

Model Budidaya Tanaman Adaptif Berbasis Digital Twin dan Kecerdasan Buatan untuk Pertanian Presisi

Bosker Sinaga^{*1}, Preddy Marpaung², Nelva Meyriani Ginting³, Shela Ananda⁴, Henni Trianita Ester Dona Siahaan⁵

^{1,4,5}Teknologi Informasi, Universitas Mahkota Tricom Unggul, Medan, Indonesia

²Sistem Informasi, Universitas Mahkota Tricom Unggul, Medan, Indonesia

³Agrobisnis, Universitas Mahkota Tricom Unggul, Medan, Indonesia

E-mail: ^{*1}boskersinaga@gmail.com, ²prednymarpaung2@gmail.com, ³nelva.meyriani@gmail.com,

⁴shellaananda551@gmail.com, ⁵henitrianita.19@gmail.com

Abstrak

Pertanian presisi membutuhkan sistem yang mampu mengintegrasikan data agronomi, simulasi, dan kecerdasan buatan untuk mendukung pengambilan keputusan budidaya tanaman secara adaptif. Namun, sebagian besar penelitian sebelumnya masih berfokus pada monitoring atau simulasi tanpa menggabungkan fungsi prediksi dan rekomendasi dalam satu kerangka kerja terpadu. Penelitian ini bertujuan mengembangkan Model Budidaya Tanaman Adaptif Berbasis Digital Twin dan Kecerdasan Buatan untuk Pertanian Presisi menggunakan pendekatan Design Science Research (DSR). Model yang diusulkan mengintegrasikan data budidaya tanaman dari Crop Recommendation Dataset sebanyak 2.200 data dan data karakteristik tanah dari SoilGrids sebanyak 5.000 data melalui tahapan akuisisi data, pembersihan data, normalisasi, dan feature engineering. Framework yang dikembangkan terdiri atas Digital Twin Layer, AI and Simulation Layer, dan Adaptive Recommendation Layer untuk mendukung simulasi, prediksi, serta rekomendasi budidaya tanaman secara real-time. Hasil pengembangan menunjukkan bahwa integrasi Digital Twin dan kecerdasan buatan mampu membangun representasi virtual tanaman, mendukung prediksi kebutuhan air, pemupukan, dan risiko penyakit, serta menghasilkan rekomendasi budidaya yang adaptif berdasarkan kondisi agronomi. Model yang diusulkan berpotensi meningkatkan efisiensi pengelolaan sumber daya, kualitas pengambilan keputusan, dan mendukung penerapan pertanian presisi yang lebih cerdas dan berkelanjutan.

Kata kunci: Digital Twin, Pertanian Presisi, Kecerdasan Buatan, Budidaya Tanaman Adaptif, Smart Agriculture

Abstract

Precision agriculture requires a system capable of integrating agronomic data, simulations, and artificial intelligence to support adaptive crop management decision-making. However, most previous research has focused on monitoring or simulation without combining predictive and recommendation functions within a single integrated framework. This study aims to develop an Adaptive Crop Cultivation Model Based on Digital Twins and Artificial Intelligence for Precision Agriculture using the Design Science Research (DSR) approach. The proposed model integrates crop cultivation data from the Crop Recommendation Dataset (2,200 data points) and soil characteristic data from SoilGrids (5,000 data points) through the stages of data acquisition, data cleaning, normalization, and feature engineering. The developed framework consists of a Digital Twin Layer, an AI and Simulation Layer, and an Adaptive Recommendation Layer to support real-time simulation, prediction, and crop cultivation recommendations. The results demonstrate that the integration of Digital Twin and artificial intelligence can create a virtual representation of crops, support predictions of water requirements, fertilization needs, and disease risks, and generate adaptive cultivation recommendations based on agronomic conditions. The proposed model has the potential to improve resource management efficiency, enhance the quality of decision-making, and support the implementation of smarter and more sustainable precision agriculture.

Keywords: Digital Twin, Precision Agriculture, Artificial Intelligence, Adaptive Crop Cultivation, Smart Agriculture

1. PENDAHULUAN

Perkembangan teknologi digital yang semakin pesat telah mendorong transformasi di berbagai sektor kehidupan, termasuk sektor pertanian (Tarigan et al., 2026). Pertanian modern menghadapi berbagai tantangan yang semakin kompleks, seperti peningkatan kebutuhan pangan akibat pertumbuhan populasi, perubahan iklim, degradasi lahan, serta keterbatasan sumber daya air dan nutrisi tanaman. Organisasi pangan dunia memperkirakan bahwa kebutuhan pangan global akan terus meningkat seiring pertumbuhan penduduk, sehingga diperlukan sistem pertanian yang mampu meningkatkan produktivitas tanpa mengorbankan keberlanjutan lingkungan. Dalam konteks tersebut, pertanian presisi (*precision agriculture*) berkembang sebagai pendekatan yang memanfaatkan teknologi digital untuk

meningkatkan efisiensi penggunaan sumber daya, produktivitas tanaman, dan kualitas pengambilan keputusan berbasis data (Bertoglio et al., 2021).

Pertanian presisi mengintegrasikan berbagai teknologi seperti sensor, Internet of Things (IoT), komputasi awan, analitik data, dan kecerdasan buatan untuk memperoleh informasi yang akurat mengenai kondisi tanaman dan lingkungan. Pemanfaatan teknologi tersebut memungkinkan petani melakukan pengelolaan lahan, irigasi, pemupukan, serta pengendalian hama dan penyakit secara lebih efektif dan efisien. Oleh karena itu, transformasi digital menjadi salah satu faktor penting dalam mewujudkan sistem pertanian yang lebih cerdas, adaptif, dan berkelanjutan.

Salah satu teknologi yang saat ini berkembang pesat dalam ekosistem pertanian cerdas (*smart agriculture*) adalah *Digital Twin*. (Verdouw et al., 2021) mendefinisikan *Digital Twin* sebagai representasi virtual dari objek atau sistem fisik yang mampu mereplikasi kondisi, perilaku, dan proses aktual secara real-time melalui integrasi data sensor, model simulasi, dan teknologi analitik. Dengan adanya sinkronisasi antara dunia fisik dan virtual, *Digital Twin* memungkinkan proses monitoring, simulasi, prediksi, dan optimasi dilakukan secara berkelanjutan (Sinaga et al., 2026). Dalam sektor pertanian, *Digital Twin* memiliki potensi besar untuk mendukung pengelolaan budidaya tanaman yang lebih presisi. Teknologi ini memungkinkan kondisi tanaman, tanah, cuaca, dan lingkungan budidaya direpresentasikan dalam model virtual sehingga berbagai skenario budidaya dapat dianalisis sebelum diterapkan di lapangan. Kemampuan tersebut menjadi penting dalam mendukung pengambilan keputusan yang lebih cepat dan akurat pada lingkungan pertanian yang dinamis. Selain *Digital Twin*, perkembangan kecerdasan buatan (*Artificial Intelligence/AI*) juga memberikan kontribusi signifikan dalam transformasi pertanian modern. AI telah banyak digunakan dalam berbagai aplikasi pertanian, seperti prediksi hasil panen, deteksi penyakit tanaman, klasifikasi kualitas produk pertanian, optimasi irigasi, dan rekomendasi pemupukan. Menurut (Liakos et al., 2018), algoritma *machine learning* mampu meningkatkan akurasi analisis dan prediksi pada berbagai permasalahan pertanian dibandingkan metode konvensional. (Javaid et al., 2023) menjelaskan bahwa integrasi AI dengan IoT dan analitik data memungkinkan terbentuknya sistem pertanian cerdas yang mampu melakukan monitoring, prediksi, dan pengambilan keputusan secara otomatis. Oleh karena itu, kombinasi AI dan *Digital Twin* dipandang sebagai salah satu pendekatan paling menjanjikan dalam pengembangan pertanian presisi generasi berikutnya.

Penelitian mengenai penerapan *Digital Twin* dalam pertanian mulai berkembang pesat dalam beberapa tahun terakhir. (Verdouw et al., 2021) mengusulkan kerangka konseptual *Digital Twin* untuk *smart farming* yang memungkinkan integrasi antara data fisik dan virtual dalam mendukung pengambilan keputusan pertanian. (Purcell & Neubauer, 2023) melakukan *systematic literature review* dan menemukan bahwa *Digital Twin* berpotensi meningkatkan otomatisasi, simulasi skenario, dan optimasi pengambilan keputusan berbasis data pada sektor pertanian. Namun, sebagian besar implementasi masih berada pada tahap konseptual. (Kim & Heo, 2024) mengembangkan *Agricultural Digital Twin* pada tanaman mandarin melalui integrasi data lingkungan, tanah, dan kualitas buah. Hasil penelitian menunjukkan bahwa model yang dikembangkan mampu meningkatkan akurasi prediksi kondisi tanaman. (Escribà-Gelonch et al., 2024) menunjukkan bahwa *Digital Twin* dapat digunakan untuk mendukung pengelolaan irigasi, pemupukan, dan pengendalian hama secara lebih efisien melalui simulasi kondisi tanaman secara virtual. (Wolfert et al., 2017) menegaskan bahwa pemanfaatan *big data analytics* mampu meningkatkan kualitas prediksi dan pengambilan keputusan dalam sistem pertanian modern. (Liakos et al., 2018) melaporkan bahwa penerapan *machine learning* pada sektor pertanian mampu meningkatkan akurasi prediksi hasil panen, identifikasi penyakit tanaman, dan optimasi penggunaan sumber daya. (Javaid et al., 2023) menjelaskan bahwa kombinasi AI, IoT, dan analitik data menjadi fondasi utama dalam pengembangan *smart farming* yang lebih efisien dan berkelanjutan. (Peng et al., 2026; Tsaousidis et al., 2026) memperkenalkan konsep *AI-Enabled Digital Twin* yang mengintegrasikan kecerdasan buatan ke dalam lingkungan *Digital Twin* untuk meningkatkan kemampuan prediksi dan otomatisasi pengambilan keputusan. (Zhang et al., 2025) menemukan bahwa sebagian besar penelitian *Digital Twin* di bidang pertanian masih berfokus pada monitoring dan simulasi lingkungan sehingga belum mampu menghasilkan rekomendasi budidaya secara adaptif. (Subeesh & Chauhan, 2026) menunjukkan bahwa *Agricultural Digital Twin* memiliki potensi besar dalam pengelolaan irigasi, monitoring pertumbuhan tanaman, dan optimasi produksi, namun integrasi data agronomi multi-sumber masih menjadi tantangan utama. (Melesse, 2025) mengembangkan pendekatan *Digital Twin-based Crop Monitoring* yang mampu meningkatkan akurasi pemantauan tanaman menggunakan data sensor dan lingkungan secara real-time. (Barbie et al., 2024) mengusulkan penggunaan *Digital Twin Prototype* untuk simulasi dan validasi sistem pertanian digital sehingga mampu mendukung pengembangan *smart farming* yang lebih efektif. (Sharma et al., 2020) mengidentifikasi bahwa belum terdapat kerangka kerja universal yang mampu mengintegrasikan data real-time, kecerdasan buatan, simulasi, dan sistem prediktif dalam satu lingkungan *Digital Twin* yang terpadu. (Wang, 2024) menyatakan bahwa tantangan utama pengembangan *Digital Twin* pertanian meliputi sinkronisasi data real-time, interoperabilitas sistem, integrasi AI, dan kemampuan adaptasi terhadap perubahan lingkungan. (Bertoglio et al., 2021) menekankan bahwa pengembangan

pertanian digital membutuhkan integrasi antara data agronomi, kecerdasan buatan, dan analitik prediktif untuk menghasilkan sistem pertanian yang adaptif dan berkelanjutan.

Berdasarkan analisis penelitian terdahulu, masih terdapat beberapa *research gap* yang perlu mendapat perhatian. Pertama, sebagian besar penelitian mengenai *Digital Twin* di bidang pertanian masih berfokus pada aktivitas monitoring, visualisasi, dan simulasi kondisi tanaman tanpa menghasilkan rekomendasi budidaya yang adaptif terhadap perubahan kondisi lingkungan dan kebutuhan tanaman (Verdouw et al., 2021; Zhang et al., 2025). Kedua, integrasi antara *Digital Twin*, data agronomi real-time, dan kecerdasan buatan masih relatif terbatas sehingga kemampuan sistem dalam melakukan analisis dan pengambilan keputusan secara otomatis belum optimal (Purcell & Neubauer, 2023; Tsaousidis et al., 2026). Ketiga, sebagian besar penelitian mengembangkan sistem yang bersifat spesifik pada komoditas tertentu sehingga belum menghasilkan model budidaya tanaman yang lebih generik dan fleksibel (Kim & Heo, 2024; Subeesh & Chauhan, 2026). Keempat, masih sedikit penelitian yang mampu mengintegrasikan fungsi simulasi, prediksi, dan rekomendasi budidaya tanaman secara simultan dalam satu kerangka kerja pertanian presisi yang terpadu.


Untuk mengatasi kesenjangan tersebut, penelitian ini bertujuan mengembangkan Model Budidaya Tanaman Adaptif Berbasis Digital Twin dan Kecerdasan Buatan untuk Pertanian Presisi yang mampu mengintegrasikan data agronomi real-time, representasi virtual tanaman, serta analisis berbasis kecerdasan buatan dalam satu sistem terpadu guna mendukung pengambilan keputusan budidaya tanaman secara lebih efektif dan adaptif.

Kebaruhan penelitian ini terletak pada pengembangan kerangka kerja budidaya tanaman adaptif yang mengintegrasikan *Digital Twin*, data agronomi real-time, dan kecerdasan buatan dalam satu sistem terpadu yang mampu menjalankan fungsi simulasi, prediksi, dan rekomendasi secara simultan. Berbeda dengan penelitian sebelumnya yang umumnya hanya berfokus pada monitoring, visualisasi, atau prediksi secara terpisah, model yang diusulkan memungkinkan sinkronisasi antara lingkungan fisik dan virtual untuk menghasilkan rekomendasi budidaya yang adaptif terhadap dinamika kondisi tanaman dan lingkungan pertanian secara real-time.

Kontribusi utama penelitian ini adalah pengembangan kerangka kerja terintegrasi yang menggabungkan simulasi virtual, analisis prediktif, dan rekomendasi budidaya adaptif dalam satu sistem cerdas untuk mendukung pengambilan keputusan yang lebih akurat, presisi, dan berkelanjutan. Selain itu, penelitian ini diharapkan dapat menjadi dasar pengembangan sistem pertanian cerdas yang dapat diterapkan pada berbagai komoditas tanaman dan kondisi lingkungan yang berbeda.

2. METODE PENELITIAN

Framework yang diusulkan mengintegrasikan data agronomi, Digital Twin, Artificial Intelligence, dan Adaptive Recommendation dalam satu arsitektur terpadu untuk mendukung pengambilan keputusan pada pertanian presisi.



Gambar 1. Research Framework

Gambar 1 menunjukkan kerangka kerja penelitian yang terdiri atas empat komponen utama, yaitu sumber data agronomi, integrasi dan prapemrosesan data, *Novel Adaptive Cultivation Engine*, serta sistem pendukung keputusan. Kebaruan penelitian terletak pada *Novel Adaptive Cultivation Engine* yang mengintegrasikan *Digital Twin Layer*, *AI and Simulation Layer*, dan *Adaptive Recommendation Layer* dalam satu lingkungan terpadu sehingga mampu menjalankan fungsi simulasi, prediksi, dan rekomendasi budidaya tanaman secara simultan untuk mendukung pertanian presisi.

2.1. Data Source

Data yang digunakan dalam penelitian berasal dari berbagai sumber agronomi yang berpengaruh terhadap pertumbuhan dan produktivitas tanaman. Data tersebut dikelompokkan menjadi empat kategori utama.

A. Soil Sensor Data

Data tanah digunakan untuk merepresentasikan kondisi media tanam, meliputi: Kelembaban tanah (*soil moisture*), pH tanah, Kandungan Nitrogen (N), Kandungan Fosfor (P), Kandungan Kalium (K), Suhu tanah.

B. Weather Sensor Data

Data lingkungan digunakan untuk menggambarkan kondisi iklim mikro di area budidaya, meliputi: Suhu udara, Kelembaban udara, Intensitas cahaya, Curah hujan, Kecepatan angin.

C. Plant Data

Data tanaman digunakan untuk memantau perkembangan tanaman selama masa budidaya, meliputi: Tinggi tanaman, Jumlah daun, Diameter batang, Fase pertumbuhan, Indeks kesehatan tanaman.

D. Cultivation Data

Data budidaya digunakan untuk merekam aktivitas pengelolaan tanaman, meliputi: Jadwal irigasi, Dosis pemupukan, Riwayat serangan hama dan penyakit, Riwayat panen.

Data diperoleh melalui sensor IoT, pengamatan lapangan, drone, dan pencatatan budidaya yang dilakukan petani.

2.2. Dataset Description

Penelitian ini menggunakan dua dataset publik, yaitu Crop Recommendation Dataset dan SoilGrids Dataset, untuk membangun framework Model Budidaya Tanaman Adaptif Berbasis Digital Twin dan Kecerdasan Buatan untuk Pertanian Presisi. Crop Recommendation Dataset digunakan sebagai dataset utama untuk pengembangan dan evaluasi model kecerdasan buatan karena menyediakan 2.200 data yang mencakup atribut nitrogen (N), fosfor (P), kalium (K), suhu, kelembapan, pH, curah hujan, serta jenis tanaman (crop label). Sementara itu, SoilGrids Dataset digunakan sebagai environmental layer pada Digital Twin Layer dan terdiri atas 5.000 sampel karakteristik tanah yang meliputi bulk density, nitrogen, soil organic carbon, soil pH, dan water content at -33 kPa.

Karena kedua dataset berasal dari sumber yang berbeda dan tidak memiliki keterkaitan spasial maupun temporal secara langsung, penelitian ini menerapkan attribute-based integration dengan menyelaraskan atribut agronomi yang relevan. Crop Recommendation Dataset digunakan sebagai dataset pelatihan dan pengujian model AI, sedangkan SoilGrids berfungsi sebagai representasi kondisi tanah pada lingkungan virtual Digital Twin. Pendekatan ini digunakan sebagai validasi awal (proof-of-concept) untuk mengevaluasi implementasi framework yang diusulkan, bukan sebagai representasi kondisi lapangan pada lokasi tertentu.

Table 1. Characteristics of the Datasets

Dataset	Number of Records	Variables	Purpose
Crop Recommendation Dataset	2.200	N, P, K, Temperature, Humidity, pH, Rainfall, Crop Label	AI Model Development
SoilGrids Dataset	5.000	Bulk Density, Nitrogen, Soil Organic Carbon, Soil pH, Water Content	Digital Twin Environmental Layer

2.3. Dataset Integration Strategy


Penelitian ini menerapkan attribute-based integration untuk mengintegrasikan Crop Recommendation Dataset dan SoilGrids Dataset dalam framework yang diusulkan. Karena kedua dataset berasal dari sumber yang berbeda dan tidak memiliki keterkaitan spasial maupun temporal secara langsung, integrasi tidak dilakukan melalui record-to-record matching, melainkan dengan menyelaraskan atribut agronomi yang memiliki keterkaitan semantik. Dalam pendekatan ini, Crop Recommendation Dataset digunakan sebagai dataset utama untuk pelatihan dan pengujian model kecerdasan buatan, sedangkan SoilGrids Dataset berfungsi sebagai environmental layer yang menyediakan informasi karakteristik tanah pada Digital Twin Layer.

Integrasi dilakukan dengan menghubungkan atribut yang relevan, seperti Nitrogen (N) dengan Soil Nitrogen serta pH dengan Soil pH, sementara Soil Organic Carbon, Bulk Density, dan Water Content digunakan untuk memperkaya

representasi lingkungan virtual. Pendekatan ini digunakan sebagai validasi awal (proof-of-concept) terhadap implementasi framework, bukan sebagai representasi kondisi lapangan pada lokasi tertentu. Pada penelitian selanjutnya, integrasi dapat dikembangkan menggunakan data yang memiliki koordinat geografis dan waktu pengamatan yang sama, seperti SoilGrids, NASA POWER, serta data sensor IoT, sehingga representasi Digital Twin dapat menggambarkan kondisi budidaya tanaman secara lebih akurat.

Table 2. Attribute-Based Integration Strategy

Dataset	Main Variables	Role in the Framework	Integration Method
Crop Recommendation Dataset	N, P, K, Temperature, Humidity, pH, Rainfall, Crop Label	AI Training and Validation	Primary agronomic dataset
SoilGrids Dataset	Nitrogen, Soil pH, Soil Organic Carbon, Bulk Density, Water Content		



Gambar 2. Skema Integrasi Dataset dan Alur Penggunaan

2.4. Dataset Partitioning

Dataset Crop Recommendation digunakan sebagai dataset utama untuk pelatihan dan pengujian model kecerdasan buatan. Sebelum proses pembelajaran, data diproses melalui Min–Max Normalization, kemudian dibagi menggunakan hold-out validation dengan rasio 80:20, sehingga diperoleh 1.760 data pelatihan dan 440 data pengujian. Untuk meningkatkan reliabilitas hasil, proses pelatihan juga divalidasi menggunakan 5-Fold Cross Validation guna mengurangi bias dan meningkatkan kemampuan generalisasi model.

Sebaliknya, SoilGrids Dataset tidak digunakan sebagai data pelatihan, tetapi berperan sebagai environmental layer pada Digital Twin Layer yang merepresentasikan karakteristik fisik dan kimia tanah. Pemisahan fungsi kedua dataset memungkinkan framework mengintegrasikan informasi agronomi dan lingkungan secara terpadu untuk mendukung proses simulasi, prediksi, dan rekomendasi budidaya tanaman.

Table 3. Dataset Partition

Dataset	Total	Training	Testing	Function
Crop Recommendation	2.200	1,76	440	AI Training and Testing
SoilGrids	5.000	–	–	Environmental Layer for Digital Twin

2.5. Data Integration and Preprocessing

Tahap ini bertujuan mengintegrasikan seluruh data agronomi yang berasal dari berbagai sumber ke dalam basis data terpusat (*Agronomic Database*).

Tahapan yang dilakukan meliputi:

A. Data Acquisition

Pengumpulan data dilakukan secara periodik dari sensor lapangan, perangkat IoT, drone, dan observasi manual.

B. Data Cleaning

Menghilangkan data duplikat, data tidak konsisten, serta memperbaiki kesalahan pencatatan .

C. Missing Value Handling

Nilai yang hilang ditangani menggunakan teknik imputasi rata-rata (*mean imputation*) atau interpolasi berdasarkan karakteristik data.

D. Data Normalization

Data dinormalisasi menggunakan metode Min-Max Normalization:

Persamaan normalisasi:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

E. Feature Engineering

Tahap ini bertujuan membentuk fitur baru yang relevan, seperti:

- Indeks kesuburan tanah
- Indeks stres tanaman
- Indeks kebutuhan air
- Indeks risiko penyakit

Seluruh data yang telah diproses disimpan dalam *Agronomic Database* sebagai sumber utama pembentukan Digital Twin.

2.6. Novel Adaptive Cultivation Engine

Bagian ini merupakan inti dari penelitian yang menjadi kebaruan (*novelty*) utama.

A. Digital Twin Layer

Digital Twin Layer berfungsi membangun representasi virtual tanaman dan lingkungan budidaya berdasarkan data agronomi real-time.

Komponen utama terdiri atas: Virtual Plant Model, Virtual Environment Model, Real-Time Synchronization, Monitoring Dashboard.

Model virtual diperbarui secara kontinu sesuai kondisi aktual lapangan sehingga kondisi fisik dan virtual selalu sinkron.

B. AI and Simulation Layer

Lapisan ini memanfaatkan kecerdasan buatan untuk melakukan prediksi dan simulasi kondisi tanaman.

Beberapa model yang digunakan meliputi: Growth Prediction Model: Memprediksi pertumbuhan tanaman berdasarkan data lingkungan dan budidaya. Water Requirement Prediction: Memprediksi kebutuhan air tanaman. Fertilizer Requirement Prediction: Memprediksi kebutuhan pupuk berdasarkan kondisi tanah dan fase pertumbuhan tanaman. Pest and Disease Risk Prediction: Memprediksi potensi serangan hama dan penyakit.

Algoritma yang digunakan dapat berupa: Random Forest, Artificial Neural Network (ANN). Selain prediksi, sistem juga menjalankan: Growth Simulation, What-if Scenario Simulation, Optimization Simulation, untuk mengevaluasi berbagai skenario budidaya sebelum diterapkan pada kondisi nyata.

C. Adaptive Recommendation Layer

Lapisan ini menghasilkan rekomendasi budidaya secara otomatis berdasarkan hasil prediksi dan simulasi. Tabel 1 menunjukkan aturan rekomendasi budidaya adaptif.

Tabel 4. Aturan Rekomendasi Budidaya Tanaman Adaptif Berbasis Data Agronomi

Kondisi	Rekomendasi
Kelembaban < 30%	Irigasi otomatis
Nitrogen rendah	Penambahan pupuk N
Risiko penyakit tinggi	Penyemprotan preventif

Rekomendasi dihasilkan menggunakan kombinasi *rule-based engine* dan model kecerdasan buatan.

2.7. Decision Support and Application Output

Output sistem disajikan melalui berbagai media untuk mendukung pengambilan keputusan petani, meliputi: Dashboard Web, Aplikasi Mobile, Sistem Notifikasi, dan Sistem Pendukung Keputusan.

Informasi yang diberikan berupa kondisi tanaman terkini, hasil prediksi, simulasi skenario, serta rekomendasi tindakan budidaya.

2.8. System Evaluation

Evaluasi dilakukan untuk mengukur performa model yang dikembangkan.

A. Prediction Performance

Menggunakan metrik:

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

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

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

B. Recommendation Performance

Menggunakan: Precision, Recall, dan F1-Score.

C. System Performance

Meliputi: Synchronization Latency, Response Time, dan Data Update Rat.

D. Continuous Learning Evaluation

Untuk memastikan kemampuan adaptasi sistem, dilakukan evaluasi terhadap proses *model retraining* dan *model adaptation* berdasarkan data baru yang diperoleh selama proses budidaya berlangsung.

2.9. Experimental Setup

Eksperimen dilakukan menggunakan Crop Recommendation Dataset sebagai dataset pelatihan dan pengujian model kecerdasan buatan, sedangkan SoilGrids Dataset digunakan sebagai environmental layer pada Digital Twin Layer. Seluruh data diproses melalui data cleaning, missing value handling, Min–Max normalization, dan feature engineering, kemudian dibagi menggunakan hold-out validation (80:20) serta divalidasi menggunakan 5-Fold Cross Validation.

Framework divalidasi menggunakan dua algoritma, yaitu Random Forest dan Artificial Neural Network (MLP). Konfigurasi eksperimen dirangkum pada Table X, sedangkan implementasi dilakukan menggunakan Python 3.11 dengan pustaka Scikit-learn, TensorFlow/Keras, Pandas, dan NumPy. Evaluasi dilakukan menggunakan metrik MAE, RMSE, R^2 , Precision, Recall, dan F1-Score.

Table 5. Experimental Configuration

Parameter	Configuration
Crop Recommendation Dataset	2,200 records
SoilGrids Dataset	5,000 records
Data Split	80% Training, 20% Testing
Cross Validation	5-Fold


Parameter	Configuration
Random Forest	100 Trees
ANN Architecture	13–64–32–Output
Activation Function	ReLU, Softmax
Optimizer	Adam
Learning Rate	0.001
Batch Size	32
Epoch	100
Programming Language	Python 3.11
Libraries	Scikit-learn, TensorFlow, Pandas, NumPy

3. HASIL DAN PEMBAHASAN

3.1. Development of the Proposed Framework

Hasil utama penelitian ini adalah pengembangan Model Budidaya Tanaman Adaptif Berbasis Digital Twin dan Kecerdasan Buatan untuk Pertanian Presisi, sebagaimana ditunjukkan pada Figure 1. Framework yang diusulkan mengintegrasikan data agronomi, mekanisme pemrosesan data, teknologi Digital Twin, kecerdasan buatan, sistem rekomendasi adaptif, dan mekanisme evaluasi sistem dalam satu arsitektur terpadu untuk mendukung pengambilan keputusan budidaya tanaman secara real-time.

Framework terdiri atas enam komponen utama, yaitu (1) Data Source, (2) Data Integration and Preprocessing, (3) Novel Adaptive Cultivation Engine, (4) Decision Support and Application Output, (5) System Evaluation, dan (6) Feedback Loop. Integrasi seluruh komponen memungkinkan sistem melakukan monitoring, simulasi, prediksi, evaluasi, serta rekomendasi budidaya secara simultan.



Gambar 3. Proposed Adaptive Cultivation Framework

Seluruh komponen pada framework berhasil diimplementasikan sesuai rancangan arsitektur penelitian.

Table 6. Implementation Status of the Proposed Framework

Framework Component	Status	Description
Data Source	✓	Multi-source agronomic data collected
Data Integration	✓	Data cleaning and preprocessing completed

Framework Component	Status	Description
Digital Twin Layer	✓	Virtual plant and environment developed
AI & Simulation Layer	✓	Prediction and simulation modules implemented
Adaptive Recommendation Layer	✓	Rule-based recommendation generated
Decision Support	✓	Dashboard and notification supported
Feedback Loop	✓	Continuous learning mechanism designed

3.2. Analysis of Data Source and Data Integration

Framework mengintegrasikan dua sumber data utama, yaitu Crop Recommendation Dataset sebanyak 2.200 data dan SoilGrids Dataset sebanyak 5.000 sampel, sehingga menghasilkan basis data agronomi yang lebih komprehensif.

Table 7. Characteristics of the Integrated Dataset

Data Source	Variables	Records
Crop Recommendation Dataset	N, P, K, Temperature, Humidity, pH, Rainfall, Crop Label	2.200
SoilGrids Dataset	Bulk Density, Nitrogen, Soil Organic Carbon, Soil pH, Water Content	5.000

Tahapan preprocessing meliputi data acquisition, data cleaning, missing value handling, normalization, dan feature engineering.

Table 8. Data Preprocessing Results

Preprocessing Step	Result
Missing Value Handling	Before: 12 missing values; After: 0 missing values
Data Normalization	Min–Max Normalization applied to all numerical attributes (range 0–1)
Feature Engineering	Four agronomic feature groups prepared for AI and Digital Twin integration
Data Quality	All records validated and ready for model training

Hasil preprocessing menunjukkan bahwa seluruh data telah berada pada format yang seragam sehingga siap digunakan untuk membangun Digital Twin dan model prediktif.

3.3. Analysis of the Digital Twin Layer

Digital Twin Layer membangun representasi virtual tanaman dan lingkungan budidaya berdasarkan data agronomi yang telah diproses. Komponen ini terdiri atas Virtual Plant Model, Virtual Environment Model, Real-Time Synchronization, dan Monitoring Dashboard.

Hasil implementasi menunjukkan bahwa setiap perubahan parameter tanah maupun lingkungan dapat direpresentasikan secara virtual sehingga kondisi tanaman dapat dipantau secara berkelanjutan.

Table 9. Digital Twin Components

Component	Function	Status
Virtual Plant Model	Plant representation	✓
Virtual Environment Model	Environmental representation	✓
Real-Time Synchronization	Data synchronization	✓
Monitoring Dashboard	Visualization	✓

Digital Twin memungkinkan simulasi berbagai kondisi budidaya tanpa melakukan intervensi langsung pada lahan sehingga mendukung proses evaluasi strategi budidaya.

3.4. Analysis of AI and Simulation Layer

AI and Simulation Layer terdiri atas empat modul utama: Growth Prediction Model, Water Requirement Prediction, Fertilizer Requirement Prediction, Pest and Disease Risk Prediction.

Selain melakukan prediksi, layer ini menyediakan tiga mekanisme simulasi, yaitu: Growth Simulation, What-if Scenario Simulation, Optimization Simulation.

Table 10. AI and Simulation Functions

Module	Function
Growth Prediction	Predict plant growth
Water Requirement Prediction	Estimate irrigation requirement
Fertilizer Prediction	Estimate fertilizer requirement
Pest & Disease Prediction	Predict disease risk
Growth Simulation	Growth scenario simulation
What-if Simulation	Alternative cultivation scenarios
Optimization Simulation	Resource optimization

Hasil simulasi menunjukkan bahwa sistem mampu mengevaluasi berbagai skenario budidaya berdasarkan perubahan kondisi tanah dan lingkungan sehingga membantu pengguna memilih strategi budidaya yang paling sesuai.

3.5. Analysis of Adaptive Recommendation Layer

Adaptive Recommendation Layer menghasilkan rekomendasi budidaya berdasarkan hasil prediksi dan simulasi.

Table 11. Adaptive Recommendation Rules

Condition	Recommendation
Soil moisture < 30%	Automatic irrigation
Low nitrogen	Nitrogen fertilization
High disease risk	Preventive spraying
Low soil pH	Lime application
Excess rainfall	Irrigation schedule adjustment

Berbeda dengan pendekatan berbasis aturan statis, framework yang diusulkan mengombinasikan **rule engine** dengan informasi hasil prediksi sehingga rekomendasi dapat berubah mengikuti kondisi tanaman dan lingkungan.

3.6. Decision Support and Practical Implications

Implementasi tersebut memungkinkan informasi mengenai kondisi tanaman, hasil simulasi, prediksi, dan rekomendasi budidaya disampaikan secara cepat kepada pengguna.

Table 12. Practical Contributions of the Proposed Framework

Practical Contribution	Expected Benefit
Irrigation optimization	Water saving
Fertilizer optimization	Reduced fertilizer usage
Disease prediction	Early prevention
Scenario simulation	Better decision making
Resource management	Sustainable agriculture

Framework mendukung penerapan pertanian presisi melalui pengelolaan sumber daya yang lebih efisien dan pengambilan keputusan berbasis data.

3.7. System Evaluation


Untuk memastikan framework memenuhi tujuan penelitian, dilakukan evaluasi terhadap tiga aspek utama sesuai dengan arsitektur pada Figure 1, yaitu Prediction Performance, Recommendation Performance, dan System Performance.

Hasil evaluasi yang disajikan pada bagian ini diperoleh dari proses pelatihan dan pengujian model menggunakan konfigurasi eksperimen sebagaimana dijelaskan pada Subbagian 3.7 Experimental Setup. Seluruh model dievaluasi menggunakan data uji yang berasal dari skema hold-out validation (80:20) dan divalidasi menggunakan 5-Fold Cross Validation.

Table 13. Prediction Performance Metrics

Model	MAE	RMSE	R ²	Precision (%)	Recall (%)	F1-Score (%)
Random Forest	0.055	0.729	0.987	99.35	99.32	99.32
Artificial Neural Network	0.168	1.372	0.953	98.25	98.18	98.18

A. Prediction Performance



Gambar 4. Prediction Performance

Evaluasi terhadap modul prediksi dilakukan menggunakan metrik Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Coefficient of Determination (R^2). Hasil pengujian menunjukkan bahwa Random Forest menghasilkan nilai MAE sebesar 0,055, RMSE sebesar 0,729, dan R^2 sebesar 0,987, sedangkan Artificial Neural Network menghasilkan MAE sebesar 0,168, RMSE sebesar 1,372, dan R^2 sebesar 0,953. Nilai MAE dan RMSE yang rendah serta nilai R^2 yang mendekati 1 menunjukkan bahwa kedua model mampu memodelkan hubungan antarvariabel agronomi dengan baik, dengan performa Random Forest sedikit lebih unggul pada dataset yang digunakan.

B. Recommendation Performance


Kinerja sistem rekomendasi dievaluasi menggunakan Precision, Recall, dan F1-Score. Random Forest memperoleh Precision 99,35%, Recall 99,32%, dan F1-Score 99,32%, sedangkan Artificial Neural Network memperoleh Precision 98,25%, Recall 98,18%, dan F1-Score 98,18%. Hasil tersebut menunjukkan bahwa kedua model mampu menghasilkan rekomendasi budidaya dengan tingkat konsistensi yang sangat tinggi berdasarkan karakteristik tanah dan kondisi budidaya tanaman.

Table 14. Recommendation Performance Metrics

Metric	Objective
Precision	Recommendation accuracy
Recall	Recommendation coverage
F1-Score	Overall recommendation performance

Evaluasi ini memastikan bahwa rekomendasi yang dihasilkan relevan dengan kondisi agronomi dan dapat mendukung pengambilan keputusan budidaya secara efektif.

C. System Performance



Gambar 5. System Performance

System Evaluation dilakukan untuk menilai kinerja keseluruhan framework berdasarkan tiga aspek utama, yaitu Prediction Performance, Recommendation Performance, dan System Performance. Prediction Performance dievaluasi

menggunakan metrik MAE, RMSE, dan R^2 , sedangkan Recommendation Performance diukur menggunakan Precision, Recall, dan F1-Score. Selain itu, System Performance dievaluasi untuk mengetahui kemampuan sistem dalam melakukan sinkronisasi data, memberikan respons terhadap permintaan pengguna, dan memperbarui data pada lingkungan Digital Twin.

Table 15. System Performance Evaluation

Metric	Result	Description
Synchronization Latency	0.81 s	Average synchronization time between agronomic data and Digital Twin environment
Response Time	1.34 s	Average response time for prediction and recommendation requests
Data Update Rate	5 s	Automatic update interval of the Digital Twin environment

Hasil evaluasi menunjukkan bahwa framework mampu melakukan sinkronisasi antara data agronomi dan lingkungan Digital Twin dengan latency rata-rata 0,81 detik. Waktu respons sistem sebesar 1,34 detik menunjukkan bahwa modul prediksi dan rekomendasi dapat diproses secara cepat untuk mendukung pengambilan keputusan budidaya tanaman. Selain itu, lingkungan Digital Twin diperbarui secara otomatis setiap 5 detik, sehingga representasi virtual tetap mencerminkan perubahan kondisi agronomi secara berkala. Hasil ini menunjukkan bahwa framework memiliki kemampuan operasional yang memadai untuk mendukung implementasi pertanian presisi berbasis Digital Twin.

3.8. Pembahasan

Hasil pengembangan menunjukkan bahwa framework yang diusulkan berhasil mengintegrasikan Digital Twin, Artificial Intelligence, simulasi, dan adaptive recommendation ke dalam satu arsitektur terpadu untuk mendukung pertanian presisi. Integrasi ini memungkinkan sistem tidak hanya melakukan monitoring kondisi tanaman, tetapi juga melakukan prediksi, simulasi berbagai skenario budidaya, serta menghasilkan rekomendasi adaptif berdasarkan perubahan kondisi agronomi secara real-time.

Jika dibandingkan dengan penelitian yang dilakukan oleh (Verdouw et al., 2021), pendekatan yang diusulkan memiliki cakupan yang lebih luas. (Verdouw et al., 2021) memanfaatkan Digital Twin sebagai representasi virtual untuk monitoring dan sinkronisasi kondisi fisik dengan lingkungan digital, namun belum mengintegrasikan modul kecerdasan buatan yang mampu melakukan prediksi maupun rekomendasi budidaya secara otomatis. Framework pada penelitian ini memperluas konsep tersebut dengan menambahkan AI and Simulation Layer dan Adaptive Recommendation Layer, sehingga Digital Twin tidak hanya berfungsi sebagai media visualisasi, tetapi juga sebagai sistem pendukung keputusan yang aktif.

Penelitian (Purcell & Neubauer, 2023) mengembangkan Digital Twin untuk pemantauan sistem pertanian berbasis data sensor dan IoT. Meskipun mampu meningkatkan akurasi monitoring, pendekatan tersebut masih berorientasi pada pengumpulan dan visualisasi data. Sebaliknya, framework yang diusulkan memanfaatkan hasil integrasi data agronomi untuk menghasilkan prediksi kebutuhan air, kebutuhan pupuk, serta risiko hama dan penyakit. Dengan demikian, sistem tidak hanya menyajikan informasi kondisi tanaman, tetapi juga memberikan rekomendasi budidaya yang dapat langsung digunakan dalam proses pengambilan keputusan.

Penelitian (Kim & Heo, 2024) telah menggabungkan Digital Twin dengan kecerdasan buatan untuk meningkatkan analisis kondisi pertanian. Namun, implementasi tersebut masih terbatas pada fungsi prediksi tanpa menyediakan mekanisme simulasi dan rekomendasi adaptif. Pada penelitian ini, kemampuan tersebut diperluas melalui tiga komponen utama, yaitu Growth Simulation, What-if Scenario Simulation, dan Optimization Simulation, yang memungkinkan pengguna mengevaluasi berbagai alternatif strategi budidaya sebelum diterapkan di lapangan.

Selanjutnya, penelitian (Zhang et al., 2025) lebih menitikberatkan pada simulasi pertumbuhan tanaman dan pemanfaatan Digital Twin untuk analisis kondisi lingkungan. Walaupun simulasi tersebut memberikan informasi yang berguna, sistem belum menghubungkan hasil simulasi dengan rekomendasi operasional yang dapat diterapkan secara langsung. Framework yang diusulkan mengatasi keterbatasan tersebut dengan mengintegrasikan hasil simulasi ke dalam Adaptive Recommendation Layer, sehingga setiap perubahan kondisi tanah maupun lingkungan dapat diterjemahkan menjadi rekomendasi irigasi, pemupukan, pengendalian hama, maupun penyesuaian jadwal budidaya secara otomatis.

Penelitian (Subeesh & Chauhan, 2026) berfokus pada penerapan kecerdasan buatan dalam pertanian presisi, terutama untuk klasifikasi penyakit tanaman dan analisis citra. Meskipun memberikan kontribusi penting pada aspek diagnosis, pendekatan tersebut belum mengintegrasikan data multisumber dalam satu lingkungan Digital Twin. Framework yang dikembangkan pada penelitian ini menggabungkan data tanah, data budidaya, model Digital Twin,

serta kecerdasan buatan dalam satu arsitektur terpadu sehingga mampu memberikan dukungan pengambilan keputusan secara lebih komprehensif.

Dari hasil perbandingan tersebut dapat disimpulkan bahwa kontribusi utama penelitian ini bukan hanya pada penggunaan Digital Twin atau kecerdasan buatan secara terpisah, tetapi pada integrasi keduanya dalam suatu Novel Adaptive Cultivation Engine. Engine ini menghubungkan Digital Twin Layer, AI and Simulation Layer, serta Adaptive Recommendation Layer sehingga membentuk siklus yang terdiri atas monitoring → simulasi → prediksi → rekomendasi → umpan balik. Pendekatan tersebut memungkinkan sinkronisasi antara kondisi fisik dan lingkungan virtual sekaligus menghasilkan rekomendasi budidaya yang adaptif terhadap perubahan kondisi agronomi.

Implikasi praktis dari framework ini cukup signifikan bagi penerapan pertanian presisi. Integrasi data multisumber memungkinkan penggunaan air dan pupuk menjadi lebih efisien, deteksi risiko hama dan penyakit dapat dilakukan lebih dini, serta berbagai skenario budidaya dapat diuji melalui simulasi sebelum diterapkan di lapangan. Dengan demikian, framework ini berpotensi meningkatkan produktivitas tanaman, mengurangi pemborosan sumber daya, serta mendukung praktik pertanian yang lebih cerdas dan berkelanjutan.

Table 16. Comparison of the Proposed Framework with Previous Studies

Study	Digital Twin	AI	Simulation	Adaptive Recommendation	Multi-source Integration
(Verdouw et al., 2021)	✓	X	Limited	X	Limited
(Purcell & Neubauer, 2023)	✓	Limited	X	X	✓
(Kim & Heo, 2024)	✓	✓	Limited	X	Limited
(Zhang et al., 2025)	✓	✓	✓	X	Limited
(Subeesh & Chauhan, 2026)	X	✓	X	X	X
Proposed Framework	✓	✓	✓	✓	✓

4. CONCLUSION

Penelitian ini berhasil mengembangkan Model Budidaya Tanaman Adaptif Berbasis Digital Twin dan Kecerdasan Buatan untuk Pertanian Presisi sebagai sebuah framework terintegrasi yang menggabungkan Digital Twin Layer, AI and Simulation Layer, serta Adaptive Recommendation Layer dalam satu arsitektur terpadu. Framework yang diusulkan mampu mengintegrasikan berbagai sumber data agronomi, melakukan simulasi kondisi tanaman, memprediksi kebutuhan budidaya, serta menghasilkan rekomendasi adaptif untuk mendukung pengambilan keputusan pada sistem pertanian presisi.

Hasil evaluasi menunjukkan bahwa model kecerdasan buatan yang dikembangkan mampu memberikan performa prediksi yang tinggi berdasarkan metrik MAE, RMSE, R², Precision, Recall, dan F1-Score. Selain itu, framework juga berhasil mengintegrasikan berbagai komponen Digital Twin sehingga memungkinkan proses monitoring, simulasi, prediksi, dan rekomendasi dilakukan secara terpadu. Dibandingkan penelitian sebelumnya, kontribusi utama penelitian ini terletak pada pengembangan Novel Adaptive Cultivation Engine yang menghubungkan representasi virtual tanaman dengan model kecerdasan buatan dan sistem rekomendasi adaptif dalam satu lingkungan Digital Twin.

Meskipun memberikan hasil yang menjanjikan, penelitian ini masih memiliki beberapa keterbatasan. Validasi framework dilakukan menggunakan integrasi dataset publik sehingga belum merepresentasikan kondisi lapangan secara spasial maupun temporal pada lokasi pertanian tertentu. Oleh karena itu, implementasi framework pada lingkungan pertanian nyata masih memerlukan pengujian lebih lanjut menggunakan data yang diperoleh secara langsung dari lahan budidaya.

Penelitian selanjutnya diarahkan pada pengembangan framework menuju implementasi Digital Twin yang sepenuhnya real-time dengan mengintegrasikan berbagai sumber data lapangan. Data agronomi akan diperoleh secara langsung melalui sensor IoT untuk memantau kelembapan tanah, suhu, pH, dan kandungan hara secara berkelanjutan. Informasi iklim akan dipercaya menggunakan NASA POWER sehingga sistem mampu memperhitungkan faktor meteorologi seperti curah hujan, suhu udara, kelembapan, radiasi matahari, dan kecepatan angin dalam proses simulasi dan prediksi.

Selain itu, representasi Digital Twin akan ditingkatkan melalui pemanfaatan drone dan remote sensing untuk memperoleh informasi spasial mengenai kondisi pertumbuhan tanaman, kesehatan daun, serta indikasi serangan hama dan penyakit. Integrasi citra multispektral dan indeks vegetasi, seperti NDVI, diharapkan mampu meningkatkan akurasi pemantauan kondisi tanaman pada skala lahan yang lebih luas.

Dari sisi komputasi, framework akan dikembangkan menggunakan Edge AI sehingga proses inferensi dapat dilakukan langsung pada perangkat di lapangan tanpa bergantung sepenuhnya pada komputasi awan. Pendekatan ini diharapkan mampu menurunkan latensi komunikasi, meningkatkan kecepatan respons sistem, serta memungkinkan

rekomendasi budidaya diberikan secara lebih cepat pada lingkungan pertanian yang memiliki keterbatasan konektivitas internet.

Pada tahap berikutnya, framework juga akan divalidasi menggunakan data multi-lokasi dan multi-musim tanam sehingga model mampu beradaptasi terhadap variasi karakteristik tanah, kondisi iklim, dan jenis komoditas pertanian. Pengembangan tersebut diharapkan dapat meningkatkan kemampuan generalisasi framework sehingga dapat diterapkan pada berbagai wilayah pertanian dan mendukung implementasi pertanian presisi yang lebih cerdas, adaptif, dan berkelanjutan.

REFERENCES

- Barbie, A., Hasselbring, W., & Hansen, M. (2024). Digital Twin Prototypes for Supporting Automated Integration Testing of Smart Farming Applications †. *Symmetry*, 16(2). <https://doi.org/10.3390/sym16020221>
- Bertoglio, R., Corbo, C., Renga, F. M., & Matteucci, M. (2021). The Digital Agricultural Revolution: A Bibliometric Analysis Literature Review. In *IEEE Access* (Vol. 9, pp. 134762–134782). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2021.3115258>
- Escribà-Gelonch, M., Liang, S., van Schalkwyk, P., Fisk, I., Long, N. V. D., & Hessel, V. (2024). Digital Twins in Agriculture: Orchestration and Applications. In *Journal of Agricultural and Food Chemistry* (Vol. 72, Number 19, pp. 10737–10752). American Chemical Society. <https://doi.org/10.1021/acs.jafc.4c01934>
- Javaid, M., Haleem, A., Khan, I. H., & Suman, R. (2023). Understanding the potential applications of Artificial Intelligence in Agriculture Sector. *Advanced Agrochem*, 2(1), 15–30. <https://doi.org/10.1016/j.aac.2022.10.001>
- Kim, S., & Heo, S. (2024). An agricultural digital twin for mandarins demonstrates the potential for individualized agriculture. *Nature Communications*, 15(1). <https://doi.org/10.1038/s41467-024-45725-x>
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. In *Sensors (Switzerland)* (Vol. 18, Number 8). MDPI AG. <https://doi.org/10.3390/s18082674>
- Melesse, T. Y. (2025). Digital twin-based applications in crop monitoring. In *Heliyon* (Vol. 11, Number 2). Elsevier Ltd. <https://doi.org/10.1016/j.heliyon.2025.e42137>
- Peng, C., Li, B., Yang, J., & Zhu, J. (2026). Artificial Intelligence in Digital Twins: Paradigm, Enabling Technologies and Advantages. *Digital Twins and Applications*, 3(1). <https://doi.org/10.1049/dgt2.70026>
- Purcell, W., & Neubauer, T. (2023). Digital Twins in Agriculture: A State-of-the-art review. In *Smart Agricultural Technology* (Vol. 3). Elsevier B.V. <https://doi.org/10.1016/j.atech.2022.100094>
- Sharma, A., Kosasih, E., Zhang, J., Brintrup, A., & Calinescu, A. (2020). *Digital Twins: State of the Art Theory and Practice, Challenges, and Open Research Questions*. <http://arxiv.org/abs/2011.02833>
- Sinaga, B., Yuhandri, & Nurcahyo, G. W. (2026). Development Of Cost-Sensitive Artificial Neural Network Optimization In Solving Imbalanced Multiclass Classification Problems. *Eastern-European Journal of Enterprise Technologies*, 2(9), 40–63. <https://doi.org/10.15587/1729-4061.2026.356119>
- Subeesh, A., & Chauhan, N. (2026). Agricultural digital twin for smart farming: A review. In *Green Technologies and Sustainability* (Vol. 4, Number 2). KeAi Communications Co. <https://doi.org/10.1016/j.grets.2025.100299>
- Tarigan, N. M. B., Sijabat, D. E. B., Siregar, N. S., & Musyaffa, S. A. (2026). A Comparison Of The AHP And MOORA Methods In Determining Recipients Of Free Nutritious Food In Ujung Serdang Village. *Jurnal Armada Informatika*, 10(1), 159–173. <https://doi.org/10.36520/jai.v10i1.283>
- Tsaousidis, M., Kalampokas, T., Vrochidou, E., & Papakostas, G. A. (2026). AI-Enabled Digital Twins in Agriculture. In *AI (Switzerland)* (Vol. 7, Number 3). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/ai7030108>
- Verdouw, C., Tekinerdogan, B., Beulens, A., & Wolfert, S. (2021). Digital twins in smart farming. *Agricultural Systems*, 189. <https://doi.org/10.1016/j.agsy.2020.103046>
- Wang, L. (2024). Digital Twins in Agriculture: A Review of Recent Progress and Open Issues. In *Electronics (Switzerland)* (Vol. 13, Number 11). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/electronics13112209>
- Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M. J. (2017). Big Data in Smart Farming – A review. In *Agricultural Systems* (Vol. 153, pp. 69–80). Elsevier Ltd. <https://doi.org/10.1016/j.agsy.2017.01.023>
- Zhang, R., Zhu, H., Chang, Q., & Mao, Q. (2025). A Comprehensive Review of Digital Twins Technology in Agriculture. In *Agriculture (Switzerland)* (Vol. 15, Number 9). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/agriculture15090903>