

Deteksi dini kerusakan roller bearing menggunakan machine learning pendekatan support vector regression (SVR)

Achmad Widodo^{a,1}, Toni Prahasto^a, Endhy Priambodo^a

^aProgram Studi Teknik Mesin, Universitas Diponegoro, Semarang

¹awidodo2010@gmail.com

ABSTRACT

Bearing adalah sebuah komponen mekanis yang digunakan untuk mengurangi gesekan antara dua komponen yang bergerak relatif satu sama lain. Karena fungsinya, bantalan digunakan pada beragam jenis mesin dan peralatan, seperti pada mesin industri, kendaraan, dan alat berat. Kondisi yang buruk pada bantalan dapat menyebabkan kerusakan pada mesin dan mengurangi umur pemakaian mesin. Oleh karena itu, pemantauan dan perawatan yang tepat pada bantalan sangat penting untuk memastikan kinerja mesin yang optimal dan menghindari kerusakan yang tidak diinginkan. Prediksi potensi terjadinya kegagalan dan menentukan estimasi sisa waktu operasi atau *remaining useful life* (RUL) dari suatu komponen menjadi krusial. Dengan *machine learning*, prediksi ini dapat dilakukan. Dataset bantalan NASA (*National Aeronautics and Space Administration*) digunakan sebagai acuan untuk memprediksi potensi kegagalan. Ekstraksi fitur dari dataset ini digunakan sebagai input algoritma *machine learning*. Menggunakan algoritma *Support Vector Regression* (SVR), 12 model dihasilkan dengan akurasi yang berbeda-beda. *Exponential Moving Average* merupakan model terbaik yang dijadikan acuan dalam memprediksi dataset baru. Model ini dapat digunakan untuk memprediksi potensi kegagalan bantalan lainnya. Perawatan dan perbaikan dapat dilakukan lebih awal guna mencegah terjadinya kerusakan yang lebih parah ketika awal mula kegagalan terdeteksi. Dengan demikian, kerugian lebih dari penggunaan mesin atau peralatan tersebut dapat diantisipasi.

Keywords: Bearing, *machine learning*, RUL, SVR

Diterima 30 September 2023; **Dipresentasikan** 5 Oktober 2023; **Publikasi** 27 Mei 2024

PENDAHULUAN

Bearing merupakan salah satu komponen penting dalam mesin yang berfungsi untuk menopang dan memposisikan poros secara radial pada saat berputar. Kinerja dan efisiensi bearing sangat mempengaruhi keberhasilan pengoperasian sistem dan mekanisme pada sebuah alat [1]. Kegagalan pada *bearing* dalam suatu mesin merupakan salah satu jenis kegagalan yang paling sering dijumpai. Salah satunya pada kegagalan pada *asynchronous motor* dimana 45-55% disebabkan oleh adanya kegagalan pada komponen bearing [2]. Kegagalan pada *bearing* diantaranya terjadi pada bagian *outer-race*, *inner-race*, *roller*, dan *cage*. Kegagalan pada bearing dapat menyebabkan malfungsi atau kerusakan lainnya pada sistem mesin yang berakibat pada terjadinya *downtime* yang lama dan *maintenance cost* yang tinggi [3]. Hal inilah yang mendorong dilakukannya proses prognostik untuk memprediksi potensi terjadinya kegagalan dan menentukan estimasi dari sisa umur efektif

komponen untuk beroperasi sebelum terjadi kegagalan RUL. Prognostik sendiri merupakan bagian dari disiplin ilmu baru yaitu *Prognostics Health Management* (PHM) yang juga menjadi strategi baru dalam bidang *maintenance* mesin maupun komponen mesin [4]. Analisis prognostik, yang juga dikenal sebagai deteksi kerusakan dini, memiliki tiga aspek penting yang perlu diperhatikan. Pertama, penentuan atau penyusunan indikator kesehatan komponen, yang bertujuan untuk mengevaluasi kondisi sistem mesin dan komponen kritisnya saat ini [5]. Hal ini digunakan sebagai dasar untuk memprediksi sisa umur manfaat (RUL). Kedua, prediksi RUL digunakan untuk memperkirakan berapa lama komponen dapat digunakan sebelum mengalami kegagalan. Ketiga, manajemen kesehatan mesin atau komponen digunakan untuk mengoptimalkan kinerja sistem mesin dengan memantau kondisi komponen secara terus-menerus [6].

Dalam analisis prognostik khususnya pada bearing, data merupakan elemen penting yang digunakan untuk mengidentifikasi kondisi

komponen dan melakukan analisis [7]. Data tersebut diperoleh melalui sensor yang dipasang pada alat dan mencatat berbagai variabel dengan interval waktu tertentu. Data kemudian diolah dan disimpan dalam bentuk log atau langsung dikirim ke sistem pengawasan (monitoring) [8]. Terdapat berbagai jenis sensor yang digunakan seperti sensor getaran, suhu, kimia, emisi akustik, dan tekanan suara. Sebelum data dari sensor tersebut digunakan untuk analisis, perlu dilakukan proses pengolahan seperti filtering dan penghilangan noise. Tidak semua data yang diperoleh dari sensor pada bearing digunakan dalam analisis prognostik. Hanya data yang paling signifikan dalam mengindikasikan terjadinya *fault* pada bearing yang dipilih. Proses ini dikenal sebagai *feature selection* [9]. Sebelum melakukan analisis diagnosis dan prognosis, data dari sensor tersebut harus melalui tahap *pre-processing data* terlebih dahulu. Tahap ini melibatkan pengolahan data untuk memastikan kualitas data yang digunakan dalam analisis.

Dalam analisis prognostik yang efektif, pemilihan algoritma yang sesuai dengan karakteristik data dan sistem menjadi langkah penting. Dalam penelitian ini, beberapa pendekatan dan algoritma diterapkan pada data yang sama untuk mengevaluasi hasil analisis yang optimal dengan membandingkan kriteria akurasi. Salah satu pendekatan yang digunakan adalah *Support Vector Regression* (SVR) pada dataset bearing NASA. Metode ini memungkinkan prediksi RUL pada bearing berdasarkan data sensor getaran. Data tersebut telah melalui proses *preprocessing*

sebelum dianalisis menggunakan metode SVR [10]. Pada dataset ini, SVR digunakan untuk menghasilkan model prediksi RUL yang akurat dan dapat diandalkan. Hasil dari analisis menggunakan metode SVR menunjukkan bahwa model tersebut mampu menghasilkan prediksi RUL dengan tingkat akurasi yang tinggi. Selain itu, metode SVR juga memungkinkan untuk melakukan analisis fitur sehingga dapat dipilih fitur-fitur yang paling penting dalam melakukan prediksi RUL pada bearing. Analisis prognostik dengan menggunakan metode SVR pada dataset bearing NASA dapat memberikan informasi yang sangat berharga dalam mengurangi biaya perawatan dan meningkatkan efisiensi dari sistem pemeliharaan mesin.

METODE PENELITIAN

Dalam melakukan analisis prognosis yaitu melakukan prediksi untuk nilai RUL dari bearing NASA, digunakan kumpulan data yang diperoleh secara daring yang dipublikasikan oleh NASA dan pusat Pusat *Intelligent Maintenance Systems* (IMS). Data ini diambil dari 4 buah bearing yang terinstalasi dengan poros yang diberi beban radial sebesar 6000 lbs. Kecepatan putar pada bearing dilakukan dengan konstan pada angka 2000 RPM. Data bearing NASA terbagi menjadi 3 set berdasarkan waktu pengambilan data serta kuantitas dalam pengambilan data. Sensor yang digunakan dalam pengambilan data yaitu PCB 353B33 *High Sensitivity Quartz ICP accelerometers*

Tabel 1. Spesifikasi NASA bearing dataset.

Set 1	Waktu pengambilan data	22 Oktober 2003 - 25 November 2003
	Jumlah sample	2156 sampel
	Jumlah poin	20.480 poin / 1 sampel
	File recording interval	Setiap 10 menit (kecuali 43 sampel pertama, diambil tiap 5 menit.)
Set 2	Waktu pengambilan data	12 Februari 2004 – 19 Februari 2004
	Jumlah sample	984 sampel
	Jumlah poin	20.480 poin / 1 sampel
	File recording interval	Setiap 10 menit
Set 3	Waktu pengambilan data	4 Maret 2004 – 18 April 2004
	Jumlah sample	4448 sampel
	Jumlah poin	20.480 poin / 1 sampel
	File recording interval	Setiap 10 menit

Preprocessing data pada dataset bantalan NASA adalah langkah penting untuk mempersiapkan data mentah dari pengukuran bantalan mesin NASA sebelum digunakan dalam

analisis lebih lanjut. Tujuannya adalah menghilangkan gangguan, meningkatkan kualitas data, mengurangi kebisingan, dan memformat data agar sesuai untuk analisis. Langkah-langkahnya melibatkan impor data ke

lingkungan pemrograman seperti Python, memahami struktur dan format data, membersihkan data dengan mengidentifikasi dan menghapus duplikat, mengganti nilai yang hilang atau kosong, serta menangani nilai ekstrem atau outlier yang tidak realistis.

Exploratory Data Analysis (EDA) adalah tahap dalam analisis dataset bantalan NASA yang bertujuan untuk memahami, menganalisis, dan mengeksplorasi data dengan mendalam. EDA membantu mengidentifikasi pola, hubungan, anomali, dan wawasan menarik dalam dataset tersebut. Setelah *preprocessing* data dari format (.mat) selesai, langkah selanjutnya adalah ekstraksi fitur. Proses ekstraksi fitur ini menghasilkan 12 fitur getaran yang merepresentasikan sinyal getaran yang tercatat oleh sensor accelerometer. Fitur-fitur tersebut mencakup Rata-Rata Absolut, Standar Deviasi (STD), Skewness, Kurtosis, Entropi, Root Mean Square (RMS), Maksimum Absolut, *Peak to Peak* (P2P), Faktor Puncak, *Clearance Factor*, *Shape Factor*, dan Impuls.

Pembuatan set time feature pada dataset bantalan NASA melibatkan ekstraksi informasi waktu dari data sensor bantalan dengan tujuan memantau pola dan tren seiring waktu. Dataset dengan jumlah data yang lebih besar cenderung memberikan representasi yang lebih akurat tentang kondisi bantalan mesin, meningkatkan kepercayaan statistik, dan akurasi hasil analisis. Oleh karena itu, pemilihan Dataset 3 dari NASA

$$Mon(X) = \left| \frac{no. of \frac{d}{dx} > 0}{n-1} - \frac{no. of \frac{d}{dx} < 0}{n-1} \right| \quad (1)$$

$$Tren(X) = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{[n\sum x^2 - (\sum x)^2][n\sum y^2 - (\sum y)^2]}} \quad (2)$$

Dalam penelitian ini, fitur terbaik yang diambil dari data getaran bantalan NASA dipilih menggunakan metrik *monotonicity* dan *trendability*. Namun, nilai-nilai pada fitur-fitur tersebut memiliki tingkat *noise* yang tinggi, sehingga tren dalam data tidak terlihat dengan jelas. Oleh karena itu, dilakukan proses *smoothing* atau penghalusan nilai fitur dengan menggunakan empat algoritma *smoothing* berbeda, yaitu *Gaussian Smoothing* dan *Exponential Moving Average*.

Bearing Dataset, yang memiliki jumlah data terbanyak, adalah langkah yang tepat untuk mengoptimalkan analisis dan pemahaman tentang performa dan kondisi bantalan mesin. Data awal disimpan dalam format (.mat), kemudian diekstraksi fiturnya dan disimpan dalam format (.csv) untuk analisis lebih lanjut.

Dalam analisis prognosis pada dataset bantalan NASA, pemilihan fitur yang tepat memiliki peran krusial dalam menentukan akurasi analisis, terutama dalam memprediksi nilai RUL. Lebih banyak fitur tidak selalu berarti hasil yang lebih baik, terutama jika tidak semua fitur relevan dalam menggambarkan degradasi bantalan NASA. Oleh karena itu, perlu memilih fitur yang paling berpengaruh dalam analisis prognosis, yang disebut sebagai indikator kesehatan bantalan NASA.

Pemilihan fitur terbaik menggunakan dua metrik yaitu *monotonicity* (Mon) untuk mengukur tren dalam nilai fitur dan *trendability* (Rob) untuk mengukur ketahanan nilai fitur terhadap outliers. Proses ini melibatkan dekomposisi fitur menjadi tren rata-rata dan bagian acak dengan menggunakan metode pemulusan. Nilai kebaikan fitur dihitung dengan persamaan tertentu, dengan menggunakan nilai parameter 0.5 untuk *monotonicity* dan 0.3 untuk *trendability*. Hal ini membantu memilih fitur-fitur yang paling relevan dan signifikan dalam analisis prognosis bantalan NASA.

Proses *smoothing* bertujuan mengurangi noise pada fitur agar tren dalam data menjadi lebih terlihat. Hasil *smoothing* disajikan dalam grafik yang membandingkan nilai asli fitur dengan nilai setelah *smoothing*. Data digunakan untuk fitur terbaik sebelum *smoothing* dan dua metode *smoothing* dibagi menjadi data train (40% dari total, rentang hari 1-20) dan data test (60%, rentang hari 21-46) untuk pelatihan dan pengujian model.

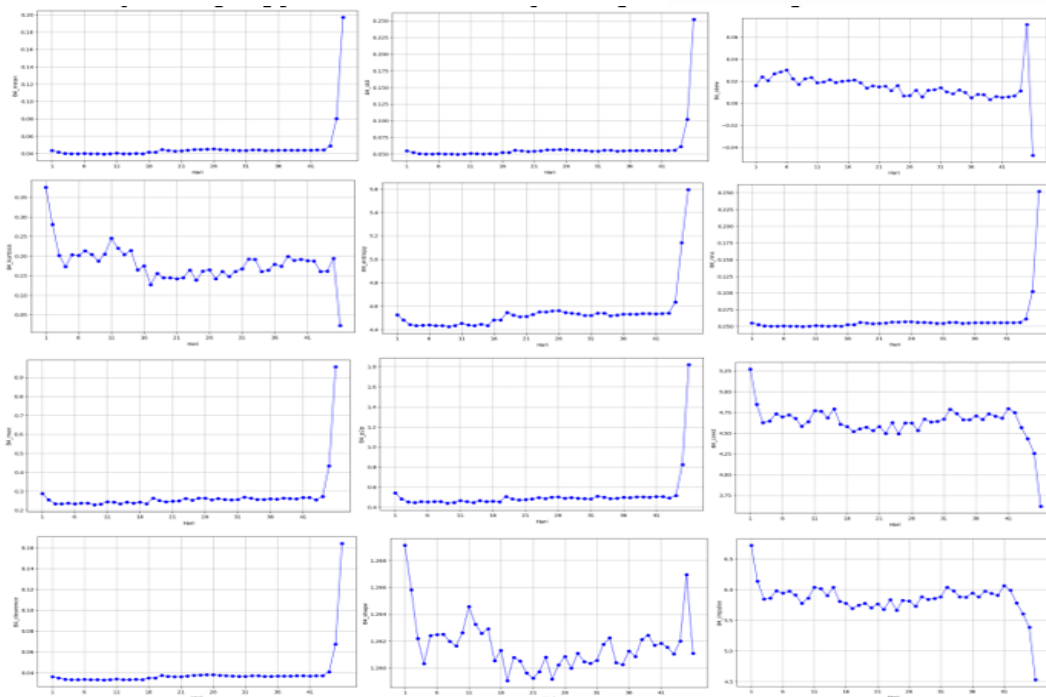
Tujuan dari pembagian data ini adalah untuk memastikan bahwa model yang dibangun dapat melakukan prediksi dengan akurat pada data baru. Data train digunakan untuk menghitung koefisien yang digunakan dalam standarisasi nilai fitur dan juga *Principal Component Analysis*. Data train mewakili data operasional sebelumnya dari bearing NASA yang berfungsi normal. Data test, di sisi lain, mencerminkan performa bantalan NASA yang sedang diuji, dengan kondisi yang tidak diketahui. Hal ini memungkinkan pengujian model pada situasi yang lebih mirip dengan keadaan sebenarnya.

Sebelum melanjutkan analisis, fitur-fitur yang telah dipilih perlu mengalami penyesuaian skala dan standarisasi. Penyesuaian skala mengubah rentang nilai fitur tanpa mengubah distribusinya, sementara standarisasi mengubah nilai fitur sehingga memiliki standar deviasi distribusi bernilai satu. Untuk memastikan hasil analisis yang akurat, dilakukan proses standarisasi dan penyesuaian skala pada fitur-fitur yang telah dipilih sebelum melakukan prognosis dan pembuatan model. Untuk melakukan hal ini, digunakan fungsi *StandardScaler* dari library *Scikit-learn*. Fungsi ini membantu menghilangkan perbedaan rentang nilai pada fitur-fitur yang memiliki karakteristik input yang berbeda.

Dalam analisis prognosis pada data getaran bantalan NASA, digunakan enam fitur terbaik yang telah dipilih dari data getaran. Fitur-fitur ini kemudian mengalami dua tahap proses, yaitu standarisasi nilai dan *Principal Component Analysis* (PCA). Proses PCA menghasilkan dua komponen, tetapi hanya satu komponen PCA yang digunakan karena dianggap mampu dengan baik merepresentasikan data asli. Untuk menilai kinerja setiap model dalam memprediksi nilai RUL, digunakan perhitungan skor dengan menggunakan *Root Mean Square Error* (RMSE) dan Koefisien Determinasi (R^2). Nilai RMSE mencerminkan sejauh mana performa model dalam melakukan prediksi, di mana semakin kecil nilai RMSE menunjukkan performa yang lebih baik. Rumus RMSE dan Koefisien Determinasi digunakan sebagai indikator evaluasi kualitas prediksi model.

HASIL DAN PEMBAHASAN

Dari hasil seluruh perhitungan statistik yang dilakukan pada data getaran bearing, diperoleh hasil sebanyak 12 fitur dengan total 46 data untuk setiap fitur menurut jumlah hari pengambilan data. Hasil perhitungan statistik fitur dari data vibrasi bantalan disajikan langsung pada Gambar 1, dimana perhitungan statistik menghasilkan 12 fitur



Gambar 1. Grafik hasil ekstraksi fitur dari data getaran bearing secara langsung.

Proses ekstraksi fitur yang dilakukan pada data getaran bearing menghasilkan 12 fitur yang kemudian dilakukan pemilihan fitur dengan menggunakan kombinasi dari dua metrik yaitu *monotonicity*, dan *trendability* dengan nilai beban metrik yang telah ditentukan masing-masing. Tabel 6 menunjukkan hasil perhitungan fitur terbaik dan dari perhitungan tersebut dipilih enam yang terbaik untuk digunakan sebagai indikator kesehatan dari bearing.


Dari Tabel 2 yang menunjukkan hasil perhitungan kualitas fitur yang diekstraksi sebagai fitur untuk memprediksi nilai RUL bearing adalah enam fitur teratas, sehingga enam fitur terbaik yang dipilih untuk digunakan untuk analisis lebih lanjut adalah impulse, faktor puncak, entropi, *Peek to Peek*, faktor bentuk, dan maksimum absolut.

Tabel 2. Hasil Perhitungan Nilai Keباikan Fitur Sebagai Indikator Kesehatan

Fitur	Monotonicity	Trendability	Goodness Metric
Impulse	0.048600	0.991748	0.520174
Faktor Puncak	0.036747	0.992142	0.514444
Entropi	0.025976	0.996074	0.511025
Peek to Peek	0.030711	0.969426	0.500068
Root Mean Square	0.000224	0.999586	0.499905
Maksimum Absolut	0.016178	0.968394	0.492286
Faktor Shape	0.004503	0.965527	0.485015
Standard Deviasi	0.004505	0.965462	0.484983
Rata-Rata Absolut	0.003501	0.966022	0.484761
Faktor Clearance	0.002911	0.966249	0.484580
Kurtosis	0.007844	0.951438	0.479641
Skewness	0.002640	0.874478	0.438559

Proses *smoothing* dua metode untuk fitur terpilih terbaik menghasilkan nilai fitur dengan noise atau variasi lebih sedikit dari nilai aslinya. Hal ini terlihat dari grafik hasil proses *smoothing* yang menunjukkan kehalusan dari data getaran bearing

yang lebih jelas pada grafik dibandingkan sebelum dilakukan *smoothing*. Pada Gambar 2. menunjukkan hasil proses *smoothing* pada fitur terbaik dengan metode *Gaussian Smoothing* dan *Exponential Moving Average*.




Gambar 2. Hasil proses *Smoothing* pada salah satu fitur terbaik dengan Metode *Gaussian Smoothing* dan *Exponential Moving Average*.

Model *Support Vector Regression* (SVR) dibangun menggunakan enam fitur terbaik yang dipilih dari total 12 fitur yang telah diekstraksi dari data getaran bantalan. Ada dua variasi utama, yaitu model SVR tanpa PCA dan dengan PCA. Pada variasi tanpa menggunakan PCA, delapan fitur tersebut dihaluskan untuk mengurangi noise, kemudian semua fitur distandarisasi dan diskalakan menggunakan *StandardScaler*. Kinerja model dievaluasi dengan menghitung *Root Mean Square Error* (RMSE)


dan koefisien determinasi (R²). Prediksi RUL oleh model dengan input tanpa proses *smoothing* ditampilkan pada Gambar 5. Pada model dengan kernel linier, model berhasil mencapai nilai RUL = 0 pada hari ke 44 sehingga model memprediksikan bearing memiliki RUL selama 3 hari. Sedangkan pada model optuna hasil prediksi menyentuh nilai RUL = 0 pada hari ke 44. Dari hasil tersebut, model yang dioptimalkan memprediksi bahwa bantalan akan memiliki Nilai dari 3 hari. Hasil keduanya memiliki kemiripan.

Prediksi RUL oleh model dengan Gaussian smoothing ditampilkan pada Gambar 6. Pada hasil prediksi, model kernel linear berhasil mencapai nilai $RUL=0$ pada hari ke 43 sehingga model memprediksikan bearing memiliki RUL selama 2 hari. Sama halnya dengan model kernel linear, model optuna pun memprediksi nilai $RUL=0$ pada hari ke 43. Hasil keduanya memiliki kemiripan


Prediksi RUL oleh model dengan input menggunakan proses *smoothing* metode *Exponential Moving Avarage* ditampilkan pada Gambar 7. Kedua model yang terbentuk mampu mendeteksi terjadinya kerusakan bantalan karena hasil prediksi yang mencapai nilai $RUL=0$ pada hari ke 45 sehingga model memprediksikan bearing memiliki RUL selama 4 hari. Dan hasil model kernel linear maupun optuna memiliki kemiripan



Gambar 3. Hasil prediksi nilai RUL tanpa proses *smoothing* menggunakan (a) kernel linier (b) optuna



Gambar 4. Hasil Prediksi Nilai RUL dengan Input Enam Fitur Terbaik dengan Proses *Smoothing* Menggunakan Metode *Gaussian Smoothing* dengan Model (a) Kernel Linier (b) optuna



Gambar 5. Hasil Prediksi Nilai RUL dengan Input Enam Fitur Terbaik dengan Proses *Smoothing* Menggunakan Metode *Exponential Moving Avarage* dengan Model (a) Kernel Linier (b) optuna

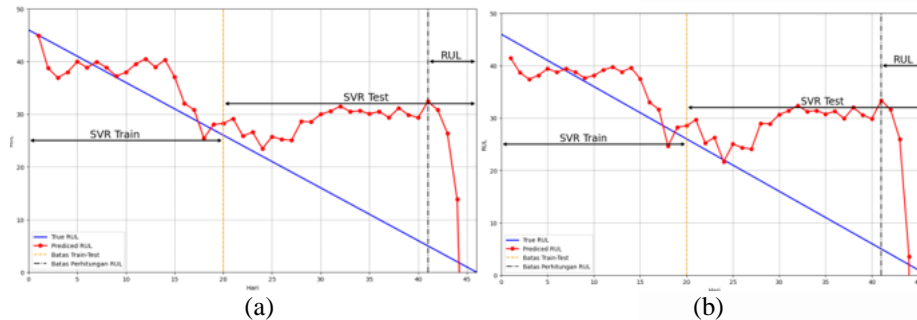
Gambar 6 menunjukkan prediksi RUL oleh model dengan input satu komponen PCA dari enam fitur terbaik tanpa proses *smoothing*. Untuk model dengan kernel linier dan parameter terbaik, hasil prediksi mencapai $RUL = 0$ pada hari ke 44. Sehingga model memiliki RUL selama 3 hari.

Pada model optuna memprediksi $RUL=0$ pada hari ke 44. Sehingga model memiliki RUL selama 3 hari. Sehingga model kernel linear maupun optuna memiliki prediksi yang hampir mirip.


Gambar 7 menunjukkan prediksi RUL Gaussian Smoothing yang mana kedua model yang

dibentuk mampu mendeteksi terjadinya kegagalan bantalan karena prediksinya mencapai RUL=0. Namun, kedua model menghasilkan RUL yang diprediksi lebih rendah nilai dari nilai sebenarnya. Dengan menggunakan input yang diambil dengan proses smoothing, prediksi model yang dihasilkan memiliki fluktuasi yang lebih kecil dibandingkan tanpa smoothing. Model dengan parameter terbaik memiliki kinerja lebih baik Gambar 8 menunjukkan


prediksi RUL oleh model dengan input satu komponen PCA dari enam fitur terbaik tanpa proses smoothing. Untuk model dengan kernel linier dan parameter terbaik, hasil prediksi mencapai RUL = 0 pada hari ke 44. Sehingga model memiliki RUL selama 3 hari. Pada model optuna memprediksi RUL= 0 pada hari ke 44. Sehingga model memiliki RUL selama 3 hari. Sehingga model kernel linear maupun optuna memiliki prediksi yang hampir mirip.



Gambar 6. Hasil Prediksi Nilai RUL dengan Input Satu Komponen PCA dari Enam Fitur Terbaik Tanpa Proses *Smoothing* dengan Model (a) Kernel Linier (b) optuna.



Gambar 7. Hasil Prediksi Nilai RUL dengan Input Satu Komponen PCA dari Enam Fitur Terbaik dengan Proses *Smoothing* Metode *Gaussian Smoothing* dengan Model (a) Kernel Linier (b) optuna



Gambar 8. Hasil Prediksi Nilai RUL dengan Input Satu Komponen PCA dari Enam Fitur Terbaik dengan Proses *Smoothing* Metode *Exponential Moving Avarage* dengan Model (a) Kernel Linier (b) optuna

Ringkasan hasil prediksi RUL ditampilkan pada Tabel 3 sebagai berikut.

Tabel 3 Hasil prediksi RUL bearing.

Variasi Model	RMSE Train	RMSE Test	RUL (hari)
Model SVR Linear tanpa proses <i>Smoothing</i>	3,75	39,26	3
Model SVR Optuna tanpa proses <i>Smoothing</i>	4,19	28,54	3
Model SVR PCA Linear tanpa proses <i>Smoothing</i>	5,95	21,13	5
Model SVR PCA Optuna tanpa proses <i>Smoothing</i>	5,54	21,13	5
Model SVR Linear dengan proses <i>Gaussian Smoothing</i>	1,11	15,29	2
Model SVR Optuna dengan proses <i>Gaussian Smoothing</i>	1,15	15,37	2
Model SVR PCA Linear dengan proses <i>Gaussian Smoothing</i>	5,33	34,78	0
Model SVR PCA Optuna dengan proses <i>Gaussian Smoothing</i>	5,37	34,81	0
Model SVR Linear dengan proses <i>Exponential Moving Avarage</i>	3,28	21,79	4
Model SVR Optuna dengan proses <i>Exponential Moving Avarage</i>	3,24	20,68	4
Model SVR PCA Linear dengan proses <i>Exponential Moving Avarage</i>	4,11	24,76	3
Model SVR PCA Optuna dengan proses <i>Exponential Moving Avarage</i>	4,12	24,63	3

KESIMPULAN

Prediksi RUL dengan model SVR menghasilkan nilai yang cukup realistis maksimal 5 hari sisa umur bearing. Namun dari test data menghasillkan RMSE yang masih tinggi. Hal ini dimungkinkan masih terjadi *overfitting* pada model sehingga perlu diperbaiki lagi dengan menambah jumlah data training. Proses training dengan data sampai pada hari ke-20 belum bisa melatih SVR untuk mendeteksi adanya degradasi yang dimulai pada hari ke-40.

DAFTAR PUSTAKA

- [1] Sukendi, I. Isranuri, and Suherman, "Analisa Karakteristik Getaran Dan Machine Learning Untuk Deteksi Dini Kerusakan Bearing," *Widya Tek.*, vol. 23, no. 2, pp. 41–49, 2015.
- [2] Y. Meng *et al.*, "Application of Machine Learning in Industrial Boilers: Fault Detection, Diagnosis, and Prognosis," *ChemBioEng Rev.*, vol. 8, no. 5, pp. 535–544, 2021, doi: 10.1002/cben.202100008.
- [3] C. Cheng *et al.*, "Online Bearing Remaining Useful Life Prediction Based on a Novel Degradation Indicator and Convolutional Neural Networks," pp. 1–12, 2018, doi: 10.1109/TMECH.2020.2971503.
- [4] D. D. Susilo, A. Widodo, T. Prahasto, and M. Nizam, "Fault diagnosis of roller bearing using parameter evaluation technique and multi-class support vector machine," *AIP Conf. Proc.*, vol. 1788, 2017, doi: 10.1063/1.4968334.

- [5] C. C. Molano, J. Strozzi, M. Rubini R., and M. Cocconcelli, "Analysis of NASA Bearing Dataset of the University of Cincinnati by means of Hjorth's Parameters," *Int. Conf. Struct. Eng. Dyn. ICEDyn*, 2019.
- [6] Y. Lei, N. Li, L. Guo, N. Li, T. Yan, and J. Lin, "Machinery health prognostics: A systematic review from data acquisition to RUL prediction," *Mech. Syst. Signal Process.*, vol. 104, pp. 799–834, 2018, doi: 10.1016/j.ymsp.2017.11.016.
- [7] X. Guan and Y. Liu, "Bayesian Analysis for Fatigue Damage Prognostics and Remaining Useful Life Prediction," *Mach. Learn. Knowl. Discov. Eng. Syst. Heal. Manag.*, no. November, pp. 203–243, 2012, doi: 10.1201/b11580-7.
- [8] K. Javed, "based on extreme learning machine and fuzzy clustering . Thèse de Doctorat," 2014.
- [9] C. Yang, J. Ma, X. Wang, X. Li, Z. Li, and T. Luo, "A novel based-performance degradation indicator RUL prediction model and its application in rolling bearing," *ISA Trans.*, vol. 121, no. xxxx, pp. 349–364, 2022, doi: 10.1016/j.isatra.2021.03.045.
- [10] A. Soualhi, K. Medjaher, and N. Zerhouni, "Bearing health monitoring based on hilbert-huang transform, support vector machine, and regression," *IEEE Trans. Instrum. Meas.*, vol. 64, no. 1, pp. 52–62, 2015, doi: 10.1109/TIM.2014.2330494.