	t-6	2.424446	-0.6979	...	-0.6979		
	t-7	-0.17441	2.425336	...	0.512876		
tn		1.870121	0.330561	...	-0.24677		

6.1.3. Normalisasi Produk K2 (Nota 2 Layer)

Normalisasi Produk Nota 2 Layer atau K2 dilakukan pada semua model JST yang telah dirancang sebelumnya.

6.1.3.1. Normalisasi Model K2M1 (JST 1)

Pada model JST 1 menghasilkan nilai mean_p , meant , std_p , stdt , dan matriks normalisasi yang dapat dilihat pada Tabel 6.14. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi

Tabel 6.14. Normalisasi Model K2M1

Matriks		Minggu 3	Minggu 4	...	Minggu 56	mean	std
p	t-1	59	16	...	39	51.33333	61.57401
	t-2	19	59	...	64	50.96296	61.70959
t		16	27	...	11	50.44444	61.80727
pn	t-1	0.124511	-0.57384	...	-0.2003		
	t-2	-0.51796	0.13024	...	0.211264		
tn		-0.55729	-0.37932	...	-0.63818		

6.1.3.2. Normalisasi Model K2M2 (JST 2)

Pada model JST 2 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.15. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.15. Normalisasi Model K2M2

Matriks		Minggu 4	Minggu 5	...	Minggu 56	mean	std
p	t-1	16	27	...	39	51.18868	62.15398
	t-2	59	16	...	64	51.56604	62.13927
	t-3	19	59	...	43	50.71698	62.2734
t		27	99	...	11	51.09434	62.21219
pn	t-1	-0.56615	-0.38917	...	-0.1961		
	t-2	0.119634	-0.57236	...	0.200098		
	t-3	-0.50932	0.133011	...	-0.12392		
tn		-0.38729	0.770037	...	-0.64448		

6.1.3.3. Normalisasi Model K2M3 (JST 3)

Pada model JST 3 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat Tabel 6.16. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks

target, p_n menunjukkan matriks input yang ternormalisasi dan t_n menunjukkan matriks target yang ternormalisasi

Tabel 6.16. Normalisasi Model K2M3

Matriks		Minggu 5	Minggu 6	...	Minggu 56	mean	std
p	t-1	27	99	...	39	51.86538	62.56292
	t-2	16	27	...	64	51.42308	62.73672
	t-3	59	16	...	43	51.32692	62.72089
	t-4	19	59	...	38	50.86538	62.87149
t		99	7	...	11	51.55769	62.72674
pn	t-1	-0.39745	0.753395	...	-0.20564		
	t-2	-0.56463	-0.38929	...	0.200471		
	t-3	0.122337	-0.56324	...	-0.13276		
	t-4	-0.50683	0.129385	...	-0.20463		
tn		0.756333	-0.71035	...	-0.64658		

6.1.3.4. Normalisasi Model K2M4 (JST 4)

Pada model JST 4 menghasilkan nilai $mean_p$, $mean_t$, std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.17. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, p_n menunjukkan matriks input yang ternormalisasi dan t_n menunjukkan matriks target yang ternormalisasi.

Tabel 6.17. Normalisasi Model K2M4

Matriks		Minggu 6	Minggu 7	...	Minggu 56	mean	std
p	t-1	99	7	...	39	52.35294	63.0856
	t-2	27	99	...	64	52.11765	63.15874
	t-3	16	27	...	43	51.17647	63.33552
	t-4	59	16	...	38	51.4902	63.33384
	t-5	19	59	...	65	51.11765	63.47051
t		7	62	...	11	50.62745	62.98761
pn	t-1	0.739425	-0.71891	...	-0.21166		
	t-2	-0.39769	0.742294	...	0.188135		
	t-3	-0.5554	-0.38172	...	-0.1291		
	t-4	0.118575	-0.56037	...	-0.213		
	t-5	-0.50602	0.124189	...	0.218721		
tn		-0.69264	0.180552	...	-0.62913		

6.1.3.5. Normalisasi Model K2M5 (JST 5)

Pada model JST 5 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.18. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.18. Normalisasi Model K2M5

Matriks		Minggu 7	Minggu 8	...	Minggu 56	mean	std
p	t-1	7	62	...	39	51.42	63.36969
	t-2	99	7	...	64	52.62	63.69695
	t-3	27	99	...	43	51.88	63.77692
	t-4	16	27	...	38	51.34	63.96766
	t-5	59	16	...	65	51.76	63.94722
	t-6	19	59	...	25	50.84	64.08361
t		62	35	...	11	51.5	63.31497
pn	t-1	-0.70097	0.166957	...	-0.19599		
	t-2	0.728135	-0.7162	...	0.178658		
	t-3	-0.39011	0.738825	...	-0.13924		
	t-4	-0.55247	-0.3805	...	-0.20854		
	t-5	0.113218	-0.55921	...	0.207046		
	t-6	-0.49685	0.127334	...	-0.40322		
tn		0.165838	-0.2606	...	-0.63966		

6.1.3.6. Normalisasi Model K2M6 (JST 6)

Pada model JST 6 menghasilkan nilai mean_p , meant , std_p , stdt , dan matriks normalisasi yang dapat dilihat pada Tabel 6.19. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.19. Normalisasi Model K2M6

Matriks		Minggu 8	Minggu 9	...	Minggu 56	mean	std
p	t-1	62	35	...	39	52.32653	63.69798
	t-2	7	62	...	64	51.67347	64.00078
	t-3	99	7	...	43	52.38776	64.33565
	t-4	27	99	...	38	52.06122	64.42483
	t-5	16	27	...	65	51.61224	64.60128
	t-6	59	16	...	25	51.4898	64.58106
	t-7	19	59	...	77	51.36735	64.638
t		35	60	...	11	51.28571	63.95278
pn	t-1	0.151865	-0.27201	...	-0.20921		
	t-2	-0.69801	0.16135	...	0.1926		
	t-3	0.724517	-0.70548	...	-0.14592		
	t-4	-0.389	0.728582	...	-0.21826		
	t-5	-0.55126	-0.38099	...	0.207237		
	t-6	0.116291	-0.54954	...	-0.41018		
	t-7	-0.50075	0.118083	...	0.396557		
tn		-0.25465	0.136261	...	-0.62993		

6.1.4. Normalisasi Produk K3 (Nota 3 Layer)

Normalisasi Produk Nota 3 Layer atau K3 dilakukan pada semua model JST yang telah dirancang sebelumnya.

6.1.4.1. Normalisasi Model K3M1 (JST 1)

Pada model JST 1 menghasilkan nilai mean_p , meant , std_p , std_t , dan matriks normalisasi yang dapat dilihat Tabel 6.20. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, p_n menunjukkan matriks input yang ternormalisasi dan t_n menunjukkan matriks target yang ternormalisasi.

Tabel 6.20. Normalisasi Model K3M1

Matriks		Minggu 3	Minggu 4	...	Minggu 56	mean	std
p	t-1	93	7	...	95	52.7963	39.11009
	t-2	40	93	...	76	51.77778	38.70433
t		7	17	...	20	51.44444	38.95555
p_n	t-1	1.027962	-1.17096	...	1.0791		
	t-2	-0.3043	1.065055	...	0.625827		
t_n		-1.1409	-0.8842	...	-0.80719		

6.1.4.2. Normalisasi Model K3M2 (JST 2)

Pada model JST 2 menghasilkan nilai mean_p , meant , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.21. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, p_n menunjukkan matriks input yang ternormalisasi dan t_n menunjukkan matriks target yang ternormalisasi.

Tabel 6.21. Normalisasi Model K3M2

Matriks		Minggu 4	Minggu 5	...	Minggu 56	mean	std
p	t-1	7	17	...	95	52.03774	39.08126
	t-2	93	7	...	76	52	39.03992
	t-3	40	93	...	60	51.32075	38.92734
t		17	77	...	20	52.28302	38.83316
pn	t-1	-1.15241	-0.89654	...	1.099306		
	t-2	1.050207	-1.15267	...	0.614755		
	t-3	-0.29082	1.070694	...	0.22296		
tn		-0.90858	0.636492	...	-0.83133		

6.1.4.3. Normalisasi Model K3M3 (JST 3)

Pada model JST 3 menghasilkan nilai mean_p, mean_t, std_p, std_t, dan matriks normalisasi yang dapat dilihat pada Tabel 6.22. Normalisasi Model K3M3 Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.22. Normalisasi Model K3M3

Matriks		Minggu 5	Minggu 6	...	Minggu 56	mean	std
p	t-1	17	77	...	95	52.90385	38.94554
	t-2	7	17	...	76	51.21154	38.99238
	t-3	93	7	...	60	51.53846	39.27453
	t-4	40	93	...	16	51.15385	39.28797
t		77	2	...	20	52.96154	38.8935
pn	t-1	-0.9219	0.618714	...	1.080898		
	t-2	-1.13385	-0.87739	...	0.635726		
	t-3	1.055685	-1.13403	...	0.215446		
	t-4	-0.2839	1.065114	...	-0.89477		
tn		0.618059	-1.31028	...	-0.84748		

6.1.4.4. Normalisasi Model K3M4 (JST 4)

Pada model JST 4 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.23. Normalisasi Model K3M4 Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.23. Normalisasi Model K3M4

Matriks		Minggu 6	Minggu 7	...	Minggu 56	mean	std
p	t-1	77	2	...	95	53.60784	38.99748
	t-2	17	77	...	76	52.07843	38.87099
	t-3	7	17	...	60	50.72549	39.22095
	t-4	93	7	...	16	51.37255	39.64692
	t-5	40	93	...	109	51.84314	39.36007
t		2	145	...	20	52.4902	39.13023
pn	t-1	0.599838	-1.32336	...	1.061406		
	t-2	-0.90243	0.641135	...	0.615409		
	t-3	-1.11485	-0.85988	...	0.236468		
	t-4	1.049954	-1.11919	...	-0.89219		
	t-5	-0.30089	1.04565	...	1.452154		
tn		-1.29031	2.364152	...	-0.83031		

6.1.4.5. Normalisasi Model K3M5 (JST 5)

Pada model JST 5 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.24. Normalisasi Model K3M5 Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.24. Normalisasi Model K3M5

Matriks		Minggu 7	Minggu 8	...	Minggu 56	mean	std
p	t-1	2	145	...	95	53.14	39.24856
	t-2	77	2	...	76	52.78	38.93809
	t-3	17	77	...	60	51.6	39.11365
	t-4	7	17	...	16	50.54	39.59654
	t-5	93	7	...	109	52.08	39.72294
	t-6	40	93	...	9	50.7	38.89507
t		145	45	...	20	53.5	38.85045
pn	t-1	-1.30298	2.340468	...	1.066536		
	t-2	0.622013	-1.30412	...	0.596331		
	t-3	-0.8846	0.64939	...	0.214759		
	t-4	-1.09959	-0.84704	...	-0.8723		
	t-5	1.030135	-1.13486	...	1.432925		
	t-6	-0.2751	1.087541	...	-1.07212		
tn		2.355185	-0.21879	...	-0.86228		

6.1.4.6. Normalisasi Model K3M6 (JST 6)

Pada model JST 6 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.25. Normalisasi Model K3M6 Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.25. Normalisasi Model K3M6

Matriks		Minggu 8	Minggu 9	...	Minggu 56	mean	std
p	t-1	145	45	...	95	54.18367	38.94797
	t-2	2	145	...	76	52.28571	39.1828
	t-3	77	2	...	60	52.30612	39.19567
	t-4	17	77	...	16	51.42857	39.5
	t-5	7	17	...	109	51.2449	39.68865
	t-6	93	7	...	9	50.91837	39.26716
	t-7	40	93	...	31	51.55102	38.82496
t		45	78	...	20	51.63265	36.9164
pn	t-1	2.331734	-0.23579	...	1.04797		
	t-2	-1.28336	2.366199	...	0.605222		
	t-3	0.630016	-1.28346	...	0.196294		
	t-4	-0.87161	0.647378	...	-0.89693		
	t-5	-1.1148	-0.86284	...	1.455205		
	t-6	1.071675	-1.11845	...	-1.06752		
	t-7	-0.29752	1.067586	...	-0.52932		
tn		-0.17967	0.714245	...	-0.85687		

6.1.5. Normalisasi Produk K4 (Mota 4 Layer)

Normalisasi Produk Nota 4 Layer atau K4 dilakukan pada semua model JST yang telah dirancang sebelumnya

6.1.5.1. Normalisasi Model K4M1 (JST 1)

Pada model JST 1 menghasilkan nilai `meanp`, `meant`, `stdp`, `stdt`, dan matriks normalisasi yang dapat dilihat pada Tabel 6.26. Normalisasi Model K4M1Dengan `p` menunjukkan matriks input pelatihan, `t` menunjukkan matriks target, `pn` menunjukkan matriks input yang ternormalisasi dan `tn` menunjukkan matriks target yang ternormalisasi.

Tabel 6.26. Normalisasi Model K4M1

Matriks		Minggu 3	Minggu 4	...	Minggu 56	mean	std
p	t-1	59	11	...	47	56.05556	41.6628
	t-2	31	59	...	71	55.75926	41.78514
t		11	45	...	34	55.59259	41.76824
pn	t-1	0.070673	-1.08143	...	-0.21735		
	t-2	-0.59254	0.077557	...	0.364741		
tn		-1.06762	-0.2536	...	-0.51696		

6.1.5.2. Normalisasi Model K4M2 (JST 2)

Pada model JST 2 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.27. Normalisasi Model K4M2 Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.27. Normalisasi Model K4M2

Matriks		Minggu 4	Minggu 5	...	Minggu 56	mean	std
p	t-1	11	45	...	47	56	42.05948
	t-2	59	11	...	71	56.22642	42.0424
	t-3	31	59	...	50	55.4717	42.13102
t		45	70	...	34	56.43396	41.7034
pn	t-1	-1.06991	-0.26153	...	-0.21398		
	t-2	0.065971	-1.07573	...	0.351397		
	t-3	-0.58085	0.083746	...	-0.12987		
tn		-0.27417	0.325298	...	-0.53794		

6.1.5.3. Normalisasi Model K4M3 (JST 3)

Pada model JST 3 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.28.

Normalisasi Model K4M3 Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.28. Normalisasi Model K4M3

Matriks		Minggu 5	Minggu 6	...	Minggu 56	mean	std
p	t-1	45	70	...	47	56.86538	41.99068
	t-2	11	45	...	71	56.17308	42.45077
	t-3	59	11	...	50	55.94231	42.40117
	t-4	31	59	...	47	55.57692	42.53504
t		70	1	...	34	56.65385	42.07924
pn	t-1	-0.28257	0.312798	...	-0.23494		
	t-2	-1.06413	-0.2632	...	0.349273		
	t-3	0.072113	-1.05993	...	-0.14014		
	t-4	-0.5778	0.080477	...	-0.20164		
tn		0.317167	-1.3226	...	-0.53836		

6.1.5.4. Normalisasi Model K4M4 (JST 4)

Pada model JST 4 menghasilkan nilai $mean_p$, $mean_t$, std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.29. Normalisasi Model K4M4 Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.29. Normalisasi Model K4M4

Matriks		Minggu 6	Minggu 7	...	Minggu 56	mean	std
p	t-1	70	1	...	47	57.09804	42.37464
	t-2	45	70	...	71	57.05882	42.3851
	t-3	11	45	...	50	55.88235	42.82086
	t-4	59	11	...	47	56.05882	42.81468
	t-5	31	59	...	33	55.7451	42.94082
t		1	134	...	34	56.39216	42.45519
pn	t-1	0.304474	-1.32386	...	-0.2383		
	t-2	-0.28451	0.305324	...	0.328917		
	t-3	-1.04814	-0.25414	...	-0.13737		
	t-4	0.068696	-1.05242	...	-0.21158		
	t-5	-0.57626	0.0758	...	-0.52968		
tn		-1.30472	1.827994	...	-0.52743		

6.1.5.5. Normalisasi Model K4M5 (JST 5)

Pada model JST 5 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.30. Normalisasi Model K4M5 Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.30. Normalisasi Model K4M5

Matriks		Minggu 7	Minggu 8	...	Minggu 56	mean	std
p	t-1	1	134	...	47	56.84	42.76436
	t-2	70	1	...	71	57.3	42.78005
	t-3	45	70	...	50	56.78	42.76814
	t-4	11	45	...	47	56	43.24727
	t-5	59	11	...	33	56.24	43.2296
	t-6	31	59	...	5	56.2	43.25246
t		134	114	...	34	57.5	42.13499
pn	t-1	-1.30576	1.804306	...	-0.2301		
	t-2	0.296867	-1.31603	...	0.320243		
	t-3	-0.27544	0.309109	...	-0.15853		
	t-4	-1.04053	-0.25435	...	-0.20811		
	t-5	0.063845	-1.04651	...	-0.53759		
	t-6	-0.58263	0.064736	...	-1.18375		
tn		1.815593	1.340928	...	-0.55773		

6.1.5.6. Normalisasi Model K4M6 (JST 6)

Pada model JST 6 menghasilkan nilai mean_p , meant , std_p , stdt , dan matriks normalisasi yang dapat dilihat pada Tabel 6.31. Normalisasi Model K4M6 Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.31. Normalisasi Model K4M6

Matriks		Minggu 8	Minggu 9	...	Minggu 56	mean	std
p	t-1	134	114	...	47	57.97959	42.43352
	t-2	1	134	...	71	57.04082	43.1837
	t-3	70	1	...	50	57.02041	43.1772
	t-4	45	70	...	47	56.91837	43.20004
	t-5	11	45	...	33	56.18367	43.67573
	t-6	59	11	...	5	56.71429	43.54595
	t-7	31	59	...	111	57.2449	43.05836
t		114	33	...	34	55.93878	41.08447
pn	t-1	1.791518	1.320192	...	-0.25875		
	t-2	-1.29773	1.782135	...	0.323251		
	t-3	0.300612	-1.29745	...	-0.1626		
	t-4	-0.27589	0.302815	...	-0.22959		
	t-5	-1.03453	-0.25606	...	-0.53081		
	t-6	0.05249	-1.04979	...	-1.18758		
	t-7	-0.60952	0.040761	...	1.248424		
tn		1.413216	-0.55833	...	-0.53399		

6.1.6. Normalisasi Produk K5 (Nota 5 Layer)

Normalisasi Produk Nota 5 Layer atau K4 dilakukan pada semua model JST yang telah dirancang sebelumnya

6.1.6.1. Normalisasi Model K5M1 (JST 1)

Pada model JST 1 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat Tabel 6.32. Normalisasi Model K5M1 Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.32. Normalisasi Model K5M1

Matriks		Minggu 3	Minggu 4	...	Minggu 56	mean	std
p	t-1	10	5	...	32	15	14.28946
	t-2	13	10	...	16	14.64815	14.09557
t		5	0	...	6	14.92593	14.32619
pn	t-1	-0.34991	-0.69982	...	1.189688		
	t-2	-0.11693	-0.32976	...	0.095906		
tn		-0.69285	-1.04186	...	-0.62305		

6.1.6.2. Normalisasi Model K5M2 (JST 2)

Pada model JST 2 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.33. Normalisasi Model K5M2Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.33. Normalisasi Model K5M2

Matriks		Minggu 4	Minggu 5	...	Minggu 56	mean	std
p	t-1	5	0	...	32	15.09434	14.40922
	t-2	10	5	...	16	14.67925	14.22859
	t-3	13	10	...	25	14.62264	14.2292
t		0	47	...	6	15.11321	14.39639
pn	t-1	-0.70055	-1.04755	...	1.173253		
	t-2	-0.32886	-0.68027	...	0.092824		
	t-3	-0.11404	-0.32487	...	0.7293		
tn		-1.04979	2.214915	...	-0.63302		

6.1.6.3. Normalisasi Model K5M3 (JST 3)

Pada model JST 3 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.34.

Normalisasi Model K5M3. Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.34. Normalisasi Model K5M3

Matriks		Minggu 5	Minggu 6	...	Minggu 56	mean	std
p	t-1	0	47	...	32	15.28846	14.47965
	t-2	5	0	...	16	14.76923	14.35217
	t-3	10	5	...	25	14.65385	14.3662
	t-4	13	10	...	10	14.42308	14.29294
t		47	5	...	6	15.40385	14.37899
pn	t-1	-1.05586	2.190076	...	1.15414		
	t-2	-0.68068	-1.02906	...	0.085755		
	t-3	-0.32394	-0.67198	...	0.720173		
	t-4	-0.09957	-0.30946	...	-0.30946		
tn		2.197384	-0.72355	...	-0.654		

6.1.6.4. Normalisasi Model K5M4 (JST 4)

Pada model JST 4 menghasilkan nilai $mean_p$, $mean_t$, std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.35. Normalisasi Model K5M4Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.35. Normalisasi Model K5M4

Matriks		Minggu 6	Minggu 7	...	Minggu 56	mean	std
p	t-1	47	5	...	32	15.58824	14.45984
	t-2	0	47	...	16	14.96078	14.4277
	t-3	5	0	...	25	14.7451	14.49392
	t-4	10	5	...	10	14.45098	14.43373
	t-5	13	10	...	40	14.5098	14.42133
t		5	33	...	6	14.78431	13.80335
pn	t-1	2.172345	-0.73225	...	1.134989		
	t-2	-1.03695	2.220674	...	0.072029		
	t-3	-0.67236	-1.01733	...	0.707531		
	t-4	-0.30837	-0.65478	...	-0.30837		
	t-5	-0.10469	-0.31272	...	1.767534		
tn		-0.70884	1.319657	...	-0.63639		

6.1.6.5. Normalisasi Model K5M5 (JST 5)

Pada model JST 5 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.36. Dengan **p** menunjukkan matriks input pelatihan, **t** menunjukkan matriks target, **pn** menunjukkan matriks input yang ternormalisasi dan **tn** menunjukkan matriks target yang ternormalisasi.

Tabel 6.36. Normalisasi Model K5M5

Matriks		Minggu 7	Minggu 8	...	Minggu 56	mean	std
p	t-1	5	33	...	32	14.96	13.88577
	t-2	47	5	...	16	15.26	14.41344
	t-3	0	47	...	25	14.94	14.5734
	t-4	5	0	...	10	14.54	14.56612
	t-5	10	5	...	40	14.54	14.56612
	t-6	13	10	...	0	14	14.09588
t		33	3	...	6	14.98	13.87185
pn	t-1	-0.71728	1.299171	...	1.227155		
	t-2	2.202111	-0.71184	...	0.051341		
	t-3	-1.02516	2.199898	...	0.690299		
	t-4	-0.65494	-0.99821	...	-0.31168		
	t-5	-0.31168	-0.65494	...	1.747892		
	t-6	-0.07094	-0.28377	...	-0.9932		
tn		1.299034	-0.86362	...	-0.64735		

6.1.6.6. Normalisasi Model K5M6 (JST 6)

Pada model JST 6 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.37. Normalisasi Model K5M6Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.37. Normalisasi Model K5M6

Matriks		Minggu 8	Minggu 9	...	Minggu 56	mean	std
p	t-1	33	3	...	32	15.16327	13.95431
	t-2	5	33	...	16	14.61224	13.80793
	t-3	47	5	...	25	15.2449	14.56241
	t-4	0	47	...	10	14.73469	14.65119
	t-5	5	0	...	40	14.63265	14.70217
	t-6	10	5	...	0	14.02041	14.24121
	t-7	13	10	...	58	14.28571	14.09492
t		3	2	...	6	14.61224	13.76714
pn	t-1	1.278224	-0.87165	...	1.206562		
	t-2	-0.69614	1.33168	...	0.100504		
	t-3	2.180621	-0.70352	...	0.669882		
	t-4	-1.0057	2.202231	...	-0.32316		
	t-5	-0.65519	-0.99527	...	1.725415		
	t-6	-0.28231	-0.6334	...	-0.9845		
	t-7	-0.09122	-0.30406	...	3.101422		
tn		-0.84348	-0.91611	...	-0.62557		

6.1.7. Normalisasi Produk K6 (Nota 6 Layer)

Normalisasi Produk Nota 6 Layer atau K4 dilakukan pada semua model JST yang telah dirancang sebelumnya.

6.1.7.1. Normalisasi Model K6M1 (JST 1)

Pada model JST 1 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.38. Normalisasi Model K6M1Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.38. Normalisasi Model K6M1

Matriks		Minggu 3	Minggu 4	...	Minggu 56	mean	std
p	t-1	2	0	...	15	3.203704	4.341027
	t-2	10	2	...	10	3.111111	4.133009
t		0	10	...	1	3.185185	4.348385
pn	t-1	-0.27729	-0.73801	...	2.717398		
	t-2	1.666798	-0.26884	...	1.666798		
tn		-0.7325	1.567206	...	-0.50253		

6.1.7.2. Normalisasi Model K6M2 (JST 2)

Pada model JST 2 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.39. Normalisasi Model K6M2Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.39. Normalisasi Model K6M2

Matriks		Minggu 4	Minggu 5	...	Minggu 56	mean	std
p	t-1	0	10	...	15	3.226415	4.379329
	t-2	2	0	...	10	2.981132	4.059607
	t-3	10	2	...	4	2.981132	4.059607
t		10	10	...	1	3.245283	4.367298
pn	t-1	-0.73674	1.546718	...	2.688445		
	t-2	-0.24168	-0.73434	...	1.728953		
	t-3	1.728953	-0.24168	...	0.250977		
tn		1.546658	1.546658	...	-0.51411		

6.1.7.3. Normalisasi Model K6M3 (JST 3)

Pada model JST 3 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.40.

Normalisasi Model K6M3Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi

Tabel 6.40. Normalisasi Model K6M3

Matriks		Minggu 5	Minggu 6	...	Minggu 56	mean	std
p	t-1	10	10	...	15	3.288462	4.398469
	t-2	0	10	...	10	3	4.096866
	t-3	2	0	...	4	2.846154	3.977311
	t-4	10	2	...	0	2.961538	4.096682
t		10	0	...	1	3.115385	4.305281
pn	t-1	1.525881	1.525881	...	2.66264		
	t-2	-0.73227	1.708623	...	1.708623		
	t-3	-0.21275	-0.7156	...	0.290107		
	t-4	1.718088	-0.23471	...	-0.72291		
tn		1.599109	-0.72362	...	-0.49135		

6.1.7.4. Normalisasi Model K6M4(JST 4)

Pada model JST 4 menghasilkan nilai $mean_p$, $mean_t$, std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.41. Normalisasi Model K6M4Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.41. Normalisasi Model K6M4

Matriks		Minggu 6	Minggu 7	...	Minggu 56	mean	std
p	t-1	10	0	...	15	3.156863	4.337615
	t-2	10	10	...	10	3.058824	4.115394
	t-3	0	10	...	4	2.862745	4.01507
	t-4	2	0	...	0	2.823529	4.013507
	t-5	10	2	...	2	3.019608	4.115775
t		0	0	...	1	2.980392	4.235517
pn	t-1	1.577627	-0.72779	...	2.730334		
	t-2	1.686637	1.686637	...	1.686637		
	t-3	-0.713	1.777617	...	0.283247		
	t-4	-0.20519	-0.70351	...	-0.70351		
	t-5	1.696009	-0.24773	...	-0.24773		
tn		-0.70367	-0.70367	...	-0.46757		

6.1.7.5. Normalisasi Model K6M5 (JST 5)

Pada model JST 5 menghasilkan nilai mean_p , mean_t , std_p , std_t , dan matriks normalisasi yang dapat dilihat pada Tabel 6.42. Normalisasi Model K6M5Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi.

Tabel 6.42. Normalisasi Model K6M5

Matriks		Minggu 7	Minggu 8	...	Minggu 56	mean	std
p	t-1	0	0	...	15	3.02	4.268967
	t-2	10	0	...	10	2.92	4.034747
	t-3	10	10	...	4	2.92	4.034747
	t-4	0	10	...	0	2.84	4.052512
	t-5	2	0	...	2	2.88	4.033735
	t-6	10	2	...	0	3.04	4.154958
t		0	0	...	1	3.04	4.256855
pn	t-1	-0.70743	-0.70743	...	2.806299		
	t-2	1.754757	-0.72371	...	1.754757		
	t-3	1.754757	1.754757	...	0.267675		
	t-4	-0.7008	1.766805	...	-0.7008		
	t-5	-0.21816	-0.71398	...	-0.21816		
	t-6	1.675107	-0.2503	...	-0.73166		
tn		-0.71414	-0.71414	...	-0.47923		

6.1.7.6. Normalisasi Model K6M6 (JST 6)

Pada model JST 6 menghasilkan nilai mean_p, mean_t, std_p, std_t, dan matriks normalisasi yang dapat dilihat pada Tabel 6.43. Normalisasi Model K6M6 Dengan p menunjukkan matriks input pelatihan, t menunjukkan matriks target, pn menunjukkan matriks input yang ternormalisasi dan tn menunjukkan matriks target yang ternormalisasi

Tabel 6.43. Normalisasi Model K6M6

Matriks		Minggu 8	Minggu 9	...	Minggu 56	mean	std
p	t-1	0	0	...	15	3.081633	4.290672
	t-2	0	0	...	10	2.77551	3.943694
	t-3	10	0	...	4	2.77551	3.943694
	t-4	10	10	...	0	2.897959	4.073517
	t-5	0	10	...	2	2.897959	4.073517
	t-6	2	0	...	0	2.897959	4.073517
	t-7	10	2	...	2	3.102041	4.17455
t		0	8	...	1	3.102041	4.278069
pn	t-1	-0.71822	-0.71822	...	2.777739		
	t-2	-0.70378	-0.70378	...	1.831909		
	t-3	1.831909	-0.70378	...	0.310493		
	t-4	1.743467	1.743467	...	-0.71141		
	t-5	-0.71141	1.743467	...	-0.22044		
	t-6	-0.22044	-0.71141	...	-0.71141		
	t-7	1.652384	-0.26399	...	-0.26399		
tn		-0.7251	1.1449	...	-0.49135		

6.2. Hasil Pembentukan Model JST dan Training

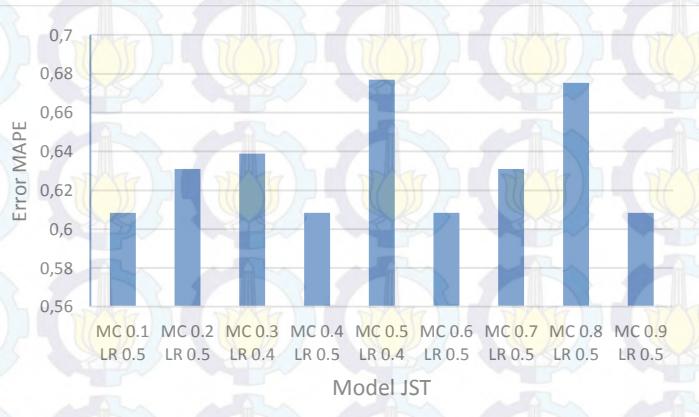
Pembentukan model JST dilakukan dengan menentukan jumlah neuron pada *hidden layer* dan menentukan parameter-parameter dari tiap model JST. Jumlah *hidden layer* dua kali dari jumlah *input*, sedangkan parameter yang digunakan *learning rate* (lr) sebesar 0.1 – 0.9, *momentum* (mc) yang digunakan sebesar 0.1 – 0.9 dan jumlah iterasi 1000 epoch. Setelah dilakukan proses *training* maka akan menghasilkan nilai *output* yang dapat digunakan untuk mengetahui model jaringan dengan parameter yang optimal berdasarkan nilai MAPE yang dihasilkan.

6.2.1. Hasil Pelatihan (*Training*) Produk Akumalasi

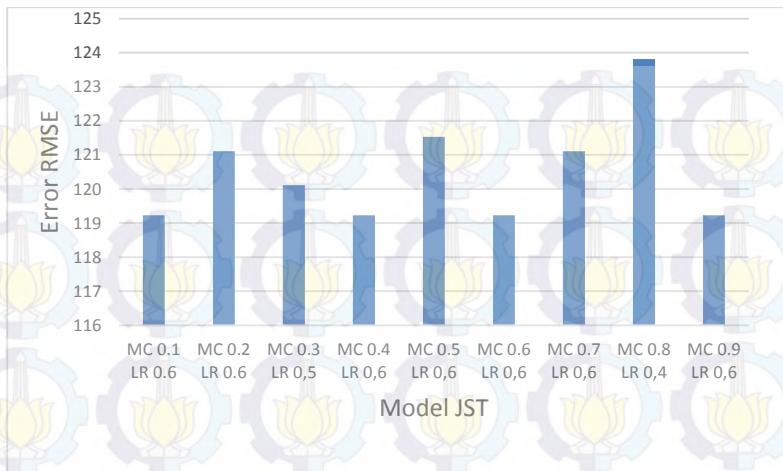
Hasil *Training* atau pelatihan pada setiap model JST pada produk Akumalasi.

6.2.1.1. Hasil MAPE Model KUM1 (JST 1)

Pada Gambar 6.1 terlihat bahwa nilai MAPE untuk KUM1 berubah secara fluktuatif. Nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.6 dan *learning rate* 0.5 sebesar $0.677032984 \cong 67.70\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan (mc 0.1 lr 0.5) sebesar $0.6084677581 \cong 60.84\%$. Sedangkan pada Gambar 6.2 menunjukkan nilai RMSE untuk KUM1 dengan nilai tertinggi 123,8152 (mc 0.8 lr 0.4) dan yang terendah 119,2271 (mc 0.1 lr 0.6).



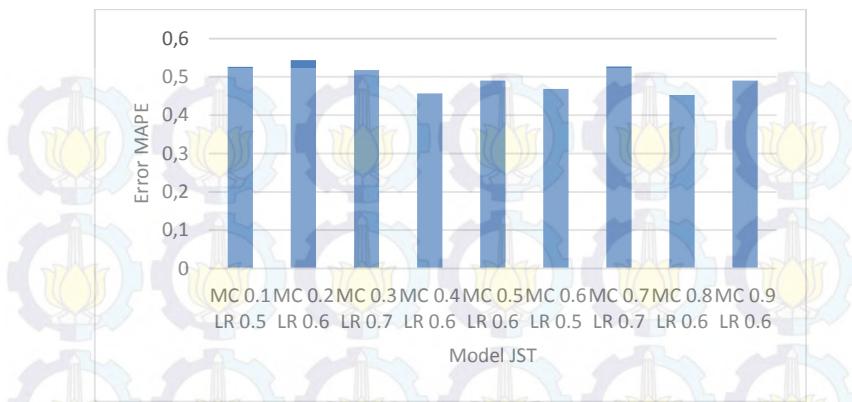
Gambar 6.1. Hasil MAPE KUM1



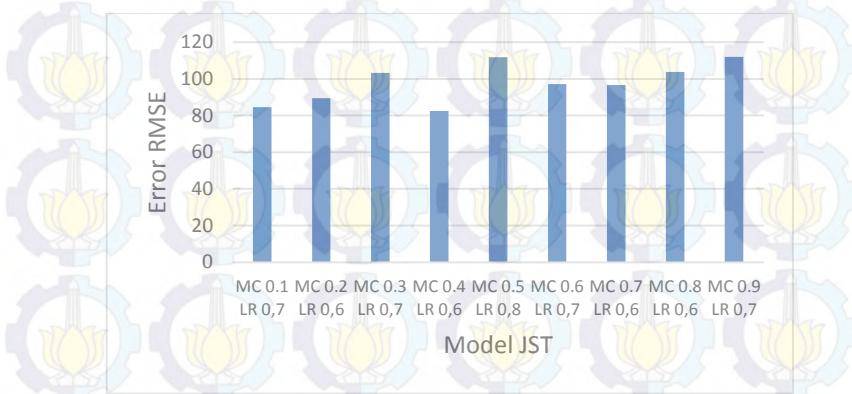
Gambar 6.2. Hasil RMSE KUM1

6.2.1.2. Hasil MAPE Model KUM2

Dari Gambar 6.3 terlihat bahwa nilai MAPE untuk KUM2 tidak mengalami perubahan secara signifikan, namun tetap terdapat fluktuasi (naik turun) meskipun tidak tajam. Nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 6.2 dan *learning rate* 0.6 sebesar $0.543813138 \cong 54.38\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.8 dan *learning rate* 0.6 sebesar $0.45273929 \cong 45.27\%$. Sedangkan pada Gambar 6.4 menunjukkan nilai RMSE untuk KUM2 dengan nilai tertinggi 103,8342226 (mc 0.8 lr 0.6) dan nilai terendah 82,52716372 (mc 0.4 lr 0,6)



Gambar 6.3. Hasil MAPE KUM2

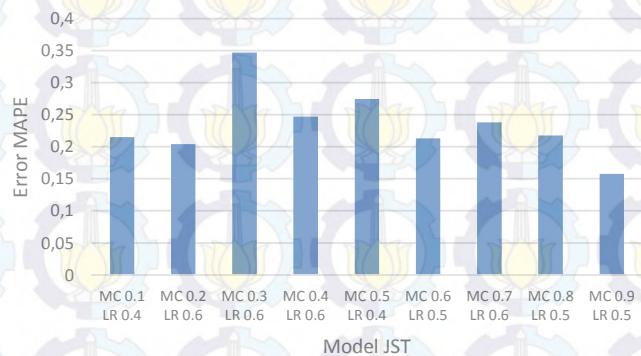


Gambar 6.4. Hasil RMSE KUM2

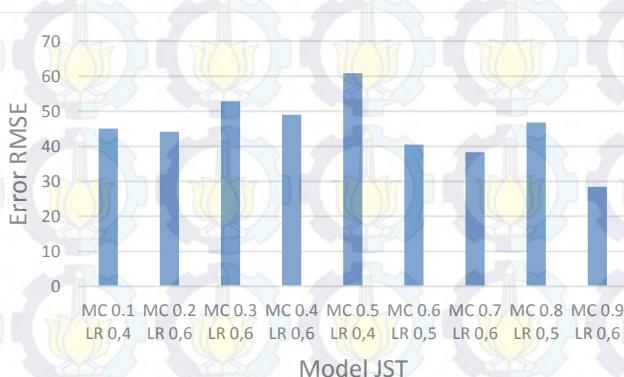
6.2.1.3. Hasil MAPE Model KUM3 (JST 3)

Pada Gambar 6.5 terlihat bahwa nilai MAPE untuk KUM3 berubah cukup fluktuatif. Nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.2 dan *learning rate* 0.6 sebesar $0.346893718 \cong 34.68\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.9 dan *learning rate* 0.5 sebesar $0.157582005 \cong 15.75\%$. Sedangkan pada Gambar 6.6

menunjukkan nilai RMSE untuk KUM3 dengan nilai tertinggi 60,90382524 (mc 0,5 lr 0,4) dan nilai terendah 28,44359393 (mc 0,9 lr 0,6)



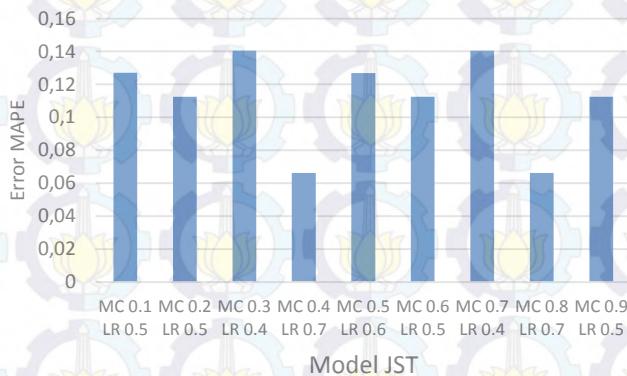
Gambar 6.5. Hasil MAPE KUM3



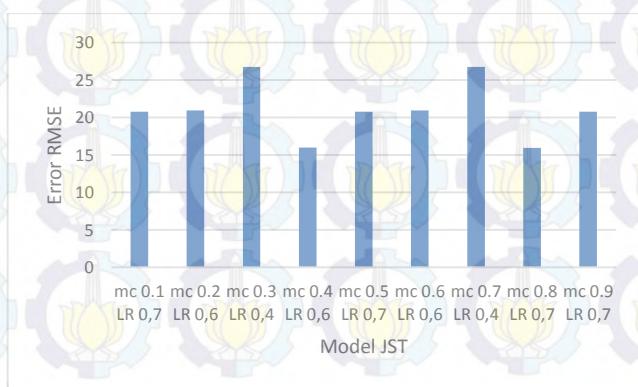
Gambar 6.6. Hasil RMSE KUM3

6.2.1.4. Hasil MAPE Model KUM4 (JST 4)

Pada Gambar 6.7 Nilai MAPE yang paling tinggi yaitu parameter dengan (mc 0.3 lr 0.4) sebesar $0.140558437 \cong 14.05\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan (mc 0.8 lr 0.7) sebesar $0.066133689 \cong 6.61\%$. Sedangkan pada Gambar 6.8 menunjukkan nilai RMSE untuk KUM4 dengan nilai tertinggi 26,73775225 (mc 0.3 lr 0,4) dan nilai terendah 15,91601122 (mc 0.8 lr 0,7)



Gambar 6.7. Hasil MAPE KUM4



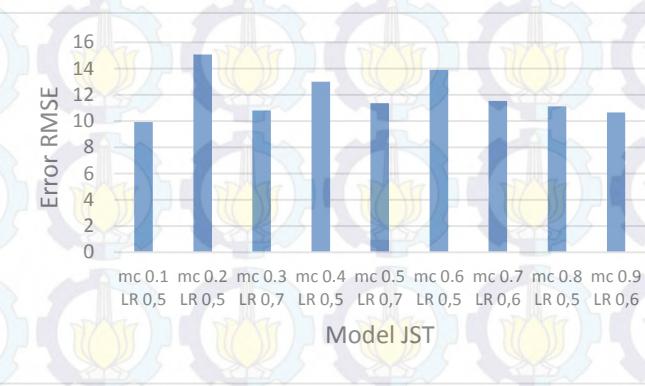
Gambar 6.8 Hasil RMSE KUM4

6.2.1.5. Hasil MAPE Model KUM5 (JST 5)

Pada Gambar 6.9 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.6 dan *learning rate* 0.6 sebesar $0.069331266 \cong 6.93\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *mc* 0.1 dan *lr* 0.5 sebesar $0.039498302 \cong 3.94\%$. Sedangkan pada Gambar 6.10 menunjukkan nilai RMSE untuk KUM5 dengan nilai tertinggi 15,06287011 (*mc* 0.2 *lr* 0,5) dan nilai terendah 9,926033378 (*mc* 0.1 *lr* 0,5)



Gambar 6.9. Hasil MAPE KUM5



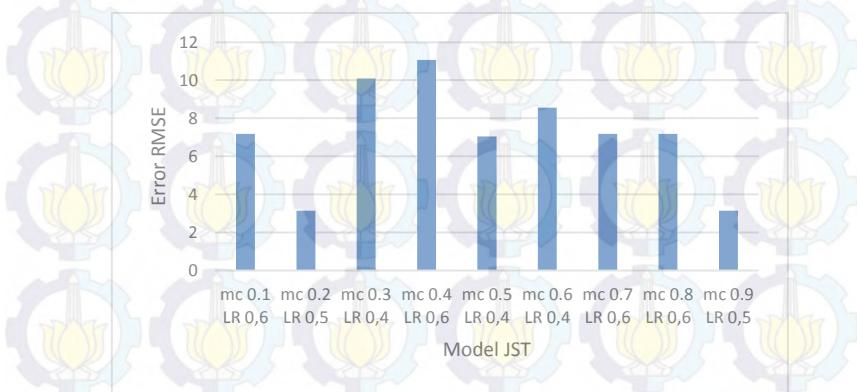
Gambar 6.10. Hasil RMSE KUM5

6.2.1.6. Hasil MAPE Model KUM6 (JST 6)

Pada Gambar 6.11 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.4 dan *learning rate* 0.6 sebesar $0.038396839 \cong 3.83\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan (mc 0.2 lr 0.5) sebesar $0.01218143 \cong 1.218\%$. Sedangkan pada Gambar 6.12 menunjukkan nilai RMSE untuk KUM6 dengan nilai tertinggi 10,09286559 (mc 0.3 lr 0,4) dan nilai terendah 3,146658233 (mc 0.2 lr 0,5)



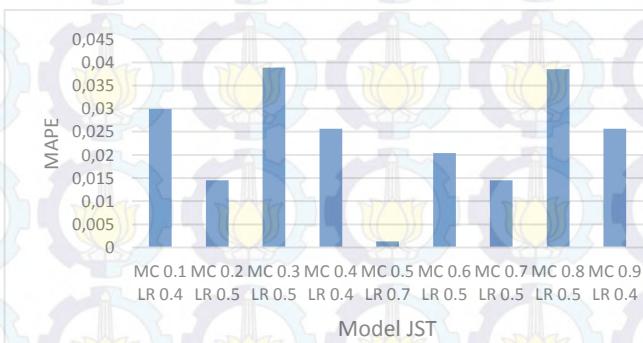
Gambar 6.11. Hasil MAPE KUM6



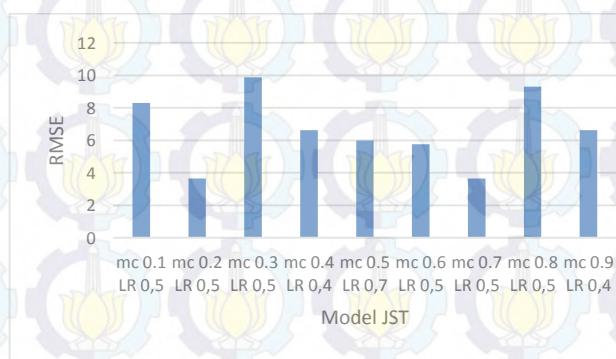
Gambar 6.12. Hasil RMSE KUM6

6.2.1.7. Hasil MAPE Model KUM7 (JST 7)

Pada Gambar 6.13 nilai MAPE yang paling tinggi yaitu parameter dengan (*mc* 0.3 *lr* 0.5) sebesar $0.038488582 \cong 3.88\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.5 dan *learning rate* 0.7 sebesar $0.001299218 \cong 0.1299\%$. Sedangkan pada Gambar 6.14 menunjukkan nilai RMSE untuk KUM7 dengan nilai tertinggi 9,880449863 (*mc* 0.3 *lr* 0,5) dan nilai terendah 3,658948431 (*mc* 0.2 *lr* 0,5)



Gambar 6.13. Hasil MAPE KUM7



Gambar 6.14. Hasil RMSE KUM7

6.2.1.8. Hasil MAPE Model KUM8 (JST 8)

Dari Gambar 6.15. Hasil MAPE Model KUM8 (JST 8) nilai MAPE yang paling tinggi yaitu parameter dengan (mc 0.3 lr 0.9) sebesar $0.000575218 \cong 0.058\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.6 dan *learning rate* 0.9 sebesar $1.56E - 09 \cong 0.00000016\%$. Sedangkan pada Gambar 6.16 menunjukkan nilai RMSE untuk KUM8 dengan nilai tertinggi 5,290575393 (mc 0.4 lr 0,7) dan nilai terendah 1,430151986 (mc 0.1 LR 0,5)



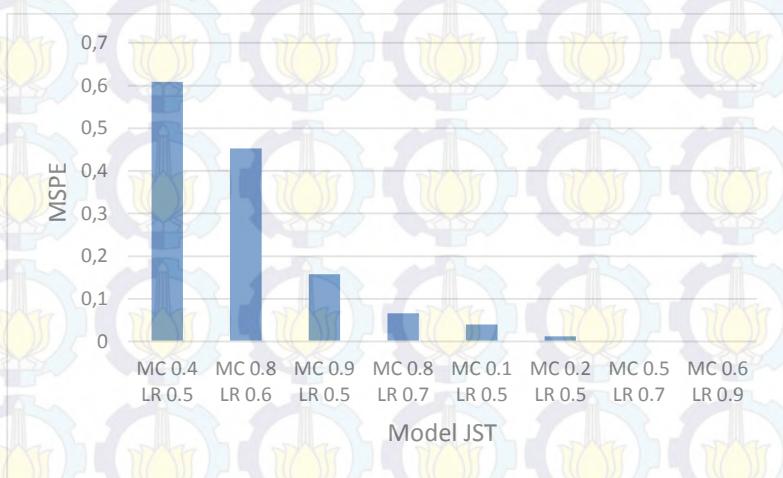
Gambar 6.15. Hasil MAPE KUM8



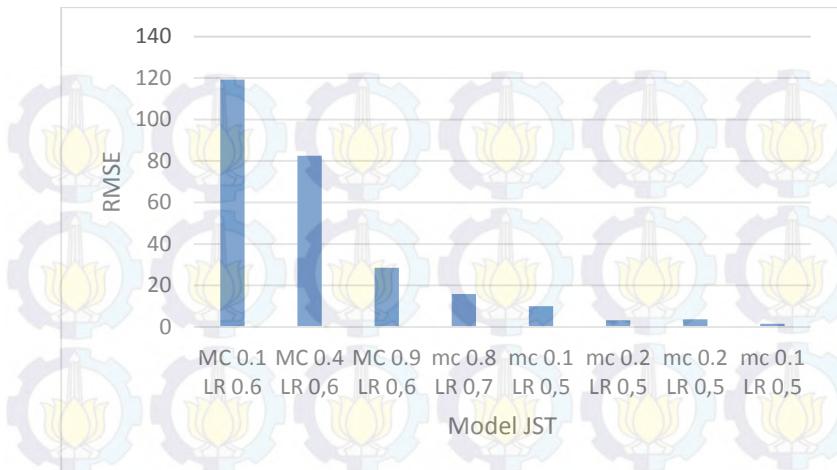
Gambar 6.16. Hasil RMSE KUM8

6.2.1.9. Hasil MAPE Optimal Akumulasi

Pada Gambar 6.17 dapat diketahui bahwa nilai MAPE pada produk Akumulasi semakin turun atau mengecil dari JST 1 ke JST 8. Model dengan nilai MAPE yang paling kecil yaitu model KUM8 (JST 8) parameter *momentum* 0.6 dan *learning rate* 0.9 dengan nilai MAPE sebesar $1.56E - 09 \cong 0.00000016\%$. Selain itu pada untuk nilai RMSE pada Gambar 6.18 juga terus turun dengan nilai terendah sebesar 1,430151986 pada JST 8 parameter *momentum* 0.1 dan *learning rate* 0.5. Namun, model tersebut belum tentu merupakan model yang optimal karena pada model KUM8 masih terjadi penurunan MAPE. Hal ini dapat terjadi karena jumlah data pada proses training samakin sedikit sehingga nilai MAPE akan terus turun seiring dengan penambahan input.



Gambar 6.17. MAPE Optimal Training Produk Akumulasi



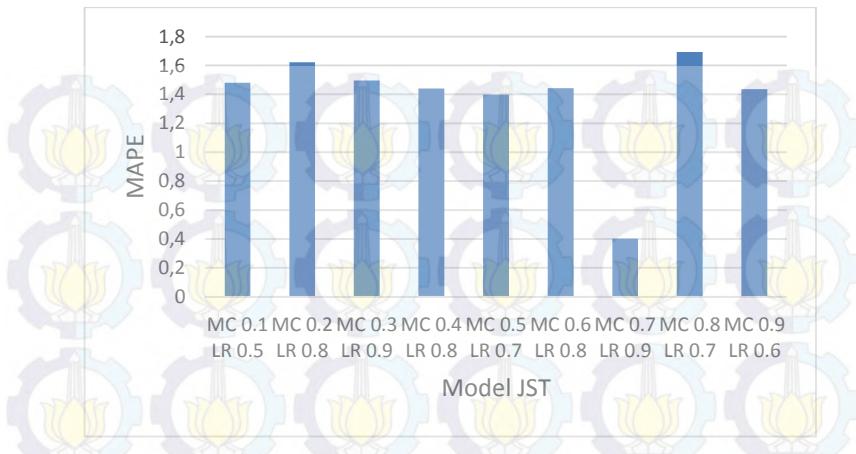
Gambar 6.18. RMSE Optimal Training Produk Akumulasi

6.2.2. Hasil Pelatihan (*Training*) Produk K1

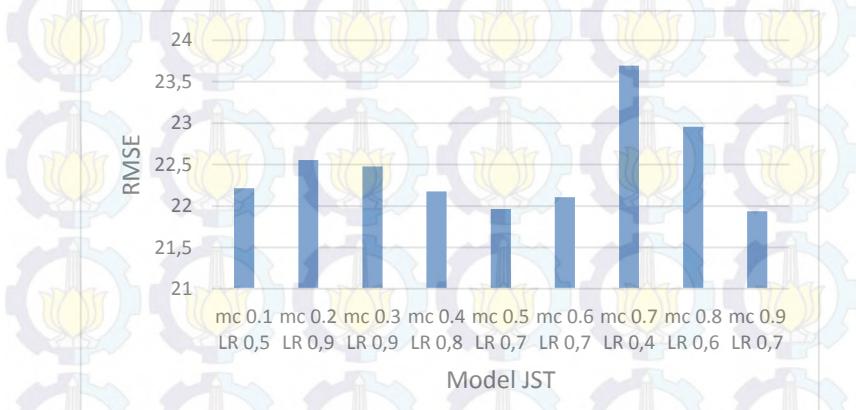
Hasil *Training* atau pelatihan pada setiap model JST pada produk K1 (Nota 1 Layer).

6.2.2.1. Hasil MAPE Model K1M1

Pada Gambar 6.19 terlihat bahwa nilai MAPE untuk K1M1 berubah secara fluktuatif. Nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.7 dan *learning rate* 0.9 sebesar $1.693019844 \cong 169.301\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.7 dan *learning rate* 0.9 sebesar $0.4016107368 \cong 40.16\%$. Sedangkan pada Gambar 6.20 menunjukkan nilai RMSE untuk K1M1 dengan nilai tertinggi 23,69270698 (mc 0.7 lr 0,4) dan nilai terendah 21,93795697 (mc 0.9 lr 0,7)



Gambar 6.19. Hasil MAPE K1M1

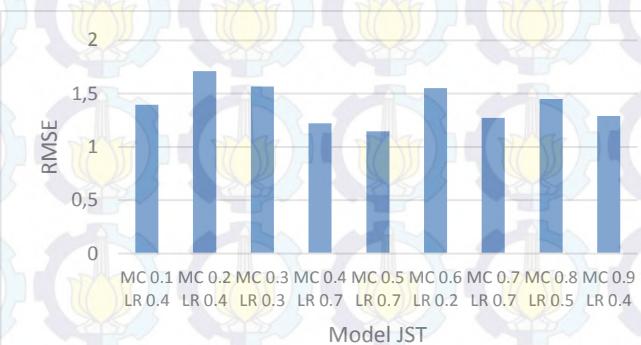


Gambar 6.20. Hasil RMSE K1M2

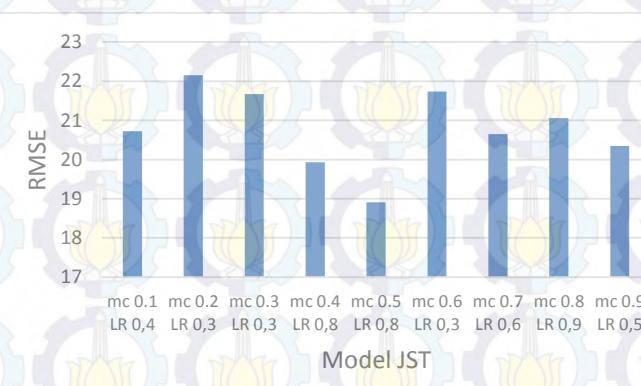
6.2.2.2. Hasil MAPE Model K1M2 (JST 2)

Dari Gambar 6.21 terlihat bahwa nilai MAPE untuk K1M2 berubah secara fluktuatif. Nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.2 dan *learning rate* 0.4 sebesar

$1.711626808 \cong 171.163\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.5 dan *learning rate* 0.7 sebesar $1.146031251 \cong 114.603\%$. Sedangkan pada Gambar 6.22 menunjukkan nilai RMSE untuk K1M2 dengan nilai tertinggi 22,15505494 (mc 0.2 lr 0.3) dan nilai terendah 18,91071581(mc 0.5 lr 0.8)



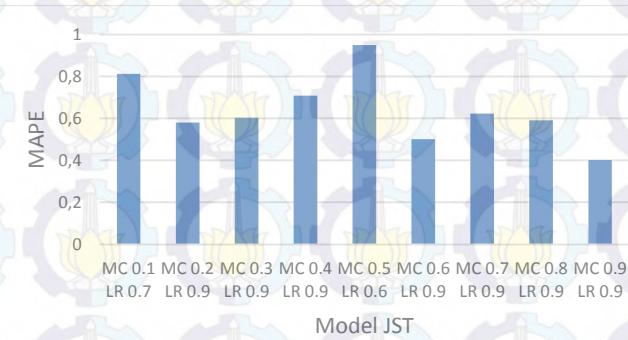
Gambar 6.21. Hasil MAPE K1M2



Gambar 6. 22. Hasil RMSE K1M2

6.2.2.3. Hasil MAPE Model K1M3 (JST 3)

Pada Gambar 6.23 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.5 dan *learning rate* 0.6 sebesar $0.949741796 \cong 94.97\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.9 dan *learning rate* 0.9 sebesar $0.401302282 \cong 40.13\%$. Sedangkan pada Gambar 6.24 menunjukkan nilai RMSE untuk K1M3 dengan nilai tertinggi 14,96520979 (mc 0.5 lr 0,9) dan terendah 10,12115028 (mc 0.8 lr 0,9)



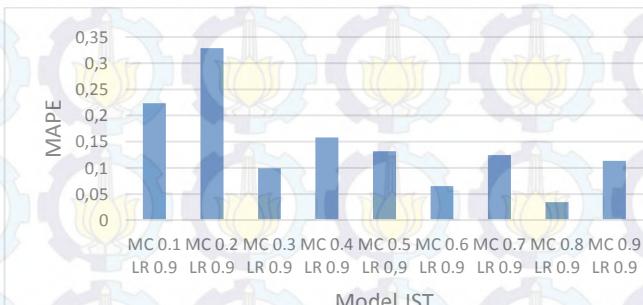
Gambar 6.23. Hasil MAPE K1M3



Gambar 6.24. Hasil RMSE K1M3

6.2.2.4. Hasil MAPE Model K1M4 (JST 4)

Pada Gambar 6.25 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.2 dan *learning rate* 0.9 sebesar $0.328829375 \cong 32.88\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.8 dan *learning rate* 0.9 sebesar $0.034227311 \cong 3.42\%$. Sedangkan pada Gambar 6.26 menunjukkan nilai RMSE untuk K1M4 dengan nilai tertinggi 4,115177114 (mc 0.1 lr 0,9) dan nilai terendah 0,442702121 (mc 0.8 lr 0,9)



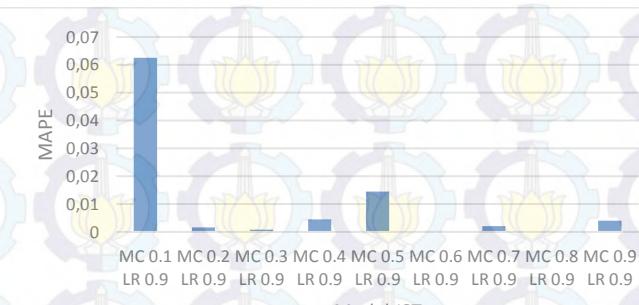
Gambar 6.25. Hasil MAPE K1M4



Gambar 6.26. Hasil RMSE K1M4

6.2.2.5. Hasil MAPE Model K1M5 (JST 5)

Pada Gambar 6.27 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.1 dan *learning rate* 0.9 sebesar $0.062588177 \cong 6.26\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.8 dan *learning rate* 0.9 sebesar $0.000109859 \cong 0.011\%$. Sedangkan pada Gambar 6.28 menunjukkan nilai RMSE untuk K1M5 dengan nilai tertinggi 1,255173914 (mc 0.1 lr 0,9) dan nilai terendah 0,0019342 (mc 0.8 lr 0,9)



Gambar 6.27. Hasil MAPE K1M5



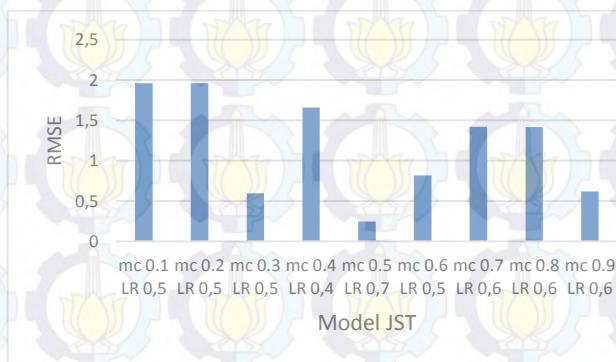
Gambar 6.28. Hasil RMSE K1M5

6.2.2.6. Hasil MAPE Model K1M6 (JST 6)

Pada Gambar 6.29 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.2 dan *learning rate* 0.5 sebesar $0.17157764 \cong 17.15\%$. Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter dengan *mc* 0.1 dan *lr* 0.9 sebesar $0.015796036 \cong 1.58\%$. Sedangkan pada Gambar 6.30 menunjukkan nilai RMSE untuk K1M6 dengan nilai tertinggi 1,959803083 (*mc* 0.1 *lr* 0,5) dan nilai terendah 0,247289029 (*mc* 0.5 *lr* 0,7)



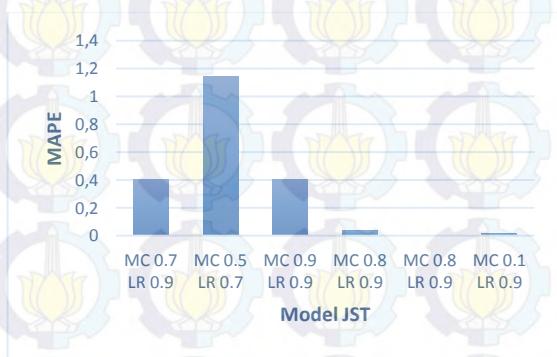
Gambar 6.29. Hasil MAPE K1M6



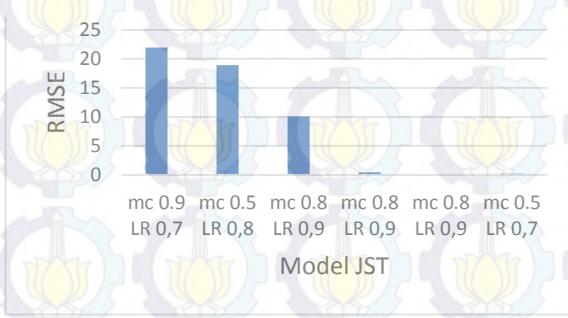
Gambar 6.30. Hasil RMSE K1M6

6.2.2.7. Hasil MAPE Optimal Produk K1

Pada Gambar 6.31 dapat dilihat nilai MAPE pada produk K1 (Nota 1 Layer) naik turun secara fluktuatif. MAPE paling kecil yaitu pada JST 5. Namun pada JST 6 nilai MAPE naik kembali, sehingga model yang paling optimal pada produk K1 yaitu model K1M5 (JST 5) parameter *momentum* 0.8 dan *learning rate* 0.9 dengan nilai MAPE sebesar $0.000109859 \cong 0.011\%$. Selain itu pada untuk nilai RMSE pada Gambar 6.32 juga terus turun hingga JST 5 kemudian naik kembali pada JST 6. Sehingga model terbaik untuk RMSE yaitu K1M5 (JST 5) parameter *momentum* 0.8 dan *learning rate* 0.9 dengan nilai sebesar 0,0019342.



Gambar 6. 31. MAPE Training Optimal Produk K1



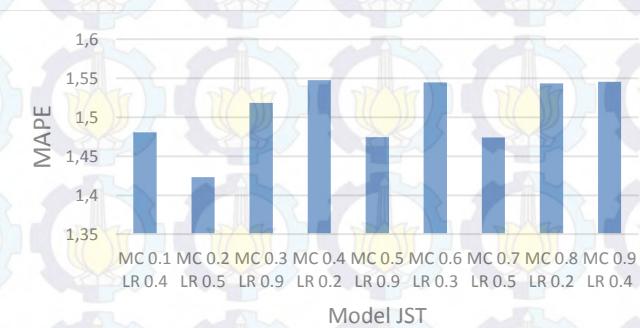
Gambar 6. 32. RMSE Training Optimal Produk K1

6.2.3. Hasil Pelatihan (*Training*) Produk K2

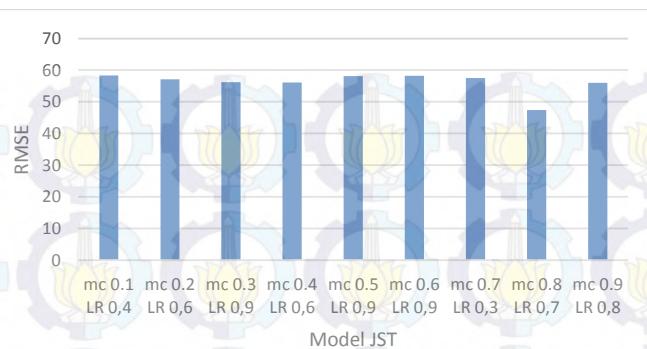
Hasil *Training* atau pelatihan pada setiap model JST pada produk K2 (Nota 2 Layer)

6.2.3.1. Hasil MAPE Model K2M1 (JST 1)

Pada Gambar 6.33 terlihat bahwa nilai MAPE untuk K2M1 berubah secara fluktuatif. Nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.4 dan *learning rate* 0.2 sebesar $1.54743421 \cong 154.74\%$. Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter *momentum* dengan 0.2 dan *learning rate* 0.5 sebesar $1.423189387 \cong 142.32\%$. Sedangkan pada Gambar 6.34 menunjukkan nilai RMSE untuk K2M1 dengan nilai tertinggi 58,29098872 (mc 0.1 lr 0.4) dan nilai terendah 47,41751271 (mc 0.8 lr 0.7)



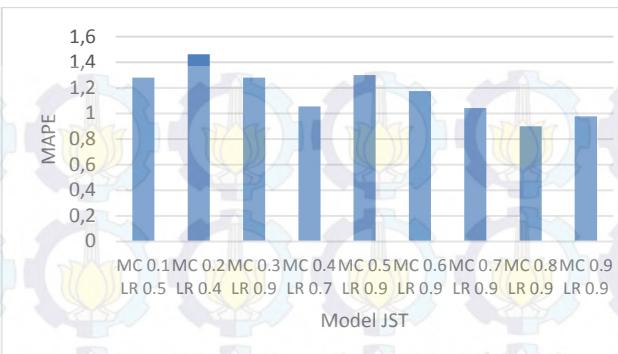
Gambar 6.33. Hasil MAPE K2M1



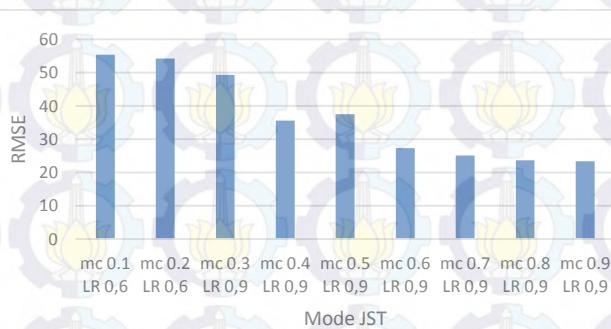
Gambar 6.34. Hasil RMSE K2M1

6.2.3.2. Hasil MAPE Model K2M2 (JST 2)

Pada Gambar 6.35 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.2 dan *learning rate* 0.4 sebesar $1.461730058 \cong 146.17\%$. Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter dengan *momentum* 0.8 dan *learning rate* 0.9 sebesar $0.89854733 \cong 89.85\%$. Sedangkan pada Gambar 6.36 menunjukkan nilai RMSE untuk K2M2 dengan nilai tertinggi 55,37702672 (mc 0.1 lr 0.6) dan nilai terendah 23,31147242 (mc 0.9 lr 0.9)



Gambar 6.35. Hasil MAPE K2M2

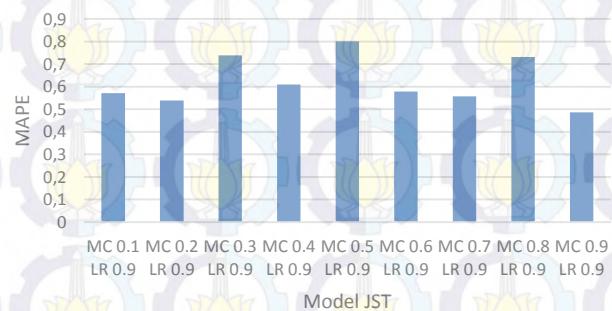


Gambar 6.36. Hasil RMSE K2M2

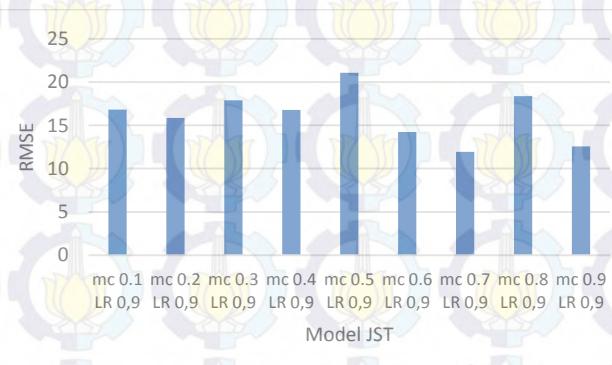
6.2.3.3. Hasil MAPE Model K2M3 (JST 3)

Pada Gambar 6.37 terlihat bahwa nilai MAPE untuk K2M3 berubah secara fluktuatif. Nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.5 dan *learning rate* 0.9 sebesar $0.801340969 \cong 80.13\%$. Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter dengan *momentum* 0.9 dan *learning rate* 0.9 sebesar $0.486589698 \cong 48.6\%$. Sedangkan pada Gambar 6.36 menunjukkan nilai RMSE untuk K2M3 dengan nilai tertinggi

21,07528418 (mc 0.5 lr 0.9) dan nilai terendah 11,9494252 (mc 0.7 lr 0.9).



Gambar 6.37. Hasil MAPE K2M3

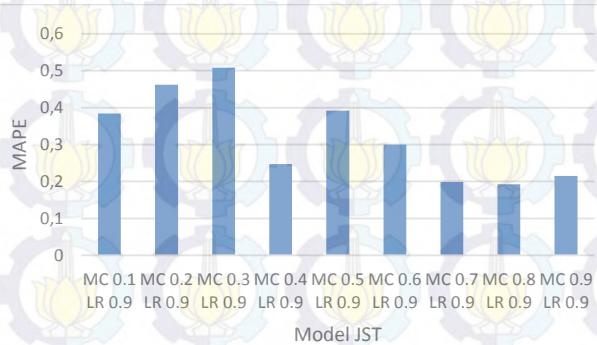


Gambar 6.38. Hasil RMSE K2M3

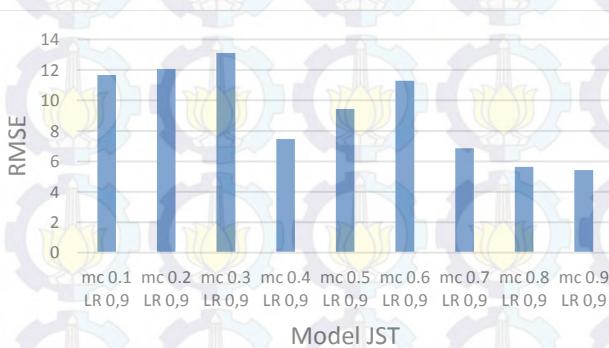
6.2.3.4. Hasil MAPE Model K2M4 (JST 4)

Pada Gambar 6.39 nilai MAPE yang paling tinggi yaitu parameter dengan mc 0.5 dan lr 0.9 sebesar $0.508283381 \cong 50.82\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan mc 0.8 dan lr 0.9 sebesar $0.192708186 \cong 19.27\%$. Sedangkan pada

Gambar 6.40 menunjukkan nilai RMSE untuk K2M4 dengan nilai tertinggi 13,1223006 (mc 0.3 lr 0.9) dan nilai terendah 5,426947272 (mc 0.9 lr 0.9)



Gambar 6.39. Hasil MAPE K2M4



Gambar 6.40. Hasil RMSE K2M4

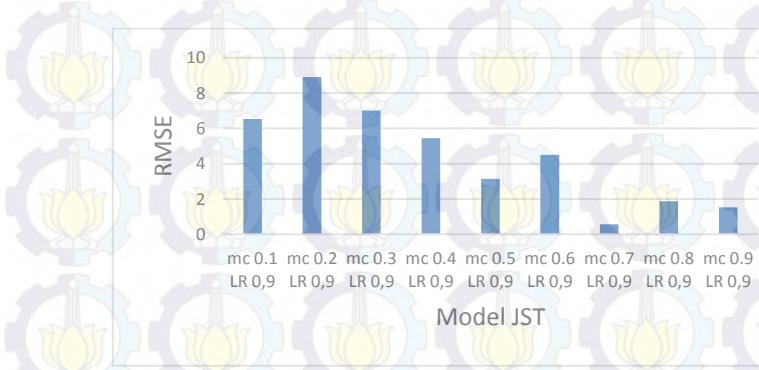
6.2.3.5. Hasil MAPE Model K2M5 (JST 5)

Pada Gambar 6.41 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.2 dan *learning rate* 0.9 sebesar 0.255253709 \cong 25.52%. Sedangkan nilai MAPE yang paling kecil

yaitu parameter dengan *momentum* 0.7 dan *learning rate* 0.9 sebesar $0.16558448 \cong 16.55\%$. Sedangkan pada Gambar 6.42 menunjukkan nilai RMSE untuk K2M5 dengan nilai tertinggi 8,913954945 (mc 0.2 lr 0.9) dan nilai terendah 0,56521533 (mc 0.7 lr 0.9)



Gambar 6.41. Hasil MAPE K2M5

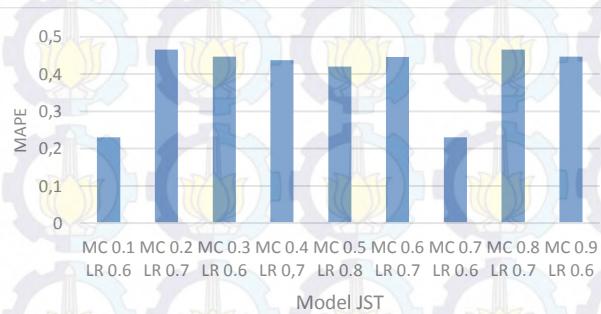


Gambar 6. 42. Hasil RMSE K2M5

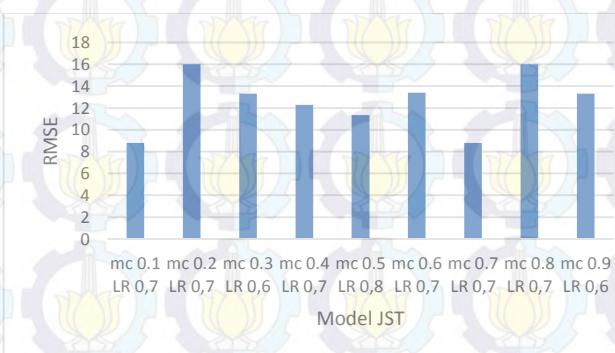
6.2.3.6. Hasil MAPE Model K2M6 (JST 6)

Pada Gambar 6.43 nilai MAPE yang paling tinggi yaitu parameter dengan (mc 0.2 lr 0.7) sebesar $0.465877141 \cong 46.58\%$. Sedangkan

nilai MAPE yang paling kecil yaitu parameter dengan (mc 0.1 lr 0.6) sebesar $0.229941264 \cong 22.99\%$. Sedangkan pada Gambar 6.44 menunjukkan nilai RMSE untuk K2M6 dengan nilai tertinggi 15,99780024 (mc 0.2 lr 0.7) dan nilai terendah 8,797746441 (mc 0.1 lr 0.7)



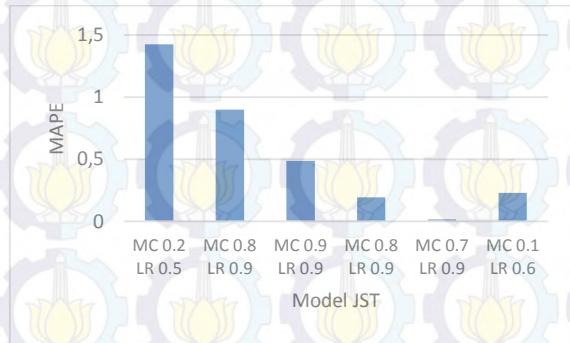
Gambar 6.43. Hasil MAPE K2M6



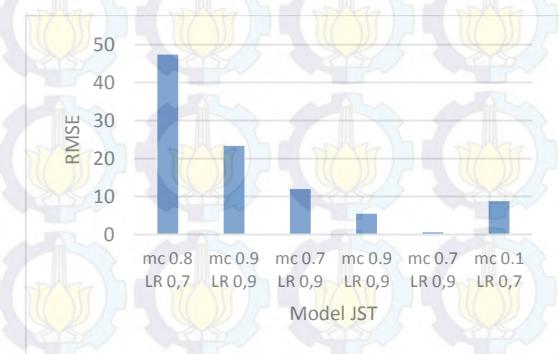
Gambar 6. 44. Hasil RMSE K2M6

6.2.3.7. Hasil MAPE Optimal Produk K2

Pada Gambar 6.45 dapat diketahui bahwa untuk produk K2 (Nota 2 Layer) nilai MAPE semakin turun dari JST 1 ke JST 5, namun mengalami kenaikan pada JST 6. Sehingga model yang paling optimal K2M5 (JST 5) parameter *momentum* 0.7 dan *learning rate* 0.9 dengan nilai MAPE sebesar $0.016558448 \cong 1.65\%$. Selain itu pada untuk nilai RMSE pada Gambar 6.46 juga terus turun hingga JST 5 kemudian naik kembali pada JST 6. Sehingga model terbaik untuk RMSE yaitu K2M5 (JST 5) parameter *momentum* 0.7 dan *learning rate* 0.9 dengan nilai sebesar 0,56521533.



Gambar 6.45. MAPE Training Optimal Produk K2



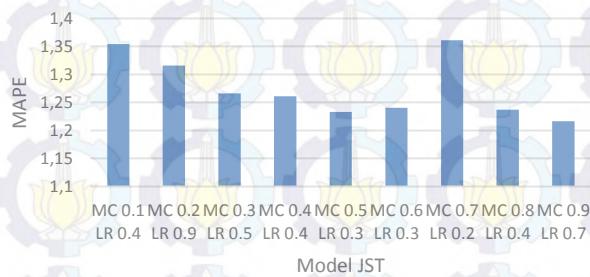
Gambar 6. 46. RMSE Training Optimal Produk K2

6.2.4. Hasil Pelatihan (*Training*) Produk K3

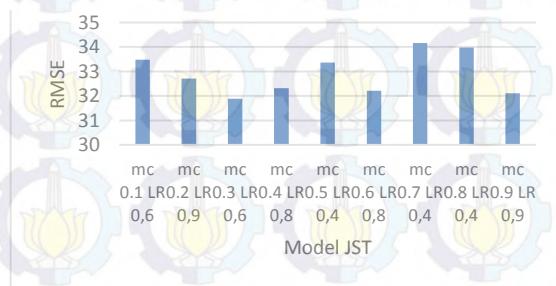
Hasil *Training* atau pelatihan pada setiap model JST pada produk K3 (Nota 3 Layer).

6.2.4.1. Hasil MAPE Model K3M1

Pada Gambar 6.47. **Error! Reference source not found.**⁴⁷ nilai MAPE yang paling tinggi yaitu parameter dengan *mc* 0.7 dan *lr* 0.2 sebesar $1.36074164 \cong 136.074\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *mc* 0.8 dan *lr* 0.9 sebesar $1.216305481 \cong 121.63\%$. Sedangkan pada Gambar 6.48 menunjukkan nilai RMSE untuk K3M1 dengan nilai tertinggi 34,16286971 (*mc* 0.7 *lr* 0.4) dan nilai terendah 31,87874711 (*mc* 0.3 *lr* 0.6)



Gambar 6.47. Hasil MAPE K3M1



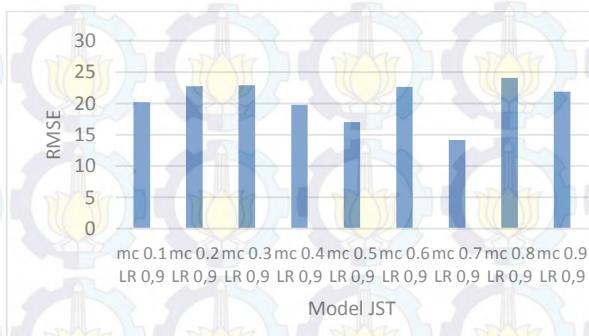
Gambar 6. 48. Hasil RMSE K3M1

6.2.4.2. Hasil MAPE Model K3M2 (JST 2)

Pada Gambar 6.49 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.3 dan *learning rate* 0.6 sebesar $0.865190895 \cong 86.51\%$ Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter dengan *momentum* 0.5 dan *learning rate* 0.9 sebesar $0.62459656 \cong 62.45\%$. Sedangkan pada Gambar 6.50 menunjukkan nilai RMSE untuk K3M2 dengan nilai tertinggi 24,08014963 (mc 0.8 lr 0.9) dan nilai terendah 14,18494576 (mc 0.7 lr 0.9)



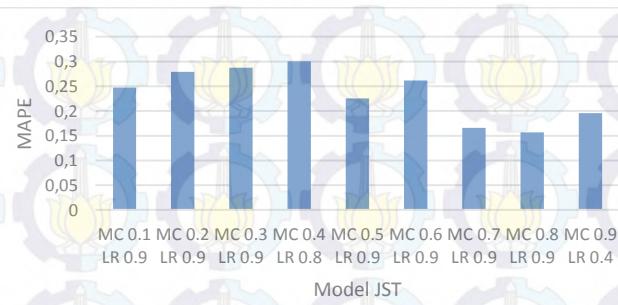
Gambar 6.49. Hasil MAPE K3M2



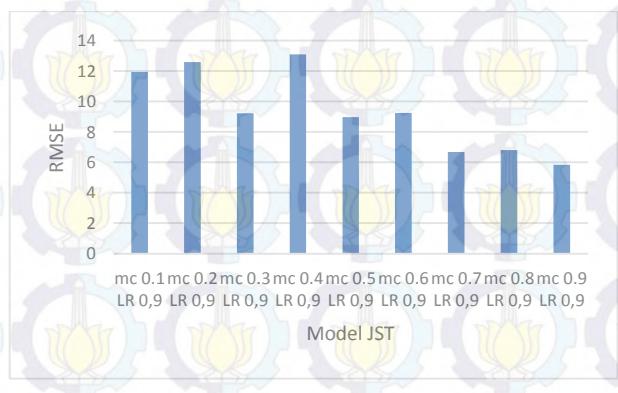
Gambar 6.50. Hasil RMSE K3M2

6.2.4.3. Hasil MAPE Model K3M3 (JST 3)

Pada Gambar 6.51 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.4 dan *learning rate* 0.8 sebesar $0.300740267 \cong 30.07\%$. Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter dengan *momentum* 0.8 dan *learning rate* 0.9 sebesar $0.156712342 \cong 15.67\%$. Sedangkan pada Gambar 6.52 menunjukkan nilai RMSE untuk K3M3 dengan nilai tertinggi 13,08520676 (mc 0.4 lr 0.9) dan nilai terendah 5,831612005 (mc 0.9 lr 0.9)



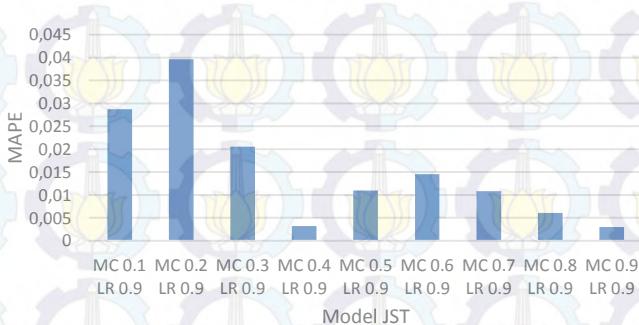
Gambar 6.51. Hasil MAPE K3M3



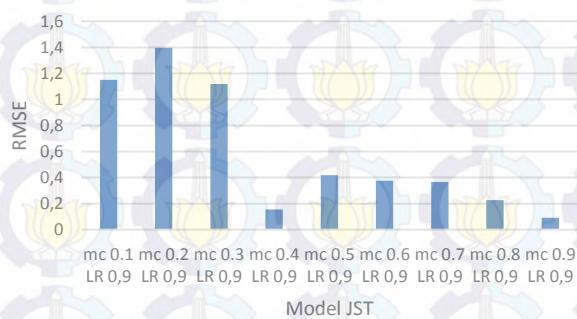
Gambar 6.52. Hasil RMSE K3M3

6.2.4.4. Hasil MAPE Model K3M4 (JST 4)

Pada Gambar 6.53 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.2 dan *learning rate* 0.9 sebesar $0.039663823 \cong 3.96\%$ Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter dengan *momentum* 0.9 dan *learning rate* 0.9 sebesar $0.002990031 \cong 0.299\%$. Sedangkan pada Gambar 6.54 menunjukkan nilai RMSE untuk K3M4 dengan nilai tertinggi 1,397673389 (mc 0.2 lr 0.9) dan nilai terendah 0,09067599 (mc 0.9 lr 0.9)



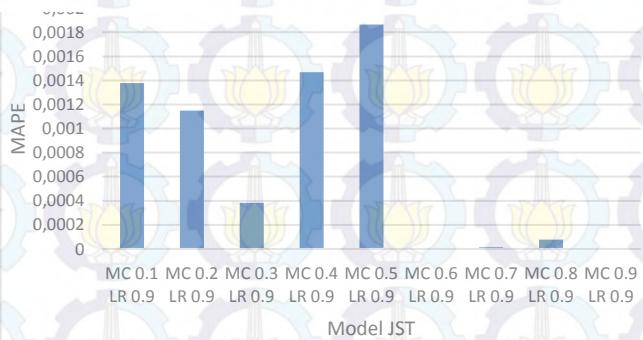
Gambar 6.53. Hasil MAPE K3M4



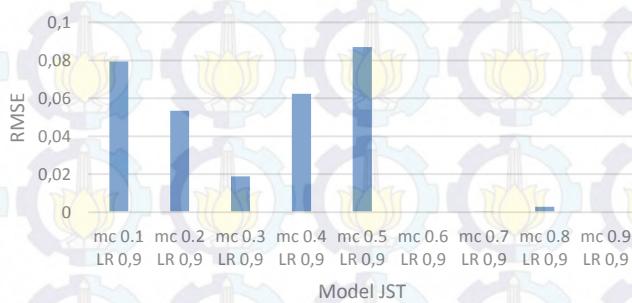
Gambar 6. 54. Hasil RMSE K3M4

6.2.4.5. Hasil MAPE Model K3M5 (JST 5)

Pada Gambar 6.55 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.5 dan *learning rate* 0.9 sebesar $0.001865944 \cong 0.187\%$ Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter dengan *momentum* 0.6 dan *learning rate* 0.9 sebesar $3.51017E - 08 \cong 0.00000351\%$. Sedangkan pada Gambar 6.56 menunjukkan nilai RMSE untuk K3M5 dengan nilai tertinggi 0,087032438 (mc 0.5 lr 0.9) dan nilai terendah 1,3955E-06 (mc 0.6 lr 0.9)



Gambar 6.55. Hasil MAPE K3M5



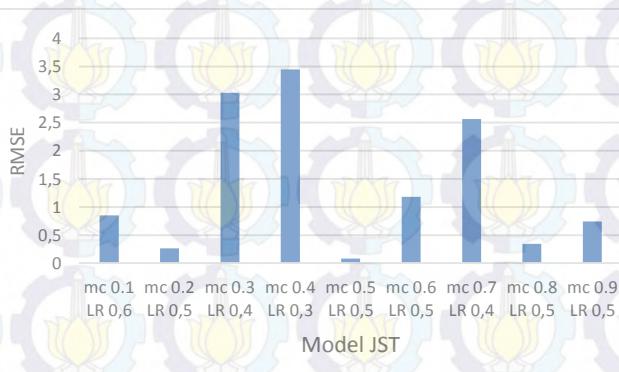
Gambar 6.56. Hasil RMSE K3M5

6.2.4.6. Hasil MAPE Model K3M6 (JST 6)

Pada Gambar 6.57 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.3 dan *learning rate* 0.3 sebesar $0.095700748 \cong 9.57\%$. Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter dengan *momentum* 0.5 dan *learning rate* 0.6 sebesar $0.001603827 \cong 0.16\%$. Sedangkan pada Gambar 6.58 menunjukkan nilai RMSE untuk K3M6 dengan nilai tertinggi 3,443320225 (mc 0.4 lr 0.3) dan nilai terendah 0,079585394 (mc 0.5 lr 0.5)



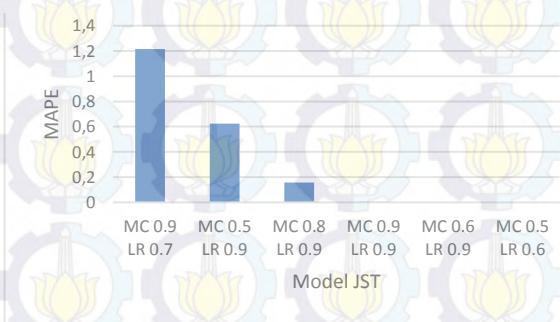
Gambar 6. 57. Hasil MAPE K3M6



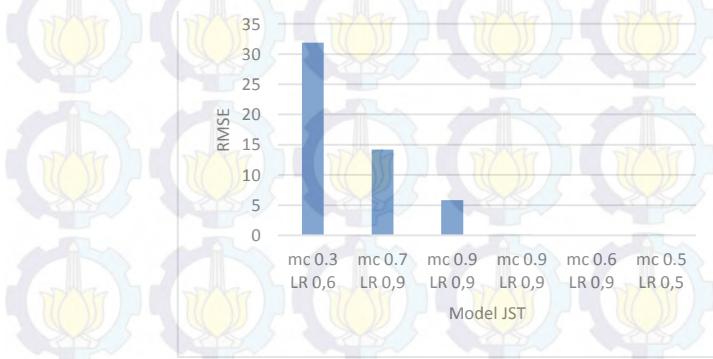
Gambar 6.58. Hasil RMSE K3M6

6.2.4.7. Hasil MAPE Optimal Produk K3

Pada Gambar 6.59 dapat diketahui bahwa untuk produk K3 (Nota 3 Layer) nilai MAPE semakin turun dari JST 1 ke JST 5, sehingga hasil peramalan semakin mendekati target. Namun, nilai MAPE pada JST 5 ke JST 6 naik kembali. Sehingga, model yang paling optimal pada produk K3 yaitu model K3M5 (JST 5) parameter mc 0.6 dan lr 0.9 dengan nilai MAPE sebesar $3.51017E - 08 \approx 0.0000035\%$. Selain itu pada untuk nilai RMSE pada Gambar 6.60 juga terus turun hingga JST 5 kemudian naik kembali pada JST 6. Sehingga model terbaik untuk RMSE yaitu K3M5 (JST 5) parameter mc 0.6 dan lr 0.9 dengan nilai sebesar $1,3955E - 06$



Gambar 6. 59. MAPE Training Optimal Produk K3



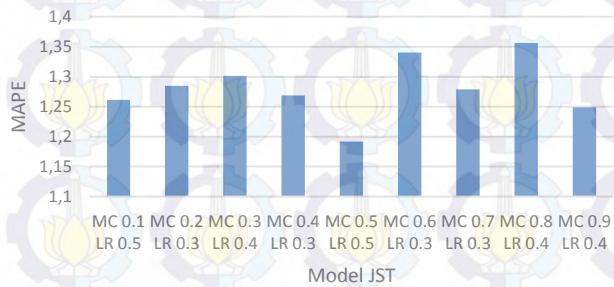
Gambar 6. 60. RMSE Training Optimal Produk K3

6.2.5. Hasil Pelatihan (*Training*) Produk K4

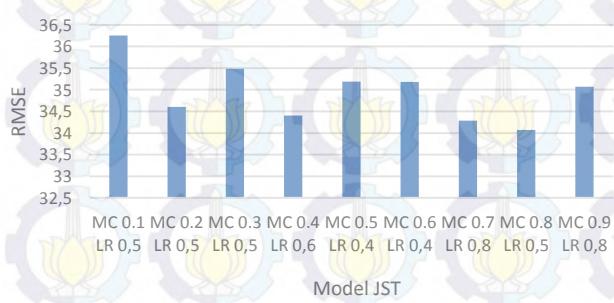
Hasil *Training* atau pelatihan pada setiap model JST pada produk K4 (Nota 4 Layer)

6.2.5.1. Hasil MAPE Model K4M1 (JST 1)

Pada Gambar 6.61 nilai MAPE yang paling tinggi yaitu parameter dengan *mc* 0.8 dan *lr* 0.4 sebesar $1.356415063 \cong 135.64\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *mc* 0.5 dan *lr* 0.5 sebesar $1.192126142 \cong 119.21\%$. Sedangkan pada Gambar 6.62 menunjukkan nilai RMSE untuk K4M1 dengan nilai tertinggi 36,25685623 (*mc* 0.1 *lr* 0.) dan nilai terendah 34,06930685 (*mc* 0.8 *lr* 0.5)



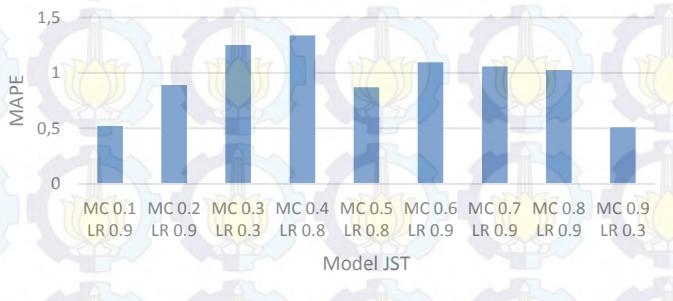
Gambar 6. 61. Hasil MAPE K4M1



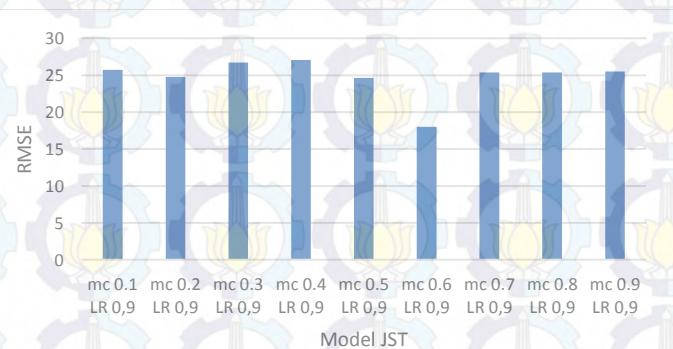
Gambar 6. 62. Hasil RMSE K4M1

6.2.5.2. Hasil MAPE Model K4M2 (JST 2)

Pada Gambar 6.63 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.4 dan *learning rate* 0.8 sebesar $1.337361738 \cong 133.73\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.9 dan *learning rate* 0.3 sebesar $0.508732399 \cong 50.87\%$. Sedangkan pada Gambar 6.64 menunjukkan nilai RMSE untuk K4M2 dengan nilai tertinggi 27,0616298 (mc 0.4 lr 0.9) dan nilai terendah 17,99953422 (mc 0.6 lr 0.9)



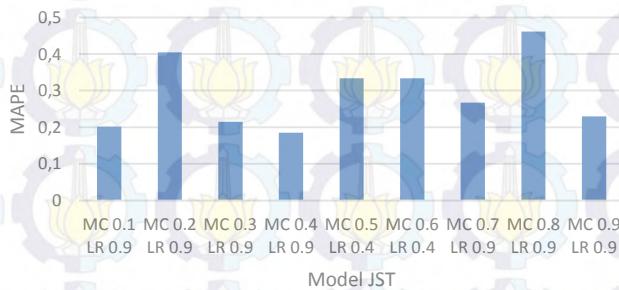
Gambar 6. 63. Hasil MAPE K4M2



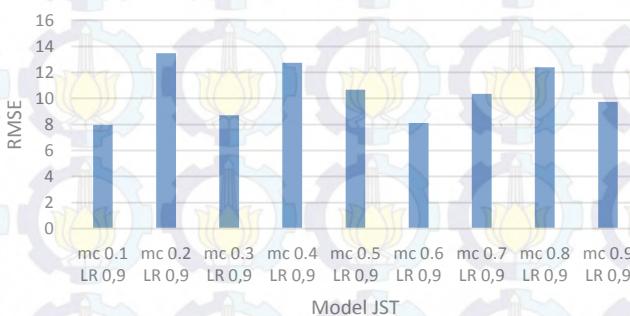
Gambar 6. 64. Hasil RMSE K4M2

6.2.5.3. Hasil MAPE Model K4M3 (JST 3)

Pada Gambar 6.65 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.8 dan *learning rate* 0.9 sebesar $0.461563934 \cong 46.15\%$. Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter dengan *momentum* 0.4 dan *learning rate* 0.9 sebesar $0.184927041 \cong 18.49\%$. Sedangkan pada Gambar 6.66 menunjukkan nilai RMSE untuk K4M3 dengan nilai tertinggi 13,48195118 (mc 0.2 lr 0.9) dan nilai terendah 7,976906737 (mc 0.1 lr 0.9)



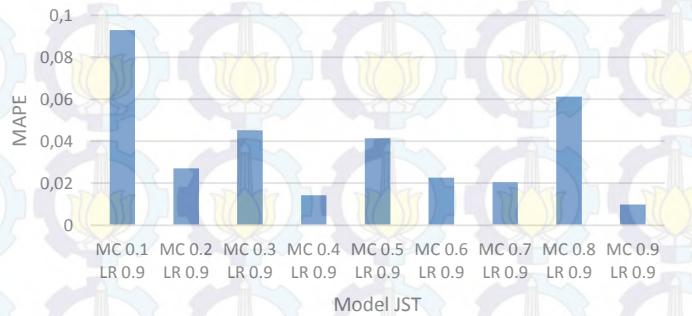
Gambar 6.65. Hasil MAPE K4M3



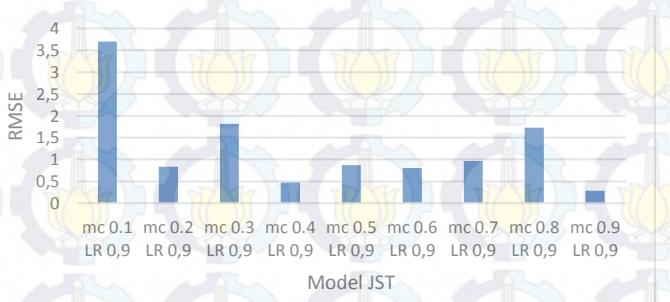
Gambar 6.66. Hasil RMSE K4M3

6.2.5.4. Hasil MAPE Model K4M4 (JST 4)

Pada Gambar 6.67 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.1 dan *learning rate* 0.9 sebesar $0.093049512 \cong 9.30\%$. Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter dengan *momentum* 0.9 dan *learning rate* 0.9 sebesar $0.0097916622 \cong 0.98\%$. Sedangkan pada Gambar 6.68 menunjukkan nilai RMSE untuk K4M4 dengan nilai tertinggi 3,698570914 (mc 0.1 lr 0.9) dan nilai terendah 0,285576299 (mc 0.9 lr 0.9)



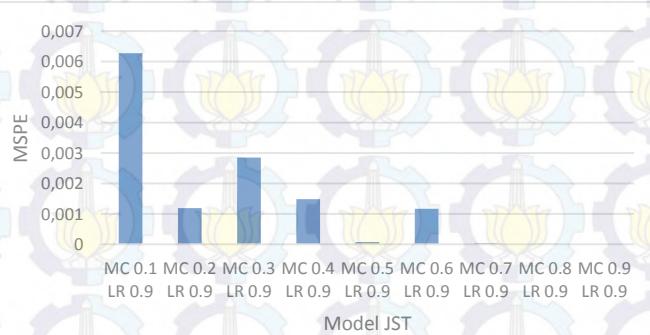
Gambar 6.67. Hasil MAPE K4M4



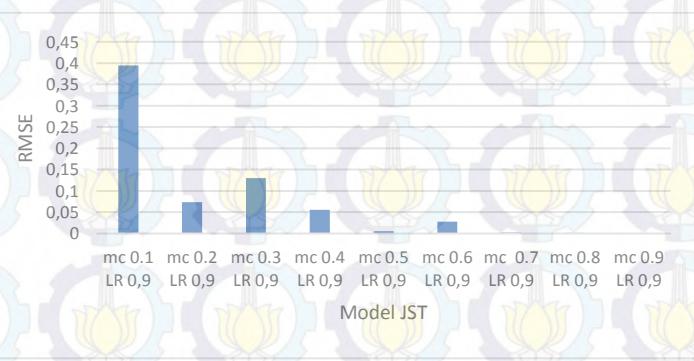
Gambar 6.68. Hasil RMSE K4M4

6.2.5.5. Hasil MAPE Model K4M5 (JST 5)

Pada Gambar 6.69 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.1 dan *learning rate* 0.9 sebesar $0.06274235 \cong 6.27\%$. Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter *momentum* 0.9 dan *learning rate* 0.9 sebesar $7.99998E - 06 \cong 0.000799\%$. Sedangkan pada Gambar 6.68 menunjukkan nilai RMSE untuk K4M5 dengan nilai tertinggi 0,394826008 (mc 0.1 lr 0.9) dan nilai terendah 0,000415366 (mc 0.9 lr 0.9)



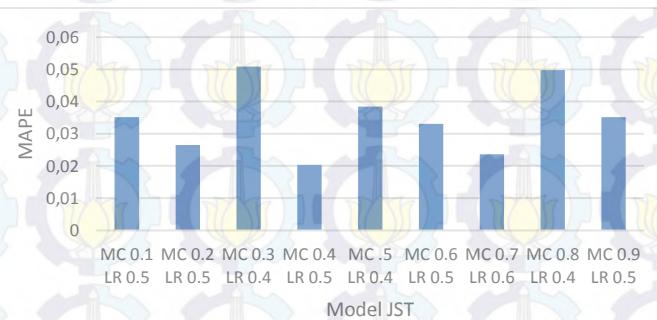
Gambar 6.69. Hasil MAPE K4M5



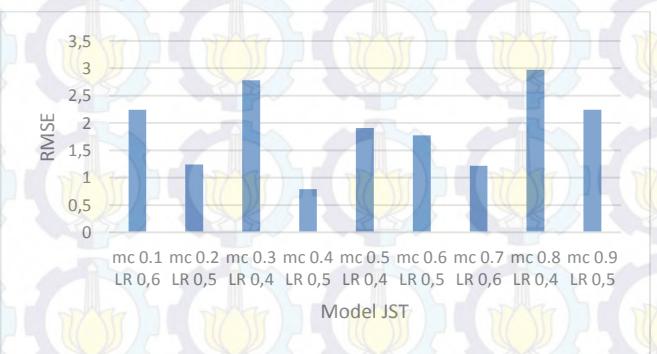
Gambar 6.70. Hasil RMSE K4M5

6.2.5.6. Hasil MAPE Model K4M6 (JST 6)

Pada Gambar 6.71 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.3 dan *learning rate* 0.4 sebesar $0.050899685 \cong 5.08\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.4 dan *learning rate* 0.5 sebesar $0.02031934 \cong 2.03\%$. Sedangkan pada Gambar 6.72 menunjukkan nilai RMSE untuk K4M6 dengan nilai tertinggi 2,973597177 (mc 0.8 lr 0.4) dan nilai terendah 0,791068639 (mc 0.4 lr 0.5)



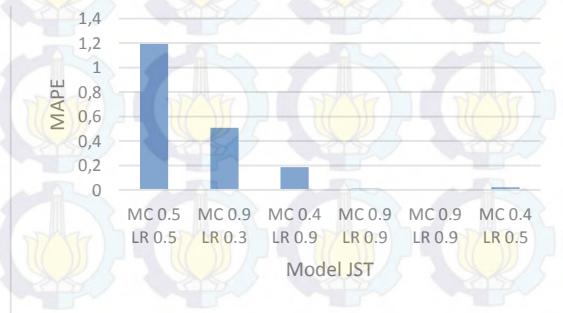
Gambar 6.71. Hasil MAPE K4M6



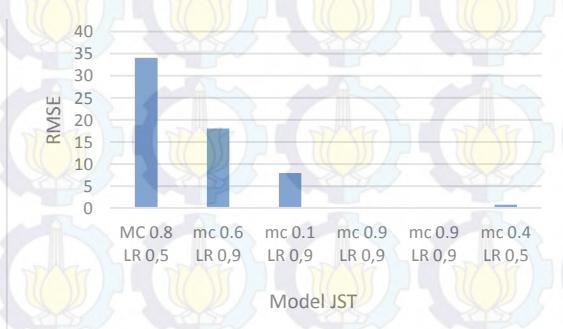
Gambar 6.72. Hasil RMSE K4M6

6.2.5.7. Hasil MAPE Optimal Produk K4

Pada Gambar 6.73 dapat diketahui bahwa untuk produk K4 (Nota 4 Layer) nilai MAPE semakin turun dari JST 1 ke JST 5, sehingga hasil peramalan semakin mendekati target. Namun, nilai MAPE pada JST 5 ke JST 6 mengalami kenaikan. Sehingga model yang paling optimal pada produk K4 yaitu model K4M5 (JST 5) parameter dengan *momentum* 0.9 dan *learning rate* 0.9 dengan nilai MAPE sebesar $7.99998E - 06 \cong 0.0008\%$. Selain itu pada untuk nilai RMSE pada Gambar 6.74 juga terus turun hingga JST 5 kemudian naik kembali pada JST 6. Sehingga model terbaik untuk RMSE yaitu K4M5 (JST 5) parameter *mc* 0.9 dan *lr* 0.9 dengan nilai sebesar 0,000415366



Gambar 6. 73. MAPE Training Optimal produk K4



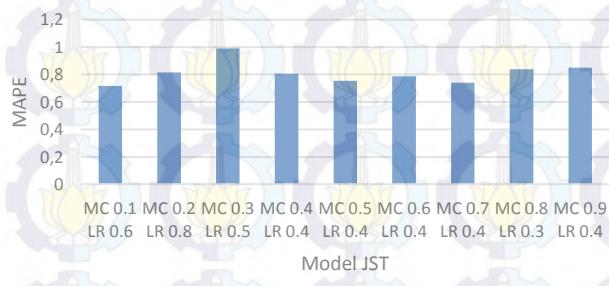
Gambar 6. 74. RMSE Training Optimal Produk K4

6.2.6. Hasil Pelatihan (*Training*) Produk K5

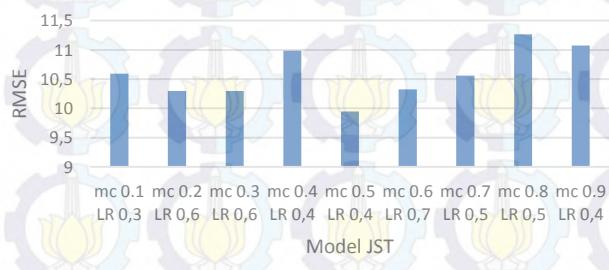
Hasil *Training* atau pelatihan pada setiap model JST pada produk K5 (Nota 5 Layer).

6.2.6.1. Hasil MAPE Model K5M1 (JST 1)

Pada Gambar 6.75 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.3 dan *learning rate* 0.5 sebesar $0.0988578354 \cong 98.85\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.1 dan *learning rate* 0.6 sebesar $0.715835814 \cong 71.58\%$. Sedangkan pada Gambar 6.76 menunjukkan nilai RMSE untuk K5M1 dengan nilai tertinggi 11,26478312 (mc 0.8 lr 0.5) dan nilai terendah 9,949875651(mc 0.5 lr 0.4)



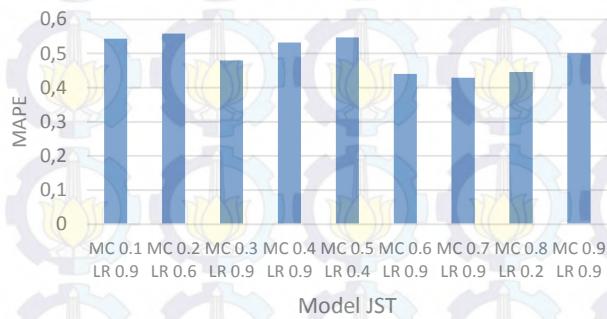
Gambar 6.75. Hasil MAPE K5M1



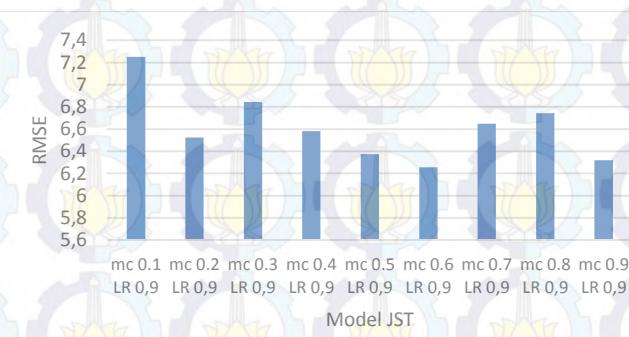
Gambar 6.76. Hasil RMSE K5M1

6.2.6.2. Hasil MAPE Model K5M2 (JST 2)

Pada Gambar 6.77 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.2 dan *learning rate* 0.6 sebesar $0.55836286 \cong 55.83\%$ Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.7 dan *learning rate* 0.9 sebesar $0.429053143 \cong 42.90\%$. Sedangkan pada Gambar 6.78 menunjukkan nilai RMSE untuk K5M2 dengan nilai tertinggi 7,251285926 (mc 0.1 lr 0.9) dan nilai terendah 6,255795014 (mc 0.6 lr 0.9)



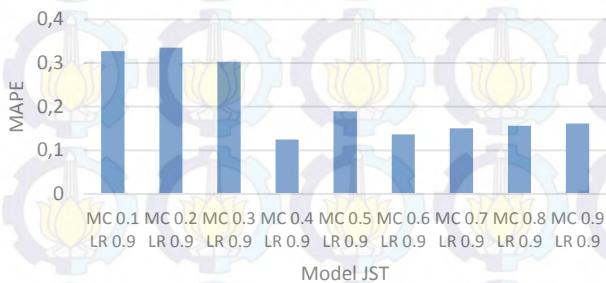
Gambar 6.77. Hasil MAPE K5M2



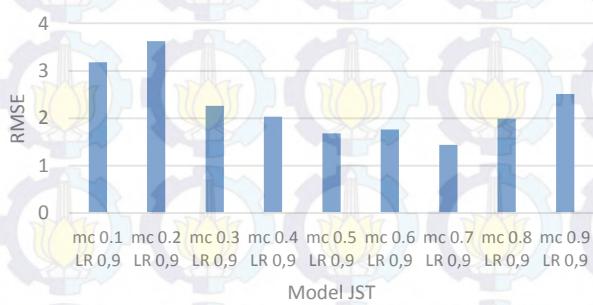
Gambar 6.78. Hasil RMSE K5M2

6.2.6.3. Hasil MAPE Model K5M3 (JST 3)

Pada Gambar 6.79 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.2 dan *learning rate* 0.9 sebesar $0.335469965 \cong 33.54\%$. Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter dengan *momentum* 0.4 dan *learning rate* 0.9 sebesar $0.12142197 \cong 12.14\%$. Sedangkan pada Gambar 6.80 menunjukkan nilai RMSE untuk K5M3 dengan nilai tertinggi 3,623049176 (mc 0.2 lr 0.9) dan nilai terendah 1,43677193 (mc 0.7 lr 0.9).



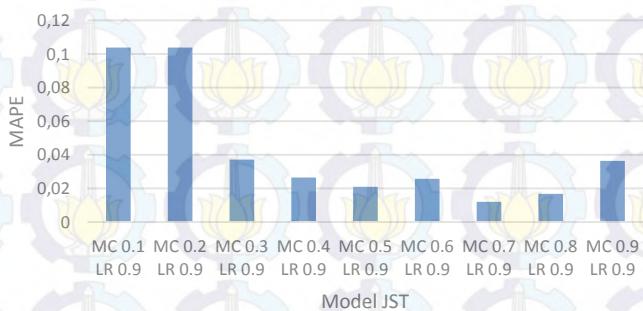
Gambar 6.79. Hasil MAPE K5M3



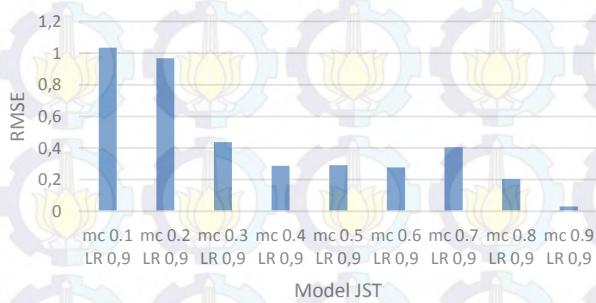
Gambar 6.80. Hasil RMSE K5M3

6.2.6.4. Hasil MAPE Model K5M4 (JST 4)

Pada Gambar 6.81 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.2 dan *learning rate* 0.9 sebesar $0.103916517 \cong 10.39\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.7 dan *learning rate* 0.9 sebesar $0.011938037 \cong 1.19\%$. Sedangkan pada Gambar 6.82 menunjukkan nilai RMSE untuk K5M4 dengan nilai tertinggi 1,033284989 (mc 0.1 lr 0.9) dan nilai terendah 0,030738029 (mc 0.9 lr 0.9).



Gambar 6.81. Hasil MAPE K5M4



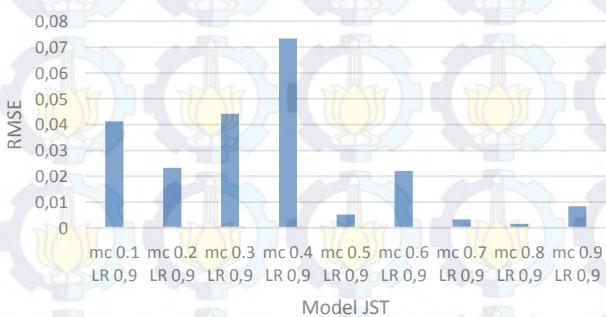
Gambar 6.82. Hasil RMSE K5M4

6.2.6.5. Hasil MAPE Model K5M5 (JST 5)

Pada Gambar 6.83 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.4 dan *learning rate* 0.9 sebesar $0.005763184 \cong 0.58\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.8 dan *learning rate* 0.9 sebesar $0.000125351 \cong 0.0125\%$. Sedangkan pada Gambar 6.84 menunjukkan nilai RMSE untuk K5M5 dengan nilai tertinggi 0,073309332 (mc 0.4 lr 0.9) dan nilai terendah 0,001580128 (mc 0.8 lr 0.9).



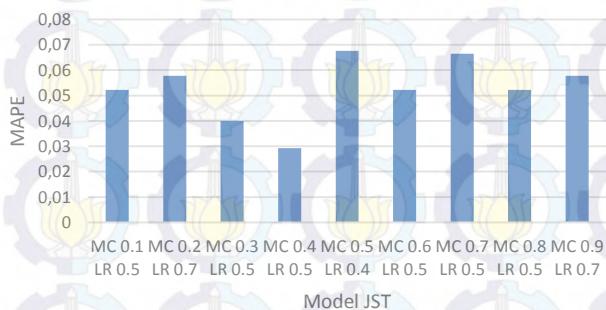
Gambar 6.83. Hasil MAPE K5M5



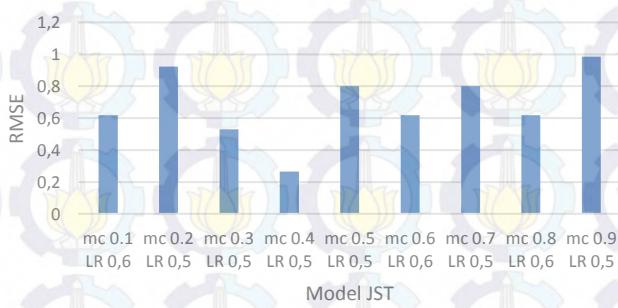
Gambar 6.84. Hasil RMSE K5M5

6.2.6.6. Hasil MAPE Model K5M6 (JST 6)

Pada Gambar 6.85 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.5 dan *learning rate* 0.4 sebesar $0.067554171 \cong 6.75\%$. Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter dengan *momentum* 0.4 dan *learning rate* 0.5 sebesar $0.029246984 \cong 2.92\%$. Sedangkan pada Gambar 6.86 menunjukkan nilai RMSE untuk K5M6 dengan nilai tertinggi 0,984657966 (mc 0.9 lr 0.5) dan nilai terendah 0,265497925 (mc 0.4 lr 0.5)



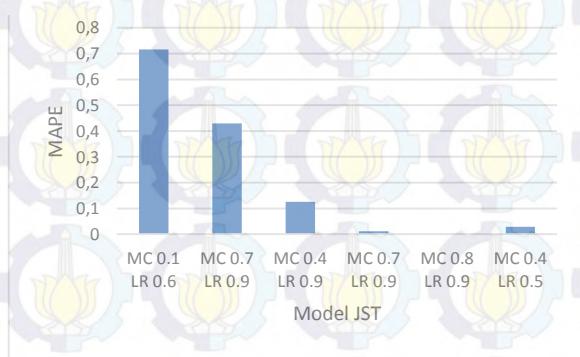
Gambar 6. 85. Hasil MAPE K5M6



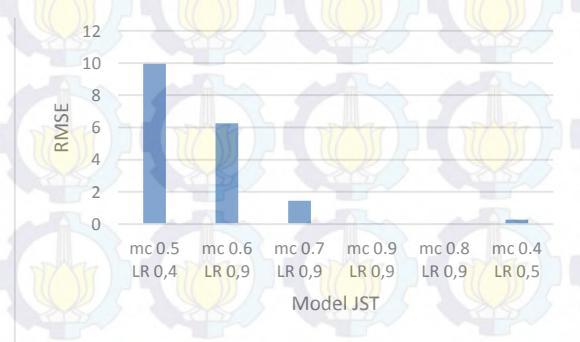
Gambar 6. 86. Hasil RMSE K5M6

6.2.6.7. Hasil MAPE Optimal Produk K5

Pada Gambar 6.87 dapat diketahui bahwa untuk produk K5 (Nota 5 Layer) nilai MAPE semakin turun dari JST 1 ke JST 5, sehingga hasil peramalan semakin mendekati target. Namun nilai MAPE naik pada JST 6. Sehingga, model yang paling optimal pada produk K5 yaitu model K5M5 (JST 5) parameter *momentum* 0.8 dan *learning rate* 0.9 dengan nilai MAPE sebesar $0.000125351 \cong 0.0125\%$. Selain itu pada untuk nilai RMSE pada Gambar 6.88 juga terus turun hingga JST 5 kemudian naik kembali pada JST 6. Sehingga model terbaik untuk RMSE yaitu K5M5 (JST 5) parameter *mc* 0.8 dan *lr* 0.9 dengan nilai sebesar 0,001580128



Gambar 6. 87. MAPE Training Optimal Produk K5



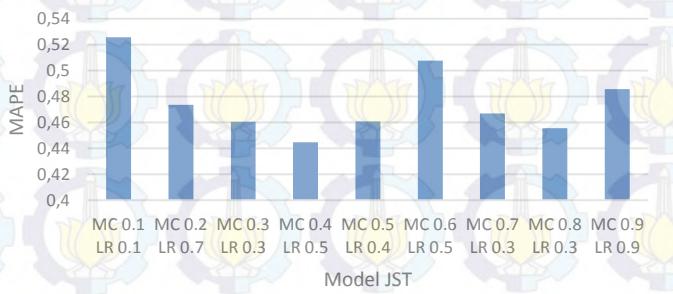
Gambar 6. 88. RMSE Training Optimal Produk K5

6.2.7. Hasil Pelatihan (*Training*) Produk K6

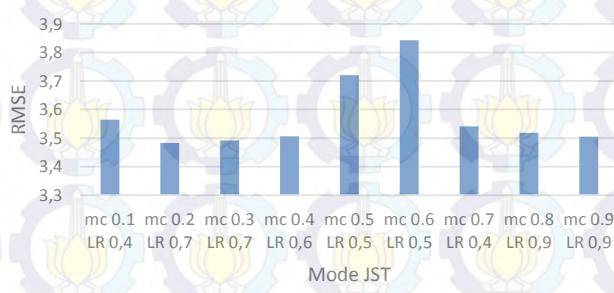
Hasil *Training* atau pelatihan pada setiap model JST pada produk K6 (Nota 6 Layer)

6.2.7.1. Hasil MAPE Model K6M1 (JST 1)

Pada Gambar 6.89 nilai MAPE yang paling tinggi yaitu parameter dengan $mc\ 0.1$ dan $lr\ 0.1$ sebesar $0.525809162 \cong 52.58\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan $mc\ 0.4$ dan $lr\ 0.5$ sebesar $0.444706276 \cong 44.47\%$. Sedangkan pada Gambar 6.90 menunjukkan nilai RMSE untuk K6M1 dengan nilai tertinggi 3,842745557 (mc 0.6 lr 0.5) dan nilai terendah 3,482515318 (mc 0.2 lr 0.7)



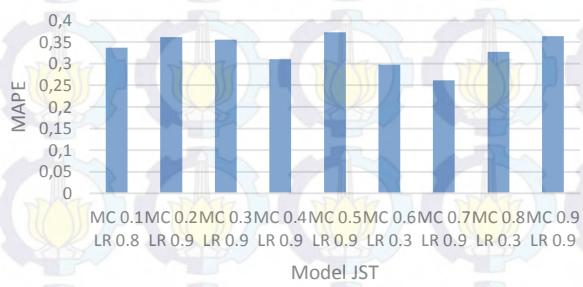
Gambar 6.89. Hasil MAPE K6M1



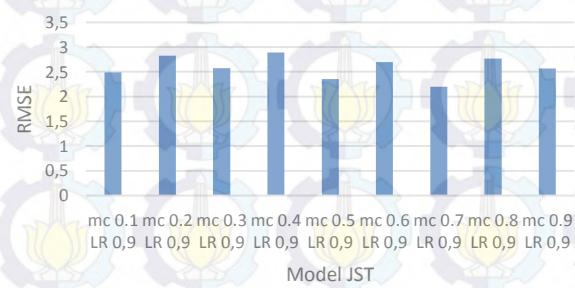
Gambar 6.90. Hasil RMSE K6M1

6.2.7.2. Hasil MAPE Model K6M2 (JST 2)

Pada Gambar 6.91 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.5 dan *learning rate* 0.9 sebesar $0.372611923 \cong 37.61\%$. Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter dengan *momentum* 0.7 dan *learning rate* 0.9 sebesar $0.261070141 \cong 26.10\%$. Sedangkan pada Gambar 6.92 menunjukkan nilai RMSE untuk K6M2 dengan nilai tertinggi 2,892827483 (mc 0.4 lr 0.9) dan nilai terendah 2,198334699 (mc 0.7 lr 0.9).



Gambar 6.91. Hasil MAPE K6M2



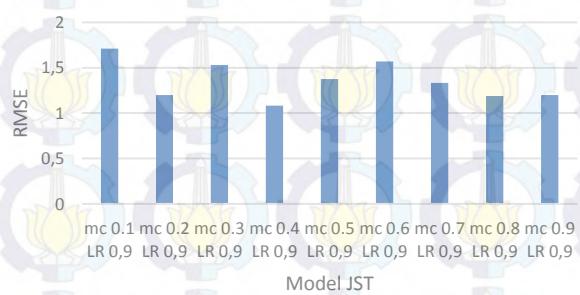
Gambar 6.92. Hasil RMSE K6M2

6.2.7.3. Hasil MAPE Model K6M3 (JST 3)

Pada Gambar 6.93 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.7 dan *learning rate* 0.9 sebesar $0.26055584 \cong 26.05\%$ Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.6 dan *learning rate* 0.9 sebesar $0.167104027 \cong 16.71\%$. Sedangkan pada Gambar 6.94 menunjukkan nilai RMSE untuk K6M3 dengan nilai tertinggi 1,708959049 (mc 0.1 lr 0.9) dan nilai terendah 1,081942094 (mc 0.4 lr 0.9)



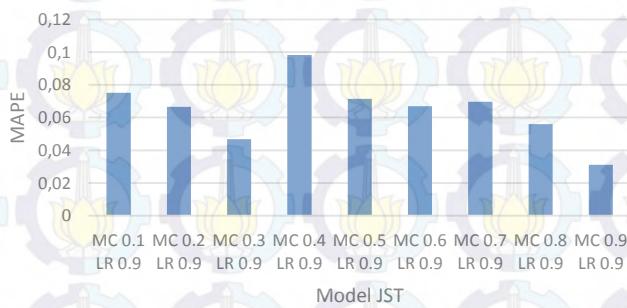
Gambar 6. 93. Hasil MAPE K6M3



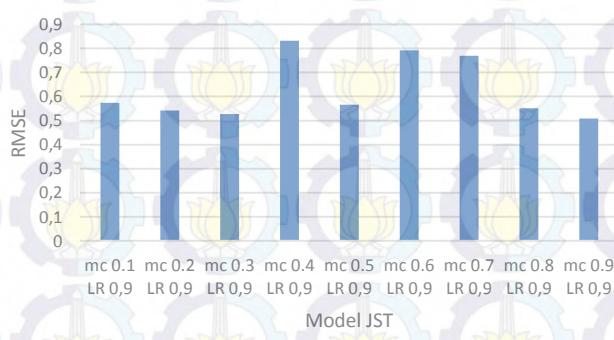
Gambar 6. 94. Hasil RMSE K6M3

6.2.7.4. Hasil MAPE Model K6M4 (JST 4)

Pada Gambar 6.95 nilai MAPE yang paling tinggi yaitu parameter *momentum* 0.4 dan *learning rate* 0.9 sebesar $0.098178338 \cong 9.81\%$ Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter *momentum* 0.9 dan *learning rate* 0.9 sebesar $0.031161651 \cong 3.11\%$. Sedangkan pada Gambar 6.96 menunjukkan nilai RMSE untuk K6M4 dengan nilai tertinggi 0,832665487 (mc 0.4 lr 0.9) dan nilai terendah 0,508151878 (mc 0.9 lr 0.9)



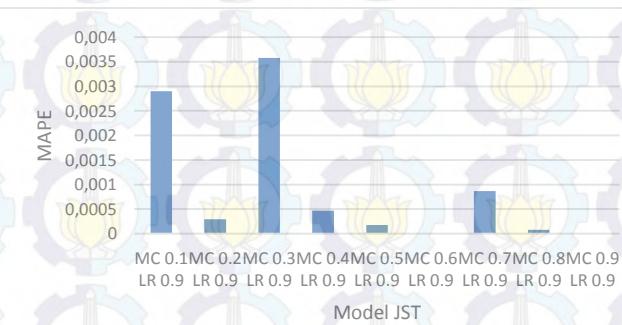
Gambar 6.95. Hasil MAPE K6M4



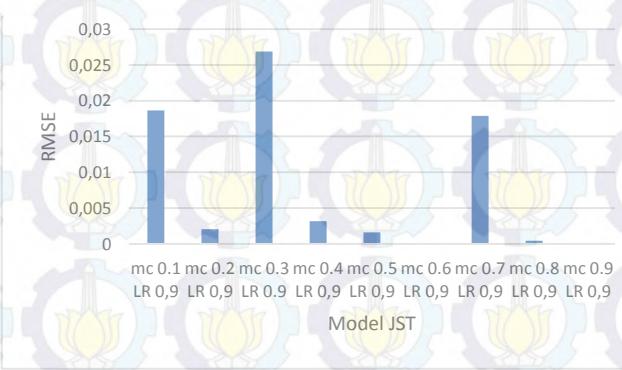
Gambar 6. 96. Hasil RMSE K6M4

6.2.7.5. Hasil MAPE Model K6M5 (JST 5)

Pada Gambar 6.97 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.3 dan *learning rate* 0.9 sebesar $0.00358092 \cong 0.36\%$. Sedangkan nilai MAPE yang paling kecil dan optimal yaitu parameter dengan *momentum* 0.9 dan *learning rate* 0.9 sebesar $1.40459E - 09 \cong 0.00000014\%$. Sedangkan pada Gambar 6.98 menunjukkan nilai RMSE untuk K6M5 dengan nilai tertinggi 0,026871814 (mc 0.3 lr 0.9) dan nilai terendah 1,55331E-08 (mc 0.9 lr 0.9)



Gambar 6. 97. Hasil MAPE K6M5



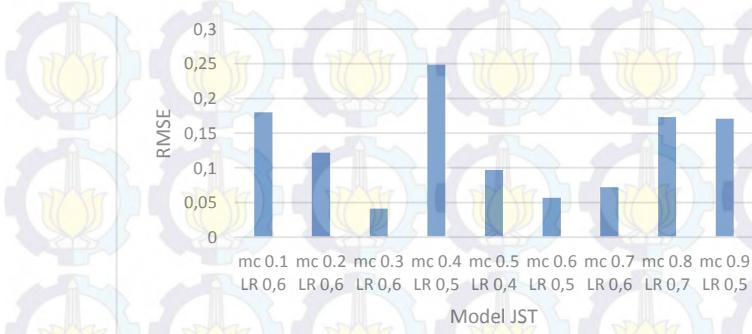
Gambar 6. 98. Hasil RMSE K6M5

6.2.7.6. Hasil MAPE Model K6M6 (JST 6)

Pada Gambar 6.99 nilai MAPE yang paling tinggi yaitu parameter dengan *momentum* 0.6 dan *learning rate* 0.6 sebesar $0.077188673 \cong 7.71\%$ Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.3 dan *learning rate* 0.6 sebesar $0.007095486 \cong 0.709\%$. Sedangkan pada Gambar 6.100 menunjukkan nilai RMSE untuk K6M6 dengan nilai tertinggi 0,248507977 (mc 0.4 lr 0.5) dan nilai terendah 0,041131259 (mc 0.3 lr 0.6)



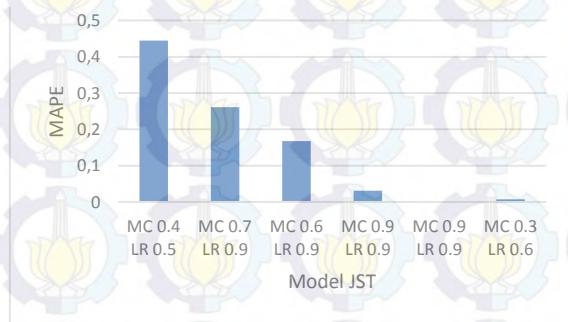
Gambar 6. 99. Hasil MAPE K6M6



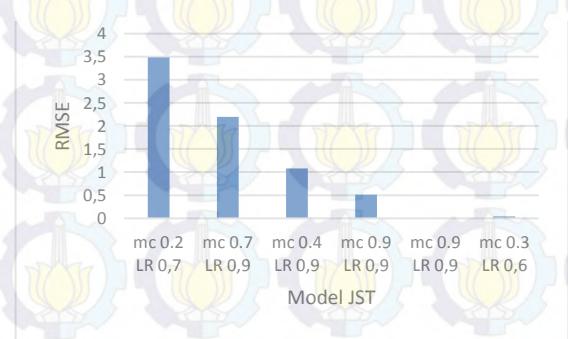
Gambar 6. 100. Hasil RMSE K6M6

6.2.7.7. Hasil MAPE Optimal Produk K6

Pada Gambar 6.101 dapat diketahui bahwa untuk produk K6 (Nota 6 Layer) nilai MAPE semakin turun dari JST 1 ke JST 5, sehingga hasil peramalan semakin mendekati target. Namun, nilai MAPE pada JST 6 kembali naik. Sehingga model yang paling optimal pada produk K6 yaitu model K6M5 (JST 5) parameter *momentum* 0.9 dan *learning rate* 0.9 dengan nilai MAPE sebesar $1.40459E - 09 \cong 0.00000014\%$. Selain itu pada untuk nilai RMSE pada Gambar 6.102 juga terus turun hingga JST 5 kemudian naik kembali pada JST 6. Sehingga model terbaik untuk RMSE yaitu K6M5 (JST 5) parameter *mc* 0.9 dan *lr* 0.9 dengan nilai sebesar $1.55331E - 08$



Gambar 6. 101. MAPE Optimal Training Produk K6



Gambar 6. 102. RMSE Optimal Training Produk K6

6.3. Hasil Uji Coba (*Testing*)

Testing (Uji coba) dilakukan terhadap arsitektur Jaringan Saraf Tiruan terbaik pada hasil *training* (pelatihan). Tujuan uji coba parameter adalah untuk mengetahui hasil peramalan pada proses pelatihan yang optimal telah sesuai dengan hasil peramalan pada proses uji coba dengan membandingkan nilai MAPE dan RMSE dari proses training dan proses testing. Nilai peramalan dikatakan baik jika memiliki nilai MAPE dan RMSE yang minimum. Hasil dari uji coba parameter optimal berada pada epoch 1000.

6.3.1. Hasil MAPE Uji Coba Produk Akumulasi (KU)

Model dan Parameter produk Akumulasi yang paling optimal pada proses training, selanjutnya dilakukan testing dan didapatkan hasil uji coba (*testing*) yaitu hasil MAPE dan RMSE *testing* untuk semua model lebih kecil dibandingkan MAPE dan RMSE *training*. Dimana parameter yang paling optimal pada proses training yaitu model KUM8 dengan MAPE 0.00000016% dan pada testing menghasilkan MAPE 0.000000077%. Sedangkan RMSE terkecil yaitu pada model KUM8 dengan RMSE $3,44208E - 08$. Meskipun nilai MAPE tersebut kurang dari 10% dan nilai RMSE juga sangat kecil. Namun, model tersebut belum tentu merupakan model yang optimal karena pada model KUM8 masih terjadi penurunan nilai error. Hal ini dapat terjadi karena jumlah data pada proses training samakin sedikit sehingga nilai error akan terus turun seiring dengan penambahan input. Sehingga dapat dikatakan bahwa parameter tersebut belum tentu cocok/sesuai untuk meramalkan data penjualan Nota Produk Akumulasi. Hasil MAPE dan RMSE *Training Testing* dapat dilihat pada Tabel 6.2.

6.3.2. Hasil MAPE Uji Coba Produk K1

Model dan Parameter produk K1 yang paling optimal pada proses training, selanjutnya dilakukan testing dan didapatkan hasil uji coba (*testing*) yaitu hasil MAPE dan RMSE *testing* untuk semua model lebih kecil dibandingkan MAPE dan RMSE *training*.

Dimana model yang paling optimal pada proses training yaitu model K1M5 dengan MAPE 0.011% dan pada testing menghasilkan MAPE 0.000008% dan nilai MAPE tersebut kurang dari 10%. Sedangkan RMSE terkecil yaitu pada model K1M5 dengan RMSE $1,64261E - 06$. Sehingga dapat dikatakan bahwa parameter cocok/sesuai untuk meramalkan data penjualan Nota Produk Nota K1. Hasil MAPE dan RMSE *Training Testing* dapat dilihat pada Tabel 6.3.

Tabel 6.2. Hasil MAPE dan RMSE Uji Coba Produk AKumulasi

Model	MC	LR	Testing (MAPE)	MC	LR	Testing (RMSE)
KUM1	0.4	0.5	0.155916323 $\cong 15.59\%$	0.1	0.6	47,73845
KUM2	0.8	0.6	0.027086971 $\cong 2.71\%$	0.4	0.6	23,38216
KUM3	0.9	0.5	4.20582E – 06 $\cong 0.000421\%$	0.9	0.6	0,000155
KUM4	0.4	0.7	6.59969E – 05 $\cong 0.007\%$	0.8	0.7	0,000478
KUM5	0.1	0.5	6.04606E – 05 $\cong 0.006\%$	0.1	0.5	0,01509
KUM6	0.2	0.5	3.51021E – 06 $\cong 0.000351\%$	0.2	0.5	0,000961
KUM7	0.5	0.7	1.02555E – 10 $\cong 0.0000000103\%$	0.2	0.5	3,88679E – 06
KUM8	0.6	0.9	7.65758E – 11 $\cong 0.0000000077\%$	0.1	0.5	3,44208E – 08

6.3.3. Hasil MAPE Uji Coba Produk K2

Model dan Parameter produk K2 yang paling optimal pada proses training, selanjutnya dilakukan testing dan didapatkan hasil uji coba (*testing*) yaitu hasil MAPE dan RMSE *testing* untuk semua model lebih kecil dibandingkan MAPE dan RMSE *training*. Dimana model yang paling optimal pada proses training yaitu model K2M5 dengan MAPE 16.55% sedangkan pada testing menghasilkan MAPE 0.00000432%, nilai MAPE tersebut kurang dari 10%. Sedangkan RMSE terkecil yaitu pada model K2M5

dengan RMSE $2,04E - 06$. Sehingga dapat dikatakan bahwa parameter cocok/sesuai untuk meramalkan data penjualan Nota Produk Nota K2. Hasil MAPE dan RMSE *Training Testing* dapat dilihat pada Tabel 6.4.

Tabel 6. 3. Hasil MAPE dan RMSE Uji Coba Produk K1

Model	MC	LR	Testing (MAPE)	MC	LR	Testing (RMSE)
K1M1	0.7	0.9	0.240734651 $\cong 24.07\%$	0.9	0.7	6,302418
K1M2	0.5	0.7	0.097823278 $\cong 9.78\%$	0.5	0.8	0,292298
K1M3	0.9	0.9	0.000607107 $\cong 0.061\%$	0.8	0.9	0,316586
K1M4	0.8	0.9	1.02708E – 05 $\cong 0.00103\%$	0.8	0.9	0,000193
K1M5	0.8	0.9	7.98594E – 08 $\cong 0.000008\%$	0.8	0.9	1,64261E – 06
K1M6	0.1	0.9	0.000134645 $\cong 0.013\%$	0.5	0.7	0,001568699

Tabel 6. 4. Hasil MAPE dan RMSE Uji Coba Produk K2

Model	MC	LR	Testing (MAPE)	MC	LR	Testing (RMSE)
K2M1	0.2	0.5	0.55489353 $\cong 55.49\%$	0.8	0.7	14,32452
K2M2	0.8	0.9	0.286241455 $\cong 28.62\%$	0.9	0.9	12,19561
K2M3	0.9	0.9	0.020020567 $\cong 2.002\%$	0.7	0.9	0,802711
K2M4	0.8	0.9	2.34705E – 09 $\cong 0.00000023\%$	0.9	0.9	0,00089
K2M5	0.7	0.9	4.32248E – 08 $\cong 0.00000432\%$	0.7	0.9	2,04E – 06
K2M6	0.1	0.6	0.001428461 $\cong 0.14\%$	0.1	0.7	0,000372

6.3.4. Hasil MAPE Uji Coba Produk K3

Model dan Parameter produk K3 yang paling optimal pada proses training, selanjutnya dilakukan testing dan didapatkan hasil uji coba (*testing*) yaitu hasil MAPE dan RMSE *testing* untuk sebagian besar model lebih kecil dibandingkan MAPE dan RMSE *training*. Model yang paling optimal pada proses training yaitu K3M5 dengan MAPE 0.00000351% dan pada testing menghasilkan MAPE 0.0027% dan nilai MAPE tersebut kurang dari 10%. Sedangkan RMSE terkecil yaitu pada model K3M5 dengan RMSE 0,00153. Sehingga dapat dikatakan bahwa parameter cocok/sesuai untuk meramalkan data penjualan Nota Produk Nota K3. Hasil MAPE dan RMSE *Training Testing* dapat dilihat Tabel 6.5

Tabel 6. 5. Hasil MAPE dan RMSE Uji Coba Produk K3

Model	MC	LR	Testing (MAPE)	MC	LR	Testing (RMSE)
K3M1	0.9	0.7	0.007982772 ≈ 0.798%	0.3	0.6	16,77052
K3M2	0.5	0.9	0.118542531 ≈ 11.85%	0.7	0.9	10,99858
K3M3	0.8	0.9	0.004665399 ≈ 0.47	0.9	0.9	0,771189
K3M4	0.9	0.9	0.001121924 ≈ 0.11%	0.9	0.9	0,111018514
K3M5	0.6	0.9	2.7492E – 05 ≈ 0.0027%	0.6	0.9	0,00153
K3M6	0.5	0.6	2.46379E – 07 ≈ 0.000025%	0.5	0.5	0,005335

6.3.5. Hasil MAPE Uji Coba Produk K4

Model dan Parameter produk K4 yang paling optimal pada proses training, selanjutnya dilakukan testing dan didapatkan hasil uji coba (*testing*) yaitu hasil MAPE dan RMSE *testing* untuk sebagian besar model lebih kecil dibandingkan MAPE dan RMSE *training*. Model K4M5 menjadi parameter yang paling optimal pada proses training dengan MAPE 0.000799% dan pada testing menghasilkan MAPE 0.0022% dan nilai MAPE tersebut kurang dari 10%. Sedangkan RMSE terkecil yaitu pada model K4M5 dengan RMSE 0,001115. Sehingga dapat dikatakan bahwa parameter cocok/sesuai untuk meramalkan data penjualan Nota Produk Nota K4. Hasil MAPE dan RMSE *Training Testing* dapat dilihat pada Tabel 6.6

6.3.6. Hasil MAPE Uji Coba Produk K5

Model dan Parameter produk K5 yang paling optimal pada proses training, selanjutnya dilakukan testing dan didapatkan hasil uji coba (*testing*) yaitu hasil MAPE *testing* untuk sebagian besar model lebih kecil dibandingkan MAPE *training*. Model K5M5 menjadi parameter yang paling optimal pada proses training dengan MAPE 0.0125% dan pada testing menghasilkan MAPE 0.027% dan nilai MAPE tersebut kurang dari 10%. Sedangkan RMSE terkecil yaitu pada model K5M5 dengan RMSE 0,003736243. Sehingga dapat dikatakan bahwa parameter cocok/sesuai untuk meramalkan data penjualan Nota Produk Nota K5. Hasil MAPE dan RMSE *Training Testing* dapat dilihat pada Tabel 6.7

Tabel 6. 6. Hasil MAPE dan RMSE Uji Coba Produk K4

Model	MC	LR	Testing (MAPE)	MC	LR	Testing (RMSE)
K4M1	0.5	0.5	0.701320137 $\cong 7.13\%$	0.8	0.5	38,59326
K4M2	0.9	0.3	0.292263973 $\cong 29.23\%$	0.6	0.9	19,70142
K4M3	0.4	0.9	0.074674542 $\cong 7.47\%$	0.1	0.9	12,72731
K4M4	0.9	0.9	0.005810863 $\cong 0.58\%$	0.9	0.9	0,401136
K4M5	0.9	0.9	2.1733E – 05 $\cong 0.0022\%$	0.9	0.9	0,001115
K4M6	0.4	0.5	3.36115E – 05 $\cong 0.00336\%$	0.4	0.5	0,001713

Tabel 6. 7. Hasil MAPE dan RMSE Uji Coba Produk K5

Model	MC	LR	Testing (MAPE)	MC	LR	Testing (RMSE)
K5M1	0.1	0.6	0.726992711 $\cong 72.70\%$	0.5	0.4	12,03102
K5M2	0.7	0.9	0.123670959 $\cong 12.37\%$	0.6	0.9	0,700183
K5M3	0.4	0.9	0.071667901 $\cong 7.17\%$	0.7	0.9	2,326714
K5M4	0.7	0.9	0.006594905 $\cong 0.66\%$	0.9	0.9	0,397683
K5M5	0.8	0.9	0.000268682 $\cong 0.027\%$	0.8	0.9	0,003736243
K5M6	0.4	0.5	0.000716206 $\cong 0.07\%$	0.4	0.5	0,024243

6.3.7. Hasil MAPE Uji Coba Produk K6

Model dan Parameter produk K6 yang paling optimal pada proses training, selanjutnya dilakukan testing dan didapatkan hasil uji coba (*testing*) yaitu hasil MAPE *testing* untuk beberapa model lebih kecil dibandingkan MAPE *training*. Model K6M5 menjadi parameter yang paling optimal pada proses training dengan MAPE 0.00000014% dan pada testing menghasilkan MAPE 7.91% dan nilai MAPE tersebut kurang dari 10%. Sedangkan RMSE terkecil yaitu pada model K6M5 dengan RMSE1,183176. Sehingga dapat dikatakan bahwa parameter cocok/sesuai untuk meramalkan data penjualan Nota Produk Nota K6. Hasil MAPE dan RMSE *Training Testing* dapat dilihat pada Tabel 6.8

Tabel 6. 8. Hasil MAPE dan RMSE Uji Coba Produk K6

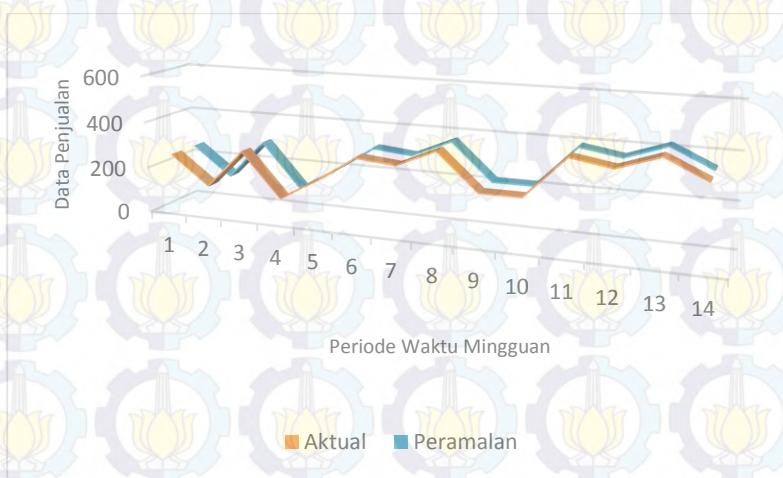
Model	MC	LR	Testing (MAPE)	MC	LR	Testing (RMSE)
K6M1	0.4	0.5	0.396648777 ≈ 39.66%	0.2	0.7	2,706292
K6M2	0.7	0.9	0.207785531 ≈ 20.78%	0.7	0.9	1,682749
K6M3	0.6	0.9	0.120365341 ≈ 12.04%	0.4	0.9	1,676824
K6M4	0.9	0.9	0.154490772 ≈ 15.45%	0.9	0.9	1,202665
K6M5	0.9	0.9	0.079135192 ≈ 7.91%	0.9	0.9	1,183176
K6M6	0.3	0.6	0.08000342 ≈ 8.00%	0.3	0.6	1,302717

Dari hasil uji coba (*testing*) dengan parameter yang telah optimal pada proses pelatihan (*training*) diketahui bahwa sebagian besar produk yang di uji coba menghasilkan nilai MAPE yang kecil yaitu kurang dari 10%. Selain itu nilai RMSE pada semua produk berkisar 0,169937802. Bahkan untuk produk Akumalasi , K1, K2 dan K3 nilai MAPE dan RMSE uji coba lebih kecil dibandingkan dengan nilai MAPE dan RMSE pelatihan. Hal ini menunjukkan

bawa produk-produk yang di uji coba dengan hasil nilai MAPE di bawah 10% mempunyai parameter yang sesuai untuk proses peramalan penjualan nota.

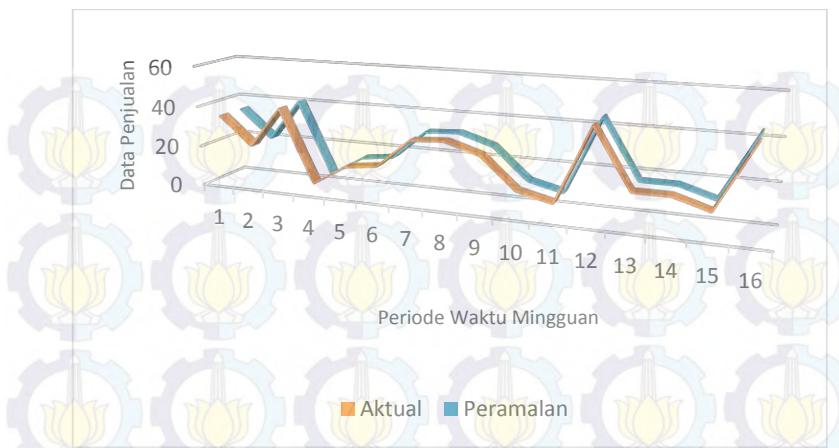
6.3.8. Perbandingan Antara Aktual dengan Hasil Peramalan

Pada Gambar 6.103 dapat terlihat bahwa hasil peramalan produk Akumulasi mempunyai pola yang hampir sama dengan data aktual. Sehingga peramalan dengan menggunakan metode Neural Network cocok untuk data penjualan Nota di CV. Gemilang Indonesia.



Gambar 6.103. Aktual VS Peramalan Produk Akumulasi

Pada Gambar 6.104 dapat terlihat bahwa hasil peramalan produk K1 mempunyai pola yang hampir sama dengan data aktual. Sehingga peramalan dengan menggunakan metode Neural Network cocok untuk data penjualan Nota di CV. Gemilang Indonesia.



Gambar 6. 104. Aktual VS Peramalan Produk K1

Pada Gambar 6.105 dapat terlihat bahwa hasil peramalan produk K2 mempunyai pola yang hampir sama dengan data aktual. Sehingga peramalan dengan menggunakan metode Neural Network cocok untuk data penjualan Nota di CV. Gemilang Indonesia.



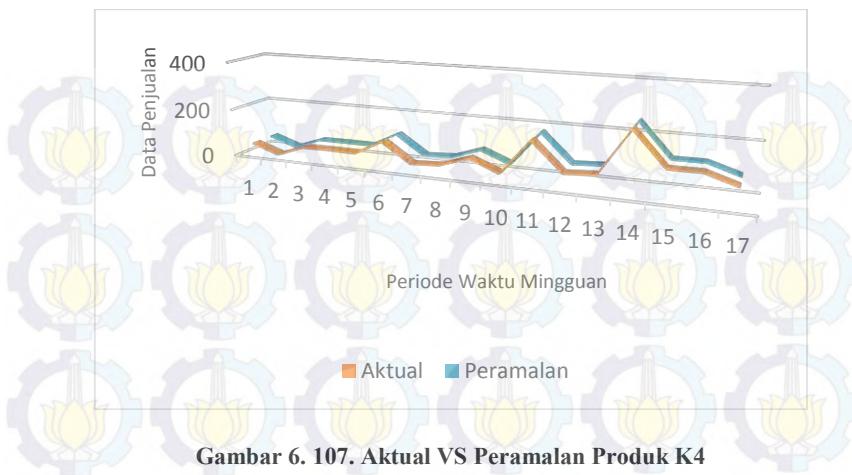
Gambar 6. 105. Aktual VS Peramalan Produk K2

Pada Gambar 6.106 dapat terlihat bahwa hasil peramalan produk K3 mempunyai pola yang hampir sama dengan data aktual. Sehingga peramalan dengan menggunakan metode Neural Network cocok untuk data penjualan Nota di CV. Gemilang Indonesia.



Gambar 6. 106. Aktual VS Peramalan Produk K3

Pada Gambar 6.107 dapat terlihat bahwa hasil peramalan produk K4 mempunyai pola yang hampir sama dengan data aktual. Sehingga peramalan dengan menggunakan metode Neural Network cocok untuk data penjualan Nota di CV. Gemilang Indonesia.



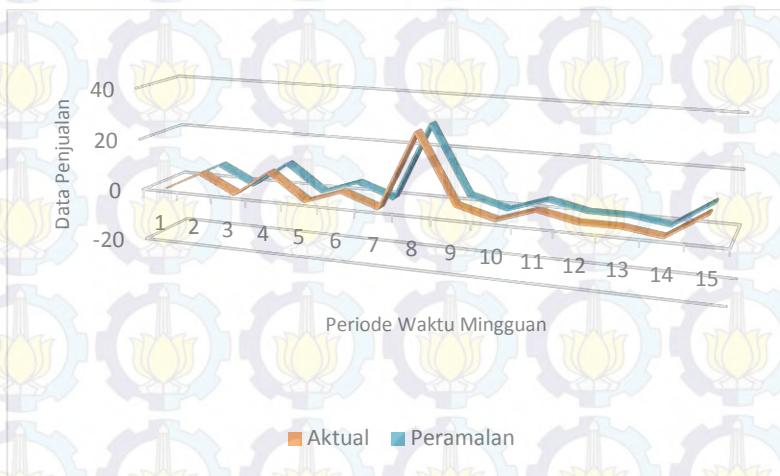
Gambar 6. 107. Aktual VS Peramalan Produk K4

Pada Gambar 6.108 dapat terlihat bahwa hasil peramalan produk K5 mempunyai pola yang hampir sama dengan data aktual. Sehingga peramalan dengan menggunakan metode Neural Network cocok untuk data penjualan Nota di CV. Gemilang Indonesia.



Gambar 6. 108. Aktual VS Peramalan Produk K5

Pada Gambar 6.109 dapat terlihat bahwa hasil peramalan produk K6 mempunyai pola yang hampir sama dengan data aktual. Sehingga peramalan dengan menggunakan metode Neural Network cocok untuk data penjualan Nota di CV. Gemilang Indonesia.



Gambar 6. 109. Aktual VS Peramalan Produk K6

6.4. Kesimpulan Hasil Eksperimen

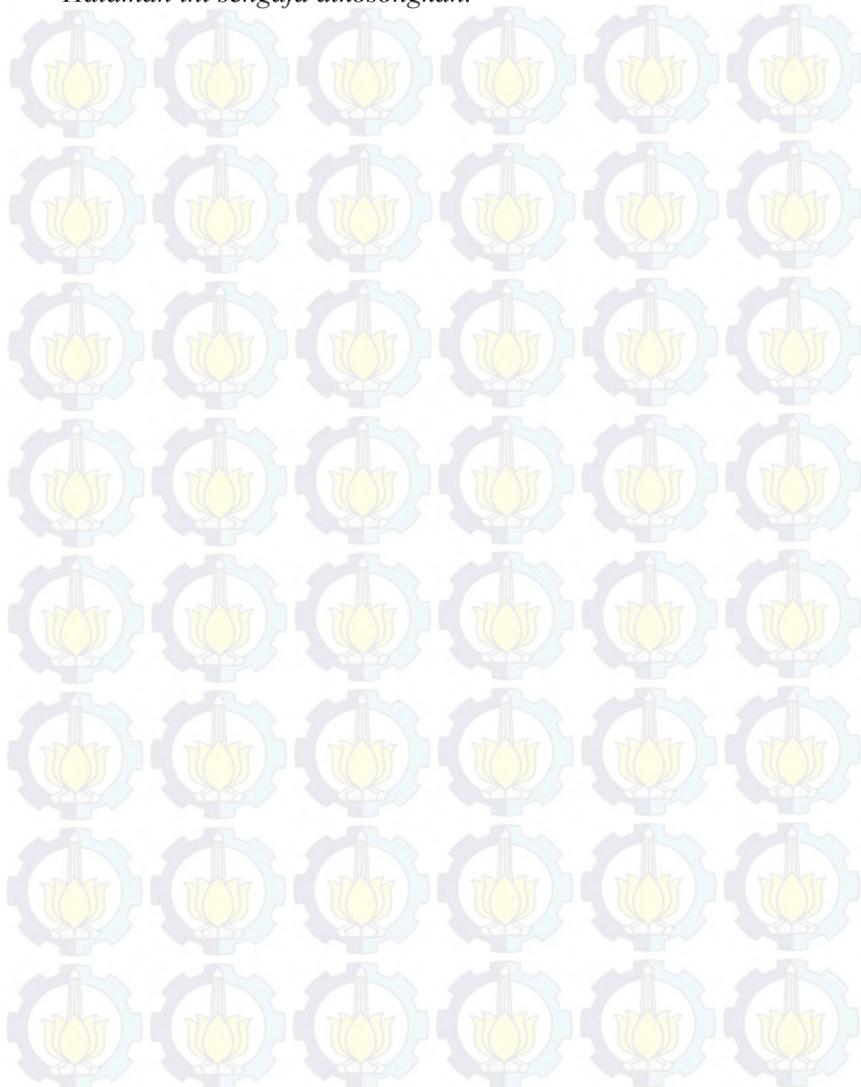
Dari eksperimen (penelitian) yang telah dilakukan maka didapatkan kesimpulan sebagai berikut :

1. Model terbaik yang dapat digunakan dalam peramalan penjualan produk-produk nota di CV. Gemilang Indonesia adalah dengan variabel input sebanyak 5 node, variabel hidden layer sebanyak 10 node dan output layer sebanyak 1 node dengan parameter optimal yaitu epoch sebesar 1000.
2. Belum terdapat model yang paling optimal pada produk Akumulasi dikarenakan nilai MAPE dan RMSE terus mengecil.

3. Parameter yang paling optimal untuk peramalan yaitu sebagai berikut :

- produk K1 (Nota 1 Layer) yaitu momentum 0.8 dan learning rate 0.9
 - produk K2 (Nota 2 Layer) yaitu momentum 0.7 dan learning rate 0.9
 - produk K3 (Nota 3 Layer) yaitu momentum 0.6 dan learning rate 0.9
 - produk K4 (Nota 4 Layer) yaitu momentum 0.9 dan learning rate 0.9
 - produk K5 (Nota 5 Layer) yaitu momentum 0.8 dan learning rate 0.9
 - produk K6 (Nota 6 Layer) yaitu momentum 0.9 dan learning rate 0.9
4. Proses *training* dan *testing* perlu dilakukan setidaknya 3-5 kali pada setiap parameter untuk mengetahui hasil terbaik. Hal ini dikarenakan bobot pada *neural network* berubah-ubah.
5. Semakin banyak jumlah input maka hasil peramalan akan semakin optimal. Namun jika nilai error telah konvergen dan/atau naik kembali maka proses training dihentikan.

Halaman ini sengaja dikosongkan.



BAB VII

KESIMPULAN DAN SARAN

Bab ini berisikan kesimpulan dari hasil penelitian dan juga saran perbaikan untuk penelitian kedepannya beserta masalah yang dihadapi selama mengerjakan penelitian tugas akhir ini.

7.1. Kesimpulan

Hasil uji coba dan pembahasan yang dilakukan dalam tugas akhir dapat ditarik kesimpulan sebagai berikut :

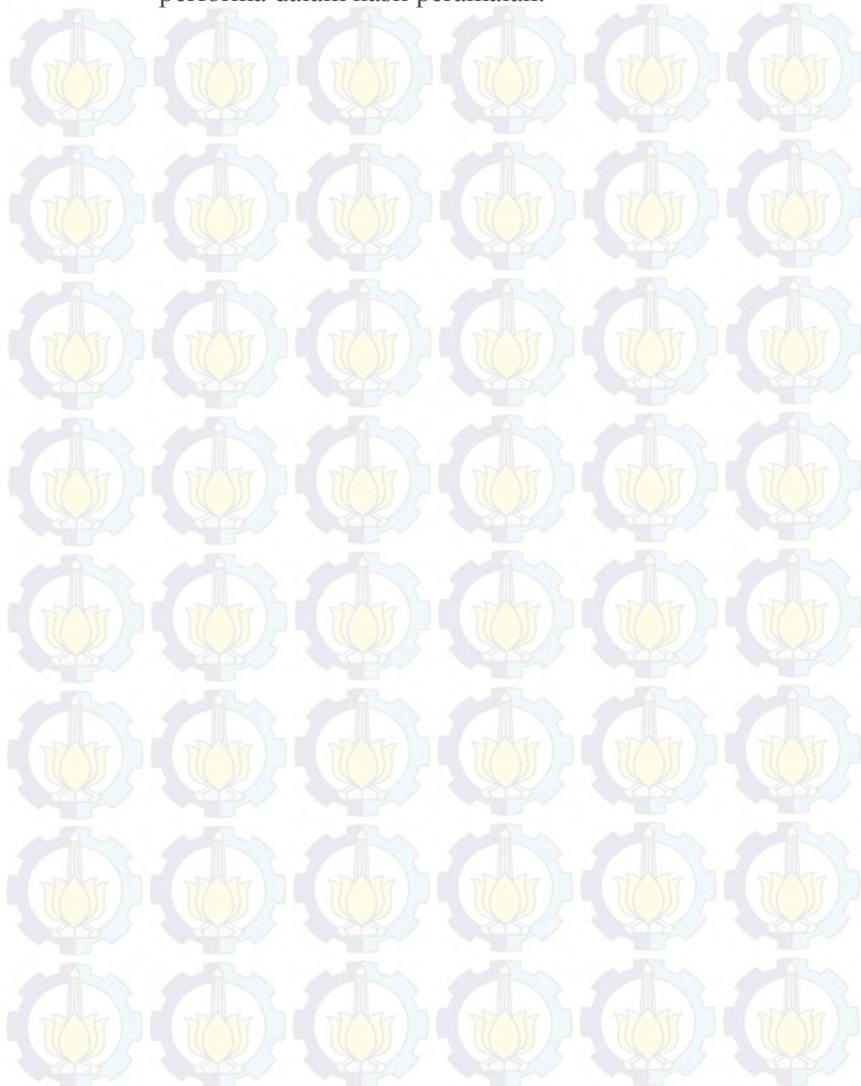
1. Metode Artificial Neural Network dapat diterapkan untuk peramalan penjualan nota di CV. Gemilang Indonesia.
2. Dari hasil peramalan terbukti bahwa data dipengaruhi oleh 6 periode waktu sebelumnya kecuali produk akumulasi.
3. Tingkat akurasi yang didapatkan dari rata rata *error* perbandingan data aktual dan data peramalan(MAPE) menggunakan ANN untuk semua produk yaitu kurang dari 8%. Sedangkan nilai RMSE rata-rata 0,169937802.

7.2. Saran

Saran yang dihasilkan dari penarikan kesimpulan dan batasan masalah dari penggerjaan tugas akhir ini adalah sebagai berikut :

1. Dalam penelitian ini , proses pelatihan dan pengujian menggunakan tools matlab dengan kode terpisah sehingga memerlukan waktu yang cukup lama dalam prosesnya. Selain itu, metode mencari nilai MAPE masih dilakukan secara manual menggunakan MS.Excel. Untuk itu, pada penelitian selanjutnya dapat dikembangkan sebuah aplikasi untuk peramalan sekaligus untuk mencari nilai MAPE nya.
2. Dapat digunakan Metode Neural Network selain backpropagation, seperti adaptive smoothing neural network atau feed forward neural network dalam

penelitian selanjutnya untuk mengetahui perbandingan performa dalam hasil peramalan.



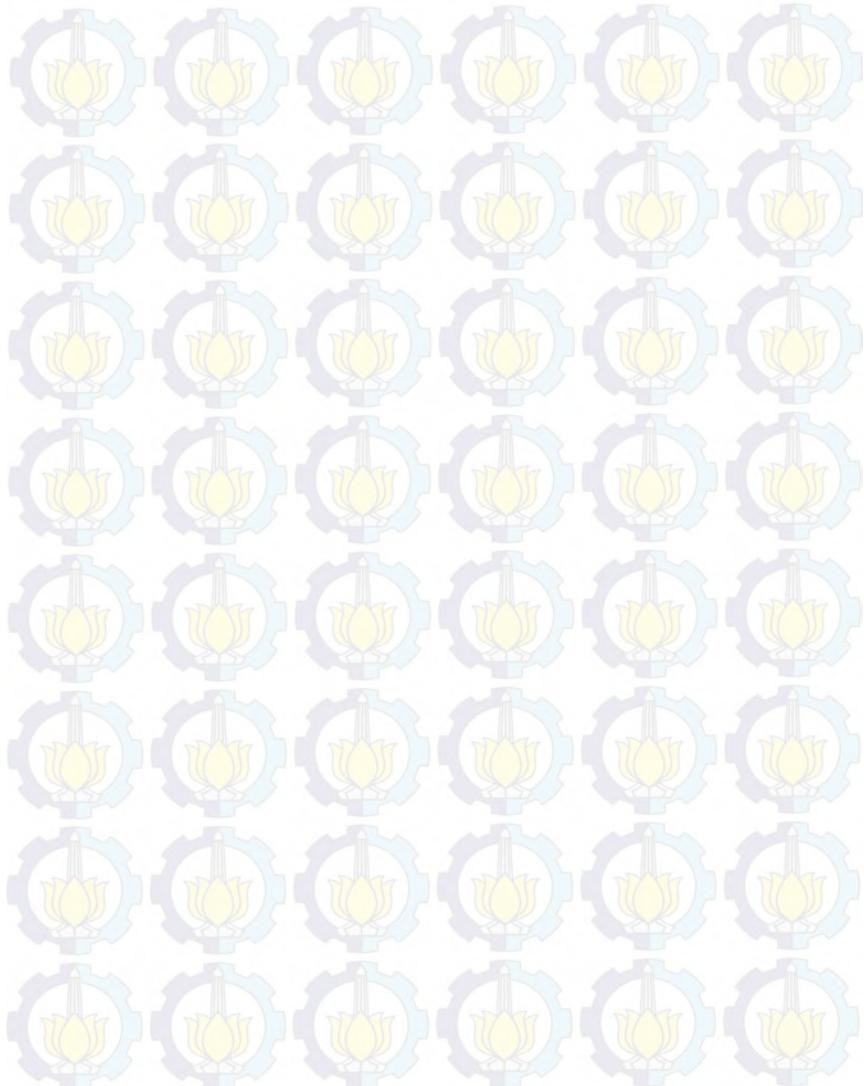
DAFTAR PUSTAKA

- [1] H. Jiang, C. Kwong, K. Siu and Y. Liu, "Rough set and PSO-based ANFIS approaches to modeling customer satisfaction for affective product design," *Advanced Engineering Informatics*, p. 12, 2015.
- [2] H. Wang, B. Chen and H. Yan, "Optimal inventory decisions in a multiperiod newsvendor problem with partially observed Markovian supply capacities," *European Journal of Operational Research*, p. 16, 2010.
- [3] D. Papakiriakopoulos, "Predict on-shelf product availability in grocery retailing with classification methods," *Expert Systems with Applications*, p. 10, 2012.
- [4] Y. G. Zhong and Y. W. Zhou, "Improving the supply chain's performance through trade credit under inventory-dependent demand and limited storage capacity," *International Journal of Production Economics*, p. 7, 2013.
- [5] B. E. Saputra, Interviewee, *Proses Bisnis dan Profil CV. Gemilang Indonesia*. [Interview]. 30 September 2015.
- [6] D. Wang, O. Tang and L. Zhang, "A periodic review lot sizing problem with random yields, disruptions and inventory capacity," *International Journal of Production Economics*, p. 10, 2014.
- [7] Z. L. Sun, T. M. Choi, K. F. Au and Y. Yu, "Sales forecasting using extreme learning machine with applications in fashion retailing," *Decision Support Systems*, p. 9, 2008.
- [8] J. Z. Wang, J. J. Wang, Z. G. Zhang and S. P. Guo, "Forecasting Stock Indices With Back Propagation Neural Network," 2011.
- [9] L. Stepvhanie, "Peramalan penjualan Produk Susu Bayi dengan Metode Grey System Theory dan Neural Network," 2012.

- [10] N. Yanti, "Penerapan Metode Neural Network Dengan Struktur Backpropagation Untuk Prodiksi Stok Obat di Apotek (Studi Kasus : Apotek ABC)," pp. 1-6, 2011.
- [11] P. Doganis, A. Alexandridis, P. Patrinos and H. Sarimveis, "Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing," 2006.
- [12] A. Krismundarto, Interviewee, *Kondisi Kekinian CV.Gemilang Indonesia*. [Interview]. 3 Oktober 2015.
- [13] Muhammad Fauzi, "Analisis Peramalan Penjualan Rokok SKT (Sigaret Kretek Tangan) Pada PT. Djitoe Indonesian Tobacco Coy Surakarta," p. 71, 2009.
- [14] F. Nur H and E. Widya F, "Manajemen Produksi dan Operasi dalam Perusahaan," Prpgram Studi Agribisnis Fakultas Pertanian Universitas Brawijaya, Malang, 2013.
- [15] J. Heizer and B. render, *Managemen Operasi Edisi 9* Terjemahan Chriswan Sungkono, Jaarta: Salemba Empat, 2009.
- [16] Y. Edward, "Information Technology (Metode Forecasting)," 21 September 2015. [Online]. Available: <http://yuliusehs.blog.widyatama.ac.id/2015/09/21/information-technology-metode-forecasting/>. [Accessed 2 oktober 2015].
- [17] M. Spyros, W. Steven C and H. Rob J, *Forecasting Methods and Application 3rd Edition*, John Wiley and Sons inc., 1998.
- [18] M. Savira and N. N.K., "Analisis Peramalan Penjualan Obat Generik Berlogo (OGB) pada PT. Indonesia Farma," p. 12, 2014.
- [19] M. F. Fad, "Peramalan Adalah Perhitungan Yang Objektif Dan Dengan Menggunakan Data," 2015. [Online]. Available: <http://www.scribd.com/doc/123304851/Peramalan-Adalah-Perhitungan-Yang-Objektif-Dan-Dengan-Menggunakan-Data#scribd>. [Accessed 3 Oktober 2015].
- [20] T. M. Mitchell, *Machine Learning*, McGraw-Hill Science/Engineering/Math, 1997.

- [21] S. Russel and P. Norvig, Artificial Intellegence A Modern Approach 3rd Edition, New Jersey: Pearson Education, Inc., 2010.
- [22] A. R. Barakbah, "neural Network," in *Soft Computing Research Group EEPIS-ITS*, Surabaya, 2009.
- [23] H. Yasin and Suparti, "Pemodelan Volatilitas Untuk Penghitungan Value At Risk (VAR) Menggunakan Feed Forward Neural Network," vol. VII, 2014.
- [24] D. H. M. Hagan and M. Baele, "Neural Network Toolbox User's Guide," Natick, The Mathworks Inc, 2015.
- [25] M. D.O, "Implementasi Jaringan Saraf Tiruan Backpropagation dalam Memprediksi Kurs Valuta Asing," *Fakultas Teknologi Industri Universitas Gundarma.*, 2010.
- [26] J. Siang, "Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab," Yogyakarta, Andi Offset, 2009, pp. 98-111.
- [27] S. Kusumadewi, "Membangun Jaringan Syaraf Tiruan, Menggunakan Matlab dan Excel Link.," Yogyakarta, Graha Ilmu, 2004, pp. 93-98.
- [28] S. E. Lestari, R. Astuti and S. Anggarini, "Perbandingan Peramalan Permintaan Keripik Nanas Menggunakan Metode Jaringan Syaraf Tiruan dan Time Series di UKM "So Kressh" Malang," p. 8, 2014.
- [29] A. A. P. P. H. S. Philip Doganis, "Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing," 2006.

Halaman ini sengaja dikosongkan.



LAMPIRAN A
DATA PENJUALAN NOTA CV. GEMILANG INDONESIA

Minggu ke	Nota K1	Nota K2	Nota K3	Nota K4	Nota K5	Nota K6
Minggu 1	23	19	40	31	13	10
Minggu 2	110	59	93	59	10	2
Minggu 3	5	16	7	11	5	0
Minggu 4	9	27	17	45	0	10
Minggu 5	23	99	77	70	47	10
Minggu 6	2	7	2	1	5	0
Minggu 7	23	62	145	134	33	0
Minggu 8	86	35	45	114	3	0
Minggu 9	38	60	78	33	2	8
Minggu 10	6	10	53	43	10	6
Minggu 11	52	53	37	29	14	4
Minggu 12	7	40	37	29	0	6
Minggu 13	59	7	33	45	4	6
Minggu 14	31	17	49	30	24	0
Minggu 15	25	36	65	58	11	0
Minggu 16	14	47	29	14	4	6
Minggu 17	14	39	52	47	13	0
Minggu 18	2	36	37	11	2	0
Minggu 19	8	20	73	38	34	6
Minggu 20	17	84	20	16	4	0
Minggu 21	13	35	17	121	2	5
Minggu 22	3	34	11	34	23	0
Minggu 23	8	2	18	24	0	6
Minggu 24	130	64	74	72	2	0
Minggu 25	144	64	58	30	0	0

A-2

Minggu ke	Nota K1	Nota K2	Nota K3	Nota K4	Nota K5	Nota K6
Minggu 26	22	22	49	100	32	10
Minggu 27	0	30	7	7	8	6
Minggu 28	0	6	37	42	20	0
Minggu 29	15	45	31	35	6	0
Minggu 30	45	74	84	158	7	0
Minggu 31	7	22	32	14	20	6
Minggu 32	12	48	26	157	12	0
Minggu 33	67	136	117	140	28	6
Minggu 34	21	16	19	59	0	3
Minggu 35	8	6	7	19	5	0
Minggu 36	5	41	36	43	26	7
Minggu 37	73	78	150	95	12	0
Minggu 38	12	39	33	77	13	2
Minggu 39	24	76	60	40	4	0
Minggu 40	24	43	101	36	18	0
Minggu 41	32	29	12	22	10	2
Minggu 42	23	76	150	67	11	2
Minggu 43	19	49	39	36	15	0
Minggu 44	5	46	45	14	28	0
Minggu 45	81	13	9	41	20	0
Minggu 46	3	453	137	143	59	20
Minggu 47	13	49	86	122	13	0
Minggu 48	4	71	61	88	10	1
Minggu 49	46	77	31	111	58	2
Minggu 50	5	25	9	5	0	0
Minggu 51	19	65	109	33	40	2
Minggu 52	38	38	16	47	10	0
Minggu 53	30	43	60	50	25	4

Minggu ke	Nota K1	Nota K2	Nota K3	Nota K4	Nota K5	Nota K6
Minggu 54	9	64	76	71	16	10
Minggu 55	18	39	95	47	32	15
Minggu 56	20	11	20	34	6	1
Minggu 57	-	-	-	-	-	-
Minggu 58	2	14	5	43	11	3
Minggu 59	32	45	66	25	8	0
Minggu 60	42	57	167	126	6	0
Minggu 61	14	53	41	77	10	0
Minggu 62	7	13	47	60	15	0
Minggu 63	16	13	92	50	9	0
Minggu 64	35	62	68	49	6	1
Minggu 65	21	37	38	11	26	0
Minggu 66	0	35	33	53	2	0
Minggu 67	41	50	95	55	0	7
Minggu 68	5	6	47	53	17	0
Minggu 69	15	41	59	113	56	10
Minggu 70	17	37	8	34	6	0
Minggu 71	31	49	36	41	35	5
Minggu 72	32	75	121	82	0	0
Minggu 73	27	120	57	35	21	30
Minggu 74	12	49	78	178	40	4
Minggu 75	8	45	59	62	31	0
Minggu 76	45	26	66	70	3	5
Minggu 77	17	39	48	253	29	2
Minggu 78	17	69	133	119	14	2
Minggu 79	12	95	189	120	3	0
Minggu 80	44	91	68	81	46	10

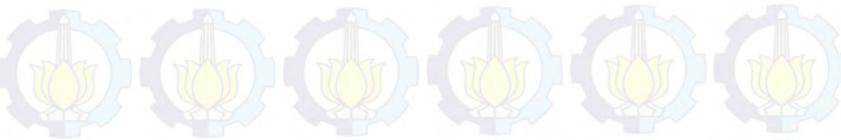
LAMPIRAN B
HASIL MAPE DAN RMSE PRODUK AKUMULASI

MAPE								
KUM1		KUM2		KUM3		KUM4		
MC 0.1 LR 0.5	0,608468	MC 0.1 LR 0.5	0,526543	MC 0.1 LR 0.4	0,215184	MC 0.1 LR 0.5	0,127028	
MC 0.2 LR 0.5	0,630956	MC 0.2 LR 0.6	0,543813	MC 0.2 LR 0.6	0,204339	MC 0.2 LR 0.5	0,112529	
MC 0.3 LR 0.4	0,638908	MC 0.3 LR 0.7	0,517772	MC 0.3 LR 0.6	0,346894	MC 0.3 LR 0.4	0,140558	
MC 0.4 LR 0.5	0,608468	MC 0.4 LR 0.6	0,45712	MC 0.4 LR 0.6	0,247151	MC 0.4 LR 0.7	0,066134	
MC 0.5 LR 0.4	0,677033	MC 0.5 LR 0.6	0,490072	MC 0.5 LR 0.4	0,274376	MC 0.5 LR 0.6	0,126856	
MC 0.6 LR 0.5	0,608468	MC 0.6 LR 0.5	0,468263	MC 0.6 LR 0.5	0,213248	MC 0.6 LR 0.5	0,112529	
MC 0.7 LR 0.5	0,630956	MC 0.7 LR 0.7	0,527214	MC 0.7 LR 0.6	0,238296	MC 0.7 LR 0.4	0,140558	
MC 0.8 LR 0.5	0,675356	MC 0.8 LR 0.6	0,452739	MC 0.8 LR 0.5	0,217577	MC 0.8 LR 0.7	0,066134	
MC 0.9 LR 0.5	0,608468	MC 0.9 LR 0.6	0,490072	MC 0.9 LR 0.5	0,157582	MC 0.9 LR 0.5	0,112529	
KUM5		KUM6		KUM7		KUM8		
MC 0.1 LR 0.5	0,039498	MC 0.1 LR 0.6	0,02913	MC 0.1 LR 0.4	0,029941	MC 0.1 LR 0.5	0,005892	
MC 0.2 LR 0.5	0,061086	MC 0.2 LR 0.5	0,012181	MC 0.2 LR 0.5	0,014495	MC 0.2 LR 0.5	0,013589	
MC 0.3 LR 0.7	0,04721	MC 0.3 LR 0.4	0,038397	MC 0.3 LR 0.5	0,038841	MC 0.3 LR 0.6	0,010493	
MC 0.4 LR 0.4	0,057269	MC 0.4 LR 0.6	0,043577	MC 0.4 LR 0.4	0,025654	MC 0.4 LR 0.7	0,016937	

B-2

MC 0.5 LR 0.7	0,046251	MC 0.5 LR 0.4	0,026821	MC 0.5 LR 0.7	0,001299	MC 0.5 LR 0.6	0,006779
MC 0.6 LR 0.6	0,069331	MC 0.6 LR 0.4	0,037534	MC 0.6 LR 0.5	0,020366	MC 0.6 LR 0.6	0,018035
MC 0.7 LR 0.6	0,055788	MC 0.7 LR 0.6	0,02913	MC 0.7 LR 0.5	0,014495	MC 0.7 LR 0.5	0,014973
MC 0.8 LR 0.5	0,04288	MC 0.8 LR 0.6	0,02913	MC 0.8 LR 0.5	0,038489	MC 0.8 LR 0.6	0,007198
MC 0.9 LR 0.6	0,046538	MC 0.9 LR 0.5	0,012181	MC 0.9 LR 0.4	0,025654	MC 0.9 LR 0.6	0,010656

RMSE							
KUM1		KUM2		KUM3		KUM4	
MC 0.1 LR 0.6	119,2272	MC 0.1 LR 0,7	84,52646	MC 0.1 LR 0,4	45,11427	mc 0.1 LR 0,7	20,76536
MC 0.2 LR 0.6	121,1049	MC 0.2 LR 0,6	89,47692	MC 0.2 LR 0,6	44,19112	mc 0.2 LR 0,6	20,91557
MC 0.3 LR 0,5	120,1171	MC 0.3 LR 0,7	103,3605	MC 0.3 LR 0,6	52,85027	mc 0.3 LR 0,4	26,73775
MC 0.4 LR 0,6	119,2272	MC 0.4 LR 0,6	82,52716	MC 0.4 LR 0,6	48,99687	mc 0.4 LR 0,6	15,99532
MC 0.5 LR 0,6	121,5337	MC 0.5 LR 0,8	111,8033	MC 0.5 LR 0,4	60,90383	mc 0.5 LR 0,7	20,76536
MC 0.6 LR 0,6	119,2272	MC 0.6 LR 0,7	97,11878	MC 0.6 LR 0,5	40,50453	mc 0.6 LR 0,6	20,91557
MC 0.7 LR 0,6	121,1049	MC 0.7 LR 0,6	96,65507	MC 0.7 LR 0,6	38,31732	mc 0.7 LR 0,4	26,73775
MC 0.8 LR 0,4	123,8152	MC 0.8 LR 0,6	103,8342	MC 0.8 LR 0,5	46,84821	mc 0.8 LR 0,7	15,91601
MC 0.9 LR 0,6	119,2272	MC 0.9 LR 0,7	112,111	MC 0.9 LR 0,6	28,44359	mc 0.9 LR 0,7	20,76536
KUM5		KUM6		KUM7		KUM8	



B-3

mc 0.1 LR 0,5	9,926033	mc 0.1 LR 0,6	7,179892	mc 0.1 LR 0,5	8,307545	mc 0.1 LR 0,5	1,430152
mc 0.2 LR 0,5	15,06287	mc 0.2 LR 0,5	3,146658	mc 0.2 LR 0,5	3,658948	mc 0.2 LR 0,6	3,504267
mc 0.3 LR 0,7	10,80325	mc 0.3 LR 0,4	10,09287	mc 0.3 LR 0,5	9,88045	mc 0.3 LR 0,6	2,908585
mc 0.4 LR 0,5	12,98882	mc 0.4 LR 0,6	11,0687	mc 0.4 LR 0,4	6,624422	mc 0.4 LR 0,7	5,290575
mc 0.5 LR 0,7	11,34696	mc 0.5 LR 0,4	7,041828	mc 0.5 LR 0,7	5,9952	mc 0.5 LR 0,6	1,804472
mc 0.6 LR 0,5	13,90026	mc 0.6 LR 0,4	8,566913	mc 0.6 LR 0,5	5,755915	mc 0.6 LR 0,6	4,674245
mc 0.7 LR 0,6	11,53339	mc 0.7 LR 0,6	7,179892	mc 0.7 LR 0,5	3,658948	mc 0.7 LR 0,5	4,015904
mc 0.8 LR 0,5	11,111191	mc 0.8 LR 0,6	7,179892	mc 0.8 LR 0,5	9,313697	mc 0.8 LR 0,6	2,099511
mc 0.9 LR 0,6	10,65453	mc 0.9 LR 0,5	3,146658	mc 0.9 LR 0,4	6,624422	mc 0.9 LR 0,5	3,570062

LAMPIRAN C
HASIL TRAINING OPTIMAL PRODUK K1

MAPE					
K1M1		K1M2		K1M3	
MC 0,1 LR 0,5	1,480979	MC 0,1 LR 0,4	1,395372	MC 0,1 LR 0,7	0,811869
MC 0,2 LR 0,8	1,54827	MC 0,2 LR 0,4	1,711627	MC 0,2 LR 0,8	0,589509
MC 0,3 LR 0,9	1,496184	MC 0,3 LR 0,3	1,565535	MC 0,3 LR 0,9	0,60272
MC 0,4 LR 0,8	1,441153	MC 0,3 LR 0,7	1,221758	MC 0,4 LR 0,9	0,708753
MC 0,5 LR 0,7	1,398544	MC 0,4 LR 0,7	1,146031	MC 0,5 LR 0,9	0,915278
MC 0,6 LR 0,8	1,442364	MC 0,5 LR 0,2	1,550899	MC 0,6 LR 0,9	0,501672
MC 0,7 LR 0,9	0,401611	MC 0,6 LR 0,7	1,273879	MC 0,7 LR 0,9	0,623449
MC 0,8 LR 0,8	1,677782	MC 0,7 LR 0,5	1,449847	MC 0,8 LR 0,9	0,591542
MC 0,9 LR 0,6	1,435197	MC 0,8 LR 0,4	1,291661	MC 0,9 LR 0,9	0,401302
K1M4		K1M5		K1M6	
MC 0,1 LR 0,9	0,223676	MC 0,1 LR 0,9	0,062588		
MC 0,2 LR 0,9	0,320945	MC 0,2 LR 0,9	0,00158	MC 0,2 LR 0,5	0,171578
MC 0,3 LR 0,9	0,099276	MC 0,3 LR 0,9	0,000769	MC 0,3 LR 0,5	0,041646
MC 0,4 LR 0,9	0,157836	MC 0,4 LR 0,9	0,004415	MC 0,4 LR 0,6	0,121116
MC 0,5 LR 0,9	0,131859	MC 0,5 LR 0,9	0,014458	MC 0,5 LR 0,5	0,203472
MC 0,6 LR 0,9	0,064958	MC 0,6 LR 0,9	0,000323	MC 0,6 LR 0,6	0,043936
MC 0,7 LR 0,9	0,124491	MC 0,7 LR 0,9	0,002087	MC 0,7 LR 0,6	0,125288
MC 0,8 LR 0,9	0,034227	MC 0,8 LR 0,9	0,00011	MC 0,8 LR 0,6	0,096975
MC 0,9 LR 0,9	0,113245	MC 0,9 LR 0,9	0,003979	MC 0,9 LR 0,6	0,042326

RMSE					
K1M1		K1M2		K1M3	
mc 0,1 LR 0,5	22,21547	mc 0,1 LR 0,4	20,72159	mc 0,1 LR 0,9	14,5867
mc 0,2 LR 0,9	22,55492	mc 0,2 LR 0,3	22,15505	mc 0,2 LR 0,9	13,68938

C-2

mc 0.3 LR 0,9	22,47654	mc 0.3 LR 0,3	21,66873	mc 0.3 LR 0,9	12,59034
mc 0.4 LR 0,8	22,17669	mc 0.4 LR 0,8	19,92958	mc 0.4 LR 0,9	14,12306
mc 0.5 LR 0,7	21,96153	mc 0.5 LR 0,8	18,91072	mc 0.5 LR 0,9	14,96521
mc 0.6 LR 0,7	22,10505	mc 0.6 LR 0,3	21,73447	mc 0.6 LR 0,9	12,51027
mc 0.7 LR 0,4	23,69271	mc 0.7 LR 0,6	20,64661	mc 0.7 LR 0,9	13,85817
mc 0.8 LR 0,6	22,95782	mc 0.8 LR 0,9	21,06076	mc 0.8 LR 0,9	10,12115
mc 0.9 LR 0,7	21,93796	mc 0.9 LR 0,5	20,34994	mc 0.9 LR 0,9	11,08999
K1M4		K1M5		K1M6	
mc 0.1 LR 0,9	4,115177	mc 0.1 LR 0,9	1,255174	mc 0.1 LR 0,5	1,959803
mc 0.2 LR 0,9	4,07288	mc 0.2 LR 0,9	0,023628	mc 0.2 LR 0,5	1,959803
mc 0.3 LR 0,9	1,793164	mc 0.3 LR 0,9	0,013624	mc 0.3 LR 0,5	0,595489
mc 0.4 LR 0,9	2,457388	mc 0.4 LR 0,9	0,060235	mc 0.4 LR 0,4	1,660358
mc 0.5 LR 0,9	2,045072	mc 0.5 LR 0,9	0,187192	mc 0.5 LR 0,7	0,247289
mc 0.6 LR 0,9	0,820884	mc 0.6 LR 0,9	0,005003	mc 0.6 LR 0,5	0,818936
mc 0.7 LR 0,9	1,586054	mc 0.7 LR 0,9	0,029022	mc 0.7 LR 0,6	1,419504
mc 0.8 LR 0,9	0,442702	mc 0.8 LR 0,9	0,001934	mc 0.8 LR 0,6	1,416282
mc 0.9 LR 0,9	1,39849	mc 0.9 LR 0,9	0,052124	mc 0.9 LR 0,6	0,61987

LAMPIRAN D
HASIL MAPE TRAINING PRODUK K2

MAPE					
K2M1		K2M2		K2M3	
MC 0,1 LR 0,4	1,480612	MC 0,1 LR 0,5	1,280147	MC 0,1 LR 0,9	0,570904
MC 0,2 LR 0,5	1,423189	MC 0,2 LR 0,5	1,494515	MC 0,2 LR 0,9	0,53853
MC 0,3 LR 0,9	1,518663	MC 0,3 LR 0,9	1,278182	MC 0,3 LR 0,9	0,739497
MC 0,4 LR 0,4	1,556565	MC 0,4 LR 0,7	1,054731	MC 0,4 LR 0,9	0,610323
MC 0,5 LR 0,9	1,474442	MC 0,5 LR 0,9	1,298176	MC 0,5 LR 0,9	0,801341
MC 0,6 LR 0,3	1,544868	MC 0,6 LR 0,8	1,169466	MC 0,6 LR 0,9	0,577994
MC 0,7 LR 0,5	1,474045	MC 0,7 LR 0,9	1,041135	MC 0,7 LR 0,9	0,557465
MC 0,8 LR 0,7	1,555677	MC 0,8 LR 0,8	0,696511	MC 0,8 LR 0,9	0,731622
MC 0,9 LR 0,4	1,54552	MC 0,9 LR 0,9	0,975767	MC 0,9 LR 0,9	0,48659
K2M4		K2M5		K2M6	
MC 0,1 LR 0,9	0,384118	MC 0,1 LR 0,9	0,198432	MC 0,1 LR 0,6	0,229941
MC 0,2 LR 0,9	0,461936	MC 0,2 LR 0,9	0,255254	MC 0,2 LR 0,7	0,465877
MC 0,3 LR 0,9	0,508283	MC 0,3 LR 0,9	0,244813	MC 0,3 LR 0,6	0,44685
MC 0,4 LR 0,9	0,246929	MC 0,4 LR 0,9	0,228682	MC 0,4 LR 0,7	0,437176
MC 0,5 LR 0,9	0,392179	MC 0,5 LR 0,9	0,110798	MC 0,5 LR 0,8	0,420012
MC 0,6 LR 0,9	0,299885	MC 0,6 LR 0,9	0,135964	MC 0,6 LR 0,7	0,445449
MC 0,7 LR 0,9	0,198313	MC 0,7 LR 0,9	0,016558	MC 0,7 LR 0,6	0,229941
MC 0,8 LR 0,9	0,192708	MC 0,8 LR 0,9	0,065193	MC 0,8 LR 0,7	0,465877
MC 0,9 LR 0,9	0,214489	MC 0,9 LR 0,9	0,033255	MC 0,9 LR 0,6	0,44685

RMSE					
K2M1		K2M2		K2M3	
mc 0,1 LR 0,4	58,29099	mc 0,1 LR 0,6	55,37703	mc 0,1 LR 0,9	16,81034
mc 0,2 LR 0,6	57,12164	mc 0,2 LR 0,6	54,25832	mc 0,2 LR 0,9	15,84208

D-2

mc 0.3 LR 0,9	56,21493	mc 0.3 LR 0,9	49,28105	mc 0.3 LR 0,9	17,88489
mc 0.4 LR 0,6	56,11976	mc 0.4 LR 0,9	35,5938	mc 0.4 LR 0,9	16,7716
mc 0.5 LR 0,9	58,16297	mc 0.5 LR 0,9	37,53394	mc 0.5 LR 0,9	21,07528
mc 0.6 LR 0,9	58,20337	mc 0.6 LR 0,9	27,31246	mc 0.6 LR 0,9	14,21258
mc 0.7 LR 0,3	57,50982	mc 0.7 LR 0,9	25,07855	mc 0.7 LR 0,9	11,94943
mc 0.8 LR 0,7	47,41751	mc 0.8 LR 0,9	23,62624	mc 0.8 LR 0,9	18,35107
mc 0.9 LR 0,8	55,98728	mc 0.9 LR 0,9	23,31147	mc 0.9 LR 0,9	12,5722
K2M4		K2M5		K2M6	
mc 0.1 LR 0,9	11,66551	mc 0.1 LR 0,9	6,531521	mc 0.1 LR 0,7	8,797746
mc 0.2 LR 0,9	12,07558	mc 0.2 LR 0,9	8,913955	mc 0.2 LR 0,7	15,9978
mc 0.3 LR 0,9	13,1223	mc 0.3 LR 0,9	7,000659	mc 0.3 LR 0,6	13,30405
mc 0.4 LR 0,9	7,471845	mc 0.4 LR 0,9	5,438027	mc 0.4 LR 0,7	12,27749
mc 0.5 LR 0,9	9,441924	mc 0.5 LR 0,9	3,141742	mc 0.5 LR 0,8	11,35826
mc 0.6 LR 0,9	11,2942	mc 0.6 LR 0,9	4,49989	mc 0.6 LR 0,7	13,39787
mc 0.7 LR 0,9	6,861112	mc 0.7 LR 0,9	0,565215	mc 0.7 LR 0,7	8,797746
mc 0.8 LR 0,9	5,648173	mc 0.8 LR 0,9	1,882617	mc 0.8 LR 0,7	15,9978
mc 0.9 LR 0,9	5,426947	mc 0.9 LR 0,9	1,522273	mc 0.9 LR 0,6	13,30405

LAMPIRAN E
HASIL MAPE TRAINING PRODUK K3

MAPE					
K3M1		K3M2		K3M3	
MC 0,1 LR 0,4	1,354105	MC 0,1 LR 0,7	0,802387	MC 0,1 LR 0,9	0,247289
MC 0,2 LR 0,9	1,315639	MC 0,2 LR 0,9	0,763344	MC 0,2 LR 0,9	0,279282
MC 0,3 LR 0,5	1,266065	MC 0,3 LR 0,6	0,865191	MC 0,3 LR 0,9	0,287342
MC 0,4 LR 0,6	1,261088	MC 0,4 LR 0,9	0,626244	MC 0,4 LR 0,8	0,30074
MC 0,5 LR 0,3	1,232771	MC 0,5 LR 0,9	0,624597	MC 0,5 LR 0,9	0,225285
MC 0,6 LR 0,5	1,259696	MC 0,6 LR 0,8	0,676078	MC 0,6 LR 0,9	0,261929
MC 0,7 LR 0,4	1,286208	MC 0,7 LR 0,9	0,64518	MC 0,7 LR 0,9	0,165719
MC 0,8 LR 0,4	1,236708	MC 0,8 LR 0,9	0,781018	MC 0,8 LR 0,9	0,156712
MC 0,9 LR 0,7	1,216305	MC 0,9 LR 0,8	0,779256	MC 0,9 LR 0,9	0,267563
K3M4		K3M5		K3M6	
MC 0,1 LR 0,9	0,028747	MC 0,1 LR 0,9	0,001379	MC 0,1 LR 0,6	0,018088
MC 0,2 LR 0,9	0,087556	MC 0,2 LR 0,9	0,001149	MC 0,2 LR 0,4	0,007955
MC 0,3 LR 0,9	0,020523	MC 0,3 LR 0,9	0,000384	MC 0,3 LR 0,3	0,095701
MC 0,4 LR 0,9	0,003213	MC 0,4 LR 0,9	0,001469	MC 0,4 LR 0,3	0,075183
MC 0,5 LR 0,9	0,010996	MC 0,5 LR 0,9	0,001866	MC 0,5 LR 0,6	0,001604
MC 0,6 LR 0,9	0,014537	MC 0,6 LR 0,9	3,51E-08	MC 0,6 LR 0,4	0,029393
MC 0,7 LR 0,9	0,010822	MC 0,7 LR 0,9	1,27E-05	MC 0,7 LR 0,5	0,049439
MC 0,8 LR 0,9	0,006071	MC 0,8 LR 0,9	7,6E-05	MC 0,8 LR 0,5	0,008125
MC 0,9 LR 0,9	0,002933	MC 0,9 LR 0,9	4,86E-08	MC 0,9 LR 0,5	0,021136

RMSE					
K3M1		K3M2		K3M3	
mc 0,1 LR 0,6	33,48195	mc 0,1 LR 0,9	20,17191	mc 0,1 LR 0,9	11,93154
mc 0,2 LR 0,9	32,70818	mc 0,2 LR 0,9	22,7629	mc 0,2 LR 0,9	12,5801

E-2

mc 0.3 LR 0,6	31,87875	mc 0.3 LR 0,9	22,90589	mc 0.3 LR 0,9	9,223324
mc 0.4 LR 0,8	32,31604	mc 0.4 LR 0,9	19,75665	mc 0.4 LR 0,9	13,08521
mc 0.5 LR 0,4	33,36047	mc 0.5 LR 0,9	17,0173	mc 0.5 LR 0,9	8,965543
mc 0.6 LR 0,8	32,20331	mc 0.6 LR 0,9	22,64063	mc 0.6 LR 0,9	9,24904
mc 0.7 LR 0,4	34,16287	mc 0.7 LR 0,9	14,18495	mc 0.7 LR 0,9	6,687538
mc 0.8 LR 0,4	33,97834	mc 0.8 LR 0,9	24,08015	mc 0.8 LR 0,9	6,797126
mc 0.9 LR 0,9	32,11095	mc 0.9 LR 0,9	21,88788	mc 0.9 LR 0,9	5,831612
K3M4		K3M5		K3M6	
mc 0.1 LR 0,9	1,152018	mc 0.1 LR 0,9	0,079471	mc 0.1 LR 0,6	0,850951
mc 0.2 LR 0,9	1,397673	mc 0.2 LR 0,9	0,053406	mc 0.2 LR 0,5	0,263417
mc 0.3 LR 0,9	1,11942	mc 0.3 LR 0,9	0,018807	mc 0.3 LR 0,4	3,029205
mc 0.4 LR 0,9	0,155627	mc 0.4 LR 0,9	0,062467	mc 0.4 LR 0,3	3,44332
mc 0.5 LR 0,9	0,417857	mc 0.5 LR 0,9	0,087032	mc 0.5 LR 0,5	0,079585
mc 0.6 LR 0,9	0,376713	mc 0.6 LR 0,9	1,4E-06	mc 0.6 LR 0,5	1,183461
mc 0.7 LR 0,9	0,366379	mc 0.7 LR 0,9	0,00056	mc 0.7 LR 0,4	2,565597
mc 0.8 LR 0,9	0,226679	mc 0.8 LR 0,9	0,002831	mc 0.8 LR 0,5	0,345471
mc 0.9 LR 0,9	0,090676	mc 0.9 LR 0,9	2,12E-06	mc 0.9 LR 0,5	0,743352

LAMPIRAN F
HASIL MAPE TRAINING PRODUK K4

MAPE					
K4M1		K4M2		K4M3	
MC 0,1 LR 0,4	1,254224	MC 0,1 LR 0,7	0,502355	MC 0,1 LR 0,9	0,201631
MC 0,2 LR 0,3	1,285039	MC 0,2 LR 0,9	0,891169	MC 0,2 LR 0,9	0,404074
MC 0,3 LR 0,4	1,301345	MC 0,3 LR 0,9	1,246523	MC 0,3 LR 0,9	0,214978
MC 0,4 LR 0,3	1,268656	MC 0,4 LR 0,9	1,746002	MC 0,4 LR 0,9	0,184927
MC 0,5 LR 0,5	1,192126	MC 0,5 LR 0,8	0,870326	MC 0,5 LR 0,9	0,345168
MC 0,6 LR 0,3	1,340521	MC 0,6 LR 0,9	1,095134	MC 0,6 LR 0,9	0,149366
MC 0,7 LR 0,3	1,279003	MC 0,7 LR 0,9	1,058256	MC 0,7 LR 0,9	0,266695
MC 0,8 LR 0,4	1,356415	MC 0,8 LR 0,9	1,024892	MC 0,8 LR 0,9	0,461564
MC 0,9 LR 0,5	1,247208	MC 0,9 LR 0,3	0,508732	MC 0,9 LR 0,9	0,229283
K4M4		K4M5		K4M6	
MC 0,1 LR 0,9	0,09305	MC 0,1 LR 0,9	0,006274	MC 0,1 LR 0,5	0,03518
MC 0,2 LR 0,9	0,02715	MC 0,2 LR 0,9	0,001188	MC 0,2 LR 0,9	0,026527
MC 0,3 LR 0,9	0,045245	MC 0,3 LR 0,9	0,002855	MC 0,3 LR 0,4	0,0509
MC 0,4 LR 0,9	0,014252	MC 0,4 LR 0,9	0,001481	MC 0,4 LR 0,5	0,020319
MC 0,5 LR 0,9	0,041422	MC 0,5 LR 0,9	7,06E-05	MC 0,5 LR 0,4	0,038428
MC 0,6 LR 0,9	0,022637	MC 0,6 LR 0,9	0,00035	MC 0,6 LR 0,5	0,033091
MC 0,7 LR 0,9	0,020545	MC 0,7 LR 0,9	4,27E-05	MC 0,7 LR 0,6	0,023675
MC 0,8 LR 0,9	0,061222	MC 0,8 LR 0,9	2,71E-05	MC 0,8 LR 0,4	0,049808
MC 0,9 LR 0,9	0,009792	MC 0,9 LR 0,9	8E-06	MC 0,9 LR 0,5	0,03518

RMSE					
K4M1		K4M2		K4M3	
MC 0,1 LR 0,5	36,25686	mc 0,1 LR 0,9	25,72695	mc 0,1 LR 0,9	7,976907

F-2

MC 0.2 LR 0,5	34,60668	mc 0.2 LR 0,9	24,77468	mc 0.2 LR 0,9	13,48195
MC 0.3 LR 0,5	35,48777	mc 0.3 LR 0,9	26,73333	mc 0.3 LR 0,9	8,695367
MC 0.4 LR 0,6	34,40574	mc 0.4 LR 0,9	27,06163	mc 0.4 LR 0,9	12,73654
MC 0.5 LR 0,4	35,18553	mc 0.5 LR 0,9	24,6491	mc 0.5 LR 0,9	10,67417
MC 0.6 LR 0,4	35,18155	mc 0.6 LR 0,9	17,99953	mc 0.6 LR 0,9	8,115874
MC 0.7 LR 0,8	34,28291	mc 0.7 LR 0,9	25,37142	mc 0.7 LR 0,9	10,343
MC 0.8 LR 0,5	34,06931	mc 0.8 LR 0,9	25,36359	mc 0.8 LR 0,9	12,40558
MC 0.9 LR 0,8	35,06838	mc 0.9 LR 0,9	25,49847	mc 0.9 LR 0,9	9,741909
K4M4		K4M5		K4M6	
mc 0.1 LR 0,9	3,698571	mc 0.1 LR 0,9	0,394826	mc 0.1 LR 0,6	2,245095
mc 0.2 LR 0,9	0,832954	mc 0.2 LR 0,9	0,073724	mc 0.2 LR 0,5	1,239224
mc 0.3 LR 0,9	1,819381	mc 0.3 LR 0,9	0,12965	mc 0.3 LR 0,4	2,780463
mc 0.4 LR 0,9	0,476006	mc 0.4 LR 0,9	0,055651	mc 0.4 LR 0,5	0,791069
mc 0.5 LR 0,9	0,871094	mc 0.5 LR 0,9	0,005141	mc 0.5 LR 0,4	1,908592
mc 0.6 LR 0,9	0,804528	mc 0.6 LR 0,9	0,027408	mc 0.6 LR 0,5	1,775624
mc 0.7 LR 0,9	0,969798	mc 0.7 LR 0,9	0,001847	mc 0.7 LR 0,6	1,221345
mc 0.8 LR 0,9	1,725822	mc 0.8 LR 0,9	0,00139	mc 0.8 LR 0,4	2,973597
mc 0.9 LR 0,9	0,285576	mc 0.9 LR 0,9	0,000415	mc 0.9 LR 0,5	2,245095

LAMPIRAN G
HASIL MAPE TRAINING PRODUK K5

MAPE					
K5M1		K5M2		K5M3	
MC 0,1 LR 0,5	0,717334	MC 0,1 LR 0,9	0,543449	MC 0,1 LR 0,9	0,327452
MC 0,2 LR 0,4	0,763481	MC 0,2 LR 0,6	0,558363	MC 0,2 LR 0,9	0,33547
MC 0,3 LR 0,5	0,988578	MC 0,3 LR 0,9	0,479924	MC 0,3 LR 0,9	0,302746
MC 0,4 LR 0,4	0,805168	MC 0,4 LR 0,9	0,532159	MC 0,4 LR 0,9	0,125142
MC 0,5 LR 0,4	0,753552	MC 0,5 LR 0,5	0,545202	MC 0,5 LR 0,9	0,189477
MC 0,6 LR 0,4	0,787717	MC 0,6 LR 0,9	0,440105	MC 0,6 LR 0,9	0,136229
MC 0,7 LR 0,5	0,736299	MC 0,7 LR 0,9	0,429053	MC 0,7 LR 0,9	0,150244
MC 0,8 LR 0,3	0,838374	MC 0,8 LR 0,7	0,473863	MC 0,8 LR 0,9	0,156077
MC 0,9 LR 0,5	0,847432	MC 0,9 LR 0,9	0,501439	MC 0,9 LR 0,9	0,161716
K5M4		K5M5		K5M6	
MC 0,1 LR 0,9	0,103746	MC 0,1 LR 0,9	0,002763	MC 0,1 LR 0,5	0,052209
MC 0,2 LR 0,9	0,103917	MC 0,2 LR 0,9	0,001991	MC 0,2 LR 0,7	0,057762
MC 0,3 LR 0,9	0,037161	MC 0,3 LR 0,9	0,004934	MC 0,3 LR 0,5	0,039926
MC 0,4 LR 0,9	0,026525	MC 0,4 LR 0,9	0,005763	MC 0,4 LR 0,5	0,029247
MC 0,5 LR 0,9	0,020863	MC 0,5 LR 0,9	0,000427	MC 0,5 LR 0,5	0,066487
MC 0,6 LR 0,9	0,025597	MC 0,6 LR 0,9	0,001575	MC 0,6 LR 0,5	0,052209
MC 0,7 LR 0,9	0,011938	MC 0,7 LR 0,9	0,000311	MC 0,7 LR 0,5	0,066487
LMC 0,8 R 0,9	0,016668	MC 0,8 LR 0,9	0,000125	MC 0,8 LR 0,5	0,052209
MC 0,9 LR 0,9	0,003828	MC 0,9 LR 0,9	0,000713	MC 0,9 LR 0,7	0,057762

RMSE					
K5M1		K5M2		K5M3	
mc 0,1 LR 0,3	10,59583	mc 0,1 LR 0,9	7,251286	mc 0,1 LR 0,9	3,183327
mc 0,2 LR 0,6	10,2972	mc 0,2 LR 0,9	6,523515	mc 0,2 LR 0,9	3,623049

G-2

mc 0.3 LR 0,6	10,2972	mc 0.3 LR 0,9	6,842741	mc 0.3 LR 0,9	2,265646
mc 0.4 LR 0,4	10,98586	mc 0.4 LR 0,9	6,580578	mc 0.4 LR 0,9	2,03314
mc 0.5 LR 0,4	9,949876	mc 0.5 LR 0,9	6,37527	mc 0.5 LR 0,9	1,680016
mc 0.6 LR 0,7	10,32589	mc 0.6 LR 0,9	6,255795	mc 0.6 LR 0,9	1,761383
mc 0.7 LR 0,5	10,56213	mc 0.7 LR 0,9	6,648912	mc 0.7 LR 0,9	1,436772
mc 0.8 LR 0,5	11,26478	mc 0.8 LR 0,9	6,741604	mc 0.8 LR 0,9	1,995266
mc 0.9 LR 0,4	11,07614	mc 0.9 LR 0,9	6,317991	mc 0.9 LR 0,9	2,51303
K5M4		K5M5		K5M6	
mc 0.1 LR 0,9	1,033285	mc 0.1 LR 0,9	0,041222	mc 0.1 LR 0,6	0,619168
mc 0.2 LR 0,9	0,96836	mc 0.2 LR 0,9	0,023279	mc 0.2 LR 0,5	0,923994
mc 0.3 LR 0,9	0,436235	mc 0.3 LR 0,9	0,044229	mc 0.3 LR 0,5	0,529149
mc 0.4 LR 0,9	0,287835	mc 0.4 LR 0,9	0,073309	mc 0.4 LR 0,5	0,265498
mc 0.5 LR 0,9	0,290842	mc 0.5 LR 0,9	0,005151	mc 0.5 LR 0,5	0,800803
mc 0.6 LR 0,9	0,276948	mc 0.6 LR 0,9	0,021976	mc 0.6 LR 0,6	0,619168
mc 0.7 LR 0,9	0,404246	mc 0.7 LR 0,9	0,003319	mc 0.7 LR 0,5	0,800803
mc 0.8 LR 0,9	0,205337	mc 0.8 LR 0,9	0,00158	mc 0.8 LR 0,6	0,619168
mc 0.9 LR 0,9	0,030738	mc 0.9 LR 0,9	0,008376	mc 0.9 LR 0,5	0,984658

LAMPIRAN H

HASIL MAPE TRAINING PRODUK K6

MAPE					
K6M1		K6M2		K6M3	
MC 0,1 LR 0,1	0,525809	MC 0,1 LR 0,8	0,336811	MC 0,1 LR 0,9	0,248579
MC 0,2 LR 0,7	0,473529	MC 0,2 LR 0,9	0,361282	MC 0,2 LR 0,9	0,192809
MC 0,3 LR 0,7	0,462584	MC 0,3 LR 0,9	0,355322	MC 0,3 LR 0,8	0,249306
MC 0,4 LR 0,5	0,444706	MC 0,4 LR 0,9	0,309981	MC 0,4 LR 0,7	0,222039
MC 0,5 LR 0,4	0,460805	C 0,5 LR 0,8	0,372616	MC 0,5 LR 0,6	0,166373
MC 0,6 LR 0,5	0,507665	MC 0,6 LR 0,9	0,334814	MC 0,6 LR 0,9	0,167104
MC 0,7 LR 0,3	0,466942	MC 0,7 LR 0,9	0,26107	MC 0,7 LR 0,9	0,269056
MC 0,8 LR 0,9	0,455583	MC 0,8 LR 0,9	0,341917	MC 0,8 LR 0,7	0,194774
MC 0,9 LR 0,4	0,488172	MC 0,9 LR 0,4	0,368918	MC 0,9 LR 0,9	0,187639
K6M4		K6M5		K6M6	
MC 0,1 LR 0,9	0,087408	MC 0,1 LR 0,9	0,002898	MC 0,1 LR 0,6	0,011952
MC 0,2 LR 0,9	0,066571	MC 0,2 LR 0,9	0,000294	MC 0,2 LR 0,6	0,011918
MC 0,3 LR 0,9	0,046782	MC 0,3 LR 0,9	0,003581	MC 0,3 LR 0,6	0,007095
MC 0,4 LR 0,9	0,098178	MC 0,4 LR 0,9	0,000469	MC 0,4 LR 0,4	0,050366
MC 0,5 LR 0,9	0,053505	MC 0,5 LR 0,9	0,000174	MC 0,5 LR 0,4	0,017339
MC 0,6 LR 0,9	0,066913	MC 0,6 LR 0,9	1,01E-05	MC 0,6 LR 0,5	0,007365
MC 0,7 LR 0,9	0,069634	MC 0,7 LR 0,9	0,000868	MC 0,7 LR 0,6	0,007701
MC 0,8 LR 0,9	0,055951	MC 0,8 LR 0,9	7,66E-05	MC 0,8 LR 0,7	0,021525
MC 0,9 LR 0,9	0,031162	MC 0,9 LR 0,9	1,4E-09	MC 0,9 LR 0,7	0,01601

RMSE					
K6M1		K6M2		K6M3	
mc 0,1 LR 0,4	3,564926	mc 0,1 LR 0,9	2,488473	mc 0,1 LR 0,9	1,708959
mc 0,2 LR 0,7	3,482515	mc 0,2 LR 0,9	2,827666	mc 0,2 LR 0,9	1,198393

H-2

mc 0.3 LR 0,7	3,491558	mc 0.3 LR 0,9	2,577064	mc 0.3 LR 0,9	1,531687
mc 0.4 LR 0,6	3,50614	mc 0.4 LR 0,9	2,892827	mc 0.4 LR 0,9	1,081942
mc 0.5 LR 0,5	3,720237	mc 0.5 LR 0,9	2,351372	mc 0.5 LR 0,9	1,374409
mc 0.6 LR 0,5	3,842746	mc 0.6 LR 0,9	2,699534	mc 0.6 LR 0,9	1,568057
mc 0.7 LR 0,4	3,54163	mc 0.7 LR 0,9	2,198335	mc 0.7 LR 0,9	1,332082
mc 0.8 LR 0,9	3,518473	mc 0.8 LR 0,9	2,765767	mc 0.8 LR 0,9	1,188093
mc 0.9 LR 0,9	3,505433	mc 0.9 LR 0,9	2,569367	mc 0.9 LR 0,9	1,198817
K6M4		K6M5		K6M6	
mc 0.1 LR 0,9	0,574073	mc 0.1 LR 0,9	0,018621	mc 0.1 LR 0,6	0,179766
mc 0.2 LR 0,9	0,542531	mc 0.2 LR 0,9	0,002051	mc 0.2 LR 0,6	0,121784
mc 0.3 LR 0,9	0,527431	mc 0.3 LR 0,9	0,026872	mc 0.3 LR 0,6	0,041131
mc 0.4 LR 0,9	0,832665	mc 0.4 LR 0,9	0,003194	mc 0.4 LR 0,5	0,248508
mc 0.5 LR 0,9	0,566367	mc 0.5 LR 0,9	0,001613	mc 0.5 LR 0,4	0,096783
mc 0.6 LR 0,9	0,792363	mc 0.6 LR 0,9	4,77E-05	mc 0.6 LR 0,5	0,056958
mc 0.7 LR 0,9	0,768958	mc 0.7 LR 0,9	0,017875	mc 0.7 LR 0,6	0,072134
mc 0.8 LR 0,9	0,551515	mc 0.8 LR 0,9	0,000455	mc 0.8 LR 0,7	0,173149
mc 0.9 LR 0,9	0,508152	mc 0.9 LR 0,9	1,55E-08	mc 0.9 LR 0,5	0,170555

BIODATA PENULIS



Penulis lahir di Ponorogo pada tanggal 06 Januari 1994 merupakan anak bungsu dari dua bersaudara. Penulis telah menempuh pendidikan formal di SD Negeri 2 Kadipaten, SMP Negeri 2 Ponorogo, dan SMA Negeri 2 Ponorogo. Setelah selesai menempuh pendidikan SMA, penulis melanjutkan pendidikan di Jurusan Sistem Informasi FTIf-ITS dan menjadi mahasiswa Sistem Informasi tahun angkatan 2012.

Selama menempuh pendidikan di perguruan tinggi, penulis aktif dalam berorganisasi, dibuktikan dengan menjadi staff Riset dan Teknologi Himpunan Mahasiswa Sistem Informasi.

Selain itu, Penulis juga aktif dalam kegiatan kepanitian ormawa seperti ITS Open dan Panitia IWIC 7 Region Surabaya. Dalam bidang akademik, penulis juga aktif dibuktikan dengan menjadi *grader* mata kuliah Matematika Diskrit dan Pengukuran Kinerja Teknologi Informasi. Pada semester delapan perkuliahan, penulis mulai mengerjakan Tugas Akhir di Laboratorium Rekayasa Data dan Intelegensi Bisnis, di bawah bimbingan Bapak Edwin Riksakomara, S.Kom., M.T., penulis mengambil topik mengenai teknik peramalan. Semoga penulisan Tugas Akhir ini mampu memberikan kontribusi positif bagi semua pihak terkait. Untuk mendapatkan informasi lebih lanjut mengenai tugas akhir ini dapat menghubungi penulis melalui email ari.dwiningsih@gmail.com.