

# Analisis *Trade-Off* Efisiensi dan Stabilitas pada Kontrol Prediktif Mikroklimat

<http://dx.doi.org/10.28932/jutisi.v12i1.12210>

Riwayat Artikel

Received: 19 Juni 2025 | Final Revision: 24 November 2025 | Accepted: 15 Januari 2026

Creative Commons License 4.0 (CC BY – NC)



Gerrio Irfan Pratama<sup>✉#1</sup>, Dewi Lestari<sup>#2</sup>, Ketut Bayu Yogha Bintoro<sup>#3</sup>

<sup>#</sup> Program studi Teknik Informatika, Universitas Trilogi

Jl. TMP. Kalibata No.1, Duren Tiga, Kec. Pancoran, Kota Jakarta Selatan, DKI Jakarta 12760, Indonesia

<sup>1</sup>gerrio.irfan@trilogi.ac.id

<sup>2</sup>dewy24@trilogi.ac.id

<sup>3</sup>ketutbayu@trilogi.ac.id

<sup>✉</sup>Corresponding author: gerrio.irfan@trilogi.ac.id

**Abstrak** — Kontrol mikroklimat presisi merupakan aspek krusial dalam berbagai aplikasi IoT, namun strategi kontrol reaktif berbasis ambang batas yang umum digunakan seringkali terbukti tidak efisien. Penelitian ini menyajikan sebuah analisis komparatif berbasis simulasi untuk mengevaluasi secara kuantitatif performa antara strategi kontrol reaktif dan kontrol prediktif yang lebih cerdas. Dengan menggunakan data kelembapan *time-series* dari sebuah terarium *Tropidolaemus sp.*, sebuah model peramalan SARIMA dikembangkan dan divalidasi untuk menjadi dasar dari kontroler prediktif. Kinerja kedua strategi kemudian diadu dalam lingkungan simulasi berdasarkan dua metrik utama: efisiensi aktuasi dan stabilitas lingkungan. Hasil menunjukkan bahwa kontroler prediktif secara signifikan lebih efisien, dengan mampu mengurangi jumlah aktivasi aktuatur hingga 47% dibandingkan kontroler reaktif. Namun, penelitian ini mengungkap adanya *trade-off* fundamental: efisiensi tersebut diiringi oleh penurunan stabilitas akibat fenomena *overshoot* yang disebabkan oleh mekanisme aksi kontrol yang kaku. Studi ini menyimpulkan bahwa keunggulan prediksi proaktif harus disinergikan dengan mekanisme aksi yang adaptif untuk mencapai performa sistem yang holistik, seraya menawarkan metodologi simulasi sebagai kerangka kerja yang efisien untuk evaluasi sistem kontrol cerdas.

**Kata kunci**— Analisis *Trade-Off*; ARIMA; Internet of Things (IoT); Kontrol Prediktif; Manajemen Mikroklimat.

## *A Trade-Off Analysis of Efficiency and Stability in Predictive Microclimate Control*

**Abstract** — Precise microclimate control is a crucial aspect in various IoT applications, yet commonly used reactive, threshold-based control strategies often prove to be inefficient. This study presents a simulation-based comparative analysis to quantitatively evaluate the performance between a reactive control strategy and a more intelligent predictive one. Using time-series humidity data from a *Tropidolaemus sp.* terrarium, a SARIMA forecasting model was developed and validated to drive the predictive controller. The performance of both strategies was then benchmarked in a simulation environment based on two key metrics: actuation efficiency and environmental stability. The results demonstrate that the predictive controller is significantly more efficient, reducing actuator activations by up to 47% compared to the reactive controller. However, this study reveals a fundamental trade-off: this efficiency is accompanied by a decrease in stability due to an overshoot phenomenon caused by a rigid control action mechanism. This study concludes that the superiority of proactive prediction must be synergized with adaptive action mechanisms to achieve holistic system optimality, while also presenting a simulation methodology as an efficient framework for evaluating intelligent control systems.

Keywords— *ARIMA; Internet of Things (IoT); Microclimate Management; Predictive Control; Trade-Off Analysis.*

## I. PENDAHULUAN

Pemanfaatan *Internet of Things (IoT)* telah membawa potensi transformatif untuk mendorong efisiensi dan otomasi di berbagai sektor, termasuk lingkungan yang sangat spesifik seperti *herpetokultur* (pemeliharaan reptil dan amfibi) [1], [2]. Otomasi menjadi kebutuhan krusial bagi spesies yang peka terhadap perubahan lingkungan, seperti ular arboreal *Tropidolaemus* sp., yang memerlukan replikasi iklim mikro yang tepat dan stabil. Stabilitas kelembapan adalah parameter fundamental bagi kesehatan spesies ini, di mana fluktuasi dapat memicu kondisi patologis serius seperti *dysecdysis* dan infeksi pernapasan [3]. Pengawasan manual rentan terhadap inkonsistensi dan kelalaian manusia, menjadikan sistem cerdas sebagai solusi yang diperlukan.

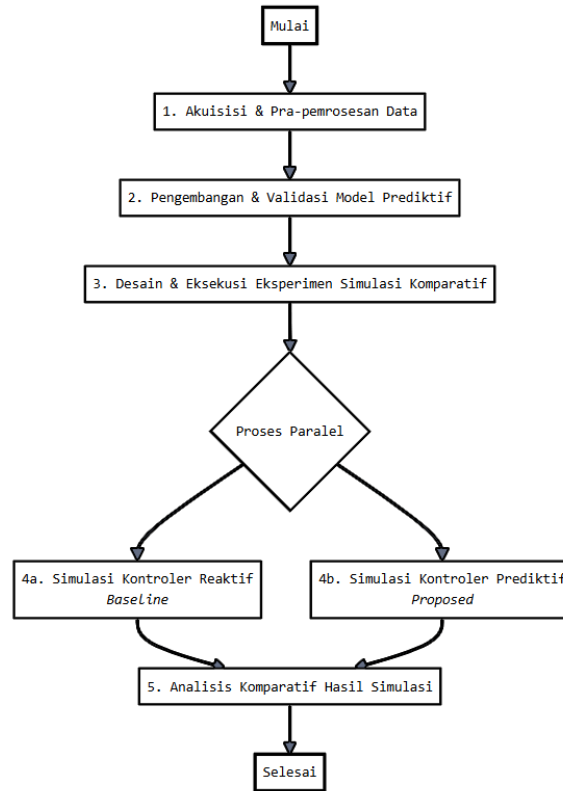
Sistem otomasi awal menggunakan logika kontrol reaktif berbasis ambang batas (*threshold-based*). Meskipun merupakan kemajuan dari metode manual, pendekatan ini memiliki kelemahan intrinsik: ia hanya dapat beraksi setelah kondisi lingkungan melewati batas ideal, menghilangkan kemampuan preventif. Selain itu, sifat *on/off* yang kaku menyebabkan siklus aktivasi aktuator yang tidak efisien, meningkatkan konsumsi daya dan mempercepat degradasi komponen mekanis [4], [5]. Untuk mengatasi inefisiensi reaktif, kontrol prediktif menawarkan paradigma solusi yang menjanjikan [6], dengan memanfaatkan model peramalan *time-series* seperti *SARIMA (Seasonal Autoregressive Integrated Moving Average)* untuk mengambil tindakan pencegahan proaktif [7], [8]. Di sinilah celah penelitian muncul: walaupun keunggulan teoretis kontrol prediktif sudah diakui dalam berbagai studi [9], [10], masih ada kekurangan penelitian yang menyediakan evaluasi kuantitatif sistematis yang secara langsung membandingkan kedua strategi ini dalam perbandingan langsung, terutama dalam konteks *trade-off* mendasar antara stabilitas lingkungan versus efisiensi sumber daya [11], [12].

Analisis *trade-off* antara efisiensi dan stabilitas menjadi krusial dalam implementasi IoT karena implikasi langsungnya pada biaya operasional dan keandalan sistem. Secara teknis, setiap pengaktifan aktuator yang tidak perlu (efisiensi rendah) berdampak pada peningkatan konsumsi daya dan percepatan keausan mekanis [13]. Secara aplikatif, ketidakstabilan lingkungan (stabilitas rendah) yang ditimbulkan oleh aksi kontrol yang terlalu keras dapat memicu risiko biologis pada objek pemeliharaan [3]. Oleh karena itu, penelitian ini tidak hanya berfokus pada pembuktian keunggulan prediktif secara umum, tetapi secara kritis mengevaluasi titik lemah implementasinya melalui mekanisme *overshoot*, yang merupakan pembeda utama dari studi literatur terdahulu.

Berdasarkan celah krusial ini, tujuan utama studi ini adalah untuk merancang, mengimplementasikan, dan mengevaluasi model kontrol prediktif berbasis *SARIMA*, serta melakukan analisis komparatif berbasis simulasi terhadap model reaktif standar. Pendekatan ini memungkinkan perbandingan kuantitatif yang fokus pada efisiensi dan stabilitas. Studi ini memberikan tiga kontribusi utama: (1) Menyajikan analisis mendalam yang mengungkapkan *trade-off* krusial antara efisiensi dan stabilitas, memberikan wawasan bahwa prediksi harus diimbangi dengan mekanisme aksi yang adaptif; (2) Menyediakan solusi kontrol presisi yang berorientasi pada kebutuhan praktisi *herpetokultur*; dan (3) Menawarkan metodologi simulasi sebagai kerangka kerja yang efisien untuk *benchmarking* algoritma kontrol cerdas.

## II. METODOLOGI PENELITIAN


Penelitian ini mengadopsi kerangka kerja kuantitatif berbasis simulasi yang dikembangkan menggunakan Python dengan pustaka *time-series* dan statistik untuk membandingkan performa dua strategi kontrol iklim mikro terarium, yaitu reaktif dan prediktif [3], [8]. Metodologi penelitian disusun dalam tiga tahapan sekuensial sebagaimana ditunjukkan pada Gambar 1 dimulai dari akuisisi dan prapemrosesan data kelembapan *time-series* sebagai fondasi analisis [3], [14]. Tahap berikutnya adalah pengembangan dan validasi model peramalan *Seasonal Autoregressive Integrated Moving Average (SARIMA)* [11]. Pemilihan *SARIMA* dijustifikasi secara kritis karena model ini menawarkan keseimbangan yang optimal antara akurasi prediksi dan efisiensi komputasi, serta mampu merepresentasikan pola musiman yang kuat pada data lingkungan. Model ini dinilai lebih layak untuk implementasi *edge computing* dibandingkan pendekatan *deep learning* seperti *Long Short-Term Memory (LSTM)* yang jauh lebih berat secara komputasi [9], [12], maupun model *Autoregressive Integrated Moving Average (ARIMA)* konvensional yang tidak mampu menangkap struktur musiman secara memadai [9]. Tahap terakhir, yang menjadi inti studi, adalah perancangan dan eksekusi eksperimen simulasi komparatif yang disusun secara rinci untuk mengevaluasi kedua strategi kontrol berdasarkan metrik kinerja khusus, yaitu efisiensi aktuator dan stabilitas lingkungan [7], [10].



Gambar 1. Alur Kerja Metodologi Penelitian

#### A. Akuisisi dan Pra-pemrosesan Data

Data *time-series* kelembaban relatif (RH) dikumpulkan selama periode 30 hari menggunakan sistem pemantauan IoT berbasis mikrokontroler *NodeMCU ESP8266*. Pembacaan data dilakukan melalui sensor *DHT11* yang ditempatkan di dalam terarium *Tropidolaemus sp.*. Berdasarkan interval pengambilan data, jumlah sampel mentah (*raw data*) diperkirakan mencapai sekitar 14.400 *data point* (diasumsikan 30 hari  $\times$  480 sampel/hari, dengan interval pembacaan setiap 3 menit). Ini memberikan transparansi data yang memadai untuk mengukur volume data yang dikumpulkan. Arsitektur perangkat keras yang digunakan ditunjukkan pada Gambar 2.




Gambar 2. Diagram Kerangka Kerja Sistem Pengumpul Data

a. Justifikasi dan Keterbatasan Akuisisi Data

Meskipun sensor DHT11 dan mikrokontroler NodeMCU memberikan solusi yang *cost-effective* untuk implementasi sistem IoT, perlu diakui bahwa akurasi sensor tersebut memiliki keterbatasan, yaitu  $\pm 5\%$  RH (sesuai spesifikasi DHT11). Keterbatasan ini dipertimbangkan dalam interpretasi hasil, di mana dinamika lingkungan diperlakukan sebagai data yang berpotensi mengandung sensor noise. Selain itu, studi ini hanya berfokus pada parameter kelembaban. Variabel lain seperti suhu dan ventilasi sebenarnya memiliki peran penting dalam kestabilan lingkungan, namun tidak dimasukkan ke dalam logika kontrol prediktif agar model tetap ringkas serta berfokus pada pembuktian konsep efisiensi sistem.

b. Justifikasi dan Keterbatasan Akuisisi Data

Data mentah terlebih dahulu melalui tahap pra-pemrosesan yang mencakup: (1) penanganan *missing values* melalui interpolasi, dan (2) *resampling* ke interval per jam untuk mengurangi *noise* dan menonjolkan pola musiman. Pola musiman harian dengan siklus 24 jam ditunjukkan pada Gambar 3, yang menjadi dasar pemilihan model SARIMA.



Gambar 3. Visualisasi Data Kelembapan per Jam Setelah Tahap Pra-pemrosesan

Untuk menjamin validitas pemodelan *time-series*, data yang telah diproses kemudian diuji tingkat stasioneritasnya menggunakan uji statistik formal, yaitu *Augmented Dickey-Fuller (ADF)*. Hasil uji *ADF* ini mengonfirmasi non-stasioneritas data, yang kemudian menentukan orde *differencing* ( $d$  dan  $D$ ) yang diperlukan sebelum pemodelan SARIMA dilakukan.

B. Pengembangan Model Peramalan SARIMA

Untuk membangun "otak" dari kontroler prediktif, sebuah model peramalan *time-series* dikembangkan dengan metode SARIMA. Metode ini dipilih karena kemampuannya yang telah terbukti dalam menangani data dengan pola tren dan musiman [9], [11]. Secara formal, model SARIMA  $(p,d,q)(P,D,Q)m$  dapat direpresentasikan dengan persamaan matematis berikut [11]:

$$\Phi_p(B)\Phi_p(B^m)(1-B)^d(1-B^m)^D Z_t = \Theta_q(B)\Theta_q(B^m)\epsilon_t \quad (1)$$

Pada persamaan di atas,  $Z_t$  merepresentasikan data *time-series* kelembaban pada waktu  $t$ , dan  $\epsilon_t$  adalah komponen *error* atau *white noise* yang tidak dapat diprediksi. Operator  $B$  adalah operator *backshift* yang menandakan nilai pada waktu sebelumnya (misalnya,  $B Z_t = Z_t - 1$ ). Komponen  $\Phi(B)$  dan  $\Theta(B)$  masing-masing adalah polinomial untuk bagian *Autoregressive (AR)* dan *Moving Average (MA)* non-musiman, sementara  $\Phi(B^m)$  dan  $\Theta(B^m)$  adalah untuk bagian musiman. Parameter  $d$  dan  $D$  merepresentasikan orde dari proses *differencing* yang bertujuan untuk membuat data menjadi stasioner, dan  $m$  adalah panjang dari satu siklus musiman (dalam kasus ini, 24 jam).

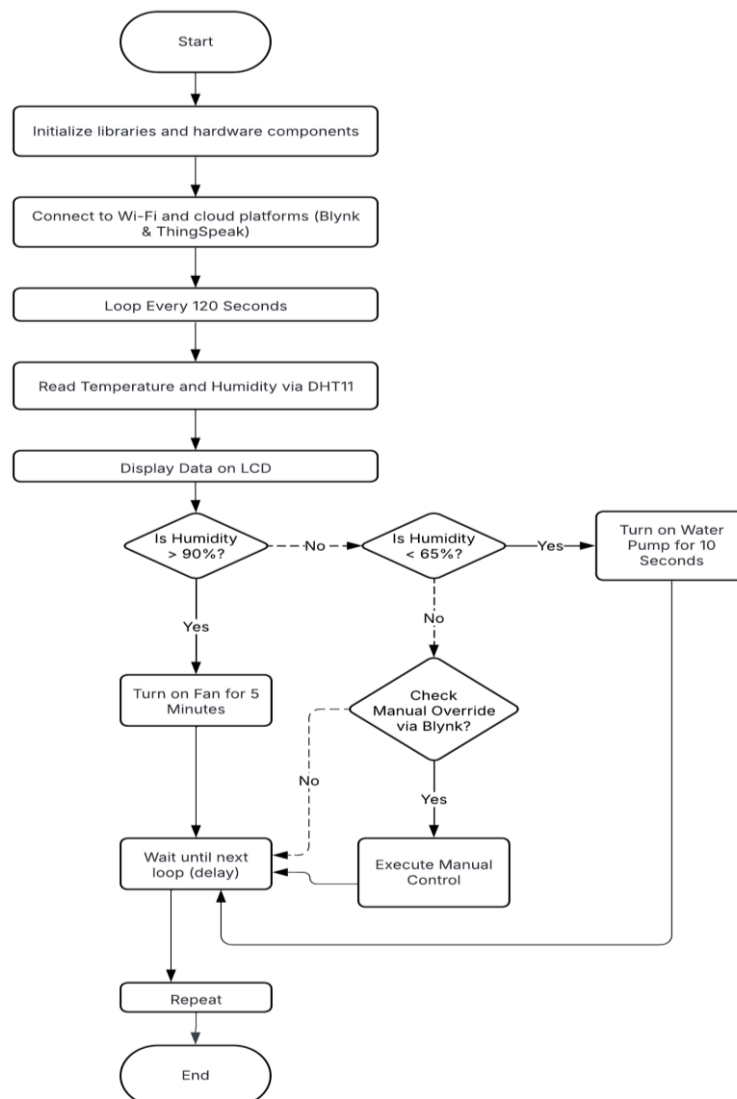
Proses pengembangan model secara praktis mengikuti langkah-langkah terstruktur. Pertama, dilakukan analisis data eksploratif untuk mengonfirmasi pola musiman harian pada data. Kedua, dilakukan pencarian parameter  $(p,d,q)(P,D,Q)m$  yang optimal melalui metode pencarian sistematis (*grid search*). Proses ini mengevaluasi berbagai kombinasi parameter dan memilih satu set parameter yang menghasilkan nilai *Akaike Information Criterion (AIC)* terendah, sebuah pendekatan standar dalam studi komparatif untuk pemilihan model [8]. Ketiga, setelah parameter terbaik ditentukan, model akhir dilatih menggunakan data 28 hari pertama sebagai set pelatihan. Terakhir, kapabilitas prediktif dari model yang telah dilatih

divalidasi dengan menguji kinerjanya pada data 2 hari terakhir sebagai set pengujian, sebuah kerangka validasi yang umum digunakan [12]. Akurasi model diukur secara kuantitatif menggunakan metrik *Root Mean Squared Error* (RMSE) untuk memastikan model memiliki kemampuan prediksi yang andal sebelum diimplementasikan pada tahap simulasi.

### C. Desain Eksperimen Simulasi Komparatif

Eksperimen inti dalam penelitian ini dirancang sebagai sebuah simulasi komparatif yang dikembangkan menggunakan *Python* (versi 3.x), dengan memanfaatkan pustaka utama *Pandas* dan *NumPy* untuk manipulasi data, serta *Statsmodels* dan *Scikit-learn* untuk pemodelan *time-series* dan statistik. Tujuan utama eksperimen ini adalah mengevaluasi dua strategi kontrol dalam lingkungan virtual yang identik. Lingkungan simulasi dibangun berdasarkan keseluruhan data kelembapan per jam yang berfungsi sebagai *ground truth* untuk merepresentasikan dinamika alami kondisi lingkungan.

1. Kontroler reaktif beroperasi menggunakan logika ambang batas sederhana. Pada pendekatan ini, pompa (aktuator) hanya diaktifkan ketika nilai kelembapan aktual ( $RH_t$ ) turun di bawah batas minimum yang ditetapkan, yaitu 65% RH. Pendekatan berbasis ambang batas ini umum digunakan dalam berbagai sistem otomasi IoT.
2. Kontroler prediktif memanfaatkan hasil peramalan dari model *SARIMA* untuk mengaktifkan pompa secara proaktif. Pompa akan diaktifkan apabila kelembapan yang diprediksi pada waktu berikutnya ( $t+1$ ) diperkirakan akan turun di bawah batas minimum 65% RH. Pendekatan berbasis prediksi ini memungkinkan sistem mengambil tindakan sebelum kondisi lingkungan mencapai titik kritis.



Gambar 4. Diagram Alur Logika Sistem

Diagram pada Gambar 4 mengilustrasikan alur pemrosesan data, pengambilan keputusan berbasis ambang batas, dan aktivasi aktuator. Secara spesifik, diagram tersebut menunjukkan bagaimana kontroler mengevaluasi kelembapan: jika nilai berada di bawah batas minimum, maka perintah aktivasi pompa dikeluarkan. Dalam simulasi ini, logika tersebut diimplementasikan secara langsung untuk Kontroler Reaktif, dan diadaptasi untuk Kontroler Prediktif dengan mengganti nilai kelembapan aktual ( $RH_t$ ) menjadi nilai ramalan ( $RH_{t+1}$ ) pada titik pengambilan keputusan yang sama.

Lingkungan simulasi dibangun berdasarkan satu set data *ground truth* sepanjang 30 hari, dengan asumsi bahwa setiap aktivasi pompa meningkatkan kelembapan sebesar 15 poin. Asumsi ini merupakan bentuk penyederhanaan yang tidak sepenuhnya merepresentasikan dinamika fisik sesungguhnya, termasuk laju penurunan kelembapan, kecepatan difusi, maupun volume terarium. Selain itu, simulasi dijalankan pada satu kondisi lingkungan tunggal tanpa variasi skenario seperti fluktuasi ekstrem atau perubahan lingkungan yang berbeda, sehingga tingkat generalisasi hasil terhadap kondisi operasional nyata yang lebih beragam menjadi terbatas. Meskipun demikian, pendekatan ini tetap dianggap memadai karena memungkinkan fokus evaluasi diarahkan pada perbandingan logika kontrol yang menjadi tujuan utama eksperimen.

Kinerja kedua kontroler kemudian dievaluasi menggunakan dua metrik utama :

1. Stabilitas Lingkungan: Diukur berdasarkan persentase waktu ketika kelembapan berhasil dipertahankan dalam rentang ideal 65%–90% RH.
2. Efisiensi Aktuasi: Ditentukan melalui jumlah total aktivasi pompa, yang menjadi indikator langsung konsumsi energi serta potensi keausan aktuator.

Selain evaluasi kuantitatif tersebut, analisis kualitatif juga dilakukan dengan meninjau *response time* kedua kontroler dan mempertimbangkan implikasi konsumsi daya, mengingat frekuensi aktivasi berperan penting dalam menentukan efisiensi operasional sistem IoT.

### III. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil dari implementasi metodologi yang telah diuraikan pada bab sebelumnya. Penyajian hasil dibagi menjadi dua bagian utama. Bagian pertama memaparkan hasil dari proses pengembangan dan validasi model peramalan *SARIMA*. Bagian kedua, yang merupakan inti dari temuan penelitian, menyajikan hasil dari eksperimen simulasi komparatif antara kontroler reaktif dan prediktif. Setiap hasil yang disajikan akan diikuti dengan pembahasan untuk menginterpretasikan makna dan implikasinya.

#### A. Hasil Pengembangan Model Peramalan *SARIMA*


Proses pengembangan model prediktif dimulai dengan pencarian parameter *SARIMA* yang optimal menggunakan metode *grid search* dengan data latih. Berdasarkan kriteria nilai *AIC* terendah, ditemukan konfigurasi model yang paling sesuai untuk memodelkan data kelembapan terarium. Parameter terpilih dirangkum pada Tabel 1.

TABEL 1  
PARAMETER OPTIMAL MODEL *SARIMA*

Parameter	Orde
Non-Musiman (p,d,q)	(1, 1, 1)
Musiman (P,D,Q,m)	(0, 1, 1, 24)
AIC	5086.67

Pemilihan parameter optimal dilakukan melalui pendekatan *grid Search* yang menguji setiap kombinasi *hyperparameter* *SARIMA*. Rentang *hyperparameter* yang diuji meliputi: orde non-musiman  $p \in [0,1]$ ,  $d \in [1]$ ,  $q \in [0,1]$ ; serta orde musiman  $P \in [0,1]$ ,  $D \in [1]$ ,  $Q \in [0,1]$  ( $m=24$ ). Kombinasi ini menghasilkan total  $X$  iterasi percobaan. Kriteria optimalitas didefinisikan secara kuantitatif sebagai model yang menghasilkan nilai *AIC* terendah. *AIC* adalah metrik yang menyeimbangkan *goodness of fit* model dengan kompleksitasnya, sehingga parameter  $(1,1,1) \times (0,1,1)^{24}$  yang terpilih adalah yang paling efisien dalam menjelaskan data.

Dengan menggunakan parameter tersebut, model dilatih dan kemudian divalidasi kemampuannya untuk melakukan peramalan pada data uji (data 48 jam terakhir). Gambar 5 menunjukkan perbandingan visual antara nilai kelembapan aktual dengan nilai yang diprediksi oleh model *SARIMA* pada periode pengujian. Secara visual, terlihat bahwa hasil prediksi mampu mengikuti pola dan dinamika data asli dengan sangat baik, menunjukkan kapabilitas model dalam menangkap tren dan musiman harian dari data, sebuah hasil yang konsisten dengan aplikasi *SARIMA* pada data lingkungan lainnya [9], [11].



Gambar 5. Validasi Kinerja Prediksi Model SARIMA pada Data Uji

Validitas model dievaluasi secara kuantitatif melalui Tabel 2 dan Tabel 3, yang menunjukkan bahwa nilai *RMSE* yang diperoleh adalah 10.33. Nilai ini merepresentasikan tingkat kesalahan prediksi rata-rata sekitar sepuluh persen kelembapan relatif. Untuk spesies reptil yang sensitif seperti *Tropidolaemus* sp., deviasi sebesar ini dapat dianggap cukup signifikan karena rentang kelembapan ideal hanya berada pada kisaran 65% hingga 90% RH. Besarnya kesalahan prediksi ini memiliki implikasi langsung terhadap kinerja logika kontrol prediktif, terutama ketika prediksi bersifat terlalu optimis atau terlalu pesimis sehingga berpotensi menimbulkan fenomena *overshoot*. Implikasi tersebut dianalisis lebih lanjut pada tahap simulasi guna memahami mekanisme dampaknya terhadap perilaku aktuasi sistem.

Selain itu, perlu diperhatikan bahwa *horizon* validasi model hanya mencakup periode 48 jam, sehingga ruang evaluasi yang digunakan bersifat jangka pendek. Meskipun rentang ini cukup untuk menguji keandalan model dalam menghasilkan prediksi cepat ( $t+1$ ) yang diperlukan oleh kontroler, keterbatasan ini membatasi generalisasi kinerja model terhadap kondisi lingkungan ekstrem atau pola musiman jangka panjang. Terkait ketiadaan model pembanding seperti *Holt-Winters* atau pendekatan berbasis *machine learning*, keputusan ini didasarkan pada fokus penelitian yang menitikberatkan pada pembuktian konsep *trade-off* antara strategi kontrol prediktif dan reaktif. *SARIMA* sejak awal dipilih karena efisiensi komputasinya yang lebih sesuai dengan karakteristik *edge computing* pada perangkat IoT, sehingga perbandingan *end-to-end* dengan model yang lebih kompleks dan intensif sumber daya tidak menjadi prioritas dalam konteks penelitian ini.

TABEL 2  
RINGKASAN STATISTIK HASIL PELATIHAN MODEL SARIMA

Parameter Model	Nilai	Parameter Diagnostik	Nilai
Variabel Dependen:	humidity	Ljung-Box (Q):	0
Model:	SARIMAX(1,1,1)x(0,1,1,24)	Prob(Q):	0.98
Jumlah Observasi:	672	Jarque-Bera (JB):	1.16
Tanggal Sampel:	15-04-2025 – 12-05-2025	Prob(JB):	0.56
AIC:	4958.483	Heteroskedasticity (H):	1.03
BIC:	4976.372	Prob(H):	0.84
HQIC:	4965.423	Skew:	-0.03
	0.0673	Kurtosis:	2.8

Hasil uji diagnostik yang disajikan pada Tabel 2 menguatkan bahwa model *SARIMA* valid secara statistik. Uji *Ljung-Box* menghasilkan probabilitas sebesar 0.98 yang menandakan tidak adanya autokorelasi pada sisaan, sementara uji *Jarque-Bera* dengan probabilitas 0.56 menunjukkan bahwa sisaan terdistribusi normal. Kondisi ini memastikan bahwa sisaan dapat dikategorikan sebagai *white noise*, sehingga model telah berhasil menangkap pola yang terdapat pada data secara memadai. Analisis lebih lanjut terhadap koefisien pada Tabel 3 menunjukkan bahwa komponen *Moving Average*, yaitu *ma.L1* dan *ma.S.L24*, memiliki pengaruh yang sangat signifikan secara statistik terhadap prediksi model ( $P > |z| = 0.000$ ). Signifikansi tersebut menegaskan pentingnya mekanisme koreksi kesalahan baik pada komponen non-musiman maupun musiman dalam menghasilkan estimasi kelembapan yang akurat pada lingkungan terarium.

TABEL 3  
HASIL SIMULASI KOMPARATIF KINERJA KONTROLER

Koefisien Model	Estimasi (coef)	Std. Error	z-value	P> z	Interval Kepercayaan 95%
ar.L1	0.0673	0.036	1.858	0.063	[-0.004, 0.138]
ma.L1	-0.9908	0.010	-95.572	0.000	[-1.011, -0.970]
ma.S.L24	-0.9496	0.040	-23.697	0.000	[-1.028, -0.871]
sigma2	112.1022	7.208	15.553	0.000	[97.975, 126.229]


B. Hasil Simulasi Komparatif Kinerja Kontroler

Setelah model prediktif divalidasi, eksperimen simulasi komparatif dijalankan selama 30 hari untuk mengevaluasi kinerja antara kontroler reaktif (*baseline*) dan kontroler prediktif (*proposed*). Hasil kuantitatif dari perbandingan kedua strategi kontrol tersebut disajikan pada Tabel 4.

TABEL 4  
PERBANDINGAN KINERJA AKHIR KONTROLER DAN PREDIKTIF

Metrik Kinerja	Kontroler Reaktif (Threshold)	Kontroler Prediktif (SARIMA)
Stabilitas (% Waktu dalam Rentang Ideal)	75.94%	67.04%
Total Aktivasi Pompa	157 kali	83 kali

Dari tabel tersebut, terungkap dua temuan utama. Pertama, dari segi efisiensi aktuasi, kontroler prediktif menunjukkan keunggulan yang signifikan, dengan jumlah aktivasi pompa hampir 50% lebih sedikit dibandingkan kontroler reaktif (83 vs 157 kali). Ini menunjukkan bahwa kemampuan prediksi berhasil mengurangi aktivasi yang tidak perlu secara drastis. Temuan kedua yang menarik adalah dari segi stabilitas lingkungan, di mana kontroler reaktif secara tak terduga menunjukkan persentase waktu dalam rentang ideal yang lebih tinggi. Untuk memahami dinamika di balik angka-angka ini, perilaku kedua kontroler selama simulasi divisualisasikan pada Gambar 6.



Gambar 6. Hasil Simulasi Komparatif Kontroler Reaktif vs. Prediktif

Gambar 6 mengilustrasikan perbedaan perilaku yang fundamental. Kontroler reaktif (biru putus-putus) terlihat sering beraksi, menyebabkan pola "gigi gergaji" di mana kelembapan terus-menerus "memantul" dari batas bawah 65%. Sebaliknya, kontroler prediktif (orange) beraksi lebih jarang, namun setiap aksinya menyebabkan lonjakan kelembapan yang signifikan. Lonjakan ini seringkali menyebabkan fenomena *overshoot*, di mana kelembapan melampaui batas atas 90%, yang menjadi penyebab utama rendahnya skor stabilitas kontroler prediktif dalam simulasi ini.

Fenomena *overshoot* ini mengungkap *trade-off* fundamental antara efisiensi aktuasi dan stabilitas lingkungan. Meskipun simulasi membuktikan bahwa pendekatan prediktif mampu meminimalkan jumlah aktuasi, pendekatan ini tidak serta-merta menjamin kestabilan kelembapan jika mekanisme aksi yang digunakan terlalu sederhana dan tidak mempertimbangkan dinamika fisik sistem secara realistis. Perlu dicatat pula bahwa temuan ini masih bersifat studi kasus karena seluruh hasil diperoleh dari satu skenario simulasi selama tiga puluh hari. Dengan demikian, generalisasi masih terbatas, dan validasi

eksternal pada lingkungan nyata diperlukan untuk menguji ketahanan model secara menyeluruh. Selain itu, uji sensitivitas terhadap parameter aksi dan logika kontrol diperlukan untuk memahami batas operasional sistem serta potensi perbaikan pada desain kontrol prediktif.

### C. Implikasi Kinerja: Analisis Trade-Off antara Efisiensi dan Stabilitas

Hasil penelitian ini memberikan wawasan bernuansa mengenai penerapan kontrol cerdas dalam sistem IoT, menggarisbawahi adanya *trade-off* fundamental antara efisiensi dan stabilitas. Kontroler prediktif menunjukkan keunggulan signifikan dalam efisiensi (mengurangi aktivasi pompa hingga 47%). Angka ini diperoleh dari perhitungan perbandingan jumlah aktivasi pompa antara Kontroler Reaktif (157 kali) dan Kontroler Prediktif (83 kali), sebagaimana dirangkum dalam Tabel 4. Pengurangan frekuensi aktuasi ini tidak hanya berimplikasi pada penghematan daya, tetapi juga berpotensi meningkatkan keandalan jangka panjang sistem dengan meminimalkan keausan komponen mekanis. Kemampuan model untuk mengantisipasi penurunan kelembapan memungkinkan sistem menghindari pola siklus "on/off" yang intens dan boros energi, yang merupakan ciri khas kontroler reaktif.

Kinerja model peramalan SARIMA yang menjadi inti kontroler prediktif divalidasi secara kuantitatif melalui perbandingan beberapa kandidat hasil *grid search*, sebagaimana dirangkum pada Tabel 5.

TABEL 5  
KONFIGURASI HYPERPARAMETER OPTIMAL MODEL SARIMA

Konfigurasi SARIMA (p,d,q) x (P,D,Q)m	AIC	RMSE
(1, 1, 1) x (0, 1, 1) <sub>24</sub> (Optimal)	4958.483	10.33
(1, 1, 0) x (0, 1, 1) <sub>24</sub>	4965.111	10.45
(0, 1, 1) x (1, 1, 1) <sub>24</sub>	4972.902	11.05

Namun demikian, efisiensi yang tinggi ini tidak serta-merta diikuti oleh stabilitas lingkungan yang lebih baik. Validitas model peramalan, sebagaimana ditunjukkan oleh RMSE minimal pada Tabel 5 (yaitu 10.33), mengindikasikan bahwa masalah *overshoot* bukan disebabkan oleh kegagalan akurasi prediksi model SARIMA. Sebaliknya, hasil simulasi menunjukkan bahwa fenomena *overshoot* muncul akibat keterbatasan mekanisme aksi yang bersifat kaku, yaitu asumsi bahwa nilai kelembapan meningkat dalam jumlah tetap setiap kali pompa diaktifkan.

Dalam konteks aplikasi praktis *herpetokulturis*, *overshoot* memiliki implikasi biologis yang signifikan. Kelembapan yang melampaui 90% RH berpotensi menimbulkan risiko kesehatan serius bagi spesies sensitif seperti *Tropidolaemus* sp. Oleh karena itu, bagi pengguna akhir, stabilitas dan pencegahan *overshoot* perlu diprioritaskan dibandingkan efisiensi energi semata.

Berdasarkan analisis tersebut, penelitian ini menunjukkan bahwa mekanisme aksi kontroler prediktif perlu dimodifikasi menuju pendekatan yang lebih dinamis dan proporsional. Walaupun simulasi lanjutan tidak dilakukan, mitigasi dapat dimulai melalui penyetelan sederhana (*tuning*) atau penerapan kontrol proporsional sebelum beralih pada *Model Predictive Control* (MPC) yang lebih kompleks. Solusi tersebut perlu dipertimbangkan bersamaan dengan konsekuensi komputasi yang menyertainya. Kontroler reaktif memiliki kompleksitas yang sangat rendah, sedangkan kontroler prediktif berbasis SARIMA membutuhkan pemrosesan matematis yang lebih intensif sehingga meningkatkan kebutuhan daya komputasi dan latensi pada sistem *edge computing*. Implikasi dari temuan ini adalah bahwa penelitian lanjutan perlu berfokus pada integrasi model prediktif dengan mekanisme aksi yang adaptif dan proporsional untuk mencapai keseimbangan optimal antara efisiensi energi, stabilitas lingkungan, dan keamanan biologis.

## IV. SIMPULAN

Penelitian ini telah berhasil mengembangkan dan mengevaluasi kinerja strategi kontrol prediktif berbasis SARIMA, dengan membandingkannya terhadap strategi kontrol reaktif standar melalui eksperimen simulasi untuk manajemen iklim mikro dalam terarium. Hasil simulasi komparatif menunjukkan bahwa kontroler prediktif secara signifikan lebih unggul dalam hal efisiensi operasional, mampu mengurangi jumlah aktivasi aktuator hingga 47%. Namun, temuan ini juga mengungkap adanya *trade-off* krusial pada stabilitas, di mana mekanisme aksi yang kaku pada kontroler prediktif menyebabkan fenomena *overshoot*, sehingga lebih sering melampaui batas kelembapan ideal dibandingkan kontroler reaktif. Studi ini menyimpulkan bahwa keunggulan dalam peramalan proaktif tidak secara otomatis menjamin optimalitas sistem secara holistik; kecerdasan dalam prediksi harus bersinergi dengan mekanisme eksekusi aksi yang adaptif untuk mencapai performa terbaik, terutama mengingat risiko biologis yang ditimbulkan oleh *overshoot* bagi pengguna (*herpetokulturis*). Meskipun temuan ini memberikan bukti awal (*preliminary evidence*), perlu diakui bahwa hasilnya dibatasi oleh asumsi simulasi sederhana dan *horizon* data tunggal (30 hari), yang membatasi generalisasi, sekaligus menyoroti perlunya validasi eksternal dan uji sensitivitas parameter dalam penelitian lanjutan.

DAFTAR PUSTAKA

- [1] S. R. Prathibha, A. Hongal, and M. P. Jyothi, "IoT Based Monitoring System in Smart Agriculture," *Proceedings - 2017 International Conference on Recent Advances in Electronics and Communication Technology, ICRAECT 2017*, pp. 81–84, 2017.
- [2] A. R. Yanes, P. Martinez, and R. Ahmad, "Towards automated aquaponics: A review on monitoring, IoT, and smart systems," *Journal of Cleaner Production*, vol. 263, p. 121571, 2020.
- [3] H. T. Ng, Z. K. Tham, N. A. A. Rahim, A. W. Rohim, W. W. Looi, and N. S. Ahmad, "IoT-enabled system for monitoring and controlling vertical farming operations," *International Journal of Reconfigurable and Embedded Systems*, vol. 12, no. 3, pp. 453–461, 2023.
- [4] "(PDF) IOT based Automated Greenhouse Using Machine Learning Approach", Accessed: Jun. 18, 2025. [Online]. Available: [https://www.researchgate.net/publication/360919248\\_IOT\\_based\\_Automated\\_Greenhouse\\_Using\\_Machine\\_Learning\\_Approach](https://www.researchgate.net/publication/360919248_IOT_based_Automated_Greenhouse_Using_Machine_Learning_Approach)
- [5] M. Pyingkodi, K. Thenmozhi, M. Karthikeyan, T. Kalpana, S. Palarimath, and G. B. A. Kumar, "IoT based Soil Nutrients Analysis and Monitoring System for Smart Agriculture," *3rd International Conference on Electronics and Sustainable Communication Systems, ICESC 2022 - Proceedings*, pp. 489–494, 2022.
- [6] H. A. Alharbi and M. Aldossary, "Energy-Efficient Edge-Fog-Cloud Architecture for IoT-Based Smart Agriculture Environment," *IEEE Access*, vol. 9, pp. 110480–110492, 2021.
- [7] C. Thiagarajan and P. Samundiswary, "A Survey on Energy Efficient, Harvesting & Optimization Approaches in IoT system," *Proceedings - 2022 International Conference on Computing, Communication and Power Technology, IC3P 2022*, pp. 129–132, 2022.
- [8] F. Y. Dtissibe, A. A. A. Ari, H. Abboubakar, A. N. Njoya, A. Mohamadou, and O. Thiare, "A comparative study of Machine Learning and Deep Learning methods for flood forecasting in the Far-North region, Cameroon," *Sci. Afr.*, vol. 23, p. e02053, 2024.
- [9] R. Zhang *et al.*, "Comparison of arima and lstm in forecasting the incidence of hfmd combined and uncombined with exogenous meteorological variables in Ningbo, China," *Int. J. Environ. Res. Public Health*, vol. 18, no. 11, 2021.
- [10] L. Judijanto, "Performance Analysis of Distributed Database Management System for IoT in the Context of Smart Agriculture in Indonesia," *West Science Nature and Technology*, vol. 1, no. 02, pp. 55–63, 2023.
- [11] G. Li and N. Yang, "A Hybrid SARIMA-LSTM Model for Air Temperature Forecasting," *Adv. Theory Simul.*, vol. 6, no. 2, p. 2200502, 2023.
- [12] S. Siami-Namini, N. Tavakoli, and A. Siami Namin, "A Comparison of ARIMA and LSTM in Forecasting Time Series," *Proceedings - 17th IEEE International Conference on Machine Learning and Applications, ICMLA 2018*, pp. 1394–1401, 2018.
- [13] A. Benaboura, R. Bechar, W. Kadri, T. D. Ho, Z. Pan, and S. Sahmoud, "Latency-Aware and Energy-Efficient Task Offloading in IoT and Cloud Systems with DQN Learning," *Preprints*, 2025
- [14] M. Gleiser and S. Moro, "Implementation of an IoT-Based Water Quality Monitoring System for Aquaculture," *International Journal of Research Publication and Reviews*, vol. 4, no. 5, pp. 1449–1452, 2023.