



## Model Machine Learning SVM (*Support Vector Machine*) untuk Deteksi Anomali pada Sistem Kelistrikan Perusahaan Kerajinan Kayu GS4

Bambang Minto Basuki<sup>1\*</sup>, Dimas Cahyono<sup>2</sup>

<sup>1,2</sup>Program Studi Teknik Elektro, Fakultas Tenik, Universitas Islam Malang, Indonesia

E-mail: [bambang.minto@unisma.ac.id](mailto:bambang.minto@unisma.ac.id), [22001053012@unisma.ac.id](mailto:22001053012@unisma.ac.id)

\*Korespondensi penulis: [bambang.minto@unisma.ac.id](mailto:bambang.minto@unisma.ac.id)

**Abstract.** *Anomaly detection in electrical systems is crucial to prevent operational disruptions and equipment damage, especially in small industries such as handicraft companies. This study aims to develop an electrical anomaly detection model using Support Vector Machine (SVM) based on current, voltage, and temperature parameters. Data were collected in real-time using sensors installed at strategic points in the company's electrical network. Anomaly criteria were determined based on normal operating limits: current (8.2–10 A), voltage (198–242 V), and temperature (30–70°C). The SVM model was trained using a dataset classified into normal and anomalous conditions. Model evaluation was conducted using accuracy, precision, recall, and F1-score metrics to assess the anomaly detection performance. Model evaluation was performed using accuracy, precision, recall, and F1-score metrics to assess the accuracy of anomaly detection. The results showed that the SVM model was able to identify anomalies with high accuracy, namely with an Accuracy value of 96.5%. Precision of 94.8% and Recall of 92.3%.*

**Keywords:** *Anomaly Detection, Electrical Anomaly, Electrical System, Support Vector Machine.*

**Abstrak.** Deteksi anomali pada sistem kelistrikan sangat penting untuk mencegah gangguan operasional dan kerusakan peralatan, terutama pada industri kecil seperti perusahaan kerajinan tangan. Penelitian ini bertujuan untuk mengembangkan model deteksi anomali sistem kelistrikan menggunakan *Support Vector Machine* (SVM) berdasarkan parameter arus, tegangan, dan suhu. Data dikumpulkan secara real-time menggunakan sensor yang dipasang pada titik strategis dalam jaringan listrik perusahaan. Kriteria anomali ditentukan berdasarkan batas normal operasi, yaitu arus (8.2–10 A), tegangan (198–242 V), dan suhu (30–70°C). Model SVM dilatih menggunakan dataset yang telah diklasifikasikan berdasarkan kondisi normal dan anomali. Evaluasi model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk menilai keakuratan deteksi anomali. Hasil penelitian menunjukkan bahwa model SVM mampu mengidentifikasi anomali dengan akurasi tinggi dengan nilai Akurasi sebesar 96,5 %. Presisi sebesar 94,8% dan Recall sebesar 92,3%.

**Kata Kunci:** *Anomali Kelistrikan, Deteksi Anomali, Sistem Kelistrikan, Support Vector Machine.*

### 1. PENDAHULUAN

Perkembangan teknologi di bidang kecerdasan buatan (AI) dan sensor elektronik telah membuka banyak peluang untuk meningkatkan efisiensi dan keselamatan dalam berbagai sektor, termasuk sektor kelistrikan. Sistem kelistrikan yang kompleks dan vital, seperti yang terdapat pada industri kerajinan kayu, seringkali menghadapi masalah dalam mendeteksi dan mengatasi masalah secara dini. Salah satu masalah yang paling umum adalah terjadinya anomali pada sistem kelistrikan, seperti lonjakan tegangan, arus lebih, atau kegagalan komponen, yang dapat menyebabkan kerusakan serius atau bahkan kebakaran (S. Raja & E. Fokoué, 2019).

Deteksi dini terhadap anomali ini sangat penting untuk mencegah kerugian material dan korban jiwa. Oleh karena itu, dibutuhkan teknologi yang dapat memantau kondisi sistem kelistrikan secara real-time dan mendeteksi tanda-tanda abnormal dengan akurat. Di sinilah peran teknologi sensor elektronik dan kecerdasan buatan menjadi sangat relevan (B. AL-Madani dkk., 2019).

Deteksi anomali listrik secara manual memiliki kelemahan jika dibandingkan dengan metode berbasis machine learning yaitu ; Rentan terhadap Human Error dan Bias, kesulitan dalam mengolah data yang sangat besar serta waktu dan efisiensi (B. AL-Madani dkk., 2019).

Penggunaan Machine Learning SVM yang dilatih untuk mengenali pola-pola anomali pada data sensor kelistrikan, sistem dapat memprediksi dan mengidentifikasi potensi masalah sebelum berkembang menjadi kerusakan yang lebih besar. Sensor elektronik, seperti sensor arus, tegangan, atau suhu, dapat menyediakan data real-time yang diperlukan untuk menganalisis kondisi sistem kelistrikan (Z. Umari & J. Supardi, 2024).

Integrasi Machine Learning SVM dengan sensor elektronik guna mendeteksi anomali pada sistem kelistrikan diharapkan dapat memberikan solusi yang lebih efektif dan efisien dalam pemantauan sistem kelistrikan dengan kemampuan deteksi yang lebih cepat dan presisi sehingga dapat mengurangi biaya jika dibandingkan dengan sistem deteksi tradisional (A. Febrianti, 2018).

Dengan menggabungkan AI dan sensor elektronik, penelitian ini bertujuan untuk mengembangkan sistem deteksi anomali yang dapat meningkatkan keandalan dan keselamatan sistem kelistrikan, pada perusahaan kerajinan kayu GS4.

## 2. METODE

Penelitian ini menggunakan metode kuantitatif dengan pendekatan eksperimen untuk mendeteksi anomali sistem kelistrikan pada perusahaan kerajinan tangan GS4. Model *Support Vector Machine* (SVM) digunakan untuk mengklasifikasikan data kelistrikan normal dan anomali berdasarkan pola arus, tegangan dan suhu. Data diperoleh secara pengukuran langsung di tempat usaha GS4. Perusahaan ini memiliki daya 3500 VA, 220 V.

Instrumen yang digunakan dalam penelitian ini meliputi:

- a. Alat ukur listrik, tegangan, arus, serta suhu.
- b. Perangkat lunak pemrosesan data, Python dengan untuk implementasi SVM.
- c. Sistem penyimpanan dan pengolahan data, berupa database untuk merekam dan menyimpan hasil pengukuran.

Data dikumpulkan melalui tahapan berikut:

- 1) Pengukuran arus, tegangan dan suhu sistem kelistrikan melalui sensor.
- 2) Perekaman data selama periode 30 hari untuk mendapatkan pola normal dan anomali.
- 3) Pembersihan dan normalisasi data untuk memastikan kualitas data sebelum analisis.
- 4) Pelabelan data berdasarkan kondisi operasional (normal/anomali).

Teknik analisis data dilakukan dengan tahapan berikut:

- 1) Preprocessing data berupa penghapusan *outlier* dan normalisasi data.
- 2) Pelatihan dan pengujian model SVM, dengan membagi data menjadi *training set* dan *testing set*.
- 3) Evaluasi model, menggunakan metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score* untuk menilai performa deteksi anomali.
- 4) Interpretasi hasil, dengan membandingkan pola anomali yang terdeteksi oleh SVM dengan kejadian sebenarnya di perusahaan.

### **3. HASIL DAN PEMBAHASAN**

#### **Peralatan yang digunakan**

- a) Sensor Arus (Current Sensor)

Spesifikasi:

Model: ACS712

Tipe: Hall effect-based current sensor

Range:  $\pm 5A$ ,  $\pm 20A$

Akurasi:  $\pm 1.5\%$

Output: Analog, 185 mV per Ampere

Tegangan Operasi: 5V DC

Sensor arus ini dipilih karena kemampuannya untuk mengukur arus secara akurat dalam kisaran yang dibutuhkan pada sistem kelistrikan rumah tangga atau industri kecil. Penggunaan sensor berbasis efek Hall memberikan pengukuran arus yang aman tanpa perlu menghubungkan sensor secara langsung ke sirkuit arus tinggi,

- b) Sensor Tegangan

Spesifikasi:

Model: ZMPT101B

Tipe: Sensor tegangan berbasis pembagi tegangan

Range: 0-250V AC

Akurasi:  $\pm 1\%$

Output: Analog, 1V untuk 100V AC

Tegangan Operasi: 5V DC

Sensor tegangan ini digunakan untuk mengukur tegangan AC pada sistem kelistrikan. Dengan kemampuan mengukur hingga 250V AC, sensor ini cocok untuk aplikasi dalam pengawasan sistem kelistrikan rumah tangga maupun industri ringan

- c) Sensor Suhu (Temperature Sensor)

Spesifikasi:

Model: DHT22 (AM2302)

Tipe: Digital temperature and humidity sensor

Range: -40°C hingga 80°C

Akurasi:  $\pm 0.5^\circ\text{C}$  (rentang 0°C hingga 50°C)

Output: Digital, sinyal 16-bit untuk suhu dan kelembaban

Tegangan Operasi: 3.3V hingga 6V DC

Sensor suhu DHT22 digunakan untuk mendeteksi suhu pada perangkat kelistrikan atau area sekitar sirkuit. Sensor ini dipilih karena kemampuannya untuk memberikan pembacaan suhu yang tepat dan stabil di lingkungan operasional.

- d) Mikrokontroler (Arduino Uno R3): Berperan sebagai penghubung antara sensor dan komputer.

Spesifikasi:

Model: Arduino Uno R3

Tipe: Mikrokontroler berbasis ATmega328P

Prosesor: 16 MHz

Pin Input/Output: 14 digital, 6 analog

Tegangan Operasi: 5V DC

- e) Komputer / Laptop i5: Digunakan untuk menjalankan program pemrosesan data dan pelatihan model SVM.
- f) Software Python : Untuk melakukan analisis data dan membangun model SVM.

SVM bekerja dengan mencari hyperplane dalam ruang berdimensi tinggi yang memisahkan kelas-kelas dengan margin maksimum. Hyperplane adalah sebuah bidang atau garis (tergantung dimensi data) yang memisahkan dua kelas berbeda yaitu dengan merumuskan

$D=\{(x_1,y_1),(x_2,y_2),\dots,(x_n,y_n)\}$

dengan:

- $x_i$  adalah vektor fitur berdimensi d

- $y_i$  adalah label kelas (untuk SVM biner)

Maka, SVM mencari hyperplane berbentuk:


$$w^T x + b = 0$$

dengan

- $w$  adalah vektor bobot,
- $b$  adalah bias (intersep),
- $x$  adalah vektor fitur.

Hyperplane optimal adalah yang memaksimalkan margin, yaitu jarak antara dua kelas yang paling dekat ke hyperplane.

## Rangkaian alat



**Gambar 1. Rangkaian Alat**

## Pengumpulan dan Preprocessing Data

Data kelistrikan dikumpulkan menggunakan sensor arus, tegangan, dan suhu yang dipasang pada beberapa titik kritis dalam sistem kelistrikan perusahaan kerajinan tangan. Data yang diperoleh terdiri dari rekaman arus (A), tegangan (V), dan suhu ( $^{\circ}\text{C}$ ) yang diperoleh dalam periode tertentu. Tahapan preprocessing yang dilakukan meliputi:

- Pembersihan Data: Menghilangkan data yang tidak valid atau mengandung noise yang terlalu tinggi.
- Normalisasi Data: Menggunakan metode *Min-Max Scaling* untuk menyetarakan skala fitur.
- Pelabelan Data: Data diberi label "Normal" atau "Anomali" berdasarkan rentang operasi normal yang telah ditetapkan sebelumnya.

Setelah preprocessing, data dibagi menjadi training set (80%) dan testing set (20%) untuk keperluan pelatihan dan pengujian model SVM:

Kriteria Deteksi Anomali:

Berdasarkan ketiga parameter di atas, kondisi sistem kelistrikan akan disebut normal jika:

- Arus berada dalam kisaran yang diizinkan.
- Tegangan berada dalam batas toleransi yang ditentukan.
- Suhu berada dalam rentang yang aman dan tidak menunjukkan tanda-tanda overheating.

Kondisi akan dianggap anomali jika salah satu atau lebih dari parameter berikut berada di luar batas toleransi yang ditentukan:

- Arus melebihi nilai ambang batas atas atau terlalu rendah.
- Tegangan terlalu tinggi atau terlalu rendah.
- Suhu melebihi ambang batas suhu yang aman (terlalu panas) atau terlalu rendah.

Dengan daya listrik sebesar 2000 VA, 220 V, maka kondisi anomali dapat dinyatakan sebagaimana dalam tabel 1 berikut

**Tabel 1. Kondisi Anomali pada Perusahaan Kerajinan Tangan GS4**


Parameter	Normal	Anomali Rendah	Anomali Tinggi
Arus (A)	8.2 – 10 A	$I < 8.2A$	$I > 10A$
Tegangan (V)	198 – 242 V	$V < 198V$	$V > 242V$
Suhu (°C)	30 – 70°C	$T < 30°C$	$T > 70°C$

Berikut adalah sebagian data hasil pengukuran sensor yang digunakan dalam penelitian ini:

Waktu Arus (A) Tegangan (V) Suhu (°C)				Label
08:00	8.5	220	35	Normal
08:30	9.2	218	36	Normal
09:00	15.3	200	50	Anomali
09:30	10.1	221	37	Normal
10:00	18.4	190	55	Anomali
10:30	7.8	222	34	Normal

### Pembentukan Model SVM [10]

Model SVM diterapkan untuk mendeteksi anomali dengan menggunakan fungsi kernel *Radial Basis Function (RBF)* karena kemampuannya dalam menangani data non-linear. Berikut bentuk diagramnya:



**Gambar 2. Diagram alir kerja algoritma SVM**

Parameter utama yang digunakan dalam model ini meliputi:

- C (Regularization Parameter): Menentukan tingkat penalti terhadap kesalahan klasifikasi.
- Gamma ( $\gamma$ ) dalam Kernel RBF: Menentukan seberapa jauh pengaruh satu sampel pelatihan terhadap lainnya.
- Kernel Trick: Digunakan untuk memetakan data ke dalam ruang berdimensi lebih tinggi agar dapat dipisahkan dengan lebih baik.

Model SVM dilatih menggunakan data *training set*, kemudian diuji pada *testing set* untuk menilai performanya.

### Implementasi Koding SVM

Berikut adalah implementasi model SVM menggunakan Python dengan pustaka scikit-learn:

rangkuman code python untuk penyelesaian algoritma SVM

Import Library

```

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.svm import OneClassSVM
from sklearn.preprocessing import StandardScaler

```

penjelasan:

- numpy digunakan untuk manipulasi array numerik.
- pandas digunakan untuk mengorganisasi data dalam bentuk tabel.
- matplotlib.pyplot digunakan untuk visualisasi data.
- OneClassSVM dari sklearn.svm digunakan untuk membangun model Support Vector Machine (SVM) untuk deteksi anomali.
- StandardScaler dari sklearn.preprocessing digunakan untuk menormalisasi data agar memiliki skala yang sama.

Baca data input

```
# data (tegangan, arus, suhu) dari sensor disimpan dalam file csv
file_path = r"D:\data\sensor_data.csv"
#baca data dari file csv
data = pd.read_csv(file_path)
```

Penjelasan:

- baca dari file csv di drive D:\ berisa data tegangan, arus, suhu

Normalisasi data

```
scaler = StandardScaler()
data_scaled = scaler.fit_transform(data)
```

Penjelasan:

- StandardScaler() digunakan untuk **menstandarkan** data dengan mengubahnya ke dalam distribusi dengan **mean = 0** dan **standar deviasi = 1**.
- fit\_transform(data) melakukan **normalisasi** agar model SVM lebih akurat.

Training SVM

```
svm_model=OneClassSVM(kernel='rbf', nu=0.05)
# nu menentukan sensitivitas anomali
svm_model.fit(data_scaled)
```

penjelasan:

- OneClassSVM digunakan untuk **deteksi anomali** karena model ini hanya mempelajari data normal.
- **kernel='rbf'** (Radial Basis Function) digunakan karena mampu menangani data **non-linear**.
- **nu=0.05** menentukan sensitivitas deteksi anomali (semakin kecil, semakin ketat deteksinya).
- fit(data\_scaled) melatih model dengan data yang telah dinormalisasi.

Prediksi anomali

```
predictions = svm_model.predict(data_scaled)
```

penjelasan:

- Model SVM digunakan untuk memprediksi apakah suatu data normal atau anomali.
- Hasil prediksi berupa 1 (Normal) atau -1 (Anomali).

Menampilkan hasil prediksi

```
results = pd.DataFrame(data, columns=['Voltage', 'Current', 'Temperature'])
results['Anomaly'] = predictions
results['Anomaly'] = results['Anomaly'].apply(lambda x: 'Normal' if x == 1 else 'Anomaly')
print(results)
```

penjelasan:

- pd.DataFrame(data, columns=['Voltage', 'Current', 'Temperature']) membuat tabel data.
- results['Anomaly'] = predictions menambahkan hasil prediksi sebagai kolom baru.
- apply(lambda x: 'Normal' if x == 1 else 'Anomaly') mengubah angka menjadi label "Normal" atau "Anomaly".
- print(results) menampilkan hasil deteksi anomali

Visualisasi data

```
plt.figure(figsize=(8, 6))
plt.scatter(data[:, 0], data[:, 1], c=predictions, cmap='coolwarm', edgecolors='k')
plt.xlabel('Voltage (V)')
plt.ylabel('Current (A)')
plt.title('Deteksi Anomali SVM pada Sistem Kelistrikan')
```

plt.show()

penjelasan:

```
plt.scatter(data[:, 0], data[:, 1], c=predictions, cmap='coolwarm', edgecolors='k')
```

Membuat scatter plot dengan sumbu X = Tegangan dan Y = Arus.

Warna titik ditentukan oleh hasil prediksi (c=predictions).

cmap='coolwarm' memberikan warna berbeda untuk normal dan anomali.

plt.xlabel('Voltage (V)') dan plt.ylabel('Current (A)') memberikan label sumbu.

plt.title('Deteksi Anomali SVM pada Sistem Kelistrikan') memberikan judul grafik.

plt.show() menampilkan grafik.

## Evaluasi Model

Setelah model SVM dilatih dan diuji, evaluasi dilakukan agar diperoleh performa alat yang lebih baik. Hasil akhir yang diperoleh dari SVM adalah

Hasil output luaran SVN

Akurasi	96.5%
Presisi	94.8%
Recall	92.3%
F1-Score	93.5%

Dari data di atas, terlihat bahwa model SVM memiliki kinerja yang sangat baik dalam mendeteksi anomali sistem kelistrikan.

## 4. KESIMPULAN

Berdasarkan hasil penelitian, SVM terbukti efektif dalam mendeteksi anomali sistem kelistrikan dengan akurasi tinggi. Hasil penelitian menunjukkan Akurasi (seberapa sering model membuat prediksi yang benar terhadap semua data yang diuji) sebesar 96,5 %. Presisi 94.8% (dari semua data yang diklasifikasikan sebagai anomali oleh model, sebanyak 94.8% benar-benar anomali). Recall 92.3% (dari semua kasus anomali yang ada, model berhasil mendeteksi 92.3%).

## REFERENSI

- Ahmed, Q. I. (2023). Development of a hybrid support vector machine with grey wolf optimization algorithm for detection of the solar power plants anomalies. *MDPI Journal*, 11(5), 237. <https://doi.org/10.3390/systems11050237>
- AL-Madani, B., Shawahna, A., & Qureshi, M. (2019). Anomaly detection for industrial control networks using machine learning with the help from the inter-arrival curves. *arXiv preprint arXiv:1911.05692*. Retrieved from <https://arxiv.org/abs/1911.05692>
- Ananta, F., Syauqy, D., & Prasetio, B. H. (2023). Perancangan sistem deteksi anomali pada panel surya menggunakan mikrokontroler dengan algoritma K-nearest neighbors. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 7(5), 2305-2312.
- Febrianti, A. (2018). *Penerapan metode K-means clustering dan support vector machine untuk klasifikasi citra* (Undergraduate thesis). UIN Jakarta. Retrieved from <https://repository.uinjkt.ac.id/dspace/bitstream/123456789/55624/1/AMANDA%20FEBRIANTI-FST.pdf>
- Lazarević, D., Živković, M., Kocić, D., & Ćirić, J. (2022). The utilizing Hall effect-based current sensor ACS712 for true RMS current measurement in power electronic systems. *Scientific Technical Review*, 72(1), 27-32.
- Noor, A. S. M., Ali, M. S. A. M., & Ali, M. A. M. (2023). Experimental analysis and monitoring of photovoltaic panel parameters using ACS712 current sensor. *International Journal of Advanced Computer Science and Applications*, 14(2), 150-156.
- Prabuningrat, G. S. W., Hostiadi, D. P., & Srinadi, N. L. P. (2024). Klasifikasi deteksi anomali menggunakan metode machine learning. *Seminar Nasional Sains dan Teknologi Komputer (SPINTER)*. Retrieved from <https://spinter.stikom-bali.ac.id/index.php/spinter/article/download/245/210/322>
- Raja, S., & Fokoué, E. (2019). Multi-stage fault warning for large electric grids using anomaly detection and machine learning. *arXiv preprint arXiv:1903.06700*. Retrieved from <https://arxiv.org/abs/1903.06700>
- Umari, Z., & Supardi, J. (2024). Deteksi anomali sinyal vibrasi pada mesin industri menggunakan autoencoder di PT. Pusri Palembang. *Jurnal Penelitian Teknologi Informasi (JPTI)*, 7(1), 45-52. Retrieved from <https://jpti.journals.id/index.php/jpti/article/download/553/300>
- Wainer, J., & Fonseca, P. (2020). How to tune the RBF SVM hyperparameters?: An empirical evaluation of 18 search algorithms. *arXiv preprint arXiv:2008.11655*.