

वानिकी और कृषि-वानिकी का भवष्य

कृत्रिम बुद्धिमत्ता और डिजिटल नवाचार से संचालित



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://www.india.gov.in/publications/268677-410-4281-84-936815>
4

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

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

विषय-सूची

अध्याय 1	वन प्रतिमान में बदलाव: डेटा और AI आधारित वन बिग डेटा तथा डिजिटल ट्विन	3
1.1	वन संसाधन प्रबंधन में प्रतिमान परिवर्तन और डिजिटल ट्विन का निर्माण	5
1.2	बहु-माध्यम दूरसंवेदी डेटा संलयन प्रौद्योगिकी	13
1.3	वानिकी-विशिष्ट विशाल भाषा मॉडल (ForestGPT) और बुद्धिमान निर्णय समर्थन	20
अध्याय 2	सटीक वानिकी: प्रत्येक वृक्ष का विश्लेषण और बायोमास व कार्बन का सटीक मापन	28
2.1	UAV-LiDAR और उच्च-रिज़ॉल्यूशन इमेजरी पर आधारित व्यक्तिगत वृक्ष-प्रजाति वर्गीकरण	30
2.2	भूमि-ऊपरी बायोमास (AGB) और वन कार्बन भंडार का अनुमान	37
2.3	वन मृदा की गतिशीलता और भूमि-आवरण परिवर्तन की निगरानी	43
अध्याय 3	वन आपदा और पारितंत्र स्वास्थ्य की निगरानी: एआई पूर्वोक्षण और आरंभिक चेतावनी	52
3.1	मशीन लर्निंग और डीप लर्निंग आधारित वनाग्नि जोखिम पूर्वानुमान और दहन क्षेत्र की पहचान	54
3.2	कीट-रोग (चीड़ का सूत्रकृमि रोग आदि) एवं मृत वृक्ष (Dead Tree) का प्रारंभिक प्रतिबिंब-आधारित निदान	61
3.3	अवैध वृक्ष-कटाई की ध्वनि पहचान और IoT/ब्लॉकचेन वन संरक्षण नेटवर्क	68
अध्याय 4	स्मार्ट वानिकी कार्य और रोबोटिक्स: कार्य सुरक्षा, स्वायत्त चालन और वन-मार्ग जाल का अनुकूलन	76
4.1	वन-मार्ग और कार्य-पथ (Skid Trail) का स्वचालित निष्कर्षण तथा भू-आकृति के अनुरूप कटाई योजना	78
4.2	रिमोट-नियंत्रित कटाई मशीनें, स्वचालित रूप से चलने वाले फॉरवर्डर और वानिकी रोबोटिक्स	86
4.3	कंप्यूटर विज्ञान और Wearable सेंसर पर आधारित श्रमिक कार्य सुरक्षा निगरानी	94
अध्याय 5	सतत कृषि वानिकी और लकड़ी आपूर्ति शृंखला का डिजिटल रूपांतरण	101
5.1	कृषि वानिकी प्रणालियों में जल-उपयोग दक्षता (WUE) और पारिस्थितिकी तंत्र सेवाओं का अनुकूलन	103
5.2	ICT-आधारित लकड़ी अनुरेखण (QR/इलेक्ट्रॉनिक टैग) और लकड़ी की गुणवत्ता का स्वचालित आकलन	110
5.3	चक्रीय जैव-अर्थव्यवस्था और वन कार्बन क्रेडिट	116

अध्याय 1

वन प्रतिमान में बदलाव: डेटा और AI आधारित वन
बिग डेटा तथा डिजिटल ट्विन

1.1

वन संसाधन प्रबंधन में प्रतिमान परिवर्तन और डिजिटल ट्विन का निर्माण

सुबह छह बजे, एक सर्वेक्षक अपने लंबी पैदल यात्रा के जूतों के फीते कसता है और एक मापने वाला टेप, एक वृक्ष-ऊंचाई व्यास मापने वाला टेप, और एक पेपर फ़िल्ड नोटबुक को अपने बैकपैक में पैक करता है। आज का नमूना प्लॉट समुद्र तल से 700 मीटर ऊपर एक पहाड़ी की ढलान पर स्थित है, और मानचित्र पर अंकित निर्देशांक तक पहुंचने में पैदल चलने में दो घंटे से अधिक का समय लगता है। कोरिया वन सेवा ने देश भर के जंगलों में 5,400 नमूना भूखंड स्थापित किए हैं। सर्वेक्षक इन स्थलों पर वृक्ष-संचय और वन स्वास्थ्य सहित 69 वस्तुओं को रिकॉर्ड करते हैं, और पांच साल के चक्र पर उन्हीं भूखंडों का दोबारा दौरा करते हैं। नमूना प्लॉट पर पहुंचने पर, सर्वेक्षक प्रत्येक पेड़ के चारों ओर एक टेप लपेटता है, पैमाने को पढ़ता है, और फ़िल्ड नोटबुक में छाती की ऊंचाई पर इसका व्यास (डीबीएच, छाती की ऊंचाई पर मापा गया पेड़ के तने का व्यास) रिकॉर्ड करता है। खड़ी ढलान पर, आंखों के स्तर पर हाइपोमीटर को संरेखित करना, कोण को मापना और पेड़ की ऊंचाई की गणना करने में समय लगता है। पूरे दिन के काम के बाद भी, एक सर्वेक्षक दो या तीन से अधिक भूखंड पूरा नहीं कर सकता है। टेप से रगड़ने से उंगलियां फट जाती हैं, और जब अचानक बौछार गुजरती है, तो फ़िल्ड नोटबुक पर पेंसिल के निशान तब तक धुंधले हो जाते हैं, जब तक उन्हें पढ़ना मुश्किल नहीं हो जाता।

इस तरह से एकत्र किए गए नंबर सटीक होते हैं, लेकिन वे जल्दी ही पुराने हो जाते हैं। यहां तक कि अगर जंगल की आग से कोई पहाड़ी जल जाती है या कीट हर पांच साल में किए जाने वाले सर्वेक्षणों के बीच पूरे स्टैंड को खा जाते हैं, तो अगले सर्वेक्षण तक आधिकारिक आंकड़ों में बदलाव दिखाई नहीं देता है। लंबे समय से, राष्ट्रीय वन सूची और टाइप II वन सूची दोनों, चाहे राष्ट्रीय या निजी वनों में हों, इस तरह से संचालित होती रही हैं। मानव पैरों और आंखों पर निर्भर सर्वेक्षण धीमे और महंगे होते हैं, और वे समय और स्थान की सूक्ष्म स्तर पर पूरी तस्वीर नहीं दे पाते हैं। यही एकमात्र समस्या नहीं है।

यहां तक कि जब योजनाकार एक सटीक कटाई योजना तैयार करने की कोशिश करते हैं, तो पांच साल पुराने आंकड़े उनके पास पेड़ों की वर्तमान स्थिति का अनुमान लगाने के अलावा कोई विकल्प नहीं छोड़ते हैं।

नमूना भूखंडों से ग्रिड मानचित्रों तक

इन सीमाओं को पार करने के प्रयास पूरे वानिकी क्षेत्र में फैल रहे हैं। वानिकी का डिजिटल परिवर्तन (डीएक्स) कागज की पर्चियों और हाथ से तैयार की गई योजनाओं को मोबाइल एप्लिकेशन और भौगोलिक सूचना प्रणाली (जीआईएस) डेटा में स्थानांतरित करने से शुरू होता है। अगले चरण में, संचित डेटा को वन प्रबंधन, मांग के साथ लकड़ी की आपूर्ति के मिलान और इलेक्ट्रॉनिक अनुप्रयोग प्रणालियों से जोड़ा जाता है। अंतिम चरण में, कटाई और रोपण जैसी अपस्ट्रीम वानिकी प्रक्रियाओं से वितरण और प्रसंस्करण जैसी डाउनस्ट्रीम प्रक्रियाओं और यहां तक कि अन्य उद्योगों के साथ संपर्क के बिंदुओं तक वास्तविक समय में डेटा प्रवाह होता है, जो निर्णय लेने को नया आकार देता है।

कोरिया में यह चलन नया नहीं है।

राष्ट्रीय वन विज्ञान संस्थान के वन आईसीटी अनुसंधान केंद्र ने डिजिटल वन संसाधन जानकारी एकत्र करने और सटीक वानिकी के लिए इसका उपयोग करने के लिए गैंगवॉन प्रांत में गैरिसन अग्रणी वन प्रबंधन परिसर में हवाई, स्थलीय और बैकपैक LiDAR उपकरणों को एक साथ तैनात करते हुए परीक्षण जारी रखा है। क्योंकि प्रत्येक उपकरण संग्रह सटीकता और संचालन गति में भिन्न होता है, प्रसंस्करण के बाद का काम यह निर्धारित करने के लिए किया जाता है कि कौन सा संयोजन वास्तविक क्षेत्र की स्थितियों के अनुकूल था।

प्रशासनिक जिलों या पारंपरिक रूप से परिभाषित उप-कम्पार्टमेंट सीमाओं, वन प्रबंधन के लिए उपयोग किए जाने वाले छोटे डिवीजनों के आधार पर आंकड़े तैयार करने की पारंपरिक पद्धति में लंबे समय से दोष था। यहां तक कि एक ही उप-कम्पार्टमेंट के भीतर, पेड़ की ऊंचाई और विकास दर घाटियों और पर्वतमालाओं की सूक्ष्म स्थलाकृति के साथ भिन्न होती है, लेकिन जैसे ही उप-कम्पार्टमेंट स्तर पर आंकड़ों का औसत निकाला जाता है, वे अंतर धुंधले हो जाते हैं। हाल के प्रयासों ने वन स्थानिक डेटा को प्रत्येक तरफ 20 मीटर मापने वाले वर्ग ग्रिड में पुनर्गठित करके समस्या को हल करने की मांग की है। इसका उद्देश्य प्रत्येक ग्रिड सेल में एयरबोर्न लेजर स्कैनिंग (एएलएस) और उपग्रह डेटा की सटीकता को संरक्षित करना है।

इस परिवर्तन के केंद्र में निर्णय समर्थन प्रणाली (डीएसएस) और एकीकृत प्लेटफॉर्म हैं जो कई प्रकार के डेटा को एक साथ लाते हैं। डीएसएस एक सॉफ्टवेयर है जो कई डेटासेट एकत्र करता है और उनका विश्लेषण करता है, फिर आंकड़े और ग्राफ़ प्रदर्शित करता है जिससे लोग निर्णय लेते समय परामर्श कर सकते हैं। यूरोपीय संघ के होराइजन यूरोप कार्यक्रम के तहत नेपल्स फेडेरिको II विश्वविद्यालय के नेतृत्व में DigiMedFor परियोजना, तीन स्तंभों के आसपास प्रौद्योगिकियों को एकीकृत करती है: वन संसाधन निगरानी और इन्वेंट्री निर्माण; लकड़ी का पता लगाने की क्षमता और ग्रेडिंग; और वन-नियोजन निर्णयों के लिए समर्थन। परियोजना द्वारा विकसित फ़ॉरिस्ट पाथवे, एक वेब-आधारित विशेषज्ञ प्रणाली है जो पेड़ों की प्रजातियों, जैव-जलवायु क्षेत्र, साइट उत्पादकता और प्रबंधन लक्ष्यों को इनपुट के रूप में लेती है और जंगल की देखभाल के लिए एक मार्ग की सिफारिश करती है। यह एक मार्गदर्शन उपकरण के करीब है जो वन प्रबंधकों को एक परिचालन सिम्युलेटर की तुलना में अपने विकल्पों को सीमित करने में मदद करता है जो स्वचालित रूप से एक विशिष्ट क्षेत्र की ड्रोन सूची और नियमों को संसाधित करता है।

वन डिजिटल ट्विन की संरचना को चार परतों में विभाजित किया जा सकता है। सबसे नीचे भौतिक पर्यावरण है जो वास्तविक जंगल, मिट्टी और माइक्रोक्लाइमेट से बना है। इसके ऊपर उपग्रहों, मानव रहित हवाई वाहनों (यूएवी), ग्राउंड IoT सेंसर और स्थलीय LiDAR द्वारा एकत्र की गई डेटा परत होती है। तीसरी परत इन डेटा को एकीकृत करती है, गहन शिक्षा के साथ सुविधाओं को निकालती है, और अंतरिक्ष और समय में संरेखित एक सिमुलेशन इंजन चलाती है। शीर्ष परत सटीक वन प्रबंधन, पूर्वानुमानित विश्लेषण, कार्बन पृथक्करण का सत्यापन और स्वायत्त संचालन के लिंग जैसे व्यावहारिक अनुप्रयोग प्रदान करती है।

यह तकनीक चरणों में विकसित हुई है। यह एक स्थिर त्रि-आयामी मॉडल के रूप में शुरू हुआ जिसने केवल जंगल की नकल की। इसके बाद यह डिजिटल छाया चरण से गुज़रा, जिसमें सेंसर डेटा केवल एक दिशा में प्रतिबिंबित होता था: वास्तविक स्थिति आभासी मॉडल में दिखाई देती थी लेकिन वापस प्रवाहित नहीं होती थी। वर्तमान लक्ष्य एक पूरी तरह से साकार डिजिटल ट्विन है जिसमें वास्तविक और आभासी वन संकेतों का आदान-प्रदान करते हैं और एक-दूसरे को वास्तविक समय पर प्रतिक्रिया प्रदान करते हैं।

LiDAR से उकेरा गया एक वृक्ष

LiDAR एक उपकरण है जो लेजर प्रकाश उत्सर्जित करता है और प्रकाश को किसी वस्तु से टकराने और वापस लौटने में लगने वाले समय को मापकर दूरी की गणना करता है। सिद्धांत कठिन नहीं है।

डिवाइस कहाँ लगाया गया है इसके आधार पर नाम बदलता है। एक विमान पर, यह एयरबोर्न लेजर स्कैनिंग (एएलएस) है; मानव रहित हवाई वाहन पर, यूएवी लेजर स्कैनिंग (यूएलएस); जमीन पर स्थिर, स्थलीय लेजर स्कैनिंग (टीएलएस); और चलते समय एक व्यक्ति की पीठ पर एक मोबाइल मैपिंग सिस्टम (एमएमएस) रखा जाता है।

पारंपरिक LiDAR आम तौर पर केवल एक तरंग दैर्ध्य का उत्सर्जन करता है, इसलिए हालांकि यह सटीक रूप से पता लगा सकता है कि लेजर पल्स कहाँ परिलक्षित हुआ था, यह यह भेद करने में खराब है कि रिटर्न एक पत्ती या शाखा से आया था या नहीं। मल्टीस्पेक्ट्रल LiDAR, जो एक साथ तीन तरंग दैर्ध्य उत्सर्जित करता है, ने हाल ही में इस समस्या का समाधान करना शुरू कर दिया है। एक अध्ययन में, कई डीप-लर्निंग मॉडल ने सार्वजनिक फ़ॉरेस्टसिमेंटिक-एमएस बेंचमार्क डेटासेट पर प्रतिस्पर्धा की। प्वाइंट ट्रांसफार्मर V3 (PTv3) मॉडल का परीक्षण छह घटकों के वर्गीकरण पर किया गया था: जमीन, झाड़ियाँ, तने, शाखाएँ, पत्तियाँ और गिरी हुई लकड़ी। इसने 69.1 प्रतिशत का औसत इंटरसेक्शन ओवर यूनियन (mIoU, औसत सीमा जिस तक मॉडल-अनुमानित और वास्तविक क्षेत्र ओवरलैप होता है) हासिल किया, अन्य मॉडलों से 21.8 प्रतिशत अंक बेहतर प्रदर्शन किया। जहाँ पत्तियाँ और शाखाएँ आपस में जुड़ी हुई हैं, वहाँ एक तरंग दैर्ध्य के साथ पेड़ के घटकों को अलग करना मुश्किल है, लेकिन जब तीन तरंग दैर्ध्य का उपयोग किया जाता है तो तस्वीर बदल जाती है। गिरी हुई मृत लकड़ी के लिए सटीकता में 12.7 प्रतिशत अंक, शाखाओं के लिए 4.5 प्रतिशत अंक और तनों के लिए 2.5 प्रतिशत अंक की वृद्धि हुई।

एक और दृष्टिकोण है: एकल-स्कैन स्थलीय LiDAR, जो श्रम-गहन एकाधिक स्कैन पर निर्भर होने के बजाय केवल एक बार किसी साइट को स्वीप करता है। संयुक्त राज्य अमेरिका के इंडियाना में मार्टेल फ़ॉरेस्ट के मिश्रित दृढ़ लकड़ी के जंगल में, शोधकर्ताओं ने एकल-स्कैन पॉइंट-क्लाउड डेटा को दो-आयामी अनुमानित

छवियों में परिवर्तित किया और व्यक्तिगत पेड़ों के उपरोक्त ग्राउंड बायोमास का अनुमान लगाने के लिए कनवल्शन और ध्यान के संयोजन के साथ एक CoAtNet तंत्रिका नेटवर्क का उपयोग किया। पेड़ों के पीछे रोड़ा लगाने की सीमा के बावजूद, विधि 0.73 की व्याख्यात्मक शक्ति तक पहुंच गई और यादृच्छिक वन और प्वाइंट ट्रांसफार्मर जैसे तुलना मॉडल से बेहतर प्रदर्शन किया।

2026 में, एक अन्य प्रयास में बिंदु बादलों का पूरी तरह से अलग तरीके से इलाज किया गया। अध्ययन ने LiDAR डेटा को गॉसियन स्प्लैटिंग नामक एक रेंडरिंग तकनीक में निर्देशित किया, जो प्रत्येक बिंदु को एक छोटे पारभासी दीर्घवृत्त में परिवर्तित करता है और पेड़ की सतहों को और अधिक यथार्थवादी रूप से पुनर्निर्माण करने के लिए उन्हें परतों में रखता है। शोधकर्ताओं ने बताया कि नरम रूप से हिलने वाली पत्तियों से अलग कठोर तनों को संभालने के नियमों से धुंधलापन और डगमगाहट कम हो गई जो आमतौर पर आरंभीकरण के दौरान होती है।

आभासी वन में पहले ही कटाई का परीक्षण

एक आभासी जंगल एक आकर्षक त्रि-आयामी छवि पर नहीं रुकता। जब वास्तविक इन्वेंट्री डेटा जैसे कि पेड़ का स्थान, ऊंचाई, मुकुट की चौड़ाई और स्तन की ऊंचाई पर व्यास को इसमें स्थानांतरित किया जाता है, तो परिणाम एक सिमुलेशन वातावरण होता है जिसमें उपयोगकर्ता पतलेपन या स्पष्ट-काटने के प्रभावों का पूर्वावलोकन कर सकते हैं। DigiMedFor प्रोजेक्ट द्वारा विकसित वर्चुअल फ़ॉरेस्ट डिज़ीज़न सपोर्ट सिस्टम (VFDSS), वास्तविक स्थानों के लगभग समान स्थानों पर आभासी पेड़ लगाकर पूरे जंगल की नकल करता है। यह प्रणाली तारीख और समय के साथ बदलती सूरज की रोशनी की मात्रा की गणना करती है और यह ट्रैक करती है कि पेड़ों को बढ़ने पर कितनी रोशनी मिलती है। उपयोगकर्ता डेस्कटॉप स्क्रीन पर पूरे जंगल को देख सकते हैं, या वर्चुअल-रियलिटी (वीआर) हेडसेट लगा सकते हैं, जंगल में चल सकते हैं, एक व्यक्तिगत पेड़ चुन सकते हैं, और उसकी कटाई या रोपण का प्रयास कर सकते हैं। जैसे ही किसी पेड़ को पतला करने के लिए चुना जाता है, शेष पेड़ों की संख्या और घनत्व, भविष्य के विकास के रुझान और काटी गई लकड़ी की मात्रा के आंकड़े तुरंत स्क्रीन पर दिखाई देते हैं। मिसिसिपी में स्टैंड और संयुक्त राज्य अमेरिका में डगलस फ़िर स्टैंड के वास्तविक अनुप्रयोगों में, पेड़ के स्थानों और आयामों और लगभग 40 पेड़ प्रजातियों के त्रि-आयामी नमूनों पर केवल डेटा का उपयोग करके स्थानीय जंगल का एक डिजिटल ट्विन घंटों के भीतर बनाया जा सकता है।

केस्केस और नीता (2026) ने फ़िनलैंड के बहु-स्रोत राष्ट्रीय वन सूची डेटा को रोमानियाई क्षेत्र डेटा से निर्मित मॉडल में जोड़ा। फ़िनलैंड में बढ़ते-स्टॉक वॉल्यूम पूर्वानुमानों की व्याख्यात्मक शक्ति 0.483 से बढ़कर 0.718 हो गई। यह एक ऐसा अध्ययन नहीं था जिसने सीधे तौर पर कार्बन मानचित्र तैयार किया, बल्कि एक परीक्षण था जिसने विभिन्न देशों के डेटा को जोड़कर स्टैंड-स्ट्रक्चर भविष्यवाणियों में सुधार किया। जब किसी मॉडल को राष्ट्रीय सीमाओं के पार स्थानांतरित किया जाता है, तो उसे स्थानीय नमूनों के साथ पुनः अंशांकित किया जाना चाहिए।

संयुक्त राज्य अमेरिका में भी ऐसी ही कोशिशें जारी हैं।

ओरेगॉन स्टेट यूनिवर्सिटी ने इलियट स्टेट फ़ॉरेस्ट के 77.6 वर्ग किलोमीटर क्षेत्र और लगभग 2.8 मिलियन पेड़ों को शामिल करते हुए एक डिजिटल ट्विन बनाया। इनमें से 26,000 पेड़ों को एक गेम इंजन में विस्तार से

प्रस्तुत किया गया था। इस आभासी जंगल के भीतर, उपयोगकर्ता समय और मौसम बदल सकते हैं, इलाके में चल सकते हैं, और उन निशानों का पूर्ववलोकन कर सकते हैं जो चयनात्मक कटाई या साफ़ कटाई पीछे छोड़ देंगे। मिशिगन स्टेट यूनिवर्सिटी और वर्जीनिया टेक के शोधकर्ताओं ने मध्य वर्जीनिया में 7.5 एकड़ के पिनस ताएडा जंगल में 3,555 पेड़ों का सर्वेक्षण किया और कई पतले परिदृश्यों की तुलना की। ब्लॉक और परिदृश्यों में हटाई गई मात्रा में अंतर 7.9 से 18.2 प्रतिशत तक था। एक ब्लॉक में, अनुमानित लॉग कीमतों के तहत अंतर लगभग 70 डॉलर प्रति एकड़ था। चूँकि यह गणना एक ही प्रायोगिक स्थल से की गई है, इसलिए यह स्थापित नहीं किया जा सकता है कि अन्य वनों में भी समान रिटर्न प्राप्त किया जाएगा।

स्थल पर डिस्प्ले और रोबोटों का पूर्वाभ्यास

डिजिटल ट्विन में जमा हुआ डेटा एक स्क्रीन तक ही सीमित नहीं रहता है। यदि फ़िल्ड कर्मचारी स्मार्टफ़ोन, टैबलेट, या मिश्रित-वास्तविकता वाले उपकरणों जैसे Microsoft HoloLens 2 या Apple Vision Pro का उपयोग करते हैं, तो वे वास्तविक पेड़ों पर संवर्धित-वास्तविकता (AR) ग्राफ़िक्स देख सकते हैं। आर्बोरियल फ़ॉरेस्ट, फ़ॉरेस्टस्कैनर और ट्री स्कैनर जैसे एप्लिकेशन स्मार्टफ़ोन में LiDAR और RGB-D सेंसर को SLAM, या एक साथ स्थानीयकरण और मैपिंग नामक पोजिशनिंग तकनीक के साथ जोड़ते हैं, जो एक मशीन को अपनी स्थिति निर्धारित करते समय अपने परिवेश को मैप करने की अनुमति देता है। जैसे ही कार्यकर्ता साइट से गुजरते हैं, वे तुरंत संवर्धित त्रि-आयामी ग्राफ़िक्स के साथ पेड़ के व्यास, ऊंचाई और समन्वय की जांच कर सकते हैं। इन प्रौद्योगिकियों की परिपक्वता प्रोटोटाइप से लेकर बाज़ार में पहले से मौजूद उत्पादों तक होती है। बोरियल वनों में, UAV LiDAR और SLAM से मापी गई छाती की ऊंचाई पर व्यास में त्रुटियाँ अपेक्षाकृत छोटी थीं, जो 2.0 से 4.0 सेंटीमीटर तक थीं। घने भंडार वाले उपोष्णकटिबंधीय शहरी जंगलों में, त्रुटि बढ़कर 5.13 सेंटीमीटर या 22.01 प्रतिशत हो गई।

वानिकी मशीनरी के लिए आभासी प्रशिक्षण मैदान भी बनाए जा रहे हैं। स्वीडन के विन्डेलन क्षेत्र में, शोधकर्ताओं ने लेईका BLK360 स्थलीय LiDAR उपकरण के साथ 30 स्थानों को स्कैन किया और उच्च-सटीक डिजिटल ट्विन को पुनः पेश करने के लिए ड्रोन डेटा जोड़ा। इस आभासी जंगल के अंदर, उन्होंने सिमफॉरेस्ट नामक सिंथेटिक डेटासेट को स्वचालित रूप से उत्पन्न करने के लिए दृष्टिकोण और सौर कोण को यादृच्छिक रूप से बदल दिया। वास्तव में, सुरक्षा सुविधाएँ जो वानिकी रोबोटों या स्वायत्त फ़ारवर्डरों को वास्तविक समय में लोगों, पेड़ों और बाधाओं को पहचानने और रोकने की अनुमति देती हैं, उन्हें वास्तविक जंगल में तैनात करने से पहले इन आभासी डेटा के साथ पहले से परीक्षण किया जा सकता है।

नेचुरल रिसोर्सेज इंस्टीट्यूट फ़िनलैंड (ल्यूक) कार्बन-ट्रेडिंग बाज़ार के उद्देश्य से एक डिजिटल ट्विन विकसित कर रहा है। LiDAR से लैस ड्रोन प्रत्येक पेड़ की ऊंचाई, ऊंचाई पर व्यास और प्रजातियों को रिकॉर्ड करते हैं। डेटा को कई उपग्रह डेटासेट के साथ मिला जाता है, फिर एक गतिशील त्रि-आयामी मॉडल में बदल दिया जाता है। लक्ष्य कार्बन-पृथक्करण विश्लेषण को बेरा या गोल्ड स्टैंडर्ड जैसी सत्यापन प्रणालियों से जोड़ना है। यह परियोजना अभी भी अनुसंधान चरण में है और व्यावसायीकरण का मार्ग तलाश रही है।

सटीकता फिर धुंधली पड़ती है

इन संचित उपलब्धियों के बावजूद, शोध निष्कर्ष अक्सर विरोधाभासी होते हैं। एकाधिक-स्कैन स्थलीय LiDAR वृक्ष-आयतन माप की सटीकता में उत्कृष्टता प्राप्त करता है, लेकिन कई स्थितियों से कैप्चर किए गए डेटा को पंजीकृत करने के लिए काफी काम करने की आवश्यकता होती है। इसके विपरीत, गहन शिक्षण के साथ एकल स्कैन के संयोजन से संग्रह की गति में काफी वृद्धि होती है, लेकिन गायब शाखाओं या पेड़ों के पीछे गिरी हुई मृत लकड़ी के कारण होने वाली त्रुटियों को पूरी तरह से समाप्त नहीं किया जाता है। मल्टीस्पेक्ट्रल LiDAR के बारे में भी यही सच है। व्यक्तिगत घटकों के लिए पहचान सटीकता में उल्लेखनीय सुधार हुआ है, लेकिन उपकरण महंगे हैं और संसाधित होने वाले डेटा की मात्रा काफी बढ़ जाती है। सीमित बजट वाली वन सहकारी समिति के लिए ऐसे उपकरण तुरंत हासिल करना आसान नहीं लगता है।

एक मॉडल जो एक प्रायोगिक वन में उच्च सटीकता प्राप्त करता है, समशीतोष्ण मिश्रित वन या उपोष्णकटिबंधीय वन में ले जाने पर खराब प्रदर्शन कर सकता है। पेड़ की प्रजातियाँ, मुकुट संरचना, सेंसर और डेटा को विभाजित करने के तरीके सभी अलग-अलग हैं। मॉडल को दूसरे जंगल में लागू करने के लिए, इसे उस क्षेत्र के डेटा के साथ पुनः कैलिब्रेट किया जाना चाहिए।

घने अंडरस्टोरी वनस्पति और कसकर जुड़े ऊपरी छतरियों वाले जंगलों में, ड्रोन या उपग्रहों द्वारा उत्सर्जित प्रकाश जमीन तक नहीं पहुंचता है, जिससे पेड़ों के निचले हिस्से और तने की मोटाई को मापने में त्रुटियाँ बढ़ जाती हैं। छत्र के नीचे उड़ान भरने वाले स्वायत्त ड्रोन पोजिशनिंग प्रौद्योगिकियों पर निर्भर करते हैं जो दृश्य और जड़त्वीय जानकारी, जैसे वीआईओ और एसएलएएम को जोड़ते हैं। जब प्रकाश कम होता है और शाखाएं हिलती हैं, तो ड्रोन अपनी स्थिति खो सकता है या पूरी तरह से खो सकता है। सूखे और गर्मी के तनाव की गणना करने वाले विकास मॉडल पहले से मौजूद हैं। जो दुर्लभ है वह एक परिचालन प्रणाली है जो डिजिटल ट्विन के भीतर फ़िल्ड-सेंसर और चरम-जलवायु डेटा को लगातार अपडेट करती है।

मॉडल जितना बेहतर प्रदर्शन करेगा, चाहे वह विज़न ट्रांसफॉर्मर (वीआईटी) हो या त्रि-आयामी कनवल्शनल न्यूरल नेटवर्क, उसके ब्लैक बॉक्स बने रहने की संभावना उतनी ही अधिक होगी जो अपने आंतरिक निर्णयों के आधार की व्याख्या नहीं कर सकता है। वन-नीति निर्णय निर्माताओं के दृष्टिकोण से, यह अपारदर्शिता विश्वास के निर्माण को धीमा कर देती है। ऐसे मॉडलों को आम तौर पर उच्च-प्रदर्शन वाले जीपीयू की आवश्यकता होती है, जिससे उन्हें दूर-दराज के क्षेत्रों में ड्रोन या फ़िल्ड डिवाइस पर सीधे स्थानांतरित करना मुश्किल हो जाता है जहां संचार आसानी से बाधित हो जाता है।

फरवरी 2026 में प्रकाशित एक लेख में, संयुक्त राष्ट्र के खाद्य और कृषि संगठन (एफएओ) ने एक अलग कोण से इसी तरह की चिंताओं को उठाया। यह तर्क दिया गया कि एआई-जनित आंकड़ों को सीधे नीति में उपयोग करने से पहले फ़िल्ड सत्यापन का पालन करना चाहिए, और प्रशिक्षित कर्मियों और मानक प्रक्रियाओं जैसे संस्थानों को प्रौद्योगिकी को अपनाने की तुलना में स्थापित होने में अधिक समय लगता है।

साथ ही इस अंतर को पाटने के प्रयास भी जारी हैं। अध्ययन एसएचएपी और ग्रेड-सीएएम जैसे व्याख्या योग्य कृत्रिम बुद्धिमत्ता (एक्सएआई) तरीकों को पेश कर रहे हैं, जो उस जानकारी की पहचान करने के लिए पीछे की ओर पता लगाते हैं जिस पर एक मॉडल अपना निर्णय आधारित करता है, और सटीकता और व्याख्या दोनों को सुरक्षित करने के लिए मॉडल में प्रजातियों-विशिष्ट फूलों की अवधि और मिट्टी की नमी जैसे

पारिस्थितिक ज्ञान को नियमों के रूप में एम्बेड करता है। ऐसे मॉडल बनाने के लिए भी काम चल रहा है जो प्रूनिंग, क्वांटाइजेशन और ज्ञान आसवन जैसी हल्की तकनीकों के माध्यम से ड्रोन और फील्ड उपकरणों पर चल सकते हैं, और क्षेत्रों और उपकरणों में बिखरे हुए डेटा को एक मानक प्रारूप में व्यवस्थित कर सकते हैं।

स्रोत और संदर्भ

1. Amoah-Nuamah, J., Child, B., Okyere, E. Y., Adams, O., & Danquah, J. A. (2025). Applications of artificial intelligence in forest health surveillance and management. *Discover Forests*, 1, Article 56. <https://doi.org/10.1007/s44415-025-00061-w>
2. AVNation. (February 27, 2026). Oregon State University builds immersive forest digital twin using scalable display technologies. <https://www.avnation.tv/2026/02/27/oregon-state-university-leverages-scalable-display-technologies-to-bring-oregons-forests-to-life-with-immersive-visualization/> (accessed August 2, 2026)
3. DigiMedFor Project Consortium. (2025). DigiMedFor: digital tools and technology systems for the sustainable management of Mediterranean forest resources (Horizon Europe Project No. 101081928). <https://digimedfor.eu> (accessed August 2, 2026)
4. Forkuo, G. O., & Borz, S. A. (2026). Deep learning-based computer vision in forest monitoring and management: a systematic review. *Biodiversity and Conservation*, 35(208), 1-37. <https://doi.org/10.1007/s10531-026-03412-x>
5. Forkuo, G. O., Picchio, R., Proto, A. R., & Borz, S. A. (2026). Applications of artificial intelligence in forest operations engineering research: A systematic review. *Current Forestry Reports*, 12, Article 14. <https://doi.org/10.1007/s40725-026-00275-x>
6. Jung, M., Choi, J., Carpenter, J., Fei, S., & Jung, J. (2025). Individual tree biomass estimation using single-scan terrestrial laser scanner with efficient projection-based deep learning. *Journal of Forestry*. <https://doi.org/10.1007/s44392-025-00065-6>
7. Keskes, M. I., & Niță, M. D. (2026). Digital twins in forest management using scalable deep learning pipeline. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 19, 8519-8547. <https://doi.org/10.1109/JSTARS.2026.3666924>
8. Lapland University of Applied Sciences, FrostBit Software Lab. (August 1, 2024). Developing a simulator platform to advance autonomous systems in forestry usage. <https://lapinamk.fi/en/blogArticle/developing-a-simulator-platform-to-advance-autonomous-systems-in-forestry-usage/> (accessed August 2, 2026)
9. Liang, X., Yao, H., Qi, H., & Wang, X. (2024). Forest in situ observations through a fully automated under-canopy unmanned aerial vehicle. *Geo-Spatial Information Science*, 27(4), 983-999. <https://doi.org/10.1080/10095020.2024.2322765>
10. Natural Resources Institute Finland (Luke). (2026). Digital Forest Carbon Twins. <https://www.luke.fi/en/carbontwins> (accessed August 2, 2026)
11. Platt, E., Carter, D. R., Reddy, A., Albaugh, T. J., Cook, R. L., Campoe, O., Rubilar, R., Barua, G., & Sumnall, M. J. (2026). Precision forestry: using machine learning and LiDAR to inform thinning in Pinus taeda plantations, a case study. *Journal of Forestry*. <https://doi.org/10.1007/s44392-026-00089-6>
12. Saha, R., Bagchie, P., Lalremsang, P., & Rai, K. C. (2025). Digital innovation in forest science: applications of artificial intelligence, remote sensing and smart monitoring systems for ecosystem conservation. *The Bioscan*, 20(3), 907-911. [https://doi.org/10.63001/tbs.2025.v20.i03.S.I\(3\).pp907-911](https://doi.org/10.63001/tbs.2025.v20.i03.S.I(3).pp907-911)
13. Takhtkeshha, N., Bocaux, L., Ruoppa, L., Remondino, F., Mandlbürger, G., Kukko, A., & Hyyppä, J. (2026). 3D forest semantic segmentation using multispectral LiDAR and 3D deep learning. *PFG - Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 94, 377-397. <https://doi.org/10.1007/s41064-025-00369-4>
14. Toaza, J. M. M., Picchi, G., Nati, C., & Borz, S. A. (2025). Accuracy and time efficiency of a new app developed to source and map single tree data: A comparison to state-of-art LiDAR data collectors in terms of basal area

- estimates. *Ecological Informatics*, 91, Article 103417. <https://doi.org/10.1016/j.ecoinf.2025.103417>
15. Valbuena, P., et al. (February 6, 2026). Artificial intelligence in forest monitoring: uses, applications, adoption and precautions. *FAO Forest Monitoring Blog*. <https://www.fao.org/forest-monitoring/blog/detail/blog/2026/02/06/artificial-intelligence-in-forest-monitoring--uses--applications--adoption--and-precautions/en> (accessed August 2, 2026)
16. Zhou, Z., Chen, Y., Deng, Y., Zheng, X., Liang, H., Zhong, X., & Li, Z. (2026). LiDAR-guided semantic 3D Gaussian splatting for forest digital twins. *Remote Sensing*, 18(11), 1696. <https://doi.org/10.3390/rs18111696>
17. Korea Forest Service. (n.d.). National Forest Inventory. https://forest.go.kr/kfswweb/kfi/kfs/cms/cmsView.do?mn=NKFS_04_05_08&cmsId=FC_000344 (accessed August 2, 2026)
18. 大萱直花. (2025). 真の林業DXとは. *森林応用研究*, 34(1), 21-23. https://doi.org/10.20660/applfor.34.1_21

1.2

बहु-माध्यम दूरसंवेदी डेटा संलयन प्रौद्योगिकी

एक गर्मियों में, जब मानसून का मोर्चा तीन दिनों के लिए कोरियाई प्रायद्वीप को कवर कर चुका था, राष्ट्रीय वन उपग्रह सूचना उपयोग केंद्र के मॉनिटर के सामने बैठे एक शोधकर्ता ने एक नई डाउनलोड की गई उपग्रह छवि खोली और आह भरी। आधी स्क्रीन धुंधली सफेद थी, मानो उस पर दूध डाल दिया गया हो। शोधकर्ता गैंगवॉन प्रांत के पूर्वी तट पर पाइन विल्ट रोग नियंत्रण क्षेत्र का निरीक्षण करने वाले थे, लेकिन बादलों ने पूरे पहाड़ को ढक लिया, जिससे एक भी पेड़ को पहचानना असंभव हो गया। नियंत्रण के लिए लक्षित पेड़ों के स्थानों को चिह्नित करने वाले लाल बिंदु स्क्रीन के नीचे बिखरे हुए थे, लेकिन उनके ऊपर बादलों ने उनकी हाल की स्थिति की जांच करना असंभव बना दिया था। पास में बैठे एक सहकर्मी ने एक पेपर कप रखा और आगे बढ़ते हुए कहा, "आज भी आसमान नहीं खुल रहा है।" ऑप्टिकल उपग्रह कैमरे के समान सिद्धांत पर काम करते हैं। क्योंकि वे पृथ्वी की सतह से परावर्तित और लेंस में प्रवेश करने वाली सूर्य की रोशनी की मात्रा को रिकॉर्ड करते हैं, बादल उसी स्थिति का निर्माण करते हैं जैसे एक हथेली कैमरे के सामने को कवर करती है। अगले उपग्रह को उसी आकाश को पार करने से पहले कई और दिन बीतने होंगे। इस बीच, रोगग्रस्त पेड़ चुपचाप फैल जाते हैं, और सूखी गिरी हुई पत्तियों के नीचे अंगारे उग आते हैं।

ऐसे क्षणों में मल्टीमॉडल रिमोट-सेंसिंग डेटा फ़्यूज़न आवश्यक हो जाता है। जब किसी जंगल को केवल एक आंख से आकाश से देखा जाता है, तो कुछ हिस्से अनिवार्य रूप से अदृश्य रह जाएंगे। उपग्रह अक्सर बड़े क्षेत्रों की तस्वीरें लेते हैं लेकिन बादलों और कोहरे के कारण अवरुद्ध हो जाते हैं, और उनकी नज़र पेड़ों की चोटी के नीचे तक नहीं पहुँचती है। मानव रहित हवाई वाहन (यूएवी) और स्थलीय लेजर स्कैनर सेंटीमीटर रिज़ॉल्यूशन पर व्यक्तिगत पत्तियों और शाखाओं को पकड़ सकते हैं, लेकिन बैटरी और श्रम लागत उन्हें पूरे देश का सर्वेक्षण करने से रोकती है। एक ड्रोन बैटरी 40 मिनट से अधिक नहीं चलती है। इसलिए शोधकर्ताओं ने अपना दृष्टिकोण बदल दिया। उन्होंने एक ही दृश्य में विभिन्न प्रकार की आंखों वाले उपकरणों को शामिल करना शुरू कर दिया। परिणाम एक बहुपरत हवाई, वायुमंडलीय और जमीनी अवलोकन नेटवर्क है जो अंतरिक्ष में उपग्रहों, हवा में ड्रोन और जमीन पर मौजूद सेंसरों को ऐसे जोड़ता है जैसे कि वे एक शरीर हों।

आकाश और ज़मीन के बीच दृष्टि की तीन परतें

तीनों परतों के अलग-अलग कार्य हैं। उपग्रह पूरे कोरियाई प्रायद्वीप में हर तीन या पाँच दिन में उड़ान भरते हैं। ड्रोन एक स्टैंड का चयन करते हैं और पेड़-पौधे उसका निरीक्षण करते हैं। जमीन पर स्थापित सेंसर एक ही स्थान पर रहते हैं और महीनों या वर्षों में, दूसरे-दर-सेकंड परिवर्तन जमा करते रहते हैं।

मैक्रोस्केल के लिए जिम्मेदार उपग्रह परत में यूरोपीय अंतरिक्ष एजेंसी की सेंटिनल श्रृंखला, संयुक्त राज्य अमेरिका की लैंडसैट श्रृंखला और चीन की जीएफ-2 शामिल हैं। ICESat-2 और GEDI, जो सीधे चंदवा की ऊंचाई मापते हैं, भी इसी परत से संबंधित हैं। जीएफ-2 एक उच्च-रिज़ॉल्यूशन उपग्रह है जो 0.8 मीटर

जितनी छोटी कोशिकाओं में सतह की तस्वीरें लेता है। लैंडसैट 8 और लैंडसैट 9 थर्मल-इन्फ्रारेड बैंड ले जाते हैं जो जंगल की आग के तुरंत बाद बची हुई गर्मी को पकड़ सकते हैं। GEDI अंतर्राष्ट्रीय अंतरिक्ष स्टेशन पर लगा एक उपकरण है जो दुनिया भर के बिंदुओं पर जंगल की ऊंचाई का नमूना लेता है। 2025 में, शोधकर्ताओं डी कोंटो, आर्मस्टन और दुबैया ने गहन शिक्षण के माध्यम से इनमें से 130 मिलियन से अधिक बिंदु मापों को सिंथेटिक एपर्चर रडार (एसएआर) डेटा के साथ जोड़ा। परिणामी वैश्विक वन-संरचना मानचित्र, 25-मीटर कोशिकाओं के साथ, 0.82 की व्याख्यात्मक शक्ति तक पहुंच गया। परिणाम 400,000 से कम पैरामीटर वाले अपेक्षाकृत हल्के मॉडल के साथ प्राप्त किया गया था।

इस परत में नए सदस्य शामिल हुए हैं।

नेशनल एरोनॉटिक्स एंड स्पेस एडमिनिस्ट्रेशन (NASA) और भारतीय अंतरिक्ष अनुसंधान संगठन (ISRO) द्वारा संयुक्त रूप से विकसित NISAR उपग्रह को 30 जुलाई, 2025 को लॉन्च किया गया था। पृथ्वी से लगभग 747 किलोमीटर ऊपर परिक्रमा करते हुए, यह मिट्टी की नमी, वन बायोमास और जमीन की सूक्ष्म गतिविधियों को मापने के लिए एल-बैंड और एस-बैंड रडार का उपयोग करता है। इस उपग्रह द्वारा एकत्र किया गया एल-बैंड डेटा 20 जुलाई, 2026 को मुफ्त में डाउनलोड करने योग्य हो गया। जो डेटा एक समय केवल राष्ट्रीय एजेंसियों या बड़े शोध संस्थानों द्वारा ही संभाला जा सकता था, उसे अब कोरिया में एक स्नातक छात्र द्वारा मुफ्त में डाउनलोड किया जा सकता है और थीसिस में उपयोग किया जा सकता है। यूरोपीय अंतरिक्ष एजेंसी का बायोमास उपग्रह पहला पी-बैंड उपकरण लेकर एक कदम आगे चला गया, जिसकी तरंग दैर्ध्य पारंपरिक रडार से अधिक लंबी है। तरंग दैर्ध्य जितनी लंबी होगी, यह पत्तियों और शाखाओं में उतनी ही गहराई तक प्रवेश करेगी, जिससे यह तनों की लकड़ी की मात्रा का भी अनुमान लगा सकेगी। उपग्रह को अप्रैल 2025 में लॉन्च किया गया था। इसने अपना पहला खुला डेटा उसी वर्ष 19 दिसंबर को जारी किया था। यूरोप के अवलोकन नेटवर्क में, सेंटिनल-1डी ने नवंबर 2025 में कक्षा में प्रवेश किया। मौजूदा सेंटिनल-1सी के साथ मिलकर, इसने हर छह दिनों में उसी स्थान पर फिर से जाने की पूर्व प्रणाली को बहाल किया।

कोरिया ने इस परत में एक और उपग्रह स्थापित किया। कोरिया एयरोस्पेस प्रशासन, ग्रामीण विकास प्रशासन और कोरिया वन सेवा द्वारा संयुक्त रूप से विकसित कृषि और वानिकी उपग्रह, कॉम्पैक्ट एडवांस्ड सैटेलाइट 4 है। एक स्पेसएक्स फाल्कन 9 रॉकेट इसे अंतरिक्ष में ले गया। प्रक्षेपण 7 जुलाई, 2026 को हुआ। उपग्रह हर तीन दिन में लगभग पांच-मीटर रिज़ॉल्यूशन पर पूरे कोरियाई प्रायद्वीप की छवि लेगा और इसका उपयोग व्यापक क्षेत्र में जंगल की आग और भूस्खलन से क्षतिग्रस्त क्षेत्रों की शीघ्र पहचान करने के लिए किए जाने की उम्मीद है। देखने लायक एक और उपग्रह सेजोंग 3 है, जो मार्च 2026 में कोरियाई निजी कंपनी हैनकॉम इनस्पेस द्वारा लॉन्च किया गया एक हाइपरस्पेक्ट्रल उपग्रह है। जबकि एक साधारण कैमरा प्रकाश को केवल तीन रंगों, लाल, हरा और नीला में विभाजित करता है, यह 6-यूनिट (6U) माइक्रोसैटेलाइट, एक सिरे से दूसरे सिरे तक रखे गए दो शूबॉक्स के आकार का, इसे 442 बैंड में रिकॉर्ड करता है। इसका वजन 11 किलोग्राम से भी कम है। इसलिए इसमें न केवल पत्तियों के रंग को बल्कि उन्हें बनाने वाले पदार्थों की परावर्तन विशेषताओं को भी अलग करने की क्षमता है।

मध्यवर्ती पैमाने पर, ड्रोन परत स्टैंड और व्यक्तिगत पेड़ों की त्रि-आयामी संरचना और रंग हस्ताक्षर एकत्र करने के लिए LiDAR, हाइपरस्पेक्ट्रल और मल्टीस्पेक्ट्रल सेंसर और अल्ट्रा-हाई-रिज़ॉल्यूशन कैमरों का उपयोग करती है। LiDAR एक उपकरण है जो प्रकाश उत्सर्जित करता है और उसके लौटने में लगने वाले समय को मापता है, जिससे किसी वस्तु की दूरी निर्धारित होती है। ड्रोन-माउंटेड LiDAR पेड़ों के ऊपर नीचे उड़ता है और प्रत्येक मुकुट की आकृति को पकड़ लेता है। सूक्ष्म स्तर की परत लगभग जमीन पर स्थित होती है। इसमें टेरैस्ट्रियल लेजर स्कैनर (टीएलएस), बैकपैक मोबाइल मैपिंग सिस्टम (बैकपैक एमएमएस), आईओटी माइक्रोक्लाइमेट सेंसर शामिल हैं जो मिट्टी की नमी और हवा के तापमान को मापते हैं, और फेनोकैम टावर जो मौसमी बदलाव की तस्वीरें लेते हैं। एक फेनोकैम हर दिन एक ही कोण से एक ही पेड़ की तस्वीरें लेता है, तारीख के अनुसार रिकॉर्डिंग करता है कि कब पत्तियां निकलती हैं और कब लाल हो जाती हैं। 15 सेंटीमीटर जमीन के अंदर दबे हुए IoT सेंसर मिट्टी के सूखने की दर को वास्तविक समय में एक सर्वर तक पहुंचाते हैं। ये उपकरण लगातार पेड़ के व्यास, स्तन की ऊंचाई, तने की वक्रता, अंडरस्टोरी वनस्पति और मिट्टी की नमी को मापते और रिकॉर्ड करते हैं। क्योंकि स्तन की ऊंचाई पर व्यास पहला इनपुट है जिसका उपयोग किसी व्यक्तिगत पेड़ की लकड़ी की मात्रा और कार्बन स्टॉक की गणना करने के लिए किया जाता है, यहां तक कि कुछ मिलीमीटर की त्रुटि भी एक आकार तक बढ़ जाती है जिसे पूरे जंगल में गुणा करने पर नजरअंदाज नहीं किया जा सकता है।

जनवरी 2026 में राष्ट्रीय वन विज्ञान संस्थान द्वारा अनावरण किया गया स्वायत्त LiDAR-सुसज्जित ड्रोन जमीन और ड्रोन परतों तक फैला हुआ है। जिस कार्य को मापने के टेप के साथ पैदल चलकर एक हेक्टेयर का सर्वेक्षण करने में एक व्यक्ति को 22 घंटे लगते थे, उसे इस ड्रोन द्वारा 2.3 घंटे में पूरा किया गया। प्रत्यक्ष क्षेत्र माप की तुलना में इसकी सटीकता 96 प्रतिशत तक पहुंच गई, और इसने स्तन की ऊंचाई पर भी व्यास को पकड़ लिया, जिसे मापना मानव आंखों के लिए मुश्किल था क्योंकि वे पत्तियों से छिपे हुए थे।

स्थान और समय को संरेखित करना

समस्या यह है कि इस तरह से एकत्र किया गया डेटा विभिन्न शासकों के साथ लिए गए माप की तरह है। एक उपग्रह-छवि सेल 10 से 30 मीटर तक की दूरी तय करता है। ड्रोन छवियां कई सेंटीमीटर के रिज़ॉल्यूशन तक पहुंचती हैं, और ग्राउंड स्कैनर कुछ मिलीमीटर के रिज़ॉल्यूशन तक पहुंचते हैं। यदि एक पिक्सेल गलत संरेखित है, तो पूरा पेड़ मानचित्र पर पड़ोसी पेड़ की छाया में गिर सकता है। इन डेटा को ओवरले करने के लिए पहले ग्राउंड-कंट्रोल-पॉइंट कार्य की आवश्यकता होती है: परावर्तक पैनल और क्रॉस-आकार के मार्कर जंगल की सड़कों पर रखे जाते हैं, और उनके निर्देशांक उपग्रह नेविगेशन के साथ मापा जाता है। इसके बाद तर्कसंगत फ्रंक्शन मॉडल और फ्रीचर-पॉइंट-आधारित ज्यामितीय सुधार होता है। क्योंकि प्रत्येक सेंसर में एक अलग रिज़ॉल्यूशन और समन्वय प्रणाली होती है, अध्ययन स्थल और उपकरण के अनुरूप पंजीकरण-त्रुटि परीक्षणों का पालन किया जाना चाहिए।

समय को संरेखित करना आसान नहीं है।

दो-उपग्रह प्रणाली में, सेंटिनल-2 लगभग हर पांच दिन में उसी क्षेत्र में दोबारा जाता है; एक लैंडसैट उपग्रह लगभग हर 16 दिन में ऐसा करता है; और ड्रोन और जमीनी सर्वेक्षण शोधकर्ताओं के कार्यक्रम के अनुसार रुक-रुक कर होते रहते हैं। इस अंतराल में, पेड़ पत्तियाँ छोड़ते हैं और उनमें जमा पानी की मात्रा बदल जाती

है। यदि बेमेल तिथियों के डेटा को वैसे ही ओवरलैप किया जाता है जैसे वे हैं, तो एक ऑप्टिकल भ्रम एक ही पेड़ को अलग-अलग रंगों में प्रदर्शित करता है। यही कारण है कि बादलों और छायाओं को फ़िल्टर करने के लिए सेन2कोर और एफमास्क जैसे एल्गोरिदम का उपयोग किया जाता है, और एक ही मौसम से कई छवियों का चयन और संयोजन क्यों किया जाता है। जब पिक्सेल स्थान और अवलोकन समय गलत तरीके से संरेखित होते हैं, तो मॉडल के इनपुट सिग्नल मिश्रित हो जाते हैं, इसलिए प्रत्येक अध्ययन को पंजीकरण त्रुटि और अस्थायी अंतर को अलग से रिपोर्ट करना होगा।

तंजानिया के दक्षिणी ऊंचे इलाकों में छोटे किसानों द्वारा लगाए गए जंगलों के एक हालिया अध्ययन ने इस समस्या को हल करने के लिए एक सुराग पेश किया। शोधकर्ता मौया और जोनास ने बताया कि क्लाउड-प्रवण क्षेत्र में यादृच्छिक वन और सपोर्ट वेक्टर मशीन (एसवीएम) मॉडल के साथ सेंटिनल -1 रडार और सेंटिनल -2 ऑप्टिकल डेटा के संयोजन से अकेले ऑप्टिकल डेटा का उपयोग करने की तुलना में छोटे धारकों द्वारा लगाए गए प्रजातियों को वर्गीकृत करने की सटीकता में सुधार हुआ है। मानसून-सीजन नियंत्रण कक्ष में आने वाली सफेद स्क्रीन की समस्या का एक समाधान इस प्रकार बनाया जा रहा है।

प्रकाश, रेडियो तरंगों और लेजर को एक साथ लाना

तीन सेंसर जंगल के विभिन्न गुणों का निरीक्षण करते हैं। ऑप्टिकल सेंसर दृश्य, निकट-अवरक्त और शॉर्टवेव-अवरक्त बैंड में पत्ती क्लोरोफिल, पानी की स्थिति और वनस्पति सूचकांकों को पढ़ते हैं। हालाँकि, घने पर्णसमूह वाले क्षेत्रों में, परावर्तन एक संतृप्ति बिंदु तक पहुँच जाता है और अब अतिरिक्त अंतरों को अलग नहीं करता है। सिंथेटिक एपर्चर रडार सेंटिनल-1 के सी-बैंड या एएलओएस पालसर के एल-बैंड जैसे माइक्रोवेव उत्सर्जित करता है, और बादलों की परवाह किए बिना मोटी शाखाओं और तनों से प्रतिबिंबित संकेतों को पकड़ता है, जिससे जंगल के आंतरिक ढाँचे का पता चलता है। यहां तक कि जब मानसून के दौरान सैटेलाइट तस्वीरें सफेद हो गईं, तब भी माइक्रोवेव सीधे बादलों से होकर गुजरे। LiDAR लेजर पल्स उत्सर्जित करता है और सीधे सेंटीमीटर रिज़ॉल्यूशन पर पेड़ की ऊंचाई, मुकुट की मात्रा, ऊर्ध्वाधर परतों और जमीन की ऊंचाई को मापता है। तीनों आँखें एक साथ खोलने से प्रत्येक को दूसरे के अंध स्थानों को भरने की अनुमति मिलती है।

इन तीन प्रकार के डेटा को एआई मॉडल में फीड करने की विधियां व्यापक श्रेणियों में आती हैं। प्रारंभिक संलयन, जो इनपुट चरण में ऑप्टिकल, रडार और LiDAR चैनलों को जोड़ता है और उन्हें एक एकल तंत्रिका नेटवर्क में फीड करता है, में एक संक्षिप्त संरचना होती है, लेकिन यदि इनपुट आयाम नमूना आकार के सापेक्ष अत्यधिक हो जाता है तो ओवरफिटिंग का जोखिम बढ़ जाता है। लेट फ़्यूज़न प्रत्येक सेंसर के लिए एक अलग तंत्रिका नेटवर्क को प्रशिक्षित करता है और अंतिम निर्णय चरण में वोटिंग या वेटेज औसत द्वारा उनके आउटपुट को जोड़ता है। यह सेंसर-विशिष्ट विशेषताओं को संरक्षित करता है लेकिन सेंसर के बीच सूक्ष्म इंटरैक्शन को मिस कर सकता है। हाइब्रिड फ़्यूज़न एक मध्यवर्ती चरण में क्रॉस-अटेंशन संरचना के साथ सुविधाओं को मिश्रित करता है। इसके लिए अधिक गणना की आवश्यकता होती है लेकिन यह प्रत्येक सेंसर से जानकारी के बीच संबंधों को अधिक गहराई से जान सकता है।

कई क्षेत्रीय अध्ययन इन विधियों के बीच व्यावहारिक अंतर दिखाते हैं। चीन के सान्हा और हुआंगफेंगकियाओ में उपोष्णकटिबंधीय मिश्रित जंगलों का एमटीएससीएफनेट अध्ययन, तीन एनकोडर

और एक क्रॉस-फ़्यूज़न मॉड्यूल के माध्यम से ड्रोन LiDAR, अल्ट्रा-हाई-रिज़ॉल्यूशन आरजीबी इमेजरी और जीएफ-2 उपग्रह इमेजरी से जुड़ा हुआ है। इसने अकेले ऑप्टिकल या LiDAR डेटा के उपयोग की तुलना में वृक्ष-प्रजाति वर्गीकरण सटीकता में उल्लेखनीय सुधार किया है। इस अध्ययन में, RIEGL मिनीVUX-1 UAV LiDAR उपकरण ने 87.14 अंक प्रति वर्ग मीटर दर्ज किया। एक DJI M300 RTK ड्रोन ने 6.23 सेंटीमीटर के पिक्सेल आकार के साथ RGB इमेजरी एकत्र की। अलग से, जीएफ-2 ऑप्टिकल उपग्रह डेटा को जीएफ-3 रडार उपग्रह डेटा के साथ कवर करने वाला एक सार्वजनिक डेटासेट हाल ही में चीन में बनाया गया था और इसका उपयोग अनुसंधान में किया जा रहा है जो उन क्षेत्रों को बारीक रूप से विभाजित करता है जहां जंगल, झाड़ी और घास के मैदान के बीच की सीमाएं अस्पष्ट हैं। हाइपरस्पेक्ट्रल और LiDAR डेटा को मिलाकर एक अन्य अध्ययन में, अकेले ऑप्टिकल डेटा के साथ समग्र सटीकता केवल 80.39 प्रतिशत थी। जब दोनों डेटासेट को क्रॉस-अटेंशन द्वारा जोड़ा गया, तो सटीकता 9.21 प्रतिशत अंक बढ़कर 89.60 प्रतिशत हो गई। वैश्विक वृक्ष-ऊंचाई मानचित्र तैयार करने वाले एक अध्ययन में, सबसे मजबूत योगदान प्रत्यक्ष LiDAR अवलोकनों से आया, इसके बाद इलाके के चर और फिर अप्रत्यक्ष ऑप्टिकल और रडार सूचकांकों का स्थान आया।

मलेशिया के बोर्नियो के डेरामाकोट और तांगकुलप उष्णकटिबंधीय वर्षावनों में, कोटारो कोमात्सु सहित एक शोध दल ने ड्रोन आरजीबी छवियों में स्वचालित रूप से डिप्टेरोकार्प पेड़ों की पहचान की, फिर परिणामों को उपग्रह डेटा और एक यादृच्छिक वन मॉडल से जोड़ा। अकेले ड्रोन इमेजरी से डिप्टेरोकार्प पेड़ों की पहचान करने की सटीकता 0.71 निर्माता की सटीकता और 0.67 उपयोगकर्ता की सटीकता थी। फ़ील्ड नमूनों के बिना अकेले उपग्रह डेटा का उपयोग करने वाले मॉडल में 0.43 की व्याख्यात्मक शक्ति और 70.60 मेगाग्राम प्रति हेक्टेयर की त्रुटि थी। ड्रोन से निकाले गए वेरिबल्स को जोड़ने से व्याख्यात्मक शक्ति 0.51 तक बढ़ गई और त्रुटि 60.53 मेगाग्राम तक कम हो गई। इसका मतलब है कि क्षेत्र में घूमने और नमूनों को एक-एक करके गिनने की लागत को काफी कम किया जा सकता है।

रूस के सखालिन में प्रबंधित वनों में एक अन्य अध्ययन में स्टैंड-सबकम्पार्टमेंट डेटा, सेंटिनल-2 टाइम सीरीज़ और इलाके के डेटा को यादृच्छिक वन, एक्सजीबूस्ट और टैबनेट में अलग-अलग फीड करके तीन मॉडलों की तुलना की गई। XGBoost ने पेड़ की ऊंचाई, बेसल क्षेत्र, लकड़ी स्टॉक और कार्बन स्टॉक के लिए अन्य दो मॉडलों की तुलना में छोटी त्रुटियां उत्पन्न कीं, और 0.68 की एकीकृत व्याख्यात्मक शक्ति दर्ज की।

बोर्नियो में ड्रोन सर्वेक्षण और गैंगवॉन प्रांत में स्वायत्त-ड्रोन सर्वेक्षण एक ही दिशा में इशारा करते हैं। लोगों द्वारा छुरियों से जंगल में अपना रास्ता काटने और एक-एक करके पेड़ों को गिनने के बजाय, संतुलन मशीनों की ओर स्थानांतरित हो रहा है जो उन्हें आकाश और जमीन के बीच कहीं गिन रहे हैं। उस गिनती पर कितना भरोसा किया जा सकता है यह अगला सवाल है।

परस्पर विरोधी परिणाम और बचे हुए कार्य

जैसे-जैसे प्रौद्योगिकी तेजी से बढ़ रही है, अध्ययन अलग-अलग उत्तर देते हैं। चीड़ जैसी एकल प्रजाति से बने जंगल में, LiDAR द्वारा मापी गई त्रि-आयामी संरचना, जिसमें ताज की चौड़ाई, ऊंचाई और शाखा व्यवस्था शामिल है, प्रजातियों और बायोमास को अलग करने में एक प्रमुख भूमिका निभाती है। अनुसंधान उन दृष्टिकोणों की भी जांच कर रहा है जो ऑप्टिकल सूचकांकों और त्रि-आयामी संरचना को जोड़कर क्षति के प्रारंभिक चरण में पेड़ों का पता लगाते हैं, इससे पहले कि पत्तियों का रंग स्पष्ट रूप से बदल जाए। इसके विपरीत, उष्णकटिबंधीय या उपोष्णकटिबंधीय मिश्रित जंगलों में जहां कई प्रजातियां और झाड़ियाँ आपस में जुड़ी हुई हैं, अकेले LiDAR अपर्याप्त है; ऑप्टिकल और हाइपरस्पेक्ट्रल सेंसर द्वारा कैप्चर किए गए पत्तों और पानी के संकेतों पर भी विचार किया जाना चाहिए। कौन सी संलयन विधि सबसे अच्छा प्रदर्शन करती है यह सेंसर पंजीकरण, नमूना आकार और जंगल के आकार पर निर्भर करता है।

ऐसी समस्याएँ जो क्षेत्र में सीधे स्थानांतरण को कठिन बनाती हैं, बनी रहती हैं। यहां तक कि एक मॉडल जो एक क्षेत्र में उच्च सटीकता प्राप्त करता है, उसे विभिन्न प्रजातियों और मौसमों वाले जंगलों में पुनः कैलिब्रेट किया जाना चाहिए। घने बंद जंगल में, उपग्रहों या ड्रोन से लेजर और ऑप्टिकल सिग्नल निचली परतों या जमीन तक नहीं पहुंचते हैं, जिससे तने के व्यास और अंडरस्टोरी वनस्पति के अनुमान में त्रुटियां जमा हो जाती हैं। यदि उपग्रह-नेविगेशन सिग्नल खो जाते हैं तो जंगल के नीचे उड़ान भरने वाले ड्रोन को भी अपनी स्थिति की पुनर्गणना करनी होगी। जब प्रकाश कम होता है और शाखाएं हवा में हिलती हैं, तो दृश्य-जड़त्वीय ओडोमेट्री (वीआईओ) और एक साथ स्थानीयकरण और मानचित्रण (एसएलएएम) में स्थितीय त्रुटियां बढ़ जाती हैं। त्रि-आयामी तंत्रिका नेटवर्क और विज़न ट्रांसफार्मर को इनपुट आकार और डिवाइस के आधार पर पर्याप्त मेमोरी और पावर की आवश्यकता होती है, इसलिए उन्हें फ़ील्ड उपकरण में रखने के लिए मॉडल लाइटवेइटिंग और डिवाइस-विशिष्ट गति परीक्षणों की आवश्यकता होती है।

इस बाधा को कम करने के प्रयास जारी हैं। अनुसंधान ज्ञान आसवन, मॉडल परिमाणीकरण और समर्पित अर्धचालक त्वरण के माध्यम से त्रि-मॉडल मॉडल को कम कर रहा है ताकि वे ड्रोन और फ़ील्ड उपकरणों पर चल सकें। ग्रेड-सीएएम और एसएचएपी जैसी व्याख्या योग्य-एआई विधियां उस आधार को प्रदर्शित करती हैं जिस पर तंत्रिका नेटवर्क ने अपना निर्णय लिया। एक अन्य दिशा पेड़ों के मौसमी बदलावों और मिट्टी की नमी के भौतिक मॉडलों को तंत्रिका नेटवर्क में बाधाओं के रूप में रखती है, जिससे पारिस्थितिक रूप से असंभव उत्तर कम हो जाते हैं। जैसे-जैसे कई क्षेत्रों में फैले सार्वजनिक डेटासेट और ट्रीसैटएआई, प्योरफॉरेस्ट और फॉरेस्टसिमेंटिक-एमएस जैसे सेंसर का विस्तार जारी रहेगा, कोरियाई प्रायद्वीप पर जंगलों के लिए उपयुक्त अलग-अलग परिष्कृत मॉडल की नींव मजबूत होगी।

स्रोत और संदर्भ

1. de Conto, T., Armston, J., & Dubayah, R. (2025). Scalable deep fusion of spaceborne lidar and synthetic aperture radar for global forest structural complexity mapping. arXiv:2510.06299. <https://arxiv.org/abs/2510.06299> (accessed August 2, 2026)
2. European Space Agency. (2025a, November 4). Copernicus Sentinel-1D launch highlights. https://www.esa.int/ESA_Multimedia/Videos/2025/11/Copernicus_Sentinel-1D_launch_highlights (accessed August 2, 2026)

August 2, 2026)

3. European Space Agency. (2025b, December 19). Biomass' first open data products now available. Earth Online. <https://earth.esa.int/eogateway/news/biomass-first-open-data-products-now-available> (accessed August 2, 2026)
4. Forkuo, G. O., & Borz, S. A. (2026). Deep learning-based computer vision in forest monitoring and management: a systematic review. *Biodiversity and Conservation*, 35(208), 1-37. <https://doi.org/10.1007/s10531-026-03412-x>
5. Jung, M., Choi, J., Carpenter, J., Fei, S., & Jung, J. (2025). Individual tree biomass estimation using single-scan terrestrial laser scanner with efficient projection-based deep learning. *Journal of Forestry*. <https://doi.org/10.1007/s44392-025-00065-6>
6. Komatsu, K., Takeshige, R., Onishi, M., Fujiki, S., Imai, N., Miyamoto, K., Aiba, S., Kitayama, K., Tsen, S. T. L., Nilus, R., Dawat, J., Pereira, J., Onoda, Y., & Aoyagi, R. (2026). Quantifying carbon stock and tree community composition in tropical forests through combining satellite and UAV analyses. *Scientific Reports*, 16. <https://doi.org/10.1038/s41598-025-34938-9>
7. Mauya, E. W., & Jonas, J. (2026). Integrating Sentinel-1 SAR and Sentinel-2 multispectral data for tree species classification and mapping in smallholder planted forests of Tanzania. *Discover Forests*. <https://doi.org/10.1007/s44415-026-00085-w>
8. NASA Earthdata. (July 20, 2026). NISAR L-band data released, expanding record of surface changes. <https://www.earthdata.nasa.gov/news/nisar-l-band-data-released-expanding-record-surface-changes> (accessed August 2, 2026)
9. Takhtkeshha, N., Bocaux, L., Ruoppa, L., Remondino, F., Mandlbürger, G., Kukko, A., & Hyypä, J. (2026). 3D forest semantic segmentation using multispectral LiDAR and 3D deep learning. *PFG - Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 94, 377-397. <https://doi.org/10.1007/s41064-025-00369-4>
10. Tasuev, U., Tregubova, P., Illarionova, S., Shadrin, D., Bernshteyn, A., & Burnaev, E. (2026). Machine learning-based geospatial assessment of forest structure characteristics and sequestration potential for informed carbon stocks inventories. *Scientific Reports*, 16, 20872. <https://doi.org/10.1038/s41598-026-50929-w>
11. Wang, L., Zhang, H., Fu, R., Lei, K., Liu, Y., Yang, T., Zhang, J., & Ge, X. (2026). MTSCFNet: a novel framework for improving tree species classification in a subtropical forest using RGB, LiDAR-derived, and GF-2 data. *Journal of Forestry Research*, 37(1), Article 22. <https://doi.org/10.1007/s11676-025-01964-2>
12. Wang, M., Zhang, Q., Liu, X., Zhang, J., Yu, F., Zhang, X., & Zhao, R. (2026). Research progress on multimodal data fusion in forest resource monitoring. *Frontiers in Plant Science*, 16, 1710618. <https://doi.org/10.3389/fpls.2025.1710618>
13. Newspim. (July 3, 2026). Korea's first agriculture and forestry satellite launched...precision observations every three days, from crop growth to disasters. <https://www.newspim.com/news/view/20260703000799> (accessed August 2, 2026)
14. Herald Economy. (2026a, January 28). Korea Forest Service opens the era of "autonomous drones" navigating through forests. <https://biz.heraldcorp.com/article/10665629> (accessed August 2, 2026)
15. Herald Economy. (2026b, March 31). Hancom InSpace hyperspectral satellite "Sejong 3" successfully communicates with ground station. <https://biz.heraldcorp.com/article/10706270> (accessed August 2, 2026)

1.3

वानिकी-विशिष्ट विशाल भाषा मॉडल (ForestGPT) और बुद्धिमान निर्णय समर्थन

गैंगवॉन प्रांत में एक स्थानीय वन सहकारी के कार्यालय में दोपहर के तीन बजे हैं। गर्मियों के अंत में सूरज की रोशनी खिड़की के माध्यम से तिरछी हो जाती है, और अधिकारी की मेज पर वन संसाधन अधिनियम के प्रवर्तन नियमों वाली एक पुस्तिका घिसे-पिटे कोनों वाले वानिकी मैनुअल के बगल में खुली रहती है। उस सुबह अकेले, तीन कॉल करने वालों ने पूछा कि क्या पाइन विल्ट रोग नियंत्रण क्षेत्र में काटे गए मृत पेड़ों को अस्थायी रूप से गांव की साफ़-सफ़ाई में रखा जा सकता है। अधिकारी क़ानून की किताब के सूचकांक को देखता है, मैनुअल के परिशिष्ट को खोजता है, और यहां तक कि पिछले साल के आधिकारिक पत्राचार को भी खोलता है, लेकिन फिर भी कोई सटीक उत्तर नहीं मिल पाता है। अंत में, अधिकारी मैनुअल को बंद कर देता है और कंप्यूटर स्क्रीन पर सीधे खोज बॉक्स में प्रश्न टाइप करता है: पाइन विल्ट रोग से मारे गए पेड़ों का धूमन उपचार कहाँ पूरा किया जाना चाहिए?

अधिक लोग एआई चैटबॉट्स पर ऐसे प्रश्न पूछ रहे हैं। बड़े भाषा मॉडल (एलएलएम), जो पाठ के विशाल निकायों से सीखते हैं और एक व्यक्ति की तरह वाक्य उत्पन्न करते हैं, अब बिना किसी हिचकिचाहट के अधिकांश प्रश्नों का उत्तर देते हैं। समस्या तब शुरू होती है जब उत्तर गलत होता है। चैटजीपीटी और क्लाउड जैसे सामान्य प्रयोजन मॉडल ने इंटरनेट पर प्रसारित भारी मात्रा में पाठ से सीखा है, लेकिन वन नियमों और वानिकी विशिष्टताओं जैसे अपेक्षाकृत कम संकीर्ण, विशेष दस्तावेजों को पढ़ा है। जब वानिकी प्रश्न पूछा जाता है, तो वे निर्माण या सामान्य इंजीनियरिंग से सीखे गए ज्ञान का उपयोग कर सकते हैं और ऐसा उत्तर दे सकते हैं जो प्रशंसनीय लगता है। यह घटना, जिसमें एक मॉडल एक ऐसे तथ्य का आविष्कार करता है जिसका अस्तित्व ही नहीं है, मतिभ्रम कहलाती है। यह एक ऐसे व्यक्ति जैसा है जो आत्मविश्वासपूर्ण अभिव्यक्ति के साथ झूठ बोल रहा है। जंगल में, मतिभ्रम एक छोटी दुर्घटना के रूप में समाप्त नहीं होता है। यदि गलत धूमन मार्गदर्शन प्राप्त करने वाला कोई अधिकारी मृत पेड़ों को गलत तरीके से संभालता है, तो पाइनवुड नेमाटोड पड़ोसी जंगल में फैल सकते हैं। यदि गलत ढलान मानदंडों के तहत कटाई की जाती है, तो इससे मानसून के दौरान भूस्खलन हो सकता है।

वर्तमान वानिकी रिपोर्ट में 2026 की एक व्यवस्थित समीक्षा में, जिसने वन इंजीनियरिंग में एआई के प्रसार का पता लगाया, फोरकुओ और उनके सहयोगियों ने देखा कि यह आंदोलन संरचित डेटा जैसे सेंसर रीडिंग और उपग्रह तस्वीरों के प्रसंस्करण से परे विनियमों, दिशानिर्देशों और रिपोर्ट जैसे असंरचित दस्तावेजों के प्रसंस्करण तक बढ़ रहा है। संरचित डेटा के साथ काम करने वाला एआई उन मानों की गणना करता है जो बड़े करीने से संख्याओं में विभाजित होते हैं, जैसे कि वन क्षेत्र या पेड़ की ऊंचाई। असंरचित दस्तावेजों के साथ

काम करने वाले एआई को वाक्यों को पढ़ना चाहिए और संदर्भ को समझना चाहिए। बाद वाला कार्य कहीं अधिक कठिन है।

फ़ॉरेस्टजीपीटी, वानिकी को समर्पित एक बड़ा भाषा मॉडल, इस अंतर को पाटने का एक प्रयास है। ऑस्ट्रियाई शोधकर्ताओं एर्लिच-सोमर, एबरहार्ड और होल्जिंगर द्वारा 2025 में इलेक्ट्रॉनिक्स में प्रकाशित एक पेपर में मॉडल को एक सहायक के रूप में दर्शाया गया है जो लोगों पर अंतिम निर्णय छोड़ते समय वन विशेषज्ञों के साथ रहता है। शोधकर्ताओं ने चार-चरणीय विकास पथ का प्रस्ताव दिया: शुरुआत एक इंटरैक्टिव टूल से हुई जो वन सामग्री को पढ़ता है, फिर पुनर्प्राप्ति-संवर्धित पीढ़ी, विकास सिमुलेटर और फ़ील्ड सेंसर से कनेक्शन की ओर बढ़ता है। फूटा एक्सपो 2025 में परीक्षण किया गया सिस्टम प्रथम चरण का बहुभाषी चैटबॉट था जो लगभग एक मेगाबाइट क्यूरेटेड सामग्री का उपयोग करके आगंतुकों का मार्गदर्शन करता था। पुनर्प्राप्ति-संवर्धित पीढ़ी, सिमुलेटर और सेंसर एकीकरण रोडमैप पर बने हुए हैं।

ऐसा ही एक आंदोलन कोरिया में शुरू हो गया है। राष्ट्रीय वन विज्ञान संस्थान ने कृत्रिम बुद्धिमत्ता के साथ वन बड़े डेटा को मिलाकर अपनी पहली प्रतियोगिता आयोजित की और सात टीमों को पुरस्कार प्रदान किए। ऐसे प्रयोग जो गहन शिक्षण, जनरेटिव कृत्रिम बुद्धिमत्ता और स्वायत्त निर्णय और कार्रवाई में सक्षम एजेंट तकनीक को वन नीति और क्षेत्र सेवाओं से जोड़ते हैं, विश्वविद्यालयों और स्टार्टअप के माध्यम से फैल रहे हैं।

एक सहायक जो कानून ढूंढता और पढ़ता है

फ़ॉरेस्टजीपीटी जैसे वानिकी-विशिष्ट मॉडल द्वारा उपयोग की जाने वाली प्रौद्योगिकियाँ दो व्यापक श्रेणियों में आती हैं। एक फाइन-ट्यूनिंग है, जो बेस मॉडल के अंदर ही वज़न को फिर से प्रशिक्षित करता है। दूसरा पुनर्प्राप्ति-संवर्धित पीढ़ी (आरएजी) है, जो मॉडल भार को अपरिवर्तित छोड़ देता है और प्रत्येक प्रश्न के साथ प्रासंगिक कानून और मार्गदर्शन दस्तावेज प्रदान करता है। उत्तरार्द्ध का व्यापक रूप से वानिकी क्षेत्र में उपयोग किया जाता है। नियम अक्सर बदलते रहते हैं, और पूरे मॉडल को दोबारा प्रशिक्षित करने में काफी समय और पैसा लगता है। आरएजी के तहत, जब कोई प्रश्न आता है, तो मॉडल पहले उन प्रावधानों के लिए प्रासंगिक दस्तावेजों के भंडार की खोज करता है जो सबूत के रूप में काम कर सकते हैं, फिर उन प्रावधानों का हवाला देते हुए एक उत्तर तैयार करता है। कोई सहायक दस्तावेज़ नहीं मिलने पर उत्तर खोजने के बजाय, यह कहने के लिए सिस्टम डिज़ाइन करना कि वह नहीं जानता है, मतिभ्रम को रोकने का एक व्यावहारिक तरीका बन गया है।

यूरोपीय संघ के FOREST4EU प्रोजेक्ट द्वारा बनाया गया संवादी एजेंट फ़ार्म असिस्टेंट, इस सिद्धांत को प्रदर्शित करता है। यह फार्मबुक से जुड़ा है, जो खेतों और वन जोतों से एकत्रित ज्ञान का एक डेटाबेस है। जब चराई पैटर्न के बारे में पूछा जाता है जो जंगल की आग को रोक सकता है या बायोमास को कम करने के तरीकों के बारे में पूछा जाता है, तो यह सहायक सामग्रियों की पहचान संख्याओं के साथ जवाब देता है। जब डेटाबेस से अनुपस्थित सामग्री के बारे में पूछा जाता है, जैसे कि किसी बाहरी राजनेता का बयान, तो वह कोई उत्तर नहीं देता है, लेकिन स्पष्ट रूप से कहता है कि उसके पास जानकारी नहीं है। आर्मेनिया में, अमेरिकन यूनिवर्सिटी ऑफ आर्मेनिया (एयूए) पर्यावरण के लिए एकोपियन सेंटर और स्विस् फेडरल इंस्टीट्यूट फॉर फॉरेस्ट, स्लो एंड लैंडस्केप रिसर्च (डब्ल्यूएसएल) ने संयुक्त रूप से जलवायु-परिवर्तन प्रभाव आकलन करने और राष्ट्रीय रिपोर्ट लिखने में नीति निर्माताओं की सहायता के लिए एक इंटरैक्टिव चैटबॉट

बनाया है। यहां तक कि वन विज्ञान में सीमित पृष्ठभूमि ज्ञान वाले सिविल सेवक भी पुनर्वनीकरण योजना तैयार करते समय और कार्बन सिंक की गणना करते समय चैटबॉट से परामर्श ले सकते हैं।

अभी तक कोई भी तकनीक मतिभ्रम को पूरी तरह से खत्म नहीं कर पाई है। आरएजी, जो अनिश्चितता अनुमान, स्व-स्थिरता जांच और प्रतिक्रिया सुरक्षा उपायों के साथ पुनर्प्राप्त दस्तावेजों में उत्तरों को एंकर करता है, त्रुटियों को कम कर सकता है, लेकिन प्रदर्शन मॉडल और परीक्षण डेटा के अनुसार भिन्न होता है। उर्वरक की मात्रा या नियंत्रण समय के बारे में सलाह, जहां एक त्रुटि उस वर्ष की फसल को बर्बाद कर सकती है, अंततः एक मानव विशेषज्ञ द्वारा जांच की जानी चाहिए। गलत उत्तर के परिणाम जितने अधिक होंगे, जैसे कि कटाई परमिट या धूमन मानकों के साथ जुर्माना या पाइनवुड नेमाटोड का प्रसार हो सकता है, उतनी ही स्पष्ट सीमा खींची जानी चाहिए: मॉडल का उत्तर संदर्भ सामग्री है, अंतिम अनुमोदन नहीं।

खतरनाक कार्यस्थलों की सुरक्षा करने वाला एक सलाहकार

कार्यालय में किसी कानून की किताब के सामने झिझकते हुए बिताई गई दोपहर अपेक्षाकृत सुरक्षित होती है। पहाड़ों में प्रवेश करने वाले लकड़ी काटने वाले कर्मचारी के लिए अलग-अलग खतरे इंतजार कर रहे हैं। वानिकी एक उच्च दुर्घटना दर वाला उद्योग है। ढलान पर चेनसॉ का उपयोग करते समय पेड़ गिरने की दिशा का गलत आकलन करने या फिसलने से होने वाली दुर्घटनाएँ हर साल दोहराई जाती हैं। जापान में किंडाई विश्वविद्यालय के शोधकर्ताओं ने एक गेम और एक एआई सलाहकार एजेंट के साथ इस समस्या का समाधान करने की कोशिश की। उन्होंने सुरक्षा दिशानिर्देशों और विशेषज्ञ ज्ञान कार्डों के साथ एक चैटजीपीटी-आधारित एजेंट पहले से लोड किया। जब एक प्रशिक्षु ने क्षेत्र की स्थिति का वर्णन किया, तो एजेंट ने खतरों की पहचान की। ज्ञान पहले से लोड होने से पहले, पहले और दूसरे राउंड में संयुक्त रूप से आठ गलत उत्तर और प्रासंगिक विचलन उत्पन्न हुए। प्रक्रिया के बाद, तीसरे और चौथे राउंड में कुल मिलाकर केवल दो गलत उत्तर मिले। 40-आइटम सुरक्षित-व्यवहार पैमाने पर स्कोर भी उनके पूर्व-प्रशिक्षण स्तर से उल्लेखनीय रूप से बढ़ गया।

क्षेत्र में वॉयस कमांड से जुड़े प्रयोगों ने एक अन्य प्रकार की समस्या को उजागर किया। वानिकी-विशिष्ट शब्द जैसे चैप्स, जिसका अर्थ है सुरक्षात्मक कपड़े, और जापानी शब्द काकारिगी (かかり木), जो एक कटे हुए पेड़ को पूरी तरह से गिरने से पहले दूसरे पेड़ में फंसने का वर्णन करता है, को स्वचालित वाक् पहचान (एएसआर) के दौरान असंबंधित शब्दों के रूप में गलत तरीके से लिखा गया था। गलत तरीके से लिखे गए शब्द सीधे अगले चरण, प्राकृतिक भाषा प्रसंस्करण (एनएलपी) में चले गए, जो कंप्यूटर को मानव भाषण और लेखन को समझने की अनुमति देता है, और संदर्भ से भटकी हुई प्रतिक्रियाओं को बढ़ाता है। यह आमतौर पर जंगलों में होता है जहां शोर तेज़ होता है और सिग्नल आसानी से खो जाते हैं। शोधकर्ताओं ने एक अलग तकनीकी-शब्द शब्दकोश और एक प्रक्रिया जोड़ने का प्रस्ताव रखा जिसमें एक व्यक्ति मान्यता प्राप्त वाक्य को एक बार फिर से जांचता है।

दृश्य निगरानी एक अलग दृष्टिकोण अपनाती है। 2025 में साइंटिफिक रिपोर्ट्स में प्रकाशित कुंडू और उनके सहयोगियों द्वारा किए गए एक अध्ययन ने YOLOv8 ऑब्जेक्ट-डिटेक्शन मॉडल को लैंग्वेज-आधारित एजेंट से जोड़ा। सिस्टम ड्रोन और सैटेलाइट इमेजरी में स्टंप, लॉगिंग मशीनरी और अनधिकृत कर्मियों को ढूंढता है, फिर जीआईएस रिपोर्ट में संदिग्ध वनों की कटाई वाले क्षेत्रों को व्यवस्थित करता है। प्रशिक्षण हानि में कमी आई और अधिकतम रिकॉल 0.24 तक पहुंच गया, लेकिन एमएपी50 0.07 के आसपास

रहा। छोटे स्टंप और उपकरण को विश्वसनीय रूप से ढूंढने में सक्षम फ़ील्ड सिस्टम के रूप में मानने के लिए इसका प्रदर्शन बहुत कम है, इसलिए मानव पुनः जांच की आवश्यकता है।

कितना काटना है और कहां खींचना है

एक बुद्धिमान निर्णय समर्थन प्रणाली (डीएसएस) एक उपकरण है जो एक साथ कई स्थितियों की गणना करता है और विकल्पों की तुलना करता है। वन प्रबंधन में, लकड़ी का उत्पादन, श्रमिक सुरक्षा, मिट्टी का कटाव और कार्बन भंडारण एक ही योजना में टकराते हैं। 2025 प्रीप्रिंट में, एबरहार्ड और सहकर्मियों ने ढलान, मिट्टी-कटाव जोखिम और अवशिष्ट पेड़ों को नुकसान पर विचार करते हुए केबल यार्डर्स, फॉरवर्डर्स और विंच-सहायक उपकरणों की तुलना करते हुए एक जीआईएस-आधारित मॉडल का प्रस्ताव रखा। यह एक सहकर्मी-समीक्षित परिचालन क्षेत्र प्रणाली नहीं है।

डेंग और फेंग ने आनुवंशिक एल्गोरिदम के साथ कटे हुए पेड़ों को ले जाने वाले ट्रकों के लिए प्रेषण और रूटिंग समस्या को हल किया। जिस तरह से जीव क्रमिक पीढ़ियों में बेहतर लक्षण पारित करते हैं, उसका अनुकरण करते हुए, यह कम्प्यूटेशनल विधि कई उम्मीदवार मार्ग उत्पन्न करती है और उन्हें प्रतिस्पर्धा कराती है, फिर एक इष्टतम प्रेषण कार्यक्रम खोजने के लिए जीवित मार्गों को थोड़ा-थोड़ा करके बदल देती है। इससे पहले, गोरगेन्स और उनके सहयोगियों ने एक बहु-उद्देश्यीय नियोजन एल्गोरिदम विकसित किया था, जो निष्कर्षण ट्रेल्स द्वारा मिट्टी को संकुचित करने की सीमा को सीमित करते हुए फसल की मात्रा में वृद्धि करता था।

वन प्रबंधन के प्रदर्शन को केवल धन के बजाय कई मानदंडों के आधार पर मापने का प्रयास किया जा रहा है। डेटा आवरण विश्लेषण (डीईए) एक सांख्यिकीय तकनीक है जो निवेश किए गए संसाधनों और उत्पादित परिणामों के बीच अनुपात की गणना करती है, जो कम कुशल इकाइयों से अत्यधिक कुशल वन-प्रबंधन इकाइयों को अलग करती है। वानिकी डीईए अनुसंधान के तीन दशकों को कवर करने वाले ज़दमीरज़ेई और उनके सहयोगियों द्वारा 2026 की समीक्षा के अनुसार, हाल ही में डीईए तेजी से कृत्रिम बुद्धिमत्ता के साथ जुड़ गया है। अनुसंधान का एक बढ़ता हुआ निकाय इनपुट चर चुनते समय प्रमुख कारकों का चयन करने के लिए एक यादृच्छिक वन एल्गोरिदम का उपयोग करता है, तंत्रिका नेटवर्क के साथ दक्षता स्कोर की भविष्यवाणी करता है, और डीईए को एनएसजीए-द्वितीय के साथ जोड़ता है, आनुवंशिक-एल्गोरिदम विधियों का एक परिवार जो ठोस नीति परिदृश्यों का निर्माण करने के लिए परिचालन दक्षता, लकड़ी राजस्व, पर्यावरण संरक्षण और कार्बन पृथक्करण जैसे विभिन्न लक्ष्यों को एक साथ अनुकूलित करता है।

दीर्घकालिक पूर्वानुमान के स्तर पर राष्ट्रीय आँकड़े अपनी शक्ति का प्रयोग करते हैं। एक उदाहरण एक अध्ययन है जिसमें तंजानिया के राष्ट्रीय वन संसाधन निगरानी और मूल्यांकन (NAFORMA) के डेटा को मशीन लर्निंग के साथ जोड़कर 2054 तक वन क्षेत्र में होने वाले परिवर्तनों का अनुमान लगाया गया है। जंगलों और वुडलैंड्स का क्षेत्र, जो 2014 में 48.09 मिलियन हेक्टेयर था, एक ऐसे परिदृश्य के तहत 32.99 मिलियन हेक्टेयर तक गिर गया है जो मौजूदा विकास प्रवृत्तियों को अपरिवर्तित जारी रखने की अनुमति देता है। भारी विकास दबाव वाले परिदृश्य में, यह घटकर 28.30 मिलियन हेक्टेयर रह जाता है। इसके विपरीत, स्थायी प्रबंधन लागू करने वाले परिदृश्य में, गिरावट का पैमाना स्पष्ट रूप से कम हो जाता है, जिससे मात्रात्मक साक्ष्य मिलते हैं जिनका उपयोग नीतिगत निर्णयों में किया जा सकता है।

गणना कृषिवानिकी तक पहुंच रही है, जिसमें पेड़ और फसलें भी एक साथ उगाई जाती हैं। इंडोनेशिया में रिडलो और उनके सहयोगियों ने यह निर्धारित करने के लिए ग्राफ सिद्धांत का उपयोग किया कि उपयुक्त आर्द्रता और कार्बन-डाइऑक्साइड सांद्रता बनाए रखने के लिए कॉफी के पेड़ों के बीच छायादार पेड़ कहाँ लगाए जाने चाहिए। उन्होंने छायादार पेड़ों के स्थान तय करने के लिए एक ग्रीडयुक्त क्षेत्र योजना में आरआईडीएस, या रिज़ॉल्विंग इंडिपेंडेंट डोमिनेटिंग सेट्स नामक एक ग्राफ एल्गोरिदम लागू किया। फिर उन्होंने 10 से 20 दिन पहले माइक्रोक्लाइमेट परिवर्तन का पूर्वानुमान लगाने के लिए स्मार्ट सेंसर द्वारा एकत्र किए गए आर्द्रता और कार्बन-डाइऑक्साइड डेटा को एक स्थानिक-लौकिक ग्राफ तंत्रिका नेटवर्क (एसटीजीएनएन) में डाला। 96 कॉफी के पेड़ों और 26 छायादार पेड़ों वाले एक भूखंड में प्रति वर्ष 520 किलोग्राम कार्बन डाइऑक्साइड बनाए रखने की गणना की गई थी। एक ग्रीड में लगाए गए 31 छायादार पेड़ों वाले एक भूखंड पर प्रति वर्ष 620 किलोग्राम प्रतिधारण बनाए रखने की गणना की गई थी। त्रुटि मेट्रिक्स मौजूदा तुलना मॉडल और व्याख्यात्मक शक्ति की तुलना में कम थे, जो दर्शाता है कि भविष्यवाणियों में बताए गए वास्तविक मूल्यों का कितना हिस्सा 0.73 से 0.81 तक था, जो अन्य तरीकों से बेहतर प्रदर्शन कर रहा था।

आत्मविश्वास से भरे गलत उत्तर का पता कैसे लगाएं

जब शोध निष्कर्षों को एक साथ रखा जाता है, तो परस्पर विरोधी दावे सामने आते हैं। चैटजीपीटी जैसे सामान्य-उद्देश्य वाले बड़े भाषा मॉडल विभिन्न भाषाओं में व्यापक सामान्य ज्ञान और लचीलेपन का नेतृत्व करते हैं, लेकिन वन नियमों और कार्यस्थल सुरक्षा नियमों जैसे संकीर्ण, विशेष प्रश्नों पर अक्सर मतिभ्रम करते हैं। आरएजी-आधारित मॉडल या फ़ॉरेस्टजीपीटी, जो सहायक दस्तावेज़ों में उत्तर देते हैं, नियामक प्रश्नों के लिए अधिक सटीकता और मजबूत साक्ष्य प्रदान करते हैं। चूंकि उन्हें निर्दिष्ट ज्ञान भंडार के बाहर के प्रश्नों को अस्वीकार करने के लिए डिज़ाइन किया गया है, हालाँकि, वे उतनी आज़ादी से बातचीत नहीं कर सकते हैं। एक ही समय में सटीकता और स्वतंत्रता हासिल करना अभी आसान नहीं है।

कम्प्यूटेशनल तरीकों के बीच भी यही तनाव दिखाई देता है। एक पारंपरिक डीईए मॉडल, रैखिक समीकरणों के माध्यम से, उस गणना को उजागर करता है जो दक्षता स्कोर उत्पन्न करती है, जिससे नीति निर्माताओं के लिए इसे स्वीकार करना आसान हो जाता है। इसके विपरीत, एक गहन-शिक्षण भविष्यवाणी मॉडल, उच्च सटीकता प्रदान करता है लेकिन एक ब्लैक बॉक्स बना रहता है जिसकी आंतरिक गणनाओं का निरीक्षण करना मुश्किल होता है। यह अपारदर्शिता उन नीतिगत दस्तावेज़ों में बाधा बन जाती है जिनके लिए कानूनी आधार का हवाला दिया जाना चाहिए।

प्रौद्योगिकी के बाहर की समस्याएँ भी कम विकराल नहीं हैं। स्वचालन और स्वायत्त निर्णय लेने वाले एजेंट तेजी से वानिकी में प्रवेश कर रहे हैं, लेकिन वन नीति और कानूनी प्रणालियाँ अभी तक यह तय नहीं कर पाई हैं कि एआई द्वारा लिए गए निर्णयों के लिए कौन जिम्मेदार है। यदि कोई एजेंट गलत सुरक्षा मार्गदर्शन देता है और कोई दुर्घटना होती है, तो यह निर्धारित करना मुश्किल है कि फ़ील्ड प्रबंधक या डेवलपर जिम्मेदार है या नहीं। सिस्टम साइंसेज (HICSS) पर 2026 हवाई अंतर्राष्ट्रीय सम्मेलन में, स्वीडिश शोधकर्ताओं बर्गक्रिस्ट और उनके सहयोगियों ने कहा कि मानकीकृत डेटा वाले अन्य उद्योगों के विपरीत, वानिकी साइटें असंगत तरीकों से जानकारी दर्ज करती हैं और कई कागजी दस्तावेज़ों को बनाए रखती हैं, इसलिए डेटा को व्यवस्थित करना स्वचालन से पहले होना चाहिए। डेटा साइलो की समस्या, जिसमें कटाई

से लेकर प्रसंस्करण और वितरण तक के रिकॉर्ड अलग-अलग संस्थानों में अलग-अलग जमा होते हैं, एकीकृत निर्णय लेने को भी धीमा कर देती है। बड़े भाषा मॉडल और स्थानिक-लौकिक ग्राफ तंत्रिका नेटवर्क को पर्याप्त ग्राफिक्स-कंप्यूटिंग संसाधनों की भी आवश्यकता होती है। सुदूर जंगलों में ड्रोन और हैंडहेल्ड उपकरणों पर जहां इंटरनेट कनेक्शन आसानी से खो जाते हैं, धीमी गणना और अपर्याप्त भंडारण अनसुलझे रहते हैं।

आगे का काम स्पष्ट है।

SHAP और ग्रेड-सीएएम जैसी व्याख्या योग्य-एआई तकनीकें, जो दिखाती हैं कि एक मॉडल किसी निर्णय पर क्यों पहुंचा, उसे निर्णय इंजनों से जोड़ा जाना चाहिए। वन नियमों और व्यावसायिक-सुरक्षा मानकों के अनुरूप दिशानिर्देशों की आवश्यकता है। परिमाणीकरण और ज्ञान आसवन के माध्यम से मॉडलों को कम करने के बाद, उनके डिवाइस-विशिष्ट प्रतिक्रिया समय और बिजली की खपत का उन जंगलों में परीक्षण किया जाना चाहिए जहां लोरा वायरलेस नेटवर्क और 5जी बेस स्टेशन दुर्लभ हैं। मानक बेंचमार्क के साथ-साथ देशों और क्षेत्रों में वन डेटा साझा करने की प्रणालियाँ भविष्य के लिए कार्य बनी हुई हैं।

इस आंदोलन में भाषा मॉडल अकेले नहीं हैं। भू-स्थानिक आधार मॉडल पृथ्वी को नेशनल एरोनॉटिक्स एंड स्पेस एडमिनिस्ट्रेशन (NASA) और IBM द्वारा संयुक्त रूप से बनाया गया था। मई 2026 में ऑस्ट्रेलिया के कान्जिनी उपग्रह और अंतर्राष्ट्रीय अंतरिक्ष स्टेशन (आईएसएस) पर इमेजिन-ई उपकरण पर संचालित एक संपीड़ित मॉडल। कक्षीय प्रदर्शन ने बाद और बादल का पता लगाने की प्रक्रिया की। जंगल की ऊंचाई और कटाई के निशानों का विश्लेषण एक संभावित जमीन-आधारित अनुप्रयोग के रूप में प्रस्तुत किया गया था और इसे इस कक्षीय परीक्षण के परिणामों से अलग किया जाना चाहिए।

लोग जंगल में एआई से अधिक से अधिक प्रश्न पूछेंगे, लेकिन निकट भविष्य के लिए, उन्हें अभी भी स्वयं जांचना होगा कि कौन सा दस्तावेज़ प्रत्येक उत्तर का समर्थन करता है। मॉडल अब नियमों का सारांश दे सकते हैं, जोखिमों को पहले से चिह्नित कर सकते हैं और ट्रक मार्गों की गणना कर सकते हैं। फिर भी एक आश्चर्य वाक्य अभी भी गलत हो सकता है। अनुमोदन बॉक्स में एक मानव हस्ताक्षर रहता है।

स्रोत और संदर्भ

1. AUA Acopian Center for the Environment, & WSL. (July 2026). A validated predictive framework: Climate-smart reforestation and resilience mapping in Armenia [Video]. YouTube. <https://www.youtube.com/watch?v=LBrq1KNUUyE> (accessed August 2, 2026)
2. Bergqvist, M., Nylén, D., Lindberg, A., & Åkesson, M. (2026). Digital innovation in data-poor and unstructured environments: Envisioning autonomous systems in forestry. In T. X. Bui (Ed.), Proceedings of the 59th Hawaii International Conference on System Sciences (pp. 5881-5890). University of Hawaii. <https://doi.org/10.24251/HICSS.2026.697>
3. Deng, W., & Feng, X. (2025). A genetic algorithm for forest logging trucks routing and scheduling problem. Forests, 16(9), 1440. <https://doi.org/10.3390/f16091440>
4. Eberhard, B., Trailović, Z., Magagnotti, N., & Spinelli, R. (2025). A GIS-based decision support model (DSM) for harvesting system selection on steep terrain: Integrating operational and silvicultural criteria. Preprints, 2025011137. <https://doi.org/10.20944/preprints202501.1137.v1>

5. FOREST4EU Project Consortium. (November 2025). Webinar: Exploring the role of knowledge repositories: Farm Assistant chatbot demo [Video]. YouTube. <https://www.youtube.com/watch?v=slRhC5sfbjA> (accessed August 2, 2026)
6. Forkuo, G. O., Picchio, R., Proto, A. R., & Borz, S. A. (2026). Applications of artificial intelligence in forest operations engineering research: A systematic review. *Current Forestry Reports*, 12, Article 14. <https://doi.org/10.1007/s40725-026-00275-x>
7. Görgens, E. B., Mund, J. P., Cremer, T., de Conto, T., Krause, S., & Valbuena, R. (2020). Automated operational logging plan considering multicriteria optimization. *Computers and Electronics in Agriculture*, 170, 105253. <https://doi.org/10.1016/j.compag.2020.105253>
8. Hayashi, K., Shimazaki, K., Takahashi, A., Ikeda, M., & Matsumoto, Y. (2026). Practice of forestry safety education game by AI advisor and verification of learning effectiveness. *Journal of Occupational Safety and Health*, advance online publication. https://www.jstage.jst.go.jp/article/josh/advpub/0/advpub_JOSH-2025-0011-GE/_pdf
9. Kundu, S., Ninoria, S. Z., Chaturvedi, R. P., Mishra, A., Agrawal, A., Batra, R., Dubale, M., & Hashmi, A. (2025). Real-time deforestation anomaly detection using YOLO and LangChain agents for sustainable environmental monitoring. *Scientific Reports*, 15, Article 39961. <https://doi.org/10.1038/s41598-025-23617-4>
10. Ridlo, Z. R., Dafik, Waluyo, J., Yushardi, & Venkatachalam, M. (2025). On RIDS analysis for shade tree placement and its application to STGNN multi-step forecasting on RH and CO2 concentration of coffee agroforestry. *Statistics, Optimization & Information Computing*, 14(4), 1889-1908. <https://doi.org/10.19139/soic-2310-5070-2643>
11. Ehrlich-Sommer, F., Eberhard, B., & Holzinger, A. (2025). ForestGPT and beyond: A trustworthy domain-specific large language model paving the way to Forestry 5.0. *Electronics*, 14(18), 3583. <https://doi.org/10.3390/electronics14183583>
12. Zadmirzaei, M., Cozzi, M., Romano, S., Amirteimoori, A., & Viccaro, M. (2026). Data envelopment analysis in forestry over three decades: An in-depth review of models and emerging directions. *Environment, Development and Sustainability*. <https://doi.org/10.1007/s10668-026-07610-z>
13. Zella, A. Y. (2026). Sustainable forest and land-use management in Tanzania: NAFORMA-based and machine learning forecasts to 2050 under Tanzania Dira 2050. *International Journal of Development and Management Review*, 21(1), 1-36. <https://doi.org/10.4314/ijdmr.v21i1.1>
14. Korea Policy Briefing. (July 24, 2026). Forest issues challenged with AI...National Institute of Forest Science holds competition. <https://www.korea.kr/briefing/pressReleaseView.do?newsId=156751645> (accessed August 2, 2026)

अध्याय 2

सटीक वानिकी: प्रत्येक वृक्ष का विश्लेषण और बायोमास व कार्बन का सटीक मापन

2.1

UAV-LiDAR और उच्च-रिज़ॉल्यूशन इमेजरी पर आधारित व्यक्तिगत वृक्ष-प्रजाति वर्गीकरण

भोर में, कोहरा पूरी तरह से छंटने से पहले, एक ड्रोन गैंगवोन प्रांत में पहाड़ की तलहटी पर स्थित कोरियाई चीड़ के वृक्षारोपण के ऊपर नीची उड़ान भरता है। प्रोपेलर का शोर घाटी में फैल जाता है, और ड्रोन एक खेत की जुताई करने वाले ट्रैक्टर की तरह एक ग्रिड में आगे और पीछे आकाश को पार करता है। LiDAR, या लाइट डिटेक्शन एंड रेंजिंग, विमान के नीचे लटका रहता है। यह हर सेकंड सैकड़ों-हजारों लेजर पल्स उत्सर्जित करता है और प्रकाश द्वारा पत्तियों और शाखाओं से टकराने और वापस लौटने में लगने वाले समय को मापकर दूरी की गणना करता है। हर बार जब ड्रोन गुजरता है, तो हजारों कोरियाई चीड़ के पेड़ों की रूपरेखा, बिंदु दर बिंदु, आकाश से चिह्नित होती है। एक बार जब सभी बिंदु इकट्ठे हो जाते हैं, तो वे न केवल पूरे जंगल को बल्कि प्रत्येक पेड़ के स्थान और ऊंचाई और यहां तक कि उसकी शाखाओं के फैलने के पैटर्न को भी प्रकट करते हैं।

लंबे समय तक, वानिकी ने पेड़ों के समूह के रूप में वनों का प्रबंधन किया। इसमें मोटे तौर पर अनुमान लगाया गया कि एक क्षेत्र में कितने चीड़ उगते हैं और उनकी औसत ऊंचाई क्या है। परिशुद्ध वानिकी गणना की इकाई को अलग-अलग पेड़ तक कम कर देती है। यह पहचानना कि प्रत्येक पेड़ कहाँ खड़ा है, व्यक्तिगत वृक्ष पहचान (आईटीडी) कहलाता है, और केवल उस पेड़ की पत्तियों और शाखाओं के कब्जे वाले क्षेत्र को काटना व्यक्तिगत वृक्ष मुकुट परिसीमन (आईटीसीडी) कहलाता है। अतीत में, लोग मापने वाले टेप और दृश्य अनुमान के साथ सीधे पेड़ों की गिनती करने के लिए पहाड़ पर चढ़ जाते थे, या जहां चमक कम हो गई थी, वहां सीमाओं को खोजने के लिए वाटरशेड विभाजन का उपयोग करके हवाई तस्वीरों में पेड़ों को अलग कर देते थे। ये विधियाँ अक्सर घने जंगलों में विफल रहीं जहाँ शाखाएँ बिना अंतराल के आकाश को ढँक लेती थीं और मिश्रित जंगलों में जिनमें कई पेड़ प्रजातियाँ थीं। अंडरसेग्मेंटेशन, जिसने दो आसन्न पेड़ों को एक में मिला दिया, और ओवरसेग्मेंटेशन, जिसने गलत तरीके से एक शाखा को दूसरे पेड़ को सौंप दिया, बार-बार हुआ।

इन सीमाओं को पार करने के लिए, अनुसंधान का एक तेजी से बढ़ता हुआ समूह मानव रहित हवाई वाहन लेजर स्कैनिंग द्वारा बनाए गए त्रि-आयामी बिंदु बादलों को जोड़ता है, जिसमें उच्च-रिज़ॉल्यूशन इमेजरी और कंप्यूटर-विज्ञान डीप लर्निंग के साथ लेजर पल्स लौटाकर पंजीकृत लाखों बिंदु शामिल होते हैं। इसी तरह के संयोजन कोरिया में पहले से ही मैदान में प्रवेश कर रहे हैं। सितंबर 2025 में, जैसे ही पाइन विल्ट बीमारी फिर से उभरी, कोरिया वन सेवा ने एक प्रणाली की घोषणा की, जिसमें संक्रमण के संदेह वाले देवदार के पेड़ों का स्वचालित रूप से चयन करने के लिए कृत्रिम बुद्धिमत्ता और LiDAR के साथ हेलीकॉप्टर और ड्रोन सर्वेक्षणों को जोड़ा गया। आकाश से खींचे गए बादल और चित्र इस प्रकार लोगों द्वारा पहाड़ पर चढ़ने और एक-एक करके पेड़ों का निरीक्षण करने की स्क्रीनिंग करते हैं। हालाँकि, यह ऑपरेशन

रोगग्रस्त पेड़ों को खोजने के लिए एक स्क्रीनिंग चरण है और पेड़-प्रजाति वर्गीकरण से एक अलग उद्देश्य पूरा करता है, जो प्रजातियों की पहचान करता है।

गहन शिक्षा जो एक पेड़ की रूपरेखा बनाती है

YOLO, या यू ओनली लुक वन्स, वास्तविक समय ऑब्जेक्ट-डिटेक्शन एल्गोरिदम का परिवार किसी ऑब्जेक्ट के स्थान और प्रकार दोनों को खोजने के लिए एक छवि को एक बार स्कैन करता है। इसकी कम्प्यूटेशनल गति इसे क्राउन डिटेक्शन के लिए भी उपयोगी बनाती है। वियतनाम के डोंग नाई में पिनस केसिया बागान में, गुयेन थान तुआन के नेतृत्व में एक टीम ने उच्च-रिज़ॉल्यूशन वाली हवाई तस्वीरों के साथ UAV-LiDAR को मिला और YOLOv8m-Seg, YOLOv11m-Seg, YOLOv12m और सामान्य प्रयोजन विभाजन मॉडल SAM2 की तुलना की। मूल एसएएम को लगभग 11 मिलियन छवियों और एक अरब से अधिक विभाजन मास्क पर प्रशिक्षित किया गया था, जबकि एसएएम2 बड़े पैमाने पर वीडियो डेटा के साथ विस्तारित एक मॉडल है।

YOLOv11m-Seg ने ट्री डिटेक्शन में mAP50 0.62 और F1 स्कोर 0.59 दर्ज किया। YOLOv12m और SAM2, साथ ही YOLOv8m-Seg को संयोजित करने वाला मॉडल इन मूल्यों तक नहीं पहुंच पाया। उन क्षेत्रों में जहां पाइन क्राउन सघन रूप से ओवरलैप होते हैं, फ्रील्ड डेटा पर प्रशिक्षित मॉडल ने सामान्य-उद्देश्य विभाजन मॉडल से बेहतर प्रदर्शन किया। जब इन सीमाओं को LiDAR बिंदु बादल के साथ मिला गया और क्षेत्र माप के साथ तुलना की गई, तो अनुमानित पेड़ की ऊंचाई की व्याख्यात्मक शक्ति 0.85 से 0.93 तक थी। क्राउन-चौड़ाई अनुमान की व्याख्यात्मक शक्ति 0.58 से 0.86 तक थी। क्योंकि परिणाम एक क्षेत्र में वृक्षारोपण से आए हैं, उन्हें अन्य प्रजातियों और प्राकृतिक वनों में फिर से मान्य किया जाना चाहिए।

उपग्रह छवियों और हवाई तस्वीरों का उपयोग करने वाली एक अन्य टीम ने फास्टर आर-सीएनएन परिवार से घनत्व-आकलन तंत्रिका नेटवर्क के साथ YOLOv5 को संयोजित करते हुए BRO हाइब्रिड मॉडल का प्रस्ताव रखा। इसमें मल्टीस्केल अपसैंपलिंग को समायोजित करने के लिए बैटल रॉयल ऑप्टिमाइज़ेशन नामक एक खोज तकनीक का उपयोग किया गया था, और इसे पेड़ों की गिनती करने के लिए डिज़ाइन किया गया था, चाहे वे कम खड़े हों या घने समूहों में। मॉडल ने 97.8 प्रतिशत वृक्ष-गणना अनुमान सटीकता और 0.0912 की औसत निरपेक्ष त्रुटि (एमएई) दर्ज की।

यू-नेट तंत्रिका नेटवर्क का व्यापक रूप से मुकुट के बारीक वक्र खींचने के लिए उपयोग किया जाता है। उनकी संरचना एक छवि को छोटे आकार में संपीड़ित करती है, फिर विस्तृत रूपरेखा को पुनर्प्राप्त करते हुए इसे मूल आकार में पुनर्स्थापित करती है। स्किप कनेक्शन पूरे नेटवर्क में संपीड़न से पहले की जानकारी ले जाता है, जिससे शाखाओं जैसी पतली सीमाओं को धुंधला होने से रोका जा सकता है। वांग लिनलॉंग के नेतृत्व में एक टीम ने अनहुई प्रांत और गुआंगशी प्रांत, चीन में जिक्सी के उपोष्णकटिबंधीय मिश्रित जंगलों में एमटीएससीएफनेट विकसित किया। इसके इनपुट में ज़ेनम्यूज़ पी1 से लैस डीजेआई एम300 आरटीके द्वारा कैप्चर की गई यूएवी-आरजीबी कैमरा इमेजरी शामिल थी। इसे RIEGL मिनीVUX-1 UAV द्वारा एकत्र किए गए LiDAR बिंदु बादल और चीन के GF-2 उपग्रह से इमेजरी भी प्राप्त हुई। LiDAR बिंदुओं का घनत्व 87.14 प्रति वर्ग मीटर था। शोधकर्ताओं ने एनकोडर को तीन शाखाओं में विभाजित किया जो

डेटा को अलग-अलग संसाधित करते थे, फिर उन्हें संयोजित करने के लिए एक ट्रिपल-ब्रांच फ्रीचर-फ़्यूज़न मॉड्यूल जोड़ा। एकल सेंसर का उपयोग करने वाले मॉडल की तुलना में, क्राउन-क्षेत्र विभाजन और वृक्ष-प्रजाति वर्गीकरण दोनों के लिए ओवरलैप-सटीकता मेट्रिक्स में सुधार हुआ है।

केवल उच्च-रिज़ॉल्यूशन दृश्य-प्रकाश ऑर्थोफोटो का उपयोग करके घने मुकुटों को अलग करने का प्रयास किया जाता है। FSC-Mask2Former नामक एक विधि को 512 गुणा 512 पिक्सेल पर क्रॉप की गई 958 छवियों पर प्रशिक्षित किया गया था। प्रत्येक छवि को जमीनी सच्चाई के डेटा के साथ जोड़ा गया था, जिसमें कुल मिलाकर 7,636 पेड़ों की सटीक रूपरेखा थी। छवि-बनावट की जानकारी के अलावा, विधि ने आवृत्ति डोमेन में निकाली गई विशेषताओं को लागू किया, जो जांच करती है कि रंग और चमक के पैटर्न कितनी बार दोहराए जाते हैं, साथ ही विरोधाभासी शिक्षा, जो समान पेड़ों को करीब और अलग-अलग पेड़ों को दूर होने के लिए प्रशिक्षित करती है। इसने घने पत्ते वाले मिश्रित जंगलों में पेड़ों की सीमाओं को अलग करने में त्रुटियों को स्पष्ट रूप से कम कर दिया।

पॉइंट ट्रांसफॉर्मर V3 (PTv3) तंत्रिका नेटवर्क में से एक है जो त्रि-आयामी बिंदु बादलों को सीधे बिंदु दर बिंदु संसाधित करता है। यह आत्म-ध्यान को स्थानांतरित करता है, एक ऐसी विधि जो गणना करती है कि डेटा का प्रत्येक भाग हर दूसरे भाग से कितनी निकटता से संबंधित है और मूल रूप से एक वाक्य में शब्दों के बीच संबंधों की जांच करने के लिए त्रि-आयामी वृक्ष संरचना का उपयोग किया जाता था। एक अध्ययन में, तीन तरंग दैर्ध्य बैंड उत्सर्जित करने वाले मल्टीस्पेक्ट्रल LiDAR द्वारा कैप्चर किए गए बिंदु बादलों को चार मॉडलों में डाला गया: PTv3, KPConv, सुपरपॉइंट ट्रांसफॉर्मर (SPT), और यादृच्छिक वन। जंगल को छह परतों में विभाजित किया गया था: ज़मीन, कम वनस्पति, पेड़ के तने, शाखाएँ, पत्तियाँ और लकड़ी का मलबा। इस तुलना में, PTv3 ने 69.1 प्रतिशत की ओवरलैप सटीकता (mIoU) हासिल की, जो अन्य त्रि-आयामी मॉडलों से 21.8 प्रतिशत अंक अधिक है।

जनवरी 2026 में प्रकाशित एक संबंधित मेटा-विश्लेषण भी इस प्रवृत्ति को संख्यात्मक रूप से प्रदर्शित करता है। जब एल्डेरी और सहकर्मियों ने व्यक्तिगत-वृक्ष का पता लगाने पर कागजात एकत्र किए और जांच की, तो व्यक्तिगत पेड़ों को काटने वाले उदाहरण-विभाजन तरीकों का योगदान कुल का लगभग 46 प्रतिशत था, जबकि इनपुट के रूप में सामान्य आरजीबी हवाई तस्वीरों का उपयोग करने वाले अध्ययनों में सबसे बड़ी हिस्सेदारी, 73 प्रतिशत थी। इसका मतलब यह है कि तस्वीरों और कैनोपी ऊंचाई मॉडल (सीएचएम) का उपयोग करने वाले संयोजन, जो मानचित्र की तरह पेड़ की ऊंचाई प्रदर्शित करते हैं, अकेले LiDAR की तुलना में अधिक सामान्य हैं।

मिश्रित वन में पेड़ों का नामकरण

एक बार जब अलग-अलग मुकुट काट दिए जाते हैं, तो अगले चरण में विशेष प्रजाति का निर्धारण करने के लिए उनके भीतर के रंग, बनावट और त्रि-आयामी आकृति की जांच की जाती है। मिश्रित वनों में यह कार्य कठिन है, जहां ऊपरी छत्र वाले पेड़ों और निचली झाड़ियों से परावर्तित प्रकाश आपस में मिलता है, पेड़ों के बीच नमूनों की संख्या तेजी से भिन्न होती है, और दुर्लभ प्रजातियों के लिए केवल कुछ तस्वीरें मौजूद हैं।

किन तियानि और झाओ क्विंगजियान ने 2025 में वैज्ञानिक रिपोर्ट में मल्टी-ब्रांच मल्टी-लेबल वृक्ष प्रजातियों के वर्गीकरण (एमएमटीएससी) का एक अध्ययन प्रकाशित किया। इसने ट्रीसैटएआई का उपयोग

करके संयुक्त रूप से यूएवी हवाई तस्वीरों और सेंटिनल उपग्रह इमेजरी का विश्लेषण किया, जो यूरोप में बनाया गया एक मल्टीसेंसर बेंचमार्क डेटासेट है और जिसमें 15 प्रमुख वृक्ष प्रजातियां शामिल हैं। शोधकर्ताओं ने वृक्ष-प्रजाति की पहचान के लिए छह बैकबोन न्यूरल नेटवर्क की तुलना की, जिनमें DenseNet121, EfficientNet-B0 और ConvNeXt-Tiny शामिल हैं। यहां तक कि जब नमूनों की संख्या प्रजातियों के बीच बहुत भिन्न होती है, तब भी DenseNet121 को अपनी रीढ़ के रूप में उपयोग करने वाले मॉडल ने अन्य पांच से बेहतर प्रदर्शन किया। इसका F1 स्कोर लगभग 72 प्रतिशत था और इसकी सटीकता लगभग 82 प्रतिशत थी।

मलेशिया के बोर्नियो द्वीप पर डेरामाकोट और तांगकुलप वन प्रबंधन इकाइयों (एफएमयू) में, शोधकर्ताओं ने उष्णकटिबंधीय वर्षावन में अन्य पेड़ों से लंबे, उभरते हुए डिप्टेरोकार्पेसी पेड़ों को अलग करने के लिए डीपफॉरेस्ट (डीएफ स्कैनर प्रो) और एक कुशलनेट-बी 4 तंत्रिका नेटवर्क का उपयोग किया। निर्माता की सटीकता, सही ढंग से पहचाने गए वास्तविक डिप्टेरोकार्प पेड़ों का अनुपात 0.71 था। उपयोगकर्ता की सटीकता, एआई द्वारा डिप्टेरोकार्प के रूप में पहचाने गए पेड़ों का अनुपात जो वास्तव में डिप्टेरोकार्प थे, 0.67 था। उपग्रह-आधारित मशीन-लर्निंग मॉडल के लिए प्रशिक्षण सामग्री के रूप में परिणामी वृक्ष-प्रजाति की जानकारी जोड़ने से जमीन के ऊपर कार्बन (एजीसी) अनुमानों में त्रुटि कम हो जाती है। अकेले उपग्रह इमेजरी का उपयोग करने वाले मॉडल की मूल माध्य वर्ग त्रुटि (आरएमएसई) 70.60 मेगाग्राम प्रति हेक्टेयर थी। जब ड्रोन द्वारा सत्यापित वृक्ष-प्रजाति की जानकारी जोड़ी गई, तो त्रुटि गिरकर 60.53 मेगाग्राम प्रति हेक्टेयर हो गई।

जनवरी 2026 में साइंटिफिक रिपोर्ट्स में प्रकाशित कोटारो कोमात्सु और उनके सहयोगियों का एक पेपर व्यापक क्षेत्र में इसी तरह की प्रवृत्ति की पुष्टि करता है। जब मलेशिया और इंडोनेशिया में 395 सर्वेक्षण भूखंडों में कार्बन स्टॉक और जैव विविधता सूचकांकों का अनुमान केवल उपग्रह संकेतकों से लगाया गया था, तो व्याख्यात्मक शक्ति 0.43 और 0.46 पर रही। ड्रोन इमेजरी के 934 सेट जोड़े जाने के बाद, व्याख्यात्मक शक्ति बढ़कर 0.51 और 0.48 हो गई। ड्रोन द्वारा ली गई अलग-अलग पेड़ों की जानकारी उपग्रह तस्वीरों के मोटे पैमाने पर बेहतर रिजॉल्यूशन में भर जाती है।

मिश्रित वनों में बहुत कम नमूनों वाली दुर्लभ प्रजातियाँ होती हैं, इसलिए यदि एक सामान्य हानि फ्रंक्शन, यह गणना करने के लिए उपयोग की जाने वाली विधि कि मॉडल कितना गलत है, अपरिवर्तित लागू किया जाता है, तो भविष्यवाणियाँ कई व्यक्तियों के साथ पेड़ प्रजातियों की ओर झुक जाती हैं। इस असंतुलन को ठीक करने के लिए एम-मोएनेट, या मल्टीमॉडल स्पार्स मिक्सचर-ऑफ-एक्सपर्ट्स नेटवर्क विकसित किया गया था। यह इनपुट के रूप में ऑप्टिकल इमेजरी, सेंटिनल-1 सैटेलाइट रडार (एसएआर), और डिजिटल एलिवेशन मॉडल (डीईएम) डेटा लेता है, और एनकोडर के भीतर अल्पसंख्यक प्रजातियों को समर्पित कई विशेषज्ञ सबमॉडल सम्मिलित करता है। यह आत्मविश्वास-समायोजित गेटिंग का भी उपयोग करता है, जो भविष्यवाणी में विश्वास कम होने पर इन विशेषज्ञों को निर्णय देता है। लू और सहकर्मियों द्वारा रिपोर्ट किए गए परिणामों के अनुसार, समग्र सटीकता (OA) 79.46 प्रतिशत थी, ओवरलैप सटीकता (mIoU) 60.08 प्रतिशत थी, और कप्पा गुणांक 0.74 था। सदाबहार पाइन और लिंडेन जैसे कम नमूने वाले पेड़ों के मानचित्रों से गायब होने या बिखरे हुए, अलग-अलग हिस्सों में दिखाई देने की समस्या बहुत कम हो गई थी।

साइप्रस में नौ प्रमुख वृक्ष प्रजातियों को वर्गीकृत करने वाला एक अध्ययन एक और समाधान प्रस्तुत करता है। इसने ResNet50 को रीढ़ की हड्डी के रूप में इस्तेमाल किया और इसे कमजोर पर्यवेक्षित शिक्षण के साथ जोड़ा जो मॉडल द्वारा निर्दिष्ट अनंतिम लेबल के साथ प्रशिक्षण को पूरा करता है। मॉडल, जिसे आरजीबी, निकट-अवरक्त, भूभाग और मिट्टी डेटा प्राप्त हुआ, ने 90 प्रतिशत की समग्र सटीकता दर्ज की। अध्ययन में सीधे तौर पर किसी भी दावे का आकलन नहीं किया गया कि लेबलिंग लागत आधे से अधिक कम हो गई है।

संख्याएँ जो अध्ययन दर अध्ययन भिन्न होती हैं

मुकुट विभाजन और वृक्ष-प्रजाति वर्गीकरण व्यक्तिगत प्रयोगों में काफी सटीक आंकड़े उत्पन्न करते हैं, लेकिन परिणाम प्रजातियों की संरचना और सेंसर संयोजन के साथ स्पष्ट रूप से भिन्न होते हैं। विशिष्ट शंकाकार आकृतियों वाले देवदार के एकल-प्रजाति शंकुधारी जंगलों में, जैसे कि पिनस केसिया और पिनस ताएडा, YOLOv11m-Seg और चंदवा-ऊंचाई-मॉडल-आधारित विभाजन मॉडल उच्च वृक्ष-ऊंचाई अनुमान सटीकता दिखाते हैं, जिसमें व्याख्यात्मक शक्ति 0.85 से 0.93 तक होती है। उपोष्णकटिबंधीय और उष्णकटिबंधीय चौड़ी पत्ती वाले मिश्रित जंगलों में, जहां पत्तियां व्यापक रूप से फैलती हैं, शाखाएं आपस में जुड़ती हैं, और मृत शाखाएं मिश्रित होती हैं, मुकुट-चौड़ाई अनुमान के लिए व्याख्यात्मक शक्ति 0.58 और 0.68 के बीच गिरती है, तब भी जब समान YOLO परिवार या मास्क आर-सीएनएन मॉडल का उपयोग किया जाता है। किसी पेड़ का आकार नियमित है या अनियमित, यह कृत्रिम बुद्धिमत्ता की सटीकता को विभाजित करता है।

फाउंडेशन मॉडल और डोमेन-विशिष्ट मॉडल की रैंकिंग उलट भी सकती है। बड़े पैमाने पर छवि और वीडियो डेटा पर प्रशिक्षित SAM2, कई वस्तुओं की रूपरेखा को अलग कर सकता है, लेकिन ओवरलैपिंग शाखाओं वाले जंगलों में यह वानिकी डेटा पर प्रशिक्षित YOLOv11m-Seg की तुलना में अधिक गलत पहचान उत्पन्न करता है। यहां तक कि एक विशाल सामान्य प्रयोजन मॉडल भी किसी विशेष फ़ील्ड साइट के लिए फाइन-ट्यूनिंग की जगह नहीं ले सकता है।

आसमान से क्या दृश्य याद आता है

कोई फर्क नहीं पड़ता कि ड्रोन कितना सटीक उड़ाया जाता है, कुछ स्थान आकाश से अदृश्य रहते हैं। जंगल के ऊपर ऑप्टिकल कैमरों और LiDAR से सिग्नल जंगलों में मध्य और निचली परतों तक नहीं पहुंच पाते हैं जहां घने पत्ते आकाश को अवरुद्ध कर देते हैं। परिणामस्वरूप, छोटे पेड़ों को बार-बार और गलत तरीके से उनके ऊपर बड़े पेड़ों के मुकुट में समूहित किया जाता है।

गहन-शिक्षण मॉडल को प्रशिक्षित करने के लिए जमीनी सच्चाई के डेटा की आवश्यकता होती है जिसमें प्रत्येक पेड़ के लिए एक सटीक दो- या तीन-आयामी रूपरेखा तैयार की गई है। हालाँकि, घने पत्तों वाले जंगल में, अत्यधिक अनुभवी क्षेत्र विशेषज्ञ भी इस बात पर असहमत हैं कि एक पेड़ का मुकुट कहाँ समाप्त होता है। निर्णय में यह अंतर एनोटेशन शोर के रूप में बना रहता है और मॉडल प्रशिक्षण में प्रवेश करता है। इसलिए सटीक जमीनी सच्चाई डेटा बनाना एल्गोरिदम को डिजाइन करने जितना ही श्रम-गहन है।

क्षेत्र बदलने पर सटीकता भी गिर जाती है। यहां तक कि एक पेड़-प्रजाति वर्गीकरण मॉडल जो एक जंगल में उच्च स्कोर करता है, वह अलग-अलग इलाके, सूरज की रोशनी और प्रजातियों की संरचना के साथ दूसरे जंगल में खराब प्रदर्शन कर सकता है। गिरावट का आकार डेटा और मूल्यांकन मीट्रिक के अनुसार भिन्न होता है और इसे किसी एक सीमा तक कम नहीं किया जा सकता है।

अगले चरण के लिए कार्य

इन कमियों को दूर करने के प्रयास शुरू हो चुके हैं। हाइब्रिड फाइन-ट्यूनिंग अध्ययन यूएवी-लीडार द्वारा बनाए गए त्रि-आयामी चंदवा ऊंचाई मॉडल से जानकारी स्तरित करके वानिकी डेटा पर शून्य-शॉट फाउंडेशन मॉडल एसएम 2 को फिर से प्रशिक्षित कर रहे हैं। इसका उद्देश्य एक ही समय में व्यापकता और सटीकता प्राप्त करना है। अनुसंधान आवृत्ति-घटक अपघटन, कंट्रास्टिव लर्निंग और गेटिंग एल्गोरिदम को भी परिष्कृत कर रहा है जो दुर्लभ प्रजातियों की स्वचालित पहचान में सुधार करने के लिए एम-मोनेट और एफएससी-मास्क2फॉर्मर जैसे कई विशेषज्ञ उपमॉडल को जोड़ता है।

क्राउन-बीईआरटी, वांग ज़िनबो और उनके सहयोगियों द्वारा विकसित और मई 2026 में जीआईएससाइंस एंड रिमोट सेंसिंग में प्रकाशित, इस दिशा का एक हालिया उदाहरण है। यह गतिशील क्राउन मास्किंग जोड़ता है, जो क्राउन आकार में अंतर को दर्शाता है और केवल वैध क्राउन क्षेत्रों का चयन करता है, और क्राउन पोजिशनल एन्कोडिंग, जो क्राउन के भीतर स्थान की जानकारी एम्बेड करता है। इसके बाद यह एक स्व-पर्यवेक्षित शिक्षण चरण सम्मिलित करता है जो बिना लेबल वाले क्राउन नमूनों के साथ मॉडल को पूर्व-प्रशिक्षित कर सकता है। यह दृष्टिकोण कुछ जमीनी सच्चाई वाले लेबल वाली दुर्लभ प्रजातियों के लिए भी उपयोगी सुविधाएँ निकालने का प्रयास करता है।

ट्रीसैटएआई, प्योरफॉरेस्ट और फॉरइंस्टेंस जैसे कई पारिस्थितिक तंत्रों में फैले तीन- और दो-आयामी व्यक्तिगत-ट्री बेंचमार्क डेटासेट का विस्तार और साझा करने के लिए काम जारी रहना चाहिए। ऐसे समय में जब मॉडल का प्रदर्शन महाद्वीप और वृक्ष प्रजातियों के आधार पर बहुत भिन्न होता है, डेटासेट का विस्तार करना एल्गोरिदम को परिष्कृत करने जितना ही महत्वपूर्ण है।

स्रोत और संदर्भ

1. Aldaeri, A. S. T. M., Kit, C. Y., Ting, L. S., & Abdul Rahman, M. R. B. (2026). Deep learning for tree crown detection and delineation using UAV and high-resolution imagery for biometric parameter extraction: a systematic review. *Forests*, 17(2), 179. <https://doi.org/10.3390/f17020179>
2. Bansal, H., Sinha, A., Agarwal, G., Mishra, S. K., Gupta, S., Chaudhary, P., Ashokrao, P. R., Kushwaha, A., Bagaria, M. K., Reza, M. S., Agrawal, A., Bhad, S., Khalid, S., Lasisi, A., & Aseere, A. M. (2025). A hybrid DL with Battle Royal Optimisation algorithm for accurate tree counting using satellite images. *International Journal of Computational Intelligence Systems*, 18(1), Article 222. <https://doi.org/10.1007/s44196-025-00928-y>
3. Forkuo, G. O., Picchio, R., Proto, A. R., & Borz, S. A. (2026). Applications of artificial intelligence in forest operations engineering research: A systematic review. *Current Forestry Reports*, 12, Article 14. <https://doi.org/10.1007/s40725-026-00275-x>
4. Komatsu, K., Takeshige, R., Onishi, M., Fujiki, S., Imai, N., Miyamoto, K., Aiba, S., Kitayama, K., Tsen, S. T. L., Nilus, R., Dawat, J., Pereira, J., Onoda, Y., & Aoyagi, R. (2026). Quantifying carbon stock and tree community

- composition in tropical forests through combining satellite and UAV analyses. *Scientific Reports*, 16, Article 5442. <https://doi.org/10.1038/s41598-025-34938-9>
5. Lou, T., Wang, Z., Zhang, W., Li, C., Gu, J., Zou, W., & Jing, W. (2026). Dominant tree species classification using a sparse mixture-of-experts framework. *Forest Engineering*, 42(3), 637-648. <https://doi.org/10.7525/j.issn.1006-8023.2026.03.019>
6. Nguyen Thanh Tuan, Phan Van Tuan, Nguyen Thanh Hung, & Duong Tien Duc. (2026). Individual tree detection and crown segmentation for *Pinus kesiya* using UAV-LiDAR and deep learning models. *Dendrobiology*, 95, 156-169. <https://doi.org/10.12657/denbio.095.011>
7. Qin, T., & Zhao, Q. (2025). Multi-branch and multi-label tree species classification using deep learning for UAV aerial photography and Sentinel remote sensing images. *Scientific Reports*, 15, Article 32710. <https://doi.org/10.1038/s41598-025-19827-5>
8. Takhtkeshha, N., Bocaux, L., Ruoppa, L., Remondino, F., Mandlbürger, G., Kukko, A., & Hyypä, J. (2025). 3D forest semantic segmentation using multispectral LiDAR and 3D deep learning. *PFG - Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 94(3), 377-397. <https://doi.org/10.1007/s41064-025-00369-4>
9. Wang, L., Zhang, H., Fu, R., Lei, K., Liu, Y., Yang, T., Zhang, J., & Ge, X. (2026). MTSCFNet: a novel framework for improving tree species classification in a subtropical forest using RGB, LiDAR-derived, and GF-2 data. *Journal of Forestry Research*, 37(1), Article 22. <https://doi.org/10.1007/s11676-025-01964-2>
10. Wang, M., Zhang, Q., Liu, X., Zhang, J., Yu, F., Zhang, X., & Zhao, R. (2026). Research progress on multimodal data fusion in forest resource monitoring. *Frontiers in Plant Science*, 16, Article 1710618. <https://doi.org/10.3389/fpls.2025.1710618>
11. Wang, X., Zhao, Y., Han, Y., Zhao, Y., & Zhen, Z. (2026). Crown-BERT: a crown-morphology-aware deep learning framework for individual tree species classification using UAV LiDAR and hyperspectral data. *GIScience & Remote Sensing*, 63(1), Article 2671600. <https://doi.org/10.1080/15481603.2026.2671600>
12. Yang, Z., Zhang, X., et al. (2026). 融合频域感知与对比学习的无人机影像森林全要素解译方法 : FSC-Mask2Former [FSC-Mask2Former: a forest panoptic segmentation method fusing frequency domain perception and contrastive learning]. *National Remote Sensing Bulletin*. <http://www.publish.founderss.cn/rc-pub/front/front-article/download?id=158241355&attachType=lowqualitypdf&siteId=91> (accessed August 2, 2026)
13. Digital Times. (September 24, 2025). Using advanced technologies including AI and LiDAR...halting the spread of pine wilt disease. <https://www.dt.co.kr/article/12019894> (accessed August 2, 2026)

2.2

भूमि-ऊपरी बायोमास (AGB) और वन कार्बन भंडार का अनुमान

किसी पेड़ के सूखे वजन को सीधे निर्धारित करने के लिए, एक व्यक्ति को एक आरी उठानी होगी, आधार को काटना होगा और पेड़ को गिराना होगा, शाखाओं, तने और पत्तियों को अलग करना होगा, उनका वजन करना होगा और नमी को भट्टी में डालना होगा। ऐसे विनाशकारी प्रत्यक्ष मापों का उपयोग एलोमेट्रिक समीकरणों के निर्माण के लिए संदर्भ मान प्राप्त करने के लिए किया गया था। पूरे जंगल के बायोमास का अनुमान लंबे समय से छाती की ऊंचाई पर व्यास, पेड़ की ऊंचाई और लकड़ी के घनत्व के आधार पर एलोमेट्रिक समीकरणों के साथ लगाया गया है। इन समीकरणों ने संरक्षित क्षेत्रों में पेड़ों को काटे बिना वजन की गणना करना संभव बना दिया, लेकिन त्रुटियां तब बढ़ीं जब क्षेत्र और प्रजातियां उन प्रजातियों से भिन्न हो गईं जिनके लिए एक समीकरण विकसित किया गया था।

एक कारण था कि लोग एक पेड़ का वजन जानना चाहते थे। लकड़ियाँ बाजार में लाने और उनकी कीमत तय करने के लिए, उन्हें मात्रा और वजन जानने की जरूरत थी, और कटाई और माप लंबे समय तक अविभाज्य रहे। फिर भी बिना पेड़ काटे वजन का अनुमान लगाने का एक तरीका है। यह ट्रंक की मोटाई और ऊंचाई को मापने और प्रजातियों के लिए निर्धारित समीकरण के माध्यम से उन मूल्यों को पारित करने के लिए पर्याप्त है।

किसी व्यक्ति की छाती की ऊंचाई पर मापे गए तने के व्यास को स्तन की ऊंचाई पर व्यास (डीबीएच) कहा जाता है। एक एलोमेट्रिक मॉडल पेड़ की ऊंचाई, लकड़ी के घनत्व और प्रजातियों- और क्षेत्र-विशिष्ट गुणों के साथ डीबीएच दर्ज करके एक पेड़ की मात्रा और वजन का अनुमान लगाता है। व्यास और ऊंचाई के बीच का संबंध विकासात्मक चरण और पर्यावरण के साथ बदलता है और स्थिर अनुपात में तय नहीं होता है। एक बढ़ते पेड़ के तने और शाखाओं में जमा हुए कार्बन का अनुमान लगाने के लिए गणना में इन त्रुटियों को शामिल करने की आवश्यकता होती है। भूमिगत बायोमास (एजीबी) की सटीकता सीधे राष्ट्रीय कार्बन खातों और कार्बन-बाजार के आंकड़ों को प्रभावित करती है।

डीबीएच और पेड़ की ऊंचाई को हाथ से मापना कोई आसान काम नहीं है। एक सर्वेक्षक एक टेप के साथ तने की परिधि को मापता है, हिप्सोमीटर नामक कोण-मापने वाले उपकरण के साथ पेड़ के शीर्ष को देखता है, फिर त्रिकोणमिति द्वारा ऊंचाई की गणना करता है। इस प्रक्रिया में प्रति पेड़ कई मिनट लगते हैं। पूरे जंगल को मापने के लिए कई सर्वेक्षणकर्ताओं को कई दिनों तक, कभी-कभी हफ्तों तक काम करने की आवश्यकता होती है। त्रुटि भी प्रवेश करती है, क्योंकि लोग यह तय करने में भिन्न होते हैं कि कोई तना कहाँ से शुरू होता है और कहाँ समाप्त होता है। हाल के वर्षों में, वन सर्वेक्षणों में गुरुत्वाकर्षण का केंद्र मापने वाले टेपों से लेजर और कैमरों पर और सर्वेक्षणकर्ताओं के दो पैरों से ड्रोन और कृत्रिम उपग्रहों पर स्थानांतरित हो गया है।

ग्राउंड लेजर और ड्रोन पेड़ों को कैसे पढ़ते हैं

एक स्थलीय लेजर स्कैनर (टीएलएस) एक पेड़ का चक्कर लगाता है, प्रकाश की अनगिनत दालों का उत्सर्जन करता है, और उनके वापस लौटने में लगने वाले समय को मापता है, जिससे लाखों बिंदुओं से बना एक त्रि-आयामी मानचित्र तैयार होता है। बिंदुओं के इस संग्रह को बिंदु बादल कहा जाता है। मल्टीपल-स्कैन विधि स्कैनर को कई स्थानों पर ले जाती है और बिना किसी चूक के एक पेड़ के पिछले हिस्से को भी पकड़ लेती है, लेकिन स्कैनर को स्थानांतरित करने और स्कैन को एक स्थान पर पंजीकृत करने में काफी समय लगता है। यदि सैकड़ों पेड़ों का सर्वेक्षण करना हो तो यह कार्य एक दिन में पूरा करना कठिन है। इसके विपरीत, एकल-स्कैन विधि एक ही स्थान पर होती है और केवल एक बार स्कैन करती है, मिनटों में समाप्त हो जाती है, लेकिन अन्य ट्रंक और शाखाएं एक पेड़ के पीछे को घेर लेती हैं और बिंदु डेटा में विरल अंतराल छोड़ देती हैं।

संयुक्त राज्य अमेरिका के इंडियाना में मार्टेल फ़ॉरेस्ट में, शोधकर्ताओं ने 37 पेड़ प्रजातियों वाले समशीतोष्ण चौड़ी पत्ती वाले जंगल में सिंगल-स्कैन टीएलएस को CoAtNet के साथ जोड़ा। जमीनी सच्चाई के मूल्यों की गणना सामान्य उत्तरी अमेरिकी एलोमेट्रिक समीकरणों में क्षेत्र-मापा डीबीएच दर्ज करके की गई थी। 60 परीक्षण वृक्षों में, निर्धारण का गुणांक 0.73 था। माध्य प्रतिशत पूर्वाग्रह 0.99 प्रतिशत था, लेकिन माध्य निरपेक्ष प्रतिशत त्रुटि 25.06 प्रतिशत थी और माध्य निरपेक्ष प्रतिशत त्रुटि 29.40 प्रतिशत थी। एक छोटे पूर्वाग्रह को इस अर्थ में नहीं पढ़ा जाना चाहिए कि प्रत्येक पेड़ के लिए त्रुटि एक प्रतिशत से कम थी।

आसमान से नीचे देखने का भी एक तरीका होता है।

ड्रोन तस्वीरों को एक साथ जोड़कर और उनकी विकृति को ठीक करके बनाए गए मानचित्र को ऑर्थोफोटो कहा जाता है। क्योंकि इसे उपग्रह छवि की तुलना में बहुत करीब से लिया गया है, प्रत्येक शाखा स्पष्ट रूप से दिखाई देती है। सबा, मलेशिया के डेरामाकोट और तांगकुलप उष्णकटिबंधीय वर्षावनों में, शोधकर्ताओं ने डिप्टेरोकार्पेसी पेड़ों के मुकुट, शाखाओं और पत्तियों से बने छतरी जैसे पेड़ के शीर्ष को पहचानने के लिए ड्रोन द्वारा कैप्चर किए गए आरजीबी ऑर्थोफोटो को एफिशिएंटनेट-बी 4 नामक एक गहन-शिक्षण मॉडल के साथ जोड़ा, फिर कार्बन का अनुमान लगाने के लिए उष्णकटिबंधीय-वन एलोमेट्रिक समीकरणों को लागू किया। एक बेसलाइन मॉडल अकेले उपग्रह इमेजरी के साथ चलता है और कोई भी फ़िल्ड नमूना 0.43 की व्याख्यात्मक शक्ति पर नहीं रहता है। एक मॉडल जिसने ड्रोन-कैप्चर की गई मुकुट-संरचना जानकारी को जोड़ा, व्याख्यात्मक शक्ति को 0.51 तक बढ़ा दिया और त्रुटि को 70.6 टन से घटाकर लगभग 60.5 टन प्रति हेक्टेयर कर दिया।

इसी तरह का प्रयास यूरोपीय बीच (फागस सिल्वेटिका) के जंगलों में किया गया था। शोधकर्ताओं ने यूएवी लेजर स्कैनिंग के साथ त्रि-आयामी क्राउन वॉल्यूम को मापा और अकेले डीबीएच के आधार पर मौजूदा गणना में मूल्य जोड़ा, जिससे बायोमास-अनुमान त्रुटि में उल्लेखनीय कमी आई। क्योंकि क्राउन-वॉल्यूम जानकारी को एक समीकरण में जोड़ा गया था जो पहले केवल स्टेम व्यास पर विचार करता था, सुधार स्वाभाविक प्रतीत होता है।

हालाँकि, एलोमेट्रिक समीकरण में स्वयं कमजोरियाँ हैं। उत्तरी अमेरिका या सभी उष्णकटिबंधीय जंगलों में उपयोग के लिए बनाए गए सामान्य-उद्देश्यीय फ़ॉर्मूले किसी विशिष्ट क्षेत्र में मिट्टी की उर्वरता, स्थानीय जलवायु,

या एक ही प्रजाति के भीतर भी बढ़ती जगहों पर पेड़ का रूप कैसे भिन्न होता है, इसे पूरी तरह से पकड़ नहीं सकते हैं। यहां तक कि एक ही स्प्रूस प्रजाति के भीतर, बरसाती पहाड़ी पर उगने वाले पेड़ और सूखी पहाड़ी पर उगने वाले पेड़ का व्यास एक ही हो सकता है, लेकिन उनके आंतरिक भाग कितनी मजबूती से भरे हुए हैं, यानी लकड़ी के घनत्व में भिन्न होता है। यह एक व्यवस्थित पूर्वाग्रह, क्षेत्र के अनुसार लगातार एक दिशा में झुकाव वाली त्रुटि उत्पन्न कर सकता है। सौभाग्य से, एक बार सटीक रूप से मापा गया स्थानीय एलोमेट्रिक डेटा जमा हो जाने पर इस पूर्वाग्रह को ठीक करने के लिए एक पर्यवेक्षित गहन-शिक्षण मॉडल को फिर से प्रशिक्षित किया जा सकता है। यह दृष्टिकोण शुरुआत से ही एक आदर्श फॉर्मूला खोजने की तुलना में लगातार डेटा एकत्र करने और मॉडल को सही करने के करीब है।

राष्ट्रीय वन सूची को सैटेलाइट डेटा से जोड़ना

लेज़रों और ड्रोनों से अलग-अलग पेड़ों को सटीक रूप से मापने के लिए तकनीक में चाहे कितना भी सुधार हो जाए, यह किसी देश के प्रत्येक पेड़ का इस तरह से सर्वेक्षण नहीं कर सकता है। जिस देश में जंगल जितने बड़े होंगे, उतनी ही आसानी से पेड़ों की संख्या करोड़ों में पहुंच जाएगी। एक ड्रोन एक दिन में केवल एक सीमित क्षेत्र का निरीक्षण कर सकता है, लेकिन एक कृत्रिम उपग्रह उस सीमा को तुरंत पार कर जाता है। पेड़ दर पेड़ मापे गए मूल्यों या कुछ नमूना भूखंडों के डेटा को राष्ट्रव्यापी मानचित्र में विस्तारित करने के लिए एक अलग दृष्टिकोण की आवश्यकता होती है: जमीन से मापे गए राष्ट्रीय वन सूची (एनएफआई) डेटा को कृत्रिम-उपग्रह रिमोट-सेंसिंग डेटा के साथ जोड़ना जो कृत्रिम बुद्धि का उपयोग करके एक नज़र में व्यापक क्षेत्रों का सर्वेक्षण करता है।

संयुक्त राज्य अमेरिका के कनेक्टिकट में समशीतोष्ण मिश्रित वनों में, शोधकर्ताओं ने अमेरिकी वन सेवा की राष्ट्रीय वन सूची में 142 नमूना भूखंडों के डेटा को सेंटिनल -1 रडार सिग्नल, सेंटिनल -2 और लैंडसैट उपग्रहों द्वारा पत्तियों के हरे परावर्तन से प्राप्त एनडीवीआई जैसे वनस्पति सूचकांक, और अंतरिक्ष-जनित लेजर अल्टीमीटर जीईडीआई से पेड़-ऊंचाई डेटा के साथ ओवरले करके 10-मीटर रिज़ॉल्यूशन पर एक बायोमास मानचित्र बनाया। कई मशीन-लर्निंग विधियों का परीक्षण करने के बाद, जब GEDI-मापी गई पेड़ की ऊंचाई और सेंटिनल वनस्पति सूचकांक एक साथ दर्ज किए गए तो सटीकता सबसे अधिक थी। जंगलों के बाहर के क्षेत्रों को शून्य का बायोमास मान दिया गया और फ़िल्टर किया गया, जिससे नमूने में शोर कम हो गया।

रूस के सखालिन द्वीप पर प्रबंधित जंगलों में, शोधकर्ताओं ने एनएफआई स्टैंड-सबकम्पार्टमेंट सर्वेक्षण डेटा के साथ सेंटिनल -2 उपग्रह इमेजरी और इलाके डेटा में समय-श्रृंखला परिवर्तन को जोड़ा, फिर यादृच्छिक वन, एक्सजीबूस्ट और टैबनेट की तुलना की। XGBoost ने सर्वोत्तम प्रदर्शन किया।

यह एल्गोरिदम निर्णय वृक्षों के अनुक्रम को जोड़ता है, प्रत्येक शाखा-जैसे प्रश्नों के माध्यम से एक उत्तर को सीमित करता है, जबकि प्रत्येक बाद वाला वृक्ष पिछले वाले द्वारा छूटी गई त्रुटि को कम करता है। औसत पूर्ण प्रतिशत त्रुटि, या एमएपीई, पेड़ की ऊंचाई का अनुमान लगाने के लिए 0.18 और कार्बन स्टॉक का अनुमान लगाने के लिए 0.37 थी, जबकि समग्र व्याख्यात्मक शक्ति 0.68 थी।

चीन के हेइलोंगजियांग प्रांत में प्राकृतिक वनों का अध्ययन बहुत लंबे समय के अक्ष को कवर करता है। इसने 1976 से 2015 तक एनएफआई स्थायी-नमूना-प्लॉट डेटा के नौ दौर इकट्ठे किए। शोधकर्ताओं ने

अतीत और भविष्य के जलवायु और कार्बन-डाइऑक्साइड एकाग्रता डेटा को शामिल किया और ज्ञान-निर्देशित मशीन लर्निंग (केजीएमएल) नामक एक ढांचा बनाया। यह दो चरणों वाली संरचना है। सबसे पहले, एक वन कार्बन-पृथक्करण मॉडल, जो समीकरणों में पेड़ों की पारिस्थितिक विकास प्रक्रिया को व्यक्त करता है, को कार्बन-डाइऑक्साइड निषेचन प्रभाव को प्रतिबिंबित करने के लिए परिष्कृत किया जाता है। इस मॉडल द्वारा गणना किए गए मानों को पूर्व सूचना के रूप में XGBoost को भेज दिया जाता है। पारिस्थितिक ज्ञान जोड़ने से कार्बन-घनत्व पूर्वानुमानों की व्याख्यात्मक शक्ति 0.85 से बढ़कर 0.90 से ऊपर हो गई। कार्बन उत्सर्जन को सक्रिय रूप से दबाने वाले कम-उत्सर्जन परिदृश्य के तहत, हेइलॉंगजियांग के प्राकृतिक जंगलों में कार्बन स्टॉक 2060 में 1,379.26 से 1,439.02 टेराग्राम तक होने का अनुमान लगाया गया था। क्योंकि पारिस्थितिक नियम पहले से ही अंतर्निहित थे, तब भी जब मॉडल ने अपने प्रशिक्षण डेटा की सीमा के बाहर भविष्य की भविष्यवाणी की थी, तब भी मूल्य अविश्वसनीय स्तर तक नहीं पहुंचे। एक साधारण ब्लैक-बॉक्स मशीन-लर्निंग मॉडल उन चरम जलवायु परिस्थितियों में आसानी से निरर्थक मूल्यों का उत्पादन कर सकता है जो उसने कभी नहीं देखी हैं, क्योंकि एक बार जब वह अपने प्रशिक्षण डेटा में मौजूद पैटर्न को छोड़ देता है, तो उसे नहीं पता होता है कि उत्तर के लिए किस आधार का उपयोग करना है।

एक अन्य अध्ययन में रोमानियाई क्षेत्र डेटा से निर्मित मॉडल में फिनिश नेशनल फॉरेस्ट इन्वेंटरी नमूने और सेंटिनल -2 समय श्रृंखला को जोड़ा गया। फिनिश ग्रीडिंग-स्टॉक वॉल्यूम पूर्वानुमानों की व्याख्यात्मक शक्ति 0.483 से बढ़कर 0.718 हो गई। इसका विषय कार्बन मानचित्र नहीं था, बल्कि पेड़ की ऊँचाई, बेसल क्षेत्र और आयतन जैसी विशेषताएँ थीं। तंजानिया के एक अध्ययन में 2014 के वन और वुडलैंड क्षेत्र को शुरुआती बिंदु के रूप में इस्तेमाल किया गया और 2054 तक तीन परिदृश्यों की गणना की गई: मौजूदा रुझानों की निरंतरता, टिकाऊ प्रबंधन और बढ़ा हुआ विकास दबाव।

कनेक्टिकट से सखालिन और हेइलॉंगजियांग से फ़िनलैंड तक फैले ये अध्ययन एक सामान्य तस्वीर दिखाते हैं। ग्राउंड सैंपल-प्लॉट डेटा जितना अधिक प्रचुर और विविध होगा, और जितने अधिक प्रकार के सैटेलाइट सेंसर डेटा को ओवरलैप किया जाएगा, व्यापक क्षेत्र का नक्शा उतना ही सटीक हो जाएगा।

संख्याएँ भिन्न क्यों होती हैं?

शोध के आँकड़ों को सावधानी के साथ साथ-साथ रखा जाना चाहिए। एक व्यक्तिगत पेड़ का वजन, स्टैंड की मात्रा और प्रति हेक्टेयर बायोमास अलग-अलग लक्ष्य चर हैं, और आर² डेटा रेंज और सत्यापन विधि के साथ बदलता है। एनएफआई नमूना-प्लॉट निर्देशांक में त्रुटियाँ चंदवा, इलाके, रिसीवर और सुधार विधि पर निर्भर करती हैं। कुछ सार्वजनिक डेटा निजी संपत्ति की सुरक्षा के लिए जानबूझकर निर्देशांक को धुंधला कर देते हैं। एक उपग्रह पिक्सेल में बड़े पेड़, पौधे और खाली जमीन एक साथ होती है, जो नज़दीकी सीमा पर मापे गए व्यक्तिगत-वृक्ष मूल्यों और पिक्सेल औसत के बीच एक अंतर पैदा करती है।

ऑप्टिकल और रडार उपग्रहों के बीच रैंकिंग भी उलट जाती है। उच्च-बायोमास जंगलों में ऑप्टिकल और लघु-तरंग दैर्ध्य रडार सिग्नल जल्दी से संतृप्त हो सकते हैं। संतृप्ति बिंदु वन संरचना, नमी, ध्रुवीकरण, घटना कोण और प्रतिगमन मॉडल के साथ भिन्न होता है, इसलिए एक सीमा तय करना मुश्किल है। घने जंगलों की संरचना को पढ़ने में लंबी-तरंग दैर्ध्य रडार और LiDAR अपेक्षाकृत लाभप्रद हैं। क्योंकि GEDI

तरंगरूप LiDAR है, इसे रडार बैकस्केटर के समान संतृप्ति मानदंड के तहत समूहीकृत नहीं किया गया है। सेंसरों के बीच अंतर के कारण कार्बन क्रेडिट जैसी धन संबंधी गणनाओं में संवेदनशील परिणाम होते हैं।

समस्याएँ पीछे छूट गई, और अगला चरण

तकनीकी सीमाएँ बनी हुई हैं। एनएफआई और उपग्रह अवलोकनों के अलग-अलग चक्र होते हैं और इसलिए अलग-अलग दिनों में एक ही जंगल को मापते हैं। कई देशों में सार्वजनिक एनएफआई डेटा निजी संपत्ति की सुरक्षा के लिए वास्तविक निर्देशांक को धुंधला कर सकता है, जिससे उच्च-रिज़ॉल्यूशन पिक्सेल के साथ मिलान करने पर त्रुटियाँ उत्पन्न हो सकती हैं। एलोमेट्रिक समीकरणों के साथ बनाए गए बायोमास संदर्भ मूल्यों में समीकरण की पसंद से उत्पन्न होने वाली अनिश्चितता भी होती है। दूर से संवेदित एजीबी मानचित्र को जंगल में कार्बन की कुल मात्रा के रूप में नहीं माना जाना चाहिए। एक राष्ट्रीय ग्रीनहाउस-गैस सूची अलग-अलग कार्बन पूल के रूप में नीचे के बायोमास, डेडवुड, कूड़े और मिट्टी की गणना कर सकती है।

भविष्य के काम में ज्ञान-निर्देशित मशीन लर्निंग का परीक्षण किया जाना चाहिए, जो व्यापक क्षेत्रों में तंत्रिका नेटवर्क के अंदर विकास समीकरण और कार्बन-चक्र मॉडल रखता है। GEDI और ICESat-2 जैसे स्वतंत्र अंतरिक्ष जनित LiDAR मिशनों से प्राप्त वृक्ष-ऊँचाई डेटा की तुलना NFI डेटा के साथ भी की जा सकती है। केवल जब कृत्रिम बुद्धिमत्ता रिपोर्ट अनुमानों और अनिश्चितताओं को साथ-साथ रखती है, तो इसका आउटपुट राष्ट्रीय ग्रीनहाउस-गैस सूची में उपयोग के लिए उपयुक्त कार्बन मानचित्र तक पहुंच सकता है।

स्रोत और संदर्भ

1. Geng, L., Bian, S., Ma, X., Fu, Q., Zhou, Y., & Wang, B. (2026). Prediction of carbon sequestration potential in Heilongjiang Province's natural forests based on the KGML model. *Forest Engineering*. Online first. <https://slgc.nefu.edu.cn/EN/abstract/abstract2592.shtml>
2. Jung, M., Choi, J., Carpenter, J., Fei, S., & Jung, J. (2025). Individual tree biomass estimation using single-scan terrestrial laser scanner with efficient projection-based deep learning. *Journal of Forestry*. <https://doi.org/10.1007/s44392-025-00065-6>
3. Keskes, M. I., & Nita, M. D. (2026). Digital twins in forest management using scalable deep learning pipeline. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 19, 8519-8547. <https://doi.org/10.1109/JSTARS.2026.3666924>
4. Khanal, S., Nolan, R., Medlyn, B., & Boer, M. (2025). Spatially explicit prediction of Nepal's forest biomass stocks, a data-driven bioregionalisation and machine learning approach. *Carbon Balance and Management*, 21(1), Article 23. <https://doi.org/10.1186/s13021-025-00367-4>
5. Lamahewage, S. H. G., Witharana, C., Riemann, R., Fahey, R., & Worthley, T. (2025). Aboveground biomass estimation using multimodal remote sensing observations and machine learning in mixed temperate forest. *Scientific Reports*, 15, Article 31120. <https://doi.org/10.1038/s41598-025-15585-6>
6. Liu, J., Liu, M., Shen, T., Yan, F., & Zhou, Z. (2025). Forest aboveground biomass estimation using high-resolution imagery and integrated machine learning. *Forests*, 16(12), Article 1777. <https://doi.org/10.3390/f16121777>
7. Obata, S., Cieszewski, C. J., Lowe, R. C., & Bettinger, P. (2021). Random forest regression model for estimation of the growing stock volumes in Georgia, USA, using dense Landsat time series and FIA dataset. *Remote Sensing*, 13(2), Article 218. <https://doi.org/10.3390/rs13020218>

8. Puletti, N., Innocenti, S., Guasti, M., Alvites, C., & Ferrara, C. (2025). Improving aboveground biomass estimation in beech forests with 3D tree crown parameters derived from UAV-LS. *Remote Sensing*, 17(9), Article 1497. <https://doi.org/10.3390/rs17091497>
9. Subedi, P., & Zurqani, H. (2026). Multi-sensor forest aboveground biomass estimation using GEDI, machine learning, and deep learning techniques. *Advances in Space Research*, 77(3), 2784-2806. <https://doi.org/10.1016/j.asr.2025.12.032>
10. Tasuev, U., Tregubova, P., Illarionova, S., Shadrin, D., Bernshteyn, A., & Burnaev, E. (2026). Machine learning-based geospatial assessment of forest structure characteristics and sequestration potential for informed carbon stocks inventories. *Scientific Reports*, 16, Article 20872. <https://doi.org/10.1038/s41598-026-50929-w>
11. Uyar, N. (2026). Tropical forest biomass assessment using LIDAR, DEM, and Sentinel-2 in the Daintree forest. *Plant Ecology*, 227(4), Article 42. <https://doi.org/10.1007/s11258-026-01602-9>
12. Wan, L., et al. (2025). Satellite-based mapping of annual canopy height and aboveground biomass in African dense forests. *Frontiers in Remote Sensing*, 6, Article 1724950. <https://doi.org/10.3389/frsen.2025.1724950>
13. Wang, G., Zhao, L., Song, C., Zhang, W., Dong, W., & Ji, Y. (2026). Improving forest aboveground biomass estimation accuracy via optical and SAR data fusion using deep learning algorithms. *Remote Sensing*, 18(10), Article 1536. <https://doi.org/10.3390/rs18101536>

2.3

वन मृदा की गतिशीलता और भूमि-आवरण परिवर्तन की निगरानी

यह तीन दिनों की भारी बारिश के बाद था। गैंगवॉन प्रांत में कहीं कटाई वाली जगह पर, पेड़ों की ढलान ने बारिश को सीधे अपनी नंगी त्वचा पर ले लिया था। कटी हुई ढलान से नीचे बहने वाली मिट्टी लाल थी, जो मौसम के कारण विघटित ग्रेनाइट का विशिष्ट रंग था। रबर के जूते पहने एक शोधकर्ता गंदे पानी के सामने झुक गया और मुट्ठी भर मिट्टी पकड़ ली। केवल उंगलियों के बीच फिसलने की अनुभूति से, शोधकर्ता मोटे तौर पर अनुमान लगा सकता है कि मिट्टी ने कितना कार्बनिक पदार्थ खो दिया है और अगली बारिश में कितना और बह जाएगा। कुछ कदमों की दूरी पर, एक ढलान पर जहां जड़ें अभी भी टिकी हुई थीं, मिट्टी अधिक गहरी और मजबूत थी। यहां तक कि एक ही पहाड़ पर भी पेड़ों की मौजूदगी के आधार पर मिट्टी की स्थिति में काफी अंतर होता है। लेकिन स्पर्श की अनुभूति इस पूरे ढलान का वर्णन नहीं कर सकती, कटाई वाली जगह से परे पूरे पहाड़ का तो बिल्कुल भी वर्णन नहीं कर सकती। मुट्ठी भर मिट्टी हमेशा अपर्याप्त होती है। यही कारण है कि सेंसर और उपग्रह जो एक ही समय में जमीन के नीचे और पहाड़ से परे पढ़ते हैं, और कृत्रिम बुद्धिमत्ता जो उन्हें जोड़ती है, जंगल-मिट्टी अवलोकन के केंद्र में चले गए हैं।

भूमिगत सेंसर और आकाश में आँखों द्वारा नमी को एक साथ पढ़ा जाता है

मिट्टी की नमी और कार्बनिक पदार्थ, तापमान और सापेक्ष आर्द्रता, और कार्बन-डाइऑक्साइड सांद्रता यह निर्धारित करती है कि पेड़ कितनी अच्छी तरह बढ़ते हैं, वे पानी का कितनी कुशलता से उपयोग करते हैं, और कितना कार्बन बरकरार रखते हैं। अतीत में, एकमात्र तरीका निर्धारित तिथियों पर क्षेत्र में प्रवेश करना और नमूने एकत्र करना था, या एक ही उपकरण स्थापित करना और केवल उसके द्वारा पढ़े गए नंबरों को देखना था। जब एक विस्तृत पहाड़ को इस तरह पढ़ा जाता है, तो एक पेड़ की छाया के नीचे या एक घाटी के भीतर की स्थितियाँ आसानी से छूट जाती हैं। आज, दृष्टिकोण बदल रहा है: कई इंटरनेट ऑफ थिंग्स (IoT) सेंसर जमीन में लगाए जाते हैं, उनके सिग्नल लोरा, एक कम-शक्ति वाले वाइड-एरिया नेटवर्क से जुड़े होते हैं, और परिणाम ड्रोन और उपग्रहों द्वारा कैप्चर की गई छवियों के साथ पढ़े जाते हैं।

एक अध्ययन में अल्फाल्फा जड़ों के आसपास मिट्टी की नमी का अनुमान लगाने के लिए गहन शिक्षण के साथ-साथ ड्रोन से प्राप्त मल्टीस्पेक्ट्रल, थर्मल-इन्फ्रारेड और सामान्य तस्वीरों का विश्लेषण किया गया। यिन एट अल द्वारा प्रकाशित। (2024) यूरोपियन जर्नल ऑफ एग्रोनॉमी में, अध्ययन से पता चला कि कई सेंसरों को संयोजित करने वाले मॉडल में एकल-सेंसर मॉडल की तुलना में स्पष्ट रूप से छोटी त्रुटि थी। दूसरे शब्दों में, जड़ों के आसपास पानी की स्थिति, जिसे केवल दृश्य रंग से नहीं जाना जा सकता था, कई तरंग दैर्ध्य के ओवरलैप होने पर उभरी।

गेहूं आधारित कृषि वानिकी फार्मों की समीक्षा इसी निष्कर्ष पर पहुंचती है। सिंह एट अल द्वारा प्रकाशित। (2026) इंटरनेशनल जर्नल ऑफ एनवायरनमेंट, एग्रीकल्चर एंड बायोटेक्नोलॉजी (आईजेईएबी) में, यह बताया गया है कि भूमिगत नमी सेंसर और उपग्रह-व्युत्पन्न भूमि सतह जल सूचकांक (एलएसडब्ल्यूआई) और तापमान वनस्पति सूखापन सूचकांक (टीवीडीआई) के साथ पेड़ों की छाया की चौड़ाई को नियंत्रित करने के लिए क्राउन प्रबंधन का संयोजन अग्रिम चेतावनी दे सकता है कि पेड़ और गेहूं कब पानी के लिए प्रतिस्पर्धा करना शुरू कर देंगे। प्रतियोगिता शुरू होने से पहले उसका पता लगाने से पानी बचाने की गुंजाइश बनती है।

बिजली के गुणों के माध्यम से नमी को मापने के लिए पेड़ के तनों में लगाए गए मल्टी-प्रोब सेंसर, लोरा गेटवे के साथ जो एक बैटरी पर महीनों तक काम करते हैं, खेत में स्थापित किए गए हैं। एक पाइपलाइन पहले से ही पहाड़ की गहराई में मापे गए मूल्यों को मानव हाथों से गुजरे बिना सीधे सर्वर और किनारे के उपकरणों, फ़िल्ड साइट के पास के छोटे कंप्यूटरों तक पहुंचाती है। जिस कार्य के लिए एक शोधकर्ता को महीने में एक बार पहाड़ पर चढ़ना पड़ता था और उपकरण की रीडिंग को हाथ से कॉपी करना पड़ता था, उसे अब केवल मोबाइल-फोन स्क्रीन चालू करके जांचा जा सकता है। हालाँकि, पाइपलाइन सही नहीं है। जब बैटरी खत्म हो जाती है या संचार कट जाता है, तो उस पूरे अंतराल के नंबर खाली रहते हैं।

एक समीक्षा ने इन प्रौद्योगिकियों को एकत्रित किया है और उनकी दिशा को व्यवस्थित किया है। फ्रंटियर्स इन प्लांट साइंस में, वांग एट अल। (2026) ने मल्टीमॉडल डेटा-फ्यूज़न अध्ययनों की समीक्षा की जो वन-संसाधन अवलोकन में उपयोग किए जाने वाले LiDAR, उपग्रह इमेजरी, IoT सेंसर और ड्रोन डेटा को एक ही मॉडल में रखते हैं। उन्होंने नोट किया कि जैसे-जैसे डेटा प्रकारों की संख्या बढ़ती है सटीकता बढ़ती है, लेकिन प्रीप्रोसेसिंग मुश्किल होती है क्योंकि डेटासेट के अस्थायी और स्थानिक रिज़ॉल्यूशन भिन्न होते हैं। वन-स्वास्थ्य निगरानी को कवर करने वाली समीक्षाएँ अधिक व्यापक रूप से उसी निष्कर्ष को दोहराती हैं। अमोआ-नुआमा एट अल। (2025) और साहा एट अल। (2025), क्रमशः एआई-आधारित वन-स्वास्थ्य निगरानी और रिमोट-सेंसिंग और स्मार्ट-मॉनिटरिंग सिस्टम की समीक्षा करते हुए, पाया गया कि जब सेंसर, उपग्रह और कृत्रिम बुद्धिमत्ता को अलग-अलग उपयोग करने के बजाय ओवरलेड किया जाता है, तो गलत अलार्म और चूक दोनों में गिरावट आती है।

एक मानचित्र जो मिट्टी की गुणवत्ता को स्कोर में बदल देता है

उपलब्ध जल क्षमता, कार्बनिक पदार्थ सामग्री, अम्लता और पोषक तत्व वन स्वास्थ्य के उपाय हैं। ये संख्याएँ अंततः निर्धारित करती हैं कि पेड़ की जड़ें कितनी दूर तक फैल सकती हैं और वे कितने समय तक सूखा सहन कर सकती हैं। समस्या यह है कि उन्हें फावड़े से एक ही स्कूप से नहीं जाना जा सकता है और नमूने प्रयोगशाला में भेजे जाने और कई दिन बीत जाने के बाद ही सामने आते हैं। इन आकृतियों को एक मानचित्र में खींचने का काम हाल के वर्षों में तेजी से बढ़ा है।

प्राकृतिक देवदार के जंगलों के एक अध्ययन में, पौडेल एट अल। (2025) ने मिट्टी-गुणवत्ता सूचकांक की गणना करने के लिए फ़ज़ी विश्लेषणात्मक पदानुक्रम प्रक्रिया (फ़ज़ी-एएचपी) को यादृच्छिक वन के साथ जोड़ा। साइंटिफिक रिपोर्ट्स में प्रकाशित, अध्ययन में बताया गया है कि मिट्टी की संरचना, कार्बनिक पदार्थ और जल-धारण क्षमता को शामिल करने वाला एक मशीन-लर्निंग मॉडल पारंपरिक सांख्यिकीय मॉडल की तुलना में मिट्टी की स्थिति में स्थानीय अंतर को अधिक सूक्ष्मता से मैप करता है।

उपग्रह द्वारा मृदा जैविक कार्बन (एसओसी) की पहचान करने का प्रयास जारी है। ली एट अल.

(2025) ने चीन के बोस्टन लेक ओएसिस में मिट्टी के कार्बनिक-कार्बन सांद्रता का अनुमान लगाने के लिए इलाके के चर के साथ सेंटिनल-2 उपग्रह से वर्णक्रमीय इमेजरी को जोड़ा। परविज़ी और फ़तेही (2025) ने कई भूमि-उपयोग प्रकारों में मिट्टी के कार्बनिक कार्बन का मानचित्रण किया और एक सामान्यीकृत रैखिक मॉडल, क्यूबिस्ट, सपोर्ट वेक्टर मशीन और यादृच्छिक वन की तुलना की। यादृच्छिक वन की व्याख्यात्मक शक्ति 0.64 थी, जो सामान्यीकृत रैखिक मॉडल के 0.39 और समर्थन वेक्टर मशीन के 0.41 से स्पष्ट रूप से बेहतर थी। कोई भी एल्गोरिदम हमेशा जीतता नहीं है, इसलिए जब मिट्टी और इलाके बदलते हैं, तो पहले स्थान के लिए मॉडल की पसंद पर पुनर्विचार किया जाना चाहिए।

परिणामी मृदा-गुणवत्ता सूचकांक और मृदा जैविक-कार्बन मानचित्र एक संख्या के रूप में समाप्त नहीं होते हैं। एक बार जब नक्शा रंगीन हो जाता है, तो यह एक नज़र में दिखाता है कि ढलान की दिशा के अनुसार एक ही पर्वत के भीतर मिट्टी की स्थिति कितनी तेजी से भिन्न होती है और क्या कोई स्थान पानी इकट्ठा करने वाली घाटी या रिज है। एक वानिकी अधिकारी के लिए यह निर्णय लेने के लिए कि कहाँ पेड़ लगाने हैं और कहाँ भूमि को अछूता छोड़ना है, यह मानचित्र एक संदर्भ सामग्री बन जाता है जो क्षेत्र निरीक्षण से पहले रास्ता बताता है।

एक ग्राफ न्यूरल नेटवर्क जो शेड-ट्री प्लेसमेंट की गणना करता है

कृषि वानिकी में, ऊपरी मंजिल के पेड़ों द्वारा डाली गई छाया के एक टुकड़े का स्थान निचली मंजिल की फसलों द्वारा अनुभव की जाने वाली धूप, नमी, कार्बन-डाइऑक्साइड सांद्रता और मिट्टी की नमी को बदल देता है। यदि छाया बहुत घनी है, तो फसलें धीमी गति से बढ़ती हैं; यदि यह बहुत विरल है, तो उनकी पत्तियाँ तेज धूप में जल जाती हैं। इसलिए छायादार पेड़ कहाँ लगाएँ और कितने लगाएँ, यह गणना का विषय है, अंतर्ज्ञान का नहीं।

रिडलो एट अल.

(2025) ने ग्राफ सिद्धांत से एक स्वतंत्र डोमिनेटिंग-सेट एल्गोरिदम के साथ छायादार पेड़ों और सेंसरों की नियुक्ति की गणना की, और एक स्थानिक-लौकिक ग्राफ तंत्रिका नेटवर्क (एसटीजीएनएन) के साथ सापेक्ष आर्द्रता और कार्बन-डाइऑक्साइड एकाग्रता की भविष्यवाणी की। 96 कॉफ़ी पेड़ों और 26 छायादार पेड़ों वाले परिदृश्य में, वार्षिक कार्बन-डाइऑक्साइड पृथक्करण की गणना 520 किलोग्राम की गई थी। एक ग्रिड में 31 छायादार पेड़ों वाले परिदृश्य का मूल्य 620 किलोग्राम था। ये मॉडल गणनाएँ थीं, न कि दीर्घकालिक क्षेत्रीय अध्ययन में सीधे मापी गई कार्बन-पृथक्करण मात्राएँ।

पूर्वानुमानित प्रदर्शन भी ध्यान देने योग्य है। मॉडल 10, 15 और 20 दिन आगे के माइक्रोक्लाइमेट का पूर्वानुमान लगाता है। ऐतिहासिक औसत, एआरआईएमए, सपोर्ट वेक्टर रिग्रेशन (एसवीआर), ग्राफ कनवलशनल नेटवर्क (जीसीएन), और गेटेड रिकरेंट यूनिट्स (जीआरयू) जैसे मौजूदा तरीकों की तुलना में, इसकी त्रुटियाँ स्पष्ट रूप से छोटी थीं और इसके निर्धारण का गुणांक 0.7350 से 0.8109 तक था। एक ऐसा युग शुरू हो गया है जिसमें सापेक्ष आर्द्रता और कार्बन-डाइऑक्साइड सांद्रता, जिसे मापने के लिए लोग हर दिन बाहर जाते थे, की गणना दस दिन पहले की जा सकती है और यह चुनने के लिए उपयोग किया जा सकता है कि छायादार पेड़ कहाँ लगाए जाएँ।

उपग्रहों द्वारा कैप्चर की गई 30 से अधिक वर्षों की फ़िल्म

जलवायु परिवर्तन, अनधिकृत कटाई, कृषि विस्तार और जंगल की आग लगातार जंगलों की उपस्थिति को बदल देती है। इस बदलाव को कैद करने के लिए एक तस्वीर की नहीं बल्कि दशकों की फिल्म की जरूरत है। लैंडसैट, सेंटिनल और एमओडीआईएस जैसे उपग्रहों द्वारा परत दर परत जमा की गई समय-श्रृंखला की छवियां उस फिल्म के रूप में काम करती हैं। कोरिया में, उपग्रह समय-श्रृंखला विश्लेषण के एक ही परिवार का उपयोग गैंगवॉन प्रांत में जंगल की आग से क्षतिग्रस्त क्षेत्रों और पाइन विल्ट रोग के कारण कटाई वाले स्थानों पर वसूली की जांच करने के लिए किया जाता है। कटाई या आग लगाने के तुरंत बाद, नंगी मिट्टी के विस्तृत क्षेत्र दिखाई देते हैं। कई वर्षों के बाद, घास और झाड़ियाँ पहले प्रवेश करती हैं, और उसके बाद ही पेड़ जड़ें जमाते हैं। सैटेलाइट इमेजरी के बदलते रंगों में अनुक्रम बरकरार दिखता है।

ओबाटा और उनके सहयोगियों ने 2021 में जॉर्जिया, संयुक्त राज्य अमेरिका में जंगलों का अध्ययन किया। उन्होंने 1984 से 2016 तक 33 वर्षों की लैंडसैट इमेजरी को Google Earth इंजन पर संग्रहीत किया। उन्होंने टैसल-कैप परिवर्तन के माध्यम से चमक, हरापन और गीलापन सूचकांक निकाले, हार्मोनिक प्रतिगमन विश्लेषण लागू किया, और परिणामों को यादृच्छिक वन के माध्यम से राष्ट्रीय वन सूची नमूना भूखंडों से जोड़ा। केवल तीन साल की इमेजरी का उपयोग करने वाले मॉडल की तुलना में, इसने सबसे हालिया गड़बड़ी की तारीख को अधिक सटीक रूप से पहचाना और वृक्ष-संचय की मात्रा में त्रुटि को कम किया। वही अध्ययन 2026 में एक जापानी जर्नल में फिर से पेश किया गया था, लेकिन मूल प्रकाशन वर्ष और डीओआई को उद्धरण में प्राथमिकता दी गई है।

अशांति के कारणों का वर्गीकरण वैश्विक स्तर पर विस्तारित हो गया है। लैंडसैट समय श्रृंखला और गहन शिक्षण का उपयोग करते हुए, वांग एट अल। (2026) ने 2000 से 2020 तक दुनिया भर में वन हानि को जंगल की आग, लॉगिंग और कटाई, स्थानांतरित खेती, बीमारी और हवा से होने वाली क्षति में विभाजित करके एक डेटासेट बनाया और इसे पृथ्वी प्रणाली विज्ञान डेटा में प्रकाशित किया। इसका मतलब यह है कि मानचित्र अब न केवल यह भेद कर सकते हैं कि जंगल कहाँ गायब हुए बल्कि क्यों गायब हुए।

एक अन्य अध्ययन में एआई मॉडल की तुलना की गई जो भूमि उपयोग और भूमि कवर को अलग करता है। Çalışkan (2026) ने एक ही डेटा पर एक सपोर्ट वेक्टर मशीन, रैंडम फ़ॉरेस्ट और डिसीजन ट्री को प्रशिक्षित किया और उनके प्रदर्शन की तुलना की। प्रत्येक क्षेत्र में कोई एक विधि नहीं जीती। यादृच्छिक-वन विधियों ने बेहतर प्रदर्शन किया जहां भूभाग जटिल था और भूमि उपयोग को छोटे पार्सल में विभाजित किया गया था, जबकि संरचनात्मक रूप से सरल निर्णय-वृक्ष विधि स्पष्ट सीमाओं वाले बड़े कृषि क्षेत्रों में बहुत पीछे नहीं थी।

कुछ लेबल वाले क्षेत्रों को एक अलग रणनीति की आवश्यकता होती है। कोलंबिया के उष्णकटिबंधीय शुष्क जंगलों में मौसमी रूप से पत्तियां गिरती हैं और अक्सर जलती रहती हैं, जिससे उनकी वर्णक्रमीय विशेषताओं में काफी उतार-चढ़ाव होता है। सेमी-एफसीएमनेट, गोंजालेज़-वेलेज़ एट अल द्वारा पेश किया गया। (2026), एक अर्ध-पर्यवेक्षित शिक्षण वास्तुकला है जो जमीनी सच्चाई लेबल और बिना लेबल वाले सेंटिनल-1 रडार और सेंटिनल-2 ऑप्टिकल टाइम श्रृंखला पर एक साथ प्रशिक्षण देता है। लेबल-सीमित परिस्थितियों में भी इसने 90 प्रतिशत से ऊपर सटीकता बनाए रखी। श्रम-समय की बचत को अलग से नहीं मापा गया।

ऐसे अध्ययन हैं जो विशेष रूप से पहचानते हैं कि जंगल के गायब होने के बाद क्या प्रवेश करता है। पिसल एट अल. (2026) ने एक गहन-शिक्षण मॉडल का उपयोग किया जो स्थान की जानकारी सीखकर यह पता लगाता है कि उष्णकटिबंधीय वन से साफ की गई भूमि चारागाह, फसल भूमि या सड़क बन गई है या नहीं। अध्ययन से पता चलता है कि भले ही वन हानि समान हो, लेकिन बाद में भूमि उपयोग भिन्न होने पर नीति प्रतिक्रियाएँ भिन्न होनी चाहिए।

वन विस्तार की भी एक कहानी है. सिल्वा एट अल.

(2026) ने उपोष्णकटिबंधीय ब्राजील में एक कृषि वानिकी क्षेत्र की जांच की। शोधकर्ताओं ने ब्राजील के सैटेलाइट लैंड-कवर मैपिंग प्रोजेक्ट, मैपबायोमास डेटा के साथ तीन समय बिंदुओं पर परिवर्तन को ट्रैक किया: 2000, 2010 और 2020। क्षेत्र 405.80 हेक्टेयर से 500.60 हेक्टेयर से 659.81 हेक्टेयर तक विस्तारित हुआ। इसी अवधि के दौरान आवास एकत्रीकरण सूचकांक में वृद्धि हुई। ऐसा प्रतीत होता है कि यह विस्तार कृषिवानिकी क्षेत्रों के रूप में हुआ है जो खंडित प्राकृतिक वनों को जोड़ने वाले पारिस्थितिक गलियारे के रूप में कार्य करते हैं। अध्ययन में कहा गया है कि ऐसे गलियारे जैव विविधता की रक्षा करने और मिट्टी को बह जाने से बचाने में मदद करते हैं।

शोध में भविष्य पर भी ध्यान दिया गया है। तंजानिया के राष्ट्रीय वन संसाधन निगरानी और मूल्यांकन (NAFORMA) डेटा का उपयोग करते हुए, ज़ेला (2026) ने तीन परिदृश्यों के तहत 2014 से 2054 तक वन क्षेत्र की गणना की। यदि मौजूदा रुझान जारी रहता है, तो वन और वुडलैंड्स 48.09 मिलियन हेक्टेयर से घटकर 32.99 मिलियन हेक्टेयर रह जाते हैं। भारी विकास दबाव के परिदृश्य में, वे 28.30 मिलियन हेक्टेयर तक कम हो जाते हैं। टिकाऊ-प्रबंधन परिदृश्य के तहत, 43.85 मिलियन हेक्टेयर भूमि शेष रहने का अनुमान लगाया गया था।

वास्तविक समय में कटाई का पता लगाने का प्रयास किया जा रहा है। कुंडू एट अल.

(2025) साइंटिफिक रिपोर्ट्स में प्रकाशित, लैंगचेन-आधारित एजेंट के साथ YOLO ऑब्जेक्ट-डिटेक्शन मॉडल को संयोजित करने वाली एक प्रणाली जो स्वायत्त रूप से निर्णयों के अनुक्रम को पूरा करती है। यह वास्तविक समय में उपग्रह और ड्रोन इमेजरी में संदिग्ध कटाई परिवर्तनों का पता लगाता है और अलर्ट जारी करता है। कृत्रिम बुद्धिमत्ता पहले कटाई के संदेह वाले क्षेत्रों का चयन करती है, लेकिन झूठे अलार्म पूरी तरह से गायब नहीं होते हैं, इसलिए लोगों को अभी भी अंतिम निर्णय लेना होगा।

इस प्रकार की समय-श्रृंखला निगरानी अब प्रयोगशाला के बाहर भी महत्व रखती है। यूरोपीय संघ वनों की कटाई विनियमन (ईयूडीआर) के लिए अनुबंध I में सूचीबद्ध कॉफी, कोको और लकड़ी से संबंधित उत्पादों को बाजार में पेश करने या निर्यात करने वाले ऑपरेटरों को उत्पादन के स्थान के लिए जियोलोकेशन जानकारी प्रदान करने की आवश्यकता होती है। चार हेक्टेयर या उससे कम के भूखंड को अक्षांश और देशांतर के एक बिंदु द्वारा दर्शाया जा सकता है; एक बड़े भूखंड के लिए बहुभुज सीमा की आवश्यकता होती है। कटऑफ की तारीख 31 दिसंबर, 2020 है। बड़े ऑपरेटर और कुछ छोटे और मध्यम आकार के उद्यम 30 दिसंबर, 2026 को नियमों के अधीन हो जाते हैं। प्राकृतिक व्यक्तियों और कुछ सूक्ष्म उद्यमों के लिए

आवेदन की तारीख 30 जून, 2027 है। क्योंकि तारीखें कमोडिटी कोड और ऑपरेटर की स्थिति के अनुसार भिन्न होती हैं, प्रत्येक कंपनी को अपने उत्पाद और भूमिका की अलग से पुष्टि करनी होगी।

परस्पर विरोधी संख्याएँ और शेष कार्य

इतनी तकनीक जमा हो जाने के बाद भी आंकड़े एक समान नहीं होते। एक ग्राउंड सेंसर एक संकीर्ण बिंदु पर मान मापता है, जबकि एक सेंटिनल-2 या लैंडसैट पिक्सेल एक व्यापक क्षेत्र में औसत देखता है। बजरी, छाया, चंदवा और मिट्टी की नमी में भिन्न दो डेटासेट को ओवरले करने के लिए सत्यापन की आवश्यकता होती है जो उन्हें एक ही तिथि और स्थानिक पैमाने पर संरेखित करता है।

ऐसे मामले सामने आए हैं जिनमें इस तरह के बेमेल संबंधों ने क्षेत्र में समस्याएं पैदा कर दीं। अकेले उपग्रह सूचकांकों से सुरक्षित आंका गया क्षेत्र जब दौरा किया गया तो पहले से ही काफी शुष्क था, या उपग्रह ने एक असामान्य संकेत सुनाया जो क्षेत्र में एक सामान्य मौसमी परिवर्तन साबित हुआ। जब तक कोई फ़िल्ड मैनुअल पहले से निर्दिष्ट नहीं करता है कि दोनों के बीच असहमति होने पर पहले किस संकेत पर भरोसा करना चाहिए, प्रबंधक अलग-अलग निर्णय पर पहुंचते हैं और भ्रम पैदा होता है।

एक अन्य प्रकार का संघर्ष ऑप्टिकल और रडार (एसएआर) उपग्रहों के बीच मौजूद है। उष्णकटिबंधीय और उपोष्णकटिबंधीय वर्षावनों में अक्सर बादलों और कोहरे के साथ, ऑप्टिकल इमेजरी में अक्सर अंतराल खुल जाते हैं, जिससे पत्तियों के उभरने और गिरने के चक्र को याद करना आसान हो जाता है। उन क्षेत्रों में जहां बारिश का मौसम महीनों तक जारी रहता है, एक भी प्रयोग योग्य ऑप्टिकल छवि बनाए बिना छह महीने गुजर सकते हैं। रडार बादलों के माध्यम से छवि ले सकता है, लेकिन बारिश के तुरंत बाद गीली मिट्टी की खुरदरापन सिग्नल को परेशान कर सकती है, जिससे किसी भी बदलाव का गलत पता लगाया जा सकता है।

घनी बंद छतरी वाले जंगल में, उपग्रहों या ड्रोन से निकलने वाले सिग्नल पत्तों की सतहों से वापस उछलते हैं, जिससे अप्रत्यक्ष सूचकांकों के माध्यम से नीचे की मिट्टी की स्थिति का अनुमान लगाने के अलावा कोई विकल्प नहीं बचता है। जब एक जलवायु क्षेत्र में प्रशिक्षित परिवर्तन-पहचान मॉडल को दूसरे पारिस्थितिकी तंत्र में ले जाया जाता है, तो यह पत्ती गिरने के मौसम को जंगल की आग या कटाई के रूप में गलत समझ सकता है। सटीकता में गिरावट का आकार डेटा और मीट्रिक के अनुसार भिन्न होता है और इसे किसी एक सीमा तक सीमित नहीं किया जाता है। दूरदराज के क्षेत्रों में सेंसर अक्सर बैटरी पावर और संचार खो देते हैं, जिसके लिए दीर्घकालिक क्षेत्र परीक्षण की आवश्यकता होती है।

भविष्य के लिए एक कार्य भौतिकी-सूचित तंत्रिका नेटवर्क (पिनन) है, जो तंत्रिका नेटवर्क को समीकरणों के साथ जोड़ता है जो भौतिक कानूनों के माध्यम से भूमिगत जल की गति को व्यक्त करते हैं। केवल डेटा पर प्रशिक्षित मॉडल अत्यधिक सूखे या उनके प्रशिक्षण डेटा से अनुपस्थित रिकॉर्ड वर्षा का सामना करने पर निरर्थक मूल्य उत्पन्न कर सकते हैं। यदि पानी जमीन में कैसे घुसपैठ करता है और वाष्पित होता है, इसे नियंत्रित करने वाले भौतिक नियम तंत्रिका नेटवर्क में अंतर्निहित हैं, तो ऐसी अपरिचित परिस्थितियों में भी मॉडल के प्रशंसनीय मूल्यों को बनाए रखने की अधिक संभावना है। स्थानिक-लौकिक ग्राफ तंत्रिका नेटवर्क और ट्रांसफॉर्मर को हल्के रूपों में कम करना जिन्हें सीधे ड्रोन और फ़िल्ड उपकरणों में एम्बेड किया जा सकता है, एक और कार्य है। कई दस्तावेज़ विभिन्न पारिस्थितिक तंत्रों में समय-श्रृंखला मिट्टी और भूमि-कवर बेंचमार्क डेटा का विस्तार जारी रखने की आवश्यकता को दोहराते हैं। केवल जब कम-शक्ति वाले एआई चिप्स जो एक

बैटरी पर महीनों तक चलते हैं, पहाड़ों के हर कोने तक पहुंच जाएंगे, सेंसर और उपग्रहों के बीच वर्तमान अंतर कम होना शुरू हो जाएगा।

स्रोत और संदर्भ

1. Amoah-Nuamah, J., Child, B., Okyere, E. Y., Adams, O., & Danquah, J. A. (2025). Applications of artificial intelligence in forest health surveillance and management. *Discover Forests*, 1, Article 56. <https://doi.org/10.1007/s44415-025-00061-w>
2. Çalışkan, B. (2026). Machine learning innovations in LULC classification: a comparative study of SVM, random forest, and decision trees. *Land Management and Utilization*, 2(1), 48-62. <https://doi.org/10.54963/lmu.v2i1.2356>
3. González-Vélez, J. C., Torres-Madronero, M. C., Martínez-Vargas, J. D., Rodríguez-Marín, P., Perez-Guerra, J., & Herrera-Ruiz, V. (2026). Tropical dry forest land use/land cover change detection using semi-supervised deep learning algorithms and remote sensing. *Environmental Monitoring and Assessment*, 198(2), 197. <https://doi.org/10.1007/s10661-025-14897-4>
4. Kundu, S., Ninoria, S. Z., Chaturvedi, R. P., Mishra, A., Agrawal, A., Batra, R., Dubale, M., & Hashmi, A. (2025). Real-time deforestation anomaly detection using YOLO and LangChain agents for sustainable environmental monitoring. *Scientific Reports*, 15, Article 39961. <https://doi.org/10.1038/s41598-025-23617-4>
5. Li, S., Li, X., & Ge, X. (2025). Prediction and mapping of soil organic carbon in the Bosten Lake oasis based on Sentinel-2 data and environmental variables. *International Soil and Water Conservation Research*, 13, 436-446. <https://doi.org/10.1016/j.iswcr.2024.12.002>
6. Obata, S., Cieszewski, C. J., Lowe, R. C., & Bettinger, P. (2021). Random forest regression model for estimation of the growing stock volumes in Georgia, USA, using dense Landsat time series and FIA dataset. *Remote Sensing*, 13(2), Article 218. <https://doi.org/10.3390/rs13020218>
7. Parvizi, Y., & Fatehi, S. (2025). Geospatial digital mapping of soil organic carbon using machine learning and geostatistical methods in different land uses. *Scientific Reports*, 15, 4449. <https://doi.org/10.1038/s41598-025-88062-9>
8. Pišl, J., Sumbul, G., Lenczner, G., Zamora, C., Herold, M., Wegner, J. D., & Tuia, D. (2026). Mapping land uses following tropical deforestation with location-aware deep learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 232, 578-593. <https://doi.org/10.1016/j.isprsjprs.2025.12.007>
9. Poudel, D., Abiye, W., Dengiz, O., Pacci, S., & Safli, M. E. (2025). Soil quality dynamics in natural pine forests lands integrating fuzzy-AHP and prediction-based machine learning. *Scientific Reports*, 15, 32140. <https://doi.org/10.1038/s41598-025-21943-1>
10. Ridlo, Z. R., Dafik, Waluyo, J., Yushardi, & Venkatachalam, M. (2025). On RIDS analysis for shade tree placement and its application to STGNN multi-step forecasting on RH and CO2 concentration of coffee agroforestry. *Statistics, Optimization & Information Computing*, 14(4), 1889-1908. <https://doi.org/10.19139/soic-2310-5070-2643>
11. Saha, R., Bagchie, P., Lalremsang, P., & Rai, K. C. (2025). Digital innovation in forest science: applications of artificial intelligence, remote sensing and smart monitoring systems for ecosystem conservation. *The Bioscan*, 20(3), 907-911. [https://doi.org/10.63001/tbs.2025.v20.i03.S.I\(3\).pp907-911](https://doi.org/10.63001/tbs.2025.v20.i03.S.I(3).pp907-911)
12. Silva, B. B., Brum, D., Loregian, A. C., Urruth, L. M., & Tozetti, A. M. (2026). Agroforestry systems as habitat aggregators: a spatiotemporal analysis of the Brazilian subtropical Atlantic forest. *Agroforestry Systems*, 100(6), 185. <https://doi.org/10.1007/s10457-026-01557-w>
13. Singh, A., Atish, Singh, V., Kumari, B., Arya, S., & Kamboj, A. (2026). A systematic review on water use efficiency (WUE) and soil moisture dynamics in wheat-based agroforestry systems. *International Journal of Environment, Agriculture and Biotechnology*, 11(3), 72-87. <https://doi.org/10.22161/ijeab.113.8>

14. Wang, L., Liu, S., Zhang, J., & Song, W. (2026). Global high-resolution forest disturbance type dataset between 2000 and 2020. *Earth System Science Data*, 18, 1601-1618. <https://doi.org/10.5194/essd-18-1601-2026>
15. Wang, M., Zhang, Q., Liu, X., Zhang, J., Yu, F., Zhang, X., & Zhao, R. (2026). Research progress on multimodal data fusion in forest resource monitoring. *Frontiers in Plant Science*, 16, 1710618. <https://doi.org/10.3389/fpls.2025.1710618>
16. Yin, L., Yan, S., Li, M., Liu, W., Zhang, S., Xie, X., et al. (2024). Enhancing soil moisture estimation in alfalfa root-zone using UAV-based multimodal remote sensing and deep learning. *European Journal of Agronomy*, 161, 127366. <https://doi.org/10.1016/j.eja.2024.127366>
17. Zella, A. Y. (2026). Sustainable forest and land-use management in Tanzania: NAFORMA-based and machine learning forecasts to 2050 under Tanzania Dira 2050. *International Journal of Development and Management Review*, 21(1), 1-36. <https://doi.org/10.4314/ijdmr.v21i1.1>
18. Shin & Kim LLC. (March 17, 2026). ESG regulations to watch in 2026 (4): European Union Deforestation-Free Products Regulation. <https://www.shinkim.com/kor/media/newsletter/3174> (accessed August 2, 2026)

अध्याय 3

वन आपदा और पारितंत्र स्वास्थ्य की निगरानी: एआई पूर्वोक्षण और आरंभिक चेतावनी

3.1

मशीन लर्निंग और डीप लर्निंग आधारित वनाग्नि जोखिम पूर्वानुमान और दहन क्षेत्र की पहचान

बसंत के अंत की एक दोपहर, जब शुष्कता की चेतावनी लगातार तीसरे दिन जारी थी। वनाग्नि नियंत्रण कक्ष की दीवार को भरने वाले मॉनिटरों के एक कोने में एक लाल बिंदु उभरता है। खिड़की के बाहर की हवा सूखी और तेज़ है, कल छिड़का हुआ पानी पहले ही सूख चुका है। नियंत्रण कक्ष के भीतर बस वायरलेस की आवाज़ और कीबोर्ड की टिपटिप धीमे स्वर में तैरती है। कर्मचारी तुरंत सीसीटीवी की छवि को खींचकर देखता है, थर्मल कैमरा के तापमान अंक की जाँच करता है, और यह देखने के लिए खोज विंडो खोलता है कि आस-पास से कोई सूचना आई है या नहीं। वह बिंदु सचमुच आग है, खेत की मेंड़ जलाने का धुआँ है, या शाम की धूप से तपी हुई छत है, यह छाँटने का समय ज़्यादा से ज़्यादा कुछ ही मिनट का होता है। और उन कुछ मिनटों के बीच, इससे पहले कि इंसान की आँख छवि को पूरा टटोल ले, कृत्रिम बुद्धिमत्ता के एल्गोरिदम पहले ही एक बार निर्णय कर चुके होते हैं।

मार्च 2025 में, ग्योंगसांगबुक-दो के उइसोंग में शुरू हुई आग इस निर्णय के भार को दर्शाने वाला एक उदाहरण है। आग आंदोंग और चोंगसोंग, योंगयांग, योंगदोक तक फैल गई। आधिकारिक गणना के अनुसार छब्बीस लोग मारे गए और इकहत्तर घायल हुए। ग्योंगबुक का अस्थायी वन क्षति क्षेत्रफल 99,289 हेक्टेयर था। ग्योंगबुक की अस्थायी क्षति राशि 1 खरब 13 अरब 6 करोड़ वोन है। ग्योंगबुक, ग्योंगनाम और उल्सान की पुनर्निर्माण लागत 1 खरब 88 अरब 9 करोड़ वोन आँकी गई। ये दोनों मूल्य आपस में भिन्न संख्याएँ हैं। क्षति राशि गर्मियों में बढ़ी नहीं, बल्कि क्षति सर्वेक्षण और पुनर्निर्माण योजना का क्षेत्रीय दायरा और लेखांकन की मदें अलग थीं।

ऐसी आग को रोकने की कोशिश करने वाली कृत्रिम बुद्धिमत्ता मुख्य रूप से दो चरणों में काम करती है। आँकड़ों को स्वयं टटोलकर नियम खोज निकालने वाली मशीन लर्निंग (Machine Learning), और उस नियम-खोज को कई परतों वाले तंत्रिका जाल के ज़रिए कहीं अधिक गहराई तक खोदने वाली डीप लर्निंग (Deep Learning) अपने-अपने अलग समय-बिंदु सँभालती हैं। आग लगने से कुछ दिन, और अधिक से अधिक एक महीने पहले कहाँ खतरा है, यह पहले से भाँप लेने वाला पूर्वानुमान मॉडल एक है। आग लग चुकने के बाद कुछ ही मिनटों में उस तथ्य को भाँप लेने वाला संसूचन मॉडल दूसरा है।

आर्द्रता का वक्र पहले हिलता है

पुराने वनाग्नि जोखिम आकलन स्थिर भूभाग और एक बार लिए गए वनस्पति सूचकांक पर टिके थे। किसी एक पहाड़ का ढाल और पेड़ों की जाति कई वर्षों में भी बहुत नहीं बदलती, इसलिए उतनी ही जानकारी से जोखिम मानचित्र बनाकर उसे लंबे समय तक इस्तेमाल किया जाता था। समस्या यह है कि वनाग्नि केवल भूभाग के कारण नहीं लगती। कल तक बारिश होती रही हो और आज अचानक आर्द्रता एकदम गिर जाए, तो कल जो पहाड़ सुरक्षित था वह आज खतरनाक पहाड़ में बदल जाता है। हाल की वन कृत्रिम बुद्धिमत्ता मौसम और भूभाग, ईंधन बनने वाली वनस्पति, और लोग कितना आते-जाते हैं यह दिखाने वाले सामाजिक-आर्थिक आँकड़ों तक को एक साथ जोड़कर, दैनिक आधार पर वनाग्नि होने की प्रायिकता को फिर से गणना करने की दिशा में बढ़ रही है।

इस गणना में एक सिरदर्द भरी विशेषता है। वनाग्नि लगने के दिन कुछ ही होते हैं, और न लगने के दिन कहीं अधिक होते हैं, यही बात है। इसी स्थिति में मॉडल को प्रशिक्षित किया जाए, तो वह केवल सुरक्षित दिनों को अच्छे से मिलाकर अंक बटोरने वाले आलसी विद्यार्थी की तरह व्यवहार करता है। असली आग वाले दिन को तो चूक जाता है। इसीलिए शोधकर्ता SMOTE (Synthetic Minority Over-sampling Technique) का उपयोग करते हैं। यह कम संख्या वाले मामलों, यानी वनाग्नि वाले दिनों के आँकड़ों को सांख्यिकीय रूप से मिलती-जुलती नई प्रतियों के रूप में बनाकर बढ़ाने की विधि है, ताकि मॉडल दोनों स्थितियों को समान रूप से देखकर सीखे। इसके विपरीत आग न लगने वाले दिनों के आँकड़ों को छाँटकर घटा देने वाली अंडरसैंपलिंग, या वनाग्नि चूकने पर दिए जाने वाले दंड-अंक को अधिक भारी करने वाली लागत-संवेदी शिक्षा को साथ-साथ इस्तेमाल किया जाता है।

गांगवोन विशेष स्वायत्त प्रांत को लक्ष्य बनाकर की गई एक शोध ने 2013 से 2023 तक ग्यारह वर्षों में जमा हुए मौसम, वन और जनसंख्या आँकड़ों पर यह विधि लागू की। ऐसे तालिका-रूपी आँकड़ों में गहन तंत्रिका जाल की तुलना में, कई पेड़ लगाकर बहुमत से निर्णय करने वाला वृक्ष-आधारित मॉडल अक्सर आगे रहता है। शर्तों को एक-एक करके बाँटकर शाखाएँ फैलाने का तरीका, मौसम और भूभाग जैसे भिन्न स्वभाव वाले चरों को घोल-मेल कर देखने में उल्टा लाभदायक होता है। लॉजिस्टिक रीग्रेशन और XGBoost, LightGBM, रैंडम फ़ॉरेस्ट, एक्स्ट्रा ट्री तक पाँच मॉडलों को आमने-सामने भिड़ाने पर एक्स्ट्रा ट्री AUC 0.839 के साथ आगे रहा। AUC वह सूचक है जो दर्शाता है कि सचमुच वनाग्नि वाले दिन और न वाले दिन को कितनी अच्छी तरह अलग किया जाता है, यह 1 के जितना पास हो उतना अच्छा मिलता है और 0.5 सिक्का उछालने से भिन्न नहीं होता। वनाग्नि को न चूकने की क्षमता को ही देखें तो रैंडम फ़ॉरेस्ट 0.828 की पुनःप्राप्ति दर के साथ बेहतर रहा। पुनःप्राप्ति दर का अर्थ है वास्तव में घटी वनाग्नि में से मॉडल ने बिना चूके जितना पकड़ लिया उसका अनुपात।

इस शोध ने SHAP (SHapley Additive exPlanations) नामक व्याख्या तकनीक का भी साथ उपयोग किया। यह अनेक खिलाड़ियों द्वारा मिलकर किए गए प्रदर्शन को उनके-उनके योगदान के अनुसार बाँटकर गणना करने वाली गेम थ्योरी की विधि को पूर्वानुमान मॉडल पर ज्यों-का-त्यों उतारने वाली तकनीक है। सापेक्ष आर्द्रता का योगदान 0.25 रहा जो बाकी सभी चरों से आगे निकल गया। आर्द्रता जितनी घटती गई, खतरा उतनी ही तेज़ी से ऊपर चढ़ता गया। वर्षा की उपस्थिति 0.15 के साथ पीछे रही, दैनिक अधिकतम तापमान 0.05, और जनसंख्या घनत्व 0.04 था। वृक्ष संचय मात्रा और कब्रिस्तान

अनुपात, शंकुधारी वन अनुपात, कृषि भूमि अनुपात ने भी बड़े न होते हुए भी लगातार भार जोड़ा। ताएबाएक पर्वतमाला को बीच में रखकर समुद्री हवा को सीधे झेलने वाले योंगदोंग और, पर्वतमाला के पीछे स्थित योंगसो को विभाजित करने वाला क्षेत्रीय विभाजन चर भी समान रूप से काम करता रहा। इसका अर्थ यह प्रतीत होता है कि केवल जलवायु ही नहीं, बल्कि लोगों के पहाड़ पर आने-जाने और आग लगाने की आदत तक ने खतरा ऊपर धकेला।

शंकुधारी वन अनुपात या वृक्ष संचय मात्रा जैसे ईंधन चरों को इंसान पैदल घूमकर एक-एक करके नहीं नापते। पौधों में समाए पानी की मात्रा दिखाने वाला सूचकांक (LSWI) या भू-सतह तापमान से सूखे की मात्रा भाँपने वाला सूचकांक (TVDI), ड्रोन लेज़र से बनाया गया छत्र-ऊँचाई मानचित्र (CHM) जैसे दूरस्थ अवलोकन आँकड़े इंसान के कदमों की जगह लेते हैं। मानवरहित यान पर लाइडार (LiDAR) चढ़ाकर हर एक पेड़ की स्थिति और घेरा, चोटी की चौड़ाई तक स्वतः चित्रित करने की शोध भी जारी है। वियतनाम में चीड़ की एक जाति सामयोप-सोंग (Pinus kesiya) के वन का डीप लर्निंग से विश्लेषण करने वाली शोध ने व्यक्तिगत वृक्ष संसूचन और छत्र विभाजन को स्वचालित कर, वनाग्नि ईंधन मानचित्र बनाने के मूल आँकड़े के रूप में इस्तेमाल करने का मार्ग खोला।

गांगवोन-दो की शोध यदि एक दिन आगे देखने वाला क्षेत्रीय मॉडल है, तो पूर्वानुमान अवधि को लगभग एक महीने तक बढ़ाने वाला प्रयास भी सामने आया। यूनिस्ट (UNIST) के प्रोफेसर इम जोंग-हो के शोध दल ने 2026 में, संपूर्ण विश्व के वनाग्नि मौसम सूचकांक को अधिकतम 31 दिन पहले भाँप लेने वाला डीप लर्निंग मॉडल FWI-Net अंतरराष्ट्रीय शोध पत्रिका कम्युनिकेशंस अर्थ एंड एनवायरनमेंट में प्रकाशित किया। वनाग्नि मौसम सूचकांक तापमान और आर्द्रता, हवा, वर्षा मात्रा को एक में मिलाकर, आग लगने पर वह कितनी बड़ी फैलेगी यह दर्शाने वाला सूचक है। मौजूदा यूरोपीय मध्यम-अवधि पूर्वानुमान केंद्र का संख्यात्मक पूर्वानुमान दो सप्ताह बीतने पर तेज़ी से सटीकता खो देता था, पर FWI-Net ने पूरे 31 दिन के खंड की त्रुटि 6.6 प्रतिशत घटा दी। पूर्वानुमान के पहले एक सप्ताह को ही अलग करके देखें तो त्रुटि में कमी 12.4 प्रतिशत तक बढ़ गई। जहाँ वनाग्नि जोखिम बड़ा होते हुए भी पूर्वानुमान व्यवस्था कमज़ोर थी, ऐसे क्षेत्रों में यह सुधार उतना ही बड़ा दिखाई दिया। भूभाग सूचना तकनीक और मशीन लर्निंग को जोड़ने वाली शोध को इकट्ठा कर फिर से पड़ताल करने वाली अंतरराष्ट्रीय साहित्य समीक्षा में भी निष्कर्ष समान रहा। उपग्रह छवि या भौगोलिक सूचना प्रणाली के आँकड़े में से केवल एक का उपयोग करने वाले मॉडल की तुलना में, मौसम और भूभाग, मानव गतिविधि के आँकड़ों को परतों में जोड़कर उपयोग करने वाला मॉडल देश और क्षेत्र का भेद किए बिना बेहतर प्रदर्शन दिखाता है, यह प्रवृत्ति बार-बार पुष्ट हुई।

पहाड़ के भीतर के सेंसर और आसमान की आँख वास्तविक समय में जोड़ते हैं

धरती पर सेंसर, और आसमान से उपग्रह उसी क्षण को देखते रहते हैं। LoRaWAN कम बिजली खर्च करते हुए दूर तक संकेत भेजने वाली बेतार संचार विधि है। तुर्किये के ज़ेयिनपार्क में तापमान और आर्द्रता, कार्बन मोनोऑक्साइड मापने वाले 80 सेंसर लगाए गए। शोध दल ने अनुकूली भारित Random Forest और XGBoost को जोड़ने वाला प्रारूप परखा, और सेंसर विन्यास का कवरेज 95.58 प्रतिशत गणना किया गया। बैटरी का जीवनकाल विश्लेषण के अनुसार अधिकतम 11 महीने था।

स्थान देखने वाले पैमाने को चौड़ा करने वाली शोध भी है। रूस के साइबेरिया के क्रानोयार्स्क क्षेत्र से जुड़ी शोध ने वनाग्नि स्थल को केंद्र मानकर 1 किलोमीटर से 100 किलोमीटर तक की त्रिज्या वाले छह परतों के संकेंद्रित वृत्त खींचे। प्रत्येक वृत्त के भीतर के मौसम और भूभाग आँकड़ों को 30 दिन के समय-श्रेणी के रूप में जोड़कर XGBoost से आग के आकार का वर्गीकरण किया और 88.8 प्रतिशत सटीकता की सूचना दी। शोध दल ने लिखा कि यह मान क्षेत्र के अनुरूप ढूँढने का परिणाम है, और इसे किसी अन्य महाद्वीप पर ले जाने के लिए स्थानीय आँकड़ों से फिर से अंशांकित करना होगा।

अर्थ फ़ायर अलायंस (Earth Fire Alliance) के परिचालन FireSat तीन उपग्रह 7 जुलाई 2026 को कक्षा में पहुँचे। आधिकारिक रोडमैप उसी वर्ष के अंत में आरंभिक उपयोगकर्ताओं को दिन में दो बार से अधिक अवलोकन प्रदान करने से शुरू होता है। लक्ष्य 2028 में संपूर्ण पृथ्वी तक पहुँच, अगले वर्ष 1 घंटे के भीतर पुनःभ्रमण तक जाता है। 2030 के दशक की शुरुआत में 20 मिनट के भीतर पुनःभ्रमण को निशाना बनाया गया है। उपग्रहों की संख्या और समय-सारणी प्रक्षेपण और बजट के अनुसार बदल सकती है।

घरेलू दूरस्थ संवेदन जगत में वनाग्नि लगने से पहले और फैलने के दौरान, बुझने के बाद तक के पूरे चक्र को कृत्रिम बुद्धिमत्ता और उपग्रह निगरानी से जोड़ने वाली धारा को व्यवस्थित करने वाला समीक्षा शोधपत्र भी सामने आया। प्रज्वलन से पहले जोखिम पूर्वानुमान और प्रज्वलन के दौरान वास्तविक समय संसूचन, बुझने के बाद क्षति क्षेत्रफल की गणना तक, हर चरण पर भिन्न उपग्रह आँकड़े और कृत्रिम बुद्धिमत्ता मॉडल की आवश्यकता है, यह बात इसने रेखांकित की। हमारा उपग्रह भी ऐसी ही भूमिका सँभाल रहा है। मौसम विभाग द्वारा प्रक्षेपित छोल्लियान उपग्रह 2ए प्राकृतिक रंग में पृथ्वी की छवि लेकर, अलग विश्लेषण के बिना भी केवल छवि देखकर बादल और वनाग्नि धुआँ, पीली धूल को आँख से अलग किया जा सकता है। इस उपग्रह द्वारा अवलोकित मृदा नमी के आँकड़े सूखे और वनाग्नि जोखिम को साथ-साथ जाँचने में इस्तेमाल होते हैं। वन प्रशासन के राष्ट्रीय वन विज्ञान संस्थान ने इन आँकड़ों को जोड़कर राष्ट्रीय वनाग्नि जोखिम पूर्वानुमान प्रणाली का संचालन किया, और हाल ही में उपयोगकर्ता जहाँ खड़ा है उस स्थिति के आधार पर वनाग्नि जोखिम सूचना तुरंत दिखाने वाली हथेली की सेवा भी नई शुरू की।

धुआँ है या बादल, कैमरा पहले छाँटता है

आग लग चुकने के बाद एक और लड़ाई शुरू होती है। धुआँ चौड़े में फैलने से पहले, चिंगारी उठने के कुछ ही मिनटों में उस तथ्य को भाँप लेना होता है, यही स्वर्णिम समय है। पहाड़ के नीचे स्थिर सीसीटीवी और अवरक्त कैमरा पहरा देते हैं, और जहाँ इंसान का चढ़ना कठिन है ऐसी कटक और अंध क्षेत्र में मानवरहित यान (UAV, ड्रोन) चक्कर लगाते हैं।

अकेला दृश्य-प्रकाश कैमरा कोहरे या बादल, शाम की धूप के परावर्तन से धोखा खा सकता है। थर्मल अवरक्त कैमरा ताप स्रोत को पकड़ता है पर छवि खुरदरी होने से जलते पेड़ और गर्म चट्टान को अलग करना कठिन होता है। चीन के फुजियान प्रांत के आँकड़ों से प्रशिक्षित EFFNet ने दृश्य-प्रकाश और थर्मल अवरक्त छवियों को जोड़ा। सत्यापन आँकड़ों में mAP50 97.2 प्रतिशत था। परिशुद्धता 94.9 प्रतिशत, पुनःप्राप्ति दर 94.1 प्रतिशत थी। यह मान फुजियान प्रांत की परीक्षण शर्तों में निकला परिणाम है।

धुएँ और चिंगारी की सीमा को पिक्सेल इकाई में बाँटने वाली शोध भी जारी रही। Akhyar शोध दल ने UAV छवि में वनाग्नि क्षेत्र को अलग करने वाला DeepFire S3GA-Net बनाया। परीक्षण आँकड़ों का

औसत IoU 0.8723 था। परिशुद्धता 0.9347, पुनःप्राप्ति दर 0.9194 थी। Hindarto शोध दल ने अलग वनाग्नि छवि आँकड़ों में MobileNetV3, ResNet50, YOLOv8 की तुलना की। वियतनामी सामयोप-सोंग का YOLO विभाजन और SAM2 तुलना वनाग्नि शोध नहीं, बल्कि व्यक्तिगत वृक्ष एवं छत्र विभाजन शोध है।

मॉडल भी आपस में अलग-अलग बोलते हैं

ये सभी परिणाम एक स्वर में नहीं बोलते। केवल मौसम आँकड़े डालने वाला पारंपरिक वनाग्नि मौसम सूचकांक मॉडल विस्तृत क्षेत्र की जोखिम प्रवृत्ति तो भाँप लेता है, पर उसी मौसम के भीतर किस छोटे वन क्षेत्र में सचमुच आग लगेगी यह नहीं छाँट पाता। गांगवोन-दो की शोध या मोरक्को, भारत से जुड़ी अन्य शोधों ने बताया कि जनसंख्या घनत्व और कृषि भूमि एवं कब्रिस्तान अनुपात, सड़क तक की दूरी जैसे सामाजिक-आर्थिक चरों को जोड़ने पर AUC और पुनःप्राप्ति दर 10 प्रतिशत अंक से 15 प्रतिशत अंक तक बढ़ जाती है। इसका अर्थ यह प्रतीत होता है कि मौसम की स्थिति एक-सी होने पर भी लोगों के अक्सर आने वाले स्थानों में, खेत-खलिहान और कब्र के पास वाले स्थानों में वास्तविक प्रज्वलन तक जाने की संभावना अधिक होती है।

दृश्य-प्रकाश अकेले कैमरा और द्वि-प्रकारीय कैमरा को आमने-सामने रखें तो मूल्य और सटीकता आपस में अलग-अलग दिशाओं की ओर इशारा करते हैं। केवल दृश्य-प्रकाश कैमरा लगे उपकरण का मूल्य सस्ता होता है, पर कोहरे या प्रति-प्रकाश, रात में झूठ पकड़ने या असली आग चूकने का अनुपात बढ़ जाता है। EFNNet की तरह ताप तक साथ देखने वाला द्वि-प्रकारीय उपकरण mAP50 97.2 प्रतिशत का प्रदर्शन दिखाता है, पर अवरक्त सेंसर का अपना मूल्य महँगा होता है और छवि की विभेदन क्षमता तुलनात्मक रूप से कम होती है। परिशुद्धता और लागत दोनों को साथ पकड़ने वाला उपकरण अभी नहीं आया, इसकी संभावना अधिक है। स्थानीय स्वशासन के बजट से पूरे पहाड़ पर कैमरा लगाने की स्थिति में, सस्ते दृश्य-प्रकाश कैमरे को सघन रूप से बिछाने वाले पक्ष और महँगे द्वि-प्रकारीय कैमरे को विरल अंतराल पर रखने वाले पक्ष के बीच लगातार तौलना पड़ता है।

तकनीक अभी जो नहीं कर पाती उसे भी शांत मन से रेखांकित करना चाहिए। वनाग्नि वाले दिन कम होने से, SMOTE से आँकड़ों को कृत्रिम रूप से बढ़ाने की प्रक्रिया में वास्तविकता से भिन्न नकली प्रतिरूप घुल-मिल जाने का खतरा है। गहरे पहाड़ के भीतर LTE या 5G संकेत बार-बार कट जाता है, इसलिए उच्च गुणवत्ता वाली छवि को केंद्रीय सर्वर तक तत्क्षण नहीं भेजा जा सकता। वनाग्नि न लगने पर भी मॉडल चेतावनी बजाए तो अग्निशमन बल और हेलीकॉप्टर व्यर्थ चक्कर लगाते हैं और बजट रिसता है। इसके विपरीत असली वनाग्नि की अनदेखी हो जाए तो आरंभिक प्रतिक्रिया विलंबित होकर क्षति बढ़ जाती है। इसीलिए एनवीडिया जेटसन (Jetson) की तरह ड्रोन पर लदे लघु कंप्यूटर, यानी एज कंप्यूटिंग (Edge AI) उपकरण के भीतर ही तुरंत गणना पूरी करनी होती है, पर यदि मॉडल को पर्याप्त हल्का छाँटा न जाए तो निर्णय विलंबित होता है और स्वर्णिम समय चूक जाता है। विज्ञान ट्रांसफॉर्मर या त्रि-आयामी संवलन तंत्रिका जाल की तरह अच्छे प्रदर्शन वाले मॉडल में उसने ऐसा निर्णय क्यों किया यह इंसान के लिए झाँककर देखना कठिन होने की समस्या भी बनी रहती है। आपदा-रोकथाम अधिकारी के दृष्टिकोण से मशीन के दिए निर्णय को अपने नाम पर स्वीकृत करना आसान नहीं होता।

आगे बचा काम दो दिशाओं में दिखता है। SHAP या Grad-CAM से निर्णय के आधार को छवि पर दर्शाने, और ताप एवं हवा के भौतिक समीकरणों को तंत्रिका जाल में डालने वाली शोध एक ओर है। दूसरी ओर कम-बिजली सेंसर जाल और द्वि-प्रकारीय ड्रोन को जोड़ने, और चेतावनी के घटनास्थल तक पहुँचने में लगने वाले समय को उपकरण और संचार शर्तों के अनुसार नापने का काम हो रहा है। वनाग्नि और रोग-कीट, सूखे के तनाव को एक ही निगरानी जाल में साथ सँभालने की परिकल्पना तो सामने आई, पर पहाड़ के भीतर 1 मिनट के भीतर मानवरहित प्रतिक्रिया पूरी कर देने वाली संपूर्ण व्यवस्था अभी प्रमाणित नहीं हुई है।

स्रोत और संदर्भ

1. Akhyar, A., Lee, J., Shahar, N., Saputro, A. H., & Zulkifley, M. A. (2026). Automated forest fire detection in ecological monitoring using enhanced deep learning networks. *Scientific Reports*, 16, Article 2039. <https://doi.org/10.1038/s41598-025-31707-6>
2. Amoah-Nuamah, J., Child, B., Okyere, E. Y., Adams, O., & Danquah, J. A. (2025). Applications of artificial intelligence in forest health surveillance and management. *Discover Forests*, 1, Article 56. <https://doi.org/10.1007/s44415-025-00061-w>
3. Earth Fire Alliance. (2026, 7 जुलाई). Earth Fire Alliance's first three operational FireSats reach orbit. <https://earthfirealliance.org/news-article/earth-fire-alliances-first-three-operational-firesats-reach-orbit/> (2 अगस्त 2026 को अभिगमति)
4. Hindarto, D., Sani, A., & Gunawan, A. (2026). Deep learning-based forest fire classification using MobileNetV3, ResNet50, and YOLOv8. *Journal of Computer Networks, Architecture and High Performance Computing*, 8(2), 193-204. <https://doi.org/10.47709/cnahpc.v8i2.8112>
5. Kang, Y., Lee, S., Cho, D., et al. (2026). Deep learning-based forecasting provides a pathway to closing wildfire information gaps in underserved regions. *Communications Earth & Environment*. <https://doi.org/10.1038/s43247-026-03692-9>
6. Kundu, S., Ninoria, S. Z., Chaturvedi, R. P., Mishra, A., Agrawal, A., Batra, R., Dubale, M., & Hashmi, A. (2025). Real-time deforestation anomaly detection using YOLO and LangChain agents for sustainable environmental monitoring. *Scientific Reports*, 15, Article 39961. <https://doi.org/10.1038/s41598-025-23617-4>
7. Lee, C., Choi, E. H., Han, Y., & Lee, Y. (2025). Year-round daily wildfire prediction and key factor analysis using machine learning: a case study of Gangwon State, South Korea. *Scientific Reports*, 15, Article 29910. <https://doi.org/10.1038/s41598-025-15508-5>
8. Malashin, I. P., Masich, I., Nelyub, V., Borodulin, A., Gantimurov, A., & Tynchenko, V. (2025). Assessing wildfire extents in Siberian forests using machine learning. *Scientific Reports*, 15, Article 32834. <https://doi.org/10.1038/s41598-025-17465-5>
9. Mousa, M. H., Algamdi, A. M., Fouad, Y., & Elshewey, A. M. (2026). CNN-MLP framework for forest burned areas prediction using PSO-WOA algorithm. *Scientific Reports*. <https://doi.org/10.1038/s41598-026-35836-4>
10. Nguyen, T. T., Phan, V. T., Nguyen, T. H., & Duong, T. D. (2026). Individual tree detection and crown segmentation for Pinus kesiya using UAV-LiDAR and deep learning models. *Dendrobiology*, 95, 156-169. <https://doi.org/10.12657/denbio.095.011>
11. Radhi, A. A., & Ibrahim, A. A. (2026). An intelligent IoT-machine learning framework for wildfire detection and prediction using a hybrid RF-XGB model. *Scientific Reports*. <https://doi.org/10.1038/s41598-026-52395-w>
12. Vibhandik, P., Sawant, S., Joshi, A., & Bidwe, R. (2026). A systematic literature review on forest fire susceptibility mapping using geo-spatial technologies and machine learning. *Discover Artificial Intelligence*, 6, Article 396. <https://doi.org/10.1007/s44163-026-00921-0>

13. Yang, D. Q., & Wu, J. J. (2026). 融合可见光与热红外图像的无人机早期森林火灾深度学习检测 [मानवरहति यान के दृश्य-प्रकाश एवं थर्मल अवरोक्त संलयन छविविधधरति आरंभकि वनाग्नडीप लरनगि संसूचन तकनीक]. National Remote Sensing Bulletin, 30(6), 1647-1663. <https://doi.org/10.11834/jrs.20265227>
14. Yang, S., Kim, W., Sung, T., Lee, S., Lee, G., Xu, Z., & Im, J. (2026). Satellite-based wildfire monitoring across the fire lifecycle using artificial intelligence: trends, challenges, and future directions. Korean Journal of Remote Sensing, 42(3), 315-341. <https://doi.org/10.7780/kjrs.2026.42.3.3>
15. राष्ट्रिय वन वज्जिज्ञान संस्थान. (2026). राष्ट्रिय वनाग्नजोखमि पूर्वानुमान प्रणाली. <https://forestfire.nifos.go.kr> (2 अगस्त 2026 को अभगिमति)
16. वन प्रशासन. (2025, 18 अप्रैल). ग्योंगबुक, ग्योंगनाम, उल्सान वनाग्नक्षतिपरिमाण अस्थायी रूप से 104 हजार हेक्टेयर, वन प्रशासन पुनर्नरिमाण में पूरी कोशिश. https://www.forest.go.kr/kfswweb/cop/bbs/selectBoardArticle.do?bbsId=BBSMSTR_1036&nttId=3206769 (3 अगस्त 2026 को अभगिमति)
17. कोरिया गणराज्य सरकार. (2025). वनाग्नक्षतिपुनर्नरिमाण लागत कुल 1 खरब 88 अरब 9 करोड़ वोन, अब तक की सबसे बड़ी राशकि समर्थन. https://gonggam.korea.kr/newsContentView.es?content=NC002&news_id=f4f9ac3e-81e6-4479-a9e2-6f8cf1c6a34b (3 अगस्त 2026 को अभगिमति)

3.2

कीट-रोग (चीड़ का सूत्रकृमि रोग आदि) एवं मृत वृक्ष (Dead Tree) का प्रारंभिक प्रतिबिंब-आधारित निदान

बुधवार की सुबह-सुबह, गंगवोन प्रांत के पर्वत की तलहटी चढ़ते हुए तीन सर्वेक्षण-दल सदस्यों के कदमों की आहट सूखे पत्तों पर सरसराती है। पीठ के थैले में GPS उपकरण और आनुवंशिक निदान किट रखे हैं, और गले में दूरबीन लटकी है। जब भी वे एक कगार पार करते हैं, एक व्यक्ति रुककर दूरबीन को आँखों से लगाता है। हरियाली से ढकी ढलान में कहीं लाल-भूरे रंग में बदल गए तीन-चार चीड़ के पेड़ ढूँढ़ना आज का काम है। मिल जाने पर निर्देशांक अंकित करते हैं, तने में छेदक यंत्र घुसाकर बुरादा निकालते हैं, और उसी जगह संक्रमण की जाँच करते हैं। जिन पेड़ों को मरे बहुत समय हो चुका है, उनमें राल की गंध तक फीकी पड़ चुकी होती है।

पर इस तरीके में एक निर्णायक कमी है। जब चीड़ की सुइयाँ लाल दिखने लगती हैं, तब पहले ही देर हो चुकी होती है। चीड़ के सूत्रकृमि रोग (Pine Wilt Disease) से ग्रस्त पेड़, जिस क्षण वाहक कीट जापानी चीड़ भृंग अपने शरीर में सूत्रकृमि को ले जाता है, उसी क्षण से धीरे-धीरे सूखकर मरने लगता है, और यदि हाथ न लगाया जाए तो तीन-चार साल के भीतर पूरा एक जंगल सिरे से लाल पड़ सकता है। फिर भी मनुष्य की आँख को रंग बदला दिखने में कुछ हफ्तों लग जाते हैं। उन कुछ हफ्तों के बीच वाहक कीट दूसरे पेड़ पर उड़ जाता है, और संक्रमण चुपचाप फैलता जाता है। जिस क्षण सर्वेक्षण दल दूरबीन से लाल पेड़ ढूँढ़ निकालता है, वह पेड़ पहले ही मौत की दहलीज़ पार कर चुका होता है और फैलाव पहले ही शुरू हो चुका होता है।

संक्रमित पेड़ को ढूँढ़ लेने के बाद भी काम खत्म नहीं होता। पेड़ को काटकर गिराना पड़ता है, और उसे पूरा का पूरा चूर्णक यंत्र में डालकर बारीक करना पड़ता है, या फिर उसी जगह प्लास्टिक से ढककर धूम्रन औषधि डालकर वाहक कीट के डिंभ तक को नष्ट करना पड़ता है। एक व्यक्ति एक दिन में चलकर जितनी पहाड़ी ढलान देख सकता है वह ज़्यादा चौड़ी नहीं होती, और जहाँ पेड़ घने होते हैं वहाँ तो गति और भी गिर जाती है। एक सर्वेक्षण-दल सदस्य दिन भर चलकर भी बमुश्किल छोटे पहाड़ों के कुछ मोड़ ही घूम पाता है।

इस गति को मनुष्य की आँख से पकड़ना मुश्किल है, इस निर्णय के तहत, वन विभाग ने सितंबर 2025 में शरद ऋतु की रोकथाम कार्यान्वयन योजना पेश करते हुए बताया कि वह हेलिकॉप्टर और ड्रोन सर्वेक्षण में कृत्रिम बुद्धिमत्ता और लाइडार (LiDAR, प्रकाश छोड़कर उसके वापस लौटने का समय नापकर दूरी पता लगाने वाला उपकरण) को जोड़ेगा। संक्रमण के संदिग्ध पेड़ छाँटने का काम पहले AI संभालता है, और मनुष्य उस परिणाम को आनुवंशिक निदान किट से जाँचता है, यही क्रम है। जिन राष्ट्रीय अग्रिम क्षेत्रों, बैकडुडेगान पर्वतमाला और ग्युमगांग चीड़ वन की रक्षा अवश्य करनी है, वहाँ पहले विशेषज्ञ कर्मी और उपकरण भेजे गए। बसान के गिजांग-गुन ने भी जून 2026 में चलकर देखने में कठिन पर्वतीय भू-आकृति

और अंध क्षेत्रों में ड्रोन उड़ाकर उच्च-विभेदन ऑर्थो तस्वीरें ली, और संक्रमण के संदिग्ध पेड़ों की स्थिति बुसान नगर के साथ साझा करने का सर्वेक्षण शुरू किया।

रंग बदलने से पहले को पढ़ने की तकनीक

जब पेड़ किसी रोगजनक से संक्रमित होता है, तो तने के भीतर जल-मार्ग यानी वाहिनी (पोषक तत्व और पानी को ऊपर-नीचे ले जाने वाली नलीनुमा ऊतक) बंद हो जाती है। पानी ऊपर न खींच पाने वाला पेड़ पत्तियों के पिछले हिस्से के रंध्र बंद करके जल-हानि रोकने का प्रयास करता है, और उसी क्षण वाष्पोत्सर्जन क्रिया (पत्तियों से पानी जलवाष्प बनकर निकलती है और पेड़ को ठंडा करती है) तेज़ी से गिर जाती है। बंद कर दिए गए एयर कंडीशनर वाले कमरे की तरह पत्तियों की सतह का तापमान धीरे-धीरे बढ़ने लगता है। यह संकेत पत्तियों के लाल होने से कुछ हफ्ते पहले ही दिखने लगता है। मनुष्य की आँख को अब भी हरा दिखता है, पर पेड़ के भीतर संकट पहले ही शुरू हो चुका होता है।

इस सूक्ष्म तापमान अंतर को पकड़ने वाला उपकरण मानवरहित विमान पर लगा तापीय अवरक्त संवेदक है। शिखा-तापमान और NDVI-SAVI जैसे वनस्पति सूचकांक तथा मौसम संबंधी आँकड़ों को आपस में जोड़ने पर आँखों से रंग बदलने के पहले का तनाव संकेत खोजा जा सकता है। यथार्थता वृक्ष-प्रजाति, तस्वीर लेने के समय, छाया और जल-स्थिति के अनुसार बदलती है। एक ही पेड़ की सुबह, दोपहर और शाम को बार-बार तस्वीर लेने से छाया से बने झूठे संकेत और शारीरिक तनाव के संकेत के बीच फ़र्क करने में मदद मिलती है। केवल इस संकेत से रोगजनक की पुष्टि नहीं की जा सकती, इसलिए इसके बाद मौके पर लिए नमूने की जाँच होनी चाहिए।

इन कुछ दिनों, कुछ हफ्तों का अंतर वास्तविक रोकथाम स्थल पर निर्णायक होता है। पत्तियों के लाल होने के बाद संक्रमित पेड़ ढूँढ़ने पर इस बात की प्रबल संभावना होती है कि उस पेड़ पर घूमता रहा वाहक कीट पड़ोसी कई पेड़ों पर अंडे दे चुका होगा, पर रंग बदलने से पहले वाली अवस्था में पकड़ लेने पर उस एक ही पेड़ को काटकर फैलाव रोका जा सकता है। प्रारंभिक निदान तकनीक जिसका पीछा करती है वह इन्हीं कुछ दिनों का समय है।

रंग नहीं बल्कि संघटक को देखने वाला एक तरीका भी है। पत्तियों के लाल होने से पहले भी हरितलवक, जल और वर्णक का अनुपात बदल जाता है, और यह बदलाव लाल-किनारे (रेड एज) और लघु-तरंग अवरक्त में संकेत के रूप में पकड़ा जाता है। अमेरिका के वन विभाग और मिनेसोटा विश्वविद्यालय के शोधकर्ताओं के बलूत-प्रयोग में सूखे के तनाव को अधिकतम 27 दिन और बलूत मुरझान रोग की प्रतिक्रिया को अधिकतम 24 दिन पहले पहचान लिया गया। स्पेन के शोधकर्ताओं के 2021 के अध्ययन ने *Phytophthora cinnamomi* संक्रमण और जल-तनाव से होने वाले बलूत क्षय रोग (oak decline) को उच्च-वर्णक्रमीय एवं तापीय अवरक्त प्रतिबिंब से जाँचा। बलूत मुरझान रोग (oak wilt) और बलूत क्षय रोग के रोगजनक और रोगविज्ञान अलग हैं।

चीड़ के सूत्रकृमि रोग में भी यही तरीका आजमाया जा रहा है। एक शोध दल के 2025 में रिमोट सेंसिंग में प्रकाशित अध्ययन ने UAV उच्च-वर्णक्रमीय प्रतिबिंब में वर्णक सूचकांक और जल-मात्रा सूचकांक को साथ पढ़कर संक्रमण के आरंभिक जैव-रासायनिक तनाव का पीछा किया। पत्ती के भीतर वर्णक के विघटित होने की गति और जल के निकलने की गति हर पेड़ में अलग-अलग प्रकट होती है, इसलिए दोनों सूचकों को

आपस में मिलाकर देखने पर केवल एक को देखने की तुलना में झूठी पहचान घटती है। 2024 में एक अन्य शोध दल ने हर महीने UAV से एक ही वृक्ष-समूह की खींची गई समय-श्रेणी छवियों में गहन अधिगम (कई परतों वाले कृत्रिम तंत्रिका जाल से पैटर्न सीखने की तकनीक) जोड़कर, संक्रमण की अवस्था और एक महीने में रोग के फैलने की दूरी दोनों की गणना कर ली। चिनार पौध पर किए गए 2024 के अध्ययन में कई समय-बिंदुओं के आँकड़ों को ResNet18 और CBAM, LSTM को जोड़कर बने मॉडल में डालकर किस्म और सूखे के तनाव को पहचानने में 99.69% की अत्यंत उच्च यथार्थता दर्ज की गई। केवल संख्या देखने पर लगता है मानो कृत्रिम बुद्धिमत्ता पेड़ के मन की बात पूरी तरह पढ़ लेती है, पर यह यथार्थता ज्यादातर नियंत्रित प्रायोगिक वनों से मिले मान हैं, यह याद रखने लायक है।

उपग्रह, मानवरहित विमान और भूमिस्थ संवेदकों को परत-दर-परत जोड़कर उपयोग करने की धारा इस समूचे क्षेत्र में व्याप्त है। 2026 में फ्रंटियर्स इन प्लांट साइंस में छपी एक व्यापक समीक्षा ने व्यापक क्षेत्र को खंगालने वाली उपग्रह दूरसंवेदन, मध्यम क्षेत्र संभालने वाली मानवरहित विमान उच्च-वर्णक्रमिकी और सँकरे क्षेत्र को सूक्ष्मता से नापने वाले भूमिस्थ संवेदकों को एक साथ जोड़ने वाला प्रेक्षण-जाल वृक्ष-प्रजाति वर्गीकरण से लेकर वन आपदा निगरानी और वृक्ष स्वास्थ्य आकलन तक हर जगह उपयोग हो रहा है, यह संक्षेप में बताया।

पहले ही मर चुके पेड़ों को गिनने वाली आँख

आरंभिक निदान से चूक गया पेड़ अंततः तने तक लाल पड़ता जाता है, फिर सारी पत्तियाँ गिराकर धूसर रंग में सूख जाता है। इस तरह खड़े-खड़े मर गए पेड़ को वन क्षेत्र में मृत खड़ा वृक्ष (Standing Dead Tree) कहते हैं, और ये पेड़ कहाँ कितने हैं यह गिनने का काम भी अब तक आसान चुनौती नहीं है। 2026 में Chowdhury आदि चौदह शोधकर्ताओं ने अड़तीस शोध-पत्र इकट्ठा कर विश्लेषित की गई समीक्षा देखें तो, जहाँ मृत वृक्ष छिटपुट बिखरे हों उन जंगलों में YOLO (You Only Look Once, छवि को एक ही बार में खंगालकर वस्तु की स्थिति वास्तविक समय में ढूँढ़ने वाला एल्गोरिद्म) श्रेणी के मॉडल मज़बूत होते हैं। 2022 में प्रकाशित LDS-YOLO को वातरोधी वन जैसी उन जगहों के लिए, जहाँ पेड़ छोटे और पृष्ठभूमि जटिल हो, हल्की संरचना के साथ छोटे मृत वृक्षों को न चूकने के लिए बनाया गया था। जब एक पेड़ छवि में कुछ ही पिक्सल जितना होता है, तब भारी मॉडल उन कुछ पिक्सलों को उलटे पृष्ठभूमि शोर मानकर मिटा देने की प्रवृत्ति रखता है। 2025 में आए एक अध्ययन ने दोहरे पथ से विशेषताएँ निकालकर जोड़ने के तरीके से मृत वृक्षों के जमघट वाले हिस्सों की झूठी पहचान घटाई।

समस्या उन हिस्सों की है जहाँ पेड़ घने जमे होकर उनकी शिखाएँ आपस में ओवरलैप करती हैं। ड्रोन तस्वीर के ऊपर से देखने पर यह हरे बादलों के आपस में सटे रूप जैसा दिखता है। कहाँ तक एक पेड़ की शिखा है और कहाँ से बगल का पेड़ शुरू होता है, मनुष्य की आँख से भी सीमा खींचना मुश्किल होता है। ऐसी जगहों पर चौकोर बॉक्स से केवल स्थिति दर्शाने वाली वस्तु-पहचान से बेहतर वह विभाजन (सेगमेंटेशन) मॉडल होता है जो हर पिक्सल पर दर्शाए कि जीवित पेड़ है या मृत पेड़। जर्मनी के शोधकर्ताओं ने 2021 में पेश किया सिल्वी-नेट (Silvi-Net) दो संवलन तंत्रिका जालों को साथ-साथ चलाकर वृक्ष-प्रजाति वर्गीकरण और मृत वृक्ष निर्धारण एक साथ संभालता था। Chowdhury आदि की समीक्षा ने FSC-Mask2Former और ADA-Net जैसे हाल के मॉडलों तक को संकलित किया। भिन्न-भिन्न स्रोतों से निकली परिशुद्धता को तस्वीर लेने की स्थिति और मूल्यांकन सूचक के साथ ही देखना चाहिए।

इस क्षेत्र में ध्यान देने योग्य बदलाव आँकड़े जमा करने का तरीका है। 2026 में मोज़िक (Mosig) और काटेनबॉर्न (Kattenborn) आदि ने रिमोट सेंसिंग ऑफ एनवायरनमेंट में परिचित कराया deadtrees.earth पूरे विश्व में खींची गई सेंटीमीटर-स्तरीय हवाई तस्वीरों के हज़ारों नमूने एक साथ इकट्ठा किया गया खुला डेटाबेस है। यह दस लाख हेक्टेयर से अधिक क्षेत्रफल समेटे है, और उसमें से अट्ठावन हज़ार हेक्टेयर से अधिक क्षेत्र में मनुष्यों ने स्वयं जीवित पेड़ों और मृत पेड़ों को पहचानकर चिह्नित कर रखा है। कोई भी अपनी खींची ड्रोन तस्वीर अपलोड करे तो AI पहले वर्गीकरण करता है, और मनुष्य उस परिणाम को सुधार दे तो मॉडल फिर से सीखता है, यही संरचना है। एक देश, एक जंगल में अच्छा चलने वाला मॉडल दूसरी जगह बेकार साबित होने की समस्या को सुलझाने का यह प्रयास है। यूरोपीय स्पूस वन में अच्छा बैठने वाला मॉडल कोरियाई चीड़ वन में ज्यों का त्यों ले जाने पर पत्तियों का रूप भी और पेड़ों के उगने का घनत्व भी अलग होने से अक्सर सिरे से फिर सिखाना पड़ता है, पर ऐसे खुले डेटाबेस जितने बड़े होते जाएँगे उतनी वह मेहनत घटेगी, ऐसा लगता है।

विभेदन कितना महत्वपूर्ण है यह 2025 में प्रकाशित एक प्रयोग बखूबी दिखाता है। शोधकर्ताओं ने एक ही चीड़ वन को मानवरहित विमान से 7 सेंटीमीटर विभेदन तक, चीन के स्वदेशी उपग्रह BJ3N से 30 सेंटीमीटर, BJ3A से 50 सेंटीमीटर तक घटाते हुए सूत्रकृमि रोग से संक्रमित पेड़ों को U-Net से ढूँढा। मानवरहित विमान छवि ने F1 अंक (परिशुद्धता और पुनःप्राप्ति दोनों को साथ आँकने वाला मूल्यांकन सूचक) में 89.1% दर्ज किया, और कई बैंड जोड़कर 30 सेंटीमीटर बनाई गई उपग्रह छवि भी 88.9% तक साथ आ गई। पर बिना संशोधन के मूल विभेदन 1.2 मीटर और 2 मीटर वाली उपग्रह छवि को ज्यों का त्यों उपयोग करने पर बात बदल गई। अंक क्रमशः 66.6% और 58% तक गिर गए। इसका अर्थ है कि जिस क्षण एक पिक्सल एक पेड़ से बड़ा हो जाता है, कृत्रिम बुद्धिमत्ता की आँख भी साथ में धुँधली पड़ जाती है।

फैलाव के रास्ते को चित्रित करना

एक पेड़ का निदान करना और पूरे जंगल में रोग कहाँ फैलेगा यह चित्रित करना अलग-अलग चुनौतियाँ हैं। पहले जिस शोध दल की बात हुई, जिसने हर महीने UAV से एक ही जंगल की तस्वीर ली, उसने समय-श्रेणी छवियों को आपस में जोड़कर संक्रमण की अवस्था के साथ-साथ एक महीने में रोग के फैलने की दूरी तक की गणना की। हर ऋतु बदलने पर एक ही वृक्ष-समूह की बार-बार तस्वीर लेकर बहु-वर्णक्रमीय और तापीय अवरोध छवियों को परत-दर-परत जमा करने पर रोग के फैलने का अग्रिम मोर्चा मानचित्र के रूप में चित्रित किया जा सकता है, और इस तरह बनाया मानचित्र अगली बार कहाँ से रोकथाम करनी है यह तय करने में काम आता है। मानचित्र पर रंग गहरा होने की दिशा का पीछा करने से, अब तक असंक्रमित स्वस्थ जंगल के किनारे पर पहले से रोकथाम-रेखा खींचना भी संभव हो जाता है। रोग पूरी तरह फैल जाने के बाद पीछा करने के बजाय, फैलाव के रास्ते को पहले ही रोक देना, यही बात है। गिजांग-गुन ने सर्वेक्षण परिणाम बुसान नगर के साथ साझा करने का निर्णय भी इसी संदर्भ में लिया। जब सूचना एक स्थानीय निकाय के भीतर समाप्त न होकर पड़ोसी स्थानीय निकाय तक जुड़ती है, तब फैलाव मानचित्र प्रशासनिक सीमा को लाँघकर भी अधिक उपयोगी हो जाता है।

रोकथाम कर लेने से बात खत्म नहीं होती। हवाई औषधि छिड़कने या वृक्ष-इंजेक्शन देने या संक्रमित पेड़ काटकर धूम्रन करने के बाद, 2 से 3 सप्ताह के अंतराल पर उसी जगह की फिर तस्वीर लेकर स्वस्थ संदर्भ

क्षेत्र से वर्णक्रमीय सूचकांक और शिखा-तापमान की तुलना करने पर यह संख्याओं में जाँचा जा सकता है कि रोकथाम वास्तव में कितनी कारगर रही। तुर्किये के सेविंच (Sevinç) ने 2025 में साइंटिफिक रिपोर्ट्स में प्रकाशित अध्ययन में यांत्रिक, रासायनिक और जैविक रोकथाम साधनों का काष्ठ उत्पादन और वन स्वास्थ्य पर प्रभाव कृत्रिम तंत्रिका जाल से अलग-अलग आँककर, कौन-सा संयोजन एकीकृत कीट-रोग प्रबंधन (IPM) रणनीति के अनुकूल है इसका आधार छोड़ा। यदि केवल रासायनिक औषधि पर अड़ा जाए तो मिट्टी और निकटवर्ती नदी पर बोझ पड़ता है, और केवल जैविक रोकथाम उपयोग करें तो अक्सर रोकथाम की गति फैलाव की गति के पीछे रह जाती है, इसलिए परिणाम को संख्या में दर्ज कर रखने का काम स्वयं अगली ऋतु की रणनीति तय करने में बल देता है। चीन में भी इसी तरह की धारा है। 2026 में कृषि विज्ञान (农业科学) में छपे दो शोध-पत्रों ने मानवरहित विमान दूरसंवेदन तकनीक को वन संसाधन सर्वेक्षण और कीट-रोग रोकथाम से जोड़ने की योजना, तथा बुद्धिमान तकनीक को कीट-रोग रोकथाम और सूक्ष्म प्रबंधन से जोड़ने की योजना अलग-अलग संकलित की।

चीड़ से आगे नज़र दौड़ाएँ तो छाल भृंग (Bark Beetle) क्षति में भी ऐसी ही धारा दिखती है। जुलाई 2026 में रिमोट सेंसिंग में छपे एक शोध-पत्र ने बताया कि यूरोपीय अंतरिक्ष एजेंसी के सेंटीनल-2 उपग्रह द्वारा हर सप्ताह ली गई छवियों को वृक्ष की आयु या भू-आकृति जैसी स्थिर सूचना के साथ XGBoost नामक मशीन अधिगम मॉडल में डालने पर, केवल उपग्रह छवि उपयोग करने या केवल स्थिर सूचना उपयोग करने की तुलना में, और पिछले शोध की तुलना में भी छाल भृंग की प्रारंभिक पहचान का प्रदर्शन बेहतर हुआ। चेक स्प्रूस वन को मानवरहित विमान उच्च-वर्णक्रमीय छवि से जाँचने वाले अन्य अध्ययन में स्वस्थ पेड़, संक्रमित पेड़ और मृत पेड़ को पहचानने की यथार्थता 81% तक निकली, जबकि उसी आँकड़े को मानवचालित विमान से लेने पर वह 73% पर ही रह गई। पर ऐसे अध्ययन एक स्वर में सीमा भी रेखांकित करते हैं। यह सीमा कि छाल भृंग के पेड़ के भीतर घुसने से लेकर वयस्क बनकर उड़ान भरने तक लगने वाला समय, उपग्रह या ड्रोन के शिखा के बदलाव को भाँपने जितना लंबा नहीं होता।

टकराते परिणाम और बचे हुए काम

एक ही समस्या को अलग उपकरण से सुलझाने पर उत्तर भी बँट जाते हैं। उच्च-वर्णक्रमीय संवेदक आँखों से अदृश्य वर्णक्रम बदलाव तक को पकड़कर पत्तियों के रंग बदलने से बहुत पहले भी संक्रमित पेड़ ढूँढ़ लेता है, पर उपकरण महँगा होता है और एक छवि में समाई सूचना की मात्रा अधिक होने से प्रसंस्करण समय भी लंबा लगता है। एक उच्च-वर्णक्रमीय कैमरे का दाम इतना अलग होता है कि उससे कई बहु-वर्णक्रमीय कैमरे खरीदे जा सकें, इसलिए पूरे विस्तृत राष्ट्रीय वन को केवल एक उच्च-वर्णक्रमीय उपकरण से खंगालने का तरीका बजट के आगे अक्सर अटक जाता है। RGB या बहु-वर्णक्रमीय छवि पर चलने वाले YOLO या U-Net श्रेणी सस्ते हैं और विस्तृत क्षेत्र को तेज़ी से खंगाल सकते हैं, पर उनमें यह कमी है कि पत्तियों के लाल हो जाने के बाद ही अच्छी तरह पकड़ते हैं। पहचान मॉडल चुनने का मानदंड भी जंगल के स्वरूप के अनुसार बँटता है। जहाँ मृत वृक्ष छिटपुट बिखरे हों उन पर्वतीय दुर्गम क्षेत्रों में YOLO श्रेणी का तेज़ी से खंगालते हुए गुज़र जाना लाभकारी होता है, पर जहाँ पेड़ घने ओवरलैप कर रहे हों उस मिश्रित वन में चौकोर बॉक्स आपस में ओवरलैप होकर झूठी पहचान बढ़ने के साथ U-Net या Mask R-CNN जैसे पिक्सल स्तर पर विभाजित करने वाले मॉडल आगे रहते हैं।

ड्रोन और उपग्रह चाहे कितने भी अच्छे हो जाएँ, आसमान से न दिखने वाले पेड़ रहते हैं। जहाँ ऊपरी शिखा घनी होती है उस जंगल में प्रकाशिक और तापीय अवरक्त संकेत सबसे ऊपरी परत में ही ज्यादातर लौट जाते हैं, और नीचे के पेड़ का आरंभिक संक्रमण ढक जाता है। एक पारिस्थितिकी तंत्र में उच्च यथार्थता देने वाला मॉडल भी भू-आकृति और वृक्ष-प्रजाति भिन्न जंगल में ले जाने पर प्रदर्शन में गिर सकता है। गिरावट का दायरा आँकड़े और सूचक के अनुसार अलग होता है, इसलिए इसे एक ही संख्या-परास में स्थिर नहीं किया जा सकता। मनुष्य द्वारा मृत वृक्ष की शिखा-सीमा खींचते समय पैदा होने वाला लेबल अंतर भी सत्यापन परिणाम को डगमगाता है।

शीतोष्ण शंकुधारी वन में सीखा मॉडल उपोष्ण चौड़ी-पत्ती वन में क्यों डगमगाता है, इसका कारण केवल यही नहीं कि मॉडल का प्रदर्शन खराब है। पत्ती की मोटाई और सतह का मोम, पेड़ों के उगने का घनत्व, मिट्टी की नमी तक सब भिन्न होने से मॉडल के सीखे और वास्तव में सामने आने वाले के बीच का अंतराल चौड़ा हो जाता है, यही कारण है।

अगला चरण दो दिशाओं में फैलता है। एक ओर वह काम है जिसमें बिना लेबल लगाई छवि मात्र से पैटर्न सीखने वाले स्व-पर्यवेक्षित अधिगम (Self-Supervised Learning) को deadtrees.earth जैसे संपूर्ण-भूमंडलीय डेटाबेस से जोड़कर, एक जंगल में सीखा मॉडल दूसरे जंगल में भी चले, ऐसा बनाया जाता है। दूसरी ओर वह काम है जिसमें तापीय अवरक्त, उच्च-वर्णक्रमिकी और लाइडार संवेदक को एक ही मानवरहित विमान पर साथ लादकर विमान के भीतर की छोटी गणना युक्ति में उसी जगह तुरंत गणना कर, संक्रमण के संदिग्ध पेड़ को ढूँढ़ने के 1 मिनट के भीतर मौके पर सूचना भेजने वाली मानवरहित रोकथाम व्यवस्था को पूरा किया जाता है। यदि सर्वेक्षण दल के थैले की दूरबीन किसी दिन ड्रोन और AI को अपनी भूमिका पूरी तरह सौंप दे, तो उस दिन इस बात की प्रबल संभावना होगी कि पेड़ के लाल होने से पहले ही हाथ लगाया जा चुका होगा।

स्रोत और संदर्भ

1. Briechle, S., Krzystek, P., & Vosselman, G. (2021). Silvi-Net: A dual-CNN approach for combined classification of tree species and standing dead trees from remote sensing data. *International Journal of Applied Earth Observation and Geoinformation*, 98, 102292. <https://doi.org/10.1016/j.jag.2020.102292>
2. Chowdhury, A. I., Beloiu, M., Kattenborn, T., Mosig, C., Ahishali, M., Vastaranta, M., Puttonen, E., Honkavaara, E., Huo, L., Uddin, M. J., Griess, V. C., Kuzmin, A., Cheng, Y., & Junttila, S. (2026). Remote sensing and deep learning for standing dead-tree detection and mapping: A review of advances, challenges, and future directions. *EarthArXiv*. <https://doi.org/10.31223/X5BZ05>
3. Han, Z., Hu, W., Peng, S., Lin, H., Zhang, J., Zhou, J., Wang, P., & Dian, Y. (2022). Detection of standing dead trees after pine wilt disease outbreak with airborne remote sensing imagery by multi-scale spatial attention deep learning and Gaussian kernel approach. *Remote Sensing*, 14(13), 3075. <https://doi.org/10.3390/rs14133075>
4. Hornero, A., Zarco-Tejada, P. J., Quero, J. L., North, P. R. J., Ruiz-Gómez, F. J., Sánchez-Cuesta, R., et al. (2021). Modelling hyperspectral- and thermal-based plant traits for the early detection of *Phytophthora*-induced symptoms in oak decline. *Remote Sensing of Environment*, 263, 112570. <https://doi.org/10.1016/j.rse.2021.112570>
5. Hou, R., Zhang, B., Fang, G., Yang, S., Guo, L., Huang, W., et al. (2025). Early detection of pine wilt disease by combining pigment and moisture content indices using UAV-based hyperspectral imagery. *Remote Sensing*,

- 17(11), 1833. <https://doi.org/10.3390/rs17111833>
6. Mosig, C., Kattenborn, T., Chowdhury, A. I., et al. (2026). deadtrees.earth: An open-access and interactive database for centimeter-scale aerial imagery to uncover global tree mortality dynamics. *Remote Sensing of Environment*, 332, 115027. <https://doi.org/10.1016/j.rse.2025.115027>
7. Nie, Z., Qin, L., Xing, P., Meng, X., Meng, X., Qin, K., & Wang, C. (2025). Ultra-high-resolution optical remote sensing satellite identification of pine-wood-nematode-infected trees. *Plants*, 14(22), 3436. <https://doi.org/10.3390/plants14223436>
8. Sapes, G., Schroeder, L., Scott, A., Clark, I., Juzwik, J., Montgomery, R. A., Guzmán Q., J. A., & Cavender-Bares, J. (2024). Mechanistic links between physiology and spectral reflectance enable previsual detection of oak wilt and drought stress. *Proceedings of the National Academy of Sciences*, 121(7), e2316164121. <https://doi.org/10.1073/pnas.2316164121>
9. Sevinç, V. (2025). Evaluating the effectiveness of the forest pests and diseases control methods on the industrial wood production using deep learning. *Scientific Reports*, 15, 34679. <https://doi.org/10.1038/s41598-025-06932-8>
10. Tan, C., Lin, Q., Du, H., Chen, C., Hu, M., Chen, J., et al. (2024). Detection of the infection stage of pine wilt disease and spread distance using monthly UAV-based imagery and a deep learning approach. *Remote Sensing*, 16(2), 364. <https://doi.org/10.3390/rs16020364>
11. Wang, L., Zhang, H., Bian, L., Zhou, L., Wang, S., & Ge, Y. (2024). Poplar seedling varieties and drought stress classification based on multi-source, time-series data and deep learning. *Industrial Crops and Products*, 218, 118905. <https://doi.org/10.1016/j.indcrop.2024.118905>
12. Wang, M., Zhang, Q., Liu, X., Zhang, J., Yu, F., Zhang, X., & Zhao, R. (2026). Research progress on multimodal data fusion in forest resource monitoring. *Frontiers in Plant Science*, 16, 1710618. <https://doi.org/10.3389/fpls.2025.1710618>
13. Wang, X., Zhao, Q., Jiang, P., Zheng, Y., Yuan, L., & Yuan, P. (2022). LDS-YOLO: A lightweight small object detection method for dead trees from shelter forest. *Computers and Electronics in Agriculture*, 198, 107035. <https://doi.org/10.1016/j.compag.2022.107035>
14. Yang, C., Lu, J., Fu, H., Guo, W., Shao, Z., Li, Y., Zhang, M., Li, X., & Ma, Y. (2025). Detection of pine wilt disease-infected dead trees in complex mountainous areas using enhanced YOLOv5 and UAV remote sensing. *Remote Sensing*, 17(17), 2953. <https://doi.org/10.3390/rs17172953>
15. Zeinali, S., Olsson, P.-O., Kronvall, T., Wiktorsson, M., & Lindström, J. (2026). Detection of bark beetle attacks using time-aggregated satellite data with machine learning. *Remote Sensing*, 18(13), 2234. <https://doi.org/10.3390/rs18132234>
16. मेट्रो सयोल. (27 जून 2026). गजिंग-गुन, इरोन का उपयोग कर चीड़ सूत्रकृमरोग की 'सूक्ष्म नगिरानी' संचालति। <https://www.metroseoul.co.kr/article/20260627500013> (2 अगस्त 2026 को अभगिति)
17. वशिव पर्यावरण समाचार. (25 जून 2026). वन वभिग, 2026 चीड़ सूत्रकृमरोग रोकथाम परणिगम घोषति। <https://www.e-newsp.com/news/article.html?no=88960> (2 अगस्त 2026 को अभगिति)
18. जंग छयोंग (Zhang, Q.). (2026). 林业资源调查与病虫害防治中无人机遥感技术的应用研究. *农业科学*, 9(6), 211-213. <https://doi.org/10.32629/as.v9i6.4090>
19. जंग येनयगि (Zhang, Y.). (2026). 智能化技术在林业资源病虫害防治与精细化管理中的应用研究. *农业科学*, 9(2), 202-204. <https://doi.org/10.32629/as.v9i2.3704>
20. इलेक्ट्रॉनिक टाइम्स. (24 सतिंबर 2025). वन वभिग, चीड़ सूत्रकृमरोग को AI से रोकेगा...रोकथाम कार्यान्वयन योजना बनाई। <https://www.etnews.com/20250924000152> (2 अगस्त 2026 को अभगिति)

3.3

अवैध वृक्ष-कटाई की ध्वनि पहचान और IoT/ब्लॉकचेन वन संरक्षण नेटवर्क

उष्णकटिबंधीय वर्षावन की ऊँची शाखाओं पर छोटे सौर पैनल और माइक्रोफ़ोन लगे उपकरण लटके रहते हैं। यह अमेरिकी गैर-लाभकारी संस्था रेनफ़ॉरेस्ट कनेक्शन का गार्जियन (Guardian) है। यह जंगल की आवाज़ का उपकरण पर ही विश्लेषण करता है और जब चेनसॉ या वाहन जैसी मानवीय घुसपैठ की सूचना देने वाली आवाज़ पकड़ में आती है तो चेतावनी भेजता है। संस्था की आधिकारिक वेबसाइट बताती है कि इस ध्वनि निगरानी परियोजना ने अब तक 7 लाख 26 हज़ार हेक्टेयर से अधिक क्षेत्र के संरक्षण में योगदान दिया है। सार्वजनिक रूप से बताए गए संचयी आँकड़े परियोजना-दर-परियोजना गिनती के समय और मानदंड में भिन्न होने के कारण उपकरणों की संख्या, रिकॉर्डिंग के घंटे और पुष्ट प्रजातियों की संख्या को एक ही उपलब्धि के रूप में तुलना करना कठिन बना देते हैं। उन्हीं रिकॉर्डिंग में पक्षियों, मेंढकों और कीटों की आवाज़ें भी दर्ज रहती हैं। घुसपैठ की चेतावनी के लिए लगाया गया माइक्रोफ़ोन जैव विविधता का अवलोकन करने वाला कान भी बन जाता है।

उपग्रह की तस्वीरें पेड़ के कट जाने के बाद ही उस तथ्य को दिखाती हैं। बादल छा जाएँ तो वह भी छूट जाता है। पैदल गश्त करने वाले दल का तरीका भी पूरे विशाल वन को हर दिन नहीं छान सकता। चेनसॉ चालू करके पेड़ गिराने के उन्हीं कुछ मिनटों के भीतर किसी को भनक लग जाए तभी इसे रोका जा सकता है, पर पुरानी विधियाँ उन कुछ मिनटों को पकड़ नहीं पातीं। इसीलिए पेड़ों पर लगे माइक्रोफ़ोन और सेंसर, कम-ऊर्जा संचार नेटवर्क, और आवाज़ को तुरंत परखने वाली कृत्रिम बुद्धिमत्ता को एक साथ जोड़ने वाला निगरानी तंत्र कई देशों में फैल रहा है।

आधी रात बीतने के बाद के समय में, माइक्रोफ़ोन पर दो लय में टूटती तरंग पकड़ में आने का क्षण आता है। यह वह इंजन ध्वनि की लय है जो तब बनती है जब कोई व्यक्ति ट्रिगर बार-बार दबाता और छोड़ता है। उपकरण के भीतर की छोटी चिप इस तरंग को कुछ ही सेकंड में छान लेती है, उसे शाखा टूटने की आवाज़ या मोटरसाइकिल के गुज़रने की आवाज़ से अलग पहचानती है, और विश्वास का एक अंक निर्धारित कर देती है। उसी क्षण से आवाज़ पहचानने वाली कृत्रिम बुद्धिमत्ता, मौक़े पर ही गणना पूरी कर देने वाला संचार नेटवर्क, और कटे हुए पेड़ कहाँ बहते जा रहे हैं इसका अंत तक पीछा करने वाला बहीखाता, ये तीन परतों की तकनीकें एक साथ चलने लगती हैं।

इंजन-आरी की आवाज़ पहचानने वाला जंगल का कान

चालित उपकरणों की इंजन ध्वनि वृक्ष-कटाई की सूचना देने वाला सुराग बनती है। पेड़ के तने या सहारे पर लगा अति-कम-ऊर्जा ध्वनि IoT सेंसर आसपास की आवाज़ ग्रहण करके लघु कंप्यूटर पर विश्लेषण करता है। आंद्रेआदिस शोध दल (Andreadis et al., 2021) ने आवाज़ की विशेषताएँ निकालने वाले संवलन तंत्रिका नेटवर्क को अति-कम-ऊर्जा उपकरण पर लगाया और लोरा संचार से चेतावनी भेजने वाला प्रारूप परखा। शोधपत्र में बताई गई वर्गीकरण सटीकता 85 प्रतिशत थी। यह सीमित प्रायोगिक आँकड़ों से प्राप्त परिणाम है। वन के प्रकार और मौसम, तथा उपकरण की आवाज़ बदल जाने पर वही सटीकता बनी रहेगी, ऐसा नहीं माना जा सकता।

मॉडल को इस तरह प्रशिक्षित करना सोच से अधिक पेचीदा है। मोटरसाइकिल या छोटे जनरेटर की इंजन ध्वनि की घूर्णन आवृत्ति चेनसों से मिलती-जुलती होने के कारण शुरुआती मॉडल को अक्सर भ्रमित कर देती थी। दूर कहीं पेड़ के अपने आप टूटने की आवाज़ और बिजली कड़कने की आवाज़ भी उसी तरह भ्रम पैदा करती है। शोध दल ने वास्तविक वृक्ष-कटाई स्थलों और सामान्य जंगल की जगह-जगह से कई महीनों की आवाज़ें जुटाई और इन उदाहरणों को एक-एक करके मॉडल को सिखाया, और उस प्रक्रिया से गुज़रने के बाद ही परिशुद्धता और पुनःप्राप्ति वास्तव में उपयोगी स्तर तक पहुँची। एक सेंसर कितनी दूरी तक सुन सकता है यह भूभाग और पेड़ों के घनत्व पर निर्भर करता है। इसीलिए पूरे विशाल संरक्षित क्षेत्र को ढँकने के लिए दसियों, सैकड़ों नोड जालीनुमा आकार में लगाने पड़ते हैं, और कहाँ कितने सघन लगाए जाएँ यह तय करने के लिए भी अलग गणना ज़रूरी होती है। लोगों के अक्सर आने-जाने वाले रास्तों या पहले जहाँ वृक्ष-कटाई ज़्यादा होती रही उन क्षेत्रों से प्राथमिकता तय करके तैनाती की जाती है।

कभी-कभी केवल आवाज़ पर्याप्त नहीं होती। घने पत्तों वाले जंगल में आवाज़ दूर तक नहीं फैल पाती और बीच में ही बिखर जाती है। प्रासेत्यो शोध दल (Prasetyo et al., 2018) ने चेनसों की आवाज़ के साथ-साथ, पेड़ काटते समय तने के सहारे संचारित होने वाले सूक्ष्म कंपन को भी एक साथ पकड़ने वाला सेंसर बनाया। केवल आवाज़ सुनने वाली विधि की तुलना में झूठी चेतावनी काफी घट गई। पेड़ आवाज़ और कंपन, इन दो संकेतों को एक साथ बहा देता है, और सेंसर इन दोनों में से एक के कमज़ोर पड़ने पर बाक़ी संकेत से निर्णय की भरपाई कर लेता है।

बैटरी से कई महीने टिकने वाला निर्णय और ड्रोन की रवानगी

दुर्गम वनों में रिकॉर्डिंग का मूल लगातार सर्वर पर भेजना कठिन होता है। मॉडल को उपकरण में डालकर प्राथमिक निर्णय पूरा कर लिया जाए, और चेनसाँ होने की संभावना अधिक होने पर केवल निर्देशांक और निर्णय-मान भेजा जाए तो संचार-मात्रा और ऊर्जा-खपत घटाई जा सकती है। लोरावान (LoRaWAN) की मूल संरचना ऐसी है जिसमें सेंसर गेटवे से सीधे संचार करता है, यानी स्टार ऑफ़ स्टार तरीका। यह मेश नेटवर्क की तरह पड़ोसी सेंसर के संकेत रिले करने वाली संरचना से भिन्न है। जहाँ तरंगें नहीं पहुँचतीं उन घाटियों में गेटवे और लगाने पड़ते हैं या अलग रिले तकनीक जोड़नी पड़ती है। शर्मा शोध दल (Sharma et al., 2022) के LoED ने लोरा और एज कंप्यूटिंग को जोड़ने वाली वन निगरानी संरचना प्रस्तावित की। यह सामान्यीकरण करने योग्य स्थल-परीक्षण प्रस्तुत नहीं किया गया कि सभी जंगलों में सूचना का समय 1 मिनट से कम होता है या संचरण-मात्रा 40 प्रतिशत घट जाती है। ऊर्जा-आयु भी पैनल के आकार, छाया, संचार की संख्या और मॉडल की गणना-मात्रा पर निर्भर करती है।

नियंत्रण केंद्र की स्क्रीन पर देखें तो यह सारी गणना मानचित्र पर एक बिंदु के जल उठने के रूप में सामने आती है। निर्देशांक और विश्वास-अंक तथा पास की गश्त-राह तक की बची दूरी साथ में उभरती है, और ड्यूटी पर मौजूद व्यक्ति तुरंत वायरलेस से पास के प्रवर्तन दल को बुला लेता है। जहाँ सड़कें लगभग नहीं होतीं उन दुर्गम वनों में इस क्षण के कुछ मिनट एक पेड़ को बचाने या न बचाने का अंतर बन जाते हैं। इस स्क्रीन की निगरानी करने वाला व्यक्ति प्रायः वन रक्षक या स्थानीय गैर-लाभकारी संस्था का स्थायी कर्मी होता है। भले ही कृत्रिम बुद्धिमत्ता ने चेतावनी छान कर दी हो, अंतिम रवानगी हो या नहीं यह व्यक्ति तय करता है। जहाँ बार-बार झूठी पहचान होती है उस क्षेत्र के मॉडल की संवेदनशीलता घटा देने जैसे तरीकों से, मनुष्य और मशीन एक-दूसरे के निर्णय को लगातार सुधारते रहने का संबंध बनाए रखते हैं।

चेतावनी वाले निर्देशांक पर ड्रोन भेजकर वीडियो की पुष्टि की जाए तो आवाज़ और वीडियो को दो चरणों में जोड़ा जा सकता है। रमादान शोध दल (Ramadan et al., 2024) ने ध्वनि सेंसर और मानवरहित यान को जोड़ने वाली संरचना प्रस्तावित की। कुंडू शोध दल (Kundu et al., 2025) ने अलग वीडियो आँकड़ों पर YOLOv8 और एजेंट-प्रकार की कृत्रिम बुद्धिमत्ता परखी। इस शोध की अधिकतम पुनःप्राप्ति लगभग 0.24 और mAP50 लगभग 0.07 पर ही रुकी। दोनों शोधपत्रों को मिलाकर यह कहने का आधार नहीं है कि स्वचालित रवानगी की व्यवस्था पहले से ही मौके पर तैनात है। फ़िलहाल ध्वनि चेतावनी के बाद व्यक्ति द्वारा वीडियो की पुष्टि की प्रक्रिया आवश्यक है।

ढूँठ से बिक्री-मंच तक चलने वाली डिजिटल छाप

जंगल में प्रवर्तन दल कितना भी परिश्रम करे, यदि पहले से कटा पेड़ वैध कागजात ओढ़कर बाज़ार में घुस जाए तो कोई लाभ नहीं होता। इसीलिए काटे गए ठोस लट्टे के परिवहन, प्रसंस्करण और निर्यात की पूरी प्रक्रिया का रिकॉर्ड ज़रूरी है। यूरोपीय संघ का वन-विनाश रोकथाम विनियमन (EUDR, Regulation 2023/1115) लकड़ी सहित अनुबंध I के उत्पादों को यूरोपीय संघ के बाज़ार में लाने वाले या निर्यात करने वाले व्यवसायियों पर उत्पादन-स्थल की भौगोलिक जानकारी और सम्यक जाँच का दायित्व लगाता है। 4 हेक्टेयर या उससे कम क्षेत्रफल वाला भूखंड अक्षांश और देशांतर के एक बिंदु से दर्शाया जा सकता है, और 4 हेक्टेयर से अधिक भूखंड के लिए सीमा खींचे बहुभुज निर्देशांक ज़रूरी होते हैं। सभी लकड़ी उत्पाद और सभी छोटे भूखंड बहुभुज प्रस्तुत करने के दायरे में नहीं आते।

ब्लॉकचेन एक वितरित बहीखाता तकनीक है जिसमें कई प्रतिभागी एक ही बही की प्रतियाँ आपस में बाँटकर रखते हैं। सहमति के बाद रिकॉर्ड चुपके से बदला गया या नहीं यह जाँचना आसान है, पर पहली बार दर्ज किया गया उत्पादन-स्थल या प्रजाति यदि झूठी हो तो वह झूठ भी वैसे ही बना रहता है। शटोफ़र शोध दल (Stopfer et al., 2024) और दूडर व रॉस (Düdder & Ross, 2017) ने लकड़ी आपूर्ति शृंखला के रिकॉर्ड साझा करने और सम्यक जाँच की लागत घटाने की संभावना का परीक्षण किया। केवल इसी तकनीक से वैध और अवैध लकड़ी के मिश्रण को रोका जा सके या हर एक पेड़ का इतिहास सुनिश्चित किया जा सके, इसका कोई स्थल-प्रमाण नहीं है। रिसेट ऑर्गनाइज़ेशन का ForestGuard वन-विनाश-रहित कॉफ़ी आपूर्ति शृंखला के लिए ओपन-सोर्स प्रारूप है और लकड़ी आपूर्ति शृंखला परियोजना नहीं है।

परिकल्पना-चित्र में यह प्रवाह खींचा जाता है कि कटाई मशीन निर्देशांक और व्यास दर्ज करती है, और परिवहन तथा चिराई चरणों के मापन उसी बही में जुड़ते चलते हैं। वास्तविकता में मशीन निर्माता और कंपनी के अनुसार आँकड़ों का प्रारूप भिन्न होता है, और ठोस लट्टा कई तख्तों में बँट जाने या दूसरी लकड़ी से मिल जाने के क्षण जोड़ने की कड़ी कमज़ोर पड़ जाती है। उत्पादन-स्थल प्रमाण सीमा-शुल्क और लेन-देन के लिए आवश्यक रिकॉर्ड बन सकता है, पर वह स्वयं ऊँची बिक्री-क्रीमत की गारंटी नहीं देता। सेंसर, मुद्रांकन, भौतिक चिह्न और स्थल-लेखा परीक्षण को एक साथ जोड़ने पर ही बही और वास्तविक लकड़ी के बीच का अंतर घटाया जा सकता है।

डिजिटल बही और वास्तविक ठोस लट्टे को जोड़ने वाला भौतिक चिह्न अब भी आवश्यक है। बारकोड, QR कोड, RFID जैसे टैग लगाए जा सकते हैं, पर कटाई मशीन के स्वतः चिह्न, चिराई मिल के लिडार, वृक्ष-वलय की छाप और ब्लॉकचेन को एक साथ जोड़ी गई व्यवस्था अभी सत्यापित नहीं है। त्रिप्लात शोध दल (Triplat et al., 2026) ने अलग फ़ोटो आँकड़ों से ठोस लट्टों को बाज़ार-मूल्य श्रेणी के अनुसार वर्गीकृत किया। यह शोध लकड़ी के इतिहास-अनुरेखण या त्रि-आयामी छाप-प्रमाणन का परीक्षण नहीं है।

कोरियाई कंपनियाँ भी यदि अनुबंध I के उत्पादों को यूरोपीय संघ के बाज़ार में लाने या निर्यात करने वाली आपूर्ति शृंखला में भाग लेती हैं तो विनियमन के प्रभाव में आ सकती हैं। फ़र्नीचर या प्लाईवुड नाम भर से दायरे में आना तय नहीं होता। संबंधित वस्तु का सीमा-शुल्क कोड, कंपनी की भूमिका और कच्चे माल के आपूर्ति मार्ग को साथ में जाँचना ज़रूरी है।

टकराते विकल्प, आपस में विरोधी गुण-दोष

एक ही समस्या से जूझने वाले शोध आपस में भिन्न उत्तर भी देते हैं। केवल एक ध्वनि सेंसर वाली विधि पर मौसम का लगभग असर नहीं पड़ता, आवाज़ होने के कुछ ही सेकंड में प्रतिक्रिया देती है, और उपकरण की कीमत भी अपेक्षाकृत सस्ती होती है। पर बिजली की गड़गड़ाहट, शाखा टूटने की आवाज़ या सूखी पत्तियों के घिसटने की आवाज़ से धोखा खाकर झूठी चेतावनी बजा देने की घटना होती है। उपग्रह रडार (SAR) या ड्रोन वीडियो तक साथ में उपयोग करने वाली विधि यह भी खींच देती है कि जंगल वास्तव में कितना कटा, पर छायांकन के अंतराल और बादल के कारण प्रतिक्रिया देर से आती है और स्थापना तथा संचालन में अधिक पैसा लगता है। तीव्र प्रतिक्रिया और व्यापक पुष्टि, इन दोनों को एक साथ पकड़ने का तरीका अभी नहीं है। झूठी चेतावनी बार-बार हो तो प्रवर्तन दल असली चेतावनी पर भी देर से प्रतिक्रिया देने लगता है, यह दुष्प्रभाव उत्पन्न होता है। परिशुद्धता बढ़ाने का काम आँकड़ों को सुंदर बनाने का काम नहीं, बल्कि स्थल-कर्मियों के विश्वास को बनाए रखने का मामला भी है।

ब्लॉकचेन की ओर भी विकल्प बँट जाते हैं। एथेरियम जैसा पूर्णतः सार्वजनिक ब्लॉकचेन कोई भी बही देख सकता है इसलिए पारदर्शी है, पर प्रति सेकंड संसाधित हो सकने वाले लेन-देन की संख्या कम है और शुल्क भी महंगा है। वृक्ष-कटाई के व्यस्त मौसम में चिराई मिल के तराजू पर प्रति घंटा सैकड़ों ठोस लट्टे तक चढ़ते हैं, पर सार्वजनिक ब्लॉकचेन की सत्यापन गति से इस प्रवाह के साथ नहीं चला जा सकता और अवरोध बन जाता है। इसीलिए लकड़ी आपूर्ति शृंखला के अधिकांश शोध विशिष्ट चिराई मिल और सरकारी संस्था ही बही तक पहुँच सकें, ऐसे Hyperledger Fabric जैसे निजी व कंसोर्टियम-प्रकार के ब्लॉकचेन की ओर झुके हुए हैं। जितना प्रतिभागियों को सीमित किया जाता है, आरंभ में जिस खुलापन को बनाए रखने का लक्ष्य था वह उतना ही घट जाता है।

अभी न सुलझी समस्याएँ और अगला काम

ठोस लट्टे पर लगाया बारकोड या RFID टैग कठिन पहाड़ी रास्ते के परिवहन तथा बरसात और कीचड़ में गिर जाने या टूट जाने की आशंका रखता है। ठोस लट्टे को चिरे हुए इमारती काठ या चिप में गढ़ते ही चिह्न स्वयं गायब हो जाने के मामले भी बहुत होते हैं, इसलिए प्रसंस्करण के बाद अनुरेखण टूट जाने की समस्या अभी नहीं सुलझी है। दुर्गम स्थान पर लगे ध्वनि सेंसर की परख-शक्ति तेज़ आँधी-पानी या वन्य पशुओं की आवाज़ से घट जाती है, और सौर बैटरी से कई-कई महीने टिकने के लिए ऊर्जा प्रबंधन भी आसान नहीं है। कुछ हेक्टेयर वाला छोटा जंगल रखने वाला कोई व्यक्तिगत वन-किसान अनजान ऐप से कटाई का रिकॉर्ड दर्ज करने का काम, और समर्पित कर्मी रखने वाली बड़ी कंपनी द्वारा प्रणाली संचालित करने का काम, प्रवेश-बाधा की ऊँचाई से ही भिन्न हैं। कम पूँजी वाले छोटे वन-किसान या मामूली वितरक की दृष्टि से यह बाधा ही तकनीक के प्रसार को रोकने वाली रुकावट है। उपकरण की पहली स्थापना की लागत से अधिक कई-कई साल तक चलने वाली रख-रखाव की लागत बड़ा बोझ बन जाने के मामले भी बहुत होते हैं। बैटरी और सौर पैनल बदलना, टूटे नोड को फिर खड़ा करना, और मॉडल को नवीनतम ध्वनि आँकड़ों से दोबारा प्रशिक्षित करना, ये काम परियोजना के आरंभिक उत्साह के ठंडे पड़ने के बाद भी किसी को लगातार संभालते रहने पड़ते हैं।

यूरोपीय संघ ने EUDR के लागू होने के समय को बार-बार समायोजित किया। मौजूदा कार्यक्रम में सामान्य व्यवसायी 30 दिसंबर 2026 से इसके दायरे में आते हैं। प्राकृतिक व्यक्ति के रूप वाले मामूली व लघु उद्यम, यदि उनकी स्थापना तिथि 31 दिसंबर 2024 तक की है, तो अलग रियायत के पात्र हैं। इनके लागू होने की तिथि 30 जून 2027 है। इसका यह अर्थ नहीं कि सभी छोटे व्यवसायियों को वही रियायत मिलती है। कंपनी के कानूनी स्वरूप और स्थापना तिथि को जाँचना ज़रूरी है।

पेड़ के डीएनए या स्थिर समस्थानिकों का विश्लेषण करने वाली विधि का सिद्धांत भिन्न है। लकड़ी के ऊतक में बचे आनुवंशिक व रासायनिक चिह्नों की मानक आँकड़ों से तुलना करके प्रजाति या उत्पादन-स्थल का अनुमान लगाया जाता है। चिह्न गिर जाने के बाद भी ऊतक का कुछ भाग बचा रहे तो जाँच की जा सकती है, पर मानक आँकड़ों के दायरे से बाहर के उत्पादन-स्थल को छाँटना कठिन है। प्रयोगशाला विश्लेषण में समय और लागत भी लगती है। स्थल पर ध्वनि चेतावनी, भौगोलिक जानकारी, भौतिक चिह्न, कागज़ात सत्यापन और नमूना जाँच को लागत के अनुरूप जोड़ना ज़रूरी है। स्टैनफ़ोर्ड (StanForD) वन मशीनों के कार्य व उत्पादन आँकड़ों के आदान-प्रदान का मानक है, अंतरराष्ट्रीय लकड़ी व्यापार का प्रपत्र नहीं। देश-दर-देश की सम्यक जाँच के आँकड़ों और सीमा-शुल्क तंत्र को एक ही ब्लॉकचेन से जोड़ने की परिकल्पना भी अभी प्रचलित संचालन मानक के रूप में स्थापित नहीं हुई है।

स्रोत और संदर्भ

1. Andreadis, A., Giambene, G., & Zambon, R. (2021). Monitoring illegal tree cutting through ultra-low-power smart IoT devices. *Sensors*, 21(22), 7593. <https://doi.org/10.3390/s21227593>
2. Düdler, B., & Ross, O. (2017). Timber tracking: Reducing complexity of due diligence by using blockchain technology. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3015219>
3. European Commission, Access2Markets. (28 जनवरी 2026). Delay until December 2026 and other developments in the implementation of the EUDR Regulation. <https://trade.ec.europa.eu/access-to-markets/en/news/delay-until-december-2026-and-other-developments-implementation-eudr-regulation> (2 अगस्त 2026 को अभगिति)
4. European Parliament and Council of the European Union. (2023). Regulation (EU) 2023/1115 of the European Parliament and of the Council of 31 May 2023 on the making available on the Union market and the export from the Union of certain commodities and products associated with deforestation and forest degradation and repealing Regulation (EU) No 995/2010. *Official Journal of the European Union*, L 150, 206-247. <https://eur-lex.europa.eu/eli/reg/2023/1115/oj>
5. Kundu, S., Ninoria, S. Z., Chaturvedi, R. P., Mishra, A., Agrawal, A., Batra, R., Dubale, M., & Hashmi, A. (2025). Real-time deforestation anomaly detection using YOLO and LangChain agents for sustainable environmental monitoring. *Scientific Reports*, 15, Article 39961. <https://doi.org/10.1038/s41598-025-23617-4>
6. Prasetyo, D. C., Mutiara, G. A., & Handayani, R. (2018). Chainsaw sound and vibration detector system for illegal logging. In 2018 International Conference on Control, Electronics, Renewable Energy and Communications (ICCEREC) (pp. 93-98). IEEE. <https://doi.org/10.1109/ICCEREC.2018.8712091>
7. Rainforest Connection. (2026). Rainforest Connection. <https://rfcx.org/> (3 अगस्त 2026 को अभगिति)
8. Ramadan, M. N., Ali, M. A., Khoo, S. Y., & Alkhdher, M. (2024). AI-powered IoT and UAV systems for real-time detection and prevention of illegal logging. *Results in Engineering*, 24, 103277. <https://doi.org/10.1016/j.rineng.2024.103277>
9. RESET.org. (24 मार्च 2025). ForestGuard: An open-source blockchain for deforestation-free coffee supply chains. <https://en.reset.org/forestguard-an-open-source-blockchain-for-deforestation-free-coffee-supply-chains/>

10. Sasaki, N., & Abe, I. (2025). A digital twin architecture for forest restoration: Integrating AI, IoT, and blockchain for smart ecosystem management. *Future Internet*, 17(9), 421. <https://doi.org/10.3390/fi1709421>
11. Sharma, M., Rastogi, R., Arya, N., Akram, S. V., Singh, R., Gehlot, A., Buddhi, D., & Joshi, K. (2022). LoED: LoRa and edge computing based system architecture for sustainable forest monitoring. *International Journal of Engineering Trends and Technology*, 70(5), 88-93. <https://doi.org/10.14445/22315381/IJETT-V70I5P211>
12. Stopfer, L., Kaulen, A., & Purfürst, T. (2024). Potential of blockchain technology in wood supply chains. *Computers and Electronics in Agriculture*, 216, Article 108496. <https://doi.org/10.1016/j.compag.2023.108496>
13. Tandon, A., Kaur, P., Mäntymäki, M., & Dhir, A. (2021). Blockchain applications in management: A bibliometric analysis and literature review. *Technological Forecasting and Social Change*, 166, 120649. <https://doi.org/10.1016/j.techfore.2021.120649>
14. Triplat, M., Lukančič, Ž., & Kavčič, V. (2026). Evaluation of deep learning models for image-based classification of timber logs by market value. *Forests*, 17(5), Article 518. <https://doi.org/10.3390/f17050518>

अध्याय 4

स्मार्ट वानिकी कार्य और रोबोटिक्स: कार्य सुरक्षा, स्वायत्त चालन और वन-मार्ग जाल का अनुकूलन

4.1

वन-मार्ग और कार्य-पथ (Skid Trail) का स्वचालित निष्कर्षण तथा भू-आकृति के अनुरूप कटाई योजना

स्क्रीन पर दिखते नक्शे में एक रास्ता था। हरी रेखा पहाड़ की कमर को पार करती हुई सहजता से आगे बढ़ रही थी, और ट्रक में लगी नेविगेशन ने बताया कि केवल चार सौ मीटर और चलने पर लकड़ी जमा करने के स्थान तक पहुँच जाएँगे। मोड़ मुड़ते ही रास्ता नहीं था। पिछली गर्मियों में हुई मूसलाधार बारिश में मिट्टी पूरी तरह बह गई थी, सड़क की आधी सतह घाटी के नीचे ढह गई थी, और बची हुई आधी में बाँह जितनी मोटी झाड़ियाँ इंसान की ऊँचाई तक बढ़ आई थीं। लकड़ियों से भरा ट्रक वहीं रुक गया। ड्राइवर ने खिड़की नीचे की और इंजन बंद करके काफी देर तक बैठा रहा। रेडियो से दफ्तर को बुलाने की कोशिश की, पर पहाड़ों के बीच सिग्नल बार-बार टूट जाता था। आखिरकार किसी आदमी को पैदल ऊपर चढ़कर ढहे हुए हिस्से की लंबाई और ढलान आँखों से मापनी पड़ी, नोटबुक में स्केच बनाकर नीचे उतरने के सिवा और कोई चारा नहीं था। पीछे आ रहे दो ट्रक भी बगल में रुककर इंजन चालू रखे इंतज़ार करते रहे, और उस दिन की तय की गई गाड़ी-वितरण योजना वहीं पूरी तरह बिगड़ गई। ठंडा होता इंजन टिक, टिक की आवाज़ कर रहा था, और चीड़ के रस की गंध तीखी डीज़ल की गंध से मिलकर गाड़ी के भीतर घुल रही थी। वह नक्शा तीन साल पहले बना था, और जंगल इस बीच किसी और रूप में बदल चुका था।

ऐसा दृश्य कोरिया के पहाड़ों में भी अनजाना नहीं है। वन-मार्ग हर साल नए खुलते हैं, और हर साल ढहते हैं। वन विभाग ने 2026 का बजट 3 खरब 260 अरब वॉन के पैमाने पर निर्धारित किया। यह पिछले वर्ष की तुलना में 15.6 प्रतिशत, राशि के हिसाब से 409 अरब 100 करोड़ वॉन अधिक का आँकड़ा है। उसमें अत्यधिक मौसम में भी टिके रहने वाले मज़बूत वन-मार्ग नए बनाना और मरम्मत करना भी 2026 के प्रमुख अग्रसर कार्य के रूप में शामिल है। जहाँ पहाड़ खड़ी ढलान वाले हों और बारिश गर्मी के एक ही मौसम में झमाझम बरसती हो, ऐसी भू-आकृति में एक बार बनाया गया वन-मार्ग कुछ ही वर्षों में ढलान के साथ ढह जाने की घटना दोहराई जाती है। संसद ने वन-मार्ग की योजना और स्थापना, संचालन और रखरखाव को एक ही कानूनी ढाँचे में बाँधने वाला वन-मार्ग स्थापना कानून का मसौदा पारित कर दिया। रास्ता बनाने का काम सिर्फ मौके पर तैनात निरीक्षक की अटकल और अनुभव के बल पर चलने का ज़माना ढलता दिखता है। मगर कानून और बजट चाहे जितने भी तैयार हों, अगर नक्शा हकीकत से मेल न खाए तो ट्रक अब भी उसी जगह रुक जाता है। इसीलिए आसमान से खींची गई सामग्री से ज़मीन पर के रास्ते को स्वचालित रूप से फिर से खींचने वाली तकनीक अपनी जगह बनाती जा रही है।

आसमान से फिर खींचा जाने वाला रास्ता

परंपरागत वन-मार्ग सर्वेक्षण इस तरीके पर निर्भर था कि आदमी खुद पैदल चले या गाड़ी चलाकर घूमे, सड़क की सतह की स्थिति आँखों से जाँचे और हाथ से नक्शा सुधारे। पेड़ों से घनी ढकी वितान (canopy, जंगल के ऊपरी हिस्से को ढकने वाली टहनियों और पत्तियों की परत) के नीचे होने वाले सूक्ष्म भू-आकृतिक बदलाव, सड़क का टूटना या नई खुली पगडंडी अगले नियमित सर्वेक्षण तक नक्शे में दर्ज हुए बिना यँ ही पड़े रहते थे। इस खाली जगह को हवाई लेज़र स्कैनिंग ने भरा। विमान या ड्रोन पर लाइडार (LiDAR, प्रकाश छोड़कर उसके लौटने का समय मापकर वस्तु तक की दूरी जानने वाला यंत्र) लगाकर पूरे जंगल को स्कैन किया जाए, तो पत्तियों के बीच से चीरकर भू-सतह तक पहुँची लेज़र की बिंदुओं को ही छाँटकर पेड़ हटा दी गई नंगी ज़मीन की ऊँचाई-नीचाई, यानी संख्यात्मक भू-आकृति मॉडल (DTM) खींचा जा सकता है। उसी बिंदु-समूह से पेड़ की चोटी तक की ऊँचाई समेटने वाला वितान-ऊँचाई मॉडल (CHM) और ढलान कितनी खड़ी है यह रंग से दर्शाने वाला ढलान-मात्रा नक्शा भी साथ में निकाला जा सकता है। सड़क इन तीनों नक्शों पर स्पष्ट निशान छोड़ती है। ढलान का धीरे-धीरे आगे बढ़ना, सतह का चिकना होना और चौड़ाई का एक समान बना रहना, यही वह फीता-आकार है, और कृत्रिम बुद्धिमत्ता इसी निशान को सीखकर रास्ता खोज निकालती है।

सामग्री वास्तव में जिस क्रम में बहती है, वह इस प्रकार है। विमान या ड्रोन जंगल के ऊपर से गुजरते हुए बिंदु-समूह और अति-उच्च रिज़ॉल्यूशन की तस्वीरें इकट्ठा करता है, और यह सामग्री भू-आकृति मॉडल, वितान-ऊँचाई नक्शा और ढलान-मात्रा नक्शा के रूप में परिकलित होती है। उसके ऊपर कृत्रिम बुद्धिमत्ता सड़क जैसे दिखने वाले आकार को ढूँढकर रेखा खींचती है, और उस रेखा को आर-पार काटने वाला अनुप्रस्थ काट लेकर आवागमन की चौड़ाई और सड़क सतह की स्थिति आँकती है। अंत में यह परिणाम मौजूदा वन-मार्ग जाल के नक्शा फ़ाइल में स्वचालित रूप से समाहित हो जाता है, और टूटे हुए हिस्से, कटाव वाले हिस्से तथा वनस्पति के आक्रमण वाले हिस्से दर्शाने वाला नया नक्शा तैयार हो जाता है। आदमी पैदल चलकर जो मापता और हाथ से सुधारता था, उस काम को आसमान से खींची सामग्री और परिकलन अपने ज़िम्मे ले लेते हैं। परिणाम आमतौर पर ऐसे वेक्टर फ़ाइल के रूप में निकलता है जिसे भौगोलिक सूचना प्रणाली में तुरंत खोलकर देखा जा सकता है। मौके पर तैनात कर्मी पहले से इस्तेमाल किए जा रहे नक्शा कार्यक्रम में इस फ़ाइल को बस चढ़ा दे, तो नए बने रास्ते और गायब हुए रास्ते अलग-अलग रंग में दिखने वाली स्क्रीन देख सकता है।

रुसेल और उनके साथियों ने इस तरह प्राप्त बिंदु-समूह सामग्री से सड़क की चौड़ाई, ढलान, मोड़ जैसे सात संकेतक निकाले, और इन्हें पथ-खोज एल्गोरिद्म से जोड़कर मौजूदा वन-मार्ग नक्शे की त्रुटि खुद-ब-खुद सुधारने वाली प्रणाली एएलएसरोड्स (ALSroads) 2022 में पेश की। पुराने वेक्टर नक्शे को नई लाइडार सामग्री पर ओवरलैप कर दिया जाए, तो टूटे हुए हिस्से और नए खुले हिस्से को कार्यक्रम पिक्सेल-दर-पिक्सेल पहचानकर अद्यतन कर देता है, यही इसका तरीका है। इससे पहले 2021 में बुहान और उनके साथियों ने लाइडार सामग्री में ढलान, मोड़, परावर्तन तीव्रता जैसी कई शर्तों को नियमों में गूँथने वाली मिश्रित वर्गीकरण तकनीक लगाकर वन-मार्ग पहचानने का प्रयास पेश किया था, और एएलएसरोड्स उसके बाद सटीकता को और ऊपर उठाने वाले उदाहरण के रूप में गिना जाता है। संवलन तंत्रिका जाल (CNN) और यू-नेट (U-Net) श्रेणी के कृत्रिम बुद्धिमत्ता मॉडल भी संख्यात्मक भू-आकृति

मॉडल पर सड़क की खास चपटी और चिकनी बनावट को आसपास की भू-आकृति से अलग पहचानने में इस्तेमाल हो रहे हैं। वितान जहाँ घनी बंद हो, ऐसे जंगल के नीचे भी रेखा-आकार का रास्ता छाँट निकालने की क्षमता कई अध्ययनों में सत्यापित हुई।

व्यापक क्षेत्र को तेज़ी से स्कैन करने की ओर नज़र फेरने वाले अध्ययन भी हैं। मॉर्ली और उनके साथियों ने 2024 में उत्तरी शंकुधारी वन में एकल-प्रकाशकण लाइडार (SPL, इतना संवेदनशील कि एक-एक प्रकाशकण को भाँप ले, इसीलिए कम शक्ति से भी व्यापक क्षेत्रफल खींच सके ऐसा उपकरण) का उपयोग करके व्यापक वन-मार्ग जाल को अद्यतन किया। उसी वर्ष विनिवार्टर और उनके साथियों ने क्यूबसैट की 3 मीटर श्रेणी की PlanetScope तस्वीरों पर संवलन तंत्रिका जाल लगाकर वन-मार्ग निकाला। शोधकर्ताओं ने बादल और धुएँ रहित मोज़ेक छाँटे, और जहाँ साफ़ तस्वीर नहीं थी वहाँ सामग्री की रिक्तता रह गई। यह ऐसा उदाहरण नहीं है कि प्रकाशीय उपग्रह ने बादल चीरा हो। सियाफाली और उनके साथियों ने 2025 में लकड़ी कटाई क्षेत्र में हवाई लाइडार, चलायमान स्लैम लाइडार और आईफोन लाइडार की सामग्री को ओवरलैप करके पर्वतीय वन-मार्ग की सड़क सतह की बनावट को फिर से रचा। व्यापक अवलोकन और निकट-दूरी की सूक्ष्म अवलोकन अलग-अलग समस्याएँ हल करते हैं।

वह चौड़ाई जहाँ से ट्रक गुज़र सके

वन-मार्ग नक्शे में रेखा के रूप में दर्ज हो, तब भी वह रेखा असल में इतनी चौड़ी है कि बड़े लकड़ी-ट्रक गुज़र सकें या नहीं, यह अलग बात है। कार्यालाइनेन और वागा ने क्रमशः 2024 और 2020 के शोधपत्रों में लाइडार बिंदु-समूह से सड़क के समकोण दिशा में भू-सतह का अनुप्रस्थ काट लेकर मशीन अधिगम से विश्लेषण करने की विधि पेश की। जहाँ टहनियाँ ऊपर से ढक देती हों और आसमान से सड़क की चौड़ाई सीधे मापना कठिन हो, ऐसे हिस्से में भी इस अनुप्रस्थ प्रोफ़ाइल को देखकर वास्तव में गुज़रने योग्य चौड़ाई तथा सड़क का कटाव, दरार, नाली का बंद होना और किनारे तक घुस आई वनस्पति की मात्रा आँकी जा सकती है। इसका अर्थ है कि ट्रक ड्राइवर मोड़ के आगे रुकने के बजाय, चलने से पहले ही दफ़्तर के कंप्यूटर की स्क्रीन पर पता कर सकता है कि उस हिस्से से गुज़रा जा सकता है या नहीं। अनुप्रस्थ प्रोफ़ाइल सड़क को बगल से एकाएक काटकर देखी गई बनावट जैसी होती है। बीच में चपटी दबाई गई सड़क सतह होती है, दोनों छोर नाली की ओर हल्के झुके होते हैं, और उसके बाहर मूल पहाड़ की ढलान फिर से शुरू हो जाती है। यह उतार-चढ़ाव लाइडार बिंदु-समूह पर स्पष्ट हो तो सड़क की स्थिति अच्छी है ऐसा अर्थ है, और उतार-चढ़ाव धुँधला हो या एक ओर ढह गया हो तो मरम्मत ज़रूरी है इसका संकेत है।

हूज़ा और उनके साथियों ने 2025 में ड्रोन और हवाई लाइडार सामग्री को जोड़कर चट्टान, न कटी रह गई ढूँठ, गिरे हुए मुरझाए पेड़ जैसी वन-मार्ग निर्माण में बाधक छोटी-मोटी रुकावटों को स्वचालित रूप से ढूँढ निकालने और लकड़ी जमा करने के कार्यस्थल तक पहुँचने वाला अनुकूल मार्ग आभासी रूप से पहले से खींच देखने वाला मॉडल पेश किया। असल में ज़मीन खोदने से पहले स्क्रीन पर पहले रास्ता खोद देखने जैसा ही है। जापानी शोधकर्ता तानाका और उनके साथियों ने 2025 में वन-कार्यपथ (森林作業道) का निर्माण मार्ग और प्राथमिकता तय करते समय बाहरी सामग्री जोड़े बिना केवल लाइडार विश्लेषण परिणाम से निर्णय लेने वाला एल्गोरिद्म प्रमाणित किया। भू-आकृतिक ढलान और सूक्ष्म-जलवायु, पेड़ों के जमा होने की मात्रा, कटी लकड़ी जमा करने के लिए उपयुक्त स्थान जैसी जानकारी एक ही लाइडार सामग्री से निकालकर, किस हिस्से से रास्ता बनाना शुरू करना है इसका क्रम तय करने का तरीका है। सर्वेक्षण दल

अलग से भेजे बिना भी प्राथमिकता तय की जा सकती है, यह बात उन वन-संघों या छोटे उद्यमों के लिए राहत भरी हो सकती है जिनके पास प्रचुर बजट नहीं। ऐसी क्रम-तालिका हाथ में मिलने पर वन-प्रौद्योगिक को नक्शे पर दर्ज हिस्सों को क्रम से जाँचते जाना भर होता है। पहले जिसका जवाब पूरे पहाड़ को पैदल स्कैन करके ही निकलता था, अब वही मॉनिटर के सामने बैठकर सुलझाया जा सकता है।

पहिए ने छोड़े निशान को मापना

अगर वन-मार्ग वह पक्की सड़क है जहाँ से ट्रक चलते हैं, तो कार्य-पथ या ढुलाई-पथ (skid trail) वह अस्थायी आवागमन मार्ग है जिसे हार्वेस्टर (harvester, पेड़ काटकर उसकी टहनियाँ छाँटकर एक निश्चित लंबाई में काटने वाली बड़ी लकड़ी-कटाई मशीन), फॉरवर्डर (forwarder, कटी लकड़ी को लादकर ढोने वाली मशीन) और स्किडर (skidder, लकड़ी को लटकाकर या घसीटकर ले जाने वाली मशीन) बार-बार आते-जाते हुए बना देते हैं। हार्वेस्टर पेड़ काटकर गिरा दे, तो स्किडर लकड़ी के तने का निचला सिरा फँसाकर ज़मीन पर घसीटते हुए जमा-स्थान तक ले जाता है, और फॉरवर्डर लकड़ी को पूरा-का-पूरा माल-डिब्बे पर लादकर ढोता है। घसीटने और लादने में से कौन-सा तरीका अपनाया जाए, उसके अनुसार ज़मीन पर बचे निशान की बनावट और गहराई भी बदल जाती है। चूँकि सड़क सतह को दबाया या बजरी बिछाई नहीं जाती, भारी मशीन एक ही जगह से कई बार गुज़रे तो मिट्टी कुचल जाती है और पहिए के निशान गहरे धँस जाते हैं। कुचली मिट्टी हवा और पानी के गुज़रने की जगह खो देती है, और वर्षा का पानी रिसने के बजाय सतह पर बहकर उतर जाता है। जिनकी जड़ें दब गई वे बचे पेड़ धीमे बढ़ते हैं, और गंभीर स्थिति में भूस्खलन तक हो जाता है। बरसात के मौसम में पहिए के निशान के साथ-साथ वर्षा का पानी छोटी नाली की तरह बहते हुए मिट्टी बहा ले जाता है, और वह मिट्टी पहाड़ के नीचे की घाटी के पानी को गँदला भी कर देती है।

अब्दी और उनके साथियों ने 2022 में उच्च-घनत्व वाली हवाई लाइडार सामग्री में यू-नेट तंत्रिका जाल जोड़कर, निचली वनस्पति से कुछ हद तक ढके कार्य-पथ को पिक्सेल-दर-पिक्सेल छाँटने वाला मॉडल बनाया। दबाई हुई मिट्टी मूल ज़मीन से नीचे धँसी होती है और सतह का उतार-चढ़ाव भी सपाट होता है, इसलिए कृत्रिम बुद्धिमत्ता इस सूक्ष्म ऊँचाई-अंतर और चिकनेपन को सामान्य ज़मीन से अलग करने का सुराग बनाती है। इंसान की आँख को जो पहिए का निशान झाड़-झंखाड़ में दबा दिखता तक नहीं, वह भी भू-सतह की ऊँचाई-नीचाई की सामग्री में बदलकर देखने पर स्पष्ट रेखा के रूप में उभर आया। लातेरिनी और उनके साथियों ने भूमध्य तट के पाँच जंगलों में कटाई कार्य से पहले और बाद दो बार ड्रोन लाइडार से तस्वीरें लेकर तुलना की। पेड़ काटने से पहले जो निशान नहीं था, वह काटने के बाद की सामग्री में नया प्रकट होने की जगह को, दोनों समयबिंदुओं की भू-सतह ऊँचाई ओवरलैप करके जाँचने का तरीका है। इन्होंने छाया-उभार (hillshading), स्थानीय-उभार मॉडल (LRM), सापेक्ष-घनत्व मॉडल (RDM), और मशीन अधिगम आधारित कार्यक्रम स्किडरोडफाइंडर (SkidRoad_Finder) तक चार विश्लेषण तकनीकें साथ-साथ परखीं। सापेक्ष-घनत्व मॉडल का प्रदर्शन बाकी तीन तकनीकों से आगे रहा, जिसकी सटीकता लगभग 73 प्रतिशत और संवेदनशीलता 66 प्रतिशत थी। उसी सामग्री से पहिए के निशान की गहराई और आयतन, मिट्टी के दबाव के जोखिम तक त्रि-आयामी अंकों में निकाल लिए गए। यह सौ प्रतिशत तक तो नहीं पहुँचता प्रदर्शन है, पर आदमी जंगल की तली में एक-एक करके चलते हुए फीता लगाने वाले पुराने तरीके से तुलना करें तो सर्वेक्षण की सीमा और गति में बड़ा अंतर है।

कार्य-पथ ढूँढ निकालने वाली कृत्रिम बुद्धिमत्ता को प्रशिक्षित करने के लिए वास्तव में दबाव पड़ी जगह की तस्वीर-सामग्री बहुत चाहिए होती है, पर मौके पर ऐसी तस्वीरें इकट्ठा करने में समय और लागत बहुत लगती है। उसुई ने 2021 में जननात्मक प्रतिकूल तंत्रिका जाल (GAN, दो कृत्रिम बुद्धिमत्ताएँ आपस में प्रतिस्पर्धा करते हुए असली जैसी नकली छवि बनाती हैं ऐसी तकनीक) से नई छवियाँ संश्लेषित करके अधिगम-नमूने की कमी की समस्या को भरा, और कार्य-पथ पहचानने की क्षमता ऊपर उठाई।

नुकसान से बचने का रास्ता पहले परिकलित करना

कार्य-पथ बनाने के बाद क्षति मापने का काम पहले ही घट चुकी समस्या को जाँचने की प्रक्रिया है। क्षति को ही घटाना हो तो पेड़ काटने से पहले, मशीन जिस रास्ते से गुजरेगी उसे भू-आकृति के अनुरूप पहले से छाँट रखना होगा। गोरेंस और उनके साथियों ने 2020 में लाइडार से जानी गई एक-एक पेड़ की स्थिति और आयतन, भू-आकृतिक ढलान, मिट्टी की आर्द्रता सूचकांक को एक साथ बाँधकर कटाई योजना स्वचालित रूप से बनाने वाला मॉडल विकसित किया। आनुवंशिक एल्गोरिद्म (प्राकृतिक चयन की प्रक्रिया की नकल करके कई प्रत्याशी मार्ग बनाकर आपस में स्पर्धा कराने के बाद केवल बेहतर विकल्प बचा लेने वाली परिकलन विधि) और गतिशील प्रोग्रामन, रैखिक प्रोग्रामन तीनों को ओवरलैप करके इस्तेमाल करने वाला यह मॉडल लकड़ी ढोने की आवागमन दूरी घटाने के साथ-साथ, दबाव का जोखिम अधिक वाले क्षेत्र और खड़ी ढलान वाली भू-आकृति को स्वचालित रूप से बचाते हुए कार्य-पथ का मार्ग छाँट देता है। प्रत्याशी मार्ग दसियों-सैकड़ों तरह के बनाकर शर्त पर खरे न उतरने वाले विकल्प एक-एक करके छाँट देने का तरीका है, इसलिए आदमी हाथ से चंद विकल्पों की ही तुलना करने वाले पुराने तरीके से जाँची जाने वाली संभावनाओं की संख्या ही अलग है। मशीन को किधर हाँका जाए कि पेड़ भी कम घायल हों और मिट्टी भी कम खुदे, आदमी अटकल से जो तय करता था वह काम परिकलन अपने ज़िम्मे ले लेता है।

पिक्कियो और उनके साथियों का 2018 का अध्ययन इटली की पर्वतीय भू-आकृति को लक्ष्य करके भू-आकृतिक ढलान-मात्रा और मिट्टी के कटाव की संवेदनशीलता, बचे पेड़ की क्षति की मात्रा, केबल यार्डर तथा फ़ॉरवर्डर तथा विंच सहायक उपकरणों में से कौन-सा इस्तेमाल करना है इसे एक ही स्क्रीन पर तय करने वाला भौगोलिक सूचना प्रणाली आधारित निर्णय-सहायता मॉडल (GIS-DSS) खड़ा किया। इस धारा को आगे लेकर एबरहार्ड और उनके साथियों ने 2025 में मिलते-जुलते ढाँचे के मॉडल को खड़ी ढलान वाले क्षेत्रों तक विस्तृत किया। जहाँ ढलान धीमी होती है वहाँ पहिएदार फ़ॉरवर्डर चलता है, पर ढलान तीखी हो जाए तो तार से लकड़ी को हवा में खींच ऊपर उठाने वाले केबल यार्डर की ओर निर्णय झुक जाता है। हर भू-आकृति अलग जवाब माँगती है, इसलिए यह ऐसा क्षेत्र है जिसे मानकीकृत नियमावली के एक ही पन्ने से निपटाना कठिन है। केबल यार्डर तार से लकड़ी को शून्य में लटकाकर ढोता है ऐसी खड़ी ढलान, और फ़ॉरवर्डर पहियों से डग भरता चढ़ता-उतरता है ऐसी धीमी ढलान, शुरू से ही अलग दुनिया हैं। भौगोलिक सूचना प्रणाली की स्क्रीन पर उस सीमा-रेखा को पहले से खींच रखना, मौके पर मशीन उतारने के बाद गलती को पलटने से कम नुकसानदेह है। इस तरह तय किया गया मार्ग रेखाचित्र के रूप में छापकर कार्य-दल के मुखिया को सौंपा जाता है, या हाल में टैबलेट की स्क्रीन पर हूबहू भेज भी दिया जाता है।

सिद्धांत और मौके के बीच बची दूरी

यहाँ तक बताए गए अध्ययनों को साथ-साथ रखकर देखें तो आपस में टकराने वाले बिंदु उभर आते हैं। एकल-प्रकाशकण लाइडार या क्यूबसैट उपग्रह तस्वीरें व्यापक क्षेत्र के प्रमुख वन-मार्ग जाल को कम लागत में स्कैन कर देखने में मज़बूत हैं, पर बिंदु-समूह घनत्व कम होने से सँकरे कार्य-पथ या पहिए के निशान तक अलग नहीं पहचान पातीं। इसके विपरीत ड्रोन लाइडार और ज़मीनी स्लैम, स्मार्टफ़ोन लाइडार को ओवरलैप करने वाला मॉडल सेंटीमीटर इकाई तक गहराई में जाता है, पर सामग्री-प्रसंस्करण का समय लंबा है और एक बार में खींचा जाने वाला क्षेत्रफल सँकरा है। व्यापक देखा जाए या घना देखा जाए, इसका जवाब अब तक किसी एक ओर तय नहीं हुआ ऐसा चुनाव दिखता है। गोरेंस के मॉडल ने परिकलन से छाँटा हुआ सैद्धांतिक अनुकूल मार्ग, और अब्दी की कृत्रिम बुद्धिमत्ता ने वास्तविक मौके पर मशीन चालक द्वारा छोड़े पहिए के निशान की तुलना करें तो दोनों ठीक-ठीक मेल नहीं खाते, यह भी सत्यापित होता है। भू-आकृतिक रुकावट या उस दिन का मौसम, चालक की आदत जैसे चर परिकलन में पूरी तरह नहीं समाते, इसीलिए।

मौके पर उतरने पर सीमाएँ और स्पष्ट हो जाती हैं। गर्मी के मौसम में पत्तों से भरे जंगल या निचली झाड़ियों से घने क्षेत्र में लेज़र के ज़मीन तक पहुँचने का अनुपात गिर जाता है, जिससे भू-आकृति मॉडल और कटाव-गहराई के अनुमान में त्रुटि जमा होती है। अति-उच्च घनत्व वाली बिंदु-समूह सामग्री का परिकलन बोझ भी बढ़ा है। एक क्षेत्र में सीखे मॉडल को भिन्न वृक्ष-प्रजाति और भू-आकृति वाले जंगल में ले जाने पर प्रदर्शन के गिरने की मात्रा सामग्री और मूल्यांकन विधि के अनुसार बदलती है। नए क्षेत्र में मौके के नमूने से दोबारा सत्यापित करना होता है।

बर्फ़ से ढकी भू-आकृति में समस्या फिर बदल जाती है। रूसी शोधकर्ता पोटोल्स्काया और सिनिचिना ने 2026 में क्रास्तोयार्स्क क्षेत्र के शीतकालीन वन-मार्गों पर मशीन अधिगम डेटासेट पेश किया। बर्फ़ से ढके होने के कारण गर्मी की सामग्री से पहचान में न आने वाले रास्ते केवल सर्दी में प्रकट होकर बर्फ़-पिघलाव काल में गायब हो जाने की परिघटना दर्ज करने वाली सामग्री है। इसका अर्थ है कि ऋतु और अक्षांश बदलें तो वही एल्गोरिद्म भी दोबारा सीखना पड़ता है। उपयोगिता को व्यापक करने के प्रयास भी जारी हैं। चीनी शोधकर्ता गाओ और उनके साथियों ने 2026 में कई अलग-अलग समयों में खींची गई उपग्रह तस्वीरों पर गहन-अधिगम मॉडल डीपलैबवी3प्लस (DeepLabv3+) को सुधारकर लगाया, और जंगल में आग लगने पर अग्निशमन कर्मी और उपकरण किस वन-मार्ग से पहुँच सकते हैं इसे तेज़ी से तय करने में इस्तेमाल किया। जहाँ जंगल की आग अक्सर लगती है ऐसी कांगवोन प्रांत की भू-आकृति के लिए भी गौर करने लायक दृष्टिकोण है।

ये सभी मॉडल तभी प्रदर्शन देते हैं जब आदमी ने खुद जाँचकर नाम दी हुई अधिगम-सामग्री हो। वन-मार्ग और कार्य-पथ जैसे लक्ष्य, जो हर क्षेत्र में अलग दिखते हैं और जिनके उदाहरणों की संख्या ही अधिक नहीं होती, उनके लिए अधिगम-सामग्री जुटाने से ही देर लगती है। उसुई की छवि-संश्लेषण तकनीक जैसे सामग्री-संवर्धन अध्ययन लगातार आते रहने का कारण भी यही है। जिस क्षेत्र में सामग्री जितनी कम, उतना ही सामग्री को कृत्रिम रूप से बढ़ाने वाली तकनीक पर निर्भरता का अनुपात बढ़ा होता है, यही अर्थ है।

आगे बचे कार्यों में से एक यह है कि कृत्रिम बुद्धिमत्ता ने आवागमन संभव है या नहीं इसका जो आधार तय किया, उसे मौके के प्रौद्योगिक द्वारा जाँची जाने वाली स्क्रीन बनाना। जोखिम वाला हिस्सा छाँटा हो तो

ढलान-मात्रा और सड़क सतह का उतार-चढ़ाव साथ में दिखाने जैसे। कार्य-पथ योजना को मशीन को सौंपते समय StanForD जैसे वन-मशीन उत्पादन एवं कार्य सामग्री मानक को जोड़ने की कड़ी के रूप में जाँचा जा सकता है। केवल इस मानक से सुरक्षित नौवहन पूरा नहीं हो जाता। मार्ग सामग्री, मशीन नियंत्रण, मौके की सुरक्षा नियमों को अलग से सत्यापित करना होता है।

स्रोत और संदर्भ

1. Abdi, O., Uusitalo, J., & Kivinen, V. P. (2022). Logging trail segmentation via a novel U-Net convolutional neural network and high-density laser scanning data. *Remote Sensing*, 14(2), 349. <https://doi.org/10.3390/rs14020349>
2. Buján, S., Guerra-Hernández, J., González-Ferreiro, E., & Miranda, D. (2021). Forest road detection using LiDAR data and hybrid classification. *Remote Sensing*, 13(3), 393. <https://doi.org/10.3390/rs13030393>
3. Eberhard, B., Trailović, Z., Magagnotti, N., & Spinelli, R. (2025). A GIS-based decision support model (DSM) for harvesting system selection on steep terrain: Integrating operational and silvicultural criteria. *Preprints*, 2025011137. <https://doi.org/10.20944/preprints202501.1137.v1>
4. Forkuo, G. O., Picchio, R., Proto, A. R., & Borz, S. A. (2026). Applications of artificial intelligence in forest operations engineering research: A systematic review. *Current Forestry Reports*, 12, Article 14. <https://doi.org/10.1007/s40725-026-00275-x>
5. Gao, Z., Li, Z., Yao, W., Zhang, T., Qiu, S., & Liu, Z. (2026). Forest road extraction via optimized DeepLabv3+ and multi-temporal remote sensing for wildfire emergency response. *Applied Sciences*, 16(7), 3228. <https://doi.org/10.3390/app16073228>
6. Görgens, E. B., Mund, J. P., Cremer, T., de Conto, T., Krause, S., Valbuena, R., et al. (2020). Automated operational logging plan considering multicriteria optimization. *Computers and Electronics in Agriculture*, 170, 105253. <https://doi.org/10.1016/j.compag.2020.105253>
7. Hrůza, P., Mikita, T., & Žižlavská, N. (2025). Application of unmanned aerial vehicle and airborne light detection and ranging technologies to identifying terrain obstacles and designing access solutions for the interior parts of forest stands. *Forests*, 16(5), 729. <https://doi.org/10.3390/f16050729>
8. Karjalainen, T., Karjalainen, V., Waga, K., & Tokola, T. (2024). Predicting the roadway width of forest roads by means of airborne laser scanning. *International Journal of Applied Earth Observation and Geoinformation*, 133, 104109. <https://doi.org/10.1016/j.jag.2024.104109>
9. Latterini, F., Dyderski, M. K., Picchio, R., Venanzi, R., Spinelli, R., & Magagnotti, N. (2025). Mapping skid trails and evaluating soil disturbance from UAV-based LiDAR surveys in Mediterranean forests. *Land Degradation & Development*. <https://doi.org/10.1002/ldr.70162>
10. Morley, I. D., Coops, N. C., Roussel, J. R., Achim, A., Dech, J., & Meecham, D. (2024). Updating forest road networks using single photon LiDAR in Northern forest environments. *Forestry: An International Journal of Forest Research*, 97(1), 38-47. <https://doi.org/10.1093/forestry/cpad021>
11. Picchio, R., Pignatti, G., Marchi, E., Latterini, F., Benanchi, M., Foderi, C., Venanzi, R., & Verani, S. (2018). The application of two approaches using GIS technology implementation in forest road network planning in an Italian mountain setting. *Forests*, 9(5), 277. <https://doi.org/10.3390/f9050277>
12. Podolskaia, E., & Sinitsina, A. (2026). A machine learning dataset on winter roads of Krasnoyarsk Krai, Russia for the forestry and infrastructural projects. *European Journal of Forest Engineering*, 12(1), 7-22. <https://doi.org/10.33904/ejfe.1743822>
13. Roussel, J. R., Bourdon, J. F., Morley, I. D., Coops, N. C., & Achim, A. (2022). Correction, update, and enhancement of vectorial forestry road maps using ALS data, a pathfinder, and seven metrics. *International Journal of Applied Earth Observation and Geoinformation*, 114, 103020. <https://doi.org/10.1016/j.jag.2022.103020>

14. Siafali, E., Polychronos, V., & Tsioras, P. A. (2025). Fusion of airborne, SLAM-based, and iPhone LiDAR for accurate forest road mapping in harvesting areas. *Land*, 14(8), 1553. <https://doi.org/10.3390/land14081553>
15. Tanaka, K., Uehagi, H., Shiota, H., & Mishima, Y. (2025). LiDARデータの解析結果のみを活用した森林作業道開設優先順位付け-京都府福知山市へ提案した手法-. *森林利用学会誌*, 40(1), 15-20. https://www.jstage.jst.go.jp/article/jjfes/40/1/40_40.3/_article/-char/ja
16. Usui, K. (2021). Data augmentation using image-to-image translation for detecting forest strip roads based on deep learning. *International Journal of Forest Engineering*, 32(1), 57-66. <https://doi.org/10.1080/14942119.2021.1831426>
17. Waga, K., Tompalski, P., Coops, N. C., White, J. C., Wulder, M. A., & Malinen, J. (2020). Forest road status assessment using airborne laser scanning. *Forest Science*, 66(4), 501-508. <https://doi.org/10.1093/forsci/fxz053>
18. Winiwarter, L., Coops, N. C., Bastyr, A., Roussel, J. R., Zhao, D. Q. R., & Lamb, C. T. (2024). Extraction of forest road information from CubeSat imagery using convolutional neural networks. *Remote Sensing*, 16(6), 1083. <https://doi.org/10.3390/rs16061083>
19. वन विभाग. (2025, 12 दसंबर). 'लोगों को बचाने वाला जंगल, जंगल को बचाने वाली जनता' 2026 के प्रमुख अग्रसर कार्यों की घोषणा. <https://v.daum.net/v/20251212095549587> (2 अगस्त 2026 को अभगिमति)
20. वन विभाग. (2026). वन-मार्ग स्थापना एवं प्रबंधन का कानूनी आधार तैयार, 'वन-मार्ग स्थापना कानून' संसद में पारति. <https://idsn.co.kr/news/view/1065599659428633> (2 अगस्त 2026 को अभगिमति)

4.2

रिमोट-नियंत्रित कटाई मशीनें, स्वचालित रूप से चलने वाले फॉरवर्डर और वानिकी रोबोटिक्स

अभियंता दफ़्तर की कुर्सी पर बैठा है। कुर्सी की पीठ गद्देदार है, और पैरों के नीचे कालीन बिछा है। मेज़ के एक कोने पर ठंडी हो चुकी कॉफ़ी का एक कप रखा है, और खिड़की के बाहर जंगल की जगह एक पार्किंग स्थल दिखाई देता है। आँखों के सामने छह मॉनिटर एक कतार में रखे हैं, और हाथ में गेम-मशीन के नियंत्रक जैसा दिखने वाला एक जॉयस्टिक पकड़ा हुआ है। कुछ साल पहले तक तो यह व्यक्ति इस समय किसी खड़ी पहाड़ी ढलान पर, हिलती-डुलती चालक-सीट में इंजन के शोर और कंपन को अपने पूरे शरीर से सहते हुए पेड़ काट रहा होता। अब स्थिति अलग है। जॉयस्टिक को हल्का-सा झुकाते ही सैकड़ों मीटर दूर जंगल के भीतर एक विशाल रोबोट-बाँह पेड़ को पकड़ लेती है, और स्क्रीन में लगा कैमरा उस दृश्य को वास्तविक समय में दिखाता है। एक स्क्रीन पर वह कोण दिखता है जिस पर उस चिमटे को पेड़ के तने को पकड़ना है, दूसरी स्क्रीन पर यह दिखता है कि मशीन का ढाँचा ढलान पर कितना झुका हुआ है, और एक और स्क्रीन पर वह वीडियो चलता है जो पास में कोई व्यक्ति या दूसरा उपकरण होने की जाँच करता है। पुरानी चालक-सीट में जो कोण एक साथ नहीं दिखते थे, वे दफ़्तर की कुर्सी पर उलटे एक ही नज़र में सामने आ जाते हैं। न कंपन है, न शोर, और न ही पेड़ के गिरते समय पैरों के नीचे गूँजने वाला वह एहसास बचता है। बस उँगलियों की बहुत छोटी-सी हरकत ही बच रहती है।

ऐसे रिमोट-नियंत्रण कक्ष अब विज्ञान-कथा फ़िल्मों का दृश्य नहीं रहे। स्वीडन में उप्साला के पास येला (Jälla) स्थित त्रोएड्सन वानिकी टेलीऑपरेशन प्रयोगशाला (Troëdsson Forestry Teleoperation Lab) में, 2025 के पतझड़ में, कोमात्सु (Komatsu) की नई बनाई गई एक फॉरवर्डर मशीन पहुँची। यह फॉरवर्डर रिमोट-नियंत्रण उपकरण के साथ ही प्रयोगशाला में आई। शोधकर्ता इस मशीन पर उमेओ विश्वविद्यालय के साथ मिलकर शोध करते हुए, उस कृत्रिम बुद्धिमत्ता मॉडल को खिलाने के लिए डेटा निकाल रहे हैं जो रोबोट को स्वयं निर्णय लेने के लिए प्रशिक्षित करता है। ऐसी वानिकी बनाना जिसमें न व्यक्ति घायल हो, न पेड़ को क्षति पहुँचे, और जो लंबे समय तक टिक सके, इस प्रयोगशाला का घोषित लक्ष्य है।

कोरिया ने भी ऐसा ही प्रयोग पहले ही शुरू कर दिया है। राष्ट्रीय वन विज्ञान संस्थान ने 2025 के अगस्त में, उपग्रह नौवहन प्रणाली (GNSS) और जड़त्वीय नौवहन प्रणाली (INS) को एक साथ जोड़कर और कैमरा वीडियो पर प्रशिक्षित कृत्रिम बुद्धिमत्ता को मशीन के ढाँचे के भीतर ही सीधे बिठाए हुए बुद्धिमान वन-कार्य रोबोट के चालन-परीक्षण के परिणाम प्रस्तुत किए। यह रोबोट वन-मार्ग को, यानी पहाड़ पर बनाई गई काम की संकरी सड़क को, स्वयं पहचान सका, और सड़क के ठीक बीचोंबीच की रेखा को खोजकर उस रेखा के साथ-साथ दौड़ सका। चूँकि कृत्रिम बुद्धिमत्ता मशीन के ढाँचे के भीतर ही गणना पूरी

कर लेती है, इसलिए संचार-नेटवर्क कट जाने या धीमा हो जाने पर भी रोबोट रुकता नहीं। पहाड़ के भीतर गहराई में तो अक्सर मोबाइल फ़ोन का संकेत तक ठीक से नहीं मिलता, इसलिए यह तरीका कोरिया के वन-क्षेत्र में भी अच्छी तरह जँचने वाला दृष्टिकोण दिखता है।

व्यक्ति के बजाय मशीन को पहले खतरनाक जगह भेजने के इस चलन के पीछे कारण हैं। चैनसों से पेड़ काटने और खींचकर नीचे लाने के श्रम में खड़ी ढलान, गिरते पत्थर, मशीन का पलटना और मांसपेशियों-हड्डियों पर पड़ने वाला बोझ, सब एक साथ जुड़ जाते हैं। मानवरहित बनाने से पहले वीडियो और जड़त्वीय सेंसर से काम की मुद्रा या काम के चरण को वर्गीकृत करने का शोध भी चल रहा है। कुछ प्रयोगों ने ऊँची सटीकता की सूचना दी, पर वे मान छोटे परीक्षण-समुच्चय या सीमित व्यवहार-विभाजन से प्राप्त हुए हैं। इसका यह अर्थ नहीं कि असली जंगल की सभी काम-मुद्राओं और थकान को उसी स्तर पर पहचान लिया जाता है।

ग्योंगबुक प्रांत के बोंगह्वा ज़िले में, वन विभाग के योंगजू राष्ट्रीय वन प्रबंधन कार्यालय ने हार्वेस्टर, फॉरवर्डर और मल्चर जैसे उच्च-निष्पादन उपकरण एकत्र करके उनकी मरम्मत के लिए एक विशेष उपकरण-भंडार नए सिरे से बनाया है, जो 2026 के अगस्त से चालू होगा। एक रोबोट को विकसित करने के काम से कम अहम नहीं है, उस रोबोट को खरीदने, चलाने और मरम्मत करने की व्यवस्था जुटाने का काम, जो साथ-साथ चल रहा है।

45 डिग्री की ढलान पर खड़ी मशीन

विंच-असिस्ट (Winch-Assist) नामक उपकरण को पहली बार देखकर सब लगभग एक जैसा सवाल पूछते हैं। क्या वह मोटी लोहे की रस्सी सचमुच मशीन को थाम सकती है। पहाड़ के ऊपरी हिस्से के किसी मज़बूत पेड़ या विशेष लंगर-मशीन पर एक मज़बूत लोहे की रस्सी बाँधकर, उस रस्सी को नीचे की कटाई-मशीन से जोड़कर खींचने का बल लगातार जोड़ते रहने वाला यह उपकरण है। कलाई जितनी मोटी लोहे की रस्सी पहाड़ की चोटी से लेकर मशीन तक तनी हुई फैली रहती है, यह दृश्य दूर से देखने पर ऐसा लगता है मानो मशीन को पहाड़ से बाँध दिया गया हो। पहिए या ट्रैक फिसलने ही वाले हों उस क्षण भी लोहे की रस्सी का खींचने वाला बल बना रहता है, इसलिए 30 डिग्री से लेकर 45 डिग्री से अधिक झुकाव वाली ढलानों पर भी मशीन ज़मीन को पकड़े हुए काम जारी रख सकती है। जब यह उपकरण नहीं था, तब ऐसी ढलानों पर भी व्यक्ति चैनसों लेकर पेड़ों के तनों के बीच से खुद चलकर जाता था। लोहे की रस्सी के बिना खड़ी ढलान पर मशीन चढ़ाने पर पहिए व्यर्थ ही घूमते हुए मिट्टी को खोदते हैं, और गंभीर स्थिति में मशीन एक ओर लुढ़क जाने के हादसे तक पहुँच जाती है।

जापान वानिकी यंत्रीकरण संघ द्वारा जारी की गई स्मार्ट वानिकी सत्यापन-परिणामों को देखें तो, ढलान की मात्रा के अनुसार काम का तरीका स्पष्ट रूप से बाँट जाता है। मध्यम ढलान वाले पहाड़ों पर रिमोट से नियंत्रित होने वाली कटाई-मशीन पेड़ काटती है, और मानव हाथ से गुज़रे बिना स्वचालित रूप से चलने वाला फॉरवर्डर उस पेड़ को ढोकर ले जाता है। पहले जिस लकड़ी-संग्रहण के काम में पाँच-छह लोग जुटते थे, उसे दो लोग करने वाली व्यवस्था है। जनसंख्या घटने वाले समाज में, जहाँ कामगार कम हो रहे हैं, जंगल की रक्षा कैसे की जाए, यह जापान के वन-शोध संस्थानों के लिए भी साझा चर्चा का विषय है। वन-श्रमिक उम्रदराज़ हैं और उनकी संख्या भी लगातार घट रही है, इसलिए युवा जनशक्ति ढूँढ़ने के बजाय जो जनशक्ति है उसी से अधिक

बड़े क्षेत्र को सँभालने का तरीका खोजने की ओर झुकाव अधिक है। कहीं ज़्यादा खड़ी ढलान वाले पहाड़ों पर व्यक्ति के हाथ में लेकर चलने वाले चेनसॉ के काम को ही हटा दिया जाता है, और उसकी जगह विंच-असिस्ट लगी रिमोट-नियंत्रित कटाई-मशीन ले लेती है। पेड़ को खींचकर नीचे लाने की संग्रहण-प्रक्रिया को भी लोहे की रस्सी में लटके चिमटे या पहाड़ के ऊपरी हिस्से में खड़ा किया गया मीनार जैसा उपकरण, यानी टावर याडर, अपने हाथ में ले लेता है। व्यक्ति स्क्रीन के सामने बचा रहता है, और खतरनाक ढलान पर सिर्फ़ मशीन चढ़ती है। पहले जहाँ कई लकड़हारे रस्सी और घिरनी को हाथ से खिसकाकर बाँधते हुए पेड़ खींचकर नीचे लाते थे, वहीं अब उस रस्सी का एक सिरा मशीन पकड़ती है और व्यक्ति यह भूमिका निभाने की ओर पीछे हट गया है कि मशीन ठीक से चल रही है या नहीं, इसे स्क्रीन पर जाँचे।

यूरोपीय शोधकर्ताओं द्वारा 2025 में प्रस्तुत किया गया शोध इस चुनाव को डेटा से सहारा देता है। भू-आकृति की ढलान, मिट्टी के कटकर बह जाने के जोखिम, और बचाकर रखे जाने वाले पेड़ों को क्षति न पहुँचने की शर्तों को एक साथ गणना में लेने वाला भौगोलिक सूचना प्रणाली (GIS) आधारित निर्णय-समर्थन मॉडल बनाया गया। एक ही पहाड़ को लेकर भी हर क्षेत्र में यह उत्तर बदल जाता है कि विंच-असिस्ट का उपयोग करना है या लोहे की रस्सी से पूरा का पूरा खींचकर ऊपर उठाने वाला केबल-कार्य करना है। कोई क्षेत्र ऐसा है जहाँ ढलान खड़ी होने पर भी मिट्टी सख्त होने के कारण विंच-असिस्ट से काम चल जाता है, और कोई क्षेत्र ऐसा है जहाँ मिट्टी मुलायम और आसानी से टूटने वाली होने के कारण मशीन के पहियों के निशान तक न छोड़ने वाले केबल-कार्य की ओर बढ़ना पड़ता है। व्यक्ति के अनुमान के बजाय नक्शे पर के आँकड़े उस उत्तर को चुनकर देते हैं।

जहाँ पेड़ उपग्रह-संकेत को ढक लेते हैं

समस्या यह है कि जंगल के भीतर जितना गहरे जाया जाए, आकाश उतना ही गायब होता जाता है। पत्तों से घनी पेड़ की चोटी, यानी वृक्ष-मुकुट जब आकाश को ढक लेता है, तो उपग्रह नौवहन प्रणाली (GNSS) का संकेत या तो पूरी तरह कट जाता है, या फिर पेड़ की डालियों से टकराकर लौटे संकेत आपस में गड़मड़ होकर स्थिति को किसी बेतुकी जगह की ओर उधाल देते हैं। यह ऐसा है मानो नेविगेशन के ठप्प हो जाने पर जंगल के बीचोंबीच कार चलानी पड़े। व्यक्ति चलाए तो आँखों से देखकर और अनुमान से टिका रहता है, पर रिमोट या स्वचालित मशीन ऐसा नहीं कर सकती। इसीलिए ज़मीन पर लगे सेंसर मात्र से अपनी स्थिति और आसपास का नक्शा एक साथ खींच लेने वाली तकनीक, यानी स्लैम (SLAM), का होना अनिवार्य है। यह ध्यान में रखें कि कोरिया के अधिकांश वन ढलानदार पहाड़ी इलाकों में सिमटे हैं और ऐसी घाटियाँ भी बहुत हैं जहाँ पेड़ घने भरे हैं, तो यह तकनीक केवल दूसरे देश की बात नहीं रह जाती।

चीनी शोधकर्ता याओ और उनके सहयोगियों ने 2025 में, घने जंगल के भीतर चलने वाली वानिकी मशीन के लिए हेक्टर स्लैम (Hector SLAM) नामक मौजूदा तकनीक में सुधार करके कई सेंसरों को एक साथ उपयोग करने वाला स्थिति-आकलन एल्गोरिदम बनाया और असली जंगल में उसका परीक्षण किया। पहले लाइडार (LiDAR), यानी प्रकाश छोड़कर और लौटने में लगे समय को नापकर आसपास की वस्तुओं तक की दूरी जान लेने वाले उपकरण द्वारा दर्ज किए गए बिंदुओं में से पत्तों या छोटी टहनियों से टकराकर बने शोर-बिंदुओं को छान लिया जाता है। उसके बाद मशीन कितनी झुकी है यह नापने वाले जड़त्वीय मापन उपकरण (IMU) के मान को लाइडार की सूचना के साथ मिलाकर, ज़मीन के ऊबड़-खाबड़ होने पर भी स्कैन-परिणाम विकृत न हो, इस तरह सुधार लिया जाता है। पहिए के व्यर्थ घूमने पर पैदा होने वाली त्रुटि

से बचने के लिए, पहिए की चक्कर-संख्या के बजाय लाइडार द्वारा दर्ज किए गए बिंदुओं को सीधी रेखा से मिलाकर तुलना करने के तरीके से यह गणना की जाती है कि मशीन कितनी चली।

परीक्षण के परिणाम आँकड़ों में स्पष्ट रूप से सामने आए। मौजूदा हेक्टर स्लैम की तुलना में त्रुटि 47.65 प्रतिशत घटी। नक्शा खींचने की औसत त्रुटि 4.78 सेंटीमीटर रही, और अधिकतम त्रुटि भी 8.7 सेंटीमीटर से अधिक नहीं हुई। मशीन के रुके होने पर स्थिति की त्रुटि औसतन 9.9 सेंटीमीटर रही। गति को तीन चरणों में बदल-बदलकर दौड़ने के दौरान भी क्षैतिज त्रुटि 7.9 सेंटीमीटर से अधिक नहीं हुई, और दिशा बताने वाली त्रुटि को भी 36.5 डिग्री से नीचे थामे रखा गया। कुछ सेंटीमीटर तो कोई बड़ी बात नहीं लगती, पर संकरे वन-मार्ग पर इतना चूक जाने पर पहिया सड़क के बाहर निकल सकता है या बचाकर रखे जाने वाले पेड़ की जड़ों को कुचल सकता है।

राष्ट्रीय वन विज्ञान संस्थान ने जो वन-मार्ग पर परीक्षण किया और याओ शोध-दल ने जो जंगल के भीतर परीक्षण किया, उनके लक्ष्य अलग हैं। एक ओर तो पहले से बनी सड़क पर कैमरे से बीच की रेखा खोज लेने वाला पक्ष है, और दूसरी ओर सड़क जैसी कोई चीज़ ही न होने पर पेड़ों के बीच से लाइडार से टटोलते हुए आगे बढ़ने वाला पक्ष है। दोनों प्रयास लगभग एक ही समय पर साथ-साथ सामने आए हैं, यह देखते हुए यह संभावना अधिक है कि GNSS संकेत के कट जाने वाले जंगल को भेदकर मशीन को अकेले चलाने का प्रयास अब केवल एक देश का ही कार्यभार नहीं रह गया।

चार पैरों से चलने वाला रोबोट, बोझ ढोने वाला रोबोट

अगर किसी भू-आकृति के लिए अनियमित शब्द उपयुक्त बैठता है, तो जंगल का धरातल ठीक वैसा ही है। अचानक उभरी चट्टान, गिरे हुए हाल में सड़ते जा रहे सूखे पेड़, घुटनों तक आने वाली झाड़ियाँ, और ऐसी नालियाँ जिनमें पैर धँस जाए, सब मिले-जुले होते हैं, इसलिए पहियों वाली मशीन हो या ट्रैक लपेटे मशीन, आसानी से अटककर गिर जाती है। यूरोपीय संघ की डिजीमेडफोर (DigiMedFor) परियोजना में इस समस्या को पैरों से हल किया गया। रोबोटिक्स कंपनी बॉस्टन डायनामिक्स (Boston Dynamics) द्वारा बनाए गए चार पैरों वाले चलने वाले रोबोट स्पॉट (Spot) की पीठ पर त्रिआयामी लाइडार, उच्च-गुणवत्ता कैमरा, छोटा कंप्यूटर, केवल कुछ ख़ास रंगों को छानने वाला प्रकाशीय फ़िल्टर, GPS मॉड्यूल, और रोबोट के झुकाव को दर्ज करने वाला उपकरण रखकर उसे जंगल में भेजा गया। बजरी के मैदान, झाड़-झंखाड़ और ढलानदार पहाड़ी के बीच आते-जाते हुए डेटा एकत्र करने के बाद शोधकर्ताओं द्वारा दिया गया आकलन छोटा और साफ़ था। लगभग कहीं भी जाया जा सकता है, यही उसका सार था। जहाँ पहिए होते तो व्यर्थ घूमकर रुक जाते, ऐसे बजरी के मैदान में भी स्पॉट एक-एक पैर को सँभालकर रखते हुए चलता रहा। स्पॉट चलते-चलते पेड़ की चोटी, तने और धरातल के त्रिआयामी बिंदु-बादल और उच्च-गुणवत्ता तस्वीरें वास्तविक समय में एकत्र करता रहा, और उस डेटा को ऑनलाइन अभिलेख-उपकरण से जोड़कर एक-एक पेड़ की जानकारी समेटे हुए डिजिटल जुड़वाँ को स्वयं अद्यतन करता रहा। व्यक्ति के मापन-फ़ीता और टैबलेट लेकर एक-एक पेड़ की परिधि नापने की पुरानी सर्वेक्षण-पद्धति की तुलना में, रोबोट के चलते-चलते खींचे गए बिंदु-बादल पेड़ की स्थिति, मोटाई, यहाँ तक कि झुकाव तक एक साथ दर्ज कर लेते हैं।

स्वीडन में चलने वाले रोबोट के बजाय बोझ ढोने वाले रोबोट का परीक्षण किया गया। लकड़ी ढोकर ले जाने वाले बड़े उपकरण फॉरवर्डर को स्वचालित चालन में बदलकर, उसके परिणाम को तकनीक, संगठन और पर्यावरण, इन तीन धुरियों से एक साथ देखने वाले टीओई (TOE) विश्लेषण-ढाँचे से खंगाला गया। कारखाने के फ्रंश या शहरी सड़क से अलग, जंगल में मौसम अक्सर बदलता है, मिट्टी की नमी भी हर क्षेत्र में भिन्न होती है, और पेड़ों के बढ़ने का आकार भी किसी मानक जैसा नहीं होता। इसीलिए शोधकर्ताओं ने, मशीन के सब कुछ अकेले तय करने वाले पूर्ण मानवरहित रूप के बजाय, एक ऐसा सहयोग-मॉडल यथार्थवादी उत्तर के रूप में प्रस्तुत किया जिसमें अनुभवी चालक बड़े प्रवाह का निर्णय लेता है और रोबोट केवल बाधाओं से बचते हुए तथा बचाकर रखे जाने वाले पेड़ों को क्षति न पहुँचाते हुए संकरे दायरे का चालन ही सँभालता है। व्यक्ति यह तय करता है कि आज किस क्षेत्र से ढोना शुरू करना है और जहाँ सड़क टूटी है वहाँ किधर से बचकर घूमकर जाना है, और रोबोट उस खंड के भीतर स्वयं यह तय करता है कि पहिए के नीचे क्या अटक रहा है और बचाकर रखे जाने वाले पेड़ से कितनी दूरी बनाकर गुज़रना है। संगठन की धुरी से देखें तो वानिकी कंपनी को कटाई-अभियंता को रिमोट चालक-सीट पर बिठाना होगा, और मरम्मत-कर्मियों को स्वचालित उपकरण सँभालने के योग्य बनाने के लिए फिर से प्रशिक्षित करना होगा। सिर्फ मशीन ही नहीं बदलती, व्यक्ति के काम की विषय-वस्तु भी साथ-साथ बदल जाती है।

रोबोट को असली जंगल में छोड़कर आपात-ब्रेकिंग या बाधा-पहचान का परीक्षण करते-करते मशीन टूट जाती है और जंगल को भी क्षति पहुँचती है। इसीलिए फ़िनलैंड की लापलैंड एप्लाइड साइंसेज़ विश्वविद्यालय और स्वीडन के RISE के शोधकर्ताओं ने एक आभासी जंगल बनाया। स्वीडन के विंडेल्ल (Vindeln) परीक्षण-वन को तीस स्थानों पर लगे ज़मीनी लाइडार और ड्रोन से खींची तस्वीरों द्वारा बारीक़ी से स्कैन करके, लंबाई-चौड़ाई में 200-200 मीटर, भौतिकी के नियमों तक हूबहू उतारे हुए, एक डिजिटल जुड़वाँ जंगल कंप्यूटर के भीतर खड़ा किया। इस आभासी जंगल के भीतर दृष्टि-बिंदु, धूप के कोण और पेड़ के खड़े होने के स्थान को लगातार बदल-बदलकर संक्षेपित डेटा सिमफ़ॉरेस्ट (SimForest) तैयार किया गया। कोई आभासी कामगार अचानक मशीन के आगे चलकर आने का दृश्य या कोहरे के घने छा जाने का दृश्य सैकड़ों बार दोहराकर बनाया जाता है, और हर बार रोबोट को रुकने में लगने वाला समय नापा जाता है। स्वचालित रोबोट को कोहरे, बारिश या उलटी रोशनी जैसी परिस्थितियों को बिना किसी असली ख़तरे के पहले ही अनुभव कर लेने का अवसर मिल गया।

अभी पूरी तरह न विकसित हुआ स्वचालन

चार पैरों वाले रोबोट और बड़े स्वचालित फॉरवर्डर को साथ-साथ रखकर देखें तो यह बात सामने आती है कि दोनों की उपयोगिता ठीक विपरीत दिशा में है। स्पोर्ट जैसे चलने वाले रोबोट बजरी के मैदान और सूखे पेड़ों से उलझे बीहड़ में स्थिर रूप से चलते हैं और नीचे की वनस्पति तक बारीक़ी से स्कैन कर लेते हैं, पर उनकी ढो सकने की क्षमता कुछ दसियों किलोग्राम तक ही सीमित रहती है, इसलिए पेड़ काटने या ढोकर ले जाने का काम स्वयं वे नहीं कर सकते। इसके विपरीत, मध्यम आकार के स्वचालित फॉरवर्डर या रिमोट-नियंत्रित कटाई-मशीन कई टन तक के लट्टे सँभाल सकते हैं, पर जहाँ भू-आकृति में उतार-चढ़ाव तीव्र है या पेड़ घने भरे हैं, वहाँ पहिए धँसकर हिल भी नहीं पाते या मिट्टी को दबाकर सख़्त कर देते हैं। इसका अर्थ यह हुआ कि चलने वाले पैर और घूमने वाले पहिए, इन दोनों में से कोई एक हर जंगल को नहीं सँभाल सकता, और अंततः भू-आकृति के अनुसार अलग-अलग शरीर वाली मशीनों को बारी-बारी से लगाने की ओर जाने के अलावा कोई रास्ता नहीं दिखता। एक पक्ष जो काम अच्छा करता है, वह दूसरा पक्ष नहीं कर सकता।

आभासी जंगल से मिले परिणाम और असली जंगल के परिणाम के बीच एक अंतराल है। कोहरा और बारिश, लेंस पर की मिट्टी-धूल, हिलती हुई डालियाँ और उलटी रोशनी कैमरे और लाइडार के निर्णय को धुँधला कर देते हैं। सटीकता में गिरावट की मात्रा सेंसर, मौसम और परीक्षण-सामग्री के अनुसार भिन्न होती है, इसलिए उसे किसी एक दायरे में स्थिर नहीं किया जा सकता। संश्लेषित सामग्री पर प्रशिक्षित मॉडल का असली जंगल की अलग परीक्षण-सामग्री से फिर से मूल्यांकन करना होगा।

तकनीक को जो दहलीज़ पार करनी है, वह भी अब भी ऊँची है। स्पोर्ट जैसे विद्युत-चालित चलने वाले रोबोट की बैटरी बाहर एक-दो घंटे में ख़त्म हो जाती है, इसलिए जहाँ बिजली न खींची जा सके, ऐसे दूरदराज़ इलाक़े में लंबे समय तक ठहरकर निगरानी करने के मिशन के लिए वे उपयुक्त नहीं हैं। घने जंगल को लंबे समय तक पार करते-करते अगर स्लैम एल्गोरिदम बीत चुके रास्ते को फिर से पहचानने में विफल हो जाए, तो स्थिति की त्रुटि जमा होते-होते मशीन के तय रास्ते से हट जाने का ख़तरा भी है। इसका अर्थ यह है कि स्क्रीन के नक्शे में मशीन अब भी सड़क के बीचोंबीच दौड़ रही दिखती है, जबकि असल में वह पेड़ों के बीच से किनारे होकर घुस चुकी होने की स्थिति पैदा हो सकती है। महँगी शुरुआती अपनाने की लागत छोटे वन-मालिक के सँभाल पाने के स्तर से बाहर है, और मानवरहित मशीन के ग़लत ढंग से चलने पर कौन ज़िम्मेदारी लेगा, इसका क़ानून और व्यवस्था अभी तैयार नहीं हुई है। रोबोट के व्यक्ति को न पहचान पाने के कारण हादसा हो जाने पर, वह ज़िम्मेदारी रोबोट बनाने वाली कंपनी की है, रोबोट खरीदने वाली वानिकी कंपनी की है, या फिर दूर से जॉयस्टिक पकड़े हुए अभियंता की, इसका भी उत्तर अभी तय नहीं है।

आगे जो कार्यभार सुलझाना है, वह अलग-अलग रोबोटों की भूमिकाओं को जोड़ने का है। ड्रोन वन-मार्ग की हालत देखे, चलने वाला रोबोट भू-आकृति की जाँच करे, और फॉरवर्डर लकड़ी ढोए, ऐसी परिकल्पना है। चैन शोध-दल (Chen et al., 2025) ने कृषि-वानिकी परिवेश में कई रोबोटों के बिखरकर सूचना एकत्र करने की वितरित नियंत्रण-पद्धति प्रस्तावित की। जंगल में ऐसी व्यवस्था चलाने के लिए कट जाने वाले संचार, मौक़े पर की गणना, टकराव-रोकथाम और आपात-ठहराव, सबका एक साथ सत्यापन करना होगा। StanForD जैसा वानिकी-मशीन कार्य-सामग्री मानक अभिलेख के आदान-प्रदान में मदद कर सकता है, पर रोबोट की सुरक्षा की गारंटी नहीं देता। ठहराव-समय को मशीन की गति और ब्रेकिंग-दूरी, संवेदन-दायरे तथा कामगार से बनाई जाने वाली सुरक्षित दूरी के आधार पर तय करना होगा।

सुरक्षा इंटरलॉक को क्रानून से तय करने और अंतरराष्ट्रीय मानक से डेटा मिलाने की प्रशासनिक प्रक्रिया, रोबोट को नए सिरे से डिज़ाइन करने के काम से अधिक समय ले सकती है। गलत ढंग से चलने की ज़िम्मेदारी कौन-सी कंपनी, कौन-सी संस्था लेगी, यह तक तय न होने की स्थिति में महँगे उपकरण को झट से अपने यहाँ लगाने वाली वानिकी कंपनियाँ भी बहुत नहीं होंगी। ये मशीनें वन-क्षेत्र में जगह-जगह फैलने तक जो अड़चनें बची हैं, वे तकनीक से अधिक व्यवस्था की ओर ज़्यादा जमा हुई दिखती हैं।

स्रोत और संदर्भ

1. Bergqvist, M., Nylén, D., Lindberg, A., & Åkesson, M. (2026). Digital innovation in data-poor and unstructured environments: Envisioning autonomous systems in forestry. *Proceedings of the 59th Hawaii International Conference on System Sciences (HICSS)*, 5881-5890.
<https://umu.diva.portal.org/smash/get/diva2:2044606/FULLTEXT01>
2. Borz, S. A., Kaakkurivaara, T., Forkuo, G. O., & Kaakkurivaara, N. (2026). Activity recognition in motor-manual cross-cutting operations by machine learning on multimodal data. *Forest Science and Technology*, 22, 26-35.
<https://doi.org/10.1080/21580103.2025.2543281>
3. Chen, J., Chen, M., Wang, J., Mao, Q., Xie, F., & Dames, P. (2025). Distributed multi-robot active gathering for non-uniform agriculture and forestry information. *Frontiers in Plant Science*, 16, Article 1699124.
<https://doi.org/10.3389/fpls.2025.1699124>
4. DigiMedFor Project Consortium. (2025). Webinar #3: Enhancing forestry inventory, quadruped robot (Spot) field performance and demonstration [वीडियो]. YouTube. <https://www.youtube.com/watch?v=58rjC9O-1Mk> (2 अगस्त 2026 को अभिगमिति)
5. Eberhard, B., Trailović, Z., Magagnotti, N., & Spinelli, R. (2025). A GIS-based decision support model (DSM) for harvesting system selection on steep terrain: Integrating operational and silvicultural criteria. *Preprints*, 2025011137. <https://doi.org/10.20944/preprints202501.1137.v1>
6. Forest Machine Magazine. (2025, December 9). The next step in the automation of forestry machines.
<https://forestmachinemagazine.com/the-next-step-in-the-automation-of-forestry-machines/> (2 अगस्त 2026 को अभिगमिति)
7. Forkuo, G. O., Picchio, R., Proto, A. R., & Borz, S. A. (2026). Applications of artificial intelligence in forest operations engineering research: A systematic review. *Current Forestry Reports*, 12, Article 14.
<https://doi.org/10.1007/s40725-026-00275-x>
8. Forkuo, G. O., Bilici, E., & Borz, S. A. (2026). Automated OWAS in forestry using deep learning for posture classification. *International Journal of Industrial Ergonomics*, 113, 103930.
<https://doi.org/10.1016/j.ergon.2026.103930>
9. Forestry and Forest Products Research Institute. (2025). 2025 FFPRI सार्वजनिक व्याख्यान सभा, 2050 का जंगल, जनसंख्या घटने वाले समाज में जंगल की भूमिका [वीडियो]. YouTube. <https://www.youtube.com/watch?v=OEhqSNoACCo> (2 अगस्त 2026 को अभिगमिति)
10. Japan Forest Machinery Association. (2026). Part 3, वृत्ति वर्ष 2025 स्मार्ट वानिकी मशीन एवं काष्ठ-आधारित नव-सामग्री संगोष्ठी [वीडियो]. YouTube. https://www.youtube.com/watch?v=uzSCOk_qQl8 (2 अगस्त 2026 को अभिगमिति)
11. Avula, R. R., Narkilahti, A., & Unga, J. (2026). From digital twin to AI-based perception system validation. In A. Saloniemi (Ed.), *Digital Solutions for Forestry (Pohjoisen tekijät - Lapland University of Applied Sciences Publications, 7/2026)*. Lapland University of Applied Sciences. <https://urn.fi/urn:isbn:978-952-316-582-3>
12. Yao, L., Wen, J., Bian, C., Chen, Y., Xu, L., & Yao, L. (2025). Localization and mapping method for forestry mobile platforms based on enhanced Hector SLAM. *Journal of King Saud University - Computer and Information Sciences*, 37, Article 229. <https://doi.org/10.1007/s44443-025-00221-0>

13. रोबोट अखबार. (2025, 6 अगस्त). राष्ट्रीय वन विज्ञान संस्थान, अंतःस्थापित AI तकनीक आधारित बुद्धिमान वन-कार्य रोबोट का विकास. <https://www.irobotnews.com/news/articleView.html?idxno=41635> (2 अगस्त 2026 को अभिगमिति)
14. इजू बीमा समाचार. (2026, 31 जुलाई). जंगल का भवष्य लादकर, उच्च-नष्टिपादन वानिकी मशीन उपकरण-भंडार का पूर्ण संचालन. https://dazabi.com/insurance_magazine/article.php?id=40560 (2 अगस्त 2026 को अभिगमिति)

4.3

कंप्यूटर विज्ञान और Wearable सेंसर पर आधारित श्रमिक कार्य सुरक्षा निगरानी

तड़के छह बजे, गांगवोन प्रांत के इंजे के एक लकड़ी कटाई स्थल पर एक वृक्ष-कटाई कर्मचारी सुरक्षा हेलमेट का फीता दो बार खींचकर कसता है। चेनसाँ के तेल के डिब्बे का ढक्कन खोलकर चेन ऑयल भरते समय उसकी उंगलियों के पोर अब भी ठंडे हैं। सुरक्षा हेलमेट उतारकर उलटकर देखें तो उसके छज्जे के भीतरी हिस्से में नाखून जितना छोटा एक धूसर पुर्जा चिपका हुआ है। जड़त्व मापन उपकरण (IMU, Inertial Measurement Unit) नामक यह पुर्जा एक छोटा सेंसर है जो मापता है कि शरीर कितना झुका हुआ है और कदम कितने तेज़ हैं। यह पुर्जा हेलमेट के भीतर कब से आ बैठा है, यह उसे ठीक-ठीक याद नहीं। कंपनी ने नए हेलमेट बाँटे हुए तीन महीने हो चुके हैं, और बची हुई एक ही अनुभूति है कि वज़न लगभग 20 ग्राम बढ़ गया है। इंजन खींचकर चालू करते ही पक्षियों की आवाज़ थम जाती है और इंजन की आवाज़ घाटी को भर देती है। आज तीन पेड़ काटने हैं, यह इलाका कल से भी अधिक तीव्र ढलान वाला है।

रोजगार एवं श्रम मंत्रालय ने मार्च 2026 में, वर्ष 2025 के पूरे साल में जमा हुए औद्योगिक दुर्घटना आँकड़े जारी किए। वानिकी और मत्स्य-पालन को मिलाकर बने उद्योग-वर्ग में दुर्घटना से मरने वालों की संख्या 18 रही, जो पिछले वर्ष से 11 अधिक है। दोनों उद्योगों को अलग-अलग करके दिखाने वाले आँकड़े अलग से न होने के कारण अकेले वानिकी की संख्या ज्ञात नहीं हो पाती, फिर भी यह तथ्य ध्यान खींचता है कि कारोबार का आकार छोटा और सुरक्षा प्रबंधन तंत्र कमज़ोर होने वाले उद्योग के रूप में इसे थोक एवं खुदरा व्यापार के साथ गिना गया। गिरते पेड़ के नीचे दब जाने या ढलान पर फिसलकर उपकरण के नीचे दब जाने की दुर्घटनाएँ हर साल दोहराई जाती रहती हैं। औद्योगिक सुरक्षा एवं स्वास्थ्य अधिनियम के प्रवर्तन अध्यादेश का अनुच्छेद 24 वानिकी को विनिर्माण उद्योग तथा मलजल-अपशिष्ट प्रसंस्करण उद्योग के साथ एक ही वर्ग में रखता है। यदि किसी कारोबार में सामान्यतः 20 से अधिक और 50 से कम स्थायी श्रमिक हैं, तो नियमित सुरक्षा प्रबंधक के बदले सही, कम-से-कम एक सुरक्षा-स्वास्थ्य प्रबंधन प्रभारी अवश्य रखना होगा। कानून व्यक्ति नियुक्त कर भी दे, तब भी तीव्र ढलान वाली भूमि पर अकेले चेनसाँ पकड़े व्यक्ति की मुद्रा तक प्रभारी वास्तविक समय में नहीं देख सकता। वानिकी के कार्यस्थलों पर काम करने वालों की उम्र हर साल बढ़ती जा रही है, और पहले जैसा शरीर न रहते हुए भी तीव्र पहाड़ चढ़ते-उतरते लोगों की संख्या भी बढ़ रही है।

वानिकी के खतरनाक होने का कारण कोई नई बात नहीं है। ढलान वाली भूमि और अनियमित भू-आकृति, भारी लकड़ी, तथा चेनसाँ जैसी उच्च-जोखिम वाली शक्ति-चालित मशीनें सब एक ही कार्यस्थल में इकट्ठा रहती हैं। अमेरिकी श्रम सांख्यिकी ब्यूरो (BLS) द्वारा संकलित 2023 के आँकड़ों में वृक्ष-कटाई मज़दूरों की मृत्यु दर प्रति एक लाख व्यक्तियों पर 98.9 है। समस्त श्रमिकों के औसत 3.5 से तुलना करें तो यह 28 गुना तक पहुँचने वाला आँकड़ा है। पेड़ काटने (Felling), टहनियाँ छाँटने (Limbing) और लट्टों को काटने

(Cross-cutting) की प्रक्रिया में श्रमिक शरीर को झुकाए, मरोड़े और एक ओर टेढ़ी मुद्रा में देर तक रखता है। ऐसी मुद्राएँ जमा हों तो यह पेशीय-कंकालीय रोग, अंग्रेज़ी संक्षेप में WMSD (Work-related Musculoskeletal Disorders) कहलाने वाली बीमारी की ओर ले जाती हैं। कमर की डिस्क या कंधे के स्नायु-शोथ की तरह इनके नाम भले ही अलग-अलग हों, पर झुकी और मरोड़ी मुद्रा के देर तक जमा होने से पैदा होने का कारण एक ही है।

इस मुद्रा को अंक देने का उपकरण OWAS (Ovako Working Posture Analysis System) है। पीठ, बाँह और पैर किस कोण पर हैं, तथा कितना वज़न उठाया है, यह देखकर चार स्तरों के जोखिम श्रेणियों में बाँटने की पद्धति है। स्तर 1 वैसी ही रहने देने योग्य मुद्रा को, और स्तर 4 अभी तुरंत मुद्रा बदल लेने की ज़रूरत वाली खतरनाक स्थिति को दर्शाता है। OWAS के अलावा RULA या REBA जैसी चचेरी-भाई किस्म की मूल्यांकन विधियाँ भी हैं, पर चाहे कोई भी हो, व्यक्ति स्क्रीन में झाँककर हाथ से अंक देने का ढाँचा एक जैसा ही था। पहले विशेषज्ञ कार्यस्थल के वीडियो को एक-एक फ्रेम आँखों से घुमाकर देखते हुए श्रेणी देते थे। इसमें बहुत समय लगता था। हर व्यक्ति का निर्णय अलग-अलग होने की समस्या भी थी। पूरे जंगल के श्रमिकों को निरंतर देखते रहना तो मूलतः मानव हाथों से सँभालने योग्य पैमाने का काम ही नहीं था। इस अंतर को पाटने के लिए कंप्यूटर विज्ञान और पहनने योग्य सेंसर को जोड़ने वाला स्वचालित मूल्यांकन तंत्र हाल के कुछ वर्षों में तेज़ी से सामने आया।

कैमरा मुद्रा को कैसे पढ़ता है

मानव मुद्रा अनुमान वीडियो में मौजूद कंधे, कोहनी, घुटने जैसे जोड़ों की स्थिति को बिंदुओं से अंकित कर उनका अनुसरण करता है। फोरकुओ (Forkuo) और उनके साथियों ने छवि और मानव कंकाल की जोड़ने वाली रेखाएँ साथ-साथ डालकर ResNet-50 मॉडल को प्रशिक्षित किया। OWAS श्रेणी को पूरी तरह समान संख्या में मिलाई गई 252 परीक्षण छवियों में सटीकता और F1 अंक 99.8 प्रतिशत रहा। यह एक छोटे संतुलित परीक्षण-सेट का परिणाम है, इसलिए इसे यँ नहीं पढ़ना चाहिए कि अवरोध और भिन्न प्रकाश-व्यवस्था वाले वास्तविक समस्त वन में भी वही प्रदर्शन पुष्ट हो गया।

उसी शोध-दल के 2025 के शोधपत्र ने निर्णय-समय और मूल्यांकनकर्ताओं के बीच सहमति की तुलना की। मॉडल ने मनुष्य से 19 गुना से 53 गुना तेज़ी से श्रेणी दी। मानव मूल्यांकनकर्ताओं के बीच Fleiss' kappa 0.28 से 0.49 था। यह आँकड़ा प्रसंस्करण गति और मनुष्यों के बीच निर्णय के अंतर को दिखाता है। यह इस बात का प्रमाण नहीं है कि मॉडल मनुष्य से अधिक सटीक है या शूटिंग कोण के बदलाव से नहीं डगमगाता। स्वचालित निर्णय समय घटा तो सकता है, पर आधार बने मनुष्य के लेबल और शूटिंग की परिस्थितियाँ गलत हों तो वही त्रुटि तेज़ी से दोहरा सकता है।

हल्के मॉडल का उपयोग करने वाला शोध भी है। फोरकुओ शोध-दल ने Inception V3 और SqueezeNet पर छवि एम्बेडिंग लागू की। विकास प्रक्रिया में 84 प्रतिशत और 89 प्रतिशत जैसे मान निकले। बिना देखे गए डेटा का प्रदर्शन लगभग 49 प्रतिशत से 60 प्रतिशत रहा। शोधपत्र ने स्मार्टफोन की कार्यस्थल तैनाती को प्रमाणित नहीं किया। मॉडल के आकार में छोटा होने का तथ्य और पहाड़ के भीतर मोबाइल फोन पर स्थिर रूप से चलने का तथ्य अलग-अलग करके देखने चाहिए।

शरीर पर लगाने वाले सेंसर और ध्वनि

कैमरे में यह कमज़ोरी है कि जो आँखों को न दिखे उसका कोई काम नहीं। पहाड़ के निचले हिस्से में, पत्तों और टहनियों से घने वृक्ष-आवरण के नीचे लेंस श्रमिक के शरीर को आधा ही समेट पाता है या पूरी तरह चूक जाना आसान है। इस अंधे कोने को पाटने वाला पक्ष पहनने योग्य सेंसर है। स्मार्टफोन या स्मार्टवॉच में लगे 3-अक्ष त्वरणमापी और जायरोस्कोप तथा शोर के संपर्क की मात्रा मापने वाले शोरमापी (Noise Dosimeter) को शरीर या उपकरण पर लगा दें तो कैमरे के लेंस के बिना भी गति और कंपन मापे जा सकते हैं। चेनसॉ पकड़े हाथ की कैपकैपी, कंधे के झुकाव का कोण, कदमों के डगमगाने की मात्रा सब संख्याओं में बदल जाते हैं। पेड़ की छाया कितनी ही गहरी हो, या कोहरा छाकर कैमरे का लेंस धुँधला हो जाए, इससे कोई फर्क नहीं पड़ता।

बोर्ज़ शोध-दल ने लट्टों को काटने वाले कटाई-कार्य में श्रमिक और चेनसॉ पर लगाए गए त्वरणमापी तथा शोरमापी के डेटा से सात मॉडलों का परीक्षण किया। पीठ पर लगाए एक त्वरणमापी का उपयोग करने पर सटीकता 63 प्रतिशत रही, और चेनसॉ के त्वरण तथा शोर को मिलाने वाली कुछ व्यवस्थाओं में 99.8 प्रतिशत निकला। शोध ने जिसमें भेद किया वह है काम, विश्राम, गति जैसी सक्रियता-अवस्थाएँ। यह ऐसा परीक्षण नहीं था जिसने अत्यधिक जोड़-मुड़ाव या थकान का उसी सटीकता से निदान किया हो। सेंसर की स्थिति और व्यवहार-श्रेणियाँ बदलने पर प्रदर्शन को फिर से मापना होगा।

कोरिया में भी सेंसर लगे सुरक्षा हेलमेट का परिचय हुआ। 21 मई 2025 की रिपोर्ट में असगार्ड ने बताया कि निर्माण श्रमिकों के लिए स्मार्ट सुरक्षा हेलमेट 'TUGU' में आघात तथा तापमान-आर्द्रता सेंसर, कैमरा और वायरलेस संचार सुविधा डाली गई है। यह निर्माता की व्याख्या को प्रस्तुत करने वाला लेख है, स्वतंत्र कार्यस्थल प्रदर्शन सत्यापन नहीं। यह वानिकी-विशेष उत्पाद भी नहीं है। वन विभाग ने अक्टूबर 2020 में राष्ट्रीय चिलगोक वन-अनुभव केंद्र में जंगल की आग बुझाने वाले दल के लिए पहनने योग्य रोबोट और बुद्धिमान सुरक्षा हेलमेट के प्रारूप प्रस्तुत किए। इसके बाद यह उपकरण देश भर के वृक्ष-कटाई कार्यस्थलों पर मानक आपूर्ति-सामग्री बन गया, इसका कोई प्रमाण पुष्ट नहीं होता।

पसीने और कठोर काम के कारण सेंसर का शरीर से गिर जाना, बैटरी का दिन भर के काम के समय तक न टिक पाना, और श्रमिक का पहनने से ही कतराना, यहाँ तक कि पहनने योग्य तकनीक कैमरे से भिन्न किस्म की अड़चनें लिए हुए है। शोधकर्ताओं ने स्वयं भी इन तीनों को कैमरा-पद्धति के विपरीत खड़ी स्पष्ट तकनीकी अदला-बदली के रूप में रेखांकित कर रखा है।

जब सुरक्षा हेलमेट बात करने लगे

मुद्रा मापने के काम से अलग, बड़े भाषा मॉडल को वानिकी सुरक्षा परामर्श में इस्तेमाल किया जा सकता है या नहीं, इसकी पड़ताल करने वाला शोध भी सामने आया। आरिमिज़ु केन-गो (Arimizu Ken-go, 2026) ने वानिकी की दुर्घटना स्थितियों और विशेषज्ञ प्रश्नों के प्रति मॉडल के उत्तरों का मूल्यांकन कर संभावनाओं और सीमाओं को व्यवस्थित किया। यह ऐसा शोध नहीं था जिसमें अतीत की दुर्घटना रिपोर्टें और कार्यस्थल की तस्वीरें लेकर जोखिम स्तर स्वतः तय करने वाला पूर्ण कार्यस्थल तंत्र तैनात किया गया हो। अटके हुए पेड़ जैसे संदर्भ-प्रधान जोखिमों को केवल मॉडल के उत्तर से नहीं निपटाना चाहिए, बल्कि दक्ष व्यक्ति की पुष्टि से गुज़ारना चाहिए।

शिक्षा के क्षेत्र में हायाशी (Hayashi) शोध-दल का 2025 और 2026 में प्रकाशित शोध ध्यान खींचता है। ChatGPT आधारित संवादात्मक एजेंट को वानिकी सुरक्षा शिक्षा के कार्ड गेम में परामर्शदाता की भूमिका में जोड़ा गया। हर कार्ड पर कटाई कार्यस्थल में सचमुच घट सकने योग्य स्थिति और प्रश्न लिखा है, और प्रतिभागी ने जो उत्तर चुना वह सही है या नहीं, यह एजेंट फिर से जाँचकर बताता है। इस गेम को विश्वविद्यालय के छात्रों और अकुशल व्यक्तियों पर लागू करने से पहले और बाद की तुलना की गई। कार्यस्थल सुरक्षा व्यवहार मापने वाले 40 प्रश्नों के पैमाने में सुरक्षा संचार, व्यक्तिगत सुरक्षा सुनिश्चित करना आदि पाँचों क्षेत्रों में सांख्यिकीय रूप से स्पष्ट अंक-वृद्धि दिखी। हालाँकि शुरू में भूल-चूक भी हुई। सामान्य-उपयोग भाषा मॉडल ने ईंधन के डिब्बे की सामग्री या चेनसाँ की धार तेज़ करने की विधि (目立テ) जैसे वानिकी-विशेष प्रश्नों पर आठ बार बेतुके यांत्रिक-अभियांत्रिकी गलत उत्तर दे डाले। वानिकी सुरक्षा ज्ञान के कार्ड को प्रॉम्प्ट में पहले से डाल रखने वाली इन-कॉन्टेक्स्ट लर्निंग (In-context Learning) पद्धति से कस्टम मॉडल को फिर से गढ़ा गया, तो गलत उत्तर घटकर दो रह गए। प्रश्न और सही उत्तर के उदाहरण प्रॉम्प्ट की शुरुआत में पहले से जोड़ रखें, तो मॉडल उन उदाहरणों को संदर्भ बनाकर उत्तर चुनता है। यह मॉडल को शुरू से फिर प्रशिक्षित करने की तुलना में तेज़ और सस्ती विधि है। कार्यस्थल की आवाज़ को अक्षरों में बदलने वाले स्वचालित वाणी पहचान चरण में चेनसाँ कार्य-पोशाक का निचला भाग 'चैप्स (Chaps)' या अटके हुए पेड़ को कहने वाला 'काकारिगी' जैसे विशेष शब्द बेतुके अक्षरों में बदल जाने की समस्या भी पाई गई। इसे रोकने के लिए 'क्या यह शब्द सही है' पूछकर पुनः जाँचने की पुष्टि प्रक्रिया मानक दिशानिर्देश के रूप में प्रस्तावित की गई।

एर्लिश-सोमर (Ehrlich-Sommer) और उनके साथियों द्वारा 2025 में प्रस्तुत ForestGPT ऑस्ट्रिया के पूता एक्सपो में लगभग 1 मेगावाइट परिमाण की आयोजन-सामग्री के आधार पर आगंतुकों के प्रश्नों का उत्तर देने वाला एक संवादात्मक प्रारूप था। खोज-संवर्धित उत्पादन, वन वृद्धि सिम्युलेटर, तथा सेंसर-ड्रोन-मशीन डेटा से जुड़ाव आगे आने वाले विकास चरण हैं। वर्तमान प्रारूप ये सारी सुविधाएँ रखने वाला वन कार्यस्थल-उपयोगी मॉडल नहीं है।

निगरानी में होने का एहसास

कार्यस्थल पर इस तकनीक के सचमुच उपयोग होने का चित्र खींचें तो यह ऐसा है। दफ्तर की मॉनिटर पर उस दिन काम करने वाले कई वृक्ष-कटाई श्रमिकों के जोखिम स्तर वास्तविक समय में उभरते हैं, और स्तर 4 तक पहुँचते ही प्रभारी के मोबाइल फोन पर सूचना चली जाती है। सुरक्षा प्रबंधन के पक्ष में यह स्वागत योग्य चित्र है, पर सुरक्षा हेलमेट पहने व्यक्ति के पक्ष से देखें तो यह एक अलग चित्र भी है।

तकनीक जितनी जमा होती है, अदला-बदली उतनी ही स्पष्ट होती जाती है। कैमरे में शरीर पर कुछ भी लगाने की ज़रूरत नहीं, पर टहनी से ढँकने पर चूक जाता है। पहनने योग्य सेंसर ढँकने पर भी नहीं चूकता, पर पसीना, बैटरी और पहनने की अनिच्छा का बोझ छोड़ जाता है। सामान्य-उपयोग भाषा मॉडल कई भाषाओं में लचीले ढंग से बातचीत करता है, पर वानिकी ज्ञान उथला होने के कारण बकवास गढ़ लेता है। ज्ञान पहले से डाला हुआ कस्टम मॉडल गलत उत्तर तो घटाता है, पर कार्ड में न होने वाला प्रश्न आते ही जानकारी न होने की बात कहकर मुँह बंद कर लेता है। सटीक उत्तर और लचीली बातचीत के बीच तराजू का पलड़ा किसी एक ओर पूरी तरह नहीं झुकता। दोनों में से कोई भी अकेले पर्याप्त नहीं है।

मूलभूत समस्या यही है कि प्रयोगशाला के वर्गीकरण मॉडल और कार्यस्थल के आपातकालीन ब्रेक के बीच अंतराल शेष रहता है। संचार टूट जाने वाले वन में मुद्रा-निर्णय या व्यक्ति-पहचान को मशीन नियंत्रण से बाँधने वाला पूर्ण सत्यापन अब भी दुर्लभ है। वास्तविक वृक्ष-कटाई कार्यस्थल में कीचड़-पानी और ठंड, संचार-विच्छेद, हर मशीन की ब्रेकिंग दूरी तक को साथ में परखना होगा।

कैमरे को कार्यस्थल पर हरदम चालू रखने के काम में एक और भार है। अपनी मुद्रा को दिन भर लेंस देखता रहे, इस तथ्य का स्वागत करने वाले श्रमिक कम ही हैं। सुरक्षा हेलमेट के भीतरी सेंसर से कंपनी के सर्वर पर जाने वाले डेटा को कौन रखता है, कितने समय तक संग्रहीत करता है, और दुर्घटना होने के अलावा किसी अन्य उपयोग में भी लगाया जाता है या नहीं, इस प्रश्न का स्पष्ट उत्तर देने वाला शोध अब तक नहीं आया लगता। दफ्तर-कर्मियों को लक्ष्य बनाकर हुई कृत्रिम बुद्धिमत्ता निगरानी की बहस में भी, कंपनी द्वारा सुरक्षा के नाम पर जुटाए गए डेटा को चुपके से किसी अन्य मूल्यांकन में लगा देने के उदाहरण बार-बार रेखांकित किए जाते हैं। भूमि, अवसंरचना एवं परिवहन मंत्रालय तथा कोरिया अवसंरचना सुरक्षा निगम ने मई 2026 में स्मार्ट सुरक्षा उपकरण उपयोग दिशानिर्देश में संशोधन किया। पहनने योग्य कैमरे सहित श्रमिक सुरक्षा उपकरणों को तीन मुख्य वर्गों और सात उप-वर्गों वाली प्रणाली में फिर से गढ़ा गया। यह दिशानिर्देश निर्माण कार्यस्थल को लक्ष्य बनाकर बनाया गया। वानिकी कार्यस्थल को अलग से लक्ष्य बनाने वाला दिशानिर्देश अगस्त 2026 तक भी नहीं आया।

कैमरे और सेंसर तथा सर्वर के उपयोग शुल्क को हर महीने वहन करने वाला पक्ष अधिकांशतः कुछ ही लोगों वाले छोटे वृक्ष-कटाई कारोबार हैं। दाम न वहन कर पाने के कारण उपयोग टालने वाले कारोबार, और लागत वहन कर लेने पर भी डेटा को कैसे इस्तेमाल किया जाए, इस पर श्रमिकों से जूझने वाले कारोबार के बीच, तकनीक अब तक व्यापक रूप से नहीं फैल पाई। दूर-नियंत्रित कटाई-मशीन और स्वचालित-चालित फॉरवर्डर लोगों को खतरनाक ढलान से खींचकर निकालते हुए भी, हाथ से चेनसॉ पकड़कर बचे रहने वाले व्यक्ति फिलहाल गायब नहीं होंगे। सुरक्षा निगरानी तकनीक जिस पर निशाना साधती है, वह अंततः वैसे ही बचकर काम करने वाले लोग हैं।

Grad-CAM और SHAP जैसी तकनीकों से कृत्रिम बुद्धिमत्ता ने शरीर के किस अंग को देखकर खतरनाक होने का निर्णय लिया, इसे रंग से इंगित करके दिखाने वाली व्याख्या-योग्य कृत्रिम बुद्धिमत्ता, XAI (Explainable AI) डैशबोर्ड अगले चरण के रूप में चर्चित है। ज्ञान आसवन (Knowledge Distillation) से मॉडल को छोटा घटाकर संचार टूटे पहाड़ के भीतर के उपकरण में भी डालने की योजना भी शोधपत्र में मौजूद है। कैमरे, पहनने योग्य उपकरण और भाषा मॉडल को एक ही पाइपलाइन में बाँधकर पेशीय-कंकालीय रोग रोकने और दुर्घटना को शुरुआत में ही पकड़ लेने वाला तंत्र खड़ा करने का काम, योजना के रूप में तो पहले से ही कई शोधपत्रों में लिखा हुआ है। वह योजना असली वृक्ष-कटाई कार्यस्थल की मानक सामग्री के रूप में आपूर्ति होने का समय, तथा जुटाए गए वीडियो और संकेतों को कौन कितने समय तक संग्रहीत करेगा, यह तय करने वाला नियमन, ये दोनों अब तक नहीं आए हैं। श्रेणी देने और जोखिम की सूचना देने वाला पक्ष उत्तरोत्तर परिष्कृत होता जा रहा है, पर उसके परिणाम को किसके हाथ सौंपा जाए, यह तय करने वाला नियमन अभी उतना परिष्कृत नहीं हो पाया है।

स्रोत और संदर्भ

1. Borz, S. A., Kaakkurivaara, T., Forkuo, G. O., & Kaakkurivaara, N. (2026). Activity recognition in motor-manual cross-cutting operations by machine learning on multimodal data. *Forest Science and Technology*, 22, 26-35. <https://doi.org/10.1080/21580103.2025.2543281>
2. Ehrlich-Sommer, F., Eberhard, B., & Holzinger, A. (2025). ForestGPT and beyond: A trustworthy domain-specific large language model paving the way to Forestry 5.0. *Electronics*, 14(18), 3583. <https://doi.org/10.3390/electronics14183583>
3. Forkuo, G. O., Borz, S. A., Kaakkurivaara, T., & Kaakkurivaara, N. (2025a). Postural classification by image embedding and transfer learning: An example of using the OWAS method in motor-manual work to automate the process and save resources. *Forests*, 16(3), 492. <https://doi.org/10.3390/f16030492>
4. Forkuo, G. O., Marcu, M. V., Kaakkurivaara, N., Kaakkurivaara, T., & Borz, S. A. (2025b). Human and machine reliability in postural assessment of forest operations by OWAS method: Level of agreement and time resources. *Forests*, 16(5), 759. <https://doi.org/10.3390/f16050759>
5. Forkuo, G. O., Bilici, E., & Borz, S. A. (2026). Automated OWAS in forestry using deep learning for posture classification. *International Journal of Industrial Ergonomics*, 113, 103930. <https://doi.org/10.1016/j.ergon.2026.103930>
6. Forkuo, G. O., Picchio, R., Proto, A. R., & Borz, S. A. (2026). Applications of artificial intelligence in forest operations engineering research: A systematic review. *Current Forestry Reports*, 12, Article 14. <https://doi.org/10.1007/s40725-026-00275-x>
7. Hayashi, K., Shimazaki, K., Takahashi, A., Ikeda, M., & Matsumoto, Y. (2025/2026). AI सलाहकार जोड़े गए वानिकी सुरक्षा शक्तिषा गेम का व्यवहार और अधगमि प्रभाव सत्यापन, पूर्व-पश्चात तुलना तथा उच्चारण-वशिलेषण आधारति मूल्यांकन. *Journal of Occupational Safety and Health*, 18/19, 1-12. <https://doi.org/10.2486/josh.JOSH-2025-0011-GE>
8. Arimizu, K. (2026). बड़े भाषा मॉडल का उपयोग करते हुए वानिकी सुरक्षा सहायता की संभावनाओं और सीमाओं पर एक अध्ययन. *Journal of the Japan Forest Engineering Society*, 41(1), 5-14. <https://doi.org/10.18945/jjfes.2026.250013>
9. Japan Forest Machinery Association. (2026). FY2025 वानिकी, काष्ठ उद्योग कार्य सुरक्षा संवर्धन वेबिनार, पूर्ण संस्करण [वीडियो]. YouTube. <https://www.youtube.com/watch?v=Q1w9DxFpgE8> (2 अगस्त 2026 को अभगिमति)
10. Japan Forest Machinery Association. (2026). Part 3, FY2025 स्मार्ट वानिकी मशीन एवं काष्ठ-आधारति नव-सामग्री संगोष्ठी [वीडियो]. YouTube. https://www.youtube.com/watch?v=uzSCOk_qQI8 (2 अगस्त 2026 को अभगिमति)
11. रोजगार एवं श्रम मंत्रालय. (2026, 31 मार्च). 2025 वर्ष (संचयी) औद्योगिक दुर्घटना स्थिति अतिरिक्त सांख्यिकी. https://www.moel.go.kr/news/enews/report/enewsView.do?news_seq=19159 (2 अगस्त 2026 को अभगिमति)
12. भूमि, अवसंरचना एवं परिवहन मंत्रालय · कोरिया अवसंरचना सुरक्षा नगिम. (2026, 6 मई). निर्माण कार्यस्थल स्मार्ट सुरक्षा उपकरण का चयन एवं उपयोग और आसान होगा. <https://v.daum.net/v/20260506110012733> (2 अगस्त 2026 को अभगिमति)
13. मशीनरी एवं उपस्कर समाचार. (2025, 21 मई). असगारड ने निर्माण श्रमिकों के अनुरूप स्मार्ट सुरक्षा हेलमेट 'TUGU' वकिसति कयि. <https://www.kmecnews.co.kr/news/articleView.html?idxno=41084> (2 अगस्त 2026 को अभगिमति)
14. बोआन न्यूज़. (2020, 31 अक्टूबर). पहनने योग्य रोबोट, बुद्धिमिान सुरक्षा हेलमेट से वन आपदा का सामना. <https://m.boannews.com/html/detail.html?idx=92245> (2 अगस्त 2026 को अभगिमति)

अध्याय 5

सतत कृषि वानिकी और लकड़ी आपूर्ति शृंखला का डिजिटल रूपांतरण

5.1

कृषि वानिकी प्रणालियों में जल-उपयोग दक्षता (WUE) और पारिस्थितिकी तंत्र सेवाओं का अनुकूलन

उत्तरी भारत के पंजाब में, जब सूरज सुबह-सुबह गेहूं के खेत में पहुँचता है, तो उसके बीच में खड़ी चिनार की कतार की छाया धीरे-धीरे हिलने लगती है। 20 मीटर से अधिक ऊँचे पेड़ों की कतार सुबह के समय मैदान के पश्चिम की ओर खाँचों को ढँक देती है; दोपहर के समय छाया पेड़ों के पैरों तक सिमट जाती है, और शाम को यह फिर से विपरीत दिशा की खाँचों को ढँक लेती है। मिट्टी से उठने वाली गर्मी मृगतृष्णा की तरह कांपती है, और गेहूं की बालें बार-बार नीचे झुकती हैं और गर्मियों की शुरुआत में ऊपर उठती हैं। कोई भी किसान जिसने उस खेत में वर्षों बिताए हैं, वह जानता है कि जहाँ पेड़ की छाया चली गई है और जहाँ नहीं गई है, वहाँ गेहूं का रंग सूक्ष्म रूप से भिन्न होता है। किसान के लिए ये पेड़ दो चेहरों वाले पड़ोसी हैं। उनकी जड़ें गहरी होती हैं और पानी खींचती हैं जिसे गेहूं को पीना चाहिए, लेकिन उनके तने और पत्तियां गर्म हवाओं को रोकती हैं और मिट्टी में नमी बनाए रखती हैं। अकेले देखने से यह उत्तर नहीं मिल सकता कि क्या पेड़ चोर हैं जो पानी लेते हैं या संतरी हैं जो इसकी रक्षा करते हैं। ये चिनार केवल छाया देने के लिए खड़े नहीं होते। एक बार जब उनके तने मोटे हो जाते हैं, तो वे माचिस की तीलियों, प्लाईवुड या कागज के लिए बेची जाने वाली लकड़ी बन जाते हैं, इसलिए गेहूं की खेती और पेड़ों की खेती एक ही खेत में होती है। उत्तर के लिए संख्याओं में यह मापना आवश्यक है कि जड़ों के नीचे क्या होता है और प्रत्येक पत्ती कितना पानी छोड़ती है।

एक ही भूमि पर पेड़ों और फसलों और कभी-कभी पशुधन को एक साथ उगाने की प्रथा को कृषि वानिकी कहा जाता है। पेड़ की जड़ें पानी के लिए फसलों के साथ प्रतिस्पर्धा कर सकती हैं और साथ ही छाया और पत्तों के कूड़े के माध्यम से वाष्पीकरण और मिट्टी के नुकसान को कम कर सकती हैं। जल-उपयोग दक्षता, वास्तविक वाष्पीकरण-उत्सर्जन द्वारा उपज को विभाजित करके गणना की जाती है, इन दो प्रभावों के परिणाम का एक संकेतक है। संयुक्त राष्ट्र के खाद्य और कृषि संगठन द्वारा व्यापक रूप से उपयोग किए जाने वाले आँकड़ों के अनुसार, वैश्विक मीठे पानी की निकासी में 70 प्रतिशत से अधिक का योगदान कृषि का है। "अस्सी प्रतिशत उपभोग" और "70 प्रतिशत से अधिक निकासी" एक ही संकेतक नहीं हैं।

दक्षिण कोरिया में, कृषि भूमि पर पेड़ लगाए जाने पर कानूनी भूमि श्रेणी और सार्वजनिक-हित प्रत्यक्ष भुगतान की पात्रता भूमि की स्थिति, खेती की विधि और संबंधित कार्यक्रम की आवश्यकताओं द्वारा निर्धारित की जाती है। पेड़ लगाने से कृषि भूमि स्वचालित रूप से वन भूमि में नहीं बदल जाती है या किसान भुगतान पात्रता खो नहीं देता है। गोद लेने पर विचार करने वाले किसानों को पहले स्थानीय सरकार और राष्ट्रीय कृषि उत्पाद गुणवत्ता प्रबंधन सेवा के साथ संबंधित पार्सल की आवश्यकताओं की पुष्टि करनी चाहिए।

जड़ों के नीचे का अंकगणित

कृषिविज्ञानी इस गणना के लिए दो व्यापक दृष्टिकोणों का उपयोग करते हैं। एक है अपने हाथ ज़मीन में डालना और सीधे मापना। जब टाइम-डोमेन रिफ्लेक्टोमेट्री (टीडीआर) और फ्रीक्वेंसी-डोमेन रिफ्लेक्टोमेट्री (एफडीआर) जांच को जड़ों के पास मिट्टी में डाला जाता है, तो वे मिट्टी के कणों के बीच पानी कितनी तेजी से विद्युत संकेत प्रसारित करता है, उससे नमी की मात्रा निर्धारित करते हैं। उन मूल्यों को प्राप्त करने के लिए, एक शोधकर्ता को सुबह से ही जूते पहनने चाहिए और जांच डालते हुए क्षेत्र में घूमना चाहिए। क्योंकि सिग्नल मिट्टी की स्थिति के साथ बदलता रहता है, यहां तक कि विश्वसनीय मूल्य प्राप्त करने के लिए एक ही स्थान को कई दिनों तक बार-बार मापा जाना चाहिए। न्यूट्रॉन जांच और स्वचालित मौसम स्टेशनों को जोड़ने से घंटे दर घंटे रिकॉर्ड करना संभव हो जाता है कि पेड़ की जड़ें और फसल की जड़ें एक ही मिट्टी की परत में कितना पानी साझा करती हैं। गेहूं-आधारित कृषिवानिकी की 2026 की व्यवस्थित समीक्षा के अनुसार, शोधकर्ता इन क्षेत्र मापों को फसल और मिट्टी-नमी मॉडलिंग कार्यक्रमों जैसे क्रॉपवाट, एक्वाक्रॉप और एपीएसआईएम में डालते हैं ताकि यह अनुकरण किया जा सके कि पानी प्रत्येक जड़ परत के माध्यम से कैसे चलता है।

इस तरह का हाथ से किया जाने वाला काम पूरे क्षेत्र को कवर नहीं कर सकता है, इसलिए उपग्रह उस कार्य को अपने हाथ में लेते हैं। सामान्यीकृत अंतर जल सूचकांक (एनडीडब्ल्यूआई, एक सूचकांक जो पौधों की पत्तियों से परावर्तित प्रकाश की तरंग दैर्ध्य का विश्लेषण करके नमी का अनुमान लगाता है) और भूमि-सतह के तापमान जैसे मान सेंटिनल और लैंडसैट जैसे उपग्रहों द्वारा ली गई इमेजरी से निकाले जा सकते हैं। जब उन मूल्यों को वाष्पीकरण-उत्सर्जन मॉडल जैसे कि SEBAL या METRIC में फीड किया जाता है, तो वे मैप कर सकते हैं कि क्षेत्र के कौन से हिस्से सूखे हैं और कौन से गीले हैं। रैंडम फ़ॉरेस्ट जैसे एल्गोरिदम जोड़ें, एक मशीन-लर्निंग विधि जिसमें कई निर्णय-वृक्ष मॉडल प्रत्येक एक उत्तर देते हैं और अंतिम उत्तर बहुमत के वोट के साथ-साथ समर्थन-वेक्टर मशीनों, कृत्रिम तंत्रिका नेटवर्क और XGBoost द्वारा निर्धारित किया जाता है, और एक मॉडल जल-उपयोग दक्षता की भविष्यवाणी करने के लिए मिट्टी की स्थिति, सिंचाई कार्यक्रम और पेड़ की छाया की डिग्री को एक साथ सीख सकता है। समीक्षा में पाया गया कि केवल शाखाओं की छंटाई और छाया के बीच के अंतर को समायोजित करने से अंडरस्टोरी फसलों की सतह से पानी की कमी को कम करके और जमीन में घुसपैठ करने वाले सिंचाई के पानी की हिस्सेदारी को बढ़ाकर पूरे सिस्टम की जल दक्षता में सुधार किया जा सकता है। किसानों के लिए यह गणना मायने रखती है इसका कारण स्पष्ट है। सिंचाई के समय या मात्रा में एक या दो दिन का बदलाव उस वर्ष की फसल को तेजी से प्रभावित कर सकता है। बार-बार पड़ने वाले सूखे के युग में, पानी की एक बूंद का मूल्य वह नहीं रह गया है जो पहले था।

उपग्रहों द्वारा तैयार किया गया कृषि वानिकी मानचित्र

भारत के पश्चिमी तट पर, गोवा में, कुलागर नामक एक पारंपरिक कृषि प्रणाली है। एरेका पाम को काली मिर्च, कोको या केले के साथ लगाया जाता है ताकि छाया और नमी साझा की जा सके। कुलागर भूखंड में प्रवेश करें और ऊपर ताड़ के पत्तों से बनी छत है; इसके नीचे काली मिर्च की लताएँ ताड़ के तनों को लपेटती हैं, जबकि केले और मसाले की फसलें पैरों पर खड़ी होती हैं। प्रत्येक परत पर अलग-अलग पौधे अलग-अलग ऊंचाई पर पानी और सूरज की रोशनी साझा करते हैं। अकेले उपग्रह चित्रों से इस क्षेत्र, निकटवर्ती शुद्ध ताड़ के बागान और प्राकृतिक जंगल में अंतर करना मुश्किल लग सकता है। उथप्पा और उनके सहयोगियों ने सेंटिनल सैटेलाइट इमेजरी पर तीन मशीन-लर्निंग मॉडल, रैंडम फॉरेस्ट, ग्रेडिएंट बूस्टिंग और सपोर्ट-वेक्टर मशीनें चलाकर उस अंतर को निपटाया। सामान्य वनस्पति सूचकांक केवल यह दिखाते हैं कि पत्तियाँ कितनी हरी हैं, और इसलिए बरसात के मौसम के ठीक बाद एक अच्छी तरह से सिंचित कृषि वानिकी भूखंड को प्राकृतिक जंगल के रूप में भ्रमित कर सकते हैं। इसीलिए एक अलग नमी-उत्तरदायी सूचकांक का उपयोग किया जाता है। परिणाम स्पष्ट था।

NDWI2, एक जल सूचकांक जो सीधे पेड़ और फसल की पत्तियों में नमी को दर्शाता है, तीनों मॉडलों में क्षेत्र-वर्गीकरण सटीकता निर्धारित करने वाले प्रमुख चर के रूप में उभरा। ग्रेडिएंट-बूस्टिंग मॉडल ने 0.86 की सटीकता और एक कप्पा गुणांक दर्ज किया, जो 0.83 के संयोग के कारण समझौते को फ़िल्टर करता है, जिससे इसका वर्गीकरण तीन मॉडलों में सबसे स्थिर हो जाता है।

उपग्रहों की उस क्षेत्र को पढ़ने की क्षमता जहां फसलें और पेड़ आपस में जुड़े हुए हैं, नीति निर्माताओं को कृषि वानिकी का विस्तार करने के लिए एक उपयोगी उपकरण प्रदान करती है। वे हर साल हर क्षेत्र का दौरा किए बिना यह पता लगा सकते हैं कि किसी दिए गए क्षेत्र में कृषिवानिकी कितने व्यापक रूप से फैली है। कोरिया का वार्षिक वानिकी प्रबंधन सर्वेक्षण समान आँकड़ों से संबंधित है, लेकिन यह कृषि प्रभावली और क्षेत्र सर्वेक्षणों पर बहुत अधिक निर्भर करता है और अभी तक उपग्रह मानचित्रों द्वारा स्वचालित रूप से अपडेट की गई प्रणाली तक नहीं पहुँच पाया है।

कॉफी-पेड़ की छाया की सटीक गणना

इंडोनेशियाई कॉफी क्षेत्रों में, यह प्रश्न कुछ अलग ढंग से प्रस्तुत किया जाता है: कॉफी के पेड़ों को सीधी धूप और पानी के तनाव से बचाने के लिए ऊपरी परत में कहाँ और कितने छायादार पेड़ लगाए जाने चाहिए?

रिडलो और सहकर्मियों ने इस प्लेसमेंट समस्या को ग्राफ़ सिद्धांत से तैयार आरआईडीएस एल्गोरिदम के साथ संबोधित किया। सीधे शब्दों में कहें, तो यह क्षेत्र को बिंदुओं से जुड़े बिंदुओं के एक नेटवर्क के रूप में मानता है और गणना करता है कि कहाँ पेड़ लगाए जाने चाहिए ताकि छाया अत्यधिक न हो और मैदान के हर कोने तक समान रूप से पहुंचे।

रिडलो और सहकर्मियों ने एक ग्राफ़ के रूप में छाया-वृक्ष और सेंसर स्थिति की गणना की। 96 कॉफी पेड़ों और 26 छायादार पेड़ों वाले परिदृश्य में, वार्षिक कार्बन-डाइऑक्साइड पृथक्करण की गणना 520 किलोग्राम की गई थी। एक ग्रिड में 31 छायादार पेड़ों की व्यवस्था के साथ यह आंकड़ा 620 किलोग्राम था। ये मॉडल गणनाएं हैं, लंबी अवधि में क्षेत्र में मापी गई कार्बन मात्राएं नहीं।

शोधकर्ताओं ने 10 से 20 दिन पहले सापेक्ष आर्द्रता और कार्बन-डाइऑक्साइड सांद्रता की भविष्यवाणी करने के लिए एक स्पेटियोटेम्पोरल ग्राफ न्यूरल नेटवर्क का उपयोग किया। व्याख्यात्मक शक्ति सेटिंग के आधार पर 0.73 से 0.81 तक थी। ये परिणाम मॉडल तुलनाओं से प्राप्त किये गये। वे कोई दीर्घकालिक क्षेत्रीय परीक्षण नहीं हैं जो दिखाते हैं कि कॉफी किसानों ने वास्तविक सिंचाई कार्यक्रम और बेहतर उपज या पानी के उपयोग के लिए प्रणाली का उपयोग किया।

जल से परे पारिस्थितिकी तंत्र सेवाएँ

पारिस्थितिकी तंत्र सेवाएँ वे लाभ हैं जो प्रकृति मानव हस्तक्षेप के बिना प्रदान करती है, जैसे कि वन, आर्द्रभूमि और ज्वारीय समतल। साफ पानी को छानना, बाढ़ को धीमा करना और अगली पीढ़ी की फसलों के परागण में मदद के लिए मधुमक्खियों और पक्षियों को जीवित रखना सभी इस शब्द के अंतर्गत आते हैं। कृषि वानिकी के लाभ उपज और जल दक्षता तक सीमित नहीं हैं। पेड़ों की जड़ें बारिश से मिट्टी को बहने से रोकती हैं, जबकि पत्तों का कूड़ा और छाया पक्षियों और कीड़ों को आश्रय प्रदान करते हैं।

सिल्वा और उनके सहयोगियों द्वारा उपग्रह समय-श्रृंखला विश्लेषण, जिन्होंने 20 वर्षों तक उपोष्णकटिबंधीय दक्षिणी ब्राजील का अवलोकन किया, इस मूल्य पर संख्याएँ डालते हैं। 2000 के आसपास, कृषि वानिकी द्वारा कब्जा किया गया निवास क्षेत्र 400 हेक्टेयर से थोड़ा अधिक था। 2020 तक यह बढ़कर लगभग 660 हेक्टेयर हो गया। इसी अवधि में, बिखरे हुए प्राकृतिक वनों को जोड़ने वाले आवास-एकत्रीकरण सूचकांक में भी वृद्धि हुई। प्राकृतिक वन जो खेतों और खेतों के बीच टुकड़ों की तरह बिखरे हुए थे, कृषि वानिकी बेल्ट के साथ फिर से जुड़ने लगे थे।

इसका मतलब यह नहीं है कि कृषि वानिकी पूरी तरह से प्राकृतिक वन की जगह ले सकती है। डोहर्टी और हैगर (2026) ने रिमोट सेंसिंग और फ़िल्ड डेटा का उपयोग करके कोस्टा रिकन प्राकृतिक वन की तुलना कॉफी और चारागाह कृषि वानिकी से की। ज़मीन के ऊपर कार्बन भंडारण और पेड़-प्रजातियों की विविधता भूमि के प्रकार के अनुसार भिन्न होती है। प्राकृतिक वन में, कार्बन-समृद्ध स्थानों और उच्च वृक्ष-प्रजाति विविधता वाले स्थानों के बीच स्थानिक ओवरलैप 25.5 प्रतिशत था। कृषि वानिकी खेती योग्य भूमि में पेड़ और कनेक्टिविटी बढ़ा सकती है, लेकिन यह प्राकृतिक वन के कार्बन और जैव विविधता मूल्यों की गारंटी नहीं देती है।

जेमल (2026) ने एफ1000रिसर्च में एक व्यवस्थित समीक्षा का संस्करण 1 जारी किया, जिसमें इथियोपियाई कृषिवानिकी के लिए रिमोट सेंसिंग और गहन शिक्षण में अनुसंधान रुझानों को व्यवस्थित किया गया। यह एक प्रायोगिक पेपर नहीं है जो सीधे तौर पर एक ही साइट पर कन्वेन्शनल न्यूरल नेटवर्क, यू-नेट और विज़न ट्रांसफार्मर की तुलना करता है। घाना में, विश्व संसाधन संस्थान ने प्राकृतिक वन, मोनोकल्चर वृक्षारोपण और कृषि वानिकी में अंतर करने के लिए स्थानांतरण शिक्षण का उपयोग करके शोध प्रकाशित किया। यदि वर्गीकरण परिणामों का उपयोग नीति में किया जाना है, तो प्रत्येक वर्ग के लिए फ़िल्ड नमूने और ग़लत वर्गीकरण मानचित्रों का एक साथ खुलासा किया जाना चाहिए।

भारत में, चव्हाण और उनके सहयोगियों द्वारा आंवले के पेड़ों के नीचे सोयाबीन रोपने के एक प्रयोग से पता चला कि केवल छाया की तीव्रता को समायोजित करने से सोयाबीन के शरीर विज्ञान और खराब मिट्टी में भी उपज बदल सकती है। जिंजर और सहकर्मियों ने एक प्रयोग का प्रदर्शन किया जिसमें एक सिल्वो-एरोमैटिक

प्रणाली, औषधीय और सुगंधित पेड़ों को मिट्टी-नमी-संरक्षण तकनीकों के साथ जोड़कर, खराब भूमि पर मिट्टी की संरचना को बहाल किया और कार्बन डाइऑक्साइड को अलग किया। औषधीय और सुगंधित पेड़ों के जड़ पकड़ने से पहले, खराब भूमि आमतौर पर बारिश होने पर चैनलों में गंदा पानी बहाती है और शुष्क मौसम में केवल धूल उठाती है। पेड़ों और जल-प्रबंधन संरचनाओं को एक साथ स्थापित करने के बाद, उसी भूमि से कम मिट्टी खोती है और वर्षा जल को जड़ों के बीच घुसपैठ करने के लिए अधिक समय मिलता है। अलग-अलग देशों और अलग-अलग पेड़ों पर किए गए ये अध्ययन एक ही दिशा की ओर इशारा करते हैं: पेड़ और फसल दोनों वाली भूमि मिट्टी को बनाए रख सकती है, पानी बचा सकती है और कार्बन जमा कर सकती है। 2022 की समीक्षा में ऐसे व्यक्तिगत मामलों को मृदा स्वास्थ्य के ढांचे के तहत एक साथ लाया गया और कृषिवानिकी को कुछ कृषि प्रणालियों में से एक के रूप में वर्णित किया गया जो रासायनिक उर्वरकों पर भरोसा किए बिना मिट्टी की उर्वरता को बहाल कर सकती है।

संख्याएँ क्या चूकती हैं

एक ही उपग्रह छवि के साथ भी, मॉडल कभी-कभी अलग-अलग उत्तर देते हैं। गोवा कुलागर अध्ययन में, यादृच्छिक वन और ग्रेडिएंट-बूस्टिंग मॉडल ने समर्थन-वेक्टर मशीन की तुलना में एक बड़े कृषि वानिकी क्षेत्र का अनुमान लगाया। पहले दो मॉडल खेतों की जटिल सीमा को पढ़ते हैं जहां पेड़ों और फसलों को अधिक उदारतापूर्वक और गैर-रेखीय रूप से मिश्रित किया जाता है, जबकि समर्थन-वेक्टर मशीन एक रूढ़िवादी सीमा खींचती है। एक मॉडल जो केवल एक उपग्रह जल सूचकांक को देखता है, वह व्यापक क्षेत्र में सूखे की स्थिति की तुरंत गणना कर सकता है, लेकिन यह नहीं पकड़ सकता कि प्रत्येक फसल-विकास चरण में मिट्टी की नमी कैसे बदलती है। इसके विपरीत, इंटरनेट-ऑफ-थिंग्स सेंसर और न्यूरल नेटवर्क को संयोजित करने वाले मॉडल सटीक होते हैं, लेकिन सेंसर स्थापित करने और बनाए रखने की संबंधित लागत वहन करते हैं।

सैटेलाइट और ड्रोन इमेजरी पेड़ की छतरियों, फसलों और नंगी-मिट्टी के प्रतिबिंब को 10 से 30 मीटर मापने वाले एक पिक्सेल में मिलाती है। एक एकल उपग्रह-छवि सेल की कल्पना करें जिसमें एक पेड़ का शीर्ष, उसके नीचे की छाया, मिट्टी और फसलें हों: इससे परावर्तित प्रकाश पेंट से अलग नहीं है जिसमें कई रंग पहले ही मिश्रित हो चुके हैं। किसी कंप्यूटर को इस मिश्रित रंग से क्रॉप सिग्नल को अलग करने के लिए कहना, पहले से ही मिश्रित किए गए पेंट से मूल रंगों को पुनर्प्राप्त करने की कोशिश करने जैसा है। कृषि वानिकी जल संतुलन और मिट्टी के कार्बन में परिवर्तन के लिए एक पैटर्न दिखाई देने से पहले कम से कम 10 साल के अवलोकन की आवश्यकता होती है, फिर भी अधिकांश वर्तमान गहन-शिक्षण अध्ययन केवल कुछ वर्षों तक चलने वाले छोटे डेटासेट पर निर्भर करते हैं, जिससे जलवायु परिवर्तन के प्रति लचीलापन का पूरी तरह से परीक्षण करना मुश्किल हो जाता है। विकासशील देश में खेत जितना अधिक दूर होगा, इंटरनेट-ऑफ-थिंग्स सेंसर और वायरलेस नेटवर्क दोनों के लिए धन की कमी होने की संभावना उतनी ही अधिक होगी, इसलिए बुद्धिमान जल-प्रबंधन तकनीक अक्सर उन क्षेत्रों तक पहुंचने में विफल रहती है जहां इसकी सबसे अधिक आवश्यकता होती है।

गेहूं के खेत में उठाया गया सवाल, क्या पेड़ पानी लेते हैं या इसकी रक्षा करते हैं, यूरोपियन सेंटर फॉर मीडियम-रेंज वेदर फोरकास्ट्स की गणना में लौटा। 2026 के एक अध्ययन में, एक परिदृश्य में रणनीतिक रूप से चयनित रोपण स्थानों ने वाष्पीकरण-उत्सर्जन को 60 प्रतिशत तक कम कर दिया और भूजल भंडारण

को तीन गुना तक बढ़ा दिया। यह परिणाम एक मॉडल परिदृश्य है, न कि प्रत्येक खेती वाले खेत के लिए गारंटीशुदा मूल्य।

शोधकर्ता अगला कदम तैयार कर रहे हैं: भौतिक कानूनों को कृत्रिम तंत्रिका नेटवर्क से जोड़ना। भौतिक समीकरणों पर आधारित मौजूदा मॉडलों, जैसे कि क्रॉपवाट और एपीएसआईएम, की बाधाओं को भौतिकी-सूचित तंत्रिका नेटवर्क (पिनन) नामक गहन-शिक्षण वास्तुकला के अंदर रखने के प्रयास चल रहे हैं, ताकि मिश्रित उपग्रह पिक्सल से त्रुटि को कम करते हुए माइक्रोक्लाइमेट और नमी की एक साथ गणना की जा सके। शुष्क क्षेत्रों, उपोष्णकटिबंधीय और उष्णकटिबंधीय क्षेत्रों में खुले डेटासेट बनाने और वास्तविक समय में सिंचाई का समय प्रदान करने के लिए किसानों के फोन पर उन डेटा पर प्रशिक्षित हल्के एआई मॉडल लोड करने की भी चर्चा है। एक किसान के फोन पर इस हल्के वजन वाले मॉडल की कल्पना एक ऐसी चीज़ के रूप में की गई है जो एक सुबह संदेश भेज सकता है कि उस दिन खेत में कितना पानी देना है और कब लगाना है। पहाड़ी गांवों में जहां इंटरनेट कनेक्शन अक्सर विफल हो जाते हैं, गणना फोन पर पूरी हो जाती है, जिससे सर्वर से सिग्नल भेजने और प्राप्त करने में लगने वाला समय समाप्त हो जाता है। फिर भी, यह दृष्टिकोण प्रयोगशाला पत्रों में एक प्रस्ताव के करीब है; वास्तविक क्षेत्रों में कई वर्षों में मान्य कुछ मामले हैं।

संयुक्त राष्ट्र का खाद्य और कृषि संगठन बताता है कि भारत की कृषि-वानिकी और कृषि वानिकी प्रणाली वार्षिक लकड़ी की मांग का लगभग 93 प्रतिशत आपूर्ति करती है। यह आंकड़ा वार्षिक लकड़ी की मांग को दर्शाता है, न कि सभी लकड़ी उत्पादों की घरेलू खपत को। छोटे किसानों के वृक्ष उत्पादन का विस्तार करने के लिए रोपण, प्रौद्योगिकी, बाजार पहुंच और भूमि और फसल के अधिकारों पर ध्यान देने की आवश्यकता है।

स्रोत और संदर्भ

1. Chavan, S. B., Rawale, G. B., Pradhan, A., Uthappa, A. R., Kakade, V. D., Morade, A. S., Paul, N., Das, B., Chichaghare, A. R., Changan, S., Khapte, P. S., Basavaraj, P. S., Babar, R., Salunkhe, V. S., Jinger, D., Nangare, D. D., & Reddy, K. S. (2025). Optimizing tree shade gradients in *Emblia officinalis*-based agroforestry systems: Impacts on soybean physio-biochemical traits and yield under degraded soils. *Agroforestry Systems*, 99, Article 21. <https://doi.org/10.1007/s10457-024-01123-2>
2. Doherty, S., & Häger, A. (2026). Forests and agroforestry as overlapping hotspots of woody species diversity and above-ground carbon storage in a Costa Rican landscape: A remote sensing analysis. *Frontiers in Sustainable Food Systems*, 10. <https://doi.org/10.3389/fsufs.2026.1770039>
3. European Centre for Medium-Range Weather Forecasts. (2026, April 14). The machine learning method advising on tree planting for water sustainability. <https://www.ecmwf.int/en/about/media-centre/news/2026/machine-learning-tree-planting-water-sustainability> (accessed August 2, 2026)
4. Fahad, S., Chavan, S. B., Chichaghare, A. R., Uthappa, A. R., Kumar, M., Kakade, V., Pradhan, A., Jinger, D., Rawale, G., Yadav, D. K., Kumar, V., Farooq, T. H., Ali, B., Sawant, A. V., Saud, S., Chen, S., & Pocza, P. (2022). Agroforestry systems for soil health improvement and maintenance. *Sustainability*, 14(22), 14877. <https://doi.org/10.3390/su142214877>
5. Jemal, O. M. (2026). Deep learning based monitoring of forest dynamics and degradation in agroforestry landscapes of Ethiopia: A systematic review. *F1000Research*, 15, 769. <https://doi.org/10.12688/f1000research.180012.1>

6. Jinger, D., Kakade, V. D., Kaushal, R., Bhatnagar, P. R., Ghosh, A., Mahawer, S. K., Dinesh, D., Singh, G., Akula, C., Paramesh, V., Meena, V. S., Roy, T., Islam, S., Kumar, D., Uthappa, A. R., Chavan, S. B., Pradhan, A., Kumar, R., Kaledhonkar, M. J., & Madhu, M. (2025). Nature-based solutions for enhancing CO₂ sequestration and rehabilitating degraded lands through silvo-aromatic system and soil moisture conservation techniques. *Journal of Environmental Management*, 380, Article 124904. <https://doi.org/10.1016/j.jenvman.2025.124904>
7. Ridlo, Z. R., Dafik, Waluyo, J., Yushardi, & Venkatachalam, M. (2025). On RIDS analysis for shade tree placement and its application to STGNN multi-step forecasting on RH and CO₂ concentration of coffee agroforestry. *Statistics, Optimization & Information Computing*, 14(4), 1889-1908. <https://doi.org/10.19139/soic-2310-5070-2643>
8. Silva, B. B., Brum, D., Lorean, A. C., Urruth, L. M., & Tozetti, A. M. (2026). Agroforestry systems as habitat aggregators: A spatiotemporal analysis of the Brazilian subtropical agroforestry using MapBiomass datasets. *Agroforestry Systems*, 100, Article 185. <https://doi.org/10.1007/s10457-026-01557-w>
9. Singh, A., Atish, Singh, V., Kumari, B., Arya, S., & Kamboj, A. (2026). A systematic review on water use efficiency (WUE) and soil moisture dynamics in wheat-based agroforestry systems. *International Journal of Environment, Agriculture and Biotechnology*, 11(3), 75-86. <https://doi.org/10.22161/ijeab.113.8>
10. Uthappa, A. R., Das, B., Chavan, S. B., Raizada, A., Desai, S., Paramesha, V., Kumar, P., Jha, P. K., & Vara Prasad, P. V. (2025). Comparison of machine learning models for mapping Arecanut-based agroforestry system in Goa by enhancing precision and efficiency. *Scientific Reports*, 15. <https://doi.org/10.1038/s41598-025-27845-6>
11. World Resources Institute. (2025). Transfer learning to detect natural, monoculture, and agroforestry tree-based systems in Ghana using remote sensing. <https://files.wri.org/d8/s3fs-public/2025-12/transfer-learning-to-detect-natural-monoculture-and-agroforestry-tree-based-systems-in-ghana-using-remote-sensing.pdf> (accessed August 2, 2026)
12. Food and Agriculture Organization of the United Nations. (2025). Agroforestry for wood production: Insights from multifunctional smallholder tree farming systems in Asia and the Pacific. <https://www.fao.org/in-action/forests-landscape-restoration-mechanism/news-and-events/news/news-detail/agroforestry-for-wood-production---insights-from-multifunctional-smallholder-tree-farming-systems-in-asia-and-the-pacific/en> (accessed August 3, 2026)
13. Food and Agriculture Organization of the United Nations. (2026). AQUASTAT methodology: Water use. <https://www.fao.org/aquastat/en/overview/methodology/water-use> (accessed August 3, 2026)

5.2

ICT-आधारित लकड़ी अनुरेखण (QR/इलेक्ट्रॉनिक टैग) और लकड़ी की गुणवत्ता का स्वचालित आकलन

नाकाज़ावा और सहकर्मियों का सिस्टम आरेख एक हार्वेस्टर द्वारा मापी गई लॉग जानकारी को सर्वर तक ले जाने वाली एक लाइन दिखाता है। कटाई मशीन व्यास और लंबाई को मापती है और स्टैनफोर्ड प्रारूप में परिचालन डेटा छोड़ती है। भौतिक टैग और परिवहन और आरा मिलिंग रिकॉर्ड को इस डेटा से जोड़ने से लॉग-ट्रेसिविलिटी सिस्टम के लिए एक डिज़ाइन प्रदान किया जा सकता है। हालाँकि, उद्धृत स्रोत किसी आराघर का चित्रण नहीं करता है जहाँ QR कोड या RFID टैग स्वचालित रूप से प्रत्येक लॉग से जुड़े होते हैं।

इलेक्ट्रॉनिक रिकॉर्ड कटाई के स्थानों और मापों को शीघ्रता से साझा कर सकते हैं। रिकॉर्ड को वास्तविक लॉग से पूरी तरह कनेक्टेड रखना एक अलग समस्या है। जब कोई टैग गिर जाता है या लॉग बोर्डों में विभाजित हो जाता है तो लिंक टूट सकता है।

क्यूआर कोड और आरएफआईडी केवल कुंजी हैं जो रिकॉर्ड को कॉल करते हैं; वे स्वयं लॉग की पहचान की गारंटी नहीं देते हैं। आपूर्ति-श्रृंखला का पता लगाने की क्षमता तभी काम करती है जब कटाई के रिकॉर्ड, भौतिक चिह्न, परिवहन हैंडओवर, काटने के बाद बंडल प्रबंधन और फ़िल्ड ऑडिट सभी जगह पर होते हैं।

लकड़ी का वितरण एक समय कागज की पर्चियों और हस्तलिखित फ़िल्ड शीट पर निर्भर था। लोगों द्वारा दर्ज किए गए आंकड़ों में त्रुटियां हो सकती हैं, और कानूनी लॉग के बीच मिश्रित अवैध रूप से लॉग की गई लकड़ी को फ़िल्टर करना मुश्किल है। कोरिया वन सेवा ने एक साल के परीक्षण के आधार पर अपनी कानूनी इमारती लकड़ी व्यापार संवर्धन प्रणाली का संचालन किया। पूर्ण कार्यान्वयन की तारीख 1 अक्टूबर, 2019 थी। ढकी हुई लकड़ी और लकड़ी के उत्पादों का आयात करने वाले व्यवसायों को सीमा शुल्क निकासी से पहले यह साबित करना होगा कि लकड़ी की कटाई उसके मूल देश में कानूनी रूप से की गई थी। कोरिया वन सेवा देश-विशिष्ट मानक दिशानिर्देश वितरित करती है। हार्वेस्टर सेंसर, इलेक्ट्रॉनिक टैग और एआई वृत्तचित्र समीक्षा में अंतराल को कम करने के सहायक साधन हैं।

दूसरा नाम एक लॉग में उकेरा गया

कटाई स्थल में प्रवेश करने वाला एक स्मार्ट हार्वेस्टर उसी समय डेटा लिखता है जब वह एक पेड़ गिराता है और इसे निर्धारित लंबाई में संसाधित करता है। कटिंग हेड से जुड़े सेंसर, दूसरे-दर-सेकंड, लॉग का व्यास और लंबाई और पेड़ किस हद तक टेढ़ा हो गया है, मापते हैं, जबकि एक उपग्रह-नेविगेशन डिवाइस कटाई के सटीक स्थान को रिकॉर्ड करता है। जिस संक्षिप्त क्षण में मशीन एक पेड़ को काटती है, वह गणनाएं पूरी कर लेती है जो लोग कभी आंखों से करते थे।

नाकाज़ावा और उनके सहयोगियों ने स्टैनफोर्ड के आधार पर, हार्वेस्टर के लॉग माप और गुणवत्ता निर्णय साझा करने के लिए एक प्रणाली विकसित की। इसके अनुसंधान का दायरा वन मशीनरी से उत्पादन और परिचालन डेटा का संबंध है; इसमें पूरे जापान के लिए व्यापार और निपटान प्रणाली शामिल नहीं है।

अकेले हार्वेस्टर डेटा किसी पेड़ का अंत तक पीछा नहीं कर सकता। ऐसी प्रक्रिया को डिज़ाइन करना संभव है जिसमें एक बारकोड या आरएफआईडी टैग एक लॉग से जुड़ा होता है और अगला व्यवसाय इसे प्राप्त करता है। एक ऑपरेटिंग सिस्टम जो कटाई मशीनरी द्वारा स्वचालित टैग एप्लिकेशन, अंत-अनाज विकास रिंगों के त्रि-आयामी फ़िंगरप्रिंट और ब्लॉकचेन तुलना को जोड़ता है, अभी तक मान्य नहीं किया गया है।

आरएफआईडी संपर्क के बिना एक पहचान संख्या पढ़ सकता है, लेकिन इसके लिए टैग लागत और स्थायित्व, संलग्नक के लिए श्रम और प्रसंस्करण के बाद बंडल प्रबंधन की आवश्यकता होती है। केवल एक टैग किसी लॉग की उत्पत्ति या वैधता की गारंटी नहीं दे सकता।

ट्रक पर लदे पेड़ों की गिनती कैसे करें?

लैंडिंग पर लट्टों के ढेर या परिवहन ट्रक पर लदे लट्टों की मात्रा मापना लंबे समय तक सीधे हाथ से किया जाने वाला कार्य था। लोगों ने टेप से प्रत्येक लट्टे का व्यास मापा और ढेर की कुल मात्रा का अनुमान लगाया। हाल के वर्षों में, काम स्मार्टफोन कैमरों और आईपैड में निर्मित LiDAR सेंसर पर स्थानांतरित हो गया है। LiDAR प्रकाश उत्सर्जित करके और उसकी वापसी का समय निर्धारित करके किसी वस्तु से दूरी मापता है, और यह लॉग पाइल की आकृति को घने बिंदु बादल के रूप में प्रस्तुत करने के लिए उस सिद्धांत का उपयोग करता है।

एलियास और सहकर्मियों द्वारा 2025 प्रोटोटाइप अध्ययन, उकार और सहकर्मियों द्वारा तुर्की परीक्षण, और पुरफर्स्ट और सहकर्मियों द्वारा तुलनात्मक अध्ययन ने स्मार्टफोन तस्वीरों और LiDAR के साथ लॉग-पाइल वॉल्यूम का अनुमान लगाया। छवि-आधारित माप से क्षेत्र में समय कम हो सकता है, लेकिन त्रुटि पेड़ की प्रजाति, लोडिंग कॉन्फ़िगरेशन और कैमरा कोण के अनुसार भिन्न होती है।

ट्रक के बिस्तर में लट्टों के बीच खाली जगह होती है। Nižä और सहकर्मियों ने एक एल्गोरिदम का मूल्यांकन किया जो LiDAR बिंदु बादलों से भार के बाहरी रूप और लकड़ी की मात्रा का अनुमान लगाता है। यह ऐसा अध्ययन नहीं है जो त्रुटि के बिना लकड़ी की वास्तविक मात्रा को ठीक करता है या स्केलिंग स्टेशन पर निपटान को स्वचालित करता है।

लेन-देन में LiDAR अनुमानों का उपयोग करने के लिए, हितधारकों को स्वीकार्य त्रुटि निर्धारित करने और सेंसर अंशांकन और आपत्ति प्रक्रियाओं को स्थापित करने के लिए संदर्भ माप के साथ उनकी बार-बार तुलना करनी चाहिए। किसी एल्गोरिदम का परीक्षण प्रदर्शन स्वचालित रूप से भुगतान निपटान के लिए कानूनी मानक स्थापित नहीं करता है।

जिस क्षण कैमरे को एक गाँठ मिलती है

आराधन में प्रवेश करने वाले लॉग और बोर्ड का मूल्य अंततः दोषों द्वारा निर्धारित होता है। एक ही पेड़ को अलग-अलग ग्रेड मिलते हैं, जो इस बात पर निर्भर करता है कि उसमें कितनी गाँठें हैं, क्या उसमें दरारें हैं, और क्या उसका रंग फीका पड़ गया है। लंबे समय तक, यह निर्णय एक ग्रेडर की नज़र में सौंपा गया था। यहां तक कि पूरे दिन बोर्ड देखने के बाद एक कुशल व्यक्ति का निर्णय भी डगमगा सकता है, और एक व्यक्ति से दूसरे व्यक्ति के लिए थोड़े से भिन्न मानक एक ही बोर्ड के लिए अलग-अलग ग्रेड दे सकते हैं। सुबह और दोपहर में एक ही लॉग का निरीक्षण करने वाले ग्रेडर के लिए अलग-अलग ग्रेड शीट लिखना असामान्य नहीं था। सैंडविक और सहकर्मियों द्वारा 2024 साहित्य समीक्षा के अनुसार, लॉग स्केलिंग और ग्रेडिंग के तरीके 2018 के आसपास तेजी से गहन शिक्षण की ओर स्थानांतरित हो गए, जिससे अन्य मशीन-लर्निंग दृष्टिकोण विस्थापित हो गए।

किड और सहकर्मियों ने 2026 में PADDL-YOLO नामक एक लकड़ी-सतह-दोष-पहचान मॉडल पेश किया। परीक्षण डेटा पर, सटीकता 91.5 प्रतिशत और रिकॉल 91.4 प्रतिशत थी। mAP@0.5 95.0 प्रतिशत था। बेसलाइन मॉडल की तुलना में कम्प्यूटेशनल लोड 25.6 प्रतिशत कम था। किसी मॉडल को हल्का करने से उसे फील्ड उपकरण पर तैनात करने की संभावना बढ़ जाती है, लेकिन यह इस बात का सबूत नहीं है कि यह सॉमिल कन्वेयर पर व्यावसायिक गति से लंबी अवधि तक संचालित होता है।

कई अध्ययन अलग-अलग रास्तों से एक ही लक्ष्य का पीछा करते हैं। उन्होंने और उनके सहयोगियों ने पूरी तरह से दृढ़ तंत्रिका नेटवर्क के साथ आंतरिक लकड़ी के दोषों का पता लगाया, जबकि ह्वांग और उनके सहयोगियों ने नोड प्रकारों को अलग करने के लिए छवि पहचान में व्यापक रूप से उपयोग किए जाने वाले रेसनेट-34 तंत्रिका नेटवर्क में स्थानांतरण सीखने को लागू किया। अबोनस और सहकर्मियों ने लिबास सतहों पर दोष खोजने के लिए फास्टर आर-सीएनएन का उपयोग किया। कन्वेयर बेल्ट के साथ गुजरने वाले बोर्डों में वास्तविक समय दोषों का पता लगाने के लिए, लॉन्ग्युएटाउड और सहकर्मियों ने एक बेहतर YOLOv5s का उपयोग किया, और झांग और झाओ ने YOLOv7 का उपयोग किया। ओज़कान और सहकर्मियों ने दोष खोजने के लिए 2,972 बीच लैमेल टुकड़ों पर एक मास्क आर-सीएनएन-परिवार तंत्रिका नेटवर्क को प्रशिक्षित किया और 90.90 प्रतिशत की सटीकता तक पहुंचे। ह्वांग और सहकर्मियों ने कुछ अलग दृष्टिकोण चुना, गांठ सतहों से बनावट और स्थानीय-आकार की जानकारी निकाली और इसे ध्वनि, सड़े हुए और गायब गांठों को अलग करने के लिए एक कृत्रिम तंत्रिका नेटवर्क में डाला। उनके दृष्टिकोण अलग-अलग हैं, लेकिन लक्ष्य एक है: बोर्ड सामग्री की मात्रा को बढ़ाने के लिए कैमरे और तंत्रिका नेटवर्क का उपयोग करें जिसे मानव आंखें एक दिन में निरीक्षण कर सकती हैं।

जिन बोर्डों को ग्रेडर पूरे दिन देखते थे, वे अब कैमरे के सामने से गुजरते हैं, और लोग केवल उन कुछ बोर्डों को दोबारा जांचते हैं जिन्हें मशीन ने अस्पष्ट के रूप में चिह्नित किया है। स्क्रीन पर कुछ बोर्ड पीले रंग में रेखांकित हैं। ये ऐसे बोर्ड हैं जिनके बारे में तंत्रिका नेटवर्क आश्वस्त नहीं है और एक व्यक्ति के पास चला गया है। ग्रेडर अब संपूर्ण कन्वेयर के बजाय इन फ़िल्टर किए गए बोर्डों पर ध्यान केंद्रित कर सकता है। ऐसा नहीं है कि काम खत्म हो गया है; वह स्थान जहां व्यक्ति खड़ा है, कन्वेयर के सामने से मॉनिटर के सामने चला गया है।

एक तस्वीर से लकड़ी की कीमत क्यों नहीं तय की जा सकती?

दोष ढूँढना और बाज़ार-मूल्य ग्रेड निर्दिष्ट करना अलग-अलग कार्य हैं। 2026 में, ट्रिप्लैट और उनके सहयोगियों ने स्लोवेनियाई लॉग नीलामी से 5,549 तस्वीरों का उपयोग करके बाज़ार-मूल्य-ग्रेड वर्गीकरण मॉडल की तुलना की। कई मॉडलों ने समग्र सटीकता 90 प्रतिशत से अधिक कर दी, लेकिन कम-मूल्य वाले ग्रेड के लिए प्रदर्शन अपेक्षाकृत कमजोर था। केवल उच्च समग्र सटीकता ही दुर्लभ ग्रेडों के गलत वर्गीकरण को छुपा सकती है।

छवि वर्गीकरण डेटासेट में खींची गई सतह और ग्रेड लेबल को सीखता है। यह तस्वीर से अनुपस्थित कारकों, जैसे आंतरिक दोष, नमी और ताकत का सीधे तौर पर आकलन नहीं कर सकता है। प्रशिक्षण डेटा में दुर्लभ ग्रेड नमूनों की कमी से अधिक प्रभावित होते हैं।

बाज़ार-मूल्य निर्णयों में तस्वीर के अलावा निरीक्षण और लेन-देन की स्थितियाँ भी शामिल हो सकती हैं। इसलिए स्क्रीनिंग में सहायता के लिए छवि मॉडल का उपयोग किया जाना चाहिए, जबकि लोगों द्वारा कम आत्मविश्वास और दुर्लभ ग्रेड की दोबारा जांच की जानी चाहिए।

जब नीलामी में कोई ग्रेड गलत तरीके से दिया जाता है, तो पैसा तुरंत चला जाता है। यदि उच्च-श्रेणी के लॉग को गलत तरीके से निम्न-श्रेणी के रूप में वर्गीकृत किया जाता है, तो वन मालिक को इसका उचित मूल्य नहीं मिलता है; इसके विपरीत, यदि निम्न-श्रेणी के लॉग को उच्च-श्रेणी के रूप में पारित कर दिया जाता है, तो इसे खरीदने वाली आरा मशीन को इसके नुकसान का पता इसे बोर्डों में काटने के बाद ही लग सकता है। यही कारण है कि स्वचालित मूल्यांकन प्रणालियों में मानव अंतिम जांच बनी रहती है।

PADDL-YOLO का mAP@0.5 और ट्रिप्लैट के अध्ययन में वर्गीकरण सटीकता विभिन्न डेटा और कार्यों से आती है। उनकी तुलना सीधे तौर पर नहीं की जानी चाहिए। सतह-दोष का पता लगाना, बाज़ार-मूल्य वर्गीकरण और आंतरिक ताकत का आकलन अलग से मान्य किया जाना चाहिए।

बारिश क्या मिटा देती है और कीमत क्या रोक देती है

कटाई स्थल पर भौतिक निशान कीचड़, बारिश, प्रभाव और छाल के नुकसान के कारण अपठनीय हो सकते हैं या गिर सकते हैं। आरएफआईडी इसी तरह से क्षतिग्रस्त हो सकती है, यह इस बात पर निर्भर करता है कि यह कैसे जुड़ा हुआ है और परिवहन प्रभाव पर निर्भर करता है। ग्रोथ रिंग्स के त्रि-आयामी फ़िंगरप्रिंट एक मान्य ऑपरेटिंग सिस्टम नहीं बन पाए हैं जो इस समस्या का समाधान करता है। चिह्नों के स्थायित्व परीक्षण, हैंडओवर रिकॉर्ड और नमूना ऑडिट सभी की आवश्यकता होती है।

द्वि-आयामी कैमरों की सीमाएँ बनी हुई हैं। सतह की छवियाँ किसी पेड़ के अंदर बढ़ते क्षय या छिपी हुई आंतरिक दरारों को नहीं पकड़ सकती हैं, इसलिए अप्रत्याशित दोष केवल काटने के बाद ही दिखाई दे सकते हैं। इन सभी उपकरणों को प्राप्त करने की लागत छोटी आरा मिलों और वन मालिकों के लिए काफी बोझ है। उच्च-प्रदर्शन वाले LiDAR स्कैनर, एक्स-रे CT उपकरण और फ़ील्ड AI कंप्यूटर को एक साथ स्थापित करने के लिए पर्याप्त प्रारंभिक निवेश की आवश्यकता होती है, और छोटे ऑपरेशनों के लिए सीमा को पार करना कठिन होता है। अनुसंधान बजट वाला एक संस्थान, जैसे कि राष्ट्रीय वन विज्ञान संस्थान, इस उपकरण को परीक्षण के आधार पर पेश कर सकता है, लेकिन यह एक छोटे से जंगल के मालिक के लिए पहुंच से बाहर है, जिसके पास प्रबंधन करने के लिए पहाड़ है या पड़ोस में आराघर है। जहां प्रौद्योगिकी

मौजूद है लेकिन उसे वहन नहीं किया जा सकता, वहां हाथ से मापने और आंख से ग्रेडिंग करने की पुरानी प्रथा जारी है। फ़ॉर्कुओ और बोरज़ द्वारा वन संचालन में एआई अनुप्रयोगों की 2026 की समीक्षा में लकड़ी की ट्रेसबिलिटी और गुणवत्ता मूल्यांकन को कटाई मशीनीकरण के बाद सबसे तेजी से बढ़ते क्षेत्रों में से एक के रूप में पहचाना गया।

एक्स-रे सीटी और ध्वनिक परीक्षण आंतरिक दोषों की पहचान करने के लिए पूरक उपकरण हैं जिन्हें कोई तस्वीर नहीं देख सकती है। नोसेटी और सहकर्मियों ने ओक लॉग्स पर फोटोग्रामेट्री और ध्वनिक सर्वेक्षण को एक साथ लागू किया। ब्लॉकचेन अनुसंधान कई व्यवसायों के लिए एक ही रिकॉर्ड साझा करने और बाद में परिवर्तनों की जांच करने के तरीकों का प्रस्ताव करता है। यह गलत प्रारंभिक प्रविष्टियों, टैग प्रतिस्थापन, या वास्तविक लॉग और उसके रिकॉर्ड के बीच अंतराल को समाप्त नहीं कर सकता है। ईयूडीआर के अनुपालन के लिए जियोलोकेशन जानकारी, उचित परिश्रम, जोखिम मूल्यांकन और दस्तावेज़ प्रतिधारण की आवश्यकता होती है। StanForD और ब्लॉकचेन जैसे ऑपरेशनल-डेटा मानक केवल ऐसे उपकरण हैं जो अनुपालन साक्ष्य की सहायता करते हैं; वे अनुपालन की गारंटी नहीं देते।

स्रोत और संदर्भ

1. Damaševičius, R., & Maskeliūnas, R. (2025). Blockchain-enabled smart contracts for secure and transparent timber traceability. *Journal of Industrial Information Integration*, 48, Article 100934. <https://doi.org/10.1016/j.jii.2025.100934>
2. Elias, M., Forkuo, G. O., Picchi, G., Nati, C., & Borz, S. A. (2025). Accuracy of a novel smartphone-based log measurement app in the prototyping phase. *Sensors*, 25(18), Article 5847. <https://doi.org/10.3390/s25185847>
3. Forkuo, G. O., Picchio, R., Proto, A. R., & Borz, S. A. (2026). Applications of artificial intelligence in forest operations engineering research: A systematic review. *Current Forestry Reports*, 12, Article 14. <https://doi.org/10.1007/s40725-026-00275-x>
4. He, T., Liu, Y., Xu, C., Zhou, X., Hu, Z., & Fan, J. (2019). A fully convolutional neural network for wood defect location and identification. *IEEE Access*, 7, 123453-123462. <https://doi.org/10.1109/ACCESS.2019.2937461>
5. Hwang, S. W., Lee, T., Kim, H., Chung, H., Choi, J. G., & Yeo, H. (2022). Classification of wood knots using artificial neural networks with texture and local feature-based image descriptors. *Holzforschung*, 76(1), 1-13. <https://doi.org/10.1515/hf-2021-0051>
6. Forestry Agency, Japan (林野庁). (2025, June 3). 令和6年度 森林・林業白書 [FY2024 White Paper on Forests and Forestry]. <https://www.rinya.maff.go.jp/j/kikaku/hakusyo/r6hakusyo/index.html>
7. Longuetaud, F., Mothe, F., Kerautret, B., Krähenbühl, A., Hory, L., & Leban, J. M. (2012). Automatic knot detection and measurements from X-ray CT images of wood: A review and validation of an improved algorithm on softwood samples. *Computers and Electronics in Agriculture*, 85, 77-89. <https://doi.org/10.1016/j.compag.2012.03.013>
8. Nakazawa, M., et al. (2021). 原木品質自動判定装置を備えたハーベスタのための原木情報共有システムの開発 [Development of a log information sharing system for harvesters equipped with an automatic log quality judgment device]. *Journal of the Japan Forest Engineering Society*, 36(1), 21-26. <https://doi.org/10.18945/jjfes.36.21>
9. Niță, M. D., Cucu-Dumitrescu, C., Candrea, B., Grama, B., Iuga, I., & Borz, S. A. (2025). The performance of a novel automated algorithm in estimating truckload volume based on LiDAR data. *Forests*, 16(8), Article 1281. <https://doi.org/10.3390/f16081281>

10. Nocetti, M., Aminti, G., Vicario, M., & Brunetti, M. (2025). Assessment of oak roundwood quality using photogrammetry and acoustic surveys. *Forests*, 16(3), Article 421. <https://doi.org/10.3390/f16030421>
11. Ozkan, M., Ozcan, C., & Gokmen, M. S. (2025). Deep learning based defect detection and quality classification on lamella pieces used in solid wood panel production. *Operations Research Forum*, 6(4), Article 160. <https://doi.org/10.1007/s43069-025-00534-w>
12. Purfürst, T., De Miguel-Díez, F., Berendt, F., Engler, B., & Cremer, T. (2023). Comparison of wood stack volume determination between manual, photo-optical, iPad-LiDAR and handheld-LiDAR based measurement methods. *iForest - Biogeosciences and Forestry*, 16(4), 243-252. <https://doi.org/10.3832/for4153-016>
13. Qiu, C., Zhu, L., Liang, Z., Wang, Z., & Liu, T. (2026). A multi-scale feature aggregation algorithm for wood defect detection (PADDL-YOLO). *Forest Engineering*, 42(2), 387-401. <https://doi.org/10.7525/j.issn.1006-8023.2026.02.014>
14. Sandvik, Y. J., Futsæther, C. M., Liland, K. H., & Tomic, O. (2024). A comparative literature review of machine learning and image processing techniques used for scaling and grading of wood logs. *Forests*, 15(7), Article 1243. <https://doi.org/10.3390/f15071243>
15. Triplat, M., Lukančič, Ž., & Kavčič, V. (2026). Evaluation of deep learning models for image-based classification of timber logs by market value. *Forests*, 17(5), Article 518. <https://doi.org/10.3390/f17050518>
16. Ucar, Z., Eker, R., Bilici, E., & Akay, A. E. (2024). Evaluating the use of smartphone applications for log stacks volume measurement in Turkish forestry practices. *Croatian Journal of Forest Engineering*, 45(2), 263-276. <https://doi.org/10.5552/crojfe.2024.2398>
17. Urbonas, A., Raudonis, V., Maskeliūnas, R., & Damaševičius, R. (2019). Automated identification of wood veneer surface defects using faster region-based convolutional neural network with data augmentation and transfer learning. *Applied Sciences*, 9(22), Article 4898. <https://doi.org/10.3390/app9224898>
18. Korea Forest Service. (2019, September 18). Imports of timber will require proof of legality for customs clearance from October 1. https://www.forest.go.kr/kfswb/cop/bbs/selectBoardArticle.do?bbsId=BBSMSTR_1036&nttId=3136493 (accessed August 3, 2026)

5.3

चक्रीय जैव-अर्थव्यवस्था और वन कार्बन क्रेडिट

कटाई समाप्त होने के बाद शाखाएँ, छाल और ठूँठ ढलान पर बने रहते हैं। क्या उन्हें मिट्टी में वापस लौटने के लिए छोड़ देना चाहिए या उन्हें काटकर ईंधन या सामग्री फीडस्टॉक के रूप में ले जाना चाहिए, इसका निर्णय जंगल की आग के जोखिम, पोषक चक्रण, परिवहन दूरी और प्रसंस्करण मांग पर एक साथ विचार करके किया जाना चाहिए। उच्च नमी परिवहन भार को बढ़ाती है लेकिन ईंधन के कैलोरी मान को कम कर सकती है। केवल वजन के आधार पर कीमत तय करने से गुणवत्ता और ऊर्जा दक्षता के बीच विसंगति पैदा हो सकती है।

सामग्री बनाने के लिए लिग्निन और सेलूलोज़ को लकड़ी के अवशेषों से निकाला जा सकता है, और मानक पूरे करने वाले लठ्ठों को इंजीनियर्ड लकड़ी में बदला जा सकता है। प्रत्येक शाखा और जड़ आर्थिक रूप से व्यवहार्य फीडस्टॉक नहीं है। गणना में संग्रह, सुखाने, परिवहन और प्रसंस्करण के लिए आवश्यक ऊर्जा के साथ-साथ जंगल में रहने वाले कार्बनिक पदार्थों की मात्रा को भी घटाया जाना चाहिए। कार्बन क्रेडिट भी, किसी प्रोजेक्ट के पंजीकरण, अतिरिक्तता, बेसलाइन और सत्यापन आवश्यकताओं को पूरा करने के बाद ही जारी किया जाता है।

अवशेषों से नई सामग्री तक

पेड़ों में मुख्य रूप से तीन पदार्थ होते हैं: सेलूलोज़, जो उनके रेशे बनाता है; हेमिकेलुलोज, जो उनके बीच की जगह को भरता है; और लिग्निन, जो एक पेड़ को सीधा और कठोर बनाए रखता है। लंबे समय तक, कागज और लुगदी मिलें लिग्निन को एक उपद्रव मानती थीं। यह लुगदी निकालने के बाद बची ब्लैक लिकर में मिलाए जाने वाले उप-उत्पाद से अधिक कुछ नहीं था, जिसे बाद में जला दिया जाता था या फेंक दिया जाता था। 2025 और 2026 में जापान के वानिकी और वन उत्पाद अनुसंधान संस्थान (एफएफपीआरआई) और पर्यावरण मंत्रालय द्वारा जारी सामग्री से पता चलता है कि संशोधित लिग्निन तकनीक, जो लिग्निन की रासायनिक संरचना को पुनः कॉन्फिगर करती है, इस स्थिति को बदल रही है। संशोधित लिग्निन, जिसकी संरचना को गर्मी झेलने और टूटने से बचाने के लिए बदल दिया गया है, का उपयोग ऑटोमोटिव पार्ट्स, इलेक्ट्रॉनिक-उत्पाद आवरण और बायोडिग्रेडेबल-राल फीडस्टॉक के लिए किया जाता है। सेल्यूलोज नैनोफाइबर (सीएनएफ), जो लकड़ी के फाइबर को नैनोमीटर मोटाई में अलग करता है, का उपयोग पेट्रोलियम आधारित प्लास्टिक के स्थान पर भी तेजी से किया जा रहा है। संशोधित लिग्निन से बने हिस्से सबसे पहले ऑटोमोटिव इंटीरियर ट्रिम और इलेक्ट्रॉनिक-उत्पाद केसिंग जैसी जगहों पर दिखाई दे रहे हैं, जहां केवल स्पर्श से लकड़ी और प्लास्टिक के बीच अंतर करना मुश्किल हो जाता है।

यह पहले से नहीं माना जा सकता कि लकड़ी आधारित सामग्री पेट्रोलियम आधारित सामग्री की तुलना में कम ग्रीनहाउस गैसों का उत्सर्जन करती है। जीवन-चक्र मूल्यांकन के माध्यम से फीडस्टॉक की उत्पत्ति, प्रसंस्करण

ताप स्रोतों, रसायनों, उत्पाद जीवन, पुनः उपयोग और निपटान की तुलना की जानी चाहिए। सर्कुलर बायोइकोनॉमी एक ऐसा ढांचा है जो नवीकरणीय जैविक संसाधनों का लंबे समय तक उपयोग करने और उन्हें फिर से प्रसारित करने का प्रयास करता है। वांग और उनके सहयोगियों ने एआई-सक्षम वन प्रबंधन को जलवायु अनुकूलन और शमन के साथ जोड़ने वाले दृष्टिकोण के रूप में जलवायु-स्मार्ट वानिकी का आयोजन किया।

शहर में उगाया गया वन

लकड़ी में कार्बन को लंबे समय तक रखने का एक तरीका उस लकड़ी से निर्माण करना है। इंजीनियर्ड लकड़ी जैसे कि क्रॉस-लेमिनेटेड लकड़ी (सीएलटी), जो बारी-बारी से अनाज के साथ परतों में बोर्डों को जोड़कर बनाई जाती है, और ग्लुलम, जिसका उपयोग कॉलम और बीम के लिए किया जाता है, कंक्रीट या संरचनात्मक स्टील के स्थान पर उपयोग किए जाने पर भी काफी संख्या में कहानियां बनाने के लिए पर्याप्त मजबूत होती है। इस मोटी लकड़ी से निर्मित मध्य और ऊँची इमारतों को सामूहिक लकड़ी की इमारतें कहा जाता है। जापान की वानिकी एजेंसी और पर्यावरण मंत्रालय शहरी प्रबलित-कंक्रीट संरचनाओं को लकड़ी से बदलने के लिए "वन राष्ट्र, लकड़ी का शहर" नामक नीति को आगे बढ़ा रहे हैं। किसी लकड़ी-निर्माण स्थल पर जाएँ और वहाँ का वातावरण शुरू से ही कंक्रीट से अलग होता है। रेडी-मिक्स-कंक्रीट शोर और धूल के बजाय, क्रेन कारखाने से पहले से कटे हुए लकड़ी के पैनल उठाते हैं और श्रमिक बोल्ट कसते हैं। कंक्रीट को जलाने और स्टील को पिघलाने से उत्सर्जित होने वाली कार्बन डाइऑक्साइड शुरू में ही कम हो जाती है, जबकि पूरी इमारत दशकों या सदियों से पेड़ों द्वारा अवशोषित कार्बन को अपने फ्रेम में रखती है। जो पेड़ पहाड़ों में खड़े थे, वे शहर के मध्य में स्थानांतरित होकर कार्बन का भंडारण करने वाला दूसरा जंगल बन गए हैं।

लकड़ी के निर्माण का जलवायु लाभ तब होता है जब लकड़ी की आपूर्ति कानूनी और स्थायी रूप से प्रबंधित जंगलों से की जाती है, कटाई के बाद वन कार्बन ठीक हो जाता है, और उत्पाद वास्तव में उच्च उत्सर्जन वाली सामग्री का विकल्प बन जाता है। बढ़ती निर्माण मांग स्वचालित रूप से अपने साथ पुनर्वनीकरण और वन निवेश नहीं लाती है। आपूर्ति-शृंखला प्रमाणीकरण और वन-प्रबंधन नियमों को उन स्थितियों का निर्माण करना चाहिए।

श्रेष्ठ वृक्ष और चक्रीय कटाई

पेड़ों की उम्र और कार्बन संचय को एक वाक्य में तय नहीं किया जा सकता। वैश्विक आंकड़ों से पता चलता है कि बड़े व्यक्तिगत पेड़ उम्र बढ़ने के बावजूद हर साल अधिक कार्बन जोड़ सकते हैं। स्टैंड क्षेत्र की प्रति इकाई शुद्ध उत्पादन उम्र के साथ घट सकता है, लेकिन यह प्रजातियों, मिट्टी, गड़बड़ी और प्रबंधन इतिहास के साथ बदलता रहता है। सभी वनों के लिए कोई सार्वभौमिक "30 से 40 वर्ष के बीच शिखर" नहीं है। प्रजनन और जीनोमिक चयन से विकास या लकड़ी के लक्षणों के चयन के लिए आवश्यक समय कम हो सकता है, लेकिन विकास में सुधार का परिमाण भी प्रजातियों और परीक्षण स्थितियों के अनुसार भिन्न होता है।

क्या कटाई से कार्बन को लाभ होता है, इसका निर्णय केवल एक निश्चित रोटेशन आयु से नहीं किया जा सकता है। जंगल में बचा हुआ कार्बन, कटाई और परिवहन से उत्सर्जन, लकड़ी के उत्पादों में भंडारण की अवधि, कंक्रीट और स्टील के प्रतिस्थापन प्रभाव और पुनर्वनीकरण की सफलता को एक ही जीवन-चक्र मूल्यांकन में रखा जाना चाहिए। पुराने प्राकृतिक वन को संरक्षित करने का विकल्प और बारी-बारी से उत्पादन वन का

प्रबंधन करने का विकल्प, वन कार्यों और स्थानीय परिस्थितियों के आधार पर अलग-अलग उत्तर हैं। जब तेजी से बढ़ने वाली किस्मों को व्यापक रूप से लगाया जाता है, तो कीटों और बीमारियों से होने वाले जोखिम और आनुवंशिक एकरूपता की भी गणना की जानी चाहिए।

कार्बन गिनने वाली आँखें: उपग्रह और कृत्रिम बुद्धिमत्ता

क्या सामग्री के लिए पेड़ों की कटाई और उन्हें दोबारा रोपने का चक्र कार्बन तटस्थता में मदद करता है, इसे संख्याओं के साथ सत्यापित किया जाना चाहिए। वन कार्बन में परिवर्तन को मापने, उनकी रिपोर्ट करने और तीसरे पक्ष से उनकी पुष्टि कराने की प्रक्रिया को एमआरवी कहा जाता है। कोरिया की वन कार्बन ऑफसेट योजना में नए वनीकरण और पुनर्वनीकरण, वन प्रबंधन, लकड़ी के उत्पादों का उपयोग और वन-बायोमास ऊर्जा उपयोग जैसे परियोजना प्रकार शामिल हैं। तथ्य यह है कि योजना में एक परियोजना प्रकार का नाम दिया गया है, छोटी शाखाओं के ढेर को तुरंत उत्सर्जन-कटौती परिणाम में नहीं बदलता है। इसे पंजीकृत कार्यप्रणाली, बेसलाइन, अतिरिक्तता, निगरानी और सत्यापन आवश्यकताओं को पूरा करना होगा।

निष्कासन को मापने के लिए ग्राउंड नमूने और रिमोट सेंसिंग का एक साथ उपयोग किया जाता है। GEDI अपनी कक्षा में तरंगरूप LiDAR से नमूने छोड़ता है; दो-उपग्रह सेंटिनल-2 प्रणाली भूमध्य रेखा के पास लगभग हर पांच दिन में एक ही स्थान पर फिर से आती है। एक लैंडसैट उपग्रह का पुनः भ्रमण अंतराल लगभग 16 दिनों का होता है। क्लाउड कवर ऑप्टिकल छवियों के बीच अंतराल बनाता है जिसे वास्तव में लंबे समय तक उपयोग किया जा सकता है। ग्राउंड नमूने एक मॉडल को कैलिब्रेट करने के लिए आधार हैं, और उपग्रह और LiDAR आँखें हैं जो उनके बीच की जगह का अनुमान लगाते हैं।

गैंग एट अल. (2026) हेडलॉगजियांग प्रांत में प्राकृतिक वनों, पारिस्थितिक मॉडल और जलवायु परिदृश्यों के दीर्घकालिक सर्वेक्षण डेटा को ज्ञान-निर्देशित मशीन लर्निंग के साथ जोड़ा गया। कम उत्सर्जन परिदृश्य के तहत, 2060 में कार्बन स्टॉक 1,379.26 टेराग्राम से 1,439.02 टेराग्राम तक होने का अनुमान लगाया गया था। यह एक मॉडल प्रक्षेपण है, कोई अवलोकित भविष्य नहीं।

केस्केस और नीता (2026) ने रोमानियाई क्षेत्र डेटा से निर्मित मॉडल में फिनिश बहु-स्रोत राष्ट्रीय वन-इन्वेंट्री डेटा जोड़ा। विषय कार्बन मानचित्र नहीं था बल्कि फिनिश खड़ी लकड़ी की मात्रा की भविष्यवाणी थी। व्याख्यात्मक शक्ति 0.483 से बढ़कर 0.718 हो गई। लामाहेवेज और उनके सहयोगियों द्वारा संयुक्त राज्य अमेरिका में मिश्रित वनों के अध्ययन से पता चलता है कि कई रिमोट-सेंसिंग डेटासेट के संयोजन से जमीन के ऊपर-बायोमास अनुमान में सुधार हो सकता है। क्योंकि लक्ष्य चर और सत्यापन क्षेत्र अध्ययन के अनुसार भिन्न होते हैं, एक मॉडल से एक संख्या को दूसरे देश के कार्बन मानचित्र में स्थानांतरित नहीं किया जाना चाहिए।

फुलाए गए आँकड़े और भरोसे की समस्या

स्विनफील्ड एट अल.

(2026) ने 2020 तक क्रेडिट जारी करने वाली लगभग 45 प्रतिशत REDD+ परियोजनाओं की तुलना छह स्वतंत्र मूल्यांकनों के परिणामों से की। प्रासंगिक सेट में 44 परियोजनाएँ थीं। सभी निर्गमों में कुल ओवर-क्रेडिट अनुपात 10.7 गुना था, जो कई बड़ी परियोजनाओं द्वारा बढ़ाया गया आंकड़ा था। एक विशिष्ट परियोजना के लिए औसत स्तर 4.1 गुना था। परिणाम यह पाते हैं कि कई परियोजनाओं ने वनों

की कटाई को कम कर दिया है और परिणाम यह पाते हैं कि आधार रेखाएँ बढ़ गई हैं, एक साथ दिखाई दीं। "परियोजना विफल रही" और "परियोजना ने अपने प्रदर्शन से अधिक क्रेडिट जारी किए" एक ही कथन नहीं हैं।

वेरा का VM0048 क्षेत्राधिकार संबंधी वनों की कटाई-जोखिम डेटा का उपयोग करके आधार रेखा आवंटित करने के लिए एक रूपरेखा प्रदान करता है। कार्यप्रणाली के 10 वर्ष एक ऐतिहासिक संदर्भ अवधि हैं, और इसके छह वर्ष आधारभूत अनुप्रयोग की अवधि हैं। इसने समान पुनर्गणना चक्र को 10 वर्ष से घटाकर छह वर्ष नहीं किया। डिजिटल एमआरवी डेटा संग्रह और ऑडिटिंग में मदद कर सकता है, लेकिन यह बेसलाइन चयन या हितों के टकराव को स्वचालित रूप से हल नहीं करता है।

जहां राष्ट्रीय वन सूची नमूना भूखंडों के सार्वजनिक रूप से जारी निर्देशांक को सुरक्षा कारणों से विस्थापित किया गया है, उन्हें सीधे 10-मीटर सैटेलाइट पिक्सल से मिलान करने से स्थितिगत त्रुटि उत्पन्न होती है। नई लकड़ी-आधारित सामग्रियों के जलवायु लाभ की गणना उत्पाद जीवन और निपटान के माध्यम से फीडस्टॉक निष्कर्षण, रसायनों और गर्मी स्रोतों से पूरे जीवन चक्र में भी की जानी चाहिए। विनिर्माण के दौरान गायब होने वाले प्रभावों को एक निश्चित अनुपात के रूप में नहीं माना जा सकता है। पेरिस समझौते के अनुच्छेद 6.4 के तहत कार्यप्रणाली और मानक मौजूद हैं, लेकिन स्वैच्छिक बाजारों और राष्ट्रीय शमन परिणामों के बीच अंतरसंचालनीयता और दोहरी गिनती की रोकथाम अभी तक पूरी नहीं हुई है।

पुराने-विकसित वन प्रमुख कार्बन भंडार हैं, और बड़े व्यक्तिगत पेड़ कार्बन जोड़ना जारी रख सकते हैं। उत्पादन वनों में, कटाई की गई लकड़ी के भंडारण और सामग्री-प्रतिस्थापन प्रभावों पर एक साथ विचार किया जा सकता है। किस विकल्प से जलवायु को लाभ होगा यह वन के प्रकार, कटाई की तीव्रता, पुनर्जनन दर, उत्पाद जीवन, प्रसंस्करण उत्सर्जन और प्रतिस्थापित की जा रही सामग्री पर निर्भर करता है। एक नियम जो 30 से 40 वर्षों में सभी वनों की कटाई करता है, और एक नियम जो सभी कटाई पर रोक लगाता है, न तो इस गणना को प्रतिस्थापित कर सकता है।

यदि कटाई के स्थान और मात्रा, लकड़ी-उत्पाद उत्पादन, इमारतों की सामग्री विशिष्टताएं, और नई-सामग्री प्रक्रियाओं से जीवन-चक्र डेटा जुड़ा हुआ है, तो जंगल से उत्पाद तक कार्बन बहीखाता बनाया जा सकता है। एक एकीकृत डिजिटल ट्विन जो एक विशेष दीवार में लगे व्यक्तिगत पेड़ का भी अनुसरण करता है, एक ऑपरेटिंग सिस्टम की तुलना में एक डिजाइन लक्ष्य के करीब है।

समान उत्सर्जन कटौती की दोहरी गणना को रोकने के लिए विशिष्ट पहचानकर्ताओं, रजिस्ट्रियों के बीच समन्वय, स्वामित्व नियम, रद्दीकरण रिकॉर्ड और स्वतंत्र सत्यापन की आवश्यकता होती है। ब्लॉकचेन या भौतिकी-सूचित तंत्रिका नेटवर्क अकेले इस समस्या को संरचनात्मक रूप से हल नहीं कर सकते हैं।

स्रोत और संदर्भ

1. Carbon Market Watch. (2026). Quality assessment of REDD+ carbon credit projects. <https://carbonmarketwatch.org/publications/quality-assessment-of-redd-carbon-credit-projects/> (accessed August 2, 2026)

2. Carbon Pulse. (2026). Digital MRV could strengthen carbon credit integrity but data quality concerns persist, ICVCM survey says. <https://carbon-pulse.com/491240/> (accessed August 2, 2026)
3. Forestry and Forest Products Research Institute, Forest Research and Management Organization. (2025, September 3). 2025年度森林総合研究所公開講演会「2050年の森：人口減少社会において森林の果たす役割とは」開催のお知らせ [Announcement of the 2025 FFPRI public lecture, "Forests in 2050: What roles will forests play in a society with a declining population?"]. <https://www.ffpri.go.jp/press/2025/20251015/index.html>
4. Geng, L., Bian, S., Ma, X., Fu, Q., Zhou, Y., & Wang, B. (2026). Prediction of carbon sequestration potential in Heilongjiang Province's natural forests based on the KGML model. *Forest Engineering*. Online first. <https://slgc.nefu.edu.cn/EN/abstract/abstract2592.shtml>
5. Keskes, M. I., & Niță, M. D. (2026). Digital twins in forest management using scalable deep learning pipeline. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 19, 8519-8547. <https://doi.org/10.1109/JSTARS.2026.3666924>
6. Lamahewage, S. H. G., Witharana, C., Riemann, R., Fahey, R., & Worthley, T. (2025). Aboveground biomass estimation using multimodal remote sensing observations and machine learning in mixed temperate forest. *Scientific Reports*, 15, 31120. <https://doi.org/10.1038/s41598-025-15585-6>
7. Ministry of the Environment, Japan (環境省). (2025, February 18). 地球温暖化対策計画 [Plan for Global Warming Countermeasures]. <https://www.env.go.jp/content/000291618.pdf>
8. Saha, R., Bagchie, P., Lalremang, P., & Rai, K. C. (2025). Digital innovation in forest science: Applications of artificial intelligence, remote sensing and smart monitoring systems for ecosystem conservation. *The Bioscan*, 20(3), 907-911. [https://doi.org/10.63001/tbs.2025.v20.i03.S.I\(3\).pp907-911](https://doi.org/10.63001/tbs.2025.v20.i03.S.I(3).pp907-911)
9. Swinfield, T., Williams, A., Coomes, D., Dales, M., Ferris, P., Guizar-Coutiño, A., Hartup, J., Holland, J., Jaffer, S., Jones, J. P. G., Lam, M. O. K., Keshav, S., Madhavapeddy, A., Teye-Scott, E., West, T. A. P., & Balmford, A. (2026). Learning lessons from over-crediting to ensure additionality in forest carbon credits. *Nature Communications*, 17(1), Article 3944. <https://doi.org/10.1038/s41467-026-71552-3>
10. Wang, G. G., Lu, D., Gao, T., Zhang, J., Sun, Y., Teng, D., Yu, F., & Zhu, J. (2024). Climate-smart forestry: An AI-enabled sustainable forest management solution for climate change adaptation and mitigation. *Journal of Forestry Research*, 36(1), Article 7. <https://doi.org/10.1007/s11676-024-01802-x>
11. Korea Forest Service. (2026). Forest Carbon Offset Scheme. https://www.forest.go.kr/newkfsweb/html/HtmlPage.do?pg=fcm/UI_FCS_111000.html&mn=KFS_02_10_11_10&orgId=fcm (accessed August 2, 2026)
12. Korea Forestry Promotion Institute. (2026). Operation of the Forest Carbon Offset Scheme. https://www.kofpi.or.kr/intro/bizGuide_04_02.do (accessed August 2, 2026)
13. Stephenson, N. L., Das, A. J., Condit, R., Russo, S. E., Baker, P. J., Beckman, N. G., et al. (2014). Rate of tree carbon accumulation increases continuously with tree size. *Nature*, 507, 90-93. <https://doi.org/10.1038/nature12914>
14. Verra. (2026). Technical background note: Verra's new REDD methodology. <https://verra.org/methodologies-main/technical-background-note-new-redd-methodology/> (accessed August 3, 2026)

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।