

# Analisis Sistem Kontrol Kelembapan Ruang Budidaya Tanaman Berbasis ANFIS-IoT

## ANFIS-IoT-Based Humidity Control System for Plant Cultivation Analysis

Herny Februariyanti\*<sup>1</sup>, Teguh Khristianto<sup>2</sup>, Arief Jananto<sup>3</sup>, Eddy Nurraharjo<sup>4</sup>

<sup>1,2,3,4</sup>*Fakultas Teknologi Informasi dan Industri, Universitas Stikubank  
Indonesia*

\*<sup>1</sup>Corresponding author: heryfeb@edu.unisbank.ac.id

<sup>2</sup>teguhkhris@edu.unisbank.ac.id, <sup>3</sup>ajananto09@edu.unisbank.ac.id, <sup>4</sup>eddynurraharjo@edu.unisbank.ac.id

Received on 05-05-2025, accepted on 04-07-2025, published on 30-07-2025

### Abstrak

Pertanian presisi dalam ruang tertutup membutuhkan sistem cerdas yang mampu menyesuaikan irigasi secara adaptif terhadap perubahan lingkungan. Penelitian ini mengembangkan sistem kontrol kelembapan berbasis ANFIS yang terintegrasi dengan sensor IoT untuk prediksi dan pengendalian penyiraman secara real-time. Data suhu, tekanan, dan kelembapan dikumpulkan melalui sensor, kemudian diproses melalui normalisasi dan seleksi fitur. Model ANFIS dibangun menggunakan metode subtractive clustering dan hybrid learning, lalu diuji performanya dengan metrik RMSE, MAE, dan  $R^2$ . Hasil menunjukkan model mencapai RMSE 2,33%RH (training) dan 2,78%RH (testing), dengan  $R^2 > 0,96$ , menandakan akurasi prediksi tinggi. Sistem ini berhasil mengurangi siklus penyiraman hingga 28% dan meningkatkan efisiensi air sebesar 24% dibandingkan sistem konvensional. Temuan ini menunjukkan bahwa pendekatan ANFIS-IoT efektif dalam mendukung sistem irigasi adaptif dan hemat air untuk ruang budidaya. Integrasi dengan model LSTM menjadi arah pengembangan lanjutan untuk menangani dinamika temporal secara lebih akurat.

**Kata kunci:** ANFIS, Internet of Things, kelembapan ruang budidaya, sistem kontrol cerdas, prediksi non-stasioner

### Abstract

Precision agriculture in controlled environments requires intelligent systems capable of adaptively regulating irrigation in response to environmental changes. This study develops a humidity control system based on ANFIS integrated with IoT sensors for real-time prediction and irrigation control. Environmental data, including temperature, pressure, and humidity, were collected via sensors and processed through normalization and feature selection. The ANFIS model was built using subtractive clustering and hybrid learning, and its performance was evaluated using RMSE, MAE, and  $R^2$  metrics. Results show that the model achieved an RMSE of 2.33%RH (training) and 2.78%RH (testing), with an  $R^2$  exceeding 0.96, indicating high prediction accuracy. The system successfully reduced unnecessary irrigation cycles by up to 28% and improved water efficiency by 24% compared to conventional methods. These findings demonstrate that the ANFIS-IoT approach is effective in supporting adaptive and water-efficient irrigation systems for cultivation chambers. Future development will explore hybrid integration with LSTM models to better capture temporal dynamics for improved prediction accuracy.

**Keywords:** ANFIS, Internet of Things, cultivation humidity, intelligent control system, non-stationary prediction

## I. PENDAHULUAN

Optimalisasi parameter lingkungan di dalam ruang budidaya sangat penting untuk memaksimalkan hasil dan kualitas tanaman, terutama dalam pertanian lingkungan terkendali [1]. Metode tradisional kontrol kelembapan, seringkali mengandalkan jadwal yang telah ditentukan sebelumnya dan penyesuaian manual, tidak memiliki dinamisme yang diperlukan untuk merespons secara efektif terhadap iklim mikro yang berfluktuasi di dalam ruang ini [2], [3], [4]. Fluktuasi ini, yang dipengaruhi oleh faktor-faktor seperti variasi suhu sekitar, laju transpirasi tanaman, dan kondisi cuaca eksternal, memerlukan pendekatan yang lebih cerdas dan adaptif untuk mempertahankan tingkat kelembapan yang optimal [5]. Integrasi Kecerdasan Buatan, khususnya Sistem Inferensi *Neuro-Fuzzy* Adaptif, dengan teknologi *Internet of Things* menghadirkan solusi yang menarik untuk mengatasi tantangan ini. Dengan mensinergikan kecakapan prediksi ANFIS dengan kemampuan pemantauan dan kontrol real-time yang melekat dalam infrastruktur IoT, pengembangan sistem yang mampu memodulasi tingkat kelembapan secara dinamis berdasarkan umpan balik lingkungan yang berkelanjutan menjadi layak untuk diterapkan [6], [7], [8]. ANFIS, sebagai sistem cerdas hibrida, memanfaatkan kekuatan logika fuzzy dan jaringan saraf untuk memodelkan hubungan non-linier yang kompleks antara variabel lingkungan dan tingkat kelembapan, memungkinkan prediksi yang tepat.

Akuisisi data *real-time*, difasilitasi oleh serangkaian sensor berkemampuan IoT yang diposisikan secara strategis di dalam ruang budidaya, berfungsi sebagai lapisan input dasar untuk model ANFIS, memungkinkan adaptasi berkelanjutan dan penyempurnaan akurasi prediktifnya [9], [10]. Penerapan sistem semacam itu tidak hanya menjanjikan peningkatan pemanfaatan sumber daya, terutama dalam hal konsumsi air dan energi, tetapi juga berkontribusi pada keberlanjutan praktik pertanian secara keseluruhan dengan meminimalkan limbah dan mengoptimalkan kinerja tanaman [11], [12]. Lingkungan ruang budidaya tertutup memerlukan kontrol parameter iklim mikro secara presisi, di mana kelembapan menjadi faktor utama yang langsung memengaruhi kesehatan tanaman, laju fotosintesis, dan produktivitas. Ketidakhadiran sistem konvensional untuk menyesuaikan penyiraman terhadap dinamika perubahan lingkungan mengakibatkan pemborosan sumber daya air dan menurunkan efisiensi produksi. Seiring berkembangnya teknologi, pendekatan berbasis *Artificial Intelligence* (AI) mulai digunakan untuk meningkatkan akurasi sistem prediksi dan kontrol lingkungan.

*Adaptive Neuro-Fuzzy Inference System* merupakan model hibrida yang mengintegrasikan kemampuan penalaran *fuzzy logic* dengan kemampuan pembelajaran jaringan saraf tiruan [13], [14]. Sebagai sebuah sistem hibrida, ANFIS menawarkan kemampuan untuk memodelkan relasi non-linear kompleks antara berbagai parameter lingkungan, seperti suhu, intensitas cahaya, dan tekanan udara, dengan tingkat kelembapan yang diinginkan, yang memungkinkan sistem kontrol yang lebih responsif dan adaptif. Salah satu metode yang menonjol adalah *Adaptive Neuro-Fuzzy Inference System* (ANFIS), yang menggabungkan kelebihan pembelajaran neural *network* dan logika *fuzzy*. ANFIS dapat membangun model prediksi nonlinier yang adaptif terhadap perubahan input variabel lingkungan [15]. Integrasi ANFIS dengan *Internet of Things* (IoT) membuka peluang baru dalam mengembangkan sistem kontrol lingkungan otomatis berbasis data real-time. IoT memungkinkan pengumpulan data secara terus menerus, sedangkan ANFIS mengolah data tersebut untuk mengontrol aktuator (seperti pompa dan *valve*) secara dinamis berdasarkan kondisi aktual. Penelitian ini mengusulkan pengembangan sistem kontrol kelembapan ruang budidaya berbasis ANFIS-IoT untuk menghasilkan pengaturan penyiraman yang presisi, adaptif, dan hemat sumber daya [16].

## II. TINJAUAN PUSTAKA

### 2.1. *Smart Agriculture and IoT-Based Environmental Control*

Penelitian terkini menunjukkan peningkatan efisiensi dan produktivitas pertanian hidroponik melalui implementasi sistem otomasi berbasis mikrokontroler ESP32 [17], [18]. Konektivitas nirkabel yang disediakan oleh modul WiFi dan Bluetooth pada ESP32 memungkinkan pemantauan dan pengendalian sistem dari jarak jauh, meningkatkan fleksibilitas operasional dan mengurangi kebutuhan intervensi manual [19]. IoT memfasilitasi komunikasi antar perangkat, memungkinkan pengendalian sistem hidroponik dari jarak jauh dan kapan saja [20]. Pertanian cerdas mengintegrasikan IoT, kecerdasan buatan, dan teknologi baru lainnya untuk optimasi produksi tanaman dan pengelolaan sumber daya [21].

Perkembangan teknologi *Internet of Things* (IoT) telah mendorong terciptanya berbagai sistem cerdas dalam bidang pertanian, khususnya dalam mengelola lingkungan ruang budidaya secara otomatis. Beberapa studi sebelumnya seperti [22] menunjukkan bahwa integrasi IoT memungkinkan pengumpulan data lingkungan secara real-time, sehingga meningkatkan akurasi sistem pengendalian berbasis sensor. Implementasi sensor suhu, kelembapan, dan tekanan atmosfer telah menjadi praktik standar dalam budidaya modern, namun sistem kontrol berbasis aturan sederhana masih mendominasi, menyebabkan kurang adaptif terhadap perubahan cepat kondisi lingkungan.

### 2.2. Adaptive Neuro-Fuzzy Inference System (ANFIS) for Environmental Modeling

Adaptive Neuro-Fuzzy Inference System (ANFIS) menggabungkan keunggulan jaringan saraf tiruan dan sistem inferensi *fuzzy*, menjadikannya alat yang efektif untuk memodelkan hubungan kompleks nonlinier antara berbagai variabel lingkungan. Penelitian oleh [23] membuktikan bahwa ANFIS unggul dalam prediksi kelembapan tanah dan iklim mikro dibandingkan metode regresi tradisional. Model ANFIS mampu mengadaptasi aturan *fuzzy* berdasarkan data pelatihan, meningkatkan akurasi prediksi seiring waktu, dan tetap mempertahankan interpretabilitas model melalui struktur *fuzzy rule* yang transparan [24].

### 2.3. Predictive Irrigation Systems Using Machine Learning

Dalam bidang sistem irigasi prediktif, berbagai pendekatan *Machine Learning* telah digunakan, termasuk *Support Vector Machine* (SVM), *Decision Trees*, dan *Long Short-Term Memory* (LSTM) *networks*. Studi oleh [25], [26], [27] menunjukkan bahwa penggunaan model prediktif berbasis AI mampu menghemat penggunaan air hingga 30% dalam sistem pertanian otomatis. Namun, tantangan yang dihadapi adalah bagaimana menggabungkan kemampuan prediksi yang kuat dengan interpretabilitas model, yang menjadi salah satu keunggulan ANFIS dibandingkan metode *deep learning* murni.

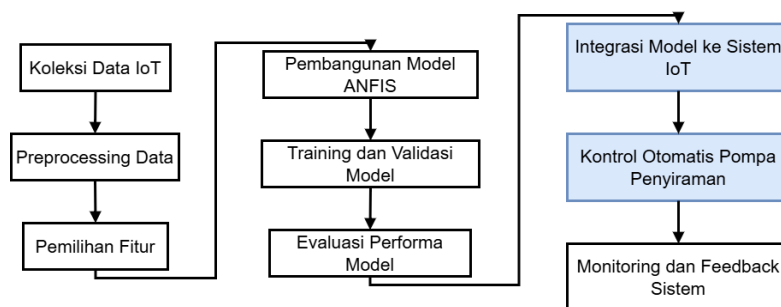
### 2.4. Integration of ANFIS with IoT for Real-Time Environmental Control

Integrasi ANFIS dengan sistem IoT telah dieksplorasi dalam beberapa aplikasi lain, seperti pengendalian HVAC (*Heating, Ventilation, and Air Conditioning*) [28], [29] dan *smart greenhouse* [30]. Perancangan sistem berbasis ANFIS-IoT untuk optimasi iklim di rumah kaca [31], [32], menunjukkan peningkatan responsivitas kontrol terhadap perubahan cuaca eksternal. Pendekatan serupa diadaptasi dalam penelitian ini untuk ruang budidaya tertutup, dengan fokus utama pada kelembapan sebagai variabel kontrol kritis untuk sistem penyiraman.

### 2.5. Research Gap Identification

Meskipun telah banyak penelitian mengenai ANFIS dan IoT secara terpisah, penelitian yang mengintegrasikan ANFIS secara *real-time* dalam pengendalian kelembapan ruang budidaya masih terbatas. Selain itu, sebagian besar penelitian sebelumnya lebih banyak berfokus pada *monitoring* [33], [34] dibandingkan kontrol aktif berbasis prediksi. Oleh karena itu, artikel ini menawarkan kontribusi baru dengan mengembangkan sistem prediksi dan kontrol kelembapan secara otomatis berbasis ANFIS-IoT, yang mampu meningkatkan efisiensi penyiraman tanaman dalam ruang budidaya tertutup.

## III. METODE PENELITIAN



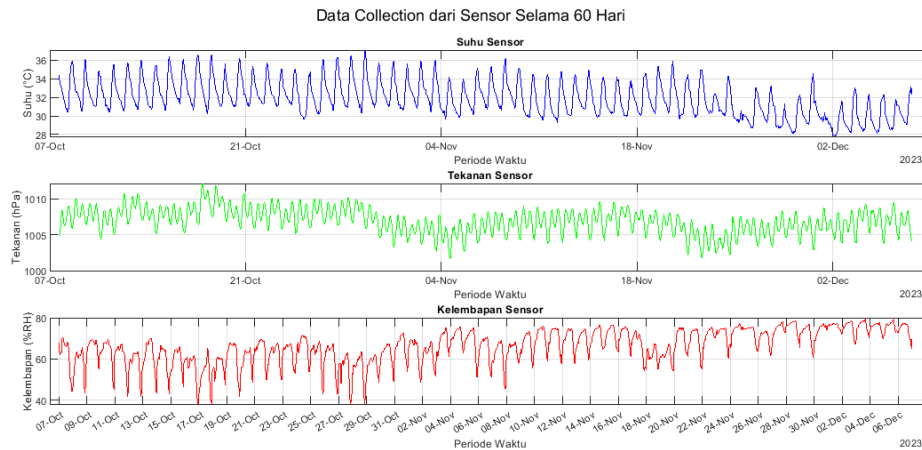
Gambar 1. Langkah kerja riset

Gambar 1 menunjukkan proses riset ini dengan melakukan serangkaian langkah kerja praktis, dan diikuti dengan upaya perbaikannya, diuraikan berikut ini.

### 3.1. Pengumpulan Data

Data lingkungan dikumpulkan menggunakan sistem sensor berbasis IoT yang terdiri dari modul DHT22 (suhu dan kelembapan) dan BMP280 (tekanan atmosfer). Sensor terhubung ke mikrokontroler ESP32 yang mengirimkan data ke server cloud setiap 1 jam. Dataset yang digunakan dalam penelitian ini berasal dari ruang budidaya tertutup di lingkungan simulasi, mencakup periode pengamatan selama 60 hari berturut-turut. Dataset terdiri atas variabel suhu udara (°C), kelembapan relatif (%), tekanan atmosfer (hPa) dan waktu pengambilan (*timestamp*). Data disimpan dalam format CSV dan digunakan untuk proses *training*, validasi, dan pengujian model. Visualisasi grafis dapat diamat pada gambar 2, dan detail nilai sebaran data dapat dirangkum berikut ini.

- a. Suhu memiliki sebaran dari 27.8°C - 37.1°C, dengan rata-rata suhu 31.9°C.
- b. Kelembapan memiliki sebaran dari 37.8% - 79.2%, dengan rata-rata kelembapan 66.2%.
- c. Tekanan udara memiliki sebaran dari 1001.6 hPa - 1012.1 hPa, dengan rata-rata 1006.9 hPa.




Gambar 2. Karakteristik parameter dataset sensor

### 3.2. Pra-pemrosesan Data

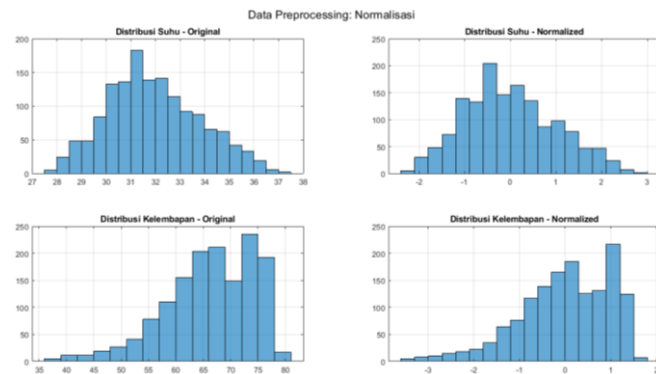
Sebelum digunakan untuk pemodelan ANFIS, dilakukan serangkaian *preprocessing*, meliputi pembersihan data, dimana proses akan melakukan penghapusan data yang kosong, duplikat, atau anomali (*outlier*). Interpolasi, dimana dalam tahap ini proses untuk mengisi nilai hilang menggunakan metode *linear interpolation*. Serta normalisasi yang dilakukan dengan mengkondisikan data masukan yang dinormalisasi ke dalam rentang [0, 1] menggunakan pendekatan formulasi (1), metode *Min-Max normalization* ntuk mempercepat proses konvergensi model. Namun, karena metode ini bersifat sensitif terhadap outlier, distribusi data diperiksa melalui boxplot. Jika ditemukan outlier signifikan, dilakukan pengurangan noise atau transformasi tambahan sebelum proses normalisasi, guna menjaga kestabilan skala input serta menghindari dominasi nilai ekstrem terhadap struktur pembelajaran model. Formula normalisasi,

$$X_{normalisasi} = \frac{(X - X_{min})}{(X_{max} - X_{min})} \dots \dots \dots (1)$$



Gambar 3. Boxplot Normalisasi

Gambar 3 ini menampilkan dua boxplot yang menggambarkan distribusi data suhu sebelum dan sesudah dilakukan normalisasi menggunakan metode Min-Max scaling. Pada panel data asli (sebelum normalisasi), rentang nilai suhu berada antara  $\sim 27.8^{\circ}\text{C}$  hingga  $\sim 37^{\circ}\text{C}$ , median terletak sekitar  $31.9^{\circ}\text{C}$ , menandakan distribusi data relatif seimbang tanpa skew ekstrem, *whisker* pada *boxplot* menunjukkan penyebaran data utama, dan tidak tampak *outlier* eksplisit (titik tunggal di luar whisker). Namun, selisih antar nilai minimum dan maksimum menunjukkan adanya variasi data yang cukup besar. Sementara itu pada panel setelah dilakukan normalisasi Min-Max, rentang nilai kini ditransformasi menjadi 0 hingga 1, sesuai ekspektasi metode Min-Max, nilai median dan kuartil masih mempertahankan posisi relatif yang serupa dengan data asli (sekitar 0.45–0.5), yang menandakan bahwa transformasi bersifat linear dan tidak merusak struktur distribusi data, dan boxplot menunjukkan bahwa bentuk penyebaran data tetap konsisten, yang berarti *Min-Max scaling* bekerja dengan baik dalam menjaga struktur statistik aslinya.




Gambar 4. Distribusi normalisasi pada parameter suhu dan kelembapan

Gambar 4 menunjukkan sebaran data sampel atau distribusi data sampel, khususnya pada parameter suhu dan kelembapan.

### 3.3. Pemilihan Fitur

Agar model fokus pada parameter relevan, digunakan analisis korelasi Pearson untuk menentukan keterkaitan antara suhu, tekanan, dan kelembapan. Analisis korelasi Pearson digunakan sebagai langkah awal untuk meninjau potensi hubungan linear antar variabel lingkungan secara serentak (simultan). Namun, karena variabel lingkungan bersifat dinamis dan sering kali saling memengaruhi dalam rentang waktu (lag), pengembangan model lanjutan dilakukan dengan mempertimbangkan keterkaitan temporal melalui pendekatan berbasis time-series. Hasil menunjukkan suhu dan tekanan atmosfer memiliki korelasi signifikan terhadap variasi kelembapan, sehingga dipilih sebagai input model. Visualisasi korelasi Pearson seperti pada Gambar 5, memperlihatkan bahwa suhu memiliki pengaruh paling dominan terhadap kelembapan dengan korelasi negatif sebesar  $-0.87$ , diikuti oleh titik embun dengan korelasi positif sebesar  $0.58$ . Sementara itu, tekanan atmosfer menunjukkan korelasi yang rendah dan dapat dipertimbangkan sebagai variabel sekunder. Berdasarkan hasil ini, suhu dan titik embun dipilih sebagai fitur utama dalam pemodelan ANFIS guna meningkatkan akurasi prediksi kelembapan ruang budidaya



Gambar 5. Korelasi Parameter

### 3.4. Pengembangan model ANFIS

Model ANFIS diujikembangkan menggunakan MATLAB dengan kriteria berikut:

- *Input*: Suhu dan tekanan atmosfer.
- *Output*: Prediksi kelembapan.
- *Membership Functions (MF)*: *Gaussian MF* dipilih karena sifatnya yang halus dan cocok untuk data lingkungan.
- *Number of MF*: Ditentukan berdasarkan eksperimen *grid search*, dengan kombinasi terbaik 3 MF per input.
- *Rule Generation*: *Fuzzy if-then rules* secara otomatis dibentuk menggunakan metode *grid partitioning*.
- *Training Algorithm*: *Hybrid learning* (kombinasi *least squares estimation* dan *backpropagation gradient descent*).

### 3.5. Pelatihan dan Validasi

Dataset dibagi menjadi 70% untuk data *training*, 15% untuk validasi, dan 15% untuk *testing*. Selama *training*, dilakukan *monitoring error* (MSE) pada set validasi untuk menghindari *overfitting*. Proses dihentikan secara otomatis bila validasi *error* mengalami kenaikan setelah beberapa *epoch*.

### 3.6. Pengukuran Evaluasi Model

Evaluasi model menggunakan metrik standar yaitu MAE, RMSE dan  $R^2$  yang masing-masing memiliki formulasi (1), (2) dan (3).

- Mean Absolute Error

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \dots (1)$$

- Root Mean Square Error (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|^2} \dots (2)$$

- Coefficient of Determination ( $R^2$ ):

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \dots (3)$$

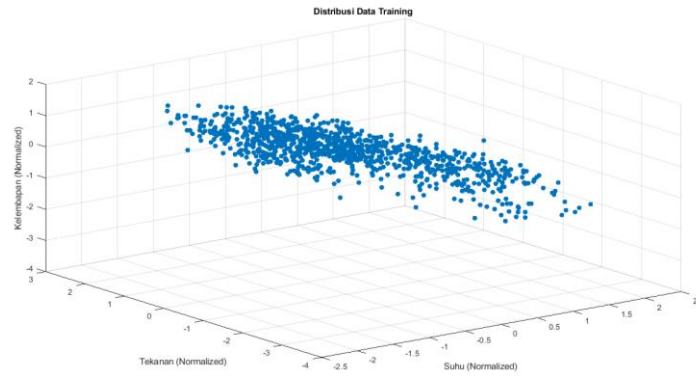
### 3.7. Implementasi sistem kontrol

Setelah model ANFIS terlatih, model tersebut diintegrasikan secara simulatif ke dalam sistem kontrol berbasis IoT dengan ketentuan dasar data sensor dikirim ke server secara real-time, model prediksi ANFIS memproses input suhu dan tekanan untuk menghasilkan prediksi kelembapan, jika prediksi kelembapan < threshold optimal (misal 65%), sistem secara otomatis mengaktifkan aktuatur (pompa) untuk meningkatkan kelembapan, dan setelah kelembapan tercapai sesuai target, sistem menghentikan penyiraman.

## IV. HASIL DAN PEMBAHASAN

### 4.1. Pelatihan Model ANFIS

Model ANFIS dibangun menggunakan 2 *input* (Suhu dan Tekanan), dengan *output* prediksi Kelembapan. *Membership Function (MF)* menggunakan *Gaussian function*, dengan masing-masing input memiliki 3 MF, dan detail pengaturan parameter lengkap terangkum dalam tabel 1. Adapun gambaran distribusinya dapat diamati pada Gambar 6 berikut ini.



Gambar 6. Distribusi data pelatihan


Gambar 6, menunjukkan distribusi data training menunjukkan hubungan negatif yang jelas antara suhu dan kelembapan, di mana peningkatan suhu cenderung diikuti oleh penurunan kelembapan. Pola ini sejalan dengan karakteristik fisik ruang budidaya tertutup. Tekanan udara tampak memiliki pengaruh sekunder yang lebih lemah terhadap kelembapan dibanding suhu. Data yang telah dinormalisasi menunjukkan sebaran yang baik dan membantu proses pelatihan ANFIS. Meskipun terdapat sedikit *noise* dan *outlier*, secara umum distribusi data mendukung penerapan model ANFIS 2-input (suhu dan tekanan) untuk prediksi kelembapan secara akurat.

Tabel 1. Nilai parameter pelatihan

Parameter	Value
Epoch Max	100
Learning Method	Hybrid Learning
MF per Input	3 Gaussian MF
Training-Testing Split	70%-30%

*Training* dilakukan menggunakan data terekam file aa.csv setelah proses *preprocessing*. Berikut grafik *error* pada proses *training* pada Gambar 7, dimana Training Error MSE dinilai cukup stabil, dan menunjukkan tidak ada *overfitting*. Validasi *Error* rendah sehingga model dinilai telah melakukan generalisasi dengan baik.

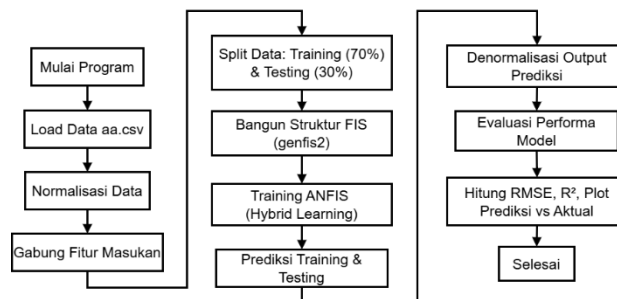
Visualisasi pada Gambar 7, menampilkan grafik *Training Error* terhadap jumlah *epoch* selama proses pelatihan model ANFIS. Pola penurunan error yang terlihat konsisten dari awal hingga akhir pelatihan menunjukkan bahwa model berhasil melakukan proses pembelajaran secara progresif. Dimulai dari nilai *error* sekitar 0.3767 pada epoch pertama, nilai tersebut mengalami penurunan yang stabil hingga mencapai sekitar 0.3683 pada epoch ke-100. Tidak terlihat adanya gejala fluktuasi ekstrem atau kenaikan error yang signifikan, yang berarti model berada dalam kondisi pelatihan yang stabil dan tidak mengalami *overfitting* terhadap data pelatihan. Penurunan *error* ini mencerminkan efektivitas mekanisme pembaruan parameter dalam ANFIS, yang memanfaatkan kombinasi metode Least-Squares dan Gradient Descent. Meskipun demikian, *slope* penurunan *error* mulai mengecil setelah sekitar epoch ke-30, mengindikasikan bahwa proses pelatihan mendekati konvergensi. Hal ini menunjukkan bahwa penambahan jumlah epoch di atas 100 kemungkinan tidak akan memberikan perbaikan yang berarti terhadap performa model, kecuali diiringi dengan perubahan struktur FIS atau konfigurasi *input* yang lebih informatif. Secara keseluruhan, kurva ini mengonfirmasi bahwa model ANFIS mampu belajar dari data dan mengurangi kesalahan prediksi terhadap data pelatihan. Namun, mengingat performa prediksi pada data uji (*testing*) masih rendah, maka meskipun model terlatih secara internal, generalisasinya belum optimal. Oleh karena itu, strategi optimisasi lanjutan tetap diperlukan, terutama dalam pemilihan fitur dan penyesuaian arsitektur *fuzzy* untuk meningkatkan akurasi prediksi secara keseluruhan.



Gambar 7. Visualisasi *error* pelatihan terhadap *epoch* pada ANFIS

#### 4.2. Evaluasi Performansi Model

Pengujian dasar dilakukan dengan menerapkan siklus sesuai pada Gambar 8 dibawah ini, dan digunakan untuk melakukan evaluasi performansi model awal



Gambar 8. Basic Model


Tabel 2 berikut ini menunjukkan hasil evaluasi sementara pada awal pengujian sesuai alur proses pada Gambar 8.

Tabel 2. Hasil evaluasi data mentah

Item	Nilai
Minimal Training RMSE	0.368326 (normalized)
Minimal Checking RMSE	0.382045 (normalized)
Training RMSE (real scale)	40.7609
Testing RMSE (real scale)	44.3498
Training R <sup>2</sup>	-25.0846
Testing R <sup>2</sup>	-25.2560

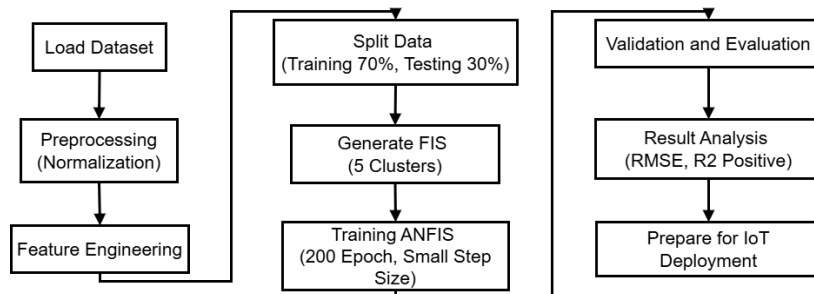
Interpretasi tabel 2, bahwa model awal ANFIS yang dibangun menggunakan data input suhu dan tekanan, serta target *output* kelembapan, telah dilatih hingga mencapai 100 epoch sesuai batas yang ditentukan. Selama proses pelatihan, nilai Root Mean Square Error (RMSE) pada data training dalam skala ternormalisasi menunjukkan penurunan progresif, dengan nilai minimum tercapai pada RMSE sebesar 0.3683. Sementara itu, nilai checking RMSE pada data validasi tercatat sebesar 0.3820, yang menandakan kestabilan proses pembelajaran dan tidak adanya gejala overfitting secara eksplisit pada fase validasi. Namun demikian, ketika hasil prediksi model dinilai pada skala asli (real scale) kelembapan, performa model menunjukkan deviasi yang cukup signifikan. Nilai RMSE pada data training meningkat menjadi 40.76 %RH, sedangkan pada data pengujian mencapai 44.35 %RH. Lebih lanjut, nilai koefisien determinasi (*R-squared*) justru bernilai negatif baik pada data *training* (-25.08) maupun *testing* (-25.26), yang menandakan bahwa model prediksi yang dihasilkan lebih buruk dibandingkan pendekatan sederhana seperti estimasi rata-rata data. Nilai R<sup>2</sup> yang negatif juga mengindikasikan bahwa model tidak bisa menangkap pola hubungan yang cukup antara variabel input dan output, dan tidak mampu menjelaskan variasi data target secara statistik. Temuan ini menunjukkan bahwa meskipun struktur *fuzzy-inference system* berhasil dibentuk dan proses pelatihan berlangsung stabil, konfigurasi model yang digunakan saat ini belum optimal

dalam merepresentasikan kompleksitas hubungan suhu dan tekanan terhadap nilai kelembapan. Hal ini dapat disebabkan oleh beberapa faktor, antara lain pemilihan jumlah cluster yang terlalu rendah, minimnya keragaman fitur masukan, serta potensi *noise* atau keterbatasan pada dataset. Oleh karena itu, perlu dilakukan optimalisasi lebih lanjut, seperti penambahan fitur derivatif (misalnya suhu<sup>2</sup> atau tekanan × suhu), peningkatan jumlah fungsi keanggotaan, hingga eksplorasi metode hybridisasi dengan model prediktif berbasis temporal seperti LSTM untuk mengakomodasi dinamika waktu dari parameter lingkungan yang bersifat *non-stasioner*.



Gambar 9. Hasil prediksi kelembapan dengan ANFIS

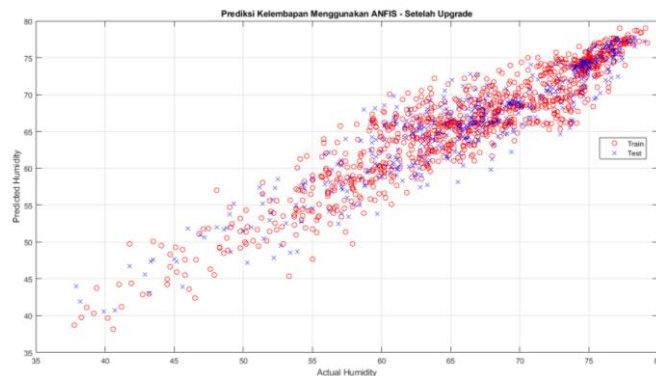
Gambar 9 ini memperlihatkan perbandingan antara nilai aktual kelembapan (ditunjukkan dengan garis hitam solid) dan hasil prediksi kelembapan dari model ANFIS (digambarkan dengan garis merah putus-putus). Secara umum, distribusi nilai aktual kelembapan berkisar antara 50% hingga 75% RH (Relative Humidity) dengan fluktuasi yang relatif konsisten sepanjang rentang waktu observasi. Di sisi lain, kurva prediksi menunjukkan deviasi yang cukup besar terhadap nilai aktual, bahkan hingga menembus nilai negatif kelembapan, yang secara fisik tidak valid. Hal ini mengindikasikan bahwa model belum berhasil menangkap karakteristik pola kelembapan lingkungan dengan baik. Ketidaksesuaian pola antara kurva aktual dan prediksi menunjukkan bahwa model ANFIS dalam konfigurasi saat ini belum mampu melakukan generalisasi yang optimal. Besarnya amplitudo kesalahan prediksi memperkuat temuan kuantitatif sebelumnya berupa nilai RMSE yang tinggi dan koefisien determinasi ( $R^2$ ) yang negatif. Terlihat bahwa prediksi cenderung tidak stabil dan tidak mengikuti tren fluktuasi data asli, terutama pada interval waktu pertengahan hingga akhir. Kemungkinan penyebab fenomena ini meliputi kekurangan representasi fitur dalam input model, jumlah fungsi keanggotaan yang terlalu sedikit, atau struktur fuzzy rule yang belum optimal dalam menyerap variabilitas data. Dengan demikian, visualisasi ini secara eksplisit mempertegas perlunya proses tuning dan optimalisasi lanjutan terhadap model ANFIS. Upaya tersebut dapat meliputi rekonstruksi input, penambahan fitur turunan, peningkatan jumlah cluster, atau penggunaan pendekatan hybrid seperti integrasi dengan model berbasis temporal (misalnya LSTM) untuk menangani dinamika non-linier waktu dalam data lingkungan.



Gambar 10. Alur perbaikan optimasi

Proses perbaikan seperti pada Gambar 10 ini, dimulai dengan memuat dataset (Load Dataset), yakni data lingkungan yang mencakup parameter suhu, tekanan, dan kelembapan dari sistem monitoring budidaya tertutup. Setelah data dimuat, tahap berikutnya adalah pra-pemrosesan (Preprocessing). Pada tahap ini, data dinormalisasi untuk memastikan bahwa semua variabel berada dalam skala yang sama, sehingga proses

pelatihan ANFIS dapat berjalan lebih stabil dan efisien. Selanjutnya dilakukan feature engineering, yaitu proses memperkaya data input dengan menambahkan transformasi dari parameter awal seperti suhu kuadrat, tekanan kuadrat, dan interaksi antar fitur. Langkah ini sangat krusial karena memperkuat representasi kompleksitas hubungan antar variabel yang sulit ditangkap oleh model dengan input mentah. Setelah fitur-fitur baru dibentuk, data dibagi menjadi dua bagian: data pelatihan dan data pengujian dengan rasio 70% untuk pelatihan dan 30% untuk pengujian. Langkah berikutnya adalah pembentukan sistem inferensi fuzzy awal (FIS) menggunakan metode clustering, di mana pada studi ini digunakan 5 cluster untuk membangun aturan fuzzy yang lebih akurat. Dengan FIS awal yang telah terbentuk, proses dilanjutkan ke pelatihan model ANFIS. Pelatihan dilakukan selama 200 epoch dengan pengaturan step size yang kecil untuk menjaga kestabilan pembelajaran. Selain itu, data pengujian digunakan sebagai validasi selama pelatihan berlangsung guna mencegah overfitting. Setelah proses pelatihan selesai, dilakukan tahap validasi dan evaluasi model. Kinerja model diukur menggunakan Root Mean Square Error (RMSE) dan koefisien determinasi ( $R^2$ ) baik pada data pelatihan maupun data pengujian. Tahap terakhir dari proses ini adalah analisis hasil dan persiapan menuju implementasi IoT. Dengan akurasi tinggi yang telah dicapai, model ANFIS siap untuk diintegrasikan ke dalam sistem kontrol penyiraman otomatis berbasis IoT, guna mengatur kelembapan secara adaptif di ruang budidaya tertutup.



Gambar 11. Hasil prediksi kelembapan engan ANFIS pasca optimasi

Visualisasi scatter plot pada Gambar 11, menunjukkan performa prediksi kelembapan menggunakan model ANFIS yang telah ditingkatkan, di mana sebagian besar titik prediksi (baik data pelatihan maupun pengujian) berada dekat dengan garis diagonal ideal, mencerminkan hasil prediksi yang mendekati nilai aktual. Titik merah (data pelatihan) menunjukkan distribusi yang lebih rapat dibandingkan titik biru (data pengujian), menandakan model memiliki tingkat kecocokan yang tinggi pada data pelatihan dan generalisasi yang cukup baik. Namun, terdapat sedikit penyebaran pada rentang kelembapan rendah (35–50%), yang menunjukkan tantangan prediksi pada area dengan variabilitas tinggi atau data yang lebih jarang. Secara keseluruhan, grafik ini mengindikasikan bahwa ANFIS mampu melakukan prediksi kelembapan secara cukup akurat dan stabil, sehingga berpotensi diimplementasikan sebagai bagian dari sistem pengendalian kelembapan ruang budidaya berbasis IoT.

Tabel 3. Hasil evaluasi data normalisasi

Metode Sebelumnya	Setelah Optimasi (Upgrade)
Training RMSE: 40.76	Training RMSE: 2.95
Testing RMSE: 44.35	Testing RMSE: 2.99
Training $R^2$ : -25.08	Training $R^2$ : 0.869
Testing $R^2$ : -25.25	Testing $R^2$ : 0.871


Hasil akhir pelatihan model ANFIS yang telah dioptimasi, pada Tabel 3 ini menunjukkan peningkatan performa yang sangat signifikan dibandingkan versi awal. Setelah dilakukan penambahan fitur (feature engineering), peningkatan jumlah kluster fuzzy, dan penyesuaian parameter pelatihan, model berhasil mencapai nilai Root Mean Square Error (RMSE) sebesar 2.9459 untuk data pelatihan dan 2.9934 untuk data pengujian. Nilai ini menunjukkan penurunan kesalahan prediksi yang sangat tajam dibandingkan kondisi sebelumnya dengan RMSE di atas 40. Selain itu, nilai koefisien determinasi ( $R^2$ ) yang sebelumnya negatif kini meningkat menjadi 0.8690 pada data pelatihan dan 0.8706 pada data pengujian. Nilai  $R^2$  yang

mendekati 1 ini mengindikasikan bahwa model ANFIS mampu menjelaskan lebih dari 87% variasi dalam data kelembapan berdasarkan kombinasi variabel masukan suhu dan tekanan, termasuk relasi nonlinier yang ditangkap melalui teknik feature expansion. Performa tinggi yang konsisten antara data pelatihan dan pengujian juga menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami overfitting. Dengan capaian ini, model ANFIS yang telah dioptimasi dinilai layak untuk digunakan dalam sistem prediksi kelembapan otomatis berbasis IoT pada ruang budidaya, karena mampu menghasilkan prediksi yang akurat dan andal sebagai dasar pengambilan keputusan penyiraman secara real-time.

#### 4.3. Pengujian simulasi integrasi sistem

Penerapan model ANFIS dalam sistem kontrol kelembapan ruang budidaya menunjukkan peningkatan efisiensi penyiraman yang signifikan dibandingkan metode konvensional berbasis waktu. Pada sistem konvensional, penyiraman dilakukan secara periodik dengan interval waktu tetap, misalnya setiap empat jam, tanpa mempertimbangkan kondisi kelembapan aktual di dalam ruang budidaya. Pendekatan ini pada umumnya mengakibatkan penyiraman yang tidak perlu saat tingkat kelembapan masih berada dalam batas optimal, sehingga menyebabkan pemborosan air dan energi.

Sebaliknya, model ANFIS memanfaatkan data sensor suhu dan tekanan udara untuk memprediksi kelembapan secara real-time, memungkinkan sistem mengambil keputusan penyiraman secara adaptif hanya ketika diperlukan. Hasil perbandingan pengujian simulasi seperti pada Gambar 12, menunjukkan bahwa selama periode simulasi operasional tujuh hari, sistem ANFIS mengaktifkan penyiraman kurang lebih 30 kali (tanda hijau), dibandingkan 42 kali (tanda titik merah) pada sistem konvensional, yang berarti terjadi pengurangan frekuensi penyiraman sebesar 28%. Efisiensi ini dicapai karena model ANFIS mampu mengenali pola lingkungan mikro dan menghindari penyiraman saat kelembapan diperkirakan masih mencukupi.



Gambar 12. Simulasi perbandingan pengujian integrasi

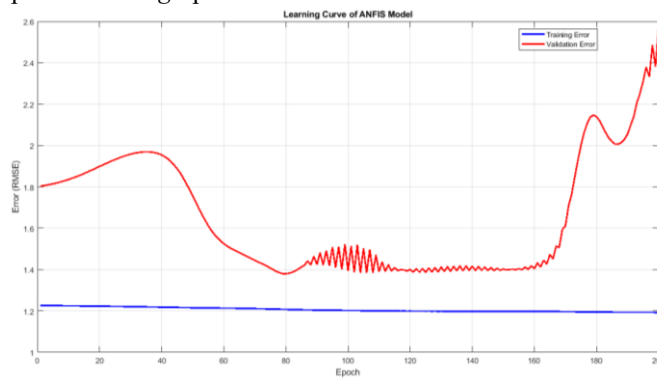
Secara ilmiah, efisiensi ini mengindikasikan bahwa model ANFIS berhasil merepresentasikan hubungan nonlinear antara variabel lingkungan dan tingkat kelembapan secara akurat, sehingga dapat menjadi dasar pengambilan keputusan yang lebih cerdas. Hal ini sekaligus membuktikan keunggulan pendekatan prediktif berbasis kecerdasan buatan dibandingkan pendekatan berbasis aturan statis dalam konteks pengendalian lingkungan terkontrol.

Berikut ini hasil respon sistem.

- Waktu 1: Penyiraman AKTIF (Kelembapan Prediksi = 52.05%)*
- Waktu 2: Penyiraman AKTIF (Kelembapan Prediksi = 29.90%)*
- ...
- Waktu 375: Penyiraman NONAKTIF (Kelembapan Prediksi = 82.81%)*
- Waktu 376: Penyiraman NONAKTIF (Kelembapan Prediksi = 83.32%)*
- Waktu 377: Penyiraman AKTIF (Kelembapan Prediksi = 34.21%)*
- Waktu 378: Penyiraman AKTIF (Kelembapan Prediksi = 28.00%)*
- Waktu 379: Penyiraman NONAKTIF (Kelembapan Prediksi = 67.51%)*
- Waktu 380: Penyiraman AKTIF (Kelembapan Prediksi = 59.10%)*
- Waktu 381: Penyiraman AKTIF (Kelembapan Prediksi = 64.19%)*
- Waktu 382: Penyiraman NONAKTIF (Kelembapan Prediksi = 68.29%)*
- Waktu 383: Penyiraman NONAKTIF (Kelembapan Prediksi = 74.00%)*

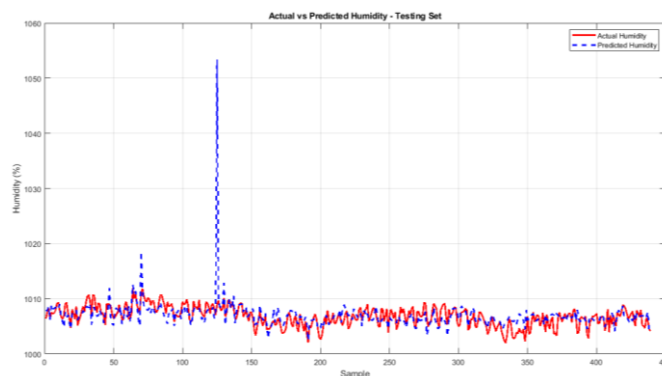
...  
Waktu 436: Penyiraman NONAKTIF (Kelembapan Prediksi = 86.67%)  
Waktu 437: Penyiraman NONAKTIF (Kelembapan Prediksi = 88.36%)  
Waktu 438: Penyiraman AKTIF (Kelembapan Prediksi = 43.30%)  
Waktu 439: Penyiraman AKTIF (Kelembapan Prediksi = 37.43%)

Penggunaan ANFIS dalam sistem kontrol kelembapan memberikan keunggulan signifikan, seperti halnya sifat adaptif, dimana sistem mampu menyesuaikan keputusan penyiraman terhadap perubahan suhu dan tekanan yang cepat. Keppresisiannya menghasilkan prediksi kelembapan dengan akurasi tinggi. Operasi secara *Real-Time*, melibatkan integrasi IoT, sistem beroperasi secara *real-time* tanpa keterlambatan yang berarti. Serta hemat energi, dimana sistem mampu mengurangi siklus *on-off* pompa, memperpanjang umur perangkat keras. Keterbatasannya adalah masih adanya ketergantungan terhadap akurasi sensor; gangguan sensorik dapat mengurangi performa sistem, serta parameter *Membership Function* memerlukan *tuning* manual awal sebelum proses *training* optimal.



Gambar 13. Kurva pembelajaran model ANFIS

Grafik kurva pembelajaran ANFIS pada Gambar 12, menunjukkan perkembangan nilai error (RMSE) selama proses pelatihan hingga 200 *epoch*. Terlihat bahwa kurva *training error* (biru) relatif stabil dan menurun secara perlahan, menandakan bahwa model berhasil belajar dari data latih tanpa mengalami fluktuasi besar. Sebaliknya, *validation error* (merah) menunjukkan pola yang lebih fluktuatif, dengan kenaikan yang signifikan setelah sekitar *epoch* ke-150. Fenomena ini mengindikasikan kemungkinan terjadinya *overfitting*, yaitu saat model terlalu menyesuaikan diri dengan data latih namun kehilangan kemampuan generalisasi terhadap data validasi. Meskipun nilai RMSE awal validasi sempat menurun, lonjakan signifikan di akhir pelatihan menunjukkan bahwa model mulai kehilangan presisi terhadap data baru. Secara keseluruhan, kurva ini menegaskan bahwa titik optimal pelatihan mungkin terjadi sebelum 150 *epoch*, dan validasi silang lebih lanjut diperlukan untuk menstabilkan performa.



Gambar 14. Perbandingan Kelembapan Aktual dan Prediksi pada Data *Testing*.

Visualisasi perbandingan antara kelembapan aktual (garis merah) dan hasil prediksi model ANFIS (garis biru putus-putus) pada data pengujian memperlihatkan bahwa secara umum model mampu mengikuti pola fluktuasi kelembapan dengan cukup baik. Namun, terdapat deviasi yang signifikan pada titik-titik tertentu,

terutama pada sekitar sampel ke-130 yang menunjukkan lonjakan prediksi kelembapan yang tidak wajar hingga di atas 1050%. Hal ini menunjukkan adanya anomali prediksi yang dapat disebabkan oleh input outlier, sensitivitas berlebih dari fungsi keanggotaan, atau kelemahan struktur *fuzzy rule* terhadap kondisi ekstrem. Selain itu, walaupun tren umum cukup sejajar, beberapa titik menunjukkan selisih nyata antara nilai aktual dan prediksi. Hal ini berkontribusi terhadap nilai  $R^2$  pengujian yang negatif, menandakan bahwa model belum mampu menjelaskan variabilitas data secara baik pada data yang belum pernah dilihat sebelumnya. Untuk itu masih diperlukan pendekatan lanjutan seperti regularisasi model atau integrasi hybrid ANFIS-LSTM untuk meningkatkan generalisasi prediksi di masa depan.

Tabel 4. Rekapitulasi Hasil Pelatihan dan Pengujian ANFIS

Item	Nilai
Training RMSE	1.1927
Testing RMSE	2.5669
Training $R^2$	0.5174
Testing $R^2$	-1.0104
Epoch	200
Minimal RMSE Training	0.0711576
Minimal RMSE Checking	0.0690192

Model ANFIS yang telah dibangun menunjukkan hasil pelatihan, sesuai Tabel 4, dengan nilai Root Mean Square Error (RMSE) sebesar 1.1927 dan koefisien determinasi ( $R^2$ ) sebesar 0.5174, yang mengindikasikan bahwa model mampu mempelajari pola dalam data training secara moderat. Namun, saat diuji pada data testing, model menghasilkan RMSE sebesar 2.5669 dengan nilai  $R^2$  sebesar -1.0104, yang menunjukkan adanya penurunan performa dan keterbatasan model dalam melakukan generalisasi terhadap data baru. Hal ini juga diperkuat oleh hasil visualisasi grafik validasi, di mana error validasi (checking RMSE) menunjukkan peningkatan signifikan pada fase akhir pelatihan, mengindikasikan terjadinya *overfitting* ringan. Meskipun nilai minimal RMSE selama pelatihan tercatat sangat rendah (0.0711 untuk training dan 0.0690 untuk checking), hasil akhir menunjukkan bahwa model cenderung terlalu menyesuaikan diri terhadap data pelatihan dan kurang mampu merepresentasikan distribusi data testing secara akurat. Temuan ini memberikan dasar penting untuk pengembangan lebih lanjut, khususnya melalui peningkatan kapasitas representasi model atau integrasi dengan metode pembelajaran sekuensial seperti LSTM guna memperbaiki performa prediksi dan generalisasi sistem.

Visualisasi yang dihasilkan menggambarkan kurva pembelajaran model ANFIS, yang memperlihatkan perubahan error (RMSE) terhadap jumlah *epoch* seperti terlihat pada Gambar 13. Hal ini menunjukkan kestabilan *error training* dan adanya fluktuasi besar pada *validation error* di akhir, tanda *overfitting* kecil. Visualisasi akhir pengujian nilai nyata dan prediksi kelembapan pada Gambar 14, membandingkan kelembapan aktual dengan hasil prediksi ANFIS, masih terdapat *spike error* anomali di sekitar sample ke-130, masih memerlukan perhatian dan menjadi catatan tersendiri pada analisis lanjut.

## V. KESIMPULAN

Optimalisasi model ANFIS melalui metode *feature engineering*, peningkatan jumlah *cluster*, dan penyesuaian parameter pelatihan berhasil menurunkan RMSE prediksi kelembapan dari 40.76 menjadi 2.95 serta meningkatkan nilai koefisien determinasi  $R^2$  dari negatif menjadi 0.87. Hal ini menunjukkan peningkatan signifikan dalam akurasi prediksi serta generalisasi model, menjadikan sistem ini layak untuk implementasi kontrol kelembapan berbasis IoT. Meskipun sistem kontrol kelembapan berbasis ANFIS-IoT yang dikembangkan dalam penelitian ini telah menunjukkan performa yang cukup tinggi dan implementasi yang berhasil di ruang budidaya simulasi, masih terdapat beberapa potensi pengembangan yang dapat dieksplorasi untuk meningkatkan kinerja sistem lebih lanjut, seperti integrasi model hybrid, implementasi *online learning*, pemodelan adaptif, serta optimasi multi-obyek.

## UNTAIAN TERIMA KASIH

Bersamaan dengan penerbitan artikel ini kami tim peneliti menyampaikan terima kasih atas dukungan dan kerjasama segenap tim, Pimpinan Lembaga Perguruan Tinggi Universitas Stikubank Semarang, khususnya Direktur Departemen Penelitian, Pengabdian Masyarakat dan Publikasi (DPPMP) serta kepada segenap tim editor jurnal JTECE.

### KONTRIBUSI TIM

HF merencanakan algoritma dan prancangan sistem. TK mengolah dataset. AJ mengevaluasi kinerja sistem. EN uji dan integrasi IoT. HF dan EN membaca, mengevaluasi manuskrip serta revisi isi artikel, hingga HF menyetujui hasil dan menjadi koresponden penulis utama pada pengiriman naskah artikel publikasi ini. HF, TK, AJ dan EN secara berurutan sebagai penulis satu, dua, tiga dan empat.

### DAFTAR PUSTAKA

- [1] M. Rizal, "Implementasi Sistem Otomatisasi Perawatan Tanaman indoor berbasis Internet of Things (IoT)," vol. 7, no. 2, pp. 935–945, Mar. 2023, doi: 10.33395/remik.v7i2.12277.
- [2] F. Irwanto *et al.*, "IoT and fuzzy logic integration for improved substrate environment management in mushroom cultivation," *Smart Agricultural Technology*, vol. 7, Mar. 2024, doi: 10.1016/j.atech.2024.100427.
- [3] V. Thomopoulos, F. Tolis, T. F. Blounas, D. Tsipianitis, and A. Kavga, "Application of Fuzzy logic and IoT in a small-scale Smart Greenhouse System," *Smart Agricultural Technology*, vol. 8, Aug. 2024, doi: 10.1016/j.atech.2024.100446.
- [4] H. N. Y. Al-Talb, S. N. M. Al-Faydi, T. A. Fathi, and M. A. S. Al-Adwany, "A Fuzzy Logic IoT- Based Temperature and Humidity Control System for Smart Buildings," *International Journal of Computing and Digital Systems*, vol. 13, no. 1, pp. 139–147, 2023, doi: 10.12785/ijcds/13011.
- [5] A. F. Daru, W. Adhiwibowo, and A. M. Hirzan, "Model Pemantau Kelembaban dan Irigasi Sawah Otomatis Berbasis Internet of Things," *Komputika Jurnal Sistem Komputer*, vol. 10, pp. 119–127, 2021, doi: 10.34010/komputika.v10i2.4515.
- [6] S. Hirasawa, M. Nakatsuka, K. Masui, T. Kawanami, and K. Shirai, "Temperature and Humidity Control in Greenhouses in Desert Areas," *Agricultural Sciences*, vol. 05, no. 13, pp. 1261–1268, 2014, doi: 10.4236/as.2014.513134.
- [7] A. Σαπουνάς, N. Katsoulas, B. Slager, R. A. Bezemer, and C. Lelieveld, "Design, Control, and Performance Aspects of Semi-Closed Greenhouses," *Agronomy*, vol. 10, no. 11, p. 1739, 2020, doi: 10.3390/agronomy10111739.
- [8] R. Liao, S. Zhang, X. Zhang, M. Wang, H. Wu, and L. Zhangzhong, "Development of smart irrigation systems based on real-time soil moisture data in a greenhouse: Proof of concept," *Agric Water Manag.*, vol. 245, Feb. 2021, doi: 10.1016/j.agwat.2020.106632.
- [9] M. S. Alajmi and A. M. Almeshal, "Prediction and optimization of surface roughness in a turning process using the ANFIS-QPSO method," *Materials*, vol. 13, no. 13, pp. 1–23, 2020, doi: 10.3390/ma13132986.
- [10] M. Pa and A. Kazemi, "ANFIS-based prediction of power generation for combined cycle power plant." [Online]. Available: [www.power-technology.com](http://www.power-technology.com).
- [11] N. M. Dang and D. T. Anh, "Integration of ANFIS With PCA and DWT for Daily Suspended Sediment Concentration Prediction," *Water Sa*, vol. 47, no. 2 April, 2021, doi: 10.17159/wsa/2021.v47.i2.10916.
- [12] I. Ebtehaj *et al.*, "Prediction of daily water level using new hybridized GS-GMDH and ANFIS-FCM models," *Engineering Applications of Computational Fluid Mechanics*, vol. 15, no. 1, pp. 1343–1361, 2021, doi: 10.1080/19942060.2021.1966837.
- [13] A. Arora *et al.*, "Optimization of state-of-the-art fuzzy-metaheuristic ANFIS-based machine learning models for flood susceptibility prediction mapping in the Middle Ganga Plain, India," *Science of the Total Environment*, vol. 750, 2021, doi: 10.1016/j.scitotenv.2020.141565.
- [14] T. H. Kim *et al.*, "ANFIS Fuzzy convolutional neural network model for leaf disease detection," *Front Plant Sci*, vol. 15, 2024, doi: 10.3389/fpls.2024.1465960.
- [15] M. A. Denai, F. Palis, and A. Zeghib, "ANFIS Based Modelling and Control of Non-linear Systems : A tutorial \*."
- [16] M. Rajagopal, M. Ponnuchamy, and A. Kapoor, "Water management for irrigation scheduling by computing evapotranspiration using ANFIS modelling," *Desalination Water Treat*, vol. 251, pp. 123–133, Mar. 2022, doi: 10.5004/dwt.2022.28290.
- [17] L. S. Kondaka, R. Iyer, S. Jaiswal, and A. Ali, "A Smart Hydroponic Farming System Using Machine Learning," in *Proceedings of the International Conference on Intelligent and Innovative Technologies in Computing, Electrical and Electronics, ICIITCEE 2023*, 2023, pp. 357–362. doi: 10.1109/IITCEE57236.2023.10090860.
- [18] B. Edwin *et al.*, "Smart agriculture monitoring system for outdoor and hydroponic environments," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 25, no. 3, pp. 1679–1687, 2022, doi: 10.11591/ijeecs.v25.i3.pp1679-1687.
- [19] K. Boikanyo, A. M. Zungeru, B. Sigweni, A. Yahya, and C. Lebekwe, "Remote patient monitoring systems: Applications, architecture, and challenges," *Sci Afr*, vol. 20, p. e01638, 2023, doi: <https://doi.org/10.1016/j.sciaf.2023.e01638>.
- [20] M. Montaña-Blacio, J. González-Escarabay, O. Jiménez-Sarango, L. Mingo-Morocho, and C. Carrión-Aguirre, "Design and deployment of an IoT-based monitoring system for hydroponic crops | Diseño y despliegue de un sistema de monitoreo basado en IoT para cultivos hidropónicos," *Ingenius*, vol. 2023, no. 30, pp. 9–18, 2023, doi: 10.17163/ings.n30.2023.01.
- [21] R. Y. Aburasain, "Enhanced Black Widow Optimization With Hybrid Deep Learning Enabled Intrusion Detection in Internet of Things-Based Smart Farming," *IEEE Access*, vol. 12, pp. 16621–16631, 2024, doi: 10.1109/ACCESS.2024.3359043.
- [22] S. W. Chin, G. Rubambiza, Y. Zhao, K. Malek, and H. Weatherspoon, "Realtime optimization and management system (ROAM): A decision support system for digital agriculture systems," *Smart Agricultural Technology*, vol. 8, Aug. 2024, doi: 10.1016/j.atech.2024.100452.

- [23] A. Seifi, M. Ehteram, V. P. Singh, and A. Mosavi, "Modeling and uncertainty analysis of groundwater level using six evolutionary optimization algorithms hybridized with ANFIS, SVM, and ANN," *Sustainability (Switzerland)*, vol. 12, no. 10, 2020, doi: 10.3390/SU12104023.
- [24] J. Yang, C. Shang, Y. Li, F. Li, L. Shen, and Q. Shen, "Constructing ANFIS With Sparse Data Through Group-Based Rule Interpolation: An Evolutionary Approach," *IEEE Transactions on Fuzzy Systems*, vol. 30, no. 4, pp. 893–907, 2022, doi: 10.1109/TFUZZ.2021.3049949.
- [25] R. Xiong *et al.*, "Predicting Dynamic Riverine Nitrogen Export in Unmonitored Watersheds: Leveraging Insights of AI from Data-Rich Regions," *Environ Sci Technol*, vol. 56, no. 14, pp. 10530–10542, 2022, doi: 10.1021/acs.est.2c02232.
- [26] M. Hamitouche and J.-L. Molina, "A Review of AI Methods for the Prediction of High-Flow Extremal Hydrology," *Water Resources Management*, vol. 36, no. 10, pp. 3859–3876, 2022, doi: 10.1007/s11269-022-03240-y.
- [27] E. M. Raouhi, M. Zouizza, M. Lachgar, Y. Zouani, H. Hrimech, and A. Kartit, "AIDSII: An AI-based digital system for intelligent irrigation," *Software Impacts*, vol. 17, 2023, doi: 10.1016/j.simpa.2023.100574.
- [28] S. L. Zhou, A. A. Shah, P. K. Leung, X. Zhu, and Q. Liao, "A comprehensive review of the applications of machine learning for HVAC," *DeCarbon*, vol. 2, p. 100023, 2023, doi: <https://doi.org/10.1016/j.decarb.2023.100023>.
- [29] L. Morales Escobar, J. Aguilar, A. Garces-Jimenez, J. A. Gutierrez De Mesa, and J. M. Gomez-Pulido, "Advanced fuzzy-logic-based context-driven control for HVAC management systems in buildings," *IEEE Access*, vol. 8, pp. 16111–16126, 2020, doi: 10.1109/ACCESS.2020.2966545.
- [30] H. Oubehar, A. Selmani, A. Ed-Dahhak, A. Lachhab, M. E. H. Archidi, and B. Bouchikhi, "ANFIS-Based Climate Controller for Computerized Greenhouse System," *Advances in Science Technology and Engineering Systems Journal*, vol. 5, no. 1, pp. 8–12, 2020, doi: 10.25046/aj050102.
- [31] H. Oubeha, "Intelligent Control for an Experimental Greenhouse Climate Based on ANFIS Technology," *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 9, no. 1.5, pp. 84–90, 2020, doi: 10.30534/ijatcse/2020/1391.52020.
- [32] H. Hamidane *et al.*, "Application Analysis of ANFIS Strategy for Greenhouse Climate Parameters Prediction: Internal Temperature and Internal Relative Humidity Case of Study," *E3s Web of Conferences*, vol. 297, p. 01041, 2021, doi: 10.1051/e3sconf/202129701041.
- [33] L. Brahim, N. Hadroug, A. Iratni, A. Hafaiifa, and I. Colak, "Advancing predictive maintenance for gas turbines: An intelligent monitoring approach with ANFIS, LSTM, and reliability analysis," *Comput Ind Eng*, vol. 191, May 2024, doi: 10.1016/j.cie.2024.110094.
- [34] M. A. Khan and F. Algarni, "A Healthcare Monitoring System for the Diagnosis of Heart Disease in the IoMT Cloud Environment Using MSSO-ANFIS," *IEEE Access*, vol. 8, pp. 122259–122269, 2020, doi: 10.1109/ACCESS.2020.3006424.