

PENERAPAN *MACHINE LEARNING* DALAM *PREDICTIVE MAINTENANCE* PADA UNIT *L.O COOLER* MESIN INDUK NKK SEMPT – PIELSTICK 12PC4-2V-570 PADA KAPAL *PASSENGER*

Kelviano Daffa Septiangga^{1*}, Nurvita Arumsari², George Endri Kusuma³

Program Studi D-IV Teknik Permesinan Kapal, Jurusan Teknik Permesinan Kapal, Politeknik Perkapalan Negeri Surabaya, Indonesia^{1*}

Program Studi D-IV Teknik Permesinan Kapal, Jurusan Teknik Permesinan Kapal, Politeknik Perkapalan Negeri Surabaya, Indonesia²

Program Studi D-IV Teknik Permesinan Kapal, Jurusan Teknik Permesinan Kapal, Politeknik Perkapalan Negeri Surabaya, Indonesia³

Email: kelvianodaffa@student.ppns.ac.id^{1*}; arum@ppns.ac.id^{2*}; kusuma.george@ppns.ac.id^{3*}

Abstract - Predictive maintenance (PdM) is a type of maintenance that is used to predict when a part of equipment or system fails and assist in planning maintenance in advance of potential future failures. Maintenance can be applied based on the equipment condition using Condition Based Monitoring (CBM). Condition Based Monitoring (CBM) is maintenance performed by monitoring equipment conditions using sensors, software, or the Internet of Things (IoT). The monitoring results are then analyzed to determine whether a condition occurred indicating damage or not, using predictive maintenance. In this research, predictive maintenance is applied to the L.O cooler unit on the main engine to predict failures on the unit based on engine log sheet data derived from the engine operational condition. The application of predictive maintenance is carried out using the results of modelling from artificial intelligence, namely machine learning with supervised learning type and the classifications used are Support Vector machine (SVM) and logistic regression. Based on the results of the ratio and method evaluation, it is found that the logistic regression method with a ratio of 90%:10% is the most accurate method as evidenced by the MAE, RMSE, RAE, and Accuracy values of 0.0012, 0.035, 0.631% dan 99.877%. The results of predictive maintenance modeling obtained that the LO cooler is predicted to fail when 3292 hours of operation.

Keyword : Condition Based Monitoring, Predictive maintenance, Lifetime, Machine Learning, Supervised Learning, Heat Exchanger, Lubricating Oil System

1. PENDAHULUAN

L.O cooler merupakan unit yang berfungsi untuk mendinginkan suhu oli dan menjaga agar oli mesin tetap dalam kondisi suhu yang optimal. Apabila *L.O cooler* mengalami kerusakan, suhu oli akan panas dan viskositas oli akan rendah yang menyebabkan gesekan antar komponen meningkat dan mesin akan cepat panas. Sehingga diperlukan perawatan untuk mencegah kerusakan atau kegagalan selama unit beroperasi. Pemeliharaan terhadap peralatan atau sistem yang dilakukan secara teratur merupakan aspek penting dalam operasional sebuah perusahaan atau organisasi.

Predictive maintenance (PdM) merupakan salah satu jenis pemeliharaan yang digunakan untuk memprediksi kapan suatu peralatan mungkin mengalami kegagalan dan membantu dalam perencanaan pemeliharaan yang memadai sebelum potensi kegagalan dimasa mendatang [1]. Perencanaan *predictive maintenance* (PdM) memiliki output memprediksi kapan unit mengalami kegagalan dan memungkinkan identifikasi potensi kegagalan pada peralatan atau sistem dengan menganalisa data operasional secara terus menerus.

Pemeliharaan dapat dilakukan secara berkala atau berdasarkan kondisi peralatan tersebut. Pemeliharaan berdasarkan kondisi peralatan atau yang biasa disebut dengan *Condition Based Monitoring* (CBM) merupakan pemeliharaan prediktif yang dilakukan dengan cara memantau kondisi operasional peralatan atau mesin secara berkala menggunakan data *real-time* yang dihasilkan dari sensor, *software*, dan *Internet of Things* (IoT). Data tersebut kemudian dianalisis untuk mendeteksi adanya perubahan kondisi yang dapat mengindikasikan adanya suatu kerusakan, salah satunya menggunakan *predictive maintenance*. Untuk melakukan *predictive maintenance* dapat dilakukan menggunakan hasil pemodelan dari kecerdasan buatan dimana saat ini kecerdasan buatan berkembang sangat pesat.

Machine learning merupakan salah satu bentuk kecerdasan buatan yang berfokus pada algoritma komputer dan memiliki kemampuan agar sistem dapat belajar sendiri melalui pengalaman [2]. *Machine learning* terbagi menjadi tiga kategori salah satunya ialah *supervised learning* dimana *supervised learning* ini memiliki beberapa metode klasifikasi yang sering digunakan dalam melakukan pemodelan

data yaitu *Support Vector Machine (SVM)* dan *Logistic Regression*. *Support vector machine (SVM)* memiliki keunggulan dalam menghasilkan klasifikasi yang baik dan diuji dengan dataset yang relatif kecil pada pengaturan parameter sederhana, juga mempunyai konsep dan formulasi yang relatif jelas dengan beberapa parameter yang mudah disesuaikan [3]. Sedangkan *logistic regression* merupakan salah satu metode klasifikasi yang paling sederhana, mampu menghasilkan probabilitas dan hasil klasifikasi yang terkalibrasi dengan baik, dan memberikan efisiensi training yang baik dalam beberapa kasus.

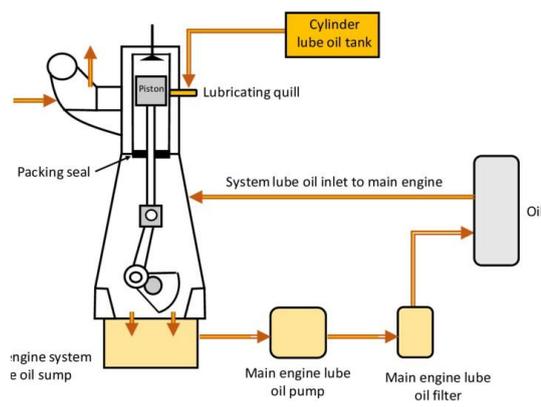
Pada data *engine log sheet* hasil dari *Condition Based Monitoring (CBM)* yang dicatat setiap 4 jam sekali selama kapal *passenger* beroperasi menunjukkan beberapa unit dari mesin yang seringkali mengalami kondisi anomali, salah satunya adalah *L.O cooler* dimana suhu oli yang keluar dari *L.O cooler* seringkali melebihi batas suhu maksimal dari kerja mesin. Meningkatnya suhu oli yang melebihi batas maksimal dari kerja mesin secara terus menerus dapat menurunkan viskositas/kekentalan oli sehingga kurang melumasi komponen pada mesin, akibatnya gesekan antar komponen mesin akan semakin meningkat sehingga terjadi keausan dan mesin akan cepat panas karena oli lebih cepat menguap. Dalam penelitian ini penerapan PdM dilakukan berdasarkan pada data *engine log sheet* dengan menggunakan hasil pemodelan dari kecerdasan buatan yaitu *machine learning* dengan metode dari *supervised learning* yaitu *Support Vector machine (SVM)* dan *logistic regression*.

2. METODOLOGI

2.1 Sistem Pelumasan (*Lubricating System*)

Menurut [4] pelumasan merupakan proses memberi minyak lumas antara dua permukaan bantalan yang bersinggungan dengan tekanan dan saling bergerak satu dengan lainnya. Fungsi dari pelumasan pada *main engine* adalah untuk mengurangi gaya gesek pada komponen dalam mesin, pendinginan, dan pencegah karat. Sebelum masuk ke mesin, Oli dari *sump tank* akan dipisahkan antara air atau fluida lain dan kotoran yang bercampur dengan oli di *L.O purifier*, kemudian oli dari *sump tank* yang sudah diproses *L.O purifier* akan dipompa menuju engine menggunakan *gear pump* dan melewati *L.O filter* lalu oli bersirkulasi di dalam mesin dan melumasi komponen-komponen pada mesin. Setelah oli bersirkulasi di dalam mesin kemudian oli akan keluar melalui *L.O outlet* dan akan dilakukan penurunan suhu oli melalui *L.O cooler* karena oli yang telah bekerja di dalam mesin memiliki suhu

yang tinggi. Berikut merupakan skema *L.O system* pada mesin induk



Gambar 1. 1 Skema Sistem Kerja Lub Oil System

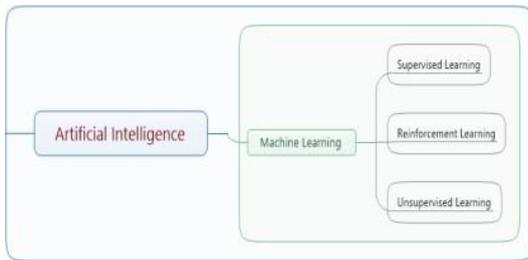
2.2 Maintenance

Maintenance atau pemeliharaan merupakan kegiatan menjaga atau memperbaiki suatu peralatan yang dilakukan secara berkala agar peralatan dapat beroperasi dengan optimal. Menurut [5] perawatan merupakan tindakan atau kegiatan yang diperlukan terhadap berbagai objek, baik yang bersifat non-teknis seperti manajemen dan sumber daya manusia untuk memastikan kinerja yang optimal, maupun yang bersifat teknis seperti material atau benda yang dapat bergerak atau tidak bergerak. Hal ini bertujuan agar komponen tersebut dapat digunakan secara efektif, berfungsi dengan baik, dan selalu memenuhi standar yang ditetapkan. Menurut [6] perawatan terbagi dalam 3 jenis ; *preventive maintenance*, *corrective maintenance*, dan *predictive maintenance*.

2.3 Machine Learning

[7], *machine learning* dapat didefinisikan sebagai metode pembelajaran hasil dari penerapan algoritma komputer dan matematika yang menghasilkan prediksi untuk masa depan yang diperoleh dari data. Metode pembelajaran yang dimaksud adalah sebuah proses pengolahan data yang dilakukan melalui dua tahapan yaitu latihan (*training*) dan pengujian (*testing*) untuk memperoleh kecerdasan tersebut.

Menurut [8], *machine learning* terbagi menjadi tiga kategori yaitu *Supervised learning*, *Unsupervised learning*, dan *Reinforcement learning*.



Gambar 1. 2 Skema *Artificial intelligence* dan *Machine Learning*

Setiap kategori dari *machine learning* memiliki *output* dan kegunaan yang berbeda-beda. Pada persoalan terkait dengan prediksi (*regression problem*) dan klasifikasi (*classification problem*) maka menggunakan *supervised learning*, pada persoalan terkait dengan klasifikasi (*classification problem*) dan deteksi anomali (*unsupervised anomaly detection*) maka menggunakan *unsupervised learning*, dan saat persoalan terkait dengan persoalan yang tidak dapat diselesaikan oleh *supervised learning* dan *unsupervised learning* maka menggunakan *reinforcement learning*.

2.4 Logistic Regression

Merupakan metode yang digunakan untuk mengetahui hubungan antara dua variabel, yaitu variabel respon (y) dengan karakteristik *dichotomous* (dua kategori) atau *polychotomous* (lebih dari dua kategori) dengan satu atau lebih variabel prediktor (x) ber-skala kategori atau numerik [2]. Metode *Logistic Regression* yang digunakan untuk menguji hipoteses sebagai berikut :

$$Y = a + \beta_1.X_1 + \beta_2.X_2 + \dots \beta_n.X_n + e \quad (1)$$

2.5 Support Vector Machine (SVM)

Menurut penelitian [9] *Support vector machine* (SVM) adalah suatu algoritma yang digunakan untuk melakukan klasifikasi maupun prediksi. *Support vector machine* (SVM) merupakan salah satu algoritma yang dapat melakukan *training* dengan *training dataset* sehingga membentuk suatu *machine learning* model yang dapat membuat prediksi atau klasifikasi dari data baru. Menemukan *hyperplane* terbaik untuk memisahkan dua kelas data input merupakan ide dasar dari SVM Fungsi pemisah (*hyperplane*) didefinisikan sebagai berikut:

$$f(x) = w \cdot x + b \quad (2)$$

2.6 Evaluasi Error

Evaluasi model performa merupakan salah satu aspek penting dalam membangun model *predictive maintenance*. Beberapa evaluasi performa model yang umum digunakan di antaranya *Mean Absolute Error* (MAE), *Root*

Mean Squared Error (RMSE), dan *Relative Absolute Error* (RAE). Setelah melakukan perhitungan nilai prediksi pada dataset *training* dengan melatih model dalam bentuk metode *supervised learning*, yang bertujuan untuk meminimalkan *cost value for the training set*, langkah selanjutnya adalah memasukkan koefisien (atau bobot) ke dalam model. Proses ini melibatkan penggunaan data *testing* untuk mengevaluasi keakuratan estimasi model terhadap dataset pengujian. Evaluasi dilakukan menggunakan metrik seperti *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE). Metrik kinerja ini memiliki rentang nilai antara 0 dan ∞ , dan masing-masing menunjukkan kecocokan yang semakin baik ketika nilai estimasi mendekati 0 [10].

Untuk mencari nilai MAE dapat menggunakan persamaan 1.

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_{i-} - y_i| \quad (3)$$

Untuk mencari nilai RMSE dapat menggunakan persamaan 2.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (h(x^{(i)}) - y^{(i)})^2} \quad (4)$$

Untuk mencari nilai RAE dapat menggunakan persamaan 3.

$$RAE = \frac{\sum_{i=1}^n |P_{(i)} - T_{i}|}{\sum_{i=1}^n |T_j - \frac{1}{m} \sum_{i=1}^m T_j|} \quad (5)$$

2.7 Perhitungan Accuracy Model

Selain itu performa *machine learning* dapat dilihat dari beberapa indikator. Dalam penelitian yang dilakukan oleh itu performa *machine learning* dapat dilihat dari beberapa indikator. Dalam penelitian yang dilakukan oleh [11] kinerja klasifikasi dapat dilihat melalui nilai kinerja klasifikasi dapat dilihat melalui nilai *True positive rate* (TP) ini adalah data positif yang diprediksi benar, *false positive rate* (FP) berupa data negatif yang salah diprediksi sebagai data positif, *precision* menggambarkan tingkat keakuratan antara data yang diminta dan hasil prediksi model. Oleh karena itu, *precision* adalah perbandingan antara prediksi positif dengan semua hasil yang diprediksi sebagai positif. Dari semua prediksi yang benar mengidentifikasi kelas positif, *precision* mengukur berapa banyak di antaranya yang benar benar positif. Nilai *precision* dapat dihitung dengan persamaan 4.

$$Precision = \frac{TP}{TP+FP} \quad (6)$$

Recall Menggambarkan seberapa baik model dalam mendeteksi kembali sebuah informasi. Oleh karena itu, *recall* adalah perbandingan antara prediksi benar positif dengan semua data

yang memang benar positif. *Recall* dapat dihitung dengan persamaan 5.

$$Recall = \frac{TP}{TP+FN} \quad (7)$$

F-measure Menggambarkan perbandingan rata-rata antara *precision* dan *recall*. Ketika dataset memiliki jumlah data *false negative* dan *false positive* yang samir sama (simetris), kita dapat menggunakan *accuracy*. Namun jika jumlahnya tidak mendekati, maka sebaiknya menggunakan *F-measure* sebagai acuan. *F-Measure* dapat dihitung dengan persamaan 6.

$$F - Measure = \frac{2 \times Recall \times Precision}{Recall + Precision} \quad (8)$$

3. Hasil dan PEMBAHASAN

3.1 Pengumpulan Data

Pada penelitian ini, data yang digunakan berupa data sensor parameter kinerja dari komponen *L.O system main engine NKK SEMT PIELSTICK 12PC4-2V-570* pada kapal *passenger*. Data sensor yang dikumpulkan sebanyak 4 sensor yang digunakan untuk memonitoring kondisi dari komponen *L.O system* pada saat *main engine* sedang beroperasi. Berikut merupakan 4 variabel sensor *L.O system* pada *main engine NKK SEMT PIELSTICK 12PC4-2V-570* yang digunakan dalam penelitian ini.

No	Kode Sensor	Jenis Sensor	Nama Sensor
1	0102	RPM	RPM Engine 1
2	0108	Pressure	LO Inlet Pressure
3	0152	Temperature	LO Inlet Temperature
4	0175	Temperature	LO Inlet Temperature Purifier

Parameter pemilihan sensor berdasarkan pada sensor mana yang paling banyak mengalami anomali, pada penelitian ini sensor *LO inlet temperature* merupakan sensor yang paling banyak mengalami anomali dimana oli yang masuk ke *engine*, seringkali masih dalam kondisi temperatur tinggi.

3.2 Pemodelan Matematis

Proses *labeling* data untuk *machine learning* dilakukan dengan membandingkan data yang telah tercatat dengan *standard* yang telah ditetapkan oleh *engine maker*. Pelabelan data dilakukan untuk model *SVM* dan *logistic regression* dengan klasifikasi sebagai berikut.

Tabel 3. 1 Label Klasifikasi Data

Nama Label	Deskripsi	Jumlah Data
Normal	<i>LO Inlet Temperature</i> < 60	810
Abnormal	<i>LO Inlet Temperature</i> ≥ 60	97

Pada Tabel 3.1 merupakan klasifikasi yang digunakan untuk pelabelan data. Klasifikasi yang digunakan berjumlah 2 klasifikasi, yaitu normal dan abnormal. Data normal berupa data *LO Inlet*

Temperature yang memiliki suhu kurang dari 60° C. Sedangkan data abnormal berupa data *LO Inlet Temperature* yang memiliki suhu lebih dari atau sama dengan 60° C.

Pada Tabel 3. 2 merupakan data monitoring sensor yang telah diklasifikasi dan diberi label.

Tabel 3. 2 Data Sensor Yang Telah Diklasifikasi

0102 (RPM)	0108 (kg/cm ²)	0152 (°C)	0175 (°C)	Hasil Deteksi
378	5.6	50	87	Normal
378	5.6	64	87	Abnormal
378	5.6	64	86	Abnormal
378	5.8	50	86	Normal
377	5.8	49	87	Normal
377	5.8	49	87	Normal
375	5.7	49	87	Normal
376	5.6	49	86	Normal
366	5.6	50	86	Normal
373	5.8	49	87	Normal
373	5.8	65	86	Abnormal

Sebelum pembuatan model *predictive maintenance*, dilakukan pembagian *dataset* menjadi 2 yaitu data *training* dan data *testing* dimana data *training* digunakan untuk mempelajari dan melatih model sedangkan data *testing* digunakan untuk mengevaluasi performa dan keakuratan model yang telah dilatih. Mengapa perlu dilakukan pembagian *training* dan *testing*, karena yang paling penting dalam pemodelan *machine learning* adalah seberapa akurat model dalam melakukan klasifikasi atau prediksi pada data yang belum pernah dilatih sebelumnya. Persentase data *training* harus lebih besar dari data *testing* agar model memiliki cukup informasi untuk mempelajari dan menyimpulkan pola dari data. Rasio pembagian *dataset training* dan *testing* dilakukan dengan beberapa rasio untuk mencari rasio pembagian *dataset* mana yang akan memiliki nilai akurasi tertinggi terhadap pemodelan *predictive maintenance*. Pada Tabel 3. 3 merupakan jumlah *dataset* berdasarkan rasio pembagian.

Tabel 3. 3 Pembagian Dataset

No	Jenis Data	Rasio	Jumlah Data	Total
1	Training	90%	816	907
	Testing	10%	91	
2	Training	80%	725	907
	Testing	20%	182	
3	Training	70%	634	907
	Testing	30%	273	
4	Training	60%	544	907
	Testing	40%	363	

Selanjutnya dilakukan evaluasi beberapa rasio pembagian data pada model model SVM dan *logistic regression*. Tujuan dilakukannya evaluasi beberapa rasio pembagian data untuk menentukan rasio mana yang memiliki nilai akurasi terbaik untuk membuat pemodelan *predictive*

maintenance dengan bantuan software WEKA TOOLS 3.8.6.

3.3 Evaluasi Rasio Model Support Vector Machine (SVM)

Tabel 3. 4 Confusion Matrix Model SVM

Percentage split	90% : 10%		80% : 20%		70% : 30%		60% : 40%	
	Prediksi		Prediksi		Prediksi		Prediksi	
Aktual	Normal	Abnormal	Normal	Abnormal	Normal	Abnormal	Normal	Abnormal
Normal	734	1	656	1	572	1	486	1
Abnormal	17	64	6	63	5	57	4	53

Pada Tabel 3. 4 merupakan hasil *confusion matrix* dari model SVM dimana pada *percentage split* rasio 60% : 40% menunjukkan kesalahan klasifikasi yang paling sedikit diantara *percentage split* rasio lainnya yaitu sebanyak 5 data diantaranya 1 data aktual berlabel normal diprediksi abnormal dan 4 data aktual berlabel abnormal diprediksi normal.

Tabel 3. 5 Classification Report Model SVM

Training	Testing	MAE	RMSE	RAE	Correct	Incorrect
90%	10%	0.022	0.148	11.36%	97.79%	2.21%
80%	20%	0.0096	0.098	4.89%	99.03%	0.97%
70%	30%	0.0094	0.097	5.08%	99.05%	0.95%
60%	40%	0.0092	0.095	5.08%	99.08%	0.92%

Berdasarkan hasil evaluasi model SVM pada Tabel 3. 5 bahwa dengan rasio pembagian data *training* dan *testing* 60% : 40%, SVM dapat mengklasifikasikan data dengan persentase ketepatan sebesar 99.08% dan presentase nilai *error* paling kecil yaitu nilai MAE adalah 0.0092, nilai RMSE adalah 0.095, dan nilai RAE adalah 5.08%.

Hasil uji keakuratan model juga dilihat dari nilai *detail accuracy classification* dimana nilai-nilai tersebut juga digunakan untuk mengetahui seberapa baik model dapat mengklasifikasikan antara data aktual dengan data prediksi. Berikut merupakan nilai-nilai *detail accuracy classification* model :

Tabel 3. 6 Detail Accuracy Classification Model SVM

Training	Testing	TP Rate	FP Rate	Precision	Recall	F - Measure	Class
90%	10%	0.999	0.210	0.977	0.999	0.988	Normal
		0.790	0.001	0.985	0.790	0.877	Abnormal
Average		0.978	0.189	0.978	0.978	0.977	
80%	20%	0.998	0.087	0.991	0.998	0.995	Normal
		0.913	0.002	0.984	0.913	0.947	Abnormal
Average		0.991	0.073	0.990	0.991	0.990	
70%	30%	0.998	0.081	0.991	0.998	0.995	Normal
		0.919	0.002	0.983	0.919	0.950	Abnormal
Average		0.991	0.073	0.990	0.991	0.990	
60%	40%	0.998	0.070	0.992	0.998	0.995	Normal
		0.930	0.002	0.981	0.930	0.955	Abnormal
Average		0.991	0.063	0.991	0.991	0.991	

Berdasarkan hasil evaluasi rasio *percentage split* pada software WEKA TOOLS menggunakan model SVM dengan 4 kombinasi rasio *percentage split* yang berbeda, menunjukkan bahwa semakin besar nilai rasio *percentage split* maka nilai akurasi akan semakin baik, dibuktikan dengan hasil *confusion matrix* dan hasil *classification*

report. Hasil *confusion matrix* model SVM pada rasio 60% : 40% memiliki kesalahan klasifikasi hanya 5 data, untuk hasil *classification report* model SVM pada rasio 60% : 40% memiliki nilai *error* paling kecil dari rasio lainnya dibuktikan dengan nilai MAE, RMSE, dan RAE berturut-turut yaitu 0.0092, 0.095, dan 5.08%.

3.4 Evaluasi Rasio Model Logistic Regression

Tabel 3. 7 Confusion Matrix Model Logistic Regression

Percentage split	90% : 10%		80% : 20%		70% : 30%		60% : 40%	
	Prediksi		Prediksi		Prediksi		Prediksi	
Aktual	Normal	Abnormal	Normal	Abnormal	Normal	Abnormal	Normal	Abnormal
Normal	734	1	656	1	572	1	486	1
Abnormal	0	81	0	69	0	62	0	57

Pada Tabel 3. 7 merupakan Hasil *confusion matrix* dari model *logistic regression* dimana pada setiap rasio *percentage split* menunjukkan kesalahan klasifikasi yang sama yaitu hanya 1 data saja, sehingga dilakukan evaluasi berdasarkan nilai *error* yaitu MAE, RMSE, dan RAE yang ditunjukkan dalam tabel *classification report* berikut.

Tabel 3. 8 Classification Report Model Logistic Regression

Training	Testing	MAE	RMSE	RAE	Correct	Incorrect
90%	10%	0.0012	0.035	0.631%	99.877%	0.123%
80%	20%	0.0014	0.037	0.699%	99.862%	0.138%
70%	30%	0.0016	0.039	0.847%	99.842%	0.158%
60%	40%	0.0018	0.042	1.018%	99.816%	0.184%

Pada Tabel 3. 8 merupakan *classification report* dari model *logistic regression* yang menunjukkan bahwa dengan rasio pembagian data *training* dan *testing* 90% : 10%, *logistic regression* dapat mengklasifikasikan data dengan persentase ketepatan sebesar 99.877% dan presentase nilai *error* paling kecil yaitu nilai MAE adalah 0.0012, nilai RMSE adalah 0.035, dan nilai RAE adalah 0.631%.

Hasil uji keakuratan model juga dilihat dari nilai *detail accuracy classification* dimana nilai-nilai tersebut juga digunakan untuk mengetahui seberapa baik model dapat mengklasifikasikan antara data aktual dengan data prediksi. Berikut merupakan nilai-nilai *detail accuracy classification* model :

Tabel 3. 9 Detail Accuracy Classification Model Logistic Regression

Training	Testing	TP Rate	FP Rate	Precision	Recall	F - Measure	Class
90%	10%	0.999	0	1	0.999	0.999	Normal
		1	0.001	0.988	1	0.994	Abnormal
Average		0.999	0	0.999	0.999	0.999	
80%	20%	0.998	0	1	0.998	0.999	Normal
		1	0.002	0.986	1	0.993	Abnormal
Average		0.999	0	0.999	0.999	0.999	
70%	30%	0.998	0	1	0.998	0.999	Normal
		1	0.002	0.984	1	0.992	Abnormal
Average		0.998	0	0.998	0.998	0.998	
60%	40%	0.998	0	1	0.998	0.999	Normal
		1	0.002	0.983	1	0.991	Abnormal
Average		0.998	0	0.998	0.998	0.998	

Berdasarkan hasil evaluasi rasio *percentage split* pada *software WEKA TOOLS* menggunakan model *logistic regression* dengan 4 kombinasi rasio *percentage split* yang berbeda, menunjukkan bahwa semakin besar nilai rasio *percentage split* maka nilai akurasi akan semakin baik, dibuktikan dengan hasil *confusion matrix* dan hasil *classification report*. Hasil *confusion matrix* model *logistic regression* pada rasio 90% : 10% memiliki kesalahan klasifikasi hanya 1 data, untuk hasil *classification report* model *logistic regression* pada rasio 90% : 10% memiliki nilai error paling kecil dari rasio lainnya dibuktikan dengan nilai MAE, RMSE, dan RAE berturut-turut yaitu 0.0012, 0.035, dan 0.631%.

3.5 Pemodelan Predictive Maintenance

Setelah melakukan evaluasi nilai akurasi setiap rasio, selanjutnya melakukan pemodelan *predictive maintenance* menggunakan metode SVM dan *logistic regression* dengan bantuan *software WEKA TOOLS*. Pemodelan dilakukan menggunakan *dataset* yang telah dibagi 60% untuk data *training* dan 40% untuk data *testing*.

3.6 Training Model Dengan Metode Support Vector Machine

Training model dilakukan menggunakan data *training* untuk melatih model agar dapat mempelajari pola dari data *training* yang nantinya model tersebut akan digunakan untuk memprediksi kapan terjadinya kerusakan *lo cooler* pada data baru atau data *testing*. Berikut merupakan hasil uji model dengan data *training* menggunakan metode SVM.

Tabel 3. 10 Confusion Matrix Training Model Metode SVM

Percentage split	60% : 40%	
Aktual	Prediksi	
	Normal	Abnormal
Normal	510	0
Abnormal	0	34

Pada Tabel 3. 10 merupakan hasil *confusion matrix* dari model yang menunjukkan sebanyak 510 data dari 510 data normal berhasil di klasifikasikan dengan benar dan sebanyak 34 data abnormal dari total 34 data berhasil di prediksi dengan benar. Dengan hasil ini metode SVM mampu mempelajari dan memprediksi data *training* dengan akurat.

3.7 Prediksi Kegagalan Mendatang LO Cooler Metode SVM

Tabel 3. 11 Contoh Output Prediksi Kegagalan

Instance	Actual	Predicted	Prediction	Running Hours
1	1:?	1:NORMAL	1	2180
2	1:?	1:NORMAL	1	2184
3	1:?	1:NORMAL	1	2188
...
33	1:?	1:NORMAL	1	2308
34	1:?	1:NORMAL	1	2312
35	1:?	2:ABNORMAL	1	2316
...
114	1:?	2:ABNORMAL	1	2632
115	1:?	1:NORMAL	1	2636
116	1:?	1:NORMAL	1	2640
...
362	1:?	1:NORMAL	1	3624
363	1:?	1:NORMAL	1	3628

Pada Tabel 3. 11 menunjukkan contoh *output* dari pemodelan *predictive maintenance*, berdasarkan hasil prediksi untuk kegagalan *LO cooler* akan terjadi setelah beroperasi selama 2316 jam kedepan. Hasil prediksi ini akan digunakan untuk menentukan strategi perawatan *lo cooler*.

3.8 Training Model Dengan Metode Logistic Regression

Tabel 3. 12 Confusion Matrix Training Model Metode Logistic Regression

Percentage split	90% : 10%	
Aktual	Prediksi	
	Normal	Abnormal
Normal	746	0
Abnormal	0	70

Pada Tabel 3. 12 merupakan hasil *confusion matrix* dari model yang menunjukkan sebanyak 746 data dari 746 data normal berhasil di klasifikasikan dengan benar dan sebanyak 70 data abnormal dari total 70 data berhasil di prediksi dengan benar. Dengan hasil ini metode *logistic regression* mampu mempelajari dan memprediksi data *training* dengan akurat.

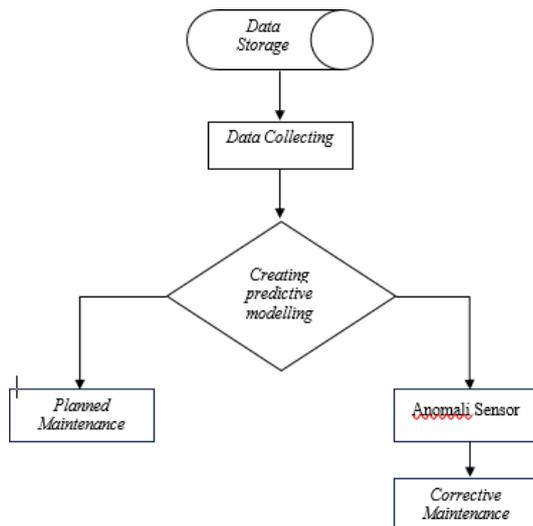
3.9 Prediksi Kegagalan Mendatang LO Cooler Metode Logistic Regression

Tabel 3. 13 Contoh Output Prediksi Kegagalan

Instance	Actual	Predicted	Prediction	Running Hours
1	1:2	1:NORMAL	1	3268
2	1:2	1:NORMAL	1	3272
3	1:2	1:NORMAL	1	3276
4	1:2	1:NORMAL	1	3280
5	1:2	1:NORMAL	1	3284
6	1:2	1:NORMAL	1	3288
7	1:2	2:ABNORMAL	1	3292
...
...
48	1:2	1:NORMAL	1	3456
49	1:2	1:NORMAL	1	3460
50	1:2	2:ABNORMAL	1	3464
...
...
89	1:2	2:ABNORMAL	1	3620
90	1:2	1:NORMAL	1	3624
91	1:2	1:NORMAL	1	3628

Pada Tabel 3. 13 menunjukkan contoh output dari pemodelan predictive maintenance, berdasarkan hasil prediksi untuk kegagalan LO cooler akan terjadi setelah beroperasi selama 3292 jam kedepan. Hasil prediksi ini akan digunakan untuk menentukan strategi perawatan lo cooler.

3.10 Strategi Perawatan



Gambar 3. 1 Skema Strategi Perawatam

Berdasarkan skema strategi perawatan, dalam melakukan predictive maintenance, langkah pertama yang dilakukan adalah pengumpulan data operasional kapal yang telah ter-record pada engine log sheet. Data tersebut berupa hasil rekaman setiap 4 jam dari setiap sensor pada sistem yang terdapat di engine room. Selanjutnya dilakukan reprocessing data untuk membuat pemodelan predictive maintenane dengan metode SVM dan logistic regression. Hasil dari pemodelan predictive maintenance menggunakan metode yang terpilih yaitu logistic regression bahwa LO cooler diprediksi akan mengalami kegagalan setelah beroperasi selama

3292 jam. Selanjutnya menentukan pemilihan maintenance yang akan dilakukan, antara planned maintenance atau corrective maintenance.

3.11 Planned Maintenance

Planned maintenance merupakan jenis perawatan yang dilakukan secara teratur dan direncanakan sebelumnya. Tujuan dilakukannya planned maintenance adalah untuk mencegah terjadinya kerusakan atau kegagalan yang tidak terduga.

Penentuan dilakukannya planned maintenance dapat dilakukan dengan perhitungan total jam operasional kapal untuk melakukan prediksi interval perawatan pada lo cooler. Pada kapal passenger lama operasional dalam 1 kali perjalanan adalah 32 jam, sedangkan dalam seminggu pelayaran dilakukan sebanyak 4 kali, jadi lama operasional dalam seminggu adalah 128 jam, sehingga dalam 1 tahun lama operasional yang dilakukan pada kapal passenger adalah 6.144 jam. Pada perhitungan total jam operasional kapal dibutuhkan waktu downtime (docking) kapal, pada kapal passenger docking dilakukan 1 kali dalam setahun. Berikut jadwal docking yang dilakukan kapal passenger selama beroperasi.

Tabel 3. 14 Jadwal Docking Kapal

Tanggal Docking	Lama Docking (Hari)	Lama Docking (Hari)	Lama Docking (Jam)
7 - 19 November	13 Hari	- Blower Side Tc ng bocor - Rumah ball bearing pecah	312 Jam
16 - 24 Februari	9 Hari	- Coil katapas rem crane rusak	216 Jam
6 - 11 Maret	6 Hari	- Rekonidisi elmoat	144 Jam
25 Maret - 1 April	8 Hari	- Cleaning exh valve ME	192 Jam
7 - 18 Juni	12 Hari	- Cuci intercooler turbo	288 Jam
Total	48 Hari		1.152 Jam

Selama beroperasi, LO cooler belum pernah mengalami kegagalan, sehingga perawatan pada LO cooler dapat dilakukan bersamaan dengan waktu docking tahunan atau planned maintenance untuk mengurangi downtime dan mencegah terjadinya kerusakan yang tidak terduga karena perawatan lebih terjadwal.

3.12 Corrective Maintenance

Corrective maintenance dilakukan ketika terjadi anomali pada lo cooler saat kapal sedang beroperasi, dimana saat anomali terjadi alarm di engine room akan berbunyi dan ABK langsung melakukan pengecekan pada lo cooler. Langkah pertama yang dilakukan adalah mengidentifikasi penyebab anomali, apabila terjadi kerusakan maka dilakukan pengambilan tindakan apakah hanya dilakukan perbaikan atau harus mengganti komponen yang rusak. Pemodelan ini dilakukan untuk mencegah kerusakan yang lebih parah dan kapal dapat segera kembali beroperasi.

Ketika LO cooler telah beroperasi selama 3292 jam dan mengalami anomali sesuai dengan hasil prediksi, maka perawatan *corrective maintenance* dapat dilakukan untuk mencegah kerusakan yang lebih parah. Sedangkan *planned maintenance* dapat diterapkan dengan cara melakukan perawatan bersamaan dengan docking tahunan untuk mengurangi *downtime* dan mencegah terjadinya kerusakan yang tidak terduga karena perawatan lebih terjadwal.

4. KESIMPULAN

Pemodelan *machine learning* untuk melakukan *predictive maintenance* dilakukan menggunakan *software WEKA TOOLS 3.8.6*. Data *input* yang digunakan untuk pemodelan ini adalah data *record* operasional kapal secara *real time* pada sistem pelumasan yaitu *RPM engine*, *LO inlet pressure*, dan *LO inlet temperature* yang telah diklasifikasi dan dibagi menjadi data *training* dan data *testing* dengan rasio terbaik. Hasil dari pemodelan ini adalah prediksi kegagalan pada peralatan dengan parameter jam operasional yang dibutuhkan peralatan hingga mengalami anomali yang diukur melalui TP, FP, *F-measure*, dll.

Model *machine learning* yang memiliki tingkat akurasi yang paling baik untuk menunjang pemodelan *predictive maintenance* dalam melakukan prediksi kegagalan *lo cooler* adalah model *logistic regression* berdasarkan *classification report* pada rasio 90% : 10% dengan nilai MAE, RMSE, dan RAE berturut-turut yaitu 0.0012, 0.035, dan 0.631% dan rata-rata nilai akurasi TP, FP, dan *F-measure* berturut-turut adalah 0.999, 0, dan 0.999.

Berdasarkan hasil pemodelan *predictive maintenance* yang telah dilakukan menggunakan metode *logistic regression* dengan rasio pembagian data 90% : 10%, prediksi kegagalan pada *LO cooler* akan terjadi setelah 3292 jam beroperasi, sehingga strategi perawatan yang dapat dilakukan adalah dengan menerapkan *corrective maintenance* saat terjadi anomali untuk mencegah kerusakan yang semakin parah.

5. DAFTAR PUSTAKA

- [1] R. Kizito, P. Scruggs, X. Li, R. Kress, M. Devinney, and T. Berg, "The application of random forest to predictive maintenance," *IISE Annu. Conf. Expo 2018*, pp. 354–359, 2018.
- [2] A. H. Rambe, "Klasifikasi Data Getaran Motor Beat Pop Dengan Metode Support Vector Machine (Svm) Menggunakan Bahasa Python," 2022, [Online]. Available: <https://dspace.uui.ac.id/handle/123456789/41128%0Ahttps://dspace.uui.ac.id/bitstr>

- [3] A. S. Rahayu, A. Fauzi, and R. Rahmat, "Komparasi Algoritma Naïve Bayes Dan Support Vector Machine (SVM) Pada Analisis Sentimen Spotify," *J. Sist. Komput. dan Inform.*, vol. 4, no. 2, p. 349, 2022, doi: 10.30865/json.v4i2.5398.
- [4] Z. A. Yusuf, "Analisa Perawatan Berbasis Resiko Pada Sistem Pelumas Km. Lambelu," *J. Ris. dan Teknol. Kelaut.*, vol. 14, no. 1, pp. 129–140, 2016.
- [5] Widiatmaka F. Pambudi, *Manajemen Perawatan Dan Perbaikan Kapal*, vol. 8311527. 2017. [Online]. Available: <http://repository.pip-semarang.ac.id/93/1/11.MANAJEMEN PERAWATAN DAN PERBAIKAN KAPAL%23.pdf>
- [6] M. Nasution, A. Bakhori, and W. Novarika, "Manfaat Perlunya Manajemen Perawatan Untuk Bengkel Maupun Industri," *Bul. Utama Tek.*, vol. 16, No. 3, pp. 248–252, 2021.
- [7] A. Roihan, P. A. Sunarya, and A. S. Rafika, "Pemanfaatan Machine Learning dalam Berbagai Bidang: Review paper," *IJCIT (Indonesian J. Comput. Inf. Technol.)*, vol. 5, no. 1, pp. 75–82, 2020, doi: 10.31294/ijcit.v5i1.7951.
- [8] M. Somvanshi, "Iccubea.2016.7860040," 2016.
- [9] H. Apriyani and K. Kurniati, "Perbandingan Metode Naïve Bayes Dan Support Vector Machine Dalam Klasifikasi Penyakit Diabetes Melitus," *J. Inf. Technol. Ampere*, vol. 1, no. 3, pp. 133–143, 2020, doi: 10.51519/journalita.volume1.issue3.yea r2020.page133-143.
- [10] W. K. O. Ho, B. S. Tang, and S. W. Wong, "Predicting property prices with machine learning algorithms," *J. Prop. Res.*, vol. 38, no. 1, pp. 48–70, 2021, doi: 10.1080/09599916.2020.1832558.
- [11] I. J. Biosci and R. M. Dellosa, "Determining the classification of dry beans using WEKA," *Int. J. Biosci.*, vol. 6655, pp. 81–92, 2023, doi: 10.12692/ijb/23.1.81-92.