

बागवानी में कृत्रिम बुद्धिमत्ता

रोग और कीट नדיान से बुद्धिमिान प्रजनन तक



अधविक्ता कमि क्यूंग-जनि

**यह पुस्तक कृत्रिम बुद्धिमत्ता की सहायता से व्यवस्थित और तैयार की गई है।
इसमें विश्व की प्रमुख भाषाओं में प्रकाशित सामग्री को एकत्र और समेकित किया
गया है।**

<https://notebook.google.com/notebook/9b8e426d-0ee9-4890-9911-cefce7a0f598>

ऊपर दिया गया लिंक इस पुस्तक की तैयारी में देखी गई सामग्री का सार्वजनिक NotebookLM संग्रह
खोलता है।

कोई भी इसे स्वतंत्र रूप से खोलकर उपयोग कर सकता है।

विषय-सूची

अध्याय 1	कंप्यूटर विज्ञान और डीप लर्निंग से फसल के रोगों और कीटों का निदान	3
1.1	फसल के रोगों, कीटों और खरपतवारों की सटीक पहचान और निदान	5
1.2	फलों की परिपक्वता का आकलन तथा वृद्धि और उपज का पूर्वानुमान	14
अध्याय 2	बागवानी रोबोट और स्वायत्त कार्य स्वचालन	25
2.1	फल, सब्जी और मशरूम कटाई रोबोट तथा एंड-इफेक्टर	27
2.2	स्वायत्त रोबोट मार्ग, ड्रोन दल और सटीक नियंत्रण का अनुकूलन	36
अध्याय 3	स्मार्ट ग्रीनहाउस और नियंत्रित वातावरण कृषि (CEA) का पर्यावरण नियंत्रण	45
3.1	IoT-आधारित बहु-सेंसर निगरानी और बुद्धिमान पर्यावरण मापन	47
3.2	डिजिटल द्विचक्र और AI से पर्यावरण और वृद्धि का बुद्धिमान अनुकूलन	58
अध्याय 4	डेटा-आधारित सटीक कृषि और निर्णय सहायता	68
4.1	स्मार्ट सिंचाई और उर्वरक आपूर्ति का अनुकूलन	70
4.2	स्थान-समय डेटा संलयन तथा वितरण और गुणवत्ता प्रबंधन	79
अध्याय 5	AI-आधारित डिजिटल फीनोटाइपिंग और प्रजनन जैव प्रौद्योगिकी	90
5.1	उच्च-श्रृंखला फसल फीनोटाइपिंग	92
5.2	पूर्वानुमानात्मक प्रजनन और बुद्धिमान जैव-प्रजनन तकनीक	102

अध्याय 1

कंप्यूटर विज्ञान और डीप लर्निंग से फसल के रोगों और कीटों का निदान

1.1

फसल के रोगों, कीटों और खरपतवारों की सटीक पहचान और निदान

अमेरिकी कंपनी Carbon Robotics का बनाया LaserWeeder प्रति घंटे 100,000 से अधिक खरपतवारों को लेज़र से जलाकर नष्ट करता है। 2022 में पेश किए जाने के बाद से यह रोबोट कुल 10 अरब से अधिक खरपतवार नष्ट कर चुका है, 2026 की पहली तिमाही में इसका राजस्व 100 मिलियन डॉलर से अधिक हो गया और 15 देशों के लगभग 100 खेत इसका उपयोग कर रहे हैं। इसी अवधि में दक्षिण कोरिया में Rural Development Administration का बनाया कृत्रिम बुद्धिमत्ता निदान ऐप 31 फसलों तथा 182 रोगों और कीटों की पहचान कर रहा है। हम ऐसे युग में प्रवेश कर चुके हैं जिसमें पत्तियों को एक-एक करके पलटकर घाव देखने और हाथ से खरपतवार उखाड़ने का काम कैमरे और एल्गोरिदम संभाल रहे हैं।

बागवानी फसलों की उपज और गुणवत्ता राष्ट्रीय खाद्य सुरक्षा और किसानों की आय, दोनों को सहारा देती हैं। लेकिन जलवायु बदलने पर रोगजनक नए रूप धारण करते हैं और अनजान क्षेत्रों तक फैलते हैं, जबकि खरपतवार फसलों के साथ उसी धूप, पानी और पोषक तत्वों के लिए प्रतिस्पर्धा करते हैं। लंबे समय तक इस लड़ाई की अग्रिम पंक्ति मनुष्य की आंखें थीं। अंग्रेज़ी में इस तरीके को विज़ुअल स्काउटिंग (Visual Scouting) कहा जाता है। अनुभवी कृषि वैज्ञानिक या उत्पादक खेत में घूमकर पत्तियां देखते हैं, और यह दृश्य निरीक्षण आज भी व्यापक है, लेकिन एक व्यक्ति एक दिन में सीमित कतारें ही देख सकता है और एक ही घाव पर अलग-अलग लोगों का निर्णय अलग हो सकता है। खेत जितना बड़ा होता है, इस तरीके की दरारें उतनी चौड़ी होती जाती हैं और रोग उन्हीं से चुपचाप फैलता है।

जब खरपतवार फसल के पास उगने लगता है, जड़ों के नीचे हर दिन एक अदृश्य संघर्ष चलता है। बारिश का पानी मिट्टी में उतरने और उर्वरक के घुलने के थोड़े से समय में खरपतवार की जड़ें बार-बार फसल की जड़ों से पहले पानी और पोषक तत्व खींच लेती हैं। पत्तियों के आकार में अंतर दिखने में कई सप्ताह लगते हैं, लेकिन तब तक फसल पूरी बढ़त पाए बिना कटाई के समय पहुंच जाती है। रोग हो या खरपतवार, लक्षण साफ दिखने तक अक्सर हस्तक्षेप के लिए बहुत देर हो चुकी होती है।

इन समस्याओं का जवाब देने वाली व्यापक दिशा को सटीक कृषि कहा जाता है। इसमें पूरे खेत पर एक जैसा उपचार लगाने के बजाय हर छोटे हिस्से या हर पौधे को केवल आवश्यक मात्रा में उपचार दिया जाता है। रोग, कीट और खरपतवार का सटीक पता लगाना इस बदलाव का पहला कदम है। जब यह ही पता न हो कि क्या कहां है, तो केवल उसी स्थान पर सटीक उपचार करना संभव नहीं है।

कंप्यूटर विज्ञान और डीप लर्निंग को जोड़ने वाली सटीक निदान तकनीक इसी कमी को भरने के लिए सामने आई है। कैमरे की एक तस्वीर में रोगग्रस्त और स्वस्थ भागों तथा फसल और खरपतवार के बीच अंतर मनुष्य के बजाय एल्गोरिदम करता है। इसके मूल में कन्वोल्यूशनल न्यूरल नेटवर्क है, जिसका अंग्रेज़ी संक्षेप CNN (Convolutional Neural Network) है। यह तस्वीर के छोटे-छोटे पैचों में रंग, बनावट और घाव के किनारे की वक्रता देखता है, फिर परिणामों को परत-दर-परत जोड़कर एक निर्णय बनाता है। ट्रांसफर लर्निंग में ResNet, EfficientNet, DenseNet या MobileNet जैसे किसी बड़े चित्र-संग्रह पर पहले से प्रशिक्षित मॉडल को फसल की तस्वीरों के अनुसार फिर सिखाया जाता है, जिससे खेत में जुटाई जा सकने वाली केवल कुछ हजार तस्वीरों से भी काफी सटीक वर्गीकारक बनाया जा सकता है। इसका सिद्धांत उस व्यक्ति जैसा है जो एक भाषा पहले से जानता हो और नई भाषा जल्दी सीख ले।

तेज़ी से बदलते खेत में सटीकता जितनी महत्वपूर्ण है, गति भी उतनी ही महत्वपूर्ण है। YOLO (You Only Look Once) परिवार के मॉडल पूरी तस्वीर को केवल एक बार देखते हैं, रोग के घाव, कीट या खरपतवार के चारों ओर आयत बनाते हैं और उसी समय उनका नाम भी लगाते हैं। नाम के अनुसार एक बार देखकर काम पूरा करने के कारण वे कैमरे से आने वाले वास्तविक समय के वीडियो के साथ चल सकते हैं। पत्तियों के एक-दूसरे पर चढ़ने, छाया पड़ने और पृष्ठभूमि में मिट्टी तथा पुआल मिले होने के बावजूद YOLOv5 से YOLOv8, YOLOv9e, YOLOv10 और YOLOv11 तक की नई पीढ़ियां हर घाव, हर कीट और हर खरपतवार का स्थान खोज लेती हैं।

CNN और YOLO की एक साझा कमजोरी है। तस्वीर को छोटे पैचों में बांटकर देखने के कारण वे पैचों के बीच संबंध, पूरी पत्ती में फैला चौड़ा नमूना या पूरे पौधे के आकार में बदलाव छोड़ सकते हैं। विज्ञान ट्रांसफॉर्मर, जिसे संक्षेप में ViT (Vision Transformer) कहते हैं, और उसका निकट संबंधी Swin Transformer तस्वीर को 16×16 पिक्सेल के पैचों में बांटकर सभी पैचों के आपसी संबंधों की गणना करते हैं। सेल्फ-अटेंशन (Self-Attention) कहलाने वाली यह गणना मॉडल को व्यापक दृश्य देती है, जिससे वह तय कर सकता है कि तस्वीर के एक कोने और दूसरे कोने के घाव एक ही रोग से आए हैं या नहीं। CBAM या CAB जैसे अटेंशन मॉड्यूल को CNN के साथ लगाने वाली मिश्रित संरचना एक ही प्रणाली को बारीक घाव पढ़ने और पूरी पत्ती देखने, दोनों की क्षमता देती है। यह ऐसा है मानो एक व्यक्ति की उंगलियां पास से बनावट टटोल रही हों और उसकी आंखें दूर से पूरा दृश्य देख रही हों।

संख्याएं दिखाती हैं कि ये मॉडल वास्तव में कितनी अच्छी पहचान करते हैं। अंगूर की पत्ती के रोग पहचानने वाले EfficientNet-B0 और B3 संस्करणों ने सत्यापन डेटा पर 99.5 प्रतिशत सटीकता और 1.00 AUC-ROC दर्ज किया। क्वॉका समूह की गति से प्रेरित अनुकूलन तकनीक DSOCA-QSO जोड़ने वाला मॉडल सब्जियों की पत्ती के रोगों के वर्गीकरण में 99.9 प्रतिशत सटीकता और 99.35 प्रतिशत F1 स्कोर तक पहुंचा, जबकि संदर्भ के अनुसार विशेषताएं चुनने वाला TL-DCFP-CNN कपास, मक्का, धान, गेहूं और गन्ना, इन पांच फसलों को एक साथ संभालकर भी 98.09 प्रतिशत सटीक रहा। वास्तविक समय के पता लगाने में YOLOv11 ने टमाटर की पत्ती के रोगों पर लगभग 94 प्रतिशत सटीकता दी, जबकि छोटे YOLO-NAS ने उष्णकटिबंधीय खेतों में खरपतवार पहचान की 96 प्रतिशत सटीकता बनाए रखते हुए एक तस्वीर 25 मिलीसेकंड में संसाधित की। यह मनुष्य के एक बार पलक झपकाने के समय के दसवें हिस्से से भी कम है। जिन उष्णकटिबंधीय खेतों में YOLO-NAS की जांच हुई, उनकी रोशनी और आर्द्रता

समशीतोष्ण क्षेत्रों से अलग है। वहां सूरज ऊंचा होता है, छाया छोटी और गहरी होती है और हवा में नमी अधिक रहती है। इन परिस्थितियों में सटीकता बनाए रखने का परिणाम संकेत देता है कि एक जलवायु क्षेत्र में बनाया मॉडल बिल्कुल अलग क्षेत्र में भी काम कर सकता है।

मानवरहित वायुयान और जमीनी रोबोट खेत में लगातार चलते हुए तस्वीरें लेते हैं। निर्णय आधी धड़कन भी देर से आए तो रोबोट उस घाव से आगे निकल चुका होता है। इसलिए खेत का वास्तविक प्रदर्शन केवल रोग पहचानने की सटीकता से नहीं, निर्णय लेने की गति से भी तय होता है। एक तस्वीर के प्रसंस्करण में मिलीसेकंड का अंतर अंततः यह तय करता है कि एक रोबोट दिन भर में कितना खेत देख पाएगा।

जब फसल और खरपतवार की पत्तियां एक-दूसरे को छूती हैं, आयताकार बॉक्स पर्याप्त नहीं होते। तब सेगमेंटेशन मॉडल हर पिक्सेल को फसल या खरपतवार के रूप में रंगते हैं। PSPEdgeWeedNet ने अलग किनारा-पहचान शाखा और कंडीशनल रैंडम फील्ड का साथ उपयोग करके मूंगफली के खेतों में फसल और खरपतवार की सीमा स्पष्ट की, जबकि संदर्भ पढ़ने वाली दोहरी शाखा संरचना CAMDWS ने ऑस्ट्रेलियाई गेहूं के खेतों के प्रमुख खरपतवार कठोर राईग्रास (*Lolium rigidum*) और जंगली मूली (*Raphanus raphanistrum*) को क्रमशः 91 प्रतिशत और 90 प्रतिशत से अधिक IoU पर पहचाना, जहां IoU वास्तविक और अनुमानित क्षेत्रों के ओवरलैप का अनुपात है। ViT ने PlantVillage डेटा पर 99.8 प्रतिशत सटीकता दी, और ViT को कन्वोल्यूशनल अटेंशन ब्लॉक से जोड़ने वाले HybridViT-CAB ने केवल 412,000 पैरामीटर तथा 1.57 मेगाबाइट आकार में एक चरण को 141 मिलीसेकंड में संसाधित करते हुए 0.97 AUC और 91 प्रतिशत सटीकता प्राप्त की। Swin Transformer को backbone बनाकर ConvNeXt-V2, SE-BiLSTM और डीप Q-लर्निंग अनुशंसा परत जोड़ने वाली मानवरहित वायुयान प्रणाली ने SAR-CLD-2024 कपास डेटा पर 99.30 प्रतिशत सटीकता दर्ज की। अनुसंधान का केंद्र ऐसे हल्के मॉडल की ओर बढ़ता दिखता है जो सटीकता न गंवाएं।

सर्वश्रेष्ठ एल्गोरिदम भी कैमरे में आने वाली चीजों से बंधा रहता है। RGB सेंसर मनुष्य की आंख के समान तरंगदैर्घ्य दर्ज करते हैं और सस्ते, हल्के तथा फोन और ड्रोन में पहले से लगे होने के कारण लक्षण वर्गीकरण और खरपतवार पहचान के मानक उपकरण बन गए हैं। लेकिन पत्ती के भीतर शुरुआती संक्रमण को लक्षण बाहर आने से पहले पकड़ने या फसल जैसे रंग वाले हरे खरपतवार को अलग करने में दृश्य प्रकाश की सीमा मनुष्य की दृष्टि जैसी ही है। इस कमी को मल्टीस्पेक्ट्रल और हाइपरस्पेक्ट्रल इमेजिंग भरती है। 475 नैनोमीटर नीला, 560 नैनोमीटर हरा, 668 नैनोमीटर लाल, 717 नैनोमीटर रेड एज और 840 नैनोमीटर निकट-अवरक्त जैसे चुने हुए बैंडों की परावर्तनशीलता अलग-अलग मापने वाले सेंसर इन मानों को सामान्यीकृत अंतर वनस्पति सूचकांक (NDVI), हरित सामान्यीकृत अंतर वनस्पति सूचकांक (GNDVI), रेड-एज NDVI और मृदा-समायोजित वनस्पति सूचकांक (SAVI) जैसे संकेतकों में बदलते हैं और दिखाई देने वाले लक्षण आने से पहले क्लोरोफिल टूटने या पानी घटने का शुरुआती तनाव पकड़ लेते हैं।

RGB-D सेंसर रंगीन तस्वीर के हर पिक्सेल में दूरी का मान जोड़कर त्रि-आयामी स्थान की सूचना देता है। यही गहराई सूचना वे निर्देशांक बनाती है जिनसे कटाई रोबोट की उंगलियां या निराई रोबोट का लेज़र ठीक निशाना साधते हैं। इन सेंसरों वाले मानवरहित वायुयान जमीन से 2 से 50 मीटर की कम ऊंचाई पर उड़ते हैं और ऐसी स्पष्टता से पूरा खेत देखते हैं जिसमें एक पिक्सेल 0.3 से 5 सेंटीमीटर दर्शाता है, जबकि

जमीनी रोबोट और हाथ में पकड़े मोबाइल उपकरण बची जगह भरते हैं। वायु तापमान, आर्द्रता, मिट्टी की नमी और वर्षा मापने वाले Internet of Things सेंसर तथा मौसम के अभिलेख जोड़ने पर समय और स्थान के अनेक स्तरों का डेटा एक ही पाइपलाइन में बहता है। यह डेटा निदान पर नहीं रुकता, बल्कि पूर्वानुमान तक जाता है। पिछले कुछ दिनों के तापमान और आर्द्रता के रुझान को पुराने रोग अभिलेखों पर रखने से घाव दिखने से पहले बढ़ते संक्रमण जोखिम की सूचना मिल सकती है। तकनीक दिखाई देने वाले रोग खोजने से एक कदम आगे बढ़कर अभी न दिखने वाले रोग पहचानती है।

एकत्र की गई तस्वीरें तुरंत उपयोग योग्य नहीं होतीं। उन्हें 224×224, 512×512 या 736×736 जैसे तय आकार में काटा जाता है और पिक्सेल मानों को एक निश्चित सीमा में सामान्यीकृत किया जाता है। धूप की दिशा बदलने और अलग रोगों की तस्वीरों की संख्या असमान होने की भरपाई के लिए तस्वीरें घुमाई, पलटी, झुकाई और धुंधली की जाती हैं, साथ ही GAN, cGAN और DoubleGAN जैसे जनरेटिव मॉडल रोगी पत्तियों और खरपतवार की कृत्रिम तस्वीरें बनाकर प्रशिक्षण डेटा बढ़ाते हैं। कंडीशनल जेनरेटिव एडवर्सरियल नेटवर्क, यानी cGAN, रोग के प्रकार को पहले से दी गई शर्त के रूप में लेकर उसी रोग का नया कृत्रिम घाव बनाता है। एक पक्ष असली जैसी तस्वीर बनाता है और दूसरा उसे नकली पहचानने की कोशिश करता है, जिससे मुकाबले में दोनों बेहतर होते हैं। क्रॉस-एंट्रॉपी लॉस, वर्ग-भारित लॉस और सीमा लॉस जैसे फलन मॉडल की गलती मापते हैं, जबकि Adam और AdamW जैसी अनुकूलन विधियां त्रुटि को धीरे-धीरे घटाती हैं।

प्रशिक्षित मॉडल को अंततः खेत की छोटी मशीन में चलना होता है। NVIDIA Jetson Xavier NX, Jetson Nano और Raspberry Pi जैसे हथेली के आकार के कंप्यूटर तथा Xilinx Zynq-7000 जैसे FPGA त्वरक यह काम करते हैं। क्वांटाइजेशन सूक्ष्म दशमलव मानों को पूर्णांकों में गोल करके हर गणना में बिटों की संख्या घटाता है और समय तथा मेमोरी दोनों बचाता है। सटीकता थोड़ी घटती है, लेकिन गणना कहीं तेज़ हो जाती है। प्रूनिंग पेड़ की अनावश्यक शाखाओं की तरह परिणाम पर कम असर डालने वाले कनेक्शन हटाती है, और मॉडल को TensorFlow Lite या TensorRT में बदलने से संचालन समय बहुत घट सकता है। रिपोर्टों के अनुसार FPGA-त्वरित मॉडल ने केवल RGB वाले मॉडल से 43.2 गुना तेज़ inference, 10 मिलीसेकंड से कम latency और ऊर्जा खपत में 88 प्रतिशत कमी दी। नई प्रणालियां एक तस्वीर 42.6 मिलीसेकंड में संसाधित करती हैं, जिससे फोन स्तर के उपकरणों पर वास्तविक समय निदान संभव है, और 1.9 मिलियन पैरामीटर वाला PMVT तथा pruned transformer अब TensorFlow Lite, ONNX Runtime और हल्के gRPC संचार के साथ कृषि ड्रोन और छोटे उपकरणों पर सीधे चलते हैं।

ऐसे मॉडल की उपयोगिता कई मापदंडों से आंकी जाती है। Accuracy सभी निर्णयों में सही निर्णयों का अनुपात है, precision रोग बताए गए मामलों में वास्तव में रोगी मामलों का अनुपात है और recall वास्तव में रोगी पत्तियों में बिना छूटे पकड़ी गई पत्तियों का अनुपात है। कुछ रोगों की हजारों तस्वीरें होती हैं, जबकि दुर्लभ रोगों की केवल कुछ दर्जन। जब रोगों के बीच तस्वीरों की संख्या इतनी अलग हो, F1 स्कोर precision और recall को जोड़कर दिखाता है कि मॉडल सामान्य रोगों की ओर झुका है या नहीं। AUC-ROC कई thresholds पर प्रदर्शन दिखाता है, जबकि confusion matrix असली रोग नाम और मॉडल के अनुमान को तालिका में रखकर साफ करता है कि कौन सा रोग किससे गलत पहचाना गया।

रोगी पत्ती को स्वस्थ बताने से रोग को पूरे खेत में फैलने का समय मिल जाता है, इसलिए रोग और कीट निदान में precision से अधिक recall को महत्व देना चाहिए। किसी मामले को छोड़ने की तुलना में थोड़ा अधिक संदेह सुरक्षित है।

लक्ष्य की जगह भी खोजने वाले detection और segmentation के लिए अलग मापदंड होते हैं। IoU बताता है कि मॉडल का बनाया क्षेत्र वास्तविक घाव से कितना मिलता है, और mAP कई thresholds पर मापी precision का औसत है। यह दो मुहरों को एक ही जगह लगाकर उनके निशान का मेल देखने जैसा है। प्रति सेकंड संसाधित frames और inference time तय करते हैं कि मॉडल वास्तविक खेत की गति पर काम कर सकता है या नहीं। लेकिन खेत में उपयोग न हो तो सभी अच्छे संकेतक निरर्थक हैं। इसलिए खरपतवार हटाने की दर, फसल क्षति की दर, प्रति hectare herbicide उपयोग और छिड़काव दक्षता जैसे कृषि मापदंड भी साथ देखे जाते हैं। कंप्यूटर का सही अनुमान और किसान की लागत तथा उपज में वास्तविक सुधार दो अलग प्रश्न हैं, और दूसरे का उत्तर न देने वाला मॉडल ऊंची सटीकता के बावजूद खेत में जड़ नहीं जमा पाएगा।

संख्याओं के पीछे असली खेतों में लगे कैमरे और ऐप हैं। टमाटर, अंगूर, कपास, मिर्च और स्ट्रॉबेरी जैसी मूल्यवान बागवानी फसलों पर मोबाइल ऐप और ड्रोन को जोड़ने वाली निदान प्रणालियां फैल रही हैं। YOLOv8, YOLOv11, EfficientNet या MobileNet चलाने वाले मॉडल खेत में ही रोग पहचानते हैं: टमाटर का early blight और leaf mold, शिराओं को विकृत करने वाला mosaic virus, किनारों को पीला कर ऊपर मोड़ने वाला yellow leaf curl virus, अंगूर का downy mildew, black rot और शिराओं के बीच पीली धारियां सुखाने वाला esca, कपास के aphid और two-spotted spider mite तथा पत्ती में सुरंग बनाने वाला leafminer। उत्पादक रोगी पौधे के सामने एक तस्वीर लेता है और कुछ सेकंड बाद स्क्रीन पर रोग का नाम तथा नियंत्रण विधि देखकर अगला कदम चुनता है।

टमाटर, आलू और मक्का वाले परीक्षण खेतों ने दिखाया है कि निदान के बाद क्या होता है। शुरुआती fungicide केवल उन क्षेत्रों में डाला गया जिन्हें डीप लर्निंग मॉडल ने रोगी बताया, और उन्हीं क्षेत्रों की सिंचाई अलग से समायोजित की गई। निदान स्क्रीन की संख्या पर समाप्त नहीं हुआ, बल्कि दवा और पानी की वास्तविक मात्रा बदलने वाले निर्णय में बदल गया। फिर भी बहुत से परीक्षण एक खेत और एक मौसम तक सीमित हैं, इसलिए कई भूखंडों, मौसमों और रोशनी के स्तरों वाले बड़े डेटा की जरूरत बताई जाती है।

ये निदान उपकरण उन क्षेत्रों में प्रभावी हैं जहां विशेषज्ञ तक जल्दी पहुंचना कठिन है। एक कृषि वैज्ञानिक को कितने खेत देखने हैं, यह क्षेत्र के अनुसार बदलता है, लेकिन हर जगह संख्या इतनी बड़ी है कि पैदल सभी जगह जाना कठिन है। एक फोन से विशेषज्ञ के करीब निदान तुरंत मिलने की क्षमता इस तकनीक के फैलने का एक कारण दिखती है। इसकी भूमिका मनुष्य को हटाने से अधिक उन समयों और स्थानों को भरने की है जहां उसकी आंख नहीं पहुंचती।

कैमरे से फसल और खरपतवार अलग करके केवल जरूरी स्थान पर उपचार करने की पद्धति को स्थल-विशिष्ट खरपतवार प्रबंधन, या SSWM (Site-Specific Weed Management), कहा जाता है। इसका केंद्र पूरे खेत पर बराबर मात्रा छिड़कने से हटकर केवल खरपतवार वाले स्थान चुनना और वहीं

आवश्यक उपचार करना है। लेकिन उस सीमा को सही खींचना आसान नहीं है। फसल और खरपतवार जितने छोटे और जितने पास होते हैं, सीमा उतनी धुंधली होती है।

फसल और खरपतवार को अलग करना रोग खोजने से कठिन है। दोनों हरे हैं, दोनों बढ़ते हैं और छोटी अवस्था में उनकी पत्तियों का आकार भी समान हो सकता है। ऑस्ट्रेलिया के 120 hectare गेहूं खेत के प्रयोग ने समय के सहारे समस्या हल की। कम ऊंचाई के मानवरहित वायुयान ने उसी खेत की अठारह अलग समयों पर तस्वीरें लीं और AMSTF नामक स्थानिक-कालिक-स्पेक्ट्रल fusion algorithm ने उन्हें परतों की तरह पढ़ा। दैनिक वृद्धि-दर सूचकांक खरपतवार में 0.025 और गेहूं में 0.015 था, यह अंतर time-series spectral indices में साफ दिखा, और CAMDWS segmentation जोड़ने पर फसल-खरपतवार सीमा की 9.8 से 12.3 प्रतिशत misclassification दर घटकर 5.4 प्रतिशत हो गई। वृद्धि गति का यह सूक्ष्म अंतर सीमा फिर खींचने की कुंजी बना।

See & Spray नामक लक्षित नियंत्रण उपकरण हर नोज़ल के ऊपर कैमरा और नीचे अत्यंत तेज़ इलेक्ट्रॉनिक वाल्व लगाता है। इसे John Deere की सहायक कंपनी Blue River Technology ने बनाया। यह green-on-green समस्या, यानी हरी फसल के बीच छिपे हरे खरपतवार, को वास्तविक समय में पहचानता है। मनुष्य की आंख भी हरी पत्तियों के बीच हरे खरपतवार को तुरंत नहीं पकड़ पाती। खरपतवार की घनता और प्रकार के अनुसार प्रणाली बूंद का आकार 150 से 250 माइक्रोमीटर और छिड़काव दर 0.12 से 0.35 लीटर प्रति मिनट के बीच बदलती है। पूरे खेत पर खरपतवारनाशी समान रूप से फैलाने वाले पारंपरिक व्यापक छिड़काव की तुलना में यह उपयोग 31 से 32 प्रतिशत घटाकर लगभग 0.68 लीटर प्रति हेक्टेयर कर देती है। फसल रसायन से बचती है और मिट्टी में जाने वाली कुल मात्रा भी घटती है।

इस रासायनिक विधि से अलग, बिल्कुल रसायन न इस्तेमाल करने वाला रास्ता भी व्यावसायिक तैनाती तक पहुंच चुका है। DIN-LW-YOLO पहचान एल्गोरिदम और RGB-D कैमरा वाला स्वायत्त रोबोट फसल के बीच उगे छोटे खरपतवार के बड़वार बिंदु को त्रि-आयामी निर्देशांकों में खोजता है। बड़वार बिंदु सबसे ऊपरी भाग है जहां से पौधा नया विकास करता है। रोबोट उस बिंदु पर क्षण भर उच्च-शक्ति लेज़र चलाकर उसे गर्मी से नष्ट करता है। वह खरपतवारनाशी की बूंदों के बजाय प्रकाश से खरपतवार मारता है। अमेरिका की Carbon Robotics का LaserWeeder इस विधि को व्यावसायिक स्तर तक ले जाने का प्रमुख उदाहरण है। यह प्रति घंटे 100,000 से अधिक खरपतवार हटाता है और 2022 में पेश होने के बाद कुल 10 अरब से अधिक खरपतवार नष्ट कर चुका है। 2026 की पहली तिमाही में वार्षिकीकृत राजस्व 100 मिलियन डॉलर से अधिक हुआ और बाद में 177 मिलियन डॉलर तक बताया गया, जो कृषि रोबोटिक्स कंपनी के लिए अभूतपूर्व स्तर है। रोबोट 15 देशों में लगाए जा चुके हैं और उत्तरी अमेरिका, यूरोप तथा ऑस्ट्रेलिया के 100 से अधिक उत्पादक उनका उपयोग करते हैं।

फरवरी 2026 में कंपनी ने 150 मिलियन लेबल लगी पादप तस्वीरों पर प्रशिक्षित विशाल पादप मॉडल जारी किया। कंपनी के अनुसार नए खेत या अनजान फसल मिलने पर पहले कई सप्ताह लेने वाला अनुकूलित प्रशिक्षण अब कुछ मिनटों में पूरा होता है। दूसरे रोबोट को पहले रोबोट के अनुभव वाले खरपतवार, मिट्टी और रोशनी के हर संयोजन को शुरू से नहीं सीखना पड़ता। एक रोबोट का अनुभव अगले रोबोट और अगले खेत

तक सीधे ले जाया जा सकता है, जिससे लेज़र निराई एक खेत के उपकरण से कई खेतों के साझा मॉडल की ओर बढ़ती दिखती है।

भोर के उसी ग्रीनहाउस में लौटें तो उत्पादक के हाथ में अब टॉर्च की तुलना में फोन होने की संभावना अधिक है। जो हाथ पहले पत्ती पलटकर आंख से घाव परखता था, वही अब एक तस्वीर लेकर स्क्रीन पर रोग का नाम देखता है। दक्षिण कोरिया में Rural Development Administration ने इसी उद्देश्य का अपना ऐप बनाया और चला रहा है। उत्पादक रोगी पत्ती या फल की तस्वीर लेकर अपलोड करे तो कृत्रिम बुद्धिमत्ता तुरंत रोग पहचानकर उपयुक्त नियंत्रण रसायन सुझाती है। अभी यह 31 मुख्य फसलों और 182 रोगों तथा कीटों को शामिल करता है, और 2030 तक दक्षिण कोरिया की 139 मुख्य फसलों तक बढ़ाने की योजना है। कोरिया के दूसरी पीढ़ी के स्मार्ट फार्मों में क्लाउड-आधारित कृत्रिम बुद्धिमत्ता वास्तविक समय में वृद्धि दर्शाएं और फसल जैवमापी डेटा पढ़कर late blight तथा powdery mildew सहित पांच रोग और leafminer सहित दो कीट पकड़ती है। यह एजेंसी 17 सूचना प्रणालियों से जुड़ा कृषि-विशेष AI सहायक “AI Isagi” भी चलाती है और बोलकर पूछे प्रश्नों का उत्तर देने तथा खेत प्रबंधन का निदान करने वाला नया संस्करण तैयार कर रही है।

रोग खोजने वाला कैमरा, खरपतवार चुनने वाला कैमरा और उसके अनुसार रसायन छिड़कने या लेज़र चलाने वाला उपकरण अंततः एक सतत प्रवाह बनाते हैं। यह पूरे खेत पर एक जैसा उपचार करने से हटकर हर पत्ती और फल अलग पहचानने तथा हर एक के लिए अलग प्रतिक्रिया तय करने का बदलाव है। खेतों में जांचे जा रहे कैमरे और रोबोट इसी सीमा पर खड़े हैं। यह दिशा कितनी फैलेगी, इसका निर्णय सटीकता, लागत और उत्पादक का भरोसा करेंगे।

इन परिणामों के बावजूद खेत प्रयोगशाला नहीं है। PlantVillage जैसे डीप लर्निंग प्रशिक्षण डेटा-संग्रहों में साफ पृष्ठभूमि और समान रोशनी वाली तस्वीरें होती हैं। असली खेत में सूरज का कोण मौसम और समय के साथ बदलता है, छाया गहरी होती है, पत्तियां हवा में हिलती और एक-दूसरे पर चढ़ती हैं, लेंस पर धूल जमती है तथा मिट्टी और सूखे तने पृष्ठभूमि को उलझाते हैं। प्रयोगशाला की तस्वीरों पर प्रशिक्षित मॉडल को सीधे ऐसे खेत में ले जाने पर domain shift के कारण सटीकता साफ गिरती है। चित्र लेने का वातावरण बदलते ही मॉडल उसी रोग को किसी और चीज़ के रूप में पहचान सकता है। प्रकाश का रंग-तापमान, लेंस का देखने का कोण या पत्ती पर छाया की दिशा निर्णय को अस्थिर कर सकती है। कितनी भी तस्वीरें इकट्ठी हों, यदि उन्हें लेने का वातावरण असली खेत से अलग है तो मॉडल का सीखा ज्ञान बिना बदलाव वहां उपयोग नहीं हो सकता।

लेबल लगाना भी एक बाधा है। Bounding box खींचने और हर पिक्सेल को नाम देने के लिए कृषि विज्ञान विशेषज्ञ चाहिए और हर तस्वीर पर कई मिनट लग सकते हैं। शोधकर्ता semi-supervised learning पर काम कर रहे हैं, जो थोड़े लेबल से सीखती है; self-supervised learning पर, जो सीखते समय अपने उत्तर बनाती है; और few-shot learning पर, जो केवल कुछ तस्वीरें देखकर नया रोग पहचानती है। Large vision-language model और बड़ी संख्या में लेबल लगी कृत्रिम तस्वीरें बनाने वाली generative AI इस बाधा से निकलने का दूसरा रास्ता बनी हैं।

सेंसर बढ़ने पर गणना भी बढ़ती है। दृश्य-प्रकाश तस्वीरों को लघु-तरंग अवरोक्त, हाइपरस्पेक्ट्रल डेटा और मिट्टी तथा मौसम के Internet of Things मापों के साथ वास्तविक समय में जोड़ने की शुरुआत अलग गति से आने वाली डेटा धाराओं को मिलाने की कठिनाई से होती है। ड्रोन की तस्वीरों और जमीनी सेंसर के मापों का अंतराल तथा अद्यतन दर अलग होती है, इसलिए एक ही समय और स्थान का मेल करने की अलग प्रक्रिया चाहिए। फिर बैटरी से चलने वाले छोटे उपकरण को पहचान, अनुमान, मार्ग योजना और छिड़काव दर नियंत्रण एक साथ बिना विलंब चलाने होते हैं, और समाधान के लिए मॉडल को छोटा करने तथा FPGA या NPU जैसा समर्पित हार्डवेयर जोड़ने, दोनों की जरूरत है।

अंतिम चुनौती भरोसा है। डीप लर्निंग मॉडल black box के करीब होता है और अपने निर्णय का कारण नहीं बताता। उत्पादक और कृषि वैज्ञानिक उस निर्णय पर भरोसा करके नियंत्रण रसायन लगाने से पहले देखना चाहते हैं कि पत्ती के किस हिस्से ने मॉडल को रोग का निर्णय दिया। Grad-CAM, SHAP या causal attention mechanism को मॉडल में जोड़कर हर घाव क्षेत्र का योगदान दिखाने वाला शोध इस भरोसे की अगली सीढ़ी लगता है। तकनीक कितनी भी सटीक हो, उत्पादक को उसके निर्णय पर संदेह हो तो खेत में उसे स्वीकार करना कठिन होगा।

स्रोत और संदर्भ

शैक्षणिक शोधपत्र

1. Adewumi, A., & Saraswat, D. (2026). सटीक खरपतवार नियंत्रण के लिए कृत्रिम बुद्धिमत्ता और एज कंप्यूटिंग की व्यापक समीक्षा। *Artificial Intelligence and Applications*. DOI: 10.47852/bonviewAIA62028867.
2. Kakde, S., Poyam, P., et al. (2025). स्वायत्त सटीक खरपतवार प्रबंधन के लिए एकीकृत स्थानिक-कालिक डीप लर्निंग ढांचे की रचना। *International Journal of Applied Mathematics*, 38(2s), 1340-1363.
3. Latif, A., Jati, H., Surjono, H. D., & Yusuf, M. (2026). टिकाऊ कृषि और पर्यावरणीय लचीलेपन के लिए ड्रोन-सहायित डीप लर्निंग खरपतवार पहचान। *IAES International Journal of Artificial Intelligence (IJ-AI)*, 15(2), 1428-1440. DOI: 10.11591/ijai.v15.i2.pp1428-1440.
4. Mathew, M. P. (2025). EfficientNetB0, InceptionV3 और Xception से अंगूर की पत्ती के रोग वर्गीकरण का तुलनात्मक डीप लर्निंग ढांचा। *Discover Applied Sciences*, 7, 1222. DOI: 10.1007/s42452-025-07457-5.
5. Moldvai, L., & Nyéki, A. (2025). टमाटर (*Solanum lycopersicum*) की पहचान और खेती के लिए नवीन कंप्यूटर वज़िन वधियां। *Discover Applied Sciences*, 7, 975.
6. Pai, D. G., Balachandra, M., & Kamath, R. (2025). PSPEdgeWeedNet से मूंगफली की खेती में फसल-खरपतवार सेगमेंटेशन का डीप लर्निंग दृष्टिकोण। *Scientific Reports*, 15, 43032. DOI: 10.1038/s41598-025-24174-6.
7. Yenna, G. R., Kumari, N. V., Chouhan, A. S., Umar, S., & Macha, S. R. (2026). HybridViT-CAB: कृषि प्रणालियों में सटीक खरपतवार पहचान के लिए वज़िन ट्रांसफॉर्मर और कन्वोल्यूशनल अटेंशन नेटवर्क। *Scientific Reports*, 16, 18473. DOI: 10.1038/s41598-026-48652-7.
8. सटीक फसल रोग निगरानी के लिए causal attention multi-modal deep learning network की FPGA-accelerated IoT deployment। (2026). *Environment Conservation Journal*.
9. AgroDualNet: फसल रोग पूर्वानुमान और फल पकने की पहचान के लिए dual deep learning framework। (2026). *Scientific Reports*.
10. बड़े पैमाने पर सटीक कृषि vision transformers से रोग की शुरुआती पहचान। (2026). *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 14(4).

11. Transfer learning-based deep convolutional neural network से फसल रोग पहचान का नया दृष्टिकोण। (2026). Neural Computing & Applications, 38, 500. DOI: 10.1007/s00521-026-12216-7.
12. Convolutional neural networks (CNNs) से खेतों में कीट पहचान: एक deep learning approach। (2026). Volume 14, Issue 3.
13. PMC13066816. (2025). National Library of Medicine, PubMed Central.
<https://pmc.ncbi.nlm.nih.gov/articles/PMC13066816/>
14. Article PII S2095809925006769. (2025). Elsevier ScienceDirect.
<https://www.sciencedirect.com/science/article/pii/S2095809925006769>

व्याख्यान और वीडियो सामग्री

1. C-DAC. (2025). कृषि में AI: भारत के कृषि परिवर्तन का रूपांतरण। YouTube.
https://www.youtube.com/watch?v=IV3_VnWiBpM
2. RMCG. (2025). AI की परतें खोलना: सब्जी उत्पादकों के लिए व्यावहारिक उपकरण। YouTube.
<https://www.youtube.com/watch?v=G2ytLXLW7hw>
3. Grounded AI. (2025). AI खेती को कैसे बदल रही है: अधिक समझदार गायें, फसलें और कीट नियंत्रण। YouTube.
<https://www.youtube.com/watch?v=bxIF2MpXsB0>
4. SyncTelle Automation Hub. (2026). शुरुआत से अंत तक AI/ML परियोजना शृंखला | दिन 1: परियोजना आरंभ और फसल रोग पहचान परिचय। YouTube. <https://www.youtube.com/watch?v=SNqOcVib3BY>
5. Royal Society of Biology. (2026). पादप स्वास्थ्य शृंखला | डिजिटल अंगूर खेती: बेल स्वास्थ्य का भविष्य। YouTube.
<https://www.youtube.com/watch?v=5iXPOMxl6bU>

लेख और रिपोर्ट

1. Carbon Robotics. (2026). LaserWeeder के परिणाम। Carbon Robotics. <https://carbonrobotics.com/results>
2. Hypersinc. (2026). AI LaserWeeding platform से Carbon Robotics का राजस्व 100M पार। Hypersinc.
<https://hypersinc.com/article/carbon-robotics-crosses-100m-revenue-on-ai-laserweeding-platform-1775055784166>
3. Design News. (2026). LaserWeeders ने पछिल्ले दो वर्षों में अरबों खरपतवार नष्ट किए। Design News.
<https://www.designnews.com/automation/laserweeders-killed-billions-of-weeds-in-the-last-two-years>
4. Rural Development Administration. (2026). फसल रोगों और कीटों के लिए AI-आधारित चित्र नदिन और उपचार सेवा। Rural Development Administration.
https://www.rda.go.kr/board/board.do?mode=view&prgId=day_farmprmninfoEntry&dataNo=100000806197
5. Smart Farm Korea. (2026). कृत्रिम बुद्धिमत्ता-आधारित फसल वृद्धि प्रबंधन परामर्श सेवा। Smart Farm Korea.
<https://www.smartfarmkorea.net/analyService/internal/aiAdvice.do?menuId=M11030102>

1.2

फलों की परिपक्वता का आकलन तथा वृद्धि और उपज का पूर्वानुमान

एक बड़े व्यावसायिक ग्रीनहाउस में पाइप रेल पर चलने वाली ट्रॉली पर कैमरा लगाकर परिपक्वता के हर चरण में शिमला मिर्चों की संख्या गिनने और उस संख्या का कुल उपज से संबंध जाँचने का परीक्षण किया गया। ग्रीनहाउस की छत के पास लगी रेल पर ट्रॉली 0.3 से 0.5 मीटर प्रति सेकंड की रफ्तार से चलती है, और उसके नीचे लटका कैमरा कतार में लगे पौधों की पत्तियों के बीच दिखाई देने वाली शिमला मिर्चों की सतह का रंग पढ़कर उनके लाल पकने की मात्रा को संख्या में बदल देता है। ट्रॉली पर लगा यह गणना उपकरण पूरी परीक्षण अवधि में बिना उतार-चढ़ाव के पहचान क्षमता बनाए रखता है।

फल कब पका है, यह जानना जितना सहज लगता है, उससे कहीं अधिक आर्थिक महत्व रखता है। बहुत जल्दी तोड़ने पर फल में मिठास बढ़ने से पहले ही वह बिक जाता है, और बहुत देर करने पर वह नरम पड़ जाता है या खराब होकर वितरण के दौरान फेंकना पड़ता है। लंबे समय तक यह निर्णय मजदूरों की आँखों और हाथों पर निर्भर रहा। वे खेत या ग्रीनहाउस में घूमकर रंग देखते और फल छूते थे, पर हर व्यक्ति का मानदंड थोड़ा अलग होने के कारण एक ही फल के बारे में अलग-अलग निर्णय होना आम था। मिठास, अम्लता या कठोरता ठीक-ठीक जानने के लिए फल काटकर उसका रस निकालना और उपकरण से रासायनिक विश्लेषण करना पड़ता था, जिससे वह फल उपयोग के लायक नहीं रहता। कुछ नमूने काटने से पूरे खेत की स्थिति नहीं जानी जा सकती, इसलिए किसान काफी श्रम और समय खर्च करके भी अक्सर केवल अनुमान जैसा उत्तर पाते थे। गलत फैसला केवल एक बार की हानि तक सीमित नहीं रहता। पहली तुड़ाई में छूट गया अधपका फल अगली तुड़ाई तक अक्सर बाजार योग्य नहीं रहता और फेंकना पड़ता है।

एक कैमरे को वास्तव में केवल एक प्रश्न का उत्तर नहीं देना होता। यह पूछना कि कोई फल आज पूरी तरह पका है या नहीं, यह पूछना कि पूरा पौधा अभी फूलने के चरण में है या फल मोटा होने के चरण में, और यह पूछना कि इस खेत से आगे कितने किलोग्राम उपज मिलेगी, तीन अलग प्रश्न हैं। परिपक्वता का निर्णय एक फल देखकर किया जाता है, वृद्धि चरण का निर्णय पूरे पौधे या खेत की प्रवृत्ति देखकर, और उपज का अनुमान इन दोनों को गिनकर भविष्य की संख्या में बदलता है। फिर भी तीनों की शुरुआत एक ही लेंस से ली गई तस्वीर से होती है, इसलिए हाल की शोध दिशा हर प्रश्न का अलग उत्तर देने के बजाय एक कैमरे और एक ही पाइपलाइन से तीनों को एक साथ सँभालने की ओर बढ़ रही है।

कैमरा केवल रंग देखकर भी पकने का अनुमान लगा सकता है, और इसका जैविक कारण है। फल पकने पर उसके छिलके में क्लोरोफिल टूटने लगता है, हरा रंग फीका पड़ता है और कैरोटिनाइड या एंथोसाइनिन जैसे वर्णक उसकी जगह लेकर फल को पीला, नारंगी या लाल बनाते हैं। इसी समय भीतर होने वाले, आँखों से न दिखने वाले बदलाव भी जारी रहते हैं। पानी में घुली शर्करा अर्थात् कुल घुलनशील ठोस पदार्थ

(TSS) बढ़ते हैं, खट्टापन बताने वाली टाइटेरेबल अम्लता (TA) घटती है, और स्टार्च तथा नमी का अनुपात भी बदलता है। दृश्य प्रकाश क्षेत्र, अर्थात् मानव आँख को दिखाई देने वाला 400 से 700 नैनोमीटर का तरंगदैर्घ्य क्षेत्र दर्ज करने वाला RGB कैमरा, रंगत, बनावट और आकार जैसे बाहरी बदलाव पढ़ने का मूल उपकरण है।

RGB-D कैमरा रंग से न मिल पाने वाली दूरी की जानकारी जोड़ता है। सामान्य कैमरा केवल सपाट रंग संबंधी सूचना दर्ज करता है, जबकि RGB-D कैमरा हर पिक्सेल के साथ दूरी का एक मान भी जोड़ता है। यह वैसा ही है जैसे किसी नक्शे पर अक्षांश और देशांतर के साथ ऊँचाई भी दिखने लगे। इस गहराई के मान से कैमरा फल की आगे-पीछे और दाएँ-बाएँ स्थिति, त्रिज्या और आयतन निकालता है, और पत्तियों या शाखाओं से आधे ढके फल को भी पहचान लेता है। ढके हुए फलों की उपेक्षा करने पर वास्तविक संख्या से कम फल गिने जाते हैं, जिससे आगे का पूरा उपज पूर्वानुमान नीचे की ओर झुक जाता है। ग्रीनहाउस में गश्त करने वाले रोबोटों में प्रचलित Intel RealSense D435i जैसे उपकरण यही भूमिका निभाते हैं।

डेटा इकट्ठा करने में भी काफी श्रम लगता है। कैमरे की तस्वीरों में शोर मिला रहता है, इसलिए Gaussian filtering और Wiener filtering से शोर हटाया जाता है और CLAHE तकनीक से छायादार तथा चमकीले हिस्सों का कंट्रास्ट समान किया जाता है। इसके बाद पिक्सेल मानों को निश्चित दायरे में लाने के लिए min-max normalization किया जाता है। तस्वीरें कम हों तो मौजूदा तस्वीरों को घुमाकर, पलटकर, उनकी चमक बदलकर या स्क्रीन का एक हिस्सा ढककर संख्या बढ़ाई जाती है, और हाल में CGAN या SMOTE जैसी तकनीकों से वास्तव में न लिए गए काल्पनिक फलों के चित्र और रासायनिक संघटन के मान भी बनाकर प्रशिक्षण में जोड़े जाते हैं। पर इन बढ़ाई गई तस्वीरों को प्रशिक्षण और सत्यापन समूहों में बाँटने से पहले मिलाना नहीं चाहिए। पहले डेटा बाँटना और फिर केवल प्रशिक्षण वाले हिस्से को बदलना जरूरी है, ताकि बाद में कृत्रिम रूप से बढ़ा हुआ मूल्यांकन परिणाम न मिले।

जिन फलों के छिलके का रंग अंत तक नहीं बदलता, उनके सामने दृश्य प्रकाश बेबस हो जाता है। थाई आम की किस्म Nam Dok Mai Si Tong (NDMST) इसका उदाहरण है, क्योंकि पकने की पूरी अवधि में उसका छिलका एकसमान पीला रहता है और केवल तस्वीर देखकर सही तुड़ाई समय तय करना कठिन होता है। ऐसे में निकट-अवरक्त, अर्थात् मानव आँख से न दिखने वाले 700 नैनोमीटर से अधिक तरंगदैर्घ्य को मापने वाले multispectral और hyperspectral कैमरे काम आते हैं। निकट-अवरक्त प्रकाश गूदे में नमी और रासायनिक संघटन के बदलावों पर संवेदनशील प्रतिक्रिया देता है, इसलिए छिलके के भीतर छिपी स्थिति भी बताता है। शोधकर्ताओं ने इसी सिद्धांत पर AFMG-DLFF प्रणाली बनाई, जिसमें RGB चित्र से निकली बाहरी रूप-रंग की 1536-आयामी विशेषताओं को आंतरिक स्थिति बताने वाले 512-आयामी वेक्टर से जोड़ा जाता है; इस दूसरे वेक्टर में मिठास से अम्लता घटाकर निकाला गया BrimA index भी शामिल है, और दोनों मिलकर 2048-आयामी वेक्टर बनाते हैं। K-means clustering से कच्चा, आधा पका और पूरा पका, ये तीन चरण तय किए गए, और जुगनुओं के एक-दूसरे की चमक का पीछा करके जमा होने के व्यवहार से प्रेरित Glowworm Swarm Optimization से learning rate तथा batch size जैसे मान समायोजित किए गए; इसके बाद इस fusion model ने 97.86 प्रतिशत grading accuracy हासिल की। उन्हीं परिस्थितियों में केवल छवि सूचना वाले model

की accuracy 88.16 प्रतिशत और केवल छवियों को जोड़ने वाले model की 88.73 प्रतिशत रही, जिससे स्पष्ट हुआ कि आंतरिक डेटा जोड़ने से accuracy काफी बढ़ी।

प्रकाश के बजाय ताप से परिपक्वता मापने का तरीका भी है। फल पकने के साथ उसकी सतह और आसपास की हवा के तापमान का अंतर धीरे-धीरे कम होता जाता है, और thermal imaging sensor इस सूक्ष्म अंतर को सीधे पढ़ता है। तेल ताड़ के बागानों में इस सिद्धांत के साथ निकट-अवरक्त मापन और रंग विश्लेषण जोड़कर फल-गुच्छों में तेल तथा मुक्त वसीय अम्ल (FFA) की मात्रा बिना काटे आँकी जाती है। पेड़ के नीचे सस्ता ESP32-CAM module टाँग देने पर वह अपने आप गिरे फलों को वास्तविक समय में गिनता है और YOLOv8x recognition model से जुड़े web dashboard के माध्यम से प्रबंधक को सूचना देता है। यह प्रणाली अधिकतम 0.94 का F1 score, अर्थात् precision और recall दोनों को साथ रखने वाला संतुलित score, दर्ज करती है और उचित तुड़ाई समय चूकने से बचाती है।

खेत को कैसी आँख चाहिए, यह लागत और फसल की प्रकृति पर निर्भर करता है। जिन फसलों में केवल रंग देखना पर्याप्त है, उनके लिए एक सस्ता RGB कैमरा काफी है, लेकिन पत्तियों के पीछे छिपने वाले फलों वाली फसल के लिए depth information वाला RGB-D कैमरा चाहिए। आम जैसे फलों में बाहर और भीतर की स्थिति अलग हो तो निकट-अवरक्त या hyperspectral sensor जैसे महँगे उपकरण लगाने पड़ते हैं, और तेल या fatty acid जैसे सूक्ष्म घटक देखने हों तो thermal imaging sensor भी साथ जोड़ा जाता है। एक सस्ते कैमरे से शुरुआत करके जरूरत के अनुसार एक-एक sensor जोड़ना फिलहाल सबसे व्यावहारिक कार्यान्वयन क्रम लगता है।

अब ग्रीनहाउस की छत पर चलती ट्रॉली पर लौटें तो कैमरे का काम एक तस्वीर लेने पर समाप्त नहीं होता। कृत्रिम बुद्धिमत्ता तस्वीर में हर फल के चारों ओर आयताकार box बनाती है, या एक कदम आगे जाकर पिक्सेल स्तर पर फल की सीमा खोजकर उसे पृष्ठभूमि से अलग करती है। समस्या यह है कि ट्रॉली के उसी हिस्से से दोबारा गुजरने या कैमरे का कोण थोड़ा बदलने पर एक ही फल को दो या तीन बार गिनने का खतरा रहता है। इसे रोकने के लिए overlapping boxes में सबसे अधिक confidence score वाला एक box रखा जाता है और बाकी हटाने वाली non-maximum suppression तकनीक लगाई जाती है। इसके साथ DeepSORT जैसी object tracking तकनीक जोड़ी जाती है, जो लगातार जाँचती है कि मौजूदा frame में दिख रहा फल पिछले frame वाला ही फल है या नहीं। इन दोनों उपायों से ट्रॉली ग्रीनहाउस का एक चक्कर पूरा करने के बाद बिना दोहराव वाली फल संख्या देती है।

गुच्छों में लगने वाले टमाटरों के लिए अलग-अलग टमाटरों से भिन्न तरीका चाहिए। एक ग्रीनहाउस में गश्ती रोबोट पर Intel RealSense D435i कैमरा लगाया गया। ऊँचाई 1.2 मीटर, ऊपर-नीचे झुकाव 30 डिग्री और दाएँ-बाएँ घुमाव 15 डिग्री पर तय किया गया, तथा lens और फल के बीच की दूरी 0.5 से 1 मीटर रखी गई। इससे 1280×720 resolution पर 30 frames per second का video मिलता है। जब रोबोट 0.3 से 0.5 मीटर प्रति सेकंड की रफ्तार से rail पर चलता है, तब कृत्रिम बुद्धिमत्ता एक गुच्छे में लाल हुए फलों के अनुपात से परिपक्वता को तीन चरणों में बाँटती है। प्रारंभिक चरण में लाल रंग केवल 10 से 30 प्रतिशत, मध्य चरण में 30 से 70 प्रतिशत और अंतिम चरण में 70 प्रतिशत से अधिक फल पर फैला होता है। इस काम के लिए बना LampCT-YOLO model, YOLOv10 backbone पर

SegNeXt नामक attention mechanism लगाकर रंग की सूचना के प्रति अधिक संवेदनशील बनाया गया है। ग्रीनहाउस के ढाँचे या मिट्टी जैसी अनावश्यक पृष्ठभूमि प्रतिक्रिया घटाने के साथ LAMP channel pruning की lightweight प्रक्रिया जोड़कर model का आकार इतना कम किया गया कि रोबोट के छोटे computing device पर भी real-time detection संभव हो सके।

इस रोबोट को और करीब से देखें तो उसके मुख्य ढाँचे पर NVIDIA Jetson AGX Orin या Xavier NX जैसा edge computing device लगा है, और सामने RealSense कैमरे के साथ 2D LiDAR sensor जुड़ा है। LiDAR प्रकाश भेजकर उसके लौटने का समय मापता है और आसपास की बाधाओं की दूरियों का सघन नक्शा बनाता है, जिससे रोबोट ग्रीनहाउस की rail और गलियारे से बाहर नहीं जाता। कैमरा और LiDAR साथ इस्तेमाल करने वाला यह रोबोट केवल वास्तविक समय में फलों की परिपक्वता की grading नहीं करता, बल्कि हर पके फल के 3D coordinates भी निकालता है। coordinates जानना जरूरी है, क्योंकि अगले चरण में robot arm या व्यक्ति को ठीक उसी जगह पहुँचकर फल तोड़ना होता है।

किसानों के लिए रोग देखने और परिपक्वता पहचानने के अलग-अलग उपकरण चलाना झंझट का काम है। इसी कठिनाई को घटाने के लिए AgroDualNet बनाया गया, जिसमें दोनों कार्य एक ही प्रणाली में हैं। रोग पहचानने वाला भाग CBAM और ResNet50 के साथ SMO optimization तकनीक जोड़ता है और पत्तियों के रोग लक्षणों वाली PlantVillage dataset पर 99.6 प्रतिशत accuracy देता है। परिपक्वता वाला भाग काफी हल्के MobileNetV2 और YOLOv8 से कच्चा, आधा पका, पूरा पका और नरम पड़ा, इन चार चरणों को अलग करता है, और battery से चलने वाले छोटे device पर भी वास्तविक समय में काम करता है। एक कैमरे और एक program से दोनों निर्णय एक साथ मिलते हैं, इसलिए किसान को दो अलग equipment sets नहीं रखने पड़ते।

जापान में नाशपाती उगाने वालों के सामने explainable artificial intelligence की अलग चुनौती थी। grading करने वाली कृत्रिम बुद्धिमत्ता यदि उत्पादक को यह न बता सके कि उसने कोई grade क्यों दिया, तो खेत में उस पर विश्वास पाना कठिन है। शोधकर्ताओं ने Mask R-CNN neural network में global context block जोड़ा, जो पहले पूरी तस्वीर देखता है और संभावित दोष वाले हिस्सों का अग्रिम संकेत देता है; इससे नाशपाती की सतह के दाग और धब्बे पिक्सेल स्तर पर सटीक अलग किए गए। फिर पूरी सतह में दोष के अनुपात को बढ़ा, थोड़ा बढ़ा, थोड़ा छोटा और छोटा जैसी अस्पष्ट श्रेणियों में बाँटकर विशेषज्ञ के निर्णय नियमों की नकल करने वाली fuzzy inference system में डाला गया, जिसने बाजार में प्रयुक्त premium, superior, good और off-grade, इन चार grades में अंतिम वर्गीकरण किया। एक निश्चित संख्या से कठोर उत्तर देने के बजाय मानव निर्णय की अस्पष्टता अपनाने से उत्पादक उस आधार को समझ सकता है जिस पर नाशपाती को grade मिला।

पूरे विस्तृत खेत की कटाई कब की जाए, यह तय करने में drone काम आता है। Mavic 2 Pro drone लगभग 7 मीटर की ऊँचाई से मकई के ऊपरी हिस्से में उगने वाले नर पुष्प, यानी tassel वाले खेत की तस्वीर लेता है और 1 hectare का क्षेत्र दर्ज करने में केवल 5 मिनट लगाता है। YOLOv5 पर आधारित tassel detection model हर tassel को अभी फूल नहीं आया, फूलना शुरू हुआ और पूरा फूल आया,

इन तीन चरणों में बाँटता है, और फिर सभी tassels में पूरी तरह खिले तथा अभी न खिले tassels के अनुपात के अंतर से growth index निकाला जाता है। इस index का मकई में silk emergence की तारीख के साथ मजबूत negative correlation मिला, और correlation coefficient -0.943 था।

मकई में silk निकलने की तारीख से आगे की गणना में हर दिन का तापमान जोड़ा जाता है। किसी दिन तापमान अधिक हो या कम, मकई को अगले चरण में पहुँचने के लिए निश्चित accumulated temperature पूरा करना ही पड़ता है। Emi Star किस्म में accumulated temperature 500 डिग्री सेल्सियस होने पर कटाई शुरू होती है और 560 डिग्री पर समाप्त होती है, जबकि Honey Bantam 20 में यह 450 डिग्री पर शुरू होकर 510 डिग्री पर समाप्त होती है, अर्थात् हर किस्म का मानदंड अलग है। इस तरह तय उचित कटाई अवधि करीब पाँच दिन की होती है, और कटाई से एक महीने पहले किए गए ऐसे पूर्वानुमान लगभग 70 प्रतिशत मामलों में सही निकले। इसी तरह सेब के पेड़ में पहला फूल खिलने की तारीख बताने वाले शोध में BiLSTM-MhA model ने रोज दर्ज तापमान, ऊँचाई, अक्षांश और देशांतर को साथ लिया, 15 से 20 दिन पहले तारीख बताई और त्रुटि केवल लगभग एक दिन, ठीक 1.34 दिन रही।

sweet corn के खेतों में यह जाँचने के लिए field validation भी किया गया कि पूर्वानुमान सचमुच उपयोगी है या नहीं। 80 से अधिक खेतों में परिणाम मिलाने पर 70 प्रतिशत accuracy फिर प्रमाणित हुई। अनुमानित तारीख पर पूरे खेत को एक बार में काटने वाली batch harvesting और हर भुट्टे की परिपक्वता देखकर कई दिनों में चुनकर काटने वाली selective harvesting के बीच उपज का अंतर सांख्यिकीय रूप से significant नहीं था (p-value 0.07)। पूर्वानुमान सही हो तो मजदूरों को बार-बार खेत में जाकर चयन नहीं करना पड़ता और मशीन एक दिन में पूरा खेत काट सकती है, वह भी उपज घटाए बिना।

ऐसी पूर्वानुमान प्रणाली वास्तव में उपयोगी तभी होगी जब परिणाम खेत प्रबंधक तक तुरंत पहुँचे। sweet corn के खेत में drone image analysis का परिणाम अपने आप regional weather data server से जुड़ता है और अलग से गणना किए बिना expected harvest date screen पर दिख जाती है। तेल ताड़ के बागान का web dashboard भी इसी तरह काम करता है, और प्रबंधक कार्यालय में बैठे हुए वास्तविक समय में देखता है कि किस पेड़ के नीचे गिरे फल जमा हैं तथा उसी आधार पर मजदूर भेजने का क्रम तय करता है। जिस काम के लिए पहले पैदल खेत देखना पड़ता था, वह अब एक screen पर आ गया है, और यह automatic linkage ही laboratory model को वास्तविक farm tool में बदलने वाली अंतिम कड़ी है।

स्ट्रॉबेरी के खेत की तस्वीर में पत्तियों के बीच लाल फल घने और एक-दूसरे पर चढ़े दिखाई देते हैं। स्ट्रॉबेरी और आड़ू जैसे छोटे, पास-पास उगने वाले फलों में हर फल को अलग पहचानना अपने आप में कठिन है। हाल का FruitQuery model transformer architecture से खेत में लगे स्ट्रॉबेरी और आड़ू की परिपक्वता पहचानता है, और 67.02 प्रतिशत mean average precision के साथ केवल 14.08 million parameters रखता है, इसलिए YOLOv8, YOLOv9 और YOLOv10 से हल्का और अधिक सटीक है। स्ट्रॉबेरी खेत की हर तस्वीर पर सही उत्तर का label मनुष्य को हाथ से लगाना पड़ता है,

इसलिए annotation का यह काम training bottleneck बन जाता है। 2026 में आए SSEFNet model ने इस बोझ को घटाने के लिए semi-supervised learning चुना, जिसमें कुछ labeled और बाकी unlabeled pictures साथ प्रशिक्षण में ली जाती हैं, और उलझे हुए strawberry dataset में भी 91.1 प्रतिशत precision मिली। University of Florida के शोधकर्ताओं ने वास्तविक खेत के बजाय computer में virtual strawberry field बनाया और model को पहले उसी में प्रशिक्षित किया। इससे तैयार model ने वास्तविक खेत में 92 प्रतिशत accuracy से फल खोजे और फल का व्यास मापने की त्रुटि केवल 1.2 मिलीमीटर रही, जो commercial grading में सीधे उपयोग के योग्य स्तर है। image data इकट्ठा करने और label लगाने की लागत घटने की इस दिशा को देखते हुए, तापमान, आर्द्रता और ethylene gas concentration मापने वाले sensors को image के साथ जोड़ने वाला multisensory fusion अगला स्थापित चरण बन सकता है।

उपज का पूर्वानुमान देखने में आसान लगता है, पर वास्तव में ऐसा नहीं है। तस्वीर में आए फल केवल वही हैं जो तस्वीर लेते समय दिखाई दे रहे थे, जबकि नीचे पत्तियों से ढके अदृश्य फल और आने वाले कुछ हफ्तों में लगने वाले नए फूल भी मौजूद हैं। इसलिए अच्छा forecasting model आज दिख रहे फलों की संख्या तक सीमित नहीं रहता, बल्कि पेड़ का growth stage, अब तक जमा तापमान और पिछले वर्षों की इसी अवधि के harvest records भी गणना में जोड़ता है। कैमरे ने वर्तमान का केवल एक दृश्य देखा है, जबकि उपज पूर्वानुमान उस दृश्य में समय जोड़कर भविष्य की तस्वीर बनाता है।

गिनती, गुणवत्ता वर्गीकरण और उपज आकलन को एक ही क्रम में जोड़ने वाली प्रणालियाँ भी हैं। FruitNet pipeline पहले YOLOv8 से तस्वीर में फल को real time में खोजकर प्रारंभिक संख्या गिनती है, और फिर deep convolutional neural network तथा support vector machine के संयुक्त model से फलों को गुणवत्ता के चार grades में बाँटती है। अंत में हर grade की संख्या और आकार की सूचना random forest regression नामक statistical technique में डालकर पूरे खेत की अंतिम उपज निकालती है। 18 हजार से अधिक apple images और 40 हजार से अधिक individual annotations वाले MinneApple dataset पर परीक्षण में training accuracy 98 प्रतिशत से ऊपर रही और validation accuracy 94 से 95 प्रतिशत के बीच रही। फल घने हों और एक-दूसरे से ढकें तो overlapping boxes को समेटने वाली technique और कई variables को साथ देखने वाला regression module दोहरी गणना रोकते हैं।

फलों को गिनने और grade देने से आगे robot arm के वास्तव में फल तक पहुँचने का रास्ता तय करने में भी यही camera information काम आती है। Kinect या RealSense जैसे RGB-D sensor से फल खोजने के बाद कृत्रिम बुद्धिमत्ता निर्णय की विश्वसनीयता बताने वाला confidence score, gripper में दो उँगलियाँ हैं या तीन, और फल vertical axis से कितना झुका है, इन सबको एक regression equation में जोड़ती है। इस मान को A* pathfinding algorithm की cost calculation में डालने पर robot arm केवल सबसे छोटा रास्ता नहीं चुनता, बल्कि पकड़ने के अनुकूल angle और निश्चित रूप से पहचाने गए फल दोनों को देखकर मार्ग बनाता है। संतरे के परीक्षण में coefficient of determination 0.89, position error 3.2 सेंटीमीटर और percentage error 5.4 प्रतिशत था। स्ट्रॉबेरी के परीक्षण में coefficient of determination 0.82, position error 4.7 सेंटीमीटर और percentage error 7.9

प्रतिशत था। यह गणना जोड़ने के बाद संतरा तोड़ते समय robot arm की travel distance 14 प्रतिशत और strawberry तोड़ते समय 11 प्रतिशत घटी, जबकि सही स्थान पकड़ने की precision 12 से 15 प्रतिशत बढ़ी।

इन उदाहरणों को साथ रखने पर दिशा स्पष्ट दिखाई देती है। आरंभ में केवल परिपक्वता पहचानने वाला model और केवल गिनती करने वाला model अलग थे, लेकिन अब AgroDualNet की तरह रोग और परिपक्वता साथ देखने वाले model, FruitNet की तरह संख्या, गुणवत्ता और उपज को एक क्रम में जोड़ने वाले model, तथा RGB-D robot arm की तरह perception और motion planning को एक प्रणाली में रखने वाले model लगातार आ रहे हैं। आगे की दिशा एक camera और एक program से अधिक प्रश्नों के उत्तर देने की लगती है, और इससे किसानों पर कई equipment अलग-अलग खरीदने तथा सँभालने का बोझ घटता है। कई camera लगाने के बजाय एक ही camera से एक साथ कई काम कराए जाते हैं।

अलग तरीकों से बनाए गए इन models का प्रदर्शन कुछ साझा मानकों से मापा जाता है। accuracy सभी निर्णयों में सही निर्णय का अनुपात है, precision कृत्रिम बुद्धिमत्ता द्वारा पका बताए गए फलों में वास्तव में पके फलों का अनुपात है, और recall वास्तव में पके फलों में बिना छूटे खोजे गए फलों का अनुपात है। कच्चे या खराब फलों जैसी कम संख्या वाली classes को कितनी अच्छी तरह पहचाना गया, यह देखने में precision और recall दोनों को जोड़ने वाला F1 score उपयोगी है। box कितनी सटीक बनी, इसे IoU से मापा जाता है, जो कृत्रिम बुद्धिमत्ता के बनाए box और वास्तविक फल स्थान के overlap का अनुपात है, जबकि अलग-अलग confidence thresholds का औसत mAP पूरे detection model की क्षमता दिखाता है। robot या patrol camera जैसे real-time device में FPS भी देखा जाता है, जो प्रति सेकंड process होने वाली images की संख्या है। उपज या मिठास जैसे संख्यात्मक prediction के लिए अलग मानक हैं; mean absolute error और root mean square error predicted तथा actual value के अंतर को बताते हैं, जबकि mean absolute percentage error उसे प्रतिशत में दिखाता है। coefficient of determination 0 से 1 के बीच बताता है कि prediction model वास्तविक उपज या मिठास के उतार-चढ़ाव को कितना समझाता है, और 1 के करीब मान अधिक सटीक prediction दर्शाता है; freshness score पूरे fruit surface में दोषरहित क्षेत्र का प्रतिशत बताता है। इसलिए research papers केवल accuracy न देकर कई metrics साथ लिखते हैं, ताकि केवल अच्छा दिखने वाला कोई एक metric चुनने से बचा जा सके।

ये सभी आँकड़े अंततः एक table में सिमटकर farm office की दीवार या tablet screen पर दिखाई देते हैं। हर क्षेत्र के लिए आज तोड़े गए फलों की संख्या, हर grade का अनुपात और अगले एक सप्ताह में पूरी तरह पकने वाले फलों की अनुमानित संख्या साथ लिखी होती है। manager इस table से तय करता है कि कल किस क्षेत्र में कितने लोग भेजने हैं और कितने boxes तैयार रखने हैं। कुछ संख्याएँ किसी व्यक्ति की पूरे दिन की समय-सारिणी बदल देती हैं, इसलिए field में model accuracy का 1 प्रतिशत अंतर कभी छोटा मामला नहीं है।

यह चित्र harvest पर समाप्त नहीं होता, बल्कि उसके बाद की logistics तक जाता है। आज कितने boxes आने वाले हैं, यह पहले से जानने पर एक दिन पहले तय किया जा सकता है कि कितने refrigerated trucks बुलाने हैं और sorting facility में कितने workers लगाने हैं। prediction गलत हो और अचानक अधिक माल आ जाए तो cold storage के सामने boxes जमा हो जाते हैं, और कुछ को समय पर ठंडा न कर पाने से गुणवत्ता गिरती है। maturity classification और yield prediction खेत के भीतर की technology हैं, पर वे खेत के बाहर की logistics planning को बदलने वाले variables भी हैं।

farm owner के लिए लगातार एकसमान accuracy महत्वपूर्ण है। साफ दिन में ली गई कुछ तस्वीरों पर अच्छा चलने, पर बादल वाले दिन या शाम के समय गलत होने वाला model field में उपयोगी नहीं है। किसी संख्या का संयोग से एक बार अच्छा आना और हर सुबह उसी स्तर पर मिलना बिल्कुल अलग बातें हैं। ग्रीनहाउस में रोज घूमने वाली trolley-mounted counting system ने पूरी test period में स्थिर performance बनाए रखी, और यह तथ्य उसकी peak accuracy जितना ही महत्वपूर्ण है।

ऐसी प्रणाली को field में ज्यों का त्यों रखने पर वे समस्याएँ दिखाई देती हैं जो laboratory में नहीं दिखतीं। खुले खेत में धूप की तीव्रता हर घंटे बदलती है, तेज सीधी रोशनी गहरी छाया बनाती है, और हवा में शाखाएँ तथा पत्तियाँ बार-बार एक-दूसरे पर चढ़ती और अलग होती हैं। lens पर धूल या नमी जमने पर एक camera पर निर्भर recognition performance तेजी से गिर जाती है। बदलते environment में स्थिर रहने के लिए कई angles से एक साथ होने वाली multi-view imaging और उन pictures को एक three-dimensional point cloud में जोड़ने वाली 3D fusion technology की जरूरत पड़ेगी।

बाहर और भीतर अलग संकेत देने वाले फल अब भी बड़ी बाधा हैं। आम जैसे जिन फलों का छिलका अंत तक रंग नहीं बदलता या मोटा होता है, उनमें केवल तस्वीर से मिठास, अम्लता या fatty acid level जानने का कोई उपाय नहीं है। सस्ते RGB camera में थोड़े chemical measurements जोड़ने वाली fusion method और निकट-अवरक्त तथा hyperspectral sensors को छोटा व सस्ता बनाने का research साथ आगे बढ़ना चाहिए। बाहर और भीतर दोनों देखने वाली आँख न हो तो अत्यंत परिष्कृत artificial intelligence भी छिलके के भीतर की पूरी कहानी नहीं पढ़ सकती।

खेत में इस्तेमाल होने वाले equipment के पास laboratory computer जितने संसाधन नहीं होते। शक्तिशाली vision transformer या बड़े convolutional neural network सीमित battery और graphics processing unit वाले छोटे robots अथवा सस्ते IoT modules पर धीमे प्रतिक्रिया देते हैं। इसलिए कम precision वाले numbers से computation घटाने वाली quantization, LAMP channel pruning की तरह अनावश्यक connections काटने वाली structural pruning और बड़े model का निर्णय छोटे model में पहुँचाने वाली knowledge distillation जैसी lightweight techniques लगातार सुधारी जा रही हैं। अंततः field में प्रयुक्त artificial intelligence अक्सर वही model होता है जो उपलब्ध hardware के भीतर सबसे व्यावहारिक रहता है।

training method में भी एक आम जाल है। कुछ research तस्वीरों को घुमाकर, पलटकर और brightness बदलकर data बढ़ाने के बाद training तथा validation sets अलग करती हैं, जिससे एक

ही फल की बदली हुई pictures दोनों sets में मिल जाती हैं और data leakage होता है। इससे validation score वास्तविक क्षमता से अधिक दिखता है। इसे रोकने के लिए training और validation data पहले अलग करना, augmentation केवल training set पर करना और validation set को बिना छेड़े मूल रूप में रखना जरूरी है। इस सिद्धांत का पालन करने और न करने वाले research results की सीधी तुलना नहीं की जा सकती।

स्रोत और संदर्भ

शोध पत्र

1. Bijwe, K. B., & Gadicha, A. B. (2026). FruitNet: फल पहचान और उपज आकलन के लिए एक deep hybrid model. Bulletin of Electrical Engineering and Informatics, 15(2), 1150-1160. DOI: 10.11591/eei.v15i2.11112.
2. Kripa, S., & Jeyalakshmi, V. (2026). feature fusion के साथ deep learning का उपयोग करके स्वचालित फल परीक्षणता grading. Preprint submitted to Scientific Reports.
3. Moldvai, L., & Nyéki, A. (2025). टमाटर (Solanum Lycopersicon) की पहचान और खेती के लिए नवीन computer vision methods: एक समीक्षा. Discover Applied Sciences, 7, 975. <https://doi.org/10.1007/s42452-025-07613-x>
4. Simatupang, et al. (2026). गरि फलों की पहचान से तेल ताड़ की कटाई तत्परता जानने वाली YOLOv8-based IoT system. Journal of Deep Learning, Computer Vision and Digital Image Processing, 15(2), 237-249.
5. Zeeshan, S., et al. (2025). deep learning-based perception और actuator-aware motion planning के माध्यम से robotic fruit harvesting में data-driven trajectory optimization. Engineering Research Express, 7, 045210.
6. तेल ताड़ के ताजे फल-गुच्छों की परीक्षणता grading के लिए deep learning: एक व्यापक समीक्षा. (2026). Trends in Sciences, 23(8), 13227.
7. smart farming में strawberry fruit और ripeness की deep learning-based detection: architectures और methodologies की पहली समीक्षा. (2026). Smart Agricultural Technology.
8. AgroDualNet: crop disease forecasting और fruit ripening detection के लिए dual deep learning-based framework. (2026). Scientific Reports. <https://www.nature.com/articles/s41598-026-49002-3>
9. 大澤央, 齋藤正博, 八木岡敦. (2026). object detection AI का उपयोग करके sweet corn की उचित कटाई अवधि बताने वाली technology का विकास. 『農業食料工学会誌』, 88(2), 85-91.
10. 大澤央, 齋藤正博, 八木岡敦. (2026). processing sweet corn की उचित कटाई अवधि बताने वाली AI technology का विकास. 『農業食料工学会誌』, 88(3), 123-128.
11. 劉恩奇, 劉淼, 楊貴軍 और अन्य. (2026). time-series temperature features को मजबूत करने पर आधारित apple first-flowering date की Bi-LSTM prediction method. 『智慧農業(中英文)』, 8(2), 84-96.
12. 趙麗成 और अन्य. (2026). improved YOLOv10 और LAMP channel pruning पर आधारित cluster tomato maturity detection algorithm का विकास. 『智慧農業(中英文)』, 8(2), 133-146.
13. global context information वाले deep learning और fuzzy inference का उपयोग करके नाशपाती grading method का अध्ययन. (2026). 『農業情報研究』, 35(2), 65-78.
14. commercial greenhouse में pipe-rail trolley-mounted camera system से sweet pepper की deep learning-based fruit counting और yield estimation. (2026). Horticulturae, 11(7), 718. <https://doi.org/10.3390/horticulturae11070718>
15. FruitQuery: orchard conditions में strawberry और peach ripeness detection के लिए transformer-based model. (2026).
16. SSEFNet: complex field datasets में strawberry ripeness detection के लिए semi-supervised learning model. (2026). arXiv:2602.15656. <https://arxiv.org/pdf/2602.15656>

17. fruit detection और sizing models को train करने के लिए virtual strawberry field simulation. (2026). University of Florida.

व्याख्यान और वीडियो सामग्री

1. CSUMB College of Business. (2025). 2025 Ag Jobs: व्यापक दृष्टि लाना, डेटा की कटाई: कृषि में करियर. YouTube. <https://www.youtube.com/watch?v=rgshB8Jh2ZE>
2. Street Science with Fun. (2025). AI/ML से संचालित आम पहचान और कटाई मशीन. YouTube. <https://www.youtube.com/watch?v=Dy3xDC8rElw>
3. Washington State Academy of Sciences. (2025). कटाई के बाद के लिए AI. YouTube. <https://www.youtube.com/watch?v=hJlOrgNIQG4>
4. Solvi. (2026). Webinar: वास्तविक field data से AI-based plant counts का सत्यापन. YouTube. <https://www.youtube.com/watch?v=B0KuJdRtmaQ>
5. Greg Bronevetsky. (2025). simulated और controlled environments में plant growth traits की predictive pattern recognition. YouTube. <https://www.youtube.com/watch?v=uKepfZAnKbk>

अध्याय 2

बागवानी रोबोट और स्वायत्त कार्य स्वचालन

2.1

फल, सब्जी और मशरूम कटाई रोबोट तथा एंड-इफेक्टर

अप्रैल 2026 तक जापान में चेरी टमाटर तोड़ने वाला ऐसा रोबोट व्यावसायिक उत्पादन में आ चुका था, जो अकेले एक दिन में 31 किलोग्राम फसल काटता है। उसी महीने इजरायली एगटेक कंपनी DailyRobotics ने अमेरिका के कैलिफोर्निया में एक खेत पर खुले खेत का स्ट्रॉबेरी हार्वेस्टर तैनात किया, जबकि जापानी स्टार्टअप inaho के सेवा-आधारित स्लैक टमाटर हार्वेस्टिंग रोबोट ने खेतों की श्रम मांग 45 प्रतिशत से अधिक घटा दी। बागवानी फसल काटने वाले रोबोटों के सामने तीन बड़े काम हैं। फल कहाँ है यह देखना, बिना क्षति पहुँचाए कितना बल लगाया जा सकता है यह आँकना, और गलत पकड़ बनते ही उसे तुरंत सुधारना।

टमाटर, स्ट्रॉबेरी और बटन मशरूम जैसी फसलों में, जिन्हें हाथ से एक-एक करके चुनना पड़ता है, कटाई कुल उत्पादन लागत के आधे से लेकर 70 प्रतिशत तक होती है। ग्रामीण श्रमबल लगातार घट और वृद्ध हो रहा है, इसलिए मानव हाथों की जगह लेने वाली रोबोटिक भुजाओं से उम्मीद हर साल बढ़ रही है। फिर भी मौजूदा व्यावसायिक कटाई रोबोटों की औसत सफलता दर लगभग 66 प्रतिशत है, और तोड़े गए हर बीस फलों में करीब एक पर घाव या दबाव का निशान रह जाता है। मनुष्य आँखों से देखकर और उँगलियों के स्पर्श से बल का अनुमान लगाकर फल तोड़ता है, लेकिन रोबोट को यही इंद्रियाँ सेंसर और गणना से बनानी पड़ती हैं। इसलिए फल, सब्जी और मशरूम काटने वाले रोबोट में फसल को वास्तव में पकड़ने वाले हाथ, यानी एंड-इफेक्टर की बनावट और बल नियंत्रण पूरे रोबोटिक हाथ की क्षमता तय करते हैं।

कटाई रोबोट की भुजा का आकार रोपण पद्धति और फल के ढके होने की मात्रा के अनुसार बदलता है। एक-दूसरे पर चढ़ी शाखाओं और पत्तियों वाले घने पेड़ों में पाँच या छह जोड़ वाली बहु-संधियुक्त भुजा लाभकारी होती है। जैसे कोई व्यक्ति कंधे, कोहनी और कलाई को क्रम से मोड़कर संकरी जगह में हाथ डालता है, वैसे ही पाँच या छह जोड़ वाली रोबोटिक भुजा पत्तियों के बीच रास्ता खोजकर भीतर छिपे फल तक पहुँचती है। इसके विपरीत, ग्रीनहाउस की पाइप रेल के साथ लगी फसल जैसे निश्चित बेलनाकार क्षेत्र में काम करने पर समानांतर रोबोटिक भुजा अधिक उपयुक्त होती है। कई छोटी कड़ियाँ मिलकर एक बिंदु को थामती हैं, इसलिए यह भुजा मजबूत और तेज प्रतिक्रिया वाली होती है तथा लगभग 300 मिलीमीटर त्रिज्या और 300 मिलीमीटर ऊँचाई की तंग जगह में भी बिना डगमगाए तेजी से चलकर सक्शन से फल अलग करती है।

मशरूम कक्षों में, जहाँ शेल्फ 250 मिलीमीटर या उससे कम अंतर पर कई स्तरों में लगे होते हैं, भुजा को ऊपर-नीचे व्यापक रूप से चलाने की जगह नहीं होती। ऐसे स्थानों में SCARA, यानी Selective Compliance Assembly Robot Arm, संरचना स्थापित हो चुकी है। SCARA भुजा समतल सतह पर तेजी से दाएँ-बाएँ घूमती है और जरूरत पड़ने पर थोड़ा ही ऊपर-नीचे जाती है, इसलिए वह मानो

लेटकर पतली शेल्फों के बीच घुस सकती है और मशरूम तोड़ सकती है। सेब के पेड़ जैसी फसल में, जहाँ फल चारों ओर लगे होते हैं, एक भुजा पर्याप्त नहीं होती। MARS 3.1 नाम का सेब कटाई रोबोट अपनी दो भुजाएँ स्वतंत्र रूप से चलाता है और पेड़ की बाहरी सतह के ठीक भीतर वाले उथले हिस्से में दोनों ओर से एक साथ पहुँचकर बिना टकराव के फल बाँटकर तोड़ता है।

फल को वास्तव में छूने वाली उँगलियाँ, यानी एंड-इफेक्टर, मुख्यतः तीन प्रकार से बनाए जाते हैं। स्कू से चलने वाली तीन उँगलियों वाला कठोर यांत्रिक ग्रीपर फल को केंद्र में समेटने और उसका भार सँभालने में अच्छा है, और जरूरत हो तो उँगलियों पर छोटा ब्लेड या घूमने वाला कटर लगाकर डंठल वहीं काटा जा सकता है। किंतु उँगलियाँ धातु या कठोर प्लास्टिक की होने से बल फल की सतह पर एक बिंदु में केंद्रित होकर दबाव के निशान या घाव छोड़ सकता है। वैक्यूम सक्शन प्रणाली में उँगलियों की जगह सक्शन कप फल की सतह पर लगाया जाता है, भीतर की हवा निकालकर ऋणात्मक दबाव बनाया जाता है, फिर फल को खींचकर या मरोड़कर अलग किया जाता है। यह चिकनी सतह या मोटे छिलके वाले फल के लिए अच्छा है, लेकिन सतह ऊबड़-खाबड़ हो या उस पर महीन रोएँ हों तो कप और सतह के बीच हवा रिसती है और पकड़ तुरंत ढीली हो जाती है।

इन दोनों तरीकों की कमियाँ दूर करने के लिए सिलिकॉन या हाइपरइलास्टोमर जैसी मुलायम सामग्री से बनी उँगलियों वाला लचीला अनुकूल ग्रीपर विकसित हुआ। इसकी उँगलियों के भीतर कई छोटे वायु-कक्ष होते हैं, जिनमें हवा भरने और निकालने की मात्रा बदलकर उन्हें मोड़ा जाता है, या Fin Ray Effect नाम की संरचना अपनाई जाती है। मछली के पंख की तरह इसके सहारे तिरछे एक-दूसरे को काटते हैं, इसलिए एक ओर दबाने पर दूसरी ओर अपने आप वस्तु को घेरते हुए मुड़ जाती है। फल गोल हो या अनियमित, ये उँगलियाँ उसकी सतह के अनुसार अपना आकार बदल लेती हैं, जिससे बल एक बिंदु पर न टिककर बड़े क्षेत्र में फैलता है और फल की क्षति मूल रूप से घटती है। हाथ जितना मुलायम होता है, रोबोट उतनी ही मजबूत पकड़ के साथ फल को कम चोट पहुँचाने के उस लक्ष्य के निकट आता है जो पहली नजर में विरोधाभासी लगता है।

हाथ कितना भी मुलायम हो, दृष्टि और स्पर्श के बिना बेकार है। रोबोट को एक साथ ठीक-ठीक जानना होता है कि फल कहाँ है, डंठल कहाँ काटना है और उँगलियों पर इस समय कितना बल पड़ रहा है। स्थान देखने वाली आँख का काम रंग और गहराई एक साथ दर्ज करने वाले RGB-D कैमरे, जैसे Intel RealSense D435i और D405 तथा Microsoft Kinect v2, साथ ही स्टीरियो कैमरे और 3D लेजर स्कैनर करते हैं। रंगीन चित्र से पकाव और बनावट पढ़कर तथा गहराई सूचना जोड़कर पॉइंट क्लाउड बनाया जाता है, जिसके आधार पर रोबोटिक भुजा के निर्देशांक तंत्र में फल की आगे-पीछे, दाएँ-बाएँ और ऊपर-नीचे की स्थिति, गोलाई और आयतन तक निकाले जा सकते हैं। बटन मशरूम काटते समय 3D स्कैनर टोपी का व्यास और ऊँचाई मापता है, तय बाजार मानक से छोटे मशरूम छोड़ देता है और केवल पूरी तरह बड़े मशरूम चुनता है।

दृष्टि से स्थान मिलने के बाद उँगलियों का स्पर्श काम करता है। उँगली के भीतर लगा पतली फिल्म वाला दबाव सेंसर, मोटर पर लगा बल वापस पढ़ने वाला टॉर्क सेंसर, अल्ट्रासोनिक दूरी सेंसर, सटीक स्थिति पढ़ने वाला 23-बिट एनकोडर और वायु व हाइड्रोलिक दबाव सेंसर एक इकाई की तरह काम करते हैं। दबाव सेंसर

वास्तविक समय में देखता है कि फल पर लगा बल फसल की सहन सीमा से अधिक तो नहीं है, जबकि अल्ट्रासोनिक सेंसर फल के हाथ में हल्का फिसलते ही उसे पकड़कर मोटर बल तुरंत बदलता है। जब फल घने पत्तों और शाखाओं वाले कैनोपी में छिपा हो, तब उँगली के सिरे पर लगा छोटा कैमरा, यानी फिंगर विजन, और भुजा की जगह बदलकर फिर चित्र लेने वाली व्यू-रीप्लानिंग साथ काम करते हैं। पास जाते समय दृश्य रुक जाए तो रोबोट तुरंत कोण बदलकर खुली दरार फिर खोजता है।

फल कहाँ है और कहाँ काटना है, यह खोजने वाली आँख डीप लर्निंग डिटेक्शन मॉडल की होती है। YOLO, यानी You Only Look Once, परिवार के नए YOLOv8, YOLOv10 और YOLOv11 व्यापक रूप से इस्तेमाल होते हैं, और टमाटर के लिए बनाया गया LampCT-YOLO, YOLOv10 को बैकबोन बनाकर SegNeXt नाम की अटेंशन तकनीक जोड़ता है। यह तकनीक सेगमेंटेशन, यानी चित्र में वस्तु की सीमा को पिक्सेल-दर-पिक्सेल काटने की प्रक्रिया, के साथ जुड़कर ग्रीनहाउस में मिले-जुले पत्तों की अव्यवस्थित पृष्ठभूमि के बीच भी टमाटर के पकाव बताने वाले रंग संकेतों को अधिक महत्व देती है। LAMP प्रूनिंग जोड़कर गणना घटाई जाती है, इसलिए मॉडल महँगे सर्वर के बिना खेत के छोटे नियंत्रक पर सीधे चल सकता है। सही कटाई बिंदु खोजने के लिए Swift Transformer V2 मॉडल को पिक्सेल समूहों की आकृति सँवारने वाली पारंपरिक मॉर्फोलॉजिकल इमेज प्रोसेसिंग के साथ जोड़ा जाता है, जिससे फल, कैलेक्स और पेडंकल अलग-अलग सेगमेंट होते हैं।

व्यवहार में उपयोगी होने के लिए प्रशिक्षित मॉडल को बड़े लैपटॉप पर नहीं, भुजा के पास लगे छोटे डिब्बे में चलना चाहिए। ONNX या TensorRT रूप में हल्के किए मॉडल NVIDIA Jetson Xavier NX, AGX Orin, Raspberry Pi 5 या Omron PLC जैसे क्षेत्रीय नियंत्रकों में डाले जाते हैं। फल को पहचानने और तोड़ने में लगा समय, यानी कटाई चक्र, फसल और हाथ की बनावट के अनुसार बदलता है। SCARA भुजा एक बटन मशरूम 10 सेकंड से कम में तोड़ती है, MARS 3.1 की एक भुजा एक सेब 7 से 9 सेकंड में, स्ट्रॉबेरी लगभग 4 से 11 सेकंड में और संतरा लगभग 7 से 11 सेकंड में तोड़ती है।

रोबोट की क्षमता कुछ संख्याओं से आँकी जाती है। कैमरा फल और पेडंकल कितनी शुद्धता से खोजता है, इसे mean Average Precision, यानी mAP, से दिखाया जाता है, और खोजी गई तथा वास्तविक स्थिति का अंतर सेंटीमीटर में मापा जाता है। मगर खेत में काम करने वालों के लिए अहम आँकड़े दूसरे हैं। कुल प्रयासों में सफल कटाई का अनुपात, कटाई के बाद क्षतिग्रस्त फलों का अनुपात, उँगलियों ने सतह का कितना हिस्सा घेरा यह दिखाने वाला enclosure ratio, और पकड़ फसल के सुरक्षित बल क्षेत्र में रही या नहीं। स्ट्रॉबेरी के लिए सुरक्षित पकड़ 8 से 12 न्यूटन, संतरे के लिए करीब 80 न्यूटन और मंदारिन के लिए 6 से 8 न्यूटन मानी जाती है, जिसे समझने के लिए सेब को उँगली से हल्का दबाने और बच्चे का हाथ कसकर पकड़ने के बल का फर्क सोचा जा सकता है। शाखा या पेडंकल अनावश्यक रूप से टूटा या नहीं, इसे बताने वाला संरक्षण अनुपात भी दर्ज होता है।

टमाटर का छिलका मुलायम होता है, लेकिन डंठल और फल का जोड़ मजबूत होता है, इसलिए हाथ की बनावट दबाकर कुचलने और खींचकर भी अलग न कर पाने के बीच तय करनी पड़ती है। Dragon Skin 30 सिलिकॉन की तीन उँगलियों और चार वायु-क्षों वाला लचीला ग्रीपर आनुवंशिक एल्गोरिदम से निकले 28.293 किलोपास्कल दबाव पर फल को घेरता है। आनुवंशिक एल्गोरिदम अनेक परीक्षण संयोजन

बनाकर बेहतर परिणामों को बार-बार मिलाता है और सर्वोत्तम उत्तर के करीब पहुँचता है, इसलिए हर मान हाथ से समायोजित नहीं करना पड़ता। इस सुधरे हाथ से पकड़े टमाटरों में नौ दिन से अधिक समय बाद भी खराबी का निशान नहीं था, और गतिशील कटाई परीक्षण में 100 में लगभग 97 फल सफलतापूर्वक तोड़े गए।

दूसरा तरीका मानव हाथ की गति की सीधी नकल करता है। तीन उँगलियों से टमाटर पकड़कर 360 डिग्री घुमाने पर पेडंकल को नुकसान पहुँचाए बिना केवल फल अलग होता है, ठीक वैसे ही जैसे मेज पर टमाटर तोड़ते समय कलाई अनजाने में घूमती है। पेडंकल काटने वाले तरीके में Swift Transformer V2 सही कटाई बिंदु खोजता है। ग्रीनहाउस रेल पर चलने वाला LampCT-YOLO से लैस गश्ती हार्वेस्टर गुच्छों में लगे टमाटरों के पकाव को हरा, नारंगी और लाल, इन तीन चरणों में तुरंत बाँटता हुआ दिनभर चलता है।

स्ट्रॉबेरी का गूदा नाजुक होता है और हल्के बल से भी नीला या नरम पड़ जाता है। इसलिए इसकी रूपरेखा किसी भी दूसरी फसल से अधिक संपर्क क्षेत्र और बल घटाने पर केंद्रित होती है। तीन की जगह दो उँगलियों वाला लचीला सिलिकॉन गिपर स्ट्रॉबेरी से छूने वाला क्षेत्र न्यूनतम रखता है और केवल 8 से 12 न्यूटन बल लगाता है। प्रतिगमन विश्लेषण और A^* खोज को मिलाने वाली पथ योजना पकड़ की स्थिति की शुद्धता 15 प्रतिशत बढ़ाती और भुजा की यात्रा 11 प्रतिशत घटाती है। एक तरीका फल के शरीर को छूता ही नहीं है। कैमरा डंठल खोजता है, कैंची जैसी उँगलियाँ केवल डंठल काटती हैं, फिर उसी को पकड़कर फल संग्रह पेटी तक पहुँचाती हैं।

सक्शन तरीके में 15 मिलीमीटर गहरा मुलायम कप स्ट्रॉबेरी पर रखकर 2.38 न्यूटन सक्शन बल पैदा किया जाता है, जबकि फल पर वास्तविक दबाव उसके गूदे की सहन सीमा का केवल 20 से 31 प्रतिशत रहता है, इसलिए बिना क्षति कटाई संभव है। यह हाथ तकनीक वास्तविक खेतों तक पहुँच चुकी है। इजरायली एगटेक कंपनी DailyRobotics ने अप्रैल 2026 से कैलिफोर्निया के खेतों में Q2 खुले खेत का स्ट्रॉबेरी हार्वेस्टर तैनात किया। दो रोबोटिक भुजाओं और मुलायम गिपरों वाली यह मशीन स्ट्रॉबेरी तोड़ते ही उन्हें क्लैमशेल नाम की पारदर्शी पैकिंग में रखती है, और कंपनी का कहना है कि यह मनुष्य से 2 से 3 गुना तेज है।

बटन मशरूम कक्षों में शेल्फ 250 मिलीमीटर या कम अंतर पर कई स्तरों में लगे होते हैं, इसलिए भुजा को ऊपर उठने की जगह नहीं मिलती। कम ऊँचाई वाला हार्वेस्टर इस समस्या को SCARA संरचना से हल करता है, जिसमें एक ऊर्ध्वाधर अक्ष और दो क्षैतिज घूमते जोड़ मिलकर भुजा को लगभग लेटी मुद्रा में शेल्फों के बीच सरकाते हैं। ऊर्ध्वाधर अक्ष पर स्ट्रेन-वेव गियर नाम का सटीक रिडक्शन उपकरण, बेल्ट और संतुलन भार लगा होता है, जिससे झटके लगभग मिटते हैं और स्थिति त्रुटि 1 मिलीमीटर के भीतर रहती है। 3D स्कैनर पहले टोपी का व्यास मापता है और तय बाजार मानक वाले मशरूम ही सक्शन कप या लचीले गिपर से निकाले जाते हैं, तथा पूरी प्रक्रिया प्रति मशरूम 10 सेकंड से कम लेती है।

एक सेब के पेड़ पर फल आगे से पीछे तक कई परतों में लगे रहते हैं, इसलिए एक भुजा भीतर छिपे फल तक नहीं पहुँच सकती। दो स्वतंत्र भुजाओं वाला MARS 3.1 पेड़ की सतह के ठीक भीतर उथले क्षेत्र तक दोनों ओर से एक साथ पहुँचता है, एक भुजा एक फल 7 से 9 सेकंड में तोड़ती है और चोट लगे फलों का अनुपात 1 प्रतिशत से नीचे रखती है। एक भुजा सामने की शाखा से फल तोड़ती है, जबकि दूसरी समय

बचाने के लिए सीधे भीतर के फल की ओर बढ़ती है। Fin Ray Effect वाली उँगली, मोटर टॉर्क फीडबैक और अल्ट्रासोनिक फिसलन पहचान को मिलाने वाले परीक्षणों में क्षति दर 0 प्रतिशत तक दर्ज हुई।

संतरे का छिलका मोटा और मजबूत होता है, इसलिए वह पर्याप्त बल सह सकता है। 80 न्यूटन तक बल लगाने वाले तीन उँगलियों के सिलिकॉन ग्रीपर में A* पथ खोज जोड़ने से भुजा की यात्रा 14 प्रतिशत घटती और पकड़ की स्थिति की शुद्धता 12 प्रतिशत बढ़ती है। इसके विपरीत खीरे की सतह ऊबड़-खाबड़ और बहुत वक्र होती है, इसलिए एक सक्शन कप का बिना अंतर चिपकना कठिन है। कागज मोड़ने, यानी ओरिगामी, पर आधारित चुन्नटदार सक्शन कप अपनी अवतल वक्र संरचना से खीरे की सतह के अनुसार खुद मुड़ता और खुलता है, तथा सक्शन संपर्क त्रिज्या 10.66 मिलीमीटर तक बढ़ाकर खेत में 86.2 प्रतिशत सफलता दर प्राप्त करता है। हर फल के छिलके की मोटाई और वक्रता अलग होने से एक ही एंड-इफेक्टर द्वारा हर फसल काटने की अपेक्षा अभी समय से पहले है।

ये उँगली तकनीकें प्रयोगशाला से निकलकर वास्तविक खेत की दिनचर्या में प्रवेश कर रही हैं। जापान में करीब तीन वर्ष के क्षेत्रीय सुधार के बाद अप्रैल 2026 तक चेरी टमाटर रोबोट अकेले प्रतिदिन 31 किलोग्राम फल तोड़ रहा था। फल-सब्जी हार्वेस्टर को व्यावसायिक खेत में स्थायी रूप से लगाकर लगातार चलाने के उदाहरण दुनिया में अब भी दुर्लभ हैं। जापानी स्टार्टअप inaho के सैक टमाटर रोबोट ने खरीद के बजाय सेवा-आधारित किराये का मॉडल अपनाया और खेतों की श्रम जरूरत 45 प्रतिशत से अधिक घटाई। 2026 में केवल पाँच खेतों ने ऐसे किराये के रोबोट आजमाए, लेकिन उसी वर्ष TTA-ISO ने लगभग बिना मानव हस्तक्षेप वाला पूर्ण स्वचालित टमाटर हार्वेस्टर पेश किया और पहली आपूर्ति की तैयारी की। स्ट्रॉबेरी के लिए फल की वास्तविक क्षेत्रीय स्थिति और अभिविन्यास का सार्वजनिक डेटासेट भी आया, जिससे अलग-अलग शोध दल अपने रोबोटों की समान कसौटी पर तुलना कर सकते हैं। प्रतिदिन तय मात्रा खुद भरने वाली मशीनों के ये उदाहरण बताते हैं कि फल-सब्जी कटाई रोबोट प्रयोग की अवस्था पार करके वास्तविक आय और श्रम लागत की गणना में आ गए हैं।

उँगली तकनीक इतनी परिष्कृत होने पर भी मानव हाथ को पूरी तरह बदलने से पहले कई बाधाएँ बची हैं। पत्तियों, शाखाओं और फलों की अनियमित परतों वाले कैनोपी में एक कैमरा हर फल के केंद्र और डंठल की स्थिति नहीं खोज पाता। दृश्य का भाग ढक जाए तो भुजा गलत वस्तु से टकरा सकती है या अदृश्य फल को छोड़ सकती है। अनेक दृष्टिकोणों के पॉइंट क्लाउड जोड़ने और रुकावट के अनुसार स्वतः कोण बदलने वाली सक्रिय इमेजिंग को और सुधारना होगा।

मुलायम उँगलियों की अपनी कठिनाइयाँ हैं। लचीले सिलिकॉन ग्रीपर फल को बचाने में अच्छे हैं, लेकिन हवा भरने-निकालने पर धीरे प्रतिक्रिया देते हैं, भारी फल उठाने की शक्ति सीमित है और लंबे उपयोग में सामग्री खिंच या फट जाती है। परिवर्तनशील कठोरता इस समस्या का उपाय मानी जाती है, जिसमें हाथ सामान्यतः मुलायम रहता है और पकड़ते समय भीतर के कण जुटकर उसे क्षण भर के लिए कठोर बनाते हैं। कॉफी पाउडर से भरी थैली की हवा निकालने पर उसके कठोर होने के सिद्धांत को उँगलियों में उतारने का शोध कई जगह चल रहा है। इस विरोधाभास का समाधान अगले कुछ वर्षों में कटाई रोबोट कंपनियों की स्थिति तय करने वाली कसौटी बन सकता है।

लागत भी बाधा है। सटीक रिड्यूसर, 3D सेंसर और कई मोटरों वाला हार्वेस्टर छोटे खेत के लिए सहज खरीद से बाहर है। खेत और ग्रीनहाउस की धूल, कंपन और नमी में सेंसर जल्दी गंदे होते और पुर्जे बार-बार खराब होते हैं। पूरी इकाई के रूप में बदले जा सकने वाले मानक मॉड्यूल और मौके पर मरम्मत की व्यवस्था बने बिना तकनीक व्यापक नहीं होगी।

अंतिम चुनौती लोगों को यह समझाना है कि रोबोट ने ऐसा निर्णय क्यों लिया। नियंत्रक में चित्र, गहराई और उँगलियों के दबाव संकेत बिना विलंब जोड़ने के साथ स्क्रीन पर यह भी दिखना चाहिए कि रोबोट ने उसी जगह क्यों पकड़ा और उतना ही बल क्यों लगाया। इसे Explainable AI, यानी XAI, कहा जाता है, और इसी व्याख्या से किसान रोबोट के निर्णय पर भरोसा करके पूरा खेत सौंप सकता है। बल नियंत्रण और दृश्य पहचान कितने भी अच्छे हों, निर्णय प्रक्रिया देखने की खिड़की के बिना रोबोट अपरिचित मजदूर ही रहता है।

छह फसलों को साथ रखने पर एंड-इफेक्टर रूपरेखा का विभाजन साफ दिखता है। स्ट्रॉबेरी और टमाटर जैसे नाजुक छिलके और अधिक बाजार मूल्य वाले फलों के लिए वायु-कक्ष और सक्शन पर आधारित कोमल हाथ पहले बने, जबकि संतरे जैसे मोटे छिलके वाले फल के लिए अधिक बल वाले हाथ बाद में आए। खीरा आम है, लेकिन उसकी अनियमित सतह पर सक्शन कठिन है, इसलिए ओरिगामी जैसी अलग संरचनाएँ बाद में विकसित हुईं। मनुष्य जिस काम को उँगलियों के स्पर्श से सहज अलग करता है, रोबोट को देने पर वह हर फसल के लिए पूरी तरह अलग नक्शा बन जाता है।

कुसुम के खेत के ऊपर समानांतर रोबोटिक भुजा नीची रहकर तेजी से आती-जाती है, और उँगलियों के हर स्पर्श पर धागे जैसे पुष्पक का एक गुच्छा गायब हो जाता है। फल पहचानने और बल आँकने की क्षमता होने पर भी गलत क्रम चुनने से भुजा बीती जगह लौटती है और समय खोती है। यह क्रम तय करना रोबोट का मस्तिष्क है, और कुसुम खेत में समस्या सबसे स्पष्ट दिखती है। कुसुम के एक फूल में पच्चीस से इकतीस बारीक पुष्पक घने जुड़े होते हैं, इसलिए रोबोट सामने दिखते लक्ष्य का पीछा नहीं कर सकता और उसे पूरे चक्र का सबसे छोटा मार्ग पहले बनाना पड़ता है। Traveling Salesman Problem, यानी TSP, की न्यूनतम पथ गणना लेकर reinforcement learning से प्रशिक्षित pointer network पुष्पकों के स्थान प्राप्त करता है और पास के लक्ष्य को अधिक भार देकर भ्रमण क्रम तुरंत पुनर्गठित करता है। समानांतर भुजा इस क्रम में सक्शन युक्त उँगलियों से पुष्पक समेटती है तो बिना क्रम के चलने की तुलना में यात्रा दूरी 11.5 से 20.17 प्रतिशत घटती है।

स्ट्रॉबेरी और संतरे में ऊपर देखे पथ सुधार भी ऐसी ही गणना से निकलते हैं। अगली चाल तय करते समय रोबोट कैमरे का फल पर विश्वास, गिरफ का प्रकार और पहुँच कोण का विचलन साथ देखता है। इन मानों को प्रतिगमन विश्लेषण से तैयार सूत्र में डालकर अगली चाल की लागत का अनुमान लगाया जाता है, और उसी अनुमान से A^* वास्तविक पथ खींचता है। कम विश्वास वाली दिशा से बचते और उँगली को नुकसान देने वाले कोण छोड़ते हुए मार्ग को पहले ही इस तरह मोड़ा जाता है कि फल के पास संभवतः 90 डिग्री के सीधे कोण से पहुँचा जाए। मानव का दृष्टि-अनुभव गणना में बदलते ही भुजा का भटकाव स्पष्ट रूप से घटता है।

कैमरे को यह विश्वास मिलने से पहले प्रशिक्षण होता है। मूल चित्रों से सिखाने पर रोबोट केवल साफ दिन में सामने से देखी वस्तु पहचानता है। इसलिए प्रशिक्षण चित्र जानबूझकर बिगाड़े जाते हैं। उन्हें घुमाया जाता है, चमक बढ़ाई-घटाई जाती है और हल्का शोर जोड़ा जाता है, ताकि पत्तियों की छाया और बादल वाले दिन की मंद रोशनी पहले से देखी जा सके। इन बदले चित्रों पर Adam प्रशिक्षण के बाद खेत में अनजान कोण और प्रकाश मिलने पर रोबोट आसानी से नहीं घबराता।

इस मस्तिष्क और हाथ की क्षमता केवल दृष्टि शुद्धता से नहीं मापी जाती। ढीली और कठोर कसौटियों पर अलग गणना करके कैमरे की स्थिरता देखी जाती है, तथा प्रतिगमन से निकला पथ अनुमान वास्तविक पथ से कितना मेल खाता है, इसे determination coefficient और error rate से अलग मापा जाता है। क्षेत्रीय नियंत्रक को एक चित्र का उत्तर देने में लगा समय और प्रति सेकंड संसाधित चित्रों की संख्या भी दर्ज की जाती है। पथ और समय में प्रतिशत बचत को साथ रखने पर अलग रोबोटों की तुलना संभव होती है।

शोधपत्र की संख्या और खेत में महसूस होने वाली संख्या अलग स्तरों की होती है। enclosure ratio में कुछ प्रतिशत वृद्धि या पथ में दस-बीस प्रतिशत कमी समान दशाओं में पुराने तरीके पर सुधार भर दिखाती है। परीक्षण खेत की कतार दूरी और रोशनी पहले से नियंत्रित होती है, लेकिन वास्तविक खेत इतना आज्ञाकारी नहीं होता। दिन में कितने किलोग्राम तोड़े गए और श्रम कितने प्रतिशत घटा, ये आँकड़े रोबोट को असली खेत में कई दिन चलाने के बाद मिलते हैं। अब तक बहुत कम रोबोटों ने दोनों स्तरों के आँकड़े साथ प्रस्तुत किए हैं।

स्ट्रॉबेरी डेटासेट में स्थान के साथ झुकाव की दिशा रखने का कारण है। केवल फल कहाँ है जानना पर्याप्त नहीं, डंठल किस ओर है यह भी चाहिए, ताकि हाथ सीधे कोण से पहुँचे और पेडंकल को बिना क्षति फल तोड़े। ऐसी pose सूचना कई खेतों से एकत्र कर सार्वजनिक करने पर नए शोध दल फिर से चित्र जुटाए बिना सीधे हाथ की रूपरेखा जाँच सकते हैं।

कटाई रोबोट खरीदने के बजाय किराये पर देने का मॉडल भी इन्हीं परिस्थितियों से जुड़ा है। इसका लक्ष्य सटीक रिड्यूसर, 3D स्कैनर और कंप्यूटर सहित पूरी मशीन खरीदने का बोझ घटाना है। मगर रोबोट को नए खेत में रखते ही दशाएँ बदल जाती हैं। ग्रीनहाउस की संरचना, खेती की विधि और रोपण दूरी हर खेत में अलग होने से कैमरा फिर समायोजित और पकड़ बल पुनः मापा जाता है। एक फल बिना क्षति तोड़ना और उसी क्षमता को दूसरे खेत में ले जाना अलग समस्याएँ हैं।

खेत मालिक की नजर से गणना साफ है। श्रमिकों की कमी वाले मौसम में मशीन कुछ दिन किराये पर चलाकर, क्षति दर और दैनिक कटाई स्वीकार्य हों तो अगले मौसम में संख्या बढ़ाई जा सकती है। खरीद से पहले अपने खेत में परीक्षण का रास्ता खुलना उस पुराने दौर से सबसे बड़ा फर्क है, जब एक महँगी मशीन पर एक बार में निर्णय लेना पड़ता था।

इतना प्रशिक्षित मॉडल भी एक समय में केवल एक फसल पहचानता है। टमाटर का पकाव बारीकी से पहचानने वाली आँख स्ट्रॉबेरी खेत में जाकर फिर शून्य से सीखती है। स्ट्रॉबेरी को बचाने वाली उँगली सेब के पेड़ पर भारी फल छोड़ सकती है। मनुष्य खेत बदलते हुए आँख और हाथ स्वयं समायोजित करता है, लेकिन रोबोट को हर फसल बदलने पर दृष्टि फिर सिखानी और उँगली फिर बनानी पड़ती है। कई फसलों में काम

करने वाले वास्तविक मजदूर जैसा बनने के लिए फसल-विशिष्ट आँख और हाथ को जोड़कर भी अलग खेतों में तुरंत काम करने वाली तकनीक चाहिए।

पिछले कुछ वर्षों में आँख और उँगली सुधारना मुख्य चुनौती थी, जबकि अब भ्रमण क्रम स्वयं तय करने वाला मस्तिष्क लगाना, परिणाम समान कसौटी पर मापना और एक फसल व खेत का कौशल दूसरे में ले जाना नई चुनौती है। कुसुम खेत में सिद्ध गणना स्ट्रॉबेरी ग्रीनहाउस या सेब बगीचे में चलेगी या नहीं, इसका उत्तर अगले वर्षों के क्षेत्रीय परीक्षण देंगे। हाथ, आँख और मस्तिष्क अभी अलग-अलग फसलों और खेतों में अलग जाँचे जा रहे हैं, और इन्हें एक रोबोट में एकीकृत करना बाकी है।

स्रोत और संदर्भ

शोधपत्र

1. Feng, K. (2026). फल और सब्जी कटाई के एंड-इफेक्टों के संरचनात्मक रूप और फसल अनुकूलन तंत्र। *Automation and Machine Learning*, 7(2), 60-67. DOI: 10.23977/autml.2026.070207.
2. Zeeshan, S., Malik, M. A. I., et al. (2025). डीप लर्निंग आधारित अनुभूति, ग्रिपर वन्यास और फल आकारमिति से रोबोटिक फल कटाई में डेटा-आधारित प्रक्षेपपथ अनुकूलन। *Engineering Research Express*, 7, 045210.
3. Minorowicz, B., Patalas, A., & Łuczak, A. (2026). मशरूम कटाई के लिए SCARA रोबोटिक भुजा की रूपरेखा। *Acta Mechanica et Automatica*, 20(2), 366-378. DOI: 10.65731/ama/2026-0037.
4. Li, M., Wang, X., Liu, Z., Duan, M., & Jin, Z. (2026). DEMA-3D TSP: कुसुम कटाई रोबोट के अनुक्रम अनुकूलन में DEMA अटेंशन के साथ उन्नत reinforcement learning। *Smart Agriculture*, 8(2), 200-219. DOI: 10.12133/j.smartag.SA202506004.
5. Zhao, L., Lu, X., Wu, Q., Ren, N., Zhou, L., Cheng, Y., Hu, A., & Qi, C. (2026). LAMP चैनल पूरनगि के साथ बेहतर YOLOv10 आधारित टमाटर पकाव पहचान एल्गोरिदम। *Smart Agriculture*, 8(2), 133-146. DOI: 10.12133/j.smartag.SA202507045.
6. Moldvai, L., & Nyéki, A. (2025). टमाटर (*Solanum Lycopersicon*) पहचान और खेती के लिए नवीन कंप्यूटर वजिन वधियाँ: एक समीक्षा। *Discover Applied Sciences*, 7, 975. <https://doi.org/10.1007/s42452-025-07613-x>

व्याख्यान और वीडियो सामग्री

1. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026 वैश्विक कृषि-खाद्य नवाचार रोडशो का शुभारंभ और पहला रोडशो। YouTube. https://www.youtube.com/watch?v=U5CRelR_Rg
2. World AgriFood Innovation Conference (WAFI). (2026). ऑस्ट्रेलिया कृषि-खाद्य नवाचार | WAFI2026 वैश्विक कृषि-खाद्य नवाचार रोडशो। YouTube. <https://www.youtube.com/watch?v=ITnVRq1Tioo>
3. C-DAC. (2025). कृषि में AI: भारत के कृषिपरिदृश्य का रूपांतरण। YouTube. https://www.youtube.com/watch?v=IV3_VnWiBpM
4. Street Science with Fun. (2025). AI/ML आधारित आम पहचान और कटाई मशीन। YouTube. <https://www.youtube.com/watch?v=Dy3xDC8rElw>
5. Department of ECE, MGR Educational and Research Institute. (2025). वशिष्ठज्ज वार्ता: स्मार्ट कृषि के स्वायत्त नेवगेशन में कंप्यूटर वजिन की भूमिका का अवलोकन। YouTube. <https://www.youtube.com/watch?v=GVZ46DY2Tao>
6. UC Agriculture and Natural Resources. (2025). 2026 फार्म रोबोटिक्स चैलेंज - IP 101। YouTube. <https://www.youtube.com/watch?v=JA1greBXSoA>
7. HortiQD. (2026). HortiQD चौथा वेबिनार: डेटा ब्रिज, बेहतर कृषि के लिए किसानों और रोबोटों को जोड़ना। YouTube. <https://www.youtube.com/watch?v=7W8NbMdhuss>

8. Farm Foundation. (2025). Farm Foundation Forum: कृषि के टिकाऊ भवष्य के लिए स्वचालन। YouTube. <https://www.youtube.com/watch?v=aWWqVnNkhoQ>

लेख और ऑनलाइन सामग्री

1. AgFunderNews. (2026). DailyRobotics 2026 में रोबोटिक स्ट्रॉबेरी हार्वेस्टर के साथ कैलिफोर्निया में व्यावसायिक शुरुआत की तैयारी में। AgFunderNews. <https://agfundernews.com/dailyrobotics-gears-up-for-commercial-launch-in-california-in-2026-with-robotic-strawberry-harvester>
2. HortiDaily. (2026). जापानी एगटेक स्टार्टअप ने चेरी टमाटर हार्वेस्टर को नियमित उत्पादन उपयोग में लगाया। HortiDaily. <https://www.hortidaily.com/article/9842754/japanese-agri-tech-startup-puts-cherry-tomato-harvesting-robot-into-routine-production-use/>
3. HortiDaily. (2026). स्नैक टमाटर हार्वेस्टिंग रोबोट व्यावसायिक उपयोग के लिए तैयार। HortiDaily. <https://www.hortidaily.com/article/9778303/harvest-robot-snack-tomato-commercial-ready/>
4. Future Farming. (2026). TTA-ISO ने पूर्ण स्वचालित टमाटर हार्वेस्टर पेश किया। Future Farming. <https://www.futurefarming.com/tech-in-focus/field-robots/tta-iso-introduces-fully-automated-tomato-harvesting-robot/>
5. arXiv. (2026). [स्ट्रॉबेरी कटाई रोबोटों के लिए खेत में मापा गया 6D pose डेटासेट और benchmark model preprint]। arXiv:2606.11381. <https://arxiv.org/pdf/2606.11381>

2.2

स्वायत्त रोबोट मार्ग, ड्रोन दल और सटीक नियंत्रण का अनुकूलन

Hyllo को एक ऑपरेटर द्वारा तीन ड्रोन के समूह की एक साथ निगरानी के तरीके के लिए U.S.

Federal Aviation Administration की मंजूरी मिली। ऑपरेटर ड्रोन सीधे चलाने वाले जॉयस्टिक के बजाय कई विमानों की स्थिति एक साथ दिखाने वाली स्क्रीन हाथ में रखता है। कंपनी का HYL-150 ARES लगभग 50 किलोग्राम भार लेकर प्रति घंटे 20 हेक्टेयर से अधिक क्षेत्र में छिड़काव करता है, जबकि XAG P150 में AI आधारित सेंसर हैं जो बाधाएँ स्वयं पहचानते हैं। कई ड्रोन द्वारा अपने-आप क्षेत्र बाँटकर दिशा और गति मिलाने की इस स्वीकृत व्यवस्था के पीछे मशीनों द्वारा उन मार्गों की गणना है, जो मनुष्य के लिए एक-एक करके बनाना बहुत जटिल है।

यह समस्या रोबोटिक भुजा की उँगलियों से फल को सही पकड़ने की तकनीक से अलग है। हाथ कितना भी कुशल हो, यदि रोबोट कहाँ से शुरू करे और किस क्रम में चले यह तय न कर सके तो वह एक ही कतार दो बार पार करेगा या दूर के लक्ष्य तक भटकते हुए बैटरी खत्म कर देगा। खेत में बिखरे फल, खरपतवार और पुष्पक साफ कतार में नहीं होते। शाखा के पीछे छिपा फल रोबोट के बगल में खिसकते ही अचानक दिख सकता है, और हवा में पत्ती हिलने पर अभी दिखा फल फिर छिप सकता है। डाकिए को एक दिन में बीस घरों तक पहुँचने का सबसे छोटा रास्ता खोजने की समस्या Traveling Salesman Problem कहलाती है, और खेत के रोबोट तथा ड्रोन इसे सपाट तल पर नहीं, ऊँचाई वाले त्रि-आयामी स्थान में हल करते हैं। इसलिए इसे 3D Traveling Salesman Problem, संक्षेप में 3D-TSP, कहते हैं। लक्ष्य पच्चीस या तीस से अधिक होते ही संभावित मार्ग तेजी से बढ़ते हैं, और genetic algorithm जैसी पुरानी खोज विधियाँ बहुत समय लेती या वास्तविक सर्वोत्तम उत्तर से पहले रुक जाती हैं।

इस समस्या को reinforcement learning से पहले भी हल करने के प्रयास हुए थे। भोजन खोजते समय चींटियों के गंध-चिह्नों का अनुसरण करने की आदत पर ant colony algorithm और झुंड में उड़ते पक्षियों पर particle swarm algorithm बनाए गए। कीट या पक्षी समूहों से नियम लेने में तर्क था, लेकिन लक्ष्य बढ़ने और बाधाएँ हर पल बदलने वाले असली खेत में गणना पूरी होने तक रोबोट को लंबे समय खड़ा रहना पड़ता था। पूर्वनिर्धारित नियमों के बजाय अनेक प्रयासों से अपने नियम सीखने वाला reinforcement learning इसलिए आगे आया कि हर खेत और हर मौसम के लिए नियम अलग-अलग लिखना व्यावहारिक नहीं है।

नया समाधान reinforcement learning और pointer network को जोड़ता है। reinforcement learning पहले उत्तर-पुस्तिका नहीं देता, बल्कि अपने प्रयासों के परिणाम को अंक देकर धीरे-धीरे सुधारता है। pointer network नया गंतव्य नहीं बनाता, बल्कि इनपुट में मिले निर्देशांकों में से किसी एक को उँगली से संकेत करने की तरह चुनता है। दोनों का मेल अभिनेता और आलोचक जैसा है। actor नाम

का neural network कलाकार की तरह एक-एक निर्देशांक के भ्रमण क्रम का प्रस्ताव रखता है, और critic नाम का neural network समीक्षक की तरह पूरे प्रस्तावित मार्ग की दक्षता पहले से आँकता है। actor critic के अंक देखकर अगला प्रस्ताव थोड़ा सुधारता है और यह प्रक्रिया हजारों बार दोहराने पर छोटे मार्ग चुनने की प्रवृत्ति विकसित होती है।

निर्णय को परिष्कृत करने के लिए कई उपाय जुड़ते हैं। multi-head self-attention हर निर्देशांक को दूसरे सभी निर्देशांकों से दूरी और दिशा में एक साथ मिलाता है, जबकि distance encoding वास्तविक Euclidean दूरी पहले निकालकर reference data के रूप में देता है। Dynamic Exponential Moving Average, यानी DEMA, हाल के मार्गों को अधिक महत्व देता और पुराने मार्ग धीरे-धीरे भुलाकर निर्णय अद्यतन करता है। चीन में विकसित AC-RL-PtrNet को गुलबहार कुल की फसल कुसुम के हार्वेस्टर पर लगाया गया। यह Long Short-Term Memory, यानी LSTM, से 3D निर्देशांकों का प्रवाह पढ़ता और critic network में layer normalization तथा residual connections जोड़कर प्रशिक्षण स्थिर करता है। गणना घटाने के लिए structural pruning पेड़ की शाखाएँ छाँटने की तरह LSTM gates और fully connected layers के अनावश्यक संबंध हटाता है, जिससे निर्णय शुद्धता अधिक घटाए बिना मॉडल छोटा होता है।

इस मॉडल वाले हार्वेस्टर का चीन के शिनजियांग के वास्तविक कुसुम खेत में परीक्षण हुआ। समानांतर संरचना में कई भुजाएँ पास-पास लगी थीं और एक मार्ग के हिस्से बाँटकर एक साथ संभालती थीं, जिससे काम तेज हुआ। Yuhong No. 1 और Yunhong No.

5 किस्मों वाले खेत में पच्चीस लक्ष्य बिंदुओं की स्थिति जाँची गई। genetic algorithm और इस मॉडल को साथ चलाने पर मार्ग लंबाई 9.56 प्रतिशत और कार्य समय 5.43 प्रतिशत घटा। इकतीस लक्ष्यों वाली अधिक घनी स्थिति में अंतर और बढ़ा, जहाँ मार्ग लंबाई 20.17 प्रतिशत और कार्य समय 29.70 प्रतिशत घटा। लक्ष्य जितने अधिक और उलझे, मानव-निर्धारित क्रम पर सीखे निर्णय का लाभ उतना बड़ा रहा।

पथ अनुकूलन केवल भ्रमण क्रम तय करने पर समाप्त नहीं होता। भूमि समतलीकरण और यात्रा मार्ग की रूपरेखा में Proximal Policy Optimization, यानी PPO, नाम की reinforcement learning तकनीक लगती है। PPO नीति को एक साथ बहुत बदलने के बजाय थोड़ा-थोड़ा बदलता है, जिससे प्रशिक्षण अचानक ध्वस्त नहीं होता। यह यात्रा दूरी और खोदी व हटाई जाने वाली मिट्टी दोनों घटाने वाला मार्ग बना सकता है, इसलिए रोबोट कम चलता और बैटरी अधिक चलती है। भूमि समतल करना और उस पर चलना अलग समस्याएँ लगती हैं, पर दोनों अंततः एक reinforcement learning ढाँचे में हल होती हैं।

सर्वोत्तम मार्ग भी बेकार है यदि रोबोट अपना स्थान ठीक न जानता हो। स्वायत्त जमीनी रोबोट RTK-GPS से, जो base station signal द्वारा satellite navigation की त्रुटि सुधारता है, स्थिति त्रुटि 2 सेंटीमीटर से कम करता है, फिर लेजर प्रकाश लौटने का समय मापने वाला lidar आसपास की भूमि का 3D नक्शा बनाता और RGB-D कैमरा रंग में दूरी सूचना जोड़ता है। पास-पास लगे दो stereo vision कैमरों के दृष्टिकोण अंतर से गहराई निकलती है, जिससे फल या डंठल का स्थान कैमरा निर्देशांक से

रोबोटिक भुजा के निर्देशांक में बदला जा सकता है। ultrasonic distance sensor कतार के अंत पर मुड़ते समय या दृश्य रुकने पर रोबोट को बाधा से टकराने या उलटने से रोकता है।

स्वायत्त रोबोट के भीतर कई अन्य छोटे सेंसर भी लगे होते हैं, जिनकी देखभाल जरूरी है। 12-वोल्ट बैटरी का voltage sensor शेष ऊर्जा वास्तविक समय में बताता है, जबकि solenoid valve controller एक विद्युत संकेत से nozzle खोलने-बंद करने वाला द्वारपाल है। permanent-magnet DC geared motor का encoder पहिए के चक्कर गिनकर वास्तविक चली दूरी निकालता है, और वायु तथा जल दबाव सेंसर spraying system का दबाव तय सीमा में रखते हैं। मार्ग कितना भी सटीक हो, इनमें से एक छोटा सेंसर भी काम न करे तो गणित के अंक पहिए और nozzle की वास्तविक गति नहीं बन सकते।

जमीन पर रेंगते रोबोट की कमी आकाश के ड्रोन पूरी करते हैं। कई दिनों में ड्रोन से ली multispectral तस्वीरों से निकले vegetation indices रोगी पत्तियाँ खोजने में भी लगते हैं, लेकिन यहाँ उनका काम अलग है। पूरे खेत के समान संकेत पढ़कर क्षेत्रवार खरपतवार घनत्व की संभावना दिखाने वाला prescription map बनता है। खरपतवार की वृद्धि के साथ यह नक्शा हर कुछ दिनों में फिर बनाया और अद्यतन रखा जाता है। नक्शा मिलने के बाद ड्रोन वास्तविक उड़ान मार्ग तय करता है।

संदर्भ को संयुक्त रूप से पढ़ने वाला dual-branch convolutional neural network फसल और खरपतवार की सीमा पिक्सेल स्तर पर अलग करता है। सीमा मिलने के बाद AWTPPO नाम का चरण modified Dijkstra algorithm से उम्मीदवार मार्गों में कम ईंधन, बैटरी और रसायन भार वाला मार्ग खोजता है। Dijkstra algorithm मूलतः कई स्टेशनों वाली metro lines में सबसे तेज transfer route खोजने की स्थापित तकनीक है, जबकि यहाँ स्टेशन की जगह खेत के निर्देशांक और transfer time की जगह ईंधन व बैटरी खपत रखी जाती है। बनी प्रणाली ड्रोन को चुने मार्ग पर उड़ाती है और खरपतवार के ऊपर से गुजरते समय ही nozzle खोलती है।

nozzle के आगे लगी अलग आँख खरपतवार समूह का आकार वास्तविक समय में मापती है। खरपतवार क्षेत्र 1.5 वर्ग मीटर से अधिक होने पर VRMDWN नाम का variable-rate microsprayer सक्रिय होता है। वह बूंदों का आकार 100 से 400 माइक्रोमीटर के बीच समायोजित करता है। प्रवाह दर साथ में 0.12 से 0.35 लीटर प्रति मिनट के बीच बदलती है। घने खरपतवार पर मोटी बूंदें और अधिक द्रव, विरल खरपतवार पर महीन बूंदें और कम द्रव गिरता है। छिड़काव पर काम समाप्त नहीं होता और 7, 14 तथा 28 दिन बाद नई तस्वीरें लेकर पुराने पुनर्विकास रिकॉर्ड पर चढ़ाई जाती हैं। इन आँकड़ों से PTWRP चरण Q-learning नाम की reinforcement learning विधि द्वारा खरपतवार के फिर उगने की जगह का अनुमान लगाता है।

खरपतवार फिर कहाँ उगेगा इसकी भविष्यवाणी छिड़काव जितनी दिखाई नहीं देती, लेकिन व्यावहारिक मूल्य बड़ा है। पूर्वानुमान न हो तो उपचार के बाद किसान को हर कुछ दिन पूरे खेत में चलकर फिर उगे खरपतवार देखने पड़ते हैं। PTWRP का prediction map पुनः निरीक्षण वाले क्षेत्र कुछ स्थानों तक सीमित करता है, जिससे अगली drone flight या मानव गश्त का समय बहुत घटता है। फसल संरक्षण एक बार में खत्म होने वाला काम न रहकर बार-बार पूर्वानुमान और जाँच का चक्र बन जाता है।

ड्रोन और जमीनी रोबोट को सही मार्ग खोजने से पहले अलग सेंसरों से अलग तरीकों में मापी स्थिति एक reference frame में मिलानी पड़ती है। satellite navigation का latitude-longitude, lidar और कैमरों के robot-relative coordinates तथा रोबोटिक भुजा के joint coordinates अलग origin और दिशाएँ रखते हैं। coordinate-frame transformation से इन्हें एक खेत नक्शे पर चढ़ाने के बाद ही ड्रोन द्वारा खोजे खरपतवार की जगह जमीनी रोबोट के nozzle खुलने वाली जगह से मिलेगी। यह alignment थोड़ा भी गलत हो तो मेहनत से निकला सर्वोत्तम मार्ग गलत कतार पर बेकार यात्रा बन जाता है।

इस प्रणाली का वास्तविक गेहूँ खेत में परीक्षण हुआ। 12 हेक्टेयर के व्यावसायिक खेत में बीज अंकुरण से बाली निकलने से पहले तक 90 दिन ड्रोन लगातार तस्वीरें लेते रहे। AWTPPO के उड़ान मार्ग ने drone flight time 17.5 मिनट कर दिया, और VRMDWN के targeted spraying ने herbicide use 0.68 लीटर प्रति हेक्टेयर तक घटाया, जो पारंपरिक blanket spraying से 32 प्रतिशत कम था। खरपतवार से बची उपज 18 से 22 प्रतिशत बढ़ी। पूरे खेत में समान मात्रा छिड़कने की तुलना में केवल जरूरत की जगह सही मात्रा देने से herbicide use और उपज दोनों में साफ फर्क दिखा।

कुछ मिनट छोटा मार्ग छोटा आँकड़ा लग सकता है, लेकिन खेत में इसका संचय अलग होता है। रोबोट का दैनिक काम बैटरी क्षमता और दिन की रोशनी से सीमित है, इसलिए हर चक्कर में बचा समय दिन के अंत तक कई अतिरिक्त कतारों के लिए पर्याप्त होता है। एक व्यक्ति दिन में कितने रोबोट और ड्रोन देख सकता है यह इसी अतिरिक्त समय पर निर्भर है, इसलिए छोटा मार्ग समान श्रम से बड़ा खेत संभालने देता है। अचानक मोड़ और एक हिस्से में अनावश्यक दोहरी यात्रा घटने से मनुष्य और रोबोट के साथ काम वाले खेत में टक्कर का जोखिम भी घटता है।

एक ड्रोन के सटीक निर्णयों की असली शक्ति कई ड्रोन के समूह में दिखती है। एक ड्रोन अकेले बड़े खेत को पार करे तो बैटरी खत्म होने से पहले कुछ क्षेत्र छूटते हैं, लेकिन कई ड्रोन क्षेत्र बाँटकर साथ उड़ें तो समान समय में कई गुना जमीन देख सकते हैं। 2026 तक spraying drones कुछ खेतों के विशेष उपकरण से आगे बढ़कर बड़े टैंक और AI वाली मुख्यधारा मशीनें बन रहे थे। Pegasus Robotics का XAG P150 चार rotors की नीचे जाती हवा से रसायन समान फैलाता है और 1.5 से 90 मीटर दूरी पर बाधा स्वयं पहचानता है। Hylio का HYL-150 ARES swarm operation के लिए है, जो करीब 50 किलोग्राम लेकर प्रति घंटे 20 हेक्टेयर से अधिक क्षेत्र में छिड़काव करता है। यह समूह उड़ान संभव है क्योंकि onboard computers हर ड्रोन को संकेत साझा करते हुए multispectral camera, spray tank और satellite-navigation signal मिलाने देते हैं। Hylio को एक operator द्वारा तीन ड्रोन के समूह की निगरानी के लिए U.S.

Federal Aviation Administration की मंजूरी मिली, और इस तरीके से एक व्यक्ति दिन में हजारों acre देख सकता है। क्षेत्र खुद बाँटकर दिशा और गति मिलाने वाले ड्रोन की ऐसी मंजूरी दिखाती है कि एक व्यक्ति की multi-aircraft swarm supervision खेत में पहले से काम कर रही है।

मनुष्य और रोबोट एक ही खेत में अधिक समय साथ काम कर रहे हैं। नीचे उड़कर छिड़काव करते ड्रोन की कतार में मनुष्य हो तो ultrasonic sensor और vision camera उसकी गति पकड़कर drone को

धीमा करते या मार्ग बदलते हैं। एक operator द्वारा कई drone या robot देखने की मौजूदा व्यवस्था में एक screen पर कई मशीनों की स्थिति होती है, और किसी एक की समस्या का संकेत पकड़ना supervisor का नया काम है। मशीनें जितना अपना मार्ग स्वयं चुनती हैं, मानव भूमिका सीधे नियंत्रण करने वाले हाथ से पूरी व्यवस्था देखने वाली आँख बनती दिखती है।

ऊपर-नीचे घने पेड़ों वाले बगीचे में drone से अधिक ground robot उपयोग होते हैं। electric autonomous spraying robot OrcBOT RTK-GPS और stereo camera से अपनी स्थिति तथा पेड़ का आकार पढ़ता है, जबकि YOLOv5 neural network पत्तेदार canopy है या नहीं यह वास्तविक समय में पहचानता है। central electronic control unit इस निर्णय से बाएँ और दाएँ nozzle अलग खोलता-बंद करता और पेड़ न होने पर कुछ नहीं छिड़कता। दूसरी इकाई 10 किलोवोल्ट देकर बूंदों को electrostatic charge देती है, जिससे वे सर्दी में sweater उतारते समय बाल चिपकने वाले सिद्धांत की तरह पत्तियों के पीछे और शाखाओं के भीतर पहुँचकर चिपकती हैं। पारंपरिक sprayer हवा की ओर वाले पत्ते के सामने ही रसायन जमा कर पीछे का भाग छोड़ सकता है, पर charged particles में पत्ते की दिशा चाहे जो हो उसकी ओर खिंचने वाला अतिरिक्त बल होता है।

Türkiye में Ankara University के Faculty of Agriculture के बगीचे में इस रोबोट के वास्तविक परीक्षण के परिणाम उपलब्ध हैं। sprayed droplets का व्यास 150 से 167 माइक्रोमीटर था और वे American Society of Agricultural Engineers के fine-droplet standard ASAE S572.1 पर खरे उतरे। पत्ती की सतह पर रसायन वाले भाग का canopy coverage औसतन 55 प्रतिशत और अधिकतम 57 प्रतिशत था। पारंपरिक tractor sprayer की तुलना में रसायन 49 से 72 प्रतिशत घटा और यह अंतर सांख्यिकीय रूप से संयोग की संभावना से बाहर था। मनुष्य द्वारा tractor चलाकर spraying की लागत 19.70 डॉलर प्रति घंटा थी, जो रोबोट से लगभग 95 प्रतिशत घटकर 0.76 डॉलर प्रति घंटा हुई।

हेक्टेयरों में फैले गेहूँ खेत के खरपतवार और अलग-अलग पेड़ों वाले बगीचे के रोग-कीट को शुरू से अलग spray pattern चाहिए। VRMDWN खेत में बिखरे छोटे खरपतवार समूहों को ही चुनता है और बीच की जगह बिल्कुल खाली छोड़ता है, जबकि OrcBOT को पूरा पेड़ घेरना होता है, इसलिए लक्ष्य बड़ा है और पत्तियों के पीछे भी समान पहुँच चाहिए। खरपतवार नियंत्रण में स्थान पहचानने वाला सही नक्शा निर्णायक है, जबकि पेड़ उपचार में ज्ञात पेड़ के भीतर रसायन कितनी समानता से पहुँचा यह निर्णायक है। बाहर से दोनों autonomous spraying लगते हैं, पर इनके हल करने वाले प्रश्न अलग हैं।

स्वायत्त तकनीक बड़े खेतों के साथ छोटे भूखंडों में भी पहुँच रही है। PIC microcontroller से चलने वाला छोटा रोबोट module बदलकर कई काम करता है। 250 ग्राम seed hopper लगाने पर तय अंतर पर एक-एक बीज की precision hill seeding, 500 मिलीलीटर general-purpose pump nozzle लगाने पर जरूरत की जगह spot spraying, और mild-steel blade लगाने पर पौधों के बीच mechanical weeding करता है। एक battery और microcontroller से तीनों काम करने वाला छोटा रोबोट बड़े कृषि यंत्र न खरीद सकने वाले छोटे खेतों का विकल्प बन रहा है।

खेत में जाने से पहले ये सभी neural networks PyTorch या TensorFlow जैसे platform पर Adam या AdamW optimization से pretrained होते हैं। प्रशिक्षित मॉडल ONNX या TensorRT रूप में NVIDIA Jetson Xavier NX, Jetson Nano, Raspberry Pi 5 या industrial PLC controller जैसे हथेली आकार के device पर डालकर हल्का किया जाता है। पच्चीस से इकतीस लक्ष्य बिंदुओं वाला वास्तविक 3D Traveling Salesman Problem कुछ दर्जन milliseconds में हल होता है, इसलिए रोबोट के गणना की प्रतीक्षा में रुकने का समय लगभग महसूस नहीं होता। drone 5 मीटर प्रति सेकंड की गति से spraying करे तब भी motion planning nozzle खुलने-बंद होने की छोटी देरी पहले से जोड़ती है।

बनी प्रणाली वास्तव में उपयोगी है या नहीं, यह कई कसौटियों से साथ मापा जाता है। पारंपरिक algorithm से route reduction, operating-time reduction, edge device की route-calculation latency और battery व fuel की energy saving रोबोट तथा ड्रोन की गति मापते हैं। प्रति हेक्टेयर घंटा herbicide, canopy coverage, droplet size, फसल-खरपतवार सीमा की misclassification rate, बची उपज और उपचार बाद फिर उगे खरपतवार के अनुमान की recurrence-prediction accuracy कृषि लाभ दिखाते हैं। कैमरा खरपतवार और फसल कितना अलग करता है, इसकी भी कई संख्याओं से जाँच होती है, जिसमें model और वास्तविक खरपतवार क्षेत्र का overlap मापने वाला IoU उसी जगह लगे दो stamps के overlap जैसा है, और कई thresholds की precision का औसत mAP अलग दशाओं में यह stamping दोहराकर औसत निकालने जैसा है। F1 score precision, यानी खरपतवार बताए गए में वास्तविक खरपतवार का अनुपात, और recall, यानी वास्तविक खरपतवार में पकड़े गए का अनुपात, मिलाकर एक ओर झुके निर्णय खोलता है। इन तीन परतों में केवल एक अच्छी हो तो विश्वसनीय field system नहीं बनता, क्योंकि routing, treatment और recognition के तीन पहिए साथ चलने चाहिए।

इन उपलब्धियों के बाद भी कई बाधाएँ हैं। अब तक अधिकतर परिणाम एक विशेष खेत में मिले हैं, इसलिए सीमित हैं। शिनजियांग के कुसुम खेत में सीखा क्रम अलग पेड़ दूरी और भूभाग वाले सेब बगीचे में वैसे ही चले, इसकी गारंटी नहीं है। फसल ऊँचाई, रोपण अंतर और जमीन ढलान बदलने पर सबसे छोटे मार्ग का आकार भी बदलता है, इसलिए कई फसलों और भूभागों के परीक्षण जमा होने पर ही route-optimization model एक खेत के औजार से अनेक खेतों का औजार बनेगा।

मौजूदा 3D Traveling Salesman algorithms और flight-path calculations आम तौर पर समतल या व्यवस्थित खेत मानते हैं, इसलिए तेज ढलान या बाधाओं वाले क्षेत्र में बिना बदलाव नहीं चलते। हवा 4.5 मीटर प्रति सेकंड से अधिक हो या कोहरा, बारिश और घने बादल हों तो multispectral image quality घटती और drone position में करीब 1 मीटर त्रुटि आती है, जिससे गलत खरपतवार पहचान या गलत कतार पर रसायन गिर सकता है। साफ और शांत दिन चुनने की मौजूदा पद्धति में खराब मौसम लंबा रहे तो उपचार का सही समय छूट सकता है। ऐसे दिन मनुष्य को बाहर जाकर आँखों से जाँचकर फसल संरक्षण का समय फिर तय करना पड़ता है।

drone और ground robot की भौतिक सीमा भी बाधा है। परीक्षण drone केवल करीब 22 मिनट उड़ता और लगभग 1.2 लीटर रसायन लेता था, इसलिए बड़े खेत को लगातार देखने में battery बदलने और tank भरने का समय बार-बार लगता है। मनुष्य द्वारा battery और chemical tank बदलने के कुछ मिनट में drone उड़ नहीं सकता और खेत के किनारे पड़ा रहता है। बैटरी बदलने घूमने वाला mobile ground charging equipment और drone व ground robot द्वारा अलग भूमिकाएँ बाँटकर सहयोग करने वाला heterogeneous swarm control अगली चुनौतियाँ हैं। charging infrastructure की लागत जोड़ने पर आरंभिक बोझ बड़े खेत के लिए और भारी होता है। आकाश और जमीन के रोबोट अपने श्रेष्ठ काम बाँटकर उनके बीच handoff स्वतः जोड़ें, तभी तकनीक परीक्षण खेत से कहीं बड़े खेत तक जा सकेगी।

खेत के बीच जटिल गणना करना दूसरी बाधा है। reinforcement-learning route planning और कई काम वाले vision model अधिक computation माँगते हैं और छोटे battery-powered device पर धीमे निर्णय दे सकते हैं। computation घटाने के लिए quantization और pruning तथा NPU या FPGA जैसे dedicated processors पर लगातार शोध हो रहा है। computing resources और accuracy का संतुलन खेत आकार और फसल मूल्य के अनुसार हर किसान के लिए अलग होगा।

अंतिम चुनौती विश्वास है। किसान के पास अभी यह देखने का संतोषजनक तरीका नहीं है कि reinforcement-learning model ने वही मार्ग और केवल वही spray location क्यों चुनी। निर्णय का आधार चित्र में दिखाने वाले Grad-CAM या SHAP जैसे Explainable AI को प्रणाली में रखने पर किसान तय कर सकता है कि रोबोट का चयन मानना है या फिर जाँचना है। उपचार रिकॉर्ड और खरपतवार पुनर्विकास स्थान वर्ष-दर-वर्ष knowledge feedback में जोड़ने से प्रणाली कई वर्षों में धीरे बदलती मिट्टी और खरपतवार ecology तक देख सकती है। ऐसा विश्वास बनने पर ही अंतिम स्वीकृति मनुष्य द्वारा देने वाली मौजूदा semiautonomous व्यवस्था से पूरी autonomous व्यवस्था की ओर बढ़ा जा सकेगा।

इस तकनीक को बड़े खेतों में फैलाने से पहले कुछ और प्रश्न हल करने होंगे। किसान को reinforcement learning के मार्ग और उपचार निर्णय का आधार देखने की व्यवस्था तथा battery या chemical खत्म होने पर काम का अंतराल घटाना अभी बाकी है। कई drone द्वारा संकेत साझा करके क्षेत्र बाँटने वाली swarm flight में संकेत टूटने पर विमान एक-दूसरे की स्थिति खो सकते, मार्ग मिला सकते या टकरा सकते हैं। एक operator द्वारा कई aircraft screen देखने वाली मौजूदा निगरानी की उपयोगिता इस पर निर्भर है कि disconnected aircraft को कितनी जल्दी पहचानकर सुरक्षित रोका जाता है।

स्रोत और संदर्भ

शोधपत्र

1. Adewumi, A., & Saraswat, D. (2026). सटीक खरपतवार नियंत्रण के लिए Artificial Intelligence और Edge Computing की व्यापक समीक्षा। Artificial Intelligence and Applications. <https://doi.org/10.47852/bonviewAIA62028867>

2. Choudhari, A., Katkar, R., Gupta, M., Wathe, N., Kakde, S., & Poyam, P. (2025). drone-based smart farming में autonomous precision weed detection, treatment और recurrence prediction के लिए integrated spatiotemporal deep learning framework की रूपरेखा। International Journal of Applied Mathematics, 38(2s), 1339-1366.
3. CropLife. (2026). 2026 में देखने योग्य 7 agricultural spray drones। CropLife.
<https://www.croplife.com/iron/sprayers/7-agricultural-spray-drones-to-watch-in-2026/>
4. Gerdan Koc, D., Koc, C., & Comakli, M. (2025). सटीक बगीचा अनुप्रयोगों के लिए AI-powered autonomous spraying robot। Journal of Agricultural Engineering, 56(1) / 2026 LVII:1766. <https://doi.org/10.4081/jae.2025.1766>
5. Gundi, A., Kulagod, A., Sunny K, H., & Parashuram, B. (2026). बुवाई, छड़िकाव और नरिई के लिए autonomous agricultural robot। International Journal of Advanced Research in Computer and Communication Engineering (IJARCCE), 15(5), 1308-1311. <https://doi.org/10.17148/IJARCCE.2026.155170>
6. Li, M., Wang, X., Liu, Z., Duan, M., & Jin, Z. (2026). DEMA-3D TSP: कुसुम कटाई रोबोट के अनुक्रम अनुकूलन में DEMA attention के साथ enhanced reinforcement learning। Smart Agriculture, 8(2), 200-219.
<https://doi.org/10.12133/j.smartag.SA202506004>
7. Logeshwaran, J., et al. (2026). Vision AI के साथ सटीक कृषि के लिए embedded drone swarm। International Journal of Computer Applications, 187(115), 42-43.
8. The Robot Report. (2026). Drone swarms वास्तव में कैसे काम करते हैं और कनि उद्योगों को ध्यान देना चाहिए। The Robot Report.
<https://www.therobotreport.com/drone-swarms-how-they-actually-work-and-what-industries-should-care/>

व्याख्यान और वीडियो सामग्री

1. Food and Agriculture Organization (FAO). (2025). Digital FAO और Agro-Informatics के साथ दुनिया की यात्रा, Sydney। YouTube. <https://www.youtube.com/watch?v=tbFEk73816U>
2. PhD Navigator. (2025). ICT research में sampling techniques | कृषि के लिए energy-optimised field robot। YouTube.
https://www.youtube.com/watch?v=jJerj_N7ALQ
3. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026 Global Agrifood Innovation Roadshow launch event और inaugural roadshow। YouTube. https://www.youtube.com/watch?v=U5CRelR_Rrg
4. 茶柱. (2026). 20260120 चाय बागान की smart agriculture, Kawasaki Giken, Ochiai Cutlery और Terada Seisakusho। YouTube. <https://www.youtube.com/watch?v=zmFbOC5RcJU>
5. 臉書李載榮. (2025). A88 नज़ी Institute for Information Industry satellite precision agriculture AI adoption workshop, Taoyuan: AI satellite multispectral imagery और drone applications। YouTube.
<https://www.youtube.com/watch?v=dtT3bafdKgw>
6. Trimble Geospatial. (2026). eCognition webinar: Deep Learning, UAVs और Precision Agriculture। YouTube.
<https://www.youtube.com/watch?v=alrseDYV8Lo>
7. Society of Precision Agriculture Australia SPAA. (2025). Grain Automate national webinar: खेत की autonomy का मार्ग। YouTube. <https://www.youtube.com/watch?v=nZnsWgvs6-g>
8. Agri Coaching Chandigarh. (2026). Digital Agriculture Mission 2026 | AI, Drones, Agri Stack और Smart Farming | Current Affairs। YouTube. <https://www.youtube.com/watch?v=al2rsTZBwMA>

अध्याय 3

स्मार्ट ग्रीनहाउस और नियंत्रित वातावरण कृषि (CEA) का पर्यावरण नियंत्रण

3.1

IoT-आधारित बहु-सेंसर निगरानी और बुद्धिमान पर्यावरण मापन

दुनिया के 70 देशों में लगाए गए कम ऊर्जा वाले LoRaWAN Internet of Things उपकरणों की संख्या 125 मिलियन से अधिक हो चुकी है और संबंधित बाजार 2026 में 14.25 बिलियन अमेरिकी डॉलर का आँका गया है। अमेरिका के University of Nebraska की शोध टीम ने report किया कि केवल real-time soil moisture monitoring से पानी का उपयोग 35 प्रतिशत तक घटा। greenhouse के भीतर भी उतने ही सघन मापन की आवश्यकता है। plastic greenhouse में floor level और आँख की ऊँचाई के temperature में 3 या 4 degree का अंतर हो सकता है, जबकि roof के पास गर्म हवा की अलग परत बनती है। greenhouse के खंभे पर लगे हथेली भर white box में temperature और humidity value हर कुछ second में नए होते हैं, और यही value तय करते हैं कि उस रात ventilation opening खुलेगा, heater चलेगा या irrigation system चालू होगा।

greenhouse में केवल air temperature का प्रबंधन नहीं करना पड़ता। air temperature और relative humidity, carbon dioxide concentration, sunlight की मात्रा, जहाँ photosynthesis में वास्तव में उपयोग होने वाले wavelength के light का माप Photosynthetic Photon Flux Density कहलाता है, hydroponics में nutrient solution की Electrical Conductivity और hydrogen ion concentration, soil या substrate में बची moisture, water tank का temperature और storage facility में ethylene gas तक साथ बदलते हैं। ये value स्वतंत्र रूप से नहीं चलते। temperature घटाने के लिए opening खोलने पर humidity और carbon dioxide भी साथ बाहर निकलते हैं, जबकि heater चलाने से केवल temperature नहीं बढ़ता बल्कि relative humidity तेजी से गिरती है। अधिक पानी देने से substrate moisture बढ़ती है, पर जड़ों के आसपास air humidity भी बढ़ सकती है और mold के अनुकूल परिस्थिति बन सकती है। इसलिए greenhouse microclimate, यानी छोटे बंद स्थान की climate, को एक-एक variable नियंत्रित करने वाले अलग switch के समूह की तरह नहीं, बल्कि ऐसे nonlinear और time-varying coupled system के रूप में देखना चाहिए जिसमें अनेक variable लगातार एक-दूसरे को खींचते और धकेलते हैं।

यह संतुलन टूटते ही नुकसान आँखों के सामने आ जाता है। उपयुक्त temperature range से केवल कुछ दिन बाहर रहने पर stem बहुत लंबा बढ़ सकता है या flower bud गिर सकते हैं, और रात भर high humidity रहने पर पत्ती के नीचे water droplet बनकर fungus तथा powdery mildew pathogen के बढ़ने की अनुकूल दशा बनाते हैं। एक बार fruit set विफल होना या disease outbreak पूरे season की yield घटा सकता है। इसलिए farmer की intuition और experience पर्याप्त नहीं हैं, बल्कि greenhouse में सघन लगाए Internet of Things (IoT) sensor और उनके value पढ़कर

real time में निर्णय लेने वाली artificial intelligence calculation साथ चाहिए। sensor आँख और त्वचा हैं तो पीछे की calculation हर क्षण की स्थिति तौलकर अगला action चुनने वाला judgment है।

समस्या यह है कि greenhouse में केवल एक sensor हो तो यह judgment सही काम नहीं कर सकता। ventilation fan के ठीक सामने और opposite corner में airflow speed अलग होती है, जबकि dense crop canopy के ऊपर और उसके नीचे shade में temperature कई degree अलग हो सकता है। greenhouse wall के पास का किनारा और center भी अलग weather झेलते हैं। एक sensor के representative reading को पूरे greenhouse का value मानकर heating या ventilation तय करने पर उससे दूर zone unattended रह सकते हैं और पौधे लंबे या मुरझाए हो सकते हैं। इस spatial nonuniformity को संभालना greenhouse instrumentation design की मुख्य समस्या है।

greenhouse में वास्तव में जाने वाले sensor की सूची काफी लंबी है। air side पर DHT11 और DHT22 temperature-humidity sensor minus 40 से 80 degree temperature तथा 0 से 100 प्रतिशत relative humidity मापते हैं और उनके साथ WQX-TH temperature-humidity sensor रहता है। water tank में DS18B20 water-temperature sensor होता है, WQX-L light sensor 0 से 157,286 lux तक light मापता है और WQX-R तथा UV sensor 0 से 2,000 watt per square meter ultraviolet radiation मापते हैं। FC-28 या YL-69 moisture sensor soil या substrate में बचा पानी मापते हैं, और air carbon dioxide concentration को gas द्वारा infrared light absorption के स्तर से मापने वाला nondispersive infrared (NDIR) sensor संभालता है। hydroponic nutrient solution में Electrical Conductivity (EC) और hydrogen ion concentration (pH) दोनों मापने वाला sensor डाला जाता है, जबकि harvested produce की cold-chain distribution में fruit द्वारा छोड़ी ethylene gas के लिए अलग sensor लगाया जाता है। एक sensor की कीमत केवल कुछ हजार से कुछ दसियों हजार won है, पर साथ मिलकर वे greenhouse की हर साँस पढ़ने वाला जाल बनते हैं।

बिजली कैसे मिलेगी, यह sensor node की life तय करने वाला दूसरा प्रश्न है। greenhouse roof या substrate के पास जहाँ नया power outlet खींचना कठिन है, वहाँ छोटे solar panel और storage battery वाला node आम है, जिसका circuit सामान्यतः सोता है और तय समय पर थोड़ी देर जागकर reading लेने के बाद फिर सो जाता है, इसलिए एक charge पर कई महीने चलता है। irrigation pump और ventilation fan जैसे physical work करने वाले actuator शुरुआत से commercial power से जुड़े रहते हैं, जबकि पास के sensor node अलग low-power battery पर चलते हैं। transmission की ऊर्जा तक बचाने के लिए हर माप के बाद भेजने के बजाय reading को तय समय तक जमा करके साथ भेजा जाता है, लेकिन यह trade-off गलत हो तो battery अपेक्षा से जल्दी खत्म होती है और sensor ठीक decision के समय बंद पड़ सकता है।

greenhouse के बाहर भी आँख चाहिए। JNGW100 weather station और WQX spectral sensor बाहर लगाने पर वे outdoor air temperature और humidity, dew point तथा solar

irradiance 1-minute interval में दे सकते हैं। Japan के agricultural research organization का grid agricultural weather data, WeatherAPI, अमेरिकी अंतरिक्ष एजेंसी का NASA POWER, संयुक्त राष्ट्र Food and Agriculture Organization का FAO CLIMWAT और अन्य foreign open dataset real time में लिए जाते हैं, फिर आने वाले कुछ दिनों के forecast value control model में डाले जाते हैं। केवल greenhouse के अंदर के sensor आने वाली cold wave या heat wave की advance warning नहीं दे सकते, इसलिए outdoor weather data को indoor sensor reading के साथ रखना मानक प्रक्रिया बन रहा है। opening बंद करने का समय एक घंटे पहले जानना भी crop के जीवन और मृत्यु का अंतर बना सकता है, जबकि value बढ़ने के बाद जानना बहुत देर हो सकती है।

सारी संख्या air से नहीं आती। speaking plant approach कहलाने वाली विधि crop द्वारा दिए signal पढ़ती है। greenhouse में आने और जाने वाली air की carbon dioxide concentration का अंतर airflow rate से गुणा करके हर 5 minute पर गणना की जा सकती है कि पूरी crop canopy photosynthesis से कितना carbon dioxide लेती और रात में respiration से कितना छोड़ती है। उसी तरह water-vapor concentration के अंतर को airflow rate से गुणा करके बिना एक भी पत्ती छुए अनुमान लगाया जा सकता है कि पत्तियों से कितना पानी निकला और पत्ती surface के छोटे pore, यानी stomata, कितने खुले हैं। thermometer कमरे की air मापने का tool है तो यह विधि crop को ही जीवित measurement instrument बना देती है।

sensor reading कई layers से होकर जाती है। field की front line पर STM32 या ESP32, Wi-Fi वाला ESP8266 module, अथवा Arduino Uno और Arduino Nano का वह संयोजन रहता है जिसमें दो device काम बाँटते हैं। Arduino Uno sensor value जुटाकर actuator सीधे चलाता है, जबकि पास का Arduino Nano web server से communication और display पर graph बनाता है, इसलिए एक side रुकने पर दूसरी चल सकती है। greenhouse के nodes RS485 wired method या ZigBee wireless sensor network पर value बाँटते हैं, और central server या cloud तक भेजने के लिए 4G DTU, GPRS, LPWAN तथा Wi-Fi network क्रम से प्रयोग होते हैं। फलस्वरूप greenhouse का छोटा display, office computer और farmer का mobile app उसी समय समान संख्या पाते हैं।

industry में लंबे समय से proven RS485 wiring moisture या electromagnetic interference से प्रभावित हुए बिना reading विश्वसनीय रूप से ले जाती है, पर greenhouse layout बदलने पर cable फिर बिछानी पड़ती है। ZigBee जैसे wireless sensor network wiring नहीं माँगते और बार-बार cultivation method बदलने वाले greenhouse के लिए उपयुक्त हैं, लेकिन steel frame और water tank जैसे radio wave रोकने वाले obstacle से reading टूट सकती है या देर से आ सकती है। इसलिए field में किसी एक method को standard बनाने के बजाय दोनों मिलते हैं, जहाँ core section wired और बार-बार बदलने वाले section wireless connection से supplement होते हैं।

इनमें LPWAN का low-power long-range network LoRaWAN कुछ वर्षों में laboratory technology से industrial-scale infrastructure बन गया है। वर्ष 2026 तक global LoRaWAN IoT market 14.25 बिलियन अमेरिकी डॉलर आँका गया है और 2035 तक प्रति वर्ष 34.7 प्रतिशत बढ़ने का अनुमान है। 70 देशों में 125 मिलियन से अधिक LoRaWAN device पहले से लगाए जा चुके हैं। एक battery पर वर्षों चलकर कई kilometer दूर reading भेज सकने के कारण sensor अब plastic greenhouse या खुले खेत के उस कोने में भी लगाया जा सकता है जहाँ नई electrical wiring कठिन है।

वर्ष 2026 की प्रमुख प्रवृत्ति calculation को cloud से site के communication relay device, यानी gateway, में ले जाना है। हर sensor reading दूर server को भेजकर answer की प्रतीक्षा करने के बजाय lightweight artificial intelligence model gateway में रखा जाता है, ताकि वह तुरंत decision दे। इससे server तक आने-जाने का समय और communication cost दोनों घटते हैं। अमेरिका की University of Nebraska के experiment में इस विधि से real-time soil-moisture monitoring ने water use 35 प्रतिशत तक घटाया। sensor reading लेने पर नहीं रुकता, बल्कि उसे सीधे decision में बदलता है।

फिर भी greenhouse के हर कोने में महँगा sensor लगाना व्यावहारिक नहीं है। इसका एक विकल्प केवल थोड़े sensor लगाकर calculation से पूरे greenhouse का three-dimensional climate map बनाना है। Computational Fluid Dynamics (CFD) वह simulation technique है जो computer में दोहराती है कि greenhouse के भीतर air और gas वास्तव में कैसे बहते और मिलते हैं, मानो weather map को greenhouse के बंद स्थान में ले आया गया हो। इसे image पढ़ने वाले Convolutional Neural Network (CNN), समय के बदलाव का अनुसरण करने वाले Temporal Convolutional Network (TCN) और candidate value में optimum खोजने वाले Particle Swarm Optimization (PSO) को जोड़ने वाले DeepCFD-OptNet जैसे machine learning model, अथवा Random Forest, Support Vector Regression (SVR) तथा Deep Neural Network (DNN) के साथ चलाने पर केवल कुछ sensor value से greenhouse के हर कोने में temperature और carbon dioxide distribution का यथार्थसंगत पुनर्निर्माण हो सकता है। map update करने के लिए यह reconstruction प्रायः हर कुछ minute में फिर calculate होता है, इसलिए sensor रहित zone में भी नवीनतम स्थिति के निकट value निकाला जा सकता है। calculation sensor placement cost और measurement precision की खींचतान का gap भरती है।

एक ही value को जानबूझकर दो या तीन बार मापने वाला redundant design measurement precision बचाने का दूसरा तरीका है। केवल एक temperature sensor पर निर्भर system में उसके खराब होते ही पूरा greenhouse आँख बंद करके चलता है, लेकिन समान zone में थोड़ा अलग performance वाले दो या तीन sensor overlap करें तो reading की तुलना से पता चल सकता है कि कौन failure के निकट है। कई inexpensive sensor का overlap एक expensive sensor से अधिक failure-resistant होता है, इसलिए greenhouse size और budget के अनुसार किस value को

कितनी overlapping layer में मापना है, यह designer को तय करना पड़ता है। ऐसी overlapping reading होने पर ही आगे बताया adaptive Kalman filter सही भूमिका निभा सकता है।

reading हमेशा समय पर नहीं आती। थोड़ी देर communication कटने या sensor खराब होने पर data gap बनता है। gap छोटा और 10 step से अधिक न हो तो forward-backward linear interpolation interruption से पहले की अंतिम reading और connection लौटने के बाद की पहली reading के बीच straight line खींचकर खाली जगह भरता है। gap 10 step से अधिक हो तो केवल यह method मजबूर हो जाती है, इसलिए Dynamic Time Warping (DTW) historical record में current pattern जैसा change flow खोजकर उसे blank में लाता है। तरीका diary का एक दिन छूटने पर पिछले वर्ष उसी season और समान weather वाले दिन की entry देखकर blank page भरने जैसा है।

gap भरने से अलग received value के अचानक उछलने या बदलने की समस्या भी है। humid और dusty greenhouse में sensor कभी-कभी क्षणिक निरर्थक value देता है। self-adaptive Kalman filter इसे smooth करता है। Kalman filter sensor की अभी मिली कुछ erratic value और पिछले trend से अनुमानित expected value को weight देकर दोनों के बीच के किसी point पर धीरे converging करता है, और इसका सिद्धांत satellite signal डगमगाने पर भी vehicle की पिछली speed तथा direction देखकर position स्थिर करने वाली navigation calculation जैसा है। इसे adaptive इसलिए कहते हैं कि filter स्वयं तय करता है किस sensor पर कितना भरोसा करना है। नई reading और expected value का अंतर जितना बड़ा होगा, उस sensor का weight उतना घटेगा और दूसरे sensor को अधिक weight मिलेगा, जिससे moisture या dust से क्षणिक गड़बड़ी वाला एक sensor पूरे decision को नहीं हिलाता।

उत्तर-पश्चिम China के Ningxia स्थित Hengsheng Seedling Base का सामान्य double-film solar greenhouse वह field site था जहाँ इस filter का practical test हुआ। greenhouse में WQX-TH, WQX-L और WQX-R spectral sensor के चार set फैलाए गए और बाहर अलग weather station लगाया गया। अलग sensor स्थानों से एक साथ आने वाली reading को adaptive Kalman filter से पहले smooth करने के बाद temperature-humidity forecast और heating तथा ventilation equipment खोलने या बंद करने के automatic decision बहुत अधिक स्थिर हुए। measurement stage पर noise न हटे तो data पर रखा कितना भी sophisticated decision logic foundation से अस्थिर रहेगा।

smooth reading की unit अलग होने से उसे calculation में सीधे नहीं दिया जा सकता। temperature degree Celsius, humidity percent, light lux, carbon dioxide ppm और acidity pH में मापे जाते हैं, और हर scale अलग है। min-max normalization scale को smallest और largest value के बीच 0 से 1 में बदलकर इन्हें साथ रखकर तुलना योग्य बनाता है। यह कई देशों की currency को एक common reference currency में बदलने के बाद goods price की तुलना करने जैसा है। प्रक्रिया पूरी होने पर ही data machine learning pipeline का input बनता है।

value smooth और scale aligned होने के बाद उसे physical movement में बदलने की बारी आती है। काम site पर NodeMCU ESP8266 या Raspberry Pi, local Qt display वाले control terminal और कभी-कभी cloud server के बीच बाँटा जाता है, तथा reading आने से decision तक अधिकतम कुछ second लगते हैं और कभी इससे भी कम। decision के बाद command relay module से irrigation pump, ventilation fan, shade screen, carbon dioxide supplementation system, misting nozzle और supplemental LED lighting तक सीधे जाता है। sensor box की green light से शुरू संख्या कुछ second बाद greenhouse के दूसरे सिरे का fan घुमाती है।

stored और displayed होने पर measured value का दूसरा उपयोग बनता है। gateway से गुजरने वाला data time-series database में क्रम से जमा होता है और farmer web या mobile phone screen पर पिछले दिन या सप्ताह का temperature-humidity graph देख सकता है। value predefined danger threshold पार करे तो text message या app notification तुरंत warning देता है, जिससे farmer cold wave या power failure जैसी अचानक स्थिति पर पूरी रात greenhouse में रहे बिना response कर सकता है। long-term record बाद में yield या disease occurrence से तुलना का data बनता है, और certification या traceability माँगने वाले produce के लिए cultivation process का evidence भी हो सकता है।

Indonesia के Sandi Buana Farm और Purwosari के दो commercial hydroponic lettuce greenhouse यह पूरा flow दिखाते हैं। DHT11 temperature-humidity sensor, DS18B20 water-temperature sensor, FC-28 soil-moisture sensor तथा pH और EC nutrient-solution sensor लगाए गए, उनकी reading NodeMCU ESP8266 gateway से इकट्ठी होकर cloud database तक गई। चार महीनों में 15,492 reading जमा हुई और बाद में yield पहले से बताने तथा environment automatic adjust करने वाले decision system की raw material बनीं। मामला दिखाता है कि थोड़े sensor और inexpensive Wi-Fi module से भी commercial greenhouse scale का data foundation बनाया जा सकता है।

Kangwon National University का 300-square-meter winter greenhouse भी समान configuration रखता है। pellet boiler, heat-storage tank और tube-rail heating system वाला greenhouse JNGW100 outdoor weather device तथा GL840 logger से interior में फैले thermocouple sensor की हर minute reading बिना छूट दर्ज करता है। ऐसे densely accumulated record से ही predictive heating संभव होती है, जिसमें severe cold wave आने से कई घंटे पहले heat-storage tank का water preheat किया जाता है। measurement interval को 1 minute तक घटाना स्वयं वह foundation है जो sophisticated decision logic रखने से पहले बनाना पड़ता है।

Japan के Aichi Prefecture के agricultural innovation project में smart mist-control test दिखाता है कि एक sensor जुड़ने पर क्या बदलता है। केवल greenhouse temperature और

humidity देखने के बजाय system outdoor solar radiation, यानी sunlight intensity, भी पढ़ता है और value साथ लेकर real time में Vapor Pressure Deficit (VPD) निकालता है, जो air की thirst को एक संख्या में दिखाता है। sunlight अचानक तेज होकर यह number बढ़ाए तो system छोटे burst में उतना mist देता है कि पत्ती गीली न हो और plant stress घटे, जबकि farmer smartphone app पर पूरा trend देखता है। temperature और humidity जैसे अलग value जोड़कर नई संख्या बनाना practical intelligent measurement की निकट तस्वीर है।

Taiwan के Kaohsiung में बड़े multitier cultivation rack और vertical farm दिखाते हैं कि sensor network को layer-wise रखने पर और क्या दिखाई देता है। अनेक level के shelf पर orchid और hydroponic vegetable उगाने वाले farm हर compartment में अलग temperature, humidity, pH और moisture sensor लगाकर reading को central field control box तथा cloud monitoring display में जुटाते हैं। upper और lower compartment को light तथा ventilation अलग मिलने से पूरे greenhouse को एक space मानने वाला measurement scheme level के अनुसार subdivide हुआ है। electricity और water consumption भी मापकर carbon emission display पर बनाया जाता है, जिससे sensor crop condition के साथ पूरे farm operation की efficiency दिखाने वाला dashboard बनता है।

अच्छी तरह design किए system में भी weak link रहते हैं। greenhouse में relative humidity बार-बार 90 प्रतिशत से ऊपर हो, pesticide application के साथ corrosive gas फैले और dust तथा water droplet चिपकें तो sensor sensitivity समय के साथ धीरे घटती है। इस phenomenon को drift कहते हैं, जिसमें greenhouse का वास्तविक temperature समान रहता है पर केवल sensor की संख्या धीरे-धीरे alignment से बाहर जाती है। इसे रोकने के लिए कई sensor reading की तुलना कर manual adjustment के बिना scale सुधारने वाला self-calibrating software और water तथा dust को रोकने वाला durable nanomaterial-coated sensor विकसित हो रहा है।

regular calibration भी आवश्यक प्रक्रिया है। नया sensor पहली बार लगाते समय manufacturer reference reading को actual field value से मिलाने वाला initial calibration होता है, फिर हर कुछ महीने में पहले से ज्ञात standard solution या standard light source से तुलना करके scale दोबारा adjust किया जाता है। humidity sensor के लिए सामान्य तरीका उसे स्थिर humidity रखने वाले salt solution जैसे saturated solution में थोड़ी देर रखकर उस reading को reference बनाना है। हर बार मनुष्य के greenhouse में घूमकर यह laborious procedure दोहराने के बजाय sensor reading की तुलना कर out-of-alignment sensor खोजने वाला software calibration धीरे-धीरे कुछ काम सँभाल रहा है।

space को कैसे बाँटकर sensor लगाए जाएँ, यह अभी हल होने वाला प्रश्न है। greenhouse जितना बड़ा होगा, ventilation fan के सामने और center तथा crop canopy के upper और lower हिस्से में climate difference उतना बड़ा होगा, लेकिन समान interval के regular grid में sensor लगाने पर वही area छूट सकता है जहाँ temperature difference सबसे अधिक है। greenhouse को zone में

बाँटकर अलग density में sensor रखने वाला stratified sampling और CFD-based reconstruction इसका alternative है। कितने sensor कहाँ लगाने हैं, इसका decision किस प्रकार का sensor चुनना है, उतना ही महत्वपूर्ण होता जा रहा है।

अलग manufacturer के sensor को Programmable Logic Controller (PLC) और दूसरे controller से जोड़ने पर अलग communication language के कारण reading misaligned या connection पूरी तरह fail हो सकता है। हर बार farm में नई machinery आने पर existing equipment से compatibility जाँचने का burden भी यहीं से आता है। इसे हल करने के लिए industry में व्यापक standard communication protocol OPC UA, Japan का agricultural data-sharing platform WAGRI और IoT को agriculture के लिए adapt करने वाला IoP cloud जैसे common standard आकार ले रहे हैं। protocol standardization के साथ ऐसा easy interface और control बनाना भी समानांतर कार्य है जिसे engineering training न पाए farmer कुछ दिनों में सीख सके।

field में artificial intelligence calculation की वास्तविक कठिनाइयाँ test accuracy से पूरी नहीं दिखतीं। actuator को command मिलने और वास्तव में चलने के बीच स्पष्ट delay होता है, जबकि wind और vibration जैसे physical factor unexpected moment पर हस्तक्षेप करते हैं। थोड़ी देर communication टूटे तो gateway cloud के answer की अनंत प्रतीक्षा नहीं कर सकता, इसलिए कम से कम minimal decision logic site पर रहना चाहिए। inexpensive microcontroller पर भी ऐसे decision बिना चूके चलाना अगला उद्देश्य है।

calculation gateway में जाने की प्रवृत्ति स्थापित होने पर वहाँ का artificial intelligence model स्वयं छोटा और हल्का होना चाहिए। number को 8 bit में घटाकर computational load कम करने वाली Quantization और बड़े model का knowledge छोटे model में पहुँचाने वाली Knowledge Distillation जैसी technique समाधान के रूप में सुधारी जा रही हैं। sensor selection, power supply, communication network, missing reading भरना, noise filter करना और scale align करना अलग-अलग छोटे काम लग सकते हैं, लेकिन एक भी छोटे तो उनके ऊपर के हर decision में instability आती है। greenhouse post के sensor box की reading gap भरने, noise हटाने और scale align होने के बाद ही कुछ second में fan, pump और light चलाने वाला decision बनती है।

white box का sensor सही value पढ़ रहा है या नहीं, यह अलग प्रश्न है। farmer के हाथ की छोटी bottles में pH 4, 7 और 10 पर precisely adjusted clear liquid है, और sensor tip को एक-एक bottle में डालकर display number को standard value से मिलाना verification तथा calibration है। Electrical Conductivity sensor भी known conductivity वाले standard solution में डुबोकर scale reset किया जाता है। काम एक calibration पर समाप्त नहीं होता, बल्कि season बदलने पर और कम से कम हर कुछ महीने में दोहराना पड़ता है। छह महीने या एक वर्ष verification तथा calibration बिना बीत जाए तो sensor संख्या देता रहता है, पर उन संख्या और जिस actual value को वे दिखाती हैं, उनका अंतर धीरे बढ़ता है। इसलिए farm अलग calibration log

रखता है जिसमें दर्ज होता है कि कब किस sensor को किस standard value से adjust किया गया, और इसी record से बाद में तय होता है कि किस period का data भरोसे योग्य और किस पर संदेह करना है।

कई sensor overlap हों तो किसकी बात मानी जाए, इसके नियम भी चाहिए। समान zone में तीन temperature sensor साथ रखें तो उनमें से दो लगभग 24 degree Celsius दिखा सकते हैं। शेष अकेला 31 degree दिखाए तो majority वाले दो reading स्वीकार होते हैं और अलग sensor watch list में जाता है। 10 second में temperature 5 degree से अधिक उछलने जैसी वास्तविकता में कठिन change भी इसी तरह filter होती है। flagged sensor तुरंत हटाया नहीं जाता, बल्कि कुछ दिन और देखकर same discrepancy दोहरने पर failure confirm होता है। एक spike dust particle गुजरने की chance event हो सकता है, लेकिन recurring divergence को sensor की अपनी problem मानना चाहिए।

interpolation से भरे value को flag करना जरूरी है। straight line से जुड़े या similar historical pattern से लाए number sensor की वास्तविक reading नहीं, calculation से inferred value हैं। flag न हो तो कई महीने बाद environment record को yield से मिलाते समय inferred और measured number मिश्रित होकर conclusion को गलत दिशा में ले जा सकते हैं। कठिन मामला वह है जहाँ communication outage नहीं बल्कि frozen pipe या stopped pump जैसी वास्तविक failure हो, पर interpolation blank को smooth number से भरकर problem छिपा दे। इसलिए gap तय अवधि से अधिक चले तो interpolation के साथ separate onsite inspection alert देना चाहिए, ताकि calculation समस्या को चुपचाप न छिपाए।

communication network design में wiring की मात्रा जितनी महत्वपूर्ण है, signal loss सहने का तरीका भी उतना ही है। wireless sensor node gateway connection खोए तो reading मिटने देने के बजाय built-in memory में temporarily रखता है और connection लौटने पर backlog साथ upload करता है। node एक-दूसरे का signal relay करने वाली mesh arrangement बनाएँ तो steel post radio wave रोके तब भी neighboring node का detour उपलब्ध रहता है। wired section को detour नहीं चाहिए, पर cable टूटे तो alternative नहीं होता, इसलिए critical trunk cable के साथ spare line बिछाकर duplication किया जाता है।

farmer की screen केवल संख्या की कतार लगाए तो उपयोगी नहीं है। normal range को green, attention वाला yellow और immediate action वाला red करने पर greenhouse state एक नज़र में समझी जा सकती है। problem यह है कि alarm बहुत बार बजे तो farmer महत्वपूर्ण क्षण की notification भी ignore कर सकता है। इसलिए threshold level में बाँटे जाते हैं, जहाँ small fluctuation screen पर quietly दिखता है और phone notification तभी जाती है जब कई value साथ danger range में जाएँ या वही warning तय समय से अधिक रहे। कुछ site पर first notification का response न मिले तो delay के बाद phone call करके escalation होता है।

screen के corner में एक घंटे और एक दिन आगे के predicted value current reading के साथ बनते हैं, जिससे farmer संख्या बढ़ने से पहले action ले सकता है।

ये सभी device केवल बड़े और पर्याप्त budget वाले farm पर इस्तेमाल हों तो उपलब्धि आधी है। sensor, gateway और software subscription की combined cost आसानी से उस स्तर पर पहुँचती है जहाँ small farm निवेश से हिचकता है, और equipment लगने के बाद rural area में failure repair करने वाला technician खोजना भी कठिन हो सकता है। pump और vent को remotely चलाना सुविधाजनक है, पर unauthorized external access तथा manipulation का risk भी रखता है। midwinter में कोई system में घुसकर vent खोल दे तो पूरा greenhouse कुछ घंटों में freeze हो सकता है। वर्षों का environment और growth record value बनाने वाले farmer के पास न रहकर equipment vendor के server में locked हो सकता है, और farm दूसरी company का equipment लेते ही पूरा record टूट सकता है। equipment acquisition cost, maintenance personnel, remote-control security और data portability इस technology की शेष समस्याएँ हैं।

स्रोत और संदर्भ

शोध पत्र

1. Arfiyani, S. A., Wardihani, E. D., & Helmy. (2026). Smart Greenhouse Data Integration Using Machine Learning Approaches. Jurnal Nasional Teknik Elektro dan Teknologi Informasi, 15(2), 291-305. DOI: 10.22146/jnteti.v15i2.21951.
2. Cai, Y., Liu, D., Xu, Q., Li, B., & Liu, B. (2026). Greenhouse Temperature and Humidity Prediction Method Based on Adaptive Kalman Filter and GWO-LSTM-Attention. Smart Agriculture, 8(1), 148-155. DOI: 10.12133/j.smartag.SA202506033.
3. Huang, X., Zhu, Q., & Huang, M. (2026). Online Detection System for Freshness of Fruits and Vegetables Based on Temporal Multi-source Information Fusion. Smart Agriculture, 8(1), 203-212. DOI: 10.12133/j.smartag.SA202505037.
4. Jamjachi Yauri, R. I., Herbozo Ramirez, J. R., & Ovalle, C. (2026). Sustainable greenhouse using IoT and machine learning to optimize the microclimate for lettuce cultivation. Bulletin of Electrical Engineering and Informatics, 15(3), 2138-2149. DOI: 10.11591/eei.v15i3.9877.
5. Park, S., Kim, D. H., & Oh, K. C. (2026). Field-based implementation of machine learning forecasting for energy-efficient temperature control in a greenhouse system. Journal of Agricultural Engineering, LVII:11eb730c.
6. Qiu, J., Liu, Y., Gao, X., Huang, Y., Zhang, H., Tian, F., Li, W., & Feng, Z. (2026). AgriAgent: End-to-End Large Model Agent System Architecture for Agricultural Environment Control. Smart Agriculture, 8(2), 220-236. DOI: 10.12133/j.smartag.SA202507042.
7. Wang, J., et al. (2026). Research Progress and Prospects of Intelligent Management and Control Technologies for Facility Vegetables. Smart Agriculture, 8(1), 105-120.
8. (2026). Systematic Review of Autonomous Weed Detection and Identification Using Deep Learning. Precision Agriculture.
9. 高山弘太郎. (2026). 施設園芸のメガスケールとストロングミニマム : 環境制御高度化と作業自動化に向けて. 農業食料工学会誌, 87(4), 502-503.

10. (2026). 植物環境工学の研究展望 第二十七回 植物工場の環境評価・予測における数値解析研究の現状と展望. 植物環境工学, 38(2), 55-60 / 506-510.

रिपोर्ट और वेब सामग्री

1. Semtech. (2026). LoRaWAN reaches critical mass: 125 million devices and accelerating growth. Semtech Blog. <https://blog.semtech.com/lorawan-reaches-critical-mass-125-million-devices-and-accelerating-growth>
2. Atom Senses. (2026). 2026 LoRaWAN IoT trends: What's new in low-power wide-area networks. Atom Senses. <https://atomsenses.com/company/news/2026-lorawan-iot-trends-whats-new-in-low-power-wide-area-networks>
3. HashStudioz. (2026). LoRaWAN for IoT ecosystem. HashStudioz Blog. <https://www.hashstudioz.com/blog/lorawan-for-iot-ecosystem/>

व्याख्यान और वीडियो सामग्री

1. 高雄農來訊. (2025). 114年高雄智慧農業年度成果發表暨研討會. YouTube. <https://www.youtube.com/watch?v=1Edc6pP4HnU>
2. KYOTO SMART CITY EXPO. (2025). スマート農業の最前線～植物との対話からつくる未来の農業. YouTube. <https://www.youtube.com/watch?v=PzHccCvmsRs>
3. 愛知県農業水産局. (2026). 【あいち農業イノベーションプロジェクト】プロジェクト2027 技術提案募集説明会 (2026.6.10開催) . YouTube. <https://www.youtube.com/watch?v=jpkoNqscGu8>
4. 農業農村情報通信環境整備 準備会. (2026). 第5回オンラインセミナー「地域でデータを共有しよう！農業データの活用最前線～データ駆動型農業WAGRIとIoPクラウド (SAWACHI) でのNext次世代型施設園芸システム～」. YouTube. <https://www.youtube.com/watch?v=k8Qvv6CKB2A>
5. Supreme Knowledge Foundation. (2026). IoT and GNSS technology based Smart Precision Farming and Community Development. [Part I]. YouTube. <https://www.youtube.com/watch?v=8VssYT1onkA>
6. Kanal Pengetahuan Fakultas Teknologi Pertanian UGM. (2025). AI and IoT in Smart Agriculture: How Young Innovators Can Shape the Future of Farming. YouTube. https://www.youtube.com/watch?v=77_Aa0bdchQ
7. 農業農村情報通信環境整備 準備会. (2026). 第6回オンラインセミナー「自治体・農業DXを支える次世代無線:Wi-Fi HaLowの最新動向と活用事例」. YouTube. https://www.youtube.com/watch?v=1Gn_rbR6_Tc
8. Life at PTPN. (2025). Webinar GO DIGI SERIES #5 IOT And AI Implementation In Agriculture. YouTube. <https://www.youtube.com/watch?v=TvmtvwyHwUQ>

3.2

डिजिटल ट्विन और AI से पर्यावरण और वृद्धि का बुद्धिमान अनुकूलन

डिजिटल ट्विन (Digital Twin) ऐसी तकनीक है जिसमें वास्तविक ग्रीनहाउस की संरचना और उपकरणों को कंप्यूटर के भीतर हूबहू उतारने वाले आभासी मॉडल से तापमान, आर्द्रता, कार्बन डाइऑक्साइड सांद्रता और मिट्टी की नमी जैसे वास्तविक समय के सेंसर डेटा जोड़े जाते हैं, ताकि पहले ही गणना की जा सके कि ग्रीनहाउस का वातावरण आगे कैसे बदलेगा। छत की खिड़की खोलने या सिंचाई वाल्व समायोजित करने जैसी कार्रवाई पहले स्क्रीन पर बने मॉडल में लागू की जाती है और गणना से उसका परिणाम जांचने के बाद ही वही आदेश वास्तविक ग्रीनहाउस उपकरणों को भेजा जाता है। समय के साथ वास्तविक ग्रीनहाउस की स्थिति के समानांतर चलते रहने के कारण इसे ट्विन, यानी जुड़वां कहा गया है।

डिजिटल ट्विन केवल ग्रीनहाउस की नकल करने वाला त्रि-आयामी चित्र नहीं है। यदि मॉडल केवल बाहरी रूप से मिलता-जुलता हो, तो गणना की जरूरत ही नहीं पड़ेगी और एक तस्वीर पर्याप्त होगी। इसका असली सार उस जीवंत इंजन में है जो गणना करता है कि ग्रीनहाउस की हवा, मिट्टी और उनमें उगते पौधे समय के साथ कैसे बदलते हैं। इस इंजन के केंद्र में अंतरराष्ट्रीय स्तर पर व्यापक रूप से प्रयुक्त फसल वृद्धि मॉडल DSSAT, यानी कृषि प्रौद्योगिकी हस्तांतरण के लिए निर्णय सहायता प्रणाली, का संस्करण 4.8 है। यह मॉडल हर दिन गणना करता है कि पत्तियों में प्रकाश संश्लेषण से बने पोषक तत्व जड़ों और फलों सहित पौधे के अलग-अलग अंगों में कैसे बंटते हैं, जड़ें मिट्टी से पानी और पोषक तत्व किस गति से खींचती हैं और पौधा गर्मी या सूखे जैसे तनाव पर कितनी तीव्र प्रतिक्रिया देता है। उत्पादक स्क्रीन पर खिड़की खोलता या बंद करता है तो इंजन उस बदलाव को शामिल करके दोबारा गणना करता है और पहले ही दिखा देता है कि अगले दिन इस ग्रीनहाउस में टमाटर का तना कितना मोटा होगा तथा पत्तियां कितनी और झुकेंगी।

ग्रीनहाउस में तापमान, आर्द्रता, कार्बन डाइऑक्साइड की सांद्रता, धूप की तीव्रता और मिट्टी या उगाने वाले माध्यम में पानी तथा उर्वरक की मात्रा अलग-अलग नहीं बदलती, बल्कि एक-दूसरे में उलझकर साथ चलती हैं। खिड़की खुलने पर तापमान और आर्द्रता साथ घटते हैं और इसी कारण कार्बन डाइऑक्साइड के बाहर निकलने की गति भी बदल जाती है। यह वैसा ही जुड़ाव है जैसे शॉवर का केवल एक हैंडल घुमाने पर पानी का दबाव और तापमान दोनों बदल जाते हैं। तब तापमान आते ही पंखा चालू करने और तापमान घटते ही बंद करने वाली पुरानी ऑन-ऑफ नियंत्रण प्रणाली इस उलझे संबंध के साथ कदम नहीं मिला सकती। हर प्रतिक्रिया थोड़ी देर से होती है, उतनी ही देर में गर्मी और पानी व्यर्थ जाते हैं तथा पौधों को कई दिनों तक जरूरत से अधिक गर्मी, ठंड या सूखापन सहना पड़ता है। इसी वजह से डिजिटल ट्विन और कृत्रिम बुद्धिमत्ता नियंत्रण ग्रीनहाउस तकनीक के केंद्र में आए हैं। वास्तविक खिड़कियां और वाल्व चलाने से पहले स्क्रीन पर गणना करके ही इन परस्पर जुड़ी प्रतिक्रियाओं को समय रहते संभाला जा सकता है।

डिजिटल ट्विन का सबसे बड़ा मूल्य उस समय सामने आता है जब उत्पादक ऐसी कार्रवाई आजमाना चाहता है जो उसने पहले कभी नहीं की। यदि वह वास्तविक ग्रीनहाउस में जांचे कि पूरक रोशनी सामान्य से बहुत तेज करने या सिंचाई दो घंटे पहले शुरू करने पर फल का आकार कैसे बदलेगा, तो नतीजा जानने में कम से कम एक मौसम और कभी-कभी पूरा वर्ष लग सकता है। इस बीच निर्णय गलत निकला तो उस वर्ष की फसल चली जाती है। लेकिन स्क्रीन पर बने जुड़वां ग्रीनहाउस में वही कार्रवाई कुछ ही मिनटों में गणना से चलाई जा सकती है और परिणाम खराब हो तो उसे वापस करना पर्याप्त है। इसका सिद्धांत उस नए पायलट जैसा है जो असली विमान में बैठने से पहले उड़ान सिमुलेटर में बार-बार गलती करता है। असफल होने की छूट देने वाला अभ्यास स्थल मिलने भर से उत्पादक उन कदमों को अधिक साहस से आजमा सकता है जिनसे वह अब तक हिचकता रहा था।

मनुष्य दिन-रात इन सभी गणनाओं और निर्णयों की देखभाल नहीं कर सकता। इसलिए शोधकर्ताओं ने ऐसा कृत्रिम बुद्धिमत्ता एजेंट बनाया है जो उत्पादक के स्थान पर ग्रीनहाउस को देखता और निर्णय लेता है। चीनी शोधकर्ताओं का AgriAgent इसका एक उदाहरण है। यह केवल सवालों के जवाब देने वाला चैटबॉट नहीं, बल्कि ग्रीनहाउस में रहने वाले नए उत्पादक जैसा है। वह मीटर पढ़ने, पिछले सप्ताह की गई कार्रवाई याद रखने और जरूरत पड़ने पर मोटी खेती पुस्तिका खोलने के बाद ही वाल्व घुमाने वाले व्यवहार की नकल करता है। AgriAgent का मुख्य निर्णय कार्य Qwen2.5 नामक बड़े भाषा मॉडल, यानी LLM (Large Language Model), को दिया गया और 1.5 अरब, 3 अरब तथा 7 अरब पैरामीटर वाले तीन अलग आकार के मॉडल साथ-साथ परखे गए। पैरामीटर मॉडल के भीतर वे संख्याएं हैं जिनके मान प्रशिक्षण से तय होते हैं, और उनकी संख्या जितनी बड़ी हो, मॉडल उतनी अधिक परिस्थितियों को अलग करके याद रख सकता है तथा उतना सूक्ष्म निर्णय दे सकता है।

AgriAgent संवेदन, स्मृति, खोज, तर्क और कार्रवाई के पांच चरण हर सात दिन में एक बार क्रम से पूरा करता है। सबसे पहले सेंसर डेटा को बारह संख्याओं वाले अवस्था मान में बदला जाता है। इसमें मिट्टी के पानी, नाइट्रोजन और जैविक पदार्थ की मात्रा, दिन का औसत और अधिकतम तापमान, दैनिक वर्षा, हवा की गति, वायु में कार्बन डाइऑक्साइड की सांद्रता, प्रकाश संश्लेषण में वास्तव में काम आने वाली रोशनी की तीव्रता, बुआई के बाद बीते दिन और पानी की कमी तथा वृद्धि में देरी को एक अंक में दिखाने वाले दो तनाव सूचकांक शामिल होते हैं। फॉर्मेट कनवर्टर नामक उपकरण इन संख्याओं को मनुष्य के पढ़ने योग्य वाक्यों में बदलता है और उन्हें पुराने अभिलेखों तथा आगे बताए जाने वाले खोज परिणामों के साथ कृत्रिम बुद्धिमत्ता मॉडल को देता है। बारह संख्याओं को एक-एक वाक्य में खोलने पर वे केवल यह बताते हैं कि फसल इस समय कितनी प्यासी है और कितनी अच्छी बढ़ी है। यह संख्याओं से भरी तालिका को ऐसी छोटी रिपोर्ट में बदलने की प्रक्रिया है जिसे मनुष्य पढ़ते ही समझ सके।

खेती में बहुत सा बारीक ज्ञान केवल पाठ्यपुस्तकों में मिलता है, इसलिए सबसे बड़ा भाषा मॉडल भी सब कुछ याद नहीं रख सकता। AgriAgent इस ज्ञान को पूरा रटने के बजाय जरूरत पड़ने पर मोटी पुस्तक का सबसे उपयुक्त पृष्ठ खोजकर खोलता है। इस विधि को खोज-संवर्धित सृजन या RAG (Retrieval-Augmented Generation) कहते हैं, और इसे लागू करने के लिए शोधकर्ताओं ने कृषि विज्ञान की पाठ्यपुस्तकों तथा तकनीकी पुस्तिकाओं के 51 लाख अक्षरों को ऑप्टिकल कैरेक्टर रिकग्निशन (OCR) से डिजिटल दस्तावेज में बदला और उनमें से उपयोगी 44 लाख अक्षरों को छोटे खंडों में बांटा। हर

खंड पर यह बताने वाला टैग लगाया गया कि सामग्री किस अध्याय और खंड से आई है। bge-large-zh नामक 768-आयामी एम्बेडिंग मॉडल वाक्यों को संख्यात्मक वेक्टर में बदलकर समान अर्थ वाले वाक्यों को पास रखता है, फिर शब्दों के हूबहू मेल की खोज जोड़कर मौजूदा स्थिति के लिए सबसे उपयुक्त पांच दस्तावेज चुनता है और उन्हें कृत्रिम बुद्धिमत्ता को सौंपता है।

दस्तावेज मिलने के बाद कृत्रिम बुद्धिमत्ता तुरंत उत्तर नहीं देती, बल्कि क्रमिक चरणों से गुजरती है। वह पहले तय करती है कि अभी अंकुरण का समय है या फूल और फल बनने का, फिर पानी की कमी तथा धीमी वृद्धि जांचती है और उस निर्णय के आधार पर आदेश तय करती है, जिसे विचार-शृंखला (Chain-of-Thought) पद्धति कहते हैं। यह उस व्यक्ति जैसा है जो मन में केवल उत्तर नहीं बताता, बल्कि हल की प्रक्रिया पंक्ति-दर-पंक्ति लिखता है। निष्कर्ष सिंचाई की मात्रा, पूरक रोशनी की तीव्रता, वेंटिलेशन और ताप देने की स्थिति, उर्वरक की मात्रा तथा कार्बन डाइऑक्साइड छोड़ने की मात्रा सहित छह मानों वाले निश्चित JSON प्रारूप में रखा जाता है। सिंचाई 0 से 30 मिलीमीटर प्रति घंटा, पूरक रोशनी सामान्य स्तर के 0 से 200 प्रतिशत और उर्वरक 0 से 50 किलोग्राम प्रति हेक्टेयर के बीच तय किया जाता है। अंतिम जांच करने वाला टूल एकजीक्यूटर दोबारा देखता है कि ये संख्याएं सुरक्षित सीमा से बाहर तो नहीं हैं, बाहर गए मानों को सीमा तक काटता है और उसके बाद ही DSSAT इंजन या वास्तविक ग्रीनहाउस उपकरणों को आदेश भेजता है।

मान लें कि किसी सोमवार सुबह सेंसर दिखाता है कि मिट्टी में सामान्य से कम पानी है और दिन का अधिकतम तापमान औसत से 3 डिग्री अधिक है। पानी की कमी का तनाव सूचकांक भी खतरे के संकेत के पास पहुंच गया है। AgriAgent इस संयोजन के साथ इस तथ्य को पढ़ता है कि फल बढ़ने का चरण चल रहा है और ज्ञान आधार में लिखा है कि इस समय मिट्टी सूखने पर शारीरिक विकार आसानी से हो सकते हैं। इसलिए वह सिंचाई सामान्य से बढ़ाने और दोपहर की पूरक रोशनी थोड़ी घटाकर पत्तियों का बोझ कम करने का निष्कर्ष देता है। मनुष्य जिस निर्णय को अनुभव और सहज ज्ञान से लेता, AgriAgent उसे संख्याओं और दस्तावेजों के आधार पर कुछ सेकंड में तैयार कर देता है।

उपकरण कभी भी खराब हो सकते हैं। मान लें कि सिंचाई यंत्र रुक गया और मिट्टी में पानी देना संभव नहीं रहा। ऐसी स्थिति में मनुष्य घबरा सकता है, पर AgriAgent कारण और परिणाम का तर्क लगाकर दूसरा रास्ता खोजता है। वह वेंटिलेशन और ताप व्यवस्था समायोजित करके पत्तियों से पानी निकलने की वाष्पोत्सर्जन दर घटाता है तथा कार्बन डाइऑक्साइड की मात्रा बढ़ाकर प्रकाश संश्लेषण में मदद देता है, जिससे पानी की कमी का कुछ नुकसान संतुलित हो सके। यह उस रसोइये जैसा है जो फ्रिज में कोई एक सामग्री खत्म देखकर बाकी सामग्री का अनुपात बदलता है और वही व्यंजन पूरा करता है। जब तक मनुष्य पहुंचकर वाल्व ठीक करता है, यह अस्थायी समायोजन फसल को सबसे खराब स्थिति से बचाता है।

यह जानने के लिए कि ऐसी निर्णय क्षमता सचमुच भरोसेमंद है या नहीं, उसे पहले चरम मौसम में परखना चाहिए। शोधकर्ताओं ने 1994 से 2023 तक के 30 वर्षों के मौसम डेटा से सामान्य, अस्थिर और चरम तीव्रता वाला आभासी मौसम बनाया तथा कुल 90 वार्षिक परिदृश्य तैयार किए। चरम परिदृश्यों में 20 दिन लगातार चलने वाली गर्म और शुष्क दशा, पांच दिन में 80 मिलीमीटर से अधिक बारिश और 20 सूखे दिनों के तुरंत बाद 10 दिन की मूसलाधार वर्षा जैसी अचानक उलटती संयुक्त आपदाएं शामिल थीं। फिर

AgriAgent को इन परिस्थितियों से गुजारकर देखा गया कि फसल जीवित रहती है या नहीं और कितनी अच्छी तरह टिकती है। वास्तविक ग्रीनहाउस में मुश्किल से मिलने वाले सबसे खराब संयोजन को स्क्रीन के भीतर बिना खतरे के बार-बार दोहराया जा सकता है।

उच्च लचीलेपन का अर्थ एक ठोस दृश्य है। लगातार 20 गर्म और सूखे दिनों वाले परिदृश्य में कम प्रशिक्षित नियंत्रण पद्धति का तनाव सूचकांक एक बार खतरे के क्षेत्र में जाने के बाद शायद ही लौट पाया और फसल मुरझाती गई। इसके विपरीत AgriAgent ने पानी की कमी के शुरुआती चरण में सिंचाई और पूरक रोशनी थोड़ा-थोड़ा बढ़ाकर तनाव सूचकांक को कम रखा, फिर अचानक भारी बारिश शुरू होने पर तुरंत वेंटिलेशन बढ़ाकर अधिक नमी का नुकसान घटाया। इसका अर्थ है कि सबसे खराब मौसम के सामने भी उसने हार नहीं मानी और हर क्षण परिस्थिति के अनुसार कुछ बेहतर विकल्प चुनता रहा।

ग्रीनहाउस में केवल AgriAgent जैसी भाषा संभालने वाली कृत्रिम बुद्धिमत्ता ही नहीं आई है। लंबे समय से प्रयुक्त कृत्रिम तंत्रिका नेटवर्क, यानी ANN (Artificial Neural Network), और सपोर्ट वेक्टर मशीन, यानी SVM (Support Vector Machine), भी सूक्ष्म जलवायु पढ़ते हैं। दोनों संख्यात्मक डेटा में पैटर्न खोजने वाले सांख्यिकीय प्रोग्राम हैं और Orange नामक डेटा विश्लेषण उपकरण पर ग्रीनहाउस का तापमान, आर्द्रता तथा पराबैंगनी प्रकाश की तीव्रता साथ देखकर वर्तमान दशा को उचित, अधिक या कम, इन तीन वर्गों में रखते हैं। इस वर्गीकरण की सटीकता 99.99 प्रतिशत तक पहुंची। दस हजार निर्णयों में मुश्किल से एक गलती का यह स्तर मनुष्य के बार-बार मीटर देखने से कहीं अधिक सघन निगरानी देता है।

तापमान और आर्द्रता एक ही दिन में बहुत ऊपर-नीचे होते हैं और एक-दूसरे को प्रभावित करते हैं, इसलिए उनका अनुमान कठिन है। कुछ क्षण बादल से ढकी धूप फिर निकल आए तो भी ग्रीनहाउस के मान बारीकी से हिलते हैं। शोधकर्ता पहले अलग-अलग स्थानों के सेंसर मानों पर अनुकूली कालमन फिल्टर लगाकर इस अस्थिर शोर को शांत करते हैं। यह तस्वीर खींचते समय हाथ का कंपन सुधारकर धुंधलापन घटाने जैसी प्रक्रिया है। शोर हटे मान ही अगले पूर्वानुमान मॉडल को गलत दिशा में सीखने से रोकते हैं।

शोर हटाने के बाद ग्रे वुल्फ ऑप्टिमाइजर, यानी GWO (Grey Wolf Optimizer), से पूर्वानुमान तंत्रिका नेटवर्क की बारीक सेटिंग समायोजित की जाती है। जैसे भेड़ियों का झुंड शिकार को कई दिशाओं से धीरे-धीरे घेरता है, वैसे ही यह पद्धति कई संभावित सेटिंग मानों को बार-बार संकरा करके सही संयोजन खोजती है। इस तरह सुधारे गए LSTM (Long Short-Term Memory) तंत्रिका नेटवर्क में अटेंशन (Attention) तकनीक जोड़ने पर पिछले कई घंटों के अभिलेखों में से केवल मौजूदा पूर्वानुमान के लिए सचमुच महत्वपूर्ण क्षण चुने जाते हैं और उन्हें अधिक भार मिलता है। यह संयोजन एक बार में अनुमान लगाता है कि अगले कुछ घंटों में ग्रीनहाउस का तापमान और आर्द्रता कैसे बदलेंगे।

पूर्वानुमान कितना भी सटीक हो, उसे वास्तविक हीटर चालू या बंद करने के निर्णय में न बदला जा सके तो वह बेकार है। डेटा-आधारित पूर्वानुमान नियंत्रण या DDPC (Data-Driven Predictive Control) ठंड पड़ने का पहले से अनुमान लगाकर शीतलहर आने से पूर्व पानी गर्म करता है। दक्षिण कोरिया के गांगवोन प्रांत में स्थित चुन्चन के 300 वर्गमीटर ग्रीनहाउस में पेलेट बायलर, ताप संचय टैंक और ट्यूब-रेल हीटिंग लगाकर हर 1 मिनट में डेटा जुटाने वाला क्षेत्र परीक्षण किया गया। LSTM से हल्के GRU (Gated Recurrent Unit) तंत्रिका नेटवर्क ने हाल के सात दिनों के 10,080 माप सीखे और अगले एक दिन के

डेटा पर प्रदर्शन जांचने की प्रक्रिया दोहराई। मॉडल शीतलहर आने से 1 से 3 घंटे पहले ग्रीनहाउस का तापमान गिरने का पूर्वानुमान देता और उसके अनुसार बॉयलर तथा गर्म पानी के वाल्व पहले ही चलाता था। परिणामस्वरूप तापमान को फसल की सहनीय न्यूनतम सीमा से नीचे जाने से रोकते हुए अनावश्यक ताप घटा और ईंधन खर्च बचा।

ताप व्यवस्था और उपज प्रायः विपरीत दिशाओं में खींचने वाली शक्तियां हैं। तापमान पर्याप्त ऊंचा रखने पर पौधे तेजी से बढ़ते और अधिक फल देते हैं, लेकिन बॉयलर बिना रुके चलता है तथा ईंधन खर्च बढ़ाता है। इसके उलट गर्मी बचाने पर ईंधन खर्च घटता है, मगर कम तापमान से फसल की वृद्धि धीमी पड़ सकती है या फूल की कलियां गिर सकती हैं, जिससे अंत में उपज का नुकसान होता है। डिजिटल ट्विन इन दोनों लक्ष्यों को अलग नहीं गिनता, बल्कि एक स्क्रीन पर साथ रखकर देखता है। समान शीतकालीन परिदृश्य में ताप की तीव्रता कई स्तरों पर बदलकर परीक्षण करने से वह तापमान दिखाई देता है जहां ईंधन और उपज के नुकसान का कुल मान सबसे कम होता है। चुन्चन ग्रीनहाउस के GRU-आधारित DDPC ने शीतलहर से ठीक पहले थोड़ी देर बॉयलर चलाकर न्यूनतम तापमान बनाए रखा, और यह उसी संतुलन बिंदु को वास्तविक समय में बार-बार खोजने वाली गणना का परिणाम था।

इन पूर्वानुमान मॉडलों की क्षमता कुछ संख्याओं से जांची जा सकती है। निर्धारण गुणांक को संकेत में R-वर्ग लिखा जाता है और यह 0 से 1 के बीच बताता है कि अनुमानित मान वास्तविक मान से कितना मेल खाता है, जहां 1 के निकट मान बेहतर मेल दर्शाता है। इन सूक्ष्म जलवायु पूर्वानुमान मॉडलों ने 0.77 से 0.93 के बीच मान दिए। चुन्चन ग्रीनहाउस के GRU-आधारित ताप नियंत्रण मॉडल में मूल माध्य वर्ग त्रुटि, यानी RMSE, लगभग 1.43 डिग्री थी। यह तापमापी के केवल डेढ़ निशान जितना अंतर है, इसलिए ताप नियंत्रण के लिए पर्याप्त सटीकता देता है। ग्रीनहाउस की दशा को उचित, अधिक और कम वर्गों में रखने वाले मॉडल ने AUC-ROC में 0.988 से 0.991 अंक दर्ज किए, जिसका अर्थ है कि तीनों स्थितियां लगभग कभी एक-दूसरे से नहीं उलझीं।

इस प्रकार बने AgriAgent की क्षमता कई फसलों पर परखी गई। शोधकर्ताओं ने DSSAT-आधारित डिजिटल ट्विन पर मक्का, बाजरा, चुकंदर, टमाटर और पत्तागोभी जैसी पांच अलग फसलें चुनीं। मक्का धूप का असाधारण कुशलता से उपयोग करने वाली प्रकाश संश्लेषण पद्धति का प्रतिनिधि है, बाजरा सूखा सहने वाली फसल है, चुकंदर की जड़ खाई जाती है, टमाटर का फल और पत्तागोभी की पत्तियां खाई जाती हैं, इसलिए ये अलग वृद्धि शैलियों का व्यापक प्रतिनिधित्व करती हैं। 90 मौसम परिदृश्यों को तीन तीव्रता स्तरों से जोड़कर कुल 450 पूरे वृद्धि-काल के सिमुलेशन किए गए। 7 अरब पैरामीटर वाले मॉडल ने बिना मानवीय हस्तक्षेप की प्राकृतिक वृद्धि की तुलना में मक्का, बाजरा और चुकंदर की उपज का सूखा भार स्पष्ट रूप से बढ़ाया। अंकुरण के समय कम तापमान की चेतावनी आने पर उसने पूरक रोशनी का हस्तक्षेप स्वयं 120 प्रतिशत तक बढ़ाकर ठंड से होने वाला नुकसान भी घटाया। पैरामीटर 1.5 अरब से 3 अरब और फिर 7 अरब होने के साथ नियंत्रण प्रदर्शन क्रमशः सुधरने की प्रवृत्ति भी मिली।

उदाहरण के लिए मक्का के एक सिमुलेशन में एजेंट बुआई की तारीख से बीते दिन गिनकर पहले तय करता है कि अभी अंकुर मिट्टी से निकल रहे हैं या बालियां बन रही हैं। बुआई के दसवें दिन की ठंड और बालियां भरने के समय की ठंड फसल को अलग तरह से चोट पहुंचाती है, इसलिए वृद्धि चरण की गलत पहचान

सटीक तापमान पूर्वानुमान को भी गलत उपचार में बदल सकती है। वास्तविक परीक्षण में एजेंट कम तापमान की चेतावनी पर पूरक रोशनी इसलिए बढ़ा पाया क्योंकि वृद्धि चरण का निर्णय पहले हो चुका था। वह केवल दिन नहीं गिनता, बल्कि यह भी पढ़ता है कि उस तारीख का पौधे के शरीर के लिए क्या अर्थ है।

डिजिटल ट्विन प्रयोगशाला तक सीमित नहीं रहा और वास्तविक व्यावसायिक खेतों में भी लगाया गया है। इंडोनेशिया के Sandi Buana Farm में हाइड्रोपोनिक सलाद पत्ता उगाते हुए तापमान, आर्द्रता, EC और अम्लता मापने वाले उच्च-रिजॉल्यूशन सेंसरों से 15,492 नमूने जुटाए गए। EC पानी में घुले उर्वरक की मात्रा को विद्युत चालकता से मापता है और अम्लता बताती है कि पानी कितना अम्लीय या क्षारीय है। इन आंकड़ों को मशीन लर्निंग पूर्वानुमान एल्गोरिदम में डालकर सलाद पत्ते की उपज और खेती के पर्यावरणीय मानों को साथ-साथ स्वतः समायोजित करने वाली प्रणाली चलाई गई, जिससे मनुष्य के लगातार हस्तक्षेप के बिना पानी तथा उर्वरक की उचित सांद्रता बनी रही। इस खेत ने दिखाया कि प्रयोगशाला सिमुलेशन के बिना भी वास्तविक स्थल पर जमा संख्याओं से निर्णय प्रणाली बनाई जा सकती है।

डिजिटल ट्विन पर चलने वाला भाषा मॉडल एजेंट और ग्रीनहाउसों में बहुत पहले से प्रयुक्त सांख्यिकीय पूर्वानुमान मॉडल प्रतिस्पर्धी नहीं, बल्कि अलग भूमिकाओं वाले सहकर्मी हैं। एजेंट वृद्धि चरण तथा अनेक चरों को साथ पढ़कर बड़े परिप्रेक्ष्य में सिंचाई, उर्वरक और पूरक रोशनी का संतुलन तय करता है, जबकि ANN, SVM तथा LSTM श्रेणी के मॉडल हर मिनट और सेकंड बदलते तापमान तथा आर्द्रता को पकड़ते हैं। वास्तविक क्षेत्र में दोनों परतें अक्सर साथ चलती हैं, इसलिए बड़े निर्णय एजेंट लेता है और उन्हें सेकंड-दर-सेकंड बारीकी से समायोजित करने का काम सांख्यिकीय मॉडल संभालते हैं। एक परत तय करती है कि छत की खिड़की खोलनी है या नहीं, और दूसरी खिड़की खुलने के बाद हर सेकंड देखती है कि तापमान अनुमान से अलग तो नहीं जा रहा। इनमें से केवल एक परत होती तो निर्णय अधूरा रहता, क्योंकि या तो बड़ी तस्वीर सही होते हुए क्षणिक उतार-चढ़ाव छूटता या क्षण संभल जाता लेकिन पूरे मौसम की दिशा नहीं पढ़ी जाती।

एक ग्रीनहाउस में प्रमाणित एजेंट को दस या सौ ग्रीनहाउसों तक बढ़ाना अंकगणित जितना आसान नहीं है। हर ग्रीनहाउस की दिशा, निर्माण सामग्री और आसपास की इमारतों की छाया अलग होती है, इसलिए समान आदेश अलग परिणाम देता है। इसी कारण नए ग्रीनहाउस में एजेंट लगाने पर शुरुआती कुछ सप्ताह उस स्थान की अपनी आदतें सीखने की अनुकूलन अवधि रखी जाती है। पुराने ग्रीनहाउस से मिले ज्ञान आधार और निर्णय व्यवहार को नींव बनाकर नए स्थल के आंकड़े जुड़ने के साथ व्यवस्था को थोड़ा-थोड़ा दोबारा समायोजित किया जाता है।

यह प्रवृत्ति कुछ स्थानीय प्रयोगों तक सीमित नहीं है। हाल के शोध में डिजिटल ट्विन को ऑनलाइन सिमुलेटर बनाकर बड़े भाषा मॉडल एजेंट से एक बंद चक्र में जोड़ा गया, ताकि वास्तविक उपकरण को आदेश जाने से पहले उसकी सुरक्षा वास्तविक समय में जांची जा सके। परिणाम ने दिखाया कि भाषा मॉडल समय के प्रवाह से कसकर जुड़े निर्णय चक्र में भी अपनी भूमिका निभा सकता है। वायरलेस सेंसर तथा एक्जुएटर नेटवर्क को ट्विन सॉफ्टवेयर से जोड़कर सूक्ष्म जलवायु और सिंचाई की दूरस्थ निगरानी तथा स्वचालित नियंत्रण करने और रोग की संभावना पहले पहचानने वाला स्मार्ट ग्रीनहाउस भी बनाया गया है। उत्पादक ग्रीनहाउस में प्रवेश

किए बिना मौजूदा स्थिति देख सकता है और वास्तविक कार्रवाई करने से पहले उसे स्क्रीन पर आजमा सकता है। वर्ष 2026 में फसल वृद्धि मॉडल और स्वायत्त जलवायु नियंत्रण को जोड़ने वाली डेटा-आधारित ग्रीनहाउस प्रबंधन पद्धति भी सामने आई, जिससे स्पष्ट हुआ कि डिजिटल ट्विन प्रदर्शन के मॉडल से निर्णय और क्रियान्वयन दोनों करने वाले उपकरण में बदल रहा है।

उत्पादक के सामने वास्तविक स्क्रीन रंगीन उपकरण-पटल के रूप में आती है। बारह अवस्था मान और छह नियंत्रण आदेश ग्राफ तथा पट्टियों में साथ दिखते हैं, और उनके बगल में एक या दो वाक्यों में बताया जाता है कि कृत्रिम बुद्धिमत्ता ने वह आदेश क्यों दिया। उत्पादक इसे स्वीकार कर सकता है या असहमति होने पर संख्या हाथ से बदलकर वापस भेज सकता है। मनुष्य के अंतिम हस्ताक्षर तक एजेंट का निर्णय केवल मसौदा है, और यह सिद्धांत स्क्रीन की रचना में समाया हुआ है।

इस प्रणाली से पहले उत्पादक को हर भोर हाथ में टॉर्च लेकर ग्रीनहाउस घूमना और हर तापमापी देखना पड़ता था। शीतलहर की चेतावनी वाली रातों में हर दो या तीन घंटे बाद उठकर बॉयलर देखना असामान्य नहीं था। डिजिटल ट्विन और एजेंट ने यह दोहराया जाने वाला श्रम संभाला तो उत्पादक की दिनचर्या ऐसी हो गई कि समस्या आने पर ही उसे स्क्रीन के सामने बुलाया जाता है। रात शांत बीती हो तो सुबह तक कोई सूचना नहीं आती, और गड़बड़ी होते ही मोबाइल फोन बजता है। हाथ से होने वाली गश्त खत्म हुई है, लेकिन उसका काम अब गणना कर रही है।

फिर भी यह तकनीक पूरी नहीं हुई है। DSSAT-आधारित डिजिटल ट्विन में प्रमाणित नियंत्रण विधि को वास्तविक ग्रीनहाउस में जस का तस ले जाने पर गणना और वास्तविकता अलग होने लगती हैं। आदेश मिलने के बाद एक्चुएटर के चलने में लगने वाला समय, पुराने सेंसर के मानों का धीरे-धीरे खिसकना, ग्रीनहाउस के कोने तथा मध्य का तापांतर और अप्रत्याशित बाहरी झटके स्क्रीन की गणना तथा वास्तविक परिणाम के बीच अंतर पैदा करते हैं। शोधकर्ता इसे सिमुलेशन और वास्तविकता की खाई कहते हैं तथा ट्विन में पहले अधिक कठिन परिस्थितियों का प्रशिक्षण और तैनाती के बाद भी लगातार सीखने की व्यवस्था जोड़कर इसे भरना चाहते हैं। LoRA नामक फाइन-ट्यूनिंग विधि पूरे बड़े मॉडल को फिर प्रशिक्षित करने के बजाय केवल कुछ नियंत्रण बिंदुओं को थोड़ा बदलकर नए स्थल के अनुकूल बनाती है, इसलिए इसे निरंतर सीखने के लिए उपयुक्त उपकरण माना जाता है।

तकनीक कितनी भी परिष्कृत हो, उसे चलाने वाला व्यक्ति न हो तो वह ग्रीनहाउस के कोने में पड़ी सजावटी वस्तु बन जाती है। AgriAgent का निर्णय ज्यों का त्यों मानना है या अपने लंबे अनुभव के आधार पर संख्या हाथ से बदलनी है, यह आखिर उत्पादक तय करता है। यह भरोसा एक दिन में नहीं बनता और एजेंट जब कई मौसमों तक बिना बड़ी गलती के निर्णय देता है तभी मजबूत होता है। जिस उत्पादक ने स्क्रीन के ट्विन को वास्तविक ग्रीनहाउस से अलग चलते कई बार देखा हो, वह बाद के सटीक पूर्वानुमानों पर भी आसानी से विश्वास नहीं करेगा।

7 अरब पैरामीटर वाला मॉडल चलाने के लिए महंगा ग्राफिक्स कंप्यूटिंग सर्वर और बिना रुकावट का संचार नेटवर्क चाहिए। ये शर्तें सीमित पूंजी वाले किसानों के लिए बाधा बनती हैं और डेटा भेजने तथा लेने में निर्णय की देरी भी पैदा करती हैं। समाधान के लिए शोधकर्ता क्वांटाइजेशन (INT8) तकनीक से मॉडल की हर संख्या को कम बिटों में संग्रहित करते हैं और नॉलेज डिस्टिलेशन (Knowledge Distillation) से

बड़े मॉडल की सीखी निर्णय पद्धति छोटे मॉडल को सिखाते हैं। जैसे कुशल वरिष्ठ अपने तरीके समेटकर कनिष्ठ को देता है, वैसे ही 7 अरब मॉडल की निर्णय आदतें 1.5 अरब या 3 अरब के छोटे मॉडल में डालकर उसे ग्रीनहाउस के सस्ते उपकरणों पर चलाया जाता है। आकार घटा मॉडल क्लाउड में डेटा भेजे बिना ग्रीनहाउस के पास रखे छोटे कंप्यूटर पर निर्णय पूरा कर सकता है। एक छोटे किसान के ग्रीनहाउस में भी एजेंट चलना चाहिए, तभी यह तकनीक केवल कुछ बड़े खेतों का उपकरण बनकर नहीं रह जाएगी।

उपज बढ़ाने का लक्ष्य, ऊर्जा बचाने का लक्ष्य और पानी तथा कार्बन उत्सर्जन घटाने का लक्ष्य अक्सर एक-दूसरे से टकराते हैं। पूरक रोशनी तेज करने पर उपज बढ़ती है, लेकिन बिजली खर्च भी बढ़ता है। एजेंट इनमें से किसी एक लक्ष्य का पक्ष न ले, इसके लिए पुरस्कार गणना की कई परतें तैयार की जा रही हैं। उत्पादक को स्क्रीन पर तुरंत दिखना चाहिए कि कृत्रिम बुद्धिमत्ता ने इसी समय खिड़की खोलने का निर्णय क्यों लिया और उसका आधार क्या था। निर्णय प्रक्रिया काले डिब्बे की तरह छिपी हो तो सबसे सटीक मॉडल को भी क्षेत्र में भरोसे से सौंपना कठिन है। डिजिटल ट्विन और बुद्धिमान नियंत्रण को प्रयोगशाला से निकलकर सामान्य ग्रीनहाउस का उपकरण बनने के लिए अधिक व्याख्येय बनाने वाला शोध अभी चाहिए।

स्रोत और संदर्भ

शैक्षणिक शोधपत्र

1. Qiu, J., Liu, Y., Gao, X., Huang, Y., Zhang, H., Tian, F., Li, W., & Feng, Z. (2026). AgriAgent: कृषि पर्यावरण नियंत्रण के लिए आरंभ से अंत तक बड़े मॉडल एजेंट की प्रणाली संरचना। *Smart Agriculture*, 8(2), 220-236. DOI: 10.12133/j.smartag.SA202507042.
2. Park, S., Kim, D. H., & Oh, K. C. (2026). ग्रीनहाउस प्रणाली में ऊर्जा-कुशल तापमान नियंत्रण के लिए मशीन लर्नगि पूर्वानुमान का क्षेत्र-आधारित कार्यान्वयन। *Journal of Agricultural Engineering*, LVII:11eb730c.
3. Cai, Y., Liu, D., Xu, Q., Li, B., & Liu, B. (2026). अनुकूली कालमन फिल्टर और GWO-LSTM-Attention पर आधारित ग्रीनहाउस तापमान तथा आर्द्रता पूर्वानुमान बढ़ि। *Smart Agriculture*, 8(1), 148-155. DOI: 10.12133/j.smartag.SA202506033.
4. Arfiyani, S. A., Wardihani, E. D., & Helmy. (2026). मशीन लर्नगि दृष्टिकोण से स्मार्ट ग्रीनहाउस डेटा एकीकरण। *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, 15(2), 291-305. DOI: 10.22146/jnteti.v15i2.21951.
5. Xu, Q., Zheng, B., & Zhong, S. (2026). आधुनिक कृषि जैविक प्रजनन को सशक्त बनाती कृत्रिम बुद्धिमत्ता। *Smart Agriculture*, 8(3), 69-85.
6. Wang, J., et al. (2026). संरक्षित सब्जियों के बुद्धिमान प्रबंधन और नियंत्रण की प्रौद्योगिकियों में शोध प्रगति तथा संभावनाएं। *Smart Agriculture*, 8(1), 105-120.
7. Jamjachi Yauri, R. I., Herbozo Ramirez, J. R., & Ovalle, C. (2026). सलाद पत्ते की खेती के लिए सूक्ष्म जलवायु अनुकूलित करने वाला IoT और मशीन लर्नगि-आधारित टिकाऊ ग्रीनहाउस। *Bulletin of Electrical Engineering and Informatics*, 15(3), 2138-2149. DOI: 10.11591/eei.v15i3.9877.

रिपोर्ट और वेब सामग्री

1. arXiv. (2025). ऑनलाइन समियुलेटर-आधारित डिजिटल ट्विन और बड़े भाषा मॉडल एजेंट से ग्रीनहाउस के बंद-चक्र नियंत्रण के सत्यापन पर अध्ययन। <https://arxiv.org/pdf/2507.07115>
2. Springer. (n.d.). स्मार्ट ग्रीनहाउस डिजिटल ट्विन का कार्यान्वयन: वायरलेस सेंसर और एक्जुटर नेटवर्क पर आधारित सूक्ष्म जलवायु की दूरस्थ नगरानी तथा रोग पूर्वानुमान का अध्ययन। https://link.springer.com/chapter/10.1007/978-981-99-0252-1_5

3. PLOS ONE. (n.d.). डिजिटल ट्वनि ग्रीनहाउस में दूरस्थ अवस्था नगरानी और आभासी कार्रवाई सत्यापन पर अध्ययन। <https://journals.plos.org/plosone/article?id=10.1371%2Fjournal.pone.0344946>
4. ScienceDirect. (2026). फसल वृद्धि मॉडल को स्वायत्त जलवायु नियंत्रण से जोड़ने वाले डेटा-आधारित अनुकूली ग्रीनहाउस प्रबंधन का अध्ययन। <https://www.sciencedirect.com/science/article/pii/S2590005626000445>

व्याख्यान और वीडियो सामग्री

1. 高雄農來訊. (2025). वर्ष 114 के Kaohsiung स्मार्ट कृषि वार्षिक परणामों की प्रस्तुति और संगोष्ठी। YouTube. <https://www.youtube.com/watch?v=1Edc6pP4HnU>
2. Kanal Pengetahuan Fakultas Teknologi Pertanian UGM. (2025). स्मार्ट ग्रीनहाउस में कृत्रिम बुद्धिमत्ता: फसल नगरानी और पर्यावरण नियंत्रण को बेहतर बनाना। YouTube. <https://www.youtube.com/watch?v=zFP6Nm4i4Ec>
3. WiseFood Project. (2025). WiseFood और STELAR वेबिनार: LLM-आधारित डेटासेट खोज तथा एकीकरण से कृषि-खाद्य ऐप को सशक्त बनाना। YouTube. https://www.youtube.com/watch?v=Keqo17qBr_g
4. Regace Project. (2026). ग्रीनहाउस में कृषि-वोल्टाइक: धूप को ऊर्जा और फसल में बदलना। YouTube. <https://www.youtube.com/watch?v=rSJvJAxnY8w>
5. KYOTO SMART CITY EXPO. (2025). स्मार्ट कृषि की अग्रिम पंक्ति: पौधों से संवाद करके भविष्य की खेती बनाना। YouTube. <https://www.youtube.com/watch?v=PzHccCvmsRs>

अध्याय 4

डेटा-आधारित सटीक कृषि और निर्णय सहायता

4.1

स्मार्ट सिंचाई और उर्वरक आपूर्ति का अनुकूलन

बुद्धिमान सिंचाई प्रणाली में वाल्व मनुष्य नहीं, बल्कि मिट्टी में लगे सेंसर और क्लाउड सर्वर पर चलने वाला पूर्वानुमान मॉडल खोलते हैं। प्रणाली गणना करती है कि मिट्टी कितनी सूखी है, दिन का तापमान कितना बढ़ा है और कल वर्षा की संभावना कितने प्रतिशत है, फिर सिंचाई का समय और पानी की मात्रा तय करती है। अमेरिका के Nebraska में खेत परीक्षण के दौरान इस सिंचाई समय-सारणी उपकरण का उपयोग करने वाले मक्का खेतों ने 29 से 43 प्रतिशत और सोयाबीन खेतों ने 10 से 37 प्रतिशत पानी बचाया, जबकि दोनों की उपज पारंपरिक विधि के लगभग समान रही।

पारंपरिक खेती में कब और कितना पानी तथा उर्वरक देना है, यह किसान के अनुभवी स्पर्श और तय समय-सारणी पर निर्भर था। उदाहरण के लिए सुबह छह बजे पानी खोलना और महीने में एक बार उर्वरक मिलाना तय रहता था। समस्या यह है कि मिट्टी और आकाश समय-सारणी के अनुसार नहीं चलते। किसी दिन पहले से गीली मिट्टी पर और पानी डाल दिया जाता है और जड़ों को साँस लेने की जगह नहीं मिलती, तो किसी दिन सूखी मिट्टी यूँ ही छोड़ दी जाती है और फसल मुरझाती है। अतिरिक्त पानी गहराई में बहकर मिट्टी को साथ ले जाता है, और उसमें घुला नाइट्रोजन तथा फॉस्फोरस नालों और नदियों में पहुँचता है। जलवायु परिवर्तन से सूखे और भारी वर्षा के दौर अधिक तीखे होने पर अनुभव तथा समय-सारणी आधारित सिंचाई और उर्वरक प्रयोग अधिक हानि करने लगे हैं।

इन हानियों को घटाने वाली तकनीक सिंचाई और उर्वरक आपूर्ति का बुद्धिमान अनुकूलन है। यह मिट्टी नमी सेंसर, मौसम मापन उपकरण, Internet of Things (IoT, इंटरनेट से अनेक उपकरण जोड़कर सूचना का आदान-प्रदान कराने वाला नेटवर्क) और machine learning पूर्वानुमान मॉडल को एक प्रणाली में मिलाता है। प्रणाली मिट्टी, हवा और फसल के बीच पानी की आवाजाही को अनेक कोणों से मापती है, हर वृद्धि अवस्था में बदलती पानी तथा पोषक तत्व की जरूरत निकालती है, सेंसर डेटा और मौसम पूर्वानुमान मॉडल में डालकर अगले कुछ दिनों की आवश्यकता बताती है, और फिर cloud server उस पूर्वानुमान के आधार पर वाल्व तथा पंप वास्तव में चलाता है। उत्तर-पूर्वी चीन के meta-analysis में पारंपरिक सिंचाई और उर्वरक के स्थान पर drip irrigation के साथ fertigation देने से फसल उपज, water productivity और nitrogen use efficiency तीनों बढ़े (Li et al., 2021)। इसका अर्थ है कि पूरे खेत में पानी छिड़कने के बजाय ठीक जड़ों के सामने सही मात्रा देना बेहतर है।

Nebraska परीक्षण ने किसान की सामान्य विधि और साथ चलाए गए व्यावसायिक irrigation scheduling tool की तुलना की। समान उपज के साथ बहुत कम पानी लगा। सेंसर मानों को लगातार देखकर और प्रत्येक वृद्धि अवस्था पर निर्णय बदलने वाली AI scheduling से 87.97 प्रतिशत तक पानी

बचने की रिपोर्ट भी है। फिर भी यह किसी विशेष फसल और परिस्थिति में मिला ऊपरी मान है, इसलिए इसे हर खेत पर ज्यों का त्यों लागू नहीं माना जा सकता।

वैज्ञानिक भूमि, आकाश और फसल के बीच पानी के आदान-प्रदान के संबंध को Soil-Plant-Atmosphere Continuum (SPAC) कहते हैं। पानी मिट्टी से जड़ों, जड़ों से तने और पत्तियों, फिर पत्तियों से वापस हवा में लगातार बहता है। इस प्रवाह की गति केवल मिट्टी में पानी की मात्रा से तय नहीं होती। तापमान ऊँचा, हवा तेज और धूप प्रबल हो तो पानी पत्तियों से तेजी से वाष्पित होता है और जड़ें मिट्टी से उसी अनुपात में अधिक तेजी से पानी खींचती हैं। मिट्टी से वाष्पित और पत्तियों से वाष्पोत्सर्जित पानी का कुल योग Evapotranspiration (ET) कहलाता है, और सिंचाई प्रणाली तापमान, आर्द्रता, सौर विकिरण, हवा की गति तथा वर्षा लगातार मापकर इसका अनुमान लगाती है। capacitive या resistive moisture sensor मिट्टी की कई गहराइयों में दबाए जाते हैं, ताकि ऊपरी परत और जड़ों की वास्तविक गहराई दोनों की नमी देखी जा सके। प्रणाली इन डेटा परतों को जोड़कर उस क्षण खेत में बचे पानी का चित्र बनाती है।

फसल को अंकुरण से अंत तक पानी और उर्वरक की समान मात्रा नहीं चाहिए। बीज अंकुरित होने की अवस्था में थोड़ा पानी पर्याप्त है, लेकिन vegetative growth तेजी से बढ़ने पर माँग अचानक बढ़ती है। फूल आने के समय पानी कम हो तो फूल झड़ते हैं, और फल बनने तथा बढ़ने की अवस्था में थोड़ी कमी भी फल छोटा कर सकती है या उसमें दरार डाल सकती है। कुछ फसलों में पकने के पास पानी घटाना पड़ता है, तभी शर्करा बढ़ती है। शोधकर्ता इन परिवर्तनों को Development Volume Index (DVI, फसल के विकास स्तर को एक संख्या में दिखाने वाला सूचकांक) से व्यक्त करते हैं। फसल का वर्तमान विकास स्तर 0 से 1 के बीच संख्या में दिखाकर प्रत्येक अवस्था के water-stress threshold से मिलाया जाता है। नाइट्रोजन, फॉस्फोरस और पोटैशियम जैसे उर्वरक घटकों की सांद्रता तथा मात्रा भी हर वृद्धि अवस्था के लिए अलग गणना की जाती है। यह तरीका पूरे वर्ष समान मात्रा देने वाली एक समय-सारणी से मूल रूप से अलग है।

मनुष्य के लिए इन सभी भौतिक और वृद्धि डेटा की हाथ से गणना कठिन है। चर दस या बीस हो जाएँ तो यह समझना मुश्किल होता है कि वर्तमान स्थिति में कौन-सा निर्णायक है। पिछले कुछ वर्षों में ग्रीनहाउस और खुले खेतों में machine learning model ने यह गणना सँभालनी शुरू की है। सेंसर से आए मान और मौसम विभाग के पूर्वानुमान इनपुट के रूप में लेकर मॉडल तय करता है कि उस समय सिंचाई चाहिए या नहीं, और चाहिए तो कितने लीटर। मॉडल का चुनाव फसल, खेत के आकार, जुटाए गए डेटा के प्रकार और संग्रह अवधि पर निर्भर है।

Random Forest व्यापक रूप से उपयोग होने वाले मॉडलों में से एक है। नाम के अनुसार यह कई decision tree का जंगल बनाता है, हर tree के निर्णय का मतदान कराता है और बहुमत से निष्कर्ष निकालता है। मिट्टी नमी, तापमान, वायु आर्द्रता, वर्षा, मिट्टी का प्रकार और फसल जैसे परस्पर जुड़े चर देने पर भी यह स्थिर परिणाम देता है। भारत की एक शोध टीम ने model को web platform पर परखा, जहाँ उपयोगकर्ता खेत की स्थिति डालते थे और प्रणाली सिंचाई की जरूरत पर हाँ या नहीं में उत्तर देती थी, और जरूरत होने पर लगभग 25 लीटर की ठोस मात्रा भी बताती थी (Ajay Kumar et al.,

2026)। Indonesia में शोधकर्ताओं ने सरसों और lettuce वाले सब्जी भूखंडों में NodeMCU microcontroller, temperature sensor और real-time clock module लगाकर 1,200 records जुटाए और उसी Random Forest algorithm से सिंचाई valve अपने आप खोले तथा बंद किए (Pradasari et al., 2026)। Overfitting के प्रति प्रतिरोध, जिसमें model training data पर सही पर वास्तविक खेत में गलत हो जाता है, इस model के क्षेत्र में बार-बार चुने जाने का कारण दिखता है।

Decision Tree model उर्वरक मात्रा तय करने में मजबूत है। Sri Lanka के कृषि मंत्रालय के Horticultural Crop Research and Development Institute (HORDI) की पारंपरिक दिशानिर्देशों से बना cloud platform EcoGrow इसका उदाहरण है। फसल, क्षेत्र, मिट्टी के गुण, सिंचाई अंतराल, जलवायु क्षेत्र और उर्वरक समय डालने पर यह बताता है कि Urea, triple superphosphate (TSP) और muriate of potash (MOP) तीन उर्वरकों को प्रति hectare कितने kilogram मिलाना है। 32 बागवानी सब्जी फसलों के 1,535 records पर सीखकर model ने 97.39 प्रतिशत accuracy प्राप्त की और इसी परिणाम के आधार पर वास्तविक deployment के लिए चुना गया। EcoGrow एक ही screen पर पास के उर्वरक विक्रेता खोजने की सुविधा और उर्वरक विधि के प्रश्नों का संवाद की तरह अपने आप उत्तर देने वाला AI chatbot भी जोड़ता है। किसान स्वयं संख्या तालिका खोजे बिना screen पर दिखे अनुपात से उर्वरक मिला सकता है।

Linear Regression और Deep Neural Network (DNN, जटिल pattern सीखने के लिए कई परतों वाला artificial neural network) को साथ प्रयोग करने वाली विधि भी है। Linear Regression समय के साथ मिट्टी नमी घटने की दर को लगभग एक सीधी ढलान वाली रेखा के रूप में बनाता है। deep neural network इसमें एक तस्वीर जोड़ता है। मिट्टी की तस्वीर को alluvial soil, black soil, clay soil और red soil जैसे वर्गों में बाँटने वाले Convolutional Neural Network (CNN) के निर्णय को मौसम डेटा तथा नाइट्रोजन, फॉस्फोरस और पोटैशियम सांद्रता के साथ मिलाकर उर्वरक prescription दिया जाता है। मिट्टी का दृश्य रूप पहचानने और संख्यात्मक डेटा गणना करने की क्षमता एक model में मिलती है।

धान की खेती में Reinforcement Learning प्रयोग होती है। यह लगातार किसी action से मिली reward को देखती है और trial and error से बेहतर action स्वयं खोजती है। मौसम पूर्वानुमान मिलने पर model Markov Decision Process के अनुसार सबसे लाभकारी सिंचाई समय सीखता है, जिसमें अगला action केवल वर्तमान state देखकर तय किया जाता है। model DVI tracking को Alternate Wetting and Drying (AWD, धान के खेत को बार-बार भरने और मिट्टी दिखने तक सूखने देने की सिंचाई विधि) के साथ जोड़ता है, ताकि बालियाँ निकलने जैसे water-sensitive समय में बचत करते हुए ठीक आवश्यक मात्रा दी जा सके (Chen et al., 2021)। धान के खेत को लगातार भरा रखने वाली पारंपरिक विधि के विपरीत परिणाम बताते हैं कि नियंत्रित सूखने और भरने का चक्र धान के लिए अधिक लाभकारी है।

इन मॉडलों के वास्तविक खेत में चलने की प्रक्रिया लगभग समान है। sensor data के missing value भरे जाते हैं, संख्याएँ 0 से 1 के बीच normalize होती हैं और फसल या मिट्टी प्रकार जैसी text value

संख्या में बदली जाती हैं। तैयार data से model को server के बाहर पहले प्रशिक्षित किया जाता है और केवल प्रशिक्षित model cloud server पर चढ़ाया जाता है। field sensor node 1 से 15 मिनट के अंतराल पर नया मान server को भेजते हैं, और server मिलते ही inference चलाकर सिंचाई तथा उर्वरक का निर्णय करता है। निर्णय IoT gateway से relay switch चलाता है, और वास्तव में गया पानी pulse water meter से फिर मापा जाता है, जो हर बार पानी गुजरने पर एक छोटा electrical signal गिनता है, तथा database में दर्ज होता है। prediction, execution और फिर measurement का यह चक्र बिना रुके चलता रहे, तभी intelligent irrigation system बनता है।

खेत में दबे प्रत्येक sensor को देखने पर पता चलता है कि निर्णय कहाँ से शुरू होता है। FC-28 और YL-69 जैसे कई capacitive या resistive moisture sensor मिट्टी में अलग-अलग गहराइयों पर दबाए जाते हैं। ऊपरी मिट्टी और जड़ की गहराई का पानी अलग गति से सूखता है, इसलिए केवल एक स्थान का माप वास्तविक स्थिति छोड़ सकता है। DS18B20 temperature and humidity sensor तथा DS3231 real-time clock module जोड़कर यह भी दर्ज किया जाता है कि मिट्टी किस घंटे और मिनट पर किस तापमान तक पहुँची।

पोषक घोल खेती, यानी बिना मिट्टी के उर्वरक को पानी में घोलकर सीधे जड़ों तक पहुँचाने वाला hydroponic farm, अलग sensor set माँगती है। Electrical Conductivity (EC) sensor पानी में घुले कुल उर्वरक लवण की सांद्रता मापता है, pH sensor पानी की अम्लीय या क्षारीय स्थिति मापता है, नाइट्रोजन, फॉस्फोरस और पोटैशियम सांद्रता sensor तथा Total Dissolved Solids (TDS) sensor मिलकर पूरा set बनाते हैं। EC बहुत अधिक हो तो reverse osmosis जड़ कोशिकाओं से पानी बाहर खींचती है और जड़ सूखने जैसा नुकसान करती है, तथा बहुत कम हो तो पोषक तत्व अपर्याप्त रहते हैं। अम्लता हर फसल के लिए तय संकीर्ण सीमा से बाहर जाए तो जड़ों के पोषक तत्व सोखने के रास्ते ही बंद हो जाते हैं। पोषक घोल खेती की control program EC और pH के आधार पर गणना करती है कि water tank में कितना concentrated fertilizer और acidic solution डालना है, फिर मान सीमा से निकलते ही pump अपने आप चलाकर उसे ठीक करती है।

केवल खेत के sensor पर्याप्त नहीं हैं। प्रणाली एक साथ 40 वर्ष से अधिक के ऐतिहासिक मौसम database, soil survey data, 30,000 से अधिक फसल किस्मों की जानकारी और 7-day weather forecast लेती है। WeatherAPI, अमेरिकी अंतरिक्ष एजेंसी का NASA POWER और संयुक्त राष्ट्र खाद्य तथा कृषि संगठन का FAO CLIMWAT जैसी बाहरी सेवाओं से real-time temperature तथा rain probability मिलती है, इसलिए कल वर्षा का अनुमान हो तो आज रात की सिंचाई पहले ही घटाई जा सकती है। आकाश में unmanned aerial vehicle multispectral camera और visible-near infrared (Vis-NIR) spectroscopy equipment लेकर खेत के ऊपर कम ऊँचाई पर उड़ता है और फसल पत्तियों का रंग तथा reflected light दर्ज करता है। मनुष्य की आँख को पत्ती अभी स्वस्थ दिखती हो, तब भी नाइट्रोजन, पोटैशियम या मैग्नीशियम की कमी शुरू होने पर विशेष wavelength का reflection पहले बदल जाता है। इन reflection data को Diagnosis and Recommendation Integrated System (DRIS) से विश्लेषित करके दिखाई देने वाले लक्षण आने से पहले कमी वाला पोषक तत्व पहचाना जा सकता है। सेब बाग के unmanned aerial vehicle data को fertigation

model से जोड़ने वाले परीक्षण में पत्तियाँ तोड़कर प्रयोगशाला भेजे बिना आकाश से नाइट्रोजन की कमी पहचानी गई (Sun et al., 2023)।

खेत के माप से server तक संख्या का मार्ग भी कई परतों वाला है। ESP32, NodeMCU ESP8266, Arduino और PIC जैसे कम लागत microcontroller field node पर रहकर sensor value पढ़ते हैं। ये मान Wi-Fi, उद्योग में प्रचलित RS485 wired bus, कम ऊर्जा से बड़ा क्षेत्र कवर करने वाला LPWAN, चौथी पीढ़ी mobile communication module और कम ऊर्जा में छोटे संदेश भेजने वाले MQTT protocol से cloud तक जाते हैं। server की ओर Firebase real-time database या FastAPI और Flask जैसे backend होते हैं, और उनके ऊपर Scikit-learn, Pandas तथा NumPy जैसी library से लिखा machine learning code चलता है। किसान को यह पूरी प्रक्रिया जानने की जरूरत नहीं है। उसे website या mobile phone पर दिखता dashboard देखना भर है। भारत के Maharashtra में एक platform ने Marathi, Hindi और English तीन भाषाओं में interface दिखाया, ताकि सिंचाई तथा उर्वरक सलाह उन खेतों तक भी पहुँचे जहाँ English समझना कठिन था (Shriwas et al., 2026)।

cloud पर पहुँचा निर्णय वास्तविक प्रभाव के लिए खेत में लौटना चाहिए। server सिंचाई तय करे तो signal IoT gateway से खेत में लगे digital relay तक जाता है, और relay pump चालू या बंद करता तथा क्षेत्रवार valve खोलता या बंद करता है। पानी की धार की मोटाई बदल सकने वाले variable nozzle एक ही pipe से अलग क्षेत्रों को अलग मात्रा देते हैं। जिस नल को पहले मनुष्य हाथ से घुमाता था, उसे अब electrical signal खोलता और बंद करता है। हर चक्र में signal मिट्टी के sensor से शुरू होकर cloud का चक्कर लगाता और फिर मिट्टी में लौटता है।

कुछ प्रणालियाँ camera भी जोड़ती हैं। ESP32 sensor terminal, ESP32-CAM imaging sensor और FastAPI server को जोड़ने वाली self-adaptive irrigation system तापमान, आर्द्रता और मिट्टी नमी मापने के साथ camera से फसल की दशा भी देखती है (Ramya et al., 2026)। सिंचाई शुरू होने पर pulse water meter pipe से वास्तव में गुजरा पानी गिनकर वह संख्या server को वापस भेजता है। यह Closed-loop control संरचना है, जो आदेश देने पर नहीं रुकती बल्कि यह भी जाँचती है कि आदेश कितना पूरा हुआ। प्रक्रिया निर्देश देखकर पुर्जा जोड़ने और अंत में हाथ से जाँचने जैसी है कि screw वास्तव में कस गया है।

जापान में कृषि मशीन कंपनी Kubota ने इस प्रणाली को ZeroAgri नाम से व्यावसायिक बनाया। ग्रीनहाउस के भीतर soil sensor data और weather forecast cloud पर जाते हैं, जहाँ server सिंचाई तथा उर्वरक की सर्वोत्तम मात्रा निकालकर अपने आप देता है। mulch वाले citrus orchard में यही soil-moisture visualization technology उलटी दिशा में प्रयोग होती है। उद्देश्य पानी बचाना नहीं, बल्कि मिट्टी को जानबूझकर उचित सीमा तक सुखाकर पेड़ों पर हल्का stress डालना और फल की शर्करा बढ़ाना है। अधिक और कम पानी देने की तकनीकें समान sensor तथा cloud पर अलग उद्देश्यों के लिए चलती हैं।

प्रणाली ठीक चल रही है या नहीं, इसे कुछ संख्याएँ बताती हैं। सिंचाई की जरूरत या उर्वरक प्रकार का अनुमान देने वाले classification model का मूल्यांकन accuracy, precision और recall से होता है, और EcoGrow का 97.39 प्रतिशत accuracy का उदाहरण है। मिट्टी नमी जैसे continuous value का अनुमान लगाने वाले model वास्तविक और अनुमानित मान का अंतर Mean Absolute Error (MAE) तथा Root Mean Square Error (RMSE) से मापते हैं। ये संख्या कितनी भी अच्छी हों, खेती को वास्तविक लाभ हुआ या नहीं, इसे दूसरी कसौटियों से फिर मापना चाहिए। इनमें 1 cubic meter पानी से बनी फसल की मात्रा बताने वाली Water Use Efficiency (WUE) और 1 kilogram नाइट्रोजन उर्वरक से बढ़ा crop biomass बताने वाली Nitrogen Use Efficiency (NUE) शामिल हैं। वास्तव में बचा पानी और उर्वरक AI model की accuracy से अधिक सीधे इस तकनीक का मूल्य बताता है।

ठीक जड़ों के सामने तय मात्रा पहुँचाने की विधि Fertigation कहलाती है, जिसमें उर्वरक सिंचाई जल में घोलकर root zone तक दिया जाता है। यह शब्द irrigation और fertilization को जोड़कर बना है। पूरे मिट्टी तल पर उर्वरक फैलाकर पानी देने के विपरीत fertigation पानी में घुला उर्वरक drip line से केवल जड़ों वाले संकरे क्षेत्र तक भेजता है। Italy में मिट्टी रहित strawberry cultivation के परीक्षण में sensor आधारित fertigation management ने resource use और crop performance दोनों सुधारे (Bonelli et al., 2024)। उत्तर-पूर्वी चीन के खेत परीक्षणों में भी drip irrigation और fertilization technology मिलाने पर पोषक तत्व तथा पानी दोनों की उपयोग दक्षता बढ़ी (Fan et al., 2020)। पूरे खेत में पानी देने से उर्वरक भी उतना ही फैलता है और जड़ों की पहुँच से नीचे गया नाइट्रोजन पूरी तरह खो जाता है। संकरे क्षेत्र में सटीक आपूर्ति इस हानि को स्रोत पर रोकती है।

पत्ती तोड़े बिना पोषण स्थिति जानने का प्रयास केवल unmanned aerial vehicle की तस्वीरों तक सीमित नहीं है। roofed plastic house या glasshouse जैसी protected tomato cultivation में जल-बचत सिंचाई के साथ visible और near-infrared जोड़ने वाले hyperspectral imaging equipment से पत्ती के nitrogen content का nondestructive अनुमान परखा गया (Hu et al., 2025)। जल-बचत सिंचाई और पत्ती नाइट्रोजन को साथ देखने से पानी तथा पोषक तत्व की संयुक्त कमी जल्दी पकड़ी जा सकती है। पुराने तरीके में पत्ती तोड़कर analyzer तक ले जाने में समय लगता था और तब तक फसल अगली अवस्था में पहुँच सकती थी। camera से पत्ती पर प्रकाश डालकर ही नाइट्रोजन का अनुमान हो जाए तो सिंचाई और उर्वरक का निर्णय एक-दो दिन देर से नहीं, तुरंत दिया जा सकता है।

महँगा server न खरीद सकने वाले छोटे खेतों की ओर भी रुझान है। कम लागत और कम बिजली वाले edge AI तथा TinyML को संसाधन-विहीन खेतों में लगाने की विधियाँ व्यवस्थित की जा रही हैं, जहाँ TinyML इतना हल्का model है कि बहुत छोटे microcontroller पर भी चलता है। हर बार data cloud को भेजकर उत्तर लेने के बजाय निर्णय खेत के छोटे उपकरण में ही पूरा हो जाता है। दूर-दराज़ क्षेत्र में network टूटने या Internet शुल्क का भार झेलने वाले किसान के लिए onsite closed AI अधिक उपयोगी है। IoT और machine learning जोड़ने वाले smart irrigation अनुसंधान लगातार पुष्टि कर रहे हैं कि कम लागत sensor तथा microcontroller से भी सिंचाई अपने आप चलाई जा सकती है

(Kathilkar et al., 2026)। उपकरण मूल्य काफी घट चुका है और अब शेष प्रश्न उसे चला सकने वाले लोगों की संख्या बढ़ाने का है।

खेत में लंबे समय दबे sensor का प्रदर्शन समय के साथ बदलता है। बार-बार उर्वरक मिलने से मिट्टी में लवण बढ़ता है, और नमी तथा biofilm sensor surface पर जमकर moisture और EC sensor की sensitivity धीरे घटाते हैं। इसे Drift कहते हैं, जिसमें माप समय के साथ मूल मानक से हटता जाता है और स्थापना के समय सही value कुछ महीने बाद वास्तविकता से कम या अधिक हो जाती है। कई सप्ताह drift न पकड़ा जाए तो प्रणाली पहले से गीली मिट्टी में और पानी देने का आदेश जारी रख सकती है। इसे रोकने के लिए software से स्वयं calibration करने वाले virtual sensor और corrosion-resistant nanomaterial sensor विकसित किए जा रहे हैं। यह प्रयास समय-समय पर धुंधले चश्मे को पोंछने के बजाय शुरू से धुंधला न होने वाला पदार्थ लगाने जैसा है।

एक sensor जितने क्षेत्र का प्रतिनिधित्व करता है, वह कल्पना से कम है। बड़े खेत या ग्रीनहाउस में मिट्टी, ढलान और कैनोपी घनत्व क्षेत्रवार अलग होते हैं, इसलिए उसी समय कहीं गीलापन और कहीं सूखापन होता है। एक बिंदु sensor पर विश्वास करके पूरे खेत को समान पानी देने से गीला स्थान और गीला तथा सूखा स्थान फिर भी सूखा रहता है। एक ही ग्रीनहाउस में दरवाज़े के पास और भीतर की पंक्तियों को अलग धूप तथा हवा मिलती है, इसलिए एक ही भवन होने के कारण एक sensor पर्याप्त नहीं माना जा सकता। इसी कारण unmanned aerial vehicle की real-time multispectral image तथा spatial interpolation को ground sensor data से जोड़ने वाली multi-scale fusion अगली तकनीकी समस्या मानी जाती है।

उपकरण सस्ता होने से adoption अपने आप आसान नहीं होता। ESP32 जैसे components बहुत सस्ते हुए हैं, पर उन्हें जोड़ना और farm के लिए model को फिर calibrate करना श्रम माँगता है। पुरानी खेती से पूरी तरह अलग screen और संख्या सीखने का भार वास्तविक adoption में दीवार बनता है। इस दीवार को घटाने के लिए intuitive mobile screen, AI chatbot और बहुभाषी voice guidance साथ जोड़ने वाले परीक्षण चल रहे हैं। मशीन की कीमत से उसे सीखने की लागत अब भी कहीं अधिक हो सकती है।

केवल पहले जमा data पर सीखा model कभी न देखी स्थिति में डगमगाता है। कई वर्षों में न आई गर्मी या अचानक सूखा हो तो अतीत पर स्थिर model गलत उत्तर दे सकता है। इसे सुधारने के लिए field data लगातार लेकर स्वयं update होने वाली online adaptive learning विधि का अध्ययन हो रहा है। पौधे की पूरी physiological response का simulation करने वाले DSSAT या AquaCrop जैसे dynamic crop model जोड़ने पर पानी बचाने और उपज सुरक्षित रखने का multi-objective optimization साथ किया जा सकता है। sensor और कृत्रिम बुद्धिमत्ता कितने भी उन्नत हों, सामने हर बार अलग रूप में आने वाला मौसम रहता है।

कई उद्देश्यों वाली गणना केवल सिद्धांत नहीं रहती, बल्कि वास्तविक खेती स्थल के परीक्षण भूखंड में पहले सत्यापित होती है। अनेक अध्ययन समानांतर control दोहराते हैं, जिसमें एक greenhouse plot को पुराने तरीके से और पास वाले को केवल AI की गणना से पानी देकर उपज तथा पानी की तुलना की जाती

है। ऐसे control जमा होने पर ही विशेष परिस्थिति के ऊपरी मान और अधिकतर खेतों में अपेक्षित औसत बचत अलग की जा सकती है। Nebraska जैसे मामलों की ईमानदार संख्यात्मक पुष्टि प्रक्रिया के बिना नई तकनीक किसान का विश्वास कठिनाई से जीतती है।

Soil-Plant-Atmosphere Continuum में भौतिक मानों का लगातार मापन, वृद्धि अवस्था का modeling, कई machine learning model की inference और cloud decision एक-दूसरे पर चढ़कर valve खोलने या बंद करने का एक आदेश बनते हैं। पानी और उर्वरक बचाने का निर्णय मिट्टी के प्रत्येक sensor की संख्या और उसे पढ़ने वाला code करता है। अगली सुबह किसान phone पर देखता है कि पिछली रात किस समय कितने liter पानी गया और केवल graph में असामान्य उछाल होने पर जूते पहनकर खेत में जाता है। हर सिंचाई में किसान की भूमिका प्रणाली के निर्णय के बाद जाँच करने तक सीमित हो जाती है।

स्रोत और संदर्भ

शोध पत्र

1. Ajay Kumar, C. V. R., Supriya, L., Navya Sree, P., & Santosh Kumar, M. (2026). Adaptive machine learning framework for precision driven smart irrigation optimization. *World Journal of Advanced Research and Reviews*, 30(1), 421-428. <https://doi.org/10.30574/wjarr.2026.30.1.0841>
2. Bonelli, L., Montesano, F. F., D'Imperio, M., Gonnella, M., Boari, A., Leoni, B., & Serio, F. (2024). Sensor-based fertigation management enhances resource utilization and crop performance in soilless strawberry cultivation. *Agronomy*, 14(3), 465. <https://doi.org/10.3390/agronomy14030465>
3. Chen, M., Cui, Y., Wang, X., Xie, H., Liu, F., Luo, T., Zheng, S., & Luo, Y. (2021). A reinforcement learning approach to irrigation decision-making for rice using weather forecasts. *Agricultural Water Management*, 250, 106838. <https://doi.org/10.1016/j.agwat.2021.106838>
4. EcoGrow Development Team, & Sri Lanka HORDI. (2026). EcoGrow: Cloud-enabled machine learning driven fertilizer recommendation platform for horticultural vegetable crops in Sri Lanka. *International Journal of Advanced Networking and Applications*, 17(6), 7236-7243. <https://doi.org/10.35444/IJANA.2026.17607>
5. Fan, J., Lu, X., Gu, S., & Guo, X. (2020). Improving nutrient and water use efficiencies using water-drip irrigation and fertilization technology in Northeast China. *Agricultural Water Management*, 241, 106352. <https://doi.org/10.1016/j.agwat.2020.106352>
6. Hu, C., Zhao, T., Duan, Y., Zhang, Y., Wang, X., Li, J., & Zhang, G. (2025). Visible-near infrared hyperspectral imaging for non-destructive estimation of leaf nitrogen content under water-saving irrigation in protected tomato cultivation. *Frontiers in Plant Science*, 16, 1676457. <https://doi.org/10.3389/fpls.2025.1676457>
7. Kathilkar, S., Chavan, A., Sahu, K., Phalke, D., & Shedbale, S. (2026). Smart irrigation system using IoT device and machine learning. *International Journal for Research in Applied Science & Engineering Technology*, 14(5), 83111. <https://doi.org/10.22214/ijraset.2026.83111>
8. Li, H., Mei, X., Wang, J., Huang, F., Hao, W., & Li, B. (2021). Drip fertigation significantly increased crop yield, water productivity, and nitrogen use efficiency compared with traditional irrigation and fertilization practices: A meta-analysis in China. *Agricultural Water Management*, 244, 106534. <https://doi.org/10.1016/j.agwat.2020.106534>
9. Pradasari, N. I., Wahyudi, E., Atimi, R. L., Muhammad, A., Darmanto, & Pratiwi, I. (2026). IoT and machine learning-based smart watering model for water optimization in vegetable gardens. *Zetroem*, 8(2), 140-147.

10. Ramya, S. Y., Aravinda, T. V., Krishnareddy, K. R., & Ramesh, B. E. (2026). AI-driven self-adaptive smart irrigation system using IoT, computer vision and machine learning. International Research Journal on Advanced Engineering Hub, 4(6), 4074-4080. <https://doi.org/10.47392/IRJAEH.2026.0526>
11. Shriwas, M. K., Sindhi, K., & Thakre, P. (2026). Deep learning-based multilingual smart farming system for crop recommendation and nutrient monitoring. African Journal of Applied Research, 12(5), 260-280.
12. Sun, G., Hu, T., Chen, S., Sun, J., Zhang, J., Ye, R., & Liu, J. (2023). Using UAV-based multispectral remote sensing imagery combined with DRIS method to diagnose leaf nitrogen nutrition status in a fertigated apple orchard. Precision Agriculture, 24(6), 2522-2548. <https://doi.org/10.1007/s11119-023-10051-7>

व्याख्यान और वीडियो सामग्री

1. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026 Global AgriFood Innovation Roadshow: China Agricultural University Special Session [Video]. YouTube. <https://www.youtube.com/watch?v=SS2qVda11nw>
2. 農業農村情報通信環境整備準備会. (2025). 気候変動と農業の未来: ICT・IoT活用によるデータ駆動型農業の重要性 [ऑनलाइन संगोष्ठी वीडियो]. YouTube. <https://www.youtube.com/watch?v=iqLmEFT1wZo>
3. 農林水産省(MAFF). (2025). 中国四国地域スマート農業推進フォーラム2025 [Video]. YouTube. <https://www.youtube.com/watch?v=16rooPtFOMM>
4. Agricultural, Life & Environmental Sciences. (2026). Bentley Lecture in Sustainable Agriculture (2025) | AI, Machine Learning and the future of soils. YouTube. <https://www.youtube.com/watch?v=ct0VrqKTmVU>
5. Daugherty Water for Food Global Institute. (2025). Artificial Intelligence for Climate Smart Solution and Resilient Agriculture. (Archive). YouTube. <https://www.youtube.com/watch?v=n1MYEcAeMRU>
6. Global Soil Biodiversity Initiative. (2025). Harnessing AI to measure soil biodiversity. YouTube. <https://www.youtube.com/watch?v=AT29crluxow>
7. 気象ビジネス推進コンソーシアムWXBC. (2026). 2025年度 農研機構メッシュ農業気象データ分析チャレンジ!. YouTube. <https://www.youtube.com/watch?v=w1SrS3iwA4E>

रिपोर्ट और समाचार

1. The Fence Post. (2026). 2026 Spring Homeland: Where artificial intelligence meets water stewardship in agriculture. <https://www.thefencepost.com/news/2026-spring-homeland-where-artificial-intelligence-meets-water-stewardship-in-agriculture/>
2. ScienceDirect. (2025). [Nebraska के क्षेत्रीय तुलनात्मक परीक्षण और AI सचिवाई समय-सारणी से संबंधित सामग्री]. <https://www.sciencedirect.com/science/article/pii/S2772375525002151>
3. arXiv. (2026). [कृषि क्षेत्र में कम लागत, कम ऊर्जा edge AI और TinyML लगाने की प्रवृत्ति से संबंधित सामग्री]. <https://arxiv.org/pdf/2603.15085>

4.2

स्थान-समय डेटा संलयन तथा वितरण और गुणवत्ता प्रबंधन

सुबह चार बजे एक refrigerated truck देश के दक्षिणी भाग में कृषि उपज logistics center के unloading bay में आता है। strawberry के हर pallet box पर नाखून के आकार का electronic data logger लगा है, और truck का दरवाज़ा खुलते ही display का मान हिमांक के पास से लगभग 10 degree Celsius तक उछलता है, फिर कुछ मिनट बाद दरवाज़ा बंद होने पर धीरे-धीरे नीचे आता है। तापमान का ऐसा हर छोटा बदलाव strawberry की बची shelf life वास्तव में घटाता है। खेत से निकलने के बाद consumer refrigerator तक पहुँचने के बीच temperature, humidity और gas concentration sensor हर चरण बदलते समय data का आदान-प्रदान करते हैं।

समस्या यह है कि satellite, drone और ground sensor अलग चक्र में data लेते हैं। satellite 4 से 10 दिन में एक बार उसी orbit पर लौटकर एक नज़र में सैकड़ों hectare देखता है। drone केवल उस दिन चलता है जब कोई उसे उड़ाने का निर्णय करे, लेकिन हथेली जितने छोटे क्षेत्र की भी सूक्ष्म तस्वीर लेता है। खेत और greenhouse के ground sensor कुछ सेकंड के अंतराल पर बिना रुके मान देते हैं। तीनों उपकरणों के record एक-दूसरे पर रखने पर उनके समय और स्थान के scale अलग होते हैं, इसलिए उन्हें एक सुसंगत चित्र की तरह नहीं पढ़ा जा सकता। scale का यही अंतर precision agriculture में yield forecast और disaster early warning के बार-बार गलत होने का कारण है।

industry इन scale को मिलाने के काम को climate-smart agriculture, यानी CSA, data pipeline कहती है। satellite की optical और multispectral image, drone की high-resolution image तथा ground sensor के real-time value को समान coordinate और time scale पर स्थानिक तथा कालिक रूप से मिलाने के बाद hybrid deep learning और Graph Neural Network (GNN) उन्हें एक प्रवाह में जोड़ते हैं, जिसमें GNN हर खेत को node और पास के खेत से संबंध को line दिखाने वाली mesh structure से सीखता है। मिला हुआ data उन क्षेत्रों को पहले पहचानता है जहाँ drought stress या pest and disease फैलने की संभावना है, फिर उस वर्ष के weather scenario में उपयुक्त planting और harvest time तथा expected yield निकालता है।

उपयोग में मौजूद कुछ model देखने पर इस network की संरचना समझना आसान है। AMSTF, यानी Adaptive Multispectral Spatiotemporal Fusion model, और GNN को Long Short-Term Memory neural network (LSTM) के साथ जोड़ने वाला hybrid model अलग समय पर satellite तथा drone से मिली multispectral image को ground weather और soil time series के साथ मिलाकर crop growth के spatial-temporal change और final yield का सटीक अनुमान लगाता है। XGBoost, CatBoost और LSTM तीन algorithm जोड़ने वाला fusion model temperature,

rainfall और humidity जैसी weather time series, pesticide input तथा Normalized Difference Vegetation Index (NDVI) से regression के माध्यम से yield का पूर्वानुमान करता है। Vision Transformer (ViT) वाला दूसरा pipeline satellite, drone, ground sensor और field worker के smartphone camera तक की image को छोटे patch में बदलता है, self-attention से उनके परस्पर संबंध की निकटता सीखता है और field-level crop diagnosis map तथा climate-response prescription बनाता है। इन model के परीक्षण में measured और predicted value के मेल का coefficient of determination सामान्यतः 0.85 से 0.95 था, और एक report में crop boundary को गलत zone में बाँटने से हुई 9.8 से 12.3 प्रतिशत spatial misclassification rate घटकर 5.4 प्रतिशत हो गई। इन संख्याओं के पीछे अलग scale वाले तीन sensor की reading को एक साझा आधार पर रखने का कठिन alignment work है।

self-attention शब्द अपरिचित लग सकता है, लेकिन classroom group project इसका सहज उदाहरण देता है। प्रक्रिया ऐसी है जैसे हर student तय करे कि दूसरों की बात कितनी ध्यान से सुननी है और धीरे-धीरे अपनी राय सुधारे। model तय करता है कि satellite image का कोई area drone image के दूसरे area और ground sensor reading से कितना जुड़ा है, इन संबंधों को weight देता है और final decision में weight का उपयोग करता है। यह पारंपरिक statistical model से अलग है, क्योंकि पहले से मनुष्य के बनाए नियम नहीं, बल्कि data model को सिखाता है कि किस पर अधिक ध्यान देना है।

एक screen से यह आसानी से समझ आता है कि overlay map वास्तविकता में कैसे प्रयोग होता है। farm manager के tablet पर पूरा खेत हरे, पीले और लाल रंग के चिह्नीदार map की तरह दिखता है, और red zone उस क्षेत्र को बताता है जहाँ satellite ने water stress पाया और drone की close-up image में मुड़ी पत्तियों ने उसकी पुष्टि की। ground sensor भी उस zone की soil moisture threshold से नीचे होने की पुष्टि करे तो model चेतावनी देता है कि तीन दिनों में उसी क्षेत्र से pest या disease फैलना शुरू हो सकता है। precision agriculture data pipeline का व्यावहारिक सार यह है कि एक warning बनाने के लिए satellite, drone और ground sensor के प्रमाण की तीन परतें मिलनी चाहिए।

यह pipeline satellite, drone और ground sensor तीन प्रणालियों के physical equipment पर चलती है। satellite की ओर Sentinel-2 और Landsat जैसे multispectral satellite एक बार में 1,000 hectare से अधिक farmland देखते हैं और नियमित रूप से NDVI, GNDVI तथा SAVI जैसे vegetation index और soil moisture distribution निकालते हैं। satellite sensor की ताकत यह है कि इतने बड़े क्षेत्र की निगरानी drone की लागत के लगभग 20 प्रतिशत में हो जाती है। इसके विपरीत drone छोटे क्षेत्र को बहुत अधिक विस्तार से जाँचता है। प्रति pixel 5 centimeter से कम ground sampling distance पर वह near-infrared और red-edge band, कभी-कभी hyperspectral image भी लेता है, और असामान्य रूप से मुरझाए zone, खरपतवार से भरे zone तथा खेत के भीतर leaf morphology के अंतर को एक map में रखता है। इस map को prescription map कहते हैं, और

पूरे खेत में समान मात्रा देने के पुराने तरीके के विपरीत यह किसान को केवल आवश्यक स्थान पर आवश्यक मात्रा में intervention बताता है।

भूमि पर greenhouse और खुले खेत में फैले sensor temperature, humidity, carbon dioxide concentration, soil moisture, Electrical Conductivity (EC), acidity (pH) और light को real time में मापते हैं। इसके बाद 40 वर्षों के historical weather record, weekly forecast, fine-grid agricultural weather data, soil survey data और 30,000 से अधिक crop variety वाले database को cloud pipeline से जोड़ा जाता है। केवल एक खेत की reading देखने वाले समय की तुलना में किसान अब nationwide weather map और variety trait table साथ खोलकर उस खेत को उनके भीतर रख सकता है। farm machinery भी बदल गई है। जापान के ऐसे मामले हैं जहाँ tea plant trimming machine जैसे specialized farm equipment पर machine control का छोटा computer PLC, GPS और automatic steering sensor लगाकर operation time, travel distance, speed, working height तथा working width अपने आप cloud पर भेजे जाते हैं। Kawasaki Kiko, Ochiai Cutlery Manufacturing और Terada Seisakusho वाले tea plantation management project में operation record जमा होने पर farms के work characteristics और field condition का अंतर दिखाई देने लगा। satellite और drone आकाश से नीचे देखते हैं, जबकि machinery record जमीन पर छोड़े रास्ते को सुरक्षित रखते हैं और बाद में distribution history trace करने में काम आते हैं।

इतनी अलग विशेषताओं वाला data एक स्थान पर आने के बाद उसे संसाधित करना पड़ता है। satellite image में cloud cover से बने gap और sensor के कुछ समय रुकने से छूटे value adaptive Kalman filter नामक statistical technique से भरे जाते हैं और noise हटाया जाता है। फिर data को normalize करके value 0 से 1 के बीच लाए जाते हैं, और image को rotate या flip करके sample बढ़ाने तथा training data को एक ओर झुकने से रोकने वाला augmentation किया जाता है, जिससे model में जाने से पहले की तैयारी पूरी होती है। यहाँ तक खेत में फसल बढ़ने की कहानी है। harvest होकर box में जाने के क्षण से वही logic अलग target पर लागू होता है। अंतर यह है कि अब प्रणाली growth के बजाय decay मापती है और vegetation index के बजाय temperature तथा ethylene gas देखती है, जबकि अलग device के scale जोड़कर decision तक पहुँचने का सिद्धांत समान रहता है।

strawberry box पर लगा data logger केवल temperature मापता है। commercial cold-chain management box में अब thermometer के साथ hygrometer, carbon dioxide sensor, ethylene gas sensor और freshness बताने के लिए रंग बदलने वाला hydrophobic indicator label भी बढ़ रहे हैं। गूदा काटे बिना sugar content और acidity बताने वाला near-infrared spectrometer तथा surface damage खोजने वाला 3D vision camera भी इस उपकरण समूह में जुड़ गए हैं। इन device की साझा बात है कि वे surface को छूते या नुकसान नहीं पहुँचाते। truck के भीतर strawberry tray का box खोले बिना sugar content, damage और freshness पढ़ी जा सकती है।

इन device के signal को एक decision में जोड़ने वाला प्रमुख model cooperative-attention convolutional recurrent network, यानी Co-ACRN, है। चीन के Jiangnan University के शोधकर्ताओं ने 2026 में report किया कि model cold-chain transport के दौरान जमा temperature, humidity, carbon dioxide तथा ethylene time-series data और hydrophobic indicator label image साथ लेता है। आगे का cooperative-attention module image और sensor stream की time axis मिलाता है, जबकि पीछे का self-attention module aligned information को फिर देखकर whole context को शामिल करता है और surface को नुकसान पहुँचाए बिना fruit तथा vegetable का real-time freshness score देता है। freshness score देने का formula सीधा है। यह total surface area में defect वाले प्रतिशत को 100 से घटाता है। defect न होने पर score 100 के पास रहता है और आधा खराब होने पर लगभग 50 तक गिरता है।

इस प्रकार का multisensor fusion Jiangnan University के मामले तक सीमित नहीं है। temperature, relative humidity, ethylene, carbon dioxide, box को मिला vibration, location data, image feature और spectroscopy signal मिलाने वाली विधियाँ shelf-life prediction model में सामान्य हो चुकी हैं। industry assessment प्रायः computer-vision grading, IoT आधारित cold-chain monitoring और shelf-life prediction तीन applications को तत्काल शुरुआती adoption के लिए उपयुक्त बताता है। camera और sensor मौजूदा logistics facility को बदले बिना ऊपर जोड़े जा सकते हैं, लेकिन cultivation method बदलने में कहीं अधिक समय लगता है। theory प्रभावशाली हो तब भी technology को pipe, refrigerator और truck जैसे पुराने hardware पर रखना पड़ता है, इसलिए adoption पहले वहाँ होता है जहाँ intervention आसान है।

अमेरिकी cold-chain equipment company DeltaTrak ने predictive shelf-life analytics को cold-chain freshness management का तरीका बदलने वाली तकनीक बताया है। ऐसी predictive shelf-life analysis प्रायः refrigerated container की sensor reading real time में जुटाती है और shipper तथा retailer को पहले बताती है कि हर box के store shelf तक पहुँचने से पहले कितना समय बचा है। खजूर जैसे फल, जिनके भीतर की दशा केवल बाहर देखकर समझना कठिन है, अलग तरीका माँगते हैं। शोध में गूदा पकते समय निकलने वाले odor molecule के संयोजन को multichannel gas sensor से पढ़कर shelf life का अनुमान देने वाले machine learning model में डालने की जानकारी दी गई है। पका और खराब फल odor molecule के अलग संयोजन छोड़ता है, और machine इस अंतर को gas sensor के electrical signal pattern के रूप में पढ़ती है।

grading में विधियों का एक और संयोजन दिखाई देता है। जापान के Niigata प्रांत के Western pear brand Le Lectier के लिए GCBLOCK के साथ Mask R-CNN नामक image segmentation model नाशपाती की surface के defect और contaminated area को pixel स्तर पर अलग करता है। निकाले गए contaminated area का अनुपात सीधे grade नहीं बनता, बल्कि पहले fuzzy logic नामक विधि से गुजरता है। fuzzy logic गर्म और ठंडे जैसी साफ सीमा में न बँटने वाली स्थिति संभालने की computational method है। 3 प्रतिशत contamination को स्पष्ट high grade और 30 प्रतिशत

को स्पष्ट low grade कहना आसान है, लेकिन बीच के अस्पष्ट मानों में human inspector की आँख के निर्णय जैसी कई grades में probability बाँटी जाती है। प्राप्त value expert experience से निकले नियम वाले fuzzy inference system में जाता है, जो final grade अपने आप देता है।

अंतिम grade चार स्तरों में बँटते हैं, लाल मुहर वाले सर्वोच्च Aka-shu से एक स्तर नीचे Ao-shu, स्वीकार्य Ryo और commercial product के रूप में कठिन Mu-in तक। पहले लोग पूरे दिन हर नाशपाती को घुमाकर देखते और stamp लगाते थे, अब camera और fuzzy rule यह काम करते हैं। हर फल की विशेषता अलग होने से industry एक समान model इस्तेमाल नहीं करती। skin thickness, color और softening rate में अलग mango, tomato और kiwifruit जैसे फलों पर DenseNet तथा EfficientNet family model लगाकर बाहरी रूप और अंदर की ripeness दोनों का grade दिया जाता है। नाशपाती में surface defect, tomato में color और kiwifruit में firmness अधिक महत्वपूर्ण है, इसलिए criteria भी फल के अनुसार बदलते हैं।

इन assessment model के test result प्रायः काफी ऊँचे होते हैं। accuracy, precision, recall और F1 score जैसे classification performance indicator अक्सर 95 से 99 प्रतिशत के बीच होते हैं, और defect area कितनी सही तरह segment हुआ यह बताने वाले mAP तथा IoU भी report किए जाते हैं। mAP कई threshold पर model द्वारा मिले defect location और वास्तविक defect location के overlap का average देता है, जबकि IoU दो क्षेत्रों के overlapping area को उनके combined area से भाग देता है, इसलिए 1 के पास value अधिक precise segmentation बताता है। संख्यात्मक रूप से machine का score मनुष्य की पुरानी visual sorting के बराबर स्तर तक पहुँच गया है।

यह बदलाव labor घटाने से आगे जाता दिखता है। human inspector का concentration सुबह और दोपहर अलग होता है, और बार-बार काम से बनी आदत एक ही नाशपाती का grade अलग दिनों में थोड़ा अलग कर सकती है। camera और fuzzy rule थकते नहीं और पूरे दिन तथा पूरे season समान standard रखते हैं। फिर भी बाहर से ठीक दिखते पर भीतर नरम फल को पहचानने जैसी वर्षों के अनुभव से बनी सूक्ष्म समझ को machine पूरी तरह दोहरा सकेगी या नहीं, यह अभी देखना है।

grade मिलने के बाद agricultural product सीधे inventory और traceability management में जाता है। खेत या greenhouse से harvest उत्पाद basket या steel rack के अनुसार समूहित होते हैं और हर unit पर barcode, QR code या smart tag लगाया जाता है। Taiwan के Kaohsiung का smart agriculture project इसका प्रमुख उदाहरण है। project नीली plastic basket या steel rack पर tag लगाकर field-batch inventory को real time में database पर भेजता है और greenhouse environment alert को सरकारी agricultural production and distribution traceability system से अपने आप जोड़ता है। multilevel cultivation rack और logistics warehouse में space utilization सुधारने की report भी है। हर tag किसी box के source और travel route को सत्यापित करने का रास्ता देता है।

incident होने पर tracking function उपयोगी होता है। TaiwanICDF ने 2025 में एक मामला बताया जिसमें farm production data और food ingredient supplier data को एक commercial-area map platform से जोड़ा गया था। school meal में food safety problem आए तो system तुरंत trace करता है कि उस भोजन की उपज किस किसान के खेत से आई थी। फिर उसी farm का product पाने वाले अन्य सभी school पहचानकर तुरंत preventive action लिया जा सकता है। तरीका incident के बाद cause खोजने से बदलकर उसके फैलने से पहले related scope पहचानने की ओर गया है।

produce batch number scan करने पर box का खेत, harvest date, उसके truck और logistics warehouse screen पर आते हैं। गलत भेजी book या manufactured goods recall किए जा सकते हैं, लेकिन खराब produce table तक पहुँचने के बाद वापस नहीं लिया जा सकता। इसलिए traceability system का मूल्य incident के बाद cleanup से अधिक इस बात में है कि फैलने से पहले वह incident को कितनी जल्दी छोटे scope में रोकता है।

केवल shelf-life prediction value अधूरी जानकारी है। अब ऐसे modular system सामने आ रहे हैं जो shelf-life prediction, अमेरिकी Food Safety Modernization Act की traceability और carbon-emission accounting को एक data foundation पर रखते हैं, ताकि producer, shipper और retailer समान screen देख सकें। कई अलग system में login करने की प्रथा एक data foundation तक पहुँच में बदल गई है। लगभग 2018 में predictive analytics केंद्रित postharvest management technology बाद में blockchain और digital twin की ओर बढ़ी, जबकि lightweight artificial intelligence TinyML सीमित बिजली या communication infrastructure वाले स्थल पर traceability तथा information disclosure को सहारा देती है। shelf life, history और carbon emission एक screen पर आने से एक ही box के लिए freshness deterioration risk और traceability gap एक ही समय दिखने लगे हैं।

logistics warehouse में YOLOv5 और YOLOv8 जैसे deep-learning object-detection model real time में आने-जाने वाले box गिनते हैं और result को पूरे warehouse की virtual replica वाले digital twin से जोड़ते हैं। office monitor के सामने बैठा manager भी हर rack पर क्या और कितना रखा है तथा किस zone का temperature या humidity threshold से बाहर है, यह देख सकता है। problem दिखे तो manager पहले virtual model पर intervention परखकर परिणाम सही होने पर physical warehouse में वही action ले सकता है।

digital twin logistics warehouse की वास्तविक अवस्था दोहराने वाला virtual model है। warehouse में आया हर नया box और temperature थोड़ा बढ़ने वाला हर rack real time में virtual screen पर दिखता है, और manager किसी भी area को zoom कर सकता है। physical thermometer और virtual screen की संख्या अलग होने लगे तो यह अंतर sensor failure या communication delay का संकेत हो सकता है। इससे physical warehouse और virtual model को एक साथ देखा जा सकता है।

भोर से पहले logistics center में उछला temperature value अंततः इस virtual screen पर कहीं एक point बनता है। truck का door खुलने पर थोड़ी देर का spike मनुष्य को छोटा लग सकता है, लेकिन digital twin पर record रहकर manager को तुलना करने देता है कि उस दिन door कितनी बार खुला और temperature दूसरे truck से अधिक बार बदला या नहीं। किसी truck में असामान्य रूप से खराब pattern दिखे तो record उसके refrigeration equipment की जाँच करा सकता है। अलग-अलग reading में न दिखने वाला pattern जमा होने पर सामने आता है।

जापान के Kochi प्रांत का Internet of Plants (IoP) SAWACHI cloud इस विचार को पूरे क्षेत्र तक फैलाता है। यह 1,600 से अधिक greenhouse का environment data और 3,000 से अधिक farms का shipping data जापान के national agricultural data platform WAGRI से जोड़ता है और 16 analytical model चलाकर क्षेत्र के कुल shipment का पूर्वानुमान तथा distribution schedule बनाता है। पहले हर farm अलग दर्ज करता था, अब shipping information पूरे Kochi प्रांत का कुल shipment बताने और distribution schedule समायोजित करने वाला data बन गया है। हर farm द्वारा अगले सप्ताह का अपना shipment अनुमान लगाने की पुरानी प्रथा की तुलना में यह तरीका पूरे क्षेत्र की supply और demand साथ देखकर उसी अनुसार क्रम तय करने के अधिक निकट है।

इन मामलों में बार-बार आने वाले कुछ metrics को संक्षेप में रखा जा सकता है। इनमें multilevel cultivation rack और logistics warehouse कितना भरा है यह मापने वाला space utilization rate, problem आने पर producing farm और delivery destination तक सफल trace हुए मामलों का भाग बताने वाला production and distribution traceability rate, तथा सटीक prescription और management से pesticide और energy use में कमी मापने वाला reduction rate शामिल हैं। Kaohsiung के cultivation rack और Taiwan school-meal traceability case के result प्रायः इन्हीं तीन में से किसी एक संख्या में बदले जाते हैं। हर संख्या अकेली छोटी लग सकती है, लेकिन warehouse space को बार-बार थोड़ा अधिक इस्तेमाल करना और incident को कई दिन पहले पकड़ना farm के कुल profit पर ठोस प्रभाव डालता है।

नाशपाती, mango और strawberry के लिए अलग model प्रशिक्षित करना इस क्षेत्र की छिपी लागत है। दस से अधिक product उगाने वाले production area को दस से अधिक model बनाने और हर season नए data से प्रत्येक को फिर प्रशिक्षित करने की जरूरत पड़ती है। जितनी crops उतने model बनाए रखने और update करने का भार बड़ा है, और बड़े distributor के अलावा दूसरी company के लिए cost सहना कठिन हो सकता है। इसलिए research कई fruits पर चलने वाला एक foundation model बनाने और केवल हर fruit के final decision stage को समायोजित करने की दिशा में जाती दिखती है।

prediction, grading और traceability कितने भी precise हों, final decision मनुष्य करता है। model Mu-in grade दे या तीन दिनों में pest या disease फैलने की warning दे, field manager ही तय करता है कि box फेंकना है या control agent कब लगाना है। data pipeline, grading model और distribution traceability system उस decision के लिए information जल्दी तथा

सही तैयार करते हैं, जबकि अगले चरण में क्या और कैसे करना है, यह लोग तय करते हैं। technology ने judgment के लिए उपलब्ध सामग्री की quality और speed बदली है, पर judgment स्वयं human responsibility है।

अब तक के case Taiwan, China, Japan और United States तक फैले हैं। refrigerated truck, cold storage facility और school cafeteria में समान problem मिलने पर हर देश ने satellite data, camera और gas sensor को थोड़ा अलग अनुपात में जोड़कर उत्तर बनाया है। language और government organization अलग हैं, लेकिन temperature बढ़ने के क्षण को पकड़ना और एक खराब box कई दिन पहले खोजना उनका साझा लक्ष्य है। कहा जा सकता है कि सीमा पार भी technology समान दिशा में converging है।

फिर भी ये system एक-दूसरे से सहज संवाद नहीं करते। Taiwan का production and distribution traceability system, Japan का WAGRI और अमेरिकी Food Safety Modernization Act अलग field और code system से history दर्ज करते हैं। एक देश में उगा produce सीमा पार बिके तो इन अलग ledger के बीच record ले जाने में अभी भी काफी manual work चाहिए। जब तक साझा standard हर देश में एक batch number को समान अर्थ नहीं देता, cross-border traceability में मनुष्य का final step बना रहने की संभावना है।

यह चित्र अभी पूरा नहीं है। हर कुछ दिन में satellite observation, कभी-कभार drone flight और हर second ground-sensor record के scale का अंतर spatiotemporal interpolation तथा generative artificial intelligence वाली high-resolution reconstruction research से भी पूरी तरह हल नहीं हुआ है। cold-chain box की अधिक humidity, lens पर condensation और बदलती gas concentration optical तथा gas sensor reading को धीरे-धीरे बिगाड़ते हैं। धुंधले चश्मे से मनुष्य को साफ न दिखने की तरह नमी sensor को अपना मूल target value सही पढ़ने नहीं देती। इसे सुधारने के लिए software से value अपने आप adjust करने वाला calibration algorithm और नमी सहने वाला surface material दोनों चाहिए।

farm द्वारा जुटाए data का owner कौन है, उसका value तथा trade कैसे हो और blockchain falsification रोकते समय rule किसान के rights कैसे बचाए, ये प्रश्न technology से अधिक institutional solution माँगते हैं। दूसरा future task logistics warehouse के digital twin में explainable artificial intelligence जोड़ना है, ताकि machine field manager को शब्दों में बता सके कि किसी box को Mu-in grade क्यों मिला। कारण के बिना केवल grade पाने वाला किसान निर्णय का आधार न देखकर निराश हो सकता है। grading मनुष्य से machine की ओर जाए तो system को बताना होगा कि machine ने क्या देखा और decision तक कैसे पहुँची।

refrigerated truck के temperature logger का data एक pipeline में satellite image, logistics warehouse के digital twin और cafeteria की traceability lookup screen से जुड़ता है। इस structure में किसी एक stage का missing या गलत record बाकी stages के decision भी कम accurate बनाता है। शेष कार्य हर देश की अलग traceability code system को एक करना और

temperature, humidity तथा gas sensor जैसे moisture-sensitive equipment की measurement error घटाना है।

स्रोत और संदर्भ

शोध पत्र

1. Choudhari, A., Katkar, R., Gupta, M., Wathe, N., Kakde, S., & Poyam, P. (2025). Design of an integrated spatiotemporal deep learning framework for autonomous precision weed detection, treatment, and recurrence prediction in drone-based smart farming sets. *International Journal of Applied Mathematics*, 38(2s), 1339-1366.
2. Hoque, M. D. J., et al. (2024). Incorporating meteorological data and pesticide usage for crop yield prediction using machine learning. *IEEE Access*, 12, 40947-40961.
3. Huang, X., Zhu, Q., & Huang, M. (2026). Online detection system for freshness of fruits and vegetables based on temporal multi-source information fusion. *Smart Agriculture*, 8(1), 203-212. DOI: 10.12133/j.smartag.SA202505037.
4. Pasupuleti, M. K. (2026). Vision transformers for crop intelligence and sustainable precision agriculture. *International Journal of Academic and Industrial Research Innovations (IJAIRI)*, 6(4), 1-45.
5. Wang, J., et al. (2026). Research progress and prospects of intelligent management and control technologies for facility vegetables. *Smart Agriculture*, 8(1), 105-120.
6. 中澤健介, 山崎達也. (2026). 大域文脈情報を導入した深層学習とファジー推論を用いた洋ナシ等級判定手法の研究. 『農業情報研究』, 35(2), 65-78.

रिपोर्ट और ऑनलाइन सामग्री

1. CABI Digital Library. (2026). कृत्रिम बुद्धिमत्ता आधारित कटाई-पश्चात प्रबंधन और shelf-life prediction की प्रवृत्तियों की समीक्षा. CABI Reviews. <https://www.cabidigitallibrary.org/doi/10.1079/cabireviews.2026.0011>
2. DeltaTrak. (2026). How predictive shelf-life analytics redefines freshness in the cold chain. Food Logistics. <https://www.foodlogistics.com/software-technology/supply-chain-visibility/article/22954945/deltatrak-how-predictive-shelf-life-analytics-redefines-freshness-in-the-cold-chain>
3. National Center for Biotechnology Information. (2026). multichannel gas sensor आधारित खजूर shelf life estimation machine learning model से संबंधित सामग्री. PubMed Central. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC12252097/>
4. shelf-life prediction, traceability और carbon accounting को जोड़ने वाली modular data-based system पर प्रारंभिक शोध पत्र. (2026). arXiv. <https://arxiv.org/pdf/2511.05920>

व्याख्यान और वीडियो सामग्री

1. 高雄農來訊. (2025). 114年高雄智慧農業年度成果發表暨研討會. YouTube. <https://www.youtube.com/watch?v=1Edc6pP4HnU>
2. 気象ビジネス推進コンソーシアムWXBC. (2025). 2025年度 農研機構メッシュ農業気象データ分析チャレンジ. YouTube. <https://www.youtube.com/watch?v=w1SrS3iwA4E>
3. TaiwanICDF國合會. (2025). 2025第三屆國際開發援助現場論壇: 全球智慧農業發展探究. YouTube. <https://www.youtube.com/watch?v=0qUeP8A4Pro>
4. 茶柱. (2026). 茶園スマート農業 カワサキ技研・落合刃物・寺田製作所. YouTube. <https://www.youtube.com/watch?v=zmFbOC5RcJU>

5. 李載榮. (2025). A88 資策會衛星精準農業AI導入工作坊: 桃園AI衛星多光譜圖像與無人機應用. YouTube. <https://www.youtube.com/watch?v=dtT3bafdKgw>
6. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026 Global AgriFood Innovation Roadshow: China Agricultural University Special Session. YouTube. <https://www.youtube.com/watch?v=SS2qVda11nw>
7. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026 Global Agrifood Innovation Roadshow: Session 2. YouTube. <https://www.youtube.com/watch?v=DQrCqyNAqY>
8. 農業農村情報通信環境整備準備会. (2026). 地域でデータを共有しよう: 農業データの利活用最前線, データ駆動型農業WAGRIとIoTクラウド(SAWACHI)でのNext次世代型施設園芸システム. YouTube. <https://www.youtube.com/watch?v=k8Qvv6CKB2A>
9. Centre for Networked Intelligence, IISc. (2025). Webinar on Track-1: Crop identification using satellite data [IndiaAI Impact Gen-AI Hackathon]. YouTube. https://www.youtube.com/watch?v=9xi5_1rrJ9o
10. Sampurna Challenge. (2026). Post-Harvest Innovation, Startups & Agri Value Chain Solutions | Webinar | Sampurna 2026. YouTube. <https://www.youtube.com/watch?v=0HTys4rPdwE>
11. AgriBusiness Forum. (2026). AI, Data, Digital Transformation of the agrifood value chain. YouTube. <https://www.youtube.com/watch?v=OMFBQz27YyU>
12. 臉書李載榮協助進駐科學園區科技廠商團膳機器人電動三輪車物流餐車全球愛玉全球機器人口全球AI族譜規劃. (2025). A89私密資策會衛星精準農業AI導入工作坊桃園AI衛星多光譜圖像與無人機應用主辦單位:資策會協辦單位:擎壤科技公司【悠由數據 FarmiSpace × 大賀米 × 擎壤無人機 × 資策會】聯合打造精準. YouTube. <https://www.youtube.com/watch?v=L27xkkSrSa0>
13. Washington State Academy of Sciences (WSAS). (2026). AI for Post Harvest. YouTube. <https://www.youtube.com/watch?v=hJIOrNIQG4>

अध्याय 5

AI-आधारित डिजिटल फीनोटाइपिंग और प्रजनन जैव प्रौद्योगिकी

5.1

उच्च-श्रृपुट फसल फीनोटाइपिंग

ग्रीनहाउस की छत की रेल पर लटकी गैन्ट्री प्रणाली किसी गमले के सामने से गुजरते समय कई कैमरों से पौधे की अलग-अलग कोणों से तस्वीरें लेती है और फिर उन्हें जोड़कर प्रत्येक पौधे का त्रि-आयामी मॉडल अपने आप बनाती है। जिस काम में पहले एक व्यक्ति फीता लेकर पूरे दिन ग्रीनहाउस में घूमता और माप करता था, उसे अब यही उपकरण एक रात में हजारों गमलों के लिए पूरा कर देता है। तस्वीरों से त्रि-आयामी मॉडल के पुनर्निर्माण की गणना भी हाल के वर्षों में बहुत तेज हुई है। वर्ष 2026 में प्रकाशित त्रि-आयामी फाउंडेशन मॉडल ने औसत पुनर्निर्माण समय 6 मिनट 31 सेकंड से घटाकर 1.58 सेकंड कर दिया, जबकि 3D Gaussian Splatting विधि ने प्रति सेकंड 6.39 फ्रेम की प्रसंस्करण गति प्राप्त की।

मशीनों से पौधों की बाहरी विशेषताएँ मापने के इस काम को फीनोटाइप विश्लेषण कहते हैं। फीनोटाइप वह रूप है जिसमें बीज की आनुवंशिक जानकारी बड़े हुए पौधे में ऊँचाई, पत्ती के आकार, तने की मोटाई और रोग के निशान जैसी विशेषताओं के रूप में दिखाई देती है, और फीनोटाइप विश्लेषण इन विशेषताओं को मापने और दर्ज करने की पूरी प्रक्रिया है। लंबे समय तक यह सारा काम मनुष्य करते रहे। प्रजनक स्वयं फीता लगाकर ऊँचाई मापते, आँख से पत्तियों का रंग देखते, रोग की गंभीरता को श्रेणी देते और कभी-कभी पूरे पौधे को उखाड़कर तौलते थे। मनुष्य के माप में उस दिन की स्थिति और देखने की क्षमता के अनुसार त्रुटि आ सकती है, जबकि एक किस्म के परीक्षण में हजारों से लेकर दसियों हजार वंश शामिल हो सकते हैं, इसलिए पूरी वृद्धि अवधि में सब पर लगातार नज़र रखना शुरू से ही मानवीय क्षमता से बाहर था। प्रजनन क्षेत्र इस बाधा को लंबे समय से जानता था, पर उसे दूर करने का उपयुक्त साधन नहीं था।

वह साधन सेंसर अभियांत्रिकी, रोबोट और कृत्रिम बुद्धिमत्ता ने बनाया। लेज़र और कैमरे मनुष्य के स्थान पर पौधों को मापते हैं, मानवरहित विमान और पहियों वाले रोबोट खेतों तथा ग्रीनहाउसों में घूमकर तस्वीरें और वीडियो जुटाते हैं, और डीप लर्निंग तस्वीरों में पत्तियों तथा फलों को अलग करती है। इन तीन तत्वों को मिलाने वाली तकनीक उच्च-प्रवाह फसल फीनोटाइपिंग (High-Throughput Phenotyping) कहलाती है और इसे प्रायः HTP लिखा जाता है। यदि एक व्यक्ति एक दिन में 100 गमले माप सकता है तो HTP उपकरण उतने ही समय में हजारों गमले बिना छुए और बिना पत्ती काटे माप सकता है। स्मार्ट प्रजनन की चर्चा में यह तकनीक हमेशा आती है, क्योंकि अच्छी किस्म चुनने का पहला कदम सटीक मापन है और HTP यह काम मशीन को सौंपता है।

HTP का मूल सिद्धांत ग्रीनहाउस और खेत में उगती पौध आबादी की त्रि-आयामी संरचना तथा प्रकाश परावर्तन विशेषताओं को बिना क्षति पहुँचाए तेजी से दर्ज करना और फिर डेटा को ऐसे ढाँचे में संख्याओं में बदलना है जहाँ जीन, पर्यावरण और बाहरी रूप परस्पर क्रिया करते हैं। एक ही बीज अधिक पानी वाले और कम पानी वाले खेत में अलग तरह से बढ़ता है। बाहरी रूप केवल जीन से निर्धारित नहीं होता, बल्कि

जीन और पर्यावरण के संयुक्त प्रभाव का परिणाम होता है। प्रजनक इस संबंध को जीनोटाइप, पर्यावरण और फीनोटाइप के शुरुआती अक्षरों से $G \times E \times P$ कहते हैं, और HTP इसमें फीनोटाइप को भरता है, जो इस संबंध का अंतिम और असाधारण रूप से कठिन मापनीय घटक है। फीनोटाइप डेटा के बिना सर्वोत्तम आनुवंशिक मानचित्र भी वास्तविक खेत में सही है या नहीं, इसे जाँचने का कोई उपाय नहीं रहता।

लेज़र स्कैनिंग त्रि-आयामी संरचना दर्ज करने की व्यापक रूप से प्रयुक्त विधियों में से एक है। LiDAR लेज़र छोड़ता है, माइक्रोसेकंड में यह मापता है कि प्रकाश किसी वस्तु से टकराकर लौटने में कितना समय लेता है, और उससे दूरी निकालता है, फिर लाखों दूरी मान निर्देशांक पर रखने से बिंदु मिलकर पौधे के बाहरी आकार की त्रि-आयामी छवि बनाते हैं। इन बिंदुओं के समूह को पॉइंट क्लाउड कहते हैं, जिसका सिद्धांत रेत के कण जितने असंख्य बिंदुओं से चेहरे की रूपरेखा बनाने वाले मोज़ेक जैसा है। PhenoSpex का PlantEye F600 लेज़र स्कैनर का प्रमुख उदाहरण है और इतना घना पॉइंट क्लाउड बनाता है कि दो पास-पास के बिंदुओं के बीच केवल 0.1 मिलीमीटर की दूरी रहती है। इस उपकरण में निकट-अवरक्त और लाल प्रकाश का परावर्तन एक साथ मापने वाले सेंसर लगे हैं, इसलिए यह उसी क्षण त्रि-आयामी आकार दर्ज करने के साथ पत्ती के स्वास्थ्य का संकेत देने वाला सामान्यीकृत अंतर वनस्पति सूचकांक (NDVI) भी निकालता है। रंगीन छवि और दूरी की जानकारी एक फ्रेम में दर्ज करने वाले RGB-D गहराई सेंसर, दो या अधिक कैमरों की तस्वीरों के विस्थापन से दूरी निकालने वाला स्टीरियो विज़न और अनेक कोणों की तस्वीरें जोड़ने वाला Multi-View Stereo (MVS) पुनर्निर्माण भी इसी उद्देश्य से काम करते हैं, और ये विधियाँ मनुष्य की दो आँखों से दूरी समझने के तरीके जैसी हैं।

प्राप्त पॉइंट क्लाउड से कंप्यूटर वे मान अपने आप निकालता है जिन्हें पहले लोग पैमाने से मापते थे। पौधे की ऊँचाई, पत्तियों से ढका क्षेत्र, पत्ती का कोण, तने की मोटाई और एक-दूसरे पर चढ़ी पत्तियों से बना आयतन, जिन्हें पहले अलग-अलग हाथ से मापना पड़ता था, अब एक पॉइंट क्लाउड का विश्लेषण करके साथ में निकाले जा सकते हैं। यदि हर दिन एक ही समय पर हजारों गमले मापे जाएँ तो प्रणाली प्रत्येक पौधे की दैनिक वृद्धि दिखाने वाला वृद्धि वक्र अपने आप बनाती है। ग्रीनहाउस से बहुत बड़े खेतों में ऐसे स्थलीय स्कैनर पर्याप्त नहीं होते और आकाश से नीचे देखने वाली एक और आँख की आवश्यकता पड़ती है।

उस आँख की भूमिका मानवरहित हवाई वाहन, यानी UAV, निभाता है। खेत के ऊपर कम ऊँचाई पर उड़ने वाला ड्रोन 20 मिलियन से अधिक पिक्सेल वाला अति-उच्च-रिज़ॉल्यूशन रंगीन कैमरा और नीले, हरे, लाल, red-edge तथा निकट-अवरक्त को अलग-अलग दर्ज करने वाला 5 तरंगदैर्घ्य बैंड का मल्टीस्पेक्ट्रल सेंसर लेकर चलता है। इसमें 400 से 1000 नैनोमीटर के प्रकाश को संकीर्ण बैंडों में बाँटने वाला हाइपरस्पेक्ट्रल सेंसर और सतह के तापमान को रंग से दिखाने वाला तापीय सेंसर भी जोड़ा जा सकता है। ड्रोन पर सामान्यतः लगाया जाने वाला MicaSense का मल्टीस्पेक्ट्रल सेंसर इन 5 तरंगदैर्घ्य बैंडों को दर्ज करने वाला प्रतिनिधि उपकरण है। प्राप्त तस्वीरें पूरे खेत के वनस्पति आवरण अनुपात और NDVI, GNDVI तथा SAVI जैसे वनस्पति सूचकांकों में बदली जाती हैं। रोगग्रस्त या सूखी पत्तियाँ निकट-अवरक्त प्रकाश कम परावर्तित करती हैं और लाल प्रकाश को ठीक से अवशोषित नहीं करतीं, जबकि स्वस्थ हरी पत्तियों का क्लोरोफिल लाल प्रकाश सोखता और निकट-अवरक्त को तीव्रता से लौटाता है, इसलिए दोनों तरंगदैर्घ्यों के परावर्तन का अंतर पत्ती के स्वास्थ्य को एक संख्या में दिखाता है। कुछ घंटों तक कम ऊँचाई

पर उड़ने वाला एक ड्रोन दसियों हेक्टेयर क्षेत्र स्कैन कर सकता है, वनस्पति सूचकांक मानचित्र पूरा कर सकता है और रुकी हुई वृद्धि वाले भूखंडों को रंग से चिह्नित कर सकता है।

डीप लर्निंग तस्वीरों और पॉइंट क्लाउड से पत्तियाँ, फूल और फल अलग करती है। Convolutional Neural Network (CNN), Vision Transformer (ViT) और Graph Neural Network (GNN) जैसे मॉडल यह कार्य करते हैं, और तस्वीर में वस्तु की सीमा को प्रत्येक पिक्सेल तक पहचानकर अलग करने की प्रक्रिया को इंस्टेंस सेगमेंटेशन कहते हैं। इसे एक भुट्टे, उसके पास वाले भुट्टे और अगली पत्ती को अलग-अलग वस्तु मानकर पहचानने तथा चिह्नित करने के रूप में समझा जा सकता है। जब इस प्रकार अलग किए गए अंगों की कई दिनों या सप्ताहों तक एक ही स्थान से बार-बार तस्वीर ली जाती है तो पत्तियों के खुलने और फलों के बढ़ने की गति को समय के साथ देखा जा सकता है, और इस क्रम से कुल भार, बायोमास तथा अंतिम उपज का पहले से अनुमान लगाया जाता है।

चीन के हेनान प्रांत के एक मक्का खेत में यह इंस्टेंस सेगमेंटेशन तकनीक वास्तविक कतारों के बीच चल रही है। पहियों वाला मानवरहित स्थलीय वाहन (UGV) मक्का की कतारों के बीच धीरे चलता है और सामने लगे बड़े पैनोरमिक कैमरे से दोनों ओर स्कैन करता है। दोपहर का प्रकाश पल-पल बदलता है और ऊपर की पत्तियाँ नीचे के भुट्टों को ढकती हैं, इसलिए मनुष्य के लिए भी सही संख्या गिनना कठिन होता है। यहाँ लगाया गया CornYOLO मॉडल हल्के YOLO11n न्यूरल नेटवर्क को backbone बनाता है और पत्तियों के पीछे आंशिक रूप से दिखाई देने वाले भुट्टों को खोजने के लिए frame reconstruction module (FRM) जोड़ता है। सटीकता का सूचक mean average precision, यानी mAP, 91.5 प्रतिशत तक पहुँचा, जो आँख से की गई गिनती के बराबर है। रोबोट के खेत का एक चक्कर लगाने के दौरान प्रत्येक पौधे पर भुट्टों की संख्या और स्थिति अपने आप तालिका में जुड़ती जाती है, और यह तालिका उपज से जुड़े गुणों के चयन का आधार डेटा बनती है।

मक्का और धान के फूल आने के समय की निगरानी में भी ऐसी ही विधि काम आती है। ड्रोन से ली गई कैनोपी तस्वीरों पर YOLOv5 और Vision Transformer लगाने पर प्रणाली पराग बनाने वाले मक्का के नर पुष्पक्रम की उपस्थिति और पुष्पन स्थिति को 3 अवस्थाओं में अलग करती है, जिनमें अभी फूल न आना, फूल आना शुरू होना और पूरा खिलना शामिल हैं। परिणामों का समेकन अपने आप वृद्धि सूचकांक बनाता है जो बताता है कि पूरा खेत किस विकास अवस्था में है, और इससे फूल आने का समय उस पुराने तरीके की तुलना में कहीं छोटे अंतराल पर जाँचा जा सकता है जिसमें लोग कुछ दिनों में एक बार खेत में चलकर आँख से मूल्यांकन करते थे। प्रजनक के लिए फूल आने का समय यह तय करता है कि किन वंशों का परस्पर संकरण किया जाएगा, और केवल इस कसौटी को दिन-स्तर तक सटीक बनाने से संकरण योजना की सफलता दर बदल सकती है।

हर खेत के पास CornYOLO जैसा विशेष मॉडल विकसित करने के साधन नहीं होते, इसलिए ऐसे मुक्त-स्रोत उपकरण भी साथ-साथ विकसित हो रहे हैं जिन्हें कोई भी डाउनलोड करके चला सकता है। PlantCV v2 तस्वीरों में पत्ती के रंग और आकार का विश्लेषण करने की प्रक्रिया पहले से लिखकर देने वाला मुक्त-स्रोत कार्यक्रम है, जो केवल तस्वीरें देने पर पत्ती क्षेत्रफल, कैनोपी आयतन और रंग बदलने का अनुपात अपने आप निकालता है। kmSeg सांख्यिकीय K-means तकनीक से रंगों को कई समूहों में

बाँटकर पौधे और पृष्ठभूमि को अलग करता है, जबकि PhenolImage क्लोरोफिल द्वारा प्रकाश ग्रहण करने की स्थिति दिखाने वाली बड़ी मात्रा की फ्लोरेसेंस तस्वीरें संसाधित करता है। इन उपकरणों से सीमित अनुसंधान बजट वाली विश्वविद्यालय प्रयोगशालाएँ भी बड़ी कंपनियों के निकट स्तर का फीनोटाइप विश्लेषण कर सकती हैं।

ग्रीनहाउस में गैन्ट्री या रेल पर चलने वाली स्थिर प्रणालियाँ मानक बन चुकी हैं। LemnaTec, PhenoSpex और Field Scanalyzer जैसी कंपनियों के उपकरण ग्रीनहाउस या छत वाले परीक्षण क्षेत्र में लगी रेल पर चलते हैं और तय समय पर हजारों गमलों या भूखंडों को स्कैनर के नीचे अपने आप ले जाते हैं। मशीनें मनुष्य द्वारा पहले से तय क्रम और समय पर दिन-रात चलती हैं, इसलिए वे उसी गमले को सुबह 3 बजे ठीक उन्हीं परिस्थितियों में फिर माप सकती हैं जैसी दोपहर 12 बजे थीं। मनुष्य हाथ से इस दोहराव को हासिल नहीं कर सकता, जबकि प्रतिदिन एक ही पौधे की एक ही कोण और प्रकाश में तस्वीर लेने वाले फीनोटाइप विश्लेषण को इसी की आवश्यकता होती है।

ग्रीनहाउस के बाहर बड़े और बिना छत वाले खेतों की परिस्थितियाँ अलग होती हैं। क्षेत्र रेल बिछाने के लिए बहुत बड़ा होने के कारण वास्तविक समय गतिज स्थिति निर्धारण, यानी 2 सेंटीमीटर से कम स्थान त्रुटि वाली RTK-GPS दिशा-निर्देशन प्रणाली से लैस ड्रोन और स्थलीय रोबोट यह भूमिका निभाते हैं। ड्रोन ऊपर से बड़ा क्षेत्र स्कैन करता है और स्थलीय रोबोट कैनोपी के नीचे से पास जाकर भुट्टों को देखता है, इस तरह काम बाँटकर वे कुछ दिनों में हजारों वंशों वाले पूरे प्रजनन परीक्षण खेत का सर्वेक्षण कर लेते हैं। दोनों उपकरणों की स्थिति सूचना एक ही निर्देशांक प्रणाली में रहने के कारण ऊपर से ड्रोन द्वारा लिया गया डेटा बाद में बगल से रोबोट द्वारा लिए गए डेटा पर रखा जा सकता है।

सीमित उपकरण बजट वाले स्थानों के लिए कम लागत के विकल्प भी सामने आए हैं। MVS-Pheno और LITERAL जैसे उपकरण तथा Arduino माइक्रोकंट्रोलर और कुछ कैमरों से बने छोटे सिस्टम भी त्रि-आयामी पुनर्निर्माण कर सकते हैं। उनकी कीमत व्यावसायिक गैन्ट्री उपकरण की कीमत के कुछ प्रतिशत भर होती है, फिर भी वे छोटी प्रयोगशाला या खेत के अपने किसी भूखंड को स्कैन करने के लिए पर्याप्त हैं। अब महँगे उपकरण के बिना भी फीनोटाइप विश्लेषण शुरू किया जा सकता है।

अब तक बताए गए सभी उपकरण जमीन के ऊपर दिखाई देने वाले हिस्सों को मापते हैं। मिट्टी में दबे रहने के कारण जड़ें पूरी तरह अलग समस्या प्रस्तुत करती हैं, और MultipleX-Lab तथा RhizoPot जैसे उपकरण पौधों को पारदर्शी नलियों में उगाकर और नली की दीवार से प्रकाश भेजकर जड़ों की छाया की तस्वीर लेकर इसका समाधान करते हैं। जड़ उखाड़े बिना भी प्रणाली समय के साथ बार-बार दर्ज कर सकती है कि कितनी पार्श्व जड़ें किस दिशा में बढ़ीं और कितनी गहराई तक गईं, इसलिए यह सूखा सहने वाली जड़ संरचना के प्रजनन में बहुत उपयोगी है। ये उपकरण भूमिगत हिस्से से वह जानकारी जोड़ते हैं जो जमीन के ऊपर के पौधे की तस्वीरों से नहीं मिल सकती।

कैमरा कितना भी सटीक हो, तस्वीरों में मिट्टी, कंकड़, खरपतवार और छाया जैसा शोर रहता है। पृष्ठभूमि हटाने के पहले चरण में रंग-स्थान परिवर्तन सूत्र ExG और CVI जैसे सूचकांकों से हरे पौधे को बाकी हिस्से से अलग करते हैं और साथ में भू-आकृति का अनुसरण करने वाला टोपोलॉजिकल फ़िल्टर लगाते हैं। पॉइंट क्लाउड में इतने अधिक बिंदु होते हैं कि कंप्यूटर के लिए मूल रूप में उन्हें संभालना कठिन है, इसलिए

Plant-denoising-net (PDN), जो पौध-विशिष्ट शोर हटाना सीखता है, और self-organizing map down-sampling (SOM Down-sampling), जो बिंदुओं को समान रूप से कम करता है, उनकी संख्या को प्रबंधनीय स्तर तक घटाते हैं। अगले चरण में केवल पौधे का साफ आकार संसाधित करने के लिए मिट्टी के हर कण और धुंधली छाया तक को हटाना आवश्यक है। यह तैयारी न हो तो मूल पॉइंट क्लाउड में मिला शोर बाद की गणनाओं को बिगाड़ देता है।

Multi-View Stereo पुनर्निर्माण एल्गोरिदम और सीमाओं को अधिक संवेदनशीलता से पहचानने वाला Vision Transformer, Edge_MVS-Former, कई साफ की गई तस्वीरों से प्रत्येक पौधे का त्रि-आयामी आकार पुनर्निर्मित करने के लिए साथ काम करते हैं। प्राप्त त्रि-आयामी मॉडल TrackPlant3D जैसे इंस्टेंस सेगमेंटेशन न्यूरल नेटवर्क से गुजरता है, जो तनों और पत्तियों को अलग करके अंगों के अनुसार व्यवस्थित करता है। समस्या गति की थी। पुराने तरीकों में दर्जनों तस्वीरें इनपुट लेने और एक पूरा त्रि-आयामी मॉडल बनाने में कई मिनट लगते थे, और जिस प्रजनन केंद्र को हर दिन हजारों ग्रीनहाउस गमलों की फिर से तस्वीर लेनी हो वहाँ ये मिनट जुड़कर पूरे दिन का कार्य समय घेर लेते थे।

Neural Radiance Field, यानी NeRF, ने गति की इस समस्या के समाधान का संकेत दिया। NeRF अलग-अलग कोणों से ली गई कई तस्वीरें न्यूरल नेटवर्क में डालता है और नेटवर्क को यह अनुमान लगाना सिखाता है कि त्रि-आयामी स्थान के किसी भी बिंदु को किसी भी दिशा से देखने पर वहाँ रंग और प्रकाश की तीव्रता क्या होगी। न्यूरल नेटवर्क तस्वीरों के बीच के खाली हिस्सों को यथार्थसंगत ढंग से भरता है, जिनमें कैमरे से न लिए गए कोण भी शामिल हैं, और पहले से कहीं अधिक स्वाभाविक त्रि-आयामी दृश्य बनाता है। फिर भी स्क्रीन पर हर बिंदु बनाते समय प्रणाली को न्यूरल नेटवर्क से अलग-अलग पूछना पड़ता था, इसलिए लंबे समय तक इस विधि को सटीक पर धीमा माना गया। वर्ष 2026 में प्रकाशित त्रि-आयामी फाउंडेशन मॉडल ने इस धारणा को सीधे बदल दिया। अनेक पौध प्रजातियों की बड़ी मात्रा की तस्वीरों पर पहले से सीखकर और नए पौधे की तस्वीर आने पर उस सीख को फिर इस्तेमाल करके मॉडल ने आकार की सटीकता और फीनोटाइप माप बनाए रखते हुए औसत पुनर्निर्माण समय 6 मिनट 31 सेकंड से घटाकर 1.58 सेकंड कर दिया।

गति बढ़ाने वाली एक अन्य विधि 3D Gaussian Splatting, यानी 3DGS, है। जहाँ NeRF को हर गणना में रंग के लिए न्यूरल नेटवर्क से पूछना पड़ता है, वहीं 3DGS पौधे की सतह को पहले ही लाखों छोटे धुंधले और अर्धपारदर्शी पिंडों के रूप में मॉडल करता है और रंगे हुए रूई के फाहों की तरह सबको एक साथ स्क्रीन पर बिछाकर छवि पूरी करता है। प्रत्येक पिंड की स्थिति, रंग और धुंधलापन गणना हो जाने के बाद ग्राफिक्स कार्ड न्यूरल नेटवर्क की पूछताछ प्रक्रिया के बिना सीधे रेंडर कर सकता है।

Instant-NGP और Nerfacto के साथ तुलनात्मक परीक्षण में 3DGS ने प्रति सेकंड 6.39 फ्रेम प्राप्त किए, और इस परिणाम ने त्रि-आयामी निरूपण का केंद्र न्यूरल नेटवर्क से ऐसी स्पष्ट संरचनाओं की ओर ले जाने में योगदान दिया।

कई कैमरों से ली गई तस्वीरों में प्रत्येक पौधे को अलग वस्तु के रूप में पहचानना आज भी कठिन कार्य है। PlantSegNeRF, Neural Radiance Field को बहु-दृश्य तस्वीरों में एक ही अंग के मिलान की प्रक्रिया से जोड़कर कम नमूने होने या पहले कभी न देखी गई फसल प्रजाति मिलने पर भी त्रि-आयामी

पॉइंट क्लाउड को अलग-अलग पौधों के अनुसार विभाजित करता है। अनुसंधान ने रोबोट को यह स्वयं तय करने योग्य भी बनाया है कि अगला कौन-सा कोण सबसे अधिक नई जानकारी देगा, और SSL-NBV स्व-पर्यवेक्षित शिक्षण से रोबोट को हर बार मनुष्य के निर्देश के बिना अगली कैमरा स्थिति चुनने देता है। सही भौतिक अनुपात वाले खेत-स्तरीय पॉइंट क्लाउड को पूरा करने के लिए 5 चरणों की प्रक्रिया भी प्रस्तावित की गई है, जो डेटा ग्रहण, पौधे और पृष्ठभूमि का अर्थगत विभाजन, कुछ बिंदु पहले स्थापित करने वाला विरल पुनर्निर्माण, बिंदुओं को भरने वाला सघन पुनर्निर्माण और अंत में फीनोटाइप गुण निकालने तक चलती है।

नई विधियों की श्रृंखला की तुलना करने वाले अध्ययन भी शीघ्र सामने आए। वर्ष 2026 में *Frontiers in Plant Science* ने खेत की परिस्थितियों में पॉइंट क्लाउड आधारित त्रि-आयामी फसल फीनोटाइपिंग अध्ययनों की तुलनात्मक समीक्षा प्रकाशित की, और लगभग उसी समय *Sensors* ने पूरी त्रि-आयामी पुनर्निर्माण तकनीक पर एक समीक्षा प्रकाशित की। दोनों समीक्षाओं ने एक महँगे उपकरण पर निर्भर रहने से हटकर कई कम लागत वाले कैमरों को तेज सॉफ्टवेयर के साथ जोड़ने की प्रवृत्ति दिखाई।

इन विधियों की व्यावहारिक उपयोगिता कुछ सूचकांकों से जाँची जाती है। mean average precision, यानी mAP, यह मापता है कि प्रणाली भुट्टे या पत्ती जैसे लक्ष्य कितनी सही तरह खोजती है, जबकि intersection over union, यानी IoU, यह बताता है कि विभाजित पत्ती की सीमा वास्तविक सीमा से कितनी मेल खाती है। root mean square error (RMSE) मिलीमीटर में बताता है कि लेज़र या कैमरे से बने त्रि-आयामी मॉडल और पैमाने से मापे आकार में कितना अंतर है, जबकि स्थल पर छोटा कंप्यूटर एक तस्वीर कितने समय में संसाधित करता है और प्रति सेकंड कितनी तस्वीरें संभालता है, इससे पता चलता है कि प्रणाली वास्तविक समय में चल सकती है या नहीं। तस्वीर से अनुमानित भार या ऊँचाई प्रत्यक्ष विनाशकारी मापन से कितना मेल खाती है, इसे निर्धारण गुणांक दिखाता है, और कई अध्ययनों में इसका 0.75 से अधिक होना इस प्रमाण को मजबूत कर रहा है कि छवि मापन विनाशकारी सर्वेक्षण का स्थान ले सकता है। फूल आने की अवस्था या रोग श्रेणी जैसे संख्या के बजाय वर्ग में बाँटे जाने वाले गुणों का अलग से F1-Score और confusion matrix के माध्यम से मूल्यांकन किया जाता है।

कैमरे और रोबोट हर दिन अलग प्रकार और आकार की तस्वीरें, पॉइंट क्लाउड तथा संख्यात्मक डेटा बनाते हैं, इसलिए शोधकर्ताओं को डेटा साझा करने के लिए स्पष्ट और व्यवस्थित नियम चाहिए। इन नियमों का मूल ढाँचा FAIR सिद्धांत है। डेटा खोजने योग्य (Findable), पहुँच योग्य (Accessible), अलग कार्यक्रमों के बीच परस्पर संचालनीय (Interoperable) और बाद में पुनः उपयोग योग्य (Reusable) होना चाहिए। FAIR को लागू करने के लिए कच्ची सेंसर तस्वीरों, संसाधित त्रि-आयामी पॉइंट क्लाउड, तस्वीर लेने के समय और स्थान तथा अंतिम फीनोटाइप मानों सहित हर डेटा के साथ यह बताने वाला मेटाडेटा जोड़ा जाता है कि क्या, कब और कहाँ दर्ज हुआ, और फिर सबको केंद्रीय डेटाबेस में व्यवस्थित किया जाता है।

PHIS, जिसका पूरा नाम Phenotyping Hybrid Information System है, इन सिद्धांतों को ठोस प्रणाली में बदलने का उदाहरण है। PHIS मानक शब्दावली Plant Ontology (PO) लागू करता है और ग्रीनहाउस या खेत की हर परीक्षण वस्तु, सेंसर और घटना को अलग पहचान कोड देता है। किसी गमले को

ग्रीनहाउस के एक ओर से दूसरी ओर ले जाना, पत्ती पर धब्बा दिखना और तापमान सेंसर का माप सभी स्थायी विशिष्ट पहचान URI से जुड़े रहते हैं, इसलिए कई वर्ष पुराने परीक्षण डेटा की तुलना इस महीने के डेटा से समान कसौटी पर की जा सकती है। यह पहचान प्रणाली परीक्षण डेटा के स्तर पर FAIR द्वारा अपेक्षित परस्पर संचालन और पुनः उपयोग को साकार करती है।

PHIS के साथ काम करने वाला OpenSILEX एक सॉफ्टवेयर वास्तुकला है जो अलग-अलग स्थानों पर बिखरे फीनोटाइप डेटा और उन्हें प्रबंधित करने वाली वेब सेवाओं को मानक द्वार से जोड़ता है। अंतरराष्ट्रीय अकादमिक समुदाय ने फीनोटाइप परीक्षण दर्ज करते समय सुरक्षित रखी जाने वाली न्यूनतम जानकारी भी तय की है, और MIAPPE (Minimum Information About a Plant Phenotyping Experiment) मानक स्थान, परीक्षण तिथि, खेती की स्थिति तथा मापन विधि पूरी तरह दर्ज करने की माँग करता है, जबकि PHIS और OpenSILEX जैसी प्रणालियाँ इसे अपनी आधारभूत संरचना में अपनाती हैं। खेत परीक्षण के पर्यावरण, कृषि कार्य इतिहास और मौसम डेटा को समेटने वाला ICASA Version 2.0 मानक भी इसी उद्देश्य से काम करता है। ये मानक अलग देशों और विश्वविद्यालयों की प्रयोगशालाओं के भिन्न नामों को एक साझा भाषा में बदलते हैं।

इस प्रकार व्यवस्थित फीनोटाइप डेटा जीनोम डेटा से जुड़ने पर अधिक मूल्यवान हो जाता है। CropGS-Hub और PHENOPSIS DB जैसे डेटाबेस जीनोम जानकारी तथा उच्च-प्रवाह फीनोटाइप डेटा को एक स्थान पर रखते हैं, ताकि Genomic Selection मॉडल अलग-अलग स्रोत खोजे बिना सीधे जुड़कर उनका उपयोग कर सकें। यदि फीनोटाइप डेटाबेस साझा मानक का पालन न करे तो बाहरी रूप मापने और जीन पढ़ने वाली तकनीकें अलग प्रारूप और विनिर्देश अपनाएँगी, जिससे फीनोटाइप डेटा को जीनोम डेटा से जोड़ना शुरू से ही असंभव हो जाएगा।

PhenoSpex के PlantEye का उपयोग करने वाले एक ग्रीनहाउस में स्कैनर हर दिन उन्हीं गमलों के पास से गुजरता है और कैनोपी की ऊँचाई, पत्ती क्षेत्रफल तथा पत्ती के झुकाव कोण के दैनिक माप जोड़ता जाता है। ये मान ज्यों के त्यों कंप्यूटर के आभासी ग्रीनहाउस, यानी Digital Twin, में प्रतिलिपि किए जाते हैं और स्क्रीन पर वास्तविक ग्रीनहाउस के साथ बढ़ता दूसरा ग्रीनहाउस बनाते हैं। खेती प्रभारी आभासी पौधे की पानी और पोषक तत्व की आवश्यकता को उल्टी गणना से निकालकर वास्तविक ग्रीनहाउस में पोषक घोल की आपूर्ति वाले वाल्व को कब और कितना खोलना या बंद करना है, यह तय करता है। पौधा प्यास बताने के बजाय पत्ती के कोण और कैनोपी आयतन में बदलाव से अपनी स्थिति प्रकट करता है।

सोयाबीन और शीतकालीन गेहूँ वाले प्रजनन परीक्षण खेत में एक ड्रोन मल्टीस्पेक्ट्रल सेंसर और LiDAR दोनों लेकर उड़ता है। कैनोपी ऊँचाई और पत्ती रंग की जानकारी को उचित भार के साथ गणना में मिलाने पर खेत में जमा भूमिपृष्ठीय बायोमास और उसमें मौजूद नाइट्रोजन का काफी सटीक अनुमान लगाया जा सकता है। कटाई के समय क्लस्टरिंग विधि तस्वीर में एक-दूसरे पर चढ़ी सोयाबीन फलियों को भी अपने आप गिनती है, जिससे प्रजनक पौधे उखाड़कर तौलने से पहले केवल एक ड्रोन तस्वीर से अधिक उपज की संभावना वाले वंश छॉट सकता है।

फूलों और फलदार वृक्षों पर काम करने वाले बड़े शोध संस्थान पूरे डेटा भंडार के प्रबंधन के लिए OpenSILEX और PHIS साथ लागू करते हैं। हर दिन जमा होने वाली दसियों हजार रंगीन तथा

त्रि-आयामी तस्वीरें, वास्तविक समय के सेंसर माप और प्रत्येक किस्म की जीनोटाइप जानकारी एक प्रणाली में इकट्ठी होती है, और Plant Ontology मानक वाले लेबल अलग शोध समूहों द्वारा उसी गमले को अलग नाम देने की उलझन समाप्त करते हैं। डेटा खोजने और साझा करने का समय घटने पर शोधकर्ता तुरंत AI प्रजनन मॉडल को उस डेटा से जोड़ने के अगले चरण पर जा सकते हैं। मानकीकरण स्वयं चमकदार परिणाम नहीं देता, लेकिन परिणाम आने में लगने वाला समय स्पष्ट रूप से घटाता है।

इन उपलब्धियों के बावजूद कुछ समस्याएँ अभी अनसुलझी हैं। पौधे बढ़ने और कैनोपी घनी होने पर ऊपर की पत्तियाँ नीचे के फूल, फल और रोग के निशान तक ढक देती हैं, इसलिए कैनोपी के ऊपर केवल एक कैमरा या लेज़र स्कैनर रखने वाली विधि अक्सर नीचे के गुण देख ही नहीं पाती। अभी आशाजनक समाधान स्थलीय रोबोट और ड्रोन से अलग-अलग कोणों की तस्वीरों को जोड़ना तथा आसपास की जानकारी से छिपी और दर्ज न हुई पत्तियों को भरने वाली पॉइंट क्लाउड पुनर्निर्माण गणना सुधारना है। तस्वीर से पूरी तरह गायब पत्ती का आकार पूरी तरह लौटाना अब भी कठिन है, लेकिन क्षेत्र के विशेषज्ञ मानते हैं कि अनुमानित मान भी डेटा न होने से कहीं अधिक उपयोगी है।

डेटा का आकार भी बाधा है। 0.1 मिलीमीटर रिज़ॉल्यूशन वाला पॉइंट क्लाउड या सैकड़ों तरंगदैर्घ्य वाली हाइपरस्पेक्ट्रल तस्वीर प्रति छवि कई गीगाबाइट तक पहुँच सकती है, इसलिए खेत के किनारे रखा छोटा कंप्यूटर उसे वास्तविक समय में संसाधित नहीं कर पाता। डेटा घटाने या गणना तेज करने के लिए कई विधियाँ साथ-साथ अध्ययन में हैं, जिनमें बिंदु कम करने वाली down-sampling, बड़े न्यूरल नेटवर्क का ज्ञान छोटे नेटवर्क में ले जाने वाली Knowledge Distillation और उपकरण में neural processing unit (NPU) सीधे लगाकर किया जाने वाला hardware acceleration शामिल हैं। उपकरण जितना हल्का होगा, उतना ही खेत के बीच तुरंत उत्तर दे सकेगा, इसलिए गणना का भार घटाने की यह दौड़ आगे भी चलने की संभावना है।

बाहरी मौसम भी कृत्रिम बुद्धिमत्ता को अक्सर भ्रमित करता है। तेज सीधी धूप में पत्ती की सतह सफेद चमकती है और रंग की जानकारी खो जाती है, हवा एक ही पत्ती को हर तस्वीर में अलग आकार की दिखाती है, और बादल गुजरने से चमक पल-पल बदलती है तो पिछली तस्वीर से सीखा मॉडल अगली में उलझ सकता है। नियंत्रित प्रकाश और हवा वाले ग्रीनहाउस में सीखा मॉडल खुले खेत में सीधे ले जाने पर प्रायः बहुत सटीकता खो देता है, और इस घटना को Domain Shift कहते हैं। विविध मौसम और प्रकाश स्थितियों को कृत्रिम रूप से मिलाकर प्रशिक्षण डेटा बढ़ाना या Domain Adaptation से मॉडल को नए वातावरण के लिए फिर समायोजित करना इस समस्या से निपटने की मुख्य विधियाँ हैं। अंततः प्रयोगशाला के बाहर जिसकी सटीकता सत्यापित नहीं हुई, ऐसा मॉडल केवल ग्रीनहाउस में काम करने वाला अधूरा परिणाम बनकर रह सकता है।

अब तक बताई लगभग सभी तकनीकें जमीन के ऊपर पत्तियों और फलों पर केंद्रित हैं, इसलिए एक ही प्रक्रिया में भूमिगत जड़ों को भी ट्रैक करने वाला एकीकृत फीनोटाइप विश्लेषण अगला कार्य है। इसके साथ Explainable AI (XAI) भी चाहिए, ताकि मनुष्य समझ सके कि प्रणाली ने कौन-सी तस्वीर देखकर किसी पौधे को रोगग्रस्त या अधिक उपज की संभावना वाला क्यों माना। Grad-CAM और SHAP जैसी तकनीकें निर्णय लेते समय न्यूरल नेटवर्क द्वारा ध्यान दिए गए छवि क्षेत्र रंगीन heat map में दिखाती हैं,

और ऐसा दृश्य प्रमाण मिलने पर ही प्रजनक मशीन के निर्णय पर भरोसा करके अगली संकरण योजना बना सकता है। गैन्ट्री गुजर जाने के बाद कुछ तस्वीरें नहीं, बल्कि लाखों निर्देशांक मान और उनसे निकाले गए गुण मान बचते हैं। साझा मानक के अनुसार व्यवस्थित होने पर ये मान कई ग्रीनहाउसों के डेटा को दूसरे देश की शोध प्रयोगशाला के डेटा से जोड़ सकते हैं। तब प्रजनक संख्याओं से जाँच सकता है कि किसी विशेष जीन वाला बीज किसी विशेष खेत में कैसे बढ़ेगा।

स्रोत और संदर्भ

शोध पत्र

1. Xu, Q., Zheng, B., & Zhong, S. (2026). Artificial Intelligence Empowering Modern Agricultural Biological Breeding. *Smart Agriculture*, 8(3), 69-85.
2. Gao, G., Wang, Q., Song, L., Feng, H., Shi, L., Yang, H., Liu, Y., & Yue, J. (2026). Object Detection Method of Maize Ears Within Canopy Based on CornYOLO. *Smart Agriculture*, 8(1), 167-177. DOI: 10.12133/j.smartag.SA202509005.
3. Moldvai, L., & Nyéki, A. (2025). Innovative computer vision methods for tomato (*Solanum Lycopersicon*) detection and cultivation: a review. *Discover Applied Sciences*, 7, 975. <https://doi.org/10.1007/s42452-025-07613-x>
4. Harnessing artificial intelligence in plant breeding: Innovations in digital phenotyping and breeding methods. (2026). *Plant Methods*. DOI: 10.1007/s13007-026-01286-0.
5. Neveu, P., Tireau, A., Hilgert, N., Negre, V., Mineau-Cesari, J., et al. (2019). Dealing with multi-source and multi-scale information in plant phenomics: The ontology-driven Phenotyping Hybrid Information System. *New Phytologist*, 221(1), 588-601.
6. OpenSILEX. (2026). Plan de gestion logiciel.
7. 田中佑, 郭威, 山口友亮, 桂圭佑, 中島洸太, & 戸田陽介. (2025). "AI時代"の作物学研究. *日本作物学会紀事*, 94(3), 329-330.
8. 大澤央, 齋藤正博, & 八木岡敦. (2026). 物体検出AIを活用したスイートコーン収穫適期予測技術の開発. *農業食料工学会誌*, 88(2), 85-91.
9. arXiv. (2026). त्रिआयामी फाउंडेशन मॉडल पर आधारित अत्यंत तेज फसल पुनर्निर्माण और फीनोटाइप सटीकता बनाए रखने का अध्ययन. <https://arxiv.org/abs/2607.01753>
10. arXiv. (2025). PlantSegNeRF: बहु-दृश्य छवियों से मलिन पर आधारित चैनल-संयोजित Neural Radiance Field से पौधों के त्रिआयामी इंस्टेंस पॉइंट क्लाउड का पुनर्निर्माण. <https://arxiv.org/pdf/2507.00371>
11. arXiv. (2024). SSL-NBV: स्व-पर्यवेक्षण अगले सर्वोत्तम दृश्य चयन से रोबोटिक पौध त्रिआयामी पुनर्निर्माण. <https://arxiv.org/pdf/2410.14790>
12. *Frontiers in Plant Science*. (2026). खेत की परिस्थितियों में पॉइंट क्लाउड आधारित त्रिआयामी फसल फीनोटाइप विश्लेषण की तुलनात्मक समीक्षा. <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2026.1731852/full>
13. *Sensors*. (2026). फसल फीनोटाइप विश्लेषण के लिए त्रिआयामी पुनर्निर्माण तकनीकों की समग्र समीक्षा. <https://doi.org/10.3390/s26092730>

व्याख्यान और वीडियो सामग्री

1. IPPN - International Plant Phenotyping Network. (2025). Dr. Michael Selveraj: AI-Powered Phenomics: Transforming Crop Science for Climate-Resilient Future. YouTube. <https://www.youtube.com/watch?v=eoTvCz3YTzo>

2. Greg Bronevetsky. (2025). Predictive Pattern Recognition of Plant Growth Traits in Simulated and Controlled Environments. YouTube. <https://www.youtube.com/watch?v=uKepfZAnKbk>
3. Bioingene. (2026). International Webinar- Biotechnological strategies to improve plant traits for enhanced productivity. YouTube. <https://www.youtube.com/watch?v=duUd8ajVo44>
4. Solvi. (2026). Webinar: Validating AI-Based Plant Counts with Real Field Data. YouTube. <https://www.youtube.com/watch?v=B0KuJdRtmaQ>

5.2

पूर्वानुमानात्मक प्रजनन और बुद्धिमान जैव-प्रजनन तकनीक

फसल प्रजनन की शुरुआत फीनोटाइप चयन से हुई, जिसमें किसान खेत में जाकर केवल दिखाई देने वाली विशेषताओं के आधार पर अच्छे पौधे चुनता था। बाद में मेंडल के आनुवंशिक नियमों और सांख्यिकी से माता-पिता तथा संतति के प्रदर्शन की गणना जोड़ी गई, और जीन के किसी विशेष स्थान को चिह्न बनाकर इच्छित गुण पहले से छाँटने वाला Marker-Assisted Selection (MAS) स्थापित हुआ। इसके बाद पूरे जीनोम में फैले दसियों हजार चिह्नों को एक साथ पढ़ने वाला Genomic Selection (GS) आया, जिससे चयन की सटीकता बढ़ी और एक पीढ़ी उगाकर अगली तक पहुँचने का समय घटा। यह विधि प्रजनक को पहले से गणना किया हुआ वह मान देती है जो बताता है कि मिट्टी में अभी न बोया गया बीज बढ़कर कितनी उपज दे सकता है, और इसे Genomic Estimated Breeding Value (GEBV) कहते हैं। यह केवल प्रत्येक बीज की आनुवंशिक जानकारी से निकाला गया पूर्वानुमान है।

समस्या उपज जैसे गुणों में थी जिनमें अनेक जीन साथ काम करते हैं। ऊँचाई या रोग प्रतिरोध जैसे एक-दो जीन से तय होने वाले गुणों के विपरीत उपज छोटे प्रभाव वाले सैकड़ों या हजारों जीनों की परस्पर क्रिया से बनती है, और एक ही बीज किस खेत में बोया गया है, इसके अनुसार यह क्रिया अलग रूप लेती है। वही किस्म सूखे खेत में खराब और पर्याप्त पानी वाले खेत में अच्छा प्रदर्शन कर सकती है। जीन और पर्यावरण के इस पारस्परिक प्रभाव को Genotype by Environment Interaction (G×E) कहते हैं, और केवल Genomic Selection से इसे सटीक रूप से समझने की स्पष्ट सीमा थी। इसी पृष्ठभूमि में स्मार्ट जैविक प्रजनन आया, जो जीनोम और फीनोटाइप के साथ खेती के पर्यावरण की जानकारी भी गणना में डालता है।

स्मार्ट जैविक प्रजनन तीन प्रकार के डेटा, Genomics, Phenomics और Enviromics, को एक ही कृत्रिम बुद्धिमत्ता मॉडल में साथ डालता है। Genomics बीज को मिली आनुवंशिक जानकारी है, Phenomics बढ़ते समय वास्तव में दिखने वाली ऊँचाई, पत्ती का रंग और उपज है, और Enviromics उस खेत का तापमान, वर्षा तथा मिट्टी के गुण हैं जहाँ फसल उगी। अलग-अलग देखने पर ये तीनों बिखरी सूचनाएँ हैं, लेकिन कृत्रिम न्यूरल नेटवर्क की कई परतों से गुजारकर उन्हें एक Latent Space में रखा जाए, जहाँ अलग प्रकार के डेटा को संपीड़ित कर समान निर्देशांक पर तुलना की जा सके, तो उनके संबंध सामने आते हैं। वास्तविक बीज बोने से पहले कंप्यूटर में देखा जाता है कि कौन-सा जीनोटाइप किस खेत में कैसा प्रदर्शन करेगा। प्रजनक केवल स्क्रीन की रैंकिंग देखकर बीस वंश चुन सकता है, क्योंकि यह गणना पीछे पहले ही पूरी हो चुकी होती है।

जलवायु परिवर्तन से सूखा और अत्यधिक गर्मी बढ़ने पर किसी विशेष पर्यावरण में भी स्थिर रहने वाली किस्मों को पहले से चुनना प्रजनन का केंद्रीय कार्य बन गया है। इस उद्देश्य से बना Integrated

Genomic-Enviromic Prediction (iGEP) तंत्र पिछले मौसम डेटा, भविष्य के मौसम पूर्वानुमान, मिट्टी के गुण और स्थान जानकारी को जीनोम के Single Nucleotide Polymorphism (SNP) मानचित्र के साथ बहु-स्तरीय न्यूरल नेटवर्क में डालता है, जिसमें SNP वह परिवर्तन है जहाँ व्यक्तियों के जीन अनुक्रम का केवल एक अक्षर अलग होता है। लक्षित खेती क्षेत्र और जलवायु पट्टी को Target Population of Environments (TPE) के रूप में समूहित किया जाता है, और फिर अनुमान लगाया जाता है कि उस समूह में सूखा या उच्च तापमान जैसी चरम स्थिति आने पर कोई जीनोटाइप कितना टिकेगा और कितनी उपज देगा। खेत में बोंकर कई महीने प्रतीक्षा किए बिना भी प्रजनक कुछ हद तक जान सकता है कि कौन-सी किस्म अगले वर्ष की गर्मी सह पाएगी।

कुछ प्रणालियाँ फसल की पूरी शरीरक्रिया का अनुकरण करने वाला वृद्धि मॉडल भी जोड़ती हैं। APSIM और DSSAT जैसे फसल वृद्धि मॉडल भौतिकी तथा रसायन के समीकरणों से दिखाते हैं कि प्रकाश, तापमान और पानी किस तरह पत्तियों और फलों में बदलते हैं, और वृद्धि मॉडल को जीनोमिक पूर्वानुमान मॉडल से जोड़ने वाला genomic-crop model (CGM-G2P) उन शरीरक्रियात्मक प्रक्रियाओं का अनुकरण करता है जिनसे कोई विशेष जीन अंततः उपज को प्रभावित करता है। केवल संख्याओं के बीच सहसंबंध दिखाने वाले पुराने सांख्यिकीय मॉडल के विपरीत यह तरीका यह स्पष्ट करते हुए पूर्वानुमान करता है कि जीन पौधे के भीतर वास्तव में क्या करता है, इसलिए प्रजनक परिणाम का आधार चरण-दर-चरण समझ सकता है।

इन सभी गणनाओं को डेटा चाहिए। पूर्वानुमानात्मक प्रजनन का आधार बनने वाले डेटा की सबसे निचली परत स्वयं जीनोम है। Next-generation sequencing (NGS) और एक बार में अधिक लंबा खंड पढ़ने वाली तीसरी पीढ़ी की sequencing तकनीक से पूरा जीनोम फिर पढ़कर Single Nucleotide Polymorphism, insertion और deletion (InDel), तथा पूरी बड़ी संरचना बदलने वाले Structural Variant (SV) खोजे जाते हैं। एक किस्म का एक जीनोम मानचित्र पर्याप्त नहीं माना जाता, इसलिए कई वंशों के जीनोम एक-दूसरे पर रखकर Pangenome मानचित्र भी बनाए और उपयोग किए जाते हैं। समय के साथ इनके ऊपर जीन की अभिव्यक्ति की मात्रा दिखाने वाला Transcriptomics, प्रोटीन की मात्रा दिखाने वाला Proteomics, चयापचय उत्पाद दिखाने वाला Metabolomics और जीन अनुक्रम बदले बिना अभिव्यक्ति बदलने वाला Epigenetics डेटा भी परत-दर-परत जुड़ता है।

खेत से आने वाला Enviromics डेटा भी बहुत सघन है। खेत में लगाए Internet of Things सेंसर, देशव्यापी ग्रिड वाला कृषि मौसम डेटा, अमेरिकी अंतरिक्ष एजेंसी का NASA POWER उपग्रह डेटा और मिट्टी के गुणों वाला soil survey database मिलकर प्रतिदिन का न्यूनतम और अधिकतम तापमान, संचित तापमान, हवा की शुष्कता बताने वाला Vapor Pressure Deficit (VPD), मिट्टी की नमी तथा नाइट्रोजन, फॉस्फोरस और पोटैशियम की सांद्रता समय क्रम में जमा करते हैं। अलग संस्थानों और देशों के शोधकर्ताओं को यह डेटा साथ उपयोग करना हो तो पहले प्रारूप मिलना चाहिए। इसलिए डेटा के खोजने योग्य (Findable), पहुँच योग्य (Accessible), दूसरे कार्यक्रमों से परस्पर संचालनीय (Interoperable) और पुनः उपयोग योग्य (Reusable) होने के चार FAIR सिद्धांत डेटा प्रबंधन का मानक बन गए हैं। प्रजनन डेटा के आदान-प्रदान का साझा विनिर्देश BrAPI (Plant Breeding API) और फसल खेती डेटा का मानक ICASA अपनाए जाने से अलग शोध संस्थान अपना संचित डेटा मानक प्रारूप में बाँट सकते हैं।

इस प्रकार एकत्र डेटा Breedbase, OpenSILEX और CropGS-Hub जैसे एकीकृत मंचों पर रखकर ऐसे ज्ञान आधार में व्यवस्थित किया जाता है जहाँ जीनोम, फीनोटाइप और पर्यावरण को एक स्क्रीन से खोजा जा सके। शोध पत्रों और पुरानी प्रजनन पुस्तिकाओं में बिखरा ज्ञान भी दबा नहीं रह जाता।

PlantConnectome जैसी वाक्य-विश्लेषक कृत्रिम बुद्धिमत्ता दसियों हजार शोध पत्र देखती है, कौन-सा जीन किस गुण से जुड़ा बताया गया है यह अपने आप खोजती है, और उन संबंधों को बिंदुओं तथा रेखाओं वाले Knowledge Graph में व्यवस्थित करती है। दशकों पहले सेवानिवृत्त प्रजनक की पुस्तिका में हाथ से लिखी एक टिप्पणी भी अब एक खोज से निकाली जा सकती है।

डेटा जमा होना उसके भीतर उपयोगी पैटर्न पहचाने जाने के समान नहीं है। शुरुआती जीनोमिक पूर्वानुमान गणना GBLUP (Genomic Best Linear Unbiased Prediction) और RKHS (Reproducing Kernel Hilbert Space) जैसे सांख्यिकीय मॉडल करते थे। दोनों मॉडल समीकरण हल करके अनुमान लगाते हैं कि दसियों हजार चिह्नों में प्रत्येक किसी गुण में कितना योगदान देता है, फिर सारे योगदान जोड़कर किसी पौधे का अपेक्षित प्रदर्शन निकालते हैं। कई प्रश्नों की शाखाएँ बनाकर उत्तर सीमित करने वाला Random Forest, त्रुटि क्रमशः घटाकर पूर्वानुमान सुधारने वाला Extreme Gradient Boosting (XGBoost), Support Vector Machine (SVM) और LASSO regression जैसी machine learning तकनीकें जुड़ने पर पूर्वानुमान का दायरा बढ़ा। ये सांख्यिकीय और machine learning मॉडल आज भी दसियों हजार चिह्नों में वास्तव में महत्वपूर्ण कुछ सौ को चुनने और शेष को शोर मानकर हटाने में उपयोगी हैं।

सांख्यिकीय मॉडलों के बाद deep neural network आए। सोयाबीन प्रजनन में प्रयुक्त SoyDNGP जीनोमिक जानकारी को त्रि-आयामी तस्वीर की तरह सजाकर three-dimensional convolutional neural network (3D CNN) से गुजारता है और उपज, कटाई का समय तथा तेल और प्रोटीन की मात्रा का पूर्वानुमान करता है। कई प्रकार के omics डेटा को साथ लेने वाला DNGP, धान, मक्का, कपास और बाजरा की तिरपन कृषि विशेषताओं पर परखा गया CropARNet, convolutional neural network को Self-Attention से जोड़ने वाला Cropformer, जहाँ गणना स्वयं तय करती है कि इनपुट के किस भाग को अधिक भार देना है, और जीनोटाइप तथा फीनोटाइप के जटिल गैर-रैखिक संबंध संभालने वाला DPCformer क्रमशः सामने आए और पूर्वानुमान प्रदर्शन बढ़ता गया। ये मॉडल Epistasis प्रभाव पकड़ते हैं, जिसमें जीन एक-दूसरे को दबाते या बढ़ाते हैं। यह मान केवल दो या तीन जीनों के प्रभाव जोड़ने से नहीं मिलता।

AutoGP और एक साथ कई गुणों की गणना करने वाले MtCro जैसे मॉडल मक्का, धान और गेहूँ जैसी लंबे समय से डेटा जमा वाली फसलों पर लागू हुए हैं और एक ही गणना में उपज, रोग प्रतिरोध तथा दाने की गुणवत्ता देते हैं। परतें गहरी होने पर मॉडल के Overfitting में फँसने की संभावना बढ़ती है, जिसमें वह प्रशिक्षण डेटा की छोटी विशेषताएँ तक याद कर लेता है और परीक्षण डेटा पर अच्छा पर वास्तविक खेत में गलत प्रदर्शन करता है। इसे रोकने के लिए न्यूरल नेटवर्क नोडों को यादृच्छिक रूप से बंद करने वाला Dropout और गणना मान को बहुत बड़ा होने से रोकने वाली L2 regularization जैसी तकनीकें साथ प्रयोग होती हैं। नए मॉडलों के साथ प्रथा केवल सटीकता बताने से बदलकर यह रिपोर्ट करने की ओर बढ़ रही है कि पहले कभी न देखे गए खेतों में प्रदर्शन कितना स्थिर रहता है।

जीनोम पढ़ने वाली कृत्रिम बुद्धिमत्ता ने जीन के nucleotide sequence को मनुष्य की भाषा जैसा मानना शुरू करके एक और कदम बढ़ाया। AgroNT (Agro-Nucleotide Transformer) और FloraBERT को gene expression नियंत्रित करने वाले जीन के आगे और पीछे के noncoding क्षेत्रों, यानी promoter और enhancer, के अनुक्रम पर बिना उत्तर-लेबल वाले Self-Supervised Learning से पहले प्रशिक्षित किया जाता है। प्रशिक्षण के बाद मॉडल पहले कभी न देखी गई पौध प्रजाति का अनुक्रम लेकर तुरंत gene expression की मात्रा और regulatory region की सक्रियता पहचान सकता है। PlantCaduceus ने और आगे बढ़कर दूर संबंध वाली सोलह angiosperm प्रजातियों के जीनोम साथ सीखे और supervised learning मॉडल से अधिक सही बताया कि कोई जीन अनुक्रम लंबे विकासक्रम में क्यों सुरक्षित रहा।

कृत्रिम बुद्धिमत्ता पूर्वानुमान से आगे बढ़कर जीनोम को सीधे संपादित करने में भी आ गई है। विकास दल द्वारा पौधों के लिए अपनी तरह का पहला बताया गया OpenCRISPR-1, CRISPR-Cas gene editing प्रणाली की त्रि-आयामी संरचनाओं और nucleotide sequence के विशाल मौजूदा डेटा से सीखता है और फिर पहले कभी न रहे नए cleavage enzyme तथा guide RNA (gRNA) स्वयं बनाता है, जिसमें gRNA कैची को इच्छित स्थान तक ले जाने वाला छोटा आनुवंशिक अनुक्रम है। प्राकृतिक cleavage enzyme को ज्यों का त्यों इस्तेमाल करने की तुलना में गलत स्थान काटने वाले Off-target दुष्प्रभाव घटा सकना इस तरीके का मूल्य है। जीन संपादन में ठीक इच्छित स्थान ही काटना आवश्यक है, इसलिए यही सटीकता सफलता या विफलता तय करती है।

इन सभी पूर्वानुमान और डिजाइन क्षमताओं को जोड़ने वाला विशाल Breeding Foundation Model भी विकसित किया जा रहा है। मनुष्य की भाषा सीखने वाले large language model की तरह breeding foundation model भी Scaling Law का पालन करता है, जिसमें मॉडल का आकार, प्रशिक्षण डेटा और गणना साथ बढ़ने पर प्रदर्शन अनुमानित मात्रा में सुधरता है। आकार एक सीमा पार करने पर Emergent Abilities प्रकट होती हैं और मॉडल अचानक वे काम करने लगता है जो पहले नहीं कर सकता था। वह सीमा कब पार होगी, यह पहले नहीं जाना जा सकता। इसका एक उदाहरण Chain-of-Thought क्षमता है, जो कई जीनों के एक साथ संपादन के संयोजन का पूरी फसल पर प्रभाव चरण-दर-चरण जाँचती है। फिर भी बड़े मॉडल Hallucination से मुक्त नहीं हैं, जिसमें वे विश्वसनीय लगने वाला पर गलत उत्तर आत्मविश्वास से देते हैं, इसलिए उत्तर से पहले मान्य प्रजनन डेटाबेस खोजने वाली Retrieval-Augmented Generation (RAG) तकनीक भी साथ उपयोग होती है। पूरे मॉडल को शुरू से फिर प्रशिक्षित करने के बजाय कुछ गणना मार्गों को समायोजित करने वाली Low-Rank Adaptation (LoRA) तकनीक से महँगे सर्वर के बिना किसी विशेष फसल और क्षेत्र के लिए अलग संस्करण बनाया जा सकता है।

प्रशिक्षित मॉडल द्वारा वास्तविक पूर्वानुमान मान देने की प्रक्रिया मोटे तौर पर दो चरणों में बँटी है। पहले offline चरण में जीनोम, फीनोटाइप और Enviromics का विशाल संयुक्त डेटा सैकड़ों या हजारों GPU वाले server cluster में बाँटा जाता है, और सीमित hardware पर बड़े मॉडल का प्रशिक्षण संभव बनाने के लिए memory waste घटाने वाली ZeRO optimization तथा three-dimensional parallelization से मॉडल को कई सप्ताह प्रशिक्षित किया जाता है। प्रशिक्षण पूरा होने पर मॉडल online

चरण में जाता है और वास्तविक प्रजनन स्थल पर उम्मीदवार माता तथा पिता वंशों के जीनोम मानचित्र और लक्षित क्षेत्र के मौसम परिदृश्य लेता है। फिर दसियों हजार संकरण संयोजनों के प्रदर्शन को कंप्यूटर में पहले से आजमाने वाला In-silico Cross Screening कुछ ही सेकंड में पूरा हो जाता है। स्क्रीन पर फैली रैंकिंग उसी कुछ सेकंड की गणना को रात भर बार-बार दोहराने का परिणाम है। जो उत्तर पहले खेत में बोकर पूरी पीढ़ी उगाने के बाद मिलता था, वह अब बीज को मिट्टी में रखने से पहले कंप्यूटर में मिल जाता है।

इन पूर्वानुमानों की वास्तविक विश्वसनीयता कुछ संख्याओं से जाँची जाती है। वास्तविक प्रदर्शन और मॉडल द्वारा पहले से निकाले मान के साथ-साथ बदलने की मात्रा बताने वाली prediction accuracy का लक्ष्य 0.70 से 0.85 के बीच रखा जाता है। पूरे प्रदर्शन अंतर में मॉडल द्वारा समझाए गए अनुपात को दर्शाने वाले coefficient of determination के लिए 0.75 से 0.90 का मानक लिया जाता है। उपज, बाली निकलने की तारीख और तने की ऊँचाई जैसे संख्यात्मक गुणों को mean absolute error (MAE), यानी पूर्वानुमान और माप के औसत अंतर, तथा root mean square error (RMSE), यानी उन अंतरों के वर्ग के औसत के वर्गमूल, से फिर जाँचा जाता है। रोगग्रस्त पत्तियाँ सही पहचानने की क्षमता precision, यानी रोगी बताई गई पत्तियों में वास्तव में रोगी पत्तियों का अनुपात, recall, यानी सभी वास्तविक रोगी पत्तियों में मॉडल द्वारा मिली पत्तियों का अनुपात, और दोनों को मिलाने वाले F1 score से मापी जाती है, जबकि gene editing tool ने इच्छित स्थान कितना सही काटा, इसे on-target efficiency और गलत स्थान काटने वाले Off-target अनुपात से अलग-अलग मापा जाता है।

प्रजनक एक दूसरी कसौटी पर अधिक ध्यान देते हैं। वह कसौटी बताती है कि इस सटीकता से वास्तविक किस्म कितनी तेजी से सुधरती है। rate of genetic gain कहलाने वाला यह मान selection intensity, prediction accuracy और गुण में बची genetic variation को गुणा करके और फिर एक पीढ़ी से अगली तक लगने वाले समय से भाग देकर निकाला जाता है। पीढ़ी अंतराल जितना कम और पूर्वानुमान जितना सही होगा, उतनी ही अवधि में किस्म सुधार की मात्रा उतनी अधिक होगी। Heritability भी साथ देखा जाता है, जो पूरे गुण अंतर में जीन का हिस्सा बताता है, और यह जितना अधिक होगा, पर्यावरण की तुलना में गुण को जीन उतना अधिक निर्धारित करेंगे तथा चयन का प्रभाव बढ़ेगा। बड़े मॉडलों की क्षमता साथ परखने के लिए SeedBench जैसे साझा benchmark भी बने हैं, जिनसे मानकीकृत कसौटी पर तुलना की जा सकती है कि कौन-सा मॉडल gene search, phenotype interpretation और cross design में अच्छा है।

इन गणनाओं से खेत में वास्तविक बदलाव का उदाहरण Consultative Group on International Agricultural Research (CGIAR) के International Maize and Wheat Improvement Center (CIMMYT) में मिलता है। पूर्वी अफ्रीका और लैटिन अमेरिका के मक्का तथा गेहूँ प्रजनन कार्यक्रमों में पूरे जीनोम के marker data, मानवरहित विमान से मापे multispectral index और मौसम तनाव रिकॉर्ड मिलाने वाली predictive breeding प्रणाली लगाने पर गंभीर सूखे और उच्च तापमान में उपज तथा सूखा सहनशीलता का पूर्वानुमान पारंपरिक सांख्यिकीय मॉडल से लगभग 15 प्रतिशत से 25 प्रतिशत अधिक सटीक हुआ। खुले परीक्षण खेतों के भूखंड घटे और संकरण से अगली पीढ़ी पाने का समय लगभग

आधा रह गया। अफ्रीका में अधिक सूखे वाले अगले खेती मौसम से पहले प्रजनक बोए बिना ही उन वंशों को छॉट सकते हैं जो टिक सकेंगे।

सोयाबीन प्रजनन में SoyDNGP पहले से सार्वजनिक web service के रूप में चल रहा है। प्रजनक किसी वंश का जीनोमिक डेटा अपलोड करता है तो three-dimensional convolutional neural network उपज, कटाई समय तथा तेल और प्रोटीन की मात्रा निकालकर संभावनाशील माता-पिता संयोजन अपने आप चुनता है। मक्का, धान और गेहूँ के लिए CropGS-Hub तथा AutoGP मंच भी इसी तरह जीनोटाइप और फीनोटाइप डेटा को web database में जोड़ते हैं और किसी भी शोधकर्ता को पहुँच देकर virtual cross simulation चलाने देते हैं। एक प्रयोगशाला द्वारा कई वर्षों में जमा डेटा दुनिया के दूसरी ओर का संस्थान तुरंत लेकर इस्तेमाल कर सकता है।

Syngenta और InstaDeep ने साथ विकसित AgroNT को अनेक पौध प्रजातियों के regulatory sequence पर लगाकर एक भी बीज बोए बिना पहले ही क्रमबद्ध किया कि कौन-सा जीन पर्यावरण परिवर्तन के प्रति कितना संवेदनशील होगा। हजारों संभावित regulatory region का भार एक साथ निकालकर उन्होंने जलवायु सहनशील किस्म बनाने के लिए आवश्यक आणविक स्तर का आधार तैयार किया। बीज कंपनियों और कृत्रिम बुद्धिमत्ता कंपनियों की साझेदारी बढ़ना स्वयं संकेत है कि यह तकनीक प्रयोगशाला से बाहर निकलकर व्यावसायिक प्रजनन का साधन बन रही है। इस सहयोग का महत्व अलग है, क्योंकि यह केवल शोध पत्र में नहीं रहा बल्कि वास्तविक प्रजनन pipeline में रखा गया है।

OpenCRISPR-1 द्वारा बनाए gene editing tool ने फसलों के सूखा प्रतिरोध और रोग प्रतिरोध के लिए जिम्मेदार जीनों का सटीक संपादन किया। परिणामों ने दिखाया कि प्राकृतिक cleavage enzyme को बिना बदले इस्तेमाल करने की तुलना में अनचाहे स्थान पर प्रभाव का दुष्परिणाम कम हुआ। एक बीज के जीनोम में ठीक इच्छित पंक्ति और अक्षर चुनकर सुधारना अब संभावना से आगे बढ़कर प्रमाणित परिणाम बन गया है। प्रयोगशाला के बाहर खेत में यह परिणाम कई पीढ़ियों तक बना रहेगा या नहीं, इसका निश्चय कुछ और खेती मौसम गुजरने के बाद होगा।

जापान के Kochi प्रांत में SAWACHI नामक cloud platform 1,600 से अधिक ग्रीनहाउसों का पर्यावरण डेटा और 3,000 खेतों का उत्पादन रिकॉर्ड राष्ट्रीय कृषि big-data network WAGRI से जोड़ता है, फिर वृद्धि तथा उपज का पूर्वानुमान करने वाले AI मॉडल चलाकर यह जाँचता है कि उम्मीदवार प्रजनन वंश वास्तविक खेत के अनुकूल कितने हैं। उसी देश के Aichi प्रांत में carnation किस्म सुधार के लिए अलग प्रकार की कृत्रिम बुद्धिमत्ता प्रयोग होती है। शोधकर्ता उस epigenetic घटना को स्पष्ट करते हैं जिसमें पर्यावरण या propagation प्रक्रिया carnation के gene expression को बदलकर पंखुड़ी का रंग बदलती है, और फिर इस ज्ञान से इच्छित रंग वाली नई किस्म सटीकता से चुनते हैं। हजारों ग्रीनहाउसों का डेटा जोड़ना और एक पंखुड़ी रंग की आनुवंशिक प्रक्रिया की गहराई में जाना आकार में अलग हैं, पर दोनों एक ही predictive breeding ढाँचे में साथ चलते हैं।

उपलब्धियाँ स्पष्ट हैं और अनसुलझी समस्याएँ भी स्पष्ट हैं। ग्रीनहाउस या कंप्यूटर के virtual environment में प्रशिक्षित मॉडल कभी-कभी पहले कभी न आए चरम मौसम या कई प्रतिकूलताओं के साथ पड़ने वाले compound environment में पूर्वानुमान क्षमता बहुत खो देते हैं। virtual space और

वास्तविक खेत के इस अंतर को Sim-to-Real Gap कहते हैं, और इसका कारण Domain Shift है जिसमें प्रशिक्षण में न मिली स्थिति आने पर निर्णय अस्थिर हो जाता है। इसे घटाने के लिए अधिक विविध पर्यावरणों का डेटा लगातार जोड़ना और खेत से आने वाले डेटा से मॉडल को स्वयं अद्यतन करने वाली online adaptive learning प्रणाली बनाना आवश्यक है।

मॉडल ने कोई उत्तर क्यों दिया, यह न समझा पाना भी बड़ी समस्या है। deep neural network अधिक सटीकता देते हुए भी किसी विशेष संकरण संयोजन की सिफारिश का कारण प्रजनक को समझ आने वाले जैविक प्रमाण में नहीं बता सकता। निर्णय देकर उस तक पहुँचने का मार्ग छिपाने के कारण ऐसा मॉडल Black-box कहलाता है। इस डिब्बे को खोलने के प्रयासों में SHAP और Grad-CAM जैसी व्याख्या तकनीकें तथा Knowledge Graph जोड़कर पूर्वानुमान परिणाम को दिखाई देने वाले जैविक कारण संबंध से जोड़ने वाले अध्ययन शामिल हैं। जब तक प्रमाण आँख से न दिखे, अत्यधिक सटीक मॉडल भी अनुभवी प्रजनक का पूरा विश्वास कठिनाई से पाएगा।

गणना लागत भी बाधा बनती है। अरबों parameters वाले breeding foundation model को प्रशिक्षित और चलाने के लिए महँगे GPU server चाहिए, इसलिए ऐसे उपकरण न खरीद सकने वाली छोटी प्रयोगशालाओं और छोटे प्रजनन उद्यमों के लिए इस तकनीक तक पहुँचना भी कठिन है। गणना मानों को कुछ integer स्तरों तक घटाकर मॉडल हल्का करने वाली Quantization और बड़े मॉडल का सीखा ज्ञान छोटे मॉडल में ले जाने वाली Knowledge Distillation जैसी तकनीकों का इस सीमा को घटाने के लिए अध्ययन हो रहा है। cloud पर server किराए से लिया जा सकता है, लेकिन अनेक कंपनियाँ अपना breeding data बाहरी server को सौंपने से हिचकती हैं। एक server की लागत उठा सकना नवीनतम प्रजनन तकनीक तक पहुँच को बाँटने वाली एक और रेखा बन रहा है।

अंत तक बची बाधा मनुष्य है। उन्नत कृत्रिम बुद्धिमत्ता algorithm संभालने के साथ molecular genetics और field agronomy दोनों को समझने वाले बहुविषयी विशेषज्ञ अब भी दुर्लभ हैं, इसलिए प्रयोगशाला का परिणाम वास्तविक खेत में किस्म सुधार तक धीरे पहुँचता है। कृत्रिम बुद्धिमत्ता द्वारा बनाई gene-edited फसलों की समीक्षा और स्वीकृति कैसे हो तथा डेटा और मॉडल का स्वामित्व किसे मिले, यह तय करने वाले कानून और संस्थाएँ अब भी तकनीक की गति से पीछे हैं। बीज का पूर्वानुमान और डिजाइन करने की क्षमता कितनी भी मजबूत हो, उसकी समीक्षा तथा जिम्मेदारी लेने वाले मनुष्य और नियम न हों तो खेत तक का रास्ता बंद रहता है।

स्रोत और संदर्भ

शोध पत्र

1. Xu, Q., Zheng, B., & Zhong, S. (2026). Artificial intelligence empowering modern agricultural biological breeding. Smart Agriculture, 8(3), 69-85. <https://doi.org/10.12133/j.smartag.SA202602016>
2. Harnessing artificial intelligence in plant breeding: Innovations in digital phenotyping and breeding methods. (2026). Plant Methods. <https://doi.org/10.1007/s13007-026-01286-0>

3. Shokor, F. (2025). Deep learning models for genomic prediction accounting for heterosis in crossbreeding systems and multi-trait selection (Doctoral dissertation). Université Paris-Saclay, INRAE, AgroParisTech.
4. Qiu, J., Liu, Y., Gao, X., Huang, Y., Zhang, H., Tian, F., Li, W., & Feng, Z. (2026). AgriAgent: End-to-end large model agent system architecture for agricultural environment control. *Smart Agriculture*, 8(2), 220-236. <https://doi.org/10.12133/j.smartag.SA202507042>
5. Yang, J., Yang, W., Yang, S., He, L., & Zhang, D. (2026). Intelligent Q&A method for crop diseases and pests using LLM augmented by adaptive hybrid retrieval. *Smart Agriculture*, 8(1), 52-61. <https://doi.org/10.12133/j.smartag.SA202506026>
6. 田中佑, 郭威, 山口友亮, 桂圭佑, 中島洸太, 戸田陽介. (2025). AI時代の作物学研究. *日本作物学会紀事*, 94(3), 329-330.
7. APSIM crop model innovations for breeding and deep learning. (2026). in silico Plants. <https://doi.org/10.1093/insilicoplants/diaa016>
8. CropARNet: self-attention और deep residual network पर आधारित genomic selection model. (n.d.). ScienceDirect. <https://www.sciencedirect.com/science/article/pii/S2772899425000242>
9. Cropformer: convolutional neural network और self-attention को जोड़ने वाला फसल phenotype prediction model. (n.d.). ScienceDirect. <https://www.sciencedirect.com/science/article/pii/S2590346224006448>
10. DPCformer: convolutional neural network और self-attention आधारित genotype-phenotype nonlinear relation prediction model. (n.d.). arXiv. <https://arxiv.org/html/2510.08662v1>
11. PlantCaduceus: 16 angiosperm प्रजातियों के genome pretraining पर आधारित बहु-प्रजातीय पौध DNA language model. (n.d.). Computomics. <https://www.computomics.com/news-reader/foundation-models-in-plant-breeding-an-introduction-copy.html>
12. AI breeder: फसल प्रजनन के लिए genomic prediction artificial intelligence का अध्ययन. (n.d.). ScienceDirect. <https://www.sciencedirect.com/science/article/pii/S2949952623000109>

व्याख्यान और वीडियो सामग्री

1. Plant-OpenCRISPR1. (2025). Plant-OpenCRISPR1: The world's first AI-designed genome editing platform for plants [Video]. YouTube. <https://www.youtube.com/watch?v=DEkNOyybGtE>
2. World Food Prize, & CIMMYT. (2025). Predictive breeding: Bridging genetics, artificial intelligence and agriculture (B. M. Prasanna) [Video]. YouTube. <https://www.youtube.com/watch?v=FWcxeEC90JA>
3. WAF. (2025). WAF interactive webinar on biotechnology and AI contributions to plant breeding [Video]. YouTube. <https://www.youtube.com/watch?v=xkVT9D7Nqy0>
4. 農業農村情報通信環境整備準備会. (2026). 地域でデータを共有しよう、農業データの利活用最前線、データ駆動型農業WAGRIとIoPクラウド(SAWACHI)でのNext次世代型施設園芸システム(第5回オンラインセミナー) [Video]. YouTube. <https://www.youtube.com/watch?v=k8Qvv6CKB2A>
5. 愛知県農業水産局. (2026). あいち農業イノベーションプロジェクト2027技術提案募集説明会 [Video]. YouTube. <https://www.youtube.com/watch?v=jpkoNqscGu8>

इस पुस्तक का समर्थन करें

यदि यह पुस्तक उपयोगी लगी हो, तो आगामी अनुवादों,
सार्वजनिक संस्करणों और खुले AI ज्ञान कार्यों को PayPal से सहयोग दें।



PayPal

<https://paypal.me/kimkjkj>

QR कोड स्कैन करें या ऊपर दिया गया लिंक खोलें।