

EVALUASI MODEL PREDIKTIF BERBASIS *IoT* DAN *LONG SHORT-TERM MEMORY* UNTUK PREDIKSI JANGKA SANGAT PENDEK SUHU DAN INTENSITAS CAHAYA PADA SISTEM PERTANIAN CERDAS

Ridwan¹, Firman Santosa², Muslim³

^{1,2,3}Program Studi Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Rokania, Riau, Indonesia
Email: ¹ridwan.psp2018@gmail.com, ²firman.snts@gmail.com, ³muslimpkuuu@gmail.com

Submit: 05 Desember 2025, Diterima: 02 Januari 2026, Diterbitkan: 31 Januari 2026

Abstrak: Pertanian cerdas memerlukan informasi lingkungan yang tidak hanya bersifat pemantauan, tetapi juga dapat dievaluasi untuk prediksi jangka sangat pendek. Penelitian ini merupakan eksperimen eksploratif (proof-of-concept) penerapan Internet of Things (IoT) dan Long Short-Term Memory (LSTM) menggunakan delapan parameter sensor, masing-masing 100 observasi selama sekitar 30,27 menit. Pemodelan difokuskan pada suhu lingkungan dan intensitas cahaya karena keduanya memiliki variasi temporal yang lebih informatif. Interval sampling tidak seragam (13-37 detik; median 18 detik), sehingga selisih waktu antarobservasi (Δt) dimasukkan sebagai fitur ketiga bersama suhu dan intensitas cahaya. Data dibentuk menjadi sekuen 15 langkah dan dibagi secara kronologis menjadi 59 sekuen latih, 12 validasi, dan 14 uji. Untuk mengurangi risiko overfitting, digunakan LSTM ringkas 8 unit secara terpisah untuk setiap target dan pelatihan diulang lima kali dengan seed berbeda. Model dibandingkan dengan persistence dan autoregression AR(3)-Ridge. Pada suhu, LSTM menghasilkan MAE $0,117 \pm 0,033$ °C dan belum mengungguli persistence ($0,021$ °C). Pada intensitas cahaya, MAE LSTM $6,689 \pm 0,350$ Lux sedikit lebih rendah daripada persistence (6,992 Lux), tetapi AR(3)-Ridge memberikan hasil terbaik dengan MAE 5,317 Lux, RMSE 6,704 Lux, dan R^2 0,293. Hasil menunjukkan bahwa keunggulan LSTM belum dapat digeneralisasi pada dataset yang sangat kecil dan berdurasi pendek; model sederhana tetap kompetitif dan bahkan lebih stabil pada kondisi tertentu.

Kata kunci: Internet Of Things, Long Short-Term Memory, Iklim Mikro, Pertanian Cerdas, Prediksi Deret Waktu

Abstract: Smart agriculture requires environmental information that goes beyond monitoring and can be evaluated for very-short-term prediction. This study is an exploratory proof-of-concept of Internet of Things (IoT) and Long Short-Term Memory (LSTM) modelling using eight sensor parameters, each containing 100 observations collected over approximately 30.27 minutes. Modelling focused on environmental temperature and light intensity because both exhibited more informative temporal variation. Sampling intervals were irregular (13-37 s; median 18 s); therefore, the time difference between consecutive observations (Δt) was included as a third input feature together with temperature and light intensity. The data were transformed into 15-step sequences and chronologically divided into 59 training, 12 validation, and 14 test sequences. To reduce overfitting risk, a compact 8-unit LSTM was trained separately for each target and repeated five times with different seeds. The model was compared with persistence and AR(3)-Ridge autoregression. For temperature, the LSTM achieved an MAE of 0.117 ± 0.033 °C and did not outperform persistence (0.021 °C). For light intensity, the LSTM MAE of 6.689 ± 0.350 Lux was slightly lower than persistence (6.992 Lux), while AR(3)-Ridge performed best with an MAE of 5.317 Lux, RMSE of 6.704 Lux, and R^2 of 0.293. These results show that LSTM superiority cannot be generalized from a very small and short-duration dataset; simpler models remain competitive and can be more stable under such conditions.

Keywords: Internet Of Things, Long Short-Term Memory, Microclimate, Smart Farming, Time-Series Prediction

1. PENDAHULUAN

Transformasi pertanian menuju precision agriculture dan smart farming mendorong penggunaan sensor, jaringan komunikasi, komputasi data, dan kecerdasan buatan untuk memperoleh informasi kondisi budidaya secara kontinu. Integrasi Internet of Things (IoT) memungkinkan pengamatan parameter lingkungan dan media tanam secara real-time, sedangkan analitik data memberi dasar untuk mengubah pengukuran sensor menjadi informasi yang mendukung keputusan operasional [1], [2], [3], [4].

Dalam konteks Indonesia, berbagai penelitian telah menunjukkan kelayakan IoT untuk pemantauan suhu, kelembapan, cahaya, pH, dan kelembapan tanah. Sistem greenhouse dan smart farming pada tanaman hortikultura memperlihatkan bahwa akuisisi data terdistribusi dapat digunakan untuk memonitor kondisi mikroklimat, mengendalikan irigasi, serta menjaga kondisi lingkungan budidaya. Infrastruktur edge computing dan sumber daya energi mandiri melalui baterai atau panel surya juga mulai diintegrasikan agar sistem lapangan lebih adaptif [5], [6], [7], [8], [9], [10], [11].

Meskipun pemantauan IoT dapat memberikan kondisi saat ini, kebutuhan pertanian cerdas juga mencakup kemampuan memperkirakan perubahan berikutnya. Permasalahan tersebut dapat dipandang sebagai pemodelan deret waktu karena pengamatan pada suatu waktu memiliki ketergantungan terhadap pengamatan sebelumnya. Pada konteks greenhouse, pendekatan prediktif telah digunakan untuk suhu, kelembapan, dan parameter mikroklimat lain pada horizon satu maupun beberapa langkah [12], [13], [14].

Long Short-Term Memory (LSTM) merupakan pengembangan recurrent neural network yang dirancang untuk mempertahankan informasi temporal melalui mekanisme gate. Dalam kajian mikroklimat pertanian, LSTM dan turunannya telah digunakan untuk prediksi suhu dan kelembapan greenhouse, suhu udara dan tanah, serta peramalan mikroklimat multi-step. Sejumlah penelitian memadukan LSTM dengan attention, convolutional neural network, Kalman filter, atau encoder-decoder untuk menangkap pola temporal yang lebih kompleks [12], [13], [14], [15], [16], [17].

Pendekatan prediktif juga digunakan dalam pengendalian mikroklimat greenhouse dan machine learning berbasis penempatan sensor. Temuan terdahulu menunjukkan bahwa karakteristik data, penempatan sensor, horizon prediksi, dan variasi temporal setiap parameter memengaruhi performa model. Variabel dengan dinamika tinggi umumnya menyediakan informasi temporal yang lebih kaya dibandingkan variabel yang hampir konstan [18], [19], [20].

Pada media tanam, LSTM telah diterapkan untuk memprediksi kelembapan tanah berdasarkan riwayat kelembapan dan faktor cuaca. Hal ini menunjukkan bahwa pemodelan temporal pada sistem pertanian dapat diperluas dari parameter atmosfer ke parameter tanah apabila tersedia deret pengamatan yang memadai, konsisten, dan representatif [21], [22].

Penelitian Indonesia juga telah menerapkan LSTM untuk prediksi data cuaca, curah hujan, dan deret waktu sektor pertanian [23], [24], [25]. Namun, sebagian besar studi tersebut menggunakan data historis yang jauh lebih panjang daripada dataset sensor lapangan yang hanya berlangsung puluhan menit. Perbedaan skala data ini penting karena deep learning membutuhkan jumlah dan keragaman observasi yang memadai; oleh sebab itu, penelitian dengan data sangat terbatas lebih tepat diposisikan sebagai eksperimen eksploratif daripada validasi performa LSTM secara umum.


Berdasarkan kondisi tersebut, penelitian ini mengevaluasi penerapan LSTM sebagai lapisan prediktif pada platform IoT untuk prediksi jangka sangat pendek dua parameter mikroklimat, yaitu suhu lingkungan dan intensitas cahaya. Kebaruan penelitian tidak terletak pada pengembangan arsitektur LSTM baru, melainkan pada evaluasi eksploratif data sensor aktual yang mencakup karakterisasi kualitas data, pemodelan interval waktu tidak seragam melalui fitur Δt , pengurangan kapasitas model, pengulangan eksperimen, dan perbandingan dengan dua baseline sederhana. Tujuan penelitian adalah menilai apakah LSTM memberikan manfaat terukur pada skenario data lapangan berukuran kecil sekaligus mengidentifikasi batas validitas penggunaannya [1], [12], [23].

2. METODE PENELITIAN

2.1. Desain dan Alur Penelitian

Penelitian menggunakan pendekatan eksperimental berbasis data deret waktu. Data sensor IoT disinkronkan, diperiksa kualitas numerik dan temporalnya, kemudian dianalisis secara deskriptif. Dua variabel dengan variasi temporal memadai dipilih sebagai target. Karena interval pencatatan tidak seragam, selisih waktu antarobservasi (Δt) dipertahankan sebagai fitur masukan. Selanjutnya dibentuk sekuen kronologis, dilatih LSTM ringkas untuk setiap target, dan dilakukan evaluasi terhadap persistence serta autoregression linear. Pelatihan LSTM diulang lima kali agar sensitivitas terhadap inisialisasi dapat diamati. Alur penelitian ditunjukkan pada Gambar 1 [12], [14], [23].

Alur Revisi Pemodelan Prediktif IoT-LSTM



Gambar 1. Alur revisi pengolahan data IoT dan evaluasi model prediktif

2.2. Dataset Sensor IoT

Dataset terdiri atas delapan berkas sensor yang merepresentasikan kondisi lingkungan, media tanam, kualitas air, dan sumber daya sistem. Setiap berkas memuat timestamp, Entry_id, dan nilai sensor. Masing-masing parameter terdiri atas 100 observasi dengan Entry_id 2245-2344. Rentang pengamatan utama berlangsung pada 27 September 2024 sekitar pukul 12:58 hingga 13:28 pada zona waktu +05:30. Interval sampling tidak seragam, dengan minimum 13 detik, maksimum 37 detik, median 18 detik, dan rata-rata 18,34 detik. Keseluruhan pengamatan mencakup sekitar 30,27 menit. Karakteristik deskriptif dataset disajikan pada Tabel 1 [5], [7], [9].

Tabel 1. Statistik Deskriptif Data Sensor IoT

Parameter	Unit	n	Minimum	Rata-rata	Maksimum	Std. Dev.
Suhu lingkungan	°C	100	26,10	26,342	26,90	0,230
Kelembapan lingkungan	%	100	95,00	95,000	95,00	0,000
Intensitas cahaya	Lux	100	14,17	43,201	71,67	13,853
Kelembapan tanah	%	100	0,91	60,929	64,22	8,447
Suhu tanah	°C	100	18,10	18,143	18,20	0,050
pH tanah	pH	100	6,10	6,100	6,10	0,000
Water TDS	mg/L	100	0,51	118,489	155,42	13,997
Tegangan baterai panel surya	V	100	3,550	3,630	3,719	0,049

Tidak ditemukan nilai numerik kosong pada kedelapan parameter. Namun, pemeriksaan variansi menunjukkan dua parameter tanpa variasi, yaitu kelembapan lingkungan yang seluruh nilainya 95% dan pH tanah yang seluruh nilainya 6,1. Suhu tanah juga hanya berubah antara 18,1-18,2 °C. Selain itu, terdapat transien ekstrem pada kelembapan tanah dan TDS air pada sebagian kecil Entry_id. Nilai tersebut dipertahankan pada analisis deskriptif karena metadata eksperimen tidak menyediakan informasi yang cukup untuk memastikan bahwa pengamatan tersebut merupakan kesalahan sensor. Untuk pemodelan prediktif, target yang konstan atau hampir konstan tidak digunakan [19], [21].

Sinkronisasi antarberkas dilakukan berdasarkan Entry_id karena identitas tersebut konsisten pada seluruh sensor. Ditemukan satu ketidaksesuaian timestamp pada kelembapan lingkungan untuk Entry_id 2344, yaitu 13:27:26, sedangkan sensor lain menunjukkan 13:28:26. Karena kelembapan tidak digunakan sebagai target dan Entry_id tersedia sebagai kunci pengukuran, ketidaksesuaian tersebut dicatat sebagai isu kualitas data tanpa mengubah nilai sensor [1], [5].

2.3. Seleksi Variabel dan Pembentukan Sekuen

Pemodelan difokuskan pada suhu lingkungan dan intensitas cahaya karena kedua parameter menunjukkan dinamika temporal yang lebih informatif dibandingkan kelembapan lingkungan dan pH tanah yang konstan. Untuk menangani interval sampling yang tidak seragam, setiap observasi diberi fitur Δt , yaitu selisih waktu terhadap observasi sebelumnya. Nilai Δt pertama diisi dengan median interval 18 detik. Dengan demikian, setiap langkah sekuen memiliki tiga kanal input: suhu lingkungan, intensitas cahaya, dan Δt . Normalisasi Min-Max dilakukan menggunakan parameter yang dihitung hanya dari data latih, kemudian diterapkan pada validasi dan uji untuk mencegah kebocoran informasi masa depan [12], [14], [15].

Deret waktu diubah menjadi pasangan input-output menggunakan sliding window sepanjang 15 observasi. Dengan median interval 18 detik, satu jendela memuat riwayat tipikal sekitar 4,5 menit, sedangkan target adalah nilai pada satu observasi berikutnya. Dari 100 titik mentah diperoleh 85 sekuen. Pembagian dilakukan secara kronologis menjadi 59 sekuen latih, 12 sekuen validasi, dan 14 sekuen uji tanpa pengacakan sehingga urutan temporal tetap terjaga [13], [23].

2.4. Arsitektur dan Pelatihan LSTM

Untuk mengurangi ketidakseimbangan antara kapasitas model dan jumlah data, arsitektur awal 32 unit direvisi menjadi LSTM ringkas 8 hidden units. Dua model dilatih secara terpisah untuk target suhu dan intensitas cahaya; masing-masing menerima input 15 langkah $\times$ 3 fitur dan menghasilkan satu nilai keluaran melalui lapisan Dense. Setiap model memiliki 425 parameter yang dapat dilatih. Optimasi menggunakan Adam dengan learning rate 0,001, weight decay 0,0001, fungsi kerugian mean squared error (MSE), maksimum 600 epoch, dan early stopping dengan patience 60 berdasarkan loss validasi. Pelatihan diulang lima kali menggunakan seed 1-5; pada setiap pengulangan digunakan checkpoint dengan loss validasi terendah [12], [17], [23].

Tabel 2. Konfigurasi Model LSTM Ringkas

Komponen	Konfigurasi
Input	15 langkah $\times$ 3 fitur (suhu, cahaya, Δt)
Target	1 langkah berikutnya; model terpisah per target
LSTM hidden units	8
Jumlah layer LSTM	1
Parameter trainable	425 per model
Output layer	Dense, 1 unit
Optimizer	Adam
Learning rate	0,001
Weight decay	0,0001
Loss	Mean Squared Error
Maksimum epoch	600
Early stopping	Patience 60
Split	59 train; 12 validation; 14 test
Pengulangan	5 run; seed 1-5

2.5. Evaluasi Model


Performa model dievaluasi menggunakan mean absolute error (MAE), root mean squared error (RMSE), mean absolute percentage error (MAPE), dan coefficient of determination (R^2). MAE dan RMSE mengukur besar kesalahan pada satuan asli, MAPE menunjukkan kesalahan relatif, sedangkan R^2 menilai proporsi variasi target yang dijelaskan model. Karena R^2 sensitif terhadap rentang target yang sempit dan ukuran data uji yang kecil, interpretasinya dilakukan bersama MAE dan RMSE [13], [16], [23].

Sebagai pembandingan digunakan dua baseline. Persistence memprediksi nilai berikutnya sama dengan observasi terakhir pada jendela input. Baseline kedua adalah autoregression linear AR(3)-Ridge dengan regularisasi $\alpha=1,0$, menggunakan tiga observasi terakhir dari suhu, intensitas cahaya, dan Δt sebagai prediktor. Hasil LSTM dilaporkan sebagai rata-rata $\pm$ simpangan baku dari lima pengulangan, sedangkan baseline bersifat deterministik. Pengulangan ini mengukur sensitivitas optimasi terhadap inisialisasi, tetapi tidak menghilangkan keterbatasan bahwa data uji hanya terdiri atas 14 sekuen [14], [23].

3. HASIL DAN PEMBAHASAN

3.1. Karakteristik Temporal Data IoT

Visualisasi tiga parameter lingkungan utama menunjukkan karakter temporal yang berbeda. Kelembapan lingkungan membentuk garis datar pada 95% sepanjang pengamatan. Intensitas cahaya mengalami fluktuasi tertinggi pada rentang 14,17-71,67 Lux, sedangkan suhu lingkungan bergerak pada rentang sempit 26,1-26,9 °C dan memperlihatkan kecenderungan meningkat pada bagian akhir periode. Tren ketiga parameter ditunjukkan pada Gambar 2 [5], [19].



Gambar 2. Tren kelembaban, intensitas cahaya, dan suhu lingkungan pada data IoT

Perbedaan karakter tersebut berimplikasi langsung terhadap proses prediksi. Variabel konstan tidak menyediakan variasi temporal yang cukup untuk dipelajari, sedangkan intensitas cahaya memiliki dinamika yang lebih kaya. Suhu lingkungan berada di antara keduanya: perubahan absolut kecil tetapi membentuk pola bertahap. Temuan ini konsisten dengan literatur yang menekankan pentingnya dinamika temporal, kualitas sensor, dan horizon prediksi dalam pemodelan mikroklimat greenhouse [13], [19], [20].

Parameter pendukung juga menunjukkan karakter beragam. Kelembaban tanah rata-rata 60,929% tetapi memiliki transien rendah, TDS air rata-rata 118,489 mg/L dengan transien ekstrem, dan tegangan baterai panel surya berada pada rentang 3,550-3,719 V. Parameter tersebut memperlihatkan keluasan konteks yang dapat disediakan platform IoT, tetapi tidak seluruhnya dijadikan target prediksi karena durasi data pendek dan tingkat variasi sensor berbeda [8], [9], [21].

3.2. Hasil Pelatihan, Baseline, dan Stabilitas Model

Lima pengulangan LSTM menghasilkan checkpoint terbaik yang berbeda pada tiap seed, menunjukkan sensitivitas optimasi pada dataset berukuran kecil. Oleh karena itu, hasil LSTM dilaporkan sebagai rata-rata±simpangan baku, bukan sebagai satu nilai dari satu inisialisasi. Evaluasi tetap dilakukan pada 14 sekuen uji terakhir yang tidak digunakan untuk pelatihan maupun pemilihan checkpoint. Tabel 3 membandingkan LSTM dengan persistence dan AR(3)-Ridge [12], [23].


Tabel 3. Kinerja LSTM, Persistence, dan AR(3)-Ridge pada Data Uji

Variabel	Model	MAE	RMSE	MAPE (%)	R ²	Ket.
Suhu (°C)	LSTM-8	0,117	0,134	0,439	-3,80	5 run
Suhu (°C)	Persist.	0,021	0,046	0,080	0,45	Best suhu
Suhu (°C)	AR(3)	0,055	0,066	0,204	-0,12	Baseline
Cahaya (Lux)	LSTM-8	6,689	8,429	22,288	-0,12	5 run
Cahaya (Lux)	Persist.	6,992	8,403	23,145	-0,1	Baseline
Cahaya (Lux)	AR(3)	5,317	6,704	17,223	0,3	Best

3.3. Prediksi Suhu Lingkungan

Pada target suhu, rata-rata lima run LSTM menghasilkan MAE 0,117±0,033 °C, RMSE 0,134±0,029 °C, MAPE 0,439±0,124%, dan R² -3,801±2,032. Persistence jauh lebih baik dengan MAE 0,021 °C, RMSE 0,046 °C, MAPE 0,080%, dan R² 0,447. AR(3)-Ridge berada di antara keduanya dengan MAE 0,055 °C dan

RMSE 0,066 °C. Dengan demikian, LSTM tidak memberikan keuntungan pada suhu dalam dataset ini [13], [15].




Gambar 3. Perbandingan suhu aktual, rata-rata LSTM, persistence, dan AR(3)-Ridge

Hasil tersebut dapat dijelaskan oleh rentang suhu yang hanya 0,8 °C dan dominasi perubahan kecil sekitar 0,1 °C. Pada deret yang sangat halus, nilai terakhir merupakan prediktor jangka sangat pendek yang kuat sehingga persistence sulit dikalahkan. R^2 LSTM yang negatif juga memperlihatkan bahwa, walaupun galat absolut masih kecil dalam satuan suhu, variasi residual lebih besar daripada variasi target. Hasil ini mendukung perlunya interpretasi metrik secara kontekstual dan memperkuat indikasi bahwa kapasitas deep learning belum sebanding dengan informasi yang tersedia pada seri suhu berdurasi pendek [13], [14], [15], [16].

3.4. Prediksi Intensitas Cahaya

Pada intensitas cahaya, rata-rata LSTM menghasilkan MAE $6,689 \pm 0,350$ Lux, RMSE $8,429 \pm 0,284$ Lux, MAPE $22,288 \pm 2,733\%$, dan $R^2 -0,118 \pm 0,076$. Dibandingkan persistence, MAE LSTM hanya lebih rendah sekitar 4,34%, sedangkan RMSE justru sekitar 0,31% lebih tinggi dan R^2 hampir sama. AR(3)-Ridge memberikan hasil terbaik dengan MAE 5,317 Lux, RMSE 6,704 Lux, MAPE 17,223%, dan R^2 0,293; terhadap persistence, AR(3)-Ridge menurunkan MAE sekitar 23,96% dan RMSE sekitar 20,22%. Dengan demikian, pada dataset ini keunggulan LSTM terhadap baseline tidak bersifat konsisten [12], [14].



Gambar 4. Perbandingan intensitas cahaya aktual, rata-rata LSTM, persistence, dan AR(3)-Ridge

Hasil intensitas cahaya menunjukkan dua hal. Pertama, informasi beberapa langkah sebelumnya tetap berguna karena baik LSTM maupun autoregression memanfaatkan riwayat temporal. Kedua, kompleksitas model tidak otomatis menghasilkan performa lebih baik ketika jumlah observasi sangat terbatas. AR(3)-Ridge yang jauh lebih sederhana justru memberikan generalisasi uji terbaik. Temuan ini selaras dengan literatur greenhouse yang menunjukkan manfaat model temporal ketika perubahan lingkungan nyata, tetapi sekaligus menegaskan bahwa pemilihan arsitektur harus mempertimbangkan skala dan kualitas data [12], [14], [17], [19].

3.5. Implikasi untuk Sistem Pertanian Cerdas

Dari perspektif sistem, penelitian ini membentuk proof-of-concept lapisan prediktif setelah akuisisi IoT, bukan model produksi yang siap digunakan sebagai peringatan dini. Pada implementasi lanjutan, prediksi suhu, cahaya, kelembapan tanah, atau parameter lain dapat dikembangkan untuk mendukung notifikasi, pengaturan irigasi, ventilasi, pencahayaan, atau manajemen energi setelah tersedia data dengan horizon yang lebih panjang dan validasi yang memadai. Konsep ini konsisten dengan perkembangan smart microclimate

control dan smart greenhouse yang menggabungkan penginderaan, pemrosesan, dan keputusan otomatis [6], [7], [11], [18].

Meskipun platform menyediakan delapan sensor, penelitian ini hanya mengevaluasi prediksi dua parameter mikroklimat, yaitu suhu lingkungan dan intensitas cahaya. Kelembapan lingkungan dan pH tanah tidak memiliki variasi pada periode pengamatan, suhu tanah hampir konstan, sedangkan kelembapan tanah dan TDS memiliki transien ekstrem yang memerlukan validasi fisik serta kalibrasi sebelum dimodelkan lebih lanjut. Kelembapan tanah tetap merupakan kandidat penting untuk pengembangan berikutnya karena penelitian terdahulu menunjukkan efektivitas LSTM ketika tersedia riwayat yang lebih panjang dan fitur cuaca yang memadai [21], [22].

3.6. Keterbatasan Penelitian

Keterbatasan utama penelitian adalah hanya 100 observasi per sensor dengan durasi sekitar 30 menit. Walaupun lima pengulangan pelatihan telah dilakukan untuk mengukur sensitivitas terhadap inisialisasi, data uji tetap hanya 14 sekuen sehingga ketidakpastian akibat ukuran sampel belum dapat dihilangkan. Hasil penelitian karena itu harus dipandang sebagai proof-of-concept dan evaluasi eksploratif, bukan bukti keunggulan LSTM secara umum. Horizon satu langkah dengan interval tipikal sekitar 18 detik juga terlalu pendek untuk disebut peringatan dini operasional pada pertanian [12], [14], [23].

Dataset juga belum memuat metadata kalibrasi sensor, jenis tanaman, lokasi eksperimen, kondisi greenhouse atau lahan, kejadian intervensi, dan cuaca eksternal. Penelitian lanjutan perlu melakukan pencatatan multi-hari atau multi-musim dengan interval yang lebih konsisten, menguji horizon beberapa menit hingga jam melalui multi-step forecasting, serta menggunakan walk-forward validation pada periode uji yang lebih panjang. Perbandingan dengan SARIMA, GRU, attention-LSTM, dan hybrid CNN-LSTM juga dapat dilakukan setelah jumlah data memadai agar kesimpulan metodologis lebih kuat [12], [13], [17], [23].

4. KESIMPULAN

Penelitian ini mengevaluasi secara eksploratif LSTM sebagai model prediktif jangka sangat pendek untuk dua parameter mikroklimat, yaitu suhu lingkungan dan intensitas cahaya, pada platform IoT yang memiliki delapan sensor. Interval pencatatan yang tidak seragam ditangani dengan memasukkan Δt sebagai fitur, sedangkan kapasitas LSTM dikurangi menjadi 8 unit per target dan pelatihan diulang lima kali. Pada suhu, persistence memberikan hasil terbaik dengan MAE 0,021 °C, sedangkan LSTM menghasilkan 0,117±0,033 °C. Pada intensitas cahaya, LSTM memperoleh MAE 6,689±0,350 Lux, tetapi AR(3)-Ridge memberikan performa terbaik dengan MAE 5,317 Lux, RMSE 6,704 Lux, dan R^2 0,293. Temuan ini menunjukkan bahwa LSTM belum memberikan keunggulan yang konsisten pada dataset yang hanya mencakup sekitar 30 menit; model sederhana dapat lebih sesuai pada kondisi data terbatas. Kontribusi penelitian terutama terletak pada evaluasi transparan terhadap kualitas waktu, kapasitas model, pengulangan eksperimen, dan baseline. Validasi lanjutan memerlukan data multi-hari atau multi-musim, horizon prediksi beberapa menit hingga jam, serta evaluasi lintas model yang lebih luas [12], [21], [23].

DAFTAR PUSTAKA

- [1] A. Soussi, E. Zero, R. Sacile, D. Trincherro, and M. Fossa, "Smart sensors and smart data for precision agriculture: A review," *Sensors*, vol. 24, no. 8, Art. no. 2647, 2024, doi: 10.3390/s24082647.
- [2] V. Kumar, K. V. Sharma, N. Kedam, A. B. Patel, T. R. Kate, and U. Rathnayake, "A comprehensive review on smart and sustainable agriculture using IoT technologies," *Smart Agricultural Technology*, vol. 8, Art. no. 100487, 2024, doi: 10.1016/j.atech.2024.100487.
- [3] S. Dhanasekar, "A comprehensive review on current issues and advancements of Internet of Things in precision agriculture," *Computer Science Review*, vol. 55, Art. no. 100694, 2025, doi: 10.1016/j.cosrev.2024.100694.
- [4] T. Alahmad, M. Neményi, and A. Nyéki, "Applying IoT sensors and big data to improve precision crop production: A review," *Agronomy*, vol. 13, no. 10, Art. no. 2603, 2023, doi: 10.3390/agronomy13102603.
- [5] L. Hartawan et al., "Design of IoT-based greenhouse temperature and humidity monitoring system," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 12, no. 4, pp. 1051-1062, 2024, doi: 10.26760/elkomika.v12i4.1051.
- [6] M. D. Agustiniingsih, P. C. A. Lestari, R. M. Savitrah, A. Fahmi, and Hamdan, "Nogo Osing Apps: Aplikasi sistem monitoring & kontrol buah naga berbasis IoT," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 1, pp. 145-154, 2024, doi: 10.25126/jtiik.20241117683.

- [7] H. Hasfani and U. Ristian, "Infrastruktur jaringan komunikasi pada smart-green house tanaman anggur berbasis edge computing," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 12, no. 2, pp. 484-497, 2024, doi: 10.26760/elkomika.v12i2.484.
- [8] I. Ruslianto, U. Ristian, and H. Hasfani, "Sistem pintar untuk anggur (Sipunggur) pada kawasan tropis berbasis Internet of Things (IoT)," *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 8, no. 1, pp. 121-127, 2022, doi: 10.26418/jp.v8i1.52835.
- [9] Y. Taqiyuddin, I. Ruslianto, and U. Ristian, "Sistem monitoring hidroponik indoor berbasis wick menggunakan HOPONIC (Home Pot Hidroponic)," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 12, no. 1, pp. 201-215, 2024, doi: 10.26760/elkomika.v12i1.201.
- [10] A. Suryaningrat, D. Kurnianto, and R. A. Rochmanto, "Sistem monitoring kelembaban tanaman cabai rawit menggunakan irigasi tetes gravitasi berbasis Internet of Things (IoT)," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no. 3, pp. 568-580, 2022, doi: 10.26760/elkomika.v10i3.568.
- [11] H. Februariyanti, T. Khristianto, A. Jananto, and E. Nurraharjo, "Analisis sistem kontrol kelembapan ruang budidaya tanaman berbasis ANFIS-IoT," *Journal of Telecommunication, Electronics, and Control Engineering*, vol. 7, no. 2, pp. 119-133, 2025, doi: 10.20895/jtece.v7i2.1833.
- [12] Y. Wang, M. O. Ojo, and A. Zahid, "Automated IoT-enabled greenhouse microclimate prediction using multivariate sequence-to-sequence LSTM-based encoder-decoder," *Internet of Things*, vol. 38, Art. no. 102015, 2026, doi: 10.1016/j.iot.2026.102015.
- [13] Z. Guo and L. Feng, "Multi-step prediction of greenhouse temperature and humidity based on temporal position attention LSTM," *Stochastic Environmental Research and Risk Assessment*, vol. 38, pp. 4907-4934, 2024, doi: 10.1007/s00477-024-02840-x.
- [14] Y. Yang, P. Gao, Z. Sun, H. Wang, M. Lu, Y. Liu, and J. Hu, "Multistep ahead prediction of temperature and humidity in solar greenhouse based on FAM-LSTM model," *Computers and Electronics in Agriculture*, vol. 213, Art. no. 108261, 2023, doi: 10.1016/j.compag.2023.108261.
- [15] X. Li, L. Zhang, X. Wang, and B. Liang, "Forecasting greenhouse air and soil temperatures: A multi-step time series approach employing attention-based LSTM network," *Computers and Electronics in Agriculture*, vol. 217, Art. no. 108602, 2024, doi: 10.1016/j.compag.2023.108602.
- [16] P.-Y. Kow, M.-H. Lee, W. Sun, M.-H. Yao, and F.-J. Chang, "Integrate deep learning and physically-based models for multi-step-ahead microclimate forecasting," *Expert Systems with Applications*, vol. 210, Art. no. 118481, 2022, doi: 10.1016/j.eswa.2022.118481.
- [17] T. Liu, X. Qiao, S. Liu, and S. Qi, "Research on greenhouse environment prediction based on GCAKF-CNN-LSTM," *Applied Engineering in Agriculture*, vol. 40, no. 2, pp. 181-187, 2024, doi: 10.13031/aea.15867.
- [18] T.-H. Chen, M.-H. Lee, I.-W. Hsia, C.-H. Hsu, M.-H. Yao, and F.-J. Chang, "Develop a smart microclimate control system for greenhouses through system dynamics and machine learning techniques," *Water*, vol. 14, no. 23, Art. no. 3941, 2022, doi: 10.3390/w14233941.
- [19] O. S. Ajani, M. J. Usigbe, E. Aboyeji, D. D. Uyeh, Y. Ha, T. Park, and R. Mallipeddi, "Greenhouse micro-climate prediction based on fixed sensor placements: A machine learning approach," *Mathematics*, vol. 11, no. 14, Art. no. 3052, 2023, doi: 10.3390/math11143052.
- [20] T. Petrakis, A. Kavga, V. Thomopoulos, and A. A. Argiriou, "Neural network model for greenhouse microclimate predictions," *Agriculture*, vol. 12, no. 6, Art. no. 780, 2022, doi: 10.3390/agriculture12060780.
- [21] S.-H. Park, B.-Y. Lee, M.-J. Kim, W. Sang, M. C. Seo, J.-K. Baek, J. E. Yang, and C. Mo, "Development of a soil moisture prediction model based on recurrent neural network Long Short-Term Memory (RNN-LSTM) in soybean cultivation," *Sensors*, vol. 23, no. 4, Art. no. 1976, 2023, doi: 10.3390/s23041976.
- [22] D. F. Kandamali, E. Porter, W. M. Porter, A. McLemore, D. O. Kiobia, A. P. Tavandashti, and G. C. Rains, "Hybrid LSTM method for multistep soil moisture prediction using historical soil moisture and weather data," *AgriEngineering*, vol. 7, no. 8, Art. no. 260, 2025, doi: 10.3390/agriengineering7080260.
- [23] H. T. A. Simanjuntak, A. Lumbanraja, G. Samosir, and Regita, "Prediksi single-step dan multi-step data cuaca menggunakan model Long Short-Term Memory dan SARIMA," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 12, no. 2, pp. 399-410, 2025, doi: 10.25126/jtiik.2025129444.
- [24] N. M. M. C. Devi, I. P. A. Bayupati, and N. K. A. Wirdiani, "Prediksi curah hujan dasarian dengan metode Vanilla RNN dan LSTM untuk menentukan awal musim hujan dan kemarau," *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 8, no. 3, pp. 405-411, 2022, doi: 10.26418/jp.v8i3.56606.

- [25] R. Hidayat and I. Wibisonya, "Rice price prediction with Long Short-Term Memory (LSTM) neural network," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 8, no. 5, pp. 658-664, 2024, doi: 10.29207/resti.v8i5.6041.