

HABA-TANI: FRAMEWORK AGENTIC AI UNTUK PERTANIAN TROPIS

Atika Istiqomah ¹⁾

¹⁾ *Teknologi Rekayasa Perangkat Lunak Sekolah Vokasi IPB University*
email : istiqomahatika.ai@gmail.com¹⁾

Abstraksi

Pertanian tropis Indonesia membutuhkan sistem pendukung keputusan yang mampu mengintegrasikan evaluasi kesesuaian lahan, perancangan tata letak tanaman, penilaian risiko sumber daya, dan penjelasan rekomendasi. Kebutuhan ini penting karena keputusan budidaya dipengaruhi variasi agroekologi, keterbatasan data lahan, dominasi petani berlahan kecil, fragmentasi sistem AI pertanian, serta risiko iklim. Penelitian ini mengusulkan HABA-Tani sebagai framework agentic AI berbasis design research. Metode penelitian mencakup sintesis literatur terbuka 2021-2026, pencarian terarah pada basis data ilmiah, seleksi inklusi-eksklusi, pemetaan konsep, analisis kesenjangan, perumusan prinsip desain, dan validasi analitis melalui scenario-based demonstration. Framework terdiri atas Orchestrator Agent, Land Suitability Agent, Crop Layout and Rotation Agent, Resource and Risk Agent, Explainability Agent, serta Governance and Memory Layer. Hasil perancangan menunjukkan bahwa orkestrasi multi-agen dapat menghubungkan prediksi, optimasi, risiko, explainability, dan audit trail dalam satu alur rekomendasi. Keterbatasan penelitian adalah framework masih konseptual dan belum divalidasi empiris pada dataset serta pengguna pertanian Indonesia.

Kata Kunci :

agentic AI, kesesuaian lahan, pertanian tropis, sistem rekomendasi, explainable AI

Abstract

Indonesian tropical agriculture requires decision support systems that integrate land suitability assessment, crop layout planning, resource-risk evaluation, and explainable recommendations. This need is important because cultivation decisions are affected by agroecological diversity, incomplete land data, smallholder farming dominance, fragmented agricultural AI systems, and climate-related risks. This study proposes HABA-Tani as an agentic AI framework using a design research approach. The method includes synthesis of open scientific literature from 2021-2026, targeted database searching, inclusion-exclusion screening, concept mapping, gap analysis, design-principle formulation, and analytical validation through scenario-based demonstration. The framework consists of an Orchestrator Agent, Land Suitability Agent, Crop Layout and Rotation Agent, Resource and Risk Agent, Explainability Agent, and Governance and Memory Layer. The design shows that multi-agent orchestration can connect prediction, optimization, risk assessment, explainability, and audit trail within one recommendation workflow. This study remains conceptual and has not been empirically validated using Indonesian agricultural datasets and end users.

Keywords :

agentic AI, land suitability, tropical agriculture, recommender system, explainable AI

Pendahuluan

Pertanian tropis menghadapi tekanan yang semakin kompleks karena perubahan iklim, fragmentasi lahan, fluktuasi ketersediaan air, perubahan hama dan penyakit, serta kebutuhan peningkatan produktivitas. Pada saat yang sama, digitalisasi pertanian menghasilkan sumber data baru, seperti citra satelit, sensor tanah, catatan budidaya, data iklim, basis pengetahuan agronomi, dan riwayat hasil panen. Perkembangan big data dan artificial intelligence (AI) memperlihatkan peluang besar untuk mengubah praktik pertanian dari pengamatan manual menuju decision support system yang lebih adaptif [1]. Konteks Indonesia memperkuat kebutuhan tersebut. Sensus Pertanian 2023 mencatat jumlah Rumah Tangga Usaha Pertanian (RTUP) sebanyak 28.419.398 rumah tangga, sedangkan jumlah Usaha

Pertanian Perorangan (UTP) mencapai 29.342.202 unit [2]. Selain itu, jumlah petani pengguna lahan pertanian di Indonesia mencapai 27.802.434 petani dan 17.251.432 di antaranya termasuk petani gurem [2]. Data ini menunjukkan bahwa sistem rekomendasi pertanian perlu mempertimbangkan karakter pengguna yang sangat besar, tersebar, dan banyak berada pada skala lahan kecil. Risiko iklim juga membuat keputusan budidaya tidak dapat hanya bergantung pada pengalaman historis. Laporan Climate-Smart Agriculture in Indonesia menjelaskan bahwa perubahan iklim menimbulkan risiko bagi pertanian Indonesia, sehingga pendekatan climate-smart agriculture diarahkan untuk meningkatkan produktivitas, memperkuat adaptasi, dan mengurangi risiko secara terpadu [3]. Dalam situasi tersebut, sistem AI pertanian perlu mampu menjelaskan alasan rekomendasi, menandai

ketidakpastian data, dan memberi alternatif tindakan yang layak diterapkan.

Namun, sebagian besar sistem pendukung keputusan pertanian masih bekerja secara terpisah. Model kesesuaian lahan biasanya menghasilkan kelas cocok, cukup cocok, atau tidak cocok; model rekomendasi tanaman menghasilkan daftar komoditas; sedangkan modul penjelasan sering hanya berupa teks statis atau interpretasi umum. Fragmentasi tersebut menimbulkan masalah praktis karena pengguna akhir tidak hanya membutuhkan skor prediksi, tetapi juga alasan keputusan, alternatif tata letak tanaman, risiko budidaya, dan konsekuensi sumber daya yang harus disiapkan.

Research gap pada penelitian ini terletak pada belum terintegrasinya empat fungsi utama dalam satu kerangka kerja yang dapat diaudit, yaitu prediksi kesesuaian lahan, optimasi layout dan rotasi tanaman, evaluasi risiko sumber daya, serta penjelasan berbasis bukti. Penelitian sebelumnya telah mengembangkan machine learning untuk kesesuaian lahan, crop recommendation, foundation models, explainable AI, dan agentic AI pertanian. Akan tetapi, sebagian besar studi masih berhenti pada klasifikasi, pemeringkatan komoditas, atau kerangka automasi umum, belum secara eksplisit merancang orkestrasi multi-agen untuk konteks pertanian tropis Indonesia yang memiliki variasi agroekologi, keterbatasan data, dan kebutuhan human-in-the-loop.

Agentic AI menawarkan pendekatan baru untuk masalah tersebut. Berbeda dari sistem AI tunggal yang hanya menerima masukan dan mengeluarkan prediksi, agentic AI memecah tugas kompleks ke dalam beberapa agen spesialis yang dapat merencanakan, menjalankan subtugas, memeriksa hasil, dan berkoordinasi melalui mekanisme orkestrasi. Dalam ranah pertanian, paradigma ini relevan karena keputusan budidaya secara alamiah bersifat multi-kriteria dan membutuhkan alur kerja bertahap: validasi data, evaluasi kesesuaian, optimasi layout, pemeriksaan risiko, hingga penyusunan rekomendasi yang komunikatif.

Penelitian ini bertujuan menyusun framework agentic AI untuk evaluasi kesesuaian lahan dan rekomendasi tata letak tanaman pada pertanian tropis. Kontribusi artikel ini meliputi: (1) sintesis kesenjangan riset dari studi terbuka tahun 2021-2026; (2) perancangan arsitektur HAFA-Tani sebagai hybrid agentic AI framework; (3) formulasi peran agen, alur kerja, kebutuhan data, mekanisme teknis antaragen, dan tata kelola; serta (4) rancangan evaluasi untuk mengukur kinerja prediksi, kualitas rekomendasi, faithfulness penjelasan, dan kesiapan implementasi. Artikel ini tidak mengklaim telah menghasilkan prototipe final, melainkan menyediakan proposed framework yang dapat menjadi dasar implementasi dan pengujian empiris pada penelitian selanjutnya.

Tinjauan Pustaka

Evaluasi kesesuaian lahan merupakan fondasi penting dalam perencanaan budidaya. Pendekatan

klasik biasanya menggunakan kriteria biofisik dan ambang agronomi, seperti pH, tekstur tanah, kemiringan, curah hujan, suhu, drainase, serta ketersediaan air. Perkembangan machine learning memperluas pendekatan tersebut dengan mempelajari pola dari data historis dan variabel spasial. Moller dkk. [4] menunjukkan bahwa machine learning dapat digunakan untuk memetakan kesesuaian lahan, tetapi asumsi bahwa pola tanam historis selalu mencerminkan area terbaik perlu diuji secara kritis. Dengan demikian, model prediktif perlu dilengkapi validasi domain dan tidak boleh diperlakukan sebagai sumber keputusan tunggal.

Rekomendasi tanaman berbasis machine learning juga berkembang cepat. Hasan dkk. [5] memperlihatkan bahwa ensemble learning dapat meningkatkan prediksi komoditas yang sesuai berdasarkan atribut pertanian. Nabiollahi dkk. [6] menggabungkan multi-criteria decision model dan machine learning untuk kesesuaian gandum, sehingga menunjukkan bahwa pendekatan hybrid dapat menangani heterogenitas tanah dan ruang lebih baik daripada pendekatan tunggal. Kendati demikian, studi semacam ini umumnya masih berorientasi pada klasifikasi atau pemeringkatan, belum sepenuhnya menerjemahkan hasil prediksi ke dalam rekomendasi tata letak, rotasi, dan estimasi trade-off sumber daya. Dalam konteks publikasi JOISM, Sucipto dan Sari [7] menunjukkan penerapan deep learning berbasis ResNet50 untuk klasifikasi varietas bibit durian sebagai contoh implementasi AI pada pertanian digital.

Perkembangan large language models (LLM), generative AI, dan foundation models membuka peluang baru untuk antarmuka pertanian yang lebih natural. De Clercq dkk. [8] menekankan bahwa LLM dapat membantu produksi pangan, tetapi risiko factuality, bias, dan penyalahgunaan perlu dikelola. Krupitzer [9] menjelaskan potensi generative AI di rantai nilai agri-food, khususnya untuk ekstraksi informasi, sintesis pengetahuan, dan dukungan keputusan. Zhao dkk. [10] menunjukkan integrasi LLM dan agricultural knowledge graph untuk deteksi penyakit tanaman. Kuska dkk. [11] secara khusus membahas nilai LLM untuk produksi tanaman, tetapi juga menekankan kebutuhan grounding pada data domain.

Foundation models di pertanian memberikan peluang integrasi multimodal karena dapat menghubungkan citra, teks, data tabular, dan sinyal sensor. Li dkk. [12] serta Yin dkk. [13] menggarisbawahi bahwa foundation models dapat mempercepat pengembangan model agrikultur, tetapi masih menghadapi tantangan generalisasi, kebutuhan data berkualitas, komputasi, dan interpretabilitas. Haghghat dkk. [14] memperluas diskusi ini ke multimodal language models, yang relevan untuk sistem pertanian berbasis citra dan tanya jawab. Meskipun demikian, penerapan model multimodal pada pertanian tidak dapat dilepaskan dari mekanisme verifikasi, provenance, dan kendali manusia.

Explainable AI (XAI) menjadi komponen penting karena keputusan pertanian harus dapat dijelaskan kepada pengguna non-teknis. Mohan dkk. [15] menunjukkan integrasi AI dan XAI untuk prediksi hasil panen, sedangkan Rajbongshi dkk. [16] meninjau kemajuan XAI untuk pertanian berkelanjutan. Dalam konteks framework yang diusulkan, XAI tidak hanya dipakai untuk menampilkan feature importance, tetapi juga untuk memastikan narasi rekomendasi tetap setia terhadap data, keluaran model, dan aturan agronomi. Agentic AI mulai muncul sebagai arah baru dalam smart agriculture. Srinivasu dkk. [17] membahas agentic AI untuk precision agriculture berkelanjutan. Murad dkk. [18] mengusulkan framework agentic AI

untuk otomatisasi pertanian tradisional. Swati dkk. [19] mengembangkan autonomous decision support system berbasis agen untuk klasifikasi tanah, estimasi parameter tanah, rekomendasi tanaman, dan rekomendasi pupuk. Tariq dkk. [20] menambahkan dimensi edge-enabled smart agriculture yang menggabungkan IoT, lightweight deep learning, dan agentic AI. Literatur tersebut memperkuat urgensi agentic AI, tetapi masih diperlukan rancangan khusus yang menjembatani kesesuaian lahan, layout tanaman, penjelasan, dan governance untuk konteks pertanian tropis.

Tabel 1. Perbandingan penelitian terdahulu dan posisi penelitian

Penelitian	Fokus utama	Keterbatasan yang menjadi dasar pengembangan
Moller dkk. [4]	Pemetaan kesesuaian lahan menggunakan machine learning.	Belum diarahkan ke rekomendasi layout dan orkestrasi keputusan.
Hasan dkk. [5]	Rekomendasi komoditas berbasis ensemble machine learning.	Fokus pada prediksi komoditas, belum mengintegrasikan risiko dan penjelasan berbasis bukti.
Nabiollahi dkk. [6]	Hybrid MCDA dan machine learning untuk kesesuaian gandum.	Masih berorientasi pada komoditas dan wilayah tertentu; belum menjadi sistem multi-agen.
De Clercq dkk. [8]; Kuska dkk. [11]	Potensi dan risiko LLM untuk pertanian.	Belum merancang pipeline agentic end-to-end untuk kesesuaian lahan dan tata letak.
Li dkk. [12]; Yin dkk. [13]	Foundation models dan multimodal AI untuk smart agriculture.	Menekankan peluang dan tantangan, tetapi belum spesifik pada workflow rekomendasi lahan tropis.
Srinivasu dkk. [17]; Murad dkk. [18]; Swati dkk. [19]	Agentic AI dan autonomous decision support untuk smart agriculture.	Belum memformalkan layer governance, audit trail, dan explainability untuk rekomendasi layout tanaman tropis.

Metode Penelitian

Penelitian ini menggunakan pendekatan design research karena keluaran utama penelitian adalah artefak konseptual berupa framework. Design research sesuai untuk penelitian sistem informasi yang berorientasi pada pembangunan artefak, pemecahan masalah, dan evaluasi rancangan [21]. Tahapan penelitian mengadaptasi design science research methodology yang mencakup identifikasi masalah, penetapan tujuan solusi, desain dan pengembangan artefak, demonstrasi, evaluasi, serta komunikasi hasil [22].

Data penelitian berupa literatur ilmiah terbuka yang diterbitkan pada periode 2021-2026. Proses pencarian dilakukan secara terarah melalui Google Scholar, ScienceDirect, IEEE Xplore, SpringerLink, MDPI, Frontiers, Nature, dan sumber open access lain yang relevan. Kata kunci yang digunakan antara lain land suitability machine learning, crop recommendation system, smart agriculture decision support system, explainable AI agriculture, foundation models agriculture, large language model agriculture, agentic AI agriculture, precision agriculture, dan tropical agriculture. Pencarian juga menggunakan kombinasi kata kunci bahasa Indonesia, seperti kesesuaian lahan, rekomendasi tanaman, sistem pendukung keputusan pertanian, pertanian tropis, dan AI pertanian.

Kriteria inklusi mencakup artikel jurnal, prosiding ilmiah, laporan resmi, atau sumber data resmi yang membahas sedikitnya salah satu tema berikut:


kesesuaian lahan berbasis machine learning, crop recommendation, LLM atau generative AI di pertanian, foundation atau multimodal models, explainable AI, smart agriculture, IoT/edge agriculture, agentic AI, serta konteks pertanian Indonesia. Kriteria eksklusi mencakup artikel yang tidak relevan dengan pertanian, tidak menjelaskan metode atau komponen sistem, hanya berupa opini tanpa dukungan ilmiah, duplikat, serta sumber yang tidak dapat diakses secara terbuka. Prinsip transparansi proses seleksi mengacu secara adaptif pada PRISMA 2020, tetapi penelitian ini tidak diposisikan sebagai systematic literature review penuh [23].

Analisis literatur dilakukan melalui empat tahap. Tahap pertama adalah pemetaan konsep, yaitu mengelompokkan artikel berdasarkan fungsi sistem: prediksi, rekomendasi, optimasi, penjelasan, dan governance. Tahap kedua adalah analisis kesenjangan, yaitu mengidentifikasi bagian yang belum terintegrasi dalam penelitian terdahulu. Tahap ketiga adalah perumusan prinsip desain, meliputi modularity, human-in-the-loop, evidence-grounded explanation, auditability, uncertainty tagging, dan robustness terhadap data tidak lengkap. Tahap keempat adalah formulasi framework HAFATani beserta komponen, alur kerja, kebutuhan data, mekanisme antaragen, dan skema evaluasi.

Validasi framework dilakukan pada level konseptual melalui tiga bentuk evaluasi awal. Pertama, analytical evaluation untuk menilai konsistensi hubungan antara

masalah, kebutuhan desain, komponen agen, dan keluaran sistem. Kedua, literature-based validation untuk memastikan setiap komponen framework memiliki dasar dari penelitian terdahulu. Ketiga, scenario-based demonstration menggunakan studi kasus sintetis pertanian tropis untuk menunjukkan

bagaimana input diproses menjadi rekomendasi, penjelasan, dan audit trail. Validasi ini belum setara dengan uji empiris lapangan, sehingga pengujian menggunakan dataset riil dan pengguna akhir tetap menjadi agenda penelitian lanjutan.



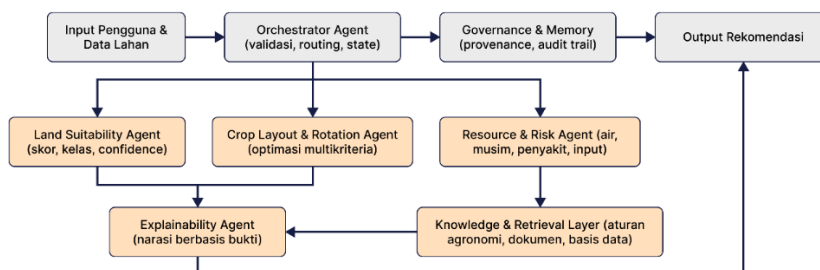
Gambar 1. Tahapan penelitian dalam penyusunan proposed framework

Hasil dan Pembahasan Kebutuhan Desain Sistem

Hasil sintesis menunjukkan bahwa framework agentic AI untuk pertanian tropis harus memenuhi enam kebutuhan desain. Pertama, sistem harus mampu mengelola data heterogen, yaitu data tanah, iklim, topografi, citra, riwayat tanam, dan preferensi pengguna. Kedua, sistem harus memisahkan fungsi prediksi, optimasi, risiko, dan penjelasan agar setiap komponen dapat dievaluasi secara mandiri. Ketiga, sistem harus menghasilkan lebih dari satu alternatif rekomendasi karena keputusan budidaya tidak bersifat tunggal. Keempat, sistem harus menyediakan penjelasan yang terikat pada bukti, bukan sekadar

teks generatif. Kelima, sistem harus menyimpan jejak keputusan sehingga hasil rekomendasi dapat diaudit. Keenam, sistem harus menandai ketidakpastian data agar rekomendasi tidak disajikan dengan tingkat keyakinan yang berlebihan.

Berdasarkan kebutuhan tersebut, artikel ini mengusulkan HAFA-Tani atau Hybrid Agentic Framework for Agriculture. Istilah hybrid digunakan karena framework menggabungkan rule agronomi, machine learning, optimasi multikriteria, retrieval-augmented generation, dan human oversight. Istilah agentic digunakan karena fungsi utama sistem dibagi ke dalam agen yang memiliki mandat spesifik dan dikoordinasikan oleh orchestrator.



Gambar 2. Arsitektur HAFA-Tani sebagai hybrid agentic AI framework

Komponen Framework HAFA-Tani

Orchestrator Agent berfungsi sebagai pengendali alur kerja. Agen ini menerima permintaan pengguna, memeriksa kelengkapan input, mengatur urutan pemanggilan agen, mengelola state, dan menangani konflik antarkomponen. Orchestrator tidak menjadi model prediktif utama, tetapi memastikan setiap agen bekerja pada input yang sesuai dan output yang terstruktur.

Land Suitability Agent bertugas menghitung skor dan kelas kesesuaian lahan. Komponen ini menggunakan dua lapisan: rule agronomi eksplisit dan model machine learning. Rule agronomi digunakan sebagai guardrail, misalnya rentang pH, drainase, suhu, atau kemiringan yang menjadi faktor pembatas. Model machine learning kemudian mempelajari hubungan nonlinier antarvariabel. Keluaran agen ini mencakup kelas kesesuaian, confidence, variabel pembatas, dan variabel pendukung.

Crop Layout and Rotation Agent bertugas mengubah daftar komoditas kandidat menjadi rancangan tata letak dan rotasi. Agen ini menggunakan optimasi multikriteria dengan tujuan seperti produktivitas, diversifikasi, efisiensi air, pengurangan risiko penyakit, dan kemudahan implementasi. Keluaran yang diharapkan bukan satu rekomendasi tunggal, tetapi beberapa alternatif dengan trade-off yang dapat dibandingkan.

Resource and Risk Agent mengevaluasi kelayakan rekomendasi berdasarkan kondisi sumber daya dan risiko. Agen ini memperhitungkan ketersediaan air, kalender musim, kebutuhan input, tenaga kerja, potensi hama dan penyakit, serta sensitivitas cuaca. Peran agen ini penting karena rekomendasi yang optimal secara matematis belum tentu layak diterapkan di lapangan.

Explainability Agent mengubah artefak teknis menjadi penjelasan yang dapat dipahami. Agen ini menerima hasil prediksi, skor optimasi, faktor

pembatas, dan catatan risiko, lalu menyusun narasi berbasis bukti. Agar tidak terjadi halusinasi, agen penjelas harus terhubung dengan knowledge and retrieval layer serta dibatasi oleh evidence template. Governance and Memory Layer menyimpan metadata keputusan, versi model, sumber data, aturan yang aktif, dan riwayat interaksi. Lapisan ini

memungkinkan audit trail, pelacakan provenance, human override, serta personalisasi terbatas. Dalam konteks pertanian, tata kelola semacam ini penting karena rekomendasi dapat berdampak pada biaya, hasil panen, dan risiko gagal tanam.

Tabel 2. Peran agen dalam framework HAFA-Tani

Komponen	Input utama	Keluaran utama	Risiko yang dikendalikan
Orchestrator Agent	Kueri pengguna, status data, output agen lain	Rencana eksekusi, routing, state, resolusi konflik	Alur kerja tidak konsisten dan kesalahan koordinasi
Land Suitability Agent	pH, tekstur, elevasi, curah hujan, suhu, drainase	Skor kesesuaian, kelas, confidence, faktor pembatas	Prediksi black-box dan penggunaan data tidak valid
Crop Layout and Rotation Agent	Komoditas kandidat, ukuran lahan, batasan tanam	Alternatif layout, rotasi, kepadatan, trade-off	Rekomendasi tunggal yang tidak fleksibel
Resource and Risk Agent	Musim, air, input, tenaga kerja, risiko penyakit	Peringkat risiko dan filter kelayakan	Rencana tanam tidak realistis
Explainability Agent	Output model, aturan, evidence, preferensi pengguna	Penjelasan natural language berbasis bukti	Halusinasi dan penjelasan tidak setia data
Governance and Memory Layer	Log sistem, versi model, provenance, preferensi	Audit trail, memori terkontrol, dokumentasi keputusan	Keputusan tidak dapat ditelusuri

Alur Kerja dan Logika Rekomendasi

Alur kerja HAFA-Tani dimulai dari tahap intake. Pengguna memasukkan lokasi lahan, luas lahan, atribut tanah yang tersedia, komoditas prioritas, tujuan budidaya, serta batasan seperti air, biaya, atau risiko. Orchestrator Agent menilai kelengkapan data dan memberi tanda pada variabel yang hilang. Jika data krusial tidak tersedia, sistem dapat meminta input tambahan atau menggunakan estimasi berbasis sumber sekunder dengan label confidence rendah.

Tahap kedua adalah penilaian kesesuaian. Land Suitability Agent menjalankan rule agronomi untuk menyaring komoditas yang jelas tidak sesuai, lalu model prediktif menghitung skor kandidat. Output tahap ini tidak hanya berisi kelas kesesuaian, tetapi juga alasan utama, misalnya pH terlalu rendah, kemiringan tinggi, atau curah hujan sesuai. Informasi tersebut menjadi bukti awal untuk agen penjelas.

Tahap ketiga adalah perancangan alternatif. Crop Layout and Rotation Agent menyusun beberapa skenario. Contohnya, skenario A memaksimalkan produktivitas satu komoditas, skenario B menyeimbangkan dua komoditas untuk diversifikasi, dan skenario C meminimalkan kebutuhan air. Setiap skenario dinilai ulang oleh Resource and Risk Agent agar tidak menghasilkan rekomendasi yang mengabaikan kondisi lapangan.

Tahap keempat adalah penjelasan dan validasi pengguna. Explainability Agent menyajikan ringkasan rekomendasi, alasan, risiko, dan tindakan lanjutan. Pengguna dapat meminta revisi, misalnya alternatif yang lebih hemat air atau lebih aman terhadap penyakit tertentu. Orchestrator akan mengulang proses secara selektif sehingga sistem tidak perlu menghitung ulang seluruh pipeline jika hanya terjadi perubahan preferensi.

Secara operasional, logika rekomendasi dapat dirumuskan sebagai: (1) validasi input; (2) estimasi kualitas data; (3) hitung skor kesesuaian; (4) bentuk

kandidat layout; (5) evaluasi resource-risk; (6) susun penjelasan berbasis bukti; dan (7) simpan audit trail. Logika ini membuat sistem lebih terkendali dibandingkan penggunaan LLM langsung untuk menjawab pertanyaan pertanian tanpa grounding data.

Mekanisme Teknis Antaragen

Mekanisme teknis antaragen dirancang melalui kontrak pesan terstruktur. Setiap agen tidak mengirimkan keluaran bebas, tetapi wajib menyertakan identitas tugas, skema input, skema output, nilai confidence, evidence, uncertainty flag, dan rekomendasi tindakan. Kontrak ini penting untuk memastikan Orchestrator Agent dapat memeriksa kelengkapan keluaran sebelum melanjutkan proses ke agen berikutnya.

Dalam skenario normal, Orchestrator Agent mengirimkan data lahan ke Data Quality Layer untuk profil kelengkapan data. Data yang telah diberi label kualitas dikirim ke Land Suitability Agent. Hasil skor kesesuaian kemudian diteruskan ke Crop Layout and Rotation Agent untuk membentuk alternatif layout. Alternatif tersebut dievaluasi oleh Resource and Risk Agent. Explainability Agent hanya boleh menghasilkan narasi apabila evidence dari agen sebelumnya tersedia. Governance and Memory Layer mencatat seluruh input, versi model, aturan yang digunakan, serta keputusan pengguna.

Apabila terjadi konflik, misalnya Land Suitability Agent memberi skor tinggi tetapi Resource and Risk Agent menandai risiko air tinggi, Orchestrator tidak langsung memilih rekomendasi terbaik. Sistem harus menurunkan peringkat alternatif, meminta revisi constraint, atau menyajikan trade-off kepada pengguna. Dengan demikian, keputusan akhir tetap berada pada manusia, sedangkan sistem menyediakan evidence dan konsekuensi pilihan.

Tabel 3. Kontrak pesan antaragen dalam HAFA-Tani

Elemen pesan	Isi minimum	Fungsi kontrol	Contoh
task_id	Identitas permintaan dan tahap eksekusi	Melacak proses dari input sampai output	LT-001-Suitability
input_schema	Variabel yang dipakai dan status kelengkapan	Mencegah penggunaan data tanpa validasi	pH tersedia; NPK hilang
output_schema	Kelas, skor, alasan, atau alternatif layout	Membuat keluaran antaragen dapat diproses ulang	S2; confidence 0,78
evidence	Rule, dokumen, atau output model yang mendukung	Mengurangi risiko halusinasi penjelasan	pH menjadi faktor pembatas
uncertainty_flag	Label rendah, sedang, atau tinggi	Memberi peringatan terhadap data tidak lengkap	Sedang karena data NPK tidak tersedia
action_required	Lanjut, revisi, minta data, atau human review	Mengatur routing oleh Orchestrator	Minta data drainase tambahan

Strategi Data dan Pemodelan

Framework ini membutuhkan empat kelompok data. Pertama, data biofisik lahan, seperti pH, tekstur tanah, nitrogen, fosfor, kalium, bahan organik, elevasi, kemiringan, dan drainase. Kedua, data agroklimat, seperti curah hujan, suhu, kelembapan, indeks kekeringan, dan kalender musim. Ketiga, data manajemen budidaya, seperti riwayat tanam, pola rotasi, hasil panen, penggunaan pupuk, dan catatan gangguan. Keempat, basis pengetahuan agronomi, seperti ambang kesesuaian komoditas, aturan jarak tanam, kebutuhan air, dan pedoman pengendalian risiko.

Kualitas data menjadi isu utama karena lahan tropis sering memiliki variasi mikro yang tinggi dan tidak semua petani memiliki data lengkap. Oleh karena itu, pipeline data perlu memisahkan tiga proses: data profiling, imputation, dan uncertainty tagging. Data profiling menilai kelengkapan dan konsistensi input. Imputation digunakan untuk mengisi nilai hilang yang masih dapat diperkirakan. Uncertainty tagging memberi label kepercayaan agar sistem tidak menyajikan rekomendasi dengan kepastian palsu.

Model prediktif pada tahap awal dapat menggunakan Random Forest, Gradient Boosting, atau XGBoost karena relatif kuat untuk data tabular heterogen dan dapat dijelaskan melalui feature importance. Untuk wilayah dengan data citra memadai, model geospatial deep learning atau foundation models dapat ditambahkan. Namun, model yang lebih kompleks harus tetap terhubung dengan governance layer agar versi model, data latihan, dan batasan penggunaan dapat ditelusuri.

Lapisan penjelasan sebaiknya menggunakan retrieval-augmented generation. Artinya, LLM tidak dibiarkan menghasilkan rekomendasi dari memori internalnya saja, tetapi mengambil evidence dari output model, rule agronomi, dan dokumen pengetahuan yang disediakan. Dengan mekanisme ini, narasi rekomendasi dapat dikendalikan, misalnya dengan pola: rekomendasi, alasan utama, bukti data, asumsi, risiko, dan langkah tindak lanjut.

Studi Kasus Ilustratif dan Simulasi Workflow

Untuk memperkuat metodologi, artikel ini menambahkan contoh implementasi sederhana berupa studi kasus sintesis. Contoh ini tidak dimaksudkan sebagai rekomendasi agronomis final, tetapi sebagai demonstrasi alur kerja framework. Skenario yang digunakan adalah lahan tropis dataran rendah seluas 1 hektare dengan pH 5,2, tekstur lempung berpasir, kemiringan 4 persen, curah hujan tahunan sekitar 2.200 mm, drainase sedang, ketersediaan air sedang, dan preferensi komoditas cabai, jagung, serta ubi kayu.

Pada tahap intake, Orchestrator Agent menandai bahwa data NPK dan riwayat penyakit belum tersedia sehingga uncertainty diberi label sedang. Land Suitability Agent kemudian menilai bahwa ubi kayu relatif lebih toleran terhadap pH masam, jagung memerlukan perbaikan pH dan pemupukan, sedangkan cabai memiliki potensi ekonomi tetapi lebih sensitif terhadap drainase dan penyakit. Crop Layout and Rotation Agent membentuk tiga alternatif layout. Resource and Risk Agent menurunkan peringkat alternatif yang terlalu bergantung pada air dan input tinggi. Explainability Agent menyusun penjelasan yang menyebutkan faktor pembatas, asumsi, risiko, dan data tambahan yang perlu dikumpulkan.

Simulasi tersebut menunjukkan bahwa HAFA-Tani tidak hanya menghasilkan daftar komoditas, tetapi juga memperlihatkan alasan, trade-off, dan tindakan lanjutan. Dalam skenario ini, rekomendasi tidak diberikan sebagai keputusan tunggal. Sistem menyajikan alternatif konservatif, alternatif nilai ekonomi, dan alternatif hemat air agar pengguna dapat memilih sesuai konteks lokal.

Tabel 4. Mockup output rekomendasi pada studi kasus sintesis

Alternatif	Komposisi layout	Alasan utama	Risiko utama	Tindak lanjut
A: konservatif	60% ubi kayu, 40% jagung	Lebih toleran terhadap pH 5,2 dan input sedang	Pendapatan potensial lebih rendah dibanding cabai	Uji NPK dan susun jadwal pemupukan

B: nilai ekonomi	50% cabai, 30% jagung, 20% ubi kayu	Memfaatkan potensi cabai dengan diversifikasi	Sensitif terhadap drainase, penyakit, dan kebutuhan input	Perbaiki bedengan, cek drainase, siapkan mitigasi penyakit
C: hemat air	70% ubi kayu, 30% jagung rotasi	Menekan kebutuhan air dan kompleksitas budidaya	Diversifikasi rendah dan pasar perlu dipastikan	Validasi akses pasar dan kalender tanam lokal

Catatan: nilai dan rekomendasi pada tabel ini bersifat ilustratif untuk menunjukkan alur kerja sistem, bukan hasil uji lapangan.

Validasi Awal dan Proof-of-Concept Konseptual

Validasi awal dilakukan melalui proof-of-concept konseptual berbasis skenario. Validasi ini menggunakan checklist internal untuk menilai lima aspek: (1) setiap rekomendasi memiliki evidence; (2) data hilang diberi uncertainty flag; (3) alternatif layout menunjukkan trade-off; (4) penjelasan tidak menambahkan klaim di luar evidence; dan (5) human review tetap tersedia sebelum keputusan diterapkan. Hasil walkthrough pada studi kasus sintetis menunjukkan bahwa kontrak antaragen mampu mempertahankan traceability dari input menuju output. Misalnya, rekomendasi alternatif B tidak hanya menyatakan cabai sebagai komoditas bernilai ekonomi, tetapi juga menampilkan risiko drainase, kebutuhan mitigasi penyakit, dan kebutuhan data NPK tambahan. Dengan demikian, kontribusi praktis framework terletak pada struktur pengambilan keputusan yang dapat ditelusuri, bukan pada klaim akurasi empiris.

Batas validasi ini perlu ditegaskan. Proof-of-concept konseptual belum mengukur accuracy, F1-score, atau usability dengan pengguna akhir. Oleh karena itu, penelitian berikutnya perlu membangun prototipe minimum viable system, menguji model pada dataset pertanian tropis Indonesia, dan melakukan evaluasi dengan penyuluh atau petani.

Rencana Evaluasi Framework

Evaluasi framework agentic AI tidak cukup memakai akurasi prediksi. Terdapat lima dimensi evaluasi yang perlu digunakan. Dimensi pertama adalah kinerja prediktif Land Suitability Agent, mencakup accuracy, macro-F1, AUC, calibration, dan robustness terhadap data hilang. Dimensi kedua adalah kualitas rekomendasi layout, mencakup kepatuhan terhadap constraint, stabilitas solusi, dan kejelasan trade-off. Dimensi ketiga adalah kualitas penjelasan, mencakup faithfulness terhadap output model, factual consistency, dan keterpahaman pengguna. Dimensi keempat adalah evaluasi operasional, mencakup waktu respons, kemampuan audit, dan kemudahan penggunaan oleh petani atau penyuluh. Dimensi kelima adalah governance, mencakup provenance, human override, dan keamanan penggunaan. Baseline evaluasi dapat berupa model rekomendasi tunggal tanpa orkestrasi agen. HAFA-Tani dianggap lebih baik apabila tidak hanya mempertahankan atau meningkatkan kinerja prediksi, tetapi juga menghasilkan rekomendasi yang lebih dapat ditindaklanjuti, lebih transparan, dan lebih mudah diaudit. Uji lapangan sebaiknya dilakukan bertahap mulai dari satu komoditas dan satu wilayah, kemudian diperluas ke skenario multi-komoditas.

Tabel 5. Matriks evaluasi framework HAFA-Tani

Dimensi evaluasi	Contoh metrik	Tujuan evaluasi
Prediksi kesesuaian	Accuracy, macro-F1, AUC, calibration, missing-data robustness	Menilai kualitas Land Suitability Agent.
Kualitas rekomendasi	Constraint satisfaction, jumlah alternatif valid, stabilitas trade-off	Menilai kelayakan layout dan rotasi tanaman.
Explainability	Faithfulness, factual consistency, user comprehension score	Menilai apakah penjelasan sesuai bukti dan dipahami pengguna.
Operasional	Waktu respons, auditability, jumlah revisi interaksi, usability score	Menilai kesiapan sistem sebagai decision support.
Governance	Kelengkapan provenance, versi model, log keputusan, human override	Menilai keterlacakan dan keamanan penggunaan.

Pembahasan

Kontribusi konseptual utama HAFA-Tani adalah perubahan orientasi dari sistem prediksi menuju sistem orkestrasi keputusan. Dalam sistem prediksi biasa, model berhenti pada output berupa label atau skor. Dalam framework ini, output tersebut menjadi salah satu artefak yang diproses oleh agen lain untuk menghasilkan alternatif layout, penilaian risiko, dan penjelasan. Dengan demikian, nilai AI tidak hanya terletak pada akurasi, tetapi juga pada kemampuan menyusun rekomendasi yang relevan secara agronomis.

Framework ini juga memperjelas batas antara automasi dan dukungan keputusan. Dalam pertanian, sistem tidak seharusnya menggantikan sepenuhnya

penilaian petani atau penyuluh, terutama ketika data tidak lengkap atau kondisi lokal belum terekam dalam dataset. Karena itu, HAFA-Tani menempatkan human-in-the-loop sebagai prinsip desain. Pengguna dapat menerima, menolak, atau meminta alternatif rekomendasi, sedangkan sistem wajib menyimpan jejak alasan dan asumsi.

Dari sisi kebaruan, HAFA-Tani berbeda dari pendekatan crop recommendation yang hanya mengoptimalkan klasifikasi komoditas. Framework ini mengintegrasikan empat lapisan: prediksi kesesuaian, optimasi tata letak, risiko sumber daya, dan penjelasan berbasis bukti. Integrasi tersebut membuat framework lebih sesuai untuk artikel sistem

informasi karena menekankan arsitektur, aliran data, proses keputusan, dan tata kelola sistem.

Studi kasus sintesis yang ditambahkan memperlihatkan bahwa framework dapat dijelaskan secara operasional. Orchestrator Agent tidak hanya meneruskan permintaan pengguna, tetapi juga mengatur data quality check, memanggil agen prediksi, memeriksa alternatif layout, meneruskan hasil ke agen risiko, dan memastikan Explainability Agent bekerja dengan evidence. Hal ini menjawab kebutuhan metodologis untuk memperlihatkan bagaimana framework dapat diimplementasikan secara sederhana sebelum pengujian empiris dilakukan.

Keterbatasan framework ini adalah belum tersedianya evaluasi empiris pada dataset pertanian Indonesia. Selain itu, efektivitas framework sangat bergantung pada kualitas data, ketersediaan basis pengetahuan agronomi, dan validasi lapangan. LLM juga tetap membawa risiko halusinasi jika retrieval, prompt constraint, dan validasi output tidak dirancang dengan baik. Oleh sebab itu, implementasi lanjutan perlu dimulai dengan cakupan terbatas, misalnya satu wilayah dan dua atau tiga komoditas, sebelum diperluas.

Kesimpulan dan Saran

Penelitian ini mengusulkan HAFZA-Tani sebagai hybrid agentic AI framework untuk evaluasi kesesuaian lahan dan rekomendasi tata letak tanaman pada pertanian tropis. Framework terdiri atas Orchestrator Agent, Land Suitability Agent, Crop Layout and Rotation Agent, Resource and Risk Agent, Explainability Agent, serta Governance and Memory Layer. Hasil perancangan menunjukkan bahwa pendekatan multi-agen dapat mengintegrasikan prediksi, optimasi, risiko, dan penjelasan dalam satu alur decision support yang lebih transparan dan dapat diaudit.

Keunggulan framework terletak pada modularitas, kemampuan menghasilkan alternatif rekomendasi, evidence-grounded explanation, uncertainty tagging, serta pencatatan provenance. Kelemahannya adalah framework masih konseptual dan membutuhkan validasi empiris. Penelitian berikutnya disarankan mengembangkan prototipe minimum viable system, menguji model kesesuaian pada dataset pertanian tropis Indonesia, melakukan evaluasi dengan penyuluh atau petani, dan membandingkan kinerjanya dengan baseline crop recommendation biasa. Selain itu, pengembangan basis pengetahuan agronomi lokal menjadi prioritas agar sistem tidak hanya kuat secara teknis, tetapi juga relevan secara kontekstual.

Daftar Pustaka

[1] S. A. Bhat and N.-F. Huang, "Big Data and AI Revolution in Precision Agriculture: Survey and Challenges," *IEEE Access*, vol. 9, pp. 110209-110222, 2021, doi: 10.1109/ACCESS.2021.3102227.

[2] Badan Pusat Statistik, "Hasil Pencacahan Lengkap Sensus Pertanian 2023 - Tahap I," Badan Pusat Statistik, 2023. [Online]. Available: <https://www.bps.go.id/id/pressrelease/2023/12/04/2050/hasil-pencacahan-lengkap-sensus-pertanian-2023---tahap-i.html>

[3] A. Savelli, M. Atieno, J. Giles, J. Santos, J. Leyte, N. V. B. Nguyen, H. Koostanto, Y. Sulaeman, S. Douchamps, and G. Grosjean, *Climate-Smart Agriculture in Indonesia*. Hanoi, Vietnam: The Alliance of Bioversity International and CIAT; The World Bank Group, 2021. [Online]. Available: <https://hdl.handle.net/10568/114898>

[4] A. B. Moller, V. L. Mulder, G. B. M. Heuvelink, N. M. Jacobsen, and M. H. Greve, "Can We Use Machine Learning for Agricultural Land Suitability Assessment?," *Agronomy*, vol. 11, no. 4, Art. no. 703, 2021, doi: 10.3390/agronomy11040703.

[5] M. Hasan, M. A. Marjan, M. P. Uddin, M. I. Afjal, S. Kadry, S. Ma, and Y. Nam, "Ensemble Machine Learning-Based Recommendation System for Effective Prediction of Suitable Agricultural Crop Cultivation," *Frontiers in Plant Science*, vol. 14, Art. no. 1234555, 2023, doi: 10.3389/fpls.2023.1234555.

[6] K. Nabiollahi, N. M. Kebonye, F. Molani, M. H. Tahari-Mehrjardi, R. Taghizadeh-Mehrjardi, H. Shokati, and T. Scholten, "Assessment of Land Suitability Potential Using Ensemble Approaches of Advanced Multi-Criteria Decision Models and Machine Learning for Wheat Cultivation," *Remote Sensing*, vol. 16, no. 14, Art. no. 2566, 2024, doi: 10.3390/rs16142566.

[7] J. K. P. Sucipto and B. W. Sari, "Klasifikasi varietas bibit durian menggunakan ResNet50: Pendekatan deep learning untuk pertanian digital," *Journal of Information System Management (JOISM)*, vol. 7, no. 2, pp. 236-243, 2026, doi: 10.24076/joism.2026v7i2.2479.

[8] D. De Clercq, E. Nehring, H. Mayne, and A. Mahdi, "Large Language Models Can Help Boost Food Production, but Be Mindful of Their Risks," *Frontiers in Artificial Intelligence*, vol. 7, Art. no. 1326153, 2024, doi: 10.3389/frai.2024.1326153.

[9] C. Krupitzer, "Generative Artificial Intelligence in the Agri-Food Value Chain-Overview, Potential, and Research Challenges," *Frontiers in Food Science and Technology*, vol. 4, Art. no. 1473357, 2024, doi: 10.3389/frfst.2024.1473357.

[10] X. Zhao, B. Chen, M. Ji, X. Wang, Y. Yan, J. Zhang, S. Liu, M. Ye, and C. Lv, "Implementation of Large Language Models and Agricultural Knowledge Graphs for Efficient Plant Disease Detection," *Agriculture*, vol. 14, no. 8, Art. no. 1359, 2024, doi: 10.3390/agriculture14081359.

[11] M. T. Kuska, M. Wahabzada, and S. Paulus, "AI for Crop Production-Where Can Large Language Models (LLMs) Provide Substantial Value?," *Computers and Electronics in Agriculture*, vol. 221, Art. no. 108924, 2024, doi: 10.1016/j.compag.2024.108924.

[12] J. Li, M. Xu, L. Xiang, D. Chen, W. Zhuang, X. Yin, and Z. Li, "Foundation Models in Smart Agriculture: Basics, Opportunities, and Challenges," *Computers and Electronics in Agriculture*, vol. 222, Art. no. 109032, 2024, doi: 10.1016/j.compag.2024.109032.

[13] S. Yin, Y. Xi, X. Zhang, C. Sun, and Q. Mao, "Foundation Models in Agriculture: A Comprehensive Review," *Agriculture*, vol. 15, no. 8, Art. no. 847, 2025, doi: 10.3390/agriculture15080847.

- [14] M. Haghghat, A. Saleh, and M. R. Azghadi, "Multimodal Language Models in Agriculture: A Tutorial and Survey," *Information Fusion*, vol. 129, Art. no. 104042, 2026, doi: 10.1016/j.inffus.2025.104042.
- [15] R. N. V. J. Mohan, P. S. Rayanoothala, and R. P. Sree, "Next-Gen Agriculture: Integrating AI and XAI for Precision Crop Yield Predictions," *Frontiers in Plant Science*, vol. 15, Art. no. 1451607, 2025, doi: 10.3389/fpls.2024.1451607.
- [16] A. Rajbongshi, F. T. Johora, A. Hossain, M. S. Sarker, M. H. Rahman, M. W. Rahman, F. T. Alotaibi, and M. A. Moni, "Leveraging Explainable AI for Sustainable Agriculture: A Comprehensive Review of Recent Advances," *Artificial Intelligence Review*, vol. 59, no. 3, Art. no. 105, pp. 1-46, 2026, doi: 10.1007/s10462-025-11459-5.
- [17] P. N. Srinivasu, A. Pavate, G. JayaLakshmi, J. Shafi, J. Choi, and M. F. Ijaz, "Agentic AI for Smart and Sustainable Precision Agriculture," *Frontiers in Plant Science*, vol. 16, Art. no. 1706428, 2026, doi: 10.3389/fpls.2025.1706428.
- [18] M. Murad, M. Ahmed, N. Ul Din, M. F. Shahid, S. Siddiqui, D. Byers, and M. H. Tanveer, "Agentic AI Framework to Automate Traditional Farming for Smart Agriculture," *AgriEngineering*, vol. 8, no. 1, Art. no. 8, 2026, doi: 10.3390/agriengineering8010008.
- [19] N. L. P. Swati, S. V. Gupta, N. S. Duddela, and L. R. Parvathy, "Agentic AI-Driven Autonomous Decision Support System for Smart Agriculture," *Scientific Reports*, vol. 16, Art. no. 9972, 2026, doi: 10.1038/s41598-026-39472-w.
- [20] M. U. Tariq, S. M. Saqib, T. Mazhar, M. A. Khan, T. Shahzad, and H. Hamam, "Edge-Enabled Smart Agriculture Framework: Integrating IoT, Lightweight Deep Learning, and Agentic AI for Context-Aware Farming," *Results in Engineering*, vol. 28, Art. no. 107342, 2025, doi: 10.1016/j.rineng.2025.107342.
- [21] A. R. Hevner, S. T. March, J. Park, and S. Ram, "Design Science in Information Systems Research," *MIS Quarterly*, vol. 28, no. 1, pp. 75-105, 2004, doi: 10.2307/25148625.
- [22] K. Peffers, T. Tuunanen, M. A. Rothenberger, and S. Chatterjee, "A Design Science Research Methodology for Information Systems Research," *Journal of Management Information Systems*, vol. 24, no. 3, pp. 45-77, 2007, doi: 10.2753/MIS0742-1222240302.
- [23] M. J. Page et al., "The PRISMA 2020 Statement: An Updated Guideline for Reporting Systematic Reviews," *BMJ*, vol. 372, Art. no. n71, 2021, doi: 10.1136/bmj.n71.