

인공지능과 디지털 혁신이 이끄는 미래 임업·산림농업



김경진

이 책은 인공지능으로 정리 제작된 것입니다.
전 세계의 주요 언어로된 자료를 수집 종합한 것입니다.

<https://notebook.google.com/notebook/2d68677c-b410-4281-bd84-9368ae15eeb4>

위 링크는 이 책을 제작하는데 참고된 자료들이 수집 저장된
노트북 엘엠의 주소 유알엘 입니다.
누구든지 자유롭게 접근 활용할 수 있도록 공개해 두었습니다.

차례

제1장	산림 패러다임의 전환: 데이터·AI 기반 산림 빅데이터와 디지털 트윈	3
1.1	산림 자원 관리의 패러다임 시프트와 디지털 트윈(Digital Twin) 구축	5
1.2	다중모달(Multimodal) 원격탐사 데이터 융합 기술	12
1.3	산림 전용 대형언어모델(ForestGPT)과 지능형 의사결정 지원	19
제2장	정밀 임업(Precision Forestry): 단목 해석 및 바이오매스·탄소 정밀 측정	27
2.1	UAV-LiDAR 및 고해상도 영상 기반 단목(Individual Tree) 수종 분류	29
2.2	지상부 바이오매스(AGB) 및 산림 탄소 축적량 추정	36
2.3	산림 토양 동태 및 토지 피복 변동 모니터링	41
제3장	산림 재해 및 생태계 건강 모니터링: AI 예찰과 조기 경보	49
3.1	머신러닝·딥러닝 기반 산불 위험도 예측 및 연소지 감지	51
3.2	병해충(소나무재선충병 등) 및 고사목(Dead Tree) 조기 영상 진단	57
3.3	불법 벌목 음향 감지 및 IoT/블록체인 산림 보호 네트워크	64
제4장	스마트 임업 작업과 로봇틱스: 작업 안전, 자율주행 및 임도망 최적화	71
4.1	임도 및 작업로(Skid Trail) 자동 추출과 지형 맞춤형 수확 계획	73
4.2	원격 조종 벌채기, 자율주행 포워더 및 임업 로봇틱스	81
4.3	컴퓨터 비전·Wearable 센서 기반 근로자 작업 안전 예찰	88
제5장	지속가능한 산림농업(Agroforestry)과 목재 공급망 DX	95
5.1	산림농업 시스템에서의 수분 이용 효율(WUE) 및 생태계 서비스 최적화	97
5.2	ICT 기반 목재 트레이서빌리티(QR/전자태그) 및 목재 품질 자동 감정	104
5.3	순환 바이오경제(Circular Bioeconomy)와 산림 탄소 신용(Carbon Credit)	110

제1장

산림 패러다임의 전환: 데이터·AI 기반 산림 빅데이터와 디지털 트윈

1.1

산림 자원 관리의 패러다임 시프트와 디지털 트윈(Digital Twin) 구축

아침 여섯 시, 조사원은 등산화 끈을 조이고 배낭에 줄자와 흉고직경 테이프, 종이 야장을 챙겨 넣습니다. 오늘 올라야 할 표본점은 해발 700미터 능선 사면에 있고, 지도에 찍힌 좌표까지는 걸어서 두 시간 남짓 걸립니다. 산림청은 전국 산림에 5,400개 표본점을 배치했습니다. 조사원들은 이곳에서 임목 축적과 숲의 건강 상태를 비롯한 69개 항목을 기록하며, 같은 표본점을 5년 주기로 다시 찾습니다. 표본점에 닿은 조사원은 나무 한 그루 한 그루에 줄자를 두르고 눈금을 읽어 흉고직경(DBH, 가슴 높이에서 잰 나무 줄기의 지름)을 야장에 옮겨 적습니다. 비탈이 가파르면 측고기를 눈높이에 맞추는 일도, 각도를 재고 계산해서 나무 키를 구하는 일도 시간이 걸립니다. 하루를 꼬박 채워도 조사원 한 사람이 마칠 수 있는 표본점은 많아야 두세 곳입니다.

손끝은 줄자에 쏠려 뜨고, 갑자기 소나기가 지나가면 야장 위 연필 글씨는 번져서 다시 알아보기 어려워집니다.

이렇게 모은 숫자는 정확하지만 낡기 쉽습니다. 5년에 한 번 표본점을 도는 사이에 산불이 능선을 태우고 병해충이 임분 하나를 통째로 갉아먹어도, 다음 조사가 돌아올 때까지 그 변화는 공식 통계에 잡히지 않습니다. 국유림과 사유림을 가리지 않고 국가산림자원조사와 이류(二類) 산림조사는 오랫동안 이런 식으로 운영되어 왔습니다. 사람의 발과 눈에 기대는 조사는 느리고 비용이 많이 들고, 시간과 공간을 촘촘하게 채우지 못합니다. 그것으로 끝이 아닙니다. 정밀한 수확 계획을 세우려 해도 5년 전 숫자로는 당장의 나무 상태를 짐작할 수밖에 없습니다.

표본점에서 격자 지도로

이런 한계를 넘어서려는 움직임이 산림 분야 전체에서 벌어지고 있습니다. 임업의 디지털 전환(DX)은 종이 전표와 손으로 그린 도면을 모바일 앱과 지리정보시스템(GIS) 데이터로 옮기는 일에서 시작합니다. 그다음 단계에서는 이렇게 쌓인 데이터를 산림 관리와 목재 수급 매칭, 전자 신청 체계로 엮어 냅니다. 마지막 단계에 이르면 벌채와 조림 같은 임업의 상류 공정부터 유통과 가공이라는 하류 공정까지, 그리고 다른 산업과 만나는 곳까지 데이터가 실시간으로 흐르면서 의사결정 자체가 새로 짜입니다.

이런 흐름은 한국에서도 낫설지 않습니다. 국립산림과학원 산림ICT연구센터는 강원도 가리산 선도산림경영단지를 무대로 항공 라이다와 지상 라이다, 백팩형 라이다 장비를 나란히 투입해 디지털 산림자원정보를 모으고 정밀임업에 쓰는 시험을 이어 왔습니다. 장비마다 데이터를 모으는 정확도와 작업 속도가 다르다 보니, 어떤 조합이 실제 현장에 맞는지 가려내는 후처리 작업이 뒤따랐습니다.

행정구역이나 관습적으로 나뉜 온 소반(小班, 산림 관리를 위해 잘게 나눈 구획) 경계에 의존해 통계를 내던 방식에는 오래된 결함이 있었습니다. 같은 소반 안에서도 골짜기와 능선의 미지형에 따라 나무 키와 성장 속도가 다른데, 소반 단위로 평균을 내는 순간 그 차이는 묻개져 버립니다. 최근에는 이 문제를 풀기 위해 산림 공간 데이터를 20미터 정방형 격자로 다시 짜는 시도가 이어지고 있습니다. 항공 레이저 측량(ALS)과 위성 데이터가 가진 정밀도를 격자 하나하나에 그대로 담아 두려는 목적입니다.

이 변화의 중심에는 의사결정 지원 시스템(DSS, Decision Support System)과 여러 종류의 데이터를 한데 묶는 통합 플랫폼이 있습니다. DSS는 여러 데이터를 모아 분석한 뒤 사람이 결정을 내릴 때 참고할 수치와 그래프를 보여주는 소프트웨어입니다. 유럽연합의 호라이즌 유럽(Horizon Europe) 사업으로 나폴리 페데리코2세 대학교가 이끄는 디지메드포(DigiMedFor) 프로젝트는 산림 자원 모니터링과 인벤토리 구축, 목재의 이력 추적과 등급 판정, 산림 계획 의사결정 지원이라는 세 가지 축을 중심에 놓고 기술을 통합합니다. 이 프로젝트의 포레스트 패스웨이(Forest Pathway)는 수종과 생물기후대, 입지생산력, 경영목표를 입력받아 숲을 가꿀 경로를 안내하는 웹 전문가 시스템입니다.

특정 지역의 드론 인벤토리와 법령을 자동으로 처리하는 현장 시뮬레이터가 아니라, 산림 경영자가 선택지를 좁힐 때 참고하는 지침 도구에 가깝습니다.

산림 디지털 트윈을 이루는 구조는 네 층으로 나뉘 볼 수 있습니다. 맨 아래에는 실제 숲과 토양, 미기후로 이뤄진 물리 환경이 있고, 그 위로 위성과 무인기(UAV), 지상 IoT 센서, 지상 라이다가 모아 온 데이터 층이 쌓입니다. 세 번째 층은 이 데이터를 하나로 엮고 딥러닝으로 특징을 뽑아내며 시공간을 맞춘 시뮬레이션 엔진을 돌립니다. 맨 위층에서 정밀 산림 관리와 예측 분석, 탄소 흡수량 검증, 자율 작업 연계 같은 실제 쓰임이 나옵니다.

이 기술은 단계를 밟으며 자라 왔습니다. 처음에는 숲을 그대로 본뜬 정적인 3차원 모델에 머물렀습니다. 그다음에는 센서 데이터가 한쪽 방향으로만 반영되는 디지털 섀도(Digital Shadow, 실제 상황이 가상 모델에 비치기만 하고 되돌아가지는 않는 단계)를 거쳤습니다. 지금 겨냥하는 형태는 실제 숲과 가상 숲이 서로 신호를 주고받으며 실시간으로 되먹임하는 완성형 디지털 트윈입니다.

라이다가 그리는 나무 한 그루

라이다(LiDAR)는 레이저 빛을 쏘아 보내고 그 빛이 물체에 부딪혀 되돌아오는 시간을 재서 거리를 계산하는 장치입니다. 계산 원리는 어렵지 않습니다. 이 빛을 어디에 다느냐에 따라 이름이 달라집니다. 비행기에 실으면 항공 라이다(ALS), 무인기에 실으면 무인기 라이다(ULS), 땅 위에 세워 두면 지상 라이다(TLS), 등에 메고 걸어 다니면 이동식 매핑 시스템(MMS)이 됩니다.

기존 라이다는 대체로 파장 하나만 쏘기 때문에 레이저가 어디서 튕겨 나왔는지 위치는 정확해도 그것이 잎인지 가지인지 구별하는 데는 서툴렀습니다. 최근에는 세 개 파장을 동시에 쏘는 멀티스펙트럼 라이다가 이 문제를 파고들고 있습니다. 공개 벤치마크 데이터셋 포레스트세맨틱-MS(ForestSemantic-MS)를 놓고 여러 딥러닝 모델을 겨루게 한 연구가 있습니다. 이 연구에서 포인트 트랜스포머 V3(PTv3) 모델은 지표면과 관목, 줄기, 가지, 잎, 쓰러진 고사목이라는 여섯 가지 구성 요소를 나누는 시험을 치렀습니다. 평균 교집합 비율(mIoU, 모델이 예측한 영역과 실제 영역이 겹치는 정도를 평균으로 나타낸 값)에서 69.1퍼센트를 기록해 다른 모델보다 21.8퍼센트포인트 앞섰습니다.

잎과 가지가 뒤엉킨 곳에서는 파장 하나로 나무 부위를 구별하기 어렵지만, 파장을 세 개로 늘리면 이야기가 달라집니다. 쓰러진 고사목을 알아보는 정확도는 12.7퍼센트포인트, 가지는 4.5퍼센트포인트, 줄기는 2.5퍼센트포인트 올라갔습니다.

손이 많이 가는 다중 스캔 대신 한 번만 훑고 지나가는 단일 스캔 지상 라이다도 있습니다. 미국 인디애나주 마텔 숲(Martell Forest)의 활엽수 혼효림에서는 이렇게 한 번 스캔한 점군 데이터를 2차원 투영 이미지로 바꾸고, 합성곱과 주의집중(attention) 방식을 함께 쓰는 코엣넷(CoAtNet) 신경망으로 나무 한 그루 한 그루의 지상부 바이오매스를 추정하는 실험이 이뤄졌습니다. 나무 뒤편이 가려지는 결함을 안고도 이 방식은 설명력이 0.73에 이르렀고, 랜덤 포레스트나 포인트 트랜스포머 같은 비교 모델보다 나은 성적을 냈습니다.

2026년에는 점군을 아예 다른 방식으로 다루는 시도도 나왔습니다. 라이다 데이터를 가우시안 스플래팅(Gaussian Splatting)이라는 렌더링 기법으로 이끄는 연구인데, 점 하나 하나를 작은 반투명 타원으로 바꿔 쌓아서 나무 표면을 훨씬 사실적으로 복원합니다. 딱딱한 줄기와 부드럽게 흔들리는 잎을 따로 다루는 규칙을 넣어서, 초기화 단계에서 흔히 생기던 뭉개짐과 흔들림을 줄였다고 연구진은 보고합니다.

가상 숲에서 미리 베어보기

가상 산림은 예쁜 3차원 그림에서 멈추지 않습니다. 나무의 위치와 키, 수관 폭, 흉고직경 같은 실제 인벤토리 데이터를 그대로 옮겨 놓으면, 간벌이나 개벌처럼 나무를 솎아 내고 베어 내는 작업의 결과를 미리 눈으로 확인할 수 있는 시뮬레이션 환경이 만들어집니다. 디지메드포 프로젝트가 개발한 가상 숲 의사결정 지원 시스템(VFDSS, Virtual Forest Decision Support System)은 실제와 거의 같은 위치에 가상 나무를 심어 놓고 숲을 통째로 복제합니다. 이 시스템은 날짜와 시각에 따라 달라지는 햇빛의 양을 계산해서 나무가 얼마나 별을 받고 자라는지 지켜봅니다. 사용자는 책상 앞 데스크톱 화면으로 숲 전체를 내려다볼 수도 있고, 가상현실(VR) 헤드셋을 쓰고 숲 안으로 걸어 들어가 나무 한 그루를 골라 벌채나 식재 작업을 해 볼 수도 있습니다.

간벌할 나무를 고르는 순간 남는 나무의 수와 밀도, 앞으로의 성장 추이, 베어 낸 목재의 수확량이 통계로 곧바로 화면에 뜹니다. 미국 미시시피와 더글러스퍼(Douglas fir) 임분에 실제로 적용해 본 결과, 위치와 나무 치수를 담은 데이터와 40개 남짓한 수종의 3차원 견본만 갖추면 몇 시간 안에 그 지역 숲의 디지털 트윈을 세울 수 있었습니다.

케스케스와 니처(Keskes & Niță, 2026)는 루마니아 현장 자료를 바탕으로 만든 모형에 핀란드의 다원천 국가산림자원조사 자료를 더했습니다. 핀란드 임목 재적 예측의 설명력은 0.483에서 0.718로 올랐습니다. 탄소 지도를 직접 만든 연구가 아니라, 서로 다른 나라의 자료를 연결해 임분 구조 예측을 개선한 시험입니다. 나라를 넘겨 모형을 쓸 때에는 현지 표본으로 다시 보정해야 합니다.

비슷한 시도는 미국에서도 이어지고 있습니다. 오리건주립대학교는 엘리엇 주립림(Elliott State Forest)의 77.6제곱킬로미터와 나무 약 280만 그루를 포괄하는 디지털 트윈을 만들었습니다. 이 가운데 2만 6,000그루는 게임 엔진에서 세밀하게 구현했습니다. 이 가상 숲 안에서는 시간과 날씨를 바꿔 가며 지형을 걸어 다니고, 선택적 벌채나 개벌이 숲에 남기는 흔적을 미리 살펴볼 수 있습니다. 미시간주립대학교와 버지니아텍 연구진은 버지니아 중부의 리기다소나무(Pinus taeda) 숲 7.5에이커에서 나무 3,555그루를 조사해 여러 간벌 시나리오를 비교했습니다. 블록과 시나리오에 따른 제거 재적의 차이는 7.9퍼센트에서 18.2퍼센트였습니다. 한 블록에서는 원목 가격을 가정했을 때 에이커당 약 70달러의 차이가 났습니다.

한 시험지에서 얻은 계산이라 다른 숲에서도 같은 수익이 난다고 단정할 수는 없습니다.

숲속 화면과 로봇의 예행연습

디지털 트윈에 쌓인 데이터는 화면 안에만 머물지 않습니다. 현장 작업자가 스마트폰이나 태블릿, 또는 마이크로소프트 홀로렌즈2(HoloLens 2)나 애플 비전 프로(Apple Vision Pro) 같은 혼합현실 기기를 쓰면 실제 나무 위에 겹쳐진 증강현실(AR) 그래픽을 볼 수 있습니다. 아보리얼 포레스트(Arboreal Forest)와 포레스트스캐너(ForestScanner), 트리 스캐너(Tree Scanner) 같은 애플리케이션은 스마트폰에 달린 라이다와 RGB-D 센서, 위치 추적 기술(SLAM, Simultaneous Localization and Mapping, 기계가 스스로 주변 지도를 그리며 제 위치를 찾는 기술)을 엮어서 현장을 걸어가는 동안 나무의 흉고직경과 키, 좌표를 증강된 3차원 그래픽과 함께 현장에서 바로 확인하게 해 줍니다.

기술 성숙도는 시제품 수준부터 이미 상품으로 팔리는 수준까지 걸쳐 있습니다. 보리얼(Boreal) 산림에서 무인기 라이다와 SLAM으로 잰 흉고직경 오차는 2.0에서 4.0센티미터 사이로 작았습니다. 나무가 뻗뻗하게 들어찬 아열대 도시 숲에서는 오차가 5.13센티미터, 비율로는 22.01퍼센트까지 커졌습니다.

임업 기계를 위한 가상 훈련장도 만들어지고 있습니다. 스웨덴 빈델른(Vindeln) 지역에서는 지상 라이다 장비 라이카 BLK360으로 서른 개 위치를 스캔하고 드론 데이터를 더해 고정밀 디지털 트윈을 복제했습니다. 이렇게 만든 가상 숲 안에서 시점과 태양 각도를 무작위로 바꿔 가며 심포레스트(SimForest)라는 합성 데이터셋을 자동으로 만들어 냈습니다. 임업 로봇이나 자율주행 포워더가 사람이나 나무, 장애물을 실시간으로 알아채고 멈추는 안전 기능을 실제 숲에 내보내기 앞서 이 가상 데이터로 미리 검증하는 셈입니다.

핀란드 자연자원연구소(Luke)는 탄소 거래 시장을 겨냥한 디지털 트윈을 개발하고 있습니다. 라이다를 단 드론으로 나무 각각의 높이와 흉고직경, 수종을 기록하고 여러 위성 자료를 겹친 뒤, 이 원자료를 동적인 3차원 모형으로 바꿉니다. 탄소 흡수량 분석을 베라(VERRA)나 골드 스탠더드(Gold Standard) 같은 검증 체계와 잇는 것이 목표입니다. 아직은 상용화 경로를 찾는 연구 단계입니다.

다시 흐려지는 정확도

이렇게 쌓인 성과에도 연구 결과가 서로 어긋나는 경우가 적지 않습니다. 다중 스캔 지상 라이다는 나무 부피를 재는 정밀도에서 뛰어나지만, 여러 위치에서 찍은 데이터를 짜 맞추는 정합 과정에 손이 많이 갑니다. 반대로 단일 스캔과 딥러닝을 묶은 방식은 수집 속도를 크게 끌어올렸지만, 나무 뒤편에 가려진 가지나 쓰러진 고사목을 놓치는 오차를 완전히 없애지는 못했습니다. 멀티스펙트럼 라이다도 마찬가지입니다. 부위별 인식 정확도는 눈에 띄게 올라가지만 장비 값이 비싸고 처리해야 할 데이터 양도 훨씬 늘어납니다. 예산이 넉넉하지 않은 산림조합이 이런 장비를 당장 들이기는 쉽지 않아 보입니다.

한 시험림에서 높은 정확도를 낸 모델도 온대 혼효림이나 아열대림으로 옮기면 성능이 낮아질 수 있습니다. 수종과 수관 구조, 센서, 자료를 나누는 방식이 달라지기 때문입니다. 다른 숲에 적용하려면 그 지역 자료로 모델을 다시 보정해야 합니다.

하층 식생이 우거지고 나무 위쪽이 촘촘하게 맞닿은 숲에서는 드론이나 위성이 쏘는 빛이 땅까지 닿지 못해 나무 아래쪽과 줄기 굵기를 재는 오차가 커집니다. 나무 아래를 날아다니는 자율주행 드론은 시각과 관성 정보를 함께 쓰는 위치 추적 기술(VIO, SLAM)에 기대는데, 빛이 부족하고 나뭇가지가 흔들리면 위치를 놓치거나 아예 길을 잃기도 합니다. 가뭄과 고온 스트레스를 계산하는 생장모형은 이미 존재합니다. 아직 드문 것은 현장 센서와 극한기후 자료를 디지털 트윈 안에서 계속 갱신하는 운영형 시스템입니다.

비전 트랜스포머(ViT)나 3차원 합성곱신경망처럼 성능이 뛰어난 모델일수록 내부에서 어떤 근거로 그런 판단을 내렸는지 설명하기 어려운 블랙박스로 남습니다. 산림 정책을 결정하는 사람 처지에서는 이 불투명함이 신뢰를 늦추는 요인이 됩니다. 이런 모델은 대개 성능 좋은 GPU를 필요로 하기 때문에, 통신이 끊기기 쉬운 오지의 드론이나 현장 단말기에 그대로 옮겨 심기도 쉽지 않습니다.

유엔식량농업기구(FAO)는 2026년 2월 펴낸 글에서 비슷한 걱정을 다른 각도에서 짚었습니다. 인공지능이 뽑아낸 숫자를 그대로 정책에 쓰려면 현장 검증이 반드시 뒤따라야 하고, 이를 다룰 훈련된 인력과 표준 절차 같은 제도가 기술 도입 자체보다 오래 걸린다는 지적입니다.

이 틈을 메우려는 시도도 함께 진행되고 있습니다. 모델이 어떤 정보에 기대어 판단했는지 거꾸로 짚어 보는 샵(SHAP)이나 그래드캠(Grad-CAM) 같은 설명 가능한 인공지능(XAI) 기법을 끌어들이고, 수종별 개화 시기나 토양 수분 같은 생태학적 지식을 모델 안에 규칙으로 심어 정확도와 설명력을 함께 잡으려는 연구가 이어지고 있습니다. 가지치기와 양자화, 지식 증류 같은 경량화 기법으로 드론과 현장 단말기에서도 돌아가는 모델을 만드는 작업도, 지역과 장비마다 흩어진 데이터를 하나의 표준 형식으로 묶는 작업도 함께 진행되고 있습니다.

근거 및 참고문헌

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. (2026, 2월 27일). 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/> (2026년 8월 2일 접속)
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> (2026년 8월 2일 접속)
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. (2024, 8월 1일). 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/> (2026년 8월 2일 접속)
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> (2026년 8월 2일 접속)
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. (2026, 2월 6일). 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> (2026년 8월 2일 접속)
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. 산림청. (n.d.). 국가산림자원조사. https://forest.go.kr/kfsweb/kfi/kfs/cms/cmsView.do?mn=NKFS_04_05_08&cmsId=FC_000344 (2026년 8월 2일 접속)
18. 大萱直花. (2025). 眞の林業DXとは. *森林応用研究*, 34(1), 21-23. https://doi.org/10.20660/applfor.34.1_21

1.2

다중모달(Multimodal) 원격탐사 데이터 융합 기술

장마전선이 사흘째 한반도를 덮고 있던 어느 여름, 국가산림위성정보활용센터의 모니터 앞에 앉은 연구원이 새로 내려받은 위성 영상을 열어 보고 한숨을 쉬었습니다. 화면 절반이 우유를 부어 놓은 듯 뿌옇게 하였습니다. 강원도 동해안의 소나무재선충병 방제 구역을 확인하려던 참이었는데, 구름이 산 전체를 가리고 있어서 나무 한 그루도 구분할 수 없었습니다. 화면 아래쪽에는 방제 대상목의 위치를 표시한 붉은 점들이 흩어져 있었지만, 그 위를 덮은 구름 때문에 최근 상태를 확인할 방법이 없었습니다. 옆에 앉은 동료가 종이컵을 내려놓으며 오늘도 하늘이 안 열리네요, 하고 짧게 한마디를 던지고 지나갔습니다. 광학 위성은 사진기와 같은 원리로 움직입니다. 태양빛이 지표에서 반사되어 렌즈로 들어오는 양을 기록하는 장치이기 때문에, 구름이 끼면 사진기 앞을 손바닥으로 가린 것과 똑같은 상태가 됩니다.

다음 위성이 같은 하늘을 다시 지나가려면 며칠을 더 기다려야 합니다. 그사이 병든 나무는 조용히 번지고, 마른 낙엽 밑에서는 불씨가 자랍니다.

다중모달 원격탐사 데이터 융합은 이런 순간에 필요해집니다. 하늘 위에서 눈 하나로만 숲을 보면 반드시 못 보는 구간이 생깁니다. 위성은 넓은 지역을 자주 찍지만 구름과 안개에 가로막히고, 나무 꼭대기 아래로는 눈길이 닿지 않습니다. 무인기(UAV)나 지상 레이저 스캐너는 앞 한 장, 가지 하나까지 센티미터 단위로 잡아내지만 배터리와 인건비 때문에 국토 전체를 훑을 수는 없습니다. 드론 한 대의 배터리는 길어야 40분을 버팁니다. 그래서 연구자들은 방법을 바꿨습니다. 서로 다른 눈을 가진 장비를 한 화면 안에 겹쳐 놓는 쪽으로 방향을 잡은 것입니다. 하늘에 떠 있는 위성과 대기 중을 나는 드론, 땅에 발을 붙인 센서를 한 몸처럼 엮는 공중, 대기, 지상 다층 관측망입니다.

하늘과 땅 사이, 세 겹의 눈

세 계층은 맡는 일이 다릅니다. 위성은 한반도 전체를 사흘이나 닷새 만에 훑고, 드론은 임분 하나를 골라 나무 한 그루 단위로 들여다보고, 땅에 놓인 센서는 한곳에 눌러앉아 몇 달, 몇 년 치 변화를 초 단위로 쌓습니다.

거시 규모를 맡는 위성 계층에는 유럽우주국의 센티널 계열, 미국의 랜드샷 계열, 중국의 GF-2가 들어갑니다. 수관 높이를 직접 재는 아이스샷-2와 게디(GEDI)도 이 계층에 놓입니다. GF-2는 지표를 0.8미터 칸까지 나누어 찍는 고해상도 위성입니다. 랜드샷-8과 랜드샷-9는 열적외선 밴드를 함께 실어 산불 직후의 열기까지 잡아냅니다. 게디는 국제우주정거장에 실려 지구 곳곳의 숲 높이를 점 단위로 찍어내는 장비입니다. 드콘토와 암스턴, 두베이아 연구자들은 2025년에 이 점 자료 1억 3천만 개 이상을 합성개구레이더(SAR) 자료와 딥러닝으로 엮었습니다. 그 결과로 나온 25미터 칸의 전 지구 산림 구조 지도는 설명력이 0.82에 이르렀습니다. 매개변수가 40만 개도 안 되는 비교적 가벼운 모델로 얻은 결과입니다.

이 계층에는 새 얼굴도 들어왔습니다. 미국항공우주국(NASA)과 인도우주연구기구(ISRO)가 함께 만든 니사르(NISAR) 위성은 2025년 7월 30일 발사됐습니다. 지표에서 약 747킬로미터 위를 돌며 엘(L) 밴드와 에스(S) 밴드 레이더로 토양 수분과 산림 바이오매스, 땅의 미세한 움직임을 잡니다. 이 위성이 모은 엘 밴드 자료는 2026년 7월 20일부터 누구나 내려받을 수 있게 되었습니다. 예전에는 국가기관이나 대형 연구소만 손댈 수 있던 이런 자료를, 이제는 한국의 대학원생도 인터넷에서 무료로 내려받아 자기 논문에 쓸 수 있습니다. 유럽우주국의 바이오매스(Biomass) 위성은 한발 더 나아가 기존 레이더보다 파장이 긴 피(P) 밴드를 처음으로 실었습니다. 파장이 길수록 잎과 가지를 깊이 뚫고 들어가 줄기의 목질 부피까지 가늠할 수 있습니다.

이 위성은 2025년 4월 발사됐습니다. 그해 12월 19일 첫 공개 자료를 내놓았습니다. 유럽의 관측망에서는 센티널-1디가 2025년 11월 궤도에 올랐습니다. 앞서 있던 센티널-1씨와 짝을 이루면서 옛새 주기로 같은 곳을 다시 찍는 예전 체계가 되살아났습니다.

한국도 이 계층에 새 위성을 하나 올렸습니다. 우주항공청과 농촌진흥청, 산림청이 함께 만든 농림위성은 차세대중형위성 4호입니다. 스페이스엑스의 팰컨9 로켓이 이 위성을 실었습니다. 발사일은 2026년 7월 7일이었습니다. 해상도 5미터급 영상을 사흘 주기로 한반도 전역에서 찍는 이 위성은 산불과 산사태 피해 구간을 넓은 범위에서 빠르게 짚어내는 데 쓰일 예정입니다. 국내 민간 기업 한컴인스페이스가 2026년 3월 쏘아 올린 초분광 위성 세종 3호도 눈여겨볼 만합니다. 보통 카메라가 빛을 빨강, 초록, 파랑 세 색깔로만 나누어 담는다면, 신발 상자 두어 개를 이어 붙인 크기의 이 6유닛(6U)급 초소형위성은 442개 구간으로 나누어 담습니다. 무게는 11킬로그램이 채 안 됩니다. 나뭇잎의 색이 아니라 나뭇잎을 이루는 물질 자체의 반사 특성까지 구분해 낼 잠재력을 지닌 셈입니다.

중간 규모를 맡는 드론 계층에서는 라이다(LiDAR)와 고분광(Hyperspectral), 다분광(Multispectral) 센서, 초고해상도 카메라가 임분과 개별 나무의 입체 구조와 색 지문을 함께 모읍니다. 라이다는 빛을 쏘아 되돌아오는 시간을 재서 물체까지의 거리를 알아내는 장치입니다. 드론에 실린 라이다는 나무 위를 낮게 날면서 수관 하나하나의 굴곡까지 잡

아닙니다. 미시 규모 계층은 땅바닥에 거의 붙어 있습니다. 지상 라이다(TLS), 등에 지고 다니는 이동식 매핑 장비(Backpack MMS), 토양 수분과 기온을 재는 사물인터넷 미기후 센서, 계절 변화를 촬영하는 페노캠(PhenoCam) 탐이 이 계층을 이룹니다. 페노캠은 같은 나무를 매일 같은 각도에서 찍어 잎이 언제 돋고 언제 붉게 물드는지를 날짜 단위로 기록합니다.

사물인터넷 센서는 땅속 15센티미터 깊이에 묻혀 흙이 마르는 속도를 서버로 실시간 전송합니다. 이 장비들은 나무의 가슴높이 지름과 줄기의 휘어진 정도, 하층 식생, 토양 수분을 쉬지 않고 재고 기록합니다. 가슴높이 지름은 나무 한 그루의 목재 부피와 탄소 축적량을 계산하는 첫 입력값이기 때문에, 몇 밀리미터 오차도 숲 전체로 곱해지면 무시하기 어려운 크기로 불어납니다.

국립산림과학원이 2026년 1월 공개한 라이다 탑재 자율주행 드론은 이 계층과 드론 계층 사이에 걸쳐 있는 장비입니다. 사람이 줄자를 들고 걸어서 한 헥타르를 조사하는 데 22시간이 걸리던 일을, 이 드론은 2.3시간 만에 끝냈습니다. 현장에서 직접 잴 것과 비교했을 때 정확도는 96퍼센트에 이르렀고, 나뭇잎에 가려 사람 눈으로는 재기 힘들던 흉고직경까지 잡아냈습니다.

시공간을 맞추는 일

문제는 이렇게 모인 자료들이 서로 다른 자료 잴 것과 같다는 데 있습니다. 위성 영상은 한 칸에 10미터에서 30미터를 담습니다. 드론 영상은 수 센티미터, 지상 스캐너는 수 밀리미터 단위까지 촘촘합니다. 화소 하나가 어긋나면 지도 위에서는 나무 한 그루가 옆 나무의 그림자 속으로 통째로 들어가 버립니다. 이 자료를 겹치려면 산길 곳곳에 반사판과 십자 표식을 놓고 위성항법으로 좌표를 재는 지상기준점 작업이 먼저입니다. 그런 뒤 합리적합수모델과 특징점 기반의 기하 보정을 거칩니다. 센서마다 해상도와 좌표계가 달라, 연구지와 장비에 맞춘 정합 오차 검사가 뒤따라야 합니다.

시간을 맞추는 일도 만만치 않습니다. 센티널-2는 두 위성 체계에서 약 닷새, 랜드샷 한 위성은 약 열엿새 만에 같은 구역을 다시 지나가고, 드론과 지상 조사는 연구자의 일정에 맞추어 뜬문뜬문 이루어집니다. 그 사이에 나무는 잎을 내고 물을 머금은 정도가 달라지기 때문에, 시점이 어긋난 자료를 그대로 겹치면 같은 나무인데도 다른 색으로 보이는 착시가 생깁니다. 구름과 그림자를 거르는 Sen2Cor와 Fmask 같은 알고리즘을 거치고, 같은 계절의 여러 영상을 골라 합성하는 이유입니다. 화소 위치와 관측 시점이 어긋나면 모델의 입력 신호가 뒤섞이므로, 연구마다 정합 오차와 시간 차이를 따로 보고해야 합니다.

탄자니아 남부 고원의 소농림에서 진행한 최근 연구는 이 문제에 실마리 하나를 보였습니다. 마우야와 조나스 두 연구자는 구름이 잦은 지역에서 센티널-1 레이더와 센티널-2 광학 자료를 무작위숲과 서포트벡터머신(SVM) 모델로 합쳤더니, 광학 자료 하나만 썼을 때

보다 소농이 심은 나무의 수종 분류 정확도가 올랐다고 밝혔습니다. 장마철 관제실에서마 주쳤던 하얀 화면 문제에 대한 답 하나가 이렇게 쌓이고 있는 셈입니다.

빛과 전파와 레이저를 하나로

세 가지 센서는 숲의 서로 다른 성질을 봅니다. 광학 센서는 가시광선과 근적외선, 단파적 외선 대역으로 잎의 엽록소와 수분 상태, 식생지수를 읽어 냅니다. 다만 잎이 뽀뽀하게 우 거진 구간에서는 반사값이 한계치에 닿아 버려서 그 이상은 구분하지 못합니다. 합성개구 레이더는 센티널-1의 씨(C) 밴드나 알로스 팔사(ALOS PALSAR)의 엘 밴드처럼 마이크로파를 쏘아 구름과 상관없이 굵은 가지와 줄기에서 튕겨 나오는 신호를 잡아 숲 속 열개 를 짐작합니다. 장마철에 위성 사진이 하얗게 지워지던 순간에도, 마이크로파는 구름을 그냥 통과해 버립니다. 라이다는 레이저 펄스를 쏘아 나무의 높이와 수관 부피, 층 구조, 땅의 높낮이를 센티미터 단위로 직접 잽니다. 세 눈을 한꺼번에 뜨면 서로의 빈틈을 채울 수 있습니다.

이 세 가지 자료를 인공지능 모델에 넣는 방식은 크게 나뉩니다. 입력 단계에서 광학, 레 이더, 라이다 채널을 이어 붙여 신경망 하나에 넣는 조기 융합은 구조가 간결하지만, 표본 에 견줘 입력 차원이 지나치게 커지면 과적합 위험이 높아집니다. 각 센서마다 별도의 신 경망으로 학습시킨 뒤 마지막 판단 단계에서 투표나 가중 평균으로 합치는 후기 융합은 센서별 특성을 지키지만 센서 사이의 미묘한 상호작용을 놓치기 쉽습니다. 중간 단계에서 교차주의집중(Cross-Attention) 구조로 특징을 섞는 하이브리드 융합은 계산량이 늘어 나는 대신 센서별 정보의 관계를 더 깊게 배울 수 있습니다.

이 방식들이 실제로 어떤 차이를 만드는지는 몇몇 현장 연구에서 드러납니다. 중국 산하 와 황풍교 지역의 아열대 혼효림을 대상으로 한 MTSCFNet 연구는 드론 라이다와 초고해 상도 RGB 영상, GF-2 위성 영상을 세 개의 인코더와 교차 융합 모듈로 엮어, 광학이나 라 이다 하나만 썼을 때보다 수종 분류 정확도를 뚜렷하게 끌어올렸습니다. 이 연구에서는 라이다 장비 RIEGL miniVUX-1UAV로 1제곱미터당 87.14개의 점을 찍었습니다. DJI M300 RTK 드론으로는 화소 크기 6.23센티미터의 RGB 영상을 모았습니다. 중국에서는 이와 별도로 GF-2 광학 위성과 GF-3 레이더 위성 자료를 겹쳐 놓은 공개 데이터셋도 최 근 만들어져, 숲과 관목, 초지의 경계가 흐릿하게 뒤섞인 지역을 촘촘하게 나누는 연구에 쓰이고 있습니다.

고분광과 라이다를 결합한 다른 연구에서는 광학 자료 하나만 쓴 전체 정확도가 80.39퍼 센트에 머물렀던 반면, 교차주의집중으로 두 자료를 엮자 정확도가 89.60퍼센트까지 올 라 9.21퍼센트포인트가 뛰었습니다. 전 지구 수고 지도를 만드는 연구에서는 기여도가 라이다 직접 관측값, 지형 변수, 광학과 레이더의 간접 지수 순으로 높게 나타났습니다.

말레이시아 보르네오섬 데라마콧과 탕쿨랍 열대우림에서는 고마쓰 고타로를 비롯한 연구 진이 드론 RGB 영상으로 용뇌향과 나무를 자동으로 가려낸 뒤, 이를 위성 자료와 무작위

숲 모델에 역었습니다. 드론 영상만으로 용늪향과 나무를 가려낸 정확도는 생산자 정확도 0.71, 사용자 정확도 0.67이었습니다. 현장 표본 없이 위성 자료만 쓴 모델은 설명력이 0.43, 오차는 헥타르당 70.60메가그램이었습니다. 드론에서 뽑은 변수를 더하자 설명력은 0.51로 오르고 오차는 60.53메가그램까지 줄었습니다. 현장을 일일이 걸어 다니며 표본을 세는 비용을 크게 아낄 수 있다는 뜻입니다.

러시아 사할린의 관리림에서는 임분 소반 자료와 센티널-2 시계열, 지형 자료를 무작위숲과 엑스지부스트(XGBoost), 탭넷(TabNet) 세 가지 모델에 각각 넣어 겨루어 본 연구도 있었습니다. 엑스지부스트는 다른 두 모델보다 수고와 흉고단면적, 목재 축적량, 탄소 축적량의 오차가 모두 작았고, 통합 설명력은 0.68을 기록했습니다.

보르네오의 드론 조사와 강원도의 자율주행 드론 조사가 가리키는 방향은 같습니다. 사람이 정글칼을 들고 숲을 헤치며 나무를 한 그루씩 세는 대신, 하늘과 땅 사이 어느 층에선가 기계가 대신 세어 주는 쪽으로 저울이 기울고 있습니다. 그 저울을 얼마나 믿을 수 있는지는 다음 문제입니다.

어긋나는 결과와 남은 숙제

기술이 빠르게 늘어나는 만큼, 연구마다 서로 다른 답을 내놓습니다. 소나무처럼 한 수종으로만 이루어진 숲에서는 라이다가 재는 입체 구조, 곧 수관 폭과 높이, 가지 배치가 수종과 바이오매스를 가리는 데 큰 역할을 합니다. 잎 색이 아직 눈에 띄게 변하지 않은 초기 피해목을 찾는 일에도 광학 지수와 입체 구조를 함께 보는 접근이 연구되고 있습니다. 반대로 생물종이 뒤섞이고 관목까지 얹힌 열대나 아열대 혼효림에서는 라이다만으로 부족해, 광학과 고분광이 잡는 잎과 수분의 신호를 함께 봐야 합니다. 어떤 융합 방식이 앞서는지 센서 정합, 표본 수, 숲의 생김새에 따라 달라집니다.

현장에 그대로 옮기기 어려운 문제도 남아 있습니다. 한 지역에서 높은 정확도를 낸 모델도 수종과 계절이 다른 숲에서는 다시 보정해야 합니다. 나무가 뻗뻗하게 우거진 밀폐림에서는 위성이나 드론의 레이저와 광학 신호가 나무 아래층과 땅까지 닿지 않아 줄기 지름과 하층 식생 추정값에 오차가 쌓입니다. 숲 아래로 낮게 나는 드론도 위성항법 신호가 끊기면 자기 위치를 다시 헤아려야 합니다. 빛이 부족하고 나뭇가지가 바람에 흔들리면 영상관상항법(VIO)과 동시적위치추정지도작성(SLAM)의 위치 오차가 커집니다. 3차원 신경망과 비전트랜스포머는 입력 크기와 장치에 따라 큰 메모리와 전력을 요구하므로, 현장 장비에 넣으려면 모델 경량화와 장치별 속도 시험이 필요합니다.

이 벽을 낮추려는 시도도 이어지고 있습니다. 지식 증류와 모델 양자화, 전용 반도체 가속으로 삼중 모달 모델을 줄여 드론과 현장 단말기에서 돌리는 연구가 진행 중입니다.

Grad-CAM이나 SHAP 같은 설명 가능한 인공지능 기법은 신경망이 어떤 근거로 판단했는지를 화면에 표시합니다. 나무의 계절 변화와 토양 수분 물리 모형을 신경망에 제약 조건으로 넣어 생태학적으로 벗어난 답을 줄이는 방향도 있습니다. TreeSatAI와

PureForest, ForestSemantic-MS처럼 여러 지역과 센서를 아우르는 공개 데이터셋이 늘어질수록, 한반도 숲에 맞춘 모델을 따로 다듬을 기반도 두터워집니다.

근거 및 참고문헌

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> (2026년 8월 2일 접속)
2. European Space Agency. (2025a, 11월 4일). Copernicus Sentinel-1D launch highlights. https://www.esa.int/ESA_Multimedia/Videos/2025/11/Copernicus_Sentinel-1D_launch_highlights (2026년 8월 2일 접속)
3. European Space Agency. (2025b, 12월 19일). Biomass' first open data products now available. Earth Online. <https://earth.esa.int/eogateway/news/biomass-first-open-data-products-now-available> (2026년 8월 2일 접속)
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. (2026, 7월 20일). 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> (2026년 8월 2일 접속)
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. 뉴스핌. (2026, 7월 3일). 국내 첫 농림위성 발사...농작물 생육부터 재해까지 3일마다 정밀 관측. <https://www.newspim.com/news/view/20260703000799> (2026년 8월 2일 접속)

14. 헤럴드경제. (2026a, 1월 28일). 산림청, 숲속 누비는 '자율주행 드론' 시대 연다.
<https://biz.heraldcorp.com/article/10665629> (2026년 8월 2일 접속)
15. 헤럴드경제. (2026b, 3월 31일). 한컴인스페이스 초분광 위성 '세종 3호', 지상국 교신 성공.
<https://biz.heraldcorp.com/article/10706270> (2026년 8월 2일 접속)

1.3

산림 전용 대형언어모델(ForestGPT)과 지능형 의사결정 지원

강원도의 한 지역 산림조합 사무실, 오후 세 시가 조금 넘은 시각입니다. 창밖으로 늦여름 햇살이 비스듬히 들어오고, 담당자 책상 위에는 산림자원법 시행규칙 책자와 귀퉁이가 닳은 임업 편람이 나란히 펼쳐져 있습니다. 오늘 오전에만 소나무재선충병 방제구역에서 벌목한 고사목을 마을 공터에 임시로 쌓아 뒀는지 묻는 전화가 세 통 걸려 왔습니다. 법령집 색인을 넘기고, 편람 부록을 뒤지고, 지난해 공문 파일까지 열어 봐도 정확한 답은 나오지 않습니다. 결국 담당자는 편람을 덮고 컴퓨터 화면의 검색창에 질문을 그대로 입력합니다. 소나무재선충병 고사목은 훈증 처리를 어디에서 마쳐야 하는가.

이런 질문을 인공지능 챗봇에 던져 보는 사람이 늘고 있습니다. 거대한 글 뭉치를 학습해 사람처럼 문장을 만들어 내는 대형언어모델(LLM, Large Language Model)은 이제 웬만한 질문에 막힘없이 대답합니다. 문제는 답이 틀렸을 때 벌어집니다. 챗지피티(ChatGPT)나 클로드(Claude) 같은 범용 모델은 인터넷에 떠도는 방대한 글을 익혔지만, 산림 법규나 임업 시방서처럼 좁고 전문적인 문서는 상대적으로 적게 읽었습니다. 그러다 보니 산림 관련 질문을 받으면 건설이나 일반 공학 분야에서 배운 지식을 끌어와 그럴 듯하게 짜맞춘 답을 내놓는 일이 벌어집니다. 모델이 없는 사실을 있는 것처럼 지어내는 이런 현상을 환각(Hallucination)이라고 부릅니다. 자신 있는 표정으로 거짓말을 하는 사람과 닮았습니다. 산림 현장에서 환각은 가벼운 해프닝으로 끝나지 않습니다.

훈증 기준을 잘못 안내받은 담당자가 고사목을 엉뚱하게 처리하면 재선충이 이웃 산림으로 번질 수 있고, 경사도 기준을 잘못 안내받은 채 벌목을 진행하면 장마철 산사태로 이어질 수 있습니다.

임업 공학 전반에 인공지능이 번지는 흐름을 정리한 학술지 커런트 포레스트리 리포트(Current Forestry Reports)의 2026년 체계적 문헌 검토에서 포르쿠오(Forkuo)와 동료들은, 이 흐름이 센서와 위성 사진 같은 정형 데이터 처리를 넘어 법규와 지침, 보고서 같은 비정형 문서 처리로 번지고 있다고 짚습니다. 정형 데이터를 다루는 인공지능은 산림 면적이나 나무 높이처럼 숫자로 딱 떨어지는 값을 계산하지만, 비정형 문서를 다루는 인공지능은 문장을 읽고 맥락을 헤아려야 합니다. 후자가 훨씬 까다롭습니다.

이 틈을 메우려는 시도가 산림 전용 대형언어모델, 줄여서 포레스트지피티(ForestGPT)입니다. 오스트리아 연구진 에를리히-솜머(Ehrlich-Sommer)와 에버하르트(Eberhard), 홀칭거(Holzinger)가 2025년 학술지 일렉트로닉스(Electronics)에 발표한 논문은 이 모델을 산림 전문가 결을 지키되 마지막 판단은 사람에게 맡기는 조수로 그림니다. 연구진은 개발 경로를 네 단계로 제안했습니다. 산림 자료를 읽는 대화형 도구에서 시작해 검색 증강 생성, 생장 시뮬레이터, 현장 센서 연결로 나아가는 구상입니다. 2025년 후타 엑스포(Futa Expo)에서 시험한 것은 약 1메가바이트의 선별 자료로 방문객을 안내하는 1단계 다국어 챗봇이었습니다. 검색 증강 생성과 시뮬레이터, 센서 결합은 아직 로드맵에 놓여 있습니다.

한국에서도 비슷한 흐름이 시작됐습니다. 국립산림과학원은 산림 빅데이터와 인공지능을 결합하는 첫 경진대회를 열고 7개 팀을 시상했습니다. 딥러닝과 생성형 인공지능, 스스로 판단하고 움직이는 에이전트(Agent) 기술을 산림 정책과 현장 서비스에 붙이려는 실험이 대학과 스타트업으로 번지고 있습니다.

법을 대신 찾아 읽는 조수

포레스트지피티 같은 산림 특화 모델이 쓰는 기술은 크게 두 가지로 나뉩니다. 하나는 베이스 모델 내부의 가중치 자체를 다시 훈련하는 파인튜닝(Fine-tuning)이고, 다른 하나는 모델 가중치는 그대로 둔 채 질문을 던질 때마다 관련 법규와 지침 문서를 함께 넣어 주는 검색 증강 생성(RAG, Retrieval-Augmented Generation)입니다. 산림 도메인에서는 후자가 널리 쓰입니다. 법규는 자주 바뀌는데 모델을 통째로 다시 훈련하려면 시간과 비용이 크게 들기 때문입니다. RAG 방식에서는 질문이 들어오면 모델이 먼저 관련 문서 창고를 뒤져 근거가 될 조항을 찾고, 그 조항을 인용하면서 답을 만듭니다. 근거 문서를 찾지 못하면 답을 지어내는 대신 모른다고 답하도록 설계하는 방식이 환각을 막는 실질적인 방법으로 굳어졌습니다.

유럽연합의 포레스트포유(FOREST4EU) 프로젝트가 만든 대화형 에이전트 팜 어시스턴트(Farm Assistant)가 이 원리를 보여 주는 사례입니다. 농가와 임가의 지식을 모아 둔 데이터베이스 팜북(FarmBook)과 이어져 있어서, 산불을 막는 방목 형태나 바이오매스를 줄이는 방법을 물으면 근거가 된 자료 번호를 붙여 답합니다. 반대로 외부 정치인의 발언처럼 데이터베이스에 없는 내용을 물으면, 답을 지어내지 않고 해당 정보를 갖고 있지 않다고 잘라 말합니다. 아르메니아에서는 미국 아르메니아대학교(AUA) 아코피안 환경센터와 스위스 산림·농경 연구소(WSL)가 손잡고, 기후변화 영향 평가와 국가 보고서를 쓰는 정책 담당자를 돕는 대화형 챗봇을 만들었습니다. 산림 과학 배경지식이 부족한 공무원도 이 챗봇의 자문을 받으며 재조림 계획을 세우고 탄소 흡수원을 계산할 수 있습니다.

환각을 완전히 없애는 기술은 아직 나오지 않았습니다. 근거 문서를 검색해 답을 붙드는 RAG와 불확실성 추정, 자기일관성 검사, 답변 안전장치는 오류를 줄일 수 있지만 성능은 모델과 시험자료에 따라 달라집니다. 비료량이나 방제 시기처럼 잘못되면 그해 농사를 그르칠 수 있는 조언은 사람 전문가가 최종 확인해야 합니다. 벌채 허가나 훈증 기준처럼 틀리면 벌금이나 재산총 확산으로 이어지는 질문일수록, 모델의 답은 참고 자료일 뿐 최종 결재가 아니라는 선을 분명히 그어야 합니다.

위험한 현장을 지키는 조연자

법전 앞에서 머뭇거리던 사무실의 오후는 그나마 안전합니다. 산으로 들어간 벌목 노동자에게는 다른 위험이 기다리고 있습니다. 임업은 사고율이 높은 산업입니다. 나무가 넘어지는 방향을 착각하거나 경사면에서 기계톱을 쓰다가 미끄러지는 사고가 해마다 되풀이됩니다. 일본 긴키대학교(Kindai University) 연구진은 이 문제를 게임과 인공지능 자문 에이전트로 풀어 보려 했습니다. 챗지피티 기반 에이전트에 안전 지침과 전문 지식 카드를 미리 넣어 둔 뒤, 교육생이 현장 상황을 설명하면 에이전트가 위험 요소를 짚어 주는 방식입니다. 지식을 미리 넣어 주는 처리를 하기 전에는 1회차와 2회차를 합쳐 여덟 건의 오답과 문맥 이탈이 나왔습니다. 처리를 마친 뒤 3회차와 4회차를 합친 오답은 두 건으로 줄었습니다. 마흔 개 항목으로 이뤄진 안전행동척도 점수도 교육 전보다 눈에 띄게 올랐습니다.

현장에 음성으로 명령을 내리는 실험에서는 다른 종류의 문제가 드러났습니다. 보호복을 뜻하는 차프스(Chaps)나, 벌목한 나무가 다른 나무에 걸려 완전히 넘어지지 않은 상태를 가리키는 일본어 표현 가카리기(かかり木) 같은 임업 전용 용어가 자동음성인식(ASR, Automatic Speech Recognition) 단계에서 엉뚱한 낱말로 잘못 옮겨졌습니다. 잘못 옮겨진 낱말은 사람의 말과 글을 컴퓨터가 이해하도록 처리하는 다음 단계, 자연어처리(NLP, Natural Language Processing) 기술로 그대로 넘어가 문맥에서 벗어난 답을 더 키웠습니다. 소음이 크고 신호가 끊기기 쉬운 산속에서는 흔히 벌어지는 일입니다. 연구진은 전문용어 사전을 따로 만들어 붙이고, 인식된 문장을 한 번 더 사람이 확인하는 절차를 넣는 방법을 해법으로 제안했습니다.

눈으로 보는 감시에서는 다른 접근법이 쓰입니다. 쿤두(Kundu)와 동료 연구진이 2025년 사이언티픽 리포트(Scientific Reports)에 발표한 연구는 물체 탐지 모델 YOLOv8과 LangChain 기반 에이전트를 이어 붙였습니다. 드론과 위성 사진에서 그루터기나 벌목 기계, 허가받지 않은 인원을 찾아 산림파괴 의심 구역을 GIS 보고서로 정리하는 구조입니다. 훈련 손실은 줄었고 최대 재현율은 0.24였지만, mAP50은 약 0.07에 머물렀습니다. 작은 그루터기와 장비를 안정적으로 찾는 현장 시스템으로 보기에는 성능이 낮아, 사람의 재확인이 필요합니다.

얼마나 베고 어디로 나을까

지능형 의사결정 지원 시스템(DSS, Decision Support System)은 여러 조건을 한꺼번에 계산해 선택지를 비교하는 도구입니다. 산림 경영에서는 목재 생산과 작업자 안전, 토양 침식, 탄소 저장이 한 계획 안에서 부딪힙니다. 에버하르트(Eberhard)와 동료들은 2025년 프리프린트에서 경사와 토양 침식 위험, 남은 나무의 손상을 함께 따져 케이블 야더와 포워더, 윈치 보조 장비를 비교하는 GIS 기반 모델을 제안했습니다. 동료심사를 마친 현장 운영 시스템은 아닙니다.

덩(Deng)과 펑(Feng)은 벌목한 나무를 실어 나르는 트럭의 배차와 경로 문제를 유전 알고리즘(Genetic Algorithm)으로 풀었습니다. 생물이 세대를 거듭하며 더 나은 형질을 남기는 과정을 흉내 낸 이 계산 방식은 여러 후보 경로를 만들어 겨루게 한 뒤, 살아남은 경로를 조금씩 바꿔 가며 최적의 배차표를 찾아냅니다. 괴르겐스(Görgens)와 동료들은 이보다 앞서 작업로가 흙을 짓밟는 정도를 억누르면서 벌목량은 늘리는 다목적 최적화 계획 알고리즘을 세운 바 있습니다.

산림 경영의 성과를 돈으로만 재지 않고 여러 잣대로 함께 재려는 시도도 있습니다. 투입한 자원과 거기서 나온 성과의 비율을 계산해 효율이 높은 산림 경영 단위와 그렇지 못한 단위를 가려내는 통계 기법을 자료포섭분석(DEA, Data Envelopment Analysis)이라고 부릅니다. 지난 30년 동안 쌓인 산림 분야 DEA 연구를 훑은 자드미르자에이(Zadmirzaei)와 동료들의 2026년 리뷰 논문에 따르면, 최근 DEA는 인공지능과 빠르게 손을 잡고 있습니다.

입력 변수를 고를 때는 무작위 숲(Random Forest) 알고리즘으로 핵심 요인을 추려내고, 신경망으로 효율성 점수를 예측하며, 운영 효율성과 목재 수익, 환경 보전, 탄소 고정이 라는 서로 다른 목표를 한꺼번에 최적화하는 유전 알고리즘 계열 기법인 엔에스지이에이투(NSGA-II)를 DEA와 묶어 구체적인 정책 시나리오를 뽑아내는 연구가 늘고 있습니다.

장기 예측에서는 국가 단위 통계가 힘을 발휘합니다. 탄자니아의 국가산림자원조사(NAFORMA) 데이터를 기계학습과 연결해 2054년까지 산림 면적 변화를 내다본 연구가 그 예입니다. 2014년 4,809만 헥타르였던 산림과 우드랜드 면적은 기존 개발 추세를 그대로 두는 시나리오에서 3,299만 헥타르로 줄어듭니다. 개발 압력이 큰 시나리오에서는 2,830만 헥타르까지 떨어집니다. 반면 지속가능한 관리를 적용하는 시나리오에서는 감소 폭이 눈에 띄게 줄어드는 것으로 나타나, 정책 결정에 쓸 수 있는 정량적 근거를 보여 줍니다.

나무와 작물을 함께 기르는 산림농업(Agroforestry)에서도 계산이 파고듭니다. 인도네시아의 리들로(Ridlo)와 동료들은 커피나무 사이에 그늘을 만드는 차음수를 어디에 심어야 습도와 이산화탄소 농도가 알맞게 유지되는지를 그래프 이론으로 풀었습니다. 격자 형태로 짠 밭 도면 위에 리즈(RIDS, Resolving Independent Dominating Sets)라는 그래프

알고리즘을 적용해 차음수를 심을 위치를 정하고, 스마트 센서로 모은 습도와 이산화탄소 데이터를 시공간 그래프 신경망(STGNN, Spatial-Temporal Graph Neural Network)에 넣어 앞으로 10일에서 20일 사이의 미기후 변화를 내다봤습니다. 커피나무 96그루에 차음수 26그루를 심은 구획은 연간 이산화탄소 520킬로그램을 붙잡아 두는 것으로 계산됐습니다.

격자형으로 차음수 31그루를 심은 구획은 연간 620킬로그램을 붙잡아 두는 것으로 계산됐습니다. 예측 오차를 나타내는 지표들은 기존 비교 모델보다 낮았고, 예측이 실제 값을 얼마나 설명하는지 보여 주는 설명력은 0.73에서 0.81 사이로 나와 다른 방식보다 나은 성능을 보였습니다.

확신에 찬 오답을 가려내는 법

연구 결과를 나란히 놓고 보면 서로 부딪히는 주장이 나옵니다. 챗지피티 같은 범용 대형 언어모델은 폭넓은 상식과 여러 언어를 넘나드는 유연함에서는 앞서지만, 산림 법규나 작업 안전 수칙처럼 좁고 전문적인 질문에서는 환각이 잦습니다. 반대로 근거 문서에 답을 붙들어 매는 RAG 기반 모델이나 포레스트지피티는 법규 질의의 정확도와 근거 제시력은 높은 대신, 지정된 지식 창고 밖의 질문에는 답을 거부하도록 설계되어 있어 자유롭게 대화하기는 어렵습니다. 정확함과 자유로움을 동시에 얻기는 아직 쉽지 않습니다.

계산 방식 사이에서도 같은 긴장이 나타납니다. 전통적인 DEA 모델은 효율성 점수가 어떤 계산을 거쳐 나왔는지 선형 수식으로 훤히 드러나 정책 담당자가 받아들이기 쉽습니다. 반면 딥러닝 기반 예측 모델은 정확도는 높은 대신 내부에서 무슨 계산이 오갔는지 들여다보기 어려운 블랙박스(Black-box)로 남습니다. 법적 근거로 인용해야 하는 정책 문서에는 이 불투명함이 걸림돌이 됩니다.

기술 바깥의 문제도 만만치 않습니다. 임업 자동화와 자율 판단 에이전트 도입은 빨라지는데, 산림 정책과 법 제도는 인공지능이 스스로 내린 판단에 누가 책임을 지는지를 아직 정리하지 못했습니다. 에이전트가 잘못된 안전 지침을 내놓아 사고가 나면, 현장 관리자와 개발사 가운데 누구 책임인지 가리기 어렵습니다. 스웨덴 연구진 베리크비스트(Bergqvist)와 동료들은 2026년 하와이 국제 시스템과학 학술대회(HICSS)에서, 임업 현장은 자료가 표준화된 다른 산업과 달리 기록 방식이 제각각이고 종이 문서가 여전히 많이 남아 있어 자동화보다 자료 정돈이 먼저라는 점을 짚었습니다. 벌채부터 가공과 유통까지 이어지는 자료가 기관마다 따로 쌓여 있는 데이터 사일로(Data Silo) 문제도 통합의 사결정을 더디게 만듭니다.

여기에 더해 대형언어모델과 시공간 그래프 신경망은 큰 그래픽 연산 자원을 요구하는데, 인터넷이 끊기기 쉬운 오지 산림 현장의 드론이나 휴대 기기에서는 연산이 늦어지고 저장 공간이 부족해지는 문제가 그대로 남아 있습니다.

앞으로 풀어야 할 숙제도 뚜렷합니다. SHAP이나 Grad-CAM처럼 모델이 왜 그런 판단을 내렸는지 보여 주는 설명 가능한 인공지능 기법을 의사결정 엔진에 붙여야 합니다. 산림 법규와 노동 안전 기준에 맞는 지침도 필요합니다. 양자화와 지식 증류로 모델을 줄인 뒤, LoRa 무선망이나 5G 기지국이 드문 산림에서 장치별 응답시간과 전력 소모를 시험해야 합니다. 국가와 지역을 넘나드는 산림 자료 공유 체계와 표준 벤치마크도 남은 과제입니다.

언어모델만 이런 흐름을 타는 것은 아닙니다. 지리공간 파운데이션 모델 프리트비(Prithvi)는 미국 항공우주국(NASA)과 아이비엠(IBM)이 함께 만들었습니다. 압축된 모델은 2026년 5월 호주 카니니(Kanyini) 위성과 국제우주정거장(ISS)의 IMAGIN-e 장비에서 작동했습니다. 궤도 시연이 처리한 임무는 홍수와 구름 탐지였습니다. 산림 높이와 벌채 흔적 분석은 지상에서 가능한 응용 분야로 제시됐으며, 이번 궤도 시험 결과와는 구분해야 합니다.

산림 현장에서 인공지능에 묻는 질문은 갈수록 늘어나겠지만, 그 답 뒤에 어떤 문서가 근거로 붙어 있는지 확인하는 일은 당분간 사람이 직접 맡아야 할 것으로 보입니다. 모델은 법규를 요약하고 위험을 미리 짚고 트럭의 경로를 계산하는 데까지 와 있습니다. 다만 혁신에 찬 문장 하나가 실제로는 틀린 답일 수 있다는 사실은 바뀌지 않았습니다. 결재란에는 여전히 사람의 서명이 들어갑니다.

근거 및 참고문헌

1. AUA Acopian Center for the Environment, & WSL. (2026, 7월). A validated predictive framework: Climate-smart reforestation and resilience mapping in Armenia [Video]. YouTube. <https://www.youtube.com/watch?v=LBq1KNUUyE> (2026년 8월 2일 접속)
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. (2025, 11월). Webinar: Exploring the role of knowledge repositories: Farm Assistant chatbot demo [Video]. YouTube. <https://www.youtube.com/watch?v=slRhC5sfbjA> (2026년 8월 2일 접속)
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. Zadmiraie, 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. 대한민국 정책브리핑. (2026, 7월 24일). 산림현안, AI로 도전...국립산림과학원, 경진대회 개최. <https://www.korea.kr/briefing/pressReleaseView.do?newsId=156751645> (2026년 8월 2일 접속)

제2장

정밀 임업(Precision Forestry): 단목 해석 및 바이오매스·탄소 정밀 측정

2.1

UAV-LiDAR 및 고해상도 영상 기반 단목 (Individual Tree) 수종 분류

안개가 채 걷히지 않은 새벽, 강원도 산기슭의 잣나무 조림지 위로 드론 한 대가 낮게 떠 있습니다. 프로펠러 소리가 골짜기를 타고 흩어지고, 드론은 발을 가는 트랙터처럼 바둑판 모양으로 하늘을 왕복합니다. 기체 아래에는 라이다(LiDAR, Light Detection and Ranging)가 매달려 있습니다. 초당 수십만 번씩 레이저를 쏘고, 그 빛이 나뭇잎과 가지에 부딪혀 되돌아오는 시간을 재서 거리를 계산하는 장치입니다. 드론이 한 번 지나갈 때마다 잣나무 수천 그루의 윤곽이 점 하나하나로 하늘에서 찍힙니다. 이 점을 다 모으면 숲 전체가 아니라 나무 한 그루가 선 위치와 키, 가지 뻗은 모양까지 드러냅니다.

임업은 오랫동안 숲을 임분(Stand), 그러니까 나무가 모여 있는 덩어리 단위로 관리해 왔습니다. 한 구역에 소나무가 몇 그루쯤 있는지, 평균 키는 얼마인지를 어림잡아 계산하는 식이었습니다. 정밀 임업은 이 계산 단위를 나무 한 그루로 끌어내립니다. 나무 하나하나가 어디에 서 있는지 짚어내는 일을 단목 검출(Individual Tree Detection, ITD)이라 부르고, 그 나무의 잎과 가지가 차지하는 영역만 오려내는 일을 단목 수관 분할(Individual Tree Crown Delineation, ITCD)이라 부릅니다. 예전에는 사람이 직접 산을 오르며 줄자와 눈대중으로 나무를 세거나, 유역 분할(Watershed Segmentation)이라는 방식으로 항공사진에서 밝기가 낮아지는 경계를 찾아 나무를 갈랐습니다.

나뭇가지가 하늘을 빈틈없이 가릴 만큼 빽빽한 숲이나 여러 수종이 뒤섞여 자라는 혼효림에서는 이 방법이 자주 틀렸습니다. 붙어 있는 두 나무를 하나로 묶어버리는 과소 분할, 가지 하나를 다른 나무로 잘못 나누는 과대 분할이 되풀이됐습니다.

이런 한계를 넘어서려고 무인항공기 레이저 스캐닝(UAV-LiDAR)이 만드는 3차원 점군(Point Cloud, 레이저가 되돌아와 찍힌 점 수백만 개를 모은 데이터)과 고해상도 영상을 컴퓨터 비전 딥러닝과 묶는 연구가 빠르게 늘고 있습니다. 한국에서도 비슷한 조합이 이미 현장에 들어와 있습니다. 산림청은 2025년 9월, 소나무재선충병이 다시 번지자 헬기와 드론 조사에 인공지능과 라이다 기술을 결합해 감염이 의심되는 소나무를 자동으로 골라내는 체계를 발표했습니다. 사람이 산을 타며 나무를 하나하나 살피던 일을, 하늘에서 찍은 점군과 영상이 대신 걸러내는 셈입니다. 다만 이 작업은 병든 나무를 찾아내는 선별 단계이고, 나무 종류 자체를 구별하는 수종 분류와는 다른 목적을 가지고 있습니다.

나무 한 그루의 윤곽을 그리는 딥러닝

실시간 물체 탐지 알고리즘인 옴로(YOLO, You Only Look Once) 계열은 사진을 한 번 훑어 물체의 위치와 종류를 함께 찾아내는 구조입니다. 계산이 빨라 수관 검출에도 쓰입니다. 베트남 동나이(Dong Nai) 지역의 카시아소나무(Pinus kesiya) 인공림에서 응우옌 타인 뚜언(Nguyen Thanh Tuan) 연구진은 UAV-LiDAR와 고해상도 항공사진을 겹쳐 YOLOv8m-Seg, YOLOv11m-Seg, YOLOv12m과 범용 분할 모델 SAM2를 비교했습니다. 원 SAM은 약 1,100만 이미지와 10억 개가 넘는 분할 마스크로 학습됐고, SAM2는 대규모 영상 자료로 확장된 모델입니다.

YOLOv11m-Seg는 나무 탐지에서 mAP50 0.62, F1 점수 0.59를 기록했습니다. YOLOv12m과 SAM2를 묶은 모델, YOLOv8m-Seg는 이 수치에 미치지 못했습니다. 소나무 수관이 뺄뺄하게 겹치는 구역에서는 현장 자료로 훈련한 모델이 범용 분할 모델보다 나았습니다. 이 경계와 라이다 점군을 겹쳐 실측값과 비교했을 때 나무 키 추정의 설명력은 0.85에서 0.93 사이였습니다. 수관 폭 추정의 설명력은 0.58에서 0.86 사이였습니다. 한 지역의 조림지에서 얻은 결과라 다른 수종과 천연림에는 다시 검증해야 합니다.

위성 영상과 항공사진을 함께 쓰는 다른 연구팀은 옴로v5와 밀도 추정 신경망(Faster R-CNN 계열)을 묶은 BRO 하이브리드 모델을 내놓았습니다. 배틀로얄 최적화(Battle Royal Optimisation)라는 탐색 기법으로 다중 스케일 업샘플링을 조정해, 나무가 등성등성 서 있거나 뺄뺄하게 몰려 있는 구간을 가리지 않고 나무 숫자를 세도록 설계했습니다. 이 모델은 나무 개수 추정 정확도 97.8퍼센트, 평균 오차(MAE) 0.0912를 기록했습니다.

수관의 미세한 곡선을 그리는 데는 유넷(U-Net) 계열 신경망도 널리 쓰입니다. 그림을 작게 압축했다가 다시 원래 크기로 복원하면서 세부 윤곽을 되살리는 구조인데, 압축 전 정보를 건너뛰어 전달하는 스킵 연결(Skip Connection) 덕분에 나뭇가지처럼 가는 경계도 뭉개지지 않습니다. 중국 안후이성 지시(績溪)와 광시성의 아열대 혼합림에서 왕린롱(Wang Linlong) 연구진이 MTSCFNet을 개발했습니다. 입력 자료는 DJI M300 RTK에 젠뮤즈 P1을 단 UAV-RGB 카메라 영상입니다. RIEGL miniVUX-1 UAV로 모은 라이다 점군과 중국 GF-2 위성 영상도 함께 받습니다. 라이다 점의 밀도는 1제곱미터당 87.14 개였습니다.

인코더를 세 개로 나눠 데이터를 따로 처리한 뒤 합치는 삼중 분기 특징 융합(Triple Branch Feature Fusion) 모듈을 더해, 센서 하나만 쓰는 모델보다 수관 구역 분할과 수종 분류 양쪽 모두에서 겹침 정확도 지표가 올라갔습니다.

높은 해상도의 가시광선 정사영상만으로 뺄뺄한 수관을 갈라내려는 시도도 있습니다. FSC-Mask2Former라는 이름의 이 방법은 가로세로 512픽셀 크기로 자른 사진 958장을 학습에 썼습니다. 그 사진마다 나무 7,636그루의 윤곽을 정밀하게 그려 넣은 정답 데이터를 붙였습니다. 사진의 질감 정보에 더해 주파수 영역(Frequency Domain, 색과 밝

기가 얼마나 자주 반복되는 무늬로 나타나는지를 보는 방식)에서 뽑아낸 특징과 대조 학습(Contrastive Learning, 비슷한 나무끼리는 가깝게, 다른 나무끼리는 멀게 배우는 훈련 방식)을 함께 적용해, 잎이 뺄뻣한 혼합림에서 나무 경계를 가르는 오차를 눈에 띄게 줄였습니다.

3차원 점군을 점 하나하나 단위로 직접 처리하는 신경망 가운데는 포인트 트랜스포머 브이3(Point Transformer V3, PTV3)가 있습니다. 문장 속 단어 사이의 관계를 살피던 셀프 어텐션(Self-attention, 데이터의 각 부분이 서로 얼마나 관련 있는지 스스로 계산하는 방식)을 3차원 나무 구조에 옮겨 적용한 모델입니다. 세 개 파장 대역을 쏘는 멀티스펙트럼 라이다로 찍은 점군을 PTV3, KPConv, 슈퍼포인트 트랜스포머(SPT), 랜덤 포레스트 네 가지 모델에 넣어 숲을 지표면, 키 작은 식생, 나무 몸통, 가지, 잎, 나무 부스러기까지 여섯 층으로 나눈 연구가 있습니다. 이 비교에서 PTV3는 겹침 정확도(mIoU) 69.1퍼센트를 기록해 나머지 3차원 모델보다 21.8퍼센트포인트 앞섰습니다.

2026년 1월에 나온 관련 메타 분석은 이런 흐름을 숫자로도 보여줍니다. 알다에리(Aldaeri) 연구진이 단목 검출 논문들을 모아 살펴보니, 나무를 날개로 오려내는 인스턴스 세그멘테이션 방식이 전체의 46퍼센트가량을 차지했고, 입력 데이터로는 일반 RGB 항공사진을 쓴 연구가 73퍼센트로 제일 많았습니다. 라이다 단독보다 사진과 수관 고도 모델(Canopy Height Model, CHM, 나무 꼭대기 높이를 지도처럼 펼친 데이터)을 함께 쓰는 조합이 흔하다는 뜻입니다.

섞여 자라는 숲에서 나무 이름 가려내기

수관을 날개로 오려낸 다음에는 그 안의 색깔과 질감, 3차원 굴곡을 보고 구체적으로 어떤 나무인지 알아내는 단계로 넘어갑니다. 위쪽 큰키나무와 아래쪽 관목의 반사광이 뒤섞이고, 나무마다 표본 숫자가 들쭉날쭉하고, 희귀한 나무는 사진 자체가 몇 장 안 되는 혼합림에서는 이 작업이 까다롭습니다.

유럽에서 만든 다중 센서 벤치마크 데이터셋 TreeSatAI(주요 수종 15개 포함)로 UAV 항공사진과 센티넬(Sentinel) 위성 영상을 함께 분석한 MMTSC(Multi-branch Multi-label Tree Species Classification) 연구를 친텐이(Qin Tianyi)와 자오칭젠(Zhao Qingjian)이 2025년 사이언티픽 리포트(Scientific Reports)에 발표했습니다. 이들은 나무 종류를 가려내는 인공지능의 뼈대 신경망으로 덴스넷121(DenseNet121), 이피션트 넷(EfficientNet-B0), 콘브넥스트(ConvNeXt-Tiny) 등 여섯 가지를 나란히 비교했습니다. 표본 수가 나무마다 크게 차이 나는 조건에서도 덴스넷121을 뼈대로 쓴 모델의 성적이 다른 다섯 뼈대보다 나았습니다.

F1 점수는 72퍼센트가량이었고, 정밀도(Precision)는 82퍼센트가량이었습니다.

말레이시아 보르네오섬의 데라마코트(Deramakot)와 탕쿨랍(Tangkulap) 산림경영구역(FMU)에서는 딥포레스트(DeepForest, DF 스캐너 프로)와 이피션트넷-B4(EfficientNet-B4) 신경망을 써서 열대우림에서 큰 키로 웃자라는 용뇌향과(Dipterocarpaceae) 나무와 그 밖의 나무를 가려냈습니다. 용뇌향과 나무를 실제로 맞힌 비율(Producer's Accuracy)은 0.71, 인공지능이 용뇌향과라고 답한 것 가운데 실제로 맞은 비율(User's Accuracy)은 0.67이었습니다. 이렇게 가려낸 나무 종류 정보를 위성 기반 머신러닝 모델의 학습 재료로 더하면, 지상부 탄소(AGC, Above-Ground Carbon) 추정치의 오차가 줄어듭니다.

위성 사진만 쓴 모델의 오차(RMSE)는 헥타르당 70.60메가그램이었지만, 드론으로 확인한 나무 종류 정보를 더하자 오차가 헥타르당 60.53메가그램까지 떨어졌습니다.

2026년 1월 사이언티픽 리포트에 실린 고마쓰 고타로(Komatsu Kotaro) 연구진의 논문은 더 넓은 지역에서도 비슷한 흐름을 확인해 줍니다. 말레이시아와 인도네시아 395개 조사구를 놓고 위성 지표만으로 탄소량과 생물다양성 지수를 추정했을 때 설명력은 0.43과 0.46에 머물렀습니다. 드론 영상 자료 934건을 더하자 설명력은 0.51과 0.48로 올라갔습니다. 드론이 찍은 나무 하나하나의 정보가 위성 사진의 거친 눈금을 촘촘하게 채워주는 셈입니다.

혼합림에는 표본이 극단적으로 적은 희귀 수종이 섞여 있어서, 혼한 손실 함수(모델이 얼마나 틀렸는지 계산하는 방법)를 그대로 쓰면 개체 수가 많은 나무 쪽으로 예측이 쏠립니다. 이런 쏠림을 바로잡으려고 나온 M-MoENet(Multimodal Sparse Mixture-of-Experts Network)은 광학 영상, 센티널-1 위성 레이더(SAR), 지형 고도 데이터(DEM)를 함께 입력받고, 인코더 안에 소수 수종을 전담하는 전문가 소모델을 여러 개 끼워 넣습니다. 예측에 확신이 낮을 때는 이 전문가들에게 판단을 넘기는 신뢰도 게이팅(Confidence-adjusted Gating) 방식도 함께 씁니다. 러우(Lou) 연구진이 보고한 결과에 따르면 전체 정확도(OA)는 79.46퍼센트, 겹침 정확도(mIoU)는 60.08퍼센트, 카파(Kappa) 계수는 0.74였습니다.

표본이 적은 상록송이나 피나무 같은 나무가 지도에서 사라지거나 뜬문뜬문 끊겨 나타나는 문제도 크게 줄었습니다.

키프로스(Cyprus)의 주요 수종 9개를 분류한 연구는 다른 해법을 보여줍니다. ResNet50을 뼈대로 쓰되, 모델이 매긴 잠정 정답으로 학습을 보충하는 약지도 학습을 결합했습니다. RGB와 근적외선, 지형, 토양 자료를 넣은 모델은 전체 정확도 90퍼센트를 기록했습니다. 라벨 비용을 절반 넘게 줄였다는 수치는 연구에서 직접 측정하지 않았습니다.

연구마다 다르게 나오는 숫자들

수관 분할과 수종 분류 기술은 실험마다 꽤 정밀한 수치를 내놓지만, 수종 구조와 센서 조합에 따라 결과가 서로 어긋나는 경우도 뚜렷합니다. 원뿔 모양이 뚜렷한 소나무류 (Pinus kesiya, Pinus taeda) 같은 침엽수 단일림에서는 옴로v11m-세그나 수관 고도 모델 기반 분할 모델이 설명력 0.85에서 0.93에 이르는 높은 수고 추정 정확도를 보입니다. 반면 잎이 넓게 퍼지고 가지가 서로 얹히며 죽은 가지도 섞여 있는 아열대·열대 활엽 혼효림에서는 같은 옴로 계열이나 마스크 R-CNN(Mask R-CNN) 모델을 쓰더라도 수관 폭 추정의 설명력이 0.58에서 0.68로 떨어집니다. 나무 모양 자체가 반듯한지 아닌지가 인공지능의 정확도를 갈라놓는 셈입니다.

기초 모델과 도메인 전용 모델의 순위가 뒤집히는 경우도 있습니다. 대규모 이미지와 영상 자료로 훈련된 SAM2는 여러 물체의 윤곽을 나눌 수 있지만, 나뭇가지가 겹치는 숲에서는 임업 자료로 훈련한 YOLOv11m-Seg보다 오탐이 잦았습니다. 거대한 범용 모델도 현장에 맞춘 미세 조정을 대신하지 못합니다.

하늘에서 농치는 것들

드론을 아무리 정밀하게 날려도 하늘에서는 보이지 않는 데가 있습니다. 상공의 광학 카메라와 라이다 신호는 잎이 뽁뽁하게 하늘을 가린 숲의 아래쪽, 중간층과 하층 나무까지 뚫고 들어가지 못합니다. 그러다 보니 키 작은 나무가 위에 있는 큰 나무의 수관으로 잘못 묶이는 오류가 반복해서 나타납니다.

딥러닝 모델을 학습시키려면 나무마다 2차원 또는 3차원 윤곽을 정밀하게 그려 넣은 정답 데이터가 있어야 합니다. 그런데 잎이 뽁뽁한 숲에서는 오랜 경력의 현장 전문가조차 어디까지가 한 나무의 수관인지 사람마다 다르게 판단합니다. 이 판단 차이가 그대로 라벨링 노이즈(Annotation Noise)로 남아 모델 학습에 섞여 들어갑니다. 정밀한 정답 데이터를 만드는 일이 알고리즘을 설계하는 일 못지않게 손이 많이 가는 작업이라는 뜻입니다.

지역을 옮기면 정확도가 떨어지는 문제도 있습니다. 특정 숲에서 높은 점수를 낸 수종 분류 모델도 지형과 햇빛, 수종 구성이 다른 숲에서는 성능이 낮아질 수 있습니다. 하락 폭은 자료와 평가 지표마다 달라 하나의 범위로 묶을 수 없습니다.

다음 단계로 남은 과제

이런 틈을 메우려는 시도는 이미 시작됐습니다. 제로샷 기초 모델 SAM2에 UAV-LiDAR가 만든 3차원 수관 고도 모델 정보를 층층이 얹어 임업 데이터로 다시 훈련시키는 하이브리드 미세 조정 연구가 이어지고 있습니다. 범용성과 정밀도를 동시에 잡으려는 시도입니다. M-MoENet이나 FSC-Mask2Former처럼 주파수 성분 분해, 대조 학습, 여러 전문가 소모델을 섞는 게이팅 알고리즘을 다듬어 희귀 수종을 자동으로 알아보는 능력을 끌어올리는 연구도 진행 중입니다.

2026년 5월 *GIScience & Remote Sensing*에 실린 왕신보(Wang Xinbo) 연구진의 Crown-BERT는 이 방향의 최근 사례입니다. 수관마다 모양이 다른 점을 반영해 유효한 수관 영역만 가려내는 동적 수관 마스킹(Dynamic Crown Masking)과 수관 안의 위치 정보를 심는 수관 위치 인코딩(Crown Positional Encoding)을 더하고, 라벨이 없는 수관 샘플로도 미리 훈련할 수 있는 자기지도 학습(Self-supervised Learning) 단계를 끼워 넣었습니다. 정답 라벨이 부족한 희귀 수종에서도 쓸 만한 특징을 뽑아내려는 접근입니다.

TreeSatAI, PureForest, ForInstance처럼 여러 생태계를 아우르는 3차원·2차원 단목 벤치마크 데이터셋을 넓혀서 공유하는 작업도 이어져야 합니다. 대륙과 수종에 따라 모델 성능이 크게 갈리는 지금 상황에서는, 데이터셋 자체를 넓히는 일이 알고리즘을 다듬는 일 못지않게 큰 비중을 차지합니다.

근거 및 참고문헌

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.jssn.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> (2026년 8월 2일 접속)
13. 디지털타임스. (2025, 9월 24일). AI·라이다 등 첨단기술 활용... 소나무재선충병 확산 막는다. <https://www.dt.co.kr/article/12019894> (2026년 8월 2일 접속)

2.2

지상부 바이오매스(AGB) 및 산림 탄소 축적량 추정

나무 한 그루의 건중량을 직접 확인하려면 톱을 들고 밑동을 베어 넘어뜨린 뒤, 가지와 줄기와 잎을 나눠 무게를 재고 가마에서 물기를 날립니다. 이런 파괴적 직접 측정은 상대성장식을 만들 기준값을 얻는 데 쓰였습니다. 숲 전체의 바이오매스는 오래전부터 가슴높이 지름과 수고, 목재밀도에 기반 상대성장식으로 추정해 왔습니다. 보호구역에서 나무를 베지 않고도 무게를 계산할 수 있었지만, 식의 지역과 수종이 달라지면 오차가 커졌습니다.

나무 무게를 알고 싶어 한 데는 이유가 있습니다. 통나무를 시장에 내놓아 값을 매기려면 부피와 무게를 알아야 했고, 벌목과 측정은 오랫동안 한 몸처럼 붙어 다녔습니다. 그런데 나무를 베지 않고도 무게를 짐작하는 길이 있습니다. 줄기 굵기와 키만 재고, 거기에 수종별로 정해진 계산식 하나를 통과시키면 됩니다.

사람 가슴 높이에서 잰 줄기 지름을 가슴높이지름(Diameter at Breast Height, DBH)이라 부릅니다. 여기에 수고와 목재밀도, 수종·지역 계수를 넣어 나무의 부피와 무게를 추정하는 식이 상대성장 모형(Allometric Model)입니다. 굵기와 키의 관계는 생육단계와 환경에 따라 달라져 일정한 비례로 고정되지 않습니다. 나무가 자라며 줄기와 가지에 쌓은 탄소를 짐작하려면 이런 오차까지 계산에 넣어야 합니다. 지상부 바이오매스(Aboveground Biomass, AGB)의 정밀도는 국가 탄소계정과 탄소시장 수치에 곧바로 영향을 줍니다.

그런데 DBH와 수고를 손으로 재는 일도 만만치 않습니다. 조사원이 줄자로 줄기 둘레를 재고, 측고기라는 각도 측정 도구로 나무 꼭대기를 올려다본 각도를 잰 뒤 삼각법으로 키를 계산하는 방식은 나무 한 그루당 몇 분씩 걸립니다. 숲 하나를 다 재려면 조사원 여러 명이 며칠씩, 때로는 몇 주씩 매달려야 하고, 사람마다 줄기를 어디서부터 어디까지로 볼지 판단이 다르다 보니 오차도 끼어듭니다. 최근 몇 년 사이 산림 조사의 무게중심은 줄자 대신 레이저와 카메라로, 조사원의 두 다리 대신 드론과 인공위성으로 옮겨 가고 있습니다.

지상 레이저와 드론이 나무를 읽는 법

지상 레이저 스캐너(Terrestrial Laser Scanner, TLS)는 나무 둘레를 돌며 빛을 수없이 쏘고, 그 빛이 되돌아오는 시간을 재서 수백만 개의 점으로 이루어진 입체 지도를 그려냅니다. 이 점들의 모음을 점군(Point Cloud)이라 부릅니다. 스캐너를 여러 곳으로 옮겨 가며 찍는 다중 스캔 방식은 나무 뒷면까지 빠짐없이 담아내지만, 스캐너를 옮기고 각 스캔을 하나로 이어 붙이는 데 시간이 많이 듭니다. 조사할 나무가 수백 그루라면 하루 안에 끝내기 어렵습니다. 반대로 한곳에 서서 한 번만 스캔하는 단일 스캔 방식은 몇 분이면 끝나지만, 나무 뒤쪽이 다른 줄기나 가지에 가려 점 데이터가 듬성듬성 비어 버립니다.

미국 인디애나주의 마텔 산림(Martell Forest)에서는 서른일곱 개 수종이 뒤섞인 온대 활엽수림을 대상으로 단일 스캔 TLS와 CoAtNet을 결합했습니다. 정답값은 현장에서 잰 DBH에 북미 범용 상대성장식을 대입해 계산했습니다. 시험 나무 60그루에서 결정계수는 0.73이었습니다. 중앙 백분율 편향은 0.99퍼센트였지만 중앙 절대백분율오차는 25.06퍼센트, 평균 절대백분율오차는 29.40퍼센트였습니다. 편향이 작다는 사실을 개별 나무의 오차가 1퍼센트 미만이라는 뜻으로 읽어서는 안 됩니다.

하늘에서 내려다보는 방법도 있습니다. 드론이 찍은 사진을 이어 붙여 왜곡을 바로잡은 지도를 정사영상(Orthophoto)이라 부르는데, 위성사진보다 훨씬 가까워서 찍다 보니 나뭇가지 하나하나가 뚜렷하게 잡힙니다. 말레이시아 사바주의 데라마코트와 탕쿨랍 열대우림에서는 드론으로 찍은 RGB 정사영상과 EfficientNet-B4라는 딥러닝 모델을 결합해 용뇌향과(Dipterocarpaceae) 나무의 수관, 그러니까 가지와 잎이 우산처럼 펼쳐진 나무 꼭대기를 인식하고, 여기에 열대림용 상대성장식을 적용해 탄소량을 추정했습니다. 현장 표본 없이 위성 영상만으로 돌린 기본 모델은 설명력이 0.43에 머물렀습니다. 드론으로 찍은 수관 구조 정보를 더한 모델은 설명력이 0.51로 올라갔고, 오차는 헥타르당 70.6톤에서 60.5톤 수준으로 줄었습니다.

유럽의 너도밤나무(*Fagus sylvatica*) 숲에서도 비슷한 시도가 있었습니다. 드론 레이저 스캐닝으로 수관의 입체 부피를 재고, 이 값을 기존의 DBH 단독 계산식에 얹었더니 바이오매스 추정 오차가 눈에 띄게 줄었습니다. 줄기 굵기 하나만 보던 계산식에 수관 부피 정보를 더한 셈이니, 성적이 나아진 것도 자연스러운 결과로 보입니다.

다만 상대성장식 자체에 약점이 있습니다. 북미나 열대림 전역에 쓰라고 만든 범용 공식은 특정 지역의 토양이 얼마나 기름진지, 그 지역 기후가 어떤지, 같은 수종이라도 자라는 곳마다 나무 모양이 어떻게 달라지는지를 다 담지 못합니다. 가문비나무 한 종류만 놓고 봐도, 비가 많이 오는 산비탈에서 자란 나무와 메마른 능선에서 자란 나무는 굵기가 같아도 속이 짙은 정도, 곧 목재 밀도가 다를 수 있습니다. 그래서 지역에 따라 한쪽으로 치우친 오차, 곧 계통적 편향이 생길 수 있습니다. 다행히 지도학습 방식의 딥러닝 모델은 나중에 그 지역에서 정밀하게 잰 상대성장 데이터가 모이면 재학습을 거쳐 이 치우침을 바

로잡을 여지가 있습니다. 처음부터 완벽한 공식을 찾기보다, 데이터를 계속 모아 고쳐 나가는 방식에 가깝습니다.

국가 산림조사와 위성 데이터를 잇다

레이저와 드론으로 개별 나무를 정밀하게 재는 기술이 아무리 좋아져도, 나라 전체의 숲을 나무 한 그루씩 이 방식으로 훑을 수는 없습니다. 숲이 넓은 나라일수록 나무의 숫자는 억 단위를 훌쩍 넘어섭니다. 드론 한 대가 하루에 살필 수 있는 면적에는 한계가 있지만, 인공위성은 그 한계를 단숨에 뛰어넘습니다. 나무 한 그루씩 잴 값이나 표본점 몇 곳의 데이터를 나라 전체 지도로 넓히려면 다른 접근이 필요합니다. 지상에서 실측한 국가 산림 자원 조사(National Forest Inventory, NFI) 데이터와, 넓은 지역을 한눈에 훑는 인공위성 원격탐사 데이터를 인공지능으로 엮는 작업입니다.

미국 코네티컷주의 온대 혼효림에서는 미국 산림청의 국가산림자원조사 표본점 백마흔두 곳의 자료에 Sentinel-1 위성의 레이더 신호와, Sentinel-2·Landsat 위성이 앞의 초록빛 반사 정도를 지수로 바꾼 식생 지수(NDVI 등), 그리고 GEDI라는 우주 탑재 레이저 고도계의 수고 자료를 겹쳐서 10미터 해상도의 바이오매스 지도를 만들었습니다. 여러 머신러닝 방법을 시험한 결과, GEDI가 잴 나무 높이와 Sentinel 위성의 식생 지수를 함께 넣었을 때 정확도가 제일 좋았습니다. 숲이 아닌 지역은 바이오매스 값을 0으로 놓고 걸러내어 표본의 잡음을 줄였습니다.

러시아 사할린섬의 관리림에서는 NFI 소반 조사 자료에 Sentinel-2 위성 영상의 시계열 변화와 지형 자료를 결합해 랜덤 포레스트, XGBoost, TabNet 세 가지 알고리즘을 겨루게 했습니다. 이 가운데 XGBoost, 그러니까 질문을 하나씩 던져 가지를 치듯 답을 좁혀가는 의사결정나무 여러 개를 순서대로 이어 붙이고 앞선 나무가 놓친 오차를 다음 나무가 줄여 가는 방식의 알고리즘이 제일 나은 성적을 냈습니다. 평균 절대 백분율 오차, 곧 MAPE 기준으로 나무 높이를 추정할 때는 0.18, 탄소 축적량을 추정할 때는 0.37이었고, 전체적인 설명력은 0.68을 기록했습니다.

중국 헤이룽장성의 천연림 연구는 시간 축이 훨씬 깁니다. 1976년부터 2015년까지 NFI 고정 표본점 자료를 아홉 차례 모았습니다. 여기에 과거와 미래의 기후 및 이산화탄소 농도 자료를 겹쳐서 지식 유도 머신러닝(Knowledge-Guided Machine Learning, KGML)이라는 틀을 만들었습니다. 나무의 생태적 생장 과정을 수식으로 옮긴 산림 탄소 고정 모형에 이산화탄소 시비 효과를 반영해 다듬고, 이 모형이 계산해 낸 값을 XGBoost가 먼저 참고할 정보로 넘겨주는 이단계 구조입니다. 이렇게 생태학 지식을 엮은 덕분에 탄소 밀도 예측의 설명력은 0.85에서 0.90 위로 올라갔습니다. 탄소 배출을 적극적으로 억제하는 저배출 시나리오에서 헤이룽장성 천연림의 탄소 축적량은 2060년에 1,379.26 테라그램에서 1,439.02테라그램 사이로 전망됐습니다.

생태학의 규칙을 미리 심어 두었기 때문에, 학습 데이터 범위를 벗어난 미래를 예측할 때도 값이 터무니없이 튀지 않았습니다. 보통의 블랙박스 머신러닝 모델은 한 번도 보지 못한 극단적인 기후 조건 앞에서 엉뚱한 값을 내놓기 쉬운데, 학습 데이터 안에서 본 패턴을 벗어나면 무엇을 근거로 답해야 할지 모르기 때문입니다.

루마니아 현장 자료를 바탕으로 만든 모형에 핀란드 국가산림자원조사 표본과 Sentinel-2 시계열을 더한 연구도 있습니다. 핀란드 임목 재적 예측의 설명력은 0.483에서 0.718로 올랐습니다. 연구 대상은 탄소 지도가 아니라 수고와 흉고단면적, 재적 같은 임분 속성이었습니다. 탄자니아 연구는 2014년 산림·우드랜드 면적을 출발점으로 2054년까지 기존 추세, 지속가능 관리, 개발 압력 증가라는 세 시나리오를 계산했습니다.

코네티컷부터 사할린, 헤이룽장, 핀란드까지 이어지는 이 연구들은 공통된 그림을 보여줍니다. 지상 표본점 데이터가 많고 다양할수록, 위성 센서를 여러 종류 겹쳐 쓸수록 광역 지도의 정확도가 올라간다는 사실입니다.

숫자가 어긋나는 이유

연구의 숫자를 나란히 놓을 때는 조심해야 합니다. 나무 한 그루의 무게와 임분 재적, 헥타르당 바이오매스는 서로 다른 목표변수이고, R^2 도 자료 범위와 검증 방식에 따라 달라 집니다. NFI 표본점 좌표의 오차는 수관과 지형, 수신기, 보정 방식에 좌우됩니다. 일부 공개 자료는 사유지 보호를 위해 좌표를 의도적으로 흐리기도 합니다. 위성 화소에는 큰 나무와 어린나무, 빈 땅이 함께 담기므로 가까이서 켜 개체목 값과 화소 평균 사이에 간격이 생깁니다.

광학 위성과 레이더 위성 사이에서도 순위가 뒤집힙니다. 광학과 짧은 파장 레이더는 바이오매스가 높은 숲에서 신호 포화가 빨리 나타날 수 있습니다. 포화 지점은 숲 구조와 수분, 편파, 입사각, 회귀모형에 따라 달라져 하나의 임계값으로 못 박기 어렵습니다. 긴 파장 레이더와 LiDAR는 울창림의 구조를 읽는 데 상대적으로 유리합니다. GEDI는 파형 LiDAR이므로 레이더 후방산란과 같은 포화 기준으로 묶지 않습니다. 센서별 차이는 탄소 배출권처럼 돈이 오가는 계산에서 민감하게 작용합니다.

남겨진 문제, 다음 단계

기술적인 한계도 남아 있습니다. NFI와 위성은 관측 주기가 달라 같은 숲을 다른 날에 재게 됩니다. 여러 나라의 공개 NFI 자료는 사유지 보호를 위해 실제 좌표를 흐려 놓기도 해, 고해상도 화소와 맞출 때 오차가 생깁니다. 상대성장식으로 만든 바이오매스 참고값에도 식 선택에 따른 불확실성이 들어 있습니다. 원격탐사 AGB 지도를 숲 전체의 탄소량으로 간주해서는 안 됩니다. 국가 온실가스 인벤토리는 지하부 바이오매스와 고사목, 낙엽, 토양을 별도 탄소 저장고로 계산할 수 있습니다.

앞으로는 생장 방정식과 탄소 순환 모형을 신경망에 넣는 지식 유도 머신러닝을 넓은 지역으로 시험해야 합니다. GEDI와 ICESat-2 같은 서로 독립된 우주 탑재 LiDAR 임무의 수고 자료도 NFI와 함께 비교할 수 있습니다. 인공지능이 추정값과 불확실성을 나란히 내놓아야 국가 온실가스 인벤토리에서 쓸 수 있는 탄소 지도로 다가갈 수 있습니다.

근거 및 참고문헌

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

산림 토양 동태 및 토지 피복 변동 모니터링

큰비가 사흘 내리 쏟아진 뒤였습니다. 강원도 어느 벌채지, 나무를 걷어낸 비탈은 맨살을 드러낸 채 빗물을 그대로 받아 냈습니다. 절개면을 타고 흘러내린 흙은 붉었습니다. 화강암이 풍화되어 만들어진 마사토 특유의 색입니다. 강화를 신은 연구원 한 사람이 흙탕물 앞에 쭈그려 앉아 손으로 흙을 한 줌 쥐어 보았습니다. 손가락 사이로 빠져나가는 감촉만으로도 이 흙이 유기물을 얼마나 잃었는지, 다음 비에 또 얼마나 씻겨 내려갈지 대강은 가늠할 수 있습니다. 몇 걸음 옆, 뿌리가 아직 붙어 있는 비탈에서는 흙빛이 한결 짙고 단단합니다. 같은 산인데도 나무가 있고 없고에 따라 흙의 사정이 이렇게 달라집니다. 그런데 손끝의 감각은 이 비탈 전체를, 벌채지 너머 산 전체를 말해 주지 못합니다. 흙 한 줌은 늘 부족합니다.

그래서 흙 속과 산 너머를 동시에 읽어 내는 센서와 위성, 그리고 그 둘을 엮는 인공지능이 산림 토양 관측의 한복판으로 들어왔습니다.

땅속 센서와 하늘의 눈이 함께 읽는 수분

토양 수분과 유기물, 온도와 상대습도, 이산화탄소 농도는 나무가 얼마나 잘 자라는지, 물을 얼마나 아껴 쓰는지, 탄소를 얼마나 붙잡아 두는지를 가르는 조건입니다. 예전에는 정해진 날짜에 맞춰 현장에 나가 표본을 뜨거나, 계측기 하나를 꽂아 두고 그 계측기가 읽는 숫자만 들여다보는 방식이 전부였습니다. 넓은 산을 그런 식으로 읽으면 나무 그늘 하나, 골짜기 하나의 사정은 놓치기 쉽습니다. 요즘은 사물인터넷(IoT) 센서를 땅에 여러 개 심고, 저전력 장거리 통신망인 로라(LoRa)로 신호를 묶은 뒤, 드론과 인공위성이 찍은 영상까지 함께 겹쳐서 읽는 방식으로 바뀌고 있습니다.

드론을 띄워 얻은 다중분광 영상과 열적외선 영상, 일반 사진을 딥러닝으로 한꺼번에 분석해 알팔파 뿌리 부근 토양 수분을 추정한 연구가 있습니다. Yin 등(2024)이 유럽농학저널(European Journal of Agronomy)에 발표한 이 연구는 센서 하나짜리 모델보다 여러 센서를 합친 모델의 오차가 뚜렷이 작다는 사실을 보였습니다. 눈에 보이는 색만으로는 알 수 없던 뿌리 부근의 물 사정이, 여러 파장을 겹쳐 보면 드러난다는 뜻입니다.

밀을 심은 산림농업 농장을 다룬 리뷰 논문도 비슷한 결을 보여 줍니다. Singh 등(2026)이 국제환경농업생명공학저널(IJEAB)에 실은 이 리뷰는 나무 그늘의 폭을 조절하는 수관 관리와 땅속 수분 센서, 그리고 위성에서 얻는 지표수분지수(LSWI)와 온도식생건조지수

(TVDI)를 함께 쓰면 나무와 밀이 물을 놓고 다투는 시점을 미리 알아차릴 수 있다고 설명합니다. 물싸움이 시작되기 전에 알아차리면 물을 아껴 쓸 여지가 생깁니다.

나무줄기 속에 꽂아 전기적 성질로 수분을 재는 다중 프로브 센서, 배터리 하나로 몇 달을 버티는 로라 게이트웨이도 현장에 설치되어 있습니다. 산속 깊은 곳에서 잦 값이 사람 손을 거치지 않고 서버와 에지(edge, 현장 근처의 소형 컴퓨터) 단말기로 곧장 전송되는 배관이 이미 돌아가고 있습니다. 예전 같으면 연구원이 한 달에 한 번 산을 올라 계측기 숫자를 손으로 옮겨 적던 일이, 이제는 휴대전화 화면을 켜는 것만으로 확인됩니다. 다만 이 배관도 완벽하지는 않습니다. 배터리가 떨어지거나 통신이 끊기면 그 구간의 숫자는 통째로 비어 버립니다.

이런 여러 기술을 한데 모아 놓고 흐름을 정리한 리뷰도 나왔습니다. Wang 등(2026)은 산림 자원 관측에 쓰이는 라이다와 위성 영상, IoT 센서, 드론 자료를 한 모델 안에 섞어 넣는 다중모달 데이터 융합 연구들을 프런티어스 인 플랜트 사이언스(Frontiers in Plant Science)에서 정리하며, 자료 종류가 늘어날수록 정확도는 오르지만 자료마다 시간과 공간의 해상도가 달라 이를 맞추는 전처리 작업이 만만치 않다고 짚었습니다. 산림 건강 감시 전반을 다룬 리뷰들도 같은 결론을 되풀이합니다. Amoah-Nuamah 등(2025)과 Saha 등(2025)은 각각 인공지능 기반 산림 건강 감시와 원격탐사, 스마트 모니터링 체계를 정리하면서, 센서와 위성과 인공지능을 따로 쓰기보다 서로 겹쳐 쓸 때 오탐과 누락이 함께 줄어든다고 짚었습니다.

흙의 질을 점수로 바꾸는 지도

토양의 가용 수분 용량, 유기물 함량, 산도, 영양분은 숲이 얼마나 건강한지 가르는 척도입니다. 나무 뿌리가 어디까지 뻗을 수 있는지, 가뭄이 왔을 때 얼마나 버틸 수 있는지도 결국 이 숫자들에서 갈립니다. 문제는 이 숫자들이 샅으로 한 번 떠 봐서는 알 수 없고, 실험실에 보내 며칠을 기다려야 나온다는 점입니다. 이 숫자들을 한 장의 지도로 그리는 작업이 최근 몇 년 사이 빠르게 늘었습니다.

자연 소나무 숲을 대상으로 한 연구에서 Poudel 등(2025)은 계층화 분석법(Fuzzy-AHP)과 랜덤포레스트를 섞어 토양 질 지수를 산출했습니다. 사이언티픽 리포트(Scientific Reports)에 실린 이 연구는 토양 구조와 유기물, 수분 보유력을 함께 넣은 머신러닝 모델이 기존 통계 모델보다 지역마다 다른 토양 사정을 훨씬 촘촘하게 그려 낸다고 보고했습니다.

토양유기탄소(SOC) 자체를 위성으로 짚어 내려는 시도도 이어지고 있습니다. Li 등(2025)은 센티널-2 위성의 분광 영상과 지형 변수를 엮어 중국 보스토허 오아시스의 토양유기탄소 농도를 추정했습니다. Parvizi와 Fatehi(2025)는 여러 토지 이용 유형에 걸쳐 토양유기탄소를 지도화하면서 일반화선형모델, 큐비스트, 서포트벡터머신, 랜덤포레스트를 나란히 겨루게 했습니다. 랜덤포레스트의 설명력은 0.64로, 일반화선형모델의

0.39나 서포트벡터머신의 0.41보다 뚜렷이 나은 수치였습니다. 알고리즘 하나가 늘 이기는 것은 아니어서, 토양과 지형이 달라지면 어떤 모델을 앞세울지도 다시 따져 봐야 합니다.

이렇게 얻은 토양 질 지수나 토양유기탄소 지도는 숫자 하나로 끝나지 않습니다. 지도 위에 색을 입히면 같은 산 안에서도 비탈 방향에 따라, 물이 고이는 골짜기인지 능선인지에 따라 흙의 사정이 얼마나 다른지 한눈에 드러납니다. 임업 담당자 입장에서는 어디에 나무를 심고 어디는 그대로 두어야 할지를 정할 때, 이 지도가 현장 답사보다 먼저 짚어 주는 참고자료가 됩니다.

그늘나무 배치를 계산하는 그래프 신경망

산림농업에서는 위층 나무가 드리우는 그늘의 위치 하나가 아래층 작물의 햇볕과 습도, 이산화탄소 농도, 토양 수분을 통째로 바꿔 놓습니다. 그늘이 너무 길으면 작물이 웃자라고, 너무 열으면 퇴락별에 잎이 타 버립니다. 그늘을 어디에, 몇 그루 세울지는 그래서 감이 아니라 계산의 문제가 됩니다.

Ridlo 등(2025)은 그래프 이론의 독립지배집합 알고리즘으로 그늘나무와 센서의 배치를 계산하고, 시공간 그래프 신경망(STGNN)으로 상대습도와 이산화탄소 농도를 예측했습니다. 커피나무 96그루와 그늘나무 26그루를 둔 시나리오에서는 연간 이산화탄소 고정량 520킬로그램이 산출됐습니다. 그늘나무 31그루를 격자로 둔 시나리오의 값은 620킬로그램이었습니다. 장기간 현장에서 직접 잰 탄소고정량이 아니라 모형의 계산값입니다.

예측 성능도 눈여겨볼 만합니다. 이 모델은 10일, 15일, 20일 뒤의 미기후를 내다봤습니다. 과거 평균을 그대로 쓰는 방식이나 에이림아(ARIMA), 서포트벡터회귀(SVR), 그래프 합성곱신경망(GCN), 순환신경망(GRU) 같은 기존 기법들과 겨뤘을 때 오차가 뚜렷이 작았고, 결정계수는 0.7350에서 0.8109 사이였습니다. 사람이 매일 나가 재던 상대습도와 이산화탄소 농도를, 이제는 열흘 뒤 것까지 미리 계산해 두고 그늘나무 심을 곳을 고르는 시대가 열렸습니다.

위성이 30년 넘게 찍어 온 숲의 필름

기후변화와 무허가 벌채, 농경지 확장과 산불은 숲의 겉모습을 계속 바꿔 놓습니다. 이 변화를 잡아내려면 한 장의 사진이 아니라 수십 년 치 필름이 있어야 합니다. 랜드샷(Landsat)과 센티널, 모디스(MODIS) 같은 위성들이 켜켜이 쌓아 온 시계열 영상이 그 필름 역할을 합니다. 한국에서도 강원도 산불 피해지나 소나무재선충병 벌채지의 회복 상태를 살필 때 같은 계열의 위성 시계열 분석이 쓰입니다. 벌채나 산불 직후에는 맨흙이 넓게 드러나다가, 몇 해가 지나면 풀과 관목이 먼저 들어차고 그 다음에야 나무가 뿌리를 내리는 흐름이 위성 영상의 색 변화로 고스란히 나타납니다.

Obata 등은 2021년에 미국 조지아주 산림을 연구했습니다. Google Earth Engine 위에 1984년부터 2016년까지 33년 치 Landsat 영상을 쌓았습니다. 태슬캡 변환으로 밝기와 녹색도, 습윤도 지수를 뽑고 조화 회귀분석을 거쳐 국가산림조사 표본점과 Random Forest로 엮었습니다. 3년 치 영상만 쓴 모델보다 마지막 교란 시점을 더 잘 짚고 임목 축적량 오차도 줄였습니다. 같은 연구가 2026년 일본 학술지에 다시 소개됐지만, 원 출판연도와 DOI를 우선 인용합니다.

교란의 원인을 가려내는 작업도 전 지구 단위로 넘어갔습니다. Wang 등(2026)은 2000년부터 2020년까지 전 세계 숲에서 일어난 손실을 산불, 벌채와 수확, 화전, 병해와 풍해로 나눠 정량화한 데이터셋을 랜드셋 시계열과 딥러닝으로 구축해 지구시스템과학데이터(Earth System Science Data)에 발표했습니다. 어디서 숲이 사라졌는지를 넘어, 왜 사라졌는지를 지도 위에서 구분할 수 있게 되었다는 뜻입니다.

토지 이용과 토지 피복을 가르는 인공지능 모델들을 나란히 겨루게 한 연구도 있습니다. Çalışkan(2026)은 서포트벡터머신과 랜덤포레스트, 의사결정나무를 같은 자료로 학습시켜 성능을 비교했는데, 어느 한 기법이 모든 지역에서 이기지는 않았습니다. 지형이 복잡하고 토지 이용이 잘게 쪼개진 지역일수록 랜덤포레스트 계열이 나았고, 경계가 뚜렷한 대규모 농경지에서는 구조가 간단한 의사결정나무 기법도 크게 밀리지 않았습니다.

라벨이 부족한 지역에서는 다른 전략이 필요합니다. 콜롬비아의 열대 건조림은 계절에 따라 잎이 지고 불이 잦아 분광 특성이 크게 흔들립니다. González-Vélez 등(2026)이 내놓은 Semi-FCMNet은 정답 라벨과 라벨 없는 Sentinel-1 레이더, Sentinel-2 광학 시계열을 함께 학습시키는 준지도학습 구조입니다. 라벨이 제한된 조건에서도 90퍼센트가 넘는 정확도를 유지했습니다. 노동시간 절감은 따로 측정하지 않았습니다.

숲이 사라진 곳에 무엇이 들어서는지를 구체적으로 짚어내는 연구도 있습니다. Pišl 등(2026)은 위치 정보를 함께 학습하는 딥러닝 모델로 열대림이 사라진 곳이 목초지로 바뀌었는지, 농경지나 도로로 바뀌었는지를 구분해 냈습니다. 같은 숲 감소라도 그 뒤에 들어서는 용도가 다르면 정책 대응도 달라져야 한다는 점을 이 연구는 보여 줍니다.

숲이 늘어나는 쪽 이야기도 있습니다. 브라질 아열대 지역의 산림농업 구역은 Silva 등(2026)이 다뤘습니다. 연구진은 2000년, 2010년, 2020년, 세 시점의 맵바이오마스(MapBiomass, 브라질의 위성 토지피복 지도 사업) 자료로 변화를 추적했습니다. 이 구역의 면적은 405.80헥타르에서 500.60헥타르를 거쳐 659.81헥타르로 늘었습니다. 같은 기간 서식지 응집도 지수도 함께 올랐습니다. 파편화된 자연림 사이를 산림농업 지대가 이어 주는 생태 통로 역할을 하면서 늘어난 것으로 보입니다. 이런 통로는 생물다양성을 지키고 흩어 쓸려 내려가는 것을 막는 효과도 함께 낸다고 이 연구는 짚었습니다.

미래를 내다보는 연구도 나왔습니다. Zella(2026)는 탄자니아 국가산림자원조사(NAFORMA) 자료를 바탕으로 2014년부터 2054년까지 산림 면적을 세 가지 시나리오로 계산했습니다. 기존 추세가 이어지면 4,809만 헥타르였던 산림과 우드랜드가 3,299만 헥타르로 줄고, 개발 압력이 큰 시나리오에서는 2,830만 헥타르까지 떨어집니다. 지속가능 관리 시나리오에서는 4,385만 헥타르가 남는 것으로 예측됐습니다.

벌채를 실시간으로 잡아내려는 시도도 나왔습니다. Kundu 등(2025)은 객체 탐지 모델인 옴로(YOLO)와, 여러 단계의 판단을 스스로 이어 가는 랭체인(LangChain) 기반 에이전트를 묶어 위성과 드론 영상에서 벌채로 의심되는 변화를 실시간에 가깝게 잡아내고 경보를 띄우는 체계를 사이언티픽 리포트에 발표했습니다. 인공지능이 벌채로 의심되는 영역을 먼저 추려 주지만 오탐이 완전히 사라지지는 않아서, 마지막 판단은 여전히 사람이 내려야 합니다.

이런 시계열 감시는 이제 연구실 밖에서도 값을 매깁니다. 유럽연합 산림전용방지규정(EUDR)은 부속서 I에 든 커피와 코코아, 목재 관련 제품을 시장에 내놓거나 수출하는 사업자에게 생산지 위치 정보를 요구합니다. 4헥타르 이하 필지는 위도와 경도 한 점으로 표시할 수 있고, 그보다 큰 필지는 폴리곤 경계가 필요합니다. 기준일은 2020년 12월 31일입니다. 주요 사업자와 일부 중소기업은 2026년 12월 30일부터 적용받습니다. 자연인과 일부 초소형 사업자의 적용일은 2027년 6월 30일입니다. 품목 코드와 사업자 지위에 따라 날짜가 달라지므로 기업은 자기 제품과 역할을 따로 확인해야 합니다.

어긋나는 숫자와 남은 숙제

이만큼 기술이 쌓였어도 숫자끼리 어긋납니다. 지상 센서는 좁은 지점의 값을 재고, Sentinel-2나 Landsat의 한 화소는 넓은 면적의 평균을 봅니다. 자갈과 그늘, 수관, 토양 수분이 다른 두 자료를 겹치려면 같은 날짜와 같은 공간 규모로 맞추는 검증이 필요합니다.

실제로 이런 어긋남이 현장에서 문제가 된 사례도 보고됩니다. 위성 지수만 보고 안전하다고 판단한 구역이 막상 가 보면 이미 상당히 마른 상태였거나, 반대로 위성이 이상 신호를 울렸는데 현장에서는 그저 평범한 계절 변화였던 경우도 있습니다. 두 신호가 어긋날 때 무엇을 먼저 믿을지에 대한 규칙을 현장 편람에 미리 정해 두지 않으면, 관리자마다 판단이 엇갈리는 혼선이 빚어집니다.

광학 위성과 레이더(SAR) 위성 사이에도 다른 종류의 상충이 있습니다. 구름과 안개가 잦은 열대·아열대 우림에서는 광학 영상에 빈 곳이 자주 뚫려 잎이 피고 지는 흐름을 놓치기 쉽습니다. 우기가 몇 달씩 이어지는 지역에서는 반년 내내 쓸 만한 광학 영상을 한 장도 못 건지는 경우도 있습니다. 레이더는 구름을 뚫고 찍을 수 있지만, 비 온 직후 젖은 흙 표면의 거칠기가 신호를 흔들어 변화가 없는데도 있는 것처럼 잘못 잡아내는 일이 생깁니다.

수관이 뽕뽕하게 닫힌 숲에서는 위성이든 드론이든 위에서 쏜 신호가 나뭇잎 표면에서 되튀기 때문에, 그 아래 흙 사정은 간접 지수로 짐작할 수밖에 없습니다. 한 기후대에서 훈련한 변화 탐지 모델을 다른 생태계에 옮기면 낙엽 지는 계절을 산불이나 벌채로 잘못 읽을 수 있습니다. 정확도 하락 폭은 자료와 지표마다 달라 하나의 범위로 묶지 않습니다. 오지 센서는 배터리와 통신이 끊기는 일도 잦아 장기간 현장 시험이 필요합니다.

앞으로는 땅속 물의 움직임을 물리 법칙으로 풀어내는 방정식과 신경망을 한데 묶은 물리 정보신경망(PINN, Physics-Informed Neural Network)이 하나의 과제로 남아 있습니다. 데이터만으로 학습한 모델은 훈련 자료에 없던 극한 가뭄이나 기록적인 폭우 앞에서 엉뚱한 값을 내놓는 일이 있는데, 물이 땅속으로 스며들고 증발하는 물리 법칙을 신경망 안에 함께 넣어 두면 이런 낯선 상황에서도 그럴듯한 값을 유지할 가능성이 큼니다. 시공간 그래프 신경망과 트랜스포머를 가볍게 줄여 드론과 현장 단말기에 직접 심는 작업도 과제로 남아 있습니다. 생태계마다 다른 시계열 토양, 토지피복 벤치마크 자료를 계속 넓혀야 한다는 지적도 여러 논문에서 되풀이됩니다.

배터리 하나로 몇 달을 버티는 저전력 인공지능 칩이 산속 구석구석까지 들어가야, 지금 센서와 위성 사이에 벌어진 오차도 조금씩 좁혀질 것으로 보입니다.

근거 및 참고문헌

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. 법무법인 세종. (2026, 3월 17일). 2026년 주목해야 하는 ESG 규제 (4) EU 산림 전용 방지 규정(European Union Deforestation-Free Products Regulation). <https://www.shinkim.com/kor/media/newsletter/3174> (2026년 8월 2일 접속)

제3장

산림 재해 및 생태계 건강 모니터링: AI 예찰과 조기 경보

3.1

머신러닝·딥러닝 기반 산불 위험도 예측 및 연소지 감지

늦봄 오후, 건조주의보가 사흘째 이어지던 날입니다. 산불상황실 벽을 채운 모니터 한구석에 붉은 점 하나가 뜹니다. 창밖 바람은 마르고 세서, 어제 뿌려 둔 물은 벌써 말라 있습니다. 상황실 안에는 무전기 소리와 키보드 두드리는 소리만 낮게 깔립니다. 근무자는 곧바로 CCTV 화면을 당겨 보고, 열화상 카메라의 온도 수치를 확인하고, 인근 신고가 들어왔는지 조회창을 엽니다. 저 점이 진짜 불인지, 논둑 태우는 연기인지, 저녁 햇빛에 달궈진 지붕인지 가릴 시간은 길어야 몇 분입니다. 그리고 그 몇 분 사이, 사람의 눈이 화면을 다 훑기도 전에 인공지능 알고리즘은 이미 한 번 판단을 끝내 놓은 상태입니다.

2025년 3월, 경상북도 의성에서 시작된 불이 이 판단의 무게를 보여준 사례입니다. 불은 안동과 청송, 영양, 영덕까지 번졌습니다. 공식 집계로 스물여섯 명이 숨지고 일흔한 명이 다쳤습니다. 경북의 잠정 산림피해면적은 9만 9,289헥타르였습니다. 경북의 잠정 피해액은 1조 1,306억 원입니다. 경북·경남·울산의 복구비는 1조 8,809억 원으로 집계됐습니다. 두 값은 서로 다른 숫자입니다. 피해액이 여름에 늘어난 것이 아니라, 피해 조사와 복구 계획의 지역 범위와 회계 항목이 달랐습니다.

이런 불을 막으려는 인공지능은 크게 두 단계에서 일합니다. 자료를 스스로 훑어 규칙을 찾아내는 머신러닝(Machine Learning), 그 규칙 찾기를 여러 겹 신경망으로 훨씬 깊게 파고드는 딥러닝(Deep Learning)이 저마다 다른 시점을 말합니다. 불이 나기 며칠, 길게는 한 달 전에 어디가 위험한지 미리 짚어내는 예측 모델이 하나입니다. 불이 이미 붙은 뒤 몇 분 안에 그 사실을 알아채는 감지 모델이 다른 하나입니다.

습도 곡선이 먼저 움직인다

예전 산불 위험 평가는 고정된 지형과 한 번 찍은 식생 지수에 기댔습니다. 산 하나의 경사와 나무 종류는 몇 년이 지나도 크게 안 변하니, 그 정보만으로 위험 지도를 그려 놓고 오래 썼습니다. 문제는 산불이 지형 탓만으로 나지 않는다는 데 있습니다. 어제까지 비가 오다가 오늘 갑자기 습도가 뚝 떨어지면, 어제는 안전했던 산이 오늘은 위험한 산으로 바뀝니다. 최근 산림 인공지능은 기상과 지형, 연료가 되는 식생, 그리고 사람이 얼마나 드나드는지를 보여주는 사회경제 자료까지 한데 묶어, 하루 단위로 산불 발생 확률을 다시 계산하는 쪽으로 옮겨 가고 있습니다.

이 계산에는 골치 아픈 특징이 하나 있습니다. 산불이 난 날은 며칠 안 되고, 나지 않은 날이 압도적으로 많다는 점입니다. 이 상태 그대로 모델을 학습시키면, 안전한 날만 잘 맞히면서 점수를 채우는 게으른 학생처럼 행동합니다. 정작 실제 불이 난 날은 놓치는 겁니다. 그래서 연구자들은 SMOTE(Synthetic Minority Over-sampling Technique)를 씁니다. 적은 쪽 사례, 그러니까 산불이 난 날의 자료를 통계적으로 비슷하게 새로 만들어 늘려서 모델이 두 경우를 고르게 보고 배우게 만드는 방법입니다. 반대로 불이 나지 않은 날의 자료를 속아 내는 언더샘플링이나, 산불을 놓쳤을 때 매기는 벌점을 더 무겁게 매기는 비용민감 학습을 나란히 쓰기도 합니다.

강원특별자치도를 대상으로 한 연구는 2013년부터 2023년까지 열한 해 동안 쌓인 날씨와 산림, 인구 자료에 이 방식을 적용했습니다. 이런 표 형태 자료에서는 심층신경망보다, 나무 여러 그루를 심어 다수결로 판단하는 트리 기반 모델이 자주 앞섭니다. 조건을 하나씩 나누어 가지를 뺀 방식이, 날씨와 지형처럼 성격이 다른 변수를 뒤섞어 볼 때 오히려 유리하기 때문입니다. 로지스틱 회귀와 XGBoost, LightGBM, 랜덤 포레스트, 엑스트라 트리까지 다섯 모델을 나란히 겨룬 결과 엑스트라 트리가 AUC 0.839로 앞섰습니다. AUC는 진짜 산불이 난 날과 나지 않은 날을 얼마나 잘 갈라내는지 보여주는 지표로, 1에 가까울수록 잘 맞히고 0.5는 동전 던지기와 다르지 않습니다. 산불을 놓치지 않는 능력만 놓고 보면 랜덤 포레스트가 재현율 0.828로 더 나았습니다.

재현율은 실제로 일어난 산불 가운데 모델이 놓치지 않고 잡아낸 비율을 뜻합니다.

이 연구는 SHAP(SHapley Additive exPlanations)이라는 설명 기법도 함께 썼습니다. 여러 선수가 함께 낸 성과를 각자 기여한 만큼 나누어 계산하는 게임이론의 방식을 예측 모델에 그대로 옮긴 기법입니다. 상대습도의 기여도는 0.25로 다른 변수를 모두 앞질렀습니다. 습도가 낮아질수록 위험은 가파르게 치솟았습니다. 강수 여부는 0.15로 뒤를 이었고, 일 최고기온은 0.05, 인구 밀도는 0.04였습니다. 임목 축적량과 묘지 비율, 침엽수림 비율, 농경지 비율도 크지는 않아도 꾸준한 무게를 보였습니다. 태백산맥을 사이에 두고 바닷바람을 그대로 맞는 영동과, 산맥 뒤에 놓인 영서를 가르는 지역 구분 변수도 비슷하게 작용했습니다. 기후만이 아니라 사람이 산에 드나들고 불을 놓는 습관까지 위험을 밀어 올린다는 뜻으로 보입니다.

침엽수림 비율이나 임목 축적량 같은 연료 변수는 사람이 걸어 다니며 일일이 재지 않습니다. 식물이 머금은 물의 양을 보여주는 지수(LSWI)나 지표 온도로 가뭄 정도를 가늠하는 지수(TVDI), 드론 레이저로 그린 수관 높이 지도(CHM) 같은 원격 관측 자료가 사람의 발걸음을 대신합니다. 무인기에 라이다(LiDAR)를 얹어 나무 하나하나의 위치와 둘레, 우듬지 폭까지 자동으로 그려내는 연구도 이어지고 있습니다. 베트남에서 소나무의 한 종류인 삼엽송(Pinus kesiya) 숲을 딥러닝으로 분석한 연구는 개체목 탐지와 수관 구획을 자동화해, 산불 연료 지도를 그리는 밑자료로 쓸 길을 열었습니다.

강원도 연구가 하루 앞을 내다보는 지역 모델이라면, 예측 기간을 한 달 가까이 늘린 시도도 나왔습니다. 유니스트(UNIST) 임정호 교수 연구팀은 2026년, 전 세계 산불기상지수를 최대 31일 앞서 내다보는 딥러닝 모델 FWI-Net을 국제 학술지 커뮤니케이션스 어스 앤드 인바이런먼트에 발표했습니다. 산불기상지수는 기온과 습도, 바람, 강수량을 하나로 합쳐 불이 붙었을 때 얼마나 크게 번질지 보여주는 지표입니다. 기존 유럽중기예보센터 수치예보는 두 주가 지나면 정확도가 빠르게 떨어졌지만, FWI-Net은 31일 전체 구간의 오차를 6.6퍼센트 줄였습니다. 예보 첫 일주일만 떼어 보면 오차 감소폭은 12.4퍼센트까지 커졌습니다. 산불 위험이 큰데도 정작 예보 체계는 부실한 지역일수록 이 개선폭이 크게 나타났습니다.

지형정보 기술과 기계학습을 결합한 연구를 모아 다시 살펴본 국제 문헌 검토에서도 결론은 비슷했습니다. 위성 영상이나 지리정보시스템 자료 하나만 쓴 모델보다, 기상과 지형, 인간 활동 자료를 겹쳐 쓴 모델이 나라와 지역을 가리지 않고 더 나은 성능을 보였다는 흐름이 반복해서 확인됐습니다.

산속 센서와 하늘의 눈이 실시간으로 잇는다

땅 위에서는 센서가, 하늘에서는 위성이 같은 순간을 지켜봅니다. LoRaWAN은 전력을 적게 쓰면서 먼 거리까지 신호를 보내는 무선 통신 방식입니다. 튀르키예 제이틴파크에는 기온과 습도, 일산화탄소를 재는 센서 80개가 설치됐습니다. 연구진은 적응형 가중 Random Forest와 XGBoost를 묶은 모형을 시험했고, 센서 배치의 커버리지는 95.58퍼센트로 계산됐습니다. 배터리 수명은 분석상 최대 11개월이었습니다.

공간을 보는 눈금을 넓힌 연구도 있습니다. 러시아 시베리아 크라스노야르스크 지역을 다룬 연구는 산불 지점을 중심으로 반경 1킬로미터부터 100킬로미터까지 여섯 겹의 동심원을 그렸습니다. 각 원 안의 기상과 지형 자료를 30일 치 시계열로 엮고 XGBoost로 화재 규모를 분류해 88.8퍼센트의 정확도를 보고했습니다. 연구진은 이 값이 지역에 맞춘 탐색 결과이며, 다른 대륙에 옮기려면 현지 자료로 다시 보정해야 한다고 적었습니다.

지구화재연합(Earth Fire Alliance)의 운영 FireSat 세 기는 2026년 7월 7일 궤도에 올랐습니다. 공식 로드맵은 그해 말 초기 이용자에게 하루 두 차례 이상 관측을 제공하는 데서 시작합니다. 목표는 2028년 전 지구 접근, 이듬해 1시간 이내 재방문으로 이어집니다. 2030년대 초에는 20분 이내 재방문을 겨냥합니다. 위성 수와 일정은 발사와 예산에 따라 바뀔 수 있습니다.

국내 원격탐사학계에서는 산불이 나기 전과 번지는 중, 진화한 뒤까지 전체 주기를 인공지능과 위성 감시로 잇는 흐름을 정리한 리뷰 논문도 나왔습니다. 발화 전 위험 예측과 발화 중 실시간 탐지, 진화 후 피해 면적 산정까지, 단계마다 다른 위성 자료와 인공지능 모델이 필요하다는 점을 짚었습니다. 우리 위성도 비슷한 역할을 맡고 있습니다. 기상청이 쏘아 올린 천리안위성 2A호는 천연색으로 지구를 찍어서, 별도 분석 없이도 화면만 보고

구름과 산불 연기, 황사를 눈으로 갈라볼 수 있습니다. 이 위성이 관측한 토양 수분 자료는 가뭄과 산불 위험도를 함께 살피는 데 쓰입니다. 산림청 국립산림과학원은 이 자료들을 묶어 국가산불위험예보시스템을 운영하고, 최근에는 이용자가 서 있는 위치를 기준으로 산불 위험 정보를 바로 보여주는 손안의 서비스도 새로 열었습니다.

연기인지 구름인지, 카메라가 먼저 가른다

불이 이미 붙은 뒤에는 다른 싸움이 시작됩니다. 연기가 넓게 퍼지기 전, 불꽃이 인 지 몇 분 안에 그 사실을 알아채야 하는 골든타임입니다. 산 아래에는 고정식 CCTV와 적외선 카메라가 지키고, 사람이 오르기 힘든 능선과 사각지대는 무인기(UAV, 드론)가 돕니다.

단일 가시광선 카메라는 안개나 구름, 저녁 햇빛 반사에 속을 수 있습니다. 열적외선 카메라는 열원을 잡지만 화면이 거칠어 타는 나무와 뜨거운 바위를 구별하기 어렵습니다. 중국 푸젠성 자료로 학습한 EFFNet은 가시광선과 열적외선 영상을 합쳤습니다. 검증 자료에서 mAP50은 97.2퍼센트였습니다. 정밀도는 94.9퍼센트, 재현율은 94.1퍼센트였습니다. 이 값은 푸젠성 시험조건에서 나온 결과입니다.

연기와 불꽃의 경계를 화소 단위로 나누는 연구도 이어졌습니다. Akhyar 연구진은 UAV 영상에서 산불 구역을 가르는 DeepFire S3GA-Net을 만들었습니다. 시험자료의 평균 IoU는 0.8723이었습니다. 정밀도는 0.9347, 재현율은 0.9194였습니다. Hindarto 연구진은 별도의 산불 영상 자료에서 MobileNetV3, ResNet50, YOLOv8을 비교했습니다. 베트남 삼엽송의 YOLO 분할과 SAM2 비교는 산불 연구가 아니라 개체목·수관 구획 연구입니다.

모델도 서로 다르게 말할 때가 있다

이 모든 결과가 한목소리를 내지는 않습니다. 기상 자료만 넣은 전통적인 산불기상지수 모델은 넓은 지역의 위험 경향은 짚어내지만, 같은 날씨 안에서 어느 작은 산림 구역에 실제로 불이 붙을지는 가려내지 못합니다. 강원도 연구나 모로코, 인도를 다룬 다른 연구들은 인구 밀도와 농경지·묘지 비율, 도로까지의 거리 같은 사회경제 변수를 더했을 때 AUC와 재현율이 10퍼센트포인트에서 15퍼센트포인트까지 올라간다고 보고했습니다. 기상 조건이 똑같아도 사람이 자주 다니는 곳, 논밭과 무덤이 가까운 곳에서 실제 발화로 이어질 가능성이 크다는 뜻으로 보입니다.

가시광선 단독 카메라와 이중모달 카메라를 놓고 보면 값과 정확도가 서로 다른 방향을 가리킵니다. 가시광선 카메라만 단 장비는 값이 싸지만, 안개나 역광, 밤에는 헛것을 잡거나 진짜 불을 놓치는 비율이 올라갑니다. EFFNet처럼 열까지 함께 보는 이중모달 장비는 mAP50 97.2퍼센트라는 성능을 보였지만, 적외선 센서 자체의 값이 비싸고 화면 해상도는 상대적으로 낮습니다. 정밀도와 비용을 동시에 잡는 장비는 아직 나오지 않았을 가능성이 큼니다. 지방자치단체 예산으로 산 전체에 카메라를 놓아야 하는 처지에서는, 값싼

가시광선 카메라를 촘촘히 까는 쪽과 비싼 이중모달 카메라를 성긴 간격으로 놓는 쪽 사이에서 계속 저울질해야 합니다.

기술이 아직 못 하는 일도 담담히 짚어야 합니다. 산불이 난 날은 적어서, SMOTE로 자료를 인위적으로 불리는 과정에 실제와는 다른 가짜 패턴이 섞여 들어갈 위험이 있습니다. 깊은 산속에서는 LTE나 5G 신호가 끊기기 일쑤라 고화질 영상을 중앙 서버로 그때그때 보낼 수 없습니다. 산불이 나지 않았는데도 모델이 경보를 올리면 소방 인력과 헬기가 헛 걸음하고 예산이 썩습니다. 반대로 진짜 산불을 넘겨짚으면 초동 대응이 늦어져 피해가 커 집니다. 그래서 엔비디아 젯슨(Jetson)처럼 드론에 실린 소형 컴퓨터, 이른바 에지 컴퓨팅(Edge AI) 장비 안에서 곧바로 계산을 끝내야 하는데, 모델을 충분히 가볍게 깎아내지 못 하면 판단이 늦어지고 골든타임을 놓칩니다. 비전 트랜스포머나 3차원 합성곱 신경망처럼 성능이 좋은 모델일수록 왜 그렇게 판단했는지 사람이 들여다보기 어려운 문제도 남습니다.

방재 담당자 입장에서는 기계가 내린 판단을 자기 이름을 걸고 승인하기가 쉽지 않습니다.

앞으로 남은 일은 두 방향으로 보입니다. SHAP이나 Grad-CAM으로 판단 근거를 화면에 표시하고, 열과 바람의 물리 방정식을 신경망에 넣는 연구가 한쪽에 있습니다. 다른 쪽에서는 저전력 센서망과 이중모달 드론을 잇고, 경보가 현장에 닿기까지 걸리는 시간을 장치와 통신 조건별로 재고 있습니다. 산불과 병해충, 가뭄 스트레스를 한 감시망에서 함께 다루려는 구상은 나왔지만, 산속에서 1분 이내 무인 대응을 끝낸 완성형 체계는 아직 입증되지 않았습니

근거 및 참고문헌

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, 7월 7일). Earth Fire Alliance's first three operational FireSats reach orbit. <https://earthfirealliance.org/news-article/earth-fire-alliances-first-three-operational-firesats-reach-orbit/> (2026년 8월 2일 접속)
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 [무인기 가시광선·열적외선 융합 영상 기반 초기 산불 딥러닝 탐지 기법]. *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. 국립산림과학원. (2026). 국가산불위험예보시스템. <https://forestfire.nifos.go.kr> (2026년 8월 2일 접속)
16. 산림청. (2025, 4월 18일). 경북·경남·울산 산불피해 규모 잠정 104천ha, 산림청 복구에 최선. https://www.forest.go.kr/kfswweb/cop/bbs/selectBoardArticle.do?bbsId=BBSMSTR_1036&nttid=3206769 (2026년 8월 3일 접속)
17. 대한민국 정부. (2025). 산불 피해 복구비 총 1조 8809억 역대 최대 규모 지원. https://gonggam.korea.kr/newsContentView.es?content=NC002&news_id=f4f9ac3e-81e6-4479-a9e2-6f8cf1c6a34b (2026년 8월 3일 접속)

3.2

병해충(소나무재선충병 등) 및 고사목(Dead Tree) 조기 영상 진단

수요일 이른 아침, 강원도 산기슭을 오르는 예찰단 세 사람의 발소리가 낙엽 위에서 부스럭거립니다. 배낭에는 GPS 단말기와 유전자진단키트가 들어 있고, 목에는 쌍안경이 걸려 있습니다. 능선을 하나 넘을 때마다 한 사람이 걸음을 멈추고 쌍안경을 눈에 댑니다. 초록으로 뒤덮인 사면 어딘가에서 붉은 갈색으로 변한 소나무 서너 그루를 찾는 일이 오늘의 임무입니다. 발견하면 좌표를 찍고, 줄기에 시추기를 꽂아 톱밥을 채취하고, 그 자리에서 감염 여부를 확인합니다. 죽은 지 오래된 나무는 송진 냄새마저 열어져 있습니다.

그런데 이 방식에는 결정적인 흠이 있습니다. 소나무 잎이 붉게 보일 때는 이미 늦었습니다. 소나무재선충병(Pine Wilt Disease)에 걸린 나무는 매개충인 솔수염하늘소가 몸속에 재선충을 옮기는 순간부터 서서히 말라 죽어 가고, 손을 쓰지 않으면 서너 해 안에 숲 하나가 통째로 붉게 물들 수 있습니다. 그런데도 사람 눈에 색이 달라 보이기까지는 몇 주가 걸립니다. 그 몇 주 사이 매개충은 다른 나무로 날아가고, 감염은 조용히 번집니다. 예찰단이 쌍안경으로 붉은 나무를 찾아내는 순간, 그 나무는 이미 죽음의 문턱을 넘은 뒤이고 확산은 벌써 시작된 뒤입니다.

감염목을 찾아낸 뒤에도 일은 끝나지 않습니다. 나무를 베어 넘기고, 통째로 파쇄기에 넣어 잘게 부수거나, 그 자리에서 비닐로 덮고 훈증제를 넣어 매개충 유충까지 없애야 합니다. 사람이 하루에 걸어서 살필 수 있는 산비탈은 넓지 않고, 그나마도 나무가 뺄뺄한 지역에서는 속도가 푹 떨어집니다. 예찰단원 한 명이 하루 종일 걸어도 겨우 야산 몇 굽이를 돌아볼 뿐입니다.

이런 속도를 사람 눈으로 따라잡기 어렵다는 판단 아래, 산림청은 2025년 9월 가을철 방제 실행계획을 내놓으면서 헬기와 드론 조사에 인공지능과 라이다(LiDAR, 빛을 쏘아 되돌아오는 시간을 재서 거리를 알아내는 장비)를 더하겠다고 밝혔습니다. 감염 의심목을 골라내는 일을 시가 먼저 맡고, 사람은 그 결과를 유전자진단키트로 확인하는 순서입니다. 반드시 지켜야 할 국가 선단지와 백두대간, 금강소나무림에는 전문 인력과 장비부터 보냈습니다. 부산 기장군도 2026년 6월 걸어서 살피기 힘든 산악 지형과 사각지대에 드론을 띄워 고해상도 정사 사진을 찍고, 감염 의심목 위치를 부산시와 나누는 예찰을 시작했습니다.

색이 변하기 전에 읽는 기술

나무가 병원체에 감염되면 줄기 속 물길인 도관(양분과 물이 오르내리는 관 모양 조직)이 막힙니다. 물을 끌어올리지 못하는 나무는 잎 뒤편 기공을 닫아 수분 손실을 막으려 하고, 그 순간 증산 작용(잎에서 물이 수증기로 빠져나가며 나무를 식히는 작용)이 뚝 떨어집니다. 에어컨을 끈 방처럼 나뭇잎 표면 온도가 슬금슬금 오릅니다. 이 신호는 잎이 붉어지기 몇 주 전부터 이미 나타나기 시작합니다. 사람 눈에는 아직 초록으로 보이지만, 나무 속에서는 위기가 이미 시작된 뒤입니다.

이 미세한 온도 차이를 잡아내는 장비가 무인기에 매단 열적외선 센서입니다. 수관 온도와 NDVI·SAVI 같은 식생지수, 기상 자료를 포개면 육안 변색 전의 스트레스 신호를 찾을 수 있습니다. 정확도는 수종과 촬영 시각, 그늘, 수분 상태에 따라 달라집니다. 같은 나무를 아침과 한낮, 저녁에 반복 촬영하면 그늘로 생긴 가짜 신호와 생리 스트레스 신호를 가르는 데 도움이 됩니다. 이 신호만으로 병원체를 확진할 수는 없어 현장 시료 검사가 뒤따라야 합니다.

이 며칠, 몇 주의 차이가 실제 방제 현장에서는 결정적입니다. 잎이 붉어지고 나서 감염목을 찾으면 이미 그 나무를 옮겨 다닌 매개충이 이웃한 나무 여러 그루에 알을 낳은 뒤일 가능성이 크지만, 색이 바뀌기 전 단계에서 잡아내면 그 나무 한 그루만 잘라내는 것으로 확산을 꺾을 수 있습니다. 조기 진단 기술이 쫓는 대상은 이 며칠의 시간입니다.

색이 아니라 성분을 보는 접근도 있습니다. 잎이 붉어지기 전에도 엽록소와 수분, 색소 비율이 달라지고, 이 변화는 적색 경계와 단파적외선에서 신호로 잡힙니다. 미국 산림청과 미네소타대학 연구진의 참나무 실험에서는 가뭄 스트레스를 최대 27일, 참나무시뒀병 반응을 최대 24일 앞서 구분했습니다. 스페인 연구진의 2021년 연구는 *Phytophthora cinnamomi* 감염과 수분 스트레스에 따른 참나무 쇠퇴병(oak decline)을 고분광·열적외선 영상으로 살폈습니다. 참나무시뒀병(oak wilt)과 참나무 쇠퇴병은 병원체와 병리가 다릅니다.

소나무재선충병에서도 같은 접근이 시도됩니다. 한 연구팀이 2025년 리모트센싱에 발표한 연구는 UAV 고분광 영상에서 색소 지수와 수분 함량 지수를 함께 읽어 감염 초기의 생화학적 스트레스를 쫓았습니다. 잎 속 색소가 분해되는 속도와 수분이 빠지는 속도는 나무마다 다르게 나타나기 때문에, 두 지표를 겹쳐 보면 한 가지만 볼 때보다 오탐이 줄어듭니다. 2024년 다른 연구팀은 매달 UAV로 같은 임분을 찍은 시계열 영상에 딥러닝(여러 층의 인공신경망으로 패턴을 학습하는 기술)을 결합해, 감염 단계와 한 달 사이 병이 번진 거리를 함께 계산해 냈습니다. 포플러 묘목을 대상으로 한 2024년 연구에서는 여러 시점의 데이터를 ResNet18과 CBAM, LSTM을 엮은 모델에 넣어 품종과 가뭄 스트레스를 가려내는 데 99.69%라는 극히 높은 정확도를 기록했습니다.

숫자만 보면 인공지능이 나무의 속마음을 다 읽어내는 듯하지만, 이 정확도는 대부분 관리된 실험실에서 나온 값이라는 점은 새겨 둘 만합니다.

위성과 무인기, 지상 센서를 층층이 겹쳐 쓰는 흐름은 이 분야 전체를 관통합니다. 2026년 프런티어스인플랜트사이언스에 실린 한 종합 리뷰는 넓은 범위를 훑는 위성 원격탐사와 중간 범위를 맡는 무인기 고분광, 좁은 범위를 정밀하게 재는 지상 센서를 하나로 엮는 관측망이 수종 분류부터 산림 재해 모니터링, 수목 건강 평가까지 두루 쓰이고 있다고 정리했습니다.

이미 죽은 나무를 세는 눈

초동 진단을 놓친 나무는 결국 줄기까지 붉어지다 잎을 다 떨구고 회색으로 마릅니다. 이렇게 서서 죽은 나무를 산림 쪽에서는 고사목(Standing Dead Tree)이라 부르는데, 이 나무들이 어디에 얼마나 있는지 세는 일도 여전히 만만치 않은 과제입니다. 2026년 Chowdhury 등 열네 명의 연구자가 서른여덟 편의 논문을 모아 분석한 리뷰를 보면, 고사목이 듬성듬성 흩어진 숲에서는 YOLO(You Only Look Once, 영상을 한 번에 훑어 물체 위치를 실시간으로 찾아내는 알고리즘) 계열 모델이 강합니다. 2022년 발표된 LDS-YOLO는 방풍림처럼 나무가 작고 배경이 복잡한 곳에서도 가벼운 구조로 작은 고사목을 놓치지 않도록 설계되었습니다. 나무 한 그루가 영상 속에서 몇 픽셀에 지나지 않을 때, 무거운 모델은 오히려 그 몇 픽셀을 배경 잡음으로 지워 버리기 쉽기 때문입니다.

2025년 나온 한 연구는 이중 경로로 특징을 뽑아 합치는 방식으로 고사목이 몰린 구간의 오염을 줄였습니다.

문제는 나무가 뾰뾰하게 몰려 수관끼리 겹치는 구간입니다. 드론 사진 위에서 보면 초록색 뭉게구름이 서로 맞닿은 모양과 비슷합니다. 어디까지가 한 그루의 수관이고 어디부터 옆 나무인지 사람 눈으로도 경계를 긋기 어렵습니다. 이런 곳에서는 네모난 박스로 위치만 표시하는 객체 탐지보다 화소마다 살아 있는 나무인지 죽은 나무인지 표시하는 세그멘테이션 모델이 낫습니다. 독일 연구진이 2021년 내놓은 실비넷(Silvi-Net)은 두 개의 합성곱신경망을 나란히 돌려 수종 분류와 고사목 판정을 함께 처리했습니다. Chowdhury 등의 리뷰는 FSC-Mask2Former와 ADA-Net 같은 최근 모델까지 정리했습니다. 서로 다른 자료에서 나온 정밀도는 촬영 조건과 평가 지표를 함께 봐야 합니다.

이 분야에서 눈여겨볼 변화는 데이터를 쌓는 방식입니다. 2026년 모지크(Mosig)와 카텐보른(Kattenborn) 등이 리모트센싱오브인바이런먼트에 소개한 deadtrees.earth는 전 세계에서 찍힌 센티미터급 항공사진 수천 장을 한데 모은 공개 데이터베이스입니다. 백만 헥타르 넘는 면적을 담고 있고, 그중 오만팔천 헥타르 넘는 구역은 사람이 직접 살아 있는 나무와 죽은 나무를 구분해 표시해 두었습니다. 누구나 자기가 찍은 드론 사진을 올리면 AI가 먼저 분류하고, 사람이 그 결과를 고쳐 주면 모델이 다시 배우는 구조입니다. 한

나라, 한 숲에서 잘 되던 모델이 다른 곳에서는 맥을 못 추는 문제를 풀어 보려는 시도입니다.

유럽 가문비나무 숲에서 잘 맞던 모델을 한국 소나무 숲에 그대로 옮기면 잎의 생김새도 나무가 자라는 밀도도 달라 처음부터 다시 가르쳐야 하는 경우가 많은데, 이런 공개 데이터베이스가 커질수록 그 수고는 줄어든 것으로 보입니다.

해상도가 얼마나 중요한지는 2025년 발표된 한 실험이 잘 보여줍니다. 연구진은 같은 소나무 숲을 무인기로 7센티미터 해상도까지, 중국의 자국산 위성 BJ3N으로 30센티미터, BJ3A로 50센티미터까지 낮추어 가며 재선충병 감염목을 U-Net으로 찾아냈습니다. 무인기 영상은 F1 점수(정밀도와 재현율을 함께 따지는 평가 지표)로 89.1%를 기록했고, 여러 밴드를 합쳐 30센티미터로 만든 위성 영상도 88.9%까지 따라왔습니다. 그런데 보정하지 않은 원래 해상도인 1.2미터와 2미터짜리 위성 영상을 그대로 쓰자 이야기가 달라졌습니다. 점수는 각각 66.6%와 58%까지 떨어졌습니다. 화소 하나가 나무 한 그루보다 커지는 순간, 인공지능의 눈도 함께 흐려진다는 뜻입니다.

번져 가는 길목을 그린다

나무 한 그루를 진단하는 일과 숲 전체에서 병이 어디로 번질지 그리는 일은 다른 과제입니다. 앞서 말한, 매달 UAV로 같은 숲을 찍은 연구팀은 시계열 영상을 이어 붙여 감염 단계뿐 아니라 한 달 동안 병이 퍼진 거리까지 계산했습니다. 계절이 바뀔 때마다 같은 임분을 반복 촬영해 다분광과 열적외선 영상을 겹겹이 쌓으면 병이 번지는 앞선을 지도로 그릴 수 있고, 이렇게 그린 지도는 다음에 어디부터 방제할지 정하는 데 쓰입니다. 지도 위에서 색이 짙어지는 방향을 따라가면, 아직 감염되지 않은 건강한 숲 가장자리에 미리 방제선을 긋는 일도 가능해집니다. 병이 다 퍼진 뒤에 뒤쫓는 대신, 번지는 길목을 앞서 막는 셈입니다. 기장군이 예찰 결과를 부산시와 나누기로 한 것도 같은 맥락입니다.

한 지자체 안에서 끝나는 정보가 아니라 이웃 지자체와 이어질 때, 확산 지도는 행정 경계를 넘어서도 쓸모가 커집니다.

방제를 했다고 끝이 아닙니다. 항공 약제를 뿌리거나 나무주사를 놓거나 감염목을 잘라 훈증한 뒤, 2주에서 3주 간격으로 같은 자리를 다시 찍어 건강한 참조 구역과 분광 지수, 수관 온도를 견주면 방제가 실제로 얼마나 먹혔는지 숫자로 확인할 수 있습니다. 튀르키예의 세빈치(Sevinç)가 2025년 사이언티픽리포트에 발표한 연구는 기계적, 화학적, 생물학적 방제 수단이 목재 생산량과 산림 건강에 미치는 영향을 인공지능경망으로 나누어 평가해, 어떤 조합이 통합 병해충 관리(IPM) 전략에 맞는지 근거를 남겼습니다. 화학 약제만 고집하면 토양과 인근 하천에 부담을 주고, 생물 방제만 쓰면 방제 속도가 확산 속도를 못 따라가는 경우가 많아서, 결과를 수치로 남겨 두는 작업 자체가 다음 계절 전략을 정하는데 힘을 보탍니다. 중국에서도 비슷한 흐름이 있습니다.

2026년 농업과학(农业科学)에 실린 두 논문은 무인기 원격탐사 기술을 산림자원 조사와 병해충 방제에 묶는 방안과, 지능형 기술을 병해충 방제와 세밀한 관리에 접목하는 방안을 각각 정리했습니다.

소나무 밖으로 눈을 돌리면 나무좀(Bark Beetle) 피해에도 비슷한 흐름이 보입니다. 2026년 7월 리모트센싱에 실린 한 논문은 유럽우주국의 센티넬-2 위성이 매주 찍는 영상을 나무 나이나 지형 같은 고정 정보와 함께 XGBoost라는 기계학습 모델에 넣었더니, 위성 영상만 쓰거나 고정 정보만 쓸 때보다, 그리고 이전 연구보다도 나무좀 조기 탐지 성능이 나아졌다고 보고했습니다. 체코 가문비나무 숲을 무인기 고분광 영상으로 조사한 다른 연구에서는 건강목과 감염목, 고사목을 가리는 정확도가 81%까지 나왔는데, 같은 데이터로 유인 항공기로 찍었을 때는 73%에 그쳤습니다. 다만 이런 연구들은 한목소리로 한계도 짚습니다. 나무좀이 나무 속을 파고든 순간부터 성충이 되어 날아오르기까지 걸리는 시간이, 위성이나 드론이 수관의 변화를 알아챌 만큼 길지 않다는 한계입니다.

엇갈리는 결과와 남은 숙제

같은 문제를 다른 장비로 풀면 답도 갈립니다. 고분광 센서는 눈에 보이지 않는 스펙트럼 변화까지 잡아내 잎이 변색되기 한참 전에도 감염목을 찾아내지만, 장비 값이 비싸고 한 장의 영상에 담긴 정보량이 많아 처리 시간도 오래 걸립니다. 고분광 카메라 한 대 값이 다분광 카메라 여러 대를 살 수 있을 만큼 차이가 나기 때문에, 넓은 국유림 전체를 고분광 장비 하나로만 훑는 방식은 예산 앞에서 곧잘 막힙니다. RGB나 다분광 영상으로 돌리는 YOLO나 U-Net 계열은 값싸고 넓은 면적을 빠르게 훑을 수 있지만, 잎이 이미 붉어진 뒤에야 잘 잡아낸다는 흠이 있습니다. 탐지 모델을 고르는 기준도 숲의 생김새에 따라 갈립니다.

고사목이 듬성듬성 떨어진 산악 오지에서는 YOLO 계열이 빠르게 훑고 지나가는 쪽이 유리하지만, 나무가 뺏뺏하게 겹친 혼효림에서는 네모 박스끼리 겹쳐 오탐이 늘어나면서 U-Net이나 Mask R-CNN처럼 화소 단위로 구획하는 모델이 앞섭니다.

드론과 위성이 아무리 좋아져도 하늘에서는 보이지 않는 나무가 있습니다. 위쪽 수관이 우거진 숲에서는 광학과 열적외선 신호가 맨 위층에서 대부분 되돌아오고, 아래에 있는 나무의 초기 감염은 가려집니다. 한 생태계에서 높은 정확도를 낸 모델도 지형과 수종이 다른 숲으로 옮기면 성능이 낮아질 수 있습니다. 하락 폭은 자료와 지표마다 달라 하나의 수치 범위로 고정할 수 없습니다. 사람이 고사목 수관 경계를 그릴 때 생기는 라벨 차이도 검증 결과를 혼듭니다.

온대 침엽수림에서 배운 모델이 아열대 활엽수림에서 흔들리는 까닭은 모델 성능이 나빠서만은 아닙니다. 잎의 두께와 표면 밀랍, 나무가 자라는 밀도, 토양의 습도까지 다 달라서 모델이 배운 것과 실제로 마주치는 것 사이의 간격이 벌어지기 때문입니다.

다음 단계는 두 방향으로 뻗어 갑니다. 라벨을 매기지 않은 영상만으로도 패턴을 익히는 자기지도학습(Self-Supervised Learning)을 deadtrees.earth 같은 전 지구 데이터베이스와 이어 붙여, 한 숲에서 배운 모델이 다른 숲에서도 통하게 만드는 작업이 한쪽입니다. 다른 한쪽은 열적외선과 고분광, 라이다 센서를 한 무인기에 함께 얹고 기체 안의 작은 연산 장치에서 그 자리에서 바로 계산해, 감염 의심목을 찾은 지 1분 안에 현장으로 알림을 보내는 무인 방제 체계를 완성하는 일입니다. 예찰단의 배낭 속 쌍안경이 언젠가 드론과 AI로 역할을 완전히 넘겨준다면, 그날은 나무가 불어지기 전에 이미 손을 쓴 뒤일 가능성이 큼니다.

근거 및 참고문헌

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. 메트로서울. (2026, 6월 27일). 기장군, 드론 활용 소나무재선충병 '정밀 예찰' 진행. <https://www.metroseoul.co.kr/article/20260627500013> (2026년 8월 2일 접속)
17. 세계환경신문. (2026, 6월 25일). 산림청, 2026년 소나무재선충병 방제 결과 발표. <https://www.e-newsp.com/news/article.html?no=88960> (2026년 8월 2일 접속)
18. 장琮(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. 장艳英(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. 전자신문. (2025, 9월 24일). 산림청, 소나무재선충병 AI로 막는다…방제 실행계획 수립. <https://www.etnews.com/20250924000152> (2026년 8월 2일 접속)

3.3

불법 벌목 음향 감지 및 IoT/블록체인 산림 보호 네트워크

열대우림의 높은 가치에 작은 태양광 패널과 마이크를 단 장치가 매달려 있습니다. 미국 비영리단체 레인포레스트 커넥션의 가디언(Guardian)입니다. 숲의 소리를 기기에서 분석해 전기톱이나 차량처럼 사람의 침입을 알리는 소리가 잡히면 경보를 보냅니다. 단체 공식 사이트는 이런 음향 감시 사업이 지금까지 72만 6천 헥타르가 넘는 지역의 보호에 기여했다고 밝힙니다. 공개된 누적 수치는 사업별 집계 시점과 기준이 달라 장치 수, 녹음 시간, 확인 종 수를 한 묶음의 성과로 비교하기 어렵습니다. 같은 녹음에는 새와 개구리, 곤충의 울음도 남습니다. 침입 경보를 위해 설치한 마이크가 생물다양성을 관찰하는 귀가 되기도 합니다.

인공위성 사진은 나무가 잘려 나간 다음에야 그 사실을 보여줍니다. 구름이 끼면 그마저도 놓칩니다. 순찰대가 걸어서 도는 방식도 넓은 산림 전체를 매일 훑을 수는 없습니다. 전기톱을 켜고 나무를 쓰러뜨리는 바로 그 몇 분 사이에 누군가 알아채야 막을 수 있는데, 기존 방식은 그 몇 분을 잡아내지 못했습니다. 그래서 나무에 매단 마이크와 센서, 저전력 통신망, 소리를 즉시 판단하는 인공지능을 하나로 엮은 감시망이 여러 나라로 퍼지고 있습니다.

자정을 넘긴 시각, 마이크에 두 박자로 끊어지는 파형이 잡히는 순간이 있습니다. 사람이 방아쇠를 당겼다 놓았다 반복할 때 나는 엔진 소리의 리듬입니다. 장치 안의 작은 칩이 이 파형을 몇 초 사이에 훑어, 나뭇가지가 부러지는 소리나 오토바이가 지나가는 소리와 구별해 내고 확신도 숫자 하나를 매깁니다. 그 순간부터 소리를 알아듣는 인공지능과 현장에서 바로 계산을 끝내는 통신망, 잘린 나무가 어디로 흘러가는지 끝까지 따라가는 장부까지, 세 겹의 기술이 함께 움직이기 시작합니다.

엔진톱 소리를 알아듣는 숲속의 귀

동력 장비의 엔진 소리는 벌목을 알리는 단서가 됩니다. 나무줄기나 지지대에 붙은 초저 전력 음향 IoT 센서는 주변 소리를 받아 소형 컴퓨터에서 분석합니다. 안드레아디스 연구진(Andreadis et al., 2021)은 소리의 특징을 뽑아내는 합성곱 신경망을 초저전력 기기에 올리고, 로라 통신으로 경보를 보내는 시제품을 시험했습니다. 논문이 보고한 분류 정확도는 85퍼센트였습니다. 이는 제한된 실험 자료에서 얻은 결과입니다. 숲의 종류와 계절, 장비 소리가 달라지면 같은 정확도가 이어진다고 볼 수 없습니다.

모델을 이렇게 훈련시키는 일은 생각보다 까다롭습니다. 오토바이나 소형 발전기 엔진은 회전 주파수가 전기톱과 비슷해서 초기 모델을 자주 헛갈리게 만들었습니다. 멀리서 나무가 저절로 부러지는 소리, 천둥이 치는 소리도 마찬가지로 혼동을 일으킵니다. 연구진은 실제 벌목 현장과 평범한 숲 곳곳에서 몇 달치 소리를 모아 이런 사례를 하나하나 모델에 가르쳤고, 그 과정을 거치고 나서야 정밀도와 재현율이 실제로 쓸 만한 수준까지 올라갔습니다. 센서 하나가 알아들을 수 있는 거리는 지형과 나무 밀도에 따라 다릅니다. 그래서 넓은 보호구역 전체를 덮으려면 수십, 수백 개의 노드를 격자 모양으로 심어야 하고, 어디에 얼마나 촘촘히 심을지 정하는 일도 별도의 계산이 필요합니다. 사람이 자주 드나드는 길목이나 예전에 벌목이 잦았던 구역부터 우선순위를 매겨 배치하는 식입니다.

소리만으로는 부족할 때도 있습니다. 나뭇잎이 뽀뽀한 밀림에서는 소리가 멀리 퍼지지 못하고 중간에 흩어지기 때문입니다. 프라세티요 연구진(Prasetyo et al., 2018)은 전기톱 소리와 함께, 나무를 자를 때 줄기를 타고 전해지는 미세한 진동을 같이 잡아내는 센서를 만들었습니다. 소리만 듣는 방식보다 헛경보가 크게 줄었습니다. 나무는 소리와 진동이라는 두 가지 신호를 동시에 흘려보내고, 센서는 둘 중 하나가 약해져도 나머지 신호로 판단을 채웁니다.

배터리로 몇 달을 버티는 판단과 드론 출동

오지의 산림에서는 녹음 원본을 계속 서버로 보내기 어렵습니다. 모델을 기기에 넣어 1차 판단을 끝내고, 전기톱일 가능성이 높을 때 좌표와 판정값만 보내면 통신량과 전력 소모를 줄일 수 있습니다. 로라완(LoRaWAN)의 기본 구조는 센서가 게이트웨이와 직접 통신하는 스타 오브 스타 방식입니다. 메시망처럼 이웃 센서가 신호를 릴레이하는 구조와는 다릅니다. 전파가 닿지 않는 골짜기에는 게이트웨이를 더 놓거나 별도의 중계 기술을 붙여야 합니다. 샤르마 연구진(Sharma et al., 2022)의 LoED는 로라와 에지 컴퓨팅을 결합한 산림 감시 구조를 제안했습니다. 모든 숲에서 알림 시간이 1분보다 짧거나 전송량이 40퍼센트 줄었다고 일반화할 현장 실증은 제시하지 않았습니다. 전력 수명도 패널 크기, 그늘, 통신 횟수, 모델 계산량에 따라 달라집니다.

관제센터의 화면에서 보면 이 모든 계산은 지도 위에 점 하나가 켜지는 일로 나타납니다. 좌표와 확신도, 근처 순찰로까지 남은 거리가 함께 뜨고, 당직자는 바로 무전으로 근처 단

속반을 부릅니다. 도로가 거의 없는 오지 산림에서는 이 순간의 몇 분이 나무 한 그루를 살리느냐 마느냐를 가르는 차이가 됩니다. 이 화면을 지키는 사람은 대개 삼림 감시원이나 지역 비영리단체 소속 상근 인력입니다. 인공지능이 걸러 낸 경보라 해도 마지막 출동여부는 사람이 정합니다. 오탐이 반복되는 구역이 있으면 그곳 모델의 민감도를 낮추는 식으로, 사람과 기계가 서로의 판단을 계속 손보는 관계를 유지합니다.

경보가 뜬 좌표에 드론을 보내 영상을 확인하면 소리와 영상을 두 단계로 역을 수 있습니다. 라마단 연구진(Ramadan et al., 2024)은 음향 센서와 무인기를 연결하는 구조를 제안했습니다. 쿤두 연구진(Kundu et al., 2025)은 별도의 영상 자료에서 YOLOv8과 에이전트형 인공지능을 시험했습니다. 이 연구의 최대 재현율은 약 0.24, mAP50은 약 0.07에 머물렀습니다. 두 논문을 합쳐 이미 자동 출동 체계가 현장에 배치됐다고 말할 근거는 없습니다. 당장은 음향 경보 뒤에 사람이 영상을 확인하는 절차가 필요합니다.

그루터기에서 진열대까지 이어지는 디지털 흔적

숲에서 단속반이 아무리 열심히 뛰어도, 이미 잘린 나무가 합법적인 서류를 두르고 시장에 흘러 들어가면 소용이 없습니다. 그래서 벌채된 원목이 운송되고 가공되고 수출되는 전 과정의 기록이 필요합니다. 유럽연합의 산림파괴 방지 규정(EUDR, Regulation 2023/1115)은 목재를 포함한 부속서 I 상품을 유럽연합 시장에 내놓거나 수출하는 사업자에게 산지 지리정보와 실사 의무를 부과합니다. 면적이 4헥타르 이하인 필지는 위도와 경도 한 점으로 표시할 수 있고, 4헥타르를 넘는 필지는 경계를 그린 다각형 좌표가 필요합니다. 모든 목재 제품과 모든 소규모 필지가 다각형 제출 대상인 것은 아닙니다.

블록체인은 여러 참여자가 같은 장부의 사본을 나눠 갖는 분산 원장 기술입니다. 기록이 합의된 뒤 몰래 바뀌었는지는 확인하기 쉽지만, 처음 입력한 산지나 수종이 거짓이면 그 거짓도 그대로 남습니다. 슈토퍼 연구진(Stopfer et al., 2024)과 뉘더·로스(Düdder & Ross, 2017)는 목재 공급망의 기록 공유와 실사 비용을 줄일 가능성을 검토했습니다. 이 기술만으로 합법 목재와 불법 목재의 혼합을 막거나 나무 한 그루마다 이력을 보장할 수 있다는 현장 증거는 없습니다. 리셋 오거니제이션의 ForestGuard는 산림 전용 없는 커피 공급망을 위한 오픈소스 시제품이며 목재 공급망 사업은 아닙니다.

구상도에는 벌채 기계가 좌표와 지름을 기록하고, 운송과 제재 단계의 측정값이 같은 장부에 이어지는 흐름이 그려집니다. 현실에서는 기계 제조사와 업체마다 자료 형식이 다르고, 원목이 여러 판재로 갈라지거나 다른 목재와 섞이는 순간 연결 고리가 약해집니다. 산지 증명은 통관과 거래에 필요한 기록이 될 수 있지만, 그 자체가 높은 판매가를 보장하지는 않습니다. 센서, 검인, 물리 표식, 현장 감사를 함께 묶어야 장부와 실제 목재의 간격을 줄일 수 있습니다.

디지털 장부와 실제 원목을 잇는 물리 표식은 여전히 필요합니다. 바코드, QR코드, RFID 같은 태그를 붙일 수 있지만 벌채 기계의 자동 표식과 제재소 라이다, 나이트 지문, 블록

체인을 한데 묶은 체계는 아직 검증되지 않았습니다. 트리플라트 연구진(Triplat et al., 2026)은 별도의 사진 자료로 원목을 시장 가치 등급에 따라 분류했습니다. 이 연구는 목재 이력 추적이나 3차원 지문 인증 시험이 아닙니다.

한국 기업도 부속서 1의 상품을 유럽연합 시장에 내놓거나 수출하는 공급망에 참여하면 규정의 영향을 받을 수 있습니다. 가구나 합판이라는 이름만으로 대상 여부가 정해지는 것은 아닙니다. 해당 품목의 세관 코드, 기업의 역할, 원료의 공급 경로를 함께 확인해야 합니다.

엇갈리는 선택, 상충하는 장단점

같은 문제를 다루는 연구들이 서로 다른 답을 내놓기도 합니다. 음향 센서 하나만 쓰는 방식은 날씨에 거의 영향받지 않고 소리가 난 지 몇 초 안에 반응하며, 장비값도 상대적으로 쌉니다. 다만 천둥소리나 나뭇가지가 부러지는 소리, 낙엽이 쏠리는 소리에 속아 헛경보를 울리는 일이 있습니다. 위성 레이더(SAR)나 드론 영상까지 함께 쓰는 방식은 숲이 실제로 얼마나 깎였는지 면적까지 그려내지만, 촬영 주기와 구름 탓에 반응이 늦고 설치와 운영에 돈이 더 듭니다. 빠른 반응과 넓은 확인, 이 둘을 한꺼번에 잡는 방법은 아직 없습니다. 헛경보가 반복되면 단속반이 진짜 경보에도 늦게 반응하게 되는 부작용이 생깁니다. 정밀도를 높이는 일은 숫자를 예쁘게 만드는 작업이 아니라, 현장 인력의 신뢰를 지키는 문제이기도 합니다.

블록체인 쪽에서도 선택이 갈립니다. 이더리움 같은 완전 공개형 블록체인은 누구나 장부를 들여다볼 수 있어 투명하지만, 초당 처리할 수 있는 거래 건수가 적고 수수료도 비쌉니다. 벌목 성수기에는 제재소 저울에 원목이 시간당 수백 개씩 오르기도 하는데, 퍼블릭 블록체인의 검증 속도로는 이 흐름을 따라가지 못해 병목이 생깁니다. 그래서 목재 공급망 연구 상당수는 특정 제재소와 정부 기관만 장부에 접근하는 Hyperledger Fabric 같은 프라이빗·컨소시엄형 블록체인 쪽으로 기울어 있습니다. 참여자를 제한하는 만큼 애초에 지키려던 개방성은 그만큼 줄어듭니다.

아직 못 푼 문제와 다음 숙제

원목에 붙인 바코드나 RFID 태그는 험한 산길 운송과 빗물, 진흙 속에서 떨어지거나 망가지기 쉽습니다. 원목을 제재목이나 칩으로 가공하는 순간 표식 자체가 사라지는 경우도 많아서, 가공 이후의 추적이 끊기는 문제는 아직 풀리지 않았습니다. 오지에 설치한 음향 센서는 강한 비바람이나 야생동물 소리에 판단력이 떨어지고, 태양광 배터리로 몇 달씩 버티려면 에너지 관리도 만만치 않습니다. 몇 헥타르짜리 작은 숲을 가진 개인 임가가 낯선 앱으로 벌채 기록을 입력하는 일과, 전담 인력을 둔 대기업이 시스템을 운영하는 일은 진입 장벽의 높이부터 다릅니다. 자본이 적은 소규모 임가나 영세 유통업체 입장에서는 이 장벽 자체가 기술 확산을 가로막는 걸림돌입니다. 장비를 처음 설치하는 비용보다 몇 년째 이어지는 유지 비용이 더 큰 부담이 되는 경우도 많습니다.

배터리와 태양광 패널을 갈아 끼우고, 파손된 노드를 다시 세우고, 모델을 최신 소리 데이터로 다시 학습시키는 작업은 프로젝트 초기의 관심이 식은 뒤에도 누군가 계속 맡아야 하는 일입니다.

유럽연합은 EUDR 적용 시점을 거듭 조정했습니다. 현행 일정에서 일반 사업자는 2026년 12월 30일부터 적용을 받습니다. 자연인 형태의 영세·소기업은 설립일이 2024년 12월 31일까지인 경우 별도 유예 대상입니다. 이들의 적용일은 2027년 6월 30일입니다. 모든 소규모 사업자가 같은 유예를 받는다는 뜻은 아닙니다. 기업의 법적 형태와 설립일을 확인해야 합니다.

나무의 DNA나 안정 동위원소를 분석하는 방식은 원리가 다릅니다. 목재 조직에 남은 유전적·화학적 흔적을 기준 자료와 비교해 종이나 산지를 추정합니다. 표식이 떨어진 뒤에도 조직 일부가 남으면 검사할 수 있지만, 기준 자료의 범위 밖에 있는 산지는 가려내기 어렵습니다. 실험실 분석에는 시간과 비용도 듭니다. 현장에서는 음향 정보, 지리정보, 물리 표식, 서류 검증, 표본 검사를 비용에 맞게 조합해야 합니다. 스탠포드(StanForD)는 산림 기계의 작업·생산 자료 교환 표준이지 국제 목재 무역 서식이 아닙니다. 나라별 실사 자료와 세관 체계를 하나의 블록체인으로 잇는 구상도 아직 통용되는 운영 표준으로 자리 잡지 않았습니다.

근거 및 참고문헌

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. (2026, 1월 28일). 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> (2026년 8월 2일 접속)
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/> (2026년 8월 3일 접속)

8. Ramadan, M. N., Ali, M. A., Khoo, S. Y., & Alkhedher, 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. (2025, 3월 24일). 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>

제4장

스마트 임업 작업과 로봇틱스: 작업 안전, 자율주행 및 임도망 최적화

4.1

임도 및 작업로(Skid Trail) 자동 추출과 지형 맞춤형 수확 계획

화면 속 지도에는 길이 있었습니다. 초록 실선이 산 중턱을 가로질러 매끄럽게 이어졌고, 트럭에 달린 내비게이션은 사백 미터만 더 가면 집재장에 닿는다고 안내했습니다. 커브를 돌아 길이 없었습니다. 지난여름 쏟아진 폭우에 흙이 통째로 흘러내려 노면 절반이 계곡 아래로 무너졌고, 남은 절반에는 팔뚝만 한 잡목이 사람 키높이로 자라 있었습니다. 통나무를 가득 실은 트럭은 그 자리에 멈춰 섰습니다. 기사는 창문을 내리고 시동을 끈 채 한 참을 앉아 있었습니다. 무전으로 사무실을 불러 봤지만 산 사이에서는 신호가 자꾸 끊겼습니다. 결국 사람이 걸어 올라가 무너진 구간의 길이와 경사를 눈으로 재고, 수첩에 스케치를 그려서 내려오는 수밖에 없었습니다. 뒤따라오던 트럭 두 대도 나란히 멈춰 서서 엔진을 공회전시킨 채 기다렸고, 그날 잡혀 있던 배차 계획은 그 자리에서 통째로 어긋났습니다.

식어가는 엔진이 틱, 틱 소리를 냈고, 소나무 수액 냄새가 매캐한 디젤 냄새와 뒤섞여 차 안으로 흘러들었습니다. 지도는 삼 년 전에 만들어진 것이었고, 숲은 그동안 다른 모습이 되어 있었습니다.

이런 장면은 한국 산에서도 낯설지 않습니다. 임도는 해마다 새로 뚫리고, 해마다 무너집니다. 산림청은 2026년도 예산을 3조 260억 원 규모로 편성했습니다. 전년보다 15.6퍼센트, 금액으로는 4091억 원을 늘린 수치입니다. 그중에는 극한기상에도 버티는 튼튼한 임도를 새로 놓고 고치는 일도 2026년 중점 추진 과제로 들어가 있습니다. 산이 가파르고 비가 여름 한철에 몰아 내리는 지형에서는, 한 번 놓은 임도가 몇 해를 못 가 비탈면과 함께 무너지는 일이 되풀이됩니다. 국회는 임도의 계획과 설치, 운영과 유지관리를 하나의 법 체계로 묶은 임도설치법 제정안을 통과시켰습니다. 길을 내는 일이 현장 감독관의 눈대중과 경험만으로 굴러가던 시대가 저물고 있다고 보입니다. 그런데 법과 예산이 아무리 갖춰져도 지도가 현실과 어긋나 있으면 트럭은 여전히 그 자리에서 멈춥니다.

하늘에서 찍은 자료로 땅 위의 길을 자동으로 다시 그리는 기술이 그래서 자리를 잡아가고 있습니다.

하늘에서 다시 그리는 길

전통적인 임도 조사는 사람이 직접 걷거나 차를 몰고 다니며 노면 상태를 눈으로 확인하고 손으로 지도를 고치는 방식에 의존했습니다. 나무가 뺄뺄하게 우거진 수관(canopy, 숲 위쪽을 덮은 나뭇가지와 잎의 층) 아래에서 벌어지는 미세한 지형 변화나 노면 파손, 새로 뚫린 샛길은 다음 정기 조사 때까지 지도에 반영되지 못한 채 방치되곤 했습니다. 이 틈을 메운 것이 항공 레이저 스캐닝입니다. 항공기나 드론에 라이다(LiDAR, 빛을 쏘아 되돌아오는 시간을 재서 물체까지 거리를 알아내는 장치)를 달아 숲 전체를 훑으면, 나뭇잎 사이를 뚫고 지표면까지 도달한 레이저 점들만 골라내 나무를 걷어낸 맨땅의 높낮이, 곧 수치지형모델(DTM)을 그릴 수 있습니다. 같은 점군에서 나무 꼭대기까지의 높이를 담은 수관고모형(CHM)과 비탈이 얼마나 가파른지를 색으로 나타낸 경사도 지도도 함께 뽑아낼 수 있습니다.

도로는 이 세 지도 위에서 뚜렷한 흔적을 남깁니다. 경사가 완만하게 이어지고 표면이 매끄러우며 폭이 일정하게 유지되는 띠 모양이 그것이고, 인공지능은 바로 이 흔적을 학습해서 길을 찾아냅니다.

자료가 실제로 흘러가는 순서는 이렇습니다. 비행기나 드론이 숲 위를 지나가며 점군과 초고해상도 사진을 모으고, 이 자료가 지형 모델과 수관 높이 지도, 경사도 지도로 계산됩니다. 그 위에서 인공지능이 도로처럼 생긴 형태를 찾아 선을 긋고, 그 선을 가로지르는 단면을 잘라 통행 폭과 노면 상태를 가늠합니다. 마지막으로 이 결과가 기존 임도망 지도 파일에 자동으로 반영되어, 끊긴 구간과 침식된 구간, 식생이 침입한 구간이 표시된 새 지도가 완성됩니다. 사람이 걸어서 재고 손으로 고치던 일을, 하늘에서 찍은 자료와 계산이 대신 떠맡는 흐름입니다. 결과물은 대개 지리정보시스템에서 곧바로 열어 볼 수 있는 벡터 파일로 나옵니다. 현장 담당자는 기존에 쓰던 지도 프로그램에 이 파일을 엮기만 하면, 새로 생긴 길과 사라진 길이 다른 색으로 표시된 화면을 볼 수 있습니다.

루셀과 동료들은 이렇게 얻은 점군 자료에서 도로 폭과 경사, 굴곡 같은 일곱 개 지표를 뽑아내고, 이를 경로 탐색 알고리즘과 묶어 기존 임도 지도의 오차를 스스로 교정하는 시스템 알스로즈(ALSRoads)를 2022년에 내놓았습니다. 낡은 벡터 지도를 새 라이다 자료에 겹쳐 놓으면, 끊어진 구간과 새로 뚫린 구간을 프로그램이 픽셀 단위로 짚어내고 갱신하는 방식입니다. 이보다 앞서 2021년 부한과 동료들이 라이다 자료에 경사와 굴곡, 반사 강도 같은 여러 조건을 규칙으로 엮은 혼합 분류 기법을 적용해 임도를 탐지하는 시도를 내놓은 바 있었는데, 알스로즈는 그 뒤를 이어 정확도를 한층 끌어올린 사례로 꼽힙니다. 합성곱신경망(CNN)과 유넷(U-Net) 계열 인공지능 모델도 수치지형모델 위에서 도로 특유의 평평하고 매끄러운 형태를 주변 지형과 구분해내는 데 쓰이고 있습니다.

수관이 촘촘히 닫힌 숲 아래에서도 선 모양의 길을 골라내는 성능이 여러 연구에서 확인됐습니다.

넓은 지역을 빠르게 훑는 쪽으로 눈을 돌린 연구도 있습니다. 물리와 동료들은 2024년 북방 침엽수림에서 단일광자라이다(SPL, 광자 하나하나를 감지할 만큼 예민해서 낮은 출력으로도 넓은 면적을 찍을 수 있는 장비)를 이용해 광역 임도망을 갱신했습니다. 같은 해 비니바르터와 동료들은 큐브셋의 3미터급 PlanetScope 영상에 합성곱신경망을 적용해 임도를 추출했습니다. 연구진은 구름과 연기가 없는 모자이크를 골랐고, 깨끗한 영상이 없는 곳에는 자료 공백이 남았습니다. 광학 위성이 구름을 뚫은 사례는 아닙니다. 시아팔리와 동료들은 2025년 목재 수확 구역에서 항공 라이다와 이동식 슬램 라이다, 아이폰 라이다 자료를 겹쳐 산악 임도의 노면 형태를 복원했습니다. 광역 관측과 근거리 정밀 관측은 서로 다른 문제를 푼니다.

트럭이 지나갈 수 있는 폭

임도가 지도에 선으로 표시돼 있어도, 그 선이 실제로 대형 목재 트럭이 지날 수 있는 폭 인지는 다른 문제입니다. 카르알라이넨과 바가는 각각 2024년과 2020년 논문에서, 라이다 점군에서 도로와 직각 방향으로 지표면 단면을 잘라내 기계학습으로 분석하는 방법을 제시했습니다. 나뭇가지가 위를 가려 하늘에서 도로 폭을 곧바로 재기 어려운 구간에서도, 이 단면 프로파일을 보면 실제 통행 가능한 너비와 노면 침식, 균열, 배수로 막힘, 길가로 침입한 식생의 정도를 가늠할 수 있습니다. 트럭 운전기사가 커브 앞에서 멈추는 대신, 출발 전 사무실 컴퓨터 화면으로 그 구간을 지날 수 있는지 미리 알 수 있다는 뜻입니다. 단면 프로파일은 도로를 옆에서 똑 잘라 본 모양과 비슷합니다.

가운데는 평평하게 다져진 노면이고 양쪽 끝은 배수로를 향해 살짝 기울어져 있으며, 그 바깥으로는 원래 산의 경사가 다시 시작됩니다. 이 굴곡이 라이다 점군 위에서 뚜렷하면 도로 상태가 양호하다는 뜻이고, 굴곡이 흐릿하거나 한쪽이 무너져 있으면 정비가 필요하다는 신호입니다.

흐루자와 동료들은 2025년 드론과 항공 라이다 자료를 결합해 바위, 미처 잘라내지 못한 그루터기, 쓰러진 고사목처럼 임도 개설을 가로막는 자잘한 장애물을 자동으로 찾아내고, 집재 작업지까지 이어지는 최적 노선을 가상으로 미리 그려보는 모델을 내놓았습니다. 실제로 땅을 파헤치기 전에 화면 위에서 길을 먼저 뚫어보는 셈입니다. 일본 연구진 다나카와 동료들은 2025년 산림 작업도(森林作業道)의 개설 노선과 우선순위를 정할 때 외부 자료를 더하지 않고 라이다 해석 결과만으로 판단하는 알고리즘을 실증했습니다. 지형 경사와 미기후, 나무가 쌓여 있는 양, 벌목한 나무를 모아두기 좋은 자리 같은 정보를 라이다 자료 하나에서 뽑아내, 어느 구간부터 길을 내야 하는지 순서를 매기는 방식입니다.

측량팀을 따로 보내지 않고도 우선순위를 정할 수 있다는 점은 예산이 넉넉하지 않은 산림 조합이나 소규모 사업체에 반가운 접근일 가능성이 큼니다. 이런 순위표를 받아 든 산림 기술자는 지도 위에 표시된 구간부터 순서대로 확인하면 됩니다. 예전 같으면 산 전체를 걸어서 훑어야 나올 답을, 이제는 모니터 앞에 앉아서 정리할 수 있습니다.

바퀴가 남긴 흔적을 재다

임도가 트랙이 다니는 정식 도로라면, 작업로 또는 가운로(skid trail)는 하베스터(harvester, 나무를 베어 가지를 치고 일정한 길이로 자르는 대형 벌목 기계)와 포워더(forwarder, 잘라낸 통나무를 실어 나르는 기계), 스키더(skidder, 통나무를 매달거나 끌어서 옮기는 기계)가 반복해서 오가며 만들어내는 임시 이동로입니다. 하베스터가 나무를 베어 놓으면 스키더는 통나무 밑동을 걸어 땅에 끌며 집재장까지 옮기고, 포워더는 통나무를 통째로 짐칸에 얹어 나릅니다. 끌기와 싣기 가운데 어느 쪽을 쓰느냐에 따라 땅에 남는 자국의 모양과 깊이도 달라집니다. 노면을 다지거나 자갈을 깔지 않기 때문에, 무거운 기계가 같은 자리를 여러 번 지나가면 흙이 짓눌리고 바퀴 자국이 깊게 파입니다. 짓눌린 흙은 공기와 물이 통하는 틈을 잃고, 빗물은 스며들지 못한 채 표면을 타고 흘러내립니다.

뿌리가 눌린 남은 나무들은 자라는 속도가 느려지고, 심하면 산사태로 이어지기도 합니다. 장마철이면 바퀴 자국을 따라 빗물이 작은 개울처럼 흐르면서 흙을 실어 나르고, 그 흙은 산 아래 계곡물을 뿌옇게 흐리기도 합니다.

압디와 동료들은 2022년 고밀도 항공 라이다 자료에 유넷 신경망을 결합해, 하층 식생에 일부 가려진 작업로를 픽셀 단위로 골라내는 모델을 만들었습니다. 다져진 흙은 원래 지면보다 낮게 눌러 있고 표면 굴곡도 밋밋해서, 인공지능은 이 미세한 높이 차이와 매끄러움을 정상 지면과 구분하는 실마리로 삼습니다. 사람 눈에는 수풀에 묻혀 잘 보이지 않는 바퀴자국도, 지표면 높낮이 자료로 바꿔놓고 보면 뚜렷한 선으로 드러났습니다. 라테리니와 동료들은 지중해 연안 숲 다섯 곳에서 수확 작업 전후로 드론 라이다를 두 차례 촬영해 비교했습니다. 나무를 베기 전에는 없던 자국이 베어낸 뒤 자료에서 새로 나타나는 자리를, 두 시점의 지표면 높이를 겹쳐 놓고 확인하는 방식입니다.

이들은 음영기복(hillshading), 국지기복모델(LRM), 상대밀도모델(RDM), 그리고 기계학습 기반 프로그램 스킵로드파인더(SkidRoad_Finder)까지 네 가지 분석 기법을 나란히 시험했습니다. 상대밀도모델의 성적이 나머지 세 기법보다 앞섰는데, 정확도 약 73퍼센트에 민감도 66퍼센트였습니다. 같은 자료에서 바퀴 자국의 깊이와 부피, 토양 다짐 위험도까지 입체 수치로 뽑아냈습니다. 백 퍼센트에는 못 미치는 성적이지만, 사람이 숲 바닥을 일일이 걸어 다니며 줄자를 대던 예전 방식과 비교하면 조사 범위와 속도에서 차이가 큽니다.

작업로를 찾아내는 인공지능을 훈련하려면 실제로 다짐이 일어난 사진 자료가 많아야 하는데, 현장에서 그런 사진을 모으는 일은 시간과 비용이 많이 듭니다. 우수이는 2021년 생성적 적대 신경망(GAN, 두 개의 인공지능이 서로 경쟁하며 진짜 같은 가짜 이미지를 만들어내는 기법)으로 이미지를 새로 합성해 학습 표본 부족 문제를 메우고, 작업로 탐지 성능을 끌어올렸습니다.

손해를 피할 길을 먼저 계산하다

작업로를 만든 뒤 손상을 재는 일은 이미 벌어진 문제를 확인하는 절차입니다. 손상 자체를 줄이려면 나무를 베기 전, 기계가 지나갈 길을 지형에 맞춰 미리 골라 두어야 합니다. 고르헨스와 동료들은 2020년 라이다로 알아낸 나무 한 그루 한 그루의 위치와 부피, 지형 경사, 토양 습윤 지수를 한데 묶어 벌채 계획을 자동으로 짜는 모델을 개발했습니다. 유전 알고리즘(자연 선택 과정을 흉내 내어 여러 후보 노선을 만들고 서로 겨루게 한 뒤 더 나은 안만 남기는 계산 방식)과 동적 계획법, 선형 계획법 세 가지를 겹쳐 쓰는 이 모델은 통나무를 옮기는 이동 거리를 줄이는 동시에, 다짐 위험이 큰 구역과 경사가 급한 지형을 자동으로 피해가는 작업로 노선을 골라줍니다.

후보 노선을 수십, 수백 가지 만들어 놓고 조건에 맞지 않는 안을 하나씩 걸러내는 방식이어서, 사람이 손으로 몇 가지 대안만 비교하던 예전 방식과는 검토하는 경우의 수 자체가 다릅니다. 어디로 기계를 몰아야 나무도 덜 다치고 흙도 덜 파이는지, 사람이 눈대중으로 정하던 일을 계산이 대신하는 셈입니다.

피키오와 동료들의 2018년 연구는 이탈리아 산악 지형을 대상으로 지형 경사도와 토양 침식 민감도, 남은 나무의 손상 정도, 케이블 야더와 포워더와 윈치 보조 장비 가운데 무엇을 써야 하는지를 한 화면에서 결정하는 지리정보시스템 기반 의사결정지원모델(GIS-DSS)을 세웠습니다. 이 흐름을 이어받은 에버하드와 동료들은 2025년 비슷한 열개의 모델을 급경사지 전반으로 확장했습니다. 경사가 완만한 곳에서는 바퀴 달린 포워더가 다니지만, 경사가 심해지면 와이어로 통나무를 공중으로 끌어올리는 케이블 야더 쪽으로 판단이 넘어갑니다. 지형 하나하나가 다른 답을 요구하는 셈이라, 표준화된 매뉴얼 한 장으로는 다루기 어려운 영역입니다. 케이블 야더가 와이어로 통나무를 허공에 매달아 옮기는 급경사지와, 포워더가 바퀴로 성큼성큼 오르내리는 완경사지는 애초에 다른 세계입니다.

지리정보시스템 화면 위에서 그 경계선을 미리 그어 두는 편이, 현장에 기계를 들여놓았다가 잘못을 되돌리는 것보다 손실이 적습니다. 이렇게 정해진 노선은 도면으로 출력되어 작업반장에게 전달되거나, 최근에는 태블릿 화면으로 그대로 전송되기도 합니다.

이론과 현장 사이에 남은 간격

여기까지 소개한 연구들을 나란히 놓아보면 서로 부딪히는 지점이 드러납니다. 단일광자 라이다나 큐브셋 위성 영상은 넓은 지역의 주요 임도망을 낮은 비용으로 훑어보는 데는 강하지만, 점군 밀도가 낮아 좁은 작업로나 바퀴 자국까지 구분해내지는 못합니다. 반대로 드론 라이다와 지상 슬램, 스마트폰 라이다를 겹친 모델은 센티미터 단위까지 파고들지만, 자료 처리 시간이 길고 한 번에 찍을 수 있는 면적이 좁습니다. 넓게 볼 것인가, 촘촘히 볼 것인가는 아직 어느 한쪽으로 답이 정해지지 않은 선택으로 보입니다. 고르헨스의 모델이 계산으로 골라낸 이론적 최적 노선과, 압디의 인공지능이 실제 현장에서 기계 운전자가 남긴 바퀴자국을 비교하면 둘이 정확히 겹치지 않는다는 점도 확인됩니다. 지형 장애물이나 그날의 날씨, 운전자의 습관 같은 변수가 계산에 다 담기지 않기 때문입니다.

현장에 내려오면 한계는 또렷해집니다. 여름철 잎이 무성한 숲이나 하층 관목이 뺄뻣한 구역에서는 레이저가 땅바닥까지 닿는 비율이 떨어져 지형 모델과 침식 깊이 추정에 오차가 쌓입니다. 초고밀도 점군 자료의 계산 부담도 큼니다. 한 지역에서 학습한 모델을 수종과 지형이 다른 숲으로 옮겼을 때의 성능 하락 폭은 자료와 평가법에 따라 달라집니다. 새 지역에서는 현장 표본으로 다시 검증해야 합니다.

눈으로 덮인 지형에서는 문제가 또 달라집니다. 러시아 연구진 포돌스카이아와 시니치나는 2026년 크라스노야르스크 지역의 겨울철 임도를 다룬 기계학습 데이터셋을 내놓았습니다. 눈에 덮여 여름 자료로는 확인되지 않던 길들이 겨울에만 나타났다가 해빙기에 사라지는 현상을 기록한 자료입니다. 계절과 위도가 달라지면 같은 알고리즘도 다시 배워야 한다는 뜻입니다. 쓰임새를 넓히는 시도도 이어집니다. 중국 연구진 가오와 동료들은 2026년 여러 시기에 걸쳐 찍은 위성 영상에 딥러닝 모델 딥랩브이3플러스(DeepLabv3+)를 개선해 적용하고, 산불이 났을 때 소방 인력과 장비가 어느 임도로 접근할 수 있는지를 빠르게 판단하는 데 썼습니다. 산불이 잦은 강원도 지형에도 눈여겨볼 접근입니다.

이 모든 모델은 사람이 직접 확인하고 이름 붙인 학습 자료가 있어야 성능이 나옵니다. 임도와 작업로처럼 지역마다 생김새가 다르고 사례 수 자체가 많지 않은 대상은 학습 자료를 모으는 일부터 오래 걸립니다. 우수이의 이미지 합성 기법 같은 데이터 증강 연구가 계속 나오는 이유도 여기에 있습니다. 자료가 부족한 지역일수록 자료를 인위적으로 늘리는 기술에 기대는 비중이 커진다는 뜻입니다.

앞으로 남은 과제 가운데 하나는 인공지능이 통행 가능 여부를 판단한 근거를 현장 기술자가 확인할 화면을 만드는 일입니다. 위험 구간을 골랐다면 경사도와 노면 굴곡을 함께 보여주는 식입니다. 작업로 계획을 기계로 넘길 때는 StanForD 같은 산림기계 생산·작업 자료 표준을 연결 고리로 검토할 수 있습니다. 이 표준만으로 안전 항법이 완성되는 것은 아닙니다. 경로 자료, 기계 제어, 현장 안전 규칙을 따로 검증해야 합니다.

근거 및 참고문헌

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. Hruža, 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., & Tsiaras, 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. 산림청. (2025, 12월 12일). '사람을 살리는 숲, 숲을 살리는 국민' 2026년 중점 추진과제 발표.
<https://v.daum.net/v/20251212095549587> (2026년 8월 2일 접속)
20. 산림청. (2026). 임도 설치·관리 법적 근거 마련, '임도설치법' 국회 통과.
<https://idsn.co.kr/news/view/1065599659428633> (2026년 8월 2일 접속)

4.2

원격 조종 벌채기, 자율주행 포워더 및 임업 로봇 틱스

기사는 사무실 의자에 앉아 있습니다. 등받이는 폭신하고, 발밑에는 카펫이 깔려 있습니다. 책상 한쪽에는 식은 커피 한 잔이 놓여 있고, 창밖으로는 숲 대신 주차장이 내다보입니다. 눈앞에는 모니터 여섯 대가 나란히 놓여 있고, 손에는 게임기 조종간과 비슷하게 생긴 조이스틱이 쥐어져 있습니다. 몇 해 전까지만 해도 이 사람은 지금쯤 가파른 산비탈 위, 흔들리는 조종석 안에서 엔진 소음과 진동을 온몸으로 견디며 나무를 베고 있었을 겁니다. 지금은 다릅니다. 조이스틱을 살짝 기울이면 수백 미터 떨어진 숲속에서 거대한 로봇 팔이 나무를 붙잡고, 화면 속 카메라가 그 장면을 실시간으로 비춥니다.

화면 하나에는 나무 밑동을 물어야 할 집계의 각도가 잡히고, 다른 화면에는 기계 몸체가 비탈 위에서 얼마나 기울어 있는지가 나타나고, 또 다른 화면에는 근처에 사람이나 다른 장비가 있는지를 살피는 영상이 흐릅니다. 예전 조종석에서는 한꺼번에 다 보이지 않던 각도들이 사무실 의자에서는 오히려 한눈에 들어옵니다. 진동도 없고 소음도 없고, 나무가 쓰러질 때 발밑이 울리던 그 감각도 없습니다. 손끝의 아주 작은 움직임만 남습니다.

이런 원격 조종실은 이제 공상과학 영화 속 장면이 아닙니다. 스웨덴 옘살라 인근 옐라(Jälla)에 있는 트뢰드손 임업 원격조종연구소(Troëdsson Forestry Teleoperation Lab)에는 2025년 가을, 코마츠(Komatsu)가 새로 만든 포워더 한 대가 들어왔습니다. 이 포워더는 원격 조종 장치를 갖춘 채로 연구소에 도착했습니다. 연구진은 이 기계를 우메오 대학교와 함께 연구하면서, 로봇이 스스로 판단하도록 훈련시키는 인공지능 모델에 먹일 데이터를 뽑아내고 있습니다. 사람이 다치지 않고, 나무도 다치지 않고, 오래 버틸 수 있는 임업을 만드는 일이 이 연구소가 내세우는 목표입니다.

한국도 비슷한 실험을 이미 시작했습니다. 국립산림과학원은 2025년 8월, 위성항법시스템(GNSS)과 관성항법시스템(INS)을 하나로 묶고 카메라 영상을 학습한 인공지능을 기계 몸체 안에 직접 심은 지능형 산림작업 로봇의 주행 시험 결과를 내놓았습니다. 이 로봇은 임도, 그러니까 산에 낸 작업용 좁은 길을 스스로 알아보고, 길 한가운데 선을 찾아 그 선을 따라 달릴 수 있었습니다. 인공지능이 기계 몸체 안에서 계산을 끝내기 때문에, 통신망이 끊기거나 느려져도 로봇은 멈추지 않습니다. 산속 깊은 곳은 휴대전화 신호조차 잘 잡

하지 않는 경우가 많으니, 이런 방식은 한국의 산림 현장에도 잘 들어맞는 접근으로 보입니다.

사람 대신 기계를 위험한 곳으로 먼저 들여보내는 흐름에는 이유가 있습니다. 체인소로 나무를 베고 끌어내리는 노동에는 가파른 경사, 낙석, 기계 전복, 근골격계 부담이 겹칩니다. 무인화에 앞서 영상과 관성 센서로 작업 자세나 작업 단계를 분류하는 연구도 진행됩니다. 일부 실험은 높은 정확도를 보고했지만 작은 시험셋이나 제한된 행동 구분에서 얻은 값입니다. 실제 산림의 모든 작업 자세와 피로를 같은 수준으로 알아본다는 뜻은 아닙니다.

경북 봉화군에서는 산림청 영주국유림관리소가 하베스터와 포워더, 멀처 같은 고성능 장비를 모아 두고 손불 전용 장비고를 새로 지어 2026년 8월부터 가동합니다. 로봇 한 대를 개발하는 일 못지않게, 그 로봇을 사고 굴리고 고치는 살림을 갖추는 일도 함께 진행되고 있습니다.

45도 비탈에 서 있는 기계

윈치 어시스트(Winch-Assist)라는 장치를 처음 보면 다들 비슷한 질문을 던집니다. 저 굵은 쇠줄이 기계를 정말 붙잡아 줄 수 있냐는 것입니다. 산 위쪽 튼튼한 나무나 전용 달 기계에 강한 쇠줄을 걸고, 그 줄을 아래쪽 벌채 기계에 이어서 끌어당기는 힘을 계속 보태 주는 장치입니다. 굵기가 손목만 한 쇠줄이 산꼭대기부터 기계까지 팽팽하게 뻗어 있는 모습을 멀리서 보면, 마치 기계를 산에 묶어 둔 것처럼 보입니다. 바퀴나 궤도가 미끄러지려는 순간에도 쇠줄이 당기는 힘이 남아 있어서, 기울기 30도에서 45도가 넘는 비탈에서도 기계가 지면을 붙든 채로 작업을 이어갈 수 있습니다. 이 장치가 없던 시절에는 이런 비탈에서도 사람이 체인소를 들고 나무 밑동 사이를 직접 걸어 다녔습니다.

쇠줄 없이 급경사에 기계를 올리면 바퀴가 헛돌면서 흙을 파헤치고, 심하면 기계가 옆으로 넘어가는 사고로 이어집니다.

일본임업기계화협회가 공개한 스마트 임업 실증 결과를 보면, 경사도에 따라 작업 방식이 뚜렷하게 나뉩니다. 경사가 중간 정도인 산에서는 원격으로 조종하는 벌채기가 나무를 자르고, 사람의 손을 거치지 않는 자율주행 포워더가 그 나무를 실어 나릅니다. 예전에는 대여섯 명이 매달리던 집재 작업을 두 사람이 해내는 체계입니다. 일손이 줄어드는 인구 감소사회에서 숲을 어떻게 지킬지는 일본 산림 연구 기관들도 함께 다루는 화두입니다. 산림 노동자는 나이가 많고 수도 꾸준히 줄어드는 형편이라, 젊은 인력을 구하기보다 있는 인력으로 더 넓은 면적을 감당할 방법을 찾는 쪽에 가깝습니다. 경사가 훨씬 가파른 산에서는 사람이 들고 다니던 체인소 작업 자체를 없애고, 윈치 어시스트를 단 원격 조종 벌채기로 바꿉니다.

나무를 끌어내리는 집재 과정도 쇠줄에 매단 집게나 산 위쪽에 세운 탑 모양 장비, 곧 타워 야더가 대신 맡습니다. 사람은 화면 앞에 남고, 위험한 비탈에는 기계만 올라갑니다. 예전에는 벌목꾼 여러 명이 밧줄과 도르래를 손으로 옮겨 걸며 나무를 끌어내렸다면, 지금은 그 밧줄의 한쪽 끝을 기계가 쥐고 사람은 기계가 제대로 움직이는지 화면으로 확인하는 역할로 물러났습니다.

유럽 연구진이 2025년에 내놓은 연구는 이 선택을 데이터로 뒷받침합니다. 지형 경사도와 토양이 깎여 나갈 위험, 남겨 둔 나무들이 다치지 않을 조건을 한꺼번에 계산에 넣는 지리정보시스템(GIS) 기반 의사결정 지원 모델을 만들었습니다. 산 하나를 두고도 구역마다 원치 어시스트를 쓸지, 쇠줄로 통째로 끌어 올리는 가선 작업을 쓸지 답이 달라집니다. 어느 구역은 경사가 급해도 흙이 단단해서 원치 어시스트로 충분하고, 어느 구역은 흙이 무르고 잘 부서져서 기계 바퀴 자국조차 남기지 않는 가선 작업으로 넘어가야 하는 식입니다. 사람의 감이 아니라 지도 위의 숫자가 그 답을 골라 줍니다.

나무가 위성 신호를 가리는 곳

문제는 숲 안으로 깊이 들어갈수록 하늘이 사라진다는 점입니다. 잎이 뺄뺄한 나무 꼭대기, 그러니까 수관이 하늘을 덮으면 위성항법시스템(GNSS) 신호가 아예 끊기거나, 나뭇가지에 튕긴 신호가 뒤섞여 위치가 엉뚱한 곳으로 튀어 버립니다. 내비게이션이 먹통이 된 자동차를 숲 한가운데서 몰아야 하는 셈입니다. 사람이 운전하면 눈으로 보고 감으로 버티지만, 원격이나 자율주행 기계는 그럴 수 없습니다. 그래서 땅 위에 달린 센서만으로 자기 위치와 주변 지도를 동시에 그려내는 기술, 곧 슬램(SLAM)이 반드시 있어야 합니다. 한국 산림 대부분이 경사진 산지에 몰려 있고 나무가 뺄뺄하게 들어선 계곡도 많다는 사실을 생각하면, 이 기술이 남의 나라 이야기만은 아닙니다.

중국 연구진 야오와 동료들은 2025년, 뺄뺄한 산림 안에서 움직이는 임업용 기계를 위해 헥터 슬램(Hector SLAM)이라는 기존 기술을 손봐서 여러 센서를 함께 쓰는 위치추정 알고리즘을 만들고 실제 숲에서 시험했습니다. 먼저 라이다(LiDAR), 그러니까 빛을 쏘고 되돌아오는 시간을 재서 주변 사물까지의 거리를 알아내는 장치가 찍은 점들 가운데 나뭇잎이나 잔가지에 튕겨 생긴 잡음 점을 걸러 냅니다. 그다음 기계가 얼마나 기울었는지 재는 관성측정장치(IMU)의 값을 라이다 정보와 섞어서, 지면이 울퉁불퉁해도 스캔 결과가 뒤틀리지 않게 바로잡습니다. 바퀴가 헛돌 때 생기는 오차를 피하려고, 바퀴 회전수 대신 라이다가 찍은 점들을 직선에 맞춰 비교하는 방식으로 기계가 얼마나 움직였는지를 계산합니다.

시험 결과는 숫자로 뚜렷하게 나타났습니다. 기존 헥터 슬램과 비교하면 오차가 47.65퍼센트 줄었습니다. 지도를 그리는 평균 오차는 4.78센티미터였고, 최대 오차도 8.7센티미터를 넘지 않았습니다. 기계가 멈춰 있을 때 위치 오차는 평균 9.9센티미터였습니다. 속도를 세 단계로 바꿔 가며 달리는 동안에도 수평 오차는 7.9센티미터를 넘지 않았고, 방

향을 가리키는 오차 역시 36.5도 아래로 붙잡아 두었습니다. 몇 센티미터쯤은 별것 아닌 듯 보이지만, 폭이 좁은 임도 위에서 그만큼을 놓치면 바퀴가 길 밖으로 빠지거나 남겨 둔 나무의 뿌리를 짓밟을 수 있습니다.

국립산림과학원이 임도에서 시험한 것과 야오 연구진이 숲 안에서 시험한 것은 겨냥한 곳이 다릅니다. 한쪽은 이미 나 있는 길 위에서 카메라로 중심선을 찾아내는 쪽이고, 다른 한쪽은 길이랄 것도 없는 나무 사이를 라이다로 더듬어 나가는 쪽입니다. 두 시도가 비슷한 시기에 나란히 나온 것을 보면, GNSS 신호가 끊기는 숲을 뚫고 기계를 혼자 움직이게 하려는 노력은 이제 한 나라만의 숙제가 아닐 가능성이 큼니다.

네 다리로 걷는 로봇, 짐을 나르는 로봇

비정형이라는 말이 어울리는 지형이 있다면 산림 바닥이 딱 그렇습니다. 불쑥 솟은 바위, 쓰러진 채 썩어가는 고사목, 무릎까지 오는 관목, 발이 푹 빠지는 도랑이 뒤섞여 있어서 바퀴 달린 기계도, 궤도를 두른 기계도 쉽게 걸려 넘어집니다. 유럽연합의 디지메드포(DigiMedFor) 사업에서는 이 문제를 다리로 풀었습니다. 로봇 공학 회사 보스턴 다이내믹스(Boston Dynamics)가 만든 네발 보행 로봇 스팟(Spot)의 등에 3차원 라이다, 고화질 카메라, 소형 컴퓨터, 특정 빛깔만 걸러내는 광학 필터, GPS 모듈, 로봇의 기울기를 기록하는 장치를 얹어 숲으로 들여보냈습니다. 자갈밭과 관목 덩굴, 경사진 비탈을 오가며 데이터를 모은 뒤 연구진이 남긴 평가는 짧고 분명했습니다. 거의 어디든 갈 수 있다는 것이었습니다.

바퀴였다면 헛돌고 멈춰을 자갈밭에서도, 스팟은 다리를 하나씩 고쳐 디디며 걸음을 이어갔습니다. 스팟은 걸어 다니며 나무 꼭대기와 몸통, 바닥의 3차원 점 구름과 고화질 사진을 실시간으로 모으고, 그 데이터를 온라인 기록 도구와 이어 붙여 나무 한 그루 한 그루의 정보를 담은 디지털 트윈을 스스로 갱신했습니다. 사람이 줄자와 태블릿을 들고 나무 둘레를 하나하나 재던 예전 조사 방식과 비교하면, 로봇이 걸으면서 찍어 내는 점 구름은 나무의 위치와 굵기, 기울기까지 한꺼번에 남깁니다.

스웨덴에서는 걷는 로봇 대신 짐을 나르는 로봇을 시험했습니다. 목재를 실어 나르는 대형 장비인 포워더를 자율주행으로 바꾸고, 그 결과를 기술과 조직, 환경이라는 세 축으로 함께 들여다보는 토(TOE) 분석틀로 뜯어보았습니다. 공장 바닥이나 도심 도로와 달리 숲은 날씨가 자주 바뀌고, 흙의 물기도 구역마다 다르고, 나무가 자라는 모양도 규격이랄 게 없습니다. 그래서 연구진은 기계가 모든 것을 혼자 결정하는 완전 무인화 대신, 노련한 운전자가 큰 흐름을 판단하고 로봇은 장애물을 피하며 남겨 둔 나무를 다치지 않게 하는 좁은 범위의 주행만 맡는 협력 모델을 현실적인 답으로 내놓았습니다. 사람은 오늘 어느 구역부터 실어 나를지, 길이 무너진 곳은 어디를 피해 돌아갈지를 정하고, 로봇은 그 구간 안에서 바퀴 밑에 무엇이 걸리는지, 남겨 둔 나무와 얼마나 떨어져 지나가야 하는지를 스스로 판단합니다.

조직이라는 축에서 보면 임업 회사는 벌목 기사를 원격 조종석에 앉히고, 정비 인력은 자율주행 장비를 다룰 수 있도록 다시 훈련시켜야 합니다. 기계만 바뀌는 것이 아니라 사람이 하는 일의 내용도 함께 바뀝니다.

로봇을 실제 숲에 풀어놓고 비상 제동이나 장애물 인식을 시험하다가 기계가 부서지고 숲도 다칩니다. 핀란드 라플란드응용과학대학과 스웨덴 RISE 연구진은 그래서 가상의 숲을 만들었습니다. 스웨덴 빈델른(Vindeln) 시험림을 지상 라이다 서른 곳과 드론 촬영으로 정밀하게 스캔해서, 가로세로 200미터씩 물리 법칙까지 그대로 옮긴 디지털 쌍둥이 숲을 컴퓨터 안에 지어 올렸습니다. 이 가상 숲 안에서 시점과 햇빛 각도, 나무가 서 있는 위치를 계속 바꿔 가며 합성 데이터인 심포레스트(SimForest)를 만들어 냈습니다. 가상의 작업자가 갑자기 기계 앞으로 걸어 나오는 장면이나 안개가 짙게 깔리는 장면을 수백 번 되풀이해서 만들고, 그때마다 로봇이 멈추는 데 걸리는 시간을 재는 식입니다. 자율주행 로봇은 안개나 비, 역광 같은 조건을 실제 위험 없이 미리 겪어 볼 수 있게 되었습니다.

아직 다 자라지 않은 자동화

네발 로봇과 커다란 자율주행 포워더를 나란히 놓고 보면 둘의 쓸모가 정확히 어긋난다는 사실이 드러납니다. 스팟처럼 걷는 로봇은 자갈밭과 고사목이 뒤엉킨 험지에서 안정적으로 움직이고 하층 식생까지 정밀하게 스캔하지만, 실을 수 있는 무게가 수십 킬로그램에 그쳐서 나무를 베거나 실어 나르는 일 자체는 할 수 없습니다. 반대로 중형 자율주행 포워더나 원격 조종 벌채기는 수 톤에 이르는 통나무를 다룰 수 있는 대신, 지형 기복이 심하거나 나무가 뻗뻗하게 들어찬 구역에서는 바퀴가 파묻혀 꼼짝 못 하거나 흙을 다져서 굳혀 버립니다. 걷는 다리와 구르는 바퀴 중 어느 한쪽이 모든 숲을 다 맡을 수는 없다는 뜻이고, 결국 지형에 따라 서로 다른 몸을 가진 기계를 번갈아 투입하는 쪽으로 갈 수밖에 없어 보입니다. 한쪽이 잘하는 일을 다른 쪽은 하지 못합니다.

가상 숲에서 얻은 결과와 실제 숲의 결과 사이에는 틈이 있습니다. 안개와 비, 렌즈의 흠먼지, 흔들리는 나뭇가지와 역광은 카메라와 라이다의 판정을 흐립니다. 정확도 하락 폭은 센서와 날씨, 시험 자료에 따라 달라 하나의 범위로 고정할 수 없습니다. 합성 자료에서 학습한 모델은 실제 숲의 별도 시험 자료로 다시 평가해야 합니다.

기술이 넘어야 할 문턱도 여전히 높습니다. 스팟 같은 전동 보행 로봇은 야외에서 배터리가 한두 시간이면 바닥나서, 전기를 끌어올 수 없는 오지에서 오래 머물며 감시하는 임무에는 어울리지 않습니다. 울창한 숲을 오래 가로지르다가 슬램 알고리즘이 지나온 길을 다시 알아보는 데 실패하면, 위치 오차가 쌓이고 쌓여서 기계가 정해진 길을 벗어날 위험도 있습니다. 화면 속 지도에서는 기계가 여전히 길 한가운데를 달리고 있는데, 실제로는 나무 사이로 비껴 들어가 있는 상황이 벌어질 수 있다는 뜻입니다. 값비싼 초기 도입 비용은 작은 임가가 감당하기 어려운 수준이고, 무인 기계가 오작동을 일으켰을 때 누가 책임을 지는지에 대한 법과 제도는 아직 마련되지 않았습니다.

로봇이 사람을 알아보지 못해 사고를 냈을 때, 그 책임이 로봇을 만든 회사에 있는지, 로봇을 산 임업 회사에 있는지, 아니면 멀리서 조이스틱을 쥐고 있던 기사에게 있는지조차 아직 답이 정해지지 않았습니다.

앞으로 풀어야 할 숙제는 서로 다른 로봇의 역할을 잇는 일입니다. 드론이 임도 상태를 보고, 보행 로봇이 지형을 살피고, 포워더가 목재를 옮기는 구상입니다. 천 연구진(Chen et al., 2025)은 농림 환경에서 여러 로봇이 흩어져 정보를 모으는 분산 제어 방식을 제안했습니다. 산림에서 이런 체계를 운용하려면 끊기는 통신, 현장 계산, 충돌 방지, 비상 정지를 함께 검증해야 합니다. StanForD 같은 산림기계 작업 자료 표준은 기록 교환을 도울 수 있지만 로봇 안전을 보장하지는 않습니다. 정지 시간은 기계의 속도와 제동거리, 감지 범위, 작업자와의 안전거리를 바탕으로 정해야 합니다.

안전 인터록을 법으로 정하고 국제 표준에 데이터를 맞추는 행정 절차는 로봇을 새로 설계하는 일보다 시간이 더 걸릴 수 있습니다. 오작동 책임을 어느 회사, 어느 기관이 지는 지조차 정해지지 않은 상태에서는 값비싼 장비를 선뜻 들여놓을 임업 회사도 많지 않을 겁니다. 이 기계들이 산림 현장 곳곳에 퍼지기까지 남은 걸림돌은 기술보다 제도 쪽에 더 많이 쌓여 있는 것으로 보입니다.

근거 및 참고문헌

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 [동영상]. YouTube.
<https://www.youtube.com/watch?v=58rjC9O-1Mk> (2026년 8월 2일 접속)
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/> (2026년 8월 2일 접속)
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 공개강연회, 2050년의 숲, 인구감소사회에서 숲의 역할 [동영상]. YouTube. <https://www.youtube.com/watch?v=OEhqSNoACCo> (2026년 8월 2일 접속)
10. Japan Forest Machinery Association. (2026). Part 3, FY2025 스마트 임업기계 및 목질계 신소재 심포지엄 [동영상]. YouTube. https://www.youtube.com/watch?v=uzSCOk_qQI8 (2026년 8월 2일 접속)
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. 로봇신문. (2025, 8월 6일). 국립산림과학원, 탑재형 AI 기술 기반 지능형 산림작업 로봇 개발.
<https://www.irobotnews.com/news/articleView.html?idxno=41635> (2026년 8월 2일 접속)
14. 이즈보험 뉴스. (2026, 7월 31일). 숲의 미래를 신다, 고성능 임업기계장비고 본격 운영.
https://dazabi.com/insurance_magazine/article.php?id=40560 (2026년 8월 2일 접속)

4.3

컴퓨터 비전·Wearable 센서 기반 근로자 작업 안전 예찰

새벽 여섯 시, 강원도 인제의 산판에서 한 벌목 작업자가 안전모 끈을 두 번 당겨 조입니다. 체인톱 기름통 뚜껑을 열고 사슬유를 채우는 손끝이 아직 차갑습니다. 안전모를 벗어 뒤집어 보면 챙 안쪽에 손톱만 한 회색 부품이 하나 붙어 있습니다. 관성측정장치(IMU, Inertial Measurement Unit)라는 이름의 이 부품은 몸이 얼마나 기울어졌는지, 걸음이 얼마나 빠르지를 재는 작은 센서입니다. 이 부품이 언제부터 헬멧 안에 들어와 있었는지, 그는 정확히 기억하지 못합니다. 회사가 새 헬멧을 나눠준 지 석 달, 남은 감각은 무게가 20그램쯤 늘었다는 것뿐입니다. 엔진을 당겨 시동을 거는 순간, 새소리가 끊기고 엔진음이 골짜기를 채웁니다. 오늘 벨 나무는 셋, 어제보다 경사가 가파른 구역입니다.

고용노동부는 2026년 3월, 2025년 한 해 동안 쌓인 산업재해 통계를 발표했습니다. 임업과 어업을 합친 업종의 사고 사망자는 18명으로, 전년대비 11명 늘어난 숫자입니다. 두 업종을 가르는 통계가 따로 없어 임업만의 숫자는 알 수 없지만, 사업장 규모가 작고 안전관리 체계가 열은 업종으로 도소매업과 나란히 꼽혔다는 사실은 눈에 걸립니다. 떨어지는 나무에 깔리거나 경사면에서 미끄러져 장비에 눌리는 사고가 해마다 되풀이해서 보고됩니다. 산업안전보건법 시행령 제24조는 임업을 제조업, 하수·폐기물 처리업과 함께 묶어 놓았습니다. 상시근로자 20명 이상 50명 미만 사업장이라면, 정식 안전관리자 대신이라도 안전보건관리담당자를 한 명은 반드시 두어야 합니다. 법이 사람을 지정해 놓아도, 가파른 경사지에서 혼자 체인톱을 든 사람의 자세까지 담당자가 실시간으로 볼 수는 없습니다.

임업 현장에서 일하는 사람들의 나이는 해마다 올라가고, 몸이 예전 같지 않은 채로 가파른 산을 오르내리는 이들도 늘고 있습니다.

임업이 위험한 이유는 새삼스럽지 않습니다. 경사지와 불규칙한 지형, 무거운 원목, 체인톱 같은 고위험 동력 기계가 한 작업장 안에 다 모여 있습니다. 미국 노동통계국(BLS)이 집계한 2023년 자료에서 벌목 노동자의 사망률은 10만 명당 98.9명입니다. 전체 근로자 평균인 3.5명과 비교하면 28배에 이르는 수치입니다. 나무를 베고(Felling), 가지를 치고(Limbing), 통나무를 자르는(Cross-cutting) 과정에서 근로자는 몸을 굽히고 비틀고 한 쪽으로 기운 자세를 오래 유지합니다. 이런 자세가 쌓이면 근골격계 질환, 영어 약자로

WMSD(Work-related Musculoskeletal Disorders)라 부르는 병으로 이어집니다. 허리 디스크나 어깨 힘줄염처럼 이름은 저마다 다르지만, 굽고 비틀린 자세가 오래 쌓여 생긴다는 원인만은 같습니다.

이 자세를 점수로 매기는 도구가 OWAS(Ovako Working Posture Analysis System)입니다. 등과 팔, 다리가 어떤 각도로 있는지, 짐을 얼마나 들었는지를 보고 네 단계 위험 등급으로 나누는 방식입니다. 1등급은 그대로 두어도 되는 자세, 4등급은 지금 당장 자세를 바꿔야 하는 위험한 상태를 가리킵니다. OWAS 말고도 RULA나 REBA 같은 사춘별 평가법이 있지만, 어느 쪽이든 사람이 화면을 들여다보고 손으로 점수를 매기는 틀은 같았습니다. 예전에는 전문가가 현장 영상을 한 프레임씩 눈으로 돌려 보며 등급을 매겼습니다. 시간이 오래 걸렸습니다. 사람마다 판단이 갈리는 문제도 있었습니다. 숲 전체 노동자를 계속 지켜보는 일은 애초에 사람 손으로 감당할 규모가 아니었습니다.

이 틈을 메우려고 컴퓨터 비전과 웨어러블 센서를 결합한 자동 평가 체계가 최근 몇 년 사이 빠르게 등장했습니다.

카메라가 자세를 읽는 법

인체 포즈 추정은 영상 속 어깨, 팔꿈치, 무릎 같은 관절 위치를 점으로 찍어 추적합니다. 포르쿠오(Forkuo)와 동료들은 이미지와 인체 골격 연결선을 함께 넣어 ResNet-50 모델을 학습시켰습니다. OWAS 등급을 완전히 같은 수로 맞춘 시험 이미지 252장에서 정확도와 F1 점수는 99.8퍼센트였습니다. 작은 균형 시험셋의 결과이므로, 가림과 조명이 다른 실제 산림 전체에서 같은 성능이 확인됐다고 읽어서는 안 됩니다.

같은 연구진의 2025년 논문은 판정 시간과 평가자 사이의 일치도를 비교했습니다. 모델은 사람보다 19배에서 53배 빠르게 등급을 냈습니다. 사람 평가자 사이의 Fleiss' kappa는 0.28에서 0.49였습니다. 이 수치는 처리 속도와 사람 사이의 판단 차이를 보여 줍니다. 모델이 사람보다 정확하거나 촬영 각도 변화에 흔들리지 않는다는 증거는 아닙니다. 자동 판정은 시간을 줄일 수 있지만, 기준이 된 사람의 라벨과 촬영 조건이 잘못되면 같은 오류를 빠르게 되풀이할 수 있습니다.

가벼운 모델을 쓴 연구도 있습니다. 포르쿠오 연구진은 Inception V3와 SqueezeNet에 이미지 임베딩을 적용했습니다. 개발 과정에서는 84퍼센트와 89퍼센트라는 값이 나왔습니다. 보지 못한 자료의 성능은 약 49퍼센트에서 60퍼센트였습니다. 논문은 스마트폰 현장 배치를 실증하지 않았습니다. 모델 크기가 작다는 사실과 산속 휴대전화에서 안정적으로 작동한다는 사실은 구분해야 합니다.

몸에 붙이는 센서와 소리

카메라에는 눈에 보이지 않으면 소용없다는 약점이 있습니다. 산의 아래쪽, 나뭇잎과 가지가 우거진 임관 하부에서는 렌즈가 작업자의 몸을 반토막만 담거나 아예 놓치기 쉽습니다. 이 사각지대를 메우는 쪽이 웨어러블 센서입니다. 스마트폰이나 스마트워치에 든 3축 가속도계와 자이로스코프, 소음 노출량을 재는 소음계(Noise Dosimeter)를 몸이나 장비에 붙이면 카메라 렌즈 없이도 움직임과 진동을 쫓 수 있습니다. 체인톱을 켜 손의 떨림, 어깨가 기울어지는 각도, 걸음이 흔들리는 정도가 전부 숫자로 바뀝니다. 나무 그늘이 얼마나 짙든, 안개가 끼서 카메라 렌즈가 뿌예지든 상관이 없습니다.

보르츠 연구진은 통나무를 자르는 조재 작업에서 작업자와 체인톱에 붙인 가속도계, 소음계 자료로 일곱 모델을 시험했습니다. 등에 붙인 가속도계 하나를 썼을 때 정확도는 63퍼센트였고, 체인톱의 가속도와 소음을 합친 일부 설정에서는 99.8퍼센트가 나왔습니다. 연구가 구분한 것은 작업, 휴식, 동작 같은 활동 상태입니다. 무리한 관절 꺾임이나 피로를 같은 정확도로 진단한 시험은 아닙니다. 센서 위치와 행동 범주가 달라지면 성능도 다시 재야 합니다.

한국에서도 센서를 넣은 안전모가 소개됐습니다. 2025년 5월 21일 보도에서 아스가드는 건설근로자용 스마트 안전모 ‘TUGU’에 충격과 온습도 센서, 카메라, 무전 기능을 넣었다고 밝혔습니다. 제조사 설명을 전한 기사이며 독립된 현장 성능 검증은 아닙니다. 임업 전용 제품도 아닙니다. 산림청은 2020년 10월 국립칠곡숲체원에서 산불 진화대원용 입는 로봇과 지능형 안전모 시제품을 선보였습니다. 이후 이 장비가 전국 벌목 현장의 표준 지급품이 됐다는 자료는 확인되지 않습니다.

땀과 거친 작업 탓에 센서가 몸에서 떨어지는 일, 배터리가 하루 작업 시간을 못 버티는 일, 작업자가 아예 착용을 꺼리는 일까지, 웨어러블 기술은 카메라와는 다른 종류의 걸림돌을 안고 있습니다. 연구자들 스스로도 이 세 가지를 카메라 방식과 대비되는 뚜렷한 기술적 상충으로 짚어 두었습니다.

안전모가 말을 걸 때

자세를 재는 일과 별개로, 대형언어모델을 임업 안전 상담에 쓸 수 있는지 살핀 연구도 나왔습니다. 아리미즈 겐고(Arimizu Ken-go, 2026)는 임업의 사고 상황과 전문 질문에 대한 모델의 답을 평가해 가능성과 한계를 정리했습니다. 과거 재해 보고서와 현장 사진을 받아 위험도를 자동 판정하는 완성형 현장 체계가 배치된 연구는 아닙니다. 걸린 나무처럼 맥락이 중요한 위험은 모델의 답만으로 처리하지 말고 숙련자의 확인을 거쳐야 합니다.

교육 쪽에서는 하야시(Hayashi) 연구진이 2025년과 2026년에 걸쳐 발표한 연구가 눈에 띕니다. ChatGPT 기반 대화형 에이전트를 임업 안전 교육 카드 게임의 자문 역할로 붙였습니다. 카드 한 장마다 벌채 현장에서 실제로 벌어질 법한 상황과 질문이 적혀 있고,

참가자가 고른 답이 맞는지를 에이전트가 되짚어 줍니다. 이 게임을 대학생과 미숙련자를 대상으로 적용 전후를 비교했습니다. 직장 안전 행동을 재는 40개 문항 척도에서 안전 소 통, 개인 안전 확보 등 다섯 개 영역 모두 통계적으로 뚜렷한 점수 상승을 보였습니다. 다만 초기에는 착오도 있었습니다. 범용 언어모델은 연료 용기의 재질이나 체인톱 날을 가는 법(目立て) 같은 임업 특화 질문에 여덟 번이나 엉뚱한 기계공학적 오답을 내놓았습니다.

임업 안전 지식 카드를 프롬프트에 미리 넣어 두는 인컨텍스트 러닝(In-context Learning) 방식으로 커스텀 모델을 다시 짰더니, 오답은 두 번으로 줄었습니다. 질문과 정답 예시를 프롬프트 앞머리에 미리 붙여 놓으면, 모델은 그 예시를 참고 삼아 답을 고릅니다. 모델을 처음부터 다시 훈련시키는 것보다 빠르고 값싼 방법입니다. 현장 음성을 문자로 바꾸는 자동음성인식 단계에서는 체인톱 작업복 하의인 '차프스(Chaps)'나 걸린 나무를 뜻하는 '카카리기' 같은 전문용어가 엉뚱한 글자로 바뀌어 버리는 문제도 확인되었습니다. 이를 막으려고 이 말이 맞느냐고 되묻는 확인 절차가 표준 지침으로 제안되었습니다.

에얼리히쑤머(Ehrlich-Sommer)와 동료들이 2025년에 소개한 ForestGPT는 오스트리아 푸타 엑스포에서 약 1메가바이트 분량의 행사 자료를 바탕으로 방문객 질문에 답한 대화형 시제품입니다. 검색 증강 생성, 산림 성장 시뮬레이터, 센서·드론·기계 자료 연결은 뒤이은 개발 단계입니다. 현재 시제품은 이 기능들을 모두 갖춘 산림 현장용 모델이 아닙니다.

감시받는다는 느낌

현장에서 이 기술이 실제로 쓰이는 그림을 그려 보면 이렇습니다. 사무실 모니터에 그날 작업한 벌목 작업자 여럿의 위험 등급이 실시간으로 뜨고, 4등급에 달하는 순간 담당자의 휴대전화로 알림이 갑니다. 안전관리 쪽에서는 반가운 그림이지만, 안전모를 쓰고 있는 사람 쪽에서 보면 다른 그림이기도 합니다.

기술이 쌓일수록 상충도 뚜렷해집니다. 카메라는 몸에 아무것도 붙이지 않아도 되지만 가지에 가리면 놓칩니다. 웨어러블 센서는 가려도 놓치지 않지만 땀과 배터리, 착용 거부감이라는 짐을 남깁니다. 범용 언어모델은 여러 언어로 유연하게 대화하지만 임업 지식이 얇아 헛소리를 만들어 냅니다. 지식을 미리 넣어 둔 커스텀 모델은 오답은 줄이지만, 카드에 없는 질문이 들어오면 정보가 없다며 입을 닫습니다. 정확한 답과 유연한 대화 사이에서 저울추가 한쪽으로 완전히 기울지 않습니다. 어느 쪽도 혼자서는 충분하지 않습니다.

근본적인 문제는 실험실의 분류 모델과 현장의 비상 제동 사이에 간격이 남아 있다는 데 있습니다. 통신이 끊기는 산림에서 자세 판정이나 사람 인식을 기계 제어와 묶은 완성형 검증은 아직 드뭅니다. 실제 벌목 현장에서는 흙탕물과 추위, 통신 두절, 기계별 제동거리까지 함께 시험해야 합니다.

카메라를 현장에 상시로 켜 두는 일에는 또 다른 무게가 있습니다. 자기 자세를 하루 종일 렌즈가 지켜본다는 사실을 반기는 노동자는 많지 않습니다. 안전모 안쪽 센서가 회사 서버로 보내는 데이터를 누가 갖고, 얼마나 오래 저장하고, 사고가 났을 때 말고 다른 용도로 쓰이는지, 이 질문에 명확히 답한 연구는 아직 없는 것으로 보입니다. 사무직을 대상으로 한 인공지능 감시 논쟁에서도, 회사가 안전을 이유로 모은 데이터가 다른 평가에 슬며시 쓰이는 사례가 거듭 지적됩니다. 국토교통부와 국토안전관리원은 2026년 5월, 스마트 안전장비 활용 가이드라인을 고쳤습니다. 웨어러블 카메라를 포함한 근로자 보호 장비를 세 개 대분류와 일곱 개 중분류 체계로 다시 짰습니다. 이 가이드라인은 건설 현장을 겨냥해 만들어졌습니다. 임업 현장을 따로 겨누는 지침은 2026년 8월까지도 나오지 않았습니다.

카메라와 센서, 서버 사용료를 매달 감당해야 하는 쪽은 대부분 몇 명이 전부인 영세 벌목 사업체입니다. 값을 감당하지 못해 도입을 미루는 사업장과, 비용을 감당해도 데이터를 어떻게 쓸지를 두고 근로자와 씨름하는 사업장 사이에서, 기술은 아직 널리 퍼지지 못했습니다. 원격 조종 벌채기와 자율주행 포워더가 사람을 위험한 비탈에서 끌어내는 동안에도, 손으로 체인톱을 쥐고 남는 사람은 당분간 사라지지 않습니다. 안전 예찰 기술이 겨누는 대상은 결국 그렇게 남아 일하는 사람들입니다.

Grad-CAM과 SHAP 같은 기법으로 인공지능이 신체의 어느 부위를 보고 위험하다고 판단했는지 색으로 짙어 보여 주는 설명 가능한 인공지능, XAI(Explainable AI) 대시보드가 다음 단계로 거론됩니다. 지식 증류(Knowledge Distillation)로 모델을 작게 줄여 통신이 끊긴 산속 단말기에도 넣겠다는 계획도 논문에 나와 있습니다. 카메라와 웨어러블, 언어모델을 하나의 파이프라인으로 묶어 근골격계 질환을 막고 사고를 초기에 잡아내는 체계를 세우는 일은, 계획으로는 이미 여러 논문에 적혀 있습니다. 그 계획이 실제 벌목 현장의 표준 장비로 지급되는 시점과, 수집된 영상과 신호를 누가 얼마나 오래 보관하는지를 정하는 규정은, 둘 다 아직 나오지 않았습니다.

등급을 매기고 위험을 알리는 쪽은 갈수록 정교해지는데, 그 결과를 누구 손에 맡길지를 정하는 규정은 아직 그만큼 정교해지지 못한 셈입니다.

근거 및 참고문헌

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 어드바이저를 붙인 임업 안전교육 게임의 실천과 학습효과 검증, 사전사후 비교 및 발화분석 기반 평가. *Journal of Occupational Safety and Health*, 18/19, 1-12. <https://doi.org/10.2486/josh.JOSH-2025-0011-GE>
8. Arimizu, K. (2026). 대규모 언어모델을 이용한 임업 안전 지원의 가능성과 한계에 관한 연구. *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 임업, 목재산업 작업안전 추진 웨비나, 전체판 [동영상]. YouTube. <https://www.youtube.com/watch?v=Q1w9DxFpgE8> (2026년 8월 2일 접속)
10. Japan Forest Machinery Association. (2026). Part 3, FY2025 스마트 임업기계 및 목질계 신소재 심포지엄 [동영상]. YouTube. https://www.youtube.com/watch?v=uzSCOk_qQI8 (2026년 8월 2일 접속)
11. 고용노동부. (2026, 3월 31일). 2025년(누적) 산업재해 현황 부가통계. https://www.moel.go.kr/news/enews/report/enewsView.do?news_seq=19159 (2026년 8월 2일 접속)
12. 국토교통부·국토안전관리원. (2026, 5월 6일). 건설현장 스마트 안전장비 선택·활용 더 쉬워진다. <https://v.daum.net/v/20260506110012733> (2026년 8월 2일 접속)
13. 기계설비신문. (2025, 5월 21일). 아스가드, 건설근로자 맞춤형 스마트 안전모 'TUGU' 개발. <https://www.kmecnews.co.kr/news/articleView.html?idxno=41084> (2026년 8월 2일 접속)
14. 보안뉴스. (2020, 10월 31일). 입는 로봇, 지능형 안전모로 산림재해 대응한다. <https://m.boannews.com/html/detail.html?idx=92245> (2026년 8월 2일 접속)

제5장

지속가능한 산림농업(Agroforestry)과 목재 공급망 DX

5.1

산림농업 시스템에서의 수분 이용 효율(WUE) 및 생태계 서비스 최적화

인도 북부 편자브 지방, 이른 아침 밀밭에 해가 걸리면 밭 한가운데 줄지어 선 포플러 나무들의 그림자가 서서히 움직이기 시작합니다. 키가 20미터 넘는 이 나무 열은 아침에는 밭 서쪽 고랑을 덮었다가, 한낮에는 그림자가 나무 발치로 잣아들고, 저녁이 되면 다시 반대편 고랑을 뒤덮습니다. 흙바닥에서 올라오는 열기가 아지랑이처럼 흔들리고, 밀 이삭은 초여름 바람에 낮게 몸을 눕혔다 일어서기를 되풀이합니다. 나무 그늘이 지나간 곳과 그렇지 않은 곳에서 밀 색깔이 미묘하게 다르다는 사실은 그 밭에서 여러 해를 보낸 농부라면 누구나 압니다. 농부에게 이 나무는 두 얼굴을 가진 이웃입니다. 뿌리는 땅속 깊이 뻗어 밀이 마셔야 할 물을 함께 빨아들이지만, 줄기와 잎은 뜨거운 바람을 막고 흙 속 물기를 가둡니다. 나무가 물을 뺏는 도둑인지 지켜 주는 파수꾼인지는 눈으로 봐서 답이 나오지 않습니다.

이 포플러는 그늘로만 서 있는 나무도 아닙니다. 줄기가 굵어지면 성냥개비나 합판, 종이 원료로 팔려 나가는 목재이기도 해서, 밀농사와 나무 농사를 한 밭에서 함께 짓는 셈입니다. 뿌리 밑에서 무슨 일이 벌어지는지, 잎 하나하나가 물을 얼마나 내보내는지를 숫자로 재야 답을 구할 수 있습니다.

이렇게 나무와 작물, 때로는 가축까지 한 땅에서 함께 기르는 농법을 산림농업(Agroforestry)이라고 부릅니다. 나무뿌리는 작물과 물을 두고 경쟁하면서도 그늘과 낙엽으로 증발과 토양 유실을 줄일 수 있습니다. 수확량을 실제증발산량으로 나눈 수분 이용 효율은 이 두 작용의 결과를 보여 주는 지표입니다. 유엔 식량농업기구가 널리 쓰는 통계에서 농업은 세계 담수 취수량의 70퍼센트 이상을 차지합니다. ‘소비량 80퍼센트’와 ‘취수량 70퍼센트 이상’은 같은 지표가 아닙니다.

한국에서 농지에 나무를 심을 때의 법적 지목과 공익직불금 자격은 토지 상태, 재배 방식, 해당 사업 요건에 따라 판단됩니다. 나무를 심는 순간 자동으로 산지가 되거나 직불금 자격을 잃는 것은 아닙니다. 도입을 검토하는 농가는 관할 지방자치단체와 농산물품질관리원에 해당 필지의 요건을 먼저 확인해야 합니다.

뿌리 밑의 셈법

농학자들이 이 셈을 하는 방식은 두 가지로 나뉩니다. 하나는 땅에 손을 넣어 직접 재는 방식입니다. 시간영역반사법(TDR)과 주파수영역반사법(FDR) 탐침을 뿌리 근처 흙에 꽂으면, 흙 알갱이 사이 물기가 전기 신호를 얼마나 빨리 통과시키는지로 수분 함량을 알아냅니다. 이 값을 얻으려면 연구자가 새벽부터 장화를 신고 밭 여기저기에 탐침을 꽂고 다녀야 합니다. 흙 상태에 따라 신호가 흔들리기 때문에, 같은 곳이라도 며칠에 걸쳐 반복해서 재야 믿을 만한 값이 나옵니다. 중성자 프로브와 자동기상관측소까지 더하면 나무뿌리와 작물 뿌리가 같은 층의 물을 얼마나 나눠 쓰는지 시간 단위로 기록할 수 있습니다.

밀 기반 산림농업을 정리한 2026년 체계적 문헌고찰 논문에 따르면, 연구자들은 이런 현장 측정값을 크롭왓, 아쿠아크롭, 앱심 같은 이름의 작물, 흙 수분 계산 프로그램에 넣어 뿌리 층마다 물이 어떻게 오가는지 시뮬레이션합니다.

이 정도 손 작업으로는 밭 전체를 살필 수 없기 때문에 위성이 그 일을 맡습니다. 센티넬이나 랜드샷 같은 위성이 찍은 영상에서 정규수분지수(NDWI, 식물 잎이 반사하는 빛의 파장을 분석해 물기를 가늠하는 지수)나 지표면 온도 같은 값을 뽑아내고, 이를 세발이나 메트릭이라는 이름의 증발산 계산 모델에 넣으면 밭 구역별로 어디가 마르고 어디가 젖어 있는지 지도로 그릴 수 있습니다. 여기에 랜덤 포레스트, 즉 여러 개의 결정 나무 모형이 각자 답을 낸 뒤 다수결로 최종 답을 정하는 기계학습 방식을 비롯해 서포트벡터머신, 인공신경망, XGBoost 같은 알고리즘을 얹으면, 흙 상태와 관개 일정, 나무 그늘의 정도를 한꺼번에 학습해 수분 이용 효율을 예측하는 모형이 만들어집니다.

이 문헌고찰은 나뭇가지를 숙아 내는 가지치기와 차음 간격 조정만으로도 밑에 있는 작물 표면에서 헛되이 날아가는 수분을 줄이고 관개수가 땅속으로 스며드는 비율을 높여 시스템 전체의 물 효율을 뚜렷하게 끌어올릴 수 있다고 밝혔습니다. 농부에게 이 계산이 중요한 까닭은 뚜렷합니다. 관개용수를 언제 얼마나 줄지 하루 이틀 어긋나면 그해 수확이 크게 흔들리기 때문입니다. 가뭄이 잦아지는 요즘 같은 시기에는 물 한 방울의 값어치가 예전과 다릅니다.

위성이 그리는 산림농업 지도

인도 서쪽 해안 고아 지역에는 쿨라가르라고 부르는 전통 농법이 있습니다. 아레카야자 나무 사이에 후추나 카카오, 바나나를 함께 심어 그늘과 습도를 나눠 쓰는 방식입니다. 쿨라가르 밭에 들어서면 머리 위로 야자 잎이 만든 지붕이 있고, 그 아래 후추 덩굴이 야자 나무 줄기를 감고 오르며, 밭밑에는 바나나와 향신료 작물이 줄지어 있습니다. 층마다 다른 식물이 다른 높이에서 물과 별을 나눠 쓰는 구조입니다. 위성 영상만으로 이 밭과 옆에 있는 순수 야자 농장, 자연림을 구분하기는 쉽지 않아 보입니다. 우타파 연구진은 센티널 위성 영상에 랜덤 포레스트와 그래디언트 부스팅, 서포트벡터머신 세 가지 기계학습 모델을 나란히 돌려 이 구분에 도전했습니다. 일반 식생지수는 잎이 얼마나 푸른지만 보기 때문에 관개가 잘 된 산림농업 밭과 우기 직후의 자연림을 혼동하기 쉽습니다.

물기에 반응하는 지수를 따로 쓰는 이유가 여기에 있습니다. 결과는 뚜렷했습니다. 나뭇잎과 작물 잎에 든 물기를 그대로 반영하는 수분지수인 NDWI2가 세 모델 모두에서 밭 구분 정확도를 결정짓는 핵심 변수로 나타났습니다. 그래디언트 부스팅 모델은 정확도 0.86, 유연히 맞힌 값까지 걸러 낸 카파 계수는 0.83으로 나타나 세 모델 중에서도 판정이 안정적이었습니다.

작물과 나무가 뒤섞인 밭을 위성이 이렇게 읽어 낼 수 있다는 사실은 산림농업 면적을 넓히려는 정책 담당자에게 쓸모 있는 도구를 하나 쥐여 줍니다. 눈으로 밭을 일일이 찾아다니지 않고도 어느 지역에 산림농업이 얼마나 퍼져 있는지 해마다 지도로 확인할 수 있기 때문입니다. 한국 산림청이 해마다 진행하는 임업경영실태조사도 이와 비슷한 통계를 다루지만, 농가 설문과 현장 조사에 크게 기대고 있어 위성 지도로 자동 갱신되는 체계까지는 아직 이르지 못한 것으로 보입니다.

커피나무 그늘의 정밀 계산

인도네시아 커피밭에서는 질문이 조금 다르게 던져집니다. 상층에 그늘을 드리우는 차음수를 어디에 몇 그루 심어야 커피나무가 직사광선과 수분 스트레스에서 벗어나는가라는 질문입니다. 리들로와 동료 연구진은 그래프 이론에서 가져온 리즈(RIDS) 알고리즘을 이용해 이 배치 문제를 풀었습니다. 쉽게 말하면, 밭을 점과 점을 잇는 그물망으로 놓고, 그늘을 지나치게 많이 만들지 않으면서도 밭 구석구석까지 그늘이 고르게 닿도록 나무를 심을 곳을 계산하는 방식입니다.

리들로 연구진은 그늘나무와 센서 위치를 그래프로 계산했습니다. 커피나무 96그루와 그늘나무 26그루를 둔 시나리오에서는 연간 이산화탄소 고정량이 520킬로그램으로 산출됐습니다. 그늘나무 31그루를 격자로 둔 시나리오의 값은 620킬로그램이었습니다. 장기간 현장에서 잦은 탄소량이 아니라 모형의 계산값입니다.

연구진은 시공간 그래프 신경망으로 10일에서 20일 뒤의 상대습도와 이산화탄소 농도를 예측했습니다. 설명력은 설정에 따라 0.73에서 0.81이었습니다. 이 결과는 모형 비교에서 얻은 값입니다. 커피 농가가 실제 관개 일정에 써서 수확량이나 물 사용량을 개선했다는 장기 현장 시험은 아닙니다.

물 너머의 생태계 서비스

생태계 서비스란 숲과 습지, 갯벌처럼 사람이 손대지 않아도 자연이 거저 내주는 값을 말합니다. 맑은 물을 걸러 주고, 홍수를 늦추고, 벌과 새를 살려 두어 다음 세대 작물의 수분을 돕는 일 모두가 여기에 들어갑니다. 산림농업이 주는 값도 수확량과 물 효율에서 그치지 않습니다. 나무뿌리는 흙이 빗물에 쓸려 내려가는 것을 막고, 낙엽과 그늘은 새와 곤충에게 보금자리를 내줍니다.

브라질 남부 아열대 지역을 20년 동안 관찰한 실바 연구진의 위성 시계열 분석은 이 값을 숫자로 보여 줍니다. 2000년 무렵 산림농업이 차지한 서식지 면적은 400헥타르 남짓이었습니다. 2020년에는 그 면적이 660헥타르 가까이 늘었습니다. 같은 기간 흩어진 자연림들을 잇는 서식지 응집 지수도 함께 올라갔습니다. 논밭 사이사이 파편처럼 흩어져 있던 자연림들이 산림농업 띠를 따라 다시 이어지기 시작했다는 뜻입니다.

그렇다고 산림농업이 자연림을 완전히 대신하지는 못합니다. 도허티와 해거(Doherty & Häger, 2026)는 코스타리카의 자연림과 커피·목초지 산림농업을 원격탐사와 현장 자료로 비교했습니다. 지상부 탄소 저장량과 나무 종 다양성은 토지 유형마다 달랐습니다. 탄소가 많은 곳과 나무 종 다양성이 높은 곳의 공간 일치도는 자연림에서 25.5퍼센트였습니다. 산림농업은 경작지의 나무와 연결성을 늘릴 수 있지만 자연림과 같은 탄소·생물다양성 값을 보장하지 않습니다.

제말(Jemal, 2026)은 에티오피아 산림농업의 원격탐사와 딥러닝 연구 흐름을 정리한 체계적 문헌고찰을 F1000Research 버전 1로 공개했습니다. 합성곱신경망, U-Net, 비전 트랜스포머를 한 현장에서 직접 비교한 실험 논문은 아닙니다. 가나에서는 세계자원연구소가 전이학습으로 자연림, 단일 조림지, 산림농업을 구분하는 연구를 내놓았습니다. 분류 결과를 정책에 쓰려면 각 유형의 현장 표본과 오분류 지도를 함께 공개해야 합니다.

인도에서는 인도구스베리 나무 그늘 아래 대두를 심는 차반 연구진의 실험이, 그늘 세기를 조절하는 것만으로 메마른 흙에서도 대두의 생리와 수확량이 달라진다는 사실을 보여 주었습니다. 진저 연구진은 약초와 향료 나무를 함께 심고 토양 수분을 붙잡아 두는 기술을 더한 실보아로마틱 시스템으로 황폐해진 땅의 흙 구조를 되살리고 이산화탄소를 가두는 실험을 실증했습니다. 약초와 향료 나무가 뿌리내리기 전까지 황폐지는 대개 비가 오면 흙탕물이 골을 파며 흘러내리고, 마른 철에는 먼지만 날리는 맨땅입니다. 나무를 심고 물길을 다스리는 구조물을 함께 놓은 뒤로는 같은 땅에서 흙이 쓸려 나가지 않고 뿌리 사이로 빗물이 스며드는 시간이 늘었습니다. 결이 다른 나라, 다른 나무를 다루는 이 연구들

은 방향만은 같습니다. 나무와 작물을 함께 심은 땅이 흙을 붙잡고 물을 아끼고 탄소를 가둔다는 방향입니다.

2022년에 나온 리뷰 논문은 이런 개별 사례들을 흙 건강이라는 틀로 묶어, 산림농업이 화학비료에 기대지 않고도 지력을 회복시키는 몇 안 되는 농법이라고 설명했습니다.

숫자가 놓치는 것들

같은 위성 사진을 놓고도 모델마다 답이 갈리는 경우가 있습니다. 고아 쿨라가르 연구에서 랜덤 포레스트와 그래디언트 부스팅 모델은 산림농업 면적을 서포트벡터머신보다 넓게 잡았습니다. 나무와 작물이 촘촘하게 뒤섞인 밭의 복잡한 경계를 앞의 두 모델은 비선형적으로 넉넉하게 읽어 낸 반면, 서포트벡터머신은 경계선을 보수적으로 그리는 성향 탓입니다. 위성 수분지수 하나만 보는 모델은 넓은 지역의 가뭄 상태를 빠르게 계산하지만, 작물이 자라는 단계별로 흙 속 수분이 어떻게 바뀌는지는 잡아내지 못합니다. 반대로 사물인터넷 센서와 신경망을 결합한 모델은 정밀하지만, 센서를 심고 관리하는 비용이 그만큼 따라붙습니다.

위성이나 드론으로 찍은 사진은 10미터에서 30미터 크기 화소 하나에 나무 수관과 작물, 맨흙 반사광까지 뒤섞여 담깁니다. 위성 사진 한 칸 안에 나무 꼭대기와 그 밑 그늘, 흙, 작물이 모두 들어가 있는 모습을 그려 보면, 그 안에서 반사되어 돌아오는 빛은 이미 여러 색이 섞인 물감과 다르지 않습니다. 컴퓨터가 이 뒤섞인 색에서 작물만의 신호를 다시 갈라내는 일은, 이미 섞어 버린 물감에서 원래 색을 되짚어 찾는 일과 비슷합니다. 산림농업의 물 수지와 흙 속 탄소 변화는 못해도 10년은 지켜봐야 흐름이 보이는데, 지금 나온 딥러닝 연구 대부분은 몇 년짜리 단기 자료에 기대고 있어 기후변화에 대한 적응력을 끝까지 검증하기 어렵습니다.

개발도상국의 외딴 농가일수록 사물인터넷 센서를 설치할 돈과 무선 통신망이 부족해, 똑똑한 물 관리 기술이 정작 그 기술이 절실한 밭에는 닿지 못하는 경우가 많습니다.

나무가 물을 뺏는지 지켜 주는지를 놓고 밭밭에서 품었던 물음은 유럽중기예보센터의 계산에서도 돌아왔습니다. 2026년 연구에서 전략적으로 식재 위치를 고른 시나리오는 증발산량을 최대 60퍼센트 줄이고 지하수 보유량을 최대 세 배로 늘렸습니다. 이 결과는 모형 시나리오이며 모든 농경지의 보장값은 아닙니다.

연구자들은 다음 단계로 물리 법칙과 인공지능망을 잇는 작업을 준비하고 있습니다. 크롭 왓이나 애플처럼 물리 방정식에 기반한 기존 모형의 제약 조건을 물리 정보 신경망(PINN)이라는 딥러닝 구조 안에 통째로 넣어, 위성 화소가 뒤섞이는 오차를 줄이면서 미기후와 수분을 한 번에 계산하려는 시도가 진행 중입니다. 건조 지역과 아열대, 열대를 아우르는 공개 데이터셋을 만들고, 그 데이터로 학습한 가벼운 인공지능 모델을 농민의 휴대전화에 담아 실시간으로 관개 시점을 알려 주는 방향도 함께 논의되고 있습니다. 농민의 휴대전

화에 담긴 이 가벼운 모델은 아침마다 그날 밭에 물을 얼마나, 언제 줘야 하는지 문자 한 줄로 알려 주는 수준까지 그려지고 있습니다. 인터넷이 자주 끊기는 산간 마을에서도 전화기 안에서 계산이 끝나므로 서버에 신호를 보내고 받는 시간이 필요 없습니다.

다만 이런 그림은 아직 실험실 논문 속 제안에 가깝고, 실제 밭에서 여러 해 검증을 거친 사례는 많지 않습니다.

유엔 식량농업기구는 인도의 농장림과 산림농업 체계가 연간 목재 수요의 약 93퍼센트를 공급한다고 설명합니다. 이는 모든 목질 제품의 국내 소비를 뜻하는 수치가 아니라 연간 timber demand를 가리킵니다. 소농의 나무 생산을 넓히려면 묘목과 기술, 판로, 토지·수확 권리를 함께 살펴야 합니다.

근거 및 참고문헌

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 *Emblica 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, 4월 14일). 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> (2026년 8월 2일 접속)
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., Loregian, 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> (2026년 8월 2일 접속)
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/forest-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> (2026년 8월 3일 접속)
13. Food and Agriculture Organization of the United Nations. (2026). AQUASTAT methodology: Water use. <https://www.fao.org/aquastat/en/overview/methodology/water-use> (2026년 8월 3일 접속)

5.2

ICT 기반 목재 트레이서빌리티(QR/전자태그) 및 목재 품질 자동 감정

나카자와 연구팀의 시스템 구성도에는 하베스터가 측정한 원목 정보가 서버로 넘어가는 선이 그려져 있습니다. 벌채 기계가 지름과 길이를 재고, StanForD 형식으로 작업 자료를 남기는 구조입니다. 이 기록에 물리 태그와 운송·제재 기록을 이어 붙이면 원목 추적 체계를 설계할 수 있습니다. 다만 인용 자료는 모든 원목에 QR코드나 RFID가 자동 부착되는 제재소를 보여 주지 않습니다.

전자 기록은 벌채 위치와 측정값을 빠르게 공유할 수 있습니다. 기록과 실제 원목을 끝까지 잇는 일은 별개의 문제입니다. 태그가 떨어지고 원목이 판재로 갈라지면 연결 고리가 끊어질 수 있습니다.

QR코드와 RFID는 기록을 부르는 열쇠일 뿐, 원목의 신원을 스스로 보증하지는 않습니다. 공급망 추적은 벌채 기록, 물리 표식, 운송 인수인계, 제재 뒤의 묶음 관리, 현장 감사를 함께 갖춰야 작동합니다.

과거의 목재 유통은 종이 전표와 손글씨 야장에 기대어 굴러갔습니다. 사람이 적은 숫자에는 오차가 끼어 들고, 합법 원목 사이에 불법 목재가 섞여도 걸러 내기 어려웠습니다. 산림청은 합법목재 교역촉진제도를 1년간 시범 운영했습니다. 본격 시행일은 2019년 10월 1일이었습니다. 대상 목재와 목재 제품을 수입하는 업체는 통관 전에 원산국에서 합법적으로 벌채됐음을 입증해야 합니다. 산림청은 국가별 표준지침을 배포하고 있습니다. 하베스터 센서와 전자태그, 인공지능은 서류 심사의 빈틈을 줄일 보조 수단입니다.

원목에 새기는 두 번째 이름

벌채 현장에 들어간 스마트 하베스터는 나무를 베어 정해진 길이로 자르는 조재 작업을 하면서 동시에 데이터를 씁니다. 절단 헤드에 붙은 센서가 원목의 지름과 길이, 나무가 얼마나 휘어 자랐는지를 초 단위로 재고, 위성항법장치가 정확한 벌채 위치를 함께 기록합니다. 사람이 눈대중으로 하던 계산을 기계가 나무를 자르는 그 짧은 순간에 끝내 버리는 셈입니다.

나카자와 연구팀은 StanForD를 바탕으로 하베스터의 원목 측정값과 품질 판정을 공유하는 시스템을 개발했습니다. 연구 범위는 산림기계의 생산·작업 자료 연결이며, 일본 전역의 거래와 정산 체계를 다룬 것은 아닙니다.

하베스터 자료만으로는 나무를 끝까지 따라갈 수 없습니다. 원목에 바코드나 RFID를 붙이고 다음 사업자가 이를 인수하는 방식은 설계할 수 있습니다. 벌채기의 자동 태그 부착과 단면 나이트의 3차원 지문, 블록체인 대조를 한데 묶은 운용 체계는 아직 검증되지 않았습니다.

RFID는 비접촉식으로 식별번호를 읽을 수 있지만 태그 가격과 내구성, 부착 인력, 가공 뒤의 묶음 관리가 필요합니다. 태그만으로 원목의 산지와 합법성을 보증할 수는 없습니다.

트럭에 실린 나무를 셈하는 법

집재장에 쌓인 원목 더미나 수송 트럭에 실린 통나무의 부피를 재는 일은 오랫동안 사람이 손으로 직접 하던 일이었습니다. 줄자로 원목 하나하나의 지름을 재고 더미 전체 부피를 어림으로 계산했습니다. 최근 몇 년 사이 이 작업이 스마트폰 카메라와 아이패드엔 내장된 라이다 센서로 넘어가고 있습니다. 라이다는 빛을 쏘아 되돌아오는 시간을 재서 물체까지의 거리를 알아내는 장치인데, 이 원리로 원목 더미의 굴곡을 촘촘한 점 구름으로 그려 냅니다.

엘리아스 연구팀의 2025년 시제품 연구와 우자르 연구팀의 튀르키예 시험, 푸르푸르스트 연구팀의 비교 연구는 스마트폰 사진과 라이다로 원목 더미 부피를 추정했습니다. 촬영 기반 측정은 현장 시간을 줄일 가능성이 있지만, 수종과 적재 모양, 촬영 각도에 따라 오차가 달라집니다.

트럭 적재함의 통나무 사이에는 빈 공간이 있습니다. 니처 연구팀은 라이다 점군으로 적재물의 바깥 형태와 목재 부피를 추정하는 알고리즘을 평가했습니다. 실제 목재 부피를 오차 없이 확정하거나 검량소의 정산까지 자동화한 연구는 아닙니다.

라이다 추정치를 거래에 쓰려면 기준 측량과 반복 비교해 허용오차를 정하고, 센서 교정과 이의 제기 절차를 마련해야 합니다. 알고리즘의 시험 성능만으로 대금 정산의 법적 기준이 저절로 정해지지는 않습니다.

카메라가 옹이를 찾아내는 순간

제재소에 들어온 원목과 판재의 값은 결국 흠집이 결정합니다. 옹이가 몇 개 박혀 있는지, 갈라진 틈이 있는지, 색이 바랬는지에 따라 같은 나무라도 등급이 갈립니다. 이 판정은 오랫동안 등급판정사의 눈에 맡겨져 있었습니다. 숙련자라도 하루 종일 판재를 들여다보면 판단이 흔들리고, 사람마다 기준이 조금씩 달라서 같은 판재를 두고 등급이 엇갈리는 일도 있었습니다. 같은 원목을 오전에 본 판정사와 오후에 본 판정사가 서로 다른 등급표를 써낸 사례도 드물지 않았습니다. 산드빅 연구팀이 2024년에 정리한 문헌 검토에 따르면, 통나무 재적과 등급을 매기는 기술은 2018년 무렵을 기점으로 다른 기계학습 방식을 밀어내고 딥러닝 쪽으로 빠르게 기울었습니다.

치우 연구팀은 2026년 PADDL-YOLO라는 목재 표면 결함 탐지 모델을 내놓았습니다. 시험 자료에서 정밀도는 91.5퍼센트, 재현율은 91.4퍼센트였습니다. mAP@0.5는 95.0퍼센트였습니다. 계산량은 기준 모델보다 25.6퍼센트 줄었습니다. 경량화는 현장 장비에 옮길 가능성을 높이지만, 제재소 컨베이어에서 상용 속도로 장기간 운용됐다는 증거는 아닙니다.

같은 목표를 향해 다른 길을 걷는 연구도 많습니다. 허 연구팀은 완전합성곱신경망으로 목재 내부 결함의 위치를 짚어 냈고, 가오 연구팀은 이미지 인식에 널리 쓰이는 ResNet-34 신경망에 전이 학습을 적용해서 옹이를 종류별로 갈랐습니다. 우르보나스 연구팀은 단판 표면의 흠집을 찾아내는 데 Faster R-CNN을 썼습니다. 룡 연구팀은 개선된 YOLOv5s로, 장·자오 연구팀은 YOLOv7로 컨베이어벨트를 지나가는 판재의 결함을 실시간으로 잡아냈습니다. 오즈칸 연구팀은 너도밤나무 판재 2,972장으로 마스크 R-CNN 계열 신경망을 학습시켜서 흠집을 찾아냈고 정확도는 90.90퍼센트에 이르렀습니다. 황 연구팀은 조금 다른 방식을 택해서, 옹이 표면의 질감과 국소적인 형태 정보를 뽑아낸 뒤 인공신경망에 입력해서 건전한 옹이와 썩은 옹이, 빠진 옹이를 구분해 냈습니다.

접근 방식은 저마다 달라도 목표는 하나입니다. 사람의 눈이 하루에 볼 수 있는 판재의 양을 카메라와 신경망으로 몇 배 늘리는 일입니다.

등급판정사가 하루 종일 들여다보던 판재는 이제 카메라 앞을 지나가고, 사람은 기계가 애매하다고 표시해 둔 몇 장만 다시 확인합니다. 화면에 뜬 판재 중 일부는 노란 테두리로 표시됩니다. 신경망이 확신하지 못하고 사람에게 넘긴 판재입니다. 등급판정사는 이제 컨베이어벨트 전체가 아니라 이렇게 걸러진 몇 장에만 집중하면 됩니다. 일이 없어졌다기보다, 사람이 서 있던 곳이 컨베이어벨트 앞에서 모니터 앞으로 옮겨간 셈입니다.

사진 한 장으로 값을 매길 수 없는 이유

결함을 찾는 일과 시장 가치 등급을 매기는 일은 다릅니다. 트리플라트 연구팀은 2026년 슬로베니아 원목 경매장의 사진 5,549장으로 시장 가치 등급 분류 모델을 비교했습니다. 여러 모델이 전체 정확도 90퍼센트를 넘겼지만 낮은 가치 등급의 성능은 상대적으로 약했습니다. 높은 전체 정확도만 보면 드문 등급의 오분류를 놓칠 수 있습니다.

사진 분류는 촬영된 표면과 자료의 등급 라벨을 배웁니다. 내부 결함과 수분, 강도처럼 사진에 없는 요인은 직접 판단하지 못합니다. 학습 자료에서 드문 등급은 표본 부족의 영향을 더 크게 받습니다.

시장 가치 판정에는 사진 밖의 검사와 거래 조건도 들어갈 수 있습니다. 따라서 사진 모델은 선별을 돕는 도구로 쓰고, 낮은 확신도와 드문 등급은 사람이 다시 확인하는 편이 안전합니다.

경매장에서 등급을 잘못 매기면 돈이 바로 움직입니다. 상급 원목을 하급으로 잘못 분류하면 산주가 제값을 받지 못하고, 반대로 하급 원목이 상급으로 둔갑하면 그 원목을 사들인 제재소가 나중에 판재를 켜고 나서야 손해를 알아챱니다. 자동 감정 시스템에 사람의 최종 확인이 여전히 남아 있는 까닭이 여기에 있습니다.

PADDL-YOLO의 mAP@0.5와 트리플라트 연구의 분류 정확도는 서로 다른 자료와 과제에서 나온 값입니다. 숫자를 곧바로 견주면 안 됩니다. 표면 결함 탐지, 시장 가치 분류, 내부 강도 평가는 따로 검증해야 합니다.

빗물이 지우는 것과 값이 막는 것

벌채 현장의 물리 표식은 진흙과 비, 충격, 수피 박리로 읽기 어려워지거나 떨어질 수 있습니다. RFID도 부착 방식과 운송 충격에 따라 손상될 수 있습니다. 나이트 3차원 지문은 이 문제를 대신할 검증된 운영 체계로 자리 잡지 않았습니다. 표식의 내구성 시험과 인수인계 기록, 표본 감사가 함께 필요합니다.

2차원 카메라의 한계도 여전합니다. 겉면 영상은 나무 속에서 진행되는 썩음이나 안쪽에 숨은 균열까지는 잡아내지 못해서, 제재 이후에야 예상 밖의 불량률이 드러나는 경우가 생깁니다. 이 모든 장비를 갖추는 데 드는 비용은 영세한 제재소와 임가에는 상당한 부담입니다. 고성능 라이더 스캐너와 엑스레이 CT 장비, 현장용 인공지능 컴퓨터를 한꺼번에 들려면 적지 않은 초기 투자가 필요한데, 소규모 사업장일수록 그 문턱을 넘기 어렵습니다. 국립산림과학원처럼 연구 예산을 가진 기관은 이런 장비를 시범 도입할 수 있지만, 산 하나를 낀 영세 임가나 동네 제재소에는 그림의 떡에 가깝습니다. 기술이 있어도 손에 넣을 형편이 안 되는 곳에서는 사람이 손으로 재고 눈으로 등급을 매기는 예전 방식이 그대로 이어집니다.

포쿠오와 보르즈가 2026년에 임업 작업 전반의 인공지능 적용 사례를 정리한 검토에서도, 목재 추적과 품질 판정은 벌채 기계화 다음으로 빠르게 커지는 영역으로 꼽혔습니다.

엑스레이 CT와 음향 검사는 사진이 보지 못하는 내부 결함을 확인하는 보조 수단입니다. 노체티 연구팀은 참나무 원목에 사진 측량과 음향 조사를 나란히 적용했습니다. 블록체인 연구는 여러 사업자가 같은 기록을 공유하고 사후 변경을 확인하는 방안을 제안합니다. 거짓 최초 입력, 태그 교체, 실제 원목과 기록의 단절까지 없애지는 못합니다. EUDR 준수에는 지리정보, 실사, 위험평가, 문서 보존이 함께 필요합니다. StanForD 같은 작업 자료 표준이나 블록체인은 준수 증빙을 돕는 수단일 뿐, 규정 준수를 보장하지 않습니다.

근거 및 참고문헌

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. 林野庁. (2025, 6월 3일). 令和6年度 森林・林業白書. <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. 산림청. (2019, 9월 18일). 울 10월 1일부터 수입목재 합법성 입증해야 통관 가능.
https://www.forest.go.kr/kfswweb/cop/bbs/selectBoardArticle.do?bbsId=BBSMSTR_1036&nttId=3136493
(2026년 8월 3일 접속)

5.3

순환 바이오경제(Circular Bioeconomy)와 산림 탄소 신용(Carbon Credit)

벌채가 끝난 비탈에는 가지와 수피, 밑동이 남습니다. 이를 현장에 남겨 토양으로 돌려보낼지, 파쇄해 연료나 소재 원료로 옮길지는 산불 위험과 양분 순환, 운반 거리, 가공 수요를 함께 보고 정해야 합니다. 수분이 많으면 운송 중량은 늘지만 연료의 발열량은 낮아질 수 있습니다. 무게만으로 값을 매기면 품질과 에너지 효율이 어긋납니다.

목질 부산물에서는 리그닌과 셀룰로오스를 뽑아 소재를 만들 수 있고, 규격에 맞는 원목은 공학목재가 될 수 있습니다. 모든 가지와 뿌리가 경제성 있는 원료가 되는 것은 아닙니다. 수거·건조·운송·가공에서 드는 에너지와 산림에 남겨야 할 유기물의 양을 빼고 계산해야 합니다. 탄소 크레딧도 사업 등록과 추가성, 기준선, 검증 요건을 통과해야 발행됩니다.

부산물에서 신소재로

나무는 크게 세 가지 물질로 이루어져 있습니다. 섬유질을 이루는 셀룰로오스(Cellulose), 그 사이를 채우는 헤미셀룰로오스(Hemicellulose), 그리고 나무를 뿔뿔하게 세워 주는 리그닌입니다. 종이나 펄프를 만드는 공장에서는 오랫동안 리그닌을 골칫거리로 여겼습니다. 펄프를 뽑아내고 남은 검은 폐액에 섞여 있다가 태워지거나 버려지는 부산물에 지나지 않았습니다. 일본 산림종합연구소(FFPRI)와 일본 환경성이 2025년과 2026년에 걸쳐 내놓은 자료를 보면, 리그닌의 화학 구조를 다시 짜 맞추는 개질 리그닌(Modified Lignin) 기술이 이 상황을 바꾸고 있습니다. 열에 강하고 잘 부러지지 않도록 구조를 바꾼 개질 리그닌은 자동차 부품이나 전자제품 겉면, 생분해 수지 원료로 쓰입니다.

나무 섬유를 나노미터 굵기로 풀어낸 셀룰로오스 나노파이버(Cellulose Nanofiber, CNF)도 석유계 플라스틱을 대신해 쓰이는 곳이 늘고 있습니다. 개질 리그닌으로 만든 부품은 자동차 실내 마감재나 전자제품 겉면처럼, 손으로 만졌을 때 나무인지 플라스틱인지 구분이 잘 안 가는 데에 먼저 쓰이고 있습니다.

목질 소재가 석유계 소재보다 온실가스를 덜 낸다고 미리 정할 수는 없습니다. 원료의 산지, 가공 열원, 약품, 제품 수명, 재사용과 폐기를 전과정평가로 비교해야 합니다. 순환 바이오경제는 재생 가능한 생물자원을 오래 쓰고 다시 순환시키려는 틀입니다. 왕(Wang)

연구팀은 기후 스마트 임업을 인공지능 기반 산림관리와 기후 적응·완화를 잇는 관점으로 정리했습니다.

도시에 심는 숲

나무 속 탄소를 오랫동안 가두어 두는 방법 가운데 하나는 그 나무로 건물을 짓는 것입니다. 널빤지를 결이 엇갈리게 겹겹이 붙인 직교집성재(Cross-Laminated Timber, CLT)와 기둥과 보를 만드는 데 쓰는 글루램(Glulam) 같은 공학목재는 콘크리트나 철골 대신 써도 웬만큼 층수를 올릴 수 있을 만큼 튼튼합니다. 이런 두꺼운 목재로 짓는 중고층 건물을 매스 티버(Mass Timber) 건축이라고 부릅니다. 일본 임야청과 환경성은 도시의 철근 콘크리트 구조물을 목조로 바꾸어 나가자는 정책을 숲의 나라, 나무의 도시라는 이름으로 밀고 있습니다. 실제로 목조 건축 현장에 가 보면 콘크리트 타설 현장과 분위기부터 다릅니다. 레미콘 소음과 먼지 대신, 공장에서 미리 잘라 온 목재판을 크레인으로 얹고 볼트로 조이는 작업이 이어집니다.

콘크리트를 굽고 철을 녹이는 과정에서 나오는 이산화탄소부터 줄어 들고, 다 지어진 건물은 그 뼈대 속에 나무가 흡수했던 탄소를 수십 년에서 수백 년 동안 그대로 품고 있습니다. 산에 있던 나무가 도심 한복판으로 옮겨 가 탄소를 가두는 두 번째 숲 노릇을 하는 셈입니다.

목조건축의 기후효과는 목재가 합법적이고 지속가능한 산림에서 공급되고, 벌채 뒤의 산림 탄소가 회복되며, 실제로 배출이 큰 재료를 대신할 때 생깁니다. 건축 수요가 늘었다고 재조림과 산림 투자가 자동으로 따라오는 것은 아닙니다. 공급망 인증과 산림경영 규칙이 그 조건을 만들어야 합니다.

엘리트 나무와 순환 벌채

나무의 나이와 탄소 축적은 한 문장으로 정리되지 않습니다. 큰 개체목은 나이가 들어도 해마다 더 많은 탄소를 더할 수 있다는 세계 자료가 있습니다. 임분 면적당 순생산은 수령이 높아지며 낮아지는 경우가 있지만 수종, 토양, 교란, 관리 이력에 따라 달라집니다. 모든 숲에 통하는 ‘30년에서 40년 정점’은 없습니다. 육종과 유전체 선발은 생장이나 목재 형질을 고르는 시간을 줄일 수 있지만, 생장 개선 폭도 수종과 시험 조건마다 다릅니다.

벌채가 탄소에 이로운지는 정해진 수령만으로 판단할 수 없습니다. 산림에 남는 탄소, 벌채와 운송의 배출, 목제품에 저장되는 기간, 콘크리트·철강 대체효과, 재조림의 성공 여부를 같은 전과정평가에 넣어야 합니다. 오래된 천연림을 보전하는 선택과 생산림을 순환 경영하는 선택은 숲의 기능과 지역 조건에 따라 답이 달라집니다. 빠른 생장 품종을 넓게 심을 때에는 병해충과 유전적 획일화 위험도 함께 계산해야 합니다.

탄소를 세는 눈, 위성과 인공지능

나무를 베어 소재로 쓰고 다시 심는 순환이 탄소중립에 도움이 되는지는 숫자로 검증해야 합니다. 숲의 탄소 변화를 측정하고 보고하며 제3자가 확인하는 절차를 MRV라고 부릅니다. 한국의 산림탄소상쇄제도에는 신규 조림·재조림, 산림경영, 목제품 이용, 산림 바이오매스 에너지 이용 같은 사업 유형이 있습니다. 사업 유형에 이름이 들어 있다고 잔가지 더미가 곧바로 감축 실적이 되는 것은 아닙니다. 등록된 방법론과 기준선, 추가성, 모니터링, 검증을 통과해야 합니다.

흡수량 측정에는 지상 표본과 원격탐사를 함께 씁니다. GEDI는 궤도를 따라 파형 라이다 표본을 남기고, Sentinel-2 두 위성 체계는 적도 부근에서 약 5일 간격으로 같은 곳을 다시 봅니다. Landsat 한 위성의 재방문 간격은 약 16일입니다. 구름 때문에 실제로 쓸 수 있는 광학 영상 간격은 더 길어집니다. 지상 표본은 모형을 보정하는 닳이고, 위성과 라이다는 그 사이의 공간을 추정하는 눈입니다.

경루쿤(Geng et al., 2026) 연구팀은 헤이룽장성 천연림의 장기 조사 자료와 생태 모형, 기후 시나리오를 지식 유도 머신러닝으로 묶었습니다. 저배출 시나리오에서 2060년 탄소 축적량은 1,379.26테라그램에서 1,439.02테라그램으로 예측됐습니다. 이 값은 관측된 미래가 아니라 모형 전망입니다.

케스케스와 니처(Keskes & Niță, 2026)는 루마니아 현장 자료로 만든 모형에 핀란드 다원천 국가산림자원조사 자료를 더했습니다. 대상은 탄소 지도가 아니라 핀란드의 임목 재적 예측이었습니다. 설명력은 0.483에서 0.718로 올랐습니다. 라마헤와게 연구팀의 미국 혼효림 연구는 여러 원격탐사 자료를 합치면 지상부 바이오매스 추정이 나아질 수 있음을 보여 줍니다. 연구마다 대상 변수와 검증 지역이 다르므로 한 모형의 수치를 다른 나라 탄소 지도에 옮기면 안 됩니다.

부풀려진 숫자와 신뢰의 문제

스윈필드 연구진(Swinfield et al., 2026)은 2020년까지 크레딧을 발행한 REDD+ 사업 가운데 약 45퍼센트를 여섯 독립 평가 결과와 비교했습니다. 이에 해당하는 사업은 44개였습니다. 전체 발행량을 합친 과잉 비율은 10.7배였고, 일부 대형 사업이 이 값을 끌어올렸습니다. 전형적인 사업의 중앙 수준은 4.1배였습니다. 많은 사업이 산림파괴를 줄였다는 결과와 기준선이 부풀려졌다는 결과가 함께 나왔습니다. ‘사업이 실패했다’와 ‘성과보다 많은 크레딧을 발행했다’는 같은 말이 아닙니다.

베라의 VM0048은 관할권 차원의 산림파괴 위험 자료로 기준선을 배분하는 틀을 둡니다. 방법론의 10년은 역사적 참조기간이고, 6년은 기준선 적용기간입니다. 같은 재계산 주기를 10년에서 6년으로 줄인 것이 아닙니다. 디지털 MRV는 자료 수집과 감사를 도울 수 있지만, 기준선 선택과 이해충돌까지 저절로 해결하지는 않습니다.

국가산림자원조사 표본점의 공개 좌표가 보안상 이동된 경우, 10미터 위성 화소와 곧바로 맞추면 위치 오차가 생깁니다. 목질 신소재의 기후효과도 원료 채취, 약품, 열원, 수명, 폐기까지 전과정으로 계산해야 합니다. 제조 과정에서 사라지는 효과를 하나의 고정 비율로 둘 수는 없습니다. 파리협정 6.4조의 방법론과 표준은 존재하지만, 자발적 시장과 국가 감축 실적 사이의 상호운용과 이중계산 방지는 아직 완성되지 않았습니다.

노령림은 큰 탄소 저장고이며 큰 개체목도 계속 탄소를 더할 수 있습니다. 생산림에서는 수확한 목재의 저장과 재료 대체효과를 함께 볼 수 있습니다. 어느 선택이 기후에 이로운지는 숲의 종류, 벌채 강도, 재생 속도, 제품 수명, 가공 배출, 대체되는 재료에 따라 달라집니다. 모든 숲을 30년에서 40년에 베는 규칙도, 모든 벌채를 금하는 규칙도 이 계산을 대신할 수 없습니다.

벌채 위치와 물량, 목제품 생산, 건축물의 자재 명세, 신소재 공정의 전과정 자료를 연결하면 산림에서 제품까지의 탄소 장부를 만들 수 있습니다. 나무 한 그루가 어느 벽에 들어갔는지까지 이어지는 통합 디지털 트윈은 운영 체계보다 설계 목표에 가깝습니다.

같은 감축량의 이중계산을 막으려면 고유 식별번호, 등록부 간 조정, 소유권 규칙, 취소 기록, 독립 검증이 필요합니다. 블록체인이나 물리 정보 신경망만으로 이 문제를 구조적으로 해결할 수는 없습니다.

근거 및 참고문헌

1. Carbon Market Watch. (2026). Quality assessment of REDD+ carbon credit projects. <https://carbonmarketwatch.org/publications/quality-assessment-of-redd-carbon-credit-projects/> (2026년 8월 2일 접속)
2. Carbon Pulse. (2026). Digital MRV could strengthen carbon credit integrity but data quality concerns persist, ICVCM survey says. <https://carbon-pulse.com/491240/> (2026년 8월 2일 접속)
3. 国立研究開発法人森林研究・整備機構 森林総合研究所. (2025, 9월 3일). 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. <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. 環境省. (2025, 2월 18일). 地球温暖化対策計画. <https://www.env.go.jp/content/000291618.pdf>
8. 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)
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., Toye-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. 산림청. (2026). 산림탄소상쇄제도. https://www.forest.go.kr/newkfsweb/html/HtmlPage.do?pg=/fcm/UI_FC_S_111000.html&mn=KFS_02_10_11_10&orgId=fcm (2026년 8월 2일 접속)
 12. 한국임업진흥원. (2026). 산림탄소상쇄제도 운영. https://www.kofpi.or.kr/intro/bizGuide_04_02.do (2026년 8월 2일 접속)
 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/> (2026년 8월 3일 접속)

이 책을 후원해 주십시오

이 책을 잘 읽으셨고 새로운 가치 있는 지식을 얻으셨다고 생각되시면
아래 계좌로 자발적 후원을 부탁드립니다.

후원 계좌

농협 302-1096-0948-81 (예금주 김경진)

후원금은 다음 책의 번역과 무료 공개판 제작에 쓰입니다.