

Evaluasi Model LSTM untuk Prediksi *Chemical Treatment* pada Sistem Ultrafiltrasi

Jecky¹, Chao Lung Yang², dan Nur Aini Masrurroh³

¹Teknik Industri, Universitas Gadjah Mada, Jl. Grafika 2, Daerah Istimewa Yogyakarta, Indonesia, 55281

²Manajemen Industri, National Taiwan University of Science and Technology, 43, Section 4, Taipei City

³Teknik Industri, Universitas Gadjah Mada, Jl. Grafika 2, Daerah Istimewa Yogyakarta, Indonesia, 55281

Correspondence: Jecky (jecky@email.ac.id)

Received: 15 06 2025 – Revised: 01 07 2025 - Accepted: 22 07 2025 - Published: 15 08 2025

Abstrak. Penyumbatan atau yang biasa dikenal dengan *membrane fouling* (MF) merupakan masalah yang umum dalam sistem pemurnian air ultrafiltrasi dan penanganan terhadap permasalahan ini diantaranya adalah dengan pembilasan balik (*water treatment*) ataupun penggunaan bahan kimia (*chemical treatment*). Masing-masing perlakuan memiliki keunggulan dan kelemahan masing-masing dari segi waktu dan biaya pelaksanaan. Di dalam dunia nyata, pelaksanaan *chemical treatment* (CT) seringkali memerlukan waktu yang lama, namun efektivitas yang tinggi sehingga CT menjadi hal yang paling diperhatikan dalam penelitian ini. Keputusan untuk pelaksanaan CT umumnya didasarkan pada penilaian subyektif manusia sehingga sangat beresiko untuk terjadinya inkonsistensi dalam pelaksanaan CT. Oleh sebab itu, diperlukan pemanfaatan *deep learning* untuk membantu melakukan automasi terhadap pelaksanaan CT. Riset ini dilakukan untuk mengevaluasi performa dari 3 model *deep learning* yakni LSTM, Bidirectional LSTM (Bi-LSTM), dan Bi-LSTM + Transformer dalam memprediksi laju alir yang kemudian digunakan untuk memprediksi kejadian pelaksanaan CT. Evaluasi dilakukan berdasarkan nilai *Root Mean Squared Error* (RMSE) dan kecocokan waktu pelaksanaan CT antara prediksi dan aktual. Berdasarkan nilai RMSE yang didapat, Bi-LSTM + Transformer memberikan nilai terbaik dengan nilai RMSE sebesar 26,01 disusul oleh Bi-LSTM dan LSTM dengan nilai 26,02 dan 26,03 dimana nilai RMSE yang lebih kecil dari 30 menunjukkan akurasi prediksi yang moderat. Berdasarkan kecocokan antara prediksi waktu pelaksanaan CT dengan aktual, model LSTM, Bi-LSTM dan Bi-LSTM + Transformer memberikan hasil *F1-Score* sebesar 0,80; 0,79; dan 0,72 dimana nilai *F1-Score* yang semakin mendekati 1 menunjukkan hasil prediksi yang baik/semakin mendekati data aktual. Berdasarkan performa yang diperoleh, dapat disimpulkan bahwa model LSTM memiliki performa yang lebih baik dibandingkan model yang lebih kompleks seperti Bi-LSTM dan Bi-LSTM + Transformer.

Kata kunci: automasi, *deep learning*, *membrane fouling*, ultrafiltrasi

PENDAHULUAN

Di Indonesia, sistem pemurnian air memegang peranan penting dalam keberlanjutan industri. Salah satu tantangan utama dalam sistem ini adalah *membrane fouling (MF)*, yaitu penurunan kinerja membran penyaringan akibat penumpukan partikel dan kontaminan. Kondisi ini dapat mengurangi efisiensi filtrasi, menurunkan produktivitas, serta meningkatkan biaya operasional.

Selama ini, penentuan waktu dan jenis pemeliharaan membran sering dilakukan secara manual berdasarkan penilaian subjektif operator. Pendekatan ini memiliki kelemahan signifikan, seperti kurangnya konsistensi, rendahnya objektivitas, serta tingginya risiko *human error*, yang pada akhirnya dapat berdampak pada efektivitas dan produktivitas sistem secara keseluruhan.

Berbagai penelitian telah mencoba mengatasi masalah ini dengan teknologi berbasis *machine learning*. Niu *et al.* (2022) membandingkan beberapa metode optimisasi dengan model *machine learning* dan menemukan bahwa *machine learning* memberikan hasil lebih baik dibandingkan metode konvensional. Studi lain mengenai penggunaan *artificial neural network (ANN)* pada prediksi *MF* menunjukkan nilai R^2 sebesar 0,97, menandakan potensi besar teknologi ini untuk pemurnian air. Kovacs *et al.* (2022) juga membuktikan bahwa *ANN*, *LSTM*, dan *random forest (RF)* mampu memberikan nilai R^2 di atas 93%, dengan *ANN* dan *LSTM* menunjukkan performa lebih baik dalam menghadapi ketidakpastian. Selain itu, model *deep learning* berbasis deret waktu seperti *Bi-LSTM* dan *Transformer* telah banyak digunakan untuk data serupa. Penelitian terdahulu (Nie *et al.*, 2021; Zhang *et al.*, 2022; Bi *et al.*, 2022) melaporkan bahwa *Bi-LSTM* memiliki akurasi prediksi yang tinggi, sedangkan Shi *et al.* (2024) menunjukkan bahwa penggabungan *Transformer* dan *LSTM* mampu menurunkan tingkat kesalahan prediksi hingga 10% dibandingkan model *LSTM*.

Meskipun penelitian terkait *ANN* telah cukup banyak, eksplorasi penggunaan model berbasis *LSTM*, terutama yang dikombinasikan dengan metode *Transformer*, masih terbatas. Padahal, metode ini memiliki potensi besar untuk meningkatkan akurasi prediksi dan efisiensi sistem pemurnian air, khususnya dalam konteks penjadwalan *chemical treatment (CT)*.

Penelitian ini bertujuan untuk mengembangkan kerangka pemanfaatan model *deep learning* berbasis *LSTM* dan *Transformer* untuk optimasi sistem pemurnian air, khususnya dalam memprediksi waktu pelaksanaan *CT* di industri Indonesia. Diharapkan, hasil

penelitian ini dapat memberikan wawasan bagi pengembangan model prediksi yang lebih akurat dan membantu meningkatkan efisiensi serta produktivitas sistem pemurnian air.


MASALAH

Sistem pemurnian air ultrafiltrasi banyak digunakan di industri, namun sering menghadapi masalah *membrane fouling* (MF). Untuk mengatasinya, biasanya digunakan *water treatment* (WT) dan *chemical treatment* (CT). WT cepat dilakukan namun kurang efektif, sedangkan CT lebih efektif tetapi memerlukan waktu dan biaya lebih besar. Saat ini, pemilihan metode perawatan masih bergantung pada penilaian subjektif operator, yang rentan terhadap kesalahan.

Penelitian ini berfokus pada prediksi CT karena dampaknya signifikan terhadap efisiensi operasional. Mengacu pada konsep *predictive maintenance*, model *deep learning* dilatih menggunakan data performa penyaringan sebelum pelaksanaan CT, sehingga dapat memprediksi waktu pelaksanaan CT berikutnya secara lebih akurat.

METODE PELAKSANAAN

Penelitian ini dilakukan dengan cara menawarkan sistem deteksi penyumbatan dan sistem peringatan CT secara otomatis berbasis AI untuk menggantikan sistem manual yang sekarang masih umum dilakukan di berbagai industri. Berikut merupakan diagram alir penelitian yang digunakan dalam penelitian ini.



Gambar 1. Diagram Alir Penelitian

Pengumpulan data

Data diperoleh dari perusahaan pemurnian air di Taiwan, mencakup laju alir, tekanan masuk, dan tekanan keluar. Data dikumpulkan per menit selama 30 hari melalui sensor di sekitar membran penyaringan.

Tabel 1. Informasi Data yang Digunakan

No	Fitur	Data
1	Nomor Identifikasi Pipa penyaringan (Filter ID)	16501 -16524
2	Waktu	2024/03/09 00:00:00 – 2024/04/10 00:00:00
3	Laju alir (FI_16506)	0 – 80 ton/jam
4	Tekanan Masukan (PI_16506)A	0 – 600 bar
5	Tekanan Keluaran (PI_16506)C	0 – 600 bar

Pemrosesan Awal Data

Data yang ada kemudian akan diproses dalam rangkaian tahap pemrosesan data yang melingkupi:

1. Analisa *missing value* dan *outlier*

Deteksi *missing value* dan *outlier* menggunakan NumPy, Pandas, dan metode Tukey.

2. Pembagian Data

Data-data yang telah dibersihkan kemudian dibagi menjadi 3 set data yakni: set data *training*, *validation* dan *testing* dengan proporsi sebesar 60%, 20%, dan 20%

3. Penskalaan Data

MinMaxScaler (0–1) diterapkan hanya pada *training set*, lalu digunakan pada *validation* dan *testing set* untuk mencegah *data leakage*.


4. Analisa Korelasi Variabel

Korelasi Pearson digunakan untuk menghindari variabel input yang redundan.

Pembangunan Model

Pada penelitian ini, seluruh model *deep learning* akan dibangun dengan menggunakan 60 menit data dari masing-masing variabel untuk menghasilkan output berupa prediksi 60 menit berikutnya. Sistematis pergerakan data yang digunakan sebagai input serta output yang dihasilkan mengadopsi konsep *sliding windows* dengan *sliding size* sebesar 60

menit. Gambaran sistem input dan output yang digunakan dalam penelitian ini beserta parameter dari masing-masing model dapat dilihat pada Gambar 2. dan Tabel 2.



Gambar 2. Gambaran Input dan Output Model

Tabel 2. Parameter Model yang Digunakan

LSTM			
Layer		Parameter	
Sequence Layer		LSTM(64)	
Dropout		Discard Ratio = 0.2	
Dense		Unit = 60, activation = ReLU	

Bidirectional LSTM		Bidirectional LSTM + Transformer	
Layer	Parameter	Layer	Parameter
Sequence Layer	Bidirectional(LSTM(64))	Sequence Layer	Bidirectional(LSTM(64))
Dropout	Discard Ratio = 0.2	Attention	MultiHeadAttention (num_heads=4, key_dim=64)
Dense	Unit = 60, activation = ReLU	Dense 1	Unit = 64, activation = ReLU
		Pooling	GlobalAveragePooling
		Dropout	Discard Ratio = 0.2
		Dense 2	Unit = 60, activation = ReLU

Evaluasi Model

Terdapat 2 evaluasi model yang dilakukan dalam penelitian ini, yakni melalui *RMSE* dan *F1-Score*. Pada perhitungan *F1-Score*, prediksi waktu pelaksanaan *CT* yang masuk dalam daerah CT_{actual} terdekat $\pm$ toleransi akan dikategorikan sebagai “True” atau akurat, namun apabila prediksi waktu pelaksanaan *CT* berada diluar CT_{actual} terdekat $\pm$ toleransi, akan dikategorikan sebagai “False”. Perhitungan terhadap kedua parameter evaluasi ini di tuliskan sebagai berikut:

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(y_{prediction} - y_{actual})^2}{n}}$$

$$\text{Toleransi} = 1.96 \times \text{StDev} (CT.start_{actual\ train})$$

$$\text{Presisi} = \frac{\#TP}{\#Total\ CT\ Prediksi}$$

$$\text{Recall} = \frac{\#TP}{\#Total\ CT\ Aktual}$$

$$\text{F1-Score} = \frac{2 \times (\text{Presisi} \times \text{Recall})}{(\text{Presisi} + \text{Recall})}$$

Keterangan:

StDev (*CT.start_{train}*) = standar deviasi dari jarak antara waktu dimulainya CT pada dataset *training*


TP = *True Positive* = Hasil Prediksi waktu pelaksanaan CT yang masuk dalam kategori “True”

HASIL DAN PEMBAHASAN

Hasil Pemrosesan Awal Data


Deteksi terhadap missing data menunjukkan bahwa terdapat 4 baris data yakni data pada waktu 2024-03-11 08:51:00 - 2024-03-11 08:54:00 (4 menit) yang mencakup 0,0087% dari keseluruhan data. Jumlah *missing data* ini sangat kecil sehingga penanganan yang dilakukan pendekatan sederhana terhadap *missing value* ini yakni dengan mengubah nilai dari baris yang memiliki *missing value* ini menjadi 0.

Hasil analisis terhadap outlier seperti yang dapat dilihat pada Gambar 3. menunjukkan bahwa pada tekanan masukan dan tekanan keluaran, terdapat nilai outlier yang menunjukkan nilai yang sangat besar dan hal ini mungkin disebabkan oleh kesalahan pada sensor dalam melakukan pembacaan yang dan nilai-nilai tersebut jauh diatas kapasitas operasional (2 bar) sehingga nilai-nilai tersebut dianggap tidak memberikan informasi penting dan penanganan terhadap nilai-nilai outlier ini dilakukan dengan mengganti nilai outlier tersebut dengan nilai dari baris sebelumnya.



Gambar 3. Hasil deteksi *outlier* pada data

Hasil analisa korelasi variabel




Gambar 4. Hasil korelasi Pearson antara: a. laju alir dan tekanan masukan, b. laju alir dan c. tekanan masukan dan tekanan keluaran

Melalui Gambar 4.a., dapat dilihat bahwa bahwa koefisien korelasi Pearson antara variabel tekanan masukan dan tekanan keluaran pada Filter ID 16502 – 16508 semuanya lebih kecil dari 0,3 dan nilai ini masuk dalam kategori rendah (Papageorgiou, 2022) . Hal ini berarti kedua variabel tidak memiliki kecenderungan yang sama dalam data sehingga memberikan informasi yang lebih beragam kepada model, sebaliknya, pada pada Filter ID 16509 – 16524, koefisien korelasi antara tekanan masukan dan tekanan keluaran sangat tinggi, yakni lebih dari 0,7 sehingga untuk Filter ID 16509 – 16524, hanya salah satu variabel yang perlu digunakan sebagai input. Berdasarkan Gambar 4.b. dan 4.c., terlihat bahwa korelasi antara laju alir dengan tekanan keluaran lebih rendah dari pada tekanan masukan sehingga diputuskan untuk Filter ID 16509 – 16524, variabel yang digunakan sebagai input

untuk model yang akan dibangun adalah laju alir dan tekanan keluaran, sedangkan untuk Filter ID 16501 – 16508, variabel yang akan digunakan sebagai input bagi model adalah laju alir, tekanan masukan dan tekanan keluaran dan untuk Filter ID 16501, input yang akan digunakan adalah laju alir dan tekanan masukan karena pada Filter ID 16501, tidak tersedia data tekanan keluaran.

Hasil *loss* pada dataset *training* dan *validation*

Sebelum dilakukan evaluasi terhadap performa model, perlu dilakukan evaluasi terhadap kemampuan generalisasi dari model. Dimana dalam penelitian ini, performa generalisasi model dievaluasi dari pola *loss*/eror pada set data *training* dan *validation* yang disajikan dalam bentuk *MAE* (*Mean Absolute Error*). Model yang baik dan tidak mengalami *overfitting* pada dasarnya akan memiliki performa yang tidak jauh berbeda ketika dijalankan pada model yang digunakan untuk melatih ataupun pada data yang belum pernah dilihat. Hal inilah yang dievaluasi melalui pola *loss* karena besarnya *loss* yang ada pada data *training* akan semakin mirip dan mengecil seiring dengan semakin banyaknya iterasi (Li *et al.*, 2024). Grafik perbandingan *loss* antara set data *training* dan *validation* dari seluruh model dapat dilihat pada Gambar 5.



Gambar 5. Grafik perbandingan *loss* antara set data *training* and *validation* pada model a. LSTM, b. Bi-LSTM, c. Bi-LSTM + Transformer

Hasil perbandingan *loss* antara set data *training* dan *validation* dari seluruh model terlihat sangat baik dan tidak menunjukkan adanya potensi overfitting pada data karena *loss* pada dataset *validation* semakin membaik seiring dengan bertambahnya iterasi.

Performa Prediksi Laju Alir

Evaluasi terhadap performa prediksi model pada dasarnya dilakukan dengan dua tahapan, dimana pada tahap pertama, evaluasi dilakukan dengan melihat besarnya perbedaan antara hasil prediksi dengan data aktual yang diukur dengan menggunakan *Root Mean Squared Error (RMSE)*. Rerata hasil *RMSE* dari semua model ditunjukkan dalam Tabel 3.

Tabel 3. Hasil Rata-Rata *RMSE* dari Model *Deep Learning*

<i>LSTM</i>	<i>Bi-LSTM</i>	<i>Bi-LSTM + Transformer</i>
26.03	26.02	26.01

Berdasarkan hasil yang ada pada Tabel 3., terlihat bahwa hasil *RMSE* dari ketiga model tidak terlalu jauh berbeda, namun hasil performa pada model *Bi-LSTM + Transformer* sedikit lebih baik dibandingkan dengan model yang lainnya. Pada hasil *RMSE*, model dengan nilai yang lebih kecil menunjukkan performa yang lebih baik karena nilai yang lebih kecil merujuk pada nilai eror antara prediksi dan aktual yang lebih kecil pula dan dalam penelitian ini, model *Bi-LSTM + Transformer* memiliki nilai yang paling kecil. Hasil yang didapat ini cukup masuk akal karena model *Bi-LSTM + Transformer* menggabungkan kapabilitas model *Bi-LSTM* untuk meninjau data dengan pola maju dan mundur sehingga memperkaya informasi yang bisa didapatkan dari data. Hal ini dipadukan dengan mekanisme atensi yang memungkinkan model gabungan ini untuk melihat pola dan informasi yang tersembunyi dalam data secara lebih baik dibandingkan model *Bi-LSTM* dan *LSTM* (Wang & Chai, 2025). Penemuan yang menarik dari hasil *RMSE* ini adalah perbedaan hasil yang sangat kecil diantara model yang digunakan. Perbedaan yang kecil ini mengindikasikan bahwa informasi yang terkandung di dalam data yang digunakan tidak memiliki kompleksitas yang tinggi, sehingga model yang sederhana seperti *LSTM* sudah mampu untuk mempelajari data dan menghasilkan prediksi yang cukup baik.

Tabel 4. Hasil Perbandingan Rata-Rata *F1-Score* Model *Deep Learning*

<i>Bidirectional LSTM</i>	<i>Bidirectional LSTM + Transformer</i>	<i>LSTM</i>
0,72	0,79	0,80

Hasil evaluasi terhadap *FI-Score* pelaksanaan *CT* hasil prediksi dan aktual juga mendukung temuan yang didapatkan sebelumnya. Berdasarkan hasil yang didapat, model *LSTM* memiliki nilai *FI-Score* pelaksanaan *CT* antara prediksi dan aktual yang paling besar. Hal ini menunjukkan bahwa model *LSTM* mampu memprediksi *CT* dengan lebih baik dibandingkan model lain, disusul oleh *Bi-LSTM* dan model yang memiliki performa prediksi *CT* yang paling buruk adalah model *Bi-LSTM + Transformer*. Temuan ini bertolak belakang dengan hasil yang didapat oleh Shi *et al.* (2024) dan hal ini dapat dijelaskan karena meskipun model *Bi-LSTM + Transformer* dapat mempelajari dan menangkap pola dari data secara keseluruhan, namun model transformer umumnya mengalami kesulitan dan bereaksi secara berlebihan terhadap perubahan kecil pada data yang memiliki fluktuasi yang tinggi (Zhang *et al.*, 2024) seperti halnya data aktual yang digunakan dalam penelitian ini, akibatnya, perubahan yang kecil pada data yang digunakan sebagai input dapat diterjemahkan sebagai perubahan yang besar oleh model dan hal ini dapat menyebabkan model untuk gagal memprediksi waktu pelaksanaan *CT* dengan baik. Melalui penelitian ini, dapat dinyatakan bahwa model yang sederhana terkadang belum tentu memiliki performa yang lebih buruk daripada model yang lebih kompleks. Setiap model memiliki keunggulan dan kekurangannya tersendiri sehingga pemilihan terhadap model harus disesuaikan dengan kebutuhan dan jenis data yang digunakan.

KESIMPULAN

Permasalahan penyumbatan pada sistem pemurnian air merupakan permasalahan yang sangat umum ditemukan hampir diseluruh industri namun penanganan akan masalah ini umumnya masih menggunakan sistem manual sehingga diperlukan automasi berbasis data untuk menangani permasalahan ini. Penelitian ini dilakukan dengan tujuan untuk mengeksplorasi model *deep learning* berbasis *LSTM* yang cocok digunakan untuk memprediksi waktu pelaksanaan *CT* dalam sistem pemurnian air. Hasil *RMSE* dari model *LSTM*, *Bi-LSTM* dan *Bi-LSTM + Transformer* yang digunakan secara berturut-turut adalah 26,03; 26,02; dan 26,01 ton/jam, sedangkan besarnya *FI-Score* prediksi vs aktual dari masing-masing model adalah 0,80; 0,79; dan 0,72 menit. Berdasarkan hal ini, maka dapat dikatakan bahwa model *LSTM* memiliki performa yang lebih baik untuk memprediksi pelaksanaan *CT*. Di dalam penelitian ini, terdapat beberapa keterbatasan diantaranya: data yang digunakan hanya dalam kurun waktu 1 bulan saja, variabel yang digunakan cukup terbatas dan evaluasi terhadap model hanya memperhitungkan faktor *CT* saja. Agar

didapatkan wawasan yang lebih menyeluruh, maka untuk penelitian selanjutnya, dapat digunakan data yang lebih banyak (dalam kurun waktu yang lebih panjang), dapat juga ditambahkan variabel—variabel lain yang relevan, serta dapat dilakukan eksplorasi terhadap model *deep learning* yang lainnya seperti *SVM* atau *CNN* agar didapatkan perbandingan performa model *deep learning* yang lebih luas.

UCAPAN TERIMA KASIH

Ucapan terima kasih yang sebesar-besarnya disampaikan pada pihak perusahaan pengolahan air di Taiwan yang telah memberikan data yang digunakan untuk penelitian ini serta Professor Chao-Lung Yang dari NTUST dan Professor Nur Aini dari UGM yang senantiasa mendukung dan memberikan masukan selama penelitian berlangsung.

DAFTAR PUSTAKA

- Bi, J., Chen, Z., Yuan, H., Lin, Y., & Qiao, J. (2022). Hybrid Prediction for Water Quality with Bidirectional LSTM and Temporal Attention. *IEEE International Conference on Systems, Man and Cybernetics* (pp. 2009–2014). IEEE. <https://doi.org/10.1109/SMC53654.2022.9945409>
- Kovacs, D. J., Li, Z., Baetz, B. W., Hong, Y., Donnaz, S., Zhao, X., Zhou, P., Ding, H., & Dong, Q. (2022). Membrane fouling prediction and uncertainty analysis using machine learning: A wastewater treatment plant case study. *Journal of Membrane Science*, 660, 120817. <https://doi.org/10.1016/j.memsci.2022.120817>
- Li, H., Rajbahadur, G. K., Lin, D., Bezemer, C. P., & Jiang, Z. M. (2024). Keeping Deep Learning Models in Check: A History-Based Approach to Mitigate Overfitting. *IEEE Access*, 12, 70676–70689. <https://doi.org/10.1109/ACCESS.2024.3402543>
- Nie, Q., Wan, D., & Wang, R. (2021). CNN-BiLSTM water level prediction method with attention mechanism. *Journal of Physics: Conference Series*, 2078(1). <https://doi.org/10.1088/1742-6596/2078/1/012032>
- Niu, C., Li, X., Dai, R., & Wang, Z. (2022). Artificial intelligence-incorporated membrane fouling prediction for membrane-based processes in the past 20 years: A critical review. *Water Research*, 216, 118299. <https://doi.org/10.1016/j.watres.2022.118299>
- Papageorgiou, S. N. (2022). On correlation coefficients and their interpretation. *Journal of Orthodontics*, 49(3), 359–361. <https://doi.org/10.1177/14653125221076142>
- Shi, J., Wang, S., Qu, P., & Shao, J. (2024). Time series prediction model using LSTM-Transformer neural network for mine water inflow. *Scientific Reports*, 14(1), 1–16. <https://doi.org/10.1038/s41598-024-69418-z>
- Wang, J., & Chai, W. (2025). Research and Application of Intelligent Learning Path Optimization Based on LSTM-Transformer Model. *Systems and Soft Computing*, 7, 200332. <https://doi.org/10.1016/j.sasc.2025.200332>

- Zhang, Q., Wang, R., Qi, Y., & Wen, F. (2022). A watershed water quality prediction model based on attention mechanism and Bi-LSTM. *Environmental Science and Pollution Research*, 29(50), 75664–75680. <https://doi.org/10.1007/s11356-022-21115-y>
- Zhang, W., Jia, J., Pang, X., Wen, J., Shi, Y., & Zeng, J. (2024). An Improved Transformer Model for Remaining Useful Life Prediction of Lithium-Ion Batteries under Random Charging and Discharging. *Electronics*, 13(8). <https://doi.org/10.3390/electronics13081423>



© 2025 by authors. Content on this article is licensed under a Creative Commons Attribution 4.0 International license. (<http://creativecommons.org/licenses/by/4.0/>).