

DETEKSI SERANGAN MALWARE MENGGUNAKAN METODE SUPPORT VECTOR MACHINE

Hery Sanjaya Simbolon¹, Andi Maslan²

¹Program Studi Teknik Informatika, Universitas Putera Batam

²Program Studi Teknik Informatika, Universitas Putera Batam

email: pb210210069@upbatam.ac.id

ABSTRACT

The rapid development of information technology has increased the potential for system security threats, including malware attacks. Malware is malicious software that can damage, disrupt, or steal data without the user's knowledge. This study aims to build a classification model to detect malware attacks based on the behavior of operating system processes using the Support Vector Machine (SVM) method. The dataset consists of 100,000 entries with 33 attributes related to process activities, such as CPU usage, memory, and context switches. The data is split into training and testing sets, followed by exploratory data analysis (EDA), data cleaning, feature selection based on correlation, and training of the model using a linear kernel SVM. Evaluation is carried out using a confusion matrix and metrics such as accuracy, precision, recall, and F1-score. The results show that the SVM model performed very well, achieving 99.57% accuracy, 99.76% precision, 99.38% recall, and a 99.57% F1-score. The model successfully distinguished between malware and normal processes with minimal misclassification. These findings demonstrate that SVM is effective in detecting malware based on system process behavior and has the potential to support the development of automated security systems capable of real-time threat detection.

Keywords: *classification, cyber, malware, SVM, Security*

PENDAHULUAN

Di era Industri 4.0, teknologi berkembang pesat, khususnya di bidang Network Security atau keamanan jaringan. Teknologi ini digunakan untuk mengamankan suatu jaringan di perusahaan atau organisasi. Salah satu teknologi Menurut informasi Dari TechCrunch laporan Gertner. yang sering digunakan masyarakat adalah android. Pada Tahun 2017, Gertner melaporkan bahwa penjualan ponsel pintar global meningkat sebesar 9 persen pada kuartal

pertama, dengan 380 juta perangkat seluler terjual, dengan Android memimpin pasar dengan 84,1 persen. Menurut laporan Kementerian Komunikasi dan Informatika, jumlah pengguna aktif smartphone di Indonesia melebihi 200 juta orang pada tahun 2024 dan StatCounter melaporkan bahwa jumlah pengguna Android di Indonesia sebesar 91% pada tahun 2018 , sehingga dapat diasumsikan jumlah pengguna Android di Indonesia sekitar 91 juta orang(laporan serangan malware kaspersky). Jumlah

pengguna Android meningkat pesat sehingga sistem operasi Android menjadi sasaran serangan malware, sistem operasi yang diserang malware rusak, dan bahkan dengan niat yang lebih jahat, informasi penting dapat dicuri dari sistem dengan bantuan malware. . Malware atau malware seperti yang biasa dikenal adalah perangkat lunak yang diprogram untuk menyusup ke sistem operasi dan dapat merusak sistem bahkan mencuri data penting dari perangkat korban. Menurut Lembaga Standar Keamanan Menurut konsep Privilege Escalation dalam keamanan siber Ada banyak jenis malware dan mereka memiliki cara kerja yang berbeda, misalnya serangan malware melalui aplikasi jahat yang menggunakan hak istimewa secara ilegal tanpa izin pengguna dan sistem operasi. Karena kerentanan terhadap serangan malware dan kerentanan yang memengaruhi pengguna Android, diperlukan analisis malware lebih lanjut. Pada Tahun 2019, perusahaan keamanan siber Kaspersky melaporkan 556.486 deteksi malware, dan pada Tahun 2020, Kaspersky juga melaporkan penurunan serangan malware di Indonesia sebesar 31,89% menjadi 378.973. Hal ini menjadikan Indonesia sebagai negara dengan jumlah ancaman malware yang terdeteksi terbanyak di Asia Tenggara dan tertinggi keempat di dunia Analisis statis dilakukan dengan mengekstraksi kode sumber malware dan kemudian memeriksa dan memahami perilaku berbahaya melalui kode sumber, data, dan binari, sehingga proses analisis statis tidak memerlukan malware untuk dijalankan. Analisis statis digunakan untuk mengekstrak fitur dan mengidentifikasi setiap aplikasi menggunakan ApkTool 2.0.3 . Berdasarkan data serangan malware dan

jumlah pengguna Android yang besar, hal ini menjadi masalah, sehingga penelitian ini menerapkan sistem machine learning untuk menentukan metode klasifikasi yang menjamin akurasi tinggi dalam deteksi dini serangan malware. Beberapa penelitian sebelumnya menggunakan beberapa metode machine learning seperti Naive Bayes, Decision Tree, KNN dan metode lainnya seperti Lopez et al yang melakukan penelitian menggunakan beberapa metode machine learning dengan akurasi hingga 95%. Menurut (Wanli Sitorus et al., 2021) Melaporkan bahwa tahun 2018 pengguna aktif smartphone di Indonesia lebih dari 100 juta orang serta pada tahun yang sama data dari statcounter pengguna android di Indonesia sebanyak 90,85%. Dengan berkembangnya metode pembelajaran mesin untuk klasifikasi, penelitian ini mengadopsi sistem pembelajaran mesin untuk menentukan metode pembelajaran mesin yang memberikan kinerja matriks dalam deteksi dini serangan malware yang lebih baik dari penelitian . Penelitian ini menggunakan metode klasifikasi Support Vector Machine (SVM). Hasil penelitian ini diharapkan dapat membantu pengembang dan pengguna untuk mengunduh aplikasi. Aplikasi yang ingin dipublikasikan oleh individu dan perusahaan dapat menentukan apakah suatu aplikasi tidak aman atau tidak. Sehingga aplikasi lebih terlindungi dari serangan malware dan pengguna memiliki unduhan yang aman.

Tujuan dari penelitian ini adalah untuk membuat model klasifikasi yang dapat mengidentifikasi serangan malware berdasarkan perilaku proses sistem operasi saat menggunakan metode Support Vector Machine (SVM). Dataset yang digunakan memiliki 100.000 entri data yang memiliki 33 atribut yang

menunjukkan aktivitas proses seperti penggunaan CPU, memori, dan konteks pergeseran. Pembagian data menjadi data latih dan data uji, analisis data exploratory (EDA) untuk memahami karakteristik data, preprocessing data untuk membersihkan dan menstandarisasi atribut, seleksi fitur berdasarkan korelasi untuk mengurangi kompleksitas model, dan pengembangan dan pelatihan model klasifikasi menggunakan SVM dengan kernel linear. Menggunakan confusion matrix dan metrik evaluasi seperti akurasi, precision, recall, dan skor F1, model dievaluasi. Hasil pengujian menunjukkan bahwa model SVM yang dibangun memiliki performa yang sangat baik dengan akurasi sebesar 99,57%, ketepatan sebesar 99,76%, recall sebesar 99,38%, dan skor F1 sebesar 99,57%. Model ini juga memiliki kemampuan untuk membedakan proses yang merupakan malware dari proses normal dengan jumlah kesalahan klasifikasi yang sangat kecil. Hasilnya menunjukkan bahwa SVM dapat melakukan deteksi malware berbasis perilaku proses sistem dengan cukup baik. Penelitian ini dapat berkontribusi pada pengembangan sistem keamanan otomatis yang dapat mendeteksi ancaman secara real-time dan membantu memperkuat pertahanan sistem terhadap serangan siber

Kajian Teori

2.1 Keamanan Jaringan

Menurut (Sinaga, Irmayani, and Hasibuan 2024) Dengan globalisasi dan perkembangan teknologi informasi yang cepat saat ini, keamanan jaringan menjadi masalah yang semakin penting. Semakin banyak organisasi dan individu yang bergantung pada infrastruktur

jaringan untuk kegiatan sehari-hari dan operasional bisnis, membuat keamanan informasi menjadi sangat penting. Dengan berbagai jenis serangan yang terus berkembang, seperti malware, ransomware, dan serangan phishing, ancaman keamanan jaringan semakin sering dan semakin kompleks. Akibatnya, untuk mengatasi masalah keamanan ini, diperlukan pendekatan yang lebih canggih dan responsif.

2.2 Malware

Menurut (Wanli Sitorus, Sukarno, and Mandala 2021) *Malicious Software* atau sering dikenal sebagai malware merupakan sebuah software yang diprogram agar dapat menyusup ke sebuah sistem operasi yang dapat merusak cara kerja sistem dan bahkan digunakan untuk mencuri data-data penting pada perangkat korban Selain itu Menurut (Putra and Komputer 2024) Malware adalah perangkat lunak berbahaya yang dirancang untuk merusak, mengganggu, atau mendapatkan akses tidak sah ke sistem komputer. Untuk itu maka diperlukan analisis untuk mendeteksi malware karena tujuan akhir dari analisis malware adalah menggambarkan secara tepat cara kerja sebuah malware. Deteksi SVM (*Support Vector Machine*) terhadap serangann malware menggunakan algoritma pembelajaran mesin yang membedakan perangkat lunak berbahaya (malware) dan perilaku perangkat lunak yang sah. Malware ada dalam berbagai bentuk *script*, *code*, *activecontent*, dan perangkat lunak.

2.3 Algoritma Machine Learning

Menurut (Mahesh 2020) (Mahesh 2020) Pembelajaran mesin adalah bidang yang menyelidiki bagaimana

komputer dapat belajar tanpa diprogram secara eksplisit. Program catur Arthur Samuel terkenal. Pembelajaran mesin (ML) membantu mesin belajar menangani data dengan lebih baik. Kadang-kadang kita tidak dapat menafsirkan informasi ekstrak dari data setelah melihatnya.

2.3.1 Support Vector Machine

Menurut (Tjahjadi and Santoso 2023) *Support Vector Machine* (SVM) adalah algoritma pembelajaran mesin klasifikasi yang berbasis pengawasan (*Supervised Learning*). Algoritma ini menggunakan dua garis vector (*Hyperplane*) dengan margin yang terbesar. Hyperplane adalah garis yang digunakan untuk memisahkan data dari berbagai kelompok. Margin adalah jarak antara hyperplane dengan titik data terdekat dari masing-masing kelompok. SVM mampu menyelesaikan masalah klasifikasi baik yang bersifat linear maupun non-linear. *Support Vector Machine* (SVM) dikembangkan oleh Boser, Guyon, Vapnik. Pertama kali dipresentasikan pada lokakarya tahunan pada tahun 1992.

2.3.2 Metode K-Nearest Neighbors

Algoritma *K-Nearest Neighbor* (K- NN) adalah algoritma klasifikasi yang bergantung pada kedekatan suatu data dengan data lain. Dengan data berdimensi q , jarak antara dua data dapat dihitung. Nilai jarak ini digunakan untuk menentukan seberapa dekat atau mirip data uji dengan data latih. Nilai K pada K-NN menunjukkan K -data uji terdekat. Algoritma klasifikasi K-Nearest Neighbor

digunakan untuk membuat sistem deteksi malware yang efektif dan akurat. (Halim and Anraeni 2021)

2.3.3 Metode Random Forest

Random Forest adalah pengembangan dari metode *Decision Tree* yang menggunakan beberapa *Decision Tree*. Setiap *Decision Tree* telah dilatih dengan sampel dan setiap atribut didistribusikan ke pohon yang dipilih dari subset atribut yang acak. memiliki beberapa kelebihan, termasuk kemampuan untuk meningkatkan akurasi dalam kasus data yang hilang dan untuk menahan keluaran, serta kemampuan untuk menyimpan data dengan efisien. mempunyai proses seleksi fitur yang dapat mengambil fitur terbaik untuk meningkatkan kinerja model klasifikasi. (Rayuwati, Husna Gemasih, and Irma Nizar 2022)

2.3.4 Metode Naive Bayes

memberikan penjelasan *Naive Bayes* untuk setiap kelas keputusan, yang menghitung probabilitas dengan asumsi bahwa kelas keputusan adalah benar, mengingat vektor informasi obyek. Algoritma ini menganggap bahwa atribut obyek adalah independen. Jumlah frekuensi dari "master" tabel keputusan adalah jumlah kemungkinan yang terlibat dalam pembuatan perkiraan akhir. Jika dibandingkan dengan model klasifikasi lainnya, *Naive Bayes Classifier* memiliki kinerja yang sangat baik. (Rayuwati et al. 2022)

2.3.5 Metode Neural Networks

Jaringan Saraf Tiruan (JST) atau *Artificial Neural Network* (ANN) adalah prosesor terdistribusi besar-besaran secara paralel yang terdiri dari unit proses

sederhana. ANN dapat menyimpan pengetahuan dalam bentuk pengalaman dan dapat digunakan untuk proses lain. ANN juga dapat digambarkan sebagai jaringan yang mirip dengan otak manusia yang diprogram untuk melakukan tugas tertentu. ANN dapat menyimpan pengetahuan dalam bentuk pengalaman dan dapat digunakan untuk proses lain. ANN juga dapat digambarkan sebagai jaringan yang mirip dengan otak manusia yang diprogram untuk melakukan tugas tertentu. ANN dapat digunakan untuk memodelkan hubungan yang kompleks antara input dan output, yang kemudian dapat digunakan untuk menemukan pola dalam data. Biasanya, jaringan ini dijalankan dengan komponen elektronik atau disimulasikan melalui aplikasi komputer. (Rayuwati et al. 2022)


2.3.6 Metode Decision Tree

Decision Tree termasuk dalam kategori machine learning dan merupakan bagian dari supervised learning. *Decision tree* juga dikenal sebagai CART (Classification and Regression Tree), dan metode ini adalah kombinasi dari dua jenis pohon: *classification tree* dan *regression tree*. (Bintoro, Trisnawan, and Data 2023). *Decision Tree* biasanya menggunakan strategi pencarian secara top-down. Dalam proses mengklasifikasi data yang tidak diketahui, nilai atribut diuji dengan melacak jalur dari node akar hingga node akhir, yang dikenal sebagai daun. Setelah itu, nilai atribut akan diprediksi kelas yang dimiliki oleh data baru. (Bintoro et al. 2023)

METODE PENELITIAN

Perencanaan penelitian adalah perencanaan penelitian yang tujuannya

untuk memberikan pedoman dalam melakukan proses penelitian. Perencanaan penelitian menyediakan kerangka kerja dan alur kerja untuk seluruh proses penelitian. Berikut adalah desain penelitian dari penelitian ini



Gambar 1. Metode Penelitian
Sumber: Data Penelitian, 2025

Berikut penjelasan untuk desain Penelitian dari penelitian ini:

1. Pengumpulan Data

Data dikumpulkan dari kumpulan sampel malware dan non-malware yang berasal dari Sumber tertentu Yaitu Kanggle. Data ini digunakan untuk melakukan pelatihan dan pengujian model.

2. Pra Pemrosesan Data

Pada titik ini, data dibersihkan dan disusun. Misalnya, hapus data duplikat atau tidak relevan; normalisasi nilai; menangani data kosong atau tidak lengkap; dan encoding variabel kategori jika diperlukan.

3. Pembagian Data

Data set yang telah diproses terdiri dari dua bagian yaitu data latih dan data uji

4. Evaluasi Model

Akurasi, precision, recall, dan f1 score ini adalah metrik yang digunakan untuk mengevaluasi tes

5. Hasil Akhir

Evaluasi menghasilkan kesimpulan tentang seberapa baik model SVM mendeteksi malware. Keputusan ini membantu menentukan efektivitas metode yang digunakan.

3.2 Metode Pengumpulan Data

Dalam penelitian ini, metode pengumpulan data dilakukan melalui beberapa metode, yaitu Survei, observasi eksperimen, dan studi pustaka untuk mendukung pemahaman terhadap kebutuhan serta tantangan dalam sistem deteksi malware.

3.3 Metode Deteksi Malware Menggunakan Algoritma SVM

Berikut beberapa Metode Deteksi Malware Menggunakan Algoritma Support Vector Machine yang digunakan dalam penelitian ini:

1. Pengumpulan Dataset

Dalam penelitian ini dataset malware diambil dari sumber yaitu Kaggle. Dataset yang digunakan dalam proses pre-processing 100.000 data sampel untuk menemukan malware dalam penelitian ini. Jumlah fitur yg terdapat ada 33 fitur

2. Data Processing

Dalam deteksi serangan malware, dataset yang didapatkan dilakukan preprocessing yang dimulai dengan pembersihan data, yang menghilangkan

duplikat data dan menangani nilai yang tidak ada. Selanjutnya, fitur dinamis dan statis, seperti ukuran file, entropi, panggilan API, dan izin, diekstraksi. Encoding mengubah semua fitur menjadi format numerik dan kemudian dinormalisasi untuk memastikan skala yang seragam. Untuk menjaga proporsi kelas, metode sampling stratified digunakan untuk membagi dataset menjadi dua bagian: 80% data latih dan 20% data uji.

3. Explanatory Data Analysis

Sebelum memasuki tahap pemodelan, analisis data eksplisit (EDA) dilakukan untuk mendapatkan pemahaman tentang karakteristik data. Pada titik ini, analisis distribusi data, identifikasi pola, pencarian anomali, dan analisis hubungan antar fitur dilakukan. EDA memastikan data yang digunakan tepat dan berkualitas tinggi. Untuk menunjukkan persebaran data, visualisasi seperti histogram, boxplot, dan scatterplot digunakan. Selain itu, dilakukan analisis korelasi fitur untuk menentukan fitur mana yang memiliki korelasi kuat dengan label malware.

4. Feature Extraction

Tujuan ekstraksi fitur adalah untuk mengekstrak informasi penting dari data mentah yang terkait dengan aktivitas malware. Studi ini mengekstraksi fitur dinamis seperti jumlah dan jenis panggilan API dan izin yang diminta oleh aplikasi serta fitur statis seperti ukuran file dan entropi. Teknik encoding mengubah fitur menjadi representasi numerik, sehingga dapat digunakan dalam proses pelatihan model pembelajaran Mesin.

$$\text{F1-Score} = \frac{2 \times \text{Precision} \times \text{Recal}}{\text{Precision} + \text{recal}}$$

The screenshot displays the Microsoft Excel 2010 application window. The title bar reads 'Microsoft Excel - [Book1.xlsx]'. The ribbon at the top is set to 'Formulas', with the 'Data' tab selected. The main workspace shows a spreadsheet with 10 columns (A-J) and 10 rows (1-10). The data is as follows:

	A	B	C	D	E	F	G	H	I	J
1	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
2	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
3	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
4	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
5	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
6	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
7	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
8	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
9	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
10	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000

The status bar at the bottom indicates 'Formulas' and 'Data'.

Data yang semula memiliki beberapa kolom bertipe objek telah berhasil dikonversi menjadi numerik, dibersihkan dari nilai yang tidak valid, dan seluruh fitur telah distandarisasi agar siap digunakan dalam proses klasifikasi. Fitur tersebut adalah sebagai berikut:


No	Nama Kolom	Jumlah Data (Non-Null)	Tipe Data
0	millisecond	100000	float64
1	state	100000	int64
2	usage_counter	100000	float64
3	prio	100000	float64
4	static_prio	100000	float64
5	normal_prio	100000	float64
6	policy	100000	float64
7	vm_pgoff	100000	float64
8	vm_truncate_count	100000	float64
9	task_size	100000	float64
10	cached_hole_size	100000	float64
11	free_area_cache	100000	float64
12	mm_users	100000	float64
13	map_count	100000	float64
14	hiwater_rss	100000	float64
15	total_vm	100000	float64
16	shared_vm	100000	float64
17	exec_vm	100000	float64
18	reserved_vm	100000	float64
19	nr_ptes	100000	float64
20	end_data	100000	float64
21	last_interval	100000	float64
22	nvcs	100000	float64
23	nvcs	100000	float64
24	min_fit	100000	float64
25	maj_fit	100000	float64
26	fs_excl_counter	100000	float64
27	lock	100000	float64
28	utime	100000	float64
29	stime	100000	float64
30	gtime	100000	float64
31	cgtime	100000	float64
32	signal_nvcs	100000	float64
33	classification	100000	int64

Gambar 3. Hasil Processing
Sumber: Data Penelitian, 2025

3. Hasil Explanatory Data Analysis

Ada variasi skala nilai yang cukup besar, seperti yang ditunjukkan oleh statistik deskriptif untuk setiap fitur. Selain itu, ada nilai-nilai ekstrem (*outlier*) pada beberapa fitur, seperti *utime*, *stime*, dan *gtime*. Oleh karena itu, normalisasi data adalah langkah penting untuk memastikan bahwa semua fitur memiliki skala yang sama. Selain itu, seperti yang ditunjukkan oleh analisis korelasi, beberapa fitur memiliki korelasi yang cukup kuat terhadap label target klasifikasi. Ini dapat menjadi tanda penting dari proses klasifikasi.

Sebaliknya, ditemukan korelasi tinggi antara fitur, yang mungkin menjadi alasan untuk mempertimbangkan untuk melakukan seleksi fitur untuk mengurangi redundansi. Hasil EDA ini membantu menentukan fitur yang relevan dan menyiapkan data untuk tahap pemodelan



Gambar 4. Hasil Statistik Deskriptif
Sumber: Data Penelitian, 2025

4. Hasil Feature Extraction

Ekstraksi fitur dilakukan untuk memilih dan menyaring fitur-fitur yang paling penting bagi tujuan klasifikasi. Tujuan dari proses ini adalah untuk meningkatkan efisiensi model, mengurangi kompleksitas data, dan mengurangi kemungkinan terjadinya overfitting selama pelatihan.

==== Tabel Fitur Terpilih Berdasarkan Korelasi > 0.1 ====

No	Fitur	Korelasi
0 1	free_area_cache	0.235423
1 2	min_flt	0.146533
2 3	map_count	-0.105953
3 4	total_vm	-0.109715
4 5	nvcs	-0.119344
5 6	utime	-0.173988
6 7	vm_truncate_count	-0.251970
7 8	shared_vm	-0.324839
8 9	end_data	-0.324839
9 10	maj_flt	-0.324839

Gambar 5. Hasil Fitur terpilih Berdasarkan Korelasi
Sumber: Data Penelitian, 2025

5. Hasil Data Split

Data dibagi menjadi data latih dan data uji untuk keperluan pelatihan dan evaluasi model.

Index	Jenis Data	Ukuran Data	Fitur	Distribusi Label 0	Distribusi Label 1
0	X_train	80000	33	50%	50%
1	X_test	20000	33	50%	50%

Show 25 per page

Gambar 6. Hasil Data Split
Sumber: Data Penelitian, 2025

6. Hasil Build Model Klasifikasi

Pada titik ini, model klasifikasi dibangun menggunakan algoritma Support Vector Classifier (SVC) yang memiliki kernel linear. Data latihan yang diperoleh dari proses pembagian dataset sebelumnya digunakan untuk melatih model.


Index	Komponen	Nilai/Deskripsi
0	Algoritma	Support Vector Classifier (SVC)
1	Library	sklearn.svm.SVC
2	Parameter Utama	random_state=42
3	Data latih (X_train)	80000 baris = 33 fitur
4	Data target (y_train)	80000 label
5	Tahapan	1. Instansiasi model, 2. Pelatihan model
6	Status	Model berhasil dilatih

Gambar 7. Hasil Build Model Klasifikasi
Sumber: Data Penelitian, 2025

7. Hasil Evaluation Model


Untuk melakukan evaluasi model, confusion matrix digunakan. Hasil

pengujian model SVM dengan confusion matrix adalah Sebagai berikut.



Gambar 8. Confusion Matrix SVM
Sumber: Data Penelitian, 2025

Gambar di bawah ini menunjukkan distribusi label asli dan hasil prediksi. Ditunjukkan oleh dominasi prediksi yang sesuai dengan label; aktual, model SVM mampu mengklasifikasikan data malware dan bukan malware dengan sangat baik. Dengan akurasi 99,57%, model ini memiliki jumlah kesalahan prediksi yang sangat kecil.



Gambar 9. Distribusi Hasil prediksi Model SVM
Sumber: Data Penelitian, 2025

Tabel di bawah ini menunjukkan hasil evaluasi model klasifikasi menggunakan metrik akurasi, ketepatan, recall, dan skor

F1. Metrik-metrik ini menunjukkan kemampuan model untuk mengklasifikasikan data dengan tepat, terutama dalam membedakan antara kelas normal dan kelas malware.

Tabel 1. Tabel Evaluasi Model

Metrik	Nilai
Akurasi	0.9957
Precision	0.9976
Recall	0.9938
F1-Score	0.9957

Sumber: Data Penelitian, 2025

Hasil perhitungan confusion matrix berikut menunjukkan bagaimana model berhasil membedakan data normal dan malware berdasarkan prediksi dan label aktual.

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} = \frac{9.938+9.976}{9.938+9.976+24+62} = \frac{19.914}{20.000} = 0,9957 = 99,57\%$$

$$\text{Precision} = \frac{TP}{TP+FP} = \frac{9.938}{9.938+24} = \frac{9.938}{9.962} = 0,9976 = 99,76\%$$

$$\text{Recall} = \frac{TP}{TP+FN} = \frac{9.938}{9.938+62} = \frac{9.938}{10.000} = 0,9938 = 99,38\%$$

$$\text{F1-Score} = \frac{2 \times 0,9976 \times 0,9938}{0,9976 + 0,9938} = \frac{1,9828}{1,9914} = 0,9957$$

Hasil pengujian menunjukkan bahwa algoritma SVM memiliki kinerja yang sangat baik dengan tingkat akurasi 99,57%. Selain itu, nilai *Precision* 99,76%, *recall* 99,38%, dan skor F1 99,57% menunjukkan bahwa model mampu membedakan secara sangat tepat antara data serangan malware dan non-malware. Dari 20.000 data yang diuji, hanya ada 86 kesalahan klasifikasi.

SIMPULAN

1. Menurut fitur aktivitas sistem seperti penggunaan CPU, memori, dan *switching* konteks, algoritma *Support Vector Machine* (SVM) berhasil mengklasifikasikan proses sistem operasi menjadi dua kelas: malware dan non-malware.
2. Dengan *accuracy* 99,57%, *Precision* 99,76%, *recall* 99,38%, dan skor F1 99,57%, model yang dibangun menggunakan SVM dengan kernel linear menunjukkan tingkat keakuratan dan konsistensi model dalam mengenali serangan malware.
3. Proses *preprocessing* data seperti normalisasi, konversi tipe data numerik, dan seleksi fitur berbasis korelasi meningkatkan
4. Untuk memastikan bahwa proses pelatihan dan evaluasi model berjalan secara adil dan representatif, distribusi data uji dan latihan yang seimbang (masing-masing 50% untuk setiap kelas diperlukan
5. Secara keseluruhan, metode klasifikasi berbasis SVM sangat cocok untuk sistem pendeteksi dini malware,
6. Terutama yang bergantung pada perilaku proses sistem operasi. Namun, untuk menjaga keakuratan, model harus diperbarui secara berkala dengan data terbaru seiring dengan perkembangan metode serangan malware.

DAFTAR PUSTAKA

- Bintoro, R. F. A., P. H. Trisnawan, and M. Data. 2023. "Deteksi Bot Network (BOTNET) Menggunakan Metode Decision Tree Dari Dataset CTU." ... *Teknologi Informasi Dan Ilmu* ... 7(6):2921–30.
- Halim, Andi Ainun Dzariah, and Siska

- Anraeni. 2021. "Analisis Klasifikasi Dataset Citra Penyakit Pneumonia Menggunakan Metode K-Nearest Neighbor (KNN)." *Indonesian Journal of Data and Science* 2(1):01–12. doi: 10.33096/ijodas.v2i1.23.
- Mahesh, Batta. 2020. "Machine Learning Algorithms - A Review." *International Journal of Science and Research (IJSR)* 9(1):381–86. doi: 10.21275/art20203995.
- Putra, Rizki Ramadhan, and Ilmu Komputer. 2024. "ANALISIS DATA MINING UNTUK DETEKSI MALWARE PADA." 1(6):1–17.
- Rayuwati, Husna Gemasih, and Irma Nizar. 2022. "IMPLEMENTASI ALGORITMA NAIVE BAYES UNTUK MEMPREDIKSI TINGKAT PENYEBARAN COVID." *Jurnal Riset Rumpun Ilmu Teknik* 1(1):38–46. doi: 10.55606/jurritek.v1i1.127.
- Sinaga, Novica Handayani, Deci Irmayani, and Mila Nirmala Sari Hasibuan. 2024. "Mengoptimalkan Keamanan Jaringan: Memanfaatkan Kecerdasan Buatan Untuk Meningkatkan Deteksi Dan Respon Ancaman." *Jurnal Ilmu Komputer Dan Sistem Informasi (JIKOMSI)* 7 Nomor 2(September):364–69.
- Tjahjadi, Evan Valdis, and Budy Santoso. 2023. "Klasifikasi Malware Menggunakan Teknik Machine Learning." *Jurnal Ilmiah Ilmu Komputer* 2(1):60–70.
- Wanli Sitorus, Yitshak, Parman Sukarno, and Satria Mandala. 2021. "Analisis Deteksi Malware Android Menggunakan Metode Support Vector Machine & Random Forest." *E-Proceeding of Engineering* 8(6):12500–518.
- Bintoro, R. F. A., P. H. Trisnawan, and M. Data. 2023. "Deteksi Bot Network (BOTNET) Menggunakan Metode Decision Tree Dari Dataset CTU." ... *Teknologi Informasi Dan Ilmu ...* 7(6):2921–30.
- Halim, Andi Ainun Dzariah, and Siska Anraeni. 2021. "Analisis Klasifikasi Dataset Citra Penyakit Pneumonia Menggunakan Metode K-Nearest Neighbor (KNN)." *Indonesian Journal of Data and Science* 2(1):01–12. doi: 10.33096/ijodas.v2i1.23.
- Mahesh, Batta. 2020. "Machine Learning Algorithms - A Review." *International Journal of Science and Research (IJSR)* 9(1):381–86. doi: 10.21275/art20203995.
- Putra, Rizki Ramadhan, and Ilmu Komputer. 2024. "ANALISIS DATA MINING UNTUK DETEKSI MALWARE PADA." 1(6):1–17.
- Rayuwati, Husna Gemasih, and Irma Nizar. 2022. "IMPLEMENTASI ALGORITMA NAIVE BAYES UNTUK MEMPREDIKSI TINGKAT PENYEBARAN COVID." *Jurnal Riset Rumpun Ilmu Teknik* 1(1):38–46. doi: 10.55606/jurritek.v1i1.127.
- Sinaga, Novica Handayani, Deci Irmayani, and Mila Nirmala Sari Hasibuan. 2024. "Mengoptimalkan Keamanan Jaringan: Memanfaatkan Kecerdasan Buatan Untuk Meningkatkan Deteksi Dan Respon Ancaman." *Jurnal Ilmu Komputer Dan Sistem Informasi (JIKOMSI)* 7 Nomor 2(September):364–69.
- Tjahjadi, Evan Valdis, and Budy Santoso. 2023. "Klasifikasi Malware Menggunakan Teknik Machine Learning." *Jurnal Ilmiah Ilmu Komputer* 2(1):60–70.

Wanli Sitorus, Yitshak, Parman Sukarno,
and Satria Mandala. 2021. "Analisis
Deteksi Malware Android
Menggunakan Metode Support
Vector Machine & Random Forest."
E-Proceeding of Engineering 8(6):12500–
518.

	Hery Sanjaya Simbolon, merupakan mahasiswa Prodi Teknik Informatika Universitas Putera Batam
	Andi Maslan, S.T,M.SI,P.HD. merupakan Dosen Prodi Teknik Informatika Universitas Putera Batam, yang aktif dan <i>expert</i> di bidang Teknik Informatika