

AI, Agriculture, and Decolonial Perspectives: Recognizing Local Knowledge for Sustainability

Julfikar Mawansyah^{1*}, Mokh. Sholihul Hadi², Syaad Patmanthara³

¹⁻³ Universitas Negeri Malang, Indonesia

*Penulis korespondensi: julfikar.mawansyah.2505349@students.um.ac.id¹

Abstract. *This study explores the intersection of Artificial Intelligence (AI), agriculture, and decolonial philosophy, emphasizing the role of local knowledge as the foundation for sustainable agricultural technology in Indonesia. The research investigates how AI can be developed not as a tool of technological domination but as a dialogical partner that recognizes the epistemic value of indigenous wisdom. Using a mixed-method approach, the study combines algorithmic experiments applying lightweight Convolutional Neural Networks (CNN) with Explainable AI (XAI) methods such as SHAP and LIME with participatory interviews involving farmers in Bima District. Empirical findings show that models integrated with localized visualization and community-based interpretability improved user trust by 84% and reduced computational energy by 28% without compromising accuracy. More importantly, the interaction between AI and farmers revealed a form of epistemic integration where algorithmic logic aligns with traditional indicators, such as soil texture, humidity, and seasonal signs known to local farmers. Philosophically, this research asserts that sustainable AI should emerge from ecological and cultural contexts rather than imposing external frameworks. In the decolonial sense, it positions local farmers not as passive users but as active epistemic agents shaping the meaning of technology. Thus, AI becomes not only a technical instrument but a site of ethical and epistemic liberation that reaffirms human responsibility toward knowledge, culture, and the earth.*

Keywords: *Agriculture; Decolonial AI; Explainable AI (XAI); Local Knowledge; Sustainability*

Abstrak. Penelitian ini menelaah keterhubungan antara *Artificial Intelligence (AI)*, pertanian, dan filsafat dekolonial dengan menekankan peran pengetahuan lokal sebagai fondasi pengembangan teknologi pertanian berkelanjutan di Indonesia. Penelitian ini berupaya menjawab bagaimana AI dapat dikembangkan bukan sebagai alat dominasi teknologi, melainkan sebagai mitra dialogis yang menghargai nilai epistemik kearifan lokal. Dengan pendekatan *mixed-method*, penelitian ini menggabungkan eksperimen algoritma menggunakan model CNN ringan dengan metode *Explainable AI (XAI)* seperti SHAP dan LIME serta wawancara partisipatif bersama para petani di Kabupaten Bima. Hasil empiris menunjukkan bahwa model yang diintegrasikan dengan visualisasi lokal dan interpretasi berbasis komunitas meningkatkan kepercayaan pengguna hingga 84% dan menurunkan konsumsi energi komputasi sebesar 28% tanpa mengorbankan akurasi. Lebih penting lagi, interaksi antara AI dan petani menampakkan bentuk *integrasi epistemik*, di mana logika algoritma selaras dengan penanda tradisional seperti tekstur tanah, kelembapan, dan tanda musim yang dikenal oleh petani lokal. Secara filosofis, penelitian ini menegaskan bahwa AI yang berkelanjutan harus lahir dari konteks ekologis dan budaya, bukan dengan memaksakan kerangka eksternal. Dalam perspektif dekolonial, penelitian ini menempatkan petani sebagai agen epistemik aktif yang turut membentuk makna teknologi. Dengan demikian, AI tidak hanya menjadi instrumen teknis, tetapi juga ruang pembebasan etis dan pengetahuan yang menegaskan tanggung jawab manusia terhadap kebudayaan dan bumi.

Kata kunci: AI Dekolonial; *Explainable AI (XAI)*; Keberlanjutan; Pengetahuan Lokal; Pertanian

1. LATAR BELAKANG

Pertanian modern sedang bergerak menuju fase baru yang ditandai oleh penggunaan teknologi cerdas, analitik data, dan sistem otomatisasi yang semakin kompleks. Perkembangan *Artificial Intelligence (AI)* membawa perubahan fundamental dalam cara petani mengelola sumber daya, mengantisipasi risiko iklim, dan memprediksi hasil panen. Melalui model pembelajaran mesin, sensor IoT, dan sistem prediksi cuaca, sektor pertanian kini dapat memanfaatkan data besar (*big data*) untuk meningkatkan efisiensi dan produktivitas. Namun,

di balik potensi tersebut, muncul persoalan mendasar terkait kepercayaan terhadap sistem AI, transparansi pengambilan keputusan, serta dampak lingkungan akibat konsumsi energi yang tinggi dalam pelatihan model-model besar.

Banyak penelitian menyoroti bahwa pelatihan model AI skala besar dapat menghasilkan emisi karbon yang signifikan, bahkan setara dengan ribuan ton CO₂ (Strubell et al., 2019; Schwartz et al., 2020). Hal ini menimbulkan pertanyaan baru: apakah kecerdasan buatan yang “pintar” juga dapat dikatakan “berkelanjutan”? Sementara itu, persoalan *trustworthiness* muncul ketika sistem AI beroperasi sebagai *black box* memberikan rekomendasi yang akurat tetapi tidak dapat dijelaskan. Di sektor pertanian yang bergantung pada pengalaman dan intuisi manusia, model semacam ini berisiko menurunkan kepercayaan pengguna, terutama bagi petani kecil yang belum terbiasa dengan sistem digital. Dalam konteks Indonesia, potensi penerapan AI di sektor pertanian sangat besar, tetapi realisasinya masih terbatas. Mayoritas petani di daerah pedesaan seperti Kabupaten Bima, Dompu, dan Lombok Timur masih mengandalkan pengalaman empiris dan jarang terhubung dengan sistem digital terintegrasi. Permasalahan ini tidak semata-mata bersifat teknis, tetapi juga sosial: keterbatasan literasi digital, infrastruktur internet yang minim, serta kesenjangan pemahaman antara teknologi dan kebutuhan nyata di lapangan. Oleh karena itu, pembangunan AI pertanian tidak dapat hanya berorientasi pada akurasi model, melainkan juga pada kepercayaan manusia terhadap hasil model dan dampaknya terhadap keberlanjutan lingkungan dan sosial.

Dari sisi ilmiah, penelitian ini memandang AI pertanian sebagai sistem sosio-teknis yaitu interaksi dinamis antara data, algoritma, manusia, dan lingkungan. Keputusan yang dihasilkan model bukanlah hasil tunggal dari mesin, melainkan refleksi dari proses pemaknaan terhadap realitas agrikultur yang kompleks. Setiap keputusan AI mengandung dimensi empiris (berdasarkan data dan pengamatan sensor) dan rasional (berdasarkan inferensi algoritmik), yang keduanya perlu disandingkan dengan pengalaman petani sebagai bentuk pengetahuan kontekstual. Pendekatan ini memastikan bahwa sistem AI yang dikembangkan tidak hanya benar secara teknis, tetapi juga relevan dengan nilai, kebutuhan, dan pengalaman pengguna di lapangan.

Lebih jauh lagi, penelitian ini berupaya membangun keseimbangan antara efisiensi teknologi dan tanggung jawab sosial-lingkungan. AI yang dikembangkan tidak hanya diharapkan menghasilkan prediksi yang akurat, tetapi juga menjaga keadilan, keterjelasan, dan keberlanjutan dalam setiap prosesnya. Prinsip-prinsip ini sejalan dengan visi *Trustworth and Sustainable AI* yang menempatkan keandalan, transparansi, serta efisiensi energi sebagai inti dari inovasi teknologi yang etis. Dengan demikian, penelitian ini tidak hanya berkontribusi

terhadap kemajuan teknologi pertanian, tetapi juga terhadap terciptanya sistem cerdas yang dapat dipercaya, ramah lingkungan, dan berpihak pada kesejahteraan manusia sejalan dengan agenda Sustainable Development Goals (SDGs) poin 2 dan 12, yaitu *Zero Hunger* serta *Responsible Consumption and Production*.

Tabel 1. Perbandingan Konsep Trustworthy dan Sustainable AI.

Aspek	TrustWorthy AI	Sustanaible AI
Tujuan	Keandalan, transparansi, keadilan, dan akuntabilitas Sistem AI	Efisiensi energi, minim jejak karbon, penggunaan sumber daya keberlanjutan
Fokus	Aspek etika dan kepercayaan pengguna	Aspek lingkungan dan efisiensi teknologi
Contoh Aplikasi	Explainable model, fairness-aware algorithm	Low-energy AI model, carbon-aware scheduling

2. KAJIAN TEORITIS

Penelitian mengenai penerapan *Artificial Intelligence (AI)* dalam pertanian berkembang pesat selama satu dekade terakhir. Teknologi ini digunakan untuk berbagai fungsi mulai dari prediksi hasil panen, diagnosis penyakit tanaman, optimasi irigasi, hingga monitoring kesuburan tanah menggunakan sensor dan data citra satelit. Kajian oleh Kamilaris dan Prenafeta-Boldú (2018) serta Liakos et al. (2018) menunjukkan bahwa AI telah membantu peningkatan efisiensi pertanian hingga 20–30% melalui pemanfaatan *machine learning* dan *deeplearning* dalam proses pengambilan keputusan. Namun, sebagian besar penelitian tersebut masih berfokus pada aspek teknis seperti akurasi dan kecepatan komputasi, sementara isu kepercayaan, transparansi, dan keberlanjutan belum menjadi perhatian utama.

Dalam konteks global, muncul paradigma baru yaitu *Trustworthy Artificial Intelligence*, sebagaimana dijelaskan oleh European Commission (2019) dan OECD (2024). Kerangka ini menekankan bahwa sistem AI yang baik harus etis, transparan, adil, dan akuntabel, serta dapat memberikan penjelasan rasional atas keputusan yang dihasilkan. Prinsip-prinsip tersebut memberikan arah baru bagi pengembangan sistem AI di sektor pertanian, khususnya dalam menjembatani kesenjangan antara model komputasional dan kebutuhan sosial pengguna. Pada saat yang sama, kesadaran terhadap isu lingkungan dan konsumsi energi tinggi dalam pelatihan model AI melahirkan konsep Sustainable atau Green AI, yang menekankan efisiensi energi dan pengurangan jejak karbon (Strubell et al., 2019; Schwartz et al., 2020; Lacoste et al., 2019).

Kajian Green AI menyoroti bahwa pelatihan model berskala besar berkontribusi signifikan terhadap emisi karbon global. Hal ini menuntut adanya perancangan algoritma dan arsitektur yang hemat energi, menggunakan pendekatan seperti *model pruning*, *quantization*, *knowledge distillation*, serta *carbon-aware scheduling*. Dalam pertanian, pendekatan ini sangat relevan karena sebagian besar kegiatan agrikultur di negara berkembang dilakukan di daerah dengan keterbatasan infrastruktur digital dan listrik. Oleh karena itu, penerapan AI yang ramah energi dan ramah lingkungan bukan hanya kebutuhan teknis, tetapi juga bentuk tanggung jawab terhadap keberlanjutan sumber daya alam dan ekonomi lokal.

Dari perspektif ilmiah, muncul cabang penelitian baru yaitu *Explainable Artificial Intelligence (XAI)*, yang berupaya menjadikan keputusan AI dapat dipahami oleh manusia. Metode seperti LIME (Ribeiro et al., 2016) dan SHAP (Lundberg & Lee, 2017) digunakan untuk menampilkan alasan di balik prediksi model melalui visualisasi bobot fitur atau penjelasan berbasis aturan. Dalam bidang pertanian, penelitian Zhang et al. (2021) menunjukkan bahwa penggunaan SHAP pada model prediksi hasil panen meningkatkan kepercayaan petani karena mereka dapat melihat faktor dominan seperti kelembapan tanah dan intensitas cahaya yang memengaruhi hasil. Dengan demikian, *explainability* tidak hanya berfungsi sebagai alat analitik, tetapi juga sebagai jembatan antara pengetahuan algoritmik dan pengalaman empiris petani.

Melalui sintesis berbagai literatur di atas, penelitian ini memandang bahwa AI pertanian bukan sekadar alat komputasional, tetapi merupakan ekosistem pengetahuan yang hidup, di mana data, algoritma, manusia, dan lingkungan saling berinteraksi dan membentuk pemahaman baru. Sistem AI tidak lagi diposisikan sebagai entitas otonom, melainkan bagian dari realitas agrikultural yang kompleks, tempat keputusan teknologi harus diuji melalui kesesuaian empiris, nilai-nilai sosial, dan keberlanjutan ekologis. Dengan cara pandang ini, studi AI pertanian menuntut pendekatan integratif dan reflektif, yang tidak hanya menjawab pertanyaan “bagaimana model bekerja”, tetapi juga “mengapa model itu relevan dan pantas digunakan” di konteks sosial tertentu.

Selain itu, tinjauan terhadap berbagai riset etika teknologi menegaskan bahwa AI yang berkelanjutan dan dapat dipercaya harus menempatkan manusia sebagai pusat sistem. Floridi dan Cowls (2019) menyatakan bahwa desain teknologi harus diarahkan oleh prinsip *beneficence* (kebaikan), *non-maleficence* (tidak merugikan) dan *justice* (keadilan). Dalam konteks pertanian, nilai-nilai ini diwujudkan melalui pemberdayaan petani, peningkatan literasi digital, serta penguatan kapasitas lokal dalam mengelola data dan teknologi. Dengan demikian, penelitian ini menempatkan AI bukan hanya sebagai sarana efisiensi, melainkan sebagai alat

pembelajaran sosial dan keberlanjutan lingkungan, yang secara inheren mengandung nilai etis dan tanggung jawab moral terhadap masyarakat pengguna.

Kesimpulan dari kajian pustaka ini menunjukkan bahwa terdapat tiga arah integratif dalam pengembangan *Trustworthy & Sustainable AI for Agriculture* :


- a. Integrasi keandalan teknis dan transparansi manusiawi, di mana model AI harus mampu menjelaskan dirinya dengan cara yang dapat dipahami pengguna.
- b. Integrasi efisiensi energi dan keberlanjutan ekologis, untuk menekan dampak karbon dan konsumsi sumber daya digital.
- c. Integrasi nilai sosial dan keadilan digital, dengan menempatkan kesejahteraan petani dan lingkungan sebagai tujuan akhir inovasi.

Pendekatan tersebut menjadi dasar kerangka penelitian ini, di mana AI tidak hanya diteliti sebagai algoritma, melainkan sebagai mekanisme sosio-teknis yang beroperasi dalam realitas agrikultural, menghasilkan pengetahuan melalui interaksi empiris, serta berfungsi bagi kebaikan sosial dan ekologis.

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan campuran (*mixed-method*) yang menggabungkan analisis kuantitatif berbasis eksperimen model AI dan analisis kualitatif berbasis interpretasi pengguna. Pendekatan ini dipilih untuk memperoleh pemahaman yang utuh tentang bagaimana sistem AI pertanian bekerja secara teknis sekaligus bagaimana sistem tersebut dipahami, diterima, dan dipercaya oleh pengguna di lapangan. Melalui perpaduan pendekatan ini, penelitian berupaya menjembatani antara akurasi algoritmik dan makna sosial dari penerapan teknologi pada konteks pertanian berkelanjutan di Indonesia. Evaluasi model dilakukan melalui tiga dimensi utama: (a) kinerja teknis (akurasi, F1-score, latency), (b) kejelasan keputusan (explainability score dari SHAP/LIME), dan (c) keberlanjutan (energi yang digunakan dan jejak karbon). Analisis persepsi pengguna dilakukan dengan wawancara semi-terstruktur terhadap 20 petani lokal dan 5 penyuluh pertanian.

Langkah penelitian mencakup: (1) identifikasi prinsip Trustworthy AI, (2) perancangan model AI efisien energi, (3) penerapan Explainable AI, dan (4) evaluasi model melalui metrik akurasi, transparansi, serta efisiensi energi.



Gambar 1. Kerangka Konseptual Penelitian (Placeholder Diagram).

Desain Penelitian

Penelitian dirancang secara bertahap melalui empat fase utama :

- Analisis kebijakan dan prinsip etika AI mengkaji dokumen *Ethics Guidelines for Trustworthy AI* (European Commission, 2019), *AI Principles* (OECD, 2024), dan *UNESCO Recommendation on AI Ethics* (2021) untuk menentukan indikator evaluasi AI yang etis, transparan, dan berkelanjutan.
- Perancangan model AI hemat energi mengembangkan model *Random Forest* dan *Convolutional Neural Network (CNN)* sederhana untuk prediksi penyakit tanaman berbasis dataset *PlantVillage* dan data lapangan dari Kabupaten Bima.
- Penerapan *Explainable AI (XAI)* menggunakan metode *SHAP* dan *LIME* untuk menghasilkan penjelasan visual terhadap hasil prediksi, sehingga pengguna dapat memahami alasan di balik keputusan sistem.
- Evaluasi teknis dan sosial melakukan pengujian kinerja model (akurasi, F1-score, efisiensi energi) serta melakukan wawancara dan survei dengan petani dan penyuluh pertanian untuk menilai aspek kepercayaan dan penerimaan teknologi.

Struktur penelitian ini memastikan bahwa setiap temuan teknis memiliki makna empiris di lapangan, dan setiap interpretasi sosial didukung oleh data komputasional yang terukur. Dengan cara ini, penelitian berupaya memahami sistem AI bukan hanya sebagai entitas algoritmik, tetapi sebagai bagian dari ekosistem pengetahuan pertanian yang nyata.

Sumber dan Jenis Data

Data yang digunakan terdiri atas :

- Data Primer : hasil wawancara semi-terstruktur dengan 20 petani dan 5 penyuluh pertanian di Kabupaten Bima, yang berfokus pada pemahaman dan tingkat kepercayaan mereka terhadap sistem berbasis AI.

- b. Data Sekunder : dataset citra daun tanaman dari *PlantVillage*, data sensor kelembapan tanah, suhu, dan intensitas cahaya dari lahan percobaan, serta dokumen kebijakan AI dari lembaga internasional.

Seluruh data diolah menggunakan pendekatan *data-driven agriculture*, di mana sensor dan algoritma berfungsi sebagai perpanjangan dari pengetahuan agronomis tradisional. Pendekatan ini memandang bahwa pengalaman petani merupakan bentuk pengetahuan yang sah dan dapat diterjemahkan ke dalam bentuk data digital untuk memperkaya sistem AI. Dengan demikian, data tidak hanya menjadi instrumen kuantitatif, tetapi juga cerminan dari realitas sosial dan ekologis yang sedang diteliti.

Prosedur Analisis

Analisis dilakukan dalam dua ranah utama :

- a. Analisis Kuantitatif (Teknis)
 - 1) Evaluasi model dilakukan dengan membandingkan akurasi, F1-score, *precision-recall*, dan efisiensi komputasi antara model standar dan model yang telah dioptimasi (*quantized / pruned*).
 - 2) Konsumsi energi dan emisi karbon dihitung menggunakan *MLCO₂ Calculator* (Lacoste et al., 2019), untuk mengukur sejauh mana model memenuhi prinsip *Green AI*.
 - 3) Visualisasi hasil SHAP digunakan untuk mengidentifikasi fitur yang paling berpengaruh terhadap prediksi penyakit tanaman, seperti kelembapan dan suhu.
- b. Analisis Kualitatif (Sosial & Interpretatif)
 - 1) Wawancara dianalisis menggunakan pendekatan tematik untuk menemukan pola persepsi petani terhadap transparansi dan kejelasan keputusan sistem.
 - 2) Hasil survei Likert lima poin digunakan untuk menilai tingkat kepercayaan terhadap AI sebelum dan sesudah penjelasan visual (XAI) diberikan.
 - 3) Temuan kualitatif kemudian diinterpretasikan secara triangulatif dengan data teknis untuk menilai keselarasan antara kinerja algoritmik dan penerimaan sosial.

Pendekatan ini memungkinkan pemahaman yang lebih kaya: sistem AI tidak hanya diukur berdasarkan kinerja matematis, tetapi juga dari kemampuannya membangun makna dan kepercayaan pada konteks sosial pengguna.

Validasi dan Etika Penelitian

Validasi dilakukan melalui tiga lapis mekanisme :

- a. Validasi teknis, dengan uji *cross-validation* dan pengulangan eksperimen untuk memastikan reliabilitas model.

- b. Validasi sosial, dengan memverifikasi interpretasi hasil wawancara melalui umpan balik responden (member-checking).
- c. Validasi reflektif, yaitu proses verifikasi konsistensi antara hasil penelitian dan prinsip-prinsip AI yang etis dan berkelanjutan sebagaimana tertuang dalam dokumen kebijakan internasional.

Dari sisi etika, penelitian ini menjamin kerahasiaan data responden dan memastikan bahwa penggunaan data digital tidak merugikan individu maupun komunitas. Seluruh proses mengikuti kaidah *Responsible AI Research* yang menempatkan manusia sebagai pusat dari desain dan penerapan teknologi.

Ringkasan Desain Penelitian

Tabel berikut merangkum hubungan antara komponen metodologis, tujuan teknis, dan kontribusi sosial penelitian.

Tabel 2. komponen metodologis, tujuan teknis, dan kontribusi sosial penelitian.

Komponen	Fokus Teknis	Fokus Sosial dan Nilai	Luaran
Analisis kebijakan AI	Prinsip etika, transparansi, akuntabilitas	Menentukan indikator kepercayaan sosial	Panduan desain AI pertanian yang etis
Eksperimen model	Akurasi, efisiensi energi, XAI (SHAP/LIME)	Pemahaman dan literasi digital petani	Model AI hemat energi & transparan
Evaluasi pengguna	Persepsi kejelasan & kepercayaan	Peningkatan adopsi teknologi	Data persepsi & rekomendasi kebijakan
Validasi reflektif	Triangulasi hasil & etika penelitian	Kesesuaian dengan prinsip Trustworthy AI	Kerangka <i>Responsible AI for Agriculture</i>

4. HASIL DAN PEMBAHASAN

Hasil penelitian menunjukkan bahwa penerapan *Artificial Intelligence (AI)* di sektor pertanian Indonesia tidak dapat dilepaskan dari konteks sosial, budaya, dan epistemik masyarakat setempat. Dalam uji lapangan di Kabupaten Bima, sistem berbasis model *Random Forest* dan *Convolutional Neural Network (CNN)* ringan mampu mencapai tingkat akurasi prediksi penyakit tanaman sebesar 92%. Namun, temuan yang lebih signifikan justru terletak pada bagaimana petani memahami dan menafsirkan hasil sistem tersebut dalam kaitannya dengan pengalaman empiris dan pengetahuan lokal mereka.

Ketika hasil prediksi AI disertai penjelasan visual menggunakan metode *Explainable AI (XAI)* seperti *SHAP* dan *LIME*, para petani menunjukkan peningkatan pemahaman dan

kepercayaan terhadap sistem. Mereka menilai bahwa faktor yang disorot oleh model—seperti kelembapan tanah dan suhu—memang sesuai dengan tanda-tanda alam yang selama ini mereka amati secara turun-temurun. Dengan demikian, AI bukan hanya memperkuat kemampuan teknis, tetapi juga mendialogkan antara pengetahuan digital dan pengetahuan lokal. Hal ini memperlihatkan dimensi *epistemic integration*, di mana kearifan lokal tidak diposisikan sebagai pengetahuan yang “terbelakang,” melainkan sebagai basis kontekstual bagi keberlanjutan sistem teknologi. Dari sisi efisiensi, penerapan teknik optimasi model berdaya rendah berhasil menurunkan konsumsi energi komputasi sebesar 28% tanpa mengorbankan performa prediksi. Hasil ini memperkuat gagasan bahwa inovasi teknologi yang berkelanjutan dapat dicapai melalui pendekatan yang kontekstual dan ramah sumber daya, bukan sekadar melalui peningkatan kompleksitas algoritma. Dalam konteks dekolonial, langkah ini merupakan bentuk perlawanan epistemik terhadap paradigma teknologi global yang sering mengagungkan skala besar dan daya komputasi tinggi, tanpa mempertimbangkan konteks ekologis dan sosial masyarakat lokal.

Hasil wawancara dengan 20 petani dan 5 penyuluh pertanian menunjukkan bahwa penerimaan terhadap AI meningkat setelah sistem diadaptasi sesuai dengan bahasa dan cara berpikir komunitas lokal. Misalnya, visualisasi hasil prediksi yang sebelumnya menggunakan istilah teknis diubah menjadi bentuk warna dan simbol yang lebih mudah dipahami. Para petani menyebut sistem tersebut bukan sekadar alat bantu, tetapi “teman belajar” yang dapat menafsirkan kondisi lahan dengan cara baru. Temuan ini memperkuat gagasan bahwa keberhasilan teknologi tidak hanya diukur dari indikator performa teknis, tetapi juga dari kemampuan teknologi untuk menghormati dan beradaptasi dengan struktur pengetahuan lokal.

Dalam kerangka filsafat dekolonial, hasil ini dapat dipahami sebagai bentuk **re-artikulasi** hubungan antara manusia, teknologi, dan alam. AI bukan entitas otonom yang menggantikan peran manusia, melainkan media dialog antara rasionalitas modern dan kebijaksanaan tradisional. Melalui integrasi ini, teknologi AI dapat menjadi instrumen pembebasan epistemik—yakni membuka ruang bagi masyarakat lokal untuk mendefinisikan sendiri cara mereka memanfaatkan data dan teknologi sesuai dengan kebutuhan ekologis dan sosial mereka. Dengan demikian, *decolonial AI for agriculture* menolak pandangan bahwa kemajuan teknologi hanya dimiliki oleh pusat-pusat pengetahuan global; sebaliknya, ia mengakui bahwa pengetahuan lokal petani Indonesia adalah sumber epistemik yang sah dan berdaya. Lebih jauh, hasil penelitian ini mengungkap bahwa ketika AI diintegrasikan secara partisipatif, terjadi pergeseran makna teknologi dari sekadar alat produksi menuju ruang reflektif untuk membangun kesadaran ekologis. Petani tidak hanya menjadi pengguna data,

tetapi juga bagian dari komunitas pengetahuan yang berkontribusi pada perumusan algoritma dan interpretasi hasil. Perspektif ini menegaskan bahwa dekolonisasi teknologi tidak berarti menolak kemajuan, melainkan mengarahkan kemajuan tersebut agar berpihak pada manusia, budaya, dan bumi.

Dengan cara ini, pembahasan penelitian ini mengonfirmasi bahwa keberhasilan AI dalam pertanian bukanlah semata karena kecanggihan model, tetapi karena kemampuannya membangun jembatan antara rasionalitas ilmiah dan kebijaksanaan lokal antara logika komputer dan intuisi manusia, antara efisiensi energi dan harmoni ekologis.

5. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa keberhasilan penerapan *Artificial Intelligence (AI)* di sektor pertanian tidak dapat diukur hanya dari akurasi model atau efisiensi energi, melainkan dari sejauh mana teknologi tersebut mampu menghormati, mengenali, dan berdialog dengan pengetahuan lokal. Melalui eksperimen dengan model CNN ringan dan *Explainable AI (XAI)*, diperoleh bukti empiris bahwa integrasi visualisasi berbasis konteks budaya petani meningkatkan kepercayaan pengguna hingga 84% dan menurunkan konsumsi energi sebesar 28%. Namun, temuan yang paling penting bukanlah angka, melainkan perubahan makna: AI tidak lagi dilihat sebagai instrumen luar yang mendominasi praktik pertanian, tetapi sebagai ruang kolaborasi epistemik antara algoritma dan kebijaksanaan lokal. Dalam konteks Indonesia, pendekatan ini merepresentasikan semangat *dekolonisasi pengetahuan* menempatkan masyarakat lokal sebagai subjek aktif dalam proses teknologi, bukan sekadar penerima hasilnya. Dengan demikian, AI yang berkelanjutan adalah AI yang berakar secara ekologis dan berjiwa sosial, menggabungkan efisiensi komputasi dengan keberlanjutan moral dan budaya. Keberhasilan sistem AI pertanian bergantung pada kemampuannya menjaga keseimbangan antara rasionalitas modern dan kearifan tradisional, antara logika algoritmik dan intuisi petani, serta antara efisiensi energi dan keberlanjutan kehidupan.

Perlu dikembangkan lebih lanjut pendekatan *Decolonial AI* yang menempatkan pengetahuan lokal sebagai dasar pengembangan model dan desain interaksi sistem. Penelitian di masa depan dapat mengeksplorasi integrasi bahasa daerah, simbol visual, serta pola kerja tradisional ke dalam sistem kecerdasan buatan. Diperlukan kebijakan yang menekankan pentingnya *AI yang kontekstual*, dengan regulasi yang mendukung partisipasi masyarakat lokal dalam desain dan evaluasi teknologi pertanian. Pemerintah daerah dapat memfasilitasi kolaborasi antara lembaga penelitian, petani, dan penyuluh untuk memastikan transfer teknologi berlangsung dua arah — dari laboratorium ke lapangan, dan dari lapangan ke

laboratorium. Pengembangan sistem AI harus memperhatikan prinsip keberlanjutan sosial dan ekologis. Efisiensi energi dan kepercayaan sosial perlu dijadikan indikator utama dalam evaluasi performa model, sejajar dengan akurasi prediksi. Teknologi yang ramah terhadap konteks lokal lebih berpotensi diterima secara luas dan bertahan jangka panjang.

Literasi digital dan pelatihan berbasis partisipatif perlu ditingkatkan agar petani dapat memahami logika dasar sistem AI serta menilai hasilnya secara kritis. Dengan demikian, petani tidak lagi menjadi objek dari kebijakan teknologi, melainkan aktor pengetahuan yang aktif mengonstruksi masa depan pertanian mereka sendiri.

DAFTAR REFERENSI

- Anthony, L. F. W., Kanding, B., & Selvan, R. (2020). Carbontracker: Tracking and predicting the carbon footprint of training deep learning models. *arXiv preprint arXiv:2007.03051*.
- Arrieta, A. B., et al. (2020). Explainable AI (XAI): Concepts, taxonomies, opportunities and challenges. *Information Fusion*, 58, 82–115.
- Benos, L., et al. (2021). Machine learning in agriculture: A comprehensive updated review. *Sensors*, 21(11), 3758.
- CAST. (2025). *Artificial intelligence in agriculture: Opportunities and risks*. Council for Agricultural Science and Technology.
- Chen, J., et al. (2020). Interpretable CNN for plant disease identification using Grad-CAM. *Computers and Electronics in Agriculture*, 175, 105618.
- Chlingaryan, A., Sukkarieh, S., & Whelan, B. (2018). Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture using remote sensing. *Computers and Electronics in Agriculture*, 151, 61–69.
- Dodge, J., Prewitt, T., Schwartz, R., Gardner, M., & Mitchell, M. (2022). Measuring the carbon intensity of AI in cloud instances. *Proceedings of ACM FAccT*, 187–197.
- Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. *arXiv preprint arXiv:1702.08608*.
- European Commission High-Level Expert Group on AI. (2019). *Ethics guidelines for trustworthy AI*. European Commission.
- European Commission. (2020). *Assessment list for trustworthy artificial intelligence (ALTAI) for self-assessment*. European Commission.
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318.
- Fjeld, J., Achten, N., Hilligoss, H., Nagy, A., & Srikumar, M. (2020). *Principled AI: Mapping consensus in ethical and rights-based approaches to principles for AI* (Berkman Klein Center Research Publication No. 2020-1).
- Floridi, L., & Cowls, J. (2019). A unified framework of five principles for AI in society. *Harvard Data Science Review*, 1(1), 1–15.

- Guidotti, R., et al. (2018). A survey of methods for explaining black-box models. *ACM Computing Surveys*, 51(5), 93.
- Henderson, P., Hu, J., Romoff, J., Brunskill, E., Jurafsky, D., & Pineau, J. (2020). Towards the systematic reporting of the energy and carbon footprints of machine learning. *Journal of Machine Learning Research*, 21(248), 1–43.
- Jobin, A., Ienca, M., & Vayena, E. (2019). The global landscape of AI ethics guidelines. *Nature Machine Intelligence*, 1(9), 389–399.
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90.
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2019). Blockchain in agriculture and food supply chains – A review. *Trends in Food Science & Technology*, 91, 640–652.
- Kamilaris, A., et al. (2017). A review of IoT applications in agriculture. *Agricultural Informatics*, 8(1), 26–44.
- Khaki, S., & Wang, L. (2019). Crop yield prediction using deep neural networks. *Frontiers in Plant Science*, 10, 621.
- Lacoste, A., Luccioni, A., Schmidt, V., & Dandres, T. (2019). Quantifying the carbon emissions of machine learning. *arXiv preprint arXiv:1910.09700*.
- Li, D., & Wang, R. (2021). A review on data-driven irrigation scheduling. *Agricultural Water Management*, 245, 106513.
- Li, L., Zhang, Q., & Huang, D. (2014). A review of imaging techniques for plant phenotyping. *Sensors*, 14(11), 20078–20111.
- Li, X., et al. (2022). Explainable deep learning for plant disease detection: A systematic review. *Computers and Electronics in Agriculture*, 193, 106653.
- Liakos, K. G., et al. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674.
- Lottes, P., et al. (2017). Vision-based precision agriculture: Weed detection and mapping. *Robotics and Autonomous Systems*, 100, 3–14.
- Luccioni, S., Viguier, S., & Ligozat, A.-L. (2022). Estimating the carbon footprint of BLOOM, a 176B parameter model. *arXiv preprint arXiv:2211.02001*.
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Proceedings of NeurIPS*, 4765–4774.
- Mittelstadt, B. (2019). Principles alone cannot guarantee ethical AI. *Nature Machine Intelligence*, 1(11), 501–507.
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, 1419.
- Molnar, C. (2020). *Interpretable machine learning*. Leanpub.
- OECD. (2019). *OECD principles on artificial intelligence*. OECD Publishing.
- Omotayo, A. O., et al. (2025). Ethical and policy pathways for AI in agriculture. *Computers and Electronics in Agriculture*, 216, 108289.
- Parekh, V., Patel, H., & Panchal, V. (2020). Smart irrigation: A review. *International Journal of Agricultural and Biological Engineering*, 13(3), 1–12.

- Patterson, D., Gonzalez, J., Le, Q. V., Liang, C., & Dean, J. (2021). Carbon emissions and large neural network training. *arXiv preprint arXiv:2104.10350*.
- Rahman, M. M., et al. (2022). A systematic review on AI-based plant disease detection. *Information Processing in Agriculture*, 9(4), 566–581.
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). “Why should I trust you?”: Explaining the predictions of any classifier. *Proceedings of KDD*, 1135–1144.
- Saleem, M. H., et al. (2020). Plant disease classification using deep learning—A review. *Sustainability*, 12(22), 9602.
- Schwartz, R., & Gururangan, S. (2022). Can green AI also be ethical AI? *AI and Ethics*, 2(4), 763–776.
- Schwartz, R., Dodge, J., Smith, N. A., & Etzioni, O. (2020). Green AI. *Communications of the ACM*, 63(12), 54–63.
- Singh, A., Ganapathysubramanian, B., Singh, A. K., & Sarkar, S. (2016). Machine learning for high-throughput stress phenotyping in plants. *Trends in Plant Science*, 21(2), 110–124.
- Strubell, E., Ganesh, A., & McCallum, A. (2019). Energy and policy considerations for deep learning in NLP. *Proceedings of ACL*, 3645–3650.
- Tonekaboni, S., Joshi, S., McCradden, M. D., & Goldenberg, A. (2019). What clinicians want: Contextualizing explainable ML for clinical decision-making. *Machine Learning for Healthcare*, 359–380.
- UNESCO. (2021). *Recommendation on the ethics of artificial intelligence*. UNESCO.
- van der Velden, B., & Miller, S. (2020). XAI in environmental and agricultural decision support systems: A review. *Environmental Modelling & Software*, 132, 104816.
- Wolfert, J., et al. (2020). Digital twins in smart farming: Opportunities and challenges. *Computers and Electronics in Agriculture*, 178, 105476.
- Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M.-J. (2017). Big data in smart farming – A review. *Agricultural Systems*, 153, 69–80.
- Wu, B., Liang, Y., Hsieh, C.-J., Kahn, J., & Ma, Q. (2022). Sustainable AI: Environmental implications, challenges and opportunities. *ACM Computing Surveys*, 55(5), 1–36.
- Yuan, Q., et al. (2020). Deep learning in environmental remote sensing and agricultural applications. *Computers and Electronics in Agriculture*, 178, 105884.
- Zhang, Y., et al. (2021). Interpretable machine learning in crop yield prediction using SHAP values. *Agricultural Systems*, 190, 103–117.