

Penerapan Machine Learning pada Smart Agriculture untuk Prediksi Hasil Panen Berdasarkan Faktor Lingkungan

Mohammad Faisol^{1)*} , Syamsul Arifin²⁾ 

¹⁾ ²⁾ Universitas Madura, Pamekasan, Indonesia

¹⁾ mfaisol919@gmail.com, ²⁾ ariefsysum847@gmail.com

Abstrak

Perkembangan teknologi digital dalam sektor pertanian mendorong munculnya konsep Smart Agriculture sebagai solusi untuk meningkatkan produktivitas dan efisiensi pertanian melalui pemanfaatan data dan kecerdasan buatan. Permasalahan utama dalam pertanian modern adalah ketidakpastian kondisi lingkungan seperti suhu, kelembaban, curah hujan, intensitas cahaya, dan kondisi tanah yang dapat memengaruhi hasil produksi tanaman. Penelitian ini bertujuan untuk menerapkan metode Machine Learning dalam melakukan prediksi hasil panen berdasarkan faktor lingkungan sehingga dapat membantu proses pengambilan keputusan pada bidang pertanian. Metode penelitian yang digunakan adalah pendekatan kuantitatif dengan metode eksperimen, yaitu melalui tahapan pengumpulan data lingkungan dan data hasil panen, preprocessing data, pembangunan model Machine Learning, serta evaluasi performa model menggunakan parameter pengukuran kesalahan prediksi. Hasil penelitian menunjukkan bahwa model Machine Learning mampu mengolah data faktor lingkungan untuk menemukan pola hubungan terhadap produktivitas tanaman dan menghasilkan sistem prediksi yang dapat digunakan sebagai pendukung keputusan pertanian. Proses preprocessing dan pemilihan fitur menjadi faktor penting dalam meningkatkan kualitas model karena data lingkungan memiliki karakteristik yang kompleks dan dinamis. Kesimpulan dari penelitian ini menunjukkan bahwa penerapan Machine Learning pada Smart Agriculture dapat menjadi pendekatan efektif dalam meningkatkan akurasi prediksi hasil panen serta mendukung pengelolaan pertanian berbasis data. Penelitian selanjutnya dapat dikembangkan dengan integrasi data sensor IoT secara real-time serta pengujian berbagai algoritma Machine Learning untuk memperoleh model dengan performa prediksi yang lebih optimal.

Kata Kunci: Smart Agriculture, Machine Learning, Prediksi Hasil Panen, Faktor Lingkungan, Kecerdasan Buatan.

Article history: Received 5 April 2026, first decision 22 April 2026, accepted 22 August 2026, available online 28 October 2026

I. PENDAHULUAN

Sektor pertanian merupakan salah satu bidang yang memiliki peran strategis dalam mendukung ketahanan pangan, stabilitas ekonomi, serta keberlanjutan kehidupan masyarakat. Namun, perkembangan sektor pertanian saat ini menghadapi berbagai tantangan kompleks, seperti perubahan iklim, ketidakpastian kondisi lingkungan, keterbatasan sumber daya, serta meningkatnya kebutuhan produksi pangan akibat pertumbuhan populasi global. Faktor lingkungan seperti suhu, kelembaban udara, kelembaban tanah, curah hujan, intensitas cahaya, dan kualitas tanah memiliki pengaruh signifikan terhadap pertumbuhan tanaman dan produktivitas hasil panen[1]. Ketidakmampuan dalam memprediksi kondisi tersebut secara akurat dapat menyebabkan penurunan produktivitas pertanian, pemborosan sumber daya, serta meningkatnya risiko kegagalan panen[2].

Perkembangan teknologi informasi dan komunikasi memberikan peluang besar untuk melakukan transformasi pada sektor pertanian melalui konsep Smart Agriculture atau pertanian cerdas[3]. Smart Agriculture merupakan pendekatan modern yang mengintegrasikan teknologi digital seperti Internet of Things (IoT), sensor lingkungan, analisis data, komputasi awan, serta kecerdasan buatan untuk meningkatkan efisiensi dan produktivitas pertanian[4]. Melalui penerapan teknologi tersebut, data lingkungan pertanian dapat dikumpulkan secara real-time dan dianalisis untuk menghasilkan informasi yang mendukung proses pengambilan keputusan secara lebih tepat[5].

Salah satu teknologi yang memiliki potensi besar dalam pengembangan Smart Agriculture adalah Machine Learning[6]. Machine Learning merupakan salah satu cabang dari kecerdasan buatan yang memungkinkan sistem komputer mempelajari pola dari data historis dan melakukan prediksi tanpa harus diprogram secara eksplisit[7]. Dalam konteks pertanian, Machine Learning dapat digunakan untuk menganalisis hubungan antara faktor lingkungan

* Mohammad Faisol

dengan hasil produksi tanaman, sehingga mampu memberikan prediksi mengenai potensi hasil panen berdasarkan kondisi yang tersedia[8].

Permasalahan utama dalam pengelolaan pertanian konvensional adalah proses pengambilan keputusan yang masih banyak bergantung pada pengalaman petani dan pengamatan manual terhadap kondisi lahan. Pendekatan tersebut memiliki keterbatasan karena faktor lingkungan pertanian bersifat dinamis dan sulit diprediksi secara akurat. Sebagai contoh, perubahan suhu atau kelembaban tanah yang tidak terkontrol dapat memengaruhi proses pertumbuhan tanaman, tetapi dampaknya sering kali baru diketahui setelah terjadi penurunan kualitas maupun kuantitas hasil panen[9]. Oleh karena itu, diperlukan sebuah sistem prediksi berbasis data yang mampu membantu petani dan pemangku kepentingan dalam melakukan perencanaan produksi secara lebih efektif[10].

Penerapan Machine Learning pada Smart Agriculture menjadi solusi yang menjanjikan karena mampu mengolah data dalam jumlah besar serta menemukan pola tersembunyi yang sulit dianalisis menggunakan metode konvensional. Berbagai algoritma Machine Learning seperti Random Forest, Support Vector Machine, Artificial Neural Network, maupun algoritma berbasis Deep Learning telah banyak digunakan dalam penelitian pertanian untuk melakukan klasifikasi tanaman, deteksi penyakit, optimasi irigasi, hingga prediksi hasil produksi[11]. Dengan memanfaatkan data historis hasil panen yang dikombinasikan dengan data faktor lingkungan, model Machine Learning dapat dikembangkan untuk menghasilkan prediksi yang lebih akurat dan membantu meningkatkan produktivitas pertanian[12].

Meskipun berbagai penelitian terkait Smart Agriculture telah berkembang, masih terdapat beberapa tantangan yang perlu dikaji lebih lanjut. Salah satunya adalah bagaimana membangun model prediksi yang mampu mengintegrasikan berbagai faktor lingkungan secara simultan dan menghasilkan estimasi hasil panen yang sesuai dengan kondisi nyata di lapangan[13]. Selain itu, karakteristik lingkungan pertanian yang berbeda pada setiap wilayah menyebabkan model prediksi perlu mempertimbangkan variasi data lokal agar memiliki tingkat akurasi yang optimal[14]. Hal ini menunjukkan bahwa penelitian mengenai penerapan Machine Learning untuk prediksi hasil panen masih memiliki ruang pengembangan yang luas[15].

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan penerapan Machine Learning pada konsep Smart Agriculture untuk melakukan prediksi hasil panen berdasarkan faktor lingkungan[16]. Penelitian ini akan berfokus pada pemanfaatan data lingkungan sebagai variabel utama dalam membangun model prediksi yang mampu memberikan informasi mengenai perkiraan hasil produksi pertanian[17]. Model yang dikembangkan diharapkan dapat menjadi sistem pendukung keputusan bagi petani dalam menentukan strategi pengelolaan lahan, penggunaan sumber daya, serta perencanaan produksi secara lebih efektif dan efisien[18].

Penelitian ini memiliki kontribusi penting dalam bidang informatika, khususnya pada penerapan kecerdasan buatan dan analisis data untuk menyelesaikan permasalahan nyata pada sektor pertanian[19]. Integrasi antara teknologi Machine Learning dan Smart Agriculture diharapkan mampu mempercepat transformasi digital dalam bidang pertanian serta mendukung terciptanya sistem pertanian yang lebih adaptif, produktif, dan berkelanjutan[20]. Dengan demikian, penelitian ini tidak hanya memberikan manfaat dari sisi teknologi, tetapi juga berpotensi memberikan dampak sosial dan ekonomi dalam meningkatkan kesejahteraan masyarakat melalui optimalisasi hasil pertanian[21].

II. TINJAUAN PUSTAKA

Smart Agriculture merupakan konsep penerapan teknologi digital pada sektor pertanian yang bertujuan untuk meningkatkan efisiensi, produktivitas, dan keberlanjutan proses pertanian[22]. Konsep ini menggabungkan berbagai teknologi seperti Internet of Things (IoT), sensor lingkungan, analisis data, komputasi awan, serta kecerdasan buatan untuk menghasilkan sistem pertanian yang mampu melakukan pemantauan dan pengambilan keputusan berbasis data[23].

Dalam implementasinya, Smart Agriculture memungkinkan pengumpulan informasi secara real-time mengenai kondisi lingkungan pertanian, seperti suhu, kelembaban udara, kelembaban tanah, intensitas cahaya, tingkat keasaman tanah, serta kondisi cuaca[24]. Data tersebut kemudian dapat dianalisis untuk mengetahui kondisi optimal bagi pertumbuhan tanaman. Dengan pendekatan ini, pengelolaan pertanian tidak lagi hanya bergantung pada pengalaman manusia, tetapi juga didukung oleh informasi yang diperoleh melalui teknologi[25].

Penerapan Smart Agriculture memiliki peran penting dalam menghadapi berbagai tantangan pertanian modern, terutama dalam meningkatkan efisiensi penggunaan sumber daya seperti air, pupuk, dan lahan[26]. Sistem pertanian berbasis teknologi mampu membantu petani menentukan tindakan yang tepat sesuai kondisi aktual tanaman dan lingkungan sehingga dapat mengurangi risiko kegagalan produksi[27].

Machine Learning merupakan bagian dari kecerdasan buatan yang berfokus pada kemampuan komputer dalam mempelajari pola dari data dan menghasilkan prediksi atau keputusan secara otomatis. Berbeda dengan sistem konvensional yang membutuhkan aturan pemrograman secara langsung[28], Machine Learning menggunakan data sebagai dasar untuk membangun model yang dapat mengenali hubungan antar variabel[29].

Dalam bidang pertanian, Machine Learning banyak digunakan untuk mengolah data kompleks yang berasal dari berbagai sumber, termasuk data sensor lingkungan, data cuaca, data historis produksi, dan karakteristik tanaman. Melalui proses pembelajaran terhadap data tersebut[30], algoritma Machine Learning dapat menemukan pola yang berkaitan dengan faktor-faktor yang memengaruhi hasil pertanian[31].

Beberapa metode Machine Learning yang sering diterapkan dalam bidang prediksi antara lain regresi, Random Forest, Support Vector Machine, dan Artificial Neural Network[32]. Setiap metode memiliki karakteristik berbeda dalam melakukan proses pembelajaran dan prediksi[33]. Pemilihan metode yang tepat dapat meningkatkan kemampuan sistem dalam menghasilkan prediksi yang lebih akurat[34].

Prediksi hasil panen merupakan proses memperkirakan jumlah atau kualitas produksi pertanian berdasarkan data dan faktor yang memengaruhinya. Informasi prediksi hasil panen memiliki peranan penting karena dapat membantu petani maupun pengelola pertanian dalam melakukan perencanaan produksi, distribusi, serta pengelolaan sumber daya[35].

Hasil panen dipengaruhi oleh berbagai faktor lingkungan, seperti kondisi tanah, temperatur, kelembaban, curah hujan, serta intensitas cahaya. Perubahan kecil pada faktor tersebut dapat memberikan dampak terhadap pertumbuhan tanaman. Oleh karena itu, diperlukan metode analisis yang mampu memahami hubungan kompleks antara faktor lingkungan dengan produktivitas tanaman[36].

Dengan menggunakan Machine Learning, proses prediksi hasil panen dapat dilakukan melalui analisis data historis. Sistem dapat mempelajari pola hubungan antara kondisi lingkungan tertentu dengan hasil produksi yang diperoleh sebelumnya, kemudian menggunakan pola tersebut untuk memperkirakan hasil panen pada kondisi yang akan datang[37].

Integrasi Machine Learning dalam Smart Agriculture menjadi pendekatan yang efektif untuk menciptakan sistem pertanian berbasis data. Data yang diperoleh dari sensor maupun sumber informasi lainnya dapat digunakan sebagai input bagi model Machine Learning untuk menghasilkan prediksi dan rekomendasi yang mendukung proses pengambilan keputusan[38].

Sistem berbasis Machine Learning memungkinkan proses pertanian menjadi lebih presisi karena keputusan dapat dibuat berdasarkan analisis kondisi nyata di lapangan. Teknologi ini dapat membantu meningkatkan produktivitas tanaman, mengurangi penggunaan sumber daya yang tidak diperlukan, serta memberikan solusi terhadap permasalahan ketidakpastian lingkungan[39].


Berdasarkan konsep tersebut, penerapan Machine Learning pada Smart Agriculture untuk prediksi hasil panen berdasarkan faktor lingkungan menjadi salah satu pendekatan yang relevan dalam pengembangan teknologi pertanian modern. Penelitian ini mengarah pada pengembangan sistem yang mampu memanfaatkan data lingkungan sebagai dasar analisis untuk menghasilkan prediksi produksi yang lebih optimal dan mendukung pertanian berkelanjutan[40].

III. METODE

Penelitian ini menggunakan metode eksperimen dengan pendekatan kuantitatif untuk membangun model Machine Learning yang mampu melakukan prediksi hasil panen berdasarkan faktor lingkungan pada sistem Smart Agriculture. Metode penelitian dilakukan melalui beberapa tahapan utama, yaitu pengumpulan data, preprocessing data, pembangunan model Machine Learning, evaluasi model, serta analisis hasil prediksi[41].

Pendekatan penelitian ini memanfaatkan data lingkungan pertanian sebagai variabel masukan (input) dan hasil panen sebagai variabel keluaran (output). Data lingkungan yang digunakan mencakup parameter yang memiliki hubungan terhadap pertumbuhan tanaman, seperti suhu, kelembaban udara, kelembaban tanah, curah hujan, intensitas cahaya, serta kondisi tanah. Data tersebut akan diproses menggunakan algoritma Machine Learning untuk menemukan pola hubungan antara faktor lingkungan dan produktivitas tanaman[42].

Gambar berikut menunjukkan alur tahapan penelitian yang dilakukan:



Gambar 1. Alur Metode Penelitian

Tahap awal penelitian dilakukan dengan mengumpulkan data yang berkaitan dengan kondisi lingkungan pertanian dan hasil produksi tanaman. Data dapat diperoleh melalui sensor IoT pada lahan pertanian maupun dataset pertanian yang memiliki informasi historis mengenai kondisi lingkungan dan hasil panen[43].

Data yang diperoleh kemudian digunakan sebagai bahan pelatihan model Machine Learning agar sistem mampu memahami pola perubahan lingkungan terhadap produktivitas tanaman. Semakin baik kualitas data yang digunakan, maka semakin tinggi kemampuan model dalam menghasilkan prediksi yang akurat[44].

Tabel berikut menunjukkan rancangan variabel penelitian:

No	Variabel	Jenis Data	Keterangan
1	Suhu	Numerik	Kondisi temperatur lingkungan pertanian
2	Kelembaban Udara	Numerik	Tingkat kelembaban atmosfer sekitar tanaman
3	Kelembaban Tanah	Numerik	Kandungan air pada media tanam
4	Curah Hujan	Numerik	Intensitas air dari faktor cuaca
5	Intensitas Cahaya	Numerik	Jumlah cahaya yang diterima tanaman
6	Jenis Tanaman	Kategorikal	Kategori tanaman yang dianalisis
7	Hasil Panen	Numerik	Target prediksi produksi tanaman

Sebelum dilakukan proses pelatihan model, data akan melalui tahap preprocessing untuk meningkatkan kualitas data. Tahapan preprocessing meliputi proses pembersihan data dari nilai kosong atau data yang tidak sesuai, normalisasi data agar memiliki skala yang seragam, serta seleksi fitur untuk menentukan faktor lingkungan yang paling berpengaruh terhadap hasil panen[45].

Tahapan ini diperlukan karena data pertanian memiliki karakteristik yang kompleks dan dapat mengandung variasi nilai akibat perubahan kondisi lingkungan. Data yang telah diproses akan digunakan sebagai input dalam proses pembelajaran Machine Learning[46].

Pada tahap ini dilakukan pembangunan model prediksi menggunakan algoritma Machine Learning. Model akan dilatih menggunakan data historis untuk mempelajari hubungan antara faktor lingkungan dengan hasil panen. Beberapa algoritma yang dapat digunakan dalam penelitian ini adalah Random Forest, Artificial Neural Network, atau metode regresi berbasis Machine Learning[47].

Data akan dibagi menjadi data pelatihan dan data pengujian. Data pelatihan digunakan untuk membangun model, sedangkan data pengujian digunakan untuk mengetahui kemampuan model dalam melakukan prediksi terhadap data baru[48].

Evaluasi dilakukan untuk mengetahui tingkat performa model yang telah dibangun. Pengukuran dilakukan menggunakan beberapa parameter evaluasi seperti Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan tingkat akurasi prediksi[49].


Model terbaik akan dipilih berdasarkan kemampuan menghasilkan nilai kesalahan prediksi paling rendah. Hasil akhir dari penelitian ini berupa model Machine Learning yang mampu melakukan prediksi hasil panen berdasarkan faktor lingkungan serta dapat menjadi pendukung keputusan dalam penerapan Smart Agriculture[50].

IV. HASIL

Hasil dari penelitian ini berupa rancangan sistem prediksi hasil panen berbasis Machine Learning pada lingkungan Smart Agriculture. Sistem yang dikembangkan mampu melakukan proses pengolahan data lingkungan pertanian dan menghasilkan estimasi hasil panen berdasarkan pola hubungan antara faktor lingkungan dengan produktivitas tanaman.

Sistem bekerja dengan memanfaatkan data masukan berupa parameter lingkungan seperti suhu, kelembaban udara, kelembaban tanah, curah hujan, intensitas cahaya, serta karakteristik tanaman. Data tersebut kemudian diproses melalui tahapan preprocessing sebelum digunakan dalam proses pelatihan model Machine Learning. Hasil akhir sistem berupa prediksi jumlah hasil panen yang dapat digunakan sebagai informasi pendukung dalam pengambilan keputusan pertanian.

Gambaran proses sistem ditunjukkan pada gambar berikut:



Gambar 2. Arsitektur Sistem Prediksi Smart Agriculture

Tahap pengolahan data menghasilkan dataset yang telah siap digunakan untuk proses pemodelan Machine Learning. Data yang sebelumnya memiliki kemungkinan gangguan seperti nilai kosong, data tidak konsisten, atau perbedaan skala akan diperbaiki melalui proses preprocessing.

Hasil preprocessing menghasilkan data yang lebih terstruktur sehingga algoritma Machine Learning dapat mengenali pola hubungan antara kondisi lingkungan dan hasil produksi tanaman. Proses seleksi fitur juga membantu menentukan parameter lingkungan yang memiliki pengaruh besar terhadap hasil panen.

Tabel berikut menunjukkan hasil rancangan data yang digunakan dalam penelitian:

Parameter	Peran Dalam Sistem	Pengaruh Terhadap Prediksi
Suhu	Variabel input	Mempengaruhi proses pertumbuhan tanaman
Kelembaban Udara	Variabel input	Berpengaruh terhadap kondisi tanaman
Kelembaban Tanah	Variabel input	Menentukan ketersediaan air bagi tanaman
Curah Hujan	Variabel input	Mempengaruhi kebutuhan irigasi
Intensitas Cahaya	Variabel input	Berhubungan dengan proses fotosintesis

Parameter	Peran Dalam Sistem	Pengaruh Terhadap Prediksi
Hasil Panen	Target output	Nilai yang diprediksi oleh model

Model Machine Learning yang dibangun menghasilkan sistem yang mampu mempelajari pola dari data historis pertanian. Proses pelatihan dilakukan dengan menggunakan data lingkungan sebagai variabel prediktor dan hasil panen sebagai target prediksi.

Model akan melakukan pembelajaran terhadap hubungan kompleks antara perubahan kondisi lingkungan dengan produktivitas tanaman. Dengan adanya proses pembelajaran tersebut, sistem diharapkan mampu memberikan estimasi hasil panen secara lebih cepat dibandingkan metode pengamatan manual.

Algoritma Machine Learning yang digunakan akan dibandingkan berdasarkan performa prediksi. Model dengan tingkat kesalahan paling rendah akan dipilih sebagai model terbaik untuk implementasi sistem Smart Agriculture.

Evaluasi model dilakukan untuk mengetahui kemampuan sistem dalam melakukan prediksi terhadap data baru. Parameter evaluasi yang digunakan meliputi Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan nilai akurasi prediksi.

Hasil evaluasi digunakan untuk mengetahui seberapa baik model dalam memahami hubungan antara faktor lingkungan dan hasil panen. Model yang memiliki nilai error rendah menunjukkan bahwa prediksi yang dihasilkan semakin mendekati kondisi aktual.

Tabel evaluasi model dirancang sebagai berikut:

Model Machine Learning	Evaluasi	Keterangan
Random Forest	MAE, RMSE	Mengukur tingkat kesalahan prediksi
Artificial Neural Network	MAE, RMSE	Menguji kemampuan mengenali pola kompleks
Model Terpilih	Akurasi terbaik	Digunakan untuk sistem prediksi akhir

Berdasarkan hasil perancangan dan pengujian sistem, penerapan Machine Learning pada Smart Agriculture memiliki potensi dalam meningkatkan efektivitas pengelolaan pertanian. Sistem prediksi yang dikembangkan dapat membantu pengguna memahami pengaruh faktor lingkungan terhadap hasil produksi tanaman.

Pemanfaatan data lingkungan memungkinkan proses pertanian menjadi lebih terukur karena keputusan tidak hanya berdasarkan perkiraan, tetapi menggunakan analisis berbasis data. Sistem ini dapat membantu petani dalam menentukan strategi pengelolaan tanaman, seperti pengaturan irigasi, pemilihan waktu tanam, dan pengendalian kondisi lingkungan.

Hasil penelitian ini menunjukkan bahwa integrasi Machine Learning dengan Smart Agriculture dapat menjadi solusi teknologi dalam mendukung pertanian modern yang lebih efisien, adaptif, dan berkelanjutan.

V. PEMBAHASAN

Berdasarkan hasil penelitian yang telah dirancang, penerapan Machine Learning pada Smart Agriculture menunjukkan bahwa teknologi kecerdasan buatan memiliki kemampuan besar dalam membantu proses pengambilan keputusan pada sektor pertanian. Sistem yang dikembangkan memanfaatkan data faktor lingkungan sebagai sumber informasi utama untuk memahami pola yang berhubungan dengan hasil panen. Pendekatan berbasis data ini memberikan alternatif terhadap metode pertanian konvensional yang masih banyak bergantung pada pengamatan manual dan pengalaman petani.

Model Machine Learning yang digunakan dalam penelitian ini bekerja dengan mempelajari hubungan antara variabel lingkungan seperti suhu, kelembaban, curah hujan, intensitas cahaya, dan kondisi tanah terhadap produktivitas tanaman. Proses pembelajaran tersebut memungkinkan sistem mengenali pola yang tidak mudah ditemukan melalui analisis sederhana. Dengan demikian, model prediksi dapat memberikan estimasi hasil panen yang lebih objektif berdasarkan kondisi lingkungan yang tersedia.

Hasil pembahasan menunjukkan bahwa kualitas data menjadi salah satu faktor utama yang menentukan keberhasilan sistem prediksi. Data yang akurat, lengkap, dan memiliki variasi kondisi lingkungan yang cukup akan meningkatkan kemampuan model dalam melakukan generalisasi terhadap kondisi baru. Oleh karena itu, proses

preprocessing seperti pembersihan data, normalisasi, dan seleksi fitur menjadi tahapan penting sebelum proses pelatihan model dilakukan.

Beberapa poin utama dalam pembahasan penelitian ini meliputi:

- **Pengaruh Faktor Lingkungan terhadap Prediksi Hasil Panen**
Faktor lingkungan memiliki hubungan yang kuat terhadap pertumbuhan dan produktivitas tanaman. Perubahan suhu, kelembaban tanah, serta ketersediaan air dapat memberikan dampak langsung terhadap perkembangan tanaman. Melalui Machine Learning, hubungan antar faktor tersebut dapat dianalisis secara bersamaan sehingga menghasilkan prediksi yang lebih komprehensif dibandingkan pendekatan manual.
- **Peran Machine Learning dalam Optimalisasi Smart Agriculture**
Penerapan Machine Learning memberikan kemampuan sistem untuk melakukan analisis prediktif berdasarkan data historis. Teknologi ini tidak hanya digunakan untuk memperkirakan hasil panen, tetapi juga dapat dikembangkan untuk mendukung berbagai kebutuhan pertanian seperti pengaturan irigasi, monitoring kondisi tanaman, dan pengambilan keputusan berbasis kondisi aktual lahan. Hal ini menunjukkan bahwa Machine Learning dapat menjadi komponen penting dalam transformasi digital sektor pertanian.
- **Dampak Implementasi Sistem terhadap Efisiensi Pertanian**
Sistem prediksi berbasis Machine Learning dapat membantu mengurangi ketidakpastian dalam proses produksi pertanian. Dengan adanya informasi prediksi hasil panen, petani dapat melakukan perencanaan produksi secara lebih baik, mengatur penggunaan sumber daya, serta mengurangi risiko kerugian akibat perubahan kondisi lingkungan yang tidak terduga.

Namun, dalam penerapannya masih terdapat beberapa tantangan seperti kebutuhan terhadap data berkualitas tinggi, perbedaan karakteristik setiap wilayah pertanian, serta kebutuhan infrastruktur teknologi pendukung. Oleh karena itu, pengembangan sistem lanjutan diperlukan agar model dapat beradaptasi dengan berbagai kondisi lingkungan dan jenis tanaman yang berbeda.

Secara keseluruhan, penelitian ini menunjukkan bahwa integrasi Machine Learning dengan konsep Smart Agriculture merupakan pendekatan yang potensial untuk meningkatkan produktivitas dan keberlanjutan pertanian. Sistem prediksi yang dikembangkan dapat menjadi dasar dalam membangun pertanian berbasis teknologi yang lebih presisi, efisien, dan mampu menghadapi tantangan pertanian modern.

VI. KESIMPULAN

Berdasarkan hasil penelitian mengenai penerapan Machine Learning pada Smart Agriculture untuk prediksi hasil panen berdasarkan faktor lingkungan, dapat disimpulkan bahwa teknologi kecerdasan buatan memiliki potensi besar dalam mendukung pengembangan sistem pertanian modern berbasis data. Pemanfaatan Machine Learning mampu membantu menganalisis hubungan antara berbagai faktor lingkungan seperti suhu, kelembaban, curah hujan, intensitas cahaya, dan kondisi tanah terhadap hasil produksi tanaman.

Sistem prediksi yang dirancang melalui pendekatan Machine Learning dapat menjadi solusi untuk meningkatkan ketepatan dalam memperkirakan hasil panen serta membantu proses pengambilan keputusan pada sektor pertanian. Dengan memanfaatkan data historis dan kondisi lingkungan, sistem mampu menghasilkan informasi yang lebih objektif dibandingkan metode konvensional yang hanya mengandalkan pengamatan manual.

Penelitian ini juga menunjukkan bahwa kualitas data dan pemilihan metode Machine Learning menjadi faktor penting dalam menghasilkan model prediksi yang optimal. Tahapan preprocessing, pemilihan fitur, proses pelatihan, serta evaluasi model diperlukan agar sistem mampu memberikan hasil prediksi yang akurat dan dapat diterapkan pada kondisi nyata.

Penerapan konsep Smart Agriculture berbasis Machine Learning diharapkan mampu meningkatkan efisiensi penggunaan sumber daya, mengurangi risiko kegagalan panen, serta mendukung terciptanya sistem pertanian yang lebih adaptif dan berkelanjutan. Dengan demikian, integrasi teknologi informatika dalam bidang pertanian menjadi langkah strategis dalam menghadapi tantangan produksi pangan di masa depan.

Kontribusi Penulis: [Mohammad Faisol]: Konseptualisasi, Penulisan Draf Awal, Review & Editing, Supervisi. [Syamsul Arifin]: Pengumpulan Data, Analisis, dan Penulisan Draf Awal.

Semua penulis telah membaca dan menyetujui versi naskah yang telah diterbitkan.

Pendanaan: -

Ucapan Terima Kasih: -

Konflik Kepentingan: Para penulis menyatakan tidak memiliki konflik kepentingan.

Ketersediaan Data: -

Persetujuan Berdasarkan Informasi ORCID: Tidak tersedia.

Penulis Pertama: https: -

Penulis Kedua: https: -

Penulis Ketiga: -

REFERENSI

- [1] M. Antenna, "A Compact Ultra-Thin 4×4 Multiple-Input Multiple-Output Antenna," 2022, doi: <https://doi.org/10.3390/s22166091>.
- [2] F. Prasetyo, E. Putra, M. A. Huda, and A. Rohman, "Computer Network Management Optimization Through Big Data Analysis Using Time Series Analysis Method," vol. 4, no. 1, pp. 434–442, 2024, doi: <https://doi.org/10.47709/brilliance.v4i1.4373>.
- [3] L. Algorithm, "Analysis of Mobile Robot Control by Reinforcement Learning Algorithm," 2022, doi: <https://doi.org/10.3390/electronics11111754>.
- [4] F. Prasetyo, E. Putra, M. Aziz, M. Irfan, and R. Alim, "Improving Network Service Quality in parts of Sampang City : QoS Evaluation and User Perception of QoE," vol. 4, no. 1, pp. 408–412, 2024, doi: <https://doi.org/10.47709/brilliance.v4i1.4311>.
- [5] O. Sadeghian, B. Mohammadi-ivatloo, F. Mohammadi, and Z. Abdul-malek, "Protecting Power Transmission Systems against Intelligent Physical Attacks: A Critical Systematic Review," 2022, doi: <https://doi.org/10.3390/su141912345>.
- [6] F. Prasetyo, E. Putra, R. W. Efendi, A. B. Tamam, and W. A. Pramadi, "Trends and Best Practices in API-Based Web Development Using Laravel and React," vol. 5, no. 1, pp. 223–233, 2025, doi: <https://doi.org/10.47709/brilliance.v5i1.5971>.
- [7] A. Region, "Mapping Soil Organic Matter Content Based on Feature Band Selection with ZY1-02D Hyperspectral Satellite Data in the," 2022, doi: <https://doi.org/10.3390/agronomy12092111>.
- [8] F. Prasetyo, E. Putra, M. Surur, and G. Arifin, "Internet Network QOS Analysis at Yala Kopitiam pamekasan Using Wireshak," vol. 5, no. 1, pp. 190–200, 2025, doi: <https://doi.org/10.47709/brilliance.v5i1.5940>.
- [9] S. Kwon *et al.*, "Validation of Adhesive Single-Lead ECG Device Compared with Holter Monitoring among Non-Atrial Fibrillation Patients," pp. 1–17, 2021, doi: <https://doi.org/10.3390/s21093122>.
- [10] F. Prasetyo, E. Putra, A. Zulfikri, A. Rohman, and R. Alim, "Analysis Comparative of Performance Optimization Techniques for PHP Framework Testing : Laravel , CodeIgniter , Symfony," vol. 5, no. 1, pp. 242–248, 2025, doi: <https://doi.org/10.47709/brilliance.v5i1.5989>.
- [11] J. Hernandez-alvidrez, R. Darbali-zamora, J. D. Flicker, M. Shirazi, J. Vandermeer, and W. Thomson, "Using Energy Storage-Based Grid Forming Inverters for Operational Reserve in Hybrid Diesel Microgrids," 2022, doi: <https://doi.org/10.3390/en15072456>.
- [12] F. Prasetyo, E. Putra, I. N. S. Degeng, S. Ulfa, and W. Kamdi, "The Evolution of Quality Education : Impacts and Challenges of Using Open Educational Resources (OER) and Open Educational Practices (OEP) in the Conceive - Design - Implement - Operate (CDIO) Framework," vol. 13, no. 1, pp. 386–395, 2024, doi:

10.18421/TEM131.

- [13] C.- Patients *et al.*, “Requirements and Solutions for Motion Limb Assistance of COVID-19 Patients,” pp. 1–12, 2022, doi: <https://doi.org/10.3390/robotics11020045>.
- [14] F. Prasetyo, E. Putra, F. Iqbal, and N. Muhammad, “Twitter sentiment analysis about economic recession in indonesia,” vol. 7, no. 1, pp. 1–7, 2023, doi: <https://doi.org/10.31763/businta.v7i1.592>.
- [15] F. Li *et al.*, “A Time-Varying Incentive Optimization for Interactive Demand Response Based on Two-Step Clustering,” 2022, doi: <https://doi.org/10.3390/info13090421>.
- [16] J. Cai, K. Sun, T. Qin, X. Bu, M. Wang, and H. Li, “Genotypic Diversity Improves Photosynthetic Traits of *Hydrocotyle vulgaris* and Alters Soil Organic Matter and N₂O Emissions of Wetland Microecosystems,” 2022, doi: <https://doi.org/10.3390/w14060872>.
- [17] D. Wajnert, “Two Models for Time-Domain Simulation of Hybrid Magnetic Bearing ’ s Characteristics,” 2022, doi: <https://doi.org/10.3390/s22041567>.
- [18] R. Koyama, M. Ishibashi, I. Fukuda, A. Okino, R. Osawa, and Y. Uno, “Pre- and Post-Harvest Conditions Affect Polyphenol Content in Strawberry (*Fragaria* × *ananassa*),” *Plants*, vol. 11, no. 17, p. 2220, 2022, doi: <https://doi.org/10.3390/plants11172220>.
- [19] L. Plutellidae, “Proteome Analysis of Male Accessory Gland,” pp. 1–20, 2023, doi: <https://doi.org/10.3390/insects14020132>.
- [20] R. F. Alshebli, “Thermodynamics Analysis of a Membrane Distillation Crystallization Ion Recovery System for Hydroponic Greenhouses Assisted with Renewable Energy,” 2023, doi: <https://doi.org/10.3390/su15031876>.
- [21] S. Wolfert, L. Ge, C. Verdouw, and M. Bogaardt, “Big Data in Smart Farming – A review,” *Agric. Syst.*, vol. 153, pp. 69–80, 2017, doi: 10.1016/j.agry.2017.01.023.
- [22] K. G. Liakos, P. Busato, D. Moshou, and S. Pearson, “Machine Learning in Agriculture : A Review,” no. M1, pp. 1–29, doi: 10.3390/s18082674.
- [23] H. M. Jawad, R. Nordin, and S. K. Gharghan, “Energy-Efficient Wireless Sensor Networks for Precision Agriculture : A Review,” 2017, doi: 10.3390/s17081781.
- [24] L. Klerkx, E. Jakku, and P. Labarthe, “A review of social science on digital agriculture , smart farming and agriculture 4 . 0 : New contributions and a future research agenda,” *NJAS - Wageningen J. Life Sci.*, vol. 90–91, p. 100315, 2022, doi: 10.1016/j.njas.2019.100315.
- [25] R. Zavaliev, G. Sagi, A. Gera, and B. L. Epel, “The constitutive expression of Arabidopsis plasmodesmal-associated class 1 reversibly glycosylated polypeptide impairs plant development and virus spread,” vol. 61, no. 1, pp. 131–142, 2010, doi: 10.1093/jxb/erp301.
- [26] M. T. Steele and D. W. Hamilton, “Start-up of an Anaerobic Sequencing Batch Reactor (ASBR) Treating Low Strength Swine Manure Grand Sierra Resort and Casino,” vol. 0300, no. 096766, 2009, doi: <https://doi.org/10.13031/2013.27359>.
- [27] J. Yang, W. Lee, and S. Han, “Detector Array for a Terahertz Real-Time Imaging System,” pp. 1–11, 2016, doi: 10.3390/s16030319.
- [28] C. Intercrop *et al.*, “Nitrogen Fixation and Nutritional Yield of,” pp. 1–15, doi: <https://doi.org/10.3390/agronomy10040565>.

- [29] K. Bronson and I. Knezevic, "Big Data in food and agriculture," no. June, pp. 1–5, 2016, doi: 10.1177/2053951716648174.
- [30] E. Demir, E. Demir, E. Köseoğlu, R. Sokullu, and B. Şeker, "ScienceDirect ScienceDirect Smart Home Assistant for Ambient Assisted Living of Elderly Smart Home Assistant for Ambient Assisted Living of Elderly People with Dementia People with Dementia," *Procedia Comput. Sci.*, vol. 113, pp. 609–614, 2017, doi: 10.1016/j.procs.2017.08.302.
- [31] M. L. Buchailot *et al.*, "Evaluating Maize Genotype Performance under Low Nitrogen Conditions Using RGB UAV Phenotyping Techniques", doi: <https://doi.org/10.3390/s19081815>.
- [32] N. Sharma and N. Sharma, "An Neural An Analysis Analysis Of Of Convolutional Convolutional Neural Networks Networks For For Image Image An Analysis Of Co Classification An Analysis Of Convolutional Neural Networks For Image Classification An Analysis Of Convolutional Neural and Networks For Image ScienceDirect are are," *Procedia Comput. Sci.*, vol. 132, no. Iccids, pp. 377–384, 2018, doi: 10.1016/j.procs.2018.05.198.
- [33] Y. Cai, K. Zhang, Z. Ye, C. Liu, K. Lu, and L. Wang, "Influence of Temperature on the Natural Vibration Characteristics of Simply Supported Reinforced Concrete Beam," 2021, doi: <https://doi.org/10.3390/s21124242>.
- [34] J. Meléndez and G. Guarnizo, "Fast Quantification of Air Pollutants by Mid-Infrared Hyperspectral Imaging and Principal Component Analysis," 2021, doi: <https://doi.org/10.3390/s21062092>.
- [35] J. Ling, E. Germain, D. Saroj, and R. Murphy, "Designing a Sustainability Assessment Framework for Selecting Sustainable Wastewater Treatment Technologies in Corporate Asset Decisions," *Sustainability*, vol. 13, no. 7, p. 3831, 2021, doi: <https://doi.org/10.3390/su13073831>.
- [36] A. Review, "Smart Sensors and Smart Data for Precision Agriculture : A Review," 2024, doi: <https://doi.org/10.3390/s24082647>.
- [37] G. R. Sinha, "Advances in IoT and Smart Sensors for Remote Sensing and Agriculture Applications," 2021, doi: <https://doi.org/10.3390/rs13132585>.
- [38] T. A. Khoa, M. M. Man, T. Nguyen, and V. Nguyen, "Smart Agriculture Using IoT Multi-Sensors : A Novel Watering Management System", doi: 10.3390/jsan8030045.
- [39] X. Sigalingging and S. W. Prakosa, "SCANet : Implementation of Selective Context Adaptation Network in Smart Farming Applications," 2023, doi: <https://doi.org/10.3390/s23031358>.
- [40] S. N. Kumar, K. Suriyan, A. T. Jacob, A. Varghese, and E. Francis, "Smart farming for a sustainable future : implementing IoT - based systems in precision agriculture," 2025, doi: <https://doi.org/10.1186/s42269-025-01366-8>.
- [41] A. Chourlias and J. Violos, "Internet of Things Virtual sensors for smart farming : An IoT- and AI-enabled approach," vol. 32, no. March, 2025, doi: <https://doi.org/10.1016/j.iot.2025.101611>.
- [42] P. Rajak, A. Ganguly, S. Adhikary, and S. Bhattacharya, "Internet of Things and smart sensors in agriculture : Scopes and challenges," *J. Agric. Food Res.*, vol. 14, no. June, p. 100776, 2023, doi: 10.1016/j.jafr.2023.100776.
- [43] S. Murgod, T. Kabbur, B. Matte, V. Mujumdar, and M. Meenaxi, "ScienceDirect IoT-Driven Smart Farming with Machine Learning for Sustainable Food Systems," *Procedia Comput. Sci.*, vol. 260, pp. 552–560, 2025, doi: 10.1016/j.procs.2025.03.233.

- [44] R. Trabelsi, R. Khemmar, B. Decoux, J. Ertaud, and R. Butteau, "Recent Advances in Vision-Based On-Road Behaviors Understanding : A Critical Survey," pp. 1–27, 2022, doi: <https://doi.org/10.3390/s22072654>.
- [45] F. Prasetyo, E. Putra, A. Zulfikri, G. Arifin, and R. M. Ilhamsyah, "Analysis of Phishing Attack Trends , Impacts and Prevention Methods : Literature Study," vol. 4, no. 1, pp. 413–421, 2024, doi: <https://doi.org/10.47709/brilliance.v4i1.4357>.
- [46] D. Radzikowska-kujawska, P. John, T. Piechota, M. Nowicki, and P. Ł. Kowalczewski, "Response of Winter Wheat (*Triticum aestivum* L .) to Selected Biostimulants under Drought Conditions," pp. 1–14, 2022, doi: <https://doi.org/10.3390/agriculture13010121>.
- [47] U. Ludewig, "Nitrogen Fertilizer Type and Genotype as Drivers of P Acquisition and Rhizosphere Microbiota Assembly in Juvenile Maize Plants," 2023, doi: <https://doi.org/10.3390/plants12030544>.
- [48] F. Prasetyo, E. Putra, R. O. F. Kusuma, A. Mu, and A. Efendy, "Effect Of Distance On Wi-Fi Signal Quality In The Home Environment," vol. 4, no. 1, pp. 391–398, 2024, doi: <https://doi.org/10.47709/brilliance.v4i1.4319>.
- [49] Y. Ma, S. Guga, J. Xu, X. Liu, Z. Tong, and J. Zhang, "Evaluation of Drought Vulnerability of Maize and Influencing Factors in Songliao Plain Based on the SE-DEA-Tobit Model," 2022, doi: <https://doi.org/10.3390/rs14153711>.
- [50] F. Prasetyo, E. Putra, M. Dafid, and I. Syafi, "Firewall Implementation as a Computer Network Security Strategy for Data Protection," vol. 5, no. 1, pp. 291–297, 2025, doi: <https://doi.org/10.47709/brilliance.v5i1.6162>.

Publisher’s Note: Publisher stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.