



TUGAS AKHIR - IS184853

**PERAMALAN JUMLAH PENUMPANG KRL
COMMUTER LINE MENGGUNAKAN METODE *DEEP
NEURAL NETWORK* (DNN)**

***FORECASTING THE NUMBER OF COMMUTER LINE
TRAIN PASSENGER USING DEEP NEURAL
NETWORK (DNN) METHOD***

IRSHAD AL ISLAMY
NRP 0521154000049

Dosen Pembimbing
Wiwik Anggraeni, S.Si., M.Kom.

DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Informasi dan Komunikasi
Institut Teknologi Sepuluh Nopember
Surabaya 2019

TUGAS AKHIR – IS184853

**PERAMALAN JUMLAH PENUMPANG KRL
COMMUTER LINE MENGGUNAKAN
METODE *DEEP NEURAL NETWORK* (DNN)**

**IRSHAD AL ISLAMY
NRP 0521154000049**

**Dosen Pembimbing
Wiwik Anggraeni, S.Si., M.Kom.**

**DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Informasi dan Komunikasi
Institut Teknologi Sepuluh Nopember Surabaya 2019**

Halaman ini sengaja dikosongkan

FINAL PROJECT – IS184853

***FORECASTING THE NUMBER OF
COMMUTER LINE TRAIN PASSENGER
USING DEEP NEURAL NETWORK (DNN)
METHOD***

**IRSHAD AL ISLAMY
NRP 0521154000049**

**Supervisor
Wiwik Anggraeni, S.Si., M.Kom.**

**INFORMATION SYSTEMS DEPARTMENT
Faculty of Information and Communication Technology
Sepuluh Nopember Institute of Technology
Surabaya 2019**

Halaman ini sengaja dikosongkan

LEMBAR PENGESAHAN

PERAMALAN JUMLAH PENUMPANG KRL COMMUTER LINE MENGGUNAKAN METODE DEEP NEURAL NETWORK (DNN)

TUGAS AKHIR

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

Oleh:

IRSHAD AL ISLAMY

NRP. 05211540000049

Surabaya, 18 Juli 2019

KEPALA

DEPARTEMEN SISTEM INFORMASI



Mahendrawathi ER, S.T., M.Sc., Ph.D

NIP. 19761011 200604 2 001

Halaman ini sengaja dikosongkan

LEMBAR PERSETUJUAN

PERAMALAN JUMLAH PENUMPANG KRL COMMUTER LINE MENGGUNAKAN METODE DEEP NEURAL NETWORK

TUGAS AKHIR

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

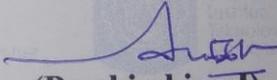
Oleh :

IRSHAD AL ISLAMY

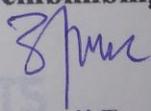
NRP. 05211540000049

Disetujui Tim Penguji : Tanggal Ujian : 5 Juli 2019
Periode Wisuda : September 2019

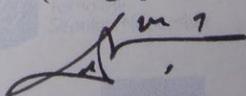
Wiwik Anggraeni, S.Si., M.Kom.


(Pembimbing I)

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


(Penguji I)

Faizal Mahananto, S.Kom., M.Eng


(Penguji II)



Halaman ini sengaja dikosongkan

PERAMALAN JUMLAH PENUMPANG KRL COMMUTER LINE MENGGUNAKAN METODE DEEP NEURAL NETWORK (DNN)

Nama Mahasiswa : Irshad Al Islamy
NRP : 0521154000049
Departemen : Sistem Informasi
Dosen Pembimbing : Wiwik Anggraeni, S.Si., M.Kom.

ABSTRAK

KRL Commuter Line merupakan salah satu transportasi yang diminati oleh masyarakat DKI Jakarta. Hal ini ditunjukkan oleh peningkatan jumlah pengguna KRL Commuter Line dari Januari 2013 hingga Juli 2018 dimana pada Januari 2013, jumlah penumpang KRL Commuter Line mencapai 10.089.000 penumpang dan meningkat hingga 29.086.000 penumpang pada Juli 2018. Tingginya minat masyarakat DKI Jakarta terhadap KRL Commuter Line menjadikan PT.KAI Commuter Jakarta seyogyanya mampu mengantisipasi kenaikan jumlah penumpang di masa yang akan datang. Karena itu, diperlukan peramalan jumlah penumpang KRL Commuter Line yang bertujuan untuk mengetahui perkiraan jumlah penumpang KRL Commuter Line pada masa depan.

Dalam menyelesaikan permasalahan meramalkan jumlah penumpang KRL Commuter Line di masa yang akan datang, dilakukan dengan menggunakan metode DNN (Deep Neural Network) dengan menggunakan enam variabel, yaitu; variabel waktu keberangkatan penumpang (hari, tanggal, dan bulan), variabel hari libur, variabel stasiun, dan variabel jumlah penumpang pada waktu dan stasiun tersebut. Hasil yang didapatkan dari peramalan menggunakan model yang didapatkan dari metode DNN (Deep Neural Network) menunjukkan nilai akurasi yang sangat baik untuk setiap

stasiun yang dilalui KRL Commuter Line yaitu dengan MAPE < 10% dimana stasiun dengan MAPE terkecil dimiliki oleh Stasiun Depok Baru dengan nilai 0.706% dan MAPE terbesar dimiliki oleh Stasiun Cawang dengan nilai 9.964% serta rata-rata MAPE seluruh stasiun yaitu 3.423%. Hal ini berarti model yang diperoleh mempunyai hasil peramalan yang sangat baik. Harapan yang diharapkan dari penelitian peramalan dalam tugas akhir ini yaitu kebermanfaatan hasil peramalan sebagai bahan pertimbangan dalam memutuskan kebijakan dalam mengantisipasi kenaikan jumlah penumpang KRL Commuter Line di masa depan.

Kata Kunci : Data Deret Waktu, DNN (Deep Neural Network, MAPE, Penumpang KRL Commuter Line, Peramalan

**FORECASTING THE NUMBER OF COMMUTER LINE
TRAIN PASSENGER USING DEEP NEURAL NETWORK
(DNN) METHOD**

Name : Irshad Al Islamy
NRP : 0521154000049
Department : Information Systems
Supervisor : Wiwik Anggraeni, S.Si., M.Kom.

ABSTRACT

KRL Commuter Line is one of the most favourable transportation for people in DKI Jakarta. This is indicated by the increasing of the number of Commuter Line KRL passengers from January 2013 to July 2018 which in January 2013, the number of KRL Commuter Line passengers reached 10,089,000 passengers and increased to 29,086,000 passengers in July 2018. The high interest of the DKI Jakarta people towards KRL Commuter Line makes PT. KAI Jakarta Commuter should be able to anticipate the increasing of the number of passengers in the future. Therefore, it is necessary to forecast the number of KRL Commuter Line passengers which aims to determine the estimated number of KRL Commuter Line passengers in the future.

In solving the problem of predicting the number of KRL Commuter Line passengers in the future, DNN (Deep Neural Network) method used with six variables, that are; departure time (day, month, year) variable, holiday variable, final destination station variable, and the number of passengers at that time and station. The obtained forecasting results from the obtained model from the DNN (Deep Neural Network) method show very good accuracy rate for each station of KRL Commuter Line with MAPE <10% which the station with the

smallest MAPE is Depok Baru Station with 0.706 % and the biggest MAPE is Cawang Station with 9.964% and the average MAPE of all stations is 3.423%. This means that the obtained model has very good forecasting results. The expectations of this study is the usefulness of this study as a consideration in deciding policies for anticipation of the increasing number of Commuter Line KRL passengers in the future.

Keywords: DNN (Deep Neural Network), Forecasting, KRL Commuter Line Passengers, MAPE, Time Series Data

KATA PENGANTAR

Puji syukur kehadirat Allah atas segala limpahan rahmat dan karunia-Nya hingga saat ini sehingga penulis dapat menyelesaikan tugas akhir dengan judul **Peramalan Jumlah Penumpang KRL Commuter Line Menggunakan Metode Deep Neural Network (DNN)**. Penulis menghaturkan terima kasih kepada seluruh pihak yang telah mendukung, memberi saran, motivasi, bantuan baik moril, spiritual, dan materi dalam pembuatan tugas akhir ini hingga selesai. Secara khusus, penulis menghaturkan terima kasih kepada:

1. Papa (Awwaby Hafidz), Ibu (Yenny Husrida), Uni (Jazmin Nabila) dan yang telah dipanggil Allah, Abang (Auzan Yusofi) yang hingga saat ini selalu mendukung penulis dan memberi semangat.
2. Ibu Hanim Maria Astuti, S.Kom, M.Sc. selaku dosen wali penulis yang membimbing saya dari awal perkuliahan hingga akhir kuliah.
3. Ibu Wiwik Anggraeni, S.Si., M.Kom. selaku dosen pembimbing pertama penulis yang meluangkan waktu, memberikan ilmu serta petunjuk dan memotivasi untuk kelancaran tugas akhir ini.
4. Bapak Erwin Riksakomara, S.Kom., M.T. dan Bapak Faizal Mahananto, S.Kom., M.Eng., selaku dosen penguji yang telah memberikan saran dan kritik untuk perbaikan tugas akhir.
5. Seluruh dosen Jurusan Sistem Informasi ITS yang telah memberikan ilmu yang bermanfaat kepada penulis.
6. Iqlima Hafidatun Nisa' Islamiah (Mba Iqma) dan Aatikah Zaki Rihaadatul`Aisy (Mba Tika (Kyo)) yang telah bersama dengan penulis di kala suka dan duka selama kuliah di SI ITS.

7. Alifah Nur Suciani, Septian Ikhsanuddin Alfarizi, dan Dhiemas Rakadewa yang telah menemani penulis dari mahasiswa baru hingga tugas akhir ini dapat diselesaikan.
8. Andira Gita Nawangsari, Ratih Cahyaningtyas, Gamal Akbar Adzani, I Gusti Agung Premananda, Magrid Prisca Juwita, dan seluruh teman RDIB dan ADDI yang telah berjuang bersama menyelesaikan tugas akhir ini.
9. Teman-teman grup Lambe Turah IFLS yang telah memberikan dukungan kepada penulis dan menghibur penulis di kala penulis suntuk dengan tugas akhir.
10. Berbagai pihak yang tidak dapat dituliskan satu persatu yang telah turut serta menyukseskan penulis dalam menyelesaikan tugas akhir.

Penyusunan laporan ini memiliki berbagai kekurangan sehingga penulis menerima segala kritik dan saran yang membangun untuk perbaikan di masa depan. Semoga buku tugas akhir ini dapat memberikan manfaat bagi pembaca.

Surabaya, 30 Juni 2019

Irshad Al Islamy

DAFTAR ISI

| | |
|-------------------------------------|-------|
| LEMBAR PENGESAHAN..... | v |
| LEMBAR PERSETUJUAN..... | vii |
| ABSTRAK | ix |
| ABSTRACT | xi |
| KATA PENGANTAR | xiii |
| DAFTAR ISI | xv |
| DAFTAR GAMBAR | xix |
| DAFTAR TABEL..... | xxiii |
| BAB I PENDAHULUAN | 1 |
| 1.1. Latar Belakang..... | 1 |
| 1.2. Perumusan Masalah | 3 |
| 1.3. Batasan Masalah | 4 |
| 1.4. Tujuan Tugas Akhir | 4 |
| 1.5. Manfaat Tugas Akhir | 4 |
| 1.6. Relevansi | 5 |
| BAB II TINJAUAN PUSTAKA | 7 |
| 2.1. Studi Sebelumnya | 7 |
| 2.2. Dasar Teori | 8 |
| 2.2.1. Definisi Peramalan | 9 |
| 2.2.2. Pengelompokan Peramalan..... | 9 |
| 2.2.3. Data Peramalan | 10 |

| | | |
|--|--|----|
| 2.2.4. | Proses Peramalan..... | 11 |
| 2.2.5. | <i>Artificial Neural Network (ANN)</i> | 11 |
| 2.2.6. | <i>Deep Neural Network (DNN)</i> | 14 |
| 2.2.7. | Akurasi Peramalan..... | 17 |
| BAB III METODOLOGI PENELITIAN | | 21 |
| 3.1. | Tahapan Pelaksanaan Tugas Akhir | 21 |
| 3.1.1. | Identifikasi masalah | 22 |
| 3.1.2. | Studi Literatur | 23 |
| 3.1.3. | Penentuan Metode dari Literatur | 23 |
| 3.1.4. | Persiapan Data..... | 23 |
| 3.1.5. | Permodelan Peramalan | 24 |
| 3.1.6. | Pengujian Model Peramalan..... | 24 |
| 3.1.7. | Analisa Hasil dan Penarikan Kesimpulan..... | 24 |
| BAB IV PERANCANGAN | | 27 |
| 4.1. | Persiapan Data | 27 |
| 4.2. | Pra Proses Data | 27 |
| 4.3. | Perancangan Model DNN | 33 |
| BAB V IMPLEMENTASI | | 45 |
| 5.1. | Pengelompokan Data Jumlah Penumpang di Setiap Stasiun Tujuan Berdasarkan Pola Data | 45 |
| 5.2. | Implementasi DNN dengan <i>Tools</i> RapidMiner pada Data Aktual | 49 |
| 5.2.1 | Persiapan Data Input..... | 50 |
| 5.2.2 | Cross – Validation | 54 |

| | | |
|-----------------------------------|--|----|
| 5.2.3 | Penerapan Model DNN | 57 |
| 5.2.4 | Penghitungan MSE dari Model DNN | 57 |
| 5.3. | Implementasi DNN dengan <i>Tools</i> RapidMiner pada Kelompok Pola Data yang Sama dan Data untuk Peramalan (<i>Forecasting</i>) ke Depan | 58 |
| BAB VI HASIL DAN PEMBAHASAN | | 59 |
| 6.1. | Hasil Uji Coba Parameter Jumlah <i>Hidden Layer</i> dan Neuron pada Model DNN | 59 |
| 6.2. | Hasil Uji Coba Parameter Jumlah <i>Epochs</i> pada Model DNN | 66 |
| 6.3. | Hasil Uji Coba Parameter Nilai <i>Epsilon</i> pada Model DNN | 67 |
| 6.4. | Hasil Uji Coba Parameter Nilai <i>Rho</i> pada Model DNN | 68 |
| 6.5. | Hasil Akhir Uji Coba Seluruh Parameter pada Model DNN | 69 |
| 6.6. | Hasil Pengujian Model DNN untuk Data Jumlah di Setiap Stasiun Tujuan dengan Pola Data Seasonal | 70 |
| 6.7. | Hasil Pengujian Model DNN untuk Data Jumlah di Setiap Stasiun Tujuan dengan Pola Data Stasioner | 76 |
| 6.8. | Hasil Pengujian Model DNN untuk Data Jumlah di Setiap Stasiun Tujuan dengan Pola Data Seasonal Sisir Terbalik | 89 |
| 6.9. | Hasil Pengujian Model DNN untuk Data Jumlah di Setiap Stasiun Tujuan dengan Pola Data Seasonal dengan Nilai Ekstrem..... | 98 |

| | | |
|---|---|-------|
| 6.10. | Hasil Pengujian Model DNN untuk Data Jumlah di Setiap Stasiun Tujuan dengan Pola Data Seasonal Sisir Terbalik dengan Nilai Ekstrem | 102 |
| 6.11. | Analisis Terhadap Hasil Pengujian Model DNN untuk Data Jumlah Penumpang di Setiap Stasiun Tujuan | 106 |
| 6.12. | Hasil Uji Nilai Parameter <i>Epsilon</i> Baru pada Model DNN untuk Kelompok Data Jumlah Penumpang di Setiap Stasiun Khusus MAPE > 10% | 109 |
| 6.13. | Analisis MAPE dan MSE Seluruh Stasiun Tujuan.... | 119 |
| BAB VII KESIMPULAN DAN SARAN..... | | 125 |
| 7.1. | Kesimpulan | 125 |
| 7.2. | Saran | 126 |
| DAFTAR PUSTAKA..... | | 127 |
| BIODATA PENULIS..... | | 129 |
| LAMPIRAN A. DATA MENTAH | | A-131 |
| LAMPIRAN B: GRAFIK CONTOH POLA DATA | | B-132 |
| LAMPIRAN C: DATA PENGUJIAN MODEL DNN (<i>Deep Neural Network</i>) | | C-137 |
| LAMPIRAN D: DATA HASIL PERAMALAN | | D-138 |

DAFTAR GAMBAR

| | |
|--|----|
| Gambar 1. 1 Grafik Hasil Survey Pengguna Harian Transportasi Umum di DKI Jakarta Tahun 2017 | 2 |
| Gambar 2. 1 Struktur dari ANN | 12 |
| Gambar 2. 2 Multilayer Perceptron | 12 |
| Gambar 2. 3 Arsitektur Deep Neural Network (DNN) | 14 |
| Gambar 3. 1 Alur Pengerjaan Tugas Akhir | 22 |
| Gambar 5. 1 Rangkaian Alur Blok Operator Implementasi DNN dengan Rapidminer pada Data Aktual | 50 |
| Gambar 5. 2 Tombol “ <i>Import Data</i> ” | 50 |
| Gambar 5. 3 Panel “ <i>Import Data – Where is your data?</i> ” | 51 |
| Gambar 5. 4 Operator “ <i>Retrieve</i> ” | 51 |
| Gambar 5. 5 Operator “ <i>Split Data</i> ” | 52 |
| Gambar 5. 6 Tombol “ <i>Edit Enumeration</i> ” pada Parameter “ <i>partitions</i> ” | 52 |
| Gambar 5. 7 Tampilan Panel “ <i>Edit Parameter List: partitions</i> ” | 53 |
| Gambar 5. 8 Operator “ <i>Set Role</i> ” | 53 |
| Gambar 5. 9 Operator “ <i>Cross Validation</i> ” | 54 |
| Gambar 5. 10 Dua Subset Proses dalam Cross Validation | 55 |
| Gambar 5. 11 Panel “ <i>Edit Parameter List: hidden layer sizes</i> ” | 56 |
| Gambar 5. 12 Parameter <i>Epochs</i> dengan Nilai 1500 | 57 |

Gambar 5. 13 Parameter *Epsilon* dengan Nilai 1×10^{-10} dan *Rho* dengan Nilai 0.9957

Gambar 5. 14 Operator “Apply Model”57

Gambar 5. 15 Operator “*Performance*”58

Gambar 5. 16 Rangkaian Alur Blok Operator Implementasi DNN dengan Rapidminer pada Kelompok Pola Data yang Sama dan Data untuk Peramalan (*Forecasting*) ke Depan.....58

Gambar 6. 1 Grafik Hasil Pengujian Stasiun Tanah Abang ...71

Gambar 6. 2 Grafik Hasil Pengujian Stasiun Sudirman72

Gambar 6. 3 Grafik Hasil Pengujian Stasiun Bekasi73

Gambar 6. 4 Grafik Hasil Pengujian Stasiun Karet74

Gambar 6. 5 Grafik Hasil Pengujian Stasiun Univ. Pancasila75

Gambar 6. 6 Grafik Hasil Pengujian Stasiun Bogor77

Gambar 6. 7 Grafik Hasil Pengujian Stasiun Tangerang78

Gambar 6. 8 Grafik Hasil Pengujian Stasiun Duri79

Gambar 6. 9 Grafik Hasil Pengujian Stasiun Parung Panjang80

Gambar 6. 10 Grafik Hasil Pengujian Stasiun Serpong81

Gambar 6. 11 Grafik Hasil Pengujian Stasiun Kemayoran82

Gambar 6. 12 Grafik Hasil Pengujian Stasiun Kali Deres83

Gambar 6. 13 Grafik Hasil Pengujian Stasiun Gang Sentiong84

Gambar 6. 14 Grafik Hasil Pengujian Stasiun Pondok Jati....85

Gambar 6. 15 Grafik Hasil Pengujian Stasiun Bojong Indah.86

| | |
|---|-----|
| Gambar 6. 16 Grafik Hasil Pengujian Stasiun Cibinong | 87 |
| Gambar 6. 17 Grafik Hasil Pengujian Stasiun Daru | 88 |
| Gambar 6. 18 Grafik Hasil Pengujian Stasiun Tambun..... | 89 |
| Gambar 6. 19 Grafik Hasil Pengujian Pasar Senen | 90 |
| Gambar 6. 20 Grafik Hasil Pengujian Stasiun Tiga Raksa | 91 |
| Gambar 6. 21 Grafik Hasil Pengujian Stasiun Nambo | 92 |
| Gambar 6. 22 Grafik Hasil Pengujian Stasiun Tenjo | 93 |
| Gambar 6. 23 Grafik Hasil Pengujian Stasiun Maja | 94 |
| Gambar 6. 24 Grafik Hasil Pengujian Tanjung Stasiun Priok | 95 |
| Gambar 6. 25 Grafik Hasil Pengujian Stasiun Angke | 96 |
| Gambar 6. 26 Grafik Hasil Pengujian Stasiun Citeras | 97 |
| Gambar 6. 27 Grafik Hasil Pengujian Rongkas Stasiun Bitung | 98 |
| Gambar 6. 28 Grafik Hasil Pengujian Stasiun Juanda | 99 |
| Gambar 6. 29 Grafik Hasil Pengujian Stasiun Buaran..... | 100 |
| Gambar 6. 30 Grafik Hasil Pengujian Stasiun Tanah Tinggi | 101 |
| Gambar 6. 31 Grafik Hasil Pengujian Stasiun Bekasi Timur | 102 |
| Gambar 6. 32 Grafik Hasil Pengujian Stasiun Jakarta Kota | 103 |
| Gambar 6. 33 Grafik Hasil Pengujian Stasiun Ancol | 104 |
| Gambar 6. 34 Grafik Hasil Pengujian Stasiun Cibitung | 105 |

| | |
|--|-----|
| Gambar 6. 35 Grafik Hasil Pengujian Stasiun Cikarang..... | 106 |
| Gambar 6. 36 Grafik Hasil Pengujian Stasiun Sudirman..... | 111 |
| Gambar 6. 37 Grafik Hasil Pengujian Stasiun Karet | 112 |
| Gambar 6. 38 Grafik Hasil Pengujian Stasiun Univ. Pancasila | 113 |
| Gambar 6. 39 Grafik Hasil Pengujian Stasiun Parung Panjang | 114 |
| Gambar 6. 40 Grafik Hasil Pengujian Stasiun Bojong Indah | 115 |
| Gambar 6. 41 Grafik Hasil Pengujian Stasiun Tanjung Priok | 116 |
| Gambar 6. 42 Grafik Hasil Pengujian Stasiun Citeras | 117 |
| Gambar 6. 43 Grafik Hasil Pengujian Stasiun Ancol..... | 118 |
| Gambar B. 1 Jumlah Penumpang KRL Commuter Line Stasiun Tanah Abang | 132 |
| Gambar B. 2 Jumlah Penumpang KRL Commuter Line Stasiun Bogor..... | 133 |
| Gambar B. 3 Jumlah Penumpang KRL Commuter Line Stasiun Nambo | 134 |
| Gambar B. 4 Jumlah Penumpang KRL Commuter Line Stasiun Juanda..... | 135 |
| Gambar B. 5 Jumlah Penumpang KRL Commuter Line Stasiun Jakarta Kota | 136 |

DAFTAR TABEL

| | |
|--|----|
| Tabel 2. 1 Tingkat Signifikansi MAPE | 19 |
| Tabel 4. 1 Konversi Data Non-Numerik pada Variabel Hari Keberangkatan Penumpang ke Data Numerik | 28 |
| Tabel 4. 2 Konversi Data Non-Numerik pada Variabel Bulan Keberangkatan Penumpang ke Data Numerik | 29 |
| Tabel 4. 3 Konversi Data Non-Numerik pada Variabel Hari Libur ke Data Numerik | 29 |
| Tabel 4. 4 Konversi Data Non-Numerik pada Variabel Stasiun ke Data Numerik | 30 |
| Tabel 4. 5 Tabel Perancangan Model DNN..... | 34 |
| Tabel 4. 6 Skenario Eksperimen Kombinasi Jumlah Neuron dengan Hidden Layer Optimal | 36 |
| Tabel 4. 7 Skenario Eksperimen Jumlah Epochs Optimal | 40 |
| Tabel 4. 8 Skenario Eksperimen Jumlah <i>Epsilon</i> Optimal | 41 |
| Tabel 4. 9 Skenario Eksperimen Jumlah <i>Rho</i> Optimal | 41 |
| Tabel 5. 1 Kelompok Pola Data | 45 |
| Tabel 6. 1 Nilai MSE untuk Skenario 1-9 | 60 |
| Tabel 6. 2 Nilai MSE untuk Skenario 10-18 | 61 |
| Tabel 6. 3 Nilai MSE untuk Skenario 19 - 36 | 62 |
| Tabel 6. 4 Nilai MSE untuk Skenario 37 - 45 | 63 |
| Tabel 6. 5 Nilai MSE untuk Skenario 46- 63 | 64 |

| | |
|---|-----|
| Tabel 6. 6 Nilai MSE untuk Hidden Layer dan Neuron Optimal | 65 |
| Tabel 6. 7 Nilai MSE untuk Nilai Epochs Optimal | 66 |
| Tabel 6. 8 Nilai MSE untuk Nilai <i>Epsilon</i> Optimal | 67 |
| Tabel 6. 9 Nilai MSE untuk Nilai <i>Rho</i> Optimal..... | 69 |
| Tabel 6. 10 Nilai Parameter dalam Model Terbaik..... | 70 |
| Tabel 6. 11 Hasil Analisa Pengujian Model DNN Terhadap Data Jumlah Penumpang di Setiap Stasiun Tujuan..... | 108 |
| Tabel 6. 12 Nilai MSE untuk Skenario 85 dan 86 | 110 |
| Tabel 6. 13 Nilai Parameter Terbaik dalam Model Terbaik untuk Kelompok Stasiun Khusus dengan MAPE > 10% | 110 |
| Tabel 6. 14 Hasil MAPE dan MSE Seluruh Stasiun Tujuan | 119 |

BAB I

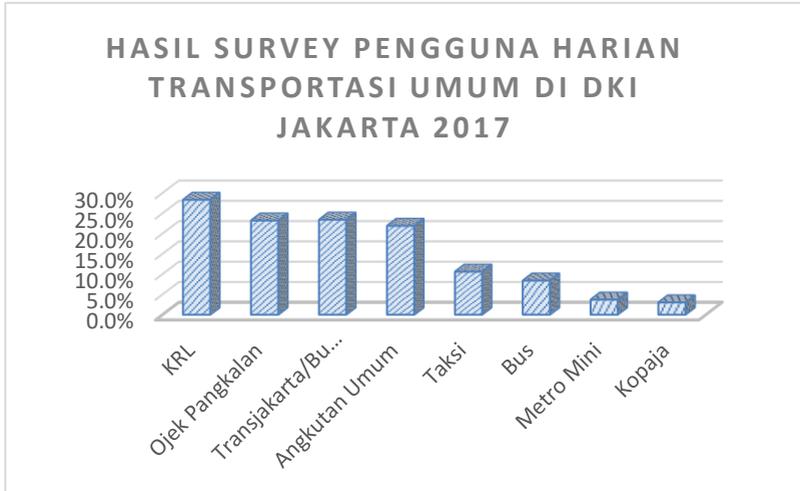
PENDAHULUAN

Pada bagian pendahuluan ini terdapat penjelasan mengenai latar belakang masalah, perumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, serta relevansi tugas akhir. Berdasarkan uraian pada bab ini diharapkan gambaran umum mengenai permasalahan dan pemecahan masalah pada tugas akhir dapat dipahami.

1.1. Latar Belakang

Transportasi merupakan sesuatu yang menyediakan mobilitas atau pergerakan barang dan manusia menuju suatu tempat dari tempat sebelumnya. Fungsi dari transportasi ini menyebabkan transportasi menjadi hal yang vital bagi DKI Jakarta yang memiliki jumlah penduduk terpadat di Indonesia. Untuk mendukung fungsi transportasi tersebut, maka DKI Jakarta membangun berbagai macam jenis transportasi, salah satunya adalah KRL Commuter Line.

KRL Commuter Line merupakan salah satu transportasi yang diminati oleh masyarakat DKI Jakarta. Hal ini dibuktikan oleh sebuah survey pengguna transportasi umum harian tahun 2017 yang dilakukan oleh Cermati.com terhadap 6.904 responden yang menyatakan bahwa KRL Commuter Line unggul sebagai transportasi umum terfavorit masyarakat DKI Jakarta dengan presentase 28.3% [1].



Gambar 1. 1 Grafik Hasil Survey Pengguna Harian Transportasi Umum di DKI Jakarta Tahun 2017

Sebagai salah satu transportasi favorit masyarakat DKI Jakarta, maka sudah selayaknya PT. KAI Commuter Jakarta dapat memenuhi alur pergerakan penumpang yang ada melalui berbagai cara, salah satu diantaranya adalah dengan penambahan kereta. Untuk dapat merencanakan dengan baik jumlah kereta yang akan ditambahkan, dibutuhkan peramalan jumlah penumpang KRL Commuter Line agar jumlah kereta yang ditambahkan sesuai dengan alur pergerakan penumpang. Salah satu metode peramalan yang dapat digunakan adalah metode peramalan berdasarkan DNN (Deep Neural Network) yang mana metode ini menggunakan berbagai faktor yang mempengaruhi hasil peramalan.

Metode DNN (Deep Neural Network) dipilih untuk memecahkan permasalahan peramalan penumpang kereta api ini karena DNN (Deep Neural Network) merupakan sebuah neural network buatan yang terdiri dari berbagai hidden layers

dan bekerja dengan mempertimbangkan seluruh faktor yang mempengaruhi hasil peramalan dan pendekatan permodelan. Penelitian menggunakan metode DNN ini telah dilakukan oleh Rung-Ching Chen dan Lijuan Liu yang ditulis dalam sebuah jurnal berjudul “A MRT Daily Passenger Flow Prediction Model with Different Combinations of Influential Factors” yang di dalam kesimpulannya dituliskan bahwa model dari metode DNN (Deep Neural Network) ini secara efektif menangkap hubungan non-linier antara jumlah penumpang dengan faktor yang mempengaruhinya, yang dapat memberikan hasil prediksi yang baik [2].

Berdasarkan penelitian yang dilakukan oleh Rung-Ching Chen dan Lijuan Liu pada paragraph sebelumnya terkait peramalan jumlah penumpang KRL menggunakan metode DNN, maka diuji keefektifan dari metode DNN dalam memecahkan permasalahan peramalan jumlah penumpang dengan studi kasus KRL Commuter Line.

1.2. Perumusan Masalah

Berdasarkan latar belakang di atas, berikut adalah rumusan masalah berupa pertanyaan-pertanyaan yang akan terjawab dengan adanya tugas akhir ini.

1. Bagaimana model peramalan jumlah penumpang KRL Commuter Line dengan menggunakan metode DNN (Deep Neural Network)?
2. Bagaimana hasil peramalan jumlah penumpang KRL Commuter Line menggunakan metode DNN (Deep Neural Network)?

3. Seberapa baik kinerja dari metode DNN (Deep Neural Network) dalam peramalan jumlah penumpang KRL Commuter Line?

1.3. Batasan Masalah

Batasan pada penelitian ini yaitu pada peramalan jumlah penumpang KRL Commuter Line menggunakan data jumlah penumpang KRL Commuter Line per hari dari tanggal 1 Januari 2018 hingga 31 Desember 2018 menggunakan metode DNN (Deep Neural Network) dengan *tools* yang digunakan adalah RapidMiner.

1.4. Tujuan Tugas Akhir

Dengan melihat rumusan masalah yang telah dituliskan pada sub bab 1.2. Perumusan Masalah, maka tujuan dari tugas akhir ini yaitu:

1. Mengetahui model peramalan jumlah penumpang KRL Commuter Line dengan menggunakan metode DNN (Deep Neural Network).
2. Mengetahui hasil peramalan jumlah penumpang KRL Commuter Line dengan menggunakan metode DNN (Deep Neural Network).

Mengetahui kinerja dari metode DNN (Deep Neural Network) dalam melakukan peramalan jumlah penumpang KRL Commuter Line.

1.5. Manfaat Tugas Akhir

Berikut adalah manfaat dari penelitian, yaitu:

1. Memberikan prediksi jumlah penumpang KRL Commuter Line di masa depan kepada PT. KAI Commuter Jakarta.
2. Sebagai bahan pertimbangan bagi PT. KAI Commuter Jakarta dalam mengambil keputusan untuk mengantisipasi peningkatan jumlah penumpang KRL Commuter Line di masa depan.

1.6. Relevansi

Keterkaitan antara penelitian ini dengan keilmuan jurusan dan laboratorium tugas akhir yang dipilih yaitu terletak topik dari tugas kahir ini yaitu mengenai peramalan yang merupakan salah satu mata kuliah pilihan Departemen Sistem Informasi dari Laboratorium Rekayasa Data dan Intelegensia Bisnis dengan menggunakan metode DNN (Deep Neural Network) yang berkaitan dengan mata kuliah Departemen Sistem Informasi yaitu Sistem Cerdas yang membahas mengenai Artificial Intelligence (AI).

Halaman ini sengaja dikosongkan

BAB II

TINJAUAN PUSTAKA

Dalam bab ini, akan dijelaskan mengenai penelitian terdahulu dan landasan teori yang digunakan sebagai acuan dalam pengerjaan tugas akhir. Penelitian terdahulu merupakan suatu penelitian yang pernah dilakukan oleh peneliti-peneliti sebelumnya yang digunakan sebagai acuan tugas akhir. Landasan teori merupakan teori-teori yang berhubungan dengan pengerjaan tugas akhir.

2.1. Studi Sebelumnya

Studi sebelumnya terkait peramalan jumlah penumpang kereta api KRL Commuter Line belum dilakukan sebelumnya, namun terdapat sebuah penelitian pola pergerakan penumpang menggunakan studi kasus KRL Commuter Line yang dilakukan oleh Pudji Astuti, Winnie Septiani, dan Amal Witonohadi dalam jurnal berjudul “Pemetaan Pergerakan Pengguna Layanan Kereta Commuter Jabodetabek (PT. KCI) Menggunakan Simulasi” dimana dengan menggunakan simulasi para peneliti memetakan pola pergerakan penumpang pada setiap stasiun yang dilalui oleh KRL Commuter Line sehingga diketahui rute dengan jumlah penumpang terbanyak, stasiun yang padat penumpang, dan stasiun dengan jumlah penumpang melebihi kapasitas maksimum gerbong.

Untuk peramalan jumlah penumpang kereta api dengan studi kasus selain KRL Commuter Line, telah banyak dilakukan sebelumnya menggunakan berbagai metode seperti ARIMA dan ANFIS. Salah satu jurnal yang menggunakan metode ARIMA dan ANFIS sebagai metode dalam melakukan peramalan jumlah penumpang kereta api yaitu jurnal dengan judul “Peramalan Jumlah Penumpang Kereta Api Kelas Ekonomi Kertajaya Menggunakan ARIMA dan ANFIS” oleh

Ilafi Andalita dan Irhama dimana dalam jurnal ini dapat ditarik kesimpulan bahwa model ARIMA $([4,6],1,1) (0,1,1)$ merupakan model terbaik ketimbang model ARIMA lainnya. Namun, model ini tidak seakurat model ANFIS dengan input Z_t-8, Z_t-7, Z_t-1 yang dimana model ANFIS ini merupakan model paling akurat dari model ANFIS dengan input lainnya.

Dalam penelitian peramalan jumlah penumpang kereta api KRL Commuter Line ini, peneliti menggunakan metode DNN (Deep Neural Network) yang menggunakan pendekatan permodelan dan faktor-faktor yang mempengaruhi. Peramalan jumlah penumpang kereta api dengan metode ini telah diterapkan sebelumnya oleh Lijuan Liu dan Rung-Ching Chen dalam sebuah jurnal berjudul "A MRT Daily Passenger Flow Prediction Model with Different Combinations of Influential Factors".

Hasil dari penelitian tersebut menyimpulkan bahwa pendekatan dari DNN (Deep Neural Network) ini secara efektif menangkap hubungan non-linear antara arus penumpang dengan faktor yang mempengaruhi di dalamnya, dimana seluruh faktor yang digunakan dalam peramalan ini dan mempengaruhi arus penumpang seperti faktor sementara, faktor liburan, dan faktor arah merupakan faktor yang penting dan mempengaruhi performa dari model prediksi selain riwayat arus penumpang. Penambahan faktor-faktor berpengaruh lainnya seperti faktor sosial dan faktor cuaca. serta penambahan data arus penumpang pada stasiun yang berbeda-beda merupakan saran yang diberikan dari jurnal terkait pengembangan terhadap model ini untuk memverifikasi pengaruh dari seluruh faktor-faktor tersebut [2].

2.2. Dasar Teori

Pada subbab ini akan dijabarkan mengenai dasar teori yang digunakan untuk mendukung pengerjaan tugas akhir.

2.2.1. Definisi Peramalan

Peramalan merupakan suatu ilmu yang dipelajari untuk memprediksi nilai yang didapatkan di masa depan dengan mempertimbangkan data yang terdapat pada masa lalu dan data masa kini menggunakan sebuah model matematis. Peramalan saat ini telah digunakan di berbagai sektor industri seperti finansial, pendidikan, hingga meteorologi. Tujuan dari adanya peramalan yaitu untuk mempersiapkan hal yang perlu dilakukan untuk mengantisipasi hal yang terjadi di masa depan sehingga dapat meminimalisir resiko yang dihasilkan [3].

2.2.2. Pengelompokan Peramalan

Pengelompokan peramalan didasarkan pada berbagai hal, diantaranya adalah berdasarkan waktu dan pendekatannya. Menurut waktunya, peramalan dibagi menjadi tiga [4], yaitu:

- a. Peramalan jangka pendek
Peramalan yang tergolong ke dalam kelompok ini, merupakan peramalan dengan tenggang kurang dari tiga bulan.
- b. Peramalan jangka menengah
Peramalan yang tergolong ke dalam kelompok ini, merupakan peramalan dengan tenggang antara tiga bulan sampai tiga tahun.
- c. Peramalan jangka panjang
Peramalan yang tergolong ke dalam kelompok ini, merupakan peramalan dengan tenggang lebih dari tiga tahun.

Sedangkan pembagian peramalan menurut pendekatannya, dibagi atas dua yaitu, pendekatan kuantitatif dan pendekatan kualitatif [5]. Pendekatan kualitatif merupakan pendekatan yang digunakan ketika data tidak relevan, terbatas, hingga

tidak tersedia, sehingga pendekatan ini lebih menggunakan pengalaman pribadi, sistem nilai pengambilan keputusan, dan intuisi. Adapun pendekatan kuantitatif merupakan pendekatan yang dapat dilakukan ketika data masa lalu yang dibutuhkan tersedia, atau informasi yang tersedia dapat dikuantitatifkan menjadi bentuk numerik, dan pola yang terdapat pada masa lalu dapat diasumsikan berlanjut di masa mendatang. Sehingga pendekatan ini akan memperlihatkan relasi antara satu atau beberapa variabel yang mempengaruhi dengan permintaan [6].

Untuk pendekatan kuantitatif, terbagi lagi menjadi dua model yaitu; time series model dan causal model. Time series model menggunakan data historis variabel tertentu atau kesalahan masa lalu dimana setiap data dikumpulkan dalam sebuah kumpulan jarak seperti; mingguan, bulanan, dan tahunan sehingga model ini cocok untuk peramalan permintaan dalam waktu yang lama dengan pola konsisten sehingga dapat diambil asumsi bahwa pola tersebut akan terus berlanjut hingga masa depan. Adapun causal model merupakan model yang berasumsi bahwa terdapat hubungan sebab akibat pada faktor yang diramalkan dengan satu atau beberapa variabel bebas.

2.2.3. Data Peramalan

Data peramalan jika dibagi berdasarkan waktu pengumpulannya, maka terbagi menjadi dua, yaitu:

a. **Data cross-section**

Data yang pengumpulannya hanya pada satu waktu tertentu, sehingga tidak berdasar waktu.

b. Data time series

Data yang pengumpulannya dari waktu ke waktu sehingga membentuk data yang berdasar pada rentang waktu pengumpulan data tersebut.

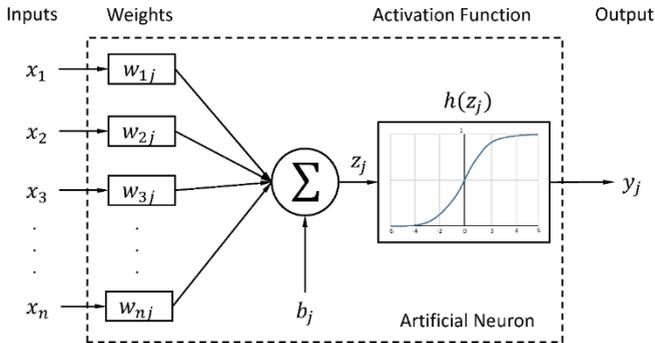
2.2.4. Proses Peramalan

Adapun proses peramalan terdiri dari sembilan tahap yang dimana dapat menjamin efisiensi dan efektivitas peramalan yang dilakukan yaitu:

1. Menentukan tujuan peramalan.
2. Memilih item yang hendak dilakukan peramalan.
3. Menentukan jangka waktu peramalan; dapat berupa jangka pendek, menengah, dan panjang.
4. Memilih model peramalan yang sesuai.
5. Mendapatkan data yang diperlukan dalam peramalan.
6. Melakukan validasi peramalan.
7. Menciptakan peramalan.
8. Menerapkan hasil-hasil peramalan.
9. Menghitung keandalan hasil peramalan.

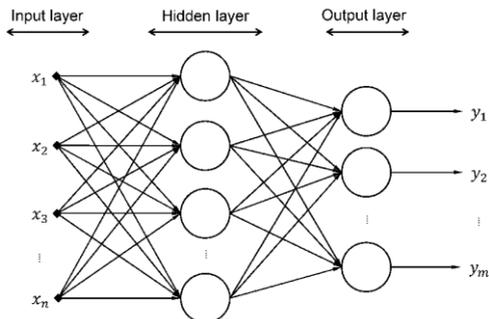
2.2.5. Artificial Neural Network (ANN)

Artificial Neural Network (ANN) merupakan model matematika yang mengimitasi neuron biologis sistem saraf pusat, dimana ini memperlihatkan reaksi nonlinear sesuai dengan sinyal input [7]. ANN dapat digunakan untuk meramalkan lalu lintas [8], radiasi matahari [9], produk domestik bruto [10], dan lain sebagainya. Gambar 2.1 menunjukkan struktur ANN dan menjabarkan mekanisme reaksi nonlinier neuron sesuai dengan input.



Gambar 2. 1 Struktur dari ANN

Struktur dari ANN seperti yang ditunjukkan pada Gambar 2.1 terdiri dari input, bias, bobot, output, dan fungsi aktivasi dimana terdapat neuron j khas dengan jumlah n input. Menurut bentuk dari fungsi aktivasi, output dapat diterjemahkan sebagai intensitas reaksi atau probabilitas turn-on dari neuron. ANN merupakan sistem neuron buatan yang terhubung yang mempunyai kemampuan untuk memodelkan fungsi nonlinear yang acak. Struktur khas ANN mengacu kepada multilayer perceptron (MLP), yang digambarkan pada Gambar 2.2.



Gambar 2. 2 Multilayer Perceptron

Pada Gambar 2.2, MLP mempunyai struktur tiga lapis; input, hidden, dan output layer. Setiap lapisan memiliki neuron tanpa

koneksi intra-layer, namun di antara lapisan, terdapat full-weighted connections di antara neuron. Unsur yang terdapat dalam MLP digambarkan dengan menggunakan superscript l untuk menunjukkan suatu layer, output vector y dari layer l adalah:

$$\mathbf{y}^l = \mathbf{h}(\mathbf{z}^l) = \mathbf{h}\left((\mathbf{W}^l)^T \mathbf{y}^{l-1} + \mathbf{b}^l\right)$$

Dimana:

$\mathbf{h}(\cdot)$ = fungsi aktivasi vektor nonlinear

$\mathbf{W}^l = [w_{ij}^l]$ = matriks bobot

\mathbf{b}^l = vektor bias

Struktur tersebut menunjukkan bahwa MLP memiliki kekuatan memanipulasi ruang input dengan menyesuaikan matriks berat antar lapisan. Proses utama membangun MLP yaitu menghitung matriks berat yang cocok dan menghasilkan output yang diinginkan sesuai dengan data yang diberikan. Algoritma back propagation (BP) digunakan untuk memperbarui matriks berat agar meminimalkan kesalahan antara nilai target dengan nilai yang dihasilkan oleh MLP.

Kemudian, w_{ij}^l diperbarui oleh:

$$\Delta w_{ij}^l = -\eta \frac{\partial E}{\partial w_{ij}^l}$$

Dimana:

η = *learning rate*

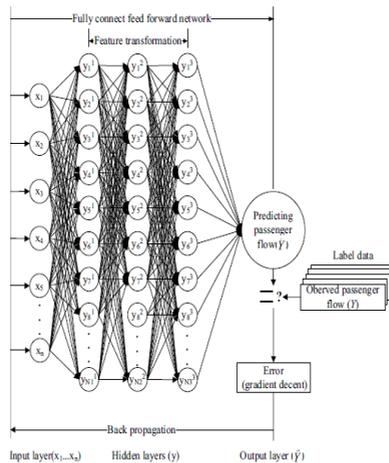
E = nilai *error*

$$\Delta w_{ij}^l = \text{dapat diturunkan dari } \textit{chain rule} \quad [11]$$

Dalam algoritma BP, error signal δ merambat mundur untuk menghitung Δw_{ij}^l . Di SNN, δ merambat dengan baik ke lapisan input. Namun, dalam DNN, karena gradien fungsi aktivasi khas adalah nol di area saturasi, δ juga menuju ke nol saat merambat ke arah lapisan input. Masalah yang ditemukan saat melakukan training DNN ini disebut vanishing gradient dan akan menyulitkan untuk melatih DNN [12].

2.2.6. Deep Neural Network (DNN)

Deep Neural Network (DNN) telah banyak digunakan dalam peramalan produksi [13], penjualan [14], Forex [15], dan lain sebagainya. Berikut dalam Gambar 2.3 di bawah ini ditampilkan arsitektur dari DNN.



Gambar 2.3 Arsitektur Deep Neural Network (DNN)

Gambar 2.3. di atas menunjukkan arsitektur dari model prediksi berbasis DNN, dimana faktor yang mempengaruhi dikumpulkan menjadi data input dan tiga lapisan tersembunyi DNN dibangun sebagai prediktor, dimana prosedur pembelajaran dideskripsikan sebagai berikut [2]:

1. Inisialisasi parameter: Awalnya neuron input akan menerima vektor fitur $X = (x_1, x_2, \dots, x_n)$ berdasarkan pada faktor yang mempengaruhi dan menyebarkannya ke semua neuron di lapisan tersembunyi pertama. Karena semua neuron terhubung sepenuhnya dengan bobot, maka semua bobot dan bias diinisialisasikan dalam DNN.

2. Transformasi fitur: Disini dihitung hubungan linier antara input $X = (x_1, x_2, \dots, x_n)$ dengan hasil tengah dari lapisan tersembunyi pertama oleh persamaan di bawah ini:

$$y_{Nj}^h = \sum_{i=1}^n w_{ih} x_i + b_h \quad (j = 1, 2, 3)$$

Kemudian membuat transformasi non-linear antara (y_{Nj}^h) sebagai hasil tengah dan output ($\varphi(x_i)$) dari layer tersembunyi pertama oleh persamaan di bawah ini:

$$\varphi(x_i) = f(y_{Nj}^h) = f\left(\sum_{i=1}^n w_{ih} x_i + b_h\right) \quad (j = 1, 2, 3)$$

Output ($\varphi(x_i)$) akan dianggap sebagai input untuk lapisan tersembunyi berikutnya. Kemudian proses ini diulangi hingga lapisan tersembunyi yang terakhir. Dimana w_{ih} mengacu pada berat antara neuron i_{ih} dari masukan dengan neuron h_{ih} dari lapisan tersembunyi; b_h adalah bias dari neuron h_{ih} dari lapisan

tersembunyi. Fungsi $f(y_{Nj}^h)$ adalah fungsi aktivasi yang ditunjukkan dari persamaan di bawah ini:

$$f(y_{Nj}^h) = f(\bullet) \quad (j = 1, 2, 3)$$

Dimana persamaan diatas menyediakan DNN dengan kemampuan pemodelan non-linear dan pembelajaran *layer-wise* antara input dan output. Disini, jumlah neuron pada lapisan tersembunyi pertama ($N1$) harus lebih dari jumlah neuron pada lapisan input (n), yang memastikan bahwa semua fitur yang disematkan di input dapat dipelajari seutuhnya dan diubah dalam setiap lapisan di DNN.

3. Regresi linier. Tahapan ini untuk mendapatkan prediksi yang mengalir di lapisan output dengan regresi linier. Kemudian, pada tahapan ini dilakukan pembaharuan wih dan bh dari semua lapisan dengan meminimalkan kesalahan antara hasil akhir yang dihasilkan (arus penumpang yang memprediksi) dan data label (aliran penumpang yang diamati) dengan gradien layak yang dipantau prosesnya. Proses parameter finetuning berdasarkan pada algoritma back propagation, yang merupakan cara pelatihan efisien yang banyak digunakan di DNN. Untuk fungsi kerugian yang dapat disebut juga fungsi biaya, ditunjukkan dalam persamaan di bawah ini.

$$\theta = \arg \min L(Y, \hat{Y})$$

Dimana untuk pembaruan bobot dan bias ditunjukkan dalam kedua persamaan ini secara berurutan.

$$w'_{ih} = w_{ih} - \eta \frac{\partial L(Y, \hat{Y})}{\partial w_{ih}}$$

$$b'_h = b_h - \eta \frac{\partial L(Y, \hat{Y})}{\partial b_h}$$

Dengan η adalah tingkat belajar; \hat{Y} dan Y mewakili prediksi dan mengamati objek yang diprediksi. w'_{ih} dan b'_h secara berurutan adalah bobot dan bias yang diperbarui [2].

2.2.7. Akurasi Peramalan

Akurasi peramalan diperlukan untuk menimbang teknik peramalan yang akan dipilih dengan melihat besarnya nilai *error*. Pengukuran akurasi peramalan menurut Render dan Heizer [4] yaitu:

1. Deviasi rata-rata absolute atau Mean Absolute Deviation (MAD)

MAD merupakan metode yang menghitung keseluruhan kesalahan peramalan dalam suatu model.

Berikut adalah rumus dari MAD:

$$MAD = \frac{\sum_{t=1}^n |A_t - F_t|}{n}$$

Dimana n mewakilkan jumlah periode data dan t mewakilkan periode ke- t , A_t adalah nilai data aktual, sedangkan F_t yaitu nilai hasil peramalan yang didapat.

2. Kesalahan rata-rata kuadrat atau Mean Squared Error (MSE)

MSE merupakan galat peramalan menurut Gasperz dimana pemakaian berbagai model peramalan dapat menyatakan hasil ramalan yang berbeda dan derajat dari galat ramalan yang juga berbeda. Berikut adalah rumus dari MSE:

$$MSE = \frac{\sum_{t=1}^n (A_t - F_t)^2}{n}$$

Dimana n merupakan jumlah periode data dan t merupakan periode ke- t , A_t adalah nilai actual data, sedangkan F_t yaitu nilai hasil peramalan.

3. Kesalahan persen rata-rata absolute atau Mean Absolute Percent Error (MAPE)

MAPE dihitung untuk rata-rata diferensiasi absolut antara nilai data aktual dengan nilai hasil peramalan, yang dinyatakan sebagai presentase nilai aktual. Berikut adalah rumus dari MAPE:

$$MAPE = \frac{\sum_{t=1}^n |A_t - F_t| \frac{1}{A_t}}{n} \times 100\%$$

Dimana n mewakili jumlah periode data dan t mewakili periode ke- t , A_t yaitu nilai actual data, sedangkan F_t merupakan nilai hasil peramalan.

Selanjutnya hasil penghitungan peramalan menggunakan MAPE digolongkan ke rentang signifikansi MAPE yang memperlihatkan kualitas dari hasil peramalan. Berikut adalah rentang hasil yang dapat dilihat pada tabel 2.1:

Tabel 2. 1 Tingkat Signifikansi MAPE

| Persentase MAPE | Tingkat Signifikansi |
|------------------------|---|
| < 10% | Excellent (hasil peramalan sangat baik) |
| 10 – 20% | Good (hasil peramalan baik) |
| 20 – 50% | Reasonable (hasil peramalan cukup) |
| > 50% | Bad (hasil peramalan buruk) |

Halaman ini sengaja dikosongkan

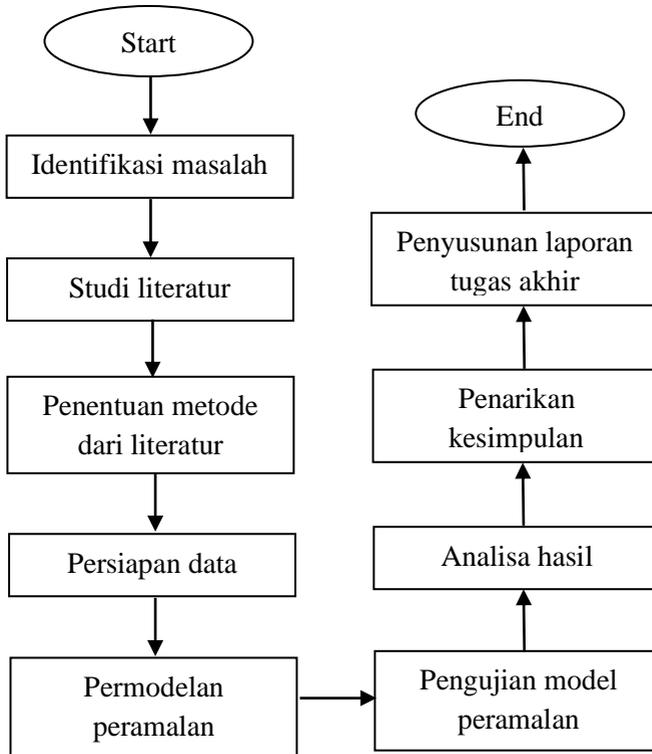
BAB III

METODOLOGI PENELITIAN

Pada bab ini akan dijelaskan mengenai alur metodologi yang akan dilakukan dalam tugas akhir ini. Metodologi ini juga digunakan sebagai pedoman untuk melaksanakan tugas akhir agar terarah dan sistematis.

3.1. Tahapan Pelaksanaan Tugas Akhir

Pada subbab ini akan menjelaskan mengenai metodologi pengerjaan dalam pelaksanaan tugas akhir. Metodologi ini digunakan sebagai panduan dan memberikan alur pengerjaan tugas akhir yang sistematis. Metodologi pengerjaan tugas akhir dapat dilihat pada gambar 3.1 berikut:



Gambar 3. 1 Alur Pengerjaan Tugas Akhir

Berdasarkan bagan alur metodologi pengerjaan pada gambar 3.1, dibawah ini merupakan penjelasan dari prosesnya.

3.1.1. Identifikasi masalah

Untuk tahapan ini, dilaksanakan identifikasi masalah terhadap studi kasus yang dipilih yang dalam hal ini yaitu KRL Commuter Line, sehingga hasil yang didapatkan dari tahapan ini berupa topik permasalahan yang digunakan untuk penelitian nantinya yaitu peramalan data jumlah penumpang

KRL Commuter Line yang dimana akan menjadi masukan (input) ke dalam proses berikutnya.

3.1.2. Studi Literatur

Pada tahapan ini, dengan menggunakan topik permasalahan yang didapatkan dari tahapan sebelumnya yaitu Identifikasi Masalah, maka selanjutnya melakukan studi literatur terkait topik permasalahan yang ada. Metode studi literatur yang dilakukan mulai dari mengumpulkan referensi penelitian sebelumnya seperti buku, paper, jurnal yang terkait dengan topik permasalahan yang kemudian dari sini didapatkan sebuah hasil mengenai pengetahuan akan dasar teori dan metode yang dapat digunakan dalam penelitian ini. Selain dari itu, tahapan ini juga bertujuan untuk menguatkan keyakinan peneliti dalam memilih topik permasalahan untuk diteliti.

3.1.3. Penentuan Metode dari Literatur

Pada tahapan ini, dengan menggunakan temuan yang didapatkan dari tahapan sebelumnya yaitu berupa dasar teori dan metode yang dianggap mendukung penelitian, maka dilakukan pemilihan metode yang dianggap paling tepat untuk menyelesaikan topik permasalahan yang dipilih. Melalui tahapan ini, didapatkan hasil yaitu sebuah metode yang dianggap dapat menyelesaikan topik permasalahan yaitu metode peramalan menggunakan DNN (Deep Neural Network) dengan input berupa berbagai faktor yang sekiranya dapat mempengaruhi hasil peramalan.

3.1.4. Persiapan Data

Pada tahapan ini, dengan menggunakan metode yang telah dipilih pada tahapan sebelumnya, maka dilakukan pencarian dan pemilihan data penelitian yang sesuai dengan karakteristik data yang dapat digunakan dalam metode yang dipilih. Sebagai objek yang penting dalam tugas akhir, maka persiapan pengumpulan data harus dilakukan dengan matang agar

didapatkan data yang lengkap dan sesuai dengan metode dan topik permasalahan yang akan diselesaikan dalam tugas akhir ini.

Dalam tugas akhir ini, data yang dipakai yaitu data time series harian Jumlah Penumpang KRL Commuter Line Jabodetabek dari 1 Januari 2017 – 30 November 2018. Selanjutnya, dilakukan pemeriksaan data untuk memastikan data siap digunakan dalam metode peramalan yang dipilih.

3.1.5. Permodelan Peramalan

Pada tahapan ini, setelah mendapatkan data yang dibutuhkan dalam peramalan, maka dibuat model dari peramalan dengan menentukan input dan output, serta variabel dependen dan variabel bebas. Adapun model yang digunakan dalam peramalan ini adalah model time series karena data yang digunakan berupa serangkaian data yang memiliki jarak sama yaitu harian. Model peramalan ini nantinya digunakan untuk tahapan selanjutnya yaitu pengujian model peramalan.

3.1.6 Pengujian Model Peramalan

Pada tahapan ini, setelah mendapatkan model peramalan, maka dilakukan pengujian model peramalan dengan mengimplementasikan model tersebut untuk meramalkan data yang ada. Kemudian selanjutnya dilakukan perhitungan nilai error dari peramalan untuk mengetahui tingkat akurasi dari model peramalan yang digunakan. Selanjutnya hasil peramalan beserta nilai error tersebut digunakan untuk tahapan berikutnya yaitu analisa hasil dan penarikan kesimpulan.

3.1.7 Analisa Hasil dan Penarikan Kesimpulan

Pada tahapan ini, dengan menggunakan hasil yang didapatkan yaitu data hasil peramalan beserta nilai error maka analisa hasil dilakukan agar dapat melakukan penarikan kesimpulan dari penelitian ini, dimana kesimpulan yang didapatkan dapat

memberikan kontribusi terhadap penelitian selanjutnya terkait peramalan dengan topik yang berhubungan.

3.1.8 Penyusunan Laporan Tugas Akhir

Pada tahapan ini, dilakukan penyusunan tugas akhir yang merupakan dokumentasi terhadap pelaksanaan penelitian secara keseluruhan. Laporan tugas akhir ini ada untuk membantu Departemen Sistem Informasi ITS menjadikan tugas akhir ini sebagai referensi untuk penelitian yang sejenis di masa depan dengan topik, dimana laporan tugas akhir ini terdiri dari:

- a. Bab I Pendahuluan
Bab ini menjabarkan tentang latar belakang, rumusan dan batasan masalah, tujuan dan manfaat pengerjaan tugas akhir ini.
- b. Bab II Tinjauan Pustaka
Bab ini menjabarkan terkait penelitian yang telah dilakukan terhadap topik penelitian yang sejenis serta teori – teori yang menunjang topik permasalahan yang digunakan dalam penelitian ini.
- c. Bab III Metodologi
Bab ini menjabarkan tentang tahapan – tahapan yang secara runtut wajib dilakukan dalam pengerjaan tugas akhir.
- d. Bab IV Analisis dan Pembahasan
Bab ini menjabarkan terkait pembahasan mengenai perancangan model peramalan dan implementasi dari model yang telah dirancang untuk menyelesaikan topik permasalahan yang dipilih dalam penelitian ini.
- e. Bab V Penutup
Bab ini menjabarkan tentang simpulan yang didapatkan dari penelitian ini beserta saran yang diberikan untuk penelitian di masa depan terkait topik yang sejenis dengan penelitian ini

Halaman ini sengaja dikosongkan

BAB IV PERANCANGAN

Dalam bab ini akan dijelaskan persiapan perancangan terkait dengan data yang digunakan dan membuat model matematis kemudian dilakukan konversi struktur data sebagai tahap persiapan implementasi model.

4.1. Persiapan Data

Di dalam tahapan ini, dilakukan permintaan data jumlah penumpang KRL Commuter Line per hari selama satu tahun dari 1 Januari 2018 – 31 Desember 2018 kepada PT. KAI Commuter Jakarta. Dari data jumlah penumpang tersebut, didapatkan enam variabel yaitu, variabel waktu keberangkatan penumpang (hari, tanggal, dan bulan), variabel hari libur, variabel stasiun, dan variabel jumlah penumpang pada waktu dan stasiun tersebut. Data jumlah penumpang tersebut dapat dilihat dalam Lampiran A.

4.2. Pra Proses Data

Dalam tahapan ini, pengolahan data yang didapatkan sebelumnya dilakukan dengan mengubah data non-numerik menjadi data numerik yang terdapat pada beberapa variabel, yaitu:

Tabel 4.1 Konversi Data Non-Numerik pada Variabel Hari Keberangkatan Penumpang ke Data Numerik

| Data Non-Numerik (Variabel Hari Keberangkatan) | Hasil Konversi ke Data Numerik |
|---|---|
| Senin | 1 |
| Selasa | 2 |
| Rabu | 3 |
| Kamis | 4 |
| Jumat | 5 |
| Sabtu | 6 |
| Minggu | 7 |

Pada Tabel 4.1 di atas, dapat dilihat bahwa variabel hari keberangkatan terdiri dari tujuh yaitu, Senin dengan label “1”, Selasa dengan label “2”, Rabu, dengan label “3”, dan seterusnya hingga Minggu dengan label “7”.

Tabel 4. 2 Konversi Data Non-Numerik pada Variabel Bulan Keberangkatan Penumpang ke Data Numerik

| Data Non-Numerik (Variabel Bulan Keberangkatan) | Hasil Konversi ke Data Numerik |
|--|---------------------------------------|
| Januari | 1 |
| Februari | 2 |
| Maret | 3 |
| April | 4 |
| Mei | 5 |
| Juni | 6 |
| Juli | 7 |
| Agustus | 8 |
| September | 9 |
| Oktober | 10 |
| November | 11 |
| Desember | 12 |

Pada Tabel 4.2 di atas, dapat dilihat bahwa variabel bulan keberangkatan terdiri dari 12 yaitu, Januari dengan label “1”, Februari dengan label “2”, Maret, dengan label “3”, dan seterusnya hingga Desember dengan label “12”.

Tabel 4. 3 Konversi Data Non-Numerik pada Variabel Hari Libur ke Data Numerik

| Data Non-Numerik (Variabel Hari Libur) | Hasil Konversi ke Data Numerik |
|---|---------------------------------------|
| Libur | 1 |
| Tidak Libur | 0 |

Pada Tabel 4.3 di atas, dapat dilihat bahwa variabel hari libur terdiri dari dua yaitu, Libur dengan label “1” dan Tidak Libur dengan label “2”.

Tabel 4. 4 Konversi Data Non-Numerik pada Variabel Stasiun ke Data Numerik

| Data Non-Numerik (Variabel Stasiun) | Hasil Konversi ke Data Numerik |
|--|---|
| Bogor | 1 |
| Tanah Abang | 2 |
| Sudirman | 3 |
| Bekasi | 4 |
| Bojonggede | 5 |
| Depokbaru | 6 |
| Citayam | 7 |
| Jakarta Kota | 8 |
| Tebet | 9 |
| Gondangdia | 10 |
| Depok | 11 |
| Cikini | 12 |
| Pondok Cina | 13 |
| Pasar Minggu | 14 |
| Manggarai | 15 |
| Duren Kalibata | 16 |
| Sudimara | 17 |
| Cilebut | 18 |
| Cawang | 19 |
| Juanda | 20 |
| Univ.Indonesia | 21 |
| Kranji | 22 |
| Palmerah | 23 |
| Jatinegara | 24 |
| Lenteng Agung | 25 |
| Tanjung Barat | 26 |
| Tangerang | 27 |
| Kebayoran | 28 |
| Rawa Buntu | 29 |

| Data Non-Numerik (Variabel Stasiun) | Hasil Konversi ke Data Numerik |
|--|---|
| Sawah Besar | 30 |
| Pondok Kranji | 31 |
| Karet | 32 |
| Duri | 33 |
| Cakung | 34 |
| Parung Panjang | 35 |
| Klender Baru | 36 |
| Mangga Besar | 37 |
| Jayakarta | 38 |
| Serpong | 39 |
| Kampung Bandan | 40 |
| Poris | 41 |
| Klender | 42 |
| Kemayoran | 43 |
| Univ.Pancasila | 44 |
| Jurangmangu | 45 |
| Buaran | 46 |
| Pesing | 47 |
| Pasar Senen | 48 |
| Pasar Minggu Baru | 49 |
| Rawabuaya | 50 |
| Cisauk | 51 |
| Kali Deres | 52 |
| Batu Ceper | 53 |
| Rajawali | 54 |
| Kramat | 55 |
| Gang Sentiong | 56 |
| Tiga Raksa | 57 |
| Cicayur | 58 |
| Pondok Jati | 59 |
| Bojong Indah | 60 |

| Data Non-Numerik (Variabel Stasiun) | Hasil Konversi ke Data Numerik |
|--|---|
| Cibinong | 61 |
| Nambo | 62 |
| Tenjo | 63 |
| Maja | 64 |
| Cilejit | 65 |
| Daru | 66 |
| Grogol | 67 |
| Taman Kota | 68 |
| Tanah Tinggi | 69 |
| Cikoya | 70 |
| Tanjung Priok | 71 |
| Ancol | 72 |
| Angke | 73 |
| Citeras | 74 |
| Rangkasbitung | 75 |
| Bekasi Timur | 76 |
| Tambun | 77 |
| Cibitung | 78 |
| Cikarang | 79 |

Pada Tabel 4.4 di atas, dapat dilihat bahwa variabel stasiun terdiri dari 79 yaitu, yaitu, Bogor dengan label “1”, Tanah Abang dengan label “2”, Sudirman dengan label “3”, dan seterusnya hingga Cikarang dengan label “79”.

Setelah dilakukan pengubahan data non-numerik menjadi data numerik pada beberapa variabel yang memiliki data mentah non-numerik, maka selanjutnya data jumlah penumpang pada setiap stasiun tujuan dibagi berdasarkan pola data dengan melihat grafik dari setiap data stasiun. Pembagian pola data ini menghasilkan lima jenis pola data, yaitu; (1) Seasonal, (2) Stasioner, (3) Seasonal Sisir Terbalik, (4) Seasonal dengan

Nilai Ekstrem, dan (5) Seasonal Sisir Terbalik dengan Nilai Ekstrem.

4.3. Perancangan Model DNN

Untuk perancangan model DNN, terlebih dahulu pada setiap data jumlah penumpang di setiap stasiun tujuan, dilakukan pembagian data menjadi dua, yaitu; data *training* dan data *testing*. Adapun proporsi perbandingan data *training* dan data *testing* yaitu sebesar 80:20, dimana 80% merupakan data *training* atau sejumlah 292 data dan 20% untuk data testing sejumlah 73 data untuk setiap data jumlah penumpang di setiap stasiun tujuan. Adapun pemilihan proporsi sebesar 80:20 adalah karena pola dari data dapat tertangkap seutuhnya dalam 80% data, sehingga data training memiliki proporsi 80% dan data testing memiliki proporsi 20%.

Pada rancangan arsitektur DNN yang dikenakan dalam tugas akhir ini, memiliki *input layer*, *hidden layer*, dan *output layer* serta parameter yang dikenakan dalam proses pelatihan data. Adapun rancangan jumlah *hidden layer*, *neuron*, dan nilai-nilai parameter yang digunakan dalam arsitektur DNN adalah sebagai berikut:

Tabel 4. 5 Tabel Perancangan Model DNN

| Parameter | Jumlah | Deskripsi |
|--|--------------------------|--|
| <i>Input Layer</i> | 6 neuron | Hari keberangkatan; Tanggal keberangkatan; Bulan keberangkatan; Hari libur; Stasiun tujuan; Jumlah penumpang di setiap stasiun |
| <i>Hidden Layer</i> | <i>Trial & Error</i> | Selengkapnya pada Tabel 4.6) |
| <i>Epochs</i> | <i>Trial & Error</i> | Selengkapnya pada Tabel 4.7 |
| ADADELTA (<i>Adaptive Learning Rate Algorithm</i>) <i>Epsilon</i> | <i>Trial & Error</i> | Selengkapnya pada Tabel 4.8 |
| ADADELTA (<i>Adaptive Learning Rate Algorithm</i>) <i>Rho</i> | <i>Trial & Error</i> | Selengkapnya pada Tabel 4.9 |
| <i>Output Layer</i> | 1 | Hasil peramalan jumlah penumpang KRL Commuter Line di setiap stasiun |

Dari perancangan model yang didapatkan dari Tabel 4.5 di atas, maka akan diterapkan pada seluruh skenario yang terdapat pada Tabel 4.6-4.9, sehingga didapatkan model terbaik yang nantinya akan diujikan pada seluruh stasiun.

Kemudian, untuk data *input* yang digunakan dalam pencarian model terbaik untuk seluruh stasiun yaitu Data Harian Jumlah Penumpang Stasiun Tanah Abang Tahun 2018. Adapun pemilihan Stasiun Tanah Abang sebagai perwakilan data *input* adalah karena Stasiun Tanah Abang termasuk kelompok pola data seasonal dimana di dalam kelompok pola data seasonal ini, terdapat 49 stasiun dari 79 stasiun yang terdapat dalam kelompok ini, yang berarti hampir sebagian besar stasiun memiliki pola data seasonal. Dari kelompok pola data seasonal ini, Stasiun Tanah Abang merupakan stasiun yang berada pada nomor dua dalam daftar nama stasiun yang dirilis oleh PT.KAI Commuter Jakarta. Sehingga Stasiun Tanah Abang dipilih sebagai perwakilan seluruh stasiun untuk data *input* dalam pencarian model terbaik bagi seluruh stasiun. Kemudian, model terbaik yang didapatkan ini akan diuji pada seluruh data jumlah penumpang di stasiun lainnya.

Lalu, dari model terbaik yang didapatkan, selanjutnya diujikan pada seluruh stasiun untuk dilihat nilai MAPE yang dihasilkan. Jika terdapat stasiun yang memiliki nilai MAPE $> 10\%$, maka seluruh stasiun dengan nilai MAPE $> 10\%$, akan dikelompokkan dalam satu kelompok yaitu dalam Kelompok Data Jumlah Penumpang di Setiap Stasiun Khusus MAPE $> 10\%$, untuk kemudian dicari model terbaik yang selanjutnya model terbaik tersebut diterapkan khusus pada Kelompok Data Jumlah Penumpang di Setiap Stasiun Khusus MAPE $> 10\%$ untuk dilihat akurasi peramalan yang dihasilkan.

Tabel 4. 6 Skenario Eksperimen Kombinasi Jumlah Neuron dengan Hidden Layer Optimal

| Skenario | HL 1 | HL 2 | HL 3 | HL 4 | HL 5 | HL 6 | HL 7 | HL 8 | HL 9 | HL 10 | Epochs | <i>Epsilon</i> | <i>Rho</i> |
|----------|------|------|------|------|------|------|------|------|------|-------|--------|---------------------|------------|
| 1 | 100 | 200 | | | | | | | | | 1500 | 1×10^{-10} | 0.99 |
| 2 | 100 | 200 | 300 | | | | | | | | 1500 | 1×10^{-10} | 0.99 |
| 3 | 100 | 200 | 300 | 400 | | | | | | | 1500 | 1×10^{-10} | 0.99 |
| 4 | 100 | 200 | 300 | 400 | 500 | | | | | | 1500 | 1×10^{-10} | 0.99 |
| 5 | 100 | 200 | 300 | 400 | 500 | 600 | | | | | 1500 | 1×10^{-10} | 0.99 |
| 6 | 100 | 200 | 300 | 400 | 500 | 600 | 700 | | | | 1500 | 1×10^{-10} | 0.99 |
| 7 | 100 | 200 | 300 | 400 | 500 | 600 | 700 | 800 | | | 1500 | 1×10^{-10} | 0.99 |
| 8 | 100 | 200 | 300 | 400 | 500 | 600 | 700 | 800 | 900 | | 1500 | 1×10^{-10} | 0.99 |
| 9 | 100 | 200 | 300 | 400 | 500 | 600 | 700 | 800 | 900 | 1000 | 1500 | 1×10^{-10} | 0.99 |
| 10 | 100 | 100 | | | | | | | | | 500 | 1×10^{-10} | 0.99 |
| 11 | 100 | 100 | 100 | | | | | | | | 500 | 1×10^{-10} | 0.99 |
| 12 | 100 | 100 | 100 | 100 | | | | | | | 500 | 1×10^{-10} | 0.99 |
| 13 | 100 | 100 | 100 | 100 | 100 | | | | | | 500 | 1×10^{-10} | 0.99 |
| 14 | 100 | 100 | 100 | 100 | 100 | 100 | | | | | 500 | 1×10^{-10} | 0.99 |

| Skenario | HL 1 | HL 2 | HL 3 | HL 4 | HL 5 | HL 6 | HL 7 | HL 8 | HL 9 | HL 10 | Epochs | <i>Epsilon</i> | <i>Rho</i> |
|----------|------|------|------|------|------|------|------|------|------|-------|--------|---------------------|------------|
| 15 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | | | | 500 | 1×10^{-10} | 0.99 |
| 16 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | | | 500 | 1×10^{-10} | 0.99 |
| 17 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | | 500 | 1×10^{-10} | 0.99 |
| 18 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 500 | 1×10^{-10} | 0.99 |
| 19 | 200 | 200 | | | | | | | | | 250 | 1×10^{-10} | 0.99 |
| 20 | 200 | 200 | 200 | | | | | | | | 250 | 1×10^{-10} | 0.99 |
| 21 | 200 | 200 | 200 | 200 | | | | | | | 250 | 1×10^{-10} | 0.99 |
| 22 | 200 | 200 | 200 | 200 | 200 | | | | | | 250 | 1×10^{-10} | 0.99 |
| 23 | 200 | 200 | 200 | 200 | 200 | 200 | | | | | 250 | 1×10^{-10} | 0.99 |
| 24 | 200 | 200 | 200 | 200 | 200 | 200 | 200 | | | | 250 | 1×10^{-10} | 0.99 |
| 25 | 200 | 200 | 200 | 200 | 200 | 200 | 200 | 200 | | | 250 | 1×10^{-10} | 0.99 |
| 26 | 200 | 200 | 200 | 200 | 200 | 200 | 200 | 200 | 200 | | 250 | 1×10^{-10} | 0.99 |
| 27 | 200 | 200 | 200 | 200 | 200 | 200 | 200 | 200 | 200 | 200 | 250 | 1×10^{-10} | 0.99 |
| 28 | 300 | 300 | | | | | | | | | 250 | 1×10^{-10} | 0.99 |
| 29 | 300 | 300 | 300 | | | | | | | | 250 | 1×10^{-10} | 0.99 |

| Skenario | HL 1 | HL 2 | HL 3 | HL 4 | HL 5 | HL 6 | HL 7 | HL 8 | HL 9 | HL 10 | Epochs | <i>Epsilon</i> | <i>Rho</i> |
|----------|------|------|------|------|------|------|------|------|------|-------|--------|---------------------|------------|
| 30 | 300 | 300 | 300 | 300 | | | | | | | 250 | 1×10^{-10} | 0.99 |
| 31 | 300 | 300 | 300 | 300 | 300 | | | | | | 250 | 1×10^{-10} | 0.99 |
| 32 | 300 | 300 | 300 | 300 | 300 | 300 | | | | | 250 | 1×10^{-10} | 0.99 |
| 33 | 300 | 300 | 300 | 300 | 300 | 300 | 300 | | | | 250 | 1×10^{-10} | 0.99 |
| 34 | 300 | 300 | 300 | 300 | 300 | 300 | 300 | 300 | | | 250 | 1×10^{-10} | 0.99 |
| 35 | 300 | 300 | 300 | 300 | 300 | 300 | 300 | 300 | 300 | | 250 | 1×10^{-10} | 0.99 |
| 36 | 300 | 300 | 300 | 300 | 300 | 300 | 300 | 300 | 300 | 300 | 250 | 1×10^{-10} | 0.99 |
| 37 | 400 | 400 | | | | | | | | | 50 | 1×10^{-10} | 0.99 |
| 38 | 400 | 400 | 400 | | | | | | | | 50 | 1×10^{-10} | 0.99 |
| 39 | 400 | 400 | 400 | 400 | | | | | | | 50 | 1×10^{-10} | 0.99 |
| 40 | 400 | 400 | 400 | 400 | 400 | | | | | | 50 | 1×10^{-10} | 0.99 |
| 41 | 400 | 400 | 400 | 400 | 400 | 400 | | | | | 50 | 1×10^{-10} | 0.99 |
| 42 | 400 | 400 | 400 | 400 | 400 | 400 | 400 | | | | 50 | 1×10^{-10} | 0.99 |
| 43 | 400 | 400 | 400 | 400 | 400 | 400 | 400 | 400 | | | 50 | 1×10^{-10} | 0.99 |
| 44 | 400 | 400 | 400 | 400 | 400 | 400 | 400 | 400 | 400 | | 50 | 1×10^{-10} | 0.99 |

| Skenario | HL 1 | HL 2 | HL 3 | HL 4 | HL 5 | HL 6 | HL 7 | HL 8 | HL 9 | HL 10 | Epochs | <i>Epsilon</i> | <i>Rho</i> |
|----------|------|------|------|------|------|------|------|------|------|-------|--------|---------------------|------------|
| 45 | 400 | 400 | 400 | 400 | 400 | 400 | 400 | 400 | 400 | 400 | 50 | 1×10^{-10} | 0.99 |
| 46 | 500 | 500 | | | | | | | | | 10 | 1×10^{-10} | 0.99 |
| 47 | 500 | 500 | 500 | | | | | | | | 10 | 1×10^{-10} | 0.99 |
| 48 | 500 | 500 | 500 | 500 | | | | | | | 10 | 1×10^{-10} | 0.99 |
| 49 | 500 | 500 | 500 | 500 | 500 | | | | | | 10 | 1×10^{-10} | 0.99 |
| 50 | 500 | 500 | 500 | 500 | 500 | 500 | | | | | 10 | 1×10^{-10} | 0.99 |
| 51 | 500 | 500 | 500 | 500 | 500 | 500 | 500 | | | | 10 | 1×10^{-10} | 0.99 |
| 52 | 500 | 500 | 500 | 500 | 500 | 500 | 500 | 500 | | | 10 | 1×10^{-10} | 0.99 |
| 53 | 500 | 500 | 500 | 500 | 500 | 500 | 500 | 500 | 500 | | 10 | 1×10^{-10} | 0.99 |
| 54 | 500 | 500 | 500 | 500 | 500 | 500 | 500 | 500 | 500 | 500 | 10 | 1×10^{-10} | 0.99 |
| 55 | 600 | 600 | | | | | | | | | 10 | 1×10^{-10} | 0.99 |
| 56 | 600 | 600 | 600 | | | | | | | | 10 | 1×10^{-10} | 0.99 |
| 57 | 600 | 600 | 600 | 600 | | | | | | | 10 | 1×10^{-10} | 0.99 |
| 58 | 600 | 600 | 600 | 600 | 600 | | | | | | 10 | 1×10^{-10} | 0.99 |
| 59 | 600 | 600 | 600 | 600 | 600 | 600 | | | | | 10 | 1×10^{-10} | 0.99 |

| Skenario | HL 1 | HL 2 | HL 3 | HL 4 | HL 5 | HL 6 | HL 7 | HL 8 | HL 9 | HL 10 | Epochs | <i>Epsilon</i> | <i>Rho</i> |
|----------|------|------|------|------|------|------|------|------|------|-------|--------|---------------------|------------|
| 60 | 600 | 600 | 600 | 600 | 600 | 600 | 600 | | | | 10 | 1×10^{-10} | 0.99 |
| 61 | 600 | 600 | 600 | 600 | 600 | 600 | 600 | 600 | | | 10 | 1×10^{-10} | 0.99 |
| 62 | 600 | 600 | 600 | 600 | 600 | 600 | 600 | 600 | 600 | | 10 | 1×10^{-10} | 0.99 |
| 63 | 600 | 600 | 600 | 600 | 600 | 600 | 600 | 600 | 600 | 600 | 10 | 1×10^{-10} | 0.99 |

Tabel 4. 7 Skenario Eksperimen Jumlah Epochs Optimal

| Skenario | Hidden Layer 1 | Hidden Layer 2 | Hidden Layer 3 | Epochs | <i>Epsilon</i> | <i>Rho</i> |
|----------|----------------|----------------|----------------|--------|---------------------|------------|
| 64 | 100 | 200 | 300 | 2000 | 1×10^{-10} | 0.99 |
| 65 | 100 | 200 | 300 | 2500 | 1×10^{-10} | 0.99 |
| 66 | 100 | 200 | 300 | 3000 | 1×10^{-10} | 0.99 |
| 67 | 100 | 200 | 300 | 3500 | 1×10^{-10} | 0.99 |
| 68 | 100 | 200 | 300 | 4000 | 1×10^{-10} | 0.99 |
| 69 | 100 | 200 | 300 | 4500 | 1×10^{-10} | 0.99 |
| 70 | 100 | 200 | 300 | 5000 | 1×10^{-10} | 0.99 |

Tabel 4. 8 Skenario Eksperimen Jumlah *Epsilon* Optimal

| Skenario | Hidden Layer 1 | Hidden Layer 2 | Hidden Layer 3 | Hidden Layer 4 | Epochs | <i>Epsilon</i> | <i>Rho</i> |
|-----------------|-----------------------|-----------------------|-----------------------|-----------------------|---------------|-----------------------|-------------------|
| 71 | 100 | 200 | 300 | 400 | 1500 | 1×10^{-4} | 0.99 |
| 72 | 100 | 200 | 300 | 400 | 1500 | 1×10^{-5} | 0.99 |
| 73 | 100 | 200 | 300 | 400 | 1500 | 1×10^{-6} | 0.99 |
| 74 | 100 | 200 | 300 | 400 | 1500 | 1×10^{-7} | 0.99 |
| 75 | 100 | 200 | 300 | 400 | 1500 | 1×10^{-8} | 0.99 |
| 76 | 100 | 200 | 300 | 400 | 1500 | 1×10^{-9} | 0.99 |

Tabel 4. 9 Skenario Eksperimen Jumlah *Rho* Optimal

| Skenario | Hidden Layer 1 | Hidden Layer 2 | Hidden Layer 3 | Hidden Layer 4 | Epochs | <i>Epsilon</i> | <i>Rho</i> |
|-----------------|-----------------------|-----------------------|-----------------------|-----------------------|---------------|-----------------------|-------------------|
| 77 | 100 | 200 | 300 | 400 | 1500 | 1×10^{-10} | 0.90 |
| 78 | 100 | 200 | 300 | 400 | 1500 | 1×10^{-10} | 0.93 |
| 79 | 100 | 200 | 300 | 400 | 1500 | 1×10^{-10} | 0.95 |
| 80 | 100 | 200 | 300 | 400 | 1500 | 1×10^{-10} | 0.98 |
| 81 | 100 | 200 | 300 | 400 | 1500 | 1×10^{-10} | 0.991 |

| Skenario | Hidden Layer 1 | Hidden Layer 2 | Hidden Layer 3 | Hidden Layer 4 | Epochs | <i>Epsilon</i> | <i>Rho</i> |
|-----------------|-----------------------|-----------------------|-----------------------|-----------------------|---------------|---------------------|------------|
| 82 | 100 | 200 | 300 | 400 | 1500 | 1×10^{-10} | 0.992 |
| 83 | 100 | 200 | 300 | 400 | 1500 | 1×10^{-10} | 0.995 |
| 84 | 100 | 200 | 300 | 400 | 1500 | 1×10^{-10} | 0.999 |

Untuk nilai *epochs* yang digunakan dalam pengujian nilai *hidden layer* dan neuron optimal, didapatkan dari uji coba parameter DNN berupa nilai *epochs* yang digunakan adalah 500 dan 1500 [2]. Sehingga *epochs* awal yang digunakan dalam penelitian ini adalah 1500 dan 500. Kemudian untuk nilai *epsilon* yang diujikan dalam penelitian, didapatkan dari *range* nilai *epsilon* terkecil pada RapidMiner yaitu 1×10^{-10} hingga yang terbesar yaitu 1×10^{-4} . Begitupun dengan nilai *Rho* yang digunakan dalam pengujian nilai *Rho* yang optimal, didapatkan dari nilai *Rho* terkecil dalam RapidMiner yaitu 0.9 dan terbesar yaitu 0.999. Sehingga untuk nilai *epsilon* dan *Rho* diuji dengan menggunakan nilai yang ada dalam kisaran tersebut.

Halaman ini sengaja dikosongkan

BAB V IMPLEMENTASI

Bab ini menjelaskan proses pelaksanaan penelitian tugas akhir dan proses implementasi dari perancangan yang telah dilaksanakan pada bab sebelumnya yaitu Bab IV.

5.1. Pengelompokan Data Jumlah Penumpang di Setiap Stasiun Tujuan Berdasarkan Pola Data

Sebelum dilakukan peramalan dengan DNN menggunakan *tools* RapidMiner, terlebih dahulu data dikelompokkan berdasarkan pola data yang dimiliki. Adapun hasil pengelompokan data berdasarkan pola datanya ini, adalah:

Tabel 5. 1 Kelompok Pola Data

| No | Kelompok Pola Data | Nama Stasiun |
|-----------|---------------------------|---------------------|
| 1 | Stasioner | Bogor |
| 2 | | Tangerang |
| 3 | | Duri |
| 4 | | Parung Panjang |
| 5 | | Serpong |
| 6 | | Kemayoran |
| 7 | | Kali Deres |
| 8 | | Gang Sentiong |
| 9 | | Pondok Jati |
| 10 | | Bojong Indah |
| 11 | | Cibinong |

| No | Kelompok Pola Data | Nama Stasiun |
|----|--------------------|-----------------|
| 12 | Stasioner | Daru |
| 13 | | Tambun |
| 14 | Seasonal | Tanah Abang |
| 15 | | Sudirman |
| 16 | | Bekasi |
| 17 | | Bojong Gede |
| 18 | | Depok Baru |
| 19 | | Citayam |
| 20 | | Tebet |
| 21 | | Gondangdia |
| 22 | | Depok |
| 23 | | Cikini |
| 24 | | Pondok Cina |
| 25 | | Pasar Minggu |
| 26 | | Manggarai |
| 27 | | Duren Kalibata |
| 28 | | Sudimara |
| 29 | | Cilebut |
| 30 | | Cawang |
| 31 | | Univ. Indonesia |
| 32 | | Kranji |
| 33 | | Palmerah |

| No | Kelompok Pola Data | Nama Stasiun |
|----|--------------------|-------------------|
| 34 | Seasonal | Jatinegara |
| 35 | | Lenteng Agung |
| 36 | | Tanjung Barat |
| 37 | | Kebayoran |
| 38 | | Rawa Buntu |
| 39 | | Sawah Besar |
| 40 | | Pondok Kranji |
| 41 | | Karet |
| 42 | | Cakung |
| 43 | | Klender Baru |
| 44 | | Mangga Besar |
| 45 | | Jayakarta |
| 46 | | Kampung Bandan |
| 47 | | Poris |
| 48 | | Klender |
| 49 | | Univ. Pancasila |
| 50 | | Jurang Mangu |
| 51 | | Pesing |
| 52 | | Pasar Minggu Baru |
| 53 | | Rawa Buaya |

| No | Kelompok Pola Data | Nama Stasiun |
|-----------|---------------------------|-------------------------------|
| 54 | Seasonal | Cisauk |
| 55 | | Batu Ceper |
| 56 | | Rajawali |
| 57 | | Kramat |
| 58 | | Cicayur |
| 59 | | Cilejit |
| 60 | | Grogol |
| 61 | | Taman Kota |
| 62 | | Cikoya |
| 63 | | Seasonal dengan Nilai Ekstrem |
| 64 | Buaran | |
| 65 | Tanah Tinggi | |
| 66 | Bekasi Timur | |
| 67 | Seasonal Sisir Terbalik | Pasar Senen |
| 68 | | Tiga Raksa |
| 69 | | Nambo |
| 70 | | Tenjo |
| 71 | | Maja |
| 72 | | Tanjung Priok |
| 73 | | Angke |
| 74 | | Citeras |
| 75 | | Rangkas Bitung |

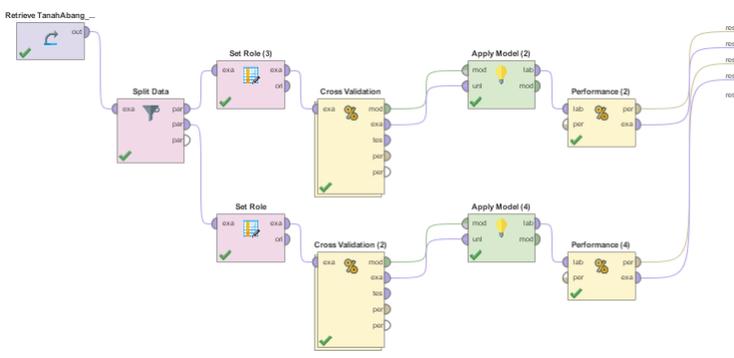
| No | Kelompok Pola Data | Nama Stasiun |
|----|--|--------------|
| 76 | Seasonal Sisir Terbalik dengan Nilai Ekstrem | Jakarta Kota |
| 77 | | Ancol |
| 78 | | Cibitung |
| 79 | | Cikarang |

Untuk contoh grafik dari setiap kelompok pola data, dapat dilihat dalam Lampiran B.

Kemudian, dari seluruh stasiun yang terdapat dalam tabel di atas, yaitu Tabel 5.1, akan dipilih satu stasiun sebagai perwakilan dari seluruh stasiun untuk dilakukan pencarian model peramalan terbaik yang kemudian model peramalan terbaik tadi digunakan untuk diuji akurasi peramalannya dengan melihat MAPE yang dihasilkan. Jika MAPE yang dihasilkan $< 10\%$, maka akan dilanjutkan dengan peramalan untuk periode ke depan, namun jika MAPE $> 10\%$, maka akan dilakukan pencarian ulang model peramalan terbaik khusus untuk stasiun dengan MAPE di atas 10% . Adapun stasiun yang dipilih untuk dilakukan pencarian model terbaik adalah Stasiun Tanah Abang.

5.2. Implementasi DNN dengan *Tools* RapidMiner pada Data Aktual

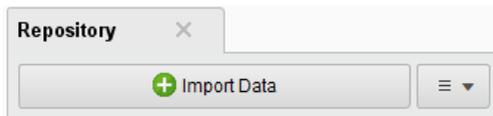
Implementasi DNN menggunakan *tools* RapidMiner dalam tugas akhir ini, dilakukan dengan menyambungkan blok-blok operator yang ada pada *tools* RapidMiner hingga membentuk sebuah rangkaian alur blok operator pada RapidMiner seperti pada gambar di bawah ini, yaitu Gambar 5.1.



Gambar 5.1 Rangkaian Alur Blok Operator Implementasi DNN dengan Rapidminer pada Data Aktual

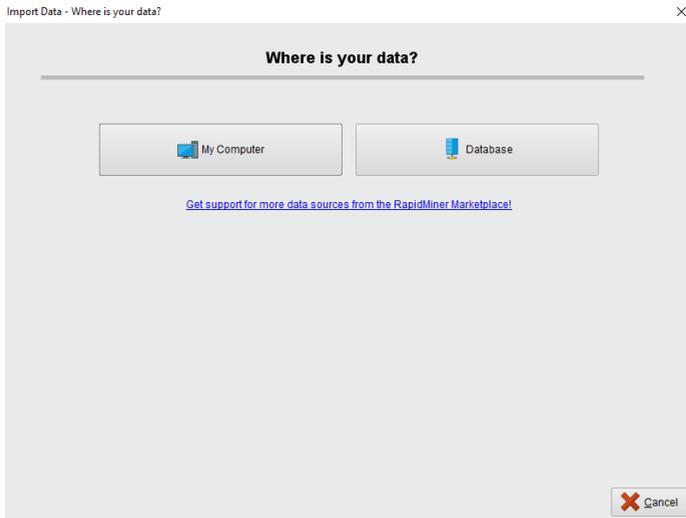
5.2.1 Persiapan Data Input

Data yang digunakan pada penelitian ini merupakan data harian dari tanggal 1 Januari 2018 hingga 31 Desember 2018. Untuk memasukkan data ke *tools* RapidMiner, pertama-tama dilakukan *Import Data* dengan melakukan klik pada tombol “Import Data” yang terdapat pada Panel “Repository” seperti pada Gambar 5.2.



Gambar 5.2 Tombol “Import Data”

Kemudian, memilih lokasi data berada pada Panel “Import Data – Where is your data?” seperti pada Gambar 5.3, dimana dalam hal ini data tersimpan di My Computer, sehingga melakukan klik pada tombol “My Computer” dan dilanjutkan dengan memilih dataset yang akan dimasukkan ke dalam Repository.



Gambar 5.3 Panel “*Import Data – Where is your data?*”

Kemudian, setelah data dimasukkan ke dalam Repository yang dipilih pada tahapan sebelumnya, data dimasukkan ke dalam Panel “*Process*” dengan menggunakan Operator “*Retrieve*” seperti pada Gambar 5.4.



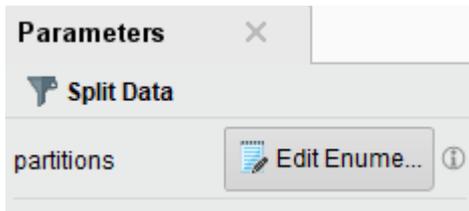
Gambar 5.4 Operator “*Retrieve*”

Lalu, data dibagi dengan proporsi 80:20 dimana 80% merupakan data training dan 20% merupakan data *testing*. Pembagian data dilakukan dengan menggunakan Operator “*Split Data*” seperti pada Gambar 5.5.



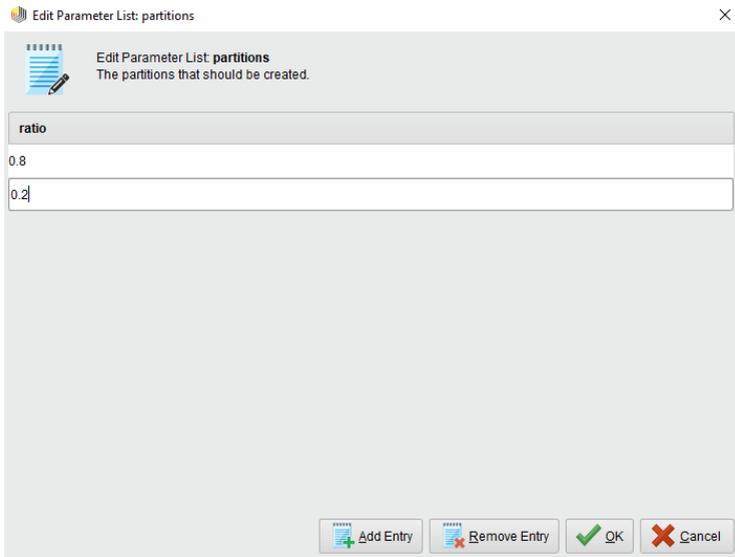
Gambar 5.5 Operator “Split Data”

Di dalam Operator “*Split Data*”, terdapat parameter partisi yang diisi dengan perbandingan pembagian data. Karena data akan dibagi dengan perbandingan 80% untuk data *training* dan 20% untuk data *testing*, maka parameter partisi diisi dengan angka 0.8 dan 0.2. Pengisian parameter partisi dilakukan dengan melakukan klik pada tombol “*Edit Enumeration*” pada parameter “*partitions*” seperti pada Gambar 5.6.



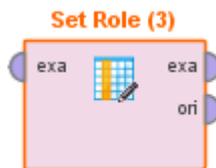
Gambar 5.6 Tombol “Edit Enumeration” pada Parameter “partitions”

Lalu, di dalam panel baru yang muncul, yaitu Panel “*Edit Parameter List: partitions*”, pada bagian “*ratio*”, melakukan klik pada “*Add Entry*”, lalu diisi dengan 0.8, dan lakukan “*Add Entry*” kembali dan isi dengan 0.2, lalu klik Tombol “*OK*”. Panel “*Edit Parameter List: partitions*” akan terlihat seperti pada gambar di bawah ini, yaitu Gambar 5.7.



Gambar 5. 7 Tampilan Panel “*Edit Parameter List: partitions*”

Setelah pembagian data dilakukan, maka pada variabel “Jumlah” yang terdapat pada data, diberikan *role* “*label*” dengan menggunakan Operator “*Set Role*” seperti pada Gambar 5.8. Operator ini diperlukan untuk menentukan variabel yang hendak diramalkan.



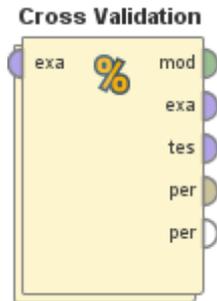
Gambar 5. 8 Operator “*Set Role*”

Di dalam Operator “*Set Role*”, terdapat parameter “*attribute name*” yang diisi dengan variabel yang hendak diramalkan

yaitu variabel “Jumlah”. Lalu pada parameter “*target role*” diisi dengan *role* “*label*” yang berperan sebagai target yang akan diramalkan nantinya.

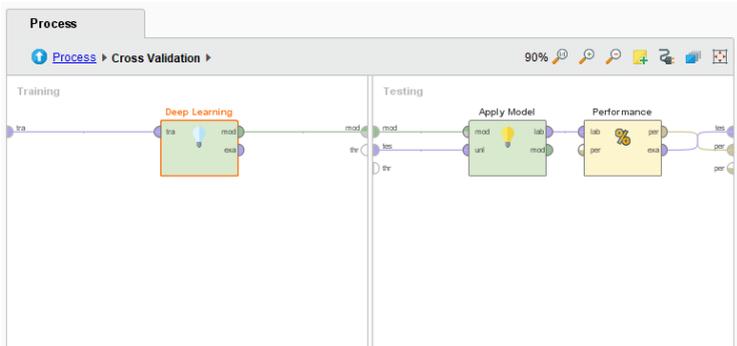
5.2.2 Cross – Validation

Langkah berikutnya yaitu memakai Operator “*Cross Validation*” seperti pada Gambar 5.9 yang berguna untuk melakukan estimasi performa model pembelajaran sehingga dapat ditentukan model pembelajaran yang lebih akurat, dimana dalam hal ini yaitu model DNN.



Gambar 5.9 Operator “*Cross Validation*”

Di dalam Operator “*Cross Validation*” terdapat dua subset proses yang dapat dilihat pada Gambar 5.10 dimana satu subset untuk melakukan pelatihan pada model DNN yang dibentuk (sub proses *Training*), sedangkan subset lainnya (sub proses *Testing*) untuk mengevaluasi performa dari model yang dibuat.

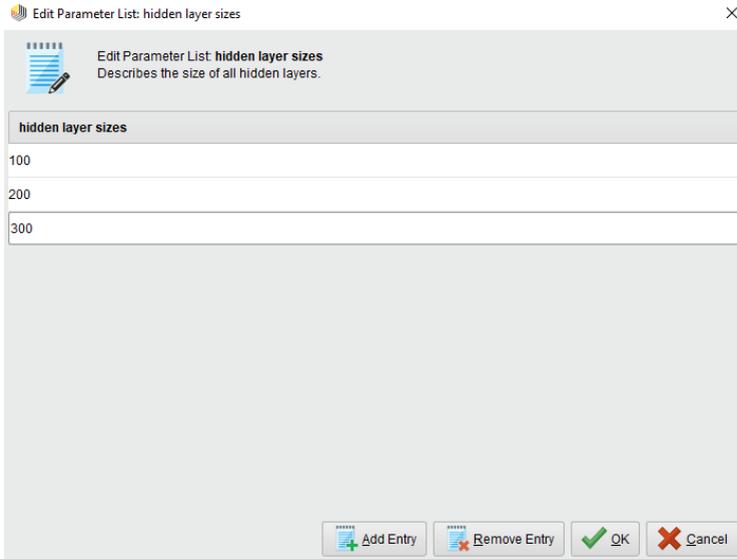


Gambar 5. 10 Dua Subset Proses dalam Cross Validation

5.2.2.1 Pembentukan DNN

Di dalam subset training, dimasukkan Operator “*Deep Learning*” untuk membuat model jaringan DNN. Dalam operator ini, parameter-parameter yang ditentukan nilainya yaitu jumlah *hidden layer* beserta jumlah neuron di dalam setiap *hidden layer*, nilai *epochs*, dan nilai ADADELTA (*Adaptive Learning Rate Algorithm*) yang terdiri dari dua, yaitu; nilai *epsilon* dan nilai *Rho*. Untuk parameter lainnya diberikan nilai *default* dari *tools* RapidMiner.

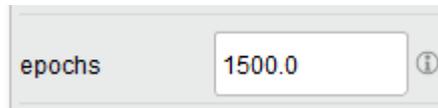
Untuk jumlah *hidden layer* beserta neuron di dalamnya, diisi dengan seluruh nilai yang telah dituliskan pada tabel 4.6 secara bergantian, hingga mendapatkan nilai MSE yang paling kecil. Sebagai contoh pengisian pada Gambar 5.11, maka jumlah *hidden layer* dan *neuron* diisi dengan skenario 56. Untuk mendapatkan tiga *hidden layer*, maka dilakukan klik tombol “*Add Entry*” sebanyak tiga kali, dan pada tiap kolom diisi secara berurutan nilai 100, 200, dan 300.



Gambar 5. 11 Panel “Edit Parameter List: hidden layer sizes”

Begitupun dengan nilai *epochs* dan nilai ADADELTA (*Adaptive Learning Rate Algorithm*) yaitu nilai *epsilon* dan *Rho*, diisi secara bergantian dengan nilai yang terdapat pada tabel 4.7, 4.8, dan 4.9 hingga mendapatkan nilai *epochs* dan nilai *epsilon* dan *Rho* yang optimal, yaitu nilai yang menghasilkan MSE terkecil.

Dengan melanjutkan skenario 56 sebagai contoh, maka seperti pada Gambar 5.12 dan Gambar 5.13 nilai *epochs* diisi dengan nilai 1500, kemudian nilai *epsilon* diisi dengan nilai 1×10^{-10} , dan nilai *Rho* diisi dengan nilai 0.99.



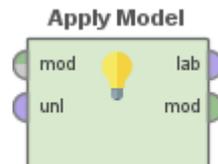
Gambar 5. 12 Parameter *Epochs* dengan Nilai 1500



Gambar 5. 13 Parameter *Epsilon* dengan Nilai 1×10^{-10} dan *Rho* dengan Nilai 0.99

5.2.3 Penerapan Model DNN

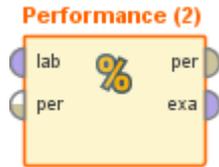
Kemudian, model DNN yang telah dibentuk pada tahapan sebelumnya, yaitu pada Sub Bab 5.2.2.1, diterapkan dengan menggunakan Operator “*Apply Model*” seperti pada Gambar 5.14 yang berguna untuk mengaplikasikan model yang dilatih sebelumnya.



Gambar 5. 14 Operator “*Apply Model*”

5.2.4 Penghitungan MSE dari Model DNN

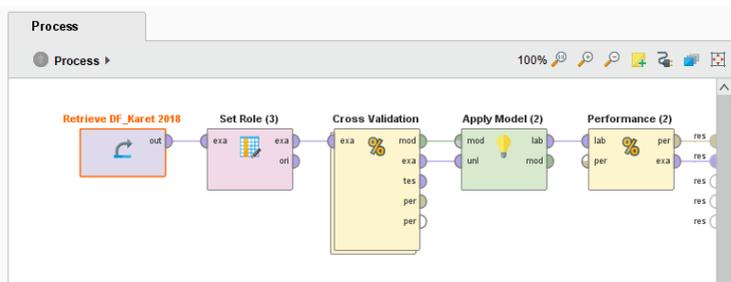
Penghitungan performa dari model yang dibuat dengan menggunakan Operator “*Performance (Regression)*” seperti pada Gambar 5.15 yang kemudian pada parameternya diberi centang pada “*squared error*” untuk mengetahui, MSE dari penerapan model yang dibuat pada data *training*.



Gambar 5. 15 Operator “Performance”

5.3. Implementasi DNN dengan *Tools RapidMiner* pada Kelompok Pola Data yang Sama dan Data untuk Peramalan (*Forecasting*) ke Depan

Setelah mendapatkan model terbaik, proses dilanjutkan dengan melakukan pengujian model pada data jumlah penumpang di stasiun lainnya serta melakukan peramalan pada periode ke depan (enam bulan ke depan) untuk setiap stasiun dengan menggunakan model terbaik yang didapatkan. Proses ini secara keseluruhan sama dengan Sub Bab 5.1, hanya saja terdapat perbedaan yaitu proses ini tidak menggunakan Operator “*Split Data*” sehingga tidak ada proses pembagian data menjadi data *training* dan data *testing*. Keseluruhan proses yang terdiri dari rangkaian alur blok operator ini dapat dilihat pada Gambar 5.16.



Gambar 5. 16 Rangkaian Alur Blok Operator Implementasi DNN dengan Rapidminer pada Kelompok Pola Data yang Sama dan Data untuk Peramalan (*Forecasting*) ke Depan

BAB VI

HASIL DAN PEMBAHASAN

Pada bab ini akan menjelaskan mengenai proses dan hasil uji coba serta analisis terhadap hasil peramalan yang diperoleh dari proses implementasi DNN dengan menggunakan *tools* RapidMiner, termasuk eksperimen parameter yang digunakan.

6.1. Hasil Uji Coba Parameter Jumlah *Hidden Layer* dan Neuron pada Model DNN

Untuk mengetahui model DNN terbaik adalah dengan cara menentukan jumlah *hidden layer* dan neuron, *epochs*, nilai ADADELTA (Adaptive Learning Rate Algorithm) yaitu *epsilon* dan *Rho* yang optimal dan menghasilkan model dengan MSE terkecil. Pada eksperimen ini dilakukan pencarian jumlah *hidden layer* dan *neuron* optimal melalui pengujian skenario, dimana beberapa skenario memiliki *epochs* yang lebih kecil ketimbang skenario lainnya karena bertujuan untuk memotong *running time*. Sehingga nantinya dari setiap beberapa kelompok skenario, diambil satu skenario terbaik untuk kemudian dilakukan pengujian kembali menggunakan jumlah *epochs* yang sama untuk dicari performa skenario terbaik.

Kemudian, untuk data *input* yang digunakan dalam pencarian model terbaik untuk seluruh stasiun yaitu Data Harian Jumlah Penumpang Stasiun Tanah Abang Tahun 2018. Adapun pemilihan Stasiun Tanah Abang sebagai perwakilan data *input* adalah karena Stasiun Tanah Abang termasuk kelompok pola data seasonal dimana di dalam kelompok pola data seasonal ini, terdapat 49 stasiun dari 79 stasiun yang terdapat dalam kelompok ini, yang berarti hampir sebagian besar stasiun memiliki pola data seasonal. Dari kelompok pola data seasonal

ini, Stasiun Tanah Abang merupakan stasiun yang berada pada nomor dua dalam daftar nama stasiun yang dirilis oleh PT.KAI Commuter Jakarta. Sehingga Stasiun Tanah Abang dipilih sebagai perwakilan seluruh stasiun untuk data *input* dalam pencarian model terbaik bagi seluruh stasiun. Kemudian, model terbaik yang didapatkan ini akan diuji pada seluruh data jumlah penumpang di stasiun lainnya. Adapun hasil uji coba parameter jumlah *hidden layer* dan neuron pada model DNN untuk Stasiun Tanah Abang ditunjukkan pada Tabel 6.1 – 6.7:

Tabel 6. 1 Nilai MSE untuk Skenario 1-9

| Skenario | Epochs | <i>Epsilon</i> | <i>Rho</i> | MSE |
|-----------------|---------------|-----------------------|-------------------|---------------|
| 1 | 1500 | 1×10^{-10} | 0.99 | 23,531,905.85 |
| 2 | 1500 | 1×10^{-10} | 0.99 | 1,258,178.32 |
| 3 | 1500 | 1×10^{-10} | 0.99 | 4,850,809.81 |
| 4 | 1500 | 1×10^{-10} | 0.99 | 1,522,964.61 |
| 5 | 1500 | 1×10^{-10} | 0.99 | 33,522,971.67 |
| 6 | 1500 | 1×10^{-10} | 0.99 | 37,510,322.52 |
| 7 | 1500 | 1×10^{-10} | 0.99 | 36,289,696.63 |
| 8 | 1500 | 1×10^{-10} | 0.99 | 37,511,247.86 |
| 9 | 1500 | 1×10^{-10} | 0.99 | 44,035,358.86 |

Skenario 1-9 merupakan skenario dimana setiap *hidden layer* memiliki kombinasi jumlah neuron yang berbeda-beda. Kombinasi jumlah neuron ini dapat dilihat di baris 1-9 pada Tabel 4.6 Hasil pada Tabel 6.1 menunjukkan bahwa MSE terkecil untuk Stasiun Tanah Abang dimiliki oleh Skenario 2 dengan Nilai MSE 1,258,178.32.

Tabel 6. 2 Nilai MSE untuk Skenario 10-18

| Skenario | Jumlah Hidden Layer | Epochs | <i>Epsilon</i> | <i>Rho</i> | MSE |
|----------|---------------------|--------|---------------------|------------|---------------|
| 10 | 2 | 500 | 1×10^{-10} | 0.99 | 26,964,597.15 |
| 11 | 3 | 500 | 1×10^{-10} | 0.99 | 21,701,754.18 |
| 12 | 4 | 500 | 1×10^{-10} | 0.99 | 9,033,168.03 |
| 13 | 5 | 500 | 1×10^{-10} | 0.99 | 15,600,136.26 |
| 14 | 6 | 500 | 1×10^{-10} | 0.99 | 14,187,968.10 |
| 15 | 7 | 500 | 1×10^{-10} | 0.99 | 13,610,798.66 |
| 16 | 8 | 500 | 1×10^{-10} | 0.99 | 13,679,401.63 |
| 17 | 9 | 500 | 1×10^{-10} | 0.99 | 6,217,402.48 |
| 18 | 10 | 500 | 1×10^{-10} | 0.99 | 14,670,378.77 |

Skenario 10-18 merupakan skenario dimana setiap *hidden layer* memiliki neuron 100. Hasil pada Tabel 6.2 menunjukkan bahwa MSE untuk Stasiun Tanah Abang terkecil dimiliki oleh Skenario 17 dengan Nilai MSE 6,217,402.48.

Tabel 6. 3 Nilai MSE untuk Skenario 19 - 36

| Skenario | Jumlah Hidden Layer | Epochs | <i>Epsilon</i> | <i>Rho</i> | MSE |
|----------|---------------------|--------|---------------------|------------|---------------|
| 19 | 2 | 250 | 1×10^{-10} | 0.99 | 30,750,183.67 |
| 20 | 3 | 250 | 1×10^{-10} | 0.99 | 23,205,569.60 |
| 21 | 4 | 250 | 1×10^{-10} | 0.99 | 27,337,352.64 |
| 22 | 5 | 250 | 1×10^{-10} | 0.99 | 19,934,549.02 |
| 23 | 6 | 250 | 1×10^{-10} | 0.99 | 15,707,442.79 |
| 24 | 7 | 250 | 1×10^{-10} | 0.99 | 11,338,840.33 |
| 25 | 8 | 250 | 1×10^{-10} | 0.99 | 15,662,561.14 |
| 26 | 9 | 250 | 1×10^{-10} | 0.99 | 29,342,324.74 |
| 27 | 10 | 250 | 1×10^{-10} | 0.99 | 12,077,031.23 |
| 28 | 2 | 250 | 1×10^{-10} | 0.99 | 31,481,038.18 |
| 29 | 3 | 250 | 1×10^{-10} | 0.99 | 23,798,531.74 |
| 30 | 4 | 250 | 1×10^{-10} | 0.99 | 31,334,219.45 |
| 31 | 5 | 250 | 1×10^{-10} | 0.99 | 23,065,145.69 |
| 32 | 6 | 250 | 1×10^{-10} | 0.99 | 30,993,496.87 |
| 33 | 7 | 250 | 1×10^{-10} | 0.99 | 36,801,949.25 |
| 34 | 8 | 250 | 1×10^{-10} | 0.99 | 36,593,519.50 |
| 35 | 9 | 250 | 1×10^{-10} | 0.99 | 30,650,913.14 |
| 36 | 10 | 250 | 1×10^{-10} | 0.99 | 26,890,126.29 |

Skenario 19-36 merupakan skenario dimana untuk skenario 19-27, setiap *hidden layer* memiliki neuron 200, sedangkan untuk skenario 28-36 setiap *hidden layer* memiliki neuron 300. Hasil pada Tabel 6.3 menunjukkan bahwa MSE untuk Stasiun Tanah Abang terkecil dimiliki oleh Skenario 24 dengan Nilai MSE 11,338,840.33.

Tabel 6. 4 Nilai MSE untuk Skenario 37 - 45

| Skenario | Jumlah Hidden Layer | Epochs | <i>Epsilon</i> | <i>Rho</i> | MSE |
|----------|---------------------|--------|---------------------|------------|---------------|
| 37 | 2 | 50 | 1×10^{-10} | 0.99 | 36,634,882.32 |
| 38 | 3 | 50 | 1×10^{-10} | 0.99 | 33,546,233.14 |
| 39 | 4 | 50 | 1×10^{-10} | 0.99 | 34,487,411.27 |
| 40 | 5 | 50 | 1×10^{-10} | 0.99 | 35,884,921.32 |
| 41 | 6 | 50 | 1×10^{-10} | 0.99 | 35,116,842.46 |
| 42 | 7 | 50 | 1×10^{-10} | 0.99 | 37,577,046.17 |
| 43 | 8 | 50 | 1×10^{-10} | 0.99 | 38,462,810.38 |
| 44 | 9 | 50 | 1×10^{-10} | 0.99 | 38,196,978.66 |
| 45 | 10 | 50 | 1×10^{-10} | 0.99 | 38,696,476.55 |

Skenario 37-45 merupakan skenario dimana setiap *hidden layer* memiliki neuron 400. Hasil pada Tabel 6.4 menunjukkan bahwa MSE untuk Stasiun Tanah Abang terkecil dimiliki oleh Skenario 39 dengan Nilai MSE 34,487,411.27.

Tabel 6. 5 Nilai MSE untuk Skenario 46- 63

| Skenario | Jumlah Hidden Layer | Epochs | <i>Epsilon</i> | <i>Rho</i> | MSE |
|----------|---------------------|--------|---------------------|------------|---------------|
| 46 | 2 | 10 | 1×10^{-10} | 0.99 | 44,934,411.74 |
| 47 | 3 | 10 | 1×10^{-10} | 0.99 | 38,561,293.08 |
| 48 | 4 | 10 | 1×10^{-10} | 0.99 | 40,773,034.97 |
| 49 | 5 | 10 | 1×10^{-10} | 0.99 | 41,425,717.88 |
| 50 | 6 | 10 | 1×10^{-10} | 0.99 | 41,435,595.23 |
| 51 | 7 | 10 | 1×10^{-10} | 0.99 | 39,415,705.66 |
| 52 | 8 | 10 | 1×10^{-10} | 0.99 | 40,275,635.09 |
| 53 | 9 | 10 | 1×10^{-10} | 0.99 | 39,903,730.08 |
| 54 | 10 | 10 | 1×10^{-10} | 0.99 | 49,260,288.32 |
| 55 | 2 | 10 | 1×10^{-10} | 0.99 | 48,555,003.55 |
| 56 | 3 | 10 | 1×10^{-10} | 0.99 | 43,810,051.67 |
| 57 | 4 | 10 | 1×10^{-10} | 0.99 | 37,336,944.27 |
| 58 | 5 | 10 | 1×10^{-10} | 0.99 | 38,742,926.54 |
| 59 | 6 | 10 | 1×10^{-10} | 0.99 | 38,787,320.62 |
| 60 | 7 | 10 | 1×10^{-10} | 0.99 | 39,628,458.94 |
| 61 | 8 | 10 | 1×10^{-10} | 0.99 | 40,207,465.89 |
| 62 | 9 | 10 | 1×10^{-10} | 0.99 | 40,446,284.43 |
| 63 | 10 | 10 | 1×10^{-10} | 0.99 | 40,203,572.98 |

Skenario 46-63 merupakan skenario dimana untuk skenario 46-54, setiap *hidden layer* memiliki neuron 500, sedangkan untuk skenario 55-63 setiap *hidden layer* memiliki neuron 600. Hasil pada Tabel 6.5 menunjukkan bahwa MSE terkecil untuk Stasiun Tanah Abang dimiliki oleh Skenario 57 dengan Nilai MSE 37,336,944.27.

Dari hasil terbaik yang didapatkan dari Tabel 6.1 – 6.5, maka dilakukan pengujian kembali dengan menyamakan nilai *epochs* menjadi 1500 untuk mengetahui jumlah *hidden layer* dan *neuron* terbaik. Adapun hasilnya ditunjukkan oleh Tabel 6.6 di bawah ini:

Tabel 6. 6 Nilai MSE untuk Hidden Layer dan Neuron Optimal

| Skenario | Epochs | <i>Epsilon</i> | <i>Rho</i> | MSE |
|----------|--------|---------------------|------------|---------------|
| 2 | 1500 | 1×10^{-10} | 0.99 | 1,258,178.32 |
| 17 | 1500 | 1×10^{-10} | 0.99 | 9,829,760.30 |
| 24 | 1500 | 1×10^{-10} | 0.99 | 8,096,171.24 |
| 39 | 1500 | 1×10^{-10} | 0.99 | 6,897,482.25 |
| 57 | 1500 | 1×10^{-10} | 0.99 | 10,084,055.23 |

Dari pengujian kembali skenario 2, 17, 24, 39, dan 57, dapat dilihat bahwa MSE untuk Stasiun Tanah Abang paling kecil dimiliki oleh Skenario 2, dimana Skenario 2 memiliki *hidden layer* tiga, dengan *hidden layer* satu berisi 100 neuron, *hidden layer* dua berisi 200 neuron, dan *hidden layer* tiga berisi 300 neuron. Sehingga, kombinasi jumlah *hidden layer* dan *neuron* terbaik adalah tiga *hidden layer*, dengan jumlah neuron secara berurutan yaitu 100, 200, dan 300.

Dari hasil pengujian Skenario 1-63 juga didapatkan bahwa semakin besar nilai neuron dan jumlah *hidden layer* tidak menjadikan nilai MSE yang semakin kecil, dan sebaliknya, nilai neuron dan jumlah *hidden layer* yang semakin kecil, juga tidak menjadikan nilai MSE semakin besar, sehingga dapat dikatakan bahwa besar kecilnya nilai *hidden layer* dan neuron tidak menentukan nilai MSE yang semakin besar atau semakin kecil. Nilai MSE yang kecil didapatkan dari kombinasi nilai *hidden layer* dan neuron yang optimal.

6.2. Hasil Uji Coba Parameter Jumlah *Epochs* pada Model DNN

Selanjutnya, dilakukan pengujian dalam mengetahui nilai *Epochs* terbaik untuk mendapatkan model DNN terbaik. Pengujian dilakukan dengan menjadikan jumlah *hidden layer* dan neuron, serta nilai *epsilon* dan *Rho* sebagai variabel tetap, yaitu dengan jumlah *hidden layer* empat dengan *hidden layer* pertama bernilai 100, *hidden layer* kedua bernilai 200, dan *hidden layer* ketiga bernilai 300. Kemudian untuk nilai *epsilon*, yaitu 1×10^{-10} dan *Rho* yaitu 0.99. Berikut adalah hasil dari pengujian model DNN dengan pengubahan parameter jumlah *epochs* pada Tabel 6.7.

Tabel 6. 7 Nilai MSE untuk Nilai Epochs Optimal

| Skenario | Epochs | <i>Epsilon</i> | <i>Rho</i> | MSE |
|----------|--------|---------------------|------------|---------------|
| 2 | 1500 | 1×10^{-10} | 0.99 | 12,319,152.44 |
| 64 | 2000 | 1×10^{-10} | 0.99 | 50,451,177.80 |
| 65 | 2500 | 1×10^{-10} | 0.99 | 7,324,792.01 |
| 66 | 3000 | 1×10^{-10} | 0.99 | 9,041,049.88 |
| 67 | 3500 | 1×10^{-10} | 0.99 | 9,559,295.64 |
| 68 | 4000 | 1×10^{-10} | 0.99 | 37,796,609.71 |
| 79 | 4500 | 1×10^{-10} | 0.99 | 12,449,436.57 |
| 70 | 5000 | 1×10^{-10} | 0.99 | 13,799,261.90 |

Setelah dilakukan *running* pada model di dalam Tabel 6.7, dapat dilihat bahwa Skenario 65 dengan nilai *epochs* 2500 memiliki MSE paling kecil yaitu 7,324,792.01. Sehingga dari pengujian model ini, dapat diketahui bahwa nilai *epochs* terbaik yaitu 2500.

Dari hasil pengujian Skenario 2 dan 64-70 juga didapatkan bahwa semakin besar nilai *epochs* tidak menjadikan nilai MSE yang semakin kecil, dan sebaliknya, nilai *epochs* yang

semakin kecil, juga tidak menjadikan nilai MSE semakin besar, sehingga dapat dikatakan bahwa besar kecilnya nilai *epochs* tidak menentukan nilai MSE yang semakin besar atau semakin kecil. Nilai MSE yang kecil didapatkan dari kombinasi nilai *epochs* yang optimal.

6.3. Hasil Uji Coba Parameter Nilai *Epsilon* pada Model DNN

Kemudian, dilakukan pengujian dalam mengetahui nilai *epsilon* terbaik untuk mendapatkan model DNN terbaik. Pengujian dilakukan dengan menjadikan jumlah *hidden layer* dan neuron, serta nilai *epochs* dan *Rho* sebagai variabel tetap, yaitu dengan jumlah *hidden layer* empat dengan *hidden layer* pertama bernilai 100, *hidden layer* kedua bernilai 200, *hidden layer* ketiga bernilai 300, dan *hidden layer* keempat bernilai 400. Kemudian untuk nilai *epochs* yaitu 2500 dan *Rho* yaitu 0.99. Berikut adalah hasil dari pengujian model DNN dengan perubahan parameter jumlah *epsilon* pada Tabel 6.8

Tabel 6. 8 Nilai MSE untuk Nilai *Epsilon* Optimal

| Skenario | Epochs | <i>Epsilon</i> | <i>Rho</i> | MSE |
|----------|--------|---------------------|------------|---------------|
| 2 | 1500 | 1×10^{-10} | 0.99 | 161,023.356 |
| 71 | 1500 | 1×10^{-4} | 0.99 | 46,027,379.02 |
| 72 | 1500 | 1×10^{-5} | 0.99 | 26,530,472.42 |
| 73 | 1500 | 1×10^{-6} | 0.99 | 2,140,429.29 |
| 74 | 1500 | 1×10^{-7} | 0.99 | 437,299.86 |
| 75 | 1500 | 1×10^{-8} | 0.99 | 224,766.02 |
| 76 | 1500 | 1×10^{-9} | 0.99 | 414,601.08 |

Pada hasil pengujian model dalam Tabel 6.8 terlihat bahwa Skenario 2 dengan nilai *epsilon* 1×10^{-10} memiliki MSE paling kecil yaitu 161,023.36. Sehingga dari pengujian model ini, dapat diketahui bahwa nilai *epsilon* terbaik yaitu 1×10^{-10} .

Dari hasil pengujian Skenario 2 dan 71-76 juga didapatkan bahwa semakin besar nilai *Epsilon* tidak menjadikan nilai MSE yang semakin kecil, dan sebaliknya, nilai *Epsilon* yang semakin kecil, juga tidak menjadikan nilai MSE semakin besar, sehingga dapat dikatakan bahwa besar kecilnya nilai *Epsilon* tidak menentukan nilai MSE yang semakin besar atau semakin kecil. Nilai MSE yang kecil didapatkan dari kombinasi nilai *Epsilon* yang optimal.

6.4. Hasil Uji Coba Parameter Nilai *Rho* pada Model DNN

Untuk mendapatkan model DNN terbaik, perlu dilakukan pengujian model DNN dengan pengubahan nilai *Rho*. Pengujian dilakukan dengan menjadikan jumlah *hidden layer* dan neuron, serta jumlah *epochs* dan nilai *epsilon* sebagai variabel tetap, yaitu dengan jumlah *hidden layer* empat dengan *hidden layer* pertama bernilai 100, *hidden layer* kedua bernilai 200, *hidden layer* ketiga bernilai 300, dan *hidden layer* keempat bernilai 400. Kemudian untuk jumlah *epochs* yaitu 1500 nilai *epsilon*, yaitu 1×10^{-10} .

Berikut adalah hasil dari pengujian model DNN dengan perubahan parameter jumlah *Rho* pada Tabel 6.9.

Tabel 6.9 Nilai MSE untuk Nilai *Rho* Optimal

| Skenario | Epochs | <i>Epsilon</i> | <i>Rho</i> | MSE |
|----------|--------|---------------------|------------|---------------|
| 2 | 1500 | 1×10^{-10} | 0.99 | 161,023.356 |
| 77 | 1500 | 1×10^{-10} | 0.90 | 26,273,282.74 |
| 78 | 1500 | 1×10^{-10} | 0.93 | 29,753,094.57 |
| 79 | 1500 | 1×10^{-10} | 0.95 | 29,913,598.36 |
| 80 | 1500 | 1×10^{-10} | 0.98 | 27,997,814.00 |
| 81 | 1500 | 1×10^{-10} | 0.991 | 17,911,284.99 |
| 82 | 1500 | 1×10^{-10} | 0.992 | 29,326,976.16 |
| 83 | 1500 | 1×10^{-10} | 0.995 | 16,583,212.71 |
| 84 | 1500 | 1×10^{-10} | 0.999 | 26,506,541.90 |

Pada hasil pengujian model dalam Tabel 6.9 terlihat bahwa Skenario 2 dengan nilai *Rho* 0.99 memiliki MSE paling kecil yaitu 1,258,178.32. Sehingga dari pengujian model ini, dapat diketahui bahwa nilai *Rho* terbaik yaitu 0.99.

Dari hasil pengujian Skenario 2 dan 77-84 juga didapatkan bahwa semakin besar nilai *Rho* tidak menjadikan nilai MSE yang semakin kecil, dan sebaliknya, nilai *Rho* yang semakin kecil, juga tidak menjadikan nilai MSE semakin besar, sehingga dapat dikatakan bahwa besar kecilnya nilai *Rho* tidak menentukan nilai MSE yang semakin besar atau semakin kecil. Nilai MSE yang kecil didapatkan dari kombinasi nilai *Rho* yang optimal.

6.5. Hasil Akhir Uji Coba Seluruh Parameter pada Model DNN

Setelah dilakukan pengujian model DNN dengan mencari jumlah *hidden layer*, neuron, dan epochs serta nilai *epsilon*

dan Rho yang terbaik, maka didapatkan hasil akhir berupa nilai terbaik dari lima parameter tersebut, yaitu dapat dilihat pada Tabel 6.10:

Tabel 6. 10 Nilai Parameter dalam Model Terbaik

| Parameter | Nilai Terbaik |
|---------------------|----------------------|
| <i>Hidden Layer</i> | 3 |
| Neuron | 100, 200, 300 |
| <i>Epochs</i> | 2500 |
| <i>Epsilon</i> | 1×10^{-10} |
| <i>Rho</i> | 0.99 |

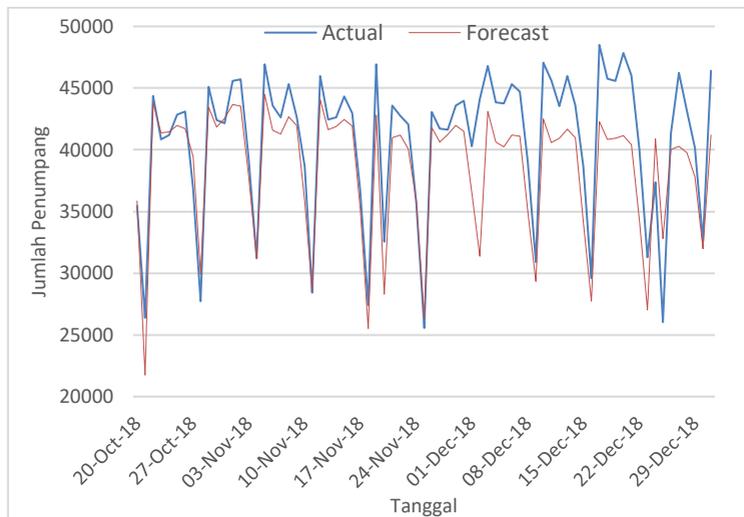
Selanjutnya, model ini akan digunakan untuk diujikan pada data jumlah penumpang di seluruh stasiun tujuan untuk dilihat akurasi peramalan berupa MAPE dan MSE, serta grafik *forecast* yang dihasilkan.

6.6. Hasil Pengujian Model DNN untuk Data Jumlah di Setiap Stasiun Tujuan dengan Pola Data Seasonal

Dengan menggunakan model DNN terbaik yang didapatkan dari hasil akhir pembentukan model DNN pada Sub Bab 6.5 menggunakan data *input* dari data jumlah penumpang Stasiun Tanah Abang, dilakukan pengujian kepada seluruh data jumlah penumpang di setiap stasiun yang memiliki pola data seasonal yang merupakan pola data dari Stasiun Tanah Abang itu sendiri, untuk diketahui akurasi dari parameter dalam model yang dihasilkan.

6.6.1. Pengujian pada Data Jumlah Penumpang di Stasiun Tanah Abang

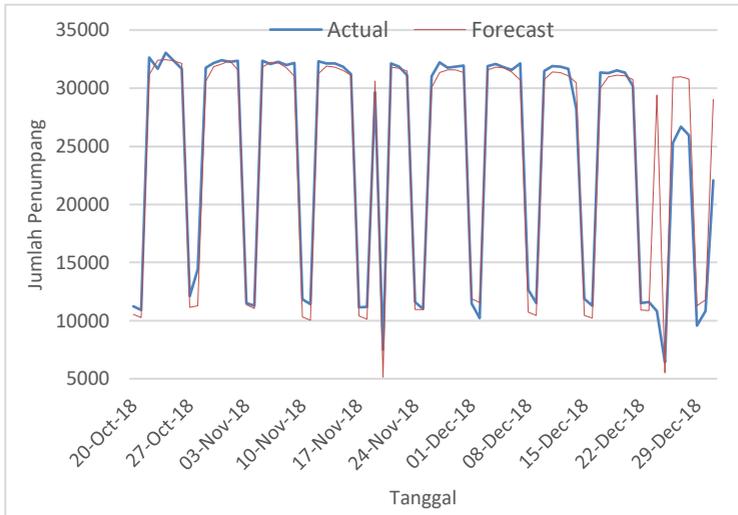
Berikut adalah hasil pengujian model DNN terbaik pada Stasiun Tanah Abang yang dapat dilihat pada Gambar 6.1. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 2,492,148.16 dan 1.913%. Karena nilai MAPE $< 10\%$, maka berarti model peramalan ini dapat digunakan untuk peramalan di masa mendatang untuk Stasiun Tanah Abang.



Gambar 6. 1 Grafik Hasil Pengujian Stasiun Tanah Abang

6.6.2. Pengujian pada Data Jumlah Penumpang di Stasiun Sudirman

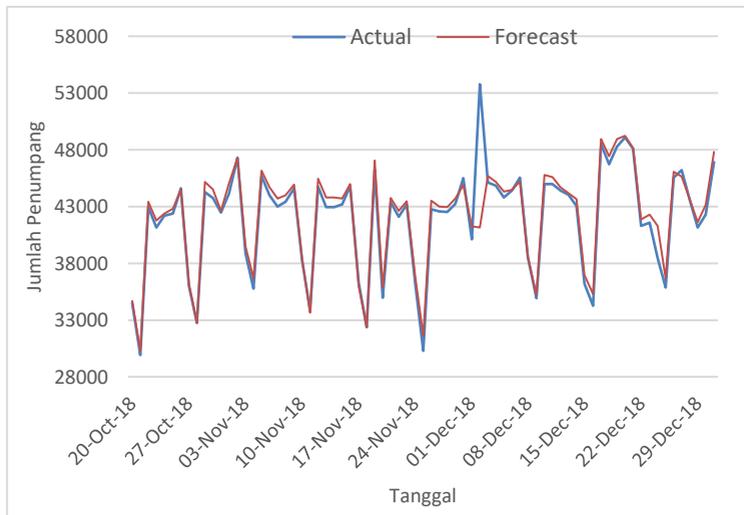
Pada Gambar 6.2 dapat dilihat hasil pengujian model DNN untuk Stasiun Sudirman. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 17,032,550.51 dan 13.426%. Dari hasil MAPE ini menunjukkan bahwa nilai $MAPE > 10\%$ sehingga akan dilakukan pencarian model baru nantinya untuk stasiun dengan MAPE 10% sebelum dilakukan peramalan masa depan untuk Stasiun Sudirman.



Gambar 6. 2 Grafik Hasil Pengujian Stasiun Sudirman

6.6.3. Pengujian pada Data Jumlah Penumpang di Stasiun Bekasi

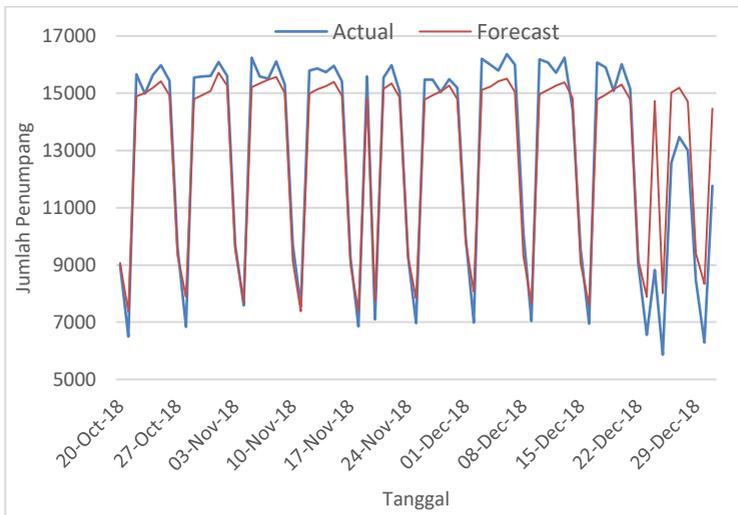
Selanjutnya adalah hasil pengujian model DNN terbaik pada Stasiun Bekasi yang dapat dilihat pada Gambar 6.3. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 2,967,760.08 dan 2.135%. Hasil MAPE di atas berarti nilai $MAPE < 10\%$ yang berarti model dapat digunakan untuk melakukan peramalan pada masa mendatang untuk Stasiun Bekasi.



Gambar 6. 3 Grafik Hasil Pengujian Stasiun Bekasi

6.6.4. Pengujian pada Data Jumlah Penumpang di Stasiun Karet

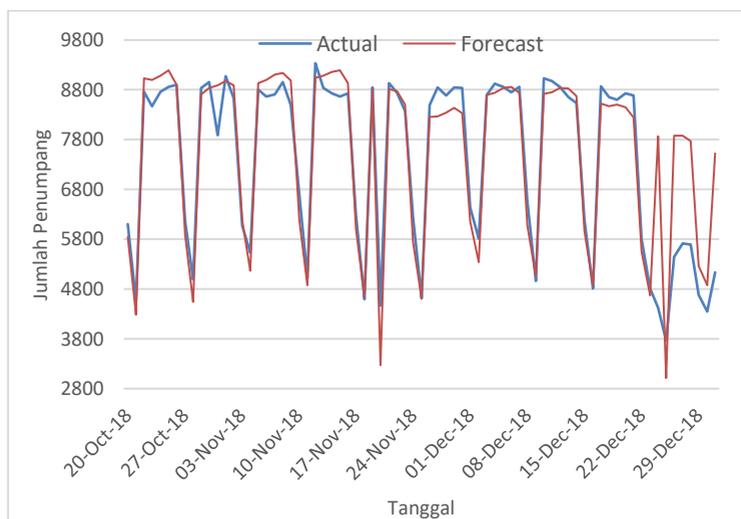
Kemudian, untuk pengujian model DNN terbaik pada Stasiun Karet yang dapat dilihat pada Gambar 6.4. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 2,846,623.75 dan 10.044%. Ini menunjukkan bahwa nilai $MAPE > 10\%$, yang berarti model tidak dapat digunakan untuk melakukan peramalan masa mendatang untuk Stasiun Karet, sehingga perlu dilakukan pencarian model kembali untuk stasiun dengan $MAPE > 10\%$.



Gambar 6. 4 Grafik Hasil Pengujian Stasiun Karet

6.6.5. Pengujian pada Data Jumlah Penumpang di Stasiun Univ. Pancasila

Lalu, untuk hasil pengujian pada Stasiun Univ. Pancasila yang dapat dilihat pada Gambar 6.5 menunjukkan bahwa nilai MSE dan MAPE yang di dapatkan secara berurutan yaitu 1,066,262.43 dan 12.209%. Karena nilai MAPE > 10%, maka akan dilakukan pencarian model untuk stasiun dengan MAPE > 10% untuk dilakukan pencarian model kembali sebelum diramalkan untuk masa mendatang pada Stasiun Univ. Pancasila.



Gambar 6. 5 Grafik Hasil Pengujian Stasiun Univ. Pancasila

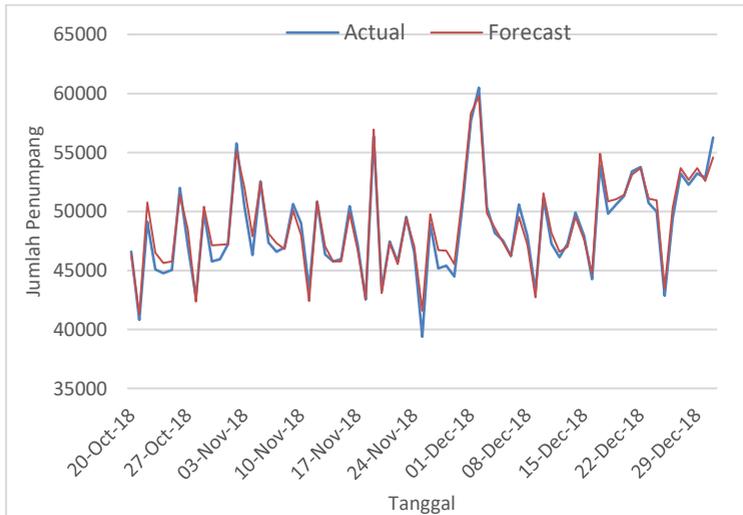
Untuk pengujian model DNN terbaik pada stasiun lainnya yang termasuk kelompok pola data seasonal, dapat dilihat dalam Lampiran C.

6.7. Hasil Pengujian Model DNN untuk Data Jumlah di Setiap Stasiun Tujuan dengan Pola Data Stasioner

Untuk model terbaik untuk Pola Data Stasioner dicoba terlebih dahulu dengan menggunakan model terbaik yang didapatkan dari Pola Data Seasonal untuk dilihat apakah akurasi peramalan yang dihasilkan, dalam hal ini yaitu MAPE, memiliki nilai dibawah 10%. Jika akurasi peramalan yang dihasilkan memiliki MAPE di atas 10%, maka model ini berarti dapat diterapkan dalam pola data stasioner untuk dilakukan peramalan di masa mendatang. Berikut adalah hasil pengujian .untuk pola data Stasioner.

6.7.1 Pengujian pada Data Jumlah Penumpang di Stasiun Bogor

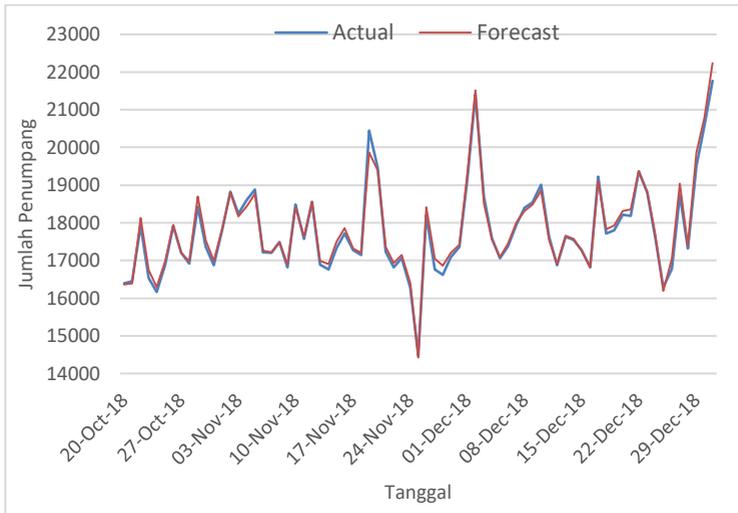
Berikut adalah hasil pengujian pada Stasiun Bogor yang dapat dilihat pada Gambar 6.6. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 8,276,087.09 dan 3.291%.



Gambar 6. 6 Grafik Hasil Pengujian Stasiun Bogor

6.7.2 Pengujian pada Data Jumlah Penumpang di Stasiun Tangerang

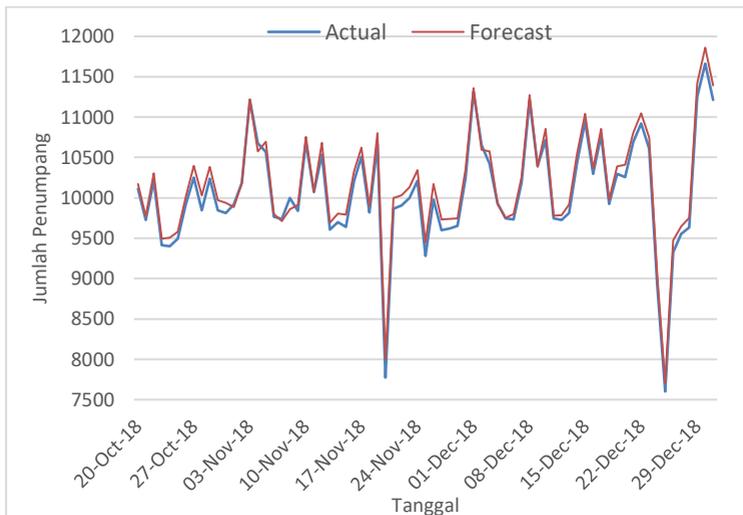
Berikut adalah hasil pengujian pada Stasiun Tangerang yang dapat dilihat pada Gambar 6.7. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 62,340.58 dan 0.970%.



Gambar 6. 7 Grafik Hasil Pengujian Stasiun Tangerang

6.7.3 Pengujian pada Data Jumlah Penumpang di Stasiun Duri

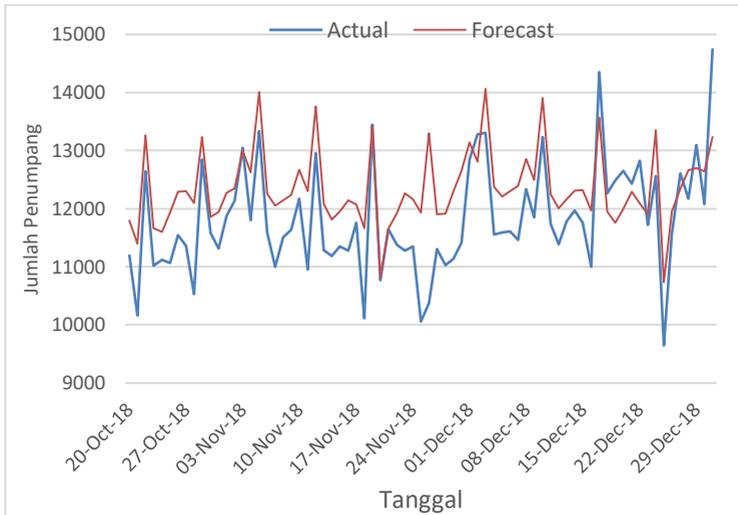
Berikut adalah hasil pengujian pada Stasiun Duri yang dapat dilihat pada Gambar 6.8. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 24,855.04 dan 1.219%.



Gambar 6. 8 Grafik Hasil Pengujian Stasiun Duri

6.7.4 Pengujian pada Data Jumlah Penumpang di Stasiun Parung Panjang

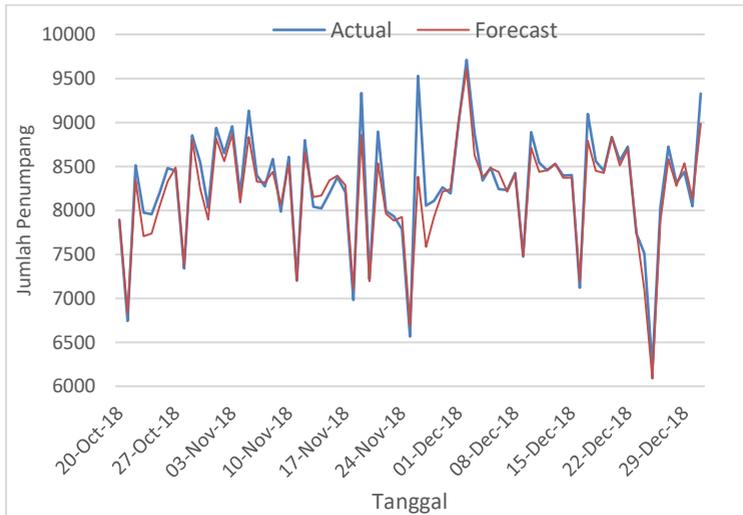
Berikut adalah hasil pengujian pada Stasiun Parung Panjang yang dapat dilihat pada Gambar 6.9. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 1,367,223.27 dan 7.047%.



Gambar 6. 9 Grafik Hasil Pengujian Stasiun Parung Panjang

6.7.5 Pengujian pada Data Jumlah Penumpang di Stasiun Serpong

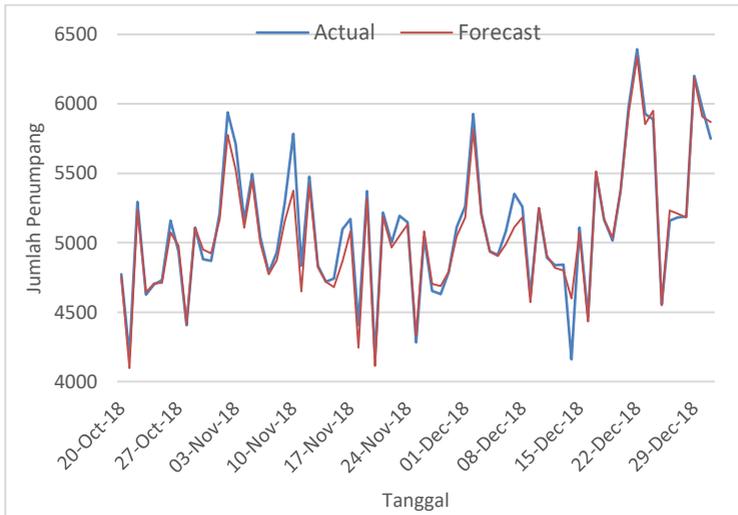
Berikut adalah hasil pengujian pada Stasiun Serpong yang dapat dilihat pada Gambar 6.10. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 24,572.23 dan 1.257%.



Gambar 6. 10 Grafik Hasil Pengujian Stasiun Serpong

6.7.6 Pengujian pada Data Jumlah Penumpang di Stasiun Kemayoran

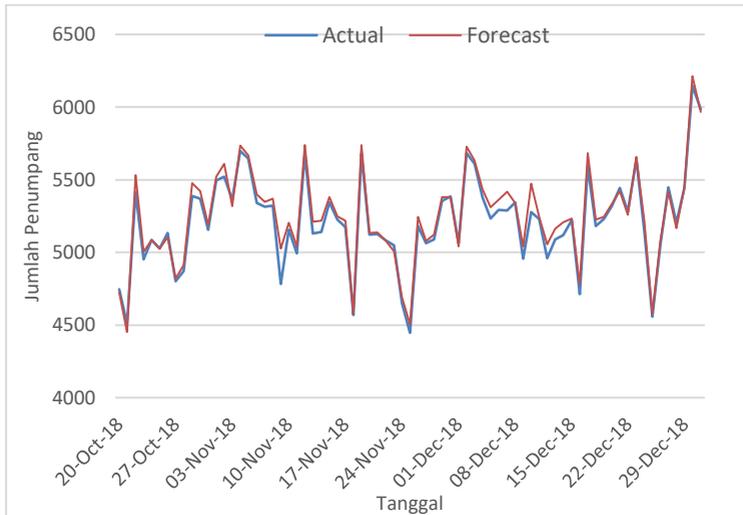
Berikut adalah hasil pengujian pada Stasiun Kemayoran yang dapat dilihat pada Gambar 6.11. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 32,042.37 dan 1.913%.



Gambar 6. 11 Grafik Hasil Pengujian Stasiun Kemayoran

6.7.7 Pengujian pada Data Jumlah Penumpang di Stasiun Kali Deres

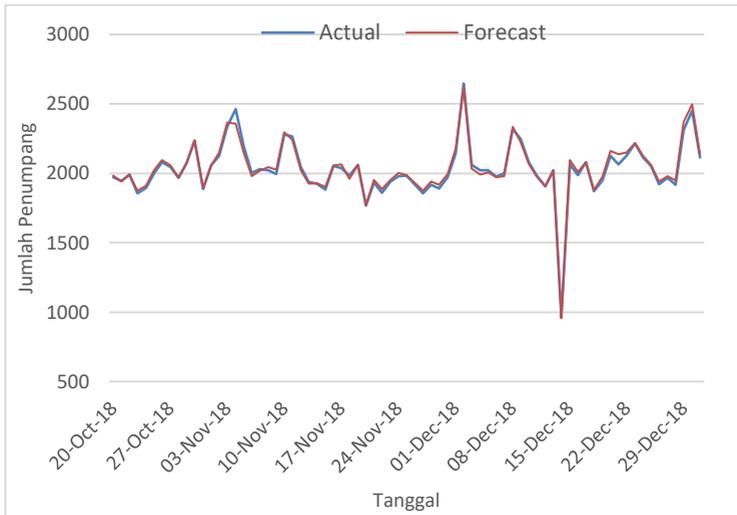
Berikut adalah hasil pengujian pada Stasiun Kali Deres yang dapat dilihat pada Gambar 6.56. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 3,843.13 dan 0.476%.



Gambar 6. 12 Grafik Hasil Pengujian Stasiun Kali Deres

6.7.8 Pengujian pada Data Jumlah Penumpang di Stasiun Gang Sentiong

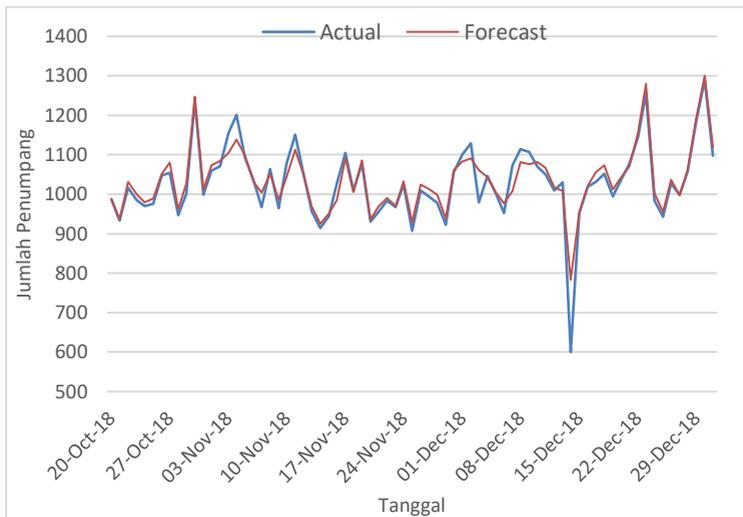
Berikut adalah hasil pengujian pada Stasiun Gang Sentiong yang dapat dilihat pada Gambar 6.57. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 1,209.62 dan 1.766%.



Gambar 6. 13 Grafik Hasil Pengujian Stasiun Gang Sentiong

6.7.9 Pengujian pada Data Jumlah Penumpang di Stasiun Pondok Jati

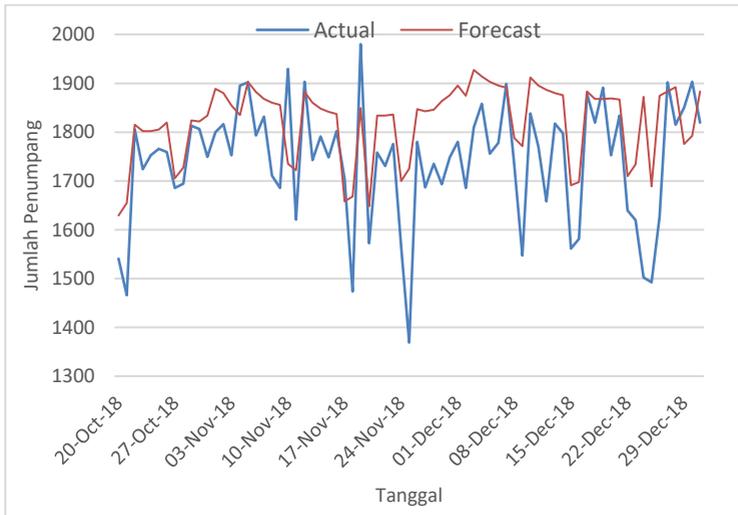
Berikut adalah hasil pengujian pada Stasiun Pondok Jati yang dapat dilihat pada Gambar 6.58. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 642.737 dan 1.159%.



Gambar 6. 14 Grafik Hasil Pengujian Stasiun Pondok Jati

6.7.10 Pengujian pada Data Jumlah Penumpang di Stasiun Bojong Indah

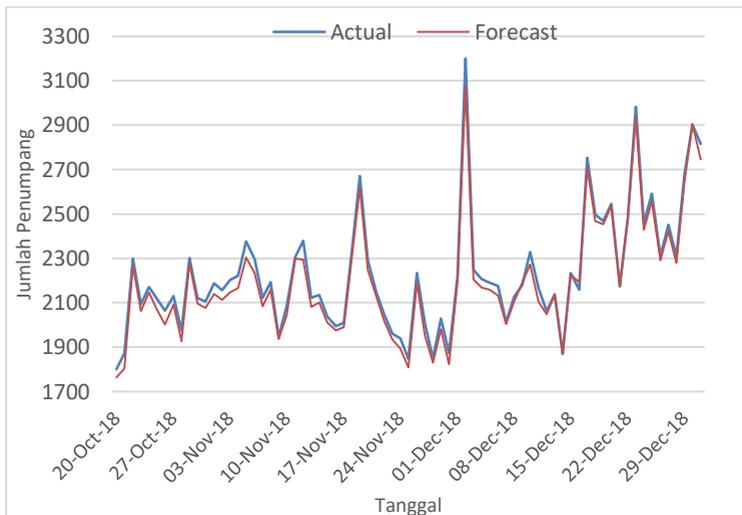
Berikut adalah hasil pengujian pada Stasiun Bojong Indah yang dapat dilihat pada Gambar 6.59. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 26,557.96 dan 4.463%.



Gambar 6. 15 Grafik Hasil Pengujian Stasiun Bojong Indah

6.7.11 Pengujian pada Data Jumlah Penumpang di Stasiun Cibinong

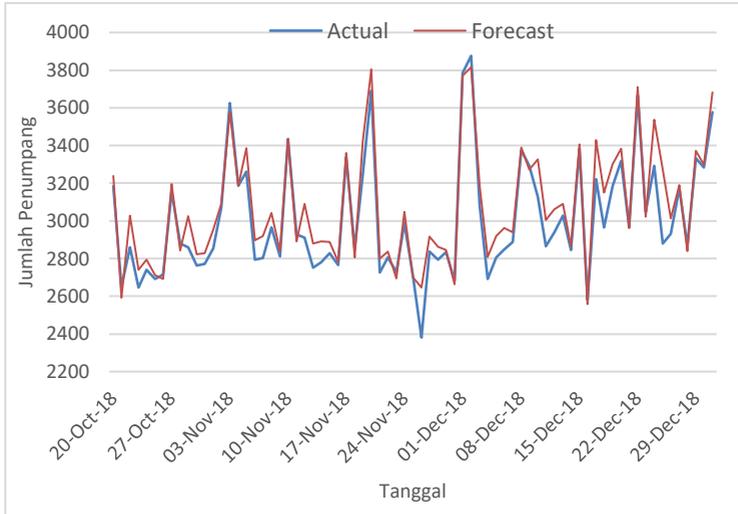
Berikut adalah hasil pengujian pada Stasiun Cibinong yang dapat dilihat pada Gambar 6.60. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 2,489.73 dan 1.730%.



Gambar 6. 16 Grafik Hasil Pengujian Stasiun Cibinong

6.7.12 Pengujian pada Data Jumlah Penumpang di Stasiun Daru

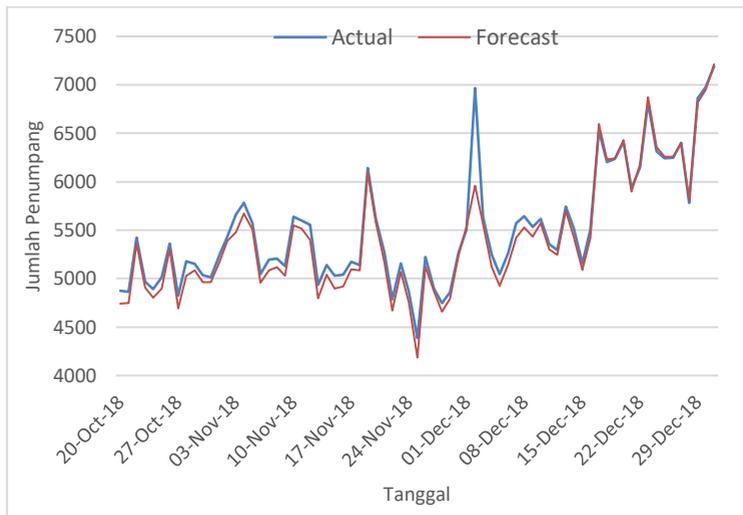
Berikut adalah hasil pengujian pada Stasiun Daru yang dapat dilihat pada Gambar 6.61. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 7,259.39 dan 1.534%.



Gambar 6. 17 Grafik Hasil Pengujian Stasiun Daru

6.7.13 Pengujian pada Data Jumlah Penumpang di Stasiun Tambun

Berikut adalah hasil pengujian pada Stasiun Tambun yang dapat dilihat pada Gambar 6.62. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 30,187.53 dan 0.458%.



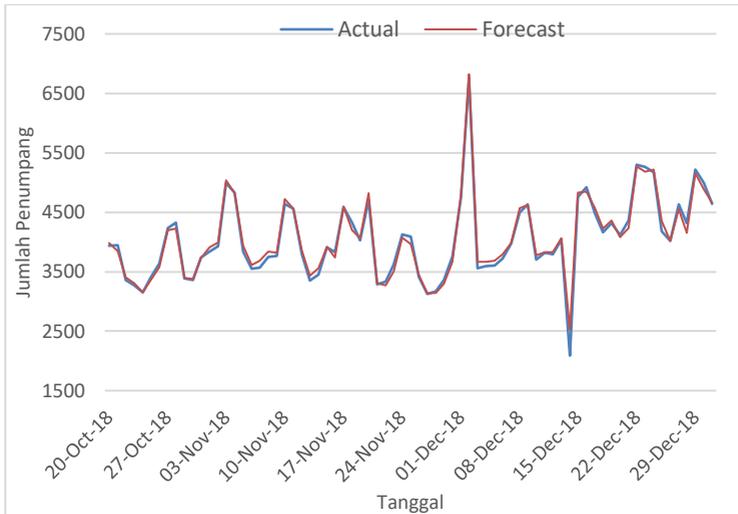
Gambar 6. 18 Grafik Hasil Pengujian Stasiun Tambun

6.8. Hasil Pengujian Model DNN untuk Data Jumlah di Setiap Stasiun Tujuan dengan Pola Data Seasonal Sisir Terbalik

Selanjutnya, model DNN terbaik yang didapatkan dari hasil akhir pembentukan model DNN pada Sub Bab 6.5, dilakukan pengujian kepada data jumlah penumpang di setiap stasiun yang memiliki pola data seasonal sisir terbalik, untuk diketahui akurasi dari parameter yang digunakan.

6.8.1 Pengujian pada Data Jumlah Penumpang di Stasiun Pasar Senen

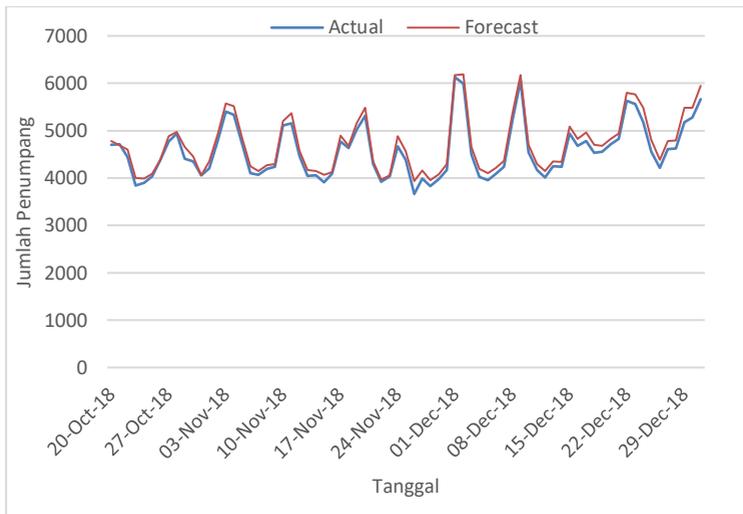
Berikut adalah hasil pengujian pada Stasiun Pasar Senen yang dapat dilihat pada Gambar 6.63. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 7,081.908 dan 1.598%.



Gambar 6. 19 Grafik Hasil Pengujian Pasar Senen

6.8.2 Pengujian pada Data Jumlah Penumpang di Stasiun Tiga Raksa

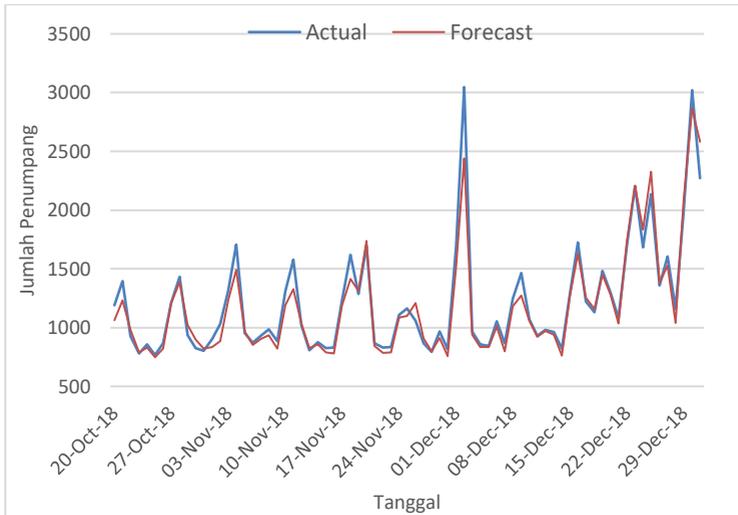
Berikut adalah hasil pengujian pada Stasiun Tiga Raksa yang dapat dilihat pada Gambar 6.64. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 18,477.60 dan 2.039%.



Gambar 6. 20 Grafik Hasil Pengujian Stasiun Tiga Raksa

6.8.3 Pengujian pada Data Jumlah Penumpang di Stasiun Nambo

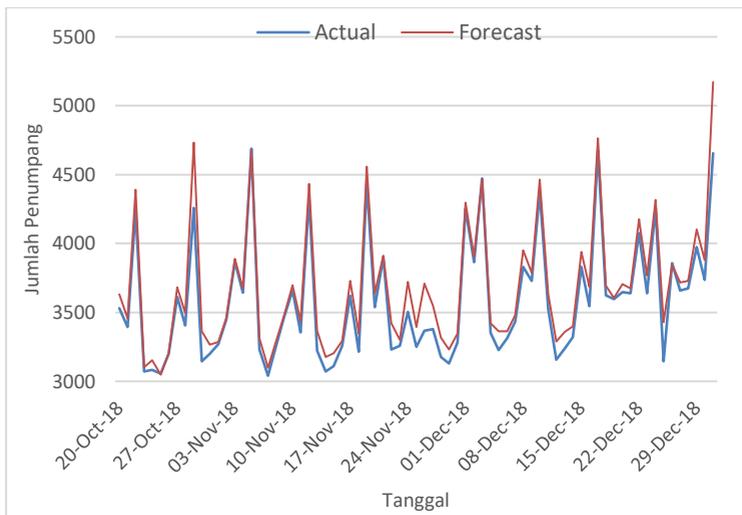
Berikut adalah hasil pengujian pada Stasiun Nambo yang dapat dilihat pada Gambar 6.65. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 29,690.15 dan 6.946%.



Gambar 6. 21 Grafik Hasil Pengujian Stasiun Nambo

6.8.4 Pengujian pada Data Jumlah Penumpang di Stasiun Tenjo

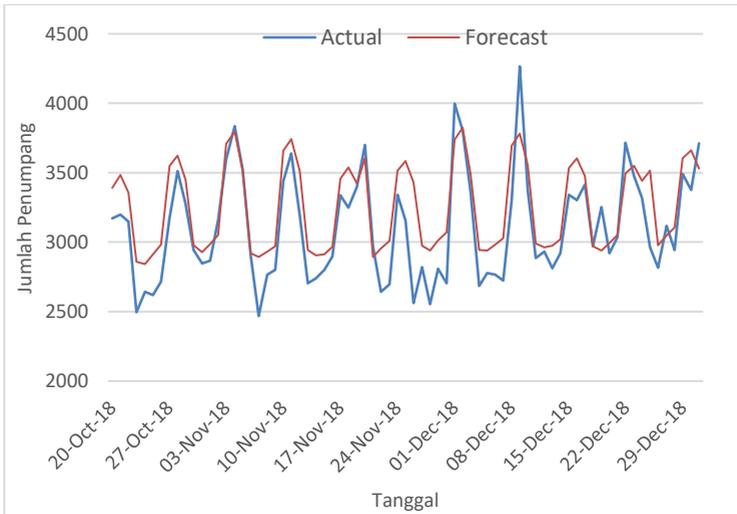
Berikut adalah hasil pengujian pada Stasiun Tenjo yang dapat dilihat pada Gambar 6.66. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 15,082.97 dan 2.177%.



Gambar 6. 22 Grafik Hasil Pengujian Stasiun Tenjo

6.8.5 Pengujian pada Data Jumlah Penumpang di Stasiun Maja

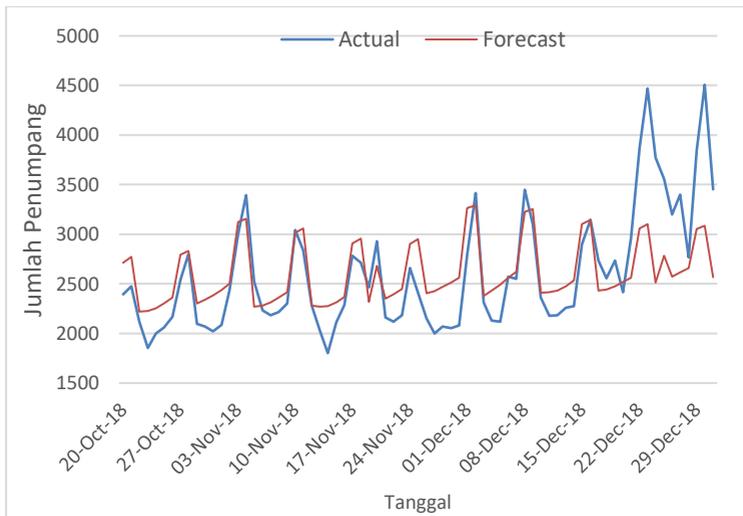
Berikut adalah hasil pengujian pada Stasiun Maja yang dapat dilihat pada Gambar 6.67. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 146,048.36 dan 8.506%.



Gambar 6. 23 Grafik Hasil Pengujian Stasiun Maja

6.8.6 Pengujian pada Data Jumlah Penumpang di Stasiun Tanjung Priok

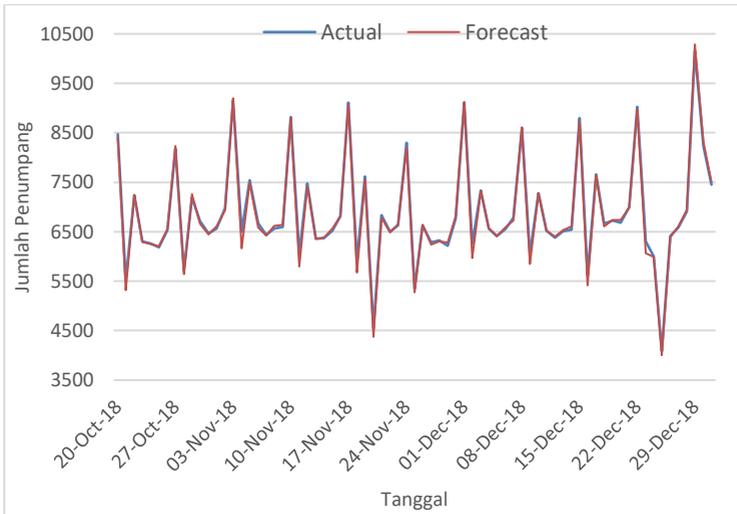
Berikut adalah hasil pengujian pada Stasiun Tanjung Priok yang dapat dilihat pada Gambar 6.68. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 145,269.50 dan 13.680%.



Gambar 6. 24 Grafik Hasil Pengujian Tanjung Stasiun Priok

6.8.7 Pengujian pada Data Jumlah Penumpang di Stasiun Angke

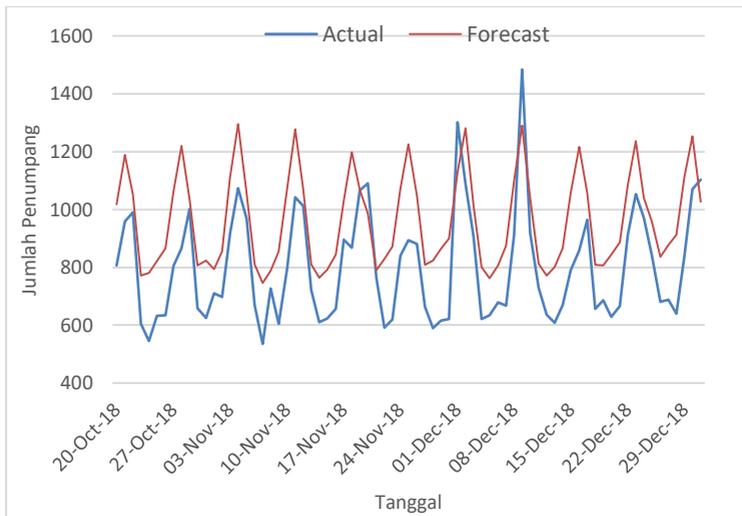
Berikut adalah hasil pengujian pada Stasiun Angke yang dapat dilihat pada Gambar 6.69. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 48,053.01 dan 1.786%.



Gambar 6. 25 Grafik Hasil Pengujian Stasiun Angke

6.8.8 Pengujian pada Data Jumlah Penumpang di Stasiun Citeras

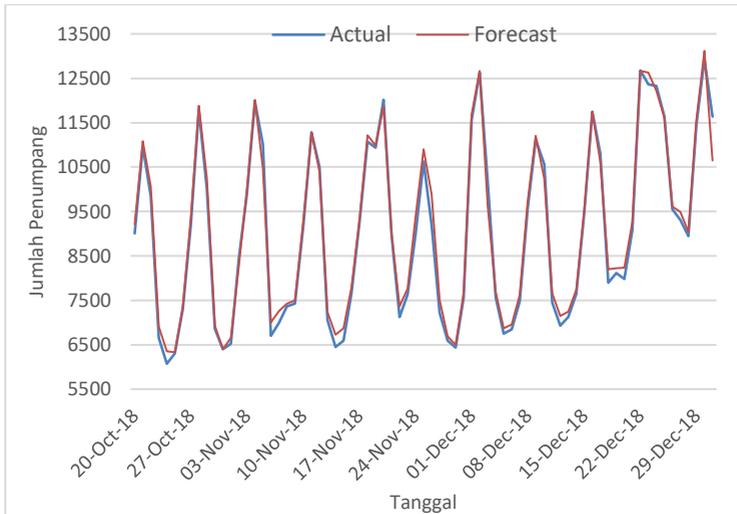
Berikut adalah hasil pengujian pada Stasiun Citeras yang dapat dilihat pada Gambar 6.70. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 25,941.50 dan 16.903%.



Gambar 6. 26 Grafik Hasil Pengujian Stasiun Citeras

6.8.9 Pengujian pada Data Jumlah Penumpang di Stasiun Rangkas Bitung

Berikut adalah hasil pengujian pada Stasiun Rangkas Bitung yang dapat dilihat pada Gambar 6.71. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 156,095.75 dan 2.893%.



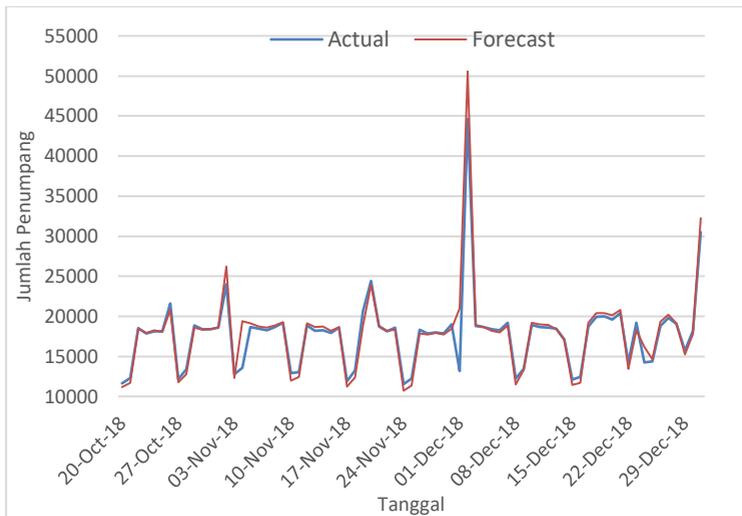
Gambar 6. 27 Grafik Hasil Pengujian Rangkas Stasiun Bitung

6.9. Hasil Pengujian Model DNN untuk Data Jumlah di Setiap Stasiun Tujuan dengan Pola Data Seasonal dengan Nilai Ekstrem

Kemudian, model DNN terbaik yang didapatkan dari hasil akhir pembentukan model DNN pada Sub Bab 6.5, dilakukan pengujian kepada data jumlah penumpang di setiap stasiun yang memiliki pola data seasonal dengan nilai ekstrem, untuk diketahui akurasi dari parameter yang digunakan.

6.9.1 Pengujian pada Data Jumlah Penumpang di Stasiun Juanda

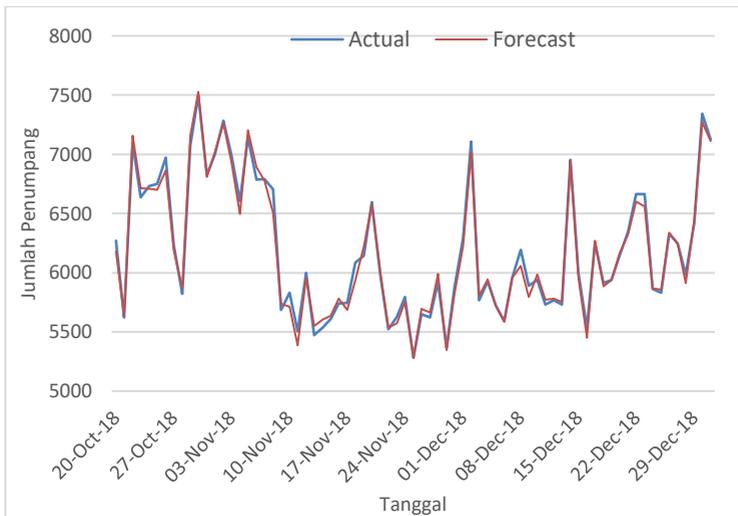
Berikut adalah hasil pengujian pada Stasiun Juanda yang dapat dilihat pada Gambar 6.72. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 2,047,928.02 dan 3.449%.



Gambar 6. 28 Grafik Hasil Pengujian Stasiun Juanda

6.9.2 Pengujian pada Data Jumlah Penumpang di Stasiun Buaran

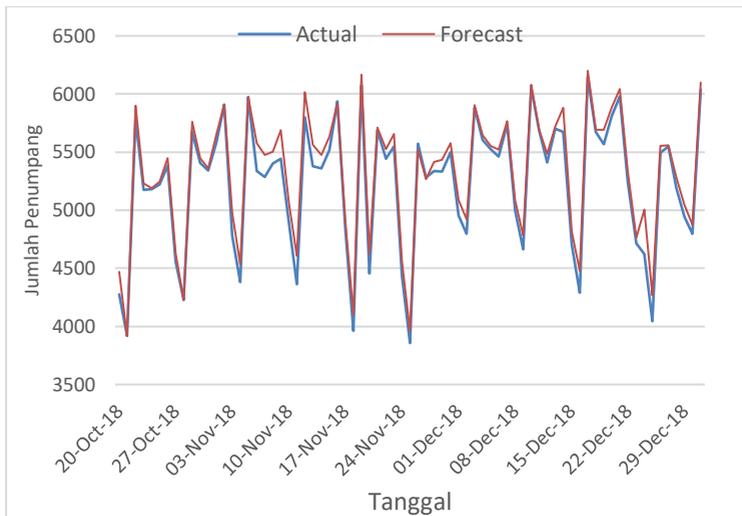
Berikut adalah hasil pengujian pada Stasiun Buaran yang dapat dilihat pada Gambar 6.73. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 9,907.26 dan 1.071%.



Gambar 6. 29 Grafik Hasil Pengujian Stasiun Buaran

6.9.3 Pengujian pada Data Jumlah Penumpang di Stasiun Tanah Tinggi

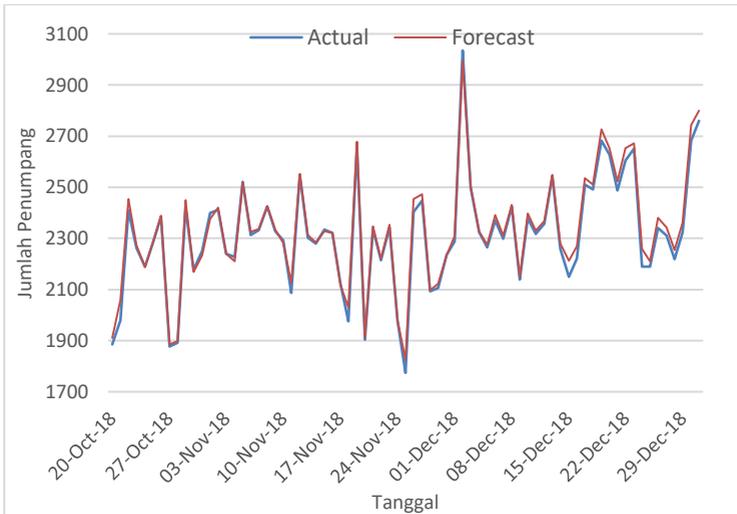
Berikut adalah hasil pengujian pada Stasiun Tanah Tinggi yang dapat dilihat pada Gambar 6.74. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 21,264.75 dan 2.774%.



Gambar 6. 30 Grafik Hasil Pengujian Stasiun Tanah Tinggi

6.9.4 Pengujian pada Data Jumlah Penumpang di Stasiun Bekasi Timur

Berikut adalah hasil pengujian pada Stasiun Bekasi Timur yang dapat dilihat pada Gambar 6.75. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 7,091.22 dan 2.119%.



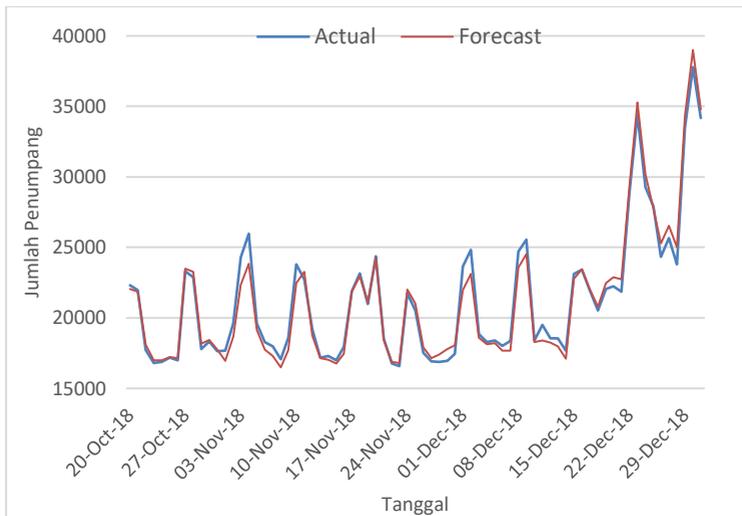
Gambar 6. 31 Grafik Hasil Pengujian Stasiun Bekasi Timur

6.10. Hasil Pengujian Model DNN untuk Data Jumlah di Setiap Stasiun Tujuan dengan Pola Data Seasonal Sisir Terbalik dengan Nilai Ekstrem

Kemudian, model DNN terbaik yang didapatkan dari hasil akhir pembentukan model DNN pada Sub Bab 6.5, dilakukan pengujian kepada data jumlah penumpang di setiap stasiun yang memiliki pola data seasonal sisir terbalik dengan nilai ekstrem, untuk diketahui akurasi dari parameter yang digunakan.

6.10.1 Pengujian pada Data Jumlah Penumpang di Stasiun Jakarta Kota

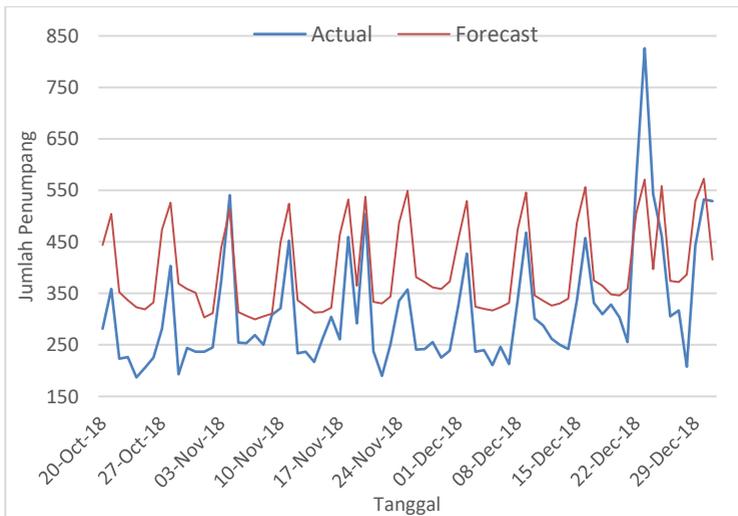
Berikut adalah hasil pengujian pada Stasiun Jakarta Kota yang dapat dilihat pada Gambar 6.76. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 327,889.31 dan 1.767%.



Gambar 6. 32 Grafik Hasil Pengujian Stasiun Jakarta Kota

6.10.2 Pengujian pada Data Jumlah Penumpang di Stasiun Ancol

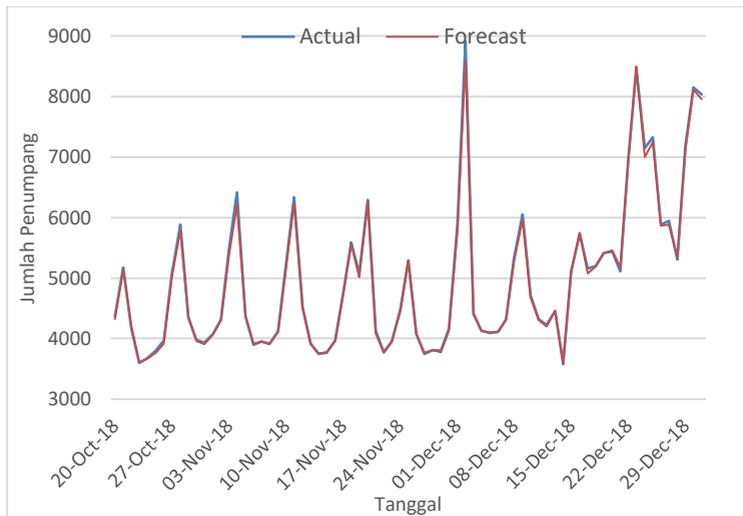
Berikut adalah hasil pengujian pada Stasiun Ancol yang dapat dilihat pada Gambar 6.77. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 52,819.30 dan 33.182%.



Gambar 6. 33 Grafik Hasil Pengujian Stasiun Ancol

6.10.3 Pengujian pada Data Jumlah Penumpang di Stasiun Cibitung

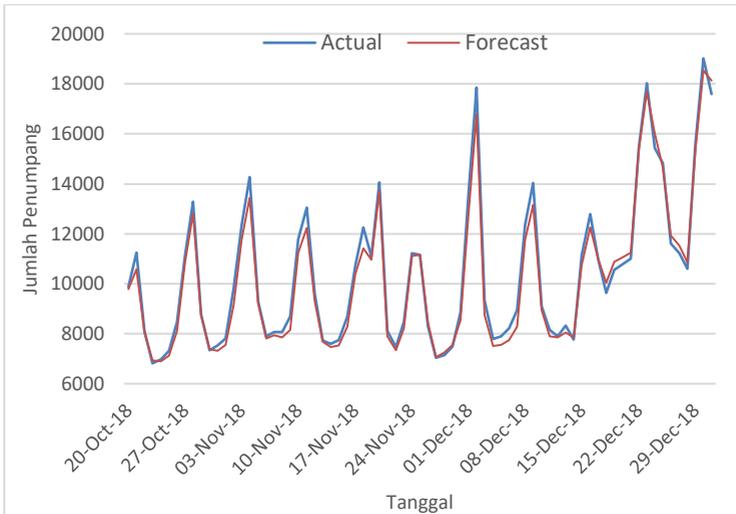
Berikut adalah hasil pengujian pada Stasiun Cibitung yang dapat dilihat pada Gambar 6.78. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 18,702.10 dan 1.983%.



Gambar 6. 34 Grafik Hasil Pengujian Stasiun Cibitung

6.10.4 Pengujian pada Data Jumlah Penumpang di Stasiun Cikarang

Berikut adalah hasil pengujian pada Stasiun Cikarang yang dapat dilihat pada Gambar 6.79. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 453,144.50 dan 4.695%.



Gambar 6. 35 Grafik Hasil Pengujian Stasiun Cikarang

6.11. Analisis Terhadap Hasil Pengujian Model DNN untuk Data Jumlah Penumpang di Setiap Stasiun Tujuan

Setelah melihat hasil pengujian model DNN terbaik yang didapatkan dan dijelaskan sebelumnya pada Sub Bab 6.1 – 6.5, maka dapat dilihat bahwa beberapa hasil pengujian memiliki $MAPE > 10\%$ dan beberapa memiliki $MAPE < 10\%$ namun grafik *forecast* tidak mengikuti pola data aktual. Untuk kelompok pola data seasonal, empat stasiun memiliki MAPE di atas 10% yaitu, Stasiun Sudirman dengan MAPE 13.426%,

Stasiun Karet dengan MAPE 10.044%, dan Stasiun Univ. Pancasila dengan MAPE 12.209%. Kemudian, untuk kelompok pola data stasioner, terdapat dua data stasiun yang memiliki pola grafik *forecast* yang tidak mengikuti pola data aktual, yaitu; Stasiun Parung Panjang dan Stasiun Bojong Indah. Lalu, untuk pola data seasonal sisir terbalik, terdapat dua data stasiun yang memiliki MAPE di atas 10% yaitu; Stasiun Tanjung Priok dengan 13.680% dan Stasiun Citeras dengan 16.903%. Selanjutnya, pada kelompok pola data seasonal dengan nilai ekstrem, seluruh pola data memiliki MAPE di bawah 10% dan pola grafik *forecast* yang mengikuti pola grafik data aktual sehingga tidak terdapat permasalahan. Namun, untuk kelompok seasonal sisir terbalik dengan nilai ekstrem, terdapat satu stasiun yang memiliki MAPE di atas 10% dan pola grafik *forecast* yang tidak mengikuti pola grafik data aktual yaitu Stasiun Ancol dengan MAPE 33.182%.

Hasil tersebut juga dapat dilihat dalam tabel di bawah ini, yaitu Tabel 6.11.

Tabel 6. 11 Hasil Analisa Pengujian Model DNN Terhadap Data Jumlah Penumpang di Setiap Stasiun Tujuan

| No | Nama Stasiun | MAPE > 10% | Pola Grafik <i>Forecast</i> Tidak Mengikuti Pola Data Aktual |
|----|-----------------|------------|---|
| 1 | Sudirman | √ | - |
| 2 | Karet | √ | - |
| 3 | Univ. Pancasila | √ | - |
| 4 | Parung Panjang | - | √ |
| 5 | Bojong Indah | - | √ |
| 6 | Tanjung Priok | √ | - |
| 7 | Citeras | √ | - |
| 8 | Ancol | √ | √ |

Selanjutnya, data jumlah penumpang di setiap stasiun yang terdapat dalam Tabel 6.11, dikelompokkan dalam satu kelompok yaitu Kelompok Data Jumlah Penumpang di Setiap Stasiun Khusus MAPE > 10% untuk kemudian dilakukan pencarian model DNN terbaik yang baru dan dapat memberikan nilai MAPE < 10% dan pola grafik *forecast* yang mengikuti pola grafik data aktual untuk Kelompok Data

Jumlah Penumpang di Setiap Stasiun Khusus MAPE > 10% ini.

6.12. Hasil Uji Nilai Parameter *Epsilon* Baru pada Model DNN untuk Kelompok Data Jumlah Penumpang di Setiap Stasiun Khusus MAPE > 10%

Untuk mendapatkan model DNN terbaik untuk Kelompok Data Jumlah Penumpang di Setiap Stasiun Khusus MAPE > 10%, dilakukan perubahan nilai pada salah satu atau beberapa parameter model DNN yang kemudian dilihat apakah hasil pengujian model DNN dapat memberikan nilai MAPE < 10% serta pola grafik *forecast* yang dapat mengikuti pola grafik pola data aktual. Perubahan nilai parameter dilakukan kepada parameter *epsilon* dengan mengubah nilai *epsilon* terbaik pada model DNN terbaik yaitu dari 1×10^{-10} , diperbesar menjadi 1×10^{-8} . Nilai 1×10^{-8} dipilih karena nilai ini pada pengujian *epsilon* yang dilakukan pada Sub Bab 6.3 dalam Tabel 6.8, merupakan nilai dengan MSE terendah kedua setelah 1×10^{-10} dengan nilai 224,766.02.

Kemudian, nilai epsilon yang baru ini diujikan kepada Stasiun Ancol untuk diketahui apakah nilai epsilon yang baru dapat memberikan nilai MSE yang lebih kecil ketimbang nilai epsilon yang lama. Stasiun Ancol dipilih sebagai stasiun perwakilan Kelompok Data Jumlah Penumpang di Setiap Stasiun Khusus MAPE > 10% karena nilai MAPE yang dimiliki Stasiun Ancol paling tinggi ketimbang stasiun lainnya dalam kelompok tersebut dan pola grafik *forecast* Stasiun Ancol tidak mengikuti grafik pola data aktual, sehingga jika dengan model baru yang dihasilkan Stasiun Ancol ini dapat menurunkan nilai MAPE menjadi di bawah 10%, maka diharapkan stasiun lain dapat memiliki MAPE di bawah 10% dan pola grafik *forecast* yang mengikuti pola grafik data aktual pada setiap stasiun.

Adapun skenario yang baru ini, hanya memiliki perbedaan pada nilai epsilon. Sedangkan parameter lainnya memiliki nilai yang sama dengan skenario terbaik pada pengujian sebelumnya yaitu *hidden layer* tiga dengan neuron 100, 200, dan 300, *epochs* senilai 2500 dan *rho* senilai 0.99. Berikut pada Tabel 6.12, ditampilkan hasil MSE antara skenario terbaik yang sebelumnya dengan skenario baru.

Tabel 6. 12 Nilai MSE untuk Skenario 85 dan 86

| Skenario | Epochs | <i>Epsilon</i> | <i>Rho</i> | MSE |
|----------|--------|---------------------|------------|------------|
| 85 | 2500 | 1×10^{-10} | 0.99 | 52,819.301 |
| 86 | 2500 | 1×10^{-8} | 0.99 | 1,022.938 |

Pada Tabel 6.12 dapat dilihat bahwa Skenario 86 yang merupakan skenario baru dengan nilai epsilon yang baru, memiliki nilai MSE yang lebih kecil ketimbang skenario terbaik sebelumnya. Maka berarti, model terbaik yang digunakan untuk pengujian pada Kelompok Data Jumlah Penumpang di Setiap Stasiun Khusus MAPE > 10% yaitu terdapat pada Tabel 6.13.

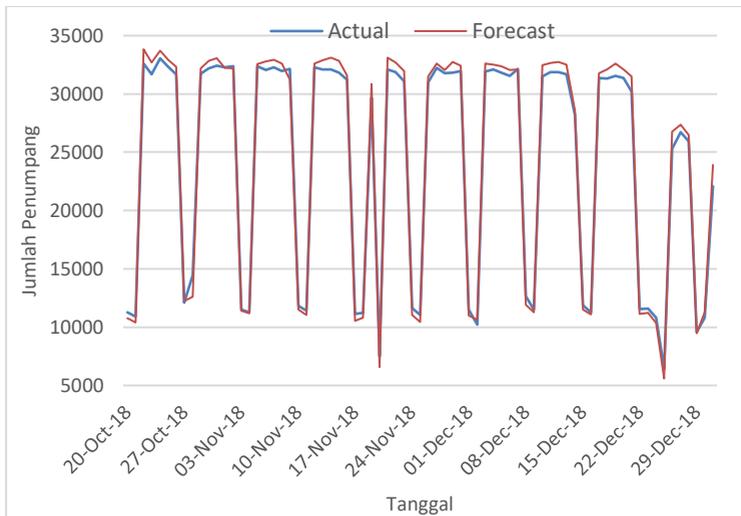
Tabel 6. 13 Nilai Parameter Terbaik dalam Model Terbaik untuk Kelompok Stasiun Khusus dengan MAPE > 10%

| Parameter | Nilai Terbaik |
|---------------------|--------------------|
| <i>Hidden Layer</i> | 3 |
| Neuron | 100, 200, 300 |
| <i>Epochs</i> | 2500 |
| <i>Epsilon</i> | 1×10^{-8} |
| <i>Rho</i> | 0.99 |

Selanjutnya model terbaik ini, akan diujikan kepada seluruh stasiun yang terdapat pada Kelompok Data Jumlah Penumpang di Setiap Stasiun Khusus MAPE > 10% untuk dilihat akurasi peramalan yang dihasilkan pada tiap stasiun.

6.12.1. Pengujian pada Data Jumlah Penumpang di Stasiun Sudirman

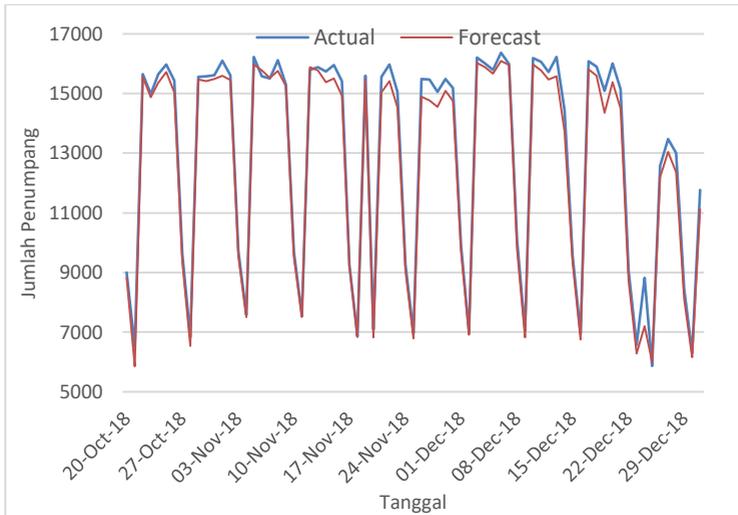
Berikut adalah hasil pengujian pada Stasiun Sudirman yang dapat dilihat pada Gambar 6.80. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 350,633.727 dan 2.292%.



Gambar 6. 36 Grafik Hasil Pengujian Stasiun Sudirman

6.12.2. Pengujian pada Data Jumlah Penumpang di Stasiun Karet

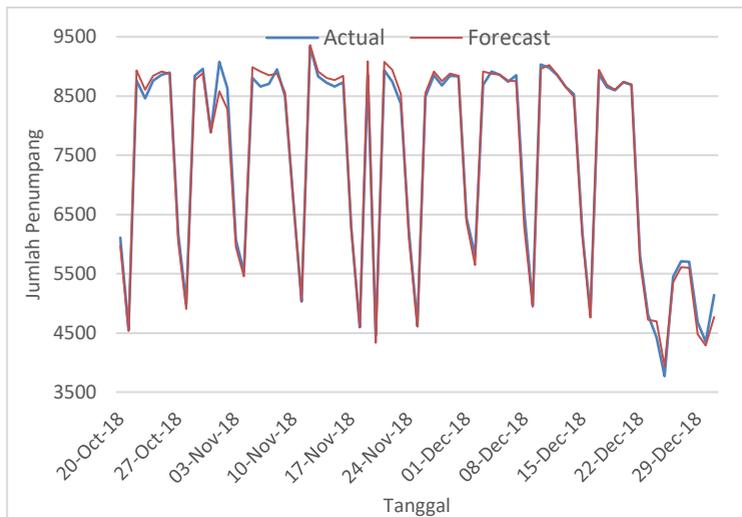
Berikut adalah hasil pengujian pada Stasiun Karet yang dapat dilihat pada Gambar 6.81. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 190,653.402 dan 2.117%.



Gambar 6. 37 Grafik Hasil Pengujian Stasiun Karet

6.12.3. Pengujian pada Data Jumlah Penumpang di Stasiun Univ. Pancasila

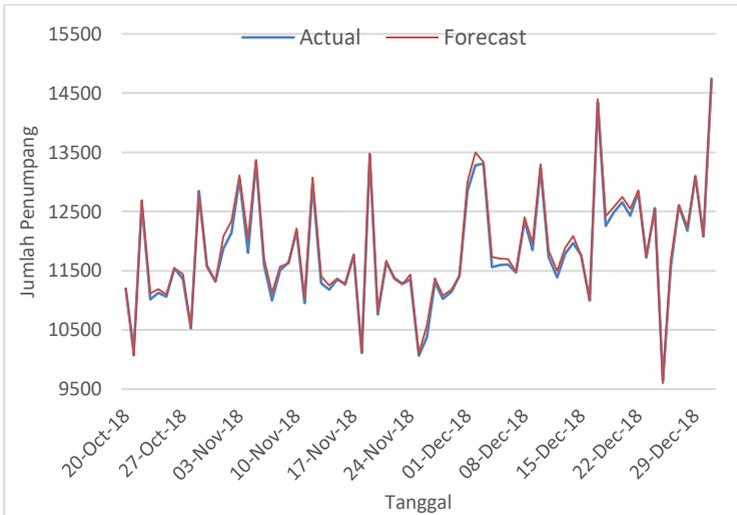
Berikut adalah hasil pengujian pada Stasiun Univ. Pancasila yang dapat dilihat pada Gambar 6.82. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 186,347.10 dan 3.622%.



Gambar 6. 38 Grafik Hasil Pengujian Stasiun Univ. Pancasila

6.12.4. Pengujian pada Data Jumlah Penumpang di Stasiun Parung Panjang

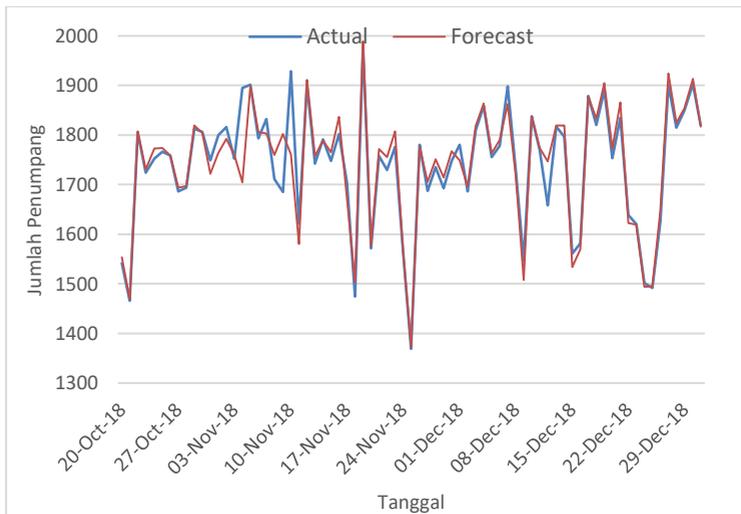
Berikut adalah hasil pengujian pada Stasiun Parung Panjang yang dapat dilihat pada Gambar 6.83. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 46,044.45 dan 1.113%.



Gambar 6. 39 Grafik Hasil Pengujian Stasiun Parung Panjang

6.12.5. Pengujian pada Data Jumlah Penumpang di Stasiun Bojong Indah

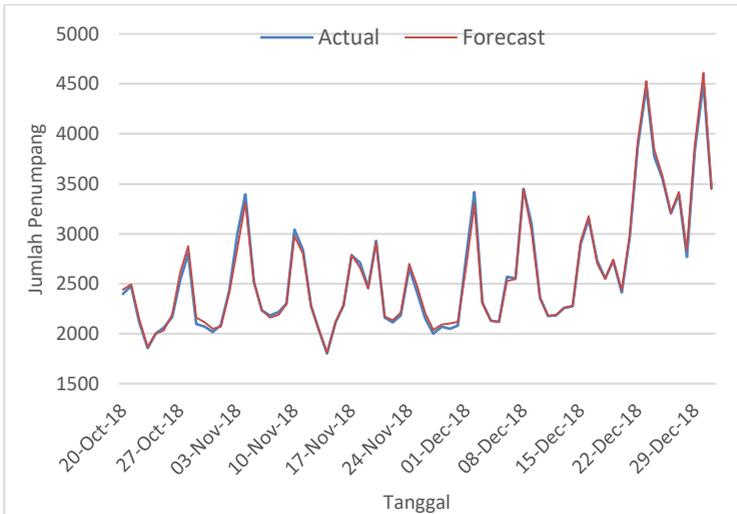
Berikut adalah hasil pengujian pada Stasiun Bojong Indah yang dapat dilihat pada Gambar 6.84. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 952.668 dan 1.003%.



Gambar 6. 40 Grafik Hasil Pengujian Stasiun Bojong Indah

6.12.6. Pengujian pada Data Jumlah Penumpang di Stasiun Tanjung Priok

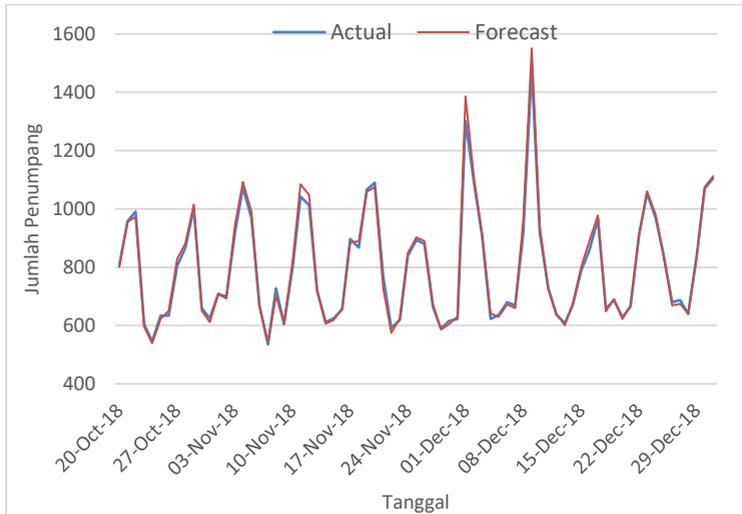
Berikut adalah hasil pengujian pada Stasiun Tanjung Priok yang dapat dilihat pada Gambar 6.85. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 12,938.15 dan 3.794%.



Gambar 6. 41 Grafik Hasil Pengujian Stasiun Tanjung Priok

6.12.7. Pengujian pada Data Jumlah Penumpang di Stasiun Citeras

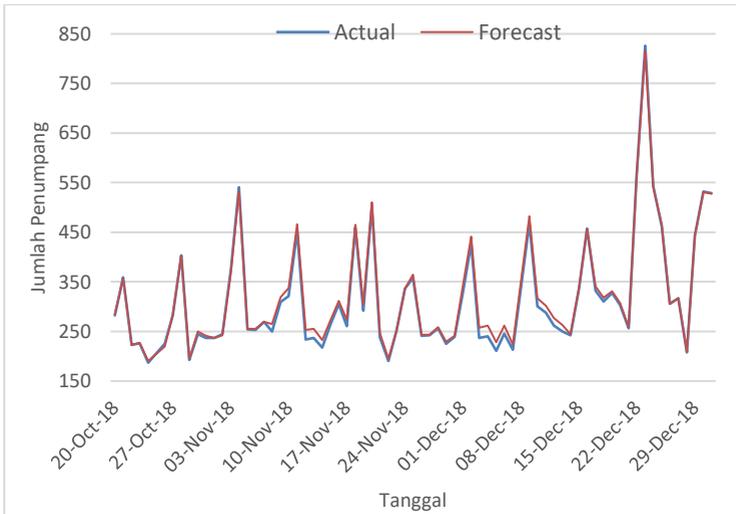
Berikut adalah hasil pengujian pada Stasiun Citeras yang dapat dilihat pada Gambar 6.86. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 736.204 dan 2.256%.



Gambar 6. 42 Grafik Hasil Pengujian Stasiun Citeras

6.12.8. Pengujian pada Data Jumlah Penumpang di Stasiun Ancol

Berikut adalah hasil pengujian pada Stasiun Ancol yang dapat dilihat pada Gambar 6.87. Dari hasil pengujian, didapatkan MSE dan MAPE secara berurutan yaitu 1,022.938 dan 7.913%.



Gambar 6. 43 Grafik Hasil Pengujian Stasiun Ancol

Berdasarkan MAPE yang didapatkan dari seluruh stasiun yang terdapat dalam Kelompok Data Jumlah Penumpang di Setiap Stasiun Khusus MAPE > 10%, maka seluruh stasiun telah memiliki MAPE < 10% yang berarti berdasarkan Tabel 2.1, maka akurasi peramalan tergolong sangat baik. Kemudian grafik *forecast* yang dihasilkan juga telah mengikuti pola data aktual sehingga seluruh stasiun kemudian dapat dilakukan peramalan untuk masa depan.

6.13. Analisis MAPE dan MSE Seluruh Stasiun Tujuan

Berikut dalam Tabel 6.12, ditampilkan MAPE dan MSE akhir dari pengujian pada seluruh stasiun tujuan

Tabel 6. 14 Hasil MAPE dan MSE Seluruh Stasiun Tujuan

| No | Stasiun | MAPE | MSE |
|----|----------------|--------|----------------|
| 1 | Bogor | 3.291% | 8,276,087.094 |
| 2 | Tanah Abang | 1.913% | 2,492,148.161 |
| 3 | Sudirman | 2.292% | 350,633.727 |
| 4 | Bekasi | 2.135% | 8,526,743.553 |
| 5 | Bojonggede | 0.924% | 281,405.133 |
| 6 | Depokbaru | 0.706% | 128,351.405 |
| 7 | Citayam | 2.137% | 1,939,760.698 |
| 8 | Jakarta Kota | 1.767% | 327,889.307 |
| 9 | Tebet | 5.406% | 7,869,161.458 |
| 10 | Gondangdia | 9.818% | 12,109,972.711 |
| 11 | Depok | 5.083% | 4,728,319.464 |
| 12 | Cikini | 8.567% | 3,621,383.332 |
| 13 | Pondok Cina | 5.709% | 3,266,147.795 |
| 14 | Pasar Minggu | 1.193% | 118,928.187 |
| 15 | Manggarai | 6.526% | 4,026,604.688 |
| 16 | Duren Kalibata | 1.218% | 137,658.519 |
| 17 | Sudimara | 0.918% | 70,504.457 |
| 18 | Cilebut | 4.306% | 1,711,627.989 |

| No | Stasiun | MAPE | MSE |
|-----------|----------------|-------------|---------------|
| 19 | Cawang | 9.964% | 3,271,480.632 |
| 20 | Juanda | 3.449% | 2,047,928.017 |
| 21 | Univ.Indonesia | 2.682% | 79,863.238 |
| 22 | Kranji | 1.130% | 79,221.855 |
| 23 | Palmerah | 2.000% | 253,148.856 |
| 24 | Jatinegara | 4.572% | 577,428.713 |
| 25 | Lenteng Agung | 0.973% | 38,866.541 |
| 26 | Tanjung Barat | 8.199% | 2,037,675.667 |
| 27 | Tangerang | 0.970% | 62,340.583 |
| 28 | Kebayoran | 5.675% | 2,126,314.907 |
| 29 | Rawa Buntu | 5.607% | 3,093,749.860 |
| 30 | Sawah Besar | 6.773% | 809,119.119 |
| 31 | Pondok Kranji | 7.681% | 1,799,089.079 |
| 32 | Karet | 2.117% | 190,653.402 |
| 33 | Duri | 1.219% | 24,855.043 |
| 34 | Cakung | 1.651% | 93,519.767 |
| 35 | Parung Panjang | 1.113% | 46,044.448 |
| 36 | Klender Baru | 0.973% | 10,381.998 |
| 37 | Mangga Besar | 5.887% | 371,674.940 |
| 38 | Jayakarta | 9.759% | 549,041.669 |
| 39 | Serpong | 1.257% | 24,572.232 |
| 40 | Kampung Bandan | 8.095% | 260,995.378 |

| No | Stasiun | MAPE | MSE |
|-----------|-------------------|-------------|---------------|
| 41 | Poris | 1.355% | 23,240.032 |
| 42 | Klender | 1.183% | 12,396.717 |
| 43 | Kemayoran | 1.947% | 32,042.371 |
| 44 | Univ.Pancasila | 3.622% | 186,347.101 |
| 45 | Jurangmangu | 8.477% | 1,495,872.702 |
| 46 | Buaran | 1.071% | 9,907.256 |
| 47 | Pesing | 7.664% | 181,383.612 |
| 48 | Pasar Senen | 1.598% | 7,081.908 |
| 49 | Pasar Minggu Baru | 1.349% | 7,984.701 |
| 50 | Rawabuaya | 3.084% | 95,257.332 |
| 51 | Cisauk | 1.428% | 15,012.311 |
| 52 | Kali Deres | 0.830% | 3,843.129 |
| 53 | Batu Ceper | 1.034% | 1,435.676 |
| 54 | Rajawali | 1.872% | 2,205.008 |
| 55 | Kramat | 2.325% | 5,493.591 |
| 56 | Gang Sentiong | 1.067% | 1,209.617 |
| 57 | Tiga Raksa | 2.039% | 18,477.599 |
| 58 | Cicayur | 1.175% | 2,679.867 |
| 59 | Pondok Jati | 1.442% | 642.737 |
| 60 | Bojong Indah | 1.003% | 952.668 |
| 61 | Cibinong | 1.730% | 2,489.731 |
| 62 | Nambo | 6.946% | 29,690.149 |

| No | Stasiun | MAPE | MSE |
|-----------|----------------|-------------|-------------|
| 63 | Tenjo | 2.177% | 15,082.968 |
| 64 | Maja | 1.949% | 8,181.652 |
| 65 | Cilejit | 8.979% | 70,008.465 |
| 66 | Daru | 1.889% | 7,259.393 |
| 67 | Grogol | 3.031% | 46,105.353 |
| 68 | Taman Kota | 8.116% | 58,457.642 |
| 69 | Tanah Tinggi | 2.774% | 21,264.748 |
| 70 | Cikoya | 2.279% | 617.095 |
| 71 | Tanjung Priok | 3.794% | 12,938.148 |
| 72 | Ancol | 7.913% | 1,022.938 |
| 73 | Angke | 1.786% | 48,053.006 |
| 74 | Citeras | 2.256% | 736.204 |
| 75 | Rangkasbitung | 2.893% | 156,095.752 |
| 76 | Bekasi Timur | 2.119% | 7,091.216 |
| 77 | Tambun | 1.850% | 30,187.528 |
| 78 | Cibitung | 1.983% | 18,702.098 |
| 79 | Cikarang | 4.695% | 453,144.500 |

Dari Tabel 6.12 di atas, dapat dilihat bahwa nilai MAPE terkecil dimiliki oleh Stasiun Depok Baru dengan nilai 0.706% dan MAPE terbesar dimiliki oleh Stasiun Cawang dengan nilai 9.964%. Hal ini menunjukkan bahwa hasil seluruh MAPE pengujian pada seluruh stasiun tujuan berada di bawah 10%, dengan rata-rata MAPE pada seluruh stasiun tujuan yaitu

3.423%. Ini menunjukkan bahwa akurasi hasil peramalan, menurut Tabel 2.1, menunjukkan hasil yang sangat baik. Sehingga, model dilanjutkan untuk dilakukan peramalan untuk masa depan pada setiap stasiun tujuan menggunakan model yang sesuai dengan model yang didapatkan dari hasil pengujian untuk masing-masing stasiun tujuan. Adapun, hasil peramalan untuk setiap stasiun tujuan dapat dilihat pada Lampiran D.

Halaman ini sengaja dikosongkan

BAB VII

KESIMPULAN DAN SARAN

Pada bab ini akan dijelaskan rangkuman singkat yang dapat disimpulkan dari penelitian ini. Terdapat saran dari penulis yang diharapkan dapat membantu dalam meningkatkan hasil pada penelitian selanjutnya.

7.1. Kesimpulan

Berdasarkan hasil yang telah diuraikan pada Bab 6, kesimpulan yang dapat ditarik adalah,

1. Model DNN dapat diterapkan untuk meramalkan jumlah penumpang KRL Commuter Line.
2. Terdapat dua model DNN terbaik yang dapat digunakan dalam meramalkan jumlah penumpang KRL Commuter Line, pertama yaitu; model DNN dengan parameter yaitu; tiga hidden layer yang berisi neuron 100, 200, dan 300, *epochs* dengan nilai 2500, dan nilai ADEDELTA (*Adaptiver Learning Rate Algorithm*) *epsilon* yaitu 1×10^{-10} dan nilai *Rho* 0.99. Sedangkan kedua, yaitu; model DNN dengan parameter yang sama dengan model DNN terbaik sebelumnya, namun memiliki perbedaan pada nilai *epsilon* yaitu sebesar 1×10^{-8} .
3. Besar kecilnya perubahan nilai parameter pada model, tidak menentukan nilai MSE yang semakin besar atau semakin kecil. Nilai MSE yang kecil didapatkan dari kombinasi nilai parameter yang optimal.
4. Akurasi peramalan berdasarkan MAPE untuk seluruh stasiun memiliki nilai di bawah 10% dimana hasil peramalan berdasar Tabel 2.1 tergolong sangat baik.

Untuk setiap stasiun memiliki nilai MAPE yang berbeda-beda. Nilai MAPE terkecil dimiliki oleh Stasiun Depok Baru dengan 0.706% dan untuk nilai MAPE terbesar dimiliki oleh Stasiun Cawang dengan 9.964%, dan rata-rata nilai MAPE seluruh stasiun yaitu 3.423%.

5. Akurasi peramalan berdasarkan MSE untuk seluruh stasiun berbeda-beda, dimana rata-rata nilai MSE untuk seluruh stasiun yaitu 1,024,327.698, dengan nilai MSE terbesar dimiliki oleh Stasiun Gondangdia dengan nilai 12,109,972.711 dan nilai MSE terkecil dimiliki oleh Stasiun Cikoya dengan nilai 617.095.

7.2. Saran

Berdasarkan hasil dan kesimpulan tersebut, saran yang dapat diberikan untuk penelitian selanjutnya adalah,

1. Penelitian kedepannya dapat melakukan variasi nilai parameter lain selain yang telah dilakukan pengujian dalam tugas akhir ini yaitu pada tabel 4.6-4.9 dalam Sub Bab 4.3.
2. Parameter DNN yang dilakukan pengujian terbatas pada jumlah *hidden layer*, neuron, *epochs*, dan nilai ADEDELTA (*Adaptive Learning Rate Algorithm*) *epsilon* dan *Rho*. Kedepannya, dapat melakukan pengujian pada parameter DNN lainnya seperti nilai *L1 and L2 Regularization* untuk menemukan model DNN yang lebih baik.
3. Dalam penelitian dengan menggunakan data yang sama, dapat dilakukan menggunakan metode *neural network* yang lain seperti RNN (*Recurrent Neural Network*) dan CNN (*Convolutional Neural Network*) dan dibandingkan performanya, untuk diketahui metode *neural network* yang paling baik performanya.

DAFTAR PUSTAKA

- [1] F. Fitriya, "Cermati.com," 10 Januari 2018. [Online]. Available: www.cermati.com. [Diakses 30 June 2019].
- [2] L. Liu dan R.-C. Chen, "A MRT Daily Passenger Flow Prediction Model with Different Combinations of Internal Factors," *2017 31st International Conference on Advanced Information Networking and Applications Workshops*, pp. 601-605, 2017.
- [3] Sudjana, *Metoda Statistika untuk Bidang Biologi, Farmasi, Geologi, Industri, Kedokteran, Pendidikan, Psikologi, Sosiologi, Teknik dll*, Bandung: Tarsito, 1986.
- [4] J. Heizer dan R. B., *Operation Management*, New Jersey: Prentice hall Inc., 2004.
- [5] M. S., *Metode dan Aplikasi Peramalan*, Jakarta: Erlangga, 1999.
- [6] S. G. Makridakis, S. C. Wheelwright dan R. J. Hyndman, *Forecasting: Methods and Applications*, 2nd Edition, New York: Wiley, 1983.
- [7] M. Leshno, V. Lin, A. Pinkus dan S. Schocken, "Multilayer Feedforward Networks with A Nonpolynomialactivation Function can Approximate any Function," *Neural Networks*, no. 6, p. 861–867, 1993.
- [8] I. S. N. S. M. A. Nadia SLIMANI, "Traffic Forecasting in Morocco Using Artificial Neural Networks," *Procedia Computer Science*, pp. 471-476, 2019.
- [9] B. L., N. G., . F. A., V. C. dan D. R., "Solar radiation

forecasting using artificial neural network and random forest methods: Application to normal beam, horizontal diffuse and global components,” *Renewable Energy*, vol. 132, pp. 871-884, 2019.

- [10] A. E. Tumer dan A. Akkus, “Forecasting Gross Domestic Product per Capita Using Artificial Neural Networks with Non-Economical Parameters,” *Physica A: Statistical Mechanics and its Applications*, vol. 512, pp. 468-473, 2018.
- [11] Y. Abu Mustofa, M. Magdon-Ismail dan H. Lin, *Learning from Data*, Berlin: AMLBook, 2012.
- [12] S. Ryu, J. Noh dan H. Kim, “Deep Neural Network Based Demand Side Short Term Load Forecasting,” *Energies*, 2017.
- [13] S. Wang, Z. Chen dan S. Chen, “Applicability of deep neural networks on production forecasting in Bakken shale reservoirs,” *Journal of Petroleum Science and Engineering*, vol. 179, pp. 112-125, 2019.
- [14] A. Loureiro, V. Migueis dan L. F. da Silva, “Exploring the use of deep neural networks for sales forecasting in fashion retail,” *Decision Support System*, vol. 114, pp. 81-93, 2018.
- [15] L. Ni, Y. Li, X. Wang, J. Zhang, J. Yu dan C. Qi, “Forecasting of Forex Time Series Data Based on Deep Learning,” *Procedia Computer Science*, vol. 147, pp. 647-652, 2019.

BIODATA PENULIS



Penulis dengan nama lengkap Irshad Al Islamy ini merupakan anak terakhir dari Bapak Awwaby Hafidz dan Ibu Yenny Husrida yang lahir di Jakarta pada tanggal 19 Agustus 1997. Penulis mengawali pendidikan formal di SD Islam Al Azhar 19 pada tahun 2003-2009, kemudian melanjutkan di SMP Negeri 255 Jakarta pada tahun 2009-2012, lalu melanjutkannya di SMA Negeri 12 Jakarta pada tahun 2012-2015. Atas rahmat الله, pada tahun 2015, penulis diterima di Departemen Sistem Informasi, Fakultas Teknologi Informasi dan Komunikasi di Institut Teknologi Sepuluh Nopember (ITS) melalui jalur SNMPTN Undangan. Penulis selama menjadi mahasiswa di ITS, meraih berbagai prestasi yaitu Top 10 National Essay Competition yang diadakan PMII UNILA pada tahun 2015 dan PKM 5 Bidang Didanai pada tahun 2016. Lalu, penulis juga aktif di UKM IFLS (ITS *Foreign Language Society*) sebagai Sie. Publikasi dan Dokumentasi dalam *event* INOCHI dan K-Fest pada tahun 2016 dan 2017, kemudian menjabat sebagai Ketua Departemen Humas IFLS di tahun 2017. Penulis juga pernah menjadi Asisten Laboratorium Studio Pemrograman Sistem Informasi (SPSI) dari tahun 2016-2017. Selain aktif dalam organisasi dan kepanitiaan, penulis juga mengikuti beberapa pelatihan diantaranya SAP University Alliance Course yang diadakan Departemen Sistem Informasi serta pernah mendapatkan sertifikasi IC3 (Internet Core Competency Certification) pada tahun 2017.

Untuk mengetahui informasi lebih lanjut mengenai penelitian ini maupun terkait dengan penulis, dapat menghubungi melalui email airshadicad@gmail.com.

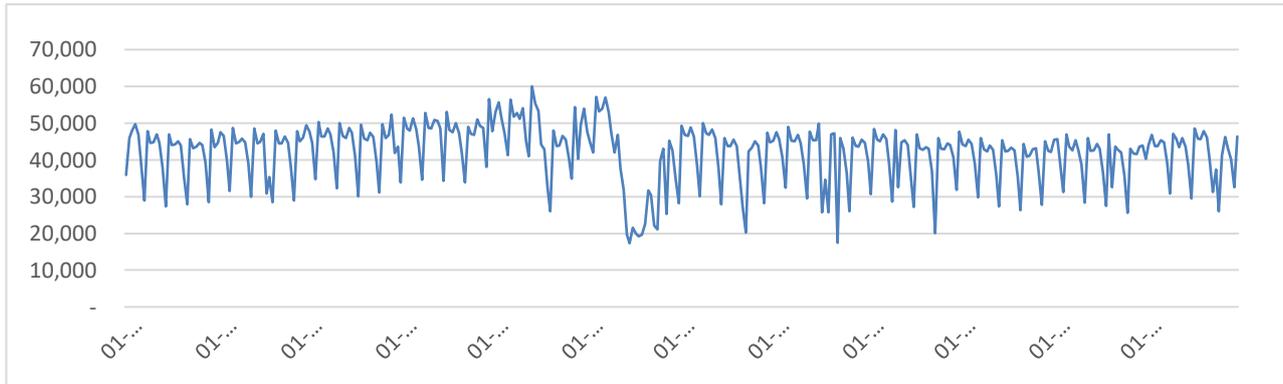
Halaman ini sengaja dikosongkan

LAMPIRAN A. DATA MENTAH

Lampiran Data Jumlah Penumpang KRL Commuter Line Tanggal 1 Januari 2018 – 31 Desember 2018 dapat dilihat di intip.in/DatasetTAIrshad

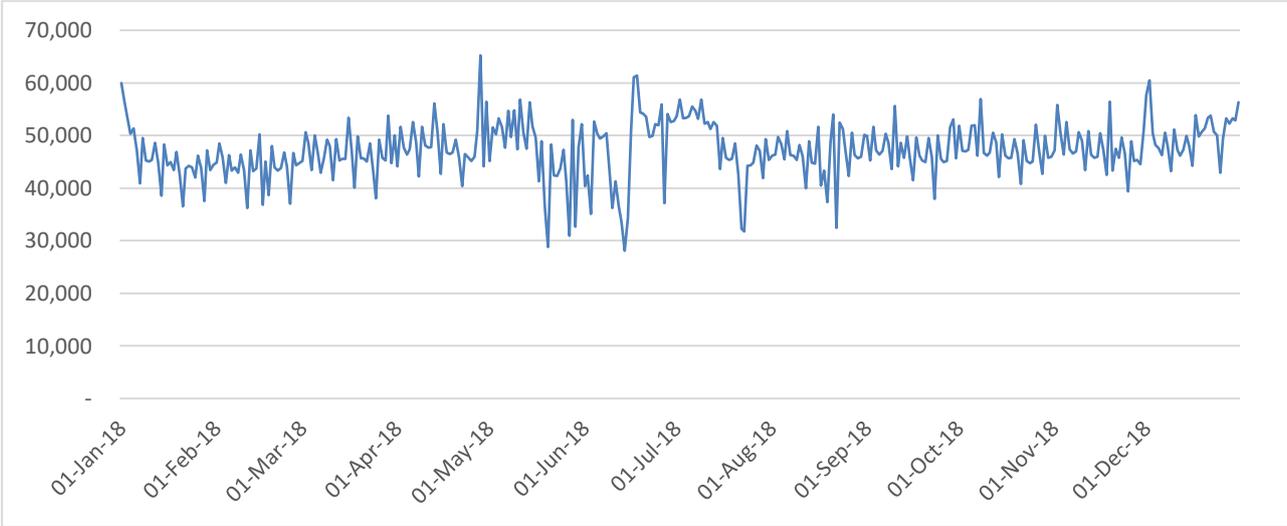
LAMPIRAN B: GRAFIK CONTOH POLA DATA

1. Grafik Contoh Kelompok Pola Data Seasonal



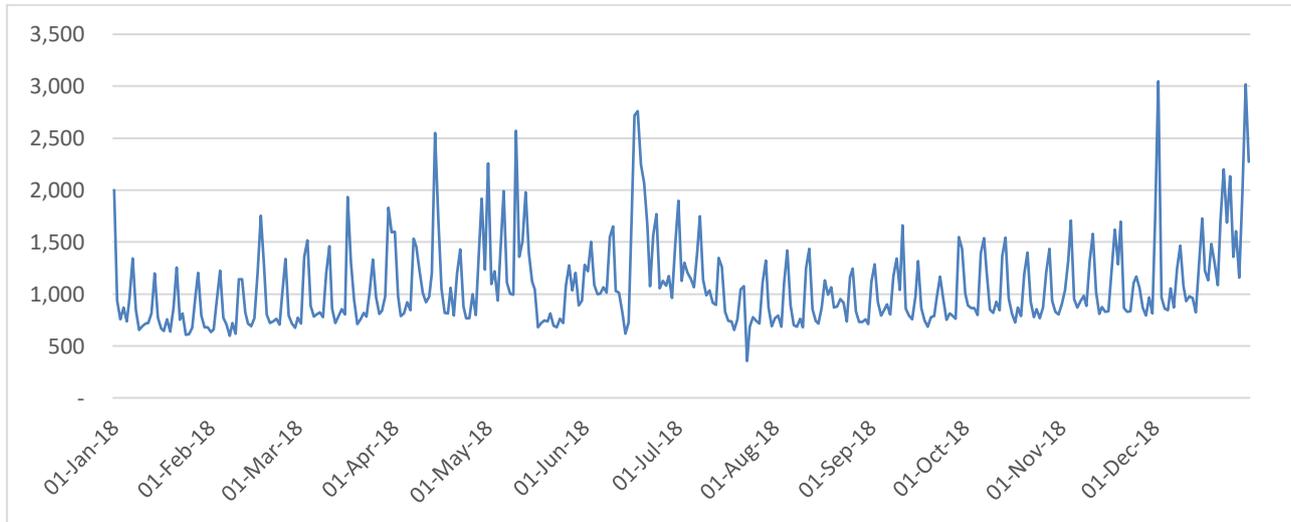
Gambar B. 1 Jumlah Penumpang KRL Commuter Line Stasiun Tanah Abang

2. Grafik Contoh Kelompok Pola Data Stasioner



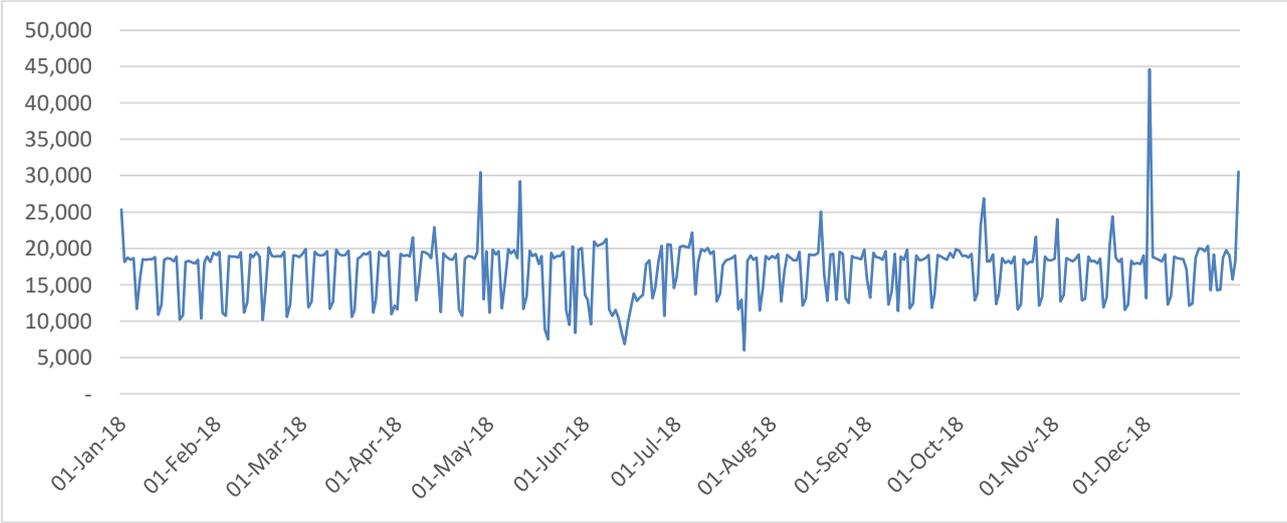
Gambar B. 2 Jumlah Penumpang KRL Commuter Line Stasiun Bogor

3. Grafik Contoh Kelompok Pola Data Seasonal Sisir Terbalik



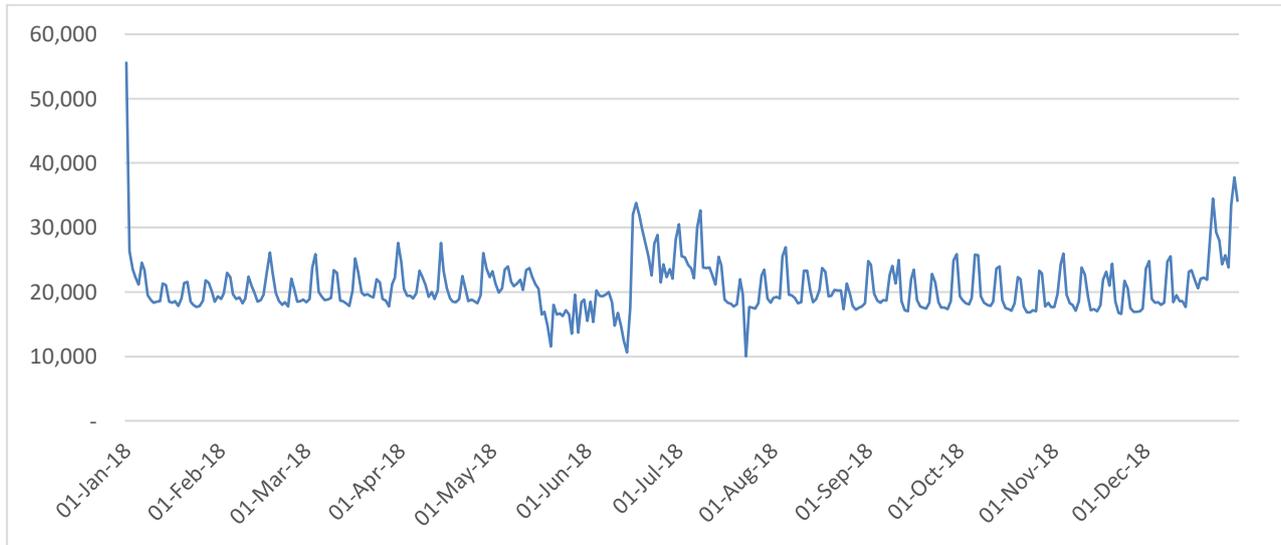
Gambar B. 3 Jumlah Penumpang KRL Commuter Line Stasiun Nambo

4. Grafik Contoh Kelompok Pola Data Seasonal dengan Nilai Ekstrim



Gambar B. 4 Jumlah Penumpang KRL Commuter Line Stasiun Juanda

5. Grafik Contoh Kelompok Pola Data Seasonal Sisir Terbalik dengan Nilai Ekstrim



Gambar B. 5 Jumlah Penumpang KRL Commuter Line Stasiun Jakarta Kota

LAMPIRAN C: DATA PENGUJIAN MODEL DNN
(Deep Neural Network)

Lampiran Data Pengujian Model DNN (*Deep Neural Network*)
dapat dilihat di intip.in/DatasetTAIrshad

LAMPIRAN D: DATA HASIL PERAMALAN

Lampiran Data Hasil Peramalan Jumlah Penumpang KRL
Commuter Line dapat dilihat di intip.in/DatasetTAIrhshad