PERANCANGAN INTERVAL *PREDICTIVE MAINTENANCE* DENGAN PENDEKATAN RELIABILITAS DISTRIBUSI WEIBULL

TUGAS AKHIR

Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana Strata-1
Program Studi Teknik Industri - Fakultas Teknologi Industri
Universitas Islam Indonesia

Nama : Adrian Oka Pramana
No. Mahasiswa : 22522079

PROGRAM STUDI TEKNIK INDUSTRI PROGRAM SARJANA
FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS ISLAM INDONESIA
YOGYAKARTA
2026

PERNYATAAN KEASLIAN

Saya mengakui bahwa tugas akhir ini adalah hasil karya saya sendiri kecuali kutipan dan ringkasan yang seluruhnya sudah saya jelaskan sumbernya. Jika dikemudian hari ternyata terbukti pengakuan saya ini tidak benar dan melanggar peraturan yang sah maka saya bersedia ijazah yang telah saya terima ditarik kembali oleh Universitas Islam Indonesia.

Yogyakarta, 10 Januari 2026



Adrian Oka Pramana
22522079

SURAT BUKTI PENELITIAN



FAKULTAS
TEKNOLOGI INDUSTRI

SURAT KETERANGAN PENELITIAN

Nomor : 235/Ka.lab SIMANTI/20/Lab.SIMANTI/I/2026

Assalamu'alaikum Warohmatullahi Wabarokaatuh

Dengan hormat,

Yang bertanda tangan dibawah ini, menerangkan bahwa:

Nama : Adrian Oka Pramana

Nim : 22522079

Jurusan : Teknik Industri

Dosen Pembimbing : Ir. Muhammad Ridwan Andi Purnomo, S.T., M.Sc., Ph.D., IPM.

Menyatakan bahwa mahasiswa tersebut diatas telah melaksanakan penelitian tugas akhir dengan judul **"PERANCANGAN INTERVAL *PREDICTIVE MAINTENANCE* DENGAN PENDEKATAN RELIABILITAS DISTRIBUSI WEIBULL"** mulai pelaksanaan penelitian 16 September 2025 sampai 10 Januari 2026.

Demikian surat keterangan penelitian ini kami buat. Atas perhatiannya dan kerja samanya kami mengucapkan terima kasih.

Wassalamu'alaikum Warohmatullahi Wabarokaatuh

Yogyakarta, 20 Januari 2026
Kepala Laboratorium
Sistem Manufaktur Terintegrasi

Putri Dwi Annisa, S.T., M.Sc.

LEMBAR PENGESAHAN PEMBIMBING

PERANCANGAN INTERVAL *PREDICTIVE MAINTENANCE* DENGAN PENDEKATAN RELIABILITAS DISTRIBUSI WEIBULL

TUGAS AKHIR

Disusun Oleh :

Nama : Adrian Oka Pramana
No. Mahasiswa : 22522079

Yogyakarta, 29 Januari 2026

Dosen Pembimbing

(Ir. Muhammad Ridwan Andi Purnomo, S.T., M.Sc., Ph.D., IPM)

LEMBAR PENGESAHAN DOSEN PENGUJI

PERANCANGAN INTERVAL *PREDICTIVE MAINTENANCE* DENGAN PENDEKATAN RELIABILITAS DISTRIBUSI WEIBULL

TUGAS AKHIR

Disusun Oleh :

Nama : Adrian Oka Pramana

No. Mahasiswa : 22522079

Telah dipertahankan di depan sidang penguji sebagai salah satu syarat untuk memperoleh gelar Sarjana Strata-1 Teknik Industri Fakultas Tekonologi Industri Universitas Islam Indonesia

Yogyakarta, 02 Februari 2026

Tim Penguji

Ir. Muhammad Ridwan Andi Purnomo, S.T., M.Sc., Ph.D., IPM Ketua	
Dian Janari, S.T., M.T. Anggota I	Dian Janari
Putri Dwi Annisa, S.T., M.Sc. Anggota II	

Mengetahui,

Ketua Program Studi Teknik Industri Program Sarjana

Fakultas Teknologi Industri

Universitas Islam Indonesia

Ir. Muhammad Ridwan Andi Purnomo, S.T., M.Sc., Ph.D., IPM

NIK. 015220101

HALAMAN PERSEMBAHAN

Bismillahirrahmanirrahim

Dengan mengucap Syukur, Alhamdulillahirabbil'alamin, segala puji bagi Allah SWT yang telah memberikan nikmat dan karunia-Nya sehingga tugas akhir ini dapat diselesaikan.

Shalawat serta salam senantiasa tercurah kepada Nabi Muhammad SAW, beserta keluarga serta sahabatnya

Tugas akhir ini saya persembahkan untuk kedua orang tua saya yang telah memberikan saya dukungan dan doa yang tiada henti. Terima kasih atas pengorbanan yang dilakukan sejak saya lahir hingga dapat menyelesaikan studi S1 di Teknik Industri FTI UII.

MOTTO

"Hidup yang tidak dipertaruhkan tidak akan pernah dimenangkan"

(Sutan Sjahrir)

"When I die, I want to be remembered for the life I lived, not the money I made"

(Avicii)

KATA PENGANTAR

Assalamu'alaikum Warrahmatullahi Wabarakaatuh.

Alhamdulillahirabbil'alamin, dengan menyebut nama Allah SWT yang Maha Pengasih dan Penyayang, segala puji dan syukur saya panjatkan kepada Allah SWT atas anugerah dan nikmat, serta ridho-Nya sehingga saya dapat menyelesaikan tugas akhir yang berjudul "Perancangan Interval *Predictive Maintenance* Dengan Pendekatan Reliabilitas Distribusi Weibull". Sholawat dan salam pun senantiasa tidak lupa tercurahkan kepada junjungan kita Nabi Muhammad SAW yang telah membimbing umat manusia dari zaman kegelapan menuju zaman yang terang benderang seperti saat ini dengan penuh ilmu dan anugerah.

Pada kesempatan kali ini, penulis ingin mengucapkan terima kasih yang tulus kepada semua pihak yang telah ikut serta membantu dan membimbing penulis dalam penulisan laporan tugas akhir ini, baik yang terlibat secara langsung maupun tidak langsung. Oleh karena itu, penulis ingin berterima kasih kepada:

1. Bapak Prof. Dr. Ir. Hari Purnomo, M.T., IPU, ASEAN Eng., selaku Dekan Fakultas Teknologi Industri, Universitas Islam Indonesia.
2. Bapak Dr. Drs. Imam Djati Widodo, M.Eng.Sc., selaku Ketua Jurusan Program Studi Teknik Industri, Fakultas Teknologi Industri, Universitas Islam Indonesia.
3. Bapak Ir. Muhammad Ridwan Andi Purnomo, S.T., M.Sc., Ph.D., IPM, selaku Ketua Program Studi Teknik Industri Program Sarjana Fakultas Teknologi Industri, Universitas Islam Indonesia dan Dosen Pembimbing Tugas Akhir yang telah memberikan bimbingan, ilmu, serta arahan sehingga penulis dapat menyelesaikan laporan tugas akhir ini.
4. Kedua orang tua penulis, Bapak Naslil dan Ibu Reni Fitria, yang selalu memberikan doa, motivasi, serta dukungan moral maupun material kepada penulis.
5. Salwa Salsabiela Dihan, sahabat terbaik yang tidak pernah lelah memberi dukungan selama penulis mengerjakan laporan tugas akhir.
6. Adamsyah Hadi Kusumah, Ikhsan Fajar Hardanta, Annisa Nathaniela Syahda, Regina Wulandari, teman terbaik yang penulis bisa dapatkan dalam menjalani masa kuliah.

Penulis menyadari bahwa penulisan laporan tugas akhir ini masih banyak kekurangan dan jauh dari kata sempurna. Maka dari itu, penulis mengharapkan kritik dan saran yang bersifat membangun dengan tujuan untuk menyempurnakan tugas akhir. Akhir kata, semoga laporan tugas akhir ini dapat bermanfaat bagi penulis dan pembaca.

Yogyakarta, 10 Januari 2026



Adrian Oka Pramana
22522079

ABSTRAK

Industri manufaktur *spare part* sangat bergantung pada keandalan peralatan produksi untuk memastikan kontinuitas operasional dan meminimalkan kerugian finansial akibat *downtime*. Mesin Sistem Obeng Torsi menunjukkan keandalan terendah dalam sistem manufaktur serial dengan MTBF 188,19 jam. Penelitian ini menganalisis data historis 44 observasi kegagalan selama enam bulan (Januari-Juni 2025) menggunakan distribusi Weibull dengan metode regresi linear sederhana untuk mengestimasi parameter bentuk (β) dan skala (η), serta menentukan interval *predictive maintenance* yang optimal. Hasil menunjukkan β = 1,573 dan η = 145,756 jam, mengindikasikan mesin berada pada fase *wear-out* dengan laju kegagalan meningkat seiring waktu operasi. Analisis reliabilitas menunjukkan pada 150 jam reliabilitas mencapai 55,05%, sedangkan pada 171,42 jam turun menjadi 50%. Optimasi *cost rate* menghasilkan interval pemeliharaan optimal 91 jam dengan biaya USD 13,181 per jam, 23% lebih rendah dibandingkan kebijakan saat ini (USD 17,124 per jam), serta memberikan reliabilitas 62,08%. Implementasi interval *predictive maintenance* 91 jam dapat meningkatkan keandalan sistem manufaktur serial dan menghemat biaya pemeliharaan signifikan sambil meminimalkan risiko *unplanned downtime*..

Kata Kunci: *Predictive maintenance, Weibull Distribution, Reliability Engineering,* Regresi linear, *Age replacement policy, Maintenance Interval Optimization*

DAFTAR ISI

PERNYATAAN KEASLIAN ..... **ii**
SURAT BUKTI PENELITIAN ..... **iii**
LEMBAR PENGESAHAN PEMBIMBING ..... **iv**
LEMBAR PENGESAHAN DOSEN PENGUJI ..... **v**
HALAMAN PERSEMBAHAN ..... **vi**
MOTTO ..... **vii**
KATA PENGANTAR ..... **viii**
ABSTRAK ..... **ix**
DAFTAR ISI ..... **x**
DAFTAR TABEL ..... **xii**
DAFTAR GAMBAR ..... **xiii**
BAB I PENDAHULUAN **1**
1.1 Latar Belakang 1
1.2 Rumusan Masalah 6
1.3 Tujuan Penelitian 6
1.4 Manfaat Penelitian 6
1.5 Batasan Penelitian 8
BAB II TINJAUAN PUSTAKA **9**
2.1 Kajian Literatur 9
2.2 *Research Gap* 15
2.3 Landasan Teori 16
2.3.1 Reliability Engineering. 16
2.3.2 Mean Time Between Failures dan Mean Time to Failure. 18
2.3.3 Predictive Maintenance. 18
2.3.4 Weibull Distribution. 19
2.3.5 Reliability Function dan Failure Function dalam Weibull Distribution. 21
2.3.6 Regresi Linear Sederhana. 21
2.3.7 Koefisien Determinasi (R^2) dan Validasi Model Weibull. 22
2.3.8 Maintenance Interval Determination Berbasis Reliability Target. 23
2.3.9 System Reliability Analysis Untuk Sistem Serial. 23
2.3.10 Konteks Industri Manufakur Indonesia. 24
BAB III METODE PENELITIAN **26**
3.1 Objek Penelitian 26
3.2 Jenis Data Penelitian 26
3.3 Alur Penelitian 26
BAB IV PENGUMPULAN DAN PENGOLAHAN DATA **33**

4.1 Pengumpulan Data 33
4.1.1 Sumber dan Jenis Data. 33
4.1.2 Perhitungan MTBF Preventive dan Corrective Maintenance. 33
4.2 Perhitungan Parameter Distribusi Weibull 34
4.2.1 Penyusunan Data Untuk Analisis Distribusi Weibull. 34
4.2.2 Transformasi Linear Pembentukan Weibull Probability Plot. 36
4.2.3 Estimasi Parameter Beta (β) dan Eta (η) 37
4.3 Perhitungan Biaya Berdasarkan Hasil Parameter Distribusi Weibull 38
4.3.1 Perhitungan Reliability Grid. 38
4.3.2 Perhitungan Optimasi Predictive Maintenance. 39
4.3.3 Perhitungan Expected Total Cost berdasarkan Kebijakan Perusahaan. 40
4.3.4 Biaya Rekomendasi Predictive Maintenance. 41
4.3.5 Perbandingan Expected Total Cost dan Predictive Maintenance. 42
BAB V PEMBAHASAN 43
5.1 Interpretasi Kondisi Awal Mesin Sistem Obeng Torsi 43
5.2 Analisis Parameter Distribusi Weibull 44
5.2.1 Interpretasi Shape Parameter(β). 44
5.2.2 Interpretasi Scale Parameter (η). 44
5.3 Analisis dan Perbandingan Biaya *Maintenance* 45
5.3.1 Analisis Expected Cost Estimation Berdasarkan Kebijakan PT XYZ.. 45
5.3.2 Analisis Biaya Predictive Maintenance**,** 45
5.3.3 Perbandingan dan Estimasi Penghematan Biaya 46
5.4 Rekomendasi Waktu Penerapan *Predictive Maintenance* 47
5.5 Aktivitas Perawatan pada Komponen Kritis 48
5.6 Keterbatasan Penelitian 49
BAB VI PENUTUP 51
6.1 Kesimpulan 51
6.2 Saran 52
DAFTAR PUSTAKA 53

DAFTAR TABEL

Tabel 1. 1 Data Reliabilitas Mesin PT XYZ 4
Tabel 1. 2 Reliabilitas Mesin dalam Sistem Produksi PT XYZ 5
Tabel 2. 1 Pemetaan Penelitian Terdahulu dan Posisi Penelitian..... 15
Tabel 4. 1 Data Operasional Harian dan Status Kegagalan Mesin 5..... 34
Tabel 4. 2 Data *Time Between Failure* (TBF) Terurut dan Peringkat Kegagalan..... 35
Tabel 4. 3 Estimasi Probabilitas Kumulatif Kegagalan dengan Median Rank 35
Tabel 4. 4 Transformasi Linear Data TBF untuk Weibull Probability Plot 36
Tabel 4. 5 Parameter Distribusi Weibull Mesin Sistem Obeng Torsi 38
Tabel 4. 6 *Reliability Grid* Mesin Sistem Obeng Torsi..... 38
Tabel 4. 7 Hasil Optimasi *Predictive Maintenance*..... 39
Tabel 4. 8 Perbandingan Biaya Pemeliharaan Berdasarkan Strategi *Maintenance*..... 42

DAFTAR GAMBAR

Gambar 3. 1 Alur Penelitian 27
Gambar 4. 1 Grafik *Cost Rate* Berdasarkan Waktu Pemeliharaan (t) 41

BAB I
PENDAHULUAN

1.1 Latar Belakang

Industri manufaktur *spare part* merupakan sektor yang sangat bergantung pada keandalan peralatan produksi untuk memastikan kontinuitas operasional dan meminimalkan kerugian finansial akibat *downtime*. Menurut Molęda et al. (2023), strategi pemeliharaan yang tidak tepat dapat mengurangi kapasitas produksi keseluruhan sebesar 5 hingga 20 persen, sementara implementasi pemeliharaan digital dapat meningkatkan ketersediaan aset sebesar 5 hingga 15 persen dan mengurangi biaya pemeliharaan sebesar 18 hingga 25 persen. Dalam konteks ini, *reliability* atau keandalan didefinisikan sebagai probabilitas bahwa suatu sistem atau peralatan dapat menjalankan fungsinya secara memuaskan dalam periode waktu tertentu di bawah kondisi operasi yang telah ditentukan. Keandalan peralatan bukan sekadar isu teknis di tingkat bengkel, melainkan bagian integral dari strategi daya saing perusahaan manufaktur modern.

Dalam konteks manufaktur modern yang memasuki era Industri 4.0, terdapat tiga strategi pemeliharaan utama yang digunakan: pemeliharaan reaktif (*corrective maintenance*), pemeliharaan preventif terjadwal (*preventive maintenance*), dan pemeliharaan prediktif berbasis kondisi (*predictive maintenance*). Molęda et al. (2023) menjelaskan bahwa *corrective maintenance* adalah pendekatan yang mengambil tindakan setelah kegagalan terjadi, yang meminimalkan biaya servis rutin tetapi meningkatkan risiko *downtime* tidak terencana, kehilangan pendapatan, dan kerusakan sekunder pada peralatan terkait. *Preventive maintenance* melibatkan inspeksi dan penggantian terjadwal secara periodik berdasarkan waktu, MTBF (*Mean Time Between Failures*), atau rekomendasi pabrikan, yang mengurangi downtime tidak terencana tetapi dapat menyebabkan *over-maintenance* dengan penggantian komponen yang terlalu dini. Sementara itu, *predictive maintenance* merupakan evolusi strategis yang mengubah

paradigma dari pendekatan reaktif atau preventif berjadwal menjadi pendekatan berbasis kondisi aktual peralatan.

Menurut survei komprehensif yang dilakukan oleh Hector, I., & Panjanathan, R. (2024), *predictive maintenance* (PdM) dalam Industri 4.0 memanfaatkan teknologi *Internet of Things* (IoT), *machine learning, big data analytics,* dan *cloud computing* untuk memungkinkan monitoring *real-time* terhadap kondisi peralatan dan prediksi kegagalan sebelum terjadi. Paradigma ini menjadi semakin relevan dalam era Industri 4.0, di mana integrasi sistem otomasi, sensor, dan pengolahan data menjadi kunci untuk mencapai *operational excellence*. Penelitian empiris menunjukkan dampak signifikan dari transformasi strategi pemeliharaan berbasis data. Wang et al. (2024) membuktikan bahwa implementasi *predictive maintenance* dengan basis analisis kuantitatif dapat menghasilkan pengurangan *downtime* yang signifikan dengan peningkatan MTBF sebesar rata-rata 25 hingga 40 persen dalam berbagai sektor industri.

Untuk mengimplementasikan *predictive maintenance* secara efektif, diperlukan alat analisis yang mampu memodelkan pola kegagalan peralatan dengan akurat. Distribusi Weibull, yang dikembangkan oleh Waloddi Weibull pada tahun 1937, telah menjadi standar industri untuk analisis keandalan dan prediksi kegagalan komponen. Menurut Nketiah et al. (2021), Weibull Distribution memiliki fleksibilitas parametrik yang unik untuk memodelkan berbagai pola laju kegagalan, dari *early-life failures* hingga w*ear-out failures*, menjadikannya alat yang sangat berguna dalam *reliability engineering*. Distribusi Weibull didefinisikan dengan dua parameter utama: shape parameter (β) yang menunjukkan pola laju kegagalan, dan *scale parameter* (η) yang merepresentasikan *characteristic life*, yaitu waktu ketika 63,2% unit mengalami kegagalan.

Nketiah et al. (2021) menekankan bahwa pemahaman mendalam terhadap parameter Weibull sangat penting untuk validitas analisis *reliability* dan perencanaan *maintenance* yang efektif. Nilai shape parameter memiliki interpretasi kunci: ketika $\beta < 1$ menunjukkan *early mortality failures* dengan tingkat kegagalan menurun seiring waktu (*infant mortality phase*), $\beta = 1$ mengindikasikan *random failures* dengan tingkat kegagalan konstan (useful life phase), dan $\beta > 1$ menunjukkan *wear-out failures* dengan

tingkat kegagalan meningkat seiring waktu operasi. Penelitian mereka membandingkan *Maximum Likelihood Estimation* (MLE) dan metode *least-squares* untuk estimasi parameter Weibull, menunjukkan bahwa MLE memperoleh performa yang lebih baik dan *asymptotically efficient* seiring meningkatnya ukuran sampel.

Meskipun analisis Weibull dan *predictive maintenance* telah terbukti efektif secara global, penerapannya di industri manufaktur Indonesia masih menghadapi tantangan signifikan. Kebijakan pemeliharaan di banyak perusahaan manufaktur lokal masih didominasi oleh pendekatan reaktif dan jadwal berkala yang belum sepenuhnya didasarkan pada analisis data kegagalan secara kuantitatif. Interval pemeriksaan dan penggantian komponen umumnya mengacu pada pengalaman teknisi atau rekomendasi umum pabrikan, bukan pada karakteristik degradasi aktual mesin di lapangan. Gap ini menimbulkan dua risiko utama: over-maintenance ketika pemeliharaan dilakukan terlalu dini sehingga membuang sumber daya, dan *under-maintenance* ketika mesin dibiarkan beroperasi terlalu lama hingga memasuki zona risiko kegagalan tinggi.

Menurut Molęda et al. (2023), untuk mengatasi gap tersebut, pendekatan *Reliability-Centered Maintenance* (RCM) dan *Failure Mode and Effects Analysis* (FMEA) dapat diintegrasikan dengan analisis Weibull untuk mengidentifikasi komponen kritis dan menentukan interval penggantian optimal. RCM adalah proses terstruktur untuk menentukan tugas optimal yang memastikan aset melakukan fungsi yang diperlukan dalam konteks operasi mereka, dengan fokus pada *system functions* daripada sekadar *uptime*. Sementara itu, FMEA mengidentifikasi mode kegagalan potensial dalam peralatan atau proses, menilai risiko yang terkait, memprioritaskan masalah, dan merekomendasikan tindakan korektif berdasarkan *Risk Priority Number* (RPN) yang dihitung dari *Severity* × *Occurrence* × *Detection*.

Menurut Hector, I., & Panjanathan, R. (2024), MTBF dihitung sebagai total waktu operasi dibagi jumlah kegagalan yang terjadi, dan pada distribusi eksponensial dengan *failure rate* konstan, probabilitas sistem bertahan hingga MTBF adalah $1/e \approx 37\%$, yang berarti 63% sistem telah gagal pada waktu MTBF. Pemahaman yang tepat tentang MTBF sangat krusial dalam perencanaan maintenance dan inventory management spare parts karena sering terjadi kesalahpahaman bahwa MTBF menjamin durasi minimum operasi,

sebaliknya, MTBF hanya merepresentasikan mean atau rata-rata. Kondisi ini mengindikasikan bahwa Mesin Sistem Obeng Torsi mengalami laju kegagalan yang lebih tinggi dan pola degradasi yang lebih cepat, menjadikannya bottleneck kritis dalam sistem produksi serial.

Perusahaan tempat penelitian ini dilakukan adalah pelaku industri manufaktur *spare part* yang memproduksi modul kontroler dengan proses produksi didukung oleh rangkaian mesin dengan konfigurasi sistem 5 mesin serial. Dalam sistem serial, kegagalan pada satu mesin akan menghentikan keseluruhan aliran produksi dan mengakibatkan kerugian finansial yang ter-akselerasi. Data historis perusahaan menunjukkan bahwa Mesin Sistem Obeng Torsi memiliki tingkat keandalan terendah dibandingkan mesin lainnya. Kondisi ini ditunjukkan pada Tabel 1.1, yang menyajikan nilai reliabilitas lima mesin dalam sistem produksi PT XYZ.

Tabel 1. 1 Data Reliabilitas Mesin PT XYZ

M1_reliability	M2_reliability	M3_reliability	M4_reliability	M5_reliability
0,932749	0,921574	0,906945	0,916532	0,894243
0,921892	0,895928	0,883624	0,89901	0,872649
0,91829	0,900976	0,88604	0,893903	0,866028
0,939329	0,922991	0,901039	0,905394	0,89474
0,919714	0,90334	0,886924	0,889033	0,857107
0,925639	0,91734	0,903444	0,906652	0,882863
0,93078	0,902054	0,900869	0,895467	0,896651
0,935122	0,910098	0,908113	0,897652	0,898447
…	…	…	…	…
0,890621	0,861728	0,832559	0,88737	0,822937

Data pada Tabel 1.1 menunjukkan nilai reliabilitas masing-masing mesin pada 360 titik waktu operasi, yang direpresentasikan sebagai fungsi keandalan R(t) dengan rentang nilai antara 0 dan 1 untuk lima mesin produksi (M1–M5). Secara umum, nilai reliabilitas yang relatif tinggi mengindikasikan bahwa seluruh mesin masih memiliki probabilitas bertahan yang cukup baik selama periode pengamatan. Namun demikian, terlihat adanya

kecenderungan penurunan nilai reliabilitas seiring bertambahnya waktu operasi, yang mencerminkan proses degradasi performa komponen.

Untuk mempermudah analisis perbandingan kinerja keandalan antar mesin, dilakukan perhitungan nilai reliabilitas rata-rata masing-masing mesin yang dirangkum dalam Tabel 1.2. Rekapitulasi ini bertujuan untuk mengidentifikasi mesin dengan tingkat keandalan tertinggi maupun terendah dalam sistem produksi.

Tabel 1. 2 Reliabilitas Mesin dalam Sistem Produksi PT XYZ

Mesin	**Reliabilitas**
Mesin PCB *Depaneling*	91,74%
Mesin Printer Solder	90,20%
Mesin *Trimming* dan *Cutting*	87,92%
Mesin Pengujian Sirkuit	88,96%
Mesin Sistem Obeng Torsi	**86,64%**

Berdasarkan Tabel 1.2, Mesin Sistem Obeng Torsi memiliki nilai reliabilitas rata-rata paling rendah, yaitu sebesar 86,64%. Rendahnya tingkat keandalan ini menunjukkan bahwa peluang mesin untuk beroperasi tanpa mengalami kegagalan dalam periode tertentu lebih kecil dibandingkan mesin lainnya, sehingga risiko terjadinya gangguan produksi menjadi lebih tinggi. Kondisi tersebut berpotensi menurunkan kapasitas produksi efektif, memicu keterlambatan jadwal pengiriman, meningkatkan kebutuhan lembur, serta menambah beban biaya perawatan darurat yang signifikan.

Molęda et al. (2023) menunjukkan bahwa teknik *predictive maintenance* konvensional yang umum digunakan meliputi *vibration monitoring, thermography, oil analysis*, *acoustic analysis, motor current analysis*, dan analisis parameter proses. Dengan monitoring kondisi ini, analisis tren tingkat getaran, profil sinyal, atau indikator kesehatan (*health index*) dapat dengan mudah dibuat menggunakan pengukuran tunggal untuk menentukan *remaining useful life* dan mengevaluasi deteriorasi komponen.

Oleh karena itu, integrasi analisis *Weibull reliability modeling* dengan *predictive maintenance* berbasis data kondisi aktual Mesin Sistem Obeng Torsi diharapkan mampu memberikan dua kontribusi utama, yaitu: (1) pemahaman kuantitatif terhadap pola

degradasi mesin sebagai dasar pengambilan keputusan pemeliharaan berbasis data, dan (2) penentuan interval *predictive maintenance* yang optimal untuk meminimalkan risiko *unplanned downtime* dalam konteks sistem produksi serial. Secara lebih luas, penelitian ini diharapkan dapat menjadi jembatan antara praktik terbaik (*best practice*) global dalam *reliability engineering* dan realitas operasional industri manufaktur Indonesia.

1.2 Rumusan Masalah

Berdasarkan dari latar belakang yang sudah dipaparkan dapat disusun rumusan masalah pada penelitian ini sebagai berikut:

1. Kapan waktu yang optimal untuk melakukan *predictive maintenance* pada komponen kritis Mesin Sistem Obeng Torsi berdasarkan analisis Weibull Distribution guna meminimalkan risiko kegagalan mendadak?
2. Berapa penghematan biaya dengan penerapan *predictive maintenance* pada komponen kritis Mesin Sistem Obeng Torsi?

1.3 Tujuan Penelitian

Tujuan penelitian ini disusun untuk menjawab rumusan masalah yang telah ditetapkan. Adapun tujuan penelitian yang ingin dicapai adalah sebagai berikut:

1. Menentukan waktu yang optimal untuk melakukan *predictive maintenance* pada komponen kritis Mesin Sistem Obeng Torsi berdasarkan analisis Weibull Distribution guna meminimalkan risiko kegagalan mendadak.
2. Mengetahui besarnya penghematan biaya dengan penerapan *predictive maintenance* pada komponen kritis Mesin Sistem Obeng Torsi.

1.4 Manfaat Penelitian

Penelitian ini diharapkan memberikan manfaat bagi berbagai pihak sebagai berikut:

1. Bagi Peneliti
    - Mengembangkan kompetensi teknis dalam penerapan analisis Weibull Distribution dan *predictive maintenance*.
    - Memperdalam penerapan praktis *reliability engineering* serta konversi parameter statistik menjadi keputusan operasional pemeliharaan.
    - Menjadi dasar untuk pengembangan penelitian lanjutan dengan cakupan yang lebih luas.

- Membuka peluang publikasi ilmiah di bidang *engineering* serta memperkuat portofolio penelitian.

2. Bagi Perusahaan
    - Memberikan pemahaman kuantitatif tentang degradasi Mesin Sistem Obeng Torsi untuk Keputusan pemeliharaan berbasis data.
    - Meminimalkan risiko *unplanned downtime* dengan penentuan waktu *predictive maintenance* yang optimal.
    - Mengurangi *downtime* dan meningkatkan *Mean Time Between Failures* (MTBF).
    - Meningkatkan efektifitas peralatan, *system availability*, serta kapasitas produksi.
    - Mendukung peningkatan kinerja operasional dan *Key Performance Indicators* (KPI) dalam kerangka *manufacturing excellence*.
3. Bagi Peneliti Selanjutnya
    - Menyediakan *empirical baseline* dan metodologi referensi untuk penelitian sejenis pada industri atau sistem berbeda.
    - Berkontribusi pada dokumentasi pola kegagalan (*failure patterns*) di industri manufaktur *spare part*.
    - Membuka peluang pengembangan analisis yang lebih kompleks, seperti optimisasi tingkat sistem (*system-level optimization*).
    - Menyediakan metodologi yang dapat diadaptasi untukberbagai konteks industri lainnya.
4. Bagi Universitas
    - Memperkaya kurikulum dengan studi kasus nyata dari industri manufaktur di Indonesia.
    - Menjadi bahan ajar (*teaching material*) untuk demonstrasi aplikasi Weibull Distribution dan *reliability engineering*.
    - Memperkaya literatur akademik di bidang Teknik Industri, khususnya dalam topik *Reliability Engineering* dan *Maintenance Management*.

1.5 Batasan Penelitian

Batasan penelitian ini digunakan agar penelitian lebih terarah serta terfokus pada tujuan penelitian tanpa memperluas pembahasan. Adapun Batasan dalam penelitian ini adalah sebagai berikut:

1. Penelitian ini terbatas pada data historis Mesin Sistem Obeng Torsi yang diasumsikan lengkap, akurat, dan representatif terhadap pola kegagalan mesin dalam kondisi operasi normal.
2. Analisis fokus hanya pada satu mesin (Mesin Sistem Obeng Torsi) tanpa perbandingan analisis terhadap keempat mesin lainnya dalam sistem.
3. Penelitian ini mengaplikasikan dua parameter Weibull Distribution (β dan η) tanpa mempertimbangkan variasi distribusi alternatif, dengan asumsi data mengikuti pola Weibull yang telah diverifikasi.
4. Tidak menganalisis *multiple failure modes* atau *competing failure mechanism*. Diasumsikan mekanisme kegagalan bersifat homogen dengan satu pola degradasi utama.
5. Semua data dianggap *complete* tanpa mempertimbangkan *censored data* atau *incomplete failure records*.
6. Tidak mempertimbangkan kondisi operasi variabel, perubahan suhu, variasi beban, atau perubahan lingkungan yang memengaruhi pola kegagalan mesin.
7. Fokus murni pada penentuan waktu *predictive maintenance* berbasis *reliability* tanpa analisis biaya, ROI, atau *total cost of ownership*.
8. Penelitian ini bersifat analitikal dan tidak mencakup implementasi *real-time monitoring*, *pilot implementation*, atau pertimbangan *human factor* dalam praktik operasional.
9. Tidak menganalisis dampak keandalan Mesin Sistem Obeng Torsi terhadap *overall system availability* dalam konteks mesin serial yang terintegrasi.
10. Tidak mengeksplorasi integrasi *machine learning* atau *artificial intelligence* untuk meningkatkan akurasi prediksi diluar *framework* Weibull Distribution.

BAB II
TINJAUAN PUSTAKA

2.1 Kajian Literatur

Transformasi strategis dalam manajemen pemeliharaan peralatan industri telah menjadi imperatif kritis dalam lanskap manufaktur kontemporer yang didorong oleh tuntutan efisiensi operasional, reduksi *downtime*, dan optimalisasi biaya siklus hidup aset. Zhu et al., (2024) dalam survei komprehensifnya mengidentifikasi evolusi paradigmatik dari tiga strategi pemeliharaan *fundamental—Reactive Maintenance* (RM), *Preventive Maintenance* (PM), dan *Predictive Maintenance* (PdM)—masing-masing dengan trade-off ekonomis dan keandalan yang spesifik. Penelitian menunjukkan bahwa strategi reaktif meminimalkan investasi awal tetapi menghasilkan biaya perbaikan yang melonjak drastis dan *downtime* tidak terencana yang mengganggu kontinuitas produksi, sementara pendekatan preventif mengurangi kegagalan mendadak namun berisiko menghasilkan pemeliharaan berlebih dengan penggantian komponen yang masih memiliki sisa umur operasional signifikan. Sebaliknya, *Predictive Maintenance* sebagai evolusi strategis memanfaatkan estimasi kondisi real-time untuk mengoptimalkan interval pemeliharaan, mencapai keseimbangan yang belum pernah dicapai antara frekuensi intervensi minimal dan biaya operasional maksimal.

Penelitian Hector & Panjanathan, (2024) menekankan bahwa transformasi menuju sistem PdM dalam ekosistem Industri 4.0 memerlukan integrasi terkoordinasi teknologi IoT, *algoritma machine learning, big data analytics*, dan infrastruktur cloud computing untuk memungkinkan pemantauan kondisi berkelanjutan dan prediksi kegagalan proaktif. Kajian sistematis mengidentifikasi lima tahapan operasional kritis dalam siklus hidup implementasi PdM: (1) artikulasi kebutuhan proyek dan pemahaman menyeluruh tentang karakteristik sistem target, (2) akuisisi dan preparasi data dari berbagai sensor dan sumber, (3) pemodelan prediktif dengan seleksi algoritma yang dioptimalkan untuk karakteristik data spesifik, (4) evaluasi rigor dan implementasi terukur model dalam setting produksi, dan (5) mekanisme pengambilan keputusan berbasis prediksi yang

mengintegrasikan output algoritma dengan pemikiran manusia dan kendala operasional. Tinjauan sistematis yang lebih terkini oleh Taoufyq et al., (2025) menganalisis 68 publikasi peer-reviewed dari 2018-2024 dan mengidentifikasi gap signifikan dalam literatur PdM kontemporer: dominasi pendekatan berbasis data (26 dari 68 artikel) secara dramatis melampaui model berbasis fisika (5 artikel) dan berbasis pengetahuan (1 artikel), sementara hanya 5 artikel yang mengusulkan kombinasi dua pendekatan dan hanya 1 yang mengintegrasikan ketiga paradigma secara simultan, mengindikasikan bahwa aplikasi industri manufaktur seharusnya memanfaatkan arsitektur hybrid yang menyatukan adaptabilitas model berbasis data dengan akurasi fundamental model berbasis fisika dan relevansi kontekstual model berbasis pengetahuan.

Distribusi Weibull telah menjadi standar de facto dalam analisis keandalan komponen industri selama puluhan tahun karena fleksibilitas parameteriknya yang luar biasa dalam memodelkan berbagai pola laju kegagalan yang dijumpai dalam praktik rekayasa. Penelitian Nketiah, (2021) mempresentasikan metodologi inovatif untuk estimasi parameter distribusi Weibull tiga-parameter menggunakan optimasi *particle swarm* (PSO), yang melampaui pendekatan konvensional Maximum Likelihood Estimation (MLE). Parameter bentuk β dalam formulasi distribusi Weibull menentukan secara fundamental karakteristik dinamika degradasi komponen: ketika $\beta < 1$ mengindikasikan *early mortality failures* dengan laju kegagalan yang menurun (karakteristik cacat manufaktur atau masalah perakitan), $\beta = 1$ menunjukkan random failures dengan laju konstan (tipikal dari periode umur berguna komponen dengan laju kerusakan acak stokastik), dan $\beta > 1$ menandakan wear-out failures dengan laju kegagalan yang meningkat secara monoton seiring akumulasi jam operasi (karakteristik fase degradasi progresif komponen mekanis). Parameter skala η, dikenal sebagai *characteristic life*, merepresentasikan waktu operasi ketika 63,2 persen dari populasi unit mengalami kegagalan, memberikan indikasi kuantitas tentang ketahanan komponen.

Penelitian (Nketiah, 2021). menunjukkan bahwa optimasi berbasis PSO menghasilkan estimasi parameter yang lebih stabil dan konsisten dibandingkan MLE konvensional, terutama dalam skenario dengan dataset terbatas yang umum dijumpai

dalam konteks industri lokal. Kontribusi metodologis tambahan dari literatur mencakup pengenalan distribusi Weibull empat-parameter dan versi modifikasi yang dapat menangkap fenomena kompleks seperti *hazard rate* berbentuk "*bathtub*", pola yang merepresentasikan perjalanan hidup operasional komponen yang sesungguhnya dengan fase mortalitas awal, periode keandalan konstan, dan akhirnya fase aus progresif Shama et al., (2023). Estimasi parameter umumnya menggunakan metode Maximum Likelihood Estimation (MLE) yang dipilih karena sifat asimptotik optimal dan non-bias, dikomplementasikan dengan validasi kesesuaian distribusi menggunakan uji statistik terstandar seperti Anderson-Darling Test dan Kolmogorov-Smirnov Test. Pengembangan metodologis dalam konteks data tersensor (censored data) yang umum dalam praktik pemeliharaan industri juga menjadi area penelitian aktif, memungkinkan estimasi parameter robust bahkan ketika observasi kegagalan belum lengkap atau masih dalam proses (Li et al., 2020).

Penelitian Tiddens et al., (2023) mengembangkan kerangka kerja pengambilan keputusan berjenjang untuk mendukung pemilihan metode pemeliharaan prediktif yang optimal dalam setting industri praktis, mengakui bahwa meskipun literatur akademis menyediakan berbagai metode pemeliharaan, praktisi masih menghadapi kesulitan substansial dalam navigasi kompleksitas pemilihan yang tepat. Penelitian mengidentifikasi tiga kesulitan utama yang secara konsisten dihadapi oleh organisasi industri: (1) ketiadaan pedoman sistematis untuk memilih metode pemeliharaan spesifik di level operasional di antara rangkaian luas alternatif teknis yang tersedia, (2) ketidaksesuaian fundamental antara tingkat ambisi organisasi untuk transformasi menuju pemeliharaan prediktif dan karakteristik data yang sebenarnya tersedia dalam operasi produksi (baik dalam hal kuantitas, kualitas, maupun granularitas temporal), dan (3) kompleksitas organisasional dalam mengintegrasikan berbagai tipe data heterogen (data struktural, waktu seri, event discrete) dengan teknik monitoring yang berbeda-beda (*vibration monitoring, thermography, oil analysis, performance metrics*). Kerangka kerja yang diusulkan membantu organisasi secara sistematis menentukan tingkat ambisi pemeliharaan yang realistis berdasarkan konteks operasional (berkisar dari pendekatan berbasis waktu tetap hingga *condition-based dan fully predictive*), mengklasifikasikan

tipe dan kualitas data yang tersedia, dan secara metodis memilih metode yang selaras dengan kombinasi keunikan sistem target dan kapabilitas organisasi yang ada.

Pendekatan terstruktur ini terbukti sangat bermanfaat bagi konteks industri manufaktur lokal Indonesia yang sering menghadapi keterbatasan sumber daya investasi teknologi, keahlian analitik yang sedang berkembang, dan kebutuhan untuk implementasi transformasi pemeliharaan secara bertahap dan inkremental. Penelitian empiris menunjukkan bahwa organisasi yang mengikuti kerangka kerja metodis mengurangi risiko implementasi berlebihan (*over-engineering*) dan mengalami waktu payback investasi teknologi yang lebih singkat. Pendukung kerangka kerja ini termasuk validasi melalui empat studi kasus industri yang mencakup sistem yang sangat berbeda (kapal angkatan perang, reaktor nuklir, mesin turbofan penerbangan, dan rangkaian perkeretaapian) yang semuanya menunjukkan relevansi universal pendekatan.

Dimensi penting dari literatur *maintenance* adalah pengembangan model optimasi yang mengkonversi estimasi keandalan komponen (berbasis Weibull atau distribusi probabilistik lainnya) menjadi rekomendasi operasional konkret tentang waktu penggantian optimal. Model *age replacement* menggunakan prinsip ekonomis fundamental bahwa terdapat *trade-off* rasional antara biaya pemeliharaan preventif (penggantian atau perbaikan proaktif) dan biaya korektif (perbaikan emergensi setelah kegagalan, termasuk dampak *downtime* yang tidak diperhitungkan secara penuh oleh manajemen tradisional). Formulasi matematis mengoptimalkan interval penggantian T* yang meminimalkan rata-rata biaya jangka panjang per satuan waktu, dengan mempertimbangkan biaya penggantian preventif per intervensi, biaya perbaikan korektif yang seringkali jauh lebih tinggi, dan dampak ekonomis dari *downtime* tak terduga terhadap produktivitas sistem (Umamaheswari et al., 2021). Penelitian terdokumentasi menunjukkan bahwa dengan menetapkan target reliabilitas sistem pada kisaran 50-60 persen pada interval penggantian yang direkomendasikan, perusahaan mencapai keseimbangan ekonomis optimal antara pencegahan *downtime* dan penghindaran pemeliharaan berlebih. Revolusi dalam aplikasi pemeliharaan prediktif telah dipercepat oleh kedatangan algoritma pembelajaran mesin dan pembelajaran mendalam yang dapat mengekstrak pola kompleks dari volume besar data sensor real-time. Literatur

kontemporer mendokumentasikan spektrum luas algoritma yang tersedia: dari metode klasik machine learning seperti Support Vector Machine (SVM), Random Fores*t* (RF), dan K-Nearest Neighbors (KNN) yang telah terbukti efektif untuk tugas klasifikasi kondisi dan estimasi Remaining Useful Life dasar, hingga arsitektur *deep learning* yang *sophisticated* seperti Convolutional Neural Networks (CNN), Long Short-Term Memory (LSTM), dan variannya yang dapat menangani pola temporal kompleks dalam data deret waktu multivariat. Penelitian Hector & Panjanathan, 2024) menyoroti bahwa dalam tiga tahun terakhir, perhatian akademis secara bertahap bergeser menuju pendekatan pembelajaran mendalam, terutama setelah demonstrasi bahwa arsitektur seperti LSTM dapat secara signifikan mengungguli metode tradisional dalam memprediksi RUL mesin pada dataset skala industri standar (misalnya CMAPSS NASA *engine degradation* dataset).

Kontribusi inovatif terkini dalam literatur *predictive maintenance* mencakup integrasi arsitektur Autoencoder dengan *Long Short-Term Memory* (LSTM) untuk pembelajaran fitur otomatis yang mampu mereduksi noise dan dimensionalitas data sekaligus mempertahankan struktur temporal sinyal operasional (Dou et al., 2022). Selain itu, sejumlah studi mengusulkan pemanfaatan *transfer learning* dan *Generative Adversarial Networks* (GAN) untuk mengatasi keterbatasan dan ketimpangan data kegagalan. Namun demikian, penerapan pendekatan PdM berbasis pembelajaran mendalam di lingkungan industri masih menghadapi tantangan signifikan, termasuk ketimpangan kelas data, perubahan pola degradasi akibat concept drift, serta kebutuhan akan keahlian dan sumber daya komputasi yang relatif tinggi, sehingga membatasi adopsinya di banyak sistem manufaktur.

Pendekatan komplementer yang dikenal sebagai *delay-time analysis*, seperti yang dirinci dalam penelitian Tiwari et al., (2022), mengintegrasikan konsep bahwa antara deteksi awal degradasi komponen melalui inspeksi hingga kegagalan fungsional terdapat "jendela waktu" di mana intervensi pemeliharaan dapat dilaksanakan. Analisis *delay-time* menggabungkan formulasi matematis berbasis probabilistik dengan algoritma optimasi metaheuristik (seperti *Multi-Objective Genetic Algorithm*) untuk menentukan frekuensi inspeksi dan kriteria keputusan penggantian yang secara simultan meminimalkan biaya

pemeliharaan total dan waktu *downtime*. Studi implementasi di unit *foundry* dan fasilitas manufaktur kompleks menunjukkan bahwa pendekatan *delay-time* menghasilkan pengurangan *downtime* pemeliharaan sebesar lebih dari 40 persen dibandingkan dengan jadwal pemeliharaan berbasis waktu tetap tradisional, dengan memberikan kontrol biaya yang ketat. Metodologi ini sangat applicable untuk sistem manufaktur serial Indonesia karena menyediakan mekanisme sistematis untuk menangani *trade-off* biaya-keandalan dalam kondisi operasional yang sangat variabel.

Literatur lokal Indonesia berkontribusi bukti empiris berharga tentang aplikabilitas metodologi pemeliharaan prediktif dan berbasis keandalan dalam konteks operasional lokal yang spesifik. Penerapan *Reliability Centered Maintenance* (RCM) terintegrasi dengan *Failure Mode and Effects Analysis* (FMEA) telah didokumentasikan di berbagai fasilitas manufaktur lokal, dari unit pendingin (*Air Handling Unit*), mesin curing untuk industri otomotif, hingga peralatan pemrosesan limbah organik. Penelitian Marimin & Zulna, (2022) di Institut Pertanian Bogor yang menganalisis interval pemeliharaan *Unit Fuel Handling System* menemukan bahwa penerapan RCM meningkatkan keandalan komponen *electromotor* sebesar 12 persen (dari 50 persen menjadi 62 persen), chain coupling sebesar 32 persen, dan gearbox sebesar 8 persen, dengan rekomendasi frekuensi inspeksi berkala yang specific untuk setiap komponen kritis.

Studi empiris tambahan menggunakan distribusi Weibull untuk analisis data kegagalan historis dari mesin produksi lokal menemukan bahwa parameter bentuk β sering berkisar antara 1.2 hingga 2.8, mengindikasikan bahwa mayoritas mesin lokal beroperasi dalam fase *wear-out* dengan laju kegagalan yang meningkat—implikasi operasional penting bahwa jadwal pemeliharaan preventif konvensional yang fixed-interval seringkali kurang optimal dan dapat ditingkatkan melalui age replacement models. Penelitian pada sistem pompa pendingin di fasilitas infrastruktur (PDAM) mengidentifikasi bahwa packing menyumbang 61.54 persen dari total biaya pemeliharaan dan menentukan interval penggantian 23 hari menggunakan pendekatan age replacement berbasis distribusi probabilistik menghasilkan penghematan biaya sebesar 27 persen (dari Rp158 juta menjadi Rp115 juta per periode). Temuan-temuan ini mengkonfirmasi bahwa metodologi analitik berbasis keandalan yang sophisticated, ketika diterapkan dengan

disiplin pada data historis lokal, menghasilkan rekomendasi operasional konkret dengan dampak ekonomis terukur dan terverifikasi.

Studi implementasi machine learning pada data bearing dari mesin berputar industri menunjukkan bahwa algoritma K-Nearest Neighbors menghasilkan akurasi prediksi yang impressive dengan MAPE 4.44 persen dan R-squared 0.849 ketika features diekstraksi dari sinyal vibration menggunakan transformasi Fourier dan dekomposisi wavelet. Penelitian pada sistem *extrusion automotive* menggunakan *Reliability Block Diagram* dan simulasi *software* khusus menemukan bahwa keandalan sistem keseluruhan hanya 0.436 persen pada 100 jam operasi, mengidentifikasi equipment kritis seperti Cooling Batch dan microwave drying yang menjadi *bottleneck—insight* yang langsung dapat digunakan untuk prioritas investasi pemeliharaan.

2.2 *Research Gap*

Untuk mengidentifikasi celah penelitian dan menunjukkan posisi penelitian ini dibandingkan penelitian terdahulu, disusun matriks *research gap* sebagaimana ditunjukkan pada Tabel 2.1.

Tabel 2. 1 Pemetaan Penelitian Terdahulu dan Posisi Penelitian

Penulis	Weibull Distribution	Reliability Engineering	Predictive Maintenance	*Age Replacement*	MTBF/ MTTR	*Manufacturing Systems*
(Zhu et al., 2024)	✓	✓	✓		✓	✓
(Hector & Panjanathan, 2024)		✓	✓			✓
(Taoufyq et al., 2025)		✓	✓			✓
(Nketiah, 2021)	✓	✓				
(Tiddens et al., 2023)		✓	✓			✓
(Shama et al., 2023)	✓	✓				
(Tiwari et al., 2022)		✓	✓	✓	✓	✓
(Dou et al., 2022)		✓	✓			
(Kamariotis et al., 2024)		✓	✓			
(Marimin & Zulna, 2022)	✓	✓			✓	✓

Penulis	Weibull Distribution	Reliability Engineering	Predictive Maintenance	*Age Replacement*	MTBF/ MTTR	*Manufacturing Systems*
(Octavia & Rusindiyanto, 2025)	✓	✓		✓	✓	✓
(Afdal & Linarti, 2023)		✓	✓			✓
(Diocta & Bangun, 2024)	✓	✓			✓	✓
(Taimun et al., 2025)		✓	✓			✓
Penulis (2026)	✓	✓	✓	✓	✓	✓

Tabel 2.1 menunjukkan bahwa penelitian terdahulu umumnya membahas *reliability engineering* dan *predictive maintenance*, namun integrasi Weibull–reliability metrics–*age replacement* pada sistem mesin serial dengan pertimbangan biaya masih terbatas. Penelitian ini mengisi celah tersebut melalui pemodelan Weibull, penyusunan *reliability grid*, dan optimisasi interval pemeliharaan berbasis *cost rate*.

2.3 Landasan Teori

2.3.1 *Reliability Engineering.*

Reliability engineering adalah disiplin ilmu yang berfokus pada probabilitas bahwa suatu sistem atau peralatan dapat menjalankan fungsinya secara memuaskan dalam periode waktu tertentu di bawah kondisi operasi yang telah ditentukan (Zhu et al., 2024). Dalam konteks industri manufaktur, *reliability* menjadi indikator kritis untuk mengukur kinerja peralatan produksi dan menentukan strategi pemeliharaan yang efektif.

Reliability engineering mencakup analisis menyeluruh terhadap sifat-sifat sistem teknis sepanjang daur hidupnya, termasuk *dependability* (kemampuan sistem untuk menjalankan fungsi yang diminta), *maintainability* (kemampuan sistem untuk diperbaiki dan dirawat), serta *availability* (proporsi waktu dimana sistem dapat beroperasi dengan baik) (Taoufyq et al., 2025). Dalam konteks industri manufaktur Indonesia, penerapan reliability engineering memiliki peran strategis karena berkaitan langsung dengan peningkatan produktivitas mesin, pencegahan kerusakan pada komponen kritis, serta pengendalian biaya operasional secara keseluruhan.

Seiring perkembangan industri, strategi pemeliharaan peralatan telah mengalami pergeseran dari pendekatan yang bersifat reaktif menuju pendekatan yang lebih prediktif dan proaktif. (Zhu et al., 2024) mengelompokkan strategi pemeliharaan ke dalam tiga kategori utama, yaitu sebagai berikut:

1. *Reactive Maintenance* (RM)

   Reactive Maintenance atau *Run-to-Failure* adalah pendekatan pemeliharaan yang hanya dilakukan setelah mesin mengalami kerusakan atau berhenti berfungsi. Meskipun memberikan utilisasi maksimal, RM menghasilkan biaya perbaikan yang tinggi, *downtime* yang tidak terencana, dan risiko kerusakan tambahan pada komponen lain.

2. *Preventive Maintenance* (PM)

   Preventive Maintenance dilakukan secara terjadwal berdasarkan waktu atau jumlah penggunaan untuk mencegah kerusakan. Taoufyq et al., (2025) menjelaskan bahwa PM dilaksanakan bahkan ketika mesin masih dalam kondisi operasional normal untuk menghindari *breakdown* yang tidak terduga beserta biaya dan *downtime* yang menyertainya. Namun, pendekatan ini dapat mengakibatkan pemeliharaan yang tidak perlu (*over-maintenance*) karena interval yang ditentukan sering kali bersifat konservatif dan tidak spesifik terhadap kondisi operasional aktual.

3. *Predictive Maintenance* (PdM)

   Predictive Maintenance, juga dikenal sebagai *Condition-Based Maintenance* (CBM), bertujuan memprediksi kapan peralatan kemungkinan akan gagal dan menentukan aktivitas pemeliharaan yang diperlukan (Zhu et al., 2024). PdM menggunakan data operasional *real-time* untuk mengoptimalkan strategi *Operation & Maintenance* (O&M) memungkinkan perusahaan melakukan maintenance hanya ketika benar-benar diperlukan. Dengan memanfaatkan teknologi *Internet of Things* (IoT), *machine learning, big data analytics,* dan *cloud* computing, PdM memungkinkan monitoring real-time terhadap kondisi peralatan dan prediksi kegagalan sebelum terjadi.

2.3.2 *Mean Time Between Failures* dan *Mean Time to Failure.*

Mean Time Between Failures (MTBF) adalah metrik fundamental dalam *reliability engineering* yang mengukur rata-rata waktu antara dua kegagalan berurutan pada sistem yang dapat diperbaiki (*repairable system*). MTBF dihitung sebagai rasio antara total waktu operasi terhadap jumlah kegagalan yang terjadi (Othman, 2024):

$$MTBF = \frac{Total\ Operating\ Time}{Number\ of\ Failures} \tag{2.1}$$

Othman (2024) menekankan bahwa MTBF merupakan parameter penting dalam perencanaan pemeliharaan, terutama untuk menentukan interval pemeliharaan preventif yang optimal. Semakin tinggi nilai MTBF, semakin baik keandalan mesin. Namun, perlu dipahami bahwa pada distribusi eksponensial dengan *failure rate* konstan, probabilitas sistem bertahan hingga MTBF adalah $1 - e^{-1} \approx 0.63$ (63%), yang berarti MTBF bukan merupakan jaminan durasi minimum operasi, melainkan hanya merepresentasikan mean atau rata-rata.

Mean Time to Failure (MTTF) digunakan untuk sistem yang tidak dapat diperbaiki (*non-repairable system*), mengukur rata-rata waktu sampai sistem mengalami kegagalan pertama. MTTF dihitung sebagai nilai ekspektasi dari fungsi keandalan):

$$MTTF = \int_0^\infty R(t)dt \tag{2.2}$$

dimana R(t) adalah fungsi keandalan pada waktu t.

2.3.3 *Predictive Maintenance.*

Predictive Maintenance (PdM) adalah strategi pemeliharaan yang menggunakan data kondisi *real-time* untuk memprediksi kapan peralatan akan gagal dan menentukan aktivitas pemeliharaan yang diperlukan. Taoufyq et al. (2025) menjelaskan bahwa PdM merupakan evolusi strategis dari pendekatan pemeliharaan tradisional yang mengubah paradigma dari pendekatan reaktif atau preventif berjadwal menjadi pendekatan berbasis kondisi aktual peralatan. Zhu et al. (2024) mengidentifikasi empat proses utama yang membentuk kerangka kerja Predictive Maintenance, yaitu *condition monitoring*, *fault diagnosis*, *fault prognosis*, dan *maintenance planning*.

Condition monitoring berfokus pada pengumpulan dan analisis data dari sensor yang terpasang pada mesin untuk memantau kondisi operasional secara berkelanjutan. Tahap selanjutnya adalah fault diagnosis, yang bertujuan mengidentifikasi jenis dan penyebab kerusakan yang terjadi. Fault prognosis dilakukan untuk memperkirakan *Remaining Useful Life* (RUL) komponen atau peralatan, sedangkan *maintenance planning* digunakan untuk menyusun jadwal dan jenis aktivitas pemeliharaan berdasarkan hasil prediksi kegagalan tersebut.

Lebih lanjut, (Taoufyq et al., 2025) menekankan pentingnya penerapan *hybrid approaches* dalam PdM, yaitu pendekatan yang mengombinasikan metode *physics-based* dan *data-driven prognostics* untuk memanfaatkan keunggulan masing-masing metode. Model hibrida ini dapat diklasifikasikan menjadi dua kategori utama, yaitu *series techniques* dan *parallel techniques*. Pada *series techniques*, model fisik digunakan untuk membangun pengetahuan awal (*prior knowledge*), kemudian metode berbasis data berperan sebagai *state estimator*. Sementara itu, pada *parallel techniques*, model berbasis data digunakan untuk memprediksi residual yang tidak dapat dijelaskan oleh *first-principle models*.

Tiddens et al., (2023) mengonfirmasi bahwa penerapan *Predictive Maintenance* mampu menurunkan *planned* dan *unplanned downtime*, mengurangi biaya pemeliharaan yang tinggi, menekan kebutuhan inventori yang tidak perlu, serta meminimalkan aktivitas pemeliharaan yang tidak bernilai tambah. Meskipun demikian, PdM memiliki tantangan awal berupa kebutuhan *initial investment* yang relatif tinggi, khususnya untuk pengadaan perangkat *condition monitoring* seperti sensor dan infrastruktur pendukung lainnya, dibandingkan dengan pendekatan *reactive maintenance* dan *preventive maintenance*.

2.3.4 *Weibull Distribution.*

Distribusi Weibull, yang dikembangkan oleh Waloddi Weibull pada tahun 1937, adalah alat statistik fundamental untuk memodelkan data waktu-ke-kegagalan (*time-to-failure*) dalam *reliability engineering* dan telah menjadi standar industri untuk berbagai aplikasi (Othman, 2024). Distribusi Weibull sangat versatile dan dapat menggambarkan berbagai pola kegagalan dalam sistem teknis, mulai dari *early-life failures* hingga *wear-out failures*.

(Putranugraha & Garniwa, 2025) menekankan bahwa distribusi Weibull memiliki fleksibilitas parametrik yang unik untuk memodelkan berbagai pola laju kegagalan. Dalam manufaktur, distribusi Weibull digunakan untuk memodelkan:

- Waktu kegagalan komponen mesin,
- Durabilitas material,
- Umur pakai (*lifetime*) peralatan industri, serta
- Pola *wear-out* dan degradasi sistem.

Distribusi Weibull memiliki dua parameter utama, yaitu shape parameter (β) dan scale parameter (η). Shape parameter (β) menentukan bentuk distribusi serta karakteristik laju kegagalan dengan interpretasi sebagai berikut:

1. Shape Parameter (β): Menentukan bentuk distribusi dan pola laju kegagalan dengan interpretasi kunci:
    - $\beta < 1$: Tingkat kegagalan menurun (*early mortality failures*),
    - $\beta = 1$: Tingkat kegagalan konstan (*random failures*),
    - $\beta > 1$: Tingkat kegagalan meningkat (*wear-out failures*),
    - $\beta > 1$: *Rapid wear-out behavior* dengan akselerasi aging.
2. Scale Parameter (η): Merepresentasikan *characteristic life*, yaitu waktu pada saat 63.2%-unit telah mengalami kegagalan. Secara matematis: $R(\eta) = ekp(-1) \approx 0{,}368$.

Fungsi kepadatan probabilitas untuk Distribusi Weibul dua-parameter adalah (Othman, 2024):

$$f(t) = \left(\frac{\beta}{\eta}\right) \times \left(\frac{t}{\eta}\right)^{\beta-1} \times \exp\left(-\left(\frac{t}{\eta}\right)^{\beta}\right), untuk\ t\ \geq\ 0 \tag{2.3}$$

Fungsi distribusi kumulatif (*Cumulative Distribution Function*) Weibull dinyatakan sebagai:

$$F(t) = \ 1\ - \exp\left(-\left(\frac{t}{\eta}\right)^{\beta}\right) \tag{2.4}$$

2.3.5 *Reliability Function* dan *Failure Function* dalam *Weibull Distribution.*

Reliability function $R(t)$ pada distribusi Weibull menunjukkan probabilitas bahwa suatu sistem dapat beroperasi tanpa mengalami kegagalan hingga waktu t, dan didefinisikan sebagai sebagai:

$$R(t) = \exp\left(-\left(\frac{t}{\eta}\right)^{\beta}\right) \tag{2.5}$$

Fungsi ini menunjukkan probabilitas bahwa sistem akan bertahan tanpa kegagalan hingga waktu t. Sementara itu, *Failure function* $F(t)$ merupakan komplemen dari *reliability function* probabilitas bahwa sistem mengalami kegagalan sebelum atau pada waktu t, yang dirumuskan sebagai:

$$F(t) = 1 - R(t) = 1 - \exp\left(-\left(\frac{t}{\eta}\right)^{\beta}\right) \tag{2.6}$$

Selain itu, *hazard rate function* atau *failure rate function* $\lambda(t)$ pada distribusi Weibull menyatakan tingkat kegagalan sesaat (*instantaneous failure rate*) pada waktu t, dengan syarat bahwa sistem telah bertahan hingga waktu tersebut. Fungsi laju kegagalan dinyatakan sebagai:

$$\lambda(t) = \left(\frac{\beta}{\eta}\right) \times \left(\frac{t}{\eta}\right)^{\beta-1} \tag{2.7}$$

Karakteristik penting adalah bahwa ketika $\beta < 1: \lambda(t)$ menurun seiring waktu, ketika $\beta = 1: \lambda(t)$ konstan (*random failure behavior*), dan ketika $\beta > 1: \lambda(t)$ laju kegagalan meningkat seiring bertambahnya waktu operasi (*wear-out behavior*)

2.3.6 *Regresi Linear Sederhana.*

Estimasi parameter Distribusi Weibull dapat dilakukan melalui berbagai metode, dengan regresi linear menjadi pendekatan praktis yang valid untuk konteks industri manufaktur. Nketiah et al. (2021) membandingkan *Maximum Likelihood Estimation* (MLE) dan regresi linear, menemukan bahwa untuk ukuran sampel 30-50 observasi, kedua metode menghasilkan estimasi parameter dengan perbedaan kurang dari 3%.

Untuk suatu dataset waktu kegagalan yang terdiri dari $t_1, t_2, \ldots t_n$, desinisi variabel transformasi dinyatakan sebagai:

$$X = \ln F(t) \tag{2.8}$$

$$Y = \ln\left(-\ln\left(1 - F(t)\right)\right) \tag{2.9}$$

Dari persamaan transformasi linear di atas, diperoleh model regresi sederhana Y = βx + a, di mana β (*slope*) merepresentasikan parameter bentuk (*shape*) dan a (*intercept*) digunakan untuk menghitung parameter skala dengan rumus:

$$\eta = \exp\left[-\frac{a}{\beta}\right] \tag{2.10}$$

Estimasi parameter dilakukan melalui fungsi regresi pada Microsoft Excel dengan rumus *slope* dan *intercept* yang memberikan estimasi langsung dan akurat untuk analisis Distribusi Weibull.

Prosedur perhitungan mencakup: (1) pengurutan data TBF secara *ascending*, (2) estimasi F(t) menggunakan *median rank*, (3) transformasi linear menggunakan persamaan (2.8) dan (2.9), serta (4) regresi *least-squares* untuk ekstraksi parameter. Pendekatan ini dipilih karena aksesibilitas, validitas untuk n=44 observasi, dan kemudahan replikasi industri.

2.3.7 Koefisien Determinasi (R^2) dan Validasi Model Weibull.

Setelah parameter Distribusi Weibull diestimasi menggunakan metode regresi linear sederhana, langkah kritis berikutnya adalah memvalidasi kesesuaian (*goodness-of-fit*) model terhadap data empiris. Koefisien determinasi (R^2) merupakan ukuran statistik yang menunjukkan proporsi variasi data yang dapat dijelaskan oleh model regresi.

Nilai R^2 dihitung menggunakan persamaan:

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2} \tag{2.11}$$

Di mana:

- y_i adalah nilai observasi
- $\hat{y}_i$ adalah nilai prediksi dari model
- $\bar{y}$ adalah rata-rata nilai observasi

Dalam konteks analisis Distribusi Weibull, R^2 mengukur seberapa baik garis regresi linear pada *Weibull Probability Plot* menjelaskan variasi data kegagalan yang telah ditransformasi. Nilai R^2 berkisar antara 0 hingga 1, di mana nilai mendekati 1 menunjukkan model yang sangat sesuai dengan data empiris.

Interpretasi nilai R^2 untuk validasi Distribusi Weibull:

- $R^2 > 0{,}95$: Model Weibull sangat sesuai (*excellent fit*).
- $0{,}90 < R^2 < 0{,}95$: Model Weibull sesuai (*good fit*).
- $R^2 \leq 0{,}90$: Model perlu evaluasi lebih lanjut atau pertimbangkan distribusi alternatif.

2.3.8 *Maintenance Interval Determination* Berbasis *Reliability Target.*

Penentuan interval pemeliharaan prediktif yang optimal memerlukan pendekatan sistematis yang mempertimbangkan *trade-off* antara *reliability* target dan frekuensi *maintenance intervention*. *Reliability* target yang umum ditetapkan dalam industri berkisar 85%-95%.

Dengan menggunakan *reliability function* $R(t)$ dari model Weibull, interval pemeliharaan dapat ditentukan berdasarkan waktu t ketika nilai reliabilitas mencapai ambang batas (*threshold*) yang ditetapkan. Sebagai contoh, apabila *reliability* target ditetapkan sebesar $R(t) = 0{,}90$:

$$\exp\left(-\left(\frac{t}{\eta}\right)^{\beta}\right) = 0.90 \tag{2.12}$$

Dengan menyelesaikan Persamaan (2.14), diperoleh waktu interval pemeliharaan sebagai berikut:

$$\exp\left(-\left(\frac{t}{\eta}\right)^{\beta}\right) = 0.90 \tag{2.13}$$

Nilai waktu t yang diperoleh merepresentasikan interval pemeliharaan prediktif yang direkomendasikan, sehingga pemeliharaan dapat dilakukan sebelum reliabilitas sistem turun di bawah target yang ditetapkan.

2.3.9 *System Reliability Analysis* Untuk Sistem Serial.

Pada sistem manufaktur dengan konfigurasi mesin serial, keandalan sistem secara keseluruhan sangat dipengaruhi oleh keandalan setiap komponen penyusunnya. Dalam

konfigurasi ini, sistem hanya dapat beroperasi apabila seluruh komponen berada dalam kondisi berfungsi. Secara matematis, keandalan sistem serial didefinisikan sebagai:

$$R_{\text{system}}(t) = \prod_{\text{i}}^{=1\text{n}} R_{\text{i}}(t) \tag{2.14}$$

di mana $R_{\text{i}}(t)$ adalah reliabilitas komponen ke-i pada waktu t, dan n adalah jumlah komponen dalam sistem.

Implikasi praktis dari konfigurasi serial adalah bahwa kegagalan satu komponen saja dapat menyebabkan kegagalan keseluruhan sistem. Selain itu, nilai *reliability* sistem akan semakin menurun seiring bertambahnya jumlah komponen. Oleh karena itu, pada sistem serial, upaya peningkatan keandalan dan perencanaan pemeliharaan sebaiknya difokuskan pada komponen dengan nilai reliabilitas terendah, yang berperan sebagai bottleneck dalam sistem.

2.3.10 Konteks Industri Manufakur Indonesia.

Taoufyq et al. (2025) mengidentifikasi empat kategori utama tantangan dalam implementasi *predictive maintenance* (PdM) pada lingkungan industri, khususnya di negara berkembang, termasuk Indonesia, yaitu sebagai berikut:

1. *Financial and Organizational Limits*

   Untuk mengimplementasikan *predictive maintenance*, perusahaan harus bersedia memanfaatkan sumber daya dan biaya yang besar. Tidak semua perusahaan memiliki kesiapan finansial dan komitmen organisasi yang memadai. Beberapa perusahaan menghindari hal tersebut karena pertimbangan keterbatasan anggaran, prioritas strategis yang berbeda, atau belum adanya visi jangka panjang terkait transformasi pemeliharaan berbasis data.

2. *Data Source Limits*

   Ketika kepercayaan yang diperlukan terhadap data tidak terjaga, misalnya ketika sensors, controllers, atau sumber data lain memberikan pengukuran yang *erroneous* atau *inaccurate*, perusahaan yang menggunakan teknik *predictive maintenance* dapat mengalami kesulitan. Hal ini dapat menyebabkan prediksi yang tidak akurat, kebutuhan pemeliharaan yang terlewat, dan alert yang salah.

3. *Machine Repair Activity Limits*

Meskipun jadwal pemeliharaan dapat direncanakan berdasarkan estimasi *remaining useful life* (RUL) komponen, pelaksanaan pemeliharaan di lapangan masih menghadapi berbagai kendala. Aktivitas perbaikan sangat bergantung pada interaksi manusia, ketersediaan teknisi, serta keterbatasan *self-maintenance capability* pada mesin. Faktor-faktor ini dapat menyebabkan ketidaksesuaian antara rekomendasi sistem PdM dengan realisasi pemeliharaan aktual.

3. *Limitations in Industrial PdM Model Deployment*

   Pengembangan *intelligent failure prediction* models biasanya melibatkan tiga tahap utama yang kompleks, yaitu *monitoring*, *integration*, dan *updating*. Tantangan terbesar sering muncul pada tahap integrasi model, karena pengelolaan sistem PdM biasanya berada di bawah tanggung jawab tim IT, sementara pengembangan model analitik dilakukan oleh tim R&D atau *data science*. Kurangnya koordinasi lintas fungsi ini dapat menghambat penerapan model PdM secara efektif dan berkelanjutan di lingkungan produksi.

BAB III
METODE PENELITIAN

3.1 Objek Penelitian

Objek penelitian merupakan segala sesuatu yang dijadikan sebagai sasaran suatu penelitian. Adapun objek penelitian pada penelitian kali ini ialah Mesin Sistem Obeng Torsi pada rangkaian mesin serial yang digunakan oleh PT. XYZ.

3.2 Jenis Data Penelitian

Penelitian ini menggunakan data sekunder yang diperoleh dari PT. XYZ serta didukung oleh kajian pustaka. Data sekunder digunakan sebagai dasar analisis reliabilitas dan penentuan interval pemeliharaan, sedangkan kajian pustaka digunakan untuk memperkuat landasan teori dan metodologi penelitian.

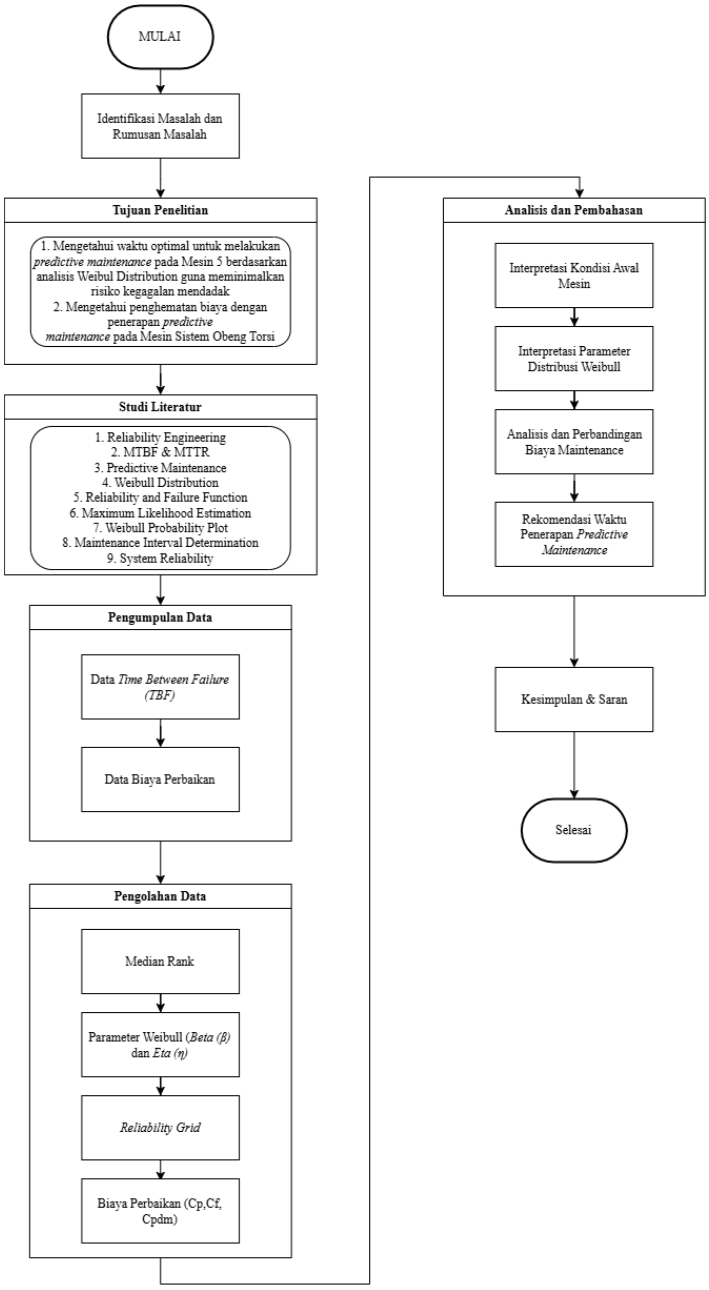
Data sekunder yang digunakan dalam penelitian ini meliputi:

a. Data spesifikasi mesin
b. Data historis kerusakan mesin
c. Data aktivitas perbaikan
d. Data frekuensi dan waktu kegagalan (*time to failure*)
e. Data distribusi kegagalan

Kajian pustaka diperoleh dari buku teks, jurnal ilmiah, artikel penelitian, dan laporan teknis yang relevan dengan topik *reliability engineering* dan *predictive maintenance*.

3.3 Alur Penelitian

Berikut merupakan diagram alur penelitian yang digunakan pada penelitian ini, yang menggambarkan tahapan penelitian mulai dari pengumpulan data, pengolahan data reliabilitas, estimasi parameter distribusi Weibull, hingga penentuan *interval predictive maintenance:*



Gambar 3. 1 Alur Penelitian

Berikut merupakan penjelasan mengenai diagram alur penelitian di atas:

1. Mulai

   Tahap ini merupakan tahap awal penelitian, di mana peneliti mempersiapkan seluruh kebutuhan penelitian dan menentukan ruang lingkup penelitian yang akan dilakukan.

2. Identifikasi Masalah dan Perumusan Masalah

   Pada tahap ini dilakukan identifikasi terhadap permasalahan yang akan diteliti, yaitu permasalahan keandalan dan penentuan interval predictive maintenance pada Mesin Sistem Obeng Torsi dalam sistem mesin serial. Berdasarkan identifikasi tersebut, selanjutnya dirumuskan permasalahan penelitian secara sistematis.

3. Tujuan Penelitian

   Pada tahap ini dilakukan penetapan tujuan penelitian berdasarkan rumusan masalah yang telah disusun. Tujuan penelitian ditetapkan agar penelitian yang dilakukan memiliki arah yang jelas dan terfokus. Adapun tujuan dari penelitian ini adalah untuk mengetahui waktu yang optimal dalam melakukan *predictive maintenance* pada Mesin Sistem Obeng Torsi berdasarkan analisis *Weibull Distribution* guna meminimalkan risiko kegagalan mendadak, serta untuk mengetahui besarnya peningkatan reliabilitas mesin setelah diperolehnya waktu optimal pelaksanaan *predictive maintenance.*

4. Studi Literatur

   Pada tahap ini peneliti melakukan pengumpulan data yang dibutuhkan untuk analisis reliabilitas Mesin Sistem Obeng Torsi. Data diperoleh dari catatan historis perusahaan selama periode operasi tertentu berupa data *Time Between Failure* (TBF). Data dikumpulkan melalui dokumentasi log mesin dan formulir laporan kerusakan, kemudian diseleksi agar hanya data yang lengkap, konsisten, dan relevan dengan objek penelitian yang digunakan pada tahap selanjutnya.

5. Pengumpulan Data

   Pada tahap ini peneliti melakukan pengumpulan data yang dibutuhkan untuk analisis reliabilitas Mesin Sistem Obeng Torsi. Data ini diperoleh dari catatan historis perusahaan selama periode operasi tertentu, berupa data *Time Between Failure* (TBF) serta biaya melakukan *preventive* dan *corrective maintenance*. Data tersebut dikumpulkan secara dokumentasi dari perusahaan, log mesin dan formular laporan kerusakan, kemudian diseleksi agar hanya data yang lengkap, konsisten, dan relevan dengan objek penelitian yang digunakan pada tahap berikutnya.

6. Pengolahan Data

   Setelah data terkumpul, dilakukan pengolahan data awal untuk menyiapkan data agar dapat dianalisis menggunakan distribusi Weibull. Pada tahap ini dilakukan perhitungan statistik deskriptif untuk *Mean Time Between Failures* (MTBF) untuk menggambarkan kondisi awal keandalan Mesin Sistem Obeng Torsi. Selanjutnya, dihitung nilai *median rank* untuk setiap data TBF guna memperoleh nilai peluang kumulatif kegagalan $F(t)$ menggunakan Persamaan:

   Berdasarkan nilai tersebut, data kemudian ditransformasikan ke dalam bentuk linear dengan persamaan:

$$F(t) = \frac{i \; - \; 0{,}3}{n \; + \; 0{,}4} \tag{3. 1}$$

   Dengan keterangan:

   - $F(t)$: estimasi probabilitas kumulatif kegagalan pada waktu t
   - i: peringkat data TBF setelah di urutkan (1 untuk nilai terkecil hingga n untuk terbesar)
   - n: jumlah total data kegagalan (dalam penelitian ini $n = 44$)

   Nilai $F(t)$ yang diperoleh dari Persamaan (3.1) selanjutnya digunakan sebagai dasar dalam proses transformasi linear untuk membentuk Weibull Probability Plot serta estimasi parameter Distribusi Weibull menggunakan persamaan:

$$\mathrm{x} = ln(TBF) \tag{3. 2}$$

$$y = ln\left[-\ln\left(1 - F(t)\right)\right] \tag{3. 3}$$

   Hasil nilai *x* dan *y* ini selanjutnya digunakan pada tahap estimasi parameter Weibull.

7. Perhitungan Koefisien Determinasi.

   Pada tahap ini peneliti akan melakukan perhitungan koefisien determinasi (R^2) untuk mengetahui kesesuaian Model Weibull untuk memvalidasi kesesuaian model terhadap data empiris. Perhitungan (R^2) dilakukan dengan menggunakan persamaan berikut:

$$\mathrm{R}^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2} \tag{3. 4}$$

8. Estimasi Parameter Distribusi Weibull

   Pada tahap ini peneliti akan melakukan pemodelan Distribusi Weibull menggunakan data hasil transformasi. Analisis ini dilakukan dengan metode regresi linear sederhana di Microsoft Excel melalui fungsi *Slope* dan *Intercept* untuk memperoleh nilai kemiringan (*slope*) dan *intercept* garis regresi antara X dan Y. nilai *slope* diinterpretasikan sebagai parameter β, sedangkan *intercept* digunakan untuk menghitung parameter skala η dengan persamaan:

$$\beta = b \tag{3.5}$$

$$\eta = \exp\left[-\frac{a}{\beta}\right] \tag{3.6}$$

   Dengan keterangan:

   - β adalah shape Parameter
   - η adalah scale parameter

     Hasil estimasi parameter tersebut kemudian menjadi dasar pembentukan fungsi reliabilitas Mesin Sistem Obeng Torsi.

9. Perhitungan *Reliability Grid*

   Sebagai Langkah krusial dalam analisis *age replacement policy*, dilakukan pembuatan *reliability grid* untuk berbagai kandidat waktu perbaikan prediktif maupun preventif yang dibuat dengan mendiskritisasi rentang waktu operasional dari 1 hingga 200 jam menggunakan interval 1 jam, di mana setiap nilai R(t) dihitung berdasarkan parameter Distribusi Weibull yang telah di estimasi sebelumnya. Perhitungan ini meliputi perhitungan trapezoidal dari fungsi keandalan serta perhitungan kumulatif yang merepresentasikan probabilitas kegagalan sebelum t. berikut formula yang digunakan untuk menentukan *Reliability Grid*:

$$Segment\ Area\ (Trap) = \left(\frac{R(t_i) + R(t_{(i+1)})}{2}\right) x\ \Delta T \tag{3.7}$$

10. Perhitungan Optimasi *Predictive Maintenance*

    Tahap ini berisi perhitungan estimasi kumulatif siklus berdasarkan waktu (t), estimasi biaya total siklus, serta *cost rate* (g(T)) yang nantinya digunakan untuk mengetahui waktu terbaik melakukan *predictive maintenance* berdasarkan *cost rate* terendah. Penentuan *cost rate* per siklus dihitung menggunakan formula:

$$Cost\ Rate\ g(T) = \frac{Estimasi\ Biaya\ Total\ Siklus}{\text{Estimasi Kumulatif Waktu Siklus}} \tag{3.8}$$

11. Perhitungan *Expected Total Cost* Berdasarkan Kebijakan Perusahaan

    Tahap ini berisi perhitungan *Expected Total Cost* dengan menggunakan kebijakan perusahaan ketika reliabilitas mesin berada di nilai sekitar 90%. Dengan menggunakan kebijakan perusahaan ini, *Expected Total Cost* per siklus dihitung menggunakan formula:

$$Expected\ Total\ Cost = \frac{(Cp \times 0{,}9) + (Cf \times 0{,}1)}{E(L[T]), R_{(t)} \sim 90\%} \tag{3.9}$$

    Dengan keterangan:

    - C_p: biaya *preventive maintenance*.
    - C_f : biaya melakukan perbaikan saat mesin mengalami kegagalan.
    - E(L[T]),R(t))~90%: *expected cycle time*.

12. Perhitungan Biaya *Predictive Maintenance*

    Biaya *predictive maintenance* dihitung berdasarkan nilai terendah dari *grand total cost* g(T) yang dihasilkan melalui formula berikut:

$$g(T) = \frac{Expected\ Total\ Cost}{E(L[T])} \tag{3.10}$$

13. Analisis dan Pembahasan

Tahap ini berisi analisis dan interpretasi hasil pemodelan distribusi Weibull. Dengan menggunakan parameter β dan η, dihitung fungsi reliabilitas $R(t)$, fungsi peluang kumulatif kegagalan $F(t)$, dan laju kegagalan pada berbagai nilai waktu operasi. Model yang diperoleh divalidasi menggunakan Weibull Probability Plot dan nilai koefisien determinasi untuk memastikan kesesuaian model terhadap data aktual. Berdasarkan pola reliabilitas tersebut, peneliti mengklasifikasikan interval *predictive maintenance* yang dianggap optimal dengan mempertimbangkan level reliabilitas tertentu, misalnya rentang $R(t)$ sekitar 50-60%.

14. Kesimpulan dan Saran

    Pada tahap ini peneliti merangkum temuan utama penelitian terkait kondisi keandalan Mesin Sistem Obeng Torsi, nilai parameter distribusi Weibull yang diperoleh, serta interval waktu optimal untuk melakukan *predictive maintenance*. Kesimpulan disusun dengan menjawab rumusan masalah dan tujuan penelitian yang telah ditetapkan sebelumnya. Selain itu, peneliti Menyusun saran praktis bagi perusahaan terkait penerapan jadwal *predictive maintenance* yang direkomendasikan, serta saran akademik untuk penelitian selanjutnya, misalnya penambahan variable lain atau perbandingan dengan metode pemodelan reliabilitas yang berbeda.

15. Selesai

    Tahap terakhir menandai berakhirnya seluruh rangkaian kegiatan penelitian. Pada tahap ini seluruh analisis telah terdokumentasi dalam bentuk laporan skripsi, termasuk lampiran data, perhitungan, dan diagram pendukung. Peneliti kemudian mempersiapkan naskah akhir untuk proses seminar atau siding sebagai bentuk pertanggungjawaban ilmiah atas penelitian yang telah dilakukan.

BAB IV
PENGUMPULAN DAN PENGOLAHAN DATA

4.1 Pengumpulan Data

4.1.1 *Sumber dan Jenis Data.*

Data yang digunakan dalam penelitian ini berasal dari PT. XYZ, sebuah perusahaan manufaktur *sparepart*. Penelitian menganalisis data historis Mesin Sistem Obeng Torsi yang dikumpulkan selama periode enam bulan, yaitu dari Januari hingga Juni 2025.

Data utama yang dianalisis adalah data *Time Between Failure* (TBF), yang merepresentasikan interval waktu dalam jam antara satu kegagalan dan kegagalan berikutnya pada mesin. Dataset terdiri dari 44 kejadian kegagalan dengan interval waktu yang bervariasi antara 12 jam hingga 282,6 jam.

Selain data teknis, penelitian ini juga mempertimbangkan dimensi ekonomis pemeliharaan, khususnya biaya yang timbul akibat penerapan strategi pemeliharaan yang berbeda. Biaya *preventive maintenance* tercatat sebesar USD 400 per kegiatan, sedangkan biaya *corrective maintenance* mencapai USD 4.000 untuk setiap kejadian kegagalan. Perbedaan signifikan dalam biaya dengan ratio 1:10 menunjukkan bahwa implementasi strategi preventive maintenance yang optimal dapat menghasilkan penghematan biaya yang substansial dibandingkan dengan pendekatan pemeliharaan reaktif yang menangani kegagalan setelah terjadi.

4.1.2 *Perhitungan MTBF Preventive dan Corrective Maintenance.*

Penelitian ini mengumpulkan data operasional mesin sistem obeng torsi selama enam bulan (Januari hingga Juni 2025). Data mencakup dua variabel utama: jam operasi (*Operating Hours*) dan status kegagalan komponen (*M5_Failed*) dengan metodologi *binary indicator*, dimana nilai "1" menunjukkan terjadinya kegagalan, sedangkan nilai **0** menunjukkan kondisi mesin beroperasi tanpa kegagalan.

Selain data teknis, penelitian ini juga mempertimbangkan dimensi ekonomis pemeliharaan, khususnya biaya yang timbul akibat penerapan strategi pemeliharaan yang berbeda. Biaya *preventive maintenance* tercatat sebesar USD 400 per kegiatan, sedangkan

biaya *corrective maintenance* mencapai USD 4000 untuk setiap kejadian kegagalan. Data TBF ditunjukkan pada Tabel 4.1 berikut:

Tabel 4. 1 Data Operasional Harian dan Status Kegagalan Mesin 5

No.	*Operating Hours*	*M5_failed*
1	24	1
2	24	1
3	24	1
4	24	1
5	24	1
6	24	1
7	24	1
8	24	1
9	24	1
10	24	1
…	…	…
44	24	1

Dataset terdiri dari 44 observasi harian dengan operasi 24 jam per hari. Analisis data menunjukkan pola yang konsisten: seluruh 44 observasi mengalami kegagalan pada komponen M5 setiap hari operasional. Dari pola ini, perhitungan *Mean Time Between Failure* (MTBF) historis menghasilkan: MTBF = 1.056 jam ÷ 44 kejadian = 24 jam. Hasil ini mengindikasikan bahwa mesin rata-rata mengalami kegagalan setiap 24 jam operasi, mencerminkan tingkat keandalan yang rendah dan kebutuhan optimisasi sistem.

4.2 Perhitungan Parameter Distribusi Weibull

4.2.1 *Penyusunan Data Untuk Analisis Distribusi Weibull.*

Langkah awal dalam analisis Distribusi Weibull adalah menyusun data *Time Between Failure* (TBF) yang merepresentasikan umur operasi mesin hingga mengalami kegagalan (*downtime*) pada Mesin Sistem Obeng Torsi. Data TBF yang diperoleh selanjutnya diurutkan dari nilai terkecil hingga terbesar untuk memudahkan proses estimasi parameter distribusi.

Setiap data TBF yang telah diurutkan kemudian diberi peringkat $i = 1, 2, 3, \dots, 44$ sesuai dengan jumlah total kejadian kegagalan. Data TBF yang sudah diurutkan beserta peringkatnya disajikan pada Tabel 4.2 berikut:

Tabel 4. 2 Data *Time Between Failure* (TBF) Terurut dan Peringkat Kegagalan

TTF (jam)	Rank (i)
12,0	1
12,4	2
13,5	3
37,1	4
50,8	5
51,4	6
…	…
268,7	44

Untuk keperluan perhitungan probabilitas kumulatif dan pembuatan *Weibull Probability Plot,* digunakan pendekatan median rank sebagai estimator fungsi distribusi kumulatif empiris. Estimator median rank dihitung menggunakan Persamaan (3.1), sehingga diperoleh nilai probabilitas kumulatif kegagalan $F(t)$ untuk setiap data TBF. Hasil perhitungan nilai $F(t)$ disajikan pada Tabel 4.3:

Tabel 4. 3 Estimasi Probabilitas Kumulatif Kegagalan dengan Median Rank

TTF (jam)	Rank (i)	$F(t)$
12,0	1	0,01577
12,4	2	0,03829
13,5	3	0,06081
37,1	4	0,08333
50,8	5	0,10586
51,4	6	0,12838
…	…	...
268,7	44	0,98423

Nilai probabilitas kumulatif $F(t)$ yang diperoleh selanjutnya digunakan dalam proses transformasi linear untuk pembentukan *Weibull Probability Plot* dan estimasi parameter distribusi Weibull.

4.2.2 *Transformasi Linear Pembentukan Weibull Probability Plot.*

Nilai probabilitas kumulatif kegagalan $F(t)$ yang diperoleh dari estimator *median rank* selanjutnya ditransformasi secara linear untuk membentuk Weibull Probability Plot. Transformasi ini dilakukan dengan memanfaatkan sifat matematis distribusi Weibull yang memungkinkan hubungan nonlinier antara waktu kegagalan dan probabilitas kumulatif diubah menjadi hubungan linier melalui transformasi logaritmik.

Tujuan dari transformasi linear ini adalah untuk menghasilkan pasangan nilai koordinat (x, y) yang dapat diplotkan pada sistem koordinat Kartesius, sehingga memungkinkan estimasi parameter distribusi Weibull, yaitu shape parameter (β) dan scale parameter (η), melalui analisis regresi linear.

Untuk setiap observasi data TBF ke-i, nilai x dihitung sebagai logaritma natural dari nilai TBF sesuai dengan persamaan (3.2), sedangkan nilai y dihitung sebagai logaritma natural ganda dari peluang kegagalan kumulatif berdasarkan persamaan (3.3). Perhitungan ini dilakukan terhadap seluruh 44 observasi data TBF, sehingga diperoleh 44 pasangan nilai koordinat (x, y) yang merepresentasikan hasil transformasi linear dari data TBF asli. Nilai koordinat (x, y) untuk setiap observasi data TBF disajikan pada Tabel 4.4:

Tabel 4. 4 Transformasi Linear Data TBF untuk Weibull Probability Plot

TBF (jam)	Rank (i)	$F(t)$	x	y
12,0	1	0,01577	2,48491	-4,14198
12,4	2	0,03829	2,51770	-3,24315
13,5	3	0,06081	2,60269	-2,76878
37,1	4	0,08333	3,61362	-2,44172
…	…	…	…	…
268,7	44	0,98423	5,59360	1,42309

Setelah diperoleh pasangan koordinat (x, y) dari masing-masing $F(t)$ menggunakan Persamaan (3.2) dan (3.3), dilakukan analisis regresi linear untuk menentukan nilai *slope*

dan *intercept* menggunakan fungsi regresi linear pada Microsoft Excel. Nilai *slope* merepresentasikan *shape parameter* (β) dari Distribusi Weibull, sedangkan nilai *intercept* digunakan untuk menghitung *scale parameter* (η). Berdasarkan perhitungan *slope* dan *intercept* menggunakan fungsi regresi linear pada Microsoft Excel untuk koordinat yang sudah dihitung sebelumnya, didapatkan nilai-nilai sebagai berikut:

- *Slope* (b) = 1,573
- *Intercept* (a) = -7,836

Nilai *slope* dan *intercept* tersebut digunakan dalam tahap berikutnya untuk melakukan perhitungan koefisien determinasi untuk memvalidasi kesesuaian model Distribusi Weibull terhadap data kegagalan Mesin Sistem Obeng Torsi dari transformasi linear data pada *Weibull Probability Plot.*

Berdasarkan perhitungan koefisien determinasi menggunakan Persamaan (3,4), didapatkan hasil R^2 berada pada nilai 0,9534 yang berarti 95,34% variasi data kegagalan dapat dijelaskan oleh model Distribusi Weibull. Nilai $R^2 > 0,95$ menunjukkan bahwa Model Weibull memberikan fit yang sangat baik terhadap data empiris.

4.2.3 *Estimasi Parameter Beta (β) dan Eta (η)*

Berdasarkan hasil regresi linear pada Weibull Probability Plot, diperoleh nilai kemiringan garis (*slope*) dan titik potong sumbu (*intercept*). Nilai-nilai ini selanjutnya digunakan untuk mengestimasi parameter distribusi Weibull, yaitu shape parameter (β) yang didapatkan dari nilai *slope* dan scale parameter (η) yang didapatkan dengan menggunakan Persamaan (3.5).

Nilai *slope* hasil regresi linear merepresentasikan shape parameter (β), sedangkan nilai *intercept* digunakan untuk menghitung scale parameter (η). Estimasi parameter dilakukan berdasarkan hubungan matematis distribusi Weibull dua parameter yang telah dijelaskan pada subbab sebelumnya.

Hasil estimasi parameter distribusi Weibull untuk Mesin Sistem Obeng Torsi dirangkum pada Tabel 4.5.

Tabel 4. 5 Parameter Distribusi Weibull Mesin Sistem Obeng Torsi

Parameter Distribusi Weibull	
β (*shape*)	1,573
Intercept	-7,836
η (*scale*) *from intercept*	145,756

Nilai $\beta > 1$ mengindikasikan bahwa pola kegagalan Mesin Sistem Obeng Torsi berada pada fase *wear-out*, yaitu kondisi di mana laju kegagalan meningkat seiring dengan bertambahnya waktu operasi. Parameter skala η = 145,756 jam merepresentasikan *characteristic life*, yaitu waktu ketika sekitar 63,2% populasi mesin identik diperkirakan telah mengalami kegagalan. Parameter-parameter ini selanjutnya digunakan sebagai dasar dalam perhitungan fungsi reliabilitas, laju kegagalan, serta analisis biaya pemeliharaan pada tahap berikutnya.

4.3 Perhitungan Biaya Berdasarkan Hasil Parameter Distribusi Weibull

4.3.1 *Perhitungan Reliability Grid.*

Reliability Grid dibuat dengan mendiskreditasi rentang waktu perbaikan preventif dari 1 hingga 300 jam menggunakan interval 1 jam, menghasilkan 300 titik evaluasi. Setiap nilai reliabilitas dihitung menggunakan fungsi reliabilitas Distribusi Weibull dengan parameter yang sudah diestimasi sebelumnya yaitu shape parameter β = 1,573 dan *scale parameter* η = 145,756 jam.

Berdasarkan nilai reliabilitas yang diperoleh, dilakukan perhitungan *segment area* menggunakan metode trapesium (*trapezoidal rule*) untuk mendekati nilai integral fungsi reliabilitas. Selanjutnya, dilakukan penjumlahan kumulatif dari setiap segment area untuk memperoleh *cumulative integral*, yang merepresentasikan estimasi panjang siklus operasi hingga waktu t.

Hasil perhitungan *Reliability Grid* disajikan pada Tabel 4.5.

Tabel 4. 6 *Reliability Grid* Mesin Sistem Obeng Torsi

t (jam)	$R(t)$	*Segment Area* (*trap*)	Integral Kumulatif
0	1	0	0
1	0,999604635	0,999802318	0,999802318

t (jam)	$R(t)$	*Segment Area* (*trap*)	Integral Kumulatif
2	0,998824336	0,999214486	1,999016803
3	0,997776645	0,998300491	2,997317294
4	0,996506716	0,997141681	3,994458975
5	0,995041697	0,995774207	4,990233181
6	0,993400518	0,994221108	5,984454289
7	0,991597498	0,992499008	6,976953298
8	0,989644053	0,990620776	7,967574073
9	0,987549624	0,988596838	8,956170911
10	0,985322237	0,98643593	9,942606842
…	…	…	…
300	0,044506013	0,044871711	128,4024335

Nilai *cumulative integral* ini digunakan sebagai dasar dalam perhitungan *expected cycle time* pada analisis optimasi *predictive maintenance*.

4.3.2 *Perhitungan Optimasi Predictive Maintenance.*

Tahap optimasi *Predictive Maintenance* mencakup perhitungan estimasi panjang siklus, estimasi *total cost*, serta *cost rate* yang merepresentasikan biaya pemeliharaan per satuan waktu operasi. Perhitungan dilakukan untuk setiap kandidat waktu pemeliharaan T berdasarkan nilai reliabilitas dan peluang kegagalan yang diperoleh dari model Weibull.

Hasil perhitungan optimasi *predictive maintenance* disajikan pada Tabel 4.7:

Tabel 4. 7 Hasil Optimasi *Predictive Maintenance*

T (jam)	*R(T)*	*F(T)*	*Expected Cycle Time*	*Expected Cycle Cost*	*g(T)*
1	0,999604635	0,0003954	0,999802318	400,6325836	400,7117973
2	0,998824336	0,0011757	1,999016803	401,8810626	201,03
3	0,997776645	0,0022234	2,997317294	403,5573676	134,6
4	0,996506716	0,0034933	3,994458975	405,5892539	101,5
5	0,995041697	0,0049583	4,990233181	407,933284	81,74
6	0,993400518	0,0065995	5,984454289	410,5591707	68,6

T (jam)	*R(T)*	*F(T)*	*Expected Cycle Time*	*Expected Cycle Cost*	*g(T)*
7	0,991597498	0,0084025	6,976953298	413,4440028	59,25
8	0,989644053	0,0103559	7,967574073	416,5695155	52,28
…	…	…	…	…	…
34	0,903628523	0,0963715	32,70156136	554,1943636	16,94
…	…	…	…	…	…
91	0,620838596	0,3791614	76,3706923	1006,658246	13,18
…	…	…	…	…	…
300	0,044506013	0,955494	128,4024335	1928,79038	15,02

Nilai *cost rate* $g(T)$ yang paling rendah menunjukkan waktu pemeliharaan yang paling optimal secara ekonomi. Hasil ini menjadi dasar penentuan *interval predictive maintenance* yang direkomendasikan pada tahap analisis dan pembahasan.

4.3.3 *Perhitungan Expected Total Cost berdasarkan Kebijakan Perusahaan.*

Kebijakan yang diterapkan oleh PT XYZ yaitu melakukan perbaikan preventif rutin ketika nilai reliabilitas berada di sekitar 90%. Berdasarkan hasil perhitungan fungsi reliabilitas, kondisi tersebut dicapai ketika *expected cycle time* atau panjang siklus operasi mesin berada pada 32,7 jam.

Dengan asumsi probabilitas mesin tidak mengalami kegagalan sebesar 90% dan probabilitas kegagalan sebesar 10% dalam satu siklus operasi, maka *Expected Total Cost* per siklus berdasarkan kebijakan perusahaan dihitung menggunakan persamaan (3.8) sebagai berikut:

$$Expected\ Total\ Cost = \frac{(400\ \times\ 0{,}9) + (2000 \times 0{,}1)}{32{,}7} = USD\ 17{,}124\ per\ jam$$

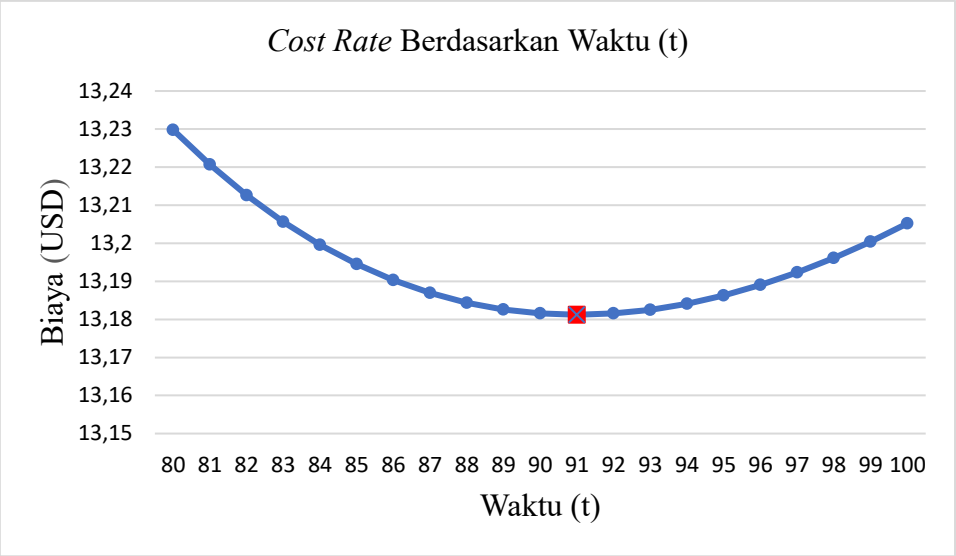
Nilai USD 17,124 yang dihasilkan merepresentasikan *cost rate* pemeliharaan yang harus ditanggung perusahaan apabila kebijakan pemeliharaan dilakukan secara rutin pada tingkat reliabilitas sekitar 90%.

4.3.4 *Biaya Rekomendasi Predictive Maintenance.*

Berdasarkan hasil perhitungan optimasi *predictive maintenance* pada Tabel Optimasi *Predictive Maintenance*, diperoleh nilai *cost rate* $g(T)$ untuk berbagai kandidat waktu pemeliharaan. Hasil analisis menunjukkan bahwa nilai *cost rate minimum* dicapai ketika mesin beroperasi hingga 91 jam, dengan nilai USD 13,18 per jam.

Nilai tersebut lebih rendah secara signifikan dibandingkan dengan *cost rate* berdasarkan kebijakan pemeliharaan rutin perusahaan, yaitu USD 17,124 per jam. Penurunan cost rate ini menunjukkan bahwa penerapan predictive maintenance berbasis analisis reliabilitas mampu menghasilkan efisiensi biaya pemeliharaan yang lebih baik dibandingkan pendekatan preventif konvensional.

Hasil ini juga diperkuat secara visual melalui Grafik 4.4, yang menunjukkan hubungan antara *cost rate* dan waktu pemeliharaan (t). Grafik tersebut memperlihatkan kurva berbentuk U, di mana *cost rate* menurun seiring bertambahnya waktu operasi hingga mencapai titik minimum pada t = 91 jam, kemudian kembali meningkat apabila pemeliharaan dilakukan terlalu lambat.



Gambar 4. 1 Grafik *Cost Rate* Berdasarkan Waktu Pemeliharaan (t)

Titik minimum pada grafik (ditandai dengan tanda merah) merepresentasikan waktu optimal pelaksanaan *predictive maintenance*, karena pada titik tersebut tercapai keseimbangan terbaik antara risiko kegagalan dan biaya pemeliharaan. Dengan demikian,

interval pemeliharaan sebesar 91 jam direkomendasikan sebagai waktu optimal *predictive maintenance* untuk Mesin Sistem Obeng Torsi berdasarkan kriteria minimisasi *cost rate*.

4.3.5 *Perbandingan Expected Total Cost dan Predictive Maintenance.*

Setelah dilakukan perhitungan *expected total cost* berdasarkan kebijakan pemeliharaan perusahaan serta *cost rate* rekomendasi *predictive maintenance*, selanjutnya dilakukan analisis perbandingan untuk mengevaluasi efektivitas masing-masing pendekatan pemeliharaan dari sisi biaya.

Hasil perbandingan biaya untuk ketiga skenario pemeliharaan tersebut disajikan pada Tabel 4.8.

Tabel 4. 8 Perbandingan Biaya Pemeliharaan Berdasarkan Strategi *Maintenance*

Kategori	*Predictive Maintenance* (PdM)	*Preventive Maintenance* (Kebijakan)	Corrective Maintenance (Saat Rusak)
T (jam)	91	32,7	-
Cost Rate (USD/jam)	13,18121148	17,1245646	166,6666667

Berdasarkan Tabel 4.7, dapat dilihat bahwa strategi *predictive maintenance* menghasilkan *cost rate* terendah, yaitu sebesar USD 13,18 per jam, dengan interval pemeliharaan optimal pada 91 jam. Nilai ini lebih rendah dibandingkan dengan strategi *preventive maintenance* berdasarkan kebijakan perusahaan yang memiliki *cost rate* sebesar USD 17,12 per jam pada interval 32,7 jam.

Sementara itu, strategi *corrective maintenance* menunjukkan nilai biaya yang jauh lebih tinggi, yaitu sekitar USD 166,67 per jam, akibat tingginya biaya perbaikan saat kegagalan terjadi serta dampak downtime yang signifikan. Hal ini menegaskan bahwa pendekatan *run-to-failure* sangat tidak efisien untuk Mesin Sistem Obeng Torsi yang bersifat kritis dalam sistem produksi serial.

Dengan demikian, hasil perbandingan ini membuktikan bahwa penerapan predictive maintenance berbasis analisis distribusi Weibull dan optimasi biaya mampu memberikan penghematan biaya yang signifikan dibandingkan kebijakan pemeliharaan eksisting,

sekaligus menurunkan risiko kegagalan mendadak dan meningkatkan keandalan operasional mesin.

BAB V
PEMBAHASAN

5.1 Interpretasi Kondisi Awal Mesin Sistem Obeng Torsi

Mesin Sistem Obeng Torsi dipilih sebagai objek penelitian karena merupakan mesin dengan tingkat keandalan terendah di antara kelima mesin yang terkonfigurasi dalam sistem manufaktur serial PT. XYZ. Data historis periode Bulan Januari hingga Juni 2025 menunjukkan Mesin Sistem Obeng Torsi mengalami frekuensi kegagalan tertinggi dengan rata-rata waktu antar kegagalan (MTBF) sebesar 24 jam.

Dalam sistem produksi dengan konfigurasi serial, mesin dengan tingkat keandalan terendah berperan sebagai bottleneck kritis, karena kegagalannya akan menghentikan seluruh aliran produksi. Oleh karena itu, peningkatan reliabilitas pada Mesin Sistem Obeng Torsi diperkirakan memberikan dampak paling signifikan terhadap *system availability* secara keseluruhan.

Dataset penelitian mencakup 44 kejadian kegagalan, dengan rentang umur mesin saat mengalami *downtime* berada antara 12 jam hingga 268,7 jam. Rentang yang lebar ini mencerminkan pola degradasi yang tidak seragam dan mengindikasikan bahwa mesin telah memasuki fase *wear-out*, di mana laju kegagalan meningkat seiring bertambahnya waktu operasi. Kondisi keandalan yang rendah ini berdampak langsung pada meningkatnya *unplanned downtime*, tingginya biaya perawatan darurat, serta terganggunya kontinuitas dan stabilitas produksi.

Dengan mempertimbangkan peran kritis Mesin Sistem Obeng Torsi dalam sistem serial serta tingginya tingkat kegagalan yang terjadi, penerapan strategi *predictive*

maintenance berbasis analisis Distribusi Weibull menjadi prioritas strategis. Pendekatan ini diharapkan mampu mengidentifikasi pola degradasi mesin secara kuantitatif dan menentukan waktu intervensi pemeliharaan yang optimal untuk meningkatkan keandalan sistem manufaktur secara menyeluruh.

.

5.2 Analisis Parameter Distribusi Weibull

5.2.1 *Interpretasi Shape Parameter(β).*

Hasil estimasi parameter bentuk (β) = 1,573 mengindikasikan bahwa Mesin Sistem Obeng Torsi berada pada fase *wear-out* dengan laju kegagalan yang meningkat seiring waktu operasi. Nilai $\beta > 1$ menunjukkan bahwa komponen mengalami degradasi progresif, di mana probabilitas kegagalan meningkat akseleratif seiring mesin beroperasi lebih lama.

Dengan nilai β = 1,573, laju kegagalan meningkat secara akseleratif, sehingga semakin lama mesin dioperasikan tanpa intervensi pemeliharaan, semakin besar probabilitas terjadinya kegagalan mendadak. Karakteristik ini menunjukkan bahwa pendekatan *corrective maintenance* atau pemeliharaan reaktif tidak lagi sesuai, karena berisiko menyebabkan downtime yang sering dan tidak terencana.

Interpretasi shape parameter ini memperkuat urgensi penerapan *predictive maintenance*, di mana intervensi dilakukan sebelum mesin memasuki zona keausan kritis. Penetapan interval pemeliharaan yang terukur dan berbasis data menjadi kunci untuk mengendalikan laju degradasi serta mencegah eskalasi kegagalan pada Mesin Sistem Obeng Torsi.

5.2.2 *Interpretasi Scale Parameter (η).*

Parameter skala η = 145,756 jam merepresentasikan *characteristic life*, yaitu waktu pada saat 63,2% populasi komponen diperkirakan telah mengalami kegagalan apabila tidak dilakukan tindakan pemeliharaan.

Nilai η yang relatif rendah menunjukkan bahwa Mesin Sistem Obeng Torsi memiliki durasi operasi yang terbatas sebelum memasuki zona degradasi kritis. Hal ini mengindikasikan bahwa mesin cenderung mengalami kegagalan dalam rentang waktu

operasi yang cukup singkat, sehingga pengoperasian mesin hingga mendekati atau melampaui nilai η tanpa intervensi pemeliharaan akan meningkatkan risiko kegagalan secara signifikan.

Kombinasi nilai β = 1,573 dan η = 145,756 jam menghasilkan fungsi reliabilitas yang menurun secara akseleratif. Implikasi praktis dari kondisi ini adalah bahwa interval pemeliharaan tidak boleh ditetapkan mendekati nilai η, melainkan harus dilakukan lebih awal untuk menjaga reliabilitas mesin tetap berada pada tingkat yang dapat diterima. Dengan demikian, penentuan *interval predictive maintenance* yang optimal menjadi krusial untuk menjamin kontinuitas produksi dan meminimalkan risiko kegagalan pada sistem manufaktur serial.

5.3 Analisis dan Perbandingan Biaya *Maintenance*

5.3.1 *Analisis Expected Cost Estimation Berdasarkan Kebijakan PT XYZ.*

Kebijakan pemeliharaan PT XYZ saat ini menerapkan preventive maintenance pada saat reliabilitas mesin mencapai 90% dengan *expected cycle time* sebesar 32,7 jam, menghasilkan *expected total cost* sebesar USD 17,124 per jam setiap siklus. Nilai biaya yang relatif tinggi ini mencerminkan bahwa strategi pemeliharaan saat ini belum optimal, dengan interval pemeliharaan yang terlalu pendek (32 jam) mengakibatkan frekuensi intervensi berlebihan dan pemborosan sumber daya.

Dengan demikian, kebijakan pemeliharaan yang berlaku saat ini masih menyisakan peluang yang signifikan untuk dilakukan optimasi. Penyesuaian interval pemeliharaan berbasis analisis kuantitatif dan pemodelan Distribusi Weibull berpotensi menurunkan biaya operasional tanpa mengorbankan tingkat keandalan mesin.

5.3.2 *Analisis Biaya Predictive Maintenance,*

Berdasarkan hasil optimisasi *Grand Total Cost* dengan interval pemeliharaan 1 jam, analisis menunjukkan bahwa biaya *maintenance* terendah dicapai pada saat mesin berusia 91 jam dengan *cost rate* sebesar USD 13,18 per jam, jauh lebih rendah dari kebijakan saat ini (USD 17,124 per jam) pada reliabilitas 90,3%.

Titik optimal t^* = 91 jam terletak pada bagian terendah dari kurva *cost rate* yang berbentuk U-shape, yang merepresentasikan keseimbangan optimal antara biaya

preventive maintenance dan risiko terjadinya *corrective maintenance*. Pada interval ini, reliabilitas mesin berada pada nilai 62,08%, yang masih berada dalam batas aman untuk operasi mesin sekaligus mampu meminimalkan biaya total pemeliharaan.

Analisis grafik *cost rate* menunjukkan bahwa sebelum mencapai titik t^* = 91 jam, biaya pemeliharaan per satuan waktu menurun secara signifikan seiring dengan diperpanjangnya interval pemeliharaan. Namun, setelah melewati titik tersebut, biaya mulai meningkat kembali akibat meningkatnya probabilitas kegagalan dan tingginya biaya *corrective maintenance.*

Dengan mengimplementasikan interval optimal ini, Mesin Sistem Obeng Torsi dapat dioperasikan dengan efisiensi biaya maksimal sambil tetap menjaga reliabilitas operasi pada level yang aman dan terukur.

5.3.3 *Perbandingan dan Estimasi Penghematan Biaya*

Perbandingan antara kebijakan pemeliharaan saat ini dengan rekomendasi *predictive maintenance* optimal menunjukkan perbedaan biaya yang signifikan. *Preventive maintenance* (PM) dengan kebijakan perusahaan pada interval 32,7 jam menghasilkan cost sebesar USD 17,124 per jam, sementara rekomendasi *predictive maintenance* (PdM) pada interval 91 jam hanya menghasilkan *cost rate* sebesar USD 13,181 per jam.

Berdasarkan perbandingan tersebut, diperoleh penghematan biaya sebesar USD 3,943 per jam, atau setara dengan pengurangan biaya sekitar 23% dibandingkan kebijakan pemeliharaan yang berlaku saat ini. Nilai ini menunjukkan bahwa perpanjangan interval pemeliharaan yang ditentukan secara kuantitatif mampu menurunkan biaya operasional secara signifikan tanpa mengorbankan tingkat keandalan mesin.

Sebaliknya, apabila tidak dilakukan pemeliharaan terjadwal dan mesin dibiarkan beroperasi hingga mengalami kegagalan, maka perusahaan akan menghadapi skenario *corrective maintenance*, dengan biaya yang meningkat drastis hingga mencapai USD 166,667 per jam. Perbedaan biaya yang sangat besar ini menegaskan bahwa pendekatan pemeliharaan reaktif memiliki risiko finansial yang tinggi dan tidak efisien untuk sistem manufaktur serial.

Dengan demikian, implementasi strategi pemeliharaan berbasis data melalui *predictive maintenance* tidak hanya memberikan peningkatan keandalan mesin, tetapi juga

menghasilkan manfaat ekonomis yang nyata dalam bentuk penghematan biaya pemeliharaan dan pengurangan risiko kerugian akibat *unplanned downtime*.

.

5.4 Rekomendasi Waktu Penerapan *Predictive Maintenance*

Berdasarkan analisis komprehensif terhadap parameter distribusi Weibull dan perbandingan biaya maintenance, rekomendasi penelitian ini adalah PT. XYZ harus menerapkan *predictive maintenance* pada tran dalam Mesin Sistem Obeng Torsi dengan interval optimal 91 jam operasional. Parameter bentuk β = 1,573 mengindikasikan mesin telah memasuki fase *wear-out* dengan laju kegagalan yang meningkat akseleratif, sementara *scale parameter* η = 145,756 jam merepresentasikan *characteristic life* mesin, yang menunjukkan bahwa durasi operasi sebelum memasuki zona degradasi kritis relatif terbatas.

Pada interval pemeliharaan 91 jam, nilai reliabilitas mesin mencapai 62,08%, yang masih berada pada tingkat aman untuk mendukung operasi berkelanjutan dalam sistem manufaktur serial. Interval ini memberikan margin keamanan yang memadai sekaligus meminimalkan risiko terjadinya kegagalan mendadak yang dapat menghentikan keseluruhan lini produksi.

Selain dari sisi keandalan, interval 91 jam juga memberikan keuntungan ekonomi yang signifikan. Pada interval ini, *cost rate* mencapai nilai minimum sebesar USD 13,18 per jam, lebih rendah sekitar 23% dibandingkan kebijakan pemeliharaan saat ini yang menghasilkan cost rate sebesar USD 17,124 per jam pada interval 32 jam. Lebih jauh, penerapan interval optimal ini mampu mencegah terjadinya skenario *corrective maintenance* darurat, yang berpotensi menimbulkan biaya sangat tinggi hingga mencapai USD 166,667 per jam.

Rekomendasi ini didasarkan pada optimisasi *Age Replacement Policy* yang secara sistematis menyeimbangkan *trade-off* antara biaya *preventive maintenance* dan risiko biaya *corrective maintenance*. Dengan demikian, keputusan interval 91 jam merupakan keputusan yang rasional, terukur, dan berbasis data kuantitatif. Implementasi rekomendasi ini diharapkan tidak hanya meningkatkan efisiensi biaya operasional, tetapi

juga memperbaiki keandalan sistem manufaktur secara keseluruhan melalui pengurangan *unplanned downtime* dan peningkatan *overall equipment effectiveness* (OEE).

5.5 Aktivitas Perawatan pada Komponen Kritis

Transduser torsi (*torque transducer*) merupakan komponen sensor presisi dalam Mesin Sistem Obeng Torsi yang mengukur momen gaya (*torque*) selama proses penggencangan (*fastening*) dan mengkonversi besaran fisik menjadi sinyal elektrik untuk ditransmisikan ke unit kontrol elektronik (*microcontroller*) mesin. Sebagai elemen kunci dalam *Quality Assurance* terintegrasi, transduser torsi berfungsi sebagai *feedback loop* yang mengubah proses manufaktur dari *open-loop control* menjadi *closed-loop control*, memungkinkan real-time adjustment dan *defect prevention*. Fungsi utamanya mencakup: (1) pengukuran torsi dengan akurasi ±2-5% dari nilai nominal, (2) penyediaan *feedback real-time* untuk algoritma adaptif motor, (3) verifikasi kepatuhan torsi dalam *tolerance window* ±5-10% dari target, (4) pencegahan kerusakan fastener melalui deteksi dini *over-torque* dan *under-torque*, serta (5) dokumentasi komprehensif untuk audit kualitas dan analisis tren degradasi sistem. Dalam sistem produksi serial, kegagalan transduser torsi mengakibatkan propagasi kesalahan ke seluruh lini produksi, menyebabkan produk cacat lolos tanpa terdeteksi dan menghasilkan kerugian finansial signifikan dari rework, scrap, atau klaim kualitas *customer*.

Aktivitas perawatan pada transduser torsi dirancang untuk mempertahankan akurasi sensor melalui pendekatan *Predictive Maintenance* sistematis pada interval 91 jam operasional. Kegiatan pertama adalah verifikasi dan kalibrasi torsi menggunakan perangkat kalibrasi standar sesuai ISO 6789 dan IEC 60068, mencakup tes zero-point, aplikasi beban referensi pada 3-5 titik kalibrasi (25%, 50%, 75%, 100%), dan dokumentasi log maintenance untuk analisis tren drift sensor. Kegiatan kedua adalah perbaikan kabel penghubung meliputi inspeksi visual untuk mendeteksi kerusakan isolasi dan thermal stress, pengujian kontinuitas elektrik menggunakan multimeter, pembersihan connector dari debu dan korosi, serta penggantian kabel jika tidak dapat diperbaiki. Kegiatan ketiga adalah pengendalian lingkungan operasi yang mencakup pengendalian suhu ambient (0-50°C), optimalisasi grounding untuk eliminasi electromagnetic

interference (EMI), dan pengecekan seal proteksi terhadap kontaminan lingkungan. Kegiatan keempat adalah optimalisasi parameter kontrol berupa analisis kurva torsi (*torque curve*), kalibrasi ambang *shut-off* (*shut-off threshold*) berdasarkan data histori pengencangan, dan pengaturan *ramp rate* untuk balance antara *cycle time* dan akurasi. Semua kegiatan dilakukan terintegrasi pada interval 91 jam dengan intensifikasi jika ada indikasi kerusakan atau perubahan spesifikasi produk.

Implementasi strategi perawatan komprehensif pada transduser torsi menjadi elemen integral dari *Reliability Engineering* dan *Predictive Maintenance* berbasis data yang direkomendasikan dalam penelitian ini untuk mencapai *operational excellence* sesuai paradigma Industri 4.0. Pemeliharaan proaktif pada interval 91 jam operasional diharapkan menghasilkan lima manfaat kunci: (1) peningkatan keandalan pengukuran torsi dan konsistensi akurasi penggencangan, (2) reduksi produk cacat melalui minimalisasi out-of-spec torsi, (3) perpanjangan lifecycle komponen transduser melalui pencegahan degradasi dini, (4) peningkatan Overall Equipment Effectiveness (OEE) dari pengurangan downtime, serta (5) optimalisasi cost of maintenance dengan preventive approach yang lebih efisien dari reactive maintenance. Dengan demikian, strategi perawatan terstruktur pada transduser torsi menunjukkan penghubung langsung terhadap pencapaian tujuan penelitian untuk menentukan interval *predictive maintenance* optimal dan menghemat biaya pemeliharaan, sejalan dengan aspirasi *manufacturing excellence* melalui *smart maintenance* dan *data-driven decision making* dalam konteks industri manufaktur Indonesia modern.

5.6 Keterbatasan Penelitian

Analisis Weibull Distribution dalam penelitian ini didasarkan pada data historis kegagalan Mesin Sistem Obeng Torsi selama periode pengamatan tertentu, sehingga hasil estimasi parameter β = 1,573 dan η = 145,756 jam hanya berlaku untuk kondisi operasional yang serupa dengan kondisi saat pengumpulan data. Perubahan signifikan dalam lingkungan operasional, beban kerja, kualitas bahan baku, atau intensitas penggunaan mesin dapat mengalihkan karakteristik distribusi kegagalan dan memerlukan re-estimation parameter. Oleh karena itu, sebelum implementasi rekomendasi interval 91

jam, perlu dilakukan validasi terhadap konsistensi kondisi operasional mesin untuk memastikan bahwa asumsi-asumsi dasar dalam analisis masih berlaku di masa depan.

Kedua, rekomendasi interval 91 jam didasarkan pada optimisasi matematis *Age Replacement Policy*, namun implementasi praktis di PT. XYZ dapat dipengaruhi oleh faktor-faktor non-teknis yang tidak selalu dapat diprediksi secara akurat. Faktor-faktor seperti ketersediaan spare parts, kapabilitas dan keahlian teknisi maintenance, koordinasi jadwal produksi, dan prioritas bisnis dapat menyebabkan penyimpangan dari interval yang telah ditentukan. Dengan demikian, kesuksesan implementasi memerlukan tidak hanya keputusan teknis yang tepat, tetapi juga komitmen organisasi dan dukungan manajemen untuk memastikan adherence terhadap interval optimal yang telah ditetapkan.

Ketiga, parameter biaya yang digunakan dalam analisis, yaitu biaya *preventive maintenance* USD 833 per unit dan biaya *corrective maintenance* USD 12.000 per unit—merupakan estimasi berdasarkan data historis dan kondisi pasar saat pengumpulan data. Biaya-biaya ini dapat berfluktuasi seiring dengan perubahan harga pasokan *spare parts*, tingkat upah tenaga kerja, atau peningkatan *downtime losses* akibat inflasi atau faktor ekonomi lainnya. Fluktuasi biaya ini dapat mempengaruhi akurasi perhitungan cost rate dan posisi interval optimal, sehingga diperlukan *periodic review* dan updating terhadap estimasi biaya perbaikan untuk memastikan rekomendasi tetap relevan dalam jangka panjang.

Terakhir, penelitian ini difokuskan pada satu mesin dengan asumsi *single failure mode*, sehingga hasil dan rekomendasi tidak dapat langsung digeneralisasi untuk mesin-mesin lain, komponen yang berbeda, atau sistem produksi yang lebih kompleks dengan multiple failure modes dan interdependensi operasional. Setiap mesin atau komponen memiliki karakteristik kegagalan yang unik yang memerlukan analisis independen. Meskipun demikian, metodologi yang diaplikasikan dalam penelitian ini (analisis Weibull Distribution dan *Age Replacement Policy*) dapat diadaptasi dan diterapkan untuk analisis serupa pada peralatan atau sistem manufaktur lain dalam industri yang sejenis.

BAB VI
PENUTUP

6.1 Kesimpulan

Berdasarkan hasil penelitian yang didapatkan, berikut ini merupakan Kesimpulan dari penelitian:

1. Waktu optimal untuk melakukan *predictive maintenance* pada Mesin Sistem Obeng Torsi adalah 91 jam operasional. Kesimpulan ini didasarkan pada analisis *Weibull Distribution* yang menghasilkan shape Parameter (β) = *1,573* dan scale parameter η = *145,756* jam, mengindikasikan mesin berada dalam fase wear-out. Melalui optimisasi *Age Replacement Policy* terhadap 300 skenario interval pemeliharaan, interval 91 jam menghasilkan *grand total cost minimum* sebesar USD 13,18 per jam operasional, yang merepresentasikan biaya paling ekonomis untuk menyeimbangkan risiko kegagalan mendadak dengan beban pemeliharaan preventif. Penerapan interval optimal ini akan meminimalkan risiko kegagalan mendadak yang merugikan operasional manufaktur PT. XYZ.
2. Penghematan biaya dengan penerapan *predictive maintenance* pada Mesin Sistem Obeng Torsi adalah sebesar USD 3,94 per jam operasional atau setara dengan penghematan 23% dibandingkan dengan kebijakan maintenance saat ini. Penghematan ini diperoleh dari selisih antara biaya perbaikan rutin pada kebijakan saat ini yaitu interval 32 jam dengan cost USD 17,124 per jam dan *grand total cost* pada interval optimal yaitu 91 jam dengan cost USD 13,181 per jam. Dalam konteks operasional, penghematan ini mencerminkan optimisasi signifikan dalam alokasi sumber daya pemeliharaan, di mana pengurangan frekuensi *over-maintenance* preventif seiring dengan penurunan risiko kegagalan mendadak menghasilkan efisiensi biaya operasional yang substantial dan berkelanjutan untuk jangka panjang.

6.2 Saran

Berikut ini merupakan saran yang dapat diberikan berdasarkan penelitian yang telah dilakukan:

1. Bagi perusahaan disarankan untuk segera mengimplementasikan rekomendasi *predictive maintenance* dengan mengubah kebijakan dari interval tetap 32,7 jam menjadi interval 91 jam operasional pada Mesin Sistem Obeng Torsi. Perusahaan juga disarankan untuk melakukan penilaian berkala terhadap estimasi parameter Distribusi Weibull dan biaya *maintenance* untuk memastikan bahwa rekomendasi interval tetap optimal dan sesuai dengan perubahan kondisi operasional dan faktor ekonomi yang dinamis.
2. Bagi peneliti selanjutnya disarankan untuk mengembangkan analisis ini dengan mempertimbangkan beberapa jenis kegagalan pada mesin, melakukan analisis terhadap komponen-komponen lain dalam sistem manufaktur, serta mengintegrasikan faktor-faktor eksternal seperti kondisi lingkungan dan variabilitas beban kerja dalam model prediksi kegagalan. Selain itu, disarankan untuk melakukan validasi empiris terhadap rekomendasi interval 91 jam melalui penerapan *pilot project* dan monitoring jangka panjang untuk memastikan akurasi estimasi parameter Distribusi Weibull dan stabilitas interval optimal dalam kondisi operasional yang sesungguhnya.

DAFTAR PUSTAKA

Afdal, Z. A., & Linarti, U. (2023). *Preventive Maintenance Analysis Using Monte Carlo Simulation and Failure Mode and Effect Analysis (FMEA)*. https://doi.org/10.23917/jiti.v22i2.21900

Diocta, A., & Bangun, T. (2024). *Analisis Penerapan Preventive Maintenance pada Pabrik Kelapa Sawit Menggunakan Metode Failure Mode and Effect Analysis (FMEA) dan Reliability Centered Maintenance (RCM)*. https://doi.org/10.32734/ee.v7i1.2269

Dou, T., Clasie, B., Depauw, N., Shen, T., Brett, R., Lu, H. M., Flanz, J. B., & Jee, K. W. (2022). A deep LSTM autoencoder-based framework for predictive maintenance of a proton radiotherapy delivery system. *Artificial Intelligence in Medicine*, *132*. https://doi.org/10.1016/j.artmed.2022.102387

Hector, I., & Panjanathan, R. (2024). Predictive maintenance in Industry 4.0: a survey of planning models and machine learning techniques. *PeerJ Computer Science*, *10*, 1–50. https://doi.org/10.7717/peerj-cs.2016

Kamariotis, A., Tatsis, K., Chatzi, E., Goebel, K., & Straub, D. (2024). A metric for assessing and optimizing data-driven prognostic algorithms for predictive maintenance. *Reliability Engineering and System Safety*, *242*. https://doi.org/10.1016/j.ress.2023.109723

Marimin, & Zulna, N. F. (2022). Analisis Interval Pemeliharaan Komponen Kritis Unit Fuel Conveyor dengan Pendekatan Reliability Centered Maintenance (RCM). *Jurnal Teknologi Industri Pertanian*, 12–20. https://doi.org/10.24961/j.tek.ind.pert.2022.32.1.12

Nketiah, E. A. (2021). Parameter estimation of the Weibull Distribution; Comparison of the Least-Squares Method and the Maximum Likelihood estimation. *International Journal of Advanced Engineering Research and Science*, *8*(9), 210–224. https://doi.org/10.22161/ijaers.89.21

Octavia, E. A., & Rusindiyanto, R. (2025). Preventive Maintenance Planning Using Age Replacement Method for Head Router Machines. *Academia Open*, *10*(2). https://doi.org/10.21070/acopen.10.2025.12012

Othman, S. A. (2024). Enhancing Reliability Engineering Through Weibull Distribution in R. In *Journal of Computer Sciences and Mathematics (RJCM)* (Vol. 18, Number 1). www.csmj.mosuljournals.com

Putranugraha, D., & Garniwa, I. (2025). Optimization of Preventive Maintenance Planning for the Motor Cooling System at PLTGU Using Differential Evolution. *International Journal of Electrical, Computer, and Biomedical Engineering*, *3*(3). https://doi.org/10.62146/ijecbe.v3i3.132

Shama, M. S., Alharthi, A. S., Almulhim, F. A., Gemeay, A. M., Meraou, M. A., Mustafa, M. S. A., Hussam, E., & Aljohani, H. M. (2023). Modified generalized Weibull distribution: theory and applications. *Scientific Reports*, *13*(1). https://doi.org/10.1038/s41598-023-38942-9

Taimun, M. T. Y., Sharan, S. M. M. I., Azad, M. A., & Joarder, M. M. I. (2025). Smart Maintenance and Reliability Engineering in Manufacturing. *Saudi Journal of Engineering and Technology*, *10*(04), 189–199. https://doi.org/10.36348/sjet.2025.v10i04.009

Taoufyq, H., El Guemmat, K., Mansouri, K., & Akef, F. (2025). Predictive Maintenance Approaches: A Systematic Literature Review. *Journal of Industrial Engineering and Management*, *18*(3), 427–458. https://doi.org/10.3926/jiem.8537

Tiddens, W., Braaksma, J., & Tinga, T. (2023). Decision Framework for Predictive Maintenance Method Selection. *Applied Sciences (Switzerland)*, *13*(3). https://doi.org/10.3390/app13032021

Tiwari, S. K., Singh, R. K., & Kumar, B. (2022). *Optimizing PM Intervals for Manufacturing Industries Using Delay-Time Analysis and MOGA*.

Umamaheswari, K., Subrahmanyam, K., & Reddy, A. M. (2021). Cataloging Of Unit Replacement Based On Long Run Repair Average Cost Rate (ACR) Based On Weibull Distribution Model. In *Turkish Journal of Computer and Mathematics Education* (Vol. 12, Number 11).

Zhu, T., Ran, Y., Zhou, X., & Wen, Y. (2024). *A Survey of Predictive Maintenance: Systems, Purposes and Approaches*. https://doi.org/10.1109/COMST.2025.3567802