



TUGAS AKHIR – TI 184833

**IMPLEMENTASI CONDITION BASED MAINTENANCE
DENGAN PENDEKATAN DATA MINING UNTUK PREDIKSI
WAKTU KEGAGALAN EQUIPMENT KRITIS MESIN RAW
MILL (STUDI KASUS: PT ABC)**

RAFIF NOVA RIANTAMA
NRP. 02411640000002

Dosen Pembimbing
Nani Kurniati, S.T., M.T., Ph.D
NIP. 197504081998022001

Dosen Ko-Pembimbing
Dewanti Anggrahini, S.T., M.T.
NIP. 198805022019032014

DEPARTEMEN TEKNIK SISTEM DAN INDUSTRI
Fakultas Teknologi Industri dan Rekayasa Sistem
Institut Teknologi Sepuluh Nopember
Surabaya 2020



TUGAS AKHIR – TI 184833

**IMPLEMENTASI CONDITION BASED MAINTENANCE
DENGAN PENDEKATAN DATA MINING UNTUK PREDIKSI
WAKTU KEGAGALAN EQUIPMENT KRITIS MESIN RAW
MILL (STUDI KASUS: PT ABC)**

RAFIF NOVA RIANTAMA
NRP. 02411640000002

Dosen Pembimbing
Nani Kurniati, S.T., M.T., Ph.D
NIP. 197504081998022001

Dosen Ko-Pembimbing
Dewanti Anggrahini, S.T., M.T.
NIP. 198805022019032014

DEPARTEMEN TEKNIK SISTEM DAN INDUSTRI
Fakultas Teknologi Industri dan Rekayasa Sistem
Institut Teknologi Sepuluh Nopember
Surabaya 2020



FINAL PROJECT – TI 184833

**CONDITION BASED MAINTENANCE IMPLEMENTATION
WITH DATA MINING APPROACHES TO PREDICT
CRITICAL EQUIPMENT FAILURE ON RAW MILL
MACHINE (CASE STUDY: PT ABC)**

RAFIF NOVA RIANTAMA
NRP. 02411640000002

Supervisor
Nani Kurniati, S.T., M.T., Ph.D
NIP. 197504081998022001

Co-Supervisor
Dewanti Anggrahini, S.T., M.T.
NIP. 198805022019032014

DEPARTMENT OF INDUSTRIAL AND SYSTEM ENGINEERING
Faculty of Industrial Technology and Systems Engineering
Institut Teknologi Sepuluh Nopember
Surabaya 2020

LEMBAR PENGESAHAN

IMPLEMENTASI CONDITION BASED MAINTENANCE DENGAN PENDEKATAN DATA MINING UNTUK PREDIKSI WAKTU KEGAGALAN EQUIPMENT KRITIS MESIN RAW MILL (STUDI KASUS: PT. ABC)

TUGAS AKHIR

Diajukan untuk memenuhi salah satu syarat memperoleh gelar
Sarjana Teknik pada Program Studi S1 Departemen Teknik Sistem dan Industri
Fakultas Teknologi Industri dan Rekayasa Sistem
Institut Teknologi Sepuluh Nopember
Surabaya, Indonesia

Oleh:

RAFIF NOVA RIANTAMA

NRP 02411640000002

Disetujui oleh:

Pembimbing

Ko-Pembimbing

Nani Kurniati, S.T., M.T., Ph.D

NIP. 197504081998022001

Dewanti Anggramini, S.T., M.T

NIP. 198805022019032014



(Halaman ini sengaja dikosongkan)

**IMPLEMENTASI CONDITION BASED MAINTENANCE
DENGAN PENDEKATAN DATA MINING UNTUK PREDIKSI
WAKTU KEGAGALAN EQUIPMENT KRITIS MESIN RAW
MILL (STUDI KASUS: PT ABC)**

Nama	:	Rafif Nova Riantama
NRP	:	02411640000002
Departemen	:	Teknik Industri - ITS
Pembimbing	:	Nani Kurniati, S.T., M.T., Ph.D
Ko-Pembimbing	:	Dewanti Anggrahini, S.T., M.T

ABSTRAK

Raw mill merupakan salah satu mesin utama dalam proses produksi semen pada unit V PT ABC. Tercatat bahwa availabilitas *raw mill* pada tahun 2015 – 2019 berada pada rentang 72,64% hingga 75,66%. Angka tersebut jauh di bawah target availabilitas perusahaan 90%. Perusahaan telah menerapkan *preventive maintenance* dengan aktivitas *overhaul* dan *condition-based maintenance* (CBM) melalui pemantauan kondisi *equipment* secara *real time* menggunakan sensor, namun pemeliharaan dilakukan ketika *equipment* mengalami kegagalan yang berpotensi menyebabkan tingginya *unplanned downtime*. Terdapat potensi untuk mengoptimalkan sistem pemeliharaan dengan menerapkan prinsip prognosis pada strategi CBM untuk prediksi waktu kegagalan *equipment* melalui perhitungan *Mean Residual Life* (MRL). Penelitian ini bertujuan untuk membuat dan menentukan model terbaik dalam prediksi MRL *equipment* pada mesin *raw mill*. Selain itu *dashboard* pemeliharaan akan dibangun untuk menunjang penerapan praktis di lapangan. Pendekatan regresi dalam *data mining* digunakan untuk prediksi MRL mesin. Model *data mining* yang digunakan adalah model *Artificial Neural Network* (ANN) dan *Support Vector Regression* (SVR). Parameter pembanding yang digunakan untuk penentuan model terbaik adalah *Root Mean Square Error* (RMSE) dan standar deviasi. *Wilcoxon test*, digunakan untuk membuktikan model terpilih layak untuk digunakan sebagai model prediksi. Selain itu digunakan *power BI software* untuk membangun *dashboard* pemeliharaan. Hasil menunjukkan bahwa tidak ada model yang dinyatakan layak untuk digunakan sebagai model prediksi kegagalan (MRL) *equipment* mesin *raw mill*, ditunjukkan dengan hasil *Wilcoxon test* lebih kecil dari 0,05. Adapun ketidaklayakan tersebut disebabkan data sensor tidak menunjukkan adanya degradasi fungsi pada *equipment*.

Kata kunci: *Raw mill*, *Mean Residual Life* (MRL), *Condition based maintenance* (CBM), *Artificial Neural Network* (ANN), *Support Vector Regression* (SVR)

(Halaman ini sengaja dikosongkan)

CONDITION BASED MAINTENANCE IMPLEMENTATION WITH DATA MINING APPROACHES TO PREDICT CRITICAL EQUIPMENT FAILURE ON RAW MILL MACHINE (CASE STUDY: PT ABC)

Name	:	Rafif Nova Riantama
NRP	:	02411640000002
Department	:	Teknik Industri - ITS
Supervisor	:	Nani Kurniati, S.T., M.T., Ph.D
Co-Supervisor	:	Dewanti Anggrahini, S.T., M.T

ABSTRACT

Raw mill is one of the important machines in cement production process at unit V of PT ABC. The availability of raw mill in 2015 – 2019 are recorded in the range of 72.64% to 75.66%, which is far below the company's target of 90%. Company has implemented condition-based maintenance (CBM) using sensor to monitor machine condition, however maintenance done when failure occurs which potentially lead to low availability. Preventive maintenance also done through overhaul activity. Prognosis process can be applied to optimize the CBM strategy to predict equipment's failure time through Mean Residual Life (MRL) calculation. The purposes of this study are to build and determine the best model to predict MRL of raw mill equipment. Moreover, maintenance dashboard will be developed to support practical implementation. Regression approach using Artificial Neural Network (ANN) and Support Vector Regression (SVR) model can be used to predict machine's MRL. Comparison parameters used to determine the best model are Root Mean Square Error (RMSE) and standard deviation. Wilcoxon test help to prove the chosen model are valid to be used as predictive model. Moreover, power BI software used to design maintenance dashboard. This research shows there is no model that feasible to be used as failure prediction model on raw mill machine's equipment, indicated by Wilcoxon test result smaller than 0,05. The model's impropriety caused by the sensors used in this research do not indicating function's degradation process on equipment.

Key word: Raw mill, Mean Residual Life (MRL), Condition based maintenance (CBM), Artificial Neural Network (ANN), Support Vector Regression (SVR)

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur kehadirat Allah SWT yang telah memberikan rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan Tugas Akhir ini sesuai dengan waktu yang telah ditetapkan.

Laporan Tugas Akhir dengan judul “**IMPLEMENTASI CONDITION BASED MAINTENANCE DENGAN PENDEKATAN DATA MINING UNTUK PREDIKSI WAKTU KEGAGALAN EQUIPMENT KRITIS MESIN RAW MILL (STUDI KASUS: PT ABC)**” disusun untuk memenuhi syarat dalam menyelesaikan studi Sarjana di Departemen Teknik Sistem dan Industri, Institut Teknologi Sepuluh Nopember, Surabaya. Tersusunnya Laporan Tugas Akhir ini tidak terlepas dari berbagai pihak yang telah memberikan semangat, kritik, masukan dan ilmu yang bermanfaat kepada penulis. Untuk itu penulis ingin menyampaikan ucapan terima kasih kepada:

1. Ibu Nani Kurniati S.T., M.T., Ph.D dan Ibu Dewanti Anggrahini S.T., M.T. selaku dosen pembimbing dan dosen ko-pembimbing atas bimbingan, arahan, motivasi dan ilmunya sehingga Tugas Akhir ini dapat terselesaikan dengan baik.
2. Bapak Inman Yasin, Manajer *Maintenance* pada PT ABC, selaku responden utama atas bantuan, bimbingan dan pengetahuan membantu dalam pengambilan data hingga proses pengerjaan Tugas Akhir.
3. Kedua orang tua serta keluarga besar yang selalu memberi doa, dukungan dan motivasi kepada penulis.
4. Bapak Nurhadi Siswanto S.T., MSIE., Ph.D, Bapak Ir. Mokhammad Suef, M.Sc., dan Bapak Prof. Ir. Moses Laksono Singgih M.Sc., Ph.D sebagai dosen penguji seminar proposal yang telah memberi arahan dan masukan untuk pelaksanaan Tugas Akhir.
5. Bapak Ir. Mokhammad Suef, M.Sc., dan Bapak Stefanus Eko Wiratno S.T., M.T. sebagai dosen penguji sidang Tugas Akhir yang telah memberi kritik dan saran untuk perbaikan Tugas Akhir.

6. Bapak dan Ibu Dosen Departemen Teknik Sistem dan Industri, Institut Teknologi Sepuluh Nopember atas ilmu yang diberikan sehingga dapat menjadi bekal penulis dalam penyelesaian Tugas Akhir.
7. Seluruh staff akademik Departemen Teknik Sistem dan Industri atas bantuan yang diberikan selama pelaksanaan perkuliahan penulis.
8. Teman-teman Asisten laboratorium sistem manufaktur atas motivasi, saran dan diskusi yang diberikan selama proses penggerjaan Tugas Akhir.
9. Teman-teman Teknik Industri Angkatan 2016 yang selalu memberi motivasi dan semangat dalam penggerjaan Tugas Akhir.
10. Serta semua pihak yang telah memberikan bantuan dan dukungan dalam penyelesaian Tugas Akhir ini yang tidak dapat disebutkan satu persatu.

Penulis menyadari bahwa masih terdapat banyak kekurangan dalam penyusunan Tugas Akhir ini. Oleh karena itu, kritik dan saran yang membangun sangat dibutuhkan bagi penulis untuk menyempurnakan Laporan Tugas Akhir ini. Akhir kata, semoga Laporan Tugas Akhir ini dapat memberikan manfaat bagi penulis, pembaca dan pihak-pihak terkait lainnya.

Surabaya, 21 Agustus 2020

Penulis

DAFTAR ISI

LEMBAR PENGESAHAN	i
ABSTRAK	iii
ABSTRACT	v
KATA PENGANTAR.....	vii
DAFTAR ISI.....	ix
DAFTAR TABEL.....	xiii
DAFTAR GAMBAR.....	xvii
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah	7
1.3 Tujuan Penelitian.....	8
1.4 Manfaat Penelitian.....	8
1.5 Batasan Penelitian	8
1.6 Asumsi Penelitian.....	9
1.7 Sistematika Penulisan.....	9
BAB 2 TINJAUAN PUSTAKA.....	13
2.1 Proses Produksi Semen.....	13
2.1.1 Jenis Proses Pembuatan Semen.....	13
2.1.2 Proses Produksi Semen PT ABC	14
2.2 Mesin <i>Raw Mill</i>	16
2.2.1 Definisi Mesin <i>Raw Mill</i>	16
2.2.2 Regulasi Kegagalan Mesin <i>Raw Mill</i>	17
2.3 <i>Condition Based Maintenance</i>	19
2.4 Konsep Statistik <i>Reliability</i>	21
2.5 <i>Data mining</i>	22
2.5.1 Definisi <i>Data Mining</i>	22
2.5.2 Proses <i>Data Mining</i>	23
2.6 <i>Artificial Neural Network (ANN)</i>	28
2.7 <i>Support Vector Regression</i>	31
2.8 <i>Grid Search</i>	33

2.9	<i>Nested Cross Validation</i>	33
2.10	Pengukuran Performa Model Regresi.....	34
2.11	<i>Critical Review</i>	36
BAB 3 METODOLOGI PENELITIAN		41
3.1	Tahap Pengumpulan dan Olah Data Awal.....	42
3.1.1	Pengumpulan Data.....	42
3.1.2	Pemilihan Data (<i>Data Selection</i>)	43
3.1.3	Perhitungan <i>Time to Failure</i> (TTF).....	43
3.1.4	Perhitungan <i>Mean Residual Life</i> (MRL)	43
3.1.5	Transformasi Data (<i>Data Transformation</i>).....	44
3.1.6	Pembagian <i>Data training</i> , <i>Data validation</i> dan <i>Data testing</i>	44
3.2	Tahap Penyusunan Model.....	45
3.2.1	Penentuan Nilai Parameter Uji Coba.....	45
3.2.2	Penentuan Parameter Model Optimal.....	45
3.3	Tahap Pemilihan Model.....	47
3.3.1	Tahap Evaluasi Model	47
3.3.2	Uji kelayakan model.....	48
3.3	Tahap Perancangan <i>Dashboard</i> Pemeliharaan	48
3.4	Kesimpulan dan Saran	49
BAB 4 PENGUMPULAN DAN OLAH DATA AWAL		51
4.1	Pengumpulan Data.....	51
4.2	Pemilihan Data.....	52
4.3	Perhitungan <i>Time to Failure</i> (TTF)	53
4.4	Perhitungan <i>Mean Residual Life</i> (MRL).....	57
4.5	Rekap Data <i>Input</i> Penyusunan Model.....	61
4.6	Transformasi Data (<i>Data Transformation</i>).....	62
4.7	<i>Data training</i> , <i>Data validation</i> & <i>Data testing</i>	64
BAB 5 PENYUSUNAN MODEL		67
5.1	Penentuan Nilai Parameter Uji Coba	67
5.2	Penentuan Parameter Optimal Model Prediksi	69
5.2.1	Model Prediksi <i>Motor Belt Conveyor (MBC) Equipment</i>	69
5.2.2	Model Prediksi <i>Sealing Air Fan (SAF) Equipment</i>	73

5.2.3	Model Prediksi <i>Rotary Feeder (RF) Equipment</i>	78
5.2.4	Model Untuk <i>Motor Bucket Elevator (MBE) Equipment</i>	82
5.3	Rekap Parameter Optimal Model SVR dan ANN	86
BAB 6 PEMILIHAN MODEL	89
6.1	Evaluasi Model	89
6.2	Uji Kelayakan Model	92
6.2.1	MRL <i>Data testing</i> dan MRL Hasil Prediksi Model	93
6.2.2	Uji Normalitas Data	94
6.2.3	Uji Beda dengan <i>Wilcoxon test</i>	96
6.2.4	Analisis Hasil Perhitungan Kelayakan Model	99
BAB 7 PERANCANGAN DASHBOARD PEMELIHARAAN	105
7.1	Sistem <i>Dashboard</i> Pemeliharaan	105
7.2	Desain <i>Dashboard</i> Pemeliharaan	106
BAB 8 KESIMPULAN DAN SARAN	109
8.1	Kesimpulan.....	109
8.2	Saran	110
DAFTAR PUSTAKA	111
LAMPIRAN	115
BIOGRAFI PENULIS	133

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

Tabel 1. 1 <i>Equipment</i> kritis Pada Bagian <i>Mill</i> dan <i>Transport Material</i>	5
Tabel 2. 1 <i>Threshold</i> Setiap <i>Sensor</i> pada <i>Equipment</i>	18
Tabel 2. 2 Regulasi Mesin <i>Raw Mill</i> dikatakan Bekerja.....	18
Tabel 2. 3 Perbandingan Penelitian Terdahulu dengan Penelitian Penulis	38
Tabel 3. 1 Sensor dan <i>Equipment</i> Pada Bagian <i>Mill</i> dan <i>Transport Material</i>	43
Tabel 3. 2 Parameter Uji Coba Model SVR dan ANN	45
Tabel 4. 1 Data Sensor RPM (MBC) - Sensor RPM (MBE) Tahun 2015 - 2019.	51
Tabel 4. 2 Data Sensor RPM (RF) - Sensor Bin (BI-2) Tahun 2015 – 2019.....	52
Tabel 4. 3 Data Sensor RPM (MBC) – Sensor Vibrasi Tahun 2017	53
Tabel 4. 4 Daftar Sensor dan <i>Equipment</i> yang Dipantau	53
Tabel 4. 5 Rekap Kondisi Motor <i>Belt Conveyor Equipment</i> (MBC).....	54
Tabel 4. 6 Rekap Kondisi <i>Sealing Air Fan Equipment</i> (SAF).....	54
Tabel 4. 7 Rekap Kondisi <i>Rotary Feeder Equipment</i> (RF).....	54
Tabel 4. 8 Rekap Kondisi <i>Motor Bucket Elevator Equipment</i> (MBE)	55
Tabel 4. 9 Rekap Hasil Perhitungan TTF (<i>MBC equipment</i>).....	55
Tabel 4. 10 Rekap Hasil Perhitungan TTF (<i>SAF equipment</i>)	56
Tabel 4. 11 Rekap Hasil Perhitungan TTF (<i>RF equipment</i>)	56
Tabel 4. 12 Rekap Hasil Perhitungan TTF (<i>MBE equipment</i>)	56
Tabel 4. 13 Rekap Distribusi Kegagalan dan Nilai Parameter Setiap <i>Equipment</i>	57
Tabel 4. 14 Rekap Contoh Perhitungan R(t) untuk setiap <i>equipment</i>	58
Tabel 4. 15 Rekap Contoh Perhitungan MRL (t).....	58
Tabel 4. 16 Rekap Hasil Perhitungan MRL (<i>MBC equipment</i>)	59
Tabel 4. 17 Rekap Hasil Perhitungan MRL (<i>SAF equipment</i>).....	60
Tabel 4. 18 Rekap Hasil Perhitungan MRL (<i>RF equipment</i>).....	60
Tabel 4. 19 Rekap Hasil Perhitungan MRL (<i>MBE equipment</i>)	60
Tabel 4. 20 Rekap Data <i>Input</i> Penyusunan Model (<i>MBC equipment</i>).....	61
Tabel 4. 21 Rekap Data <i>Input</i> Penyusunan Model (<i>SAF equipment</i>)	61
Tabel 4. 22 Rekap Data <i>Input</i> Penyusunan Model (<i>RF equipment</i>)	62
Tabel 4. 23 Rekap Data <i>Input</i> Penyusunan Model (<i>MBE equipment</i>)	62
Tabel 4. 24 Rekap Data <i>Input</i> Setelah <i>Scaling</i> (<i>MBC equipment</i>).....	63

Tabel 4. 25 Rekap Data <i>Input</i> Setelah <i>Scaling</i> (<i>SAF equipment</i>).....	63
Tabel 4. 26 Rekap Data <i>Input</i> Setelah <i>Scaling</i> (<i>RF equipment</i>).....	63
Tabel 4. 27 Rekap Data <i>Input</i> Setelah <i>Scaling</i> (<i>MBE equipment</i>).....	63
Tabel 4. 28 <i>Data training, Validation</i> dan <i>Testing</i> (<i>MBC equipment</i>).....	64
Tabel 4. 29 <i>Data training, Validation</i> dan <i>Testing</i> (<i>SAF equipment</i>).....	65
Tabel 4. 30 <i>Data training, Validation</i> dan <i>Testing</i> (<i>RF equipment</i>).....	65
Tabel 4. 31 <i>Data training, Validation</i> dan <i>Testing</i> (<i>MBE equipment</i>)	65
Tabel 5. 1 Nilai Parameter Uji Model SVR.....	67
Tabel 5. 2 Nilai Parameter Uji Model ANN.....	68
Tabel 5. 3 RMSE <i>Data validation</i> Model SVR (<i>MBC equipment</i>)	69
Tabel 5. 4 RMSE <i>Data training</i> Model SVR (<i>MBC equipment</i>)	70
Tabel 5. 5 Perbandingan RMSE <i>Data Validation</i> dan <i>Training</i> Model SVR (<i>MBC equipment</i>)	70
Tabel 5. 6 RMSE <i>Data validation</i> Model ANN (<i>MBC equipment</i>)	72
Tabel 5. 7 RMSE <i>Data training</i> Model ANN (<i>MBC equipment</i>)	72
Tabel 5. 8 Perbandingan RMSE <i>Data validation</i> dan <i>Training</i> Model ANN (<i>MBC equipment</i>)	73
Tabel 5. 9 RMSE <i>Data validation</i> Model SVR (<i>SAF equipment</i>).....	74
Tabel 5. 10 RMSE <i>Data training</i> Model SVR (<i>SAF equipment</i>).....	74
Tabel 5. 11 Perbandingan RMSE <i>Data validation</i> dan <i>Training</i> Model SVR (<i>SAF equipment</i>)	74
Tabel 5. 12 RMSE <i>Data validation</i> Model ANN (<i>SAF equipment</i>).....	77
Tabel 5. 13 RMSE <i>Data training</i> Model ANN (<i>SAF equipment</i>).....	77
Tabel 5. 14 Perbandingan RMSE <i>Data validation</i> dan <i>Training</i> Model ANN (<i>SAF equipment</i>)	78
Tabel 5. 15 RMSE <i>Data validation</i> Model SVR (<i>RF equipment</i>).....	79
Tabel 5. 16 RMSE <i>Data training</i> Model SVR (<i>RF equipment</i>).....	79
Tabel 5. 17 Perbandingan RMSE <i>Data validation</i> dan <i>Training</i> Model SVR (<i>RF equipment</i>)	80
Tabel 5. 18 RMSE <i>Data validation</i> Model ANN (<i>RF equipment</i>).....	81
Tabel 5. 19 RMSE <i>Data training</i> Model ANN (<i>RF equipment</i>)	81

Tabel 5. 20 Perbandingan RMSE <i>Data validation</i> dan <i>Training Model ANN (RF equipment)</i>	82
Tabel 5. 21 RMSE <i>Data validation</i> Model SVR (<i>MBE equipment</i>).....	83
Tabel 5. 22 RMSE <i>Data training</i> Model SVR (<i>MBE equipment</i>)	83
Tabel 5. 23 Perbandingan RMSE <i>Data validation</i> dan <i>Training Model SVR (MBE equipment)</i>	83
Tabel 5. 24 RMSE <i>Data validation</i> Model ANN (<i>MBE equipment</i>).....	85
Tabel 5. 25 RMSE <i>Data training</i> Model ANN (<i>MBE equipment</i>)	85
Tabel 5. 26 Perbandingan RMSE <i>Data validation</i> dan <i>Training Model ANN (MBE equipment)</i>	86
Tabel 5. 27 Rekap Parameter Optimal Model SVR dan ANN	87
Tabel 6. 1 Ukuran Performansi Model SVR dan ANN (<i>MBC equipment</i>).....	89
Tabel 6. 2 Ukuran Performansi Model SVR dan ANN (<i>SAF equipment</i>)	90
Tabel 6. 3 Ukuran Performansi Model SVR dan ANN (<i>RF equipment</i>)	91
Tabel 6. 4 Ukuran Performansi Model SVR dan ANN (<i>MBE equipment</i>).....	91
Tabel 6. 5 Rekap Model Terpilih Setiap <i>Equipment</i>	92
Tabel 6. 6 MRL <i>Data testing</i> dan Prediksi Model SVR (<i>MBC equipment</i>)	93
Tabel 6. 7 MRL <i>Data testing</i> dan Prediksi Model ANN (<i>SAF equipment</i>)	93
Tabel 6. 8 MRL <i>Data testing</i> dan Prediksi Model SVR (<i>RF equipment</i>).....	94
Tabel 6. 9 MRL <i>Data testing</i> dan Prediksi Model ANN (<i>MBE equipment</i>).....	94
Tabel 6. 10 Uji Normalitas Data (<i>MBC equipment</i>)	94
Tabel 6. 11 Uji Normalitas Data (<i>SAF equipment</i>)	95
Tabel 6. 12 Uji Normalitas Data (<i>RF equipment</i>)	95
Tabel 6. 13 Uji Normalitas Data (<i>MBE equipment</i>).....	96
Tabel 6. 14 Hipotesis dalam <i>Wilcoxon test</i>	96
Tabel 6. 15 <i>Wilcoxon test</i> MRL <i>Data testing</i> dan MRL Prediksi SVR (<i>MBC equipment</i>).....	97
Tabel 6. 16 <i>Wilcoxon test</i> MRL <i>Data testing</i> dan MRL Prediksi ANN (<i>SAF equipment</i>).....	97
Tabel 6. 17 <i>Wilcoxon test</i> MRL <i>Data testing</i> dan MRL Prediksi SVR (<i>RF equipment</i>).....	98

Tabel 6. 18 <i>Wilcoxon test MRL Data testing</i> dan MRL Prediksi ANN (<i>MBE equipment</i>)	98
Tabel 6. 19 Hasil Uji Regresi (<i>MBC equipment</i>).....	99
Tabel 6. 20 Hasil Uji Regresi (<i>SAF equipment</i>)	100
Tabel 6. 21 Hasil Uji Regresi (<i>RF equipment</i>)	100
Tabel 6. 22 Hasil Uji Regresi (<i>MBE equipment</i>).....	100

DAFTAR GAMBAR

Gambar 1. 1 Proses Produksi Semen Pada Unit V PT ABC.....	2
Gambar 1. 2 Grafik Availabilitas Mesin <i>Raw mill</i> Unit V (2015 – 2019).....	3
Gambar 1. 3 <i>Planned</i> dan <i>Unplanned Downtime</i> Mesin <i>Raw Mill</i> (2015 – 2019). .	4
Gambar 1. 4 <i>Pareto Chart</i> Total <i>Downtime</i> Mesin <i>Raw Mill</i> (2015 – 2019)	4
Gambar 2. 1 Proses Produksi Semen Pada PT ABC.....	14
Gambar 2. 2 Klasifikasi Strategi <i>Maintenance</i>	19
Gambar 2. 3 Proses <i>Condition Based Maintenance</i> (CBM)	20
Gambar 2. 4 Diagram MTTF, MTTR dan MTBF	21
Gambar 2.5 Proses <i>Data mining</i>	24
Gambar 2. 6 Contoh <i>Network</i> Pada <i>Artificial Neural Network</i> (ANN)	28
Gambar 2. 7 Ilustrasi <i>Plot Support Vector</i> Dengan Fungsi $f(x)$	31
Gambar 2. 8 Ilustrasi <i>Layout Grid Search</i> dengan 2 Jenis Parameter <i>Input</i>	33
Gambar 2. 9 Ilustrasi <i>Nested Cross Validation</i>	34
Gambar 3. 1 Diagram Alur Pelaksanaan Penelitian.....	42
Gambar 3. 2 Pembagian <i>Data training</i> , <i>Validation</i> , dan <i>Testing</i> dengan <i>Nested Cross Validation</i>	45
Gambar 3. 3 Proses <i>Parameter Tuning</i> Untuk Model ANN dan SVR	46
Gambar 6. 1 Grafik <i>Monitoring</i> Sensor & MRL <i>MBC equipment</i> Skala 0-1	101
Gambar 6. 2 Grafik <i>Monitoring</i> Sensor & MRL <i>SAF equipment</i> Skala 0 - 1	101
Gambar 6. 3 Grafik <i>Monitoring</i> Sensor & MRL <i>RF equipment</i> Skala 0 - 1.....	102
Gambar 6. 4 Grafik <i>Monitoring</i> Sensor & MRL <i>MBE equipment</i> Skala 0 - 1 ...	102
Gambar 7. 1 Skema Kerja <i>Dashboard</i> Pemeliharaan Mesin <i>Raw Mill</i>	105
Gambar 7. 2 <i>Dashboard</i> Utama Sistem <i>Monitoring</i> Mesin <i>Raw Mill</i>	107
Gambar 7. 3 <i>Dashboard</i> Kondisi <i>Equipment</i> secara Detail	107

(Halaman ini sengaja dikosongkan)

BAB 1

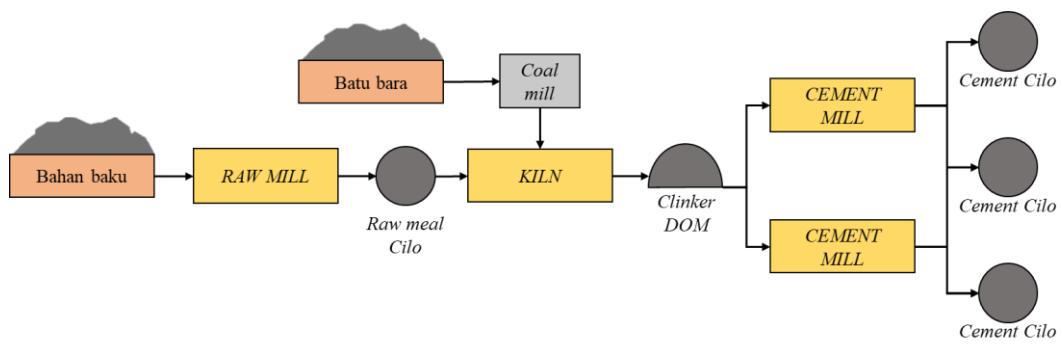
PENDAHULUAN

Pada bab ini dijelaskan mengenai latar belakang, rumusan masalah, tujuan, manfaat, batasan dan asumsi serta sistematika penulisan laporan pada penelitian ini.

1.1 Latar Belakang

PT ABC merupakan industri semen terbesar pada daerah timur Indonesia yang menempati lahan seluas 715 hektar. Industri dengan kapasitas produksi mencapai ± 5.980.000 ton pertahun tersebut menggunakan proses kering dalam proses produksi semen. Proses kering (*dry process*) merupakan teknik pembuatan semen dengan melakukan proses penggilingan dan *blending* untuk kemudian dibakar dengan bahan bakar batu bara (Susanti, 2016). Sebelumnya, proses basah pernah diaplikasikan oleh perusahaan pada unit I. Unit tersebut diberhentikan sejak tahun 1984 karena proses basah dinilai memerlukan biaya lebih mahal dibandingkan proses kering. Saat ini, PT ABC memiliki empat unit produksi yaitu, unit II, III, IV dan V dengan kapasitas berturut-turut sebesar 590.000 ton, 590.000 ton, 2.300.000 ton, dan 2.500.000 ton per tahun. Kapasitas produksi terbesar dimiliki oleh unit V, sehingga unit tersebut merupakan unit penting untuk mendukung perusahaan dalam pemenuhan permintaan semen pada pasar Indonesia.

Unit V merupakan unit produksi terbaru milik PT ABC yang didirikan pada tahun 2014. Unit tersebut dilengkapi dengan satu mesin *raw mill*, satu mesin *kiln*, dua mesin *cement mill*, satu *raw meal ciло*, satu *clinker DOM*, dan tiga *cement ciло*. Berdasarkan hasil wawancara dengan pihak perusahaan, terdapat tiga proses utama dalam proses produksi semen sesuai dengan Gambar 1.1. Proses pertama terjadi pada area *raw mill* untuk mengolah bahan baku semen menjadi produk *raw meal*. Proses kedua dilakukan oleh area *kiln* untuk memproduksi *clinker* dengan bahan baku utama adalah produk *raw meal*. Dalam proses pada area *kiln* juga dibutuhkan batu bara sebagai bahan bakar untuk proses pembakaran *raw meal*. Proses terakhir dilakukan pada area *cement mill* untuk memproduksi produk akhir semen.



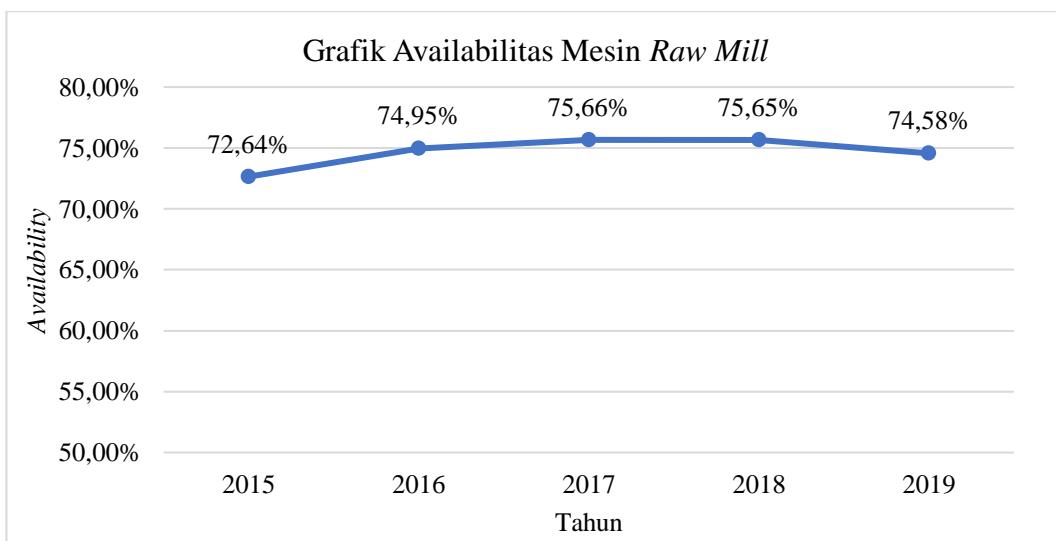
Gambar 1. 1 Proses Produksi Semen Pada Unit V PT ABC

Gambar 1.1 menunjukkan terdapat satu mesin *raw mill* dan satu mesin *kiln*. Kegagalan pada salah satunya dapat menyebabkan proses produksi semen terhenti. Berbeda dengan area *cement mill* yang memiliki dua buah mesin. Jika salah satu mesin *cement mill* mengalami kegagalan, maka proses produksi masih dapat berjalan. Hal tersebut menunjukkan bahwa perawatan pada area *raw mill* dan *kiln* perlu lebih diperhatikan, sebagai tindakan *preventive* untuk mencegah terhambatnya proses produksi.

Meninjau kondisi mesin *raw mill* dan *kiln*, total *downtime* mesin *raw mill* dalam rentang waktu 2015 – 2019 menunjukkan angka yang lebih tinggi dibandingkan mesin *kiln*. Teracatat bahwa total *downtime* mesin *raw mill* mencapai angka 13.626,71 jam dalam kurun waktu lima tahun, sedangkan mesin *kiln* hanya 6.363,886 jam. Kondisi tersebut menjadi alasan pemilihan mesin *raw mill* sebagai objek dalam penelitian ini.

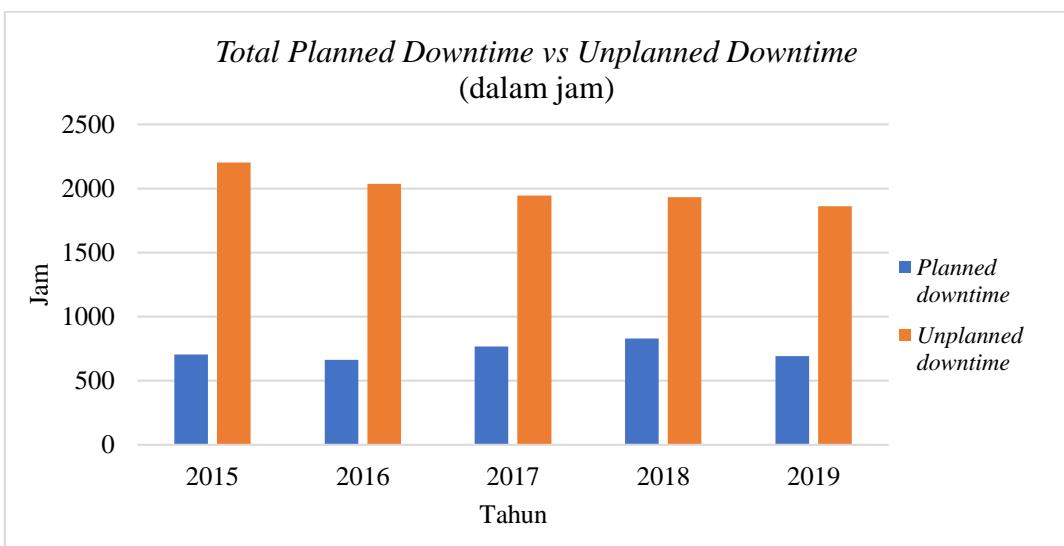
Mesin *raw mill* merupakan mesin yang digunakan untuk mencampur, menggiling, dan mengeringkan bahan baku utama yang digunakan dalam proses produksi semen (Taufik, et al., 2017). Gambar 1.1 menunjukkan mesin *raw mill* berada pada tahap awal dalam proses produksi semen, sehingga kegagalan pada mesin *raw mill* dapat menghambat proses produksi semen selanjutnya. Berdasarkan hasil pengolahan data, availabilitas mesin *raw mill* pada rentang tahun 2015 hingga 2019 beriksar antara 72,64 % hingga 75,66 %. Angka tersebut jauh dibandingkan dengan target availabilitas perusahaan. Target availabilitas dari setiap peralatan dan mesin pada PT ABC mengacu pada *world class OEE level* yaitu 90% (Patel &

Thakkar, 2014). Gambar 1.2 menunjukkan grafik availabilitas mesin *raw mill* pada rentang 2015 – 2019.



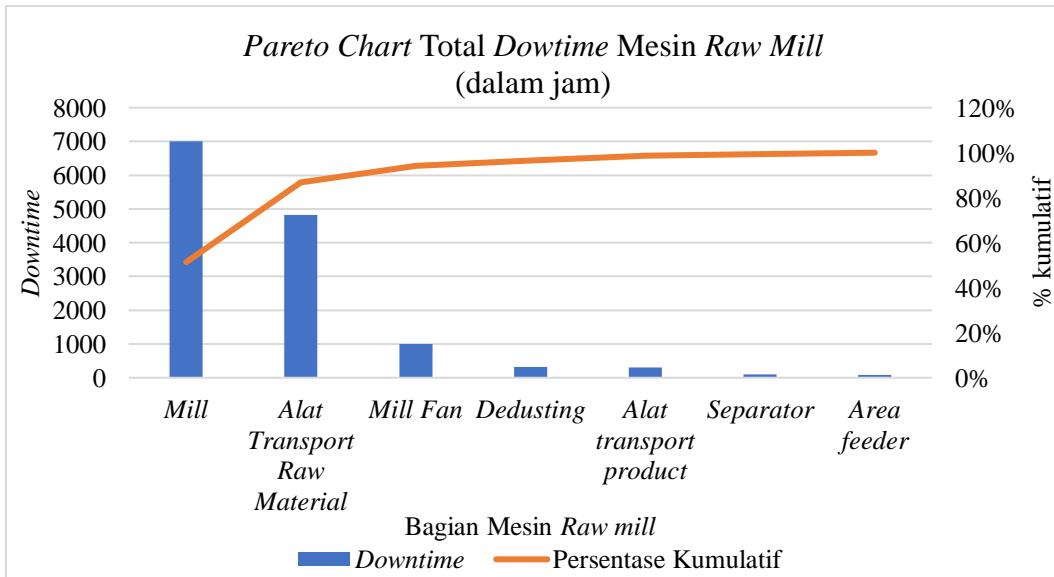
Gambar 1. 2 Grafik Availabilitas Mesin *Raw mill* Unit V (2015 – 2019)

Tingginya angka *downtime* berpotensi menjadi penyebab rendahnya availabilitas mesin *raw mill*. *Downtime* terbagi atas dua kategori yaitu *planned downtime*, dimana waktu pemeliharaan telah direncanakan sebelum proses produksi dan *unplanned downtime*, waktu pemeliharaan yang tidak direncanakan karena kegagalan mesin yang terjadi tiba-tiba (Anwar, et al., 2016). Gambar 1.3 menunjukkan bahwa dalam rentang tahun 2015 hingga 2019 *unplanned downtime* mesin *raw mill* selalu lebih tinggi dibandingkan dengan *planned downtime*. Kondisi tersebut mengindikasikan bahwa perlu adanya perbaikan pada sistem pemeliharaan mesin *raw mill*, karena sistem pemeliharaan yang diterapkan saat ini masih belum dapat menjawab tujuan pemeliharaan. Menurut Ansori & Mustajib (2013) salah satu tujuan pemeliharaan adalah menjamin kesiapan operasional seluruh fasilitas yang diperlukan saat pemakaian.



Gambar 1. 3 *Planned* dan *Unplanned Downtime* Mesin Raw Mill (2015 – 2019)

Terkait dengan *downtime* pada mesin *raw mill*, Gambar 1.4 menunjukkan total *downtime* pada setiap bagian mesin *raw mill* dalam rentang 2015 – 2019. Terdapat tujuh bagian utama pada mesin *raw mill* yaitu bagian *feeder*, *mill*, alat *transport raw material*, *separator*, *mill fan*, alat *transport produk*, dan *dedusting*.



Gambar 1. 4 *Pareto Chart Total Downtime Mesin Raw Mill* (2015 – 2019)

Menurut Al Farobi & Muslimin (2019), analisa *pareto chart* menunjukkan 80% kegagalan dari suatu mesin disebabkan karena kegagalan pada 20% bagian pada mesin tersebut. Gambar 1.4 menunjukkan bahwa bagian *mill* dan bagian alat

transport raw material merupakan 20% bagian mesin *raw mill* yang berpotensi menyebabkan 80% kegagalan pada mesin tersebut. Maka dari itu, pemeliharaan pada bagian *mill* dan alat *transport raw material* perlu diperhatikan untuk mencegah terjadinya 80% kerusakan pada mesin *raw mill*.

Berdasarkan hasil wawancara dengan pihak perusahaan, terdapat tujuh *equipment* kritis yang menjadi penyebab kegagalan pada bagian *mill* dan alat *transport raw material*, lima *equipment* pada bagian *mill* dan dua *equipment* pada bagian alat *transport raw material*. Tabel 1.1 menunjukkan daftar *equipment* kritis pada bagian *mill* dan *transport raw material*. Untuk mencegah terjadinya 80% kegagalan pada mesin *raw mill* maka penelitian ini akan fokus pada tujuh *equipment* dalam Tabel 1.1.

Tabel 1. 1 *Equipment* kritis Pada Bagian *Mill* dan *Transport Material*

Bagian	Equipment
<i>Mill</i>	<i>Motor belt conveyor</i>
	<i>Sealing air fan</i>
	<i>Hydraulic system</i>
	<i>Motor bucket elevator</i>
	<i>Rotary feeder</i>
<i>Alat transport raw material</i>	<i>Bin material (batu kapur)</i>
	<i>Bin material (tanah liat)</i>

Terdapat dua macam strategi *maintenance* yang diterapkan oleh perusahaan yaitu *preventive maintenance* dan *condition-based maintenance*. *Preventive maintenance* dilakukan melalui kegiatan *overhaul* yang dijadwalkan setiap awal tahun. Disamping itu, *condition-based maintenance* (CBM) juga diterapkan dengan mengaplikasikan sensor untuk memantau kondisi *equipment* secara *realtime*. Pemantauan kondisi *equipment* secara *realtime* cocok diterapkan oleh PT ABC, mengingat operasional perusahaan berjalan selama 24 jam, sehingga kegagalan *equipment* merupakan hal yang krusial dan penting untuk diperhatikan. Namun, sistem CBM yang diterapkan dinilai kurang optimal. *Maintenance* dilaksanakan ketika sensor memantau *equipment* mengalami kegagalan. Strategi tersebut dapat berpotensi menyebabkan tingginya *unplanned downtime*. Selain itu, dengan sistem yang ada data hasil *monitoring* sensor kurang terutilisasi secara maksimal.

Meninjau sistem pemelihaaran yang telah diterapkan dan tersedianya data sensor, terdapat potensi untuk dilakukan penyempurnaan pada strategi *condition-based maintenance*. Proses prognosis pada CBM dapat diaplikasikan untuk mengoptimalkan strategi *maintenance* dengan memaksimalkan penggunaan *data sensor*. Prognosis adalah proses prediksi terjadinya kegagalan pada mesin/*equipment* dengan mengacu pada hasil data sensor (Jardine et al., 2006). Menurut A.T. de Almeida et al. (2015), informasi prognosis adalah kunci utama dalam pengambilan keputusan dalam penyusunan CBM. Dengan mengetahui waktu terjadinya kegagalan, perusahaan dapat mempersiapkan langkah preventif untuk mencegah terjadinya kegagalan tersebut. Pada akhirnya, proses prognosis diharapkan mampu mengoptimalkan proses produksi dan meningkatkan availabilitas mesin *raw mill*.

Mengingat bahwa proses prognosis bekerja dengan jumlah data sensor yang sangat banyak, pendekatan *data mining* perlu untuk diaplikasikan. Menurut Santosa & Umam (2018), *data mining* adalah kegiatan mengekstrak pengetahuan dari data dengan metode tertentu, sehingga informasi yang dihasilkan dapat dipakai dalam memperbaiki pengambilan keputusan. Terdapat empat macam studi yang dapat dilakukan dengan *data mining*, yaitu *clustering*, klasifikasi, regresi dan asosiasi. Keempat tugas tersebut bekerja secara spesifik sesuai dengan kasus yang diselesaikan. Dalam penelitian ini digunakan model regresi, karena proses prognosis untuk prediksi waktu kegagalan *equipment* berbentuk data kontinu. Menurut Santosa & Umam (2018), model regresi memiliki *output* berupa data kontinu, berebeda dengan model klasifikasi dan *clustering* yang memiliki *output* data diskrit.

Studi sebelumnya mengenai penggunaan *data mining* dalam penerapan *condition-based maintenance* menunjukkan bahwa model *artificial neural network* (ANN) cocok diimplementasikan dalam penyelesaian kasus pada industri, khususnya untuk *predictive maintenance* (Krenek, et al., 2016). Adapun penelitian oleh Sampaio et al. (2019), menunjukkan bahwa model ANN mampu melakukan prediksi yang baik dengan nilai RMSE yang lebih rendah dibandingkan dengan model SVM (*Support Vector Machine*), RF (*random forest*) dan RT (*random tree*). Selain itu penelitian oleh Moura, et al. (2011), menunjukkan bahwa model *support*

vector regression (SVR) mampu memberikan performa yang baik dalam melakukan prediksi kegagalan mesin dengan data *time series*. Serta penelitian terakhir oleh Suyuti et al. (2013), menunjukkan bahwa model ANN dapat digunakan untuk membentuk klasifikasi kegagalan mesin pada PT. Semen Bosowa berdasarkan karakteristik kegagalan. Hal tersebut digunakan dalam penentuan perlakuan *maintenance* yang tepat.

Berdasarkan kondisi perusahaan dan tinjauan penelitian terdahulu, maka penelitian ini akan fokus pada penerapan proses prognosis dengan model *data mining* untuk prediksi waktu kegagalan *equipment*. Terdapat dua model *data mining* yang diterapkan yaitu *support vector regression* (SVR) dan *artificial neural network* (ANN) dan. SVR adalah pengembangan dari *support vector machine* dalam penyelesaian kasus secara regresi. Sedangkan ANN adalah model *data mining* yang mengadopsi sistem saraf makhluk hidup. Secara umum model ANN terdiri tiga *layer* dasar yaitu *input layer*, *hidden layer*, dan *output layer* (Krenek, et al., 2016). Model SVR dipilih karena dinilai dapat mengatasi masalah *overfitting*, dapat menyelesaikan kasus *nonlinier* dan banyak digunakan dalam penyelesaian kasus dengan data *time series*. Sedangkan pemilihan model ANN dikarenakan model ANN mampu melakukan prediksi dengan data kompleks, memiliki toleransi yang tinggi terhadap *noise*, mampu menyelesaikan kasus *nonlinear* dan merupakan metode yang banyak digunakan dalam pemecahan berbagai masalah prediksi. Maka dari itu, penelitian ini akan membandingkan performansi antara kedua model tersebut untuk memperoleh model prediksi yang tepat diterapkan pada setiap *equipment* mesin *raw mill*. Selain itu, penelitian mengenai penggunaan prinsip prognostik belum pernah diterapkan pada industri semen.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, maka permasalahan yang diangkat dalam penelitian ini adalah bagaimana melakukan prediksi kegagalan setiap *equipment* mesin *raw mill* pada unit V PT ABC melalui penerapan proses prognosis dalam *condition-based maintenance* dengan menggunakan model ANN dan SVR.

1.3 Tujuan Penelitian

Berikut merupakan tujuan yang akan dicapai dalam penelitian ini.

1. Melakukan penyusunan model ANN dan SVR untuk memprediksi waktu kegagalan setiap *equipment* mesin *raw mill*.
2. Menentukan model terbaik untuk prediksi waktu kegagalan setiap *equipment* mesin *raw mill*.
3. Melakukan uji kelayakan model untuk memastikan bahwa model yang diterapkan mampu melakukan prediksi sesuai dengan kondisi sebenarnya.
4. Merancang *dashboard* pemeliharaan untuk mengetahui waktu kegagalan *equipment* pada mesin *raw mill*.

1.4 Manfaat Penelitian

Berikut merupakan manfaat yang akan diperoleh dari pelaksanaan penelitian ini.

1. Menjadi salah satu pendekatan perusahaan dalam menentukan waktu *maintenance* yang tepat untuk mengoptimalkan kinerja mesin *raw mill*.
2. Perusahaan dapat meningkatkan availabilitas mesin *raw mill* pada unit V PT ABC.
3. Perusahaan dapat mencegah terjadinya kekurangan *supply raw meal* pada proses pembuatan *clinker* oleh kiln pada unit V.
4. Perusahaan dapat mengoptimalkan jumlah semen yang produksi oleh unit V.

1.5 Batasan Penelitian

Berikut merupakan batasan yang digunakan dalam penelitian ini.

1. Terdapat lima jenis sensor yang digunakan dalam penelitian ini yaitu sensor RPM (*motor belt conveyor*), sensor tekanan, sensor RPM (*rotary motor*), sensor RPM (*motor bucket elevator*), dan sensor vibrasi.

2. Data yang digunakan dalam penelitian ini adalah data sekunder hasil *monitoring* lima sensor dari empat *equipment* kritis pada mesin *raw mill* unit V PT ABC.
3. Data *monitoring* sensor yang digunakan dalam penelitian adalah data pada tahun 2017.
4. Prediksi waktu kegagalan dilakukan pada 4 *equipment* dalam mesin *raw mill* (*motor belt conveyor, sealing air fan, rotary feeder dan motor bucket elevator*).

1.6 Asumsi Penelitian

Adapun asumsi yang digunakan dalam penelitian ini adalah sebagai berikut.

1. Sensor beroperasi secara normal dalam rentang tahun 2017.
2. Hasil pantauan sensor diluar *threshold* menunjukkan kegagalan pada sistem *equipment*, bukan kegagalan pada sensor maupun faktor lain yang menyebabkan kinerja mesin diluar *threshold*.

1.7 Sistematika Penulisan

Berikut merupakan sistematika penulisan yang digunakan dalam penyusunan laporan pada penelitian ini.

BAB I PENDAHULUAN

Pada bab ini dijelaskan mengenai latar belakang pelaksanaan penelitian, rumusan masalah penelitian yang akan diselesaikan dalam penelitian ini, tujuan penelitian yang akan dicapai, manfaat penelitian baik bagi perusahaan objek penelitian maupun dalam pengembangan keilmuan, ruang lingkup pelaksanaan penelitian yang berisi batasan dan asumsi, serta sistematika penyusunan laporan yang menjelaskan secara singkat urutan penulisan laporan akhir penelitian.

BAB II TINJAUAN PUSTAKA

Pada bab ini dijelaskan mengenai teori dasar yang menjadi landasan dalam penelitian yang dilaksanakan oleh penulis. Dasar teori pada bab ini akan digunakan

sebagai dasar dalam penyelesaian permasalahan yang telah didefinisikan sebelumnya, serta penjelasan mengenai *tools/metode* dalam mencapai tujuan penelitian yang ditargetkan. Dasar teori pada bab ini diperoleh dari sumber-sumber yang dapat dipertanggung jawabkan, seperti buku, publikasi jurnal atau *paper* nasional dan internasional, serta penelitian sebelumnya.

BAB III METODOLOGI PENELITIAN

Pada bab ini dijelaskan mengenai tahapan pelaksanaan penelitian yang dirancang oleh penulis. Tahap pelaksanaan penelitian akan dijelaskan melalui bagan alur penelitian. Setiap prosedur dalam bagan alur penelitian akan dijelaskan secara detail dan komprehensif pada bab ini.

BAB IV PENGUMPULAN DAN OLAH DATA AWAL

Pada bab ini dipaparkan mengenai hasil data yang diperoleh untuk pelaksanaan penelitian. Selain itu dilakukan olah data awal yang meliputi *data selection*, perhitungan *time to failure* (TTF), perhitungan *mean residual life* (MRL) dan transformasi data.

BAB V PENYUSUNAN MODEL

Pada bab ini dijelaskan mengenai penyusunan model prediksi waktu kegagalan *equipment* dengan *support vector regression* (SVR) dan *artificial neural network* (ANN). Penyusunan model ditujuan untuk menentukan nilai parameter optimal pada model SVR dan ANN untuk setiap *equipment*. Penentuan nilai parameter optimal dilakukan dengan metode *grid search* melalui *nested cross validation* sebagai metode validasi model.

BAB VI PEMILIHAN MODEL

Pada bab ini dijelaskan mengenai pemilihan model terbaik, SVR atau ANN, untuk setiap equipment melalui evaluasi terhadap model tersebut dengan nilai parameter optimal. Uji kelayakan model juga dilakukan pada tahap ini untuk memastikan model dapat digunakan sebagai model prediksi waktu kegagalan (MRL).

BAB VII PERANCANGAN *DASHBOARD* PEMELIHARAAN

Pada bab ini akan dijelaskan mengenai perancangan *dashboard* pemeliharaan untuk pemantauan kondisi dan waktu kegagalan (MRL) setiap *equipment* mesin *raw mill*. *Software* power BI digunakan untuk membangun *dashboard* pemeliharaan.

BAB VIII KESIMPULAN DAN SARAN

Pada bab ini dijelaskan mengenai kesimpulan yang diperoleh dari pelaksanaan tugas akhir serta pemberian saran baik untuk pihak perusahaan maupun untuk pengembangan penelitian.

(Halaman ini sengaja dikosongkan)

BAB 2

TINJAUAN PUSTAKA

Pada bab ini dijelaskan mengenai teori dasar yang menjadi landasan dalam pelaksanaan penelitian oleh penulis.

2.1 Proses Produksi Semen

Pada bagian ini dijelaskan mengenai jenis-jenis proses pembuatan semen serta proses produksi semen yang dilakukan oleh PT ABC.

2.1.1 Jenis Proses Pembuatan Semen

Menurut Salah (2010), produksi semen dapat dilakukan melalui dua macam proses, yaitu proses kering dan proses basah. Perbedaan proses tersebut ditinjau berdasarkan perbedaan kadar air umpan dalam proses produksinya.

a. Proses Basah (*Wet Process*)

Proses basah diawali dengan penyiapan *raw material* untuk pembuatan semen dengan menggunakan *crusher*. Dalam proses tersebut *raw material* dihancurkan untuk mendapatkan ukuran yang lebih kecil. Kemudian setiap bahan baku disimpan dalam tempat yang terpisah (*bin material*). Tahap selanjutnya adalah proses penggilingan disertai dengan penambahan air ke *wash mill*, dalam tahap ini membentuk produk jadi berupa *slurry* yang mengandung air 25 – 40 %.

Slurry kemudian diaduk untuk membentuk campuran yang bersifat homogen. *Slurry* yang telah homogen kemudian masuk kedalam tahap pembakaran dengan menggunakan mesin *long rotary kiln*. Dalam tahap tersebut menghasilkan produk *clinker*, yang mana *clinker* kemudian didinginkan dalam *cooler*. Tahap terakhir dalam proses basah adalah penggilingan *clinker* dengan *gypsum* yang telah digiling dengan menggunakan *ball mill*. Dari proses tersebut dihasilkan semen dalam bentuk bubuk untuk siap dikemas (Salah, 2010).

b. Proses Kering (*Dry Process*)

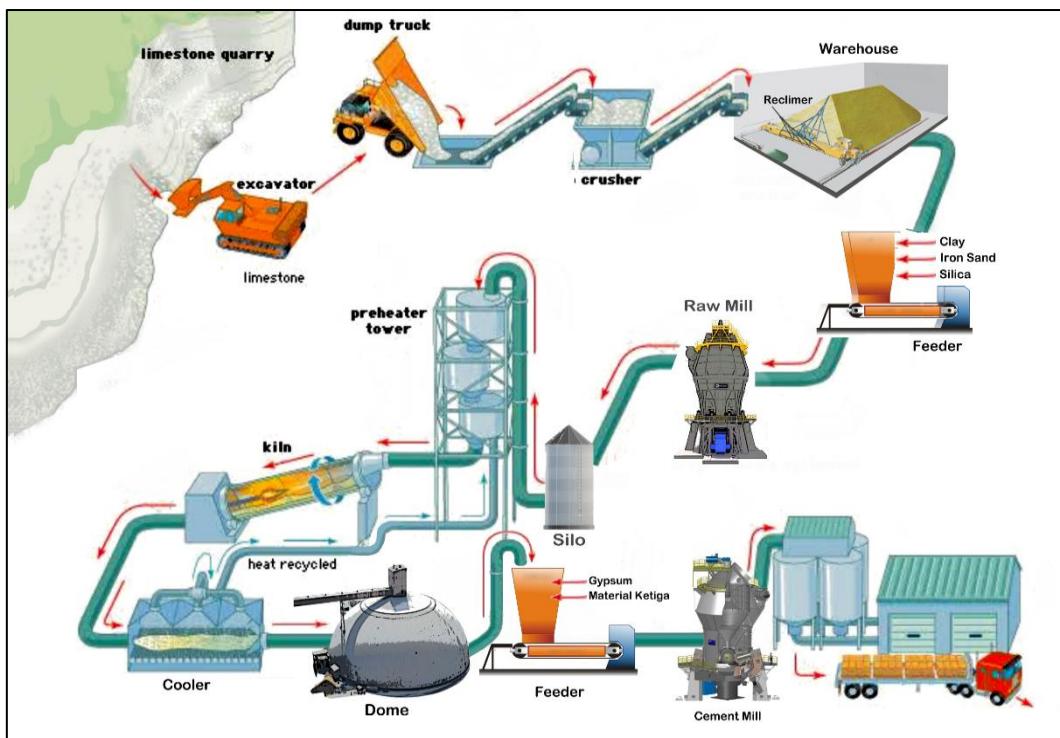
Tahap persiapan *raw material* dalam pembuatan semen melalui proses kering sama dengan proses basah, yaitu dilakukan penghancuran material untuk memperoleh ukuran *raw material* yang lebih kecil. Dalam proses kering, proses

pencampuran *raw material* dilakukan dalam kondisi kering, tanpa penambahan air seperti pada proses basah. Proses pencampuran dilakukan dengan menggunakan mesin *mill* untuk menghasilkan produk bernama *raw meal*.

Campuran *meal / raw meal* kemudian diayak dan dimasukkan ke piring berputar yang disebut sebagai *granulator*. Dalam proses tersebut, butiran keras yang berdiameter sekitar 15mm terbentuk. Butiran hasil proses tersebut kemudian masuk dalam proses *pre-heating* dengan mengalirkan gas panas dari *kiln*. Butiran kemudian masuk kedalam *kiln* untuk diproses dan akan menghasilkan produk berupa *clinker*. Tahap terakhir sama dengan proses basah, yaitu pencampuran *clinker* dengan *gypsum* halus dengan menggunakan *ball mill* (Salah, 2010).

2.1.2 Proses Produksi Semen PT ABC

Berdasarkan hasil wawancara dengan pihak perusahaan, proses produksi semen pada PT ABC dilakukan sesuai dengan Gambar 2.1 melalui proses kering.



Gambar 2. 1 Proses Produksi Semen Pada PT ABC

Gambar 2.1 menunjukkan bahwa terdapat enam tahap utama dalam proses produksi semen yaitu, *Quarry*, *crusher*, gudang, *raw mill*, *kiln*, dan *cement mill*.

a. *Quarry*

Merupakan proses penambangan batu kapur dimana merupakan bahan utama dari proses pembuatan semen. Proses penambangan dilakukan dengan peledakan. Dimana hasil proses ini kemudian dibawa oleh *truck* menuju kepada proses *crusher*.

b. *Crusher*

Merupakan proses penghancuran batu kapur menjadi ukuran yang lebih kecil. Kurang lebih ukuran batu kapur sebesar 8 cm. Selanjutnya batu kapur akan disimpan dalam gudang

c. Gudang

Dalam gudang terdapat proses pre-homogenisasi pada batu kapur dengan menggunakan *reclaimer*. Pre-homogenisasi sangat penting untuk menjamin kualitas batu kapur sebelum diproses. Kemudian batu kapur dan material lain ditimbang pada *feeder* sebelum masuk kedalam proses selanjutnya, untuk diperoleh hasil yang sesuai dengan standar.

d. *Raw mill*

Pada bagian ini, seluruh bahan baku dalam pembuatan semen akan digiling dan dicampur dengan mesin *raw mill*. Dimana hasil dari proses ini berupa butiran halus yang disebut dengan *raw meal*. Kemudian *raw meal* akan disimpan pada *silo* (*raw meal*) untuk menuju proses selanjutnya.

e. *Kiln*

Pada bagian ini, *raw meal* hasil produksi tahap sebelumnya akan dijadikan umpan di dalam *kiln* dan dibakar dengan suhu 2000°C. Selanjutnya dilakukan proses *quenching*, pendinginan dengan cepat yang dilakukan pada *cooler*, untuk kemudian menjadi produk bernama *clinker*. *Clinker* kemudian disimpan pada *Dome*.

f. *Cement mill*

Proses ini dilakukan dengan menggiling dan mencampur batu kapur, *clinker*, *gypsum*, dan *trash* dengan komposisi tertentu dengan mesin *cement mill*.

Hasil dari proses ini adalah semen yang siap untuk dikemas. Semen tersebut kemudian disimpan dalam *silo (cement)*.

2.2 Mesin *Raw Mill*

Pada subab ini dijelaskan mengenai definisi dan bagian mesin *raw mill* serta regulasi kegagalan mesin *raw mill*.

2.2.1 Definisi Mesin *Raw Mill*

Mesin *Raw mill* merupakan mesin yang digunakan untuk mencampur, menggiling dan mengeringkan bahan baku utama yang digunakan dalam proses produksi semen (Taufik, et al., 2017). Secara umum, pada proses penggilingan dan pencampuran oleh mesin *raw mill*, setiap material akan dikecilkan ukurannya dari ukuran 5 – 7 cm hingga menjadi partikel debu dengan ukuran 0 – 9 mikron. Kelembaban dari material juga dikurangi dengan cara dikeringkan (Setiyana, 2007). Mesin *raw mill* pada PT ABC beroperasi terus menerus selama 24 jam. Menurut pernyataan pihak perusahaan, mesin *raw mill* sendiri terbagi menjadi tujuh bagian sebagai berikut.

a. Bagian *Transport Raw Material*

Bagian ini dimulai dari area gudang hingga *bin material* pada area *feeder*. Setelah dilakukan proses pre-homogenisasi di dalam gudang. Material kemudian dikirim dengan *belt conveyor* menuju *bin material*. Setiap *bin* memiliki sensor untuk mendekripsi isi dari *bin*.

b. Bagian *Feeder*

Feeder atau pengumpulan, berfungsi untuk menimbang setiap bahan baku sebelum masuk kedalam area *mill*. Pada area ini terdapat empat jenis *feeder* yaitu, *feeder batu kapur*, *feeder clay/tanah liat*, *feeder pasir besi* dan *feeder silica*. Proses ini penting untuk menjamin komposisi semen tetap sesuai dengan standar.

c. Bagian *Mill*

Dalam bagian *mill* sendiri terdapat empat macam proses yaitu, *grinding*, *drying*, *classifying*, dan *transporting*.

- *Grinding*, merupakan proses penggilingan dari ukuran sekitar 7,5 cm menjadi 90 mikro meter. Proses ini menggunakan gaya sentrifugal

untuk melemparkan material ke arah samping, dimana material akan tergerus oleh *roller* yang berputar karena putaran meja (*table*)

- *Drying*, merupakan proses pengeringan material hasil penggilingan dengan suhu 300°C - 400°C. Proses ini memanfaatkan panas sisa *preheater kiln*.
- *Classifying*, merupakan proses pemisahan antara material yang sudah sesuai standar (halus) dengan material yang belum sesuai standar. Material yang sudah sesuai standar akan lolos melalui *separator*, yang belum akan terangkat naik dan jatuh kembali ke *table* untuk digiling.
- *Transporting*, Gas panas dalam bagian *mill* berfungsi sebagai media transportasi disamping sebagai pengering menuju proses berikutnya.

d. *Mill Fan*

Bgaian yang melakukan pengaturan aliran udara di dalam *mill*. Alat utama yang digunkan dalam proses ini berupa motor untuk menciptakan aliran udara.

e. *Separator*

Merupakan bagian yang berfungsi untuk melakukan pemisahan antara material produk dengan material yang perlu untuk diolah kembali.

f. *Transport product*

Merupakan bagian yang berfungsi untuk menyalurkan produk hasil keluaran *separator* dengan menggunakan air slide menuju *silo (raw meal)*.

g. *Dedusting*

Merupakan bagian yang berfungsi untuk mengolah kembali material buang yang berasal dari *electrostatic precipitator (EP)* menjadi material produk.

2.2.2 Regulasi Kegagalan Mesin *Raw Mill*

Berdasarkan hasil wawancara dengan pihak perusahaan, Tabel 2.1 menunjukkan *threshold* tujuh *equipment* kritis pada mesin *raw mill* dikatakan mengalami kegagalan. Kegagalan setiap *equipment* diidentifikasi melalui hasil *monitoring* sensor.

Tabel 2. 1 *Threshold* Setiap Sensor pada *Equipment*

<i>Equipment</i>	<i>Sensor</i>	<i>Threshold</i>
<i>Motor belt conveyor (MBC)</i>	<i>RPM sensor</i>	< 33%
<i>Sealing air fan (SAF)</i>	<i>Pressure sensor</i>	<9 millibar
<i>Hydraulic system (HS)</i>	<i>Hydraulic sensor</i>	<i>Indicate 2</i>
<i>Motor bucket elevator (MBE)</i>	<i>RPM sensor</i>	< 33%
<i>Rotary feeder (RF)</i>	<i>RPM sensor</i>	< 33%
Getaran bagian <i>mill</i> secara keseluruhan (VIB)	<i>Vibration sensor</i>	>5 mm/s
<i>Bin material</i> (batu kapur) (BI1)	<i>Bin sensor</i>	<i>Indicate 2</i>
<i>Bin material</i> (tanah liat) (BI2)	<i>Bin sensor</i>	<i>Indicate 2</i>

Khusus untuk sensor vibrasi digunakan untuk memantau kondisi seluruh *equipment* pada bagian *mill*, sehingga kondisi *equipment* MBC, SAF, HS, MBE dan RF juga dipantau oleh sensor vibrasi.

Sedangkan keseluruhan mesin *raw mill* dikatakan mengalami kegagalan ketika beberapa *equipment* di atas mengalami kegagalan. Tabel 2.2 menunjukkan regulasi mesin *raw mill* dikatakan bekerja berdasarkan hasil *monitoring* delapan sensor di atas. Selain kondisi pada Tabel 2.2 mesin *raw mill* dikatakan mengalami kegagalan.

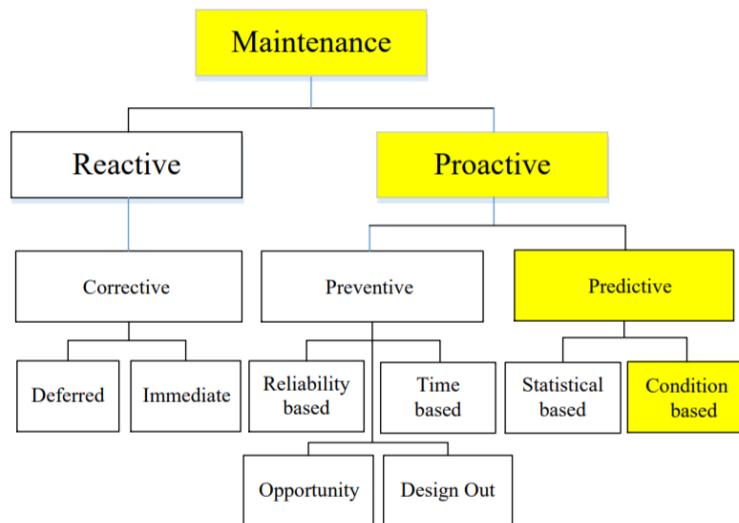
Tabel 2. 2 Regulasi Mesin *Raw Mill* dikatakan Bekerja

No	MBC	SAF	HS	MBE	RF	BI1	BI2	VIB
1	1	1	1	0	1	0	0	0
2	1	1	1	0	1	0	0	1
3	1	1	1	0	1	0	1	0
4	1	1	1	0	1	0	1	1
5	1	1	1	0	1	1	0	0
6	1	1	1	0	1	1	0	1
7	1	1	1	0	1	1	1	0
8	1	1	1	0	1	1	1	1
9	1	1	1	1	1	0	0	0
10	1	1	1	1	1	0	0	1
11	1	1	1	1	1	0	1	0
12	1	1	1	1	1	0	1	1
13	1	1	1	1	1	1	0	0
14	1	1	1	1	1	1	0	1
15	1	1	1	1	1	1	1	0
16	1	1	1	1	1	1	1	1

Keterangan: 1 (*equipment* bekerja), 0 (*equipment* gagal)

2.3 Condition Based Maintenance

Menurut Wang, et al. (2016), strategi *maintenance* dapat dibedakan menjadi dua tipe yaitu *reactive maintenance* dan *proactive maintenance*. Klasifikasi mengenai kedua jenis *maintenance* dapat dilihat pada Gambar 2.3.



Gambar 2. 2 Klasifikasi Strategi *Maintenance*
sumber: (Wang, et al., 2016)

Gambar 2.3 menunjukkan bahwa *condition-based maintenance* termasuk kedalam kategori *proactive maintenance* yaitu pada sub bagian *predictive maintenance*. Artinya *condition-based maintenance* adalah strategi *maintenance* dimana dilakukan pada waktu yang tepat, dan hanya dilakukan ketika diperlukan berdasarkan pada deteksi kondisi peralatan secara aktual (Wang, et al., 2016).

Menurut Fu C, Ye L et al. (2004), *Condition based maintenance* (CBM) merupakan suatu strategi *maintenance* dimana fokus pada prediksi proses degradasi suatu produk yang didasarkan bahwa sebagian besar abnormalitas pada produk tidak terjadi secara instan, dan biasanya terdapat beberapa jenis proses degradasi dari keadaan normal hingga menjadi abnormal. CBM memberikan rekomendasi keputusan untuk dilakukan perawatan berdasarkan pada informasi atau data hasil pengukuran dari suatu *plant* / peralatan. Menurut Jardin et al (2006), terdapat tiga tahap dalam proses CBM sesuai pada Gambar 2.4.



Gambar 2. 3 Proses *Condition Based Maintenance* (CBM)

Sumber: (Jardine, et al., 2006)

a. Pengambilan Data

Tahap ini merupakan tahap paling dasar dalam penyusunan dan pelaksanaan strategi CBM terkait dengan proses diagnosis dan prognosis kegagalan alat. Dalam proses ini dilakukan pengambilan data serta informasi yang diperlukan untuk menyusun strategi CBM yang diinginkan. Berkaitan dengan data yang dikumpulkan, terdapat dua jenis data utama yaitu data kejadian dan data pengukuran kondisi. Data kejadian dapat berupa data suatu kejadian (kerusakan, pemeriksaan dll) dan data tindakan yang dilakukan (perbaikan, penggantian komponen, dll). Sedangkan data pengukuran kondisi adalah berupa data hasil deteksi beberapa sensor pada suatu peralatan (data temperatur, data vibrasi dll).

b. Pemrosesan Data

Dalam tahap ini, dibagi menjadi dua sub bagian yaitu proses pembersihan data (*data cleaning*) dan analisis data. *Data cleaning* bisa meliputi pengisian *missing value*, menghaluskan *noisy data*, mengidentifikasi atau menghilangkan data *outlier* dan menghilangkan inkonsistensi (Santosa & Umam, 2018). Data *error* pada pengukuran kondisi dapat disebabkan karena kesalahan sensor. Menurut R. Xu (2003), pemisahan kesalahan sensor merupakan cara terbaik yang dapat dilakukan.

Untuk analisis data, terdapat banyak model algoritma yang dapat digunakan untuk menganalisis data dalam rangka penafsiran data yang lebih baik. Model algoritma yang digunakan harus disesuaikan dengan tipe data yang dikumpulkan untuk mendapatkan hasil yang *optimal*.

c. Pembuatan Keputusan Perawatan

Teknik pengambilan keputusan perawatan dalam CBM dapat digolongkan dalam dua kategori, yaitu prognosis dan diagnosis. Prognosis adalah proses yang dilakukan ketika suatu kegagalan belum terjadi. Dalam hal ini prognosis melakukan

peramalan kegagalan untuk memutuskan kegagalan yang akan terjadi. Sedangkan proses diagnosis adalah kegiatan analisis berikutnya setelah proses prognosis. Diagnosis merupakan proses pendekripsi, pengisolasian, dan pengidentifikasi setelah suatu kegagalan terjadi (Jardine, et al., 2006).

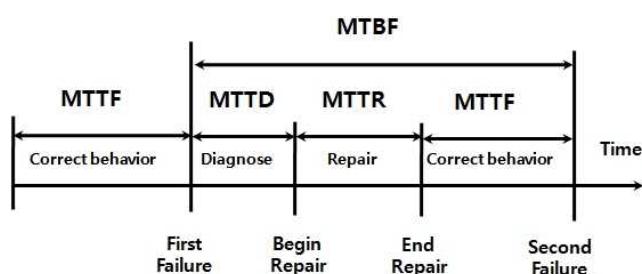
Selain itu menurut Jardine et al. (2006), penelitian mengenai prognosis dibagi dalam tiga area yaitu *remaining useful life* (RUL), penentuan kebijakan pemeliharaan dan pemantauan kondisi. *Residual life modelling* dengan menggunakan *stochastic filtering* merupakan teknik pemodelan yang relevan untuk diterapkan dalam strategi *condition-based maintenance* (Wang W, 2000). Menurut Ghodrati (2012), penyebutan RUL dapat digantikan dengan MRL (*Mean Residual Life*). Informasi prognosis adalah kunci utama dalam pemodelan aspek pengambilan keputusan dalam penyusunan CBM (A.T. de Almeida et al., 2015).

2.4 Konsep Statistik *Reliability*

Berikut merupakan beberapa konsep *reliability* yang digunakan dalam penelitian ini. Meliputi definisi TTF (*Time to Failure*) dan TTR (*Time to Repair*), *reliability* dan MRL (*Mean Residual Life*).

A. TTF (*Time to Failure*) dan TTR (*Time to Repair*)

Gambar 2.5 menunjukkan hubungan antara MTTF, MTTR dan MTBF. Dalam hal ini MTTF dan MTTR kemudian bisa dikatakan sebagai TTF dan TTR karena maksud keduanya sama namun untuk MTTR dan MTTF adalah berupa nilai rata-rata. Perhitungan TTF dilakukan dengan menghitung selisih waktu antara mesin/*equipment* mulai dapat beroperasi secara normal hingga mesin mengalami kegagalan. Sedangkan perhitungan TTR dilakukan dengan menghitung selisih waktu antara mesin mengalami kegagalan hingga mesin dapat beroperasi normal.



Gambar 2.4 Diagram MTTF, MTTR dan MTBF
Sumber: (Seong-woo, 2020)

B. *Reliability*

Reliability atau biasa disebut dengan $R(t)$ adalah probailitas mesin/peralatan dapat beroperasi dari awal mulai beroperasi hingga waktu ke- t . Untuk perhitungan nilai $R(t)$ berbeda beda tergantung pada distribusi kegagalan untuk setiap peralatan. Berikut merupakan beberapa rumus perhitungan $R(t)$ untuk masing-masing distribusi (Elsayed, 2012) dan (Teimouri & Gupta, 2013).

$$\text{Distribusi Exponensial} \quad : R(t) = e^{-\lambda t} \quad (2.1)$$

$$\text{Distribusi Weibull 2 parameter} \quad : R(t) = \exp \left[-\left(\frac{t}{\alpha} \right)^{\beta} \right] \quad (2.2)$$

$$\text{Distribusi Weibull 3 parameter} \quad : R(t) = \exp \left[-\left(\frac{t-\gamma}{\alpha} \right)^{\beta} \right] \quad (2.3)$$

$$\text{Distribusi Normal} \quad : R(t) = 1 - \varphi \left(\frac{t-\mu}{\sigma} \right) \quad (2.3)$$

$$\text{Distribusi Lognormal} \quad : R(t) = 1 - \varphi \left(\frac{\ln(t-t_0)-\mu}{\sigma} \right) \quad (2.4)$$

Dimana nilai setiap parameter yang dimasukkan kedalam rumus adalah hasil kalkulasi *fitting* distribusi dengan menggunakan *software Weibull*.

C. *MRL (Mean Residual Life)*

Menurut Elsayed (2012), MRL adalah perkiraan umur sisa suatu komponen, produk atau sistem pada titik waktu tertentu ketika dinyatakan beroperasi (tidak mengalami kegagalan). Untuk pemodelan MRL dapat digunakan rumus sebagai berikut.

$$MRL(t) = \frac{1}{R(t)} \int_t^{\infty} R(x) dx \quad (2.5)$$

2.5 *Data mining*

Dalam subbab ini dipaparkan mengenai definisi dan proses penerapan *data mining*.

2.5.1 *Definisi Data Mining*

Data mining dapat diartikan sebagai kegiatan mengekstrak informasi atau pengetahuan penting dari set data besar dengan menggunakan teknik tertentu

dengan tujuan untuk memperbaiki pengambilan keputusan (Santosa & Umam, 2018). Selain itu menurut Kursini & Taufiq (2009), tujuan dari *data mining* adalah mendapatkan hubungan pola yang mungkin memberikan indikasi yang bermanfaat.

Penggunaan *data mining* sendiri sangat luas, menurut santosa & umam (2018), terdapat empat macam studi yang dapat dilakukan oleh *data mining* yaitu, *clustering*, klasifikasi, regresi/estimasi, dan asosiasi.

a. *Clustering*

Clustering merupakan metode pengelompokan objek / data menjadi beberapa kelompok berdasarkan pada kemiripan antar objek. Dalam proses *clustering*, tidak ada kelompok tertentu sebelum pemrosesan data, melainkan dari data tersebut terbentuk kelompok kelompok baru. Dalam *clustering* tidak memerlukan *data training*.

b. *Klasifikasi*

Klasifikasi merupakan proses pengelompokan objek berdasarkan kelompok yang sudah ada. Pada proses klasifikasi diperlukan proses *data training*. Prediksi pengelompokan dilakukan dengan pembuatan model terlebih dahulu melalui proses *data training* berdasarkan data yang diperoleh. Kemudian dilakukan pengelompokan menggunakan model tersebut.

c. *Regresi / Estimasi*

Regresi berfungsi untuk mencari model hubungan antara atribut *predictor* dan atribut dependen, dimana kedua atribut tersebut berupa nilai kontinyu. Pada regresi membutuhkan *data training* terlebih dahulu sebelum diproses selanjutnya. Hasil yang diperoleh dari regresi berupa nilai kontinyu berbeda dengan klasifikasi yang berupa nilai diskrit.

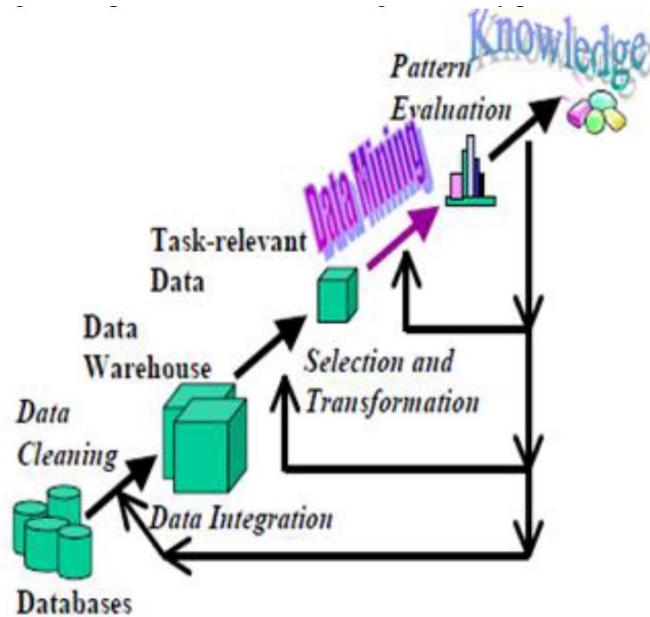
d. *Asosiasi*

Asosiasi biasanya dilakukan dengan menghitung beberapa kali dalam suatu set data transaksi yang mengandung dua item atau lebih yang berhubungan. Memang asisosiasi sering kali digunakan dalam data transaksional.

2.5.2 Proses *Data Mining*

Menurut Sahu 2010, *data mining* sering juga disebut dengan KDD (*Knowledge Discovery in Database*). Secara umum proses dari *data mining* terbagi

menjadi tujuh tahap utama, yaitu *data integration*, *data cleaning*, *data selection*, *data transformation*, *data mining*, *pattern evaluation* dan *knowledge representation* (Sahu, et al., 2010). Detail proses *data mining* dijelaskan pada Gambar 2.6 sebagai berikut.



Gambar 2.5 Proses *Data mining*
Sumber: (Sahu, et al., 2010)

2.5.2.1 *Data Integration*

Pada tahap ini dilakukan penggabungan atau pengumpulan data-data dari beberapa sumber data. Data dapat berasal dari sistem pemrosesan transaksi yang ada, juga dapat diperoleh dari data *warehouse*.

2.5.2.2 *Data Cleaning*

Data cleaning dapat meliputi pengisian *missing value* (data yang kosong), menghaluskan *noisy data*, mengidentifikasi atau menghilangkan *outlier* dan menghilangkan inkonsistensi (Santosa & Umam, 2018). Berikut merupakan beberapa problem yang perlu dilakukan proses *data cleaning*.

1. *Missing Data*

Sering terjadi dalam suatu kumpulan data terdapat beberapa varibel atau atribut yang tidak bernilai. Hal ini bisa terjadi karena peralatan yang digunakan

tidak bekerja dengan benar, penghapusan data, terjadi kesalahpahaman, dan penghapusan data tidak penting.

2. Tidak Lengkap

Data yang diperoleh tidak lengkap, sehingga data tersebut tidak dapat digunakan secara langsung.

3. Format tidak seragam

Terjadi penyusunan bentuk data yang tidak seragam dikarenakan data diambil dari berbagai sumber yang berbeda.

4. Kesalahan Penulisan (*Typo*)

5. Data *Outlier*

Data *outlier* adalah suatu kejadian atau data yang memiliki karakteristik atau memiliki nilai yang sangat berbeda jauh dengan kelompok lainnya atau hasil observasi, nilai tersebut muncul sebagai nilai ekstrim, baik untuk sebuah variabel tunggal maupun kombinasi (Ghozali, 2011). Deteksi data *outlier* dapat dilakukan dengan menentukan nilai batas yang akan dikategorikan sebagai data *outlier* dengan melakukan konversi nilai data ke dalam nilai *standardized score* yang kemudian disebut dengan *z-score* (Ghozali, 2011). Proses konversi nilai dilakukan dengan rumus sebagai berikut (Santosa & Umam, 2018).

$$\hat{Z} = \frac{X - \bar{X}}{\sigma_x} \quad (2.6)$$

Dengan Z adalah nilai *z-score* yang dicari, X adalah data yang dihitung, \bar{X} adalah rata-rata data set yang dihitung, dan σ_x adalah standar deviasi data set. Kemudian setiap nilai *z-score* diabsolutkan untuk menghilangkan nilai negatif. Menurut Ghozali (2011), untuk sampel kecil (< 80 data) standar skor adalah $\geq 2,5$ dinyatakan *outlier*, penentuan standar skor bergantung pada batasan dan ketentuan penelitian.

2.5.2.3 *Data Selection*

Pada tahap ini dilakukan seleksi mengenai data-data yang kurang relevan dengan kasus yang diangkat dengan menghilangkan beberapa variabel atau data yang tidak berhubungan dengan analisis yang dilakukan.

2.5.2.4 Data Transformation

Dapat juga disebut sebagai *data consolidation*, tahap ini merupakan tahap dimana data tertentu ditransformasi menjadi bentuk yang lebih sesuai untuk prosedur *data mining*. Menurut Santosa & Umam (2018), terdapat beberapa cara untuk melakukan *data transformation*, yaitu *centering*, *normalization*, dan *scaling*. Hal ini ditujukan agar data tidak memiliki kecenderungan pada satu atribut.

Transformasi data dilakukan ketika adanya perbedaan *range* antar atribut data yang digunakan sebagai *input* dalam pembuatan model. Maka dari itu nilai tersebut perlu untuk disetarakan. Terdapat tiga cara untuk melakukan transformasi data, yaitu *centering*, standarisasi dan *scaling* (Santosa & Umam, 2018).

1. Centering

Secara teknis centering dilakukan dengan melakukan pengurangan pada setiap data dengan nilai rata-rata dari satu set atribut yang bersangkutan. Untuk hal tersebut dapat dilakukan dengan menggunakan rumus berikut.

$$\hat{X} = X - \bar{X} \quad (2.7)$$

\hat{X} adalah vector hasil centering, X adalah vektor kolom asli dan \bar{X} adalah rata-rata dari kolom terkait. Kemudian dapat dilakukan beberapa operasi untuk mendapatkan besaran baru. Seperti matriks *scatter* atau matriks kovarian (Santosa & Umam, 2018).

2. Standarisasi (Normalisasi *z-score*)

Normalisasi data adalah proses konversi data asli ke dalam nilai *standardized score* atau *z-score*. Langkah ini digunakan untuk menyetarakan nilai seluruh atribut berdasarkan pada *z-score*. Normalisasi dilakukan dengan menggunakan rumus berikut.

$$\hat{X} = \frac{X - \bar{X}}{\sigma_x} \quad (2.8)$$

Setelah dilakukan normalisasi, maka nilai data akan memiliki rata-rata = 0 dan varian = 1 (Santosa & Umam, 2018).

3. Scaling

Scaling adalah tahap untuk melakukan konversi nilai data, sehingga data berada dalam skala tertentu. Skala dapat berada pada *range* [0,1], [-1,1] atau skala lain sesuai dengan data yang digunakan (Santosa & Umam, 2018). Untuk melakukan scaling dapat dilakukan operasi dengan menggunakan rumus sebagai berikut.

$$\hat{X} = \frac{X - X_{min}}{X_{max} - X_{min}} * (BA - BB) + BB \quad (2.9)$$

Dimana keterangan dari masing masing symbol adalah sebagai berikut:

\hat{X} = Nilai hasil *scaling*

X = Data asli

X_{min} = Nilai minimal dalam *set data*

X_{max} = Nilai maksimal dalam *set data*

BA = Batas atas nilai hasil *scaling*

BB = Batas bawah nilai hasil *scaling*

2.5.2.5 Data Mining

Tahap ini merupakan tahap krusial dimana suatu metode atau model digunakan untuk mengekstrak pola yang berpotensi berguna. Metode atau model *data mining* yang digunakan sangat beragam jenisnya. Penggunaan metode *data mining* yang relevan disesuaikan dengan jenis data. Dalam penelitian ini digunakan model SVR (*Support Vector Regression*) dan ANN (*Artificial Neural Network*).

2.5.2.6 Pattern Evaluation

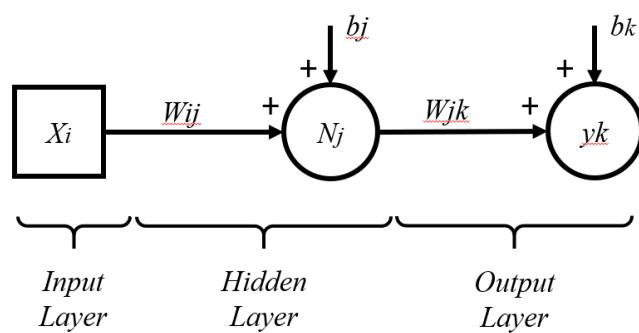
Pada tahap ini dilakukan identifikasi dan analisis mengenai pola yang diperoleh dengan menggunakan metode *data mining*. Menurut Santosa & Umam (2018), terdapat beberapa ukuran performansi untuk menilai performa model. Hal tersebut disesuaikan dengan model yang dibuat (regresi/klasifikasi/*clustering*).

2.5.2.7 Knowledge Representation

Merupakan tahap akhir dimana pengetahuan yang ditemukan atau model yang dibentuk dapat divisualisasikan kepada pengguna. Hal ini penting digunakan untuk membantu pengguna dalam memahami dan menafsirkan hasil penambangan data yang dilakukan.

2.6 Artificial Neural Network (ANN)

Artificial Neural Network merupakan suatu model *data mining* yang berbentuk seperti jaringan saraf makhluk hidup. Dimana jaringan tersebut terdiri dari *neuron* yang saling terhubung. Setiap *neuron* akan menerima *input* dari *neuron* yang lain. Dalam ANN diperlukan *data training* berlabel untuk melatih model agar dapat mengenali data-data baru untuk menciptakan *output* yang sama dengan *data training* (Santosa & Umam, 2018). *Artificial neural network* secara umum dapat digunakan untuk menyelesaikan beberapa tugas berikut: asosiasi, klasifikasi, *clustering*, *pattern recognition*, *image processing*, optimasi dan *modelling* (Krenek, et al., 2016). Dalam ANN terdapat tiga macam *layer* dasar, yaitu *input layer*, *hidden layer*, dan *output layer*. Dalam hal ini *hidden layer* dapat berjumlah satu atau lebih, umumnya dapat mencapai tiga *layer*, hal tersebut bergantung pada kompleksitas model dalam melakukan penyelesaian masalah (Krenek, et al., 2016).



Gambar 2. 6 Contoh Network Pada Artificial Neural Network (ANN)
Sumber: (Santosa & Umam, 2018)

Berdasarkan Gambar 2.7 perhitungan untuk *output* (y) secara umum pada model ANN dapat dilakukan dengan menggunakan langkah perhitungan sebagai

berikut. Pertama dilakukan perhitungan nilai untuk setiap *neuron* pada *hidden layer* dengan rumus berikut.

$$Nj = \left(\sum_{i=1}^n Wij \times Xi \right) + bj \quad (2.10)$$

Perlu diketahui bahwa jumlah *layer* dan *neuron* pada *hidden layer* dapat lebih dari satu.

Kemudian hasil perhitungan setiap nilai *neuron* pada *hidden layer* digunakan dalam perhitungan *output* (*y*) dengan menggunakan rumus sebagai berikut.

$$y = \left(\sum_{j=1}^n Wjk \times Nj \right) + bk \quad (2.11)$$

Dimana keterangan dari setiap simbol adalah sebagai berikut *X* = Variabel *input*, *N* = *Neuron*, *y* = *output*, *W* = *Weight* (bobot atau parameter pembelajaran), dan *b* = bias.

Dalam penelitian ini menggunakan algoritma RPROP untuk melakukan kalkulasi penentuan nilai parameter optimal. RPROP dalam hal ini adalah *resilience propagation* (Riedmiller & Braun, 1993). Dalam penelitian oleh Riedmiller & Braun (1993). Menunjukkan bahwa penggunaan algoritma RPROP mampu memberikan proses kalkulasi yang lebih cepat dibandingkan dengan algoritma *back propagation* tradisional. Ditunjukkan dengan hasil bahwa dengan menggunakan algoritma RPROP membutuhkan jumlah *epochs* yang lebih sedikit dibandingkan dengan *back propagation* tradisional. Berdasarkan hal tersebut maka algoritma RPROP dipilih dalam penyusunan model ANN dalam penelitian ini.

Untuk penyelesaian kasus secara nonlinear, fungsi aktivasi dapat diterapkan pada model ANN. Berikut merupakan beberapa fungsi aktivasi yang dapat dipakai pada model ANN (Santosa & Umam, 2018):

1. Fungsi *Sigmoid* atau *Logistic*

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (2.12)$$

2. Fungsi *Tanh* (tangen hiperbolik)

$$\varphi(v) = \frac{2}{1 + e^{-2v}} - 1 \quad (2.13)$$

3. Fungsi ReLu (*Rectified Linear Unit*)

$$\varphi(v) = \begin{cases} v, & v \geq 0 \\ 0, & v < 0 \end{cases} \quad (2.14)$$

Menurut Santosa & Umam (2018), untuk penyelesaian kasus regresi dengan menggunakan ANN, *output layer* atau fungsi objektifnya adalah berupa satu simpul keluaran yang memberikan prediksi nilai regresi berupa nilai kontinyu. Berbeda dengan klasifikasi yang memiliki keluaran berupa nilai diskrit (Santosa & Umam, 2018). Dalam hal ini fungsi objektif yang umumnya digunakan dalam kalkulasi model regresi adalah nilai *squared error*. Dimana *output* akan dilatih untuk mendapatkan nilai objektif yang minimal. Perhitungan nilai *squared error* dapat dilakukan dengan rumus sebagai berikut.

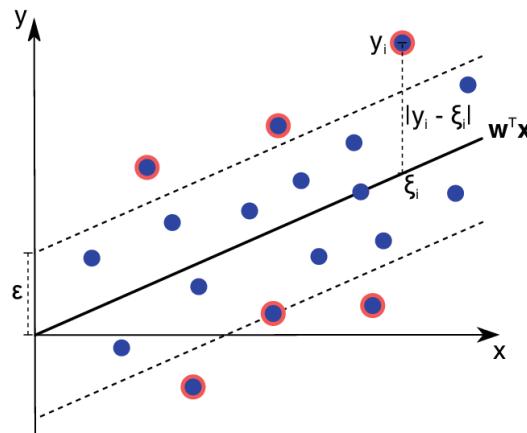
$$\text{Squared error} = (\bar{y} - y)^2 \quad (2.15)$$

Dimana \bar{y} adalah label *ground truth* dan y adalah *output* prediksi. Semakin kecil selisih antara nilai \bar{y} dan y , maka menunjukkan bahwa *output* prediksi semakin dekat dengan label *ground truth*. Dalam perhitungan *error*, adapun varian lain yang sering digunakan yaitu, SSE (*Sum Squared Error*), MSE (*Mean Squared Error*) atau RMSE (*Root Mean Squared Error*). Model regresi yang dibentuk bertujuan untuk menghasilkan nilai prediksi sedekat mungkin dengan *label ground truth* (Santosa & Umam, 2018).

Kelebihan dari model ANN adalah kemampuan model dalam melakukan prediksi dan belajar dari data-data yang kompleks (Shumeli, et al., 2007). Menurut Santosa & Umam (2018), model ANN memiliki toleransi tinggi terhadap data *noise* dan dapat menangkap hubungan yang kompleks antara prediktor dan *output*. Saat ini ANN banyak digunakan dalam pemecahan masalah dalam berbagai kasus. Namun, dalam pembentukannya model ANN memerlukan banyak *data training* untuk dapat menghasilkan model yang baik (Santosa & Umam, 2018).

2.7 Support Vector Regression

Support vector regression adalah pengembangan dari *support vector machine* dalam penyelesaian kasus secara regresi. Dalam kasus regresi, *output* data adalah berupa bilangan riil atau kontinyu (Santosa & Umam, 2018). Dengan menggunakan konsep ϵ -insensitive loss function, SVM bisa digeneralisasi untuk melakukan pendekatan fungsi atau regresi (Scholkopf & Smola, 2002). Selain itu SVR dinilai dapat mengatasi masalah *overfitting* karena didasarkan pada teori *structural risk minimization*, untuk mengestimasi suatu fungsi dengan cara meminimalkan batas atas dari *generalization error*. Tujuan dari SVR ini sendiri adalah menemukan sebuah fungsi $f(x)$ yang mempunyai deviasi paling besar ϵ dari target aktual y_i untuk semua *data training*. Maka dengan SVR akan diperoleh bentuk seperti tabung sebagai berikut (area dalam garis putus-putus).



Gambar 2. 7 Ilustrasi Plot Support Vector Dengan Fungsi $f(x)$
Sumber: (Santosa & Umam, 2018)

Dimana dapat terlihat pada Gambar 2.8 nilai $\pm \epsilon$ atau $D(x_i, y_i)$ adalah jarak terjauh *support vector* dengan *hyperplane*, yang kemudian disebut dengan *margin*. Memaksimalkan nilai *margin* akan meningkatkan probabilitas data ke dalam radius $\pm \epsilon$ (Amanda, et al., 2014). Dalam SVR, *support vector* adalah *data training* yang terletak pada dan diluar batas fungsi keputusan. Besarnya nilai $\pm \epsilon$ menentukan performansi dari model SVR. Jika nilai ϵ rendah maka diharapkan semakin banyak data pada batas tabung (dalam garis putus-putus), sebaliknya nilai ϵ yang tinggi menunjukkan sedikitnya data dalam batas tabung (Maheswari, 2013).

Penentuan *hyperplane* terbaik dilakukan dengan melakukan optimasi dengan mempertimbangkan jarak setiap *support vector* terhadap *hyperplane*. Berikut merupakan formulasi dual, untuk problem optimasi dari SVR (Santosa & Umam, 2018).

Fungsi objektif:

$$\max -\frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m (a_i - a_i^*)(a_i - a_i^*) K(x_i, x_j) - \sum_{i=1}^m y_i (a_i - a_i^*) - \varepsilon \sum_{i=1}^m (a_i - a_i^*) \quad (2.16)$$

Subject to:

$$\begin{aligned} \sum_{i=1}^m (a_i - a_i^*) &= 0 \\ 0 \leq a_i \leq C, i &= 1, 2, \dots, m \\ 0 \leq a_i^* \leq C, i &= 1, 2, \dots, m \end{aligned}$$

Dimana a_i, a_i^* adalah *lagrange non-negative multiplier*. Kemudian dengan menggunakan *lagrange multiplier* dan kondisi optimalitas, fungsi regresi secara eksplisit dirumuskan sebagai berikut.

$$f(x) = \sum_{i=1}^m (a_i - a_i^*) K(x_i, x) + b \quad (2.17)$$

Dimana $K(x_i, x)$ didefinisikan melalui fungsi *kernel K* antara *data training* x_i dan *data testing* x (Santosa & Umam, 2018).

Berikut merupakan kernel yang dapat digunakan dalam penyusunan model SVR: (Fan, et al., 2005)

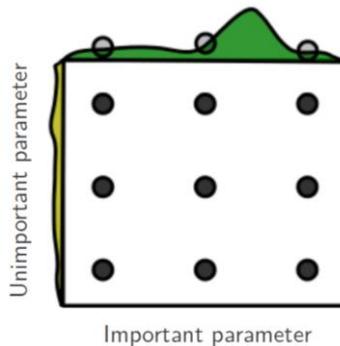
$$\begin{aligned} \text{Kernel Radial basis} &= e^{(-gamma * |xi - x|^2)} \\ \text{Kernel Tangent Hyperbolic} &= \tanh(gamma * xi * x + coef0) \\ \text{Kernel Polynomial} &= (gamma * xi * x + coef0)^{\text{degree}} \\ \text{Kernel Linear} &= xi^T x \end{aligned} \quad (2.18)$$

2.8 Grid Search

Grid search merupakan algoritma optimasi untuk menentukan nilai optimal pada setiap parameter *input* yang digunakan untuk membangun model tertentu. *Grid search* bekerja dengan mencacah nilai dalam batasan *range* tertentu lalu menginputkan segala kombinasi angka yang dimungkinkan untuk mengisi nilai parameter *input* (Natan, et al., 2019). Secara garis besar, *grid search* adalah fungsi *cartesian product* seperti pada contoh persamaan *input* berikut.

$$X_1, X_2 = \{(i, j) | i \in X_1 \text{ dan } j \in X_2\} \quad (2.19)$$

Dimana i anggota dari himpunan X_1 , j anggota dari himpunan X_2 . Sedangkan X_1 dan X_2 adalah parameter *input* untuk model. Gambar 2.9 merupakan contoh ilustrasi *layout* untuk *grid search* dengan menggunakan dua macam parameter *input* dengan total terdapat sembilan macam kombinasi.

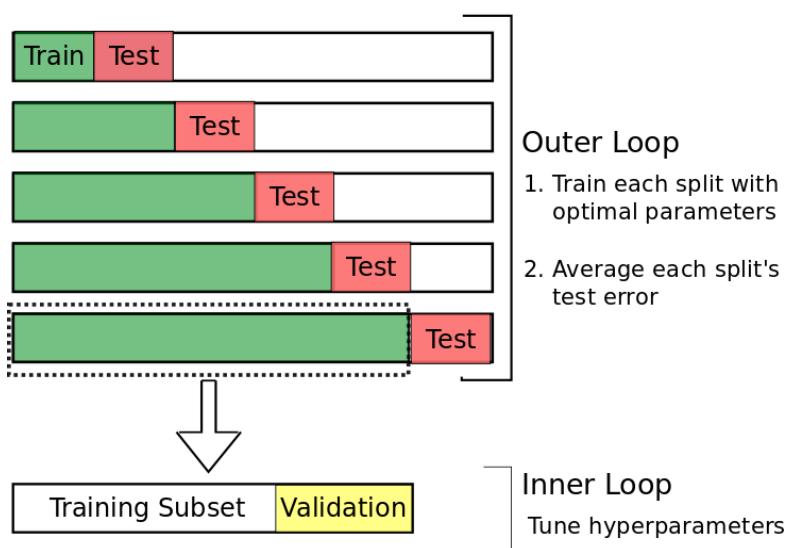


Gambar 2. 8 Ilustrasi *Layout Grid Search* dengan 2 Jenis Parameter *Input*
Sumber: (Bergstra & Bengio, 2012)

2.9 Nested Cross Validation

Nested cross validation merupakan pengembangan dari metode *k-fold cross validation* untuk menangani masalah *time series*. Metode ini digunakan untuk mengetahui rata-rata keberhasilan suatu sistem / model. Menurut Varma & Simon (2006), prosedur *nested cross validation* memberikan *error* yang hampir tidak bias. Terdapat beberapa cara dalam penyelesaian *nested cross validation*. Dalam hal ini akan digunakan penyelesaian secara regular. Dimana satu data set akan dibagi menjadi tiga bagian untuk setiap *fold*-nya, yaitu *data training*, *data validation* dan

data testing. Dimana satu data set akan dibagi menjadi N partisi. Pada iterasi ke-1, dua partisi pertama akan digunakan sebagai *data training*, dan partisi terakhir pada *data training* tersebut akan digunakan sebagai *data validation*. Fungsi dari *data validation* adalah untuk melakukan *parameter tuning*. Kemudian satu partisi berikutnya akan digunakan sebagai *data testing*. Pada iterasi berikutnya *data testing* pada iterasi sebelumnya akan digabungkan dengan *data training* pada iterasi berikutnya (Bergmeir & Benitez, 2012). Proses tersebut dilakukan hingga seluruh partisi telah digunakan. Gambar 2.9 menunjukkan ilustrasi metode *nested cross validation*.



Gambar 2. 9 Ilustrasi *Nested Cross Validation*
Sumber: (Bergmeir & Benitez, 2012)

2.10 Pengukuran Performa Model Regresi

Pengukuran performa model *learning* digunakan untuk mengetahui seberapa bagus model yang telah dibuat parameter pengukuran performansi dapat digunakan sebagai acuan untuk membandingkan model yang dibentuk. Secara teknis, pengukuran performa model untuk *supervised learning* dilakukan dengan membandingkan secara langsung dengan nilai *ground truth label*. Sedangkan untuk model *unsupervised learning* tidak bisa dilakukan dengan cara tersebut. Untuk model regresi, karena termasuk dalam *supervised learning model*, maka

pengukuran performansi dapat dilakukan dengan membandingkan nilai *ground truth label* (Santosa & Umam, 2018).

Pengukuran performansi untuk model regresi dapat mengacu kepada nilai *error* antara prediksi dan *ground truth label*. Secara umum, nilai *error* yang kecil mengindikasikan bahwa model yang terbentuk memiliki performa yang baik. Nilai *error* yang sering dijadikan acuan dalam pengukuran perfoma model adalah sebagai berikut. Dimana Y_i menunjukkan nilai *ground truth label*, \hat{Y}_i menunjukkan nilai prediksinya dan n adalah banyaknya data (Santosa & Umam, 2018).

- a. RMSE (*Root Mean Square*)

Perhitungan RMSE dilakukan dengan rumus sebagai berikut.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (2.20)$$

- b. MSE (*Mean Square Error*)

Perhitungan MSE dapat dilakukan dengan rumus berikut.

$$MSE = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n} \quad (2.21)$$

- c. MAE (*Mean Absolute Error*)

Perhitungan dilakukan dengan menggunakan rumus sebagai berikut.

$$MAE = \frac{\sum_{i=1}^n |Y_i - \hat{Y}_i|}{n} \quad (2.22)$$

- d. STD (Standar Deviasi)

Selain perhitungan mengenai *error* yang telah dipaparkan sebelumnya, perlu juga dilakukan perhitungan mengenai besar sebaran dari nilai *error* tersebut. Pengukuran ini dilakukan untuk menunjukkan seberapa konsisten performa dari model yang telah terbentuk. Nilai STD yang kecil menunjukkan bahwa performa model tersebut konsisten. Dalam melakukan perhitungan STD dapat dilakukan

dengan menggunakan rumus sebagai berikut. Dimana e_i adalah nilai *error* data ke- i sedangkan \bar{e} adalah nilai rata-rata *error*.

$$STD = \sqrt{\frac{\sum_{i=1}^n (e_i - \bar{e})^2}{n}} \quad (2.23)$$

2.11 Critical Review

Penelitian mengenai penggunaan model *data mining* dalam prediksi kegagalan mesin dengan menggunakan *condition-based maintenance* (CBM) atau *predictive maintenance* cukup banyak dilakukan. Penelitian mengenai hal tersebut ditujukan untuk berbagai macam tujuan, mulai dari penentuan jenis kegagalan mesin hingga prediksi waktu kegagalan mesin, dimana umumnya data tersebut akan digunakan sebagai acuan dalam pengambilan keputusan terkait manajemen perawatan perusahaan. Beberapa topik yang diambil dari penelitian terdahulu di antaranya adalah *review* mengenai penggunaan ANN sebagai metode dalam melakukan prediksi kegagalan pada industri otomotif, analisis waktu kegagalan mesin dengan menggunakan metode ANN (*artificial neural network*), prediksi waktu kegagalan mesin dengan metode SVR (*support vector regression*), analisis manajemen perawatan dengan *data mining* melalui klasifikasi kriteria kegagalan mesin pada pabrik semen dan penelitian penentuan waktu pemeliharaan yang tepat dengan menggunakan *preventive maintenance*.

Penelitian dengan judul “*Application of Artificial Neural Networks in Condition Based Predictive Maintenance*” dilakukan dengan tujuan melakukan *review* mengenai penggunaan ANN sebagai metode dalam teknik pemeliharaan dengan melakukan deteksi kegagalan. Hasil menunjukkan bahwa ANN cocok diimplementasikan dalam penyelesaian masalah pada industri khususnya untuk *predictive maintenance*. Selain itu ANN dinilai efektif dalam pencegah kegagalan peralatan dan berpotensi mengingkatkan OEE.

Penelitian dengan judul “*Prediction of Motor Failure Time Using an Artificial Neural Network*” dilakukan dengan tujuan membuktikan bahwa model ANN dapat digunakan dalam penyelesaian masalah regresi, tepatnya adalah

prediksi waktu kegagalan motor industri. Dalam penelitian ini dilakukan pembandingan penggunaan metode dalam pembentukan model prediksi kegagalan yaitu ANN, SVM (*support vector machine*), RT (*random tree*), dan RF (*random forest*). Pemilihan metode terbaik dilakukan dengan pembandingan nilai performansi berdasar pada nilai RMSE dengan model yang telah diregularisasi. Diperoleh bahwa nilai RMSE terbaik adalah pada model ANN.

Pada penelitian oleh Moura et al., dengan judul “*Failure and Reliability Prediction by Support Vector Machines Regression of Time Series Data*” menunjukkan bahwa SVR dilakukan untuk melakukan prediksi data *time to failure* / kegagalan mesin *turbocharger*. Hasil dalam penelitian menunjukkan bahwa SVR memberikan performa yang baik dalam menangani data *time series*.

Penelitian oleh Suyuti et al. (2013) dengan judul “Analisis Manajemen Perawatan Mesin Industri dengan Menggunakan Jaringan Saraf Tiruan *Feed Forward- Back Propagation* (Studi Kasus PT. Semen Bosowa Maros)” menunjukkan bahwa metode *data mining*, tepatnya *artificial neural network* (ANN), dapat digunakan dalam membentuk klasifikasi kegagalan mesin pada industri semen bosowa berdasarkan pada karakteristik kegagalannya. Dimana hal tersebut akan digunakan sebagai acuan dalam penentuan manajemen kegagalan.

Dari beberapa penelitian terdahulu yang telah dijelaskan sebelumnya, maka dari itu penulis melakukan kombinasi dari beberapa penelitian tersebut dengan menerapkan metode ANN (*Artificial Neural Network*) dan SVR (*Support Vector Regression*). Model ANN dan SVR yang digunakan adalah model regresi dimana ditujukan untuk memprediksi waktu kegagalan pada setiap *equipment* mesin *raw mill* pada PT ABC. Table 2.3 menjelaskan mengenai perbandingan dari setiap penelitian / studi yang telah dilakukan dengan rencana penelitian dari penulis.

Tabel 2. 3 Perbandingan Penelitian Terdahulu dengan Penelitian Penulis

Peneliti	Judul	Metode	Objek	Output
Penelitian Terdahulu				
Krenek, et al., 2016	<i>Application of Artificial Neural Networks in Condition Based Predictive Maintenance</i>	ANN (<i>Artificial Neural Network</i>)	<i>Mechanical, electrical, pneumatic, robotic device (Automotive industry)</i>	ANN memiliki potensi kuat dalam pengaplikasian di industri khususnya dalam <i>predictive maintenance</i>
Sampaio, et al., 2019	<i>Prediction of Motor Failure Time Using an Artificial Neural Network</i>	ANN (<i>Artificial Neural Network</i>) serta SVM, RF, dan RT (Regresi)	<i>Motor</i>	Membuat model ANN untuk prediksi kegagalan motor industri. Model ANN memberikan performansi terbaik (RMSE terkecil) dibandingkan SVM, RF dan RT
Moura, et al, 2011	<i>Failure and Reliability Prediction by Support Vector Machines Regression of Time Series Data</i>	SVR (<i>Support Vector Regression</i>) (Regresi)	<i>Turbochargers Diesel Engines</i>	SVM Regression digunakan untuk melakukan <i>forecast</i> data <i>time to failure</i> . SVR menunjukkan performa yang baik dalam menangani data time series.
Suyuti, et al., 2013	Analisis Manajemen Perawatan Mesin Industri	ANN (<i>Artificial Neural Network</i>)	PT. Semen Bosowa Maros	Penentuan karakteristik kerusakan mesin sebagai

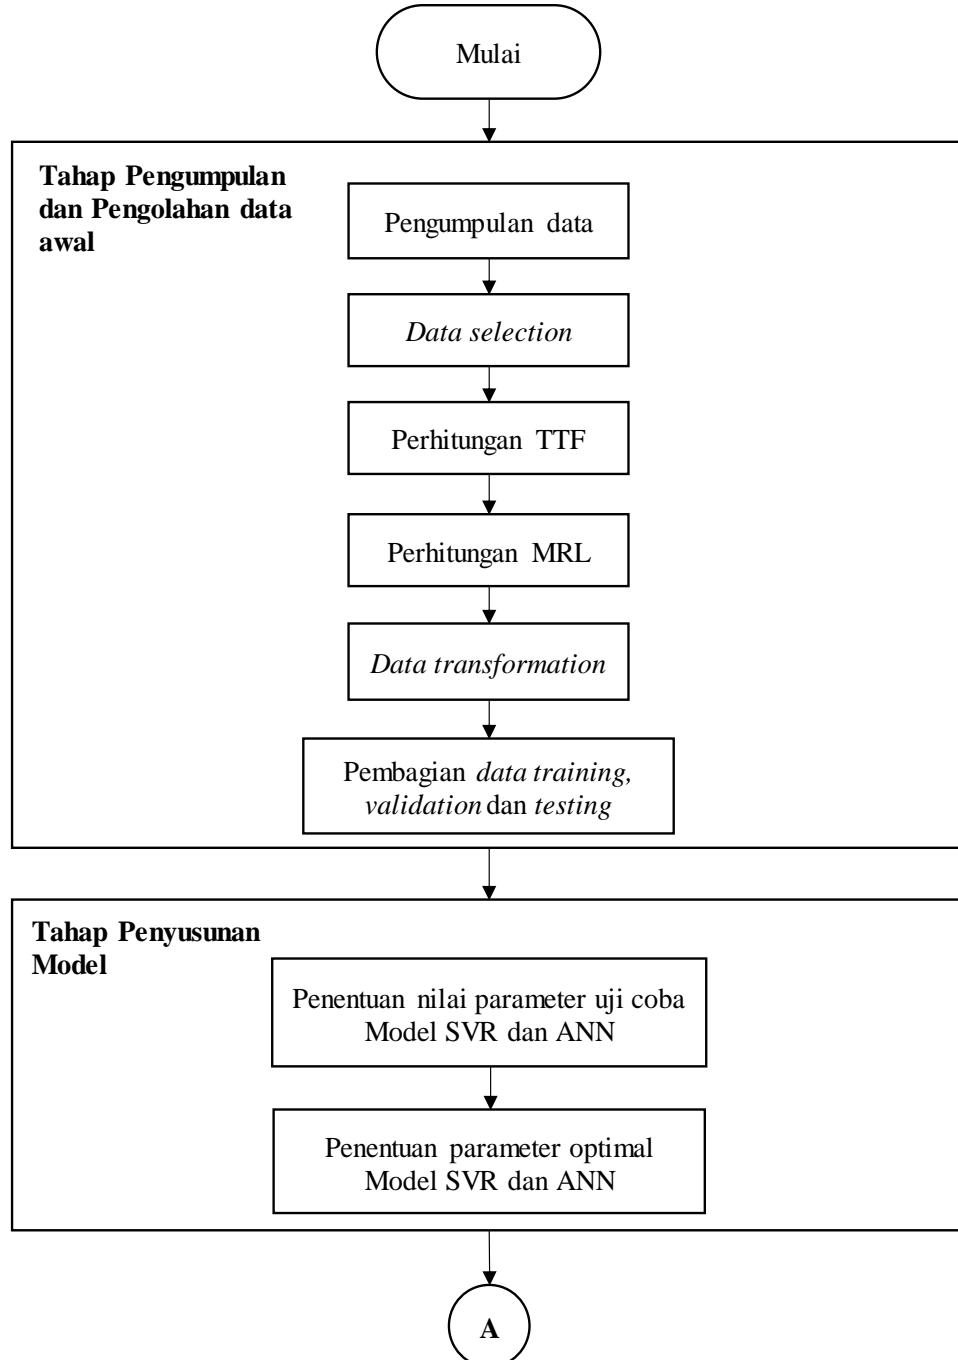
Peneliti	Judul	Metode	Objek	Output
	dengan Menggunakan Jaringan Saraf Tiruan <i>Feed Forward-Back Propagation</i> (Studi Kasus PT. Semen Bosowa Maros)	<i>Feed Forward-Back Propagation</i> (Klasifikasi)		acuan dalam penentuan jenis <i>maintenance</i> yang sesuai
Penelitian Ini				
Penelitian ini	Implementasi <i>Data Mining</i> pada <i>Condition Based Maintenance</i> Untuk Prediksi Waktu Kegagalan Mesin <i>Raw Mill</i> (Studi Kasus: PT ABC)	ANN (<i>Artificial Neural Network</i>) dan SVR (<i>Support Vector Regression</i>) (Regresi)	Mesin <i>raw mill</i> unit V PT ABC (Industri semen)	Penentuan model terbaik dengan menggunakan model ANN dan SVR untuk prediksi kegagalan setiap <i>equipment</i> pada mesin <i>raw mill</i>

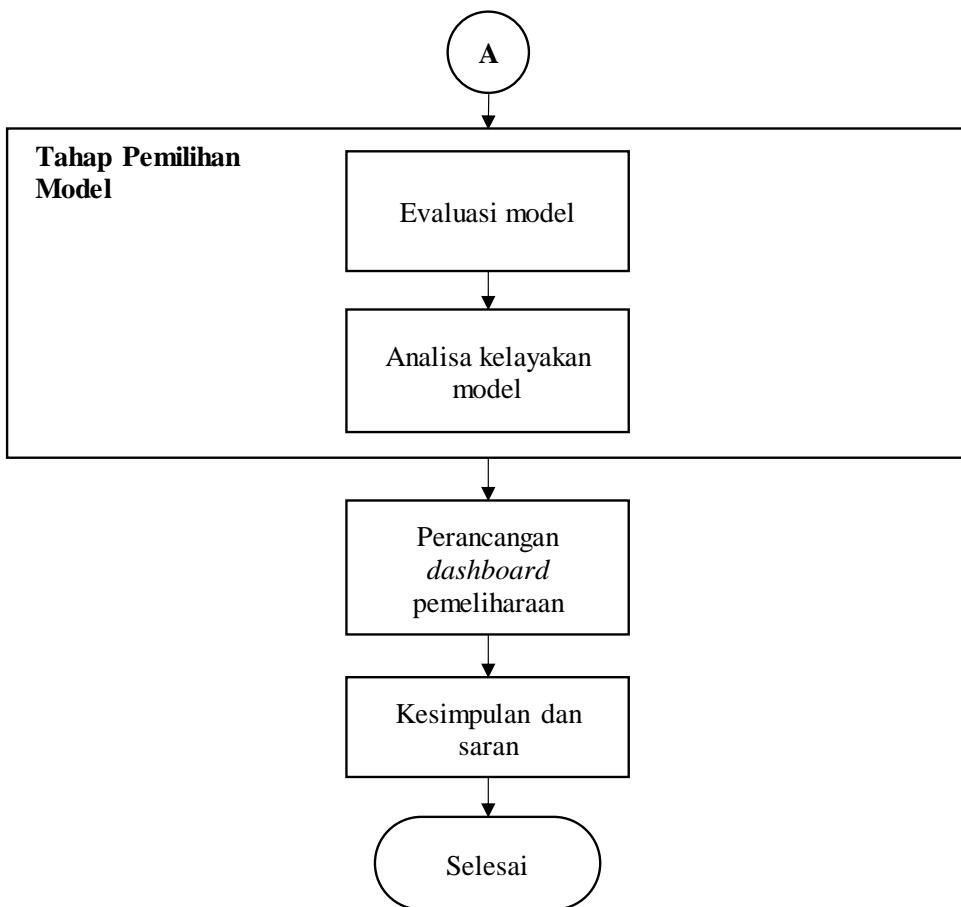
(Halaman ini sengaja dikosongkan)

BAB 3

METODOLOGI PENELITIAN

Pada bab ini dipaparkan mengenai metodologi dalam pelaksanaan penelitian. Gambar 3.1 menunjukkan diagram alur pelaksanaan penelitian ini.





Gambar 3. 1 Diagram Alur Pelaksanaan Penelitian

3.1 Tahap Pengumpulan dan Olah Data Awal

Tahap ini terdiri dari enam proses yaitu pengumpulan data (*data integration*), pemilihan data (*data selection*), perhitungan *time to failure* (TTF) perhitungan *mean residual life* (MRL), transformasi data dan pembagian *data training*, *data validation* serta *data testing*.

3.1.1 Pengumpulan Data

Pada proses ini dilakukan pengumpulan data *monitoring* sensor pada *equipment* kritis mesin *raw mill*. Data *monitoring* sensor diperoleh dengan mengambil data sekunder pada *data base* perusahaan dalam rentang waktu Januari 2015 hingga November 2019. Data yang diambil merupakan hasil *monitoring* sensor pada Tabel 3.1 dengan *extension* (.txt).

Tabel 3. 1 Sensor dan *Equipment* Pada Bagian *Mill* dan *Transport Material*

Bagian	Sensor	Equipment
<i>Mill</i>	<i>RPM sensor</i>	<i>Motor belt conveyor</i>
	<i>Pressure sensor</i>	<i>Sealing air fan</i>
	<i>Hydraulic sensor</i>	<i>Hydraulic system</i>
	<i>RPM sensor</i>	<i>Motor bucket elevator</i>
	<i>RPM sensor</i>	<i>Rotary feeder</i>
	<i>Vibration sensor</i>	Getaran bagian <i>mill</i> secara keseluruhan
<i>Alat transport raw material</i>	<i>Bin sensor</i>	<i>Bin material</i> (batu kapur)
	<i>Bin sensor</i>	<i>Bin material</i> (tanah liat)

Data hasil *monitoring* sensor yang diperoleh akan digunakan sebagai variabel prediktor dalam tahap penyusunan model.

3.1.2 Pemilihan Data (*Data Selection*)

Proses pemilihan data dilakukan untuk menyeleksi data-data yang kurang relevan dan dapat mengganggu proses pembentukan model prediksi. Keseluruhan data yang telah terkumpul akan diseleksi terlebih dahulu pada tahap ini. Tahap ini bertujuan agar model yang dihasilkan dapat memberi hasil prediksi yang baik.

3.1.3 Perhitungan *Time to Failure* (TTF)

Perhitungan nilai TTF dilakukan dengan menghitung selisih waktu antara *equipment* mulai beroperasi secara normal hingga *equipment* mengalami kegagalan. Penentuan kondisi *equipment* normal atau mengalami kegagalan didasarkan pada data *monitoring* oleh sensor, sesuai dengan ketentuan *threshold* pada Tabel 2.1. Ketika kinerja *equipment* melebihi *threshold* maka *equipment* mengalami kegagalan dan berlaku sebaliknya untuk penentuan kondisi normal.

Hasil perhitungan TTF kemudian diseleksi terlebih dahulu sebelum diproses pada tahap berikutnya. Data TTF kurang dari 0,5 jam ($TTF < 0,5$ jam) dan TTF *outlier* akan dihilangkan. Proses ini ditujukan agar model dapat mempelajari data dengan baik dan menghasilkan *output* prediksi yang lebih akurat.

3.1.4 Perhitungan *Mean Residual Life* (MRL)

Tahap ini digunakan untuk menghitung estimasi umur sisa *equipment* atau waktu kegagalan *equipment* pada titik waktu tertentu, yang kemudian disebut

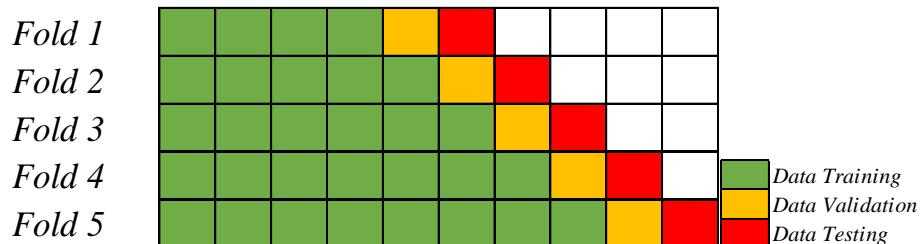
MRL(t). Proses perhitungan MRL(t) diawali dengan proses *fitting* distribusi kegagalan hasil perhitungan TTF. *Fitting* distribusi kegagalan dilakukan untuk setiap *equipment* pada mesin *raw mill* dengan menggunakan *software Weibull++*. Hasil *fitting* distribusi akan menunjukkan jenis distribusi dan nilai parameter yang sesuai dengan data kegagalan. Distribusi dan nilai parameter yang sesuai dijadikan sebagai acuan dalam perhitungan MRL (t) sesuai dengan persamaan 2.5. Nilai MRL(t) digunakan sebagai variabel respon dalam tahap penyusunan model.

3.1.5 Transformasi Data (*Data Transformation*)

Data transformation digunakan untuk mengkonversi nilai setiap variabel, baik variabel prediktor maupun variabel respon, ke dalam skala nilai yang sama. Variabel prediktor adalah waktu *monitoring* dan data *monitoring* sensor, sedangkan variabel respon adalah hasil perhitungan MRL. Teknik yang digunakan pada tahap ini adalah *data scaling*. Perhitungan *data scaling* dilakukan dengan menggunakan persamaan 2.10. Batas bawah dan atas yang digunakan secara berturut-turut adalah 0 dan 1. Hasil yang diperoleh dari tahap ini adalah keseluruhan data untuk setiap variabel prediktor dan variabel respon memiliki rentang nilai 0 hingga 1.

3.1.6 Pembagian *Data training*, *Data validation* dan *Data testing*

Pembagian *data training*, *data validation* dan *data testing* dilakukan berdasarkan prosedur *nested cross validation*. Dimana dalam satu *dataset* untuk setiap *equipment* akan dibagi menjadi tiga bagian, yaitu *data training*, *data validation* dan *data testing*. *Dataset* akan dibagi menjadi 10 partisi dan akan dilakukan perhitungan hingga 5-fold atau 5 iterasi. Pada fold pertama, empat partisi pertama akan digunakan sebagai *data training*, partisi ke-5 akan digunakan sebagai *data validation* dan partisi ke-6 sebagai *data testing*. Pada fold kedua, partisi ke-5 akan digabungkan dengan *data training*, partisi ke-6 digunakan sebagai *data validation* dan partisi ke-7 sebagai *data testing*. Pembagian tersebut dilakukan hingga 5-fold terbentuk. Gambar 3.2 menunjukkan visualisasi pembagian data pada penelitian ini.



Gambar 3. 2 Pembagian *Data training*, *Data validation*, dan *Data testing* Dengan *Nested Cross Validation*

3.2 Tahap Penyusunan Model

Dalam penyusunan model dilakukan penentuan nilai parameter uji coba terlebih dahulu sebelum dilakukan penentuan parameter optimal untuk model SVR dan ANN pada setiap *equipment*.

3.2.1 Penentuan Nilai Parameter Uji Coba

Penentuan nilai parameter uji coba pada model SVR dan ANN dilakukan dengan meninjau beberapa refrensi dan penelitian terdahulu serta didasarkan pada uji coba yang dilakukan oleh penulis. Adapun parameter yang akan diuji coba nilainya pada penelitian ini dapat dilihat pada Tabel 3.2.

Tabel 3. 2 Parameter Uji Coba Model SVR dan ANN

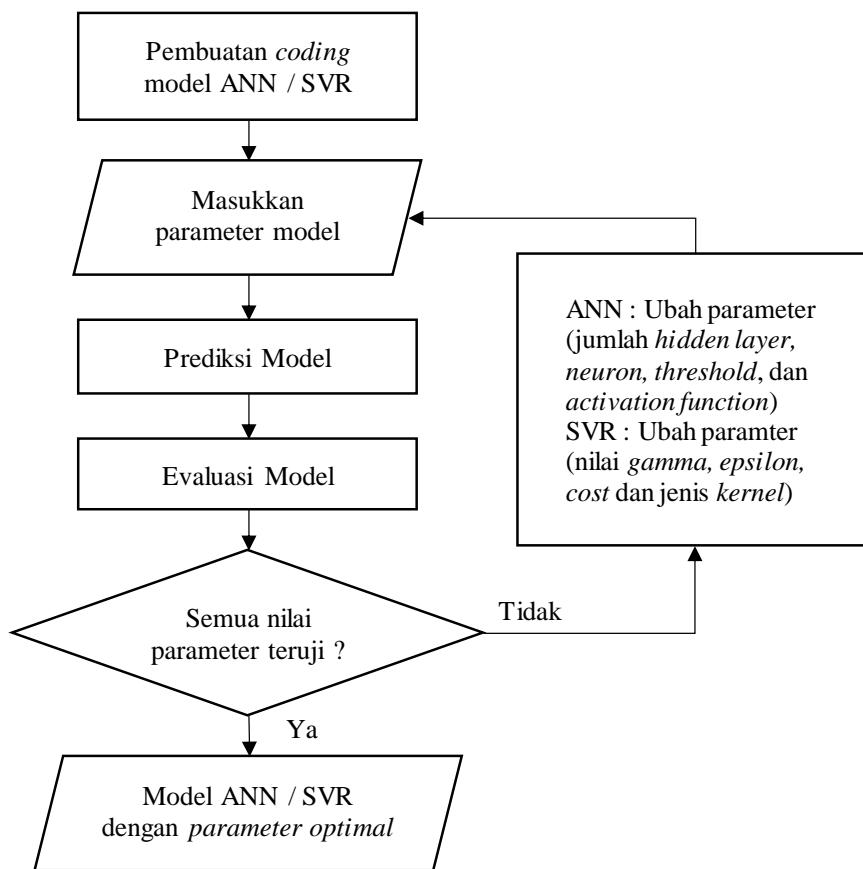
SVR (<i>Support Vector Regression</i>)	ANN (<i>Artificial Neural Network</i>)
Nilai <i>gamma</i> (γ)	Nilai <i>threshold</i>
<i>cost of constraints</i> (C)	Jumlah <i>hidden layer</i>
<i>insensitive-loss function</i> (<i>epsilon</i> , ϵ)	Jumlah <i>neuron</i>
Jenis <i>kernel</i>	Jenis <i>activation function</i>

3.2.2 Penentuan Parameter Model Optimal

Penentuan parameter model optimal dilakukan dengan membangun algoritma model prediksi ke dalam bahasa pemrograman dengan menggunakan *software R studio*. Kemudian dilakukan *parameter tuning* dengan metode *grid search*, dengan bantuan *software R studio*. Terdapat dua macam model yang digunakan dalam penelitian ini, yaitu model *support vector regression* dan model *artificial neural network*.

Tahap penentuan parameter optimal hanya akan menggunakan partisi *data training* dan *data validation* sesuai dengan pembagian data pada subbab 3.1.6. Penentuan parameter optimal dilakukan dengan mengubah dan mengkombinasikan setiap nilai parameter pada model. Pada setiap kombinasi akan dilakukan proses evaluasi dengan menghitung performa model baik pada *data training* maupun *data validation*. Proses evaluasi dilakukan sebanyak 5-fold sesuai dengan prosedur *nested cross validation*. Model dengan parameter optimal adalah model yang memiliki nilai *error* paling kecil dan tidak mengindikasikan adanya *overfitting*. Tidak *overfitting* ditunjukkan dengan performa model pada *data validation* memiliki *error* yang lebih kecil atau sama dengan nilai *error* pada *data training*.

Gambar 3.2 menunjukkan alur proses *parameter tuning* pada model *support vector regression* dan *artificial neural network* dengan metode *grid search*.



Gambar 3. 3 Proses *Parameter Tuning* Untuk Model ANN dan SVR

Berikut merupakan penjelasan langkah-langkah penentuan parameter optimal sesuai dengan Gambar 3.2.

1. Melakukan penyusunan model dengan menggunakan *software R studio*.
2. Memasukkan parameter yang telah ditentukan sebelumnya. Dimana parameter yang akan diubah nilai atau jenisnya adalah sebagai berikut (ANN = jumlah *hidden layer*, jumlah *neuron*, *threshold* dan *activation function*; sedangkan untuk SVR = nilai *gamma*, nilai *epsilon*, *cost of constraints* dan jenis *kernel*) selain parameter tersebut tidak dilakukan perubahan.
3. Prediksi dilakukan dengan membagi data menjadi *data training* dan *data validation* sesuai dengan prosedur *nested cross validation* hingga lima *fold*.
4. Proses evaluasi dilakukan baik pada *data training* maupun *data validation* sesuai dengan prosedur *nested cross validation* hingga lima kali iterasi. Nilai *error* yang digunakan adalah RMSE. Nilai rata-rata *error* pada *data training* dan *data validation* pada setiap kombinasi dibandingkan untuk mengetahui model *overfitting* atau tidak.
5. Langkah 1 hingga 4 dilakukan secara berulang hingga seluruh nilai dan jenis parameter yang telah ditetapkan pada langkah dua telah teruji.
6. Penentuan model SVR dan ANN dengan nilai parameter optimal, yaitu model tidak mengalami *overfitting*.

Hasil akhir dari tahap ini adalah model ANN dan SVR dengan nilai parameter optimal untuk masing-masing *equipment* mesin *raw mill*.

3.3 Tahap Pemilihan Model

Tahap pemilihan model terbagi menjadi dua proses yaitu evaluasi model dan uji kelayakan model.

3.3.1 Tahap Evaluasi Model

Tahap evaluasi digunakan untuk mengukur performa model dengan parameter optimal, sebagai acuan dalam menentukan satu model terbaik antara SVR atau ANN. Tahap ini menggunakan *data testing* untuk mengukur perfoma model, sedangkan *data training* yang digunakan merupakan kombinasi dari *data training* dan *data validation*. Pembagian data mengacu pada subab 3.1.6. Parameter

performansi yang digunakan adalah RMSE dan STD (Standar Deviasi). Proses evaluasi dilakukan sebanyak lima kali iterasi (*5-fold*) sesuai dengan prosedur *nested cross validation*. Dalam tahap ini akan diperoleh lima nilai ukuran performansi baik RMSE dan STD untuk model SVR dan ANN pada setiap *equipment*. Nilai tersebut kemudian dirata-rata untuk mencari model (SVR atau ANN) dengan nilai RMSE dan STD terkecil, yang mana model tersebut ditentukan sebagai model terbaik.

3.3.2 Uji kelayakan model

Uji kealayakan digunakan untuk memastikan bahwa model terbaik dapat digunakan untuk prediksi kegagalan (MRL) *equipment* sesuai dengan kondisi sebenarnya. Uji kelayakan dilakukan dengan uji beda berpasangan antara MRL *data testing* dan MRL hasil prediksi model SVR atau ANN. Metode uji beda ditentukan berdasarkan hasil uji normalitas. Jika uji normalitas menunjukkan bahwa data uji berdistribusi normal maka digunakan uji beda secara parametrik (*T-test*). Sedangkan jika tidak berdistribusi normal digunakan uji secara non-parametrik (*Wilcoxon test*). Jika dinyatakan tidak ada perbedaan signifikan antara MRL *data testing* dan MRL hasil prediksi model maka model dinyatakan layak, sebaliknya jika terdapat perbedaan signifikan maka model dinyatakan tidak layak untuk digunakan dalam prediksi waktu kegagalan.

3.3 Tahap Perancangan *Dashboard* Pemeliharaan

Tahap ini digunakan untuk menyusun *dashboard* sebagai fungsi praktis untuk memudahkan pekerja dalam pemantauan kondisi mesin dan mengetahui prediksi waktu kegagalan setiap *equipment* secara *real time*. Tahap perancangan *dashboard* dilakukan dengan menggunakan model terbaik hasil perhitungan pada subab 3.3.1 untuk melakukan prediksi kegagalan setiap *equipment*. Tiga macam *software* dikombinasikan untuk penyelesaian tahap ini, yaitu R studio, MS. Excel dan Power BI. R studio digunakan untuk melakukan prediksi waktu kegagalan setiap *equipment* dengan menggunakan model terbaik, MS. Excel berfungsi untuk menyimpan data hasil prediksi serta penghubung pada *software* power BI, sedangkan power BI sendiri berfungsi sebagai *dashboard* untuk menampilkan data *monitoring equipment* dan waktu kegagalan *equipment* secara *real time*. Hasil akhir

dari tahap ini adalah *dashboard* pemeliharaan yang mampu menampilkan hasil prediksi kegagalan *equipment* (MRL) untuk setiap *equipment* pada mesin *raw mill*.

3.4 Kesimpulan dan Saran

Dalam bagian ini dilakukan pengambilan kesimpulan berdasarkan hasil analisis dan olah data yang telah dilakukan sesuai dengan tujuan yang telah ditetapkan pada awal penelitian. Saran diberikan baik kepada perusahaan maupun untuk keberlanjutan penelitian.

(Halaman ini sengaja dikosongkan)

BAB 4

PENGUMPULAN DAN OLAH DATA AWAL

Pada bab ini dipaparkan mengenai data yang diperoleh untuk pelaksanaan penelitian serta olah data awal yang meliputi pemilihan data, perhitungan *time to failure* (TTF), *mean residual life* (MRL), transformasi data dan pembagian *data training*, *data validation* serta *data testing*.

4.1 Pengumpulan Data

Data yang diperoleh berupa hasil *monitoring* delapan sensor pada tujuh *equipment* kritis dalam mesin *raw mill*. Data yang diperoleh merupakan data sekunder hasil *monitoring* kinerja *equipment* setiap 10 detik dalam rentang waktu 1 Januari 2015 hingga 30 November 2019. Data diperoleh dari *data base monitoring* perusahaan, dengan jumlah 15.508.800 data *monitoring* untuk masing-masing sensor. Tabel 4.1 dan 4.2 menunjukkan contoh data *monitoring* sensor yang diperoleh dalam tahap pengumpulan data.

Tabel 4. 1 Data Sensor RPM (MBC) – Sensor RPM (MBE) Tahun 2015 – 2019

No	Tanggal dan Waktu	Sensor RPM (MBC)	Sensor Tekanan	Sensor Hydraulic	Sensor RPM (MBE)
1	01/01/2015 00.00.00	0	39	2	0
2	01/01/2015 00.00.10	0	39	2	0
3	01/01/2015 00.00.20	0	38	2	0
4	01/01/2015 00.00.30	0	39	2	0
5	01/01/2015 00.00.40	0	37	2	0
6	01/01/2015 00.00.50	0	39	2	0
7	01/01/2015 00.01.00	0	39	2	0
8	01/01/2015 00.01.10	0	40	2	0
9	01/01/2015 00.01.20	0	39	2	0
10	01/01/2015 00.01.30	0	39	2	0
...
7.879.681	01/07/2017 00.00.00	49	24	3	50
7.879.682	01/07/2017 00.00.10	48	24	3	50
7.879.683	01/07/2017 00.00.20	46	24	3	50
7.879.684	01/07/2017 00.00.30	44	25	3	50
7.879.685	01/07/2017 00.00.40	44	24	3	50
...
15.508.796	30/11/2019 23.59.10	0	44	2	0
15.508.797	30/11/2019 23.59.20	0	44	2	0
15.508.798	30/11/2019 23.59.30	0	44	2	0
15.508.799	30/11/2019 23.59.40	0	44	2	0
15.508.800	30/11/2019 23.59.50	0	44	2	0

Tabel 4. 2 Data Sensor RPM (RF) - Sensor Bin (BI-2) Tahun 2015 – 2019

No	Tanggal dan Waktu	Sensor RPM (RF)	Sensor Vibrasi	Sensor Bin (BI-1)	Sensor Bin (BI-2)
1	01/01/2015 00.00.00	40	0,1	75	76
2	01/01/2015 00.00.10	40	0,1	75	76
3	01/01/2015 00.00.20	40	0,1	76	76
4	01/01/2015 00.00.30	40	0,1	75	76
5	01/01/2015 00.00.40	40	0,1	75	76
6	01/01/2015 00.00.50	40	0,1	75	76
7	01/01/2015 00.01.00	40	0,1	75	76
8	01/01/2015 00.01.10	40	0,1	75	76
9	01/01/2015 00.01.20	40	0,1	75	76
10	01/01/2015 00.01.30	49	0,1	75	76
...
7.879.681	01/07/2017 00.00.00	40	3,2	40	62
7.879.682	01/07/2017 00.00.10	41	2,6	40	62
7.879.683	01/07/2017 00.00.20	40	4	39	62
7.879.684	01/07/2017 00.00.30	40	4	41	62
7.879.685	01/07/2017 00.00.40	41	2,7	40	62
...
15.508.796	30/11/2019 23.59.10	0	0	81	75
15.508.797	30/11/2019 23.59.20	0	0	81	75
15.508.798	30/11/2019 23.59.30	0	0	81	75
15.508.799	30/11/2019 23.59.40	0	0	81	75
15.508.800	30/11/2019 23.59.50	0	0	81	75

4.2 Pemilihan Data

Data hasil *monitoring* yang dinilai kurang relevan atau dapat mengganggu proses pembuatan model akan dihilangkan pada proses ini. Beberapa data yang dihilangkan adalah data hasil *monitoring* pada tahun 2015, 2016, 2018 dan 2019, sehingga dalam penelitian ini akan digunakan data pada tahun 2017. Tahun 2018 dan 2019 dihilangkan karena data *monitoring* sensor vibrasi tidak menunjukkan angka yang semestinya. Contoh hasil *monitoring* sensor vibrasi secara normal adalah dalam rentang 0 hingga 20, namun pada tahun 2018 dan 2019 terdapat data sensor vibrasi yang menunjukkan angka ribuan. Penggunaan data tersebut dapat mengganggu proses prediksi model. Selain itu data pada tahun 2015 dan 2016 juga dihilangkan karena data tahun 2017 dianggap cukup representatif untuk menunjukkan kondisi terbaru setiap *equipment*.

Selain itu, data sensor Bin (BI-1), sensor Bin (BI-2), dan sensor *hydraulic system* juga tidak digunakan dalam penelitian ini. Hal tersebut dikarenakan sensor Bin (BI-1) dan (BI-2) tidak memonitor adanya kegagalan pada *equipment* bin namun hanya memonitor volume bahan mentah yang ada pada *bin*. Kondisi tersebut tidak relevan dengan tujuan penelitian untuk melakukan prediksi waktu kegagalan

/ kerusakan *equipment*. Sedangkan data sensor *hydraulic system* tidak digunakan karena hanya memiliki 2 variasi data yaitu nilai 2 (*equipment off / fail*) dan 3 (*equipment on / operate*). Data tersebut tidak dapat digunakan dalam proses prediksi. Hasil proses *data selection* telah divalidasi oleh pihak perusahaan dan dinyatakan representatif untuk digunakan.

Dari 15.508.800 data yang telah terkumpul pada tahap pengumpulan data, dalam penelitian ini hanya akan digunakan 3.153.600 data hasil *monitoring* sensor RPM (MBC), sensor tekanan (SAF), sensor RPM (RF), sensor RPM (MBE) dan sensor vibrasi pada tahun 2017. Tabel 4.3 menunjukkan data hasil *monitoring* sensor tahun 2017 yang akan digunakan dalam penelitian ini.

Tabel 4. 3 Data *Monitoring* Sensor RPM (MBC) – Sensor Vibrasi Tahun 2017

No	Tanggal dan Waktu	Sensor RPM (MBC)	Sensor Tekanan (SAF)	Sensor RPM (RF)	Sensor RPM (MBE)	Sensor Vibrasi
1	01/01/2017 00.00.00	41	27	40	47	1,7
2	01/01/2017 00.00.10	41	28	40	47	1,9
3	01/01/2017 00.00.20	42	29	40	46	2,1
4	01/01/2017 00.00.30	42	29	41	48	1,9
5	01/01/2017 00.00.40	42	27	41	47	1,9
...
3.153.596	31/12/2017 23.59.10	40	25	41	44	1,8
3.153.597	31/12/2017 23.59.20	40	23	42	44	2,1
3.153.598	31/12/2017 23.59.30	40	26	41	45	2
3.153.599	31/12/2017 23.59.40	40	21	41	43	1,8
3.153.600	31/12/2017 23.59.50	40	24	41	42	2,4

4.3 Perhitungan *Time to Failure* (TTF)

Proses perhitungan *time to failure* dilakukan dengan menghitung *interval* antara *equipment* mulai beroperasi hingga *equipment* mengalami kegagalan. Penentuan operasi dan gagal pada *equipment* didasarkan pada data hasil *monitoring* sensor dengan mengacu pada ketentuan *threshold* Tabel 2.1.

Sensor bekerja secara spesifik untuk memantau kondisi *equipment* yang berbeda. Setiap *equipment* akan dipantau oleh dua macam sensor. Tabel 4.4 menunjukkan daftar sensor dan *equipment* yang dipantau.

Tabel 4. 4 Daftar Sensor dan *Equipment* yang Dipantau

Bagian	Equipment	Sensor	
Mill	Motor belt conveyor (MBC)	Sensor RPM (MBC)	Sensor Vibrasi

Bagian	Equipment	Sensor	
	<i>Sealing air fan (SAF)</i>	Sensor Tekanan	Sensor Vibrasi
	<i>Motor bucket elevator (MBE)</i>	Sensor RPM (MBE)	Sensor Vibrasi
	<i>Rotary feeder (RF)</i>	Sensor RPM (RF)	Sensor Vibrasi

Tabel 4.6 - 4.10 menunjukkan rekap kondisi setiap *equipment* berdasarkan data hasil *monitoring* sensor. Dimana kolom status menunjukkan kondisi *equipment* pada setiap waktu, nilai 1 dan 0 berturut-turut mengindikasikan *equipment* beroperasi dan mengalami kegagalan / sedang dilakukan perbaikan. Perhitungan TTF setiap *equipment* mengacu pada status pada Tabel 4.5 - 4.8.

Tabel 4. 5 Rekap Kondisi *Motor Belt Conveyor Equipment* (MBC)

Tanggal dan Waktu	Sensor RPM (MBC) (%)	Sensor Vibrasi (mm/s)	Status
01/01/2017 00.00.00	41	1,7	1
01/01/2017 00.00.10	41	1,9	1
01/01/2017 00.00.20	42	2,1	1
01/01/2017 00.00.30	42	1,9	1
01/01/2017 00.00.40	42	1,9	1
...
31/12/2017 23.59.10	40	1,8	1
31/12/2017 23.59.20	40	2,1	1
31/12/2017 23.59.30	40	2	1
31/12/2017 23.59.40	40	1,8	1
31/12/2017 23.59.50	40	2,4	1

Tabel 4. 6 Rekap Kondisi *Sealing Air Fan Equipment* (SAF)

Tanggal dan Waktu	Sensor Tekanan (SAF) (milibar)	Sensor Vibrasi (mm/s)	Status
01/01/2017 00.00.00	27	1,7	1
01/01/2017 00.00.10	28	1,9	1
01/01/2017 00.00.20	29	2,1	1
01/01/2017 00.00.30	29	1,9	1
01/01/2017 00.00.40	27	1,9	1
...
31/12/2017 23.59.10	25	1,8	1
31/12/2017 23.59.20	23	2,1	1
31/12/2017 23.59.30	26	2	1
31/12/2017 23.59.40	21	1,8	1
31/12/2017 23.59.50	24	2,4	1

Tabel 4. 7 Rekap Kondisi *Rotary Feeder Equipment* (RF)

Tanggal dan Waktu	Sensor RPM (RF) (%)	Sensor Vibrasi (mm/s)	Status
01/01/2017 00.00.00	40	1,7	1
01/01/2017 00.00.10	40	1,9	1
01/01/2017 00.00.20	40	2,1	1
01/01/2017 00.00.30	41	1,9	1

Tanggal dan Waktu	Sensor RPM (RF) (%)	Sensor Vibrasi (mm/s)	Status
01/01/2017 00.00.40	41	1,9	1
...
31/12/2017 23.59.10	41	1,8	1
31/12/2017 23.59.20	42	2,1	1
31/12/2017 23.59.30	41	2	1
31/12/2017 23.59.40	41	1,8	1
31/12/2017 23.59.50	41	2,4	1

Tabel 4. 8 Rekap Kondisi Motor Bucket Elevator Equipment (MBE)

Tanggal dan Waktu	Sensor RPM (MBE) (%)	Sensor Vibrasi (mm/s)	Status
01/01/2017 00.00.00	47	1,7	1
01/01/2017 00.00.10	47	1,9	1
01/01/2017 00.00.20	46	2,1	1
01/01/2017 00.00.30	48	1,9	1
01/01/2017 00.00.40	47	1,9	1
...
31/12/2017 23.59.10	44	1,8	1
31/12/2017 23.59.20	44	2,1	1
31/12/2017 23.59.30	45	2	1
31/12/2017 23.59.40	43	1,8	1
31/12/2017 23.59.50	42	2,4	1

Hasil perhitungan TTF kemudian diseleksi dengan menghapus nilai TTF kurang dari 0,5 jam ($TTF < 0,5$ jam) dan data ekstrim / *outlier*. Berdasarkan hasil wawancara dengan pihak perusahaan, durasi operasi di bawah 0,5 jam termasuk dalam masa uji coba *equipment* setelah dilakukan perbaikan, sehingga data tersebut dapat diabaikan. Penghilangan data *outlier* dilakukan untuk meminimalisir terjadinya bias pada proses prediksi oleh model. Tabel 4.9 – 4.12 menunjukkan rekap data hasil perhitungan TTF yang telah terseleksi untuk setiap *equipment*.

Tabel 4. 9 Rekap Hasil Perhitungan TTF (*MBC equipment*)

No	Operasi		Gagal		TTF (Jam)
	Tanggal & Waktu	Status	Tanggal & Waktu	Status	
1	01/01/2017 00.00	1	01/01/2017 11.38	0	11,6444444
2	01/01/2017 11.54	1	01/01/2017 23.29	0	11,575
3	02/01/2017 01.06	1	02/01/2017 11.28	0	10,3666667
4	02/01/2017 11.32	1	02/01/2017 12.03	0	0,50833333
5	02/01/2017 12.03	1	02/01/2017 12.37	0	0,56944444
...
291	29/12/2017 19.02	1	30/12/2017 01.26	0	6,40555556
292	30/12/2017 02.02	1	30/12/2017 19.32	0	17,5083333
293	30/12/2017 21.00	1	31/12/2017 08.33	0	11,5583333
294	31/12/2017 08.42	1	31/12/2017 09.54	0	1,2
295	31/12/2017 09.57	1	31/12/2017 23.59	0	14,0497222

Tabel 4. 10 Rekap Hasil Perhitungan TTF (*SAF equipment*)

No	Operasi		Gagal		TTF (Jam)
	Tanggal & Waktu	Status	Tanggal & Waktu	Status	
1	01/01/2017 00.00.00	1	17/01/2017 19.27.00	0	403,45
2	17/01/2017 21.29.40	1	28/01/2017 14.18.20	0	256,8111
3	24/03/2017 22.42.40	1	30/03/2017 09.59.00	0	131,2722
4	30/03/2017 10.15.30	1	01/04/2017 05.00.40	0	42,7527
5	01/04/2017 05.08.30	1	06/04/2017 02.00.10	0	116,8611
...
31	24/11/2017 16.17.20	1	11/12/2017 17.17.20	0	409
32	11/12/2017 17.18.20	1	12/12/2017 23.42.30	0	30,4027
33	13/12/2017 06.25.40	1	17/12/2017 00.00.40	0	89,5833
34	17/12/2017 00.09.40	1	27/12/2017 14.00.50	0	253,8527
35	27/12/2017 22.24.50	1	31/12/2017 23.59.59	0	97,5858

Tabel 4. 11 Rekap Hasil Perhitungan TTF (*RF equipment*)

No	Operasi		Gagal		TTF (Jam)
	Tanggal & Waktu	Status	Tanggal & Waktu	Status	
1	01/01/2017 00.00.00	1	01/01/2017 11.38.40	0	11,6444
2	01/01/2017 11.53.20	1	01/01/2017 23.29.10	0	11,5972
3	02/01/2017 01.04.50	1	03/01/2017 12.10.50	0	35,1
4	03/01/2017 12.45.20	1	03/01/2017 14.07.00	0	1,3611
5	04/01/2017 00.39.10	1	04/01/2017 08.00.00	0	7,3472
...
167	22/12/2017 02.25.00	1	23/12/2017 08.22.30	0	29,9583
168	23/12/2017 15.22.30	1	23/12/2017 20.55.30	0	5,55
169	24/12/2017 06.02.30	1	27/12/2017 08.57.00	0	74,9083
170	27/12/2017 22.44.00	1	29/12/2017 08.34.50	0	33,8472
171	29/12/2017 19.00.40	1	31/12/2017 23.59.59	0	52,9886

Tabel 4. 12 Rekap Hasil Perhitungan TTF (*MBE equipment*)

No	Operasi		Gagal		TTF (Jam)
	Tanggal & Waktu	Status	Tanggal & Waktu	Status	
1	01/01/2017 00.00.00	1	01/01/2017 11.38.40	0	11,6444
2	01/01/2017 12.13.30	1	01/01/2017 23.29.10	0	11,2611
3	02/01/2017 01.06.00	1	03/01/2017 12.10.50	0	35,0805
4	03/01/2017 12.47.10	1	03/01/2017 14.07.00	0	1,3305
5	04/01/2017 00.40.20	1	04/01/2017 08.00.00	0	7,3277
...
295	27/12/2017 04.34.50	1	27/12/2017 08.57.00	0	4,3694
296	27/12/2017 22.45.10	1	29/12/2017 08.34.10	0	33,8166
297	29/12/2017 19.01.50	1	30/12/2017 19.32.40	0	24,5138
298	30/12/2017 19.50.00	1	31/12/2017 08.33.40	0	12,7277
299	31/12/2017 08.39.20	1	31/12/2017 23.59.59	0	15,3441

Nilai TTF diperoleh dengan menghitung selisih antara tanggal & waktu pada kolom gagal dengan kolom operasi. Berdasarkan Tabel 4.9 – 4.12, dalam rentang waktu Januari – Desember 2017 terdapat 295 data *time to failure* untuk *MBC equipment* dengan rata-rata nilai TTF adalah sebesar 14,9332 jam. Untuk *SAF*

equipment diperoleh 35 data TTF dengan rata-rata nilai sebesar 159,1364 jam. Untuk *RF equipment* diperoleh 171 data TTF dengan rata-rata nilai sebesar 31,7127. Sedangkan untuk *MBE equipment* diperoleh 299 data TTF dengan rata-rata nilai sebesar 14,7469 jam. Data pada Tabel 4.9 – 4.12 kemudian digunakan sebagai acuan dalam proses perhitungan *mean residual life*.

4.4 Perhitungan *Mean Residual Life* (MRL)

Perhitungan MRL (*t*) dilakukan untuk mengetahui umur sisa dari setiap *equipment* pada waktu tertentu. Tahap ini ditujukan untuk membentuk nilai MRL (*t*) pada setiap waktu ke-*t* sensor melakukan *monitoring* kondisi *equipment*. Hasil perhitungan pada tahap ini akan digunakan sebagai variabel respon dalam proses penyusunan model.

Perhitungan MRL dimulai dengan melakukan *fitting* distribusi kegagalan berdasarkan hasil perhitungan TTF. *Fitting* distribusi kegagalan dilakukan dengan menggunakan *software Weibull ++*. Tabel 4.13 Menunjukkan rekap distribusi kegagalan dan nilai parameter untuk setiap *equipment*. Jenis distribusi dan nilai parameter digunakan sebagai acuan dalam penentuan nilai MRL (*t*) setiap *equipment* pada waktu tertentu. Detail hasil *fitting* distribusi kegagalan setiap *equipment* ditampilkan pada lampiran A.

Tabel 4. 13 Rekap Distribusi Kegagalan dan Nilai Parameter Setiap *Equipment*

<i>Equipment</i>	Distribusi Kegagalan	Parameter	
<i>Motor belt conveyor (MBC)</i>	Weibull 2 parameter	<i>Beta</i>	1,0734
		<i>Eta</i>	14,8083
<i>Sealing air fan (SAF)</i>	Weibull 2 parameter	<i>Beta</i>	1,2995
		<i>Eta</i>	171,7242
<i>Rotary feeder (RF)</i>	Weibull 2 parameter	<i>Beta</i>	1,778
		<i>Eta</i>	34,9463
<i>Motor bucket elevator (MBE)</i>	Weibull 2 parameter	<i>Beta</i>	1,0716
		<i>Eta</i>	14,6812

Keseluruhan *equipment* pada Tabel 4.13 menggunakan distribusi pada peringkat dua berdasarkan hasil *fitting* distribusi. Pemilihan distribusi tersebut dikarenakan distribusi pada peringkat pertama untuk keseluruhan *equipment* menunjukkan distribusi *weibull 3 parameter*, dengan parameter *gamma* bernilai positif dan terdapat suatu kondisi dimana waktu ke-*t* (waktu *monitoring* sensor)

lebih kecil dibandingkan nilai *gamma* ($t < \gamma$). Sedangkan menurut Teimouri & Gupta (2013), syarat dari penggunaan distibusi *weibull 3 parameter* adalah $t > \gamma$, $\alpha > 0$ dan $\beta > 0$. Sehingga distribusi pada peringkat 1 tidak dapat digunakan. Selain itu berdasarkan uji coba yang dilakukan penulis, penggunaan distribusi tersebut menyebabkan *error* dalam proses perhitungan MRL (t).

Perhitungan MRL (t) dilakukan sesuai dengan persamaan 2.5 menggunakan *software R Studio*. Koding terkait perhitungan MRL (t) ditampilkan pada lampiran B. Dalam perhitungan MRL (t) terdapat komponen R(t) yang dihitung menggunakan persamaan 2.1 hingga 2.4. Penggunaan persamaan R(t) disesuaikan dengan hasil *fitting* distribusi kegagalan pada Tabel 4.13. Contoh perhitungan nilai R(t) untuk setiap *equipment* ditunjukkan pada Tabel 4.14, dengan $t = 0,5$ jam.

Tabel 4. 14 Rekap Contoh Perhitungan R(t) untuk setiap *equipment*

<i>Equipment</i>	<i>Monitoring</i> ke-t (Jam)	Persamaan	Hasil R(t)
MBC	0,5	$R(30) = \exp \left[-\left(\frac{0,5}{14,8083} \right)^{1,0734} \right]$	0,974008
SAF	0,5	$R(30) = \exp \left[-\left(\frac{0,5}{171,7242} \right)^{1,2995} \right]$	0,999493
RF	0,5	$R(30) = \exp \left[-\left(\frac{0,5}{34,9463} \right)^{1,778} \right]$	0,999474
MBE	0,5	$R(30) = \exp \left[-\left(\frac{0,5}{14,6812} \right)^{1,0716} \right]$	0,973612

Hasil perhitungan nilai R(t) pada Tabel 4.14 akan digunakan dalam proses perhitungan nilai MRL (t). Tabel 4.15 menunjukkan contoh perhitungan nilai MRL (t) untuk masing-masing *equipment* dengan $t = 0,5$ jam. Persamaan yang digunakan dalam perhitungan MRL (t) adalah sebagai berikut.

$$MRL(t) = \frac{1}{R(t)} \int_t^{\text{TTF}} R(t) \quad (4.1)$$

Tabel 4. 15 Rekap Contoh Perhitungan MRL (t)

<i>Equipment</i>	<i>Monitoring</i> ke-t (Jam)	TTF (Jam)	Persamaan	MRL(t) (Jam)
MBC	0,5	11,64	$MRL(t) = \frac{1}{0,974} \int_{0,5}^{11,64} \exp \left[-\left(\frac{0,5}{14,8083} \right)^{1,073} \right] dt$	7,9392

<i>Equipment</i>	<i>Monitoring ke-t (Jam)</i>	<i>TTF (Jam)</i>	<i>Persamaan</i>	<i>MRL(t) (Jam)</i>
SAF	0,5	403,45	$MRL(t) = \frac{1}{0,999} \int_{0,5}^{403,45} \exp\left[-\left(\frac{0,5}{171,7242}\right)^{1,299}\right]$	153,548
RF	0,5	11,64	$MRL(t) = \frac{1}{0,999} \int_{0,5}^{11,64} \exp\left[-\left(\frac{0,5}{34,9463}\right)^{1,778}\right]$	10,5808
MBE	0,5	11,64	$MRL(t) = \frac{1}{0,973} \int_{0,5}^{11,64} \exp\left[-\left(\frac{0,5}{14,6812}\right)^{1,0716}\right]$	7,9132

Proses perhitungan MRL (t) dilakukan setiap *interval* 0,5 jam. Berdasarkan hasil wawancara dengan pihak perusahaan, penggunaan data tersebut cukup representatif untuk digunakan karena data sensor dalam *interval* 0,5 jam sebagian besar tidak jauh berbeda. Mengacu pada contoh perhitungan dalam Tabel 4.14 dan 4.15, diperoleh rekap nilai MRL (t) untuk setiap *equipment* ditunjukkan pada Tabel 4.16 hingga Tabel 4.19.

Waktu ke-t merupakan titik waktu setelah *equipment* dilakukan perbaikan. Sedangkan nilai TTF menunjukkan waktu *equipment* mengalami kegagalan, sesuai dengan perhitungan TTF yang telah dilakukan sebelumnya. Nilai TTF pertama akan digunakan dalam perhitungan MRL (t) hingga waktu ke-t menunjukkan angka yang sama dengan nilai TTF. Setelah mencapai kondisi tersebut, maka dilanjutkan dengan nilai TTF berikutnya. Hal tersebut berlaku hingga keseluruhan nilai TTF untuk setiap *equipment* telah digunakan.

Tabel 4. 16 Rekap Hasil Perhitungan MRL (*MBC equipment*)

No	Tanggal dan Waktu	Waktu ke-t (Jam)	TTF	R(t)	MRL (t) (Jam)
1	01/01/2017 00.00.00	0,0	11,64444	1,0000	8,2266
2	01/01/2017 00.30.00	0,5	11,64444	0,9740	7,9392
3	01/01/2017 01.00.00	1,0	11,64444	0,9461	7,6661
4	01/01/2017 01.30.00	1,5	11,64444	0,9179	7,3936
5	01/01/2017 02.00.00	2,0	11,64444	0,8899	7,1183
...
8055	31/12/2017 08.33.40	11,55833	11,55833	0,4647	0,0000
8056	31/12/2017 08.42.10	0,0	1,2	1,0000	1,1618
8057	31/12/2017 09.12.10	0,5	1,2	0,9740	0,6859
8058	31/12/2017 09.42.10	1,0	1,2	0,9461	0,1987
8059	31/12/2017 09.54.10	1,2	1,2	0,9348	0,0000

Tabel 4. 17 Rekap Hasil Perhitungan MRL (*SAF equipment*)

No	Tanggal dan Waktu	Waktu ke-t (Jam)	TTF	R(t)	MRL (t) (Jam)
1	01/01/2017 00.00.00	0,0	403,45	1,0000	153,9707
2	01/01/2017 00.30.00	0,5	403,45	0,9995	153,5486
3	01/01/2017 01.00.00	1,0	403,45	0,9988	153,1622
4	01/01/2017 01.30.00	1,5	403,45	0,9979	152,7945
5	01/01/2017 02.00.00	2,0	403,45	0,9969	152,4406
...
9908	27/12/2017 12.09.40	252,0	253,8528	0,1928	1,8382
9909	27/12/2017 12.39.40	252,5	253,8528	0,1920	1,3449
9910	27/12/2017 13.09.40	253,0	253,8528	0,1912	0,8496
9911	27/12/2017 13.39.40	253,5	253,8528	0,1904	0,3521
9912	27/12/2017 14.00.50	253,852778	253,8528	0,1898	0,0000

Tabel 4. 18 Rekap Hasil Perhitungan MRL (*RF equipment*)

No	Tanggal dan Waktu	Waktu ke-t (Jam)	TTF	R(t)	MRL (t) (Jam)
1	01/01/2017 00.00.00	0,0	11,64444	1,0000	11,0752
2	01/01/2017 00.30.00	0,5	11,64444	0,9995	10,5808
3	01/01/2017 01.00.00	1,0	11,64444	0,9982	10,0940
4	01/01/2017 01.30.00	1,5	11,64444	0,9963	9,6127
5	01/01/2017 02.00.00	2,0	11,64444	0,9938	9,1359
...
7915	29/12/2017 06.44.00	32,0	33,84722	0,4253	1,7673
7916	29/12/2017 07.14.00	32,5	33,84722	0,4152	1,3040
7917	29/12/2017 07.44.00	33,0	33,84722	0,4053	0,8298
7918	29/12/2017 08.14.00	33,5	33,84722	0,3955	0,3442
7919	29/12/2017 08.34.50	33,84722	33,84722	0,3888	0,0000

Tabel 4. 19 Rekap Hasil Perhitungan MRL (*MBE equipment*)

No	Tanggal dan Waktu	Waktu ke-t (Jam)	TTF	R(t)	MRL (t) (Jam)
1	01/01/2017 00.00.00	0,0	11,64444	1,0000	8,1981
2	01/01/2017 00.30.00	0,5	11,64444	0,9736	7,9133
3	01/01/2017 01.00.00	1,0	11,64444	0,9453	7,6424
4	01/01/2017 01.30.00	1,5	11,64444	0,9169	7,3719
5	01/01/2017 02.00.00	2,0	11,64444	0,8886	7,0986
...
7991	31/12/2017 06.50.00	11,0	12,72778	0,4800	1,6249
7992	31/12/2017 07.20.00	11,5	12,72778	0,4631	1,1751
7993	31/12/2017 07.50.00	12,0	12,72778	0,4468	0,7089
7994	31/12/2017 08.20.00	12,5	12,72778	0,4310	0,2258
7995	31/12/2017 08.33.40	12,72778	12,72778	0,4240	0,0000

Berdasarkan data pada Tabel 4.16 – 4.19, data MRL (t) yang diperoleh dari masing-masing *equipment* secara berturut-turut mulai dari *motor belt conveyor*, *sealing air fan*, *rotary feeder*, dan *motor bucket elevator* adalah 8059 data, 9912 data, 7919 data, dan 7995 data. Dimana keseluruhan data tersebut akan digunakan sebagai variabel respon untuk penyusunan model prediksi.

4.5 Rekap Data *Input* Penyusunan Model

Data *input* untuk penyusunan model terdiri dari dua variabel yaitu variabel prediktor dan variabel respon. Variabel prediktor meliputi waktu *monitoring* sensor dan data *monitoring* sensor, sedangkan nilai MRL (t) digunakan sebagai variabel respon. Tabel 4.20 – 4.23 menunjukkan rekap data *input* untuk tahap perancangan model pada setiap *equipment*. Dimana total data yang digunakan untuk *MBC*, *SAF*, *RF* dan *MBE equipment* secara berturut-turut adalah 8059, 9912, 7919, dan 7995 data yang terdiri dari tiga variabel prediktor dan satu variabel respon.

Tabel 4. 20 Rekap Data *Input* Penyusunan Model (*MBC equipment*)

No	Waktu ke-t (Jam)	Variabel Prediktor		Variabel Respon
		Monitoring Sensor	Sensor RPM (<i>MBC</i>) (%)	
1	0,0	41	1,7	8,2266
2	0,5	40	1,9	7,9392
3	1,0	41	2,6	7,6661
4	1,5	46	2,1	7,3936
5	2,0	44	1,6	7,1183
...
8055	11,55833	0	0,2	0,0000
8056	0,0	45	0,1	1,1618
8057	0,5	36	0,1	0,6859
8058	1,0	35	0,1	0,1987
8059	1,2	10	0,2	0,0000

Tabel 4. 21 Rekap Data *Input* Penyusunan Model (*SAF equipment*)

No	Waktu ke-t (Jam)	Variabel Prediktor		Variabel Respon
		Monitoring Sensor	Sensor Tekanan (<i>SAF</i>) (milibar)	
1	0,0	27	1,7	153,9707
2	0,5	27	1,9	153,5486
3	1,0	28	2,6	153,1622
4	1,5	25	2,1	152,7945
5	2,0	26	1,6	152,4406
...
9908	252,0	49	0,1	1,8382
9909	252,5	48	0,1	1,3449
9910	253,0	48	0,1	0,8496
9911	253,5	48	0,1	0,3521
9912	253,852778	4	0,1	0,0000

Tabel 4. 22 Rekap Data *Input* Penyusunan Model (*RF equipment*)

No	Waktu ke-t (Jam)	Variabel Prediktor		Variabel Respon MRL (t) (Jam)	
		Monitoring Sensor			
		Sensor RPM (RF) (%)	Sensor Vibrasi (mm/s)		
1	0,0	40	1,7	11,0752	
2	0,5	41	1,9	10,5808	
3	1,0	41	2,6	10,0940	
4	1,5	41	2,1	9,6127	
5	2,0	40	1,6	9,1359	
...	
7915	32,0	40	2,3	1,7673	
7916	32,5	41	2,2	1,3040	
7917	33,0	39	1,9	0,8298	
7918	33,5	41	0,1	0,3442	
7919	33,84722	0	0,1	0,0000	

Tabel 4. 23 Rekap Data *Input* Penyusunan Model (*MBE equipment*)

No	Waktu ke-t (Jam)	Variabel Prediktor		Variabel Respon MRL (t) (Jam)	
		Monitoring Sensor			
		Sensor RPM (MBE) (%)	Sensor Vibrasi (mm/s)		
1	0,0	47	1,7	8,1981	
2	0,5	45	1,9	7,9133	
3	1,0	44	2,6	7,6424	
4	1,5	51	2,1	7,3719	
5	2,0	54	1,6	7,0986	
...	
7991	11,0	43	2	1,6249	
7992	11,5	39	1,8	1,1751	
7993	12,0	39	1,6	0,7089	
7994	12,5	44	1,9	0,2258	
7995	12,72778	0	0,2	0,0000	

4.6 Transformasi Data (*Data Transformation*)

Transformasi data digunakan untuk mengubah nilai data pada setiap variabel, baik variabel prediktor maupun variabel respon, ke dalam skala nilai yang sama. Sebelum dilakukan data transformasi setiap data variabel memiliki rentang nilai yang berbeda-beda, seperti data variabel sensor RPM MBC memiliki nilai minimal dan maksimal berturut-turut adalah 0 dan 99 sedangkan variabel sensor vibrasi memiliki nilai maksimal dan minimal berturut-turut adalah 0 dan 10. Dalam tahap ini perbedaan skala tersebut akan disetarkan. Hasil akhir dari tahap ini adalah seluruh variabel untuk penyusunan model berada dalam rentang 0 hingga 1. Detail koding untuk transformasi data dapat dilihat pada lampiran C. Tabel 5.1 hingga 5.4 menunjukkan data variabel setelah dilakukan *scaling* untuk setiap *equipment*.

Tabel 4. 24 Rekap Data Input Setelah Scaling (*MBC equipment*)

No	Variabel Prediktor			Variabel Respon MRL (t)	
	Waktu ke-t	Monitoring Sensor			
		Sensor RPM (MBC)	Sensor Vibrasi		
1	0,0000	0,4141	0,2982	0,5875	
2	0,0107	0,4040	0,3333	0,5670	
3	0,0215	0,4141	0,4561	0,5475	
4	0,0322	0,4646	0,3684	0,5281	
5	0,0429	0,4444	0,2807	0,5084	
...	
8055	0,2480	0,0000	0,0351	0,0000	
8056	0,0000	0,4545	0,0175	0,0830	
8057	0,0107	0,3636	0,0175	0,0490	
8058	0,0215	0,3535	0,0175	0,0142	
8059	0,0257	0,1010	0,0351	0,0000	

Tabel 4. 25 Rekap Data Input Setelah Scaling (*SAF equipment*)

No	Variabel Prediktor			Variabel Respon MRL (t)	
	Waktu ke-t	Monitoring Sensor			
		Sensor Tekanan (SAF)	Sensor Vibrasi		
1	0,0000	0,5283	0,3036	0,9974	
2	0,0012	0,5283	0,3393	0,9947	
3	0,0024	0,5472	0,4643	0,9922	
4	0,0036	0,4906	0,3750	0,9898	
5	0,0049	0,5094	0,2857	0,9875	
...	
9908	0,6117	0,9434	0,0179	0,0119	
9909	0,6129	0,9245	0,0179	0,0087	
9910	0,6141	0,9245	0,0179	0,0055	
9911	0,6153	0,9245	0,0179	0,0023	
9912	0,6161	0,0943	0,0179	0,0000	

Tabel 4. 26 Rekap Data Input Setelah Scaling (*RF equipment*)

No	Variabel Prediktor			Variabel Respon MRL (t)	
	Waktu ke-t	Monitoring Sensor			
		Sensor RPM (RF)	Sensor Vibrasi		
1	0,0000	0,6250	0,3469	0,3585	
2	0,0067	0,6406	0,3878	0,3425	
3	0,0133	0,6406	0,5306	0,3268	
4	0,0200	0,6406	0,4286	0,3112	
5	0,0267	0,6250	0,3265	0,2957	
...	
7915	0,4272	0,6250	0,4694	0,0572	
7916	0,4339	0,6406	0,4490	0,0422	
7917	0,4405	0,6094	0,3878	0,0269	
7918	0,4472	0,6406	0,0204	0,0111	
7919	0,4518	0,0000	0,0204	0,0000	

Tabel 4. 27 Rekap Data Input Setelah Scaling (*MBE equipment*)

No	Variabel Prediktor			Variabel Respon MRL (t)	
	Waktu ke-t	Monitoring Sensor			
		Sensor RPM (MBE)	Sensor Vibrasi		
1	0,0000	0,1122	0,3333	0,5916	

No	Variabel Prediktor			Variabel Respon MRL (t)	
	Waktu ke-t	Monitoring Sensor			
		Sensor RPM (MBE)	Sensor Vibrasi		
2	0,0110	0,1074	0,3725	0,5711	
3	0,0220	0,1050	0,5098	0,5515	
4	0,0331	0,1217	0,4118	0,5320	
5	0,0441	0,1289	0,3137	0,5123	
...	
7991	0,2425	0,1026	0,3922	0,1173	
7992	0,2535	0,0931	0,3529	0,0848	
7993	0,2645	0,0931	0,3137	0,0512	
7994	0,2755	0,1050	0,3725	0,0163	
7995	0,2806	0,0000	0,0392	0,0000	

4.7 Data training, Data validation & Data testing

Model yang digunakan dalam penelitian ini termasuk ke dalam kategori *supervised learning* dimana dibutuhkan *data training* untuk proses penyusunan atau bahan belajar model, *data validation* untuk *parameter tuning*, serta *data testing* untuk menguji model. Pembagian *data training* dan *data testing* dilakukan sesuai dengan prosedur pada subab 3.1.6. Data yang digunakan berbentuk *time series* sehingga pembagian *data training*, *data validation* dan *data testing* dilakukan secara berurutan.

Dalam penelitian ini *data training* dan *data validation* akan digunakan pada tahap penyusunan model untuk mencari nilai parameter optimal pada setiap model. Sedangkan *data testing* murni digunakan untuk pengukuran performansi model pada tahap evaluasi model. Tabel 4.28 – 4.31 menunjukkan rincian pembagian *data training*, *data validation* dan *data testing* untuk setiap *equipment*.

Tabel 4. 28 *Data training, Validation dan Testing (MBC equipment)*

Fold	<i>Data training</i>		<i>Data validation</i>		<i>Data testing</i>	
	Urutan	Jumlah Data	Urutan	Jumlah Data	Urutan	Jumlah Data
1	1 - 3324	3224	3225 - 4030	806	4031 - 4836	806
2	1 - 4030	4030	4031 - 4836	806	4837 - 5642	806
3	1 - 4836	4836	4837 - 5642	806	5643 - 6448	806
4	1 - 5642	5642	5643 - 6448	806	6449 - 7254	806
5	1 - 6448	6448	6449 - 7254	806	7255 - 8059	805

Setiap partisi pada *MBC equipment* memiliki 806 data dan partisi terakhir memiliki 805 data.

Tabel 4. 29 *Data training, Validation dan Testing (SAF equipment)*

Fold	Data training		Data validation		Data testing	
	Urutan	Jumlah Data	Urutan	Jumlah Data	Urutan	Jumlah Data
1	1 - 3964	3964	3965 - 4955	991	4956 - 5946	991
2	1 - 4955	4955	4956 - 5946	991	5947 - 6937	991
3	1 - 5946	5946	5947 - 6937	991	6938 - 7928	991
4	1 - 6937	6937	6938 - 7928	991	7929 - 8919	991
5	1 - 7928	7928	7929 - 8919	991	8920 - 9912	993

Setiap partisi pada *SAF equipment* memiliki 991 data dan partisi terakhir memiliki 993 data.

Tabel 4. 30 *Data training, Validation dan Testing (RF equipment)*

Fold	Data training		Data validation		Data testing	
	Urutan	Jumlah Data	Urutan	Jumlah Data	Urutan	Jumlah Data
1	1 - 3168	3168	3169 - 3960	792	3961 - 4752	792
2	1 - 3960	3960	3961 - 4752	792	4753 - 5544	792
3	1 - 4752	4752	4752 - 5544	792	5545 - 6336	792
4	1 - 5544	5544	5545 - 6336	792	6337 - 7128	792
5	1 - 6336	6336	6337 - 7128	792	7129 - 7919	791

Setiap partisi pada *RF equipment* memiliki 792 data dan partisi terakhir memiliki 791 data.

Tabel 4. 31 *Data training, Validation dan Testing (MBE equipment)*

Fold	Data training		Data validation		Data testing	
	Urutan	Jumlah Data	Urutan	Jumlah Data	Urutan	Jumlah Data
1	1 - 3200	3200	3201 - 4000	800	4001 - 4800	800
2	1 - 4000	4000	4001 - 4800	800	4081 - 5600	800
3	1 - 4800	4800	4081 - 5600	800	5601 - 6400	800
4	1 - 5600	5600	5601 - 6400	800	6041 - 7200	800
5	1 - 6400	6400	6041 - 7200	800	7201 - 7995	795

Setiap partisi pada *MBE equipment* memiliki 800 data dan partisi terakhir memiliki 795 data.

(Halaman ini sengaja dikosongkan)

BAB 5

PENYUSUNAN MODEL

Pada bab ini dijelaskan mengenai penyusunan model prediksi waktu kegagalan setiap *equipment*, meliputi model *support vector regression* (SVR) dan *artificial neural network* (ANN). Tujuan dari tahap ini adalah untuk menentukan nilai parameter optimal pada setiap model prediksi.

5.1 Penentuan Nilai Parameter Uji Coba

Tabel 5.1 dan 5.2 menunjukkan nilai parameter yang digunakan dalam uji coba untuk menentukan parameter optimal model ANN dan SVR pada setiap *equipment*.

Tabel 5. 1 Nilai Parameter Uji Model SVR

<i>Gamma</i> (γ)	<i>Cost of Constraints</i> (C)	<i>Insensitive-loss function</i> (<i>epsilon</i> , ϵ)	Jenis kernel
0,001	0,1	0,4	<i>Radial basis</i>
0,01	1	0,6	<i>Sigmoid</i>
0,1	10	0,8	<i>Linear</i>
1	100	1	
10	1000	1,2	

Berdasarkan Tabel 5.1, pada model SVR terdapat tiga macam parameter uji yaitu nilai *gamma* (γ), *cost of constrain* (c), dan *insensitive-loss function* (*epsilon*) dimana terdapat lima *level* pada masing-masing parameter. Selain itu terdapat tiga jenis kernel yang digunakan dalam penentuan model SVR optimal. Penentuan nilai parameter dilakukan dengan meninjau beberapa refensi. Selain itu beberapa penyesuaian dilakukan oleh penulis. Menurut Arenas & Perez (2003), penentuan nilai C dan γ harus lebih besar dari nol, sehingga range dari kedua parameter berada pada interval $(0, \infty)$. Selain itu pada penelitian Saputra et al. (2019), menunjukkan bahwa parameter *epsilon* yang digunakan bernilai positif. Pemilihan jumlah level sebanyak 5 untuk setiap parameter mengacu pada penelitian Prangga (2017), penelitian tersebut menggunakan faktor sebanyak 5 level pada setiap parameter. Adapun beberapa penelitian yang dijadikan dasar dalam penentuan nilai parameter adalah penelitian oleh Rifqi et al., (2018), dengan C =

$\{0,0001; 0,0005; 0,001; 0,005; 0,01; 0,05; 0,1; 1,100; 200\}$ dan $epsilon = \{0,000001; 0,000005; 0,00001; 0,00005; 0,0001; 0,0005; \dots; 0,1\}$. Penelitian oleh Saputra et al. (2019) dengan $\gamma = \{2^{-7}; \dots; 2^1\}$, $C = \{1,2; \dots; 20\}$, dan $epsilon = \{0,001; \dots; 0,3\}$. Sedangkan ketiga jenis *kernel* dipilih berdasarkan uji coba penulis pada seluruh jenis kernel. Kernel *polynomial* membutuhkan waktu komputasi yang sangat lama $\pm 2,5$ jam untuk satu *fold*. Sehingga *kernel* tersebut tidak digunakan dalam penelitian ini.

Tabel 5. 2 Nilai Parameter Uji Model ANN

Threshold	Jumlah Hidden layer	Jumlah neuron pada hidden layer	Jenis Activation function
0,01	1	1	<i>Logistic</i>
0,1	2	2	<i>Tan hyperbolic</i>
	3	3	
		4	
		5	

Berdasarkan Tabel 5.2, pada model ANN terdapat tiga macam parameter yang diuji coba nilainya dalam penelitian ini yaitu nilai *threshold*, jumlah *hidden layer*, dan jumlah *neuron* pada setiap *hidden layer*. Selain itu terdapat dua *activation function* yang digunakan, *logistic* dan *tan hyperbolik*. Menurut Santosa dan Umam (2018), semakin kecil nilai *threshold* maka semakin minimal fungsi objektif yang diperoleh, namun dapat mengakibatkan *overfitting*. Selain itu berdasarkan uji coba yang dilakukan penulis, nilai $threshold < 0,01$, menyebabkan *error* pada komputasi karena algoritma tidak mencapai titik *convergence* meskipun telah mencapai *max steps* (100.000 kali iterasi). Penentuan jumlah *hidden layer* dan *neuron* juga didasarkan pada uji coba yang dilakukan oleh penulis. Jumlah neuron yang digunakan secara total untuk seluruh *hidden layer* adalah 5 *neuron*. Penentuan jumlah tersebut didasarkan bahwa uji coba dengan jumlah *neuron* lebih dari 5 dapat menyebabkan *error* pada komputasi, dengan alasan yang sama dengan sebelumnya. Sedangkan kedua jenis *activation function* dipilih karena, pada *package* ‘*neuralnet*’ dalam *software R studio* yang digunakan oleh penulis hanya menyediakan dua jenis *activation function* tersebut.

5.2 Penentuan Parameter Optimal Model Prediksi

Penentuan parameter optimal dilakukan dengan metode *grid search* untuk melakukan kombinasi nilai parameter yang telah ditentukan pada subab 5.1. Selain itu *nested cross validation* digunakan untuk validasi model, dengan melakukan evaluasi model sebanyak 5-fold / iterasi. Dalam penentuan parameter optimal perlu dilakukan penyusunan algoritma model prediksi ke dalam bahasa pemrograman dengan menggunakan *software R studio*. *Package* yang digunakan untuk penyusunan model SVR dan ANN pada *software R studio* secara berturut-turut adalah *package e1071* dan *package neuralnet*. Koding *grid search* untuk masing-masing model prediksi dapat dilihat pada lampiran D.

5.2.1 Model Prediksi *Motor Belt Conveyor (MBC) Equipment*

Pada subab ini dijelaskan mengenai penentuan parameter optimal model SVR dan ANN pada *motor belt conveyor equipment*.

A. Penentuan parameter optimal model *Support Vector Regression (SVR)*

Pada Tabel 5.3 hingga 5.5 menunjukkan hasil perhitungan nilai *error* (RMSE) untuk setiap kombinasi parameter model SVR baik pada *data validation* maupun *data training* serta perbandingan rata-rata RMSE untuk kedua data tersebut.

Tabel 5. 3 RMSE *Data validation* Model SVR (*MBC equipment*)

No	Kernel	γ	C	ε	RMSE <i>Data validation</i> (jam)					
					Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Rata-rata
1	<i>Radial Basis</i>	0,01	1000	0,8	3,6210	3,5294	3,4444	3,6831	3,6549	3,5865
2	<i>Radial Basis</i>	0,01	100	0,8	3,6468	3,5254	3,4633	3,6768	3,6330	3,5891
3	<i>Radial Basis</i>	0,01	1000	0,6	3,6492	3,5486	3,4649	3,6365	3,6507	3,5900
4	<i>Radial Basis</i>	0,01	100	0,4	3,6328	3,5531	3,4970	3,6336	3,6341	3,5901
5	<i>Radial Basis</i>	0,01	100	0,6	3,6590	3,5519	3,4830	3,6309	3,6265	3,5902
...
371	<i>Sigmoid</i>	10,00	1000	0,6	$1,9 \cdot 10^6$	$2,6 \cdot 10^6$	$3,0 \cdot 10^6$	$3,3 \cdot 10^6$	$3,7 \cdot 10^6$	$2,9 \cdot 10^6$
372	<i>Sigmoid</i>	10,00	1000	0,4	$1,9 \cdot 10^6$	$2,6 \cdot 10^6$	$3,0 \cdot 10^6$	$3,3 \cdot 10^6$	$3,7 \cdot 10^6$	$2,9 \cdot 10^6$
373	<i>Sigmoid</i>	10,00	1000	0,8	$1,9 \cdot 10^6$	$2,6 \cdot 10^6$	$3,0 \cdot 10^6$	$3,3 \cdot 10^6$	$3,7 \cdot 10^6$	$2,9 \cdot 10^6$
374	<i>Sigmoid</i>	10,00	1000	1	$1,9 \cdot 10^6$	$2,6 \cdot 10^6$	$3,0 \cdot 10^6$	$3,3 \cdot 10^6$	$3,7 \cdot 10^6$	$2,9 \cdot 10^6$
375	<i>Sigmoid</i>	10,00	1000	1,2	$1,9 \cdot 10^6$	$2,6 \cdot 10^6$	$3,0 \cdot 10^6$	$3,3 \cdot 10^6$	$3,7 \cdot 10^6$	$2,9 \cdot 10^6$

Tabel 5. 4 RMSE Data training Model SVR (*MBC equipment*)

No	Kernel	γ	C	ϵ	RMSE Data training (jam)					
					Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Rata-rata
1	<i>Radial Basis</i>	0,01	1000	0,8	3,6846	3,6571	3,6382	3,6107	3,6149	3,6411
2	<i>Radial Basis</i>	0,01	100	0,8	3,7068	3,6652	3,6474	3,6201	3,6228	3,6525
3	<i>Radial Basis</i>	0,01	1000	0,6	3,6819	3,6614	3,6416	3,6120	3,6231	3,6440
4	<i>Radial Basis</i>	0,01	100	0,4	3,7001	3,6779	3,6564	3,6265	3,6413	3,6604
5	<i>Radial Basis</i>	0,01	100	0,6	3,7009	3,6810	3,6564	3,6204	3,6296	3,6577
...
371	<i>Sigmoid</i>	10,00	1000	0,6	$1,8 \cdot 10^6$	$2,3 \cdot 10^6$	$2,8 \cdot 10^6$	$3,3 \cdot 10^6$	$3,8 \cdot 10^6$	$2,8 \cdot 10^6$
372	<i>Sigmoid</i>	10,00	1000	0,4	$1,8 \cdot 10^6$	$2,3 \cdot 10^6$	$2,8 \cdot 10^6$	$3,3 \cdot 10^6$	$3,8 \cdot 10^6$	$2,8 \cdot 10^6$
373	<i>Sigmoid</i>	10,00	1000	0,8	$1,8 \cdot 10^6$	$2,3 \cdot 10^6$	$2,8 \cdot 10^6$	$3,3 \cdot 10^6$	$3,8 \cdot 10^6$	$2,8 \cdot 10^6$
374	<i>Sigmoid</i>	10,00	1000	1	$1,8 \cdot 10^6$	$2,3 \cdot 10^6$	$2,8 \cdot 10^6$	$3,3 \cdot 10^6$	$3,8 \cdot 10^6$	$2,8 \cdot 10^6$
375	<i>Sigmoid</i>	10,00	1000	1,2	$1,8 \cdot 10^6$	$2,3 \cdot 10^6$	$2,8 \cdot 10^6$	$3,3 \cdot 10^6$	$3,8 \cdot 10^6$	$2,8 \cdot 10^6$

Tabel 5. 5 Perbandingan RMSE Data validation dan Training Model SVR (*MBC equipment*)

No	Kernel	Gamma	Cost	Epsilon	Rata-rata RMSE (jam)		Selisih (Data validation – Data training)
					Data validation	Data training	
1	<i>Radial Basis</i>	0,01	1000	0,8	3,5865	3,6411	-0,05456
2	<i>Radial Basis</i>	0,01	100	0,8	3,5891	3,6525	-0,0634
3	<i>Radial Basis</i>	0,01	1000	0,6	3,5900	3,6440	-0,05403
4	<i>Radial Basis</i>	0,01	100	0,4	3,5901	3,6604	-0,07028
5	<i>Radial Basis</i>	0,01	100	0,6	3,5902	3,6577	-0,06741
...
371	<i>Sigmoid</i>	10,00	1000	0,6	2930841,7	2841906,9	88935
372	<i>Sigmoid</i>	10,00	1000	0,4	2930864,4	2841915,5	88949
373	<i>Sigmoid</i>	10,00	1000	0,8	2930864,6	2841915,6	88949
374	<i>Sigmoid</i>	10,00	1000	0,6	2930864,8	2841915,6	88949
375	<i>Sigmoid</i>	10,00	1000	0,4	2930864,9	2841915,6	88949

Tabel 5.3 menunjukkan parameter model SVR dengan rata-rata RMSE *data validation* terkecil adalah pada kombinasi nomor 1, $gamma = 0,01$; $cost = 1000$; $epsilon = 0,8$ dan $kernel = radial basis$. Dimana menghasilkan RMSE sebesar 3,5865 jam. Selain itu, meninjau hasil perbandingan rata-rata RMSE *data validation* dan *data training* pada Tabel 5.5, menunjukkan bahwa rata-rata RMSE *data validation* memiliki nilai yang lebih kecil dibandingkan dengan RMSE *data*

training. Terlihat pada kolom selisih menunjukkan hasil negatif. Kondisi tersebut mengindikasikan bahwa kombinasi nomor 1 tidak menyebabkan *overfitting* pada model SVR. Berdasarkan alasan tersebut, maka kombinasi parameter nomor 1, dengan $gamma = 0,01$; $cost = 1000$; $epsilon = 0,8$ dan *kernel radial basis* dipilih untuk menyusun model SVR pada *MBC equipment*.

B. Penentuan parameter optimal model *Artificial Neural Network* (ANN)

Tabel 5.6 hingga 5.8 menunjukkan hasil perhitungan nilai *error* (RMSE) untuk setiap kombinasi parameter model ANN, baik pada *data validation* maupun *data training* serta perbandingan rata-rata RMSE untuk kedua data tersebut.

Tabel 5. 6 RMSE Data validation Model ANN (*MBC equipment*)

No	Act. Func.	Threshold	Hidden Layer	Jumlah Neuron Setiap Hidden Layer			RMSE Data validation (jam)					Rata-rata
				Layer 1	Layer 2	Layer 3	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	
1	<i>Logistic</i>	0,01	1	3			3,629185	3,556021	3,46152	3,67165	3,650779	3,593831
2	<i>Logistic</i>	0,1	2	3	1		3,634923	3,538591	3,480774	3,674733	3,645008	3,594806
3	<i>Logistic</i>	0,1	1	4			3,659798	3,539339	3,457872	3,695441	3,666502	3,603791
4	<i>Tanh</i>	0,01	1	1			3,632344	3,555657	3,4645	3,735658	3,643419	3,606315
5	<i>Tanh</i>	0,1	3	2	1	1	3,632157	3,565503	3,480538	3,709497	3,64454	3,606447
...
96	<i>Tanh</i>	0,01	3	1	3	1	-	-	-	-	-	-
97	<i>Tanh</i>	0,01	3	2	1	1	-	-	-	-	-	-
98	<i>Tanh</i>	0,01	3	2	1	2	-	-	-	-	-	-
99	<i>Tanh</i>	0,01	3	2	2	1	-	-	-	-	-	-
100	<i>Tanh</i>	0,01	3	3	1	1	-	-	-	-	-	-

Tabel 5. 7 RMSE Data training Model ANN (*MBC equipment*)

No	Act. Func.	Threshold	Hidden Layer	Jumlah Neuron Setiap Hidden Layer			RMSE Data training (jam)					Rata-rata
				Layer 1	Layer 2	Layer 3	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	
1	<i>Logistic</i>	0,01	1	3			3,6842567	3,6630652	3,6411849	3,6085013	3,6159673	3,6425951
2	<i>Logistic</i>	0,1	2	3	1		3,6844344	3,6683779	3,6470037	3,6018272	3,6050765	3,6413439
3	<i>Logistic</i>	0,1	1	4			3,6981616	3,6606716	3,6551238	3,5988181	3,6069132	3,6439377
4	<i>Tanh</i>	0,01	1	1			3,6912162	3,6495912	3,6376584	3,5978666	3,6118015	3,6376268
5	<i>Tanh</i>	0,1	3	2	1	1	3,7099589	3,6618327	3,6493803	3,6200909	3,6302354	3,6542997
...
96	<i>Tanh</i>	0,01	3	1	3	1	-	-	-	-	-	-
97	<i>Tanh</i>	0,01	3	2	1	1	-	-	-	-	-	-
98	<i>Tanh</i>	0,01	3	2	1	2	-	-	-	-	-	-
99	<i>Tanh</i>	0,01	3	2	2	1	-	-	-	-	-	-
100	<i>Tanh</i>	0,01	3	3	1	1	-	-	-	-	-	-

Tabel 5. 8 Perbandingan RMSE *Data validation* dan *Training Model ANN (MBC equipment)*

No	Act. Func.	Thrs	Hidden Layer	Jumlah Neuron			Rata-rata RMSE (jam)		(Data valid – Data training)
				Layer 1	Layer 2	Layer 3	Data validation	Data training	
1	<i>Logistic</i>	0,01	1	3			3,593831	3,6425	-0,04876
2	<i>Logistic</i>	0,1	2	3	1		3,594806	3,6413	-0,04654
3	<i>Logistic</i>	0,1	1	4			3,603791	3,6439	-0,04015
4	<i>Tanh</i>	0,01	1	1			3,606315	3,6376	-0,03131
5	<i>Tanh</i>	0,1	3	2	1	1	3,606447	3,6542	-0,04785
...
97	<i>Tanh</i>	0,01	3	2	1	1	-	-	-
98	<i>Tanh</i>	0,01	3	2	1	2	-	-	-
99	<i>Tanh</i>	0,01	3	2	2	1	-	-	-
100	<i>Tanh</i>	0,01	3	3	1	1	-	-	-

Tabel 5.6 menunjukkan kombinasi parameter model ANN dengan rata-rata RMSE *data validation* terkecil adalah pada kombinasi nomor 1, *threshold* = 0,01; jumlah *hidden layer* = 1; jumlah *neuron* dalam *hidden layer* = 3 dan *activation function* = *logistic*. Dimana menghasilkan RMSE sebesar 3,593 jam. Selain itu, berdasarkan hasil perbandingan rata-rata RMSE *data validation* dan *data training* pada Tabel 5.8, menunjukkan bahwa rata-rata RMSE *data validation* lebih kecil dibandingkan dengan rata-rata RMSE *data training*. Terlihat pada kolom selisih menunjukkan hasil negatif. Hal tersebut mengindikasikan bahwa kombinasi parameter nomor 1 tidak menyebabkan *overfitting* pada model ANN. Berdasarkan alasan tersebut, maka kombinasi parameter nomor 1 dengan *threshold* = 0,01; jumlah *hidden layer* = 1; jumlah *neuron* dalam *hidden layer* = 3 dan *activation function* = *logistic* dipilih untuk menyusun model ANN pada *MBC equipment*.

5.2.2 Model Prediksi Sealing Air Fan (SAF) Equipment

Pada subab ini dijelaskan mengenai penentuan parameter optimal model SVR dan ANN pada *sealing air fan equipment*.

A. Penentuan parameter optimal model *Support Vector Regression (SVR)*

Pada Tabel 5.9 hingga 5.11 menunjukkan hasil perhitungan nilai *error* (RMSE) untuk setiap kombinasi parameter model SVR, baik pada *data validation* maupun *data training* serta perbandingan rata-rata RMSE untuk kedua data tersebut.

Tabel 5. 9 RMSE Data validation Model SVR (SAF equipment)

No	Kernel	γ	C	ϵ	RMSE Data validation (jam)					
					Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Rata-rata
1	Radial Basis	0,001	1000	1	34,6539	30,5369	48,4252	36,1923	41,1517	38,1920
2	Radial Basis	0,01	10	1	34,8098	30,5522	48,4913	36,1623	41,1351	38,2301
3	Radial Basis	0,01	1	1	33,5584	31,0970	48,6339	36,6234	41,2558	38,2337
4	Radial Basis	0,10	0,1	1	35,1839	30,5475	48,4862	35,9981	41,0607	38,2553
5	Radial Basis	0,001	100	1	33,5582	30,9790	48,6693	36,8286	41,2806	38,2631
...
278	Sigmoid	0,10	0,1	1,2	35,4152	30,1801	50,7621	38,8331	59,5772	42,9535
...
372	Sigmoid	10,0	1000	1	$1,7 \cdot 10^7$	$2,3 \cdot 10^7$	$2,3 \cdot 10^7$	$4,7 \cdot 10^7$	$4,4 \cdot 10^7$	$3,1 \cdot 10^7$
373	Sigmoid	10,0	1000	0,8	$1,7 \cdot 10^7$	$2,3 \cdot 10^7$	$2,3 \cdot 10^7$	$4,7 \cdot 10^7$	$4,4 \cdot 10^7$	$3,1 \cdot 10^7$
374	Sigmoid	10,0	1000	0,6	$1,7 \cdot 10^7$	$2,3 \cdot 10^7$	$2,3 \cdot 10^7$	$4,7 \cdot 10^7$	$4,4 \cdot 10^7$	$3,1 \cdot 10^7$
375	Sigmoid	10,0	1000	0,4	$1,7 \cdot 10^7$	$2,3 \cdot 10^7$	$2,3 \cdot 10^7$	$4,7 \cdot 10^7$	$4,4 \cdot 10^7$	$3,1 \cdot 10^7$

Tabel 5. 10 RMSE Data training Model SVR (SAF equipment)

No	Kernel	γ	C	ϵ	RMSE Data training (jam)					
					Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Rata-rata
1	Radial Basis	0,001	1000	1	35,5969	34,6967	34,0111	36,3181	36,2395	35,3725
2	Radial Basis	0,01	10	1	35,5706	34,7081	34,0008	36,3096	36,2106	35,3599
3	Radial Basis	0,01	1	1	35,7208	34,8099	34,1500	36,4282	36,3063	35,4830
4	Radial Basis	0,10	0,1	1	35,4545	34,7766	34,0360	36,3145	36,1956	35,3554
5	Radial Basis	0,001	100	1	35,7004	34,8069	34,1359	36,4195	36,2987	35,4723
...
278	Sigmoid	0,10	0,1	1,2	36,2773	35,5876	43,9435	37,1923	63,1679	43,2337
...
372	Sigmoid	10,0	1000	1	$2,2 \cdot 10^7$	$2,7 \cdot 10^7$	$3,4 \cdot 10^7$	$3,8 \cdot 10^7$	$4,4 \cdot 10^7$	$3,3 \cdot 10^7$
373	Sigmoid	10,0	1000	0,8	$2,2 \cdot 10^7$	$2,7 \cdot 10^7$	$3,4 \cdot 10^7$	$3,8 \cdot 10^7$	$4,4 \cdot 10^7$	$3,3 \cdot 10^7$
374	Sigmoid	10,0	1000	0,6	$2,2 \cdot 10^7$	$2,7 \cdot 10^7$	$3,4 \cdot 10^7$	$3,8 \cdot 10^7$	$4,4 \cdot 10^7$	$3,3 \cdot 10^7$
375	Sigmoid	10,0	1000	0,4	$2,2 \cdot 10^7$	$2,7 \cdot 10^7$	$3,4 \cdot 10^7$	$3,8 \cdot 10^7$	$4,4 \cdot 10^7$	$3,3 \cdot 10^7$

Tabel 5. 11 Perbandingan RMSE Data validation dan Training Model SVR (SAF equipment)

No	Kernel	Gamma	Cost	Epsilon	Rata-rata RMSE (jam)		Selisih (Data validation – Data training)
					Data validation	Data training	
1	Radial Basis	0,001	1000	1	38,1920	35,3725	2,819553
2	Radial Basis	0,01	10	1	38,2301	35,3599	2,870193

No	Kernel	Gamma	Cost	Epsilon	Rata-rata RMSE (jam)		Selisih (Data validation – Data training)
					Data validation	Data training	
3	Radial Basis	0,01	1	1	38,2337	35,4830	2,750679
4	Radial Basis	0,10	0,1	1	38,2553	35,3554	2,899859
5	Radial Basis	0,001	100	1	38,2631	35,4723	2,790857
...
278	Sigmoid	0,10	0,1	1,2	42,9535	43,2337	-0,28015
...
372	Sigmoid	10,0	1000	1	$3,1 \cdot 10^7$	$3,3 \cdot 10^7$	-2283490
373	Sigmoid	10,0	1000	0,8	$3,1 \cdot 10^7$	$3,3 \cdot 10^7$	-2283489
374	Sigmoid	10,0	1000	0,6	$3,1 \cdot 10^7$	$3,3 \cdot 10^7$	-2283487
375	Sigmoid	10,0	1000	0,4	$3,1 \cdot 10^7$	$3,3 \cdot 10^7$	-2283486

Tabel 5.9 menunjukkan bahwa kombinasi parameter model SVR dengan nilai rata-rata RMSE terkecil adalah kombinasi nomor 1, $gamma = 0,001$; $cost = 1000$; $epsilon = 1$ dan $kernel = radial basis$. Dimana menghasilkan RMSE sebesar 38,1920 jam. Namun, berdasarkan Tabel 5.11, kombinasi nomor 1 menghasilkan rata-rata RMSE *data validation* yang lebih besar dibandingkan dengan rata-rata RMSE *data training*. Terlihat pada kolom selisih menunjukkan angka positif. Hal tersebut mengindikasikan bahwa kombinasi nomor 1 dapat menyebabkan *overfitting* pada model SVR. Untuk menghindari terjadinya *overfitting* pada model, maka dipilih parameter dengan nilai rata-rata RMSE *data validation* yang lebih kecil dibandingkan dengan rata-rata RMSE *data training* (kolom selisih menunjukkan hasil negatif). Ditentukan bahwa kombinasi parameter yang dipilih untuk menyusun model SVR pada *SAF equipment* adalah kombinasi nomor 278, dengan $gamma = 0,1$; $cost = 0,1$; $epsilon = 1,2$ dan $kernel = sigmoid$. Kombinasi tersebut dipilih karena tidak mengindikasikan adanya *overfitting*. Ditunjukkan dengan kolom selisih pada kombinasi nomor 278 menghasilkan angka negatif. Selain itu rata-rata RMSE *data validation* pada kombinasi tersebut menunjukkan nilai terkecil dibandingkan dengan kombinasi parameter yang tidak *overfitting* lainnya.

B. Penentuan parameter optimal model *Artificial Nerual Network* (ANN)

Pada Tabel 5.12 hingga 5.14 menunjukkan hasil perhitungan nilai *error* (RMSE) untuk setiap kombinasi parameter model ANN, baik pada *data validation* maupun *data training* serta perbandingan rata-rata RMSE untuk kedua data tersebut.

Tabel 5. 12 RMSE Data validation Model ANN (SAF equipment)

No	Act. Func.	Threshold	Hidden Layer	Jumlah Neuron Setiap Hidden Layer			Data validation (jam)					
				Layer 1	Layer 2	Layer 3	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Rata-rata
1	Logistic	0,1	2	3	1		35,21001	30,77169	49,17967	37,05324	40,1969	38,4823
2	Logistic	0,1	1	4			34,07553	31,533	49,72169	36,50633	40,84505	38,53632
3	Logistic	0,1	1	3			34,35211	32,36145	49,05339	36,96456	40,15136	38,57657
4	Logistic	0,1	1	2			34,09624	33,22406	48,14557	37,00531	40,65898	38,62603
5	Logistic	0,1	2	2	3		33,96509	32,53144	50,04019	36,01994	40,61991	38,63531
...
96	Tanh	0,1	1	1			32,7152	33,13982	49,78376	36,33872	41,54753	38,705
...
97	Tanh	0,01	3	2	1	1	-	-	-	-	-	-
98	Tanh	0,01	3	2	1	2	-	-	-	-	-	-
99	Tanh	0,01	3	2	2	1	-	-	-	-	-	-
100	Tanh	0,01	3	3	1	1	-	-	-	-	-	-

Tabel 5. 13 RMSE Data training Model ANN (SAF equipment)

No	Act. Func.	Threshold	Hidden Layer	Jumlah Neuron Setiap Hidden Layer			Data training (jam)					
				Layer 1	Layer 2	Layer 3	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Rata-rata
1	Logistic	0,1	2	3	1		35,0633	33,8983	33,3138	35,6762	35,6355	34,717486
2	Logistic	0,1	1	4			35,5654	33,9250	33,2936	35,4259	35,1522	34,672486
3	Logistic	0,1	1	3			35,3151	34,5625	33,7926	35,6612	35,4873	34,963797
4	Logistic	0,1	1	2			35,5277	34,5436	33,7178	35,9042	35,8564	35,109992
5	Logistic	0,1	2	2	3		35,4488	34,5745	34,1762	36,4115	35,8629	35,294825
...
8	Tanh	0,1	1	1			32,7152	33,1398	49,7837	36,3387	41,5475	38,705
...
97	Tanh	0,01	3	2	1	1	-	-	-	-	-	-
98	Tanh	0,01	3	2	1	2	-	-	-	-	-	-
99	Tanh	0,01	3	2	2	1	-	-	-	-	-	-
100	Tanh	0,01	3	3	1	1	-	-	-	-	-	-

Tabel 5. 14 Perbandingan RMSE *Data validation* dan *Training* Model ANN (*SAF equipment*)

No	Act. Func.	Thrs	Hidden Layer	Jumlah Neuron			Rata-rata RMSE (jam)		(Data valid – Data training)
				Layer 1	Layer 2	Layer 3	Data validation	Data training	
1	<i>Logistic</i>	0,1	2	3	1		38,4823	34,717486	3,7648
2	<i>Logistic</i>	0,1	1	4			38,53632	34,672486	3,8638
3	<i>Logistic</i>	0,1	1	3			38,57657	34,963797	3,6127
4	<i>Logistic</i>	0,1	1	2			38,62603	35,109992	3,5160
5	<i>Logistic</i>	0,1	2	2	3		38,63531	35,294825	3,3404
...
8	<i>Tanh</i>	0,1	1	1			38,705	38,705	3,0694
...
97	<i>Tanh</i>	0,01	3	2	1	1	-	-	-
98	<i>Tanh</i>	0,01	3	2	1	2	-	-	-
99	<i>Tanh</i>	0,01	3	2	2	1	-	-	-
100	<i>Tanh</i>	0,01	3	3	1	1	-	-	-

Tabel 5.12 menunjukkan bahwa kombinasi parameter model ANN dengan rata-rata RMSE *data validation* terkecil adalah kombinasi nomor 1, *threshold* = 0,1; jumlah *hidden layer* = 2; jumlah *neuron* dalam *hidden layer 1* = 3, *layer 2* = 1; dan *activation function* = *logistic*. Dimana menghasilkan RMSE sebesar 38,4823 jam. Namun, pada Tabel 5.14 menunjukkan bahwa seluruh kombinasi parameter yang digunakan dalam model ANN menghasilkan rata-rata RMSE *data validation* yang lebih besar dibandingkan dengan rata-rata RMSE *data training*. Terlihat pada kolom selisih menunjukkan hasil positif pada seluruh kombinasi. Hal tersebut mengindikasikan bahwa seluruh kombinasi parameter mengalami *overfitting*. Untuk meminimalisir *overfitting* pada model ANN maka dipilih kombinasi parameter dengan selisih rata-rata RMSE *data validation* dan *data training* paling kecil. Sehingga kombinasi parameter yang dipilih untuk menyusun model ANN pada *SAF equipment* adalah kombinasi nomor 8, dengan *threshold* = 0,1; jumlah *hidden layer* = 2; jumlah *neuron* dalam *hidden layer 1* = 3, *layer 2* = 1; dan *activation function* = *tanh*.

5.2.3 Model Prediksi *Rotary Feeder (RF) Equipment*

Pada subab ini dijelaskan mengenai penentuan parameter optimal model SVR dan ANN pada *rotary feeder equipment*.

A. Penentuan parameter optimal model *Support Vector Regression (SVR)*

Pada Tabel 5.15 hingga 5.17 menunjukkan hasil perhitungan nilai *error* (RMSE) untuk setiap kombinasi parameter model SVR, baik pada *data validation* maupun *data training* serta perbandingan rata-rata RMSE untuk kedua data tersebut.

Tabel 5. 15 RMSE *Data validation* Model SVR (*RF equipment*)

No	Kernel	γ	C	ε	RMSE <i>Data validation</i> (jam)					Rata-rata
					Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	
1	<i>Radial Basis</i>	0,01	1000	0,6	5,6387	5,8778	6,2357	5,7867	5,8749	5,8828
2	<i>Radial Basis</i>	0,01	100	0,6	5,6857	5,9355	6,1452	5,8072	5,8666	5,8880
3	<i>Radial Basis</i>	0,10	1	0,6	5,6846	5,8744	6,2172	5,7903	5,8791	5,8891
4	<i>Radial Basis</i>	0,01	100	0,4	5,6745	5,9019	6,1238	5,9499	5,8520	5,9004
5	<i>Radial Basis</i>	0,10	10	0,6	5,6684	5,8945	6,2810	5,8025	5,8866	5,9066
...
371	<i>Sigmoid</i>	10,00	1000	0,4	$4,5 \cdot 10^6$	$5,6 \cdot 10^6$	$6,9 \cdot 10^6$	$7,2 \cdot 10^6$	$7,4 \cdot 10^6$	$6,3 \cdot 10^6$
372	<i>Sigmoid</i>	10,00	1000	0,6	$4,5 \cdot 10^6$	$5,6 \cdot 10^6$	$6,9 \cdot 10^6$	$7,2 \cdot 10^6$	$7,4 \cdot 10^6$	$6,3 \cdot 10^6$
373	<i>Sigmoid</i>	10,00	1000	0,8	$4,5 \cdot 10^6$	$5,6 \cdot 10^6$	$6,9 \cdot 10^6$	$7,2 \cdot 10^6$	$7,4 \cdot 10^6$	$6,3 \cdot 10^6$
374	<i>Sigmoid</i>	10,00	1000	1	$4,5 \cdot 10^6$	$5,6 \cdot 10^6$	$6,9 \cdot 10^6$	$7,2 \cdot 10^6$	$7,4 \cdot 10^6$	$6,3 \cdot 10^6$
375	<i>Sigmoid</i>	10,00	1000	1,2	$4,5 \cdot 10^6$	$5,6 \cdot 10^6$	$6,9 \cdot 10^6$	$7,2 \cdot 10^6$	$7,4 \cdot 10^6$	$6,3 \cdot 10^6$

Tabel 5. 16 RMSE *Data training* Model SVR (*RF equipment*)

No	Kernel	γ	C	ε	RMSE <i>Data training</i> (jam)					Rata-rata
					Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	
1	<i>Radial Basis</i>	0,01	1000	0,6	6,3276	6,2013	6,1572	6,1528	6,1117	6,1901
2	<i>Radial Basis</i>	0,01	100	0,6	6,3485	6,2242	6,1880	6,1783	6,1264	6,2131
3	<i>Radial Basis</i>	0,10	1	0,6	6,3536	6,2288	6,1812	6,1709	6,1248	6,2119
4	<i>Radial Basis</i>	0,01	100	0,4	6,3461	6,2334	6,1852	6,1746	6,1326	6,2144
5	<i>Radial Basis</i>	0,10	10	0,6	6,3165	6,1937	6,1557	6,1535	6,1151	6,1869
...
371	<i>Sigmoid</i>	10,00	1000	0,4	$4,0 \cdot 10^6$	$5,2 \cdot 10^6$	$6,2 \cdot 10^6$	$7,1 \cdot 10^6$	$8,2 \cdot 10^6$	$6,2 \cdot 10^6$
372	<i>Sigmoid</i>	10,00	1000	0,6	$4,0 \cdot 10^6$	$5,2 \cdot 10^6$	$6,2 \cdot 10^6$	$7,1 \cdot 10^6$	$8,2 \cdot 10^6$	$6,2 \cdot 10^6$
373	<i>Sigmoid</i>	10,00	1000	0,8	$4,0 \cdot 10^6$	$5,2 \cdot 10^6$	$6,2 \cdot 10^6$	$7,1 \cdot 10^6$	$8,2 \cdot 10^6$	$6,2 \cdot 10^6$
374	<i>Sigmoid</i>	10,00	1000	1	$4,0 \cdot 10^6$	$5,2 \cdot 10^6$	$6,2 \cdot 10^6$	$7,1 \cdot 10^6$	$8,2 \cdot 10^6$	$6,2 \cdot 10^6$
375	<i>Sigmoid</i>	10,00	1000	1,2	$4,0 \cdot 10^6$	$5,2 \cdot 10^6$	$6,2 \cdot 10^6$	$7,1 \cdot 10^6$	$8,2 \cdot 10^6$	$6,2 \cdot 10^6$

Tabel 5. 17 Perbandingan RMSE *Data validation* dan *Training* Model SVR (*RF equipment*)

No	<i>Kernel</i>	<i>Gamma</i>	<i>Cost</i>	<i>Epsilon</i>	Rata-rata RMSE (jam)		Selisih (<i>Data validation</i> – <i>Data training</i>)
					<i>Data validation</i>	<i>Data training</i>	
1	<i>Radial Basis</i>	0,01	1000	0,6	5,8828	6,1901	-0,30734839
2	<i>Radial Basis</i>	0,01	100	0,6	5,8880	6,2131	-0,32507403
3	<i>Radial Basis</i>	0,10	1	0,6	5,8891	6,2119	-0,32275589
4	<i>Radial Basis</i>	0,01	100	0,4	5,9004	6,2144	-0,31396617
5	<i>Radial Basis</i>	0,10	10	0,6	5,9066	6,1869	-0,28030594
...	
371	<i>Sigmoid</i>	10,00	1000	0,4	$6,3 \cdot 10^6$	$6,2 \cdot 10^6$	158100,9957
372	<i>Sigmoid</i>	10,00	1000	0,6	$6,3 \cdot 10^6$	$6,2 \cdot 10^6$	158101,1005
373	<i>Sigmoid</i>	10,00	1000	0,8	$6,3 \cdot 10^6$	$6,2 \cdot 10^6$	158101,2344
374	<i>Sigmoid</i>	10,00	1000	1	$6,3 \cdot 10^6$	$6,2 \cdot 10^6$	158101,4173
375	<i>Sigmoid</i>	10,00	1000	1,2	$6,3 \cdot 10^6$	$6,2 \cdot 10^6$	158101,6003

Tabel 5.15 menunjukkan parameter model SVR dengan rata-rata RMSE *data validation* terkecil adalah pada kombinasi nomor 1, $\gamma = 0,01$; $cost = 1000$; $\epsilon = 0,6$ dan $kernel = radial basis$. Dimana menghasilkan RMSE sebesar 5,8828 jam. Selain itu, meninjau perbandingan rata-rata RMSE *data validation* dan *data training* pada Tabel 5.17, menunjukkan bahwa rata-rata RMSE *data validation* lebih kecil dibandingkan dengan rata-rata RMSE *data training*. Terlihat pada kolom selisih menunjukkan hasil negatif. Hal tersebut mengindikasikan bahwa kombinasi parameter nomor 1 tidak menyebabkan *overfitting* pada model SVR. Berdasarkan alasan tersebut, maka dipilih kombinasi parameter nomor 1 dengan $\gamma = 0,01$; $cost = 1000$; $\epsilon = 0,6$ dan $kernel = radial basis$ untuk menyusun model SVR pada *RF equipment*.

B. Penentuan parameter optimal model *Artificial Neural Network* (ANN)

Tabel 5.18 hingga 5.20 menunjukkan hasil perhitungan nilai *error* (RMSE) untuk setiap kombinasi parameter model ANN, baik pada *data validation* maupun *data training* serta perbandingan rata-rata RMSE untuk kedua data tersebut.

Tabel 5. 18 RMSE Data validation Model ANN (*RF equipment*)

No	Act. Func.	Threshold	Hidden Layer	Jumlah Neuron Setiap Hidden Layer			RMSE Data validation (jam)					
				Layer 1	Layer 2	Layer 3	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Rata-rata
1	Logistic	0,1	2	4	1		6,11682728	6,035015	6,126784	5,799685	5,849857	5,985634
2	Logistic	0,1	1	5			6,08228878	5,937791	6,082194	5,891467	5,945554	5,987859
3	Logistic	0,1	2	2	3		6,09449078	6,04699	6,063695	5,840593	5,904897	5,990133
4	Logistic	0,1	1	4			6,09254469	6,041189	6,081997	5,809329	5,930651	5,991142
5	Tanh	0,1	2	1	2		6,02586759	6,287852	5,873029	5,853763	5,917703	5,991643
...
96	Tanh	0,01	3	1	3	1	-	-	-	-	-	-
97	Tanh	0,01	3	2	1	1	-	-	-	-	-	-
98	Tanh	0,01	3	2	1	2	-	-	-	-	-	-
99	Tanh	0,01	3	2	2	1	-	-	-	-	-	-
100	Tanh	0,01	3	3	1	1	-	-	-	-	-	-

Tabel 5. 19 RMSE Data training Model ANN (*RF equipment*)

No	Act. Func.	Threshold	Hidden Layer	Jumlah Neuron Setiap Hidden Layer			RMSE Data training (jam)					
				Layer 1	Layer 2	Layer 3	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Rata-rata
1	Logistic	0,1	2	4	1		6,224742	6,1278656	6,1212713	6,0962022	6,06230804	6,1264779
2	Logistic	0,1	1	5			6,332136	6,2034729	6,1374477	6,0903319	6,08425149	6,1695282
3	Logistic	0,1	2	2	3		6,327241	6,1913294	6,1800657	6,1521982	6,11990143	6,1941473
4	Logistic	0,1	1	4			6,321772	6,1966284	6,1306831	6,116931	6,10916287	6,1750355
5	Tanh	0,1	2	1	2		6,381843	6,2363984	6,2146402	6,1602142	6,12184082	6,2229875
...
96	Tanh	0,01	3	1	3	1	-	-	-	-	-	-
97	Tanh	0,01	3	2	1	1	-	-	-	-	-	-
98	Tanh	0,01	3	2	1	2	-	-	-	-	-	-
99	Tanh	0,01	3	2	2	1	-	-	-	-	-	-
100	Tanh	0,01	3	3	1	1	-	-	-	-	-	-

Tabel 5. 20 Perbandingan RMSE *Data validation* dan *Training* Model ANN (*RF equipment*)

No	Act. Func.	Thrs	Hidden Layer	Jumlah Neuron			Rata-rata RMSE (jam)		(Data valid – Data training)
				Layer 1	Layer 2	Layer 3	Data validation	Data training	
1	<i>Logistic</i>	0,1	2	4	1		5,985634	6,1264779	-0,14084
2	<i>Logistic</i>	0,1	1	5			5,987859	6,1695282	-0,18167
3	<i>Logistic</i>	0,1	2	2	3		5,990133	6,1941473	-0,20401
4	<i>Logistic</i>	0,1	1	4			5,991142	6,1750355	-0,18389
5	<i>Tanh</i>	0,1	2	1	2		5,991643	6,2229875	-0,23134
...
97	<i>Tanh</i>	0,01	3	1	3	1	-	-	-
98	<i>Tanh</i>	0,01	3	2	1	1	-	-	-
99	<i>Tanh</i>	0,01	3	2	1	2	-	-	-
100	<i>Tanh</i>	0,01	3	2	2	1	-	-	-

Tabel 5.18 menunjukkan bahwa kombinasi parameter model ANN dengan rata-rata RMSE *data validation* terkecil adalah pada kombinasi nomor 1, *threshold* = 0,1; jumlah *hidden layer* = 2; jumlah *neuron* dalam *hidden layer 1* = 4, *layer 2* = 1; dan *activation function* = *logistic*. Dimana menghasilkan RMSE sebesar 5,9856 jam. Meninjau perbandingan rata-rata RMSE *data validation* dan *data training* pada Tabel 5.20, menunjukkan bahwa rata-rata RMSE *data validation* lebih kecil dibandingkan dengan rata-rata RMSE *data training*. Ditunjukkan dengan nilai negatif pada kolom selisih. Hal tersebut menunjukkan bahwa kombinasi parameter nomor 1 tidak menyebabkan overfitting pada model ANN. Berdasarkan alasan yang telah diapaparkan, maka kombinasi parameter nomor 1 dengan *threshold* = 0,1; jumlah *hidden layer* = 2; jumlah *neuron* dalam *hidden layer 1* = 4, *layer 2* = 1; dan *activation function* = *logistic* adalah parameter optimal yang dipilih untuk menyusun model ANN pada *RF equipment*.

5.2.4 Model Untuk *Motor Bucket Elevator (MBE) Equipment*

Pada subab ini dijelaskan mengenai penentuan parameter optimal model SVR dan ANN pada *motor bucket elevator equipment*.

A. Penentuan parameter optimal model *Support Vector Regression (SVR)*

Pada Tabel 5.21 hingga 5.23 menunjukkan hasil perhitungan nilai *error* (RMSE) untuk setiap kombinasi parameter model SVR, baik pada *data validation* maupun *data training* serta perbandingan rata-rata RMSE untuk kedua data tersebut.

Tabel 5. 21 RMSE Data validation Model SVR (MBE equipment)

No	Kernel	γ	C	ϵ	RMSE Data validation (jam)					
					Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Rata-rata
1	Radial Basis	0,10	0,1	0,4	3,8428	3,5580	3,5168	3,4415	3,6964	3,6111
2	Radial Basis	0,01	10	0,6	3,8412	3,5532	3,5130	3,4445	3,7187	3,6141
3	Radial Basis	0,01	10	0,4	3,8624	3,5694	3,5250	3,4266	3,6909	3,6149
4	Radial Basis	0,01	100	0,6	3,8517	3,5464	3,5144	3,4497	3,7125	3,6149
5	Radial Basis	0,01	100	0,4	3,8918	3,5521	3,5173	3,4264	3,6897	3,6155
...
371	Sigmoid	10,00	1000	0,4	2,1 10^6	2,7 10^6	3,1 10^6	3,5 10^6	3,8 10^6	3,0 10^6
372	Sigmoid	10,00	1000	0,6	2,1 10^6	2,7 10^6	3,1 10^6	3,5 10^6	3,8 10^6	3,0 10^6
373	Sigmoid	10,00	1000	0,8	2,1 10^6	2,7 10^6	3,1 10^6	3,5 10^6	3,8 10^6	3,0 10^6
374	Sigmoid	10,00	1000	1	2,1 10^6	2,7 10^6	3,1 10^6	3,5 10^6	3,8 10^6	3,0 10^6
375	Sigmoid	10,00	1000	1,2	2,1 10^6	2,7 10^6	3,1 10^6	3,5 10^6	3,8 10^6	3,0 10^6

Tabel 5. 22 RMSE Data training Model SVR (MBE equipment)

No	Kernel	γ	C	ϵ	RMSE Data training (jam)					
					Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Rata-rata
1	Radial Basis	0,10	0,1	0,4	3,6760	3,6962	3,6638	3,6458	3,6377	3,6639
2	Radial Basis	0,01	10	0,6	3,6801	3,6950	3,6639	3,6493	3,6355	3,6648
3	Radial Basis	0,01	10	0,4	3,6815	3,6964	3,6658	3,6497	3,6428	3,6672
4	Radial Basis	0,01	100	0,6	3,6581	3,6815	3,6541	3,6379	3,6263	3,6516
5	Radial Basis	0,01	100	0,4	3,6626	3,6859	3,6547	3,6411	3,6330	3,6555
...
371	Sigmoid	10,00	1000	0,4	2,0 10^6	2,5 10^6	3,0 10^6	3,5 10^6	4,0 10^6	3,0 10^6
372	Sigmoid	10,00	1000	0,6	2,0 10^6	2,5 10^6	3,0 10^6	3,5 10^6	4,0 10^6	3,0 10^6
373	Sigmoid	10,00	1000	0,8	2,0 10^6	2,5 10^6	3,0 10^6	3,5 10^6	4,0 10^6	3,0 10^6
374	Sigmoid	10,00	1000	1	2,0 10^6	2,5 10^6	3,0 10^6	3,5 10^6	4,0 10^6	3,0 10^6
375	Sigmoid	10,00	1000	1,2	2,0 10^6	2,5 10^6	3,0 10^6	3,5 10^6	4,0 10^6	3,0 10^6

Tabel 5. 23 Perbandingan RMSE Data validation dan Training Model SVR (MBE equipment)

No	Kernel	Gamma	Cost	Epsilon	Rata-rata RMSE (jam)		Selisih (Data validation – Data training)
					Data validation	Data training	
1	Radial Basis	0,10	0,1	0,4	3,6111	3,6639	-0,05456
2	Radial Basis	0,01	10	0,6	3,6141	3,6648	-0,0634
3	Radial Basis	0,01	10	0,4	3,6149	3,6672	-0,05403

No	Kernel	Gamma	Cost	Epsilon	Rata-rata RMSE (jam)		Selisih (Data validation – Data training)
					Data validation	Data training	
4	<i>Radial Basis</i>	0,01	100	0,6	3,6149	3,6516	-0,07028
5	<i>Radial Basis</i>	0,01	100	0,4	3,6155	3,6555	-0,06741
...
371	<i>Sigmoid</i>	10,00	1000	0,4	3074244	3072371	1873
372	<i>Sigmoid</i>	10,00	1000	0,6	3074244	3072371	1873
373	<i>Sigmoid</i>	10,00	1000	0,8	3074244	3072371	1873
374	<i>Sigmoid</i>	10,00	1000	1	3074244	3072371	1873
375	<i>Sigmoid</i>	10,00	1000	1,2	3074244	3072371	1873

Tabel 5.21 menunjukkan bahwa kombinasi parameter SVR dengan rata-rata RMSE *data validation* terkecil adalah pada kombinasi nomor 1, *gamma* = 0,1; *cost* = 0,1; *epsilon* = 0,4 dan *kernel* = *radial basis*. Dimana parameter tersebut menghasilkan RMSE sebesar 3,6111 jam. Meninjau hasil perbandingan rata-rata RMSE *data validation* dan *data training* pada Tabel 5.23 menunjukkan bahwa rata-rata RMSE *data validation* memiliki nilai lebih kecil dibandingkan dengan rata-rata RMSE *data training*. Terlihat pada kolom selisih yang menunjukkan hasil negatif. Hal tersebut mengindikasikan bahwa kombinasi nomor 1 tidak menyebabkan *overfitting* pada model SVR. Berdasarkan alasan tersebut, maka kombinasi parameter nomor 1, dengan *gamma* = 0,1; *cost* = 0,1; *epsilon* = 0,4 dan *kernel* = *radial basis* dipilih sebagai parameter optimal untuk menyusun model SVR pada *MBE equipment*.

B. Penentuan parameter optimal model *Artificial Neural Network* (ANN)

Tabel 5.24 hingga 5.26 menunjukkan hasil perhitungan nilai *error* (RMSE) untuk setiap kombinasi parameter model ANN, baik pada *data validation* maupun *data training* serta perbandingan rata-rata RMSE untuk kedua data tersebut.

Tabel 5. 24 RMSE Data validation Model ANN (*MBE equipment*)

No	Act. Func.	Threshold	Hidden Layer	Jumlah Neuron Setiap Hidden Layer			RMSE Data validation (jam)					
				Layer 1	Layer 2	Layer 3	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Rata-rata
1	Tanh	0,1	3	2	1	2	3,796327	3,477817	3,482313	3,504672	3,702497	3,592725
2	Logistic	0,1	3	2	2	1	3,788714	3,476189	3,485463	3,509396	3,704886	3,592929
3	Logistic	0,01	2	2	1		3,79666	3,482708	3,480783	3,508934	3,714847	3,596786
4	Tanh	0,1	2	4	1		3,781806	3,47604	3,480655	3,5207	3,738643	3,599569
5	Logistic	0,01	3	2	1	2	3,831452	3,472068	3,484765	3,49772	3,723771	3,601955
...
96	Tanh	0,01	3	1	3	1	3,798767	3,505488	3,550658	3,553057	-	-
97	Tanh	0,01	3	2	1	1	-	3,471895	3,481249	-	-	-
98	Tanh	0,01	3	2	1	2	-	3,468143	-	-	-	-
99	Tanh	0,01	3	2	2	1	-	-	-	-	-	-
100	Tanh	0,01	3	3	1	1	-	-	-	-	-	-

Tabel 5. 25 RMSE Data training Model ANN (*MBE equipment*)

No	Act. Func.	Threshold	Hidden Layer	Jumlah Neuron Setiap Hidden Layer			RMSE Data training (jam)					
				Layer 1	Layer 2	Layer 3	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Rata-rata
1	Tanh	0,1	3	2	1	2	3,6816302	3,6504746	3,6155146	3,5968862	3,5793287	3,6247669
2	Logistic	0,1	3	2	2	1	3,6253131	3,6491568	3,6144421	3,6004731	3,5839256	3,6146622
3	Logistic	0,01	2	2	1		3,6236224	3,6481102	3,6169203	3,5937394	3,5788105	3,6122406
4	Tanh	0,1	2	4	1		3,6630266	3,644567	3,6082152	3,5876557	3,5799665	3,6166862
5	Logistic	0,01	3	2	1	2	3,6243318	3,6447726	3,6186745	3,5903167	3,57466	3,6105511
...
96	Tanh	0,01	3	1	3	1	3,692079	3,7081428	3,6737854	3,6534488	-	-
97	Tanh	0,01	3	2	1	1	-	3,6454992	3,6141269	-	-	-
98	Tanh	0,01	3	2	1	2	-	3,6442263	-	-	-	-
99	Tanh	0,01	3	2	2	1	-	-	-	-	-	-
100	Tanh	0,01	3	3	1	1	-	-	-	-	-	-

Tabel 5. 26 Perbandingan RMSE *Data validation* dan *Training Model ANN (MBE equipment)*

No	Act. Func.	Thrs	Hidden Layer	Jumlah Neuron			Rata-rata RMSE (jam)		(Data valid – Data training)
				Layer 1	Layer 2	Layer 3	Data validation	Data training	
1	Tanh	0,1	3	2	1	2	3,592725	3,6247669	-0,03204
2	Logistic	0,1	3	2	2	1	3,592929	3,6146622	-0,02173
3	Logistic	0,01	2	2	1		3,596786	3,6122406	-0,01545
4	Tanh	0,1	2	4	1		3,599569	3,6166862	-0,01712
5	Logistic	0,01	3	2	1	2	3,601955	3,6105511	-0,0086
...
97	Tanh	0,01	3	1	3	1	-	-	-
98	Tanh	0,01	3	2	1	1	-	-	-
99	Tanh	0,01	3	2	1	2	-	-	-
100	Tanh	0,01	3	2	2	1	-	-	-

Tabel 5.24 menunjukkan bahwa kombinasi parameter dengan rata-rata RMSE *data validation* terkecil adalah pada kombinasi nomor 1, *threshold* = 0,1; jumlah *hidden layer* = 3; jumlah *neuron* dalam *hidden layer 1* = 2, *layer 2* = 1, *layer 3* = 2; dan *activation function* = *tanh*. Dimana parameter tersebut menghasilkan RMSE sebesar 3,5927 jam. Meninjau perbandingan rata-rata RMSE *data validation* dan *data training* pada Tabel 5.26, menunjukkan bahwa rata-rata RMSE *data validation* memiliki nilai lebih kecil dibandingkan dengan rata-rata RMSE *data training*. Terlihat pada kolom selisih yang menunjukkan hasil negatif. Hal tersebut mengindikasikan bahwa kombinasi parameter nomor 1 tidak menyebabkan overfitting pada model ANN. Berdasarkan alasan tersebut, maka kombinasi parameter nomor 1 dengan *threshold* = 0,1; jumlah *hidden layer* = 3; jumlah *neuron* dalam *hidden layer 1* = 2, *layer 2* = 1, *layer 3* = 2; dan *activation function* = *tanh* dipilih sebagai parameter optimal untuk digunakan dalam penyusunan model ANN pada *MBE equipment*.

5.3 Rekap Parameter Optimal Model SVR dan ANN

Tabel 5.27 menunjukkan rekap parameter optimal untuk model *support vector regression* (SVR) dan *artificial neural network* (ANN) pada setiap *equipment*. Setiap model dengan parameter optimal tersebut akan dibandingkan pada tahap pemilihan model untuk mengetahui model terbaik.

Tabel 5. 27 Rekap Parameter Optimal Model SVR dan ANN

Equipment	Parameter Model SVR		Parameter Model ANN	
<i>Motor Belt Conveyor</i>	<i>Gamma</i>	0,01	<i>Threshold</i>	0,01
	<i>Cost</i>	1000	<i>Hidden Layer</i>	1
	<i>Epsilon</i>	0,8	<i>Neuron</i>	3
	<i>Kernel</i>	<i>Radial Basis</i>	<i>Act. Func.</i>	<i>Logistic</i>
<i>Sealing Air Fan</i>	<i>Gamma</i>	0,1	<i>Threshold</i>	0,1
	<i>Cost</i>	0,1	<i>Hidden Layer</i>	1
	<i>Epsilon</i>	1,2	<i>Neuron</i>	1
	<i>Kernel</i>	<i>Sigmoid</i>	<i>Act. Func.</i>	<i>Tanh</i>
<i>Rotary Feeder</i>	<i>Gamma</i>	0,01	<i>Threshold</i>	0,1
	<i>Cost</i>	1000	<i>Hidden Layer</i>	2
	<i>Epsilon</i>	0,6	<i>Neuron</i>	4;1
	<i>Kernel</i>	<i>Radial Basis</i>	<i>Act. Func.</i>	<i>Logistic</i>
<i>Motor Bucket Elevator</i>	<i>Gamma</i>	0,1	<i>Threshold</i>	0,1
	<i>Cost</i>	0,1	<i>Hidden Layer</i>	3
	<i>Epsilon</i>	0,4	<i>Neuron</i>	2;1;2
	<i>Kernel</i>	<i>Radial Basis</i>	<i>Act. Func.</i>	<i>Tanh</i>

(Halaman ini sengaja dikosongkan)

BAB 6

PEMILIHAN MODEL

Pada bab ini dijelaskan mengenai pemilihan model terbaik melalui evaluasi terhadap model SVR dan ANN dengan nilai parameter optimal. Selain itu dilakukan analisa kelayakan model untuk memastikan model dapat digunakan dalam prediksi waktu kegagalan (MRL).

6.1 Evaluasi Model

Tahap evaluasi model dilakukan untuk mengukur performansi model prediksi dengan parameter optimal. Tahap ini digunakan untuk memilih model terbaik antara SVR atau ANN. Pengukuran performansi akan dilakukan sesuai dengan pembagian data pada bab 5.2 dengan tetap mengacu pada prinsip *nested cross validation*. Berbeda dengan tahap penyusunan model, yang mana menggunakan data pada *data training* dan *data validation* dalam prosesnya. Tahap evaluasi model menggunakan data pada *data testing* untuk menguji performansi model dengan *data training* yang digunakan adalah kombinasi data pada *data training* dan *data validation*. Pembagian *data training* dan *data testing* untuk setiap *equipment* dapat dilihat pada Tabel 4.28 – Tabel 4.31.

Dalam tahap evaluasi model terdapat dua parameter yang diuji yaitu *root mean square error* (RMSE) dan standar deviasi (STD). Menurut Santosa dan Umam (2018), parameter RMSE digunakan untuk mengukur besaran *error*. Semakin kecil nilai RMSE menunjukkan bahwa model yang dibentuk semakin akurat. Sedangkan STD digunakan untuk mengukur tingkat persebaran nilai *error* tersebut. Dengan kata lain, menunjukkan konsistensi performa model. Semakin kecil nilai STD, menunjukkan performa model semakin konsisten. Tabel 6.1 – 6.4 menunjukkan hasil pengukuran performansi model pada setiap *equipment*.

Tabel 6. 1 Ukuran Performansi Model SVR dan ANN (*MBC equipment*)

<i>Fold</i>	RMSE		STD	
	Model SVR	Model ANN	Model SVR	Model ANN
<i>Fold 1</i>	3,529352625	3,556021216	3,520189444	3,550529249
<i>Fold 2</i>	3,444352706	3,461520395	3,424105958	3,435155943
<i>Fold 3</i>	3,683096028	3,671649605	3,224172015	3,192910203

Fold	RMSE		STD	
	Model SVR	Model ANN	Model SVR	Model ANN
Fold 4	3,654939588	3,650779329	3,60948558	3,589815133
Fold 5	3,325681000	3,352705000	3,31437400	3,336137000
Rata-rata	3,527484389	3,538535109	3,418465399	3,420909506

Tabel 6.1 menunjukkan bahwa rata-rata RMSE untuk model SVR dan ANN secara berurut-turut adalah 3,5274 dan 3,5385. Rata-rata RMSE model SVR menunjukkan angka lebih kecil dari model ANN, sehingga model SVR dapat dikatakan mampu memberikan akurasi sedikit lebih baik dibandingkan dengan model ANN untuk memprediksi kegagalan *MBC equipment*. Ditinjau dari nilai STD, secara berturut-turut rata-rata STD model SVR dan ANN adalah 3,4184 dan 3,4209. Menunjukkan bahwa rata-rata STD model SVR memiliki nilai lebih kecil dari model ANN. Hal tersebut menunjukkan bahwa model SVR lebih konsisten dibandingkan model ANN untuk memprediksi kegagalan *MBC equipment*. Berdasarkan hasil perhitungan tersebut, maka model SVR dipilih sebagai model prediksi waktu kegagalan *MBC equipment* karena memiliki akurasi dan konsistensi lebih baik dibandingkan model ANN.

Tabel 6. 2 Ukuran Performansi Model SVR dan ANN (*SAF equipment*)

Fold	RMSE		STD	
	Model SVR	Model ANN	Model SVR	Model ANN
Fold 1	30,18013568	30,77168875	28,02899566	26,68263462
Fold 2	50,7621328	49,17967371	47,89542391	44,11199027
Fold 3	38,83319308	37,05323978	32,62962324	33,38534009
Fold 4	59,57724828	40,19690493	58,33230445	38,53202764
Fold 5	81,369740	37,18179	80,17881	36,00439
Rata-rata	52,14448997	38,87665943	49,41303145	35,74327652

Tabel 6.2 menunjukkan bahwa rata-rata RMSE model SVR dan model ANN secara berturut-turut adalah 52,144 dan 38,876. Menunjukkan bahwa model ANN memiliki rata-rata RMSE yang lebih kecil dari model SVR, sehingga model ANN dapat dikatakan memiliki akurasi yang lebih baik dibandingkan model SVR dalam prediksi kegagalan *SAF equipment*. Meninjau nilai STD, rata-rata STD model SVR dan model ANN berturut-turut adalah 49,413 dan 35,743. Menunjukkan model ANN memiliki nilai STD yang lebih kecil dari model SVR, sehingga dapat dikatakan model ANN lebih konsisten dibandingkan model SVR

dalam prediksi kegagalan *SAF equipment*. Berdasarkan hasil perhitungan tersebut, maka model ANN dipilih sebagai model prediksi waktu kegagalan *SAF equipment* karena memiliki akurasi dan konsistensi lebih baik dibandingkan model SVR.

Tabel 6. 3 Ukuran Performansi Model SVR dan ANN (*RF equipment*)

<i>Fold</i>	RMSE		STD	
	Model SVR	Model ANN	Model SVR	Model ANN
<i>Fold 1</i>	5,638652056	6,035014694	5,471142303	5,572195711
<i>Fold 2</i>	5,877811121	6,126784428	6,223937529	6,108135968
<i>Fold 3</i>	6,235660239	5,799685668	5,719014252	5,81056028
<i>Fold 4</i>	5,786724583	5,849856842	5,810858675	5,75702985
<i>Fold 5</i>	5,892501000	5,974807000	5,89029500	5,954150000
Rata-rata	5,8862698	5,957229726	5,823049552	5,840414362

Tabel 6.3 menunjukkan rata-rata RMSE SVR dan ANN berturut-turut adalah 5,886 dan 5,957. Model SVR memberikan nilai RMSE yang lebih kecil dibandingkan model ANN, menunjukkan model SVR mampu memberikan akurasi yang lebih baik dibandingkan model ANN dalam prediksi kegagalan *RF equipment*. Ditinjau dari nilai STD, diketahui bahwa STD model SVR dan model ANN berturut-turut adalah 5,823 dan 5,840. Model SVR memberikan nilai STD lebih kecil dibandingkan model ANN, sehingga model SVR dinyatakan lebih konsisten dalam melakukan prediksi kegagalan *RF equipment* dibandingkan dengan model ANN. Berdasarkan hasil perhitungan tersebut, maka model SVR dipilih sebagai model prediksi waktu kegagalan *RF equipment* karena memiliki akurasi dan konsistensi lebih baik dibandingkan model ANN.

Tabel 6. 4 Ukuran Performansi Model SVR dan ANN (*MBE equipment*)

<i>Fold</i>	RMSE		STD	
	Model SVR	Model ANN	Model SVR	Model ANN
<i>Fold 1</i>	3,557951724	3,477817137	3,527952252	3,460412037
<i>Fold 2</i>	3,516800955	3,48231337	3,501960149	3,440170233
<i>Fold 3</i>	3,441505806	3,504671883	3,302555537	3,2919124
<i>Fold 4</i>	3,696397355	3,702497184	3,679322914	3,667445296
<i>Fold 5</i>	3,435219000	3,433383000	3,42160600	3,406044000
Rata-rata	3,55316396	3,541824894	3,48667937	3,453196793

Tabel 6.4 menunjukkan rata-rata RMSE model SVR dan model ANN berturut-turut adalah 3,5531 dan 3,5418. Model ANN memberikan nilai RMSE

yang lebih kecil dibandingkan dengan model ANN. Menunjukkan bahwa model ANN untuk prediksi kegagalan *MBE equipment* memiliki akurasi yang lebih baik dibandingkan model SVR. Ditinjau dari model nilai STD, rata-rata STD model SVR dan model ANN berturut-turut adalah 3,486 dan 3,4531. Model ANN memberikan nilai STD lebih kecil dibandingkan dengan model SVR, sehingga dapat dikatakan model ANN lebih konsisten dibandingkan model SVR dalam prediksi kegagalan *MBE equipment*. Berdasarkan hasil perhitungan tersebut, maka model ANN dipilih sebagai model prediksi waktu kegagalan *MBE equipment* karena memiliki akurasi dan konsistensi lebih baik dibandingkan model SVR.

Berdasarkan hasil perhitungan ukuran performansi RMSE dan STD, model SVR pada *MBC equipment* dan *RF equipment* memberikan tingkat akurasi dan konsistensi yang lebih baik dibandingkan dengan model ANN, ditunjukkan dengan nilai RMSE dan STD yang lebih kecil. Sedangkan pada *SAF equipment* dan *MBE equipment*, model ANN menunjukkan tingkat akurasi dan konsistensi yang baik dibandingan dengan model SVR. Tabel 6.5 menunjukkan rekap model terpilih untuk setiap *equipment*.

Tabel 6. 5 Rekap Model Terpilih Setiap *Equipment*

<i>Equipment</i>	<i>Model Terpilih</i>	<i>RMSE</i>	<i>STD</i>
<i>Motor Belt Conveyor</i>	<i>Support Vector Regression</i>	3,527484389	3,418465399
<i>Sealing Air Fan</i>	<i>Artificial Neural Network</i>	38,87665943	35,74327652
<i>Rotary Feeder</i>	<i>Support Vector Regression</i>	5,8862698	5,823049552
<i>Motor Bucket Elevator</i>	<i>Artificial Neural Network</i>	3,541824894	3,453196793

6.2 Uji Kelayakan Model

Uji kelayakan model bertujuan untuk memastikan bahwa model yang telah terpilih pada tahap evlauasi model dapat melakukan prediksi sesuai dengan kondisi sebenarnya. Dalam tahap ini digunakan uji beda berpasangan untuk membandingkan MRL hasil prediksi model SVR atau ANN, dengan MRL *data testing*. Ketika hasil uji menunjukkan tidak berbeda secara signifikan, maka model dinyatakan layak digunakan. Sebaliknya, ketika berbeda signifikan maka model dinyatakan tidak layak. Terdapat dua macam uji beda berpasangan yaitu secara prametrik dan non-parametrik, dimana kondisi tersebut bergantung pada data yang digunakan. Perlu dilakukan uji normalitas terlebih dahulu untuk menentukan jenis

uji beda yang digunakan. Jika data berdistribusi normal maka digunakan uji beda secara parametrik, sedangkan ketika data tidak berdistribusi normal maka digunakan uji beda secara non-parametrik (Sunjoyo, et al., 2013). Uji beda berpasangan secara parametrik dapat dilakukan dengan menggunakan *t-test*, sedangkan secara non-parametrik dapat dilakukan dengan *wilcoxon signed rank test* (Jogiyanto, 2004).

6.2.1 MRL Data testing dan MRL Hasil Prediksi Model

Tabel 6.6 – 6.9 menunjukkan rekap *data testing* dan MRL hasil prediksi model terpilih, sesuai dengan Tabel 6.5, pada setiap *equipment*. Data MRL pada Tabel 6.6 – 6.9 digunakan sebagai acuan dalam proses uji kelayakan model. Proses prediksi menggunakan *data testing* pada *fold* ke-5 untuk setiap *equipment*.

Tabel 6. 6 MRL Data testing dan Prediksi Model SVR (*MBC equipment*)

Data ke-	Waktu ke-t (jam)	Sensor RPM MBC (%)	Sensor Vibrasi (mm/s)	MRL data testing (jam)	MRL Hasil Prediksi SVR (jam)
7255	16.5	45	1.9	10.6304	6.8603
7256	17.0	60	1.8	10.5171	7.9329
7257	17.5	42	2.3	10.4004	6.6820
7258	18.0	52	2	10.2802	7.3498
7259	18.5	46	2	10.1563	6.8518
...
8055	11,55833	0	0,2	0,0000	-2,1830
8056	0,0	45	0,1	1,1618	6.7451
8057	0,5	36	0,1	0,6859	7.0576
8058	1,0	35	0,1	0,1987	6.9672
8059	1,2	10	0,2	0,0000	3.8217

Tabel 6. 7 MRL Data testing dan Prediksi Model ANN (*SAF equipment*)

Data ke-	Waktu ke-t (jam)	Sensor RPM MBC (%)	Sensor Vibrasi (mm/s)	MRL data testing (jam)	MRL Hasil Prediksi ANN (jam)
8920	289.0001	46	0.1	72.8215	44.2854
8921	289.5001	46	0.1	72.6432	44.2846
8922	290.0001	41	0.1	72.4643	44.0218
8923	290.5001	39	0.1	72.2847	43.8198
8924	291.0001	19	1.8	72.1045	42.5408
...
9908	252.0001	49	0.1	1.8382	44.3856
9909	252.5001	48	0.1	1.3449	44.3718
9910	253.0001	48	0.1	0.8496	44.3714
9911	253.5001	48	0.1	0.3521	44.3709
9912	253.8528	4	0.1	0.0000	-1.4342

Tabel 6. 8 MRL *Data testing* dan Prediksi Model SVR (*RF equipment*)

Data ke-	Waktu ke-t (jam)	Sensor RPM MBC (%)	Sensor Vibrasi (mm/s)	MRL data testing (jam)	MRL Hasil Prediksi SVR (jam)
7129	0.5001	41	2.1	21.1852	19.7983
7130	1.0001	40	1.8	20.7119	17.8293
7131	1.5001	41	1.3	20.2509	18.1679
7132	2.0001	42	2.4	19.8004	20.7558
7133	2.5001	41	1.7	19.3593	18.0011
...
7915	32.0001	40	2.3	1.7673	9.8196
7916	32.5001	41	2.2	1.3040	9.7619
7917	33.0001	39	1.9	0.8298	8.9880
7918	33.5001	41	0.1	0.3442	7.9565
7919	33.84722	0	0.1	0.0000	4.0188

Tabel 6. 9 MRL *Data testing* dan Prediksi Model ANN (*MBE equipment*)

Data ke-	Waktu ke-t (jam)	Sensor RPM MBC (%)	Sensor Vibrasi (mm/s)	MRL data testing (jam)	MRL Hasil Prediksi ANN (jam)
7201	29.0001	57	2	6.461217	5.456083344
7202	29.5001	55	2.5	6.204053	5.287146486
7203	30.0001	48	2	5.937125	5.101904523
7204	30.5001	50	1.9	5.660022	5.036306314
7205	31.0001	50	2.5	5.372316	4.876817563
...
7991	11.0001	43	2	1.62488	7.47058977
7992	11.5001	39	1.8	1.175052	7.33547215
7993	12.0001	39	1.6	0.708932	7.306431335
7994	12.5001	44	1.9	0.225817	7.387530934
7995	12.72778	0	0.2	0	0.003769417

6.2.2 Uji Normalitas Data

Uji normalitas data dilakukan baik pada MRL *data testing* maupun pada MRL hasil prediksi dengan model terpilih, SVR atau ANN, mengacu pada Tabel 6.6 – 6.9. Hasil uji normlaitas data untuk MRL *data testing* dan MRL hasil prediksi model terpilih pada setiap *equipment* ditunjukkan pada pada Tabel 6.10 – 6.13. Proses kalkulasi dilakukan dengan *software SPSS*.

Tabel 6. 10 Uji Normalitas Data (*MBC equipment*)

Data Uji	Tests of Normality					
	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
MRL Data testing	.104	806	.000	.929	806	.000
MRL Hasil Prediksi (SVR)	.152	806	.000	.834	806	.000

Tabel 6.10 menunjukkan bahwa nilai signifikansi pada uji *Kolmogorov-Smirnov* untuk MRL *data testing* dan MRL hasil prediksi model SVR pada *MBC equipment* adalah 0,00. Nilai signifikansi tersebut lebih kecil dibandingkan dengan 0,05. Berdasarkan uji *Kolmogorov-Smirnov*, MRL *data testing* dan MRL hasil prediksi model SVR dinyatakan tidak berdistribusi normal, sehingga perlu dilakukan *wilcoxon test*, untuk membandingkan antara MRL *data testing* dengan MRL hasil prediksi model SVR.

Tabel 6. 11 Uji Normalitas Data (*SAF equipment*)

Data Uji	Tests of Normality					
	<i>Kolmogorov-Smirnov^a</i>			<i>Shapiro-Wilk</i>		
	Statistic	df	Sig.	Statistic	df	Sig.
MRL <i>Data testing</i>	.055	993	.000	.962	993	.000
MRL Hasil Prediksi (ANN)	.124	993	.000	.923	993	.000

Tabel 6.11 menunjukkan bahwa nilai signifikansi uji *Kolmogorov-Smirnov* untuk MRL *data testing* dan MRL hasil prediksi model ANN pada *SAF equipment* adalah 0,00. Nilai tersebut lebih kecil dari 0,05, mengindikasikan bahwa MRL *data testing* dan MRL hasil prediksi model ANN tidak berdistribusi normal. Berdasarkan kondisi tersebut maka perlu dilakukan *wilcoxon test*, untuk membandingkan antara MRL *data testing* dengan MRL hasil prediksi ANN.

Tabel 6. 12 Uji Normalitas Data (*RF equipment*)

Data Uji	Tests of Normality					
	<i>Kolmogorov-Smirnov^a</i>			<i>Shapiro-Wilk</i>		
	Statistic	df	Sig.	Statistic	df	Sig.
MRL <i>Data testing</i>	.043	791	.002	.980	791	.000
MRL Hasil Prediksi (SVR)	.022	791	.200*	.996	791	.051

Tabel 6.12 menunjukkan nilai signifikansi uji *Kolmogorov-Smirnov* untuk MRL *data testing* dan MRL hasil prediksi model SVR pada *RF equipment* secara berturut-turut adalah 0,00 dan 0,2. Nilai tersebut mengindikasikan bahwa MRL *data testing* tidak berdistribusi normal (sig. < 0,05), sedangkan MRL hasil prediksi model SVR berdistribusi normal (sig. > 0,05). Meskipun MRL hasil prediksi SVR berdistribusi normal, namun uji beda antara MRL *data testing* dan hasil prediksi SVR tetap dilaksanakan secara non-parametrik. Karena salah satu kelompok data

(MRL *data testing*) tidak berdistribusi normal (Sunjoyo, et al., 2013). Maka dari itu, *wilcoxon test* dilakukan untuk membandingkan antara MRL *data testing* dengan MRL hasil prediksi SVR.

Tabel 6. 13 Uji Normalitas Data (*MBE equipment*)

Data Uji	Tests of Normality			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
MRL <i>Data testing</i>	.084	795	.000	.945	795	.000
MRL Hasil Prediksi (ANN)	.216	795	.000	.686	795	.000

Tabel 6.13 menunjukkan nilai signifikansi hasil uji *Kolmogorov-Smirnov* untuk MRL *data testing* dan MRL hasil prediksi model ANN pada *MBE equipment* adalah 0,000. Nilai tersebut lebih kecil dari 0,05, mengindikasikan bahwa MRL *data testing* dan MRL hasil prediksi model ANN tidak berdistribusi normal. Berdasarkan kondisi tersebut maka perlu dilakukan *wilcoxon test*, untuk membandingkan antara MRL *data testing* dengan MRL hasil prediksi ANN.

Secara keseluruhan disimpulkan bahwa analisa kelayakan pada penelitian ini dilakukan dengan uji beda berpasangan non-parametrik *wilcoxon test*. Hal tersebut dilakukan karena data yang diuji sebagian besar tidak berdistribusi normal.

6.2.3 Uji Beda dengan *Wilcoxon test*

Wilcoxon test dilakukan untuk mengetahui ada tidaknya perbedaan secara signifikan antara MRL *data testing* dengan MRL hasil prediksi model SVR atau ANN, sesuai dengan Tabel 6.6 – 6.9. Hipotesis yang digunakan dalam *wilcoxon test* ditunjukkan pada Tabel 6.14.

Tabel 6. 14 Hipotesis dalam *Wilcoxon test*

Hipotesis	Keterangan
H0	$\mu_1 = \mu_2$
HA	$\mu_1 \neq \mu_2$

μ_1 dan μ_2 secara berturut turut pada Tabel 6.14 menunjukkan rata-rata MRL *data testing* dan rata-rata MRL hasil prediksi model terpilih. Terima H0 menunjukkan bahwa tidak terdapat perbedaan signifikan antara *data testing* dengan

hasil prediksi model SVR atau model ANN. Untuk tolak H₀ berlaku sebaliknya. Menurut Sunjoyo et al. (2013), H₀ diterima ketika nilai signifikan lebih besar dari 0,05 (*sig.* > 0,05), sedangkan H₀ ditolak ketika nilai signifikan lebih kecil dari 0,05 (*sig.* < 0,05). Perhitungan *wilcoxon test* dilakukan dengan *software SPSS*.

6.2.3.1 Motor Belt Conveyor Equipment (MBC)

Tabel 6.15 menunjukkan hasil *wilcoxon test* antara MRL *data testing* dengan MRL hasil prediksi model SVR pada *motor belt conveyor equipment*.

Tabel 6. 15 *Wilcoxon test* MRL *Data testing* dan MRL Prediksi SVR (*MBC equipment*)

	MRL Data testing	MRL Hasil Prediksi (SVR)
<i>N</i>	805	805
<i>Mean</i>	8.16550	3.9252
<i>Std. Deviation</i>	3.92527	1.73527
<i>Asymp. Sig. (2-tailed)</i>		.000

Hasil *wilcoxon test* pada Tabel 6.15 menunjukkan nilai signifikan sebesar 0,000. Nilai tersebut lebih kecil dibandingkan dengan 0,05, yang artinya terdapat cukup bukti untuk tolak H₀. Dimana mengindikasikan bahwa terdapat perbedaan signifikan antara MRL *data testing* dengan MRL hasil prediksi model SVR. Dengan kata lain model SVR tidak mampu melakukan prediksi sesuai dengan kondisi sebenarnya. Berdasarkan hasil tersebut dapat disimpulkan bahwa model SVR dinyatakan tidak layak untuk digunakan dalam prediksi waktu kegagalan *motor belt conveyor equipment*.

6.2.3.2 Sealing Air Fan Equipment (SAF)

Tabel 6.16 menujukkan hasil *wilcoxon test* antara *data testing* dengan hasil prediksi model ANN pada *sealing air fan equipment*.

Tabel 6. 16 *Wilcoxon test* MRL *Data testing* dan MRL Prediksi ANN (*SAF equipment*)

	MRL Data testing	MRL Hasil Prediksi (ANN)
<i>N</i>	993	993
<i>Mean</i>	58.02131	67.30653
<i>Std. Deviation</i>	36.322075	18.786075
<i>Asymp. Sig. (2-tailed)</i>		.000

Hasil *wilcoxon test* pada Tabel 6.16 menunjukkan nilai signifikan sebesar 0,000. Nilai tersebut lebih kecil dari 0,05, sehingga terdapat cukup bukti untuk tolak H0. Dimana mengindikasikan bahwa MRL *data testing* dan MRL hasil prediksi model ANN memiliki rata-rata yang berbeda secara signifikan. Dengan kata lain model ANN tidak mampu melakukan prediksi sesuai dengan kondisi sebenarnya. Berdasarkan hasil uji tersebut, disimpulkan bahwa model ANN dinyatakan tidak layak untuk digunakan dalam prediksi waktu kegagalan *sealing air fan equipment*.

6.2.3.3 *Rotary Feeder Equipment (RF)*

Tabel 6.17 menunjukkan hasil *wilcoxon test* antara MRL *data testing* dengan MRL hasil prediksi model SVR pada *rotary feeder equipment*.

Tabel 6. 17 *Wilcoxon test* MRL *Data testing* dan MRL Prediksi SVR (*RF equipment*)

	MRL <i>Data testing</i>	MRL Hasil Prediksi (SVR)
<i>N</i>	791	791
<i>Mean</i>	12.52098	12.35978
<i>Std. Deviation</i>	7.275064	4.500788
<i>Asymp. Sig. (2-tailed)</i>	.048	

Hasil *wilcoxon test* pada Tabel 6.17 menunjukkan nilai signifikan sebesar 0,048. Nilai tersebut lebih kecil dibandingkan dengan 0,05, sehingga terdapat cukup bukti untuk tolak H0. Dimana mengindikasikan bahwa terdapat perbedaan signifikan antara MRL *data testing* dan MRL hasil prediksi model SVR. Dengan kata lain model SVR tidak mampu melakukan prediksi sesuai dengan kondisi sebenarnya. Berdasarkan hasil tersebut, disimpulkan bahwa model SVR dinyatakan tidak layak digunakan untuk prediksi waktu kegagalan *rotary feeder equipment*.

6.2.3.4 *Motor Bucket Elevator Equipment (MBE)*

Tabel 6.18 menunjukkan hasil *wilcoxon test* antara MRL *data testing* dengan MRL hasil prediksi model ANN pada *motor bucket elevator equipment*.

Tabel 6. 18 *Wilcoxon test* MRL *Data testing* dan MRL Prediksi ANN (*MBE equipment*)

	MRL <i>Data testing</i>	MRL Hasil Prediksi (ANN)
<i>N</i>	795	795

	MRL Data testing	MRL Hasil Prediksi (ANN)
<i>Mean</i>	7.09031	6.63415
<i>Std. Deviation</i>	3.932981	1.703409
<i>Asymp. Sig. (2-tailed)</i>	.000	

Tabel 6.18 menunjukkan nilai signifikansi sebesar 0,000. Nilai tersebut lebih kecil dibandingkan 0,05, sehingga terdapat cukup bukti untuk tolak H0. Dimana hasil tersebut mengindikasikan bahwa terdapat perbedaan rata-rata yang signifikan antara MRL *data testing* dengan MRL hasil prediksi model ANN. Dengan kata lain model ANN tidak mampu melakukan prediksi sesuai dengan kondisi sebenarnya. Berdasarkan data tersebut, disimpulkan bahwa model ANN dinyatakan tidak layak untuk digunakan dalam prediksi waktu kegagalan *motor bucket elevator equipment*.

Secara keseluruhan dapat disimpulkan bahwa tidak ada model yang dinyatakan layak untuk digunakan. Dikarenakan hasil uji beda dengan *Wilcoxon test* antara MRL *data testing* dengan MRL hasil prediksi model pada setiap *equipment* menunjukkan hasil yang berbeda secara signifikan (nilai sig. < 0,05).

6.2.4 Analisis Hasil Perhitungan Kelayakan Model

Hasil uji kelayakan pada subab sebelumnya menunjukkan bahwa model yang disusun dinyatakan kurang layak untuk digunakan sebagai model prediksi. Analisa lebih lanjut diperlukan untuk mengetahui penyebab model prediksi yang ditawarkan kurang layak untuk diaplikasikan.

Analisis pertama dilakukan melalui uji regresi. Uji regresi dilakukan untuk mengetahui hubungan antara variabel prediktor dengan variabel respon pada setiap *equipment*. Tabel 6.19 – 6.22 menunjukkan hasil uji regresi pada setiap *equipment*.

Tabel 6. 19 Hasil Uji Regresi (*MBC equipment*)

Komponen	Nilai
<i>Multiple R</i>	0.396172092
<i>R Square</i>	0.156952326
<i>Adjusted R Square</i>	0.156638342
<i>Standard Error</i>	3.68333285
<i>Observations</i>	8059
<i>Sig. F</i>	6.64748100078261E-298

Tabel 6. 20 Hasil Uji Regresi (*SAF equipment*)

Komponen	Nilai
<i>Multiple R</i>	0.339562
<i>R Square</i>	0.115303
<i>Adjusted R Square</i>	0.115035
<i>Standard Error</i>	36.81549
<i>Observations</i>	9912
<i>Sig. F</i>	7.12E-263

Tabel 6. 21 Hasil Uji Regresi (*RF equipment*)

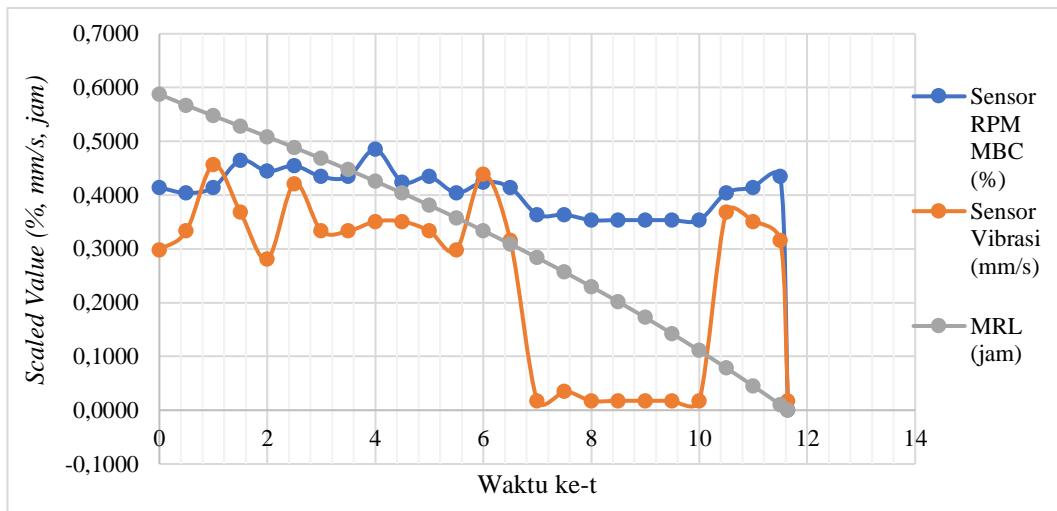
Komponen	Nilai
<i>Multiple R</i>	0.545346
<i>R Square</i>	0.297403
<i>Adjusted R Square</i>	0.297136
<i>Standard Error</i>	6.213818
<i>Observations</i>	7919
<i>Sig. F</i>	0

Tabel 6. 22 Hasil Uji Regresi (*MBE equipment*)

Komponen	Nilai
<i>Multiple R</i>	0.350494
<i>R Square</i>	0.122846
<i>Adjusted R Square</i>	0.122517
<i>Standard Error</i>	3.722178
<i>Observations</i>	7995
<i>Sig. F</i>	9.1E-227

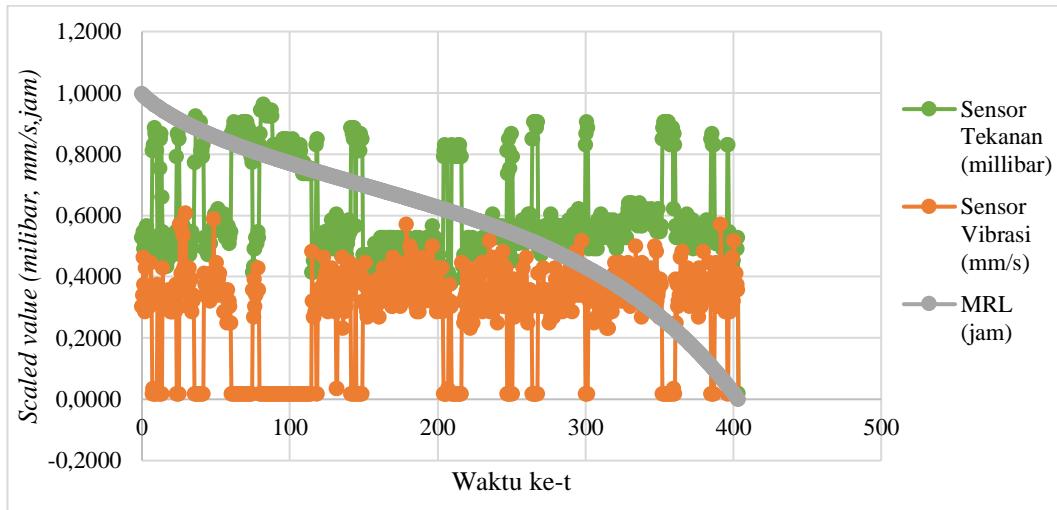
Tabel 6.19 – 6.22 menunjukkan nilai *sig. F* lebih kecil dari 0,05, yang mengindikasikan bahwa pada seluruh *equipment*, variabel prediktor berpengaruh terhadap variabel respon. *Multiple R* mengindikasikan tingkat keeratan hubungan antara variabel respon dengan seluruh variabel prediktor secara besama sama, sedangkan nilai *R square* mengindikasikan kontribusi variabel prediktor terhadap variabel respon (Junaidi, 2014). Meninjau Tabel 6.19 – 6.22 diketahui bahwa kedua komponen tersebut memiliki nilai yang cukup kecil (jauh dari angka 1), yang mana mengindikasikan hubungan antar variabel prediktor dan variabel respon pada setiap *equipment* cukup lemah. *Multiple R* yang semakin besar, mendekati 1, menunjukkan hubungan yang lebih kuat. Selain itu nilai *R square* semakin mendekati 1 menunjukkan kontribusi variabel prediktor semakin besar, artinya kecocokan model semakin baik (Junaidi, 2014). Hal tersebut dapat menjadi penyebab tingginya *error* hasil prediksi yang dihasilkan oleh model. Dimana berujung pada model prediksi yang diterapkan pada setiap *equipment* dinyatakan tidak layak.

Selain uji regresi, analisis kedua dilakukan dengan melihat grafik hasil *monitoring* sensor pada setiap *equipment*. Gambar 6.1 – 6.4 menunjukkan grafik hasil *monitoring* setiap sensor serta nilai MRL pada masing-masing *equipment*. Data pada Gambar 6.1 – 6.4 merupakan data hasil proses *scaling* yang mana memiliki rentang 0 – 1.



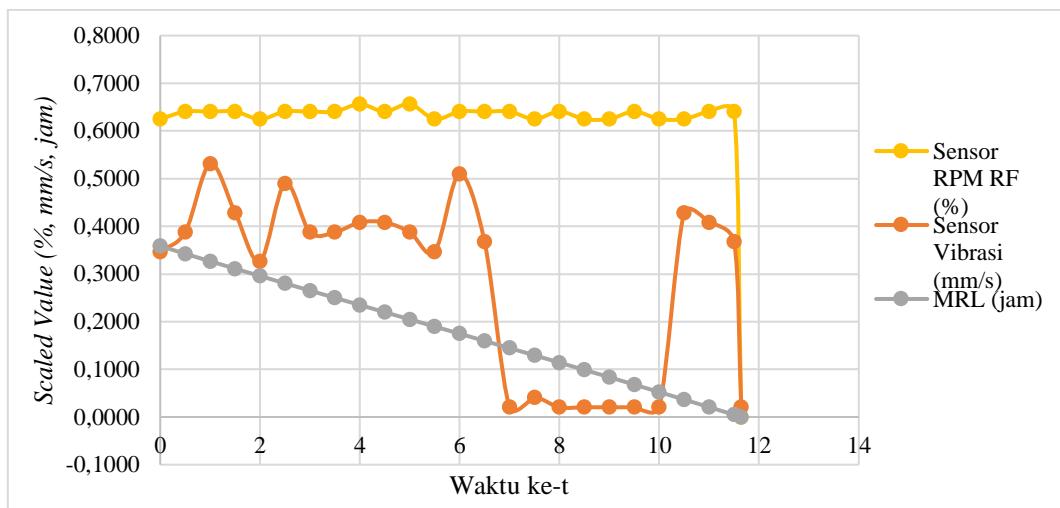
Keterangan: Menggunakan data ke 1 – 25 (*MBC equipment* beroperasi – mengalami kegagalan)

Gambar 6. 1 Grafik *Monitoring* Sensor & MRL *MBC equipment* Skala 0 - 1



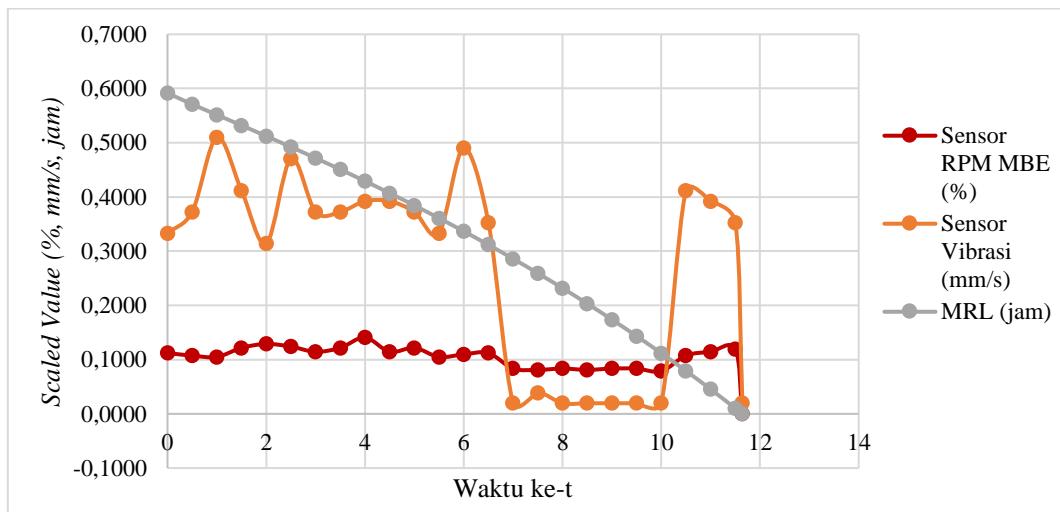
Keterangan: Menggunakan data ke 1 – 808 (*SAF equipment* beroperasi – mengalami kegagalan)

Gambar 6. 2 Grafik *Monitoring* Sensor & MRL *SAF equipment* Skala 0 - 1



Keterangan: Menggunakan data ke 1 – 25 (*RF equipment* beroperasi – mengalami kegagalan)

Gambar 6. 3 Grafik Monitoring Sensor & MRL *RF equipment* Skala 0 - 1



Keterangan: Menggunakan data ke 1 – 25 (*MBE equipment* beroperasi – mengalami kegagalan)

Gambar 6. 4 Grafik Monitoring Sensor & MRL *MBE equipment* Skala 0 - 1

Berdasarkan grafik pada Gambar 6.1 – 6.4 dapat terlihat bahwa sensor yang digunakan untuk melakukan prediksi waktu kegagalan *equipment* menunjukkan angka yang acak, baik pada *motor belt conveyor equipment* hingga *motor bucket elevator equipment*. Dengan kata lain, hasil *monitoring* sensor tidak merepresentasikan adanya proses degradasi fungsi dari *equipment* terkait sebelum *equipment* mengalami kegagalan. Menurut Fu C et al. (2004), prediksi kegagalan suatu mesin/*equipment* dalam *condition-based maintenance* didasarkan pada proses degradasi fungsi dari mesin/*equipment* terkait. Hal tersebut didasarkan pada alasan

bahwa abnormalitas tidak muncul secara tiba-tiba. Oleh karena itu, hasil *monitoring* sensor yang bergerak secara acak dapat menjadi penyebab tingginya *error* yang dihasilkan oleh model SVR atau ANN dan menyebabkan model kurang layak untuk diimplementasikan sebagai model prediksi kegagalan *equipment*.

Berdasarkan hasil wawancara dengan pihak perusahaan, pihaknya menyatakan bahwa hasil *monitoring* sensor RPM baik pada *motor belt conveyor*, *rotary feeder*, dan *motor bucket elevator* serta sensor tekanan pada *sealing air fan equipment* bukan hanya merupakan umpan balik dari aktivitas terkait. Melainkan hasil tersebut dapat diatur oleh operator dalam rangka mempercepat atau memperlambat proses produksi. Pernyataan tersebut semakin memperkuat bukti bahwa penggunaan sensor RPM dan tekanan pada *equipment* yang diterapkan dalam penelitian ini kurang tepat dijadikan sebagai acuan dalam prediksi waktu kegagalan *equipment*.

(Halaman ini sengaja dikosongkan)

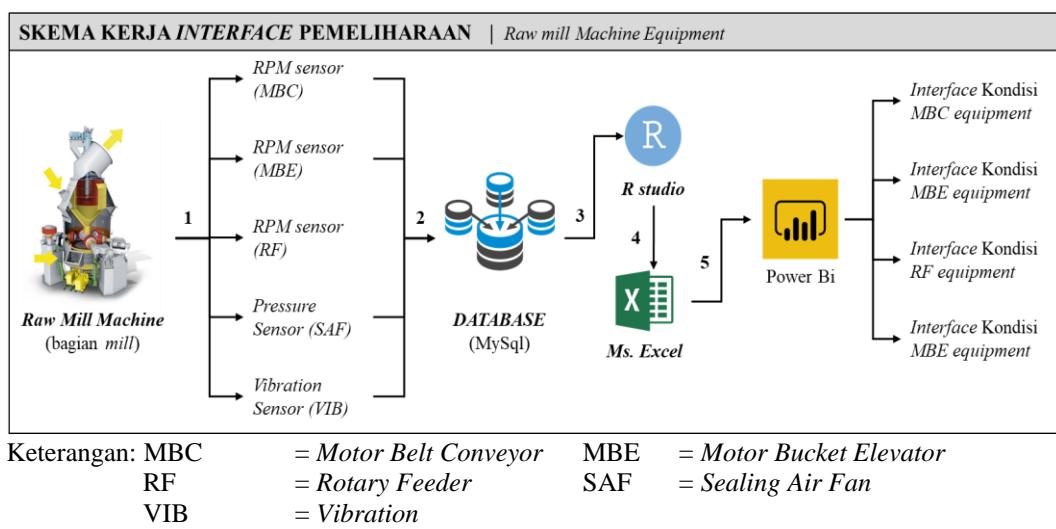
BAB 7

PERANCANGAN DASHBOARD PEMELIHARAAN

Pada bab ini akan dijelaskan mengenai perancangan *dashboard* pemeliharaan untuk pemantauan kondisi dan waktu kegagalan (MRL) setiap *equipment* mesin *raw mill*.

7.1 Sistem Dashboard Pemeliharaan

Perancangan *dashboard* pemeliharaan dilakukan dengan memadukan tiga macam *software*, yaitu *R studio* untuk melakukan prediksi waktu kegagalan, *Ms. Excel* untuk *storing* data sementara, dan *Power BI* sebagai *dashboard* untuk menampilkan data hasil prediksi. Gambar 7.1 menampilkan skema sistem kerja *dashboard* pemeliharaan.



Gambar 7. 1 Rancangan Skema Kerja *Dashboard* Pemeliharaan Mesin *Raw Mill*

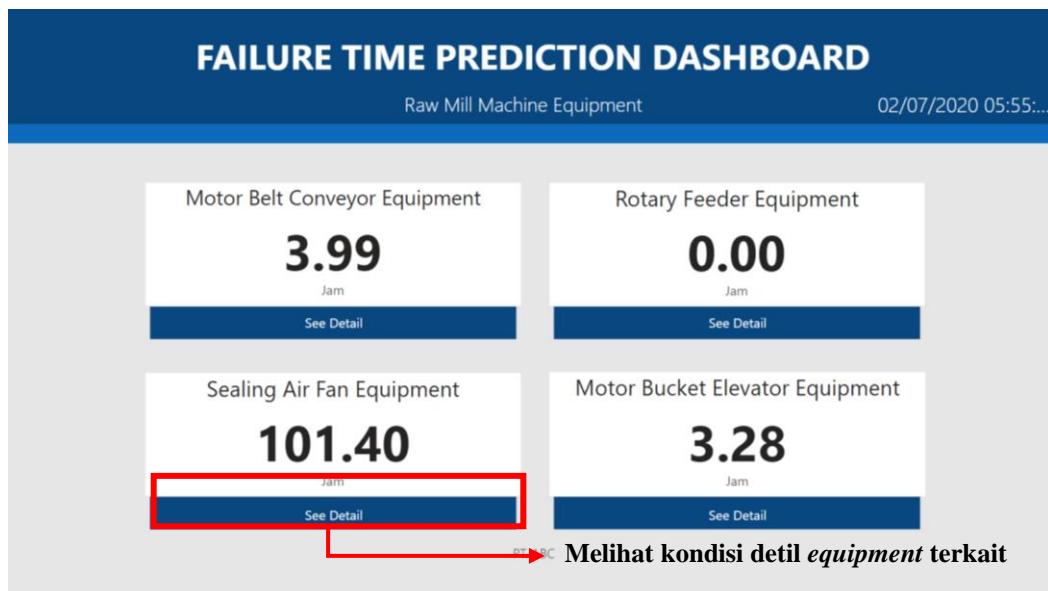
Terdapat lima tahap dalam skema kerja *dashboard* pemeliharaan *equipment* pada mesin *raw mill*. Dalam penelitian ini menggunakan contoh empat *equipment* yang telah dilakukan penyusunan model prediksi pada tahap sebelumnya. Berikut merupakan penjelasan dari setiap tahap rancangan sistem kerja *dashboard* pemeliharaan.

1. Sensor melakukan *monitoring* kondisi *equipment* secara *real time* sesuai dengan penjelasan pada Tabel 2.1.

2. Setiap data hasil *monitoring* oleh sensor disimpan dalam *data base* dengan format MySQL. Penggunaan format ini ditujukan agar data hasil *monitoring* dapat terbaca oleh *software R studio*.
3. Data *monitoring* sensor dalam *data base* kemudian diolah oleh *software R studio* untuk kemudian dilakukan prediksi waktu kegagalan setiap *equipment*. Pada *software R studio* terdapat model prediksi yang telah disusun pada tahap sebelumnya untuk masing-masing *equipment*. Secara teknis, data yang telah terekam sebelumnya oleh *software R studio* digunakan oleh model sebagai *data training* untuk mempelajari pola data. Kemudian data baru hasil *monitoring* sensor akan digunakan sebagai acuan data untuk melakukan prediksi waktu kegagalan masing-masing *equipment*. Koding mengenai prediksi waktu kegagalan *equipment* dapat dilihat pada lampiran E.
4. Hasil prediksi oleh *software R studio* kemudian disimpan sementara pada Ms. Excel. Ms. Excel digunakan untuk menghubungkan data hasil prediksi dengan *software power BI*.
5. *Power Bi* digunakan sebagai *software* untuk menampilkan data pada Ms. Excel secara *real time*. Dimana setiap terjadi tambahan data baru pada Ms. Excel maka secara otomatis *power BI* akan merekam data tersebut untuk ditampilkan pada *dashboard*. *Dashboard power BI* dirancang berbasis web dan dapat diakses secara *online*. Tautan *dashboard* pemeliharaan dapat diakses pada intip.in/DashboardRawMill.

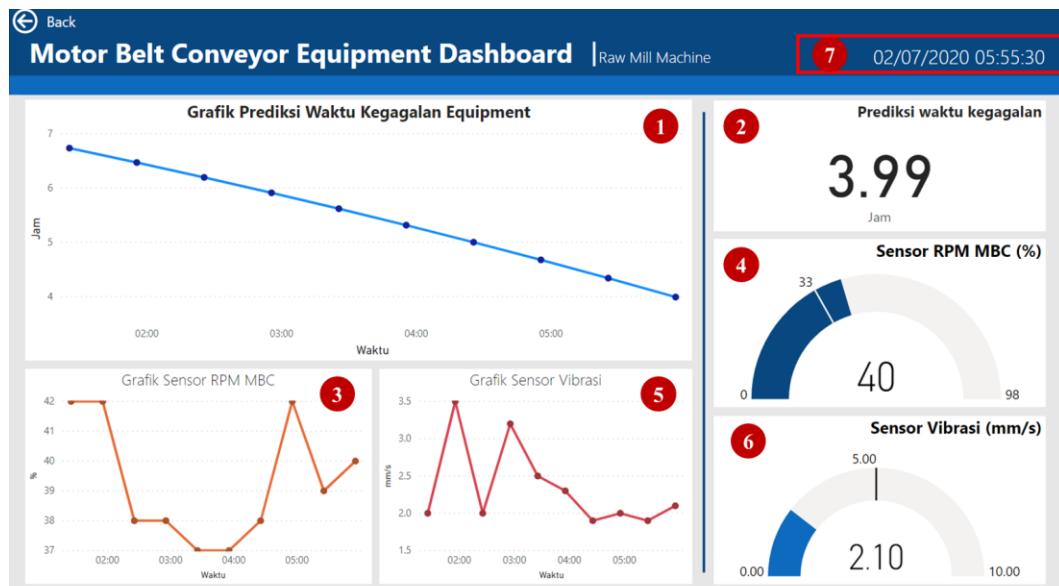
7.2 Desain *Dashboard* Pemeliharaan

Desain *dashboard* pemeliharaan disusun dengan menggunakan *software* *power BI*. Pada *dashboard* pemeliharaan terdapat lima macam tampilan yang disajikan. Tampilan pertama saat pengguna mengakses *link* terkait adalah *dashboard* utama, yang menampilkan waktu kegagalan (MRL) setiap *equipment*. Sedangkan keempat tampilan lainnya menampilkan kondisi detil setiap *equipment*.



Gambar 7. 2 Dashboard Utama Sistem Monitoring Mesin Raw Mill

Gambar 7.2 merupakan tampilan *dashboard* utama yang menunjukkan prediksi waktu kegagalan (MRL) pada setiap *equipment* mesin *raw mill*. Dalam penelitian ini menampilkan MRL *motor belt conveyor*, *rotary feeder*, *sealing air fan* dan *motor bucket elevator equipment*. Pada tampilan tersebut pengguna dapat mengakses detail kondisi untuk setiap *equipment* dengan menekan tombol “*see detail*”. Contoh detail kondisi *equipment* dapat terlihat pada Gambar 7.2 (kondisi *motor belt conveyor*).



Gambar 7. 3 Dashboard Kondisi *Equipment* secara Detail

Gambar 7.3 merupakan *dashboard* yang menampilkan kondisi *equipment* tertentu secara detail. *Dashboard* tersebut menampilkan grafik prediksi waktu kegagalan (MRL), ditunjukkan oleh nomor 1 serta grafik hasil *monitoring* sensor (nomor 3 dan 5). Grafik tersebut menampilkan 10 data terakhir, baik hasil *monitoring* sensor maupun MRL hasil prediksi. Selain itu, dashboard tersebut juga menampilkan nilai aktual hasil monitoring sensor maupun MRL hasil prediksi yang ditunjukkan oleh nomor 2, 4 dan 6. Melalui *dashboard* tersebut pengguna dapat mengetahui dengan detail kondisi dari *equipment* terkait secara aktual dan *real time*. Selain itu, data yang ditampilkan dapat menjadi bahan analisis perusahaan untuk menentukan kebijakan-kebijakan *maintenance* dalam mengoptimalkan kinerja *equipment*. Detail *dashboard* untuk *equipment* lain ditunjukkan pada lampiran F.

BAB 8

KESIMPULAN DAN SARAN

Pada bab ini dijelaskan mengenai kesimpulan yang diperoleh dari pelaksanaan tugas akhir. Selain itu dipaparkan juga mengenai pemberian saran baik untuk perusahaan maupun untuk pengembangan penelitian.

8.1 Kesimpulan

Berikut merupakan kesimpulan yang diperoleh dari pelaksanaan tugas akhir.

1. Model SVR dan ANN pada *motor belt conveyor, sealing air fan, rotary feeder* dan *motor bucket elevator equipment* dibangun dengan menggunakan bantuan *software r studio*, lebih tepatnya *package ‘e1701’* untuk model SVR dan ‘*neuralnet*’ untuk model ANN.
2. Model prediksi terbaik pada *motor belt conveyor equipment* adalah model SVR dengan RMSE sebesar 3,527 dan STD 3,418. Untuk *sealing air fan equipment* adalah model ANN dengan RMSE sebesar 38,876 dan STD sebesar 35,743. Untuk *rotary feeder equipment* adalah model SVR dengan RMSE sebesar 5,886 dan STD sebesar 5,823. Sedangkan untuk *motor bucket elevator equipment* adalah model ANN dengan RMSE sebesar 3,541 dan STD sebesar 3,453.
3. Model terbaik pada seluruh *equipment* dinyatakan tidak layak untuk digunakan sebagai model prediksi, ditunjukkan dengan hasil *wilcoxon test* berada di bawah 0,05. Ketidaklayakan model disebabkan data *monitoring* sensor yang digunakan tidak merepresentasikan adanya proses degradasi fungsi pada *equipment* sehingga kurang tepat digunakan sebagai acuan dalam prediksi waktu kegagalan *equipment*.
4. Sistem *dashboard* pemeliharaan pada mesin *raw mill* dirancang dengan memadukan tiga *software* yaitu *r studio* untuk prediksi waktu kegagalan *equipment*, *Ms. Excel* untuk tempat penyimpanan sementara dan *power BI* untuk menampilkan dan mem-*publish* data hasil prediksi secara *online*.

8.2 Saran

Adapun saran yang diberikan baik untuk pihak perusahaan maupun untuk pengembangan penelitian ini adalah sebagai berikut.

A. Saran untuk pihak perusahaan:

1. Dalam penerapan *condition-based maintenance*, perusahaan perlu untuk memilih sensor yang mampu merepresentasikan adanya degradasi fungsi pada *equipment* untuk memberikan performa model prediksi yang baik dan layak digunakan.
2. Perusahaan dapat menambahkan beberapa sensor yang bekerja secara spesifik untuk memantau kinerja dari *equipment* tertentu untuk peningkatan performa model prediksi serta dapat membantu perusahaan dalam melakukan diagnosis dengan tepat mengenai bagian *equipment* yang mengalami kegagalan.
3. Penerapan rancangan sistem *dashboard* pemeliharaan yang ditawarkan perlu dikembangkan dan disesuaikan dengan sistem *monitoring* dan *database* yang ada pada perusahaan.

B. Saran untuk penelitian selanjutnya:

1. Perlu dilakukan analisa data hasil *monitoring* sensor terlebih dahulu sebelum dilakukan pemodelan dengan *data mining* untuk mengetahui sensor yang digunakan mampu merepresentasikan adanya degradasi fungsi pada *equipment*.
2. Dapat diterapkan metode lain, seperti metode taguchi, untuk mengoptimalkan nilai parameter yang digunakan dalam penyusunan model SVR dan ANN.
3. Sistem *dashboard* yang dirancang masih berjalan secara manual. Perlu adanya pengembangan sistem *dashboard* pemeliharaan untuk dapat melakukan *monitoring* dan prediksi waktu kegagalan *equipment* secara *real time* dengan otomatis.

DAFTAR PUSTAKA

- A.T. de Almeida et al., 2015. Multicriteria and Multi-objective Models for Risk, Reliability and Maintenance Decision Analysis. *International Series in Operations Research & Management Science* 231.
- Al Farobi, M. & Muslimin, 2019. Perencanaan Preventive Maintenance Routine Spot Cooler Pada Plastic Injection Molding Di PT. X. *Prosiding Seminar Nasional Teknik Mesin Politeknik Negeri Jakarta*, Volume I, pp. 842 - 847.
- Amanda, R., Yasin, H. & Prahatama, A., 2014. Analisis Support Vector Regression dalam Memprediksi Kurs Rupiah Terhadap Dollar Amerika Serikat. *Jurnal Gaussian*, Volume 857, p. 849.
- Ansori, N. & Mustajib, M. I., 2013. *Sistem perawatan Terpadu*. 1st ed. Yogyakarta: Graha Ilm.
- Anwar, Syukriah & Muslem, 2016. Analisis Overall Equipment Effectiveness (OEE) dalam Meminimalisir Six Big Losses Pada Mesin Produksi di UD. Hidup Baru. *Industrial Engineering Journal*, Volume V, pp. 52 - 57.
- Arenas-Garcia, J. & Perez-Cruz, F., 2003. Multi-class support vector machines: A new approach. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP '03)*, pp. 781-784.
- Bergmeir, C. & Benitez, J. M., 2012. On the Use of Cross-Validation for Time Series Predictor Evaluation. *Information Sciences*, Volume 191, pp. 192-213.
- Bergstra, J. & Bengio, Y., 2012. Random Search for Hyper-Parameter Optimization. *Journal of Machine Learning Research*, Volume XIII, pp. 281-305.
- Elsayed, E. A., 2012. *Reliability Engineering*. 2nd ed. New Jersey: John Wiley & Sons.
- Fan, R.-E., Chen, P.-H. & Lin, C.-J., 2005. Working Set Selection Using Second Order Information for Training Support Vector Machines. *Journal of Machine Learning Research* 6, Volume 6, pp. 1889 - 1918.

- Fu C, et al., 2004. Predictive maintenance in intelligent control-maintenance-management system for hydroelectroic generating unit. *IEEE Transactions on Energy Conversion*, pp. 79 - 86.
- Ghodrati, B., Ahmadzadeh, F. & Kumar, U., 2012. *Mean Residual Life Estimation Considering Operating Environment*. Sweden, Div. of Operation and Maintenance Engineering Luleå University of Technology.
- Ghozali, I., 2011. *Aplikasi Analisis Multivariate Dengan Program SPSS*. 1st ed. Semarang: Badan Penerbit Universitas Diponegoro.
- Jardine, A., Lin, D. & Banjevic, D., 2006. A Review on Machinery Diagnostics and Prognostics Implementing Condition-Based Maintenance. *Mechanical System and Signal Processing*, pp. 1483 - 1510.
- Jogiyanto, 2004. *Metode Penelitian Bisnis: Salah Kaprah dan Pengalaman-Pengalaman*. Yogyakarta: BPFE.
- Junaidi, J., 2014. *Statistika Deskriptif dengan Microsoft Excel*, Jambi: Fakultas Ekonomi dan Bisnis Universitas Jambi.
- Krenek, J. et al., 2016. Application of Artificial Neural Networks in Condition Based Predictive Maintenance. *Studies in Computational Intelligence*, pp. 1 -11.
- Kursini & Luthfi, E. T., 2009. *Algoritma Data Mining*. 1st ed. Yogyakarta: C.V Andi Offset.
- Maheswari, R., 2013. *Penggunaan Support Vector Regression Pada Prediksi Return Saham Syariah BEI*. Bandung, Proceeding PESAT (Psikologi, Ekonomi, Sastra, Arsitektur & Teknik Sipil).
- Moura, M. d. C., Zio, E., Lins, I. D. & Drogue, E., 2011. Failure and Reliability Prediction by Support Vector Machines Regression of Time Series Data. *Reliability Engineering and System Safety*, Volume 1534, p. 1527.
- Natan, O., Gunawan, A. I. & Dewantara, B. S. B., 2019. Grid SVM: Aplikasi Machine Learning dalam Pengolahan Data Akuakultur. *Jurnal Rekayasa Elektrika*, Volume 15, pp. 7-17.
- Patel, V. B. & Thakkar, H. R., 2014. Review Study on Improvement of Overall Equipment Effectiveness through Total Productive Maintenance. *Journal of Emerging Technologies and Innovative Research (JETIR)*, I(7).

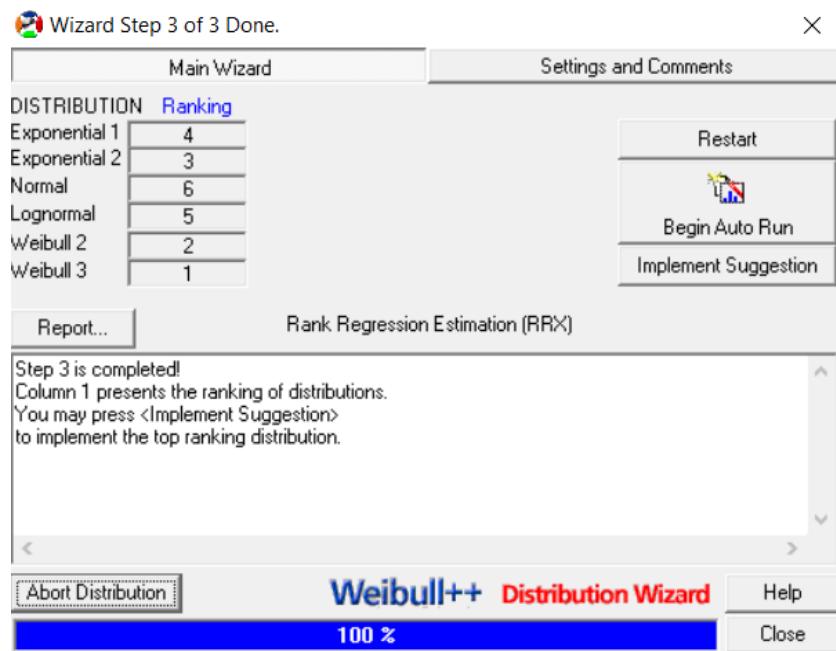
- R. Xu & C. Kwan, 2003. Robust Isolation of Sensor Failures. *Asian Journal of Control* 5, Volume V, pp. 12 - 23.
- Riedmiller, M. & Braun, H., 1993. A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm. *IEEE International Conference on Neural Networks*, Volume 1, pp. 586 - 591.
- Rifqi, M. R., Setiawan, B. D. & Bachthiar, F. A., 2018. Support Vector Regression Untuk Peramalan Permintaan Darah: Studi Kasus Unit Transfusi Darah Cabang – PMI Kota Malang. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, Volume 2, pp. 3332-3342.
- Sahu, H., Shrma, S. & Gondhalakar, S., 2010. A Brief Overview on Data Mining Survey. *International Journal of Computer Technology and Electronics Engineering (IJCTEE)*, I(3), pp. 114 - 121.
- Salah, D., B., 2010. *Concrete Technology*. [Online] Available at: <http://www.uotechnology.edu.iq/> [Accessed 27 Februari 2020].
- Sampaio, G. S., Filho, A. R. d. A. V., da Silva, L. S. & da Silva, L. A., 2019. Prediction of Motor Failure Time Using An Artificial Neural Network. *Sensors*, pp. 1 - 17.
- Santosa, B. & Umam, A., 2018. *Data Mining dan Big Data Analytics*. 2nd ed. Yogyakarta: Penebar Media Pustaka.
- Saputra, G. H., Wigena, A. H. & Sartono, B., 2019. Penggunaan Support Vector Regression Dalam Pemodelan Indeks Saham Syariah Indonesia Dengan Algoritme Grid Search. *Indonesian Journal of Statistics and Its Applications*, Volume 3, pp. 148 - 160.
- Scholkopf, B. & Smola, A., 2002. *Learning With Kernel*, Cambridge, Massachusetts: The MIT Press.
- Seong-woo, W., 2020. Modern Definitions in Reliability Engineering. In: *Reliability Design of Mechanical Systems*. Seoul: Reliability Association of Korea, pp. 53-99.
- Setiyana, B., 2007. Analisis Efisiensi Raw Griding Mill Pada Proses Pembuatan Semen. *ROTASI*, Volume IX, pp. 60 - 65.

- Shumeli, G., Patel, N. R. & Bruce, P. C., 2007. *Data Mining for Business Intelligence*. s.l.:John Wiley & Sons.
- Sunjoyo, et al., 2013. *Applikasi SPSS Untuk SMART Riset*. Bandung: ALFABETA.
- Susanti, D. I., 2016. *Pabrik Semen (Kode Okupasi 2112)*. [Online] Available at: <https://indonesiare.co.id/uploads/BPPDAN%20Highlight%202017.pdf> [Accessed 27 Februari 2020].
- Suyuti, A., Tahir, Z., Alhari, F. & Rafrin, M., 2013. *Analisis Manajemen Perawatan Mesin Industri dengan Menggunakan Jaringan Saraf Tiruan Feed Forward-Back Propagation (Studi Kasus PT. Semen Bosowa Maros)*. Makassar, Seminar Nasional Teknik Informatika (SNATIKA).
- Taufik, Fithri, P. & Arsita, R., 2017. Analisis Pemeliharaan Mesin Raw Mill Pabrik Indarung IV PT Semen Padang. *Prosiding SNTI dan SATELI*, pp. C75 - 84.
- Teimouri, M. & Gupta, A. K., 2013. On the Three-Parameter Weibull Distribution Shape Parameter Estimation. *Journal of Data Science*, Volume 11, pp. 403 -414.
- Varma, S. & Simon, R., 2006. Bias in error estimation when using cross-validation for model selection. *BMC Bioinformatics*, 23 February.
- Wang W, C. A., 2000. Towards a general condition-based maintenance model for a stochastic dynamic system. *J Oper Res Soc*, Volume II, pp. 145 - 155.
- Wang, K., Dai, G. & Guo, L., 2016. Intelligent Predictive Maintenance (IPdM) for Elevator Service. *International Workshop of Advanced Manufacturing and Automation*, pp. 1 - 6.

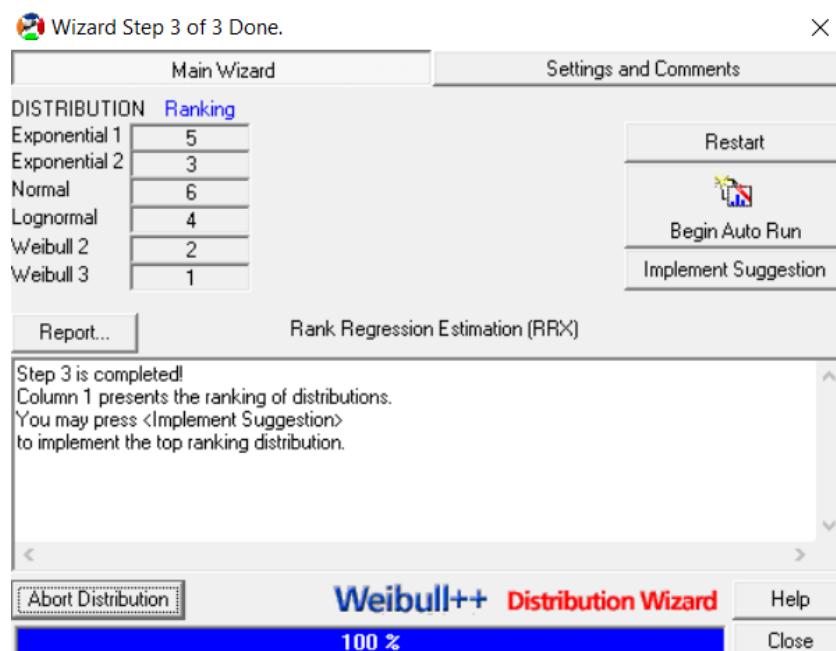
LAMPIRAN

Lampiran A

Hasil fitting distribusi kegagalan setiap *equipment* dengan *software Weibull ++*

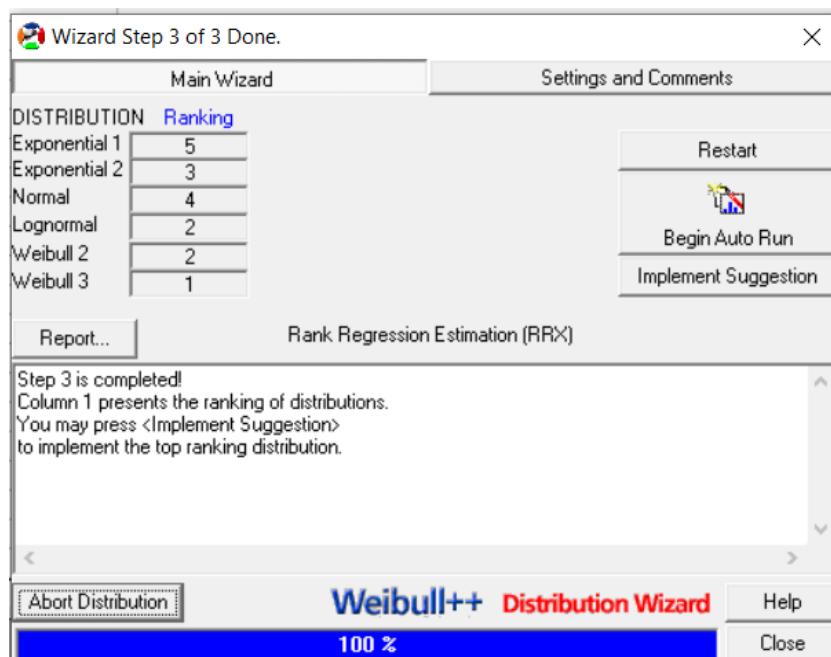


Fitting Distribusi Kegagalan Motor Belt Conveyor Equipment

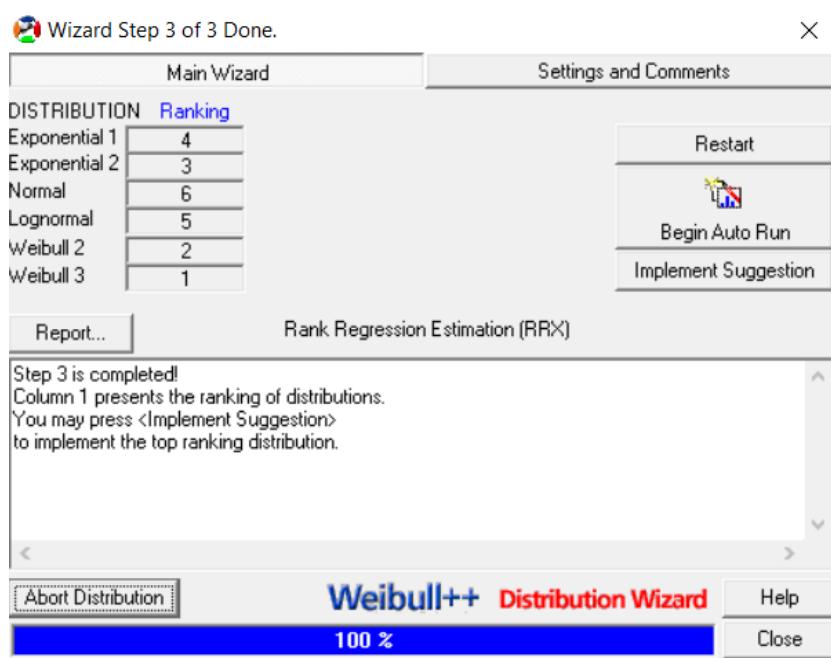


Fitting Distribusi Kegagalan Sealing Air Fan Equipment

Hasil fitting distribusi kegagalan setiap *equipment* dengan *software Weibull ++* (lanjutan)



Fitting Distribusi Kegagalan *Rotary Feeder Equipment*



Fitting Distribusi Kegagalan *Motor Bucket Elevator Equipment*

Lampiran B

Koding Perhitungan MRL setiap *equipment* dengan *software R studio*.

A. Koding Perhitungan MRL pada *motor belt conveyor equipment*

```
#pemilihan data
library(readxl)
ex<-read_excel('D:/RAFIF NOVA RIANTAMA/SEMESTER 8/BISMILLAH TUGAS
AKHIR/KODING/Calculate integral/Print MBC.xlsx', sheet = 1, range
= "A2:E8061", col_names = TRUE)

#perhitungan MRL
beta<-1.0734#parameter beta
alfa<-14.8083#parameter alfa

#hitung Rt
ex$Rt=exp(-(ex$waktu/alfa)^beta)

#hitung integral rt
flognormal<-function(x){exp(-(x/alfa)^beta)}#rumus integral Rt
result<-vector("numeric",nrow(ex))
i<-1
while(i<=nrow(ex)){
  integralrt<-integrate(flognormal,lower =
  as.numeric(ex[i,3]),upper =as.numeric(ex[i,2]))
  int=integralrt[["value"]]
  result[i]=int
  i=i+1
}
ex$integralrt<-result

#hitung MRL
ex$MRL<-ex$integralrt/ex$Rt

#penyusunan kolom
col_order<-c("TTF", "Date &
time", "waktu", "MBC", "VIB", "MRL", "Rt", "integralrt")
ex2<-ex[,col_order]
```

B. Koding Perhitungan MRL pada *sealing air fan equipment*

```
#pemilihan data
library(readxl)
ex<-read_excel('D:/RAFIF NOVA RIANTAMA/SEMESTER 8/BISMILLAH TUGAS
AKHIR/KODING/Calculate integral/Print SAF.xlsx', sheet = 1, range
= "A2:E9914", col_names = TRUE)

#perhitungan MRL
beta<-1.2995#parameter beta
alfa<-171.7242#parameter alfa

#hitung Rt
ex$Rt=exp(-(ex$waktu/alfa)^beta)

#hitung integral rt
flognormal<-function(x){exp(-(x/alfa)^beta)}#rumus integral Rt
result<-vector("numeric",nrow(ex))
i<-1
while(i<=nrow(ex)){
  integralrt<-integrate(flognormal,lower =
  as.numeric(ex[i,3]),upper =as.numeric(ex[i,2]))
  int=integralrt[["value"]]
  result[i]=int
  i=i+1
}
ex$intgralrt<-result

#hitung MRL
ex$MRL<-ex$intgralrt/ex$Rt

#penyusunan kolom
col_order<-c("TTF","Date &
time","waktu","SAF","VIB","MRL","Rt","intgralrt")
ex2<-ex[,col_order]
```

C. Koding Perhitungan MRL pada *rotary feeder equipment*

```
#pemilihan data
library(readxl)
ex<-read_excel('D:/RAFIF NOVA RIAINTAMA/SEMESTER 8/BISMILLAH TUGAS
AKHIR/KODING/Calculate integral/Print RF.xlsx', sheet = 1, range
= "A2:E7921",col_names = TRUE)

#perhitungan MRL
beta<-1.778 #parameter beta
alfa<-34.9463 #parameter alfa

#hitung Rt
ex$Rt=exp(-((ex$waktu)/alfa)^beta)

#hitung integral rt
flognormal<-function(x){exp(-(x/alfa)^beta)}#rumus integral Rt
result<-vector("numeric",nrow(ex))
i<-1
while(i<=nrow(ex)){
  integralrt<-integrate(flognormal,lower =
  as.numeric(ex[i,3]),upper =as.numeric(ex[i,2]))
  int=integralrt[["value"]]
  result[i]=int
  i=i+1
}
ex$intgralrt<-result

#hitung MRL
ex$MRL<-ex$intgralrt/ex$Rt

#penyusunan kolom
col_order<-c("TTF","Date &
time","waktu","RF","VIB","MRL","Rt","intgralrt")
ex2<-ex[,col_order]
```

D. Koding Perhitungan MRL pada *motor bucket elevator equipment*

```
#pemilihan data
library(readxl)
ex<-read_excel('D:/RAFIF NOVA RIANTAMA/SEMESTER 8/BISMILLAH TUGAS
AKHIR/KODING/Calculate integral/Print MBE.xlsx', sheet = 1, range
= "A2:E7997", col_names = TRUE)

#perhitungan MRL
beta<-1.0716#parameter beta
alfa<-14.6812#parameter alfa

#hitung Rt
ex$Rt=exp(-(ex$waktu/alfa)^beta)

#hitung integral rt
flognormal<-function(x){exp(-(x/alfa)^beta)}#rumus integral Rt
result<-vector("numeric",nrow(ex))
i<-1
while(i<=nrow(ex)){
  integralrt<-integrate(flognormal,lower =
  as.numeric(ex[i,3]),upper =as.numeric(ex[i,2]))
  int=integralrt[["value"]]
  result[i]=int
  i=i+1
}
ex$intgralrt<-result

#hitung MRL
ex$MRL<-ex$intgralrt/ex$Rt

#penyusunan kolom
col_order<-c("TTF", "Date &
time", "waktu", "MBE", "VIB", "MRL", "Rt", "intgralrt")
ex2<-ex[,col_order]
```

Lampiran C

Koding transformasi data dengan *software R studio*
(Contoh pada *motor belt conveyor equipment*)

```
#input data
library(readxl)
ex2<-read_excel('D:/RAFIF NOVA RIANTAMA/SEMESTER 8/BISMILLAH
TUGAS AKHIR/KODING/Calculate integral/Print MBC.xlsx', sheet = 1,
range = "A2:F8061", col_names = TRUE)
rawdata<-ex2[,3:6]

#data scaling dalam skala 0 - 1
max<-apply(rawdata,2,max)
min<-apply(rawdata,2,min)
scaled<-as.data.frame(scale(rawdata,center = min,scale = max-
min))
```

Lampiran D

Koding Grid Search Model *Support Vector Regression* dengan *software R studio*

```
library(readxl)
ex2<-read_excel('D:/RAFIF NOVA RIANTAMA/SEMESTER 8/BISMILLAH TUGAS AKHIR /KODING/Calculate integral/Print MBC.xlsx', sheet = 1, range = "A2:F8061 ",col_names = TRUE)
prmsvr<-read_excel('D:/RAFIF NOVA RIANTAMA/SEMESTER 8/BISMILLAH TUGAS AK HIR/KODING/Calculate integral/parameter SVR MBC.xlsx', sheet = 1, range = "B2:D127",col_names = TRUE)

#model SVR (grid search)
#pilih data training & data validation
rawdata<-ex2[,3:6]
datatrain<-rawdata[1:5946,]
datavalid<-rawdata[5947:6937,]

#data scaling
max<-apply(rawdata,2,max)
min<-apply(rawdata,2,min)
scaled<-as.data.frame(scale(rawdata,center = min,scale = max-min))

#data train n valid scaled
trainSVR<-scaled[1:5946, ]
validSVR<-scaled[5947:6937, ]

#prediksi dan perhitungan error (grid search)
library(e1071)
resultsvr1<-vector("numeric",nrow(prmsvr))
resultsvr2<-vector("numeric",nrow(prmsvr))
a<-1
while(a<=nrow(prmsvr)){
  SVR<-svm(MRL~waktu+MBC+VIB,trainSVR,type="eps-regression",kernel="radial ", gamma=prmsvr[a,1], cost=prmsvr[a,2], epsilon=prmsvr[a,3])#model svr
  prd_validSVR<-as.data.frame(predict(SVR,validSVR))#prediksi data validat ion dg data scaling
  predict_validSVR<-(prd_validSVR*(max(rawdata$MRL)-min(rawdata$MRL)))+min (rawdata$MRL)#hasil prediksi data validation
  RMSESVR1<-(sum((datavalid$MRL-predict_validSVR)^2)/nrow(datavalid))^0.5# hitung RMSE data validation

  prd_trainSVR<-as.data.frame(predict(SVR,trainSVR))#prediksi data train
  predict_trainSVR<-(prd_trainSVR*(max(rawdata$MRL)-min(rawdata$MRL)))+min (rawdata$MRL)#hasil prediksi data train
  RMSESVR2<-(sum((datatrain$MRL-predict_trainSVR)^2)/nrow(datatrain))^0.5# hitung RMSE data train

  resultsvr1[a]=RMSESVR1
  resultsvr2[a]=RMSESVR2
  a=a+1
}

prmsvr$RMSE_valid<-resultsvr1
prmsvr$RMSE_Train<-resultsvr2
```

Koding Grid Search Model Artificial Neural Network dengan software R studio

```
library(readxl)
ex2<-read_excel('D:/RAFIF NOVA RIANTAMA/SEMESTER 8/BISMILLAH TUGAS AKHIR /KODING/Calculate integral/Print MBC.xlsx', sheet = 1, range = "A2:F8061 ",col_names = TRUE)
prmNN<-read_excel('D:/RAFIF NOVA RIANTAMA/SEMESTER 8/BISMILLAH TUGAS AKH IR/KODING/Calculate integral/parameter ANN MBC.xlsx', sheet = 1, range = "C3:E3",col_names = FALSE)

#model neural network (grid search)
#pilih data training & data testing
rawdata<-ex2[,3:6]
datatrain<-rawdata[1:7928,]
datavalid<-rawdata[7929:8919,]

#data scaling
max<-apply(rawdata,2,max)
min<-apply(rawdata,2,min)
scaled<-as.data.frame(scale(rawdata,center = min,scale = max-min))

#data train n test scaled
trainNN<-scaled[1:7928, ]
validNN<-scaled[7929:8919, ]

#prediksi dan perhitungan error (grid search)
library(neuralnet)
resultnn1<-vector("numeric",nrow(prmNN))
resultnn2<-vector("numeric",nrow(prmNN))
a<-1
while(a<=nrow(prmNN)){
  NN<-neuralnet(MRL~waktu+MBC+VIB,trainNN,hidden = c(as.numeric(prmNN[a,3])),threshold = as.numeric(prmNN[a,1]),algorithm = "rprop+",act.fct ="logistic",linear.output = TRUE)#model ANN
  prd_validNN<-predict(NN,validNN,all.units = FALSE)
  predict_validNN<-(prd_validNN*(max(rawdata$MRL)-min(rawdata$MRL)))+min(rawdata$MRL)#prediksi data validation
  RMSENN1<-(sum((datavalid$MRL-predict_validNN)^2)/nrow(datavalid))^0.5#
  RMSE data validation

  prd_trainNN<-predict(NN,trainNN,all.units = FALSE)
  predict_trainNN<-(prd_trainNN*(max(rawdata$MRL)-min(rawdata$MRL)))+min(rawdata$MRL)#prediksi data train
  RMSENN2<-(sum((datatrain$MRL-predict_trainNN)^2)/nrow(datatrain))^0.5#
  RMSE data train

  resultnn1[a]=RMSENN1
  resultnn2[a]=RMSENN2
  a=a+1
}

prmNN$RMSE_Test<-resultnn1
prmNN$RMSE_Train<-resultnn
```

Lampiran E

Koding *Dashboard* dengan *software R studio*

```
#pemilihan data
library(readxl)
MBCraw<-read_excel('D:/RAFIF NOVA RIAINTAMA/SEMESTER 8/BISMILLAH T
UGAS AKHIR/KODING/Calculate integral/Data interface.xlsx', sheet
= 1, range = "B2:F3023",col_names = TRUE)
SAFraw<-read_excel('D:/RAFIF NOVA RIAINTAMA/SEMESTER 8/BISMILLAH T
UGAS AKHIR/KODING/Calculate integral/Data interface.xlsx', sheet
= 2, range = "B2:F2911",col_names = TRUE)
RFraw<-read_excel('D:/RAFIF NOVA RIAINTAMA/SEMESTER 8/BISMILLAH TU
GAS AKHIR/KODING/Calculate integral/Data interface.xlsx', sheet =
3, range = "B2:F3016",col_names = TRUE)
MBEraw<-read_excel('D:/RAFIF NOVA RIAINTAMA/SEMESTER 8/BISMILLAH T
UGAS AKHIR/KODING/Calculate integral/Data interface.xlsx', sheet
= 4, range = "B2:F3007",col_names = TRUE)

#tambah data baru
MBC=56
SAF=27
RF=46
MBE=42
VIB=1.5
now=Sys.time()
#equipment MBC
if (MBCraw[nrow(MBCraw),3]<33) {
  waktukeMBC=0
}else{
  waktukeMBC=as.numeric(MBCraw[nrow(MBCraw),2])+(as.numeric(as.da
ta.frame(now)-MBCraw[nrow(MBCraw),1]))
}
newMBC<-list(waktu=now,waktuke=waktukeMBC,MBC=MBC,VIB=VIB,MRL=0)
MBCraw=rbind(MBCraw,newMBC,stringsAsFactors=FALSE)
#equipment SAF
if (SAFraw[nrow(SAFraw),3]<9) {
  waktukeSAF=0
}else{
  waktukeSAF=as.numeric(SAFraw[nrow(SAFraw),2])+(as.numeric(as.da
ta.frame(now)-SAFraw[nrow(SAFraw),1]))
}
newSAF<-list(waktu=now,waktuke=waktukeSAF,SAF=SAF,VIB=VIB,MRL=0)
SAFraw=rbind(SAFraw,newSAF,stringsAsFactors=FALSE)
#equipment RF
if (RFraw[nrow(RFraw),3]<33) {
  waktukeRF=0
}else{
  waktukeRF=as.numeric(RFraw[nrow(RFraw),2])+(as.numeric(as.data.
frame(now)-RFraw[nrow(RFraw),1]))
}
newRF<-list(waktu=now,waktuke=waktukeRF,RF=RF,VIB=VIB,MRL=0)
```

```

RFraw=rbind(RFraw,newRF,stringsAsFactors=FALSE)
#equipment MBE
if (MBEraw[nrow(MBEraw),3]<33) {
  waktukeMBE=0
}else{
  waktukeMBE=as.numeric(MBEraw[nrow(MBEraw),2])+(as.numeric(as.data.frame(now)-MBEraw[nrow(MBEraw),1]))
}
newMBE<-list(waktu=now,waktuke=waktukeMBE,MBE=MBE,VIB=VIB,MRL=0)
MBEraw=rbind(MBEraw,newMBE,stringsAsFactors=FALSE)

#pilih data training & data testing
#Equipment MBC
dataMBC<-MBCraw[,2:5]
trainMBC<-dataMBC[1:(nrow(MBCraw)-1),]
testMBC<-dataMBC[nrow(MBCraw),]
#Equipment SAF
dataSAF<-SAFraw[,2:5]
trainSAF<-dataSAF[1:(nrow(SAFraw)-1),]
testSAF<-dataSAF[nrow(SAFraw),]
#Equipment RF
dataRF<-RFraw[,2:5]
trainRF<-dataRF[1:(nrow(RFraw)-1),]
testRF<-dataRF[nrow(RFraw),]
#Equipment MBE
dataMBE<-MBEraw[,2:5]
trainMBE<-dataMBE[1:(nrow(MBEraw)-1),]
testMBE<-dataMBE[nrow(MBEraw),]

#proses data scaling
#Equipment MBC
maxMBC<-apply(dataMBC,2,max)
minMBC<-apply(dataMBC,2,min)
scaledMBC<-as.data.frame(scale(dataMBC,center = minMBC,scale = maxMBC-minMBC))
#Equipment SAF
maxSAF<-apply(dataSAF,2,max)
minSAF<-apply(dataSAF,2,min)
scaledSAF<-as.data.frame(scale(dataSAF,center = minSAF,scale = maxSAF-minSAF))
#Equipment RF
maxRF<-apply(dataRF,2,max)
minRF<-apply(dataRF,2,min)
scaledRF<-as.data.frame(scale(dataRF,center = minRF,scale = maxRF-minRF))
#Equipment MBE
maxMBE<-apply(dataMBE,2,max)
minMBE<-apply(dataMBE,2,min)
scaledMBE<-as.data.frame(scale(dataMBE,center = minMBE,scale = maxMBE-minMBE))

```

```

#data train dan test scaled
#equipment MBC
sctrainMBC<-scaledMBC[1:(nrow(MBCraw)-1), ]
sctestMBC<-scaledMBC[nrow(MBCraw), ]
#equipment SAF
sctrainSAF<-scaledSAF[1:(nrow(SAFraw)-1), ]
sctestSAF<-scaledSAF[nrow(SAFraw), ]
#equipment RF
sctrainRF<-scaledRF[1:(nrow(RFraw)-1), ]
sctestRF<-scaledRF[nrow(RFraw), ]
#equipment MBE
sctrainMBE<-scaledMBE[1:(nrow(MBEraw)-1), ]
sctestMBE<-scaledMBE[nrow(MBEraw), ]

#proses prediksi waktu kegagalan
library(e1071)
library(neuralnet)
#equipment MBC
mdMBC<-svm(MRL~waktu+MBC+VIB,sctrainMBC,type="eps-regression",kernel="radial", gamma=0.01, cost=1000, epsilon=0.8)#model svr
scprdMBC<-as.data.frame(predict(mdMBC,sctestMBC))#pridksi dg data scaling
prdMBC<-(scprdMBC*(max(MBCraw$MRL)-min(MBCraw$MRL)))+min(MBCraw$MRL)#hasil prediksi
MBCraw<-MBCraw[-nrow(MBCraw),]
newMBC<-list(waktu=now,waktu=waktukeMBC,MBC=MBC,VIB=VIB,MRL=as.numeric(prdMBC))
MBCraw=rbind(MBCraw,newMBC,stringsAsFactors=FALSE)

#equipment SAF
mdSAF=neuralnet(MRL~waktu+SAF+VIB,sctrainSAF,hidden = c(3,1),threshold=0.1,algorithm = "rprop+",act.fct ="logistic",linear.output = TRUE)
scprdSAF<-predict(mdSAF,sctestSAF,all.units = FALSE)#pridksi dg data scaling
prdSAF<-(scprdSAF*(max(SAFraw$MRL)-min(SAFraw$MRL)))+min(SAFraw$MRL)#hasil prediksi
SAFraw<-SAFraw[-nrow(SAFraw),]
newSAF<-list(waktu=now,waktu=waktukeSAF,SAF=SAF,VIB=VIB,MRL=as.numeric(prdSAF))
SAFraw=rbind(SAFraw,newSAF,stringsAsFactors=FALSE)

#equipment RF
mdRF<-svm(MRL~waktu+RF+VIB,sctrainRF,type="eps-regression",kernel="radial", gamma=0.01, cost=1000, epsilon=0.6)#model svr
scprdRF<-as.data.frame(predict(mdRF,sctestRF))#pridksi dg data scaling
prdRF<-(scprdRF*(max(RFraw$MRL)-min(RFraw$MRL)))+min(RFraw$MRL)#hasil prediksi
RFraw<-RFraw[-nrow(RFraw),]
newRF<-list(waktu=now,waktu=waktukeRF,RF=RF,VIB=VIB,MRL=as.numeric(prdRF))

```

```

RFraw=rbind(RFraw,newRF,stringsAsFactors=FALSE)

#equipment MBE
mdMBE=neuralnet(MRL~waktuke+MBE+VIB,sctrainMBE,hidden = c(2,1,2),
threshold=0.1,algorithm = "rprop+",act.fct ="tanh",linear.output
= TRUE)
scprdMBE<-predict(mdMBE,sctestMBE,all.units = FALSE)#pridksi dg d
ata scaling
prdMBE<-(scprdMBE*(max(MBERaw$MRL)-min(MBERaw$MRL)))+min(MBERaw$M
RL)#hasil prediksi
MBERaw<-MBERaw[-nrow(MBERaw),]
newMBE<-list(waktu=now,waktuke=waktukeMBE,MBE=MBE,VIB=VIB,MRL=as.
numeric(prdMBE))
MBERaw=rbind(MBERaw,newMBE,stringsAsFactors=FALSE)

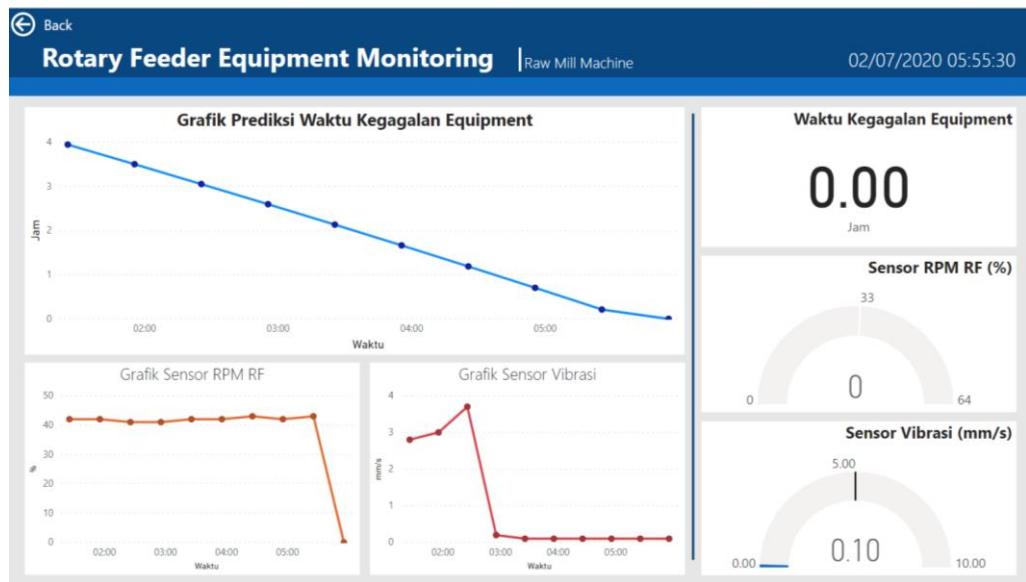
#equipment MBE
library(XLConnect)
wb<-loadWorkbook("Data Interface1.xlsx",create = TRUE)
writeWorksheet(wb,MBCraw,sheet = "MBC",startRow = 3,startCol = 2,
header = FALSE)
writeWorksheet(wb,SAFraw,sheet = "SAF",startRow = 3,startCol = 2,
header = FALSE)
writeWorksheet(wb,RFraw,sheet = "RF",startRow = 3,startCol = 2,he
ader = FALSE)
writeWorksheet(wb,MBERaw,sheet = "MBE",startRow = 3,startCol = 2,
header = FALSE)
saveWorkbook(wb)

MBCraw<-MBCraw[-1,]
SAFraw<-SAFraw[-1,]
RFraw<-RFraw[-1,]
MBERaw<-MBERaw[-1,]

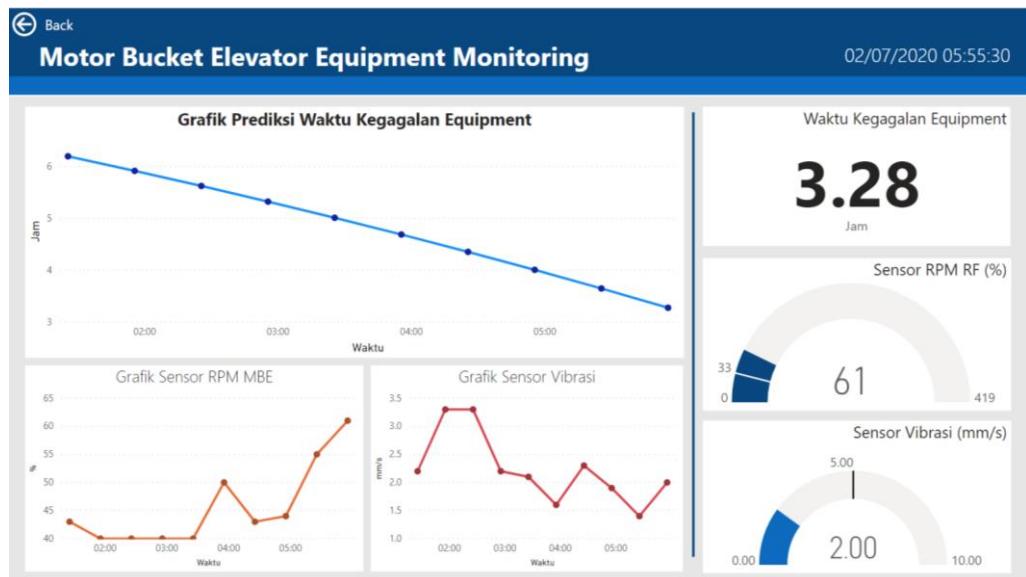
```

Lampiran F

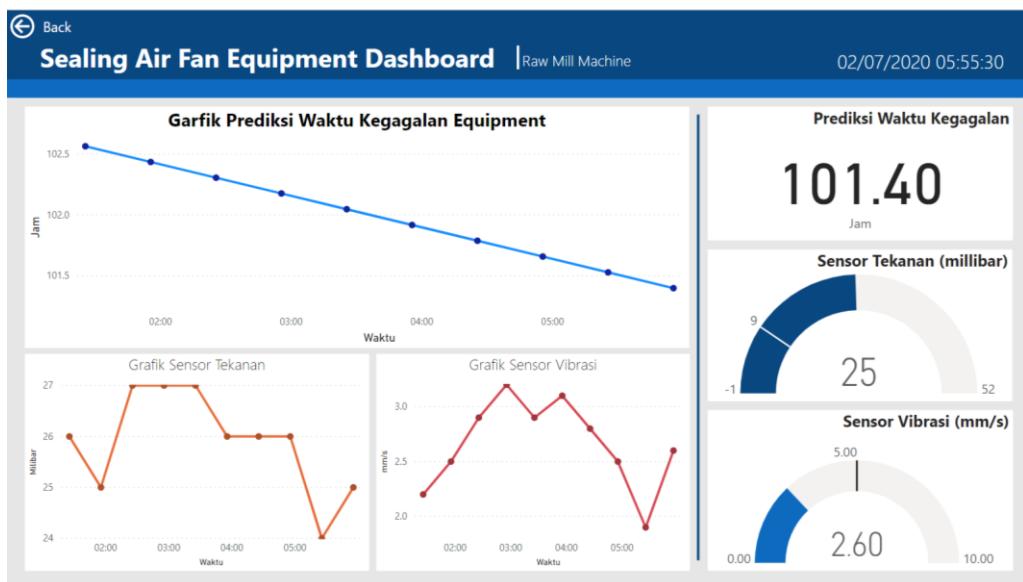
Desain Dashboard Pemantauan Kondisi *Equipment*



Dashboard Pemantauan Detil Kondisi *Rotary Feeder Equipment*



Dashboard Pemantauan Detil Kondisi *Motor Bucket Elevator Equipment*



Dashboard Pemantauan Detil Kondisi Sealing Air Fan Equipment

Lampiran G

Hasil Wawancara dengan Pihak Perusahaan

Tanggal	Media	Pertanyaan	Jawaban
Jumat, 24 Januari 2020	Wawancara langsung	Permasalahan apa yang sedang terjadi?	<p>1. Unit V PT ABC sering mengalami breakdown padahal termasuk dalam unit baru (berdiri 2014)</p> <p>2. Terdapat banyak data sensor untuk deteksi kondisi tapi belum terutilisasi dengan baik</p>
Jumat, 14 Februari 2020 Dan kamis, 13 Feb 2020	Wawancara langsung	Jenis <i>maintenance</i> apa yang sudah diterapkan?	<p>Terdapat dua macam maintenance yang dilakukan.</p> <p>1. Preventive maintenance (dengan melakukan <i>overhaul</i>) > ini terjadwal setiap tahun di rentang bulan januari – juli</p> <p>Selain itu juga dilakukan pengecekan kondisi mesin / equipment melalui sensor real time dan pengecekan manual sebagai validasi sensor</p> <p>2. Corrective maintenance > dilakukan dengan penggantian part saat terjadi kerusakan</p>
Jumat, 14 Februari 2020	Wawancara langsung dan WA	Terdapat berapa unit produksi di PT ABC?	<p>Awalnya terdapat unit 1 (proses basah), unit II, III, dan IV (proses kering)</p> <p>Tahun 1986 unit 1 ditutup > dinilai memberi cost yang lebih banyak dibanding proses kering. Karena bahan bakar solar dinilai lebih mahal.</p> <p>Tahun 2014 unit V diresmikan untuk mulai produksi.</p>
Jumat, 14 Februari 2020	Wawancara langsung	Bagaimana proses produksi yang berlangsung?	<p>Unit V terdapat 1 mesin rawmill, 1 mesin kiln dan 2 mesin <i>cement mill</i></p> <p>Kapasitas produksi:</p> <p>raw mill: asli 900 ton/jam real ± 780 ton/jam</p> <p>kiln: asli 750 ton/jam real ± 680 ton/jam</p>

Tanggal	Media	Pertanyaan	Jawaban
			<p><i>cement mill:</i> asli 250 ton/jam real \pm 225 ton/jam proses produksi Digambar sbg berikut</p> <pre> graph LR A[Bahan baku] --> B[RAW MILL ± 780 ton / jam] B --> C[Raw meal Cilo] C --> D[KILN ± 680 ton / jam] D --> E[Clinker DOM] E --> F[CEMENT MILL ± 225 ton / jam] E --> G[CEMENT MILL ± 225 ton / jam] F --> H[Cement Cilo] G --> I[Cement Cilo] H --> J[Cement Cilo] I --> K[Cement Cilo] </pre>
Jumat, 14 Februari 2020	Wawancara langsung	Berapa harga produk?	<p>Harga semen Rp 1020 / kg Harga rawmeal Rp 400 / kg (estimasi > rahasia perusahaan) Harga clinker Rp 750 / kg (estimasi > rahasia perusahaan)</p>
Jumat 21 feb 2020	WA	<p>Ada berapa banyak equipment pada mesin rawmill?</p> <p>Bagaimana proses produksi semen keseluruhan?</p>	<p>Terdapat 598 equipment, setiap equipment ditempel dengan sensor</p> <p>The diagram illustrates a cement plant's flow from a limestone quarry through various processing stages: quarry, dump truck, excavator, limestone, crusher, preheater tower, Raw Mill, kiln, cooler, dome, silo, rotary feeder, and finally the Cement Mill which outputs to a truck.</p>
Jumat 28 feb 2020	Wawancara langsung	Potensi kerusakan yang terjadi?	<p>Motor belt conveyor : Belt sobek > karena terlalu sering kejatuhan bahan (batu kapur dll) > belt diganti / disambung / ditambal Sensor rusak > ganti sensor Sensor miring > penyesuaian sensor kembali</p> <p>Bucket elevator : Terganjal batu kapur sehingga tidak bisa gerak > bahan terlalu besar > terdapat material lain yang masuk > menyebabkan RPM rendah dan persentase motor driver turun Sensor rusak > ganti sensor Sensor miring > penyesuaian sensor kembali</p> <p>Rotary feeder : Terganjal batu kapur > tidak bisa gerak > bahan terlalu besar > terdapat material lain masuk (kayu dll) Sensor rusak > ganti sensor Sensor miring > penyesuaian sensor kembali</p> <p>Bin material 1 :</p>

Tanggal	Media	Pertanyaan	Jawaban
			<p>Material kosong (belum terisi > sensor mendeteksi kosong) > belt conv. Menuju mill mati</p> <p>Bin Material 2 : Material kosong (belum terisi > sensor mendeteksi kosong) > belt conv. Menuju mill mati</p> <p>Vibrasi : Mendeteksi getaran pada keseluruhan bagian mill</p>
Jumat 28 feb 2020	Wawancara langsung	Mengapa menggunakan 8 sensor tersebut?	Hasil analisis perusahaan menyatakan sensor tersebut sensor yang paling sering mengalami kerusakan (sering muncul dalam pembahasan) > jika dipareto itu merupakan sensor kritis yang dapat menyelesaikan permasalahan lainnya.
Senin, 1 Juni 2020	WA	Data operasi di bawah 30 menit dapat dihilangkan?	Penghapusan tersebut diperbolehkan karena ada beberapa kondisi sebelum beroperasi secara normal, dilakukan uji coba terlebih dahulu pada equipment.
Selasa, 7 Juli 2020	Video Conference (Google Meet)	<p>Konsultasi mengenai hasil perhitungan</p> <p>Penggunaan data sensor setiap 30 menit apakah diperbolehkan</p> <p>Penggunaan sensor untuk <i>monitoring equipment</i> secara spesifik</p> <p>Apakah ada pengaruh setting operator terhadap hasil pembacaan sensor?</p>	<p>Diperbolehkan, penggunaan data setiap 30 menit cukup representatif dalam menunjukkan kondisi mesin secara real time.</p> <p>Equipment MBC: Sensor RPM MBC & vibrasi Equipment SAF: Sensor Tekanan & Vibrasi Equipment RF: Sensor RPM RF & vibrasi Equipment MBE: Sensor RPM MBE & Vibrasi</p> <p>Pembagian sensor seperti kondisi di atas dapat dilakukan, karena memang secara spesifik sensor RPM MBC dll melekat pada equipment tersebut, sedangkan vibrasi melekat pada mill secara keseluruhan.</p> <p>Kondisi tersebut bisa terjadi, dimana operator dapat melakukan penyesuaian terhadap kecepatan RPM, tekanan, atau komponen lainnya untuk mengatur jalannya proses produksi. Disamping equipment tersebut dapat berjalan secara otomatis.</p>
Rabu, 16 Juli 2020	Video conference (google meet)	Konfirmasi mengenai error tinggi	Perusahaan mengkonfirmasi bahwa error dapat disebabkan karena sensor yang digunakan sebagai prediksi tidak memiliki hubungan dalam proses degradasi fungsi equipment. Sehingga untuk kedepannya perusahaan dapat memilih sensor yang tepat untuk digunakan sebagai acuan atau menambah sensor agar performa model prediksi yang dihasilkan lebih baik.

BIOGRAFI PENULIS



Penulis lahir di Gresik pada tanggal 27 November 1997 dengan nama lengkap Rafif Nova Riantama. Penulis merupakan anak pertama dari dua bersaudara. Penulis telah menempuh pendidikan formal di TK Al-Ibrah Gresik, SD Muhammadiyah GKB Gresik, SMPN 1 Gresik, dan SMAN 1 Gresik. Setelah SMA, pada tahun 2016 penulis melanjutkan pendidikan pada jenjang S1 di Departemen Teknik Sistem dan Industri, Institut Teknologi Sepuluh Nopember melalui jalur SNMPTN.

Selama masa perkuliahan penulis aktif mengikuti beberapa kompetisi dan telah mendapatkan total 15 penghargaan baik nasional maupun internasional. Beberapa diantaranya Juara 1 Lomba Penelitian Transportasi, Juara 1 Think Efficiency, dan Juara 3 IEOM paper conference (Detroit, Michigan). Selain itu penulis juga aktif sebagai asisten pada Laboratorium Sistem Manufaktur ITS sejak tahun 2018 hingga 2020 dan memiliki pengalaman menjadi koordinator asisten pada kepengurusan 2019/2020 semester ganjil. Beberapa kegiatan kepanitiaan dan organisasi yang diikuti penulis selama perkuliahan diantaranya sebagai anggota Robot in Action ITS EXPO 2017, staf Departemen Sosial Masyarakat BEM FTI ITS periode 2017/2018 dan *Steering Committee* pada IE Games 2017. Penulis melaksanakan kerja praktik pada PT. Mercedes-Benz Indonesia, tepatnya pada departemen *incoming quality inspection part*. Bagi pembaca yang ingin berdiskusi, memberikan saran maupun masukkan terkait penelitian Tugas Akhir dapat menghubungi penulis melalui email: riantama76@gmail.com