

PREDICTIVE MAINTENANCE ON DRY 8 PRODUCTION MACHINE LINE USING SUPPORT VECTOR MACHINE (SVM)

[PREDICTIVE MAINTENANCE PADA LINE MESIN PRODUKSI DRY 8 MENGGUNAKAN SUPPORT VECTOR MACHINE (SVM)]

Mohammad Andi Rasyid¹⁾, Tedjo Sukmono^{*, 2)}

¹⁾ Program Studi Teknik Industri, Universitas Muhammadiyah Sidoarjo, Indonesia

²⁾ Program Studi Teknik Industri, Universitas Muhammadiyah Sidoarjo, Indonesia

*Email Penulis Korespondensi: thedjoss@umsida.ac.id

Abstract. *Machines are the main element in manufacturing companies, the role of machine performance is vital in the production process so that the condition of the machine must always be in an optimal state. Maintenance problems are often faced by manufacturing companies. The high downtime caused by frequent damage to the machine has a big impact on the productivity that the company wants to achieve. This research aims to implement the support vector machine (SVM) method to create a predictive maintenance model and evaluate the level of accuracy and error value produced by the model. The SVM method is a method that can be used in classification and regression cases. The SVM method was chosen because it can predict well with a high level of accuracy and a low error value. The evaluation technique used by analyzing the performance of the system by comparing the level of modeling accuracy based on four types of kernel functions, namely linear, radial basis function (RBF), polynomial and sigmoid. From the evaluation results, the linear kernel function with 90%:10% training and test data division was chosen because it was able to produce the best performance with an accuracy value of 99.8%, precision of 83%, recall of 83%, f1-score of 83% and a mean square error value of 3.2%. This research is expected to provide solutions for companies in conducting predictive maintenance and preventive maintenance to reduce the frequency of machine breakdowns and reduce the level of downtime.*

Keywords - *Confusion Matrix, Machine Learning, Predictive Maintenance, Support Vector Machine*

Abstrak. Mesin merupakan elemen utama dalam perusahaan manufaktur, peran kinerja mesin sangat vital dalam proses produksi sehingga kondisi mesin harus selalu dalam keadaan optimal. Permasalahan *maintenance* sering kali dihadapi oleh perusahaan manufaktur. Tingginya *downtime* yang diakibatkan oleh seringnya terjadi kerusakan pada mesin memberikan dampak yang besar terhadap produktivitas yang ingin dicapai oleh perusahaan. Penelitian ini bertujuan untuk mengimplementasikan metode *support vector machine* (SVM) untuk membuat model *predictive maintenance* dan mengevaluasi tingkat akurasi dan nilai *error* yang dihasilkan oleh model tersebut. Metode SVM merupakan metode yang dapat digunakan pada kasus klasifikasi dan regresi. Metode SVM dipilih karena dapat melakukan prediksi dengan baik dengan tingkat akurasi yang tinggi dan nilai *error* yang rendah. Teknik evaluasi yang digunakan dengan menganalisis kinerja sistem dengan membandingkan tingkat akurasi pemodelan berdasarkan empat jenis fungsi *kernel*, yaitu *linear*, *radial basis function* (RBF), *polynomial*, dan *sigmoid*. Dari hasil evaluasi, fungsi *kernel linear* dengan pembagian data latih dan uji 90%:10% dipilih karena mampu menghasilkan performa terbaik dengan nilai akurasi sebesar 99.8%, *precision* sebesar 83%, *recall* sebesar 83%, *f1-score* sebesar 83% dan nilai *mean square error* sebesar 3.2%. Penelitian ini diharapkan dapat memberikan solusi bagi perusahaan dalam melakukan perawatan prediktif dan perawatan preventif untuk mengurangi frekuensi kerusakan mesin dan mengurangi tingkat *downtime*.

Kata Kunci – *Confusion Matrix; Pembelajaran Mesin; Prediksi Pemeliharaan; Support Vector Machine*

I. PENDAHULUAN

A. Latar Belakang

PT XYZ merupakan salah satu perusahaan yang bergerak di bidang industri manufaktur yang menghasilkan produk berupa mie. Beberapa jenis produk yang dihasilkan antara lain mie kering, mie instan dan mie bihun. Untuk menjaga mutu dan kualitas produk yang dihasilkan, perusahaan telah memiliki sertifikat ISO 22000:18 untuk manajemen pangan dan terus melakukan perbaikan secara konsisten dan berkesinambungan untuk memenuhi kebutuhan konsumen. Dalam proses produksinya, perusahaan memiliki lini mesin instan, mesin kering dan mesin bihun. Dalam hal perawatan mesin, perusahaan menerapkan *preventive maintenance*, *breakdown maintenance* dan *scheduling maintenance* [1].

Salah satu masalah utama yang dihadapi oleh perusahaan adalah terjadinya kerusakan mesin DRY 8 yang mengakibatkan *downtime* sehingga proses produksi terganggu. Dengan keterbatasan teknisi sebagai pelaksana perbaikan dan kurangnya ketersediaan suku cadang mesin, maka perusahaan perlu memastikan dapat menentukan solusi terbaik untuk mengatasi permasalahan tersebut. Jumlah jam kerja yang tersedia sebanyak 22,5 jam per hari dan

rata-rata jumlah kerusakan mesin sebanyak enam kali dalam sebulan akan mengurangi jam kerja rata-rata sebanyak 0,71 jam per hari yang dapat berakibat tidak tercapainya produktivitas yang ingin dicapai oleh perusahaan. Komponen mesin yang sering mengalami kerusakan seperti *gear box*, *bearing*, *as sprocket*, roda gigi dan *cutter box*. Oleh karena itu, perusahaan harus mencari alternatif terbaik yang akan membantu menyelesaikan permasalahan tersebut [2].

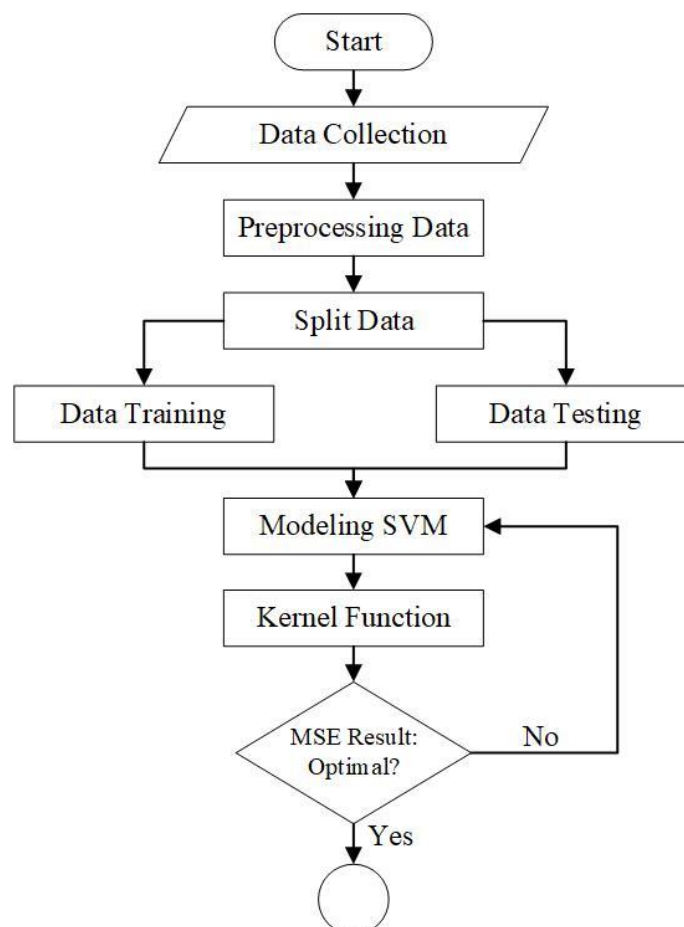
Penelitian mengenai *predictive maintenance* dengan menggunakan metode *support vector machine* (SVM) telah dilakukan oleh Haliza yang menyatakan bahwa metode SVM mampu menghasilkan nilai akurasi yang tinggi dalam melakukan prediksi [3]. Sementara itu, penelitian yang dilakukan oleh Saputra menyatakan bahwa algoritma SVM dapat dilakukan dengan fungsi *kernel linear*, *radial basis function* (RBF), *polynomial*, dan *sigmoid* [4]. Sementara itu, penelitian yang dilakukan oleh Wafa menyatakan bahwa penggunaan metode *radial basis function* (RBF) SVM dapat menghasilkan nilai akurasi yang tinggi pada kasus prediksi dengan nilai *mean square error* (MSE) yang optimal [5]. Sedangkan penelitian yang dilakukan oleh Patriya metode SVM dapat menghasilkan kemampuan prediksi dengan nilai *root mean square error* (RMSE) baik pada data *training* maupun data *testing* [6].


Berdasarkan permasalahan yang terjadi, metode *support vector machine* (SVM) dipilih sebagai alternatif terbaik untuk menyelesaikan permasalahan tersebut. *Support vector machine* (SVM) dikenal dapat memberikan akurasi yang tinggi dalam memprediksi data yang potensial. Hal ini telah dibuktikan dalam banyak implementasi SVM untuk mencari solusi optimal secara global yang memberikan hasil terbaik dibandingkan dengan algoritma lainnya, terutama dalam hal prediksi. Dengan adanya implementasi SVM ini diharapkan perusahaan dapat memberikan solusi dalam melakukan *predictive maintenance* dan *preventive maintenance* sehingga kedepannya akan lebih baik dalam melakukan perawatan mesin dan dapat meminimalisir kerusakan pada mesin-mesin produksi [7]. Tujuan dari penelitian ini adalah membuat model *support vector machine* (SVM) sebagai *predictive maintenance* yang dapat digunakan sebagai salah satu bahan pertimbangan evaluasi perawatan mesin. Selain itu, mengevaluasi implementasi SVM dengan menganalisis nilai akurasi dan *error* dari hasil pengujian.

II. METODE

A. Alur Penelitian

Pada tahap ini menjelaskan mengenai alur proses pembuatan sistem pada penelitian ini. Berikut merupakan tahapan yang dilakukan untuk membuat model *support vector machine* seperti yang terlihat pada gambar 1.





Gambar 1 Flowchart Penelitian.

B. Pengumpulan Data

Tahap awal dalam penelitian ini dilakukan pengumpulan data. Data yang akan digunakan adalah data prediksi pemeliharaan yang bersumber dan bisa diakses melalui *website* www.kaggle.com. Data yang terkumpul terdiri dari 10.000 data yang terbagi pada beberapa atribut yang terlihat pada tabel berikut [8].

Tabel 1 Atribut *Dataset*.

No	Atribut	Deskripsi	Tipe Data
1	UDI	Varian atribut sebagai petunjuk nomer urut data	<i>Numeric</i>
2	<i>Product ID</i>	Varian data yang terdiri dari seri angka yang beragam	<i>Object</i>
3	<i>Type</i>	varian data yang terdiri dari huruf L, M dan H	<i>Object</i>
4	<i>Air Temperature</i>	Temperatur udara disekitar mesin dalam satuan <i>kelvin</i>	<i>Numeric</i>
5	<i>Preces Temperature</i>	Nilai yang menunjukkan kecepatan suatu mesin	<i>Numeric</i>
6	<i>Rational Speed</i>	Temperatur udara yang dihasilkan pada proses kerja dalam satuan <i>kelvin</i>	<i>Numeric</i>
7	<i>Torque</i>	Besaran nilai gaya yang dihasilkan suatu mesin dalam satuan <i>newton meter (Nm)</i>	<i>Numeric</i>
8	<i>Tool Wear</i>	Tingkat penggunaan suatu peralatan atau mesin	<i>Numeric</i>
9	<i>Target</i>	Varian atribut yang terdiri dari angka 0 yang mendefinisikan mesin tidak mengalami kerusakan, sedangkan angka 1 mendefinisikan mesin mengalami kerusakan	<i>Numeric</i>
10	<i>Failure Type</i>	Kondisi mesin mengalami kerusakan atau tidak	<i>Object</i>

C. Preprocessing

Tahap *preprocessing* merupakan langkah terpenting dalam data mining, karena merupakan proses mengubah data mentah menjadi data yang sesuai dengan prosedur penambangan yang akan dilakukan [9]. Dalam penelitian ini *preprocessing* terbagi menjadi dua tahap yaitu data *cleaning* dan data *reduction*.

1. Data *Cleaning*

Tahap pembersihan data mengacu pada perubahan, modifikasi, atau penghapusan data dalam *database* yang dianggap tidak perlu, tidak lengkap, tidak akurat, atau format *database* atau *file* yang salah untuk menghasilkan data berkualitas tinggi [10].

2. Data *Reduction*

Pada tahap pemilihan data ini, dimensi atau atribut pada kumpulan data dihilangkan untuk mengoptimalkan atribut-atribut yang mempengaruhi keakuratan algoritma dalam proses penambangan kumpulan data, karena atribut nama dan simbol dalam kumpulan data ini akan dihilangkan dikurangi [11].

D. Pemodelan SVM

Tahap pembuatan model dalam penelitian ini menggunakan algoritma *support vector machine (SVM)*. *Support Vector Machine (SVM)* merupakan metode pembelajaran terawasi yang bisa digunakan dalam regresi dan klasifikasi [12]. Algoritma ini dapat menyelesaikan masalah prediksi atau klasifikasi dengan cara membagi kelas data dengan garis pemisah [13]. Algoritma ini mempunyai performa lebih tinggi diantara sistem lainnya [14]. Teori dasar SVM berasal dari gabungan teori-teori ilmu komputer yang sudah ada [15]. Prinsip mendasar dari algoritma ini adalah klasifikasi *linear* [16]. Algoritma SVM sangat diapresiasi oleh mereka yang bekerja di bidang data *mining* dan *machine learning*. Performa sebenarnya dalam memprediksi tipe data baru sangat akurat [17]. Tujuan dari SVM digunakan sebagai perancangan metode pembelajaran lebih efisien secara komputasi guna memisahkan *hyperplane* pada ruang fitur yang memiliki dimensi tinggi [18].

Algoritma SVM mempunyai beberapa kelas metode kernel berdasarkan teori pembelajaran statistik. Peran kernel berguna untuk menggerakkan ruang fitur dengan memetakan data pelatihan secara implisit ke ruang yang memiliki dimensi tinggi yang disebut sebagai ruang *kernel*. Dalam ruang *kernel* dapat memisahkan data menjadi kelas yang berbeda dengan sebuah *hyperline linear* [19]. *Kernel* yang digunakan dalam penelitian ini yaitu *linear*, *radial basis function* (RBF), *sigmoid* dan *polynomial* dengan membandingkan performa yang dihasilkan [20]. Persamaan yang dapat digunakan untuk menghitung fungsi *kernel* sebagai berikut.

1. *Kernel Linear*
 $K(x, y) = x^T \cdot y + c$ 1
 Sumber: [21].
2. *Kernel Radial Basis Function* (RBF)
 $K(x, y) = \exp\left(-\frac{\|x-y\|^2}{2\sigma^2}\right)$ 2
 Sumber: [21].
3. *Kernel Sigmoid*
 $K(x, y) = \text{Tanh}(ax^+ \cdot y + c)$ 3
 Sumber: [21].
4. *Kernel Polynomial*
 $K(x, y) = (ax^T y + c)^d$ 4
 Sumber: [21].

E. Evaluasi

Tahap evaluasi dalam penelitian ini digunakan untuk mengukur performa dan mengevaluasi model yang telah dibuat [22]. Dalam penelitian ini metode yang digunakan untuk evaluasi memanfaatkan *confusion matrix* yang menempatkan kelas prediksi di awal matriks dan kemudian data observasi di sisi kiri matriks. Setiap sel matriks berisi angka yang menunjukkan jumlah kasus sebenarnya di kelas yang diamati [23]. *Confusion matrix* merupakan salah satu metode yang digunakan pada proses evaluasi kinerja model data mining klasifikasi dengan memprediksi kebenaran objek [24]. Parameter yang dapat digunakan pada *confusion matrix* secara sederhana dapat disajikan menggunakan tabel 2.

Tabel 2 *Confusion Matrix*.

		Prediksi	
		<i>Positive</i>	<i>Negative</i>
Aktual	<i>Positive</i>	<i>True Positive</i> (TP)	<i>False Negative</i> (FN)
	<i>Negative</i>	<i>False Positive</i> (FP)	<i>True Negative</i> (TN)

True Positive (TP) merupakan nilai aktual bernilai positif dan prediksi bernilai positif. *False Positive* (FP) merupakan nilai aktual bernilai negatif tetapi nilai prediksi bernilai positif. *True Negative* (TN) merupakan nilai aktual bernilai negatif dan nilai prediksi bernilai negatif. *False Negative* (FN) merupakan nilai aktual bernilai positif tetapi nilai prediksinya bernilai negatif [25].

Berdasarkan evaluasi *confusion matrix* dilakukan perhitungan nilai akurasi, presisi, *recall* dan *f1-score*. Skor akurasi menunjukkan seberapa akurat sistem dapat mengklasifikasikan data. Dengan kata lain, skor akurasi adalah rasio data yang diklasifikasikan dengan benar terhadap total data [26]. Presisi adalah tingkat keakuratan antara informasi yang diminta oleh pengguna dengan respon yang diberikan oleh sistem [27]. *Recall* adalah persentase data kategori positif yang diklasifikasikan dengan benar oleh sistem [28]. *F1-score* adalah perbandingan rata-rata tertimbang antara presisi dan perolehan [29]. Persamaan yang dapat digunakan untuk menghitung akurasi, presisi, *recall* dan *f1-score* sebagai berikut.

- $$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$
- 5
-
- Sumber: [30].
- $$\text{Precision} = \frac{TP}{TP + FP}$$
- 6
-
- Sumber: [30].
- $$\text{Recall} = \frac{TP}{TP + FN}$$
- 7
-
- Sumber: [30].
- $$\text{F1 - Score} = \frac{2 * \text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}}$$
- 8
-
- Sumber: [30].

III. HASIL DAN PEMBAHASAN

A. Dataset

Data yang digunakan merupakan *dataset* prediksi pemeliharaan yang memiliki jumlah 10.000 data dengan 10 atribut data. Gambar 2 merupakan gambar *source code import dataset*. Gambar 3 merupakan *dataset* yang digunakan dalam proses pembuatan model SVM.

```
df=pd.read_csv("../content/drive/MyDrive/predictive_maintenance.csv")
```

Gambar 2 Source Code Import Dataset.

	UDI	Product ID	Type	Air temperature [K]	Process temperature [K]	Rotational speed [rpm]	Torque [Nm]	Tool wear [min]	Target	Failure Type
0	1	M14860	M	298.1	308.6	1551	42.8	0	0	No Failure
1	2	L47181	L	298.2	308.7	1408	46.3	3	0	No Failure
2	3	L47182	L	298.1	308.5	1498	49.4	5	0	No Failure
3	4	L47183	L	298.2	308.6	1433	39.5	7	0	No Failure
4	5	L47184	L	298.2	308.7	1408	40.0	9	0	No Failure
...
9995	9996	M24855	M	298.8	308.4	1604	29.5	14	0	No Failure
9996	9997	H39410	H	298.9	308.4	1632	31.8	17	0	No Failure
9997	9998	M24857	M	299.0	308.6	1645	33.4	22	0	No Failure
9998	9999	H39412	H	299.0	308.7	1408	48.5	25	0	No Failure
9999	10000	M24859	M	299.0	308.7	1500	40.2	30	0	No Failure

10000 rows x 10 columns

Gambar 3 Dataset.

B. Preprocessing Data

1. Data Cleaning

Tahap data *cleaning* dilakukan dengan menghapus data yang tidak lengkap dan tidak konsisten. Gambar 4 merupakan *source code data cleaning*.

```
df.isnull().sum()
```

Figure 4 Source Code Data Cleaning.

2. Data Reduction

Tahap data *reduction* menghilangkan atribut yang tidak digunakan dalam proses pengujian. Atribut data yang akan dihapus adalah atribut UDI dan *Product ID*. Gambar 5 merupakan *source code data reduction*.

```
df = df.drop(["UDI", "Product ID"],axis=1)
```

Figure 5 Source Code Data Reduction.

C. Pembagian Data

Tahap pembagian data merupakan proses membagi data menjadi dua jenis data, yaitu data *training* dan data *testing*. Pada penelitian ini, perbandingan pembagian data *training* dan *testing* adalah 90%:10%. Gambar 6 merupakan *source code* pembagian data.

```
X_train,X_test,y_train,y_test = train_test_split(X,y,test_size=0.1,random_state=13)
```

Figure 6 Source Code Pembagian Data.

D. Pemodelan Support Vector Machine


Setelah dilakukan *preprocessing* dan pembagian data, proses selanjutnya yaitu pembuatan model SVM dengan menggunakan *library sklearn* pada *python*. Pada tahap ini juga memanfaatkan fungsi kernel antara lain *linear*, *radial basis function* (RBF), *polynomial* dan *sigmoid*. Gambar 7 merupakan *source code* pemodelan SVM.

```
svm_model = SVC()
svm_model.fit(X_train, y_train) #melatih model menggunakan data latih
preds = svm_model.predict(X_test) #menghasilkan prediksi
```


Figure 7 Source Code Pemodelan SVM.

E. Evaluasi


Tahap evaluasi merupakan proses menganalisis performa yang dicapai dalam proses pengujian. Evaluasi dilakukan dengan memanfaatkan *confusion matrix* dengan menganalisis nilai akurasi, *precision*, *recall* dan *f1-score*. Selain itu, dilakukan evaluasi terhadap nilai *mean square error*. Gambar 8, 9, 10, 11 merupakan hasil *confusion matrix* pada skenario pembagian data latih 10% dan data uji 10% dengan memanfaatkan fungsi *kernel*.




Gambar 8 *Confusion Matrix Kernel Linear*.



Gambar 9 *Confusion Matrix Kernel RBF*.



Gambar 10 *Confusion Matrix Kernel Sigmoid*.



Gambar 11 *Confusion Matrix Kernel Polynomial*.

1. Accuracy

Berikut ini adalah hasil nilai akurasi dengan menggunakan *confusion matrix* berdasarkan pembagian 90% data *training* dan 10% data *testing*. Berdasarkan fungsi *kernel SVM*, didapatkan nilai akurasi seperti yang ditunjukkan pada Tabel 3.

Tabel 3 Hasil Nilai Akurasi Fungsi *Kernel SVM*.

Fungsi <i>Kernel</i>	Accuracy
<i>Linear</i>	99,8%
<i>Radial Basis Function (RBF)</i>	97,4%
<i>Sigmoid</i>	96,7%
<i>Polynomial</i>	97,3%

2. Precision

Berikut ini adalah hasil nilai *precision* dengan menggunakan *confusion matrix* berdasarkan pembagian 90% data *training* dan 10% data *testing*. Berdasarkan fungsi *kernel SVM*, didapatkan nilai *precision* seperti yang ditunjukkan pada Tabel 4.

Tabel 4 Nilai *Precision* Fungsi *Kernel SVM*.

Fungsi <i>Kernel</i>	Precision
<i>Linear</i>	83%
<i>Radial Basis Function (RBF)</i>	33%
<i>Sigmoid</i>	16%
<i>Polynomial</i>	16%

3. Recall

Berikut ini adalah hasil nilai *recall* dengan menggunakan *confusion matrix* berdasarkan pembagian 90% data *training* dan 10% data *testing*. Berdasarkan fungsi *kernel SVM*, didapatkan nilai *recall* seperti yang ditunjukkan pada Tabel 5.

Fungsi Kernel	Recall
Linear	83%
Radial Basis Function (RBF)	19%
Sigmoid	17%
Polynomial	17%

4. F1-Score

Berikut ini adalah hasil nilai *f1-score* dengan menggunakan *confusion matrix* berdasarkan pembagian 90% data *training* dan 10% data *testing*. Berdasarkan fungsi *kernel SVM*, diperoleh nilai *f1-score* seperti yang ditunjukkan pada Tabel 6.

Fungsi Kernel	F1-Score
Linear	83%
Radial Basis Function (RBF)	21%
Sigmoid	16%
Polynomial	16%

5. Mean Squared Error (MSE)

Berikut ini adalah hasil nilai *mean squared error* (MSE) dengan menggunakan *confusion matrix* berdasarkan pembagian 90% data *training* dan 10% data *testing*. Berdasarkan fungsi *kernel SVM*, didapatkan nilai *mean square error* seperti yang ditunjukkan pada Tabel 7.

Fungsi Kernel	MSE
Linear	3,2%
Radial Basis Function (RBF)	23,5%
Sigmoid	41,6%
Polynomial	23,6%

F. Perhitungan Manual Nilai Akurasi

Berikut merupakan perhitungan manual nilai akurasi berdasarkan hasil *confusion matrix* dengan skenario pembagian data latih 90% dan data uji 10% dan fungsi *kernel SVM*. Adapun langkah-langkahnya sebagai berikut.

1. Fungsi Kernel Linear

Adapun perhitungan manual nilai akurasi fungsi *kernel linear* dengan pembagian data latih 90% dan data uji 10% sebagai berikut:

$$\begin{aligned} \text{Accuracy} &= \frac{TP+TN}{TP + TN + FP + FN} \\ \text{Accuracy} &= \frac{967+10+3+10+8}{967+10+3+10+8+2} \\ \text{Accuracy} &= \frac{998}{1000} \\ \text{Accuracy} &= 0,998 \end{aligned}$$

Berdasarkan perhitungan tersebut didapatkan nilai akurasi fungsi *kernel linear* sebesar 0,998 atau 99,8%.

2. Fungsi Kernel Radial Basis Function (RBF)

Adapun perhitungan manual nilai akurasi fungsi *kernel RBF* dengan pembagian data latih 90% dan data uji 10% sebagai berikut:

$$\begin{aligned} \text{Accuracy} &= \frac{TP+TN}{TP + TN + FP + FN} \\ \text{Accuracy} &= \frac{973+1}{973+1} \\ \text{Accuracy} &= \frac{974}{1000} \\ \text{Accuracy} &= 0,974 \end{aligned}$$

Berdasarkan perhitungan tersebut didapatkan nilai akurasi fungsi *kernel radial basis function* (RBF) sebesar 0,974 atau 97,4%.

3. Fungsi *Kernel Sigmoid*

Adapun perhitungan manual nilai akurasi fungsi *kernel sigmoid* dengan pembagian data latih 90% dan data uji 10% sebagai berikut:

$$\begin{aligned} \text{Accuracy} &= \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \\ \text{Accuracy} &= \frac{967}{967 + 6 + 5 + 2 + 9 + 4 + 2 + 5} \\ \text{Accuracy} &= \frac{967}{1000} \\ \text{Accuracy} &= 0,967 \end{aligned}$$

Berdasarkan perhitungan tersebut didapatkan nilai akurasi fungsi *kernel sigmoid* sebesar 0,967 atau 96,7%.

4. Fungsi *Kernel Polynomial*

Adapun perhitungan manual nilai akurasi fungsi *kernel polynomial* dengan pembagian data latih 90% dan data uji 10% sebagai berikut:

$$\begin{aligned} \text{Accuracy} &= \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \\ \text{Accuracy} &= \frac{973}{973 + 7 + 9 + 4 + 2 + 5} \\ \text{Accuracy} &= \frac{973}{1000} \\ \text{Accuracy} &= 0,973 \end{aligned}$$

Berdasarkan perhitungan tersebut didapatkan nilai akurasi fungsi *kernel polynomial* sebesar 0,973 atau 97,3%.

IV. SIMPULAN

Setelah proses pemodelan dan pengujian sistem, disimpulkan bahwa *support vector machine* (SVM) dapat digunakan dalam prediksi pemeliharaan. Langkah pertama dalam menerapkan SVM adalah pengumpulan data. Kemudian data mentah tersebut diolah untuk menghilangkan data yang tidak konsisten atau data kosong sebelum dilakukan pengujian. Langkah selanjutnya membagi data menjadi dua kelas dengan perbandingan 90% data *training* dan 10% data *testing*. Kemudian model SVM dibuat dengan memanfaatkan fungsi *kernel* yaitu *linear*, *radial basis function* (RBF), *sigmoid* dan *polynomial*. Langkah terakhir pemodelan SVM dievaluasi dengan menggunakan *confusion matrix* berupa nilai akurasi, presisi, *recall*, *f1-score* dan *mean squared error* (MSE).

Berdasarkan proses pengujian dan hasil evaluasi pemodelan SVM, didapatkan performa terbaik pada fungsi *kernel linier* dengan nilai akurasi 99,8%, nilai *precision* 83%, nilai *recall* 83%, nilai *f1-score* 83% dan nilai *mean squared error* 3,2%. Penggunaan fungsi kernel SVM *linear* mampu menghasilkan tingkat akurasi yang tinggi dengan nilai *error* yang optimal dibandingkan dengan fungsi kernel lainnya. Sehingga dapat disimpulkan bahwa implementasi metode *support vector machine* (SVM) dapat digunakan dalam prediksi pemeliharaan. Rekomendasi untuk menggunakan SVM fungsi *kernel linear* karena mampu menghasilkan performa dengan nilai akurasi terbaik dan nilai *error* optimal dalam prediksi pemeliharaan sebagai upaya mengurangi tingkat *downtime*.

Saran untuk pengembangan penelitian selanjutnya adalah penambahan jumlah atribut dan jumlah data dengan tujuan untuk meningkatkan tingkat akurasi dan memberikan hasil nilai *error* yang lebih optimal.

UCAPAN TERIMA KASIH

Puji syukur terimakasih Alhamdulillah kepada Allah SWT yang memberikan rahmat dan hidayah sehingga kegiatan penelitian dan penyusunan artikel ilmiah berjalan dengan lancar. Ucapan terimakasih kepada semua pihak yang telah mendukung, membantu serta membimbing jalannya kegiatan penelitian ini.

REFERENSI

- [1] N. Khumaidah, and T. Sukmono, "Forecasting the Number of Offset Printing Machine Breakdowns Using the Support Vector Machine (SVM) Method," *Procedia of Engineering and Life Science*, vol. 1, no. 2, 2021. <https://doi.org/10.21070/pels.v1i2.1027>.
- [2] U. Farooq, M. Ademola, and A. Shaalan, "Comparative Analysis of Machine Learning Models for Predictive Maintenance of Ball Bearing Systems," *Electronics*, vol. 13, no. 2, 2024. <https://doi.org/10.3390/electronics13020438>.
- [3] S. C. R. H. Haliza, and A. Qoiriah, "Predictive Maintenance untuk Kendaraan Bermotor dengan Menggunakan Support Vector Machine (SVM)," *Journal of Informatics and Computer Science*, vol. 2, no. 3, pp. 159-168, 2021. <https://doi.org/10.26740/jinacs.v2n03.p159-168>.

- [4] S. Saha, "An Empirical Comparison of Linear and Non-linear Classification Using Support Vector Machines," *Article in International Journal of Computer Sciences International Journal of Computer Sciences and Engineering*, vol. 11, no. 1, pp. 120–126, 2023.
- [5] H. S. Wafa, A. I. Hadiana, and F. R. Umbara "Prediksi Penyakit Diabetes Menggunakan Algoritma Support Vector Machine (SVM)," *Informatics and Digital Expert.* vol. 4, no. 1, pp. 40-45, 2022. <https://doi.org/10.36423/index.v4i1.895>.
- [6] E. Eka Patriya, "Implementasi Support Vector Machine pada Prediksi Harga Saham Gabungan (IHSG)," *Jurnal Ilmiah Teknologi dan Rekayasa*, vol. 25, no. 1, pp. 24–38, 2020. <http://dx.doi.org/10.35760/tr.2020.v25i1.2571>.
- [7] M. Tarik, A. Mniai, and K. Jebari, "Hybrid Feature Selection and Support Vector Machine Framework for Predicting Maintenance Failures," *Applied Computer Science*, vol. 19, no. 2, pp. 112–124, 2023. <https://doi.org/10.35784/acs-2023-18>.
- [8] I. Assagaf, A. Sukandi, A. A. Abdillah, S. Arifin, and J. L. Ga, "Machine Predictive Maintenance by Using Support Vector Machines," *Recent in Engineering Science and Technology*, vol. 1, no. 1, pp. 31–35, 2023. <https://doi.org/10.59511/riestech.v1i01.6>.
- [9] B. F. Wiguna, H. Herlawati, A. Y. P. Yusuf, "Sentiment Analysis of On-Demand Ride-Hailing Systems using Support Vector Machine and Naïve Bayes," *Penelitian Ilmu Komputer, Sistem Embedded and Logic*, vol. 11, no. 2, pp. 401-414, 2023. <https://doi.org/10.33558/piksel.v11i2.7384>.
- [10] D. Widyawati and A. Faradibah, "Comparison Analysis of Classification Model Performance in Lung Cancer Prediction Using Decision Tree, Naive Bayes, and Support Vector Machine," *Indonesian Journal of Data and Science*, vol. 4, no. 2, pp. 80–89, 2023. <https://doi.org/10.56705/ijodas.v4i2.76>.
- [11] I. T. Julianto, D. Kurniadi, M. R. Nashrulloh, and A. Mulyani, "Comparison of Data Mining Algorithm for Forecasting Bitcoin Crypto Currency Trends," *Jurnal Teknik Informatika (JUTIF)*, vol. 3, no. 2, pp. 245–248, 2022. <https://doi.org/10.20884/1.jutif.2022.3.2.194>.
- [12] N. Srividhya, K. Divya, N. Sanjana, K. Krishna Kumari, and M. Rambhupal, "Diabetes Prediction Using Support Vector Machines," *International Journal of Multidisciplinary Research (IJMR)*, vol. 9, no. 10, pp. 421-426, 2023. <https://doi.org/10.36713/epra14769>.
- [13] A. Desiani, "Penerapan Metode Support Vector Machine dalam Klasifikasi Bungan Iris," *IJAI (Indonesian Journal of Applied Informatics)*, vol. 7, no. 1, pp. 12-18, 2022. <https://doi.org/10.20961/ijai.v7i1.61486>.
- [14] B. Sharma and N. K. Goel, "Streamflow Prediction Using Support Vector Regression Machine Learning Model for Tehri Dam," *Appl Water Sci*, vol. 14, no. 5, p. 99, 2024. <https://doi.org/10.1007/s13201-024-02135-0>.
- [15] U. Amelia, J. Indra, and A. F. N. Masruriyah, "Implementasi Algoritma Support Vector Machine (SVM) untuk Prediksi Penyakit Stroke dengan Atribut Berpengaruh," *Scientific Student Journal for Information, Technology and Science*, vol. 3, no. 2, pp. 254-259, 2022.
- [16] N. Pratiwi and Y. Setyawan, "Analisis Akurasi dari Perbedaan Fungsi Kernel dan Cost pada Support Vector Machine Studi Kasus Klasifikasi Curah Hujan di Jakarta," *Journal of Fundamental Mathematics and Applications (JFMA)*, vol. 4, no. 2, pp. 203–212, 2021. <https://doi.org/10.14710/jfma.v4i2.11691>.
- [17] T. Meisya, P. Aulia, N. Arifin, and R. Mayasari, "Perbandingan Kernel Support Vector Machine (SVM) dalam Penerapan Analisis Sentimen Vaksinisasi Covid-19," *SEINTECH Journal*, vol. 4, no. 2, pp. 139-145, 2021. <https://doi.org/10.31598>.
- [18] B. Duraisamy, R. Sunku, K. Selvaraj, M. Sanikala, and V. V. R. Pilla, "Heart Disease Prediction Using Support Vector Machine," *Multidisciplinary Science Journal*, vol. 6, pp. 1-6, 2023. doi: 10.31893/multiscience.2024ss0104.
- [19] I. Wirasati, Z. Rustam, J. E. Aurelia, S. Hartini, and G. S. Saragih, "Comparison Some of Kernel Functions with Support Vector Machines Classifier for Thalassemia Dataset," *IAES International Journal of Artificial Intelligence (IJ-AI)*, vol. 10, no. 2, pp. 430-437, 2021. <https://doi.org/10.31893/multiscience.2024ss0104>.
- [20] N. E. Febriyanty, M. Amin Hariyadi, C. Crysdian, and M. A. Hariyadi, "Hoax Detection News Using Naïve Bayes and Support Vector Machine Algorithm," *International Journal of Advances in Data and Information Systems*, vol. 4, no. 2, pp. 191–200, 2023. <https://doi.org/10.25008/ijadis.v4i2.1306>.
- [21] M. Awad dan R. Khanna, *Efficient Learning Machines: Theories, concepts, and applications for engineers and system designers*, Springer Nature, 2015.
- [22] W. Dirgantara, F. Iqbal Maulana, S. Subairi, and R. Arifuddin, "The Performance of Machine Learning Model Bernoulli Naïve Bayes, Support Vector Machine, and Logistic Regression on COVID-19 in Indonesia using Sentiment Analysis," *Jurnal Ilmiah Elektronika*, vol. 23, no. 1, pp. 153-162. <https://doi.org/10.31358/techne.v23i1.446>.
- [23] A. Andryani, A. N. Salim, and T. Sutabri, "Deteksi Email Spam dan Non-Spam Berdasarkan isi Konten Menggunakan Metode K-Nearest Neighbor dan Support Vector Machine," *Journal Syntax Idea*, vol. 6, no. 3, pp. 1-14, 2024. <https://doi.org/10.46799/syntax-idea.v6i2.3052>.

- [24] D. Rizaldi, I. Ratna, I. Astutik, and M. A. Rosid, "Classification of Sentiment Analysis of Memes on Kaggle.com Using Support Vector Machine Algorithm," *Procedia of Engineering and Life Science*, vol. 7, pp. 184-190, 2024. <https://doi.org/10.21070/pels.v7i0.1194>.
- [25] N. A'yunnisa, Y. Salim, and H. Azis, "Analisis Performa Metode Gaussian Naïve Bayes untuk Klasifikasi Citra Tulisan Tangan Karakter Arab," *Indonesian Journal of Data and Science (IJODAS)*, vol. 3, no. 3, pp. 115-121, 2022. <https://doi.org/10.31598>.
- [26] D. Leni, M. Chamim, R. Sumiati, and Y. Rosa, "Modeling Mechanical Component Classification Using Support Vector Machine with A Radial Basis Function Kernel," *JURNAL Teknik Mesin*, vol. 16, no. 2, pp. 165-174, 2023. <https://doi.org/10.30630/jtm.16.2.1250>.
- [27] Y. Liang, J. Wu, Q. Zeng, Y. Zhao, K. Ma, X. Zhang, Q. Yang, J. Zhang, and Y. Qi, "Rapid Identification of the Species of Bloodstain Based on Near Infrared Spectroscopy and Convolutional Neural Network-Support Vector Machine Algorithm," *J Braz Chem Soc*, vol. 35, no. 8, pp. 1-6, 2024. <https://dx.doi.org/10.21577/0103-5053.20240023>.
- [28] Y. Feng, "Support Vector Machine for Stroke Risk Prediction," *Highlights in Science, Engineering and Technology*, vol. 38, pp. 917-923, 2023. <https://doi.org/10.54097/hset.v38i.5977>.
- [29] M. Daffa, A. Fahreza, A. Luthfiarta, M. Rafid, M. Indrawan, and A. Nugraha, "Analisis Sentimen: Pengaruh Jam Kerja Terhadap Kesehatan Mental Generasi Z," *Journal of Applied Computer Science and Technology (JACOST)*, vol. 5, no. 1, pp. 2723-1453, 2024. <https://doi.org/10.52158/jacost.v5i1.715>.
- [30] B. Raharjo, *Pembelajaran Mesin (Machine Learning)*, Semarang: Yayasan Prima Agus Teknik, 2021.

Conflict of Interest Statement:

The author declares that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.