



ITS
Institut
Teknologi
Sepuluh Nopember

TUGAS AKHIR - KS141501

**PERAMALAN JUMLAH PENDERITA DIFTERI
MENGUNAKAN METODE *RADIAL BASIS FUNCTION*
NEURAL NETWORK (RBFNN)**

***DIPHTHERIA FORECASTING USING RADIAL BASIS
FUNCTION NEURAL NETWORK (RBFNN)***

DINA NANDIKA
NRP 0521154000016

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

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

TUGAS AKHIR - KS141501

**PERAMALAN JUMLAH PENDERITA DIFTERI
MENGUNAKAN METODE RADIAL BASIS
FUNCTION NEURAL NETWORK (RBFNN)**

**DINA NANDIKA
0521154000016**

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

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

UNDERGRADUATE THESIS - KS141501

**DIPHTHERIA FORECASTING USING RADIAL
BASIS FUNCTION NEURAL NETWORK (RBFNN)**

DINA NANDIKA
0521154000016

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

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

LEMBAR PENGESAHAN

**PERAMALAN JUMLAH PENDERITA DIFTERI
MENGUNAKAN METODE RADIAL BASIS
FUNCTION NEURAL NETWORK (RBFNN)**

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:

DINA NANDIKA

NRP. 05211540000016

Surabaya, Juli 2019

**KEPALA
DEPARTEMEN SISTEM INFORMASI**



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

NIP. 19761011 200604 2 001

LEMBAR PERSETUJUAN

**PERAMALAN JUMLAH PENDERITA DIFTERI
MENGUNAKAN METODE RADIAL BASIS
FUNCTION NEURAL NETWORK (RBFNN)**

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 :

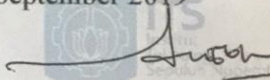
DINA NANDIKA

NRP. 0521154000016

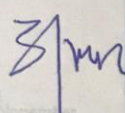
Disetujui Tim Penguji : Tanggal Ujian : 10 Juli 2019

Periode Wisuda : September 2019

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


(Pembimbing I)

Edwin Riksakomara, S.Kom, M.T


(Penguji I)

Retno Aulia Vinarti, S.Kom., M.Kom., Ph.D. (Penguji II)



**PERAMALAN JUMLAH PENDERITA DIFTERI
MENGUNAKAN METODE RADIAL BASIS
FUNCTION NEURAL NETWORK (RBFNN)**

Nama Mahasiswa : Dina Nandika
NRP : 0521154000016
Departemen : Sistem Informasi
Dosen Pembimbing : Wiwik Anggraeni, S.Si., M.Kom.

ABSTRAK

Difteri merupakan salah satu penyakit yang paling mematikan pada abad ke delapan belas dan sembilan belas, yang menyebabkan sejumlah kematian besar pada anak – anak di Eropa dengan tingkat fatalitas kasus mencapai 50%. Pada tahun 1943, difteri menyebabkan sekitar 1 juta kasus dan 50.000 kematian. Kasus difteri di Indonesia sudah hampir tidak ada pada tahun 1990-an, namun penyakit ini kembali muncul di tahun 2009 yang dinyatakan suspect. Saat ini, penyakit difteri menduduki peringkat keempat sebagai penyakit yang mematikan setelah jantung (kardiovaskuler), TBC, dan Pneumonia. Angka kematian akibat difteri di Indonesia diperkirakan mencapai 21 % dengan gejala berupa malaise, anoreksia, sakit tenggorokan, dan peningkatan suhu tubuh. Di tahun 2014, dari 22 provinsi yang melaporkan kasus difteri di Indonesia, Jawa Timur menduduki posisi tertinggi untuk kasus difteri yaitu 295 kasus, yang berkontribusi sebesar 74%. Pada tahun 2017 silam, penyakit difteri di Indonesia ini menjadi sangat diwaspadai oleh kalangan masyarakat hingga pertengahan 2018 yang ditandai dengan fluktuatif penderita difteri di Indonesia, khususnya Jawa Timur. Maka dari itu, diperlukan kegiatan peramalan terhadap penyakit difteri ini untuk membantu Dinas Kesehatan Provinsi Jawa Timur dalam menentukan kebijakan yang akan dilakukan untuk menekan jumlah penderita difteri. Metode yang digunakan untuk peramalan adalah dengan Radial Basis Function Neural Network. Metode Neural Network sudah banyak dibuktikan

menghasilkan akurasi lebih tinggi jika dibandingkan dengan metode statistikal lainnya, karena metode NN dapat belajar dari pola data yang ada sehingga ketika diuji akan menghasilkan peramalan yang lebih baik. RBFNN dipilih karena keunggulannya dalam komputasi kecepatan iterasi jika dibandingkan dengan metode jaringan syaraf tiruan yang lainnya.

Dari beberapa variabel yang dilibatkan yaitu Cakupan Imunisasi, Kepadatan Penduduk, dan Jumlah Penderita, model terbaik yang terpilih hanya melibatkan 1 variabel saja yaitu Jumlah Penderita saja. Sehingga model dapat meramalkan jumlah kasus penderita difteri di di Kabupaten Malang, Kota Surabaya, dan Kabupaten Sumenep. Hasil peramalan jumlah kasus difteri di Kabupaten Malang. Kota Surabaya, dan Kabupaten Sumenep menggunakan metode RBFNN memiliki nilai performa MSE 7,868 ; 18,5096 ; 2,4905 dan MASE 0,84 ; 0.817 ; 0.820 dimana semua nilai MASE kurang dari 1, sehingga model ini memiliki performa yang baik.

Kata Kunci: Difteri, Peramalan, Neural Network, Radial Basis Function Neural Network

DIPHTHERIA FORECASTING USING RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)

Name : Dina Nandika
NRP : 0521154000016
Department : Information Systems
Supervisor : Wiwik Anggraeni, S.Si., M.Kom.

ABSTRACT

Diphtheria was one of the deadliest diseases in the eighteenth and nineteenth centuries, which caused a large number of deaths in children in Europe with a case fatality rate of 50%. In 1943 diphtheria caused around 1 million cases and 50,000 deaths. In the 1990s there were almost no cases of diphtheria in Indonesia, but this disease re-emerged in 2009 which was declared as suspect. At present, diphtheria is ranked fourth as a deadly disease after cardiovascular disease, tuberculosis, and pneumonia. The mortality rate from diphtheria in Indonesia is estimated to reach 21% with symptoms such as malaise, anorexia, sore throat, and increased body temperature. In 2014, 22 provinces that reported cases of diphtheria in Indonesia, East Java occupied the highest position for diphtheria cases, namely 295 cases, which contributed 74%. In 2017, diphtheria in Indonesia has been very much watched by the public until mid-2018 which is characterized by patients who are fluctuating in Indonesia, especially East Java. Therefore, it is necessary to forecast this diphtheria to help Dinas Kesehatan Provinsi Jawa Timur determine the policies to be taken to reduce the number of diphtheria cases. The method used for forecasting is by Radial Basis Function Neural Network. The Neural Network method has been proven to produce higher accuracy compared to other statistical methods, because the NN method can learn from existing data patterns so that when tested it will produce better forecasting. RBFNN was chosen because of its superiority in computational iteration speeds when compared to other artificial neural network methods.

From several variables involved (Immunization Covergae, Population Density, and Number of Diptheria Patien)t, the best model chosen has one variable involved (Number of Diptheria Patient). This model can predict diptheria case in Kabupaten Malang, Kota Surabaya, and Kabupaten Sumenep. The result of forecasting of diptheria case in Kabupaten Malang, Kota Surabaya, and Kabupaten Sumenep using RBFNN has MSE value 7,868 ; 18,5096 ; 2,4905 and MASE value of 0,84 ; 0.817 ; 0.820 which all MASE value are less than 1, so that these models have good performance.

Keywords: Diptheria, Forecasting, Neural Network, Radial Basis Function Neural Network

KATA PENGANTAR

Dengan mengucapkan rasa syukur kepada Tuhan Yang Maha Pengasih dan Maha Penyayang atas izin-Nya penulis dapat menyelesaikan buku yang sederhana ini dengan judul Peramalan Jumlah Penderita Difteri Menggunakan Metode *Radial Basis Function Neural Network* (RBFNN). Dalam penyelesaian Tugas Akhir ini, penulis diiringi oleh pihak-pihak yang selalu memberi dukungan, saran, dan doa sehingga penelitian berlangsung dengan lancar. Secara khusus penulis mengucapkan terima kasih dari lubuk hati terdalam kepada:

1. Tuhan, yang selalu menemani dan membimbing penulis dalam segala aspek kehidupan.
2. Bapak Hugeng di Dinas Kesehatan Provinsi Jawa Timur selaku narasumber yang telah memfasilitasi penelitian mengenai penderita difteri.
3. Ibu Mahendrawathi ER, S.T., M.Sc., Ph.D selaku Ketua Departemen Sistem Informasi ITS Surabaya.
4. Ibu Wiwik Anggraeni, S.Si., M.Kom. selaku dosen pembimbing yang telah mencurahkan segenap tenaga, waktu dan pikiran dalam penelitian ini, serta memberikan motivasi yang membangun.
5. Bapak Edwin Riksakomara, S.Kom, M.T dan Ibu Retno Aulia Vinarti, S.Kom., M.Kom., Ph.D. selaku dosen penguji yang telah memberikan kritik dan saran yang membuat kualitas penelitian ini lebih baik lagi.
6. Orang tua penulis dan kakak, yang tiada hentinya mendoakan dan memberikan dukungan kepada penulis.
7. Segenap dosen dan karyawan Departemen Sistem Informasi.
8. Maria dan Yeyen selaku tim seperjuangan untuk menerjang penelitian ini hingga selesai.
9. Teman-teman Lannister, Waspada 4, grup koceng, teman-teman RDIB, Umar, dan teman-teman cross lab yang senantiasa memberi semangat dan dukungan.

10. Serta Mas Radit dan Firdha yang telah memberikan ilmu-ilmu yang bermanfaat untuk pengerjaan penelitian ini.
11. Dan terhadap pihak-pihak yang belum disebutkan satu per satu yang telah melancarkan penelitian ini.

Penyusunan tugas akhir ini masih jauh dari kata sempurna, untuk itu penulis menerima segala kritik dan saran yang membangun sebagai upaya menjadi lebih baik lagi ke depannya. Semoga buku tugas akhir ini dapat memberikan manfaat untuk pembaca.

Surabaya, 17 Juli 2019

Penulis

DAFTAR ISI

LEMBAR PENGESAHAN....	Error! Bookmark not defined.
LEMBAR PERSETUJUAN...	Error! Bookmark not defined.
ABSTRAK.....	v
ABSTRACT.....	vii
KATA PENGANTAR	ix
DAFTAR ISI.....	xi
DAFTAR GAMBAR	xv
DAFTAR TABEL.....	xix
KODE PROGRAM.....	xxiii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Permasalahan.....	5
1.4 Tujuan	6
1.5 Manfaat	6
1.6 Relevansi.....	7
BAB II TINJAUAN PUSTAKA	9
2.1 Penelitian Sebelumnya	9
2.2 Dasar Teori	12
2.2.1 Karakteristik Data	12
2.2.2 Uji Korelasi.....	17
2.2.3 Difteri.....	18
2.2.4 Peramalan.....	19
2.2.5 <i>Artificial Neural Network</i> (Jaringan Syaraf Tiruan)	21
2.2.6 Evaluasi Hasil Peramalan	29
BAB III METODOLOGI PENELITIAN	33
3.1 Tahapan Pelaksanaan Tugas Akhir	33
3.1.1 Identifikasi Masalah	34
3.1.2 Studi Literatur	35
3.1.3 Pengumpulan dan Pra-proses Data	35
3.1.4 Penentuan Parameter	36
3.1.5 Permodelan RBFNN	36
3.1.6 Peramalan RBFNN.....	37
3.1.7 Analisis Hasil dan Kesimpulan	38

3.1.8 Pengerjaan Laporan Tugas Akhir	38
BAB IV PERANCANGAN	39
4.1 Persiapan Data	39
4.2 Pra-proses Data	39
4.2.1 Uji Korelasi	40
4.3 Perancangan Model RBFNN.....	40
4.3.1 Penetapan Variabel <i>Input Layer</i>	41
4.3.2 Penetapan Variabel Ouput Layer.....	41
4.3.3 Penetapan Parameter	41
4.3.4 Proses <i>Training Data</i>	42
4.3.5 Proses <i>Testing Data</i>	42
4.3.6 Peramalan.....	42
4.4 Skenario Permodelan	42
4.4.1 Skenario Model Kombinasi A	42
4.4.2 Skenario Model Kombinasi B	43
4.4.3 Skenario Model Kombinasi C	43
4.4.4 Skenario Model Kombinasi D	44
4.4.5 Penyeleksian Hasil Keluaran Model.....	44
4.4.6 Validasi Model.....	44
4.5 Analisis Hasil Peramalan	44
BAB V IMPLEMENTASI	47
5.1 Pengumpulan dan Pra-Processing Data.....	47
5.1.1 Pengelompokkan Data.....	48
5.1.2 Pra-Processing Data Kepadatan Penduduk	48
5.2 Uji Korelasi.....	51
5.2.1 <i>Input Data</i>	51
5.2.2 Korelasi Data	53
5.3 Implementasi RBFNN.....	54
5.3.1 <i>Input Data</i>	54
5.3.2 Proses Training	60
5.3.3 Proses Testing	61
5.3.4 Uji Performa Model	62
5.3.5 Validasi Model.....	63
5.4 Peramalan Masa Mendatang	64
BAB VI HASIL DAN PEMBAHASAN	67
6.1 Hasil Pra-Processing Data.....	67
6.1.1 Hasil Pengelompokkan Data	67
6.1.2 Hasil Pra-Processing Data Kepadatan Penduduk 70	

6.2 Hasil Uji Korelasi	77
6.3 Hasil Implementasi Skenario Model	80
6.3.1 Hasil Model Kombinasi A.....	80
6.3.2 Hasil Model Kombinasi B	89
6.3.3 Hasil Model Kombinasi C.....	98
6.3.4 Hasil Model Kombinasi D.....	107
6.4 Kesimpulan Hasil Model Kombinasi	115
6.4.1 Pengelompokan 1 (Kabupaten Malang)	115
6.4.2 Pengelompokan 2 (Surabaya).....	115
6.4.3 Pengelompokan 3 (Sumenep).....	116
6.5 Hasil Validasi Model	116
6.5.1 Pengelompokan 1	117
6.5.2 Pengelompokan 2	127
6.5.3 Pengelompokan 3	136
6.5.4 Kesimpulan Model	145
6.6 Hasil Peramalan	147
BAB VII KESIMPULAN DAN SARAN.....	151
7.1 Kesimpulan	151
7.2 Saran	152
DAFTAR PUSTAKA	153
BIODATA PENULIS	159
A. LAMPIRAN A	A-1
B. LAMPIRAN B	B-1
C. LAMPIRAN C	C-1
D. LAMPIRAN D	D-1

DAFTAR GAMBAR

Gambar 1.1 Kasus difteri dan cakupan vaksinasi di dunia dari tahun 1980 – 2012.....	2
Gambar 1.2 Persebaran kasus difteri di Indonesia (Sumber : Google Trends Indonesia)	4
Gambar 2.1 Preview data jumlah penduduk di Kabupaten Malang	15
Gambar 2.2 Preview data luas wilayah kota/kabupaten di Jatim	15
Gambar 2.3 Persebaran jumlah penderita difteri di kota Sumenep.....	16
Gambar 2.4 Persebaran jumlah penderita difteri di kabupaten Malang	16
Gambar 2.5 Persebaran jumlah penderita difteri di kota Surabaya.....	17
Gambar 2.6 Arsitektur Single Layer Network.....	24
Gambar 2.7 Arsitektur Multi Layer Network	24
Gambar 2.8 Arsitektur Recurrent Neural Network.....	24
Gambar 2.9 Arsitektur RBFNN.....	26
Gambar 5.1 Bentuk worksheet Minitab.....	52
Gambar 5.2 Contoh pengisian data di Minitab	52
Gambar 5.3 Melakukan korelasi data	53
Gambar 5.4 Pengisian Tab Correlation	53
Gambar 5.5 Workspace Matlab	55
Gambar 5.6 Memasukkan Data pada array Matlab.....	57
Gambar 5.7 Memasukkan data target	58
Gambar 5.8 Memasukkan data input_testing	59
Gambar 6.1 Grafik Jumlah Kasus Difteri di Kabupaten Malang	68
Gambar 6.2 Grafik Jumlah Kasus Difteri di Surabaya	69
Gambar 6.3 Grafik Jumlah Kasus Difteri di Sumenep	69
Gambar 6.4 Hasil uji korelasi di Kota Surabaya.....	77
Gambar 6.5 Hasil uji korelasi di Kabupaten Malang.....	79
Gambar 6.6 Hasil uji korelasi di Kabupaten Sumenep	79
Gambar 6.7 Grafik perbandingan Skenario A Kabupaten Malang	82

Gambar 6.8 Perbandingan data aktual dan peramalan Kab. Malang Skenario A	83
Gambar 6.9 Grafik perbandingan Skenario A Surabaya.....	85
Gambar 6.10 Perbandingan data aktual dan peramalan Surabaya Skenario A	86
Gambar 6.11 Grafik perbandingan Skenario A Sumenep.....	88
Gambar 6.12 Perbandingan data aktual dan peramalan Sumenep Skenario A	89
Gambar 6.13 Grafik perbandingan Skenario B Kab. Malang	91
Gambar 6.14 Perbandingan data aktual dan peramalan Kab. Malang Skenario B.....	92
Gambar 6.15 Grafik perbandingan Skenario B Surabaya	94
Gambar 6.16 Perbandingan data aktual dan peramalan Surabaya Skenario B.....	95
Gambar 6.17 Grafik perbandingan Skenario B Sumenep	97
Gambar 6.18 Perbandingan data aktual dan peramalan Sumenep Skenario B.....	98
Gambar 6.19 Grafik perbandingan Skenario C Kab. Malang	100
Gambar 6.20 Perbandingan data aktual dan peramalan Kab. Malang Skenario C.....	101
Gambar 6.21 Grafik perbandingan Skenario C Surabaya	103
Gambar 6.22 Perbandingan data aktual dan peramalan Surabaya Skenario C.....	104
Gambar 6.23 Grafik perbandingan Skenario C Sumenep	106
Gambar 6.24 Perbandingan data aktual dan peramalan Sumenep Skenario C.....	106
Gambar 6.25 Grafik perbandingan Skenario D Kab. Malang	109
Gambar 6.26 Perbandingan data aktual dan peramalan Kab. Malang Skenario D	109
Gambar 6.27 Grafik perbandingan Skenario D Surabaya....	111
Gambar 6.28 Perbandingan data aktual dan peramalan Surabaya Skenario D	112
Gambar 6.29 Grafik perbandingan Skenario D Sumenep....	114
Gambar 6.30 Perbandingan data aktual dan peramalan Sumenep Skenario D	114

Gambar 6.31 Validasi Skenario A pada Kabupaten Sidoarjo	117
Gambar 6.32 Validasi Skenario A pada Kota Batu	118
Gambar 6.33 Validasi Skenario A pada Kabupaten Tuban .	119
Gambar 6.34 Validasi Skenario B pada Kabupaten Sidoarjo	120
Gambar 6.35 Validasi Skenario B pada Kota Batu.....	121
Gambar 6.36 Validasi Skenario B pada Kabupaten Tuban..	121
Gambar 6.37 Validasi Skenario C pada Kabupaten Sidoarjo	122
Gambar 6.38 Validasi Skenario C pada Kota Batu.....	123
Gambar 6.39 Validasi Skenario C pada Kabupaten Tuban..	124
Gambar 6.40 Validasi Skenario D pada Kabupaten Sidoarjo	125
Gambar 6.41 Validasi Skenario D pada Kabupaten Tuban .	126
Gambar 6.42 Validasi Skenario D pada Kota Batu	126
Gambar 6.43 Validasi Skenario C pada Kabupaten Blitar...	128
Gambar 6.44 Validasi Skenario C pada Kabupaten Tulungagung	128
Gambar 6.45 Validasi Skenario C pada Kabupaten Bangkalan	129
Gambar 6.46 Validasi Skenario A pada Kabupaten Blitar...	130
Gambar 6.47 Validasi Skenario A pada Kabupaten Tulungagung	131
Gambar 6.48 Validasi Skenario A pada Kabupaten Bangkalan	131
Gambar 6.49 Validasi Skenario B pada Kabupaten Blitar...	132
Gambar 6.50 Validasi Skenario B pada Kabupaten Tulungagung	133
Gambar 6.51 Validasi Skenario B pada Kabupaten Bangkalan	133
Gambar 6.52 Validasi Skenario D pada Kabupaten Blitar...	134
Gambar 6.53 Validasi Skenario D pada Kabupaten Tulungagung	135
Gambar 6.54 Validasi Skenario D pada Kabupaten Bangkalan	135
Gambar 6.55 Validasi Skenario A pada Kabupaten Bojonegoro	137

Gambar 6.56 Validasi Skenario A pada Kabupaten Magetan	137
Gambar 6.57 Validasi Skenario A pada Kabupaten Trenggalek	138
Gambar 6.58 Validasi Skenario D pada Kabupaten Bojonegoro	139
Gambar 6.59 Validasi Skenario D pada Kabupaten Magetan	139
Gambar 6.60 Validasi Skenario D pada Kabupaten Trenggalek	140
Gambar 6.61 Validasi Skenario B pada Kabupaten Bojonegoro	141
Gambar 6.62 Validasi Skenario B pada Kabupaten Magetan	142
Gambar 6.63 Validasi Skenario B pada Kabupaten Trenggalek	142
Gambar 6.64 Validasi Skenario C pada Kabupaten Bojonegoro	144
Gambar 6.65 Validasi Skenario C pada Kabupaten Magetan	144
Gambar 6.66 Validasi Skenario C pada Kabupaten Trenggalek	145
Gambar 6.67 Hasil Peramalan Jumlah Kasus Difteri di Kabupaten Malang	147
Gambar 6.68 Hasil Peramalan Jumlah Kasus Difteri di Kota Surabaya.....	148
Gambar 6.69 Hasil Peramalan Jumlah Kasus Difteri di Kabupaten Sumenep.....	148

DAFTAR TABEL

Tabel 2.1 Penelitian Sebelumnya 1	9
Tabel 2.2 Penelitian Sebelumnya 2	10
Tabel 2.3 Penelitian Sebelumnya 3	11
Tabel 2.4 Preview data cakupan imunisasi (DPT1)	13
Tabel 2.5 Preview data penderita difteri	13
Tabel 3.1 Alur Pengerjaan Tugas Akhir	33
Tabel 4.1 Kriteria data kepadatan penduduk yang dibutuhkan	40
Tabel 4.2 Data Input dan Output pada 5 Node Input Layer (model A)	42
Tabel 4.3 Data Input dan Output pada 2 Node Input Layer (model B)	43
Tabel 4.4 Data Input dan Output pada 1 Node Input Layer (model C)	43
Tabel 4.5 Data Input dan Output pada 6 Node Input Layer (model D)	44
Tabel 5.1 Perbandingan hasil pengumpulan data dengan data yang dibutuhkan	47
Tabel 5.2 Jumlah Penduduk Surabaya 2013-2014	49
Tabel 5.3 Penjelasan Kode Program Input Data	54
Tabel 5.4 Penjelasan Script Transpose	59
Tabel 5.5 Penjelasan Script Training	60
Tabel 5.6 Penjelasan proses testing	62
Tabel 5.7 Penjelasan transpose hasil	63
Tabel 5.8 Penjelasan script validasi model	64
Tabel 6.1 Hasil pengelompokkan data	67
Tabel 6.2 Hasil perhitungan laju penduduk eksponensial bulanan Kota Surabaya	70
Tabel 6.3 Hasil perhitungan laju penduduk eksponensial bulanan Kabupaten Malang	70
Tabel 6.4 Hasil perhitungan laju penduduk eksponensial bulanan Kabupaten Sumenep	71
Tabel 6.5 Hasil perhitungan jumlah penduduk bulanan Kota Surabaya	72
Tabel 6.6 Hasil perhitungan jumlah penduduk bulanan Kabupaten Malang	72

Tabel 6.7 Hasil perhitungan jumlah penduduk bulanan Kabupaten Sumenep.....	73
Tabel 6.8 Hasil perhitungan kepadatan penduduk bulanan Kota Surabaya.....	74
Tabel 6.9 Hasil perhitungan kepadatan penduduk bulanan Kabupaten Malang	75
Tabel 6.10 Hasil perhitungan kepadatan penduduk bulanan Kabupaten Sumenep.....	76
Tabel 6.11 Hasil perhitungan MSE, MAD Skenario A Kabupaten Malang	80
Tabel 6.12 Hasil perhitungan MASE Skenario A Kabupaten Malang	81
Tabel 6.13 Hasil perhitungan MSE, MAD Skenario A Surabaya	83
Tabel 6.14 Hasil perhitungan MASE Skenario A Surabaya ..	84
Tabel 6.15 Hasil perhitungan MSE, MAD Skenario A Sumenep	86
Tabel 6.16 Hasil perhitungan MASE Skenario A Sumenep ..	87
Tabel 6.17 Hasil perhitungan MSE, MAD Skenario B Kab. Malang	90
Tabel 6.18 Hasil perhitungan MASE Skenario B Kab. Malang	90
Tabel 6.19 Hasil perhitungan MSE, MAD Skenario B Surabaya	92
Tabel 6.20 Hasil perhitungan MASE Skenario B Surabaya ..	93
Tabel 6.21 Hasil perhitungan MSE, MAD Skenario B Sumenep	95
Tabel 6.22 Hasil perhitungan MASE Skenario B Sumenep ..	96
Tabel 6.23 Hasil perhitungan MSE, MAD Skenario C Kab. Malang	99
Tabel 6.24 Hasil perhitungan MASE Skenario C Kab. Malang	99
Tabel 6.25 Hasil perhitungan MSE, MAD Skenario C Surabaya	101
Tabel 6.26 Hasil perhitungan MASE Skenario C Surabaya	102
Tabel 6.27 Hasil perhitungan MSE, MAD Skenario C Sumenep	105
Tabel 6.28 Hasil perhitungan MASE Skenario C Sumenep	105

Tabel 6.29 Hasil perhitungan MSE, MAD Skenario D Kab. Malang	107
Tabel 6.30 Hasil perhitungan MASE Skenario D Kab. Malang	108
Tabel 6.31 Hasil perhitungan MSE, MAD Skenario D Surabaya	110
Tabel 6.32 Hasil perhitungan MASE Skenario D Surabaya	110
Tabel 6.33 Hasil perhitungan MSE, MAD Skenario D Sumenep	112
Tabel 6.34 Hasil perhitungan MASE Skenario D Sumenep	113
Tabel 6.35 Urutan model kombinasi kelompok 1	115
Tabel 6.36 Urutan model kombinasi kelompok 2	116
Tabel 6.37 Urutan model kombinasi kelompok 3	116
Tabel 6.38 Hasil akurasi data validasi Skenario A	118
Tabel 6.39 Hasil akurasi data validasi Skenario B	120
Tabel 6.40 Hasil akurasi data validasi Skenario C	123
Tabel 6.41 Hasil akurasi data validasi Skenario D	125
Tabel 6.42 Hasil akurasi data validasi Skenario C	129
Tabel 6.43 Hasil akurasi data validasi Skenario A	130
Tabel 6.44 Hasil akurasi data validasi Skenario B	132
Tabel 6.45 Hasil akurasi data validasi Skenario D	134
Tabel 6.46 Hasil akurasi data validasi Skenario A	136
Tabel 6.47 Hasil akurasi data validasi Skenario D	140
Tabel 6.48 Hasil akurasi data validasi Skenario B	143
Tabel 6.49 Rata-rata MSE Model.....	146

KODE PROGRAM

Kode Program 5.1 Input Data.....	54
Kode Program 5.2 Transpose Data.....	59
Kode Program 5.3 Proses Training.....	60
Kode Program 5.4 Proses testing.....	61
Kode Program 5.5 Transpose hasil peramalan	62
Kode Program 5.6 Proses validasi model	63

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

Difteri merupakan salah satu penyakit yang paling mematikan pada abad ke delapan belas dan sembilan belas, yang menyebabkan sejumlah kematian besar pada anak – anak di Eropa dengan tingkat fatalitas kasus mencapai 50%. Pada tahun 1943, difteri menyebabkan sekitar 1 juta kasus dan 50.000 kematian. Hal tersebut disebabkan tidak adanya tindakan pencegahan seperti vaksinasi dini hari yang diterapkan untuk menghindari difteri menyerang imun manusia. Vaksinasi terhadap difteri sangat mampu menekan jumlah penderita difteri di United States yang awalnya memiliki angka 200.000 kasus difteri per tahun di tahun 1921, menjadi 5 kasus difteri per tahun pada tahun 2001 hingga 2012 [1]. Jumlah kasus difteri akan terus meningkat di dunia pada akhir tahun 2015 yang bisa mencapai 500 kasus jika tidak ada tindakan pencegahan vaksinasi di negara – negara bagian. Perkembangan antara cakupan vaksinasi di dunia terhadap jumlah kasus difteri dapat dilihat pada Gambar 1.1 [2].

Gambar 1.1 menjelaskan mengenai perbandingan antara *coverage* vaksinasi dengan jumlah penderita. Pada tahun 1980, *coverage* vaksinasi masih rendah yaitu sekitar 30% dan jumlah penderita sangat tinggi hingga mencapai 90.000-an penderita. Seiring berjalannya waktu, *coverage* vaksin semakin meningkat dan dapat menekan jumlah penderita difteri. Diketahui pada tahun 2012, *coverage* vaksin mencapai 90% dan jumlah penderita yang sedikit yaitu dibawah 5000 kasus.




Gambar 1.1 Kasus difteri dan cakupan vaksinasi di dunia dari tahun 1980 – 2012

(Sumber gambar [1])

Di tahun 2016, sebanyak 86% bayi di dunia (sekitar 116,5 juta) telah diimunisasi vaksin DPT. Sementara sekitar 130 negara setidaknya sudah mencapai 90% cakupan imunisasi DPT. Walaupun demikian, sekitar 19,5 juta bayi di dunia tidak diberikan vaksin DPT, dimana sekitar 60% dari bayi – bayi tersebut tinggal di negara – negara seperti Angola, Brazil, Republik Kongo, Ethiopia, India, Indonesia, Iraq, Nigeria, Pakistan, dan Afrika Selatan. Anak – anak tersebut sangat dimungkinkan memiliki atau terekspos penyakit difteri, yang menyumbang angka kasus difteri yaitu 7097 kasus di 2016 silam. Cakupan vaksinasi yang rendah, akses yang buruk ke layanan kesehatan dan pendapatan rendah adalah faktor-faktor yang menyebabkan penyakit difteri di negara-negara berkembang tersebut melonjak. Anak-anak berisiko lebih besar terkena penyakit ini karena status vaksinasi yang tidak lengkap [3]. Di Indonesia, penyakit difteri menduduki peringkat keempat sebagai penyakit yang mematikan setelah jantung (kardiovaskuler), TBC, dan Pneumonia. Angka kematian akibat difteri di Indonesia diperkirakan mencapai 21 % dengan gejala berupa malaise, anoreksia, sakit tenggorokan, dan peningkatan

suhu tubuh [2]. Kasus difteri di Indonesia sudah hampir tidak ada pada tahun 1990-an, namun penyakit ini kembali muncul di tahun 2009 yang dinyatakan *suspect*. Walaupun di Indonesia sudah diselenggarakan vaksin DPT untuk anak – anak, namun tidak ada vaksin DPT untuk dewasa, sehingga kekebalan orang dewasa yang semakin menurun akan juga semakin rentan terhadap penyakit ini, apalagi jika pada masa kecilnya belum melakukan vaksin DPT atau vaksin yang dilakukan belum lengkap [4]. Berdasarkan data pada Google Tren yang dapat dilihat pada Gambar 1.2 , diketahui bahwa kasus difteri di Indonesia memiliki puncak peningkatan di akhir tahun 2017 dan selama tahun 2018. Kasus difteri yang dilaporkan, di Indonesia mulai ada pada tahun 2011, terdapat 3353 kasus yang dilaporkan dari 38 kota atau kabupaten di Jawa Timur, dan di tahun 2012 terdapat 11 kasus yang berada di Jakarta [3]. Di tahun 2014, dari 22 provinsi yang melaporkan kasus difteri di Indonesia, Jawa Timur menduduki posisi tertinggi untuk kasus difteri yaitu 295 kasus, yang berkontribusi sebesar 74%. Dari 295 kasus tersebut, 37% penderita tidak mendapatkan vaksin campak [5].

Kepadatan penduduk juga merupakan faktor yang sangat erat kaitannya dengan tempat berkembang biaknya beberapa jenis penyakit, termasuk penyakit difteri [6]. Oleh karena itu, kota/kabupaten dengan kepadatan penduduk yang tinggi memiliki suatu potensi penderita yang banyak dan penyebaran penyakit difteri dapat ditularkan secara cepat.



Gambar 1.2 Persebaran kasus difteri di Indonesia (Sumber : Google Trends Indonesia)

Peramalan merupakan suatu kejadian untuk meramalkan apa yang akan terjadi dimasa mendatang melalui pengujian keadaan dimasa lalu [7]. Peramalan yang akurat untuk penyakit yang menular dan berbahaya seperti difteri sangatlah penting untuk pencegahan sedini mungkin dan untuk perencanaan strategis pemerintah yang lebih baik agar dapat melaksanakan berbagai macam program preventif hingga korektif untuk wabah difteri [8]. Selama ini, banyak peramalan yang dilakukan menggunakan metode statistikal seperti *Moving Average*, *Exponential Smoothing*, ARIMA, hingga metode *machine learning* pun juga dapat diterapkan. Dari berbagai penelitian, sudah banyak yang membuktikan bahwa metode *machine learning* menghasilkan akurasi yang lebih baik dibandingkan metode statistikal. RBFNN (*Radial Basis Function Neural Network*) merupakan salah satu model *Neural Network* yang memiliki kelebihan yaitu algoritma yang sederhana dan lebih cepat komputasinya jika dibandingkan dengan metode *neural network* yang tradisional (MLP), *backpropogation*, *recurrent neural network* [9]. Beberapa studi sebelumnya yang telah dilakukan, diketahui bahwa *Radial Basis Function Neural Network* membuahkan hasil yang lebih unggul dibandingkan beberapa metode pembanding untuk peramalan. Berdasarkan teori diatas dan studi sebelumnya, maka RBFNN dipilih sebagai metode untuk penelitian pada kasus peramalan kasus difteri ini. Dengan adanya penelitian mengenai peramalan dengan metode RBFNN ini, diharapkan peramalan ini dapat membantu pihak manajemen terkait yaitu Dinas Kesehatan Provinsi Jawa Timur untuk mengetahui kasus difteri yang mendatang dan segera melakukan tindakan preventif untuk menekan angka penderita difteri tersebut.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, permasalahan yang akan diangkat pada penelitian tugas akhir ini adalah sebagai berikut:

1. Bagaimana model terbaik yang dapat dibangun dari algoritma *Radial Basis Function Neural Network* (RBFNN)?
2. Bagaimana hasil peramalan yang dihasilkan berdasarkan model terbaik dari *Radial Basis Function Neural Network* untuk meramalkan jumlah kasus (penderita) difteri pada Kota Surabaya, Kabupaten Malang, dan Kota Sumenep?
3. Bagaimana tingkat akurasi yang dihasilkan dari peramalan jumlah kasus (penderita) difteri dengan menggunakan metode *Radial Basis Function Neural Network* ?
4. Bagaimana pengaruh variabel bebas (cakupan imunisasi atau vaksinasi DPT 1-4, dan kepadatan penduduk) terhadap jumlah penderita difteri di Kota Surabaya, Kabupaten Malang, dan Kota Sumenep?
5. Apakah performa metode *Radial Basis Function Neural Network* akan lebih baik jika melibatkan beberapa variabel bebas (cakupan imunisasi atau vaksinasi DPT 1-4, dan kepadatan penduduk) untuk meramalkan jumlah penderita difteri?
6. Bagaimana performa metode *Radial Basis Function Neural Network* terhadap berbagai bentuk pola data dengan menggunakan model terbaik yang sudah didapatkan untuk meramalkan jumlah penderita difteri?

1.3 Batasan Permasalahan

Berdasarkan deskripsi permasalahan diatas, adapun batasan masalah dari penelitian tugas akhir ini adalah sebagai berikut:

1. Data yang digunakan dalam penelitian tugas akhir ini adalah data jumlah kasus difteri pada periode bulanan dari tahun 2013 hingga 2018 di Kota Surabaya, Kabupaten Malang, dan Kota Sumenep, yang didapatkan dari Dinas Kesehatan Provinsi Jawa Timur.

2. Variabel bebas yang digunakan adalah cakupan imunisasi atau vaksinasi DPT 1-4, dan kepadatan penduduk.
3. Hasil peramalan dilakukan selama 2 tahun yaitu dari Januari 2019 hingga Desember 2020 di Kota Surabaya, Kabupaten Malang, dan Kota Sumenep.
4. *Tools* yang digunakan dalam penelitian tugas akhir ini adalah MATLAB.

1.4 Tujuan

Tujuan dari penelitian tugas akhir ini adalah sebagai berikut:

1. Menemukan model terbaik dari metode *Radial Basis Function Neural Network* untuk meramalkan jumlah kasus (penderita) difteri di Kota Surabaya, Kabupaten Malang, dan Kota Sumenep.
2. Mengetahui korelasi antara variabel bebas (cakupan imunisasi atau vaksinasi DPT 1-4, dan kepadatan penduduk) dengan jumlah penderita difteri di Kota Surabaya, Kabupaten Malang, dan Kota Sumenep.
3. Mengetahui hasil peramalan jumlah penderita difteri dari model terbaik dengan menggunakan metode *Radial Basis Function Neural Network*.
4. Mengetahui tingkat akurasi yang dihasilkan dari peramalan jumlah kasus (penderita) difteri dengan menggunakan metode *Radial Basis Function Neural Network*.
5. Mengetahui performa algoritma *Radial Basis Function Neural Network* terhadap permodelan dengan beberapa kombinasi variabel bebas dengan variabel terikat.
6. Mengetahui performa algoritma terhadap berbagai bentuk pola data yang berbeda menggunakan permodelan yang terbaik.

1.5 Manfaat

Manfaat yang dapat diperoleh dari tugas akhir ini adalah sebagai berikut:

1. Bagi Instansi
Memberikan informasi sebagai referensi untuk pengambilan keputusan untuk Dinas Kesehatan Provinsi Jawa Timur untuk menekan jumlah kasus (penderita) difteri di beberapa wilayah di Jawa Timur.
2. Bagi Akademis
Memberikan referensi penelitian yang mengimplementasikan metode peramalan khususnya metode *Radial Basis Function Neural Network* sehingga dapat dijadikan sebagai acuan dalam penelitian berikutnya.
3. Bagi Penulis
Penelitian ini diharapkan dapat menambah wawasan dan pengalaman dalam bidang keilmuan sistem informasi khususnya terkait peramalan dengan menggunakan metode RBFNN pada studi kasus nyata.

1.6 Relevansi

Penelitian yang dilakukan pada tugas akhir ini bersifat penyelesaian suatu permasalahan khususnya di bidang kesehatan. Permasalahan yang dimaksud adalah mengenai jumlah penderita penyakit difteri, khususnya Jawa Timur, dimana penyakit difteri ini merupakan salah satu penyakit akut dan mematikan di Indonesia pada dua tahun terakhir ini. Untuk menekan jumlah penderita difteri di Jawa Timur, maka penelitian ini pun dilakukan untuk meramalkan jumlah penderita difteri untuk membantu Dinas Kesehatan Provinsi Jawa Timur mengambil keputusan dan langkah yang tepat dengan adanya referensi data peramalan ini. Maka dari itu, penelitian ini dianggap layak untuk dijadikan studi kasus tugas akhir bagi mahasiswa S1 Sistem Informasi.

Tugas akhir ini memiliki relevansi terhadap salah satu bidang minat di Departemen Sistem Informasi, yaitu Laboratorium Rekayasa Data dan Intelegensia Bisnis. Bidang keilmuan yang terdapat pada laboratorium ini yang sesuai dengan penelitian tugas akhir ini yaitu pada *Business Analytic* dan *Intelligent Systems* dimana lingkup penelitian pada bidang keilmuan

Business Analytic adalah *forecasting*, sedangkan pada bidang keilmuan *Intelligent Systems* adalah *Neural Network*. Topik pada tugas akhir ini erat kaitannya dengan beberapa mata kuliah di Departemen Sistem Informasi, diantaranya Statistika, Sistem Cerdas, Penggalian Data, dan Teknik Peramalan. Beberapa mata kuliah yang telah disebutkan merupakan mata kuliah pilihan yang hanya ada pada Laboratorium Rekayasa Data dan Intelegensia Bisnis, sehingga tugas akhir ini dapat disimpulkan memiliki relevansi yang sesuai dengan *roadmap* Laboratorium Rekayasa Data dan Intelegensia Bisnis.

BAB II TINJAUAN PUSTAKA

Pada bagian ini akan dijelaskan mengenai studi literatur yang digunakan sebagai objek penelitian tugas akhir serta teori-teori yang mendukung.

2.1 Penelitian Sebelumnya

Pada bagian ini terdapat penelitian sebelumnya yang berhubungan dengan tugas akhir ini dimana akan dijelaskan melalui Tabel 2.1 hingga Tabel 2.3 sebagai berikut.

Tabel 2.1 Penelitian Sebelumnya 1

Judul	Comparison of different ANN techniques in river flow prediction [10]
Penulis / tahun	Ozgur Kisi, H. Kerem Cigizoglu / 2007
Deskripsi Umum Penelitian	Penelitian ini membahas mengenai peramalan <i>river flow event</i> (arus sungai mengalir) baik jangka pendek maupun jangka panjang untuk mengoptimasi sistem atau merencanakan apakah akan ada ekspansi masa depan atau justru pengurangan. Peramalan pada penelitian ini menggunakan beberapa algoritma jaringan syaraf tiruan antara lain <i>Feedforward Backpropagation</i> (FFBP), <i>Generalized Regression Neural Network</i> (GRNN), dan <i>Radial Basis Function Neural Network</i> (RBFNN) yang diaplikasikan terhadap dua tipe data yaitu data kontinyu, dan data intermiten dari data histori dua sungai di Turki.
Hasil Penelitian	Secara garis besar, peramalan dengan metode RBFNN lebih unggul daripada GRNN dan FFBP baik pada peramalan jangka pendek maupun jangka panjang. Pada <i>continues flow</i> , rata – rata prediksi RBFNN yang paling mendekati nilai sebenarnya, sedangkan pada arus intermiten prediksi GRNN yang lebih mendekati nilai sebenarnya. Algoritma GRNN berjalan jauh lebih lama dibandingkan dengan RBFNN dan FFBP.
Relevansi Penelitian	Penelitian ini memiliki metode penelitian yang dapat diunggulkan untuk meramalkan data baik tipe arus kontinyu maupun arus intermiten yaitu

	<i>Radial Basis Function Neural Network (RBFNN)</i> yang paling unggul.
--	---

Tabel 2.2 Penelitian Sebelumnya 2

Judul	Comparative Study of Four Time Series Methods in Forecasting Typhoid Fever Incidence in China Xingyu [8]
Penulis / tahun	Xingyu Zhang, Yuanyuan Liu, Min Yang, Tao Zhang, Alistair A. Young, Xiaosong Li / 2013
Deskripsi Umum Penelitian	Penelitian ini membahas mengenai peramalan insiden penyakit tifus di negara China. Data yang digunakan untuk peramalan ini merupakan data bulanan. Penelitian ini merujuk pada perbandingan performa peramalan dan permodelan antara metode SARIMA (<i>Seasonal Autoregressive Integrated Moving Average</i>) dengan tiga algoritma jaringan syaraf tiruan yaitu <i>Backpropagation Neural Network (BPNN)</i> , <i>Radial Basis Function Neural Network (RBFNN)</i> , dan <i>Elman Recurrent Neural Network (ERNN)</i> . Evaluasi kinerja permodelan dan performa diukur berdasarkan tiga metrik yaitu <i>Mean Absolute Error (MAE)</i> , <i>Mean Absolute Percentage Error (MAPE)</i> , dan <i>Mean Square Error (MSE)</i> .
Hasil Penelitian	Dari hasil permodelan, baik MAE, MAPE, dan MSE menunjukkan RBFNN memiliki nilai terendah, selanjutnya ERNN, BPNN, dan yang terakhir SARIMA. Dari hasil performa prediksi, RBFNN masih memiliki nilai terendah untuk MAE, MAPE, dan MSE. Hasil ini menunjukkan bahwa algoritma jaringan syaraf tiruan memiliki performa yang lebih baik dibandingkan metode SARIMA.
Relevansi Penelitian	Penelitian ini memiliki kesamaan bidang penelitian yaitu bidang kesehatan, dimana penelitian ini meramalkan mengenai tifus, sedangkan penelitian tugas akhir ini meramalkan mengenai difteri. Hasil yang didapatkan dengan metode <i>Radial Basis Function Neural Network (RBFNN)</i> lebih baik dibandingkan metode statistikal seperti SARIMA.

Tabel 2.3 Penelitian Sebelumnya 3

Judul	Radial basis function neural networks for reliably forecasting rainfall [11]
Penulis / tahun	Amr H. El Shafie, A. El-Shafie, A. Almkhtar, Mohd. R. Taha, Hasan G. El Mazoghi, A. Shehata / 2012
Deskripsi Penelitian Umum	<p>Penelitian ini membahas mengenai peramalan curah hujan di kota Alexandria, Egypt. Peramalan dilakukan untuk dapat dijadikan pertimbangan analisis dan desain sistem hidrologi. Peramalan dilakukan dengan menggunakan data sepuluh tahun terakhir dari kota Alexandria. Metode yang digunakan untuk meramalkan adalah dengan <i>Radial Basis Function Neural Network</i> (RBFNN), dan untuk mengetahui kinerja RBFNN, maka peramalan juga dilakukan dengan model statistik yaitu MR (<i>Multi Linear Regression</i>). Untuk mengetahui hasil kinerja dari algoritma RBFNN dan model MR, maka digunakan pengukuran koefisien korelasi (R^2), koefisien korelasi (CE), <i>root mean square error</i> (RMSE), <i>relative root mean square error</i> (RRMSE), dan <i>absolute percentage error</i> (MAPE).</p>
Hasil Penelitian	<p>Untuk ketetapan nilai pengukurannya :</p> <ol style="list-style-type: none"> 1. Semakin besar nilai R^2 (mendekati 90%) maka semakin efisien. 2. Semakin tinggi nilai CE maka semakin efisien. 3. Semakin rendah nilai RMSE dan RRMSE maka semakin rendah error dari model. 4. Jika nilai MAPE semakin mendekati 10% maka model tersebut dapat dikatakan akurat. <p>Dari keempat kategori nilai tersebut, RBFNN memenuhi keempat kategori tersebut jauh dibandingkan MR yang masih memiliki nilai RMSE dan RRMSE yang tinggi, dan nilai R^2 pada MR sangat rendah yaitu 0.2.</p>
Relevansi Penelitian	<p>Penelitian ini memiliki pembuktian bahwa metode <i>machine learning</i> lebih unggul dan akurat jika digunakan untuk peramalan dibandingkan metode statistik seperti MR. Salah satu metode <i>machine learning</i> yang digunakan adalah RBFNN dimana</p>

	metode ini nantinya akan diimplementasikan pada penelitian tugas akhir ini.
--	---

Berdasarkan penelitian sebelumnya yang telah dilakukan, telah didapatkan penjelasan metode studi yang akan dijadikan acuan dalam penelitian ini. Dari beberapa metode yang dilakukan pada penelitian sebelumnya, diketahui bahwa *Radial Basis Function Neural Network* menunjukkan hasil yang lebih baik untuk peramalan data intermiten maupun musiman. Maka dari itu, pada penelitian ini penulis akan mencoba algoritma RBFNN untuk meramalkan penderita difteri, karena belum ada penelitian yang mencoba untuk meramalkan penderita difteri menggunakan metode RBFNN, sehingga penulis ingin melakukan percobaan terhadap implementasi metode ini.

2.2 Dasar Teori

Pada bagian ini membahas mengenai dasar teori apa saja yang penting digunakan dalam pengerjaan tugas akhir ini.

2.2.1 Karakteristik Data

Data yang digunakan untuk melakukan peramalan didapatkan dari Dinas Kesehatan Provinsi Jawa Timur dan Badan Pusat Statistik. Data yang didapatkan dari Dinas Kesehatan Provinsi Jawa Timur terbagi menjadi dua macam data, yaitu data mengenai cakupan imunisasi DPT 1 hingga DPT 4 dan data mengenai jumlah penderita difteri di seluruh kota / kabupaten di Jawa Timur. Data yang didapatkan dari Badan Pusat Statistik adalah data mengenai jumlah penduduk, dan luas wilayah kota/kabupaten di Jawa Timur. Data mengenai cakupan imunisasi tersebut merupakan data per bulan yang berisikan nama daerah (kabupaten / kota di Jawa Timur), total desa, jumlah laki-laki yang telah diimunisasi, presentase keseluruhan laki-laki yang telah diimunisasi, jumlah perempuan yang telah diimunisasi, presentase keseluruhan perempuan yang telah diimunisasi, jumlah keseluruhan laki-laki dan perempuan yang telah diimunisasi, presentase keseluruhan imunisasi di daerah

Nama Kab./Kota	Kasus Difteri												
	< 1 tahun		1 - 4 tahun		5 - 9 tahun		10 - 14 tahun		> 14 tahun		Total		
	Vaksinasi	Total	Vaksinasi	Total	Vaksinasi	Total	Vaksinasi	Total	Vaksinasi	Total	Meninggal	Vaksinasi	Total
Sidoarjo	0	0	2	2	0	0	0	0	0	1	0	2	3
Mojokerto	0	0	0	0	0	0	0	0	0	3	0	0	3
Jombang	0	0	0	0	0	0	0	0	0	0	0	0	0
Bojo negoro	0	0	0	0	0	0	0	0	0	0	0	0	0
Tuban	0	0	0	0	0	0	0	0	0	1	0	0	1
Lamongan	0	0	0	0	0	0	0	0	0	0	0	0	0

Data mengenai jumlah penduduk berisikan kategori area (desa atau kota atau desa+kota), kategorisasi umur (0 sampai 75+ dengan interval 4 tahun), jumlah penduduk setiap tahun mulai dari 2010 hingga 2020 berdasarkan kategorisasi umur, dan total jumlah penduduk keseluruhan. *Preview* data jumlah penduduk dapat dilihat pada Gambar 2.1. Data mengenai luas wilayah suatu daerah berisikan nama kota/kabupaten, luas wilayah dalam satuan km², persentase luas wilayah terhadap provinsi Jawa Timur, dan total keseluruhan luas wilayah dan persentase. *Preview* data luas wilayah dapat dilihat pada Gambar 2.2.

Untuk persebaran jumlah penderita di setiap daerah sangatlah beragam, beberapa contoh jumlah persebaran penderita difteri di berbagai kota atau kabupaten di Jawa Timur dapat dilihat pada Gambar 2.3 untuk persebaran jumlah penderita di kota Sumenep, dan Gambar 2.4 untuk persebaran jumlah penderita di kabupaten Malang, serta Gambar 2.5 untuk persebaran jumlah penderita di kota Surabaya. Total *rows* yang digunakan untuk menghasilkan satu permodelan adalah sejumlah 72 *rows*.


KABUPATEN MALANG

Kota+Desa	Laki-Laki+Perempuan						
	UMUR	2010	2011	2012	2013	2014	2015
	(1)	(2)	(3)	(4)	(5)	(6)	(7)
0-4		196.516	198.088	199.571	200.968	202.409	203.757
5-9		196.241	197.805	199.280	200.672	202.105	203.446
10-14		197.887	199.478	200.978	202.395	203.850	205.216
15-19		190.028	191.547	192.980	194.332	195.727	197.031
20-24		186.904	188.376	189.763	191.070	192.424	193.682


Gambar 2.1 Preview data jumlah penduduk di Kabupaten Malang

Kabupaten/Kota <i>Regency/Municipality</i>	Luas (km ²) <i>Total Area (km²)</i>	Persentase <i>Percentage</i>
(1)	(2)	(3)
Kabupaten/Regency		
1. Pacitan	1 389,92	2,91
2. Ponorogo	1 305,70	2,73
3. Trenggalek	1 147,22	2,40
4. Tulungagung	1 055,65	2,21
5. Blitar	1 336,48	2,80
6. Kediri	1 386,05	2,90
7. Malang	3 530,65	7,39
8. Lumajang	1 790,90	3,75
9. Jember	3 092,34	6,47


Gambar 2.2 Preview data luas wilayah kota/kabupaten di Jatim



Gambar 2.3 Persebaran jumlah penderita difteri di kota Sumenep



Gambar 2.4 Persebaran jumlah penderita difteri di kabupaten Malang



Gambar 2.5 Persebaran jumlah penderita difteri di kota Surabaya

2.2.2 Uji Korelasi

Korelasi merupakan teknik statistik untuk mengukur bentuk hubungan antar variabel dan kekuatan hubungan antar variabel tersebut. Bentuk hubungan yang dimaksud adalah hubungan linear antar variabel, lalu kekuatan yang dimaksud antar variabel apakah kuat, sedang, atau lemah [12]. Terdapat beberapa macam uji korelasi, salah satunya adalah Spearman. Uji korelasi Spearman adalah suatu teknik untuk menguji signifikansi suatu asosiasi antar variabel yang telah disusun menurut peringkat. Selain Spearman, terdapat juga uji korelasi Pearson. Perbedaan diantara keduanya adalah uji korelasi Pearson merupakan uji korelasi parametrik sedangkan uji korelasi Spearman non-parametrik. Dasar yang digunakan untuk pengambilan keputusan kekuatan korelasi pada adalah [12]:

- .00 - .19 Sangat lemah
- .20 - .39 Lemah
- .40 - .59 Sedang
- .60 - .79 Kuat
- .80 - 1.0 Sangat Kuat

2.2.3 Difteri

Difteri merupakan suatu penyakit yang disebabkan oleh bakteri Gram positif yaitu *Corynebacterium diphtheria*. Bakteri ini tidak hanya mempengaruhi saluran pernafasan, tetapi juga dapat menyebabkan penyakit kulit dan bersifat invasi.

Selama era pra-imunisasi, difteri adalah infeksi umum di kalangan anak-anak dan dikaitkan dengan tingkat kematian yang tinggi [13]. Beberapa gejala yang timbul jika pasien menderita penyakit difteri adalah sakit tenggorokan, malaise [5], batuk dan pilek ringan, demam dengan suhu tubuh meningkat sampai 38,9 derajat Celcius [2], dan pemeriksaan fisik ditemukan bengkak pada leher (*bull neck*) [14]. Penularan difteri dapat melalui *droplet*, kontak langsung dengan sekresi saluran pernafasan dari penderita difteri atau penderita yang bersifat *carrier* [5] dan dapat juga menular melalui udara [15]. Beberapa faktor yang dapat menyebabkan difteri adalah kepadatan penduduk, kondisi kesehatan yang buruk, kondisi hidup di bawah standar, imunisasi yang tidak lengkap, serta fasilitas kesehatan yang kurang memadai. Biasanya, *human carrier* adalah sumber infeksi utama, namun banyak kasus yang dilaporkan memiliki hubungan dengan hewan ternak [16]. Penyakit difteri dapat dicegah dengan vaksin. Vaksinasi terhadap difteri telah mengurangi angka kematian secara drastis, namun difteri akan masih menjadi suatu permasalahan pada anak – anak di negara – negara dengan cakupan program vaksinasi yang rendah [3]. Namun, difteri akan terus akan menjangkit jika program vaksinasi tidak terkontrol dengan baik bahkan pada negara yang sudah memiliki kontrol terhadap difteri [1].

2.2.3.1 Vaksinasi Difteri

Imunisasi merupakan salah satu upaya yang dilakukan guna mencegah terjadinya penyakit menular seperti penyakit difteri. Daya imunitas individu dipengaruhi oleh frekuensi pemberian imunisasi dasar pada usia anak. Status imunisasi yang tidak

lengkap akan berpengaruh kejadian penularan penyakit difteri pada anak dengan risiko yang lebih besar dibandingkan dengan anak dengan status imunisasi yang lengkap [6]. Cakupan imunisasi suatu daerah juga memiliki pengaruh terhadap jumlah penderita [1]. Dari hasil penelitian yang dilakukan sebelumnya oleh [17] menunjukkan bahwa semakin rendah cakupan imunisasi DPT3 maka jumlah kasus difteri yang terjadi di wilayah tersebut semakin tinggi. Pencegahan difteri melalui vaksin DPT, singkatan dari Difteri-Petrusis-Tetanus, dapat dilakukan sedini mungkin. Pemberian vaksin DPT di dosis selama tiga kali vaksinasi. Pada anak – anak yang berusia kurang dari satu tahun, tahap pertama pada saat usia sedini mungkin yaitu 6 minggu, pemberian vaksin tahap kedua diberi jarak 4 minggu setelah vaksin pertama, selanjutnya pemberian tahap ketiga dilakukan pada usia 6 bulan. Pada anak – anak yang berusia 1 – 7 tahun, pemberian vaksin kedua diberikan selang waktu 4 minggu setelah vaksin pertama diinjeksi, dan pemberian tahap ketiga diberi selang waktu 6 bulan setelah vaksin kedua [18]. Untuk vaksin difteri pada anak – anak usia 1 – 7 tahun dan orang dewasa memiliki jenis vaksin yang berbeda. Vaksin difteri tersebut yaitu menggunakan vaksin Td (*tetanus-diphtheria*) atau Tdap (*tetanus-diphtheria-acellular pertussis*), yaitu vaksin DPT dengan reduksi antigen dan pertusis. Dalam vaksin Tdap menggunakan komponen pertusis aseluler, yaitu bakteri pertusis yang dibuat tak aktif sehingga jarang menyebabkan demam [19]. Pemberian vaksin kedua memiliki selang waktu 4 minggu, dan vaksin ketiga memiliki selang waktu 6 bulan setelah vaksin kedua. Pemberian vaksin Booster juga direkomendasikan dengan selang waktu setidaknya satu tahun setelah vaksin Tdap terakhir [18].

2.2.4 Peramalan

Peramalan merupakan ilmu yang digunakan untuk memprediksi sesuatu yang kemungkinan besar akan terjadi se akurat mungkin dengan menggunakan data historis serta pengetahuan analisis untuk masa mendatang [20]. Peramalan juga sangat dibutuhkan

dalam dunia bisnis, keuangan, ekonomi, pemerintahan dan banyak lembaga lainnya [21]. Contoh peramalan antara lain adalah pengambilan keputusan apakah akan membangun pabrik baru dalam lima tahun kedepan untuk memenuhi kebutuhan permintaan masa mendatang; melakukan peramalan mengenai panggilan *call center* yang berguna untuk penjadwalan karyawan dalam periode yang diramalkan; melakukan pemasokan bahan baku dalam jumlah tertentu di masa mendatang. Peramalan dapat dilakukan secara jangka pendek (harian atau per jam), jangka menengah (triwulan), maupun jangka panjang (tahunan atau dekade) [20].

2.2.4.1 Data Peramalan

Untuk melakukan peramalan tentunya dibutuhkan data untuk memprediksi kemungkinan di masa mendatang. Terdapat tiga tipe data peramalan [22] [23], yaitu :

1. *Data Cross Sectional*
Data *cross sectional* merupakan data yang ditampilkan atau dikumpulkan pada satu titik waktu tertentu. Contoh data *cross sectional* adalah data produksi bahan baku selama bulan Maret 2019.
2. *Data Time Series*
Data *time series* adalah data yang terdiri dari satu objek namun terdiri dari beberapa waktu periode, seperti harian, bulanan, triwulanan, dan tahunan. Contoh data *time series* adalah data pertumbuhan PDB dari tahun 2009 sampai 2013.
3. *Data Panel*
Data panel merupakan gabungan antara data *cross sectional* dan *time series* yaitu data yang terdiri atas beberapa objek dalam beberapa periode waktu.

2.2.4.2 Metode Peramalan

Pemilihan metode peramalan bergantung pada aspek waktu, pola data yang ingin diramalkan, tingkat akurasi peramalan

yang diinginkan, dan lain sebagainya. Metode peramalan dibagi menjadi dua kategori utama [23], yaitu :

1. Metode Kuantitatif

Metode peramalan kuantitatif dapat diterapkan apabila:

- Tersedia informasi mengenai masa lalu,
- Informasi tersebut dapat diubah kedalam bentuk numerik (kuantifikasi), dan
- Dapat diasumsikan bahwa beberapa aspek pola masa lalu akan terus berlanjut di masa mendatang.

Terdapat dua tipe model peramalan kuantitatif yaitu :

1. Model *Time Series*

Prediksi di masa depan dilakukan berdasarkan nilai masa lalu dari suatu variabel dan/atau kesalahan masa lalu.

2. Model Kausal / Eksplanatoris

Mengasumsikan bahwa terdapat hubungan sebab akibat diantara input dengan output dari suatu sistem.

2. Metode Kualitatif

Metode kualitatif digunakan jika adanya keterbatasan data, tidak tersedianya data, atau data yang tidak lagi relevan. Peramalan dengan metode ini berdasarkan keahlian dan pengalaman peramal dan informasi yang tersedia. Hasil peramalan ditentukan berdasarkan pendapat, pengetahuan, serta pengalaman dari penyusunnya.

2.2.5 Artificial Neural Network (Jaringan Syaraf Tiruan)

Artificial Neural Network (jaringan syaraf tiruan) pertama kali diperkenalkan oleh McCulloch dan Pitts di tahun 1943. ANN adalah salah satu metode *machine learning* yang memiliki karakteristik kinerja yang sama dengan jaringan syaraf manusia (neuron) untuk melakukan pemrosesan informasi [24]. Jaringan

syaraf tiruan memproses sejumlah besar informasi secara paralel dan terdistribusi, hal ini terinspirasi oleh model kerja otak biologis [25], jaringan syaraf juga terdiri dari beberapa neuron dan terdapat hubungan antara neuron-neuron tersebut [26]. Dalam ANN, kejadian masa lalu dikirim ke neuron *input* kemudian kejadian yang akan diperkirakan akan dihasilkan dari neuron *output* setelah jaringan dilatih secara memadai. Jaringan “mempelajari” informasi yang terkandung dengan menyesuaikan interkoneksi antar lapisan [8]. Jaringan syaraf tiruan mampu mengenali pola atau kegiatan berdasarkan data masa lalu (*track record*). Data tersebut akan dipelajari oleh jaringan syaraf tiruan sehingga memiliki kemampuan *decision making* terhadap data yang belum pernah terjadi (data di masa depan) [27].

Jaringan syaraf memiliki tiga elemen pembentuk, yaitu :

1. Pola hubungan antara arsitektur jaringan
2. Metode penentuan bobot pada jaringan (metode pelatihan atau pembelajaran)
3. Fungsi aktivasi yang dikerjakan pada neuron


Jaringan syaraf tiruan terdiri dari kumpulan kelompok syaraf yang tersusun dalam lapisan [25] [28] :

1. Lapisan input (*Input Layer*) : berfungsi sebagai penghubung jaringan ke dunia luar (sumber data)
2. Lapisan tersembunyi (*Hidden Layer*) : unit – unit di dalam lapisan tersembunyi disebut unit – unit tersembunyi. Suatu jaringan dapat memiliki lebih dari satu hidden layer atau bahkan bisa juga tidak memilikinya sama sekali.
3. Lapisan Output (*Output Layer*): Prinsip kerja neuron-neuron pada lapisan ini sama dengan prinsip kerja neuron-neuron pada lapisan tersembunyi (*hidden layer*) dan di sini yang digunakan fungsi aktivasi yang digunakan adalah fungsi aktivasi berbasis radial.


2.2.5.1 Arsitektur Jaringan Syaraf Tiruan

Jaringan syaraf tiruan memiliki beberapa arsitektur, yaitu [25] [28] [29]:


1. Jaringan Layar Tunggal (*Single Layer Network*)
Jaringan dengan lapisan tunggal terdiri dari 1 *layer input* dan 1 *layer output*. Setiap unit yang terdapat di dalam lapisan / *layer input* selalu terhubung dengan setiap neural yang terdapat pada *layer output*. Sehingga ketika jaringan ini menerima input, langsung diolah dan menjadi *output* tanpa melalui *hidden layer*. Arsitektur jaringan layar tunggal dapat dilihat pada Gambar 2.6.
2. Jaringan Layar Jamak (*Multi Layer Network*)
Jaringan dengan lapisan jamak memiliki ciri khas tertentu yaitu memiliki 3 jenis layer yakni layer input, layer output, layer tersembunyi. Jaringan dengan banyak lapisan ini dapat menyelesaikan permasalahan yang kompleks dibandingkan jaringan dengan lapisan tunggal. Namun proses pelatihan sering membutuhkan waktu yang cenderung lama. Arsitektur jaringan layar jamak dapat dilihat pada Gambar 2.7.
3. *Reccurent Neural Network (RNN)*
RNN menyimpan informasi dari masa lalu adalah dengan melakukan looping di dalam arsitekturnya, yang secara otomatis membuat informasi dari masa lalu tetap tersimpan. Arsitektur RNN dapat dilihat pada Gambar 2.8.



Gambar 2.6 Arsitektur Single Layer Network



Gambar 2.7 Arsitektur Multi Layer Network



Gambar 2.8 Arsitektur Recurrent Neural Network

(Sumber [30])

2.2.5.2 Pembelajaran dan Pelatihan Jaringan Syaraf Tiruan

Salah satu proses terpenting dalam konsep JST adalah proses pembelajaran. Tujuan dari proses pembelajaran pada JST ini adalah untuk melakukan pengaturan bobot – bobot pada jaringan syaraf sehingga diperoleh bobot akhir yang sesuai dengan pola data yang dilatih. Terdapat tiga metode pembelajaran untuk JST, diantaranya *Supervised Learning* (Pembelajaran Terawasi), *Unsupervised Learning* (Pembelajaran Tidak Terawasi) [31], dan *Hybrid Learning* (Pembelajaran Hibrida atau Gabungan) [28] :

1. *Supervised Learning* (Pembelajaran Terawasi)
 Pada proses pembelajaran ini, satu *input* yang telah diberikan pada satu neuron di lapisan *input* akan dijalankan di sepanjang jaringan syaraf sampai ke neuron pada lapisan *output*. Hasil *output* yang diperoleh kemudian dicocokkan dengan target, jika terjadi perbedaan, maka akan muncul *error*. Jika nilai *error* cukup besar, akan dilakukan pembelajaran yang lebih banyak lagi. Contoh algoritma jaringan syaraf tiruan yang menggunakan metode ini adalah : *Hebbian*, *Perceptron*, *ADALINE*, *Boltzman*, *Hopfield*, *Backpropagation*.
2. *Unsupervised Learning* (Pembelajaran Tidak Terawasi)
 Pada proses pembelajaran ini, nilai bobot disusun dalam suatu interval tertentu tergantung dari nilai *input* yang diberikan. Pembelajaran ini bertujuan mengelompokkan unit-unit yang hampir sama dalam satu area tertentu. Pembelajaran ini biasanya sangat cocok untuk klasifikasi pola. Contoh algoritma jaringan syaraf tiruan yang menggunakan metode ini adalah : *Competitive*, *Hebbian*, *Kohonen*, *LVQ (Learning Vector Quantization)*, *Neocognitron*.
3. *Hybrid Learning* (Pembelajaran Hibrida atau Gabungan)
 Merupakan kombinasi dari metode pembelajaran *Supervised Learning* dan *Unsupervised Learning*,


sebagian dari bobot-bobotnya ditentukan melalui pembelajaran terawasi dan sebagian lainnya melalui pembelajaran tak terawasi. Contoh algoritma jaringan syaraf tiruan yang menggunakan metode ini adalah: *Radial Basis Function*.

2.2.5.3 Radial Basis Function Neural Network (RBFNN)

Radial Basis Function Neural Network terdiri dari tiga lapisan, yaitu lapisan *input* (*input layer*), lapisan tersembunyi (*hidden layer*) dan lapisan *output* (*output layer*). Lapisan *input* menerima suatu vektor *input* x yang kemudian dibawa ke lapisan tersembunyi yang akan memproses data *input* secara nonlinear dengan fungsi aktivasi. Output dari lapisan tersembunyi selanjutnya diproses di lapisan output secara linear [32]. Arsitektur RBFNN dapat dilihat pada Gambar 2.9.

Terdapat tiga lapisan pada arsitektur RBFNN [26] :

1. Lapisan pertama disebut *input layer* yang berisi titik (*node*) yang disusun dari variabel prediktor sebanyak R_0 .
2. Lapisan kedua disebut *hidden layer* yang terdiri dari *hidden unit*. Setiap *hidden unit* merupakan fungsi radial basis yang dinotasikan sebagai φ_{ik} .
3. Pada lapisan ketiga terdapat *output layer* yang terdiri dari unit tunggal yang linier.



Gambar 2.9 Arsitektur RBFNN

(Sumber [26])

Radial Basis Function Neural Network sering dinyatakan sebagai bagian dari *Multilayer Perceptron Network* dikarenakan memiliki arsitektur jaringan yang hampir sama. Walaupun memiliki arsitektur yang hampir sama dengan MLP, namun kinerja atau performa keduanya sangat berbeda. Arsitektur jaringan pada RBFNN lebih *simple* jika dibandingkan arsitektur MLP dimana MLP memiliki lebih dari tiga lapisan, sehingga proses pembelajaran pada jaringan RBFNN lebih cepat dibandingkan *Neural Network* biasa atau biasanya MLP. Untuk menangani *noise* pada data, RBFNN lebih toleransi terhadap data *noise* dibandingkan NN tradisional baik pada saat proses pembelajaran hingga implementasi ke proses pengujian [33].

RBFNN memiliki dua fungsi yaitu *newrbe* dan *newrb*. Perbedaan diantara kedua fungsi tersebut adalah *newrbe* memiliki jumlah neuron sebanyak jumlah input yang terbentuk, sedangkan pada *newrb* setiap iterasi akan dibentuk 1 neuron. Neuron yang memiliki total *error* terkecil akan diterima sebagai neuron baru. Kemudian *error* pada jaringan akan diperiksa kembali, jika *error* jaringan sudah cukup kecil maka iterasi dihentikan. Tetapi jika *error* jaringan masih cukup besar, maka akan ditambahkan neuron berikutnya, demikian seterusnya. Pada fungsi *newrb*, jumlah neuron pada lapisan tersembunyi belum tentu akan sama dengan jumlah vektor inputnya, dengan kata lain tidak semua lapisan *input* pada data dapat digunakan untuk pemodelan. Fungsi *newrb* dapat menciptakan dua lapis jaringan. Lapisan pertama memiliki neuron radbas dan lapisan kedua memiliki neuron purelin. Pada awalnya lapisan radbas tidak memiliki neuron, kemudian langkah-langkah yang ada di bawah ini diulang

hingga nantinya akan mendapatkan kesalahan terkecil pada jaringan [26].

1. Mensimulasikan jaringan
2. Memasukkan vektor yang memiliki *error* terbesar
3. Menambahkan neuron radial basis dengan bobot sama
4. Mendesain ulang lapisan purelin untuk meminimalkan *error*

2.2.5.4 Algoritma RBFNN

Algoritma perhitungan *Radial Basis Function Neural Network* adalah sebagai berikut [26] [34] :

1. Inisialisasi *center* dan mencari jarak *Euclidean* dengan persamaan

$$\|x_{ij} - x_{kj}\| = D_{ik} = \sqrt{\sum_{j=1}^n (x_{ij} - x_{kj})^2}$$

2. Hitung nilai aktivasi dengan menggunakan fungsi basis radial. Fungsi aktivasi berbasis radial terdapat delapan macam yang bisa diterapkan, yaitu :

- Fungsi *Gaussian*

$$\phi_{ij} (\|x - c_i\|) = \exp\left(-\frac{\|x - c_i\|^2}{2\sigma_j^2}\right)$$

Dengan x adalah *input*, c_i pusat data ke- i , $i = 1, 2, 3, \dots, n$ dan σ_j^2 adalah standar deviasi ke- j , $j = 1, 2, 3, \dots, n$ dengan n adalah banyak pusat data.

- Fungsi *Multi-Quadric*

$$\phi(r) = (r^2 + \sigma^2)^{1/2}$$

parameter $\sigma > 0$

- Fungsi *Generalized Multi-Quadric*

$$\phi(r) = (r^2 + \sigma^2)^\beta$$

parameter $\sigma > 0, 1 > \beta > 0$

- Fungsi *Inverse Multi-Quadric*

$$\phi(r) = (r^2 + \sigma^2)^{-1/2}$$

parameter $\sigma > 0$

- Fungsi *Generalized Inverse Multi-Quadric*

$$\varphi(r) = (r^2 + \sigma^2)^\alpha$$

parameter $\sigma > 0, 1 > \alpha > 0$

- Fungsi *Thin Plate Spline*

$$\varphi(r) = r^2 \ln(r)$$

- Fungsi *Cubic*

$$\varphi(r) = r^3$$

- Fungsi *Linier*

$$\varphi(r) = r$$

3. Nyatakan ke dalam matriks G dengan baris dan kolom. Dapat dinotasikan sebagai berikut :

$$\mathbf{G} \mathbf{w} = \mathbf{d}$$

$$\text{dimana } \mathbf{d} = [d_1 \ d_2 \ \dots \ d_n]^T$$

$$\mathbf{w} = [w_1 \ w_2 \ \dots \ w_n]^T$$

$$\text{dan } \mathbf{G} = \varphi_{nn}$$

4. Hitung keluaran bobot dengan rumus sebagai berikut :

$$\mathbf{w} = (\mathbf{G}^T \mathbf{G})^{-1} \mathbf{G}^T \mathbf{d}$$

5. Menghitung *output* RBF dengan menggunakan persamaan :

$$y(x) = \sum_{i=1}^j w_i G(\|x - c_i\|) + b$$

2.2.6 Evaluasi Hasil Peramalan

Evaluasi peramalan dilakukan untuk melakukan akurasi dari hasil peramalan yang telah dilakukan sebelumnya. Terdapat beberapa metode untuk mengukur perhitungan kesalahan peramalan, diantaranya [35][36]:

1. *Mean Squared Error* (MSE)

MSE merupakan salah satu metode untuk mengevaluasi peramalan. Kriteria MSE menyatakan besarnya kesalahan rata-rata kuadrat dari suatu metode peramalan, dengan rumus perhitungan :

$$MSE = \sum_{t=1}^n \left(\frac{y - y'}{n} \right)^2$$

Perhitungan akurasi dengan menggunakan pendekatan MSE ini cenderung memiliki penalti yang besar karena error yang dikuadratkan, maka dari itu biasanya jika menggunakan pengukuran ini dilihat nilai yang paling kecil, namun terkadang pada beberapa permasalahan justru yang paling besar diantara yang lain.

2. Mean Absolute Deviation (MAD)

Pengukuran lain yang dapat digunakan adalah MAE atau MAD (*mean absolute deviation*). Merupakan pengukuran dengan melakukan rata-rata pada nilai error absolut.

$$MAD = \frac{1}{n} \sum_{i=1}^n |Y_t - F_t|$$

3. Mean Absolute Scaled Error (MASE)

MAPE merupakan alternatif pengukuran yang paling banyak digunakan untuk mengukur kesalahan / error pada hasil peramalan dengan persentase kesalahan dari data aktual. Namun, kekurangan terbesar dari pengukuran MAPE adalah hanya bisa digunakan dengan data yang berskala rasio (tidak boleh ada data 0 didalamnya), sehingga tidak bisa digunakan sebagai pengukuran data intermitten. Permasalahan asimetris tersebut telah diselesaikan oleh Makridakis di tahun 1993 dengan menggunakan pengukuran sMAPE [37], namun SMAPE sendiri akan memiliki nilai *undefined* atau *division by zero* jika nilai aktual dan peramalan sama – sama 0. Oleh karena itu, pendekatan lain (alternatif) lain menggunakan MASE. Pengukuran ini dikenalkan oleh Hyndman dan Koehler di tahun 2006 untuk pengukuran data intermiten. Hyndman dan Koehler mengajukan skala eror berdasarkan *in-sample* MAE yang didapatkan dengan menggunakan metode

naive. Dimana metode *naive* sendiri merupakan peramalan 1 periode setelahnya. Skala error didefinisikan sebagai berikut :

$$q_t = \frac{e_t}{\frac{1}{n-1} \sum_{t=2}^n |Y_t - Y_{t-1}|}$$

Sehingga, MASE sendiri didefinisikan sebagai berikut :

$$MASE = \text{mean}(|q_t|)$$

Ketika nilai MASE lebih dari 1, maka peramalan dengan metode *naive* memiliki performa yang lebih bagus daripada metode yang digunakan. Sebaliknya jika kurang dari 1 atau mendekati 0 maka memiliki performa yang lebih baik.

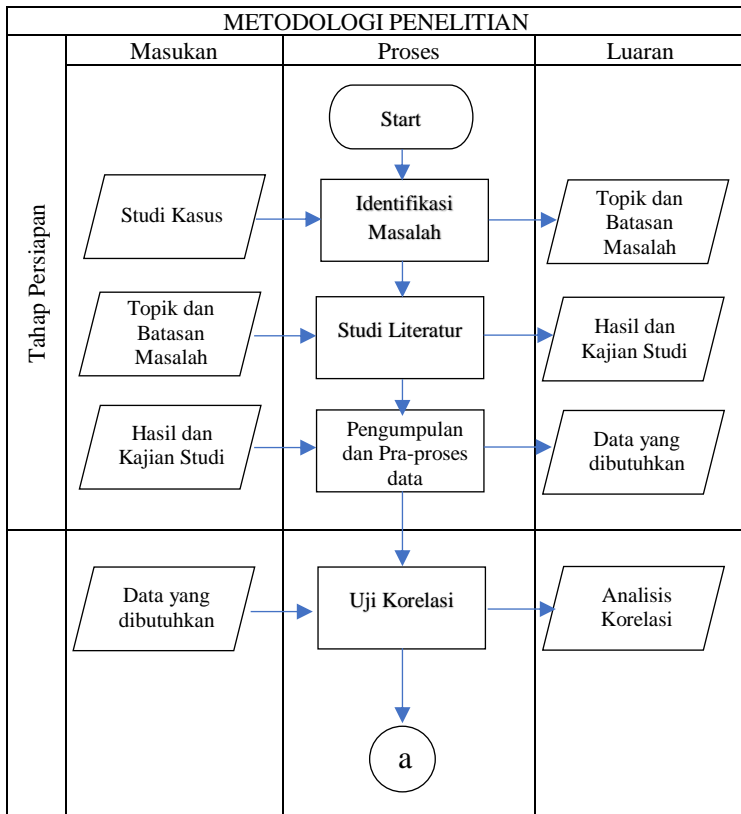
Halaman sengaja dikosongkan

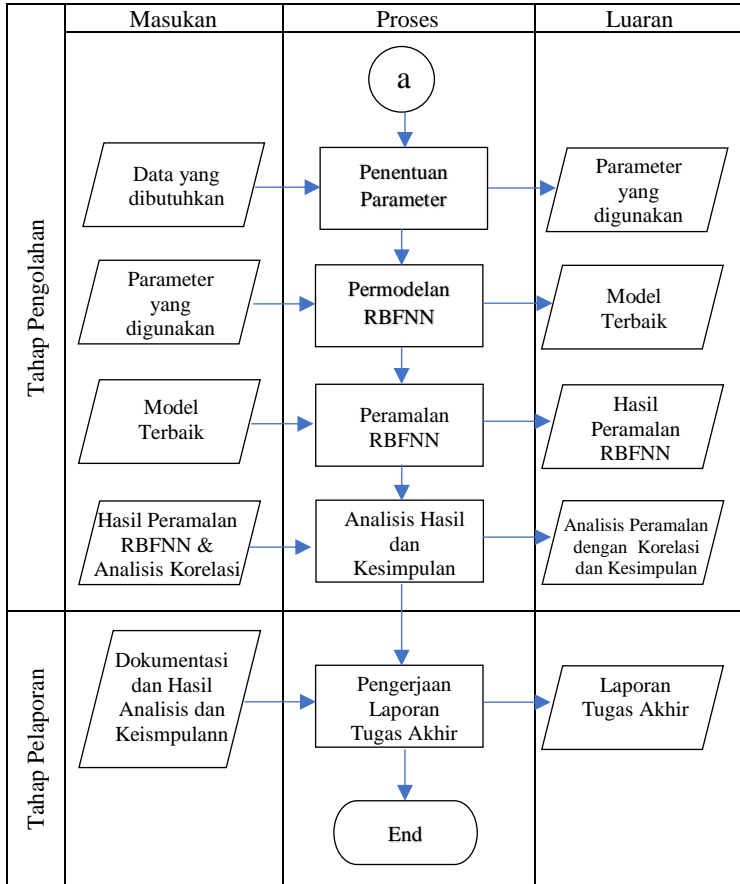
BAB III METODOLOGI PENELITIAN

3.1 Tahapan Pelaksanaan Tugas Akhir

Pada bab ini akan menjelaskan tentang metodologi yang akan digunakan untuk mengerjakan tugas akhir. Metodologi ini digunakan sebagai panduan dan memberikan alur pengerjaan tugas akhir yang sistematis. Alur metodologi pengerjaan tugas akhir dapat dilihat pada Tabel 3.1.

Tabel 3.1 Alur Pengerjaan Tugas Akhir





3.1.1 Identifikasi Masalah

Identifikasi masalah yang dilakukan adalah mencari tahu permasalahan yang ada terkait bidang kesehatan khususnya penyakit yang sedang diwaspadai masyarakat Indonesia baru-baru ini, yaitu difteri. Dari penggalan analisis tersebut, ditemukan topik permasalahan yang kemudian diangkat menjadi penelitian pada tugas akhir ini. Dengan batasan – batasan yang ada seperti cakupan area yang diteliti yaitu Surabaya dan Malang, maka topik permasalahan dan batasan

tersebut digunakan untuk melakukan studi literatur ditahap selanjutnya.

3.1.2 Studi Literatur

Dengan adanya permasalahan yang sudah didapatkan, dilakukanlah studi literatur dengan cara mengumpulkan dan memahami referensi seperti jurnal, *paper*, buku, artikel, dan penelitian-penelitian terkait. Tahap ini bertujuan agar penulis dapat memahami dasar-dasar teori yang akan menjadi dasar ilmu serta konsep dalam pengerjaan penelitian tugas akhir ini. Berdasarkan hasil studi literatur tersebut berupa kajian, didapatkan bahwa penulis mengusulkan metode *Radial Basis Function Neural Network* untuk meramalkan jumlah kasus (penderita) difteri di Kota Surabaya, Kabupaten Malang, dan Kota Sumenep karena metode yang diusulkan memiliki keunggulan-keunggulan yang tidak dimiliki metode *neural network* lainnya sebagaimana yang telah dijelaskan pada sub bab 2.1 dan sub bab 2.2.5.3.

3.1.3 Pengumpulan dan Pra-proses Data

Tahap selanjutnya adalah pengumpulan data yang dapat digunakan untuk menunjang pelaksanaan proses penelitian pada tugas akhir ini. Data yang dibutuhkan untuk keperluan penelitian tugas akhir ini adalah data penderita difteri di Jawa Timur, termasuk disetiap Kota atau Kabupaten, beserta data cakupan imunisasi dan kepadatan penduduk. Data tersebut didapatkan melalui Dinas Kesehatan Provinsi Jawa Timur dengan riwayat yang digunakan dalam penelitian ini adalah dari Januari 2013 hingga Desember 2018 dan Badan Pusat Statistik. Data yang digunakan untuk penelitian ini memiliki karakteristik sebagaimana yang telah dijelaskan pada sub bab 2.2.1. Data tersebut kemudian dilakukan pra-proses data dan uji korelasi. Dari proses tersebut didapatkan keseluruhan data yang digunakan. Pembagian data yang digunakan yaitu 75% untuk data pelatihan (*training set*), 25% untuk data pengujian (*testing set*).

3.1.4 Penentuan Parameter

Berbagai macam variasi parameter digunakan pada implementasi metode di penelitian tugas akhir ini yang bertujuan untuk mencari dan menghasilkan hasil terbaik dari kombinasi parameter yang digunakan. Parameter untuk RBFNN yang terdapat didalam *tools* MATLAB terdiri dari dua parameter yaitu *Spread Constant* dan *Performance Goal*. Kedua parameter ini terdapat didalam fungsi *newrb* sebagaimana yang telah dijelaskan pada sub bab 2.2.5.3 dengan cara kerja yang telah dijelaskan pada sub bab 2.2.5.4. Kedua parameter inilah yang akan menentukan akurasi dari proses pelatihan data dan menghasilkan MSE, MAD dan MASE sebagai tolak ukur akurasi pelatihan sebagaimana yang telah dijelaskan pada sub bab 2.2.5.5.

3.1.5 Permodelan RBFNN

Setelah parameter ditentukan, selanjutnya membuat model berupa arsitektur yang sesuai dengan metode yang digunakan yaitu *Radial Basis Function Neural Network*. Fungsi yang digunakan pada MATLAB untuk permodelan RBFNN adalah menggunakan fungsi *newrb*. Data yang akan digunakan sebagai permodelan adalah perwakilan data disetiap *kelompok* (Surabaya, Kabupaten Malang, dan Sumenep). Data dibagi menjadi dua yaitu data pelatihan dengan komposisi 75% dan data pengujian dengan komposisi 25%. Pembuatan model untuk RBFNN ini diantaranya adalah :

- a. Penetapan variabel yang digunakan sebagai data *input* (cakupan imunisasi sebagaimana yang telah dijelaskan pada sub bab 2.2.3.1, dan kepadatan penduduk) dimana penetapan variabel ini terdapat dua model yaitu berdasarkan uji korelasi sebagaimana yang telah dijelaskan pada sub bab 2.2.2 dan kombinasi variabel untuk mencoba model terbaik.
- b. Penetapan variabel yang digunakan sebagai data *output* (yaitu variabel target, dalam penelitian ini adalah jumlah penderita).

- c. Proses pelatihan merupakan proses pengenalan terhadap pola data yang bertujuan menyesuaikan antara data *input* dengan data *output* yang diinginkan. Proses pengenalan pola data ini dilakukan dengan mengubah-ubah nilai *spread constant*, penentuan *performance* sebagai target *Mean Squared Error*. Perubahan nilai *spread* akan mempengaruhi kerja jaringan yang optimal.
- d. Proses pengujian dilakukan dengan menerapkan model yang telah didapatkan dari proses pelatihan. Proses pengujian digunakan untuk mengetahui apakah jaringan terbaik yang diperoleh dari proses pelatihan memang sudah benar baik atau belum dengan melihat dari MASE dan kesesuaian pola grafik. Hasil MASE yang terkecil dari proses pengujian dan yang memiliki kesesuaian pola grafik, maka kandidat model itulah yang akan dilakukan validasi terhadap data lain.
- e. Proses validasi model dilakukan dengan menerapkan kandidat model terpilih kedalam data yang lain. Proses ini untuk mengetahui apakah model yang diterapkan tersebut layak digunakan atau tidak dengan cara dilihat dari kesesuaian model mengikuti pola data dan hasil MSE, MAD atau MASE. Model yang dapat mengikuti pola grafik dan memiliki MSE, MAD atau MASE terkecil, maka model itulah yang digunakan untuk peramalan.

3.1.6 Peramalan RBFNN

Tahap selanjutnya adalah tahap peramalan terhadap data yang sudah disiapkan. Dimana pada tahap ini peramalan dilakukan selama dua tahun (mulai dari Januari 2019 hingga Desember 2020) dengan periode bulanan. Dengan menggunakan permodelan terbaik yang sebelumnya telah dilakukan, maka model tersebut diimplementasikan untuk melakukan peramalan. Peramalan menggunakan *tools* yaitu MATLAB.

3.1.7 Analisis Hasil dan Kesimpulan

Pemilihan model terbaik adalah berdasarkan model yang dapat mengikuti kesesuaian pola grafik dan memiliki nilai performa MSE, MAD dan/atau MASE terendah dari semua model yang ada. Kegiatan analisis dilakukan dengan membandingkan hasil peramalan dengan data asli dan memperlihatkan tingkat akurasi dari peramalan tersebut dengan parameter MASE serta melakukan peramalan selama dua tahun kedepan. Selain itu juga melakukan analisis apakah model yang dibangun (model unggulan) akan bernilai bagus jika diimplementasikan ke dalam data yang lain. Setelah dilakukan kegiatan analisis hasil, maka selanjutnya dilakukan penarikan kesimpulan berdasarkan hasil yang diperoleh.

3.1.8 Pengerjaan Laporan Tugas Akhir

Setelah semua tahap diatas dilakukan, maka selanjutnya tahap terakhir ini dilakukan. Tahap ini bertujuan untuk melaporkan seluruh hasil pekerjaan yang telah dilakukan dalam menyelesaikan permasalahan. Tugas Akhir ini mendokumentasikan rangkaian proses implementasi *Radial Basis Function Neural Network* untuk peramalan jumlah kasus difteri. Luaran dari tahap ini yaitu laporan tugas akhir.

BAB IV PERANCANGAN

Pada bab ini akan dijelaskan mengenai perancangan dari *Radial Basis Function Neural Network* untuk peramalan kasus difteri.

4.1 Persiapan Data

Pada pengerjaan tugas akhir ini data yang digunakan adalah cakupan imunisasi DPT 1, cakupan imunisasi DPT 2, cakupan imunisasi DPT 3, cakupan imunisasi DPT 4, kepadatan penduduk, dan jumlah penderita difteri. Periode data yang digunakan adalah bulanan mulai dari Januari 2013 hingga Desember 2018 dengan jumlah data sebanyak 72 *rows* setiap kota/kabupaten. Data diperoleh dari Dinas Kesehatan Provinsi Jawa Timur dan website Badan Pusat Statistik.

4.2 Pra-proses Data

Tahap pertama untuk melakukan pra-proses data adalah melakukan visualisasi grafik untuk jumlah penderita difteri dari 2013 hingga 2018 periode bulanan di setiap kota dan kabupaten di Jawa Timur. Setelah visualisasi grafik, selanjutnya melakukan pengelompokkan berdasarkan tipe atau bentuk atau pola dari data di setiap kota dan kabupaten dimana pengelompokkan ini yang akan mendefinisikan kota atau kabupaten manakah yang digunakan untuk permodelan. Setelah pengelompokkan selesai, selanjutnya memilih masing-masing satu kota atau kabupaten di tiap kelompok untuk dijadikan permodelan RBFNN.

Pada tahap selanjutnya dilakukan pada data tertentu untuk mendapatkan data sesuai kriteria yang ditentukan untuk dilakukan peramalan. Pada Tabel 4.1 menunjukkan kriteria data kepadatan penduduk yang dibutuhkan.

Tabel 4.1 Kriteria data kepadatan penduduk yang dibutuhkan

Data	Periode	Wilayah	Satuan
Kepadatan penduduk	Bulanan, Januari 2013-2018	Kota/kabupaten yang dijadikan permodelan	jiwa/km ²

Setelah data sudah memenuhi kriteria maka selanjutnya merangkum data setiap kota atau kabupaten yang digunakan permodelan dengan menambahkan detail informasi mengenai cakupan imunisasi DPT 1 hingga DPT 4, kepadatan penduduk, dan jumlah penderita difteri. Setelah data sudah dirincikan, akan dilakukan pembagian data menjadi data training dan data testing dengan perbandingan 75%:25%. Data yang dibagi kedalam data training dan data testing adalah data cakupan imunisasi DPT 1 hingga DPT4, kepadatan penduduk, dan jumlah penderita difteri. Dari jumlah total 72 data pada masing-masing variable pada masing-masing kota atau kabupaten, maka diperoleh 54 data training dan 18 data testing pada masing-masing kota atau kabupaten.

4.2.1 Uji Korelasi

Uji korelasi dilakukan untuk mengetahui apakah variabel Cakupan Imunisasi pada periode ke-t, Kepadatan Penduduk pada periode ke-t, dan Jumlah Penderita itu sendiri pada periode ke-t benar-benar mempengaruhi Jumlah Penderita Difteri pada t+1. Hasil dari uji korelasi ini digunakan untuk analisis dan pembuktian untuk pembuatan permodelan kombinasi di tahap selanjutnya. Untuk melakukan uji korelasi dilakukan dengan menggunakan *tools* Minitab.

4.3 Perancangan Model RBFNN

Pada penelitian tugas akhir ini, suatu model RBFNN dikatakan model terbaik apabila memiliki nilai MASE paling rendah jika dibandingkan dengan model lainnya. Untuk memperoleh model terbaik tersebut, perlu dilakukan pengujian variabel *input layer*, *output layer*, beserta parameter *spread*.

4.3.1 Penetapan Variabel *Input Layer*

Variabel yang digunakan untuk *input layer* terdiri dari n *node*. Jumlah *node* ini menunjukkan kombinasi yang digunakan untuk permodelan. Kandidat – kandidat untuk *input layer* ini adalah cakupan imunisasi DPT, kepadatan penduduk, dan jumlah penderita difteri. Penggambaran mengenai *node* apa saja yang digunakan dapat dilihat pada Tabel 4.2, Tabel 4.3, Tabel 4.4, dan Tabel 4.5.

4.3.2 Penetapan Variabel Output Layer

Variabel yang digunakan untuk *output layer* hanya terdiri dari satu *node* saja yaitu jumlah penderita difteri. Data *output* yang digunakan adalah data dengan satu periode kedepan pada data *input* yang ada. Bila data *input* merupakan data pada periode t , maka data *output* pada periode *input* tersebut merupakan data pada periode $t+1$. Sehingga, untuk data *training* memiliki *input* dari *rows* 1 – 54, maka data *output* nya adalah *rows* 2 – 55. Penggambaran dari data *output* pada *output layer* dapat dilihat pada Tabel 4.2, Tabel 4.3, Tabel 4.4, dan Tabel 4.5.

4.3.3 Penetapan Parameter

Pengubahan paramater digunakan untuk memperoleh model terbaik berdasarkan data yang sudah ada. Pengubahan paramater ini dilakukan untuk melihat nilai MASE paling rendah yang dapat diperoleh. Parameter yang akan dilakukan perubahan nilai adalah *spread*. Pada penelitian tugas akhir ini, nilai *spread* yang digunakan terdiri dari berbagai macam opsi.

1. *Range* antara nilai *maximum differences* yaitu selisih nilai terbesar dengan nilai terkecil dan nilai *minimum differences* yaitu selisih nilai terkecil pertama dengan nilai terkecil kedua. Nilai tersebut diambil dari salah satu variabel yang digunakan untuk peramalan [38]. Untuk kombinasi model A menggunakan jumlah penderita, kombinasi model B menggunakan kepadatan penduduk, kombinasi model C menggunakan jumlah

- penderita, dan kombinasi D menggunakan jumlah penderita atau kepadatan penduduk,
2. Mengambil *range* nilai yang ada didalam variabel, atau
 3. Mengambil *range* nilai antara 0 – 100.

4.3.4 Proses *Training Data*

Proses pelatihan data menggunakan data sebesar 75% dari keseluruhan data sehingga digunakan 54 data. Proses pelatihan ini menggunakan *tools* MATLAB melalui *script*.

4.3.5 Proses *Testing Data*

Proses pengujian data menggunakan data sebesar 25% dari keseluruhan data sehingga digunakan 18 data. Proses pengujian ini menggunakan *tools* MATLAB melalui *script*.

4.3.6 Peramalan

Setelah melalui proses pelatihan dan pengujian hingga didapatkan model terbaik, selanjutnya adalah melakukan peramalan menggunakan model terbaik. Proses peramalan menggunakan *tools* MATLAB yang kemudian hasil akurasi (MSE, MAD dan MASE) akan dihitung didalam *Microsoft Excel*.

4.4 Skenario Permodelan

Skenario permodelan pada data bertujuan untuk menemukan kombinasi yang tepat untuk peramalan di kota atau kabupaten di Jawa Timur. Data yang digunakan untuk skenario permodelan ini adalah data perwakilan masing-masing kelompok.

4.4.1 Skenario Model Kombinasi A

Pada tahap ini dilakukan kombinasi variabel *input* yaitu Cakupan Imunisasi (DPT) dan Jumlah Penderita dengan variabel *ouput* adalah Jumlah Penderita. Penggambaran mengenai skenario model A dapat dilihat pada Tabel 4.2.

Tabel 4.2 Data Input dan Output pada 5 Node Input Layer (model A)

DPT1 (node 1)	DPT2 (node 2)	DPT3 (node 3)	DPT4 (node 4)	Penderita (node 5)	Penderita (output)
%	%	%	%	T	T+1
%	%	%	%	T+1	T+2
%	%	%	%	T+2	T+3
%	%	%	%	T+3	T+4

4.4.2 Skenario Model Kombinasi B

Pada tahap ini dilakukan kombinasi variabel *input* yaitu Kepadatan Penduduk dan Jumlah Penderita dengan variabel *ouput* adalah Jumlah Penderita. Penggambaran mengenai skenario model B dapat dilihat pada Tabel 4.3.

Tabel 4.3 Data Input dan Output pada 2 Node Input Layer (model B)

Kepadatan penduduk (node 1)	Penderita (node 2)	Penderita (output)
<nilai>	T	T+1
<nilai>	T+1	T+2
<nilai>	T+2	T+3
<nilai>	T+3	T+4

4.4.3 Skenario Model Kombinasi C

Pada tahap ini dilakukan kombinasi variabel *input* yaitu Jumlah Penderita dengan variabel *ouput* adalah Jumlah Penderita. Penggambaran mengenai skenario model C dapat dilihat pada Tabel 4.4.

Tabel 4.4 Data Input dan Output pada 1 Node Input Layer (model C)

Penderita (node 1)	Penderita (output)
T	T+1
T+1	T+2
T+2	T+3
T+3	T+4

4.4.4 Skenario Model Kombinasi D

Pada tahap ini dilakukan kombinasi variabel *input* yaitu Cakupan Imunisasi (DPT), Kepadatan Penduduk, dan Jumlah Penderita dengan variabel *ouput* adalah Jumlah Penderita. Penggambaran mengenai skenario model D dapat dilihat pada Tabel 4.5.

Tabel 4.5 Data Input dan Output pada 6 Node Input Layer (model D)

DPT1 (node 1)	DPT2 (node 2)	DPT3 (node 3)	DPT4 (node 4)	Kepadatan penduduk (node 5)	Penderita (node 6)	Penderita (output)
%	%	%	%	<nilai>	T	T+1
%	%	%	%	<nilai>	T+1	T+2
%	%	%	%	<nilai>	T+2	T+3
%	%	%	%	<nilai>	T+3	T+4

4.4.5 Penyeleksian Hasil Keluaran Model

Setelah keseluruhan model diperoleh, selanjutnya dilakukan seleksi terhadap semua model yang ada untuk mendapatkan model terbaik. Proses seleksi dilakukan dengan cara menyortir nilai MASE pada data pengujian di setiap skenario model kombinasi. Model terbaik adalah model yang memiliki nilai MASE paling kecil dibandingkan model lainnya.

4.4.6 Validasi Model

Tahap ini dilakukan untuk melakukan validasi apakah model terbaik yang terpilih tersebut dapat bekerja dengan baik terhadap pola data yang lain. Setelah model didapatkan melalui penyeleksian model, selanjutnya model tersebut dicoba ke data yang lain dalam satu kelompok yang sama untuk mengetahui performa model yang terpilih.

4.5 Analisis Hasil Peramalan

Setelah model divalidasi terhadap pola data lain, selanjutnya model tersebut digunakan untuk peramalan jumlah kasus difteri pada kota atau kabupaten yang terpilih sebagai permodelan per kelompok. Setelah proses peramalan, maka selanjutnya dilakukan proses analisis dengan menggunakan *tools Microsoft*

Excel. Kegiatan ini dilakukan dengan memilih hasil peramalan dan membandingkannya dengan data aktual penderita difteri.

Halaman sengaja dikosongkan

BAB V IMPLEMENTASI

Pada bab ini akan dijelaskan mengenai penerapan dari perancangan yang telah ditentukan sebelumnya dan proses peramalan harga jumlah kasus difteri menggunakan *Radial Basis Function Neural Network*.

5.1 Pengumpulan dan Pra-Processing Data

Pengumpulan data mengenai penderita difteri dan cakupan imunisasi DPT didapatkan dari Dinas Kesehatan Provinsi Jawa Timur melalui *website* internal. Pengumpulan data mengenai kepadatan penduduk didapatkan dari *website* BPS. Pada Tabel 5.1 menunjukkan data yang diperoleh dibandingkan dengan data yang dibutuhkan untuk pengerjaan tugas akhir.

Tabel 5.1 Perbandingan hasil pengumpulan data dengan data yang dibutuhkan

Data	Data Awal			Data yang Dibutuhkan		
	Periode	Wilayah	Satuan	Periode	Wilayah	Satuan
Kepadatan Penduduk	Tahunan	Kota/Kabupaten	Jiwa/km ²	Bulanan	Kota/Kabupaten	Jiwa/km ²
Cakupan Imunisasi DPT	Bulanan	Kota/Kabupaten	Persentase	Bulanan	Kota/Kabupaten	Persentase
Jumlah Penderita Difteri	Bulanan	Kota/Kabupaten	Jiwa	Bulanan	Kota/Kabupaten	Jiwa

Berdasarkan Tabel 5.1, pra-processing data dilakukan hanya pada variabel kepadatan penduduk. Sedangkan untuk variabel cakupan imunisasi dan jumlah penderita tidak perlu dilakukan pra-processing data.

5.1.1 Pengelompokkan Data

Untuk melakukan pengelompokkan data dilihat dari pola grafik jumlah penderita difteri tiap daerah (kota dan kabupaten di Jawa Timur). Pembagian kelompok terdiri dari tiga kelompok yaitu :

1. Setiap kota/kabupaten pada kelompok ini pasti memiliki nilai tertinggi jumlah penderita antara 6 hingga 10.
2. Setiap kota/kabupaten pada kelompok ini pasti memiliki nilai tertinggi jumlah penderita lebih dari 10.
3. Setiap kota/kabupaten pada kelompok ini pasti memiliki nilai tertinggi jumlah penderita kurang dari sama dengan 5.

Jika antar dua data memiliki pola data yang masuk kedalam salah satu kategori yang sama, maka dua data tersebut merupakan satu kelompok.

Setelah 3 kelompok masing-masing sudah memiliki anggota data, selanjutnya memilih satu kota atau kabupaten setiap kelompok untuk digunakan sebagai permodelan data. Dari setiap masing-masing data yang terpilih, gunakan semua detail informasi variabel dari data tersebut yaitu Cakupan DPT1, Cakupan DPT2, Cakupan DPT3, Cakupan DPT4, Kepadatan Penduduk, dan Jumlah Penderita.

5.1.2 Pra-Processing Data Kepadatan Penduduk

Data kepadatan penduduk yang diperoleh masih berupa data tahunan dan hanya tersedia dari tahun 2013 hingga 2017, sehingga perlu diubah menjadi data bulanan dan menggunakan perhitungan kepadatan penduduk untuk tahun 2018. Kepadatan penduduk per bulan diperoleh dari jumlah penduduk per bulan dibagi dengan luas wilayah daerah tersebut.

$$\text{kepadatan penduduk} = \frac{\text{jumlah penduduk}}{\text{luas wilayah}} \quad (5.1)$$

Dikarenakan data jumlah penduduk yang diperoleh masih berupa data tahunan, maka data jumlah penduduk perlu dipecah menjadi data bulanan. Untuk memecah data jumlah penduduk menjadi bulanan perlu dilihat dari laju penduduk setiap bulannya. Rumus laju pertumbuhan penduduk yang digunakan adalah rumus laju penduduk eksponensial karena menggunakan asumsi bahwa pertumbuhan penduduk berlangsung terus-menerus akibat adanya kelahiran dan kematian. Berikut merupakan persamaan dari laju pertumbuhan penduduk eksponensial [39]

$$r = \frac{1}{t} \ln \left(\frac{P_{t+1}}{P_t} \right) \quad (5.2)$$

Dimana,

r = Laju pertumbuhan penduduk

t = Jangka waktu

P_{t+1} = Jumlah penduduk pada tahun ke- $t+1$

P_t = Jumlah penduduk pada tahun ke- t

Laju pertumbuhan yang didapatkan masih berupa laju pertumbuhan tahunan, sehingga perlu dijadikan laju pertumbuhan per bulan dengan cara dibagi 12 untuk mendapatkan jumlah penduduk bulanan dengan asumsi bahwa setiap bulannya akan mengalami kenaikan atau penurunan yang konstan. Berikut ini adalah contoh perhitungan untuk kota Surabaya, dimana jumlah penduduk di tahun 2013 dan 2014 dapat dilihat pada Tabel 5.2.

Tabel 5.2 Jumlah Penduduk Surabaya 2013-2014

Tahun	Jumlah Penduduk	Luas Wilayah (km ²)
2013	2821929	350.54
2014	2833924	

Untuk perhitungan laju pertumbuhan Surabaya adalah

$$r (\text{Surabaya 2014}) = \frac{1}{1} \ln \left(\frac{P_{2014}}{P_{2013}} \right)$$

$$r (\text{Surabaya 2014}) = \frac{1}{1} \ln \left(\frac{2833924}{2821929} \right)$$

$$r (\text{Surabaya 2014}) = 0.00424163$$

Laju pertumbuhan tersebut masih berupa tahunan, sehingga perlu dibagi 12 untuk dijadikan bulanan

$$r (\text{Surabaya 2014}) = \frac{0.00424163}{12}$$

$$r (\text{Surabaya 2014}) = 0.000353469$$

Data jumlah penduduk tahunan yang sudah diperoleh dari BPS diasumsikan bahwa jumlah yang tertera merupakan jumlah penduduk pada akhir tahun atau jumlah penduduk pada bulan Desember pada masing-masing tahun. Sedangkan jumlah penduduk bulanan diperoleh dari jumlah penduduk pada periode sebelumnya ditambah dengan kenaikan/penurunan jumlah penduduk yang diperoleh dari laju penduduk. Rumus yang digunakan yaitu

$$\begin{aligned} & \text{Jumlah penduduk bulan } t_i \\ &= \text{Jumlah penduduk bulan } t_{i-1} \\ &+ (\text{Jumlah penduduk bulan } t_{i-1} \\ &\times \text{Laju pertumbuhan bulan } t_i) \end{aligned} \quad (5.3)$$

Untuk menghitung jumlah penduduk Surabaya pada bulan Januari 2014 adalah

$$\begin{aligned}
 & \text{Jumlah penduduk bulan Jan'14} \\
 & = \text{Jumlah penduduk bulan Des'13} \\
 & + (\text{Jumlah penduduk bulan Des'13} \\
 & \times \text{Laju pertumbuhan bulan Jan'14})
 \end{aligned}$$

$$\begin{aligned}
 & \text{Jumlah penduduk bulan Jan'14} \\
 & = 2821929 + (2821929 \times 0.000353469)
 \end{aligned}$$

$$\text{Jumlah penduduk bulan Jan'14} = 2821929 + 997.465$$

$$\text{Jumlah penduduk bulan Jan'14} = 2822926$$

Selanjutnya untuk mendapatkan kepadatan penduduk Surabaya pada bulan Januari 2014 adalah

$$\begin{aligned}
 & \text{kepadatan penduduk Surabaya Jan'14} \\
 & = \frac{\text{jumlah penduduk Surabaya Jan'14}}{\text{luas wilayah Surabaya}}
 \end{aligned}$$

$$\text{kepadatan penduduk Surabaya Jan'14} = \frac{2822926 \text{ jiwa}}{350.54 \text{ km}^2}$$

$$\text{kepadatan penduduk Surabaya Jan'14} = 8053.08$$

5.2 Uji Korelasi

Uji korelasi dilakukan untuk mengetahui korelasi antar variabel dan dijadikan analisis perbandingan dengan model kombinasi selanjutnya. Uji korelasi pada tugas akhir ini menggunakan *tools* Minitab.

5.2.1 Input Data

Input data merupakan proses memasukkan data kedalam *tools* Minitab. Untuk memasukkan data kedalam Worksheet Minitab adalah dengan melakukan *Copy* pada data di Microsoft Excel dan *Paste* pada Worksheet Minitab. Bentuk worksheet Minitab dapat dilihat pada Gambar 5.1. Data yang dimasukkan pada setiap kolom adalah data Cakupan Imunisasi DPT 1 pada periode ke-t, Cakupan Imunisasi DPT 2 pada periode ke-t, Cakupan Imunisasi DPT 3 pada periode ke-t, Cakupan

Imunisasi DPT 4 pada periode ke-t, Kepadatan Penduduk pada periode ke-t, Jumlah Penderita pada periode ke-t, dan Jumlah Penderita pada periode ke t+1. Sehingga kolom yang terisi adalah kolom C1 hingga C7, selanjutnya beri nama kolom tersebut pada bagian dibawah C1 hingga C7. Contoh pengisian data dapat dilihat pada Gambar 5.2. Korelasi dilakukan terhadap semua data yang digunakan untuk permodelan (tiga data).

	C1	C2	C3	C4	C5	C6	C7	C8
1								
2								
3								
4								
5								
6								
7								
8								
9								

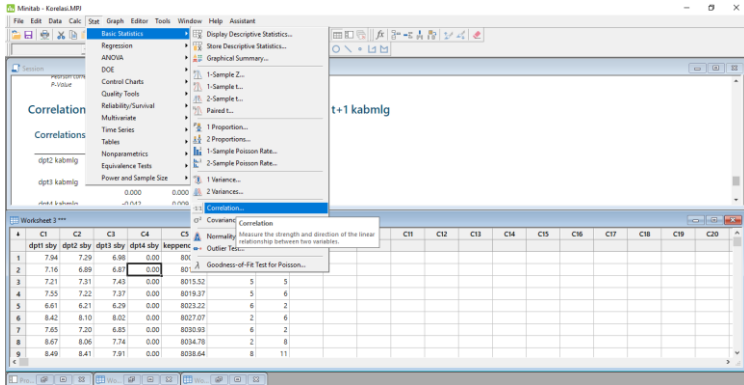
Gambar 5.1 Bentuk worksheet Minitab

	C1	C2	C3	C4	C5	C6	C7
	dpt1 sby	dpt2 sby	dpt3 sby	dpt4 sby	keppend sby	penderita sby	t+1 sby
1	7.94	7.29	6.98	0.00	8007.83	16	9
2	7.16	6.89	6.87	0.00	8011.68	9	5
3	7.21	7.31	7.43	0.00	8015.52	5	5
4	7.55	7.22	7.37	0.00	8019.37	5	6
5	6.61	6.21	6.29	0.00	8023.22	6	2
6	8.42	8.10	8.02	0.00	8027.07	2	6
7	7.65	7.20	6.85	0.00	8030.93	6	2
8	8.67	8.06	7.74	0.00	8034.78	2	8
9	8.49	8.41	7.91	0.00	8038.64	8	11

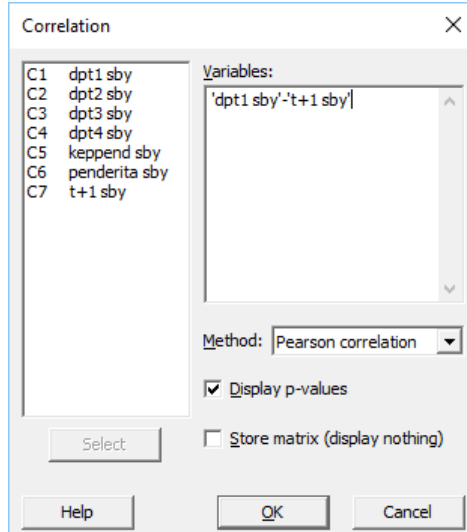
Gambar 5.2 Contoh pengisian data di Minitab

5.2.2 Korelasi Data

Untuk melakukan korelasi pada data yang sudah dimasukkan didalam worksheet Minitab, adalah dengan cara klik **Stat** pada menu Minitab lalu pilih Basic Statistic lalu pilih Correlation seperti pada Gambar 5.3.



Gambar 5.3 Melakukan korelasi data



Gambar 5.4 Pengisian Tab Correlation

Pada tab Correlation, pilih semua variabel C1 hingga C7 dan pilih metode nya menggunakan Pearson, serta centang pada **Display p-values**. Contoh pengisian dapat dilihat pada Gambar 5.4.

5.3 Implementasi RBFNN

Pada sub-bab ini berisi mengenai implementasi model *Radial Basis Function Neural Network* untuk pengerjaan tugas akhir ini.

5.3.1 Input Data

Input data merupakan proses memasukkan data yang akan digunakan dalam pemrosesan RBFNN. Untuk memasukkan data di Matlab, dengan membuat array kosong, dimana array kosong ini lah yang nantinya akan diisi oleh data-data yang akan di proses. Untuk membuat array kosong menggunakan *script* yang diketik dalam Command Window Matlab (bukan Editor dimana tempat biasa *script* dilakukan) yang dapat dilihat pada Kode Program 5.1.

```
>> input_training=[];
>> target=[];
>> input_testing=[];
```

Kode Program 5.1 Input Data

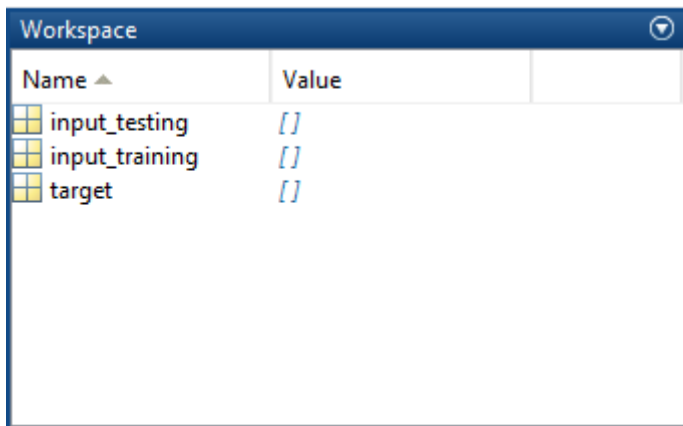
Penjelasan mengenai Kode Program 5.1 dapat dilihat pada Tabel 5.3.

Tabel 5.3 Penjelasan Kode Program Input Data

Script	Keterangan
input_training = [];	Membuat array kosong dengan nama input_training. Input_training merupakan data yang dimasukkan untuk diolah dalam proses training (75% data)

Script	Keterangan
<code>input_testing = [];</code>	Membuat array kosong dengan nama <code>input_testing</code> . <code>Input_testing</code> merupakan data yang dimasukkan untuk diolah dalam proses testing (25% data)
<code>target = [];</code>	Membuat array kosong dengan nama <code>target</code> . <code>Target</code> merupakan data jumlah penderita yang dimulai pada periode ke $t+1$ dimana <code>target</code> ini ikut dalam proses training

Untuk mengisi data pada array tersebut, klik dua kali pada variabel yang diinginkan di area Workspace Matlab yang dapat dilihat pada Gambar 5.5. Lalu masukkan data pada array yang dipilih. Contoh pemasukkan data dapat dilihat pada Gambar 5.6.



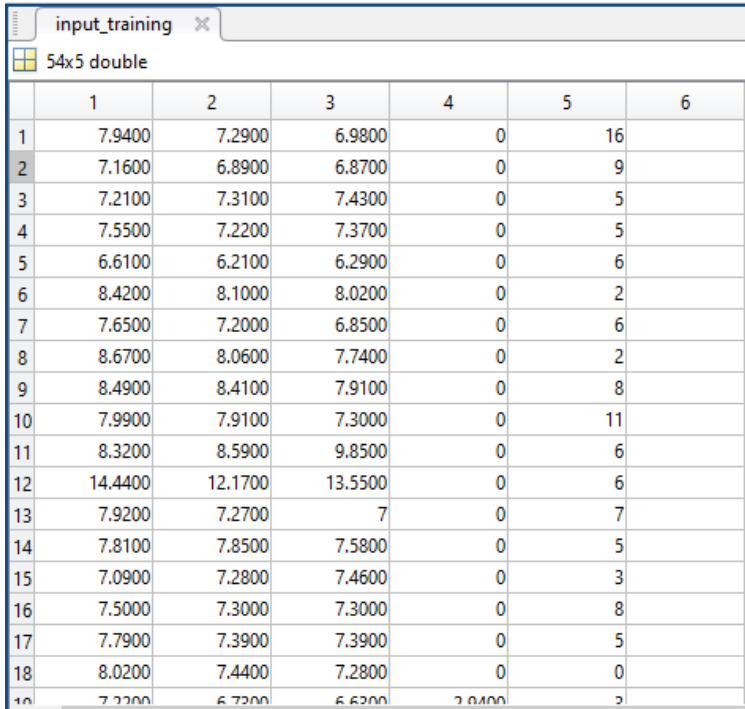
Gambar 5.5 Workspace Matlab

Data yang dimasukkan adalah data dari berbagai Skenario Model Kombinasi. Contohnya pada Skenario Model Kombinasi A, data yang dimasukkan pada `input_training` adalah data

training (54 data) dari Cakupan Imunisasi DPT 1, Cakupan Imunisasi DPT 2, Cakupan Imunisasi DPT 3, Cakupan Imunisasi DPT 4, dan Jumlah Penderita. Semua data `input_training` dimasukkan mulai dari periode ke-1 yang berarti setiap variabel nya berisikan data pada periode ke-1 hingga ke-54. Contoh memasukkan data `input_training` dapat dilihat pada Gambar 5.6.

Data yang dimasukkan pada **target** adalah target data yang ingin diramalkan yaitu Jumlah Penderita. Semua data target yang dimasukkan adalah data mulai dari periode ke-2 (karena $t+1$) yang berarti data Jumlah Penderita yang dimasukkan adalah data pada periode ke-2 hingga ke-55, dimana jumlah data nya yaitu sama 54 data. Contoh memasukkan data target dapat dilihat pada Gambar 5.7.

Data yang dimasukkan pada **input_testing** adalah data testing (18 data) yaitu data Cakupan Imunisasi DPT 1, Cakupan Imunisasi DPT 2, Cakupan Imunisasi DPT 3, Cakupan Imunisasi DPT 4, Jumlah Penderita. Semua data `input_testing` dimasukkan mulai dari ke 55 hingga 72. Contoh memasukkan data `input_testing` dapat dilihat pada Gambar 5.8.



	1	2	3	4	5	6
1	7.9400	7.2900	6.9800	0	16	
2	7.1600	6.8900	6.8700	0	9	
3	7.2100	7.3100	7.4300	0	5	
4	7.5500	7.2200	7.3700	0	5	
5	6.6100	6.2100	6.2900	0	6	
6	8.4200	8.1000	8.0200	0	2	
7	7.6500	7.2000	6.8500	0	6	
8	8.6700	8.0600	7.7400	0	2	
9	8.4900	8.4100	7.9100	0	8	
10	7.9900	7.9100	7.3000	0	11	
11	8.3200	8.5900	9.8500	0	6	
12	14.4400	12.1700	13.5500	0	6	
13	7.9200	7.2700	7	0	7	
14	7.8100	7.8500	7.5800	0	5	
15	7.0900	7.2800	7.4600	0	3	
16	7.5000	7.3000	7.3000	0	8	
17	7.7900	7.3900	7.3900	0	5	
18	8.0200	7.4400	7.2800	0	0	
19	7.7200	6.7200	6.6200	7.0400	2	

Gambar 5.6 Memasukkan Data pada array Matlab

Program Matlab membaca data berdasarkan kolom dan bukan per baris nya. Sehingga jika merancang jaringan RBFNN atau bahkan ANN sederhana pada Matlab, maka Matlab akan membaca data *input layer* berdasarkan per kolom. Jika dalam satu kolom terdapat 5 data, maka *input layer* akan terdeteksi 5 data. Matlab tidak dapat membaca *input layer* berdasarkan baris.

	1	2	3	4	5	6
1	9					
2	5					
3	5					
4	6					
5	2					
6	6					
7	2					
8	8					
9	11					
10	6					
11	6					
12	7					
13	5					
14	3					
15	8					
16	5					
17	0					
18	3					
19	2					

Gambar 5.7 Memasukkan data target

Pada proses pemasukkan data sebelumnya, pembacaan data yang dimaksud adalah per baris, sehingga harus diubah menjadi per kolom. Perubahan ini menggunakan metode *transpose matrix* dimana *transpose matrix* ini bertujuan untuk mengubah data dari baris menjadi kolom ataupun sebaliknya. Untuk mengubah hal tersebut dapat menggunakan *script* yang diketik melalui Editor Matlab yang dapat dilihat pada Kode Program 5.2. Untuk penjelasan mengenai Kode Program 5.2 dapat dilihat pada Tabel 5.4.

	1	2	3	4	5	6
1	8.2200	7.6700	7.7400	3.6900		2
2	8.3900	7.8300	7.4200	2.3700		3
3	8.0600	8.1500	7.9500	2.7000		2
4	8.9500	8.5600	8.7800	5.4800		4
5	7.8300	7.7500	8.0700	6.3200		3
6	8.0600	7.9000	7.7100	6.1600		9
7	8.3400	7.8200	7.9100	5.4700		17
8	7.6900	7.3700	7.2000	22.8800		7
9	8.1400	8.2500	7.9600	13.1100		12
10	8.8700	8.9900	8.8000	7.4800		8
11	8.4900	8.2500	8.2500	6.2700		5
12	8.0300	7.8300	7.8700	6.2800		2
13	8.7100	8.5100	8.4700	12.7700		2
14	8.7600	8.6400	8.5300	9.4900		8
15	8.3800	8.3300	8.0400	5.9600		2
16	8.2500	7.9700	8.1000	4.9900		3
17	8.3400	8.1100	8.2400	8.7600		1
18	7.9100	8.0200	7.8200	8.1600		0

Gambar 5.8 Memasukkan data input_testing

```
input_training_ =transpose(input_training);
target_ =transpose(target);
input_testing_ =transpose(input_testing);
```

Kode Program 5.2 Transpose Data

Tabel 5.4 Penjelasan Script Transpose

Script	Keterangan
input_training_ = transpose(input_training)	Melakukan <i>transpose</i> dari variabel input_training sehingga

Script	Keterangan
	data yang sudah di <i>transpose</i> ini bernama <code>input_training_</code>
<code>input_testing_ = transpose(input_testing)</code>	Melakukan <i>transpose</i> dari variabel <code>input_testing</code> sehingga data yang sudah di <i>transpose</i> ini bernama <code>input_testing_</code>
<code>target_ = transpose(target)</code>	Melakukan <i>transpose</i> dari variabel <code>target</code> sehingga data yang sudah di <i>transpose</i> ini bernama <code>target_</code>

5.3.2 Proses Training

Setelah data yang dibutuhkan sudah dimasukkan kedalam Matlab, selanjutnya adalah proses *training* terhadap data set yang ada pada `input_training`. Proses *training* tertuang pada *script* yang ditampilkan pada Kode Program 5.3.

```
net=newrb(input_training_,target_,goal,
spread,MN,DF);
view(net)
```

Kode Program 5.3 Proses Training

Penjelasan mengenai Kode Program 5.3 dijelaskan pada Tabel 5.5.

Tabel 5.5 Penjelasan Script Training

Script	Keterangan
<code>net</code>	Nama jaringan yang akan dibangun
<code>newrb()</code>	Jenis jaringan yang akan dibangun yaitu <i>radial basis function neural network</i> sekaligus melakukan proses <i>training</i>
<code>view()</code>	Untuk melihat grafik penurunan MSE

Script	Keterangan
input_training_	Untuk membaca kumpulan data yang digunakan sebagai data <i>input</i> pada saat proses <i>training</i> data
target_	Untuk membaca kumpulan data yang digunakan sebagai data <i>target/output</i> pada saat proses <i>training</i> data
goal	Untuk membaca parameter batasan MSE. Untuk mengukur error terkecil maka set batasan MSE dengan nilai 0.0
spread	Untuk membaca parameter <i>spread</i> yang telah dideklarasikan
MN	Untuk membaca parameter batasan maksimal neuron. Neuron yang digunakan adalah 54 karena data masukan terdiri dari 54 data dimana sesuai dengan konsep <i>radial basis</i> bahwa setiap 1 data <i>input</i> akan menghasilkan 1 neuron
DF	Jumlah kelipatan neuron yang ditampilkan. Set nilai 1 untuk melihat semuanya satu per satu

5.3.3 Proses Testing

Setelah proses *training* dilakukan, maka selanjutnya dilakukan *testing* berdasarkan model yang didapatkan dari *training* tersebut. Proses *testing* dilakukan dengan *script* yang ditampilkan pada Kode Program 5.4.

```
results_testing=sim(net,input_testing_);
```

Kode Program 5.4 Proses testing

Untuk penjelasan mengenai Kode Program 5.4 dijelaskan pada Tabel 5.6.

Tabel 5.6 Penjelasan proses testing

Script	Keterangan
results_testing	<i>Output</i> nilai peramalan hasil dari model yang dibentuk dari proses <i>testing</i>
sim(net, input_testing_)	Untuk mensimulasikan model <i>net</i> kedalam data <i>testing</i> yaitu <i>input_testing_</i>
net	Untuk membaca model dari hasil <i>training</i>
input_testing_	Untuk membaca data yang ingin disimulasikan

5.3.4 Uji Performa Model

Untuk mengetahui *error* yang dihasilkan dari *testing* maka diperlukan data hasil peramalan dari *testing* untuk dapat melakukan perhitungan MSE, MAD dan MASE. Hasil dari peramalan *testing* tersebut masih dalam format pembacaan Matlab yaitu per kolom. Sehingga perlu diubah kedalam deretan baris. Untuk mengubah data kedalam baris menggunakan *transpose* yang ditampilkan pada Kode Program 5.5.

```
results_testing=transpose(results_testing);
```

Kode Program 5.5 Transpose hasil peramalan

Untuk penjelasan dari Kode Program 5.5 dijelaskan pada Tabel 5.7.

Tabel 5.7 Penjelasan transpose hasil

Script	Keterangan
results_testing=	<i>Output</i> nilai peramalan hasil dari model yang dibentuk dari proses <i>testing</i>
transpose(results_testing)	Melakukan <i>transpose</i> dari variabel results_testing

Setelah didapatkan data *transpose* dari hasil peramalan maka dilakukan perhitungan MSE, MAD dan MASE di *Microsoft Excel* menggunakan persamaan yang sudah dijelaskan pada sub bab 2.2.6. Setelah MSE, MAD dan MASE diketahui, selanjutnya dipilih Skenario Kombinasi Model tiap kelompok yang terbaik. Untuk memilih model kombinasi yang terbaik, diurutkan berdasarkan hasil MASE terkecil dari setiap percobaan kombinasi sehingga setiap kota atau kabupaten memiliki 4 kandidat kombinasi terbaik yaitu dari Skenario Model A hingga D.

5.3.5 Validasi Model

Setelah mendapatkan 4 kandidat model terbaik di setiap kelompok, selanjutnya adalah melakukan validasi model yaitu mencoba model yang dihasilkan tersebut kedalam data kota atau kabupaten lain yang dalam satu kelompok. Data yang dijadikan validasi model setiap kelompok terdiri dari 3 kota atau kabupaten dengan *random sampling*.

Untuk melakukan validasi model dilakukan dengan script yang ditampilkan pada Kode Program 5.6.

```
results_validasi=sim(net,input_validasi_);
results_validasi=transpose(results_validasi)
;
```

Kode Program 5.6 Proses validasi model

Penjelasan mengenai Kode Program 5.6 dijelaskan pada Tabel 5.8.

Tabel 5.8 Penjelasan script validasi model

Script	Keterangan
results_validasi	<i>Output</i> nilai validasi
sim(net,input_validasi_)	Untuk mensimulasikan model <i>net</i> ke dalam data <i>input_validasi_</i>
transpose(results_validasi)	Untuk melakukan <i>transpose</i> dari variabel results_validasi

Terdapat 4 kandidat model tiap kelompok yang sudah diurutkan berdasarkan nilai MASE. Kandidat pertama disimulasikan kedalam 3 kota atau kabupaten lainnya dan dilakukan analisis apakah kandidat pertama (kandidat terbaik) merupakan model yang benar-benar terbaik jika diimplementasikan di data yang lain. Semua kandidat model divalidasi kedalam 3 kota/kabupaten yang dalam satu kelompok. Setelah semua model dicoba, dilihat apakah model dapat beradaptasi dengan data yang ada, apakah performa model dapat mengikuti pola data yang ada, jika terdapat salah satu model yang dapat mengikuti pola data yang ada, maka model tersebut yang akan digunakan. Jika terdapat dua model yang dapat beradaptasi dengan baik, maka dari kedua model tersebut dilihat dari rata-rata MSE yang dihasilkan di setiap kota/kabupaten validasi. Jika dari keempat kandidat tidak ada yang memiliki performa yang baik, maka dilakukan perhitungan rata-rata MSE dari setiap kandidat. MSE yang terkecil lah yang menjadi model terbaik.

5.4 Peramalan Masa Mendatang

Dari hasil model terbaik yang didapatkan melalui validasi model, selanjutnya model tersebut digunakan untuk melakukan peramalan jumlah kasus difteri. Untuk mendapat nilai peramalan dilakukan satu per satu tiap bulannya. Data aktual yang digunakan adalah data mulai dari Januari 2013 hingga Desember 2018. Setelah mendapatkan satu nilai peramalan, nilai tersebut dijadikan sebagai data aktual untuk mendapatkan

nilai permalan berikutnya, begitu seterusnya hingga mendapatkan nilai peramalan dua tahun berturut turut yaitu 2019 hingga 2020.

Halaman sengaja dikosongkan

BAB VI

HASIL DAN PEMBAHASAN

Pada bab ini akan dijelaskan mengenai hasil implementasi yang sudah dikerjakan pada bab sebelumnya.

6.1 Hasil Pra-Processing Data

Pra-processing data dilakukan terhadap variabel kepadatan penduduk dan melakukan pengelompokan data sesuai pola. Untuk hasil akhir keseluruhan dari pra-processing data dapat dilihat pada LAMPIRAN A.

6.1.1 Hasil Pengelompokan Data

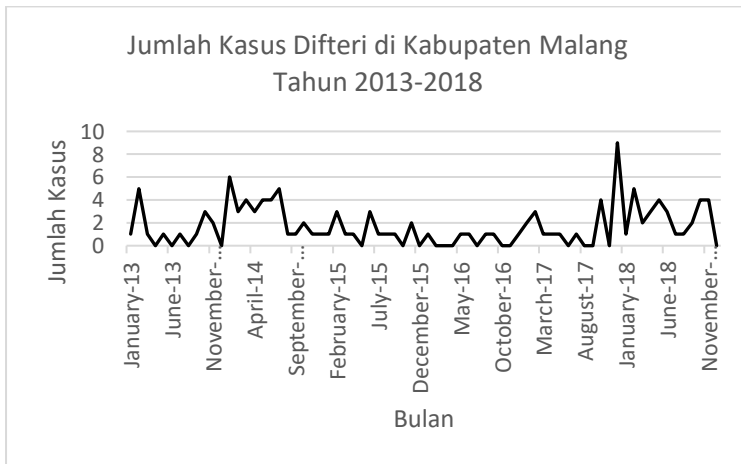
Tabel 6.1 merupakan hasil pengelompokan data yang telah dilakukan. Berdasarkan data tersebut, maka salah satu kota atau kabupaten di setiap kelompok digunakan untuk permodelan yaitu Surabaya, Kabupaten Malang, dan Sumenep. Untuk grafik jumlah penderita Surabaya, Kabupaten Malang, dan Sumenep dapat dilihat pada Gambar 6.1, Gambar 6.2, dan Gambar 6.3.

Tabel 6.1 Hasil pengelompokan data

Kelompok 1	Kelompok 2	Kelompok 3
Kab. Malang	Kota Surabaya	Kab. Sumenep
Kab. Sidoarjo	Kab. Pasuruan	Kab. Lamongan
Kab. Tuban	Kab. Blitar	Kab. Magetan
Kota Batu	Kab. Tulungagung	Kab. Ngawi
Kab. Situbondo	Kab. Jember	Kab. Pacitan
Kab. Madiun	Kab. Bangkalan	Kab. Ponorogo
Kab. Jombang		Kab. Trenggalek
Kab. Kediri		Kota Mojokerto
Kab. Lumajang		Kota Probolinggo
Kab. Sampang		Kab. Nganjuk
Kota Pasuruan		Kab. Probolinggo


Kelompok 1	Kelompok 2	Kelompok 3
Kota Blitar		Kab. Pamekasan
Kab. Gresik		Kota Kediri
Kota Malang		Kab. Bondowoso
Kab. Madiun		Kab. Banyuwangi
		Kab. Bojonegoro
		Kab. Mojokerto

Pada Tabel 6.1 pada kelompok 1 terdapat 15 kota atau kabupaten, pada kelompok 2 terdapat 6 kota atau kabupaten, dan pada kelompok 3 terdapat 17 kota atau kabupaten yang tersebar di Jawa Timur.




Gambar 6.1 Grafik Jumlah Kasus Difteri di Kabupaten Malang

Gambar 6.1 menunjukkan pola data pada Kabupaten Malang yang merupakan kabupaten pilihan untuk dijadikan permodelan pada kelompok 1.



Gambar 6.2 Grafik Jumlah Kasus Difteri di Surabaya

Gambar 6.2 menunjukkan pola data pada Kota Surabaya yang merupakan kabupaten pilihan untuk dijadikan permodelan pada kelompok 2.



Gambar 6.3 Grafik Jumlah Kasus Difteri di Sumenep

Gambar 6.3 menunjukkan pola data pada Kabupaten Sumenep yang merupakan kabupaten pilihan untuk dijadikan permodelan pada kelompok 3.

Untuk gambaran grafik setiap kelompok dapat dilihat pada LAMPIRAN B.

6.1.2 Hasil Pra-Processing Data Kepadatan Penduduk

Tabel 6.2, Tabel 6.3, dan Tabel 6.4 merupakan hasil perhitungan laju penduduk eksponensial bulanan dari Surabaya, Kabupaten Malang, dan Kabupaten Sumenep.

Tabel 6.2 Hasil perhitungan laju penduduk eksponensial bulanan Kota Surabaya

Periode	Jumlah Penduduk	Laju Penduduk Eksponensial	
		Tahunan	Bulanan
2012	2805718		
2013	2821929	0.58%	0.04801%
2014	2833924	0.42%	0.03535%
2015	2771615	-2.22%	-0.18527%
2016	2862406	3.22%	0.26860%
2017	2874699	0.43%	0.03571%
2018	2885555	0.38%	0.03141%

Pada Tabel 6.2 mengenai perhitungan laju penduduk eksponensial bulanan di Kota Surabaya, dimana jumlah penduduk di Kota Surabaya memiliki *range* 2.800.000-an.

Tabel 6.3 Hasil perhitungan laju penduduk eksponensial bulanan Kabupaten Malang

Periode	Jumlah Penduduk	Laju Penduduk Eksponensial	
		Tahunan	Bulanan
2012	2409878		

Periode	Jumlah Penduduk	Laju Penduduk Eksponensial	
		Tahunan	Bulanan
2013	2508698	4.02%	0.3349%
2014	2527087	0.73%	0.0609%
2015	2544315	0.68%	0.0566%
2016	2560675	0.64%	0.0534%
2017	2576596	0.62%	0.0517%
2018	2591795	0.59%	0.0490%

Pada Tabel 6.3 mengenai perhitungan laju penduduk eksponensial bulanan di Kabupaten Malang, dimana jumlah penduduk di Kota Surabaya memiliki *range* 2.500.000-an.

Tabel 6.4 Hasil perhitungan laju penduduk eksponensial bulanan Kabupaten Sumenep

Periode	Jumlah Penduduk	Laju Penduduk Eksponensial	
		Tahunan	Bulanan
2012	1056415		
2013	1061211	0.45%	0.03775%
2014	1067202	0.56%	0.04691%
2015	1072113	0.46%	0.03826%
2016	1076805	0.44%	0.03639%
2017	1081204	0.41%	0.03397%
2018	1085227	0.37%	0.03095%

Pada Tabel 6.4 mengenai perhitungan laju penduduk eksponensial bulanan di Kabupaten Sumenep, dimana jumlah penduduk di Kota Surabaya memiliki *range* 1.050.000-an.

Tabel 6.5, Tabel 6.6, dan Tabel 6.7 merupakan hasil perhitungan jumlah penduduk bulanan dari Surabaya, Kabupaten Malang, dan Kabupaten Sumenep tahun 2013. Untuk tahun 2014 dan selanjutnya terdapat pada LAMPIRAN C.

Tabel 6.5 Hasil perhitungan jumlah penduduk bulanan Kota Surabaya

Periode	Laju Pertumbuhan Eksponensial per Bulan	Jumlah Penduduk Bulanan
12-12		2805718
01-13	0.04801%	2807065
02-13		2808413
03-13		2809761
04-13		2811110
05-13		2812460
06-13		2813810
07-13		2815161
08-13		2816512
09-13		2817865
10-13		2819217
11-13		2820571
12-13		2821929

Pada tahun 2013 di Surabaya berdasarkan Tabel 6.5 menunjukkan laju eksponensialnya sebesar 0.048%, sehingga memiliki kenaikan sebesar angka tersebut setiap bulannya.

Tabel 6.6 Hasil perhitungan jumlah penduduk bulanan Kabupaten Malang

Periode	Laju Pertumbuhan Eksponensial per Bulan	Jumlah Penduduk Bulanan
12-12		2409878

Periode	Laju Pertumbuhan Eksponensial per Bulan	Jumlah Penduduk Bulanan
01-13	0.3349%	2417949
02-13		2426046
03-13		2434171
04-13		2442323
05-13		2450502
06-13		2458709
07-13		2466943
08-13		2475205
09-13		2483494
10-13		2491812
11-13		2500157
12-13		2508698

Pada tahun 2013 di Kabupaten Malang berdasarkan Tabel 6.6 menunjukkan laju eksponensialnya sebesar 0.3349%, sehingga memiliki kenaikan sebesar angka tersebut setiap bulannya.

Tabel 6.7 Hasil perhitungan jumlah penduduk bulanan Kabupaten Sumenep

Periode	Laju Pertumbuhan Eksponensial per Bulan	Jumlah Penduduk Bulanan
12-12	0.03775%	1056415
01-13		1056814
02-13		1057213
03-13		1057612
04-13		1058011

Periode	Laju Pertumbuhan Eksponensial per Bulan	Jumlah Penduduk Bulanan
05-13		1058410
06-13		1058810
07-13		1059209
08-13		1059609
09-13		1060009
10-13		1060409
11-13		1060810
12-13		1061211

Pada tahun 2013 di Kabupaten Malang berdasarkan Tabel 6.6 menunjukkan laju eksponensialnya sebesar 0.03775%, sehingga memiliki kenaikan sebesar angka tersebut setiap bulannya.

Tabel 6.8, Tabel 6.9, dan Tabel 6.10 merupakan hasil perhitungan kepadatan penduduk bulanan dari Surabaya, Kabupaten Malang, dan Kabupaten Sumenep pada tahun 2013. Untuk kepadatan penduduk di tahun 2014 dan selanjutnya terdapat pada LAMPIRAN C.

Tabel 6.8 Hasil perhitungan kepadatan penduduk bulanan Kota Surabaya

Periode	Jumlah Penduduk	Luas Wilayah (km ²)	Kepadatan Penduduk per Bulan
01-13	2807065	350.54	8007.83
02-13	2808413		8011.68
03-13	2809761		8015.52
04-13	2811110		8019.37
05-13	2812460		8023.22
06-13	2813810		8027.07

Periode	Jumlah Penduduk	Luas Wilayah (km ²)	Kepadatan Penduduk per Bulan
07-13	2815161		8030.93
08-13	2816512		8034.78
09-13	2817865		8038.64
10-13	2819217		8042.50
11-13	2820571		8046.36
12-13	2821929		8050.23

Setelah mendapatkan jumlah penduduk per bulan, pada Tabel 6.8 yaitu Surabaya memiliki luas wilayah sebesar 350.54 sehingga untuk kepadatan penduduk per bulan memiliki *range* 8000-an.

Tabel 6.9 Hasil perhitungan kepadatan penduduk bulanan Kabupaten Malang

Periode	Jumlah Penduduk	Luas Wilayah (km ²)	Kepadatan Penduduk per Bulan
01-13	2417949	3530.65	684.85
02-13	2426046		687.14
03-13	2434171		689.44
04-13	2442323		691.75
05-13	2450502		694.07
06-13	2458709		696.39
07-13	2466943		698.72
08-13	2475205		701.06
09-13	2483494		703.41
10-13	2491812		705.77
11-13	2500157		708.13

Periode	Jumlah Penduduk	Luas Wilayah (km ²)	Kepadatan Penduduk per Bulan
12-13	2508698		710.55

Setelah mendapatkan jumlah penduduk per bulan, pada Tabel 6.9 yaitu Kabupaten Malang memiliki luas wilayah sebesar 3530.65 sehingga untuk kepadatan penduduk per bulan memiliki *range* 710-an.

Tabel 6.10 Hasil perhitungan kepadatan penduduk bulanan Kabupaten Sumenep

Periode	Jumlah Penduduk	Luas Wilayah (km ²)	Kepadatan Penduduk per Bulan
01-13	1056415	1998.54	528.79
02-13	1056814		528.99
03-13	1057213		529.19
04-13	1057612		529.39
05-13	1058011		529.59
06-13	1058410		529.79
07-13	1058810		529.99
08-13	1059209		530.19
09-13	1059609		530.39
10-13	1060009		530.59
11-13	1060409		530.79
12-13	1060810		530.99

Setelah mendapatkan jumlah penduduk per bulan, pada Tabel 6.10 yaitu Kabupaten Sumenep memiliki luas wilayah sebesar

1998.54 sehingga untuk kepadatan penduduk per bulan memiliki *range* 500-an.

6.2 Hasil Uji Korelasi

Pada Gambar 6.4 menunjukkan hasil korelasi antara Cakupan DPT 1 hingga 4, Kepadatan Penduduk, dan Jumlah Penderita pada periode ke-t terhadap Jumlah Penderita t+1 di Kota Surabaya. Berdasarkan Gambar 6.4 diketahui bahwa baris pertama merupakan nilai dari korelasi (Pearson Correlation) dan baris kedua adalah nilai P-Value. Jika nilai p-value kurang dari 0.05, maka variabel tersebut dapat dikatakan memiliki signifikansi, jika diatas 0.05 maka tidak memiliki signifikansi yang cukup [40]. Pada Gambar 6.4 hampir semua variabel memiliki korelasi yang sangat lemah terhadap Jumlah Penderita t+1, kecuali variabel Jumlah Penderita itu sendiri yang memiliki nilai korelasi 0.485 yaitu sedang dan memiliki hubungan yang positif. Dari nilai p-value hanya variabel Jumlah Penderita saja yang memiliki signifikansi terhadap Jumlah Penderita itu sendiri. Hal ini berarti Cakupan DPT dan Kepadatan Penduduk kurang memberikan dampak yang signifikan terhadap Jumlah Penderita di kota Surabaya.

Correlation: dpt1 sby, dpt2 sby, dpt3 sby, dpt4 sby, ... erita sby, t+1 sby

Correlations

	dpt1 sby	dpt2 sby	dpt3 sby	dpt4 sby	keppend sby	
dpt2 sby	0.930					
	0.000					
dpt3 sby	0.894	0.944				
	0.000	0.000				
dpt4 sby	0.138	0.166	0.150			
	0.249	0.165	0.213			
keppend sby	0.109	0.158	0.166	0.173		
	0.367	0.187	0.167	0.148		
penderita sby	0.052	-0.003	-0.033	-0.080	0.089	
	0.667	0.977	0.785	0.506	0.460	
t+1 sby	0.091	0.052	0.042	-0.033	0.115	
	0.451	0.668	0.728	0.782	0.341	
	penderita sby					
t+1 sby	0.485					
	0.000					

Cell Contents
Pearson correlation
P-Value

Gambar 6.4 Hasil uji korelasi di Kota Surabaya

Pada Gambar 6.5 menunjukkan hasil korelasi antara Cakupan DPT 1 hingga 4, Kepadatan Penduduk, dan Jumlah Penderita pada periode ke-t terhadap Jumlah Penderita t+1 di Kabupaten Malang. Diketahui bahwa semua variabel memiliki korelasi yang sangat lemah dan tidak memiliki signifikansi yang cukup. Dilihat dari nilai koefisien korelasi yang paling memiliki korelasi yang lebih tinggi diantara lainnya adalah Cakupan DPT4 dengan nilai -0.140, Cakupan DPT1 dengan nilai -0.118 yang memiliki hubungan negatif dan Jumlah Penderita dengan nilai 0.110 yang memiliki hubungan positif, dengan masih batasan sangat lemah. Begitupun dengan keadaan di Sumenep yang ditampilkan pada Gambar 6.6 dimana tidak ada variabel yang memiliki korelasi kuat serta signifikansi terhadap Jumlah Penderita pada periode ke t+1. Variabel yang paling memiliki korelasi lebih tinggi diantara variabel lainnya adalah variabel Jumlah Penderita dengan nilai 0.168 yang masih pada kriteria sangat lemah.

Dari uji korelasi yang telah dilakukan, variabel yang konsisten mempengaruhi Jumlah Penderita pada periode ke t+1 adalah Jumlah Penderita itu sendiri. Walaupun dari hasil uji korelasi menunjukkan tidak ada variabel yang cukup kuat berkorelasi dengan Jumlah Penderita pada periode ke t+1, tidak berarti bahwa variabel-variabel tersebut tidak berpengaruh sama sekali terhadap jumlah penderita difteri.

Correlation: dpt1 kabmlg, dpt2 kabmlg, dpt3 kabmlg, ... g, t+1 kabmlg

Correlations

	dpt1 kabmlg	dpt2 kabmlg	dpt3 kabmlg	dpt4 kabmlg	
dpt2 kabmlg	0.931				
	0.000				
dpt3 kabmlg	0.924	0.967			
	0.000	0.000			
dpt4 kabmlg	-0.042	0.009	-0.004		
	0.725	0.941	0.976		
keppend kabmlg	-0.221	-0.195	-0.200	0.666	
	0.064	0.102	0.094	0.000	
penderita kabmlg	-0.095	-0.067	-0.043	-0.083	
	0.431	0.577	0.723	0.489	
t+1 kabmlg	-0.118	-0.061	-0.077	-0.140	
	0.327	0.615	0.524	0.244	
	keppend kabmlg		penderita kabmlg		
penderita kabmlg	0.069				
	0.569				
t+1 kabmlg	0.040	0.110			
	0.739	0.363			

Cell Contents
Pearson correlation
P-Value

Gambar 6.5 Hasil uji korelasi di Kabupaten Malang

Correlation: dpt1 sumenep, dpt2 sumenep, dpt3 ... enep, t+1 sumenep

Correlations

	dpt1 sumenep	dpt2 sumenep	dpt3 sumenep	dpt4 sumenep	
dpt2 sumenep	0.879				
	0.000				
dpt3 sumenep	0.891	0.908			
	0.000	0.000			
dpt4 sumenep	-0.124	-0.129	-0.142		
	0.302	0.285	0.237		
keppend sumenep	-0.331	-0.363	-0.373	0.120	
	0.005	0.002	0.001	0.319	
pender sumenep	0.060	0.101	0.111	-0.028	
	0.620	0.404	0.357	0.820	
t+1 sumenep	-0.036	0.049	0.070	-0.002	
	0.766	0.682	0.561	0.985	
	keppend sumenep		pender sumenep		
pender sumenep	0.066				
	0.584				
t+1 sumenep	0.117	0.168			
	0.333	0.162			

Cell Contents
Pearson correlation
P-Value

Gambar 6.6 Hasil uji korelasi di Kabupaten Sumenep

Hasil uji korelasi yang kecil seperti yang dilakukan dikarenakan data yang diuji tidak bersifat linear, dimana uji korelasi sendiri dilakukan untuk mengukur hubungan linear dari suatu data. Untuk mengetahui dan menkonfirmasi dari hasil uji korelasi ini dilanjutkan dengan skenario permodelan.

6.3 Hasil Implementasi Skenario Model

Pada bagian ini akan dibahas hasil dari percobaan pembuatan model yang telah dilakukan pada penelitian tugas akhir ini. Skenario model ini dilakukan dengan melakukan kombinasi variabel untuk dijadikan *input layer* sehingga jumlah node pada setiap skenario kombinasi berbeda-beda.

6.3.1 Hasil Model Kombinasi A

Pada skenario model kombinasi ini mengkombinasikan variabel cakupan imunisasi dan jumlah penderita untuk meramalkan jumlah penderita di Kabupaten Malang, Surabaya, dan Sumenep. Jumlah node pada *input layer* pada kombinasi ini terdapat 5 node yang terdiri dari Cakupan DPT 1 hingga 4, dan Jumlah Penderita. Untuk target nya adalah Jumlah Penderita mulai dari periode $t+1$.

6.3.1.1 Pengelompokkan 1 (Kabupaten Malang)

Pada pengelompokkan 1 dilakukan beberapa kali percobaan (*trial and error*) terhadap parameter *spread* terhadap data *training* yang kemudian model yang didapatkan disimulasikan kedalam data *testing*. Dari berbagai kali percobaan tersebut kemudian dihitung nilai MSE, MAD, dan MASE baik dari *training* maupun *testing*. Setelah diketahui nilai-nilai tersebut, kemudian model dipilih berdasarkan hasil MASE data *testing* terkecil yaitu 0.69 dengan parameter *spread* 0.2. Untuk hasil *trial and error* dapat dilihat pada Tabel 6.11 dan Tabel 6.12.

Tabel 6.11 Hasil perhitungan MSE, MAD Skenario A Kabupaten Malang

Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.2	0.00	1.84	0.00	1.84


Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.3	0.00	1.92	0.00	1.92
0.31	0.00	4.42	0.00	4.42
0.4	0.00	9.32	0.00	9.32
0.816	0.00	16.31	0.00	16.31
2	0.00	0.26	0.00	46.65
4	0.00	0.26	0.00	254.99
6	0.00	0.26	0.00	294.28
14	0.00	1059.94	0.00	1059.94
18	0.00	1493.17	0.00	1493.17
60	0.10	36.24	0.16	36.24
67	0.12	55.66	0.17	55.66
68	0.12	55.72	0.17	55.72
79	0.12	89.04	0.19	89.04

Tabel 6.12 Hasil perhitungan MASE Skenario A Kabupaten Malang

Spread	MASE Train	MASE Test
0.2	0.00	0.69
0.3	0.00	0.72
0.31	0.00	1.67
0.4	0.00	3.52
0.816	0.00	6.16
2	0.00	17.62
4	0.00	96.33
6	0.00	111.17
14	0.00	400.42
18	0.00	564.08
60	0.00	13.69
67	0.00	21.03
68	0.00	21.05

Spread	MASE Train	MASE Test
79	0.00	33.64


Untuk mempermudah dalam memilih MASE terendah dari tiap kandidat tersebut, digambarkan pada grafik yang ditampilkan pada Gambar 6.7.



Gambar 6.7 Grafik perbandingan Skenario A Kabupaten Malang

Pada Gambar 6.7 menunjukkan indeks terkecil adalah pada *spread* 0.2.

Perbandingan data aktual dengan data peramalan Kabupaten Malang menggunakan model terbaik dari kombinasi ini dapat dilihat pada Gambar 6.8.



Gambar 6.8 Perbandingan data aktual dan peramalan Kab. Malang Skenario A

Dari hasil grafik tersebut, diketahui bahwa hasil perbandingan dari data aktual dengan peramalan pada data *training* dapat mengikuti pola grafik secara sempurna, namun ketika disimulasikan kedalam data *testing* tidak dapat mengikuti pola yang ada, dimana hasil peramalan hampir menghasilkan nilai yang sama, dimana nilai ini secara visual merupakan rata-rata dari data *testing* sehingga nilai yang dihasilkan tidak bisa dikatakan bagus dan tidak bisa dikatakan jelek karena nilainya berada di tengah-tengah.

6.3.1.2 Pengelompokkan 2 (Surabaya)

Untuk permodelan dengan Skenario Kombinasi A pada pengelompokkan 2 dilakukan dengan menggunakan data kota Surabaya. Dari *trial and error* parameter *spread* yang dilakukan didapatkan hasil terbaik adalah 0.913 dengan nilai parameter *spread* 0.8 yang ditampilkan pada Tabel 6.13 dan Tabel 6.14.

Tabel 6.13 Hasil perhitungan MSE, MAD Skenario A Surabaya


Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.1	0.000	45.798	0.000	5.191
0.7	0.000	29.252	0.000	3.609

Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.8	0.000	17.920	0.000	3.223
0.801	0.000	17.920	0.000	3.223
0.81	0.000	17.916	0.000	3.225
0.9	0.000	17.873	0.000	3.234
1	0.000	7054.226	0.000	211.275
2.176	0.000	335070.918	0.000	478.362
5	0.000	7054.226	0.000	64.353
6	0.015	6094227.925	0.000	80.523
10	0.000	776384.123	0.000	509.714
11	0.000	1834837.823	0.000	708.934
14	0.000	10317636.492	0.000	1370.037
15	0.000	14932364.915	0.000	1579.352
16	0.000	20167380.375	0.000	1773.472

Tabel 6.14 Hasil perhitungan MASE Skenario A Surabaya

Spread	MASE Train	MASE Test
0.1	0.000	1.471
0.7	0.000	1.023
0.8	0.000	0.913
0.801	0.000	0.913
0.81	0.000	0.914
0.9	0.000	0.916
1	0.000	59.861
2.176	0.000	135.536
5	0.000	18.233
6	0.000	22.815
10	0.000	144.419
11	0.000	200.865
14	0.000	388.177
15	0.000	447.483
16	0.000	502.484


Untuk mempermudah dalam memilih MASE terendah dari tiap kandidat tersebut, digambarkan pada grafik yang ditampilkan pada Gambar 6.9.



Gambar 6.9 Grafik perbandingan Skenario A Surabaya

Pada Gambar 6.9 menunjukkan indeks terkecil adalah pada *spread* 0.8.

Perbandingan data aktual dengan data peramalan Kota Surabaya menggunakan model terbaik dari kombinasi ini dapat dilihat pada Gambar 6.10.



Gambar 6.10 Perbandingan data aktual dan peramalan Surabaya Skenario A

Dari hasil grafik tersebut sama halnya dengan Kabupaten Malang dimana perbandingan data aktual dengan peramalan pada proses *training* dapat mengikuti pola grafik secara sempurna. Namun ketika model disimulasikan kedalam data *testing* tidak dapat mengikuti pola grafik yang ada, sehingga nilai yang dihasilkan tidak bisa dikatakan bagus dan tidak bisa dikatakan jelek karena nilainya berada di tengah-tengah.

6.3.1.3 Pengelompokkan 3 (Sumenep)

Untuk permodelan dengan Skenario Kombinasi A pada pengelompokkan 3 dilakukan dengan menggunakan data kabupaten Sumenep. Dari *trial and error* parameter *spread* yang dilakukan didapatkan hasil terbaik adalah 0.711 dengan nilai parameter *spread* 0.4 yang ditampilkan pada Tabel 6.15 dan Tabel 6.16.

Tabel 6.15 Hasil perhitungan MSE, MAD Skenario A Sumenep

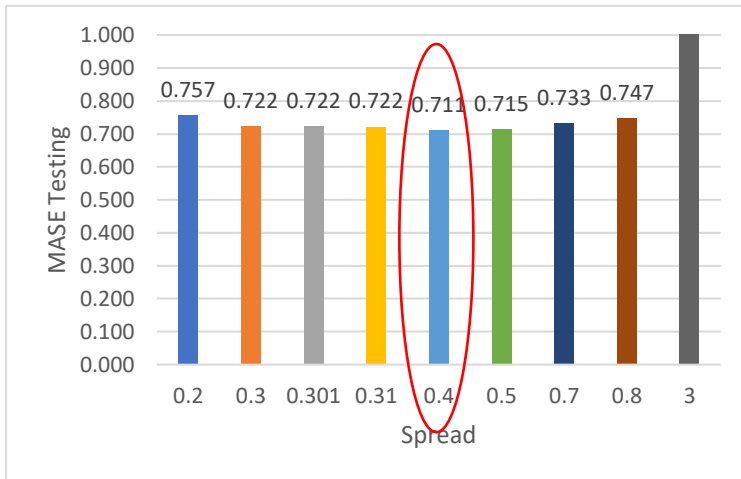
Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.2	0.009	3.018	0.019	0.979
0.3	0.009	1.964	0.019	0.935

Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.301	0.009	1.964	0.019	0.935
0.31	0.009	1.961	0.019	0.934
0.4	0.009	2.823	0.019	0.921
0.5	0.009	2.653	0.019	0.925
0.7	0.009	2.183	0.019	0.949
0.8	0.009	2.435	0.019	0.967
3	0.009	10325.981	0.019	58.058

Tabel 6.16 Hasil perhitungan MASE Skenario A Sumenep

Spread	MASE Train	MASE Test
0.2	0.029	0.757
0.3	0.029	0.722
0.301	0.029	0.722
0.31	0.029	0.722
0.4	0.029	0.711
0.5	0.029	0.715
0.7	0.029	0.733
0.8	0.029	0.747
3	0.029	44.863


Untuk mempermudah dalam memilih MASE terendah dari tiap kandidat tersebut, digambarkan pada grafik yang ditampilkan pada Gambar 6.11.



Gambar 6.11 Grafik perbandingan Skenario A Sumenep

Pada Gambar 6.11 menunjukkan indeks terkecil adalah pada *spread* 0.4.

Perbandingan data aktual dengan data peramalan Kabupaten Sumenep menggunakan model terbaik dari kombinasi ini dapat dilihat pada Gambar 6.12. Dari hasil perbandingan tersebut memiliki kasus yang mirip dengan Kabupaten Malang dan Surabaya yaitu pada saat disimulasikan kedalam data *testing* tidak dapat mengikuti pola data aktual.



Gambar 6.12 Perbandingan data aktual dan peramalan Sumenep Skenario A

6.3.2 Hasil Model Kombinasi B

Pada skenario model kombinasi ini mengkombinasikan variabel kepadatan penduduk dan jumlah penderita untuk meramalkan jumlah penderita di Kabupaten Malang, Surabaya, dan Sumenep. Jumlah node pada *input layer* pada kombinasi ini terdapat 2 node yang terdiri dari Kepadatan Penduduk dan Jumlah Penderita. Untuk target nya adalah Jumlah Penderita mulai dari periode $t+1$.

6.3.2.1 Pengelompokan 1 (Kabupaten Malang)

Pada pengelompokan 1 dilakukan beberapa kali percobaan (*trial and error*) terhadap parameter *spread* terhadap data *training* yang kemudian model yang didapatkan disimulasikan kedalam data *testing*. Dari berbagai kali percobaan tersebut kemudian dihitung nilai MSE, MAD dan MASE baik dari *training* maupun *testing*. Setelah diketahui nilai - nilai tersebut, kemudian model dipilih berdasarkan hasil MASE data *testing* terkecil yaitu 0.756 dengan parameter *spread* 0.1. Untuk hasil *trial and error* dapat dilihat pada Tabel 6.17 dan Tabel 6.18.

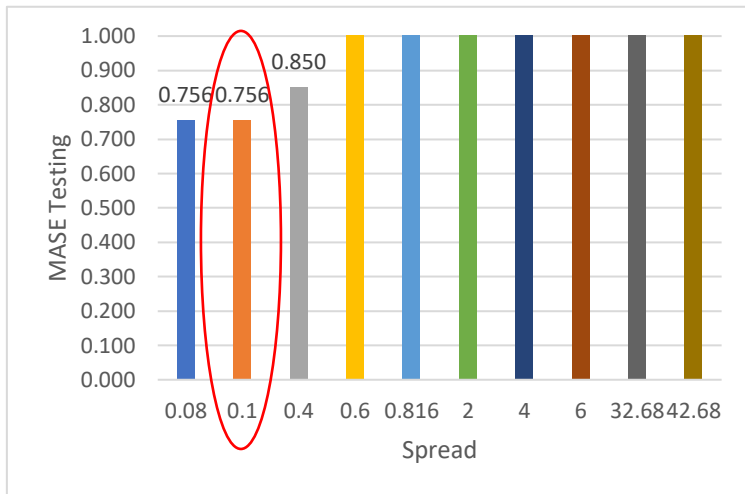
Tabel 6.17 Hasil perhitungan MSE, MAD Skenario B Kab. Malang

Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.08	0.000	7.647	0.000	2.000
0.1	0.000	7.647	0.000	2.000
0.4	0.000	9.403	0.000	2.259
0.6	0.000	21.814	0.000	4.025
0.816	0.000	185.808	0.000	13.174
2	0.000	51738333682.674	0.000	201744.594
4	0.018	20280675354623.200	0.059	3103210.237
6	0.076	920005136448.650	0.135	571037.905
32.68	0.347	381537.480	0.432	333.719
42.68	0.441	4512.143	0.501	42.028

Tabel 6.18 Hasil perhitungan MASE Skenario B Kab. Malang

Spread	MASE Train	MASE Test
0.08	0.000	0.756
0.1	0.000	0.756
0.4	0.000	0.850
0.6	0.000	1.520
0.816	0.000	4.980
2	0.000	76214.624
4	0.000	1172323.867
6	0.000	215725.431
32.68	0.000	126.072
42.68	0.000	15.880


Untuk mempermudah dalam memilih MASE terendah dari tiap kandidat tersebut, digambarkan pada grafik yang ditampilkan pada Gambar 6.13.



Gambar 6.13 Grafik perbandingan Skenario B Kab. Malang

Pada Gambar 6.13 menunjukkan indeks terkecil adalah pada *spread* 0.1.

Perbandingan data aktual dengan data peramalan Kabupaten Malang menggunakan model terbaik dari kombinasi ini dapat dilihat pada Gambar 6.14.



Gambar 6.14 Perbandingan data aktual dan peramalan Kab. Malang Skenario B

Walupun model ini memiliki MASE terkecil untuk data *testing*, namun dari grafik tersebut ketika model itu disimulasikan kedalam data *testing* tidak dapat mengikuti pola data aktualnya.

6.3.2.2 Pengelompokkan 2 (Surabaya)

Untuk permodelan dengan Skenario Kombinasi B pada pengelompokkan 2 dilakukan dengan menggunakan data kota Surabaya. Dari *trial and error* parameter *spread* yang dilakukan didapatkan hasil terbaik adalah 0.917 dengan nilai parameter *spread* 0.34 yang ditampilkan pada Tabel 6.19 dan Tabel 6.20

Tabel 6.19 Hasil perhitungan MSE, MAD Skenario B Surabaya

Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.08	0.000	29.268	3.370	1.949
0.1	0.000	18.882	3.370	5.000
0.3	0.000	20.235	3.370	4.000
0.33	0.000	20.235	3.370	4.000
0.34	0.000	23.588	3.370	3.000
0.35	0.000	23.588	3.370	3.000
0.39	0.000	23.589	3.370	3.000


Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.4	0.000	23.589	3.370	3.000
0.41	0.000	23.593	3.370	3.000
0.5	0.000	45.647	3.370	2.996
1	0.000	29.867	3.370	1.857
2	0.000	36.650	3.370	9.416
2.176	0.000	78.432	3.370	12.914
3	0.000	645446.301	3.370	805.673
6	0.000	779.356	3.370	21.900
10	0.000	47945.273	3.370	202.456
11	0.001	164.603	3.370	110.013
12	0.000	22009.853	3.370	137.248
13	0.000	296867.380	3.370	491.707
14	0.000	1838509.969	3.370	1204.575
15	0.000	10892754.758	3.370	2890.747
16	0.000	48161898.086	3.370	5997.282

Tabel 6.20 Hasil perhitungan MASE Skenario B Surabaya

Spread	MASE Train	MASE Test
0.08	0.000	1.011
0.1	0.000	0.983
0.3	0.000	0.933
0.33	0.000	0.933
0.34	0.000	0.917
0.35	0.000	0.917
0.39	0.000	0.917
0.4	0.000	0.917
0.41	0.000	0.917
0.5	0.000	0.917
1	0.000	1.031
2	0.000	1.537
2.176	0.000	2.325
3	0.000	226.807
6	0.000	7.672

Spread	MASE Train	MASE Test
10	0.000	58.829
11	0.000	32.637
12	0.000	37.520
13	0.000	137.917
14	0.000	339.852
15	0.000	817.678
16	0.000	1697.863

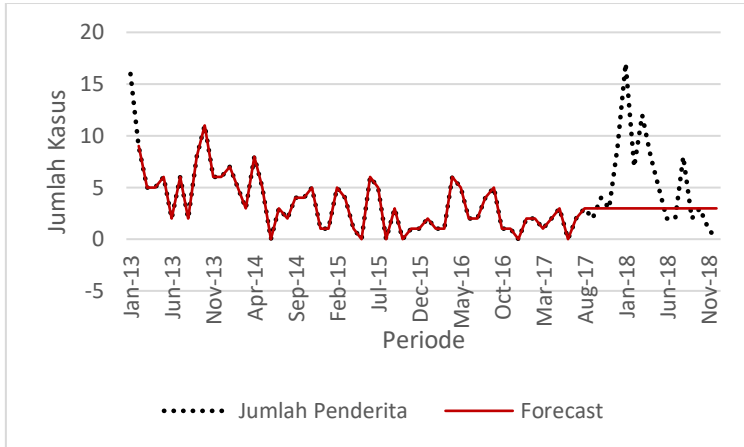
Untuk mempermudah dalam memilih MASE terendah dari tiap kandidat tersebut, digambarkan pada grafik yang ditampilkan pada Gambar 6.15.



Gambar 6.15 Grafik perbandingan Skenario B Surabaya

Pada Gambar 6.15 menunjukkan indeks terkecil adalah pada *spread* 0.34.

Perbandingan data aktual dengan data peramalan Kota Surabaya menggunakan model terbaik dari kombinasi ini dapat dilihat pada Gambar 6.16.



Gambar 6.16 Perbandingan data aktual dan peramalan Surabaya Skenario B

Dari hasil perbandingan data aktual dengan peramalan pada kota Surabaya dengan menggunakan model pada skenario ini, ketika model tersebut disimulasikan kedalam data *testing* hasil yang dikeluarkan tidak dapat mengikuti pola grafik yang ada. Nilai yang dihasilkan memiliki nilai yang sama.

6.3.2.3 Pengelompokkan 3 (Sumenep)

Untuk permodelan dengan Skenario Kombinasi B pada pengelompokkan 3 dilakukan dengan menggunakan data kabupaten Sumenep. Dari *trial and error* parameter *spread* yang dilakukan didapatkan hasil terbaik adalah 0.755 dengan nilai parameter *spread* 0.3 yang ditampilkan pada Tabel 6.21 dan Tabel 6.22.

Tabel 6.21 Hasil perhitungan MSE, MAD Skenario B Sumenep

Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.1	0.000	3.036	0.000	0.990
0.2	0.000	3.630	0.000	1.255
0.3	0.000	2.571	0.000	0.977
0.4	0.000	170.208	0.000	12.703

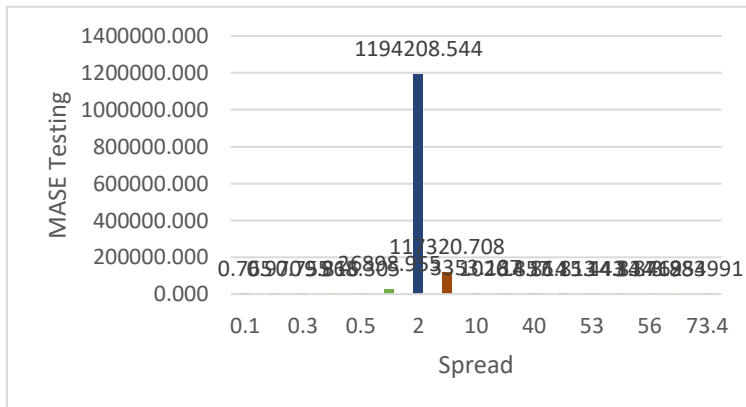
Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.5	0.000	1705800.885	0.000	1253.101
0.7	0.000	1442993539.023	0.000	34810.413
2	0.045	8527628646053.130	0.124	1545446.351
5	0.114	165028860186.507	0.215	151826.798
10	0.164	142408646.147	0.249	4339.419
11.1	0.170	10733190.137	0.262	1328.874
40	0.233	2321.364	0.344	19.171
50	0.251	2047.773	0.362	21.758
53	0.250	1913.454	0.361	19.985
55	0.248	1866.305	0.360	19.197
56	0.248	1832.416	0.363	18.716
60	0.404	47.128	0.463	5.025
73.4	0.404	46.923	0.464	5.011

Tabel 6.22 Hasil perhitungan MASE Skenario B Sumenep

Spread	MASE Train	MASE Test
0.1	0.000	0.765
0.2	0.000	0.970
0.3	0.000	0.755
0.4	0.000	9.816
0.5	0.000	968.305
0.7	0.000	26898.955
2	0.191	1194208.544
5	0.331	117320.708
10	0.384	3353.187
11.1	0.404	1026.857
40	0.530	14.814
50	0.558	16.813
53	0.558	15.443

Spread	MASE Train	MASE Test
55	0.556	14.834
56	0.559	14.462
60	0.715	3.883
73.4	0.715	3.87195499


Untuk mempermudah dalam memilih MASE terendah dari tiap kandidat tersebut, digambarkan pada grafik yang ditampilkan pada Gambar 6.17.



Gambar 6.17 Grafik perbandingan Skenario B Sumenep

Pada Gambar 6.10 menunjukkan indeks terkecil adalah pada *spread* 0.3.

Perbandingan data aktual dengan data peramalan Kabupaten Sumenep menggunakan model terbaik dari kombinasi ini dapat dilihat pada Gambar 6.18.



Gambar 6.18 Perbandingan data aktual dan peramalan Sumenep Skenario B

Dari grafik tersebut diketahui bahwa nilai yang dihasilkan pada area data *testing* terlampaui jauh dari nilai aslinya. Model pada skenario ini jika disimulasikan kedalam data *testing* tidak dapat mengikuti pola grafik yang ada.

6.3.3 Hasil Model Kombinasi C

Pada skenario model kombinasi ini hanya melibatkan variabel jumlah penderita untuk meramalkan jumlah penderita di Kabupaten Malang, Surabaya, dan Sumenep. Jumlah node pada *input layer* pada kombinasi ini terdapat 1 node yang terdiri dari Jumlah Penderita saja. Untuk target nya adalah Jumlah Penderita mulai dari periode $t+1$.

6.3.3.1 Pengelompokan 1 (Kabupaten Malang)

Pada pengelompokan 1 dilakukan beberapa kali percobaan (*trial and error*) terhadap parameter *spread* terhadap data *training* yang kemudian model yang didapatkan disimulasikan kedalam data *testing*. Dari berbagai kali percobaan tersebut kemudian dihitung nilai MSE, MAD dan MASE baik dari *training* maupun *testing*. Setelah diketahui nilai - nilai tersebut, kemudian model dipilih berdasarkan hasil MASE data *testing*

terkecil yaitu 0.840 dengan parameter *spread* 0.2. Untuk hasil *trial and error* dapat dilihat pada Tabel 6.23 dan Tabel 6.24.

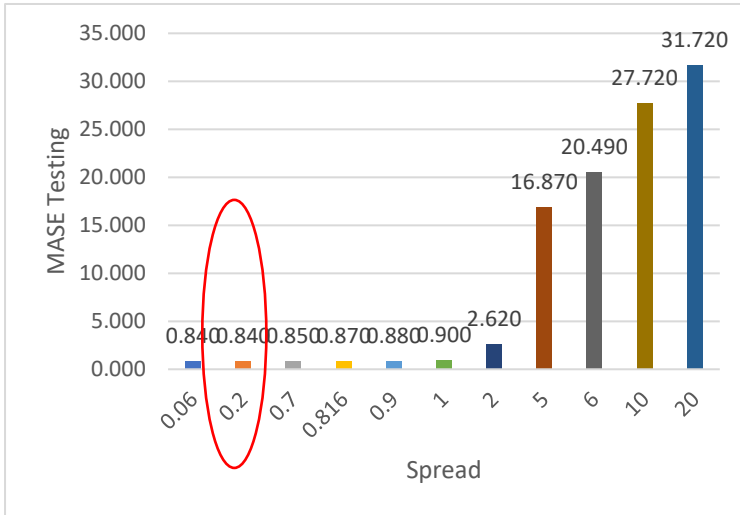
Tabel 6.23 Hasil perhitungan MSE, MAD Skenario C Kab. Malang

Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.06	1.601	7.869	0.866	2.214
0.2	1.601	7.869	0.866	2.214
0.7	1.601	8.063	0.866	2.258
0.816	1.574	8.707	0.866	2.295
0.9	1.574	8.981	0.866	2.332
1	1.574	9.509	0.866	2.391
2	1.601	381.544	0.866	6.922
5	1.601	29096.074	0.866	44.661
6	1.601	43645.193	0.866	54.230
10	1.601	86360.763	0.866	73.368
20	1.574184	113978.9	0.8661269	83.97571

Tabel 6.24 Hasil perhitungan MASE Skenario C Kab. Malang

Spread	MASE Train	MASE Test
0.06	0.709	0.840
0.2	0.709	0.840
0.7	0.709	0.850
0.816	0.709	0.870
0.9	0.709	0.880
1	0.709	0.900
2	0.709	2.620
5	0.709	16.870
6	0.709	20.490
10	0.709	27.720
20	0.709	31.720


Untuk mempermudah dalam memilih MASE terendah dari tiap kandidat tersebut, digambarkan pada grafik yang ditampilkan pada Gambar 6.19.



Gambar 6.19 Grafik perbandingan Skenario C Kab. Malang

Pada Gambar 6.19 menunjukkan indeks terkecil adalah pada *spread* 0.2.

Perbandingan data aktual dengan data peramalan Kabupaten Malang menggunakan model terbaik dari kombinasi ini dapat dilihat pada Gambar 6.20.



Gambar 6.20 Perbandingan data aktual dan peramalan Kab. Malang Skenario C

Jika dilihat dari grafik tersebut, pola peramalan yang dibentuk pada data *training* memang tidak sebagus dari skenario model yang lain, tetapi dapat dikatakan model yang dihasilkan memiliki konsistensi terhadap data, dimana ketika model sudah dibuat dan disimulasikan kedalam data *testing* dapat mengikuti pola data aktual jika dibandingkan dengan model yang lainnya (dari skenario A dan B) meskipun tidak dapat menangkap nilai fluktuasi, sehingga nilai yang diramalkan cenderung memiliki range yang sama dengan peramalan di data *training*.

6.3.3.2 Pengelompokan 2 (Surabaya)

Untuk permodelan dengan Skenario Kombinasi C pada pengelompokan 2 dilakukan dengan menggunakan data kota Surabaya. Dari *trial and error* parameter *spread* yang dilakukan didapatkan hasil terbaik adalah 0.817 dengan nilai parameter *spread* 0.8 yang ditampilkan pada Tabel 6.25 dan Tabel 6.26.

Tabel 6.25 Hasil perhitungan MSE, MAD Skenario C Surabaya


Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.03	4.212	18.568	3.370	4.519
0.07	4.212	18.568	3.370	4.519

Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.1	4.212	18.568	3.370	4.519
0.4	4.212	18.564	3.370	4.519
0.7	4.212	18.514	3.370	4.519
0.8	4.212	18.510	3.370	4.519
1	4.212	18.480	3.370	4.519
2	4.212	2094.071	3.370	19.968
2.176	4.212	3614.293	3.370	24.631
5	4.212	1023922034.110	3.370	7832.465
8	4.392	2319629.150	3.370	376.782
10	4.390	4594657.204	3.370	527.726
11	4.390	3546807.168	3.371	463.363
12	4.442	11352.898	3.370	30.450
13	4.441	13028.092	3.370	32.317
14	4.441	14602.743	3.370	33.964
15	4.441	16003.526	3.370	35.355
16	4.440	17229.425	3.370	36.523

Tabel 6.26 Hasil perhitungan MASE Skenario C Surabaya

Spread	MASE Train	MASE Test
0.03	0.703	0.834
0.07	0.703	0.834
0.1	0.703	0.834
0.4	0.703	0.833
0.7	0.703	0.822
0.8	0.703	0.817
1	0.703	0.824
2	0.703	5.211
2.176	0.703	6.532
5	0.703	2219.019
8	0.749	106.499
10	0.749	149.267
11	0.749	131.035
12	0.756	8.341


Spread	MASE Train	MASE Test
13	0.756	8.870
14	0.756	9.337
15	0.756	9.731
16	0.756	10.062



Gambar 6.21 Grafik perbandingan Skenario C Surabaya

Pada Gambar 6.21 menunjukkan indeks terkecil adalah pada *spread* 0.8.

Untuk mempermudah dalam memilih MASE terendah dari tiap kandidat tersebut, digambarkan pada grafik yang ditampilkan pada Gambar 6.21. Untuk perbandingan data aktual dengan data peramalan Kota Surabaya menggunakan model terbaik dari kombinasi ini dapat dilihat pada Gambar 6.22.



Gambar 6.22 Perbandingan data aktual dan peramalan Surabaya Skenario C

Sama halnya dengan skenario C pada pengelompokan 1, pola peramalan yang dibentuk pada data *training* memang tidak sebagus dari skenario model yang lain, tetapi dapat dikatakan model yang dihasilkan memiliki konsistensi terhadap data, dimana ketika model sudah dibuat dan disimulasikan kedalam data *testing* dapat mengikuti pola data aktual jika dibandingkan dengan model yang lainnya (dari skenario A dan B) meskipun tidak dapat menangkap nilai fluktuasi, sehingga nilai yang diramalkan cenderung memiliki range yang sama dengan peramalan di data *training*.

6.3.3.3 Pengelompokan 3 (Sumenep)

Untuk permodelan dengan Skenario Kombinasi C pada pengelompokan 3 dilakukan dengan menggunakan data kabupaten Sumenep. Dari *trial and error* parameter *spread* yang dilakukan didapatkan hasil terbaik adalah 0.820 dengan nilai parameter *spread* 1 yang ditampilkan pada Tabel 6.27 dan Tabel 6.28.


Tabel 6.27 Hasil perhitungan MSE, MAD Skenario C Sumenep

Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.01	0.551	2.530	0.573	1.086
0.1	0.551	2.530	0.573	1.086
0.3	0.551	2.530	0.573	1.086
0.9	0.551	2.508	0.573	1.073
1	0.551	2.491	0.573	1.061
2	0.551	3.851	0.573	1.312
3	0.551	5.640	0.573	1.459
4	0.551	7.072	0.573	1.547
8	0.551	9.367	0.573	1.664
15	0.551	10.117	0.573	1.698

Tabel 6.28 Hasil perhitungan MASE Skenario C Sumenep

Spread	MASE Train	MASE Test
0.01	0.884	0.839
0.1	0.884	0.839
0.3	0.884	0.839
0.9	0.884	0.829
1	0.884	0.820
2	0.884	1.014
3	0.884	1.127
4	0.884	1.196
8	0.884	1.286
15	0.884	1.312


Untuk mempermudah dalam memilih MASE terendah dari tiap kandidat tersebut, digambarkan pada grafik yang ditampilkan pada Gambar 6.23.



Gambar 6.23 Grafik perbandingan Skenario C Sumenep

Pada Gambar 6.23 menunjukkan indeks terkecil adalah pada *spread* 1.

Perbandingan data aktual dengan data peramalan Kabupaten Sumenep menggunakan model terbaik dari kombinasi ini dapat dilihat pada Gambar 6.24.



Gambar 6.24 Perbandingan data aktual dan peramalan Sumenep Skenario C

Sama halnya dengan skenario C pada pengelompokn 2, pola peramalan yang dibentuk pada data *training* memang tidak

sebagus dari skenario model yang lain, tetapi dapat dikatakan model yang dihasilkan memiliki konsistensi terhadap data, dimana ketika model sudah dibuat dan disimulasikan kedalam data *testing* dapat mengikuti pola data aktual jika dibandingkan dengan model yang lainnya (dari skenario A dan B) dan dapat menangkap nilai fluktuasi pada data *testing*.

6.3.4 Hasil Model Kombinasi D

Pada skenario model kombinasi ini melibatkan semua variabel yaitu cakupan imunisasi dpt 1 hingga 4, kepadatan penduduk, dan jumlah penderita untuk meramalkan jumlah penderita di Kabupaten Malang, Surabaya, dan Sumenep. Jumlah node pada *input layer* pada kombinasi ini terdapat 6 node yang terdiri dari Cakupan Imunisasi DPT 1 hingga 4, Kepadatan Penduduk, dan Jumlah Penderita. Untuk target nya adalah Jumlah Penderita mulai dari periode $t+1$.

6.3.4.1 Pengelompokkan 1 (Kabupaten Malang)

Pada pengelompokkan 1 dilakukan beberapa kali percobaan (*trial and error*) terhadap parameter *spread* terhadap data *training* yang kemudian model yang didapatkan disimulasikan kedalam data *testing*. Dari berbagai kali percobaan tersebut kemudian dihitung nilai MSE, MAD dan MASE baik dari *training* maupun *testing*. Setelah diketahui kedua nilai tersebut, kemudian model dipilih berdasarkan hasil MASE data *testing* terkecil yaitu 0.876 dengan parameter *spread* 0.816. Untuk hasil *trial and error* dapat dilihat pada Tabel 6.29 dan Tabel 6.30.

Tabel 6.29 Hasil perhitungan MSE, MAD Skenario D Kab. Malang


Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.816	0.000	10.362	1.444	1.239
2.5	0.000	533.154	1.444	43.193
3	0.000	10.281	1.444	59.277
4	0.000	40.977	1.444	111.794
8	0.000	2015.340	1.444	890.145
10	0.000	2049.655	1.444	100.314

Spread	MSE Train	MSE Test	MAD Train	MAD Test
11	0.000	2141.886	1.444	153.725
28.68	0.000	2430.725	1.444	3562.062
38.68	0.000	2931.032	1.444	3629.531
42.68	0.000	3045.920	1.444	3291.753

Tabel 6.30 Hasil perhitungan MASE Skenario D Kab. Malang


Spread	MASE Train	MASE Test
0.816	0.000	0.876
2.5	0.000	8.161
3	0.000	0.924
4	0.000	2.036
8	0.000	12.473
10	0.000	11.264
11	0.000	10.973
28.68	0.000	11.848
38.68	0.000	13.796
42.68	0.000	14.144

Untuk mempermudah dalam memilih MASE terendah dari tiap kandidat tersebut, digambarkan pada grafik yang ditampilkan pada Gambar 6.25. Untuk perbandingan data aktual dengan data peramalan Kabupaten Malang menggunakan model terbaik dari kombinasi ini dapat dilihat pada Gambar 6.26. Dari grafik tersebut, ketika model disimulasikan kedalam data *testing*, model cukup dapat mengikuti pola aktual walaupun pada akhir periode tidak begitu sesuai arah pola grafiknya.



Gambar 6.25 Grafik perbandingan Skenario D Kab. Malang

Pada Gambar 6.25 menunjukkan indeks terkecil adalah pada *spread* 0.82.



Gambar 6.26 Perbandingan data aktual dan peramalan Kab. Malang Skenario D

6.3.4.2 Pengelompokan 2 (Surabaya)

Untuk permodelan dengan Skenario Kombinasi D pada pengelompokan 2 dilakukan dengan menggunakan data kota Surabaya. Dari *trial and error* parameter *spread* yang dilakukan didapatkan hasil terbaik adalah 0.973 dengan nilai parameter *spread* 3 yang ditampilkan pada Tabel 6.31 dan Tabel 6.32.

Tabel 6.31 Hasil perhitungan MSE, MAD Skenario D Surabaya


Spread	MSE Train	MSE Test	MAD Train	MAD Test
1	0.000	27.587	3.370	8.132
2.176	0.000	33.472	3.370	1.536
3	0.000	26.891	3.370	2.339
5	0.000	19.694	3.370	6.393
5.01	0.000	19.668	3.370	6.382
5.011	0.000	19.665	3.370	6.381
5.03	0.000	19.615	3.370	6.361
5.1	0.000	19.424	3.370	6.283
6	0.000	207.351	3.370	18.639
9	0.000	478.848	3.370	15.813
11	0.000	228.731	3.370	9.106
14	0.000	63996.488	3.370	232.996
15	0.000	82.409	3.370	4.486
16	0.000	87.110	3.370	5.547

Tabel 6.32 Hasil perhitungan MASE Skenario D Surabaya

Spread	MASE Train	MASE Test
1	0.000	1.291
2.176	0.000	1.100
3	0.000	0.973
5	0.000	1.039
5.01	0.000	1.038
5.011	0.000	1.038
5.03	0.000	1.037
5.1	0.000	1.033
6	0.000	3.814


Spread	MASE Train	MASE Test
9	0.000	5.947
11	0.000	4.047
14	0.000	64.549
15	0.000	2.034
16	0.000	2.161

Untuk mempermudah dalam memilih MASE terendah dari tiap kandidat tersebut, digambarkan pada grafik yang ditampilkan pada Gambar 6.27. Untuk perbandingan data aktual dengan data peramalan Kota Surabaya menggunakan model terbaik dari kombinasi ini dapat dilihat pada Gambar 6.28.



Gambar 6.27 Grafik perbandingan Skenario D Surabaya

Pada Gambar 6.27 menunjukkan indeks terkecil adalah pada *spread* 3.



Gambar 6.28 Perbandingan data aktual dan peramalan Surabaya Skenario D

Dari hasil perbandingan data aktual dengan peramalan pada kota Surabaya dengan menggunakan model pada skenario ini, ketika model tersebut disimulasikan kedalam data *testing* hasil yang dikeluarkan tidak dapat mengikuti pola grafik yang ada.

6.3.4.3 Pengelompokkan 3 (Sumenep)

Untuk permodelan dengan Skenario Kombinasi D pada pengelompokkan 3 dilakukan dengan menggunakan data kabupaten Sumenep. Dari *trial and error* parameter *spread* yang dilakukan didapatkan hasil terbaik adalah 0.742 dengan nilai parameter *spread* 0.8 yang ditampilkan pada Tabel 6.33 dan Tabel 6.34.

Tabel 6.33 Hasil perhitungan MSE, MAD Skenario D Sumenep


Spread	MSE Train	MSE Test	MAD Train	MAD Test
0.8	0.000	2.941	0.000	0.961
1	0.000	29.056	0.000	5.103
2	0.000	8.415	0.000	2.669
2.01	0.000	8.601	0.000	2.697
2.1	0.000	10.490	0.000	2.962

Spread	MSE Train	MSE Test	MAD Train	MAD Test
3	0.000	62.955	0.000	6.785
5	0.000	1887.487	0.000	30.972
10	0.000	8444.306	0.000	51.946
20	0.000	2359.078	0.000	31.367
40	0.000	28272.127	0.000	69.603
42	0.000	19191.060	0.000	61.035
55	0.000	51243.488	0.000	112.796
70	0.000	91737.895	0.000	141.482

Tabel 6.34 Hasil perhitungan MASE Skenario D Sumenep

Spread	MASE Train	MASE Test
0.8	0.000	0.742
1	0.000	3.943
2	0.000	2.063
2.01	0.000	2.084
2.1	0.000	2.289
3	0.000	5.243
5	0.000	23.933
10	0.000	40.140
20	0.000	24.238
40	0.000	53.784
42	0.000	47.164
55	0.000	87.160
70	0.000	109.327


Untuk mempermudah dalam memilih MASE terendah dari tiap kandidat tersebut, digambarkan pada grafik yang ditampilkan pada Gambar 6.29.



Gambar 6.29 Grafik perbandingan Skenario D Sumenep

Pada Gambar 6.29 menunjukkan indeks terkecil adalah pada *spread* 0.8.

Perbandingan data aktual dengan data peramalan Kabupaten Sumenep menggunakan model terbaik dari kombinasi ini dapat dilihat pada Gambar 6.30.



Gambar 6.30 Perbandingan data aktual dan peramalan Sumenep Skenario D

Grafik pada Sumenep memiliki kesamaan pada pengelompokan 1 yaitu Kabupaten Malang dimana ketika model disimulasikan kedalam data *testing* sedikit dapat mengikuti pola aktual walaupun pada akhir periode tidak begitu sesuai arah pola grafiknya.

6.4 Kesimpulan Hasil Model Kombinasi

Dari berbagai kali percobaan yang dilakukan terhadap setiap pengelompokan, didapatkan hasil permodelan yang beraneka ragam, hingga dipilih model terbaik di setiap kombinasi. Hasil permodelan tersebut diurutkan berdasarkan MASE Testing terkecil, dimana proses ini digunakan untuk proses berikutnya yaitu validasi model.

6.4.1 Pengelompokan 1 (Kabupaten Malang)

Dari hasil skenario permodelan yang telah dilakukan dalam proses sebelumnya, pada Tabel 6.35 merupakan urutan model sesuai MASE Testing terendah untuk kelompok pertama dengan Kabupaten Malang sebagai acuan data permodelan.

Tabel 6.35 Urutan model kombinasi kelompok 1

Kombinasi	Spread	MASE Test
A	0.2	0.000
B	0.1	0.000
C	0.2	1.601
D	0.82	0.000

6.4.2 Pengelompokan 2 (Surabaya)

Dari hasil skenario permodelan yang telah dilakukan dalam proses sebelumnya, pada Tabel 6.36 merupakan urutan model sesuai MASE Testing terendah untuk kelompok kedua dengan Kota Surabaya sebagai acuan data permodelan.

Tabel 6.36 Urutan model kombinasi kelompok 2

Kombinasi	Spread	MASE Test
C	0.8	0.817
A	0.8	0.913
B	0.34	0.917
D	3	0.973

6.4.3 Pengelompokan 3 (Sumenep)

Dari hasil skenario permodelan yang telah dilakukan dalam proses sebelumnya, pada Tabel 6.37 merupakan urutan model sesuai MASE Testing terendah untuk kelompok ketiga dengan Kabupaten Sumenep sebagai acuan data permodelan.

Tabel 6.37 Urutan model kombinasi kelompok 3

Kombinasi	Spread	MSE Train
A	0.4	0.009
D	0.8	0.000
B	0.3	0.000
C	1	0.551

6.5 Hasil Validasi Model

Dari berbagai kali percobaan yang dilakukan terhadap setiap pengelompokan, didapatkan hasil yang beraneka ragam. Terdapat pula MASE yang kecil namun tidak dapat mengikuti pola data yang ada, terdapat pula MASE nya lebih besar dari model yang lainnya tetapi dapat mengikuti pola data yang ada. Walaupun terdapat model yang tidak bisa mengikuti pola data ketika disimulasikan kedalam data *testing*, namun model-model tersebut tetap akan divalidasi menggunakan data lain.

Jika pada saat validasi model tersebut memang tetap tidak bisa memperbaiki pola data, yang artinya tidak ada peningkatan performa, maka model tersebut tidak akan digunakan. Jika saat validasi model selanjutnya dapat mengikuti pola data yang ada,


maka model tersebut yang akan digunakan. Jika semua model pada saat validasi tidak dapat mengikuti pola data, maka dilihat dari rata-rata MSE dari setiap kombinasi dan dipilih yang memiliki rata-rata paling kecil diantaranya.

6.5.1 Pengelompokan 1

Kombinasi-kombinasi model yang ditampilkan pada Tabel 6.35 merupakan Kandidat Model Terbaik yang digunakan untuk melakukan peramalan. Tiap kandidat dilakukan validasi satu per satu ke data yang lain yaitu 3 kota/kabupaten dan dilakukan analisis apakah model yang sedang divalidasi memiliki performa yang baik terhadap data validasi. Kota / kabupaten yang digunakan pada kelompok satu adalah Sidoarjo, Batu, dan Kabupaten Tuban.

6.5.1.1 Validasi Skenario Model Kombinasi A

Kandidat urutan pertama adalah dengan Skenario Model A dengan menggunakan variabel Cakupan Imunisasi dan Jumlah Penderita. Hasil validasi pada Kabupaten Sidoarjo dapat dilihat pada Gambar 6.31. Hasil validasi pada Kota Batu dapat dilihat pada Gambar 6.32. Hasil validasi pada Kabupaten Tuban dapat dilihat pada Gambar 6.33.




Gambar 6.31 Validasi Skenario A pada Kabupaten Sidoarjo

Pada validasi yang dilakukan pada, model yang dihasilkan melalui Skenario Model A dari kelompok satu memiliki performa yang tidak baik ditandai dengan model yang tidak dapat mengikuti pola data aktual nya. Sehingga model ini tidak akan digunakan untuk peramalan.

Untuk mengetahui nilai MSE, MAD dan MASE dari validasi ini dapat dilihat pada Tabel 6.38.


Tabel 6.38 Hasil akurasi data validasi Skenario A

MODEL : A			
KOTA / KAB	MSE	MAD	MASE
Sidoarjo	5.076362	1.648129	0.774948
Kab. Tuban	2.841456	1.527478	1.838151
Batu	2.897142	1.545169	1.82845



Gambar 6.32 Validasi Skenario A pada Kota Batu

Pada validasi yang dilakukan pada Gambar 6.32, model yang dihasilkan melalui Skenario Model A dari kelompok satu memiliki performa yang tidak baik ditandai dengan model yang tidak dapat mengikuti pola data aktual nya.




Gambar 6.33 Validasi Skenario A pada Kabupaten Tuban

Pada validasi yang dilakukan pada Gambar 6.33, model yang dihasilkan melalui Skenario Model A dari kelompok satu memiliki performa yang tidak baik ditandai dengan model yang tidak dapat mengikuti pola data aktual nya.

6.5.1.2 Validasi Skenario Model Kombinasi B

Kandidat urutan kedua adalah dengan Skenario Model D dengan menggunakan variabel Kepadatan Penduduk dan Jumlah Penderita. Hasil validasi pada Kabupaten Sidoarjo dapat dilihat pada Gambar 6.34. Hasil validasi pada Kota Batu dapat dilihat pada Gambar 6.35. Hasil validasi pada Kabupaten Tuban dapat dilihat pada Gambar 6.36.




Gambar 6.34 Validasi Skenario B pada Kabupaten Sidoarjo

Pada validasi yang dilakukan, model yang dihasilkan melalui Skenario Model D dari kelompok satu memiliki performa yang tidak baik ditandai dengan model yang tidak dapat mengikuti pola data aktual nya. Prediksi yang dihasilkan antar kota/kabupaten validasi menunjukkan nilai yang sama. Sehingga model ini tidak dapat digunakan.

Untuk mengetahui nilai MSE, MAD dan MASE dari validasi ini dapat dilihat pada Tabel 6.39.


Tabel 6.39 Hasil akurasi data validasi Skenario B

MODEL : B			
KOTA / KAB	MSE	MAD	MASE
Sidoarjo	7.211268	1.887324	0.887417
Kab. Tuban	1.422535	0.859155	1.033898
Batu	1.422535	0.915493	1.083333



Gambar 6.35 Validasi Skenario B pada Kota Batu

Pada validasi yang dilakukan pada Gambar 6.35, model yang dihasilkan melalui Skenario Model B dari kelompok satu memiliki performa yang tidak baik ditandai dengan model yang tidak dapat mengikuti pola data aktual nya.




Gambar 6.36 Validasi Skenario B pada Kabupaten Tuban

Pada validasi yang dilakukan pada Gambar 6.36, model yang dihasilkan melalui Skenario Model B dari kelompok satu memiliki performa yang tidak baik ditandai dengan model yang tidak dapat mengikuti pola data aktual nya.

6.5.1.3 Validasi Skenario Model Kombinasi C

Kandidat urutan ketiga adalah dengan Skenario Model C dengan menggunakan variabel Jumlah Penderita saja. Hasil validasi pada Kabupaten Sidoarjo dapat dilihat pada Gambar 6.37. Hasil validasi pada Kota Batu dapat dilihat pada Gambar 6.38. Hasil validasi pada Kabupaten Tuban dapat dilihat pada Gambar 6.39.




Gambar 6.37 Validasi Skenario C pada Kabupaten Sidoarjo

Pada validasi yang dilakukan, model yang dihasilkan melalui Skenario Model C dari kelompok satu memiliki performa yang baik ditandai dengan model yang dapat mengikuti pola data aktual nya. Prediksi yang dihasilkan antar kota/kabupaten validasi menunjukkan nilai berdekatan dengan data aktual. Sehingga model inilah yang digunakan.

Untuk mengetahui nilai MSE, MAD dan MASE dari validasi ini dapat dilihat pada Tabel 6.40.


Tabel 6.40 Hasil akurasi data validasi Skenario C

MODEL : C			
KOTA / KAB	MSE	MAD	MASE
Sidoarjo	6.3247107	1.8729879	0.8806764
Kab. Tuban	1.6883633	1.0739437	1.2923729
Batu	1.8381953	1.1115862	1.315377



Gambar 6.38 Validasi Skenario C pada Kota Batu

Pada validasi yang dilakukan Gambar 6.38, model yang dihasilkan melalui Skenario Model C dari kelompok satu memiliki performa yang baik ditandai dengan model yang dapat mengikuti pola data aktual nya. Prediksi yang dihasilkan antar kota/kabupaten validasi menunjukkan nilai berdekatan dengan data aktual.




Gambar 6.39 Validasi Skenario C pada Kabupaten Tuban

Pada validasi yang dilakukan Gambar 6.39, model yang dihasilkan melalui Skenario Model C dari kelompok satu memiliki performa yang kurang baik ditandai dengan model yang tidak dapat mengikuti pola data aktual nya.

6.5.1.4 Validasi Skenario Model Kombinasi D

Kandidat urutan keempat adalah dengan Skenario Model B dengan menggunakan variabel Cakupan Imunisasi, Kepadatan Penduduk dan Jumlah Penderita. Hasil validasi Kabupaten Sidoarjo dapat dilihat pada Gambar 6.40. Hasil validasi pada Kabupaten Tuban dapat dilihat pada Gambar 6.41. Hasil validasi pada Kota Batu dapat dilihat pada Gambar 6.42.




Gambar 6.40 Validasi Skenario D pada Kabupaten Sidoarjo

Pada validasi yang dilakukan, model yang dihasilkan melalui Skenario Model B dari kelompok satu memiliki performa yang tidak baik ditandai dengan model yang tidak dapat mengikuti pola data aktual nya. Prediksi yang dihasilkan antar kota/kabupaten validasi menunjukkan nilai yang sama. Sehingga model ini tidak dapat digunakan.

Untuk mengetahui nilai MSE, MAD dan MASE dari validasi ini dapat dilihat pada Tabel 6.41.


Tabel 6.41 Hasil akurasi data validasi Skenario D

MODEL : D			
KOTA / KAB	MSE	MAD	MASE
Sidoarjo	9.4227554	2.306005	1.0842805
Kab. Tuban	1.4503139	0.78527	0.944986
Batu	1.3518007	0.7595137	0.8987579



Gambar 6.41 Validasi Skenario D pada Kabupaten Tuban

Pada validasi yang dilakukan Gambar 6.41, model yang dihasilkan melalui Skenario Model B dari kelompok satu memiliki performa yang tidak baik ditandai dengan model yang tidak dapat mengikuti pola data aktual nya. Prediksi yang dihasilkan antar kota/kabupaten validasi menunjukkan nilai yang sama.



Gambar 6.42 Validasi Skenario D pada Kota Batu


Pada validasi yang dilakukan Gambar 6.42, model yang dihasilkan melalui Skenario Model B dari kelompok satu memiliki performa yang tidak baik ditandai dengan model yang tidak dapat mengikuti pola data aktual nya. Prediksi yang dihasilkan antar kota/kabupaten validasi menunjukkan nilai yang sama.

6.5.2 Pengelompokan 2

Kombinasi-kombinasi model yang ditampilkan pada Tabel 6.36 merupakan Kandidat Model Terbaik yang digunakan untuk melakukan peramalan. Tiap kandidat dilakukan validasi satu per satu ke data yang lain yaitu 3 kota/kabupaten dan dilakukan analisis apakah model yang sedang divalidasi memiliki performa yang baik terhadap data validasi. Kota / kabupaten yang digunakan pada kelompok satu adalah Kabupaten Blitar, Tulungagung, dan Bangkalan..


6.5.2.1 Validasi Skenario Model Kombinasi C

Kandidat urutan pertama adalah dengan Skenario Model C dengan menggunakan variabel Jumlah Penderita saja. Hasil validasi pada Kabupaten Blitar dapat dilihat pada Gambar 6.43. Hasil validasi pada Kabupaten Tulungagung dapat dilihat pada Gambar 6.44. Hasil validasi pada Kabupaten Bangkalan dapat dilihat pada Gambar 6.45.




Gambar 6.43 Validasi Skenario C pada Kabupaten Blitar

Pada validasi yang dilakukan, model yang dihasilkan melalui Skenario Model C dari kelompok satu memiliki performa yang baik ditandai dengan model yang dapat mengikuti pola data aktual nya. Prediksi yang dihasilkan antar kota/kabupaten validasi menunjukkan nilai berdekatan dengan data aktual. Sehingga model inilah yang digunakan.



Gambar 6.44 Validasi Skenario C pada Kabupaten Tulungagung

Pada validasi yang dilakukan Gambar 6.44, model yang dihasilkan melalui Skenario Model C dari kelompok satu memiliki performa yang baik ditandai dengan model yang dapat mengikuti pola data aktual nya. Prediksi yang dihasilkan antar kota/kabupaten validasi menunjukkan nilai berdekatan dengan data aktual.



Gambar 6.45 Validasi Skenario C pada Kabupaten Bangkalan

Pada validasi yang dilakukan Gambar 6.45, model yang dihasilkan melalui Skenario Model C dari kelompok satu memiliki performa yang baik ditandai dengan model yang dapat mengikuti pola data aktual nya. Prediksi yang dihasilkan antar kota/kabupaten validasi menunjukkan nilai berdekatan dengan data aktual.


Untuk mengetahui nilai MSE, MAD dan MASE dari validasi ini dapat dilihat pada Tabel 6.42.

Tabel 6.42 Hasil akurasi data validasi Skenario C

MODEL : C			
KOTA / KAB	MSE	MAD	MASE
Kabupaten Blitar	8.93	2.13	1.02
Tulungagung	5.30	1.97	1.27
Kab. Bangkalan	4.73	1.79	1.42

6.5.2.2 Validasi Skenario Model Kombinasi A

Kandidat urutan kedua adalah dengan Skenario Model A dengan menggunakan variabel Cakupan Imunisasi dan Jumlah Penderita. Hasil validasi pada Kabupaten Blitar dapat dilihat pada Gambar 6.46. Hasil validasi pada Kabupaten Tulungagung dapat dilihat pada Gambar 6.47. Hasil validasi pada Kabupaten Bangkalan dapat dilihat pada Gambar 6.48.




Gambar 6.46 Validasi Skenario A pada Kabupaten Blitar


Untuk mengetahui nilai MSE, MAD dan MASE dari validasi ini dapat dilihat pada Tabel 6.43.

Tabel 6.43 Hasil akurasi data validasi Skenario A

MODEL : A			
KOTA / KAB	MSE	MAD	MASE
Kabupaten Blitar	14.61	3.34	4.02
Tulungagung	13.76	3.38	2.18
Kab. Bangkalan	16.05	3.63	2.86



Gambar 6.47 Validasi Skenario A pada Kabupaten Tulungagung




Gambar 6.48 Validasi Skenario A pada Kabupaten Bangkalan

Dari hasil validasi pada Kabupaten Blitar dan Tulungagung dan Bangkalan memiliki nilai yang cenderung stabil. Ketiga model ini memiliki pola, tidak seperti model yang lain, namun tidak cukup bagus untuk mengikuti pola data yang ada.

6.5.2.3 Validasi Skenario Model Kombinasi B

Kandidat urutan ketiga adalah dengan Skenario Model B dengan menggunakan variabel Kepadatan Penduduk dan Jumlah Penderita. Hasil validasi pada Kabupaten Blitar dapat dilihat pada Gambar 6.49. Hasil validasi pada Kabupaten Tulungagung dapat dilihat pada Gambar 6.50. Hasil validasi pada Kabupaten Bangkalan dapat dilihat pada Gambar 6.51.




Gambar 6.49 Validasi Skenario B pada Kabupaten Blitar

Hasil validasi menunjukkan bahwa model ini tidak dapat mengikuti data yang ada, ditandai dengan pengembalian nilai peramalan yang sama. Sehingga model ini tidak akan digunakan. Untuk melihat MSE, MAD dan MASE dari model ini dapat dilihat pada Tabel 6.44


Tabel 6.44 Hasil akurasi data validasi Skenario B

MODEL : B			
KOTA / KAB	MSE	MAD	MASE
Kabupaten Blitar	8.49	2.21	1.06
Tulungagung	6.59	2.20	1.42
Kab. Bangkalan	8.94	2.27	1.79



Gambar 6.50 Validasi Skenario B pada Kabupaten Tulungagung

Hasil validasi pada Gambar 6.50 menunjukkan bahwa model ini tidak dapat mengikuti data yang ada, ditandai dengan pengembalian nilai peramalan yang sama.




Gambar 6.51 Validasi Skenario B pada Kabupaten Bangkalan

Hasil validasi pada Gambar 6.51 menunjukkan bahwa model ini tidak dapat mengikuti data yang ada, ditandai dengan pengembalian nilai peramalan yang sama.

6.5.2.4 Validasi Skenario Model Kombinasi D

Kandidat urutan keempat atau terakhir adalah dengan Skenario Model D dengan menggunakan variabel Cakupan Imunisasi, Kepadatan Penduduk dan Jumlah Penderita. Hasil validasi pada Kabupaten Blitar dapat dilihat pada Gambar 6.52. Hasil validasi pada Kabupaten Tulungagung dapat dilihat pada Gambar 6.53. Hasil validasi pada Kabupaten Bangkalan dapat dilihat pada Gambar 6.54.




Gambar 6.52 Validasi Skenario D pada Kabupaten Blitar

Hasil validasi menunjukkan bahwa model ini tidak dapat mengikuti data yang ada, ditandai dengan pengembalian nilai peramalan yang sama. Sehingga model ini tidak akan digunakan. Untuk melihat MSE, MAD dan MASE dari model ini dapat dilihat pada Tabel 6.45


Tabel 6.45 Hasil akurasi data validasi Skenario D

MODEL : D			
KOTA / KAB	MSE	MAD	MASE
Kabupaten Blitar	8.20	1.96	0.94
Tulungagung	5.43	1.85	1.20
Kab. Bangkalan	7.73	1.83	1.45



Gambar 6.53 Validasi Skenario D pada Kabupaten Tulungagung

Hasil validasi pada Gambar 6.53 menunjukkan bahwa model ini tidak dapat mengikuti data yang ada, ditandai dengan pengembalian nilai peramalan yang sama.



Gambar 6.54 Validasi Skenario D pada Kabupaten Bangkalan

Hasil validasi pada Gambar 6.45 menunjukkan bahwa model ini tidak dapat mengikuti data yang ada, ditandai dengan pengembalian nilai peramalan yang sama.

6.5.3 Pengelompokkan 3

Kombinasi-kombinasi model yang ditampilkan pada Tabel 6.37 merupakan Kandidat Model Terbaik yang digunakan untuk melakukan peramalan. Tiap kandidat dilakukan validasi satu per satu ke data yang lain yaitu 3 kota/kabupaten dan dilakukan analisis apakah model yang sedang divalidasi memiliki performa yang baik terhadap data validasi. Kota / kabupaten yang digunakan pada kelompok satu adalah Kabupaten Bojonegoro, Kabupaten Magetan, dan Kabupaten Trenggalek..

6.5.3.1 Validasi Skenario Model Kombinasi A


Kandidat urutan pertama adalah dengan Skenario Model A dengan menggunakan variabel Cakupan Imunisasi dan Jumlah Penderita. Hasil validasi pada Kabupaten Bojonegoro dapat dilihat pada Gambar 6.55. Hasil validasi pada Kota Magetan dapat dilihat pada Gambar 6.56. Hasil validasi pada Kabupaten Trenggalek dapat dilihat pada Gambar 6.57.

Pada validasi yang dilakukan, model yang dihasilkan melalui Skenario Model A dari kelompok tiga memiliki performa yang tidak baik ditandai dengan model yang tidak dapat mengikuti pola data aktual nya. Sehingga model ini tidak akan digunakan untuk peramalan.

Untuk mengetahui nilai MSE, MAD dan MASE dari validasi ini dapat dilihat pada Tabel 6.46.


Tabel 6.46 Hasil akurasi data validasi Skenario A

MODEL : A			
KOTA / KAB	MSE	MAD	MASE
Bojonegoro	1.3261973	0.596727	0.9629004
Magetan	0.5808782	0.4352351	0.9088733
Trenggalek	1.1698442	0.642291	0.7125416



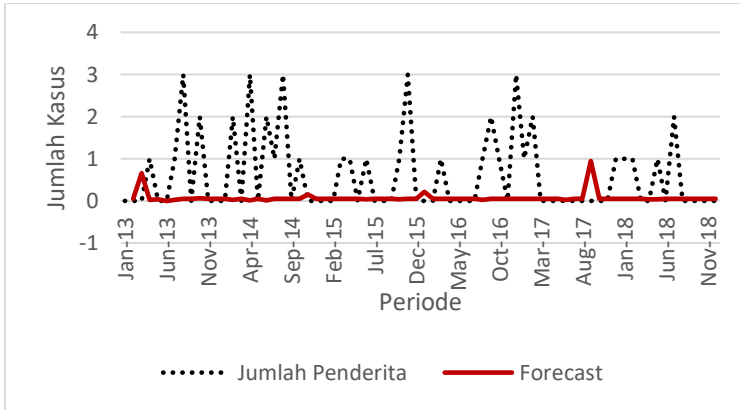
Gambar 6.55 Validasi Skenario A pada Kabupaten Bojonegoro

Hasil validasi pada Gambar 6.55 menunjukkan bahwa model ini tidak dapat mengikuti data yang ada, ditandai dengan pengembalian nilai peramalan yang sama.



Gambar 6.56 Validasi Skenario A pada Kabupaten Magetan

Hasil validasi pada Gambar 6.56 menunjukkan bahwa model ini tidak dapat mengikuti data yang ada, ditandai dengan pengembalian nilai peramalan yang sama.




Gambar 6.57 Validasi Skenario A pada Kabupaten Trenggalek

Hasil validasi pada Gambar 6.57 menunjukkan bahwa model ini tidak dapat mengikuti data yang ada, ditandai dengan pengembalian nilai peramalan yang sama.


6.5.3.2 Validasi Skenario Model Kombinasi D

Kandidat urutan kedua adalah dengan Skenario Model D dengan menggunakan variabel Cakupan Imunisasi, Kepadatan Penduduk dan Jumlah Penderita. Hasil validasi Kabupaten Bojonegoro dapat dilihat pada Gambar 6.58. Hasil validasi pada Kota Magetan dapat dilihat pada Gambar 6.59. Hasil validasi pada Kabupaten Trenggalek dapat dilihat pada Gambar 6.60.




Gambar 6.58 Validasi Skenario D pada Kabupaten Bojonegoro

Hasil validasi pada Gambar 6.58 menunjukkan bahwa model ini tidak dapat mengikuti data yang ada, ditandai dengan pengembalian nilai peramalan yang sama.



Gambar 6.59 Validasi Skenario D pada Kabupaten Magetan

Hasil validasi pada Gambar 6.59 menunjukkan bahwa model ini tidak dapat mengikuti data yang ada, ditandai dengan pengembalian nilai peramalan yang sama.



Gambar 6.60 Validasi Skenario D pada Kabupaten Trenggalek

Pada validasi yang dilakukan, model yang dihasilkan melalui Skenario Model D dari kelompok tiga memiliki performa yang tidak baik ditandai dengan model yang tidak dapat mengikuti pola data aktual nya. Prediksi yang dihasilkan antar kota/kabupaten validasi menunjukkan nilai yang sama. Sehingga model ini tidak dapat digunakan.

Untuk mengetahui nilai MSE, MAD dan MASE dari validasi ini dapat dilihat pada Tabel 6.47.


Tabel 6.47 Hasil akurasi data validasi Skenario D

MODEL : D			
KOTA / KAB	MSE	MAD	MASE
Bojonegoro	1.3899324	0.5976628	0.9644104
Magetan	0.6225415	0.4286487	0.8951193
Trenggalek	1.2220562	0.6258318	0.6942821

6.5.3.3 Validasi Skenario Model Kombinasi B


Kandidat urutan ketiga adalah dengan Skenario Model B dengan menggunakan variabel Kepadatan Penduduk dan Jumlah Penderita. Hasil validasi Kabupaten Bojonegoro dapat dilihat pada Gambar 6.61. Hasil validasi pada Kota Magetan

dapat dilihat pada Gambar 6.62. Hasil validasi pada Kabupaten Trenggalek dapat dilihat pada Gambar 6.63.




Gambar 6.61 Validasi Skenario B pada Kabupaten Bojonegoro

Hasil validasi pada Gambar 6.61 menunjukkan bahwa model ini tidak dapat mengikuti data yang ada, ditandai dengan pengembalian nilai peramalan yang sama.



Gambar 6.62 Validasi Skenario B pada Kabupaten Magetan

Hasil validasi pada Gambar 6.62 menunjukkan bahwa model ini tidak dapat mengikuti data yang ada, ditandai dengan pengembalian nilai peramalan yang sama.



Gambar 6.63 Validasi Skenario B pada Kabupaten Trenggalek

Hasil validasi pada Gambar 6.63 menunjukkan bahwa model ini tidak dapat mengikuti data yang ada, ditandai dengan pengembalian nilai peramalan yang sama.

Pada validasi yang dilakukan, model yang dihasilkan melalui Skenario Model B dari kelompok tiga memiliki performa yang tidak baik ditandai dengan model yang tidak dapat mengikuti pola data aktual nya. Prediksi yang dihasilkan antar kota/kabupaten validasi menunjukkan nilai yang sama. Sehingga model ini tidak dapat digunakan.


Untuk melihat nilai MSE, MAD dan MASE dari model ini dapat dilihat pada Tabel 6.48

Tabel 6.48 Hasil akurasi data validasi Skenario B

MODEL : C			
KOTA / KAB	MSE	MAD	MASE
Bojonegoro	1.1837033	0.711352	1.1478635
Magetan	0.4663375	0.5574215	1.1640271
Trenggalek	1.0922137	0.7957746	0.8828125


6.5.3.4 Validasi Skenario Model Kombinasi C

Kandidat urutan keempat (terakhir) adalah dengan Skenario Model C dengan menggunakan variabel dan Jumlah Penderita saja. Hasil validasi Kabupaten Bojonegoro dapat dilihat pada Gambar 6.64. Hasil validasi pada Kota Magetan dapat dilihat pada Gambar 6.65. Hasil validasi pada Kabupaten Trenggalek dapat dilihat pada Gambar 6.66.




Gambar 6.64 Validasi Skenario C pada Kabupaten Bojonegoro

Hasil validasi pada Gambar 6.64 menunjukkan bahwa model ini dapat mengikuti data cukup baik, ditandai dengan pengembalian nilai peramalan mirip dengan data aktual.



Gambar 6.65 Validasi Skenario C pada Kabupaten Magetan

Hasil validasi pada Gambar 6.65 menunjukkan bahwa model ini dapat mengikuti data cukup baik, ditandai dengan pengembalian nilai peramalan mirip dengan data aktual.



Gambar 6.66 Validasi Skenario C pada Kabupaten Trenggalek

Pada validasi yang dilakukan, model yang dihasilkan melalui Skenario Model C dari kelompok satu memiliki performa yang baik ditandai dengan model yang dapat mengikuti pola data aktual nya. Prediksi yang dihasilkan antar kota/kabupaten validasi menunjukkan nilai berdekatan dengan data aktual. Sehingga model inilah yang digunakan untuk peramalan.

6.5.4 Kesimpulan Model

Dari berbagai kandidat model yang didapatkan di setiap pengelompokan data, kandidat-kandidat model tersebut divalidasikan kedalam data yang berbeda dalam satu kelompok. Model dikatakan memiliki performa yang baik diketahui melalui uji validasi model ini. Model yang memiliki performa yang baik merupakan model yang jika model itu dicoba kedalam data lain maka model tersebut dapat menangkap pola data yang ada dan mengembalikan nilai yang hampir sama atau berbeda sedikit dengan data aktualnya. Model dikatakan memiliki performa yang kurang baik ketika model tersebut tidak dapat bekerja secara sempurna, artinya model tersebut ketika dicoba ke berbagai data akan menghasilkan nilai yang sama rata atau cenderung tidak berpola atau mengembalikan nilai yang sangat jauh berbeda.

Selain itu dapat juga dilihat dari MSE yang dihasilkan pada proses validasi model. Untuk melihat rata-rata MSE yang dihasilkan pada setiap model di setiap pengelompokan dapat dilihat pada Tabel 6.49.

Tabel 6.49 Rata-rata MSE Model

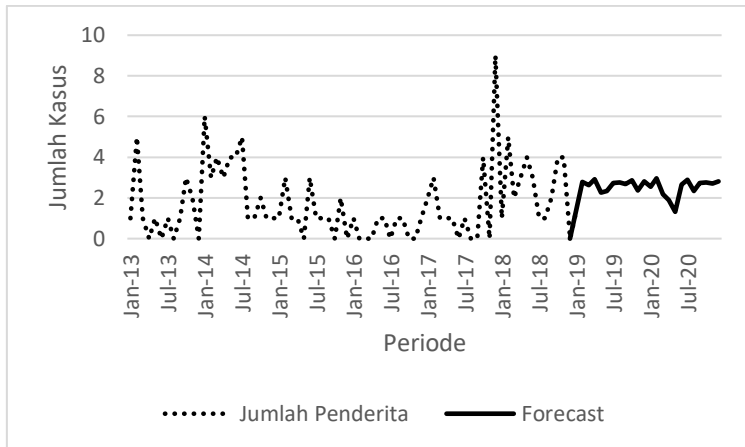
Kelompok	Skenario	Rata-rata MSE
1	A	3.605
	B	3.352
	C	3.284
	D	4.075
2	C	6.322
	A	14.807
	B	8.009
	D	7.120
3	A	1.026
	D	1.078
	B	0.850
	C	0.914

Memiliki nilai MASE, MAD atau MSE terkecil tidak selalu membuat suatu model tersebut menjadi model terbaik, karena model yang baik selain dilihat dari akurasi, dilihat juga dari segi adaptifnya. Model yang adaptif adalah model yang dapat beradaptasi dengan pola data sehingga dapat mengikuti pola data yang ada. Pada Kabupaten Sumenep, model yang memiliki rata-rata MSE terkecil adalah model B, hal tersebut dikarenakan hasil peramalan yang dihasilkan memiliki nilai yang sama, sehingga berada di tengah-tengah (tidak bagus dan tidak jelek dari nilai aktual), dan ketika dilakukan validasi masih tidak dapat beradaptasi dengan pola data yang ada. Secara visual, model terbaik dari semua pengelompokan adalah dengan menggunakan Skenario Model C. Dan dari hasil rata-rata MSE yang dihasilkan pada Tabel 6.49 menunjukkan nilai rata-rata

MSE terkecil adalah model Skenario C juga. Sehingga model yang digunakan untuk peramalan selanjutnya adalah dengan menggunakan Skenario Model C di tiap pengelompokkan.


6.6 Hasil Peramalan

Setelah diperoleh model terbaik, maka model tersebut akan diimplementasikan untuk melakukan peramalan periode kedepannya. Peramalan dilakukan selama dua tahun kedepan dengan periode bulanan. Hasil peramalan ini dapat dilihat pada Lampiran D. Berikut merupakan plot data hasil peramalan dua tahun kedepan yang ditampilkan grafik pada Gambar 6.67 untuk Kabupaten Malang, Gambar 6.68 untuk Kota Surabaya, dan Gambar 6.69 untuk Kabupaten Sumenep.




Gambar 6.67 Hasil Peramalan Jumlah Kasus Difteri di Kabupaten Malang

Dari hasil peramalan jumlah kasus difteri di tahun 2019 hingga 2020 di Kabupaten Malang mengalami kenaikan dan penurunan di akhir tahun 2020, namun cenderung stabil.



Gambar 6.68 Hasil Peramalan Jumlah Kasus Difteri di Kota Surabaya
 Dari hasil peramalan jumlah kasus difteri di tahun 2019 hingga 2020 di Kota Surabaya mengalami kenaikan dan penurunan secara rata.



Gambar 6.69 Hasil Peramalan Jumlah Kasus Difteri di Kabupaten Sumenep

Dari hasil peramalan jumlah kasus difteri di tahun 2019 hingga 2020 di Kabupaten Sumenep mengalami kenaikan dan penurunan, namun cenderung stabil.

Dari hasil peramalan 3 kota / kabupaten tersebut memiliki perbedaan hasil peramalan. Pada Kabupaten Sumenep mengembalikan nilai peramalan yang bervariasi antara 1 dan 0 sehingga terlihat grafik yang bergerak. Hal tersebut dikarenakan *range* data pada data Sumenep memiliki nilai yang rendah yaitu 0 hingga 5, sehingga nilai yang dikembalikan tidak jauh berbeda dari hasil pembelajaran. Untuk Kota Surabaya terdapat sedikit sekali kenaikan, hal tersebut dikarenakan pada data *training* terdapat nilai fluktuasi yaitu 11 sehingga dapat menangkap pola fluktuasi walaupun pada data *testing* memiliki nilai yang lebih tinggi. Untuk Kabupaten Malang mengembalikan nilai yang bervariasi, hal ini dikarenakan mirip dengan Sumenep dimana pola data Kabupaten Malang ini sedikit stasioner, sehingga nilai yang diramalkan cenderung mengikuti pola data yang ada, dan fluktuasi di 2018 tidak terlalu jauh berbeda dengan data *training* yang telah melalui proses pembelajaran.

Halaman sengaja dikosongkan

BAB VII

KESIMPULAN DAN SARAN

Pada bab ini menjelaskan kesimpulan dari penelitian tugas akhir ini yang telah dilakukan dan saran yang dapat diberikan guna pengembangan lebih lanjut dari penelitian agar lebih baik.

7.1 Kesimpulan

Berdasarkan hasil dari uji coba pada penelitian tugas akhir ini, maka kesimpulan yang dapat diambil adalah:

1. Model terbaik yang digunakan untuk peramalan jumlah kasus difteri baik di Kabupaten Malang, Kota Surabaya, dan Kabupaten Sumenep adalah dengan menggunakan *univariate variable* dimana variabel yang digunakan sebagai masukan (*independent*) adalah Jumlah Penderita itu sendiri.
2. Hasil peramalan pada Kabupaten Malang, Kota Surabaya dan Kabupaten Sumenep mengalami penurunan dan kenaikan namun cenderung stabil.
3. Untuk model terbaik pada Kabupaten Malang memiliki MASE 0.84 saat melakukan *testing* model. Untuk model terbaik pada Kota Surabaya memiliki MASE 0.917 saat melakukan *testing* model. Untuk model terbaik pada Kabupaten Sumenep memiliki MASE 0.820 saat melakukan *testing* model. Ketika nilai MASE berada dibawah 1, maka model tersebut memiliki performa yang baik.
4. Hampir semua variabel memiliki korelasi dengan kategori sangat lemah, kecuali pada Jumlah Penderita di Kota Surabaya yang memiliki korelasi dengan kategori sedang. Namun, variabel yang memiliki korelasi lebih tinggi dibandingkan variabel lainnya (meskipun masih dalam kategori sangat lemah) adalah Jumlah Penderita itu sendiri baik di Kabupaten Malang maupun Kabupaten Sumenep.
5. Penggunaan variabel bebas untuk meramalkan jumlah penderita difteri memiliki performa yang kurang baik

terhadap data karena ketika dilakukan *testing* maupun validasi data tidak dapat mengikuti pola data yang ada. Hal tersebut juga dikarenakan korelasi yang dimiliki antara variabel bebas dengan variabel terikat sangat lemah yang artinya tidak linearitas sebagian besar, dimana metode RBFNN dengan 1 *hidden layer* akan memproses data secara linear untuk *output* nya.

6. Ketika model terbaik diimplementasikan kedalam data yang berbeda, model tersebut memiliki performa yang baik ditandai dengan dapat mengikuti pola data yang ada, serta memiliki rata-rata MSE terkecil jika dibandingkan dengan menggunakan model yang lain.

7.2 Saran

Berdasarkan hasil dan kesimpulan dari penelitian tugas akhir ini, saran yang dapat diberikan bagi penelitian selanjutnya adalah :

1. Untuk memperoleh hasil yang lebih akurat, disarankan untuk menggunakan data yang memiliki periode yang lebih panjang lagi.
2. *Tools* yang digunakan dalam penelitian ini adalah MATLAB, disarankan untuk mencoba menggunakan tools lain seperti R Studio, Phyton, dan lain lain sehingga memungkinkan memberikan hasil yang lebih akurat.
3. Percobaan yang dilakukan pada tugas akhir ini terbatas pada penggunaan RBFNN dengan 1 *hidden layer*. Pada penelitian berikutnya disarankan untuk menggunakan lebih dari 1 *hidden layer* untuk membandingkan performa algoritma baik dari segi kecepatan iterasi maupun hasil akurasi.
4. Untuk mendapatkan hasil akurasi yang lebih baik, disarankan pada penelitian berikutnya menggunakan optimasi parameter *spread*.

DAFTAR PUSTAKA

- [1] T. S. P. Tiwari and D. Control, “Diphtheria,” *Int. Encycl. Public Heal.*, vol. 2, pp. 313–317, 2017.
- [2] D. Rahmi, “HUBUNGAN TINGKAT PENGETAHUAN DAN SIKAP IBU TERHADAP PENCEGAHAN PENYAKIT DIFTERI DI KELURAHAN KORONG GADANG PADANG,” *Menara Ilmu*, vol. XII, no. 79, pp. 71–78, 2018.
- [3] A. Rintani *et al.*, “RISK FACTORS ASSOCIATED TO DIPHTHERIA OUTBREAK IN DEVELOPING COUNTRIES,” *J. Ilmu Kesehat. Masy.*, vol. 9, no. 2, pp. 83–95, 2018.
- [4] A. Amindoni, “Wabah difteri di 20 provinsi: Lima hal yang perlu anda ketahui,” *BBC Indonesia*, 2017. [Online]. Available: <https://www.bbc.com/indonesia/majalah-42215042>.
- [5] E. Hartoyo, “Difteri pada Anak,” *Sari Pediatr.*, vol. 19, no. 5, 2018.
- [6] I. F. Arifin and C. I. Prasasti, “FAKTOR YANG BERHUBUNGAN DENGAN KASUS DIFTERI ANAK DI PUSKESMAS BANGKALAN TAHUN 2016,” *J. Berk. Epidemiol.*, vol. 5, no. 1, pp. 26–36, 2017.
- [7] A. A. Romdhoni, “Peramalan Nilai Tukar Mata Uang Dollar AS terhadap Rupiah Menggunakan Neural Network Ensemble Bagging,” vol. 2, no. 2, pp. 42–47, 2013.
- [8] X. Zhang, Y. Liu, M. Yang, T. Zhang, A. A. Young, and X. Li, “Comparative Study of Four Time Series Methods in Forecasting Typhoid Fever Incidence in China,” *PLoS One*, vol. 8, no. 5, 2013.

- [9] S. M. Yasfi, "PEMODELAN RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN) PADA DATA WISATAWAN MANCANEGARA DI D. I. YOGYAKARTA," *Lambung Pustaka Univ. Negeri Yogyakarta*, pp. 1–8, 2015.
- [10] O. Kisi and H. K. Cigizoglu, "Comparison of different ANN techniques," *Civ. Eng. Environ. Syst.*, vol. 24, no. 3, pp. 211–231, 2007.
- [11] A. H. El Shafi, A. El-Shafi, A. Almukhtar, M. R. Taha, H. G. El Mazoghi, and A. Shehata, "Radial basis function neural networks for reliably forecasting rainfall," *J. Water Clim. Chang.*, no. June, 2012.
- [12] R. F. Bartlett, "Linear Modelling of Pearson's Product Moment Correlation Coefficient: An Application of Fisher's χ^2 -Transformation," *J. R. Stat. Soc. Ser. D (The Stat.)*, vol. 42, no. 1, pp. 45–53, 1993.
- [13] K. Okamoto, S. Hatakeyama, C. Sugita, K. Ogura, and R. Ueda, "Nasal diphtheria (chronic carriage) caused by nontoxigenic *Corynebacterium diphtheriae*," *J. Infect. Chemother.*, vol. 24, no. 9, pp. 759–762, 2018.
- [14] W. H. Organization, "4.5.2 Difteri," *Hospital Care for Children*, 2016. [Online]. Available: <http://www.ichrc.org/452-difteri>.
- [15] K. PURNOMO, "Wabah Difteri di Indonesia, Antara Vaksinasi dan Antibiotik," *Kompas.com*, 2017. [Online]. Available: <https://sains.kompas.com/read/2017/12/13/124001723/wabah-difteri-di-indonesia-antara-vaksinasi-dan-antibiotik>.
- [16] F. Bruce M Lo, MD, MBA, CPE, RDMS, FACEP, FAAEM, "Diphtheria," *Emergency Medicine*, 2019. [Online]. Available: <https://emedicine.medscape.com/article/782051->

overview#a5.

- [17] N. Izza and Soenarnatalina, “Analisis Data Spasial Penyakit Difteri di Provinsi Jawa Timur Tahun 2010 DAN 2011,” *Bul. Penelit. Sist. Kesehat.*, vol. 18, no. 2, pp. 211–219, 2015.
- [18] W. H. Organization, “Diphtheria vaccine: WHO position paper , August 2017 – Recommendations,” *Vaccine*, vol. 36, no. 2, pp. 199–201, 2018.
- [19] C. A. Setyanti, “Wabah Difteri, Orang Dewasa juga Perlu ‘Booster’ Vaksin,” *CNN Indonesia*, 2017. [Online]. Available: <https://www.cnnindonesia.com/gaya-hidup/20171208124254-255-261026/wabah-difteri-orang-dewasa-juga-perlu-booster-vaksin>.
- [20] R. J. Hyndman and George Athanasopoulos, *Forecasting: Principles and Practice*, 2nd ed. OTEXTS, 2018.
- [21] F. X. Diebold, *Forecasting in Economics, Business, Finance and Beyond*. 2017.
- [22] M. K. Evans, *Practical Business Forecasting*. Cornwall: Blackwell Publishers, 2003.
- [23] S. Makridakis, S. C. Wheelwright, and V. E. McGee, *Forecasting: Methods and Applications*, 2nd ed. New York: Wiley, 1983.
- [24] C. Fajarianti, J. Suprijadi, and Y. Krista, “Forecasting of PT . PLN (Persero) Revenue Using Radial Basis Function Neural Network,” vol. 020037, 2017.
- [25] F. Pakaja and A. Naba, “Peramalan Penjualan Mobil Menggunakan Jaringan Syaraf Tiruan dan Certainty Factor,” *J. EECCIS*, vol. 6, no. 1, pp. 23–28, 2015.
- [26] R. A. Fauzannissa, H. Yasin, and D. Ispriyanti, “Peramalan harga minyak mentah dunia menggunakan

- metode radial basis function neural network,” *J. Gaussian*, vol. 5, pp. 193–202, 2016.
- [27] L. V. Fausett, *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*, 1st ed. New Jersey: Prentice-Hall, 1994.
- [28] M. Agustin, “PENGUNAAN JARINGAN SYARAF TIRUAN BACKPROPAGATION UNTUK SELEKSI PENERIMAAN MAHASISWA BARU PADA JURUSAN TEKNIK KOMPUTER DI POLITEKNIK NEGERI SRIWIJAYA,” Universitas Diponegoro, 2012.
- [29] E. Lopian, A. B. Osmond, and R. E. Saputra, “RECURRENT NEURAL NETWORK UNTUK PENGENALAN UCAPAN PADA DIALEK MANADO,” *e-Proceeding Eng.*, vol. 5, no. 3, pp. 6436–6443, 2018.
- [30] “Recurrent neural network,” *Wikipedia*. Wikipedia, 2019.
- [31] D. S. Yeung, I. Cloete, D. Shi, and W. Y. Ng, *Sensitivity Analysis for Neural Networks*. Berlin: Springer, 2010.
- [32] W. Shen, X. Guo, C. Wu, and D. Wu, “Forecasting stock indices using radial basis function neural networks optimized by artificial fish swarm algorithm,” *Knowledge-Based Syst.*, vol. 24, no. 3, pp. 378–385, 2011.
- [33] T. Xie, H. Yu, and B. Wilamowski, “Comparison between Traditional Neural Networks and Radial Basis Function Networks,” *IEEE Int. Symp. Ind. Electron.*, pp. 1194–1199, 2011.
- [34] A. D. Cahyani, B. K. Khotimah, R. T. Rizkillah, P. Studi, T. Informatika, and U. Trunojoyo, “PERBANDINGAN METODE SOM (SELF ORGANIZING MAP) DENGAN PEMBOBOTAN BERBASIS RBF (RADIAL BASIS FUNCTION),” *J. Teknol.*

- Technoscientia*, vol. 7, no. 1, 2014.
- [35] J. E. Hanke and D. W. Wichern, *BUSINESS FORECASTING*, 9th ed. Upper Saddle River, New Jersey 07458: Pearson Prentice Hall, 2009.
- [36] R. J. Hyndman, "ANOTHER LOOK AT FORECAST-ACCURACY METRICS FOR INTERMITTENT DEMAND," *FORESIGHT*, no. 4, pp. 43–46, 2006.
- [37] A. Syntetos, "Forecasting of Intermittent Demand," Buckinghamshire Chilterns University College, Brunel University, 2001.
- [38] A. Sachan, "INTELLIGENT PREDICTION OF RAINFALL USING GPS AND METEOROLOGICAL DATA," INDIAN INSTITUTE OF TECHNOLOGY ROORKEE, 2012.
- [39] A. A. Kollawila, W. Bunganaen, S. Utomo, and K. Kunci, "SISTEM DRAINASE ZONA V RENCANA INDUK DRAINASE KOTA KUPANG," *J. Tek. Sipil*, vol. VI, no. 2, pp. 205–218, 2017.
- [40] Minitab LLC, "Interpret the key results for Correlation," 2019. [Online]. Available: <https://support.minitab.com/en-us/minitab-express/1/help-and-how-to/modeling-statistics/regression/how-to/correlation/interpret-the-results/>.

Halaman sengaja dikosongkan

BIODATA PENULIS



Penulis bernama Dina Nandika yang akrab disapa dengan Dina atau Dinan. Penulis lahir di Surabaya, pada tanggal 02 November 1997. Penulis menempuh pendidikan mulai dari sekolah dasar hingga perguruan tinggi sebagai berikut: SDN. Sidotopo Wetan II/256 (2003-2009), SMP Negeri 37 Surabaya (2009-2012), SMA Negeri 1 Surabaya (2012-2015), dan pada tahun 2015 penulis melanjutkan pendidikan sebagai mahasiswa pada Departemen Sistem Informasi di Institut Teknologi Sepuluh Nopember.

Pada saat kuliah, penulis aktif pada kegiatan organisasi kemahasiswaan. Di lingkungan kampus, penulis pernah menjabat sebagai staff Student Resource Development dalam BEM Fakultas Teknologi Informasi, dan sekertaris Technology Development Bureau dalam Himpunan Mahasiswa Sistem Informasi. Selain organisasi kemahasiswaan, penulis juga aktif menjadi panitia acara seperti staff dan staff ahli Sie Kreatif dalam Information Systems Expo 2 periode dan FTif Festival, Sie Acara pada GERIGI ITS, sie penyisihan pada GEMASTIK 2019, dan masih banyak lainnya. Penulis juga sempat mengikuti PKM bidang KC dengan status terdantai oleh Institut.

Dalam rangka mendapatkan gelar Sarjana Komputer, maka penulis masuk ke dalam Laboratorium Rekayasa Data dan Intelegensia Bisnis dengan topik tugas akhir peramalan jumlah penderita difteri menggunakan metode *radial basis function neural network* (RBFNN). Penulis dapat dihubungi melalui email: dinannandika@gmail.com untuk kepentingan penelitian.

Halaman sengaja dikosongkan

LAMPIRAN A

Pada lampiran A berisi data *training* dan *testing* yang digunakan pada penelitian tugas akhir ini yaitu Cakupan DPT 1 hingga DPT 4, Kepadatan Penduduk, dan Jumlah Penderita Difteri untuk area Surabaya, Kabupaten Malang, dan Sumenep.

Keterangan :

- A = Cakupan DPT 1 (%)
- B = Cakupan DPT 2 (%)
- C = Cakupan DPT 3 (%)
- D = Cakupan DPT 4 (%)
- E = Kepadatan Penduduk (jiwa/km²)
- F = Jumlah Penderita (jiwa)

A.1 Variabel Kabupaten Malang

Periode	A	B	C	D	E	F
Jan-13	8.95	8.68	9.01	0	685	1
Feb-13	8.77	8.71	8.67	0	687	5
Mar-13	8.88	8.86	8.78	0	689	1
Apr-13	8.96	8.92	8.89	0	692	0
May-13	8.87	8.93	8.93	0	694	1
Jun-13	9.14	9.01	9.07	0	696	0
Jul-13	9.17	9.09	8.8	0	699	1
Aug-13	17.1	16.29	16.35	0	701	0
Sep-13	9.29	9.11	8.93	0	703	1
Oct-13	8.57	8.49	8.56	0	706	3
Nov-13	6.92	6.97	7.16	0	708	2
Dec-13	8.42	8.41	8.44	0	711	0
Jan-14	8.62	8.62	8.64	0	711	6

Periode	A	B	C	D	E	F
Feb-14	8.62	8.89	8.42	0	711	3
Mar-14	8.87	8.84	8.9	0	712	4
Apr-14	9.15	9.36	9.09	0	712	3
May-14	8.92	8.92	8.85	0	713	4
Jun-14	7.91	8.64	8.7	7.66	713	4
Jul-14	8.18	8.02	8.42	2.62	714	5
Aug-14	9.56	7.95	7.9	0.87	714	1
Sep-14	8.33	8.23	8.07	0	714	1
Oct-14	9.83	9.51	9.4	0.24	715	2
Nov-14	8.42	9.17	8.76	0.29	715	1
Dec-14	9.1	9.2	8.84	2.48	716	1
Jan-15	8.99	8.91	8.88	4.65	716	1
Feb-15	8.63	9.05	8.69	10.54	717	3
Mar-15	8.71	8.86	9.02	9.96	717	1
Apr-15	8.89	8.89	8.99	9.81	717	1
May-15	8.86	9.02	9.13	8.73	718	0
Jun-15	9.07	8.89	8.85	7.81	718	3
Jul-15	8.81	8.57	8.5	5.29	719	1
Aug-15	9.44	9.3	8.8	5.49	719	1
Sep-15	8.78	9.08	8.77	5.6	719	1
Oct-15	9.51	11.52	11.04	4.59	720	0
Nov-15	8.64	8.62	8.92	5.28	720	2
Dec-15	8.12	8.36	8.18	5.42	721	0
Jan-16	8.57	8.26	8.64	7.62	721	1
Feb-16	8.48	8.31	8.21	6.88	721	0
Mar-16	7.57	7.6	7.39	5.87	722	0
Apr-16	9.19	8.48	8.64	7.57	722	0
May-16	8.63	9	8.5	7.85	723	1
Jun-16	8.92	8.55	8.97	6.97	723	1
Jul-16	9.42	8.9	8.65	6.59	723	0

Periode	A	B	C	D	E	F
Aug-16	10.48	9.24	9.55	8.35	724	1
Sep-16	9.47	10.27	9.37	8.24	724	1
Oct-16	8.58	9.18	9.72	8.53	724	0
Nov-16	8.52	9.03	9.4	8.25	725	0
Dec-16	8.35	8.55	9.07	7.36	725	1
Jan-17	8.26	8.05	8.25	7.5	726	2
Feb-17	8.47	8.43	8.14	7.72	726	3
Mar-17	8.39	8.67	8.7	4.76	726	1
Apr-17	8.36	8.62	8.65	7.74	727	1
May-17	8.54	8.25	8.65	8.94	727	1
Jun-17	8.74	8.25	7.89	7.1	728	0
Jul-17	8.87	8.85	8.44	6.94	728	1
Aug-17	8.37	8.4	8.55	6.09	728	0
Sep-17	3.13	3.23	3.51	0.97	729	0
Oct-17	10.32	9.4	9.49	6.55	729	4
Nov-17	9.53	9.77	9.03	8.69	729	0
Dec-17	8.57	9.2	9.07	8.37	730	9
Jan-18	8.39	8.33	9.06	7.03	730	1
Feb-18	8.16	8.3	8.4	8.65	730	5
Mar-18	8.37	8.37	8.42	12.05	731	2
Apr-18	7.84	8.34	8.16	2.49	731	3
May-18	8.42	8.21	8.74	1.44	732	4
Jun-18	8.12	7.46	7.46	2.08	732	3
Jul-18	9.08	8.91	8.42	14.75	732	1
Aug-18	9.38	9.03	8.58	6.72	733	1
Sep-18	8.81	9.4	8.79	12.39	733	2
Oct-18	8.72	8.92	9.27	2.84	733	4
Nov-18	8.43	8.75	9.09	9.74	734	4
Dec-18	8.74	8.42	8.55	25.5	734	0

A.2 Variabel Kota Surabaya

Periode	A	B	C	D	E	F
Jan-13	7.94	7.29	6.98	0	8008	16
Feb-13	7.16	6.89	6.87	0	8012	9
Mar-13	7.21	7.31	7.43	0	8016	5
Apr-13	7.55	7.22	7.37	0	8019	5
May-13	6.61	6.21	6.29	0	8023	6
Jun-13	8.42	8.1	8.02	0	8027	2
Jul-13	7.65	7.2	6.85	0	8031	6
Aug-13	8.67	8.06	7.74	0	8035	2
Sep-13	8.49	8.41	7.91	0	8039	8
Oct-13	7.99	7.91	7.3	0	8042	11
Nov-13	8.32	8.59	9.85	0	8046	6
Dec-13	14.44	12.17	13.55	0	8050	6
Jan-14	7.92	7.27	7	0	8053	7
Feb-14	7.81	7.85	7.58	0	8056	5
Mar-14	7.09	7.28	7.46	0	8059	3
Apr-14	7.5	7.3	7.3	0	8062	8
May-14	7.79	7.39	7.39	0	8064	5
Jun-14	8.02	7.44	7.28	0	8067	0
Jul-14	7.22	6.73	6.63	2.94	8070	3
Aug-14	8.96	8.68	8.25	0	8073	2
Sep-14	7.9	7.9	7.37	0	8076	4
Oct-14	7.89	7.29	7.13	0	8079	4
Nov-14	8.45	8.5	8.51	0	8082	5
Dec-14	9.3	9.02	9.05	100	8084	1
Jan-15	6.51	6.29	6.38	6.23	8069	1
Feb-15	6.48	6.43	6.17	4.99	8055	5
Mar-15	7.33	7.29	7.51	3.77	8040	4

Periode	A	B	C	D	E	F
Apr-15	7.52	7.49	7.68	4.15	8025	1
May-15	7.53	7.51	7.55	3.72	8010	0
Jun-15	6.7	6.25	6.48	2.34	7995	6
Jul-15	7.43	6.86	6.83	2.19	7980	5
Aug-15	8.14	7.75	6.88	2.73	7965	0
Sep-15	8.38	8.01	7.44	2.99	7951	3
Oct-15	7.43	6.86	6.83	2.04	7936	0
Nov-15	7.84	8.02	7.89	2.52	7921	1
Dec-15	10.2	10.63	11.11	2.52	7907	1
Jan-16	7.59	7.11	7.2	3.56	7928	2
Feb-16	7.63	7.71	7.05	2.35	7949	1
Mar-16	6.93	6.91	6.87	1.75	7971	1
Apr-16	8.14	7.84	7.84	2.35	7992	6
May-16	7.32	7.16	6.73	1.85	8013	5
Jun-16	8.75	8.11	8.18	2.3	8035	2
Jul-16	8.07	7.72	7.39	1.76	8057	2
Aug-16	9.12	8.49	8	2.67	8078	4
Sep-16	9.03	9.05	8.38	2.31	8100	5
Oct-16	7.84	8.23	8.35	2.39	8122	1
Nov-16	7.45	7.86	8.28	2.44	8143	1
Dec-16	7.75	8.11	8.48	2.4	8166	0
Jan-17	7.69	7.19	7.37	3.35	8169	2
Feb-17	7.91	7.95	7.91	4.3	8172	2
Mar-17	8.38	8.5	8.39	4.77	8174	1
Apr-17	7.57	7.1	7.47	4.37	8177	2
May-17	7.35	7.43	7.25	4.02	8180	3
Jun-17	7.63	7.1	7.22	3.62	8183	0
Jul-17	8.22	7.67	7.74	3.69	8186	2
Aug-17	8.39	7.83	7.42	2.37	8189	3

Periode	A	B	C	D	E	F
Sep-17	8.06	8.15	7.95	2.7	8192	2
Oct-17	8.95	8.56	8.78	5.48	8195	4
Nov-17	7.83	7.75	8.07	6.32	8198	3
Dec-17	8.06	7.9	7.71	6.16	8201	9
Jan-18	8.34	7.82	7.91	5.47	8203	17
Feb-18	7.69	7.37	7.2	22.88	8206	7
Mar-18	8.14	8.25	7.96	13.11	8209	12
Apr-18	8.87	8.99	8.8	7.48	8211	8
May-18	8.49	8.25	8.25	6.27	8214	5
Jun-18	8.03	7.83	7.87	6.28	8216	2
Jul-18	8.71	8.51	8.47	12.77	8219	2
Aug-18	8.76	8.64	8.53	9.49	8221	8
Sep-18	8.38	8.33	8.04	5.96	8224	2
Oct-18	8.25	7.97	8.1	4.99	8227	3
Nov-18	8.34	8.11	8.24	8.76	8229	1
Dec-18	7.91	8.02	7.82	8.16	8232	0

A.3 Variabel Kabupaten Sumenep

Periode	A	B	C	D	E	F
Jan-13	9.89	10.35	9.86	0	529	3
Feb-13	10.27	10.39	10.66	0	529	1
Mar-13	9.84	10.37	10.62	0	529	1
Apr-13	10.72	10.31	11.08	0	529	1
May-13	10.19	10.32	10.29	0	530	1
Jun-13	10.69	11.04	11.75	0	530	0
Jul-13	11.07	10.81	10.84	0	530	1
Aug-13	10.19	10.32	10.29	0	530	0
Sep-13	10.72	10.31	11.08	0	530	1
Oct-13	8.55	8.95	8.43	0	531	0

Periode	A	B	C	D	E	F
Nov-13	6.73	7.26	6.87	0	531	0
Dec-13	8.16	7.74	7.93	0	531	1
Jan-14	8.2	8.1	7.7	0	531	0
Feb-14	8.42	8.19	7.82	0	531	0
Mar-14	7.38	8.29	8.34	0	532	0
Apr-14	7.47	7.26	8.15	0	532	0
May-14	8	7.53	7.55	0	532	0
Jun-14	7.81	7.45	6.93	0	532	0
Jul-14	7.81	7.83	7.48	127.02	533	0
Aug-14	8.83	8.48	8.51	0	533	0
Sep-14	8.32	8.26	8.23	0	533	0
Oct-14	9.06	8.01	8.05	0	533	0
Nov-14	8.44	9.49	8.4	0	534	0
Dec-14	7.92	7.83	8.85	25.7	534	1
Jan-15	8.66	8.34	8.06	2.69	534	3
Feb-15	8.5	9.58	8.55	2.98	534	0
Mar-15	7.95	8.24	7.96	3.66	535	0
Apr-15	7.71	7.52	8.02	5.04	535	0
May-15	8.3	7.98	8.04	2.91	535	0
Jun-15	7.15	7.33	7.05	6.42	535	0
Jul-15	7.48	7.1	7.08	1.71	535	0
Aug-15	7.59	7.48	7.24	1.69	536	0
Sep-15	8.2	7.73	7.66	1.09	536	1
Oct-15	7.6	7.94	7.54	1.04	536	1
Nov-15	6.7	6.43	7.05	2.71	536	0
Dec-15	7.18	7.87	7.59	2.71	536	2
Jan-16	8.93	8.3	8.57	2.34	537	4
Feb-16	8.27	8.31	7.73	2.27	537	0
Mar-16	8.37	8.15	8.81	0.97	537	1

Periode	A	B	C	D	E	F
Apr-16	8.73	8.04	7.83	1.57	537	0
May-16	8.23	8.96	8.22	1.25	537	0
Jun-16	8.24	7.76	8.23	1.19	538	1
Jul-16	8.54	8.44	7.78	1.61	538	0
Aug-16	8.47	8.36	8.5	6.24	538	0
Sep-16	9.1	8.81	8.63	8.06	538	0
Oct-16	9.2	9.25	8.87	5.27	538	0
Nov-16	7.98	8.74	8.97	4.94	539	0
Dec-16	10.59	10.33	10.81	3.68	539	0
Jan-17	7.8	8.74	8.03	5.67	539	2
Feb-17	7.93	7.64	7.81	4.6	539	0
Mar-17	8.19	8.52	7.86	3.79	539	0
Apr-17	8.59	8.29	8	4.51	540	0
May-17	7.33	7.23	7.35	5.68	540	1
Jun-17	8.01	8.25	8.49	3.38	540	0
Jul-17	8.65	7.86	8.34	3.12	540	0
Aug-17	8.5	8.58	8.11	3.91	540	1
Sep-17	8.88	8.48	8.57	4.66	540	0
Oct-17	8.38	8.17	8.19	4.76	541	0
Nov-17	8.01	8.33	8.07	6.21	541	1
Dec-17	8.01	8.33	8.07	5.56	541	5
Jan-18	8.68	8.2	8.28	4.89	541	1
Feb-18	7.84	7.98	7.95	15.57	541	4
Mar-18	8.24	8.25	8.14	36.25	541	1
Apr-18	8.07	8.21	8.03	0	542	1
May-18	8.22	7.86	8.4	0	542	0
Jun-18	7.9	7.57	7.57	0	542	0
Jul-18	8.43	8.47	7.94	26.54	542	0
Aug-18	9.79	8.47	8.32	16.96	542	0
Sep-18	8.22	9.21	8.55	3.61	543	0

Periode	A	B	C	D	E	F
Oct-18	8.18	8.49	8.99	5.36	543	2
Nov-18	8.43	8.33	8.45	29.36	543	0
Dec-18	8.8	8.3	8.41	4.44	543	0

Halaman sengaja dikosongkan

LAMPIRAN B

Pada LAMPIRAN B berisi data mengenai plotting grafik setiap pengelompokkan jumlah kasus di setiap kota atau kabupaten dimulai dari pengelompokkan 1 hingga pengelompokkan 3. Untuk dapat melihat pengelompokkan dapat diakses pada https://drive.google.com/file/d/14xhS7WR3cOIDdqssJ6TqUyz4QNTThCZC_/view?usp=sharing .

Halaman sengaja dikosongkan

LAMPIRAN C

Pada bagian ini merupakan lampiran Jumlah Penduduk bulanan dan Kepadatan Penduduk bulanan di Surabaya, Kabupaten Malang, dan Kabupaten Sumenep.

C.1 Kepadatan Penduduk Kabupaten Malang

Periode	Jumlah Penduduk	Luas Wilayah	Kepadatan Penduduk per Bulan
Jan-13	2417949	3530.65	684.85
Feb-13	2426046	3530.65	687.14
Mar-13	2434171	3530.65	689.44
Apr-13	2442323	3530.65	691.75
May-13	2450502	3530.65	694.07
Jun-13	2458709	3530.65	696.39
Jul-13	2466943	3530.65	698.72
Aug-13	2475205	3530.65	701.06
Sep-13	2483494	3530.65	703.41
Oct-13	2491812	3530.65	705.77
Nov-13	2500157	3530.65	708.13
Dec-13	2508698	3530.65	710.55
Jan-14	2510225	3530.65	710.98
Feb-14	2511753	3530.65	711.41
Mar-14	2513281	3530.65	711.85
Apr-14	2514811	3530.65	712.28
May-14	2516341	3530.65	712.71
Jun-14	2517873	3530.65	713.15
Jul-14	2519405	3530.65	713.58
Aug-14	2520939	3530.65	714.02
Sep-14	2522473	3530.65	714.45
Oct-14	2524008	3530.65	714.88
Nov-14	2525544	3530.65	715.32

Periode	Jumlah Penduduk	Luas Wilayah	Kepadatan Penduduk per Bulan
Dec-14	2527087	3530.65	715.76
Jan-15	2528518	3530.65	716.16
Feb-15	2529949	3530.65	716.57
Mar-15	2531382	3530.65	716.97
Apr-15	2532815	3530.65	717.38
May-15	2534249	3530.65	717.79
Jun-15	2535684	3530.65	718.19
Jul-15	2537120	3530.65	718.60
Aug-15	2538556	3530.65	719.01
Sep-15	2539993	3530.65	719.41
Oct-15	2541431	3530.65	719.82
Nov-15	2542870	3530.65	720.23
Dec-15	2544315	3530.65	720.64
Jan-16	2545674	3530.65	721.02
Feb-16	2547034	3530.65	721.41
Mar-16	2548394	3530.65	721.79
Apr-16	2549755	3530.65	722.18
May-16	2551117	3530.65	722.56
Jun-16	2552480	3530.65	722.95
Jul-16	2553843	3530.65	723.34
Aug-16	2555207	3530.65	723.72
Sep-16	2556572	3530.65	724.11
Oct-16	2557937	3530.65	724.49
Nov-16	2559304	3530.65	724.88
Dec-16	2560675	3530.65	725.27
Jan-17	2561998	3530.65	725.64
Feb-17	2563321	3530.65	726.02
Mar-17	2564645	3530.65	726.39

Periode	Jumlah Penduduk	Luas Wilayah	Kepadatan Penduduk per Bulan
Apr-17	2565970	3530.65	726.77
May-17	2567295	3530.65	727.15
Jun-17	2568621	3530.65	727.52
Jul-17	2569948	3530.65	727.90
Aug-17	2571275	3530.65	728.27
Sep-17	2572603	3530.65	728.65
Oct-17	2573932	3530.65	729.03
Nov-17	2575262	3530.65	729.40
Dec-17	2576596	3530.65	729.78
Jan-18	2577859	3530.65	730.14
Feb-18	2579122	3530.65	730.50
Mar-18	2580386	3530.65	730.85
Apr-18	2581651	3530.65	731.21
May-18	2582917	3530.65	731.57
Jun-18	2584182	3530.65	731.93
Jul-18	2585449	3530.65	732.29
Aug-18	2586716	3530.65	732.65
Sep-18	2587984	3530.65	733.00
Oct-18	2589253	3530.65	733.36
Nov-18	2590522	3530.65	733.72
Dec-18	2591795	3530.65	734.08

C.2 Kepadatan Penduduk Kota Surabaya

Periode	Jumlah Penduduk	Luas Wilayah	Kepadatan Penduduk per Bulan
Jan-13	2807065	350.54	8007.83
Feb-13	2808413	350.54	8011.68
Mar-13	2809761	350.54	8015.52

Periode	Jumlah Penduduk	Luas Wilayah	Kepadatan Penduduk per Bulan
Apr-13	2811110	350.54	8019.37
May-13	2812460	350.54	8023.22
Jun-13	2813810	350.54	8027.07
Jul-13	2815161	350.54	8030.93
Aug-13	2816512	350.54	8034.78
Sep-13	2817865	350.54	8038.64
Oct-13	2819217	350.54	8042.50
Nov-13	2820571	350.54	8046.36
Dec-13	2821929	350.54	8050.23
Jan-14	2822926	350.54	8053.08
Feb-14	2823924	350.54	8055.93
Mar-14	2824922	350.54	8058.77
Apr-14	2825921	350.54	8061.62
May-14	2826920	350.54	8064.47
Jun-14	2827919	350.54	8067.32
Jul-14	2828919	350.54	8070.17
Aug-14	2829919	350.54	8073.03
Sep-14	2830919	350.54	8075.88
Oct-14	2831920	350.54	8078.73
Nov-14	2832921	350.54	8081.59
Dec-14	2833924	350.54	8084.45
Jan-15	2828674	350.54	8069.47
Feb-15	2823433	350.54	8054.52
Mar-15	2818202	350.54	8039.60
Apr-15	2812981	350.54	8024.71
May-15	2807769	350.54	8009.84
Jun-15	2802567	350.54	7995.00
Jul-15	2797375	350.54	7980.19
Aug-15	2792193	350.54	7965.40

Periode	Jumlah Penduduk	Luas Wilayah	Kepadatan Penduduk per Bulan
Sep-15	2787020	350.54	7950.65
Oct-15	2781856	350.54	7935.92
Nov-15	2776702	350.54	7921.21
Dec-15	2771615	350.54	7906.70
Jan-16	2779060	350.54	7927.94
Feb-16	2786524	350.54	7949.23
Mar-16	2794009	350.54	7970.59
Apr-16	2801514	350.54	7991.99
May-16	2809039	350.54	8013.46
Jun-16	2816584	350.54	8034.99
Jul-16	2824149	350.54	8056.57
Aug-16	2831735	350.54	8078.21
Sep-16	2839341	350.54	8099.91
Oct-16	2846968	350.54	8121.66
Nov-16	2854615	350.54	8143.48
Dec-16	2862406	350.54	8165.70
Jan-17	2863428	350.54	8168.62
Feb-17	2864451	350.54	8171.54
Mar-17	2865474	350.54	8174.46
Apr-17	2866497	350.54	8177.38
May-17	2867521	350.54	8180.30
Jun-17	2868545	350.54	8183.22
Jul-17	2869569	350.54	8186.14
Aug-17	2870594	350.54	8189.06
Sep-17	2871619	350.54	8191.99
Oct-17	2872645	350.54	8194.91
Nov-17	2873671	350.54	8197.84
Dec-17	2874699	350.54	8200.77
Jan-18	2875602	350.54	8203.35

Periode	Jumlah Penduduk	Luas Wilayah	Kepadatan Penduduk per Bulan
Feb-18	2876505	350.54	8205.93
Mar-18	2877409	350.54	8208.50
Apr-18	2878313	350.54	8211.08
May-18	2879217	350.54	8213.66
Jun-18	2880121	350.54	8216.24
Jul-18	2881026	350.54	8218.82
Aug-18	2881931	350.54	8221.40
Sep-18	2882836	350.54	8223.99
Oct-18	2883741	350.54	8226.57
Nov-18	2884647	350.54	8229.15
Dec-18	2885555	350.54	8231.74

C.3 Kepadatan Penduduk Kabupaten Sumenep

Periode	Jumlah Penduduk	Luas Wilayah	Kepadatan Penduduk per Bulan
Jan-13	1056814	1998.54	528.79
Feb-13	1057213	1998.54	528.99
Mar-13	1057612	1998.54	529.19
Apr-13	1058011	1998.54	529.39
May-13	1058410	1998.54	529.59
Jun-13	1058810	1998.54	529.79
Jul-13	1059209	1998.54	529.99
Aug-13	1059609	1998.54	530.19
Sep-13	1060009	1998.54	530.39
Oct-13	1060409	1998.54	530.59
Nov-13	1060810	1998.54	530.79
Dec-13	1061211	1998.54	530.99
Jan-14	1061709	1998.54	531.24

Periode	Jumlah Penduduk	Luas Wilayah	Kepadatan Penduduk per Bulan
Feb-14	1062207	1998.54	531.49
Mar-14	1062705	1998.54	531.74
Apr-14	1063204	1998.54	531.99
May-14	1063703	1998.54	532.24
Jun-14	1064202	1998.54	532.49
Jul-14	1064701	1998.54	532.74
Aug-14	1065200	1998.54	532.99
Sep-14	1065700	1998.54	533.24
Oct-14	1066200	1998.54	533.49
Nov-14	1066700	1998.54	533.74
Dec-14	1067202	1998.54	533.99
Jan-15	1067610	1998.54	534.20
Feb-15	1068019	1998.54	534.40
Mar-15	1068427	1998.54	534.60
Apr-15	1068836	1998.54	534.81
May-15	1069245	1998.54	535.01
Jun-15	1069654	1998.54	535.22
Jul-15	1070063	1998.54	535.42
Aug-15	1070473	1998.54	535.63
Sep-15	1070882	1998.54	535.83
Oct-15	1071292	1998.54	536.04
Nov-15	1071702	1998.54	536.24
Dec-15	1072113	1998.54	536.45
Jan-16	1072503	1998.54	536.64
Feb-16	1072893	1998.54	536.84
Mar-16	1073284	1998.54	537.03
Apr-16	1073674	1998.54	537.23
May-16	1074065	1998.54	537.42

Periode	Jumlah Penduduk	Luas Wilayah	Kepadatan Penduduk per Bulan
Jun-16	1074456	1998.54	537.62
Jul-16	1074847	1998.54	537.82
Aug-16	1075238	1998.54	538.01
Sep-16	1075629	1998.54	538.21
Oct-16	1076021	1998.54	538.40
Nov-16	1076412	1998.54	538.60
Dec-16	1076805	1998.54	538.80
Jan-17	1077171	1998.54	538.98
Feb-17	1077537	1998.54	539.16
Mar-17	1077903	1998.54	539.35
Apr-17	1078269	1998.54	539.53
May-17	1078635	1998.54	539.71
Jun-17	1079002	1998.54	539.90
Jul-17	1079368	1998.54	540.08
Aug-17	1079735	1998.54	540.26
Sep-17	1080102	1998.54	540.45
Oct-17	1080469	1998.54	540.63
Nov-17	1080836	1998.54	540.81
Dec-17	1081204	1998.54	541.00
Jan-18	1081539	1998.54	541.16
Feb-18	1081873	1998.54	541.33
Mar-18	1082208	1998.54	541.50
Apr-18	1082543	1998.54	541.67
May-18	1082878	1998.54	541.83
Jun-18	1083213	1998.54	542.00
Jul-18	1083549	1998.54	542.17
Aug-18	1083884	1998.54	542.34
Sep-18	1084219	1998.54	542.51
Oct-18	1084555	1998.54	542.67

Periode	Jumlah Penduduk	Luas Wilayah	Kepadatan Penduduk per Bulan
Nov-18	1084891	1998.54	542.84
Dec-18	1085227	1998.54	543.01

Halaman sengaja dikosongkan

LAMPIRAN D

Pada LAMPIRAN D berisi data hasil peramalan selama dua tahun periode kedepannya pada penelitian tugas akhir ini.

D.1 Hasil Peramalan Kabupaten Malang

Periode	Jumlah Kasus
Jan-19	1.357143
Feb-19	2.78368
Mar-19	2.629565
Apr-19	2.92063
May-19	2.252845
Jun-19	2.339401
Jul-19	2.727852
Aug-19	2.768892
Sep-19	2.669664
Oct-19	2.873382
Nov-19	2.3688
Dec-19	2.809744
Jan-20	2.554929
Feb-20	2.963454
Mar-20	2.185732
Apr-20	1.899926
May-20	1.318639
Jun-20	2.662234

Periode	Jumlah Kasus
Jul-20	2.883591
Aug-20	2.341071
Sep-20	2.733133
Oct-20	2.757243
Nov-20	2.699768
Dec-20	2.824823

D.2 Hasil Peramalan Kota Surabaya

Periode	Jumlah Kasus
Jan-19	2.833333333
Feb-19	2.521659539
Mar-19	2.885047072
Apr-19	2.498959431
May-19	2.92020993
Jun-19	2.491575965
Jul-19	2.931704663
Aug-19	2.490618628
Sep-19	2.933196454
Oct-19	2.490547539
Nov-19	2.93330724
Dec-19	2.490542748
Jan-20	2.933314707

Periode	Jumlah Kasus
Feb-20	2.490542428
Mar-20	2.933315206
Apr-20	2.490542406
May-20	2.93331524
Jun-20	2.490542405
Jul-20	2.933315242
Aug-20	2.490542405
Sep-20	2.933315242
Oct-20	2.490542405
Nov-20	2.933315242
Dec-20	2.490542405

D.3 Hasil Peramalan Kabupaten Sumenep

Periode	Jumlah Kasus
Jan-19	0.333333
Feb-19	-0.168834
Mar-19	0.881634
Apr-19	0.308788
May-19	-0.156240
Jun-19	0.833598
Jul-19	0.223330
Aug-19	-0.083585

Periode	Jumlah Kasus
Sep-19	0.579012
Oct-19	-0.112613
Nov-19	0.676127
Dec-19	-0.011677
Jan-20	0.364646
Feb-20	-0.179744
Mar-20	0.924182
Apr-20	0.388608
May-20	-0.184281
Jun-20	0.942133
Jul-20	0.423289
Aug-20	-0.185164
Sep-20	0.945644
Oct-20	0.430137
Nov-20	-0.184562
Dec-20	0.943248