



# Machine Learning untuk Prediksi Kegagalan Mesin dalam Predictive Maintenance System

Nisa'ul Hafidhoh\*, Ardian Prima Atmaja, Gus Nanang Syaifuddiin, Ikhwan Baidlowi Sumafta, Salva Mahardhika Pratama, dan Hafsah Nur Khasanah

Jurusan Teknik, Politeknik Negeri Madiun, Madiun, Indonesia

\* Corresponding author: nisa@pnm.ac.id,

## Abstrak

Dalam menghadapi Revolusi Industri 4.0, teknologi seperti Internet of Things, Big Data, dan Kecerdasan Buatan menjadi kunci dalam modernisasi industri. Pendekatan Machine Learning sebagai salah satu bagian kecerdasan buatan digunakan untuk memproses data multivariabel berdimensi tinggi dan mengekstrak hubungan tersembunyi dalam lingkungan industri yang kompleks. Dalam penelitian ini, Machine Learning dimanfaatkan untuk mengklasifikasikan kegagalan mesin dalam membangun Predictive Maintenance System. Penelitian ini mengadopsi siklus CRISP-DM (Cross Industry Standard Process for Data Mining) yang terdiri dari tahap business understanding, data understanding, data preparation, modelling, evaluation dan deployment. Predictive Maintenance Dataset berupa data sintesis yang digunakan dalam penelitian ini mencerminkan situasi industri nyata terdiri dari 10.000 baris data dengan sepuluh fitur. Jenis kegagalan mesin diklasifikasikan menjadi Heat Dissipation Failure, Power Failure, Overstrain Failure, dan Tool Wear Failure. Exploratory Data Analysis dilakukan untuk mendapatkan ringkasan dan visualisasi data. Pendekatan machine learning menggunakan metode Logistic Regression dan hasil evaluasi model mencapai akurasi 96,87%, sesuai dengan kriteria sukses data. Hasil pemodelan machine learning yang dikembangkan kemudian diimplementasikan dalam aplikasi Predictive Maintenance System berbasis web untuk memudahkan pemantauan kondisi mesin dan prediksi kegagalan mesin oleh pengguna.

**Kata kunci :** CRISP-DM, exploratory data analysis, kegagalan mesin, machine learning, predictive maintenance system

## Abstract

*In facing the Industrial Revolution 4.0, technologies such as the Internet of Things, Big Data and Artificial Intelligence are key to industrial modernization. Machine Learning approach as a part of artificial intelligence is used to process high-dimensional multivariable data and extract hidden relationships in complex industrial environments. In this research, Machine Learning is used to classify machine failures in building a Predictive Maintenance System. This research adopts the CRISP-DM (Cross Industry Standard Process for Data Mining) cycle which consists of the business understanding, data understanding, data preparation, modeling, evaluation and deployment stages. The Predictive Maintenance Dataset in the form of synthetic data used in this research reflects real industrial situations consists of 10,000 rows of data with ten features. Types of machine failure are classified into Heat Dissipation Failure, Power Failure, Overstrain Failure, and Tool Wear Failure. Exploratory Data Analysis is carried out to obtain a summary and visualization of data. The machine*

Received: 8 May 2024; Revised: 22 May 2024; Accepted: 25 May 2024; Published: 31 May 2024.

© 2024 The author(s). Published by Department of Informatics, Universitas Diponegoro.

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) licence.

*learning approach uses the Logistic Regression method and the model evaluation results reach an accuracy of 96.87%, in accordance with the data success criteria. The results of the machine learning modelling developed are implemented in a web-based Predictive Maintenance System application to make it easier for users to monitor machine conditions and predict machine failures.*

**Keywords :** CRISP-DM, exploratory data analysis, machine failure, machine learning, predictive maintenance system

## 1 Pendahuluan

Perkembangan dunia industri telah melaju dengan pesat dan mengalami beberapa tahap revolusi. Revolusi Industri 1.0 diawali dengan penemuan mesin uap yang memungkinkan produksi barang secara masal dan beralih ke Revolusi Industri 2.0 dengan penggunaan listrik yang membuat biaya produksi lebih murah [1]. Selanjutnya di Revolusi Industri 3.0 ditandai dengan pemanfaatan elektronika dan teknologi informasi untuk mendukung proses otomatisasi produksi [2]. Transformasi aspek produksi pada dunia industri terjadi dalam Revolusi Industri 4.0 dengan menggabungkan teknologi otomatisasi dan internet. Pada era ini berkembang teknologi *Internet of Thing* (IoT), *Big Data* dan kecerdasan buatan (*Artificial Intelligence*) yang digunakan dalam dunia industri [3]. Pemanfaatan teknologi ini dapat digunakan untuk modernisasi industri manufaktur, baik untuk proses produksi, pemeliharaan mesin maupun proses bisnis lainnya.

Pemeliharaan mesin menjadi salah satu hal yang krusial dalam dunia industri karena berdampak langsung dalam biaya dan proses kinerja [4]. Kegagalan yang terjadi pada mesin dapat mengakibatkan mesin rusak yang membuat proses produksi terhambat dan biaya menjadi membengkak. Baik itu biaya pemeliharaan mesin ataupun konsekuensi akan proses produksi yang terlambat. Biaya yang harus dikeluarkan untuk pemeliharaan mesin pun bisa cukup besar, pada industri minyak dan gas berkisar antara 15% sampai 70% dari total biaya produksi [5]. Oleh karena itu, penting untuk melakukan pemeliharaan mesin atau maintenance sehingga menjaga mesin selalu siap produksi dan tidak terjadi kegagalan mesin. Salah satunya dengan menerapkan strategi pemeliharaan yang optimal bagi industri. Beberapa strategi pemeliharaan yaitu *corrective maintenance*, *preventive maintenance* dan *predictive maintenance* [6].


Kegagalan dapat dilihat sebagai penyimpangan yang tidak sah dari keadaan normal pada setidaknya satu properti karakteristik atau parameter pada mesin [7]. Untuk menghindari kegagalan yang dapat menyebabkan kerugian, maka diperlukan sebuah sistem untuk dapat melakukan perhitungan waktu perawatan alat sehingga dapat meminimalisir kerusakan alat. *Predictive Maintenance System* dapat menampilkan kondisi alat dan dapat memprediksi kapan waktu yang diperlukan untuk perawatan [8]. Dengan adanya sistem prediksi perawatan alat maka akan dapat menjamin kesediaan alat, produktivitas, dan keamanan [9].

Salah satu metode yang dapat digunakan untuk *predictive maintenance system* adalah dengan menggunakan *machine learning*. *Machine learning* merupakan salah satu bagian dari kecerdasan buatan yang berfokus pada pembelajaran pada sisi proses komputasi tanpa adanya pemrograman tertentu untuk dapat menjalankan sebuah tugas [10]. Pendekatan *Machine Learning* dapat memproses data multivariasi berdimensi tinggi dan mengekstrak hubungan tersembunyi di dalam data dalam lingkungan yang kompleks dan dinamis. Oleh karena itu, *Machine Learning* menyediakan pendekatan prediktif yang kuat untuk *Predictive Maintenance System* [11]. Maka daripada itu, pada penelitian ini

berfokus pada penggunaan *Machine Learning* untuk melakukan proses klasifikasi kegagalan mesin pada *Predictive Maintenance System*.

## 2 Metode

Pengembangan *Predictive Maintenance System* dengan *Machine Learning* untuk klasifikasi kegagalan mesin pada artikel ini menggunakan metode CRISP-DM (*Cross Industry Standard Process for Data Mining*). CRISP-DM menyediakan siklus yang terdiri dari beberapa tahap yang berkaitan dalam penerapan *Machine Learning* [12]. Pada Gambar 1 terdapat beberapa tahap dalam metode CRISP-DM yaitu *business understanding*, *data understanding*, *data preparation*, *modelling*, *evaluation* dan *deployment* [13].



Gambar 1 Siklus CRISP-DM [13]

Tahap awal dalam CRISP-DM adalah *Business Understanding* untuk memahami domain bisnis, tujuan dan sumber daya [14]. Dalam penelitian *Predictive Maintenance System* dengan *Machine Learning* ini bertujuan untuk melakukan prediksi dalam klasifikasi kegagalan mesin. Adapun kriteria sukses data yang diharapkan yaitu hasil akurasi prediksi di atas 90%. Pengukuran akurasi dipilih karena metrik kinerja akurasi mudah dipahami dan diinterpretasikan. Akurasi mengukur proporsi prediksi yang benar dari keseluruhan prediksi yang dibuat oleh model.

Pada tahap *data understanding*, dilakukan pengumpulan sumber data dan pemahaman terhadap data yang didapat. Data yang digunakan dalam penelitian ini adalah sekumpulan data sintetis yang mencerminkan *Predictive Maintenance Dataset* yang sebenarnya dijumpai dalam industri [15]. Dataset terdiri dari 10.000 baris data dengan 10 fitur seperti pada Tabel 1.

Tabel 1 Fitur Predictive Maintenance Dataset

No	Fitur	Deskripsi
1	UID	Kode unik mulai dari 1 hingga 10.000
2	ProductID	Nomor seri khusus varian
3	Type	Varian kualitas produk (Low, Medium, High)
4	Air temperature	Suhu di sekitar mesin atau peralatan
5	Process Temperature	Suhu yang diukur dalam proses produksi atau operasional mesin
6	Rotational Speed	Kecepatan putaran dimana mesin atau bagian mesin berputar
7	Torque	Gaya yang dapat memutar objek sekitar sumbu putar
8	Tool Wear	Penurunan kualitas alat atau keausan alat
9	Target	Pengecekan ada kegagalan atau tidak
10	Failure Type	Jenis kegagalan

Jenis kegagalan dalam dataset ini dikategorikan menjadi empat jenis kegagalan yang independen yaitu:


- a. *Tool Wear Failure* (TWF): alat akan diganti jika rusak pada waktu keausan alat yang dipilih secara acak antara 200 – 240 menit.
- b. *Heat Dissipation Failure* (HDF): pembuangan panas dapat menyebabkan kegagalan proses, jika perbedaan antara suhu udara dan suhu proses di bawah 8,6 K dan kecepatan putaran alat di bawah 1380 rpm.
- c. *Power Failure* (PWF): hasil kali *torque* (torsi) dan kecepatan putaran (dalam rad/s) sama dengan daya yang dibutuhkan untuk proses tersebut. Jika daya di bawah 3500 W atau di atas 9000 W, maka prosesnya gagal.
- d. *Overstrain Failure* (OSF): jika hasil kali *tool wear* dan torsi melebihi 11.000 minNm untuk varian produk L, 12.000 untuk M, 13.000 untuk H, proses gagal karena tegangan berlebih.

Adapun contoh data dalam *Predictive Maintenance Dataset* dapat dilihat pada Gambar 2.

	JDI	Product ID	Type	Air temperature	Process temperature	Rotational speed	Torque	Tool wear
0	1	M14860	M	298.1	308.6	1,551	42.8	0
1	2	L47181	L	298.2	308.7	1,408	46.3	3
2	3	L47182	L	298.1	308.5	1,498	49.4	5
3	4	L47183	L	298.2	308.6	1,433	39.5	7
4	5	L47184	L	298.2	308.7	1,408	40	9
5	6	M14865	M	298.1	308.6	1,425	41.9	11
6	7	L47186	L	298.1	308.6	1,558	42.4	14
7	8	L47187	L	298.1	308.6	1,527	40.2	16
8	9	M14868	M	298.3	308.7	1,667	28.6	18
9	10	M14869	M	298.5	309	1,741	28	21

Gambar 2 Contoh *Predictive Maintenance Dataset*

Dalam tahap *data understanding* juga dilakukan proses eksplorasi data dan pengecekan kualitas data [16]. Untuk mendapatkan pemahaman data yang lebih, eksplorasi data dilakukan dengan membuat visualisasi dari dataset yang ada. Contoh visualisasi sebaran data dari fitur *torque* diilustrasikan seperti pada Gambar 3.



Gambar 3 Visualisasi Sebaran Data Torque

Tahap berikutnya adalah *data preparation* untuk persiapan dataset yang akan diolah. Pada tahap ini dilakukan pemilihan data dan pembersihan dataset [17]. Pembersihan data yang dilakukan dalam penelitian ini adalah pengecekan data duplikat, penanganan data kosong serta *encoding* data yang diperlukan. Setelah dataset siap, selanjutnya dilakukan tahap Modelling atau Pemodelan. Pembangunan model Machine Learning dalam penelitian ini menggunakan metode Logistic Regression. Logistic Regression merupakan salah satu metode Supervised Learning yang memiliki kinerja unggul dalam Big Data [18]. Metode ini sesuai digunakan dalam melakukan klasifikasi beberapa variabel independen yang bersifat kategoris. Untuk membangun model dengan Logistic Regression dapat menggunakan model linier untuk model regresi pada persamaan (1) [19].

$$P = \alpha + \beta_1X_1 + \beta_2X_2 + \dots + \beta_mX_m \tag{1}$$


$P$  adalah probability,  $\beta_m$  adalah koefisien regresi dari masing-masing faktor impresi, dan  $X_m$  adalah masing-masing faktor yang mempengaruhi. Koefisien  $\beta$  didapatkan dari hasil perhitungan regresi tiap fitur. Pada penelitian ini terdapat enam fitur yang akan digunakan sebagai dasar prediksi.

Dari model yang berhasil dibangun dilakukan *Evaluation* untuk mengukur kinerja model. Evaluasi yang digunakan dalam penelitian ini dengan mengukur akurasi tiap model untuk menguji sesuai kriteria sukses yang diharapkan pada tahap *Business Understanding*. Tahap terakhir dari CRISP-DM adalah *Deployment* untuk pengaplikasian hasil klasifikasi dalam proses bisnis. Pada penelitian ini model *Machine Learning* untuk *Predictive Maintenance System* akan ditampilkan dalam sistem berbasis web.

### 3 Hasil dan Pembahasan

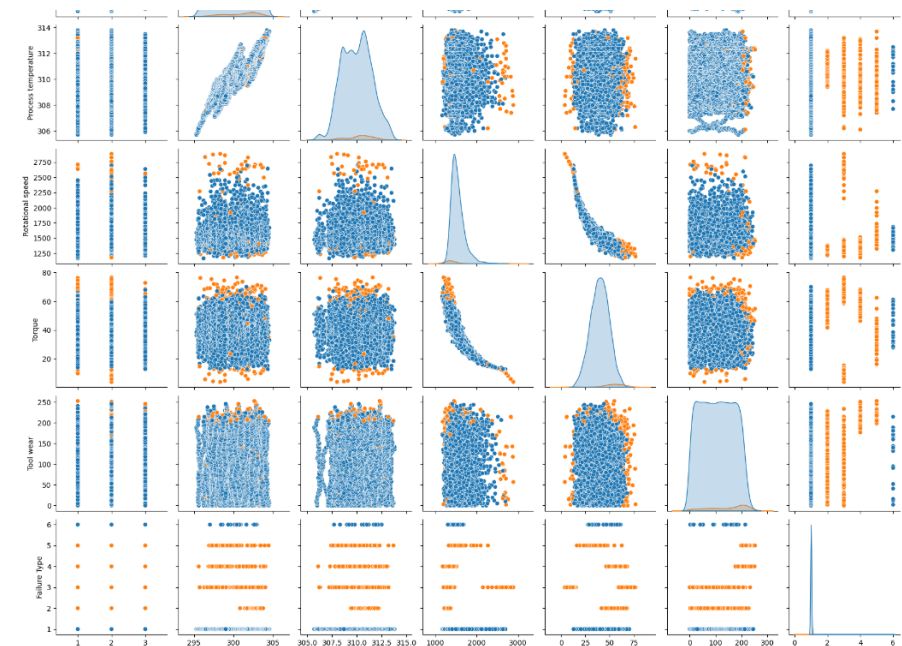
#### 3.1 Exploratory Data Analysis

*Exploratory data analysis* dilakukan pada tahap *data understanding*. Tujuan *Exploratory Data Analysis* untuk mendapatkan ringkasan data dan membuat visualisasi yang tepat dengan representasi data tersebut [20]. Dari hasil analisis data awal ini dapat dilihat sebaran data, *outlier* maupun anomali dalam dataset tersebut. Beberapa visualisasi yang dibuat dari hasil analisis data dipaparkan dalam *Exploratory data analysis*.



Gambar 4 Visualisasi Sebaran Fitur dalam Dataset

Gambar 4 menunjukkan visualisasi sebaran berbagai fitur dalam dataset yaitu *Type*, *Air temperature*, *Process temperature*, *Rotational speed*, *Torque*, dan *Tool wear*. Dari visualisasi histogram tersebut menunjukkan pola beragam yang menggambarkan bahwa sebaran data untuk tiap fitur cukup bervariasi nilainya. Jumlah tipe beragam yang mewakili varian produk L, M maupun H. Suhu di sekitar mesin (*air temperature*) serta suhu saat produksi (*process temperature*) juga bervariasi dari nilai tinggi maupun rendah. Demikian juga nilai untuk kecepatan putaran, torsi dan keausan alat pun beragam.



Gambar 5 Visualisasi Terjadinya Kegagalan dalam Dataset

Gambar 5 menunjukkan visualisasi terjadinya kegagalan mesin dengan kaitannya antar tiap fitur dalam dataset. Warna biru menunjukkan tidak terjadi kegagalan, sedangkan warna jingga memperlihatkan terjadinya kegagalan mesin. Pada bagian *torque* dapat dilihat bahwa banyak warna jingga di bagian atas dan bagian bawah nilai data, hal ini menunjukkan terjadinya kegagalan yang terkait torsi baik itu PWF ataupun OSF. PWF terjadi saat perkalian torsi dan kecepatan putaran di bawah 3500 W atau di atas 9000 W. OSF terjadi jika hasil kali *tool wear* dan torsi melebihi 11.000 minNm untuk varian produk L atau 12.000 untuk varian M ataupun 13.000 untuk varian H. Oleh karena itu, kecenderungan kegagalan banyak terjadi di bagian atas atau bawah.

### 3.2 Pre-processing Data

Pada tahap *data preparation* dilakukan *Pre-processing Data* untuk meningkatkan kualitas data dan persiapan membuat model. Setelah dipastikan tidak ada data yang duplikat maupun *missing value*, perlu dipastikan tidak ada anomali dalam dataset. Pengecekan yang dilakukan memastikan bahwa tidak ada *Failure Type* yang bernilai “No Failure” dalam data yang memiliki nilai Target = 1 (*Failure*). Sebelum membuat model dilakukan format data untuk menghasilkan dataset yang lebih berkualitas bagi model. Format model dilakukan dengan *feature engineering* sehingga menghasilkan *dataframe* baru yang terdiri delapan fitur terpilih seperti pada Gambar 6.

	Type	Air temperature	Process temperature	Rotational speed	Torque	Tool wear	Target	Failure Type
0	M	298.1	308.6	1551	42.8	0	0	No Failure
1	L	298.2	308.7	1408	46.3	3	0	No Failure
2	L	298.1	308.5	1498	49.4	5	0	No Failure
3	L	298.2	308.6	1433	39.5	7	0	No Failure
4	L	298.2	308.7	1408	40.0	9	0	No Failure

Gambar 6 Dataframe Hasil Format Data

Untuk mempermudah pemrosesan dan pembuatan model dilakukan *encoding* untuk penerjemahan data bernilai kategorikal atau *object* yaitu fitur *Type* dan *Failure Type* menjadi nilai numerik. Hasil proses *encoding* dapat dilihat pada Gambar 7. Pada fitur *Type*, nilai M diubah menjadi 1, L menjadi 2 dan H menjadi 3. Pada *Failure Type* yang bernilai 'No Failure', 'Heat Dissipation Failure', 'Power Failure', 'Overstrain Failure', 'Tool Wear Failure' berturut-turut akan dikodekan menjadi 1,2,3,4,5.

	Type	Air temperature	Process temperature	Rotational speed	Torque	Tool wear	Target	Failure Type
0	1	298.1	308.6	1551	42.8	0	0	1
1	2	298.2	308.7	1408	46.3	3	0	1
2	2	298.1	308.5	1498	49.4	5	0	1
3	2	298.2	308.6	1433	39.5	7	0	1
4	2	298.2	308.7	1408	40.0	9	0	1
...	...	...	...	...	...	...	...	...
9995	1	298.8	308.4	1604	29.5	14	0	1
9996	3	298.9	308.4	1632	31.8	17	0	1
9997	1	299.0	308.6	1645	33.4	22	0	1

Gambar 7 Hasil Encoding Data

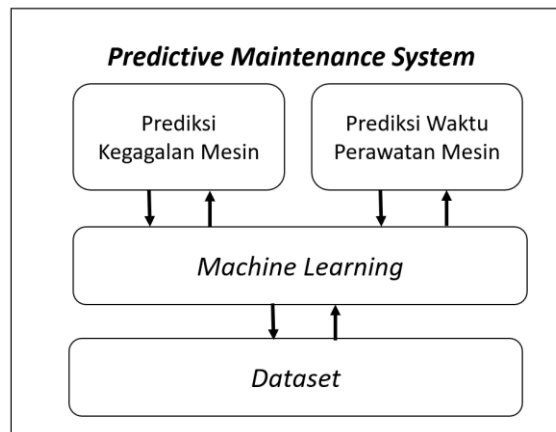
### 3.3 Pemodelan *Machine Learning*

Model *machine learning* yang dikembangkan dalam penelitian ini menggunakan *Logistic Regression*. Data x terdiri dari enam fitur yaitu *Type*, *Air temperature*, *Process temperature*, *Rotational speed*, *Torque*, dan *Tool wear*. Sedangkan target y berupa *Failure Type*. Sebelum pembangunan model, akan dilakukan pembagian dataset yang akan digunakan sebagai data latih dan data uji sebanyak 70:30. 70% dari seluruh dataset akan digunakan untuk melatih model, sedangkan 30% dari dataset akan digunakan untuk mengevaluasi model yang telah terbentuk. Sebagaimana sebaran dataset yang digambarkan pada visualisasi sebelumnya menunjukkan nilai yang cukup beragam untuk tiap fitur, sehingga dataset cukup seimbang.

Pembentukan model *Logistic Regression* menggunakan model linier sesuai persamaan (1). Selanjutnya dilakukan evaluasi model dengan pengukuran akurasi untuk melihat kriteria sukses data pada tahap *Business Understanding*. Dalam penelitian ini dikembangkan model prediksi untuk klasifikasi kegagalan mesin, evaluasi dengan akurasi tinggi diharapkan dapat menjamin proses deteksi kegagalan berjalan baik dan memberikan hasil optimal. Hasil evaluasi model *Logistic Regression* dalam penelitian ini menunjukkan nilai akurasi sebesar 96,87%. Hasil ini memenuhi kriteria sukses yang diharapkan pada tahap *Business Understanding* yaitu nilai akurasi prediksi di atas 90%.

### 3.4 Predictive Maintenance System

Pada penelitian ini diusulkan pengembangan *Predictive Maintenance System* sesuai diagram arsitektur pada Gambar 8. Tahap awal dari pengembangan *Predictive Maintenance System* yang diusulkan dalam penelitian ini adalah untuk melakukan prediksi kegagalan mesin. Setelah dapat dilakukan prediksi kegagalan mesin, selanjutnya dapat digunakan untuk mengembangkan prediksi waktu perawatan mesin. Keseluruhan sistem prediksi tersebut dikembangkan dengan memanfaatkan machine learning untuk mengolah dataset mesin yang ada.



Gambar 8 Arsitektur *Predictive Maintenance System*

Hasil pembangunan model *machine learning* berikutnya dilakukan *deployment* ke dalam aplikasi berbasis web. Pengembangan web *Predictive Maintenance System* dapat memudahkan pemantauan kondisi mesin dan prediksi kegagalan mesin oleh pengguna. Dalam web tersebut terdapat informasi tentang Prediksi Kegagalan Mesin dalam *Predictive Maintenance System* seperti pada Gambar 9.

## Prediksi Kegagalan Mesin

Selamat datang di aplikasi prediksi kegagalan mesin berbasis web.

Aplikasi ini menggunakan teknologi *Machine Learning* untuk memberikan prediksi yang akurat terkait kemungkinan kegagalan mesin berdasarkan beberapa variabel kunci. Dengan memasukkan nilai-nilai seperti Type, Air Temperature, Process Temperature, Rotational Speed, Torque, dan Tool Wear, pengguna dapat dengan mudah mendapatkan perkiraan tingkat risiko kegagalan pada mesin. Model *Machine Learning* yang kuat di balik aplikasi ini telah dilatih menggunakan data historis yang luas yakni sejumlah kurang lebih 10.000 data, memungkinkan sistem memberikan prediksi yang handal. Aplikasi ini dirancang untuk membantu pengguna mengidentifikasi potensi masalah sebelum terjadinya kerusakan serius, memungkinkan perencanaan pemeliharaan yang lebih efisien dan pengoperasian mesin yang lebih handal. Sederhana, responsif, dan mudah digunakan, aplikasi ini menjadi mitra ideal dalam mengoptimalkan kinerja dan umur pakai mesin industri.

Sumber data: <https://archive.ics.uci.edu/dataset/601/ai4i+2020+predictive+maintenance+dataset>

Gambar 9 Tampilan Halaman Deskripsi Web

Selain itu, terdapat halaman yang menampilkan informasi *dataset* yang digunakan berdasarkan penjelasan untuk tiap fitur data seperti pada Gambar 10. Grafik visualisasi serta hasil Prediksi menggunakan *machine learning*.





Gambar 10 Tampilan Halaman Dataset

Beberapa hasil visualisasi data juga ditampilkan dalam web pada halaman “Grafik” seperti pada Gambar 11. Visualisasi sebaran data untuk tiap fitur juga dapat dilihat pada web.



Gambar 11 Tampilan Halaman Grafik

Hasil model *machine learning* untuk prediksi kegagalan mesin ditampilkan dalam halaman “Prediksi” seperti pada Gambar 12.



Gambar 12 Tampilan Halaman Hasil Prediksi

Pengguna dapat mengatur nilai dari tiap fitur sesuai data yang ada untuk mengecek kondisi mesin apakah terdapat kegagalan atau tidak. Hasil prediksi *machine learning* akan ditampilkan apakah 'No

'Failure', 'Heat Dissipation Failure', 'Power Failure', 'Overstrain Failure', 'Tool Wear Failure'. Gambar 13 menunjukkan hasil prediksi 'Power Failure' berdasarkan nilai fitur yang dimasukkan pengguna.



Gambar 13 Tampilan Hasil Prediksi Kerusakan Mesin

#### 4 Kesimpulan

Prediksi kegagalan mesin untuk *Predictive Maintenance System* dengan memanfaatkan *Machine Learning* telah berhasil dikembangkan dalam penelitian ini. Pengembangan sistem menggunakan metode CRISP-DM yang terdiri dari *business understanding*, *data understanding*, *data preparation*, *modelling*, *evaluation* dan *deployment*. Metode *Logistic Regression* digunakan untuk mengembangkan model prediksi kegagalan mesin dengan hasil evaluasi akurasi sebesar 96,8%. Hasil pemodelan *machine learning* dikembangkan dalam web yang memudahkan pengguna untuk memantau kondisi dan melakukan prediksi kegagalan mesin. Penelitian selanjutnya adalah pengembangan model untuk prediksi waktu perawatan mesin sehingga dapat menjadi suatu *Predictive Maintenance System* yang utuh. Implementasi *Predictive Maintenance System* dalam dunia industri diharapkan dapat meningkatkan efisiensi, mengurangi biaya pemeliharaan, dan memastikan kondisi ketersediaan mesin.

#### Daftar Pustaka

- [1] B. Prasetyo and U. Trisyanti, "Revolusi Industri 4.0 dan Tantangan Perubahan Sosial", IPTEK: Journal of Proceedings Series, no. 5, pp. 22–28, 2018.
- [2] D. Lase, "Pendidikan di Era Revolusi Industri 4.0", SUNDERMANN: Jurnal Ilmiah Teologi, Pendidikan, Sains, Humaniora Dan Kebudayaan, vol. 12, no.2, pp. 28-43, 2019.
- [3] Y. Puspita, Y. Fitriani, S. Astuti, and Sri Novianti, "Selamat Tinggal Revolusi Industri 4.0, Selamat Datang Revolusi Industri 5.0", in Prosiding Seminar Nasional Pendidikan Program Pascasarjana Universitas PGRI Palembang 2020, p. 122-130.
- [4] Y. Ran, X. Zhou, P. Lin, Y. Wen, R. Deng, "Survey of Predictive Maintenance: Systems, Purposes and Approaches", IEEE Communications Surveys and Tutorials 2019, arXiv 2019, arXiv:1912.07383.

- [5] M. Bevilacqua and M. Braglia, "The analytic hierarchy process applied to maintenance strategy selection", *Reliability Engineering & System Safety*, vol. 70, no. 1, pp. 71–83, 2020.
- [6] A. Vemal, "Development of Apps for Predictive Maintenance System: a Case Study in HP", PhD Thesis, Universiti Sains Malaysia, Malaysia, 2018.
- [7] S. Safavi, M.A. Safavi, H. Hamid, and S. Fallah, "Multi-Sensor Fault Detection, Identification, Isolation and Health Forecasting for Autonomous Vehicles". *Sensors*. vol. 21, no. 7, p. 2547, 2021.
- [8] Y.-C. Chiu, F.-T. Cheng, and H.-C. Huang, "Developing a factory-wide intelligent predictive maintenance system based on Industry 4.0," *Journal of the Chinese Institute of Engineers*, vol. 40, no. 7, pp. 562–571, Oct. 2017, doi: 10.1080/02533839.2017.1362357.
- [9] S. Ayvaz and K. Alpay, "Predictive maintenance system for production lines in manufacturing: A machine learning approach using IoT data in real-time," *Expert Systems with Applications*, vol. 173, p. 114598, Jul. 2021, doi: 10.1016/j.eswa.2021.114598.
- [10] A. Theissler, J. Pérez-Velázquez, M. Kettelgerdes, and G. Elger, "Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry," *Reliability Engineering & System Safety*, vol. 215, p. 107864, Nov. 2021, doi: 10.1016/j.ress.2021.107864.
- [11] T. P. Carvalho, F. A. A. M. N. Soares, R. Vita, R. D. P. Francisco, J. P. Basto, and S. G. S. Alcalá, "A systematic literature review of machine learning methods applied to predictive maintenance," *Computers & Industrial Engineering*, vol. 137, p. 106024, Nov. 2019, doi: 10.1016/j.cie.2019.106024.
- [12] J. A. Solano, D. C. L. Cuesta, S. F. U. Ibanez, and J. R. C. Hernandez, "Predictive Models Assesment based on CRISP-DM Methodology for Students Performance in Colombia – Saber 11 Test", in *Procedia Computer Science*, 198, 2022, pp. 512-517.
- [13] M. Hosseini, N. Abdolvand, dan S. R. Harandi, "Two-dimensional analysis of customer behavior in traditional and electronic banking", *Digital Business*, Volume 2, Issue 2, 2022
- [14] C. Schröer, F. Kruse, dan J. M. Gómez, "A Systematic Literature Review on Applying CRISP-DM Process Model", *Procedia Computer Science*, Volume 181, 2021, pp. 526-534.
- [15] "AI4I 2020 Predictive Maintenance Dataset", 2020, UCI Machine Learning Repository, <https://doi.org/10.24432/C5HS5C>.
- [16] W. Y. Ayele, "Adapting CRISP-DM for Idea Mining: A Data Mining Process for Generating Ideas Using a Textual Dataset", *International Journal of Advanced Computer Science and Applications*, vol. 11, no. 6, 2020.
- [17] J. Brzozowska, J. Pizoń, G. Baytikenova, G. O. L. A. Arkadiusz, A. Zakimova, dan K. Piotrowska, "Data Engineering In Crisp-Dm Process Production Data–Case Study", *Applied Computer Science*, vol. 19, no.3, p. 83-95, 2023.
- [18] Z. Yang dan D. Li, "Application of Logistic Regression with Filter in Data Classification", in *Chinese Control Conference (CCC)*, 3755–3759.
- [19] X. Hui, "Comparison and Application of Logistic Regression and Support Vector Machine in Tax Forecasting", *Proceedings - 2020 International Signal Processing, Communications and Engineering Management Conference, ISPCEM*, p. 48–52, 2020.
- [20] K. Sahoo, A. K. Samal, J. Pramanik, dan S. K. Pani, "Exploratory data analysis using Python". *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, vol. 8, no. 12, 2019.