

PREDICTIVE MAINTENANCE ENGINE HEALTH MONITORING SYSTEM PADA EXCAVATOR BERBASIS MACHINE LEARNING

***Zarir Athallah¹, M. Munadi², Mochammad Ariyanto²**

¹Mahasiswa Jurusan Teknik Mesin, Fakultas Teknik, Universitas Diponegoro

²Dosen Jurusan Teknik Mesin, Fakultas Teknik, Universitas Diponegoro

Jl. Prof. Sudharto, S.H., Tembalang-Semarang 50275, Telp. +62247460059

*E-mail: zarirath@gmail.com

Abstrak

Penelitian ini bertujuan untuk menguji efektivitas prediksi *maintenance* terhadap mesin excavator dalam industri pertambangan menggunakan metode *machine learning*. Ekskavator merupakan salah satu alat berat yang memiliki peran penting dalam proses operasional, namun rentan mengalami kerusakan yang memerlukan perawatan dan perbaikan tepat waktu agar tidak mengganggu produktivitas. Untuk mengatasi masalah ini, penelitian ini menerapkan model *machine learning* guna memprediksi kemungkinan kegagalan kerusakan mesin berdasarkan data operasional. Model algoritma yang digunakan yaitu *support vector machine* (SVM) yang dianalisis untuk menentukan model dengan akurasi terbaik dalam memprediksi waktu perawatan yang optimal. Data yang digunakan mencakup parameter seperti *boost pressure*, *blowby pressure*, serta *unit lifetime* pada saat operasional sedang berlangsung. Hasil penelitian menunjukkan bahwa pendekatan berbasis *machine learning* mampu meningkatkan efisiensi perawatan dengan mengurangi *downtime* dan memperpanjang umur operasional ekskavator. Dengan adanya sistem prediksi ini, perusahaan dapat mengoptimalkan jadwal pemeliharaan, mengurangi biaya perbaikan mendadak, serta meningkatkan keselamatan dan produktivitas di lokasi pertambangan. Studi ini diharapkan dapat menjadi referensi dalam penerapan teknologi kecerdasan buatan untuk meningkatkan efisiensi industri alat berat.

Kata Kunci: ekskavator; *machine learning*; *predictive maintenance*; svm

Abstract

This study aims to examine the effectiveness of maintenance prediction for excavator machines in the mining industry using machine learning methods. Excavators are essential heavy equipment in operational processes but are prone to failures that require timely maintenance and repairs to prevent disruptions in productivity. To address this issue, this study applies a machine learning model to predict the likelihood of machine failures based on operational data. The algorithm used is the support vector machine (SVM), which is analyzed to determine the model with the best accuracy in predicting the optimal maintenance time. The data used includes parameters such as boost pressure, blowby pressure, and unit lifetime during operation. The results indicate that a machine learning-based approach can improve maintenance efficiency by reducing downtime and extending the operational lifespan of excavators. With this predictive system, companies can optimize maintenance schedules, reduce unexpected repair costs, and enhance safety and productivity in mining sites. This study is expected to serve as a reference for implementing artificial intelligence technology to improve efficiency in the heavy equipment industry.

Keywords: excavator; *machine learning*; *predictive maintenance*; svm

1. Pendahuluan

Alat berat seperti ekskavator krusial bagi industri, namun rentan rusak yang menyebabkan kerugian dan bahaya. Sistem perawatan konvensional seperti *preventive* dan *corrective maintenance* dinilai tidak efisien karena tidak berdasarkan kondisi aktual mesin. Sejalan dengan era Industri 4.0 dan konsep *smart manufacturing*, predictive maintenance menggunakan machine learning (khususnya algoritma Support Vector Machines/SVM) menjadi solusi menjanjikan[1]. Dengan menganalisis data operasional seperti tekanan *boost* dan *blowby*, sistem ini dapat memprediksi kerusakan dini, sehingga meningkatkan efisiensi perawatan, mengurangi biaya operasional, dan memperpanjang umur produktivitas ekskavator secara signifikan[2]. Penelitian ini bertujuan mengembangkan dan mengevaluasi sistem tersebut untuk mendukung transformasi digital dan *smart maintenance* di sektor alat berat. Penelitian ini bertujuan merancang, mengembangkan, dan mengevaluasi sistem pemantauan kesehatan ekskavator berbasis SVM untuk deteksi dan klasifikasi kerusakan, serta membantu klasifikasi penggunaan kendaraan secara efisien.

2. Kecerdasan Buatan

Ekskavator adalah alat berat esensial dalam konstruksi dan pertambangan untuk menggali serta menangani material. Penggunaan intensifnya membuat ekskavator rentan terhadap kegagalan, sehingga perbaikan dan pemeliharaan yang tepat sangat dibutuhkan untuk menjaga keandalan dan efisiensinya. Dalam industri pertambangan, *predictive maintenance* menjadi krusial untuk meningkatkan efisiensi dalam mengatasi kerusakan ekskavator[3].

Predictive maintenance adalah strategi pemeliharaan yang memantau kondisi aktual mesin secara berkala menggunakan data lapangan, efisiensi operasional, dan indikator lainnya. Tujuannya adalah memastikan interval perbaikan maksimal dan meminimalkan biaya perawatan, sehingga meningkatkan produktivitas, kualitas produk, dan efektivitas keseluruhan. Berbeda dari metode tradisional yang berdasarkan statistik masa pakai rata-rata, *predictive maintenance* memanfaatkan alat seperti pemantauan getaran, termografi, dan tribologi untuk mendasarkan jadwal pemeliharaan pada kondisi mesin *aktual*. Seiring perkembangan Industri 4.0, *machine learning* kini diterapkan untuk memprediksi kerusakan mesin, memungkinkan sistem belajar dari data historis untuk memaksimalkan efisiensi dan mengurangi biaya produksi[4][5].

Machine learning unggul dalam mendeteksi pola kegagalan dini dan memprediksi keandalan di berbagai industri. Kinerjanya meningkat seiring kualitas dan kuantitas data yang dipelajari[6]. Terdapat tiga jenis utama *machine learning*: *Supervised Learning* yang belajar dari data berlabel (input-output), *Unsupervised Learning* yang belajar dari data tanpa label, dan *Reinforcement Learning* yang belajar melalui interaksi dan umpan balik dari lingkungan[7]. Penerapan *machine learning* telah terbukti efektif dalam klasifikasi gambar, deteksi objek, dan prediksi kegagalan berbasis deret waktu.

Dalam berbagai industri, *machine learning* efektif mendeteksi pola kegagalan dini dan memprediksi keandalan, dengan performa yang meningkat seiring kualitas data. Tiga jenis utamanya adalah *Supervised Learning* (data berlabel), *Unsupervised Learning* (data tanpa label), dan *Reinforcement Learning* (interaksi lingkungan). Salah satu metode *machine learning* yang sangat penting adalah *Neural Network*. Metode ini unggul dalam mengenali pola kompleks dan membuat prediksi akurat di berbagai bidang seperti *computer vision*, *natural language processing*, dan *predictive maintenance*, menjadikannya krusial dalam analisis data industri dan otomasi system [8].

Regresi linier adalah metode statistik dan algoritma *machine learning* fundamental yang menganalisis serta memprediksi hubungan antara satu variabel dependen dengan satu atau lebih variabel independen. Sebagai bagian dari *supervised learning*, model regresi linier dilatih dengan data historis untuk mengidentifikasi pola dan membangun garis lurus yang paling sesuai dengan data menggunakan metode *least squares*, tujuannya adalah meminimalkan kesalahan prediksi[9]. Dengan menemukan nilai optimal dari bobot (W), regresi linier memungkinkan prediksi akurat, analisis hubungan data, dan mendukung pengambilan keputusan dalam berbagai aplikasi industri serta penelitian. Persamaan umum regresi linear dalam Machine Learning dinyatakan pada persamaan (1) sebagai berikut:

$$\hat{Y} = W_0 + W_1X_1 + W_2X_2 + \dots + W_nX_n \quad (1)$$

Support Vector Machines (SVM) adalah algoritma *supervised learning* yang efektif untuk klasifikasi dan regresi, bahkan dengan data terbatas. SVM bekerja dengan menemukan *hyperplane* optimal yang memisahkan kelas data (untuk klasifikasi) atau memprediksi nilai kontinu (untuk regresi), menggunakan pemetaan non-linear ke dimensi yang lebih tinggi[10]. Dalam kasus data yang bersifat linear, *hyperplane* memisahkan data dapat diketahui dengan persamaan (2) berikut:

$$f(x) = w^T + b = \sum_{j=1}^M w_j x_j + b = 0 \quad (2)$$

Algoritma ini memiliki dua jenis utama: *Support Vector Classification* (SVC) untuk tugas klasifikasi biner dan *Support Vector Regression* (SVR) untuk prediksi variabel kontinu. Dalam *predictive maintenance*, SVM sangat berguna untuk mengidentifikasi pola kerusakan atau degradasi performa mesin dari data sensor yang kompleks dan seringkali non-linear (seperti suhu, getaran, dan tekanan). Kemampuannya memetakan data ke ruang fitur berdimensi tinggi dan menggunakan *kernel trick* (misalnya *Radial Basis Function*) memungkinkan deteksi kerusakan dini yang akurat. Hal ini berkontribusi pada pengurangan waktu henti (*downtime*), efisiensi biaya operasional, dan optimasi jadwal perawatan, menjadikan SVM pilihan yang andal untuk sistem pemeliharaan berbasis data di industri[11][12][13][14].

Cross-validation adalah tahap krusial untuk mengevaluasi akurasi model regresi dan klasifikasi. Untuk data *time-series*, diperlukan metode *time series cross-validation*. Metode ini membagi *dataset* menjadi beberapa bagian terpisah yang akan diolah dalam iterasi, di mana bagian terakhir akan berfungsi sebagai data *testing* untuk menguji akurasi model[15].

3. Alat dan Metode Penelitian

3.1 Hardware dan Software

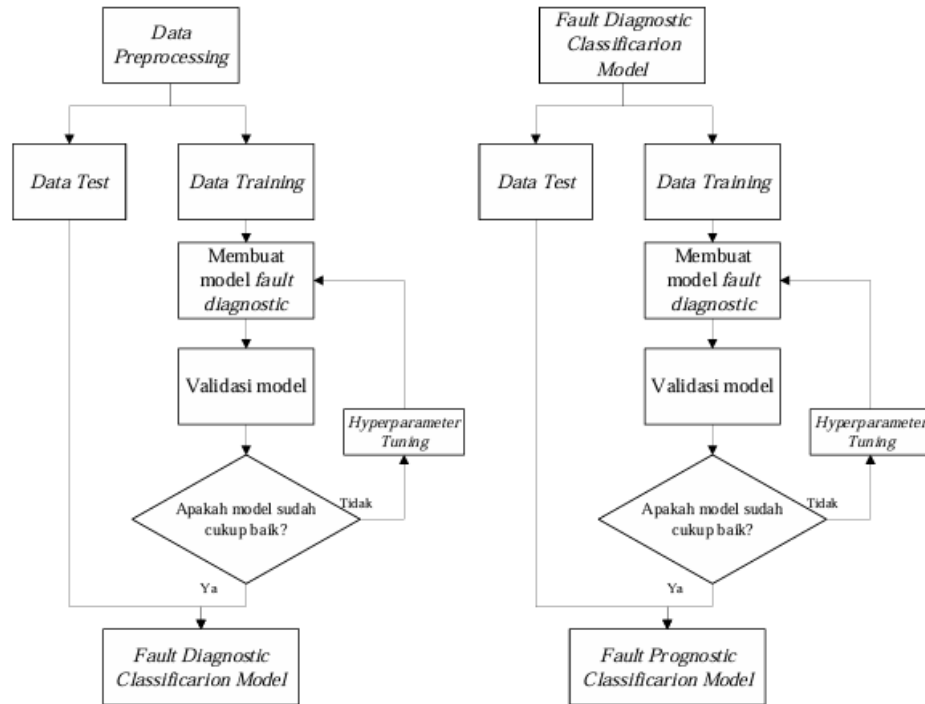
Hardware merupakan komponen esensial dalam penelitian ini, mendukung setiap tahapan pengembangan program, mulai dari pengumpulan dan pengolahan data hingga *deployment model machine learning*. *Hardware* juga memungkinkan eksplorasi algoritma, pengujian performa, dan tuning parameter untuk meningkatkan akurasi dan efisiensi sistem. Dengan spesifikasi yang memadai, *hardware* mampu menjalankan komputasi kompleks, termasuk pelatihan model *deep learning*, yang krusial untuk pengembangan model algoritma deteksi data dalam *predictive maintenance*.

Python 3.10.11 adalah rilis terbaru yang membawa peningkatan signifikan dalam pengembangan perangkat lunak, termasuk perbaikan sintaksis, manajemen memori, dan keamanan. Versi ini mendukung pustaka utama seperti *numpy*, *pandas*, *tensorflow*, dan *scikit-learn*, menjadikannya ideal untuk pengembangan web, analisis data, AI, dan otomasi. Fitur utamanya adalah *structural pattern matching* untuk kode yang lebih bersih dan pesan kesalahan tipe yang lebih baik untuk *debugging* yang cepat. Selain itu, Python 3.10.11 menawarkan optimasi kinerja, termasuk *garbage collection* yang ditingkatkan dan eksekusi komputasi berat yang lebih cepat, serta kompatibilitas luas dengan berbagai sistem operasi dan alat pengembangan.

3.2 Proses

Dalam penelitian ini, kami menggunakan variabel bebas berupa parameter mesin yang memengaruhi kinerja atau umur, seperti *exhaust gas temperature*, *blowby pressure*, *engine oil pressure* (Low/High Idle), *boost pressure*, *transmission oil temp*, *engine oil temp*, dan *coolant temp*. Variabel terikatnya adalah *unit lifetime* (Hour), yang menunjukkan umur unit atau mesin. Untuk memastikan akurasi, kami menetapkan jenis ekskavator sebagai variabel kontrol.

Dilakukan pemisahan data training pembuatan model dan validasi model pada model diagnosis dan prognosis. Gambar 1 menunjukkan proses pembuatan model diagnosis dan prognosis.



Gambar 1. Alur Diagnosa dan Prognosis

Prosedur penelitian ini mencakup beberapa tahapan: pengumpulan *dataset* dari sensor-sensor ekskavator di lapangan (meliputi tekanan *blowby* dan oli mesin, suhu *boost*, oli transmisi, oli mesin, *coolant*, gas buang, serta masa pakai unit), ekstraksi parameter data *time series* yang relevan, lalu membagi data untuk *training* dan *testing* guna memprediksi dan menentukan waktu kerusakan mesin ekskavator. Pengambilan data dilakukan langsung dari ekskavator menggunakan perangkat diagnostik CAT ET 2025A, dengan fokus pada sensor-sensor penting seperti *manifold absolute pressure*, *pressure transducer*, dan *NTC thermistor* pada ECU, yang bertujuan untuk mendeteksi potensi kerusakan mesin.

Data mentah dari sensor ekskavator diolah melalui pembersihan, eksplorasi, transformasi fitur, pelatihan, dan evaluasi untuk membangun model prediktif yang akurat. Proses ini menggunakan tiga model pengujian. Model pertama memprediksi masa pakai unit berdasarkan perbandingan *blowby pressure* dan *boost pressure*, yang penting untuk deteksi dini kerusakan. Model kedua menambahkan *engine oil temperature* untuk mengoptimalkan penggantian oli dan perawatan. Model ketiga memperluas model kedua dengan menyertakan *engine coolant temperature*, memberikan pendekatan yang lebih komprehensif untuk memprediksi kondisi dan umur operasional unit secara waktu nyata.

Proses *training* model *Support Vector Machines* (SVM) dimulai dengan mengunduh algoritma dari *library Scikit-Learn*. Data kemudian dinormalisasi dan distandardisasi agar optimal, lalu dibagi menjadi 50% *training set* dan 50% *testing set*. Selama pelatihan, *kernel trick* seperti *Radial Basis Function* (RBF) dan *hyperparameter tuning* dengan *gridsearchCV* diterapkan untuk mengoptimalkan akurasi. Setelah pelatihan, model dievaluasi menggunakan metrik akurasi, presisi, *recall*, dan *F1-score* untuk memastikan kemampuannya dalam klasifikasi kondisi mesin dan mendukung *predictive maintenance*.

Ekstraksi data *maintenance* lapangan bertujuan untuk memperkecil *dataset* yang besar demi efisiensi penyimpanan, pemrosesan, dan analisis. Dalam prediksi *maintenance* ekskavator, proses ini menghilangkan redundansi dan *noise*, serta mengekstrak fitur relevan agar model *machine learning* bekerja lebih cepat dan akurat. Data yang ringkas juga meringankan komputasi, mempercepat pelatihan model, menghemat sumber daya, dan mempermudah visualisasi serta interpretasi informasi untuk penjadwalan *maintenance* yang lebih efektif.

Algoritma *predictive maintenance* dirancang untuk memprediksi kerusakan mesin sebelum kegagalan total dengan menganalisis data operasional *real-time* dari sensor ekskavator (contohnya, *engine boost pressure*, *blowby pressure*, *engine oil temperature*, *coolant temperature*, dan jam operasional). Penggunaan *Support Vector Machines* (SVM), baik

Support Vector Classification (SVC) maupun *Support Vector Regression* (SVR), bertujuan untuk meningkatkan akurasi klasifikasi dan memprediksi kebutuhan perbaikan berdasarkan masa pakai unit. Model ini kemudian divalidasi menggunakan metrik seperti akurasi, *precision*, *recall*, dan F1-score untuk memastikan keandalan prediksinya. Setelah uji *training*, data *preprocessing* dilakukan untuk memastikan algoritma sesuai dengan data prediksi agar menghasilkan akurasi tinggi.

3.3 Pembuatan Program Klasifikasi, Prediksi Klasifikasi, Prediksi Data Kontinu, Penilaian Hasil Data Prediksi

Penelitian ini berfokus pada pengembangan program untuk deteksi, klasifikasi, dan regresi data. Program ini akan mengklasifikasikan data berdasarkan parameter peringatan mesin dan memprediksi nilai kontinu. Kami mengembangkan tiga model klasifikasi untuk membandingkan hasil, dengan menambahkan parameter *engine oil temperature* ($>100^{\circ}\text{C}$) dan *coolant temperature* ($>90^{\circ}\text{C}$) pada setiap model, selain parameter awal *blowby pressure* (>5 kPa) dan *boost pressure* (>165 kPa), semuanya berdasarkan *unit lifetime*.

Untuk memprediksi umur kerusakan ekskavator, kami menggunakan *Support Vector Classification* (SVC). Proses ini diawali dengan membagi data lapangan 50:50 menjadi *data train set* dan *test set*, lalu menormalisasinya menggunakan *StandardScaler* untuk optimalisasi. Model *Support Vector Machines* (SVM) dibangun dengan kernel RBF (*Radial Basis Function*). Parameter C diatur ke 10 untuk menyeimbangkan *margin error*, dan probabilitas diaktifkan untuk prediksi.

Setelah akurasi klasifikasi data tercapai, *Support Vector Regression* (SVR) digunakan untuk memprediksi nilai pemakaian secara kontinu. Model ini dilatih dengan pembagian data *train* dan *test* 80:20, serta *StandardScaler* untuk optimasi performa prediksi. SVR dibangun menggunakan kernel sigmoid (karena dataset menunjukkan perubahan menurun atau stabil mendekati batas) dengan nilai $C = 300$ (mengontrol regulasi) dan $\gamma = 0.4$ (mengontrol pengaruh titik data).

Visualisasi *confusion matrix* sangat penting dalam *predictive maintenance* untuk menilai kinerja model dalam mengklasifikasikan kebutuhan perawatan mesin. Matriks ini menyajikan tabel jumlah prediksi benar (*true positive* dan *true negative*) dan salah (*false positive* dan *false negative*), memberikan gambaran jelas mengenai akurasi prediksi.

4. Analisis Hasil Pengujian

4.1 Validasi Klasifikasi Dataset *Predictive Maintenance Excavator*

Evaluasi performa model deteksi kerusakan ekskavator menggunakan metrik akurasi, presisi, *recall*, dan F1-score. Model pertama, dengan parameter *boost pressure* dan *blowby pressure*, menunjukkan hasil terbaik dengan akurasi 99% dan kemampuan tinggi membedakan data perlu/tidak perlu perawatan. Namun, penambahan parameter *engine oil temperature* (model kedua) dan *coolant temperature* (model ketiga) secara berurutan menurunkan akurasi model menjadi 98%, terutama pada klasifikasi data yang tidak membutuhkan perawatan. Berikut merupakan Tabel 1 yang menunjukkan hasil validasi pada ketiga model.

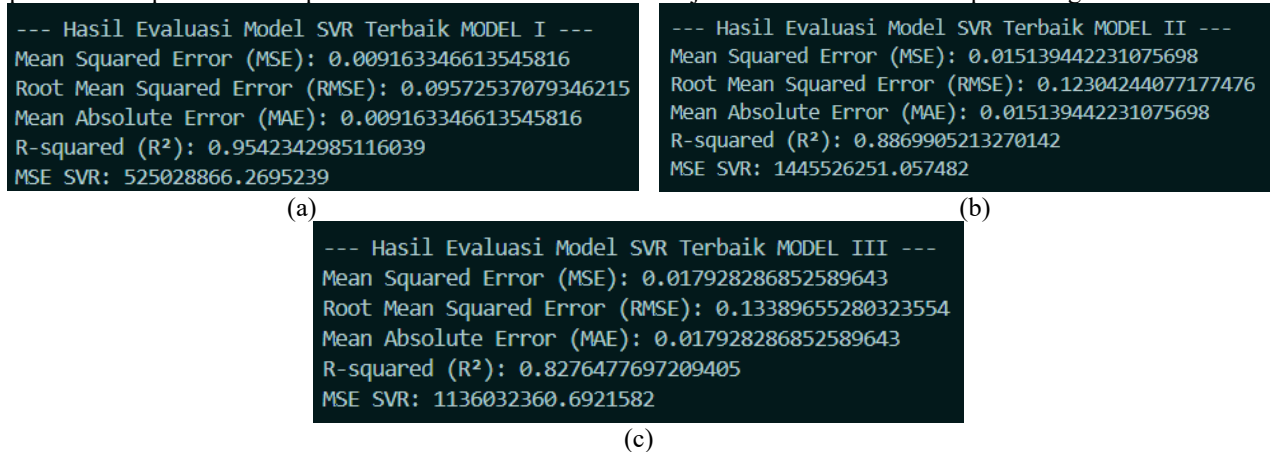
Tabel 1. Hasil Validasi Ketiga Model

Kategori	Prediksi: Tidak Perlu Maintenance	Prediksi: Perlu Maintenance	Total	Precision	Recall	F1-Score
Model 1						
<i>Actual: Tidak Perlu Maintenance</i>	679 (<i>True Negative</i>)	16 (<i>False Positive</i>)	695	0.93	0.91	0.92
<i>Actual: Perlu Maintenance</i>	7 (<i>False Negative</i>)	1808 (<i>True Positive</i>)	1815	0.99	1.00	0.99
Total	686	1824	2510	-	-	-
Akurasi	-	-	-	-	-	0.98
Macro Avg	-	-	-	0.99	0.99	0.99
Weighted Avg	-	-	-	0.99	0.99	0.99
Model 2						
<i>Actual: Tidak Perlu Maintenance</i>	380 (<i>True Negative</i>)	20 (<i>False Positive</i>)	400	0.95	0.95	0.95
<i>Actual: Perlu Maintenance</i>	18 (<i>False Negative</i>)	2092 (<i>True Positive</i>)	2110	0.99	0.99	0.99
Total	398	2112	2510	-	-	-
Akurasi	-	-	-	-	-	0.98
Macro Avg	-	-	-	0.96	0.95	0.96
Weighted Avg	-	-	-	0.98	0.98	0.98

Kategori	Prediksi: Tidak Perlu Maintenance	Prediksi: Perlu Maintenance	Total	Precision	Recall	F1-Score
Model 3						
Actual: Tidak Perlu Maintenance	270 (True Negative)	19 (False Positive)	289	0.93	0.91	0.92
Actual: Perlu Maintenance	26 (False Negative)	2195 (True Positive)	2221	0.99	0.99	0.99
Total	296	2204	2510	-	-	-
Akurasi	-	-	-	-	-	0.98
Macro Avg	-	-	-	0.96	0.95	0.96
Weighted Avg	-	-	-	0.98	0.98	0.98

4.2 Evaluasi Pengujian Dataset Support Vector Regression (SVR)


Pengujian prediktif "remaining unit lifetime" ekskavator menggunakan Support Vector Regression (SVR) menunjukkan bahwa Model I, dengan input *blowby pressure* dan *boost pressure*, mencapai performa terbaik. Model ini menunjukkan akurasi sangat tinggi dengan nilai MSE 0.00916, RMSE 0.0957, MAE 0.00916, dan R² 0.954. Penambahan variabel *engine oil temperature* pada Model II menurunkan akurasi (R² 0.887), dan penambahan *coolant temperature* pada Model III semakin memperburuk performa (R² 0.828). Ini mengindikasikan bahwa Model I adalah yang paling optimal untuk prediksi masa pakai unit. Gambar 2 berikut menunjukkan hasil akurasi SVR pada ketiga model.

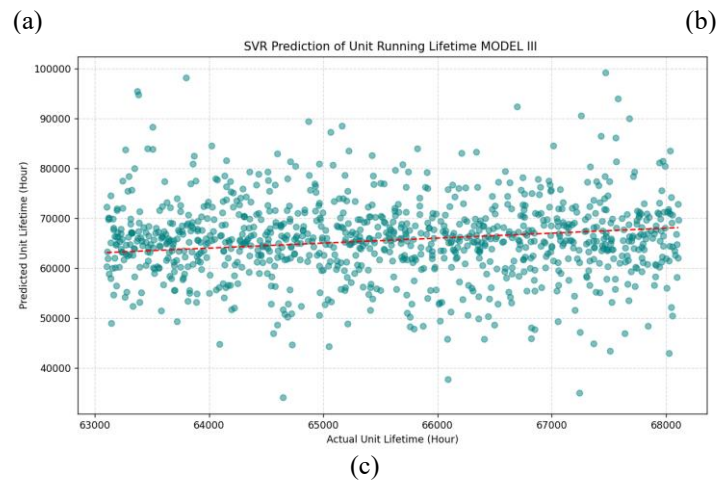


Gambar 2. (a) Hasil Akurasi Support Vector Regression (SVR) Model Pertama; (b) Hasil Akurasi Support Vector Regression (SVR) Model Kedua; (c) Hasil Akurasi Support Vector Regression (SVR) Model Ketiga

4.3 Prediksi Model Support Vector Regression (SVR)

Pengujian tiga model prediksi Unit Lifetime ekskavator menggunakan algoritma Support Vector Regression (SVR) menunjukkan variasi performa. Model I, yang memanfaatkan *Boost Pressure* dan *Blowby Pressure*, berhasil memprediksi hingga 120.000 jam dengan akurasi 95% dan konsistensi pola prediksi yang baik pada rentang 80.000–100.000 jam. Sebaliknya, Model II, yang menambahkan *Engine Oil Temperature*, mampu memprediksi hingga lebih dari 90.000 jam dengan akurasi 88%, namun sebaran prediksi lebih terbatas pada rentang 70.000–80.000 jam. Terakhir, Model III, dengan penambahan *Coolant Temperature*, memprediksi hingga 90.000 jam dengan akurasi 82%, namun rentang prediksi paling sempit, yaitu 60.000–72.000 jam, menunjukkan estimasi waktu pemakaian yang lebih rendah. Berikut merupakan Gambar 3 yang menunjukkan hasil prediksi unit lifetime pada ketiga model.





Gambar 3. (a) Hasil Prediksi Unit *Lifetime* Model Pertama; (b) Hasil Prediksi Unit *Lifetime* Model Kedua; (c) Hasil Prediksi Unit *Lifetime* Model Ketiga

5. Kesimpulan

Penelitian ini berhasil mengembangkan model *machine learning* Support Vector Machines (SVM) untuk mendeteksi dan mengklasifikasikan kerusakan mesin serta menganalisis sisa umur pakai (*remaining useful lifetime*) ekskavator. Model ini menggunakan 5020 data *time-series* yang dikumpulkan dengan alat diagnostik CAT ET 2025A oleh operator bersertifikasi. Hasilnya menunjukkan ekskavator dapat bertahan antara 75.000 hingga 100.000 jam, melebihi data aktual yang hanya mencapai 68.000 jam, yang divisualisasikan dalam *scatter plot*. Evaluasi dengan *R2 score* menunjukkan akurasi signifikan, mencapai 82,76% hingga 95,42% dengan *MAE* 0,00916, membuktikan efektivitas SVM dalam memprediksi data berdasarkan masa penggunaan.

6. Daftar Pustaka

- [1] Moyne, J. (2017). Big Data Analytics for Smart Manufacturing: Case Studies in Semiconductor Manufacturing. *Processes* 2017, 5, 39, 2-20.
- [2] Gunawan, L. (2023). Support vector machine based emotional analysis of restaurant . *Procedia Computer Science* 216 (2023) 479–484, 481.
- [3] Khushbu S. Antala, S. S. (2025). Cost optimization, reliability, and MTTF analysis for failed excavators in hydraulic repair center using queueing theory. *Swarm and Evolutionary Computation* 92 (2025) 101824 , 3.
- [4] Mobley, R. K. (2002). *An Introduction to Predictive Maintenance*. Elsevier: Technology & Engineering. Diambil kembali dari <https://books.google.com.my/books?hl=en&lr=&id=SjqXzxpAzSQC&oi=fn>
- [5] Bell, J. (2014). *Machine Learning: Hands-On for Developers and Technical Professionals*. John Willey & Sons.
- [6] Liyuan Xiao, G. Z. (2025). Real-time and High-precision SVM-RF Based Prediction Model for DOA Estimation. *Journal Pre-proof*, 1.
- [7] Joshi, V. A. (2020). *Machine Learning And Artificial Intelligence*. Springer.
- [8] Iannace, G. C. (2019). Fault Diagnosis for UAV Blades Using Artificial Neural Network. *Robotics*, 9-17. doi:<https://doi.org/10.3390/robotics8030059>
- [9] Husdi. (2023). Penerapan Metode Regresi Linear Untuk Prediksi Jumlah Bahan Baku Produksi Selai Bilfagi . *JURNAL INFORMATIKA*, Vol. 10 No. 2 Oktober 2023, Halaman 129-135 , 131.
- [10] Georgina Cosma. (2017). A survey on computational intelligence approaches for predictive modeling in prostate cancer . G. Cosma et al. / *Expert Systems With Applications* 70 (2017) 1–19 , 5-19.
- [11] Widodo, A. &. (2007). Support Vector Machine in Machine Condition Monitoring And Fault Diagnosis. *Mechanical Systems and Signal Processing* , 2560-2574. doi:<https://doi.org/10.1016/j.ymsp.2006.12.007>
- [12] Schmidta, J. (2025). A texture-dependent yield criterion based on Support Vector Classification. *International Journal of Plasticity* 188 (2025) 104311 , 1-17.
- [13] Zhu, K. (2025). Optimal modeling of fermentation process using hybrid support vector regression. *Journal of Process Control* 150 (2025) 103429, 5-10.
- [14] Sim, J. (2023). Support vector regression for prediction of stable isotopes and trace elements using hyperspectral imaging on coffee for origin verification. *Food Research International* 174(2023) 113518, 3-9.
- [15] Bergmeir, C. (2012). On the use of cross-validation for time series predictor evaluation. C. Bergmeir; J.M. Benítez/*Information Sciences* 191 (2012) 192–213, 192-213. doi:<https://doi.org/10.1016/j.ins.2011.12.028>