

Pengembangan Model Prediksi Konsumsi Energi Listrik pada Smart Greenhouse Melon Menggunakan Multivariate Long Short-Term Memory

Shoffin Nahwa Utama^{1*}, Ainur Rahmawati², Ahmad Ghiffari Fadhil Saputra¹, M Singgi Aditya Ramadhan¹

¹Fakultas Sains dan Teknologi, Program Studi Teknik Informatika, UIN Maulana Malik Ibrahim, Malang, Indonesia

²PTIPD, UIN Maulana Malik Ibrahim, Malang, Indonesia

Email: ^{1*}shoffin@uin-malang.ac.id, ²Ainur@uin-malang.ac.id, ³fadhilsaputra033@gmail.com, ⁴msinggiadityaramadhan@gmail.com

Email Penulis Korespondensi: shoffin@uin-malang.ac.id

Submitted 02-08-2026; Accepted 25-08-2026; Published 31-08-2026

Abstrak

Efisiensi energi listrik merupakan salah satu faktor penting dalam smart greenhouse. Pemakaian perangkat listrik berpengaruh pada biaya operasional greenhouse. Pada smart greenhouse hidroponik melon menggunakan berbagai perangkat otomatisasi seperti exhaust fan, humidifier dan sistem IoT. Perangkat tersebut beroperasi sesuai kebutuhan tanaman dan kondisi iklim mikro ruangan. Penggunaan sensor IoT menyebabkan pola konsumsi listrik yang bersifat dinamis dan berubah mengikuti kondisi lingkungan. Penelitian ini bertujuan mengembangkan model prediksi konsumsi energi listrik pada smart greenhouse hidroponik Melon berbasis Internet of Things menggunakan algoritma Multivariate Long Short-Term Memory (LSTM). Parameter iklim mikro yang digunakan berupa temperatur dan kelembapan sebagai variabel prediktor. Data konsumsi energi listrik beserta parameter iklim mikro direkam setiap satu jam selama periode Agustus hingga Oktober 2025 sehingga diperoleh sebanyak 1.560 data deret waktu (*time-series*). Tahapan penelitian meliputi akuisisi data, pra-proses, optimasi hyperparameter LSTM menggunakan beberapa skenario konfigurasi (*lookback window*, rasio data latih-uji, jumlah layer, dan jumlah neuron), serta evaluasi model menggunakan RMSE dan koefisien determinasi (R^2). Hasil penelitian menunjukkan bahwa Konfigurasi terbaik diperoleh pada model stacked Multivariate LSTM dengan *lookback window* 24 jam, rasio data latih 80%, dua lapisan LSTM, dan 32 neuron mampu memprediksi pola konsumsi energi listrik dengan tingkat kesalahan yang rendah. Model terbaik ini menghasilkan nilai MSE sebesar 0,00033 dan RMSE sebesar 0,0182 kWh dengan koefisien determinasi sebesar 91,68%. Hasil tersebut menunjukkan bahwa model yang dikembangkan memiliki potensi untuk mendukung perencanaan kebutuhan energi dan pengambilan keputusan dalam pengelolaan energi pada smart greenhouse berbasis IoT.

Kata Kunci: *Forecasting; Optimasi Hyperparameter; Smart Greenhouse; Multivariate LSTM; Konsumsi Energi;*

Abstract

Energy efficiency is a crucial factor in smart greenhouses. Electrical equipment usage impacts greenhouse operating costs. The melon hydroponic smart greenhouse utilizes various automation devices such as exhaust fans, humidifiers, and IoT systems. The device operates according to plant needs and the microclimate conditions of the room. The use of IoT sensors results in dynamic electricity consumption patterns that change according to environmental conditions. This research aims to develop a predictive model for electricity consumption in an Internet of Things-based melon hydroponic smart greenhouse using the Multivariate Long Short-Term Memory (LSTM) algorithm. The microclimate parameters used were temperature and humidity as predictor variables. Electricity consumption data along with microclimate parameters were recorded hourly from August to October 2025, resulting in 1,560 time-series data sets. The research stages included data acquisition, preprocessing, LSTM hyperparameter optimization using several configuration scenarios (*lookback window*, training-test data ratio, number of layers, and number of neurons), and model evaluation using RMSE and coefficient of determination (R^2). The results of the study showed that the best configuration was obtained in the stacked Multivariate LSTM model with a 24-hour lookback window, a training data ratio of 80%, two LSTM layers, and 32 neurons capable of predicting electrical energy consumption patterns with a low error rate. This best model produced an MSE value of 0.00033 and an RMSE of 0.0182 kWh with a coefficient of determination of 91.68%. These results indicate that the developed model has the potential to support energy demand planning and decision making in energy management in IoT-based smart greenhouses.

Keywords: *Energy Consumption; Forecasting; Hyperparameter Optimization; Multivariate LSTM; Smart Greenhouse.*

1. PENDAHULUAN

Pertumbuhan populasi, perubahan iklim, dan keterbatasan lahan pertanian mendorong penerapan teknologi pertanian presisi (*precision agriculture*) [1]. Salah satu implementasi yang berkembang pesat adalah *controlled environment agriculture* (CEA) [2], yaitu sistem budidaya dengan lingkungan yang dapat dikendalikan secara otomatis. Di antara berbagai bentuk CEA, greenhouse hidroponik menjadi solusi yang digunakan karena mampu mengendalikan suhu, kelembapan, pencahayaan, dan nutrisi tanaman secara lebih presisi dibandingkan budidaya konvensional. Buah melon, merupakan komoditas buah bernilai ekonomi tinggi, memiliki permintaan pasar yang terus meningkat dan membutuhkan kondisi lingkungan yang stabil untuk menghasilkan kualitas buah terbaik. Oleh karena itu, melon merupakan salah satu tanaman yang potensial untuk dibudidayakan menggunakan pendekatan ini [3]. Tanaman melon dikenal sensitif terhadap perubahan suhu dan kelembapan, terutama pada fase pertumbuhan vegetatif dan pembentukan buah. Perubahan suhu dan kelembapan tersebut secara langsung memengaruhi frekuensi kerja perangkat aktuator, khususnya exhaust fan dan humidifier, sehingga membentuk pola konsumsi energi listrik yang berubah secara dinamis sepanjang siklus budidaya. Oleh karena itu, greenhouse modern umumnya dilengkapi dengan berbagai perangkat aktuator seperti *Exhaust Fan* 14 inci untuk pengendalian suhu dan sirkulasi udara serta pompa DC untuk mendukung sistem irigasi dan nutrisi hidroponik secara otomatis [4][5].

Meskipun penggunaan aktuator dan sistem otomatisasi mampu meningkatkan efisiensi budidaya, operasional berbagai perangkat memerlukan pasokan energi listrik yang berkelanjutan. Pada smart greenhouse berbasis Internet of

Things (IoT), kebutuhan energi tidak hanya berasal dari aktuator utama, tetapi juga dari perangkat monitoring dan komunikasi data seperti mikrokontroler, sensor, serta modul jaringan. Petani umumnya hanya mengetahui konsumsi energi setelah proses budidaya selesai, sehingga sulit melakukan estimasi biaya listrik sebelum masa tanam dimulai. biaya operasional selama satu siklus tanam dapat meningkat secara signifikan dan memengaruhi keuntungan petani. Selain itu, pola konsumsi energi pada greenhouse cenderung berubah mengikuti kondisi lingkungan dan fase pertumbuhan tanaman, sehingga sulit diperkirakan secara manual. Diperlukan suatu sistem peramalan (forecasting) yang mampu memberikan estimasi kebutuhan energi listrik sebelum proses budidaya dilakukan sehingga petani dapat merencanakan biaya operasional secara lebih akurat [6].

Perkembangan teknologi Artificial Intelligence dan Machine Learning membuka peluang untuk melakukan prediksi konsumsi energi secara lebih akurat berdasarkan data historis. Salah satu metode yang banyak digunakan untuk pemodelan data deret waktu (time series) adalah Long Short-Term Memory (LSTM), yang merupakan pengembangan dari Recurrent Neural Network (RNN)[7] untuk mengatasi masalah vanishing gradient pada data berurutan[8][9]. Berbeda dengan model ARIMA yang memproses hubungan linier, LSTM mampu mempelajari hubungan nonlinier serta ketergantungan jangka panjang pada data deret waktu sehingga lebih sesuai untuk karakteristik konsumsi energi greenhouse yang dipengaruhi faktor lingkungan[10], [11]. LSTM memiliki kemampuan mengingat hubungan jangka pendek maupun jangka panjang sehingga sangat sesuai untuk mempelajari pola konsumsi energi yang dipengaruhi oleh perubahan waktu. Pada sistem smart greenhouse [12], data konsumsi energi yang direkam setiap jam membentuk pola temporal yang menunjukkan siklus harian antara siang dan malam, serta variasi penggunaan perangkat sesuai kondisi lingkungan. Karakteristik data tersebut menjadikan LSTM sebagai pendekatan yang dipilih untuk menghasilkan prediksi konsumsi energi yang lebih akurat dibandingkan metode statistik konvensional[13].

Berbagai penelitian terdahulu telah memanfaatkan algoritma Machine Learning dan Deep Learning untuk memprediksi konsumsi energi pada berbagai sektor. Penelitian oleh Durand dan Aguilar [7] menunjukkan bahwa model LSTM mampu menghasilkan akurasi yang tinggi dalam prediksi konsumsi listrik bangunan pintar (smart building) karena dapat mempelajari pola temporal dari data historis penggunaan energi. Hasil penelitian tersebut menunjukkan bahwa pendekatan berbasis LSTM memiliki performa yang lebih baik dibandingkan metode regresi linier maupun model statistik tradisional pada data yang bersifat nonlinier dan dinamis.

Penelitian lain yang dilakukan oleh Fadli dan Kartini [14] menerapkan model LSTM untuk prediksi beban listrik jangka pendek pada sistem energi cerdas (smart grid). Hasil penelitian menunjukkan bahwa model mampu mengidentifikasi pola fluktuasi konsumsi listrik harian dan mingguan dengan tingkat kesalahan yang rendah. Selain itu, penelitian Suwarjono, dkk [15] mengombinasikan data lingkungan dan konsumsi energi untuk meningkatkan akurasi prediksi pada sistem berbasis IoT [12]. Temuan tersebut menunjukkan bahwa data sensor yang dikumpulkan secara real-time dapat dimanfaatkan untuk membangun model prediksi yang lebih adaptif terhadap perubahan kondisi operasional.


Pada sektor pertanian cerdas, beberapa penelitian telah mengembangkan sistem monitoring energi untuk greenhouse berbasis IoT dan melakukan analisis penggunaan daya pada perangkat pendukung budidaya[16]. Namun, sebagian besar penelitian masih berfokus pada pemantauan (monitoring) konsumsi energi dan optimasi kendali lingkungan, sedangkan kajian mengenai prediksi konsumsi energi listrik berdasarkan data operasional aktual greenhouse masih relatif terbatas. Selain itu, penelitian yang secara khusus memanfaatkan data konsumsi energi dari budidaya hidroponik Golden Melon selama satu siklus tanam penuh juga masih jarang ditemukan dalam literatur[17].

Berdasarkan tinjauan tersebut, terdapat kesenjangan penelitian (*research gap*) berupa terbatasnya ketersediaan dataset konsumsi energi listrik yang diperoleh secara real-time dari smart greenhouse hidroponik serta minimnya penerapan model Multivariate LSTM untuk memprediksi kebutuhan energi pada budidaya Melon. Penelitian ini bertujuan mengembangkan model prediksi konsumsi energi listrik pada smart greenhouse hidroponik Golden Melon berbasis IoT menggunakan algoritma *Multivariate Long Short-Term Memory* (LSTM). Kontribusi utama penelitian ini meliputi pembangunan dataset konsumsi energi listrik rentang satu jam selama 65 hari menggunakan sensor PZEM-004T yang terintegrasi dengan ESP32, serta pengembangan model prediksi yang dapat digunakan sebagai dasar pengambilan keputusan dalam perencanaan kebutuhan energi dan estimasi biaya operasional pada sistem smart greenhouse modern.

2. METODOLOGI PENELITIAN

2.1 Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan metode *multivariate time-series forecasting* untuk memprediksi konsumsi energi listrik pada smart greenhouse hidroponik Melon. Tahapan penelitian dimulai dari pembangunan sistem monitoring energi berbasis IoT, akuisisi data mikroklimat dan konsumsi energi, pra-proses data, pengembangan model Multivariate LSTM, optimasi hyperparameter, evaluasi model, hingga analisis hasil prediksi. Alur penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 1. Alur desain sistem penelitian

2.2 Arsitektur Smart Greenhouse


Smart greenhouse yang digunakan dalam penelitian ini memiliki dimensi 4×3 meter dengan kapasitas 20 lubang tanam melon seperti ada gambar 2. Sistem dirancang untuk menjaga kondisi lingkungan budidaya tetap optimal melalui pemanfaatan berbagai sensor, aktuator, dan perangkat komunikasi. Sistem dirancang untuk menjaga kondisi mikroklimat tetap berada pada kisaran optimum melalui integrasi perangkat sensor, aktuator, dan sistem komunikasi berbasis Internet of Things (IoT). Selain mendukung proses budidaya secara otomatis, sistem ini juga berfungsi sebagai platform akuisisi data konsumsi energi listrik yang digunakan sebagai dasar dalam pengembangan model prediksi.



Gambar 2. (a) Bagian dalam greenhouse melon hidroponik 4x3 meter (b) Sistem IoT Greenhouse

Arsitektur sistem smart greenhouse secara keseluruhan ditunjukkan pada **Gambar 3**. Sistem terdiri atas empat komponen utama, yaitu lapisan akuisisi data, lapisan proses, lapisan aplikasi dan lapisan aktuator. Lapisan akuisisi data bertugas mengumpulkan data kondisi iklim greenhouse melalui sensor SHT31 dan sensor PZEM-004T untuk pemantauan konsumsi daya pada perangkat aktuator.

Seluruh data hasil pengukuran diproses oleh ESP32 yang berfungsi sebagai pengendali utama sekaligus perangkat komunikasi. Data kemudian dikirimkan melalui jaringan Wi-Fi menuju basis data (*cloud database*) sehingga dapat dimanfaatkan untuk proses pemantauan (*real-time monitoring*), penyimpanan historis, dan analisis lebih lanjut. Arsitektur ini memungkinkan proses akuisisi data berlangsung secara otomatis, kontinu, dan terintegrasi tanpa memerlukan intervensi manual selama periode pengamatan.



Gambar 3. Arsitektur Smart Greenhouse

Pada sisi aktuator, sistem greenhouse dilengkapi dengan dua unit exhaust fan berdaya 56 watt per unit yang berfungsi mengatur sirkulasi udara dan menurunkan temperatur, untuk humidifier berdaya 35 watt yang digunakan untuk membantu menurunkan suhu greenhouse. Operasional perangkat aktuator bergantung pada kondisi iklim mikro greenhouse sehingga menghasilkan pola konsumsi energi listrik yang berubah secara dinamis sepanjang siklus tanam.

2.3 Akuisisi Data

Dataset yang digunakan pada penelitian ini diperoleh melalui proses akuisisi data secara langsung (*real-time data acquisition*) dari sistem smart greenhouse hidroponik Melon yang telah diimplementasikan. Pengambilan data dilakukan mulai 5 Agustus hingga 7 Oktober 2025, yang merepresentasikan satu siklus budidaya tanaman secara penuh. Seluruh data direkam secara otomatis menggunakan sistem Internet of Things (IoT) dengan interval pengambilan data setiap satu jam, sehingga diperoleh sebanyak 1.560 data observasi (*time-series records*). Contoh data dapat dilihat pada tabel 1.

Proses akuisisi data dilakukan melalui integrasi beberapa sensor yang terhubung dengan mikrokontroler ESP32. Konsumsi energi listrik pada beban AC, seperti *exhaust fan*, diukur menggunakan sensor PZEM-004T. Selain data energi, sistem juga merekam parameter iklim mikro greenhouse berupa temperatur dan kelembapan udara yang digunakan sebagai variabel prediktor dalam pengembangan model Multivariate Long Short-Term Memory (LSTM). Seluruh hasil pengukuran dikirimkan melalui jaringan Wi-Fi menuju cloud database sehingga tersimpan secara otomatis sebagai dataset penelitian.

Data yang diperoleh terdiri atas parameter iklim mikro dan konsumsi energi listrik per jam. Parameter iklim mikro meliputi temperatur udara bagian atas (*temp_in_top*), temperatur udara bagian bawah (*temp_bot*), kelembapan udara bagian atas (*humidity_top*), dan kelembapan udara bagian bawah (*humidity_bot*). Sementara itu, variabel target berupa *Total_Energi_kWh*, yaitu akumulasi konsumsi energi listrik setiap satu jam yang dihitung berdasarkan hasil pengukuran sensor energi pada seluruh perangkat operasional greenhouse.

Karakteristik konsumsi energi listrik menunjukkan pola temporal yang dipengaruhi oleh aktivitas perangkat otomatis selama proses budidaya. Konsumsi energi cenderung meningkat pada siang hari ketika temperatur di dalam greenhouse mengalami kenaikan sehingga exhaust fan bekerja lebih intensif untuk menjaga suhu lingkungan tetap berada pada kondisi optimum. Sebaliknya, pada malam hari konsumsi energi relatif menurun karena berkurangnya frekuensi operasi aktuator. Perangkat monitoring berbasis IoT beroperasi secara kontinu selama 24 jam. Pola operasional tersebut menghasilkan karakteristik data deret waktu yang bersifat dinamis, nonlinier, dan memiliki pola harian (*daily cycle*), sehingga sesuai untuk dimodelkan menggunakan algoritma LSTM.

Seluruh dataset melalui tahapan validasi untuk memastikan konsistensi data, mengidentifikasi nilai yang hilang (*missing values*), serta memeriksa kesesuaian interval waktu pengambilan data. Dataset yang telah memenuhi kriteria kualitas selanjutnya diproses pada tahap praproses data (*data preprocessing*) sebelum digunakan dalam proses pelatihan dan pengujian model prediksi.

Tabel 1. Contoh dataset mikro iklim grennhouse dan penggunaan energi

No	timestamp	temp_bot (°C)	humidity_bot (%)	temp_top (°C)	humidity_top (%)	Wall_Fan (kWh)	Humidifier (kWh)	Sistem_IoT (kWh)	Total_Energi (kWh)
1	2025-08-05 12:00:04	46.9	47.0	48.1	46.0	0.1071	0.0358	0.0092	0.1521
2	2025-08-05 13:00:00	51.4	41.0	52.8	41.0	0.1074	0.0332	0.0092	0.1498
3	2025-08-05 14:00:05	44.5	53.0	49.2	47.0	0.1157	0.0354	0.0091	0.1602
4	2025-08-05 15:00:00	35.8	72.0	38.3	66.0	0.108	0.0	0.0088	0.1168
...									
1558	2025-10-07 11:00:03	39.21	51.0	43.59	50.0	0.1084	0.0367	0.0088	0.1539
1559	2025-10-07 12:00:03	37.08	56.0	38.71	59.0	0.1104	0.0337	0.0088	0.1529
1560	2025-10-07 13:00:01	29.66	77.0	29.65	80.0	0.0533	0.0	0.0091	0.0624

2.4 Variabel Penelitian

Penelitian ini menerapkan pendekatan *multivariate time-series forecasting*, yaitu metode prediksi yang memanfaatkan beberapa variabel masukan untuk memperkirakan nilai variabel target pada waktu berikutnya. Pemilihan variabel pada penelitian ini didasarkan pada hubungan fungsional antara kondisi mikroklimat di dalam greenhouse dan konsumsi energi listrik perangkat aktuator. Perubahan temperatur dan kelembapan secara langsung memengaruhi frekuensi operasi perangkat seperti *exhaust fan* dan *humidifier*, sehingga kedua parameter tersebut dipilih sebagai variabel prediktor dalam model *Multivariate Long Short-Term Memory (LSTM)*. Adapun variabel yang digunakan dalam penelitian ini dibedakan menjadi dua kelompok, yaitu variabel masukan (*input features*) dan variabel target (*output variable*)[7]. Variabel yang digunakan dalam penelitian ini dibedakan menjadi dua kelompok, yaitu sebagai berikut.

2.4.1 Variabel Masukan (*Input Features, (X)*)

Variabel masukan merupakan parameter mikroklimat yang digunakan sebagai prediktor dalam model Long Short-Term Memory (LSTM)[18]. Parameter tersebut diperoleh dari sistem monitoring berbasis Internet of Things (IoT) yang melakukan pengukuran kondisi lingkungan greenhouse secara berkala. 4 Variabel masukan dari mikroklimat ditampilkan pada tabel 2.

Tabel 2. Variabel Masukan Penelitian

Variabel	Simbol	Satuan	Keterangan
Temperatur udara bagian atas	temp_top	°C	Temperatur pada bagian atas greenhouse
Temperatur udara bagian bawah	temp_bot	°C	Temperatur pada bagian bawah greenhouse
Kelembapan udara bagian atas	humidity_top	%	Kelembapan relatif bagian atas greenhouse
Kelembapan udara bagian bawah	humidity_bot	%	Kelembapan relatif bagian bawah greenhouse

Keempat parameter tersebut dipilih karena berpengaruh langsung terhadap pola kerja aktuator, khususnya *exhaust fan* dan *humidifier*, yang secara otomatis aktif untuk menjaga kondisi lingkungan tetap berada pada rentang optimal bagi pertumbuhan tanaman Melon.

2.4.2 Variabel Target (*Output Variable, (y)*)

Variabel target pada penelitian ini adalah *Total_Energi_kWh*, yaitu total konsumsi energi listrik setiap satu jam yang dinyatakan dalam satuan kilowatt-hour (kWh). Nilai konsumsi energi diperoleh melalui pengukuran menggunakan sensor energi PZEM-004T yang terpasang pada sistem smart greenhouse dan merepresentasikan penggunaan energi aktual selama proses budidaya.

Konsumsi energi tersebut berasal dari perangkat aktuator utama, yaitu dua unit *exhaust fan* dengan total daya sebesar 112 W serta satu unit *humidifier* berdaya 35 W, yang beroperasi secara otomatis sesuai kondisi mikroklimat greenhouse. Dengan demikian, model LSTM dibangun untuk mempelajari hubungan antara perubahan kondisi lingkungan internal greenhouse dan konsumsi energi listrik sehingga mampu menghasilkan prediksi kebutuhan energi pada periode waktu berikutnya.

2.5 Praproses Data

Sebelum digunakan sebagai masukan pada model Long Short-Term Memory (LSTM), dataset terlebih dahulu melalui tahapan praproses untuk meningkatkan kualitas data serta memastikan proses pelatihan model berlangsung secara optimal. Tahapan ini meliputi penanganan data yang hilang (*missing values*), normalisasi data, dan pembentukan sekuens temporal (*windowing*).

2.5.1 Penanganan Data Hilang (*Missing Values Imputation*)

Selama proses akuisisi data pada sistem Internet of Things (IoT), terdapat kemungkinan terjadinya data yang hilang akibat gangguan komunikasi jaringan, keterlambatan transmisi, maupun pembacaan sensor yang tidak sempurna. Keberadaan data yang hilang dapat mengganggu kontinuitas deret waktu (*time series*) dan menurunkan akurasi model prediksi.

Penelitian ini menerapkan metode *Forward Fill* (*ffill*) yang mengisi nilai kosong menggunakan nilai valid sebelumnya. Selanjutnya dilakukan *Backward Fill* (*bfill*) untuk mengisi nilai kosong yang masih tersisa menggunakan nilai valid berikutnya. Kombinasi kedua metode tersebut dipilih karena mampu mempertahankan kesinambungan pola temporal tanpa mengubah karakteristik utama data konsumsi energi listrik.

2.5.2 Normalisasi Data

Data yang telah dibersihkan kemudian dinormalisasi menggunakan metode **Min-Max Scaling** agar seluruh variabel memiliki rentang nilai yang seragam, yaitu antara 0 dan 1. Proses normalisasi bertujuan mengurangi perbedaan skala antarvariabel sehingga proses pelatihan jaringan saraf menjadi lebih stabil, mempercepat proses konvergensi, serta meningkatkan kemampuan model dalam mempelajari pola data.

Transformasi normalisasi dilakukan menggunakan persamaan 1 berikut:

$$X_{scaled} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

2.5.3 Pembentukan Sekuens Temporal (*Windowing*)

Data yang telah dinormalisasi diubah menjadi format matriks tiga dimensi yang sesuai untuk input LSTM, yaitu *samples*, *time steps*, *features*. Proses pembentukan sekuens dilakukan menggunakan pendekatan sliding window, yaitu setiap data pada waktu dibentuk dari sejumlah pengamatan pada periode sebelumnya untuk memprediksi konsumsi energi pada periode berikutnya[19].

2.5.4 Pembagian Dataset (*Train-Test Split*)

Dataset dibagi menjadi data pelatihan dan data pengujian secara kronologis tanpa proses pengacakan. Pendekatan ini dipilih untuk mempertahankan urutan waktu sehingga tidak terjadi kebocoran informasi antara data pelatihan dan data pengujian.

Penelitian ini menggunakan dua skenario pembagian dataset, yaitu 70:30 dan 80:20. Data pelatihan digunakan untuk membangun model LSTM, sedangkan data pengujian dimanfaatkan untuk mengevaluasi kemampuan model dalam memprediksi konsumsi energi listrik pada data yang belum pernah dipelajari sebelumnya


2.6 Pengembangan Model Multivariate LSTM

Model prediksi yang dikembangkan pada penelitian ini menggunakan pendekatan Multivariate Long Short-Term Memory (LSTM) [10]. Pendekatan multivariat memungkinkan model dapat memanfaatkan beberapa parameter lingkungan secara bersamaan sehingga hubungan antarvariabel dapat dipelajari secara lebih baik [20]. Pada penelitian ini, parameter temperatur dan kelembapan digunakan sebagai variabel prediktor untuk memperkirakan konsumsi energi listrik pada periode waktu berikutnya.

Data hasil praproses diubah ke dalam bentuk tensor tiga dimensi dengan format *samples*, *time steps*, *features*, yang merupakan format standar masukan pada jaringan LSTM. Setiap sampel terdiri atas sejumlah data historis berdasarkan panjang *lookback window*, sedangkan keluaran model berupa nilai prediksi konsumsi energi listrik (*Total_Energi_kWh*) satu langkah waktu ke depan [9].

Arsitektur model Multivariate terdiri atas lapisan masukan (*input layer*), lapisan LSTM, lapisan dropout, dan lapisan keluaran (*dense layer*)[10]. Lapisan LSTM bertugas mengekstraksi pola temporal dari data historis, sedangkan dropout layer digunakan untuk mengurangi risiko *overfitting* dengan menonaktifkan sebagian neuron selama proses pelatihan. Lapisan *dense* menghasilkan satu nilai keluaran yang merepresentasikan prediksi konsumsi energi listrik pada periode berikutnya.

Selama proses pelatihan, model dioptimasi menggunakan algoritma *Adaptive Moment Estimation* (Adam) dengan *loss function* berupa *Mean Squared Error* (MSE). Pemilihan optimizer Adam didasarkan pada kemampuannya dalam mempercepat proses konvergensi dan menghasilkan performa yang stabil pada pemodelan data deret waktu berbasis *deep learning*. Setelah proses pelatihan selesai, model digunakan untuk memprediksi konsumsi energi listrik pada data pengujian yang belum pernah dipelajari sebelumnya.



Gambar 4. Arsitektur multivariate LSTM

Arsitektur yang digunakan pada penelitian ini ditunjukkan pada Gambar 4. Konfigurasi jumlah lapisan LSTM, panjang *lookback window*, rasio pembagian dataset, serta jumlah neuron tidak ditetapkan secara langsung, melainkan ditentukan melalui proses optimasi *hyperparameter* yang dijelaskan pada subbab optimasi *hyperparameter*.

2.7 Optimasi Hyperparameter

Kinerja model LSTM sangat dipengaruhi oleh pemilihan *hyperparameter* yang digunakan selama proses pelatihan. Penelitian ini menerapkan pendekatan *grid search* dengan melakukan pengujian terhadap beberapa kombinasi *hyperparameter* untuk memperoleh konfigurasi model yang memberikan performa prediksi terbaik.

Empat *hyperparameter* yang dievaluasi meliputi panjang *lookback window*, rasio pembagian data pelatihan dan pengujian, jumlah lapisan LSTM, serta jumlah neuron pada setiap lapisan tersembunyi. Variasi setiap *hyperparameter* disajikan pada tabel 3.

Tabel 3 Kombinasi Hyperparameter

Hyperparameter	Nilai yang Diuji	Jumlah Variasi
Lookback Window	12 jam, 24 jam	2
Train-Test Split	70:30, 80:20	2
Jumlah Layer LSTM	1 Layer, 2 Layer	2
Jumlah Neuron	32, 64, 128	3
Total Kombinasi Model	$2 \times 2 \times 2 \times 3$	24 Model

Seluruh kombinasi *hyperparameter* diuji menggunakan dataset yang sama sehingga diperoleh eksperimen sebanyak 24 model. Setiap model dilatih dan dievaluasi menggunakan metrik RMSE dan Koefisien Determinasi (R^2). Konfigurasi yang menghasilkan nilai kesalahan prediksi paling rendah dan nilai R^2 tertinggi dipilih sebagai model terbaik untuk memprediksi konsumsi energi listrik pada smart greenhouse hidroponik Melon.

2.8 Evaluasi Model

Performa model prediksi dievaluasi secara kuantitatif untuk mengukur tingkat akurasi hasil prediksi konsumsi energi listrik terhadap data aktual. Evaluasi dilakukan pada seluruh skenario pengujian *hyperparameter* menggunakan tiga metrik yang digunakan dalam penelitian *time-series forecasting*, yaitu *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE) dan Koefisien Determinasi (R^2). Kombinasi metrik tersebut memberikan informasi yang menyeluruh mengenai tingkat kesalahan prediksi maupun kemampuan model dalam menjelaskan variasi data aktual.

2.8.1 Root Mean Squared Error (RMSE)

Root Mean Squared Error (RMSE) merupakan akar kuadrat dari MSE sehingga memiliki satuan yang sama dengan variabel yang diprediksi, yaitu kilowatt-hour (kWh). Nilai RMSE memberikan interpretasi yang lebih mudah terhadap besar kesalahan prediksi. Semakin kecil nilai RMSE, semakin tinggi tingkat akurasi model. RMSE dihitung menggunakan Persamaan (2).

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2} \quad (2)$$

2.8.2 Koefisien Determinasi (R^2)

Koefisien Determinasi digunakan untuk mengukur kemampuan model dalam menjelaskan variasi data aktual. Nilai (R^2) berada pada rentang 0 hingga 1, di mana nilai yang semakin mendekati 1 menunjukkan model memiliki kemampuan yang semakin baik dalam merepresentasikan pola konsumsi energi listrik. Nilai R^2 dihitung menggunakan Persamaan (3).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

dengan:

- y_i = nilai konsumsi energi listrik aktual;
- $\hat{y}_i$ = nilai konsumsi energi listrik hasil prediksi model;
- $\bar{y}$ = rata-rata nilai konsumsi energi listrik aktual;
- n = jumlah sampel data pengujian.

Pada penelitian ini, konfigurasi model terbaik ditentukan berdasarkan nilai MSE dan RMSE yang paling rendah serta nilai (R^2) yang paling tinggi. Pendekatan ini memungkinkan pemilihan model yang tidak hanya memiliki tingkat kesalahan prediksi yang kecil, tetapi juga mampu merepresentasikan pola konsumsi energi listrik secara akurat pada data yang belum pernah dipelajari sebelumnya.

3. HASIL DAN PEMBAHASAN


3.1 Hasil Akuisisi dan Karakteristik Dataset

Dataset penelitian diperoleh selama satu siklus budidaya. Data yang dikumpulkan meliputi parameter mikroklimat berupa temperatur udara bagian atas (*temp_top*), temperatur udara bagian bawah (*temp_bot*), kelembapan udara bagian atas (*humidity_top*), kelembapan udara bagian bawah (*humidity_bot*), serta konsumsi energi listrik (*Total_Energi_kWh*). Statistik deskriptif pada Tabel 4 menunjukkan bahwa temperatur rata-rata di dalam greenhouse berada pada kisaran 27-28 °C, sedangkan kelembapan relatif rata-rata berada di atas 80 %. Konsumsi energi listrik memiliki nilai rata-rata sekitar 0,0625 kWh dengan rentang 0,0087 - 0,1627 kWh, yang mengindikasikan adanya variasi penggunaan energi selama periode pengamatan akibat perubahan kondisi lingkungan dan aktivitas aktuatur.

Tabel 4. Statistik deskriptif dataset

Variabel	Mean	Minimum	Maksimum	Standar Deviasi
Temperatur Atas (°C)	28,12	18,20	53,15	7,73
Temperatur Bawah (°C)	27,60	18,37	51,40	6,88
Kelembapan Atas (%RH)	83,96	31,00	100,00	18,83
Kelembapan Bawah (%RH)	81,19	31,00	100,00	19,18
Konsumsi Energi (kWh)	0,0625	0,0087	0,1627	0,0659


Karakteristik data deret waktu ditunjukkan pada Gambar 5 yang memperlihatkan pola fluktuasi konsumsi energi selama periode pengamatan. Konsumsi energi cenderung meningkat pada siang hari ketika temperatur di dalam greenhouse naik sehingga *exhaust fan* dan perangkat pengendali lingkungan bekerja lebih intensif untuk mempertahankan kondisi mikroklimat. Sebaliknya, konsumsi energi relatif menurun pada malam hari karena temperatur lingkungan lebih rendah dan kebutuhan pengoperasian aktuatur berkurang. Pola ini menunjukkan adanya siklus harian (*diurnal pattern*) yang berulang, sehingga dataset memiliki karakteristik temporal yang sesuai untuk dimodelkan menggunakan algoritma LSTM.



Gambar 5. Grafik *time-series* konsumsi energi selama periode pengamatan

Hubungan antarvariabel dianalisis menggunakan koefisien korelasi Pearson sebagaimana ditunjukkan pada Gambar 6. Hasil analisis menunjukkan bahwa temperatur memiliki korelasi positif yang sangat kuat terhadap konsumsi energi

listrik, sedangkan kelembapan memiliki korelasi negatif yang sangat kuat. Temuan tersebut menunjukkan bahwa peningkatan temperatur di dalam greenhouse cenderung diikuti oleh meningkatnya konsumsi energi akibat frekuensi operasi aktuator yang lebih tinggi, sementara peningkatan kelembapan berkaitan dengan penurunan kebutuhan energi. Hasil ini mengonfirmasi bahwa parameter temperatur dan kelembapan merupakan variabel prediktor yang relevan untuk membangun model Multivariate LSTM dalam memprediksi konsumsi energi listrik pada smart greenhouse hidroponik Melon.



Gambar 6. Koefisien Korelasi pearson

3.2 Hasil Optimasi Hyperparameter LSTM

Optimasi hyperparameter dilakukan untuk memperoleh konfigurasi model Multivariate LSTM yang mampu menghasilkan performa prediksi terbaik. Proses optimasi menggunakan pendekatan *grid search* dengan mengombinasikan empat hyperparameter, yaitu *lookback window* (12 dan 24 jam), rasio pembagian data pelatihan dan pengujian (70:30 dan 80:20), jumlah lapisan LSTM (1 dan 2 layer), serta jumlah neuron pada setiap lapisan (32, 64, dan 128). Seluruh kombinasi menghasilkan 24 skenario pengujian yang dievaluasi menggunakan metrik Mean Squared Error (MSE), Root Mean Squared Error (RMSE), dan Koefisien Determinasi (R^2), sebagaimana disajikan pada Tabel 5.

Berdasarkan hasil pengujian, konfigurasi terbaik diperoleh pada model dengan *lookback window* 24 jam, rasio data pelatihan dan pengujian 80:20, dua lapisan LSTM (*stacked Multivariate LSTM*), dan 32 neuron. Konfigurasi tersebut menghasilkan MSE sebesar 0,00033, RMSE sebesar 0,0182 kWh, serta koefisien determinasi (R^2) sebesar 91,68%, yang menunjukkan bahwa model mampu menjelaskan sebagian besar variasi konsumsi energi listrik pada data pengujian.

Tabel 5. Hasil Optimasi hyperparameter

Urutan terbaik	Panjang Sequence (Jam)	Rasio Data (Train:Test)	Jumlah Layer LSTM	Jumlah Neuron	MSE	RMSE (kWh)	R^2 Score (%)
1	24	0,8	2	32	0,00033	0,0182	91,68
2	24	0,8	1	64	0,00037	0,0192	90,72
3	24	0,8	2	64	0,00037	0,0193	90,6
4	24	0,7	2	32	0,00039	0,0197	90,32
5	12	0,8	2	32	0,00039	0,0197	90,21
6	24	0,8	1	32	0,00039	0,0197	90,21
7	12	0,8	2	128	0,00039	0,0199	90,01
8	24	0,8	2	128	0,00040	0,0199	89,98
9	24	0,8	1	128	0,00040	0,02	89,9
10	12	0,8	1	128	0,00041	0,0201	89,74
11	12	0,8	1	64	0,00041	0,0203	89,55
12	12	0,8	2	64	0,00041	0,0204	89,5
13	24	0,7	2	64	0,00042	0,0205	89,46
14	24	0,7	1	64	0,00043	0,0207	89,31
15	12	0,8	1	32	0,00043	0,0207	89,18
16	24	0,7	2	128	0,00043	0,0208	89,18
17	12	0,7	2	32	0,00043	0,0208	89,13

18	12	0,7	1	64	0,00045	0,0212	88,75
19	12	0,7	2	64	0,00045	0,0212	88,74
20	12	0,7	2	128	0,00045	0,0212	88,73
21	12	0,7	1	128	0,00045	0,0212	88,68
22	12	0,7	1	32	0,00045	0,0213	88,64
23	24	0,7	1	128	0,00046	0,0214	88,5
24	24	0,7	1	32	0,00049	0,0222	87,69


Secara umum, hasil optimasi menunjukkan bahwa penggunaan lookback window 24 jam memberikan performa yang lebih baik dibandingkan 12 jam karena model memperoleh informasi historis yang lebih lengkap mengenai pola konsumsi energi harian. Selain itu, arsitektur Stacked LSTM mampu mempelajari hubungan temporal yang lebih kompleks dibandingkan model satu lapisan. Menariknya, peningkatan jumlah neuron dari 32 menjadi 64 atau 128 tidak selalu meningkatkan akurasi prediksi. Hal ini mengindikasikan bahwa kompleksitas model yang lebih tinggi belum tentu menghasilkan kemampuan generalisasi yang lebih baik pada dataset yang digunakan. Oleh karena itu, konfigurasi terbaik dipilih sebagai model utama untuk proses prediksi konsumsi energi listrik pada tahap analisis selanjutnya.

3.3 Hasil Model Terbaik

Berdasarkan hasil optimasi hyperparameter pada 24 skenario pengujian, diperoleh konfigurasi model terbaik yang terdiri atas lookback window 24 jam, rasio data pelatihan dan pengujian 80:20, dua lapisan LSTM (*stacked Multivariate LSTM*), dan 32 neuron pada setiap lapisan tersembunyi. Konfigurasi tersebut dipilih berdasarkan nilai R^2 tertinggi dan RMSE terendah dibandingkan konfigurasi lainnya. Selanjutnya, model terbaik digunakan untuk melakukan prediksi konsumsi energi listrik pada data pengujian.

3.3.1 Analisis Proses Pelatihan Model

Proses pelatihan model dievaluasi menggunakan grafik *training loss* dan *validation loss* sebagaimana ditunjukkan pada gambar 7(a) memperlihatkan perkembangan nilai *training loss* dan *validation loss* selama proses pelatihan model LSTM. Pada beberapa epoch awal, kedua kurva mengalami penurunan yang sangat signifikan, menunjukkan bahwa model mampu dengan cepat mempelajari hubungan antara parameter mikroklimat dan konsumsi energi listrik. Setelah memasuki sekitar epoch ke-20, nilai *loss* mulai stabil hingga akhir proses pelatihan, yang mengindikasikan bahwa model telah mencapai kondisi konvergen. Selain itu, kurva *validation loss* berada sangat dekat bahkan sedikit lebih rendah dibandingkan *training loss*. Kondisi ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting*. Fenomena tersebut dipengaruhi oleh penerapan lapisan *dropout* sebesar 20% selama proses pelatihan sehingga model mampu mengurangi ketergantungan terhadap data latih dan menghasilkan performa yang lebih stabil pada data validasi.



Gambar 7. (a) Grafik *training loss* dan *validation loss* (b) Grafik perbandingan konsumsi energy actual dan prediksi

3.3.2 Perbandingan Hasil Prediksi dan Data Aktual

Kinerja model selanjutnya dievaluasi dengan membandingkan hasil prediksi terhadap data konsumsi energi aktual pada data pengujian. Gambar 7(b) menunjukkan perbandingan antara konsumsi energi listrik aktual dan hasil prediksi model LSTM pada data pengujian. Secara umum, kurva prediksi mampu mengikuti pola fluktuasi konsumsi energi aktual dengan sangat baik, terutama pada periode kenaikan dan penurunan konsumsi energi yang terjadi secara berulang setiap hari. Model berhasil menangkap pola periodik yang dihasilkan oleh siklus operasi perangkat aktuator, sehingga sebagian besar kurva prediksi hampir berimpit dengan data aktual. Meskipun demikian, masih terdapat beberapa deviasi pada saat terjadi

perubahan konsumsi energi yang sangat cepat, terutama pada fase transisi ketika aktuator mulai aktif atau berhenti beroperasi. Deviasi tersebut menunjukkan keterbatasan model dalam menangkap perubahan yang bersifat sangat mendadak, namun tidak memengaruhi kemampuan model dalam merepresentasikan pola konsumsi energi secara keseluruhan.

Pola periodik pada Gambar 7(b) menunjukkan bahwa konsumsi energi listrik dipengaruhi secara langsung oleh mekanisme pengendalian mikroklimat di dalam greenhouse. Ketika temperatur meningkat pada siang hari, sistem secara otomatis mengaktifkan *wall exhaust fan* untuk mempertahankan suhu optimum sehingga konsumsi energi meningkat. Sebaliknya, pada malam hari ketika temperatur lingkungan menurun, frekuensi operasi aktuator menjadi lebih rendah sehingga konsumsi energi kembali menurun. Karakteristik siklus harian tersebut menjelaskan mengapa model LSTM dengan *lookback window* selama 24 jam mampu memberikan performa prediksi yang lebih baik dibandingkan konfigurasi dengan *lookback* yang lebih pendek, karena model memperoleh informasi historis yang mencakup satu siklus operasional harian secara utuh.

3.3.3 Evaluasi Performa Model

Berdasarkan hasil evaluasi, model terbaik menghasilkan nilai MSE sebesar 0,00033, RMSE sebesar 0,0182 kWh, dan koefisien determinasi (R^2) sebesar 91,68%. Nilai RMSE yang rendah menunjukkan bahwa rata-rata penyimpangan prediksi terhadap data aktual hanya sekitar 0,0182 kWh pada setiap interval pengamatan. Selain itu, nilai R^2 sebesar 91,68% mengindikasikan bahwa sebagian besar variasi konsumsi energi listrik mampu dijelaskan oleh model berdasarkan informasi temperatur dan kelembapan di dalam greenhouse. Hasil tersebut menunjukkan bahwa model tidak hanya mampu mengikuti kecenderungan umum data, tetapi juga memiliki kemampuan yang baik dalam merepresentasikan dinamika konsumsi energi listrik selama satu siklus operasional greenhouse.

Tabel 6. Hasil Evaluasi Model Terbaik

Metrik Evaluasi	Nilai
Mean Squared Error (MSE)	0,00033
Root Mean Squared Error (RMSE)	0,0182 kWh
Koefisien Determinasi (R^2)	91,68 %

3.4 Analisis Prediksi Konsumsi Energi Listrik

Hasil prediksi menunjukkan bahwa konsumsi energi listrik pada smart greenhouse memiliki pola periodik harian (*daily periodic pattern*) yang berulang selama periode pengamatan. Berdasarkan Gambar 7 (b), konsumsi energi mulai meningkat pada pagi hari dan mencapai puncaknya pada rentang pukul 10.00 - 15.00, kemudian berangsur menurun menjelang sore hingga malam hari. Pola tersebut dipengaruhi oleh meningkatnya temperatur di dalam greenhouse akibat intensitas radiasi matahari, sehingga sistem secara otomatis mengaktifkan dua unit *wall exhaust fan*, pompa sirkulasi, dan *dosing pump* untuk menjaga kondisi lingkungan tetap optimal bagi pertumbuhan tanaman Golden Melon. Sebaliknya, pada malam hari konsumsi energi relatif lebih rendah karena temperatur lingkungan menurun sehingga frekuensi operasi aktuator berkurang dan beban listrik didominasi oleh perangkat IoT yang bekerja secara kontinu.

Analisis lebih lanjut menunjukkan bahwa temperatur merupakan faktor utama yang memengaruhi konsumsi energi listrik. Peningkatan temperatur menyebabkan durasi operasi *wall exhaust fan* menjadi lebih lama sehingga konsumsi energi meningkat, sedangkan peningkatan kelembapan cenderung berkorelasi dengan penurunan konsumsi energi karena kebutuhan pengoperasian perangkat pengendali lingkungan menjadi lebih rendah. Hubungan tersebut sejalan dengan hasil analisis korelasi Pearson yang menunjukkan bahwa temperatur memiliki korelasi positif yang kuat terhadap konsumsi energi, sedangkan kelembapan memiliki korelasi negatif. Temuan ini mengonfirmasi bahwa parameter mikroklimat merupakan variabel yang relevan dalam membangun model prediksi konsumsi energi pada smart greenhouse.

Karakteristik konsumsi energi yang dipengaruhi oleh siklus harian serta perubahan temperatur dan kelembapan menjadikan dataset penelitian memiliki pola temporal yang sesuai untuk dimodelkan menggunakan algoritma Multivariate LSTM. Hal ini dibuktikan dengan hasil optimasi hyperparameter yang menunjukkan bahwa konfigurasi *lookback window* 24 jam, rasio data 80:20, dua lapisan LSTM, dan 32 neuron mampu memberikan performa prediksi terbaik dengan MSE sebesar 0,00033, RMSE sebesar 0,0182 kWh, dan koefisien determinasi (R^2) sebesar 91,68%. Hasil tersebut menunjukkan bahwa model mampu merepresentasikan pola konsumsi energi listrik secara akurat dan berpotensi dimanfaatkan sebagai dasar pengambilan keputusan dalam perencanaan kebutuhan energi serta estimasi biaya operasional pada smart greenhouse berbasis IoT.

Dari perspektif operasional, hasil prediksi konsumsi energi listrik memberikan informasi yang bermanfaat bagi pengelola smart greenhouse dalam menyusun strategi manajemen energi. Prediksi kebutuhan energi sebelum masa tanam memungkinkan estimasi biaya operasional dilakukan secara lebih akurat, sehingga petani dapat merencanakan anggaran listrik, mengevaluasi kapasitas sumber daya energi yang tersedia, serta mengoptimalkan jadwal pengoperasian aktuator tanpa mengurangi kualitas lingkungan budidaya. Dengan demikian, model yang dikembangkan tidak hanya berfungsi sebagai alat prediksi, tetapi juga sebagai sistem pendukung keputusan untuk meningkatkan efisiensi pengelolaan energi pada smart greenhouse berbasis IoT.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model prediksi konsumsi energi listrik pada *smart greenhouse* hidroponik Melon berbasis IoT menggunakan algoritma *Multivariate LSTM*. Model dikembangkan berdasarkan data iklim mikro berupa temperatur dan kelembapan yang diperoleh secara *real-time* serta data konsumsi energi listrik selama satu siklus budidaya. Hasil optimasi *hyperparameter* menunjukkan bahwa konfigurasi terbaik diperoleh pada *lookback window* 24 jam, rasio data pelatihan dan pengujian 80:20, dua lapisan LSTM (*stacked Multivariate LSTM*), dan 32 neuron. Konfigurasi terbaik ini memiliki performa prediksi yang tinggi dengan *Mean Squared Error* (MSE) sebesar 0,00033, Root Mean Squared Error (RMSE) sebesar 0,0182 kWh, dan Koefisien Determinasi (R^2) sebesar 91,68%, sehingga mampu merepresentasikan pola konsumsi energi listrik pada *smart greenhouse* dengan tingkat akurasi yang sangat baik. Hasil penelitian juga menunjukkan bahwa pola konsumsi energi listrik dipengaruhi secara dominan oleh perubahan temperatur dan kelembapan. Sensor mengendalikan operasi perangkat aktuatur, terutama exhaust fan dan sistem pengendalian lingkungan. Kemampuan model LSTM dalam mempelajari pola temporal harian menjadikannya efektif untuk memprediksi kebutuhan energi listrik sebelum proses budidaya berlangsung. Model yang dikembangkan berpotensi dimanfaatkan sebagai sistem pendukung keputusan dalam perencanaan kebutuhan energi, estimasi biaya operasional, serta pengelolaan energi pada *smart greenhouse* berbasis IoT. Penelitian selanjutnya dapat difokuskan pada penambahan variabel eksternal, seperti intensitas radiasi matahari, kecepatan angin, atau prakiraan cuaca, serta eksplorasi arsitektur *deep learning* yang teraru, seperti Bidirectional LSTM, GRU, atau Transformer, untuk meningkatkan akurasi prediksi pada berbagai kondisi operasional.

UCAPAN TERIMAKASIH

Terima kasih kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat (LPPM) UIN Maulana Malik Ibrahim Malang atas dukungan pendanaan melalui skema Penelitian SBK sehingga penelitian ini dapat terlaksana dengan baik

REFERENCES

- [1] Raodatul Putri, "Pemanfaatan Teknologi Pertanian Presisi untuk Meningkatkan Produktivitas Padi dan Efisiensi Penggunaan Air di Lahan Irigasi Kabupaten Dompu," *ARMADA J. Penelit. Multidisiplin*, vol. 2, no. 6, pp. 389–394, 2024.
- [2] L. Hovi, Kaseva, and T. J., & Hyypiä, "Controlled environment agriculture for sustainable tomato production—A Review," *Agronomy*, vol. 10, no. 6, p. 841, 2020.
- [3] R. Dwityaningsih, S. S. Ningrum, H. Widiyanto, and N. L. Kumara, "Penerapan Smart Greenhouse pada Sistem Hidroponik " Melon Gadis " Kampung KB GADIS Tegalreja Cilacap Selatan," *E-DIMAS J. Pengabd. Kpd. Masy.*, vol. 17, no. 1, pp. 78–84, 2026, doi: <https://doi.org/10.26877/e-dimas.v17i1.25020>.
- [4] M. S. Farooq, Z. Atal, R. Javid, and S. Riaz, "IoT Based Smart Greenhouse Framework and Control Strategies for Sustainable Agriculture," *IEEE Access*, vol. 10, no. August, pp. 99394–99420, 2022, doi: 10.1109/ACCESS.2022.3204066.
- [5] K. Muhammad, W. Hidayat, M. Khozi, and A. Faris, "IoT - Based Electrical Power Consumption Monitoring System in Households Using ESP32 and PZEM - 004T," *Brill. Res. Artif. Intell.*, vol. 5, no. 2, pp. 1077–1081, 2025, doi: <https://doi.org/10.47709/brilliance.v5i2.6368> IoT-Based.
- [6] H. J. F. Fukuyo *et al.*, "Solar-Powered, Internet-of-Things-based Smart Greenhouse with Adaptive Environment Control for Sustainable Agriculture Nursery," in *2024 IEEE 52nd Photovoltaic Specialist Conference (PVSC)*, 2024, pp. 526–532, doi: 10.1109/PVSC57443.2024.10749686.
- [7] D. Durand and J. Aguilar, "An Analysis of the Energy Consumption Forecasting Problem in Smart Buildings Using LSTM," *Sustainability*, vol. 14, 2022, doi: <https://doi.org/10.3390/su142013358>.
- [8] N. Selle, N. Yudistira, C. Dewi, and U. Brawijaya, "PERBANDINGAN PREDIKSI PENGGUNAAN LISTRIK DENGAN MENGGUNAKAN METODE LONG SHORT TERM MEMORY (LSTM) DAN RECURRENT NEURAL NETWORK (RNN) COMPARISON OF PREDICTING ELECTRICITY CONSUMPTION USING LONG SHORT TERM MEMORY (LSTM) AND RECURRENT NEURAL NETWORK (R," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 1, pp. 155–162, 2022, doi: 10.25126/jtiik.202295585.
- [9] F. Dakheel and M. Çevik, "Electric Load Forecasting and Management in Smart Grids Using Optimized Long Short-Term Memory Network : A Real-World Evaluation," pp. 371–383, 2025.
- [10] F. Succetti, A. Rosato, R. Araneo, and M. Panella, "Deep Neural Networks for Multivariate Prediction of Photovoltaic Power Time Series," *IEEE Access*, vol. 8, pp. 211490–211505, 2020, doi: 10.1109/ACCESS.2020.3039733.
- [11] G. Airlangga, "Evaluation of Ensemble and Hybrid Models for Predicting Household Energy Consumption : A Comparative Study of Machine Learning Approaches," vol. 8, no. 1, pp. 94–101, 2025.
- [12] C. Maraveas, D. Loukatos, T. Bartzanas, K. G. Arvanitis, and J. F. Uijterwaal, "Smart and Solar Greenhouse Covers: Recent Developments and Future Perspectives," *Front. Energy Res.*, vol. 9, no. November, pp. 1–23, 2021, doi: 10.3389/fenrg.2021.783587.

- [13] A. K. Chowdhury, “Smart Renewable Energy Integration for Precision Agriculture in Off-Grid Areas,” vol. 2025, pp. 0–5, 2025.
- [14] K. Fadli and U. T. Kartini, “Peramalan Daya Listrik Jangka Sangat Pendek pada Pembangkit Fotovoltaik (PV) Menggunakan Metode Deep Learning-Long Short Term Memory (LSTM),” *J. Tek. Elektro*, vol. 12, no. 1, pp. 54–59, 2023.
- [15] Suwarjono, A. Afriza, and Y. Safari, “Smart energy monitoring: sistem pemantauan listrik cerdas berbasis iot dan machine learning dengan personalized notification melalui arsitektur hybrid di lingkungan pendidikan,” *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 10, no. 3, pp. 2847–2856, 2025, doi: <https://doi.org/10.29100/jupi.v10i3.9189>.
- [16] P. Nitnaware and M. N. Jagtap, “Enhancing Hydroponics Efficiency Using Iot-Based Automated Monitoring And Sustainable Crop Production System,” vol. 11, no. 17, pp. 1688–1700, 2025.
- [17] A. Riansyah, M. Sagaf, and M. Ismail, “Penerapan Teknologi Smart Greenhouse Berbasis Photovoltaic dan IoT pada Budidaya Sayuran Hidroponik di Desa Pekalongan Jepara,” *Abdimas Univers.*, vol. 5, no. 2, pp. 284–288, 2023, doi: 10.36277/abdimasuniversal.v5i2.342.
- [18] T. Li, M. Hua, and X. U. Wu, “A Hybrid CNN-LSTM Model for Forecasting,” *IEEE Access*, pp. 26933–26940, 2020.
- [19] Subairi, A. Puspita Sari, and E. Prakarsa Mandyartha, “Optimasi Hyperparameter Model GRU untuk Prediksi Harga Saham ANTM,” *Ilk. J. Comput. Sci. Appl. Informatics E*, vol. 7, no. 3, pp. 484–494, 2025, [Online]. Available: <http://journal.unublitar.ac.id/ilkomnika>.
- [20] X. Ma, Z. Tao, Y. Wang, H. Yu, and Y. Wang, “Long short-term memory neural network for traffic speed prediction using remote microwave sensor data,” *Transp. Res. Part C Emerg. Technol.*, vol. 54, pp. 187–197, 2015, doi: <https://doi.org/10.1016/j.trc.2015.03.014>.