



Estimasi Daya Aktif pada Gedung Bertingkat Dengan Menggunakan *Time Series Neural Network*

Ony Ramadhan Armanto¹, Novie Ayub Windarko², Setiawardhana³

Onyarmanto97@gmail.com , ayub@pens.ac.id , setia@pens.ac.id

Politeknik Elektronika Negeri Surabaya

Informasi Artikel

Diterima : 14 Feb 2024

Direview : 23 Mar 2024

Disetujui : 1 Apr 2024

Kata Kunci

Estimasi beban listrik ,
Time Series, Neural
Network , Gedung
bertingkat

Abstrak

Penggunaan energi listrik untuk kehidupan sehari – hari semakin meningkat tanpa adanya pengawasan dan pembatasan yang mengakibatkan penggunaan energi semakin semena – mena , penggunaan energi berlebihan juga disebabkan perkembangan teknologi yang semakin memudahkan pekerjaan manusia. Namun kebutuhan energi listrik yang besar tidak disertai dengan kapasitas energi listrik yang memadai. Oleh sebab itu diperlukan sebuah metode estimasi beban listrik jangka menengah dengan menggunakan *Time Series Neural Network*. Penelitian ini diharapkan dapat mengurangi jumlah energi listrik yang tidak terpakai dan digunakan se efisien mungkin. Pada penelitian ini menghasilkan nilai MAPE sebesar 5.36% dan nilai RMSE sebesar 9.2.

Keywords

Electrical Forecasting , Time Series , Neural Network , Rise Buildings

Abstract

Electricity for daily life has increased day by day without proper monitoring and restrictions, and became reckless energy consumption. Excessive energy consumptions is also impact from technologycal advancement can make human task more easier. However the electricity energy is not accompanied with the electricity produce. Therefore, a methode for estimating mid-term electrical load using time series is needed. This research expected can reduce unused electrical energy and more efficient usage. And the result value for Mean Percentage Absolut Error (MAPE) is 5.06% and the Root Mean Square Error (RMSE) value is 9.2.

A. Pendahuluan

Energi listrik merupakan energi yang sangat dibutuhkan oleh banyak orang karena membantu setiap kegiatan terutama dalam industri dan perkantoran, pertumbuhan teknologi yang semakin meningkat menyebabkan kebutuhan energi listrik semakin besar[1]. Energi listrik juga merupakan kebutuhan utama yang memiliki peran dalam berkembangnya atau kemajuan ekonomi secara global, namun kebutuhan dan produksi energi yang tidak sama akan menyebabkan kerugian secara banyak faktor[2] Oleh sebab itu diperlukan adanya estimasi atau prakiraan daya aktif agar dapat memperkirakan kebutuhan energi yang akan digunakan salah satu cara untuk melakukan estimasi beban dapat menggunakan *Artificial Neural Network* (Kecerdasan Buatan)[3].

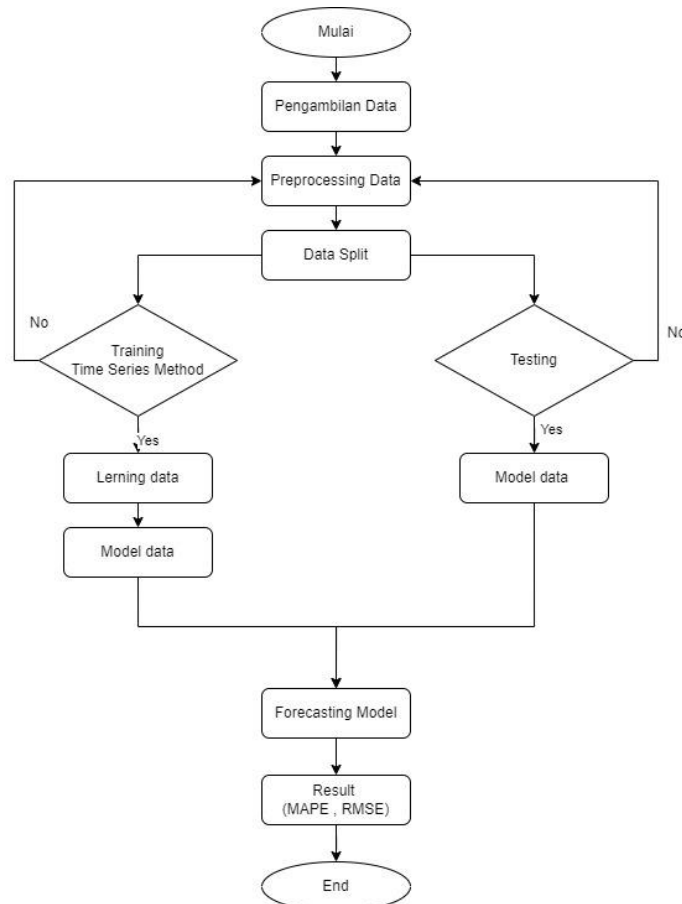
Banyak penelitian terhadap *Artificial Neural Network* (Kecerdasan Buatan) dari *Single Methode* hingga *hybrid methode* [4] . Kecerdasan buatan sendiri sudah lama digunakan dan dibenamkan dalam teknologi terbaru sebagai alat yang memudahkan pekerjaan dan memperoleh waktu se efisien mungkin. [5] , kecerdasan buatan sendiri banyak digunakan dalam berbagai penelitian terbaru, karena kecerdasan buatan menirukan kecerdasan manusia dalam prinsip kerjanya dan juga proses pembelajaran ini dapat digunakan untuk proses yang *non-linier* [6] . Salah satu metode yang sering digunakan dalam kecerdasan buatan adalah *Time Series Neural Network* yaitu salah satu metode kecerdasan buatan yang terfokus pada waktu, pada penelitian ini akan menggunakan *time series* karena salah satu jenis metode yang dapat bekerja pada proses *non - linier* dan juga dapat digunakan untuk estimasi.[7]

Penelitian untuk estimasi digunakan untuk menghasilkan model terbaik yang akan digunakan untuk memperkirakan dari objek penelitian[8]. Ada beberapa estimasi yang cukup sering digunakan untuk penelitian yaitu *Short term* (jangka pendek), *Mid - Term* (Jangka menengah) , *Long term* (jangka panjang). Perbedaan yang paling utama dari estimasi tersebut terletak pada jangka waktu yang digunakan untuk penelitian[9]. Estimasi yang digunakan untuk penelitian ini yaitu *Mid - Term* (Jangka menengah) yang berkisar kurang lebih 1 bulan hingga 6 bulan[10]. Penelitian yang menggunakan *Short Term* (Jangka Pendek) digunakan untuk mencari beban harian namun tidak menghasilkan model terbaik dan tidak digunakan dalam peramalan bulanan .Penelitian ini berfokus pada mencari model terbaik untuk beberapa bulan kedepan dan menghasilkan rekomendasi yang akan digunakan untuk parameter sistem[11].

Dari latar belakang diatas maka peneliti mengangkat topik penelitian yang berjudul Estimasi Daya Aktid pada gedung bertingkat dengan menggunakan *Time Series Neural Network*.

B. Metode Penelitian

Metode yang digunakan dalam penelitian ini menggunakan *Time Series Neural Network*, yang merupakan salah satu jenis metode dari *Artificial neural network* (Kecerdasan buatan) metode digunakan untuk menghasilkan model terbaik dengan error seminimal mungkin



Gambar 1. Diagram Alur Penelitian

Metode *time series neural network* menggunakan 8064 data yang dibagi menjadi 3 bagian, 60% untuk training data, 30% Testing data serta 10% untuk validasi data. Pada gambar 1 data diambil dari panel listrik menggunakan *Smart meter Logger*. *Smart meter logger* adalah salah satu alat yang berguna mencatat data yang kemudian tersusun rapi secara berurutan[12] data yang diambil ada beberapa diantaranya yaitu :

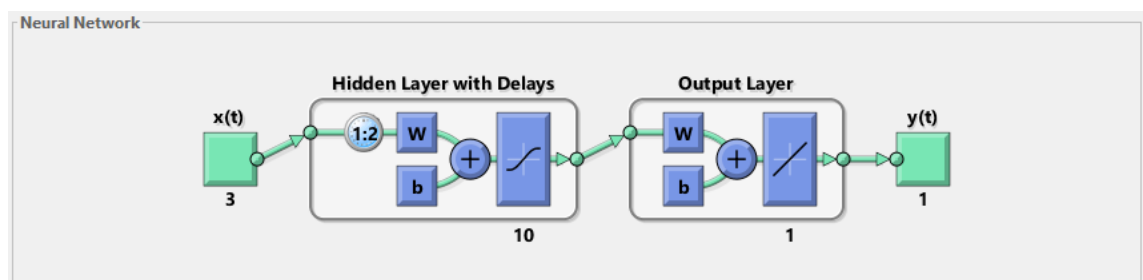
1. Data Tegangan (R,S,T)
2. Data Arus (R,S,T)
3. Hari dan Tanggal
4. Data Beban (P,S,Q)
5. Data Frekuensi
6. Data Total Energy



Gambar 2. Smart Meter Logger

Kemudian setelah data didapat dari *Smart meter logger* lakukan data processing dengan menentukan data yang akan digunakan untuk melakukan training data serta testing. Karena penelitian ini menggunakan *Time Series Neural Network* maka data yang digunakan adalah data hari, tanggal, Data beban aktif (KW). kemudian dilakukan *preprocessing data* dengan memperbaiki apabila jika ada data yang hilang.

Time Series disini menggunakan *NARX (Non - linier Autoregressive with Exogenous Input)* yang dimana menggunakan input tertentu sebagai objek yang diamati kemudian diproses dengan pemodelan deret waktu yang memperhitungkan input *Exogenous* (input yang tidak sedang diamati)[13]



Gambar 3. Jaringan Syaraf NARX Time Series Neural Network

Kemudian setelah memperoleh data preprocessing maka akan mendapat dataset, dataset ini berjumlah 8064 data yang akan dibagi menjadi 3.

- Training 60% = 4838 data
- Testing 30% = 2419 data
- Validation 10% = 807 data

Setelah menentukan jumlah data yang akan digunakan untuk training dan testing maka dilakukan split data sesuai dengan jumlah data yang akan digunakan untuk proses data. Aplikasi yang digunakan guna menunjang melakukan proses adalah aplikasi *Matlab*. Kemudian pada *Matlab* menggunakan metode *Time Series Neural Network* untuk melakukan data validasi dan data training yang kemudian

menghasilkan learning rate dan regresi serta output dari training data dan validasi

Hasil dari data training dan validasi kemudian di lakukan tesing menggunakan data tesing dan output data training. Hasil dari testing akan menghasilkan model yang akan digunakan untuk estimasi beban. Namun sebagai perbandingan dilakukan pengambilan data sekali lagi pada bulan berikutnya , lalu dilakukan perbandingan antara hasil model dengan data terbaru bulan berikutnya serta memunculkan nilai RMSE (Root Mean Square Error) dan nilai MAPE (Mean Absolute Percentage Error)

C. Hasil dan Pembahasan

Pada penelitian ini terdapat 3 macam percobaan dengan menggunakan 2 delays , 5 delays dan 10 delays. Delays digunakan untuk karena mengikuti konsep lama waktu yang digunakan untuk memproses data antara input dengan outpur berdasarkan deret waktu[14]. Pada 2 delays menggunakan input tanggal, daya aktif (KW), Tegangan(V) , Arus (A) dan PF dengan target adalah daya aktif pada bulan berikutnya, dan hasil MAPE dan RMSE sebagai berikut :

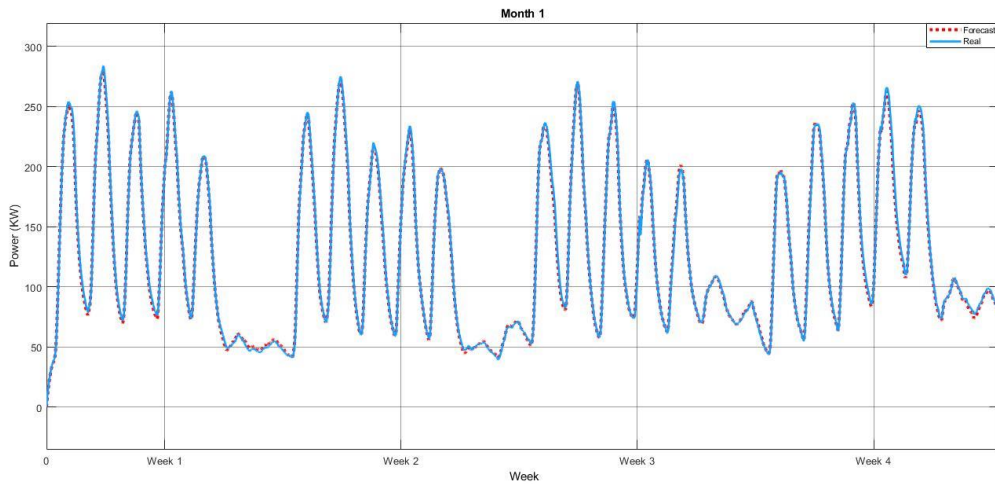
Tabel 1. Tabel MAPE 2 Delays

MAPE Time Series (2 Delays)						
JUMLAH HIDDEN NEURON						
Bulan	10 Hidden	50 Hidden	100 Hidden	150 Hidden	250 Hidden	500 Hidden
Bulan 2	6.10%	5.36%	5.66%	5.97%	6.87%	7.50%
Bulan 3	22.05%	22.10%	22.28%	22.40%	22.40%	23.03%


Tabel 2. Tabel RMSE 2 Delays

RMSE Time Series (2 Delays)						
JUMLAH HIDDEN NEURON						
Bulan	10 Hidden	50 Hidden	100 Hidden	150 Hidden	250 Hidden	500 Hidden
Bulan 2	9.36	9.2	9.5	9.81	11.93	13.5
Bulan 3	34.12	34.1	34.44	34.44	35.08	35.82

Dan untuk perbandingan antara hasil model output dengan data terbaru adalah sebagai berikut



Gambar 4. Grafik 2 Delay bulan 1



Gambar 5. Grafik 2 delay bulan 2

Untuk percobaan berikutnya yaitu dengan 5 delays menggunakan input berupa hari , tanggal dan daya aktif serta untuk target adalah daya aktif bulan berikutnya berikut hasil MAPE dan RMSE serta grafik perbandingannya.

Tabel 3. Tabel MAPE 5 delays


MAPE Time Series (5 Delay)						
JUMLAH HIDDEN NEURON						
Bulan	10 Hidden	50 Hidden	100 Hidden	150 Hidden	250 Hidden	500 Hidden
Bulan 2	19.97%	16.50%	16.41%	15.90%	15.88%	15.80%
Bulan 3	19.54%	20.80%	20.93%	21.17%	20.83%	20.86%

Tabel 4. Tabel RMSE 5 Delays

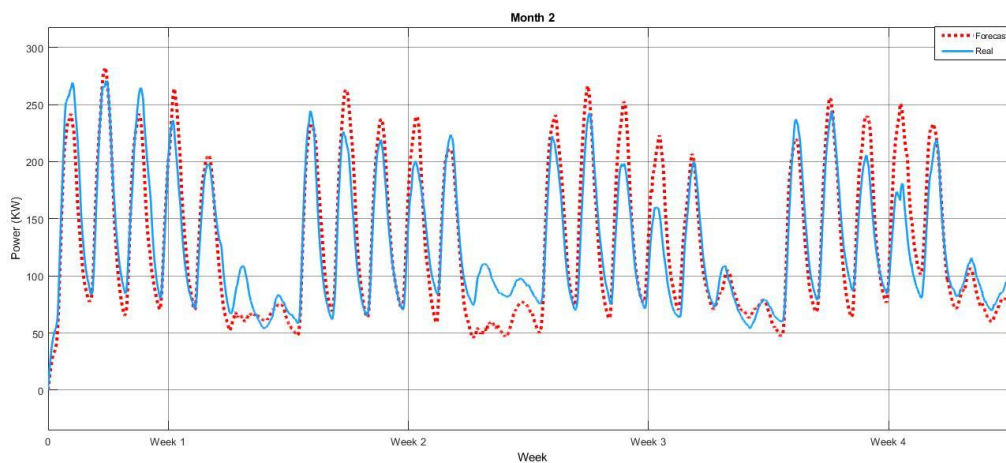
RMSE Time Series (5 Delay)						
----------------------------	--	--	--	--	--	--

Bulan	JUMLAH HIDDEN NEURON					
	10 Hidden	50 Hidden	100 Hidden	150 Hidden	250 Hidden	500 Hidden
Bulan 2	25.48	21.64	21.86	21.12	21.07	21.05
Bulan 3	29.85	31.79	32.4	32.82	32.68	32.72

Dan untuk perbandingan antara hasil model output dengan data terbaru adalah sebagai berikut



Gambar 6. Grafik 5 Delay bulan 1



Gambar 7. Grafik 5 Delays bulan 2

Kemudian berikutnya yaitu dengan 10 delays menggunakan input berupa hari , tanggal dan daya aktif serta untuk target adalah daya aktif bulan berikutnya berikut hasil MAPE dan RMSE serta grafik perbandingannya.

Tabel 5. Tabel MAPE 10 Delays

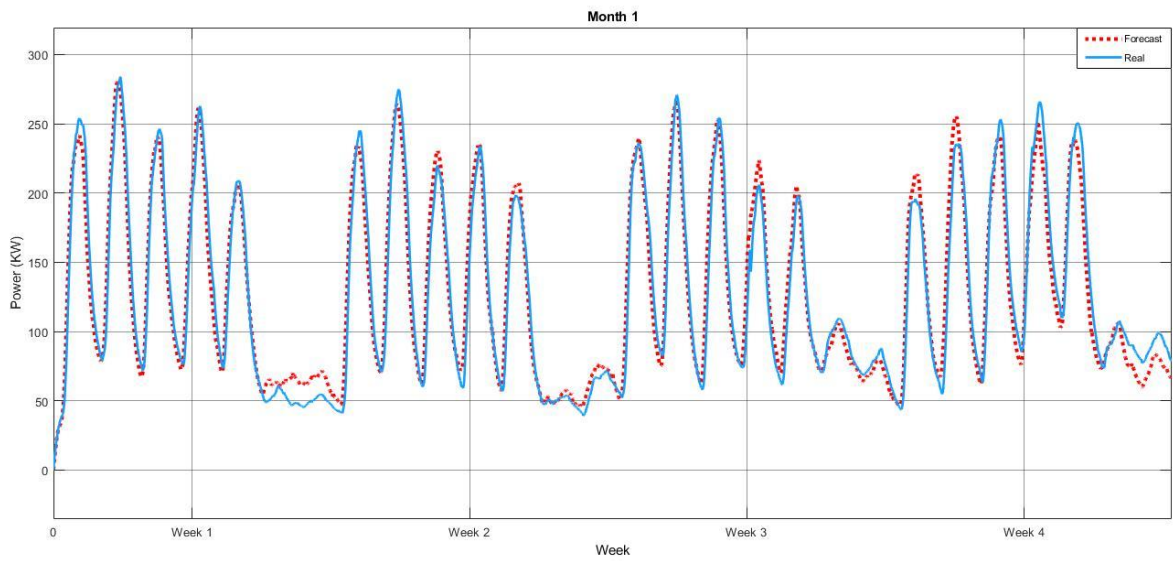
MAPE Time Series (10 Delays)	
JUMLAH HIDDEN NEURON	

Bulan	10 Hidden	50 Hidden	100 Hidden	150 Hidden	250 Hidden	500 Hidden
Bulan 2	21.87%	19.85%	19.99%	19.81%	24.28%	18.98%
Bulan 3	21.55%	22.95%	22.57%	23.42%	23.64%	23.21%


Tabel 6. Tabel RMSE 10 Delays

RMSE Time Series (10 Delays)						
JUMLAH HIDDEN NEURON						
Bulan	10 Hidden	50 Hidden	100 Hidden	150 Hidden	250 Hidden	500 Hidden
Bulan 2	29.36	27.14	27.14	28.14	32.08	26.85
Bulan 3	32.44	34.86	34.74	36.24	34.79	35.93

Dan untuk perbandingan antara hasil model output dengan data terbaru adalah sebagai berikut



Gambar 8 Grafik 10 Delay bulan 1



Gambar 9 Grafik 10 Delay bulan 2

Untuk interpretasi dari nilai MAPE sendiri adalah sebagai berikut

Tabel 7 Tabel Interpretasi MAPE

No	Persentase	Akurasi
1	0 - 10%	Sangat Akurat
2	11 - 20%	Akurat
3	21 - 30%	Kurang Akurat
4	31 - 40%	Tidak Akurat

Jika mengikuti tabel interpretasi yang digunakan maka pada percobaan 1 dengan 2 delay menghasilkan nilai MAPE terbaik yaitu 5,36% dengan akurasi sangat akurat. Untuk percobaan 2 dengan 5 delay menghasilkan nilai MAPE terbaik yaitu 15,80% dengan akurasi akurat, serta untuk percobaan 3 dengan 10 delay menghasilkan nilai MAPE terbaik yaitu 18,98%

D. Simpulan

Kesimpulan pada penelitian kali ini pada percobaan 1 menggunakan lebih banyak input yaitu tanggal, Daya aktif (KW), Tegangan(V), Arus(A), dan PF memiliki model output dengan akurasi sangat akurat pada bulan 1 namun tidak bisa digunakan ketika bulan ke 2. Berbeda dengan percobaan 2 dan 3 yang menggunakan 3 input yaitu hari, tanggal dan daya aktif yang memiliki akurasi akurat dengan nilai MAPE dibawah 20% sehingga model output bisa digunakan pada bulan bulan berikutnya.

Semakin banyak input maka akurasi semakin tinggi namun hanya terdapat pada bulan tertentu dan jika ingin memunculkan model terbaru harus melakukan training kembali. Sedangkan jika semakin sedikit input maka akurasi semakin berkurang namun pada titik tertentu akurasi dirasa cukup bisa digunakan untuk memunculkan model terbaik yang dapat melakukan estimasi beban daya aktif

E. Referensi

- [1] A. Rassõlkin *et al.*, "Implementation of digital twins for electrical energy conversion systems in selected case studies," *Proceedings of the Estonian Academy of Sciences*, vol. 70, no. 1, pp. 19–39, 2021, doi: 10.3176/proc.2021.1.03.
- [2] Y. Chen and D. Zhang, "Theory-guided deep-learning for electrical load forecasting (TgDLF) via ensemble long short-term memory," *Advances in Applied Energy*, vol. 1, Feb. 2021, doi: 10.1016/j.adapen.2020.100004.
- [3] G. Tziolis *et al.*, "Direct short-term net load forecasting in renewable integrated microgrids using machine learning: A comparative assessment," *Sustainable Energy, Grids and Networks*, vol. 37, p. 101256, Mar. 2024, doi: 10.1016/j.segan.2023.101256.
- [4] M. A. Hammad, B. Jereb, B. Rosi, and D. Dragan, "Methods and Models for Electric Load Forecasting: A Comprehensive Review," *Logistics & Sustainable Transport*, vol. 11, no. 1, pp. 51–76, Feb. 2020, doi: 10.2478/jlst-2020-0004.
- [5] M. Askari and F. Keynia, "Mid-term electricity load forecasting by a new composite method based on optimal learning MLP algorithm," *IET Generation*,

- Transmission and Distribution*, vol. 14, no. 5, pp. 845–852, Mar. 2020, doi: 10.1049/jiet-gtd.2019.0797.
- [6] N. A. Mohammed and A. Al-Bazi, “An adaptive backpropagation algorithm for long-term electricity load forecasting,” *Neural Comput Appl*, vol. 34, no. 1, pp. 477–491, Jan. 2022, doi: 10.1007/s00521-021-06384-x.
- [7] B. Lim and S. Zohren, “Time-series forecasting with deep learning: A survey,” *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 379, no. 2194. Royal Society Publishing, Apr. 05, 2021. doi: 10.1098/rsta.2020.0209.
- [8] M. Ghiassi, D. K. Zimbra, and H. Saidane, “Medium term system load forecasting with a dynamic artificial neural network model,” *Electric Power Systems Research*, vol. 76, no. 5, pp. 302–316, Mar. 2006, doi: 10.1016/j.epsr.2005.06.010.
- [9] S. L. Zubaidi *et al.*, “A Method for Predicting Long-Term Municipal Water Demands Under Climate Change,” *Water Resources Management*, vol. 34, no. 3, pp. 1265–1279, Feb. 2020, doi: 10.1007/s11269-020-02500-z.
- [10] “Medium-term load forecasting using neural network approach”.
- [11] P. Bunnoon, K. Chalermyanont, and C. Limsakul, “Mid-term load forecasting: Level suitability of wavelet and neural network based on factor selection,” in *Energy Procedia*, 2012, pp. 438–444. doi: 10.1016/j.egypro.2011.12.955.
- [12] K. Hassan, M. K. Agboola, T. A. Oladiran, and I. I. Olorunmaye, “Microcontroller Based Smart Energy Meter with Data Logger System,” *Journal of Advanced Industrial Technology and Application*, vol. 4, no. 2, Dec. 2023, doi: 10.30880/jaita.2023.04.02.009.
- [13] M. Massaoudi *et al.*, “An Effective Hybrid NARX-LSTM Model for Point and Interval PV Power Forecasting,” *IEEE Access*, vol. 9, pp. 36571–36588, 2021, doi: 10.1109/ACCESS.2021.3062776.
- [14] A. J. A. Ty, Z. Fang, R. A. Gonzalez, P. J. Rozdeba, and H. D. I. Abarbanel, “Machine learning of time series using time-delay embedding and precision annealing,” *Neural Computation*, vol. 31, no. 10. MIT Press Journals, pp. 2004–2024, Oct. 01, 2019. doi: 10.1162/neco_a_01224.