

Analisis Komparatif Algoritma LSTM, GRU, BiGRU, dan BiLSTM Untuk Prediksi Degradasi *Bearing* Turbin PLTU

Rifky Raymond^{1*}; Neva Saputra¹; Meldrin Tupamahu¹; Neng Ayu Herawati^{1,2}; Ayu Purwarianti^{1,2}; Nugraha Priya Utama^{1,2}

¹Sekolah Teknik Elektro dan Informatika (STEI), Institut Teknologi Bandung, Jl. Ganesa No.10, Coblong, Kota Bandung, Jawa Barat 40132

²Pusat *Artificial Intelligence: Computer Vision, NLP, and Big Data Analytics*, Institut Teknologi Bandung, Jl. Ganesa No.10, Coblong, Kota Bandung, Jawa Barat 40132

*Corresponding Author: 23524021@std.stei.itb.ac.id

Abstrak

Pembangkit Listrik Tenaga Uap (PLTU) merupakan salah satu sumber utama pasokan listrik nasional, di mana keandalan komponen kritis seperti bearing turbin sangat menentukan kontinuitas operasional. Kegagalan pada bearing dapat menyebabkan downtime tidak terduga dan kerugian biaya yang signifikan. Oleh karena itu, pendekatan predictive maintenance menjadi strategi penting dalam memitigasi potensi kegagalan tersebut. Penelitian ini bertujuan untuk membandingkan performa empat algoritma deep learning yaitu LSTM, GRU, BiGRU, dan BiLSTM dalam memprediksi Remaining Useful Life (RUL) dari bearing turbin. Data yang digunakan merupakan data sensor aktual dari pembangkit, yang telah direduksi dimensinya menggunakan Principal Component Analysis (PCA) untuk membentuk Health Index sebagai representasi degradasi peralatan. Evaluasi dilakukan menggunakan metrik MAE (Mean Absolute Error) dan RMSE (Root Mean Squared Error). Hasil eksperimen menunjukkan bahwa model BiLSTM memiliki performa terbaik dengan nilai MAE sebesar 0.27 dan RMSE sebesar 0.37. Penelitian ini berkontribusi dalam menyediakan panduan pemilihan model prediksi RUL berbasis data sensor riil pada peralatan PLTU, yang mendukung penerapan pemeliharaan prediktif secara lebih akurat dan efisien.

Kata kunci: BiGRU, BiLSTM, GRU, LSTM, Remaining Useful Life

Abstract

Steam power plants (PLTU) are one of the main sources of national electricity supply, where the reliability of critical components such as turbine bearings determines operational continuity. Bearing failures can lead to unexpected downtime and significant cost losses. Therefore, a predictive maintenance approach is an important strategy in mitigating such potential failures. This study aims to compare the performance of four deep learning algorithms namely LSTM, GRU, BiGRU, and BiLSTM in predicting the Remaining Useful Life (RUL) of turbine bearings. The data used is actual sensor data from the plant, which has been reduced in dimension using Principal Component Analysis (PCA) to form a Health Index as a representation of equipment degradation. Evaluation is performed using MAE (Mean Absolute Error) and RMSE (Root Mean Squared Error) metrics. The experimental results show that the BiLSTM model has the best performance with MAE value of 0.27 and RMSE of 0.37. This research contributes to providing guidance on the selection of RUL prediction models based on real sensor data on PLTU equipment, which supports the application of predictive maintenance more accurately and efficiently.

Keywords: BiGRU, BiLSTM, GRU, LSTM, Remaining Useful Life

PENDAHULUAN

Pembangkit Listrik Tenaga Uap (PLTU) merupakan tulang punggung sistem kelistrikan nasional di Indonesia, menyumbang lebih dari 50% kapasitas pembangkit yang terpasang secara nasional. Dalam operasionalnya, PLTU dituntut untuk mampu menyediakan pasokan listrik yang andal, efisien, dan berkelanjutan. Untuk mencapai hal tersebut, diperlukan sistem pemeliharaan yang mampu mendeteksi dini potensi kerusakan pada komponen-komponen vital, salah satunya adalah turbin.

Turbin pada PLTU berfungsi mengubah energi panas uap menjadi energi mekanik, dan terus beroperasi dalam kondisi tekanan serta temperatur tinggi [1]. Salah satu komponen krusial dalam turbin adalah *bearing*, yang menopang putaran poros utama [2]. Kerusakan pada *bearing* tidak hanya berdampak pada penurunan efisiensi tetapi juga berpotensi menyebabkan *shutdown* mendadak, meningkatkan risiko kerusakan sistemik, dan menimbulkan biaya pemeliharaan yang tinggi.

Dalam konteks tersebut, pendekatan pemeliharaan prediktif (*predictive maintenance*) sangat penting untuk dilakukan. Salah satu elemen kunci dalam pendekatan ini adalah prediksi *Remaining Useful Life* (RUL), yaitu estimasi waktu operasional yang tersisa sebelum suatu komponen mengalami kegagalan [3], namun dalam penelitian ini, RUL yang diprediksi merupakan representasi dari sisa umur pakai suatu peralatan dibandingkan dengan umur maksimalnya, dinyatakan dalam satuan persen (%) sebagai abstraksi nilai dari skala waktu absolut. RUL menunjukkan berapa persen dari kapasitas atau masa pakai suatu komponen yang masih tersedia sebelum mencapai batas kegagalan. Prediksi RUL yang akurat memungkinkan pengambilan keputusan pemeliharaan yang lebih efisien dan berbasis data [4].

Penelitian ini mengusulkan pendekatan prediksi degradasi turbin berbasis data sensor operasional pada *bearing* turbin PLTU. Data sensor berupa temperatur oli, suhu logam, vibrasi dan tekanan oli diolah menjadi indikator kondisi bernama *Health Index*, yang dibentuk menggunakan metode *Principal Component Analysis* (PCA). *Health Index* ini digunakan sebagai dasar untuk menghitung nilai RUL yang menjadi target prediksi.

Penelitian sejenis yang membandingkan performa metode deep learning seperti LSTM, GRU, dan BiLSTM yang diterapkan pada domain finansial atau prediksi harga saham, dengan menggunakan dataset publik dan tujuan utamanya yaitu meningkatkan akurasi prediksi nilai numerik, bukan dalam konteks pemeliharaan prediktif untuk peralatan industri dengan data sensor aktual dari pembangkit listrik seperti yang dilakukan dalam penelitian ini [5].

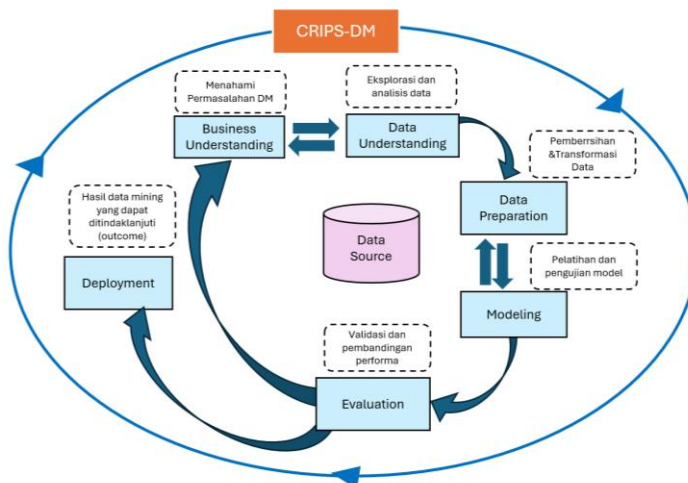
Fokus utama penelitian ini adalah membandingkan performa empat metode *deep learning time series*, yaitu *Long Short-Term Memory* (LSTM), *Gated Recurrent Unit* (GRU), *Bidirectional GRU* (BiGRU) dan *Bidirectional LSTM* (BiLSTM), dalam memprediksi degradasi *bearing* turbin melalui estimasi RUL. *Long Short-Term Memory* (LSTM) telah banyak digunakan untuk memprediksi RUL di berbagai aplikasi industri, termasuk mesin pesawat terbang, mesin *turbofan*, dan alat pemotong [6] [7] [8]. Penggunaan LSTM dalam prediksi RUL telah terbukti secara efektif menangkap pola temporal dalam data degradasi, sehingga memungkinkan prediksi RUL yang lebih akurat.

Dalam konteks prediksi RUL generator, GRU biasanya digunakan untuk menganalisis data deret waktu dari sensor dan sumber lain untuk mengidentifikasi pola dan tren yang dapat mengindikasikan sisa umur generator [9]. Teknik lain, seperti BiGRU telah terbukti efektif dalam prediksi RUL karena kemampuannya untuk menangkap ketergantungan jangka panjang dan hubungan temporal dalam data berurutan [10] [11]. Dalam konteks prediksi RUL, BiGRU dapat digunakan untuk memodelkan proses degradasi pembangkit listrik tenaga uap, dengan mempertimbangkan faktor-faktor seperti suhu, tekanan, dan getaran [12]. Dalam memprediksi RUL, BiLSTM digunakan untuk memodelkan proses degradasi peralatan mekanis, seperti mesin pesawat terbang, bantalan, dan pompa lumpur industri [13]. Baik GRU maupun BiLSTM telah terbukti efektif dalam meningkatkan akurasi prediksi RUL sehingga sangat relevan untuk diterapkan pada studi prediksi degradasi *bearing* turbin di lingkungan PLTU.

Penelitian ini menggunakan pendekatan komparatif antara LSTM, GRU, BiGRU, dan BiLSTM untuk prediksi RUL *bearing* turbin PLTU, menggunakan *Health Index* hasil reduksi dimensi dengan PCA, yang masih jarang dibahas dalam konteks studi di Indonesia. Penelitian ini tidak mencakup tahap pengambilan keputusan atau rekomendasi tindakan pemeliharaan secara langsung, melainkan berfokus pada tahap awal dari sistem pemeliharaan prediktif, yaitu prediksi RUL secara akurat. Fokus utama terletak pada pembangunan dan evaluasi model *deep learning time series* untuk memperkirakan presentase sisa umur pakai komponen *bearing* turbin berdasarkan data sensor operasional. Dengan membandingkan performa berbagai model seperti LSTM, GRU, BiGRU, dan BiLSTM, penelitian ini bertujuan untuk mengidentifikasi pendekatan yang paling efektif dalam memodelkan degradasi komponen *bearing* turbin. Hasil prediksi RUL yang akurat diharapkan dapat menjadi fondasi penting bagi pengembangan sistem pemeliharaan prediktif untuk PLTU yang lebih komprehensif.

METODOLOGI PENELITIAN

Penelitian ini menggunakan kerangka kerja CRISP-DM (*Cross Industry Standard Process for Data Mining*) untuk melakukan studi komparatif terhadap empat algoritma *deep learning* LSTM, GRU, BiGRU, dan BiLSTM guna memprediksi degradasi *bearing* turbin pada PLTU. CRISP-DM merupakan metodologi yang banyak digunakan dalam proyek *data mining*, dan telah berhasil diterapkan di berbagai industri dan domain [14]. Terdapat enam fase dalam CRIPS-DM seperti yang ditunjukkan pada Gambar 1 [15].



Gambar 1. Kerangka Kerja CRIPS-DM

1. Pemahaman Bisnis (*Business Understanding*)

Tahapan ini diperlukan untuk memahami permasalahan utama pada *bearing* turbin PLTU. *Bearing* merupakan salah satu komponen mekanis yang mengalami degradasi seiring waktu akibat beban termal, vibrasi, dan tekanan berulang. Kegagalan *bearing* merupakan jenis kegagalan yang paling sering terjadi dan dapat menyebabkan malfungsi atau kerusakan sistem mesin lainnya [16]. Hal ini berakibat pada *downtime* yang lama dan biaya perawatan yang tinggi, sehingga mengganggu kelangsungan operasi pembangkit listrik. Dengan adanya sistem prediksi terhadap degradasi *bearing* turbin, keandalan dan ketersediaan mesin atau komponen dapat ditingkatkan, sekaligus mengurangi risiko gangguan tak terduga dan biaya pemeliharaan sistem salah satunya pada turbin.

2. Pemahaman Data (*Data Understanding*)

Tahapan ini menjelaskan eksplorasi terhadap struktur serta kualitas data. Dataset yang digunakan dalam penelitian ini berasal dari sistem SCADA (*Supervisory Control and Data Acquisition*) pembangkit listrik tenaga uap yang mencakup data sensor dari tahun 2022 hingga 2025, dengan total 213.164 *record*. Data terdiri dari 38 fitur yang mencerminkan kondisi termal, mekanis, dan dinamis dari *bearing* turbin. Fitur-fitur tersebut merepresentasikan parameter penting seperti tekanan pelumas, temperatur logam dan oli *bearing*, getaran sumbu horizontal dan vertikal, posisi aksial, serta daya keluaran generator. Untuk memperjelas struktur dan jenis fitur yang digunakan, Tabel 1 menyajikan ringkasan sebagian fitur yang digunakan dalam penelitian:

Tabel 1. Ringkasan Fitur Data Sensor *Bearing* Turbin

No	Nama Fitur	Deskripsi	Tipe Data	Satuan
1	Turb Brg Oil Pressure	Tekanan oli pelumas pada sistem <i>bearing</i> turbin	Numerik	kg/cm ²
2	Turb Brg #1-6 Metal Temp	Temperatur logam <i>bearing</i> turbin (<i>bearing</i> #1-6)	Numerik	°C
3	Turb Brg #1-6 Oil Drain Temp	Temperatur oli buangan (drain) <i>bearing</i> #1-6	Numerik	°C
4	Turb Brg #1-6 Vibration Horiz./Vert.	Getaran horizontal dan vertikal pada <i>bearing</i> #1-6	Numerik	µm
5	Turb Brg Feed Oil Temp	Temperatur oli suplai masuk ke sistem <i>bearing</i>	Numerik	°C
6	Turb Thrust Brg Frnt/Rear Temp	Temperatur logam thrust <i>bearing</i> depan/belakang	Numerik	°C
7	Turb Thrust Brg Oil Drain Temp	Temperatur oli buangan dari thrust bearing	Numerik	°C
8	Turb Thrust Position	Posisi aksial thrust bearing	Numerik	mm
9	Generator Megawatts #1	Daya keluaran generator	Numerik	MW

Eksplorasi data dilakukan untuk melihat distribusi data, hubungan antar fitur, serta mendeteksi keberadaan nilai hilang dan pencilan. Proses ini akan menjadi landasan dalam proses persiapan data dan pemodelan selanjutnya.

3. Persiapan Data (*Data Preparation*)

Persiapan Data bertujuan menyiapkan dataset yang bersih dan siap digunakan sebelum dimasukkan ke dalam model. Adapun langkah-langkah yang diimpelentasi pada tahap ini adalah sebagai berikut:

3.1. Pemilihan Data Operasional

Tahap pertama dalam persiapan data melibatkan pemfilteran data untuk mengidentifikasi periode operasi normal dan masa gangguan. Proses ini berguna agar analisis model dapat secara tepat melacak degradasi *bearing* sejak awal operasi normal hingga mencapai titik kegagalan. Hasil pemfilteran menghasilkan 190.356 *record*. Data operasional yang tidak terkait dengan proses degradasi akan dihapus. Setelah itu, data akan diurutkan secara kronologis berdasarkan tanggal untuk menjamin keakuratan urutan peristiwa.

3.2. Penanganan Nilai Hilang

Penanganan nilai hilang (*missing values*) pada kolom numerik dilakukan menggunakan metode *Seasonal Trend Decomposition using Loess* (STL). Metode ini berguna untuk memahami dan memprediksi pola temporal yang kompleks dalam data [17]. STL memiliki kemampuan dalam menguraikan deret waktu menjadi komponen tren, musiman, dan residu. Dengan menginterpolasi nilai yang hilang dan menerapkan STL, pola musiman dan tren inheren dalam data sensor dapat dipertahankan selama proses imputasi, menghasilkan *dataset* yang lebih baik dibandingkan metode imputasi sederhana.

3.3. Identifikasi dan Penghapusan Pencilan (*Outlier*)

Untuk meningkatkan ketahanan model terhadap nilai-nilai ekstrem yang anomali, dilakukan identifikasi dan penghapusan pencilan menggunakan algoritma *Isolation Forest*. *Isolation Forest* adalah algoritma deteksi outlier tanpa pengawasan (*unsupervised*) yang bekerja dengan cara mengisolasi outlier dalam sebuah dataset [18]. Setelah identifikasi melalui algoritma ini, data yang teridentifikasi sebagai pencilan dieliminasi, sehingga menghasilkan *dataset* yang lebih bersih dari *noise* dan anomali. Hasil dari proses ini menghasilkan 180.838 data bersih yang siap digunakan untuk pemodelan.

3.4. Transformasi Distribusi Fitur

Fitur-fitur numerik yang menunjukkan distribusi sangat miring (*skewed*) diidentifikasi dan ditransformasi menggunakan *Power Transformer* dengan metode Yeo Johnson. Transformasi ini bertujuan untuk mendekati distribusi data ke distribusi normal, sehingga mengoptimalkan karakteristiknya untuk analisis lebih lanjut [19]. Banyak algoritma *machine learning* menunjukkan kinerja yang lebih optimal dengan data yang berdistribusi mendekati normal, sehingga langkah ini penting untuk meningkatkan kinerja model yang akan diterapkan.

3.5. Seleksi Fitur

Proses seleksi fitur dilakukan untuk mengidentifikasi subset variabel yang paling informatif dan berpengaruh terhadap hasil prediksi degradasi *bearing*. Metode yang digunakan adalah *Mutual Information Regression*, yang mengukur ketergantungan non-linear antara fitur input dan variabel target RUL, yang merepresentasikan tingkat degradasi. Dari seluruh fitur yang tersedia, hanya 15 fitur terbaik dengan nilai *mutual information* tertinggi yang dipilih. Pemilihan ini bertujuan untuk mereduksi dimensi data, mengatasi fenomena *curse of dimensionality*, mengoptimalkan efisiensi komputasi, dan meningkatkan interpretabilitas model tanpa mengorbankan informasi esensial.

3.6. Pembentukan dan Normalisasi *Health Index* serta Kalkulasi RUL

Berdasarkan 15 fitur terpilih, *Health Index* yang merefleksikan kondisi degradasi *bearing* dibentuk. Pembentukan ini dilakukan dengan menerapkan PCA pada fitur-fitur sensor yang telah diskalakan. PCA digunakan untuk reduksi dimensi karena mampu menghasilkan sejumlah variabel yang lebih sedikit, namun tetap mempertahankan sebanyak mungkin varians dari data asli [20]. Melalui proses ini, fitur-fitur yang berpotensi saling berkorelasi direduksi menjadi satu komponen utama (PC1) yang mewakili sebagian besar varians dalam data.

Selanjutnya, PC1 tersebut dinormalisasi ke dalam rentang 0 hingga 1. Untuk merepresentasikan kondisi kesehatan, sehingga nilai yang lebih tinggi menunjukkan kondisi sehat (mendekati 1) dan nilai yang lebih rendah menunjukkan degradasi (mendekati 0). *Health Index* yang dihasilkan kemudian dihaluskan menggunakan rata-rata bergerak (*rolling mean*) untuk mengurangi fluktuasi (*noise*) dan mendapatkan tren degradasi yang lebih stabil.

Setelah itu, nilai RUL dihitung berdasarkan *Health Index* yang telah dinormalisasi. Adapun formula RUL pada penelitian ini diekspresikan dalam formula sebagai berikut:

$$RUL (\%) = (1 - Health\ Index_{normalized}) \times 100\% \quad (1)$$

$$Health\ Index_{normalized} = 1 - \left(\frac{PC1 - \min(PC1)}{\max(PC1) - \min(PC1)} \right) \quad (2)$$

Dimana:

- RUL (%) adalah nilai *Remaining Useful Life* yang dinyatakan dalam persentase
- *Health Index normalized* adalah nilai yang telah dinormalisasi ke rentang 0 hingga 1
- PC1 adalah nilai komponen utama pertama dari PCA.

Dengan demikian, *Health Index* 100% akan menghasilkan RUL 0% (kegagalan), dan *Health Index* 0% akan menghasilkan RUL 100% (kondisi baru/sehat).

4. Pemodelan (*Modeling*)

Pada tahap pemodelan, dilakukan pelatihan empat arsitektur deep learning, yaitu LSTM, GRU, BiGRU, dan BiLSTM, yang merupakan varian dari *Recurrent Neural Network* (RNN) dan dirancang untuk memproses data time series sensor guna memprediksi RUL *bearing*. LSTM menggunakan tiga gerbang (*input*, *forget*, dan *output*) untuk mempertahankan informasi jangka panjang secara efektif [21], sedangkan GRU menyederhanakan struktur ini dengan hanya dua gerbang (*update* dan *reset*) sehingga lebih efisien secara komputasi [22]. BiGRU, dan BiLSTM merupakan versi *bidirectional* yang memproses data dalam dua arah, memungkinkan model menangkap konteks temporal dari masa lalu dan masa depan secara bersamaan [23].

Setiap model dibangun dengan dua lapisan utama berukuran 64 dan 32 unit, menggunakan aktivasi *ReLU* dan *dropout* sebesar 20% untuk mencegah *overfitting*. Keluaran model menggunakan aktivasi linear untuk menghasilkan prediksi RUL yang bersifat kontinu. Input berupa jendela sekuens sepanjang 30 timestep dipilih untuk menangkap dinamika jangka pendek pada sinyal sensor. Pelatihan dilakukan dengan *optimizer Adam* dan fungsi kerugian *Mean Squared Error* (MSE), serta dilengkapi dengan mekanisme *Early Stopping* untuk menghentikan pelatihan saat performa validasi tidak lagi membaik. Pemilihan parameter seperti *window size*, jumlah unit, *dropout*, dan *epoch* ditentukan berdasarkan praktik umum dan eksplorasi awal untuk menyeimbangkan akurasi, efisiensi, dan kemampuan generalisasi model.

5. Evaluasi (*Evaluation*)

Evaluasi model dilakukan untuk mengukur akurasi prediksi dalam mengidentifikasi kondisi degradasi *bearing*. Penilaian kinerja model menggunakan dua metrik utama, yaitu *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE). MAE dan RMSE dipilih karena mampu memberikan evaluasi yang saling melengkapi terhadap kesalahan prediksi [24]. MAE mengukur rata-rata selisih absolut antara nilai prediksi dan nilai aktual, sebagaimana didefinisikan pada Persamaan (3) [25]. Nilai MAE yang lebih rendah mengindikasikan akurasi prediksi yang lebih baik [25]. Sementara itu, RMSE, didefinisikan pada Persamaan (4) [25], memberikan bobot lebih besar pada kesalahan yang lebih besar dan sering digunakan untuk mengukur deviasi prediksi model dari nilai aktual RUL. Nilai RMSE yang lebih rendah menunjukkan kecocokan model yang lebih baik [25].

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

$$RMSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

Dimana :

- n merupakan Jumlah total sampel data yang dievaluasi.
- y_i merupakan nilai aktual (observasi) untuk sampel ke- i . Dalam konteks penelitian ini, y_i merepresentasikan nilai RUL aktual pada sampel ke- i .
- \hat{y}_i merupakan Nilai prediksi (estimasi) oleh model untuk sampel ke- i . Dalam konteks penelitian ini, \hat{y}_i merepresentasikan nilai RUL yang diprediksi oleh model untuk sampel ke- i

6. Implementasi (*Deployment*)

Tahap akhir dari metodologi ini berfokus pada visualisasi hasil prediksi sebagai bentuk evaluasi dan interpretasi

model. Visualisasi dilakukan untuk membandingkan antara nilai RUL aktual dengan hasil prediksi dari keempat model *deep learning*, yaitu LSTM, GRU, BiGRU, dan BiLSTM. Grafik yang dihasilkan memperlihatkan tren degradasi *bearing* berdasarkan data sensor, serta akurasi masing-masing model dalam mengikuti pola aktual.

HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk memprediksi RUL pada *bearing* turbin PLTU berdasarkan data sensor operasional dengan menggunakan empat arsitektur *deep learning*, yaitu LSTM, GRU, BiGRU, dan BiLSTM. Pengujian dilakukan berdasarkan performa terhadap metrik MAE dan RMSE. Sebelum proses pelatihan, dilakukan pembersihan data, imputasi *missing value* dengan *STL decomposition*, transformasi PCA untuk menghasilkan *Health Index*, dan kalkulasi RUL sebagai target variabel.

Hasil Model LSTM

Model pertama menggunakan LSTM. Model ini dilatih selama 14 *epoch* sebelum berhenti karena *early stopping*. Hasil evaluasi menunjukkan MAE sebesar 0.66 dan RMSE sebesar 0.80. Nilai ini merupakan yang tertinggi di antara keempat model. Kinerja yang kurang optimal ini menunjukkan keterbatasan LSTM dalam mengenali pola degradasi *bearing* yang bersifat kompleks dan non linier. Hasil ini juga sejalan dengan temuan [13] yang menunjukkan bahwa model LSTM memiliki performa terendah dibandingkan BiLSTM dalam prediksi RUL baterai *lithium-ion*, dengan nilai RMSE sebesar 24.66 yang jauh lebih tinggi dibandingkan model lainnya. Dengan RMSE di atas 1.0, mengindikasikan kebutuhan arsitektur yang lebih efisien untuk pemodelan urutan panjang.

Hasil Model GRU

Model kedua adalah GRU. Model ini berhenti pada *epoch* ke-23 dan menunjukkan peningkatan signifikan dibandingkan LSTM. Hasil evaluasi menunjukkan MAE sebesar 0.36 dan RMSE sebesar 0.49. GRU terbukti lebih ringan dari sisi komputasi dan mampu mempertahankan konteks informasi penting secara efisien. Hasil ini sebanding dengan performa GRU dalam studi [10] yang menunjukkan akurasi tinggi dalam pemodelan sistem tenaga berbasis *time-series*.

Hasil Model BiGRU

Model ketiga menggunakan *Bidirectional* GRU, yang memproses data dari dua arah. Model ini berhenti pada *epoch* ke-18. Evaluasi menunjukkan MAE sebesar 0.28 dan RMSE sebesar 0.37. BiGRU memberikan peningkatan signifikan dibandingkan GRU biasa, karena mampu memahami dinamika waktu ke depan dan ke belakang secara simultan. Performa ini mendekati hasil studi [12] yang menunjukkan efektivitas BiGRU dalam memprediksi probabilitas RUL pada *aero-engine*.

Hasil Model BiLSTM

Model terakhir adalah *Bidirectional* LSTM (BiLSTM), yang juga berhenti pada *epoch* ke-18. Model ini menunjukkan performa terbaik dengan MAE sebesar 0.27 dan RMSE sebesar 0.37. Keunggulan BiLSTM berasal dari kemampuan menangkap pola temporal dua arah secara utuh, yang sangat relevan dalam data degradasi *bearing*. Hasil ini lebih baik dibandingkan studi [13] yang mencatat nilai RMSE sebesar 0.43 untuk model BiLSTM dalam kasus prediksi RUL baterai *lithium-ion*.

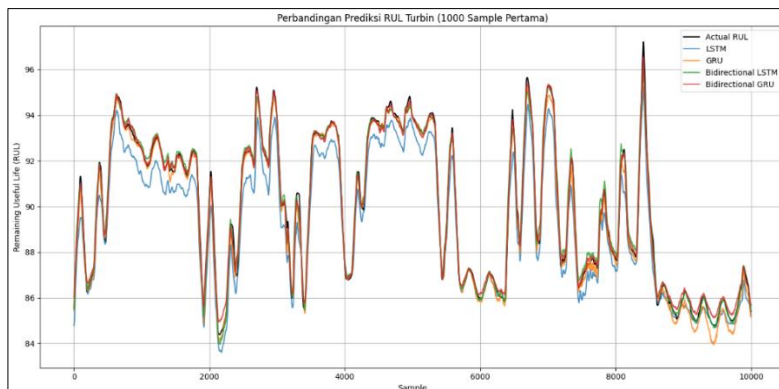
Perbandingan Kinerja Model LSTM, GRU, BiGRU, dan Bi-LSTM

Tabel berikut menyajikan ringkasan evaluasi metrik dari ketiga model:

Tabel 2. Hasil Evaluasi Model Prediksi RUL

Model	MAE	RMSE
LSTM	0.66	0.80
GRU	0.36	0.49
BiGRU	0.28	0.37
BiLSTM	0.27	0.37

Dari Tabel 2 di atas dapat disimpulkan bahwa BiLSTM adalah model paling unggul, baik dari sisi akurasi (MAE terendah) maupun konsistensi (RMSE terendah). Visualisasi hasil prediksi terhadap data aktual (10.000 sampel pertama) pada Gambar 2 juga menunjukkan bahwa kurva prediksi BiLSTM paling mendekati nilai aktual, disusul BiGRU, GRU, dan LSTM. Keunggulan BiLSTM ini juga didukung oleh studi-studi sebelumnya yang menyatakan bahwa pemrosesan dua arah dalam BiLSTM mampu meningkatkan kapasitas model dalam memahami konteks sekuensial secara simultan dan memberikan akurasi yang lebih baik dibanding model lain dalam berbagai domain [12] [13].



Gambar 2. Grafik Perbandingan Hasil Prediksi RUL dengan Data Aktual

Selain arsitektur, keberhasilan model juga ditentukan oleh kualitas fitur dan strategi *preprocessing*. Penggunaan fitur-fitur hasil seleksi *mutual information* dan pembentukan *Health Index* melalui PCA menjadi pondasi kuat dalam prediksi. Proses ini memungkinkan model hanya belajar dari fitur-fitur yang relevan dan menyederhanakan kompleksitas hubungan antar variabel. Penerapan normalisasi dan pembentukan urutan data dengan *window* sepanjang 30 waktu juga memperkuat kapabilitas model dalam mengenali tren degradasi secara progresif, karena setiap prediksi didasarkan pada 30 langkah waktu sebelumnya.

Implikasi dari temuan ini menegaskan bahwa pemilihan arsitektur *deep learning* yang tepat berperan signifikan dalam prediksi RUL. BiLSTM secara konsisten menunjukkan kemampuan prediksi lebih akurat, membuatnya lebih potensial untuk diterapkan pada sistem prediksi sisa umur *bearing* turbin untuk mendukung strategi pemeliharaan prediktif.

Secara praktis, penerapan model BiLSTM di lingkungan industri seperti PLTU membuka peluang untuk peningkatan efisiensi pemeliharaan berbasis kondisi. Model ini dapat menjadi dasar bagi sistem *maintenance* berbasis AI yang mampu mendeteksi degradasi lebih awal dan mengatur jadwal perawatan secara otomatis.

Namun demikian, penelitian ini masih memiliki keterbatasan, yaitu penggunaan data dari satu lokasi dan belum diuji untuk generalisasi di berbagai kondisi operasional. Pengujian lanjutan dengan data *multi-site* serta integrasi dengan modul pengambilan keputusan adaptif seperti *reinforcement learning* dapat menjadi arah pengembangan ke depan.

KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa pemodelan prediksi RUL pada *bearing* turbin PLTU menggunakan pendekatan *deep learning time series* dapat memberikan hasil yang akurat, dengan BiLSTM menghasilkan performa terbaik dibandingkan LSTM, GRU, dan BiGRU. Hal ini membuktikan bahwa struktur BiLSTM yang mampu memproses informasi secara dua arah lebih efektif dalam menangkap pola degradasi sistem mekanis yang kompleks. Temuan ini menjawab tujuan utama penelitian yaitu untuk mengidentifikasi model paling optimal dalam memprediksi degradasi turbin berbasis data sensor, sebagai dasar pengambilan keputusan dalam pemeliharaan prediktif.

Keakuratan model didukung oleh penggunaan *Health Index* hasil PCA dari fitur-fitur sensor yang diseleksi dengan *mutual information*, serta pembentukan data sekuens. Pendekatan ini menyederhanakan input dan memperkuat sensitivitas model terhadap tren degradasi yang berkembang secara bertahap. Namun, cakupan data yang hanya berasal dari satu unit pembangkit masih menyisakan ruang untuk pengujian lintas lokasi guna mengevaluasi generalisasi model.

Sebagai pengembangan ke depan, hasil prediksi RUL dari model BiLSTM dapat digunakan sebagai input dalam sistem pengambilan keputusan otomatis berbasis pendekatan *reinforcement learning*. Selain itu, perlu dilakukan evaluasi model pada data *multi-site* atau lintas unit pembangkit untuk menguji *robust* dan transferabilitas model. Penelitian mendatang juga dapat mengeksplorasi penggunaan model-model baru yang semakin berkembang dalam domain *time series forecasting*. Dengan begitu sistem pemeliharaan dapat ditingkatkan menjadi lebih cerdas, proaktif, dan efisien dalam menghadapi dinamika operasional PLTU yang kompleks.

UCAPAN TERIMAKASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada seluruh pihak yang telah memberikan dukungan dalam penyusunan jurnal ini, khususnya kepada instansi yang telah menyediakan data operasional peralatan *bearing* turbin yang sangat penting bagi analisis dan eksperimen dalam penelitian ini. Sebagai bagian dari upaya peningkatan kualitas penulisan, penulis juga memanfaatkan teknologi *Large Language Model (LLM)* dalam mengoreksi, menyusun ulang, dan memperbaiki struktur kalimat agar lebih jelas, akademis, dan sesuai dengan kaidah penulisan ilmiah.

DAFTAR PUSTAKA

- [1] M. Bělohoubek, K. Liška, Z. Kubín, P. Polcar, L. Smolík dan P. Polach, "An Investigation of Efficiency Issues in a Low-Pressure Steam Turbine Using Neural Modelling," *Sensors*, vol. 24, no. 7, p. 2056, 2024.
- [2] H. Peng, H. Zhang, L. Shangguan dan Y. Fan, "Review of Tribological Failure Analysis and Lubrication Technology Research of Wind Power Bearings," *Polymers*, p. 14, 2022.
- [3] S. Pashami, S. Nowaczyk, Y. Fan, J. Jakubowski, N. Paiva, N. Davari, S. Bobek, S. Jamshidi, H. Sarmadi, A. Alabdallah, B. V. Rita P. Ribeiro, M. Sayed-Mouchaweh, L. Rajaoarisoa dan G. J. Nalepa, "Explainable Predictive Maintenance," 2023.
- [4] M. Kraus dan S. Feuerriegel, "Forecasting remaining useful life: Interpretable deep learning approach via variational Bayesian inferences," *Decision Support Systems*, vol. 125, p. 113100, 2019.
- [5] M. Pirani, P. Thakkar, P. Jivrani, M. H. Bohara dan D. Garg, "A Comparative Analysis of ARIMA, GRU, LSTM and BiLSTM on Financial Time Series Forecasting," dalam *2022 IEEE International Conference on Distributed Computing and Electrical Circuits and Electronics (ICDCECE)*, Ballari, India, 2022.
- [6] Y. Li, X. Qin, F. Ma, H. Wu, M. Chai, F. Zhang, F. Jiang dan X. Lei, "Fusion Technology-Based CNN-LSTM-ASAN for RUL Estimation of Lithium-Ion Batteries," *Sustainability*, vol. 16, no. 21, p. 9223, 2024.
- [7] P. R. d. O. d. Costa, J. Rhuggenaath, Y. Zhang dan A. Akcay, "Learning 2-opt Heuristics for the Traveling Salesman Problem via Deep Reinforcement Learning," dalam *In Proceedings of the Asian Conference on Machine Learning (ACML 2020)*, PMLR, 2020.

- [8] S. Sayyad, S. Kumar, A. Bongale, K. Kotecha dan A. Abraham', "Remaining Useful-Life Prediction of the Milling Cutting Tool Using Time-Frequency-Based Features and Deep Learning Models," *Sensors*, vol. 23, no. 12, p. 5659, 2023.
- [9] D. Zhao, H. Li, F. Zhou, Y. Zhong, G. Zhang, Z. Liu dan J. Hou, "Research Progress on Data-Driven Methods for Battery States Estimation of Electric Buses," *World Electric Vehicle Journal*, vol. 14, no. 6, p. 145, 2023.
- [10] X. Tang, H. Wan, W. Wang, M. Gu, L. Wang dan L. Gan, "Lithium-Ion Battery Remaining Useful Life Prediction Based on Hybrid Model," *Sustainability*, vol. 15, no. 7, p. 6261, 2023.
- [11] K. Basulaiman dan M. Barati, "Sequence-to-Sequence Forecasting-aided State Estimation for Power Systems," dalam *2021 IEEE Texas Power and Energy Conference (TPEC)*, College Station, TX, USA, 2021.
- [12] Y. Hu, Y. Bai, E. Fu dan P. Liu, "A Novel Remaining Useful Life Probability Prediction Approach for Aero-Engine with Improved Bayesian Uncertainty Estimation Based on Degradation Data," *Applied Sciences*, vol. 13, no. 16, p. 9194, 2023.
- [13] Y. Liu, J. Liu, H. Wang, M. Yang, X. Gao dan S. Li, "A Remaining Useful Life Prediction Method of Mechanical Equipment Based on Particle Swarm Optimization-Convolutional Neural Network-Bidirectional Long Short-Term Memory," *Machines*, vol. 12, no. 5, p. 342, 2024.
- [14] V. Plotnikova, M. Dumas dan F. Milani, "Adaptations of data mining methodologies: a systematic literature review," *PeerJ Computer Science*, 2020.
- [15] C. Schröer, F. Kruse dan J. M. Gómez, "A Systematic Literature Review on Applying CRISP-DM Process Model," *Procedia Computer Science*, vol. 181, pp. 526-534, 2021.
- [16] D. T. Wiranata, T. Prahasto dan A. Widodo, "Analisis Prognostik Terhadap Kerusakan Bantalan Pada Poros Kecepatan Tinggi Turbin Angin Menggunakan Machine Learning Dengan Pendekatan Support Vector Regression (SVR)," *Jurnal Teknik Mesin Universitas Diponegoro*, vol. 9, 2021.
- [17] A. Dokumentov dan R. J. Hyndman, "STR: Seasonal-Trend Decomposition Using Regression," *INFORMS Journal on Data Science*, 2020.
- [18] R. C. Ripan, I. H. Sarker, M. M. Anwar, M. H. Furhad, F. Rahat, M. M. Hoque dan M. Sarfraz, "An Isolation Forest Learning Based Outlier Detection Approach for Effectively Classifying Cyber Anomalies," *International Conference on Health Information Science*, 2020.
- [19] Y. Xia dan G. M. J. Barca, "Machine-Learning-Driven Runtime Optimization of BLAS Level 3 on Modern Multi-Core Systems," *arXiv*, 2024.
- [20] A. Omogbai, "Application of multiview techniques to NHANES dataset," *arXiv.org*, 2016.
- [21] J. Farshad dan C. Arthur, "Striking a New Chord: Neural Networks in Music Information Dynamics," *arXiv.org*, 2024.
- [22] S. Zhang, M. Wang, W. Wang, J. Gao, W. Zhao dan Y. Yang, "GLINT-RU: Gated Lightweight Intelligent Recurrent Units for Sequential Recommender Systems," *Knowledge Discovery and Data Mining*, 2024.
- [23] J.-H. Lee dan J.-K. Hong, "Comparative Performance Analysis of RNN Techniques for Predicting Concatenated Normal and Abnormal Vibrations," *Electronics*, 2023.
- [24] O. Ozupek, R. Yilmaz, B. Ghasemkhani, D. Birant dan R. A. Kut, "A Novel Hybrid Model (EMD-TI-LSTM) for Enhanced Financial Forecasting with Machine Learning," *Mathematics*, 2024.
- [25] M. I. Rifki, A. Ikhwan dan F. Muhammad, "Performance Evaluation of RSSI Prediction Methods in Wireless Communication Networks," *Zero: Jurnal Sains, Matematika, dan Terapan*, vol. 8, pp. 14-25, 2024.
- [26] W. Li, X. Li, Q. Niu, T. Huang, D. Zhang dan Y. Dong, "Analysis and Treatment of Shutdown Due to Bearing Vibration Towards Ultra-supercritical 660MW Turbine," dalam *IOP Conference Series: Earth and Environmental Science*, 2019.