

Diagnosis Kerusakan *Boiler Feed Pump* Berbasis Integrasi *Deep Learning* dan *Sistem Expert* pada Industri Pembangkit Listrik

Habib Muhajir^a, Toni Prahasto^a, Achmad Widodo^{a*}

^aDepartemen Teknik Mesin, Fakultas Teknik, Universitas Diponegoro
Jl. Prof. Sudharto, SH, Tembalang, Semarang 50275

*E-mail: achmadwidodo@lecturer.undip.ac.id

Abstract

The advancement of technology in the era of Industry 4.0 has driven a paradigm shift from descriptive maintenance toward prescriptive maintenance. This study presents a part of a prescriptive maintenance framework designed to diagnose faults in boiler feed pumps within power plant industries. The proposed framework focuses on fault diagnosis and providing maintenance recommendations to enhance operational reliability. The approach employs a deep learning-based anomaly detection scheme using a Long Short-Term Memory Autoencoder (LSTM-AE). When anomalies are detected, the fault types are classified using expert-defined diagnostic rules that correlate abnormal operational parameters with specific fault categories and corresponding corrective recommendations. The proposed model effectively learns the temporal patterns of multivariate sensor data and demonstrates excellent reconstruction performance, achieving R^2 values between 0.92 and 0.99 with low Mean Squared Error (MSE) across all operational parameters. Experimental results show that the integration of deep learning based anomaly detection with expert knowledge based diagnostic rules provides a practical and effective approach toward implementing prescriptive maintenance in industrial environments.

Keywords: prescriptive maintenance, boiler feed pump, long short-term memory autoencoder, fault diagnosis

Abstrak

Perkembangan teknologi dalam era Industri 4.0 telah mendorong pergeseran paradigma dari pemeliharaan deskriptif menuju pemeliharaan preskriptif. Penelitian ini menyajikan bagian dari kerangka kerja *prescriptive maintenance* yang dirancang untuk mendiagnosis kerusakan *boiler feed pump* pada industri pembangkit listrik. Kerangka kerja yang diusulkan berfokus pada diagnosis kerusakan, serta pemberian rekomendasi tindakan guna meningkatkan keandalan operasional. Pendekatan ini menggunakan kerangka deteksi anomali berbasis *deep learning* menggunakan *Long Short-Term Memory Autoencoder* (LSTM-AE). Ketika anomali terdeteksi, jenis kerusakan diklasifikasikan menggunakan aturan diagnosis yang dikembangkan oleh para *expert* yang mengorelasikan parameter operasi yang anomali dengan jenis kerusakan beserta rekomendasi. Model yang diusulkan mampu mempelajari pola temporal dari data sensor multivariat secara efektif dan menunjukkan kemampuan rekonstruksi yang sangat baik dengan nilai R^2 antara 0.92–0.99 dan *Mean Squared Error* (MSE) yang rendah pada seluruh parameter operasi. Berdasarkan eksperimen menunjukkan bahwa integrasi antara deteksi anomali berbasis *deep learning* dan aturan diagnosis berbasis pengetahuan *expert* merupakan langkah praktis dan efektif menuju penerapan *prescriptive maintenance* di lingkungan industri.

Kata kunci: *prescriptive maintenance*, boiler feed pump, long short-term memory autoencoder, diagnosis kerusakan

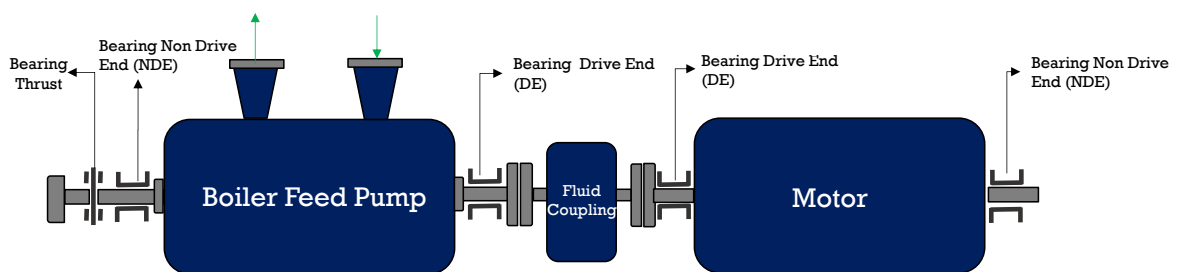
1. Pendahuluan

Boiler feed pump merupakan peralatan penting dalam sistem pembangkit listrik yang berfungsi untuk memasok air ke boiler dan termasuk salah satu pompa dengan daya terbesar dibandingkan dengan pompa lainnya [1]. Sistem kontrol industri modern mengelola data deret waktu multivariat yang terdiri atas berbagai sinyal saling berkaitan yang berasal dari sensor dan aktuator [2]. *Fault Detection and Diagnosis* (FDD) memiliki potensi besar untuk meningkatkan keandalan dan kestabilan proses industri, dengan tujuan utama mengurangi kerugian produksi sekaligus menjamin keselamatan personel dan peralatan [2]. FDD mengidentifikasi permasalahan pada peralatan penting melalui eksplorasi data historis sehingga memungkinkan pemberian peringatan dini kepada operator [3]. Perkembangan teknologi seperti *cloud computing*, jaringan nirkabel, dan sistem tertanam (*embedded systems*) mendorong kemajuan sistem FDD generasi berikutnya [4].

Berbagai metode telah diajukan untuk ekstraksi fitur dan klasifikasi guna mendeteksi serta menganalisis kerusakan pada pompa maupun peralatan rotari lainnya [5]. Metode seperti CNN-LSTM [6], variational autoencoder (VAE) [7], dan one-class SVM [8] pernah digunakan untuk menganalisis sinyal getaran dan parameter operasi mesin. Namun, sebagian besar penelitian sebelumnya memiliki kekurangan seperti akurasi deteksi yang menurun pada kondisi beban variatif, model *overfitting* akibat ketidakseimbangan data antara kondisi normal dan rusak yang jarang terjadi dan asumsi bahwa pompa beroperasi pada kecepatan konstan sehingga kurang representatif untuk *boiler feed pump* (BFP) dengan *variable speed*. Beberapa studi seperti Zhang, dkk. [9] dan Li, dkk. [10] menunjukkan bahwa perubahan kecepatan putaran secara signifikan menggeser karakteristik sinyal getaran, menyebabkan model FDD berbasis *deep learning* menjadi kurang stabil pada peralatan dengan *variable speed drive* (VSD).

Meskipun *Long Short-Term Memory Autoencoder* (LSTM-AE) bukanlah metode baru dalam bidang deteksi anomali, penerapannya pada BFP dengan *variable speed* memiliki kontribusi praktis yang signifikan karena model ini mampu mempelajari pola normal pada rentang putaran yang dinamis, sehingga lebih adaptif dibandingkan metode konvensional yang hanya stabil pada putaran tetap. Nilai kebaruan penelitian ini terletak pada pengembangan kerangka kerja terintegrasi untuk memproses data multivariat BFP yang beroperasi secara variabel, serta integrasi hasil deteksi anomali dengan proses justifikasi dan validasi diagnosis oleh expert untuk tiga jenis kerusakan utama meliputi *local bearing*, *cooling loss*, dan *axial position*.

Untuk mendukung diagnosis *real time* secara cepat dan akurat, penelitian ini mengusulkan arsitektur LSTM-AE yang diimplementasikan menggunakan *Python* untuk mendeteksi anomali secara otomatis, yang selanjutnya diteruskan ke proses klasifikasi berbasis pengetahuan *expert* [11]. Adapun skema dan spesifikasi mengenai *boiler feed pump* dapat dilihat pada Gambar 1 dan Tabel 1.



Gambar 1. Skema boiler feed pump

Table 1. Spesifikasi boiler feed pump

Kapasitas	Head	Speed	Shaft Power	Efficiency
263 m ³ /h	1527 m	2900 rpm	1310 kW	77%

2. Material dan metode penelitian

2.1 Data penelitian


Data penelitian diperoleh dari *Supervisory Control and Data Acquisition* (SCADA) untuk mendapatkan data parameter operasi pompa yang didukung dengan data lainya seperti catatan operasi, hasil inspeksi pompa, *Computerized Maintenance Management System* (CMMS), *Failure Mode and Effect Analysis* (FMEA), *Root Cause Failure Analysis* (RCFA), *manual book*, dan *operation record* yang digunakan ahli untuk merumuskan aturan diagnosis. Periode pengambilan data adalah selama enam bulan, yaitu 1 Oktober 2023 hingga 31 Maret 2024 dan objek penelitian ini adalah *boiler feed pump* pada pembangkit listrik tenaga dengan kapasitas 110 MW pada PLTU Teluk Balikpapan, Indonesia. Parameter operasi yang digunakan terdiri dari 12 variabel sensor aktif yang digunakan untuk membangun model deteksi kerusakan dan diagnosis kerusakan.

2.2 Metode penelitian

Metode penelitian ini menggunakan pendekatan berbasis *deep learning* berbasis LSTM-Autoencoder untuk mendeteksi anomali parameter operasi yang selanjutnya berdasarkan anomali tersebut akan dianggap sebagai indikasi kerusakan dan akan diklasifikasikan jenis kerusakanya, *severity*-nya dan rekomendasinya oleh ahli berdasarkan aturan diagnosis yang telah disusun. Sehingga, melalui hasil tersebut, dapat tercipta *prescriptive maintenance* yang mampu membantu memberikan keputusan otomatis untuk mencegah kerusakan melalui langkah *maintenance* yang optimal [12].

Sedangkan alur yang disusun dalam implelementasi pelaksanaan penelitian dapat dilihat pada Gambar 2. Penelitian ini dimulai dengan akuisisi data dari sistem SCADA, mencakup parameter utama operasi *boiler feed pump*. Data yang diperoleh kemudian melalui proses pembersihan dan pra-pemrosesan, termasuk *re-sampling*, normalisasi, dan transformasi ke format tiga dimensi agar sesuai dengan kebutuhan model LSTM. Selanjutnya dilakukan pembangunan model *train LSTM-Autoencoder* untuk merekonstruksi pola operasi normal pompa. Model *train* dilakukan evaluasi menggunakan metrik *Mean Squared Error* (MSE) dan R^2 guna menilai akurasi rekonstruksi model

[13]. Tahap berikutnya adalah penentuan ambang batas (*threshold*) menggunakan pendekatan statistik berdasarkan nilai rata-rata kesalahan rekonstruksi ditambah $k \cdot \sigma$. Ambang ini digunakan untuk mendeteksi anomali pada data operasi aktual. Titik data dengan eror di atas *threshold* diidentifikasi sebagai indikasi potensi anomali. Hasil deteksi tersebut kemudian divalidasi menggunakan data historis dan umpan balik dari *engineer* pembangkit untuk memastikan keakuratan indikasi anomali. Setelah validasi, dilakukan pengembangan *diagnose rule* berbasis *expert*, yang mengklasifikasikan jenis kerusakan ke dalam tiga kategori utama, yaitu *local bearing fault*, *cooling loss*, dan *axial position deviation*. Tahapan akhir meliputi klasifikasi dan pemberian rekomendasi tindakan korektif serta integrasi hasil diagnosis ke dalam sistem *prescriptive maintenance*, sehingga sistem mampu memberikan peringatan dini dan panduan pemeliharaan proaktif terhadap potensi kerusakan BFP.

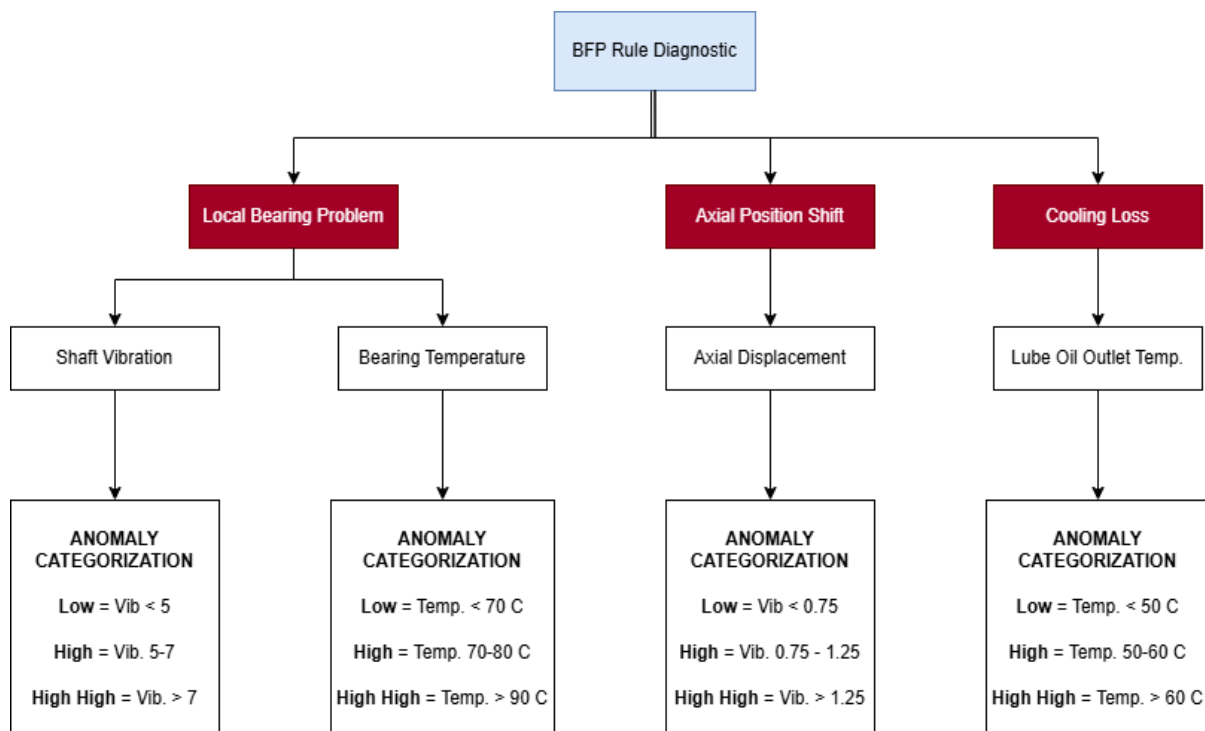


Gambar 2. Alur penelitian diagnosis kerusakan boiler feed pump

3. HASIL DAN PEMBAHASAN

3.1 Pengembangan Model diagnosis Berbasis Aturan

Model diagnosis dibangun dengan menggabungkan sistem *expert* dan *deep learning* untuk mendeteksi serta mengklasifikasikan jenis kerusakan pada boiler feed pump. Aturan diagnosis dan rekomendasi terlihat pada Gambar 3. Gambar 3 memperlihatkan diagram aturan diagnosis (BFP Rule Diagnostic) yang berfungsi untuk mengidentifikasi jenis kerusakan pada boiler feed pump berdasarkan anomali parameter operasi. Terdapat tiga jenis kerusakan yang dideteksi, yaitu *local bearing problem*, *axial position shift*, dan *cooling loss*. Sensor vibrasi shaft dan temperatur bearing digunakan untuk mendeteksi gangguan *local bearing*, sensor *axial displacement* digunakan untuk mendeteksi gangguan *axial position shift*, sedangkan sensor temperatur pelumas digunakan untuk mendeteksi gangguan *cooling loss*. Setiap parameter dibandingkan dengan nilai ambang batas yang ditetapkan berdasarkan hasil analisis model LSTM-AE dan pengalaman pakar [14]. Apabila nilai parameter melebihi batas normal, sistem mengidentifikasi anomali dan menentukan tingkat keparahan (*severity level*) yang dikategorikan menjadi rendah, sedang, dan tinggi. Berdasarkan hasil tersebut, sistem kemudian memberikan klasifikasi jenis kerusakan beserta rekomendasi tindakan korektif yang sesuai untuk mendukung keputusan pemeliharaan preskriptif.



Gambar 3. Aturan diagnosis boiler feed pump

Tabel 2 menampilkan aturan diagnosis dan rekomendasi untuk boiler feed pump berdasarkan hasil deteksi anomali pada tiga jenis potensi kerusakan utama, yaitu *local bearing problem*, *cooling loss*, dan *axial position deviation*. Setiap

kategori menampilkan korelasi sensor gangguan terkait yang mengindikasikan parameter operasi pompa yang dipantau, kondisi yang menunjukkan adanya peningkatan nilai (\uparrow), dibandingkan ambang batas normal akan dianggap sebagai anomali atau indikasi kersuakan dan akan muncul pesan preskriptif atau rekomendasi tindakan yang harus dilakukan. Pada bagian *local bearing problem*, parameter yang dipantau mencakup *shaft vibration* di sisi *drive end* dan *non-drive end* serta temperatur *bearing*. Secara keseluruhan, tabel ini berfungsi sebagai panduan preskriptif berbasis *rule expert*, di mana sistem tidak hanya mendeteksi anomali, tetapi juga memberikan pesan tindakan korektif yang dapat langsung diimplementasikan untuk mencegah kegagalan dan mendukung strategi *prescriptive maintenance* di pembangkit listrik.

Tabel 2. Aturan diagnosis dan *prescriptive message*/ rekomendasi

Gangguan	Korelasi sensor	Anomali	<i>Prescriptive Message</i> /Rekomendasi
Local Bearing	<i>Shaft Vibration</i> DE X	\uparrow	1. Monitoring trending kenaikan vibrasi dan temperature <i>bearing</i>
	<i>Shaft Vibration</i> DE Y	\uparrow	2. Pengecekan pompa di lokal untuk memastikan apakah terdapat <i>abnormal sound</i> dan memastikan keamanan operasi
	<i>Shaft Vibration</i> NDE X	\uparrow	3. Pengaturan sisi operasi pada kurva pengoperasian pompa yang aman dan vibrasi yang stabil
	<i>Shaft Vibration</i> NDE Y	\uparrow	4. Koordinasi dengan <i>engineer</i> CBM untuk melakukan analisis vibrasi lebih lanjut untuk melihat spektrum vibrasi
	Temperatur <i>Bearing Motor</i> NDE	\uparrow	5. Penjadwalan pemeliharaan sesuai hasil rekomendasi <i>engineer</i>
	Temperatur <i>Bearing Motor</i> DE	\uparrow	
	Temperatur <i>Thrust Bearing</i>	\uparrow	
Cooling Loss	<i>Oil Temp Lube Oil Cooler Inlet</i>	\uparrow	1. Periksa apakah terdapat kenaikan temperatur disertai dengan kenaikan temperatur <i>bearing</i> .
	<i>Oil Temp Lube Oil Cooler Outlet</i>	\uparrow	2. Periksa apakah terdapat kenaikan temperatur air pendingin yang masuk pada <i>oil cooler</i> 3. Periksa <i>differential oil cooler</i> apakah terdapat kenaikan, apabila penurunan performa disebabkan kenaikan <i>differential pressure</i> yang mengindikasikan <i>oil cooler</i> kotor, maka lakukan <i>change over cooler</i> .
Axial Position	<i>Axial Displacement</i>	\uparrow	1. Periksa apakah <i>pressure balance pipe</i> normal dan periksa line pipa dan <i>valve</i> di lokal 2. Pengecekan pompa di lokal untuk memastikan apakah terdapat <i>abnormal sound</i> dan memastikan keamanan operasi 3. Pengaturan sisi operasi pada kurva pengoperasian pompa yang aman dan vibrasi yang stabil 4. Koordinasi dengan <i>engineer</i> CBM untuk melakukan analisa vibrasi lebih lanjut untuk melihat spektrum vibrasi 5. Perencanaan pemeliharaan sesuai hasil rekomendasi

3.2 Data Preprocessing

Tahapan pra-pemrosesan meliputi beberapa langkah seperti pembersihan data dari nilai kosong (NaN, Null) dan sensor *redundant*. *Re-sampling* data pada interval waktu 10 menit. Normalisasi data menggunakan MinMaxScaler (0–1) untuk menyeragamkan skala antar variabel. Transformasi data menjadi bentuk tiga dimensi (*batch size*, *time step*, dan *feature count*) sesuai kebutuhan model LSTM.

Tabel 3 menampilkan ringkasan statistik deskriptif dari beberapa parameter sensor penting yang dipantau pada sistem *boiler feed pump* selama periode pengamatan. Total data yang dianalisis berjumlah 21.466 titik data untuk setiap parameter, menunjukkan bahwa tidak ada data yang hilang. Nilai rata-rata kecepatan pompa sebesar 2456 rpm mengindikasikan bahwa data yang digunakan mencerminkan kondisi aktual saat peralatan beroperasi pada rentang kerja normal di atas 2000 rpm. Parameter arus motor menunjukkan variasi wajar dengan rata-rata 96,14 A, yang menggambarkan perubahan beban akibat fluktuasi kebutuhan aliran. Nilai getaran pada poros sisi penggerak/ *drive end* (DE) dan non-penggerak/ *non drive end* (NDE) berada pada kisaran 1,8–2,9 mm/s dengan penyimpangan standar relatif kecil, menunjukkan keseimbangan dan kondisi mekanis yang stabil.

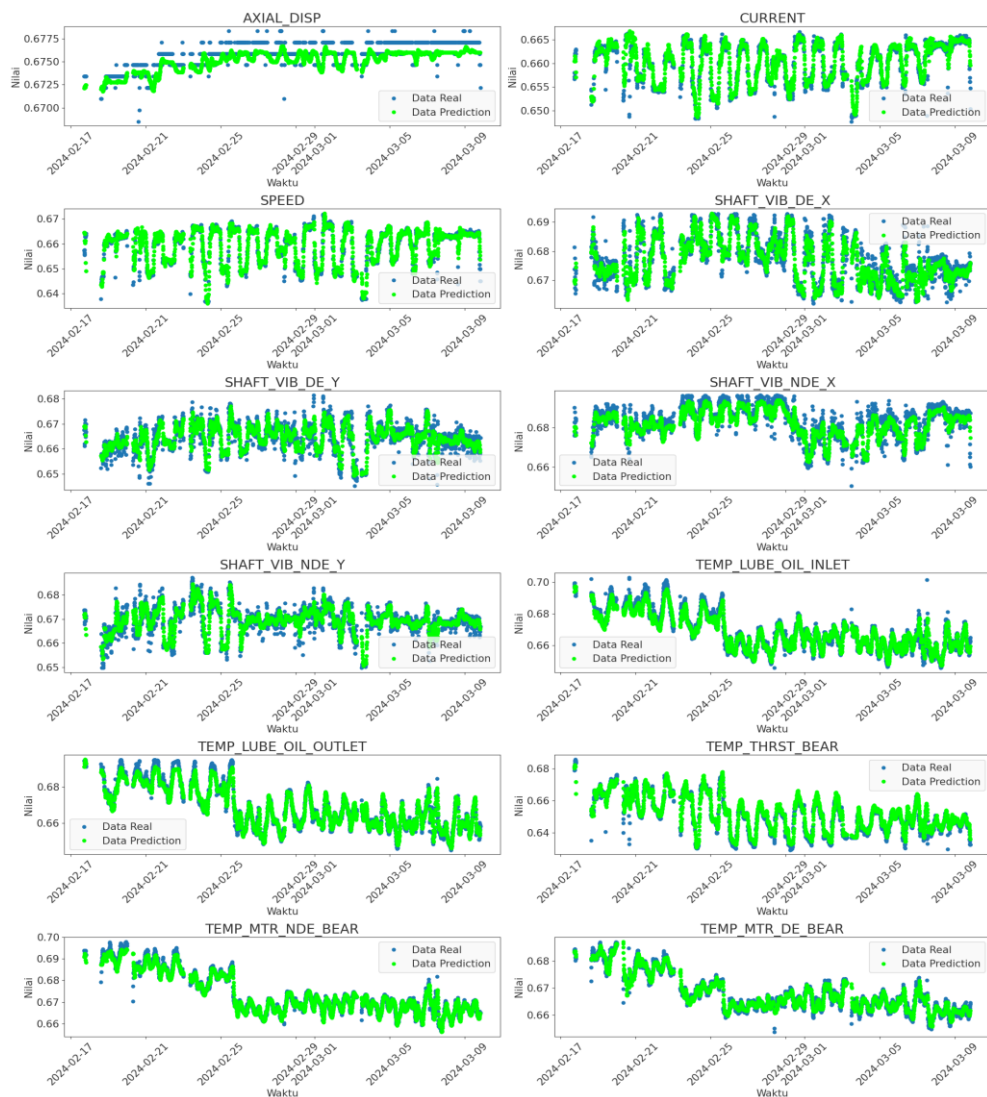
Sementara itu, parameter temperatur pelumas dan bearing memperlihatkan nilai rata-rata yang rendah dengan variasi minimal, menandakan sistem pendinginan dan pelumasan bekerja secara efektif. Tidak ditemukan nilai ekstrem atau anomali signifikan pada keseluruhan data, sehingga dapat disimpulkan bahwa data hasil monitoring bersifat representatif untuk kondisi operasi normal pompa.

Tabel 3. Data statistik parameter operasi

Parameter	Count	Mean	Std	Min	25%	50%	75%	Max
<i>Axial Displacement</i>	21466	0.60	0.12	0.28	0.45	0.66	0.69	0.74
<i>Current</i>	21466	96.14	14.66	66.90	85.80	92.36	103.04	132.31
<i>Speed</i>	21466	2456.22	98.40	2207.71	2382.75	2453.52	2516.81	2705.84
<i>Shaft Vibration DE_X</i>	21466	2.37	0.48	1.15	2.01	2.28	2.68	3.60
<i>Shaft Vibration DE_Y</i>	21466	2.39	0.20	1.90	2.30	2.41	2.52	2.88
<i>Shaft Vibration NDE_X</i>	21466	2.93	0.71	1.21	2.41	2.81	3.37	4.71
<i>Shaft Vibration NDE_Y</i>	21466	1.83	0.17	1.38	1.77	1.87	1.94	2.26
<i>Temperatur Lube Oil Inlet</i>	21466	41.64	0.61	40.14	41.19	41.56	41.97	43.61
<i>Temperatur Lube Oil Outlet</i>	21466	37.44	0.57	36.06	37.04	37.38	37.79	38.83
<i>Temperatur Thrust Bearing</i>	21466	50.30	0.82	48.15	49.69	50.43	50.93	52.41
<i>Temperatur Motor NDE Bearing</i>	21466	55.06	0.51	53.74	54.62	55.07	55.44	56.40
<i>Temperatur Motor DE Bearing</i>	21466	62.11	0.76	60.22	61.59	62.31	62.67	63.81

3.3 Pengembangan model train dan evaluasi rekonstruksi

Gambar 4 menampilkan perbandingan antara data aktual (ditunjukkan oleh titik biru) dan data hasil rekonstruksi model LSTM *Autoencoder* (garis merah) untuk setiap parameter operasi utama pada boiler feed pump.

**Gambar 4.** Hasil rekonstruksi model LSTM-*Autoencoder*

Secara umum, hasil rekonstruksi menunjukkan tingkat kesesuaian yang tinggi dengan pola data aktual, menandakan bahwa model LSTM-AE berhasil mempelajari karakteristik temporal dari masing-masing sinyal sensor secara efektif. Pada parameter seperti *axial displacement*, *current*, dan *speed*, garis rekonstruksi mengikuti tren data aktual dengan deviasi yang sangat kecil. Hal ini menunjukkan bahwa model mampu menangkap dinamika non-linier sistem yang kompleks, seperti perubahan beban dan fluktuasi operasi normal. Parameter *shaft vibration* DE X dan Y dan *shaft vibration* NDE X dan Y juga menunjukkan akurasi rekonstruksi yang baik, dengan perbedaan kecil hanya terjadi pada puncak-puncak getaran sesaat. Sementara itu, pada parameter temperatur *lube oil inlet* dan *outlet*, temperatur *thrust bearing*, temperaur motor NDE *bearing*, dan temperatur motor DE *bearing*, model berhasil merekonstruksi sinyal dengan tingkat kesalahan yang sangat rendah. Kestabilan ini mengindikasikan bahwa sistem termal dan pendinginan motor bekerja secara konsisten tanpa adanya penyimpangan signifikan. Secara keseluruhan, hasil rekonstruksi ini memperlihatkan bahwa LSTM-AE memiliki kemampuan generalisasi yang baik dalam mengenali pola operasi normal. Nilai eror rekonstruksi yang rendah mengindikasikan kondisi sistem dalam keadaan normal. Tahapan selanjutnya adalah memanfaatkan selisih antara data aktual dan hasil rekonstruksi sebagai dasar dalam pendeteksian anomali. Tabel 4 menunjukkan hasil evaluasi model LSTM-*Autoencoder* terhadap data sensor pada sistem *boiler feed pump* yang menunjukkan bahwa model memiliki kemampuan rekonstruksi yang sangat baik dengan nilai *Train R²* berkisar antara 0.92 hingga 0.99, menandakan bahwa lebih dari 90% variasi data asli dapat dijelaskan oleh hasil rekonstruksi model. Nilai *Train MSE* yang relatif kecil pada seluruh parameter, berada pada rentang 0.0027 hingga 0.078, memperkuat indikasi bahwa eror rekonstruksi pada data pelatihan sangat rendah dan model tidak mengalami *underfitting*. LSTM-*Autoencoder* berhasil mempelajari pola temporal dan karakteristik normal dari sistem secara efektif sehingga model ini dapat digunakan secara andal untuk mendeteksi anomali.

Tabel 4. Hasil evaluasi dan validasi model train

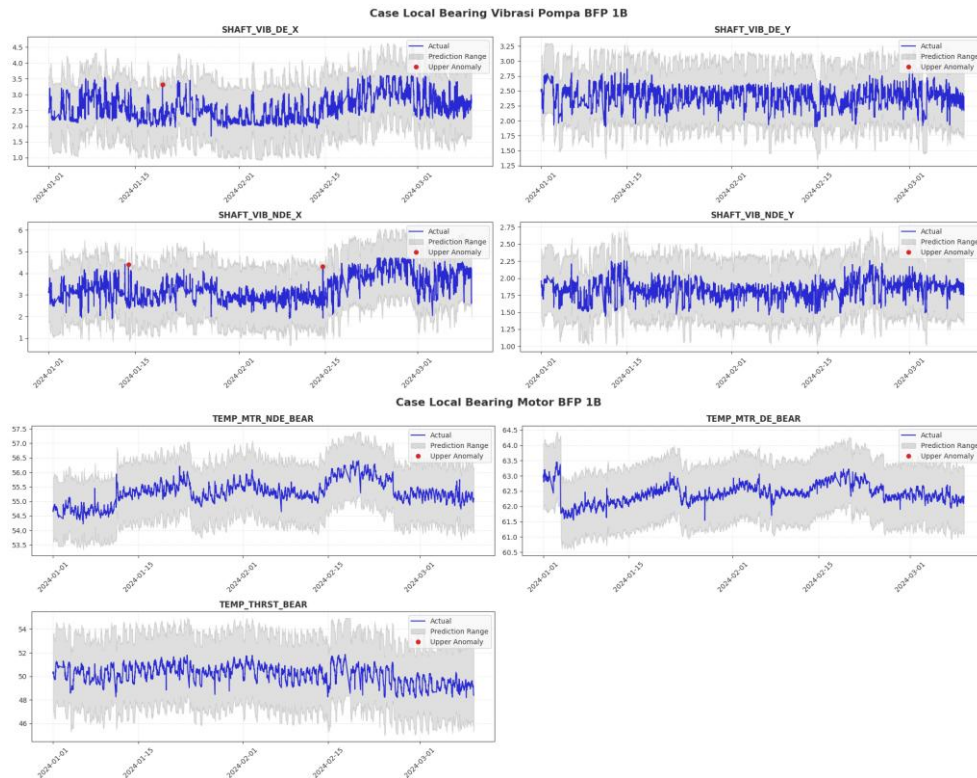
Sensor	Train MSE	Train \hat{R}^2	Val MSE	Val \hat{R}^2
<i>Axial Displacement</i>	0.00	1.00	0.00	0.75
<i>Current</i>	0.02	0.98	0.02	0.94
<i>Speed</i>	0.03	0.97	0.05	0.95
<i>Shaft Vibration</i> DE_X	0.06	0.94	0.08	0.80
<i>Shaft Vibration</i> DE_Y	0.05	0.95	0.07	0.87
<i>Shaft Vibration</i> NDE_X	0.08	0.92	0.13	0.78
<i>Shaft Vibration</i> NDE_Y	0.05	0.95	0.12	0.67
Temperatur <i>Lube Oil Inlet</i>	0.05	0.95	0.04	0.96
Temperatur <i>Lube Oil Outlet</i>	0.05	0.95	0.05	0.96
Temperatur <i>Thrust Bearing</i>	0.04	0.96	0.06	0.97
Temperatur Motor NDE <i>Bearing</i>	0.02	0.98	0.01	0.97
Temperatur Motor DE <i>Bearing</i>	0.02	0.98	0.01	0.91

3.4 Penentuan threshold dan Hasil Analisa Deteksi kerusakan


Ambang batas anomali ditentukan secara statistik berdasarkan distribusi data pelatihan, yang didefinisikan sebagai rata-rata kesalahan rekonstruksi ditambah k kali standar deviasi (σ). Beberapa nilai σ disimulasikan untuk mengidentifikasi ambang batas representatif yang mencerminkan karakteristik operasional pembangkit. Nilai σ yang lebih kecil menghasilkan model yang lebih sensitif terhadap perubahan kecil, sedangkan nilai σ yang lebih besar mengurangi kemungkinan false alarm namun menurunkan sensitivitas deteksi. Ambang batas yang dipilih kemudian divalidasi menggunakan catatan pemeliharaan historis dan umpan balik dari insinyur pembangkit. Hasil validasi menunjukkan bahwa model mampu membedakan secara akurat antara kondisi normal dan tidak normal, sehingga memberikan dasar yang andal untuk pemeliharaan proaktif dan deteksi anomali secara real-time dalam operasi pembangkit listrik.

Pada Gambar 5, garis biru menunjukkan data aktual hasil rekonstruksi model LSTM-*Autoencoder*, sedangkan area hijau mempresentasikan rentang batas normal operasi. Titik-titik merah menandai anomali, yaitu kondisi ketika sinyal getaran melampaui batas prediksi normal. Dari pola grafik dapat disimpulkan bahwa sebagian besar data berada dalam rentang normal, menunjukkan kondisi operasi yang stabil. Namun, terdapat beberapa titik anomali terutama pada vibrasi *bearing* DE X sebanyak 1 kali dan NDE X sebanyak 2 kali. Berdasarkan verifikasi data di SCADA anomali pada DE X vibrasi naik secara bertahap pada tanggal 19 Januari 2024 pukul 12.10 WITA s.d 12.40 WITA dari 1.47 mm/s to 6.07 mm/s. Sedangkan pada NDE Y *shaft* mengalami kenaikan vibrasi bertahap pada tanggal 13 Januari 2024 pukul 23.20 WITA s.d 23.40 WITA dari 3.08 mm/s s.d 4.44 mm/s dan kenaikan vibrasi secara tiba-tiba pada tanggal 14 Februari 2024 pukul 15.00 WITA s.d 15.10 WITA dari 2.66 mm/s ke 4.31 mm/s. Sedangkan pada temperatur *lube oil* dan *axial displacement*, parameter operasi dalam kondisi normal sehingga tidak muncul *case cooling loss* dan *axial position*. Hal tersebut dapat dilihat pada Gambar 6 dan 7. Dengan adanya anomali yang muncul pada vibrasi akan secara auto


berdasarkan aturan diagnosis akan dianggap muncul gangguan *local bearing* yang perlu dilakukan tindak lanjut sesuai rekomendasi.



Gambar 5. Hasil deteksi anomali pada *case local bearing*



Gambar 6. Hasil deteksi anomali pada *case cooling loss* tidak ada indikasi



Gambar 7. Hasil deteksi anomali pada *case axial position* tidak ada indikasi

4. Kesimpulan

Model yang diusulkan mampu mempelajari pola temporal dari data sensor multivariat secara efektif dan menunjukkan kemampuan rekonstruksi yang sangat baik dengan nilai R^2 antara 0.92–0.99 dan *Mean Squared Error* (MSE) yang rendah pada seluruh parameter operasi. Proses penentuan ambang batas berbasis distribusi kesalahan rekonstruksi menghasilkan model yang adaptif terhadap karakteristik operasional sistem. Validasi menggunakan data historis pemeliharaan dan dari ahli menunjukkan bahwa model LSTM-AE dapat membedakan secara akurat antara kondisi normal dan abnormal. Penerapan metode ini memungkinkan deteksi dini anomali seperti peningkatan vibrasi pada *bearing* sebelum kegagalan aktual terjadi, sehingga mendukung pelaksanaan pemeliharaan preskriptif. Integrasi antara *deep learning* dan *rule-based expert system* memperkuat kemampuan sistem dalam mengklasifikasikan jenis kerusakan *local bearing*, *cooling loss*, dan *axial position* serta memberikan rekomendasi tindak lanjut secara otomatis.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa pendekatan LSTM-AE terintegrasi dengan sistem pakar efektif untuk meningkatkan keandalan, keselamatan, dan efisiensi pemeliharaan pada peralatan kritis di industri pembangkitan listrik.

Daftar Pustaka

- [1] Kumar, P., & Singh, O. (2016). Performance analysis of boiler feed pump turbines in thermal power plants. *International Journal of Mechanical Engineering & Technology*, 7(4), 325–333.
- [2] Dai, X., Gao, Z., 2013, “From model, signal to knowledge: A data-driven perspective of fault detection and diagnosis,” *IEEE Transactions on Industrial Informatics*, 9: 2226-2238.
- [3] Ge, Z., Song, Z., Ding, S. X., Huang, B., 2017, “Data Mining and Analytics in the Process Industry: The Role of Machine Learning,” *IEEE Access*, 5: 20590-20616.
- [4] Hoffmann, J. B., Heimes, P., Senel, S., 2019, “IoT platforms for the Internet of Production,” *IEEE Internet of Things Journal*, 6: 4098-4105.
- [5] Bengio, Y., Courville, A., Vincent, P., 2013, “Representation learning: A review and new perspectives,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35: 1798-1828.
- [6] Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., Gao, R.X., 2019, “Deep learning and its applications to machine health monitoring,” *Mechanical Systems and Signal Processing*, 115: 213–237.
- [7] Malhotra, P., Vig, L., Shroff, G., Agarwal, P., 2015, “Long short term memory networks for anomaly detection in time series,” *Proceedings of ESANN*, 23rd European Symposium on Artificial Neural Networks, 89–94.
- [8] Zhang, W., Peng, G., Li, C., Chen, Y., Zhang, Z., 2017, “A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals,” *Sensors*, 17(2): 425.
- [9] Zhang, Y., Li, X., 2021, “Vibration analysis under variable speed conditions,” *Journal of Sound and Vibration*, 498: 115–134.
- [10] Li, P., Sun, W., 2022, “Deep learning-based FDD for rotating machinery under variable speed,” *Mechanical Systems and Signal Processing*, 168: 108653.
- [11] Tong, X., Wang, J., Zhang, C., Wu, T., Wang, H., Wang, Y., 2022, “LS-LSTM-AE: Power load forecasting via Long-Short series features and LSTM-Autoencoder,” *Energy Reports*, 8: 596-603.
- [12] Orošnjak, M., Saretzky, F., 2025, “Prescriptive Maintenance : A Systematic Literature Review and Exploratory Meta-Synthesis,” 1-36.
- [13] Lee, Y., Park, C., Kim, N., Ahn, J., Jeong, J., 2024, “LSTM-Autoencoder Based Anomaly Detection Using Vibration Data of Wind Turbines,” *Sensors*, 24: 1-24.
- [14] Orabi, M., Tran, K.P., Egger, P., Thomassey, S., 2024, “Anomaly detection in smart manufacturing: An Adaptive Adversarial Transformer-based model,” *J Manuf Syst*, 77: 591-611.