

Prediksi *Remaining Useful Life* Mesin Turbofan Menggunakan Metode Deep Layer Recurrent Neural Networks

Kevin Maulana Risky¹, Fitri Insani^{2*}, Jasril³, Suwanto Sanjaya⁴, Lestari Handayani⁵,

^{1,2,3,4,5} Program Studi Teknik Informatika, Fakultas Sains dan Teknologi,

Universitas Islam Negeri Sultan Syarif Kasim Riau

*Email: fitri.insani@uin-suska.ac.id

Abstrak

Dalam beberapa tahun terakhir, perkembangan prognostic dan manajemen kesehatan pada mesin dan sistem telah berkembang pesat. Salah satu bentuk interaksinya adalah memprediksi sisa berguna umur pada mesin turbofan pesawat. Penelitian ini, menggunakan metode prediksi Deep Learning RNN dengan LSTM sebagai arsitekturnya. Dataset C-MAPSS FD001 digunakan sebagai dataset pemodelan yang didalamnya terdapat data multivariate yang kompleks. Tujuan utama dalam proses analisis dan pemodelan ini adalah untuk mendapatkan hasil prediksi sisa berguna umur yang dapat menjadi patokan dalam analisa *Remaining Useful Life* (RUL) mesin turbofan tersebut. Hasil pengujian melibatkan banyak kriteria serta parameter yang diujicobakan diantaranya adalah learning rate, jumlah epoch, hidden unit, metode normalisasi yang digunakan hingga metode optimizer. Analisa hasil menunjukkan bahwa model yang dengan kriteria learning rate 0.001, jumlah epoch sebanyak 50, hidden unit 12, metode normalisasi Min-max, serta optimizer Adam yang diujicobakan dapat memahami dengan cukup akurat pola data RUL dan mengikuti pergerakan target RUL yang telah ditentukan sebelumnya. Meskipun terdapat penurunan dan sedikit lonjakan pada jenjang unit mesin 81 hingga 84, dengan nilai error pada RMSE sebesar 26.48, tetapi secara keseluruhan model dapat dianggap optimal dalam mempelajari pola prediksi target RUL. Penelitian ini menunjukkan bahwa model RNN-LSTM memiliki potensi besar dalam aplikasi prognostic mesin turbofan pesawat.

Kata kunci: Deep learning, long short term memory, mesin turbofan, prognostik, recurrent neural networks, sisa berguna umur

Abstract

In recent years, the development of prognostic and health management in engines and systems has grown rapidly, with one form of interaction being predicting the remaining useful life of aircraft turbofan engines. In this study, chose to use the Deep Learning RNN method with LSTM architecture. And in its limitation, the C-MAPSS FD001 dataset is used as a modeling dataset in which there is complex multivariate data. The main objective in this analysis and modeling process is to obtain the remaining useful life prediction results that can be a benchmark in analyzing the *Remaining Useful Life* (RUL) of the turbofan engine. The test results involved many criteria and parameters that were tested. Analysis of the results shows that the model with learning rate criteria of 0.001, number of epochs of 50, hidden unit of 12, Min-max normalization method, and Adam optimizer tested can understand quite accurately the RUL data pattern and follow the movement of the predetermined RUL target. Although there is a decrease and a slight spike in the unit level of machines 81 to 84, with an error value in RMSE of 26.48, but overall the model can be considered optimal in learning the prediction pattern of the RUL target. This research shows that the RNN-LSTM model has great potential in aircraft turbofan engine prognostic applications.

Keywords: Deep learning, long short term memory, turbofan machine, prognostic, recurrent neural networks, remaining useful life

PENDAHULUAN

Dalam beberapa tahun terakhir, bidang ilmu prognostik telah mengalami perkembangan yang signifikan. Pemahaman umum mengenai masalah prediksi kesehatan pada suatu mesin ataupun sistem telah berkembang pesat (Wang et al., 2019). Dengan dibuktikannya dari penelitian sebelumnya (Aivaliotis et al., 2019) berbasis *Data-Driven* maupun berbasis ilmu fisika. Dalam sebagian besar kasus, data hanya mencakup tanda-tanda kerusakan yang semakin parah dengan tingkat keparahan yang beragam, namun hanya sedikit data yang mencatat dan merekam perkembangan hingga mencapai titik kegagalan (Ramasso & Saxena, 2014).

Pada bidang *Prognostics and Health Management* (PHM), perhatian utamanya tertuju pada optimalisasi pemanfaatan sinyal-sinyal sensor yang diperoleh dari sistem rekayasa. Tujuan utamanya adalah melakukan pemantauan terhadap kondisi kesehatan, mendeteksi anomali, mendiagnosa kegagalan, dan yang tak kalah pentingnya, meramalkan masa pakai sistem yang dapat dimanfaatkan selama masa operasionalnya. Pendekatan ini menciptakan landasan yang lebih alami untuk memahami dan meningkatkan kinerja sistem secara keseluruhan (Rezaeianjouybari & Shang, 2020).

Dalam konteks penelitian terkait prognostik mesin, terutama pada mesin *turbofan*, pentingnya lintasan *run-to-failure* pada data menjadi aspek yang sangat krusial untuk meningkatkan realisme pengujian. Persyaratan utamanya adalah dengan adanya *model* sistem yang sesuai dan kemampuan untuk menyesuaikan variasi kesehatan, komponen dan sub-sistem, serta dapat melakukan simulasi pengukuran sensor dengan akurat (Chao et al., 2021). Karena batasan tersebut, hadirilah sebuah repositori data prognostik yang berasal dari *model* simulasi mesin *turbofan* yang diberi nama *dataset C-MAPSS* (*Commercial Modular Aero-Propulsion System Simulation*) yang memiliki *model* yang dinamis (Chao et al., 2021).

C-MAPSS merupakan representasi *Component Level Model* (CLM) dari mesin *turbofan* komersial yang menggunakan konfigurasi *dual-spool* dan tingkat umpan udara yang tinggi. Secara umum, *dataset* ini sering digunakan dalam lingkungan MATLAB/Simulink, memberikan tingkat fleksibilitas yang tinggi dalam proses implementasi dan interaksi dengan perangkat lunak pengguna (Frederick et al., 2007).

Dalam penelitian lainnya, *dataset C-MAPSS* tetap menjadi rujukan utama untuk melakukan simulasi dan membangun dasar ilmiah dalam bidang prognostik. Hal ini dikarenakan sifat istimewa dari *dataset C-MAPSS*, yang mencerminkan sistem yang sangat kompleks, bersifat *non-linear*, dan sangat mendekati data yang dapat ditemukan dalam sistem aslinya (Chao et al., 2021). Dengan memanfaatkan *dataset C-MAPSS*, para peneliti dapat menjembatani kesenjangan antara simulasi dan kondisi nyata, menciptakan landasan yang kokoh untuk pengembangan *model* prognostik yang lebih canggih.

Setiap *dataset* memiliki karakteristik unik berupa variasi dalam jumlah unit pelatihan dan unit pengujian, serta perbedaan dalam jumlah sensor yang terlibat dalam pengukuran. Sebagai contoh yang digunakan dalam penelitian ini pada *dataset FD001*, terdapat 21 jenis pengukuran sensor yang berbeda. Keberagaman ini menciptakan kompleksitas tambahan dalam analisis dan pengembangan *model*, mengingat adanya variasi signifikan dalam kondisi operasional dan jumlah *parameter* yang terlibat.

Dalam melakukan prognostik dan prediksi sisa berguna umur, pendekatan yang umum digunakan adalah melalui teknik *Data-Driven* dengan penerapan metode *Deep Learning*. Salah satu penelitian yang ada, menggunakan metode *Deep Learning Recurrent Neural Networks* (RNN) untuk memprediksi nilai RUL pada mesin *turbofan*, di dapatkan nilai errornya dari pembuktian pengecekan dengan nilai *Root Mean Square Error* (RMSE) sebesar 0.203% dan lebih rendah dari 3 metode yang telah dilakukan pengujian pada penelitian tersebut, yang membuktikan kemampuan RNN dapat mengenali pola dan memodelkan fitur dengan lebih baik (Thakkar, 2021). RNN memiliki beberapa arsitektur yang lebih baik dalam penanganan data sekuensial dengan melibatkan *memory* jangka panjang, salah satunya adalah *Long Short Term Memory* (LSTM).

Salah satu penelitian yang dilakukan oleh (Karnik et al., 2023) yang membahas tentang prediksi RUL *Turbofan* tersebut dengan konfigurasi *Proposed LSTM* yang diajukan, mendapatkan nilai RMSE terbaik sebesar 14.28% dibandingkan dengan metode lain yang diujikan pada penelitian tersebut.

Dengan merujuk pada penelitian terdahulu dan memperhatikan berbagai

konfigurasi *model* LSTM yang akan diusulkan pada penelitian sebelumnya, penulis bertujuan untuk menerapkan *model* LSTM dengan konfigurasi yang tepat untuk memprediksi sisa umur berguna mesin *turbofan* berdasarkan data *time series* dari NASA C-MAPSS. Melalui evaluasi menggunakan *Root Mean Square Error* (RMSE), penelitian ini akan mengevaluasi akurasi metode LSTM dalam memprediksi sisa umur berguna pada mesin *turbofan* tersebut.

TINJAUAN PUSTAKA

Remaining Useful Life (RUL) adalah *parameter* krusial dalam mengevaluasi penurunan performa sebuah mesin. *Parameter* ini memiliki dampak langsung pada akurasi pengambilan keputusan terkait pemeliharaan, yang pada akhirnya mempengaruhi keandalan operasional mesin tersebut (Mu et al., 2021).

Proses ini melibatkan identifikasi kondisi komponen melalui pengumpulan data dari sensor pemantauan, seperti sinyal getaran, serta memanfaatkan metode berbasis *model* dan fisika, berbasis data, atau kombinasi keduanya. RUL yang diprediksi diungkapkan sesuai dengan pengukuran utama sistem, contohnya, kilometer untuk mobil dan siklus untuk pesawat komersial (Ferreira & Gonçalves, 2022).

2.1. Dataset C-MAPSS

Turbofan merupakan varian yang mirip dengan *turbojet* yang digunakan untuk menggerakkan sistem propulsi. Perbedaan yang mencolok terdapat adanya kipas berukuran besar yang terletak di bagian depan mesin *turbofan*, disusul dengan adanya turbin tekanan rendah di belakang ruang pembakaran. Kipas besar di bagian depan bertanggung jawab untuk menarik udara ke dalam mesin, sementara turbin tekanan rendah di bagian belakang memainkan peran penting dalam mengubah energi gas buang menjadi daya dorong tambahan. Keberadaan keduanya menciptakan dinamika yang kompleks dan memberikan kontribusi besar terhadap kinerja efisiensi mesin *turbofan* (Wei, 2023).

Dataset C-MAPSS sering dijadikan bahan penilaian pengukuran penurunan kinerja mesin *Turbofan* oleh para peneliti. *Dataset* ini terdiri dari empat kelompok *dataset* mesin yang dapat dilihat pada Gambar 1, dengan variasi jumlah kondisi kerja dan kondisi cacat. Setiap *sub-dataset* dibagi menjadi *subset* pelatihan dan uji, dan masing-masing terdiri dari 26 kolom. Id unit mesin menjadi kolom pertama, kolom kedua

mencerminkan siklus operasi, sementara kolom 3-5 memberikan deskripsi tentang tiga pengaturan rezim operasi. Sementara itu, 21 pengukuran sensor tertuang dalam kolom 6-26 (Remadna et al., 2020).

Datasets	Data FD	Fault Modes	Conditions	Train Units	Test Unit
C-MAPSS Dataset	FD001	1	1	100	100
	FD002	1	6	260	259
	FD003	2	1	100	100
	FD004	2	6	249	248

Gambar 1. *Dataset* degradasi C-MAPSS (Ramasso & Saxena, 2014)

2.2. Data Mining

Data mining adalah tahap dalam proses penemuan pengetahuan dalam basis data yang melibatkan penerapan algoritma analisis dalam penemuan data. Dengan memperhatikan batasan efisiensi komputasi yang dapat diterima, langkah ini bertujuan menghasilkan suatu enumerasi pola khusus yang dapat diidentifikasi dalam data. Dalam konteks ini, penambahan data menjadi semacam "pencarian" pola yang dilakukan oleh algoritma, memungkinkan kita untuk mengeksplorasi dan memahami struktur data secara lebih mendalam. Proses ini menjadi esensial untuk mengungkap pengetahuan yang mungkin tersembunyi di dalam basis data tersebut (Gupta & Chandra, 2020).

2.3. Pra-pemrosesan

Pra-pemrosesan data merupakan salah satu tahapan yang umum dalam melakukan *data mining*. Tahap ini melibatkan serangkaian langkah untuk mengelola dan menyusun ulang data agar dapat digunakan secara efektif dalam proses *mining*. Pada tahap ini, tujuan utamanya adalah untuk mengurangi ukuran data, menemukan keterkaitan antar data, melakukan normalisasi data, menghilangkan data yang tidak representatif, serta mengekstrak ciri-ciri penting dari data (Saraswat & Raj, 2022).

Dengan melakukan langkah-langkah dalam pra-pemrosesan, data yang semula mungkin tidak terstruktur atau tidak cocok langsung untuk diproses oleh algoritma mesin, menjadi siap untuk dianalisis dengan cepat dan efisien. Hal ini memungkinkan *model machine learning* untuk dengan cepat mengenali pola-pola, hubungan, atau karakteristik yang ada

dalam data, membantu dalam membuat prediksi atau pengambilan keputusan berdasarkan informasi yang terkandung dalam data tersebut (Maharana et al., 2022).

2.4. Pemilihan Fitur

Seleksi fitur adalah langkah untuk memilih sekelompok fitur yang lebih kecil namun tetap informatif dari fitur-fitur aslinya. Dalam tugas klasifikasi, tujuan seleksi fitur adalah mencari *subset* fitur terkecil yang diperlukan dan memadai untuk menjelaskan label kelas (Nguyen et al., 2020).

Fitur merupakan faktor utama dalam menentukan hipotesis dari *model* prediksi. Jumlah fitur dan ruang hipotesis memiliki keterkaitan langsung, di mana semakin banyak fitur, semakin besar pula ruang hipotesisnya. Sebagai contoh, jika terdapat M fitur dengan label kelas *biner* dalam sebuah *dataset*, maka ruang pencarian akan memiliki 2 pangkat M kemungkinan. Reduksi ruang hipotesis bisa dilakukan dengan menghapus fitur-fitur yang tidak diperlukan dan tidak relevan (Venkatesh & Anuradha, 2019).

2.5. Normalisasi Data

Normalisasi adalah proses yang dilakukan pada data mentah untuk mengubahnya sehingga setiap fitur memiliki kontribusi yang seragam. Tujuannya adalah mengatasi dua masalah utama dalam data yang dapat menghambat proses pembelajaran algoritma *machine learning*, yakni keberadaan fitur yang dominan dan adanya *outliers* (Singh & Singh, 2020).

Dalam beberapa *dataset* yang harus kita atur, seringkali terdapat perbedaan besar antara nilai-nilai fitur, seperti nilai maksimum dan minimum, misalnya, 0.001 dan 10.000. Umumnya, keadaan ini tidak diinginkan dan memerlukan intervensi yang hati-hati untuk melakukan transformasi penurunan skala sehingga semua nilai atribut menjadi sesuai dan dapat diterima (Alexandropoulos et al., 2019).

2.6. Exponentially Weighted Average

Exponentially Weighted Moving Average sering digunakan untuk menganalisis rangkaian data yang diurutkan berdasarkan waktu, yang terdiri dari variabel acak. Metode ini menghasilkan rata-rata tertimbang dari rangkaian tersebut dengan menerapkan bobot yang secara geometris menurun seiring dengan

usia observasi (Perry, 2011)(Dudek et al., 2022). Persamaannya adalah sebagai berikut.

$$l_t = \alpha \frac{y_t}{s_t} + (1 - \alpha)l_{t-1} \quad (1)$$

Keterangan :

l_t = Nilai EWA pada waktu t .

α = Faktor peluruhan.

y_t = Nilai observasi pada waktu t .

s_t = Standar deviasi pada waktu t .

l_{t-1} = Nilai pada waktu lalu.

2.7. Recurrent Neural Networks

Recurrent Neural Network (RNN) adalah salah satu algoritma pembelajaran mesin yang menggunakan pemrosesan informasi dari data dan termasuk dalam kategori algoritma *deep learning*. Dengan melakukan perulangan di dalam strukturnya, RNN dapat menyimpan pola-pola informasi masa lalu untuk memastikan kelangsungan penyimpanan informasi tersebut (Nurashila et al., 2023).

Struktur dasar RNN terdiri dari *unit hidden layer* yang dijadikan sebagai parameter inputan di tahapan selanjutnya. Ini memungkinkannya untuk menangkap informasi kompleks dari urutan data yang masuk dan berfungsi sebagai "memori" jaringan dengan menyimpan informasi dari langkah waktu sebelumnya dan meneruskannya ke langkah waktu berikutnya. Inilah yang memungkinkan RNN untuk mempertahankan pemahaman konteks dari urutan data dalam rentang waktu yang lebih luas (Nurashila et al., 2023).

2.8. Long Short Term Memory

Recurrent networks dalam jaringan saraf memberikan peningkatan kinerja dengan memungkinkan pemahaman pola urutan data. Namun, memori yang dihasilkan dari koneksi tersebut dapat terbatas karena algoritma pelatihan yang digunakan. Pada kebanyakan *model* yang ada seringkali mengalami kendala dalam proses belajar dan menyesuaikan informasi, yang membuat jaringan kesulitan memahami pola urutan data dalam jangka waktu yang panjang. Untuk menangani masalah tersebut, beberapa *model* spesifik telah dikembangkan, dan yang paling terkenal di antaranya adalah jaringan saraf berulang yang dikenal sebagai *Long Short-Term Memory* (LSTM). LSTM menjadi salah satu teknik yang paling populer dan efisien dalam mengatasi efek

gradien yang berlebihan (Ridla et al., 2023).

Berikut adalah bentuk persamaannya.

$$\begin{aligned} i_t &= \sigma(w_i[h_{t-1}, x_t] + b_i) \\ f_t &= \sigma(w_f[h_{t-1}, x_t] + b_f) \\ o_t &= \sigma(w_o[h_{t-1}, x_t] + b_o) \end{aligned} \quad (2)$$

Keterangan :


i_t = Gerbang *input*.
 f_t = Gerbang *forget*.
 o_t = Gerbang *output*.
 w_x = Bobot nilai gerbang (x).
 h_{t-1} = Output LSTM sebelumnya.
 x_t = Input waktu saat ini.
 b_x = Bias pada gerbang (x).

Evaluasi RMSE

Root Mean Square Error (RMSE) telah menjadi metrik statistik standar yang sering digunakan untuk mengukur kinerja *model* dalam studi-studi meteorologi, kualitas udara, dan penelitian iklim. Setiap pengukuran statistik menggabungkan banyak data ke dalam satu nilai, sehingga hanya menyoroti satu sudut pandang tentang kesalahan *model* yang menekankan aspek tertentu dari karakteristik kesalahan dalam kinerja *model* (Hodson, 2022).

METODE PENELITIAN

Metodologi penelitian merujuk pada serangkaian langkah yang dirancang untuk mencapai tujuan penelitian yang diinginkan. Ini mencakup deskripsi proses dan metode yang akan digunakan untuk mengarahkan jalannya penelitian agar sesuai dengan tujuan awal.



Gambar 2. Tahapan penelitian

1. Pengumpulan Data

Dalam penelitian ini, digunakan *dataset* dari salah satu sumber terbuka yang berasal dari simulasi data mesin *jet* yang disediakan oleh NASA (*National Aeronautics and Space Administration*) yang dapat diakses melalui situs berikut: <https://data.nasa.gov/Aerospace/CMAPSS-Jet-Engine-Simulated-Data/ff5v-kuh6>.

Terdapat 3 *file dataset* seperti yang terlihat pada Tabel 1 yang disediakan dalam *folder* C-MAPSS yang terdiri dari data *train_FD001*, *test_FD001* dan *RUL_FD001*. Pada penelitian ini akan menggunakan beberapa fitur yang akan diperoleh dari proses seleksi fitur dengan melihat nilai *stagnant* hasil dari visualisasi dari masing-masing *file dataset*.

Tabel 1. Struktur *folder* C-MAPSS

No	Nama File
1.	train_FD001
2.	test_FD001
3.	RUL_FD001

2. Validasi dan seleksi fitur

Langkah ini merupakan analisis terhadap data sensor yang tersedia untuk menentukan sensor mana yang paling informatif dan mempengaruhi kinerja mesin secara signifikan. Proses ini membantu untuk mengurangi dimensi data dan fokus pada fitur-fitur yang memberikan informasi kunci bagi prediksi kerusakan atau keandalan mesin. Dalam *dataset* C-MAPSS terdapat beberapa variabel pengukuran yaitu, *unit number*, *time cycles*, *operation settings* 1, 2 dan 3 serta *sensor measurements* 1 hingga 21.

Fitur yang akan dipilih dalam penelitian kali ini akan menghapus beberapa sensor yang dianggap tidak bermanfaat dalam prediksi. Pada tahapan ini akan dilakukan proses *dropping* fitur yang dianggap tidak memberikan kontribusi terhadap hasil prediksi serta tidak memberikan hasil yang konsisten dan pola yang jelas terhadap target prediksi, diantaranya adalah *field operation setting* 3, sensor 1, 5, 6, 10, 16, 18 dan 19.

3. Pra-pemrosesan

Tahapan ini merupakan proses normalisasi menggunakan metode *Min-Max Scaling*, yang bertujuan untuk mengubah nilai-

nilai dalam setiap fitur menjadi rentang antara 0 dan 1. Normalisasi menggunakan metode *Min-Max Scaling*, di mana setiap fitur telah diubah ke dalam rentang antara 0 dan 1. Misalnya, nilai-nilai seperti *os1*, *os2*, *s2*, *s3*, *s4*, *s7*, *s8*, *s9*, *s11*, *s12*, *s13*, *s14*, *s15*, *s17*, *s20*, *s21* yang sebelumnya mungkin memiliki variasi nilai yang berbeda-beda, sekarang telah disesuaikan agar memiliki nilai yang terstandarisasi.

4. Pemodelan dengan LSTM

Pada tahapan dan proses ini akan dilakukan pemodelan dengan arsitektur LSTM sebagai metode arsitektur dari RNN yang akan melibatkan sejumlah pengujian dengan iterasi dan *epoch* tertentu dengan *Hyperparameter* yang akan ditentukan sebelumnya. Proses pelatihan dimulai di mana *model* LSTM kita mulai belajar dari data pelatihan yang telah disiapkan sebelumnya. Terdapat proses pengecekan untuk melihat apakah satu putaran pelatihan penuh *epoch* sudah selesai. Jika iya, kita memeriksa apakah sudah mencapai jumlah maksimum *epoch* yang diinginkan. Jika belum, kita kembali menghitung kerugian pada setiap *batch* data pelatihan hingga selesai pada iterasi terakhir.

5. Prediksi dan evaluasi

Setelah mencapai batas maksimum *epoch*, pelatihan selesai dan akan beralih ke tahap pengujian. Dalam proses ini akan menggunakan data pengujian untuk melihat seberapa baik *model* LSTM kita bekerja. Jika masih kurang, kita kembali ke tahap awal untuk melakukan penyesuaian pada *model*. Namun, jika hasil prediksi dari *model* LSTM sudah cukup baik, kita mendapatkan *output* prediksi yang akurat.

Dan pada tahapan terakhir akan dilakukan proses evaluasi menggunakan metrik RMSE, hasil dari metrik ini akan melakukan dan memberikan evaluasi serta pemahaman tentang performa *model* LSTM pada *dataset* C-MAPSS yang diuji, interpretasi dari RMSE akan menandakan seberapa jauh rata-rata kesalahan prediksi *model* dari kondisi aktual. Hal ini akan menjadi panduan utama dalam mengevaluasi keakuratan *model* LSTM dalam memprediksi kerusakan pada mesin *turbofan*.


HASIL DAN PEMBAHASAN

Pengujian serta pemrosesan *dataset* diproses menggunakan bahasa pemrograman

python dan hasil dari prediksi akan dijelaskan pada bagian pembahasan ini.

A. Pemilihan fitur

Pada tahapan ini menunjukkan bagaimana nilai-nilai sensor dari sebuah mesin spesifik dalam *dataset* pelatihan C-MAPSS *turbofan* berubah seiring berjalannya waktu menuju kegagalan. Setiap subgrafik dalam visualisasi ini menggambarkan tren nilai sensor dari waktu ke waktu.



Gambar 3. Visualisasi data

Setelah hasil visualisasi didapatkan, tahapan selanjutnya adalah melakukan *dropping* terhadap fitur yang tidak memberikan hasil yang bagus terhadap prediksi, dari hasil visual didapatkan sensor yang memiliki nilai *stagnan* diantaranya adalah sensor 1, 5, 6, 10, 16, 18 dan 19 serta 1 *operation conditions* yang pada tahapan ini menghapus kolom-kolom tersebut yang terlihat pada Gambar 4.

unit	time	os1	os2	s2	s3	s4	s7	s8	s9	s11	s12	s13	s14	s15	s17	s20	s21	rd	
0	1	1	0.0007	0.0004	0.4112	1569.70	1405.80	1584.36	2388.06	9046.19	47.47	521.06	2388.02	8138.82	8.4195	362	38.06	23.4760	191
1	1	2	0.0019	0.0003	0.4215	1591.82	1403.14	1553.75	2388.04	9044.37	47.46	522.28	2388.07	8131.49	8.4118	362	38.06	23.4206	196
2	1	3	0.0043	0.0003	0.4335	1587.99	1404.20	1564.26	2388.08	9052.34	47.37	522.42	2388.03	8133.23	8.4178	360	38.06	23.3442	186
3	1	4	0.0007	0.0000	0.4335	1582.79	1401.87	1564.45	2388.11	9046.48	47.13	523.96	2388.08	8133.83	8.3682	362	38.06	23.3759	188
4	1	5	0.0019	0.0002	0.4337	1582.85	1408.22	1564.00	2388.06	9055.15	47.28	522.19	2388.04	8133.80	8.4294	360	38.06	23.4044	187


unit	time	os1	os2	s2	s3	s4	s7	s8	s9	s11	s12	s13	s14	s15	s17	s20	s21	rd	
0	1	1	0.0023	0.0003	0.4302	1565.29	1398.21	1553.60	2388.08	9050.17	47.26	521.72	2388.03	8126.56	8.4052	362	38.06	23.3735	184
1	1	2	0.0007	0.0001	0.4417	1588.45	1395.45	1545.36	2388.01	9056.42	47.50	522.60	2388.06	8139.20	8.4033	363	38.02	23.3918	193
2	1	3	0.0003	0.0001	0.4408	1588.00	1401.34	1554.13	2388.03	9054.90	47.51	521.97	2388.03	8130.10	8.4441	363	38.02	23.4196	194
3	1	4	0.0042	0.0002	0.4244	1562.44	1406.45	1546.07	2388.03	9045.29	47.49	524.38	2388.05	8129.54	8.3937	391	38.00	23.2737	195
4	1	5	0.0014	0.0000	0.4551	1587.19	1391.40	1554.16	2388.01	9044.57	47.31	522.15	2388.03	8129.60	8.4031	360	38.06	23.3910	183

Gambar 4. Hasil *drop* data *train* dan *test* yang *stagnan*

B. Normalisasi pada data

Tahapan ini merupakan proses normalisasi menggunakan metode *Min-Max Scaling*, yang bertujuan untuk mengubah nilai-nilai dalam setiap fitur menjadi rentang antara 0 dan 1. Dapat dilihat hasil nilai setelah proses normalisasi menggunakan metode *Min-Max Scaling*, di mana setiap fitur telah diubah ke dalam rentang antara 0 dan 1. Misalnya, nilai-nilai seperti *os1*, *os2*, *s2*, *s3*, *s4*, *s7*, *s8*, *s9*, *s11*, *s12*, *s13*, *s14*, *s15*, *s17*, *s20*, *s21* yang sebelumnya mungkin memiliki variasi nilai yang


berbeda-beda, sekarang telah disesuaikan agar memiliki nilai yang terstandarisasi.




Gambar 5. Data hasil normalisasi

C. Implementasi *Exponentially Weighted Average*

Untuk mengatasi *noise* yang masih terdapat pada data hasil setelah normalisasi menggunakan metode *Min-Max*, langkah selanjutnya yang diambil adalah melakukan proses *smoothing*. Hasil pada Gambar 6 adalah data yang telah disaring dari fluktuasi dan *noise* yang tidak diinginkan, sehingga memberikan representasi yang lebih akurat tentang tren atau pola yang ada dalam *dataset* terlihat pula perbandingan antara data setelah normalisasi yang masih memiliki *noise* yang berlebih dan setelah dilakukan *smoothing*, terlihat data lebih stabil dan *noise* lebih berkurang terlihat pada Gambar 7.



Gambar 6. Pergerakan data *train* setelah dilakukan *smoothing* dengan EWA




Gambar 7. Perbandingan data sebelum dan setelah *smoothing*

D. Membangun *model* prediksi

Sebelum proses pelatihan dimulai, *model* LSTM untuk regresi dikonfigurasi dengan beberapa lapisan *linear* yang diikuti oleh aktivasi ReLU sebelum mencapai *output* akhir. Untuk mempersiapkan *model*, parameter-parameter diinisialisasi menggunakan metode *He initialization*, yang membantu menyesuaikan bobot agar tidak mengalami kendala gradien yang dapat menghambat pembelajaran. Nilai bias diatur ke nol konstan, memastikan titik awal yang konsisten selama proses pembelajaran.

Tabel 1. *Hyperparameter* pada *model*

Parameter	Nilai
Window Size	20
Unit Hidden	12
Epoch	50
Learning Rate	0.001
Batch Size	64
Normalize	Min-max
Optimizer	Adam



Gambar 8. Performa *model* selama pelatihan

Gambar 8 menunjukkan performa *model* selama proses pelatihan dengan dua garis yang mewakili *loss* pada data pelatihan (garis oranye) dan *loss* pada data validasi (garis biru). Garis merah menunjukkan tren penurunan yang konsisten pada *loss* data pelatihan seiring berjalannya *epoch*, menandakan bahwa *model*


terus belajar dan meningkatkan performanya pada data *training*.

Demikian pula, garis biru juga menunjukkan penurunan pada *loss* data validasi, menunjukkan bahwa model juga berhasil mengoptimalkan kinerjanya pada data yang tidak digunakan selama pelatihan. Perlu diperhatikan bahwa *loss* pada data *training* selalu lebih rendah daripada *loss* pada data validasi, yang wajar karena model diuji pada data yang tidak dipelajari sebelumnya.

E. Hasil prediksi RUL

Pada Gambar 9 menunjukkan hasil prediksi *model* terhadap RUL pada *turbofan*, di mana sumbu X menunjukkan *unit* mesin uji dan sumbu Y menunjukkan RUL dalam satuan waktu. Garis oranye menunjukkan prediksi RUL oleh *model*, sementara garis hijau mewakili nilai RUL sebenarnya. Area *gap* di antara kedua garis menandakan perbedaan antara prediksi *model* dan nilai sebenarnya, yang menunjukkan ketidakakuratan model. Semakin kecil jarak *gap* kedua area tersebut, semakin baik kinerja model.

Analisis menunjukkan bahwa model umumnya cukup akurat dalam memprediksi RUL, namun ada ketidakpastian terutama pada *unit* mesin uji dengan RUL yang lebih rendah. Implikasinya, model ini dapat digunakan untuk membantu dalam perencanaan perawatan dan penggantian mesin *turbofan*.



Gambar 9. Hasil prediksi model terhadap data uji

F. Evaluasi dengan RMSE

Dari penilaian terhadap model dan prediksi pada data uji, semakin rendah nilai RMSE menunjukkan kinerja yang lebih baik. Dalam konteks ini, RMSE sebesar 26.48 menunjukkan bahwa rata-rata perbedaan antara nilai prediksi model dan nilai sebenarnya adalah sekitar 26.48 unit waktu.

SIMPULAN

Berdasarkan hasil dari penelitian ini telah menghasilkan penilaian dan prediksi hasil dari pola pembelajaran *model* yang telah dikembangkan sebelumnya menggunakan RNN dan arsitektur LSTM terhadap 100 unit *engine* dalam *dataset* pengujian. Berdasarkan keseluruhan dari penelitian yang telah dilakukan, maka dapat ditarik kesimpulan sebagai berikut.

1. Prediksi *Remaining Useful Life* mesin *turbofan* pada *dataset* C-MAPSS dengan menggunakan metode RNN dan arsitektur LSTM diperoleh *model* dengan hasil RMSE terbaik pada *parameter* pengujian dengan nilai *error* sebesar 26.48.
2. Nilai *error* dan *loss* pada masa pemodelan dipengaruhi oleh *parameter* pengujian, mulai dari *settings learning rate*, jumlah *epoch*, *window size* dan *optimizer* yang digunakan.
3. Model dapat mengikuti pola pada *dataset* RUL yang telah disediakan.

DAFTAR PUSTAKA

- Aivaliotis, P., Georgoulas, K., Arkouli, Z., & Makris, S. (2019). Methodology for enabling digital twin using advanced physics-based modelling in predictive maintenance. *Procedia CIRP*, 81(March), 417–422.
<https://doi.org/10.1016/j.procir.2019.03.072>
- Alexandropoulos, S. A. N., Kotsiantis, S. B., & Vrahatis, M. N. (2019). Data preprocessing in predictive data mining. In *Knowledge Engineering Review* (Vol. 34, Issue April 2020).
<https://doi.org/10.1017/S026988891800036X>
- Chao, M., Kulkarni, C., Goebel, K., & Fink, O. (2021). Aircraft Engine Run-To-Failure Dataset Under Real Flight Conditions. *NASA Ames Prognostics Data Repository*.
<https://ti.arc.nasa.gov/tech/dash/groups/pc/oe/prognostic-data-repository/#turbofan-2>
- Dudek, G., Pelka, P., & Smyl, S. (2022). A Hybrid Residual Dilated LSTM and

- Exponential Smoothing Model for Midterm Electric Load Forecasting. *IEEE Transactions on Neural Networks and Learning Systems*, 33(7), 2879–2891. <https://doi.org/10.1109/TNNLS.2020.3046629>
- Estimation, L., Karnik, R., Pandya, K., & Jha, S. (2023). *Long Short-Term Memory Model for Remaining Usable*. 2, 1–7.
- Ferreira, C., & Gonçalves, G. (2022). Remaining Useful Life prediction and challenges: A literature review on the use of Machine Learning Methods. In *Journal of Manufacturing Systems*. Elsevier. <https://www.sciencedirect.com/science/article/pii/S0278612522000796>
- Frederick, D. K., Decastro, J. A., & Litt, J. S. (2007). *User's Guide for the Commercial Modular Aero-Propulsion System Simulation (C-MAPSS) - NASA Technical Reports Server (NTRS)*. October. <https://ntrs.nasa.gov/citations/20070034949>
- Gupta, M. K., & Chandra, P. (2020). A comprehensive survey of data mining. *International Journal of Information Technology (Singapore)*, 12(4), 1243–1257. <https://doi.org/10.1007/s41870-020-00427-7>
- Hodson, T. O. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. *Geoscientific Model Development*, 15(14), 5481–5487. <https://doi.org/10.5194/gmd-15-5481-2022>
- Maharana, K., Mondal, S., & Nemade, B. (2022). A review: Data pre-processing and data augmentation techniques. *Global Transitions Proceedings*, 3(1), 91–99. <https://doi.org/10.1016/j.gltp.2022.04.020>
- Mu, Z., Ran, Y., Zhang, G., Wang, H., & Yang, X. (2021). Remaining useful life prediction method for machine tools based on meta-action theory. *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability*, 235(4), 580–590. <https://doi.org/10.1177/1748006X211002544>
- Nguyen, B. H., Xue, B., & Zhang, M. (2020). A survey on swarm intelligence approaches to feature selection in data mining. *Swarm and Evolutionary Computation*, 54(February). <https://doi.org/10.1016/j.swevo.2020.100663>
- Nurashila, S. S., Hamami, F., & Kusumasari, T. F. (2023). Perbandingan Kinerja Algoritma Recurrent Neural Network (Rnn) Dan Long Short-Term Memory (Lstm): Studi Kasus Prediksi Kemacetan Lalu Lintas Jaringan Pt Xyz. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 8(3), 864–877. <https://doi.org/10.29100/jupi.v8i3.3961>
- Perry, M. B. (2011). The Exponentially Weighted Moving Average. *Wiley Encyclopedia of Operations Research and Management Science*, October. <https://doi.org/10.1002/9780470400531.eorms0314>
- Ramasso, E., & Saxena, A. (2014). Review and analysis of algorithmic approaches developed for prognostics on CMAPSS dataset. *PHM 2014 - Proceedings of the Annual Conference*. Ramasso, E., & Saxena, A. (2014). *Review and Analysis of Algorithmic Approaches Developed for Prognostics on CMAPSS Dataset*. *PHM 2014 - Proceedings of the Annual Conference of the Prognostics and Health Management*, 612–622.
- Remadna, I., Terrissa, S. L., Zemouri, R., Ayad, S., & Zerhouni, N. (2020). Leveraging the Power of the Combination of CNN and Bi-Directional LSTM Networks for Aircraft Engine RUL Estimation. *Proceedings - 2020 Prognostics and Health Management*

- Conference, PHM-Besancon 2020, March 2021*, 116–121. <https://doi.org/10.1109/PHM-Besancon49106.2020.00025>
- Rezaeianjouybari, B., & Shang, Y. (2020). Deep learning for prognostics and health management: State of the art, challenges, and opportunities. *Measurement*. <https://www.sciencedirect.com/science/article/pii/S026322412030467X>
- Ridla, M. A., Azise, N., & Rahman, M. (2023). Perbandingan Model Time Series Forecasting Dalam Memprediksi Jumlah Kedatangan Wisatawan Dan Penumpang Airport. *Simkom*, 8(1), 1–14. <https://doi.org/10.51717/simkom.v8i1.103>
- Saraswat, P., & Raj, S. (2022). Data Pre-Processing Techniques in Data Mining: a Review. *International Journal of Innovative Research in Computer Science & Technology*, 1, 122–125. <https://doi.org/10.55524/ijrcst.2022.10.1.22>
- Singh, D., & Singh, B. (2020). Investigating the impact of data normalization on classification performance. *Applied Soft Computing*, 97(xxxx), 105524. <https://doi.org/10.1016/j.asoc.2019.105524>
- Thakkar, U. R. (2021). *Remaining useful life prediction of a turbofan engine using deep layer recurrent neural networks*. repository.library.carleton.ca. <https://repository.library.carleton.ca/concern/etds/dj52w564c>
- Venkatesh, B., & Anuradha, J. (2019). A review of Feature Selection and its methods. *Cybernetics and Information Technologies*, 19(1), 3–26. <https://doi.org/10.2478/CAIT-2019-0001>
- Wang, J., Ye, L., Gao, R. X., Li, C., & Zhang, L. (2019). Digital Twin for rotating machinery fault diagnosis in smart manufacturing. *International Journal of*
- Wei, K. (2023). Turbofan and turbojet engines: Working process and future development. *Theoretical and Natural Science*, 12(1), 114–119. <https://doi.org/10.54254/2753-8818/12/20230447>
- <https://doi.org/10.1080/00207543.2018.1552032>