

Implementasi ANN Berbasis Edge Computing pada ESP32 untuk Memprediksi Kelembaban dan Suhu

¹James Erick Lumbantoruan, ^{2*}Tonny Suhendra, ³Sapta Nugraha

^{1,2,3} Program Studi Teknik Elektro, Universitas Maritim Raja Ali Haji, Tanjungpinang, Indonesia

^{1e}ricklumbantoruanjame@gmail.com, ^{2*}tonny.suhendra@gmail.com, ³saptanugraha@umrah.ac.id

Article Info

Keyword:

prediksi
suhu dan kelembaban
edge computing
ANN
ESP32
TensorFlow

Copyright © 2025 -SNTE
All rights reserved

ABSTRACT

Abstrak—Penelitian ini mengembangkan sistem prediksi suhu dan kelembaban udara menggunakan algoritma Artificial Neural Network (ANN) yang diimplementasikan langsung pada perangkat edge ESP32. Sistem dirancang sebagai solusi ketika sensor DHT22 gagal membaca data secara *real-time*. Model ANN yang terdiri dari 2 hidden layers 16 neurons dengan 'relu', dilatih menggunakan TensorFlow Keras dan dikonversi ke format TensorFlow *Lite* agar dapat dijalankan secara efisien pada perangkat dengan keterbatasan sumber daya. Pengujian dilakukan selama dua hari dengan interval prediksi antara 5 hingga 120 menit. Hasil menunjukkan bahwa model memiliki akurasi tinggi pada prediksi jangka pendek (5–10 menit), dengan nilai MAE sebesar 0,22–0,41 °C untuk suhu dan 0,16–0,24 % RH untuk kelembaban. Akurasi menurun pada prediksi jangka menengah hingga panjang, dengan kesalahan maksimum mencapai 3,26 °C dan 14,00 % RH. Sistem ini terbukti mampu memberikan estimasi yang andal saat sensor utama gagal, dan memiliki potensi pengembangan lebih lanjut dengan menambahkan variabel lingkungan lainnya sebagai *input model*. Model ANN bisa diterapkan dalam sistem prediksi berbasis *edge computing* pada Mikrokontroler ESP32 dan mampu beradaptasi melalui pembaruan data secara berkala.

Corresponding Author:

Tonny Suhendra,
Program Studi Teknik Elektro, Universitas Maritim Raja Ali Haji, Tanjungpinang,
Jalan Politeknik Senggarang, Tanjungpinang, Kepulauan Riau, Indonesia
Email: tonny@umrah.ac.id

I. PENDAHULUAN

Pemantauan suhu dan kelembaban sangat penting karena keduanya saling berkaitan dan dipengaruhi oleh faktor lingkungan, seperti ketinggian dan intensitas sinar matahari [1]. Sensor DHT22 banyak digunakan dalam sistem pemantauan karena memiliki akurasi tinggi dibandingkan sensor lainnya (Puspasari et al., 2020) [2]. Sensor DHT22 memiliki karakteristik yang lebih unggul dibandingkan dengan sensor suhu dan kelembaban lainnya (Koestoer et al., 2019) [3]. Namun, dalam kondisi lingkungan tertentu, sensor ini dapat mengalami penurunan performa sehingga pembacaan suhu dan kelembaban menjadi kurang akurat.

Penelitian yang dilakukan Mulyanto et al., (2022) [4] menunjukkan hasil akurasi sensor DHT22 dalam mengukur suhu mencapai 99,18% dan kelembaban sebesar 99,87%. Penelitian yang sama mengukur tingkat

akurasi sensor DHT22 juga dilakukan oleh [5] menunjukkan akurasi suhu sebesar 98,07% dan kelembaban mencapai 99,30%. Penelitian yang dilakukan oleh [6] menunjukkan akurasi pengukuran suhu sebesar 99,2% dan kelembaban mencapai 92,8%. Namun, pada penerapannya di lapangan, akurasi sensor DHT22 dapat mengalami penurunan akibat faktor seperti kerusakan sensor, sambungan kabel buruk, atau lingkungan ekstrem, yang dapat membuat data tidak akurat atau bahkan tidak terbaca [7].

Sistem pemantauan umumnya mengandalkan *cloud computing* untuk menyimpan dan dan mengolah data yang dikumpulkan dari sensor DHT22 [8]. Hal ini didasarkan pada keunggulan *cloud computing* dalam menyediakan kapasitas penyimpanan yang besar, kapabilitas komputasi yang tinggi, serta kemudahan akses terhadap data secara *real-time* [9]. Meski begitu, *cloud computing* memiliki kelemahan seperti ketergantungan pada internet dan latensi tinggi [10]. Masalah ini bisa diatasi dengan *edge computing*, yang memproses data langsung di lokasi, mengurangi latensi dan meningkatkan keamanan, bahkan saat koneksi tidak stabil [11].

Penerapan *edge computing* dalam pemrosesan data secara lokal memberikan peluang untuk mengintegrasikan algoritma *Artificial Neural Network* (ANN) dalam meningkatkan akurasi prediksi suhu dan kelembaban [12]. ANN dapat memanfaatkan pola historis data dan mengenali hubungan *non-linier*, serta memperbaiki kesalahan pembacaan sensor akibat faktor lingkungan [13]. Integrasi ANN ke dalam sistem *edge computing* dirancang guna memastikan ketersediaan data secara kontinyu, bahkan ketika terjadi gangguan pada proses pembacaan sensor DHT22 [14]. Hal ini memungkinkan sistem untuk tetap menghasilkan data prediksi suhu dan kelembaban secara *real-time*. Selain itu, pemrosesan data secara lokal tidak hanya mempercepat waktu respon sistem, tetapi juga mengurangi latensi dan ketergantungan terhadap konektivitas jaringan, sehingga meningkatkan keandalan dan efisiensi operasional sistem secara keseluruhan [15].

II. METODA


A. Perancangan *Firmware Google Colaboratory*

Proses penerapan model *Artificial Neural Network* (ANN) pada mikrokontroler ESP32 dimulai dengan memasukkan *library* yang diperlukan untuk membuat dan melatih model *machine learning*. Setelah itu, dataset dibaca dan diproses, lalu data dilakukan normalisasi agar memiliki rentang nilai yang sama, sehingga mempercepat proses saat pelatihan. Data yang sudah dinormalisasi dibagi menjadi dua bagian, yaitu data untuk pelatihan dan data untuk validasi, agar model dapat dinilai secara objektif selama proses pelatihan berlangsung. Model *Artificial Neural Network* kemudian dilatih menggunakan data pelatihan.

Selama pelatihan, nilai kesalahan seperti *Mean Squared Error* (MSE) pada data pelatihan dan validasi terus diperiksa. Jika nilai *Train_MSE* dan *Val_MSE* mendekati satu sama lain atau memiliki perbedaan yang kecil, maka model tersebut dianggap sudah terlatih dengan baik dan tidak mengalami *overfitting*. Setelah selesai dilatih, model tersebut dikonversi dari format *TensorFlow* (TF) ke *TensorFlow Lite* (TF Lite) yang dirancang khusus untuk digunakan pada perangkat dengan sumber daya terbatas.

Setelah itu, model yang dalam format TF Lite dikonversi kembali menjadi bentuk C array, sehingga bisa dimasukkan ke dalam program mikrokontroler. C Array yang telah dikonversi kemudian diintegrasikan ke dalam perangkat *edge* ESP32 dengan menggunakan pustaka seperti *EloquentTinyML* atau *TensorFlow Lite*. Dengan langkah ini, model ANN sudah berhasil

digabungkan di perangkat dan siap digunakan untuk melakukan prediksi. Diagram alir perancangan *firmware* pada Google Colaboratory ditunjukkan pada Gambar 1.




Gambar 1. Diagram Alir pada Google Colaboratory

B. Perancangan *Firmware* Arduino IDE

Proses sistem monitoring suhu dan kelembaban dimulai dengan inisialisasi pustaka (*library*) dan komponen, seperti sensor DHT22, modul RTC DS3231, OLED, modul *micro SD Card*, serta model *Artificial Neural Network* (ANN). Setelah itu, konfigurasi model ANN yang digunakan untuk melakukan prediksi. Apabila proses inisialisasi berhasil, sistem melanjutkan ke tahap pembacaan waktu dari modul RTC DS3231 dan pembacaan data suhu serta kelembaban dari sensor DHT22.

Setelah itu, sistem melakukan pengecekan untuk memastikan bahwa data dari sensor telah berhasil dibaca. Apabila data berhasil diperoleh, maka data suhu dan kelembaban akan ditampilkan secara *real-time* pada layar OLED, serta dicatat ke dalam SD Card. Selanjutnya, sistem akan memeriksa status perangkat guna menentukan kondisi alat masih aktif. Jika perangkat belum dimatikan, maka proses pengambilan data akan diulang secara terus-menerus.

Namun, jika pembacaan data dari sensor gagal, sistem akan melakukan normalisasi data terlebih dahulu. Data yang telah dinormalisasi selanjutnya akan diproses menggunakan model ANN untuk memprediksi suhu atau kelembaban. Hasil prediksi tersebut kemudian dinormalisasi agar nilainya sesuai dengan skala data asli, lalu ditampilkan pada layar OLED dan disimpan ke dalam SD Card. Setelah itu, sistem kembali memeriksa status perangkat, jika perangkat dalam keadaan mati proses akan berhenti dan sistem berakhir. Namun jika masih aktif, sistem akan kembali ke awal untuk mengulangi seluruh proses. Diagram alir ditunjukkan pada Gambar 2.




Gambar 2. Diagram Alir pada Arduino IDE

Model ANN menggunakan library TensorFlow Keras yang terdiri dari tiga lapisan utama, yaitu satu *input layer*, dua *hidden layer* masing-masing 16 neurons, dan menggunakan fungsi aktivasi ReLu (*Rectified Linier Unit*) yang digunakan untuk menangani hubungan *non-linier* dalam *dataset*, serta satu *output layer* yang memiliki 1 neuron yang digunakan untuk hasil prediksi.

C. Melatih Model ANN

Proses pelatihan Model ANN menggunakan TensorFlow dan Keras, dengan menggunakan aktivasi ReLU yang digunakan untuk menangani pola *non-liner* dalam data, Optimizer RMS dan MSE sebagai fungsi *loss* yang sesuai untuk mengukur fungsi kesalahan prediksi dalam regresi. *Early Stopping* digunakan untuk mencegah terjadinya *overfitting* yang menghentikan pelatihan jika nilai *val-loss* tidak membaik dalam 10 epoch berturut-turut, serta mengembalikan bobot terbaik. Model dilatih dengan data yang telah dinormalisasi hingga maksimal 1000 epoch dengan ukuran batch size 16, serta data validasi menggunakan *x_test* dan *y_test* untuk pemantauan.


Gambar 3. Hasil Pelatihan Suhu dan Kelembaban Model ANN




Hasil dari pelatihan model akan dievaluasi performa dengan melihat MSE pada data train, validasi, dan uji. Nilai MSE selama *train* diambil dari `train_model.history`, lalu ditampilkan untuk epoch terakhir guna memeriksa kemungkinan *overfitting*. Jika train MSE terlalu tinggi dibandingkan dengan validasi MSE, maka model mengalami kesalahan generalisasi atau *overfitting*, sebaliknya jika validasi MSE terlalu tinggi dibandingkan train MSE, maka model mengalami *undervitting*, seperti yang terlihat pada Gambar 3 merupakan hasil dari latih dan validasi suhu dan kelembaban.

D. Perancangan Sistem


Perancangan sistem ini dirancang dengan menggunakan beberapa komponen utama dan dataset suhu dan kelembaban, seperti ESP32, RTC DS3231, modul *micro SD Card*, dan OLED. Dataset suhu dan kelembaban diubah ke C Array untuk digabungkan dengan perangkat edge ESP32. ESP32 akan mengolah, menganalisis dan memprediksi suhu dan kelembaban berdasarkan waktu yang dikirimkan oleh RTC DS3231 dan hasil prediksi akan ditampilkan di layar OLED serta disimpan pada kartu MicroSD. Diagram blok dan integrasi komponen yang akan dirancang dapat dilihat pada Gambar 4 dan Gambar 5.



Gambar 4. Diagram Blok Sistem



Gambar 5. Integrasi Komponen



Gambar 6. (a) Skema Rangkaian (b) Hasil Pembacaan Sensor DHT22

III. HASIL DAN PEMBAHASAN


A. Pengujian Sensor DHT22

Pengujian sensor DHT22 dilakukan menggunakan ESP32 dan *software* Arduino IDE dengan melakukan pemrograman dan monitoring data suhu dan kelembaban. Pada proses ini, pin data dari sensor dihubungkan ke pin 33 pada ESP32. Sementara, pin VCC dan GND masing-masing

terhubung ke 3,3V dan GND dari ESP32. Program dikembangkan untuk membaca data suhu dan kelembaban secara berkala, lalu menampilkannya melalui serial monitor Arduino IDE secara real-time. Gambar 6(a) menunjukkan skema rangkaian, sedangkan Gambar 6(b) menampilkan hasil pembacaan suhu dan kelembaban dari sensor DHT22. Berdasarkan hasil pembacaan data suhu dan kelembaban tersebut, menunjukkan sensor DHT22 berfungsi dengan baik.

B. Pengujian OLED 128x64


Pengujian OLED 128x64 dilakukan menggunakan ESP32 dan software Arduino IDE dengan melakukan pemrograman serta menampilkan data di layar OLED. Pada proses ini, digunakan komunikasi I2C yang dihubungkan pada pin 21 (SDA) dan pin 22 (SCL). Sementara itu, pin VCC dan GND OLED terhubung ke pin 3,3V dan GND pada ESP32 sebagai sumber daya. Pemrograman dilakukan dengan menggunakan pustaka Adafruit SSD1306 dan Adafruit GFX, yang mendukung pengiriman data berupa teks maupun grafik sederhana ke layar OLED. Tujuan dari pengujian ini adalah untuk memastikan bahwa OLED mampu menampilkan data, seperti suhu dan kelembaban secara real-time dengan tampilan yang jelas dan mudah dibaca. Gambar 7(a) menunjukkan skema rangkaian, sedangkan Gambar 7(b) menampilkan hasil visualisasi data pada layar OLED 128x64.



Gambar 7. (a) Skema Rangkaian (b) Hasil Pembacaan Sensor DHT22

C. Pengujian Modul Micro SD Card


Dengan melakukan pemrograman serta menyimpan data ke dalam kartu memori. Pada pengujian ini, digunakan komunikasi SPI (Serial Peripheral Interface) yang dihubungkan pada pin 5 (CS), pin 23 (MOSI), pin 19 (MISO), dan pin 18 (SCK) dihubungkan pada pin ESP32. Pin VCC dan GND pada modul *micro SD Card* juga dihubungkan ke 3,3V dan ground dari ESP32. Gambar 8(a) menunjukkan skema rangkaian, sedangkan Gambar 8(b) menampilkan hasil penyimpanan data yang berhasil direkam ke dalam kartu memori atau SD Card.



Gambar 8. (a) Skema Rangkaian (b) Hasil Pembacaan Sensor DHT22

D. Pengujian RTC DS3231

Pengujian modul RTC DS3231 dilakukan menggunakan ESP32 dan software Arduino IDE dengan melakukan pemrograman serta menampilkan data waktu dan tanggal dari modul RTC. Pada proses ini, pin 21 (SDA) dan pin 22 (SCL) dihubungkan pada pin ESP32 untuk komunikasi I2C. Sementara itu, pin VCC dan GND modul terhubung ke 3,3V dan ground dari ESP32. Pemrograman dilakukan menggunakan pustaka RTCLib yang memungkinkan pembacaan waktu dan tanggal secara akurat dari modul RTC DS3231. Pengujian ini bertujuan untuk memastikan bahwa modul dapat memberikan data waktu real-time secara stabil dan dapat ditampilkan melalui serial monitor atau perangkat tampilan lain seperti OLED. Gambar 9(a) menunjukkan skema rangkaian, sedangkan Gambar 9(b) menampilkan hasil pembacaan waktu yang ditampilkan melalui serial monitor atau perangkat tampilan lainnya dari modul RTC DS3231.



Gambar 9. (a) Skema Rangkaian (b) Hasil Pembacaan Sensor DHT22

E. Evaluasi Hasil Prediksi Model ANN

Evaluasi dilakukan dengan membandingkan hasil prediksi model ANN terhadap data aktual dari sensor suhu dan kelembaban udara (DHT22) pada beberapa interval waktu prediksi, yaitu 5, 10, 20, 30, 40, 50, 60, 90 dan 120 menit. Pemilihan interval ini bertujuan untuk mengetahui sejauh mana kemampuan model dalam melakukan prediksi jangka pendek hingga jangka panjang dalam kondisi nyata. Tujuan dari pemilihan interval ini adalah untuk mengamati performa model dalam memprediksi parameter suhu dan kelembaban dalam rentang waktu pendek hingga panjang.

Hasil pengujian yang ditampilkan dalam Tabel 1 menunjukkan bahwa pada hari pertama, model ANN menunjukkan performa yang baik pada interval pendek, terutama 5 dan 10 menit, dengan nilai MAE dan RMSE suhu berkisar antara 0,17°C hingga 0,53°C, serta nilai MAE dan RMSE kelembaban berkisar antara 41,32%RH hingga 48,27%RH. Namun, performa model mulai menurun signifikan seiring bertambahnya waktu prediksi. Hal ini terlihat pada interval 90 dan 120 menit, di mana MAE suhu mencapai 3,06°C dan RMSE kelembaban meningkat hingga 14,61%RH, menandakan ketidakstabilan prediksi untuk rentang waktu jangka panjang.

Tabel 1. Hasil Pengukuran Prediksi Hari Pertama

Tanggal / Waktu	Waktu Prediksi	MAE (°C)	MSE (°C ²)	RMSE (°C)	MAE (%RH)	MSE (%RH ²)	RMSE (%RH)
03 Juni 2025 / (06.11 - 06.16 WIB)	5 Menit	0,53	0,29	0,54	6,43	41,32	6,43
03 Juni 2025 / (06.28 - 06.38 WIB)	10 Menit	0,41	0,17	0,41	6,80	46,27	6,80
03 Juni 2025 / (07.01 - 07.21 WIB)	20 Menit	1,47	2,82	1,68	14,00	219,47	14,81
03 Juni 2025 / (07.51 - 08.22 WIB)	30 Menit	3,20	14,46	3,80	7,95	77,43	8,80
03 Juni 2025 / (09.04 - 09.44 WIB)	40 Menit	1,09	4,15	2,04	3,64	14,83	3,85
03 Juni 2025 / (10.38 - 11.26 WIB)	50 Menit	1,94	9,69	3,11	6,22	42,68	6,53
03 Juni 2025 / (12.29 - 13.29 WIB)	60 Menit	1,76	5,27	2,30	5,94	40,75	6,38
03 Juni 2025 / (15.02 - 17.00 WIB)	90 Menit	3,06	12,58	3,55	2,92	12,69	3,56
03 Juni 2025 / (19.14 - 21.14 WIB)	120 Menit	0,54	0,50	0,71	14,02	213,38	14,61

Tabel 2 memperlihatkan hasil evaluasi pada hari kedua, menunjukkan pola yang serupa dengan hari pertama. Prediksi jangka pendek masih memberikan hasil yang cukup akurat, misalnya pada interval 5 hingga 20 menit, MAE suhu berkisar antara 0,22°C hingga 0,74°C, dan RMSE

kelembaban masih relatif kecil, antara 6,42%RH hingga 8,82%RH. Akan tetapi, akurasi model kembali menurun pada prediksi jangka menengah dan panjang. Pada interval 90 dan 120 menit, terjadi lonjakan kesalahan, di mana nilai MSE dan RMSE kelembaban kembali meningkat signifikan, dengan RMSE mencapai 13,39%RH pada prediksi 120 menit. Secara keseluruhan, dari kedua tabel dapat disimpulkan bahwa model ANN mampu memberikan prediksi yang baik pada rentang waktu pendek (≤ 20 menit), tetapi kurang stabil dan tidak akurat pada prediksi dengan interval lebih panjang (≥ 60 menit). Hal ini menunjukkan bahwa untuk penerapan di lapangan, model ANN ini lebih cocok digunakan untuk prediksi jangka pendek, atau perlu dilakukan pengembangan lebih lanjut untuk meningkatkan performa pada prediksi jangka panjang.


Tabel 2. Hasil Pengukuran Prediksi Hari Kedua

Tanggal / Waktu	Waktu Prediksi	MAE (°C)	MSE (°C ²)	RMSE (°C)	MAE (%RH)	MSE (%RH ²)	RMSE (%RH)
07 Juni 2025 / (06.29 - 06.34 WIB)	5 Menit	0,43	0,23	0,48	7,01	49,09	7,01
07 Juni 2025 / (06.44 - 06.54 WIB)	10 Menit	0,22	0,05	0,23	6,42	41,16	6,42
07 Juni 2025 / (07.14 - 07.34 WIB)	20 Menit	0,74	0,66	0,81	5,80	33,84	5,82
07 Juni 2025 / (08.04 - 08.34 WIB)	30 Menit	0,44	0,25	0,50	1,79	4,48	2,12
07 Juni 2025 / (09.14 - 09.54 WIB)	40 Menit	0,40	0,23	0,48	1,49	2,88	1,70
07 Juni 2025 / (10.51 - 11.41 WIB)	50 Menit	0,50	0,36	0,60	3,40	13,59	3,69
07 Juni 2025 / (12.41 - 13.41 WIB)	60 Menit	1,74	3,47	1,86	0,74	0,88	0,94
07 Juni 2025 / (15.11 - 16.41 WIB)	90 Menit	3,26	10,79	3,29	4,00	17,35	4,16
07 Juni 2025 / (18.42 - 20.42 WIB)	120 Menit	0,63	0,88	0,94	11,71	179,33	13,39


F. Visualisasi Pola dan Tren Prediksi

Grafik pada Gambar 10 menunjukkan hasil pengukuran suhu hari pertama. Secara umum, terlihat bahwa pada prediksi jangka pendek (5 hingga 20 menit), model ANN mampu mengikuti pola perubahan suhu dengan baik. Namun, pada interval yang lebih panjang, seperti 60 hingga 120 menit, prediksi mulai menunjukkan deviasi yang semakin besar terhadap data aktual. Grafik kedua (Gambar 11) menampilkan pola prediksi kelembaban hari pertama. Pola yang ditunjukkan serupa dengan pola suhu, di mana hasil prediksi pada interval pendek masih mengikuti arah perubahan kelembaban yang sebenarnya. Namun demikian, akurasi mulai menurun seiring bertambahnya waktu prediksi. Terutama pada interval di atas 60 menit, hasil prediksi cenderung datar dan tidak

mampu menangkap fluktuasi kelembaban secara tepat, yang mengindikasikan keterbatasan model dalam menangani dinamika jangka panjang.




Gambar 10. Pola Hasil Suhu Prediksi dan Kalibrator Hari Pertama




Gambar 11. Pola Hasil Kelembaban Prediksi dan Kalibrator Hari Pertama

Grafik pada Gambar 12 menunjukkan pengukuran suhu hari kedua memperlihatkan bahwa model prediktif ANN mampu mengikuti tren umum perubahan suhu lingkungan dalam jangka waktu pendek, khususnya pada rentang waktu prediksi 5 hingga 20 menit. Hal ini ditunjukkan oleh kedekatan antara kurva prediksi dengan kurva hasil pengukuran sensor kalibrator. Namun demikian, seiring bertambahnya rentang waktu prediksi, yakni pada interval 30 hingga 120 menit, mulai terlihat adanya penyimpangan yang signifikan antara nilai prediksi dan nilai aktual. Pola penyimpangan ini menunjukkan bahwa model mengalami penurunan akurasi dalam memprediksi suhu pada jangka waktu menengah hingga panjang, khususnya pada periode transisi suhu dari siang hingga sore hari, yang ditandai dengan perubahan suhu yang relatif fluktuatif.



Gambar 12. Pola Hasil Suhu Prediksi dan Kalibrator Hari Kedua

Pada Gambar 13 pengukuran kelembaban hari kedua, pola performa prediksi juga menunjukkan karakteristik yang serupa. Pada awal periode pengukuran (5–20 menit), model ANN menunjukkan performa prediktif yang cukup akurat, ditandai dengan kemiripan pola antara data prediksi dan data aktual. Namun, akurasi prediksi mengalami penurunan secara bertahap pada rentang waktu yang lebih panjang. Kurva prediksi cenderung tidak mampu merepresentasikan dinamika kelembaban secara tepat, bahkan pada beberapa titik mengalami perbedaan arah perubahan nilai terhadap data aktual. Kondisi ini mengindikasikan bahwa model ANN memiliki keterbatasan dalam menangkap variabilitas data kelembaban yang kompleks, terutama untuk estimasi dalam jangka waktu lebih panjang. Beberapa faktor yang mungkin memengaruhi hal tersebut antara lain adalah keterbatasan jumlah dan keragaman data pelatihan, struktur jaringan ANN yang masih sederhana, serta kemungkinan adanya gangguan atau *noise* pada data input sensor.



Gambar 13. Pola Hasil Kelembaban Prediksi dan Kalibrator Hari Kedua

IV. KESIMPULAN

Berdasarkan hasil penelitian, model *Artificial Neural Network* (ANN) mampu memprediksi suhu dan kelembaban secara akurat untuk jangka pendek (5–10 menit) dengan hasil yang stabil. Namun, akurasi menurun pada prediksi jangka menengah (30–120 menit), terutama pada menit ke 30 dan ke 40, akibat perubahan kondisi lingkungan dan keterbatasan data pelatihan. Di hari kedua, model menunjukkan stabilitas prediksi suhu yang lebih baik, meskipun prediksi kelembaban masih berfluktuasi karena variabel eksternal seperti intensitas cahaya dan kecepatan angin belum dimasukkan. Secara keseluruhan, model ANN layak diterapkan dalam sistem prediksi berbasis *edge computing* dan mampu beradaptasi melalui pembaruan data secara berkala. Dari penelitian ini juga Mikrokontroler ESP32 mampu diimplementasikan sebagai *edge computing* dengan menggunakan model ANN, pengujian selanjutnya perlu dilakukan dengan menggunakan algoritma dan model yang berbeda, serta jumlah variabel lingkungan yang lebih bervariasi (tekanan udara, intensitas cahaya, curah hujan, kecepatan dan arah angin, altitude, kualitas udara) dan lainnya.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada dosen pembimbing, dosen dan teman-teman atas segala bentuk dukungan, motivasi, bimbingan, serta doa yang telah diberikan selama proses pelaksanaan dan penyusunan penelitian ini, yang selalu memberikan arahan dalam penelitian ini

REFERENSI

Error! No bookmark name given.