

원예농업 인공지능

김경진

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

차례

1장	컴퓨터 비전 및 딥러닝 기반 작물 병해충 진단	3
1.1	작물 병해충 및 잡초 정밀 감지·진단	5
1.2	과실 성숙도 판별 및 생육·수량 예측	15
2장	원예농업 로봇 및 자율주행 작업 자동화	26
2.1	과채류·버섯 수확 로봇 및 말단 수확기(End-Effector)	28
2.2	자율주행 로봇·드론 군집의 경로 최적화와 정밀 방제	38
3장	스마트 온실 및 시설원예 환경 제어(CEA)	49
3.1	IoT 기반 멀티센서 모니터링 및 지능형 환경 측정	51
3.2	디지털 트윈 및 AI 지능형 환경·생육 최적화	62
4장	데이터 기반 정밀 농업 및 의사결정 지원	72
4.1	지능형 관수·비료 공급 최적화	74
4.2	시공간 데이터 융합 및 유통·품질 관리	84
5장	AI 기반 디지털 피노타이핑 및 육종 생물공학	94
5.1	고속 작물 피노타이핑(High-Throughput Phenotyping)	96
5.2	예측 육종 및 스마트 생물육종 기술	106

1장

컴퓨터 비전 및 딥러닝 기반 작물 병해 총 진단

1.1

작물 병해충 및 잡초 정밀 감지·진단

미국의 카본 로보틱스가 만든 레이저위더(LaserWeeder)는 시간당 10만 포기가 넘는 잡초를 레이저로 태워 없앱니다. 2022년 출시 이후 이 로봇이 없앤 잡초를 다 더하면 100억 포기를 넘고, 2026년 1분기 매출은 1억 달러를 넘겼으며, 15개국 100여 농가가 이 로봇을 쓰고 있습니다. 같은 시기 한국에서는 농촌진흥청이 만든 인공지능 진단 앱이 작물 31개와 병해충 182종을 가려내고 있습니다. 사람이 잎을 하나하나 뒤집어 보며 병반을 확인하고 잡초를 손으로 뽑던 일을, 카메라와 알고리즘이 대신 맡는 시대로 들어선 것입니다.

원예작물의 수확량과 품질은 국가 단위의 식량 안보와 농가 소득을 동시에 떠받치는 축입니다. 그런데 기후가 변하면서 병원균은 새로운 변이를 얻고, 낯선 지역까지 번지고, 잡초는 작물과 같은 햇빛과 물과 양분을 놓고 다텁니다. 오랫동안 이 싸움의 최전선은 사람의 눈이었습니다. 영어로는 이런 방식을 비주얼 스카우팅(Visual Scouting)이라 부릅니다. 숙련된 농학자나 재배자가 포장을 돌며 잎을 살피는 이 육안 예찰은 지금도 널리 쓰이지만, 사람 손이 하루에 볼 수 있는 이랑의 수는 정해져 있고, 같은 병반을 두고도 사람마다 판단이 갈립니다. 포장이 넓어질수록 이 방식의 틈은 커지고, 그 틈으로 병은 소리 없이 번집니다.

잡초가 작물 옆에서 자라기 시작하면 눈에 보이지 않는 다툼이 뿌리 밑에서 매일 벌어집니다. 빗물이 스미고 비료 성분이 녹아드는 그 짧은 시간 동안, 잡초 뿌리가 작물 뿌리보다 먼저 물과 양분을 빨아들이는 일이 되풀이됩니다. 잎의 크기 차이로 눈에 드러나기까지는 몇 주가 걸리지만, 그사이 작물은 자라야 할 만큼 자라지 못한 채로 수확철을 맞습니다. 병이든 잡초든, 증상이 눈에 뚜렷해질 때는 이미 손을 쓰기에 늦은 경우가 많습니다.

이런 문제에 대응하는 큰 흐름을 정밀 농업이라 부릅니다. 밭 전체에 같은 처방을 내리던 방식에서, 작은 구역이나 포기 하나하나에 맞춰 필요한 만큼만 손을 대는 방식으로 옮겨가는 접근입니다. 병해충과 잡초를 정밀하게 찾아내는 일은 이 흐름의 첫 단추에 해당합니다. 어디에 무엇이 있는지도 모른 채로는, 그 자리에만 손을 대는 정밀한 처방 자체가 불가능하기 때문입니다.

이 틈을 메우려고 나선 것이 컴퓨터 비전과 딥러닝을 결합한 정밀 진단 기술입니다. 카메라가 찍은 사진 한 장에서 병든 부위와 성한 부위, 작물과 잡초를 구별해 내는 일을 사람

이 아니라 알고리즘이 떠맡는 구조입니다. 그 뿌리에 있는 것은 합성곱 신경망, 영어 약자로 CNN(Convolutional Neural Network)입니다. 사진을 잘게 나눈 패치마다 색깔과 무늬, 병반 가장자리의 굴곡을 훑고 그 결과를 층층이 쌓아 올려 하나의 판단으로 모으는 구조입니다. ResNet, EfficientNet, DenseNet, MobileNet처럼 다른 대규모 이미지 자료로 미리 훈련시켜 둔 모델을 가져다 농작물 사진에 맞게 다시 가르치는 전이학습을 쓰면, 농가에서 모을 수 있는 정도의 사진 몇천 장만으로도 꽤 정확한 분류기를 세울 수 있습니다.

다른 언어를 이미 배운 사람이 새 언어를 더 빨리 익히는 것과 비슷한 원리입니다.

빠르게 움직이는 현장에서는 판단의 정확도 못지않게 속도가 문제가 됩니다.

YOLO(You Only Look Once) 계열 모델은 사진 전체를 한 번만 훑어 병반이나 해충, 잡초가 어디에 있는지 사각형 테두리로 표시하고 그것이 무엇인지 이름표까지 동시에 붙입니다. 이름 그대로 한 번만 보고 끝내는 방식이라 카메라가 실시간으로 찍어 내는 영상에도 뒤처지지 않고 따라붙습니다. 잎이 겹치고 그림자가 지고 배경에 흙과 지푸라기가 섞인 어수선했던 캐노피 속에서도, YOLOv5부터 YOLOv8, YOLOv9e, YOLOv10, YOLOv11에 이르는 최신 계열은 개별 병반과 벌레 한 마리, 잡초 한 포기의 위치를 놓치지 않고 찾아냅니다.

CNN과 YOLO에는 공통된 약점이 있습니다. 사진을 작은 패치로 쪼개어 보는 구조이다 보니 패치와 패치 사이, 잎 전체에 걸친 넓은 무늬나 포기 전체의 형태 변화는 놓치기 쉽습니다. 비전 트랜스포머, 영어 약자로 ViT(Vision Transformer)와 그 친척인 Swin Transformer는 사진을 16×16 픽셀 크기의 패치로 잘라 낸 뒤, 그 패치들이 서로 어떻게 관계를 맺는지를 통째로 계산합니다. 자기주의 기제, 영어로 셀프 어텐션(Self-Attention)이라 부르는 이 계산 방식 덕분에 사진 한쪽 구석의 병반과 반대쪽 구석의 병반이 같은 병에서 온 것인지를 넓은 시야로 판단할 수 있습니다. 여기에 CBAM이나 CAB 같은 주의 모듈을 CNN과 나란히 붙인 혼성 구조는 세밀한 병반 무늬를 읽는 눈과 잎 전체를 조망하는 눈을 한 몸에 지니게 됩니다.

가까이서 결을 더듬는 손끝과 멀리서 전체 그림을 보는 눈을, 한 사람이 동시에 지녔습니다.

이런 모델이 실제로 얼마나 잘 맞히는지는 숫자로 드러냅니다. 포도 잎 병을 가려내는 EfficientNet-B0와 B3 계열은 검증 자료에서 정확도 99.5퍼센트, AUC-ROC 1.00을 기록했습니다. 꺾기 무리의 움직임을 본뜬 최적화 기법인 DSOCA-QSO를 결합한 모델은 채소 잎 병 분류에서 정확도 99.9퍼센트, F1 점수 99.35퍼센트에 이르렀고, 문맥에 따라 특징을 골라 뽑는 TL-DCFP-CNN은 면화와 옥수수, 벼, 밀, 사탕수수까지 다섯 작물을 한꺼번에 다루면서도 정확도 98.09퍼센트를 지켰습니다. 실시간 탐지 쪽에서는 YOLOv11이 토마토 잎 병 탐지에서 정확도 94퍼센트 언저리를 냈고, 몸집을 줄인 YOLO-NAS는

열대 지역 포장의 잡초 탐지에서 정확도 96퍼센트를 지키면서도 사진 한 장을 25밀리초 만에 처리했습니다.

사람이 눈을 한 번 깜빡이는 시간의 십 분의 일에도 못 미치는 사이에 판단을 끝내는 속도입니다. YOLO-NAS가 시험된 열대 지역 포장은 온대 지역과 빛과 습도 조건이 다릅니다. 해가 높ی 때 그림자가 짧고 진하며 공기 중 습도도 높은 곳입니다. 이런 환경에서도 정확도를 지켰다는 결과는, 한 기후대에서 만든 모델이 전혀 다른 기후대에서도 통할 수 있다는 근거로 읽힙니다.

무인기나 지상 로봇은 발 위를 계속 움직이며 사진을 찍습니다. 판단이 반 박자만 늦어도 로봇은 이미 그 병반을 지나쳐 버린 뒤입니다. 그래서 병을 얼마나 정확히 맞히는지 못지 않게, 그 판단을 얼마나 빨리 내리는지가 현장에서는 실제 성능을 가릅니다. 사진 한 장을 처리하는 데 걸리는 밀리초 단위의 차이가, 결국 로봇 한 대가 하루에 돌아볼 수 있는 밭의 넓이를 정합니다.

작물과 잡초가 서로 잎을 맞대고 자랄 때는 사각형 테두리로는 부족합니다. 화소 하나하나를 작물 아니면 잡초로 갈라 칠하는 세그멘테이션 모델이 이 일을 맡습니다.

PSPEdgeWeedNet은 경계를 따로 감지하는 가지와 조건부 랜덤 필드를 함께 써서 땅콩 포장에서 작물과 잡초의 경계선을 뚜렷하게 갈라냈고, 문맥을 함께 읽는 이중 가지 구조의 CAMDWS는 호주 밀밭의 대표 잡초인 라이그래스(*Lolium rigidum*)와 야생무(*Raphanus raphanistrum*)를 각각 91퍼센트와 90퍼센트가 넘는 IoU, 즉 실제 영역과 예측 영역이 겹치는 비율로 가려냈습니다.

ViT는 PlantVillage 자료에서 정확도 99.8퍼센트를 냈고, ViT와 컨볼루션 주의 블록을 합친 HybridViT-CAB은 파라미터 41만 2천 개, 용량 1.57메가바이트에 지나지 않는 가벼운 몸집으로 한 단계 처리에 141밀리초, AUC 0.97, 정확도 91퍼센트를 확보했습니다. Swin Transformer를 백본으로 ConvNeXt-V2와 SE-BiLSTM, 심층 Q학습 추천 층까지 얹은 무인기 탑재 진단 시스템은 SAR-CLD-2024 면화 자료에서 정확도 99.30퍼센트를 기록했습니다. 몸집이 가벼우면서도 정확도를 잃지 않는 방향으로 연구의 무게중심이 옮겨 가고 있는 것으로 보입니다.

아무리 뛰어난 알고리즘도 카메라가 무엇을 담아내느냐에 매여 있습니다. 사람 눈과 비슷한 파장을 담는 RGB 센서는 값싸고 가볍고 휴대전화나 드론에 이미 달려 있어서 병징 분류와 잡초 탐지 현장에서 표준 장비가 되었습니다. 그러나 병이 겉으로 드러나기 전 잎 속에서 벌어지는 초기 감염이나, 작물과 색이 거의 같은 녹색 잡초를 가시광선만으로 가려내는 데에는 눈으로 보는 것과 똑같은 한계가 있습니다. 이 틈을 메우는 것이 다중분광과 초분광 영상입니다.

파란빛 475나노미터, 초록빛 560나노미터, 붉은빛 668나노미터, 붉은빛 경계 717나노미터, 근적외선 840나노미터처럼 특정 파장대의 반사율만 따로 재는 센서는, 정규화 식생지수(NDVI)나 녹색 정규화 식생지수(GNDVI), 붉은빛 경계 NDVI, 토양 조정 식생지수(SAVI) 같은 지표로 바뀌어 엽록소가 무너지거나 수분이 빠져나가는 초기 스트레스를 눈에 보이는 병징이 나타나기 전에 알아냅니다.

3차원 위치 정보를 더한 RGB-D 센서는 색깔 사진에 화소마다 거리 값을 엮습니다. 수확 로봇의 손가락이나 제초 로봇의 레이저가 정확히 어디를 겨냥야 하는지, 그 좌표를 만들어 내는 것이 이 깊이 정보입니다. 이런 센서를 실은 무인항공기는 지상 2미터에서 50미터 사이 낮은 고도를 날며 화소 하나가 0.3센티미터에서 5센티미터를 담는 해상도로 포장 전체를 훑고, 지상 로봇과 손에 든 이동 단말기가 그 틈을 메웁니다. 여기에 기온과 습도, 토양 수분, 강우량을 재는 사물인터넷 센서와 기상 기록까지 포개면, 시간과 공간에 걸친 여러 겹의 자료가 하나의 파이프라인으로 흘러들어 갑니다. 이렇게 모인 자료는 진단에서 그치지 않고 예측으로 이어집니다. 최근 며칠의 기온과 습도 흐름을 지난 병 발생 기록과 겹쳐 보면, 병반이 눈에 보이기 전에 발병 위험이 커지는 시점을 미리 알려 줄 수 있습니다.

눈에 보이는 병을 찾아내는 일에서, 아직 보이지 않는 병을 미리 가려내는 일로 한 걸음 나아갑니다.

사진을 모았다고 바로 쓸 수 있는 것은 아닙니다. 224×224나 512×512, 736×736 같은 정해진 크기로 다시 잘라 내고 화소값을 일정한 범위로 맞추는 손질을 거칩니다. 햇빛의 방향이 바뀌고 사진 수가 병 종류마다 고르지 않은 문제를 메우려고 사진을 돌리고 뒤집고 비스듬히 기울이고 흐리게 만드는 손질에 더해, GAN이나 cGAN, DoubleGAN처럼 없는 사진을 스스로 그려 내는 생성 모델로 병든 잎과 잡초의 가짜 사진을 만들어 학습 자료를 늘립니다. 조건부 생성적 대립 신경망인 cGAN은 병의 종류라는 조건을 미리 정해 주면 그 병에 해당하는 가짜 병반 사진을 새로 그려 냅니다. 진짜처럼 보이는 사진을 만들려는 쪽과 그것이 가짜인지 가려내려는 쪽이 서로 겨루면서 함께 실력을 키우는 구조입니다.

교차 엔트로피 손실이나 클래스별 가중 손실, 경계선 손실 같은 함수로 모델이 얼마나 틀렸는지를 재고, Adam이나 AdamW 같은 최적화 기법으로 그 오차를 조금씩 줄여 나갑니다.

훈련을 마친 모델은 결국 밭에 나가 있는 작은 기계 안에서 돌아가야 합니다. 엔비디아 젯슨 자비어 NX나 젯슨 나노, 라즈베리파이 같은 손바닥만 한 컴퓨터, 자일링스 진크-7000 같은 FPGA 가속기가 그 일을 맡습니다. 숫자를 촘촘한 소수점 대신 정수로 뚝뚝 그리는 양자화는 한 번의 연산이 다루는 비트 수를 줄여 계산에 드는 시간과 메모리를 함께 줄입니다. 정밀도는 조금 낮아지지만 계산은 훨씬 빨라집니다. 나무의 불필요한 가지

를 잘라 내듯 결과에 별 영향을 주지 않는 연결을 잘라 내는 가지치기, 텐서플로 라이트나 TensorRT로 모델을 다시 짜 넣는 변환을 거치면 연산 시간이 크게 줄어듭니다. FPGA로 가속한 모델은 RGB 단일 모델에 비해 43.2배 빠른 추론 속도, 10밀리초에 못 미치는 지연 시간, 전력 소모 88퍼센트 절감이라는 성과를 냈다고 보고되었습니다.

최근에는 사진 한 장을 42.6밀리초 만에 처리하는 시스템이 나와 휴대전화 수준의 기기에서도 실시간 진단이 가능해졌고, 파라미터 190만 개짜리 초경량 모델 PMVT나 가지치기를 거친 트랜스포머가 텐서플로 라이트와 ONNX 런타임, 가벼운 gRPC 통신 위에서 농업용 무인기와 몸체가 작은 기기에 그대로 얹힙니다.

이렇게 만든 모델이 쓸 만한지는 몇 가지 잣대로 가늠합니다. 정확도는 전체 판정 가운데 옳게 맞힌 비율이고, 정밀도는 병이라고 판정한 것 가운데 실제로 병이었던 비율이며, 재현율은 실제로 병든 잎 가운데 모델이 놓치지 않고 잡아낸 비율입니다. 어떤 병은 사진이 수천 장 쌓여 있지만 드문 병은 사진이 몇십 장에 그치기도 합니다. 병마다 사진 수가 이렇게 차이 나는 상황에서 F1 점수는 정밀도와 재현율을 하나로 합쳐, 흔한 병 쪽으로만 판단이 치우치지 않았는지를 가려내는 잣대 역할을 합니다. AUC-ROC는 여러 문턱값에 걸친 성능을 보여주고, 혼동 행렬은 실제 병명과 모델이 예측한 병명을 표로 대조해 어떤 병을 어떤 병으로 잘못 짚었는지를 그대로 드러냅니다.

병든 잎을 건강하다고 잘못 판정하면 그 밭 전체로 병이 번질 시간을 벌어 주는 셈이니, 병해충 진단에서는 정밀도보다 재현율을 더 무겁게 봐야 합니다. 놓치는 쪽보다 조금 과하게 의심하는 쪽이 안전하다는 뜻입니다.

위치까지 알아내야 하는 탐지와 세그멘테이션에는 다른 잣대가 붙습니다. IoU는 모델이 그린 영역과 실제 병반 영역이 겹치는 정도를 보여주고, mAP는 여러 문턱값에서 낸 정밀도를 평균 낸 값입니다. 도장 두 개를 같은 위치에 겹쳐 찍었을 때 얼마나 포개지는지를 살피는 것과 비슷합니다. 초당 처리 프레임 수와 추론 시간은 그 모델을 실제 현장 속도에 맞춰 쓸 수 있는지를 결정합니다. 그런데 이 모든 지표가 좋아도 밭에서 쓸모가 없으면 소용이 없습니다. 그래서 잡초 제거율과 작물 손상률, 헥타르당 제초제 사용량, 분사 효율 같은 농업 현장의 잣대를 나란히 확인합니다. 컴퓨터가 잘 맞히는 것과 농가의 비용과 수확량이 실제로 나아지는 것은 다른 질문이고, 이 두 번째 질문에 답하지 못하면 아무리 정확도가 높아도 현장에 뿌리내리기 어렵습니다.

숫자 뒤에는 실제로 밭에 놓인 카메라와 앱이 있습니다. 토마토와 포도, 면화, 고추, 딸기 처럼 값이 나가는 원예작물을 중심으로 휴대전화 앱과 드론이 짝을 이룬 진단 체계가 널리 퍼져 가고 있습니다. 토마토의 겹동근무늬병과 잎곰팡이병, 잎맥이 뒤틀리는 모자이크 바이러스, 잎 가장자리가 노랗게 말려 올라가는 황화잎말림 바이러스, 포도의 노균병과 흑색썩음병, 잎맥 사이가 줄무늬로 누렇게 마르는 에스카, 면화에 붙는 진딧물과 점박이응애, 잎을 파고드는 굴파리까지, YOLOv8과 YOLOv11, EfficientNet, MobileNet을 얹

은 모델이 밭에서 곧바로 병명을 가려냅니다. 재배자는 병이 온 포기 앞에서 사진 한 장을 찍고, 몇 초 뒤 화면에 뜬 병명과 방제 방법을 보고 다음 행동을 정합니다.

토마토와 감자, 옥수수를 심은 시험 포장에서는 진단이 실제로 어떻게 이어지는지 보여주는 사례가 나왔습니다. 딥러닝 모델이 병이 있다고 판정한 구역에만 초기 살균제를 뿌리고, 그 구역의 관수량도 따로 조정했습니다. 진단이 화면 속 숫자로 끝나지 않고 실제로 약과 물의 양을 바꾸는 결정으로 이어진 사례입니다. 다만 이런 시험은 아직 밭 하나, 계절 하나에 머무는 경우가 많아서, 여러 필지와 계절, 서로 다른 조도를 두루 아우르는 대규모 자료가 더 필요하다는 지적도 함께 나옵니다.

이런 진단 도구는 전문가를 바로 만나기 어려운 지역에서 힘을 발휘합니다. 농학자 한 사람이 살펴야 할 농가와 포장의 수는 지역마다 차이가 크지만, 사람 발로 다 돌아보기에는 어디서나 벅찬 숫자입니다. 휴대전화 한 대로 전문가의 판단에 가까운 진단을 곧바로 받을 수 있다는 점이, 이 기술이 넓게 퍼지는 이유 하나로 보입니다. 사람을 대신하기보다는, 사람의 눈이 미처 닿지 못하는 시간과 장소를 메우는 역할에 가깝습니다.

작물과 잡초를 카메라로 구분해 필요한 자리에만 손을 대는 접근을 표적 변량 방제, 영어 약자로 SSWM(Site-Specific Weed Management)이라 부릅니다. 밭 전체에 같은 양을 뿌리던 방식에서, 잡초가 있는 곳만 골라 그만큼만 처리하는 방식으로 넘어가는 것이 이 접근의 핵심입니다. 그러나 그 경계를 정확히 긋는 일 자체가 쉽지 않습니다. 작물과 잡초가 어릴수록, 그리고 서로 가까이 붙어 자랄수록 그 경계는 더 흐릿해집니다.

작물과 잡초를 가르는 일은 병을 찾는 일보다 더 까다롭습니다. 둘 다 초록색이고, 둘 다 자라고, 어릴 때는 잎 모양마저 닮아 있기 때문입니다. 120헥타르 규모의 호주 밀밭을 대상으로 한 실험은 이 문제를 시간의 흐름으로 풀었습니다. 낮은 고도의 무인기가 같은 밭을 열여덟 차례에 걸쳐 시기를 달리해 찍고, AMSTF라는 시공간·분광 융합 알고리즘으로 그 사진들을 겹쳐 읽었습니다. 잡초는 하루 생장 속도 지수가 0.025, 밀은 0.015로 나타나 그 차이가 시계열 분광 지수 위에 고스란히 드러났고, 여기에 CAMDWS 세그멘테이션을 더하자 작물과 잡초가 맞닿은 경계에서 벌어지던 오분류율이 9.8퍼센트에서 12.3퍼센트 사이였던 수준에서 5.4퍼센트까지 떨어졌습니다. 자라는 속도의 차이라는 눈에 잘 띄지 않는 단서 하나가 경계선을 다시 긋는 핵심 요인이 되었습니다.

'씨 앤드 스프레이(See & Spray)'라는 표적 방제 장비는 노즐 위에 카메라를 달고 초고속 전자 밸브를 그 아래 붙였습니다. 이 장비를 만든 곳은 존디어의 자회사인 블루리버 테크놀로지입니다. 초록 작물 사이에 숨은 초록 잡초, 이른바 그린온그린(Green-on-Green) 문제를 실시간으로 알아봅니다. 사람 눈으로도 초록 잎 사이의 초록 잡초는 한눈에 들어오지 않는 경우가 많습니다. 잡초가 모인 정도와 종류에 따라 분사 입자 크기를 150에서 250마이크로미터 사이로, 분사량을 분당 0.12에서 0.35리터 사이로 그때그때 바꿉니다. 밭 전체에 골고루 뿌리던 관행적인 전면 분사와 견주면 제초제 사용량이 31퍼센트에서

32퍼센트까지 줄어, 헥타르당 0.68리터 수준까지 내려갑니다. 작물은 약을 맞지 않고, 땅에 뿌려지는 화학 물질의 총량도 함께 줄어드는 구조입니다.

화학 약제를 쓰는 이 방식과 달리, 아예 약을 치지 않는 길도 상용 단계에 들어섰습니다. DIN-LW-YOLO라는 탐지 알고리즘과 RGB-D 카메라를 실은 자율주행 로봇은 작물 포기 사이에 갇혀있는 잡초 새싹의 생장점을 3차원 좌표로 찾아냅니다. 생장점은 식물이 새로 자라나는 맨 꼭대기입니다. 로봇은 이곳에 고출력 레이저를 순간적으로 쏘아 열로 태워 없앱니다. 제초제 방울 대신 빛으로 잡초를 없애는 방식입니다. 미국의 카본 로보틱스가 만든 레이저위더(LaserWeeder)는 이 방식을 상업 규모로 밀어붙인 대표 사례입니다. 시간당 10만 포기가 넘는 잡초를 제거하며, 2022년 출시 이후 없앤 잡초를 다 더하면 100억 포기를 넘습니다. 2026년 1분기에는 연매출 1억 달러를 넘겼고, 이후 집계로는 1억 7700만 달러까지 보고되어 농업 로봇 회사로는 처음 있는 규모에 이르렀습니다.

15개국에 로봇이 나가 있고 북미와 유럽, 호주의 재배자 100곳이 넘는 곳에서 씁니다.

2026년 2월, 이 회사는 라벨을 붙인 식물 사진 1억 5천만 장으로 훈련시킨 대형 식물 모델을 내놓았습니다. 새로운 밭이나 낫선 작물을 만날 때마다 몇 주씩 걸리던 맞춤 훈련이 몇 분으로 줄었다고 합니다. 로봇 한 대가 겪은 잡초와 흙, 빛의 조합을 다음 로봇이 처음부터 다시 배우지 않아도 되는 구조입니다. 하나의 로봇이 쌓은 경험을 다음 로봇, 다음 밭으로 그대로 옮겨 쓰는 셈이니, 레이저 제초가 농장 하나의 도구에서 여러 농장이 함께 쓰는 하나의 공용 모델로 옮겨 가는 길목에 들어선 것으로 보입니다.

다시 새벽의 그 온실로 돌아가 보면, 재배자의 손에는 손전등 대신 휴대전화가 들려 있을 가능성이 큼니다. 잎을 뒤집어 보고 눈으로 병반을 재던 손이, 사진 한 장을 찍고 화면에 뜨는 병명을 확인하는 손으로 바뀌어 가고 있습니다. 한국에서는 농촌진흥청이 이런 역할을 하는 앱을 자체 개발해 서비스하고 있습니다. 재배자가 휴대전화로 병든 잎이나 열매를 찍어 올리면, 인공지능이 곧바로 병명을 가려내고 알맞은 방제 약제까지 추천합니다. 지금은 주요 작물 31개와 병해충 182종을 다루고, 2030년까지 국내에서 기르는 주요 작물 139개로 범위를 넓힐 계획을 세워 두고 있습니다. 한국형 2세대 스마트팜에서는 클라우드에 올린 인공지능이 재배 환경과 작물의 생체 정보를 실시간으로 읽어 역병과 흰가루병 등 병 5종, 잎굴파리 등 해충 2종을 알아냅니다.

여기에 더해 '아이(AI) 이삭이'라는 이름의 농업 특화 인공지능 비서를 17개 정보 시스템과 이어 운영하고 있으며, 음성으로 묻고 답하고 농가 경영까지 진단해 주는 다음 버전을 준비하고 있습니다.

병을 찾아내는 카메라와 잡초를 골라내는 카메라, 그 결과에 따라 약을 뿌리거나 레이저를 쏘는 장치는 결국 하나의 흐름으로 이어집니다. 밭 전체를 같은 방식으로 다루던 시대에서, 잎 하나 열매 하나까지 구분해 각기 다른 처방을 내리는 시대로 넘어가는 흐름입니다.

다. 그 경계에 선 것이 지금 밭에서 시험되고 있는 카메라와 로봇들입니다. 이 흐름이 얼마나 널리 퍼지느냐는 정확도와 값, 그리고 재배자의 신뢰에 달려 있습니다.

이런 성과에도 밭은 실험실과 다릅니다. 딥러닝 모델을 처음 가르칠 때 흔히 쓰는 PlantVillage 같은 자료는 배경이 깨끗하고 빛이 고른 사진으로 이루어져 있습니다. 그러나 실제 포장은 계절과 시간에 따라 햇빛의 각도가 바뀌고, 그림자가 짙게 지고, 바람에 잎이 흔들리며 겹치고, 먼지가 렌즈에 앉고, 흙과 마른 줄기가 배경에 뒤섞입니다. 실험실 사진으로 배운 모델을 이런 밭에 그대로 옮기면 정확도가 눈에 띄게 떨어지는 이른바 도메인 시프트가 나타납니다. 촬영 환경이 바뀌면 모델은 같은 병을 다른 것으로 착각합니다. 조명의 색온도, 렌즈의 화각, 앞에 진 그림자의 방향이 학습 때와 달라지면 그것만으로 판정이 흔들립니다. 사진을 아무리 많이 모아도, 그 사진이 찍힌 환경이 실제 밭과 다르면 배운 것을 밭에서 그대로 쓸 수 없다는 뜻입니다.

라벨을 다는 일 자체도 병목입니다. 사각형 테두리를 치고 화소 하나하나에 이름을 매기는 작업은 농학 전문가의 손을 거쳐야 하고, 사진 한 장에 몇 분씩 걸리기도 합니다. 이 부담을 덜려고 적은 라벨만으로 배우는 준지도 학습과 스스로 답을 만들어 가며 배우는 자가지도 학습, 사진 몇 장만 보고도 새 병을 알아보는 몇 샷 학습이 연구되고 있습니다. 대형 비전 언어 모델과 생성형 인공지능으로 라벨이 달린 가짜 사진을 대량으로 만들어 내는 방법도 이 병목을 우회하는 길로 떠오르고 있습니다.

센서를 늘릴수록 계산할 것도 늘어납니다. 가시광선 사진에 단파 적외선과 초분광 자료, 토양과 날씨를 재는 사물인터넷 자료까지 실시간으로 포개려면 서로 다른 속도로 들어오는 자료를 맞추는 일부터 쉽지 않습니다. 드론이 보내는 사진과 지상 센서가 보내는 수치는 측정 주기와 갱신 속도가 서로 달라서, 같은 시간대의 같은 위치를 가리키도록 맞추는 절차가 따로 필요합니다. 여기에 탐지와 추론, 경로 계획, 분사량 조절까지 여러 일을 한꺼번에 하는 모델을 배터리로 움직이는 작은 기기 위에서 지연 없이 돌리려면, 모델의 몸집을 줄이는 일과 FPGA나 NPU 같은 전용 반도체를 붙이는 일을 함께 풀어야 합니다.

마지막 과제는 신뢰입니다. 딥러닝 모델은 왜 그렇게 판단했는지를 스스로 말해 주지 않는 블랙박스에 가깝습니다. 재배자와 농학자가 그 판정을 그대로 믿고 방제 약을 치려면, 모델이 앞의 어느 부위를 보고 병이라고 판단했는지를 사람이 눈으로 확인할 수 있어야 합니다. Grad-CAM이나 SHAP, 인과 관계를 밝혀 주는 주의 기제를 모델 안에 심어 병반 부위의 기여도를 그림으로 보여주는 연구가 이 신뢰를 만드는 다음 단계로 보입니다. 기술이 아무리 정확해도 재배자가 그 판단을 의심하면 현장에서 받아들여지기 어렵습니다.

근거 및 참고문헌

학술 논문

1. Adewumi, A., & Saraswat, D. (2026). Comprehensive review of artificial intelligence and edge computing for precision weed control. *Artificial Intelligence and Applications*. DOI: 10.47852/bonviewAIA62028867.
2. Kakde, S., Poyam, P., et al. (2025). Design of an integrated spatiotemporal deep learning framework for autonomous precision weed management. *International Journal of Applied Mathematics*, 38(2s), 1340-1363.
3. Latif, A., Jati, H., Surjono, H. D., & Yusuf, M. (2026). Drone-assisted deep learning weed detection for sustainable agriculture and environmental resilience. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 15(2), 1428-1440. DOI: 10.11591/ijai.v15.i2.pp1428-1440.
4. Mathew, M. P. (2025). A comparative deep learning framework for grape leaf disease classification using EfficientNetB0, InceptionV3, and Xception. *Discover Applied Sciences*, 7, 1222. DOI: 10.1007/s42452-025-07457-5.
5. Moldvai, L., & Nyéki, A. (2025). Innovative computer vision methods for tomato (*Solanum lycopersicum*) detection and cultivation. *Discover Applied Sciences*, 7, 975.
6. Pai, D. G., Balachandra, M., & Kamath, R. (2025). Deep learning approach for crop-weed segmentation in peanut cultivation using PSPEdgeWeedNet. *Scientific Reports*, 15, 43032. DOI: 10.1038/s41598-025-24174-6.
7. Yenna, G. R., Kumari, N. V., Chouhan, A. S., Umar, S., & Macha, S. R. (2026). HybridViT-CAB: a vision transformer and convolutional attention network for precision weed detection in agricultural systems. *Scientific Reports*, 16, 18473. DOI: 10.1038/s41598-026-48652-7.
8. FPGA-accelerated IoT deployment of a causal attention multi-modal deep learning network for precision crop disease monitoring. (2026). *Environment Conservation Journal*.
9. AgroDualNet: a dual deep learning-based crop disease forecasting and fruit ripening detection framework. (2026). *Scientific Reports*.
10. Precision agriculture at scale: early disease detection using vision transformers. (2026). *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 14(4).
11. A novel approach for crop disease detection using transfer learning-based deep convolutional neural network. (2026). *Neural Computing & Applications*, 38, 500. DOI: 10.1007/s00521-026-12216-7.
12. Pest identification in crop fields using convolutional neural networks (CNNs): a deep learning approach. (2026). Volume 14, Issue 3.
13. PMC13066816. (2025). National Library of Medicine, PubMed Central. <https://pmc.ncbi.nlm.nih.gov/articles/PMC13066816/>
14. Article PII S2095809925006769. (2025). Elsevier ScienceDirect. <https://www.sciencedirect.com/science/article/pii/S2095809925006769>

강연 및 영상 자료

1. C-DAC. (2025). AI in Agriculture: Transforming India's Krishi Landscape. YouTube. https://www.youtube.com/watch?v=IV3_VnWiBpM
2. RMCg. (2025). AI unpacked: Practical tools for vegetable growers. YouTube. <https://www.youtube.com/watch?v=G2ytLXLW7hw>
3. Grounded AI. (2025). How AI Is Transforming Farming: Smarter Cows, Crops & Pest Control. YouTube. <https://www.youtube.com/watch?v=bxIF2MpXsB0>
4. SyncTellect Automation Hub. (2026). End-to-End AI/ML Project Series | Day 1 - Project Kickoff & Crop Disease Detection Overview. YouTube. <https://www.youtube.com/watch?v=SNqOcVib3BY>
5. Royal Society of Biology. (2026). Série Santé des Plantes | Viticulture numérique : L'avenir de la santé de la vigne. YouTube. <https://www.youtube.com/watch?v=5iXPOMxl6bU>

기사 및 보고서

1. Carbon Robotics. (2026). LaserWeeder Results. Carbon Robotics. <https://carbonrobotics.com/results>
2. Hypersinc. (2026). Carbon Robotics crosses 100M revenue on AI LaserWeeding platform. Hypersinc. <https://hypersinc.com/article/carbon-robotics-crosses-100m-revenue-on-ai-laserweeding-platform-1775055784166>
3. Design News. (2026). LaserWeeders killed billions of weeds in the last two years. Design News. <https://www.designnews.com/automation/laserweeders-killed-billions-of-weeds-in-the-last-two-years>
4. 농촌진흥청. (2026). 농작물 병해충 인공지능 영상진단·처방 서비스. 농촌진흥청. https://www.rda.go.kr/board/board.do?mode=view&prgId=day_farmprmninfoEntry&dataNo=100000806197
5. 스마트팜코리아. (2026). 인공지능 생육관리 처방 서비스. 스마트팜코리아. <https://www.smartfarmkorea.net/analyService/internal/aiAdvice.do?menuId=M11030102>

1.2

과실 성숙도 판별 및 생육·수량 예측

대규모 상업 온실에서 파이프레일 대차에 카메라를 달아 파프리카의 성숙 단계별 개수를 세고, 그 값과 총수확량의 관계를 확인하는 시험이 이루어졌습니다. 온실 천장 가까이 걸린 레일 위로 대차가 초속 0.3에서 0.5미터로 움직이고, 밑에 매달린 카메라는 줄줄이 늘어선 파프리카를 향해 앞 사이로 드러난 열매의 표면 색깔을 읽어 붉게 익은 정도를 숫자로 바꿉니다. 이 대차형 계수 장치는 시험 기간 내내 흔들림 없는 검출 성능을 유지했습니다.

과실이 언제 익었는지를 아는 일은 생각보다 큰돈이 걸린 문제입니다. 너무 일찍 따면 당도가 오르지 않은 채로 팔리고, 너무 늦게 따면 무르거나 상해서 유통 중에 버려집니다. 오랫동안 이 판단은 일꾼의 눈과 손에 맡겨졌습니다. 발이나 온실을 돌며 색깔을 보고 만져 보는 식이었고, 사람마다 기준이 조금씩 달라 같은 열매를 두고도 판정이 엇갈리는 일이 흔했습니다. 당도나 산도, 단단한 정도를 정확히 알려면 열매를 잘라 즙을 짜내고 기기에 넣어 재는 화학 분석을 거쳐야 했는데, 이 방법은 그 열매 자체를 못 쓰게 만듭니다. 표본 몇 개를 잘라 본다고 발 전체의 사정을 알 수는 없으니, 농가는 노동력과 시간을 쏟고도 어림짐작에 가까운 답을 손에 쥐는 경우가 많았습니다. 게다가 잘못된 판단은 한 번으로 끝나지 않습니다.

첫 수확에서 덜 여문 열매를 놓치면, 그 열매는 다음번 수확 때는 이미 상품성을 잃어 버려지는 일이 잦았습니다.

한 대의 카메라가 답해야 하는 질문은 사실 한 가지가 아닙니다. 오늘 이 열매가 다 익었는지를 묻는 질문과, 나무 전체가 지금 꽃이 피는 단계인지 열매가 굵어지는 단계인지를 묻는 질문, 그리고 이 밭에서 앞으로 몇 킬로그램이 나올지를 묻는 질문은 서로 다릅니다. 성숙도는 낱개 열매를 보고 판단하고, 생육 단계는 나무나 발 전체의 흐름을 보고 판단하며, 수량은 이 둘을 셈해서 미래의 숫자로 바꾸는 일입니다. 그런데 셋 다 같은 렌즈로 찍은 사진에서 출발하기 때문에, 최근 연구는 이 세 질문에 각각 따로 답하기보다 하나의 카메라와 하나의 파이프라인으로 한꺼번에 다루는 쪽으로 가고 있습니다.

카메라가 색깔만 보고도 익음을 짐작할 수 있는 데는 이유가 있습니다. 열매가 익어 가면 표피 속 엽록소가 분해되면서 초록빛이 없어지고, 카로티노이드나 안토시아닌 같은 색소가 초록빛을 대신하면서 노랑, 주황, 빨강으로 물듭니다. 동시에 눈에는 보이지 않는 속사

정도 바뀝니다. 물에 녹아 있는 당분인 가용성 고형물(TSS)의 양이 늘고, 신맛을 내는 적정 산도(TA)는 줄며, 전분과 수분의 비율도 달라집니다. 가시광선 영역, 그러니까 사람 눈이 보는 것과 같은 400에서 700나노미터 파장 대역을 찍는 RGB 카메라는 이 겉모습의 변화, 즉 색조와 질감과 모양을 읽어 내는 기본 도구 역할을 합니다.

색깔만으로는 알 수 없는 거리 정보를 더해 주는 장비가 RGB-D 카메라입니다. 보통 사진기가 평평한 색 정보만 담는다면, RGB-D 카메라는 화소마다 거리 정보를 하나 더 엽니다. 지도에 위도와 경도만 있다가 고도까지 표시되는 것과 비슷합니다. 이 깊이 값 덕분에 카메라는 열매의 앞뒤 좌우 위치와 반지름, 부피를 계산하고, 앞이나 가지에 가려 반쯤 숨은 열매까지 그 존재를 놓치지 않고 잡아냅니다. 가려짐을 그대로 두면 실제보다 적은 개수를 세게 되므로, 뒤이어 나오는 수량 예측 전체가 낮은 쪽으로 틀어집니다. 시설 온실 안을 도는 순찰 로봇들이 흔히 쓰는 인텔 리얼센스 D435i 같은 제품이 이런 역할을 맡습니다.

데이터를 모으는 과정에도 손이 많이 갑니다. 카메라가 찍은 사진에는 잡음이 섞여 있어서, 가우시안 필터링과 위너 필터링으로 잡음을 걸러 내고, CLAHE라는 기법으로 그늘진 곳과 밝은 곳의 명암 차이를 고르게 다듬습니다. 화소 값을 일정한 범위로 맞추는 최소최대 정규화도 뒤따릅니다. 사진 수가 부족하면 있는 사진을 돌리고 뒤집고 밝기를 바꾸거나 화면 한쪽을 가리는 방식으로 양을 늘리고, 최근에는 CGAN이나 SMOTE 같은 기법으로 실제로 찍지 않은 가상의 열매 사진과 화학 성분 수치까지 만들어 학습에 보탬니다. 다만 이렇게 늘린 사진을 학습용과 검증용으로 나누기 전에 섞어 버리면 안 됩니다. 먼저 나누고 학습용 쪽에만 손을 대는 순서를 지켜야, 나중에 부풀려진 평가 결과를 받아 드는 일을 막을 수 있습니다.

껍질 색이 끝까지 변하지 않는 과일 앞에서는 눈에 보이는 빛만으로는 손을 들 수밖에 없습니다. 태국의 망고 품종 남독마이시통(Nam Dok Mai Si Tong, NDMST)이 그런 경우로, 익어 가는 내내 껍질이 고른 노란색을 유지해 사진만 보고는 언제 따야 할지 가능하기 어렵습니다. 이때 쓰이는 것이 근적외선, 그러니까 사람 눈에는 보이지 않는 700나노미터 이상의 파장 대역을 재는 멀티스펙트럼과 초스펙트럼 카메라입니다. 근적외선은 과육 속 수분과 화학 성분의 변화에 민감하게 반응하므로, 껍질 속에 감춰진 사정까지 알아낼 수 있습니다. 연구진은 이 원리를 살려 AFMG-DLFF라는 체계를 만들었는데, RGB 사진에서 뽑아낸 1536차원짜리 겉모습 특징과, 당도에서 산도를 뺀 값인 브리마 지수를 포함해 속사정을 인코딩한 512차원짜리 벡터를 하나로 합쳐 2048차원 벡터를 완성합니다.

케이평균 군집화로 덜 익음, 반쯤 익음, 다 익음 세 단계 기준을 세우고, 반딧불이 무리가 서로의 빛 밝기를 좇아 모여드는 습성을 본뜬 글로웸 스웜 최적화 기법으로 학습률과 배치 크기 같은 세부 값을 조정해 결과, 이 융합 모델은 97.86퍼센트의 등급 정확도를 냈습

니다. 같은 조건에서 사진 정보만 쓴 모델은 88.16퍼센트, 사진끼리만 합친 모델은 88.73퍼센트에 그쳤으니, 속사정 데이터를 더한 것이 정확도를 크게 밀어 올렸습니다.

빛이 아니라 열로 익음을 재는 방법도 있습니다. 열매는 익어 갈수록 표면 온도와 둘레 공기 온도의 차이가 점점 줄어드는데, 열화상 센서는 이 미세한 온도 차를 그대로 읽어 냅니다. 기름야자 농장에서는 이 원리에 근적외선 측정과 색상 분석을 더해, 열매송이 속에 든 기름과 유리지방산(FFA) 수치를 자르지 않고 짐작합니다. 나무 밑에 값싼 ESP32-CAM 모듈을 매달아 두면, 저절로 떨어진 낙과를 실시간으로 세고 YOLOv8x 인식 모델과 연결된 웹 대시보드로 관리자에게 알려 줍니다. 이 체계는 최고 0.94에 이르는 F1 점수, 그러니까 정밀도와 재현율을 함께 따진 균형 점수를 기록하며 수확 적기를 놓치지 않게 돕습니다.

농장이 어떤 눈을 갇출지는 돈과 작물의 사정에 따라 갈립니다. 색깔만 봐도 되는 작물이라면 값싼 RGB 카메라 한 대로 충분하지만, 앞에 가려 숨는 열매가 많은 작물이라면 깊이 정보가 있는 RGB-D 카메라가 필요합니다. 망고처럼 겉과 속이 따로 노는 과일에는 근적외선이나 초분광 센서처럼 더 비싼 장비를 들여야 하고, 기름이나 지방산처럼 미세한 성분까지 봐야 하는 작물에는 열화상 센서까지 겹쳐 씁니다. 값싼 카메라 한 대로 시작해서 필요할 때마다 센서를 하나씩 더하는 방식이, 현재로서는 현실적인 도입 순서로 보입니다.

다시 온실 천장의 대차로 돌아가면, 카메라가 하는 일은 사진 한 장을 찍는 데서 끝나지 않습니다. 인공지능은 사진 속 열매마다 네모난 상자를 그리거나, 한 걸음 더 나아가 열매의 테두리를 픽셀 단위로 따라 그려 배경과 오려 냅니다. 문제는 대차가 같은 구간을 다시 지나가거나 카메라 각도가 조금만 바뀌어도 같은 열매를 두 번, 세 번 세어 버릴 위험이 크다는 점입니다. 이를 막기 위해 겹쳐 그려진 상자들 중 신뢰도 점수가 높은 것 하나만 남기고 나머지를 지우는 비최대 억제 기법을 씁니다. 여기에 이번 화면 속 열매가 방금 전 화면에서 본 그 열매와 같은 개체인지를 이어서 쫓는 딥소트 같은 객체 추적 기법을 더합니다. 이 두 장치 덕분에 대차는 온실 한 바퀴를 돌고 나서 중복 없이 정리된 열매 개수를 내놓습니다.

송이로 열리는 토마토는 날개 토마토와는 다른 접근이 필요합니다. 한 온실에서는 순찰 로봇에 인텔 리얼센스 D435i 카메라를 달았습니다. 높이는 1.2미터, 위아래 기울기는 30도, 좌우 회전은 15도로 고정하고, 렌즈와 열매 사이 거리는 0.5에서 1미터로 맞췄습니다. 그 결과 1280×720 해상도, 초당 30장으로 영상을 모읍니다. 로봇이 초속 0.3에서 0.5미터로 레일을 따라 움직이는 동안, 인공지능은 한 송이 안에서 붉게 물든 낱알의 비율을 기준으로 성숙도를 세 단계로 나눕니다. 붉은빛이 열매의 10에서 30퍼센트만 번진 초기, 30에서 70퍼센트인 중기, 70퍼센트를 넘어선 후기입니다. 이 임무를 맡은 LampCT-YOLO 모델은 YOLOv10 백본에 세그넥스트라는 주의 장치를 얹어 색상 정보에 더 민감하게 반응하도록 조정합니다.

온실 골조나 흙바닥처럼 필요 없는 배경 반응은 낮추고, 램프 채널 가지치기라는 경량화 작업까지 더해 로봇에 실린 작은 연산 장치로도 실시간 탐지가 가능하도록 몸집을 줄였습니다.

이 로봇을 좀 더 들여다보면, 몸통에는 엔비디아 젯슨 AGX 오린이나 자비어 NX 같은 엣지 연산 장치가 얹혀 있고, 앞쪽에는 리얼센스 카메라와 함께 2차원 라이다 센서가 붙어 있습니다. 라이다는 빛을 쏘아 되돌아오는 시간을 재서 주변 장애물까지의 거리를 촘촘히 그려 내는 장치로, 로봇이 온실 레일과 통로를 벗어나지 않고 달리게 돕습니다. 카메라와 라이다를 함께 쓰는 이 로봇은 열매의 성숙도를 실시간으로 등급 매기는 데서 그치지 않고, 익은 열매 하나하나의 3차원 좌표까지 뽑아냅니다. 좌표를 알아야 다음 단계에서 로봇 팔이나 사람이 정확히 그 위치로 가서 열매를 딸 수 있기 때문입니다.

농가 입장에서는 병해를 살피는 장치와 성숙도를 판별하는 장치를 따로 쓰는 일이 번거롭습니다. 이 불편을 줄이려고 나온 것이 두 가지 임무를 한 몸에 담은 AgroDualNet입니다. 병해를 살피는 쪽은 CBAM과 ResNet50에 SMO 최적화 기법을 결합해, 잎사귀 병징 사진을 모은 플랜트빌리지 데이터셋에서 99.6퍼센트라는 높은 정확도를 냈습니다. 성숙도를 살피는 쪽은 훨씬 가벼운 MobileNetV2와 YOLOv8을 써서 덜 익음, 반쯤 익음, 다 익음, 물러짐 네 단계를 가려내며, 배터리로 움직이는 작은 장치에서도 실시간으로 돌아갑니다. 하나의 카메라와 하나의 프로그램으로 두 가지 판단을 동시에 받는 셈이니, 농가로서는 장비를 두 벌 갖추지 않아도 됩니다.

일본의 배 재배 현장에서는 설명 가능한 인공지능이라는 다른 과제를 풀어야 했습니다. 등급을 가르는 인공지능이 있어도, 왜 그런 등급을 매겼는지 재배자에게 설명하지 못하면 현장에서는 신뢰를 얻기 어렵습니다. 연구진은 Mask R-CNN이라는 신경망에, 사진 전체를 먼저 훑어 흠집이 있을 법한 부위에 미리 힌트를 주는 전역 맥락 블록을 더해 배 표면의 흠집과 얼룩을 픽셀 단위로 정확히 오려 냈습니다. 그다음 흠집이 전체 표면에서 차지하는 비율을 크다, 조금 크다, 조금 작다, 작다처럼 흐릿한 정도로 나눈 뒤, 전문가의 판정 규칙을 흉내 낸 퍼지 추론 체계에 넣어 실제 시장에서 쓰는 특상, 상, 양호, 등외 네 등급으로 최종 분류했습니다. 딱 잘라 숫자 하나로 답하는 대신 사람의 애매한 판단 방식을 흉내 냈기 때문에, 재배자는 왜 이 배가 이 등급을 받았는지 그 근거를 따라갈 수 있습니다.

넓은 밭 전체를 언제 걷어야 할지 정하는 일에는 드론이 나섭니다. 매빅2프로 드론이 높이 7미터쯤에서, 옥수수 위쪽에 피는 수꽃인 웅화가 자란 포장을 촬영하면 1헥타르를 찍는 데 5분이면 충분합니다. YOLOv5를 기반으로 만든 웅화 탐지 모델이 아직 피지 않음, 막 피기 시작함, 활짝 펴 세 단계로 웅화를 가려내면, 전체 웅화 가운데 활짝 핀 것과 아직 피지 않은 것의 비율 차이로 생육 지수를 계산합니다. 이 지수는 옥수수수염이 언제 나오는지와 강한 음의 상관관계를 보였는데, 상관계수가 마이너스 0.943에 이를 만큼 뚜렷했습니다.

옥수수수염이 나온 날을 기준 삼아 그 뒤로는 하루하루의 기온을 더해 나가는 계산으로 넘어갑니다. 날마다 기온이 높든 낮든 상관없이, 옥수수는 정해진 양의 누적 온도를 다 채워야 다음 단계로 넘어갑니다. 惠味스타라는 품종은 누적 기온이 섭씨 500도에 이르면 수확이 시작되어 560도에서 마무리되고, 허니반탐20이라는 품종은 450도에서 시작해 510도에서 끝나는 식으로 품종마다 다른 기준이 적용됩니다. 이렇게 정해진 수확 적기는 대략 덧새의 기간으로 나타나며, 실제로 수확 한 달 전에 이 방식으로 예측한 결과는 약 70퍼센트의 확률로 맞아떨어졌습니다. 비슷한 방식으로 사과나무의 첫 꽃이 피는 날을 맞추는 연구에서는 날마다 기록한 기온과 고도, 위도, 경도를 함께 넣은 BiLSTM-MhA라는 모델이 개화일을 15일에서 20일 미리 내다보면서도 오차는 하루 남짓, 정확히는 1.34일에 그쳤습니다.

스위트콘 밭에서는 이 예측이 실제로 쓸모가 있는지 현장에서 검증하는 절차도 뒤따랐습니다. 여든 곳 넘는 포장에서 예측 결과를 맞춰 본 결과 70퍼센트라는 정확도가 다시 한번 확인되었습니다. 예측한 날짜에 밭 전체를 한 번에 걷는 일괄 수확과, 열매마다 익은 정도를 봐 가며 여러 날에 걸쳐 따는 선택 수확 사이에 수량 차이는 통계적으로 뜻있는 수준이 아니었습니다(유의확률 0.07). 예측이 맞아떨어진다면 사람이 여러 번 밭을 오가며 고르지 않아도 되고, 기계로 하루 만에 밭 전체를 걷어도 수확량에서는 손해를 보지 않는다는 뜻이 됩니다.

이런 예측 체계가 실제로 쓸모를 가지려면 농장 관리자의 손에 결과가 곧바로 닿아야 합니다. 스위트콘 밭에서는 드론 영상 분석 결과가 지역 기상 자료 서버와 자동으로 연결되어, 사람이 따로 계산기를 두드리지 않아도 수확 예정일이 화면에 뜹니다. 기름야자 농장의 웹 대시보드도 마찬가지로, 관리자는 사무실에 앉아서도 어느 나무 밑에 낙과가 쌓였는지 실시간으로 확인하고 일꾼을 보낼 순서를 정합니다. 현장을 발로 뛰며 확인하던 일을 화면 하나로 옮겨 놓은 셈이며, 이런 자동 연동이야말로 연구실의 모델을 실제 농장의 도구로 바꾸는 마지막 고리입니다.

딸기밭을 사진으로 찍으면 잎 사이사이로 빨간 알갱이들이 다닥다닥 겹쳐 보입니다. 딸기와 복숭아처럼 알이 작고 촘촘히 붙어 자라는 과일은 날개를 구분하는 일 자체가 까다롭습니다. 최근 나온 FruitQuery라는 모델은 트랜스포머 구조를 써서 포장에 열린 딸기와 복숭아의 성숙도를 검출했는데, 평균정밀도 67.02퍼센트를 기록하면서도 매개변수는 1408만 개에 그쳐 YOLOv8과 YOLOv9, YOLOv10보다 가볍고 정확했습니다. 딸기밭 사진은 한 장 한 장 사람이 직접 정답을 표시해야 하는 부담이 커서, 이 표시 작업 자체가 학습의 병목이 됩니다. 2026년에 나온 SSEFNet이라는 모델은 이 부담을 줄이려고 준지도 학습, 즉 몇 장만 표시된 사진과 표시되지 않은 사진을 함께 학습에 쓰는 방식을 골라 복잡하게 뒤엉킨 딸기 데이터셋에서도 91.1퍼센트의 정밀도를 얻었습니다.

플로리다대학교 연구진은 아예 진짜 밭 대신 컴퓨터 속 가상 딸기밭을 지어 놓고 그 안에서 모델을 먼저 훈련시켰습니다. 이렇게 만든 모델이 실제 밭에서 열매를 찾아내는 정확도는 92퍼센트, 열매 지름을 재는 오차는 1.2밀리미터에 그쳐 상업용 등급 선별에 그대로 써도 될 만한 수준에 이르렀습니다. 사진 데이터를 모으고 표시하는 비용 자체가 줄어드는 흐름을 보면, 앞으로는 온도와 습도, 에틸렌 가스 농도를 재는 센서를 영상과 함께 묶는 다중 감각 융합이 다음 단계로 정착할 것으로 보입니다.

수량 예측은 간단해 보이지만 실제로는 그렇지 않습니다. 사진에 찍힌 열매는 어디까지나 촬영 당시 눈에 보이는 것뿐이고, 그 아래 앞에 가려 아직 보이지 않는 열매나 앞으로 몇 주 사이에 새로 맺힐 꽃도 있습니다. 그래서 좋은 예측 모델은 오늘 보이는 열매 수에 그치지 않고, 나무의 생육 단계와 그동안 쌓인 기온, 과거 같은 시기의 수확 기록까지 함께 넣어 계산합니다. 카메라가 본 것은 현재의 한 장면일 뿐이고, 수량 예측은 그 장면에 시간을 더해 미래를 그리는 작업입니다.

개수를 세는 일과 품질을 나누는 일, 수량을 셈하는 일을 한 줄로 이어 붙인 체계도 있습니다. FruitNet이라는 파이프라인은 먼저 YOLOv8로 사진 속 열매를 실시간으로 찾아 1차로 개수를 세고, 그다음 깊은 합성곱 신경망과 서포트벡터머신을 결합한 모델로 열매를 품질 네 단계로 나눕니다. 마지막으로 이때 얻은 등급별 개수와 크기 정보를 랜덤 포레스트 회귀라는 통계 기법에 넣어 밭 전체의 최종 수확량을 셈합니다. 사과 사진 1만 8천 장 넘게, 날개 주석 4만 개 넘게 모은 미네애플 데이터셋으로 시험한 결과 학습 정확도는 98퍼센트를 넘겼고 검증 정확도도 94에서 95퍼센트 사이를 오갔습니다. 열매가 다닥다닥 겹쳐 가려질 때는 겹친 상자를 정리하는 기법과 여러 변수를 함께 보는 회귀 모듈이 중복 계산을 막아 줍니다.

과일을 세고 등급을 매기는 일을 넘어, 로봇 팔이 실제로 그 열매를 따러 가는 길을 정하는 데도 같은 카메라 정보가 쓰입니다. 키넥트나 리얼센스 같은 RGB-D 센서로 열매를 찾은 뒤, 인공지능은 그 판정을 얼마나 믿을 만한지 나타내는 신뢰도 점수와 그리퍼가 손가락 두 개짜리인지 세 개짜리인지, 열매가 수직에서 얼마나 기울어졌는지를 함께 헤아려 하나의 회귀식으로 묶습니다. 이 값을 A*라는 경로 탐색 알고리즘의 비용 계산에 그대로 넣으면, 로봇 팔은 무작정 최단 거리로 뻗는 대신 잡기 좋은 각도와 확실한 열매를 함께 고려해 길을 그립니다. 오렌지를 대상으로 한 시험에서는 결정계수가 0.89, 위치 오차가 3.2센티미터, 백분율 오차가 5.4퍼센트로 나타났습니다. 딸기를 대상으로 한 시험에서는 결정계수 0.82, 위치 오차 4.7센티미터, 백분율 오차 7.9퍼센트를 보였습니다.

이 계산 방식을 더한 뒤로 로봇 팔이 오렌지를 따러 움직이는 거리는 14퍼센트, 딸기를 따러 움직이는 거리는 11퍼센트씩 줄었고, 정확한 위치를 잡아 쥐는 정밀도는 12에서 15퍼센트 올랐습니다.

이렇게 늘어놓고 보면 방향이 보입니다. 처음에는 성숙도만 가려내는 모델과 개수만 세는 모델이 따로 있었지만, AgroDualNet처럼 병해와 성숙도를 함께 보는 모델, FruitNet처럼 개수와 품질과 수량을 한 줄로 잇는 모델, RGB-D 로봇 팔처럼 인식과 동작 계획을 한 몸에 담은 모델이 잇따라 나오고 있습니다. 카메라 한 대, 프로그램 한 벌로 더 많은 질문에 답하게 만드는 쪽이 앞으로의 흐름으로 보이며, 이는 농가가 여러 장비를 따로 사고 따로 관리해야 하는 부담을 줄여 준다는 점에서도 그럴듯한 방향입니다. 카메라를 여러 대 늘어놓는 대신, 한 대로 여러 역할을 동시에 수행하게 만듭니다.

저마다 다른 방식으로 만들어진 이 모델들이 얼마나 잘하는지는 몇 가지 공통된 잣대로 가능합니다. 정확도는 전체 판단 가운데 옳게 맞힌 비율이고, 정밀도는 인공지능이 익었다고 답한 것 가운데 실제로도 익었던 비율이며, 재현율은 실제로 익은 열매 가운데 인공지능이 놓치지 않고 찾아낸 비율입니다. 익지 않은 열매나 상한 열매처럼 수가 적은 부류를 얼마나 잘 잡아내는지 보려면 정밀도와 재현율을 함께 따지는 F1 점수가 요긴합니다. 상자를 얼마나 정확히 그렸는지는 인공지능이 그린 상자와 실제 열매 위치가 겹치는 비율인 IoU로 재고, 여러 신뢰도 기준을 두루 살펴 평균을 낸 mAP는 탐지 모델 전체의 실력을 종합해 보여 줍니다. 로봇이나 순찰 카메라처럼 실시간으로 돌아가야 하는 장치라면 1초에 몇 장을 처리하는지를 나타내는 FPS도 함께 확인합니다.

수량이나 당도처럼 숫자로 답을 내는 예측에는 다른 잣대가 쓰이는데, 평균 절대 오차와 평균 제곱근 오차는 예측값과 실제값이 얼마나 떨어져 있는지를 나타내고, 평균 절대 백분율 오차는 그 차이를 비율로 바꿔 보여 줍니다. 결정계수는 예측 모델이 실제 수량이나 당도가 오르내리는 정도를 얼마만큼 설명해 내는지를 0에서 1 사이의 값으로 나타내며 1에 가까울수록 예측이 정밀하다는 뜻이고, 신선도 점수는 열매 표면 전체에서 흠집 없는 면적이 차지하는 비율을 백분율로 보여 줍니다. 그래서 논문들은 정확도 하나만 내세우지 않고 여러 지표를 나란히 적어, 어느 한 지표만 좋게 보이도록 고르는 일을 막습니다.

이 모든 수치는 결국 한 장의 표로 정리되어 농장 사무실 벽이나 태블릿 화면에 걸립니다. 구역별로 오늘 딴 열매 개수와 등급별 비율, 앞으로 일주일 사이 다 익을 것으로 보이는 열매 수가 나란히 적혀 있습니다. 관리자는 이 표를 보고 내일 몇 명을 어느 구역에 보낼지, 상자를 얼마나 준비할지를 정합니다. 숫자 몇 개가 사람의 하루 일정을 바꾸는 셈이니, 모델의 정확도 1퍼센트 차이가 현장에서는 결코 작은 문제가 아닙니다.

이 그림은 수확에서 끝나지 않고 그 뒤의 물류로 이어집니다. 오늘 몇 상자가 나올지 미리 알면 냉장 트럭을 몇 대 부를지, 선별장 인원을 몇 명 배치할지를 하루 전에 정할 수 있습니다. 반대로 예측이 틀려 갑자기 물량이 몰리면 냉장 창고 앞에 상자가 쌓이고, 몇 상자는 제때 식히지 못해 품질이 떨어집니다. 성숙도 판별과 수량 예측은 밭 안의 기술이면서 동시에 밭 밖의 물류 계획을 흔드는 변수이기도 합니다.

농장주에게 중요한 것은 한결같은 정확도입니다. 맑은 날 촬영한 몇 장에서만 잘 맞고 흐린 날이나 저녁 무렵에는 틀리는 모델은 현장에서 쓸모가 없습니다. 숫자 하나가 어찌다 한 번 잘 나온 것과, 매일 아침 같은 수준으로 나오는 것은 전혀 다른 이야기입니다. 온실 안을 매일 도는 대차형 계수 장치가 시험 기간 내내 성능이 흔들리지 않았다는 사실은, 최고 정확도 수치 못지않게 중요합니다.

현장에 이런 체계를 그대로 옮겨 놓으면 실험실에서는 안 보이던 문제가 드러납니다. 노지에서는 햇빛의 세기가 시간마다 바뀌고, 강한 직사광선은 짙은 그림자를 만들며, 바람이 불면 가지와 잎이 겹쳐다 흩어지기를 되풀이합니다. 렌즈에 먼지가 앉거나 습기가 서리기라도 하면 카메라 한 대에 의존하던 인식 성능은 뚝 떨어집니다. 이런 환경 변화 앞에서 흔들리지 않으려면 여러 각도에서 동시에 찍는 다중 시점 촬영과, 그렇게 얻은 사진을 하나의 입체 점군으로 합치는 3차원 융합 기술이 뒤따라야 할 것으로 보입니다.

겉모습과 속사정이 따로 노는 과일도 여전히 큰 걸림돌입니다. 망고처럼 껍질 색이 끝까지 바뀌지 않거나 껍질이 두꺼운 과일은, 사진만으로는 당도나 산도, 지방산 수치를 알아낼 방법이 없습니다. 저렴한 RGB 카메라에 소량의 화학 측정값을 더하는 융합 방식이나, 근적외선과 초분광 센서 자체를 작고 값싸게 만드는 연구가 함께 가야 합니다. 겉과 속을 함께 보는 눈을 갖추지 못하면, 아무리 정교한 인공지능도 껍질 안쪽 이야기까지는 다 읽어 내지 못합니다.

농장에서 실제로 쓰는 장비는 실험실 컴퓨터처럼 넉넉하지 않습니다. 성능 좋은 비전 트랜스포머나 덩치 큰 합성곱 신경망은 배터리와 그래픽 처리 장치가 빠듯한 소형 로봇이나 값싼 IoT 모듈에서는 반응이 느려집니다. 그래서 숫자를 낮은 정밀도로 바꿔 계산량을 줄이는 양자화, 램프 채널 가지치기처럼 불필요한 연결을 잘라 내는 구조적 가지치기, 큰 모델의 판단을 작은 모델에 옮겨 담는 지식 증류 같은 경량화 기술이 계속 다듬어지고 있습니다. 결국 현장에서 쓰는 인공지능은 주어진 하드웨어 안에서 그나마 실용적인 모델인 경우가 많습니다.

학습 방법 자체에도 혼란 함정이 있습니다. 몇몇 연구는 사진을 돌리고 뒤집고 밝기를 바꾸는 식으로 데이터를 부풀린 다음에야 학습용과 검증용으로 나누는데, 이렇게 하면 같은 열매에서 나온 변형 사진들이 양쪽에 함께 섞여 들어가는 데이터 누출이 생깁니다. 이 경우 검증 점수는 실제 실력보다 부풀려집니다. 이 문제를 막으려면 먼저 학습용과 검증용을 나누고 학습용 쪽에만 데이터를 부풀리는 절차를 지켜야 하며, 검증용은 손대지 않은 원본 그대로 남겨 두어야 합니다. 이런 원칙을 지킨 연구와 그렇지 않은 연구의 발표 수치는 서로 직접 비교할 수 없습니다.

근거 및 참고문헌

학술 논문

1. Bijwe, K. B., & Gadicha, A. B. (2026). FruitNet: a deep hybrid model for fruit detection and yield estimation. *Bulletin of Electrical Engineering and Informatics*, 15(2), 1150-1160. DOI: 10.11591/eei.v15i2.11112.
2. Kripa, S., & Jeyalakshmi, V. (2026). Automated fruit maturity grading using deep learning with feature fusion. Preprint submitted to *Scientific Reports*.
3. Moldvai, L., & Nyéki, A. (2025). Innovative computer vision methods for tomato (*Solanum Lycopersicon*) detection and cultivation: a review. *Discover Applied Sciences*, 7, 975.
<https://doi.org/10.1007/s42452-025-07613-x>
4. Simatupang, et al. (2026). YOLOv8-based IoT system for oil palm harvest readiness identification through loose fruit detection. *Journal of Deep Learning, Computer Vision and Digital Image Processing*, 15(2), 237-249.
5. Zeeshan, S., et al. (2025). Data-driven trajectory optimization in robotic fruit harvesting via deep learning-based perception and actuator-aware motion planning. *Engineering Research Express*, 7, 045210.
6. Deep learning for ripeness grading of oil palm fresh fruit bunches: A comprehensive review. (2026). *Trends in Sciences*, 23(8), 13227.
7. Deep learning-based detection of strawberry fruit and ripeness in smart farming: First review of architectures and methodologies. (2026). *Smart Agricultural Technology*.
8. AgroDualNet: a dual deep learning-based crop disease forecasting and fruit ripening detection framework. (2026). *Scientific Reports*. <https://www.nature.com/articles/s41598-026-49002-3>
9. 大澤央, 齋藤正博, 八木岡敦. (2026). 物体検出AIを活用したスイートコーン収穫適期予測技術の開発. 『農業食料工学会誌』, 88(2), 85-91.
10. 大澤央, 齋藤正博, 八木岡敦. (2026). 加工用スイートコーン収穫適期AI予測技術の開発. 『農業食料工学会誌』, 88(3), 123-128.
11. 劉恩奇, 劉淼, 楊貴軍 등. (2026). 基于时序气温特征增强的苹果始花期Bi-LSTM预测方法. 『智慧農業(中英文)』, 8(2), 84-96.
12. 趙麗成 등. (2026). 基于改进YOLOv10和LAMP通道剪枝的串番茄成熟度检测算法研发. 『智慧農業(中英文)』, 8(2), 133-146.
13. 大域文脈情報を導入した深層学習とファジー推論を用いた洋ナシ等級判定手法の研究. (2026). 『農業情報研究』, 35(2), 65-78.
14. Deep learning-based fruit counting and yield estimation for sweet pepper using a pipe-rail trolley-mounted camera system in a commercial greenhouse. (2026). *Horticulturae*, 11(7), 718.
<https://doi.org/10.3390/horticulturae11070718>
15. FruitQuery: a transformer-based model for strawberry and peach ripeness detection in orchard conditions. (2026).
16. SSEFNet: a semi-supervised learning model for strawberry ripeness detection in complex field datasets. (2026). arXiv:2602.15656. <https://arxiv.org/pdf/2602.15656>
17. Virtual strawberry field simulation for training fruit detection and sizing models. (2026). University of Florida.

강연 및 영상 자료

1. CSUMB College of Business. (2025). 2025 Ag Jobs: Bringing a Greater Vision, Harvesting Data: Careers in Agriculture. YouTube. <https://www.youtube.com/watch?v=rgshB8Jh2ZE>
2. Street Science with Fun. (2025). AI/ML-Powered Mango Detection & Harvesting Machine. YouTube. <https://www.youtube.com/watch?v=Dy3xDC8rElw>

3. Washington State Academy of Sciences. (2025). AI for Post Harvest. YouTube. <https://www.youtube.com/watch?v=hJIOrgNIQG4>
4. Solvi. (2026). Webinar: Validating AI-Based Plant Counts with Real Field Data. YouTube. <https://www.youtube.com/watch?v=B0KujdRtmaQ>
5. Greg Bronevetsky. (2025). Predictive Pattern Recognition of Plant Growth Traits in Simulated and Controlled Environments. YouTube. <https://www.youtube.com/watch?v=uKepfZAnKbk>

2장

원예농업 로봇 및 자율주행 작업 자동화

2.1

과채류·버섯 수확 로봇 및 말단 수확기 (End-Effector)

방울토마토를 따는 로봇은 2026년 4월 기준으로 한 대가 하루 31킬로그램을 스스로 수확하며 일본에서 상업 생산에 들어갔습니다. 같은 달 이스라엘 애그테크 기업 데일리로보틱스(DailyRobotics)는 미국 캘리포니아의 농가에 노지 딸기 수확기를 배치했고, 일본 스타트업 이나호(inaho)의 서비스형 스낵토마토 수확 로봇은 농가의 노동 수요를 45퍼센트 넘게 줄였습니다. 원예작물 수확 로봇 앞에 놓인 과제는 크게 세 가지입니다. 열매가 어디 있는지 보는 일, 얼마나 힘을 주어야 깨지지 않는지 가늠하는 일, 그리고 잘못 쥐었을 때 곧바로 고쳐 잡는 일입니다.

토마토나 딸기, 양송이버섯처럼 사람 손으로 하나하나 따야 하는 작물에서는 수확 작업이 전체 생산 비용의 절반에서 많게는 70퍼센트까지 차지합니다. 농촌에는 일할 사람이 갈수록 줄고 나이는 갈수록 많아지므로, 사람 손을 대신할 로봇 팔에 거는 기대는 해마다 커지고 있습니다. 그런데 지금 상용화된 수확 로봇을 모아 놓고 보면 열매를 따는 데 성공하는 비율은 66퍼센트 안팎에 머물고, 딴 열매 스무 개 가운데 하나꼴로 표면에 상처나 눌린 자국이 남습니다. 사람은 눈으로 보고 손끝 감각으로 힘을 가늠해 가며 열매를 따지만, 로봇은 그 감각을 센서와 계산으로 대신 만들어 내야 합니다. 그래서 과채류와 버섯을 따는 로봇에서는 열매를 실제로 붙잡는 손, 곧 말단 수확기의 생김새와 힘을 다루는 방식이 로봇 팔 전체의 실력을 가릅니다.

수확 로봇의 팔은 심는 방식과 가려진 정도에 따라 생김새가 달라집니다. 가지와 잎이 겹겹이 우거진 나무에서는 관절이 대여섯 개 달린 다관절 팔이 유리합니다. 사람이 어깨와 팔꿈치, 손목을 차례로 돌려 좁은 틈으로 손을 밀어 넣듯, 관절 다섯 개에서 여섯 개를 가진 로봇 팔은 잎 사이 빈틈을 찾아 안쪽 깊숙이 숨은 열매까지 손을 뻗습니다. 반대로 온실 안 파이프 레일을 따라 늘어선 작물처럼 작업 범위가 일정한 원기둥 모양 공간 안에서만 움직이면 될 때는 병렬형 로봇 팔이 더 잘 맞습니다. 짧은 다리 여러 개가 한 점을 함께 떠받치는 병렬형 팔은 구조가 단단하고 반응이 빨라서, 반지름 300밀리미터에 높이 300밀리미터쯤 되는 좁은 공간 안에서도 흔들림 없이 빠르게 움직이며 흡착 방식으로 열매를 뜹니다.

버섯 재배사처럼 선반이 250밀리미터 이하 간격으로 층층이 쌓인 곳에서는 팔이 위아래로 크게 움직일 여유가 없습니다. 이런 곳에는 스카라(SCARA, Selective Compliance Assembly Robot Arm) 구조가 정착했습니다. 스카라 팔은 평평한 면 위에서 좌우로 빠르게 돌다가 필요할 때만 수직으로 살짝 오르내리는 구조라, 얇은 선반 틈으로 팔을 놓히듯 밀어 넣어 버섯을 딸 수 있습니다. 사과나무처럼 열매가 사방으로 흩어져 달린 작물에서는 팔 하나로 손이 모자랍니다. 마스 3.1(MARS 3.1)이라는 이름이 붙은 사과 수확 로봇은 두 개의 팔을 따로 움직이면서, 나무 겉면 바로 안쪽 얇은 구간까지 양쪽에서 동시에 손을 넣어 서로 부딪히지 않게 열매를 나누어 따냅니다.

열매에 실제로 닿는 손끝, 곧 말단 수확기를 만드는 방식은 크게 세 가지입니다. 손가락 세 개가 나사식 구동 장치로 오므라드는 뺏뺏한 기계식 그립은 열매를 가운데로 밀어 모으는 힘이 좋고 무게도 잘 버티며, 필요하면 손끝에 작은 칼날이나 회전 날을 붙여 줄기를 바로 잘라 냅니다. 다만 손가락이 쇠나 딱딱한 플라스틱이다 보니, 열매 표면 한 점에 힘이 몰려 눌린 자국이나 상처가 남기 쉽습니다. 진공 흡착식은 손가락 대신 빨판을 열매 표면에 붙이고 안쪽 공기를 빼내 음압을 만든 뒤, 당기거나 비틀어서 열매를 떼어 냅니다. 표면이 매끈하거나 겹질이 두꺼운 열매에는 잘 맞지만, 표면이 울퉁불퉁하거나 잔털이 많으면 빨판과 표면 사이 틈으로 공기가 새어 들어가 흡착력이 금세 풀려 버립니다.

이 두 방식의 단점을 메우려고 나온 것이 실리콘이나 하이퍼일라스토머 같은 말랑한 소재로 손가락을 만드는 유연 순응형 그립입니다. 손가락 안에 작은 공기 방을 여러 칸으로 나누어 채우고 빼는 정도를 조절해 구부리거나, 지느러미 효과(Fin Ray Effect)라 부르는 구조를 씁니다. 물고기 지느러미처럼 지지대가 비스듬히 엇갈려 있어서 한쪽을 누르면 반대쪽이 저절로 대상을 감싸듯 휘어지는 구조입니다. 이런 손가락은 열매가 둥글든 울퉁불퉁하든 표면 생김새에 맞추어 스스로 모양을 바꾸므로, 힘이 손끝 한 점에 몰리지 않고 넓게 퍼져 열매가 상하는 일을 근본적으로 줄여 줍니다. 손이 부드러워질수록 로봇은 더 세게 쥐고도 열매를 덜 다치게 하는, 언뜻 모순되게 들리는 목표에 가까워집니다.

손이 아무리 부드러워도 눈과 촉각이 없으면 소용없습니다. 로봇은 열매가 정확히 어디에 있는지, 꼭지를 어디서 잘라야 하는지, 손끝에 지금 얼마만큼의 힘이 걸려 있는지를 동시에 알아야 합니다. 이 가운데 위치를 보는 눈 역할은 색과 깊이를 함께 찍는 RGB-D 카메라(인텔 리얼센스 D435i·D405, 마이크로소프트 키넥트 v2 등)와 스테레오 카메라, 3차원 레이저 스캐너가 맡습니다. 색이 있는 화면에서 열매의 익은 정도와 질감을 읽어 내고, 깊이 정보를 겹쳐 점 구름을 만들면 로봇 팔 기준 좌표계에서 열매의 앞뒤·좌우·상하 위치와 둥근 정도, 부피까지 계산해 낼 수 있습니다. 양송이버섯을 딸 때는 이 3차원 스캐너가 버섯 갓의 지름과 높이를 재서, 정해진 출하 규격보다 작은 버섯은 그대로 두고 다 자란 것만 골라 뽑도록 해 줍니다.

눈으로 위치를 찾았다면 그다음은 손끝의 감각입니다. 손가락 안쪽에 붙인 얇은 필름 형태의 압력 센서, 모터에 걸리는 힘을 되읽는 토크 센서, 초음파 거리 센서, 정밀한 위치를 읽는 23비트 인코더, 공기압과 유압을 재는 센서가 한 세트로 움직입니다. 압력 센서는 지금 손가락이 열매에 주는 힘이 그 작물이 견디는 한계를 넘지 않는지 실시간으로 감시하고, 초음파 센서는 열매가 손안에서 미세하게 미끄러지는 순간을 잡아내 모터 힘을 곧바로 다시 조절합니다. 잎과 가지가 뻗뻗하게 우거진 캐노피 구간에 열매가 가려져 있을 때는 손끝에 작은 카메라를 하나 더 붙인 핑거 비전이나, 팔의 위치를 옮겨 가며 다시 찍는 시점 재계획 기능이 함께 작동합니다. 팔이 다가가는 도중 앞이 가려지면 로봇은 곧바로 각도를 바꾸어 가려지지 않은 틈을 다시 찾아냅니다.

열매가 어디 있고 어디를 잘라야 하는지 찾아내는 눈은 딥러닝 탐지 모델이 말합니다. 옐로(YOLO, You Only Look Once) 계열 가운데 최신판인 YOLOv8과 YOLOv10, YOLOv11이 널리 쓰이고, 토마토 전용으로 다듬은 LampCT-YOLO 모델은 YOLOv10을 백본으로 삼아 세그넥스트(SegNeXt)라는 주의 기법을 엮었습니다. 세그멘테이션, 곧 사진 속 물체의 테두리를 픽셀 하나하나까지 따라 그려 오려 내는 작업에 곁들이는 이 기법 덕분에, 온실 안 잎이 뒤섞인 어수선했던 배경에서도 토마토가 얼마나 익었는지를 가리키는 색 신호에 더 무게를 둡니다. 여기에 램프(LAMP) 가지치기라는 기술을 더해 계산량을 줄였으므로, 값비싼 서버 없이도 현장의 작은 제어 장치에서 곧바로 돌아갑니다.

정확한 절단 위치를 찾을 때는 스윙프트 트랜스포머 V2(Swift Transformer V2) 모델과, 픽셀 덩어리의 모양을 보고 다듬는 전통적인 형태학적 영상 처리 방식을 함께 써서 열매와 꽃받침, 과경을 따로따로 오려 냅니다.

이렇게 학습을 마친 모델은 화면 가득한 노트북이 아니라 팔 옆에 붙은 작은 상자 안에서 돌아가야 실제로 쓸모가 있습니다. 엔비디아 젯슨 자비에 NX와 AGX 오린, 라즈베리파이 5, 오므론 PLC 같은 현장용 제어기에 ONNX나 텐서RT 형식으로 가볍게 다듬은 모델을 옮겨 담습니다. 이렇게 갖춘 로봇이 열매 하나를 알아보고 따는 데 걸리는 시간, 곧 수확 주기는 작물과 손 모양에 따라 다릅니다. 양송이버섯을 스카라 팔로 딸 때는 한 개에 10초가 걸리지 않고, 사과를 따는 마스 3.1은 팔 하나가 열매 하나를 따는 데 7초에서 9초, 딸기는 4초에서 11초, 오렌지는 7초에서 11초 정도가 걸립니다.

로봇의 실력은 몇 가지 숫자로 가능합니다. 카메라가 열매와 과경을 얼마나 정확히 찾아내는지는 평균정밀도(mAP)라는 지표로 나타내고, 찾아낸 위치와 실제 위치가 얼마나 어긋나는지는 센티미터 단위 오차로 잽니다. 하지만 밭에서 일하는 사람에게 정작 중요한 숫자는 따로 있습니다. 시도한 것 가운데 실제로 열매를 따는 데 성공한 비율, 딴 뒤에 표면이 상한 열매의 비율, 손가락이 열매 겉면을 얼마나 넓게 감싸 안았는지 보여 주는 포위율, 그리고 작물마다 정해진 안전한 힘의 범위 안에서 쥐었는지가 그것입니다. 딸기는 8뉴턴에서 12뉴턴, 오렌지는 80뉴턴 가까이, 감귤은 6뉴턴에서 8뉴턴 사이를 안전한 파

지력 범위로 잡는데, 사과 하나를 손끝으로 살짝 누르는 힘과 아이 손을 꼭 쥐는 힘 사이의 차이를 떠올리면 그 크기를 가늠할 수 있습니다.

가 지나 과정이 불필요하게 부러지지 않았는지를 보는 보전율도 함께 기록합니다.

토마토는 껍질이 물렁하면서도 꼭지와 열매가 단단히 이어져 있어서, 눌러서 깨지는 것과 당겨서 안 떨어지는 것 사이 어딘가에서 손 모양을 정해야 합니다. 실리콘 소재인 드래곤 스킨 30으로 만든 손가락 세 개, 공기방 네 칸짜리 유연 그립은 유전 알고리즘으로 찾아낸 28.293킬로파스칼의 공기압을 넣어 열매를 감싸칩니다. 유전 알고리즘이란 여러 조합을 시험 삼아 만들어 보고 그 가운데 성적이 좋은 것끼리 다시 섞어 가며 최선의 답에 가까워지는 계산 방식으로, 사람이 값을 일일이 손으로 조정하지 않아도 됩니다. 이렇게 다듬은 손으로 토마토를 쥐고 9일 넘게 두어도 상한 흔적이 전혀 없었고, 실제로 움직이며 따는 시험에서는 100개 가운데 97개꼴로 성공했습니다.

또 다른 방식은 사람의 손동작을 그대로 흉내 냅니다. 손가락 세 개로 토마토를 쥔 채 360도로 비틀어 돌리면, 식탁에서 토마토를 딸 때 무심코 하는 손목 동작과 똑같이 과정이 다치지 않고 열매만 떨어져 나옵니다. 과정을 아예 잘라 내는 방식을 쓸 때는 스위프트 트랜스포머 V2 모델이 정확한 절단 위치를 찾아 줍니다. 온실 레일 위를 오가는 이동식 로봇에 LampCT-YOLO를 얹은 순찰형 수확 로봇은 여러 개가 한 다발로 열리는 송이토마토의 익은 정도를 초록, 주황, 빨강 세 단계로 곧바로 가려내며 하루 종일 온실 사이를 오갑니다.

딸기는 살이 어려서 작은 힘에도 멍이 들거나 짓무릅니다. 그래서 다른 어떤 작물보다 손이 닿는 면적과 힘의 크기를 줄이는 쪽으로 설계 방향이 잡힙니다. 손가락 세 개 대신 두 개만 쓰는 유연 실리콘 그립은 딸기 표면에 닿는 면을 최소한으로 줄이고, 8뉴턴에서 12뉴턴 사이의 아주 작은 힘만 줍니다. 여기에 회귀 분석과 A* 탐색을 섞은 경로 계산 방식을 더하면 손이 열매를 쥐는 위치의 정확도가 15퍼센트 올라가고, 팔이 움직이는 거리는 11퍼센트 줄어듭니다. 열매 몸통에는 아예 손을 대지 않는 방법도 있습니다. 카메라로 꼭지 자루의 위치를 찾은 뒤 가위 모양의 손끝이 자루만 잘라 내면서, 잘린 자루를 그대로 집어 수거 상자로 옮기는 방식입니다.

흡착 방식을 쓸 때는 15밀리미터 깊이의 말랑한 흡착 컵을 딸기 표면에 대고 2.38뉴턴의 흡착력을 만드는데, 이때 열매에 실제로 걸리는 압력은 딸기 과육이 건디는 한계의 20퍼센트에서 31퍼센트 수준이라 상하지 않고 딸 수 있습니다. 이런 손 기술은 이미 실제 밭으로 나가고 있습니다. 이스라엘 애그테크 기업 데일리로보틱스(DailyRobotics)는 2026년 4월부터 미국 캘리포니아의 농가에 노지 딸기 수확기 큐투(Q2)를 배치했습니다. 로봇 팔 두 개와 부드러운 그리퍼를 갖춘 이 기계는 딸기를 따는 즉시 클램셀이라 부르는 투명 포장 용기에 담아내며, 회사 쪽은 사람보다 2배에서 3배 빠르다고 밝혔습니다.

양송이버섯 재배사는 선반이 250밀리미터 이하 간격으로 여러 층 쌓여 있어서 팔이 위로 솟아오를 공간이 없습니다. 이 문제를 스카라 구조로 된 저장형 수확 로봇은 수직으로 오르내리는 축 하나와 좌우로 도는 관절 두 개를 조합해, 팔을 눕히듯 낮은 자세로 선반 사이에 밀어 넣습니다. 수직 축에는 파동 기어라 부르는 정밀 감속 장치와 벨트, 무게 균형을 잡아 주는 추를 함께 달아서 덜컹거림을 거의 없애고 1밀리미터 오차 안에서 위치를 맞춥니다. 3차원 스캐너가 버섯 갓의 지름을 먼저 재고, 정해진 출하 규격에 맞는 것만 흡착 컵이나 유연 그립으로 뽑아내는데, 이 모든 과정이 버섯 한 개당 10초가 채 걸리지 않습니다.

사과나무 한 그루에는 열매가 앞뒤로 여러 겹 달려 있어서 팔 하나로는 안쪽 깊은 열매에 손이 닿지 않습니다. 두 팔을 따로 움직이는 마스 3.1은 나무 표면 바로 안쪽 얇은 구간까지 양쪽에서 동시에 손을 넣어, 팔 하나가 열매 하나를 따는 데 7초에서 9초 만에 처리하면서도 멍이 든 열매의 비율을 1퍼센트 아래로 낮였습니다. 한 팔이 앞쪽 가지의 열매를 따는 동안 다른 팔은 안쪽 깊은 곳의 열매로 곧장 파고들어 시간을 벌어들이는 방식입니다. 손끝에 지느러미 효과 구조와 모터 토크 되읽기, 초음파 미끄럼 감지를 모두 얹은 시험에서는 손상률을 0퍼센트까지 낮춘 결과도 나왔습니다.

오렌지는 껍질이 두껍고 질겨서 오히려 힘을 넉넉히 주어도 되는 쪽에 속합니다. 손가락 세 개짜리 실리콘 그립에 최대 80뉴턴까지 힘을 실을 수 있도록 설계하고 A* 경로 탐색을 더하면, 팔이 움직이는 거리가 14퍼센트 줄고 쥐는 위치의 정확도는 12퍼센트 올라갑니다. 오이는 반대로 표면이 울퉁불퉁하고 굴곡이 심해서 흡착 컵 하나로는 빈틈없이 붙기가 어렵습니다. 종이접기, 곧 오리가미 방식으로 주름을 잡은 흡착 컵은 오목하게 휘어진 곡면 구조를 살려 오이 표면에 맞추어 스스로 접히고 펴지며, 흡착이 닿는 반지름을 10.66밀리미터까지 넓혀 밭에서 86.2퍼센트의 수확 성공률을 냈습니다. 열매마다 껍질 두께와 굴곡이 다른 만큼, 손끝 하나로 모든 작물을 다 딸 수 있다는 생각은 아직 이릅니다.

이런 손끝 기술은 실험대를 벗어나 실제 농장의 하루 일과 속으로 들어가고 있습니다. 일본에서는 방울토마토를 따는 로봇이 3년 가까이 현장에서 고치고 다듬은 끝에, 2026년 4월 기준으로 한 대가 하루 31킬로그램을 스스로 따냅니다. 과채류 수확 로봇을 상업 농장에 불박이로 들여놓고 계속 운영하는 사례는 세계적으로도 드뭅니다. 일본 스타트업 이나호(inaho)가 만든 스넥토마토 수확 로봇은 사서 쓰지 않고 빌려 쓰는 서비스형 방식을 택해, 농가가 큰돈을 들이지 않고도 일손을 45퍼센트 넘게 덜었습니다. 2026년에는 이런 임대 로봇을 시범으로 들인 농장이 다섯 곳에 그쳤지만, 같은 해 티티에이이소(TTA-ISO)는 사람 손을 거의 안 타는 완전 자동 토마토 수확 로봇을 내놓아 첫 인도를 앞두고 있습니다.

딸기 쪽에서는 밭에서 실제로 잔 열매의 위치와 방향 데이터를 모아 공개한 자료도 나와, 여러 연구팀이 같은 잣대로 자기네 로봇의 실력을 견줄 수 있게 되었습니다. 기계 한 대가 매일 정해진 양을 스스로 채워 넣는 이런 사례들은, 과채류 수확 로봇이 시험 삼아 돌려 보는 단계를 지나 실제 매출과 인건비 계산 안으로 들어왔다는 뜻으로 읽힙니다.

이 정도로 손끝 기술이 정교해졌는데도 사람 손을 완전히 대신하기까지는 몇 가지 벽이 남아 있습니다. 잎과 가지, 열매가 겹겹이 겹친 비정형 캐노피 안에서는 카메라 하나로 열매 중심과 꼭지 위치를 빠짐없이 찾아내기가 어렵습니다. 시야 한쪽이 가려지면 팔이 엉뚱한 곳에 부딪히거나 눈에 띄지 않은 열매를 그냥 지나치게 됩니다. 점 구름을 여러 시점에서 겹쳐 보는 기술과, 가려진 정도에 따라 스스로 각도를 바꾸는 능동 촬영 기술을 더 다듬어야 이 벽을 낮출 수 있습니다.

말랑한 손가락이 안고 있는 숙제도 있습니다. 실리콘 재질 유연 그립은 열매를 상하지 않게 하는 데는 뛰어나지만, 공기를 채우고 빼는 반응 속도가 느리고 무거운 열매를 들어 올리는 힘에는 한계가 있으며, 오래 쓰면 소재 자체가 늘어지거나 갈라집니다. 평소에는 부드럽게 감싸다가 쥐는 순간에만 알갱이를 뭉쳐 순간적으로 딱딱해지는 구조, 이른바 가변강성 방식이 이 문제를 풀 실마리로 꼽힙니다. 커피 가루를 봉지에 담고 공기를 빼면 봉지가 단단하게 굳는 원리를, 손가락 안에 그대로 옮겨 심는 연구가 여러 곳에서 진행되고 있습니다. 이 모순을 어떻게 풀어내는지가 앞으로 몇 년 동안 수확 로봇 회사들의 순위를 가르는 잣대가 될 가능성이 큼니다.

값도 걸림돌입니다. 정밀 감속기와 3차원 센서, 여러 개의 모터를 갖춘 수확 로봇 한 대 값은 작은 농가가 선뜻 사기에는 부담스러운 수준입니다. 게다가 밭이나 온실의 먼지와 진동, 습기 속에서는 센서가 쉽게 더러워지고 부품이 자주 고장 납니다. 부품을 통째로 갈아 끼울 수 있는 표준 규격과 현장에서 바로 손볼 수 있는 정비 체계가 갖추어져야 이 기술이 널리 퍼질 수 있습니다.

마지막으로 남는 숙제는 로봇이 왜 그렇게 판단했는지를 사람이 알아볼 수 있게 만드는 일입니다. 영상과 깊이 정보, 손끝 압력 신호를 제어기 안에서 지연 없이 한데 모으는 일은 물론이고, 로봇이 왜 그곳을 쥐고 왜 그만큼의 힘을 주었는지를 재배자에게 화면으로 보여 주는 기술이 함께 갖추어져야 합니다. 이런 기술을 설명 가능 인공지능, 곧 XAI(Explainable AI)라고 부르는데, 이 설명이 있어야 농부가 로봇의 판단을 믿고 밭 전체를 맡길 수 있습니다. 손끝의 힘 조절과 눈의 인식 능력이 아무리 좋아져도, 그 판단과정을 사람이 들여다볼 창이 없다면 로봇은 여전히 낯선 일꾼으로 남습니다.

여섯 작물을 나란히 놓고 보면 손끝 설계의 방향이 뚜렷하게 갈립니다. 딸기와 토마토처럼 껍질이 여리고 시장에서 비싸게 팔리는 작물에는 공기방과 흡착처럼 살살 다루는 손끝이 먼저 개발되고, 오렌지처럼 껍질이 두꺼워 웬만한 힘에는 끄떡없는 작물에는 힘을 넉넉히 주는 손끝이 뒤따릅니다. 오이처럼 흔하지만 표면이 울퉁불퉁해 흡착 자체가 까다로

운 작물에는 뒤늦게 오리가미 구조 같은 별도의 풀이가 나왔습니다. 사람이 손끝 감각으로 자연스럽게 가려 온 이 일이, 로봇에서는 작물마다 완전히 다른 설계도로 나뉘어 나옵니다.

홍화 밭 위로 병렬형 로봇 팔이 낮게 떠서 빠르게 오가고, 손끝이 스칠 때마다 실 같은 꽃술이 한 움큼씩 사라집니다. 눈으로 열매를 찾아내고 손끝으로 힘을 가늠하는 능력을 갖추어도, 어느 열매부터 딸지 순서를 잘못 정하면 팔은 이미 지나온 곳으로 되돌아가느라 시간을 흘려보냅니다. 순서를 정하는 이 일은 로봇의 머리에 해당하는데, 홍화 밭에서 이 문제가 가장 도드라집니다. 홍화 한 송이에는 가는 꽃술이 스물다섯 개에서 서른한 개까지 촘촘히 뭉쳐 있어서, 로봇은 눈에 띄는 대로 따라가서는 안 되고 전체를 한 바퀴 도는 가장 짧은 길부터 미리 그려야 합니다.

외판원 문제(TSP, Traveling Salesman Problem)로 알려진 최단 경로 계산 방식을 빌려, 강화학습으로 훈련한 포인터 네트워크가 꽃술의 위치를 입력받고 가까운 목표에 더 무게를 두는 계산을 거쳐 방문 순서를 곧바로 새로 잡니다. 병렬형 로봇 팔이 이 순서를 따라 흡입 장치와 결합한 손끝으로 꽃술을 거두어들이면, 순서 없이 눈에 띄는 대로 따라갈 때보다 이동 거리가 11.5퍼센트에서 20.17퍼센트까지 줄어듭니다.

딸기와 오렌지에서 앞서 본 길찾기 개선도 비슷한 계산에서 나옵니다. 로봇 팔이 다음에 어디로 움직일지 정할 때는 카메라가 지금 본 열매를 얼마나 확신하는지, 손끝이 어떤 그림인지, 다가가는 각도가 얼마나 비뚤어졌는지를 함께 따집니다. 이 값을 회귀분석으로 미리 다듬어 둔 계산식에 넣으면 다음 걸음에 드는 비용을 미리 어림할 수 있고, 그 어림값을 바탕으로 A*라는 길찾기 방식이 실제 경로를 그립니다. 확신이 낮은 방향은 에둘러가고 손끝이 다치기 쉬운 각도는 피하면서, 되도록 아흔 도에 가까운 곧은 각도로 열매에 다가가도록 길을 미리 굽혀 놓습니다. 사람이 눈대중으로 익힌 요령을 계산으로 옮겨 놓았을 뿐인데, 팔이 헤매는 시간이 눈에 띄게 줄어듭니다.

카메라가 앞서 말한 확신을 갖추기까지는 미리 치른 연습이 있습니다. 사진을 찍은 그대로 넣어 가르치면 로봇은 맑은 날 정면에서 찍은 모습만 알아봅니다. 그래서 훈련용 사진을 일부러 흔들어 놓습니다. 사진을 이리저리 돌리고 밝기를 올리거나 낮추고 자잘한 잡음을 섞어, 앞 사이로 비치는 그늘이나 흐린 날의 어두운 빛까지 미리 겪어 보게 합니다. 이런 손질을 거친 사진 여러 장으로 에이담(Adam)이라 부르는 학습 방식을 거치고 나면, 밭에 나가 낮선 각도와 낮선 빛을 만나도 로봇이 쉽게 당황하지 않습니다.

이렇게 갖춘 머리와 손끝의 실력을 썰 때는 눈의 정확도 하나로 다 말하지 않습니다. 잣대를 느슨하게 잡았을 때와 빡빡하게 잡았을 때를 따로 계산해 카메라가 얼마나 꾸준히 맞히는지 보고, 회귀분석으로 뽑은 경로 예측값이 실제 경로와 얼마나 들어맞는지도 결정계수와 오차율로 따로 매깁니다. 현장의 작은 제여기가 사진 한 장을 보고 답을 내놓기까지 걸리는 시간과, 1초 동안 몇 장을 처리해 내는지도 함께 쥅니다. 길을 얼마나 줄였는지, 시

간을 얼마나 아꼈는지를 백분율로 나타낸 수치도 나란히 기록해 두어야 서로 다른 로봇의 실력을 견줄 수 있습니다.

논문에 나오는 숫자와 밭에서 체감하는 숫자는 층이 다릅니다. 포위율이 몇 퍼센트 올랐거나 경로가 십몇 퍼센트 줄었다는 숫자는 같은 조건에서 이전 방식과 견주었을 때의 개선폭을 보여 줄 뿐입니다. 시험 밭은 이랑 간격과 조명을 사람이 미리 맞추어 둔 곳이지만, 진짜 농장은 그렇게 고분고분하지 않습니다. 하루에 몇 킬로그램을 땀는지, 일손이 몇 퍼센트 줄었는지는 그 로봇을 실제 농장에 세워 두고 여러 날 돌려 본 뒤에야 나오는 숫자입니다. 지금까지 나온 사례 가운데 이 두 층의 숫자를 나란히 내놓은 로봇은 많지 않습니다.

딸기 쪽 데이터셋이 위치와 함께 기울어진 방향까지 담은 데에는 이유가 있습니다. 열매가 어디 있는지만 알아서는 부족하고, 꼭지가 어느 쪽을 향해 있는지까지 알아야 손끝이 곧은 각도로 다가가 과정을 다치지 않고 딸 수 있기 때문입니다. 이런 자세 정보를 여러 밭에서 모아 공개해 두면, 새로 뛰어드는 연구팀이 처음부터 사진을 다시 찍어 모으는 수고를 덜고 곧바로 손끝 설계를 시험해 볼 수 있습니다.

수확 로봇을 사서 쓰지 않고 빌려 쓰는 방식이 나온 것도 이런 사정과 맞물려 있습니다. 정밀 감속기와 3차원 스캐너, 계산 장치까지 얹은 로봇 한 대를 통째로 사들이는 부담을 덜어 주려는 공리입니다. 그런데 로봇을 새 밭에 옮겨 놓을 때마다 사정이 또 달라집니다. 온실 구조와 재배 방식, 심는 간격이 농가마다 다르므로 카메라를 다시 맞추고 손끝의 힘값을 새로 재는 손질이 매번 필요합니다. 열매 하나를 손상 없이 따는 실력과, 그 실력을 다른 밭에 그대로 옮겨 심는 실력은 서로 다른 숙제입니다.

밭을 가진 사람 입장에서 보면 셈법이 눈에 들어옵니다. 사람 일손을 구하기 어려운 철에 로봇 한 대를 며칠 빌려 돌려 보고, 손상률과 하루 수확량이 감당할 만하면 그다음 철에 대수를 늘리는 식입니다. 사들이기 전에 내 밭에서 먼저 시험해 볼 길이 열려 있다는 점이 값비싼 기계 한 대를 한 번에 결단해야 했던 예전과 가장 다른 점입니다.

이렇게 공들여 훈련한 모델도 한 번에 한 작물만 알아봅니다. 토마토의 익은 정도를 귀신 같이 가려내던 눈은 딸기 밭에 데려다 놓으면 처음부터 다시 배워야 합니다. 딸기의 여린 살을 다치지 않게 설계한 손끝을 사과나무에 옮겨 달면 무거운 열매를 놓치기 십상입니다. 사람은 밭을 옮겨 다니며 눈과 손의 감각을 저절로 조정하지만, 로봇은 작물 하나가 바뀔 때마다 눈을 다시 가르치고 손끝을 다시 깎아야 합니다. 여러 작물을 오가며 일하는 진짜 일꾼에 가까워지려면, 작물마다 따로 만든 눈과 손을 한데 묶어 두고도 서로 다른 밭에서 곧바로 실력을 발휘하게 만드는 기술이 더 있어야 합니다.

눈과 손끝을 다듬는 일이 지난 몇 해 동안의 숙제였다면, 어느 순서로 돌지를 스스로 정하는 머리를 달고 그 성과를 같은 잣대로 재는 일, 그리고 한 작물과 한 밭에서 익힌 실력을

다른 작물과 다른 밭으로 옮기는 일은 이제 막 시작된 숙제입니다. 홍화밭에서 검증한 계산법이 딸기 하우스나 사과나무 사이에서도 통할지는 앞으로 몇 해의 현장 시험이 답을 내놓을 것입니다. 손끝과 눈과 머리는 지금 각각 다른 작물과 다른 밭에서 따로 검증되고있으며, 이 세 요소를 하나의 로봇 안에서 통합하는 작업은 아직 이루어지지 않았습니다.

근거 및 참고문헌

학술 논문

1. Feng, K. (2026). Structural Forms and Crop Adaptation Mechanisms of End-Effectors for Fruit and Vegetable Harvesting. Automation and Machine Learning, 7(2), 60-67. DOI: 10.23977/autml.2026.070207.
2. Zeeshan, S., Malik, M. A. I., et al. (2025). Data-driven trajectory optimization in robotic fruit harvesting via deep learning-based perception, gripper configuration, and fruit morphometrics. Engineering Research Express, 7, 045210.
3. Minorowicz, B., Patalas, A., & Łuczak, A. (2026). Design of a SCARA Robotic Arm for Mushroom Harvesting. Acta Mechanica et Automatica, 20(2), 366-378. DOI: 10.65731/ama/2026-0037.
4. Li, M., Wang, X., Liu, Z., Duan, M., & Jin, Z. (2026). DEMA-3D TSP: An Enhanced Reinforcement Learning with DEMA Attention in Sequence Optimization for Safflower Picking Robot. Smart Agriculture, 8(2), 200-219. DOI: 10.12133/j.smartag.SA202506004.
5. Zhao, L., Lu, X., Wu, Q., Ren, N., Zhou, L., Cheng, Y., Hu, A., & Qi, C. (2026). An Improved YOLOv10-Based Tomato Ripeness Detection Algorithm with LAMP Channel Pruning. Smart Agriculture, 8(2), 133-146. DOI: 10.12133/j.smartag.SA202507045.
6. Moldvai, L., & Nyéki, A. (2025). Innovative computer vision methods for tomato (Solanum Lycopersicon) detection and cultivation: a review. Discover Applied Sciences, 7, 975. <https://doi.org/10.1007/s42452-025-07613-x>

강연 및 영상 자료

1. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026 Global Agrifood Innovation Roadshow Launch Event & Inaugural Roadshow. YouTube. https://www.youtube.com/watch?v=U5CReIR_Rrg
2. World AgriFood Innovation Conference (WAFI). (2026). Australia Agrifood Innovation | WAFI2026 Global Agrifood Innovation Roadshow. YouTube. <https://www.youtube.com/watch?v=ITnVRq1Tioo>
3. C-DAC. (2025). AI in Agriculture: Transforming India's Krishi Landscape. YouTube. https://www.youtube.com/watch?v=IV3_VnWiBpM
4. Street Science with Fun. (2025). AI/ML-Powered Mango Detection & Harvesting Machine. YouTube. <https://www.youtube.com/watch?v=Dy3xDC8rElw>
5. Department of ECE, MGR Educational and Research Institute. (2025). Expert Talk on An Overview - Role of Computer Vision in Autonomous Navigation for Smart Agriculture. YouTube. <https://www.youtube.com/watch?v=GVZ46DY2Tao>
6. UC Agriculture and Natural Resources. (2025). 2026 Farm Robotics Challenge - IP 101. YouTube. <https://www.youtube.com/watch?v=JA1greBXSoA>
7. HortiQD. (2026). HortiQD 4th Webinar: The Data Bridge: Connecting Farmers and Robots for Smarter Agriculture. YouTube. <https://www.youtube.com/watch?v=7W8NbMdhuss>

8. Farm Foundation. (2025). Farm Foundation Forum: Automation for a Resilient Future for Agriculture. YouTube. <https://www.youtube.com/watch?v=aWWqVnNkhoQ>

기사 및 온라인 자료

1. AgFunderNews. (2026). DailyRobotics gears up for commercial launch in California in 2026 with robotic strawberry harvester. AgFunderNews. <https://agfundernews.com/dailyrobotics-gears-up-for-commercial-launch-in-california-in-2026-with-robotic-strawberry-harvester>
2. HortiDaily. (2026). Japanese agri-tech startup puts cherry tomato harvesting robot into routine production use. HortiDaily. <https://www.hortidaily.com/article/9842754/japanese-agri-tech-startup-puts-cherry-tomato-harvesting-robot-into-routine-production-use/>
3. HortiDaily. (2026). Harvest robot snack tomato commercial ready. HortiDaily. <https://www.hortidaily.com/article/9778303/harvest-robot-snack-tomato-commercial-ready/>
4. Future Farming. (2026). TTA-ISO introduces fully automated tomato harvesting robot. Future Farming. <https://www.futurefarming.com/tech-in-focus/field-robots/tta-iso-introduces-fully-automated-tomato-harvesting-robot/>
5. arXiv. (2026). [딸기 수확 로봇용 포장 실측 6D 자세 데이터셋 및 기준 모델 프리프린트]. arXiv:2606.11381. <https://arxiv.org/pdf/2606.11381>

2.2

자율주행 로봇·드론 군집의 경로 최적화와 정밀 방제

하일리오스는 조종자 한 명이 드론 세 대로 이루어진 군집을 동시에 감독하는 방식으로 미국 연방항공청의 승인을 받았습니다. 이때 조종자는 드론을 직접 움직이는 조이스틱 대신, 여러 기체의 상태를 함께 보여주는 화면을 손에 들고 있습니다. 이 회사가 내놓은 HYL-150 ARES는 약 50킬로그램을 싣고 시간당 20헥타르가 넘는 면적에 약제를 뿌리며, XAG P150은 인공지능으로 장애물을 스스로 알아채는 감지 기능을 갖췄습니다. 드론 여러 대가 스스로 구역을 나누고 방향과 속도를 맞추는 이런 승인 사례 뒤에는, 사람이 하나하나 짜 줄 수 없을 만큼 복잡한 경로를 기계가 대신 계산해 주는 과정이 있습니다.

로봇 팔 끝의 손가락이 열매를 정확히 쥐는 기술과는 또 다른 문제가 그 앞에 놓여 있습니다. 손이 아무리 아무저도 어느 순서로 어디부터 움직일지 정하지 못하면, 로봇은 같은 이랑을 두 번 지나치거나 먼 곳부터 헤매다 배터리를 다 쓰고 맵니다. 포장 안에 흩어진 열매나 잡초, 꽃실은 가지런히 줄지어 있지 않습니다. 나뭇가지에 가려 안 보이던 열매가 로봇이 옆으로 옮겨 가면 갑자기 나타나기도 하고, 바람에 앞이 흔들리면 방금 보이던 열매가 다시 가려지기도 합니다. 우체부가 하루 배달할 집 스무 곳을 놓고 최단 경로를 짜는 문제를 외판원 문제라 부르는데, 농장의 로봇과 드론은 이 문제를 평면이 아니라 높이까지 포함한 입체 공간에서 풀어야 합니다. 그래서 이 과제를 3차원 외판원 문제, 영어로는 3D Traveling Salesman Problem을 줄여 3D-TSP라 부릅니다.

목표점이 스물다섯 개, 서른 개를 넘어가면 경우의 수가 순식간에 불어나고, 유전자 알고리즘처럼 오래전부터 쓰던 탐색 기법은 계산에 시간을 너무 많이 쓰거나 진짜 최선은 아닌 답에서 멈춰 버리곤 합니다.

이 문제를 풀려는 시도가 강화학습 이전에도 없었던 것은 아닙니다. 개미가 먹이를 찾아다니며 남긴 냄새 자국을 서로 따라가는 습성을 흉내 낸 개미 군집 알고리즘이나, 새 떼가 대형을 이루며 나는 모습을 본뜬 입자 군집 알고리즘도 한때 쓰였습니다. 이런 방식은 곤충이나 새의 무리 행동에서 규칙을 빌려 오는 셈이어서 나름의 설득력이 있었지만, 목표점의 수가 늘어나고 장애물이 시시각각 나타나는 실제 밭 앞에서는 계산이 끝날 때까지 로봇이 하염없이 멈춰 서 있어야 하는 문제를 안고 있었습니다. 미리 정해진 규칙을 따르는 대신 수많은 시도에서 스스로 규칙을 뽑아내는 강화학습이 그 뒤를 이어받은 것은, 밭

마다 다르고 계절마다 달라지는 조건에 규칙을 일일이 새로 짜 넣을 수 없다는 현실적인 이유가 큼니다.

이 문제를 새로 풀어낸 방식이 강화학습과 포인터 네트워크를 엮은 열개입니다. 강화학습은 정답지를 미리 주지 않고, 스스로 시도해 본 결과에 점수를 매겨 가며 조금씩 나아지게 만드는 학습 방식입니다. 포인터 네트워크는 다음에 갈 곳을 새로 지어내지 않고, 이미 입력으로 들어와 있는 좌표들 가운데 하나를 손가락으로 짚듯 골라내는 신경망입니다. 이 둘을 묶은 구조는 배우와 평론가에 빗댈 수 있습니다. 액터라 부르는 신경망이 다음에 방문할 좌표의 순서를 하나씩 제안하는 배우 역할을 하고, 크리틱이라 부르는 신경망은 그 제안이 전체적으로 얼마나 효율적인 경로가 될지 미리 점수를 매기는 평론가 역할을 합니다. 배우는 평론가의 채점을 참고해 다음번 제안을 조금씩 고쳐 나가고, 이 과정을 수천 번 되풀이하면서 점점 더 짧은 경로를 고르는 감각을 몸에 익힙니다.

이 판단을 더 정교하게 다듬으려고 몇 가지 장치가 더해집니다. 다중 헤드 자가 주의라는 계산 방식은 좌표 하나하나가 다른 모든 좌표와 얼마나 가깝고 어느 방향에 놓여 있는지를 한꺼번에 견주어 보게 해 주고, 거리 인코딩은 좌표들 사이의 실제 유클리드 거리를 숫자로 미리 계산해 신경망에 참고 자료로 건네줍니다. 여기에 동적 지수이동평균, 영어 약자로 DEMA라 부르는 기법을 더하면 최근에 지나온 경로에는 무게를 더 싣고 오래전 경로는 서서히 잊어 가며 판단을 갱신할 수 있습니다. 중국에서 개발되어 홍화, 우리말로는 잇꽃이라 부르는 국화와 작물의 수확 로봇에 실제로 얹힌 AC-RL-PtrNet이라는 모델이 이 조합을 그대로 구현한 사례입니다.

이 모델은 장단기 메모리, 영어 약자로 LSTM이라 부르는 구조로 입력된 3차원 좌표의 흐름을 읽어 들이고, 크리틱 신경망에는 층 정규화와 잔차 연결을 더해 학습이 흔들리지 않도록 붙잡아 줍니다. 계산량을 줄이려고 LSTM의 게이트와 완전연결층에는 나뭇가지를 속아 내듯 불필요한 연결을 잘라 내는 구조적 가지치기를 적용해, 몸집을 줄이면서도 판단의 정확도는 크게 떨어뜨리지 않았습다.

중국 신장 지역의 실제 홍화 밭에서 이 모델을 엮은 수확 로봇이 현장 시험을 거쳤습니다. 이 로봇은 팔 여러 개를 나란히 붙인 병렬 구조여서, 하나의 경로를 구간별로 나눠 각 팔이 동시에 맡는 방식으로 작업 속도를 끌어올렸습니다. 유홍1호와 윤홍5호라는 두 품종을 심은 밭에서 목표점이 스물다섯 개인 조건을 시험했습니다. 유전자 알고리즘과 이 모델을 나란히 돌려 본 결과, 경로 길이는 9.56퍼센트 짧아지고 작업 시간은 5.43퍼센트 줄었습니다. 목표점이 서른한 개로 늘어나 더 촘촘하게 엮힌 조건에서는 그 차이가 한층 크게 벌어져, 경로 길이는 20.17퍼센트, 작업 시간은 29.70퍼센트까지 줄었습니다. 목표가 많아지고 엮힐수록 사람이 정한 순서보다 학습된 판단이 더 큰 차이를 만든다는 뜻으로 읽힙니다.

경로를 최적화하는 문제는 방문 순서를 정하는 데서 그치지 않습니다. 포장을 고르게 만드는 지형 균평 작업이나 이동 경로 자체를 설계하는 분야에서는 근사 정책 최적화, 영어 약자로 PPO라 부르는 강화학습 기법이 쓰입니다. PPO는 정책을 한 번에 크게 바꾸지 않고 조금씩만 고쳐 나가면서 학습이 갑자기 무너지지 않게 붙잡아 주는 방식입니다. 이 기법을 쓰면 이동 거리와 함께 파헤쳐 옮겨야 할 흙의 양까지 동시에 줄이는 방향으로 경로를 짤 수 있어, 로봇이 덜 움직이면서도 배터리를 더 오래 쓸 수 있습니다. 땅을 고르는 일과 그 위를 오가는 일은 서로 다른 문제로 보이지만, 결국 같은 강화학습의 틀 안에서 함께 풀립니다.

경로를 아무리 잘 짜도 로봇이 자기 위치를 정확히 모르면 소용이 없습니다. 지상 자율주행 로봇은 위성항법장치의 오차를 기준국 신호로 보정하는 RTK-GPS를 달아 위치 오차를 2센티미터 아래로 낮추고, 레이저를 쏘아 되돌아오는 시간을 재는 라이다와 색깔에 거리 정보까지 더한 RGB-D 카메라로 주변 지형을 입체로 그려 냅니다. 스테레오 비전 카메라 두 대를 나란히 붙이면 두 시점의 시차로 거리감을 얻을 수 있어, 열매나 줄기의 위치를 카메라가 보는 좌표에서 로봇 팔이 움직이는 좌표로 바꾸는 작업이 가능해집니다. 초음파 거리 센서는 로봇이 이랑 끝에서 방향을 트는 구간이나 시야가 가려지는 순간에 다른 장애물과 부딪히거나 넘어지지 않도록 지켜보는 역할을 맡습니다.

자율주행 로봇의 몸속에는 이 밖에도 잔손이 많이 가는 작은 센서들이 촘촘히 박혀 있습니다. 12볼트 배터리의 전압을 재는 센서는 남은 힘이 얼마인지를 실시간으로 알려주고, 솔레노이드 밸브 컨트롤러는 전기 신호 하나로 노즐을 열고 닫는 문지기 역할을 맡습니다. 영구자석 직류 기어 모터에 붙은 엔코더는 바퀴가 몇 바퀴 돌았는지를 세어 로봇이 실제로 얼마나 움직였는지를 거꾸로 셈해 내고, 공압과 수압을 재는 센서는 분사 장치 안의 압력이 정해진 범위를 벗어나지 않는지를 지켜봅니다. 경로를 아무리 정교하게 짜도 이런 자잘한 센서 하나하나가 제 역할을 하지 못하면, 계산된 숫자는 실제 바퀴와 노즐의 움직임으로 이어지지 못합니다.

땅 위를 기는 로봇이 놓치는 것을 하늘의 드론이 채웁니다. 드론이 여러 날에 걸쳐 찍은 다중분광 사진에서 얻는 식생지수는 병든 잎을 찾아낼 때도 쓰이지만, 여기서는 쓰임새가 다릅니다. 같은 지표를 밭 전체에 걸쳐 겹쳐 읽으면 잡초가 모여 있을 확률이 구역마다 표시된 처방 지도, 영어로는 프리스크립션 맵이라 부르는 자료가 만들어집니다. 이 지도는 잡초가 자라는 속도에 맞추어 며칠 간격으로 다시 그려지며 최신 상태를 유지합니다. 드론은 이 지도를 손에 쥔 채 실제로 어느 길을 따라 날아야 하는지를 정하는 차례로 넘어 갑니다.

작물과 잡초가 맞닿은 경계를 화소 단위로 촘촘히 가려내는 일은 문맥을 함께 읽는 이중 분기 합성곱 신경망이 도맡고 있습니다. 경계가 확인되면 AWTPPO라 부르는 단계가 변형된 다익스트라 알고리즘을 써서, 여러 경로 후보 가운데 연료와 배터리, 실어야 할 약제의

무게를 덜 쓰는 길을 찾아냅니다. 다익스트라 알고리즘은 원래 여러 정류장을 거치는 지하철 노선 가운데 제일 빠른 환승 길을 찾는 데 쓰이던 오래된 길찾기 기법인데, 여기서는 정류장 대신 밭 위의 좌표를, 환승 시간 대신 연료와 배터리 소모량을 놓고 같은 방식으로 계산합니다. 이렇게 정해진 길을 따라 드론이 날면서, 잡초 뭉치가 있는 구간을 지날때만 노즐을 열어 약제를 내려보내는 체계가 완성됩니다.

노즐 앞에는 잡초 뭉치의 크기를 실시간으로 재는 눈이 따로 달려 있습니다. 잡초가 모인 면적이 1.5제곱미터를 넘어서면 VRMDWN이라 부르는 변량 미세분사 장치가 작동합니다. 분사 입자의 크기를 100마이크로미터에서 400마이크로미터 사이로 조절합니다. 분사량도 분당 0.12리터에서 0.35리터 사이에서 함께 바꿉니다. 잡초가 뽕뽕하게 뭉친 곳에는 굵고 많은 양을, 듽성듬성한 곳에는 가늘고 적은 양을 내려보내는 방식입니다. 약을 다 뿌린 뒤에도 일은 끝나지 않아서, 방제 뒤 7일과 14일, 28일이 지난 시점마다 다시 사진을 찍어 과거 재발 기록과 겹쳐 봅니다. 이렇게 모은 자료를 놓고 PTWRP 단계는 Q러닝이라는 강화학습 방식으로, 어느 위치에서 잡초가 다시 돌아날 가능성이 큰지를 미리 알아냅니다.

잡초가 다시 돌아날 위치를 미리 알아맞히는 일은 방제 자체보다 눈에 덜 띄지만 실속은 작지 않습니다. 예측이 없다면 재배자는 방제를 끝낸 뒤에도 며칠마다 밭 전체를 다시 돌아보며 잡초가 되살아났는지 눈으로 확인해야 합니다. PTWRP가 내놓는 예측 지도는 다시 돌아봐야 할 구역을 몇 군데로 좁혀 주어, 다음번 드론 비행이나 사람의 순찰 시간을 크게 줄여 줍니다. 방제 작업의 성격 자체가 한 번으로 끝나는 일회성 작업에서 예측과 확인이 되풀이되는 순환 고리로 바뀝니다.

드론과 지상 로봇이 정확한 길을 찾으려면, 서로 다른 센서가 각자의 방식으로 잰 위치를 하나의 기준으로 맞추는 손질이 먼저 끝나야 합니다. 위성항법장치가 알려주는 위도와 경도, 라이다와 카메라가 읽어 낸 로봇 기준의 상대 좌표, 로봇 팔이 움직이는 관절 기준의 좌표는 저마다 원점과 방향이 다릅니다. 이 여러 좌표를 하나의 밭 지도 위에 겹쳐 놓는 좌표계 변환을 거쳐야, 드론이 찾아낸 잡초 위치와 지상 로봇이 실제로 노즐을 여는 위치가 서로 어긋나지 않습니다. 이 정렬이 조금이라도 틀어지면, 애써 계산한 최적 경로도 엉뚱한 이랑 위를 지나가는 헛걸음이 되어 버립니다.

이 체계는 실제 밭밭에서 시험을 거쳤습니다. 12헥타르 규모의 상업용 밀 포장에서 씨앗이 움트는 시기부터 이삭이 패기 전까지 90일 동안 드론이 계속 사진을 찍어 이 체계를 돌렸습니다. AWTPO가 짠 비행 경로 덕분에 드론의 비행 시간은 17.5분으로 줄었고, VRMDWN의 표적 분사로 제초제 사용량은 헥타르당 0.68리터, 관행적인 전면 분사와 견주면 32퍼센트가 줄어든 양까지 내려갔습니다. 잡초에 빼앗기지 않고 지켜 낸 수확량은 18퍼센트에서 22퍼센트까지 늘었습니다. 밭 전체에 같은 양을 뿌리던 방식과 견주면,

필요한 위치에만 정확한 양을 내려보내는 쪽이 제초제 사용과 수확량 모두에서 뚜렷한 차이를 만든 것으로 보입니다.

경로가 몇 분 짧아졌다는 숫자는 작아 보일 수 있지만 밭에서는 다르게 쌓입니다. 로봇이 하루에 일할 수 있는 시간은 배터리 용량과 해가 떠 있는 시간으로 정해져 있어서, 한 번 오갈 때마다 아낀 시간이 하루가 끝날 무렵에는 밭 몇 이랑을 더 도는 여유로 돌아옵니다. 사람 한 명이 하루에 감독할 수 있는 로봇과 드론의 수도 결국 이 여유에 달려 있어서, 경로가 짧아질수록 같은 인력으로 더 넓은 농장을 맡을 수 있게 됩니다. 급하게 방향을 틀거나 같은 구간을 불필요하게 오가는 움직임이 줄어들면, 사람과 로봇이 함께 일하는 밭에서 부딪힐 위험도 함께 낮아집니다.

이런 개별 드론의 정교한 판단은 여러 대가 무리 지어 움직이는 드론 군집으로 이어질 때 진짜 힘을 냅니다. 드론 한 대가 넓은 밭을 처음부터 끝까지 혼자 돌면 배터리가 바닥나기 전에 다 돌지 못하는 구간이 남기 마련이지만, 여러 대가 구역을 나눠 동시에 날면 같은 시간에 몇 배 넓은 면적을 훑을 수 있습니다. 2026년 들어 방제 드론은 몇몇 농가만 쓰는 특수 장비에서 벗어나, 대용량 탱크에 인공지능을 얹은 기종이 널리 퍼지는 주류 장비로 바뀌고 있습니다. 페가수스 로보틱스가 유통하는 XAG P150은 로터 네 개가 만드는 하강 기류로 약제를 고르게 흩뿌리면서, 1.5미터에서 90미터에 이르는 범위에서 장애물을 스스로 알아채는 인공지능 감지 기능을 갖췄습니다.

하일리오라는 회사가 내놓은 HYL-150 ARES는 군집 비행에 초점을 맞춘 기체로, 약 50킬로그램을 싣고 시간당 20헥타르가 넘는 면적에 약을 칠 수 있습니다. 이런 무리 비행이 가능한 것은 드론 하나하나가 기체에 실린 컴퓨터로 서로 신호를 주고받으며, 다중분광 카메라와 살포 탱크, 위성항법 신호를 함께 맞춰 쓰기 때문입니다. 하일리오의 조종자 한 사람이 드론 세 대로 이루어진 무리를 동시에 감독하는 방식으로 미국 연방항공청의 승인을 받았고, 이 방식대로라면 사람 한 명이 하루에 수천 에이커에 이르는 밭을 돌아볼 수 있습니다. 드론끼리 스스로 구역을 나누고 방향과 속도를 맞추는 이런 승인 사례는, 한 사람이 여러 기체를 한꺼번에 감독하는 군집 비행이 이미 현장에서 작동하고 있다는 사실을 보여줍니다.

사람과 로봇이 같은 밭에서 함께 일하는 시간도 늘어나고 있습니다. 드론이 낮게 날며 방제를 하는 동안 사람이 같은 이랑에 있으면, 초음파 센서와 비전 카메라가 그 움직임을 놓치지 않고 감지해 속도를 늦추거나 경로를 바꿉니다. 조종자 한 사람이 여러 대의 드론이나 로봇을 동시에 지켜보는 지금의 방식에서는, 화면 하나에 여러 기체의 상태가 함께 떠 있어서 어느 한 대에 이상이 생기면 그 신호를 놓치지 않는 것이 감독자의 새로운 임무가 됩니다. 기계가 스스로 경로를 정하는 일이 늘어날수록, 사람의 역할은 직접 조종하는 손에서 전체를 살피는 눈으로 옮겨 가고 있는 것으로 보입니다.

나무가 위아래로 뻗뻗하게 들어선 과수원에서는 드론보다 지상 로봇이 널리 쓰이는 경우가 많습니다. 전기로 움직이는 자율주행 분무 로봇 OrcBOT은 RTK-GPS와 스테레오 카메라로 자기 위치와 나무의 형태를 함께 읽고, YOLOv5 신경망으로 나뭇잎이 우거진 캐노피의 있고 없음을 실시간으로 가려냅니다. 중앙 전자제어장치는 이 판단에 따라 좌우 노즐을 따로따로 켜고 끄면서, 나무가 없는 빈 구간에서는 약을 아예 뿌리지 않습니다. 여기에 10킬로볼트 전압을 걸어 분사 입자에 정전기를 띠게 하는 장치가 더해지는데, 겨울에 스웨터를 벗을 때 머리카락이 스웨터에 달라붙는 것과 같은 원리로 대전된 입자가 앞 뒷면이나 나뭇가지 안쪽까지 파고들어 달라붙습니다.

관행적인 분무기로는 바람이 부는 방향에 있는 앞 앞면에만 약이 얹고 그 뒤쪽은 그냥 지나치기 쉬운데, 정전기를 띤 입자는 앞이 어느 방향을 보고 있든 끌려가 붙는 힘을 하나 더 가졌습니다.

튀르키예 앙카라 대학교 농과대학 과수원에서 이 로봇을 실제로 시험한 결과가 나와 있습니다. 분사된 입자는 지름 150마이크로미터에서 167마이크로미터 사이로 형성되어, 미국 농업공학회가 정한 미세 입자 규격인 ASAE S572.1 기준을 만족했습니다. 나뭇잎 표면에 약이 얹은 비율인 캐노피 피복률은 평균 55퍼센트였고, 높을 때는 57퍼센트까지 올랐습니다. 관행적인 트랙터 분무기와 견주면 약제 사용량은 49퍼센트에서 72퍼센트까지 줄었고, 통계적으로도 우연이라 보기 어려운 차이로 확인되었습니다. 사람이 트랙터를 몰고 다니며 뿌릴 때 시간당 19.70달러가 들던 작업 비용은, 로봇이 대신하면서 시간당 0.76달러로 내려가 95퍼센트 가까이 줄었습니다.

헥타르 단위로 넓게 펼쳐진 밀밭의 잡초와, 나무 한 그루 한 그루가 서 있는 과수원의 병해충은 그 위에 뿌려야 할 약의 모양부터 다릅니다. VRMDWN은 밭 위에 점점이 흩어진 잡초 뭉치만 골라 쏘는 방식이어서 표적이 작고 그 사이는 완전히 비워 두는 반면, OrcBOT은 나무 한 그루를 통째로 감싸듯 뿌려야 하므로 표적이 크고 그 안에서도 앞 뒤 편까지 골고루 닿아야 합니다. 잡초를 상대하는 쪽은 어디에 있는지를 정확히 가려내는 지도가 관건이고, 나무를 상대하는 쪽은 이미 아는 나무 안으로 약을 얼마나 고르게 들여보내는지가 관건입니다. 두 기술이 겉보기에는 같은 자율 방제로 보여도, 실제로 풀어야 할 문제는 서로 다른 얼굴을 하고 있습니다.

큰 농장이 아니라 작은 밭에도 자율주행 기술이 들어서고 있습니다. PIC 마이크로컨트롤러로 움직이는 소형 로봇 한 대는 모듈만 바꿔 끼우면 여러 일을 해냅니다. 250그램짜리 씨앗 상자를 달면 정해진 간격마다 씨앗 한 알씩을 심는 정밀 점파를 하고, 500밀리리터 짜리 범용 펌프 노즐을 달면 필요한 위치에만 약제를 표적 살포하며, 연강으로 만든 얇은 날을 달면 포기와 포기 사이를 오가며 기계적으로 잡초를 매는 작업까지 해냅니다. 배터리 하나와 마이크로컨트롤러 하나로 이 세 가지 일을 모두 해내는 몸집 작은 로봇은, 넓은 농기계를 살 형편이 안 되는 소규모 농가에 맞춘 대안으로 떠오르고 있습니다.

이 모든 신경망은 밭에 나가기 전, 파이토치나 텐서플로 같은 플랫폼 위에서 Adam이나 AdamW 최적화 기법으로 미리 훈련을 마칩니다. 훈련을 마친 모델은 엔비디아 젯슨 자비어 NX나 젯슨 나노, 라즈베리파이 5, 또는 산업용 PLC 제어기처럼 손바닥만 한 기기 위에 ONNX나 TensorRT 형식으로 옮겨 담겨 가벼워진 몸으로 다시 태어납니다. 목표점 스물다섯 개에서 서른한 개 사이의 3차원 외판원 문제를 실제로 풀어내는 데 걸리는 시간은 수십 밀리초 안쪽이어서, 로봇이 멈춰 서서 계산을 기다리는 시간은 거의 느껴지지 않습니다. 드론이 초속 5미터로 날면서 방제 작업을 할 때도, 노즐이 열리고 닫히는 데 걸리는 짧은 지연을 미리 셈에 넣는 움직임 계획이 함께 작동합니다.

이렇게 만든 체계가 실제로 쓸 만한지는 여러 잣대로 함께 가능합니다. 경로가 관행 알고리즘보다 얼마나 짧아졌는지를 보는 경로 단축률, 작업이 얼마나 빨리 끝났는지를 보는 작업 시간 절감률, 엣지 기기가 경로를 계산하는 데 걸리는 지연 시간, 배터리와 연료를 얼마나 아꼈는지를 보는 에너지 절감률이 로봇과 드론의 움직임 자체를 평가하는 잣대입니다. 여기에 헥타르당 줄어든 제초제 사용량과 캐노피 피복률, 분사 입자 크기, 작물과 잡초 경계에서 벌어지는 오분류율, 지켜 낸 수확량의 비율, 방제 뒤 잡초가 다시 돌아나는 것을 얼마나 정확히 미리 알아맞혔는지를 보는 재발 예측 정확도가 더해져 농사에 실제로 이득이 되었는지를 보여줍니다.

카메라가 잡초와 작물을 얼마나 잘 구별했는지는 몇 가지 숫자로 다시 확인하는데, 모델이 그린 잡초 영역과 실제 잡초 영역이 얼마나 겹치는지를 보는 IoU는 도장 두 개를 같은 위치에 포개 찍었을 때 겹치는 정도를 재는 것과 비슷하고, 여러 문턱값에서 낸 정밀도를 평균 낸 mAP는 그 도장 찍기를 조건을 바꿔 가며 여러 번 되풀이한 뒤 평균을 낸 값에 가깝습니다. 잡초라고 판정한 것 가운데 실제로 잡초였던 비율인 정밀도와, 실제 잡초 가운데 놓치지 않고 잡아낸 비율인 재현율을 하나로 합친 F1 점수는 어느 한쪽으로만 치우친 판단을 가려내는 역할을 합니다. 이 세 겹의 잣대 가운데 어느 하나만 좋아서는 밭에서 신뢰받는 체계로 정착하기 어렵고, 경로와 방제와 인식이라는 세 바퀴가 함께 굴러가야 현장에서 통합니다.

이런 성과에도 넘어야 할 고비가 여럿 남아 있습니다. 지금까지 나온 결과는 대부분 특정한 밭 하나에서 거둔 성적이라는 한계를 함께 지니고 있습니다. 신장의 홍화 밭에서 익힌 순서 감각이 나무 간격과 지형이 전혀 다른 사과 과수원에서도 그대로 통하리라는 보장은 없습니다. 작물의 키와 심은 간격, 땅의 기울기가 바뀌면 최단 경로의 모양 자체가 달라지기 때문에, 여러 작물과 여러 지형에서 두루 시험한 결과가 더 쌓여야 경로 최적화 모델이 특정 밭의 도구에서 여러 밭에 두루 쓰는 도구로 넘어갈 수 있을 것으로 보입니다.

지금의 3차원 외판원 문제 알고리즘과 비행 경로 계산은 대체로 평탄하거나 정돈된 밭을 가정하고 짜여 있어서, 경사가 급한 지형이나 장애물이 뒤섞인 구역에서는 그대로 통하지 않을 때가 많습니다. 바람이 초속 4.5미터를 넘거나 안개와 비, 짙은 구름이 낀 날에는 다

중분광 사진의 품질이 떨어지고 드론의 비행 위치에도 1미터 안팎의 오차가 생겨, 잡초를 잘못 짚거나 약을 엉뚱한 이랑에 뿌리는 일로 이어질 수 있습니다. 맑고 바람 없는 날을 골라 작업하는 지금의 방식은, 궂은 날씨가 이어지면 방제 시기 자체를 놓칠 위험을 안고 있습니다. 이런 날에는 사람이 직접 나가 눈으로 확인하고 방제 시점을 다시 잡는 손길이어야 합니다.

드론과 지상 로봇의 몸집도 발목을 잡는 요인입니다. 시험에 쓰인 드론의 최대 비행 시간은 22분 남짓이고 약제를 실을 수 있는 양도 1.2리터 정도에 그쳐서, 넓은 밭을 쉬지 않고 돌려면 배터리를 갈아 끼우고 약제를 다시 채우는 시간이 자주 끼어듭니다. 사람이 손으로 배터리를 바꿔 끼우고 약통을 다시 채우는 그 몇 분 사이, 드론은 하늘에 뜨지 못한 채 밭 한편에 놓여 있을 수밖에 없습니다. 이 틈을 메우려고 땅 위를 오가며 배터리를 갈아 주는 이동식 충전 장치나, 드론과 지상 로봇이 서로 다른 역할을 나눠 맡으며 협력하는 이중 군집 제어 기술이 다음 과제로 떠오르고 있습니다. 충전 설비를 갖추는 비용까지 셈에 넣으면, 넓은 농장일수록 이 기술을 처음 들이는 부담이 만만치 않다는 점도 함께 고려해야 합니다.

하늘과 땅의 로봇이 각자 잘하는 일을 나눠 맡고 그 사이를 자동으로 이어 주는 체계가 갖춰져야, 지금의 시험 밭 규모를 넘어 훨씬 넓은 농장까지 이 기술을 그대로 옮겨 쓸 수 있을 것으로 보입니다.

복잡한 계산을 밭 한가운데서 처리해야 한다는 점도 걸림돌입니다. 강화학습 기반 경로 계산이나 여러 일을 한꺼번에 처리하는 비전 모델은 연산량이 많아서, 배터리로 움직이는 작은 기기 위에서는 판단이 늦어질 수 있습니다. 계산량을 줄이는 양자화나 가지치기, NPU나 FPGA 같은 전용 반도체를 붙이는 방법이 이 문제를 더는 길로 계속 연구되고 있습니다. 계산 자원과 정확도 사이에서 어느 균형점을 고를지는 결국 밭의 크기와 작물의 값어치에 따라 농가마다 다른 답을 낼 수밖에 없습니다.

마지막으로 남는 과제는 믿음의 문제입니다. 강화학습 모델이 왜 그 경로를 골랐고 왜 거기에만 약을 치기로 했는지, 재배자가 그 이유를 눈으로 확인할 방법이 아직 마땅치 않습니다. Grad-CAM이나 SHAP처럼 판단의 근거를 그림으로 보여주는 설명 가능 인공지능 기술을 이 체계에 심어 두면, 재배자가 로봇의 선택을 그대로 따를지 다시 살필지를 스스로 판단할 수 있습니다. 여기에 방제한 기록과 잡초가 다시 돌아난 위치를 해마다 쌓아 지식으로 되먹임하면, 몇 해에 걸쳐 서서히 바뀌는 토양과 잡초 생태의 흐름까지 쫓아갈 수 있을 것으로 보입니다. 이런 신뢰가 쌓여야, 사람이 마지막으로 확인 도장을 찍는 지금의 반자동 방식에서 사람의 손을 완전히 떠난 자율 방식으로 넘어갈 수 있을 것으로 보입니다.

이 기술이 넓은 농장으로 퍼지려면 몇 가지 과제가 더 풀려야 합니다. 강화학습이 고른 경로와 방제 판단의 근거를 재배자가 눈으로 확인할 방법을 갖추는 일, 배터리와 약제가 떨

어질 때마다 생기는 작업 공백을 줄이는 일도 아직 풀리지 않은 과제입니다. 드론 여러 대가 신호를 주고받으며 구역을 나누는 군집 비행에서는 그 신호가 끊겼을 때 기체들이 서로의 위치를 잃고 항로가 겹치거나 부딪힐 위험도 남습니다. 조종자 한 사람이 여러 기체의 화면을 한꺼번에 지켜보는 지금의 감독 방식은, 통신이 끊긴 기체를 얼마나 빨리 알아채고 안전하게 멈춰 세우느냐에 따라 실효성이 갈립니다.

근거 및 참고문헌

학술 논문

1. Adewumi, A., & Saraswat, D. (2026). Comprehensive Review of Artificial Intelligence and Edge Computing for Precision Weed Control. Artificial Intelligence and Applications. <https://doi.org/10.47852/bonviewAIA62028867>
2. Choudhari, A., Katkar, R., Gupta, M., Wathe, N., Kakde, S., & Poyam, P. (2025). Design of an Integrated Spatiotemporal Deep Learning Framework for Autonomous Precision Weed Detection, Treatment, and Recurrence Prediction in Drone-Based Smart Farming Sets. International Journal of Applied Mathematics, 38(2s), 1339-1366.
3. CropLife. (2026). 7 Agricultural Spray Drones to Watch in 2026. CropLife. <https://www.croplife.com/iron/sprayers/7-agricultural-spray-drones-to-watch-in-2026/>
4. Gerdan Koc, D., Koc, C., & Comakli, M. (2025). AI-powered autonomous spraying robot for precision orchard applications. Journal of Agricultural Engineering, 56(1) / 2026 LVII:1766. <https://doi.org/10.4081/jae.2025.1766>
5. Gundi, A., Kulagod, A., Sunny K, H., & Parashuram, B. (2026). Autonomous Agricultural Robot for Seeding, Spraying, and Weeding. International Journal of Advanced Research in Computer and Communication Engineering (IJARCCE), 15(5), 1308-1311. <https://doi.org/10.17148/IJARCCE.2026.155170>
6. Li, M., Wang, X., Liu, Z., Duan, M., & Jin, Z. (2026). DEMA-3D TSP: An Enhanced Reinforcement Learning with DEMA Attention in Sequence Optimization for Safflower Picking Robot. Smart Agriculture, 8(2), 200-219. <https://doi.org/10.12133/j.smartag.SA202506004>
7. Logeshwaran, J., et al. (2026). Embedded Drone Swarm for Precision Agriculture with Vision AI. International Journal of Computer Applications, 187(115), 42-43.
8. The Robot Report. (2026). Drone swarms: How they actually work and what industries should care. The Robot Report. <https://www.therobotreport.com/drone-swarms-how-they-actually-work-and-what-industries-should-care/>

강연 및 영상 자료

1. Food and Agriculture Organization (FAO). (2025). Travel Around the World with Digital FAO and Agro-Informatics - Sydney. YouTube. <https://www.youtube.com/watch?v=tbFEk73816U>
2. PhD Navigator. (2025). Sampling Techniques in ICT Research | Energy Optimised Field Robot for Agriculture. YouTube. https://www.youtube.com/watch?v=jJerj_N7ALQ
3. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026 Global Agrifood Innovation Roadshow Launch Event & Inaugural Roadshow. YouTube. https://www.youtube.com/watch?v=U5CRelR_Rrg
4. 茶柱. (2026). 20260120 茶園スマート農業 カワサキ技研・落合刃物・寺田製作所. YouTube. <https://www.youtube.com/watch?v=zmFbOC5RcJU>

5. 臉書李載榮. (2025). A88私密資策會衛星精準農業AI導入工作坊桃園AI衛星多光譜圖像與無人機應用. YouTube. <https://www.youtube.com/watch?v=dtT3bafdKgw>
6. Trimble Geospatial. (2026). eCognition Webinar: Deep Learning, UAVs and Precision Agriculture. YouTube. <https://www.youtube.com/watch?v=alrseDYV8Lo>
7. Society of Precision Agriculture Australia SPAA. (2025). Grain Automate National Webinar: Paving the way to on-farm autonomy. YouTube. <https://www.youtube.com/watch?v=nZnsWgvs6-g>
8. Agri Coaching Chandigarh. (2026). Digital Agriculture Mission 2026 | AI, Drones, Agri Stack & Smart Farming | Current Affairs. YouTube. <https://www.youtube.com/watch?v=al2rsTZBwMA>

3장

스마트 온실 및 시설원예 환경 제어 (CEA)

3.1

IoT 기반 멀티센서 모니터링 및 지능형 환경 측정

전 세계에 깔린 로라완(LoRaWAN) 저전력 사물인터넷 기기는 70개국에 걸쳐 1억 2500만 대를 넘어섰고, 관련 시장 규모는 2026년 142억 5천만 달러로 추정됩니다. 미국 네브래스카대학교 연구진은 토양 수분을 실시간으로 관찰하는 방식만으로 물 사용량을 최대 35퍼센트까지 줄였다고 보고했습니다. 온실 안에서도 촘촘한 계측이 필요하기는 마찬가지입니다. 비닐하우스는 바닥과 눈높이의 온도가 서너 도씩 차이 나고, 지붕 가까이는 별도의 고온 공기층이 형성됩니다. 온실 기둥 한쪽에 붙은 손바닥만 한 흰색 상자 안에서는 온도와 습도 값이 몇 초에 한 번씩 새로 기록되고, 이 값이 그날 밤 환기창이 열릴지, 난방기가 돌아갈지, 물뿌리개가 작동할지를 결정합니다.

온실 안에서 실제로 관리해야 하는 값은 기온 하나가 아닙니다. 공기 온도와 상대습도, 이산화탄소 농도, 햇빛의 양(광합성에 실제로 쓰이는 파장대의 빛을 재는 값을 광합성유효광양자속밀도라고 부릅니다), 물재배라면 양액의 전기전도도와 수소이온농도, 흙이나 배지에 남은 수분, 물탱크의 수온, 저장고라면 에틸렌 가스까지 함께 움직입니다. 이 값들은 따로따로 놀지 않습니다. 창을 열어 온도를 낮추면 습도와 이산화탄소 농도가 동시에 빠져나가고, 난방기를 켜면 온도만 오르는 게 아니라 상대습도가 똑 떨어집니다. 물을 더 주면 배지 수분은 오르지만 뿌리 주변 공기 습도까지 함께 높아져 곰팡이 조건을 거들기도 합니다.

그래서 온실의 미시기후, 곧 작은 공간 안의 기후는 한 번에 한 가지씩 통제할 수 있는 날개의 스위치들이 아니라, 여러 변수가 시시각각 서로 밀고 당기는 비선형적이고 시간에 따라 변하는 결합계로 다뤄야 합니다.

이 균형이 무너지면 손실은 곧바로 눈에 보입니다. 온도가 적정 범위를 벗어난 채 며칠만 지나도 줄기가 웃자라거나 꽃눈이 떨어지고, 습도가 높은 상태로 밤을 넘기면 잎 뒷면에 물방울이 맺힌 채로 곰팡이균과 흰가루병균이 번식하기 좋은 조건이 만들어집니다. 한 번의 착과 실패, 한 번의 병 확산은 그 계절 수확량 전체를 갉아먹습니다. 그렇기 때문에 재배자의 감각과 경험만으로는 부족하고, 온실 구석구석에 촘촘하게 심어 놓은 사물인터넷(IoT, Internet of Things) 센서와 그 값을 실시간으로 읽어 판단하는 인공지능 계산이 함께 필요합니다. 센서가 두 눈과 살갍이라면, 그 뒤에 붙는 계산은 매 순간 조건을 따져 다음 행동을 고르는 판단력에 해당합니다.

문제는 온실 하나에 센서 하나만 달아서는 그 판단력이 제대로 작동하지 않는다는 점입니다. 환기팬 바로 앞과 온실 반대쪽 구석은 기류 속도부터 다르고, 작물 잎이 뻗뻗하게 우거진 군락 위쪽과 그 아래 그늘은 온도 차이가 여러 도에 이릅니다. 온실 벽에 가까운 가장자리와 한가운데도 다른 날씨를 삽니다. 센서 하나가 읽은 대표값을 온실 전체의 값이라고 믿고 난방이나 환기를 결정하면, 정작 그 대표값과 먼 구역은 방치된 채 웃자라거나 시들 수 있습니다. 이 공간적 불균일성을 어떻게 감당하느냐가 온실 계측 설계의 숙제로 남습니다.

실제로 온실에 들어가는 센서 목록은 꽤 깁니다. 공기 쪽에서는 DHT11과 DHT22 온습도 센서가 영하 40도에서 80도, 습도 0퍼센트에서 100퍼센트 상대습도 구간을 재고, WQX-TH 온습도 센서가 그 옆을 지킵니다. 물탱크 안에는 DS18B20 수온 센서가 들어가고, 빛은 WQX-L 광량 센서가 0럭스에서 15만 7286럭스까지, 자외선은 WQX-R 및 UV 센서가 0에서 제곱미터당 2000와트까지 잽니다. 흙이나 배지에 남은 물기는 FC-28이나 YL-69 수분 센서로 재고, 공기 중 이산화탄소 농도는 적외선이 기체에 흡수되는 정도를 이용하는 방식, 곧 비분산적외선(NDIR) 방식의 센서가 말합니다. 수경재배 양액에는 전기전도도(EC)와 수소이온농도(pH)를 함께 재는 센서가 꽃히고, 수확한 농산물을 저온 유통할 때는 과일이 내뿜는 에틸렌 가스를 잡아내는 센서가 따로 붙습니다.

센서 한 알의 값은 몇천 원에서 몇만 원 사이로 그리 비싸지 않지만, 이 여럿이 한자리에 모이면 온실의 숨소리 전체를 읽어 내는 그물이 됩니다.

전력을 어떻게 대느냐도 센서 노드의 수명을 가르는 문제입니다. 온실 지붕 위나 배지 옆처럼 콘센트를 새로 끌어오기 어려운 자리에는 작은 태양전지판과 축전지를 붙인 노드가 주로 쓰이며, 평소에는 회로를 재워 두었다가 정해진 시각에만 잠깐 깨어나 값을 재고 다시 잠드는 절전 방식으로 배터리 한 번 충전으로 몇 달을 버팁니다. 관수 펌프나 환기팬처럼 직접 힘을 쓰는 구동기 쪽은 처음부터 상용 전원선에 물려 두고, 그 옆의 센서 노드만 저전력 배터리로 따로 운용하는 방식이 흔합니다. 통신 한 번에 드는 전력까지 아끼려고 값을 잴 때마다 보내는 대신 일정 시간 모아 두었다가 한꺼번에 보내는 방식도 함께 쓰이는데, 이 절충 하나가 어긋나면 배터리가 예상보다 일찍 닳아 정작 판단이 필요한 순간에 센서가 먹통이 되는 일이 벌어집니다.

온실 밖에도 눈이 필요합니다. JNGW100이라는 기상 관측 장치와 WQX 분광 센서를 온실 바깥에 세워 두면, 바깥 공기의 온도와 습도, 이슬점, 햇빛이 내리쬐는 양을 1분 간격으로 받아 볼 수 있습니다. 여기에 더해 일본 농업연구기구가 만든 격자형 농업기상 자료, 웨더에이피아이(WeatherAPI), 미국 항공우주국의 나사파워(NASA POWER), 유엔식량 농업기구의 클림와트(FAO CLIMWAT) 같은 해외 공개 자료를 실시간으로 끌어와 앞으로 며칠의 날씨 예보값을 제어 모델에 함께 넣어 줍니다. 온실 안 센서만으로는 다가올 한파나 폭염을 미리 알 수 없기 때문에, 바깥 기상 자료와 실내 센서 값을 나란히 놓고 보는

일이 점점 당연한 절차가 되고 있습니다. 창을 닫아걸 시각을 한 시간이라도 앞당겨 아는 것과 값이 오른 뒤에야 아는 것 사이에는 작물의 운명을 가르는 차이가 있습니다.

숫자를 공기에서만 뽑아내는 것도 아닙니다. '식물과의 대화 기법'이라고 부르는 방법은 작물 자체가 내보내는 신호를 읽습니다. 온실로 들어오는 공기와 빠져나가는 공기의 이산화탄소 농도 차이에 바람 속도를 곱하면, 온실 안 작물 군락 전체가 5분마다 광합성으로 얼마나 이산화탄소를 빨아들이는지, 밤사이 호흡으로 얼마나 내뿜는지를 계산할 수 있습니다. 같은 방식으로 수증기 농도 차이에 바람 속도를 곱하면 잎이 얼마나 물을 내보내는 지, 잎 표면의 작은 숨구멍인 기공이 얼마나 열려 있는지도 잎을 하나도 건드리지 않고 추정됩니다. 온도계가 방 안 공기를 재는 도구라면, 이 방법은 작물 그 자체를 살아 있는 계측기로 바꿔 놓습니다.

센서가 읽은 값은 여러 층을 거쳐 옮겨집니다. 현장 맨 앞단에는 STM32나 ESP32, 와이파이기가 붙은 ESP8266 모듈, 또는 두 대가 역할을 나눠 맡는 아두이노 우노와 아두이노 나노 조합이 들어섭니다. 아두이노 우노가 센서 값을 모으고 구동기를 직접 움직이는 일을 맡으면, 아두이노 나노는 그 옆에서 웹 서버와 통신하고 화면에 그래프를 그리는 일을 나눠 맡아 한쪽이 멈춰도 다른 쪽이 버티게 합니다. 온실 안 여러 노드끼리 값을 주고받을 때는 산업 현장에서 오래 쓰인 RS485 유선 방식이나 지그비(ZigBee) 무선 센서망이 쓰이고, 중앙 서버나 클라우드까지 값을 밀어 올릴 때는 4G DTU, GPRS, LPWAN, 와이파이 같은 통신망이 번갈아 쓰입니다. 그 덕분에 온실 현장에 달린 작은 화면과 사무실 컴퓨터, 재배자의 휴대전화 앱이 같은 순간 같은 숫자를 동시에 받아 보냅니다.

산업 현장에서 오래 검증된 RS485 유선 방식은 습기나 전자파에 흔들리지 않고 값을 안정적으로 실어 나르지만, 온실 구조를 바꿀 때마다 선을 다시 깔아야 하는 번거로움이 따릅니다. 지그비 같은 무선 센서망은 선을 깔 필요가 없어 재배 방식이 자주 바뀌는 온실에 어울리지만, 철골 구조물이나 물탱크처럼 전파를 가로막는 장애물이 있으면 값이 끊기거나 늦게 도착하는 일이 생깁니다. 그래서 실제 현장에서는 두 방식을 하나로 통일하기보다, 중심이 되는 구간은 유선으로 놓고 자주 바뀌는 구간만 무선으로 보완하는 절충이 흔하게 쓰입니다.

이 가운데 로라완(LoRaWAN)이라고 부르는 저전력 장거리 통신망, 곧 LPWAN은 몇 해 사이 실험실 기술에서 산업 규모의 기반 시설로 옮겨 갔습니다. 2026년 기준 전 세계 로라완 사물인터넷 시장은 142억 5천만 달러 규모로 추정되고, 2035년까지 해마다 34.7 퍼센트씩 성장할 것으로 전망됩니다. 이미 70개국에 걸쳐 1억 2500만 대가 넘는 로라완 기기가 깔려 있습니다. 배터리 하나로 몇 해를 버티면서 몇 킬로미터 밖까지 값을 실어 나르는 이 통신망 덕분에, 전기선을 새로 깔기 어려운 비닐하우스나 노지 한쪽 구석까지도 센서를 심을 수 있게 되었습니다.

2026년 들어 눈에 띄는 흐름은 계산을 클라우드에서 현장의 통신 중계 장치, 곧 게이트웨이 안으로 옮기는 흐름입니다. 센서 값을 일일이 먼 서버로 보내 답을 기다리는 대신, 게이트웨이 안에 가벼운 인공지능 모형을 심어 곧바로 판단을 내리게 하는 방식입니다. 이렇게 하면 서버까지 오가는 시간이 줄고, 통신에 드는 비용도 함께 줄어듭니다. 미국 네브래스카대학교 연구진이 토양 수분을 실시간으로 지켜본 실험에서는 이 방식으로 물 사용량을 최대 35퍼센트까지 줄였다고 보고했습니다. 센서가 값을 재는 일에서 그치지 않고, 그 값을 바로 판단으로 옮깁니다.

그렇다고 온실 구석마다 값비싼 센서를 다 심을 수는 없는 노릇입니다. 그래서 몇 개 안 되는 센서만 심어 놓고 온실 전체의 3차원 기후 지도를 계산으로 그려 내는 방법이 함께 쓰입니다. 수치유체역학(CFD)이라고 부르는 기법은 온실 안 공기와 기체가 실제로 어떻게 흐르고 섞이는지를 컴퓨터 안에서 흉내 내는 시뮬레이션이며, 일기예보 지도를 온실 내부라는 좁은 공간에 그대로 옮겨 온 것과 비슷합니다.

여기에 이미지를 읽는 합성곱 신경망(CNN), 시간의 흐름을 따라가는 시간적 합성곱 신경망(TCN), 여러 후보 값 가운데 최적값을 찾아가는 입자 군집 최적화(PSO) 기법을 엮은 딥씨에프디옵트넷(DeepCFD-OptNet)이나 랜덤포레스트, 서포트벡터회귀(SVR), 심층 신경망(DNN) 같은 기계학습 모형을 함께 돌리면, 몇 안 되는 센서 값만으로도 온실 구석 구석의 온도와 이산화탄소 분포를 그럴듯하게 재구성할 수 있습니다. 이런 재구성은 보통 몇 분 간격으로 다시 계산되어 지도를 갱신하므로, 센서가 없는 구역이라도 방금 전 상황에 가까운 값을 미루어 볼 수 있습니다. 센서 배치 비용과 예측 정밀도 사이의 줄다리기를 계산으로 메웁니다.

같은 값을 굳이 두 번, 세 번 재는 중복 설계도 예측 정밀도를 지키는 방법의 하나입니다. 온도 하나만 재는 센서 하나에 기대면 그 센서가 고장 났을 때 온실 전체가 눈을 감은 채로 돌아가지만, 같은 구역에 성능이 조금씩 다른 센서를 두세 개 겹쳐 두면 서로의 값을 견주어 어느 쪽이 고장에 가까운지 가려낼 수 있습니다. 값싼 센서 여러 개를 겹쳐 쓰는 쪽이 비싼 센서 하나에 기대는 쪽보다 오히려 고장에 강한 경우도 많아, 온실 규모와 예산에 맞춰 어느 값을 몇 겹으로 잴지 정하는 일 자체가 설계자가 맡을 일로 남습니다. 이렇게 겹쳐 쌓은 값이 있어야 뒤에서 설명할 적응형 칼만 필터도 제 역할을 합니다.

값이 항상 제때 들어오는 것도 아닙니다. 통신이 잠깐 끊기거나 센서 하나가 말썽을 부리면 값이 비는 구간이 생깁니다. 빈 구간이 10스텝 이내로 짧으면, 끊기기 전 마지막 값과 다시 이어진 뒤 첫 값을 직선으로 이어 그 사이를 채우는 전향·후향 선형 보간법을 씁니다. 열 걸음이 넘도록 길게 비면 이 방법만으로는 억지스러워지므로, 동적 시간 와핑(DTW)이라는 방법으로 과거 기록 가운데 지금과 닮은 흐름을 보였던 구간을 찾아내 그 패턴을 끌어와 빈자리를 채웁니다. 일기를 쓰다가 하루를 빼먹었을 때, 지난해 같은 계절 비슷한 날씨였던 날의 일기를 참고해 빈 페이지를 메우는 것과 닮은 방법입니다.

빈 곳을 채우는 일과 별개로, 들어온 값 자체가 튀거나 흔들리는 문제도 있습니다. 습기가 많고 먼지가 날리는 온실 환경에서는 센서가 순간적으로 엉뚱한 값을 찍는 일이 잦습니다. 이를 다듬는 데 자율 적응형 칼만 필터가 쓰입니다. 칼만 필터는 센서가 방금 읽은 다소 흔들리는 값과 그 직전까지의 흐름으로 미루어 짐작한 예상값에 가중치를 매겨 둘 사이 어딘가의 값으로 조용히 수렴시키는 계산법이며, 위성 신호가 흔들려도 자동차의 직전 속도와 방향을 함께 참고해 위치를 안정적으로 잡아내는 내비게이션 계산과 원리가 같습니다. '적응형'이라는 이름이 붙은 까닭은 이 필터가 센서를 얼마나 믿을지, 그 신뢰도 자체를 스스로 조정하기 때문입니다.

새로 들어온 값과 예상값의 차이가 클수록 그 센서의 가중치를 낮추고 다른 센서의 값에 더 무게를 실어서, 습기나 먼지 탓에 어느 한 센서가 잠깐 이상해지더라도 전체 판단까지 함께 흔들리지 않도록 막아 줍니다.

중국 서북부 Ningxia의 형성묘목기지에 있는 전형적인 이중막 일광온실이 이 필터를 실제로 시험한 현장입니다. WQX-TH, WQX-L, WQX-R 분광 센서 네 세트를 온실 곳곳에 나눠 달고 바깥에는 별도의 기상대를 세웠습니다. 여러 센서 위치에서 동시에 들어오는 값을 적응형 칼만 필터로 먼저 다듬고 나면, 그 뒤를 잇는 온습도 예측과 난방·환기 자동 개폐 판단이 훨씬 안정적으로 돌아갑니다. 값을 재는 단계에서 잡음을 걷어 내지 않으면, 그 뒤에 아무리 정교한 판단 로직을 엮어도 밑바닥부터 흔들리게 됩니다.

이렇게 다듬은 값도 단위가 제각각이라 그대로 계산에 넣기는 어렵습니다. 온도는 섭씨도, 습도는 퍼센트, 빛은 럭스, 이산화탄소는 피피엠, 산성도는 페하 단위로 저마다 다른 눈금을 씁니다. 이를 최솟값과 최댓값 사이를 0에서 1 사이로 다시 눈금을 매기는 최소최대 정규화 과정을 거쳐 나란히 놓고 비교할 수 있는 값으로 바꿉니다. 여러 나라 돈을 한 가지 기준 통화로 바꿔야 물건값을 서로 견줄 수 있는 것과 같은 이치입니다. 이 과정을 마친 값이라야 비로소 기계학습 파이프라인에 들어갈 재료로 쓰입니다.

값을 다듬고 눈금까지 맞췄으면, 이제 그 값을 실제 움직임으로 옮길 차례입니다. 이 일은 현장에 놓인 NodeMCU ESP8266이나 라즈베리파이, 로컬 Qt 화면이 달린 제어 단말, 때로는 클라우드 서버가 나누어 맡으며, 값이 들어와 판단이 나오기까지 걸리는 시간은 길어야 몇 초, 짧게는 그보다 더 빠릅니다. 판단이 서면 명령은 릴레이 모듈을 거쳐 관수 펌프, 환기팬, 차광막, 이산화탄소 보충 장치, 미스트 분사기, 보광용 LED로 곧장 전달됩니다. 센서 상자의 초록 불빛에서 시작된 숫자 하나가, 몇 초 뒤 온실 저편의 팬을 돌리는 순간까지 이어집니다.

측정한 값은 저장하고 보여 주는 데서 한 번 더 쓰임새가 갈립니다. 게이트웨이를 거친 값은 시계열 데이터베이스에 차곡차곡 쌓이고, 재배자는 웹이나 휴대전화 화면에서 지난 하루, 지난 한 주의 온도와 습도 그래프를 그대로 훑어볼 수 있습니다. 값이 미리 정해 둔 위험 구간을 넘어서면 문자나 앱 알림으로 곧바로 경고가 뜨기 때문에, 재배자가 밤새 온실

안에 머무르지 않아도 한파나 정전 같은 돌발 상황에 대응할 여유가 생깁니다. 오래 쌓인 기록은 그 자체로 나중에 수확량이나 병해 발생과 견주어 볼 수 있는 자료가 되고, 인증이나 이력 관리가 필요한 농산물이라면 재배 과정을 증명하는 근거로도 쓰입니다.

인도네시아의 산디부아나 농장과 푸르워사리 두 곳의 상업용 수경재배 상추 온실은 이 흐름을 통째로 보여 주는 사례입니다. DHT11 온습도 센서, DS18B20 수온 센서, FC-28 토양 수분 센서, pH와 EC 양액 센서를 심어 놓고 NodeMCU ESP8266 게이트웨이로 값을 모아 클라우드 데이터베이스까지 실어 날랐습니다. 넉 달 동안 이렇게 쌓인 값이 1만 5492건에 이르렀고, 이 값들이 훗날 수확량을 미리 가늠하고 환경을 자동으로 조절하는 판단 체계의 밑감으로 쓰였습니다. 센서 몇 개와 값싼 와이파이 모듈만으로도 상업 온실 규모의 데이터 기반을 세울 수 있다는 사실을 이 사례가 보여 줍니다.

한국 강원대학교 안에 있는 300제곱미터 규모의 겨울철 온실도 비슷한 열개를 갖추고 있습니다. 펠릿 보일러와 축열조, 튜브레일 난방 설비를 갖춘 이 온실은 JNGW100 외부 기상 장치와 내부 곳곳에 심은 열전대 센서 값을 GL840 로거로 1분마다 하나도 빠짐없이 기록합니다. 촘촘하게 쌓인 이 기록이 있어야 매서운 한파가 닥치기 몇 시간 전에 축열조의 온수를 미리 데워 두는 예측형 난방 판단도 비로소 가능해집니다. 계측 간격을 1분 단위까지 좁힌 일 자체가, 그 뒤에 올릴 어떤 정교한 판단 로직보다 먼저 갖춰야 할 바탕입니다.

일본 아이치현의 농업 혁신 사업에서 시험한 스마트 미스트 제어 사례는 센서 하나를 더 얹었을 때 무엇이 달라지는지를 보여 줍니다. 온실 안 온도와 습도만 보는 대신 바깥의 일사 강도, 곧 햇빛이 얼마나 세게 내리쬐는지를 재는 값을 함께 읽어, 공기가 얼마나 목말라 있는지를 하나의 숫자로 나타내는 포화수분부족량(VPD)을 실시간으로 계산합니다. 햇빛이 갑자기 강해져 이 숫자가 치솟으면 잎이 젖지 않을 만큼만 미스트를 짧게 뿌려 작물이 받는 스트레스를 낮여 주고, 재배자는 스마트폰 앱으로 그 흐름을 그대로 지켜봅니다. 온도와 습도 같은 날개의 값을 한데 묶어 새로운 숫자를 만들어 내는 일이 '지능형' 측정이라는 말이 가리키는 실제 모습에 가깝습니다.

타이완 가오슝의 대형 다단 재배대와 수직농장 사례는 센서망을 촘촘히 쌓아 올리면 무엇을 더 볼 수 있는지 보여 줍니다. 난초와 수경 채소를 여러 층 선반에 나눠 기르는 이 농장은 선반 한 칸마다 온습도, pH, 수분 센서를 따로 달고, 그 값을 중앙 현장 제어함과 클라우드 모니터링 화면으로 한데 모읍니다. 선반 위쪽 칸과 아래쪽 칸은 빛과 통풍이 다르게 닿기 때문에, 온실 전체를 하나로 보던 계측 방식을 층 단위로 잘게 쪼갬니다. 여기에 전력과 용수 사용량까지 함께 재어 탄소 배출량을 화면에 그려 보여 주면서, 센서가 작물 상태와 함께 농장 운영 전체의 효율까지 드러내는 계기판 역할을 겸하게 되었습니다.

이렇게 잘 짜인 체계에도 약한 고리는 남아 있습니다. 온실 안 상대습도가 90퍼센트를 넘나들고, 농약을 칠 때마다 부식성 기체가 퍼지고, 먼지와 물방울이 엉겨 붙는 환경에서는

센서의 감도가 시간이 지나며 조금씩 무뎌집니다. 이런 현상을 표류라고 부르는데, 온실 안 실제 온도는 그대로인데도 센서가 가리키는 숫자만 슬금슬금 어긋나는 상태를 뜻합니다. 이를 막기 위해 사람이 손으로 재조정하지 않아도 여러 센서 값을 서로 견주어 스스로 눈금을 바로잡는 자체 교정 소프트웨어와, 물과 먼지를 막아 내는 내구성 나노 소재 코팅을 입힌 센서가 함께 연구되고 있습니다.

정기적인 교정도 빼놓을 수 없는 절차입니다. 새 센서를 처음 설치할 때는 제조사가 재어둔 기준값과 실제 현장 값을 맞춰 보는 초기 교정을 거치고, 이후에도 몇 달에 한 번씩 값이 이미 확인된 표준 용액이나 표준 광원에 견주어 눈금을 다시 맞춥니다. 습도 센서라면 소금물처럼 습도가 일정하게 유지되는 포화 용액에 잠깐 넣어 두고 그 값을 기준으로 삼는 방법이 흔히 쓰입니다. 이런 손이 많이 가는 절차를 사람이 매번 온실을 돌며 반복하는 대신, 여러 센서의 값을 서로 견주어 어긋난 쪽을 찾아내는 소프트웨어 교정이 사람의 손을 조금씩 대신해 가고 있습니다.

공간을 어떻게 나눠 센서를 심을지도 여전히 풀어야 할 숙제입니다. 큰 온실일수록 환기 팬 앞과 온실 중앙, 작물 군락 위쪽과 아래쪽 사이의 기후 차이가 커지는데, 같은 간격으로 센서를 격자 모양으로 심는 방식은 정작 온도차가 큰 구역을 놓치기 쉽습니다. 구역을 나눠 각기 다른 밀도로 센서를 배치하는 층화 표본 방식과, CFD 기반 재구성 계산을 겹쳐 쓰는 방법이 그 대안으로 다뤄지고 있습니다. 센서를 어디에 몇 개 심을지 정하는 일이, 어떤 센서를 쓸지 고르는 일 못지않게 중요해지고 있습니다.

제조사가 다른 센서와 프로그램가능 논리제어기(PLC), 각종 제어기를 한데 묶으려 하면 서로 다른 통신 언어 탓에 값이 어긋나거나 아예 연결되지 않는 일이 자주 벌어집니다. 농장에 설비를 새로 들일 때마다 이전 장비와 호환이 되는지부터 따져야 하는 부담도 여기서 함께 생깁니다. 이를 풀기 위해 산업 현장에서 널리 쓰는 표준 통신 규격인 오피씨유에 이(OPC UA), 일본의 농업 데이터 공유 기반인 와그리(WAGRI), 사물인터넷을 농업에 맞춘 아이오피(ioP) 클라우드 같은 공통 규격이 정착해 가고 있습니다. 규격을 통일하는 일과 함께, 공학을 배우지 않은 재배자도 며칠 안에 손에 익힐 수 있는 쉬운 화면과 조작법을 만드는 일도 나란히 풀어야 할 숙제로 남아 있습니다.

현장에 내려간 인공지능 계산이 실제로 겪는 어려움은 시험 삼아 돌려 본 정확도만으로는 다 드러나지 않습니다. 구동기가 명령을 받고 실제로 움직이기까지는 눈에 띄는 지연이 있고, 바람이나 진동 같은 물리적 요인이 예상치 못한 순간에 끼어듭니다. 통신이 잠깐이라도 끊기면 게이트웨이가 클라우드의 답을 마냥 기다릴 수 없으므로, 현장 쪽에도 최소한의 판단 로직을 남겨 두어야 합니다. 값싼 마이크로컨트롤러 위에서도 이런 판단을 놓치지 않고 돌리는 일이 다음 목표로 남아 있습니다.

계산을 게이트웨이 안으로 옮기는 흐름이 굳어질수록, 그 안에 얹는 인공지능 모형 자체도 작고 가벼워져야 합니다. 숫자를 8비트로 줄여 계산량을 낮추는 양자화나, 큰 모형이

배운 내용을 작은 모형에게 옮겨 담는 지식 증류 같은 기법이 그 답으로 다듬어지고 있습니다. 센서를 고르는 일, 전력을 대는 일, 통신망을 놓는 일, 빈 값을 채우고 잡음을 거르는 일, 눈금을 맞추는 일은 저마다 따로 보면 사소해 보이지만 어느 하나가 빠지면 그 위에 올라가는 어떤 판단도 흔들립니다. 온실 기둥에 붙은 센서 상자가 읽은 값은 빈 곳이 채워지고 잡음이 걷히고 눈금이 맞춰진 뒤에야 몇 초 안에 팬과 펌프와 조명을 움직이는 판단으로 바뀝니다.

흰 상자 안의 센서가 정말 맞는 값을 읽고 있는지는 또 다른 문제입니다. 재배자가 손에 든 작은 병에는 산성도 4와 7과 10을 정확히 맞춘 투명한 액체가 담겨 있고, 센서 끝을 그 병에 차례로 담갔다 빼면서 화면에 뜨는 숫자를 표준값에 맞춰 조정하는 일이 검·교정입니다. 전기전도도 센서도 마찬가지로 전도도를 미리 알고 있는 표준 용액에 담가 눈금을 다시 맞춥니다. 이 작업은 한 번 해 두면 끝나는 게 아니라 계절이 바뀔 때마다, 못해도 몇 달에 한 번씩 되풀이해야 합니다. 검·교정을 거른 채 반년, 일 년을 흘려보내면 센서는 여전히 숫자를 뱉어내지만 그 숫자가 가리키는 실제 값과는 조금씩 벌어진 채로 시간만 흘러갑니다.

그래서 현장에서는 언제, 어떤 센서를, 어떤 표준값으로 맞췄는지 담아 두는 교정 기록표를 따로 관리하며, 이 기록이 있어야 나중에 어느 시기의 데이터를 믿고 어느 시기의 데이터를 의심해야 할지 가려낼 수 있습니다.

센서를 겹쳐 놓았을 때 어느 쪽 말을 들을지 정하는 규칙도 필요합니다. 온도 센서 세 대를 같은 구역에 나란히 심어 두면, 그 가운데 두 대는 섭씨 24도 근처를 가리킵니다. 나머지 한 대만 31도를 찍는다면, 다수결로 남은 두 값을 받아들이고 갈라진 쪽을 의심 목록에 올립니다. 십 초 사이에 온도가 5도 넘게 뛰는 것처럼 실제로는 일어나기 어려운 변화가 찍혀도 같은 방식으로 걸러 냅니다. 이렇게 걸러진 센서는 곧바로 떼어 내는 대신 며칠 더 지켜보면서 같은 어긋남이 되풀이되는지 확인한 뒤에야 고장으로 확정합니다. 한 번의 튜브는 먼지 한 톨이 지나간 우연일 수 있지만, 되풀이되는 어긋남은 센서 자체의 문제로 봐야 하기 때문입니다.

보간으로 채운 값에는 표시를 남겨 두는 일도 빼놓을 수 없습니다. 직선으로 잇는 과거의 값은 흐름을 끌어오든, 이렇게 채운 숫자는 센서가 실제로 잦 값이 아니라 계산이 짐작한 값이기 때문입니다. 이 표시가 없으면 몇 달 뒤 수확량과 환경 기록을 나란히 놓고 견줄 때 짐작한 숫자와 실제로 잦 숫자가 뒤섞여 엉뚱한 쪽으로 결론이 흐를 수 있습니다. 이보다 까다로운 경우는 통신 두절이 아니라 배관이 얼어붙거나 펌프가 멈춘 진짜 고장인데도, 보간이 그 빈자리를 매끄러운 숫자로 메워 버려 문제가 겉으로 드러나지 않는 상황입니다. 그래서 빈 구간이 일정 시간 넘게 이어지면 보간과 별개로 현장 점검 알림을 함께 띄워, 계산이 문제를 조용히 덮어 버리지 않도록 막습니다.

통신망을 잘 때는 선을 얼마나 쓸지 못지않게 신호가 끊겼을 때 어떻게 버틸지를 함께 정해야 합니다. 무선 센서 노드는 게이트웨이와 연결이 끊기면 값을 그대로 흘려보내는 대신 내장된 저장 장치에 잠시 담아 두었다가, 연결이 되살아나는 순간 밀린 값을 한꺼번에 밀어 올리는 방식을 씁니다. 노드끼리 서로 신호를 이어받아 전달하는 그물 구조를 짜 두면, 철골 기둥 하나가 전파를 막아서더라도 옆 노드를 거쳐 값이 돌아갈 길이 남습니다. 유선 구간은 이런 우회로를 잘 필요가 없는 대신 선 자체가 끊기면 대안이 없으므로, 중심이 되는 굵은 선일수록 여분의 선을 하나 더 깔아 두는 이중화가 함께 쓰입니다.

재배자가 들여다보는 화면도 숫자만 늘어놓아서 쓸모가 없습니다. 정상 범위는 초록, 주의가 필요한 구간은 노랑, 당장 손을 써야 하는 구간은 빨강으로 칠해 두면 화면을 스치듯 보고도 상태를 가늠할 수 있습니다. 문제는 경보가 너무 자주 울리면 정작 중요한 순간에 재배자가 알림을 무시하게 된다는 점입니다. 그래서 작은 변동은 화면 안에 조용히 표시만 해 두고, 여러 값이 한꺼번에 위험 구간에 들어가거나 같은 경고가 일정 시간 넘게 이어질 때만 휴대전화로 알림을 보내는 식으로 문턱을 나눕니다. 첫 알림에 아무 반응이 없으면 얼마 뒤 전화까지 걸리도록 단계를 올리는 곳도 있습니다. 화면 한구석에는 지금 값과 나란히 한 시간 뒤, 하루 뒤 예상값도 함께 그려 두어서, 재배자가 숫자가 오르면 뒤에야 반응하는 대신 오르기 전에 손을 쓸 수 있게 돕습니다.

이 모든 장치가 넉넉한 예산의 큰 농장에서만 쓰인다면 절반의 성공에 그칩니다. 센서와 게이트웨이, 소프트웨어 사용료를 합치면 작은 농가가 선뜻 들이기 어려운 금액이 되기 쉽고, 막상 장비를 들여도 고장 났을 때 봐 줄 기술자를 시골에서 구하기 어려운 경우가 많습니다. 원격으로 펌프와 환기창을 여닫는 체계는 편리한 만큼 바깥에서 함부로 접속해 조작할 위험도 함께 지고 갑니다. 한겨울에 누군가 시스템에 침투해 환기창을 열어 버리면 몇 시간 안에 온실 하나가 통째로 얼어붙을 수 있습니다. 여기에 몇 해 동안 쌓인 환경과 생육 기록이 정작 값을 만들어 낸 재배자에게 남지 않고 장비를 판 회사의 서버에 갇혀, 다른 회사 장비로 바꾸는 순간 기록이 통째로 끊기는 문제도 남아 있습니다. 장비 도입 비용과 유지보수 인력, 원격 제어 보안, 데이터 이동성은 이 기술이 앞으로 풀어야 할 과제에 남아 있습니다.

근거 및 참고문헌

학술 논문

1. Arfiyani, S. A., Wardihani, E. D., & Helmy. (2026). Smart Greenhouse Data Integration Using Machine Learning Approaches. Jurnal Nasional Teknik Elektro dan Teknologi Informasi, 15(2), 291-305. DOI: 10.22146/jnteti.v15i2.21951.
2. Cai, Y., Liu, D., Xu, Q., Li, B., & Liu, B. (2026). Greenhouse Temperature and Humidity Prediction Method Based on Adaptive Kalman Filter and GWO-LSTM-Attention. Smart Agriculture, 8(1), 148-155. DOI: 10.12133/j.smartag.SA202506033.

3. Huang, X., Zhu, Q., & Huang, M. (2026). Online Detection System for Freshness of Fruits and Vegetables Based on Temporal Multi-source Information Fusion. Smart Agriculture, 8(1), 203-212. DOI: 10.12133/j.smartag.SA202505037.
4. Jamjachi Yauri, R. I., Herbozo Ramirez, J. R., & Ovalle, C. (2026). Sustainable greenhouse using IoT and machine learning to optimize the microclimate for lettuce cultivation. Bulletin of Electrical Engineering and Informatics, 15(3), 2138-2149. DOI: 10.11591/eei.v15i3.9877.
5. Park, S., Kim, D. H., & Oh, K. C. (2026). Field-based implementation of machine learning forecasting for energy-efficient temperature control in a greenhouse system. Journal of Agricultural Engineering, LVII:11eb730c.
6. Qiu, J., Liu, Y., Gao, X., Huang, Y., Zhang, H., Tian, F., Li, W., & Feng, Z. (2026). AgriAgent: End-to-End Large Model Agent System Architecture for Agricultural Environment Control. Smart Agriculture, 8(2), 220-236. DOI: 10.12133/j.smartag.SA202507042.
7. Wang, J., et al. (2026). Research Progress and Prospects of Intelligent Management and Control Technologies for Facility Vegetables. Smart Agriculture, 8(1), 105-120.
8. (2026). Systematic Review of Autonomous Weed Detection and Identification Using Deep Learning. Precision Agriculture.
9. 高山弘太郎. (2026). 施設園芸のメガスケールとストロングミニマム：環境制御高度化と作業自動化に向けて. 農業食料工学会誌, 87(4), 502-503.
10. (2026). 植物環境工学の研究展望 第二十七回 植物工場の環境評価・予測における数値解析研究の現状と展望. 植物環境工学, 38(2), 55-60 / 506-510.

보고서 및 웹 자료

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

강연 및 영상 자료

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

7. 農業農村情報通信環境整備 準備会. (2026). 第6回オンラインセミナー「自治体・農業DXを支える次世代無線:Wi-Fi HaLowの最新動向と活用事例」. YouTube. https://www.youtube.com/watch?v=1Gn_rbR6_Tc
8. Life at PTPN. (2025). Webinar GO DIGI SERIES #5 IOT And AI Implementation In Agriculture. YouTube. <https://www.youtube.com/watch?v=TvmtwvyHwUQ>

3.2

디지털 트윈 및 AI 지능형 환경·생육 최적화

디지털 트윈(Digital Twin)은 실제 온실의 구조와 설비를 컴퓨터 안에 그대로 재현한 가상 모형에, 센서가 실시간으로 보내는 기온·습도·이산화탄소 농도·토양 수분 같은 자료를 결합해 앞으로 온실 안 환경이 어떻게 바뀔지 미리 계산하는 기술입니다. 지붕창을 열거나 관수 밸브를 조정하는 조치를 화면 속 모형에 먼저 적용해 그 결과를 계산으로 확인한 다음에야, 같은 조치를 실제 온실 설비로 내려보냅니다. 시간이 흐르는 대로 온실 상태와 함께 움직여 간다는 뜻에서 쌍둥이라는 이름이 붙었습니다.

디지털 트윈은 온실을 그대로 본뜬 3차원 그림이 전부가 아닙니다. 겉모습만 닮은 모형이라면 굳이 계산할 것도 없이 사진 한 장으로 충분하기 때문입니다. 진짜 알맹이는 온실 안 공기와 흙, 그리고 그 속에서 자라는 식물이 시간이 지나면서 어떻게 바뀌는지를 계산해 내는, 살아서 돌아가는 엔진 쪽에 있습니다. 이 엔진의 중심은 국제적으로 널리 쓰이는 작물 생장 모델인 디삐트(DSSAT, 농업기술이전 의사결정지원체계) 4.8 버전입니다. 이 모델은 앞에서 광합성으로 만들어진 양분이 뿌리와 열매 등 몸 곳곳으로 나뉘어 가는 과정, 뿌리가 흙 속 물과 양분을 빨아들이는 속도, 더위나 가뭄 같은 스트레스에 식물이 반응하는 정도를 하루 단위로 계산해 냅니다.

재배자가 화면 속 창을 열거나 닫으면 이 엔진이 그 변화를 반영해 다시 계산을 돌리고, 내일 이 온실 토마토 줄기가 얼마나 더 굵어질지, 잎이 얼마나 더 처질지까지 미리 화면에 보여 줍니다.

온실 안에서는 기온과 습도, 이산화탄소 농도와 햇빛의 세기, 흙이나 배지에 담긴 물과 거름의 양이 따로따로 움직이지 않고 한꺼번에 얹혀 움직입니다. 창을 열면 기온과 습도가 함께 낮아지고, 그 바람에 이산화탄소가 밖으로 빠져나가는 속도까지 달라집니다. 손잡이 하나를 돌렸을 뿐인데 수압과 물 온도가 동시에 바뀌는 샤워기와 다르지 않은 엄밀합니다. 정해 둔 온도에 닿으면 팬을 켜고 내려가면 끄는 예전 방식의 온오프 제어로는 이 엄밀을 따라잡지 못합니다. 반응이 한 박자씩 늦고, 그 늦은 박자만큼 난방비와 물이 헛되이 쓰이며, 식물은 필요 이상으로 덥거나 춥거나 마른 시간을 며칠이고 견뎌야 합니다. 디지털 트윈과 인공지능 제어가 온실 기술의 중심으로 들어온 이유가 바로 여기에 있습니다.

실제 창과 밸브를 움직이기 전에 화면 속에서 먼저 계산해 보아야, 이 엄밀한 반응을 늦지 않게 붙잡을 수 있기 때문입니다.

디지털 트윈이 값어치를 크게 드러내는 순간은 재배자가 한 번도 해보지 않은 조치를 시험해 볼 때입니다. 보광을 평소보다 훨씬 세게 켜면 어떻게 될지, 관수 시각을 두 시간 앞당기면 열매 크기가 어떻게 바뀔지 실제 온실에서 시험하면 최소한 한 계절, 길게는 한 해를 걸어야 결과를 압니다. 그사이 판단이 틀렸다면 그해 수확은 그대로 날아갑니다. 하지만 화면 속 쌍둥이 온실에서는 같은 조치를 몇 분 만에 계산으로 미리 돌려 보고, 결과가 나쁘면 그냥 되돌리면 그만입니다. 신입 조종사가 진짜 비행기에 오르기 전에 모의 비행 장치 안에서 몇 번이고 실수를 저질러 보는 것과 같은 이치입니다. 실패해도 되는 연습장이 있다는 사실 하나만으로도, 재배자는 그동안 망설였던 조치를 좀 더 과감하게 시험해 볼 수 있게 되었습니다.

이 모든 계산과 판단을 사람이 밤낮없이 다 챙길 수는 없습니다. 그래서 연구자들은 온실을 대신 지켜보고 판단하는 인공지능 지능체를 만들었습니다. 중국 연구진이 내놓은 애그리에이전트(AgriAgent)가 그런 예입니다. 이 시스템은 질문에 대답만 하는 챗봇이 아니라, 온실에 상주하는 신입 재배자에 가깝습니다. 계기판을 읽고, 지난주에 어떤 조치를 했는지 기억하고, 필요하면 두꺼운 재배 교본을 펼쳐 본 다음에야 밸브를 돌리는 태도를 흉내 내기 때문입니다. 애그리에이전트의 핵심 판단 기능은 큐원2.5(Qwen2.5)라는 대형 언어모델(LLM, Large Language Model)이 맡으며, 15억 개, 30억 개, 70억 개로 크기가 다른 세 가지 모델이 나란히 시험대에 올랐습니다.

매개변수, 곧 모델 안에서 학습을 통해 값이 정해지는 숫자의 개수가 클수록 더 많은 상황을 구분해 기억하고 더 섬세하게 판단합니다.

애그리에이전트는 감지, 기억, 검색, 추론, 행동이라는 다섯 단계를 이레에 한 번씩 순서대로 거칩니다. 먼저 센서 자료가 열두 가지 숫자로 정리된 상태값을 만듭니다. 흙 속 물의 양, 흙 속 질소와 유기물의 양, 그날 평균 기온과 최고 기온, 하루 강수량과 바람 속도, 공기 중 이산화탄소 농도, 광합성에 실제로 쓰이는 빛의 세기, 씨를 뿌린 뒤 지난 날수, 그리고 물 부족과 생장 지연을 하나의 점수로 나타낸 두 가지 스트레스 지수가 여기 포함됩니다. 포맷 변환기라는 장치가 이 숫자들을 사람이 읽는 문장으로 풀어 바꾸고, 지난 기록과 뒤에서 설명할 검색 결과를 함께 붙여 인공지능 모델에게 건넵니다. 열두 가지 숫자를 한 문장씩 풀어 보면, 결국 지금 이 작물이 얼마나 목마르고 얼마나 잘 자랐는지를 사람 말로 옮긴 것에 지나지 않습니다.

숫자로 가득한 표 한 장을, 사람이 읽고 바로 이해할 수 있는 짧은 보고서로 바꾸는 절차입니다.

농사에는 교과서에만 나오는 세부 지식이 많아서, 아무리 큰 언어모델이라도 모든 것을 다 외우고 있을 수는 없습니다. 애그리에이전트는 이런 지식을 통째로 암기하는 대신, 필요할 때마다 두꺼운 책에서 꼭 맞는 쪽을 찾아 펼치는 방식을 씁니다. 검색증강생성, 영어 약자로 RAG(Retrieval-Augmented Generation)라고 부르는 이 방식을 쓰기 위해 연

구진은 농학 교재와 기술 수첩 510만 자를 광학문자인식(OCR)으로 디지털 문서로 바꾸고, 그 가운데 쓸 만한 440만 자를 다시 작은 토막으로 나누어 정리했습니다. 각 토막에는 몇 장 몇 절에서 가져온 내용인지 알 수 있도록 꼬리표를 붙였습니다.

bge-large-zh라는 이름의 768차원 임베딩 모델, 곧 문장을 숫자 벡터로 바꾸어 뜻이 비슷한 문장끼리 가깝게 모아 두는 모델이 뜻이 통하는 토막을 찾아내고, 여기에 낱말이 그대로 일치하는지 보는 검색을 더해 지금 상황에 꼭 맞는 다섯 개 문서를 골라 인공지능에 건넵니다.

문서를 손에 쥔 인공지능은 곧바로 답을 내놓지 않고 단계를 밟아 갑니다. 지금이 싹이 트는 시기인지 꽃이 피고 열매가 맺는 시기인지 먼저 가리고, 물이 부족한지 생장이 처지는지를 살핀 다음, 그 판단을 근거로 명령을 정하는 사고 사슬(Chain-of-Thought) 방식입니다. 사람이 암산으로 정답만 던지지 않고 풀이 과정을 한 줄씩 적어 내려가는 것과 닮았습니다. 이렇게 나온 결론은 관수량, 보광 세기, 환기와 가온 여부, 시비량, 이산화탄소 방출량이라는 여섯 가지 수치로 이루어진 JSON이라는 정해진 형식의 자료로 정리됩니다. 관수량은 시간당 0에서 30밀리미터, 보광은 평소의 0에서 200퍼센트, 시비량은 헥타르당 0에서 50킬로그램 사이에서 정해집니다.

도구 실행기라는 마지막 확인 절차가 이 숫자들이 안전 범위를 벗어나지 않았는지 한 번 더 확인하고, 벗어난 값은 범위 안으로 깎아 낸 다음에야 디딤트 엔진이나 실제 온실 장비로 명령을 내려보냅니다.

가령 어느 월요일 아침, 센서 값이 흙 속 물의 양은 평소보다 적고 낮 최고 기온은 예년보다 3도 높다는 결과를 보였다고 해 봅니다. 물 부족 스트레스 지수도 위험 신호에 가깝게 올라와 있습니다. 애그리에이전트는 이 조합을 놓고 지금이 열매가 굼어지는 시기라는 사실과, 이런 시기에 흙이 마르면 생리 장애로 이어지기 쉽다는 지식베이스 속 문구를 함께 읽습니다. 결론은 관수량을 평소보다 끌어올리고 한낮 보광은 살짝 낮추어 잎이 겪는 부담을 줄이는 쪽으로 모아집니다. 사람 재배자라면 경험과 감으로 내릴 법한 이 판단을, 애그리에이전트는 숫자와 문서를 근거로 몇 초 만에 정리해 냈습니다.

장비는 언제든 고장 날 수 있습니다. 관수 장치가 멈추어 흙에 물을 덜 수 없게 되었다고 해 봅니다. 사람이라면 당황할 상황이지만 애그리에이전트는 원인과 결과를 따지는 추론 능력으로 다른 길을 찾습니다. 환기와 가온을 조절해 잎에서 물이 빠져나가는 증산 속도를 늦추고, 이산화탄소 방출량을 늘려 광합성을 도와줌으로써 물 부족으로 인한 손상을 어느 정도 상쇄하는 식입니다. 요리사가 냉장고에서 재료 하나가 떨어진 것을 보고 나머지 재료의 비율을 조정해 같은 요리를 완성해 내는 것과 닮은 대응입니다. 사람이 뒤늦게 달려가 밸브를 고치기 전까지, 작물은 이 임시 조정 덕분에 최악의 상황을 피합니다.

이런 판단력이 실제로 믿을 만한지 확인하려면 극단적인 날씨로 미리 시험해 보아야 합니다. 연구진은 1994년부터 2023년까지 30년치 기상 자료를 바탕으로 정상, 흔들림, 극단이라는 세 가지 강도의 가상 날씨를 만들어 모두 90가지 연간 시나리오를 준비했습니다. 극단 시나리오에는 20일 동안 이어지는 고온 건조, 80밀리미터가 넘는 폭우가 닥쳐 동안 몰아치는 상황, 건조한 20일 뒤에 곧바로 폭우 10일이 뒤따르는 급반전 같은 겹악재가 들어 있습니다. 이런 상황을 애그리에이전트가 겪게 한 다음 작물이 살아남는지, 얼마나 잘 버티는지를 지켜보는 것입니다. 실제 온실에서는 좀처럼 만나기 힘든 최악의 조합을, 화면 안에서라면 위험 없이 여러 번 되풀이해 겪어 볼 수 있습니다.

회복력이 높다는 말은 구체적인 장면을 가리킵니다. 20일 내내 덥고 마른 날이 이어지는 시나리오에서, 훈련이 덜 된 제어 방식은 스트레스 지수가 한 번 위험 구간에 들어서면 그 뒤로 좀처럼 회복하지 못하고 작물이 그대로 시들어 갔습니다. 반면 애그리에이전트는 물이 부족한 초반에 관수와 보광을 조금씩 더 얹어 스트레스 지수를 낮은 수준에서 묶어 두었고, 뒤이어 폭우가 몰아치는 급반전 구간에서도 환기량을 재빨리 늘려 과습으로 인한 피해를 줄였습니다. 최악의 날씨 앞에서도 손을 놓지 않고 매 순간 상황에 맞추어 조금이라도 나은 선택을 계속했다는 뜻입니다.

애그리에이전트처럼 언어를 다루는 인공지능만 온실에 들어온 것은 아닙니다. 더 오래전부터 쓰여 온 인공신경망(ANN, Artificial Neural Network)과 서포트벡터머신(SVM, Support Vector Machine)도 미기후를 읽는 역할을 맡고 있습니다. 두 모델 모두 숫자로 된 자료 속에서 패턴을 찾아내는 통계 기반 프로그램이며, 오렌지(Orange)라는 데이터 분석 도구 위에서 온실 안 온도와 습도, 자외선 세기를 한꺼번에 살펴 지금 상태를 걱정, 과다, 결핍이라는 세 칸 가운데 하나로 분류합니다. 이 분류의 정확도는 99.99퍼센트에 이르렀습니다. 만 번을 판정하면 겨우 한 번 틀릴까 말까 한 수준이니, 사람 눈으로 매번 계기판을 살피는 것보다 훨씬 촘촘한 감시입니다.

온도와 습도는 하루 안에서도 오르내림이 심하고 서로 영향을 주고받아서 예측이 까다롭습니다. 별이 잠깐 구름에 가렸다가 다시 나는 순간에도 온실 안 수치는 잘게 흔들립니다. 연구진은 먼저 여러 위치의 센서 값에 적응형 칼만 필터를 걸어 이런 흔들리는 잡음을 가라앉힙니다. 사진을 찍을 때 손 떨림을 보정해 흐릿함을 줄이는 것과 비슷한 절차입니다. 잡음이 걷힌 값이라야 그다음에 오는 예측 모델이 엉뚱한 방향으로 학습하지 않습니다.

잡음을 걷어 낸 다음에는 회색늑대 최적화(GWO, Grey Wolf Optimizer)라는 방법으로 예측 신경망의 세부 설정을 조율합니다. 회색늑대 무리가 사냥감을 여러 방향에서 서서히 에워싸듯, 여러 후보 설정값을 반복해서 좁혀 가며 알맞은 조합을 찾아내는 방식입니다. 이렇게 다듬어진 LSTM(장단기기억, Long Short-Term Memory) 신경망에 어텐션(주의 집중, Attention) 기법을 더하면, 지난 몇 시간의 기록 가운데 지금 예측에 정말 중요한

순간만 골라 무게를 신습니다. 이 조합은 앞으로 몇 시간 안에 온실 온도와 습도가 어떻게 움직일지를 한 번에 예측해 냅니다.

예측이 아무리 정확해도 그 예측을 실제 난방 장치를 켜고 끄는 판단으로 옮기지 못하면 소용이 없습니다. 데이터 기반 예측 제어, 줄여서 DDPC(Data-Driven Predictive Control)라고 부르는 방식은 추워질 것을 미리 알고 한파가 닥치기 전에 물을 데워 두는 접근입니다. 강원도 춘천의 300제곱미터 온실에 펠릿 보일러와 축열조, 튜브레일 가온 장치를 갖추고 1분 간격으로 자료를 모으는 현장 시험이 이루어졌습니다. GRU(Gated Recurrent Unit)라는, LSTM보다 가벼운 신경망이 최근 이레치 자료 1만 80개 측정값을 학습하고 그다음 하루치로 성능을 확인하는 방식을 되풀이했습니다. 이 모델은 한파가 오기 한두 시간에서 세 시간 전에 온실 안 기온이 떨어질 것을 예보하고, 그 예보에 맞추어 보일러와 온수 밸브를 미리 돌립니다.

그 결과 작물이 견딜 수 있는 최저 기온 아래로 떨어지는 일을 막으면서도 불필요한 난방을 줄여 연료비를 아꼈습니다.

난방과 수확량은 흔히 반대 방향으로 당기는 힘입니다. 온도를 넉넉하게 올려 두면 작물은 더 빨리 크고 열매도 더 많이 맺지만, 그만큼 보일러는 쉬지 않고 돌아가며 연료비를 잡아먹습니다. 반대로 난방을 아끼면 연료비는 줄어도 저온에 시달린 작물이 자라는 속도가 처지거나 꽃눈이 떨어져 결국 수확량으로 손해를 봅니다. 디지털 트윈은 이 두 목표를 따로 계산하지 않고 한 화면 안에 겹쳐 놓고 봅니다. 같은 겨울 시나리오를 놓고 난방 강도를 몇 단계로 바꾸어 가며 돌려 보면, 연료비 손실과 수확량 손실을 더한 값이 제일 작아지는 온도가 드러납니다. 춘천 온실의 GRU 기반 DDPC가 한파 직전에만 보일러를 짧게 돌려 최저 기온을 겨우 지켜 낸 것도, 결국 이 교차점을 실시간으로 다시 찾아가는 계산의 결과입니다.

이런 예측 모델의 실력은 몇 가지 숫자로 확인할 수 있습니다. 결정계수, 기호로는 R제곱이라고 쓰는 이 지표는 예측값이 실제값과 얼마나 가깝게 겹치는지를 0에서 1 사이 숫자로 나타내며, 1에 가까울수록 잘 맞았다는 뜻입니다. 이번 미기후 예측 모델들은 0.77에서 0.93 사이의 값을 냈습니다. 춘천 온실의 GRU 기반 난방 제어 모델은 평균 제공근 오차, 곧 RMSE 기준으로 1.43도 안팎의 오차를 보였습니다. 온도계 눈금 하나 반 정도만 어긋난 셈이니 난방 제어에 쓰기에는 충분한 정밀도입니다. 온실 상태를 적정과 과다와 결핍으로 나누는 분류 모델은 AUC-ROC라는 지표에서 0.988에서 0.991 사이를 기록했는데, 이는 세 상태를 서로 헷갈리는 일이 거의 없다는 뜻입니다.

이렇게 만들어진 애그리에이션트의 실력은 여러 작물에 걸쳐 시험되었습니다. 연구진은 디딤터 기반 디지털 트윈 위에서 옥수수, 조, 사탕무, 토마토, 배추라는 서로 다른 다섯 작물을 골랐습니다. 옥수수는 햇빛을 남달리 효율적으로 쓰는 광합성 경로를 가진 작물, 조는 가뭄에 강한 작물, 사탕무는 뿌리를 먹는 작물, 토마토는 열매를 먹는 작물, 배추는 잎

을 먹는 작물이어서 서로 다른 방식으로 자라는 작물을 고루 대표합니다. 90가지 기상 시나리오에 세 가지 강도를 곱해 모두 450번의 전체 생육 기간 시뮬레이션이 이루어졌습니다. 70억 매개변수를 가진 모델은 사람 손을 대지 않은 자연 생장과 견주어 옥수수과 조, 사탕무의 수확물 건조 중량을 뚜렷하게 늘렸습니다. 싹이 트는 시기에 저온 경보가 뜨자 보광 개입 강도를 스스로 120퍼센트까지 끌어올려 냉해를 줄이기도 했습니다.

15억, 30억, 70억으로 매개변수가 늘어날수록 제어 성능이 순서대로 좋아지는 흐름도 확인되었습니다.

가령 옥수수 시뮬레이션 한 편을 들여다보면, 지능체는 씨를 심은 날짜부터 며칠이 지났는지를 헤아려 지금이 싹이 트는 출묘기인지 이삭이 패는 시기인지를 먼저 가늠합니다. 같은 저온이라도 씨를 심은 지 열흘째 겪는 것과 이삭이 한창 여우는 시기에 겪는 것은 작물에 미치는 타격이 다르기 때문에, 생육 단계를 잘못 짚으면 아무리 정확한 온도 예측도 엉뚱한 처방으로 이어집니다. 실제 시험에서 지능체가 저온 경보 앞에서 보광을 끌어올린 시점도, 이 생육 단계 판단이 먼저 서 있었기에 가능했던 조치입니다. 날짜를 세는 것에서 그치지 않고, 그 날짜가 작물의 몸속에서 어떤 의미를 가지는지까지 함께 읽어 냅니다.

디지털 트윈은 실험실 안에서만 머무르지 않고 실제 상업 농장에도 적용되었습니다. 인도네시아의 산디부아나팜(Sandi Buana Farm)에서는 수경재배 상추를 키우면서 온도와 습도, EC, 산도를 재는 고해상도 센서에서 1만 5,492개의 표본을 모았습니다. EC는 물속에 거름 성분이 얼마나 녹아 있는지를 전기가 얼마나 잘 통하는지로 재는 값이고, 산도는 그 물이 얼마나 시거나 알칼리성인지를 나타내는 값입니다. 이 자료를 기계학습 예측 알고리즘에 넣어 상추 수확량과 재배 환경 변수를 함께 자동으로 맞추는 체계를 운영한 결과, 사람이 일일이 손보지 않아도 적절한 물과 거름 농도가 유지되었습니다. 실험실 시뮬레이션 하나 없이도, 현장에서 쌓은 숫자만으로 판단 체계를 세울 수 있다는 사실을 이 농장이 보여 주었습니다.

디지털 트윈 위에서 움직이는 언어모델 지능체와, 훨씬 오래전부터 온실에 쓰여 온 통계 기반 예측 모델은 경쟁 관계가 아니라 역할이 다른 동료에 가깝습니다. 지능체는 생육 단계와 여러 변수를 한꺼번에 읽어 큰 그림에서 관수와 시비, 보광의 균형을 잡는 역할을 맡고, ANN과 SVM, LSTM 계열 모델은 분초 단위로 바뀌는 온도와 습도를 놓치지 않고 잡아내는 역할을 맡습니다. 실제 현장에서는 두 층위가 겹쳐 돌아가는 경우가 많아서, 굵직한 판단은 지능체가 내리고 그 판단을 초 단위로 미세 조정하는 일은 통계 모델이 떠맡는 식의 분업이 자연스럽게 정착됩니다. 한쪽이 지붕 창을 열지 말지를 정한다면, 다른 한쪽은 그 창이 열린 뒤에 온도가 예상과 다르게 움직이지는 않는지 초 단위로 지켜봅니다.

두 층위 가운데 어느 하나만 있었다면, 큰 그림은 맞아도 순간의 흔들림을 놓치거나 순간은 잡아도 계절 전체의 흐름을 못 읽는 반쪽짜리 판단에 그쳤을 것입니다.

한 온실에서 검증된 지능체를 열 동, 백 동으로 늘리는 일은 산수처럼 간단하게 풀리지 않습니다. 온실마다 방향과 자재, 주변 건물의 그늘이 달라서 같은 명령이 다른 결과를 낳기 때문입니다. 그래서 새 온실에 지능체를 들일 때는 처음 몇 주 동안 그 온실만의 버릇을 따로 익히는 적응 기간을 두는 경우가 많습니다. 기존 온실에서 쌓은 지식베이스와 판단 습관을 밑감으로 삼되, 새 현장의 숫자가 쌓이는 대로 조금씩 다시 맞추어 가는 방식입니다.

이런 흐름은 몇 건의 국지적 실험에 그치지 않습니다. 디지털 트윈을 온라인 시뮬레이터로 놓고 대형언어모델 지능체와 하나의 닫힌 고리로 묶어, 실제 장비로 명령이 나가기 전에 그 명령이 안전한지 실시간으로 검증하는 구조가 최근 연구에서 제안되었습니다. 언어모델이 시간 흐름에 딱 맞춰 판단을 내리는 고리 안에서도 제 역할을 할 수 있다는 사실을 보여 준 결과입니다. 무선 센서와 구동기로 이루어진 통신망과 트윈 소프트웨어를 결합해 미기후와 관수를 멀리서 감시하고 자동으로 제어하며 병 발생 가능성까지 미리 찾아내는 스마트 온실 구현 사례도 나왔습니다. 재배자는 온실 문턱을 넘지 않고도 지금 상태를 확인하고, 조치 하나를 화면 속에서 먼저 시험해 본 다음에야 실제로 적용합니다.

2026년에는 작물 생장 모형과 자율 기후 제어를 하나로 잇는 데이터 기반 온실 관리 방식까지 제시되어, 디지털 트윈이 보여 주기용 모형에서 판단과 실행을 겸하는 도구로 옮겨가고 있음을 드러냅니다.

재배자가 실제로 마주하는 화면은 색깔 있는 계기판입니다. 열두 가지 상태값과 여섯 가지 제어 명령이 그래프와 막대로 나란히 뜨고, 인공지능이 왜 그런 명령을 냈는지 요약한 한두 문장이 그 옆에 붙습니다. 재배자는 이 문장을 읽고 그대로 두거나, 마음에 들지 않으면 숫자를 손으로 고쳐 되돌릴 수 있습니다. 사람이 최종 서명을 하기 전까지는 지능체의 판단도 초안일 뿐이라는 원칙이 화면 설계에 그대로 녹아 있습니다.

이 체계가 들어서기 전에는 재배자가 새벽마다 손전등을 들고 온실을 돌며 온도계를 하나 하나 확인해야 했습니다. 한파주의보가 뜬 밤이면 두세 시간마다 잠에서 깨어 보일러 상태를 점검하는 일도 드물지 않았습다. 디지털 트윈과 지능체가 이 반복 노동을 대신 떠맡으면서, 재배자의 하루는 문제가 생겼을 때만 화면 앞으로 불러 나가는 방식으로 바뀌었습니다. 밤새 평온했다면 알림 하나 없이 아침을 맞고, 무언가 어긋났다면 그 순간 휴대 전화가 울립니다. 손으로 하던 순찰은 사라졌지만, 그 일은 계산이 대신 맡고 있습니다.

그렇다고 이 기술이 다 완성된 것은 아닙니다. 디딤표 기반 디지털 트윈 안에서 검증된 제어 방법을 그대로 실제 온실에 옮기면 계산과 현실이 어긋나기 시작합니다. 액추에이터가 명령을 받고도 움직이기까지 걸리는 시간, 오래 쓴 센서 값이 조금씩 틀어지는 편차, 온실 구석과 중앙의 온도 차이, 예측하지 못한 외부 충격이 모두 화면 속 계산과 실제 결과 사이에 틈을 만듭니다. 연구자들은 이 틈을 시뮬레이션과 현실의 격차라고 부르며, 트윈 안에서 더 거친 상황을 미리 겪게 하는 훈련과 함께 현장에 배치한 뒤에도 계속 배우는 방

식으로 메우려 합니다. 로라(LoRA)라고 부르는 미세조정 방법은 큰 모델 전체를 다시 훈련시키는 대신 몇몇 손잡이만 살짝 돌려 새 현장에 맞추는 방식이어서, 이런 지속 학습에 잘 들어맞는 도구로 꼽힙니다.

기술이 아무리 정교해도 그 기술을 다룰 사람이 없으면 온실 구석에 놓인 장식품으로 그칩니다. 애그리에이전트가 내놓는 판단을 그대로 받아들일지, 아니면 자신의 오랜 경험에 기대어 숫자를 손으로 고칠지는 결국 재배자가 정합니다. 이런 신뢰는 하루아침에 쌓이지 않고, 지능체가 몇 계절에 걸쳐 큰 실수 없이 판단을 이어 가야 비로소 두꺼워집니다. 화면 속 쌍둥이가 실제 온실과 다르게 움직이는 순간을 몇 번 목격한 재배자라면, 그 뒤로는 아무리 정확한 예측이 나와도 곧이곧대로 믿지 않을 것입니다.

70억 매개변수짜리 모델을 돌리려면 값비싼 그래픽 연산 서버와 끊기지 않는 통신망이 있어야 합니다. 이런 조건은 자본이 넉넉하지 않은 농가에는 문턱으로 작용하고, 통신이 오갈 때마다 판단이 늦어지는 부작용도 낳습니다. 이를 풀기 위해 연구자들은 모델 안의 각 숫자를 더 적은 비트로 표현해 저장하는 양자화(INT8) 기법과, 큰 모델이 알아낸 판단 방식을 작은 모델에게 옮겨 가르치는 지식 증류(Knowledge Distillation) 기법을 함께 쓰고 있습니다. 실력이 뛰어난 선배가 요령을 정리해 후배에게 넘겨주듯, 70억 모델의 판단 습관을 15억이나 30억 규모의 작은 모델에 옮겨 심어 온실 현장의 저렴한 장비에서도 돌아가게 만드는 것입니다. 이렇게 몸집을 줄인 모델은 클라우드까지 자료를 보내지 않고도 온실 바로 옆 소형 컴퓨터에서 판단을 끝낼 수 있습니다.

소농 한 사람의 온실에서도 지능체가 돌아갈 수 있어야 이 기술이 몇몇 대형 농장만의 도구로 남지 않습니다.

수확량을 늘리는 목표와 에너지를 아끼는 목표, 물과 탄소 배출을 줄이는 목표는 자주 서로 부딪힙니다. 보광을 세게 켜면 수확량은 늘지만 전기료가 함께 오르는 식입니다. 지능체가 이 여러 목표 사이에서 어느 한쪽만 편들지 않도록 보상 계산 방식을 여러 겹으로 설계하는 작업이 이어지고 있습니다. 그리고 인공지능이 왜 이 시각에 창을 열기로 정했는지, 그 판단의 근거를 재배자가 화면에서 바로 확인할 수 있어야 합니다. 판단 과정이 검은 상자처럼 감추어져 있으면 아무리 정확한 모델이라도 현장에서 믿고 맡기기 어렵습니다. 디지털 트윈과 지능형 제어가 실험실을 벗어나 평범한 온실의 도구로 정착하려면 설명 가능성을 높이는 연구가 더 필요합니다.

근거 및 참고문헌

학술 논문

1. Qiu, J., Liu, Y., Gao, X., Huang, Y., Zhang, H., Tian, F., Li, W., & Feng, Z. (2026). AgriAgent: End-to-End Large Model Agent System Architecture for Agricultural Environment Control. *Smart Agriculture*, 8(2), 220-236. DOI: 10.12133/j.smartag.SA202507042.
2. Park, S., Kim, D. H., & Oh, K. C. (2026). Field-based implementation of machine learning forecasting for energy-efficient temperature control in a greenhouse system. *Journal of Agricultural Engineering*, LVII:11eb730c.
3. Cai, Y., Liu, D., Xu, Q., Li, B., & Liu, B. (2026). Greenhouse Temperature and Humidity Prediction Method Based on Adaptive Kalman Filter and GWO-LSTM-Attention. *Smart Agriculture*, 8(1), 148-155. DOI: 10.12133/j.smartag.SA202506033.
4. Arfiyani, S. A., Wardihani, E. D., & Helmy. (2026). Smart Greenhouse Data Integration Using Machine Learning Approaches. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, 15(2), 291-305. DOI: 10.22146/jnteti.v15i2.21951.
5. Xu, Q., Zheng, B., & Zhong, S. (2026). Artificial Intelligence Empowering Modern Agricultural Biological Breeding. *Smart Agriculture*, 8(3), 69-85.
6. Wang, J., et al. (2026). Research Progress and Prospects of Intelligent Management and Control Technologies for Facility Vegetables. *Smart Agriculture*, 8(1), 105-120.
7. Jamjachi Yauri, R. I., Herbozo Ramirez, J. R., & Ovalle, C. (2026). Sustainable greenhouse using IoT and machine learning to optimize the microclimate for lettuce cultivation. *Bulletin of Electrical Engineering and Informatics*, 15(3), 2138-2149. DOI: 10.11591/eei.v15i3.9877.

보고서 및 웹 자료

1. arXiv. (2025). 온라인 시뮬레이터 기반 디지털 트윈과 대형언어모델 지능체의 폐쇄루프 온실 제어 검증에 관한 연구. <https://arxiv.org/pdf/2507.07115>
2. Springer. (n.d.). 스마트 온실 디지털 트윈 구현: 무선 센서·구동기 통신망 기반 미기후 원격 감시와 병해 예측에 관한 연구. https://link.springer.com/chapter/10.1007/978-981-99-0252-1_5
3. PLOS ONE. (n.d.). 디지털 트윈 온실에서의 원격 상태 감시와 가상 조치 검증에 관한 연구. <https://journals.plos.org/plosone/article?id=10.1371%2Fjournal.pone.0344946>
4. ScienceDirect. (2026). 작물 생장 모형과 자율 기후 제어를 연계한 데이터 기반 적응형 온실 관리에 관한 연구. <https://www.sciencedirect.com/science/article/pii/S2590005626000445>

강연 및 영상 자료

1. 高雄農來訊. (2025). 114年高雄智慧農業年度成果發表暨研討會. YouTube. <https://www.youtube.com/watch?v=1Edc6pP4HnU>
2. Kanal Pengetahuan Fakultas Teknologi Pertanian UGM. (2025). Artificial Intelligence in Smart Greenhouses: Enhancing Crop Monitoring and Environmental Control. YouTube. <https://www.youtube.com/watch?v=zFP6Nm4i4Ec>
3. WiseFood Project. (2025). WiseFood and STELAR Webinar: Empowering Agrifood Apps With LLM-Based Dataset Search and Integration. YouTube. https://www.youtube.com/watch?v=Keqo17qBr_g
4. Regace Project. (2026). Agrivoltaics in Greenhouses - Turning Sunlight into Energy & Crops. YouTube. <https://www.youtube.com/watch?v=rSJvAXnY8w>
5. KYOTO SMART CITY EXPO. (2025). 스마트 농업의 최전선~植物との対話からつくる未来の農業. YouTube. <https://www.youtube.com/watch?v=PzHccCvmsRs>

4장

데이터 기반 정밀 농업 및 의사결정 지원

4.1

지능형 관수·비료 공급 최적화

지능형 관수 체계에서는 밸브를 여는 주체가 사람이 아니라 흙 속에 꽂힌 센서와 클라우드 서버에서 돌아가는 예측 모델입니다. 흙이 얼마나 말랐는지, 낮 기온이 얼마나 올랐는지, 내일 비가 올 확률이 몇 퍼센트인지를 계산해 관수 시각과 물의 양을 정합니다. 미국 네브래스카 현장 시험에서 이런 관수 스케줄링 도구를 쓴 옥수수 받은 물을 29퍼센트에서 43퍼센트까지 아꼈고, 콩 받은 10퍼센트에서 37퍼센트까지 아꼈으며, 두 밭 모두 수확량은 기존 방식과 비슷했습니다.

전통적인 농사에서 물과 비료를 언제 얼마나 줄지는 재배자의 손끝 감각과 정해진 시간표에 달려 있었습니다. 아침 여섯 시가 되면 물을 틀고, 한 달에 한 번 비료를 섞는 식입니다. 문제는 흙과 하늘이 시간표대로 움직이지 않는다는 점입니다. 어떤 날은 이미 젖은 흙에 또 물을 부어 뿌리가 숨 쉴 틈을 잃고, 어떤 날은 바짝 마른 흙을 그대로 두어 작물이 시듭니다. 남은 물은 땅속 깊이 흘러가며 흙을 쓸어내리고, 거기 녹아 있던 질소와 인은 하천으로 흘러들어 갑니다. 기후 변화로 가뭄과 폭우가 번갈아 심해지면서, 감각과 시간표에 기댄 관수와 시비는 점점 더 큰 손해로 이어지고 있습니다.

이 손해를 줄이려는 기술이 지능형 관수·비료 공급 최적화입니다. 토양 수분 센서와 기상 관측 장비, 사물인터넷(IoT, 여러 기기를 인터넷으로 연결해 정보를 주고받게 하는 통신망), 그리고 머신러닝 예측 모델을 하나로 묶은 체계입니다. 이 체계가 하는 일은 흙과 공기와 작물이 주고받는 물의 흐름을 여러 각도에서 재는 일, 작물이 자라는 단계마다 달라지는 물과 양분 요구량을 계산하는 일, 센서 자료와 기상 예보를 모델에 넣어 앞으로 며칠의 필요량을 예측하는 일, 그 예측을 받아 클라우드 서버가 밸브와 펌프를 실제로 움직이는 일로 이어집니다. 중국 동북부에서 진행된 메타분석 연구를 보면, 관행 관수와 시비 대신 점적관수와 관비를 결합한 방식을 쓸 때 작물 수확량과 물 생산성, 질소 이용 효율이 함께 오른 것으로 나타났습니다(Li et al., 2021).

밭 전체에 물을 흠뿌리는 방식보다 뿌리 앞에 정확한 양만 놓아 주는 방식이 낫다는 뜻으로 읽힙니다.

이 네브래스카 현장 시험은 재배자가 평소 하던 방식과 상용 관수 스케줄링 도구를 나란히 돌려 견준 결과입니다. 같은 수확을 내면서 물은 훨씬 덜 썼습니다. 생육 단계마다 센서 값을 계속 살피고 그때그때 판단을 바꾸는 인공지능 스케줄링에서는 물을 최대 87.97

퍼센트까지 아낀 사례도 보고되었습니다. 다만 이 수치는 특정 작물과 조건에서 나온 상한선이므로, 모든 농장에 그대로 적용된다고 보기는 어렵습니다.

땅과 하늘과 작물이 물을 주고받는 관계를, 과학자들은 토양-대기-작물 연속체 (Soil-Plant-Atmosphere Continuum, SPAC)라고 부릅니다. 물이 흙에서 뿌리로, 뿌리에서 줄기와 잎으로, 잎에서 다시 공기 속으로 이어져 흐른다는 뜻입니다. 이 흐름의 속도를 결정하는 것은 흙 속 물의 양만이 아닙니다. 기온이 높고 바람이 세고 햇빛이 강하면 잎에서 물이 빠르게 날아가고, 뿌리는 그만큼 흙에서 물을 더 빨리 끌어올립니다. 흙에서 마르는 물과 잎에서 날아가는 물을 합쳐 증발산량(蒸發散量, Evapotranspiration, ET)이라고 부르며, 관수 시스템은 기온과 습도, 일사량, 풍속, 강수량을 매 순간 측정해 이 증발산량을 추정합니다. 흙 속에는 정전용량식이나 저항식 수분 센서를 여러 깊이에 묻어, 겉흙과 뿌리가 실제로 뻗어 있는 깊이의 수분을 함께 살핍니다.

시스템은 이 여러 겹의 데이터를 겹쳐 놓고 지금 밭에 물이 얼마나 남았는지를 그려 냅니다.

작물은 태어나서 죽을 때까지 같은 양의 물과 거름을 원하지 않습니다. 씨앗이 싹 트는 발아기에는 적은 물로도 충분하지만, 식물이 왕성하게 자라는 영양생장기에는 요구량이 가파르게 늘어납니다. 꽃이 피는 개화기에는 물이 모자라면 꽃이 떨어지고, 열매가 굵어지는 결실기에는 조금만 물이 부족해도 열매가 작아지거나 갈라집니다. 다 익어 가는 성숙기에는 오히려 물을 줄여야 당도가 오르는 작물도 있습니다. 연구자들은 이 변화를 발육지수(Development Volume Index, DVI, 작물이 자란 정도를 하나의 숫자로 나타낸 지수)로 표현합니다. 작물이 지금 자란 정도를 0에서 1 사이 숫자로 나타내고, 그 숫자를 단계별로 정해 둔 수분 스트레스 한계치와 비교하는 방식입니다. 질소와 인, 칼륨 같은 비료 성분도 같은 논리로 생육 단계마다 다른 농도와 양으로 투입되도록 계산됩니다.

시간표 하나로 일 년 내내 같은 양을 주던 방식과는 뿌리에서부터 다른 접근입니다.

이 모든 물리 데이터와 생육 데이터를 사람이 일일이 손으로 계산하기는 어렵습니다. 변수가 열 개, 스무 개로 늘어나면 어느 변수가 지금 상황에서 결정적인지 가늠하기 힘들어 집니다. 최근 몇 년 사이 온실과 노지 농장 곳곳에서 머신러닝 모델이 이 계산을 대신 맡기 시작했습니다. 센서가 실어 나르는 숫자와 기상청 예보 자료를 입력으로 받아, 지금 물을 줘야 하는지 말아야 하는지, 준다면 몇 리터를 줘야 하는지를 모델이 직접 판단합니다. 어떤 모델을 골라 쓰는지는 농장의 작물과 규모, 어떤 데이터를 얼마나 오래 모아 왔는지에 따라 달라집니다.

여러 모델 가운데 널리 쓰이는 것은 랜덤 포레스트(Random Forest)입니다. 이름 그대로 여러 그루의 의사결정나무를 심어 숲을 만든 다음, 나무마다 내린 판단을 투표에 부쳐 다수결로 결론을 내리는 방식입니다. 토양 수분과 기온, 습도, 강수량, 토양 유형, 작물 종류

처럼 서로 얽혀 있는 변수를 넣어도 흔들리지 않고 안정적인 결과를 냅니다. 인도의 한 연구팀이 웹 기반 플랫폼에 이 모델을 얹어 시험한 결과, 사용자가 밭 상태를 입력하면 관수가 필요한지 여부를 예 또는 아니오로 답하고, 필요하다면 대략 25리터라는 구체적인 물의 양까지 추정해 냈습니다(Ajay Kumar et al., 2026).

인도네시아에서는 겨자채와 상추를 기르는 텃밭에 NodeMCU 마이크로컨트롤러와 온도 센서, 실시간 시계 모듈을 달아 1,200건의 기록을 모으고, 같은 랜덤 포레스트 알고리즘으로 관수 밸브를 자동으로 여닫게 했습니다(Pradasari et al., 2026). 오버피팅, 그러니까 훈련 자료에만 맞고 실제 밭에서는 어긋나는 현상에 강하다는 점이 이 모델이 현장에서 자주 채택되는 이유로 보입니다.

비료의 양을 정하는 데는 의사결정나무(Decision Tree) 모델이 강점을 보입니다. 스리랑카 농업부 산하 원예연구개발원(HORDI)의 관행 지침을 바탕으로 만든 클라우드 플랫폼 에코그로우(EcoGrow)가 그 사례입니다. 작물 종류와 재배 지역, 토양 성상, 관수 간격, 기후 지대, 비료를 줄 시기를 입력하면, 요소(Urea)와 중과석(TSP), 염화加里(MOP) 세 비료를 헥타르당 몇 킬로그램씩 섞어야 하는지 숫자로 알려 줍니다. 서른두 개 원예 채소 작물에 걸친 1,535건의 기록으로 학습시킨 결과 정확도가 97.39퍼센트에 이르렀고, 이 수치 덕분에 실제 배포용 모델로 채택되었습니다. 에코그로우는 여기서 그치지 않고 가까운 비료 판매점을 찾아 주는 기능과, 시비 방법을 물어보면 답해 주는 인공지능 챗봇(자동으로 대화하듯 답하는 프로그램)까지 한 화면에 묶어 두었습니다.

농부가 숫자표를 직접 뒤적이지 않아도 화면이 알려 주는 배합대로 비료를 섞으면 됩니다.

선형 회귀(Linear Regression)와 심층신경망(DNN, Deep Neural Network의 줄임말로 여러 층을 쌓아 복잡한 패턴을 배우는 인공지능망)을 함께 쓰는 방식도 있습니다. 선형 회귀는 시간이 지나면서 흙 속 수분이 어떤 기율기로 줄어드는지 하나의 직선에 가깝게 그려 냅니다. 심층신경망은 여기에 사진 한 장을 더 얹습니다. 흙 사진을 충격토, 검은토, 점토, 적토 같은 종류로 나누는 합성곱 신경망(CNN, Convolutional Neural Network)의 판단과, 기상 자료와 질소·인·칼륨 농도 자료를 한데 모아 비료 처방을 내립니다. 흙의 생김새를 눈으로 구분하는 능력과 숫자로 된 데이터를 계산하는 능력을 한 모델 안에 합쳐 놓았습니다.

쌀농사에는 강화학습(Reinforcement Learning)이 쓰입니다. 강화학습은 어떤 행동을 했을 때 돌아오는 보상을 계속 관찰하면서, 시행착오를 거쳐 더 나은 행동을 스스로 찾아가는 학습 방식입니다. 기상 예보 자료를 입력받아 마르코프 의사결정과정(Markov Decision Process, 지금 상태만 보고 다음 행동을 정하는 수학적 틀)을 따라, 어느 시점에 물을 대는 편이 유리한지를 모델 스스로 학습합니다. 이 모델은 발육지수 추적과 건습교대관개(Alternate Wetting and Drying, AWD, 논에 물을 채웠다가 흙이 드러날 때까지

말리기를 되풀이하는 관개법)를 결합해, 벼가 이삭을 내는 시기처럼 물에 민감한 시기에는 물을 아끼면서도 정확히 필요한 만큼만 대 줍니다(Chen et al., 2021).

물을 계속 채워 두는 관행 벼농사와 달리, 말리고 채우기를 정교하게 반복하는 쪽이 오히려 벼에 이롭다는 결과로 읽힙니다.

이 모델들이 밭에서 실제로 돌아가는 절차는 비슷합니다. 센서에서 들어온 자료 가운데 빠진 값을 채우고, 숫자의 크기를 0과 1 사이로 맞추는 정규화를 거치고, 작물 종류나 토양 유형처럼 글자로 된 값은 숫자로 바꿉니다. 이렇게 다듬은 자료로 서버 바깥에서 미리 모델을 학습시킨 뒤, 학습이 끝난 모델만 클라우드 서버에 올려 둡니다. 현장 센서 노드는 1분에서 15분 간격으로 새 값을 서버에 보내고, 서버는 그 값을 받는 즉시 추론을 실행해 관수와 시비 여부를 판단합니다. 판단 결과는 사물인터넷 게이트웨이를 거쳐 릴레이 스위치를 움직이고, 실제로 흘러 나간 물의 양은 펄스 수량계(물이 지나갈 때마다 짧은 전기 신호를 하나씩 세는 계량기)로 다시 측정되어 데이터베이스에 기록됩니다. 예측하고 실행하고 그 결과를 다시 재는 이 순환이 끊이지 않고 돌아야 지능형 관수 체계가 성립합니다.

현장에 묻히는 센서 하나하나를 들여다보면 이 판단이 어디서 시작되는지 보입니다. 흙 속에는 정전용량식 또는 저항식 수분 센서(FC-28, YL-69 같은 모델)가 깊이별로 여러 개 묻힙니다. 겉흙의 물기와 뿌리가 뺀 깊이의 물기는 마르는 속도가 다르기 때문에, 한 곳만 재서는 실제 사정을 놓치기 쉽습니다. 온습도 센서 DS18B20과 실시간 시계 모듈 DS3231이 여기에 더해져, 몇 시 몇 분에 흙 온도가 몇 도였는지까지 기록에 남습니다.

양액 재배, 그러니까 흙 없이 물에 비료를 녹여 뿌리에 직접 공급하는 수경재배 농장에서는 다른 종류의 센서가 필요합니다. 물에 녹은 비료 소금기의 총량을 재는 전기전도도(Electrical Conductivity, EC) 센서와 물이 산성인지 알칼리성인지를 재는 수소이온농도(pH) 센서, 질소·인·칼륨 농도 센서, 총용존고형물(Total Dissolved Solids, TDS) 센서가 한 세트로 돌아갑니다. 전기전도도가 너무 높으면 뿌리 세포 속 물이 오히려 밖으로 빠져 나가는 삼투압 역전이 일어나 뿌리가 마른 것과 비슷한 피해를 입고, 너무 낮으면 양분이 모자랍니다. 산도가 작물마다 정해진 좁은 범위를 벗어나도 뿌리가 양분을 흡수하는 통로 자체가 막힙니다.

양액 재배 현장의 제어 프로그램은 전기전도도와 산도를 기준 삼아 물통에 원액 비료와 산성 용액을 얼마씩 더할지 계산하고, 값이 범위를 벗어나는 순간 자동으로 펌프를 돌려 바로잡습니다.

밭 안의 센서만으로는 부족합니다. 시스템은 40년 넘게 쌓인 과거 기상 데이터베이스와 토양 조사 자료, 3만 종이 넘는 작물 품종 정보, 7일 단위 기상 예보를 한꺼번에 끌어옵니다. WeatherAPI나 미국 항공우주국의 NASA POWER, 유엔식량농업기구의 FAO

CLIMWAT 같은 외부 서비스에서 기온과 강수 확률을 실시간으로 받아 와, 내일 비가 온다는 예보가 뜨면 오늘 밤 관수량을 미리 줄이는 식으로 대응합니다. 하늘에서는 무인항공기가 다중분광 카메라와 가시광선-근적외선(Vis-NIR) 분광 장비를 달고 발 위를 낮게 날며 작물 잎의 색과 반사광을 찍습니다. 사람 눈에는 아직 멀쩡해 보이는 잎이라도 질소나 칼륨, 마그네슘이 부족해지기 시작하면 특정 파장의 빛을 반사하는 정도가 먼저 달라지기 때문입니다.

진단시비추천체계(Diagnosis and Recommendation Integrated System, DRIS)라는 방법으로 이 반사광 자료를 분석하면, 눈에 보이는 증상이 나타나기 전에 어느 양분이 모자란지를 찾아낼 수 있습니다. 사과 과수원에 이 무인항공기 자료를 관비 모델로 이어 붙인 시험에서는, 잎을 뜯어 실험실로 보내지 않고도 하늘에서 질소 부족 여부를 미리 찾아낼 수 있었습니다(Sun et al., 2023).

밭에서 잔 숫자가 서버까지 가는 길도 여러 겹입니다. ESP32나 NodeMCU ESP8266, 아두이노(Arduino), PIC 같은 값싼 마이크로컨트롤러가 현장 노드에 앉아 센서 값을 읽습니다. 이 값은 와이파이나 산업 현장에서 흔히 쓰는 RS485 유선 버스, 넓은 지역을 낮은 전력으로 덮는 LPWAN, 4세대 이동통신 모듈, 그리고 짧은 메시지를 적은 전력으로 주고받는 MQTT 통신 규약을 거쳐 클라우드로 올라갑니다. 서버 쪽에는 파이어베이스(Firebase) 실시간 데이터베이스나 FastAPI, 플라스크(Flask) 같은 백엔드가 들어서고, 그 위에서 사이킷런(Scikit-learn), 판다스(Pandas), 넘파이(NumPy) 같은 라이브러리로 짠 머신러닝 코드가 돌아갑니다. 재배자는 이 모든 과정을 몰라도 됩니다. 웹이나 휴대전화 화면에 뜬 대시보드만 보면 되기 때문입니다.

인도 마하라슈트라의 한 플랫폼은 이 화면을 마라티어와 힌디어, 영어 세 언어로 띄워, 영어 설명을 읽기 어려운 농가에도 관수와 시비 조언이 가닿도록 했습니다(Shriwas et al., 2026).

클라우드에 도착한 판단은 다시 밭으로 내려와야 실제 효과를 냅니다. 서버가 관수를 결정하면 그 신호는 사물인터넷 게이트웨이를 거쳐 필드에 설치된 디지털 릴레이로 전달되고, 릴레이는 펌프를 켜거나 끄고 구역별 밸브를 여닫습니다. 물줄기의 굵기를 바꿀 수 있는 가변 노즐을 쓰면 같은 배관으로도 구역마다 다른 양을 내보낼 수 있습니다. 사람이 손으로 돌리던 수도꼭지를 이제는 전자 신호가 대신 여닫는 구조입니다. 그 신호는 흙 속 센서에서 시작해 클라우드를 한 바퀴 돌고 다시 흙으로 돌아오는 여정을 매번 되풀이합니다.

카메라를 더한 사례도 있습니다. ESP32 센서 단말과 ESP32-CAM 영상 센서, FastAPI 서버를 엮은 자율 적응형 관수 시스템은 온도와 습도, 토양 수분을 재는 데서 그치지 않고 카메라로 작물 상태를 함께 지켜봅니다(Ramya et al., 2026). 관수를 시작한 뒤에는 펄스 수량계가 파이프를 지나간 물의 부피를 실제로 세어, 그 숫자를 다시 서버로 돌려보냅니다. 명령을 내리고 끝나는 것이 아니라 명령이 실제로 얼마나 이행되었는지를 확인하는

닫힌 고리, 이른바 폐쇄루프(Closed-loop) 제어를 완성한 구조입니다. 조립 설명서대로 부품을 끼운 뒤 마지막에 나사가 실제로 조여졌는지 손으로 한 번 더 확인하는 것과 비슷한 절차입니다.

일본에서는 농기계 회사 구보타(Kubota)가 제로아그리(ZeroAgri)라는 이름으로 이 체계를 상품화했습니다. 온실 안 토양 센서 정보와 기상 예보 자료를 클라우드로 보내면 서버가 최적 관수량과 시비량을 계산해 자동으로 내보내는 방식입니다. 감귤을 멀칭 재배하는 과수원에서는 같은 토양 수분 시각화 기술을 반대 방향으로 씁니다. 물을 아끼기 위해서가 아니라, 일부러 적당한 정도로 흙을 말려 나무에 약한 스트레스를 주고 그렇게 해서 과실의 당도를 끌어올리는 데 씁니다. 물을 더 주는 기술과 덜 주는 기술이 같은 센서, 같은 클라우드 위에서 서로 다른 목적으로 돌아가고 있습니다.

이 체계가 제대로 작동하는지는 몇 가지 숫자로 확인합니다. 관수 여부나 비료 종류를 맞히는 분류 모델은 정확도, 정밀도, 재현율 같은 지표로 성적을 매기는데, 에코그로우가 낸 97.39퍼센트가 정확도 지표를 보여 주는 예입니다. 토양 수분처럼 연속된 숫자를 예측하는 모델은 평균절대오차(MAE)와 평균제곱근오차(RMSE)로 실측값과 예측값의 차이를 잽니다. 이 숫자들이 아무리 좋아도 농사에 실제로 도움이 되었는지는 다른 잣대로 다시 재야 합니다. 물 1세제곱미터로 얼마만큼의 작물을 길러 냈는지를 나타내는 용수생산성(Water Use Efficiency, WUE)과, 질소 비료 1킬로그램으로 작물이 얼마나 몸집을 불렸는지를 나타내는 질소이용효율(Nitrogen Use Efficiency, NUE)이 그것입니다.

물과 비료를 실제로 얼마나 아꼈는지가 인공지능 모델의 정확도보다 이 기술의 값어치를 매기는 잣대에 더 가깝습니다.

뿌리 바로 앞에 정해진 양만 주는 방식을 관비(Fertigation, 물을 줄 때 비료를 함께 녹여 뿌리 앞으로 보내는 방식)라고 부릅니다. 물을 대는 관수와 거름을 주는 시비를 하나로 합친 말입니다. 흙 전체에 비료를 뿌리고 물을 대는 관행 방식과 달리, 관비는 점적관을 통해 뿌리가 실제로 뻗어 있는 좁은 구역에만 비료가 녹은 물을 흘려보냅니다. 이탈리아에서 흙 없이 키우는 딸기를 대상으로 한 시험에서는 센서 기반 관비 관리가 자원 이용과 작물 상태를 함께 끌어올린 것으로 나타났습니다(Bonelli et al., 2024). 중국 동북부의 밭 시험에서도 점적관수와 시비 기술을 결합했을 때 양분과 물 모두의 이용 효율이 오른 것으로 보고되었습니다(Fan et al., 2020).

밭 전체에 물을 대면 비료도 그만큼 넓게 흩어지고, 뿌리가 닿지 않는 흙속 깊은 곳으로 새어 나간 질소는 그대로 손실입니다. 좁은 구역에 정확히 주는 방식이 이 손실을 원천에서 막는 구조입니다.

잎을 뜯지 않고 양분 상태를 알아내려는 시도는 무인항공기 사진에서 그치지 않습니다. 보호지 재배, 그러니까 비닐하우스나 유리온실처럼 지붕을 덮은 시설에서 토마토를 물 절

약형으로 재배하는 시험에서는, 가시광선과 근적외선을 함께 쓰는 초분광 촬영 장비로 잎의 질소 함량을 손상 없이 추정하는 방법이 시도되었습니다(Hu et al., 2025). 물을 아끼는 관수 방식과 잎의 질소 상태를 함께 살피면, 물 부족과 양분 부족이 겹쳐 나타나는 시점을 더 일찍 가려낼 수 있습니다. 잎을 따서 실험실 분석기에 넣던 기존 방식은 시간이걸리고 그사이 작물은 이미 다음 단계로 넘어가 버립니다. 카메라로 잎을 비추기만 해도 질소 상태를 짐작할 수 있다면, 관수와 시비 결정을 하루 이틀 미루지 않고 곧바로 내릴 수 있습니다.

값비싼 서버를 갖추기 어려운 소규모 농가를 위한 흐름도 있습니다. 저비용·저전력 엣지 인공지능과 TinyML(아주 작은 마이크로컨트롤러 위에서도 돌아가도록 가볍게 줄인 인공지능 모델)을 자원이 부족한 농장에 심는 연구가 정리되고 있습니다. 클라우드 서버까지 매번 데이터를 보내고 답을 받아 오는 대신, 밭에 놓인 작은 기기 안에서 곧바로 판단을 끝내는 방식입니다. 통신이 끊기기 쉬운 오지나 인터넷 요금이 부담스러운 농가일수록 이런 현장 완결형 인공지능이 힘을 발휘합니다. 사물인터넷 기기와 머신러닝을 결합한 스마트 관수 시스템을 다룬 연구에서도, 값싼 센서와 마이크로컨트롤러만으로 관수 자동화를 구현할 수 있다는 점이 거듭 확인됩니다(Kathilkar et al., 2026). 장비 값은 이미 많이 내려갔고, 남은 숙제는 그 장비를 다룰 줄 아는 사람을 얼마나 늘리느냐에 가까워 보입니다.

현장에 오래 심어 둔 센서는 시간이 지나면서 성능이 흔들립니다. 비료를 자주 준 흙일수록 염분 농도가 올라가고, 습기와 미생물 막이 센서 표면에 들러붙으면서 수분 센서와 전기전도도 센서의 감도가 서서히 떨어집니다. 처음 설치했을 때는 정확했던 값이 몇 달 뒤에는 실제보다 낮거나 높게 나오는 드리프트(Drift, 시간이 지나며 측정값이 원래 기준에서 조금씩 어긋나는 현상) 현상입니다. 드리프트를 알아채지 못한 채 몇 주가 지나면, 시스템은 이미 충분히 젖은 흙에 계속 물을 더 대라고 명령할 수 있습니다. 이를 막으려고 소프트웨어로 센서 값을 스스로 다시 맞추는 자가보정 가상 센서 기술과, 부식에 강한 나노 소재로 만든 센서를 개발하는 연구가 진행되고 있습니다. 흙에 오래 담가 둘수록 흐려지는 유리창을, 주기적으로 닦는 대신 아예 흐려지지 않는 재질로 바꾸려는 시도에 가깝습니다.

센서 하나가 대표할 수 있는 땅은 생각보다 좁습니다. 넓은 노지 밭이나 큰 온실에서는 흙의 성질과 경사, 작물 잎이 우거진 정도가 구역마다 달라서, 같은 시각에도 어느 구역은 젖어 있고 다른 구역은 말라 있습니다. 점 하나짜리 센서 값만 믿고 밭 전체에 같은 양을 대면, 이미 젖은 구역은 더 젖고 마른 구역은 계속 마릅니다. 온실 한 동 안에서도 출입구에 가까운 줄과 안쪽 줄의 햇빛과 바람이 다르므로, 같은 온실이라는 이유로 센서 한 개만 믿고 안심할 수는 없습니다. 그래서 무인항공기로 찍은 다중분광 영상과 공간 보간법을 지상 센서 자료와 실시간으로 합치는 다중 규모 융합 기술이 다음 단계 과제로 꼽힙니다.

장비 값이 내려갔다고 해서 도입이 저절로 쉬워지지는 않습니다. ESP32 같은 부품 자체는 값이 많이 낮아졌지만, 이 부품들을 엮어 자기 농장에 맞게 모델을 다시 조율하는 일에는 여전히 손이 많이 갑니다. 농사짓던 방식과 전혀 다른 화면과 숫자를 새로 익혀야 하는 부담이 실제 도입을 가로막는 벽으로 작동합니다. 이 벽을 낮추려고 직관적인 모바일 화면과 인공지능 챗봇, 여러 언어로 말해 주는 음성 안내를 함께 엮는 시도가 이어지고 있습니다. 기계를 사는 값보다 기계와 친해지는 값이 훨씬 크게 남아 있습니다.

미리 모아 둔 자료로만 학습한 모델은 한번도 겪어 보지 못한 상황 앞에서 흔들립니다. 예년에 없던 폭염이나 갑작스러운 가뭄이 닥치면, 과거 자료로 굳어진 모델은 엉뚱한 답을 내놓을 위험이 있습니다. 이를 보완하려고 현장에서 들어오는 자료를 계속 흡수하며 스스로 갱신하는 온라인 적응형 학습 방식이 연구되고 있습니다. 여기에 DSSAT나 AquaCrop처럼 작물의 생리 반응을 통째로 흉내 내는 생체 동적 모델을 결합하면, 물을 아끼는 목표와 수확량을 지키는 목표를 동시에 만족시키는 다목적 최적화가 가능해집니다. 센서와 인공지능이 아무리 정교해져도, 겨루어야 할 상대는 매번 다른 얼굴로 찾아오는 날씨인 것입니다.

여러 목표를 동시에 만족시키는 계산은 이론에서 그치지 않고 실제 재배지의 시험 구획에서 먼저 검증됩니다. 온실 한 구획에는 기존 방식대로 물을 주고 옆 구획에는 인공지능이 계산한 양만 주는 식으로 나란히 돌려, 두 구획의 수확량과 물 사용량을 나중에 견주는 대조 시험이 여러 연구에서 반복됩니다. 이런 대조 시험이 쌓여야 비로소 특정 조건에서만 나온 상한선 수치와 대부분의 농장에서 기대할 수 있는 평균적인 절감폭을 구분할 수 있습니다. 네브래스카의 사례처럼 숫자로 정직하게 확인하는 절차 없이는, 어떤 새 기술도 농가의 신뢰를 얻기 어렵습니다.

토양 연속체를 가로지르는 물리량 측정과 생육 단계별 모델링, 여러 머신러닝 모델의 추론과 클라우드의 판단이 쌓여 밸브를 여닫는 명령 하나로 이어집니다. 물과 비료를 아끼는 판단은 흙 속 센서 하나하나가 보내는 숫자와 그 숫자를 읽는 코드가 맡고 있습니다. 재배자는 지난밤 몇 시에 몇 리터가 나갔는지를 다음 날 아침 휴대전화 화면에서 확인하고, 그래프가 이상하게 튼 구간이 있을 때만 장화를 신고 밭으로 나갑니다. 재배자의 역할은 매번의 관수 결정에서 시스템의 판단을 사후에 점검하는 일로 좁혀졌습니다.

근거 및 참고문헌

학술 논문

1. Ajay Kumar, C. V. R., Supriya, L., Navya Sree, P., & Santosh Kumar, M. (2026). Adaptive machine learning framework for precision driven smart irrigation optimization. World Journal of Advanced Research and Reviews, 30(1), 421-428. <https://doi.org/10.30574/wjarr.2026.30.1.0841>

2. Bonelli, L., Montesano, F. F., D'Imperio, M., Gonnella, M., Boari, A., Leoni, B., & Serio, F. (2024). Sensor-based fertigation management enhances resource utilization and crop performance in soilless strawberry cultivation. *Agronomy*, 14(3), 465. <https://doi.org/10.3390/agronomy14030465>
3. Chen, M., Cui, Y., Wang, X., Xie, H., Liu, F., Luo, T., Zheng, S., & Luo, Y. (2021). A reinforcement learning approach to irrigation decision-making for rice using weather forecasts. *Agricultural Water Management*, 250, 106838. <https://doi.org/10.1016/j.agwat.2021.106838>
4. EcoGrow Development Team, & Sri Lanka HORDI. (2026). EcoGrow: Cloud-enabled machine learning driven fertilizer recommendation platform for horticultural vegetable crops in Sri Lanka. *International Journal of Advanced Networking and Applications*, 17(6), 7236-7243. <https://doi.org/10.35444/IJANA.2026.17607>
5. Fan, J., Lu, X., Gu, S., & Guo, X. (2020). Improving nutrient and water use efficiencies using water-drip irrigation and fertilization technology in Northeast China. *Agricultural Water Management*, 241, 106352. <https://doi.org/10.1016/j.agwat.2020.106352>
6. Hu, C., Zhao, T., Duan, Y., Zhang, Y., Wang, X., Li, J., & Zhang, G. (2025). Visible-near infrared hyperspectral imaging for non-destructive estimation of leaf nitrogen content under water-saving irrigation in protected tomato cultivation. *Frontiers in Plant Science*, 16, 1676457. <https://doi.org/10.3389/fpls.2025.1676457>
7. Kathilkar, S., Chavan, A., Sahu, K., Phalke, D., & Shedbale, S. (2026). Smart irrigation system using IoT device and machine learning. *International Journal for Research in Applied Science & Engineering Technology*, 14(5), 83111. <https://doi.org/10.22214/ijraset.2026.83111>
8. Li, H., Mei, X., Wang, J., Huang, F., Hao, W., & Li, B. (2021). Drip fertigation significantly increased crop yield, water productivity, and nitrogen use efficiency compared with traditional irrigation and fertilization practices: A meta-analysis in China. *Agricultural Water Management*, 244, 106534. <https://doi.org/10.1016/j.agwat.2020.106534>
9. Pradasari, N. I., Wahyudi, E., Atimi, R. L., Muhammad, A., Darmanto, & Pratiwi, I. (2026). IoT and machine learning-based smart watering model for water optimization in vegetable gardens. *Zetroem*, 8(2), 140-147.
10. Ramya, S. Y., Aravinda, T. V., Krishnareddy, K. R., & Ramesh, B. E. (2026). AI-driven self-adaptive smart irrigation system using IoT, computer vision and machine learning. *International Research Journal on Advanced Engineering Hub*, 4(6), 4074-4080. <https://doi.org/10.47392/IRJAEH.2026.0526>
11. Shriwas, M. K., Sindhi, K., & Thakre, P. (2026). Deep learning-based multilingual smart farming system for crop recommendation and nutrient monitoring. *African Journal of Applied Research*, 12(5), 260-280.
12. Sun, G., Hu, T., Chen, S., Sun, J., Zhang, J., Ye, R., & Liu, J. (2023). Using UAV-based multispectral remote sensing imagery combined with DRIS method to diagnose leaf nitrogen nutrition status in a fertigated apple orchard. *Precision Agriculture*, 24(6), 2522-2548. <https://doi.org/10.1007/s11119-023-10051-7>

강연 및 영상 자료

1. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026 Global AgriFood Innovation Roadshow: China Agricultural University Special Session [Video]. YouTube. <https://www.youtube.com/watch?v=SS2qVDa11nw>
2. 農業農村情報通信環境整備準備会. (2025). 気候変動と農業の未来: ICT・IoT活用によるデータ駆動型農業の重要性 [온라인 세미나 영상]. YouTube. <https://www.youtube.com/watch?v=iqLmEFT1wZo>
3. 農林水産省(MAFF). (2025). 中国四国地域スマート農業推進フォーラム2025 [Video]. YouTube. <https://www.youtube.com/watch?v=16rooPtFOMM>
4. Agricultural, Life & Environmental Sciences. (2026). Bentley Lecture in Sustainable Agriculture (2025) | AI, Machine Learning and the future of soils. YouTube. <https://www.youtube.com/watch?v=ct0VrqKTmVU>
5. Daugherty Water for Food Global Institute. (2025). Artificial Intelligence for Climate Smart Solution and Resilient Agriculture. (Archive). YouTube. <https://www.youtube.com/watch?v=n1MYEcAeMRU>

6. Global Soil Biodiversity Initiative. (2025). Harnessing AI to measure soil biodiversity. YouTube. <https://www.youtube.com/watch?v=AT29crluxow>
7. 気象ビジネス推進コンソーシアムWXBC. (2026). 2025年度 農研機構メッシュ農業気象データ分析チャレンジ! . YouTube. <https://www.youtube.com/watch?v=w1SrS3iwA4E>

보고서 및 뉴스

1. The Fence Post. (2026). 2026 Spring Homeland: Where artificial intelligence meets water stewardship in agriculture. <https://www.thefencepost.com/news/2026-spring-homeland-where-artificial-intelligence-meets-water-stewardship-in-agriculture/>
2. ScienceDirect. (2025). [인공지능 관수 스케줄링과 네브래스카 현장 비교 연구 관련 자료]. <https://www.sciencedirect.com/science/article/pii/S2772375525002151>
3. arXiv. (2026). [저비용·저전력 엣지 인공지능과 TinyML의 농업 현장 배치 동향 관련 자료]. <https://arxiv.org/pdf/2603.15085>

4.2

시공간 데이터 융합 및 유통·품질 관리

새벽 네 시, 남쪽 지방의 한 농산물 물류센터 하역장에 냉장 트럭 한 대가 들어섭니다. 팔레트 위에 쌓인 딸기 상자마다 손톱만 한 전자 기록계가 하나씩 붙어 있는데, 트럭 문이 열리는 순간 그 기록계의 숫자판이 영하에 가까운 값에서 십 도 가까이로 튀어 오르고, 몇 분 뒤 문이 닫히면 다시 천천히 내려갑니다. 이 짧은 온도 요동 하나하나가 딸기의 남은 유통기한을 깎아 먹는 실제 원인입니다. 이 상자가 밭에서 뽑혀 나온 순간부터 소비자의 냉장고에 들어가기까지, 온도와 습도와 기체 농도를 재는 센서들이 구간마다 바뀌면서 데이터를 주고받습니다.

문제는 위성과 드론, 지상 센서가 서로 다른 주기로 자료를 모은다는 데 있습니다. 인공위성은 나흘에서 열흘에 한 번 같은 궤도로 돌아오며 수백 헥타르를 한눈에 훑습니다. 드론은 사람이 띄우기로 마음먹은 날에만, 그러나 손바닥만 한 구역까지 촘촘하게 찍습니다. 밭과 온실에 박아 둔 지상 센서는 몇 초 간격으로 쉬지 않고 숫자를 토해 냅니다. 세 기기가 남긴 기록을 겹쳐 놓으면 시간과 공간의 눈금이 제각각이라 하나의 그림으로 읽히지 않습니다. 바로 이 눈금 차이 때문에 정밀 농업의 수확량 예측과 재해 예찰이 자주 빗나갑니다.

이 눈금을 맞추는 작업을 업계에서는 기후 대응 정밀 농업, 영어 약자로 CSA(Climate-Smart Agriculture) 데이터 파이프라인이라고 부릅니다. 위성의 광학·다중분광 영상과 드론의 고해상도 영상, 지상 센서의 실시간 수치를 같은 좌표와 같은 시간대로 옮겨 붙이는 공간·시간 정렬 작업을 거친 뒤, 하이브리드 딥러닝과 그래프 신경망(GNN, 밭 하나를 점으로, 인접한 밭과의 관계를 선으로 이은 그물 구조로 학습하는 인공 신경망)을 얹어 하나의 흐름으로 합칩니다. 이렇게 합쳐진 데이터는 가뭄 스트레스나 병해충이 퍼질 구역을 미리 가려내고, 그해 날씨 시나리오에 맞춰 파종과 수확의 적기, 예상 수확량까지 미리 계산해 냅니다.

실제로 쓰이는 모델 이름을 몇 가지 꼽아 보면 이 그물이 어떻게 짜이는지 감이 잡힙니다. AMSTF(적응형 다중스펙트럼·시공간 융합 모델)와 GNN을 장기기억 신경망(LSTM)에 결합한 하이브리드 모델은 위성과 드론이 시간차를 두고 찍은 다중분광 영상과 지상의 기상·토양 시계열을 한데 묶어 작물의 시공간 생육 변화와 최종 수확량을 정밀하게 추정합니다. XGBoost와 CatBoost, LSTM 세 알고리즘을 이어 붙인 융합 모델은 기온과 강수량,

습도 같은 기상 변수와 농약 투입량, 식생 지수(NDVI)의 시계열을 재료 삼아 수확량을 회귀 방식으로 예측합니다.

비전 트랜스포머(ViT)를 쓴 또 다른 파이프라인은 위성과 드론, 지상 센서, 작업자의 스마트폰 카메라까지 이미지를 잘게 쪼갠 패치로 바꾼 뒤 서로 얼마나 관련 있는지 스스로 견주어 보는 자가 주의 방식으로 학습해, 밭 단위의 생육 진단 지도와 기후 대응 처방을 내놓습니다. 이런 모델을 시험하는 과정에서는 실측값과 예측값이 얼마나 들어맞는지를 나타내는 결정계수가 0.85에서 0.95 사이로 나오는 경우가 흔하고, 작물의 경계면을 서로 다른 구역으로 잘못 나누는 공간 오분류율은 9.8퍼센트에서 12.3퍼센트 수준이던 것이 5.4퍼센트까지 줄었다는 보고도 있습니다. 이 숫자 이면에는 서로 다른 눈금을 가진 세 종류의 센서 값을 하나로 맞추는 고단한 정렬 작업이 깔려 있습니다.

자가 주의라는 말이 낯설게 들릴 수 있는데, 교실 조별 과제에 빗대면 쉽게 다가옵니다. 학생 한 명 한 명이 다른 학생들의 발언을 얼마나 귀담아들을지 판단하면서 자기 의견을 조금씩 고쳐 나가는 과정과 비슷합니다. 위성 영상의 한 구역은 드론 영상의 다른 구역, 그리고 지상 센서의 수치와 서로 얼마나 관련 있는지를 모델 스스로 따져 가며 가중치를 매기고, 그 가중치를 반영해 최종 판단을 내놓습니다. 사람이 미리 정해 둔 규칙을 따르는 대신 데이터 스스로 무엇을 더 눈여겨봐야 할지 배운다는 점에서 기존 통계 모델과 다릅니다.

이렇게 겹쳐진 지도가 실제로 어떻게 쓰이는지는 화면 한 장을 상상하면 이해하기 쉽습니다. 농장 관리자의 태블릿에는 밭 전체가 초록과 노랑, 빨강으로 얼룩덜룩하게 칠해진 지도가 뜨는데, 빨간 구역은 위성이 잡아낸 수분 스트레스가 드론의 근접 촬영에서도 잎이 말리는 징후로 재확인된 곳입니다. 지상 센서가 그 구역의 토양 수분이 실제로 기준치 아래로 떨어졌다고 뒷받침해 주면, 모델은 사흘 안에 그 구역부터 병해충이 번질 가능성이 크다고 경고를 띄웁니다. 이 경고 하나를 만들기 위해 위성과 드론과 지상 센서 세 겹의 증언이 겹쳐져야 했다는 점이 정밀 농업 데이터 파이프라인의 실체에 가깝습니다.

이 파이프라인은 위성과 드론, 지상 센서라는 세 기기의 물리적 장비 위에서 실제로 움직입니다. 위성 쪽에서는 센티널-2(Sentinel-2)나 랜드샷(Landsat) 같은 다중분광 위성이 1,000헥타르가 넘는 논밭을 한 번에 훑으며 식생 지수(NDVI, GNDVI, SAVI)와 토양 수분 분포를 꾸준히 뽑아냅니다. 이 정도 면적을 드론 비용의 대략 20퍼센트만으로 감시할 수 있다는 점이 위성 센서의 강점입니다. 반대로 드론은 좁은 구역을 훨씬 촘촘하게 봅니다. 화소 하나가 땅 위 5센티미터 아래를 담는 해상도로 근적외선과 레드에지 대역, 때로는 초분광 영상까지 찍어, 밭 안에서도 유독 시들어 보이는 구역이나 잡초가 번진 구역, 작물 잎의 생김새 차이를 지도 한 장에 옮겨 담습니다.

이렇게 만들어진 지도를 처방 지도(Prescription Map)라고 부르는데, 밭 전체에 같은 양을 뿌리던 관행과 달리 필요한 곳에만 필요한 만큼 손을 대라고 알려 주는 지도입니다.

지상에서는 온실과 노지 곳곳에 박힌 센서가 온도와 습도, 이산화탄소 농도, 토양 수분과 전기전도도(EC), 산도(pH), 빛의 양을 실시간으로 잽니다. 여기에 40년 치 과거 기상 기록과 일주일 단위 예보, 격자 형태로 촘촘하게 나뉜 농업기상 데이터, 토양 조사 자료, 3만 종이 넘는 작물 품종 데이터베이스가 클라우드 파이프라인을 거쳐 한데 모입니다. 밭 하나 하나의 숫자만 보던 시절과 비교하면, 이제는 전국 단위의 기상 지도와 품종별 특성표를 동시에 펼쳐 놓고 그 밭의 위치를 확인합니다. 농기계에도 손이 갔습니다. 차나무를 다듬는 관리기 같은 특수 농기계엔 PLC(기계 제어용 소형 컴퓨터)와 GPS, 자동 조향 센서를 달아 가동 시간과 이동 거리, 주행 속도, 작업 높이와 폭을 자동으로 클라우드에 올리는 사례가 일본에서 보고되었습니다.

가와사키기연과 오치아이칼날, 데라다제작소가 함께 참여한 이 차밭 관리 사례에서는 누적된 운행 기록을 바탕으로 농가별 작업 특성과 밭 조건의 차이를 그림으로 그려 낼 수 있었습니다. 위성과 드론이 하늘에서 내려다본다면, 이 기계 기록은 땅바닥에 남긴 밭자국을 그대로 옮긴 것과 같아서, 나중에 유통 이력을 되짚을 때도 요긴한 재료가 됩니다.

이렇게 성격이 다른 데이터를 한곳에 모으고 나면 손질이 필요합니다. 위성 사진에 구름이 끼서 생긴 빈틈, 센서가 잠깐 먹통이 되며 남긴 결측치는 적응형 칼만 필터라는 통계 기법으로 메우고 잡음을 걸러 냅니다. 이후 값의 범위를 0과 1 사이로 맞추는 정규화를 거치고, 학습 데이터가 한쪽으로 치우치지 않도록 이미지를 돌리거나 뒤집는 방식으로 표본을 불러 주는 증강 작업까지 마쳐야 비로소 모델에 넣을 준비가 끝납니다. 밭에서 자라는 동안의 이야기는 여기까지입니다. 작물이 뻗히고 상자에 담기는 순간부터는 같은 논리가 다른 대상에 적용됩니다. 이제부터는 생육 대신 부패를 재고, 식생 지수 대신 온도와 에틸렌 가스를 쫓는다는 점이 다를 뿐, 서로 다른 기기의 눈금을 하나로 모아 판단을 내린다는 점은 그대로입니다.

딸기 상자에 붙은 기록계 하나는 온도만 잽니다. 그러나 상용화된 콜드체인 관리 상자에는 온도계 말고도 습도계, 이산화탄소 센서, 에틸렌 가스 센서, 그리고 색이 변하며 신선도를 알려 주는 소수성 표시 라벨까지 함께 붙는 경우가 늘고 있습니다. 과육을 자르지 않고 당도와 산도를 알아보는 근적외선 분광계와 표면 흠집을 입체로 잡아내는 3차원 비전 카메라도 이 대열에 합류합니다. 이 장비들의 공통점은 겉을 전혀 건드리지 않는다는 데 있습니다. 상자를 열어 보지 않고도 트럭 안 딸기 한 판의 당도와 흠집, 신선도를 읽어 냅니다.

이 여러 장비가 쏟아내는 신호를 하나의 판단으로 묶는 대표적인 모델이 협동 주의 합성곱 순환망, 줄여서 Co-ACRN입니다. 중국 장난대학 연구진이 2026년에 보고한 이 모델은 콜드체인 운송 중에 쌓이는 온도와 습도, 이산화탄소, 에틸렌 시계열 자료와 소수성 표시 라벨을 찍은 영상을 동시에 받아들입니다. 앞단의 협동 주의 장치는 영상과 센서 흐름의 시간축을 서로 맞추고, 뒷단의 자가 주의 장치는 그렇게 맞춰진 정보를 다시 훑어보며

전체 맥락을 반영해, 과일과 채소의 신선도 점수를 실시간으로, 그것도 겉을 전혀 훼손하지 않고 뽑아냅니다. 신선도 점수를 매기는 공식은 간단합니다. 표면 전체 넓이 가운데 흠집 난 면적이 차지하는 비율을 백에서 뺀 값입니다. 흠집이 없으면 백점에 가깝고, 절반 이상했으면 오십 점 안팎으로 떨어지는 식입니다.

이런 다중센서 융합은 장난대학의 사례 하나에 그치지 않습니다. 온도와 상대습도, 에틸렌, 이산화탄소, 상자가 받은 진동, 위치 정보, 영상 특징, 분광 신호까지 한꺼번에 집어넣는 방식이 저장수명 예측 모형의 공통된 방식으로 정착하고 있습니다. 업계에서 나온 평가를 들여다보면, 컴퓨터 비전을 이용한 등급 판정과 사물인터넷 기반 저온유통 감시, 저장수명 예측 세 가지가 당장 현장에 들여놓을 수 있는 초기 도입 대상으로 자주 꼽힙니다. 카메라와 센서를 새로 다는 일은 기존 물류 설비를 그대로 두고 위에 얹으면 되지만, 재배 방식 자체를 바꾸는 일은 시간이 훨씬 오래 걸립니다. 이론은 화려해도 배관과 냉동고, 트럭이라는 낡은 하드웨어 위에 얹어야 하는 기술이라, 손대기 쉬운 곳부터 순서가 매겨지는 흐름으로 읽힙니다.

미국의 콜드체인 장비업체 델타트랙은 이런 예측형 저장수명 분석이 콜드체인 신선도 관리의 방식 자체를 바꾸고 있다고 소개했습니다. 이런 예측형 저장수명 분석은 흔히 냉동 컨테이너의 센서 값을 실시간으로 모아, 각 상자가 매장 진열대에 오르기까지 남은 시간을 화주와 소매점에 미리 알려 주는 방식으로 작동합니다. 대추야자처럼 겉모습만으로는 속을 가늠하기 어려운 과일에는 다른 접근이 쓰입니다. 여러 채널의 가스 센서로 과육이 익어 가며 내뿜는 냄새 분자의 조합을 읽고, 이 값을 기계학습 모형에 먹여 저장수명을 추정하는 연구가 보고되었습니다. 잘 익은 과일과 상한 과일은 냄새 분자의 조합이 다른데, 기계는 이 차이를 가스 센서의 전기 신호 패턴으로 읽어 냅니다.

등급을 매기는 일로 눈을 옮기면 또 다른 조합이 나옵니다. 일본 니가타현의 서양배 브랜드 르렉티에는 GCBLOCK을 결합한 Mask R-CNN이라는 영상 분할 모델로 배 표면의 흠집과 오염 부위를 픽셀 단위로 오려 냅니다. 오려 낸 오염 면적의 비율은 곧바로 등급으로 바뀌지 않고, 퍼지 논리라는 방식을 한 번 거칩니다. 퍼지 논리는 덩다와 찹다처럼 딱 잘라 나누기 어려운 경계를 다루는 계산법입니다. 오염 면적이 3퍼센트면 확실히 좋은 등급, 30퍼센트면 확실히 나쁜 등급이라고 쉽게 가르치지만, 그 사이의 애매한 값은 사람 검수원의 눈짐작과 비슷하게 여러 등급에 걸쳐 확률을 나누어 놓고 판단합니다. 이렇게 나온 값을 전문가의 경험 규칙을 담은 퍼지 추론 시스템에 넣어 최종 등급을 자동으로 매깁니다.

최종 등급은 빨간 도장이 찍히는 최상급 아카슈부터 그보다 한 단계 아래인 아오슈, 무난한 수준의 료, 상품으로 내놓기 어려운 무인까지 네 단계로 나뉩니다. 사람이 하루 종일 배를 하나하나 뒤집어 보며 도장을 찍던 일을 카메라와 퍼지 규칙이 대신 맡았습니다. 과일마다 사정이 다르므로 모델도 하나로 통일되지는 않습니다. 망고와 토마토, 키위처럼 껍질 두께와 색, 무르는 속도가 저마다 다른 과일에는 덴스넷과 이피션트넷 계열 모델이

붙어 겉모양과 속 익음 정도를 함께 등급화합니다. 배는 표면 흠집이 등급을 가르는 잣대이지만, 토마토는 색깔이, 키위는 단단한 정도가 더 중요한 잣대가 되는 식으로 과일마다 기준 자체가 달라지기 때문입니다.

이런 판정 모델을 시험한 결과를 보면 숫자가 꽤 후한 편입니다. 정확도와 정밀도, 재현율, F1 점수 같은 분류 성능 지표가 95퍼센트에서 99퍼센트 사이로 나오는 경우가 많고, 흠집 영역을 얼마나 정교하게 오려 내는지를 보는 mAP와 IoU 지표도 함께 보고됩니다. mAP는 모델이 찾아낸 흠집 위치가 실제 흠집 위치와 얼마나 겹치는지를 여러 기준에서 평균 낸 값이고, IoU는 두 영역이 겹치는 넓이를 두 영역을 합친 넓이로 나눈 값이어서 1에 가까울수록 정교하게 오려 낸 것입니다. 사람이 하던 눈대중 선별과 기계가 매기는 점수 사이의 차이는, 이제 숫자로 따져도 기계 쪽이 밀리지 않는 수준에 이르렀다고 판단할 만합니다.

이 변화가 뜻하는 바는 인력을 줄이는 일에서 그치지 않는 것으로 보입니다. 사람 검수원은 아침과 오후의 집중력이 다르고, 손에 익은 습관에 따라 같은 배도 날마다 조금씩 다르게 매길 수 있습니다. 카메라와 퍼지 규칙은 피곤함을 모르고 똑같은 잣대를 하루 내내, 계절 내내 유지합니다. 다만 사람의 눈이 오랜 경험으로 잡아내는 미묘한 위화감, 이를테면 겉은 멀쩡한데 속이 물려 있을 듯한 김새를 기계가 온전히 따라잡았는지는 아직 더 지켜볼 문제로 남아 있습니다.

등급이 매겨진 농산물은 곧바로 재고와 이력 관리 단계로 들어갑니다. 발이나 온실에서 뽑혀 나온 농산물은 바구니나 철제 랙 단위로 묶여 바코드와 QR코드, 스마트 태그를 하나씩 받습니다. 대만 가오슝의 스마트 농업 사업이 대표적인 사례입니다. 이 사업에서는 파란 플라스틱 바구니나 철제 랙에 붙은 태그로 발 단위 배치 재고를 실시간으로 데이터베이스에 올리고, 온실 환경 정보와 정부의 농산물 생산·유통 이력제를 자동으로 연동합니다. 다단으로 쌓은 재배대와 물류창고의 공간 이용률을 끌어올리는 효과도 함께 보고되었습니다. 태그 하나하나가 상자의 출처와 이동 경로를 확인하는 역할을 합니다.

이 추적 기능은 사고가 났을 때 쓸모가 있습니다. 대만국제협력개발기금회가 2025년에 소개한 사례를 보면, 농장의 생산 데이터와 식자재 공급업체의 데이터를 하나의 상권도 플랫폼으로 이어 붙였습니다. 어느 학교 급식에서 식자재 안전 문제가 생기면, 그 도시락에 들어간 농산물이 어느 농장 누구의 밭에서 왔는지를 즉시 되짚습니다. 여기서 그치지 않고 같은 농장에서 물건을 받은 다른 학교들까지 한꺼번에 찾아내 미리 손을 쓸 수 있게 합니다. 사고가 난 뒤 원인을 찾는 방식에서, 사고가 퍼지기 전에 관련 범위를 먼저 확인하는 방식으로 바뀐 것입니다.

농산물의 배치 번호를 찍으면 그 상자가 어느 밭에서 언제 뽑혀 어느 트럭과 물류창고를 거쳐 왔는지가 화면에 그대로 뜹니다. 다만 잘못 유통된 책이나 공산품은 회수하면 되지만, 상한 농산물은 이미 밥상에 오른 뒤에는 되돌릴 수 없습니다. 그래서 이력 추적 시스

템의 가치는 사고가 난 다음의 뒷수습보다, 사고가 퍼지기 전에 좁은 범위에서 막아 내는 속도에서 갈립니다.

저장수명 예측값 하나만 따로 떼어 놓으면 반쪽짜리 정보에 머무릅니다. 최근에는 저장수명 예측과 미국 식품안전현대화법이 요구하는 이력 추적, 탄소 배출량 회계까지 하나의 데이터 기반 위에 얹어 생산자와 화주, 소매점이 같은 화면을 들여다보게 만드는 모듈형 체계가 나오고 있습니다. 여러 시스템에 따로 접속하던 방식이 하나의 데이터 기반에 접속하는 방식으로 바뀌었습니다. 2018년 무렵 예측 분석 중심이던 수확 후 관리 기술은 이후 블록체인과 디지털 트윈 쪽으로 무게를 옮겨 왔고, 전력이나 통신 사정이 넉넉지 않은 현장에서는 경량화된 인공지능인 TinyML이 이력 추적과 정보 공개를 거들고 있습니다. 저장수명과 이력, 탄소 배출량을 한 화면에서 같이 보게 되면서, 신선도가 떨어질 위험과 이력 추적의 공백이 같은 상자, 같은 순간에 함께 드러나는 경우가 많아졌다고 판단됩니다.

물류창고에서는 YOLOv5나 YOLOv8 같은 딥러닝 물체 탐지 모델이 드나드는 상자를 실시간으로 세고, 이 결과를 디지털 트윈, 그러니까 물류창고를 통째로 복제한 가상 모형과 연결합니다. 관리자는 사무실 모니터 앞에 앉아서도 어느 랙에 무엇이 얼마나 쌓여 있는지, 온도와 습도가 기준을 벗어난 구역이 어디인지를 확인합니다. 문제가 보이면 실제 물류창고에 가기 전에 가상 모형 위에서 먼저 손을 대 보고, 결과가 괜찮다 싶을 때 실제 조치를 내립니다.

디지털 트윈은 물류창고의 실제 상태를 그대로 옮겨 놓은 가상 모형을 뜻합니다. 물류창고에 새로 들어온 상자 하나, 온도가 살짝 오른 랙 하나까지 가상 화면에 실시간으로 반영되고, 관리자는 그 화면에서 원하는 구역을 확대해 볼 수 있습니다. 실제 온도계와 가상 화면의 숫자가 어긋나기 시작하면 센서 고장이나 통신 지연을 의심할 신호가 되기도 합니다. 이렇게 실제 물류창고와 가상 모형을 동시에 볼 수 있게 되었습니다.

새벽 물류센터에서 튀어 오르던 그 온도 값도 결국 이 가상 화면 어딘가에 점 하나로 찍힙니다. 트럭 문이 열릴 때마다 잠깐씩 튀는 숫자는 사람 눈에는 사소해 보이지만, 디지털 트윈 위에서는 그 트럭이 오늘 몇 번이나 문을 열었는지, 다른 트럭보다 온도 변동이 잦은지를 나란히 비교할 수 있는 기록으로 남습니다. 한 트럭의 습관이 유난히 나쁘다면 냉장 설비를 점검하라는 신호로 이어질 수 있습니다. 날개의 숫자로 흩어져 있을 때는 보이지 않던 습관이, 쌓이고 나서야 비로소 눈에 들어옵니다.

일본 고치현의 아이오피(ioP, 식물 인터넷) 사와치 클라우드는 이런 발상을 지역 전체로 넓힌 사례입니다. 1,600곳이 넘는 온실의 환경 데이터와 3,000곳이 넘는 농가의 출하 데이터를 국가 농업 데이터 기반인 WAGRI와 이어 붙이고, 열여섯 개의 분석 모델을 돌려 지역 전체의 출하량을 예측하며 유통 일정을 잡니다. 농가 한 곳 단위로 기록되던 출하 정보가 고치현 전체의 출하량 예측과 유통 일정 조정에 쓰이는 자료로 확장되었습니다. 개

별 농가가 각자 다음 주 출하량을 어림짐작으로 정하던 방식과 비교하면, 지역 전체의 수요와 공급을 한 번에 내려다보고 순서를 정하는 방식에 가깝습니다.

이런 사례들에서 공통으로 등장하는 숫자도 몇 가지로 정리됩니다. 다만 재배대와 물류창고를 얼마나 빈틈없이 채웠는지를 보는 공간 이용률, 문제가 생겼을 때 생산 농장과 납품처까지 역추적하는 데 성공하는 비율인 생산·유통 추적율, 정밀한 처방과 관리 덕분에 줄어든 농약과 에너지 사용량을 가리키는 절감률이 대표적입니다. 가오슝의 재배대나 대만 학교 급식 이력 추적 사례에서 나온 성과는 결국 이 세 숫자 가운데 하나로 환산되어 보고되는 경우가 많습니다. 숫자 하나하나의 작아 보이지만, 물류창고 공간을 조금 더 쓰고 사고를 며칠 일찍 잡아내는 일이 반복되면 농장 전체의 수익에 실질적인 영향을 줍니다.

배에는 배대로, 망고에는 망고대로, 딸기에는 딸기대로 모델을 따로 훈련시켜야 한다는 사정은 이 분야의 숨은 비용입니다. 재배 품목이 열 가지가 넘는 산지라면 열 개가 넘는 모델을 각각 만들고 계절마다 새 데이터로 다시 훈련시켜야 합니다. 재배 품목 수만큼 모델을 유지하고 갱신하는 부담이 커서, 큰 유통 회사가 아니고서는 이 비용을 감당하기가 만만치 않아 보입니다. 그래서 최근에는 여러 과일에 두루 통하는 하나의 기반 모델을 만들고 과일별로 마지막 판정 단계만 손보는 방향으로 연구가 옮겨 가고 있는 것으로 보입니다.

예측과 등급, 이력이 아무리 정교해도 마지막 결정은 사람이 내립니다. 모델이 무인 등급을 매기거나 사흘 뒤 병해충 확산을 경고해도, 그 상자를 실제로 폐기할지, 방제 약제를 언제 뿌릴지를 정하는 결정은 여전히 현장 관리자가 내립니다. 데이터 파이프라인과 등급 모델, 유통 이력 시스템은 그 결정에 필요한 재료를 신속하고 정확하게 갖추어 주고, 무엇을 어떻게 할지 정하는 일은 그다음 단계에서 사람이 맡습니다. 기술은 판단에 쓸 재료의 품질과 속도를 바꾸어 놓았을 뿐, 판단 자체는 여전히 사람의 일입니다.

지금까지 짚은 사례는 대만과 중국, 일본, 미국에 걸쳐 있습니다. 냉장 트럭과 냉장창고, 급식실이라는 똑같은 문제 앞에서 각기 다른 나라가 위성 자료와 카메라, 가스 센서를 조금씩 다른 비율로 섞어 답을 냈다는 점이 눈에 띕니다. 사용하는 언어와 정부 조직은 다르지만, 온도가 튀는 순간을 놓치지 않으려는 목표와 상한 상자 하나를 며칠 일찍 찾아내려는 목표는 같습니다. 기술이 국경을 넘어 비슷한 방향으로 수렴하고 있다고 보아도 무리는 아닐 것입니다.

다만 이 시스템들이 서로 매끄럽게 통하지는 않습니다. 대만의 생산·유통 이력제와 일본의 WAGRI, 미국의 식품안전현대화법은 저마다 다른 항목과 코드 체계로 이력을 기록합니다. 한 나라 안에서 기른 농산물이 국경을 넘어 팔릴 때는 이 서로 다른 장부를 다시 옮겨 적어야 하는 손이 여전히 많이 갑니다. 하나의 배치 번호가 어느 나라에서든 같은 뜻으로 읽히는 공통 규격이 갖추어지기 전까지는, 국경을 넘는 이력 추적에는 사람의 손을 거치는 마지막 구간이 당분간 남아 있을 것으로 보입니다.

그렇다고 이 그림이 다 맞춰진 것은 아닙니다. 위성의 며칠 단위 관측과 드론의 어쩌다 한번, 지상 센서의 초 단위 기록 사이에 남는 눈금 차이는 시공간 보간법과 생성형 인공지능을 동원한 고해상도 복원 연구로도 아직 완전히는 메워지지 않은 숙제로 남아 있습니다. 콜드체인 상자 안의 높은 습도와 렌즈에 서리는 김, 오르내리는 가스 농도는 광학 센서와 가스 센서의 측정값을 슬금슬금 어긋나게 만듭니다. 안경에 김이 서리면 앞이 흐려지듯, 센서도 습기 앞에서는 원래 보던 값을 제대로 보지 못하게 됩니다. 이를 잡으려면 소프트웨어로 스스로 값을 바로잡는 보정 알고리즘과 습기에 강한 표면 소재가 함께 필요해 보입니다.

농가가 모은 데이터를 누가 소유하고 어떻게 값을 매겨 사고파는지, 블록체인으로 위조를 막으면서도 농가의 권리를 지키는 규칙을 어떻게 세우는지는 기술이 아니라 제도가 풀어야 할 문제로 보입니다. 물류창고를 비추는 디지털 트윈에 설명 가능 인공지능을 더해, 기계가 왜 이 상자를 무인 등급으로 매겼는지 근거를 현장 관리자에게 말로 풀어 보여 주는 일도 앞으로의 과제로 꼽힙니다. 판정 이유를 알 수 없는 채로 등급표만 받아 드는 농민에게는 근거를 알 수 없다는 답답함이 남을 수 있습니다. 등급을 매기는 주체가 사람에서 기계로 바뀌는 만큼, 기계가 무엇을 보고 판단했는지 설명하는 일도 함께 갖추어져야 합니다.

냉장 트럭의 온도 기록계에서 나온 데이터는 위성 영상과 물류창고의 디지털 트윈, 급식실의 이력 조회 화면과 하나의 파이프라인으로 연결되어 있습니다. 이 구조에서는 어느 한 구간의 기록이 끊기거나 틀리면 나머지 구간의 판단도 함께 부정확해집니다. 남아 있는 과제는 국가마다 다른 이력 코드 체계를 하나로 통일하고, 온도와 습도, 가스 센서처럼 습기에 약한 장비의 측정 오차를 줄이는 일입니다.

근거 및 참고문헌

학술 논문

1. Choudhari, A., Katkar, R., Gupta, M., Wathe, N., Kakde, S., & Poyam, P. (2025). Design of an integrated spatiotemporal deep learning framework for autonomous precision weed detection, treatment, and recurrence prediction in drone-based smart farming sets. *International Journal of Applied Mathematics*, 38(2s), 1339-1366.
2. Hoque, M. D. J., et al. (2024). Incorporating meteorological data and pesticide usage for crop yield prediction using machine learning. *IEEE Access*, 12, 40947-40961.
3. Huang, X., Zhu, Q., & Huang, M. (2026). Online detection system for freshness of fruits and vegetables based on temporal multi-source information fusion. *Smart Agriculture*, 8(1), 203-212. DOI: 10.12133/j.smartag.SA202505037.
4. Pasupuleti, M. K. (2026). Vision transformers for crop intelligence and sustainable precision agriculture. *International Journal of Academic and Industrial Research Innovations (IJAIRI)*, 6(4), 1-45.

5. Wang, J., et al. (2026). Research progress and prospects of intelligent management and control technologies for facility vegetables. Smart Agriculture, 8(1), 105-120.
6. 中澤健介, 山崎達也. (2026). 大域文脈情報を導入した深層学習とファジー推論を用いた洋ナシ等級判定手法の研究. 『農業情報研究』, 35(2), 65-78.

보고서 및 온라인 자료

1. CABI Digital Library. (2026). 인공지능 기반 수확 후 관리와 저장수명 예측 동향에 관한 리뷰. 『CABI Reviews』. <https://www.cabidigitallibrary.org/doi/10.1079/cabireviews.2026.0011>
2. DeltaTrak. (2026). How predictive shelf-life analytics redefines freshness in the cold chain. Food Logistics. <https://www.foodlogistics.com/software-technology/supply-chain-visibility/article/22954945/deltatrak-how-predictive-shelflife-analytics-redefines-freshness-in-the-cold-chain>
3. National Center for Biotechnology Information. (2026). 다채널 가스 센서 기반 대추야자 저장수명 추정 기계학습 모형에 관한 자료. PubMed Central. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC12252097/>
4. 저장수명 예측, 이력 추적, 탄소 회계를 통합한 모듈형 데이터 기반 체계에 관한 예비 논문. (2026). arXiv. <https://arxiv.org/pdf/2511.05920>

강연 및 영상 자료

1. 高雄農來訊. (2025). 114年高雄智慧農業年度成果發表暨研討會. YouTube. <https://www.youtube.com/watch?v=1Edc6pP4HnU>
2. 気象ビジネス推進コンソーシアムWXBC. (2025). 2025年度 農研機構メッシュ農業気象データ分析チャレンジ. YouTube. <https://www.youtube.com/watch?v=w1SrS3iwA4E>
3. TaiwanICDF國合會. (2025). 2025第三屆國際開發援助現場論壇: 全球智慧農業發展探究. YouTube. <https://www.youtube.com/watch?v=0qUeP8A4Pro>
4. 茶柱. (2026). 茶園スマート農業 カワサキ技研・落合刃物・寺田製作所. YouTube. <https://www.youtube.com/watch?v=zmFbOC5RcJU>
5. 李載榮. (2025). A88 資策會衛星精準農業AI導入工作坊: 桃園AI衛星多光譜圖像與無人機應用. YouTube. <https://www.youtube.com/watch?v=dtT3bafdKgW>
6. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026 Global AgriFood Innovation Roadshow: China Agricultural University Special Session. YouTube. <https://www.youtube.com/watch?v=SS2qVDa11nw>
7. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026 Global Agrifood Innovation Roadshow: Session 2. YouTube. <https://www.youtube.com/watch?v=DQrCqqyNAqY>
8. 農業農村情報通信環境整備準備会. (2026). 地域でデータを共有しよう: 農業データの利活用最前線, データ駆動型農業WAGRIとIoTクラウド(SAWACHI)でのNext次世代型施設園芸システム. YouTube. <https://www.youtube.com/watch?v=k8Qvv6CKB2A>
9. Centre for Networked Intelligence, IISc. (2025). Webinar on Track-1: Crop identification using satellite data [IndiaAI Impact Gen-AI Hackathon]. YouTube. https://www.youtube.com/watch?v=9xi5_1rrJ9o
10. Sampurna Challenge. (2026). Post-Harvest Innovation, Startups & Agri Value Chain Solutions | Webinar | Sampurna 2026. YouTube. <https://www.youtube.com/watch?v=0HTys4rPdWE>
11. AgriBusiness Forum. (2026). AI, Data, Digital Transformation of the agrifood value chain. YouTube. <https://www.youtube.com/watch?v=OMFBQz27YyU>
12. 臉書李載榮協助進駐科學園區科技廠商團膳機器人電動三輪車物流餐車全球愛玉全球機器人口全球AI族譜規劃. (2025). A89私密資策會衛星精準農業AI導入工作坊桃園AI衛星多光譜圖像與無人機應用主辦單位:資策會協辦單位:擎壤科技公司【悠由數據 FarmiSpace × 大賀米 × 擎壤無人機 × 資策會】聯合打造精準. YouTube. <https://www.youtube.com/watch?v=L27xkkSrSa0>
13. Washington State Academy of Sciences (WSAS). (2026). AI for Post Harvest. YouTube. <https://www.youtube.com/watch?v=hJlOrgNIQG4>

5장

AI 기반 디지털 피노타이핑 및 육종 생물공학

5.1

고속 작물 피노타이핑(High-Throughput Phenotyping)

온실 천장 레일에 갠트리를 매단 장비는 화분 앞을 지날 때마다 카메라 여러 대로 여러 각도에서 사진을 찍고, 이 사진들을 모아 식물 하나하나의 입체 모형을 자동으로 세웁니다. 사람이 줄자를 들고 온실을 오가며 하루 종일 재던 일을, 그 장비는 화분 수천 개를 상대로 하룻밤 사이에 끝냅니다. 사진에서 입체 모형을 다시 세우는 계산 속도도 근래 들어 크게 빨라졌습니다. 2026년에 발표된 3차원 파운데이션 모델은 평균 6분 31초 걸리던 재구성 시간을 1.58초로 줄였고, 3차원 가우시안 스피래팅 방식은 초당 6.39프레임의 처리 속도를 냈습니다.

이렇게 기계가 식물의 겉모습을 재는 일을 표현형 분석이라고 부릅니다. 씨앗 속에 적힌 유전 정보가 실제로 자라난 식물에서 키, 잎 크기, 줄기 굵기, 병에 걸린 흔적 같은 형태로 드러난 것을 표현형이라고 하고, 그것을 측정하고 기록하는 작업 전체가 표현형 분석입니다. 오랫동안 이 일은 사람이 도맡았습니다. 육종가가 직접 줄자를 대고 키를 재고, 눈으로 잎 색을 보고 병든 정도를 등급으로 매기고, 때로는 식물을 통째로 뽑아 무게를 달았습니다. 사람이 하는 측정에는 그날의 기분과 눈썰미에 따라 오차가 끼어 들고, 품종 하나를 실험하는 데도 계통이 수천에서 수만 개에 이르면 생육 기간 내내 전부를 지켜보는 일은 애초에 손이 닿지 않았습니다. 육종 현장에서는 이 병목을 오래전부터 알고 있었지만, 뚝을 도구가 마땅치 않았습니다.

그 도구를 만든 것이 센서 공학과 로봇, 그리고 인공지능입니다. 레이저와 카메라가 식물의 몸을 대신 재고, 무인기와 바퀴 달린 로봇이 밭과 온실 구석구석을 주행하며 사진과 영상을 모으고, 딥러닝이 사진 속에서 잎과 열매를 구분해 냅니다. 이 세 가지가 하나로 묶인 기술을 고속 작물 피노타이핑, 영어로는 하이스루풋 페노타이핑(High-Throughput Phenotyping)이라고 부르며, 흔히 줄여서 에이치티피(HTP)라고 씁니다. 사람이 하루에 화분 백 개를 재는 속도와 견주면, HTP 장비는 같은 시간에 수천 개를 재면서도 화분을 건드리거나 잎을 뜯지 않습니다. 스마트 육종을 이야기할 때 이 기술이 늘 따라붙는 것은, 좋은 품종을 고르는 작업의 첫 단추가 정확한 측정이고 HTP가 그 단추를 기계의 손에 맡기기 때문입니다.

온실과 밭에서 자라는 식물 군락의 입체 구조와 빛 반사 특성을 다치지 않은 채로 빠르게 찍고, 그 자료를 유전자와 환경과 겹모습이 서로 얽혀 돌아가는 틀 안에서 숫자로 바꾸는 것이 HTP의 핵심 원리입니다. 같은 씨앗도 물을 많이 준 밭과 적게 준 밭에서 다르게 자랍니다. 겹모습은 유전자 하나만으로 정해지지 않고 유전자와 환경이 함께 빚어낸 결과입니다. 육종가들은 이 관계를 유전형과 환경과 표현형의 앞 글자를 따서 지이피($G \times E \times P$)라고 부르는데, HTP는 이 관계에서 재기가 유난히 어려웠던 마지막 항인 표현형을 채워 넣는 역할을 맡습니다. 표현형이 빠진 채로는 아무리 좋은 유전자 지도를 그려도 그 지도가 실제 밭에서 맞는지 확인할 길이 없습니다.

입체 구조를 찍는 방법 가운데 흔히 쓰이는 것이 레이저 스캐닝입니다. 라이다(LiDAR)는 레이저를 쏘고 그 빛이 물체에 부딪혀 되돌아오는 데 걸리는 시간을 마이크로초 단위로 재서 거리를 계산하는 장치이며, 이렇게 구한 수백만 개의 거리 값을 좌표로 찍으면 점 하나하나가 모여 식물의 겉모양을 그대로 본뜬 입체 그림이 됩니다. 이 점들의 모음을 포인트 클라우드라고 부르는데, 모래알만 한 점을 수없이 찍어 얼굴 윤곽을 만드는 모자이크와 비슷한 원리입니다. 레이저 스캐너 가운데 페노스펙스(PhenoSpex)의 플랜트아이 F600(PlantEye F600)이 대표적인 예로 꼽히며, 점과 점 사이 간격이 0.1밀리미터에 지나지 않을 만큼 촘촘한 포인트 클라우드를 만들어 냅니다.

그 장비는 근적외선과 붉은빛의 반사율을 함께 재는 센서를 붙여 놓아서, 입체 모양을 뜨는 것과 동시에 잎이 얼마나 건강한지를 가리키는 정규화 식생지수, 엔디비아이(NDVI)도 같은 순간에 뽑아냅니다. 색상 사진과 거리 정보를 한 장에 함께 담는 RGB-D 깊이 센서나, 카메라 두 대 이상이 찍은 사진을 겹쳐서 어긋난 정도로 거리를 셈하는 스테레오 비전, 여러 각도에서 찍은 사진을 짜 맞추는 여러 시점 스테레오(Multi-View Stereo, MVS) 복원도 같은 목적으로 쓰이는데, 이 방식들은 사람의 두 눈이 거리를 가늠하는 원리와 닮았습니다.

이렇게 얻은 포인트 클라우드에서 컴퓨터는 사람이 줄자로 재던 값을 자동으로 뽑아냅니다. 식물의 키에 해당하는 초장, 잎이 덮은 면적, 잎이 뻗어 나온 각도, 줄기의 굵기, 잎이 겹쳐 이루는 부피까지, 예전에는 사람이 하나씩 손으로 재던 항목들이 이제는 점 구름 하나를 분석하는 것만으로 한꺼번에 계산됩니다. 화분 수천 개를 매일 같은 시각에 재면, 식물이 하루하루 얼마나 자랐는지를 보여 주는 성장 곡선도 저절로 그려집니다. 온실보다 훨씬 넓은 밭을 다뤄야 할 때는 이런 지상 스캐너만으로는 부족하고, 하늘에서 내려다보는 눈이 하나 더 필요해집니다.

그 눈의 역할은 무인기, 유에이브이(UAV)가 맡습니다. 낮은 높이에서 밭 위를 날아다니는 드론에는 화소 수 2천만이 넘는 초고해상도 색상 카메라와, 파란빛과 녹색빛과 붉은빛과 레드에지와 근적외선까지 다섯 파장 대역을 나누어 찍는 다중분광 센서가 함께 실립니다. 여기에 400에서 1000나노미터 사이의 빛을 촘촘히 쪼개어 찍는 초분광 센서와 표면

온도를 색으로 보여 주는 열화상 센서까지 더해집니다. 드론에 흔히 실리는 마이캐센스(MicaSense)의 다중분광 센서가 이 다섯 파장 대역을 찍는 장비로 꼽힙니다. 이렇게 모은 사진은 발 전체가 앞으로 얼마나 덮여 있는지를 보여 주는 식생 피복률과, 엔디비아이(NDVI)와 지엔디비아이(GNDVI)와 에스에이브이아이(SAVI) 같은 식생지수로 바뀝니다.

병들거나 마른 잎은 근적외선을 적게 되쏘고 붉은빛을 삼키지 못하는 반면, 건강한 초록 잎은 엽록소가 붉은빛을 흡수하고 근적외선은 강하게 반사하기 때문에 두 파장의 반사량 차이가 잎의 건강한 정도를 숫자 하나로 드러냅니다. 드론 한 대가 낮은 고도로 몇 시간을 날면 밭 몇십 헥타르를 훑으면서 식생지수 지도를 완성하고, 자라다 만 구획이 어디인지까지 색깔로 표시해 줍니다.

사진과 점 구름에서 잎과 꽃과 열매를 갈라내는 일은 딥러닝이 맡습니다. 씨앤엔(CNN), 비전 트랜스포머(Vision Transformer, ViT), 그래프 신경망(Graph Neural Network, GNN) 같은 모델이 그 역할을 하는데, 사진 한 장 안에서 물체의 테두리를 픽셀 하나하나까지 따라 그려 올려 내는 일을 인스턴스 세그멘테이션이라고 부릅니다. 옥수수 이삭 하나, 그 옆의 이삭 하나, 다시 그 옆의 잎사귀 하나를 서로 다른 물건으로 구분해 표시하는 작업이라고 보면 됩니다. 이렇게 올려 낸 기관을 며칠, 몇 주에 걸쳐 같은 위치에서 다시 찍으면, 잎이 퍼지는 속도와 열매가 굵어지는 속도까지 시간의 흐름을 따라 추적할 수 있고, 이 흐름은 다시 전체 무게, 바이오매스와 최종 수확량을 미리 가능하게 해 줍니다.

중국 허난성의 한 옥수수 재배 포장에서는 이 인스턴스 세그멘테이션이 실제로 밭을 누빔니다. 바퀴 달린 지상 자율주행 로봇, 유지비(UGV) 한 대가 옥수수 줄 사이를 천천히 지나가며 앞쪽에 달린 대형 파노라마 카메라로 좌우를 훑습니다. 한낮의 햇빛은 시시각각 달라지고 위쪽 잎이 아래쪽 이삭을 가리는 통에, 사람 눈으로도 이삭이 몇 개나 달렸는지 세기가 쉽지 않은 장면입니다. 여기에 투입된 콘올로(CornYOLO) 모델은 가벼운 신경망인 옴로11엔(YOLO11n)을 백본으로 삼고 프레임 재구성 모듈(FRM)을 덧붙여, 잎에 가려 반쯤만 보이는 이삭까지 찾아냅니다. 정확도를 재는 잣대인 평균정밀도, 엠에이피(mAP)가 91.5퍼센트에 이르러, 사람이 눈으로 세는 것과 맞먹는 수준에 도달했다고 볼 수 있습니다.

로봇이 밭 한 바퀴를 도는 사이 포기마다 이삭이 몇 개 달렸는지, 어느 위치에 달렸는지가 자동으로 표로 쌓이고, 이 표는 그대로 수확량과 관련된 형질을 고르는 밑자료가 됩니다.

옥수수와 벼가 꽃을 피우는 시기를 살피는 데도 비슷한 방식이 쓰입니다. 드론이 위에서 찍은 군락 사진에 옴로브이5(YOLOv5)와 비전 트랜스포머를 적용하면, 꽃가루를 만드는 수이삭(웅수, Tassel)이 얼마나 올라왔는지, 아직 피지 않았는지, 막 피기 시작했는지, 이미 활짝 피었는지를 세 단계로 나누어 자동으로 구별합니다. 이 결과를 모으면 포장 전체가 지금 어느 생육 단계에 있는지를 보여 주는 생육지수가 저절로 계산되어, 사람이 며칠 간격으로 밭을 돌며 눈대중으로 판단하던 개화 시기를 훨씬 촘촘한 간격으로 다시 확인할

수 있게 됩니다. 육종가에게 개화 시기는 어느 계통과 어느 계통을 교배할지를 정하는 기준이 되며, 이 기준이 하루 단위로 정밀해지는 것만으로도 교배 설계의 성공률이 달라집니다.

모든 농장이 콘올로 같은 전용 모델을 새로 만들 형편은 아니므로, 누구나 내려받아 쓸 수 있는 오픈소스 도구도 함께 자랍니다. 식물시브이2(PlantCV v2)는 사진 속 잎의 색과 모양을 분석하는 절차를 스크립트로 짜 두어, 사용자가 자기 사진만 넣으면 잎 면적과 수관 부피와 변색된 비율을 자동으로 뽑아내는 오픈소스 프로그램입니다. 케이엠세그(kmSeg)는 케이민즈(K-means)라는 통계 기법으로 색상을 몇 개의 무리로 나눠 식물과 배경을 구별하고, 페노이미지(PhenoImage)는 엽록소가 빛을 받아 내는 형광 이미지를 대량으로 처리합니다. 연구비가 넉넉하지 않은 대학 실험실에서도 이런 도구 덕분에 대기업 수준의 표현형 분석을 흉내 낼 수 있게 되었습니다.

온실 안에서는 갠트리나 레일을 놓은 고정형 장비가 표준으로 정착했습니다. 레르나텍(LemnaTec), 페노스펙스, 필드 스캐널라이저(Field Scanalyzer) 같은 회사의 장비는 온실이나 지붕이 덮인 실험 포장에 레일을 깔고, 화분이나 구획 수천 개를 정해진 시각마다 자동으로 실어 날라 스캐너 아래를 지나가게 합니다. 사람이 정해 둔 순서와 시각을 따라 기계가 밤낮없이 움직이므로, 새벽 세 시에도 낮 열두 시와 똑같은 조건으로 같은 화분을 다시 잴 수 있습니다. 이런 반복성은 사람의 손으로 흉내 낼 수 없고, 같은 식물을 매일 같은 각도와 밝기에서 찍어야 하는 표현형 분석에 정확히 들어맞습니다.

온실 밖, 지붕 없는 넓은 밭에서는 사정이 다릅니다. 레일을 깔 수 없을 만큼 면적이 넓기 때문에, 위치를 2센티미터 오차 이내로 잡아내는 실시간 이동 측위, 알티케이(RTK)-지피에스(GPS) 항법을 갖춘 드론과 지상 로봇이 그 역할을 대신합니다. 드론은 하늘에서 넓은 면을 훑고 지상 로봇은 군락 아래쪽 눈높이에서 이삭을 가까이 들여다보는 식으로 역할을 나누어, 수천 계통이 심긴 육종 시험 포장 전체를 며칠 안에 두루 훑습니다. 두 장비가 주고받는 위치 정보가 같은 좌표계 위에 놓이기 때문에, 드론이 위에서 본 자료와 로봇이 옆에서 본 자료를 나중에 하나로 겹쳐 볼 수도 있습니다.

장비를 살 예산이 빠듯한 현장을 위한 저비용 대안도 나와 있습니다. 엠브이에스페노(MVS-Pheno)와 리터럴(LITERAL) 같은 장치, 그리고 아두이노(Arduino) 마이크로컨트롤러에 카메라 몇 대만 붙인 소형 장비도 3차원 재구성 작업을 해냅니다. 값은 상업용 갠트리 장비의 수십분의 일에 지나지 않지만, 소규모 연구실이나 농가 한 곳이 자기 밭 한 패기를 스스로 스캔하기에는 부족함이 없습니다. 비싼 장비가 없어도 표현형 분석을 시작할 수 있게 되었습니다.

지금까지 다룬 장비는 모두 땅 위, 눈에 보이는 부위를 잽니다. 뿌리는 흙에 묻혀 있어 사정이 전혀 다른데, 멀티플렉스랩(MultipleX-Lab)과 라이조팟(RhizoPot) 같은 장치는 투명한 관 속에 식물을 심고 빛을 관 옆면으로 투과시켜 뿌리의 그림자를 찍는 방식으로 이

문제를 푼다. 뿌리를 뽑지 않고도 결뿌리가 사방으로 몇 개나 뻗었는지, 얼마나 깊이 내려갔는지를 시간에 따라 반복해서 기록할 수 있어서, 가뭄에 강한 뿌리 구조를 고르는 육종에 요긴하게 쓰입니다. 지상부 사진만으로는 알 수 없는 정보를, 그 장치들이 땅속에서 대신 채워 줍니다.

카메라가 아무리 정교해도 찍힌 사진에는 흙, 자갈, 잡초, 그림자 같은 잡음이 함께 담깁니다. 이런 배경을 골라내는 첫 단계에서는 색상 공간을 바꾸는 계산식, 이지지(ExG)와 시브이아이(CVI) 같은 지수를 써서 초록 식물과 그 밖의 것을 갈라내고, 지형을 따라가며 걸러 내는 위상학적 필터링을 함께 적용합니다. 포인트 클라우드는 점의 개수가 너무 많아 그대로 다루면 컴퓨터가 버거워하므로, 식물 전용으로 잡음을 없애도록 학습된 신경망인 식물잡음제거망(Plant-denoising-net, PDN)과, 점을 고르게 속아 내는 자기조직화지도 다운샘플링(SOM Down-sampling)을 거쳐 다루기 좋은 크기로 줄입니다. 흙 알갱이 하나까지, 열게 드리운 그림자까지 걸러 내야 다음 단계에서 식물만 남은 깨끗한 형태를 다룰 수 있습니다.

이 손질을 거치지 않은 원본 점 구름은 잡음이 뒤섞인 채로 다음 단계의 계산을 어지럽힙니다.

잡음을 걷어 낸 사진 여러 장에서 식물 한 포기의 입체 모양을 다시 세우는 작업에는 여러 시점 스테레오 복원 알고리즘과, 테두리를 더 예민하게 찾아내는 비전 트랜스포머인 에지 엠브이에스포머(Edge_MVS-Former)가 함께 쓰입니다. 이렇게 세운 3차원 모형은 트랙 플랜트3디(TrackPlant3D) 같은 인스턴스 세그멘테이션 신경망을 다시 거쳐, 줄기와 잎이 하나하나 갈라져 기관 단위로 정리됩니다. 문제는 속도였습니다. 사진 수십 장을 입력 받아 반듯한 입체 모형 하나를 완성하기까지 예전 방식으로는 몇 분씩 걸렸고, 온실 화분 수천 개를 매일 다시 찍어야 하는 육종 현장에서 이 몇 분은 쌓이고 쌓여 하루 전체 일정을 잡아먹는 부담이 되었습니다.

이 속도 문제에 실마리를 던진 것이 신경방사장, 너프(NeRF, Neural Radiance Field)라는 방식입니다. 너프는 여러 각도에서 찍은 사진 몇 장을 신경망에 입력해, 3차원 공간 어디에서 어느 방향을 바라보든 그곳의 색과 빛의 세기를 신경망이 스스로 추측하도록 학습 시킵니다. 사진과 사진 사이의 빈 틈, 그러니까 카메라가 미처 찍지 못한 각도까지 신경망이 그럴듯하게 채워 넣어서, 이전보다 훨씬 자연스러운 입체 장면을 만들어 냈습니다. 다만 화면의 점 하나를 그리려 할 때마다 신경망에 일일이 물어보아야 했기 때문에, 정밀한 대신 느리다는 꼬리표가 오래 따라다녔습니다. 2026년에 발표된 3차원 파운데이션 모델은 이 꼬리표를 정면으로 반박했습니다.

여러 식물 종의 사진을 미리 대량으로 학습해 둔 뒤 새로운 식물 사진이 들어오면 그 학습 결과를 그대로 끌어다 쓰는 방식으로, 평균 6분 31초 걸리던 재구성 시간을 1.58초로 줄이면서도 모양의 정확도와 표현형 수치는 그대로 지켰습니다.

속도를 끌어올린 또 다른 방식은 3차원 가우시안 스피래팅, 쓰리디지에스(3DGS)입니다. 너프가 신경망에게 매번 색을 물어보는 방식이라면, 쓰리디지에스는 식물의 표면을 작고 흐릿한 반투명 덩어리 수십만 개로 미리 빚어 놓고, 색이 뻗 숨뭉치를 훌쩍리듯 화면 위에 한꺼번에 펼쳐 그림을 완성하는 방식입니다. 덩어리 하나하나의 위치와 색과 흐릿한 정도만 계산하면 그리는 작업은 그래픽카드가 곧바로 처리하므로, 신경망에 묻고 답하는 절차를 거치지 않아도 됩니다. 기존 방식인 인스턴트엔지피(Instant-NGP), 너프팩토(Nerfacto)와 겨룬 실험에서 쓰리디지에스는 초당 6.39프레임의 속도를 냈고, 이 결과를 계기로 3차원 표현 방식의 중심축이 신경망 쪽에서 이런 명시적 구조 쪽으로 옮겨 갔습니다.

카메라 여러 대가 찍은 사진에서 식물 개체 하나하나를 서로 다른 물건으로 구분하는 일은 아직 쉽지 않은 과제입니다. 플랜트세그너프(PlantSegNeRF)는 여러 시점에서 찍힌 사진 속 같은 기관을 서로 짝짓는 절차를 신경망사장에 결합해, 표본 수가 적거나 처음 보는 작물 중에서도 개체별 3차원 점 구름을 나누어 냅니다. 로봇이 스스로 다음에 어느 각도에서 찍어야 새로운 정보를 더 많이 얻을지 판단하게 만든 연구도 나왔는데, 에스에스엘엔비비(SSL-NBV)라는 이 방식은 정답을 일일이 알려 주지 않아도 로봇이 스스로 깨우치는 자가지도학습으로, 사람이 매번 정해 주지 않아도 다음에 카메라를 세울 위치를 스스로 고릅니다.

실제 밭 규모의 점 구름을 물리적으로 정확한 축척까지 갖추어 완성하려는 다섯 단계짜리 처리 절차도 제안되었는데, 사진을 찍는 자료 획득 단계, 식물과 배경을 가르는 의미 분할 단계, 성긴 점만 먼저 세우는 희소 재구성 단계, 점을 촘촘히 채우는 조밀 재구성 단계, 마지막으로 표현형 형질을 뽑아내는 단계로 이어집니다.

이렇게 쏟아진 방법들을 나란히 놓고 견주는 작업도 뒤따랐습니다. 2026년 국제 학술지 프런티어스인플랜트사이언스(Frontiers in Plant Science)에는 포장 조건에서 점 구름을 중심으로 이루어진 3차원 작물 표현형 연구들을 모아 비교한 리뷰 논문이 실렸고, 비슷한 시기에 학술지 센서스(Sensors)에도 3차원 재구성 기술 전반을 정리한 리뷰가 나왔습니다. 두 리뷰가 공통으로 짚는 흐름은, 값비싼 장비 하나에 기대던 시대에서 값싼 카메라 여러 대와 빠른 소프트웨어를 조합하는 시대로 무게 중심이 옮겨 가고 있다는 것입니다.

이렇게 만들어진 여러 방법이 실제로 쓸 만한지는 몇 가지 잣대로 확인합니다. 옥수수 이삭이나 잎처럼 찾으려는 대상을 얼마나 잘 가려내는지는 평균정밀도, 엠에이피(mAP)로 재고, 오려 낸 잎의 테두리가 실제 테두리와 얼마나 겹치는지는 아이오유(IoU)라는 겹침 비율로 잹니다. 레이저나 카메라로 세운 입체 모형이 자로 잰 실제 치수와 어긋난 정도는 제곱평균오차, 알엠에스이(RMSE)로 밀리미터 단위까지 표시하고, 현장에 붙은 작은 컴퓨터가 사진 한 장을 처리하는 데 걸리는 시간과 초당 처리 장수는 실시간으로 쓸 수 있는지를 가르는 기준이 됩니다. 파괴 조사로 직접 잰 무게나 키와, 사진만으로 추정한 값이

서로 얼마나 잘 들어맞는지는 결정계수로 나타내는데, 여러 연구에서 이 결정계수가 0.75를 넘어서면서 사진으로 잦 값이 파괴 조사를 대신할 만하다는 근거가 쌓이고 있습니다.

개화 단계나 병해 등급처럼 숫자가 아니라 등급으로 나뉘는 형질은 에프원(F1-Score) 점수와 혼동행렬로 따로 검증합니다.

카메라와 로봇이 매일 쏟아 내는 사진과 점 구름과 숫자는 종류도 다르고 규모도 제각각이어서, 이 자료를 연구자들끼리 나누어 쓰려면 정리된 약속이 있어야 합니다. 그 약속의 기본 틀이 페어(FAIR) 원칙입니다. 찾을 수 있어야 하고(Findable), 접근할 수 있어야 하고(Accessible), 서로 다른 프로그램끼리도 맞물려 돌아가야 하고(Interoperable), 나중에 다시 꺼내 써도 문제가 없어야 하는(Reusable) 네 가지 조건을 말합니다. 센서가 찍은 원본 사진, 손질을 거친 3차원 점 구름, 촬영 시각과 위치, 마지막으로 뽑아낸 표현형 수치까지, 이 모든 자료에 언제 어디서 무엇을 찍었는지 밝히는 꼬리표를 붙여 중앙 데이터베이스에 정리해 두는 것이 페어 원칙을 지키는 실제 방법입니다.

이 원칙을 구체적인 시스템으로 옮긴 사례가 피스(PHIS, Phenotyping Hybrid Information System)입니다. 피스는 식물 온톨로지(Plant Ontology, PO)라는 표준 용어 체계를 끌어와, 온실이나 밭에서 벌어지는 모든 실험 대상과 센서와 사건에 하나씩 고유한 이름표를 붙입니다. 화분 하나가 온실 이쪽에서 저쪽으로 옮겨진 일, 앞에 반점이 생긴 일, 온도 센서가 읽은 값까지 모두 고유한 영구 식별자, 유알아이(URI)로 연결해 두기 때문에, 몇 해 전 실험 자료와 이번 달 실험 자료를 같은 잣대로 견주어 볼 수 있습니다. 이런 식별자 체계가 페어 원칙이 요구하는 상호운용성과 재사용성을 실험 자료 차원에서 구현합니다.

피스와 짝을 이루는 오픈실렉스(OpenSILEX)는 여기저기 흩어진 표현형 자료와 이를 다루는 웹 서비스를 하나의 표준 통로로 이어 주는 소프트웨어 구조입니다. 국제 학계는 표현형 실험을 기록할 때 최소한 어떤 정보를 반드시 남겨야 하는지도 별도로 정해 두었는데, 미아페(MIAPPE, Minimum Information About a Plant Phenotyping Experiment)라는 이름의 이 규격은 실험 장소와 날짜, 재배 조건, 측정 방법을 빠뜨리지 않고 적도록 요구하며 피스나 오픈실렉스 같은 시스템이 이 규격을 기반 구조로 삼습니다. 포장 실험 환경과 농작업 이력과 기상 자료를 다루는 아이카사 2.0(ICASA Version 2.0) 표준도 비슷한 목적으로 쓰입니다.

서로 다른 나라, 서로 다른 대학의 실험실이 저마다 다른 이름으로 부르던 것을 이런 규격 몇 가지가 같은 말로 옮겨 줍니다.

이렇게 정리된 표현형 자료는 유전체 자료와 만날 때 비로소 값어치가 커집니다. 크롭지 에스허브(CropGS-Hub)와 피노프시스디비(PHENOPSIS DB) 같은 데이터베이스는 유전체 정보와 고속 표현형 자료를 한곳에 모아 두어, 예측 육종(Genomic Selection) 모델이

두 자료를 따로 찾아다니지 않고 곧바로 이어 쓸 수 있게 합니다. 표현형 데이터베이스가 표준 규격을 따르지 않았다면, 겉모습을 재는 기술과 유전자를 읽는 기술이 서로 다른 형식과 규격을 써서 유전체 자료와 잇는 작업 자체가 이루어지지 못했을 것입니다.

페노스펙스의 플랜트아이가 실제로 쓰이는 온실에서는, 스캐너 한 대가 매일 같은 화분을 지나가며 수관 높이와 잎 면적과 잎이 기울어진 각도를 하루 단위로 쌓아 갑니다. 이 수치들은 그대로 컴퓨터 속 가상 온실, 디지털 트윈(Digital Twin)에 복제되어, 실제 온실과 나란히 자라는 두 번째 온실을 화면 안에 만들어 냅니다. 재배 담당자는 화면 속 가상 식물이 물과 양분을 얼마나 원하는지를 거꾸로 계산해서, 실제 온실의 급액 밸브를 열고 닫는 시각과 양을 정합니다. 식물이 목마르다고 말하는 대신 잎의 기울기와 수관의 부피 변화가 그 말을 대신 전합니다.

대두와 겨울밀을 심은 육종 시험 포장에서는 드론 한 대에 다중분광 센서와 라이다를 함께 얹어 날립니다. 수관의 높이 정보와 잎의 색깔 정보를 가중치를 두어 함께 계산하면 발 위에 쌓인 지상부 바이오매스와 그 안에 담긴 질소량을 상당히 정밀하게 추정할 수 있습니다. 수확철에는 사진 속에서 서로 뭉친 콩 꼬투리도 군집 계산 방식으로 자동으로 헤아리는데, 이 결과 덕분에 수확량이 높을 것으로 보이는 계통을 받을 갈아엎어 무게를 달아 보기도 전에 드론 사진 한 장으로 먼저 추려 낼 수 있습니다.

화훼와 과수를 다루는 큰 연구 기관에서는 오픈실렉스와 피스를 함께 들여와 자료 더미 전체를 감당합니다. 하루에도 수만 장씩 쌓이는 색상 사진과 3차원 영상, 센서가 실시간으로 보내는 값, 품종별 유전형 정보가 한 시스템 안에 모이고, 식물 온톨로지 표준으로 붙은 이름표 덕분에 서로 다른 연구팀이 같은 화분을 두고도 다른 이름으로 부르는 혼선이 사라집니다. 자료를 찾고 나누는 절차가 줄어든 만큼 연구자들은 인공지능 육종 모델을 자료에 이어 붙이는 다음 단계로 곧장 넘어갈 수 있습니다. 표준화는 화려한 결과물을 내놓지는 않지만, 그 결과물이 나오기까지 걸리는 시간을 눈에 띄게 줄이는 일입니다.

이런 성과에도 불구하고 아직 풀리지 않은 문제도 여럿 남아 있습니다. 작물이 자라 군락이 우거지면 위쪽 잎이 아래쪽 꽃과 열매, 병든 흔적까지 가려 버려서, 카메라나 레이저 스캐너를 위에 하나만 세워 두는 방식으로는 아래쪽 형질을 아예 볼 수 없는 경우가 잦습니다. 지상 로봇과 드론이 다른 각도에서 함께 찍고, 가려서 찍히지 않은 잎을 주변 정보로 메워 채우는 점 구름 복원 계산을 다듬는 것이 지금으로서는 유력한 해법으로 보입니다. 잎 한 장이 통째로 사라진 사진에서 그 잎의 모양을 완벽히 되살리기는 여전히 어렵지만, 어림값만으로도 없는 것보다는 훨씬 낫다는 것이 현장의 판단입니다.

자료의 몸집도 걸림돌입니다. 0.1밀리미터 해상도의 점 구름이나 수백 개 파장을 담은 초분광 사진은 한 장 한 장이 기가바이트 단위로 불어나서, 발 한쪽에 세워 둔 작은 컴퓨터가 실시간으로 처리하기에는 벅찬 크기입니다. 점을 속아 내는 다운샘플링, 큰 신경망의 지식을 작은 신경망에 옮겨 담는 지식 증류(Knowledge Distillation), 인공지능 연산 전

용 칩(NPU)을 장비 안에 직접 심어 두는 하드웨어 가속까지, 자료를 줄이거나 계산을 빠르게 만드는 여러 방법이 나란히 연구되고 있습니다. 가벼운 장비일수록 밭 한가운데서 답을 즉시 내놓을 수 있으므로, 이 무게 줄이기 경쟁은 앞으로도 한동안 이어질 것으로 보입니다.

바깥 날씨도 인공지능을 자주 헛갈리게 합니다. 강한 직사광선 아래서는 잎 표면이 하얗게 반사되어 색 정보가 날아가 버리고, 바람에 잎이 흔들리면 같은 잎이 사진마다 다른 모양으로 찍히며, 구름이 지나가며 밝기가 순간순간 바뀌면 방금 학습한 모델이 다음 사진에서는 헤매기도 합니다. 온실처럼 빛과 바람을 통제된 곳에서 학습한 모델을 그대로 노지에 옮겨 놓으면 정확도가 뚝 떨어지는 일이 흔한데, 이런 현상을 도메인 시프트(Domain Shift)라고 부릅니다. 다양한 날씨와 빛 조건을 인위적으로 섞어 학습 자료를 불러 두거나, 새로운 환경에 맞추어 모델을 다시 손보는 도메인 적응(Domain Adaptation) 기법이 이 문제를 다루는 주된 방법으로 쓰이고 있습니다. 결국 실험실 밖으로 나가 정확도를 검증받지 않은 모델은 온실 안에서만 통하는 반쪽짜리 결과로 남을 위험이 있습니다.

지금까지 다룬 기술은 거의 모두 땅 위 잎과 열매를 향해 있어서, 땅속 뿌리까지 한 파이프라인 안에서 함께 추적하는 통합 표현형 분석이 다음 과제로 꼽힙니다. 여기에 더해, 인공지능이 어떤 사진을 보고 왜 그 식물을 병든 것으로, 혹은 수확량이 높을 것으로 판정했는지를 사람이 알아볼 수 있게 보여 주는 설명 가능 인공지능(Explainable AI, XAI) 기술도 함께 요구됩니다. 그라드캠(Grad-CAM)이나 샵(SHAP) 같은 기법은 신경망이 판정을 내릴 때 사진의 어느 구역을 눈여겨보았는지를 색으로 표시한 열지도로 보여 주는데, 이런 시각 자료가 갖추어져야 육종가가 기계의 판정을 그대로 믿고 다음 교배 계획을 세울 수 있습니다. 갠트리가 지나가고 나면 남는 것은 결국 사진 몇 장이 아니라 좌표값 수백만 개와 그 값에서 뽑아낸 형질 수치입니다.

이 수치가 표준 규격에 따라 정리되면 온실 몇 동을 넘어 다른 나라 연구소의 자료와도 이어집니다. 그러면 특정 유전자를 지닌 씨앗이 어떤 밭에서 어떻게 자라는지를 육종가가 숫자로 확인할 수 있습니다.

근거 및 참고문헌

학술 논문

1. Xu, Q., Zheng, B., & Zhong, S. (2026). Artificial Intelligence Empowering Modern Agricultural Biological Breeding. *Smart Agriculture*, 8(3), 69-85.
2. Gao, G., Wang, Q., Song, L., Feng, H., Shi, L., Yang, H., Liu, Y., & Yue, J. (2026). Object Detection Method of Maize Ears Within Canopy Based on CornYOLO. *Smart Agriculture*, 8(1), 167-177. DOI: 10.12133/j.smartag.SA202509005.

3. Moldvai, L., & Nyéki, A. (2025). Innovative computer vision methods for tomato (*Solanum Lycopersicon*) detection and cultivation: a review. *Discover Applied Sciences*, 7, 975.
<https://doi.org/10.1007/s42452-025-07613-x>
4. Harnessing artificial intelligence in plant breeding: Innovations in digital phenotyping and breeding methods. (2026). *Plant Methods*. DOI: 10.1007/s13007-026-01286-0.
5. Neveu, P., Tireau, A., Hilgert, N., Negre, V., Mineau-Cesari, J., et al. (2019). Dealing with multi-source and multi-scale information in plant phenomics: The ontology-driven Phenotyping Hybrid Information System. *New Phytologist*, 221(1), 588-601.
6. OpenSILEX. (2026). Plan de gestion logiciel.
7. 田中佑, 郭威, 山口友亮, 桂圭佑, 中嶋洸太, & 戸田陽介. (2025). "AI時代"の作物学研究. *日本作物学会紀事*, 94(3), 329-330.
8. 大澤央, 齋藤正博, & 八木岡敦. (2026). 物体検出AIを活用したスイートコーン収穫適期予測技術の開発. *農業食料工学会誌*, 88(2), 85-91.
9. arXiv. (2026). 3차원 파운데이션 모델 기반 초고속 작물 재구성 및 표현형 정확도 유지에 관한 연구.
<https://arxiv.org/abs/2607.01753>
10. arXiv. (2025). PlantSegNeRF: 다시점 영상 인스턴스 정합 기반 채널 결합 신경방사장을 통한 식물 3차원 인스턴스 점군 재구성. <https://arxiv.org/pdf/2507.00371>
11. arXiv. (2024). SSL-NBV: 자기지도학습 기반 차기 최적 시점 선택을 통한 로봇 식물 3차원 재구성 연구.
<https://arxiv.org/pdf/2410.14790>
12. *Frontiers in Plant Science*. (2026). 포장 조건 점군 기반 3차원 작물 표현형 분석 비교 리뷰.
<https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2026.1731852/full>
13. *Sensors*. (2026). 작물 표현형 분석을 위한 3차원 재구성 기술 종합 리뷰. <https://doi.org/10.3390/s26092730>

강연 및 영상 자료

1. IPPN - International Plant Phenotyping Network. (2025). Dr. Michael Selteraj: AI-Powered Phenomics: Transforming Crop Science for Climate-Resilient Future. YouTube.
<https://www.youtube.com/watch?v=eoTvCz3YTzo>
2. Greg Bronevetsky. (2025). Predictive Pattern Recognition of Plant Growth Traits in Simulated and Controlled Environments. YouTube. <https://www.youtube.com/watch?v=uKepfZAnKbk>
3. Bioingene. (2026). International Webinar- Biotechnological strategies to improve plant traits for enhanced productivity. YouTube. <https://www.youtube.com/watch?v=duUd8ajVo44>
4. Solvi. (2026). Webinar: Validating AI-Based Plant Counts with Real Field Data. YouTube.
<https://www.youtube.com/watch?v=B0KuDrtmaQ>

5.2

예측 육종 및 스마트 생물육종 기술

작물 육종은 재배자가 밭에 나가 눈에 보이는 모습만으로 좋은 개체를 고르는 표현형 선발에서 출발했습니다. 이후 멘델의 유전 법칙과 통계를 끌어와 아버지와 자식 사이의 성적을 계산하는 방식이 더해졌고, 유전자의 특정 위치를 표지로 삼아 원하는 형질을 미리 가려내는 분자 표지 선발(Marker-Assisted Selection, MAS)이 정착했습니다. 유전체 전체에 흩어진 수만 개의 표지를 한꺼번에 읽어 내는 유전체 선발(Genomic Selection, GS)이 그 뒤를 이으면서, 선발의 정확도는 올라가고 한 세대를 키워 다음 세대로 넘어가는 시간은 짧아졌습니다. 이 방식은 아직 흙에 심지 않은 씨앗이 자라서 얼마나 거들지를 미리 계산한 값을 육종가에게 제공하는데, 이 값을 유전체 추정 육종가치(Genomic Estimated Breeding Value, GEBV)라고 부릅니다.

씨앗 하나하나가 지닌 유전 정보만으로 계산해 낸 예측값입니다.

문제는 수확량처럼 여러 유전자가 함께 관여하는 형질이었습니다. 키나 병 저항성처럼 유전자 한둘이 결정하는 형질과 달리, 수확량은 자잘한 효과를 지닌 유전자 수백, 수천 개가 서로 얹혀 있고, 그 얹힘은 같은 씨앗이라도 어느 밭에 심느냐에 따라 다르게 나타납니다. 같은 품종이 가뭄이 든 밭에서는 부진해도 물이 넉넉한 밭에서는 좋은 성적을 내는 식입니다. 유전자와 환경이 서로 영향을 주고받는 이 관계를 유전형과 환경의 상호작용(Genotype by Environment Interaction, G×E)이라고 부르는데, 유전체 선발만으로는 이 상호작용을 정밀하게 풀어내는 데 한계가 뚜렷했습니다. 유전체와 표현형에 더해 재배 환경 정보까지 한꺼번에 계산에 넣는 스마트 생물육종이 등장한 배경이 여기에 있습니다.

스마트 생물육종은 유전체(Genomics), 표현형(Phenomics), 환경체(Enviromics)라는 세 가지 자료를 하나의 인공지능 모델 안에 함께 밀어 넣는 접근입니다. 유전체는 씨앗이 타고난 유전 정보이고, 표현형은 그 씨앗이 자라면서 실제로 보여 주는 키와 잎 색과 수확량이며, 환경체는 그 작물이 자란 밭의 기온과 강수량과 흙의 성질을 가리킵니다. 세 자료를 따로 보면 각각 흩어진 정보일 뿐이지만, 인공지능망의 여러 층을 통과시켜 하나의 잠재 공간(Latent Space, 서로 다른 종류의 자료를 같은 좌표 위에 놓고 비교할 수 있게 압축한 공간)에 모아 두면 서로 어떻게 얹혀 있는지가 드러납니다. 씨앗을 실제로 심어 보기 전에, 어떤 유전형이 어떤 밭에서 어떤 성적을 낼지를 컴퓨터 안에서 먼저 그려 보는 것입니다.

육종가가 화면 위 순위표만 보고 스무 줄을 고를 수 있는 것은 바로 이 계산이 뒤에서 이미 끝나 있기 때문입니다.

기후 변화로 가뭄과 폭염이 잦아지면서, 특정 환경에서도 흔들리지 않는 품종을 미리 골라내는 일이 육종의 핵심 과제로 떠올랐습니다. 이를 위해 만들어진 통합 유전체-환경체 예측(Integrated Genomic-Enviromic Prediction, iGEP) 체계는 과거 기상 자료와 앞으로의 기상 전망, 흙의 성질과 위치 정보를 유전체의 단일염기다형성(Single Nucleotide Polymorphism, SNP, 개체마다 유전자 서열의 한 글자만 다르게 나타나는 변이) 지도와 함께 여러 층으로 쌓은 신경망에 넣습니다. 목표로 삼는 재배 지역과 기후대를 대상 생태구(Target Population of Environments, TPE)라는 이름으로 묶어 두고, 그 생태구 안에서 가뭄이나 고온 같은 극단적인 조건이 닥쳤을 때 특정 유전형이 얼마나 버티고 얼마나 거들지를 미리 추정합니다.

실제 밭에 심어 몇 달을 기다리지 않아도, 어느 품종이 내년 여름의 폭염을 견딜지 어느 정도 가능할 수 있게 되었습니다.

여기에 작물의 생리 작용을 통째로 흉내 내는 생장 모델을 더한 체계도 있습니다. APSIM이나 DSSAT 같은 작물 생장 모델은 햇빛과 온도와 물이 잎과 열매로 바뀌는 과정을 물리와 화학의 방정식으로 풀어내는 프로그램인데, 이 생장 모델과 유전체 예측 모델을 이어 붙인 유전체-작물 모델(CGM-G2P)은 특정 유전자가 실제로 어떤 생리 작용을 거쳐 수확량으로 이어지는지를 시뮬레이션합니다. 숫자와 숫자 사이의 상관관계만 보여 주던 기존 통계 모델과 달리, 유전자가 식물 몸속에서 실제로 무슨 일을 하는지를 밝혀 가며 예측하는 방식이라, 예측값을 받아 든 육종가가 그 근거를 한 단계씩 따라가 볼 수 있습니다.

이 모든 계산에는 자료가 필요합니다. 예측 육종을 뒷받침하는 자료들 가운데 맨 아래층에 놓이는 것은 유전체 그 자체입니다. 차세대 염기서열 분석(NGS)과 더 긴 구간을 한 번에 읽어 내는 3세대 시퀀싱 기술로 전체 유전체를 다시 읽어, 단일염기다형성과 삽입·결실(InDel), 큰 구조가 통째로 바뀌는 구조변이(Structural Variant, SV)를 찾아냅니다. 한 품종의 유전체 지도 한 장으로는 부족하다는 판단 아래, 여러 계통의 유전체를 겹쳐 그린 범유전체(Pangenome) 지도까지 만들어 씁니다.

여기에 유전자가 실제로 얼마나 발현되는지를 보여 주는 전사체(Transcriptomics), 단백질 양을 보여 주는 단백질체(Proteomics), 대사산물을 보여 주는 대사체(Metabolomics), 그리고 유전자 서열 자체는 그대로인데 발현 여부만 바뀌는 후성유전(Epigenetics) 자료까지 시간에 따라 겹겹이 쌓입니다.

밭에서 올라오는 환경체 자료도 촘촘합니다. 포장에 박아 둔 사물인터넷 센서와 전국 단위로 촘촘하게 짠 격자형 농업기상 자료, 미국 항공우주국의 NASA POWER 위성 자료, 흙의 성질을 기록한 토양 조사 데이터베이스가 한데 모여 하루하루의 최저·최고 기온과

누적 온도, 공기가 얼마나 건조한지를 나타내는 포화수증기압차(Vapor PressureDeficit, VPD), 흙 속 수분과 질소·인·칼륨 농도를 시간 순서대로 쌓아 올립니다. 이 자료를 서로 다른 기관, 서로 다른 나라의 연구자가 함께 쓰려면 형식부터 맞아야 합니다. 그래서 찾을 수 있고(Findable) 접근할 수 있고(Accessible) 다른 프로그램과 호환되고(Interoperable) 다시 쓸 수 있어야 한다(Reusable)는 네 가지 원칙, 이른바 FAIR 원칙이 자료 관리의 기준이 되었습니다.

육종 자료를 주고받는 공통 규격인 BrAPI(Plant Breeding API)와 작물 재배 자료 표준인 ICASA가 채택되면서, 서로 다른 연구소가 쌓아 온 자료를 이제는 표준 규격에 맞춰 주고 받을 수 있게 되었습니다.

이렇게 모인 자료는 브리드베이스(Breedbase), 오픈실렉스(OpenSILEX), 크롭지ես허브(CropGS-Hub) 같은 통합 플랫폼에 얹혀 유전체와 표현형과 환경체를 한 화면에서 검색할 수 있는 지식 기반으로 정리됩니다. 논문과 오래된 육종 수첩에 흩어져 있던 지식도 그냥 묻어 두지 않습니다. 플랜트커넥톰(PlantConnectome) 같은 문장 분석 인공지능은 수만 편의 논문을 훑어 어떤 유전자가 어떤 형질과 관련 있다고 언급되었는지를 자동으로 찾아내고, 그 관계를 점과 선으로 그린 지식 그래프(Knowledge Graph)로 정리합니다. 몇십 년 전 은퇴한 육종가가 손으로 적어 둔 수첩 속 관찰 하나까지, 이제는 검색 한 번으로 불러올 수 있게 되었습니다.

자료가 쌓여도 그 안에서 쓸모 있는 패턴을 골라내는 것은 또 다른 일입니다. 유전체 예측의 초기 계산은 GBLUP(Genomic Best Linear Unbiased Prediction)과 RKHS(Reproducing Kernel Hilbert Space) 같은 통계 모델이 맡았습니다. 두 모델 모두 수만 개의 표지 하나하나가 형질에 얼마씩 기여하는지를 방정식으로 풀어, 그 기여도를 모두 더해 개체의 예상 성적을 냅니다.

여기에 여러 개의 질문을 던져 가치를 치듯 답을 좁혀 가는 랜덤 포레스트(Random Forest)와, 오차를 조금씩 줄여 가며 예측을 다듬는 익스트림 그레이디언트 부스팅(Extreme Gradient Boosting, XGBoost), 서포트 벡터 머신(Support Vector Machine, SVM), 라쏘(LASSO) 회귀 같은 기계학습 기법이 더해지면서 예측의 폭이 넓어졌습니다. 표지 수만 개 가운데 정말 중요한 몇백 개를 가려내고 나머지는 잡음으로 걸러 내는 일에, 이런 통계·기계학습 모델이 여전히 쓸모를 지키고 있습니다.

통계 모델 다음에 등장한 것은 심층신경망입니다. 대두 육종에 쓰이는 소이디엔지피(SoyDNGP)는 유전체 정보를 입체 사진처럼 배열해 3차원 합성곱 신경망(3D CNN)에 통과시켜 수확량과 수확 시기, 기름과 단백질 함량을 예측합니다. 여러 종류의 오믹스 자료를 한꺼번에 집어넣는 디엔엔지피(DNNGP), 벼와 옥수수과 목화과 기장 네 작물의 농업 형질 원세 가치를 대상으로 성능을 시험한 크롭에이알넷(CropARNet), 합성곱 신경망에 자기주의 기제(Self-Attention, 입력값 가운데 어디에 더 무게를 둘지 스스로 정하는

계산 방식)를 결합한 크롭포머(Cropformer), 유전형과 표현형 사이의 뒤틀린 비선형 관계를 다루는 디피시포머(DPCformer)가 잇달아 발표되면서 예측 성능이 한 단계씩 올라갔습니다.

이런 모델들은 유전자끼리 서로 억누르거나 끌어올리는 상위성(Epistasis) 효과를 잡아냅니다. 유전자 두세 개의 효과를 더하기만 해서는 나오지 않는 값입니다.

오토지피(AutoGP)와 여러 형질을 한꺼번에 계산하는 엠티크로(MtCro) 같은 모델은 옥수수과 벼와 밀처럼 오랫동안 자료가 쌓인 작물에 적용되어, 수확량과 병 저항성과 낱알 품질까지 한 번의 계산으로 함께 내놓습니다. 층이 깊어질수록 모델은 훈련에 쓴 자료의 자잘한 특징까지 외워 버리는 과적합(Overfitting, 시험 자료에는 강하지만 실제 현장에서는 어긋나는 현상)에 빠지기 쉽습니다. 이를 막으려고 신경망 노드를 무작위로 꺼 두는 드롭아웃(Dropout)과, 계산 값이 지나치게 커지지 않도록 눌러 주는 L2 정규화 같은 기법이 함께 쓰입니다. 새로 나온 모델일수록 정확도만 자랑하지 않고, 처음 보는 밭에서도 성적이 얼마나 흔들리지 않는지를 함께 보고하는 쪽으로 관행이 옮겨 가고 있습니다.

유전체를 읽는 인공지능은 여기서 한 걸음 더 나아가, 사람이 쓰는 언어를 배우듯 유전자의 염기서열 자체를 언어로 취급하기 시작했습니다. 아그로엔티(AgroNT, Agro-Nucleotide Transformer)와 플로라버트(FloraBERT)는 유전자 앞뒤에 붙어 발현을 조절하는 비암호화 영역, 이른바 프로모터와 인핸서의 염기서열을 정답 없이 스스로 학습하는 자기지도학습(Self-Supervised Learning) 방식으로 미리 훈련받습니다. 학습을 마친 모델은 한 번도 본 적 없는 새로운 식물 종의 염기서열을 받아도, 곧바로 유전자 발현량과 조절 부위의 활성 정도를 찾아냅니다.

여기서 더 나아간 플랜트카두시어스(PlantCaduceus)는 서로 멀리 떨어진 속씨식물 열여섯 종의 유전체를 한꺼번에 학습해, 유전자가 오랜 진화 과정에서 왜 그 서열을 지켜 왔는지를 지도학습 모델보다 더 정확하게 밝혀내는 성과를 냈습니다.

예측을 넘어 유전체를 직접 고치는 일에도 인공지능이 들어왔습니다. 개발진이 식물용으로는 처음이라고 소개한 오픈크리스퍼원(OpenCRISPR-1)은 크리스퍼-카스(CRISPR-Cas) 유전자가위의 3차원 입체 구조와 염기서열을 방대한 기존 자료로 학습한 뒤, 세상에 없던 새로운 절단 효소와 안내 RNA(gRNA, 가위를 원하는 위치로 데려가는 짧은 유전 서열)를 스스로 설계해 냅니다. 자연에 있는 절단 효소를 그대로 가져다 쓸 때 보다 엉뚱한 위치를 잘라 버리는 오프타겟(Off-target) 부작용을 줄일 수 있다는 점이 이 접근의 값어치입니다. 원하는 위치만 정확히 잘라 내야 하는 유전자 편집의 특성상, 이 정밀도가 성패를 가르는 기준이 됩니다.

이 모든 예측과 설계 능력을 하나로 묶어 두는 거대한 육종 기초 모델(Breeding Foundation Model)도 만들어지는 중입니다. 사람의 말을 배우는 거대언어모델이 그렇

듯, 육종 기초 모델도 모델의 크기와 학습 자료의 양과 계산량을 함께 늘릴수록 성능이 예측 가능한 만큼 좋아진다는 확장 법칙(Scaling Law)을 따릅니다. 크기가 어느 문턱을 넘어서면 그전까지 못 하던 일을 갑자기 해내는 발현 능력(Emergent Abilities)이 나타납니다. 문턱을 넘는 시점은 미리 알 수 없습니다. 여러 유전자를 동시에 편집했을 때 그 조합이 작물 전체에 어떤 영향을 미칠지를 단계별로 따져 가며 추론하는 사고사슬(Chain-of-Thought) 능력이 그런 사례로 꼽힙니다.

다만 큰 모델일수록 그럴듯하지만 틀린 답을 자신 있게 내놓는 환각(Hallucination) 현상에서 자유롭지 않아, 답을 내놓기 전에 공인된 육종 데이터베이스를 먼저 검색하게 만드는 검색증강생성(Retrieval-Augmented Generation, RAG) 기술이 함께 쓰입니다. 모델 전체를 처음부터 다시 훈련하는 대신 계산 경로 몇 곳만 다시 조율하는 저랭크 적응(Low-Rank Adaptation, LoRA) 기법 덕분에, 값비싼 서버 없이도 특정 작물과 지역에 맞춘 버전을 따로 만들 수 있게 되었습니다.

이렇게 훈련된 모델이 실제로 예측값을 내놓는 과정은 크게 두 단계로 나뉩니다. 먼저 오프라인 단계에서는 유전체와 표현형과 환경체를 합친 방대한 자료를 GPU 수백, 수천 대로 이루어진 서버 묶음에 나누어 싣고, 3차원 병렬화 기법과 제로(ZeRO, 메모리 낭비를 줄여 큰 모델도 한정된 장비로 훈련할 수 있게 하는 최적화 기법)를 동원해 몇 주에 걸쳐 모델을 훈련합니다. 훈련이 끝나면 이 모델은 온라인 단계로 넘어가, 실제 육종 현장에서 후보로 오른 어미 계통과 아비 계통의 유전체 지도와 목표 재배지의 기상 시나리오를 입력받습니다. 그러면 수만 가지 교배 조합의 성적을 컴퓨터 안에서 미리 겪어 보는 가상 교배 심사(In-silico Cross Screening)가 단 몇 초 만에 끝납니다. 화면 위에 늘어서 있던 순위표는 바로 이 몇 초짜리 계산이 밤새 몇 번이고 되풀이된 결과물입니다.

실제 밭에 심어 한 세대를 다 키워야 알 수 있었던 답을, 씨앗을 흙에 묻기도 전에 컴퓨터 안에서 먼저 받아 봅니다.

이렇게 나온 예측이 실제로 믿을 만한지는 몇 가지 숫자로 확인합니다. 실제로 거둔 성적과 모델이 미리 계산한 값이 얼마나 나란히 움직이는지를 나타내는 예측 정확도는 0.70에서 0.85 사이를 목표로 잡습니다. 전체 성적 차이 가운데 모델이 설명해 내는 비율을 나타내는 결정계수는 0.75에서 0.90 사이를 기준으로 삼습니다. 수확량이나 이삭이 패는 날짜, 줄기 키처럼 실제 숫자로 떨어지는 형질은 예측값과 실측값의 차이를 평균한 평균 절대오차(MAE)와 그 차이를 제곱해 평균 낸 평균제곱근오차(RMSE)로 다시 확인합니다.

병에 걸린 잎을 얼마나 정확히 골라내는지는 정밀도(병으로 예측한 잎 가운데 실제로 병에 걸린 비율)와 재현율(실제 병든 잎 가운데 모델이 찾아낸 비율), 그 둘을 합친 F1 점수로 재고, 유전자가위가 원하는 위치를 얼마나 정확히 잘랐는지는 온타깃 효율(의도한 위치를 자른 비율)과 엉뚱한 위치를 자른 오프타깃 비율로 각각 따로 잹니다.

육종가가 더 눈여겨보는 잣대는 따로 있습니다. 그 정확도 덕분에 실제로 품종이 얼마나 빨리 좋아지느냐는 것이 그 잣대입니다. 유전적 증진 속도라고 부르는 이 값은 한 번 선발할 때 얼마나 엄격하게 골라내는지, 예측이 얼마나 정확한지, 그 형질에 유전적 차이가 얼마나 남아 있는지를 모두 곱한 값을, 한 세대에서 다음 세대로 넘어가는 데 걸리는 시간으로 나누어 구합니다. 세대 간격이 짧을수록, 그리고 예측이 정확할수록 같은 기간에 품종이 개선되는 폭이 커진다는 뜻입니다. 형질 전체의 차이 가운데 유전자가 차지하는 비중을 나타내는 유전력도 함께 살피는데, 유전력이 높을수록 환경보다 유전자가 그 형질을 더 많이 결정한다는 뜻이라 선발의 효과도 더 크게 나타납니다.

여러 대형 모델의 실력을 나란히 겨루게 하는 시드벤치(SeedBench) 같은 공통 시험 문제집도 만들어져, 어떤 모델이 유전자 검색과 표현형 해독과 교배 설계를 두루 잘하는지 표준화된 잣대로 비교할 수 있게 되었습니다.

이 계산이 실제로 받을 바꾼 사례는 국제농업연구협의그룹(CGIAR) 산하 국제 옥수수·밀 개선센터(CIMMYT)에서 확인됩니다. 동아프리카와 라틴아메리카 곳곳의 옥수수와 밀 육종 프로그램에 전유전체 표지 자료와 무인기로 켜 다중분광 지표, 기상 스트레스 기록을 한데 묶은 예측 육종 체계를 적용한 결과, 가뭄과 고온이 심한 조건에서 수확량과 내건성을 미리 맞히는 정확도가 기존 통계 모델보다 15퍼센트에서 25퍼센트가량 올라갔습니다. 야외 시험 포장의 구획 수는 줄었고, 교배해서 다음 세대를 얻기까지 걸리던 시간은 절반 수준으로 짧아졌습니다. 가뭄이 심해질 아프리카의 다음 재배철을 앞두고, 심어 보기 전에 어떤 계통이 버틸지를 먼저 걸러 낼 수 있게 된 것입니다.

대두 육종 현장에서는 소이디엔지피가 이미 인터넷에 공개된 웹 서비스로 돌아가고 있습니다. 육종가가 계통의 유전체 자료를 올리면 3차원 합성곱 신경망이 수확량과 수확 시기, 기름과 단백질 함량을 계산해 어느 어버이 조합이 유망한지를 자동으로 추려 줍니다. 옥수수와 벼와 밀을 다루는 크롭지스에스허브(CropGS-Hub)와 오토지피 플랫폼도 비슷한 방식으로 유전형과 표현형 자료를 웹 데이터베이스에 묶어 두고, 연구자 누구나 접속해 가상 교배 시뮬레이션을 돌려 볼 수 있게 열어 두었습니다. 실험실 하나가 몇 년에 걸쳐 쌓은 자료를 지구 반대편의 다른 연구소가 곧바로 이어받아 쓸 수 있는 구조입니다.

신젠타(Syngenta)와 인스타딥(InstaDeep)은 함께 개발한 아그로엔티를 다양한 식물 종의 조절 서열에 적용해, 씨앗 하나 심어 보지 않고도 어떤 유전자가 환경 변화에 얼마나 민감하게 반응할지를 미리 정렬해 보였습니다. 수천 개에 이르는 잠재적 조절 부위의 가중치를 한꺼번에 계산해, 기후 회복력이 강한 품종을 설계하는 데 필요한 분자 수준의 근거 자료를 만들어 낸 것입니다. 종자 회사와 인공지능 기업이 손을 잡는 사례가 흔해지고 있다는 사실 자체가, 이 기술이 실험실 담장을 벗어나 상업 육종의 도구로 쓰이기 시작했다는 신호로 보입니다. 논문으로만 남지 않고 실제 육종 파이프라인에 얹혔다는 점에서 이 협업의 무게가 다르게 읽힙니다.

오픈크리스퍼원이 설계한 유전자가위는 실제로 작물의 가뭄 저항성과 병 저항성을 담당하는 유전자를 정밀하게 편집하는 데 성공했습니다. 자연에 존재하는 절단 효소를 그대로 썼을 때보다 엉뚱한 위치를 건드리는 부작용이 줄었다는 결과가 뒤따랐습니다. 씨앗 하나의 유전체에서 정확히 원하는 줄, 원하는 글자만 골라 고치는 일이 이제 가능성 수준을 넘어 확인된 결과가 되었습니다. 실험실 밖 밭에서 이 결과가 몇 세대에 걸쳐 그대로 이어지는지는 앞으로 몇 번의 재배철을 더 지나 봐야 확실해질 문제입니다.

일본 고치현에서는 사와치(SAWACHI)라는 클라우드 플랫폼이 온실 1,600곳 넘는 곳의 환경 자료와 농가 3,000곳의 생산 기록을 국가 농업 빅데이터망 와그리(WAGRI)와 이어 붙여, 생육과 수확량을 예측하는 인공지능 모델을 돌리고 육종 후보 계통이 실제 현장에 얼마나 잘 맞는지를 가늠합니다. 같은 나라의 아이치현에서는 카네이션 품종 개량에 다른 종류의 인공지능이 쓰입니다. 환경 조건이나 번식 과정에서 카네이션의 유전자 발현이 흔들리며 꽃잎 색이 달라지는 후성유전 현상을 규명해, 원하는 색을 지닌 새 품종을 정밀하게 골라내는 데 이 지식을 응용하고 있습니다. 온실 수천 곳의 자료를 모으는 일과 꽃잎 색 하나의 유전 기전을 파고드는 일이, 규모는 달라도 같은 예측 육종의 틀 안에서 나란히 돌아가고 있습니다.

성과가 뚜렷한 만큼, 아직 풀리지 않은 문제도 뚜렷합니다. 온실이나 컴퓨터 안의 가상 환경에서 훈련한 모델은 한 번도 겪어 보지 못한 이상 기후나 여러 역경이 한꺼번에 겹치는 복합 환경 앞에서 예측력이 뚝 떨어지는 경우가 있습니다. 가상 공간과 실제 밭 사이에 벌어지는 이 틈을 시뮬레이션과 실제 사이의 격차(Sim-to-Real Gap)라고 부르며, 훈련 때 보지 못한 조건을 만나면 판단이 흔들리는 도메인 시프트(Domain Shift) 현상이 그 원인입니다. 이를 줄이려면 더 다양한 환경에서 얻은 자료를 꾸준히 더해 넣고, 현장에서 들어오는 자료로 모델이 스스로 갱신하는 온라인 적응형 학습 체계를 갖추어야 합니다.

모델이 왜 그런 답을 냈는지 설명하지 못한다는 것도 만만치 않은 문제입니다. 심층신경망은 높은 정확도를 내면서도, 특정 교배 조합을 추천한 이유를 육종가가 알아들을 수 있는 생물학적 근거로 풀어 주지는 못합니다. 판단은 내리지만 그 판단에 이른 경로를 감춘 상자와 같다고 해서 이런 모델을 블랙박스(Black-box)라고 부릅니다. 이 상자를 열어 보려는 시도로 샤프(SHAP)와 그라드캠(Grad-CAM) 같은 설명 기법, 그리고 지식 그래프를 연결해 예측 결과에 생물학적 인과 관계를 붙여 보여 주는 연구가 이어지고 있습니다. 근거를 눈으로 확인하지 못하는 한, 아무리 정확도가 높아도 오랜 경험을 지닌 육종가의 신뢰를 온전히 얻기는 어려워 보입니다.

계산 비용 역시 발목을 잡습니다. 매개변수가 수십억 개에 이르는 육종 기초 모델을 훈련하고 돌리려면 값비싼 GPU 서버가 있어야 하는데, 이런 장비를 갖추기 어려운 소규모 연구소나 영세한 육종 기업은 이 기술에 다가서기부터 쉽지 않습니다. 모델의 계산값을 정수 몇 개로 줄여 가볍게 만드는 양자화와, 큰 모델이 배운 지식을 작은 모델에 옮겨 담는

지식 증류(Knowledge Distillation) 같은 기법이 이 문턱을 낮추는 방향으로 연구되고 있습니다. 클라우드로 서버를 빌려 쓰는 방법도 있지만, 육종 자료를 외부 서버에 맡기는 일 자체를 꺼리는 기업도 적지 않습니다. 서버 한 대 값을 감당할 수 있느냐가 최신 육종 기술에 다가설 수 있느냐를 가르는 또 다른 경계선이 되어 가고 있습니다.

정작 마지막까지 남는 벽은 사람입니다. 첨단 인공지능 알고리즘을 다룰 줄 알면서 동시에 분자유전학과 현장 농학까지 꿰뚫은 융합 인재를 아직 드물어서, 연구실에서 나온 성과가 실제 발의 품종 개선으로 이어지는 속도를 더디게 만듭니다. 여기에 인공지능이 설계한 유전자 편집 작물을 어떻게 심사하고 승인할지, 그 자료와 모델의 소유권을 누구에게 둘지를 정하는 법과 제도는 아직 기술의 속도를 따라잡지 못하고 있습니다. 씨앗을 예측하고 설계하는 능력이 아무리 뛰어나도, 그 씨앗을 심사하고 책임질 사람과 규칙이 뒤따르지 않으면 발까지 가는 길은 여전히 막혀 있습니다.

근거 및 참고문헌

학술 논문

1. Xu, Q., Zheng, B., & Zhong, S. (2026). Artificial intelligence empowering modern agricultural biological breeding. *Smart Agriculture*, 8(3), 69-85. <https://doi.org/10.12133/j.smartag.SA202602016>
2. Harnessing artificial intelligence in plant breeding: Innovations in digital phenotyping and breeding methods. (2026). *Plant Methods*. <https://doi.org/10.1007/s13007-026-01286-0>
3. Shokor, F. (2025). Deep learning models for genomic prediction accounting for heterosis in crossbreeding systems and multi-trait selection (Doctoral dissertation). Université Paris-Saclay, INRAE, AgroParisTech.
4. Qiu, J., Liu, Y., Gao, X., Huang, Y., Zhang, H., Tian, F., Li, W., & Feng, Z. (2026). AgriAgent: End-to-end large model agent system architecture for agricultural environment control. *Smart Agriculture*, 8(2), 220-236. <https://doi.org/10.12133/j.smartag.SA202507042>
5. Yang, J., Yang, W., Yang, S., He, L., & Zhang, D. (2026). Intelligent Q&A method for crop diseases and pests using LLM augmented by adaptive hybrid retrieval. *Smart Agriculture*, 8(1), 52-61. <https://doi.org/10.12133/j.smartag.SA202506026>
6. 田中佑, 郭威, 山口友亮, 桂圭佑, 中嶋洸太, 戸田陽介. (2025). AI時代の作物学研究. *日本作物学会紀事*, 94(3), 329-330.
7. APSIM crop model innovations for breeding and deep learning. (2026). *in silico Plants*. <https://doi.org/10.1093/insilicoplants/diaa016>
8. CropARNet: 자기주의 기제와 심층 잔차망 기반 유전체 선발 모형. (n.d.). ScienceDirect. <https://www.sciencedirect.com/science/article/pii/S2772899425000242>
9. Cropformer: 합성곱 신경망과 자기주의 기제를 결합한 작물 표현형 예측 모형. (n.d.). ScienceDirect. <https://www.sciencedirect.com/science/article/pii/S2590346224006448>
10. DPCformer: 합성곱 신경망과 자기주의 기반 유전형-표현형 비선형 관계 예측 모형. (n.d.). arXiv. <https://arxiv.org/html/2510.08662v1>
11. PlantCaduceus: 속씨식물 16종 유전체 사전학습 기반 다중 식물 DNA 언어모델. (n.d.). Computomics. <https://www.computomics.com/news-reader/foundation-models-in-plant-breeding-an-introduction-copy.html>

12. AI breeder: 작물 육종을 위한 유전체 예측 인공지능 연구. (n.d.). ScienceDirect.
<https://www.sciencedirect.com/science/article/pii/S2949952623000109>

강연 및 영상 자료

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

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.