

Jutisi: Jurnal Ilmiah Teknik Informatika dan Sistem Informasi

<https://ojs.stmik-banjarbaru.ac.id/index.php/jutisi/index>

Jl. Ahmad Yani, K.M. 33,5 - Kampus STMIK Banjarbaru

Loktabat – Banjarbaru (Tlp. 0511 4782881), e-mail: puslit.stmikbjb@gmail.com

e-ISSN: 2685-0893

Pengembangan Model *Random Forest Regressor* untuk Prediksi Kelembaban pada Pertanian Perkotaan Berkelanjutan

DOI: <http://dx.doi.org/10.35889/jutisi.v14i3.3162>

Creative Commons License 4.0 (CC BY – NC) 

Saeful Bahri^{1*}, Miftah Farid Adiwisastra², Habib Umar³

^{1,3}Informatika, Universitas Bina Sarana Informatika, Sukabumi, Indonesia

²Sistem Informasi, Universitas Bina Sarana Informatika, Tasikmalaya, Indonesia

*e-mail Corresponding Author: saeful.sel@bsi.ac.id

Abstract

Agriculture is a sector that supports food security. Currently, agriculture faces serious challenges due to climate change, land limitations, and low technology adoption. This study aims to develop an Internet of Things (IoT)-based smart farming system integrated with artificial intelligence and run through edge computing. The prototype system is designed to collect real-time data on crop growth environments using pH, TDS, temperature, humidity, and water level sensors. The data is then processed locally using the Random Forest Regressor algorithm to determine optimal environmental conditions. Test results show that the model has very high accuracy in predicting humidity ($R^2 = 0.99$; RMSE = 0.65) and temperature ($R^2 = 0.99$; RMSE = 0.17), although there are still discrepancies in extreme conditions. The integration of IoT, AI, and edge computing has proven to improve energy efficiency, accelerate response times, and provide adaptive and affordable solutions in support of sustainable urban agriculture productivity.

Keywords: Artificial Intelligence; Random Forest Regressor; IoT; Edge Computing

Abstrak

Pertanian merupakan sektor yang mendukung ketahanan pangan, saat ini pertanian menghadapi tantangan serius akibat perubahan iklim, keterbatasan lahan, dan rendahnya adopsi teknologi. Penelitian ini bertujuan mengembangkan sistem pertanian cerdas berbasis *Internet of Things* (IoT) yang terintegrasi dengan kecerdasan buatan dan dijalankan melalui komputasi tepi. Prototipe sistem dirancang untuk mengumpulkan data lingkungan pertumbuhan tanaman secara real-time menggunakan sensor pH, TDS, suhu, kelembaban, dan tinggi permukaan air. Data kemudian diproses secara lokal menggunakan algoritma *Random Forest Regressor* untuk menentukan kondisi lingkungan optimal. Hasil pengujian menunjukkan model memiliki akurasi sangat tinggi pada prediksi kelembaban ($R^2 = 0,99$; RMSE = 0,65) dan suhu ($R^2 = 0,99$; RMSE = 0,17), meskipun masih terdapat selisih pada kondisi ekstrem. Integrasi IoT, AI, dan *edge computing* terbukti mampu meningkatkan efisiensi energi, mempercepat respons, serta memberikan solusi adaptif dan terjangkau dalam mendukung produktivitas pertanian perkotaan berkelanjutan.

Kata kunci: Kecerdasan Buatan; Random Forest Regressor; IoT; Edge Computing

1. Pendahuluan

Pertanian merupakan salah sektor strategis yang menjadi penopang perekonomian di banyak negara Asia, termasuk Indonesia[1] [2]. Selain berfungsi sebagai penyedia pangan, sektor pertanian memiliki peran penting dalam pembangunan nasional dan peningkatan pendapatan masyarakat. Namun perubahan iklim, pemanasan global, serta penyempitan lahan akibat urbanisasi, yang menyebabkan penurunan tingkat produktivitas dan efisiensi pertanian [3].

Urban farming hadir sebagai salah satu solusi adaptif dalam mengatasi keterbatasan lahan di wilayah perkotaan [4][5]. Namun pada umumnya praktik pertanian perkotaan masih dilakukan secara tradisional [6] sehingga kurang presisi, boros sumber daya, dan memiliki produktivitas

yang *relative* rendah. Rendanya tingkat adopsi teknologi dalam urban farming disebabkan oleh keterbatasan biaya, kurangnya literasi digital, serta tidak adanya model teknologi yang sesuai dengan kebutuhan lokal [7][8]. Kondisi ini menimbulkan kesenjangan, dimana potensi urban farming dalam mendukung ketahanan pangan belum sepenuhnya tercapai akibat keterbatasan inovasi teknologi

Salah satu pendekatan yang dinilai efektif adalah integrasi *Internet of Things* (IoT) dengan kecerdasan buatan (*Artificial Intelligence/AI*), khususnya melalui penerapan komputasi tepi (*edge computing*). IoT memungkinkan akuisisi data lingkungan secara real-time, sementara AI berperan dalam analisis dan pengambilan keputusan adaptif [9][10][11][12]. Beberapa penelitian terdahulu membuktikan bahwa AI berhasil diterapkan dalam klasifikasi tanaman, deteksi penyakit, prediksi panen, hingga otomatisasi irigasi [13][14]. Dengan tambahan pemrosesan data melalui *edge computing*, sistem menjadi lebih efisien karena dapat mengurangi ketergantungan pada internet, meningkatkan kecepatan respons, serta menghemat energi [15][16]. Oleh karena itu, solusi berupa model AI berbasis IoT dengan pendekatan komputasi tepi dipandang relevan dan tepat guna untuk mendukung *urban farming* yang lebih produktif dan berkelanjutan.

Penelitian ini bertujuan mengembangkan sistem pertanian cerdas berbasis IoT yang terintegrasi dengan kecerdasan buatan dan diproses melalui komputasi tepi. Tujuan utama penelitian adalah meningkatkan presisi dan efisiensi pengelolaan lingkungan pertanian pada skala *urban farming*. Manfaat penelitian ini diharapkan tidak hanya berkontribusi pada pengembangan ilmu pengetahuan, tetapi juga memberikan solusi praktis yang terjangkau, efisien, dan adaptif dalam mendukung produktivitas, efisiensi sumber daya, serta kemandirian pangan di kawasan perkotaan Indonesia..

2. Tinjauan Pustaka

Seiring dengan meningkatnya tantangan global di sektor pertanian akibat perubahan iklim, keterbatasan lahan, dan kebutuhan efisiensi produksi, banyak penelitian telah mengkaji penerapan teknologi cerdas dalam prediksi dan monitoring pertanian berkelanjutan, termasuk pada skala urban. Penerapan kecerdasan buatan (*Artificial Intelligence/AI*) dan *Internet of Things* (IoT) menjadi salah satu pendekatan yang menonjol karena kemampuannya dalam otomasi, peningkatan presisi keputusan, serta pengurangan ketergantungan terhadap tenaga manusia.

Abed et al. [17], pada penelitian berjudul "*IoT and AI-driven solutions for human-wildlife conflict: Advancing sustainable agriculture and biodiversity conservation*" mengintegrasikan sensor IoT dengan AI untuk memonitor interaksi satwa liar dan lahan pertanian. Sistem ini mengolah data sensor gerak dan citra secara *real-time*, lalu menggunakan algoritma klasifikasi berbasis machine learning untuk mendeteksi potensi ancaman terhadap hasil panen. Hasilnya mampu memberikan proteksi adaptif terhadap sumber daya pertanian dengan tingkat akurasi deteksi yang tinggi.

Durai et al. [1], dalam studi "*Smart farming using Machine Learning and Deep Learning techniques*" menekankan penerapan algoritma pembelajaran mesin dan pembelajaran mendalam untuk monitoring dan prediksi kondisi pertanian. Sistem memanfaatkan data sensor lingkungan (suhu, kelembaban, dan pH tanah) yang diolah dengan metode *supervised learning*, seperti *Random Forest* dan CNN, untuk memprediksi pertumbuhan tanaman dan hasil panen. Penelitian ini membuktikan bahwa AI meningkatkan akurasi pemantauan kondisi pertanian dan memberikan rekomendasi pengelolaan yang lebih presisi.

Khan et al. [8], dalam penelitian "*Adoption of smart urban farming to enhance social and economic well-being of elderly: a qualitative content analysis*" menekankan aspek adopsi teknologi pertanian pintar di perkotaan. Meskipun fokusnya lebih ke dampak sosial, penelitian ini juga menguraikan prosedur monitoring tanaman berbasis sensor sederhana untuk mengukur kelembaban tanah dan pencahayaan. Data tersebut dipakai sebagai dasar rekomendasi aktivitas pertanian perkotaan skala kecil, namun dengan keterbatasan pada fitur prediksi berbasis AI.

berikutnya, [18]. Pada penelitian yang berjudul "*Smart farming: Leveraging IoT and deep learning for sustainable tomato cultivation and pest management*" menunjukkan pemanfaatan IoT untuk monitoring pertumbuhan tomat dengan parameter suhu, kelembaban, dan intensitas cahaya. Data tersebut diolah menggunakan algoritma *deep learning* untuk mendeteksi pola serangan hama secara dini. Integrasi ini berhasil meningkatkan ketepatan prediksi serangan hama dan efisiensi penggunaan pestisida dalam sistem pertanian berkelanjutan.

Dari berbagai penelitian di atas, dapat disimpulkan bahwa pemanfaatan IoT dan AI dalam pertanian telah banyak dikaji, khususnya untuk monitoring kondisi lingkungan dan prediksi hasil

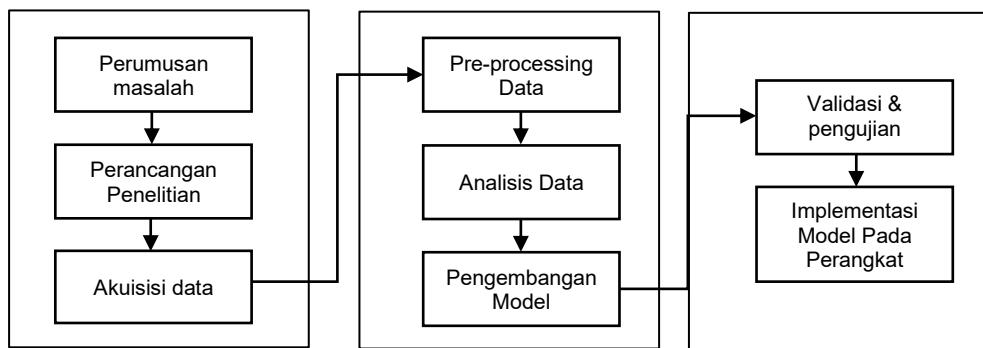
panen. Namun, sebagian besar sistem yang dikembangkan masih bergantung pada pemrosesan berbasis *cloud*, sehingga membutuhkan koneksi internet yang stabil serta konsumsi energi yang tinggi. Selain itu, banyak penelitian hanya berfokus pada parameter terbatas (misalnya kelembaban tanah atau serangan hama) dan belum menekankan integrasi penuh antarparameter lingkungan secara simultan.

Pada penelitian ini kami menawarkan beberapa pendekatan seperti mengintegrasikan IoT, kecerdasan buatan, dan komputasi tepi. Sistem ini kami rancang untuk melakukan monitoring multi-parameter lingkungan (pH, TDS, suhu, kelembaban, dan tinggi permukaan air) secara *realtime*, dengan pemrosesan langsung di perangkat lokal.

Dengan demikian, penelitian ini menghadirkan berupa pengembangan model kecerdasan buatan berbasis komputasi tepi yang mampu memadukan fungsi monitoring multi-parameter dan prediksi kondisi pertanian secara efisien, adaptif, dan sesuai konteks *urban farming* lokal.

3. Metodologi

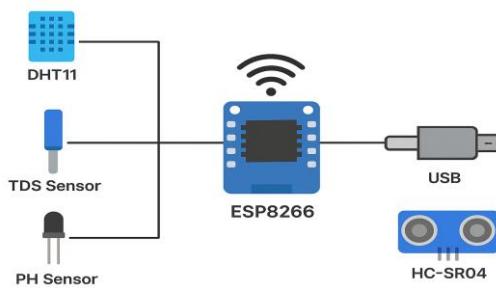
Berdasarkan analisis permasalahan dan gap penelitian, pada penelitian ini dirancangan melalui pendekatan *experimental* menggunakan integrasi IoT, kecerdasan buatan, dan komputasi tepi. Tahapan utama meliputi akuisisi data, *pra-processing*, pengembangan model, validasi model dan implementasi pada perangkat edge. Tahap penelitian dapat dilihat pada gambar 1



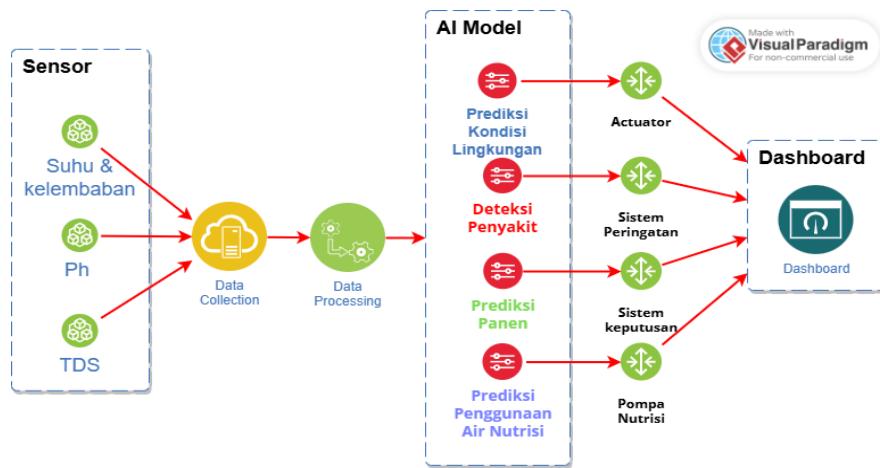
Gambar 1.Tahapan Penelitian

1.) Perancangan Sistem Akuisisi Data

Data penelitian diakuisisi secara mandiri dari instalasi hidroponik skala kecil yang dilengkapi perangkat IoT perangkat sensor yang digunakan diantaranya Sensor (pH, TDS, Sensor Suhu air dan udara, sensor kelembaban), data dikumpulkan secara *realtime* setiap 60 menit dalam kurun waktu 3 bulan yang disimpan kedalam basis data, data yang dikumpulkan berupa text yang memiliki beberapa parameter diantaranya id, suhu, kelembaban, suhu udara, ph, tds, pompa_air, pompa_nutrisi,dan level_air. Selanjutnya dilakukan seleksi parameter yang kurang relevan seperti id.pompaair, pompa nutrisi dan level_air, pada akhirnya parameter yang digunakan adalah suhu, kelembaban, suhu udara, ph dan tds, yang akan digunakan sebagai data dalam pengembangan model selanjutnya dilakukan pembersihan data untuk mengurangi noise dari *null value* dan data yang duplikat. Adapun beberapa sensor yang kami gunakan pada proses akuisi data meliputi DHT11 yang digunakan untuk mengukur suhu dan kelembaban udara, TDS Sensor digunakan untuk mengukur Tingkat konsentrasi nutrisi (ppm) pH sensor untuk memantau tingkat keasaman nutrisi, DS18B20 digunakan untuk mengukur suhu air nutrisi dan HC-SR04 digunakan mengukur ketinggian air nutrisi keseluruhan sensor diintegrasikan dan dikelola dengan modul ESP8266, pada gambar 2 dapat dilihat ilustrasi rancangan sistem akuisisi data, sedangkan pada gambar 3 dapat dilihat visualisasi prototipe sistem cerdas



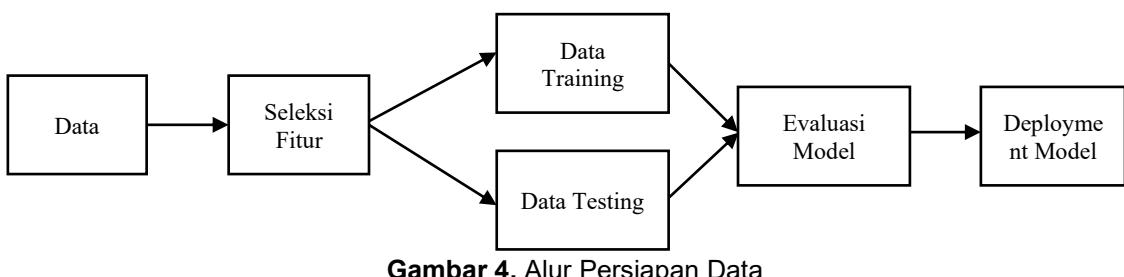
Gambar 2. Rancangan Sistem akuisisi data



Gambar 3. Visualisasi Rancangan Sistem Cerdas

2.) Persiapan dan *Preprocessing Data*

Pada tahapan ini data dipersiapkan sebelum data dilatih, berupa pembersihan data (menghapus nilai outlier dan missing value) serta normalisasi skala komposisi dataset dibagi kedalam dua bagian yaitu data training 80% dan data testing 20 % pembagian data dilakukan secara acak (*randomized split*) yang bertujuan untuk menjaga representasi distribusi data menyeragamkan data agar lebih terstruktur untuk mudah dianalisis. Augmentasi diterapkan untuk menambah variasi dari dataset. Data telah melewati augmentasi, kemudian dibagi menjadi 3 subset data dengan pembagian 80% untuk training, berjumlah 513 data, 20% untuk validation dan testing, berjumlah 128 data. Data training digunakan untuk melatih model, data validation mengecek dan memvalidasi hasil training. Model diuji sebagai ukuran performa model menggunakan data testing. Pada gambar 4 dapat dilihat alur persiapan data



Gambar 4. Alur Persiapan Data

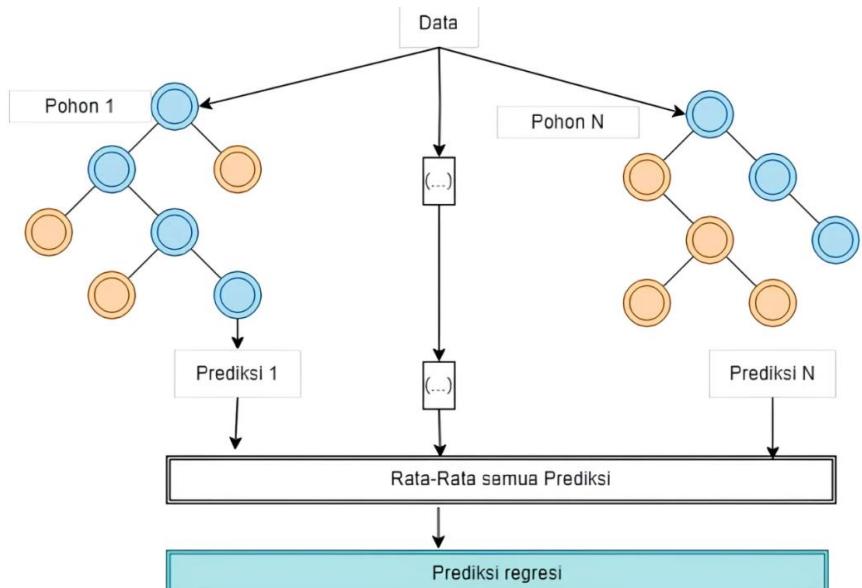
3.) Pengembangan Model

a.) Random Forest Regressor

Random forest regressor adalah salah satu algoritma *machine learning* berbasis *ensemble* yang digunakan untuk memprediksi nilai berupa angka atau nilai kontinyu. Algoritma

ini bekerja dengan cara membuat beberapa pohon keputusan dari data yang sama dan fitur yang dipilih secara acak. Hasil prediksi diperoleh dengan menghitung rata-rata dari semua pohon yang dibuat. Adapun struktur pohon keputusan dapat dilihat pada gambar 3

$$r_n(X) = E_{\theta}[r_n(X, \theta)] \quad \dots \dots \dots \quad (1)$$



Gambar 5. Struktur Pohon Keputusan

b.) Kuadrat Kesalahan Rata-rata

Setelah pohon terbentuk dan dilakukan prediksi akhir selanjutnya dihitung kuadrat kesalahan. Melalui persamaan (2)

$$E(X, Y) = (Y - h(X))^2 \quad \dots \dots \dots \quad (2)$$

Di mana Y adalah nilai target yang sebenarnya dan $h(X)$ adalah prediksi dari model. Rumus ini menunjukkan seberapa baik model memprediksi nilai sebenarnya dibandingkan dengan prediksi yang dihasilkan.

c.) Training Model

Pelatihan model dilakukan dengan mengatur beberapa parameter. Jumlah pohon keputusan ditetapkan antara 100-500 (`n_estimators`) dengan kedalaman maksimum pohon(`max_depth`) 20 dan diterapkan secara bervariasi, berikutnya proses training menggunakan Teknik *bootstrap aggregating*, setiap pohon dilatih secara general dengan data acak Selain model utama, dilakukan juga pengujian dengan beberapa variasi *hyperparameter* (*grid search*) guna menemukan konfigurasi optimal. Hasil dari kombinasi pengujian *hyperparameter* ini menghasilkan beberapa model regresi yang dibandingkan, sebagai mana dijabarkan pada Tabel 1. kemudian dianalisis untuk menilai ketahanan terhadap *overfitting* serta kontribusi fitur (*feature importance*) dalam mendukung proses pengambilan keputusan pada konteks pertanian urban.

Tabel 1. Inisialisasi Model *Random Forest Regressor*

Model	<code>n_estimators</code>	<code>max_depth</code>	<code>min_sampel_leaf</code>	<code>Max_feature</code>
m1	100	8	5	Sqrt
m2	200	10	2	Sqrt
m3	300	12	2	sqrt
m4	400	15	2	sqrt
m5	500	20	3	log

4.) Evaluasi

Model yang telah dilatih secara khusus dengan beberapa tunnig yang serupa, model diukur performanya. Evaluasi model menggunakan beberapa metrik evaluasi Perhitungan *Pixel Accuracy* ditampilkan pada persamaan Evaluasi kinerja model dilakukan dengan metrik R-Square (R^2) dan *Root Mean Square Error* (RMSE) data dilihat pada persamaan (3) (4)

$$R^2 = \frac{SSR}{SST} = \frac{\sum(Y_i - \bar{Y})^2}{\sum(Y_{i-} - \bar{Y})^2} \quad \dots \dots \dots \quad (3)$$

$$RMSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \dots \dots \dots \quad (4)$$

4. Hasil dan Pembahasan

Penelitian ini berhasil mengembangkan sebuah prototipe sistem cerdas yang digunakan dalam pertanian pada skala urban berbasis *Internet of Things* (IoT) yang diintegrasikan dengan model kecerdasan buatan (*Artificial Intelligence/AI*) dan dijalankan melalui komputasi tepi (*edge computing*). Sistem

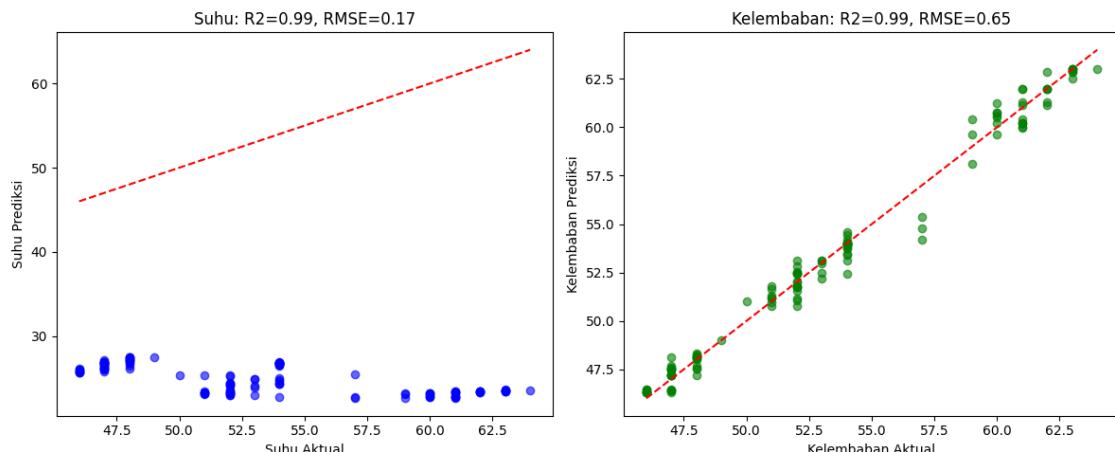
4.1. Hasil Pengujian

Pada bagian ini kami akan menjelaskan hasil dari penelitian yang kami lakukan, penelitian ini menghasilkan sebuah model kecerdasan buatan yang dirancang untuk melakukan prediksi terhadap parameter-parameter yang penting dalam sebuah instalasi hidroponik, khususnya suhu dan kelembaban. Model yang dibangun dengan menggunakan algoritma *Random Forest Regressor* yang telah dilatih menggunakan data hasil akuisisi sensor pada sistem hidroponik skala kecil. Jumlah data yang kami gunakan saat artikel ini ditulis Adalah sebanyak 642 data yang dibagi kedalam 80% data training dan 20% data uji sampe data dapat dilihat pada tabel 2

Tabel 2. Sample Data

Tabel 2. Sample Data						
Id	Suhuudara	kelembaban	suhu	pH	tds	Date
1	25,7	49,08	24,3	5,7	985	14/3/2025
2	25,9	47,51	23	5,4	960	15/3/2025
3	26	46,8	23,2	5,5	970	16/3/2025
4	25,8	47,12	22,6	5,5	970	17/3/2025
5	25,7	47,64	25,1	5,3	940	18/3/2025
...
640	22,65	59,81	20,3	5,9	935	04/6/2025

Data tersebut telah dibersihkan seperti menghilangkan nilai-nilai anomali seperti nilai minus dan nilai null menggunakan metode *forward fill* maupun *backward fill*. Dari hasil training dapat diperoleh hasil metrik, hasil metrik dapat dilihat pada gambar 6.



Gambar 6. Hasil Evaluasi Performa Model Prediksi

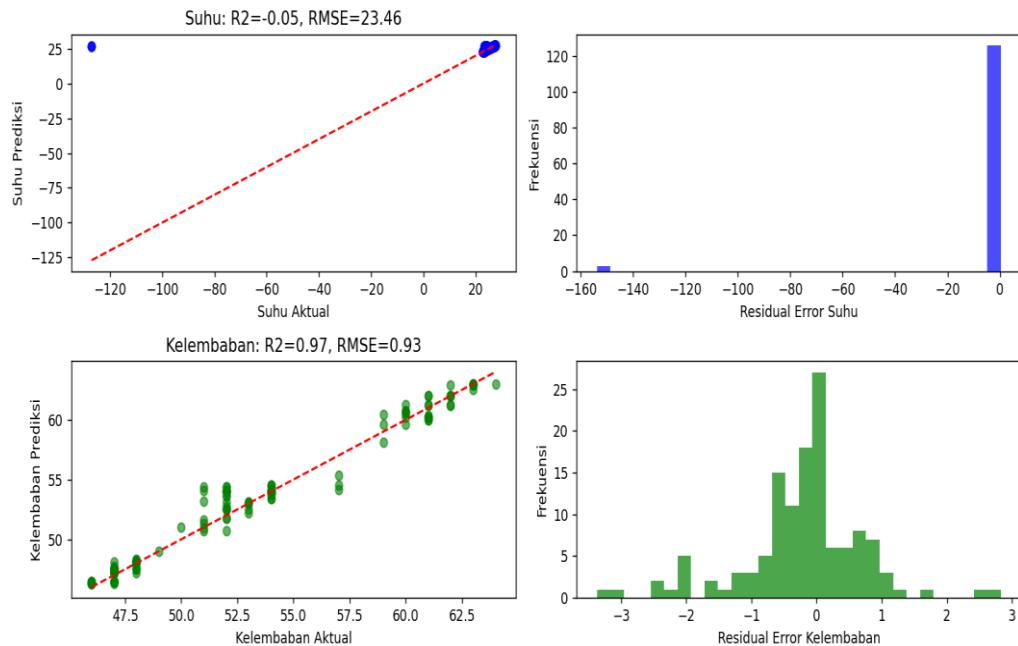
Gambar 6 menampilkan hasil evaluasi kinerja model prediksi terhadap dua parameter lingkungan utama, yaitu suhu dan kelembaban, dalam sistem hidroponik. Grafik di sebelah kiri menunjukkan perbandingan antara nilai suhu aktual dan nilai suhu hasil prediksi model. Meskipun koefisien determinasi (R^2) mencapai 0,99 dan nilai *Root Mean Square Error* (RMSE) relatif rendah sebesar 0,17, pola sebaran data prediksi belum secara konsisten mengikuti garis referensi ($y = x$). Hal ini mengindikasikan adanya deviasi sistematis antara nilai aktual dan hasil prediksi, yang dapat disebabkan oleh keterbatasan jumlah data latih, keberadaan *outlier* pada pengukuran sensor, atau keterbatasan model dalam menangkap variasi suhu secara akurat. Namun, grafik di sisi kanan menunjukkan keterhubungan antara nilai kelembaban aktual dengan hasil prediksi model. Parameter ini menunjukkan pola sebaran data yang lebih linier dan mendekati garis referensi, dengan nilai R^2 sebesar 0,99 serta RMSE sebesar 0,65. Hasil ini menunjukkan bahwa model memiliki kemampuan generalisasi yang lebih baik dalam memprediksi kelembaban dibandingkan suhu, dengan tingkat akurasi yang sangat tinggi serta penyimpangan prediksi yang relatif kecil. Secara keseluruhan, hasil evaluasi ini menunjukkan bahwa model yang dikembangkan telah mampu memprediksi kelembaban lingkungan dengan performa yang sangat baik. Secara kesekuruan, hasil evaluasi ini menunjukkan bahwa model yang dikembangkan telah mampu memprediksi kelembaban lingkungan dengan performa yang sangat baik. Namun, ada beberapa situasi di mana prediksi menunjukkan deviasi yang lebih besar, terutama ketika sistem menghadapi perubahan lingkungan yang tiba-tiba, seperti saat terjadi kenaikan suhu udara yang drastis. Ini memberikan kesempatan untuk meningkatkan kinerja model dengan menambahkan data pelatihan dari periode yang lebih lama atau dengan menyesuaikan *hyperparameter*.

4.2 Penerapan Model

Model *Random Forest Regressor* terbaik diimplementasikan pada perangkat yang terhubung dengan sensor pH, TDS, suhu, dan kelembaban. Data sensor diproses secara *real-time* untuk memprediksi kondisi optimal pertumbuhan tanaman. Hasil prediksi digunakan sebagai dasar pengambilan keputusan adaptif, seperti pengaturan irigasi dan nutrisi otomatis. Validasi lapangan dilakukan guna memastikan akurasi prediksi sesuai dengan kondisi nyata. Selain itu, sistem dilengkapi mekanisme monitoring performa model agar dapat diperbarui dengan data baru, sehingga tetap adaptif, efisien, dan relevan untuk mendukung urban farming secara berkelanjutan.

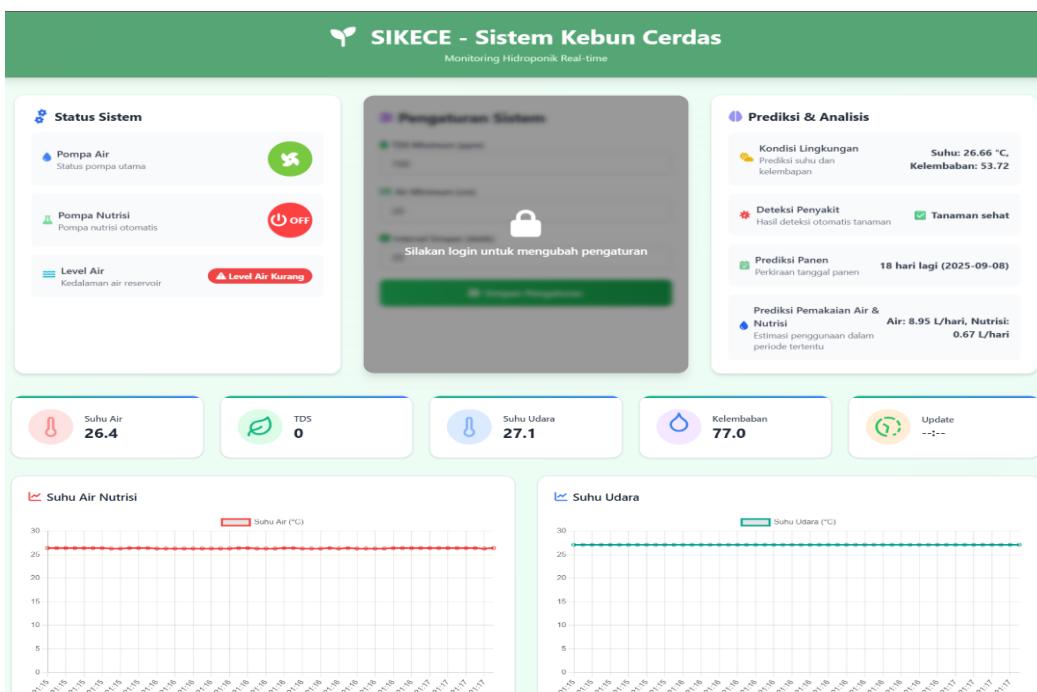
Setelah training model dan proses pengukuran dilakukan tahapan berikutnya adalah melakukan deployment model, model yang telah diterapkan dalam sebuah modul mengunggulkan mampu , Melakukan prediksi suhu dan kelembaban secara langsung berdasarkan masukan dari sensor. Menyediakan sebuah mekanisme deteksi anomali secara sederhana, misalnya jika suhu melebihi 40°C atau kelembaban turun di bawah 30%, kemudian model mampu memberikan estimasi kebutuhan air dan nutrisi harian, meskipun masih berbasis aturan sederhana, meskipun demikian estimasi kebutuhan nutrisi dan air dapat menjadi dasar bagi pengembangan sistem rekomendasi yang lebih cerdas, kemudian model juga menyediakan fitur untuk melakukan estimasi waktu panen, yang ditetapkan secara *default* selama 60 hari ke depan, sebagai fitur tambahan untuk membantu perencanaan budidaya.

Berdasarkan hasil pengujian sistem dengan data *realtime*, menunjukkan bahwa performa sistem menunjukkan perbedaan kinerja antara hasil prediksi suhu dan kelembaban. Pada prediksi kelembaban sistem bekerja sangat baik dengan nilai $R^2=0.97$ dan RMSE =0.93. terlihat Sebaran antara kelembaban aktual dan prediksi mengikuti garis regresi secara konsisten, serta error residual terpusat di sekitar nol, sehingga menandakan tingkat kesalahan prediksi kelembaban yang rendah. Hal ini menunjukkan bahwa sistem dapat diandalkan untuk mendukung pemantauan kondisi lingkungan hidroponik secara *real-time*. Namun pada prediksi suhu sistem menunjukkan performa yang kurang optimal. Nilai $R^2=0.05$ dan RMSE sebesar 23.46 mengindikasikan bahwa sistem belum mampu menangkap pola suhu pada data *real-time* dengan baik. Grafik sebaran juga memperlihatkan adanya penyimpangan signifikan, kemungkinan disebabkan oleh distribusi data suhu yang berbeda dengan data training atau adanya outlier pada data lapangan. Namun secara keseluruhan hasil akurasi pada sistem yang dibangun telah konsisten dengan akurasi model, terutama mengenai prediksi kelembaban dengan akurasi yang cukup tinggi. Gambar 7 menyajikan grafik hasil evaluasi sistem.



Gambar 7. Grafik Hasil Evaluasi Model Prediksi Pada Sistem

Dengan pendekatan ini, model kecerdasan buatan tidak hanya berperan sebagai prediktor, tetapi juga sebagai *decision support system* yang mampu memberikan wawasan praktis bagi pengelola *urban farming*. Keunggulan penggunaan *edge computing* pada *deployment* memastikan bahwa seluruh proses dapat berjalan secara lokal, tanpa ketergantungan penuh pada koneksi internet, sehingga meningkatkan reliabilitas dan responsivitas sistem. supaya lebih mempermudah dalam pembacaan data maupun hasil prediksi kami juga menyediakan *dashboard* yang hanya tersedia secara lokal pada gambar 8 dapat dilihat tampilan *dashboard*



Gambar 7. Dashboard Hasil Prediksi

Pada gambar 8 dapat dilihat tampilan *interface* yang berfungsi sebagai halaman *dashboard* yang memuat beberapa informasi seperti hasil prediksi, tampilan monitoring kondisi lingkungan dan pengaturan otomasi pada prangkat IoT

4.4 Pembahasan

Hasil pengujian menunjukkan bahwa *Random Forest Regressor* mampu membuat prediksi kelembaban dengan akurasi yang cukup tinggi, seperti terlihat dari nilai RMSE yang rendah dan R^2 yang mendekati nilai 1. Temuan ini menunjukkan bahwa model ini bisa digunakan secara efektif untuk mendukung sistem pemantauan lingkungan berbasis sensor dalam pertanian perkotaan. Dengan demikian, penelitian ini berpotensi menjawab masalah utama yang diidentifikasi sejak awal, yaitu kebutuhan akan model prediksi yang handal, responsif, dan dapat berjalan di perangkat edge tanpa bergantung pada server eksternal. Dibandingkan dengan pendekatan regresi sederhana atau metode klasik berbasis aturan, penggunaan *Random Forest Regressor* memberikan peningkatan kinerja yang nyata, terutama dalam menghadapi ketidaklinieran data sensor dan mengurangi dampak noise. Karena itu, sistem bisa memberikan estimasi kebutuhan air dan nutrisi yang lebih tepat, serta membantu perencanaan waktu panen secara lebih adaptif. Kontribusi penelitian ini juga dapat dilihat dalam konteks pengintegrasian dengan penelitian sebelumnya. Misalnya, beberapa penelitian telah mengkaji penggunaan model pembelajaran mesin untuk memprediksi parameter lingkungan pertanian [20], serta penelitian yang membandingkan *Random Forest Regressor* dengan regresi linier dalam estimasi kelembaban tanah [21]. Hasil penelitian ini mendukung temuan-temuan tersebut dan memperkuat bukti bahwa *Random Forest Regressor* lebih unggul dalam menghadapi kompleksitas data lingkungan pertanian. Selain itu, penelitian ini juga memberikan kontribusi tambahan dengan menekankan penerapan model pada *platform edge computing* [22]. Beberapa penelitian telah menyoroti pentingnya mengurangi latensi dan meningkatkan kemandirian sistem pertanian berbasis IoT, namun belum banyak yang mengintegrasikan RFR langsung ke dalam arsitektur edge. Oleh karena itu, penelitian ini menawarkan nilai tambah berupa penguatan implementasi praktis yang menggabungkan keunggulan RFR dengan kemampuan pemrosesan lokal.

Secara keseluruhan, hasil ini menunjukkan bahwa penelitian ini tidak hanya mampu menyelesaikan masalah praktis dalam pertanian perkotaan, tetapi juga memberikan kontribusi penting terhadap pengembangan bidang AI dan IoT untuk pertanian berkelanjutan. Cara penelitian ini mengintegrasikan temuan yang ada ke dalam *body of knowledge* yang sudah ada, sekaligus membuka peluang bagi penelitian lanjutan berkaitan dengan sistem rekomendasi otomatis berbasis model prediktif yang lebih kompleks.

5. Simpulan

Pada bagian ini kami akan memberikan Kesimpulan dari hasil penelitian yang telah kami lakukan, pada penelitian ini kami telah sukses mengembangkan sebuah prototipe sistem yang digunakan untuk pertanian cerdas berbasis IoT dan menerapkan sebuah model kecerdasan buatan yang dijalankan melalui komputasi tepi yang mendukung praktik pertanian urban. Model kecerdasan buatan yang kami gunakan yaitu algoritma *Random Forrest Regressor*, pada pengukuran kinerja model *Random Forest Regressor* menunjukkan kinerja prediksi yang sangat baik, khususnya pada variabel kelembaban, sementara akurasi pada hasil prediksi suhu masih perlu ditingkatkan baik itu melalui penambahan data pelatihan maupun optimasi parameter model. Integrasi sistem kecerdasan buatan dengan komputasi tepi terbukti efektif dalam mengurangi ketergantungan terhadap koneksi internet sekaligus meningkatkan kecepatan dan keandalan dalam proses pengambilan keputusan. Secara keseluruhan, penelitian ini menegaskan bahwa penerapan AI berbasis IoT dan *edge computing* menjadi sebuah pendekatan yang strategis dalam menjawab tantangan keterbatasan lahan, rendahnya adopsi teknologi, dan kebutuhan efisiensi pada pertanian urban. Hasil penelitian ini tidak hanya relevan pada ranah akademis, akan tetapi memiliki beberapa potensi implementasi secara praktis sebagai salah satu solusi berkelanjutan dalam mewujudkan kemandirian pangan diwilayah perkotaan terkhusus Indonesia.

Meskipun demikian penelitian masih terdapat beberapa hal yang perlu dikembangkan, seperti, jumlah data yang digunakan pada tahap pelatihan model relatif masih terbatas, untuk penelitian lanjutan kami sarankan memperluas cakupan *dataset* dengan periode pengamatan yang lebih panjang dengan kondisi lingkungan yang lebih beragam supaya meningkatkan kemampuan model. Dari sisi pemodelan yang kami gunakan hanya sebatas menerapkan

algoritma *Random Forest Regressor*, diharapkan pada penelitian berikutnya dapat menerapkan algoritma pembelajaran mesin dan deep *learning*, seperti *Gradient Boosting*, LSTM, atau CNN, yang memiliki potensi performa yang lebih baik utamanya bagi variabel dengan lingkungan yang dinamis.

Selain penerapan algoritma lain yang lebih baik, penelitian berikutnya pun perlu penambahan beberapa modul *control* yang otomasi seperti sistem irigasi dan sistem nutrisi pintar agar sistem tidak hanya sebagai prediktor, tetapi juga mampu menjalankan aksi korektif secara real-time. Berikutnya pengembangan pada aspek keamanan data dan efisiensi energi, mengingat keterbatasan sumberdaya pada perangkat keras yang digunakan dalam komputasi tepi. Terakhir, melakukan pengujian sistem pada skala komunitas *urban farming* yang lebih luas, yang bertujuan menilai tingkat penerimaan pengguna, biaya implementasi, serta dampak sosial-ekonomi dari penerapan teknologi tersebut. Dengan pengembangan lebih lanjut, sistem ini diharapkan mampu menjawab tantangan dalam ketahanan pangan perkotaan secara berkelanjutan.

Daftar Referensi

- [1] S. K. S. Durai and M. D. Shamili, "Smart farming using Machine Learning and Deep Learning techniques," *Decision Analytics Journal*, vol. 3, no. 3, pp. 2–30, Jun. 2022, doi: 10.1016/j.dajour.2022.100041.
- [2] N. Mahdavi, A. Dutta, S. H. Tasnim, and S. Mahmud, "Review of machine learning techniques for energy sharing and biomass waste gasification pathways in integrating solar greenhouses into smart energy systems," *Energy and AI*, vol. 20, no. 2, pp. 1–37, May 2025, doi: 10.1016/j.egyai.2025.100498.
- [3] S. G. Eladl, A. Y. Haikal, M. M. Saafan, and H. Y. ZainEldin, "A proposed plant classification framework for smart agricultural applications using UAV images and artificial intelligence techniques," *Alexandria Engineering Journal*, vol. 109, pp. 466–481, Dec. 2024, doi: 10.1016/j.aej.2024.08.076.
- [4] M. Ashikuzzaman, M. S. H. Swapan, and A. U. Zaman, "Integrating urban rooftop farming into city governance in megacities: A systematic literature review," *Cities*, vol. 161, no. 1, pp. 1–14, Jun. 2025, doi: 10.1016/j.cities.2025.105893.
- [5] G. Papadopoulos *et al.*, "Stakeholders' perspective on smart farming robotic solutions," *Smart Agricultural Technology*, vol. 11, no. 100916, pp. 1–26, Aug. 2025, doi: 10.1016/j.atech.2025.100916.
- [6] A. Toku, S. Twumasi Amoah, and N. Nyabanyi N-yanbini, "Exploring the potentials of urban crop farming and the question of environmental sustainability," *City and Environment Interactions*, vol. 24, no. 1, pp. 2–11, Dec. 2024, doi: 10.1016/j.cacint.2024.100167.
- [7] G. A. Pratio, S. N. Rohmah, M. A. Akbarsyah, and A. E. Supriyanto, "Praktek Smart Farming Pada Kota-Kota Di Dunia," *Jurnal Bengawan Solo Pusat Kajian Penelitian dan Pengembangan Daerah Kota Surakarta*, vol. 3, no. 2, pp. 88–106, Nov. 2024, doi: 10.58684/jbs.v3i2.79.
- [8] N. Khan, T. C. Lau, and B. C. Tan, "Adoption of smart urban farming to enhance social and economic well-being of elderly: a qualitative content analysis," *Food Res*, vol. 7, no. 5, pp. 114–118, Sep. 2023, doi: 10.26656/fr.2017.7(5).460.
- [9] A. Upadhyay, S. G C, Y. Zhang, C. Koparan, and X. Sun, "Development and evaluation of a machine vision and deep learning-based smart sprayer system for site-specific weed management in row crops: An edge computing approach," *J Agric Food Res*, vol. 18, no. 11, pp. 2–10, Dec. 2024, doi: 10.1016/j.jafr.2024.101331.
- [10] S. Ghazal, A. Munir, and W. S. Qureshi, "Computer vision in smart agriculture and precision farming: Techniques and applications," Sep. 01, 2024, *KeAi Communications Co., Florida*, doi: 10.1016/j.aiia.2024.06.004.
- [11] N. Ahmed and N. Shakoor, "Advancing agriculture through IoT, Big Data, and AI: A review of smart technologies enabling sustainability," Mar. 01, 2025, *Elsevier B.V.* doi: 10.1016/j.atech.2025.100848.
- [12] S. J. Wibowo, B. Hartono, and V. Lusiana, "Sistem Kontrol Lampu Otomatis dan Semi Otomatis berbasis Internet of Things," *Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, vol. 2, no. 14, pp. 856–868, Aug. 2025, Accessed: Aug. 12, 2025. [Online]. Available: <https://ojs.stmik-banjarbaru.ac.id/index.php/jutisi/article/view/2361>

- [13] A. Chourlias, J. Violos, and A. Leivadeas, "Virtual sensors for smart farming: An IoT- and AI-enabled approach," *Internet of Things (The Netherlands)*, vol. 32, p. 101611, Jul. 2025, doi: 10.1016/j.iot.2025.101611.
- [14] B. V. Balaji Prabhu, R. Shashank, B. Shreyas, and O. S. Jois Narsipura, "ARIA: Augmented Reality and Artificial Intelligence enabled mobile application for Yield and grade prediction of tomato crops," in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 2693–2702. doi: 10.1016/j.procs.2024.04.254.
- [15] M. A. Zamora-Izquierdo, J. Santa, J. A. Martínez, V. Martínez, and A. F. Skarmeta, "Smart farming IoT platform based on edge and cloud computing," *Biosyst Eng*, vol. 177, pp. 4–17, Jan. 2019, doi: 10.1016/j.biosystemseng.2018.10.014.
- [16] J. Wang *et al.*, "A review of the application prospects of cloud-edge-end collaborative technology in freshwater aquaculture," *Artificial Intelligence in Agriculture*, vol. 15, no. 2, pp. 232–251, Jun. 2025, doi: 10.1016/j.aiia.2025.02.008.
- [17] N. Abed, R. Murgun, A. Deldari, S. Sankarannair, and M. V. Ramesh, "IoT and AI-driven solutions for human-wildlife conflict: Advancing sustainable agriculture and biodiversity conservation," *Smart Agricultural Technology*, vol. 10, Mar. 2025, doi: 10.1016/j.atech.2025.100829.
- [18] M. R. Hasan, Md. M. Rahman, F. Shahriar, S. I. Khan, K. M. Mohi Uddin, and Md. M. Hasan, "Smart Farming: Leveraging IoT and Deep Learning for Sustainable Tomato Cultivation and Pest Management," *Crop Design*, p. 100079, Nov. 2024, doi: 10.1016/j.croppd.2024.100079.
- [19] J. E. Chaparro, J. E. Aedo, and F. Lumbreras Ruiz, "Machine Learning for the estimation of foliar nitrogen content in pineapple crops using multispectral images and Internet of Things (IoT) platforms," *J Agric Food Res*, vol. 18, p. 101208, Dec. 2024, doi: 10.1016/j.jafr.2024.101208.
- [20] L. Mancipe-Castro and R. E. Gutiérrez-Carvajal, "Prediction of environment variables in precision agriculture using a sparse model as data fusion strategy," *Information Processing in Agriculture*, vol. 9, no. 2, pp. 171–183, Jun. 2022, doi: 10.1016/j.inpa.2021.06.007.
- [21] U. Acharya, A. L. M. Daigh, and P. G. Oduor, "Machine Learning for Predicting Field Soil Moisture Using Soil, Crop, and Nearby Weather Station Data in the Red River Valley of the North," *Soil Syst*, vol. 5, no. 4, pp. 57-66, Sep. 2021, doi: 10.3390/soilsystems5040057.
- [22] I. Ficili, M. Giacobbe, G. Tricomi, and A. Puliafito, "From Sensors to Data Intelligence: Leveraging IoT, Cloud, and Edge Computing with AI," *Sensors*, vol. 25, no. 6, p. 1763, Mar. 2025, doi: 10.3390/s25061763.