



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 5 No. 2 (2026) pp: 16765-16775

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Tinjauan Sistematis Peramalan Beban Listrik Menggunakan Deep Learning dan Hybrid

Halim Prasetyo Rieno*, Desti Mualfah

Fakultas Ilmu Komputer, Universitas Muhammadiyah Riau

220401180@student.umri.ac.id*, destimualfah@umri.ac.id

Abstrak

Peramalan beban listrik memiliki peran yang sangat penting dalam pengelolaan sistem tenaga modern karena hasil prediksi yang akurat berpengaruh langsung terhadap efisiensi operasi, keandalan sistem, perencanaan energi, pengalokasian sumber daya, serta stabilitas smart grid. Seiring meningkatnya kebutuhan listrik dan kompleksitas pola konsumsi energi, metode peramalan berbasis kecerdasan buatan, khususnya deep learning dan hybrid, semakin banyak dikembangkan untuk meningkatkan akurasi prediksi dibandingkan metode konvensional. Penelitian ini bertujuan untuk mengkaji perkembangan metode deep learning dan hybrid dalam peramalan beban listrik dengan fokus pada algoritma yang digunakan, variabel input, serta metrik evaluasi yang diterapkan. Metode penelitian menggunakan Systematic Literature Review (SLR) dengan mengacu pada kerangka PRISMA. Sebanyak 18 artikel ilmiah yang diterbitkan pada periode 2022–2026 dipilih melalui proses identifikasi, penyaringan, dan seleksi dari basis data Google Scholar, MDPI, Frontiers, dan arXiv. Hasil kajian menunjukkan bahwa beban historis, fitur waktu, dan variabel cuaca merupakan variabel input yang paling sering digunakan karena memiliki pengaruh signifikan terhadap pola konsumsi listrik. Dari sisi algoritma, penelitian terbaru menunjukkan pergeseran dari model deep learning tunggal menuju model Transformer dan pendekatan hybrid, seperti CNN-GRU, CNN-LSTM, serta BiLSTM-Transformer, yang terbukti lebih mampu menangkap karakteristik data deret waktu yang kompleks, nonlinier, dan dinamis. Sementara itu, metrik evaluasi yang paling banyak digunakan untuk mengukur performa model adalah Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), dan Mean Absolute Error (MAE). Temuan penelitian ini menunjukkan bahwa integrasi data multivariat dengan model deep learning hybrid berpotensi meningkatkan akurasi peramalan beban listrik serta menjadi arah pengembangan yang menjanjikan dalam mendukung implementasi sistem smart grid yang lebih efisien, adaptif, dan berkelanjutan.

Kata kunci: Peramalan Beban Listrik, Deep Learning, Transformer, Smart Grid, Systematic Literature Review

1. Latar Belakang

Peramalan beban listrik merupakan salah satu kebutuhan utama dalam sistem tenaga listrik modern. Melalui peramalan, kebutuhan konsumsi energi pada periode tertentu, baik dalam rentang menit, jam, maupun harian, dapat diperkirakan sebelum proses operasi dan perencanaan sistem dilakukan. Ketepatan hasil peramalan berpengaruh langsung terhadap efisiensi operasi, biaya produksi, dan keandalan sistem tenaga listrik (Abumohsen dkk., 2023). Ketika hasil prediksi kurang akurat, sistem berisiko mengalami ketidakseimbangan antara pasokan dan permintaan energi. Situasi tersebut semakin penting untuk diperhatikan karena perkembangan *smart grid* dan meningkatnya penggunaan energi terbarukan membuat pola beban listrik menjadi lebih dinamis, fluktuatif, dan sulit diprediksi dengan pendekatan sederhana.

Pada tahap awal, peramalan beban listrik banyak dilakukan dengan pendekatan konvensional seperti regresi linear. Namun, pendekatan tersebut memiliki keterbatasan ketika digunakan pada data yang kompleks dan berubah secara dinamis (Cui dkk., 2024). Kondisi ini mendorong penggunaan metode deep learning karena memiliki kemampuan untuk mempelajari hubungan nonlinier dan dependensi temporal pada data deret waktu. Beberapa model yang banyak digunakan dalam penelitian peramalan beban listrik antara lain *Long Short-Term Memory (LSTM)*, *Gated Recurrent Unit (GRU)*, *Convolutional Neural Network (CNN)*, dan *Transformer* (Dakheel & Cevik, 2025). Selain model tunggal, penelitian terbaru juga mulai banyak mengembangkan model hybrid seperti CNN-GRU, BiLSTM-Transformer, dan GCN-Transformer untuk meningkatkan ketepatan prediksi pada pola beban yang semakin tidak stabil.


Walaupun penelitian tentang peramalan beban listrik berbasis deep learning terus berkembang, masih diperlukan pemetaan yang lebih terarah mengenai metode yang paling sering digunakan, variabel input yang dominan, serta metrik evaluasi yang umum dipakai dalam literatur terbaru. Rentang tahun 2022-2026 dipilih karena pada periode ini perkembangan model berbasis Transformer dan hybrid mulai banyak muncul dalam penelitian load forecasting. Tanpa pemetaan yang sistematis, peneliti berikutnya dapat mengalami kesulitan dalam menentukan metode, fitur input, maupun metrik evaluasi yang paling relevan untuk digunakan.

Berdasarkan alasan tersebut, penelitian ini dilakukan dengan pendekatan Systematic Literature Review (SLR) menggunakan protokol PRISMA. Fokus kajian diarahkan pada penelitian peramalan beban listrik berbasis deep learning dan hybrid dalam periode 2022-2026. Secara khusus, penelitian ini bertujuan untuk mengidentifikasi model algoritma yang dominan, memetakan variabel input yang paling banyak digunakan, serta merangkum metrik evaluasi yang digunakan untuk menilai kinerja model. Hasil kajian ini diharapkan dapat menjadi rujukan awal bagi penelitian selanjutnya dalam mengembangkan model peramalan beban listrik yang lebih akurat dan sesuai dengan kebutuhan smart grid.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan *Systematic Literature Review* (SLR) dengan mengacu pada protokol PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*). Kerangka PRISMA digunakan agar proses pencarian, penyaringan, penilaian kelayakan, dan penentuan artikel final dapat dilakukan secara terstruktur. Dengan cara ini, proses kajian literatur tidak dilakukan secara acak, tetapi mengikuti tahapan yang jelas sehingga hasilnya lebih mudah ditelusuri dan dipertanggungjawabkan. Literatur yang dikaji difokuskan pada penelitian peramalan beban listrik berbasis deep learning dan hybrid yang dipublikasikan pada periode 2022-2026.

Seleksi artikel dilakukan melalui empat tahap utama, yaitu identification, screening, eligibility, dan included sebagaimana ditampilkan pada Gambar 1. Pada tahap awal, artikel dikumpulkan dari beberapa repositori yang relevan. Selanjutnya, artikel disaring berdasarkan kesesuaian judul, abstrak, ketersediaan full text, topik penelitian, metode yang digunakan, dan keterkaitannya dengan pertanyaan penelitian. Setelah proses tersebut selesai, diperoleh 18 artikel final yang memenuhi kriteria inklusi dan digunakan sebagai sumber utama dalam analisis.



Gambar 1. Prisma Flow Diagram

2.1. Pertanyaan Penelitian

Pertanyaan penelitian disusun sebelum proses pencarian literatur dilakukan agar arah kajian tetap fokus. Dalam penelitian ini, pertanyaan penelitian digunakan untuk membatasi ruang lingkup analisis sehingga setiap artikel

yang dipilih benar-benar berkaitan dengan tujuan tinjauan. Pertanyaan penelitian yang digunakan adalah sebagai berikut:

RQ1: Model algoritma apa yang paling dominan dalam peramalan beban listrik?

RQ2: Fitur variabel input apa yang paling sering digunakan dalam peramalan beban listrik?

RQ3: Metrik evaluasi apa yang digunakan untuk menilai kinerja model?

2.2. Strategi Pencarian Literatur

Pencarian literatur dilakukan dengan menentukan database terlebih dahulu, kemudian menyusun kata kunci pencarian yang sesuai dengan topik peramalan beban listrik. Database yang digunakan meliputi Google Scholar, MDPI, Frontiers, dan arXiv. Keempat sumber tersebut dipilih karena menyediakan artikel yang berkaitan dengan kecerdasan buatan, *deep learning*, *smart grid*, dan sistem tenaga listrik. Kata kunci yang digunakan adalah kombinasi dari "*electricity load forecasting*", "*deep learning*", "*short-term load forecasting*", dan "*machine learning*".

Agar artikel yang dianalisis tetap relevan, penelitian ini menetapkan kriteria inklusi dan eksklusi. Kriteria inklusi digunakan untuk memilih artikel yang sesuai dengan topik, rentang tahun, metode, bahasa, dan ketersediaan naskah lengkap. Sementara itu, kriteria eksklusi digunakan untuk mengeluarkan artikel yang berada di luar fokus penelitian, misalnya artikel yang tidak membahas beban listrik, tidak menggunakan pendekatan kecerdasan buatan, atau hanya tersedia dalam bentuk abstrak. Dengan kriteria ini, artikel final yang digunakan diharapkan benar-benar sesuai dengan kebutuhan analisis.

Kriteria inklusi dan eksklusi yang diterapkan dalam penelitian ini disajikan pada Tabel 1 berikut:

Tabel 1 Kriteria Inklusi dan Eksklusi

Kriteria	Inklusi	Eksklusi
Tahun	Rentan waktu 2022–2026	Sebelum 2022
Metode	Machine Learning, Deep Learning, dan Hybrid	Metode selain peramalan berbasis kecerdasan buatan pada beban listrik
Topik	Peramalan beban listrik (Load Forecasting)	Selain beban listrik (misal: cuaca atau saham).
Sumber	Jurnal ilmiah dalam Bahasa Indonesia dan Bahasa Inggris	Artikel yang ditulis bukan dalam Bahasa Indonesia berupa abstrak tanpa teks lengkap

2.3. Ekstraksi Data

Ekstraksi data dilakukan setelah artikel final ditentukan. Pada tahap ini, setiap artikel dibaca dan dicatat informasi pentingnya, meliputi nama penulis, tahun publikasi, judul penelitian, algoritma yang digunakan, variabel input, metrik evaluasi, dan hasil utama. Informasi tersebut kemudian dirangkum untuk menjawab RQ1, RQ2, dan RQ3. Ringkasan proses pencarian ditampilkan pada Tabel 2, sedangkan karakteristik artikel yang lebih rinci disajikan pada Tabel 3.

Tabel 2 Ringkasan Hasil Pencarian

Sumber Database	Ditemukan	Disaring	Full Text	Direview
-----------------	-----------	----------	-----------	----------

Google Scholar	60	55	5	0
MDPI	25	15	10	9
Frontiers	20	10	10	6
ArXiv	15	0	15	3
Total	120	80	40	18

Tabel 3 Karakteristik Ekstraksi Data Sesuai Research Question


No	Nama Penulis (Tahun)	Judul Penelitian	(RQ1) Algoritma	(RQ2) Variabel Input	(RQ3) Metrik Evaluasi	Hasil Singkat
1	Abumohsen dkk., (2023)	<i>Electrical Load Forecasting Using LSTM, GRU, and RNN Algorithms</i>	LSTM, GRU, RNN	Data historis beban listrik	MAE, RMSE, MAPE, MSE, R ²	Arsitektur berbasis <i>gated recurrent unit</i> menghasilkan tingkat galat paling rendah dibandingkan RNN standar.
2	Cui dkk., (2024)	<i>Advanced Short-Term Load Forecasting with XGBoost-RF Feature Selection and CNN-GRU</i>	XGBoost, CNN-GRU	Beban historis, fitur kalender, dan variabel cuaca	RMSE, MAPE, MSE	Integrasi seleksi fitur meningkatkan efisiensi model hibrida CNN-GRU.
3	Dakheel & Çevik, (2025)	<i>Optimizing Smart Grid Load Forecasting via a Hybrid Long Short-Term Memory-XGBoost Framework</i>	LSTM-XGBoost	Beban historis dan variabel smart grid	RMSE, MAE, MAPE	Pendekatan hybrid meningkatkan robustness dan ketahanan stabilitas prediksi energi.
4	Ding dkk., (2024)	<i>Improving Short-Term Load Forecasting with Multi-Scale CNN and Transformer-Based Attention</i>	CNN + Transformer	Pembelajaran fitur multi-skala (<i>multi-scale feature learning</i>)	MAE, MSE, NMAE	Pendekatan multi-skala meningkatkan kemampuan ekstraksi fitur dan akurasi model.
5	Dong dkk., (2026)	<i>Short-Term Electricity Load Forecasting with Multi-Frequency Reconstruction</i>	Hybrid Deep Learning (Diffusion Model)	Rekonstruksi frekuensi data beban listrik	MAE, RMSE, MAPE, R ²	Rekonstruksi frekuensi memberikan performa terbaik pada data

		<i>Diffusion</i>				fluktuatif.
6	Dudek, (2022)	<i>A Comprehensive Study of Random Forest for Short-Term Load Forecasting</i>	Random Forest	Data historis beban listrik	RMSE, MAPE	Random Forest menunjukkan performa stabil pada prediksi jangka pendek.
7	Hong dkk., (2024)	<i>Advancing Long-Term Multi-Energy Load Forecasting with Patchformer</i>	Patchformer (Transformer)	Data multi-energi dan fitur deret waktu	RMSE, MAE	Patchformer efektif menangkap dependensi jangka panjang pada data energi.
8	Ibrahim dkk., (2022)	<i>Machine Learning for Short-Term Load Forecasting in Smart Grids</i>	LSTM, GRU, CNN	Beban historis, suhu, dan fitur waktu	MAE, RMSE, MAPE, MSE, R ²	Model mencapai skor korelasi R ² sebesar 0.93 pada sistem <i>smart grid</i> .
9	Kondaiah & Saravanan, (2022)	<i>A Modified Deep Residual Network for Short-Term Load Forecasting</i>	Deep Residual Network	Data historis dan fitur waktu	RMSE, MAPE	Modifikasi residual network meningkatkan akurasi prediksi beban listrik.
10	L'heureux dkk., (2022)	<i>Transformer-Based Model for Electrical Load Forecasting</i>	Transformer	Data deret waktu dan fitur kontekstual	MAE, RMSE, MAPE	Mekanisme <i>self-attention</i> lebih akurat dibandingkan arsitektur RNN tradisional.
11	Li & Chen, (2023)	<i>Short-Term Load Forecasting Based on CEEMDAN-FE-ISSA-LightGBM Model</i>	LightGBM Hybrid	Beban historis dan fitur hasil dekomposisi	RMSE, MAE, MAPE	Model hybrid meningkatkan stabilitas prediksi beban listrik.
12	Liu dkk., (2022)	<i>An Improved Informer Model for Short-Term Load Forecasting</i>	Informer (Transformer)	Pola periodik beban listrik	RMSE, MAPE, MSE	Informer meningkatkan akurasi pada peramalan beban jangka pendek.
13	Moosbrugger dkk., (2025)	<i>Load Forecasting for Households and Energy Communities</i>	LSTM, CNN, Transformer	Data rumah tangga dan komunitas energi	RMSE, MAE	Model deep learning memberikan hasil baik pada komunitas

						energi modern.
14	Tao dkk., (2023)	<i>Intelligent Grid Load Forecasting Based on BERT Network Model</i>	BERT	Dataset beban listrik kompleks	MAE, RMSE, MAPE, MSE	Model BERT menunjukkan performa lebih baik dibandingkan pendekatan LSTM standar.
15	Wu dkk., (2025)	<i>Short-Term Power Load Forecasting Using an Improved Model Integrating GCN and Transformer</i>	GCN-Transformer	Data spasial dan dependensi temporal	MAE, RMSE, MSE, R ²	Integrasi GCN dan Transformer menurunkan tingkat kesalahan prediksi.
16	Xiong dkk., (2024)	<i>Load Forecasting for Commercial Buildings Using BiLSTM-Transformer Network</i>	BiLSTM-Transformer	Data deret waktu dan fitur kontekstual	RMSE, MSE	Kombinasi BiLSTM dan Transformer menghasilkan akurasi prediksi tinggi.
17	Zeng dkk., (2025)	<i>Enhanced Short-Term Load Forecasting Based on Adaptive Residual Fusion of Autoformer and Transformer</i>	Autoformer-Transformer	Beban historis dan fitur waktu	MAE, RMSE, MAPE, R ²	Model enhanced Transformer memberikan performa prediksi yang konsisten dan akurat.
18	Zheng dkk., (2023)	<i>TCN-GAT Multivariate Load Forecasting Model Based on SHAP Value Selection Strategy</i>	TCN-GAT	Data multivariat dan seleksi fitur SHAP	RMSE, MAE, MAPE	Seleksi fitur SHAP meningkatkan interpretabilitas dan akurasi model.

3. Hasil dan Diskusi

Bab ini menyajikan hasil tinjauan terhadap 18 artikel final yang telah melalui proses PRISMA. Pembahasan disusun berdasarkan tiga pertanyaan penelitian, yaitu algoritma yang dominan, variabel input yang digunakan, dan metrik evaluasi yang paling sering dipakai. Penyajian hasil dilakukan dalam bentuk tabel, grafik, dan uraian naratif agar pola dari setiap artikel dapat terlihat lebih jelas.




Gambar 2. Distribusi Artikel Berdasarkan Tahun Publikasi (2022-2026)

Gambar 2 memperlihatkan distribusi artikel berdasarkan tahun publikasi. Pada periode 2022-2024, jumlah artikel relatif stabil dengan masing-masing 5 artikel per tahun. Setelah itu, jumlah artikel menurun menjadi 2 artikel pada tahun 2025 dan 1 artikel pada tahun 2026. Total artikel yang digunakan dalam kajian ini berjumlah 18 artikel. Sebaran tersebut menunjukkan bahwa penelitian mengenai peramalan beban listrik berbasis machine learning, deep learning, dan model hybrid cukup aktif pada periode 2022-2024, kemudian mulai mengarah pada model-model yang lebih baru pada tahun berikutnya.

3.1. Model Algoritma Yang Paling Dominan (RQ1)

Berdasarkan hasil ekstraksi, RQ1 membahas model algoritma yang paling banyak digunakan dalam penelitian peramalan beban listrik. Aspek ini penting karena pemilihan algoritma sangat menentukan kemampuan model dalam membaca pola beban listrik yang kompleks, dinamis, dan nonlinier. Dari artikel yang dikaji, model berbasis Transformer dan mekanisme attention muncul sebagai pendekatan yang paling dominan. Temuan ini memperlihatkan adanya pergeseran dari model sekuensial seperti RNN, LSTM, dan GRU menuju arsitektur yang lebih adaptif dalam menangkap hubungan jangka panjang pada data deret waktu (L'heureux dkk., 2022; Liu dkk., 2022).

Dominasi Transformer berkaitan dengan kemampuan mekanisme self-attention dalam mempelajari pola temporal dan perubahan konsumsi energi. Pada data beban listrik, hubungan antarwaktu sering kali tidak sederhana karena dipengaruhi oleh aktivitas harian, pola musiman, dan perubahan kebutuhan energi. Selain Transformer standar, beberapa penelitian juga menggunakan varian atau kombinasi model seperti Informer, Patchformer, Autoformer-Transformer, BiLSTM-Transformer, dan GCN-Transformer (Hong dkk., 2024; Liu dkk., 2022; Wu dkk., 2025; Xiong dkk., 2024; Zeng dkk., 2025). Hal ini menunjukkan bahwa arah penelitian tidak hanya berfokus pada satu model, tetapi juga pada penggabungan beberapa arsitektur untuk memperoleh hasil prediksi yang lebih stabil.



Gambar 3. Frekuensi Penggunaan Algoritma pada 18 Artikel (2022-2026)


Berdasarkan Gambar 3, Transformer dan model berbasis attention menjadi kelompok metode yang paling banyak digunakan, yaitu muncul pada 8 artikel. Temuan ini menunjukkan bahwa model tersebut dianggap mampu mempelajari dependensi jangka panjang dan pola nonlinier pada data deret waktu. Dalam konteks peramalan beban listrik, kemampuan tersebut penting karena pola konsumsi energi dapat berubah mengikuti waktu, musim, dan kondisi sistem (L'heureux dkk., 2022).

Selain Transformer, model hybrid deep learning juga cukup menonjol dalam artikel yang dikaji. Beberapa contoh model hybrid yang muncul adalah CNN-GRU, BiLSTM-Transformer, GCN-Transformer, dan Autoformer-Transformer (Cui dkk., 2024; Wu dkk., 2025; Xiong dkk., 2024; Zeng dkk., 2025). Model hybrid digunakan karena dapat menggabungkan kelebihan beberapa arsitektur, misalnya CNN untuk ekstraksi fitur lokal, LSTM/BiLSTM untuk pola sekuensial, dan GCN untuk relasi spasial. Kombinasi ini membantu model menangani data beban listrik yang kompleks dan fluktuatif.

Di sisi lain, model tunggal berbasis RNN seperti LSTM dan GRU masih digunakan, tetapi tidak lagi menjadi satu-satunya pendekatan utama (Abumohsen dkk., 2023; Ibrahim dkk., 2022). Tren ini menunjukkan bahwa penelitian terbaru mulai bergerak ke arah model yang lebih adaptif, terutama untuk mendukung kebutuhan smart grid yang memiliki pola konsumsi energi lebih dinamis.

3.2. Fitur Variabel Input Yang Digunakan (RQ2)

RQ2 membahas variabel input yang digunakan dalam artikel peramalan beban listrik. Dari hasil tinjauan, sebagian besar penelitian tidak hanya menggunakan satu jenis input, tetapi mulai mengarah pada dataset multivariat. Beban listrik historis tetap menjadi input utama karena data tersebut menggambarkan pola konsumsi sebelumnya. Namun, banyak penelitian juga menambahkan fitur waktu, fitur kalender, variabel cuaca, data smart grid, serta fitur hasil dekomposisi atau seleksi fitur untuk meningkatkan kualitas prediksi. Penambahan variabel tersebut dilakukan karena konsumsi listrik tidak hanya dipengaruhi oleh pola masa lalu, tetapi juga oleh rutinitas manusia dan kondisi lingkungan (Cui dkk., 2024; Kondaiah & Saravanan, 2022).



Gambar 4. Frekuensi Variabel Input pada 18 Artikel (2022-2026)


Gambar 4 menunjukkan bahwa beban historis menjadi variabel input yang paling dominan, yaitu ditemukan pada seluruh 18 artikel. Hal ini wajar karena peramalan beban listrik sangat bergantung pada pola konsumsi sebelumnya. Selain itu, fitur waktu atau kalender digunakan pada 8 artikel, misalnya jam, hari, akhir pekan, bulan, dan hari libur. Fitur waktu membantu model mengenali pola penggunaan listrik yang mengikuti aktivitas harian dan mingguan.

Variabel kontekstual atau multivariat muncul pada 7 artikel. Variabel ini mencakup data smart grid, data multi-energi, data spasial-temporal, dan fitur pendukung lain yang berhubungan dengan karakteristik sistem. Variabel cuaca atau meteorologi, seperti suhu dan kelembapan, ditemukan pada 2 artikel. Selain itu, terdapat 4 artikel yang menggunakan teknik rekonstruksi, dekomposisi, atau seleksi fitur seperti SHAP. Temuan ini memperlihatkan bahwa penggunaan data tambahan menjadi salah satu strategi untuk memperkuat kemampuan model dalam membaca pola beban listrik.

Secara umum, kombinasi antara beban historis, fitur kalender, dan variabel cuaca dapat membantu meningkatkan akurasi prediksi dibandingkan penggunaan data univariat saja (Cui dkk., 2024; Ibrahim dkk., 2022; Zheng dkk., 2023). Dengan demikian, pemilihan variabel input menjadi bagian penting dalam pengembangan model deep learning untuk peramalan beban listrik pada sistem smart grid.

3.3. Metrik Evaluasi Yang Digunakan (RQ3)

RQ3 membahas metrik evaluasi yang digunakan untuk menilai kinerja model. Dari 18 artikel yang dikaji, sebagian besar penelitian menggunakan metrik deterministik atau point forecasting. Metrik ini digunakan untuk mengukur selisih antara nilai aktual dan nilai prediksi. Penggunaan metrik tersebut cukup umum dalam penelitian forecasting karena hasilnya mudah dibandingkan antar model dan mudah dipahami oleh pembaca.



Gambar 5. Frekuensi Metrik Evaluasi pada 18 Artikel (2022–2026)

Gambar 5 menunjukkan bahwa RMSE menjadi metrik yang paling sering digunakan, yaitu pada 16 artikel. RMSE banyak dipilih karena dapat memberikan penalti lebih besar pada kesalahan prediksi yang tinggi. MAPE digunakan pada 15 artikel karena hasilnya berbentuk persentase sehingga mudah diinterpretasikan. MAE digunakan pada 14 artikel karena memberikan nilai rata-rata kesalahan absolut yang sederhana. Selain itu, R² digunakan pada 9 artikel, MSE pada 6 artikel, NRMSE pada 3 artikel, serta metrik lain seperti SMAPE dan MASE pada 2 artikel. Berdasarkan hasil tersebut, RMSE, MAPE, dan MAE dapat dianggap sebagai metrik utama dalam penelitian peramalan beban listrik. Ke depan, pengembangan model yang adaptif terhadap perubahan pola konsumsi atau concept drift menjadi peluang penting, terutama dalam konteks smart grid yang terus berkembang (Ibrahim dkk., 2022; Wu dkk., 2025).

4. Kesimpulan

Berdasarkan *Systematic Literature Review* terhadap 18 artikel ilmiah periode 2022-2026, penelitian ini menunjukkan bahwa Transformer dan model hybrid deep learning menjadi pendekatan yang paling menonjol dalam peramalan beban listrik modern. Pergeseran dari model RNN tradisional menuju Transformer dan hybrid menunjukkan bahwa penelitian terbaru membutuhkan model yang lebih mampu menangani pola beban listrik yang kompleks, nonlinier, dan dinamis. Dari sisi variabel input, sebagian besar penelitian menggunakan data multivariat dengan menggabungkan beban historis, fitur kalender, dan variabel cuaca. Temuan ini menunjukkan bahwa kualitas input sangat berpengaruh terhadap kemampuan model dalam memahami pola konsumsi energi. Beban historis tetap menjadi dasar utama, tetapi penambahan fitur kontekstual dapat membantu model menghasilkan prediksi yang lebih baik. Dari sisi evaluasi, metrik yang paling banyak digunakan adalah RMSE, MAPE, dan MAE. Ketiga metrik tersebut dipilih karena mudah dipahami, umum digunakan dalam penelitian forecasting, dan dapat membantu membandingkan performa antar model. Secara keseluruhan, hasil kajian ini menunjukkan bahwa pengembangan peramalan beban listrik tidak hanya diarahkan pada peningkatan akurasi, tetapi juga pada model yang adaptif, efisien, dan mudah diinterpretasikan untuk mendukung implementasi smart grid berbasis kecerdasan buatan. Penelitian ini memiliki keterbatasan pada jumlah artikel, rentang tahun, dan cakupan database yang digunakan. Oleh karena itu, penelitian berikutnya disarankan untuk memperluas database, misalnya IEEE Xplore, ScienceDirect, SpringerLink, Scopus, dan Web of Science. Selain itu, kajian lanjutan dapat membandingkan performa model berdasarkan jenis dataset, wilayah penerapan, skala sistem kelistrikan, dan karakteristik beban listrik. Dengan perluasan tersebut, pemetaan mengenai peramalan beban listrik berbasis kecerdasan buatan dapat disusun secara lebih komprehensif.

Referensi

- [1] M. Abumohsen, A. Y. Owda, and M. Owda, "Electrical load forecasting using LSTM, GRU, and RNN algorithms," *Energies*, vol. 16, no. 5, Art. no. 2283, 2023. doi: <https://doi.org/10.3390/en16052283>
- [2] J. Cui, W. Kuang, K. Geng, A. Bi, F. Bi, X. Zheng, and C. Lin, "Advanced short-term load forecasting with XGBoost-RF feature

- selection and CNN-GRU,” *Processes*, vol. 12, no. 11, Art. no. 2466, 2024. doi: <https://doi.org/10.3390/pr12112466>
- [3] F. Dakheel and M. Çevik, “Optimizing smart grid load forecasting via a hybrid long short-term memory-XGBoost framework: Enhancing accuracy, robustness, and energy management,” *Energies*, vol. 18, no. 11, Art. no. 2842, 2025. doi: <https://doi.org/10.3390/en18112842>
- [4] S. Ding, D. He, and G. Liu, “Improving short-term load forecasting with multi-scale convolutional neural networks and transformer-based multi-head attention mechanisms,” *Electronics*, vol. 13, no. 24, Art. no. 5023, 2024. doi: <https://doi.org/10.3390/electronics13245023>
- [5] Q. Dong, R. Huang, L. Zhou, D. Towey, J. Tian, and J. Wang, “Short-term electricity load forecasting with multi-frequency reconstruction diffusion,” *arXiv*, 2026. doi: <https://arxiv.org/abs/2601.06533>
- [6] G. Dudek, “A comprehensive study of random forest for short-term load forecasting,” *Energies*, vol. 15, no. 20, Art. no. 7547, 2022. doi: <https://doi.org/10.3390/en15207547>
- [7] Q. Hong, F. Meng, and F. Maldonado, “Advancing long-term multi-energy load forecasting with Patchformer: A patch and transformer-based approach,” *arXiv*, 2024. doi: <https://arxiv.org/abs/2404.10458>
- [8] B. Ibrahim, L. Rabelo, E. Gutierrez-Franco, and N. Clavijo-Buritica, “Machine learning for short-term load forecasting in smart grids,” *Energies*, vol. 15, no. 21, Art. no. 8079, 2022. doi: <https://doi.org/10.3390/en15218079>
- [9] V. Y. Kondaiah and B. Saravanan, “A modified deep residual network for short-term load forecasting,” *Front. Energy Res.*, vol. 10, Art. no. 1038819, 2022. doi: <https://doi.org/10.3389/fenrg.2022.1038819>
- [10] A. L’heureux, K. Grolinger, and M. A. M. Capretz, “Transformer-based model for electrical load forecasting,” *Energies*, vol. 15, no. 14, Art. no. 4993, 2022. doi: <https://doi.org/10.3390/en15144993>
- [11] Z. Li and Z. Chen, “Short-term load forecasting based on CEEMDAN-FE-ISSA-LightGBM model,” *Front. Energy Res.*, vol. 11, Art. no. 1111786, 2023. doi: <https://doi.org/10.3389/fenrg.2023.1111786>
- [12] F. Liu, T. Dong, and Y. Liu, “An improved informer model for short-term load forecasting by considering periodic property of load profiles,” *Front. Energy Res.*, vol. 10, Art. no. 950912, 2022. doi: <https://doi.org/10.3389/fenrg.2022.950912>
- [13] L. Moosbrugger, V. Seiler, P. Wohlgenannt, S. Hegenbart, S. Ristov, E. Eder, and P. Kepplinger, “Load forecasting for households and energy communities: Are deep learning models worth the effort?” *arXiv*, 2025. doi: <https://arxiv.org/abs/2501.05000>
- [14] P. Tao, H. Ma, C. Li, and L. Liu, “Intelligent grid load forecasting based on BERT network model in low-carbon economy,” *Front. Energy Res.*, vol. 11, Art. no. 1197024, 2023. doi: <https://doi.org/10.3389/fenrg.2023.1197024>
- [15] M. Wu, W. Feng, X. Li, Y. Liu, and C. Cao, “Short-term power load forecasting using an improved model integrating GCN and transformer,” *Appl. Sci.*, vol. 15, no. 13, Art. no. 7003, 2025. doi: <https://doi.org/10.3390/app15137003>
- [16] X. Xiong, Z. Huang, Y. Chen, and J. Sun, “Load forecasting for commercial buildings using BiLSTM–Transformer network and cyber–physical cognitive control systems,” *Symmetry*, vol. 16, no. 12, Art. no. 1601, 2024. doi: <https://doi.org/10.3390/sym16121601>
- [17] L. Zeng, K. Zheng, G. Lin, J. Yang, M. Wu, G. Chen, and H. Jiang, “Enhanced short-term load forecasting based on adaptive residual fusion of Autoformer and Transformer,” *Energies*, vol. 18, no. 24, Art. no. 6496, 2025. doi: <https://doi.org/10.3390/en18246496>
- [18] Q. Zheng, J. Zheng, F. Mei, A. Gao, X. Zhang, and Y. Xie, “TCN-GAT multivariate load forecasting model based on SHAP value selection strategy in integrated energy system,” *Front. Energy Res.*, vol. 11, Art. no. 1208501, 2023. doi: <https://doi.org/10.3389/fenrg.2023.1208501>