

園芸農業の 人工知能



キム・ギョンジン 弁護士

本書は人工知能によって整理・制作されたものです。
世界の主要言語で書かれた資料を収集し、まとめました。

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

上のリンクは、本書の制作で参照した資料を収集・保存した公開NotebookLMです。

誰でも自由にアクセスして利用できます。

目次

第1章	コンピュータビジョンと深層学習による作物病虫害診断	3
1.1	作物の病虫害・雑草の精密検出と診断	5
1.2	果実の成熟度判定と生育・収量予測	15
第2章	園芸農業ロボットと自律作業の自動化	26
2.1	果菜類・キノコ類の収穫ロボットとエンドエフェクタ	28
2.2	自律移動ロボットとドローン群の経路最適化・精密防除	38
第3章	スマート温室と施設園芸の環境制御（CEA）	49
3.1	IoT多種センサーによる監視とスマート環境計測	51
3.2	デジタルツインとAIによるスマート環境・生育最適化	62
第4章	データ駆動型精密農業と意思決定支援	73
4.1	スマート灌漑と施肥供給の最適化	75
4.2	時空間データ融合と流通・品質管理	85
第5章	AIによるデジタル表現型解析と育種バイオテクノロジー	96
5.1	ハイスループット作物表現型解析	98
5.2	予測育種とスマート生物育種技術	108

第1章

コンピュータビジョンと深層学習による作物病虫害診断

1.1

作物の病害虫・雑草の精密検出と診断

米国のCarbon Roboticsが開発したLaserWeederは、1時間に10万株を超える雑草をレーザーで焼却します。2022年の発売以来、このロボットが除去した雑草は累計100億株を超え、2026年第1四半期の売上高は1億ドルを突破し、15カ国の約100戸の農家が利用しています。同じ時期、韓国では農村振興庁が開発した人工知能診断アプリが、31作物と182種の病害虫を識別しています。人が葉を一枚ずつ裏返して病斑を確認し、雑草を手で抜いていた作業を、カメラとアルゴリズムが引き受ける時代に入ったのです。

園芸作物の収量と品質は、国レベルの食料安全保障と農家所得を同時に支える柱です。しかし気候が変化するなか、病原菌は新たな変異を獲得して未知の地域にまで広がり、雑草は作物と同じ日光、水、養分を奪い合います。長い間、この戦いの最前線にあったのは人の目です。英語ではこの方法をVisual Scoutingと呼びます。熟練した農学者や栽培者が圃場を歩いて葉を調べる目視予察は今も広く使われていますが、一人が1日に確認できる畝の数には限りがあり、同じ病斑を見ても判断は人によって分かります。圃場が広くなるほど、この方法の隙間は大きくなり、その隙間から病気が音もなく広がっていきます。

雑草が作物の隣で育ち始めると、目に見えない争いが根の下で毎日起こります。雨水がしみ込み、肥料成分が溶け出す短い時間に、雑草の根が作物の根より先に水と養分を吸い取ることが繰り返されます。葉の大きさの違いとして目に見えるまでには数週間かかりますが、その間に作物は十分に育たないまま収穫期を迎えます。病気であれ雑草であれ、症状がはっきり見える時点では、すでに対処が手遅れになっていることが少なくありません。

こうした問題に対応する大きな流れを精密農業と呼びます。圃場全体に同じ処方を施す方法から、小区画や一株ごとの状態に合わせ、必要なだけ手を加える方法へ移る考え方です。病害虫と雑草を精密に見つけることは、この流れの第一歩に当たります。どこに何があるのかも分からなければ、その場所だけに働きかける精密な処方そのものが不可能だからです。

この隙間を埋めるために登場したのが、コンピュータビジョンとディープラーニングを組み合わせた精密診断技術です。カメラが撮影した一枚の写真から病気の部分

と健全な部分、作物と雑草を区別する仕事を、人ではなくアルゴリズムが担う仕組みです。その根幹にあるのが畳み込みニューラルネットワーク、英語の略称でCNN（Convolutional Neural Network）です。写真を細かく分けた各パッチについて、色、模様、病斑の縁の曲線を調べ、その結果を層ごとに積み上げ、一つの判断にまとめる構造です。ResNet、EfficientNet、DenseNet、MobileNetのように、別の大規模画像データで事前学習したモデルを持ち込み、農作物の写真に合わせて教え直す転移学習を使えば、農家で集められる程度の数千枚の写真でも、かなり正確な分類器を構築できます。すでに別の言語を学んだ人が、新しい言語をより速く習得するのと似た原理です。

速く動く現場では、判断の正確さと同じくらい速度が問題になります。YOLO（You Only Look Once）系列のモデルは、写真全体を一度だけ走査して、病斑、害虫、雑草がどこにあるかを四角い枠で示し、それが何かを表すラベルも同時に付けます。名前どおり一度見るだけで処理を終えるため、カメラがリアルタイムで撮影する映像にも遅れず追従します。葉が重なり、影が落ち、背景に土やわらが混じる雑然としたキャノピーの中でも、YOLOv5からYOLOv8、YOLOv9e、YOLOv10、YOLOv11に至る最新系列は、個々の病斑、一匹の虫、一株の雑草の位置を見落とさずに見つけます。

CNNとYOLOには共通の弱点があります。写真を小さなパッチに分けて見る構造のため、パッチとパッチの間、葉全体に広がる大きな模様、株全体の形態変化を見落としやすいのです。ビジョントランスフォーマー、英語の略称でViT（Vision Transformer）と、その近縁であるSwin Transformerは、写真を16×16ピクセルのパッチに切り分けた後、パッチ同士がどのような関係を持つかをまとめて計算します。自己注意機構、英語でSelf-Attentionと呼ばれるこの計算方法により、写真の片隅の病斑と反対側の病斑が同じ病気に由来するかを、広い視野で判断できます。さらにCBAMやCABなどの注意モジュールをCNNと並べたハイブリッド構造は、細かな病斑模様を読む目と、葉全体を見渡す目を一つの身体に備えます。近くで木目をなぞる指先と、遠くから全体像を見る目を、一人が同時に持つようなものです。

こうしたモデルが実際にどれほど正しく判定するかは、数字に表れます。ブドウ葉の病気を識別するEfficientNet-B0とB3系列は、検証データで精度99.5パーセント、AUC-ROC 1.00を記録しました。クオッカの群れの動きを模した最適化手法DSOCA-QSOを組み合わせたモデルは、野菜葉の病害分類で精度99.9パーセント、F1スコア99.35パーセントに達し、文脈に応じて特徴を選び出すTL-DCFP-CNNは、ワタ、トウモロコシ、イネ、コムギ、サトウキビの5作物を同時に扱いながら、精度98.09パーセントを保ちました。リアルタイム検出では、YOLOv11がトマト葉病害の検出で約94パーセントの精度を示し、小型化したYOLO-NASは熱帯地域の圃場

で雑草を検出し、精度96パーセントを維持しながら一枚の写真を25ミリ秒で処理しました。人が一度まばたきする時間の10分の1にも満たない間に判断を終える速さです。YOLO-NASが試験された熱帯地域の圃場は、温帯地域とは光と湿度の条件が異なります。太陽が高く昇り、影は短く濃く、空気中の湿度も高い場所です。この環境でも精度を維持したという結果は、ある気候帯で作られたモデルが、まったく異なる気候帯でも通用する可能性を示す根拠と読めます。

無人機や地上ロボットは、圃場の上を動き続けながら写真を撮ります。判断が一瞬でも遅れれば、ロボットはすでにその病斑を通り過ぎています。そのため現場では、病気をどれだけ正確に当てると同じくらい、どれだけ速く判断するかが実際の性能を分けます。一枚の写真を処理する時間の数ミリ秒の差が、最終的には一台のロボットが1日に巡回できる圃場面積を決めます。

作物と雑草が葉を接して育つ場合、四角い枠だけでは足りません。一つ一つの画素を作物か雑草かに塗り分けるセグメンテーションモデルがこの仕事を担います。PSPEdgeWeedNetは、境界を別に検出する枝と条件付き確率場を併用し、ラッカセイ圃場で作物と雑草の境界線を明瞭に分け、文脈も読む二重分岐構造のCAMDWSは、オーストラリアの小麦畑を代表する雑草であるライグラス（*Lolium rigidum*）と野生ダイコン（*Raphanus raphanistrum*）を、それぞれ91パーセントと90パーセントを超えるIoU、すなわち実領域と予測領域が重なる割合で識別しました。ViTはPlantVillageデータで精度99.8パーセントを示し、ViTと畳み込み注意ブロックを組み合わせたHybridViT-CABは、パラメータ数41万2千、モデル容量1.57メガバイトという軽量構成で、1回の処理時間は141ミリ秒、AUC 0.97、精度91パーセントを確保しました。Swin Transformerをバックボーンとし、ConvNeXt-V2、SE-BiLSTM、深層Q学習の推薦層まで載せた無人機搭載診断システムは、SAR-CLD-2024ワタデータで精度99.30パーセントを記録しました。軽量でありながら精度を失わない方向へ、研究の重心が移っているようです。

どれほど優れたアルゴリズムも、カメラが何を捉えるかに縛られます。人の目に近い波長を捉えるRGBセンサーは、安価で軽く、携帯電話やドローンにすでに搭載されているため、病徴分類と雑草検出の現場で標準装備になりました。しかし病気が外見に現れる前に葉の内部で進む初期感染や、作物とほぼ同じ色の緑色雑草を可視光だけで識別する場合には、人の目と同じ限界があります。この隙間を埋めるのがマルチスペクトル画像とハイパースペクトル画像です。青色光475ナノメートル、緑色光560ナノメートル、赤色光668ナノメートル、レッドエッジ717ナノメートル、近赤外線840ナノメートルのように、特定波長帯の反射率だけを個別に測るセンサーの値は、正規化植生指数（NDVI）、緑色正規化植生指数（GNDVI）、レッドエッ

ジNDVI、土壌調整植生指数（SAVI）などの指標に変換され、クロロフィルの崩壊や水分の流出による初期ストレスを、目に見える病徴が現れる前に検出します。

三次元位置情報を加えたRGB-Dセンサーは、カラー写真の各画素に距離値を重ねます。収穫ロボットの指や除草ロボットのレーザーが正確にどこを狙うべきか、その座標を作り出すのがこの深度情報です。このセンサーを搭載した無人航空機は、地上2メートルから50メートルの低高度を飛び、1画素が0.3センチメートルから5センチメートルを捉える解像度で圃場全体を走査し、地上ロボットと手持ちの移動端末がその隙間を埋めます。そこに気温、湿度、土壌水分、降雨量を測るIoTセンサーと気象記録を重ねると、時間と空間にまたがる多層のデータが一つのパイプラインに流れ込みます。こうして集めたデータは、診断だけでなく予測にもつながります。直近数日間の気温と湿度の推移を過去の発病記録と重ねれば、病斑が見える前に発病リスクが高まる時点を知らせることができます。目に見える病気を探す段階から、まだ見えない病気を事前に見分ける段階へ、一歩進みます。

写真を集めても、そのまますぐには使えません。224×224、512×512、736×736などの決められた大きさに切り直し、画素値を一定の範囲にそろえる処理を施します。日光の方向が変わり、病気の種類ごとに写真数が均等でない問題を補うため、写真の回転・反転・傾斜・ぼかし処理に加え、GAN、cGAN、DoubleGANのように存在しない写真を自ら描く生成モデルで、病葉や雑草の合成画像を作り、学習データを増やします。条件付き敵対的生成ネットワークであるcGANは、病気の種類という条件を事前に指定すると、その病気に該当する偽の病斑写真を新たに生成します。本物らしい写真を作ろうとする側と、それが偽物か見分けようとする側が競い合いながら、ともに能力を高める構造です。交差エントロピー損失、クラス別加重損失、境界損失などの関数でモデルがどれだけ誤ったかを測り、AdamやAdamWなどの最適化手法で誤差を少しずつ減らします。

学習を終えたモデルは、最終的に圃場にある小さな機械の中で動かなければなりません。NVIDIA Jetson Xavier NXやJetson Nano、Raspberry Piのような手のひら大のコンピュータ、Xilinx Zynq-7000のようなFPGAアクセラレータがその役割を担います。多桁の小数値を整数に丸める量子化は、一度の演算で扱うビット数を減らし、計算時間とメモリを同時に削減します。精度は少し低下しますが、計算は大幅に速くなります。木の不要な枝を切るように、結果へほとんど影響しない接続を取り除く枝刈り、TensorFlow LiteやTensorRT向けにモデルを組み直す変換を経ると、演算時間は大幅に短くなります。FPGAで高速化したモデルは、RGB単一モデルと比べて推論速度が43.2倍速く、遅延は10ミリ秒未満、消費電力は88パーセント削減されたと報告されています。最近では一枚の写真を42.6ミリ秒で処理するシステムが登場し、携帯電話並みの機器でもリアルタイム診断が可能になり、パラメータ

190万個の超軽量モデルPMVTや、枝刈り済みのTransformerが、TensorFlow Lite、ONNX Runtime、軽量のgRPC通信上で、農業用無人機や小型機器にそのまま搭載されています。

こうして作られたモデルが有用かどうかは、いくつかの指標で判断します。正解率は全判定のうち正しく当てた割合、適合率は病気と判定したもののうち実際に病気だった割合、再現率は実際に病気の葉のうちモデルが見落とさず捉えた割合です。ある病気は写真が数千枚ある一方、まれな病気は数十枚しかない場合もあります。病気ごとに写真数がこれほど異なる状況で、F1スコアは適合率と再現率を一つにまとめ、判断が一般的な病気だけに偏っていないかを見分ける指標になります。AUC-ROCは複数のしきい値にわたる性能を示し、混同行列は実際の病名とモデルが予測した病名を表で照合し、どの病気をどの病気と誤認したかをそのまま表します。病気の葉を健康だと誤判定すれば、その圃場全体に病気が広がる時間を与えることになるため、病害虫診断では適合率より再現率を重く見る必要があります。見落とすより、少し過剰に疑うほうが安全だという意味です。

位置まで特定する必要がある検出とセグメンテーションには、別の指標が付きます。IoUはモデルが描いた領域と実際の病斑領域が重なる程度を示し、mAPは複数のしきい値で測った適合率の平均値です。二つの印章を同じ場所に押したとき、どれほど重なるかを見るのに似ています。1秒当たりの処理フレーム数と推論時間は、そのモデルを実際の現場速度に合わせて使えるかを決めます。しかし、これらすべての指標が良くても、圃場で役に立たなければ意味がありません。そのため、雑草除去率、作物損傷率、1ヘクタール当たりの除草剤使用量、散布効率といった農業現場の指標も並べて確認します。コンピュータが正しく当てることと、農家の費用や収量が実際に改善することは別の問いであり、後者に答えられなければ、どれほど精度が高くても現場には根づきにくいのです。

数字の背後には、実際に圃場へ置かれたカメラとアプリがあります。トマト、ブドウ、ワタ、トウガラシ、イチゴなど価格の高い園芸作物を中心に、携帯電話アプリとドローンを組み合わせた診断システムが広がっています。トマトの早期疫病、葉かび病、葉脈をねじれさせるモザイクウイルス、葉縁が黄色く巻き上がる黄化葉巻ウイルス、ブドウのべと病と黒腐病、葉脈の間が縞状に黄変して枯れるエスカ、ワタに付くアブラムシとナミハダニ、葉に潜るハモグリバエに至るまで、YOLOv8、YOLOv11、EfficientNet、MobileNetを載せたモデルが、圃場で直ちに病名を見分けます。栽培者は病気が出た株の前で写真を一枚撮り、数秒後に画面へ表示された病名と防除方法を見て、次の行動を決めます。

トマト、ジャガイモ、トウモロコシを植えた試験圃場では、診断が実際の対応へどうつながるかを示す事例が報告されました。ディープラーニングモデルが病気ありと判定した区域だけに初期殺菌剤を散布し、その区域の灌水量も個別に調整しました。診断が画面上の数字で終わらず、実際に薬剤と水の量を変える決定につながった事例です。ただし、こうした試験はまだ一つの圃場、一つの季節にとどまる場合が多く、複数の圃場と季節、異なる照度を幅広く含む大規模データがさらに必要だとの指摘もあります。

この種の診断ツールは、専門家にすぐ会うのが難しい地域で力を発揮します。一人の農学者が確認しなければならない農家と圃場の数は地域によって大きく異なりますが、人が歩いてすべてを回るには、どの地域でも人だけで対応するには過大な数です。携帯電話一台で専門家の判断に近い診断をすぐ受けられることが、この技術が広く普及する理由の一つと考えられます。人に代わるというより、人の目が届かない時間と場所を埋める役割に近いものです。

作物と雑草をカメラで区別し、必要な場所だけに手を加える手法を、サイトスペシフィック雑草管理、英語の略称でSSWM（Site-Specific Weed Management）と呼びます。圃場全体へ同じ量を散布する方式から、雑草がある場所だけを選び、その分だけ処理する方式へ移ることが、この手法の核心です。しかし、その境界を正確に引くこと自体が容易ではありません。作物と雑草が幼いほど、また互いに近く生えるほど、その境界はより曖昧になります。

作物と雑草を分けることは、病気を探すことよりも難しい作業です。どちらも緑色で、どちらも成長し、若い時期には葉の形まで似ているからです。120ヘクタール規模のオーストラリアの小麦畑を対象にした実験は、この問題を時間の流れから解きました。低高度の無人機が同じ圃場を時期を変えて18回撮影し、AMSTFという時空間・スペクトル融合アルゴリズムで写真を重ねて読み取りました。雑草は1日の生長速度指数が0.025、コムギは0.015で、その違いが時系列スペクトル指数にそのまま表れ、さらにCAMDWSセグメンテーションを加えると、作物と雑草が接する境界で9.8パーセントから12.3パーセントだった誤分類率が、5.4パーセントまで下がりました。成長速度の違いという目立たない手掛かりが、境界線を引き直す決め手になりました。

「See & Spray」という標的防除装置は、ノズルの上にカメラを取り付け、その下に超高速電子バルブを備えています。この装置を開発したのは、John Deereの子会社Blue River Technologyです。緑の作物の間に隠れた緑の雑草、いわゆるGreen-on-Green問題をリアルタイムで見分けます。人の目でも、緑の葉の間にある緑の雑草を一目で見つけられないことは少なくありません。雑草の密度と種類に

応じて、散布粒子の大きさを150から250マイクロメートルの間、散布量を1分当たり0.12から0.35リットルの間で随時変えます。圃場全体に均一に散布する従来の全面散布と比べると、除草剤使用量は31パーセントから32パーセント減り、1ヘクタール当たり0.68リットル程度まで下がります。作物には薬剤がかからず、土へ散布される化学物質の総量も同時に減る仕組みです。

化学薬剤を使うこの方法とは別に、まったく薬剤を散布しない道も商用段階に入りました。DIN-LW-YOLOという検出アルゴリズムとRGB-Dカメラを搭載した自動走行ロボットは、作物株の間に芽を出したばかりの雑草の生長点を三次元座標で見つけます。生長点は植物が新たに伸びる最上部です。ロボットはここへ高出力レーザーを瞬間的に照射し、熱で焼却します。除草剤の液滴ではなく、光で雑草を除く方法です。米国のCarbon Roboticsが開発したLaserWeederは、この方式を商業規模へ押し広げた代表例です。1時間に10万株を超える雑草を除去し、2022年の発売以来、累計除草数は100億株を超えます。2026年第1四半期の売上高は1億ドルを超え、その後の集計では1億7,700万ドルまで報告され、農業ロボット企業として初めての規模に達しました。ロボットは15カ国へ出荷され、北米、欧州、オーストラリアの100を超える栽培者が使っています。

2026年2月、同社はラベル付き植物写真1億5千万枚で学習した大規模植物モデルを発表しました。新しい圃場や未知の作物に出会うたびに数週間かかっていたカスタム学習が、数分に短縮されたといいます。一台のロボットが経験した雑草、土、光の組み合わせを、次のロボットが最初から学び直す必要がない仕組みです。一台のロボットが蓄えた経験を次のロボット、次の圃場へそのまま移して使うことになるため、レーザー除草は一農場の道具から、複数農場が共有する一つの共通モデルへ移る入り口に立ったとみられます。

再び明け方のあの温室へ戻ると、栽培者の手には懐中電灯ではなく携帯電話が握られている可能性が高いでしょう。葉を裏返し、目で病斑を測っていた手が、一枚の写真を撮り、画面に出る病名を確認する手へ変わりつつあります。韓国では農村振興庁が、こうした役割を果たすアプリを独自に開発し、提供しています。栽培者が携帯電話で病気の葉や果実を撮って送ると、人工知能が直ちに病名を見分け、適切な防除薬剤まで推奨します。現在は主要31作物と182種の病害虫を扱い、2030年までに韓国内で栽培される主要139作物へ対象を広げる計画です。韓国型第2世代スマートファームでは、クラウド上の人工知能が栽培環境と作物の生体情報をリアルタイムで読み取り、疫病とうどんこ病など5種の病気、ハモグリバエなど2種の害虫を検出します。さらに「アイ (AI) イサギ」という農業特化型人工知能アシスタントを17の情報システムにつないで運用し、音声で質問に答え、農家経営まで診断する次期版を準備しています。

病気を見つけるカメラ、雑草を選び出すカメラ、その結果に応じて薬を散布したりレーザーを照射したりする装置は、最終的に一つの流れにつながります。圃場全体を同じ方法で扱っていた時代から、一枚の葉、一個の果実まで区別し、それぞれ異なる処方を下す時代へ移る流れです。その境目に立っているのが、現在圃場で試験されているカメラとロボットです。この流れがどれほど広く普及するかは、精度、価格、そして栽培者の信頼にかかっています。

こうした成果があっても、圃場は実験室とは異なります。ディープラーニングモデルを最初に学習させる際によく使われるPlantVillageなどのデータは、背景がきれいで光が均一な写真から成ります。しかし実際の圃場では、季節と時間によって日光の角度が変わり、影が濃くなり、風で葉が揺れて重なり、レンズにほこりが積もり、土と枯れた茎が背景に混じります。実験室の写真で学んだモデルをこのような圃場へそのまま移すと、精度が目に見えて落ちる、いわゆるドメインシフトが起こります。撮影環境が変われば、モデルは同じ病気を別のものと取り違えます。照明の色温度、レンズの画角、葉に落ちた影の方向が学習時と異なるだけで、判定は揺らぎます。どれほど多くの写真を集めても、撮影環境が実際の圃場と異なれば、学んだことをそのまま圃場で使えないという意味です。

ラベル付けそのものもボトルネックです。四角い枠を描き、一つ一つの画素に名前を付ける作業は農学専門家の手を経なければならず、一枚の写真に数分かかることもあります。この負担を減らすため、少数のラベルだけで学ぶ半教師あり学習、自ら答えを作りながら学ぶ自己教師あり学習、数枚の写真だけを見て新しい病気を認識する少数ショット学習が研究されています。大規模視覚言語モデルと生成AIでラベル付きの合成画像を大量に作る方法も、このボトルネックを迂回する道として浮上しています。

センサーを増やすほど、計算すべきものも増えます。可視光写真に短波赤外線、ハイパースペクトルデータ、土壌と天候を測るIoTデータまでリアルタイムで重ねるには、異なる速度で入ってくるデータを合わせる作業から容易ではありません。ドローンが送る写真と地上センサーが送る数値は、測定周期と更新速度が異なるため、同じ時間帯の同じ位置を指すように合わせる別の手順が必要です。さらに検出、推論、経路計画、散布量調節まで複数の作業を同時に行うモデルを、電池で動く小型機器上で遅延なく動かすには、モデルを小さくすることと、FPGAやNPUのような専用半導体を搭載することを一緒に解決しなければなりません。

最後の課題は信頼です。ディープラーニングモデルは、なぜそう判断したかを自ら説明しないブラックボックスに近い存在です。栽培者と農学者が判定をそのまま信じて防除薬を散布するには、モデルが葉のどの部分を見て病気と判断したかを、人

が目で確認できなければなりません。Grad-CAM、SHAP、因果関係を明らかにする注意機構をモデル内に組み込み、病斑部位の寄与度を画像で示す研究が、この信頼を築く次の段階とみられます。技術がどれほど正確でも、栽培者がその判断を疑えば、現場で受け入れられるのは困難です。

出典・参考文献

学術論文

1. Adewumi, A., & Saraswat, D. (2026). 精密雑草防除のための人工知能とエッジコンピューティングに関する包括的レビュー. *Artificial Intelligence and Applications*. DOI: 10.47852/bonviewAIA62028867.
2. Kakde, S., Poyam, P., et al. (2025). 自律型精密雑草管理のための統合時空間ディープラーニング枠組みの設計. *International Journal of Applied Mathematics*, 38(2s), 1340-1363.
3. Latif, A., Jati, H., Surjono, H. D., & Yusuf, M. (2026). 持続可能な農業と環境レジリエンスに向けたドローン支援ディープラーニング雑草検出. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 15(2), 1428-1440. DOI: 10.11591/ijai.v15.i2.pp1428-1440.
4. Mathew, M. P. (2025). EfficientNetB0、InceptionV3、Xceptionを用いたブドウ葉病害分類の比較ディープラーニング枠組み. *Discover Applied Sciences*, 7, 1222. DOI: 10.1007/s42452-025-07457-5.
5. Moldvai, L., & Nyéki, A. (2025). トマト (*Solanum lycopersicum*) の検出と栽培のための革新的コンピュータビジョン手法. *Discover Applied Sciences*, 7, 975.
6. Pai, D. G., Balachandra, M., & Kamath, R. (2025). PSPEdgeWeedNetを用いたラッカセイ栽培における作物・雑草セグメンテーションのディープラーニング手法. *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: 農業システムの精密雑草検出のためのビジョントランスフォーマーおよび畳み込み注意ネットワーク. *Scientific Reports*, 16, 18473. DOI: 10.1038/s41598-026-48652-7.
8. 精密作物病害監視のための因果注意マルチモーダル・ディープラーニングネットワークのFPGA高速化IoT展開. (2026). *Environment Conservation Journal*.
9. AgroDualNet: 作物病害予測と果実成熟検出のための二重ディープラーニング枠組み. (2026). *Scientific Reports*.
10. 大規模精密農業: ビジョントランスフォーマーを用いた早期病害検出. (2026). *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 14(4).
11. 転移学習に基づく深層畳み込みニューラルネットワークを用いた作物病害検出の新手法. (2026). *Neural Computing & Applications*, 38, 500. DOI: 10.1007/s00521-026-12216-7.
12. 畳み込みニューラルネットワーク (CNN) を用いた作物圃場の害虫識別: ディープラーニング手法. (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>

講演・映像資料

1. C-DAC. (2025). 農業におけるAI: インドの農業風景を変革する. YouTube. https://www.youtube.com/watch?v=IV3_VnWiBpM

2. RMCg. (2025). AIを読み解く：野菜栽培者のための実用ツール. YouTube.
<https://www.youtube.com/watch?v=G2ytLXLW7hw>
3. Grounded AI. (2025). AIは農業をどう変えるか：より賢い牛、作物、害虫防除. YouTube.
<https://www.youtube.com/watch?v=bxIF2MpXsB0>
4. SyncTellect Automation Hub. (2026). エンドツーエンドAI/MLプロジェクトシリーズ | 第1日：プロジェクト開始と作物病害検出の概要. YouTube. <https://www.youtube.com/watch?v=SNqOcVib3BY>
5. Royal Society of Biology. (2026). 植物健康シリーズ | デジタルブドウ栽培：ブドウ樹の健康の未来. YouTube.
<https://www.youtube.com/watch?v=5iXPOMxl6bU>

記事・報告書

1. Carbon Robotics. (2026). LaserWeederの成果. Carbon Robotics. <https://carbonrobotics.com/results>
2. Hypersinc. (2026). Carbon RoboticsのAIレーザー除草プラットフォーム、売上高1億ドルを突破. Hypersinc.
<https://hypersinc.com/article/carbon-robotics-crosses-100m-revenue-on-ai-laserweeding-platform-1775055784166>
3. Design News. (2026). LaserWeeder、過去2年間で数十億株の雑草を除去. Design News.
<https://www.designnews.com/automation/laserweeders-killed-billions-of-weeds-in-the-last-two-years>
4. 韓国農村振興庁. (2026). 農作物病害虫の人工知能画像診断・処方サービス. 韓国農村振興庁.
https://www.rda.go.kr/board/board.do?mode=view&prgId=day_farmprmninfoEntry&dataNo=100000806197
5. スマートファーム・コリア. (2026). 人工知能生育管理処方サービス. スマートファーム・コリア.
<https://www.smartfarmkorea.net/analyService/internal/aiAdvice.do?menuId=M11030102>

1.2

果実の成熟度判定と生育・収量予測

大規模な商業温室で、パイプレール台車にカメラを取り付け、パプリカを成熟段階別に数え、その値と総収穫量の関係を確認する試験が行われました。温室の天井近くに設けたレール上を台車が秒速0.3から0.5メートルで動き、下に吊り下げたカメラは、列をなすパプリカに向けて、葉の間から見える果実表面の色を読み、赤く熟した程度を数値に変えます。この台車型計数装置は、試験期間を通じて安定した検出性能を維持しました。

果実がいつ熟したかを知ることは、想像以上に大きな経済的損失に直結する問題です。早く採りすぎれば糖度が上がらないまま販売され、遅すぎれば軟化または腐敗し、流通中に廃棄されます。長い間、この判断は作業者の目と手に委ねられていました。畑や温室を回り、色を見て触る方法で、人によって基準が少しずつ違うため、同じ果実をめぐる判定が分かれることも珍しくありませんでした。糖度、酸度、硬さを正確に知るには、果実を切り、果汁を搾って機器に入れる化学分析が必要でしたが、この方法ではその果実自体が使えなくなります。標本を数個切っただけで畑全体の状態は分からないため、農家は労力と時間を費やしても、推測に近い答えしか得られないことが多くありました。しかも、誤った判断の影響は一度で終わりません。最初の収穫で未熟な果実を見落とすと、その果実は次の収穫時には商品価値を失い、捨てられることが多かったのです。

一台のカメラが答えるべき問いは、実際には一つではありません。今日この果実が完熟しているかという問い、木全体が今、開花段階にあるのか果実肥大段階にあるのかという問い、そしてこの畑から今後何キログラム収穫できるかという問いは、それぞれ異なります。成熟度は一個の果実を見て判断し、生育段階は樹木や畑全体の流れを見て判断し、収量は両者を計算して将来の数字に変えるものです。しかし、三つとも同じレンズで撮った写真から始まるため、最近の研究は三つの問いに別々に答えるより、一台のカメラと一つのパイプラインで同時に扱う方向へ進んでいます。

カメラが色だけを見ても成熟を推測できるのには理由があります。果実が熟すと、果皮内のクロロフィルが分解されて緑色が薄くなり、カロテノイドやアントシアニンなどの色素が緑色に代わって、黄、橙、赤に色づきます。同時に、目には見えな

い内部の状態も変わります。水に溶けた糖分である可溶性固形分（TSS）の量が増え、酸味を生む滴定酸度（TA）は低下し、デンプンと水分の割合も変わります。可視光領域、すなわち人の目と同じ400から700ナノメートルの波長帯を撮影するRGBカメラは、こうした外見の変化、つまり色調、質感、形状を読み取る基本的な道具です。

色だけでは分からない距離情報を加える装置がRGB-Dカメラです。通常のカメラが平面的な色情報だけを記録するのに対し、RGB-Dカメラは各画素に距離情報を一つ追加します。地図に緯度と経度しかなかったところへ、標高まで表示されるようなものです。この深度値により、カメラは果実の前後左右の位置、半径、体積を計算し、葉や枝に遮られて半分隠れた果実も見落とさずに捉えます。遮蔽をそのままにすると実際より少なく数えるため、後に続く収量予測全体が低い方向へずれます。施設温室内を巡回するロボットがよく使うIntel RealSense D435iなどが、この役割を担います。

データ収集にも多くの手間がかかります。カメラで撮った写真にはノイズが混じるため、ガウシアンフィルタとウィナーフィルタでノイズを除き、CLAHEという手法で日陰と明るい場所の明暗差を均一に整えます。画素値を一定の範囲にそろえる最小最大正規化も続きます。写真が足りなければ、手元の写真を回転、反転し、明るさを変えたり、画面の一部を隠したりして量を増やし、最近ではCGANやSMOTEなどの手法で、実際には撮影していない仮想果実画像や化学成分値まで作り、学習に加えます。ただし、こうして増やした写真を、学習用と検証用に分ける前に混ぜてはいけません。先に分け、学習用だけを加工する順序を守ってこそ、後で水増しされた評価結果を受け取る事態を防げます。

皮の色が最後まで変わらない果物の前では、可視光だけでは判定できません。タイのマンゴー品種Nam Dok Mai Si Tong（NDMST）がその例で、熟す間も皮が均一な黄色を保つため、写真だけではいつ採るべきか判断しにくいのです。このとき使われるのが近赤外線、すなわち人の目には見えない700ナノメートル以上の波長帯を測るマルチスペクトルカメラとハイパースペクトルカメラです。近赤外線は果肉内の水分と化学成分の変化に敏感に反応するため、皮の中に隠れた状態まで把握できます。研究チームはこの原理を生かしてAFMG-DLFFというシステムを作り、RGB画像から抽出した1,536次元の外見特徴と、糖度から酸度を引いた値であるBrimA指数を含めて内部状態を符号化した512次元ベクトルを一つに合わせ、2,048次元ベクトルを完成させます。K平均法クラスタリングで未熟、半熟、完熟の3段階の基準を設け、ホタルの群れが互いの光の明るさを追って集まる習性を模したグローワーム・スウォーム最適化手法で、学習率とバッチサイズなどの細かな値を調整した結果、この融合モデルは97.86パーセントの等級精度を示しました。同じ条

件で画像情報だけを使ったモデルは88.16パーセント、画像同士だけを融合したモデルは88.73パーセントにとどまったため、内部状態データの追加が精度を大きく押し上げました。

光ではなく熱で成熟を測る方法もあります。果実は熟すほど表面温度と周囲の気温との差が徐々に小さくなり、熱画像センサーはこの微細な温度差をそのまま読み取ります。アブラヤシ農園では、この原理に近赤外線測定と色分析を加え、果房内の油分と遊離脂肪酸（FFA）の値を切らずに推測します。木の下に安価なESP32-CAMモジュールを吊るしておけば、自然に落ちた落果をリアルタイムで数え、YOLOv8x認識モデルと接続したウェブダッシュボードで管理者に知らせます。このシステムは最高0.94のF1スコア、すなわち適合率と再現率をともに考慮する均衡スコアを記録し、適期を逃さず収穫するのに役立ちます。

農場がどの目を備えるかは、費用と作物の事情によって分かります。色だけで判断できる作物なら安価なRGBカメラ一台で十分ですが、葉に隠れる果実が多い作物なら深度情報を持つRGB-Dカメラが必要です。マンゴーのように外見と内部状態が一致しない果物には、近赤外線やハイパースペクトルセンサーなど、より高価な装置を導入しなければならず、油分や脂肪酸のような微細な成分まで見る必要がある作物では、熱画像センサーも重ねて使います。安価なカメラ一台から始め、必要になるたびセンサーを一つずつ追加する方法が、現時点では現実的な導入順序とみられます。

再び温室天井の台車へ戻ると、カメラの仕事は一枚の写真を撮るだけでは終わりません。人工知能は写真内の各果実に四角い枠を描き、さらに一步進んで、果実の輪郭を画素単位でたどり、背景から切り出します。問題は、台車が同じ区間をもう一度通ったり、カメラの角度が少し変わったりするだけで、同じ果実を二度、三度と数える危険が大きいことです。これを防ぐため、重なって描かれた枠のうち信頼度スコアが高い一つだけを残し、残りを消す非最大抑制を使います。そこへ、現在の画面にある果実が直前の画面で見た果実と同一個体かを追跡し続けるDeepSORTなどの物体追跡手法を加えます。この二つの仕組みにより、台車は温室を一周した後、重複なく整理された果実数を提示します。

房状に実るトマトには、一個ずつ実るトマトとは異なる方法が必要です。ある温室では、巡回ロボットにIntel RealSense D435iカメラを取り付けました。高さは1.2メートル、上下の傾きは30度、左右の回転は15度に固定し、レンズと果実の距離は0.5から1メートルに合わせました。その結果、1280×720の解像度、每秒30フレームで映像を収集します。ロボットが秒速0.3から0.5メートルでレールに沿って動く間、人工知能は一房の中で赤く色づいた果実の割合を基準に、成熟度を3段階に分

けます。赤色が果実の10から30パーセントだけに広がった初期、30から70パーセントの中期、70パーセントを超える後期です。この任務を担うLampCT-YOLOモデルは、YOLOv10バックボーンにSegNeXtという注意機構を載せ、色情報へより敏感に反応するよう調整します。温室の骨組みや土の床など不要な背景への反応を抑え、LAMPチャネル枝刈りという軽量化作業も加え、ロボット搭載の小型演算装置でもリアルタイム検出が可能な大きさに縮小しました。

このロボットをさらに詳しく見ると、胴体にはNVIDIA Jetson AGX OrinやXavier NXなどのエッジ演算装置が載り、前方にはRealSenseカメラとともに二次元LiDARセンサーが付いています。LiDARは光を照射し、戻ってくる時間を測って周囲の障害物までの距離を緻密に描く装置で、ロボットが温室のレールと通路を外れずに走るのを助けます。カメラとLiDARを併用するこのロボットは、果実の成熟度をリアルタイムで等級分けするだけでなく、熟した果実一個一個の三次元座標まで抽出します。座標が分かってこそ、次の段階でロボットアームや人が正確にその位置へ行き、果実を採れるからです。

農家にとって、病害を調べる装置と成熟度を判別する装置を別々に使うのは煩雑です。この不便を減らすために登場したのが、二つの任務を一体化したAgroDualNetです。病害を調べる側は、CBAMとResNet50にSMO最適化手法を組み合わせ、葉の病徴写真を集めたPlantVillageデータセットで99.6パーセントという高い精度を示しました。成熟度を調べる側は、はるかに軽いMobileNetV2とYOLOv8を使って、未熟、半熟、完熟、軟化の4段階を識別し、電池で動く小型機器でもリアルタイムで作動します。一台のカメラと一つのプログラムで二つの判断を同時に受けられるため、農家は装置を二組そろえる必要がありません。

日本のナシ栽培現場では、説明可能な人工知能という別の課題を解く必要がありました。等級を判定する人工知能があっても、なぜその等級になったのかを栽培者に説明できなければ、現場で信頼を得るのは困難です。研究チームはMask R-CNNというニューラルネットワークに、写真全体を先に走査して傷がありそうな部分に手掛かりを与えるグローバルコンテキストブロックを加え、ナシ表面の傷と汚れを画素単位で正確に切り出しました。次に、傷が表面全体に占める割合を、大きい、やや大きい、やや小さい、小さいという曖昧な程度に分け、専門家の判定規則を模したファジー推論システムに入れ、実際の市場で使う特秀、秀、良、無印の4等級に最終分類しました。一つの数字で明確に答えるのではなく、人の曖昧な判断方法を模したため、栽培者はなぜこのナシがこの等級になったか、その根拠をたどれます。

広い畑全体をいつ収穫するか決める仕事には、ドローンが登場します。Mavic 2 Proドローンが約7メートルの高さから、トウモロコシの上部に咲く雄花である雄

穂が育った圃場を撮影すると、1ヘクタールを撮るのに5分で足りる。YOLOv5を基に作った雄穂検出モデルが、未開花、開花直後、満開の3段階に雄穂を分けると、全雄穂のうち満開と未開花の割合の差から生育指数を計算します。この指数は、トウモロコシの絹糸が出る時期と強い負の相関を示し、相関係数はマイナス0.943に達するほど明瞭でした。

トウモロコシの絹糸が出た日を基準に、その後は1日ごとの気温を加算する計算へ移ります。毎日の気温が高いか低いかにかかわらず、トウモロコシは定められた累積温度を満たして初めて次の段階へ進みます。「恵味スター」という品種は累積温度が摂氏500度に達すると収穫を始め、560度で終わり、「ハニーバンタム20」という品種は450度で始まり510度で終わるように、品種ごとに異なる基準が適用されます。こうして決められる収穫適期は約5日間で、実際に収穫の1カ月前にこの方法で予測した結果は、約70パーセントの確率で的中しました。同様の方法でリンゴ樹の初花日を予測する研究では、日々記録した気温、高度、緯度、経度を一緒に入れたBiLSTM-MhAというモデルが、開花日を15日から20日前に見通しながら、誤差は約1日、正確には1.34日にとどまりました。

スイートコーン畑では、この予測が実際に役立つかを現場で検証する手順も続けました。80カ所を超える圃場で予測結果を照合したところ、70パーセントという精度が改めて確認されました。予測日に畑全体を一度に刈り取る一括収穫と、果実ごとの成熟度を見ながら数日にわたって採る選択収穫の間に、収量差は統計的に有意ではなく、有意確率は0.07でした。予測が当たれば、人が何度も畑を往復して選別しなくても、機械で1日で畑全体を収穫しても収量では損をしないという意味になります。

こうした予測システムが実際に役立つには、結果が農場管理者の手にすぐ届かなければなりません。スイートコーン畑では、ドローン映像の分析結果が地域の気象データサーバーと自動接続され、人が別途計算しなくても、収穫予定日が画面に表示されます。アブラヤシ農園のウェブダッシュボードも同様に、管理者は事務所に座ったまま、どの木の下に落果が積もったかをリアルタイムで確認し、作業者を送る順序を決めます。現場を歩いて確認していた仕事を一つの画面へ移したことになる、この自動連携こそ、研究室のモデルを実際の農場の道具に変える最後の輪です。

イチゴ畑を写真に撮ると、葉の間に赤い粒が密集して重なって見えます。イチゴやモモのように実が小さく、密集して育つ果物は、個々の実を区別すること自体が難しいのです。最近登場したFruitQueryというモデルは、Transformer構造を用いて圃場のイチゴとモモの成熟度を検出し、平均適合率67.02パーセントを記録しながら、パラメータは1,408万個にとどまり、YOLOv8、YOLOv9、YOLOv10より軽量で

正確でした。イチゴ畑の写真は、人が一枚ずつ正解を表示しなければならない負担が大きく、この表示作業自体が学習のボトルネックになります。2026年に登場したSSEFNetというモデルは、この負担を減らすため、半教師あり学習、すなわち数枚だけラベルが付いた写真とラベルのない写真を一緒に学習へ使う方法を選び、複雑に入り組んだイチゴデータセットでも91.1パーセントの適合率を得ました。フロリダ大学の研究チームは、実際の畑の代わりにコンピュータ内へ仮想イチゴ畑を作り、そこでモデルを先に学習させました。こうして作ったモデルは、実際の圃場で果実を見つける精度が92パーセント、果実直径の測定誤差が1.2ミリメートルにとどまり、商用等級選別にそのまま使える水準に達しました。写真データを集めてラベル付けする費用自体が下がる流れを見ると、今後は温度、湿度、エチレングス濃度を測るセンサーと画像を組み合わせる多感覚融合が次の段階として定着するとみられます。

収量予測は簡単に見えますが、実際はそうではありません。写真に写った果実は、あくまで撮影時に見えたものだけで、その下の葉に隠れてまだ見えない果実や、今後数週間の間に新たに付く花もあります。そのため、良い予測モデルは今日見える果実数だけでなく、樹木の生育段階、それまでに蓄積した気温、過去の同時期の収穫記録も一緒に入れて計算します。カメラが見たものは現在の一場面にすぎず、収量予測はその場面に時間を加え、未来を描く作業です。

個数を数えること、品質を分けること、収量を計算することを一列につないだシステムもあります。FruitNetというパイプラインは、まずYOLOv8で写真内の果実をリアルタイムに探して一次計数し、次に深層畳み込みニューラルネットワークとサポートベクターマシンを組み合わせたモデルで、果実を4段階の品質に分けます。最後に、そこで得た等級別の個数と大きさの情報を、ランダムフォレスト回帰という統計手法に入れ、畑全体の最終収穫量を計算します。リンゴ写真1万8千枚以上、個別アノテーション4万件以上を集めたMinneAppleデータセットで試験した結果、学習精度は98パーセントを超え、検証精度も94から95パーセントの間でした。果実が密集して重なり、隠れる場合は、重複した枠を整理する手法と、複数変数を同時に見る回帰モジュールが重複計算を防ぎます。

果物を数えて等級を付けるだけでなく、ロボットアームが実際に果実を採りに行く経路を決める際にも、同じカメラ情報が使われます。KinectやRealSenseなどのRGB-Dセンサーで果実を見つけた後、人工知能は判定がどれほど信頼できるかを示す信頼度スコア、グリッパーが2本指か3本指か、果実が垂直からどれだけ傾いているかを一緒に考慮し、一つの回帰式にまとめます。この値をA*という経路探索アルゴリズムのコスト計算にそのまま入れると、ロボットアームはむやみに最短距離へ伸びるのではなく、つかみやすい角度と確実な果実をともに考慮して経路を描きま

す。オレンジを対象にした試験では決定係数0.89、位置誤差3.2センチメートル、百分率誤差5.4パーセントでした。イチゴの試験では決定係数0.82、位置誤差4.7センチメートル、百分率誤差7.9パーセントを示しました。この計算方法を加えた後、ロボットアームがオレンジを採りに動く距離は14パーセント、イチゴを採りに動く距離は11パーセント減り、正確な位置をつかむ精度は12から15パーセント上がりました。

このように並べると方向が見えます。当初は成熟度だけを見分けるモデルと、個数だけを数えるモデルが別々にありましたが、AgroDualNetのように病害と成熟度を同時に見るモデル、FruitNetのように個数、品質、収量を一つにつなぐモデル、RGB-Dロボットアームのように認識と動作計画を一体化したモデルが相次いで登場しています。一台のカメラ、一組のプログラムで、より多くの問いに答える方向が今後の流れとみられ、農家が複数の装置を別々に購入し、別々に管理する負担を減らす点でも、理にかなった方向です。カメラを何台も並べるのではなく、一台に複数の役割を同時に果たさせます。

それぞれ異なる方法で作られたモデルの性能は、いくつかの共通指標で測ります。正解率は全判断のうち正しく当てた割合、適合率は人工知能が熟したと答えたもののうち実際にも熟していた割合、再現率は実際に熟した果実のうち人工知能が見落とさずに見つけた割合です。未熟な果実や傷んだ果実など数の少ないクラスをどれだけよく捉えるかを見るには、適合率と再現率をともに考慮するF1スコアが役立ちます。枠をどれだけ正確に描いたかは、人工知能が描いた枠と実際の果実位置が重なる割合であるIoUで測り、複数の信頼度基準を広く調べて平均したmAPは、検出モデル全体の能力を総合的に示します。ロボットや巡回カメラのようにリアルタイムで動く必要がある装置では、1秒に何枚処理するかを示すFPSも確認します。収量や糖度のように数値で答える予測には別の指標を使い、平均絶対誤差と二乗平均平方根誤差は、予測値と実測値がどれだけ離れているかを示し、平均絶対パーセント誤差は、その差を割合に変えて示します。決定係数は、予測モデルが実際の収量や糖度の変動をどれほど説明できるかを0から1の値で表し、1に近いほど予測が精密であることを意味し、鮮度スコアは、果実表面全体で傷のない面積が占める割合をパーセントで示します。そのため論文は、正解率一つだけを掲げず複数の指標を並べ、一つの指標だけが良く見えるよう選ぶことを防ぎます。

これらすべての数値は、最終的に一枚の表にまとめられ、農場事務所の壁やタブレット画面に掲げられます。区域ごとに、今日採った果実数、等級別の割合、今後1週間に完熟するとみられる果実数が並びます。管理者はこの表を見て、明日は何人をどの区域へ送るか、箱をいくつ用意するかを決めます。数個の数字が人の1日の予

定を変えるのですから、モデル精度1パーセントの差は、現場では決して小さな問題ではありません。

この図は収穫で終わらず、その後の物流へ続きます。今日、何箱出るかを事前に知れば、冷蔵トラックを何台呼ぶか、選果場に何人配置するかを1日前に決められます。反対に予測が外れ、急に荷物が殺到すると、冷蔵倉庫の前に箱が積まれ、いくつかは適時に冷却できず品質が落ちます。成熟度判別と収量予測は、畑の中の技術であると同時に、畑の外の物流計画を左右する変数でもあります。

農場主にとって重要なのは、一貫した精度です。晴れた日に撮影した数枚だけで正しく、曇りの日や夕方には間違えるモデルは、現場では役に立ちません。ある数字がたまたま一度良かったことと、毎朝同じ水準で出るとは、まったく別の話です。温室内を毎日巡回する台車型計数装置が、試験期間を通じて性能を揺るがせなかった事実は、最高精度の数値と同じくらい重要です。

このシステムをそのまま現場へ移すと、実験室では見えなかった問題が現れます。露地では日光の強さが時間ごとに変わり、強い直射光が濃い影を作り、風が吹けば枝と葉が重なっては離れることを繰り返します。レンズにほこりが積もったり、湿気が結露したりすれば、一台のカメラに頼る認識性能は急落します。こうした環境変化に揺らがないためには、複数角度から同時に撮る多視点撮影と、得られた写真を一つの立体点群へ統合する三次元融合技術が続かなければならないとみられます。

外見と内部状態が一致しない果物も、依然として大きな障害です。マンゴーのように皮の色が最後まで変わらない果物や皮の厚い果物は、写真だけでは糖度、酸度、脂肪酸の値を知る方法がありません。安価なRGBカメラに少量の化学測定値を加える融合方式と、近赤外線やハイパースペクトルセンサー自体を小型で安価にする研究を、同時に進める必要があります。外側と内側を一緒に見る目を持てなければ、どれほど精巧な人工知能でも、果皮内部の状態までは判定できません。

農場で実際に使う装置には、実験室のコンピュータほど余裕がありません。高性能なビジョントランスフォーマーや大型の畳み込みニューラルネットワークは、電池とグラフィックス処理装置に余裕のない小型ロボットや安価なIoTモジュールでは反応が遅くなります。そのため数値を低精度に変えて計算量を減らす量子化、LAMPチャネル枝刈りのように不要な接続を切る構造化枝刈り、大規模モデルの判断を小型モデルへ移す知識蒸留などの軽量化技術が、引き続き改良されています。結局、現場で使われる人工知能は、与えられたハードウェア内で最も実用的なモデルである場合が多いのです。

学習方法そのものにも、よくある落とし穴があります。一部の研究は、写真を回転、反転し、明るさを変える方法でデータを増やした後に、学習用と検証用へ分けますが、こうすると同じ果実から生じた変形画像が両方へ混ざるデータ漏洩が起こります。この場合、検証スコアは実力より高く膨らみます。この問題を防ぐには、まず学習用と検証用を分け、学習用だけでデータを増やす手順を守り、検証用は手を加えない原本のまま残さなければなりません。この原則を守った研究と守らなかった研究が発表した数値は、互いに直接比較できません。

出典・参考文献

学術論文

1. Bijwe, K. B., & Gadicha, A. B. (2026). FruitNet : 果実検出と収量推定のための深層ハイブリッドモデル. *Bulletin of Electrical Engineering and Informatics*, 15(2), 1150-1160. DOI: 10.11591/eei.v15i2.11112.
2. Kripa, S., & Jeyalakshmi, V. (2026). 特徴融合とディープラーニングを用いた果実成熟度の自動等級付け. Preprint submitted to *Scientific Reports*.
3. Moldvai, L., & Nyéki, A. (2025). トマト (*Solanum Lycopersicon*) の検出と栽培のための革新的コンピュータビジョン手法: レビュー. *Discover Applied Sciences*, 7, 975. <https://doi.org/10.1007/s42452-025-07613-x>
4. Simatupang, et al. (2026). 落果検出によるアブラヤシの収穫準備状態識別のためのYOLOv8ベースIoTシステム. *Journal of Deep Learning, Computer Vision and Digital Image Processing*, 15(2), 237-249.
5. Zeeshan, S., et al. (2025). ディープラーニングに基づく知覚とアクチュエータを考慮した動作計画によるロボット果実収穫のデータ駆動型軌道最適化. *Engineering Research Express*, 7, 045210.
6. アブラヤシ生果房の成熟等級付けのためのディープラーニング: 包括的レビュー. (2026). *Trends in Sciences*, 23(8), 13227.
7. スマート農業におけるイチゴ果実と成熟度のディープラーニング検出: アーキテクチャと方法論の初のレビュー. (2026). *Smart Agricultural Technology*.
8. AgroDualNet : 作物病害予測と果実成熟検出のための二重ディープラーニング枠組み. (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, 劉森, 楊貴軍ほか. (2026). 時系列気温特徴の強化に基づくリンゴ初花期Bi-LSTM予測手法. 『智慧農業(中英文)』, 8(2), 84-96.
12. 趙麗成ほか. (2026). 改良YOLOv10とLAMPチャネル枝刈りに基づく房取りトマト成熟度検出アルゴリズムの開発. 『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. 商業温室のパイプライン台車搭載カメラを用いた、ディープラーニングによるパブリカの果実計数と収量推定. (2026). *Horticulturae*, 11(7), 718. <https://doi.org/10.3390/horticulturae11070718>
15. FruitQuery : 果樹園環境におけるイチゴとモモの成熟度検出のためのTransformerベースモデル. (2026).

16. SSEFNet：複雑な圃場データセットにおけるイチゴ成熟度検出のための半教師あり学習モデル. (2026). arXiv:2602.15656. <https://arxiv.org/pdf/2602.15656>
17. 果実検出・寸法測定モデルの学習に向けた仮想イチゴ圃場シミュレーション. (2026). University of Florida.

講演・映像資料

1. CSUMB College of Business. (2025). 2025年の農業の仕事：より広い視野をもたらし、データを収穫する農業キャリア. YouTube. <https://www.youtube.com/watch?v=rgshB8Jh2ZE>
2. Street Science with Fun. (2025). AI/ML駆動のマンゴー検出・収穫機. YouTube. <https://www.youtube.com/watch?v=Dy3xDC8rElw>
3. Washington State Academy of Sciences. (2025). 収穫後管理のためのAI. YouTube. <https://www.youtube.com/watch?v=hJlOrgNIQG4>
4. Solvi. (2026). ウェビナー：実際の圃場データによるAIベースの植物計数の検証. YouTube. <https://www.youtube.com/watch?v=B0KuJdRtmaQ>
5. Greg Bronevetsky. (2025). シミュレーション環境および制御環境における植物生育形質の予測的パターン認識. YouTube. <https://www.youtube.com/watch?v=uKepfZAnKbk>

第2章

園芸農業ロボットと自律作業の自動化

2.1

果菜類・キノコ類の収穫ロボットとエンドエフェクタ

ミニトマトを摘み取るロボットは、2026年4月時点で1台が1日31キログラムを自動収穫し、日本の商業農場で実運用に入っています。同じ月、イスラエルのアグテック企業DailyRoboticsは米国カリフォルニア州の農場に露地イチゴ収穫機を配備し、日本のスタートアップinahoがサービスとして提供するスナックトマト収穫ロボットは、農場の労働需要を45パーセント以上減らしました。園芸作物の収穫ロボットが直面する課題は、大きく三つあります。果実がどこにあるかを見ること、壊さないためにどれほどの力を加えるべきか見極めること、そしてつかみ損ねたときにすぐつかみ直すことです。

トマトやイチゴ、マッシュルームのように、人の手で一つずつ摘み取らなければならない作物では、収穫作業が総生産費の半分から、多い場合は70パーセントまでを占めます。農村では働き手が減り続け、高齢化も進んでいるため、人の手に代わるロボットアームへの期待は年々高まっています。しかし、現在実用化されている収穫ロボットを見渡すと、果実の収穫成功率は66パーセント前後にとどまり、収穫した果実二十個に一個ほどの割合で表面に傷や圧痕が残ります。人は目で見て、指先の感覚で力加減を測りながら果実を摘み取りますが、ロボットはその感覚をセンサーと計算によって作り出さなければなりません。そのため、果菜類やキノコを収穫するロボットでは、果実を実際につかむ手、すなわちエンドエフェクタの形状と力の扱い方が、ロボットアーム全体の性能を左右します。

収穫ロボットのアームは、栽植方式と遮蔽の程度によって形が変わります。枝と葉が幾重にも茂る樹木では、五、六個の関節を備えた多関節アームが有利です。人が肩、肘、手首を順に回して狭い隙間へ手を差し込むように、五つから六つの関節を持つロボットアームは、葉の間の隙間を見つけ、奥深くに隠れた果実まで手を伸ばします。反対に、温室内のパイプレールに沿って並ぶ作物のように、作業範囲が一定の円柱状空間内に限られる場合は、平行型ロボットアームが適しています。複数の短い脚が一点を共に支える平行型アームは、構造が堅固で応答も速いため、半径300ミリメートル、高さ約300ミリメートルの狭い空間でも揺れずに素早く動き、吸着方式で果実を取り外します。

キノコ栽培施設のように、棚が250ミリメートル以下の間隔で何段も積み重なる場所では、アームを上下に大きく動かす余裕がありません。こうした場所では、スカラ（SCARA, Selective Compliance Assembly Robot Arm）構造が定着しています。スカラアームは平面上で左右に素早く旋回し、必要なときだけ垂直方向にわずかに上下する構造なので、薄い棚の隙間へアームを寝かせるように差し込んでキノコを採れます。リンゴの木のように果実が四方に散らばって実る作物では、アーム一本では手が足りません。マーズ3.1（MARS 3.1）という名のリンゴ収穫ロボットは、二本のアームを別々に動かしながら、樹冠表面のすぐ内側にある浅い領域まで両側から同時に手を入れ、互いにぶつからないよう分担して果実を収穫します。

果実に実際に触れる指先、すなわちエンドエフェクタの作り方は、大きく三つあります。三本の指がねじ式駆動装置で閉じる硬い機械式グripperは、果実を中央へ押し集める力に優れ、重さにもよく耐え、必要なら指先に小さな刃や回転刃を取り付けて茎をその場で切断します。ただし、指が金属や硬質プラスチックでできているため、果実表面の一点に力が集中し、圧痕や傷が残りやすくなります。真空吸着式は、指の代わりに吸盤を果実表面へ密着させ、内部の空気を抜いて負圧を生み出した後、引っ張るかひねって果実を取り外します。表面が滑らかな果実や果皮の厚い果実には適していますが、表面に凹凸がある場合や細かい毛が多い場合は、吸盤と表面の隙間から空気が漏れ込み、吸着力がすぐに失われます。

この二方式の欠点を補うために登場したのが、シリコンや超弾性エラストマーのような柔らかい素材で指を作る、柔軟順応型グripperです。指の内部を複数の小さな空気室に分け、空気を出し入れする量を調節して曲げる方式や、フィンレイ効果（Fin Ray Effect）と呼ばれる構造を用います。魚のひれのように支持材が斜めに交差し、一方を押すと反対側が対象物を包み込むように自然に曲がる構造です。こうした指は、果実が丸くても凹凸があっても、表面形状に合わせて自ら形を変えるため、力が指先の一点に集中せず広く分散し、果実の損傷を根本から減らします。手が柔らかくなるほど、ロボットは強く握っても果実を傷つけにくいという、一見矛盾して聞こえる目標に近づきます。

どれほど手が柔らかくても、視覚と触覚がなければ役に立ちません。ロボットは、果実が正確にどこにあるか、へたをどこで切るべきか、指先にいまどれほどの力がかかっているかを同時に把握する必要があります。このうち位置を見る目の役割は、色と深度を同時に撮影するRGB-Dカメラ（Intel RealSense D435i・D405、Microsoft Kinect v2など）とステレオカメラ、3次元レーザースキャナーが担います。カラー画像から果実の熟度と質感を読み取り、深度情報を重ねて点群を作れば、ロボットアームの基準座標系における果実の前後・左右・上下の位置、丸み、体積まで計算できます。マッシュルームを採るときには、この3次元スキャナーが傘の

直径と高さを測り、所定の出荷規格より小さいものは残して、十分に育ったものだけを選んで採れるようにします。

目で位置を見つけた後は、指先の感覚が必要になります。指の内側に貼り付けた薄膜型圧力センサー、モーターに加わる反力を検出するトルクセンサー、超音波距離センサー、精密な位置を読み取る23ビットエンコーダー、空気圧と油圧を測るセンサーが一组となって働きます。圧力センサーは、指が果実に加える力がその作物の耐えられる限界を超えていないかリアルタイムで監視し、超音波センサーは果実が手の中でわずかに滑る瞬間を捉え、モーターの力をただちに再調整します。葉や枝が密に茂るキャノピー内で果実が隠れているときは、指先に小型カメラを追加したフィンガービジョンや、アームの位置を変えながら撮り直す視点再計画機能も同時に働きます。アームが近づく途中で前方が遮られると、ロボットはすぐに角度を変え、遮られていない隙間を改めて探します。

果実がどこにあり、どこを切るべきかを見つける目は、深層学習検出モデルが担います。YOLO (You Only Look Once) 系列の最新モデルであるYOLOv8、YOLOv10、YOLOv11が広く使われ、トマト専用に調整されたLampCT-YOLOモデルは、YOLOv10をバックボーンとし、SegNeXtという注意機構を組み込んでいます。この手法は、セグメンテーション、すなわち写真内の物体の輪郭を一画素ずつたどって切り出す作業に用いられ、温室内で葉が入り交じる雑然とした背景でも、トマトの熟度を示す色の信号により大きな重みを置きます。さらにLAMPブルーニングという技術を加えて計算量を減らしているため、高価なサーバーがなくても現場の小型制御装置上で直接動作します。正確な切断位置を探すときは、Swift Transformer V2モデルと、画素の塊の形を見て整える従来型の形態学的画像処理を併用し、果実、がく、果柄を個別に切り出します。

このように学習を終えたモデルは、大画面のノートパソコンではなく、アーム脇に取り付けた小箱の中で動いてこそ実用になります。NVIDIA Jetson Xavier NXやAGX Orin、Raspberry Pi 5、OMRON PLCなどの現場用制御機器に、ONNXやTensorRT形式で軽量化したモデルを移します。こうして構成されたロボットが果実一個を認識して摘み取るまでの時間、すなわち収穫サイクルは、作物と手の形によって異なります。スカラアームでマッシュルームを採る場合は一個10秒未満で、リンゴを採るMARS 3.1はアーム一本が果実一個を採るのに7秒から9秒、イチゴは4秒から11秒、オレンジは7秒から11秒ほどかかります。

ロボットの能力はいくつかの数値で測ります。カメラが果実と果柄をどれほど正確に見つけるかは、平均適合率 (mAP) という指標で表し、検出位置と実際の位置がどれほどずれているかは、センチメートル単位の誤差で測ります。しかし、畑で

働く人にとって本当に重要な数値は別にあります。試行のうち実際に果実の収穫に成功した割合、収穫後に表面が傷んだ果実の割合、指が果実表面をどれほど広く包んだかを示す包囲率、そして作物ごとに定められた安全な力の範囲内で握れたかどうかです。安全な把持力の範囲は、イチゴが8ニュートンから12ニュートン、オレンジが80ニュートン近く、ミカンが6ニュートンから8ニュートンで、指先でリンゴ一個を軽く押す力と子どもの手を強く握る力の差を思い浮かべれば、その大きさを推し量れます。枝や果柄が不必要に折れなかったかを示す保存率も併せて記録します。

トマトは果皮が柔らかい一方で、へたと果実が強くつながっているため、押してつぶすことと、引いても外れないことの間で手の形を決める必要があります。シリコン素材Dragon Skin 30で作った三本の指と、四室の空気室を備えた柔軟グリッパーは、遺伝的アルゴリズムで求めた28.293キロパスカルの空気圧を加えて果実を包み込みます。遺伝的アルゴリズムとは、さまざまな組み合わせを試しに作り、その中で成績のよいもの同士を再び混ぜ合わせながら最善の答えに近づく計算方式で、人が値を一つずつ手作業で調整する必要がありません。こうして改良した手でトマトを握り、9日以上置いても傷みの痕跡はまったくなく、実際に動かして採る試験では100個中97個ほどの割合で成功しました。

別の方法は、人の手の動きをそのまままねます。三本の指でトマトを握ったまま360度ひねって回すと、食卓でトマトを摘むときに無意識に行う手首の動きと同じように、果柄を傷めず、果実だけが外れます。果柄を完全に切り落とす方式では、Swift Transformer V2モデルが正確な切断位置を見つけます。温室のレール上を往復する移動ロボットにLampCT-YOLOを搭載した巡回型収穫ロボットは、複数の実が一房に付く房どりトマトの熟度を緑、オレンジ、赤の三段階に即座に見分け、一日中温室内を巡回します。

イチゴは果肉が柔らかく、わずかな力でもあざができたり、つぶれたりします。そのため、ほかのどの作物よりも、接触面積と力の大きさを減らす方向で設計されます。三本ではなく二本だけを使う柔軟シリコングリッパーは、イチゴ表面への接触面を最小限に抑え、8ニュートンから12ニュートンのごく小さな力だけを加えます。ここに回帰分析とA*探索を組み合わせた経路計算方式を加えると、手が果実を握る位置の精度が15パーセント上がり、アームの移動距離は11パーセント減ります。果実本体にはまったく触れない方法もあります。カメラで果柄の位置を見つけた後、はさみ形の先端が果柄だけを切り、その果柄をつかんだまま回収箱へ運ぶ方式です。

吸着方式では、深さ15ミリメートルの柔らかい吸着カップをイチゴ表面に当て、2.38ニュートンの吸着力を生み出しますが、このとき果実に実際にかかる圧力は、イチゴ果肉が耐えられる限界の20パーセントから31パーセント程度なので、傷めずに採れます。こうしたグリッパー技術は、すでに実際の畑へ出ています。イスラエルのアグテック企業DailyRoboticsは、2026年4月から米国カリフォルニア州の農場に露地イチゴ収穫機Q2を配備しました。二本のロボットアームと柔らかいグリッパーを備えたこの機械は、イチゴを摘むとすぐ、クラムシェルと呼ばれる透明な包装容器へ収め、同社は人より2倍から3倍速いと説明しています。

マッシュルーム栽培施設では、棚が250ミリメートル以下の間隔で何段も積まれているため、アームが上へせり上がる空間がありません。この問題をスカラ構造で解決した低床型収穫ロボットは、垂直に上下する一軸と、左右に回転する二つの関節を組み合わせ、アームを寝かせるような低い姿勢で棚の間へ差し込みます。垂直軸には、波動歯車と呼ばれる精密減速装置、ベルト、重量の釣り合いを取るカウンターウェイトを取り付け、がたつきをほぼなくし、1ミリメートル以内の誤差で位置を合わせます。3次元スキャナーが最初にキノコの傘の直径を測り、所定の出荷規格に合うものだけを吸着カップや柔軟グリッパーで抜き取りますが、この全工程はキノコ一個当たり10秒もかかりません。

一本のリンゴの木には果実が前後に何層も実るため、アーム一本では奥深くの果実に手が届きません。二本のアームを別々に動かすMARS 3.1は、樹冠表面のすぐ内側にある浅い領域まで両側から同時に手を入れ、アーム一本が果実一個を7秒から9秒で処理しながら、あざの付いた果実の割合を1パーセント未満に抑えました。一方のアームが手前の枝の果実を採る間に、もう一方のアームは奥の果実へまっすぐ入り込み、時間を稼ぎます。指先にフィンレイ効果構造、モータートルクの読み返し、超音波による滑り検出をすべて搭載した試験では、損傷率を0パーセントまで下げた結果も得られました。

オレンジは果皮が厚く丈夫で、むしろ十分な力を加えてもよい部類に入ります。三本指のシリコングリッパーに最大80ニュートンまで力を加えられるよう設計し、A*経路探索を組み合わせると、アームの移動距離は14パーセント減り、把持位置の精度は12パーセント上がります。キュウリは反対に、表面に凹凸があり曲がりも大きいため、吸着カップ一個では隙間なく密着させにくい作物です。折り紙方式でひだを付けた吸着カップは、内側に湾曲した曲面構造を生かしてキュウリ表面に合わせて自ら折り畳まれたり広がったりし、吸着半径を10.66ミリメートルまで広げ、畑で86.2パーセントの収穫成功率を達成しました。果実ごとに果皮の厚さと曲面が異なる以上、一つの指先ですべての作物を採れると考えるのはまだ早すぎます。

こうした指先技術は実験台を離れ、実際の農場の日課へ入り始めています。日本では、ミニトマト収穫ロボットが3年近く現場で修正と改良を重ねた末、2026年4月時点で1台が1日31キログラムを自動収穫しました。果菜類収穫ロボットを商業農場へ常設し、継続運用する事例は、世界的にもまれです。日本のスタートアップ inahoが開発したスナックトマト収穫ロボットは、購入せず借りて使うサービス方式を採用し、農場は多額の資金を投じなくても人手を45パーセント以上減らせました。2026年にこうしたレンタルロボットを試験導入した農場は五か所にとどまりましたが、同年、TTA-ISOはほぼ無人で動く全自動トマト収穫ロボットを発表し、初号機の納入を目前にしています。イチゴ分野では、畑で実測した果実の位置と向きを集めて公開した資料も登場し、複数の研究チームが同じ基準で自分たちのロボットの性能を比較できるようになりました。1台の機械が毎日一定量を自ら収穫するこうした事例は、果菜類収穫ロボットが試験運転の段階を越え、実際の売上と人件費の計算に組み込まれたことを意味します。

指先技術がここまで精巧になっても、人の手を完全に代替するまでには、いくつかの壁が残っています。葉、枝、果実が幾重にも重なる不定形なキャノピー内では、カメラ一台で果実の中心とへたの位置を漏れなく見つけるのは困難です。視野の一部が遮られると、アームが見当違いの場所にぶつかったり、見えない果実をそのまま通り過ぎたりします。複数の視点から点群を重ね合わせる技術と、遮蔽の程度に応じて自ら角度を変える能動撮影技術をさらに改良しなければ、この壁は低くできません。

柔らかい指にも課題があります。シリコン製の柔軟グリップパーは果実を傷めない点では優れていますが、空気を入れたり抜いたりする反応が遅く、重い果実を持ち上げる力には限界があり、長く使うと素材そのものが伸びたり裂けたりします。普段は柔らかく包み、握る瞬間だけ粒子を固めて一時的に硬くする構造、いわゆる可変剛性方式が、この問題を解く糸口として挙げられます。コーヒー粉を袋に入れて空気を抜くと袋が硬く固まる原理を、そのまま指の内部へ移す研究が各地で進められています。この矛盾をどう解くかが、今後数年間、収穫ロボット企業の順位を分ける基準となる可能性があります。

価格も障害です。精密減速機、3次元センサー、複数のモーターを備えた収穫ロボット1台の価格は、小規模農家が簡単に購入を決められる水準ではありません。しかも、畑や温室のほこり、振動、湿気の中ではセンサーが汚れやすく、部品も頻繁に故障します。部品を一式交換できる標準規格と、現場ですぐ修理できる整備体制が整わなければ、この技術は広く普及しません。

最後に残る課題は、ロボットがなぜそのように判断したのかを、人が理解できるようにすることです。映像、深度情報、指先の圧力信号を制御器内で遅延なく統合するだけでなく、ロボットがなぜそこを握り、なぜその強さの力を加えたのかを、栽培者の画面に示す技術も必要です。この技術は説明可能な人工知能、すなわちXAI（Explainable AI）と呼ばれ、この説明があつてこそ、農家はロボットの判断を信頼し、畑全体を任せられます。指先の力の調節と目の認識能力がどれほど高まっても、その判断過程を人がのぞける窓がなければ、ロボットは依然として見知らぬ働き手のままです。

六つの作物を並べると、指先設計の方向性がはっきり分かります。イチゴやトマトのように果皮が弱く、市場で高値で売れる作物には、空気室や吸着のように優しく扱う指先が先に開発され、オレンジのように果皮が厚く、通常の力ではびくともしない作物には、十分な力を加える指先が後に続きます。キュウリのように一般的でも、表面の凹凸が大きく吸着自体が難しい作物には、遅れて折り紙構造のような別の解決策が登場しました。人が指先の感覚で自然に見分けてきたこの作業は、ロボットでは作物ごとにまったく異なる設計図へ分かります。

ベニバナ畑の上をパラレル型ロボットアームが低く浮かぶように素早く行き来し、指先が触れるたびに糸のような採花対象が一握りずつ消えていきます。目で果実を見つけ、指先で力を見極める能力を備えていても、どの果実から採るかという順序を誤れば、アームは通り過ぎた場所へ引き返し、時間を浪費します。順序を決めるこの作業はロボットの頭脳に当たり、その問題が最も目立つのがベニバナ畑です。圃場には多数の採花対象が散在するため、ロボットは目に付いた順に追うのではなく、全体を巡る短い経路をあらかじめ計算する必要があります。巡回セールスマン問題（TSP, Traveling Salesman Problem）として知られる最短経路計算方式を用い、強化学習で訓練したポインターネットワークが採花対象の位置を受け取ると、近い目標に大きな重みを与える計算を経て、訪問順序をただちに組み直します。パラレル型ロボットアームがこの順序に従い、吸引装置と組み合わせた先端で採花対象を集めると、順序を決めず目に付いたまま追う場合より移動距離が11.5パーセントから20.17パーセントまで短くなります。

イチゴとオレンジで先に見た経路探索の改善も、同様の計算から生まれます。ロボットアームが次にどこへ動くかを決める際は、カメラが現在見ている果実をどの程度確信しているか、指先がどのようなグリッパーか、接近角度がどれほど傾いているかを同時に考慮します。この値を回帰分析であらかじめ調整した計算式へ入れると、次の動きにかかるコストを事前に見積もることができ、その推定値を基にA*という経路探索方式が実際の経路を描きます。確信度の低い方向を迂回し、指先を傷めやすい角度を避けながら、できる限り直角に近い角度で果実へ近づくよう、経路をあ

らかじめ曲げておきます。人が目測で身に付けたコツを計算へ移しただけですが、アームが迷う時間は目に見えて減ります。

カメラが先に述べた確信を持つまでには、事前の練習があります。撮った写真をそのまま入れて教えると、ロボットは晴天時に正面から撮った姿しか認識しません。そのため、訓練用写真を意図的に乱します。写真をさまざまな方向へ回転させ、明るさを上げ下げし、小さなノイズを混ぜて、葉の間から差す陰や曇天の暗い光まで事前に経験させます。こうして加工した複数の写真を使い、Adamと呼ばれる学習方式で訓練すれば、畑へ出て見慣れない角度や光に出会っても、ロボットは簡単には戸惑いません。

このように備えた頭脳と指先の能力を測るときは、目の精度一つだけでは語れません。基準を緩くした場合と厳しくした場合を別々に計算して、カメラがどれほど安定して正解するかを調べ、回帰分析で得た経路予測値が実際の経路とどれほど一致するかも、決定係数と誤差率で個別に評価します。現場の小型制御器が写真一枚を見て答えを出すまでにかかる時間と、1秒間に何枚を処理できるかも併せて測ります。経路をどれほど短縮し、時間をどれほど節約したかをパーセントで示す数値も並べて記録しなければ、異なるロボットの能力を比較できません。

論文に出る数値と、畑で実感する数値は層が異なります。包囲率が数パーセント上がった、あるいは経路が十数パーセント短くなったという数値は、同じ条件で従来方式と比べた改善幅を示すにすぎません。試験圃場は畝間と照明を人があらかじめ整えた場所ですが、実際の農場条件はそこまで整っていません。1日に何キログラム採れたか、人手が何パーセント減ったかという数値は、そのロボットを実際の農場に置き、何日も動かして初めて得られます。これまでの事例で、この二つの層の数値を並べて示したロボットは多くありません。

イチゴのデータセットが位置とともに傾きの方向まで収めているのには、理由があります。果実がどこにあるかを知るだけでは足りず、へたがどちらを向いているかまで把握してこそ、指先が直角に近づき、果柄を傷めずに摘み取れるからです。こうした姿勢情報を複数の畑で集めて公開しておけば、新たに参入する研究チームは最初から写真を撮り直して集める手間を省き、すぐに指先設計を試せます。

収穫ロボットを買わずに借りて使う方式が登場したことも、こうした事情と結び付いています。精密減速機、3次元スキャナー、計算装置まで搭載したロボット1台を丸ごと購入する負担を軽減するための工夫です。しかし、ロボットを新しい畑へ移すたびに、事情はまた変わります。温室構造、栽培方式、植え付け間隔は農場ごとに異なるため、毎回カメラを再調整し、指先の力の値を測り直す作業が必要です。

果実一個を傷つけずに採る能力と、その能力を別の畑へそのまま移植する能力は、互いに異なる課題です。

畑を持つ人の立場から見ると、採算の考え方が見えてきます。人手を確保しにくい時期にロボット1台を数日借りて動かし、損傷率と1日の収穫量が許容範囲なら、次のシーズンに台数を増やすという方法です。購入前に自分の畑で先に試せる道が開かれていることが、高価な機械1台を一度に決断しなければならなかった以前との最大の違いです。

これほど手間をかけて訓練したモデルも、一度に一種類の作物しか認識しません。トマトの熟度を見事に見分けていた目も、イチゴ畑へ連れて行けば最初から学び直さなければなりません。イチゴの柔らかい果肉を傷めないよう設計した指先をリンゴの木に取り付けられれば、重い果実を取り落としがちです。人は畑を歩きながら目と手の感覚を自然に調整しますが、ロボットは作物が一つ変わるたびに目を教え直し、指先を作り直す必要があります。複数の作物を行き来して働く本物の働き手に近づくには、作物ごとに別々に作った目と手を一つにまとめても、異なる畑ですぐ能力を発揮できる技術がさらに必要です。

目と指先を磨くことがここ数年の課題だったとすれば、どの順番で回るかを自ら決める頭脳を持たせ、その成果を同じ基準で測ること、そして一つの作物と一つの畑で身に付けた能力を別の作物と別の畑へ移すことは、始まったばかりの課題です。ベニバナ畑で検証した計算法がイチゴのハウスやリンゴの木の間でも通用するかは、今後数年間の現場試験が答えを出すでしょう。指先、目、頭脳は現在、それぞれ異なる作物と異なる畑で別々に検証されており、この三要素を一台のロボットに統合する作業は、まだ実現していません。

出典・参考文献

学術論文

1. Feng, K. (2026). 果菜類収穫用エンドエフェクタの構造形態と作物適応メカニズム. *Automation and Machine Learning*, 7(2), 60-67. DOI: 10.23977/autml.2026.070207.
2. Zeeshan, S., Malik, M. A. I., et al. (2025). 深層学習ベースの知覚、グリッパー構成、果実形態計測によるロボット果実収穫のデータ駆動型軌道最適化. *Engineering Research Express*, 7, 045210.
3. Minorowicz, B., Patalas, A., & Łuczak, A. (2026). キノコ収穫用SCARAロボットアームの設計. *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: ベニバナ収穫ロボットの系列最適化に向けたDEMA注意機構による強化学習の拡張. *Smart Agriculture*, 8(2), 200-219. DOI: 10.12133/j.smartag.SA202506004.

5. Zhao, L., Lu, X., Wu, Q., Ren, N., Zhou, L., Cheng, Y., Hu, A., & Qi, C. (2026). LAMPチャネルブルーニングを用いた改良YOLOv10ベースのトマト熟度検出アルゴリズム. Smart Agriculture, 8(2), 133-146. DOI: 10.12133/j.smartag.SA202507045.
6. Moldvai, L., & Nyéki, A. (2025). トマト (Solanum Lycopersicon) の検出と栽培に向けた革新的コンピュータビジョン手法：レビュー. Discover Applied Sciences, 7, 975. <https://doi.org/10.1007/s42452-025-07613-x>

講演・映像資料

1. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026世界農食イノベーション・ロードショー開幕イベントおよび初回ロードショー. YouTube. https://www.youtube.com/watch?v=U5CReIR_Rrg
2. World AgriFood Innovation Conference (WAFI). (2026). オーストラリア農食イノベーション | WAFI2026世界農食イノベーション・ロードショー. YouTube. <https://www.youtube.com/watch?v=lTnVRq1Tioo>
3. C-DAC. (2025). 農業におけるAI：インドの農業を変革する. YouTube. https://www.youtube.com/watch?v=lv3_VnWiBpM
4. Street Science with Fun. (2025). AI/ML駆動のマンゴー検出・収穫機. YouTube. <https://www.youtube.com/watch?v=Dy3xDC8rElw>
5. Department of ECE, MGR Educational and Research Institute. (2025). 専門家講演：スマート農業の自律航法におけるコンピュータビジョンの役割概説. YouTube. <https://www.youtube.com/watch?v=GVZ46DY2Tao>
6. UC Agriculture and Natural Resources. (2025). 2026年農業ロボティクス・チャレンジ：IP 101. YouTube. <https://www.youtube.com/watch?v=JA1greBXSoA>
7. HortiQD. (2026). HortiQD第4回ウェビナー：データの橋渡し、農家とロボットをつないで農業をよりスマートに. YouTube. <https://www.youtube.com/watch?v=7W8NbMdhuss>
8. Farm Foundation. (2025). Farm Foundationフォーラム：強靱な農業の未来に向けた自動化. YouTube. <https://www.youtube.com/watch?v=aWWqVnNkhoQ>

記事・オンライン資料

1. AgFunderNews. (2026). DailyRobotics、ロボット式イチゴ収穫機で2026年のカリフォルニア州における商業展開を準備. AgFunderNews. <https://agfundernews.com/dailyrobotics-gears-up-for-commercial-launch-in-california-in-2026-with-robotic-strawberry-harvester>
2. HortiDaily. (2026). 日本のアグリテック・スタートアップ、ミニトマト収穫ロボットを通常生産に導入. HortiDaily. <https://www.hortidaily.com/article/9842754/japanese-agri-tech-startup-puts-cherry-tomato-harvesting-robot-into-routine-production-use/>
3. HortiDaily. (2026). スナックトマト収穫ロボット、商用化の準備完了. HortiDaily. <https://www.hortidaily.com/article/9778303/harvest-robot-snack-tomato-commercial-ready/>
4. Future Farming. (2026). TTA-ISO、全自動トマト収穫ロボットを発表. Future Farming. <https://www.futurefarming.com/tech-in-focus/field-robots/tta-iso-introduces-fully-automated-tomato-harvesting-robot/>
5. arXiv. (2026). [イチゴ収穫ロボット向け圃場実測6D姿勢データセットおよびベースラインモデルのプレプリント]. arXiv:2606.11381. <https://arxiv.org/pdf/2606.11381>

2.2

自律移動ロボットとドローン群の経路最適化・精密防除

Hylioは、1人の操縦者が3機のドローンで構成される群れを同時に監督する方式で、米連邦航空局の承認を得ました。このとき操縦者が手にしているのは、ドローンを直接動かすジョイスティックではなく、複数の機体の状態を一つに表示する画面です。同社が発売したHYL-150 ARESは約50キログラムの薬剤を搭載し、1時間当たり20ヘクタールを超える面積に薬剤を散布し、XAG P150には人工知能で障害物を自ら検知する機能が備わっています。複数のドローンが自ら区域を分け、方向と速度をそろえるこうした承認事例の背後では、人間が一つずつ組むには複雑すぎる経路を機械が代わって計算しています。

その前には、ロボットアーム先端の指で果実を正確につかむ技術とは別の問題があります。どれほど器用な手でも、どの順序でどこから動くかを決められなければ、ロボットは同じ畝を二度通ったり、遠い場所からさまよった末にバッテリーを使い切ったりします。圃場内に散らばる果実や雑草、採花対象は、きれいな列に並んでいるわけではありません。枝に隠れて見えなかった果実が、ロボットが横へ移動すると突然現れることもあれば、風で葉が揺れ、たった今見えていた果実が再び隠れることもあります。郵便配達員が1日に配達する20軒を前に最短経路を組む問題を巡回セールスマン問題と呼びますが、農場のロボットとドローンは、平面だけでなく高さを含む立体空間でこの問題を解かなければなりません。そのため、この課題は三次元巡回セールスマン問題、英語の3D Traveling Salesman Problemを略して3D-TSPと呼ばれます。目標点が25個、30個を超えると組み合わせの数が瞬く間に膨らみ、遺伝的アルゴリズムのように古くから使われてきた探索手法は、計算に時間をかけすぎたり、本当の最適解ではない答えで止まったりしがちです。

強化学習以前にも、この問題を解こうとする試みがなかったわけではありません。アリが餌を探して残した匂いの跡を互いにたどる習性を模した蟻コロニー最適化や、鳥の群れが編隊を組んで飛ぶ姿にならった粒子群最適化も、一時期使われていました。こうした方法は昆虫や鳥の集団行動から規則を借りるもので、それなりの説得力がありましたが、目標点が増え、障害物が刻々と現れる実際の畑では、計算が終わるまでロボットがいつまでも立ち止まらなければならないという問題を抱えてい

ました。あらかじめ定められた規則に従うのではなく、膨大な試行から自ら規則を引き出す強化学習が後を継いだ背景には、畑ごと、季節ごとに異なる条件に合わせて規則を一つずつ組み直すことはできないという現実的な事情があります。

この問題を新たに解いたのが、強化学習とポインターネットワークを組み合わせた仕組みです。強化学習は正解をあらかじめ与えず、自ら試した結果に点数を付けながら少しずつ向上させる学習方式です。ポインターネットワークは、次に行く場所を新たに作り出すのではなく、すでに入力されている座標の中から一つを指さすように選ぶニューラルネットワークです。この二つを結んだ構造は、俳優と批評家にたとえられます。アクターと呼ばれるニューラルネットワークが、次に訪れる座標の順序を一つずつ提案する俳優の役を担い、クリティックと呼ばれるニューラルネットワークは、その提案が全体としてどれほど効率的な経路になるかを前もって採点する批評家の役を担います。俳優は批評家の採点を参考に次の提案を少しずつ直し、この過程を数千回繰り返しながら、次第に短い経路を選ぶ感覚を身につけます。

この判断をさらに精緻にするため、いくつかの仕組みが加えられます。マルチヘッド自己注意という計算方式は、各座標がほかのすべての座標とどれほど近く、どの方向に位置するかを一度に比較できるようにし、距離エンコーディングは座標間の実際のユークリッド距離をあらかじめ数値で計算し、参考情報としてニューラルネットワークに渡します。ここに動的指数移動平均、英語の略称でDEMAと呼ばれる手法を加えると、最近通った経路に重みを置き、古い経路は徐々に忘れながら判断を更新できます。中国で開発され、ベニバナと呼ばれるキク科作物の収穫ロボットに実際に搭載されたAC-RL-PtrNetというモデルが、この組み合わせをそのまま実装した例です。このモデルは長・短期記憶、英語の略称でLSTMと呼ばれる構造で入力された三次元座標の流れを読み取り、クリティックのニューラルネットワークには層正規化と残差接続を加えて、学習の安定性を保ちます。計算量を減らすため、LSTMのゲートと全結合層には、枝を間引くように不要な接続を切る構造化枝刈りを適用し、規模を縮小しながら判断精度の大幅な低下を抑えました。

中国・新疆地域の実際のベニバナ畑で、このモデルを搭載した収穫ロボットの現地試験が行われました。このロボットは複数のアームを横に並べた並列構造で、一つの経路を区間ごとに分け、各アームが同時に担当することで作業速度を高めました。Yuhong No.1とYunhong No.5という2品種を植えた畑で、目標点が25個の条件を試しました。遺伝的アルゴリズムとこのモデルを並行して動かした結果、経路長は9.56パーセント短くなり、作業時間は5.43パーセント減りました。目標点が31個に増え、より密に絡み合った条件では差がさらに大きくなり、経路長は20.17パーセント、作業時間は29.70パーセントまで減りました。目標が増えて複雑に絡むほど、人が決めた順序より学習された判断が大きな差を生むことを示す結果と読めます。

経路を最適化する問題は、訪問順序を決めるだけにとどまりません。圃場を平らにする地形均平作業や、移動経路そのものを設計する分野では、近接方策最適化、英語の略称でPPOと呼ばれる強化学習手法が使われます。PPOは方策を一度に大きく変えず、少しずつ修正することで、学習が突然崩れないようにする方式です。この手法を使えば、移動距離と、掘り起こして運ぶ必要がある土の量を同時に減らす方向で経路を組めるため、ロボットの動きを減らしながらバッテリーを長く使えます。土地をならす作業と、その上を行き来する作業は別の問題に見えますが、結局は同じ強化学習の枠組みの中で一緒に解かれます。

どれほど優れた経路を組んでも、ロボットが自分の位置を正確に知らなければ役に立ちません。地上の自律走行ロボットは、衛星測位装置の誤差を基準局の信号で補正するRTK-GPSを装備して位置誤差を2センチメートル未満に抑え、レーザーを照射して戻ってくるまでの時間を測るLiDARと、色情報に距離情報まで加えたRGB-Dカメラで周囲の地形を立体的に描き出します。ステレオビジョンカメラを2台並べると、二つの視点の視差から距離感を得られるため、果実や茎の位置を、カメラが見る座標からロボットアームが動く座標へ変換できます。超音波距離センサーは、ロボットが畝の端で方向転換する区間や、視界が遮られた瞬間に、ほかの障害物と衝突したり転倒したりしないよう見守る役割を担います。

自律走行ロボットの内部には、このほかにも細かな手入れを要する小型センサーが密集しています。12ボルトバッテリーの電圧を測るセンサーは残量をリアルタイムで知らせ、ソレノイドバルブコントローラーは一つの電気信号でノズルを開閉する門番の役を担います。永久磁石直流ギヤードモーターに付いたエンコーダーは、車輪が何回転したかを数えてロボットが実際にどれだけ動いたかを逆算し、空気圧と水圧を測るセンサーは、噴霧装置内の圧力が所定の範囲を外れていないかを監視します。どれほど緻密な経路を組んでも、こうした細かなセンサーの一つ一つが役割を果たせなければ、計算された数値は実際の車輪やノズルの動きにつながりません。

地上を進むロボットが見落とすものを、空のドローンが補います。ドローンが数日間にわたって撮影したマルチスペクトル画像から得る植生指数は、病気の葉を見つけるときにも使われますが、ここでは用途が異なります。同じ指標を畑全体に重ねて読み取ると、雑草が集まっている確率を区域ごとに示した処方マップ、英語でPrescription Mapと呼ばれる資料が作られます。この地図は雑草の成長速度に合わせて数日おきに描き直され、最新の状態に保たれます。ドローンはこの地図に基づいて、実際にどの経路を飛ぶかを決める段階に移ります。

作物と雑草が接する境界を画素単位できめ細かく見分ける作業は、文脈を同時に読み取る二分岐畳み込みニューラルネットワークが担います。境界が確認されると、

AWTPOと呼ばれる段階が改良ダイクストラ法を使い、複数の候補経路の中から燃料とバッテリー、積載する薬剤の重量を少なくできる道を探します。ダイクストラ法はもともと、複数の駅を通る地下鉄路線の中から最も速い乗り換え経路を探すために使われてきた古い経路探索法ですが、ここでは駅の代わりに畑の座標を、乗り換え時間の代わりに燃料とバッテリーの消費量を置いて同じ方法で計算します。こうして決められた経路に沿ってドローンが飛び、雑草の塊がある区間を通るときだけノズルを開いて薬剤を投下する仕組みが完成します。

ノズルの前には、雑草の塊の大きさをリアルタイムで測る目が別に付いています。雑草が集まった面積が1.5平方メートルを超えると、VRMDWNと呼ばれる可変量微細噴霧装置が作動します。噴霧粒子の大きさを100マイクロメートルから400マイクロメートルの間で調整します。噴霧量も1分当たり0.12リットルから0.35リットルの間で同時に変わります。雑草が密集した場所には大きな粒子を多く、まばらな場所には小さな粒子を少なく散布する方式です。薬剤をすべてまいた後も作業は終わらず、防除後7日、14日、28日が経過するたびに再び撮影し、過去の再発記録と重ね合わせます。こうして集めた資料を基に、PTWRP段階はQ学習という強化学習方式で、どの位置に雑草が再び生える可能性が高いかを事前に把握します。

雑草が再び生える位置を予測する作業は、防除そのものより目立ちませんが、実利は小さくありません。予測がなければ、栽培者は防除を終えた後も数日おきに畑全体を見回り、雑草がよみがえったかを目で確認しなければなりません。PTWRPが作る予測地図は、再び確認すべき場所を数か所に絞り込み、次回のドローン飛行や人による巡回の時間を大幅に減らします。防除作業そのものが、一度で終わる単発の作業から、予測と確認を繰り返す循環へと変わります。

ドローンと地上ロボットが正確な経路を見つけるには、異なるセンサーがそれぞれの方法で測った位置を一つの基準に合わせる処理を先に済ませなければなりません。衛星測位装置が示す緯度と経度、LiDARとカメラが読み取ったロボット基準の相対座標、ロボットアームが動く関節基準の座標は、それぞれ原点と方向が異なります。これらの座標を一枚の圃場地図上に重ねる座標系変換を経て初めて、ドローンが見つけた雑草の位置と、地上ロボットが実際にノズルを開く位置がずれずに済みます。この位置合わせが少しでも狂えば、苦労して計算した最適経路も見当違いの畝を通る無駄足になります。

このシステムは実際の小麦畑で試験されました。12ヘクタール規模の商業用小麦圃場で、種子が発芽する時期から出穂前までの90日間、ドローンが継続して撮影し、このシステムを稼働させました。AWTPOが組んだ飛行経路によってドローンの飛行時間は17.5分に短縮され、VRMDWNの標的散布によって除草剤使用量は1ヘクター

ル当たり0.68リットル、慣行的な全面散布に比べて32パーセント少ない量まで下がりました。雑草に奪われず確保できた収量は18パーセントから22パーセント増えました。畑全体に同じ量をまく方式に比べると、必要な位置にだけ正確な量を散布する方法は、除草剤使用量と収量の双方に明確な差をもたらしたとみられます。

経路が数分短くなったという数字は小さく見えるかもしれませんが、畑では違う形で積み重なります。ロボットが1日に働ける時間はバッテリー容量と日照時間で決まっているため、一往復ごとに節約した時間は、その日の終わりには畝をさらに数列回れる余裕になります。1人が1日に監督できるロボットとドローンの台数も、結局はこの余裕に左右されるため、経路が短くなるほど同じ人員でより広い農場を担当できます。急に方向を変えたり、同じ区間を不必要に往復したりする動きが減れば、人とロボットが一緒に働く畑で衝突する危険も下がります。

個々のドローンによるこうした精密な判断は、複数機が群れで動くドローン群へつながったときに真価を発揮します。1機のドローンが広い畑を最初から最後まで単独で回れば、バッテリーが切れる前に回り切れない区間が残りがちですが、複数機が区域を分けて同時に飛べば、同じ時間で数倍広い面積を見回れます。2026年に入り、防除ドローンは一部の農家だけが使う特殊機器を脱し、大容量タンクに人工知能を載せた機種が広く普及する主流機器へと変わりつつあります。Pegasus Roboticsが販売するXAG P150は、4基のローターが生む下降気流で薬剤を均一に散布しながら、1.5メートルから90メートルの範囲で障害物を自ら検知する人工知能検知機能を備えています。Hylíoが発売したHYL-150 ARESは群飛行に重点を置く機体で、約50キログラムを積み、1時間当たり20ヘクタールを超える面積に薬剤を散布できます。こうした群飛行が可能なのは、各ドローンが機載コンピューターを通じて互いに信号を交わし、マルチスペクトルカメラ、散布タンク、衛星測位信号を連携させて使うためです。Hylíoは、1人の操縦者が3機のドローンからなる群れを同時に監督する方式で米連邦航空局の承認を得ており、この方式なら1人で1日に数千エーカーに及ぶ畑を見回れます。ドローン同士が自ら区域を分け、方向と速度をそろえるこうした承認事例は、1人が複数の機体を同時に監督する群飛行がすでに現場で機能していることを示しています。

人とロボットが同じ畑で一緒に働く時間も増えています。ドローンが低く飛びながら防除する間に人が同じ畝にいれば、超音波センサーとビジョンカメラがその動きを見逃さずに検知し、速度を落とすか経路を変えます。1人の操縦者が複数のドローンやロボットを同時に見守る現在の方式では、一つの画面に複数の機体の状態が一緒に表示されるため、どれか1機に異常が起きたとき、その信号を見逃さないことが監督者の新たな任務になります。機械が自ら経路を決める場面が増えるほど、人の役割は直接操縦する手から全体を見渡す目へ移っているように見えます。

木々が上下に密集する果樹園では、ドローンより地上ロボットが広く使われます。電動の自律走行噴霧ロボットOrcBOTは、RTK-GPSとステレオカメラで自らの位置と樹木の形を同時に読み取り、YOLOv5ニューラルネットワークで葉が茂ったキャノピーの有無をリアルタイムに見分けます。中央電子制御装置はこの判断に従って左右のノズルを別々にオン・オフし、木のない空白区間では薬剤をまったく散布しません。ここに10キロボルトの電圧をかけて噴霧粒子を帯電させる装置が加わり、冬にセーターを脱ぐと髪がセーターに付くのと同一原理で、帯電した粒子が葉の裏側や枝の内側まで入り込んで付着します。慣行的な噴霧器では風上側の葉の表面にだけ薬剤が付き、その裏側は素通りしやすいのに対し、帯電した粒子には葉がどちらを向いていても引き寄せられて付く力が一つ加わっています。

トルコのアンカラ大学農学部で、このロボットを実際に試験した結果が示されています。噴霧粒子は直径150マイクロメートルから167マイクロメートルの範囲に形成され、米国農業工学会が定めた微細粒子規格ASAE S572.1を満たしました。葉面に薬剤が付着した割合であるキャノピー被覆率は平均55パーセントで、高いときには57パーセントに達しました。慣行的なトラクター噴霧器に比べ、薬剤使用量は49パーセントから72パーセント減り、統計的にも偶然とは考えにくい差が確認されました。人がトラクターを運転して散布すると1時間当たり19.70ドルかかっていた作業費は、ロボットに置き換えると1時間当たり0.76ドルまで下がり、95パーセント近く減りました。

ヘクタール単位で広がる小麦畑の雑草と、木が1本ずつ立つ果樹園の病害虫では、薬剤の散布方法から異なります。VRMDWNは畑に点在する雑草の塊だけを選んで散布するため、標的が小さく、その間は完全に空けておく一方、OrcBOTは木1本を丸ごと包むように散布しなければならず、標的が大きいうえ、その中でも葉の裏側までまんべんなく届かせる必要があります。雑草を相手にする側では、どこにあるかを正確に見分ける地図が鍵となり、木を相手にする側では、位置が分かっている木の内側へ薬剤をどれだけ均一に届けるかが鍵となります。二つの技術は見た目には同じ自律防除に見えても、実際に解くべき問題はそれぞれ異なる顔をしています。

大規模農場だけでなく、小さな畑にも自律走行技術が入り始めています。PICマイクロコントローラーで動く小型ロボット1台は、モジュールを交換するだけで複数の仕事をこなします。250グラムの種子箱を付ければ、一定の間隔で種子を1粒ずつまく精密点播を行い、500ミリリットルの汎用ポンプノズルを付ければ必要な位置だけに薬剤を標的散布し、軟鋼製の薄い刃を付ければ株と株の間を移動しながら機械的に除草する作業まで行います。1個のバッテリーと1個のマイクロコントロー

ラーでこの三つの仕事をすべてこなす小さなロボットは、大型農機を購入する余裕のない小規模農家に適した選択肢として浮上しています。

これらすべてのニューラルネットワークは畑に出る前に、PyTorchやTensorFlowなどのプラットフォーム上でAdamやAdamWによる最適化手法を使い、あらかじめ訓練を終えます。訓練済みモデルは、NVIDIA Jetson Xavier NXやJetson Nano、Raspberry Pi 5、あるいは産業用PLC制御器のような手のひらサイズの機器にONNXやTensorRT形式で移され、軽量な実行形式へ変換されます。目標点が25個から31個の三次元巡回セールスマン問題を実際に解く時間は数十ミリ秒以内で、ロボットが止まって計算を待つ時間はほとんど感じられません。ドローンが秒速5メートルで飛びながら防除作業をするときも、ノズルの開閉にかかる短い遅延をあらかじめ計算に入れた動作計画が同時に働きます。

このように作られたシステムが実際に使えるかどうかは、複数の指標で総合的に測ります。経路が慣行アルゴリズムよりどれだけ短くなったかを見る経路短縮率、作業がどれだけ早く終わったかを見る作業時間削減率、エッジ機器が経路を計算するまでの遅延時間、バッテリーと燃料をどれだけ節約したかを見るエネルギー削減率が、ロボットとドローンの動きそのものを評価する指標です。これに1ヘクタール当たりの除草剤削減量、キャノピー被覆率、噴霧粒子径、作物と雑草の境界で生じる誤分類率、確保できた収量の割合、防除後に雑草が再び生えることをどれだけ正確に予測したかを見る再発予測精度を加え、農業に実際の利益があったかを示します。カメラが雑草と作物をどれほど正確に区別したかは、いくつかの数値でさらに確認しますが、モデルが描いた雑草領域と実際の雑草領域がどれほど重なるかを見るIoUは、二つの印章を同じ位置に重ねて押したときの重なり具合を測ることに似ており、複数のしきい値で測った適合率の平均であるmAPは、条件を変えながらその押印を何度も繰り返した後に平均を取る値に近いものです。雑草と判定したもののうち実際に雑草だった割合である適合率と、実際の雑草のうち見逃さずに捉えた割合である再現率を一つにまとめたF1スコアは、一方だけに偏った判断を見分ける役割を果たします。この三層の指標のうち、どれか一つだけが良くても畑で信頼されるシステムとして定着するのは難しく、経路、防除、認識という三つの車輪がそろって回って初めて現場で通用します。

こうした成果にも、越えなければならない難関がいくつも残っています。これまでの結果は、大半が特定の一つの畑で得た成績だという限界も抱えています。新疆のベニバナ畑で学習した訪問順序が、木の間隔も地形もまったく異なるリンゴ園でそのまま通用する保証はありません。作物の高さや植え付け間隔、土地の傾斜が変われば最短経路の形そのものが変わるため、複数の作物と地形で幅広く試した結果が

さらに蓄積されて初めて、経路最適化モデルは特定の畑だけの道具から、多様な畑で使える道具へ移行できるとみられます。

現在の三次元巡回セールスマン問題のアルゴリズムと飛行経路計算は、おおむね平坦または整った畑を前提に組まれているため、急斜面や障害物が混在する区域では、そのまま通用しないことが少なくありません。風が秒速4.5メートルを超えたり、霧や雨、厚い雲に覆われたりした日には、マルチスペクトル画像の品質が低下し、ドローンの飛行位置にも1メートル前後の誤差が生じて、雑草の位置を誤認したり、見当違いの畝に薬剤を散布したりする恐れがあります。晴れて風のない日を選んで作業する現在の方式には、悪天候が続くと防除時期そのものを逃す危険があります。このような日には、人が現場へ出て目で確認し、防除時期を調整し直す作業がまだ必要です。

ドローンと地上ロボットの機体規模も足かせとなる要因です。試験に使われたドローンの最大飛行時間は約22分で、搭載できる薬剤も約1.2リットルにとどまるため、広い畑を休みなく回するには、バッテリー交換と薬剤補充の時間が頻繁に挟まります。人が手でバッテリーを交換し、薬剤タンクを補充する数分間、ドローンは空を飛べず、畑の片隅に置かれたままです。この隙間を埋めるため、地上を移動しながらバッテリーを交換する移動式充電装置や、ドローンと地上ロボットが異なる役割を分担して協力する異種群制御技術が、次の課題として浮上しています。充電設備を整える費用まで計算に入れると、農場が広いほど、この技術を初めて導入する負担も小さくない点を考慮しなければなりません。空と地上のロボットがそれぞれ得意な仕事を分担し、その間を自動でつなぐ仕組みが整って初めて、現在の試験圃場を超え、はるかに広い農場へこの技術をそのまま移せるようになるとみられます。

複雑な計算を畑の真ん中で処理しなければならない点も障壁です。強化学習に基づく経路計算や、複数の仕事を一度に処理するビジョンモデルは演算量が多いため、バッテリーで動く小型機器上では判断が遅れる可能性があります。演算量を減らす量子化や枝刈り、NPUやFPGAなどの専用半導体を取り付ける方法が、この問題を軽減する手段として研究され続けています。計算資源と精度の間でどの均衡点を選ぶかは、結局、畑の広さと作物の価値に応じて農家ごとに異なる答えを出さざるを得ません。

最後に残る課題は信頼の問題です。強化学習モデルがなぜその経路を選び、なぜそこだけに薬剤を散布すると決めたのか、栽培者が理由を目で確認する方法はまだ十分ではありません。Grad-CAMやSHAPのように判断の根拠を画像で示す説明可能な人工知能技術をこのシステムに組み込めば、栽培者はロボットの選択にそのまま従うか、もう一度見直すかを自ら判断できます。さらに、防除記録と雑草が再び生

えた位置を毎年蓄積して知識としてフィードバックすれば、数年かけてゆっくり変わる土壌と雑草生態の流れまで追えるとみられます。こうした信頼が積み重なって初めて、人が最後に確認印を押す現在の半自律方式から、人の手を完全に離れた自律方式へ移行できるとみられます。

この技術を広い農場へ普及させるには、さらにいくつかの課題を解かなければなりません。強化学習が選んだ経路と防除判断の根拠を栽培者が目で確認する方法を整えること、バッテリーや薬剤が切れるたびに生じる作業の空白を減らすことも、まだ解決されていない課題です。複数のドローンが信号を交わして区域を分ける群飛行では、その信号が途切れたとき、各機体が互いの位置を見失い、飛行経路が重なったり衝突したりする危険も残ります。1人の操縦者が複数の機体の画面を同時に見る現在の監督方式は、通信が切れた機体をどれだけ早く見つけ、安全に停止させられるかで実効性が決まります。

出典・参考文献

学術論文

1. Adewumi, A., & Saraswat, D. (2026). 精密雑草防除のための人工知能とエッジコンピューティングに関する包括的レビュー. *Artificial Intelligence and Applications*. <https://doi.org/10.47852/bonviewAIA62028867>
2. Choudhari, A., Katkar, R., Gupta, M., Wathe, N., Kakde, S., & Poyam, P. (2025). ドローン型スマート農業環境における自律精密雑草検出・処理・再発予測のための統合時空間深層学習フレームワークの設計. *International Journal of Applied Mathematics*, 38(2s), 1339-1366.
3. CropLife. (2026). 2026年に注目すべき7機種の農業用散布ドローン. CropLife. <https://www.croplife.com/iron/sprayers/7-agricultural-spray-drones-to-watch-in-2026/>
4. Gerdan Koc, D., Koc, C., & Comakli, M. (2025). 精密果樹園作業向けAI駆動型自律散布ロボット. *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). 播種・散布・除草を行う自律型農業ロボット. *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：ペニバナ収穫ロボットの系列最適化にDEMA注意機構を用いた強化学習の高度化. *Smart Agriculture*, 8(2), 200-219. <https://doi.org/10.12133/j.smartag.SA202506004>
7. Logeshwaran, J., et al. (2026). ビジョンAIを備えた精密農業向け組み込み型ドローン群. *International Journal of Computer Applications*, 187(115), 42-43.
8. The Robot Report. (2026). ドローン群は実際にどう動くのか、注目すべき産業とは. The Robot Report. <https://www.therobotreport.com/drone-swarms-how-they-actually-work-and-what-industries-should-care/>

講演・映像資料

1. Food and Agriculture Organization (FAO). (2025). デジタルFAOと農業情報学で世界を巡る、シドニー. YouTube. <https://www.youtube.com/watch?v=tbFEk73816U>

2. PhD Navigator. (2025). ICT研究におけるサンプリング手法 | 農業用エネルギー最適化フィールドロボット. YouTube. https://www.youtube.com/watch?v=jJerj_N7ALQ
3. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026世界アグリフード・イノベーション・ロードショー開幕イベントと初回ロードショー. YouTube. https://www.youtube.com/watch?v=U5CReIR_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非公開資策会衛星精密農業AI導入ワークショップ、桃園AI衛星マルチスペクトル画像とドローンの応用. YouTube. <https://www.youtube.com/watch?v=dtT3bafdKgw>
6. Trimble Geospatial. (2026). eCognitionウェビナー：深層学習、UAV、精密農業. YouTube. <https://www.youtube.com/watch?v=alrseDYV8Lo>
7. Society of Precision Agriculture Australia SPAA. (2025). Grain Automate全国ウェビナー：農場自律化への道を切り開く. YouTube. <https://www.youtube.com/watch?v=nZnsWgvs6-g>
8. Agri Coaching Chandigarh. (2026). デジタル農業ミッション2026 | AI、ドローン、Agri Stack、スマート農業 | 時事. YouTube. <https://www.youtube.com/watch?v=al2rsTZBwMA>

第3章

スマート温室と施設園芸の環境制御（CEA）

3.1

IoT多種センサーによる監視とスマート環境計測

世界各地に配備されたLoRaWAN低消費電力IoT機器は70か国で1億2500万台を超え、関連市場の規模は2026年に142億5000万ドルに達すると推定されています。米国ネブラスカ大学の研究チームは、土壌水分をリアルタイムで観測するだけで、水使用量を最大35パーセント削減できたと報告しました。温室内でも、きめ細かな計測が必要であることに変わりはありません。ビニールハウスでは床面と目の高さの温度が3、4度ずつ異なり、屋根近くには別の高温空気層ができます。温室の柱の片側に取り付けられた手のひらほどの白い箱の中では、温度と湿度の値が数秒に一度ずつ更新され、その値が、その日の夜に換気窓を開くか、暖房機を動かすか、散水装置を作動させるかを決めます。

温室内で実際に管理しなければならない値は、気温だけではありません。気温と相対湿度、二酸化炭素濃度、日射量（光合成に実際に使われる波長帯の光を測る値を光合成有効光量子束密度と呼びます）、水耕栽培であれば培養液の電気伝導度と水素イオン濃度、土や培地に残る水分、水槽の水温、貯蔵庫であればエチレングラスまでが一緒に変動します。これらの値は、それぞれ独立して動くわけではありません。窓を開けて温度を下げれば湿度と二酸化炭素濃度も同時に逃げ、暖房機をつければ温度が上がるだけでなく、相対湿度が急低下します。水を多く与えれば培地の水分は増えますが、根の周囲の空気湿度まで上昇し、カビが発生しやすい条件を助長することもあります。そのため温室の微気候、すなわち小さな空間内の気候は、一度に一つずつ制御できる個別のスイッチの集まりではなく、複数の変数が刻々と互いに押し引きする、非線形かつ時間変動性の結合系として扱わなければなりません。

この均衡が崩れると、損失はすぐに目に見える形で現れます。温度が適正範囲を外れたまま数日過ぎるだけでも茎が徒長したり花芽が落ちたりし、高湿度のまま夜を越すと、葉裏に水滴が付着してカビ菌やうどんこ病菌が増殖しやすい条件が整います。一度の着果失敗、一度の病害拡大が、その季節の収穫量全体をむしばみます。だからこそ栽培者の感覚と経験だけでは足りず、温室の隅々まで密に設置したモノのインターネット（IoT, Internet of Things）センサーと、その値をリアルタイムで読み取って判断する人工知能による計算がともに必要です。センサーが両目と皮膚なら、その背後で働く計算は、瞬間ごとに条件を吟味して次の行動を選ぶ判断力に当たります。

問題は、一つの温室にセンサーを一つ取り付けただけでは、その判断力が正しく働かないことです。換気ファンのすぐ前と温室の反対側の隅では気流速度からして異なり、作物の葉が密生する群落の上部と、その下の陰では温度が数度も違います。温室の壁に近い縁と中央部も、異なる気候の中にあります。一つのセンサーが読み取った代表値を温室全体の値だと信じて暖房や換気を決めれば、その代表値から遠い区域は放置され、徒長したりしおれたりしかねません。この空間的不均一性をどう扱うかが、温室計測設計の課題として残ります。

実際に温室へ導入されるセンサーの一覧はかなり長くなります。空気側ではDHT11およびDHT22温湿度センサーがマイナス40度から80度、相対湿度0パーセントから100パーセントの範囲を測り、WQX-TH温湿度センサーがその隣を守ります。水槽内にはDS18B20水温センサーが入り、光はWQX-L光量センサーが0ルクスから15万7286ルクスまで、紫外線はWQX-RおよびUVセンサーが0から1平方メートル当たり2000ワットまで測ります。土や培地に残る水分はFC-28またはYL-69水分センサーで測り、空気中の二酸化炭素濃度は、赤外線が気体に吸収される度合いを利用する方式、すなわち非分散型赤外線（NDIR）方式のセンサーが担当します。水耕栽培の培養液には電気伝導度（EC）と水素イオン濃度（pH）を同時に測るセンサーが挿され、収穫した農産物を低温流通させる際には、果実が放出するエチレンガスを捉えるセンサーが別に取り付けられます。センサー一個の価格は数千ウォンから数万ウォンの間で、それほど高くありませんが、これらが一か所に集まれば、温室の息づかいを余すところなく読み取る網になります。

電力をどう確保するかも、センサーノードの寿命を左右する問題です。温室の屋根上や培地の脇など、コンセントを新設しにくい場所では、小型の太陽電池パネルと蓄電池を取り付けたノードが主に使われ、通常は回路をスリープ状態にしておき、決めた時刻だけ短時間起動して値を測り、再びスリープ状態に戻す省電力方式により、バッテリーを一度充電すれば数か月持ちます。灌水ポンプや換気ファンのように直接動力を使うアクチュエーター側は、初めから商用電源線につないでおき、その隣のセンサーノードだけを低消費電力バッテリーで別に運用する方式が一般的です。一回の通信に必要な電力まで節約するため、測定のたびに送るのではなく、一定時間ためてから一括送信する方式も併用されますが、この折り合いが少しでも崩れると、バッテリーが予想より早く切れ、判断が必要な肝心の瞬間にセンサーが作動しなくなります。

温室の外にも目が必要です。JNGW100という気象観測装置とWQX分光センサーを温室の外に設置すれば、外気の温度と湿度、露点、日射量を1分間隔で受け取れます。これに加え、日本の農業研究機構が作成したメッシュ農業気象データ、WeatherAPI、米国航空宇宙局のNASA POWER、国連食糧農業機関のFAO

CLIMWATなど、海外の公開データをリアルタイムで取り込み、今後数日間の天気予報値も制御モデルに入力します。温室内のセンサーだけでは、近づく寒波や猛暑を事前を知ることができないため、外部の気象データと室内センサーの値を並べて見ることが、次第に当然の手順となっています。窓を閉める時刻を1時間でも早く知ることと、値が上がってから知ることとの間には、作物の命運を分ける差があります。

数値を空気からだけ取り出すわけでもありません。「植物との対話技法」と呼ばれる方法は、作物そのものが発する信号を読み取ります。温室へ入る空気と出ていく空気の二酸化炭素濃度差に風速を掛けると、温室内の作物群落全体が5分ごとに、光合成によって二酸化炭素をどれだけ吸収し、夜間の呼吸によってどれだけ放出するかを計算できます。同じ方法で水蒸気濃度差に風速を掛けると、葉がどれだけ水分を放出しているか、葉面の小さな呼吸孔である気孔がどれほど開いているかも、葉に一枚も触れずに推定できます。温度計が室内の空気を測る道具なら、この方法は作物そのものを生きた計測器に変えます。

センサーが読み取った値は、複数の層を経て運ばれます。現場の最前線にはSTM32やESP32、Wi-Fiを備えたESP8266モジュール、または2台が役割を分担するArduino UnoとArduino Nanoの組み合わせが置かれます。Arduino Unoがセンサー値を収集してアクチュエーターを直接動かす仕事を担うと、Arduino Nanoはその隣でウェブサーバーと通信し、画面にグラフを描く仕事を分担して、一方が止まってももう一方が持ちこたえられるようにします。温室内の複数のノード間で値をやり取りするときは、産業現場で長く使われてきたRS485有線方式やZigBee無線センサーネットワークが使われ、中央サーバーやクラウドまで値を送り上げるときは、4G DTU、GPRS、LPWAN、Wi-Fiなどの通信網が使い分けられます。そのおかげで、温室現場に取り付けた小型画面と事務所のコンピューター、栽培者の携帯電話アプリが、同じ瞬間に同じ数値を受け取ります。

産業現場で長く実証されてきたRS485有線方式は、湿気や電磁波に影響されず、値を安定して伝送できますが、温室の構造を変えるたびに配線し直さなければならない手間が伴います。ZigBeeのような無線センサーネットワークは配線が不要なため、栽培方式が頻繁に変わる温室に適していますが、鉄骨構造物や水槽のように電波を遮る障害物があると、値が途切れたり遅れて届いたりします。そのため実際の現場では、どちらか一方に統一するのではなく、中心となる区間を有線で構成し、頻繁に変わる区間だけを無線で補完する折衷方式が広く使われています。

このうちLoRaWANと呼ばれる低消費電力広域通信網、すなわちLPWANは、ここ数年で実験室の技術から産業規模の基盤施設へ移行しました。2026年現在、世界の

LoRaWAN IoT市場は142億5000万ドル規模と推定され、2035年まで毎年34.7パーセントずつ成長すると予測されています。すでに70か国で1億2500万台を超えるLoRaWAN機器が配備されています。一個のバッテリーで数年間作動しながら数キロメートル先まで値を伝えられるこの通信網のおかげで、新たな電線を敷設しにくいビニールハウスや露地の片隅にもセンサーを設置できるようになりました。

2026年に入って目立つ流れは、計算をクラウドから現場の通信中継装置、すなわちゲートウェイ内へ移す動きです。センサー値を一つずつ遠隔サーバーへ送り、応答を待つ代わりに、ゲートウェイ内へ軽量の人工知能モデルを組み込み、その場で判断させる方式です。こうすればサーバーとの往復時間が短くなり、通信費も減ります。米国ネブラスカ大学の研究チームが土壌水分をリアルタイムで監視した実験では、この方式によって水使用量を最大35パーセント削減できたと報告しました。センサーは値を測るだけにとどまらず、その値を直ちに判断へつなげます。

とはいえ、温室の隅々に高価なセンサーをくまなく設置することはできません。そこで、わずかな数のセンサーだけを設置し、温室全体の3次元気候マップを計算によって描く方法も併用されます。数値流体力学（CFD）と呼ばれる技法は、温室内の空気と気体が実際にどのように流れ、混ざるかをコンピューター内で再現するシミュレーションで、天気予報図を温室内部という狭い空間へそのまま移したものに似ています。ここに、画像を読み取る畳み込みニューラルネットワーク（CNN）、時間の流れを追う時間畳み込みニューラルネットワーク（TCN）、複数の候補値から最適値を探す粒子群最適化（PSO）技法を組み合わせたDeepCFD-OptNetや、ランダムフォレスト、サポートベクター回帰（SVR）、深層ニューラルネットワーク（DNN）などの機械学習モデルと一緒に動かせば、少数のセンサー値だけでも、温室の隅々の温度と二酸化炭素分布を妥当に再構成できます。この再構成は通常、数分間隔で再計算されてマップが更新されるため、センサーのない区域でも直前の状況に近い値を推定できます。センサーの配置費用と計測精度とのせめぎ合いを、計算で埋め合わせます。

同じ値をあえて二重、三重に測る冗長設計も、計測精度を守る方法の一つです。温度だけを測る一つのセンサーに依存すると、そのセンサーが故障したときに温室全体が目を閉じたまま動くことになりますが、同じ区域に性能が少しずつ異なるセンサーを2、3個重ねて置けば、互いの値を比較して、どれが故障に近いかを見分けられます。安価なセンサーを複数重ねて使う方が、高価なセンサー一つに頼るより故障に強い場合も多く、温室の規模と予算に応じて、どの値を何重に測るかを決めること自体が設計者の仕事として残ります。このように重ねて蓄積した値があってこそ、後述する適応型カルマンフィルターも役割を果たします。

値がいつも時間どおりに届くわけでもありません。通信が一時的に途切れたり、一つのセンサーに不具合が起きたりすると、値が欠ける区間が生じます。欠測区間が10ステップ以内と短ければ、途切れる直前の最終値と、再接続後の最初の値を直線で結んで間を埋める前方・後方線形補間法を使います。10ステップを超えて長く欠けると、この方法だけでは不自然になるため、動的時間伸縮法（DTW）という方法で、過去の記録の中から現在と似た推移を示した区間を探し、そのパターンを取り込んで空白を埋めます。日記を一日書き忘れたとき、去年の同じ季節に似た天気だった日の記録を参考にして、空白のページを埋めるような方法です。

空白を埋めることとは別に、入ってきた値そのものが跳ねたり揺れたりする問題もあります。湿気が多く、ほこりの舞う温室環境では、センサーが瞬間的に誤った値を示すことがよくあります。これを整えるために、自律適応型カルマンフィルターが使われます。カルマンフィルターは、センサーが直前に読み取った多少揺らぎのある値と、それまでの推移から推測した予測値に重みを付け、両者の間の値へ静かに収束させる計算法で、衛星信号が揺れても、自動車の直前の速度と方向も参照して位置を安定して捉えるカーナビゲーションの計算と原理が同じです。「適応型」という名が付くのは、このフィルターがセンサーをどれだけ信頼するか、その信頼度そのものを自ら調整するからです。新しく入った値と予測値との差が大きいほど、そのセンサーの重みを下げ、ほかのセンサーの値により大きな重みを置くことで、湿気やほこりによって一つのセンサーが一時的に異常になっても、全体の判断まで揺らぐことを防ぎます。

中国北西部、寧夏の恒生苗木基地にある典型的な二重膜型日光温室が、このフィルターを実地試験した現場です。WQX-TH、WQX-L、WQX-R分光センサー4セットを温室内の各所に分散して取り付け、屋外には別の気象観測所を設けました。複数のセンサー位置から同時に入る値を適応型カルマンフィルターで先に整えると、その後続く温湿度予測と暖房・換気の自動開閉判断が、はるかに安定して作動します。値を測る段階でノイズを取り除かなければ、その後どれほど精巧な判断ロジックを載せても、土台から揺らぐことになります。

このように整えた値も単位がまちまちで、そのまま計算に入れるのは困難です。温度は摂氏度、湿度はパーセント、光はルクス、二酸化炭素はppm、酸性度はpHと、それぞれ異なる尺度を使います。これを最小値と最大値の間で0から1までの尺度に置き換える最小最大正規化の過程を経て、並べて比較できる値に変えます。各国の通貨を一つの基準通貨に換算して初めて、商品の価格を比較できるのと同じ理屈です。この過程を終えた値であってこそ、機械学習パイプラインへ投入する材料として使えます。

値を整え、尺度までそろえたら、今度はその値を実際の動きへ変える番です。この仕事は、現場に置かれたNodeMCU ESP8266やRaspberry Pi、ローカルQt画面を備えた制御端末、ときにはクラウドサーバーが分担し、値が入力されてから判断が出るまでの時間は、長くても数秒、短ければそれ未満です。判断が下されると、命令はリレーモジュールを介して灌水ポンプ、換気ファン、遮光幕、二酸化炭素補給装置、ミスト噴霧器、補光用LEDへ直ちに伝えられます。センサーボックスの緑色の光から始まった一つの数値が、数秒後に温室の向こう側のファンを回す瞬間までつながります。

測定値は、保存するか表示するかによって、用途がもう一度分かります。ゲートウェイを通った値は時系列データベースに順々に蓄積され、栽培者はウェブや携帯電話の画面で、過去一日、過去一週間の温度と湿度のグラフをそのまま見渡せます。値があらかじめ定めた危険範囲を超えると、SMSやアプリの通知ですぐに警報が出るため、栽培者が夜通し温室内にいなくても、寒波や停電などの突発事態に対応する余裕が生まれます。長期間にわたって蓄積された記録は、それ自体が後で収穫量や病害発生と照合できる資料となり、認証や履歴管理が必要な農産物なら、栽培過程を証明する根拠にもなります。

インドネシアのサンディブアナ農場とプルウォサリにある2か所の商業用水耕レタス温室は、この流れを一体として示す事例です。DHT11温湿度センサー、DS18B20水温センサー、FC-28土壤水分センサー、pHおよびEC培養液センサーを設置し、NodeMCU ESP8266ゲートウェイで値を収集して、クラウドデータベースまで運びました。4か月間で蓄積された値は1万5492件に達し、後に収穫量を予測し、環境を自動調節する判断体系の基礎材料として使われました。数個のセンサーと安価なWi-Fiモジュールだけでも、商業温室規模のデータ基盤を構築できることを、この事例は示しています。

韓国の江原大学校内にある300平方メートル規模の冬季温室も、よく似た構成を備えています。ペレットボイラーと蓄熱槽、チューブレイル暖房設備を備えたこの温室は、JNGW100外部気象装置と、内部各所に設置した熱電対センサーの値をGL840ロガーで1分ごとに漏れなく記録します。このように密に蓄積された記録があって初めて、厳しい寒波が訪れる数時間前に蓄熱槽の温水をあらかじめ加熱しておく予測型暖房判断も可能になります。計測間隔を1分単位まで狭めること自体が、その後に載せるどのような精巧な判断ロジックより先に整えるべき基盤です。

日本の愛知県の農業イノベーション事業で試験されたスマートミスト制御の事例は、センサーを一つ追加すると何がかわるかを示しています。温室内の温度と湿度だけを見るのではなく、屋外の日射強度、すなわち日光がどれほど強く降り注いでいる

かを測る値も読み取り、空気がどれほど乾いているかを一つの数値で表す飽差（VPD）をリアルタイムで計算します。日差しが急に強まり、この数値が急上昇すると、葉が濡れない程度に短時間だけミストを噴霧して作物のストレスを和らげ、栽培者はスマートフォンアプリでその推移を見守ります。温度や湿度のような個別の値を一つにまとめて新たな数値を作ることが、「インテリジェント」計測という言葉が指す実際の姿に近いものです。

台湾・高雄の大型多段栽培棚と垂直農場の事例は、センサーネットワークを何層にも積み上げると、さらに何が見えるかを示しています。ランと水耕野菜を多層の棚に分けて栽培するこの農場は、棚の一区画ごとに温湿度、pH、水分センサーを別々に取り付け、その値を中央の現場制御盤とクラウド監視画面へ集約します。棚の上段と下段では光と風の当たり方が異なるため、温室全体を一つとして捉えていた計測方式を、層単位に細分化しました。ここに電力と用水の使用量も併せて測り、炭素排出量を画面に表示することで、センサーが作物の状態とともに、農場運営全体の効率まで示す計器盤の役割を兼ねるようになりました。

このように周到に設計された体系にも、弱い部分は残っています。温室内の相対湿度が90パーセントを上回ったり下回ったりし、農薬を散布するたびに腐食性ガスが広がり、ほこりと水滴がこびり付く環境では、センサーの感度が時間とともに少しずつ鈍ります。この現象をドリフトと呼び、温室内の実際の温度は変わらないのに、センサーが示す数値だけが少しずつずれていく状態を意味します。これを防ぐため、人が手で再調整しなくても複数のセンサー値を相互に比較して自ら目盛りを直す自己校正ソフトウェアと、水やほこりを防ぐ耐久性ナノ素材コーティングを施したセンサーが併せて研究されています。

定期的な校正も欠かせない手順です。新しいセンサーを初めて設置するときは、メーカーが測定した基準値と実際の現場値を合わせる初期校正を行い、その後も数か月に一度、値がすでに確認されている標準液や標準光源と照合して目盛りを合わせ直します。湿度センサーであれば、食塩水のように湿度が一定に保たれる飽和溶液にしばらく入れ、その値を基準とする方法が一般に使われます。このように手間のかかる手順を、人が毎回温室内を回って繰り返す代わりに、複数のセンサー値を相互に比較し、ずれたものを見つけるソフトウェア校正が、少しずつ人手に代わりつつあります。

空間をどのように分けてセンサーを設置するかも、依然として解くべき課題です。大きな温室ほど、換気ファンの前と温室中央、作物群落の上部と下部との気候差が大きくなりますが、等間隔でセンサーを格子状に設置する方式では、肝心の温度差が大きい区域を見落としがちです。区域を分け、それぞれ異なる密度でセンサーを

配置する層化サンプリング方式と、CFDによる再構成計算を重ねて使う方法が、その代案として扱われています。センサーをどこに何個置くかを決めることが、どのセンサーを使うかを選ぶことに劣らず重要になっています。

メーカーの異なるセンサーとプログラマブルロジックコントローラー（PLC）、各種制御装置を一つにまとめようとする、異なる通信言語のために値がずれたり、まったく接続できなかったりすることが頻繁に起きます。農場に新たな設備を導入するたびに、既存の機器と互換性があるかを先に確認しなければならない負担も、ここから生じます。これを解決するため、産業現場で広く使われる標準通信規格 OPC UA、日本の農業データ連携基盤WAGRI、IoTを農業向けにしたIoPクラウドなどの共通規格が定着しつつあります。規格を統一するとともに、工学を学んでいない栽培者でも数日以内に使いこなせる、わかりやすい画面と操作方法を作ること、並行して解くべき課題として残っています。

現場へ下ろした人工知能による計算が実際に直面する難しさは、試験運転で得た精度だけではすべて明らかになりません。アクチュエーターが命令を受けて実際に動くまでには目に見える遅れがあり、風や振動といった物理的要因が予期しない瞬間に入り込みます。通信が一時的にでも途切れると、ゲートウェイはクラウドからの応答をいつまでも待てないため、現場側にも最低限の判断ロジックを残しておくなければなりません。安価なマイクロコントローラー上でも、このような判断を取りこぼさず実行することが、次の目標として残っています。

計算をゲートウェイ内へ移す流れが定着するほど、そこに載せる人工知能モデル自体も小さく軽くしなければなりません。数値を8ビットに減らして計算量を抑える量子化や、大規模モデルが学んだ内容を小規模モデルへ移す知識蒸留などの技法が、その解決策として磨かれています。センサーを選ぶこと、電力を供給すること、通信網を敷くこと、欠測値を埋めてノイズを除くこと、尺度を合わせることは、それぞれを別々に見れば些細に思えますが、一つでも欠ければ、その上で下されるあらゆる判断が揺らぎます。温室の柱に付いたセンサーボックスが読み取った値は、空白が埋まり、ノイズが除かれ、尺度がそろって初めて、数秒以内にファンとポンプと照明を動かす判断へ変わります。

白い箱の中のセンサーが本当に正しい値を読み取っているかは、また別の問題です。栽培者が手にする小瓶には、酸性度4、7、10に正確に調整した透明な液体が入っており、センサーの先端をその瓶へ順番に浸しては取り出しながら、画面に表示される数値を標準値に合わせて調整する作業が検査・校正です。電気伝導度センサーも同じように、伝導度があらかじめわかっている標準液に浸して、目盛りを合わせ直します。この作業は一度行えば終わるものではなく、季節が変わるたび、少なく

とも数か月に一度は繰り返さなければなりません。検査・校正を行わないまま半年、1年が過ぎると、センサーは相変わらず数値を出し続けますが、その数値が示す実際の値との開きが少しずつ広がったまま、時間だけが流れます。そのため現場では、いつ、どのセンサーを、どの標準値に合わせたかを記載する校正記録表を別に管理し、この記録があって初めて、後にどの時期のデータを信頼し、どの時期のデータを疑うべきかを見分けられます。

センサーを重ねて設置したとき、どのセンサーの値を採るかを定める規則も必要です。同じ区域に温度センサー3台を並べて設置すると、そのうち2台は摂氏24度前後を示します。残りの1台だけが31度を示すなら、多数決で残る2つの値を採用し、外れた側を疑わしいセンサーの一覧に加えます。10秒間に温度が5度以上跳ね上がるような、現実には起こりにくい変化が記録された場合も、同じ方法で除外します。このように除外されたセンサーはすぐに取り外さず、数日間さらに観察し、同じずれが繰り返されるかを確認してから故障と確定します。一度の跳ねは一粒のほこりが通り過ぎた偶然かもしれませんが、繰り返されるずれはセンサー自体の問題と見なすべきだからです。

補間で埋めた値には、印を残しておくことも欠かせません。直線で結んだ場合も、過去の似た推移を取り込んだ場合も、このように埋めた数値はセンサーが実際に測定した値ではなく、計算が推定した値だからです。この印がなければ、数か月後に収穫量と環境記録を並べて比較するとき、推定した数値と実測値が混ざり、見当違いの結論へ流れかねません。さらに厄介なのは、通信断ではなく、配管の凍結やポンプ停止という本当の故障であるにもかかわらず、補間がその空白を滑らかな数値で埋め、問題が表面に現れない場合です。そのため空白区間が一定時間を超えて続けば、補間とは別に現場点検の通知も出し、計算が問題をひそかに覆い隠すことを防ぎます。

通信網を設計するときは、どれだけ配線するかと同じく、信号が途切れた際にどう持ちこたえるかも決めておかねばなりません。無線センサーノードは、ゲートウェイとの接続が切れると値をそのまま失うのではなく、内蔵記憶装置へ一時的に保存し、接続が回復した瞬間に、たまった値を一括して送り上げる方式を使います。ノード同士が信号を中継して伝えるメッシュ構造を組んでおけば、鉄骨の柱一本が電波を遮っても、隣のノードを経由して値を迂回させる経路が残ります。有線区間はこのような迂回路を設ける必要がない一方、線自体が切れると代替手段がないため、中心となる幹線ほど予備線を一本追加しておく冗長化が併用されます。

栽培者が見る画面も、数値を並べるだけでは役に立ちません。正常範囲は緑、注意が必要な区間は黄色、直ちに対処すべき区間は赤で塗り分ければ、画面を一瞥した

だけでも状態を判断できます。問題は、警報が頻繁に鳴りすぎると、肝心なときに栽培者が通知を無視するようになることです。そこで、小さな変動は画面内に静かに表示するだけにし、複数の値が同時に危険範囲へ入るか、同じ警告が一定時間を超えて続いたときだけ携帯電話へ通知するように、しきい値を分けます。最初の通知に反応がなければ、しばらくして電話までかかるように段階を上げる農場もあります。画面の片隅には、現在値と並べて1時間後、1日後の予測値も表示し、栽培者が数値の上昇後に反応するのではなく、上がる前に対処できるよう支援します。

これらすべての装置が、潤沢な予算を持つ大規模農場でしか使えないなら、成功は半分にとどまります。センサーとゲートウェイ、ソフトウェアの利用料を合わせると、小規模農家が気軽に導入しにくい金額になりがちで、いざ機器を導入しても、故障時に対応できる技術者を農村で見つけにくい場合が少なくありません。遠隔からポンプと換気窓を開閉する体系は便利である一方、外部から不正に接続され、操作される危険も抱えます。真冬に誰かがシステムへ侵入して換気窓を開ければ、数時間以内に温室一棟が丸ごと凍り付く恐れがあります。さらに、数年間にわたって蓄積された環境と生育の記録が、データを生み出した栽培者の手元に残らず、機器を販売した会社のサーバーに閉じ込められ、別会社の機器へ替えた瞬間に記録全体が途切れる問題も残っています。機器の導入費用と保守要員、遠隔制御のセキュリティ、データポータビリティは、この技術が今後解決すべき課題です。

出典・参考文献

学術論文

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.

報告書およびウェブ資料

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/>

講演・映像資料

1. 高雄農来訊. (2025). 114年高雄智慧農業年度成果發表暨研討會. YouTube. <https://www.youtube.com/watch?v=1Edc6pP4HnU>
2. KYOTO SMART CITY EXPO. (2025). スマート農業の最前線～植物との対話からつくる未来の農業. YouTube. <https://www.youtube.com/watch?v=PzHccCvmsRs>
3. 愛知県農業水産局. (2026). 【あいち農業イノベーションプロジェクト】プロジェクト2027 技術提案募集説明会（2026.6.10開催）. YouTube. <https://www.youtube.com/watch?v=jpkoNqscGu8>
4. 農業農村情報通信環境整備 準備会. (2026). 第5回オンラインセミナー「地域でデータを共有しよう！農業データの利活用最前線～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=TvmtvwyHwUQ>

3.2

デジタルツインとAIによるスマート環境・生育最適化

デジタルツイン（Digital Twin）は、実際の温室の構造と設備をコンピューター内にそのまま再現した仮想モデルに、センサーがリアルタイムで送る気温、湿度、二酸化炭素濃度、土壌水分などのデータを組み合わせ、今後温室内の環境がどのように変化するかを事前に計算する技術です。天窓を開けたり灌水バルブを調整したりする措置を画面内のモデルに先に適用し、その結果を計算で確認した後に、同じ措置を実際の温室設備へ送ります。時間の経過に沿って温室の状態とともに動いていくことから、ツインという名が付けました。

デジタルツインは、温室をそのまま写した3次元画像だけを指すものではありません。外観が似ているだけのモデルなら、わざわざ計算しなくても写真一枚で足りるからです。本当の中核は、温室内の空気と土、そしてそこで育つ植物が時間とともにどう変わるかを計算する、生きて動くエンジンにあります。このエンジンの中心となるのは、国際的に広く使われる作物生育モデルDSSAT（農業技術移転のための意思決定支援システム）バージョン4.8です。このモデルは、葉で光合成によって作られた養分が根や果実など体の各部へ配分される過程、根が土中の水と養分を吸収する速度、暑さや干ばつなどのストレスに植物が反応する程度を、日単位で計算します。栽培者が画面上の窓を開閉すると、このエンジンがその変化を反映して再計算し、明日この温室のトマトの茎がどれだけ太くなるか、葉がどれだけ垂れるかまで、あらかじめ画面に表示します。

温室内では、気温と湿度、二酸化炭素濃度と日射の強さ、土や培地に含まれる水と肥料の量が別々に動くのではなく、すべて絡み合って動きます。窓を開けると気温と湿度がともに下がり、その風によって二酸化炭素が外へ逃げる速度まで変わります。ハンドルを一つ回しただけで水圧と水温が同時に変わるシャワーと変わらない絡み合いです。設定温度に達したらファンをつけ、下がれば切る従来のオン・オフ制御では、この絡み合いについていけません。反応が一拍ずつ遅れ、その遅れた分だけ暖房費と水が無駄になり、植物は必要以上に暑い、寒い、乾いた時間を何日も耐えなければなりません。デジタルツインと人工知能制御が温室技術の中心へ入ってきた理由は、まさにここに 있습니다。実際の窓とバルブを動かす前に、画面内で先に計算してこそ、この絡み合った反応を遅れずに捉えられるからです。

デジタルツインが大きな価値を示すのは、栽培者が一度も行ったことのない措置を試すときです。補光を普段よりはるかに強くしたらどうなるか、灌水時刻を2時間早めたら果実の大きさがどう変わるかを実際の温室で試せば、結果がわかるまで少なくとも一作期、長ければ1年かかります。その間に判断が間違っていれば、その年の収穫はそのまま失われます。しかし画面内の双子の温室では、同じ措置を数分で事前に計算でき、結果が悪ければ元に戻すだけで済みます。新人パイロットが実機に乗る前に、フライトシミュレーター内で何度も失敗してみるのと同じ理屈です。失敗してもよい練習場があるというだけで、栽培者はこれまでためらっていた措置を、より果敢に試せるようになりました。

これらすべての計算と判断を、人が昼夜を問わず管理することはできません。そこで研究者たちは、温室に代わって監視し判断する人工知能エージェントを作りました。中国の研究チームが発表したAgriAgentがその一例です。このシステムは質問に答えるだけのチャットボットではなく、温室に常駐する新人栽培者に近いものです。計器盤を読み、先週どのような措置を取ったかを記憶し、必要なら分厚い栽培教本を開いてからバルブを回す態度を再現するからです。AgriAgentの中核的な判断機能は、Qwen2.5という大規模言語モデル（LLM, Large Language Model）が担い、15億、30億、70億と規模の異なる3種類のモデルが並んで試験されました。パラメーター、すなわちモデル内で学習によって値が定まる数値の個数が多いほど、より多くの状況を区別して記憶し、よりきめ細かく判断します。

AgriAgentは、感知、記憶、検索、推論、行動という5段階を7日に一度、順にたどります。まずセンサーデータを12種類の数値に整理した状態値を作ります。土中の水分量、土中の窒素と有機物の量、その日の平均気温と最高気温、日降水量と風速、空気中の二酸化炭素濃度、光合成に実際に使われる光の強さ、播種後の経過日数、そして水不足と生育遅延を一つの点数で表す2種類のストレス指数が含まれます。フォーマット変換器という装置がこれらの数値を人が読める文章へ展開し、過去の記録と後述する検索結果を添えて人工知能モデルに渡します。12種類の数値を一文ずつ文章にすれば、結局、いまこの作物がどれほど水を欲し、どれほど順調に育ったかを人の言葉へ移したものにすぎません。数字で埋まった表一枚を、人が読んですぐ理解できる短い報告書へ変える手順です。

農業には教科書にしか載っていない細かな知識が多く、どれほど大きな言語モデルでも、すべてを記憶しておくことはできません。AgriAgentは、このような知識を丸ごと暗記する代わりに、必要になるたび分厚い本から該当するページを探して開く方式を使います。検索拡張生成、英語の略称でRAG（Retrieval-Augmented Generation）と呼ばれるこの方式を使うため、研究チームは農学教材と技術手帳の510万字を光学文字認識（OCR）によってデジタル文書に変換し、そのうち有用

な440万字を再び小さな断片に分けて整理しました。各断片には、どの章、どの節から取った内容かわかるようにタグを付けました。bge-large-zhという768次元埋め込みモデル、すなわち文章を数値ベクトルへ変換し、意味の似た文同士を近くに集めるモデルが、意味の通じる断片を探し、そこへ語句がそのまま一致するかを見る検索を加えて、現在の状況に最も合う5つの文書を選び、人工知能に渡します。

文書を手にした人工知能は、すぐに答えを出さず、段階を踏みます。今が発芽期なのか、開花して結実する時期なのかをまず見分け、水が不足しているか、生育が遅れているかを調べた後、その判断に基づいて命令を決める思考の連鎖（Chain-of-Thought）方式です。人が暗算で答えだけを出すのではなく、解法の過程を一行ずつ書いていくことに似ています。こうして得られた結論は、灌水量、補光強度、換気と加温の有無、施肥量、二酸化炭素放出量という6種類の数値からなるJSONという所定形式のデータに整理されます。灌水量は毎時0から30ミリメートル、補光は通常の0から200パーセント、施肥量は1ヘクタール当たり0から50キログラムの範囲で決まります。ツール実行器という最後の確認手順が、これらの数値が安全範囲を外れていないかをもう一度確認し、範囲外の値を範囲内へ切り詰めてから、DSSATエンジンまたは実際の温室機器へ命令を送ります。

例えばある月曜日の朝、センサー値が、土中の水分量は通常より少なく、日中の最高気温は平年より3度高いという結果を示したとします。水不足ストレス指数も、危険信号に近い水準まで上がっています。AgriAgentはこの組み合わせを前に、現在が果実の肥大期であることと、この時期に土が乾くと生理障害につながりやすいという知識ベース内の記述を併せて読みます。結論は、灌水量を通常より増やし、日中の補光を少し弱めて、葉にかかる負担を減らす方向へまとまります。人間の栽培者なら経験と勘で下すようなこの判断を、AgriAgentは数値と文書を根拠に数秒で整理しました。

機器はいつでも故障する可能性があります。灌水装置が止まり、土へ水を供給できなくなったとします。人なら慌てる状況ですが、AgriAgentは原因と結果を考える推論能力によって別の道を探します。換気と加温を調節して葉から水分が失われる蒸散速度を遅らせ、二酸化炭素放出量を増やして光合成を助けることで、水不足による損傷をある程度相殺する方法です。料理人が冷蔵庫で一つの材料が切れていることに気づき、残りの材料の比率を調整して同じ料理を仕上げるのに似た対応です。人が遅れて駆けつけ、バルブを修理するまで、作物はこの暫定調整によって最悪の事態を免れます。

このような判断力が実際に信頼できるかを確かめるには、極端な天候で事前に試験しなければなりません。研究チームは1994年から2023年までの30年分の気象デー

タを基に、平常、変動、極端という3段階の強度の仮想天候を作り、合計90種類の年間シナリオを用意しました。極端シナリオには、20日間続く高温乾燥、80ミリメートルを超える豪雨が5日間集中する状況、乾燥した20日の直後に豪雨の10日間が続く急変など、複合的な悪条件が含まれています。このような状況をAgriAgentに経験させた後、作物が生き残るか、どれほど耐えられるかを見守ります。実際の温室ではめったに遭遇しない最悪の組み合わせも、画面内なら危険を伴わず何度も経験できます。

レジリエンスが高いという言葉は、具体的な場面を指します。20日間ずっと暑く乾いた日が続くシナリオで、訓練の足りない制御方式は、ストレス指数が一度危険範囲に入ると、その後なかなか回復できず、作物はそのまましおれていきました。一方、AgriAgentは水が不足する初期に灌水と補光を少しずつ増やし、ストレス指数を低い水準に抑え、続いて豪雨が集中する急変区間でも換気量を素早く増やして、過湿による被害を減らしました。最悪の天候を前にしても手をこまねかず、瞬間ごとに状況に合わせ、少しでも良い選択を続けたということです。

AgriAgentのように言語を扱う人工知能だけが、温室へ入ってきたわけではありません。より以前から使われてきた人工ニューラルネットワーク（ANN, Artificial Neural Network）とサポートベクターマシン（SVM, Support Vector Machine）も、微気候を読み取る役割を担っています。両モデルとも、数値データの中からパターンを見つける統計ベースのプログラムで、Orangeというデータ分析ツール上で、温室内の温度と湿度、紫外線強度を同時に調べ、現在の状態を適正、過剰、不足の3区分のいずれかに分類します。この分類の精度は99.99パーセントに達しました。1万回判定して、ようやく1回間違えるかどうかという水準ですから、人が目で毎回計器盤を確認するより、はるかにきめ細かな監視です。

温度と湿度は一日の中でも激しく上下し、互いに影響し合うため、予測が困難です。日差しが一時的に雲に隠れ、再び差した瞬間にも、温室内の数値は細かく揺れます。研究チームはまず、複数の位置のセンサー値へ適応型カルマンフィルターをかけ、この揺らぐノイズを静めます。写真を撮るときに手ぶれを補正し、ぼやけを減らすのと似た手順です。ノイズを除いた値でなければ、その次の予測モデルが誤った方向に学習してしまいます。

ノイズを除いた後は、灰色オオカミ最適化（GWO, Grey Wolf Optimizer）という方法で、予測ニューラルネットワークの詳細設定を調整します。灰色オオカミの群れが獲物を多方向から徐々に囲むように、複数の設定候補を反復して絞り込み、適切な組み合わせを見つける方式です。こうして調整したLSTM（長短期記憶、Long Short-Term Memory）ニューラルネットワークにアテンション（注意、Attention）

技法を加えると、過去数時間の記録のうち、現在の予測に本当に重要な瞬間だけを選んで重みを付けます。この組み合わせは、今後数時間以内に温室の温度と湿度がどのように動くかを同時に予測します。

どれほど正確な予測でも、それを実際の暖房装置をつけたり消したりする判断へ移せなければ意味がありません。データ駆動型予測制御、略してDDPC（Data-Driven Predictive Control）と呼ばれる方式は、寒くなることを事前に知り、寒波が到来する前に水を温めておく手法です。韓国・江原道春川の300平方メートルの温室に、ペレットボイラーと蓄熱槽、チューブレール加温装置を備え、1分間隔でデータを収集する現場試験が行われました。GRU（Gated Recurrent Unit）というLSTMより軽量のニューラルネットワークが、直近7日分のデータである1万80個の測定値を学習し、その後の1日分で性能を確認する手順を繰り返しました。このモデルは寒波が来る1、2時間前から3時間前に温室内の気温低下を予報し、その予報に合わせてボイラーと温水バルブを事前に動かします。その結果、作物が耐えられる最低気温を下回ることを防ぎながら、不要な暖房を減らして燃料費を節約しました。

暖房と収穫量は、しばしば反対方向へ引っ張る力です。温度を余裕を持って上げれば作物は早く育ち、果実も多く実りますが、その分ボイラーは休まず動き、燃料費がかさみます。反対に暖房を控えれば、燃料費は減っても、低温に苦しむ作物の生育速度が落ちたり、花芽が落ちたりして、結局は収穫量で損をします。デジタルツインは、この二つの目標を別々に計算せず、一つの画面上に重ねて見ます。同じ冬季シナリオで暖房強度を数段階に変えて実行すると、燃料費による損失と収穫量の損失を合計した値が最小になる温度が明らかになります。春川の温室のGRUベースDDPCが、寒波直前だけボイラーを短時間動かし、最低気温をぎりぎり守ったことも、結局はこの交点をリアルタイムで探し直す計算の結果です。

このような予測モデルの性能は、いくつかの数値で確認できます。決定係数、記号ではR二乗と表記するこの指標は、予測値が実測値とどれほど近く重なるかを0から1までの数値で示し、1に近いほどよく一致したことを意味します。今回の微気候予測モデルは0.77から0.93までの値を示しました。春川の温室のGRUベース暖房制御モデルは、二乗平均平方根誤差、すなわちRMSEで1.43度前後の誤差を示しました。温度計の目盛り一つ半ほどのずれですから、暖房制御に使うには十分な精度です。温室状態を適正、過剰、不足に分ける分類モデルは、AUC-ROCという指標で0.988から0.991までを記録し、これは3つの状態を取り違えることがほとんどないことを意味します。

こうして作られたAgriAgentの能力は、複数の作物で試験されました。研究チームはDSSATベースのデジタルツイン上で、トウモロコシ、キビ、テンサイ、トマト、ハクサイという異なる5作物を選びました。トウモロコシは日光をひときわ効率よく使う光合成経路を持つ作物、キビは干ばつに強い作物、テンサイは根を食べる作物、トマトは果実を食べる作物、ハクサイは葉を食べる作物で、異なる生育様式の作物を幅広く代表します。90種類の気象シナリオに3段階の強度を掛け、合計450回の全生育期間シミュレーションが行われました。70億パラメーターのモデルは、人の介入がない自然生育と比べて、トウモロコシ、キビ、テンサイの収穫物乾燥重量を明らかに増やしました。発芽期に低温警報が出ると、補光介入の強度を自ら120パーセントまで引き上げ、冷害を減らすこともありました。15億、30億、70億とパラメーターが増えるにつれ、制御性能も順に向上する傾向が確認されました。

例えば、トウモロコシのシミュレーション一例を見ると、エージェントは播種日から何日経過したかを数え、現在が芽の出る出芽期なのか、穂が出る時期なのかを最初に判断します。同じ低温でも、播種から10日目に経験する場合と、穂が実る盛りに経験する場合では作物への打撃が異なるため、生育段階を見誤れば、どれほど正確な温度予測も不適切な処方につながります。実際の試験で、エージェントが低温警報を受けて補光を引き上げた時点も、この生育段階の判断が先にあったからこそ可能だった措置です。日数を数えるだけでなく、その日数が作物の体内でどのような意味を持つかまで読み取ります。

デジタルツインは実験室内にとどまらず、実際の商業農場にも適用されました。インドネシアのSandi Buana Farmでは、水耕レタスを栽培しながら、温度、湿度、EC、酸性度を測る高解像度センサーから1万5,492件の標本を集めました。ECは、水中にどれほど肥料成分が溶けているかを電気の通りやすさで測る値で、酸性度はその水がどれほど酸性またはアルカリ性かを示す値です。このデータを機械学習予測アルゴリズムに入力し、レタスの収穫量と栽培環境変数を一緒に自動調整する体系を運用した結果、人が一つずつ手を加えなくても、適切な水分量と肥料濃度が維持されました。実験室シミュレーションが一つもなくとも、現場で蓄積した数値だけで判断体系を構築できることを、この農場は示しました。

デジタルツイン上で動く言語モデルエージェントと、はるか以前から温室で使われてきた統計ベースの予測モデルは競争関係ではなく、役割の異なる仲間に近いものです。エージェントは生育段階と複数の変数を一度に読み取り、大局的な視点から灌水、施肥、補光の均衡を取る役割を担い、ANN、SVM、LSTM系モデルは、分秒単位で変化する温度と湿度を取りこぼさず捉える役割を担います。実際の現場では、二つの層が重なって動く場合が多いため、大きな判断はエージェントが下し、その判断を秒単位で微調整する仕事は統計モデルが担うという分業が自然に定着します。

一方が天窓を開けるかどうかを決めれば、もう一方は窓が開いた後、温度が予想外の動きをしないかを秒単位で監視します。二つの層のどちらか一方しかなければ、大局は合っていても瞬間的な揺れを見逃すか、瞬間は捉えても季節全体の流れを読めない、片手落ちの判断にとどまったでしょう。

一つの温室で検証されたエージェントを10棟、100棟へ増やすことは、算数のように簡単には解けません。温室ごとに方角や資材、周辺建物の影が異なり、同じ命令が異なる結果を生むからです。そこで新しい温室へエージェントを導入するときは、最初の数週間、その温室固有の癖を別に学ぶ適応期間を置くことが多くなります。既存の温室で蓄積した知識ベースと判断習慣を土台にしながら、新しい現場の数値が蓄積するにつれ、少しずつ調整し直す方式です。

この流れは、数件の局地的な実験にとどまりません。デジタルツインをオンラインシミュレーターとして置き、大規模言語モデルエージェントと一つの閉ループに結び、実際の機器へ命令を出す前に、その命令が安全かをリアルタイムで検証する構造が、最近の研究で提案されました。言語モデルが、時間の流れに正確に合わせて判断を下すループ内でも役割を果たせることを示した結果です。無線センサーとアクチュエーターからなる通信網とツインソフトウェアを組み合わせ、微気候と灌水を遠隔監視して自動制御し、病害発生の可能性まで事前に見つけるスマート温室の実装事例も報告されました。栽培者は温室の敷居をまたがずに現在の状態を確認し、一つの措置を画面内で先に試してから、実際に適用します。2026年には、作物生育モデルと自律気候制御を一つにつなぐデータ駆動型温室管理方式まで提案され、デジタルツインが見せるためのモデルから、判断と実行を兼ねる道具へ移行していることが示されています。

栽培者が実際に目にする画面は、色分けされた計器盤です。12種類の状態値と6種類の制御命令がグラフと棒で並んで表示され、人工知能がなぜその命令を出したかを要約した1、2文がその隣に添えられます。栽培者はこの文を読み、そのままにすることも、気に入らなければ数値を手で修正して戻すこともできます。人が最終的に承認するまでは、エージェントの判断も草案にすぎないという原則が、画面設計へそのまま反映されています。

この体系が導入される前は、栽培者が夜明けごとに懐中電灯を持って温室を回り、温度計を一つずつ確認しなければなりませんでした。寒波注意報が出た夜は、2、3時間ごとに目を覚まし、ボイラーの状態を点検することも珍しくありませんでした。デジタルツインとエージェントがこの反復作業を引き受けることで、栽培者の一日は、問題が生じたときだけ画面の前に呼び出される形へ変わりました。一晩中平穏

なら通知一つなく朝を迎え、何かに異常があれば、その瞬間に携帯電話が鳴ります。人の手による巡回はなくなりましたが、その仕事は計算が代わりに担っています。

だからといって、この技術がすべて完成したわけではありません。DSSATベースのデジタルツイン内で検証された制御方法を、そのまま実際の温室へ移すと、計算と現実のずれが生じ始めます。アクチュエーターが命令を受けてから動くまでにかかる時間、長く使ったセンサー値が少しずつずれる偏差、温室の隅と中央の温度差、予測できなかった外部衝撃が、すべて画面内の計算と実際の結果との間に隔たりを作ります。研究者たちはこの隔たりをシミュレーションと現実のギャップと呼び、ツイン内でより厳しい状況を事前に経験させる訓練と、現場配備後も学び続ける方式によって埋めようとしています。LoRAと呼ばれる微調整方法は、大規模モデル全体を再訓練する代わりに、いくつかのつまみだけをわずかに回して新しい現場に合わせる方式で、このような継続学習に適した道具とされています。

技術がどれほど精巧でも、その技術を扱う人がいなければ、温室の片隅に置かれた飾り物にとどまります。AgriAgentが出す判断をそのまま受け入れるか、自らの長年の経験を頼りに数値を手で修正するかは、結局、栽培者が決めます。このような信頼は一朝一夕には築かれず、エージェントが数作期にわたって大きな過ちなく判断を続けて、初めて厚みを増します。画面内の双子が実際の温室と違う動きをする瞬間を数回目撃した栽培者なら、その後どれほど正確な予測が出ても、額面どおりには信じないでしょう。

70億パラメーターのモデルを動かすには、高価なグラフィックス演算サーバーと、途切れない通信網が必要です。この条件は資本に余裕のない農家には参入障壁となり、通信のたびに判断が遅れる副作用も生みます。これを解決するため、研究者たちは、モデル内の各数値をより少ないビットで表して保存する量子化（INT8）技法と、大規模モデルが見いだした判断方法を小規模モデルへ移して教える知識蒸留（Knowledge Distillation）技法を併用しています。腕の立つ先輩が要領を整理した後輩へ渡すように、70億モデルの判断習慣を15億または30億規模の小さなモデルへ移植し、温室現場の安価な機器でも動かせるようにするのです。このように小型化したモデルは、クラウドへデータを送らなくても、温室のすぐ脇にある小型コンピュータで判断を完了できます。小規模農家一人の温室でもエージェントを動かしてこそ、この技術が一部の大規模農場だけの道具にとどまらずに済みます。

収穫量を増やす目標とエネルギーを節約する目標、水と炭素排出を減らす目標は、しばしば互いにぶつかります。補光を強くすれば収穫量は増えますが、電気代も上がるという具合です。エージェントが複数の目標の間で一方だけに肩入れしないよう、報酬の計算方法を多層に設計する作業が続いています。そして人工知能がなぜ

この時刻に窓を開けると決めたのか、その判断の根拠を栽培者が画面ですぐに確認できなければなりません。判断過程がブラックボックスのように隠されていれば、どれほど正確なモデルでも、現場で信頼して任せることは困難です。デジタルツインとインテリジェント制御が実験室を出て、一般の温室の道具として定着するには、説明可能性を高める研究がさらに必要です。

出典・参考文献

学術論文

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.

報告書およびウェブ資料

1. arXiv. (2025). オンラインシミュレーターを基盤とするデジタルツインと大規模言語モデルエージェントの閉ループ温室制御検証に関する研究. <https://arxiv.org/pdf/2507.07115>
2. Springer. (n.d.). スマート温室デジタルツインの実装：無線センサー・アクチュエーター通信網に基づく微気候の遠隔監視と病害予測に関する研究. https://link.springer.com/chapter/10.1007/978-981-99-0252-1_5
3. PLOS ONE. (n.d.). デジタルツイン温室における遠隔状態監視と仮想措置検証に関する研究. <https://journals.plos.org/plosone/article?id=10.1371%2Fjournal.pone.0344946>
4. ScienceDirect. (2026). 作物生育モデルと自律気候制御を連携させたデータ駆動型適応温室管理に関する研究. <https://www.sciencedirect.com/science/article/pii/S2590005626000445>

講演・映像資料

1. 高雄農来訊. (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=rSJvjAxnY8w>
5. KYOTO SMART CITY EXPO. (2025). スマート農業の最前線~植物との対話からつくる未来の農業. YouTube.
<https://www.youtube.com/watch?v=PzHccCvmsRs>

第4章

データ駆動型精密農業と意思決定支援

4.1

スマート灌漑と施肥供給の最適化

インテリジェント灌漑システムでは、バルブを開く主体は人ではなく、土中に挿したセンサーとクラウドサーバー上で動く予測モデルです。土がどれほど乾いたか、日中の気温がどれほど上がったか、明日雨が降る確率が何パーセントかを計算し、灌漑時刻と水量を決めます。米国ネブラスカ州の実地試験では、このような灌漑スケジューリングツールを使ったトウモロコシ畑は水を29パーセントから43パーセント、ダイズ畑は10パーセントから37パーセント節約し、両方の畑で収穫量は従来方式とほぼ同じでした。

従来の農業では、水と肥料をいつ、どれだけ与えるかは、栽培者の指先の感覚と決められた時間割に委ねられていました。朝6時になると水を出し、月に一度肥料を混ぜるといった具合です。問題は、土と空が時間割どおりには動かないことです。ある日はすでに湿った土へさらに水を注いで根が呼吸する余地を奪い、別の日は乾き切った土をそのままにして作物をしおれさせます。余った水は地中深く流れて土を削り、そこに溶けていた窒素とリンは河川へ流れ込みます。気候変動によって干ばつと豪雨が交互に激しくなるなか、感覚と時間割に頼る灌漑と施肥は、ますます大きな損失につながっています。

この損失を減らす技術が、インテリジェントな灌漑・施肥供給の最適化です。土壌水分センサーと気象観測機器、モノのインターネット（IoT、複数の機器をインターネットで接続して情報をやり取りさせる通信網）、機械学習予測モデルを一つにまとめた体系です。この体系の仕事は、土と空気と作物の間を行き来する水の流れを多角的に測ること、作物の生育段階ごとに変わる水と養分の必要量を計算すること、センサーデータと天気予報をモデルへ入力して今後数日間の必要量を予測すること、その予測を受けたクラウドサーバーがバルブとポンプを実際に動かすことへ続きます。中国東北部で行われたメタ分析研究によると、慣行灌漑と施肥の代わりに、点滴灌漑と養液土耕を組み合わせた方式を使うと、作物収量、水生産性、窒素利用効率がいずれも向上しました（Li et al., 2021）。畑全体へ水をまく方式より、根元へ正確な量だけを供給する方式が優れていることを示す結果と読めます。

このネブラスカ州の実地試験は、栽培者が普段行っていた方法と、市販の灌漑スケジューリングツールを並行して動かし、比較した結果です。同じ収穫を得ながら、

水の使用量は大幅に少なくなりました。生育段階ごとにセンサー値を継続して確認し、その都度判断を変える人工知能スケジューリングでは、水を最大87.97パーセント節約した事例も報告されています。ただし、この数値は特定の作物と条件で得られた上限値であり、すべての農場へそのまま当てはまるとは考えにくいものです。

土と空と作物が水をやり取りする関係を、科学者は土壌・植物・大気連続体（Soil-Plant-Atmosphere Continuum, SPAC）と呼びます。水が土から根へ、根から茎と葉へ、葉から再び空気中へ連続して流れるという意味です。この流れの速度を決めるのは、土中の水分量だけではありません。気温が高く、風が強く、日差しが強ければ、葉から水分が急速に失われ、根はその分、土から水をより速く吸い上げます。土から蒸発する水と葉から失われる水を合わせて蒸発散量（Evapotranspiration, ET）と呼び、灌水システムは気温、湿度、日射量、風速、降水量を刻々と測定し、この蒸発散量を推定します。土中には静電容量式または抵抗式の水分センサーを複数の深さに埋め、表土と、根が実際に伸びている深さの水分を併せて確認します。システムは、これら多層のデータを重ね、現在畑にどれだけ水が残っているかを描き出します。

作物は、生まれてから枯れるまで、同じ量の水と肥料を求めるわけではありません。種子が芽を出す発芽期には少量の水で足りませんが、植物が盛んに成長する栄養生長期には必要量が急増します。花が咲く開花期には、水が不足すると花が落ち、果実が大きくなる結実期には、わずかな水不足でも果実が小さくなったり割れたりします。成熟が進む時期には、むしろ水を減らすことで糖度が上がる作物もあります。研究者はこの変化を発育指数（Development Volume Index, DVI、作物の生育程度を一つの数値で表す指数）で表します。作物の現在の生育程度を0から1までの数値で示し、その数値を段階ごとに定めた水分ストレスの限界値と比較する方式です。窒素、リン、カリウムなどの肥料成分も、同じ論理に基づき、生育段階ごとに異なる濃度と量で投入されるよう計算されます。一つの時間割に従って一年中同じ量を与えていた方式とは、根本から異なる手法です。

これらすべての物理データと生育データを、人が一つずつ手計算することは困難です。変数が10個、20個と増えると、どの変数が現在の状況で決定的かを判断しにくくなります。ここ数年、温室と露地農場の各所で、機械学習モデルがこの計算を担い始めました。センサーが運ぶ数値と気象庁の予報データを入力として受け、いま水を与えるべきか、与えるなら何リットルにするかをモデルが直接判断します。どのモデルを選ぶかは、農場の作物と規模、どのようなデータをどれだけ長く集めてきたかによって異なります。

複数のモデルのうち広く使われるのは、ランダムフォレスト（Random Forest）です。その名のとおり、複数の決定木を植えて森を作り、木ごとの判断を投票にかけ、多数決で結論を出す方式です。土壌水分、気温、湿度、降水量、土壌型、作物の種類のように、互いに絡み合う変数を入力しても、揺らぐことなく安定した結果を出します。インドの研究チームがウェブベースのプラットフォームへこのモデルを載せて試験した結果、利用者が畑の状態を入力すると、灌水が必要かどうかを「はい」または「いいえ」で答え、必要ならおよそ25リットルという具体的な水量まで推定しました（Ajay Kumar et al., 2026）。インドネシアでは、カラシナとレタスを育てる菜園にNodeMCUマイクロコントローラーと温度センサー、リアルタイムクロックモジュールを取り付け、1,200件の記録を集め、同じランダムフォレストアルゴリズムで灌水バルブを自動開閉させました（Pradasari et al., 2026）。過学習、すなわち訓練データにだけ適合し、実際の畑ではずれ現象に強いことが、このモデルが現場で頻繁に採用される理由とみられます。

肥料の量を決めるうえでは、決定木（Decision Tree）モデルが強みを示します。スリランカ農業省傘下の園芸研究開発研究所（HORDI）の慣行指針を基に作られたクラウドプラットフォームEcoGrowが、その事例です。作物の種類と栽培地域、土壌特性、灌水間隔、気候帯、施肥時期を入力すると、尿素（Urea）、重過リン酸石灰（TSP）、塩化カリウム（MOP）の3肥料を1ヘクタール当たり何キログラムずつ混ぜるべきか、数値で示します。32種類の園芸野菜作物にわたる1,535件の記録で学習させた結果、精度は97.39パーセントに達し、この数値によって実運用モデルに採用されました。EcoGrowはそれだけでなく、最寄りの肥料販売店を探す機能と、施肥方法について質問すると答える人工知能チャットボット（自動で会話するように応答するプログラム）まで一画面にまとめています。農家は数値表を自ら探し回らなくても、画面が示す配合どおりに肥料を混ぜれば済みます。

線形回帰（Linear Regression）と深層ニューラルネットワーク（DNN、Deep Neural Networkの略で、複数の層を重ねて複雑なパターンを学ぶ人工ニューラルネットワーク）を併用する方式もあります。線形回帰は、時間の経過とともに土中の水分がどのような傾きで減るかを、一本の直線に近い形で描きます。深層ニューラルネットワークは、ここに写真一枚を加えます。土の写真を沖積土、黒土、粘土、赤土などの種類へ分ける畳み込みニューラルネットワーク（CNN, Convolutional Neural Network）の判断と、気象データおよび窒素・リン・カリウム濃度データをまとめて、肥料処方を出します。土の外観を目で見分ける能力と、数値データを計算する能力を、一つのモデル内に組み合わせたものです。

稲作には強化学習（Reinforcement Learning）が使われます。強化学習は、ある行動をしたときに返ってくる報酬を観察し続け、試行錯誤を通じて、より良い行動

を自ら見つける学習方式です。天気予報データを入力として受け、マルコフ決定過程（Markov Decision Process、現在の状態だけを見て次の行動を決める数学的枠組み）に従い、どの時点で灌水する方が有利かをモデル自らが学習します。このモデルは、発育指数の追跡と間断灌漑（Alternate Wetting and Drying, AWD、水田に水を張った後、土が露出するまで乾かすことを繰り返す灌漑法）を組み合わせ、イネが穂を出す時期のように水に敏感な時期には、水を節約しながらも正確に必要な量だけを供給します（Chen et al., 2021）。水を張り続ける慣行稲作とは異なり、乾燥と湛水を精密に繰り返す方が、かえってイネに有益であることを示す結果と読めます。

これらのモデルが畑で実際に動く手順は似ています。センサーから入ったデータの欠測値を補い、数値の大きさを0と1の間にそろえる正規化を行い、作物の種類や土壌型のような文字の値を数値へ変えます。このように整えたデータで、サーバー外で事前にモデルを学習させた後、学習済みモデルだけをクラウドサーバーに置きます。現場のセンサーノードは1分から15分間隔で新しい値をサーバーへ送り、サーバーはその値を受けると直ちに推論を実行し、灌水と施肥の要否を判断します。判断結果はIoTゲートウェイを経てリレースイッチを動かし、実際に流れた水量はパルス流量計（水が通過するたびに短い電気信号を一つずつ数える計量器）で再び測定され、データベースへ記録されます。予測し、実行し、その結果を再び測る循環が途切れず動いてこそ、インテリジェント灌水システムが成立します。

現場に埋設されるセンサーを一つずつ見れば、この判断がどこから始まるかがわかります。土中には静電容量式または抵抗式の水分センサー（FC-28、YL-69などのモデル）が、深さ別に複数埋められます。表土の水分と根が伸びた深さの水分では乾く速度が異なるため、一か所だけを測ると実情を見落としやすくなります。温湿度センサーDS18B20とリアルタイムクロックモジュールDS3231も加わり、何時何分に土壤温度が何度だったかまで記録に残します。

養液栽培、すなわち土を使わず、水に肥料を溶かして根へ直接供給する水耕栽培農場では、別の種類のセンサーが必要です。水に溶けた肥料塩類の総量を測る電気伝導度（Electrical Conductivity, EC）センサー、水が酸性かアルカリ性かを測る水素イオン濃度（pH）センサー、窒素・リン・カリウム濃度センサー、全溶解固形分（Total Dissolved Solids, TDS）センサーが一组で動きます。電気伝導度が高すぎると、根の細胞内の水が逆に外へ出る浸透圧の逆転が起き、根が乾いたときと似た被害を受け、低すぎれば養分が不足します。酸性度が作物ごとに定まった狭い範囲を外れても、根が養分を吸収する経路自体が塞がれます。養液栽培現場の制御プログラムは、電気伝導度と酸性度を基準に、タンクへ原液肥料と酸性溶液をどれだ

け追加するかを計算し、値が範囲を外れた瞬間に自動でポンプを動かして是正します。

畑の中のセンサーだけでは足りません。システムは、40年以上にわたって蓄積された過去の気象データベースと土壌調査資料、3万種を超える作物品種情報、7日単位の天気予報を一括して取り込みます。WeatherAPI、米国航空宇宙局のNASA POWER、国連食糧農業機関のFAO CLIMWATなどの外部サービスから気温と降水確率をリアルタイムで受け取り、明日は雨という予報が出れば、今夜の灌水量を事前に減らすといった対応をします。空では無人航空機がマルチスペクトルカメラと可視・近赤外（Vis-NIR）分光装置を搭載して畑の上を低く飛び、作物の葉の色と反射光を撮影します。人の目にはまだ正常に見える葉でも、窒素、カリウム、マグネシウムが不足し始めると、特定波長の光を反射する度合いが先に変わるからです。診断・施肥勧告統合システム（Diagnosis and Recommendation Integrated System, DRIS）という方法でこの反射光データを分析すると、目に見える症状が現れる前に、どの養分が不足しているかを見つけられます。リンゴ園でこの無人航空機データを養液土耕モデルへつないだ試験では、葉を摘み取って実験室へ送らなくても、上空から窒素不足の有無を事前に見つけることができました（Sun et al., 2023）。

畑で測った数値がサーバーへ届く経路も、多層になっています。ESP32やNodeMCU ESP8266、Arduino、PICなどの安価なマイクロコントローラーが現場ノードに置かれ、センサー値を読み取ります。この値はWi-Fi、産業現場で一般的なRS485有線バス、広い地域を低消費電力で覆うLPWAN、第4世代移動通信モジュール、短いメッセージを少ない電力でやり取りするMQTT通信プロトコルを経て、クラウドへ上がります。サーバー側にはFirebaseリアルタイムデータベースやFastAPI、Flaskなどのバックエンドが置かれ、その上でScikit-learn、Pandas、NumPyなどのライブラリで作成した機械学習コードが動きます。栽培者は、この全過程を知る必要はありません。ウェブや携帯電話の画面に表示されるダッシュボードだけを見ればよいからです。インド・マハラシュトラ州のあるプラットフォームは、この画面をマラーティー語、ヒンディー語、英語の3言語で表示し、英語の説明を読みづらい農家にも灌水と施肥の助言が届くようにしました（Shriwas et al., 2026）。

クラウドへ到着した判断は、再び畑へ下りてきて初めて実際の効果を生みます。サーバーが灌水を決定すると、その信号はIoTゲートウェイを経て圃場に設置したデジタルリレーへ伝えられ、リレーがポンプをつけたり消したりし、区域ごとのバルブを開閉します。水流の太さを変えられる可変ノズルを使えば、同じ配管でも区域ごとに異なる量を送れます。人が手で回していた水栓を、今では電子信号が代わりに

開閉する構造です。その信号は土中のセンサーから始まり、クラウドを一周して、再び土へ戻る旅を毎回繰り返します。

カメラを加えた事例もあります。ESP32センサー端末とESP32-CAM画像センサー、FastAPIサーバーを組み合わせた自律適応型灌水システムは、温度、湿度、土壌水分を測るだけでなく、カメラで作物の状態も監視します（Ramya et al., 2026）。灌水開始後はパルス流量計がパイプを通過した水の体積を実際に数え、その数値を再びサーバーへ返します。命令を出して終わるのではなく、命令が実際にどれほど履行されたかを確認する閉ループ（Closed-loop）制御を完成させた構造です。組立説明書どおりに部品をはめた後、最後にねじが実際に締まっているかを手でもう一度確認するのと似た手順です。

日本では、農業機械メーカーのクボタ（Kubota）が、ゼロアグリ（ZeroAgri）という名称でこの体系を商品化しました。温室内の土壌センサー情報と天気予報データをクラウドへ送ると、サーバーが最適な灌水量と施肥量を計算し、自動で供給する方式です。カンキツをマルチ栽培する果樹園では、同じ土壌水分可視化技術を反対方向へ使います。水を節約するためではなく、意図的に適度に土を乾かして樹体へ軽いストレスを与え、それによって果実の糖度を上げるために使います。水を多く与える技術と少なく与える技術が、同じセンサー、同じクラウド上で異なる目的のために動いています。

この体系が正しく作動するかは、いくつかの数値で確認します。灌水の可否や肥料の種類を当てる分類モデルは、正解率、適合率、再現率などの指標で評価し、EcoGrowが示した97.39パーセントは正解率の一例です。土壌水分のような連続値を予測するモデルは、平均絶対誤差（MAE）と二乗平均平方根誤差（RMSE）により、実測値と予測値の差を測ります。これらの数値がどれほど良くても、農業に実際に役立ったかは、別の物差しで測り直さなければなりません。水1立方メートルでどれだけの作物を育てたかを示す水利用効率（Water Use Efficiency, WUE）と、窒素肥料1キログラムで作物がどれだけ生育したかを示す窒素利用効率（Nitrogen Use Efficiency, NUE）が、その物差しです。水と肥料を実際にどれだけ節約したかが、人工知能モデルの正解率より、この技術の価値を測る尺度に近いものです。

根のすぐ前へ決めた量だけを与える方式を、養液土耕（Fertigation、水を与えるときに肥料も溶かし、根元へ送る方式）と呼びます。水を与える灌水と肥料を与える施肥を一つにまとめた言葉です。土全体へ肥料をまいて水を与える慣行方式とは異なり、養液土耕は点滴管を通じ、根が実際に伸びている狭い区域だけへ肥料を溶かした水を流します。イタリアで土を使わずに栽培するイチゴを対象にした試験では、センサーを基盤とする養液管理が、資源利用と作物の状態をともに向上させま

した（Bonelli et al., 2024）。中国東北部の圃場試験でも、点滴灌水と施肥技術を組み合わせた際に、養分と水の利用効率がともに向上したと報告されています（Fan et al., 2020）。畑全体へ水を与えれば、肥料もそれだけ広く分散し、根の届かない土中深くへ漏れ出した窒素は、そのまま損失になります。狭い区域へ正確に与える方式が、この損失を発生源で防ぐ構造です。

葉を摘み取らずに養分状態を把握しようとする試みは、無人航空機の画像にとどまりません。施設栽培、すなわちビニールハウスやガラス温室のように屋根で覆われた施設で、トマトを節水型で栽培する試験では、可視光と近赤外を併用するハイパースペクトル撮像装置によって、葉の窒素含有量を非破壊で推定する方法が試みられました（Hu et al., 2025）。節水灌水方式と葉の窒素状態を併せて観察すれば、水不足と養分不足が重なって現れる時点を、より早く見分けられます。葉を摘んで実験室の分析装置へ入れる従来方式は時間がかかり、その間に作物はすでに次の段階へ進んでしまいます。カメラで葉を照らすだけで窒素状態を推測できれば、灌水と施肥の決定を1日、2日と先延ばしにせず、直ちに下せます。

高価なサーバーを用意するのが難しい小規模農家に向けた動きもあります。低コスト・低消費電力のエッジ人工知能とTinyML（ごく小さなマイクロコントローラー上でも動くよう軽量化した人工知能モデル）を、資源の乏しい農場へ導入する研究が整理されています。毎回クラウドサーバーへデータを送り、応答を受け取る代わりに、畑に置いた小型機器内で直ちに判断を完了する方式です。通信が途切れやすい遠隔地や、インターネット料金が負担になる農家ほど、この現場完結型人工知能が力を発揮します。IoT機器と機械学習を組み合わせたスマート灌水システムを扱う研究でも、安価なセンサーとマイクロコントローラーだけで灌水の自動化を実装できることが、繰り返し確認されています（Kathilkar et al., 2026）。機器の価格はすでに大きく下がっており、残る課題は、その機器を扱える人をどれだけ増やすかに近いものです。

現場へ長期間埋設したセンサーは、時間が経つにつれ性能が揺らぎます。肥料を頻繁に与えた土ほど塩分濃度が高まり、湿気と微生物膜がセンサー表面に付着することで、水分センサーと電気伝導度センサーの感度が徐々に低下します。設置時には正確だった値が、数か月後には実際より低く、または高く出るドリフト（Drift、時間とともに測定値が本来の基準から少しずつずれる現象）です。ドリフトに気づかないまま数週間過ぎると、システムは、すでに十分湿った土へ水を与え続けるよう命令する可能性があります。これを防ぐため、ソフトウェアによってセンサー値を自動で合わせ直す自己補正仮想センサー技術と、耐食性の高いナノ素材で作ったセンサーを開発する研究が進められています。土中へ長く入れるほど曇るガラス窓を、

定期的に拭くのではなく、初めから曇らない素材へ替えようとする試みに近いものです。

一つのセンサーが代表できる土地は、考えるほど広くありません。広い露地畑や大きな温室では、土の性質と傾斜、作物の葉の繁り方が区域ごとに異なるため、同じ時刻でも、ある区域は湿り、別の区域は乾いています。一点だけのセンサー値を信じて畑全体へ同じ量を与えれば、すでに湿った区域はさらに湿り、乾いた区域は乾いたままです。一棟の温室内でも、出入口に近い列と奥の列では日光と風が異なるため、同じ温室だからとセンサー一つだけを信じて安心することはできません。そこで、無人航空機で撮影したマルチスペクトル画像と空間補間法を、地上センサーデータとリアルタイムで融合するマルチスケール融合技術が、次の段階の課題に挙げられます。

機器の価格が下がったからといって、導入が自然に容易になるわけではありません。ESP32のような部品自体は大幅に安くなりましたが、これらの部品を組み合わせ、自分の農場に合わせてモデルを再調整する作業には、依然として多くの手間がかかります。これまでの農作業とはまったく異なる画面と数値を新たに習得しなければならない負担が、実際の導入を阻む壁になっています。この壁を低くするため、直感的なモバイル画面と人工知能チャットボット、多言語による音声案内を併せて搭載する試みが続いています。機械を購入する費用より、機械に慣れる費用の方がはるかに大きく残っています。

事前に集めたデータだけで学習したモデルは、一度も経験していない状況を前にすると揺らぎます。例年にない猛暑や突然の干ばつが起きれば、過去のデータで固まったモデルは、不適切な答えを出す危険があります。これを補うため、現場から入るデータを継続して吸収し、自ら更新するオンライン適応学習方式が研究されています。ここにDSSATやAquaCropのように、作物の生理反応全体を再現する生物動態モデルを組み合わせれば、水を節約する目標と収穫量を守る目標を同時に満たす多目的最適化が可能になります。センサーと人工知能がどれほど精巧になっても、競う相手は、毎回異なる顔で訪れる天候なのです。

複数の目標を同時に満たす計算は、理論にとどまらず、実際の栽培地の試験区画で先に検証されます。温室の一区画には従来方式で水を与え、隣の区画には人工知能が計算した量だけを与えるように並行して動かし、後に両区画の収穫量と水使用量を比較する対照試験が、複数の研究で繰り返されています。このような対照試験が蓄積されて初めて、特定条件だけで得られた上限値と、大半の農場で期待できる平均的な節減幅を区別できます。ネブラスカ州の事例のように、数値で誠実に確認する手順がなければ、どのような新技術も農家の信頼を得ることは困難です。

土壌連続体を横切る物理量の測定と、生育段階別のモデル化、複数の機械学習モデルによる推論、クラウドによる判断が積み重なり、バルブを開閉する一つの命令へつながります。水と肥料を節約する判断は、土中のセンサー一つ一つが送る数値と、その数値を読み取るコードが担っています。栽培者は、昨夜何時に何リットルが流れたかを翌朝、携帯電話の画面で確認し、グラフに不自然な跳ねがある区間だけ、長靴を履いて畑へ出ます。栽培者の役割は、灌水のたびにシステムの判断を事後点検する仕事へ絞られました。

出典・参考文献

学術論文

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>

講演・映像資料

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 [オンラインセミナー映像]. 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>

報告書およびニュース

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). [人工知能による灌水スケジューリングとネブラスカ州の現地比較研究に関する資料]. <https://www.sciencedirect.com/science/article/pii/S2772375525002151>
3. arXiv. (2026). [低コスト・低消費電力エッジ人工知能とTinyMLの農業現場への配備動向に関する資料]. <https://arxiv.org/pdf/2603.15085>

4.2

時空間データ融合と流通・品質管理

午前4時、南部地方のある農産物物流センターの荷降ろし場へ、冷蔵トラック一台が入ってきます。パレットに積まれたイチゴの箱には、それぞれ爪ほどの電子データロガーが一つずつ取り付けられています。トラックの扉が開いた瞬間、その表示値は氷点下に近い値から10度近くまで跳ね上がり、数分後に扉が閉まると、再びゆっくり下がります。この短い温度変動の一つ一つが、イチゴの残りの保存期間を削る実際の原因です。この箱が畑から収穫された瞬間から消費者の冷蔵庫へ入るまで、温度、湿度、ガス濃度を測るセンサーが区間ごとに替わりながら、データをやり取りします。

問題は、衛星とドローン、地上センサーが互いに異なる周期でデータを収集することです。人工衛星は4日から10日に一度、同じ軌道へ戻り、数百ヘクタールを一目で見渡します。ドローンは人が飛ばすと決めた日に限られますが、手のひらほどの区域まで細かく撮影します。畑と温室に設置した地上センサーは、数秒間隔で休むことなく数値を出します。3種類の機器が残した記録を重ねると、時間と空間の尺度がまちまちで、一つの画像として読み取れません。まさにこの尺度の違いによって、精密農業の収穫量予測と災害予察は、しばしば外れます。

この尺度をそろえる作業を、業界では気候スマート農業、英語の略称でCSA（Climate-Smart Agriculture）データパイプラインと呼びます。衛星の光学・マルチスペクトル画像、ドローンの高解像度画像、地上センサーのリアルタイム数値を、同じ座標と同じ時間帯へ移して結び付ける空間・時間整合作業を経た後、ハイブリッド深層学習とグラフニューラルネットワーク（GNN、一つの畑を点、隣接する畑との関係を線で結んだ網状構造として学習する人工ニューラルネットワーク）を載せ、一つの流れへ統合します。このように統合されたデータは、干ばつストレスや病害虫が広がる区域を事前に見分け、その年の天候シナリオに合わせて、播種と収穫の適期、予想収穫量まで事前に計算します。

実際に使われるモデル名をいくつか挙げると、この網がどのように組まれるかがわかります。AMSTF（適応型マルチスペクトル・時空間融合モデル）とGNNを長短期記憶ニューラルネットワーク（LSTM）へ組み合わせたハイブリッドモデルは、衛星とドローンが時間差で撮影したマルチスペクトル画像と、地上の気象・土壌時

系列を一つにまとめ、作物の時空間的な生育変化と最終収穫量を精密に推定します。XGBoost、CatBoost、LSTMの3アルゴリズムを連結した融合モデルは、気温、降水量、湿度などの気象変数と農薬投入量、植生指数（NDVI）の時系列を材料に、収穫量を回帰方式で予測します。ビジョントランスフォーマー（ViT）を使った別のパイプラインは、衛星、ドローン、地上センサー、作業者のスマートフォンカメラの画像までを小さく分割したパッチへ変えた後、相互の関連性を自ら比較するセルフアテンション方式で学習し、圃場単位の生育診断マップと気候対応処方を示します。このようなモデルの試験過程では、実測値と予測値がどれほど一致するかを示す決定係数が0.85から0.95の間になることが多く、作物の境界面を異なる区域に誤って分ける空間誤分類率が9.8パーセントから12.3パーセントの水準だったものが、5.4パーセントまで減ったという報告もあります。これらの数値の背後には、異なる尺度を持つ3種類のセンサー値を一つに合わせる、骨の折れる整合作業があります。

セルフアテンションという言葉はなじみにくいかもしれませんが、教室でのグループ課題に例えると理解しやすくなります。生徒一人一人が、ほかの生徒の発言をどの程度重く受け止めるかを判断しながら、自分の意見を少しずつ修正していく過程に似ています。衛星画像のある区域が、ドローン画像の別の区域、そして地上センサーの数値とどれほど関連しているかをモデル自らが検討して重みを付け、その重みを反映して最終判断を出します。人が事前に定めた規則に従う代わりに、データ自身が、何へより注意を向けるべきかを学ぶ点で、従来の統計モデルと異なります。

このように重ねた地図が実際にどう使われるかは、一枚の画面を思い浮かべると理解しやすくなります。農場管理者のタブレットには、畑全体を緑、黄、赤でまだらに塗った地図が表示され、赤い区域は、衛星が捉えた水分ストレスがドローンの近接撮影でも葉の巻き込みの兆候として再確認された場所です。地上センサーが、その区域の土壌水分が実際に基準値を下回ったと裏付ければ、モデルは3日以内にその区域から病害虫が広がる可能性が高いという警告を表示します。この警告一つを作るために、衛星、ドローン、地上センサーという3層の証言を重ねなければならなかった点が、精密農業データパイプラインの実像に近いものです。

このパイプラインは、衛星、ドローン、地上センサーという3種類の物理機器上で実際に動きます。衛星側ではSentinel-2やLandsatなどのマルチスペクトル衛星が、1,000ヘクタールを超える田畑を一度に見渡し、植生指数（NDVI、GNDVI、SAVI）と土壌水分分布を継続して抽出します。この面積をドローン費用のおよそ20パーセントだけで監視できる点が、衛星センサーの強みです。反対にドローンは、狭い区域をはるかに細かく見ます。1画素が地上5センチメートル以下を捉える解像度で、近赤外とレッドエッジ帯、ときにはハイパースペクトル画像まで撮影し、畑の中で

もひときわしおれて見える区域、雑草が広がった区域、作物の葉の形状差を、一枚の地図へ収めます。このように作られた地図を処方マップ（Prescription Map）と呼び、畑全体へ同じ量をまいていた慣行とは異なり、必要な場所だけへ必要な分を施すよう示す地図です。

地上では、温室と露地の各所に設置したセンサーが、温度、湿度、二酸化炭素濃度、土壌水分と電気伝導度（EC）、酸性度（pH）、光量をリアルタイムで測ります。ここに40年分の過去の気象記録と一週間単位の予報、格子状に細かく分けた農業気象データ、土壌調査資料、3万種を超える作物品種データベースが、クラウドパイプラインを通じて一か所へ集まります。一つの畑の数値だけを見ていた時代と比べ、現在は全国単位の気象図と品種別の特性表を同時に広げ、その畑の位置を確認します。農業機械にも手が加えられました。茶樹を整枝する管理機のような特殊農業機械へPLC（機械制御用小型コンピューター）とGPS、自動操舵センサーを取り付け、稼働時間、移動距離、走行速度、作業高と作業幅を自動でクラウドへ上げる事例が、日本で報告されています。カワサキ機研、落合刃物工業、寺田製作所が共同参加したこの茶園管理事例では、蓄積された運行記録を基に、農家ごとの作業特性と畑の条件差を図示できました。衛星とドローンが空から見下ろすものなら、この機械の記録は地面に残した足跡をそのまま写したようなもので、後に流通履歴をたどる際にも有用な材料となります。

このように性格の異なるデータを一か所へ集めた後は、前処理が必要です。衛星画像で雲によって生じた空白、センサーが一時的に動かなくなって残した欠測値は、適応型カルマンフィルターという統計技法で補い、ノイズを取り除きます。その後、値の範囲を0と1の間にそろえる正規化を行い、学習データが一方へ偏らないよう、画像を回転または反転させて標本を増やすデータ拡張まで終えて、初めてモデルへ入力する準備が整います。畑で育つ間の話は、ここまでです。作物が収穫され、箱詰めされた瞬間からは、同じ論理が別の対象へ適用されます。今度は生育の代わりに腐敗を測り、植生指数の代わりに温度とエチレングスを追う点だけが異なり、異なる機器の尺度を一つにまとめ、判断を下す点は変わりません。

イチゴの箱に付いた一つのデータロガーは、温度だけを測ります。しかし市販のワールドチェーン管理ボックスには、温度計に加えて湿度計、二酸化炭素センサー、エチレングスセンサー、色が変わって鮮度を知らせる疎水性表示ラベルまで、一緒に取り付ける例が増えています。果肉を切らずに糖度と酸性度を調べる近赤外分光計と、表面の傷を立体的に捉える3次元ビジョンカメラも、この列に加わります。これらの機器に共通する点は、外側にまったく触れないことです。箱を開けなくても、トラック内のイチゴケースの糖度、傷、鮮度を読み取ります。

これら複数の機器が出す信号を一つの判断へまとめる代表的なモデルが、協調注意畳み込み再帰ネットワーク、略してCo-ACRNです。中国・江南大学の研究チームが2026年に報告したこのモデルは、コールドチェーン輸送中に蓄積される温度、湿度、二酸化炭素、エチレンの時系列データと、疎水性表示ラベルを撮影した画像を同時に受け取ります。前段の協調注意装置は画像とセンサーの流れの時間軸を互いに合わせ、後段のセルフアテンション装置は、そうして合わせた情報を再び見渡し、全体の文脈を反映して、果物と野菜の鮮度スコアをリアルタイムで、しかも外観をまったく損なわずに算出します。鮮度スコアの算定式は簡単です。表面全体の面積に占める傷の面積の割合を、100から引いた値です。傷がなければ100点に近く、半分か傷んでいれば50点前後まで下がるという具合です。

このようなマルチセンサー融合は、江南大学の一事例にとどまりません。温度、相対湿度、エチレン、二酸化炭素、箱が受けた振動、位置情報、画像特徴、分光信号までを一度に入力する方式が、保存期間予測モデルの共通方式として定着しています。業界の評価を見ると、コンピュータービジョンを使った等級判定、IoTによるコールドチェーン監視、保存期間予測の3つが、直ちに現場へ導入できる初期導入対象として頻繁に挙げられます。カメラとセンサーを新設する作業は、既存の物流設備をそのまま残して上に載せれば済みますが、栽培方式自体を変える作業には、はるかに長い時間がかかります。理論は華やかでも、配管、冷凍庫、トラックという古いハードウェアの上に載せなければならない技術であるため、手を付けやすい箇所から順番が付く流れと読めます。

米国のコールドチェーン機器会社DeltaTrakは、このような予測型保存期間分析が、コールドチェーンにおける鮮度管理の方式自体を変えていると紹介しました。このような予測型保存期間分析は一般に、冷凍コンテナのセンサー値をリアルタイムで集め、各箱が店舗の陳列棚に並ぶまでに残された時間を、荷主と小売店へ事前に知らせる方式で機能します。ドイツのように外観だけでは中身を判断しにくい果実には、別の手法が使われます。複数チャンネルのガスセンサーで、果肉が熟すにつれて放出するにおい分子の組み合わせを読み取り、この値を機械学習モデルに入力して保存期間を推定する研究が報告されました。よく熟した果実と傷んだ果実では、におい分子の組み合わせが異なり、機械はこの差をガスセンサーの電気信号パターンとして読み取ります。

等級付けへ目を移すと、別の組み合わせが現れます。日本・新潟県の西洋ナシブランド「ルレクチエ」には、GCBlockを組み合わせたMask R-CNNという画像セグメンテーションモデルを用い、ナシ表面の傷と汚れの領域を画素単位で切り出します。切り出した汚れ面積の割合は、直ちに等級へ変換せず、ファジー論理という方式を一度通します。ファジー論理は、暑いと寒いのように明確に分けにくい境界を扱う

計算法です。汚れ面積が3パーセントなら明らかに良い等級、30パーセントなら明らかに悪い等級と容易に分けられますが、その間の曖昧な値は、人の検査員の目算と同じように、複数の等級にまたがって確率を分配して判断します。こうして得た値を、専門家の経験則を組み込んだファジー推論システムへ入力し、最終等級を自動で付けます。

最終等級は、赤い印が押される最上級の赤秀から、その一段下の青秀、標準的な良、商品として出しにくい無印までの4段階に分かれます。人が一日中ナシを一つずつ裏返して印を押していた仕事を、カメラとファジールールが代わりに担います。果物ごとに事情が異なるため、モデルも一つには統一されません。マンゴー、トマト、キウイのように、皮の厚さ、色、軟化速度がそれぞれ異なる果物には、DenseNetとEfficientNet系モデルが使われ、外観と内部の熟度を一緒に等級付けします。ナシでは表面の傷が等級を分ける尺度ですが、トマトでは色、キウイでは硬さがより重要な尺度になるように、果物ごとに基準そのものが異なるからです。

このような判定モデルの試験結果を見ると、数値はかなり高い水準です。正解率、適合率、再現率、F1スコアなどの分類性能指標が95パーセントから99パーセントの間になることが多く、傷の領域をどれほど精密に切り出すかを見るmAPとIoU指標も併せて報告されます。mAPは、モデルが検出した傷の位置と実際の傷の位置がどれほど重なるかを複数の基準で平均した値で、IoUは2領域が重なる面積を2領域の和集合の面積で割った値であり、1に近いほど精密に切り出したことを示します。人の目視選別と機械が付ける点数との差は、数値で見ても機械側が劣らない水準に達したと判断できます。

この変化は、人員を減らすことにとどまらなないとみられます。人の検査員は午前と午後で集中力が異なり、身に付いた習慣によって、同じナシでも日ごとに少し違う等級を付けることがあります。カメラとファジールールは疲れを知らず、同じ尺度を一日中、一作期中、保ちます。ただし、人の目が長年の経験で捉える微妙な違和感、例えば外見は正常でも中が軟らかそうな兆候を、機械が完全に捉えられたかは、なお見守るべき問題として残っています。

等級付けされた農産物は、直ちに在庫と履歴の管理段階へ入ります。畑や温室から収穫された農産物は、かごまたは鉄製ラック単位にまとめられ、バーコード、QRコード、スマートタグを一つずつ受け取ります。台湾・高雄のスマート農業事業が代表例です。この事業では、青いプラスチックかごや鉄製ラックに付けたタグによって、圃場単位のロット在庫をリアルタイムでデータベースへ上げ、温室環境警報と政府の農産物生産・流通履歴制度を自動連携します。多段に積んだ栽培棚と物流倉

庫の空間利用率を高める効果も併せて報告されました。タグの一つ一つが、箱の出所と移動経路を確認する役割を果たします。

この追跡機能は、事故が起きたときに役立ちます。台湾国際合作発展基金会在2025年に紹介した事例では、農場の生産データと食材供給業者のデータを、一つの商圏図プラットフォームへ接続しました。ある学校給食で食材の安全問題が起きれば、その弁当に入った農産物が、どの農場の誰の畑から来たかを直ちに遡ります。それだけでなく、同じ農場から品物を受け取ったほかの学校も一括して特定し、事前に対処できるようにします。事故発生後に原因を探す方式から、事故が広がる前に関連範囲を先に確認する方式へ変わったのです。

農産物のロット番号を入力すると、その箱がどの畑でいつ収穫され、どのトラックと物流倉庫を経てきたかが、そのまま画面に表示されます。ただし、誤って流通した書籍や工業製品は回収できますが、傷んだ農産物は、すでに食卓へ上った後では取り戻せません。したがって、履歴追跡システムの価値を決めるのは、事故発生後の事後処理より、事故が広がる前に狭い範囲で食い止める速さです。

保存期間の予測値を一つだけ切り離せば、不完全な情報にとどまります。近年は、保存期間予測と、米国食品安全強化法が求める履歴追跡、炭素排出量会計までを一つのデータ基盤上に載せ、生産者、荷主、小売店が同じ画面を見るモジュール型体系が登場しています。複数のシステムへ別々に接続していた方式が、一つのデータ基盤へ接続する方式へ変わりました。2018年頃に予測分析が中心だった収穫後管理技術は、その後、ブロックチェーンとデジタルツインへ軸足を移し、電力や通信事情に余裕のない現場では、軽量人工知能TinyMLが履歴追跡と情報公開を支援しています。保存期間、履歴、炭素排出量を一画面で併せて見ることで、鮮度低下の危険と履歴追跡の空白が、同じ箱の同じ瞬間にともに現れることが多くなったと判断されます。

物流倉庫では、YOLOv5やYOLOv8などの深層学習物体検出モデルが出入りする箱をリアルタイムで数え、その結果をデジタルツイン、すなわち物流倉庫全体を複製した仮想モデルへ接続します。管理者は事務所のモニター前に座ったまま、どのラックに何がどれだけ積まれているか、温度と湿度が基準を外れた区域はどこかを確認します。問題が見つかれば、実際の物流倉庫へ行く前に仮想モデル上で先に措置を試し、結果が良いと判断したときに、実際の措置を指示します。

デジタルツインは、物流倉庫の実際の状態をそのまま移した仮想モデルを意味します。物流倉庫へ新たに入った箱一つ、温度がわずかに上がったラック一つまで、仮想画面へリアルタイムで反映され、管理者はその画面で目的の区域を拡大できます。実際の温度計と仮想画面の数値がずれ始めれば、センサー故障または通信遅延を疑

う信号になることもあります。こうして実際の物流倉庫と仮想モデルを同時に見られるようになりました。

未明の物流センターで跳ね上がったその温度値も、結局、この仮想画面のどこかへ一つの点として記録されます。トラックの扉が開くたびに一時的に跳ねる数値は、人の目には些細に見えますが、デジタルツイン上では、そのトラックが今日何回扉を開けたか、ほかのトラックより温度変動が多いかを並べて比較できる記録として残ります。一台のトラックにひととき悪い癖があれば、冷蔵設備の点検を求める信号につながる可能性があります。個別の数値として散らばっていたときには見えなかった習慣が、蓄積されて初めて見えるようになります。

日本・高知県のIoP（Internet of Plants）SAWACHIクラウドは、この発想を地域全体へ広げた事例です。1,600か所を超える温室の環境データと3,000戸を超える農家の出荷データを、国の農業データ基盤WAGRIへ接続し、16種類の分析モデルを動かして、地域全体の出荷量を予測し、流通日程を組みます。農家一戸単位で記録されていた出荷情報が、高知県全体の出荷量予測と流通日程の調整に使われるデータへ拡張されました。個別農家がそれぞれ翌週の出荷量を概算で決めていた方式と比べれば、地域全体の需要と供給を一度に見渡し、順序を決める方式に近いものです。

このような事例に共通して現れる数値も、いくつか整理できます。多段栽培棚と物流倉庫をどれほど隙間なく埋めたかを見る空間利用率、問題発生時に生産農場と納品先まで遡及することに成功する割合である生産・流通追跡率、精密な処方と管理によって減った農薬とエネルギーの使用量を示す削減率が代表的です。高雄の栽培棚や台湾の学校給食の履歴追跡事例で得られた成果は、結局、この3数値のいずれかに換算して報告されることが多くあります。個々の数値は小さく見えても、物流倉庫の空間を少し広く使い、事故を数日早く見つけることが繰り返されれば、農場全体の収益に実質的な影響を及ぼします。

ナシにはナシ、マンゴーにはマンゴー、イチゴにはイチゴと、モデルを別々に訓練しなければならない事情は、この分野の隠れた費用です。栽培品目が10種類を超える産地なら、10個を超えるモデルをそれぞれ作り、季節ごとに新しいデータで再訓練しなければなりません。栽培品目数に応じたモデルを維持、更新する負担が大きく、大手流通会社でなければ、この費用を賄うことは容易でないとみられます。そこで近年は、複数の果物に広く通用する一つの基盤モデルを作り、果物別に最終判定段階だけを調整する方向へ、研究が移っているとみられます。

予測と等級、履歴がどれほど精巧でも、最後の決定は人が下します。モデルが無印等級を付け、または3日後の病害虫拡大を警告しても、その箱を実際に廃棄するか、防除薬剤をいつ散布するかを決めるのは、依然として現場管理者です。データパイ

プラインと等級モデル、流通履歴システムは、その決定に必要な材料を迅速かつ正確にそろえ、何をどう行うかを決める仕事は、次の段階で人が担います。技術は、判断に使う材料の質と速さを変えただけで、判断自体は今も人の仕事です。

ここまで取り上げた事例は、台湾、中国、日本、米国にまたがっています。冷蔵トラック、冷蔵倉庫、給食室という共通の問題を前に、それぞれの国が衛星データ、カメラ、ガスセンサーを少しずつ異なる割合で組み合わせ、答えを出した点が目を引きまします。使う言語と政府組織は異なりますが、温度が跳ねる瞬間を見逃さない目標と、傷んだ箱一つを数日早く見つける目標は同じです。技術が国境を越え、似た方向へ収束していると見ても無理はないでしょう。

ただし、これらのシステムは互いに円滑につながるわけではありません。台湾の生産・流通履歴制度と日本のWAGRI、米国の食品安全強化法は、それぞれ異なる項目とコード体系で履歴を記録します。一国内で育てた農産物を国境を越えて販売するときは、これら異なる帳簿へ転記する手間が、依然として多くかかります。一つのロット番号がどの国でも同じ意味で読まれる共通規格が整うまでは、国境を越える履歴追跡に、人手を介する最後の区間が当面残るとみられます。

だからといって、この全体像が完成したわけではありません。衛星の数日単位の観測、ドローンの不定期な観測、地上センサーの秒単位記録の間に残る尺度差は、時空間補間法と生成型人工知能を用いた高解像度復元研究によっても、いまだ完全には埋められていない課題です。コールドチェーンの箱内の高湿度、レンズに生じる曇り、上下するガス濃度は、光学センサーとガスセンサーの測定値を少しずつずらします。眼鏡が曇ると前が見えにくくなるように、センサーも湿気の前では、本来見ていた値を正しく捉えられません。これを抑えるには、ソフトウェアで値を自動修正する補正アルゴリズムと、湿気に強い表面素材がともに必要とみられます。

農家が集めたデータを誰が所有し、どのように値を付けて売買するか、ブロックチェーンで改ざんを防ぎながら農家の権利を守る規則をどう作るかは、技術ではなく制度が解決すべき問題とみられます。物流倉庫を映すデジタルツインへ説明可能な人工知能を加え、機械がなぜこの箱を無印等級と判定したか、その根拠を現場管理者へ言葉で説明して示すことも、今後の課題に挙げられます。判定理由がわからないまま等級表だけを受け取る農家には、根拠がわからないというもどかしさが残り得ます。等級を付ける主体が人から機械へ変わる以上、機械が何を見て判断したかを説明する仕組みも、併せて整えなければなりません。

冷蔵トラックの温度データロガーから得たデータは、衛星画像、物流倉庫のデジタルツイン、給食室の履歴照会画面と、一つのパイプラインでつながっています。この構造では、一つの区間の記録が途切れたり誤ったりすると、残りの区間の判断も

一緒に不正確になります。残る課題は、国ごとに異なる履歴コード体系を一つに統一し、温度、湿度、ガスセンサーのように湿気に弱い機器の測定誤差を減らすことです。

出典・参考文献

学術論文

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.

報告書およびオンライン資料

1. CABI Digital Library. (2026). 人工知能を基盤とする収穫後管理と保存期間予測の動向に関するレビュー. 『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). マルチチャンネルガスセンサーを基盤とするデータの保存期間推定機械学習モデルに関する資料. PubMed Central. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC12252097/>
4. 保存期間予測、履歴追跡、炭素会計を統合したモジュール型データ基盤体系に関する予備論文. (2026). arXiv. <https://arxiv.org/pdf/2511.05920>

講演・映像資料

1. 高雄農来訊. (2025). 114年高雄智慧農業年度成果發表暨研討會. YouTube. <https://www.youtube.com/watch?v=1Edc6pP4HnU>
2. 気象ビジネス推進コンソーシアムWXBC. (2025). 2025年度 農研機構メッシュ農業気象データ分析チャレンジ. YouTube. <https://www.youtube.com/watch?v=w1SrS3iwA4E>
3. TaiwanICDF國合會. (2025). 2025第三屆國際開發援助現場論壇: 全球智慧農業發展探究. YouTube. <https://www.youtube.com/watch?v=0qUeP8A4Pro>

4. 茶柱. (2026). 茶園スマート農業 カワサキ技研・落合刃物・寺田製作所. YouTube.
<https://www.youtube.com/watch?v=zmFbOC5RcJU>
5. 李載榮. (2025). A88 資策會衛星精準農業AI導入工作坊: 桃園AI衛星多光譜圖像與無人機應用. YouTube.
<https://www.youtube.com/watch?v=dtT3bafdKgw>
6. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026 Global AgriFood Innovation Roadshow: China Agricultural University Special Session. YouTube.
<https://www.youtube.com/watch?v=SS2qVda11nw>
7. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026 Global Agrifood Innovation Roadshow: Session 2. YouTube. <https://www.youtube.com/watch?v=DQrCqyNAqY>
8. 農業農村情報通信環境整備準備会. (2026). 地域でデータを共有しよう: 農業データの利活用最前線, データ駆動型農業WAGRIとIoTクラウド(SAWACHI)でのNext次世代型施設園芸システム. YouTube.
<https://www.youtube.com/watch?v=k8Qvv6CKB2A>
9. Centre for Networked Intelligence, IISc. (2025). Webinar on Track-1: Crop identification using satellite data [IndiaAI Impact Gen-AI Hackathon]. YouTube. https://www.youtube.com/watch?v=9xi5_1rrJ9o
10. Sampurna Challenge. (2026). Post-Harvest Innovation, Startups & Agri Value Chain Solutions | Webinar | Sampurna 2026. YouTube. <https://www.youtube.com/watch?v=0HTys4rPdwE>
11. AgriBusiness Forum. (2026). AI, Data, Digital Transformation of the agrifood value chain. YouTube.
<https://www.youtube.com/watch?v=OMFBQz27YyU>
12. 臉書李載榮協助進駐科學園區科技廠商團膳機器人電動三輪車物流餐車全球愛玉全球機器人口全球AI族譜規劃. (2025). A89私密資策會衛星精準農業AI導入工作坊桃園AI衛星多光譜圖像與無人機應用主辦單位:資策會協辦單位: 擎壤科技公司【悠由數據 FarmiSpace × 大賀米 × 擎壤無人機 × 資策會】聯合打造精準. YouTube.
<https://www.youtube.com/watch?v=L27xkkSrSa0>
13. Washington State Academy of Sciences (WSAS). (2026). AI for Post Harvest. YouTube.
<https://www.youtube.com/watch?v=hJlOrgNIQG4>

第5章

AIによるデジタル表現型解析と育種バイオテクノロジー

5.1

ハイスループット作物表現型解析

温室の天井レールからガントリーをつり下げた装置は、鉢の前を通るたびに複数のカメラでさまざまな角度から撮影し、それらの写真を集めて一株ずつ立体模型を自動で構築します。人が巻尺を手に温室を行き来し、一日中測っていた作業を、この装置は数千鉢を対象に一晩で終わります。写真から立体模型を再構築する計算速度も近年、大幅に向上しました。2026年に発表された3次元基盤モデルは、平均6分31秒かかっていた再構築時間を1.58秒に短縮し、3次元ガウシアン・スプラッティング方式は毎秒6.39フレームの処理速度を記録しました。

このように機械が植物の外見を測る作業を表現型解析と呼びます。種子に記された遺伝情報が、実際に育った植物で草丈、葉の大きさ、茎の太さ、病気の痕跡などとして現れたものが表現型であり、それを測定して記録する作業全体が表現型解析です。長い間、この仕事は人が担ってきました。育種家が自ら巻尺を当てて草丈を測り、目で葉色を見て罹病程度を等級化し、ときには植物を丸ごと引き抜いて重さを量りました。人による測定には、その日の状態や観察力によって誤差が入り、1品種の試験でも系統数が数千から数万に及ぶため、生育期間を通してすべてを観察することは初めから人の手に余りました。育種の現場ではこのボトルネックを以前から認識していましたが、打開するための適切な手段がありませんでした。

その手段を生み出したのが、センサー工学、ロボット、人工知能です。レーザーとカメラが植物体を代わりに測り、無人機と車輪型ロボットが圃場や温室の隅々を走って写真と映像を集め、ディープラーニングが画像の中から葉と果実を識別します。この3要素を一体化した技術をハイスループット作物フェノタイピング（High-Throughput Phenotyping）と呼び、一般にHTPと略します。人が1日に100鉢を測る速度と比べると、HTP装置は同じ時間に数千鉢を測りながら、鉢に触れず、葉も切り取りません。スマート育種を論じる際にこの技術が必ず登場するのは、優良品種を選ぶ作業の第一歩が正確な測定であり、HTPがその工程を機械に任せるからです。

温室や圃場で生育する植物群落の立体構造と光反射特性を、傷つけずに素早く撮影し、そのデータを遺伝子、環境、外見が相互に関わる枠組みの中で数値に変えることがHTPの中心原理です。同じ種子でも、水を多く与えた圃場と少なく与えた圃場

では異なる育ち方をします。外見は遺伝子だけで決まるものではなく、遺伝子と環境がともに形づくる結果です。育種家はこの関係を遺伝子型、環境、表現型の頭文字からG×E×Pと呼び、HTPはこの関係のうち測定がひととき難しかった最後の項、表現型を埋める役割を担います。表現型が欠けたままでは、どれほど優れた遺伝子地図を作っても、それが実際の圃場で正しいか確かめる方法がありません。

立体構造を撮影する方法の中で広く使われるのがレーザースキャニングです。LiDARはレーザーを照射し、その光が物体に当たって戻るまでの時間をマイクロ秒単位で測って距離を計算する装置であり、こうして得た数百万個の距離値を座標上に置くと、各点が集まって植物の外形を写し取った立体画像になります。この点の集合をポイントクラウドと呼び、その原理は砂粒ほどの点を無数に並べて顔の輪郭を作るモザイクに似ています。レーザースキャナーではPhenoSpexのPlantEye F600が代表例で、隣り合う点の間隔がわずか0.1ミリメートルという高密度のポイントクラウドを生成します。この装置には近赤外線と赤色光の反射率を同時に測るセンサーが備わり、立体形状を取得すると同時に、葉の健康状態を示す正規化植生指数（NDVI）も算出します。カラー画像と距離情報を1枚に収めるRGB-D深度センサー、2台以上のカメラで撮った画像を重ねてずれから距離を計算するステレオビジョン、多方向から撮った写真を組み合わせる多視点ステレオ（Multi-View Stereo、MVS）再構築も同じ目的に使われ、これらの方式は人の両眼が距離を捉える仕組みに似ています。

こうして得たポイントクラウドから、コンピューターは人が巻尺で測っていた値を自動で抽出します。植物の高さに当たる草丈、葉が覆う面積、葉の角度、茎の太さ、葉が重なって形成する体積まで、以前は人が一つずつ手で測っていた項目を、今では一つのポイントクラウドの解析だけでまとめて計算できます。数千鉢を毎日同じ時刻に測れば、植物が日ごとにどれだけ伸びたかを示す成長曲線も自動で描かれます。温室よりはるかに広い圃場を扱う場合は、このような地上スキャナーだけでは足りず、上空から見下ろす目がもう一つ必要になります。

その目の役割を担うのが無人航空機、UAVです。低空で圃場の上を飛ぶドローンには、画素数2,000万を超える超高解像度カラーカメラと、青、緑、赤、レッドエッジ、近赤外の5波長帯を分けて撮影するマルチスペクトルセンサーが搭載されます。これに400～1,000ナノメートルの光を細かな帯域に分けて撮影するハイパースペクトルセンサーと、表面温度を色で示す熱画像センサーが加わることもあります。ドローンに広く搭載されるMicaSenseのマルチスペクトルセンサーは、この5波長帯を撮影する代表的な装置です。収集した画像は、圃場全体が葉でどれほど覆われているかを示す植生被覆率と、NDVI、GNDVI、SAVIなどの植生指数に変換されます。病気や乾燥で傷んだ葉は近赤外線をあまり反射せず、赤色光を十分に吸収でき

ませんが、健全な緑葉ではクロロフィルが赤色光を吸収し、近赤外線を強く反射するため、2波長の反射量の差が葉の健康状態を一つの数値で示します。1機のドローンが低空を数時間飛ばば、数十ヘクタールを走査して植生指数地図を完成させ、生育が停滞した区画まで色で表示できます。

写真とポイントクラウドから葉、花、果実を分ける作業はディープラーニングが担います。畳み込みニューラルネットワーク（CNN）、Vision Transformer（ViT）、グラフニューラルネットワーク（Graph Neural Network、GNN）などのモデルがこの役割を果たし、1枚の写真で物体の境界を画素単位までたどって切り出す処理をインスタンスセグメンテーションと呼びます。トウモロコシの雌穂を一つ、その隣の雌穂を一つ、さらに隣の葉を一枚と、それぞれ別の物体として識別して表示する作業です。このように切り出した器官を数日から数週間にわたって同じ位置から繰り返し撮影すると、葉が展開する速度と果実が肥大する速度を時間に沿って追跡でき、その推移は全体の重量、バイオマス、最終収量を事前に見積もるために使われます。

中国河南省のあるトウモロコシ圃場では、このインスタンスセグメンテーションが実際の畝間を移動しています。車輪型の無人地上車両（UGV）1台がトウモロコシの列間をゆっくり進み、前部に取り付けた大型パノラマカメラで左右を走査します。真昼の日光は刻々と変化し、上の葉が下の雌穂を隠すため、人の目でも雌穂の数を数えるのが容易ではありません。ここに導入されたCornYOLOモデルは、軽量ニューラルネットワークYOLO11nをバックボーンとし、フレーム再構築モジュール（FRM）を加えて、葉に隠れて一部しか見えない雌穂まで検出します。精度指標である平均適合率（mAP）は91.5パーセントに達し、人が目視で数えるのに匹敵する水準です。ロボットが圃場を一周する間に、各株の雌穂の数と位置が自動で表に蓄積され、この表は収量に関わる形質を選ぶ基礎データになります。

トウモロコシとイネの開花時期の監視にも、同様の方法が使われます。ドローンが上空から撮影した群落画像にYOLOv5とVision Transformerを適用すると、花粉を作る雄穂（Tassel）の出現と開花状態を、未開花、開花開始、満開の3段階に分けて自動識別します。結果を集計すると、圃場全体が現在どの生育段階にあるかを示す生育指数が自動で算出され、人が数日おきに圃場を歩いて目視判断していた開花時期を、はるかに細かな間隔で確認できるようになります。育種家にとって開花時期は、どの系統同士を交配するかを決める基準であり、この基準が1日単位で正確になるだけでも交配設計の成功率は変わります。

すべての農場がCornYOLOのような専用モデルを新たに開発できるわけではないため、誰でもダウンロードして使えるオープンソースツールも並行して発展していま

す。PlantCV v2は画像中の葉色と形状を解析する手順をスクリプト化し、利用者が写真を入力するだけで葉面積、群落体積、変色割合を自動抽出するオープンソースプログラムです。kmSegはK-meansという統計手法で色を複数の群に分け、植物と背景を識別し、PhenolImageはクロロフィルが光を受けたときの蛍光画像を大量に処理します。研究費に余裕のない大学研究室でも、これらのツールによって大企業に近い水準の表現型解析が可能になりました。

温室内では、ガントリーやレールを設けた固定式装置が標準として定着しました。LemnaTec、PhenoSpex、Field Scanalyzerなどの企業の装置は、温室や屋根付き試験圃場にレールを敷き、数千の鉢や区画を決められた時刻に自動搬送してスキャナーの下を通過させます。人が定めた順序と時刻に従って機械が昼夜を問わず動くため、午前3時でも正午とまったく同じ条件で同じ鉢を再測定できます。この再現性は人の手では実現できず、同じ植物を毎日同じ角度と明るさで撮影する必要がある表現型解析に合致します。

温室の外にある屋根のない広い圃場では、条件が異なります。レールを敷けないほど面積が広いため、位置を2センチメートル以内の誤差で特定するリアルタイムキネマティック測位、RTK-GPS航法を備えたドローンと地上ロボットがその役割を代行します。ドローンは上空から広い範囲を走査し、地上ロボットは群落の下の目線から雌穂を間近に観察するという分担で、数千系統が植えられた育種試験圃場全体を数日以内に調べます。両方の装置がやり取りする位置情報は同じ座標系に置かれるため、ドローンが上から見たデータとロボットが横から見たデータを後で重ね合わせることもできます。

装置の購入予算が限られる現場に向けた低価格の代替手段も登場しています。MVS-PhenoやLITERALのような装置、Arduinoマイクロコントローラーに数台のカメラを取り付けた小型システムでも、3次元再構築ができます。価格は商用ガントリー装置の数十分の一にすぎませんが、小規模な研究室や一軒の農家が自分の圃場の一区画を走査するには十分です。高価な装置がなくても表現型解析を始められるようになりました。

ここまで扱った装置は、すべて地上の目に見える部位を測ります。根は土に埋まっているため事情がまったく異なり、MultipleX-LabやRhizoPotのような装置は、透明な管の中で植物を育て、側面から光を通して根の影を撮影する方法でこの問題に対処します。根を抜かなくても、側根が四方へ何本伸びたか、どれほど深く下りたかを時間に沿って繰り返し記録できるため、乾燥に強い根系を選ぶ育種に役立ちます。地上部の写真だけでは得られない情報を、これらの装置が地下から補います。

どれほど精密なカメラでも、撮影画像には土、砂利、雑草、影などのノイズが含まれます。この背景を除く最初の段階では、色空間を変換する計算式、ExGやCVIなどの指数を使って緑色の植物とそれ以外を分け、地形に沿って除去するトポロジカルフィルタリングも適用します。ポイントクラウドは点数が多すぎてそのままではコンピュータの負担になるため、植物固有のノイズ除去を学習したニューラルネットワークPlant-denoising-net (PDN) と、点を均等に間引く自己組織化マップ・ダウンサンプリング (SOM Down-sampling) を経て扱いやすい規模に縮小します。土の粒一つや薄い影まで取り除いて初めて、次の段階で植物だけが残ったきれいな形を扱えます。この前処理を経ていない元のポイントクラウドでは、混在するノイズが後続の計算を乱します。

ノイズを取り除いた複数の画像から一株の立体形状を再構築する作業には、多視点ステレオ再構築アルゴリズムと、境界を高感度で検出するVision TransformerであるEdge_MVS-Formerが併用されます。構築された3次元模型はTrackPlant3Dのようなインスタンスセグメンテーション・ニューラルネットワークを再び通り、茎と葉が個別に分離され、器官単位で整理されます。問題は速度でした。数十枚の写真を入力して整った立体模型を一つ完成させるまで、従来方式では数分ずつかかり、温室の数千鉢を毎日撮り直す育種現場では、その数分が積み重なって一日の全日程を圧迫しました。

この速度問題を解く手掛かりとなったのが、ニューラル放射場、NeRF (Neural Radiance Field) です。NeRFは複数の角度から撮った数枚の写真ニューラルネットワークに入力し、3次元空間の任意の地点を任意の方向から見たときの色と光強度を推定するよう学習させます。写真と写真の間の空白、つまりカメラが撮らなかった角度までニューラルネットワークがもっともらしく補い、従来よりはるかに自然な立体場面を作りました。ただし、画面上の点を一つ描くたびにニューラルネットワークへ個別に問い合わせる必要があったため、高精度だが遅いという評価が長く付きまといました。2026年に発表された3次元基盤モデルは、この評価を正面から覆しました。複数の植物種の写真をあらかじめ大量に学習し、新しい植物写真が入るとその学習結果を再利用する方式により、平均6分31秒かかっていた再構築時間を1.58秒に短縮しながら、形状精度と表現型測定値を維持しました。

速度を高めたもう一つの方式は、3次元ガウシアン・スプラッティング、3DGSです。NeRFがニューラルネットワークに毎回色を問い合わせるのに対し、3DGSは植物の表面を小さくぼやけた半透明の塊数十万個としてあらかじめモデル化し、色の付いた綿の塊を散らすように画面上へ一度に広げて画像を完成させます。各塊の位置、色、ぼかしの程度を計算すれば描画はグラフィックスカードが直接処理できるため、ニューラルネットワークとの問い合わせと応答の手順が不要です。従来方式の

Instant-NGP、Nerfactoと比較した実験で、3DGSは每秒6.39フレームを記録し、この結果を契機に3次元表現方式の軸足はニューラルネットワークから、このような明示的構造へ移りました。

複数のカメラで撮影した画像から植物の各個体を別々の物体として識別することは、現在も難しい課題です。PlantSegNeRFは、多視点画像に写った同じ器官を対応付ける手順をニューラル放射場に組み合わせ、標本数が少ない場合や未知の作物種でも、個体ごとの3次元ポイントクラウドを分離します。次にどの角度から撮れば新しい情報を最も多く得られるかをロボット自身に判断させる研究も登場し、SSL-NBVというこの方式は、正解を一つずつ与えずにロボットが学ぶ自己教師あり学習によって、人が毎回指定しなくても次のカメラ位置を自ら選びます。実際の圃場規模のポイントクラウドを物理的に正確な縮尺で完成させる5段階の処理手順も提案されており、画像を撮るデータ取得、植物と背景を分けるセマンティックセグメンテーション、少数の点を先に構築する疎再構築、点を高密度に埋める密再構築、最後に表現型形質を抽出する工程へと進みます。

次々に登場した方法を並べて比較する作業も続けました。2026年、学術誌Frontiers in Plant Scienceには、圃場条件でポイントクラウドを中心に行われた3次元作物表現型研究を比較したレビュー論文が掲載され、ほぼ同じ時期に学術誌Sensorsにも3次元再構築技術全般を整理したレビューが掲載されました。両レビューが共通して示す流れは、高価な装置1台に依存する時代から、複数の安価なカメラと高速ソフトウェアを組み合わせる時代へ重心が移っていることです。

こうして開発された方法が実用に耐えるかは、いくつかの指標で確認します。トウモロコシの雌穂や葉のような対象をどれだけ正しく検出するかは平均適合率（mAP）で測り、切り出した葉の境界が実際の境界とどれほど重なるかはIoUという重なり率で測ります。レーザーやカメラで作った立体模型が巻尺による実測寸法からどれだけずれるかは二乗平均平方根誤差（RMSE）でミリメートル単位まで示し、現場の小型コンピューターが1枚の画像を処理する時間と毎秒の処理枚数は、リアルタイム運用の可否を決める基準になります。破壊調査で直接測った重量や草丈と、画像だけから推定した値の一致度は決定係数で表し、複数の研究でこの係数が0.75を超えたことで、画像測定が破壊調査に代わり得るという根拠が蓄積されています。開花段階や病害等級のように数値ではなく等級で分類する形質は、 $F1 \propto \frac{1}{1 + \frac{1}{F1} + \frac{1}{F2}}$ と混同行列で別に検証します。

カメラとロボットが毎日生成する写真、ポイントクラウド、数値は種類も規模も異なるため、研究者間で共有するには整理された取り決めが必要です。その基本的な枠組みがFAIR原則です。見つけられること（Findable）、アクセスできること（

Accessible)、異なるプログラム間で相互運用できること (Interoperable)、後で再利用できること (Reusable) という4条件を指します。センサーが撮影した元画像、処理後の3次元ポイントクラウド、撮影時刻と場所、最終的に抽出した表現型値まで、すべてのデータにいつ、どこで、何を記録したかを示すメタデータを付け、中央データベースに整理することがFAIR原則を実践する方法です。

この原則を具体的なシステムに移した例がPHIS (Phenotyping Hybrid Information System) です。PHISはPlant Ontology (PO) という標準用語体系を取り入れ、温室や圃場で生じるすべての実験対象、センサー、事象に固有の識別名を付けます。一つの鉢が温室の一方から他方へ移されたこと、葉に斑点が現れたこと、温度センサーの測定値まで、すべてを固有の永続識別子であるURIで結び付けるため、数年前の実験データと今月の実験データを同じ基準で比較できます。この識別子体系が、FAIR原則の求める相互運用性と再利用性を実験データの水準で実現します。

PHISと連携するOpenSILEXは、各所に分散した表現型データと、それを扱うウェブサービスを一つの標準経路で結ぶソフトウェア構造です。国際的な研究界は、表現型実験を記録するときに最低限残すべき情報も別に定めており、MIAPPE (Minimum Information About a Plant Phenotyping Experiment) という規格は、実験場所と日付、栽培条件、測定方法を漏れなく記すことを求め、PHISやOpenSILEXなどのシステムはこの規格を基盤構造に取り入れています。圃場試験の環境、農作業履歴、気象データを扱うICASA Version 2.0標準も、同じ目的で使われます。国や大学が異なる研究室で別々の名称が使われてきた対象を、これらの規格が共通の言葉に置き換えます。

このように整理された表現型データは、ゲノムデータと結び付いて初めて価値が高まります。CropGS-HubやPHENOPSIS DBなどのデータベースは、ゲノム情報とハイスループット表現型データを一か所に集め、ゲノミック選抜 (Genomic Selection) モデルが別々に探さず直接連結して使えるようにします。表現型データベースが標準規格に従っていなければ、外見を測る技術と遺伝子を読む技術が異なる形式と規格を使うため、ゲノムデータとの接続自体が成立しなかったはずです。

PhenoSpexのPlantEyeが実際に使われる温室では、1台のスキャナーが毎日同じ鉢の前を通り、群落高、葉面積、葉の傾斜角を日ごとに蓄積します。これらの値はコンピューター内の仮想温室であるデジタルツイン (Digital Twin) にそのまま複製され、実際の温室と並行して成長する第2の温室を画面内に作ります。栽培担当者は、画面上の仮想植物が必要とする水と養分の量を逆算し、実際の温室で給液バル

ブを開閉する時刻と量を決めます。植物が喉の渇きを訴える代わりに、葉の傾きと群落体積の変化がその状態を伝えます。

ダイズと冬小麦を植えた育種試験圃場では、1機のドローンにマルチスペクトルセンサーとLiDARを載せて飛ばします。群落高の情報と葉色の情報を重み付けして計算すると、圃場に蓄積した地上部バイオマスと、その中に含まれる窒素量を相当な精度で推定できます。収穫期には画像内で重なったダイズの莢もクラスタリング手法で自動計数し、この結果によって、収量が高いと見込まれる系統を圃場から掘り起こして重さを量る前に、1枚のドローン画像から選び出せます。

花卉と果樹を扱う大規模研究機関では、OpenSILEXとPHISを併用してデータ全体を管理します。1日に数万枚ずつ蓄積するカラー写真と3次元画像、センサーがリアルタイムで送る値、品種ごとの遺伝子型情報が一つのシステムに集まり、Plant Ontology標準に基づくラベルによって、研究チームごとに同じ鉢を別の名前と呼ぶ混乱がなくなります。データを探して共有する手間が減った分、研究者はAI育種モデルをデータに接続する次の段階へすぐ移れます。標準化そのものは目を引く成果を生みませんが、その成果が出るまでの時間を明確に短縮します。

こうした成果がある一方、未解決の問題もいくつか残っています。作物が育って群落が繁茂すると、上の葉が下の花、果実、病気の痕跡まで隠すため、カメラやレーザースキャナーを上にも1台だけ置く方法では、下部の形質がまったく見えない場合が頻繁に生じます。地上ロボットとドローンが異なる角度から撮影した画像を組み合わせ、隠れて記録されなかった葉を周囲の情報で補うポイントクラウド再構築計算を改良することが、現在の有力な解決策です。画像から完全に消えた葉1枚の形を完全に復元することは今も困難ですが、推定値だけでも情報がない状態より大幅に有用だと現場では判断されています。

データ量の大きさも障害です。0.1ミリメートル解像度のポイントクラウドや数百波長を収めたハイパースペクトル画像は、1枚ごとにギガバイト単位まで膨らみ、圃場脇の小型コンピューターがリアルタイムで処理するには過大です。点を間引くダウンサンプリング、大規模ニューラルネットワークの知識を小規模ネットワークへ移す知識蒸留（Knowledge Distillation）、AI演算専用チップ（NPU）を装置内に直接組み込むハードウェアアクセラレーションなど、データ量を減らす方法と計算を高速化する方法が並行して研究されています。軽量の装置ほど圃場の中央ですぐ答えを出せるため、計算負荷を減らす競争は今後もしばらく続くとみられます。

屋外の天候も人工知能をしばしば混乱させます。強い直射日光の下では葉の表面が白く反射して色情報が失われ、風で葉が揺れると同じ葉が写真ごとに異なる形で写り、雲が通過して明るさが刻々と変わると、直前の画像で学習したモデルが次の画

像では判断を誤ることがあります。温室のように光と風を制御した場所で学習したモデルをそのまま露地へ移すと、精度が急落することが多く、この現象を DomainShift と呼びます。多様な天候と光条件を人工的に混ぜて学習データを増やす方法や、新しい環境に合わせてモデルを調整する Domain Adaptation が、この問題に対処する主な手法です。研究室の外で精度を検証していないモデルは、結局、温室内でしか通用しない不完全な成果にとどまる危険があります。

ここまで扱った技術のほぼすべてが地上の葉と果実を対象としているため、地下の根まで一つのパイプラインで追跡する統合表現型解析が次の課題です。これに加え、人工知能がどの画像を見て、なぜその植物を病気、または高収量と判定したかを人が理解できる形で示す説明可能AI（Explainable AI、XAI）も求められます。Grad-CAMやSHAPなどの手法は、ニューラルネットワークが判定時に画像のどの領域を注視したかを色分けしたヒートマップで示し、こうした視覚的根拠がそろって初めて、育種家は機械の判定を信頼して次の交配計画を立てられます。ガントリーが通過した後に残るのは数枚の写真ではなく、数百万個の座標値と、そこから抽出した形質値です。これらの数値が標準規格に従って整理されれば、複数の温室を越えて他国の研究機関のデータとも接続できます。そうすれば育種家は、特定の遺伝子を持つ種子が特定の圃場でどう育つかを数値で確認できます。

出典・参考文献

学術論文

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). 3次元基盤モデルに基づく超高速作物再構築と表現型精度の維持に関する研究.
<https://arxiv.org/abs/2607.01753>
10. arXiv. (2025). PlantSegNeRF：多視点画像のインスタンス対応に基づくチャネル結合ニューラル放射場による植物3次元インスタンスポイントクラウド再構築. <https://arxiv.org/pdf/2507.00371>
11. arXiv. (2024). SSL-NBV：自己教師あり学習に基づく次善視点選択によるロボット植物3次元再構築研究.
<https://arxiv.org/pdf/2410.14790>
12. Frontiers in Plant Science. (2026). 圃場条件におけるポイントクラウドベースの3次元作物表現型解析の比較レビュー. <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2026.1731852/full>
13. Sensors. (2026). 作物表現型解析のための3次元再構築技術の総合レビュー.
<https://doi.org/10.3390/s26092730>

講演・映像資料

1. IPPN - International Plant Phenotyping Network. (2025). Dr. Michael Selveraj: AI-Powered Phenomics: Transforming Crop Science for Climate-Resilient Future. YouTube.
<https://www.youtube.com/watch?v=eoTvCz3YTzo>
2. Greg Bronevetsky. (2025). Predictive Pattern Recognition of Plant Growth Traits in Simulated and Controlled Environments. YouTube. <https://www.youtube.com/watch?v=uKepfZAnKbk>
3. Bioingene. (2026). International Webinar- Biotechnological strategies to improve plant traits for enhanced productivity. YouTube. <https://www.youtube.com/watch?v=duUd8ajVo44>
4. Solvi. (2026). Webinar: Validating AI-Based Plant Counts with Real Field Data. YouTube.
<https://www.youtube.com/watch?v=B0KuJdRtmaQ>

5.2

予測育種とスマート生物育種技術

作物育種は、栽培者が圃場に出て目に見える姿だけから優れた個体を選ぶ表現型選抜から始まりました。その後、メンデルの遺伝法則と統計を取り入れて親と子の成績を計算する方法が加わり、遺伝子の特定位置を標識として望ましい形質を事前に見分けるマーカー選抜（Marker-Assisted Selection、MAS）が定着しました。ゲノム全体に分散する数万個の標識を一度に読み取るゲノミック選抜（Genomic Selection、GS）が続き、選抜精度は高まり、1世代を育てて次世代へ移る時間は短くなりました。この方法は、まだ土にまいていない種子が成長したときの収量を事前に計算した値を育種家に示し、この値をゲノム推定育種価（Genomic Estimated Breeding Value、GEBV）と呼びます。種子一粒ごとが持つ遺伝情報だけから算出した予測値です。

問題は、収量のように多数の遺伝子が関与する形質でした。草丈や病害抵抗性のようにつか二つの遺伝子が決める形質と異なり、収量には効果の小さい数百、数千個の遺伝子が相互に関わり、その関係は同じ種子でも植える圃場によって異なって現れます。同じ品種が干ばつの圃場では不振でも、水が十分な圃場では良い成績を示すことがあります。遺伝子と環境が相互に影響するこの関係を遺伝子型・環境交互作用（Genotype by Environment Interaction、 $G \times E$ ）と呼びますが、ゲノミック選抜だけでこの相互作用を精密に解明するには明確な限界がありました。ゲノムと表現型に栽培環境の情報まで加え、一度に計算するスマート生物育種が登場した背景はここにあります。

スマート生物育種は、ゲノミクス（Genomics）、フェノミクス（Phenomics）、エンバイロミクス（Enviromics）という3種類のデータを、一つのAIモデルへまとめて入力する手法です。ゲノミクスは種子が受け継いだ遺伝情報、フェノミクスはその種子が成長しながら実際に示す草丈、葉色、収量、エンバイロミクスはその作物が育った圃場の気温、降水量、土壌特性を指します。3種類のデータを個別に見れば散在する情報にすぎませんが、人工ニューラルネットワークの複数層を通し、一つの潜在空間（Latent Space、異なる種類のデータを同じ座標上に置いて比較できるよう圧縮した空間）へ集めると、相互の関連が明らかになります。種子を実際にまく前に、ある遺伝子型がある圃場でどのような成績を示すかをコンピューター

内で先に描くのです。育種家が画面上の順位表だけを見て20系統を選べるのは、この計算が背後ですでに終わっているためです。

気候変動で干ばつと猛暑が頻発するなか、特定の環境でも安定する品種を事前に選び出すことが育種を中心課題になりました。この目的で開発された統合ゲノム・エンバイローム予測（Integrated Genomic-Enviromic Prediction、iGEP）システムは、過去の気象データ、将来の気象予測、土壌特性、位置情報を、ゲノムの一塩基多型（Single Nucleotide Polymorphism、SNP、個体ごとに遺伝子配列の1文字だけが異なる変異）地図とともに多層ニューラルネットワークへ入力します。対象とする栽培地域と気候帯を対象環境集団（Target Population of Environments、TPE）としてまとめ、その中で干ばつや高温のような極端な条件が生じたとき、特定の遺伝子型がどれほど耐え、どれほど収穫できるかを事前に推定します。実際の圃場に植えて数か月待たなくても、どの品種が翌夏の猛暑に耐えるかをある程度見通せるようになりました。

これに作物の生理作用全体を再現する生育モデルを加えたシステムもあります。APSIMやDSSATなどの作物生育モデルは、日光、温度、水が葉や果実に変わる過程を物理・化学の方程式で表すプログラムであり、この生育モデルとゲノム予測モデルを接続したゲノム・作物モデル（CGM-G2P）は、特定の遺伝子が実際にどのような生理過程を経て収量につながるかをシミュレーションします。数値間の相関だけを示した従来の統計モデルと違い、遺伝子が植物体内で実際に何をするかを明らかにしながら予測するため、予測値を受け取った育種家はその根拠を段階ごとにたどれます。

これらすべての計算にはデータが必要です。予測育種を支えるデータの最下層にあるのはゲノムそのものです。次世代シーケンシング（NGS）と、より長い領域を一度に読み取る第3世代シーケンシング技術で全ゲノムを再解析し、一塩基多型、挿入・欠失（InDel）、大きな構造全体が変わる構造変異（Structural Variant、SV）を見つけます。一品種のゲノム地図だけでは不十分だという判断から、複数系統のゲノムを重ねたパンゲノム（Pangenome）地図も作成して使います。さらに、遺伝子が実際にどれほど発現するかを示すトランスクリプトーム（Transcriptomics）、タンパク質量を示すプロテオーム（Proteomics）、代謝産物を示すメタボローム（Metabolomics）、遺伝子配列自体は変わらず発現だけが変わるエピジェネティクス（Epigenetics）のデータが、時間に沿って層状に蓄積されます。

圃場から得られるエンバイロームデータも高密度です。圃場に設置したIoTセンサー、全国規模の格子状農業気象データ、米国航空宇宙局のNASA POWER衛星データ、土壌特性を記録した土壌調査データベースを統合し、日々の最低・最高気温、積算

温度、空気の乾燥度を表す飽差（Vapor Pressure Deficit、VPD）、土壌水分、窒素・リン・カリウム濃度を時系列で蓄積します。異なる機関や国の研究者がこれらのデータを共同利用するには、まず形式をそろえる必要があります。このため、見つけられること（Findable）、アクセスできること（Accessible）、ほかのプログラムと相互運用できること（Interoperable）、再利用できること（Reusable）という4原則、FAIR原則がデータ管理の基準になりました。育種データ交換の共通仕様であるBrAPI（Plant Breeding API）と、作物栽培データ標準のICASAが採用され、異なる研究機関が蓄積したデータを標準形式で交換できるようになりました。

収集されたデータはBreedbase、OpenSILEX、CropGS-Hubなどの統合プラットフォームに載せられ、ゲノム、表現型、環境を一つの画面で検索できる知識基盤として整理されます。論文や古い育種ノートに散在する知識も埋もれたままにはされません。PlantConnectomeのような文章解析AIは数万本の論文を調べ、どの遺伝子がどの形質と関連すると記されたかを自動で見つけ、その関係を点と線で表す知識グラフ（Knowledge Graph）に整理します。数十年前に引退した育種家がノートに手書きした一つの観察記録まで、今では1回の検索で呼び出せます。

データが蓄積しても、その中から有用なパターンを選び出すことは別の課題です。初期のゲノム予測計算は、GBLUP（Genomic Best Linear Unbiased Prediction）やRKHS（Reproducing Kernel Hilbert Space）などの統計モデルが担いました。どちらのモデルも数万個のマーカーそれぞれが形質にどれほど寄与するかを方程式で求め、その寄与度を合計して個体の予想成績を出します。そこへ、複数の質問を枝分かれさせて答えを絞るランダムフォレスト（Random Forest）、誤差を少しずつ減らして予測を改善するExtreme Gradient Boosting（XGBoost）、Support Vector Machine（SVM）、LASSO回帰などの機械学習手法が加わり、予測の幅が広がりました。数万個のマーカーから本当に重要な数百個を選び、残りをノイズとして除く作業で、これらの統計・機械学習モデルは今も有用です。

統計モデルの次に登場したのがディープニューラルネットワークです。ダイズ育種に使われるSoyDNGPは、ゲノム情報を立体画像のように配列して3次元畳み込みニューラルネットワーク（3D CNN）へ通し、収量、収穫時期、油分、タンパク質含量を予測します。複数種類のオミクスデータを一度に入力するDNGP、イネ、トウモロコシ、ワタ、キビの4作物にまたがる53の農業形質で性能を試験したCropARNet、畳み込みニューラルネットワークと自己注意機構（Self-Attention、入力値のどこに大きな重みを置くかを自ら決める計算方式）を組み合わせたCropformer、遺伝子型と表現型の複雑な非線形関係を扱うDPCformerが相次いで発表され、予測性能は段階的に向上しました。これらのモデルは、遺伝子同士が互

いの働きを抑えたり強めたりするエピスタシス (Epistasis) 効果を捉えます。これは二つか三つの遺伝子効果を足すだけでは得られない値です。

AutoGPや複数形質を一度に計算するMtCroなどのモデルは、トウモロコシ、イネ、コムギのように長期間データが蓄積した作物へ適用され、収量、病害抵抗性、穀粒品質を1回の計算で同時に出します。層が深くなるほど、モデルは学習データの細かな特徴まで記憶する過学習 (Overfitting、試験データには強いが実際の現場では外れる現象) に陥りやすくなります。これを防ぐため、ニューラルネットワークのノードを無作為に無効化するDropoutと、計算値が過度に大きくならないよう抑えるL2正則化などの手法が併用されます。新しいモデルほど、精度だけでなく、未知の圃場でも性能がどれほど安定するかを併せて報告する傾向が強まっています。

ゲノムを読む人工知能はさらに進み、人間の言語を学ぶように、遺伝子の塩基配列自体を言語として扱い始めました。AgroNT (Agro-Nucleotide Transformer) とFloraBERTは、遺伝子の前後に位置して発現を調節する非コード領域、すなわちプロモーターとエンハンサーの塩基配列を、正解ラベルなしで学ぶ自己教師あり学習 (Self-Supervised Learning) によって事前学習します。学習済みモデルは、見たことのない植物種の塩基配列を受け取っても、すぐに遺伝子発現量と調節領域の活性度を特定します。さらに進んだPlantCaduceusは、系統的に離れた16種の被子植物のゲノムを同時に学習し、特定の遺伝子配列が長い進化の過程でなぜ保存されたかを、教師あり学習モデルより正確に明らかにしました。

予測を越え、ゲノムを直接編集する作業にも人工知能が導入されました。開発者が植物用として世界初と紹介したOpenCRISPR-1は、CRISPR-Cas遺伝子編集システムの3次元立体構造と塩基配列に関する膨大な既存データを学習し、これまで存在しなかった新しい切断酵素とガイドRNA (gRNA、はさみを目的位置へ運ぶ短い遺伝配列) を自ら設計します。自然界の切断酵素をそのまま使う場合より、意図しない位置を切るオフターゲット (Off-target) の副作用を減らせることが、この手法の価値です。目的位置だけを正確に切る必要がある遺伝子編集では、この精度が成否を分けます。

これらすべての予測能力と設計能力を一つに統合する巨大な育種基盤モデル (Breeding Foundation Model) も開発中です。人間の言語を学ぶ大規模言語モデルと同じく、育種基盤モデルもモデル規模、学習データ量、計算量を同時に増やすほど性能が予測可能な形で向上するスケーリング則 (Scaling Law) に従います。規模が一定の閾値を超えると、それ以前にはできなかった仕事を突然こなす創発能力 (Emergent Abilities) が現れます。その閾値を超える時点は事前に分かりません。複数の遺伝子を同時編集したとき、その組み合わせが作物全体へ及ぼす影響を段階

ごとに検討して推論する思考連鎖（Chain-of-Thought）能力が一例です。ただし、大規模なモデルほど、もっともらしい誤答を確信をもって出すハルシネーション（Hallucination）を避けられないため、回答前に公認の育種データベースを検索させる検索拡張生成（Retrieval-Augmented Generation、RAG）が併用されます。モデル全体を最初から再学習せず、いくつかの計算経路だけを調整する低ランク適応（Low-Rank Adaptation、LoRA）によって、高価なサーバーがなくても特定の作物と地域に合わせた版を作れるようになりました。

このように学習したモデルが実際に予測値を出す過程は、大きく2段階に分かれます。まずオフライン段階では、ゲノム、表現型、環境を統合した膨大なデータを数百、数千基のGPUで構成するサーバークラスターへ分散配置し、3次元並列化とZeRO（メモリーの無駄を減らし、限られた装置でも大規模モデルを学習できるようにする最適化手法）を使って数週間にわたりモデルを学習します。学習が終わるとモデルはオンライン段階へ移り、実際の育種現場で候補となった母系統と父系統のゲノム地図、対象栽培地の気象シナリオを入力として受け取ります。すると、数万通りの交配組み合わせの成績をコンピューター内で事前に試す仮想交配審査（In-silico Cross Screening）が、わずか数秒で終わります。画面上に並ぶ順位表は、この数秒の計算を一晚に何度も繰り返した結果です。実際の圃場に植えて一世代を育てなければ分からなかった答えを、種子を土に埋める前にコンピューター内で得られます。

得られた予測が実際に信頼できるかは、いくつかの数値で確認します。実際の成績とモデルの予測値がどれほど連動するかを示す予測精度は、0.70から0.85を目標とします。実測成績のばらつきのうちモデルが説明する割合を示す決定係数は、0.75から0.90を基準にします。収量、出穂日、茎長のように数値で表す形質は、予測値と実測値の差の平均である平均絶対誤差（MAE）と、その差を二乗して平均した値の平方根である二乗平均平方根誤差（RMSE）で再確認します。罹病葉をどれだけ正確に選び出すかは、適合率（病気と予測した葉のうち実際に病気だった割合）、再現率（実際の罹病葉のうちモデルが検出した割合）、両者を組み合わせたF1スコアで測り、遺伝子編集用のはさみが目的位置をどれほど正確に切ったかは、オンターゲット効率（意図した位置を切った割合）とオフターゲット率（意図しない位置を切った割合）で別々に測ります。

育種家がより注目する指標は別にあります。その精度によって実際に品種がどれほど速く改良されるかという指標です。遺伝的改良速度と呼ぶこの値は、選抜時の厳しさ、予測精度、その形質に残る遺伝的差異をすべて掛け、その値を1世代から次世代へ移る時間で割って求めます。世代間隔が短く、予測が正確であるほど、同じ期間内の品種改良幅が大きくなることを意味します。形質のばらつき全体のうち遺

伝的要因が占める割合を示す遺伝率も調べ、遺伝率が高いほど環境より遺伝子はその形質を大きく決めるため、選抜効果も高まります。複数の大規模モデルを同じ条件で競わせるSeedBenchなどの共通ベンチマークも作られ、どのモデルが遺伝子検索、表現型解読、交配設計に優れるかを標準化された指標で比較できるようになりました。

この計算が実際の圃場を変えた事例は、国際農業研究協議グループ（CGIAR）傘下の国際トウモロコシ・コムギ改良センター（CIMMYT）で確認されています。東アフリカとラテンアメリカ各地のトウモロコシ・コムギ育種計画へ、全ゲノムマーカーデータ、無人機で測ったマルチスペクトル指数、気象ストレス記録を統合した予測育種システムを適用した結果、厳しい干ばつと高温の条件で収量と乾燥耐性を予測する精度が、従来の統計モデルより約15パーセントから25パーセント向上しました。屋外試験圃場の区画数は減り、交配から次世代を得るまでの時間はおよそ半分に短縮しました。干ばつが深刻化するアフリカで次の栽培期を迎える前に、どの系統が耐えられるかを植える前から選別できるようになりました。

ダイズ育種の現場では、SoyDNGPがすでに公開ウェブサービスとして稼働しています。育種家が系統のゲノムデータをアップロードすると、3次元畳み込みニューラルネットワークが収量、収穫時期、油分、タンパク質含量を計算し、有望な親の組み合わせを自動で選びます。トウモロコシ、イネ、コムギを扱うCropGS-HubとAutoGPプラットフォームも、同様に遺伝子型と表現型のデータをウェブデータベースへ統合し、誰でもアクセスして仮想交配シミュレーションを実行できるよう公開しています。一つの研究室が数年かけて蓄積したデータを、地球の反対側にある別の研究機関が直ちに引き継いで使える構造です。

SyngentaとInstaDeepは共同開発したAgroNTを多様な植物種の調節配列へ適用し、種子を一粒もまかずに、どの遺伝子が環境変化へどれほど敏感に反応するかを事前に順位付けしました。数千か所に及ぶ潜在的な調節領域の重みを一度に計算し、気候レジリエンスの高い品種を設計するために必要な分子水準の根拠データを作成しました。種苗会社とAI企業の提携が増えている事実は、この技術が研究室を出て商業育種の道具として使われ始めたことを示します。論文だけにとどまらず実際の育種パイプラインに組み込まれた点で、この協業の意味は大きくなります。

OpenCRISPR-1が設計した遺伝子編集ツールは、作物の乾燥抵抗性と病害抵抗性を担う遺伝子の精密編集に成功しました。自然界に存在する切断酵素をそのまま使った場合より、意図しない位置を編集する副作用が減ったという結果も得られました。一粒の種子のゲノムから、目的とする行と文字だけを選んで直す作業は、可能性の段階を越え、実証済みの成果になりました。研究室外の圃場でもこの成果が数世代

にわたって維持されるかは、今後さらに数回の栽培期を経て確認する必要があります。

日本の高知県では、SAWACHIというクラウドプラットフォームが1,600棟を超える温室の環境データと3,000戸の農家の生産記録を国の農業ビッグデータ基盤WAGRIへ接続し、生育と収量を予測するAIモデルを運用して、育種候補系統が実際の現場にどれほど適合するかを評価しています。同じ日本の愛知県では、カーネーションの品種改良に別の種類の人工知能が使われています。環境条件や繁殖過程によってカーネーションの遺伝子発現が変化し、花弁色が変わるエピジェネティックな現象を解明し、その知識を望ましい色の新品種を精密に選ぶために応用しています。数千棟の温室データを集める作業と、一つの花弁色の遺伝機構を掘り下げる研究は、規模こそ異なりますが、同じ予測育種の枠組みで並行して進んでいます。

成果が明確である一方、未解決の問題も明確です。温室やコンピューター内の仮想環境で学習したモデルは、経験したことのない異常気象や、複数のストレスが同時に生じる複合環境に直面すると、予測力が急落する場合があります。仮想空間と実際の圃場の間に生じるこの隔たりをSim-to-Real Gapと呼び、学習時になかった条件で判断が不安定になるDomain Shiftが原因です。これを縮めるには、より多様な環境から得たデータを継続して追加し、現場から入るデータによってモデルが自ら更新するオンライン適応学習システムを整える必要があります。

モデルが回答の理由を説明できないことも重大な問題です。ディープニューラルネットワークは高い精度を出しても、特定の交配組み合わせを推奨した理由を、育種家が理解できる生物学的根拠として説明できません。判断を出しながら、そこに至った経路を隠す箱に似ていることから、このようなモデルをブラックボックス（Black-box）と呼びます。この箱を開く試みとして、SHAPやGrad-CAMなどの説明手法と、知識グラフを接続して予測結果へ生物学的因果関係を付けて示す研究が続いています。根拠を目で確認できない限り、精度がどれほど高くても、経験豊富な育種家の全面的な信頼を得ることは難しいとみられます。

計算費用も障壁になります。数十億個のパラメーターを持つ育種基盤モデルを学習して動かすには高価なGPUサーバーが必要であり、その装置を備えにくい小規模研究所や零細な育種企業にとっては、この技術を導入すること自体が容易ではありません。モデルの計算値を少数の整数に減らして軽量化する量子化と、大規模モデルが学んだ知識を小規模モデルへ移す知識蒸留（Knowledge Distillation）などが、この参入障壁を下げる方向で研究されています。クラウドでサーバーを借りる方法もありますが、育種データを外部サーバーへ預けること自体に消極的な企業も少な

くありません。サーバー1台の費用を負担できるかどうか、最新の育種技術へ到達できるかを分ける新たな境界になりつつあります。

最後まで残る障壁は人材です。高度なAIアルゴリズムを扱いながら、分子遺伝学と現場農学にも精通する学際的人材は現在も少なく、研究室の成果が実際の圃場での品種改良につながる速度を遅らせています。AIが設計した遺伝子編集作物をどのように審査して承認するか、そのデータとモデルの所有権を誰に認めるかを定める法制度も、技術の進展に追いついていません。種子を予測して設計する能力がどれほど高くても、その種子を審査し責任を負う人と規則が整わなければ、圃場まで進む道は閉ざされたままです。

出典・参考文献

学術論文


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 : 自己注意機構と深層残差ネットワークに基づくゲノミック選抜モデル. (n.d.). ScienceDirect. <https://www.sciencedirect.com/science/article/pii/S2772899425000242>
9. Cropformer : 畳み込みニューラルネットワークと自己注意機構を組み合わせた作物表現型予測モデル. (n.d.). ScienceDirect. <https://www.sciencedirect.com/science/article/pii/S2590346224006448>
10. DPCformer : 畳み込みニューラルネットワークと自己注意に基づく遺伝子型・表現型の非線形関係予測モデル. (n.d.). arXiv. <https://arxiv.org/html/2510.08662v1>
11. PlantCaduceus : 16種の被子植物ゲノムによる事前学習に基づく多植物DNA言語モデル. (n.d.). Computomics. <https://www.computomics.com/news-reader/foundation-models-in-plant-breeding-an-introduction-copy.html>
12. AI breeder : 作物育種のためのゲノム予測AI研究. (n.d.). ScienceDirect. <https://www.sciencedirect.com/science/article/pii/S2949952623000109>

講演・映像資料

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>

この本を支援してください

本書が役に立ったと感じられたら、今後の翻訳や公開版の制作、
開かれたAI知識プロジェクトをPayPalでご支援ください。



PayPal

<https://paypal.me/kimkjkj>

QRコードを読み取るか、上のリンクを開いてください。