



TUGAS AKHIR – TI 184833

PERANCANGAN STRATEGI *MAINTENANCE* PADA *KILN EQUIPMENT* MENGGUNAKAN METODE *CONDITION BASED MAINTENANCE* BERBASIS *DATA ANALYTICS* (STUDI KASUS: PT XYZ)

ABIYYU DIMAS PRASANTO

NRP 02411640000141

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

**MAINTENANCE STRATEGY DESIGN IN KILN EQUIPMENT
USING CONDITION BASED MAINTENANCE METHOD
BASED ON DATA ANALYTICS (CASE STUDY: PT XYZ)**

ABIYU DIMAS PRASANTO

NRP 02411640000141

SUPERVISOR :

NANI KURNIATI, S.T., M.T., Ph.D.

NIP 197504081998022001

CO-SUPERVISOR :

DEWANTI ANGGRAHINI, S.T., M.T.

NIP 198805022019032014

DEPARTMENT OF SYSTEM AND INDUSTRIAL ENGINEERING

Faculty of Industrial Technology and System Engineering

Institut Teknologi Sepuluh Nopember

Surabaya 2020

(Halaman ini Sengaja Dikosongkan)

LEMBAR PENGESAHAN

PERANCANGAN STRATEGI *MAINTENANCE* PADA *KILN EQUIPMENT* MENGGUNAKAN METODE *CONDITION BASED MAINTENANCE* BERBASIS *DATA ANALYTICS* (STUDI KASUS: PT XYZ)

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

Penulis:

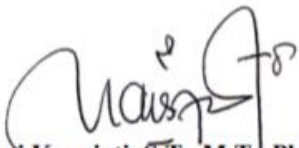
Abiyyu Dimas Prasanto

NRP 02411640000141

Disetujui oleh:

Pembimbing

Ko-Pembimbing


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


Dewanti Anggrahini, S.T., M.T
NIP. 198805022019032014



(Halaman ini Sengaja Dikosongkan)

**PERANCANGAN STRATEGI MAINTENANCE PADA KILN
EQUIPMENT MENGGUNAKAN METODE CONDITION
BASED MAINTENANCE BERBASIS DATA ANALYTICS
(STUDI KASUS: PT XYZ)**

Nama	: Abiyyu Dimas Prasanto
NRP	: 02411640000141
Departemen	: Teknik Sistem dan Industri - ITS
Dosen Pembimbing	: Nani Kurniati, S.T., M.T., Ph.D.
Dosen Ko- Pembimbing	: Dewanti Anggrahini, S.T., M.T.

ABSTRAK

PT XYZ merupakan salah satu produsen semen yang terdapat di Kawasan Indonesia Timur. Unit V sebagai pabrik baru memiliki desain kapasitas produksi terbesar sering mengalami *breakdown* dalam operasinya. Sebesar 33% kasus *breakdown* disebabkan oleh *kiln equipment*. Tercatat bahwa *kiln* mengalami *breakdown* sebanyak 198 kali dengan total *downtime* sebesar 5042 jam pada periode 2015 hingga 2018. *Downtime* tersebut menyebabkan *availability* rata-rata sebesar 83,6% masih berada dibawah target perusahaan yaitu 90% *World Class OEE*. Terjadinya *breakdown* terpantau menggunakan peralatan sensor yang menghasilkan data sensor. Namun data sensor tersebut belum digunakan secara optimal oleh perusahaan. Penelitian ini bertujuan untuk meminimalkan *downtime* dengan menggunakan *framework condition-based maintenance* yang berbasis *data analytics*. Teknik *k-means clustering* mendapatkan lima jenis klaster berdasarkan karakteristik data sensor. Selanjutnya dilakukan prediksi menggunakan nonlinear regression pada kelima klaster. Didapatkan bahwa tingkat kerusakan berat terjadi pada klaster 3, kerusakan ringan pada klaster 4, sedangkan kerusakan sedang pada klaster 1, klaster 2, dan klaster 5. Kemudian hasil prediksi tersebut digunakan untuk merancang *maintenance strategy* menggunakan model *downtime minimization*. *Constant interval replacement policy* (CIRP) pada model tersebut digunakan untuk menentukan penjadwalan maintenance yang optimal. Didapatkan bahwa jadwal *maintenance* pada klaster 3 dilakukan pada interval 800 jam. Dan jadwal *maintenance* klaster 4 dilakukan pada interval 400 jam. Sedangkan jadwal *maintenance* klaster 1, klaster 2, dan klaster 5 secara berturut-turut pada interval 800 jam, 2100 jam, dan 400 jam. Namun pada klaster 2 dengan interval 2100 kurang sesuai dengan kondisi *downtime* sebenarnya. Hal ini diakibatkan oleh data sensor yang kurang sesuai sehingga menyebabkan hasil prediksi yang kurang akurat.

Kata Kunci : *Condition-Based Maintenance, Data Mining, K-Means Clustering, Nonlinear Regression, Preventive Maintenance and Replacement Models*

(Halaman ini Sengaja Dikosongkan)

MAINTENANCE STRATEGY DESIGN IN KILN EQUIPMENT USING CONDITION BASED MAINTENANCE METHOD BASED ON DATA ANALYTICS (CASE STUDY: PT XYZ)

Name : Abiyyu Dimas Prasanto
NRP : 02411640000141
Department : Teknik Sistem dan Industri - ITS
Supervisors : Nani Kurniati, S.T., M.T., Ph.D.
Co-Supervisor : Dewanti Anggrahini, S.T., M.T.

ABSTRACT

PT XYZ is a cement producer in Eastern Indonesia. Unit V as a new plant has the largest production capacity design, often occurring breakdown in operations. 33% of breakdown cases are caused by kiln equipment. It was noted that the kiln experienced a breakdown of 198 times with a total downtime of 5042 hours in the period 2015 to 2018. The downtime caused an average availability of 83.6% to be below the company's target of 90% World Class OEE. The breakdown is monitored using sensor equipment that generates sensor data. But the sensor data has not been used optimally by the company. This study aims to minimize downtime by using a condition-based maintenance framework based on data analytics. The k-means clustering technique gets five types of clusters based on the characteristics of the sensor data. Then predictions are made using nonlinear regression in the five clusters. It was found that heavy damage occurred in cluster 3, mild damage in cluster 4, whereas moderate damage in cluster 1, cluster 2, and cluster 5. Then the prediction results were used to design maintenance strategies using the downtime minimization model. Constant interval replacement policy (CIRP) on the model is used to determine optimal maintenance scheduling. It was found that the maintenance schedule for cluster 3 was at 800 hours intervals. And cluster 4 maintenance schedule was at 400 hours intervals. Whereas the maintenance schedule for cluster 1, cluster 2, and cluster 5 are respectively at intervals of 800 hours, 2100 hours and 400 hours. However, cluster 2 with 2100 interval is not suitable with actual downtime conditions. This is caused by inadequate sensor data that causes inaccurate prediction results.

Key Words : *Condition-Based Maintenance, Data Mining, K-Means Clustering, Nonlinear Regression, Preventive Maintenance and Replacement Models*

(Halaman ini Sengaja Dikosongkan)

KATA PENGANTAR

Puji dan syukur penulis panjatkan ke hadirat Allah SWT karena atas limpahan rahmat dan karunia-Nya, penulis dapat menyelesaikan Laporan Tugas Akhir ini dengan lancar dan tepat yang berjudul “Perancangan Strategi *Maintenance* Pada *Kiln equipment* Menggunakan Metode *Condition Based Maintenance* Berbasis *Data Analytics* (Studi Kasus: PT XYZ)”.

Laporan Tugas Akhir ini disusun sebagai salah satu syarat memperoleh gelar Sarjana pada program studi S-1 Departemen Teknik Sistem dan Industri, Institut Teknologi Sepuluh Nopember Surabaya. Selama proses pengerjaan laporan, penulis menerima banyak bantuan, saran, dan dukungan motivasi dari berbagai pihak. Pada kesempatan ini penulis ingin menyampaikan ucapan terimakasih kepada seluruh pihak yang telah membantu dalam penyelesaian laporan ini, yaitu :

1. Allah SWT yang senantiasa melindungi dan memberikan petunjuk dan kemudahan kepada penulis dalam menyelesaikan laporan Tugas Akhir ini.
2. Nani Kurniati, S.T., M.T., Ph.D. selaku Dosen Pembimbing yang telah meluangkan waktu untuk membimbing penulis dalam penyelesaian Tugas Akhir ini.
3. Dewanti Anggrahini, S.T., M.T. selaku Ko-Dosen Pembimbing yang selalu memberikan bimbingan dan arahan dalam penyelesaian Tugas Akhir ini.
4. Bapak Inman Yasin S.T. yang telah memberikan kesempatan, bantuan, dan bimbingan dalam proses pengambilan data di perusahaan.
5. Bapak Prof. Ir. Budi Santosa, M.Sc., Ph.D., Bapak Dr. Ir. Mokh Suef, M.Sc(Eng), Bapak Bapak Prof. Ir. Moses Laksono Singgih, M.Sc., M.Reg.Sc., Ph.D., IPU, dan Ibu Putu Dana Karningsih S.T., M.Eng.Sc., Ph.D., selaku dosen penguji Tugas Akhir yang telah banyak memberi saran dan masukan untuk perbaikan Tugas Akhir ini.
6. Bapak Nurhadi Siswanto, S.T., M.S.I.E., Ph.D. selaku Kepala Departemen Teknik Sistem dan Industri, Institut Teknologi Sepuluh Nopember Surabaya.
7. Segenap dosen dan karyawan Departemen Teknik Sistem dan Industri ITS yang telah banyak memberikan pelajaran dan pengalaman bagi penulis

selama menempuh studi di Departemen Teknik Sistem dan Industri ITS.

8. Kedua orang tua penulis dan keluarga yang selalu memberikan dukungan, semangat, dan motivasi kepada penulis.
9. Asisten Laboratorium Sistem Manufaktur angkatan 2015, 2016, dan 2017 atas pengalaman dan kebersamaan dalam suka duka selama menempuh studi di Departemen Teknik Sistem dan Industri ITS.
10. Keluarga besar angkatan 2016 Adhigana TI-32 atas pengalaman dan kebersamaan dalam suka duka selama menempuh studi di Departemen Teknik Sistem dan Industri ITS.
11. Teman-teman yang membantu dalam menyelesaikan Tugas Akhir.
12. Seluruh pihak yang terlibat yang tidak dapat disebutkan satu persatu.

Penulis menyadari bahwa penulisan laporan Tugas Akhir ini tidak lepas dari kesalahan dan kekurangan. Oleh karena itu, penulis mohon kritik dan saran pembaca yang dapat membangun dan memperbaiki penulisan selanjutnya. Sekian yang dapat penulis sampaikan, akhir kata penulis menyampaikan terima kasih.

Surabaya, Juli 2020

Abiyyu Dimas Prasanto

DAFTAR ISI

LEMBAR PENGESAHAN	I
ABSTRAK	III
ABSTRACT	V
KATA PENGANTAR	VII
DAFTAR ISI.....	IX
DAFTAR TABEL	XIII
DAFTAR GAMBAR	XIII
BAB 1 PENDAHULUAN	1
1.1. LATAR BELAKANG	1
1.2. RUMUSAN MASALAH	8
1.3. TUJUAN PENELITIAN.....	8
1.4. MANFAAT PENELITIAN	9
1.5. RUANG LINGKUP PENELITIAN	9
1.6. SISTEMATIKA PENULISAN.....	10
BAB 2 TINJAUAN PUSTAKA.....	13
2.1 PRODUKSI SEMEN.....	13
2.1.1. <i>Definisi Semen</i>	13
2.1.2. <i>Proses Produksi Semen</i>	14
2.1.3. <i>Kiln Equipment</i>	16
2.2 <i>DOWNTIME</i>	18
2.3 <i>MAINTENANCE</i>	18
2.3.1 <i>Definisi Maintenance</i>	18
2.3.2 <i>Condition Based Maintenance</i>	19
2.4 <i>DATA MINING</i>	20
2.4.1 <i>Definisi Data Mining</i>	20
2.4.2 <i>Data Mining for Condition Based Maintenance</i>	20
2.4.3 <i>Data Pre-Processing</i>	22
2.4.4 <i>K-Means Clustering</i>	23
2.4.5 <i>Nonlinear Regression</i>	25
2.5 <i>PREVENTIVE MAINTENANCE AND REPLACEMENT MODELS</i>	26
2.5.1 <i>Downtime Minimization</i>	26
2.6 PENELITIAN SEBELUMNYA	27
BAB 3 METODOLOGI PENELITIAN	35
3.1 IDENTIFIKASI DAN ANALISIS CURRENT INFORMATION	36
3.1.1 <i>Identifikasi Data Sensor Kiln</i>	36
3.1.2 <i>Analisis Availability Kiln Equipment Melalui Data Sensor</i>	38
3.2 PERANCANGAN FRAMEWORK CONDITION-BASED MAINTENANCE.....	39
3.2.1 <i>Data Acquisition</i>	40
3.2.1.1 Sinyal Analog	41

3.2.1.2	Peralatan Sensor.....	41
3.2.1.3	Database.....	41
3.2.2	<i>Data Processing</i>	42
3.2.2.1	Data Pre-Processing.....	42
3.2.2.2	Perancangan Model K-Means Clustering.....	43
3.2.2.3	Perancangan Model Nonlinear Regression.....	44
3.3.1	<i>Maintenance Decision Making</i>	44
3.3	PENYUSUNAN REKOMENDASI MAINTENANCE STRATEGY.....	45
3.3.1	<i>Rekomendasi Maintenance Strategy</i>	46
3.3.1.1	Failure Time dan repair Time Berdasarkan Jenis Klaster.....	47
3.3.1.2	Mendapatkan Parameter Distribusi Failure Time dan Repair Time 47	
3.3.1.3	Menghitung Failure Rate dan Repair Rate.....	47
3.3.1.4	Menghitung Expected Number of Failures.....	47
3.3.1.5	Pengolahan Menggunakan Model Downtime Minimization.....	48
3.3.2	<i>Evaluasi Rekomendasi Maintenance Strategy</i>	49
3.4	KESIMPULAN DAN SARAN.....	49
BAB 4 IDENTIFIKASI DAN ANALISIS CURRENT INFORMATION.....		51
4.1.	JENIS DATA SENSOR <i>KILN EQUIPMENT</i>	51
4.1.1	<i>Identifikasi Jenis Data Sensor Kiln Equipment</i>	51
4.1.2	<i>Data Sensor Kiln Equipment</i>	52
4.1.3	<i>Regulasi Kiln Equipment</i>	55
4.2.	IDENTIFIKASI DAN ANALISIS CURRENT INFORMATION.....	56
4.2.1	<i>Failure Data</i>	56
4.2.2	<i>Repair Data</i>	57
4.3.	ANALISIS AVAILABILITY KILN EQUIPMENT MELALUI DATA SENSOR.....	58
4.3.1	<i>Penghitungan Availability Kiln Equipment</i>	58
4.3.2	<i>Analisis Availability Kiln Equipment</i>	59
BAB 5 PERANCANGAN FRAMEWORK CONDITION BASED MAINTENANCE		61
5.1.	DATA PRE-PROCESSING.....	61
5.2.	PERANCANGAN MODEL K-MEANS CLUSTERING.....	63
5.2.1	<i>Elbow Method</i>	63
5.2.2	<i>Silhouette Index</i>	65
5.2.3	<i>K-Means Clustering</i>	65
5.3.	PERANCANGAN MODEL NONLINEAR REGRESSION.....	72
5.4.	<i>MAINTENANCE DECISION MAKING</i>	78
BAB 6 PENYUSUNAN REKOMENDASI MAINTENANCE STRATEGY....		79
6.1	PENGOLAHAN MENGGUNAKAN <i>MODEL DOWNTIME MINIMIZATION</i>	79
6.1.1	<i>Klaster 1</i>	80
6.1.2	<i>Klaster 2</i>	81

6.1.3	<i>Klaster 3</i>	82
6.1.4	<i>Klaster 4</i>	83
6.1.5	<i>Klaster 5</i>	84
6.2	EVALUASI REKOMENDASI <i>MAINTENANCE STRATEGY</i>	85
6.2.1	<i>Evaluasi Hasil K-Means Clustering</i>	85
6.2.2	<i>Evaluasi Hasil Nonlinear Regression</i>	87
6.3.1.	<i>Evaluasi Hasil Rekomendasi Maintenance Strategy</i>	92
BAB 7 KESIMPULAN DAN SARAN		95
7.1.	KESIMPULAN	95
7.2.	SARAN.....	96
7.2.1.	<i>Saran bagi Perusahaan</i>	96
7.2.2.	<i>Saran bagi Pengembangan Penelitian Selanjutnya</i>	97
DAFTAR PUSTAKA		XV
LAMPIRAN 1 SCALING CODE IN MATLAB		XIX
LAMPIRAN 2 K-MEANS CODE IN MATLAB		XXI
LAMPIRAN 3 CLUSTER CENTEROID		XXIII
LAMPIRAN 4 WAWANCARA PERUSAHAAN		XXVII
BIOGRAFI PENULIS		XXXIII

(Halaman ini Sengaja Dikosongkan)

DAFTAR TABEL

Tabel 2. 1 Review Penelitian Sebelumnya.....	28
Tabel 2. 2 Perbandingan Penelitian.....	33
Tabel 3. 1 Peralatan Sensor Kiln.....	36
Tabel 3. 2 Threshold Sensor.....	37
Tabel 3. 3 Regulasi Kiln Equipmet	37
Tabel 4. 1 Jenis Data Kiln Equipment	52
Tabel 4. 2 Data Sensor Kiln Equipment 2015	53
Tabel 4. 3 Data Sensor Kiln Equipment 2016	53
Tabel 4. 4 Data Sensor Kiln Equipment 2017	54
Tabel 4. 5 Data Sensor Kiln Equipment 2018	54
Tabel 4. 6 Kiln Equipment Regulation	55
Tabel 4. 7 Failure Data Kiln Equipment	57
Tabel 4. 8 Repair Data Kiln Equipment.....	58
Tabel 4. 9 Availability Kiln Equipment.....	59
Tabel 5. 1 Data Sensor	61
Tabel 5. 2 Data Scaling	62
Tabel 5. 3 Data Scaling Klaster 1.....	66
Tabel 5. 4 Data Sensor Klaster 1.....	67
Tabel 5. 5 Data Scaling Klaster 2.....	67
Tabel 5. 6 Data Sensor Klaster 2.....	68
Tabel 5. 7 Data Scaling Klaster 3.....	68
Tabel 5. 8 Data Sensor Klaster 3.....	69
Tabel 5. 9 Data Scaling Klaster 4.....	69
Tabel 5. 10 Data Sensor Klaster 4.....	70
Tabel 5. 11 Data Scaling Klaster 5.....	70
Tabel 5. 12 Data Sensor Klaster 5.....	71
Tabel 5. 13 Hasil Regresi Klaster 1	73
Tabel 5. 14 Parameter Hasil Regresi Klaster 1	73
Tabel 5. 15 Hasil Regresi Klaster 2	74
Tabel 5. 16 Parameter Hasil Regresi Klaster 2	74
Tabel 5. 17 Hasil Regresi Klaster 3	75
Tabel 5. 18 Parameter Hasil Regresi Klaster 3	75
Tabel 5. 19 Hasil Regresi Klaster 4	76
Tabel 5. 20 Parameter Hasil Regresi Klaster 4	76
Tabel 5. 21 Hasil Regresi Klaster 5	77
Tabel 5. 22 Parameter Hasil Regresi Klaster 5	77
Tabel 6. 1 CIRP Klaster 1	80
Tabel 6. 2 CIRP Klaster 2	81
Tabel 6. 3 CIRP Klaster 3	82

Tabel 6. 4 CIRP Klaster 4.....	83
Tabel 6. 5 CIRP Klaster 5.....	84
Tabel 6. 6 Failure Time Parameter	85
Tabel 6. 7 Repair Time Parameter.....	85
Tabel 6. 8 New Threshold	86

(Halaman ini Sengaja Dikosongkan)

DAFTAR GAMBAR

Gambar 1. 1 Kiln Equipment Failure	3
Gambar 1. 2 Kiln Equipment Availability	5
Gambar 1. 3 Volume Produksi Terak (Clinker).....	5
Gambar 2. 1 Proses Produksi Semen	16
Gambar 2. 2 Rotary Kiln	17
Gambar 2. 3 Kiln Equipment Component	17
Gambar 2. 4 Overview of Different Maintenance Types.....	19
Gambar 2. 5 CBMS Workflow	19
Gambar 2. 6 Conceptual Framework CBM with Data Mining Techniques	21
Gambar 3. 1 Flowchart Metodologi Penelitian	35
Gambar 3. 2 Tahapan Pengumpulan Data dan Pengolahan Informasi Awal	36
Gambar 3. 3 Schematic Diagram of MTTF, MTTR, and MTBF	39
Gambar 3. 4 Tahapan Perancangan Model Framework Condition Based Maintenance	40
Gambar 3. 5 Tahapan Data Acquisition	40
Gambar 3. 6 Proses Konversi Sinyal Analog ke Sinyal Digital.....	41
Gambar 3. 7 Data Processing	42
Gambar 3. 8 Tahapan Perancangan Model Data Mining.....	46
Gambar 3. 9 Rekomendasi Maintenance Strategy	46
Gambar 5. 1 Sum of Square Error (SSE)	64
Gambar 5. 2 Silhouette Index.....	65
Gambar 6. 1 Failure Rate Klaster 1.....	87
Gambar 6. 2 Repair Rate Klaster 1	87
Gambar 6. 3 Failure Rate Klaster 2.....	88
Gambar 6. 4 Repair Rate Klaster 2	88
Gambar 6. 5 Failure Rate Klaster 3.....	89
Gambar 6. 6 Repair Rate Klaster 3	89
Gambar 6. 7 Failure rate Klaster 4	90
Gambar 6. 8 Repair Rate Klaster 4	90
Gambar 6. 9 Failure Rate Klaster 5.....	91
Gambar 6. 10 Repair Rate Klaster 5	91
Gambar 6. 11 Jadwal Maintenance	92

(Halaman ini Sengaja Dikosongkan)

BAB 1

PENDAHULUAN

Pada bab ini dijelaskan mengenai latar belakang dilakukannya penelitian, rumusan masalah, tujuan dan manfaat yang dicapai dari penelitian ini, serta batasan dan asumsi yang digunakan.

1.1. Latar Belakang

Salah satu perusahaan semen terbesar di Kawasan Indonesia Timur adalah PT XYZ yang telah berdiri sejak tahun 1968. Perusahaan ini kemudian bergabung dalam anak usaha PT Semen Indonesia pada tahun 1995. Pasar potensial dari penjualan semen PT XYZ mencakup wilayah Sulawesi dan sekitarnya. Hal tersebut juga ditunjang dengan banyaknya realisasi proyek infrastruktur pada Kawasan Indonesia Timur. Perusahaan terus berupaya meningkatkan penjualan pada pasar ekspor untuk meningkatkan keuntungan dari pendapatannya. Beberapa negara yang menjadi tujuan ekspor yaitu Malaysia, Singapura, Bangladesh, Madagaskar, Timor Leste, Kamboja, Filipina, Vietnam, dan beberapa negara di Afrika. Pasar ekspor tersebut mengindikasikan bahwa terdapat permintaan pasar yang besar terhadap produk semen PT XYZ. Pemenuhan permintaan pasar disesuaikan oleh kapasitas produksi semen perusahaan. Sehingga untuk memaksimalkan keuntungan dari pendapatan perusahaan diperlukan optimalisasi kapasitas produksi pada setiap unit pabrik.

Pada awal berdirinya PT XYZ memiliki empat unit pabrik yaitu Unit I, Unit II, Unit III, dan Unit IV. Kemudian dibangun pabrik baru yaitu Unit V pada tahun 2014. Namun Unit I dengan kapasitas 0,12 juta ton yang menggunakan proses basah dihentikan operasionalnya karena faktor ekonomis. Sehingga hanya empat unit pabrik yang masih beroperasi dengan total kapasitas produksi 5,98 juta ton per tahun (Anonymous, 2020). Keseluruhan unit pabrik yang masih beroperasi menggunakan proses kering pada proses operasi produksinya. Pada Unit II dan III masing-masing kapasitas produksinya mencapai sebesar 0,59 juta ton semen per tahun. Unit IV memiliki kapasitas produksi sebesar 2,3 juta ton semen per tahun.


Dan Unit V yang merupakan pabrik baru dibangun memiliki kapasitas produksi sebesar 2,5 juta ton semen per tahun. Kapasitas produksi Unit V adalah yang terbesar dibanding dengan unit lainnya.

Unit V merupakan pabrik baru dengan kapasitas produksi terbesar yang menghasilkan produk berupa terak (*clinker*) dan semen. Terak (*clinker*) adalah material berwarna abu-abu gelap yang terbuat dari pemanasan batu kapur dan tanah liat pada temperatur tinggi yang membentuk butir-butiran sebagai bahan baku pembuatan semen (Winter, 2005). Sedangkan semen merupakan serbuk yang terbuat dari batu kapur dan campuran material lainnya yang digunakan untuk membuat beton dan perekat untuk menyusun batu bata (KBBI, 2012). Terak (*clinker*) tersebut digunakan sebagai bahan baku utama pembuatan semen. Sedangkan semen dapat dijual secara langsung dalam bentuk kantong dan curah sebagai bahan bangunan. Terdapat beberapa proses yang dilakukan oleh Unit V untuk menghasilkan produk semen.

Secara keseluruhan proses produksi semen pada Unit V dilakukan melalui lima tahapan. Proses diawali dengan penghancuran batu kapur dan tanah liat pada *crusher* yang kemudian disimpan pada *storage*. Tahap kedua dilakukan proses prehomogenisasi yang disebut *reclaimer* pada *storage*. Hal tersebut bertujuan untuk menjamin kualitas bahan baku untuk menyuplai *raw mill*. Pada tahap ketiga dilakukan penambahan pasir besi dan pasir silika pada *raw mill* akan menghasilkan produk berupa *raw meal*. Kemudian *raw meal* disimpan dalam *silo* sebagai *buffer* bahan baku penyuplai *kiln*. Proses tahap keempat dilakukan pembakaran *raw meal* menggunakan batu bara yang menghasilkan produk berupa terak (*clinker*). Dan yang terakhir penggilingan terak (*clinker*) beserta penambahan *gypsum* pada *cement mill* untuk menghasilkan produk semen yang ada di pasaran.

Area *kiln* mempunyai peranan penting proses produksi dikarenakan menghasilkan produk terak (*clinker*) sebagai suplai bahan baku pembuatan semen. Namun area *kiln* sering mengalami *breakdown* yang tidak terjadwal saat menjalankan operasi produksi. Berdasarkan data frekuensi *breakdown* area *kiln* pada Gambar 1.1 menunjukkan bahwa *kiln* memiliki nilai tertinggi jika dibandingkan yang lain di area *kiln*. Equipment *kiln* mempunyai frekuensi kegagalan terbesar yaitu 33% dari semua area *kiln*. Disusul dengan *kiln feed* sebesar

24%, cooler 15%, cyclone preheater 10%, coal mill dan firing system sama-sama sebesar 9%, sedangkan clinker transport tidak mengalami kegagalan atau 0%.



Gambar 1. 1 *Kiln Equipment Failure*
Sumber : PT XYZ (2019)

Kiln equipment yang menempati persentase terbesar dalam terjadinya *breakdown* mengindikasikan bahwa terdapat masalah. Tercatat seperti pada frekuensi *breakdown kiln* sebanyak 198 kali dengan total durasi *breakdown* sebesar 5042 jam. Berdasarkan data *breakdown* tersebut *kiln* menjadi peralatan yang sering mengalami kerusakan dan waktu *breakdown* yang paling besar.

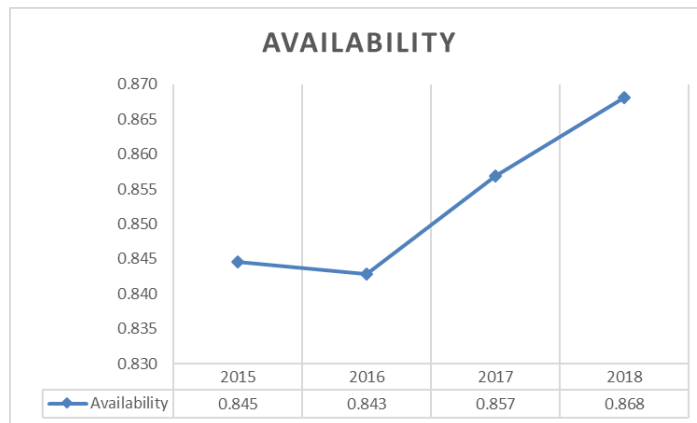
Frekuensi *breakdown* yang terjadi pada *kiln* dideteksi oleh peralatan sensor yang ditempatkan pada area *kiln*. Ribuan peralatan sensor yang ditempatkan pada area *kiln* untuk menunjang proses pengawasan operasi produksi terak (*clinker*). Masing-masing sensor tersebut diletakkan pada beberapa komponen *kiln*. Setiap sensor akan menghasilkan data yang merepresentasikan kondisi *kiln*. Peralatan sensor tersebut menghasilkan data *real-time* yang *continuous* yang tersimpan dalam *database* perusahaan. Namun dengan banyaknya jenis peralatan

sensor yang menghasilkan data, hanya diambil beberapa jenis peralatan sensor yang paling kritis untuk menganalisis permasalahan *kiln*.

Menurut (Yasin, 2020), hasil frekuensi tersebut didapatkan melalui tujuh peralatan sensor kritis. Peralatan sensor yang pertama adalah sensor EPFAN. Sensor ini digunakan untuk *monitoring* putaran kipas yang membuang udara keluar dari mesin *kiln*. Peralatan sensor kedua dan ketiga adalah sensor IDFAN I dan IDFAN II. Penggunaannya untuk *monitoring* putaran kipas yang menarik udara hasil pembakaran mesin *kiln* untuk suplai preheater *raw meal*. Peralatan sensor keempat adalah sensor *Maindrive Kiln*. Penggunaan sensor ini untuk mengawasi putaran mesin *kiln* saat proses pembakaran. Yang kelima adalah peralatan sensor *Temperature Calciner* yang digunakan untuk *monitoring* suhu pembakaran yang ada pada mesin *kiln*. Sensor *Coal Feeder* merupakan sensor yang keenam yang digunakan untuk mengawasi banyaknya batu bara yang masuk sebagai suplai pembakaran. Dan sensor yang terakhir adalah sensor *Kiln Feed* untuk *monitoring* suplai *raw meal* yang masuk kedalam *kiln equipment*.


Tingkat frekuensi *breakdown* yang telah dideteksi oleh ketujuh peralatan sensor kritis memengaruhi tingkat *availability kiln equipment*. Berdasarkan pengolahan ketujuh data sensor kritis *kiln equipment* periode tahun 2015 hingga 2018 seperti yang terlihat pada Gambar 1.2 menunjukkan bahwa tingkat *availability kiln equipment* mengalami tren kenaikan. Nilai *availability* yang dihasilkan *kiln equipment* tertinggi hanya sebesar 86,7% di tahun 2018. Dengan rata-rata *availability* sebesar 83,6%. Namun dengan tingkat *availability kiln equipment* tersebut masih belum mencukupi untuk mencapai target yang telah ditetapkan oleh perusahaan.

Perusahaan menginginkan tercapainya target *World Class OEE* pada proses operasi *kiln equipment* di pabrik terbarunya. Target *World Class OEE* yaitu nilai sebesar 85% (Vorne, 2019) pada *kiln equipment*. Standar nilai tersebut terdiri dari *availability*, *performance*, dan *quality*. Dalam mencapai target *World Class OEE* diperlukan nilai *availability* minimal sebesar 90% untuk menunjang nilai *performance* dan *quality* yang rendah. Namun berdasarkan pengolahan data sensor mengindikasikan bahwa *availability kiln equipment* yang belum mencapai target tersebut dan akan berpengaruh pada kapasitas produksi yang kurang optimal.



Gambar 1. 2 *Kiln Equipment Availability*
 Sumber : Data Sensor Kiln Equipment PT XYZ (2015-2018)

Berdasarkan *original equipment manufacturer (OEM)*, *kiln* memiliki klaim desain kapasitas sebesar 750 ton per jam. Dengan desain kapasitas sebesar itu seharusnya *kiln* dapat menghasilkan 6,57 juta ton terak (*clinker*) per tahun. Namun pada kenyataannya volume produksi terak (*clinker*) yang dihasilkan *kiln* masih dibawah klaim desain kapasitasnya. Dapat diperhatikan pada Gambar 1.3 menunjukkan bahwa keseluruhan volume produksi terak (*clinker*) masih berada dibawah 5,91 juta ton per tahun dengan jika menggunakan standar *World Class OEE*. Volume produksi terak (*clinker*) tertinggi yang didapatkan pada tahun 2018 hanya sebesar 5,7 juta ton terak (*clinker*) dan masih berada jauh di bawah klaim desain kapasitas *OEM* maupun standar *World Class OEE*. Berdasarkan analisis tersebut mengindikasikan bahwa diperlukan *maintenance strategy* yang tepat diharapkan mampu meningkatkan *availability kiln*.



Gambar 1. 3 *Volume Produksi Terak (Clinker)*
 Sumber : Pengolahan Data Sensor PT XYZ (2015-2018)

Sistem *maintenance* yang telah diterapkan oleh perusahaan masih belum tepat untuk mengatasi masalah *breakdown* yang terjadi. Sistem *maintenance* yang telah diterapkan oleh perusahaan hanya berupa *preventive maintenance* dan *corrective maintenance*. Operasi *Preventive maintenance* berupa pengecekan berkala terhadap komponen mesin secara terjadwal. Sedangkan *corrective maintenance* berupa perbaikan pada mesin yang mengalami kegagalan. *Breakdown* yang terjadi secara acak pada periode waktu tertentu tidak dapat ditangani secara optimal oleh sistem *maintenance* tersebut. Karena *preventive maintenance* dan *corrective maintenance* hanya berfungsi untuk mencegah dan mengatasi terjadinya kegagalan. Oleh karena itu, perusahaan membutuhkan suatu informasi yang sesuai untuk merancang strategi *maintenance* yang optimal.

Salah satu informasi yang telah ada di perusahaan adalah data yang dihasilkan oleh peralatan sensor. Data sensor tersebut hanya digunakan untuk memantau kondisi mesin dan kemudian disimpan pada *database* perusahaan. Data sensor dapat dimanfaatkan oleh perusahaan untuk merancang strategi *maintenance* yang optimal. Data sensor tersebut seharusnya dapat digunakan untuk mengetahui kondisi *kiln* bahkan dapat memprediksi akan terjadinya kegagalan. Memprediksi kegagalan suatu mesin dapat membantu perusahaan mengatasi masalah ketidakpastian kegagalan yang terjadi. Sehingga dengan memprediksi terjadinya kegagalan merupakan strategi *maintenance* yang optimal untuk masalah ini.

Salah satu strategi *maintenance* yang dapat digunakan untuk memprediksi kerusakan adalah *condition based maintenance*. *Condition based maintenance* merupakan *framework* yang digunakan untuk merancang strategi *maintenance*. Strategi *maintenance* ini menggunakan data *real-time* yang dihasilkan sensor. Kemudian dilakukan pengolahan data sensor bertujuan untuk mempermudah dalam analisis data. Dibutuhkan metode analisis data yang tepat untuk mendapatkan informasi dari data sensor. Dan hasil dari analisis data berupa informasi untuk memprediksi terjadinya *breakdown*.

Informasi yang terdapat pada data sensor digunakan untuk memonitoring peralatan. Data sensor tersebut mendeteksi perilaku peralatan sebelum terjadi kerusakan. Banyaknya data sensor yang dihasilkan membutuhkan metode yang tepat untuk mendapatkan informasi pada data sensor tersebut. Dalam

mempermudah melakukan analisis informasi pada data sensor perlu dilakukan klastering dan prediksi. Klastering digunakan untuk mengelompokkan data sedangkan regresi untuk mendapatkan hasil prediksi.

Metode yang biasa digunakan untuk mendapatkan informasi dari data sensor adalah *data analytics*. Dalam *data analytics* terdapat *data mining* untuk menganalisis data sensor. *K-means clustering* merupakan salah satu teknik dalam *data mining* berfungsi untuk mengelompokkan data dengan kesamaan karakteristik suatu data. Sehingga akan lebih mudah untuk mendapatkan informasi yang terkandung pada data tersebut. Informasi yang didapatkan juga dapat digunakan untuk memprediksi kapan waktu kegagalan mesin akan terjadi.

Proses prediksi waktu kegagalan menggunakan *nonlinear regression*. Penggunaan *nonlinear regression* pada data hasil klastering karena data tersebut memiliki bermacam-macam distribusi data. Sedangkan *linear regression* hanya dapat digunakan pada data yang memiliki distribusi normal. Waktu prediksi kegagalan nantinya akan digunakan untuk menyusun rekomendasi *maintenance strategy*. Dengan menentukan *expected number of failure* yang kemudian akan digunakan sebagai acuan untuk mendapatkan jadwal *maintenance* optimal.

Beberapa penelitian mengenai *condition based maintenance* dan *data analytics* mengarah pada tindakan untuk meminimalkan terjadinya *breakdown* pada mesin. Hal tersebut akan berdampak pada *downtime* dan *availability* mesin. Karena *condition based maintenance* menggunakan data sensor yang merepresentasikan kondisi mesin secara *real-time*. Tujuannya adalah *data analytics*, yaitu proses analisis data yang dihasilkan oleh sistem mesin. Menghasilkan *anomaly detection* yang mengidentifikasi ketidaknormalan kondisi mesin yang tidak sesuai dengan perilaku mesin biasanya (Djurdjanovic, et al., 2003). Hasil dari *anomaly detection* akan dijadikan sebagai acuan untuk mengambil keputusan strategi *maintenance* yang akan dilakukan.

Dikarenakan *preventive maintenance* yang digunakan perusahaan masih belum sesuai dalam menangani *downtime*. Karena tingkat *downtime* masih cukup tinggi dan berdampak pada *availability* mesin. Maka dari itu penelitian ini menggunakan *condition based maintenance* sebagai *framework maintenance*. Serta metode *data analytics* untuk mendapatkan informasi penting yang terkandung

dalam sebuah data. Kedua metode tersebut bertujuan untuk memprediksi *anomaly detection* mesin yang mengarah pada terjadinya *breakdown*. Sehingga dengan menggunakan metode tersebut diharapkan mampu untuk memprediksi terjadinya *breakdown* pada mesin. Dan secara tidak langsung akan berdampak pada usaha untuk meningkatkan *availability* dan menurunkan *downtime kiln equipment*.

Penelitian ini diharapkan mampu memberikan *maintenance strategy* yang sesuai untuk menangani permasalahan perusahaan terutama pada *kiln equipment*. Hipotesis yang digunakan dalam penelitian ini berupa penggunaan metode *condition based maintenance* untuk memprediksi *breakdown* untuk merancang penjadwalan *maintenance* pada *kiln equipment*. Sehingga diharapkan mampu berpengaruh terhadap *availability* dan *downtime equipment*.

H0: Hasil prediksi menggunakan data sensor mampu menghasilkan jadwal *maintenance* yang akurat menggunakan metode *condition based maintenance*.

H1: Hasil prediksi menggunakan data sensor kurang mampu menghasilkan jadwal *maintenance* yang akurat menggunakan metode *condition based maintenance*.

1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah dijelaskan sebelumnya, maka rumusan masalah yang akan diangkat dalam penelitian ini adalah bagaimana cara memprediksi terjadinya *breakdown* pada *kiln* menggunakan metode *condition based maintenance* dan *data analytics* untuk meminimalkan *downtime kiln equipment PT XYZ*.

1.3. Tujuan Penelitian

Tujuan yang ingin dicapai dari pelaksanaan penelitian tugas akhir ini adalah :

1. Mengetahui gambaran umum mengenai *breakdown* yang terjadi pada *kiln equipment* beserta dampak yang ditimbulkan.
2. Mengetahui perilaku *kiln equipment* berdasarkan data sensor yang menyebabkan terjadinya *breakdown* menggunakan metode *k-means clustering*.
3. Memprediksi terjadinya *breakdown* pada *kiln equipment* berdasarkan data sensor menggunakan metode *nonlinear regression*.

4. Merancang rekomendasi *maintenance strategy* menggunakan *preventive maintenance and replacement model*.

1.4. Manfaat Penelitian

Manfaat yang akan didapatkan dari hasil penelitian tugas akhir ini bagi perusahaan adalah sebagai berikut:

1. Perusahaan dapat menentukan *maintenance strategy* yang optimal menggunakan prediksi terjadinya *breakdown* berdasarkan data sensor.
2. Perusahaan dapat meminimalkan tingkat *downtime* dengan menggunakan strategi *maintenance* optimal yang berdampak pada *availability* mesin.

1.5. Ruang Lingkup Penelitian

Ruang lingkup penelitian terbagi menjadi batasan dan asumsi yang digunakan dalam penelitian. Batasan yang digunakan dalam penelitian tugas akhir ini adalah sebagai berikut.

1. Objek penelitian adalah *kiln equipment* pada pabrik unit V.
2. Data yang digunakan berupa data 7 (tujuh) sensor kritis, yang dioperasikan pada periode tahun 2015 hingga 2018.
3. Kerusakan yang terjadi pada komponen berasal dari deteksi ketujuh sensor kritis, tidak disebabkan dan tidak mengakibatkan kerusakan komponen lain.
4. Penelitian ini dilakukan hingga tahap perancangan strategi *maintenance* untuk *kiln equipment*, tidak sampai pada tahap implementasi.

Sedangkan asumsi yang digunakan dalam penelitian tugas akhir ini adalah sebagai berikut.

1. Tidak ada perubahan konfigurasi *kiln equipment* dalam operasi produksi *clinker* selama penelitian tugas akhir dilakukan.
2. Jenis kegagalan pada komponen *kiln equipment* terdeteksi oleh masing-masing jenis peralatan sensor.
3. Terdapat regulasi mengenai dependensi data sensor dalam membaca *breakdown* pada *kiln equipment*.

1.6. Sistematika Penulisan

Penyusunan laporan penelitian tugas akhir ini terdiri dari beberapa subbab dengan sistematika penulisan laporan sebagai berikut.

BAB 1 PENDAHULUAN

Pada bab pendahuluan menjelaskan mengenai beberapa hal yang menjadi dasar dilakukannya penelitian ini. Meliputi latar belakang masalah yang terjadi, rumusan masalah yang digunakan, tujuan penelitian yang ingin dicapai, manfaat yang diperoleh dari penelitian, dan sistematika penulisan laporan.

BAB 2 TINJAUAN PUSTAKA

Pada bab tinjauan pustaka menjelaskan mengenai landasan teori beserta konsep yang berasal dari sumber literatur seperti buku, jurnal, dan penelitian sebelumnya. Landasan teori dan konsep yang digunakan berkaitan dengan permasalahan dalam penelitian ini. Tinjauan pustaka berupa *Produksi Semen, Downtime, Data Mining, Condition Based Maintenance, Preventive Maintenance and Replecement Models* dan penelitian sebelumnya.

BAB 3 METODOLOGI PENELITIAN

Pada bab metodologi penelitian menjelaskan mengenai tahapan alur pengerjaan beserta metode yang digunakan dalam penelitian ini. Metodologi penelitian digunakan sebagai kerangka berpikir dalam pelaksanaan penelitian secara sistematis dan terarah.

BAB 4 IDENTIFIKASI DAN ANALISIS *CURRENT INFORMATION*

Pada bab identifikasi dan analisis *current information* menjelaskan mengenai cara mendapatkan dan mengidentifikasi jenis data yang digunakan. Data yang telah didapatkan kemudian dilakukan analisis untuk mengetahui kondisi dan informasi yang terkandung dalam data tersebut.

BAB 5 PERANCANGAN *FRAMEWORK CONDITION BASED MAINTENANCE*

Pada bab perancangan *framework condition based maintenance* menjelaskan mengenai bagaimana cara menggali informasi pada data sensor. Tahapan perancangan dimulai dari mengelompokkan data sensor ke dalam beberapa klaster untuk mengetahui penyebab *breakdown*. Kemudian dilakukan prediksi waktu akan terjadinya *breakdown*. Informasi tersebut akan digunakan untuk menyusun rekomendasi *maintenance* yang sesuai.

BAB 6 PENYUSUNAN REKOMENDASI *MAINTENANCE STRATEGY*

Pada bab penyusunan rekomendasi *maintenance strategy* menjelaskan mengenai rancangan rekomendasi yang akan diterapkan dalam penelitian ini. Tahapan dimulai dari menentukan jadwal *maintenance* yang optimal untuk meminimalkan downtime. Kemudian dilakukan evaluasi *maintenance strategy*.

BAB 7 KESIMPULAN DAN SARAN

Pada bab kesimpulan dan saran menjelaskan mengenai hasil penelitian tugas akhir yang telah dilakukan. Beserta pemberian saran kepada pihak perusahaan dan pengembangan untuk penelitian selanjutnya.

(Halaman ini Sengaja Dikosongkan)

BAB 2

TINJAUAN PUSTAKA

Pada bab ini dijelaskan mengenai tinjauan pustaka yang merupakan landasan teori yang digunakan dalam pengerjaan penelitian tugas akhir. Tinjauan pustaka terdiri dari Produksi Semen, *Downtime*, *Data Mining*, *Condition Based Maintenance*, *Preventive Maintenance and Replecement Models* dan penelitian sebelumnya.

2.1 Produksi Semen

Pada subbab proses produksi semen akan dijelaskan mengenai definisi semen, proses produksi semen, dan *kiln equipment*.

2.1.1. Definisi Semen

Menurut Kamus Besar Bahasa Indonesia semen adalah serbuk terbuat dari tepung dan material lain yang digunakan untuk bahan pembuat beton dan perekat batu bata. Semen merupakan salah satu bahan perekat yang mampu mengikat bahan lain menjadi satu jika dicampur air. Semen dihasilkan dengan cara menghaluskan klinker. Semen terdiri dari 70-95% klinker, 5% *gypsum*, dan material tambahan lainnya. Klinker tersusun atas silikat kalsium dan batu *gypsum* yang dapat bereaksi dengan air membentuk zat yang bersifat merekatkan bebatuan.

Bahan baku pembuatan semen terdiri dari bahan utama dan bahan tambahan. Bahan utama yaitu batu kapur, tanah liat, dan bahan penunjang. Batu kapur merupakan sumber utama kalsium yang tersedia banyak di berbagai tempat. Tanah liat adalah sumber utama silikat yang berperan dalam merekatkan material lainnya. Dan bahan penunjang seperti pasir silika dan pasir besi ditambahkan ketika bahan utama masih kekurangan komponen campuran. Sedangkan bahan tambahan berupa *gypsum* dan *fly ash*. Penambahan *gypsum* sebanyak 4-5% pada proses penggilingan klinker. Fungsinya sebagai pengikat semen yang biasa disebut *retarder*. Dan *fly ash* adalah sisa pembakaran batu bara dari pembangkit listrik. Jika terkena air akan membentuk senyawa yang bersifat mengikat.

Menurut Standar Nasional Indonesia (SNI) semen dibagi menjadi Sembilan jenis. Dan secara umum membunyai sifat adhesive dan cohesive yang digunakan sebagai bahan pengikat. Jenis semen berdasarkan sifat kegunaannya adalah sebagai berikut.

- *Portland Cemen* yang merupakan bahan pembuatan beton dan plesteran semen.
- *Super Masonry Cemen* yang digunakan untuk konstruksi bangunan umum.
- *Oil Well Cemen* merupakan semen khusus untuk konstruksi sumur minyak.
- Semen Putih yang biasa digunakan sebagai *filler* untk pekerjaan *finishing*.
- *Hidropobic Cement* merupakan klinker yang ditambahkan asam oleat.
- *Waterproofed Cement* adalah campuran antara *Portland* dengan serat logam.
- Semen Alumina adalah campuran antara batu kapur dengan bauksit.
- *Portland Pozzolan Cement* merupakan semen hidrolis untuk ketahanan struktur.
- *Portland Composite Cement* menghasilkan struktur beton yang lebih halus.


2.1.2. *Proses Produksi Semen*

Proses produksi semen terdiri dari dua jenis proses yaitu proses basah dan jenis kering. Proses basah menggunakan *kiln* yang lebih sederhana dengan bahan baku *slurry* untuk pembuatan *klinker*. *Kiln* berbentuk panjang berfungsi menguapkan banyak air agar perpindahan panas lebih optimal. Keuntungan proses basah yaitu campuran lebih homogen, efisiensi penggilingan, dan menghasilkan sedikit jumlah debu. Namun kerugiannya yaitu kebutuhan air relatif besar, butuh tempat yang luas, dan boros bahan bakar karena butuh panas tinggi. Sedangkan proses kering menggunakan bahan baku *rawmeal* kering yang telah melewati proses *preheater*. Kemudian *rawmeal* dipanaskan menggunakan gas panas di dalam *kiln*. Keuntungan dari proses kering yaitu membutuhkan sedikit tempat, hemat bahan bakar, dan proses pemanasan yang lebih efisien. Namun kerugiannya yaitu

lebih banyak menghasilkan debu dan campuran kurang homogen.

Poses produksi semen pada Parbrik V PT XYZ menggunakan metode kering. Metode kering digunakan karena proses produksi yang lebih efisien. Gambaran umum proses produksi semen yang dapat dilihat pada Gambar 2.1 berikut ini.

- *Quarry*, merupakan tambang kapur yang menjadi bahan baku utama proses produksi semen. Material kapur diangkut menggunakan truk untuk dibawa ke proses selanjutnya yaitu mesin *crusher*.
- *Crusher*, merupakan mesin yang berfungsi sebagai penghancur batu kapur menjadi ukuran kecil. Kemudian produk kapur yang berukuran kecil disimpan pada *warehouse*.
- *Warehouse*, kapur yang berukuran kecil kemudian dilakukan proses prehomogenisasi menggunakan *reclaimer*. Kemudian dicampurkan dengan material lainnya ke dalam *feeder* sesuai standar.
- *Raw Mill*, proses penggilingan material yang telah tercampur pada *feeder* menghasilkan produk *rawmeal*. *Rawmeal* merupakan produk *rawmill* berupa butiran halus yang kemudian disimpan pada silo.
- *Kiln*, *rawmeal* pada silo akan disalurkan kedalam *kiln* untuk proses pembakaran dengan temperatur 2000⁰C. Kemudian dilakukan pendinginan secara cepat yang di dalam *cooler*. Proses ini disebut *quenching* menghasilkan produk *clinker* yang disimpan dalam *dome*.
- *Cement Mill*, *clinker* pada *dome* kemudian disalurkan menuju *cement mill* menggunakan *feeder*. Pada *feeder* terjadi penyampuran material *clinker*, *gypsum*, *trash*, dan batu kapur. Seluruh material tersebut akan digiling di dalam *cement mill* menghasilkan produk semen. Produk semen yang dihasilkan berupa semen curah dan semen kantong.



Gambar 2. 1 Proses Produksi Semen
 Sumber : PT XYZ (2019)


2.1.3. *Kiln Equipment*

Salah satu jenis *kiln equipment* yang biasa digunakan oleh pabrik semen yaitu *rotary kiln*. *Rotary kiln* adalah sebuah perangkat *pyroprocessing* yang digunakan untuk memanaskan bahan baku semen hingga suhu tinggi untuk proses selanjutnya. Pada gambar 2.2, *Kiln* merupakan bejana silinder yang diletakkan secara horizontal dan miring beberapa derajat. Proses perputaran pada *kiln* ditujukan untuk menggerakkan dan mencampurkan material. Dengan material yang dimasukkan dari bagian atas silinder akan menuju bagian bawah silinder akibat putaran terus menerus. Gas panas yang ditimbulkan dari pembakaran akan melewati sepanjang *kiln* untuk memanaskan bahan baku. Pembakaran tersebut membutuhkan bahan bakar berupa batu bara.



Gambar 2. 2 Rotary Kiln
 Sumber : Chinafote.com (2020)

Pada gambar 2.3, Komponen penyusun dari *rotary kiln* yaitu *shell*, *refractory lining*, *roller*, *drive gear*, *motor*, dan *heat exchanger*. *Shell* merupakan plat baja rol yang digunakan sebagai struktur utama silinder. *Refractory lining* adalah batu tahan api yang diletakkan di dalam silinder. Hal ini ditujukan agar silinder tahan terhadap panas yang tinggi. *Roller* digunakan untuk menumpu beban silinder dalam berputar. *Drive gear* akan terhubung dengan *motor* untuk menggerakkan perputaran silinder. Dan *heat exchanger* merupakan kipas yang digunakan untuk menyerap udara panas dan memanjangkan semburan api



Gambar 2. 3 Kiln Equipment Component
 Sumber : European Lime Association (2020)

2.2 *Downtime*

Downtime didefinisikan sebagai waktu dimana komponen suatu sistem dalam kondisi yang tidak baik sehingga menyebabkan kegagalan sistem (Gasperz, 1992). Aktivitas penghentian operasi karena *downtime* dari suatu komponen sistem tidak dapat ditentukan. Penyebab terjadinya *downtime* dapat berupa kurangnya pemeliharaan sistem, salah dalam melakukan operasi sistem, dan kegagalan sistem sehingga menyebabkan kerusakan. Kerugian yang ditimbulkan *downtime* berdampak besar bagi perusahaan.

Perusahaan menekan biaya kerugian yang ditimbulkan *downtime* dengan menerapkan beberapa metode. Metode yang digunakan untuk menurunkan *downtime* yaitu sebagai berikut.

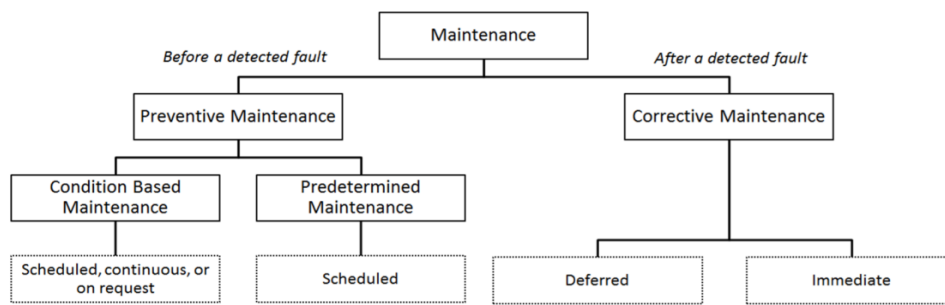
- a. Melaksanakan Audit Resiko
- b. Pemasangan Sensor Pendeteksi Kegagalan Peralatan Sistem
- c. Menggunakan Laporan Data Peralatan Sensor
- d. Pelatihan Sumber Daya Manusia
- e. Pembuatan Jadwal *Maintenance*

2.3 *Maintenance*

Pada subbab *maintenance* akan dijelaskan mengenai definisi *maintenance*, dan *condition based maintenance*.

2.3.1 *Definisi Maintenance*

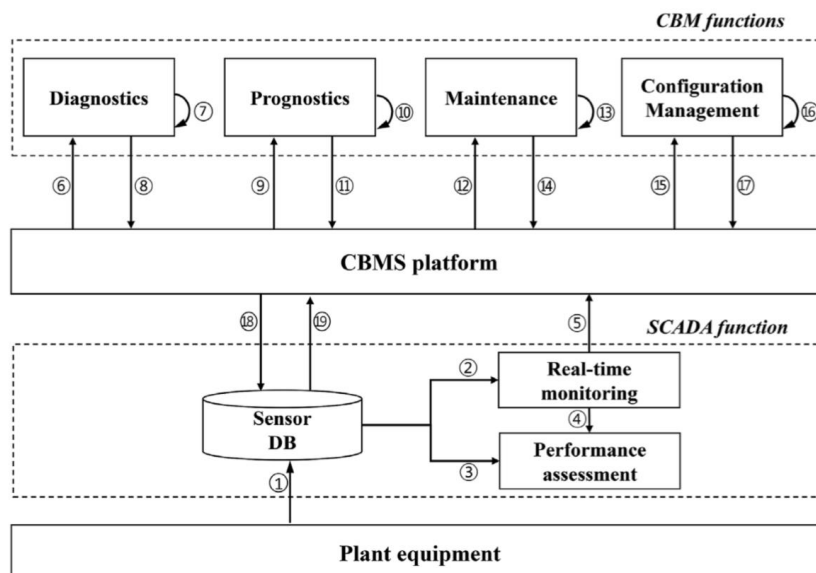
Penggunaan beragam metode *maintenance* diklasifikasikan berdasarkan fungsi dan tujuannya. *Maintenance* dibagi menjadi dua tipe yaitu *corrective maintenance* dan *preventive maintenance*. *Corrective maintenance* didefinisikan sebagai pemeliharaan yang dilakukan ketika telah terjadi kegagalan suatu sistem. Sistem pemeliharaan yang digunakan berupa *run to failure* sehingga dilakukan penanganan perbaikan untuk mengembalikan kondisi sistem seperti kondisi awal. Sedangkan untuk *preventive maintenance* merupakan pemeliharaan dengan melihat kriteria kondisi sistem. Hal tersebut bertujuan untuk mengurangi peluang terjadinya kegagalan dan penurunan fungsi kinerja sistem. Sehingga dengan melihat performansi suatu sistem dapat memprediksi periode pemeliharaan.



Gambar 2. 4 Overview of Different Maintenance Types
 Sumber: SS-EN 13306, 2010, p.20 (Rastegrari, 2017))

2.3.2 Condition Based Maintenance

Condition based maintenance merupakan metode yang digunakan untuk mengurangi ketidakpastian aktivitas pemeliharaan berdasarkan kondisi suatu sistem. Dengan mengidentifikasi kondisi suatu sistem dapat menyelesaikan permasalahan pemeliharaan sebelum terjadi kegagalan sistem. *Condition based maintenance* dapat memantau umur dari sistem melalui kondisi operasinya. Mencegah potensi dari kegagalan sistem dapat mengurangi dampak yang ditimbulkan seperti biaya *life cycle* sistem yang rendah.



Gambar 2. 5 CBMS Workflow
 Sumber : A Study of the Development of a Condition Based Maintenance System for an LNG FPSO (Hwang, et al., 2018)

2.4 *Data Mining*

Pada subbab *data mining* akan dijelaskan mengenai definisi *data mining*, *data mining for condition based maintenance*, *data pre-processing*, dan *k-means clustering*.

2.4.1 *Definisi Data Mining*

Data mining merupakan pengambilan informasi atau *knowledge* yang penting dari suatu *set data* yang berukuran besar dengan menggunakan teknik tertentu (Santosa & Umam, 2018). Informasi atau *knowledge* yang dihasilkan dari *data mining* digunakan untuk pengambilan keputusan. Terdapat beberapa metode dalam *data mining* yang digunakan untuk mendeteksi pola dan melakukan prediksi suatu data. Secara umum *data mining* di deskripsikan melalui beberapa tahapan. Tahap pertama yaitu proses pengumpulan data yang dilakukan dengan cara penyeleksian data yang relevan. Kemudian tahap kedua yaitu proses persiapan data yang dilakukan agar siap untuk diolah. Dan yang terakhir yaitu proses *data mining* yang dilakukan untuk mendapatkan informasi atau *knowledge* dari data tersebut.

Beberapa masalah yang dapat diselesaikan oleh *data mining* yaitu (Piatetsky & Shapiro, 2006):

- a. Masalah bersifat *knowledge-based* untuk pengambilan keputusan.
- b. Masalah dengan faktor lingkungan yang selalu berubah.
- c. Masalah yang menggunakan metode yang bersifat sub-optimal.
- d. Tersedia data masalah yang relevan dan cukup untuk dapat diakses.
- e. Pengambilan keputusan masalah memberikan keuntungan tinggi.

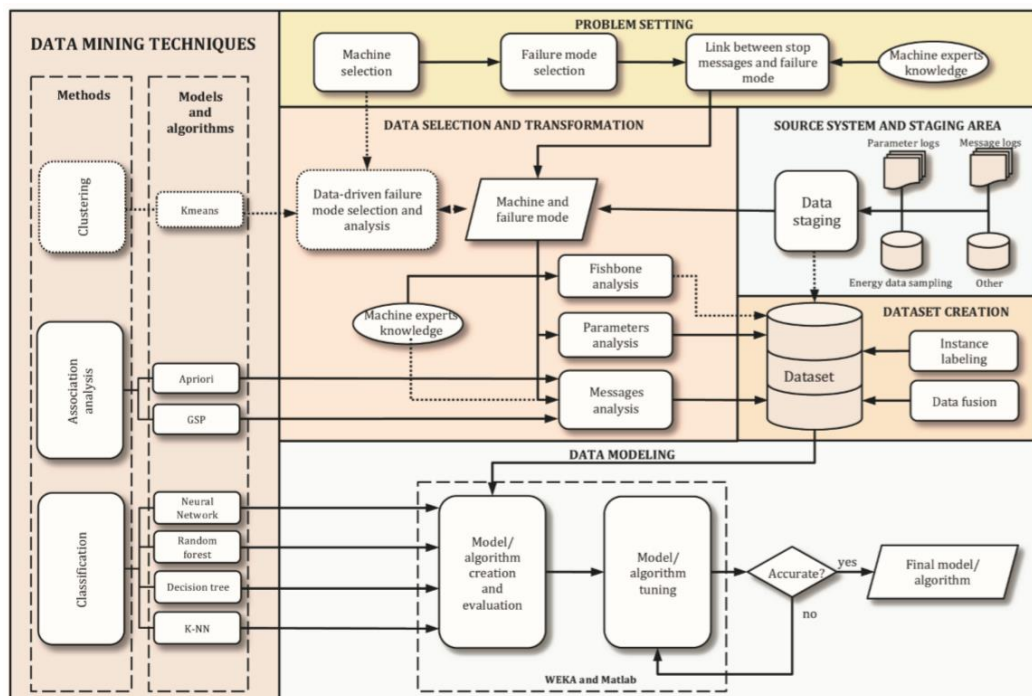
2.4.2 *Data Mining for Condition Based Maintenance*

Tujuan penggunaan *framework condition based maintenance* pada *data mining* adalah untuk mendiagnosa kondisi mesin. Diagnosa tersebut dapat berupa kondisi yang mengarah pada terjadinya kegagalan. Dengan *diagnostic model* dapat mengidentifikasi bagian yang sering mengalami kegagalan akan mempermudah dilakukan penanganan. *Diagnostic model* juga berperan dalam mengetahui pola kegagalan dari suatu kondisi mesin kedepannya.

Terdapat lima komponen utama pada *framework* untuk mendapatkan

diagnostic model (Riccardo, et al., 2017) seperti terlihat pada gambar berikut.

- Komponen permasalahan terdiri dari kegiatan pendahuluan seperti pemilihan mesin yang diamati, modus kegagalan yang sering muncul, dan bantuan expert untuk mengidentifikasi kegagalan yang dihasilkan mesin.
- Data selection* dan *transformation* digunakan untuk mengubah data terpilih menjadi *training dataset*. Data yang telah terpilih tersebut berasal dari pengetahuan *expert* dan analisis kegagalan pada komponen sebelumnya.
- The source system* dan *staging area* berupa pengambilan data yang didapatkan dari beragam sumber. Kemudian dilakukan penyeragaman struktur data agar dapat diproses pada komponen selanjutnya.
- The dataset creation* merupakan upaya menghasilkan dataset untuk digunakan pada algoritma diagnose
- The data modelling* terdapat model analisis data dan algoritma yang digunakan untuk memprediksi perilaku mesin secara *real time*.



Gambar 2. 6 *Conceptual Framework CBM with Data Mining Techniques*
 Sumber: *Data Mining and Machine Learning for Condition Based Maintenance*,
 (Riccardo, et al., 2017)

2.4.3 *Data Pre-Processing*

Data Preprocessing bertujuan untuk mendapatkan hasil analisis yang lebih akurat dalam penggunaan teknik *data mining*. Dampak yang dihasilkan dari data *preprocessing* adalah waktu yang digunakan untuk melakukan komputasi data lebih sedikit. Dan juga dapat membuat nilai data menjadi lebih kecil tanpa mengubah informasi yang didapatkan. Berikut ini merupakan beberapa metode yang digunakan dalam melakukan *data preprocessing*.

a. *Data Cleaning*

Pembersihan data diperlukan untuk menghilangkan data yang *outlier*. *Data cleaning* dilakukan sebelum diproses menggunakan data mining. Proses ini meliputi pengisian *missing value* (data kosong), menghilangkan data outlier dan noise, dan menghilangkan inkonsistensi data yang tidak diperlukan. Berikut ini merupakan beberapa masalah yang sering dijumpai pada proses *data cleaning*.

- *Missing Data*

Beberapa data yang berhasil dikumpulkan tidak memiliki nilai. Hal ini diakibatkan karena data yang tersimpan tidak tepat, memiliki nilai yang tidak konsisten dengan data lain, salah dalam memasukkan data, dan berupa data tertentu yang kurang penting untuk disimpan.

- *Incomplete Data*

Data yang tidak lengkap akan membuat proses selanjutnya tidak dapat dijalankan. Banyak data yang menampilkan informasi yang kurang lengkap. Hal ini bisa disebabkan oleh sistem maupun *human error*.

- *Format Data Tidak Seragam*

Data yang berasal dari berbagai macam sumber mengakibatkan data tersebut menjadi tidak seragam. Data yang tidak seragam akan membuat proses selanjutnya tidak berjalan lancar.

- *Kesalahan Penulisan Data*

Banyak data yang mengalami kesalahan saat penulisan. Seperti salah dalam menuliskan nilai, salah dalam meletakkan data, dan salah karena terdapat data yang berulang. Hal tersebut dapat menimbulkan pengertian yang salah saat pengambilan keputusan.

- *Missing Value*

Suatu *set data* memiliki nilai atribut yang kosong. *Missing value* pada kasus *set data* dalam jumlah besar dapat diabaikan. Data yang hilang dapat digantikan oleh data lain yang sejenis. Jika *missing value* pada kasus *set data* dalam jumlah kecil diperlukan untuk diperhatikan. Nilai data yang hilang tersebut dapat digantikan oleh nilai rata-rata dari atribut *set data*. Namun jika terlalu banyak *missing value* maka data atribut tersebut dapat dihilangkan.

b. *Data Transformation*

Proses untuk merubah bentuk suatu *set data* bertujuan untuk mendapatkan hasil analisis yang lebih baik. Berikut ini merupakan beberapa cara untuk melakukan *data transformation*.

- *Centering*: Proses *centering* dilakukan dengan cara mengurangi setiap data dengan rata-rata.
- *Standardisasi*: Merupakan proses yang dilakukan setelah *centering* dengan membuat nilai setiap data pada *range* yang sama.
- *Scaling*: Data yang telah dilakukan standarisasi akan diubah kedalam skala tertentu.

2.4.4 *K-Means Clustering*

K-Means Clustering merupakan teknik untuk mengelompokkan obyek data ke dalam k klaster menggunakan ukuran ketidakmiripan (Santosa & Umam, 2018). Ukuran ketidakmiripan menggunakan jarak *Euclidean*. Semakin jauh jarak data yang dihasilkan, maka ketidakmiripannya semakin tinggi. Teknik *k-means clustering* sering digunakan untuk data yang berukuran besar. Data yang digunakan merupakan hasil dari *pre-processing* data.

Setiap klaster pada *k-means* terdiri dari beberapa anggota data dan *centroid*. Dan setiap anggota data memiliki nilai jarak yang terendah terhadap *centroid* klasternya. Beberapa hal dalam melakukan *k-means clustering* agar mendapatkan hasil yang baik adalah sebagai berikut.

- Membandingkan solusi *k-means clustering* terhadap nilai k yang berbeda untuk menentukan klaster yang optimal.
- Evaluasi solusi klaster menggunakan pengujian *elbow method* dan

silhouette index.

- Replikasi hasil kluster berasal dari centeroid yang berbeda dan mencari jarak terendah diantara semua replikasi.

Konsep jarak yang digunakan dalam penghitungan ketidakmiripan yaitu menggunakan jarak *Euclidean*. Rumus jarak Euclidean secara matematis dapat dinyatakan pada persamaan 2.1 sebagai berikut.

$$E = \sum_{j=1}^k \sum_{i=1}^{n_j} \|x_i^j - c_j\|^2 \dots\dots\dots(2.1)$$

Dengan:

- x_i^j : obyek ke i pada kluster ke j
- c_j : pusat kalster j (centeroid)
- K : jumlah kluster

Langkah-langkah dalam menyelesaikan permasalahan menggunakan teknik *k-means clustering* adalah sebagai berikut.

- 1) Tentukan jumlah kluster (k) berdasarkan informasi yang telah diketahui. Dalam penentuan jumlah kluster dapat menggunakan cara random berdasarkan informasi data yang telah diketahui.
- 2) Masukkan setiap data ke dalam kluster berdasarkan jarak terdekat. Penggunaan jarak Euclidean untuk mengetahui kedekatan data dengan pusat kluster (centeroid). Penghitungan jarak dilakukan pada setiap data dengan setiap pusat kluster. Sehingga data yang paling dekat dengan suatu pusat kluster (centerid) akan dimasukkan ke dalam kluster tersebut.
- 3) Hitung kembali pusat kluster dengan anggota kluster yang terbentuk. Kluster data yang telah terbentuk kemudian dilakukan penghitungan rata-rata data untuk mengetahui pusat kluster (*centeroid*) yang baru.
- 4) Ulangi langkah (b) dan (c) dengan pusat kluster baru. Hal tersebut dilakukan untuk mengetahui apakah pusat kluster yang telah terbentuk sudah tidak berubah lagi. Sehingga proses pengklasteran dapat dinyatakan telah konvergen dan selesai.
- 5) Evaluasi hasil kluster tersebut menggunakan *elbow method* dan *silhouette*

index untuk mengetahui jumlah klaster dan iterasi optimal. Penurunan nilai *sum of square error* (SSE) tertinggi pada *elbow method* dan nilai *silhouette index* tertinggi menunjukkan jumlah klaster dan iterasi optimal yang dapat digunakan.

2.4.5 *Nonlinear Regression*

Nonlinear regression merupakan suatu teknik statistik untuk mendeskripsikan hubungan *nonlinear* pada suatu data. Model *nonlinear regression* biasanya diasumsikan memiliki parameter. Parameter dari model *nonlinear regression* berupa sebuah fungsi kombinasi *nonlinear*. Keunggulan model *nonlinear regression* adalah dapat digunakan pada data yang memiliki banyak distribusi. Fungsi ini terdiri dari *dependent variable* (variabel respon) dan satu atau lebih *independent variable* (variabel prediktor). Model ini dapat berupa variabel respon tunggal (*univariate*) atau variabel respon ganda (*multivariate*)

Model *parametric nonlinear* merepresentasikan hubungan antar variabel respon dengan variabel prediktor. Hasil dari analisis *nonlinear regression* berupa persamaan regresi dan koefisien. Bentuk parameter distribusi data yang digunakan dapat berupa *exponential*, *trigonometri*, dan lainnya. Secara umum bentuk persamaan model *nonlinear regression* ditunjukkan dalam persamaan (2.2).

$$y = f(X, \beta) + \varepsilon \dots \dots \dots (2.2)$$

- y : variabel respon.
- f : fungsi X dan β .
- X : matriks prediktor.
- β : parameter vektor yang tidak diketahui untuk diestimasi.
- ε : merupakan vektor bebas.

Dengan mempertimbangkan hubungan antar data sensor yang tergabung dalam algoritma regresi bertujuan untuk mengecilkan ukuran data yang di alirkan (Sreenivasulu & P. Chenna, 2020). Fungsi dari model *nonlinear regression* dapat digunakan untuk mencari beberapa hasil dari permasalahan sebagai berikut.

- Menentukan model *nonlinear* terhadap data
- Membandingkan model yang berbeda
- Menghasilkan prediksi
- Evaluasi parameter *confidence interval*
- Evaluasi *goodness of fit*

2.5 Preventive Maintenance and Replacement Models

Pada subbab *preventive maintenance and replacement model* akan dijelaskan mengenai teknik *downtime minimization*.

2.5.1 Downtime Minimization

Teknik *downtime minimization* merupakan salah satu teknik dari *preventive maintenance and replacement model* yang bertujuan untuk menentukan interval waktu *maintenance* yang optimum (Elsayed, 2012). Tujuan utamanya adalah untuk meminimalkan *downtime*. Terdapat situasi dimana *availability* dari peralatan lebih penting dibandingkan dengan biaya perbaikan atau *maintenance*. Konsekuensi dari terjadinya *downtime* peralatan juga akan menimbulkan biaya kerugian. Namun terdapat beberapa kasus dimana lebih sesuai dengan meminimalkan *downtime* daripada total biaya *maintenance*.

Mekanisme terjadinya *failure* menggunakan pendekatan *continuous time* membutuhkan informasi berupa parameter distribusi. Setiap *downtime* memiliki parameter distribusi diperlukan untuk menghitung *failure rate* dan *repair rate* adalah nilai *hazard rate* $h(t)$. *Hazard rate* merupakan laju failure pada interval waktu tertentu dan dapat dituliskan dalam persamaan (2.3) (Elsayed, 2012)

$$h(t) = \frac{\gamma}{\theta} \left(\frac{t}{\theta}\right)^{\gamma-1} \dots\dots\dots(2.3)$$

Kemudian dilanjutkan dengan menghitung nilai *expected number of failure* $M(t)$. Peran dari *expected number of failure* $M(t)$ untuk mengestimasi jumlah *failure* yang terjadi dalam interval waktu tertentu. Sehingga dapat ditentukan periode yang optimal untuk dilakukan *maintenance* peralatan. Pendekatan parametrik

digunakan karena parameter distribusi *failure rate* (λ) dan *repair rate* (μ) telah diketahui. Secara umum *expected number of failure* $M(t)$ dapat dituliskan menggunakan persamaan (2.4) (Elsayed, 2012)

$$M(t) = \frac{\lambda\mu}{(\lambda+\mu)}t - \frac{\lambda\mu}{(\lambda+\mu)^2} + \frac{\lambda\mu}{(\lambda+\mu)^2}e^{-(\lambda+\mu)t} \dots\dots\dots(2.4)$$

▪ *The Constant Interval Replacement Policy (CIRP)*

Sama seperti yang dijelaskan *constant interval replacement policy* sebelumnya, namun tujuannya adalah untuk meminimalkan total *downtime* per satuan waktu. Replacement dilakukan berdasarkan waktu yang telah ditentukan sebelumnya, bukan berdasarkan terakhir kali komponen telah diganti. Model rumusan untuk menentukan *total replacement downtime* persatuan waktu dituliskan dalam persamaan (2.5) (Elsayed, 2012)

$$D(t_p) = \frac{M(t_p)T_r + T_p}{T_p + t_p} \dots\dots\dots(2.5)$$

2.6 Penelitian Sebelumnya

Dalam penelitian tugas akhir ini menggunakan penelitian terdahulu yang masih relevan sebagai acuan dalam pengerjaan dan memudahkan penyusunan penelitian tugas akhir secara sistematis. Penelitian dengan menggunakan pendekatan *data mining* dan *condition based maintenance* telah banyak dilakukan dan dipublikasikan namun dengan lingkup permasalahan dan objek yang berbeda. Sedangkan penelitian tugas akhir ini yang dilakukan pada PT XYZ memiliki perbedaan pendekatan permasalahan dan metode yang digunakan. Pada tabel x akan dijelaskan terkait perbandingan penelitian ini dengan penelitian sebelumnya.

Tabel 2. 1 *Review* Penelitian Sebelumnya

No.	Penulis	Judul Penelitian	Metode Penelitian	Hasil Penelitian
1	(Myhre, et al., 2014)	Using Wireless Vibration Monitoring to Enable Condition-Based Maintenance of Rotating Machinery in the Water Wastewater Industries	<ul style="list-style-type: none"> ▪ Condition-Based Maintenance ▪ Wireless Sensor Networks ▪ Wireless Instrumentation ▪ Real-time Monitoring ▪ Asset Management 	WirelessHART dan ISA100.11a diharapkan teknologi nirkabel ini mungkin pemantauan aset dan menemukan penggunaan pertama di dalam air dan air limbah. Pemantauan getaran nirkabel menunjukkan bahwa dapat mendeteksi kegagalan dini, berpotensi untuk mengoptimalkan perencanaan pemeliharaan dan mengurangi kemungkinan kegagalan. Dari sudut pandang teknis membuktikan bahwa sensor getaran nirkabel sepenuhnya mampu memungkinkan langkah akuisisi data menggunakan CBM.
2	(Yang, et al., 2020)	A Review of Data Mining Technologies in Building Energy Systems: Load Prediction, Pattern Identification, Fault	<ul style="list-style-type: none"> ▪ Supervised Data Mining ▪ Unsupervised Data Mining ▪ Big Data 	Metode data mining menggunakan supervised data baik memprediksi beban energi dan FDD. Keuntungannya yaitu memiliki akurasi prediksi yang tinggi. Unsupervised data baik untuk ekstraksi dan

Tabel 2.1 *Review* Penelitian Sebelumnya (Lanjutan)

No.	Penulis	Judul Penelitian	Metode Penelitian	Hasil Penelitian
		Detection and Diagnosis	<ul style="list-style-type: none"> ▪ Building Energy Efficiency ▪ Building Energy Systems 	<p>identifikasi pola operasi dan kesalahan. Keuntungannya yaitu memiliki kapasitas mengungkapkan pola operasi yang bermakna, namun sulit secara manual dari sejumlah besar pola.</p>
3	(Wei, et al., 2020)	Research on Clustering Method Based on Weighted Distance Density and K-Means	<ul style="list-style-type: none"> ▪ K-means Algorithm ▪ Density Calculation ▪ Weighted Distance ▪ Cluster Centroid 	<p>Algoritma k-means tradisional secara acak memilih pusat pengelompokan awal, yang mudah dipengaruhi oleh sampel data anomali, menghasilkan hasil pengelompokan yang tidak stabil. Metode pengelompokan berdasarkan jarak tertimbang dan K-means diusulkan. Hasil percobaan menunjukkan bahwa algoritma dapat menghindari optimasi lokal, varians intra-cluster berkurang sebesar 15,5% dibandingkan dengan metode tradisional dan lebih meningkatkan kinerja clustering.</p>

Tabel 2.1 *Review* Penelitian Sebelumnya (Lanjutan)

No.	Penulis	Judul Penelitian	Metode Penelitian	Hasil Penelitian
4	(Sreenivasulu & P. Chenna, 2020)	NLDA Nonlinear Regression Model for Perserving Data Privacy in Wireless Sensor Network	<ul style="list-style-type: none"> ▪ Nonlinear Regression ▪ Data Aggregation ▪ Data Accuracy ▪ Sensor Nodes ▪ Wireless Sensor Networks ▪ Privacy Preserving 	Model berbasis regresi non-linier untuk agregasi data setiap node sensor ke kepala cluster untuk penggabungan data dan menghasilkan fungsi non-linear bertopeng tunggal. Sink node memperoleh prediksi hasil dengan memproses data sensor yang telah terkumpul. Hasil percobaan membuktikan bahwa protokol yang diusulkan efisien dalam mengurangi overhead komunikasi dan meningkatkan akurasi agregasi data dibandingkan dengan protokol lain yang ada.
5	(Nilda, et al., 2020)	Preventive Maintenance Scheduling by Modularity Design Applied to Limestone Crusher Machine	<ul style="list-style-type: none"> ▪ Scheduling ▪ Preventive Maintenance ▪ Modularity Design ▪ Maintenance Modul 	Implementasi desain modularitas bertujuan untuk membantu kegiatan preventive maintenance pada modul komponen mesin menjadi suatu maintenance. Keuntungannya yaitu mengurangi waktu yang maintenance

Tabel 2.1 *Review* Penelitian Sebelumnya (Lanjutan)

No.	Penulis	Judul Penelitian	Metode Penelitian	Hasil Penelitian
			<ul style="list-style-type: none"> ▪ Mechanical Structure 	<p>dan kebutuhan tenaga kerja, meningkatkan produktivitas karena waktu produksi lebih tinggi, serta penghematan sebesar Rp 417.643.637. Penerapan desain modularitas, menggunakan modul pemeliharaan yang merupakan kombinasi dari beberapa komponen.</p>
6	(Kanika, et al., 2018)	Toward Data Mining Based Decision Support in Manufacturing Maintenance	<ul style="list-style-type: none"> ▪ Maintenance ▪ Decision Support Systems ▪ Data Mining ▪ Classification Methods ▪ Knowledge Extraction 	<p>Arsitektur mengintegrasikan beberapa teknik data mining untuk mengekstrak informasi penting dalam hal fitur penting dan jalur penting dalam decision trees. Fitur yang diekstraksi digunakan dalam metode klasifikasi untuk mengevaluasi akurasi kelas sehubungan dengan jalur yang diambil dari metode klasifikasi data mining. DSSA yang diusulkan dapat memprediksi RUL dan tindakan pemeliharaan komponen.</p>

Tabel 2.1 *Review* Penelitian Sebelumnya (Lanjutan)

No.	Penulis	Judul Penelitian	Metode Penelitian	Hasil Penelitian
7	(Selcuk & Fuat, 2019)	A New Model Based on Artificial Bee Colony Algorithm for Preventive Maintenance with Replacement Scheduling in Continuous Production Lines	<ul style="list-style-type: none"> ▪ Replacement Scheduling ▪ Preventive Maintenance ▪ Bin Packing ▪ Time Based Maintenance ▪ Rolling Mill 	<p>Model baru untuk integrasi metode Bin Packing menyelesaikan masalah penjadwalan penggantian. Algoritma Bottom Left (BL) Bin Packing untuk menetapkan penggantian dua metode solusi. Pertama, metode Time-Based Replacement (TBR) klasik dianalisis dan waktu henti dihitung. Kedua, metode Flexible Time-Based Replacement (FTBR) dikembangkan dengan mengintegrasikan algoritma Bee Bee Colony (ABC). Hasilnya FTBR memberikan penurunan sekitar 12% pada downtime dibandingkan dengan TBR. Peningkatan ini berarti 21.328 ton produksi kereta api.</p>
8	(Abiyyu, 2020)	Perancangan Strategi Maintenance Pada Kiln equipment Menggunakan	<ul style="list-style-type: none"> ▪ Condition-Based Maintenance ▪ Data Mining 	<p>Framework condition based maintenance yang berbasis data analytics untuk menggali informasi melalui data sensor dan preventive</p>

Tabel 2.1 *Review* Penelitian Sebelumnya (Lanjutan)

No.	Penulis	Judul Penelitian	Metode Penelitian	Hasil Penelitian
		Metode Condition Based Maintenance Berbasis Data Analytics (Studi Kasus: PT XYZ)	<ul style="list-style-type: none"> ▪ K-Means Clustering ▪ Regresi Linier Multivariate ▪ Preventive Maintenance and Replacement Models 	maintenance and replacement model untuk mengetahui jadwal maintenance yang optimal. Dengan menggunakan ketiga metode diharapkan dapat meminimalkan downtime dan berdampak pada availability kiln equipment.

Tabel 2. 2 Perbandingan Penelitian

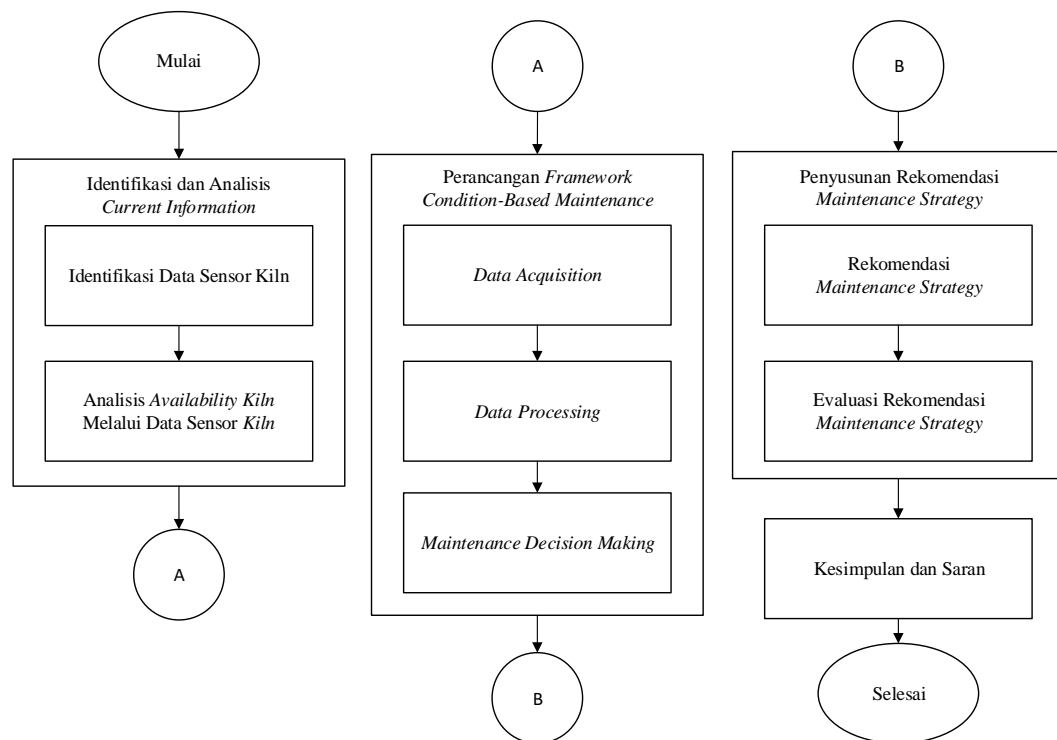
Penelitian	Metode		
	Condition-Based Maintenance		Preventive Maintenance and Replacement Models
	Data Mining	Nonlinear Regression	
(Myhre, et al., 2014)	V		
(Yang, et al., 2020)	V		
(Wei, et al., 2020)	V		
(Sreenivasulu & P. Chenna, 2020)		V	
(Nilda, et al., 2020)	V		V
(Kanika, et al., 2018)	V		V
(Selcuk & Fuat, 2019)	V		V
(Prasanto, 2020)	V	V	V

(Halaman ini Sengaja Dikosongkan)

BAB 3

METODOLOGI PENELITIAN

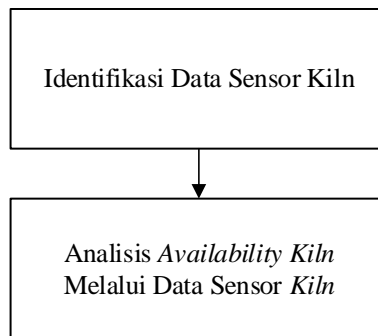
Pada bab ini dijelaskan mengenai tahapan sistematis dalam pelaksanaan penelitian tugas akhir. Pelaksanaan penelitian dimulai dari tahap identifikasi dan analisis *current information*. Dalam tahapan tersebut tersebut terdiri dari identifikasi data sensor *kiln* dan analisis *availability kiln* melalui data sensor *kiln equipment*. Kemudian dilanjutkan dengan tahap perancangan model *framework condition based maintenance*. Tahapan ini terdiri dari *data acquisition*, *data processing*, dan *maintenance decision making*. Selanjutnya tahap penyusunan rekomendasi *maintenance strategy*. Terdiri dari rekomendasi jadwal waktu *maintenance* dan evaluasi hasil rekomendasi *maintenance strategy*. Dan diakhiri dengan penarikan kesimpulan dan saran dari penelitian tugas akhir ini.



Gambar 3. 1 *Flowchart* Metodologi Penelitian

3.1 Identifikasi dan Analisis Current Information

Pada tahap pengumpulan data dan pengolahan informasi awal terdiri dari dua proses yaitu identifikasi data sensor *kiln* dan analisis *availability kiln* melalui data sensor *kiln*.



Gambar 3. 2 Tahapan Pengumpulan Data dan Pengolahan Informasi Awal

3.1.1 Identifikasi Data Sensor Kiln

Proses identifikasi didapatkan melalui pendeteksian peralatan sensor pada *kiln* perusahaan PT XYZ. *Kiln equipment* memiliki ribuan peralatan sensor yang menghasilkan data. Namun data yang diambil berasal dari tujuh peralatan sensor kritis yang mendeteksi kondisi operasi *kiln equipment*. Pengambilan data dilakukan menggunakan data sekunder yaitu data sensor periode januari 2015 hingga November 2018. Data sensor yang digunakan dalam merancang model sebagai berikut.

Tabel 3. 1 Peralatan Sensor Kiln

Sumber : PT XYZ (2019) , (Yasin, 2020)

Mesin	Sensor	Peralatan
Kiln	533FN01U01S01	Motor EPFAN
	533FN02U01S01	Motor IDFAN 1
	533FN02U01S01	Motor IDFAN 2
	541KF01A01F01X01	Kiln Feed
	542CL01N03T01	Temperature Calciner
	543MD01U01S01	Maindrive Kiln
	545RL03A01F01	Coal Feeder

Mekanisme sensor dalam membaca kegagalan pada komponen *kiln equipment* dengan menggunakan *threshold*. Fungsi dari *threshold* adalah sebagai batasan dimana mesin tersebut dapat dikatakan sedang beroperasi atau sedang mengalami *breakdown*. *Threshold* memiliki nilai tertentu sebagai batas untuk menentukan kondisi komponen. Nilai *threshold* masing masing sensor dapat dilihat pada tabel (3.2). Dimana ketika sensor menghasilkan data untuk mendeteksi komponen *kiln equipment* berada dibawah nilai *threshold* tersebut maka komponen tersebut sedang berada di kondisi *breakdown*.

Tabel 3. 2 *Threshold Sensor*

Sensor	Peralatan	Threshold
533FN01U01S01	Motor EPFAN	50 RPM
533FN02U01S01	Motor IDFAN 1	50 RPM
533FN02U01S01	Motor IDFAN 2	50 RPM
541KF01A01F01X01	Kiln Feed	150 Ton/Hours
542CL01N03T01	Temperature Calciner	300° C
543MD01U01S01	Maindrive Kiln	0.5 RPM
545RL03A01F01	Coal Feeder	1 Ton/Hours

Dalam mengetahui kiln equipment berada pada kondisi *breakdown* atau beroperasi menggunakan regulasi *kiln equipment*. Regulasi ini terdiri dari gabungan berbagai macam kombinasi data sensor komponen. Terdapat 128 kombinasi regulasi dalam mendeteksi kondisi *kiln equipment*. Berbagai macam kombinasi tersebut dapat dilihat pada tabel (3.3). Tindakan *maintenance* untuk menangani *breakdown* dilakukan dengan cara inspeksi terlebih dahulu pada komponen yang mengalami kegagalan. Jika terjadi kerusakan akan dilakukan penggantian pada komponen.

Tabel 3. 3 Regulasi *Kiln Equipmet*

<i>Kiln Equipment Regulation</i>								
No	X1	X2	X3	X4	X5	X6	X7	Status
1	0	0	0	0	0	0	0	FAILURE
2	0	0	0	0	0	0	1	FAILURE
3	0	0	0	0	0	1	0	FAILURE
4	0	0	0	0	0	1	1	FAILURE

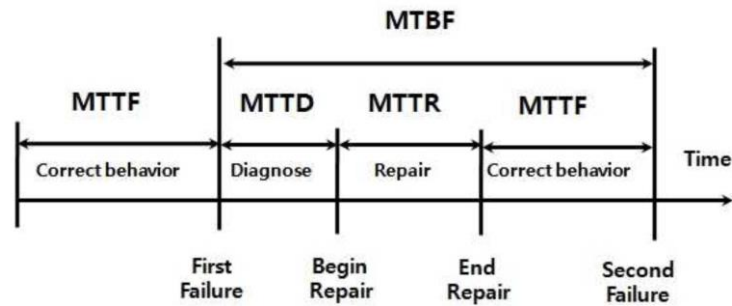
Kiln Equipment Regulation								
No	X1	X2	X3	X4	X5	X6	X7	Status
5	0	0	0	0	1	0	0	FAILURE
6	0	0	0	0	1	0	1	FAILURE
7	0	0	0	0	1	1	0	FAILURE
8	0	0	0	0	1	1	1	FAILURE
9	0	0	0	1	0	0	0	FAILURE
10	0	0	0	1	0	0	1	FAILURE
...
115	1	1	1	0	0	1	0	FAILURE
116	1	1	1	0	0	1	1	RUNNING
117	1	1	1	0	1	0	0	FAILURE
118	1	1	1	0	1	0	1	FAILURE
119	1	1	1	0	1	1	0	FAILURE
120	1	1	1	0	1	1	1	RUNNING
121	1	1	1	1	0	0	0	FAILURE
122	1	1	1	1	0	0	1	FAILURE
123	1	1	1	1	0	1	0	FAILURE
124	1	1	1	1	0	1	1	RUNNING
125	1	1	1	1	1	0	0	FAILURE
126	1	1	1	1	1	0	1	FAILURE
127	1	1	1	1	1	1	0	RUNNING
128	1	1	1	1	1	1	1	RUNNING

Langkah-langkah yang dilakukan dalam identifikasi data sensor adalah sebagai berikut.

- Identifikasi permasalahan *breakdown* yang terjadi pada area *kiln*
- Menghitung *downtime* akibat *breakdown kiln equipment*
- Analisis dampak akibat *breakdown* terhadap *kiln equipment*

3.1.2 Analisis Availability Kiln Equipment Melalui Data Sensor

Proses analisis *availability kiln* dari peralatan menggunakan data ketujuh sensor. Pada awalnya dilakukan identifikasi waktu kerusakan (TTF) dan waktu perbaikan (TTR). Waktu kerusakan (TTF) didapatkan dari mulainya peralatan beroperasi hingga mengalami kegagalan. Sedangkan waktu perbaikan (TTR) didapatkan dari mulainya peralatan mengalami kegagalan hingga beroperasi normal kembali. MTTF dan MTTR merupakan nilai rata-rata dari TTF dan TTR. Berikut ini merupakan diagram MTTF dan MTTR yang digunakan sebagai acuan.



Gambar 3. 3 Schematic Diagram of MTTF, MTRR, and MTBF
 Sumber: *Modern in Reliability Engineering*, 2020, (Woo, 2020)

Formula penghitungan *availability* dapat dihitung menggunakan rumus 3.1 sebagai berikut (Elsayed, 2012)

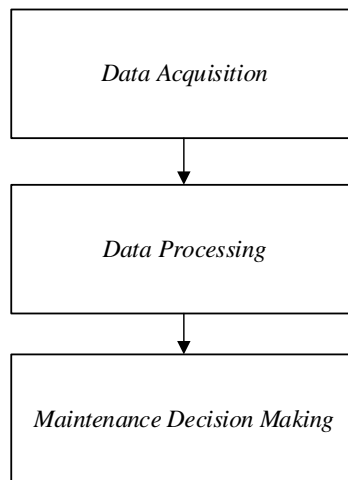
$$Availability = \frac{MTTF}{MTTF+MTRR} \dots\dots\dots(3.1)$$

Langkah-langkah yang dilakukan dalam analisis *availability kiln equipment* melalui data sensor adalah sebagai berikut.

- Identifikasi *threshold* masing-masing *kiln equipment* menggunakan data sensor.
- Klasifikasikan data sensor terhadap *threshold* masing-masing *kiln equipment* untuk mengetahui kondisi operasi atau *breakdown*.
- Menghitung interval *time to failure* dan *time to repair kiln equipment* berdasarkan klasifikasi kondisi *kiln equipment*.
- Menghitung nilai *availability kiln equipment* dengan menggunakan persamaan (3.1).
- Analisis *availability kiln equipment* yang telah diperoleh.

3.2 Perancangan Framework Condition-Based Maintenance

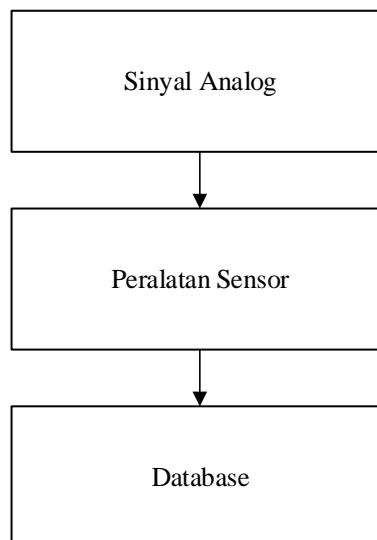
Pada tahap perancangan *framework* dengan *condition based maintenance* terdiri dari tiga proses yaitu *data acquisition*, *data processing*, dan *maintenance decision making*.



Gambar 3. 4 Tahapan Perancangan Model *Framework Condition Based Maintenance*

3.2.1 *Data Acquisition*

Data acquisition merupakan cara yang mengumpulkan data yang didapatkan dari peralatan sensor. *Kiln* akan menghasilkan *signal* yang ditangkap oleh peralatan sensor. *Signal* yang dihasilkan merepresentasikan kondisi dan perilaku *kiln*. Peralatan sensor mengubah *signal* tersebut menjadi bentuk data digital agar dapat mempermudah pengolahan data. Data digital tersebut kemudian disimpan pada sistem perusahaan.




Gambar 3. 5 Tahapan *Data Acquisition*

3.2.1.1 Sinyal Analog

Kiln equipment akan menghasilkan sinyal analog saat beroperasi. Sinyal analog ini merepresentasikan perilaku dari *kiln*. Sinyal analog yang dihasilkan oleh *kiln equipment* berupa getaran, panas, dan suara. Sinyal analog dapat digunakan sebagai sumber data. Namun sinyal analog memiliki kekurangan karena berbentuk gelombang yang mudah rusak karena terpengaruh *noise*. Maka dari itu diperlukan suatu konversi bentuk agar lebih *robust* dan mudah dilakukan pengolahan lebih lanjut.

3.2.1.2 Peralatan Sensor

Kiln memiliki banyak peralatan sensor yang telah dipasang pada setiap komponen *kiln*. Peralatan sensor digunakan untuk melakukan konversi sinyal analog menjadi sinyal digital. Sinyal digital yang berbentuk numerik dan dilakukan pengolahan lebih lanjut.



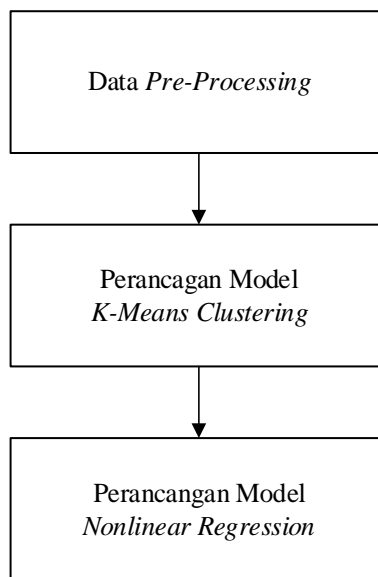
Gambar 3. 6 Proses Konversi Sinyal Analog ke Sinyal Digital

3.2.1.3 Database

Kemudian sinyal digital dalam bentuk numerik akan disimpan pada database perusahaan. Database berbentuk *platform online* yang memudahkan penggunaannya untuk mengaksesnya. Ketika data tersebut diperlukan dapat dilakukan pengunduhan oleh pegawai perusahaan. Data yang telah diunduh tersebut merupakan data sekunder yang akan digunakan sebagai sumber informasi dalam penelitian ini.

3.2.2 Data Processing

Data processing merupakan pengolahan data bertujuan untuk mendapatkan informasi yang dibutuhkan. Pengolahan menggunakan data yang berasal dari *data acquisition*. Teknik *data mining* digunakan untuk memperoleh informasi mengenai jenis *breakdown* yang terjadi, pengelompokan jenis *breakdown*, dan memprediksi akan terjadinya *breakdown*. *Data processing* terdiri dari beberapa tahapan yaitu data *pre processing*, perancangan model *k-means clustering*, dan perancangan model *nonlinear regression*.



Gambar 3. 7 Data Processing

3.2.2.1 Data Pre-Processing

Data pre-processing terdiri dari proses *data cleaning* dan *data transformation*. *Data cleaning* digunakan untuk membersihkan data dari *outlier*. Proses ini meliputi pengisian *missing value* (data kosong), menghilangkan data *outlier* dan *noise*, dan menghilangkan inkonsistensi data yang tidak diperlukan. Sedangkan *data transformation* adalah mengubah bentuk data menjadi bentuk tertentu agar menghasilkan analisis yang lebih baik (Santosa & Umam, 2018). Langkah-langkah dalam melakukan data pre processing adalah sebagai berikut.

- Data yang digunakan adalah data sensor periode 2015 hingga 2018.
- Proses *data cleaning* untuk menghilangkan *outlier*.

- Proses *data transformation* menggunakan teknik *scaling* yaitu dengan mengubah data menjadi *range* skala tertentu. *Range* data berupa nilai interval yaitu nilai 0 sebagai batas bawah dan nilai 1 sebagai batas atas.

Formula dalam melakukan *scaling* dapat dituliskan dalam persamaan (3.2) (Santosa & Umam, 2018). Setelah dilakukan keseluruhan *data pre-processing* maka data tersebut dapat digunakan sebagai pembentukan model *data mining*.

$$X = \frac{x - x_{min}}{x_{max} - x_{min}} (BA - BB) + BB \dots\dots\dots(3.2)$$

3.2.2.2 Perancangan Model K-Means Clustering

Model *K-Means Clustering* merupakan teknik untuk mengelompokkan obyek data ke dalam k klaster menggunakan ukuran ketidakmiripan (Santosa & Umam, 2018). Ukuran ketidakmiripan menggunakan jarak *Euclidean*. Semakin jauh jarak data yang dihasilkan, maka ketidakmiripannya semakin tinggi. Teknik *k-means clustering* sering digunakan untuk data yang berukuran besar. Data yang digunakan merupakan hasil dari *pre-processing* data.

Dengan menggunakan *software* Matlab dapat mempercepat penghitungan jarak *Euclidean* untuk menghasilkan klaster terbaik. Tahapan dalam pengklasteran menggunakan model *K-Means* sebagai berikut.

1. Tentukan nilai k klaster berdasarkan informasi yang telah diketahui dari data sensor. Dalam kasus ini jumlah klaster telah ditentukan berdasarkan tingkat *downtime*. Dan kemudian tentukan pusat klaster (*centroid*) masing-masing klaster secara *random*.
2. Kemudian pembuatan *coding* berdasarkan algoritma *k-means clustering* menggunakan *software* Matlab. Penghitungan ketidakmiripan menggunakan jarak *Euclidean* untuk mengetahui jarak antara setiap data sensor dengan pusat klaster (*centroid*) yang telah ditentukan.
3. Hitung kembali pusat klaster (*centroid*) dengan anggota klaster yang telah terbentuk. Lakukan penghitungan ulang jarak dengan pusat klaster (*centroid*) hingga pusat klaster tidak berubah lagi. Sehingga proses pengklasteran dapat dinyatakan telah konvergen dan selesai.

4. Evaluasi hasil data kluster menggunakan *elbow method* dan *silhouette index*. Penurunan nilai *sum of square error (SSE)* terbesar pada *elbow method* dan nilai *silhouette index* tertinggi mengindikasikan jumlah kluster dan iterasi optimal yang dapat digunakan.
5. Didapatkan kluster data berdasarkan tingkat *downtime* dan *repair time* dari masing-masing komponen *kiln equipment* yang akan digunakan sebagai input prediksi.

3.2.2.3 Perancangan Model Nonlinear Regression

Model *nonlinear regression* umumnya digunakan untuk mendapatkan estimasi prediksi suatu data. Penggunaan *nonlinear regression* dikarenakan model ini dapat digunakan pada data dengan bermacam-macam distribusi. Sedangkan linear regression hanya dapat digunakan pada data dengan distribusi normal.

Model ini merepresentasikan hubungan antar variabel respon dengan variabel prediktor. Secara umum bentuk persamaan model *nonlinear regression* ditunjukkan dalam persamaan (3.3). Dimana β merepresentasikan estimasi parameter *nonlinear* dan ε merepresentasikan *error*.

$$y = f(X, \beta) + \varepsilon \dots\dots\dots(3.3)$$

Data yang digunakan berupa data kluster yang berdasarkan jenis karakteristik sebagai variabel bebas dan *failure time* dan *repair time* sebagai variabel respon. Tahapan dalam melakukan perancangan model nonlinear regression menggunakan *tools data analytics* pada *software* Microsoft Excel. Proses regresi dengan menggunakan software akan mempercepat waktu prosesnya.

3.3.1 Maintenance Decision Making

Maintenance decision making melibatkan penilaian dan pemilihan strategi *maintenance* yang lebih efisien. Tujuan utama dari *condition based maintenance* menurut (Gupta & Lawsirirat, 2006) adalah mengukur kondisi peralatan untuk pengambilan keputusan dilakukan *maintenance*, mengurangi *maintenance* yang tidak diperlukan dan memengaruhi biaya *maintenance*.

Konsekuensi dari pemilihan strategi *maintenance* yang sesuai akan berpengaruh pada biaya *maintenance* yang dikeluarkan. Namun *condition based maintenance* tidak cukup untuk mengatasi permasalahan *kiln equipment*. Pendekatan prediksi diperlukan untuk mengetahui terjadinya *breakdown* mesin di masa akan datang. Hasil prediksi akan digunakan *preventive maintenance and replacement models* dalam meminimalkan biaya kerusakan dan *downtime* mesin (Usher, et al., 1998).


Menurut (Labib, 2004), alasan mengapa diperlukan *preventive maintenance and replacement models* adalah sebagai berikut.

- Setiap peralatan bekerja di kondisi lingkungan yang berbeda sehingga memerlukan perencanaan jadwal *maintenance* yang berbeda.
- *Machine designers* tidak berpengalaman dalam kegagalan mesin dibandingkan dengan operator yang mengoperasikan mesin
- *Original Equipment Manufacturer* (OEM) memaksimalkan penggantian *spare part* melalui jadwal *maintenance* yang dianjurkan.

Sehingga dengan hasil prediksi *breakdown kiln equipment* akan digunakan untuk menyusun strategi *preventive maintenance and replacement models*. Strategi ini menggunakan pendekatan penjadwalan *maintenance* sesuai hasil prediksi *breakdown*.

3.3 Penyusunan Rekomendasi Maintenance Strategy

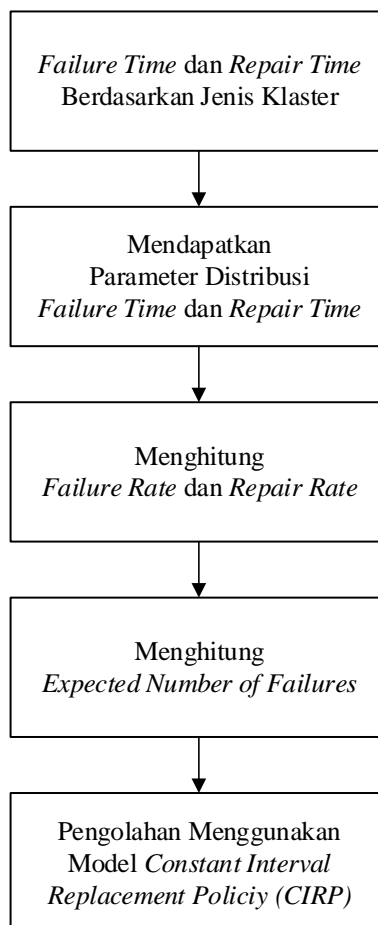
Pada tahap penyusunan rekomendasi *maintenance strategy* terdiri dari dua proses yaitu rekomendasi jadwal waktu *maintenance* dan evaluasi hasil rekomendasi *maintenance strategy*.



Gambar 3. 8 Tahapan Perancangan Model *Data Mining*

3.3.1 Rekomendasi *Maintenance Strategy*

Tahapan rekomendasi *maintenance strategy* menggunakan pendekatan *preventive maintenance and replacement model*. *Maintenance strategy* terdiri dari *downtime* dibagi berdasarkan jenis komponen *kiln*, mendapatkan parameter distribusi *downtime*, mencari *probability density function*, menghitung *expected number of failures*, dan pengolahan menggunakan model *downtime minimization*.



Gambar 3. 9 Rekomendasi *Maintenance Strategy*

3.3.1.1 Failure Time dan repair Time Berdasarkan Jenis Klaster

Failure time dan *repair time* pada *kiln equipment* dikelompokkan berdasarkan jenis klaster. Tujuannya adalah untuk memudahkan dalam memprediksi jadwal *maintenance* masing-masing klaster. Sehingga ketika terdeteksi *anomaly* akan terjadinya *breakdown*, user akan segera menangani *anomaly* tersebut sesuai dengan jenis klasternya.

3.3.1.2 Mendapatkan Parameter Distribusi Failure Time dan Repair Time

Failure time dan *repair time* merupakan hasil dari deteksi peralatan sensor. Kemudian dilakukan pencarian parameter distribusinya untuk mengetahui pola atau tren kecenderungannya. Parameter distribusi *failure time* dan *repair time* didapatkan melalui pengolahan *software* Weibull++.

3.3.1.3 Menghitung Failure Rate dan Repair Rate

Penghitungan *failure rate* dan *repair rate* menggunakan rumus *hazard rate* $h(t)$. Dimana *hazard rate* $h(t)$ merupakan laju kerusakan pada interval waktu tertentu. Nilai *hazard rate* $h(t)$ dapat dicari menggunakan *software* Weibull++ maupun penghitungan melalui rumus. Formula untuk mendapatkan *hazard rate* $h(t)$ dapat ditulis dengan persamaan (4.1).

$$h(t) = \frac{\gamma}{\theta} \left(\frac{t}{\theta}\right)^{\gamma-1} \dots\dots\dots(3.4)$$

3.3.1.4 Menghitung Expected Number of Failures

Expected Number of Failures merupakan jumlah kegagalan yang diharapkan pada interval waktu tertentu. Terdiri dari dua jenis yaitu parameter dan non parameter. Parameter menggunakan parameter distribusi *downtime*. Sedangkan non parameter tidak menggunakan parameter distribusi *downtime*. Kemudian berdasarkan parameter dibagi menjadi dua jenis waktu yaitu *continuous time* dan *discrete time*. *Continuous time* merupakan suatu pendekatan yang tanpa probabilitas terjadinya *failure* pada setiap interval waktu. Sedangkan *discrete time* merupakan pendekatan yang mempertimbangkan probabilitas terjadinya *failure*

pada setiap interval waktu.

Penghitungan *expected number of failure* pada *kiln* menggunakan pendekatan parameter dan *discrete time*. Formula untuk menghitung dapat dituliskan dalam persamaan (4.2). Variabel ini digunakan sebagai input untuk mendapatkan *total expected downtime* per satuan waktu $D(t_p)$.

$$M(t) = \frac{\lambda\mu}{(\lambda+\mu)}t - \frac{\lambda\mu}{(\lambda+\mu)^2} + \frac{\lambda\mu}{(\lambda+\mu)^2}e^{-(\lambda+\mu)t} \dots\dots\dots(3.5)$$

3.3.1.5 Pengolahan Menggunakan Model Downtime Minimization

Pengolahan menggunakan model *downtime minimization* bertujuan untuk mengurangi *downtime* yang terjadi akibat *breakdown*. Data yang digunakan adalah data *downtime* dari hasil pengelompokkan berdasarkan jenis komponen *kiln*. Model ini memiliki dua metode yaitu *constant interval replacement policy (cirp)* dan *replacement at predetermined age*.

Constant interval replacement policy (cirp) merupakan metode yang digunakan untuk melakukan *preventive replacement* dalam interval waktu yang telah ditetapkan. Formula *constant interval replacement policy (cirp)* dapat dituliskan dengan persamaan (4.3).

$$D(t_p) = \frac{M(t_p)T_r + T_p}{T_p + t_p} \dots\dots\dots(3.6)$$

Hasil dari *preventive maintenance and replacement model* akan digunakan sebagai acuan untuk mendapatkan jadwal *maintenance* yang optimum. Jadwal *maintenance* tersebut berdasarkan setiap komponen *kiln equipment*. Sehingga terdapat tujuh jadwal *maintenance* untuk *kiln equipment*.

Terdapat beberapa tindakan yang dapat diambil dalam menjalankan evaluasi rekomendasi *maintenance strategy*.

1. Tindakan inspeksi dan monitoring ketika terdapat kondisi mendekati kondisi *abnormal* pada *kiln equipment* berdasarkan hasil dari data sensor.
2. Tindakan *overhaul* diperlukan ketika *kiln equipment* telah mengalami kondisi *abnormal* yang parah dan berpotensi mengalami kerusakan.

Overhaul merupakan tindakan perbaikan yang bertujuan untuk mengembalikan kondisi *kiln equipment* seperti semula.

3. Tindakan replacement diperlukan ketika terdapat komponen *kiln equipment* telah benar-benar rusak, diperlukan tindakan *replacement*. Dengan melakukan penggantian komponen rusak dengan komponen yang baru akan membuat *kiln equipment* seperti kondisi semula.

3.3.2 *Evaluasi Rekomendasi Maintenance Strategy*

Proses evaluasi dilakukan dengan membandingkan jadwal *maintenance* yang telah didapatkan dengan informasi kondisi sebenarnya yang terjadi di perusahaan. Hasil jadwal *maintenance* telah mendekati kondisi sebenarnya maka dapat disimpulkan bahwa hasilnya telah sesuai. Namun ketika hasilnya ternyata tidak mendekati kondisi sebenarnya maka diperlukan analisis lebih lanjut.

3.4 **Kesimpulan dan Saran**

Tahap ini merupakan bagian akhir dari penelitian. Penarikan kesimpulan berdasarkan tujuan yang ingin dicapai dalam penelitian ini. Sedangkan saran yang diusulkan ditujukan kepada perusahaan dan pengembangan penelitian selanjutnya.

(Halaman ini Sengaja Dikosongkan)

BAB 4

IDENTIFIKASI DAN ANALISIS *CURRENT* INFORMATION

Pada bab ini menjelaskan mengenai jenis data sensor *kiln equipment* yang akan digunakan dalam penelitian ini. Selanjutnya akan dilakukan identifikasi dan analisis informasi awal melalui data sensor. Kemudian dari identifikasi dan analisis tersebut didapatkan nilai *availability kiln equipment* dan dilakukan analisis.

4.1. Jenis Data Sensor *Kiln Equipment*

Pada subbab ini menjelaskan mengenai identifikasi jenis data sensor *kiln equipment*, data sensor *kiln equipment* periode tahun 2015 hingga 2018, dan regulasi *kiln equipment*.

4.1.1 Identifikasi Jenis Data Sensor Kiln Equipment

Dalam *kiln equipment* terdiri dari tujuh data sensor. Masing-masing jenis data sensor mendeteksi perilaku jenis peralatan yang berbeda-beda. Namun dapat juga untuk mendeteksi jenis peralatan yang masih berhubungan. Pada setiap jenis data sensor terdapat *threshold* dimana sebagai batas untuk mengetahui kondisi *kiln equipment*. Ketika data sensor mendeteksi kondisi dibawah *threshold* maka merepresentasikan kondisi *kiln equipment* sedang *breakdown*. Dan data sensor mendeteksi kondisi diatas *threshold* maka merepresentasikan kondisi kiln equipment sedang beroperasi.

Masing-masing jenis data sensor mendeteksi peralatan yang berbeda. Jenis data sensor Motor EPFAN, Motor IDFAN I dan Motor IDFAN II mendeteksi putaran *fan kiln equipment* dengan *threshold* nilai putaran (*RPM*). Kemudian data sensor *Kiln Feed* mendeteksi jumlah suplai yang masuk *kiln equipment* dengan *threshold* nilai aliran suplai (*Ton/Hours*). Lalu data sensor *Temperature Calciner* mendeteksi suhu *kiln equipment* dengan *threshold* nilai suhu ($^{\circ}C$). Data sensor *Maindrive Kiln* mendeteksi putaran *kiln equipment* dengan *threshold* nilai putaran (*RPM*). Dan terakhir data sensor *Coal Feeder* mendeteksi jumlah suplai *coal* untuk

kiln equipment dengan *threshold* nilai aliran suplai (*Ton/Hours*). Ketujuh jenis data sensor beserta masing-masing nilai *threshold* dapat dilihat pada Tabel 4.1 sebagai berikut.

Tabel 4. 1 Jenis Data *Kiln Equipment*

<i>Variable</i>	<i>Type</i>	<i>Equipment</i>	<i>Threshold</i>
X1	533FN01U01S01	Motor EPFAN	50 <i>RPM</i>
X2	533FN02U01S01	Motor IDFAN 1	50 <i>RPM</i>
X3	533FN02U01S01	Motor IDFAN 2	50 <i>RPM</i>
X4	541KF01A01F01X01	<i>Kiln Feed</i>	150 <i>Ton/Hours</i>
X5	542CL01N03T01	<i>Temperature Calciner</i>	300 °C
X6	543MD01U01S01	<i>Maindrive Kiln</i>	0.5 <i>RPM</i>
X7	545RL03A01F01	<i>Coal Feeder</i>	1 <i>Ton/Hours</i>

Dengan nilai ketujuh jenis data sensor tersebut akan dilakukan identifikasi permasalahan yang terjadi pada *kiln equipment*. Dengan mengetahui permasalahan pada *kiln equipment* akan menjadi informasi untuk perancangan *maintenance strategy*. Tujuan dari perancangan *maintenance strategy* tersebut untuk mencari jadwal *maintenance* yang paling efisien untuk meminimalkan *downtime* dari *kiln equipment*.

4.1.2 *Data Sensor Kiln Equipment*

Pengambilan data sensor *kiln equipment* pada empat periode yaitu tahun 2015 hingga 2018. Data Sensor yang digunakan adalah ketujuh jenis data sensor *kiln equipment*. Sistem pengambilan data sensor dapat menggunakan beberapa skema pengambilan. Pengambilan data sensor dapat dilakukan dengan skema pengambilan setiap beberapa detik, setiap beberapa menit, dan setiap beberapa jam. Namun pada penelitian ini menggunakan interval waktu satu jam sekali pada setiap periode. Seluruh data sensor yang digunakan dapat terlihat pada Tabel 4.2 untuk periode 2015, Tabel 4.3 untuk periode 2016, Tabel 4.4 untuk periode 2017, dan Tabel 4.5 untuk periode 2018 sebagai berikut.

Tabel 4. 2 Data Sensor *Kiln Equipment* 2015

2015								
No	Date	X1	X2	X3	X4	X5	X6	X7
0	01/01/2015 00:00	1083	666	666	569	800	3.70	19.20
1	01/01/2015 01:00	940	674	673	581	800	3.80	19.40
2	01/01/2015 02:00	837	673	673	577	798	3.80	19.50
3	01/01/2015 03:00	847	674	673	585	802	3.80	19.40
4	01/01/2015 04:00	1182	673	674	574	810	3.75	19.40
5	01/01/2015 05:00	826	674	673	573	808	3.75	19.40
...
8754	31/12/2015 19:00	824	630	629	519	797	3.55	20.70
8755	31/12/2015 20:00	801	629	629	520	787	3.55	20.50
8756	31/12/2015 21:00	812	629	630	521	802	3.55	20.50
8757	31/12/2015 22:00	809	629	629	520	787	3.55	20.50
8758	31/12/2015 23:00	792	629	629	521	789	3.55	20.90

Tabel 4. 3 Data Sensor *Kiln Equipment* 2016

2016								
No	Date	X1	X2	X3	X4	X5	X6	X7
8758	31/12/2015 23:00	792	629	629	521	789	3.55	20.90
1	01/01/2016 00:00	778	629	629	519	788	3.55	21.00
2	01/01/2016 01:00	786	628	629	519	790	3.55	21.10
3	01/01/2016 02:00	800	629	629	520	793	3.55	21.00
4	01/01/2016 03:00	793	628	629	519	788	3.55	21.00
5	01/01/2016 04:00	789	629	629	520	789	3.55	21.00
...
8780	31/12/2016 19:00	796	666	666	569	789	3.90	18.70
8781	31/12/2016 20:00	823	666	666	569	792	3.90	18.70
8782	31/12/2016 21:00	840	666	665	569	799	3.90	18.70
8783	31/12/2016 22:00	764	666	666	575	812	3.90	18.70
8784	31/12/2016 23:00	742	666	666	569	806	3.90	18.70

Tabel 4. 4 Data Sensor *Kiln Equipment* 2017

2017								
No	Date	X1	X2	X3	X4	X5	X6	X7
8784	31/12/2016 23:00	742	666	666	569	806	3.90	18.70
1	01/01/2017 00:00	755	681	681	560	797	3.80	22.00
2	01/01/2017 01:00	753	681	681	560	796	3.90	22.00
3	01/01/2017 02:00	748	680	681	554	792	3.90	22.00
4	01/01/2017 03:00	728	680	681	562	793	3.85	21.80
5	01/01/2017 04:00	710	659	658	562	790	3.85	21.80
...
8755	31/12/2017 19:00	759	614	614	490	818	3.55	26.80
8756	31/12/2017 20:00	750	614	614	490	816	3.55	26.80
8757	31/12/2017 21:00	738	614	614	492	812	3.60	26.80
8758	31/12/2017 22:00	737	614	614	490	812	3.60	26.80
8759	31/12/2017 23:00	749	614	614	490	813	3.60	26.50

Tabel 4. 5 Data Sensor *Kiln Equipment* 2018

2018								
No	Date	X1	X2	X3	X4	X5	X6	X7
8759	31/12/2017 23:00	749	614	614	490	813	3.60	26.50
1	01/01/2018 00:00	747	613	614	490	809	3.60	25.80
2	01/01/2018 01:00	754	614	614	489	806	3.60	25.80
3	01/01/2018 02:00	755	614	614	483	809	3.60	25.80
4	01/01/2018 03:00	767	614	613	493	810	3.60	25.80
5	01/01/2018 04:00	740	614	614	488	808	3.60	25.80
...
8706	31/12/2018 19:00	730	584	584	491	705	3.20	21.60
8707	31/12/2018 20:00	718	585	585	495	702	3.20	21.20
8708	31/12/2018 21:00	712	584	584	493	703	3.20	21.00
8709	31/12/2018 22:00	705	584	584	495	704	3.30	21.00
8710	31/12/2018 23:00	814	577	577	489	702	3.30	21.00

Skema pengambilan data sensor dengan interval satu jam sekali menghasilkan data sensor sekitar 8700 data. Data sensor tersebut merupakan data kontinyu dari awal periode hingga akhir. Sehingga untuk total data sensor periode 2015 hingga 2018 berjumlah sekitas 34800 data. Setiap jenis data sensor tersebut memiliki *threshold* untuk menentukan kondisi setiap peralatan *kiln equipment*.

Kemudian kondisi setiap jenis peralatan tersebut akan diintegrasikan dengan jenis peralatan lainnya. Hasil integrasi setiap jenis peralatan tersebut akan dibandingkan dengan *kiln equipment regulation* untuk mengetahui kondisi *kiln equipment*. Sehingga didapatkan waktu terjadinya breakdown dan waktu kembali beroperasi. Kemudian dari waktu terjadinya breakdown dan waktu kembali beroperasi akan dilakukan penghitungan untuk mendapatkan nilai *Time to failure* (TTF) dan *Time to repair* (TTR).

Proses monitoring *kiln equipment* menggunakan peralatan sensor bertujuan untuk mengetahui perilaku peralatan sebelum terjadi kerusakan. Sehingga dengan adanya peralatan sensor ini dapat mengantisipasi kerusakan yang akan terjadi. Dan juga dapat digunakan untuk memprediksi kerusakan peralatan di masa yang akan datang.

4.1.3 Regulasi Kiln Equipment

Regulasi pada *kiln equipment* merupakan integrasi kondisi ketujuh peralatan *kiln equipment* untuk menentukan kondisi dari *kiln equipment*. Regulasi ini menggunakan integrasi peralatan kiln equipment karena menggunakan sistem *interlock* untuk mendeteksi kegagalan. Sistem *interlock* akan mendeteksi kegagalan ketika memenuhi kriteria kegagalan dari regulasi. Regulasi *kiln equipment* tersebut dapat dilihat pada Tabel 4.6 sebagai berikut.

Tabel 4. 6 *Kiln Equipment Regulation*

<i>Kiln Equipment Regulation</i>								
No	X1	X2	X3	X4	X5	X6	X7	Status
1	0	0	0	0	0	0	0	FAILURE
2	0	0	0	0	0	0	1	FAILURE
3	0	0	0	0	0	1	0	FAILURE
4	0	0	0	0	0	1	1	FAILURE
5	0	0	0	0	1	0	0	FAILURE

Tabel 4.6 *Kiln Equipment Regulation* (Lanjutan)

<i>Kiln Equipment Regulation</i>								
No	X1	X2	X3	X4	X5	X6	X7	Status
6	0	0	0	0	1	0	1	FAILURE
7	0	0	0	0	1	1	0	FAILURE
8	0	0	0	0	1	1	1	FAILURE
9	0	0	0	1	0	0	0	FAILURE
10	0	0	0	1	0	0	1	FAILURE
...
115	1	1	1	0	0	1	0	FAILURE
116	1	1	1	0	0	1	1	RUNNING
117	1	1	1	0	1	0	0	FAILURE
118	1	1	1	0	1	0	1	FAILURE
119	1	1	1	0	1	1	0	FAILURE
120	1	1	1	0	1	1	1	RUNNING
121	1	1	1	1	0	0	0	FAILURE
122	1	1	1	1	0	0	1	FAILURE
123	1	1	1	1	0	1	0	FAILURE
124	1	1	1	1	0	1	1	RUNNING
125	1	1	1	1	1	0	0	FAILURE
126	1	1	1	1	1	0	1	FAILURE
127	1	1	1	1	1	1	0	RUNNING
128	1	1	1	1	1	1	1	RUNNING

Total *kiln equipment regulation* berjumlah 128 regulasi. Regulasi tersebut terdiri dari 5 regulasi ketika data sensor mendeteksi *kiln equipment* dalam kondisi *running* dan 123 regulasi ketika data sensor mendeteksi *kiln equipment* dalam kondisi *breakdown*.

4.2. Identifikasi dan Analisis Current Information

Pada subbab ini menjelaskan mengenai identifikasi dan analisis informasi *failure data* dan *repair data*. Pada *failure data* dan *repair data* terdiri dari tujuh jenis data sensor.

4.2.1 *Failure Data*

Hasil dari pengolahan data sensor berdasarkan regulasi *kiln equipment* menghasilkan *failure data*. Nilai *failure data* tersebut merupakan data sensor pada kondisi ketika *kiln equipment* mengalami *breakdown*. Kemudian dari beroperasi

hingga *breakdown* terdapat interval waktu kegagalan atau biasa disebut *Time to failure* (TTF). *Time to failure* (TTF) menjadi variabel bebas berupa X8. Sehingga penambahan *Time to failure* (TTF) pada keseluruhan *failure data* dapat dilihat pada Tabel 4.7 sebagai berikut.

Tabel 4. 7 *Failure Data Kiln Equipment*

Failure								
No	X1	X2	X3	X4	X5	X6	X7	TTF (X8)
1	365	0	0	280	756	0.10	2.00	139
2	364	0	0	0	712	0.00	0.00	73
3	425	0	0	0	778	0.10	0.00	117
4	365	0	0	0	750	0.10	0.00	53
5	364	0	0	0	739	0.10	0.00	7
...
194	0	0	0	0	873	0.10	3.00	37
195	425	0	0	0	788	0.10	0.00	361
196	365	0	0	0	820	0.10	0.00	196
197	480	0	0	0	820	0.10	0.00	12
198	542	0	0	0	793	0.00	0.00	297

Hasil *failure data* yang didapatkan pada periode 2015 hingga 2018 dengan total berjumlah 198 data. Sehingga *failure data* merepresentasikan ketujuh data sensor pada saat mengalami *breakdown* dan ditambah dengan nilai *Time to failure* (TTF) *kiln equipment*.

4.2.2 *Repair Data*

Hasil dari pengolahan data sensor berdasarkan regulasi *kiln equipment* menghasilkan *repair data*. Nilai *repair data* tersebut merupakan data sensor pada kondisi ketika *kiln equipment* mengalami beroperasi. Kemudian dari *breakdown* hingga beroperasi terdapat interval waktu perbaikan atau biasa disebut *Time to repair* (TTR). *Time to repair* (TTR) menjadi variabel bebas berupa X9. Sehingga penambahan *Time to repair* (TTR) pada keseluruhan *repair data* dapat dilihat pada Tabel 4.8 sebagai berikut.

Tabel 4. 8 *Repair Data Kiln Equipment*

Repair								
No	X1	X2	X3	X4	X5	X6	X7	TTR (X9)
1	1036	488	488	319	764	1.10	11.50	1
2	699	429	429	280	747	0.65	12.90	3
3	899	444	444	291	764	0.70	11.50	4
4	712	424	422	280	759	0.50	14.00	6
5	497	437	437	282	750	0.65	10.30	6
...

Tabel 4.8 *Repair Data Kiln Equipment (Lanjutan)*

Repair								
No	X1	X2	X3	X4	X5	X6	X7	TTR (X9)
194	727	429	429	290	816	0.75	18.00	5
195	737	444	444	299	210	0.90	13.20	18
196	699	407	407	287	820	0.60	14.30	2
197	789	437	437	289	820	0.85	13.00	3
198	885	422	422	268	682	0.60	14.00	43

Hasil *repair data* yang didapatkan pada periode 2015 hingga 2018 dengan total berjumlah 198 data. Sehingga *repair data* merepresentasikan ketujuh data sensor pada saat kembali beroperasi dan ditambah dengan nilai *Time to repair (TTR) kiln equipment*.

4.3. Analisis Availability Kiln Equipment Melalui Data Sensor

Pada subbab analisis *availability kiln equipment* melalui data sensor menjelaskan mengenai penghitungan *availability kiln equipment* dan analisis *availability kiln equipment*.

4.3.1 Penghitungan Availability Kiln Equipment

Penghitungan *availability* menggunakan jumlah nilai *time to failure (TTF)* dan *time to repair (TTR)*. Nilai dari TTF dan TTR kemudian digunakan untuk menjadi *mean time to failure (MTTF)* dan *mean time to repair (MTTR)*. MTTF dan MTTR akan digunakan sebagai acuan untuk mencari nilai *availability kiln equipment*. Dimana nilai *availability* menjadi informasi kondisi awal pada *kiln equipment*.

Formula penghitungan *availability kiln equipment* dapat dihitung menggunakan formula (4.1) (Elsayed, 2012) sebagai berikut.

$$Availability = \frac{MTTF}{MTTF+MTTR} \dots\dots\dots(4.1)$$

MTTF : *mean time to failure*

MTTR : *mean time to repair*

Tabel 4. 9 *Availability Kiln Equipment*

Tahun	MTTF (hours)	MTTR (hours)	Availability
2015	121	22	0.845
2016	144	27	0.843
2017	185	31	0.857
2018	155	24	0.868

Berdasarkan Tabel 4.9 pada periode 2016 memiliki *cycle time* terbesar karena merupakan tahun kabisat. Sehingga bertambah *cycle time* bertambah 24 jam. Kemudian dilakukan penghitungan *availability* dilakukan pada periode 2015 hingga 2018 menggunakan formula (4.1) dan didapatkan bahwa nilai *availability* pada setiap periode.

Nilai *availability kiln equipment* terus mengalami peningkatan pada setiap periode. Diketahui nilai *availability kiln equipment* tertinggi pada tahun 2018 yaitu sebesar 86,7%. Sedangkan nilai *availability kiln equipment* terendah pada tahun 2016 yaitu sebesar 81,2%. Sehingga dapat disimpulkan bahwa *availability kiln equipment* pada setiap periode telah mengalami peningkatan namun masih berada dibawah target yang telah ditetapkan perusahaan.

4.3.2 *Analisis Availability Kiln Equipment*

Berdasarkan penghitungan nilai *availability kiln equipment* setiap periode menunjukkan bahwa nilai tersebut masih berada dibawah standar target yang diinginkan yaitu 90%. Target sebesar 90% didapatkan dari nilai *availability* pada *World Class OEE* yang ingin dicapai perusahaan.

World Class OEE (Vorne, 2019) terdiri atas faktor *availability*, *performance* dan *quality*. Untuk mencapai target *World Class OEE* sebesar 85% diperlukan nilai faktor *availability* sebesar 90%, *performance* sebesar 95% dan *quality* sebesar 99%. Jika semua faktor bernilai 90% maka akan membuat nilai OEE sebesar 72,9%. Sehingga diperlukan beberapa nilai faktor yang lebih tinggi daripada faktor lainnya untuk menunjang tercapainya target *World Class OEE*.

Pada kasus *kiln equipment* target perusahaan dalam mencapai *World Class OEE* adalah melalui faktor *availability*. Hal ini dikarenakan perusahaan ingin meminimalkan downtime yang sering terjadi pada kiln equipment. Sehingga untuk mencapai nilai *World Class OEE* sebesar 85% diperlukan nilai faktor *availability* minimal 90%.

BAB 5

PERANCANGAN FRAMEWORK CONDITION BASED MAINTENANCE

Pada bab ini dijelaskan mengenai data pre-processing dari data sensor. Selanjutnya dilakukan perancangan model k-means clustering untuk mendapatkan kluster data. Kemudian hasil kluster data tersebut dilakukan regresi nonlinear untuk mendapatkan hasil prediksi. Dan dilakukan *maintenance decision making* berdasarkan hasil prediksi.

5.1. Data Pre-Processing

Data preprocessing bertujuan untuk mendapatkan hasil analisis yang lebih akurat dengan waktu komputasi data lebih sedikit (Santosa & Umam, 2018). Proses ini juga dapat membuat nilai data menjadi lebih terstandarisasi dengan cara mentransformasikan data pada range tertentu tanpa mengubah informasi yang didapatkan. *Data pre-processing* dilakukan dengan menggunakan eksekusi *coding* dari *software* Matlab. Sehingga dengan cara tersebut diharapkan akan mempercepat waktu penghitungan. *Coding* untuk *data pre-processing* pada *software* Matlab dapat dilihat pada Lampiran 1.

Tabel 5. 1 Data Sensor

Sensor Data									
No	X1	X2	X3	X4	X5	X6	X7	X8	X9
1	365	0	0	280	756	0.1	2	139	1
2	364	0	0	0	712	0	0	73	3
3	425	0	0	0	778	0.1	0	117	4
4	365	0	0	0	750	0.1	0	53	6
5	364	0	0	0	739	0.1	0	7	6
...
194	0	0	0	0	873	0.1	3	37	5
195	425	0	0	0	788	0.1	0	361	18
196	365	0	0	0	820	0.1	0	196	2
197	480	0	0	0	820	0.1	0	12	3
198	542	0	0	0	793	0	0	297	43

Data sensor yang digunakan terdiri dari sembilan atribut. Sembilan atribut tersebut terdiri dari nilai tujuh data sensor saat mendeteksi *breakdown* ditambah dengan nilai *time to failure* (TTF) dan *time to repair* (TTR). Berdasarkan nilai data sensor pada Tabel 5.1 dapat diketahui bahwa nilai data sensor yang beragam mengakibatkan variansi data yang cukup tinggi. Sehingga diperlukan transformasi data menggunakan *data preprocessing*.

Transformasi data pada *data pre-processing* menggunakan teknik *scaling*. Teknik *scaling* merupakan prosedur bertujuan untuk transformasi data kedalam range skala tertentu. Pada penelitian ini menggunakan range 0 hingga 1. Berikut ini persamaan 5.1 merupakan formula yang digunakan dalam melakukan teknik *scaling* (Santosa & Umam, 2018).

$$X = \frac{x-x_{min}}{x_{max}-x_{min}}x (BA - BB) + BB \dots\dots\dots(5.1)$$

- X : data ke-i pada atribut-i
- Xmin : data minimum pada atribut-i
- Xmax : data maksimum pada atribut-i
- BA : nilai batas atas yang digunakan yaitu 1
- BB : nilai batas bawah yang digunakan yaitu 0

Tabel 5. 2 Data *Scaling*

Scaling Data									
No	X1	X2	X3	X4	X5	X6	X7	X8	X9
1	0.332	0.000	0.000	0.479	0.772	0.033	0.149	0.093	0.000
2	0.331	0.000	0.000	0.000	0.727	0.000	0.000	0.048	0.004
3	0.386	0.000	0.000	0.000	0.795	0.033	0.000	0.078	0.007
4	0.332	0.000	0.000	0.000	0.766	0.033	0.000	0.035	0.011
5	0.331	0.000	0.000	0.000	0.755	0.033	0.000	0.004	0.011
...
194	0.000	0.000	0.000	0.000	0.892	0.033	0.224	0.024	0.009
195	0.386	0.000	0.000	0.000	0.805	0.033	0.000	0.242	0.037
196	0.332	0.000	0.000	0.000	0.838	0.033	0.000	0.131	0.002
197	0.436	0.000	0.000	0.000	0.838	0.033	0.000	0.007	0.004
198	0.493	0.000	0.000	0.000	0.810	0.000	0.000	0.199	0.091

Hasil penghitungan dari proses transformasi data menggunakan teknik *scaling* dengan formula (5.1) menghasilkan 198 data yang terdiri dari sembilan atribut variabel. Berdasarkan Tabel 5.2 dapat diketahui bahwa nilai data sensor yang memiliki variansi tinggi telah diubah menjadi data dengan *range* 0 hingga 1. Kemudian hasil dari *data pre-processing* akan digunakan dalam perancangan model *k-means clustering*.

5.2. Perancangan Model K-Means Clustering

Perancangan model *k-means clustering* dilakukan melalui dua tahapan. Tahapan tersebut berupa *design of experiment* (DOE) untuk menentukan jumlah kluster dan iterasi yang akan digunakan dan prosedur *k-means clustering* untuk mengklusterkan data pada hasil *data pre-processing*.


Tahapan yang *design of experiment* dilakukan untuk menentukan jumlah iterasi dan kluster yang akan digunakan. Penentuan jumlah iterasi dan kluster dengan *elbow method* berdasarkan nilai *sum of square error* (SSE) dan *silhouette method* nilai dari *silhouette coefficient*. Proses penghitungan menggunakan *coding* dari *software* Matlab yang dapat dilihat pada Lampiran 2.

5.2.1 Elbow Method

Elbow method merupakan metode untuk menghasilkan informasi dalam menentukan jumlah kluster optimum engan membandingkan nilai *sum of square error* (SSE) pada setiap kluster. Dimana nilai tren membentuk suatu sudut siku pada suatu titik nilai SSE. Persamaan 5.2 berikut ini merupakan formula yang digunakan SSE (Santosa & Umam, 2018).

$$SSE = \sum_{i=1}^k \sum_{x \in D_i} \|x - m_i\|^2 \dots\dots\dots(5.2)$$

- Di : kluster ke-i
- X : data ke-I pada kluster ke-i
- Mi : mean pada kluster ke-i




Gambar 5.1 *Sum of Square Error (SSE)*

Hasil penghitungan menggunakan *coding software Matlab*. menggunakan formula (5.2) menghasilkan tren penurunan nilai *sum of square error (SSE)*. Hal ini dikarenakan semakin besar jumlah kluster akan menyebabkan semakin kecil nilai *sum of square error (SSE)*. Dan semakin banyak jumlah iterasi maka semakin stabil nilai *sum of square error (SSE)* yang dihasilkan. Namun hal tersebut juga dipengaruhi oleh algoritma dari *software Matlab*. Dimana nilai *sum of square error (SSE)* dapat berubah-ubah walaupun tidak signifikan.

Analisis teori mengenai jumlah kluster dan jumlah iterasi dapat dibuktikan dengan hasil penghitungan. Berdasarkan Gambar 5.1 terlihat bahwa titik dari jumlah kluster 4 ke jumlah kluster 5 mengalami penurunan nilai *sum of square error (SSE)* lebih besar dari jumlah kluster lainnya. Hal ini juga ditunjang *elbow method* dengan melihat terbentuknya sudut siku pada titik jumlah kluster 5. Kemudian dengan analisis teori mengenai jumlah iterasi yang dilakukan menjelaskan bahwa iterasi sebesar 100 menghasilkan nilai *sum of square error (SSE)* yang lebih stabil. Sehingga mengindikasikan bahwa pada kluster 5 dengan iterasi 100 merupakan menghasilkan jumlah kluster yang optimum.

5.2.2 Silhouette Index

Selanjutnya metode *silhouette index* digunakan untuk melihat kualitas dan seberapa *robust* dari suatu jumlah klaster. Metode ini gabungan dari metode *cohesion* dan *separation*. *Silhouette index* memiliki variasi nilai diantara -1 hingga 1. Dimana *silhouette index* yang mendekati nilai 1 mengimplikasikan bahwa jumlah klaster mendekati klaster yang optimum. Sedangkan *silhouette index* yang mendekati -1 mengimplikasikan bahwa jumlah klaster yang kurang optimum



Gambar 5.2 Silhouette Index

Analisis teori mengenai *silhouette index* dapat dibuktikan melalui hasil penghitungan. Berdasarkan Gambar 5.2 dapat dilihat bahwa grafik *silhouette index* mengalami fluktuasi dengan tren penurunan. Namun pada jumlah klaster 5 mengalami kenaikan dengan *silhouette index* tertinggi yaitu 0.752. Sehingga dengan hasil *silhouette index* mengindikasikan bahwa jumlah klaster 5 merupakan klaster yang optimum.

5.2.3 K-Means Clustering

Teknik *k-means clustering* merupakan teknik yang sederhana dan sering digunakan dalam pengelompokan data ke dalam beberapa klaster (Santosa & Umam, 2018). Dengan cara mengukur ketidakmiripan melalui penghitungan jarak antara setiap data dengan pusat data (*centroid*) pada suatu klaster. Jarak yang

digunakan dalam penelitian ini yaitu Euclidean. Formula untuk menghitung jarak Euclidean adalah sebagai berikut.

$$E = \sum_{j=1}^k \sum_{i=1}^{n_j} \|x_i^j - c_j\|^2 \dots\dots\dots(5.3)$$

x_j^i : data ke-i pada klaster ke-j

c_j : pusat klaster j (*centroid*)

K : jumlah klaster

Proses pengklasteran data menggunakan jumlah klaster 5 dan jumlah iterasi 100. Dan menggunakan data hasil transformasi menggunakan teknik *scaling*. Hal ini bertujuan untuk proses pengklasteran yang lebih cepat dan lebih akurat namun tidak mengubah nilainya. Pengklasteran dilakukan menggunakan *software* Matlab untuk efisiensi waktu.

Tabel 5. 3 Data *Scaling* Klaster 1

Klaster 1										
No.	(n)	X1	X2	X3	X4	X5	X6	X7	X8	X9
1	1	0.33	0.00	0.00	0.48	0.77	0.03	0.15	0.09	0.00
2	8	0.43	0.00	0.00	0.00	0.81	0.03	0.19	0.00	0.00
3	9	0.31	0.00	0.00	0.00	0.83	0.03	0.22	0.02	0.01
4	36	0.39	0.00	0.00	0.00	0.82	0.03	0.19	0.01	0.00
5	52	0.39	0.00	0.00	0.00	0.87	0.03	0.22	0.05	0.00
...
37	162	0.35	0.00	0.00	0.00	0.96	0.03	0.22	0.21	0.01
38	166	0.33	0.00	0.00	0.00	0.93	0.03	0.22	0.05	0.00
39	175	0.39	0.00	0.00	0.00	1.00	0.03	0.22	0.03	0.00
40	176	0.44	0.00	0.00	0.00	0.88	0.03	0.22	0.00	0.00
41	193	0.39	0.00	0.00	0.00	0.85	0.03	0.22	0.00	0.22

Berdasarkan Tabel 5.3 didapatkan bahwa data anggota klaster 1 berjumlah 41 data. Kemudian data *scaling* klaster 1 diubah kembali ke nilai aslinya untuk dilakukan analisis karakteristik dari klaster tersebut.

Tabel 5. 4 Data Sensor Klaster 1

Klaster 1										
No.	(n)	X1	X2	X3	X4	X5	X6	X7	X8	X9
1	1	365	0	0	280	756	0.10	2.00	139	1
2	8	477	0	0	0	791	0.10	2.50	7	2
3	9	341	0	0	0	815	0.10	3.00	29	5
4	36	426	0	0	0	804	0.10	2.50	13	1
5	52	426	0	0	0	853	0.10	3.00	71	1
...
37	162	388	0	0	0	941	0.10	3.00	309	5
38	166	365	0	0	0	912	0.10	3.00	72	2
39	175	425	0	0	0	979	0.10	3.00	53	2
40	176	486	0	0	0	864	0.10	3.00	1	2
41	193	425	0	0	0	837	0.10	3.00	3	102

Berdasarkan Tabel 5.4 didapatkan bahwa data anggota klaster 1 memiliki nilai rata-rata, tertinggi dan terendah untuk TTF sebesar 101,12 jam, 520 jam, dan 1 jam. Sedangkan nilai rata-rata, tertinggi dan terendah TTR sebesar 19,024 jam, 166 jam, dan 1 jam. Sehingga untuk standar deviasi yang dihasilkan cukup besar yaitu 123,12 jam untuk TTF dan 35,817 jam untuk TTR.

Tabel 5. 5 Data Scaling Klaster 2

Klaster 2										
No.	(n)	X1	X2	X3	X4	X5	X6	X7	X8	X9
1	2	0.33	0.00	0.00	0.00	0.73	0.00	0.00	0.05	0.00
2	3	0.39	0.00	0.00	0.00	0.79	0.03	0.00	0.08	0.01
3	4	0.33	0.00	0.00	0.00	0.77	0.03	0.00	0.03	0.01
4	5	0.33	0.00	0.00	0.00	0.75	0.03	0.00	0.00	0.01
5	7	0.34	0.00	0.00	0.00	0.79	0.03	0.01	0.03	0.00
...
106	191	0.42	0.00	0.00	0.00	0.84	0.03	0.00	0.22	0.02
107	195	0.39	0.00	0.00	0.00	0.80	0.03	0.00	0.24	0.04
108	196	0.33	0.00	0.00	0.00	0.84	0.03	0.00	0.13	0.00
109	197	0.44	0.00	0.00	0.00	0.84	0.03	0.00	0.01	0.00
110	198	0.49	0.00	0.00	0.00	0.81	0.00	0.00	0.20	0.09

Berdasarkan Tabel 5.5 didapatkan bahwa data anggota klaster 2 berjumlah 110 data. Kemudian data scaling klaster 2 diubah kembali ke nilai aslinya untuk dilakukan analisis karakteristik dari klaster tersebut.

Tabel 5. 6 Data Sensor Klaster 2

Klaster 2										
No.	(n)	X1	X2	X3	X4	X5	X6	X7	X8	X9
1	2	364	0	0	0	712	0.00	0.00	73	3
2	3	425	0	0	0	778	0.10	0.00	117	4
3	4	365	0	0	0	750	0.10	0.00	53	6
4	5	364	0	0	0	739	0.10	0.00	7	6
5	7	377	0	0	0	769	0.10	0.20	50	1
...
106	191	462	0	0	0	825	0.10	0.00	332	12
107	195	425	0	0	0	788	0.10	0.00	361	18
108	196	365	0	0	0	820	0.10	0.00	196	2
109	197	480	0	0	0	820	0.10	0.00	12	3
110	198	542	0	0	0	793	0.00	0.00	297	43

Berdasarkan Tabel 5.6 didapatkan bahwa data anggota klaster 2 memiliki nilai rata-rata, tertinggi dan terendah untuk TTF sebesar 145,782 jam, 1021 jam, dan 1 jam. Sedangkan nilai rata-rata, tertinggi dan terendah TTR sebesar 14,527 jam, 145 jam, dan 1 jam. Sehingga untuk standar deviasi yang dihasilkan cukup besar yaitu 170,73 jam untuk TTF dan 23,653 jam untuk TTR.

Tabel 5. 7 Data Scaling Klaster 3

Klaster 3										
No.	(n)	X1	X2	X3	X4	X5	X6	X7	X8	X9
1	30	0.33	0.00	0.00	0.00	0.77	0.03	0.00	0.00	0.96
2	37	0.55	0.00	0.00	0.00	0.79	0.03	0.00	1.00	0.49
3	72	0.50	0.00	0.00	0.00	0.84	0.03	0.00	0.05	0.90
4	85	0.28	0.00	0.00	0.00	0.81	0.03	0.00	0.17	0.45
5	115	0.33	0.00	0.00	0.00	0.71	0.00	0.13	0.03	0.60
6	122	0.39	0.00	0.00	0.00	0.84	0.03	0.00	0.19	0.99
7	163	0.42	0.00	0.00	0.00	0.88	0.10	0.45	0.00	1.00

Berdasarkan Tabel 5.7 didapatkan bahwa data anggota klaster 3 berjumlah 7 data. Kemudian data scaling klaster 3 diubah kembali ke nilai aslinya untuk dilakukan analisis karakteristik dari klaster tersebut.

Tabel 5. 8 Data Sensor Klaster 3

Klaster 3										
No.	(n)	X1	X2	X3	X4	X5	X6	X7	X8	X9
1	30	365	0	0	0	757	0.10	0.00	5	443
2	37	607	0	0	0	770	0.10	0.00	1491	227
3	72	547	0	0	0	824	0.10	0.00	72	415
4	85	304	0	0	0	789	0.10	0.00	256	208
5	115	365	0	0	0	691	0.00	1.70	49	277
6	122	425	0	0	0	823	0.10	0.00	291	457
7	163	462	0	0	0	860	0.30	6.00	5	461

Berdasarkan Tabel 5.8 didapatkan bahwa data anggota klaster 3 memiliki nilai rata-rata, tertinggi dan terendah untuk TTF sebesar 309,857 jam, 1491 jam, dan 5 jam. Sedangkan nilai rata-rata, tertinggi dan terendah TTR sebesar 355,429 jam, 461 jam, dan 208 jam. Sehingga untuk standar deviasi yang dihasilkan cukup besar yaitu 494,087 jam untuk TTF dan 104,922 jam untuk TTR.

Tabel 5. 9 Data Scaling Klaster 4

Klaster 4										
No.	(n)	X1	X2	X3	X4	X5	X6	X7	X8	X9
1	79	0.57	0.60	0.60	0.44	0.74	0.13	1.00	0.01	0.00
2	83	0.55	0.60	0.60	0.48	0.80	0.10	0.52	0.01	0.00
3	128	0.61	0.60	0.60	0.46	0.75	0.10	0.75	0.00	0.00
4	169	0.80	1.00	1.00	0.96	0.85	0.00	0.00	0.01	0.00
5	170	0.77	0.99	0.00	0.00	0.00	0.00	0.00	0.07	0.00
6	172	1.00	0.96	0.00	0.00	0.00	0.00	0.00	0.15	0.00
7	173	0.80	0.96	0.00	0.00	0.00	0.00	0.00	0.00	0.00
8	179	0.76	0.97	0.97	0.00	0.00	0.00	0.00	0.11	0.00
9	181	0.74	0.97	0.97	1.00	0.82	0.00	0.00	0.01	0.00
10	183	0.81	0.99	0.99	0.95	0.83	0.00	0.00	0.19	0.00
11	188	0.82	0.97	0.97	0.94	0.00	0.00	0.00	0.08	0.00
12	190	0.80	0.93	0.93	0.00	0.00	0.00	0.00	0.30	0.00
13	192	0.72	0.87	0.87	0.84	0.82	0.00	0.00	0.02	0.00

Berdasarkan Tabel 5.9 didapatkan bahwa data anggota klaster 4 berjumlah 13 data. Kemudian data scaling klaster 4 diubah kembali ke nilai aslinya untuk dilakukan analisis karakteristik dari klaster tersebut.

Tabel 5. 10 Data Sensor Klaster 4

Klaster 4										
No.	(n)	X1	X2	X3	X4	X5	X6	X7	X8	X9
1	79	624	407	407	259	728	0.40	13.40	12	1
2	83	610	407	407	281	787	0.30	7.00	22	1
3	128	670	406	407	271	734	0.30	10.00	3	1
4	169	884	674	673	563	834	0.00	0.00	16	1
5	170	844	666	0	0	0	0.00	0.00	102	1
6	172	1100	644	0	0	0	0.00	0.00	228	1
7	173	885	644	0	0	0	0.00	0.00	3	1
8	179	834	651	651	0	0	0.00	0.00	165	1
9	181	817	651	652	585	805	0.00	0.00	18	1
10	183	888	666	666	554	812	0.00	0.00	288	1
11	188	902	651	651	547	0	0.00	0.00	123	1
12	190	877	629	629	0	0	0.00	0.00	443	1
13	192	796	585	585	490	805	0.00	0.00	27	1

Berdasarkan Tabel 5.10 didapatkan bahwa data anggota klaster 4 memiliki nilai rata-rata, tertinggi dan terendah untuk TTF sebesar 111,538 jam, 443 jam, dan 3 jam. Sedangkan nilai rata-rata, tertinggi dan terendah TTR sebesar 1 jam, 1 jam, dan 1 jam. Sehingga untuk standar deviasi yang dihasilkan cukup besar yaitu 131,313 jam untuk TTF dan 0 jam untuk TTR.

Tabel 5. 11 Data Scaling Klaster 5

Klaster 5										
No.	(n)	X1	X2	X3	X4	X5	X6	X7	X8	X9
1	6	0.00	0.00	0.00	0.00	0.72	0.03	0.00	0.00	0.01
2	12	0.00	0.00	0.00	0.00	0.79	0.03	0.00	0.04	0.03
3	13	0.00	0.00	0.00	0.00	0.83	0.03	0.00	0.05	0.00
4	16	0.00	0.00	0.00	0.00	0.83	0.03	0.00	0.05	0.01
5	17	0.00	0.00	0.00	0.00	0.86	0.03	0.00	0.11	0.01
...
23	160	0.00	0.00	0.00	0.00	0.91	0.03	0.00	0.89	0.01
24	161	0.00	0.00	0.00	0.00	0.82	0.03	0.00	0.03	0.00
25	168	0.00	0.00	0.00	0.00	0.85	0.03	0.00	0.08	0.00
26	187	0.00	0.00	0.00	0.00	0.80	0.00	0.00	0.03	0.03
27	194	0.00	0.00	0.00	0.00	0.89	0.03	0.22	0.02	0.01

Berdasarkan Tabel 5.11 didapatkan bahwa data anggota klaster 5 berjumlah 27 data. Kemudian data scaling klaster 5 diubah kembali ke nilai aslinya

untuk dilakukan analisis karakteristik dari klaster tersebut.

Tabel 5. 12 Data Sensor Klaster 5

Klaster 5										
No.	(n)	X1	X2	X3	X4	X5	X6	X7	X8	X9
1	6	0	0	0	0	709	0.10	0.00	4	5
2	12	0	0	0	0	773	0.10	0.00	66	14
3	13	0	0	0	0	808	0.10	0.00	69	1
4	16	0	0	0	0	810	0.10	0.00	77	6
5	17	0	0	0	0	845	0.10	0.00	168	7
...
23	160	0	0	0	0	888	0.10	0.00	1320	7
24	161	0	0	0	0	804	0.10	0.00	40	3
25	168	0	0	0	0	828	0.10	0.00	121	2
26	187	0	0	0	0	787	0.00	0.00	52	14
27	194	0	0	0	0	873	0.10	3.00	37	5

Berdasarkan Tabel 5.12 didapatkan bahwa data anggota klaster 5 memiliki nilai rata-rata, tertinggi dan terendah untuk TTF sebesar 203,926 jam, 1320 jam, dan 4 jam. Sedangkan nilai rata-rata, tertinggi dan terendah TTR sebesar 6,03 jam, 16 jam, dan 1 jam. Sehingga untuk standar deviasi yang dihasilkan cukup besar yaitu 279,954 jam untuk TTF dan 4,167 jam untuk TTR.

Sehingga kesimpulan berdasarkan nilai TTF dan TTR hasil data yang telah di kelompokkan dalam 5 klaster memiliki karakteristik masing masing. Dimana klaster 3 merupakan klaster dengan tingkat kerusakan berat. Hal tersebut terlihat dari dengan rata-rata TTF dan TTR tertinggi yaitu 309,8571 jam dan 355,428 jam. Dan klaster 4 merupakan klaster dengan tingkat kerusakan ringan. Hal tersebut terlihat dari dengan rata-rata TTF dan TTR terendah yaitu 111,53 jam dan 1 jam. Sedangkan klaster1, klaster 2, dan klaster 5 merupakan klaster dengan tingkat kerusakan sedang. Tingkat kerusakan sedang dibagi menjadi 3 tingkatan berdasarkan nilai TTF dan TTR. Klaster 5 merupakan tingkatan ringan, klaster 2 merupakan tingkatan sedang, dan klaster 1 merupakan tingkatan berat. Kemudian hasil dari data klaster ini akan dilakukan prediksi menggunakan metode regresi.

5.3. Perancangan Model Nonlinear Regression

Perancangan model *nonlinear regression* dilakukan untuk memprediksi waktu *breakdown kiln equipment* menggunakan data klaster dari *k-means clustering*. Dimana hasil dari pengolahan menggunakan teknik *k-means clustering* menghasilkan 5 klaster. Proses prediksi terjadinya *breakdown* menggunakan *nonlinear regression* dikarenakan model ini lebih dapat mencakup semua parameter distribusi data variabel. Sedangkan hal tersebut tidak dapat dilakukan oleh *linier regression* karena hanya dapat dilakukan pada data berdistribusi normal. Pengolahan model *nonlinear regression* menggunakan *tools data analytics* dari Microsoft Excel. Secara umum formula *nonlinear regression* dapat dituliskan sebagai berikut.

$$Y = f(X, \beta) + \varepsilon \dots\dots\dots(5.4)$$

- X : vektor dari p prediktor
- B : vektor dari k parameter
- f(-) : fungsi regresi berdasarkan distribusi
- ε : error

Model *nonlinear regression* dilakukan untuk mendapatkan hasil prediksi dari *time to failure* dan *time to repair*. Untuk mendapatkan hasil prediksi *time to failure* menggunakan variabel bebas data sensor X1 hingga X7 ditambah dengan *time to repair* (X9). Sedangkan untuk mendapatkan hasil prediksi *time to repair* menggunakan variabel bebas data sensor X1 hingga X7 ditambah dengan *time to failure* (X8). Kemudian hasil dari prediksi tersebut dicari parameternya untuk mengetahui karakteristik dari data untuk memudahkan pemberian label.

Hasil prediksi menghasilkan beberapa parameter. Salah satunya adalah parameter distribusi. Dari hasil prediksi *failure* dan *repair* menghasilkan parameter berupa distribusi Weibull. Dimana terdapat parameter Beta sebagai *shape parameter*, parameter Eta sebagai *slope parameter* dan parameter Gamma sebagai *location parameter*. Dan juga terdapat parameter lain seperti data rata-rata, data maksimal, data minimal dan lainnya. Juga terdapat hasil penghitungan *root mean*

square error (RMSE) untuk mengetahui sebaik mana hasil regresinya.

Tabel 5. 13 Hasil Regresi Klaster 1

Klaster 1				
No.	Failure		Repair	
	X8	Predicted X8	X9	Predicted X9
1	139	139.000	1	1.000
2	7	90.449	2	25.380
3	29	131.611	5	22.374
4	13	99.892	1	23.542
5	71	100.425	1	19.590
...
37	309	84.036	5	6.712
38	72	98.836	2	14.157
39	53	64.704	2	10.197
40	1	81.908	2	21.168
41	3	79.087	102	22.399

Tabel 5. 14 Parameter Hasil Regresi Klaster 1

Klaster 1		
Regression Statistics	Failure	Repair
Multiple R	0.332178047	0.212615755
R Square	0.110342255	0.045205459
Adjusted R Square	-0.11207218	-0.19349318
Standard Error	131.4493955	39.61581706
Observations	41	41
Avg	103.729	19.024
Max	239.624	34.970
Min	44.225	1.000
Stdev	31.937	6.040
RMSE	117.863	35.305
Avg/Hours	0.010	0.053
Distribution:	Weibull	Weibull
Beta:	2.580	2.187
Eta:	3457.001	598.337
Gamma:	-825.703	-113.198

Berdasarkan hasil regresi klaster 1 pada Tabel 5.14 yaitu Multiple R dan R Square sangat kecil. Hal tersebut menandakan bahwa hubungan antar variabel dan proporsi variabel terikat dan bebas bernilai kecil. Dan nilai RMSE yang tinggi manandakan bahwa error yang besar. Sehingga hasil prediksi yang dihasilkan

kurang baik.

Tabel 5. 15 Hasil Regresi Klaster 2

Klaster 2				
No.	Failure		Repair	
	X8	Predicted X8	X9	Predicted X9
1	73	130.222	3	13.505
2	117	147.694	4	14.139
3	53	131.029	6	14.609
4	7	128.811	6	14.357
5	50	137.689	1	12.351
...
106	332	166.139	12	14.860
107	361	153.652	18	15.532
108	196	142.673	2	15.450
109	12	166.208	3	12.782
110	297	192.822	43	12.303

Tabel 5. 16 Parameter Hasil Regresi Klaster 2

Klaster 2		
Regression Statistics	Failure	Repair
Multiple R	0.159176492	0.126055654
R Square	0.025337156	0.015890028
Adjusted R Square	-0.051863862	-0.062059277
Standard Error	175.9032769	24.48792217
Observations	110	110
Avg	145.7818182	14.52727273
Max	231.0772966	31.9229147
Min	53.89491721	2.108220219
Stdev	24.47443029	2.842595902
RMSE	168.967	23.482
Avg/Hours	0.00686	0.06884
Distribution:	Weibull	Weibull
Beta:	1.8132	1.595
Eta:	10262	983.7122
Gamma:	-960.3604	-51.8946

Berdasarkan hasil regresi klaster 2 pada Tabel 5.16 yaitu Multiple R dan R Square sangat kecil. Hal tersebut menandakan bahwa hubungan antar variabel dan proporsi variabel terikat dan bebas bernilai kecil. Dan nilai RMSE yang tinggi manandakan bahwa error yang besar. Sehingga hasil prediksi yang dihasilkan kurang baik.

Tabel 5. 17 Hasil Regresi Klaster 3

Klaster 3				
No.	Failure		Repair	
	X8	Predicted X8	X9	Predicted X9
1	5	92.76436466	443	396.8212588
2	1491	1338.724241	227	229.5387304
3	72	418.903384	415	475.2404403
4	256	333.2079572	208	295.4554308
5	49	49	277	277
6	291	-68.5999468	457	352.9441397
7	5	5	461	461

Tabel 5. 18 Parameter Hasil Regresi Klaster 3

Klaster 3		
Regression Statistics	Failure	Repair
Multiple R	0.912326898	0.827881669
R Square	0.832340369	0.685388058
Adjusted R Square	-0.00595778	-0.88767165
Standard Error	535.2622149	155.7045484
Observations	7	7
Avg	372.933	355.429
Max	1338.724	475.240
Min	5.000	229.539
Stdev	457.392	86.863
RMSE	202.310	58.851
Avg/Hours	0.00268	0.00281
Distribution:	Weibull	Weibull
Beta:	0.5909	1.8251
Eta:	332.6906	216.4959
Gamma:	-3.6275	168.5633

Berdasarkan hasil regresi klaster 3 pada Tabel 5.18 yaitu Multiple R dan R Square relatif tinggi. Hal tersebut menandakan bahwa hubungan antar variabel dan proporsi variabel terikat dan bebas bernilai besar. Namun nilai RMSE yang tinggi menandakan bahwa error yang besar. Sehingga hasil prediksi yang dihasilkan kurang baik.

Tabel 5. 19 Hasil Regresi Klaster 4

Klaster 4				
No.	Failure		Repair	
	X8	Predicted X8	X9	Predicted X9
1	12	-29.6604614	1	1
2	22	21.07421875	1	1
3	3	59.47290039	1	1
4	16	80.70617676	1	1
5	102	60.05889893	1	1
6	228	263.2219238	1	1
7	3	11.2510376	1	1
8	165	292.8111572	1	1
9	18	90.14434814	1	1
10	288	166.1017456	1	1
11	123	121.0249634	1	1
12	443	315.9274902	1	1
13	27	-2.1350708	1	1

Tabel 5. 20 Parameter Hasil Regresi Klaster 4

Klaster 4		
Regression Statistics	Failure	Repair
Multiple R	0.841094332	0.663598419
R Square	0.707439675	0.440362862
Adjusted R Square	0.122319026	-0.678911414
Standard Error	128.0430565	0
Observations	13	13
Avg	134.7086237	1
Max	315.9274902	1
Min	11.2510376	1
Stdev	104.3660149	0
RMSE	71.026	0.000
Avg/Hours	0.00742	0.00000
Distribution:	Weibull	Weibull
Beta:	0.9878	1.8089
Eta:	718.9994	8.9492
Gamma:	-22.7128	-0.77

Berdasarkan hasil regresi klaster 4 pada Tabel 5.20 yaitu Multiple R dan R Square relatif tinggi. Hal tersebut menandakan bahwa hubungan antar variabel dan proporsi variabel terikat dan bebas bernilai besar. Namun nilai RMSE yang relatif rendah ngenidikasikan bahwa hasil prediksi yang dihasilkan relatif baik.

Tabel 5. 21 Hasil Regresi Klaster 5

Klaster 5				
No.	Failure		Repair	
	X8	Predicted X8	X9	Predicted X9
1	4	218.6042781	5	4.063492858
2	66	356.1938843	14	5.07053143
3	69	138.423878	1	5.526218722
4	77	219.8729214	6	5.576330906
5	168	230.9964048	7	6.302618791
...
23	1320	224.5758271	7	10.39353736
24	40	171.720211	3	5.386019266
25	121	151.7870978	2	5.941240371
26	52	196.4919234	14	13.64589822
27	37	37	5	5

Tabel 5. 22 Parameter Hasil Regresi Klaster 5

Klaster 5		
Regression Statistics	Failure	Repair
Multiple R	0.29446574	0.468311835
R Square	0.086710072	0.219315974
Adjusted R Square	-0.31919656	-0.1276547
Standard Error	327.6697615	4.509938986
Observations	27	27
Avg	203.926	6.037
Max	381.875	13.646
Min	37.000	4.063
Stdev	76.251	1.929
RMSE	269.369	3.694
Avg/Hours	0.00490	0.16564
Distribution:	Weibull	Weibull
Beta:	1.7387	1.5594
Eta:	3703.881	95.2773
Gamma:	-220.8833	-5.4656

Berdasarkan hasil regresi klaster 5 pada Tabel 5.22 yaitu Multiple R dan R Square rendah. Hal tersebut menandakan bahwa hubungan antar variabel dan proporsi variabel terikat dan bebas bernilai besar. Namun nilai RMSE yang relatif tinggi menandakan bahwa error yang besar. Sehingga hasil prediksi yang dihasilkan kurang baik.

5.4. *Maintenance Decision Making*

Pada subbab *maintenance decision making* dilakukan pendekatan prediksi terjadinya *breakdown kiln equipment*. Hasil prediksi akan digunakan untuk membuat penjadwalan berdasarkan *preventive maintenance and replacement models* dalam meminimalkan *downtime* mesin (Usher, et al., 1998).

Menurut (Labib, 2004), alasan mengapa diperlukan *preventive maintenance and replacement models* adalah sebagai berikut.

- Setiap peralatan bekerja di kondisi lingkungan yang berbeda sehingga memerlukan perencanaan jadwal *maintenance* yang berbeda.
- *Machine designers* tidak berpengalaman dalam kegagalan mesin dibandingkan dengan operator yang mengoperasikan mesin
- *Original Equipment Manufacturer (OEM)* memaksimalkan penggantian *spare part* melalui jadwal *maintenance* yang dianjurkan.

BAB 6
PENYUSUNAN REKOMENDASI MAINTENANCE
STRATEGY

6.1 Pengolahan Menggunakan Model Downtime Minimization

Pengolahan menggunakan *model downtime minimization* bertujuan untuk mengurangi *downtime* yang terjadi akibat *breakdown*. *Constant Interval Replacement Policy (CIRP)* merupakan metode yang digunakan untuk melakukan *preventive replacement* dalam interval waktu yang telah ditetapkan. Formula *Constant Interval Replacement Policy (CIRP)* dapat dituliskan Jardine (1973) dan Blanks and Jordan (1986) pada persamaan (6.1) sebagai berikut (Elsayed, 2012)

$$D(t_p) = \frac{M(t_p)T_f + T_p}{T_p + t_p} \dots\dots\dots(6.1)$$

Dimana

$M(t_p)$ = *expected number of failure in the interval (0, t_p)*

T_f = *time to perform a failure replacement*

T_p = *time to perform a preventive replacement*

Nilai dari *expected number of failure* $M(t)$ didapatkan dari model *parametric renewal estimation* menggunakan *continuous time*. Secara umum formula *expected number of failure* $M(t)$ dapat ditulis seperti persamaan 6.2 berikut. (Elsayed, 2012)

$$M(t) = \frac{\lambda\mu}{(\lambda+\mu)} t - \frac{\lambda\mu}{(\lambda+\mu)^2} + \frac{\lambda\mu}{(\lambda+\mu)^2} e^{-(\lambda+\mu)t} \dots\dots\dots(6.2)$$

λ : failure rate (distribution parameter)

μ : repair rate (distribution parameter)

t : time interval

6.1.1 Klaster 1

Penghitungan *constant interval replacement policy* (CIRP) pada klaster 1 menggunakan interval waktu setiap 100 jam sekali. Hal ini dikarenakan data rata-rata terjadinya breakdown sebesar 103 jam sekali. Dan kemudian dilakukan penghitungan hingga interval 2000 jam untuk mengetahui nilai D_{cirp} terkecil. Dimana nilai D_{cirp} akan menjadi interval waktu yang optimum untuk melakukan jadwal *maintenance*.

Tabel 6. 1 CIRP Klaster 1

Downtime Minimization					
The Constant Interval Replacement Policy (CIRP)					
No.	Interval (tp)	Failure Rate	Repair Rate	M(tp)	D_{cirp}(tp)
1	100	9.30419E-05	0.001073761	0.000480649	0.160254948
2	200	0.000109416	0.001695103	0.003300704	0.088422887
3	300	0.000126744	0.002355326	0.010637901	0.063091882
4	400	0.00014499	0.003046414	0.024093092	0.051365847
5	500	0.000164122	0.003763315	0.044208728	0.045489418
6	600	0.000184109	0.004502519	0.070653042	0.042572086
7	700	0.000204928	0.005261431	0.102774473	0.041285225
8	800	0.000226554	0.006038048	0.140064661	0.040967226
9	900	0.000248967	0.00683077	0.182318895	0.041278716
10	1000	0.000272146	0.007638289	0.229575538	0.042038279
11	1100	0.000296074	0.008459511	0.281998525	0.043140986
12	1200	0.000320734	0.00929351	0.339794366	0.044519962
13	1300	0.000346112	0.010139488	0.403174458	0.046128998
14	1400	0.000372191	0.010996748	0.472343558	0.047934423
15	1500	0.00039896	0.011864681	0.547498161	0.049910869
16	1600	0.000426405	0.012742745	0.628827369	0.052038761
17	1700	0.000454515	0.013630456	0.716513988	0.054302702
18	1800	0.000483279	0.014527379	0.810735427	0.05669037
19	1900	0.000512685	0.015433119	0.911664385	0.059191757
20	2000	0.000542724	0.01634732	1.019469387	0.061798624

Hasil penghitungan menggunakan *Constant Interval Replacement Policy* (CIRP) pada klaster 1 didapatkan bahwa terjadi penurunan yang nilai D_{cirp} dari interval waktu 100 hingga 800 jam. Dan kemudian mengalami peningkatan pada interval waktu 900 jam keatas. Sehingga jadwal *maintenance* optimum dapat dilakukan pada setiap 800 jam.

6.1.2 Klaster 2

Penghitungan *constant interval replacement policy* (CIRP) pada klaster 2 menggunakan interval waktu setiap 150 jam sekali. Hal ini dikarenakan data rata-rata terjadinya breakdown sebesar 145 jam sekali. Dan kemudian dilakukan penghitungan hingga interval 3000 jam untuk mengetahui nilai D_{cirp} terkecil. Dimana nilai D_{cirp} akan menjadi interval waktu yang optimum untuk melakukan jadwal *maintenance*.

Tabel 6. 2 CIRP Klaster 2

Downtime Minimization					
The Constant Interval Replacement Policy (CIRP)					
No.	Interval (tp)	Failure Rate	Repair Rate	M(tp)	D_{cirp}(tp)
1	150	2.89635E-05	0.000631954	0.000199	0.088474
2	300	3.21072E-05	0.000879532	0.001162	0.046726
3	450	3.51816E-05	0.001086427	0.003293	0.032307
4	600	3.81953E-05	0.001269322	0.00683	0.02526
5	750	4.11554E-05	0.001435773	0.011865	0.021264
6	900	4.40673E-05	0.001589998	0.01838	0.018815
7	1050	4.69356E-05	0.00173464	0.026284	0.017246
8	1200	4.97641E-05	0.001871496	0.035455	0.016217
9	1350	5.25562E-05	0.002001851	0.045765	0.015536
10	1500	5.53146E-05	0.002126665	0.057097	0.015088
11	1650	5.80418E-05	0.002246679	0.069355	0.014802
12	1800	6.07398E-05	0.002362478	0.082465	0.014631
13	1950	6.34105E-05	0.002474535	0.096373	0.014546
14	2100	6.60557E-05	0.002583239	0.11104	0.014526
15	2250	6.86767E-05	0.002688914	0.126439	0.014555
16	2400	7.12749E-05	0.002791835	0.142552	0.014623
17	2550	7.38516E-05	0.002892235	0.159366	0.014724
18	2700	7.64078E-05	0.002990316	0.176873	0.014851
19	2850	7.89444E-05	0.003086254	0.195064	0.014999
20	3000	8.14625E-05	0.003180204	0.213933	0.015165

Hasil penghitungan menggunakan *Constant Interval Replacement Policy* (CIRP) pada klaster 2 didapatkan bahwa terjadi penurunan yang nilai D_{cirp} dari interval waktu 150 hingga 2100 jam. Dan kemudian mengalami peningkatan pada interval waktu 2250 jam keatas. Sehingga jadwal *maintenance* optimum dapat dilakukan pada setiap 2100 jam.

6.1.3 Kluster 3

Penghitungan *constant interval replacement policy* (CIRP) pada kluster 3 menggunakan interval waktu setiap 170 jam sekali. Hal ini dikarenakan data rata-rata terjadinya breakdown sebesar 372 jam sekali. Dan kemudian dilakukan penghitungan hingga interval 265 jam untuk mengetahui nilai D_{cirp} terkecil. Dimana nilai D_{cirp} akan menjadi interval waktu yang optimum untuk melakukan jadwal *maintenance*.

Tabel 6. 3 CIRP Kluster 3

Downtime Minimization					
The Constant Interval Replacement Policy (CIRP)					
No.	Interval (tp)	Failure Rate	Repair Rate	M(tp)	D_{cirp}(tp)
1	170	0.00231746	0.000134493	0.003938166	0.679249786
2	175	0.0022907	0.000463538	0.013933663	0.679874573
3	180	0.002264975	0.000744837	0.022996621	0.679838166
4	185	0.002240218	0.001004676	0.031838619	0.679649953
5	190	0.002216369	0.001250823	0.040646712	0.67944201
6	195	0.002193372	0.001487033	0.049497725	0.679266924
7	200	0.002171177	0.001715508	0.058427076	0.679147589
8	205	0.002149737	0.001937686	0.067450559	0.679093023
9	210	0.002129009	0.002154577	0.07657338	0.679104941
10	215	0.002108954	0.002366926	0.08579455	0.679180949
11	220	0.002089534	0.002575306	0.095109277	0.679316269
12	225	0.002070717	0.002780167	0.10451038	0.679504756
13	230	0.002052471	0.002981874	0.113989173	0.679739514
14	235	0.002034767	0.003180727	0.123536052	0.680013301
15	240	0.002017579	0.003376976	0.133140895	0.680318795
16	245	0.00200088	0.003570836	0.142793351	0.680648773
17	250	0.001984648	0.003762488	0.152483044	0.680996239
18	255	0.001968861	0.003952093	0.162199727	0.681354501
19	260	0.001953498	0.004139787	0.171933396	0.681717236
20	265	0.00193854	0.004325694	0.181674378	0.682078519

Hasil penghitungan menggunakan *Constant Interval Replacement Policy* (CIRP) pada kluster 3 didapatkan bahwa terjadi penurunan yang nilai D_{cirp} dari interval waktu 170 hingga 205 jam. Dan kemudian mengalami peningkatan pada interval waktu 210 jam keatas. Sehingga jadwal *maintenance* optimum dapat dilakukan pada setiap 205 jam.

6.1.4 Klaster 4

Penghitungan *constant interval replacement policy* (CIRP) pada klaster 4 menggunakan interval waktu setiap 2 jam sekali. Hal ini dikarenakan data rata-rata terjadinya breakdown sebesar 134 jam sekali. Dan kemudian dilakukan penghitungan hingga interval 40 jam untuk mengetahui nilai Dcirp terkecil. Dimana nilai Dcirp akan menjadi interval waktu yang optimum untuk melakukan jadwal *maintenance*.

Tabel 6. 4 CIRP Klaster 4

Downtime Minimization					
The Constant Interval Replacement Policy (CIRP)					
No.	Interval (tp)	Failure Rate	Repair Rate	M(tp)	Dcirp(tp)
1	2	0.001431525	0.07828057	0.000212671	0.342882873
2	4	0.001430167	0.121502611	0.001187759	0.232000275
3	6	0.001428907	0.161285479	0.00307266	0.201987684
4	8	0.001427734	0.198849483	0.00568833	0.196251902
5	10	0.001426635	0.234796369	0.008742841	0.197976013
6	12	0.001425603	0.269482092	0.011985372	0.20111792
7	14	0.001424629	0.30314051	0.015261302	0.203721931
8	16	0.001423707	0.335936264	0.018499876	0.205417227
9	18	0.001422833	0.367991125	0.021680555	0.206345142
10	20	0.001422001	0.399398543	0.024805143	0.206736511
11	22	0.001421207	0.430232337	0.027882224	0.206781564
12	24	0.001420448	0.460552178	0.030920696	0.206611379
13	26	0.001419722	0.490407227	0.033927932	0.206310556
14	28	0.001419025	0.519838629	0.036909646	0.205932676
15	30	0.001418356	0.548881289	0.039870223	0.205511706
16	32	0.001417712	0.57756516	0.042813057	0.205069332
17	34	0.001417091	0.605916206	0.04574081	0.204619473
18	36	0.001416492	0.633957131	0.048655604	0.204171066
19	38	0.001415913	0.661707943	0.051559151	0.203729803
20	40	0.001415353	0.689186395	0.054452852	0.203299238

Hasil penghitungan menggunakan *Constant Interval Replacement Policy* (CIRP) pada klaster 4 didapatkan bahwa terjadi penurunan yang nilai Dcirp dari interval waktu 2 hingga 8 jam. Dan kemudian mengalami peningkatan pada interval waktu 10 jam keatas. Sehingga jadwal *maintenance* optimum dapat dilakukan pada setiap 8 jam.

6.1.5 *Klaster 5*

Penghitungan *constant interval replacement policy* (CIRP) pada klaster 5 menggunakan interval waktu setiap 25 jam sekali. Hal ini dikarenakan data rata-rata terjadinya breakdown sebesar 203 jam sekali. Dan kemudian dilakukan penghitungan hingga interval 500 jam untuk mengetahui nilai *Dcirp* terkecil. Dimana nilai *Dcirp* akan menjadi interval waktu yang optimum untuk melakukan jadwal *maintenance*.

Tabel 6. 5 CIRP Klaster 5

<i>Downtime Minimization</i>					
<i>The Constant Interval Replacement Policy (CIRP)</i>					
<i>No.</i>	<i>Interval (tp)</i>	<i>Failure Rate</i>	<i>Repair Rate</i>	<i>M(tp)</i>	<i>Dcirp(tp)</i>
1	25	6.33042E-05	0.008648973	0.000159325	0.195557567
2	50	6.79981E-05	0.012092839	0.000847711	0.110817908
3	75	7.25801E-05	0.01489086	0.002161525	0.079936633
4	100	7.70618E-05	0.017324057	0.004036885	0.064696852
5	125	8.14532E-05	0.019513262	0.006357165	0.055964543
6	150	8.57623E-05	0.021523933	0.00901493	0.050471446
7	175	8.99961E-05	0.023396368	0.011934427	0.046790294
8	200	9.41605E-05	0.02515751	0.015070708	0.044217027
9	225	9.82608E-05	0.026826453	0.018400357	0.042371332
10	250	0.000102301	0.028417322	0.021912294	0.041031258
11	275	0.000106286	0.029940927	0.025601466	0.040058207
12	300	0.000110219	0.03140576	0.029465349	0.039360548
13	325	0.000114103	0.032818643	0.033502287	0.038874871
14	350	0.00011794	0.034185156	0.037710837	0.038555692
15	375	0.000121734	0.035509931	0.042089547	0.038369464
16	400	0.000125487	0.036796869	0.046636915	0.038290874
17	425	0.0001292	0.038049291	0.051351406	0.038300467
18	450	0.000132875	0.039270049	0.056231471	0.038383049
19	475	0.000136516	0.040461622	0.061275569	0.038526585
20	500	0.000140122	0.041626172	0.06648218	0.038721429

Hasil penghitungan menggunakan *Constant Interval Replacement Policy* (CIRP) pada klaster 4 didapatkan bahwa terjadi penurunan yang nilai *Dcirp* dari interval waktu 25 hingga 400 jam. Dan kemudian mengalami peningkatan pada interval waktu 425 jam keatas. Sehingga jadwal *maintenance* optimum dapat dilakukan pada setiap 400 jam.

6.2 Evaluasi Rekomendasi *Maintenance Strategy*

Pada subbab ini akan dijelaskan terkait evaluasi hasil k-means clustering, evaluasi hasil nonlinear regression, dan evaluasi hasil rekomendasi *maintenance strategy*.

6.2.1 Evaluasi Hasil K-Means Clustering

Dengan menggunakan *software* Matlab sangat berdampak pada lama waktu pemrosesan data menggunakan teknik *k-means clustering*. Untuk mendapatkan hasil yang optimal diperlukan metode penghitungan nilai optimal dalam menentukan jumlah klaster dan jumlah iterasi. Metode yang digunakan dapat berupa *elbow method* dengan nilai *sum of square error* (SSE) dan *silhouette index*.

Tabel 6. 6 Failure Time Parameter

Klaster	Failure Time			
	Avg	Max	Min	Stdev
1	101.122	520	1	123.120
2	145.782	1021	1	170.730
3	309.857	1491	5	494.087
4	111.538	443	3	131.313
5	203.926	1320	4	279.954

Tabel 6. 7 Repair Time Parameter

Klaster	Repair Time			
	Avg	Max	Min	Stdev
1	19.024	166	1	35.818
2	14.527	145	1	23,65
3	355.429	461	208	104.922
4	1	1	1	0
5	6.037	16	1	4.168

Teknik *k-means clustering* menghasilkan 5 klaster data berdasarkan tingkat keparahan dari *breakdown*. Data pada Tabel 6.6 dan Tabel 6.7 menunjukkan karakteristik data klaster dibagi menjadi 3 kategori berdasarkan *failure time* dan *repair time*. Kategori yang pertama yaitu *breakdown berat* ditemukan pada klaster 3. Hal ini disebabkan oleh nilai rata-rata *failure time* dan *repair time* tertinggi diantara klaster lainnya yaitu sebesar 309,85 jam dan 355,43 jam. Selanjutnya

kategori yang kedua yaitu breakdown ringan ditemukan pada klaster 4. Hal ini disebabkan oleh nilai rata-rata *failure time* dan *repair time* terendah diantara klaster lainnya yaitu sebesar 111,54 jam dan 1 jam. Kemudian kategori yang ketiga yaitu breakdown sedang. Kategori breakdown sedang ini dibagi menjadi 3 tingkatan. Tingkatan berat terjadi pada klaster 1. Tingkatan sedang terjadi pada klaster 2. Tingkatan ringan terjadi pada klaster 5. Namun standar deviasi yang dihasilkan masih tinggi. Hal ini mengindikasikan bahwa proses klustering menggunakan data sensor menghasilkan klaster data yang masih memiliki *range* data yang tinggi.

Kemudian didapatkan *threshold* baru hasil data klaster. Bentuk dari *threshold* baru ini berupa centeroid masing-masing klaster. *Threshold* tersebut akan digunakan ketika terdapat data sensor baru yang masuk. Jenis klasternya data sensor baru dapat diketahui menggunakan *threshold* baru hasil data klaster. *Threshold* baru data klaster yang dapat dilihat pada Tabel 6.8 sebagai berikut.


Tabel 6. 8 New Threshold

Klaster	Threshold						
	X1	X2	X3	X4	X5	X6	X7
1	418.134	0.000	0.000	6.835	835.923	0.181	2.860
2	403.460	0.000	0.000	9.743	772.128	0.112	0.013
3	439.214	0.000	0.000	0.000	787.815	0.114	1.101
4	825.508	590.787	440.660	273.060	423.455	0.077	2.338
5	0.000	0.000	0.000	9.598	771.089	0.092	0.111


Data sensor baru akan diklasifikasikan menggunakan *threshold* untuk mengetahui klaster yang sesuai. Dengan cara menghitung jarak kedekatan data sensor baru dengan *threshold* baru dari klaster yang telah terbentuk. Jarak kedekatan antar data dengan *threshold* menggunakan jarak Euclidean. Jika jarak data sensor dengan salah satu *threshold* berdekatan maka data sensor baru tersebut masuk kedalam klaster tersebut. Label klaster untuk data sensor baru masih sama menggunakan label dari hasil klustering. Dimana untuk klaster 3 merupakan data sensor dengan kerusakan berat. Klaster 4 untuk data sensor dengan kerusakan ringan. Dan klaster 1,2, dan 5 merupakan klaster dengan kerusakan sedang.

6.2.2 Evaluasi Hasil Nonlinear Regression

Pengolahan model *nonlinear regression* menggunakan *tools data analytics* dari Microsoft Excel. Model *nonlinear regression* dilakukan untuk mendapatkan hasil prediksi dari *time to failure* dan *time to repair*. Hasil prediksi menghasilkan parameter berupa distribusi Weibull. Dimana terdapat parameter Beta, parameter Eta, dan parameter Gamma. Dan hasil penghitungan *root mean square error* (RMSE) untuk mengetahui sebaik mana hasil regresinya.




Gambar 6. 1 Failure Time Klaster 1




Gambar 6. 2 Repair Time Klaster 1

Berdasarkan Gambar 6.1 dan Gambar 6.2 yaitu *failure time* dan *repair time* didapatkan bahwa hasil prediksi pada klaster 1 memiliki kecenderungan data yang memiliki standar deviasi yang kecil. Hal ini berbanding dengan data klaster yang memiliki kecenderungan standar deviasi yang tinggi. Hal ini juga dapat terlihat pada hasil penghitungan *root mean square error* (RMSE) yang tinggi yaitu sebesar 117,86 untuk *failure time* dan 35,3 untuk *repair time*. Sehingga dapat menyebabkan hasil prediksi pada klaster 1 menjadi kurang akurat.




Gambar 6. 3 Failure Time Klaster 2




Gambar 6. 4 Repair Time Klaster 2

Berdasarkan Gambar 6.3 dan Gambar 6.4 yaitu *failure time* dan *repair time* didapatkan bahwa hasil prediksi pada kluster 2 memiliki kecenderungan data yang memiliki standar deviasi yang kecil. Hal ini berbanding dengan data kluster yang memiliki kecenderungan standar deviasi yang tinggi. Hal ini juga dapat terlihat pada hasil penghitungan *root mean square error* (RMSE) yang tinggi yaitu sebesar 168,967 untuk *failure time* dan 23,482 untuk *repair time*. Sehingga dapat menyebabkan hasil prediksi pada kluster 2 menjadi kurang akurat.




Gambar 6. 5 Failure Time Kluster 3




Gambar 6. 6 Repair Time Kluster 3

Berdasarkan Gambar 6.4 dan Gambar 6.6 yaitu *failure time* dan *repair time* didapatkan bahwa hasil prediksi pada klaster 3 memiliki kecenderungan data yang memiliki standar deviasi yang besar. Hal ini sebanding dengan data klaster yang memiliki kecenderungan standar deviasi yang tinggi. Hal ini juga dapat terlihat pada hasil penghitungan *root mean square error* (RMSE) yang tinggi yaitu sebesar 202,31 untuk *failure time* dan 58,85 untuk *repair time*. Sehingga dapat menyebabkan hasil prediksi pada klaster 3 menjadi kurang akurat.




Gambar 6. 7 Failure Time Klaster 4

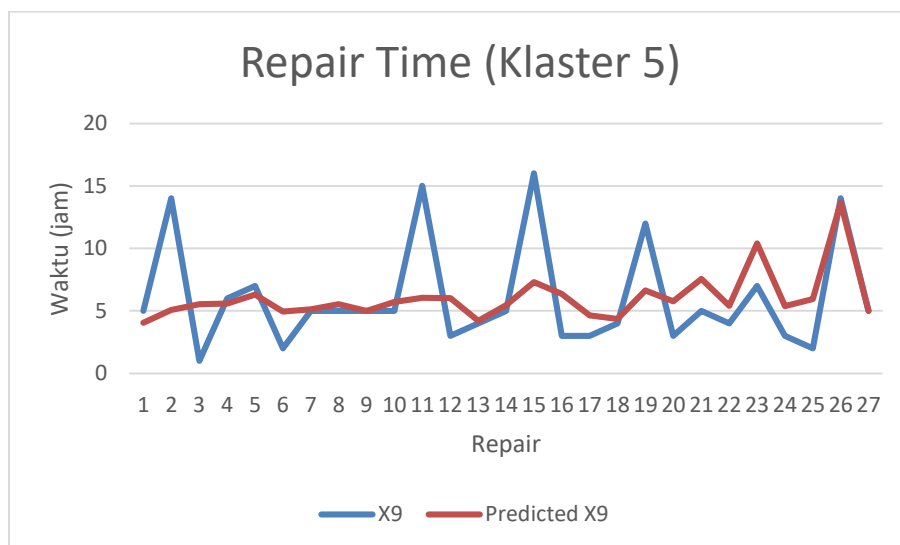


Gambar 6. 8 Repair Time Klaster 4

Berdasarkan Gambar 6.7 dan Gambar 6.8 yaitu *failure time* dan *repair time* didapatkan bahwa hasil prediksi pada klaster 4 memiliki kecenderungan data yang memiliki standar deviasi yang kecil. Hal ini berbanding dengan data klaster yang memiliki kecenderungan standar deviasi yang tinggi. Hal ini juga dapat terlihat pada hasil penghitungan *root mean square error* (RMSE) yang tinggi yaitu sebesar 71,026 untuk *failure time* dan 0 untuk *repair time*. Sehingga dapat menyebabkan hasil prediksi pada klaster 4 menjadi kurang akurat.



Gambar 6. 9 Failure Rate Klaster 5




Gambar 6. 10 Repair Rate Klaster 5

Berdasarkan Gambar 6.9 dan Gambar 6.10 yaitu *failure time* dan *repair time* didapatkan bahwa hasil prediksi pada klaster 5 memiliki kecenderungan data yang memiliki standar deviasi yang kecil. Hal ini berbanding dengan data klaster yang memiliki kecenderungan standar deviasi yang tinggi. Hal ini juga dapat terlihat pada hasil penghitungan *root mean square error* (RMSE) yang tinggi yaitu sebesar 269,37 untuk *failure time* dan 3,694 untuk *repair time*. Sehingga dapat menyebabkan hasil prediksi pada klaster 5 menjadi kurang akurat.

Data hasil prediksi yang kurang akurat tersebut disebabkan oleh pemilihan data sensor yang kurang tepat. Pemilihan data sensor tersebut berdasarkan frekuensi data sensor dalam mendeteksi *breakdown*. Agar dapat menghasilkan data prediksi yang akurat diperlukan data sensor dengan melihat hubungan antar data sensor. Sehingga data sensor sebagai variabel bebas dapat menghasilkan variabel respon yang memiliki kecenderungan keterikatan yang tinggi.

6.3.1. Evaluasi Hasil Rekomendasi Maintenance Strategy

Data hasil prediksi digunakan untuk merancang rekomendasi *maintenance strategy*. Metode yang digunakan yaitu *constant interval replacement policy* (CIRP). Metode tersebut bertujuan untuk meminimalkan terjadinya *downtime* melalui perancangan jadwal *maintenance* yang optimal.



Gambar 6. 11 Jadwal Maintenance

Hasil perancangan *maintenance strategy* yang optimal didapat seperti pada Gambar 6.11 sebagai berikut. Jadwal *maintenance* yang didapatkan berbeda-beda

berdasarkan nilai dari *failure rate* dan *repair rate*. Sehingga didapatkan lima jadwal *maintenance* berdasarkan klaster.

Klaster dengan *breakdown* berat yaitu klaster 3 mendapatkan jadwal *maintenance* pada interval 205 jam. Hal ini dikarenakan untuk mencegah kerusakan yang lebih parah. Kemudian klaster dengan *breakdown* ringan yaitu klster 4 mendapatkan jadwal *maintenance* pada interval 8 jam. Hal ini bertujuan untuk mencegah terjadinya kerusakan dengan melakukan monitoring. Sedangkan klaster dengan *breakdown* sedang yaitu klaster 1, klaster 2, dan klaster 5 mendapatkan jadwal *maintenance* secara berturut-turut 800 jam, 2100 jam, dan 400 jam.

Berdasarkan hasil wawancara dengan pihak perusahaan, beberapa jadwal tersebut telah sesuai dengan kondisi interval *failure* di perusahaan (Yasin, 2020). Namun jadwal pada klaser 2 yaitu sebesar 2100 jam dirasa kurang sesuai. Hal ini dikarenakan interval *failure* tertinggi yang terjadi selama 2 bulan atau sekitar 1476 jam pada 2016. Dan rata-rata interval *failure* yang terjadi yaitu selama 28 hari atau sekitar 672 jam. Serta data yang terbaru pada tahun 2019 memiliki interval *failure* tertinggi sebesar 1420 jam. Sehingga untuk jadwal *maintenance* pada interval 2100 tidak sesuai karena tidak akan memberikan dampak yang signifikan dalam meminimalkan *downtime*.

Hasil yang tidak akurat tersebut dapat disebabkan oleh beberapa faktor. Faktor yang pertama adalah pemilihan data sensor yang salah. Pemilihan data sensor tersebut berdasarkan frekuensi data sensor dalam mendeteksi *breakdown*. Seharusnya pemilihan data sensor berdasarkan hubungan antar data untuk menghasilkan data klaster yang baik. Sehingga dapat menghasilkan data prediksi yang akurat. Selanjutnya data sensor yang digunakan telah mendapatkan intervensi dari sistem maupun operator. Sehingga sulit untuk mengetahui kondisi perilaku mesin yang sebenarnya.

(Halaman ini Sengaja Dikosongkan)

BAB 7

KESIMPULAN DAN SARAN

Pada bab ini dijelaskan mengenai hasil kesimpulan penelitian tugas akhir dan juga disertai dengan pemberian saran kepada perusahaan dan pengembangan penelitian selanjutnya.

7.1. Kesimpulan

Kesimpulan yang dapat diambil dari penelitian ini adalah sebagai berikut.

1. Kondisi terjadinya *breakdown* pada *kiln equipment* dapat dideteksi oleh tujuh peralatan sensor. Tujuh peralatan sensor tersebut terpasang pada masing-masing peralatan. Ketika hasil pembacaan dari data sensor terindikasi berada dibawah *threshold* maka berada kondisi *failure*. Kemudian hasil pembacaan data sensor tersebut kemudian diintegrasikan dengan hasil pembacaan data sensor keenam peralatan lainnya untuk dibandingkan dengan regulasi *kiln equipment*. Jika hasil yang dicapai tidak memenuhi regulasi maka dapat disimpulkan bahwa sedang terjadi *breakdown* pada *kiln equipment*.
2. Pada regulasi *kiln equipment* yang menyebutkan 128 kondisi yang terdiri dari 5 kondisi operasi dan 123 kondisi *breakdown*. Berdasarkan regulasi tersebut ditemukan 198 *breakdown* pada periode tahun 2015 hingga 2018. Kemudian dengan menggunakan teknik *k-means clustering* didapatkan 5 klaster kondisi *breakdown* berdasarkan data sensor saat failure beserta data *time to failure* (TTF) dan *time to repair* (TTR). Klaster 3 merupakan klaster data sensor yang mengindikasikan tingkat *breakdown* berat. Hal ini dapat dilihat melalui nilai rata-rata TTF dan TTR tertinggi yaitu 309,85 jam dan 355,43 jam. Dan klaster 4 merupakan klaster data sensor yang mengindikasikan tingkat *breakdown* ringan. Dengan nilai rata-rata TTF dan TTR yang terendah yaitu 11,53 jam dan 1 jam. Sedangkan klaster 1, klaster 2 dan klaster 5 merupakan klaster data sensor yang mengindikasikan tingkat *breakdown* sedang.

3. Proses prediksi *breakdown* menggunakan lima klaster data sensor dilakukan dengan model *nonlinear regression*. Hasilnya berupa klaster 3 masih menjadi klaster data sensor yang mengindikasikan tingkat *breakdown* berat. Dengan nilai rata-rata TTF dan TTR tertinggi yaitu 372,93 jam dan 355,42 jam. Dan klaster 4 juga masih menjadi klaster data sensor yang mengindikasikan tingkat *breakdown* ringan. Dimana nilai rata-rata TTF dan TTR yang terendah yaitu 134,7 jam dan 1 jam. Sedangkan klaster 1, klaster 2 dan klaster 5 masih tetap menjadi klaster data sensor yang mengindikasikan tingkat *breakdown* sedang. Hasil prediksi dari klaster data sensor akan digunakan untuk menentukan *maintenance strategy* yang tepat.
4. Perancangan *maintenance strategy* menggunakan *preventive maintenance and replacement model* bertujuan untuk meminimalkan downtime. Metode yang digunakan yaitu *the constant interval replacement policy (CIRP)* dengan cara perancangan penjadwalan *maintenance* berdasarkan interval waktu. Jadwal *maintenance* yang optimum didapatkan melalui hasil penghitungan nilai D_{cirp} paling minimum. Nilai D_{cirp} dipengaruhi oleh *failure rate* dan *repair rate*. Jadwal *maintenance* optimum untuk klaster 1, klaster 2, klaster 3, klaster 4, dan klaster 5 secara berturut-turut adalah 800 jam, 2100 jam, 205 jam, 8 jam, dan 400 jam.

7.2. Saran

Saran yang dapat diberikan untuk perusahaan dan pengembangan penelitian selanjutnya adalah sebagai berikut.

7.2.1. Saran bagi Perusahaan

Saran yang diberikan kepada perusahaan adalah sebagai berikut.

1. Proses operasi mesin di perusahaan dapat dilakukan tanpa intervensi tindakan preventive dari sistem atau operator untuk menjamin kebenaran data sensor dalam membaca kondisi peralatan.
2. Proses penerapan *maintenance strategy* yang telah dibuat dapat dilakukan secara berkelanjutan dan selalu menggunakan data yang telah diperbarui.

Hal tersebut bertujuan untuk mendapatkan hasil yang lebih akurat untuk meminimalkan *downtime*.

7.2.2. *Saran bagi Pengembangan Penelitian Selanjutnya*

Saran yang diberikan kepada pengembangan penelitian selanjutnya adalah sebagai berikut.

1. Penelitian selanjutnya dapat menggunakan data sensor tanpa intervensi dari sistem maupun operator. Sehingga akan menghasilkan data yang lebih akurat.
2. Penelitian selanjutnya dapat menggunakan data sensor dengan interval waktu yang lebih singkat. Hal ini bertujuan untuk mendapatkan hasil yang lebih akurat.
3. Penelitian selanjutnya dapat menggunakan jenis data sensor yang lebih lengkap. Sehingga dapat mengetahui hubungan antar jenis data sensor untuk mendapatkan hasil prediksi yang lebih baik.
4. Penelitian selanjutnya dapat dilakukan dengan metode klasifikasi dan regresi untuk data analytics pada *condition based maintenance*.

(Halaman ini Sengaja Dikosongkan)

DAFTAR PUSTAKA

- Anonymous, 2020. *Laporan PT Semen Tonasa*, Makasar: Semen Tonasa.
- Barros, M., Bello, P., Bao, M. & Torrado, J., 2009. From Waste to Commodity: Transforming Shells into High Purity Calcium Caronate. *Journal of Cleaner Production, Elsevier*, Issue 17, pp. 400-407.
- Djurdjanovic, D., Lee, J. & Ni, J., 2003. Watchdog Agent - An Infotronics Based Prognostics Approach for Product Performance Degradation Assessment and Prediction. *Elsevier*, Volume 17, pp. 109-125 No.3-4.
- Elsayed, A. E., 2012. *Reliability Engineering*. Hoboken, New Jersey: John Wiley & Sons, Inc..
- Gasperz, V., 1992. *Analisa Sistem Terapan Beerdasarkan Pendekatan Teknik Industri*. Bandung: Tarsito.
- Gupta, A. & Lawsirirat, C., 2006. Strategically Optimum Maintenance of Monitoring Enabled Multi-Component Systems Using Continuous-Time Jump Deterioration Models. *Jurnal of Quality in Maintenance Engineering*, Issue 12(3), pp. 306-329.
- Hwang, H. J., Lee, J. H., Hwang, J. S. & Jun, H. B., 2018. A Study of Development of a Condition Based Maintenance System for an LNG FPSO. *Elsevier*, pp. 604-615.
- Kanika, G., Bernard, S. & Amos, H. N., 2018. Toward Data Mining Based Decision Support in Manufacturing Maintenance. *Elsevier*, Issue 72, pp. 261-265.
- KBBI, 2012. *Semen*. [Online]
Available at: <https://kbbi.kemdikbud.go.id/>
[Accessed 09 February 2020].
- Labib, A., 2004. A Decision Analysis Model for Condition Based Maintenance Policy Selection Using a CMMS. *Journal of Quality in Maintenance Engineering*, Issue 10(3), pp. 191-202.
- Myhre, B., Petersen, S. & Ugarelli, R., 2014. Using Wireless Vibration Monitoring to Enable Condition-Based Maintenance of Rotating Machinery in the Water and Wastewater Industries. *Elsevier*, Issue 89, pp. 1397-1403.
- Nilda, T. P., Taufik & Filly, S. B., 2020. Preventive Maintenance Scheduling by

- Modularity Design Applied to Limestone Crusher Machine. *Elsevier*, Issue 43, pp. 682-687.
- Piatetsky, G. & Shapiro, 2006. *An Introduction: Machine Learning, Data Mining, and Knowledge Discovery*. s.l.:KDnuggets.
- Rastegrari, A., 2017. *Condition Based Maintenance in the Manufacturing Industry From Strategy to Implementation*, Eskilstuna: Malardalen University Press Dissertations.
- Riccardo, A. et al., 2017. Data Mining and Machine Learning for Condition-Based Maintenance. *Elsevier*, pp. 1153-1161.
- Sanjay, K. et al., 2018. Condition Based Maintenance of Bearing and Gears for Fault Detection - A Review. *Elsevier*, pp. 6128-6137.
- Santosa, B. & Umam, A., 2018. *Data Mining dan Big Data Analytics*. Yogyakarta: Penebar Media Pustaka.
- Selcuk, O. & Fuat, S., 2019. A New Model Based on Artificial Bee Colony Algorithm for Preventive Maintenance with Replacement Scheduling in Continuous Production Lines. *Elsevier*, Issue 22, pp. 1175-1186.
- Sreenivasulu, A. & P. Chenna, R., 2020. NLDA Non-Linear Regression Model for Preserving Data Privacy in Wireless Sensor Networks. *Digital Communication and Networks*, Issue 6, pp. 101-107.
- Usher, S., Kamal, A. & Syed, W., 1998. Cost Optimal Preventive Maintenance and Replacement Scheduling. *IEEE Transactions*, Issue 30, pp. 1121-1128.
- Vorne, 2019. *World Class OEE*. [Online]
Available at: www.oee.com
[Accessed 28 February 2020].
- Wei, Y., Hua, L., Lihua, M. & Huifang, S., 2020. Research on Clustering Method Based on Weighted Distance Density and K-Means. *Elsevier*, Issue 166, pp. 507-511.
- Winter, N. B., 2005. *Understanding Cement*, Rendlesham: WHD Microanalysis Consultants Ltd..
- Woo, S., 2020. Modern Definition in Reliability Engineering. *ResearchGate*.
- Yang, Z. et al., 2020. A Review of Data Mining Technologies in Building Energy Systems: Load Prediction, Pattern Identification, Fault Detection and

Diagnosis. *Elsevier*, Issue 1, pp. 149-164.

Yasin, I., 2020. *Sensor Mesin Kiln* [Interview] (January 2020).

(Halaman ini Sengaja Dikosongkan)

LAMPIRAN 1

SCALING CODE IN MATLAB

```
function failurescaling = scalingfailure(failure,LL,UL)
%input

[dataMax]=max(failure);
[dataMin]=min(failure);
[R,C]=size(failure);
failurescaling = (failure-ones(R,1)*dataMin).*(ones(R,1)*(UL-
LL)*(ones(1,C)./(dataMax-dataMin)))+LL;
```

(Halaman ini Sengaja dikosongkan)

LAMPIRAN 2

K-MEANS CODE IN MATLAB

K-Means Clustering

```
function [cluster,centres] = kmeans(k,data,niters)
```

```
%input
```

```
[ndata, data_dim]=size(data);
```

```
ncentres=k;
```

```
if (ncentres > ndata)
```

```
    error('Jumlah klaster melebihi data')
```

```
end
```

```
%menentukan pusat klaster secara random
```

```
perm=randperm(ndata);
```

```
indpusat=perm(1:ncentres);
```

```
centres=data(indpusat,:);
```

```
%loop utama
```

```
for n = 1:niters
```

```
    %menyimpan pusat lama klaster
```

```
    pusatlama = centres;
```

```
    %menghitung jarak data dengan pusat klaster
```

```
    jarak = distance(data,centres);
```

```
    %menugaskan data ke klaster terdekat
```

```
    [minvals,ind] = min(jarak,[],2);
```

```
    %mencari banyak titik data yg masuk kelas j
```

```
    post = accumarray(ind,1,[k,1]);
```

```
    cluster = ind;
```

```
for j = 1:ncentres
```

```

    if(post(j) > 0)
        %mencari pusat klaster baru
        centres(j,:) = sum(data(find(ind==j),:))/post(j);
    end
end

change=sum(sum(abs(pusatlama-centres)));
%menandakan kalster telah konvergen
if change < 1e-10
    break
end
end

function jarak = distance(data,centres)
ndata = size(data,1);
ncentres = size(centres,1);
jarak = zeros(ndata,ncentres);
for j = 1:ncentres
    jarak(:,j) = sum((data-repmat(centres(j,:),ndata,1)).^2,2);
end

```

Silhouette Index

```
[s,h]=silhouette(scaling,cluster,'sqEuclidean')
```


LAMPIRAN 3

CLUSTER CENTEROID

Centeroid 1

Iterasi	Klaster	Centeroid 2 Klaster								
		X1	X2	X3	X4	X5	X6	X7	X8	X9
5	1	0.32	0.00	0.00	0.01	0.80	0.04	0.05	0.10	0.06
	2	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
20	1	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
	2	0.32	0.00	0.00	0.01	0.80	0.04	0.05	0.10	0.06
100	1	0.32	0.00	0.00	0.01	0.80	0.04	0.05	0.10	0.06
	2	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00

Centeroid 2

Iterasi	Klaster	Centeroid 3 Klaster								
		X1	X2	X3	X4	X5	X6	X7	X8	X9
5	1	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
	2	0.00	0.00	0.00	0.02	0.79	0.03	0.01	0.14	0.01
	3	0.37	0.00	0.00	0.01	0.81	0.04	0.06	0.09	0.06
20	1	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
	2	0.37	0.00	0.00	0.01	0.81	0.04	0.06	0.09	0.06
	3	0.00	0.00	0.00	0.02	0.79	0.03	0.01	0.14	0.01
100	1	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
	2	0.37	0.00	0.00	0.01	0.81	0.04	0.06	0.09	0.06
	3	0.00	0.00	0.00	0.02	0.79	0.03	0.01	0.14	0.01

Centeroid 3

Iterasi	Klaster	Centeroid 4 Klaster								
		X1	X2	X3	X4	X5	X6	X7	X8	X9
5	1	0.00	0.00	0.00	0.02	0.78	0.03	0.01	0.11	0.01
	2	0.35	0.00	0.00	0.02	0.82	0.03	0.04	0.31	0.09
	3	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
	4	0.37	0.00	0.00	0.01	0.80	0.05	0.06	0.05	0.06
20	1	0.40	0.00	0.00	0.00	0.80	0.04	0.08	0.21	0.77
	2	0.26	0.00	0.00	0.02	0.80	0.03	0.00	0.10	0.03
	3	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
	4	0.43	0.00	0.00	0.01	0.82	0.06	0.16	0.08	0.04
100	1	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
	2	0.27	0.00	0.00	0.03	0.82	0.03	0.04	0.42	0.07
	3	0.37	0.00	0.00	0.01	0.81	0.04	0.06	0.07	0.03
	4	0.09	0.00	0.00	0.01	0.78	0.03	0.03	0.06	0.19

Centeroid 4

Iterasi	Klaster	Centeroid 5 Klaster								
		X1	X2	X3	X4	X5	X6	X7	X8	X9
5	1	0.82	0.69	0.27	0.00	0.00	0.00	0.00	0.12	0.00
	2	0.00	0.00	0.00	0.02	0.79	0.03	0.01	0.14	0.01
	3	0.70	0.82	0.83	0.76	0.70	0.04	0.28	0.04	0.00
	4	0.36	0.00	0.00	0.02	0.80	0.04	0.00	0.10	0.07
	5	0.38	0.00	0.00	0.01	0.85	0.06	0.22	0.07	0.06
20	1	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
	2	0.36	0.00	0.00	0.02	0.82	0.04	0.06	0.09	0.03
	3	0.54	0.00	0.00	0.00	0.00	0.00	0.00	0.13	0.00
	4	0.40	0.00	0.00	0.00	0.80	0.04	0.08	0.21	0.77
	5	0.00	0.00	0.00	0.02	0.82	0.03	0.01	0.13	0.01
100	1	0.38	0.00	0.00	0.01	0.85	0.06	0.21	0.07	0.04
	2	0.37	0.00	0.00	0.02	0.79	0.04	0.00	0.10	0.03
	3	0.40	0.00	0.00	0.00	0.80	0.04	0.08	0.21	0.77
	4	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
	5	0.00	0.00	0.00	0.02	0.79	0.03	0.01	0.14	0.01

Centeroid 5

Iterasi	Klaster	Centeroid 6 Klaster								
		X1	X2	X3	X4	X5	X6	X7	X8	X9
5	1	0.35	0.00	0.00	0.04	0.82	0.03	0.05	0.45	0.08
	2	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
	3	0.48	0.00	0.00	0.00	0.61	0.03	0.07	0.08	0.61
	4	0.00	0.00	0.00	0.02	0.82	0.03	0.01	0.05	0.01
	5	0.00	0.00	0.00	0.00	0.67	0.03	0.00	0.31	0.01
	6	0.36	0.00	0.00	0.01	0.82	0.05	0.06	0.07	0.03
20	1	0.38	0.00	0.00	0.00	0.86	0.06	0.21	0.06	0.04
	2	0.00	0.00	0.00	0.02	0.78	0.03	0.01	0.11	0.01
	3	0.35	0.00	0.00	0.00	0.83	0.03	0.02	0.50	0.08
	4	0.37	0.00	0.00	0.02	0.79	0.04	0.00	0.07	0.03
	5	0.37	0.00	0.00	0.00	0.81	0.04	0.10	0.08	0.82
	6	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
100	1	0.35	0.00	0.00	0.05	0.82	0.03	0.02	0.48	0.08
	2	0.37	0.00	0.00	0.00	0.78	0.04	0.00	0.07	0.03
	3	0.00	0.00	0.00	0.02	0.78	0.03	0.01	0.11	0.01
	4	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
	5	0.37	0.00	0.00	0.00	0.81	0.04	0.10	0.08	0.82
	6	0.38	0.00	0.00	0.03	0.86	0.06	0.21	0.06	0.04

Centeroid 6

Iterasi	Klaster	Centeroid 7 Klaster								
		X1	X2	X3	X4	X5	X6	X7	X8	X9
5	1	0.37	0.00	0.00	0.02	0.79	0.04	0.00	0.09	0.03
	2	0.38	0.00	0.00	0.00	0.86	0.06	0.21	0.07	0.03
	3	0.29	0.00	0.00	0.00	0.86	0.03	0.00	0.86	0.18
	4	0.00	0.00	0.00	0.00	0.67	0.03	0.00	0.31	0.01
	5	0.00	0.00	0.00	0.02	0.82	0.03	0.01	0.05	0.01
	6	0.37	0.00	0.00	0.00	0.81	0.04	0.10	0.06	0.70
	7	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
20	1	0.39	0.00	0.00	0.00	0.86	0.06	0.22	0.06	0.04
	2	0.41	0.00	0.00	0.00	0.74	0.03	0.01	0.35	0.08
	3	0.00	0.00	0.00	0.00	0.78	0.03	0.01	0.11	0.01
	4	0.35	0.00	0.00	0.00	0.80	0.04	0.00	0.06	0.03
	5	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00
	6	0.39	0.00	0.00	0.00	0.81	0.04	0.12	0.06	0.89
	7	0.30	0.00	0.00	0.55	0.79	0.03	0.03	0.11	0.01
100	1	0.34	0.00	0.00	0.00	0.80	0.04	0.00	0.04	0.03
	2	0.00	0.00	0.00	0.02	0.78	0.03	0.01	0.11	0.01
	3	0.42	0.00	0.00	0.07	0.75	0.03	0.01	0.21	0.03
	4	0.37	0.00	0.00	0.00	0.81	0.04	0.10	0.08	0.82
	5	0.39	0.00	0.00	0.00	0.86	0.06	0.21	0.06	0.04
	6	0.29	0.00	0.00	0.00	0.86	0.03	0.00	0.86	0.18
	7	0.75	0.88	0.65	0.47	0.43	0.03	0.17	0.07	0.00

(Halaman ini Sengaja Dikosongkan)

LAMPIRAN 4

WAWANCARA PERUSAHAAN

Tabel Wawancara 1

Tanggal	Media	Pertanyaan	Jawaban
Jumat, 24 Januari 2020	Wawancara langung	Permasalahan yang terjadi di perusahaan	<ul style="list-style-type: none"> ▪ Perusahaan memiliki permasalahan breakdown yang terjadi pada pabrik barunya yaitu Unit V yang baru berdiri pada tahun 2014. ▪ Unit V merupakan pabrik yang telah dilengkapi banyak peralatan sensor untuk memantau kondisi mesin. Namun data sensor tersebut belum digunakan secara optimal.
Jumat, 14 Pebruari 2020	Wawancara langsung	Maintenance yang telah diterapkan oleh perusahaan	<p>Maintenance yang telah dilakukan perusahaan:</p> <ul style="list-style-type: none"> ▪ Preventive maintenance Maintenance terjadwal yang dilakukan pada interval Januari hingga Juli. Hal tersebut dikarenakan pada interval Agustus hingga Desember mendapatkan permintaan yang besar. Aktifitas yang dilakukan berupa overhaul, pengecekan, dan perbaikan. ▪ Corrective maintenance Maintenance yang dilakukan ketika terjadi kerusakan secara tiba-tiba. Jenis kerusakan ini yang belum diketahui kapan akan terjadi. Sehingga dapat memberikan

Tanggal	Media	Pertanyaan	Jawaban
			kerugian pada proses produksi di perusahaan.
Kamis, 13 Pebruari 2020	Wawancara langsung	Dampak maintenance yang telah diterapkan	Maintenance yang telah diterapkan masih belum optimal. Sehingga masih menyebabkan tingginya downtime yang terjadi akibat breakdown. Hal tersebut juga berpengaruh pada availability kiln equipment.
Jumat, 14 Pebruari 2020	Wawancara langsung dan WA	Kondisi aktual yang terjadi di perusahaan	Kapasitas produksi kiln memiliki klaim sebesar 750 ton/jam. Namun pada kenyataannya hanya 680 ton/jam.
		Kondisi proses produksi di perusahaan	Proses diawali dari feeder yang memberikan pasokan bahan baku. Selanjutnya bahan baku dicampur dalam rawmill. Kemudian ditampung ke dalam silo sebagai buffer. Setelah itu diolah dalam kiln untuk menjadi klinker dan disimpan dalam doome. Material dalam doome kemudian dibawa ke cement mill untuk diproses dan menjadi semen.
		Harga produk yang berada di perusahaan	Harga penjualan produk semen perusahaan sebesar Rp 1020/kg. Sedangkan untuk material penyusunnya yaitu raw meal 40.000/ton, klinker 75.000/ton, dan semen 100.000/ton.
Jumat, 21	Wawancara langsung	Proses produksi	Proses produksi

Tanggal	Media	Pertanyaan	Jawaban
Pebruari 2020		yang terjadi di perusahaan	 <p data-bbox="850 689 1353 943">Keseluruhan peralatan pada Unit V telah terpasang sensor untuk proses monitoring. Jumlah sensor dalam setiap peralatan dapat sekitar 2000 sensor.</p>
Jumat, 28 Pebruari 2020	Wawancara langsung	Kerusakan yang terjadi di kiln equipment	<p data-bbox="850 976 1353 1055">Terdapat tujuh jenis sensor yang mendeteksi breakdown.</p> <ul data-bbox="850 1077 1353 1447" style="list-style-type: none"> ▪ Motor EPFAN (X1) ▪ Motor IDFAN 1 (X2) ▪ Motor IDFAN 2 (X3) ▪ Kiln Feed (X4) ▪ Temperature Calciner (X5) ▪ Maindrive Kiln (X6) ▪ Coal Feeder (X7) <p data-bbox="850 1469 1353 1603">Pengambilan ketujuh data sensor tersebut berdasarkan frekuensi dalam mendeteksi breakdown.</p>
		Data sensor dalam membaca kerusakan	<p data-bbox="850 1637 1353 1839">Tujuh jenis sensor yang mendeteksi breakdown berdasarkan threshold. Jika data sensor terbaca dibawah threshold, maka dianggap mengalami breakdown.</p> <ul data-bbox="850 1850 1353 1939" style="list-style-type: none"> ▪ Motor EPFAN (X1) <p data-bbox="887 1906 1150 1939">Threshold: 50 RPM</p>

Tanggal	Media	Pertanyaan	Jawaban
			<ul style="list-style-type: none"> ▪ Motor IDFAN 1 (X2) Threshold: 50 RPM ▪ Motor IDFAN 2 (X3) Threshold: 50 RPM ▪ Kiln Feed (X4) Threshold: 150 ton/jam ▪ Temperature Calciner (X5) Threshold: 300°C ▪ Maindrive Kiln (X6) Threshold: 0,5 RPM ▪ Coal Feeder (X7) Threshold: 1 ton/jam <p>Ketujuh data sensor diintegrasikan menjadi menjadi setiap data terdapat 7 variabel. Kemudian data sensor tersebut di bandingkan dengan regulasi kiln equipment. Jika data sensor tersebut memenuhi regulasi maka dianggap mesin masih beroperasi.</p>
Senin, 01 Juni 2020	Wawancara langsung	Unplanned downtime	Unplanned downtime dapat dihilangkan untuk menghasilkan data yang lebih akurat.
Selasa, 07 Juli 2020	Video conference (google meet)	Penggunaan data sensor interval 1 jam	Penggunaan data dalam interval waktu 1 jam diperbolehkan. Hal ini dapat mempersingkat waktu proses penghitungan. Dan juga dapat menghindari error pada laptop dengan spesifikasi minim. Namun alangkah lebih baik menggunakan data yang lebih detail seperti interval setiap

Tanggal	Media	Pertanyaan	Jawaban
			<p>beberapa detik atau beberapa menit. Sehingga dapat merepresentasikan kondisi asli dari mesin.</p>
		<p>Data sensor mendeteksi kerusakan</p>	<p>Perilaku mesin yang dapat dideteksi oleh data sensor adalah sebagai berikut.</p> <ul style="list-style-type: none"> ▪ Vibrasi (getaran) ▪ Feeding (pasokan) ▪ Rotasi (rpm) ▪ Temperatur (°c)
<p>Selasa, 14 Juli 2020</p>	<p>Video conference (zoom)</p>	<p>Validasi hasil klaster, prediksi, dan maintenance</p>	<p>Terdapat lima klaster data sensor yang dihasilkan. Klaster data sensor tersebut mendeteksi breakdown ringan, sedang, dan berat. Kemudian breakdown sedang dibagi menjadi tiga berdasarkan tingkatannya. Sehingga dihasilkan lima jadwal maintenance yang optimal untuk kiln equipment. Namun hanya empat jadwal maintenance yang sesuai dengan kondisi sebenarnya di perusahaan. Jadwal maintenance dengan interval 2100 jam dirasa kurang sesuai karena downtime tertinggi terjadi selama sekitar 1400 jam saja.</p>

(Halaman ini Sengaja Dikosongkan)

BIOGRAFI PENULIS



Penulis bernama lengkap Abiyyu Dimas Prasanto lahir di Kediri, 05 Juli 1997. Penulis merupakan anak pertama dari dua bersaudara dari Bapak Djoko Santoso dan Ibu Priska Indah Prasetya. Penulis telah menempuh pendidikan formal di SD Kadipaten II (2003-2009), SMP Negeri 1 Bojonegoro (2009-2012), SMA Negeri 1 Bojonegoro (2012-2015), dan Departemen Teknik Industri Institut Teknologi Sepuluh Nopember (ITS) Surabaya (2016-2020).

Penulis aktif dalam berbagai kegiatan kepanitiaan yakni *Industrial Engineering Games 13th Edition* yang merupakan kompetisi berbasis keilmuan Teknik Industri Tingkat Nasional untuk Mahasiswa Sekolah Menengah Atas IPA, serta *Industrial Challenge (INCHALL) 2017* yang merupakan kompetisi berbasis Teknik Industri Tingkat International untuk Mahasiswa se-Asia. Penulis juga pernah melakukan kegiatan magang pada Team Sapu Angin ITS yang bergerak pada bidang kompetisi mobil hemat energi.

Selain itu, penulis diamanahi menjadi Asisten Laboratorium Sistem Manufaktur Departemen Teknik Industri ITS pada tahun 2018 hingga 2020. Pada saat menjadi asisten, penulis pernah menjabat sebagai Wakil Koordinator Asisten Mata Kuliah Menggambar Teknik periode Genap 2018/2019 dan Koordinator Asisten Mata Kuliah Proses Manufaktur periode Ganjil 2019/2020 dan mengikuti beberapa pelatihan *softskills* seperti SOLIDWORKS dan AutoCAD dan Pelatihan *CNC Machine*. Penulis juga pernah menjadi tutor dalam pelatihan SOLIDWORKS. Dalam rangka pengaplikasian keilmuan Teknik Industri, penulis pernah melaksanakan Kerja Praktik di PT PETROKIMIA GRESIK pada Departemen Pemeliharaan II Di Pabrik IIA pada bulan Agustus 2019.

Apabila ada pertanyaan atau membutuhkan informasi lebih lanjut mengenai penelitian ini, dapat menghubungi penulis melalui email abiyyudimas5@gmail.com.

