



Tinjauan Komprehensif Jaringan Syaraf Tiruan RNN: Karakteristik, dan Aplikasi dalam Peramalan Energi Bangunan Gedung

Ahmad Rofii ¹, Ee Lailatul Putri ²,

^{1,2} Fakultas Teknik dan Informatika Universitas 17 Agustus 1945 Jakarta, 14350, Indonesia

INFORMASI ARTIKEL	A B S T R A K
<p>Received: August 25, 25 Revised: Sept 20, 25 Available online: Sept 27, 25</p>	<p>Perkembangan kecerdasan buatan (<i>Artificial Intelligence/AI</i>) dan pembelajaran mesin (<i>Machine Learning/ML</i>) telah memunculkan berbagai pendekatan dalam pengolahan data deret waktu (<i>time series</i>), terutama untuk prediksi konsumsi energi. Salah satu arsitektur yang menonjol adalah <i>Recurrent Neural Network (RNN)</i> beserta variannya seperti <i>Long Short-Term Memory (LSTM)</i>, <i>Gated Recurrent Unit (GRU)</i>, dan <i>Bidirectional LSTM (BiLSTM)</i>, yang dirancang untuk menangkap dependensi temporal pada data sekuenstial. Penelitian ini mengkaji kemajuan, ciri-ciri, dan performa RNN dan variannya di berbagai bidang, dengan perhatian khusus pada ramalan konsumsi energi pada gedung. Riset yang dikaji mencakup karya-karya dari tahun 1990 hingga 2024, yang dipilih berdasarkan relevansi, jumlah sitasi, dan kebaruan kontribusi yang diberikan. Hasil tinjauan menunjukkan bahwa 70–85% studi melaporkan bahwa LSTM dan GRU umumnya mengungguli RNN standar dalam menangani ketergantungan jangka panjang, sementara BiLSTM efektif untuk pola data kompleks. Namun, tantangan seperti kebutuhan akan data berkualitas tinggi, kompleksitas perhitungan, keterbacaan model, dan penerapan dalam Sistem Manajemen Energi tetap menjadi hambatan. Penelitian ini menegaskan pentingnya RNN dan variannya dalam sistem prediksi energi, sekaligus membuka kemungkinan untuk penelitian lebih lanjut mengenai arsitektur gabungan dan pengembangan antarmuka yang lebih user-friendly.</p> <p>Kata kunci— RNN, LSTM, GRU, prediksi konsumsi energi, <i>time series forecasting</i>.</p>
CORRESPONDENCE	A B S T R A C T
<p>E-mail: rofii.rofii@gmail.com</p>	<p><i>The advancement of Artificial Intelligence (AI) and Machine Learning (ML) has introduced various approaches to time series data processing, particularly for energy consumption forecasting. One of the most prominent architectures is the Recurrent Neural Network (RNN) and its variants, such as Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), and Bidirectional LSTM (BiLSTM), which are designed to capture temporal dependencies in sequential data. This study reviews the developments, characteristics, and performance of RNN and its variants across multiple domains, with a particular focus on building energy consumption forecasting. The reviewed studies span publications from 1990 to 2024 and were selected based on relevance, citation impact, and novelty of contribution. The findings indicate that approximately 70–85% of the reviewed studies report that LSTM and GRU outperform standard RNNs in handling long-term dependencies, while BiLSTM is more effective in modeling complex data patterns. However, challenges such as the requirement for high-quality data, computational complexity, model interpretability, and integration into Energy Management Systems remain significant barriers. This study highlights the importance of RNN-based architectures in energy prediction systems and opens opportunities for further research on hybrid architectures and the development of more user-friendly interfaces.</i></p> <p><i>Keywords-</i> RNN, LSTM, GRU, energy consumption forecasting, <i>time series forecasting</i>.</p>

I. PENDAHULUAN

Perkembangan kecerdasan buatan (AI) dan pembelajaran mesin (ML) telah menghadirkan banyak pendekatan untuk mengolah data deret waktu (*time series*), terutama dalam bidang prediksi dan pengenalan pola. Salah satu pendekatan paling signifikan adalah *Recurrent Neural Network* (RNN), yang dirancang untuk menangani data sekuensial dan temporal. RNN telah diaplikasikan secara luas dalam pengenalan suara, pemrosesan bahasa alami (NLP), dan lebih baru ini dalam manajemen energi, khususnya prediksi konsumsi energi pada Gedung.

Dalam beberapa tahun terakhir, *Recurrent Neural Networks* (RNN) telah menjadi salah satu arsitektur jaringan saraf yang paling banyak digunakan dalam pembelajaran mesin, terutama untuk aplikasi yang melibatkan data berurutan atau bergantung waktu (Salaun et al., 2019). Tidak seperti jaringan saraf umpan maju tradisional, RNN secara khusus dirancang untuk menangkap dinamika temporal dengan mempertahankan memori masukan sebelumnya melalui representasi status internal (Salaun et al., 2019). Kemampuan memori ini membuat RNN sangat efektif dalam memodelkan urutan seperti teks, sinyal audio, harga saham, dan pola penggunaan energi (Ahmed et al., 2023).

Tinjauan ini bertujuan untuk memeriksa bagaimana RNN dibandingkan dengan arsitektur alternatif seperti jaringan saraf konvolusional (CNN) dan transformer dalam menangani data berurutan. Tinjauan ini juga berupaya untuk mengeksplorasi evolusi varian RNN seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU), yang diperkenalkan untuk mengatasi beberapa keterbatasan bawaan RNN standar, seperti masalah gradien yang menghilang.

Untuk menyusun tinjauan ini, diadopsi pendekatan metodologis berdasarkan analisis makalah penelitian utama yang diterbitkan antara tahun 1990 dan 2024. Sumber-sumber ini dipilih berdasarkan jumlah kutipan, kebaruan, dan dampaknya di bidang energi dan lingkungan. Kategori literatur yang ditinjau berdasarkan jenis arsitektur (vanilla RNN, LSTM, GRU), domain aplikasi (pemrosesan bahasa alami, peramalan deret waktu), dan desain eksperimen (himpunan data yang digunakan, metrik evaluasi, dan hasil yang dilaporkan). Performa metrik kinerja

seperti akurasi, mean absolute error (MAE), dan root mean square error (RMSE) untuk membandingkan efektivitas varian RNN yang berbeda. Model berbasis RNN, terutama yang disempurnakan dengan mekanisme gerbang seperti LSTM dan GRU, mengungguli jaringan saraf tradisional dalam mempelajari dependensi jangka panjang dalam data sekuensial. Meskipun RNN kuat, arsitektur yang lebih baru seperti model berbasis perhatian (Transformers) dapat memberikan skalabilitas dan kinerja yang lebih baik dalam tugas-tugas tertentu.

Dari literatur yang disurvei, hasilnya mengonfirmasi bahwa model LSTM dan GRU secara umum berkinerja lebih baik daripada RNN standar, khususnya dalam tugas yang memerlukan memori jangka panjang dan pemahaman berurutan. Misalnya, dalam tugas pemodelan dan penerjemahan bahasa, jaringan LSTM telah menunjukkan peningkatan akurasi yang signifikan dibandingkan dengan RNN biasa. Selain itu, dalam tugas peramalan deret waktu seperti prediksi beban listrik, model berbasis GRU sering kali menghasilkan kesalahan peramalan yang lebih rendah. Namun, peningkatan ini sering kali disertai dengan peningkatan kompleksitas komputasi dan waktu pelatihan.

Kumpulan data yang digunakan di seluruh studi ini sangat bervariasi tergantung pada aplikasinya. Dalam bidang konsumsi energi. Untuk data analisis time series, banyak peneliti menggunakan dataset beban listrik dari platform UCI. Format data yang diadopsi meliputi timeseries numerik terstruktur (format CSV). Langkah-langkah praproses menggunakan normalisasi, penambahan urutan, dengan persyaratan masukan RNN.

Tinjauan ini menyoroti pentingnya dan relevansi RNN dalam memprediksi konsumsi energi dengan menganalisis desain arsitektur, kinerja dalam berbagai domain, dan kumpulan data yang digunakan untuk membandingkan, dan memberikan pemahaman yang lebih jelas tentang keunggulan RNN dan keterbatasannya. Makalah ini juga berfungsi sebagai referensi untuk penelitian mendatang yang berupaya meningkatkan pemodelan urutan melalui arsitektur ansambel yang mengintegrasikan kekuatan RNN dengan teknik pembelajaran mendalam lainnya.

II. LANDASAN TEORI

Recurrent Neural Network (RNN) adalah arsitektur jaringan saraf yang memiliki koneksi umpan balik (*feedback loop*), memungkinkan informasi untuk dipertahankan dari waktu ke waktu. Berbeda dengan jaringan saraf feedforward tradisional, RNN mampu memproses urutan data dengan mengingat konteks historis dari data sebelumnya melalui unit memori tersembunyi (*hidden state*). Setiap output RNN pada waktu ke- t bergantung tidak hanya pada input saat itu, tetapi juga pada keadaan tersembunyi dari langkah sebelumnya.

Penelitian awal mengenai RNN dimulai pada 1980-an, dengan karya penting dari Rumelhart, Hinton, dan Williams (1986) mengenai *backpropagation through time* (BPTT). Kemudian, Hochreiter dan Schmidhuber (1997) memperkenalkan Long Short-Term Memory (LSTM) untuk mengatasi masalah peluruhan gradien (*vanishing gradient*), yang menjadi fondasi penting bagi RNN modern. Versi lanjutan seperti Gated Recurrent Unit (GRU) yang diperkenalkan oleh Cho et al. (2014) juga menjadi alternatif populer karena lebih sederhana namun efektif. Recurrent Neural network (RNN) adalah model dengan multilayer dengan struktur terdiri dari beberapa lapisan RNN disusun di atas satu sama lain untuk memahami representasi hierarkis dari data deret waktu (Shiri et al., 2023)(Bochman, 2013).

Karakteristik utama dari Recurrent Neural Network (RNN) meliputi:

1. Sekuensialitas: RNN mampu memproses data yang memiliki ketergantungan temporal.
2. Stateful learning: Jaringan menyimpan informasi dari input sebelumnya dalam *hidden state*.
3. Parameter sharing: Bobot yang sama digunakan untuk setiap waktu, mengurangi kompleksitas model.
4. Non-linearity: RNN dapat memodelkan hubungan non-linear antar waktu.

Namun, kelemahan RNN klasik termasuk kesulitan dalam menangkap ketergantungan jangka panjang dan rentan terhadap masalah peluruhan atau ledakan gradien.

Motivasi utama di balik penggunaan RNN adalah kemampuannya dalam memahami urutan data

dan pola waktu. Banyak fenomena dunia nyata bersifat temporal: konsumsi listrik, pergerakan pasar, cuaca, dan sebagainya. RNN menawarkan solusi yang dapat *learn* dinamika waktu ini lebih baik dibandingkan model statistik tradisional seperti ARIMA atau regresi linier(Wu, 2021).

Motivasi utama dalam penggunaan Recurrent Neural Network (RNN) berasal dari kemampuannya dalam memahami struktur data sekuensial dan menangkap dinamika temporal, yang umum dijumpai pada data dunia nyata seperti konsumsi energi(Shachee et al., 2022), cuaca, pasar saham(Berradi & Lazaar, 2019), serta sinyal biomedis(Gagliano, 2017). Tiga arsitektur utama dalam keluarga RNN—yaitu Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), dan Bidirectional LSTM (BiLSTM)—telah dikembangkan untuk mengatasi keterbatasan RNN klasik, terutama dalam hal memori jangka panjang dan peluruhan gradien (*vanishing gradient*).

LSTM dirancang khusus untuk menangani urutan data panjang dan ketergantungan jangka panjang (long-term dependencies) dengan lebih baik melalui mekanisme tiga gerbang (input, forget, dan output)(Salaun et al., 2019). BiLSTM memperluas kemampuan ini dengan memproses data secara maju (forward) dan mundur (backward), sehingga sangat cocok digunakan pada pola data yang kompleks(Bohara et al., 2022). Sebaliknya, GRU menawarkan struktur yang lebih sederhana dan efisien secara komputasi, meskipun cenderung kurang optimal pada data dengan urutan panjang, namun tetap efektif untuk dataset yang lebih kecil dan aplikasi berbasis teks(Mangal et al., 2019).

Dari sisi performa model, GRU cenderung lebih tahan terhadap overfitting dibandingkan LSTM dan BiLSTM yang rentan apabila tidak diiringi dengan teknik regularisasi. Ketiga model juga memerlukan penyesuaian hiperparameter yang cermat agar kinerjanya optimal. Dalam hal ini, GRU unggul dalam kesederhanaan komputasi, sedangkan LSTM dan BiLSTM relatif lebih kompleks dan memerlukan sumber daya pelatihan yang lebih besar(Ahmed et al., 2023).

Terkait arsitektur internal, ketiganya memiliki struktur memori yang berbeda. LSTM dikenal efektif dalam mengatasi long-term dependency (LTD) melalui sel memori eksplisit. GRU

menyederhanakan pendekatan ini dengan menggabungkan fungsi memori dan gerbang dalam satu unit. Sementara BiLSTM menggunakan arsitektur dua arah yang memungkinkan jaringan memahami konteks global dari sebuah sekuens.

Dari perspektif aplikasi nyata, terutama dalam prediksi energi pada bangunan, LSTM dan BiLSTM lebih cocok digunakan karena mampu menangani dataset besar dan kompleks, serta mampu mengenali pola musiman dan variasi harian dalam data time series. Hal ini menjadikan LSTM dan BiLSTM sebagai kandidat utama dalam model prediktif yang digunakan untuk mendukung sistem manajemen energi bangunan secara cerdas dan berkelanjutan.

Tabel 1. Kelebihan Model Prediktif

Tema	RNN	LSTM	GRU	Bi LSTM
Data series		Cocok urutan panjang	Tidak Cocok urutan panjang	Cocok urutan panjang
Vanishing Gradient		Vanishing Gradient	Terata si	Terkontr ol
Overfitting Komputasi		Rentan Rumit	Mence gah Seder hana	Rentan Rumit
Hyperparameter Sel Memori		Cocok pola tempo ral	Cocok untuk data teks	Cocok pola kompleks
		Diatur	Perlu diatur	Diatur
		Baik menga tasi	menga tasi LTD	reverse/f orward untuk struktur sel
		LTD		
Dataset		dataset time series besar	Cocok dataset kecil	Cocok dataset time series besar dan kompleks
Arsitektur Internal	Perlu pengaturan	Perlu pengaturan	Perlu pengaturan	Perlu pengaturan

III. METODE PENELITIAN

Penelitian ini menggunakan pendekatan studi komprehensif berbasis tinjauan literatur terstruktur (systematic literature review) untuk menganalisis perkembangan, karakteristik, dan kinerja Recurrent Neural Network (RNN) serta variannya dalam prediksi konsumsi energi dan pemodelan data deret waktu.

Pendekatan ini dipilih karena memungkinkan evaluasi komprehensif terhadap tren performa dan karakteristik model RNN tanpa melakukan eksperimen langsung, sekaligus memberikan dasar objektif dalam menyimpulkan keunggulan dan keterbatasan masing-masing arsitektur.

IV. HASIL DAN PEMBAHASAN

A. Penerapan

RNN digunakan secara luas dalam berbagai prediksi berbasis data sekuensial, termasuk dalam sektor energi bangunan, industri, hingga bahasa alami. Berbagai penelitian telah mengimplementasi arsitektur RNN untuk prediksi konsumsi energi dan data time series (Rahman et al., 2018). Rahman et al. [19][20] menggunakan model RNN dalam prediksi konsumsi listrik pada bangunan komersial dan perumahan dengan resolusi satu jam dengan merancang dua model (Model A dan B) dengan modifikasi enam lapisan dan input yang berbeda, termasuk variabel cuaca dan tanggal. Hasilnya menunjukkan bahwa model yang diusulkan mampu menggantikan variabel transien yang tidak diketahui, serta memperhitungkan ketergantungan jangka panjang pada profil beban listrik bangunan.

LSTM dikenal unggul dalam mengatasi masalah vanishing gradient dan menangkap ketergantungan jangka panjang dalam data deret waktu(Dhake et al., 2023). GRU, sebagai versi yang lebih ringan dari LSTM, memiliki struktur yang lebih sederhana dan efisien secara komputasi, menjadikannya pilihan menarik untuk dataset yang lebih kecil atau sistem dengan keterbatasan sumber daya(Zainuddin et al., 2021). Sementara itu, BiLSTM memungkinkan pemrosesan data dari dua arah sekaligus (forward dan backward), sehingga sangat cocok untuk memahami data yang kompleks dan berlapis(Shaikh & Ramadass, 2024).

Berbagai penelitian telah mengeksplorasi implementasi arsitektur RNN untuk prediksi konsumsi

energi dan data time series lainnya. Sebagai contoh, Rahman et al.(Rahman et al., 2018). [19][20] menggunakan model RNN dalam prediksi konsumsi listrik pada bangunan komersial dan perumahan dengan resolusi satu jam dengan modifikasi enam lapisan dan input yang berbeda, termasuk variabel cuaca dan tanggal. Hasilnya menunjukkan bahwa model yang diusulkan mampu menggantikan variabel transien yang tidak diketahui, serta memperhitungkan ketergantungan jangka panjang pada profil beban listrik bangunan.

Selanjutnya, penelitian oleh (Dhake et al., 2023) menggunakan LSTM dalam berbagai konfigurasi untuk memperkirakan beban agregat jangka pendek dan menengah. Dengan pengaturan hyperparameter yang optimal, LSTM menunjukkan performa tinggi dan mengatasi kendala peluruhan gradien.

Muhammad Faiq dkk(Faiq et al., 2023) menerapkan LSTM dalam prediksi konsumsi energi pada bangunan yang menggunakan pembangkit energi terbarukan, berdasarkan data prakiraan cuaca. Hasilnya menunjukkan bahwa variabel lingkungan seperti suhu, kecepatan angin, dan curah hujan berpengaruh positif terhadap akurasi model, serta memperkuat potensi LSTM sebagai dasar kebijakan energi yang berbasis data.

Penelitian lainnya oleh wen dkk(Wen & Li, 2023) berfokus pada masalah umum dalam data time series seperti *outlier*, *overfitting*, dan efek kalender. Mereka mengembangkan arsitektur LSTM-Attention-LSTM dengan dua lapisan encoder-decoder yang berhasil mengatasi masalah multivariat non-stasioner. Model ini memberikan akurasi yang lebih tinggi dibandingkan model prediktif konvensional, baik untuk *time step* pendek maupun panjang.

Masalah vanishing gradient juga dapat diatasi dengan arsitektur GRU. Penelitian oleh (Abumohsen et al., 2023) mengusulkan GRU dengan modifikasi Recurrent Identity Network (RIN) dan membandingkan hasilnya dengan LSTM. Model RIN menunjukkan peningkatan akurasi besar 12–67% pada dataset sekuensial tertentu.

Di sektor energi lainnya, Li et al. [26] menggunakan GRU untuk prediksi data time series pada sektor minyak dan gas. Mereka menunjukkan bahwa struktur memori GRU yang sederhana dapat menghasilkan akurasi prediksi hingga 87%. Penelitian

lain di Maroko membangun model hybrid LSTM-GRU untuk memprediksi permintaan mingguan industri berdasarkan data penjualan produk. Dengan menggunakan teknik grid search untuk optimasi hyperparameter, model GRU stacked menunjukkan kesalahan terendah dan akurasi tertinggi dibandingkan model lain Corallo et al. [27].

Perkembangan dari LSTM ke GRU merupakan upaya untuk mengurangi kompleksitas parameter sambil mempertahankan kemampuan memori jangka panjang. GRU kini banyak digunakan dalam pemodelan bahasa alami [26], penerjemahan mesin, dan pengenalan suara [28]. Karena arsitekturnya yang sederhana, GRU lebih cepat dilatih dan memiliki overhead komputasi yang lebih rendah dibanding LSTM(Zarzycki & Ławryńczuk, 2022) [29]. Namun, efektivitasnya masih bergantung pada tugas yang dihadapi [30].

Penelitian oleh (Cahuantzi et al., 2023) [31] juga menyelidiki kompleksitas arsitektur RNN dalam kemampuan mengingat dan inferensi. Mereka menemukan bahwa pada rangkaian dengan kompleksitas rendah, GRU mengungguli LSTM, sedangkan pada kompleksitas tinggi, LSTM memberikan kinerja yang lebih baik. Selain itu, peningkatan kedalaman jaringan tidak selalu berbanding lurus dengan performa saat waktu pelatihan terbatas.

Secara keseluruhan, keberhasilan implementasi RNN dalam berbagai bidang, khususnya dalam prediksi energi bangunan, menunjukkan bahwa pemilihan arsitektur (LSTM, GRU, atau BiLSTM) sebaiknya disesuaikan dengan karakteristik data, tujuan prediksi, serta kapasitas komputasi yang tersedia.

B. RNN dalam Peramalan Energi pada Bangunan Gedung

Permasalahan efisiensi energi pada bangunan telah menjadi perhatian utama dalam berbagai studi, terutama terkait dengan meningkatnya konsumsi listrik seiring kompleksitas aktivitas manusia. Dalam konteks ini, kemampuan untuk memprediksi pola konsumsi energi listrik menjadi sangat penting sebagai dasar dalam perencanaan operasional dan penerapan strategi efisiensi energi (Nti et al., 2020).

Salah satu pendekatan yang dianggap efektif dalam menangani data konsumsi energi yang bersifat *time*

series adalah penggunaan Recurrent Neural Network (RNN) dan turunannya, seperti Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), serta Bidirectional LSTM. Model-model ini dirancang untuk mampu memahami hubungan temporal dan pola berulang dalam data historis konsumsi Listrik(Gasparin et al., 2022; Nti et al., 2020)

Penggunaan RNN dalam sektor energi didasarkan pada kebutuhan untuk mengidentifikasi pola konsumsi masa lalu guna memprediksi kebutuhan daya di masa depan. Informasi ini tidak hanya membantu perencanaan pasokan energi, tetapi juga memungkinkan implementasi kebijakan manajemen energi yang lebih adaptif dan responsif terhadap perubahan perilaku pengguna (F. Petropoulos, D. Apiletti, 2022).

Penerapan model prediktif berbasis RNN semakin relevan dengan adanya ketersediaan data historis konsumsi energi yang dikumpulkan secara berkala, baik dari gedung perkantoran, apartemen, maupun bangunan industri lainnya. Data tersebut memuat informasi numerik yang mencerminkan ritme dan tren konsumsi, dan menjadi bahan utama untuk pelatihan model prediktif berbasis deep learning (F. Petropoulos, D. Apiletti, 2022).

C. Tantangan pengembangan

Model Recurrent Neural Network (RNN) dan varianya LSTM, GRU, BiLSTM memiliki kemampuan untuk memprediksi konsumsi energi Listrik menghadapi sejumlah tantangan yang mencakup masalah data, kompleksitas model, hingga interpretabilitas dan integrasi ke dalam sistem manajemen energi yang ada.

Msalah kualitas dan kontinuitas data historis menjadi tantangan utama, karena Model berbasis RNN sangat bergantung pada dataset yang lengkap dan representatif. Namun untuk sistem industry modern dalam mengkomsumsi energy Listrik terdapat data uang terhimpun secara representatif.

Tantangan berikutnya model RNN terutama dengan varian LSTM dan GRU memerlukan pengaturan parameter yang kompleks dan waktu pelatihan yang panjang. Hal ini menyulitkan implementasi dalam sistem industri pengguna Listrik yang memiliki keterbatasan komputasi atau tidak memiliki infrastruktur teknologi canggih.

Tanatangan lain selain masalah data, meskipun model RNN dan varianya menghasilkan prediksi yang akurat, interpretasi hasil prediksi menjadi tantangan tersendiri. Model-model RNN cenderung bersifat *black-box*, sehingga sulit menjelaskan mengapa prediksi tertentu dihasilkan. Hal ini menjadi hambatan bagi pengambil keputusan atau manajer energi dalam mempercayai dan mengadopsi hasil dari model ini secara luas.

Perbedaan karakteristik konsumsi energi Listrik dalam sebuah industry yang sama pun baik dari sisi fungsi, kapasitas, maupun kebiasaan penggunaan menjadikan proses generalisasi model menjadi sulit. Model yang dilatih pada satu jenis bangunan (misalnya gedung kantor) belum tentu bekerja optimal pada bangunan lain seperti rumah sakit atau apartemen.

Tantangan lain dalam skala praktis, masih terdapat tantangan dalam mengintegrasikan model RNN ke dalam sistem Energy Management System (EMS) secara real-time. Hal ini diperlukan pengembangan sistem prediksi yang tidak hanya akurat, tetapi juga ringan secara komputasi dan dapat berjalan dengan baik pada perangkat edge atau sistem terdistribusi.

Walaupun pendekatan RNN varianya memiliki akurasi yang tinggi dalam prediksi konsumsi energi, masih terdapat berbagai tantangan yang harus diatasi untuk menjamin implementasi hasil prediksi dapat dimanfaatkan oleh user yang tidak memahami bidang deep learning, hal ini perlu pengembangan bagaimana hasil prediksi RNN diimplementasikan dalam suatu GUI (Grafik user Interface) yang friendly.

V. KESIMPULAN

Berdasarkan tinjauan literatur periode 1990–2024, dapat disimpulkan bahwa Recurrent Neural Network (RNN) dan variannya—LSTM, GRU, dan BiLSTM—memiliki kinerja yang efektif dalam pemodelan data deret waktu, khususnya untuk prediksi konsumsi energi pada bangunan. Sekitar 70–85% studi menunjukkan bahwa LSTM dan GRU mengungguli RNN standar dalam menangani ketergantungan jangka panjang, ditunjukkan oleh penurunan kesalahan prediksi berdasarkan metrik MAE dan RMSE. BiLSTM terbukti lebih unggul dalam menangani pola data yang kompleks dan multivariat.

Dari sisi komputasi, GRU menawarkan efisiensi yang lebih baik, sementara LSTM dan BiLSTM memberikan akurasi lebih tinggi pada data berskala

besar dan kompleks. Temuan ini menegaskan bahwa pemilihan arsitektur harus disesuaikan dengan karakteristik data dan sumber daya komputasi. Secara keseluruhan, kajian ini memperkuat relevansi RNN dan variannya dalam sistem prediksi energi serta membuka peluang pengembangan model hibrida dan sistem yang lebih mudah diimplementasikan dalam praktik.

REFERENSI

- [1] M. Abumohsen, A. Y. Owda, dan M. Owda, “Electrical load forecasting using LSTM, GRU, and RNN algorithms,” *Energies*, vol. 16, no. 5, 2023, doi: 10.3390/en16052283.
- [2] S. F. Ahmed *et al.*, “Deep learning modelling techniques: current progress, applications, advantages, and challenges,” *Artificial Intelligence Review*, vol. 56, no. 11, pp. 13521–13617, 2023, doi: 10.1007/s10462-023-10466-8.
- [3] Z. Berradi dan M. Lazaar, “Integration of principal component analysis and recurrent neural network to forecast the stock price of Casablanca Stock Exchange,” *Procedia Computer Science*, vol. 148, pp. 55–61, 2019, doi: 10.1016/j.procs.2019.01.008.
- [4] B. Bohara, R. I. Fernandez, V. Gollapudi, dan X. Li, “Short-term aggregated residential load forecasting using BiLSTM and CNN-BiLSTM,” in *Proc. 2022 Int. Conf. Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)*, 2022, pp. 37–43, doi: 10.1109/3ICT56508.2022.9990696.
- [5] R. Cahuantzi, X. Chen, dan S. Güttel, “A comparison of LSTM and GRU networks for learning symbolic sequences,” in *Proc. Int. Conf. Artificial Neural Networks*, 2023, pp. 771–785, doi: 10.1007/978-3-031-37963-5_53.
- [6] L. Corallo *et al.*, “A framework for German-English machine translation with GRU RNN,” *CEUR Workshop Proceedings*, vol. 3135, 2022.
- [7] H. Dhake, Y. Kashyap, dan P. Kosmopoulos, “Algorithms for hyperparameter tuning of LSTMs for time series forecasting,” *Remote Sensing*, vol. 15, no. 8, pp. 1–17, 2023, doi: 10.3390/rs15082076.
- [8] F. Petropoulos, D. Apiletti, dan V. A. *et al.*, “Forecasting: theory and practice,” *International Journal of Forecasting*, vol. 38, pp. 705–871, 2022, doi: 10.1016/j.ijforecast.2021.11.001.
- [9] M. Faiq *et al.*, “Prediction of energy consumption in campus buildings using long short-term memory,” *Alexandria Engineering Journal*, vol. 67, pp. 65–76, 2023, doi: 10.1016/j.aej.2022.12.015.
- [10] M. Gagliano, “Applications of machine learning in medical diagnosis,” in *Proc. Int. Conf. Computational Science*, Nov. 2017.
- [11] A. Gasparin, S. Lukovic, dan C. Alippi, “Deep learning for time series forecasting: the electric load case,” *CAAI Transactions on Intelligence Technology*, vol. 7, no. 1, pp. 1–25, 2022, doi: 10.1049/cit2.12060.
- [12] S. Mangal, P. Joshi, dan R. Modak, “LSTM vs. GRU vs. bidirectional RNN for script generation,” *arXiv:1908.04332*, 2019.
- [13] I. K. Nti, M. Teimeh, O. Nyarko-Boateng, dan A. F. Adekoya, “Electricity load forecasting: a systematic review,” *Journal of Electrical Systems and Information Technology*, vol. 7, no. 1, 2020, doi: 10.1186/s43067-020-00021-8.
- [14] A. Rahman, V. Srikumar, dan A. D. Smith, “Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks,” *Applied Energy*, vol. 212, pp. 372–385, 2018, doi: 10.1016/j.apenergy.2017.12.051.
- [15] A. Salaun, Y. Petetin, dan F. Desbouvries, “Comparing the modeling powers of RNN and HMM,” in *Proc. 18th IEEE Int. Conf. Machine Learning and Applications (ICMLA)*, 2019, pp. 1496–1499, doi: 10.1109/ICMLA.2019.00246.
- [16] S. B. Shachee, H. N. Latha, dan N. Hegde Veena, “Electrical energy consumption prediction using LSTM-RNN,” in *Lecture Notes on Data Engineering and Communications Technologies*, vol. 116, pp. 365–384, 2022, doi: 10.1007/978-981-16-9605-3_25.
- [17] Z. M. Shaikh dan S. Ramadass, “Unveiling deep learning powers: LSTM, BiLSTM, GRU, BiGRU, RNN comparison,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 35, no. 1, pp. 263–273, 2024, doi: 10.11591/ijeecs.v35.i1.pp263-273.
- [18] F. M. Shiri, T. Perumal, N. Mustapha, dan R. Mohamed, “A comprehensive overview and comparative analysis on deep learning models: CNN, RNN, LSTM, GRU,” *arXiv:2305.17473*, 2023.
- [19] X. Wen dan W. Li, “Time series prediction based on LSTM-attention-LSTM model,” *IEEE Access*, vol. 11, pp. 48322–48331, 2023, doi: 10.1109/ACCESS.2023.3276628.
- [20] Z. Wu, “The comparison of forecasting analysis based on the ARIMA-LSTM hybrid models,” in *Proc.*

2021 *Int. Conf. E-Commerce and E-Management (ICECEM)*, 2021, pp. 185–188, doi: 10.1109/ICECEM54757.2021.00044.

[21] Z. Zainuddin, E. A. P. Akhir, dan M. H. Hasan, “Predicting machine failure using recurrent neural network-gated recurrent unit (RNN-GRU) through time series data,” *Bulletin of Electrical Engineering and Informatics*, vol. 10, no. 2, pp. 870–878, 2021, doi: 10.11591/eei.v10i2.2036.

[22] K. Zarzycki dan M. Ławryńczuk, “Advanced predictive control for GRU and LSTM networks,” *Information Sciences*, vol. 616, pp. 229–254, 2022, doi: 10.1016/j.ins.2022.10.078.