

園藝農業

人工智慧



金京鎮律師

本書由人工智慧整理製作。

彙集並整理了以世界主要語言公開的資料。

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

上方連結是本書製作時參考資料的公開 NotebookLM 收藏。

任何人都可以自由開啟與使用。

目錄

第1章	基於電腦視覺與深度學習的作物病蟲害診斷	3
1.1	作物病蟲害與雜草的精準偵測與診斷	5
1.2	果實成熟度判別與生長、產量預測	13
第2章	園藝農業機器人與自主作業自動化	22
2.1	果蔬與菇類採收機器人及末端執行器	24
2.2	自主移動機器人與無人機群的路徑最佳化和精準防治	32
第3章	智慧溫室與設施園藝環境控制（CEA）	41
3.1	基於物聯網的多感測器監測與智慧環境量測	43
3.2	數位孿生與 AI 智慧環境、生長最佳化	52
第4章	資料驅動的精準農業與決策支援	60
4.1	智慧灌溉與肥料供應最佳化	62
4.2	時空資料融合與流通及品質管理	70
第5章	基於 AI 的數位表型分析與育種生物工程	79
5.1	高通量作物表型分析	81
5.2	預測育種與智慧生物育種技術	89

第1章

基於電腦視覺與深度學習的作物病蟲害診斷

1.1

作物病蟲害與雜草的精準偵測與診斷

美國 Carbon Robotics 製造的雷射除草機 LaserWeeder，每小時可用雷射燒除超過 10 萬株雜草。自 2022 年上市以來，這款機器人清除的雜草累計超過 100 億株，2026 年第 1 季營收突破 1 億美元，目前已有 15 個國家、約 100 家農場使用。同一時期，韓國農村振興廳開發的人工智慧診斷應用程式，已能辨識 31 種作物及 182 種病蟲害。人們逐葉翻看、確認病斑，再用手拔除雜草的工作，正逐漸交由攝影機與演算法接手。

園藝作物的產量與品質，是同時支撐國家糧食安全和農家所得的兩根樑柱。然而隨著氣候變化，病原體出現新的變異並蔓延到陌生地區，雜草也與作物爭奪相同的陽光、水分與養分。長久以來，這場戰鬥的最前線一直是人的眼睛。這種方式英文稱為目視巡查 Visual Scouting。由經驗豐富的農學家或栽培者巡視田區、查看葉片的肉眼監測，至今仍廣泛使用，但一個人一天能查看的畦數有限，面對同一處病斑，不同的人也可能作出不同判斷。田區越大，這套方法的缺口就越大，病害便從缺口中悄然擴散。

當雜草開始在作物旁生長，每天都會在看不見的根部下方發生競爭。在雨水滲入、肥料成分溶解的短暫時間裡，雜草根系比作物根系更早吸收水分與養分的情況一再重演。這種差異要過幾週才會從葉片大小看得出來，但在此期間，作物尚未充分生長就迎來了收穫季節。無論是病害還是雜草，等到症狀清楚可見時，往往已經太遲而難以補救。

為了應對這類問題而形成的大方向，稱為精準農業。它從整片田地採取相同處方的方式，轉向依照小區域甚至每一株作物的情況，只在必要之處投入所需的處理。精準找出病蟲害與雜草，是這股潮流的第一步。若連哪裡有什麼都不知道，就不可能只針對該位置採取精準處方。

為填補這個缺口，結合電腦視覺與深度學習的精準診斷技術應運而生。在一張攝影機拍攝的照片中，辨別患病部位與健康部位、作物與雜草的工作，不再由人處理，而是交給演算法。其根基是卷積神經網路，英文縮寫為 CNN，Convolutional Neural Network。這種架構會逐一掃描影像小區塊的顏色、紋理與病斑邊緣曲線，再將結果逐層堆疊，彙整成一項判斷。若採用遷移學習，把 ResNet、EfficientNet、DenseNet、MobileNet 等已用其他大型影像資料預先訓練的模型帶入，再針對農作物照片重新訓練，即使用農場所能蒐集的幾千張照片，也能建立準確度頗高的分類器。原理就像已學過一種語言的人，能更快學會另一種新語言。

在快速移動的田間，速度和判斷準確度一樣重要。YOLO，You Only Look Once，系列模型只掃描整張照片一次，就用矩形框標示病斑、害蟲或雜草的位置，並同時貼上名稱標籤。正如名稱所示，它只看一次便完成判斷，因此即使是攝影機即時拍攝的影像也能跟上。在葉片重疊、陰影覆蓋，背景又混雜泥土與枯草的凌亂冠層中，從YOLOv5、YOLOv8、YOLOv9e、YOLOv10到YOLOv11的最新系列，仍能找出個別病斑、每一隻昆蟲與每一株雜草的位置。

CNN與YOLO有共同弱點。由於它們把照片切成小區塊來看，容易忽略區塊之間的關係、橫跨整片葉子的寬廣紋理，或整株作物的形態變化。視覺Transformer，英文縮寫ViT，Vision Transformer，及其近親Swin Transformer，會先將照片切成 16×16 像素的區塊，再整體計算這些區塊彼此的關係。憑藉稱為自我注意力機制Self-Attention的計算方式，模型能以寬廣視野判斷照片一角的病斑與另一角的病斑是否源於同一病害。把CBAM或CAB等注意力模組與CNN並列的混合架構，便能同時擁有閱讀細微病斑紋理的眼睛，以及觀看整片葉子的眼睛。就像一個人同時擁有近距離觸摸紋理的指尖，以及從遠處觀看全貌的雙眼。

這些模型實際上能判斷得多準確，可以從數字看出來。辨識葡萄葉病害的EfficientNet-B0與B3系列，在驗證資料中取得99.5%準確率與1.00的AUC-ROC。結合模仿矮袋鼠群體移動之最佳化技術DSOCA-QSO的模型，在蔬菜葉片病害分類中達到99.9%準確率與99.35%的F1分數。能依情境挑選特徵的TL-DCFP-CNN，即使同時處理棉花、玉米、水稻、小麥與甘蔗5種作物，仍維持98.09%準確率。在即時偵測方面，YOLOv11偵測番茄葉片病害時，準確率約為94%。縮小體積的YOLO-NAS在熱帶地區田區偵測雜草時，維持96%準確率，且只需25毫秒就能處理一張照片。這還不到人眨一次眼所需時間的十分之一。YOLO-NAS的測試田區位於熱帶，光線與濕度條件都與溫帶不同。當地太陽高懸，陰影短而深，空氣濕度也高。即使在這種環境中仍維持準確率，顯示在一種氣候帶建立的模型，也可能適用於截然不同的氣候帶。

無人機或地面機器人持續在田間移動並拍照。只要判斷慢了半拍，機器人就已經越過病斑。因此在田間，判斷病害有多準確，和多快作出判斷，同樣會左右實際效能。處理一張照片所需時間相差幾毫秒，最後便會決定一台機器人一天能巡查多少面積的田地。

當作物與雜草葉片相互接觸生長時，矩形框就不夠用了。這項工作由分割模型負責，把每一個像素分別標成作物或雜草。PSPEdgeWeedNet同時使用專門偵測邊界的分支與條件隨機場，清楚劃分花生田裡作物與雜草的邊界線。採用雙分支架構並同時理解情境的CAMDWS，則以超過91%與90%的IoU，亦即實際區域與預測區域的重疊比例，分別辨識澳洲小麥田常見雜草硬直黑麥草 *Lolium rigidum* 與野生蘿蔔

Raphanus raphanistrum。ViT 在 PlantVillage 資料上達到99.8%準確率。結合 ViT 與卷積注意力區塊的 HybridViT-CAB，只有41萬2千個參數，容量僅1.57 MB，卻能以每個處理階段141毫秒的速度，取得0.97的 AUC 與91%準確率。以 SwinTransformer 為骨幹，再加入 ConvNeXt-V2、SE-BiLSTM 與深度 Q 學習推薦層的無人機搭載診斷系統，在 SAR-CLD-2024 棉花資料上取得99.30%準確率。研究重心似乎正朝向模型輕量化但不犧牲準確度的方向移動。

再出色的演算法，也受限於攝影機拍到了什麼。RGB 感測器擷取與人眼相近的波長，價格低廉、重量輕，又已裝在手機或無人機上，因此成為病徵分類與雜草偵測現場的標準設備。然而要在病害顯現於外表之前，找出葉片內部正在發生的初期感染，或只用可見光辨別與作物顏色幾乎相同的綠色雜草，仍有與人眼相同的限制。填補這個缺口的是多光譜與高光譜影像。分別測量特定波段反射率的感測器，例如藍光475奈米、綠光560奈米、紅光668奈米、紅邊717奈米與近紅外線840奈米，會把資料轉換為常態化差異植生指數 NDVI、綠色常態化差異植生指數 GNDVI、紅邊 NDVI、土壤調整植生指數 SAVI 等指標，在肉眼可見的病徵出現之前，找出葉綠素受損或水分流失造成的早期逆境。

加入三維位置資訊的 RGB-D 感測器，會在彩色照片的每一像素上疊加距離值。這項深度資訊能建立座標，告訴採收機器人的手指或除草機器人的雷射應該精準瞄準何處。搭載這類感測器的無人機在離地2公尺至50公尺的低空飛行，以每一像素涵蓋0.3公分至5公分的解析度掃過整片田區，再由地面機器人與手持行動終端填補空隙。若再疊加測量氣溫、濕度、土壤水分與降雨量的物聯網感測器及氣象紀錄，多層的時空資料就會流入同一條資料管線。這些蒐集到的資料不只用於診斷，也會進一步用於預測。把最近幾天的氣溫與濕度變化和過去病害發生紀錄疊合，就能在病斑肉眼可見之前，預先警告發病風險上升的時間點。技術從找出看得見的危害，更進一步走向預先辨識尚未看見的危害。

照片蒐集完成後，並不能立刻使用。照片要重新裁切成224×224、512×512、736×736等固定大小，並將像素值調整到一定範圍。為彌補陽光方向變化以及各類病害照片數量不均的問題，除了旋轉、翻轉、傾斜與模糊照片之外，也會用 GAN、cGAN、DoubleGAN 等自行生成原本不存在影像的生成模型，製作患病葉片與雜草的合成照片，增加訓練資料。條件式生成對抗網路 cGAN，只要事先指定病害種類作為條件，就會新生成該病害的合成病斑照片。試圖製作逼真照片的一方，與試圖辨別照片真假的一方彼此競爭，在過程中共同提升能力。研究人員用交叉熵損失、類別加權損失、邊界損失等函數衡量模型錯了多少，再以 Adam 或 AdamW 等最佳化方法逐步縮小誤差。

完成訓練的模型，最終必須在田間的小型機器內運作。NVIDIA Jetson Xavier NX、Jetson Nano、Raspberry Pi 等掌心大小的電腦，以及 Xilinx Zynq-7000 等 FPGA 加速器，負責這項工作。量化把密集的小數近似成整數，減少一次運算處理的位元數，同時降低計算時間與記憶體用量。精確度會稍微下降，但計算速度大幅提高。像剪除樹木不必要的枝條一樣，剪枝會移除對結果影響不大的連結，再經過使用 TensorFlow Lite 或 TensorRT 重構模型的轉換，運算時間便能大幅縮短。據報導，經 FPGA 加速的模型與單一 RGB 模型相比，推論速度快43.2倍，延遲低於10毫秒，耗電量減少88%。近期已有系統能在42.6毫秒內處理一張照片，使手機等級的裝置也能進行即時診斷。只有190萬個參數的超輕量模型 PMVT，或經剪枝的 Transformer，也能直接部署在 TensorFlow Lite、ONNX Runtime 與輕量 gRPC 通訊環境下的農業無人機和小型裝置上。

要判斷這樣建立的模型是否實用，可以從幾項指標衡量。準確率是所有判斷中答對的比例；精確率是模型判定為病害的案例中，實際有病的比例；召回率則是實際患病葉片中，模型沒有漏掉而成功找出的比例。有些病害累積了數千張照片，罕見病害卻可能只有幾十張。在各病害照片數量差距如此大的情況下，F1 分數把精確率與召回率合併為一項指標，用來判斷模型是否只偏向常見病害。AUC-ROC 顯示多個閾值下的效能，混淆矩陣則用表格對照實際病名與模型預測病名，直接呈現模型把哪一種病誤判成哪一種病。若把患病葉片誤判為健康，就等於替病害爭取擴散到整片田區的時間。因此在病蟲害診斷中，召回率必須比精確率受到更高重視。稍微過度懷疑，比漏掉病害更安全。

需要找出位置的偵測與分割，採用不同的指標。IoU 顯示模型標示區域與實際病斑區域重疊的程度，mAP 則是多個閾值下精確率的平均值。這就像把兩個印章蓋在同一位置，查看彼此重疊多少。每秒處理影格數與推論時間，決定模型是否能配合實際田間速度使用。然而，即使所有指標都很好，若在田裡沒有用處，仍毫無意義。因此，還要同時查看雜草清除率、作物損傷率、每公頃除草劑用量與噴灑效率等農業現場指標。電腦判斷得準不準，與農家的成本和收穫量是否真正改善，是兩個不同問題。若無法回答第二個問題，準確率再高也難以在現場扎根。

數字背後，是實際設置在田間的攝影機與應用程式。以番茄、葡萄、棉花、辣椒、草莓等高價園藝作物為中心，結合手機應用程式與無人機的診斷系統正逐漸普及。番茄早疫病、葉黴病、會使葉脈扭曲的嵌紋病毒、使葉緣發黃捲起的黃化捲葉病毒，葡萄的露菌病、黑腐病，以及使葉脈間形成條紋狀黃化乾枯的 Esca 病，還有附著在棉花上的蚜蟲與二點葉蟊、鑽入葉片的潛葉蠅，搭載 YOLOv8、YOLOv11、EfficientNet、MobileNet 的模型，都能直接在田間辨識病名。栽培者站在患病植株前拍一張照片，幾秒後查看螢幕顯示的病名與防治方法，再決定下一步行動。

種植番茄、馬鈴薯與玉米的試驗田，呈現了診斷如何延伸到實際處置。深度學習模型只在判定有病害的區域噴灑初期殺菌劑，並個別調整該區域的灌溉量。診斷不再停留於螢幕上的數字，而是進一步成為改變藥劑與用水量的決策。不過這類試驗仍常侷限於一塊田地、一個季節，因此研究也指出，仍需要涵蓋多塊田地、多個季節與不同照度的大規模資料。

這類診斷工具在難以立刻接觸專家的地區更能發揮作用。一名農學家必須照看的農家與田區數量，各地差異很大，但無論在哪裡，要靠雙腳全部巡查都十分吃力。只用一支手機，就能立即獲得接近專家判斷的診斷，似乎正是這項技術廣泛擴散的原因之一。它與其說是取代人，不如說是在人的目光來不及觸及的時間與地點填補空缺。

利用攝影機區分作物與雜草，只在必要位置採取處理的方法，稱為區位特定雜草管理，英文縮寫 SSWM，Site-Specific Weed Management。這套方法的核心，是從整片田地噴灑相同劑量，轉向只挑選有雜草的地方，施作相應份量。然而，準確劃出這條邊界本身並不容易。作物與雜草越幼小，彼此長得越靠近，邊界就越模糊。

區分作物與雜草，比找出病害更困難。兩者都是綠色、都會生長，而且幼苗期連葉形都很相似。一項以澳洲120公頃小麥田為對象的實驗，從時間變化著手處理這個問題。低空無人機在不同時間共拍攝同一片田地18次，再以稱為 AMSTF 的時空光譜融合演算法疊合判讀這些照片。雜草的每日生長速率指數為0.025，小麥為0.015，差異完整呈現在時間序列光譜指數上。加入 CAMDWS 分割後，作物與雜草交界處原本介於9.8%至12.3%的誤分類率，降至5.4%。生長速度差異這項不易察覺的線索，成為重新劃定邊界線的關鍵因素。

名為 See & Spray 的精準防治設備，把攝影機裝在噴嘴上方，並在下方安裝超高速電子閥。這套設備由 John Deere 旗下公司 Blue River Technology 製造。它能即時辨識藏在綠色作物之間的綠色雜草，亦即 Green-on-Green 問題。即使是人眼，也常無法一眼看出綠色葉片之間的綠色雜草。系統會依雜草密度與種類，隨時把噴霧粒徑調整在150至250微米之間，噴灑量調整在每分鐘0.12至0.35公升之間。與整片田地均勻噴灑的傳統全面施藥相比，除草劑用量可減少31%至32%，降到每公頃0.68公升左右。作物不會沾到藥劑，施入土地的化學物質總量也一併下降。

不同於使用化學藥劑的方法，完全不施藥的途徑也已進入商用階段。搭載 DIN-LW-YOLO 偵測演算法與 RGB-D 攝影機的自動駕駛機器人，能以三維座標找出剛從作物植株之間萌發的雜草幼苗生長點。生長點是植物新生組織所在的最頂端。機器人瞬間向此處發射高功率雷射，以熱能燒除。這是用光代替除草劑液滴清除雜草的方法。美國 Carbon Robotics 製造的 LaserWeeder，是把這套方法推向商業規模的代表案例。它每小時清除超過10萬株雜草，自2022年上市以來，累計清除的雜草已超過100億株。2026年第1季年營收突破1億美元，其後統計更報告達到1億7,700萬美元

，規模為農業機器人公司前所未見。機器人已銷往15個國家，北美、歐洲與澳洲超過100名栽培者正在使用。

2026年2月，該公司推出以1億5千萬張已標註植物照片訓練的大型植物模型。據稱，每次面對新田地或陌生作物時，原本需要數週的客製訓練，已縮短到幾分鐘。一台機器人遇過的雜草、土壤與光線組合，下一台機器人不必從頭重新學習。這等於把一台機器人累積的經驗原封不動移轉到下一台機器人、下一片田地。雷射除草似乎已走到一個轉折點，正從單一農場的工具，轉向多個農場共同使用的共享模型。

再回到清晨的那座溫室，栽培者手裡很可能拿著手機，而不是手電筒。原本翻開葉片、用眼睛測量病斑的手，正變成拍一張照片、查看螢幕病名的手。在韓國，農村振興廳已自行開發並提供這類功能的應用程式。栽培者用手機拍攝患病葉片或果實並上傳後，人工智慧立即辨識病名，甚至推薦合適的防治藥劑。目前系統涵蓋31種主要作物與182種病蟲害，並計畫在2030年前擴大到韓國栽種的139種主要作物。韓國型第2代智慧農場中，上傳到雲端的人工智慧會即時讀取栽培環境與作物生物資訊，辨識晚疫病、白粉病等5種病害，以及潛葉蠅等2種害蟲。農村振興廳並將名為 AI Isagi 的農業專用人工智慧助理與17個資訊系統串接運作，且正準備下一版本，使其能以語音問答，甚至診斷農場經營狀況。

找出病害的攝影機、辨識雜草的攝影機，以及依結果噴藥或發射雷射的裝置，最終連成一條流程。農業正從整片田地採取相同處理的時代，轉向連每片葉子、每顆果實都加以區分，並分別開出不同處方的時代。如今在田間接受測試的攝影機與機器人，正站在這條界線上。這股潮流能擴散多廣，取決於準確率、價格以及栽培者的信任。

即使已有這些成果，田間仍與實驗室不同。PlantVillage 等常用於初步訓練深度學習模型的資料，由背景乾淨、光線均勻的照片組成。然而在實際田區，陽光角度會隨季節與時間改變，陰影變深，葉片在風中搖動、彼此重疊，灰塵落在鏡頭上，泥土與枯莖混雜於背景。把從實驗室照片學習的模型直接移到這種田地，就會出現準確率明顯下降的領域偏移。拍攝環境一變，模型便會把同一種病誤認成另一種病。照明色溫、鏡頭視角、落在葉片上的陰影方向，只要與訓練時不同，就足以動搖判斷。無論蒐集多少照片，如果照片拍攝環境與真實田地不同，所學內容就無法直接用於田間。

標註本身也是瓶頸。畫出矩形框、逐一替每個像素命名，必須由農學專家親手處理，一張照片有時要花幾分鐘。為減輕這項負擔，研究人員正探討只用少量標註學習的半監督學習、自行產生答案並學習的自監督學習，以及只看幾張照片就能辨識新病害的少樣本學習。利用大型視覺語言模型與生成式人工智慧，大量製作附有標註的合成照片，也成為繞過這項瓶頸的方法。

感測器越多，需要計算的資料也越多。若要把可見光照片、短波紅外線與高光譜資料，以及測量土壤和天氣的物聯網資料即時疊合，光是對齊以不同速度傳入的資料就不容易。無人機傳送的照片與地面感測器傳送的數值，測量週期與更新速度不同，因此另需一道程序，使它們對應到同一時段的同一位置。若還要在以電池驅動的小型裝置上，毫無延遲地同時執行偵測、推論、路徑規劃與噴灑量調節，就必須同步縮小模型體積，並加裝 FPGA 或 NPU 等專用晶片。

最後一項課題是信任。深度學習模型近似於無法自行說明判斷理由的黑箱。若要讓栽培者與農學家相信判斷並據此施用防治藥劑，人們必須能親眼確認模型看了葉片哪一部分，才判斷為病害。把 Grad-CAM、SHAP 或能揭示因果關係的注意力機制植入模型，並以影像呈現病斑部位貢獻度的研究，看來是建立這種信任的下一步。技術再準確，只要栽培者懷疑其判斷，就難以在現場被接受。

資料來源與參考文獻

學術論文

1. Adewumi, A., & Saraswat, D. (2026). 人工智慧與邊緣運算應用於精準雜草控制之綜合回顧. *Artificial Intelligence and Applications*. DOI: 10.47852/bonviewAIA62028867.
2. Kakde, S., Poyam, P., et al. (2025). 用於自主精準雜草管理的整合式時空深度學習架構設計. *International Journal of Applied Mathematics*, 38(2s), 1340-1363.
3. Latif, A., Jati, H., Surjono, H. D., & Yusuf, M. (2026). 以無人機輔助的深度學習雜草偵測，促進永續農業與環境韌性. *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). 使用 EfficientNetB0、InceptionV3 與 Xception 進行葡萄葉病害分類的比較式深度學習架構. *Discover Applied Sciences*, 7, 1222. DOI: 10.1007/s42452-025-07457-5.
5. Moldvai, L., & Nyéki, A. (2025). 番茄 (*Solanum lycopersicum*) 偵測與栽培的創新電腦視覺方法. *Discover Applied Sciences*, 7, 975.
6. Pai, D. G., Balachandra, M., & Kamath, R. (2025). 使用 PSPEdgeWeedNet 進行花生栽培作物與雜草分割的深度學習方法. *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：用於農業系統精準雜草偵測的視覺 Transformer 與卷積注意力網路. *Scientific Reports*, 16, 18473. DOI: 10.1038/s41598-026-48652-7.
8. 以 FPGA 加速部署於物聯網的因果注意力多模態深度學習網路，用於精準作物病害監測. (2026). *Environment Conservation Journal*.
9. AgroDualNet：以雙重深度學習為基礎的作物病害預測與果實成熟偵測架構. (2026). *Scientific Reports*.
10. 大規模精準農業：使用視覺 Transformer 進行早期病害偵測. (2026). *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 14(4).
11. 使用遷移學習式深度卷積神經網路進行作物病害偵測的新方法. (2026). *Neural Computing & Applications*, 38, 500. DOI: 10.1007/s00521-026-12216-7.
12. 使用卷積神經網路 (CNN) 辨識作物田間害蟲：一種深度學習方法. (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>

演講與影音資料

1. C-DAC. (2025). 農業中的人工智慧：改造印度農業地景. YouTube.
https://www.youtube.com/watch?v=IV3_VnWiBpM
2. RMCG. (2025). 人工智慧解密：蔬菜栽培者的實用工具. YouTube.
<https://www.youtube.com/watch?v=G2ytLXLW7hw>
3. Grounded AI. (2025). 人工智慧如何改變農業：更智慧的牛隻、作物與病蟲害控制. YouTube.
<https://www.youtube.com/watch?v=bxlF2MpXsB0>
4. SyncTellect Automation Hub. (2026). 端對端 AI/ML 專案系列 | 第1天：專案啟動與作物病害偵測概述. YouTube. <https://www.youtube.com/watch?v=SNqOcVib3BY>
5. Royal Society of Biology. (2026). 植物健康系列 | 數位葡萄栽培：葡萄藤健康的未來. YouTube.
<https://www.youtube.com/watch?v=5iXPOMxl6bU>

新聞與報告

1. Carbon Robotics. (2026). LaserWeeder 成果. Carbon Robotics. <https://carbonrobotics.com/results>
2. Hypersinc. (2026). Carbon Robotics 的 AI 雷射除草平台營收突破1億. Hypersinc.
<https://hypersinc.com/article/carbon-robotics-crosses-100m-revenue-on-ai-laserweeding-platform-1775055784166>
3. Design News. (2026). LaserWeeder 在過去兩年清除了數十億株雜草. Design News.
<https://www.designnews.com/automation/laserweeders-killed-billions-of-weeds-in-the-last-two-years>
4. 韓國農村振興廳. (2026). 農作物病蟲害人工智慧影像診斷與處方服務. 韓國農村振興廳.
https://www.rda.go.kr/board/board.do?mode=view&prgId=day_farmprmninfoEntry&dataNo=100000806197
5. 韓國智慧農場平台 (Smart Farm Korea) . (2026). 人工智慧生長管理處方服務. 韓國智慧農場平台 (Smart Farm Korea) . <https://www.smartfarmkorea.net/analyService/internal/aiAdvice.do?menuId=M11030102>

1.2

果實成熟度判別與生長、產量預測

一項試驗在大型商業溫室的管軌台車上安裝攝影機，計算各成熟階段甜椒的數量，並確認這些數值與總收穫量的關係。台車沿著接近溫室天花板的軌道，以每秒0.3至0.5公尺的速度移動。懸掛在下方的攝影機朝向成排的甜椒，讀取從葉片間露出的果實表面顏色，將成熟轉紅的程度轉換成數字。這套台車式計數裝置在整個試驗期間都維持穩定的偵測效能。

判斷果實何時成熟，涉及的金額比想像中更大。採得太早，果實會在甜度尚未提高時出售；採得太晚，則會變軟或腐壞，在運銷過程中遭到丟棄。長久以來，這項判斷交由工人的眼睛與雙手負責。他們巡視田地或溫室，觀察顏色並用手觸摸。由於每個人的標準略有不同，面對同一顆果實，判定結果不一致的情況很常見。若要準確得知糖度、酸度或硬度，必須切開果實、榨取汁液，再放入儀器進行化學分析，但這種方法會讓該果實本身無法再使用。切開幾個樣本，無法掌握整片田地的情況，所以農家即使投入勞力與時間，往往也只能得到接近猜測的答案。錯誤判斷不只造成一次損失。第一次採收時漏掉尚未成熟的果實，等到下次採收，果實常已失去商品價值而被丟棄。

一台攝影機要回答的問題，其實不只一個。這顆果實今天是否完全成熟、整棵樹目前處於開花或果實膨大階段，以及這片田地未來能生產多少公斤，是三個不同問題。成熟度根據單顆果實判斷，生長階段根據整棵樹或整片田地的變化判斷，產量則是把兩者計算後轉換成未來數字。然而，三者都從同一個鏡頭拍攝的影像出發，因此近期研究不再分別回答這三個問題，而是轉向以一台攝影機和一條資料管線同時處理。

攝影機只看顏色就能推測成熟度，自有其原因。果實成熟時，果皮內的葉綠素逐漸分解，綠色變淡，類胡蘿蔔素或花青素等色素取代綠色，轉為黃色、橘色與紅色。同時，肉眼看不見的內部情況也在改變。水溶性糖分，也就是總可溶性固形物 TSS 的含量增加，產生酸味的可滴定酸度 TA 下降，澱粉與水分比例也跟著改變。RGB 攝影機拍攝可見光範圍，也就是和人眼相同的400至700奈米波段，是讀取外觀變化的基本工具，包括色調、質地與形狀。

能在顏色之外加入距離資訊的設備，是 RGB-D 攝影機。一般相機只記錄平面的色彩資訊，RGB-D 攝影機則為每個像素增加一個距離值。就像地圖原本只有經緯度，現在又標上高度。憑藉深度值，攝影機能計算果實前後左右的位置、半徑與體積，甚至不會漏掉被葉片或枝條遮住一半的果實。如果不處理遮蔽，計數結果就會低於實際數

量，接下來整套產量預測也會偏低。設施溫室巡檢機器人常用的 Intel RealSenseD435i 等產品，便負責這項工作。

蒐集資料的過程也需要許多工夫。攝影機拍攝的照片混有雜訊，因此要用高斯濾波與維納濾波去除雜訊，再以稱為 CLAHE 的技術均衡陰暗處與明亮處的對比差異。接著還要進行最小最大正規化，把像素值調整到一定範圍。照片不足時，會透過旋轉、翻轉、改變亮度或遮住畫面一角來增加數量。近來也用 CGAN 或 SMOTE 等技術，生成並未實際拍攝的虛擬果實照片與化學成分數值，加入訓練。不過，不能在把增生照片混合後，才分成訓練集與驗證集。必須先完成資料切分，只對訓練資料進行處理，才能避免日後取得被灌高的評估結果。

面對果皮顏色直到最後都不改變的水果，只看可見光也無能為力。泰國芒果品種 Nam Dok Mai Si Tong，NDMST，便是如此。它在整個成熟過程中，果皮始終保持均勻黃色，很難只憑照片判斷採收時間。這時使用的是近紅外線，也就是測量人眼看不見之700奈米以上波段的多光譜與高光譜攝影機。近紅外線會敏銳回應果肉水分與化學成分變化，因此能讀出藏在果皮內部的情況。研究團隊依此原理建立 AFMG-DLFF 系統，把從 RGB 照片提取的1,536維外觀特徵，與編碼內部資訊的512維向量結合，後者包含糖度減去酸度所得的 BrimA 指數，形成2,048維向量。研究人員以 K-means 分群建立未熟、半熟、全熟3個階段的標準，再用模仿螢火蟲群追隨彼此光亮而聚集之習性的螢光蟲群最佳化法，調整學習率與批次大小等細部數值。結果顯示，這套融合模型的分級準確率達97.86%。相同條件下，只使用照片資訊的模型為88.16%，只融合照片的模型為88.73%。加入內部資料，大幅提高了準確率。

也有不用光，而以熱測量成熟度的方法。果實越成熟，表面溫度與周圍空氣溫度的差距越小，熱影像感測器會直接讀取這項細微溫差。在油棕農場，系統把近紅外線測量與色彩分析加入這項原理，不切開果串便推測其中的油分與游離脂肪酸 FFA 數值。只要在樹下懸掛低價 ESP32-CAM 模組，就能即時計算自然掉落的落果，並透過連接 YOLOv8x 辨識模型的網頁儀表板通知管理者。這套系統取得最高0.94的 F1 分數，也就是同時衡量精確率與召回率的平衡分數，協助農場不錯過最佳採收期。

農場要配備哪一種眼睛，取決於預算與作物條件。若只看顏色便足以判斷，一台低價 RGB 攝影機即可；若作物有許多果實藏在葉片後方，就需要具備深度資訊的 RGB-D 攝影機。像芒果這樣外表與內部變化不同步的水果，必須引進近紅外線或高光譜感測器等更昂貴的設備。需要查看油分或脂肪酸等細微成分的作物，則還要疊加熱影像感測器。先從一台低價攝影機開始，有需要時再逐一增加感測器，就目前而言是較實際的導入順序。

回到溫室天花板下方的台車，攝影機的工作並不止於拍一張照片。人工智慧會在照片中每顆果實周圍畫出方框，或更進一步逐像素描繪果實輪廓，從背景中切割出來。問

題在於，台車再次經過同一區段，或攝影機角度稍有變化，就很可能把同一顆果實計算兩次、三次。為防止這種情況，系統採用非極大值抑制，只保留重疊方框中信賴分數最高的一個，刪除其餘方框。接著再加入 DeepSORT 等物件追蹤技術，持續追蹤目前畫面中的果實，是否就是前一畫面看過的同一個體。憑藉這兩道機制，台車繞行溫室一圈後，能提供已排除重複項目的果實數量。

成串生長的番茄，需要和單顆番茄不同的處理方式。一座溫室在巡檢機器人上安裝 Intel RealSense D435i 攝影機。攝影機高度固定為1.2公尺，上下傾斜30度，左右旋轉15度，鏡頭與果實間距則設為0.5至1公尺。由此取得解析度1280×720、每秒30張的影像。機器人沿軌道以每秒0.3至0.5公尺移動時，人工智慧依一串果實中轉紅單果的比例，將成熟度分為3個階段。紅色只擴散到果實10%至30%的是初期，30%至70%為中期，超過70%則是後期。負責這項任務的 LampCT-YOLO 模型，在 YOLOv10 骨幹上加入名為 SegNeXt 的注意力裝置，使模型對色彩資訊更敏感。它降低溫室骨架或泥土地面等無用背景的反應，再加入 LAMP 通道剪枝的輕量化處理，縮小模型體積，使其即使在機器人搭載的小型運算裝置上，也能進行即時偵測。

進一步觀察這台機器人，可以看到機身上裝有 NVIDIA Jetson AGX Orin 或 Xavier NX 等邊緣運算裝置，前方則與 RealSense 攝影機一同安裝二維 LiDAR 感測器。LiDAR 發射光線並測量反射回來的時間，密集描繪到周圍障礙物的距離，協助機器人沿著溫室軌道與通道行駛，不偏離路線。這台同時使用攝影機與 LiDAR 的機器人，不只即時評定果實成熟度，還能提取每顆成熟果實的三維座標。必須先知道座標，下一階段的機械手臂或工作人員才能準確前往該位置採摘果實。

對農家而言，分開使用病害監測設備與成熟度判別設備很麻煩。為減少這項不便，AgroDualNet 把兩種任務合為一體。病害監測部分把 CBAM、ResNet50 與 SMO 最佳化技術結合，在收錄葉片病徵照片的 PlantVillage 資料集上，取得99.6%的高準確率。成熟度判別部分使用更輕量的 MobileNetV2 與 YOLOv8，分辨未熟、半熟、全熟、軟化4個階段，在電池驅動的小型裝置上也能即時運作。農家能以一台攝影機和一套程式同時取得兩項判斷，不必配備兩套設備。

在日本梨栽培現場，另一項必須解決的課題是可解釋人工智慧。即使有人工智慧負責分級，若無法向栽培者解釋分級理由，就難以在現場取得信任。研究團隊在名為 Mask R-CNN 的神經網路中，加入先掃描整張照片、事先提示可能有瑕疵部位的全域情境區塊，逐像素準確切割梨子表面的損傷與斑點。接著，把瑕疵佔整個表面的比例分成大、稍大、稍小、小等模糊程度，再輸入模仿專家判定規則的模糊推論系統，最終分為實際市場使用的特級、上級、良好、等外4個等級。由於它不是用一個截然分明的數字回答，而是模仿人類模糊的判斷方式，栽培者能追溯這顆梨獲得該等級的原因。

要決定整片廣大田地何時採收，無人機便會出場。Mavic 2 Pro 無人機在約7公尺高處拍攝玉米雄穗生長的田區，拍完1公頃只需5分鐘。以 YOLOv5 為基礎建立的雄穗偵測模型，把雄穗分為尚未開花、剛開始開花、盛開3個階段，再以所有雄穗中盛開與尚未開花者的比例差異計算生長指數。這項指數與玉米吐絲時間呈現強烈負相關，相關係數達負0.943，關係非常明顯。

以玉米吐絲日為基準，之後的計算會逐日累加氣溫。無論每天氣溫高低，玉米都必須累積到固定的熱量，才會進入下一個階段。惠味 Star 品種在累積溫度達攝氏500度時開始採收，於560度結束；Honey Bantam 20 品種則在450度開始、510度結束，各品種採用不同標準。由此決定的適收期約有5天，實際在採收前1個月以此方式預測，命中機率約為70%。以類似方式預測蘋果樹初花日期的研究，使用名為 BiLSTM-MhA 的模型，把每日氣溫與海拔、緯度、經度一併輸入。模型能提前15天至20天預測花期，誤差僅約1天，精確而言是1.34天。

甜玉米田也進一步在現場驗證這項預測是否真正實用。把預測結果與超過80處田區比對後，再次確認準確率為70%。在預測日期一次收完整片田地的統一採收，與逐顆查看成熟程度、分多天採摘的選擇性採收之間，產量差異在統計上並不顯著，顯著性機率為0.07。這表示只要預測正確，人們就不必多次來回田間挑選，即使以機械在一天內收完整片田地，產量也不會受損。

這類預測系統若要產生實際效用，結果必須立即送到農場管理者手中。在甜玉米田，無人機影像分析結果會自動連接地區氣象資料伺服器，不必由人另外按計算機，螢幕上就會顯示預定採收日期。油棕農場的網頁儀表板也是如此，管理者即使坐在辦公室，也能即時確認哪棵樹下累積了落果，並決定派遣工人的順序。原本必須用雙腳巡查現場的工作，移到一個畫面上完成。這類自動串接，正是把實驗室模型轉變為實際農場工具的最後一環。

拍攝草莓田時，葉片之間會出現密密重疊的紅色果粒。草莓與桃子這類果實小、密集生長的水果，光是區分單顆果實就很困難。近期提出的 FruitQuery 模型以 Transformer 架構偵測田間草莓與桃子的成熟度，平均精確率達67.02%，參數卻只有1,408萬個，比 YOLOv8、YOLOv9、YOLOv10 更輕且更準確。草莓田照片必須由人逐張標示正確答案，負擔很大，標示工作本身便成為訓練瓶頸。2026年提出的 SSEFNet 為減輕這項負擔，選擇半監督學習，也就是同時使用只有少數照片已標示、其餘未標示的資料，在複雜交錯的草莓資料集上取得91.1%精確率。佛羅里達大學研究團隊甚至不用真實田地，而是在電腦中建立虛擬草莓田，先讓模型在其中訓練。由此建立的模型，在真實田間偵測果實的準確率為92%，測量果實直徑的誤差僅1.2毫米，達到可以直接用於商業分級篩選的水準。從蒐集與標示照片資料的成本不斷下降

來看，未來把測量溫度、濕度、乙烯氣體濃度的感測器與影像結合之多感官融合，似乎會成為下一階段的常態。

產量預測看似簡單，實際上並非如此。照片中的果實終究只是拍攝當下看得見的部分，還有藏在下方葉片後、尚未露出的果實，以及未來幾週將新長出的花。因此，良好的預測模型不只計算今天看見的果實數量，也把樹木生長階段、至今累積的氣溫，以及過去同一時期的收穫紀錄一併納入。攝影機看到的只是現在的一個畫面，產量預測則是在這個畫面上加入時間，描繪未來。

也有把計數、品質分類與產量計算串成一條流程的系統。名為 FruitNet 的資料管線，先以 YOLOv8 即時找出照片中的果實，進行初次計數；接著以結合深度卷積神經網路與支援向量機的模型，把果實分成4個品質等級；最後把各等級的數量與大小資訊，輸入稱為隨機森林迴歸的統計技術，計算整片田地的最終收穫量。使用收集超過1萬8千張蘋果照片、超過4萬個單體標註的 MinneApple 資料集進行測試，訓練準確率超過98%，驗證準確率則介於94%至95%。當果實密集重疊、彼此遮蔽時，整理重疊方框的技術與同時查看多個變數的迴歸模組，會防止重複計算。

同一套攝影機資訊，不只用於計算與分級果實，也用於規劃機械手臂實際前往採摘果實的路徑。以 Kinect 或 RealSense 等 RGB-D 感測器找出果實後，人工智慧會把代表判斷可信程度的信賴分數、夾爪有兩根還是三根手指，以及果實偏離垂直方向的角度，一併納入一條迴歸方程式。把這個數值直接放入 A* 路徑搜尋演算法的成本計算，機械手臂就不會盲目朝最短距離伸展，而是會同時考慮容易抓取的角度與判斷可靠的果實，規劃路徑。柳橙試驗的決定係數為0.89，位置誤差3.2公分，百分比誤差5.4%。草莓試驗的決定係數為0.82，位置誤差4.7公分，百分比誤差7.9%。加入這套計算後，機械手臂採摘柳橙的移動距離減少14%，採摘草莓的移動距離減少11%，準確定位抓取的精準度則提高12%至15%。

把這些發展排列在一起，便能看出方向。起初，判別成熟度的模型與單純計數的模型彼此分開，如今已接連出現像 AgroDualNet 這樣同時查看病害與成熟度的模型、像 FruitNet 這樣把數量、品質與產量串成一條流程的模型，以及像 RGB-D 機械手臂這樣把辨識與動作規劃合為一體的模型。未來趨勢看來是讓一台攝影機、一套程式回答更多問題。這也能減輕農家分別購買、分別管理多種設備的負擔，因此是合理的方向。與其並排增加多台攝影機，不如讓一台攝影機同時扮演多種角色。

要衡量以不同方式建立的這些模型表現如何，可以使用幾項共同指標。準確率是所有判斷中正確的比例；精確率是人工智慧判定成熟的果實中，實際也已成熟的比例；召回率是實際成熟果實中，人工智慧沒有漏掉而成功找到的比例。若要查看模型能否找出數量較少的類別，例如未熟或腐壞果實，同時考慮精確率與召回率的 F1 分數非常實用。方框畫得多準確，以人工智慧方框和實際果實位置的重疊比例 IoU 衡量；在多

種信賴門檻下觀察後取平均的 mAP，則綜合呈現整體偵測模型的能力。若裝置必須即時運作，如機器人或巡檢攝影機，也要查看代表每秒處理張數的 FPS。預測產量或糖度等數值時，會使用不同指標。平均絕對誤差與均方根誤差，表示預測值和實際值相差多少；平均絕對百分比誤差，則把差異轉換成比例。決定係數以0至1之間的數值，表示預測模型能解釋實際產量或糖度升降變化的程度，越接近1，代表預測越精準。新鮮度分數則以百分比顯示果實整個表面中無瑕疵面積所佔比例。因此論文不只提出一項準確率，而是並列多項指標，避免只挑選看起來最好的一項。

所有這些數值最後會整理成一張表，掛在農場辦公室牆上或顯示於平板螢幕。表中依區域並列今天採收的果實數量、各等級比例，以及預計未來一週內完全成熟的果實數量。管理者看著這張表，決定明天要派多少人前往哪個區域，以及要準備多少箱子。幾個數字就能改變人的一日行程，因此模型準確率相差1%，在現場絕不是小問題。

這幅圖景不會在採收時結束，而會延伸到後續物流。如果預先知道今天會產出多少箱，就能提前一天決定要叫幾輛冷藏車、在分級場安排多少人。相反地，如果預測錯誤、貨量突然湧入，箱子就會堆在冷藏庫前，其中一些來不及降溫，品質因而下降。成熟度判別與產量預測既是田間技術，也是牽動田外物流規劃的變數。

對農場主而言，重要的是始終如一的準確率。只在晴天拍攝的幾張照片上表現良好，到了陰天或傍晚就出錯的模型，在現場毫無用處。偶爾一次得到漂亮數字，與每天早晨都維持同樣水準，是完全不同的事。每天巡行溫室的台車式計數裝置，在整個試驗期間效能始終穩定，這項事實和最高準確率數值一樣重要。

把這類系統直接移到現場，就會出現實驗室裡看不見的問題。露天田地的陽光強度每小時都在變，強烈直射光形成深色陰影，起風時枝葉反覆重疊又分開。只要鏡頭沾上灰塵或凝結濕氣，依賴單一攝影機的辨識效能就會驟降。若要在這些環境變化前維持穩定，可能還需要從多角度同步拍攝的多視角影像，以及把這些照片合成一組立體點雲的三維融合技術。

外觀與內部狀況不同步的水果，仍是重大障礙。像芒果一樣果皮顏色始終不變，或果皮很厚的水果，無法只憑照片得知糖度、酸度或脂肪酸數值。把少量化學測量值加入低價 RGB 攝影機的融合方式，以及讓近紅外線與高光譜感測器本身變得更小、更便宜的研究，必須同步推進。如果沒有能同時觀看外部與內部的眼睛，再精密的人工智慧也無法讀懂果皮裡面的全部故事。

農場實際使用的設備，不像實驗室電腦那樣資源充裕。高效能視覺 Transformer 或大型卷積神經網路，在電池與圖形處理器資源有限的小型機器人或低價物聯網模組上，反應會變慢。因此，降低數值精度以減少計算量的量化、像 LAMP 通道剪枝一樣切除不必要連結的結構化剪枝，以及把大型模型判斷移轉到小型模型的知識蒸餾等輕量

化技術，仍在持續改進。實際在田間使用的人工智慧，往往是在既有硬體條件下最為實用的模型。

訓練方法本身也有常見陷阱。有些研究先用旋轉、翻轉、改變亮度等方式擴增照片，之後才分成訓練資料與驗證資料。這樣做會造成資料洩漏，使源自同一顆果實的變形照片同時混入兩邊。此時驗證分數會高估實際能力。為避免這個問題，必須先切分訓練資料與驗證資料，只擴增訓練端的資料，驗證資料則應保留未經處理的原始狀態。遵守這項原則的研究，和未遵守者所發表的數字，不能直接比較。

資料來源與參考文獻

學術論文

1. Bijwe, K. B., & Gadicha, A. B. (2026). FruitNet：用於果實偵測與產量估算的深度混合模型. *Bulletin of Electrical Engineering and Informatics*, 15(2), 1150-1160. DOI: 10.11591/eei.v15i2.11112.
2. Kripa, S., & Jeyalakshmi, V. (2026). 使用特徵融合與深度學習進行自動化果實成熟度分級. Preprint submitted to *Scientific Reports*.
3. Moldvai, L., & Nyéki, A. (2025). 番茄 (*Solanum Lycopersicon*) 偵測與栽培的創新電腦視覺方法：回顧. *Discover Applied Sciences*, 7, 975. <https://doi.org/10.1007/s42452-025-07613-x>
4. Simatupang, et al. (2026). 透過落果偵測識別油棕適收狀態的 YOLOv8 物聯網系統. *Journal of Deep Learning, Computer Vision and Digital Image Processing*, 15(2), 237-249.
5. Zeeshan, S., et al. (2025). 透過基於深度學習的感知與致動器感知運動規劃，對機器人果實採收進行資料驅動軌跡最佳化. *Engineering Research Express*, 7, 045210.
6. 油棕新鮮果串成熟度分級的深度學習方法：綜合回顧. (2026). *Trends in Sciences*, 23(8), 13227.
7. 智慧農業中以深度學習偵測草莓果實與成熟度：架構與方法的首次回顧. (2026). *Smart Agricultural Technology*.
8. AgroDualNet：以雙重深度學習為基礎的作物病害預測與果實成熟偵測架構. (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). 運用物件偵測 AI 開發甜玉米適收期預測技術. 『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). 加工用甜玉米適收期 AI 預測技術的開發. 『農業食料工学会誌』, 88(3), 123-128.
11. 劉恩奇, 劉淼, 楊貴軍 等. (2026). 基於時間序列氣溫特徵增強的蘋果初花期 Bi-LSTM 預測方法. 『智慧農業(中英文)』, 8(2), 84-96.
12. 趙麗成 等. (2026). 基於改良 YOLOv10 與 LAMP 通道剪枝的串番茄成熟度偵測演算法研發. 『智慧農業(中英文)』, 8(2), 133-146.
13. 導入全域情境資訊，使用深度學習與模糊推論的西洋梨分級方法研究. (2026). 『農業情報研究』, 35(2), 65-78.
14. 使用管軌台車搭載攝影機，在商業溫室中以深度學習計算甜椒果實並估算產量. (2026). *Horticulturae*, 11(7), 718. <https://doi.org/10.3390/horticulturae11070718>
15. FruitQuery：用於果園環境草莓與桃子成熟度偵測的 Transformer 模型. (2026).
16. SSEFNet：用於複雜田間資料集之草莓成熟度偵測的半監督學習模型. (2026). arXiv:2602.15656. <https://arxiv.org/pdf/2602.15656>
17. 用於訓練果實偵測與尺寸測量模型的虛擬草莓田模擬. (2026). University of Florida.

演講與影音資料

1. CSUMB College of Business. (2025). 2025年農業工作：拓展視野，收穫資料，農業職涯. YouTube.
<https://www.youtube.com/watch?v=rgshB8Jh2ZE>
2. Street Science with Fun. (2025). AI/ML 驅動的芒果偵測與採收機. YouTube.
<https://www.youtube.com/watch?v=Dy3xDC8rElw>
3. Washington State Academy of Sciences. (2025). 用於採後處理的人工智慧. YouTube.
<https://www.youtube.com/watch?v=hJlOrgNIQG4>
4. Solvi. (2026). 網路研討會：以真實田間資料驗證人工智慧植物計數. YouTube.
<https://www.youtube.com/watch?v=B0KuJdRtmaQ>
5. Greg Bronevetsky. (2025). 模擬與控制環境中植物生長性狀的預測式模式辨識. YouTube.
<https://www.youtube.com/watch?v=uKepfZAnKbk>

第2章

園藝農業機器人與自主作業自動化

2.1

果蔬與菇類採收機器人及末端執行器

截至2026年4月，日本已有一部小番茄採收機器人每天能自行採收31公斤，並投入商業生產。同月，以色列農業科技公司DailyRobotics在美國加州農場部署露天草莓採收機，日本新創公司inaho以服務模式提供的零食番茄採收機器人，則讓農場的勞動需求降低逾45%。園藝作物採收機器人面臨的課題大致有三項。看見果實位於何處，估算施加多大的力才不會弄破果實，以及抓錯時立即重新調整抓握。

番茄、草莓與洋菇等必須逐一用手採收的作物，採收作業占總生產成本的一半，最高甚至達70%。農村勞動人口日益減少，年齡也愈來愈高，因此人們對能取代人手的機械手臂寄予的期待逐年升高。然而綜觀目前已商業化的採收機器人，果實採收成功率仍停留在66%左右，每採下二十顆果實，約有一顆表面會留下傷痕或壓痕。人類靠眼睛觀察，並憑指尖觸覺拿捏力道採摘果實，機器人卻必須用感測器與運算重現這種感覺。因此，在採收果菜類與菇類的機器人中，實際抓住果實的手，也就是末端採收器的形狀與控制力量的方式，決定了整支機械手臂的能力。

採收機器人的手臂會依栽植方式與遮蔽程度而有不同外形。在枝葉層層茂密的果樹間，配有五至六個關節的多關節手臂較有利。就像人依序轉動肩膀、手肘與手腕，把手伸入狹窄縫隙，具有五至六個關節的機械手臂也會尋找葉片間的空隙，伸向藏在深處的果實。反過來，如果像溫室內沿著管軌排列的作物，只需在工作範圍固定的圓柱形空間內移動，並聯式機械手臂會更合適。多根短臂共同支撐一點的並聯式手臂結構堅固、反應快速，即使在半徑300毫米、高度約300毫米的狹小空間內，也能穩定而迅速地移動，並以吸附方式摘下果實。

在菇類栽培場這種層架以250毫米以下間距層層堆疊的場所，手臂沒有上下大幅移動的餘裕。這類場所已採用SCARA（Selective Compliance Assembly Robot Arm）結構。SCARA手臂平時在平面上快速左右旋轉，只在需要時略微垂直升降，因此能像把手臂平放般伸入薄窄的層架縫隙採菇。像蘋果樹這樣果實向四面八方分散生長的作物，一支手臂便不夠用。名為MARS 3.1的蘋果採收機器人分別控制兩支手臂，從兩側同時伸入樹冠表面內側的淺層區域，分區採收果實並避免互相碰撞。

實際接觸果實的指端，也就是末端採收器，大致有三種製作方式。三根手指以螺旋式致動裝置收攏的剛性機械夾爪，能有效把果實推向中央並承受重量，必要時還可在指端裝上小刀片或旋轉刀，直接切斷果梗。不過，由於手指由金屬或硬塑膠製成，力量

容易集中在果實表面的一點，留下壓痕或傷口。真空吸附式則不用手指，而是把吸盤貼在果實表面，抽出內側空氣形成負壓，再以拉扯或扭轉方式摘下果實。這種方式適合表面光滑或外皮厚的果實，但表面凹凸不平或細毛較多時，空氣會從吸盤與表面間的縫隙漏入，吸力很快便會消失。

為彌補這兩種方式的缺點，研究人員以矽膠或超彈性體等柔軟材料製作手指，形成柔性順應夾爪。這類夾爪會把手指內部分成數個小氣室，藉由調節充氣與排氣程度使其彎曲，或採用稱為鰭條效應（Fin Ray Effect）的結構。其支撐件像魚鰭一樣斜向交錯，按壓一側時，另一側便會自行彎曲包住物體。這種手指不論面對圓形或凹凸不平的果實，都會配合表面形狀自行改變外形，使力量不集中於指端一點，而是廣泛分散，從根本上減少果實受損。手愈柔軟，機器人便愈接近一個乍聽矛盾的目標，即使握得更用力，也能讓果實少受傷。

手再柔軟，沒有視覺與觸覺也沒有用。機器人必須同時知道果實的精確位置、應從哪裡切斷果梗，以及指端目前承受多少力量。其中負責觀察位置的是同時拍攝色彩與深度的RGB-D相機（Intel RealSense D435i、D405，Microsoft Kinect v2等）、立體相機與三維雷射掃描器。從彩色畫面讀取果實的成熟度與質地，再疊合深度資訊形成點雲，便能在機械手臂座標系中計算果實的前後、左右、上下位置，以及圓潤程度與體積。採收洋菇時，三維掃描器會量測菇傘的直徑與高度，留下小於既定出貨規格的菇，只挑選完全長成的菇採下。

用眼睛找到位置後，下一步便是指端的感覺。貼在手指內側的薄膜壓力感測器、回讀馬達受力的扭矩感測器、超音波距離感測器、讀取精密位置的23位元編碼器，以及量測氣壓與液壓的感測器會成套運作。壓力感測器即時監控手指施加於果實的力是否超過作物可承受的極限，超音波感測器則捕捉果實在手中微微滑動的瞬間，立即重新調節馬達力量。當果實被茂密葉枝構成的樹冠遮蔽時，指端會加裝一部小型相機形成手指視覺，或啟動一邊移動手臂位置一邊重新拍攝的視點重新規劃功能。手臂靠近途中若視線受阻，機器人便立即改變角度，再次尋找未被遮蔽的縫隙。

找出果實位置與切割點的眼睛由深度學習偵測模型擔任。YOLO（You Only Look Once）系列的最新版本YOLOv8、YOLOv10與YOLOv11廣泛使用，針對番茄調整的LampCT-YOLO模型則以YOLOv10為骨幹，加入名為SegNeXt的注意力技術。這項技術用於分割，也就是逐像素沿著照片中物體邊界描繪並裁切，使模型即使面對溫室內葉片交錯的凌亂背景，也會更加重視顯示番茄成熟程度的色彩訊號。再加入LAMP剪枝技術降低運算量後，即使沒有昂貴伺服器，也能直接在現場的小型控制裝置運作。尋找精確切割位置時，系統會同時使用Swift Transformer V2模型與依像素塊形狀進行修整的傳統形態學影像處理，分別切分果實、萼片與果梗。

完成訓練的模型必須在裝於手臂旁的小盒子裡運作，而不是在占滿畫面的筆記型電腦上運作，才有實際用途。研究人員把以ONNX或TensorRT格式輕量化的模型移植到NVIDIA Jetson Xavier NX、AGX Orin、Raspberry Pi 5、OMRON PLC等現場控制器。配備這些設備的機器人辨識並採下一顆果實所需的時間，也就是採收週期，會依作物與手的形狀而異。以SCARA手臂採收洋菇時，每顆不到10秒；採收蘋果的MARS 3.1每支手臂採一顆果實需要7至9秒，草莓需要4至11秒，柳橙約需7至11秒。

機器人的能力可用幾項數字衡量。相機辨識果實與果梗的準確程度以平均精確度（mAP）表示，偵測位置與實際位置的偏差則以公分為單位量測。然而，對在田間工作的人而言，真正重要的是其他數字。包括嘗試中實際成功採下果實的比例、採下後表面受損的果實比例、顯示手指包覆果實表面多大範圍的包覆率，以及抓握力是否處於各作物規定的安全範圍。草莓的安全抓握力為8至12牛頓，柳橙接近80牛頓，柑橘為6至8牛頓。想像指尖輕壓一顆蘋果的力量與緊握孩子手掌的力量之差，就能估量其大小。是否避免枝條或果梗不必要折斷的保存率也會一併記錄。

番茄外皮柔軟，但果蒂與果實連接牢固，因此必須在壓破與拉不下來之間決定手的形狀。由矽膠Dragon Skin 30製成的三根手指、內含四個氣室的柔性夾爪，會注入以遺傳演算法求得的28.293千帕氣壓，包住果實進行抓握。遺傳演算法是一種先試製多種組合，再把其中表現良好的組合重新混合，逐步接近最佳答案的運算方式，無須由人逐一手動調整數值。以這種改良後的手抓住番茄放置超過9天，也完全沒有腐壞痕跡；在實際移動採收的試驗中，每100顆約有97顆成功。

另一種方式直接模仿人的手部動作。以三根手指抓住番茄旋轉扭動360度，便會像人在餐桌上摘番茄時下意识做出的手腕動作一樣，不損傷果梗，只讓果實脫落。若採用直接切斷果梗的方式，Swift Transformer V2模型會找出精確切割位置。搭載LampCT-YOLO、沿著溫室軌道往返的巡檢型採收機器人，能立刻把成串生長的串番茄成熟度分成綠色、橙色、紅色三個階段，整天穿梭於溫室之間。

草莓果肉柔嫩，稍微受力便會瘀傷或潰爛。因此，設計方向比任何作物都更著重縮小接觸面積與力量。只使用兩根手指而非三根的柔性矽膠夾爪，會把接觸草莓表面的面積降至最低，僅施加8至12牛頓的微小力量。再加入結合迴歸分析與A*搜尋的路徑計算方式，手抓住果實的位置準確度會提高15%，手臂移動距離則縮短11%。也有完全不碰果實本體的方法。相機找出果柄位置後，剪刀形指端只切斷果柄，同時夾住切下的果柄，送到收集箱。

採用吸附方式時，把深15毫米的柔軟吸盤貼上草莓表面，產生2.38牛頓的吸力。此時果實實際承受的壓力僅達草莓果肉耐受極限的20%至31%，因此能在不受損的情況下採收。這類手部技術已走進真實田間。以色列農業科技公司DailyRobotics自2026年4月起，在美國加州農場部署露天草莓採收機Q2。這部機器配備兩支機械手臂與柔軟

夾爪，摘下草莓後立即放入稱為clamshell的透明包裝盒。公司表示，其速度比人快2至3倍。

洋菇栽培場的層架以250毫米以下間距堆成數層，沒有讓手臂向上抬升的空間。以SCARA結構解決這項問題的低背型採收機器人，組合一條垂直升降軸與兩個左右旋轉關節，讓手臂保持低姿態，像平放般伸入層架之間。垂直軸同時裝有稱為波動齒輪的精密減速裝置、皮帶與平衡重量的配重，幾乎消除晃動，並把定位誤差控制在1毫米內。三維掃描器先量測菇傘直徑，只用吸盤或柔性夾爪採下符合既定出貨規格的菇，整個過程每顆洋菇不到10秒。

一棵蘋果樹上的果實前後分成多層生長，單靠一支手臂無法觸及內側深處的果實。分別控制兩支手臂的MARS 3.1從兩側同時伸入樹冠表面內側的淺層區域，每支手臂採一顆果實僅需7至9秒，同時把果實瘀傷率壓到1%以下。一支手臂採收前側枝條的果實時，另一支手臂會直接深入內部果實，以此節省時間。在指端同時加入鰭條效應結構、馬達扭矩回饋與超音波滑動偵測的試驗中，也曾得到把損傷率降至0%的結果。

柳橙外皮厚而堅韌，反而屬於可以施加較大力量的作物。把三指矽膠夾爪設計為最高可施力80牛頓，再加入A*路徑搜尋，手臂移動距離會縮短14%，抓握位置準確度提高12%。小黃瓜則相反，表面凹凸不平、曲度大，單一吸盤很難無縫貼合。以摺紙方式形成皺褶的吸盤，藉由內凹彎曲的曲面結構配合小黃瓜表面自行摺疊與展開，將吸附半徑擴大到10.66毫米，並在田間達到86.2%的採收成功率。每種果實的外皮厚度與曲度都不同，認為一種指端就能採收所有作物仍為時過早。

這類指端技術已離開實驗台，進入真實農場的日常工作。日本的小番茄採收機器人在現場歷經近3年修正與改良，截至2026年4月，一部機器每天能自行採收31公斤。在商業農場固定配置果菜類採收機器人並持續運轉的案例，即使放眼全球也很少見。日本新創公司inaho製造的零食番茄採收機器人採取不購買而租用的服務模式，讓農場無須投入鉅資，也能減少逾45%的人力需求。2026年，試用這類租賃機器人的農場只有五座，但同年TTA-ISO推出幾乎不需人手的全自動番茄採收機器人，即將交付首部產品。草莓領域也已公開彙集田間實測果實位置與方向的資料，使多個研究團隊能用相同標準比較各自機器人的能力。機器每天自行完成固定採收量的案例，顯示果菜類採收機器人已越過試運轉階段，進入實際營收與人力成本的計算。

指端技術雖已精密到這種程度，要完全取代人手仍有幾道障礙。在葉片、枝條與果實層層重疊的不規則樹冠內，單靠一部相機很難毫無遺漏地找出果實中心與果蒂位置。視野一側受阻時，手臂可能撞上不該碰的地方，或直接略過沒有看見的果實。必須進一步改良從多個視點疊合點雲的技術，以及依遮蔽程度自行改變角度的主動拍攝技術，才能降低這道障礙。

柔軟手指也有待解的課題。矽膠柔性夾爪雖然很能避免果實受損，但充排氣的反應速度慢，抬起重果實的力量有限，使用時間一長，材料本身還會鬆弛或龜裂。平時柔軟包覆，僅在抓握瞬間把顆粒聚集並暫時硬化的結構，也就是可變剛性方式，被視為解決這項問題的線索。把咖啡粉裝入袋中抽掉空氣，袋子就會變硬。多地研究正把這項原理直接移植到手指內部。如何解開這組矛盾，很可能成為未來幾年衡量採收機器人公司排名的尺度。

價格也是阻礙。配備精密減速機、三維感測器與多具馬達的採收機器人，單機價格對小型農場而言難以輕易負擔。此外，田間或溫室中的灰塵、震動與濕氣容易弄髒感測器，零件也經常故障。必須建立可整組更換零件的標準規格，以及能在現場立即維修的體系，這項技術才可能廣泛普及。

最後一項課題，是讓人能看懂機器人為何做出這種判斷。不只要在控制器內毫無延遲地整合影像、深度資訊與指端壓力訊號，還必須具備把機器人為何抓住該處、為何施加該程度力量，以畫面呈現給栽培者的技術。這類技術稱為可解釋人工智慧，也就是XAI（Explainable AI）。有了這項解釋，農民才能相信機器人的判斷，把整片田地交給它。無論指端力量控制與視覺辨識能力多好，如果沒有一扇讓人看見判斷過程的窗，機器人仍然只是陌生的工人。

把六種作物並列來看，指端設計的方向分野清楚。草莓與番茄的外皮脆弱、市價高，優先發展的是氣室與吸附等輕柔處理的指端；柳橙外皮厚，一般力量難以撼動，隨後發展的是能施加充足力量的指端。小黃瓜雖常見，表面卻凹凸不平，吸附本身很困難，因此較晚才出現摺紙結構等另類解法。人類用指尖感覺自然分辨並完成的工作，在機器人身上卻依作物分成截然不同的設計圖。

並聯式機械手臂低懸在紅花田上快速往返，每當指端掠過，一把把細絲般的花絲便隨之消失。即使能用眼睛找出果實、用指端估量力量，如果選錯先採哪一顆的順序，手臂便會折返已走過的地方，白白耗費時間。決定順序的功能相當於機器人的頭腦，而這項問題在紅花田裡最為突出。一朵紅花密集聚集25至31根細花絲，機器人不能看到哪裡就跟到哪裡，而必須事先畫出繞行全部目標一圈的最短路徑。借用稱為旅行推銷員問題（TSP, Traveling Salesman Problem）的最短路徑計算方式，以強化學習訓練的指標網路接收花絲位置後，透過對鄰近目標賦予較高權重的運算，立即重新排定拜訪順序。並聯式機械手臂依照這項順序，以結合吸入裝置的指端收集花絲，移動距離比毫無順序地逐一追隨眼前目標縮短11.5%至20.17%。

草莓與柳橙先前提到的路徑改良，也源自相似的計算。決定機械手臂下一步移往何處時，系統會同時考量相機對眼前果實的信心程度、指端採用何種夾爪，以及接近角度偏斜多少。把這些數值輸入以迴歸分析預先調整的算式，就能估算下一步所需成本，A*路徑搜尋再根據估值畫出實際路徑。系統會繞過信心度低的方向，避開容易傷及指

端的角度，預先彎折路徑，使指端盡量以接近九十度的正角接近果實。這只是把人憑目測學會的訣竅轉成計算，卻明顯減少了手臂迷失方向的時間。

相機要獲得上述信心，必須事先練習。若直接用原始照片教學，機器人只會辨認晴天從正面拍攝的樣子。因此，訓練照片會被刻意擾動。研究人員旋轉照片、提高或降低亮度，並混入細小雜訊，讓模型預先經歷葉片間的陰影與陰天的昏暗光線。多張經過這種處理的照片採用稱為Adam的學習方式訓練後，機器人走進田間，即使遇到陌生角度與陌生光線，也不容易慌亂。

衡量這套頭腦與指端的能力時，不能只看視覺準確度。系統會分別採用寬鬆與嚴格標準，觀察相機能否穩定命中，也以決定係數與誤差率分別評量迴歸分析所得路徑預測值與實際路徑的吻合程度。現場小型控制器看完一張照片到給出答案所需的時間，以及每秒可處理幾張照片，也要一併量測。路徑縮短多少、時間節省多少的百分比數值同樣必須並列記錄，才能比較不同機器人的能力。

論文裡的數字與田間實際感受到的數字分屬不同層次。包覆率提高幾個百分點，或路徑縮短十幾個百分點，只顯示在相同條件下相較於先前方式的改善幅度。試驗田的畦距與照明由人預先調整，真正的農場卻不會如此配合。每天採了幾公斤、人力減少幾個百分點，都必須把機器人放在真實農場連續運轉多日後，才能得到數字。目前公布的案例中，能把這兩個層次的數字並列提出的機器人並不多。

草莓資料集除了位置，還記錄傾斜方向，自有其原因。只知道果實在哪裡還不夠，還必須知道果蒂朝向何方，指端才能以正角接近，在不傷害果梗的情況下採下果實。若從多座田區蒐集這種姿態資訊並公開，新加入的研究團隊便可省去從頭重新拍照蒐集的工夫，直接測試指端設計。

採收機器人不買而租的模式，也是由這些情況促成。這項構想是為了減輕一次買下整部搭載精密減速機、三維掃描器與運算裝置機器人的負擔。然而，每次把機器人搬到新田區，情況又會不同。各農場的溫室結構、栽培方式與株距不同，因此每次都必須重新校準相機，再次量定指端力量。毫無損傷地摘下一顆果實的能力，與把這項能力原封不動移植到另一座田區的能力，是兩項不同的課題。

從擁有田地的人立場看，計算方式一目了然。在難以找到人力的採收季，先租一部機器人運轉幾天，若損傷率與每日採收量可以接受，下一季再增加數量。能在買下之前先於自家田地測試，是它與過去必須一次決定是否購買一部昂貴機器最大的不同。

如此費心訓練的模型，一次仍只能辨認一種作物。能精準分辨番茄成熟度的眼睛，一旦帶到草莓田，就必須從頭學習。為避免傷害草莓柔嫩果肉而設計的指端，如果移裝到蘋果樹上，很容易漏接沉重果實。人類在不同田區間移動時，會自然調整視覺與手部感覺；機器人每換一種作物，就必須重新教導眼睛、重新塑造指端。若要接近能往

返多種作物間工作的真正工人，還需要一項技術，讓各作物分別打造的眼睛與手整合在一起後，仍能立即在不同田區發揮能力。

如果改良視覺與指端是過去幾年的課題，那麼裝上能自行決定作業順序的頭腦、以相同標準衡量成果，以及把在一種作物與一座田區學到的能力轉移到另一種作物與另一座田區，則是才剛開始的課題。在紅花田驗證的計算法能否同樣適用於草莓溫室或蘋果樹間，未來幾年的現場試驗將給出答案。指端、視覺與頭腦目前各自在不同作物與不同田區接受驗證，將這三項要素整合進同一部機器人的工作仍未完成。

資料來源與參考文獻

學術論文

1. Feng, K. (2026). 果蔬採收末端執行器的結構形式與作物適應機制. *Automation and Machine Learning*, 7(2), 60-67. DOI: 10.23977/autml.2026.070207.
2. Zeeshan, S., Malik, M. A. I., et al. (2025). 透過基於深度學習的感知、夾爪配置與果實形態計量進行機器人果實採收的資料驅動軌跡最佳化. *Engineering Research Express*, 7, 045210.
3. Minorowicz, B., Patalas, A., & Łuczak, A. (2026). 菇類採收SCARA機械手臂設計. *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：以DEMA注意力增強強化學習，用於紅花採摘機器人的序列最佳化. *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). 結合LAMP通道剪枝的改良YOLOv10 番茄成熟度偵測演算法. *Smart Agriculture*, 8(2), 133-146. DOI: 10.12133/j.smartag.SA202507045.
6. Moldvai, L., & Nyéki, A. (2025). 番茄 (*Solanum Lycopersicon*) 偵測與栽培的創新電腦視覺方法：綜述. *Discover Applied Sciences*, 7, 975. <https://doi.org/10.1007/s42452-025-07613-x>

演講與影音資料

1. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026全球農食創新巡迴展啟動活動暨首場巡迴展. YouTube. https://www.youtube.com/watch?v=U5CReIR_Rrg
2. World AgriFood Innovation Conference (WAFI). (2026). 澳洲農食創新 | WAFI2026全球農食創新巡迴展. YouTube. <https://www.youtube.com/watch?v=ITnVRq1Tioo>
3. C-DAC. (2025). 農業人工智慧：改造印度農業版圖. YouTube. https://www.youtube.com/watch?v=IV3_VnWiBpM
4. Street Science with Fun. (2025). AI/ML驅動的芒果偵測與採收機. YouTube. <https://www.youtube.com/watch?v=Dy3xDC8rElw>
5. Department of ECE, MGR Educational and Research Institute. (2025). 專家講座：電腦視覺在智慧農業自主導航中的作用概述. YouTube. <https://www.youtube.com/watch?v=GVZ46DY2Tao>
6. UC Agriculture and Natural Resources. (2025). 2026農業機器人挑戰賽：IP 101. YouTube. <https://www.youtube.com/watch?v=JA1greBXSoA>
7. HortiQD. (2026). HortiQD第4場網路研討會：資料橋梁，連結農民與機器人，打造更智慧的農業. YouTube. <https://www.youtube.com/watch?v=7W8NbMdhuss>
8. Farm Foundation. (2025). Farm Foundation論壇：為農業韌性未來而自動化. YouTube. <https://www.youtube.com/watch?v=aWWqVnNkhoQ>

新聞與線上資料

1. AgFunderNews. (2026). DailyRobotics準備於2026年在加州商業推出草莓採收機器人. AgFunderNews.
<https://agfundernews.com/dailyrobotics-gears-up-for-commercial-launch-in-california-in-2026-with-robotic-strawberry-harvester>
2. HortiDaily. (2026). 日本農業科技新創公司讓小番茄採收機器人投入常態生產. HortiDaily.
<https://www.hortidaily.com/article/9842754/japanese-agri-tech-startup-puts-cherry-tomato-harvesting-robot-into-routine-production-use/>
3. HortiDaily. (2026). 零食番茄採收機器人已具備商業化條件. HortiDaily.
<https://www.hortidaily.com/article/9778303/harvest-robot-snack-tomato-commercial-ready/>
4. Future Farming. (2026). TTA-ISO推出全自動番茄採收機器人. Future Farming.
<https://www.futurefarming.com/tech-in-focus/field-robots/tta-iso-introduces-fully-automated-tomato-harvesting-robot/>
5. arXiv. (2026). [草莓採收機器人用田間實測6D姿態資料集與基準模型預印本]. arXiv:2606.11381.
<https://arxiv.org/pdf/2606.11381>

2.2

自主移動機器人與無人機群的路徑最佳化和精準防治

海利奧採用由一名操作員同時監督三架無人機所組成機群的方式，獲得美國聯邦航空總署核准。此時，操作員手上拿的不是直接操控無人機的搖桿，而是能在同一個畫面上顯示多架飛行器狀態的螢幕。該公司推出的HYL-150 ARES可搭載約50公斤藥劑，每小時為超過20公頃的面積進行施藥；XAG P150則具備利用人工智慧自行辨識障礙物的偵測功能。多架無人機自行劃分區域並協調方向與速度，這類核准案例的背後，是由機器代替人類計算複雜到無法逐一規劃的路徑。

這與機器手臂末端的手指精準握住果實，是另一個截然不同的問題。手再靈巧，如果無法決定要按什麼順序、從哪裡開始移動，機器人仍會兩度走過同一條畦溝，或先在遠處徘徊，最後把電池耗盡。散落在田區裡的果實、雜草與花絲並不會整齊排列成行。原本被樹枝擋住而看不見的果實，可能在機器人向旁邊移動時突然出現；風吹動葉片後，剛才還看得見的果實也可能再次被遮住。郵差面對一天要投遞的二十戶人家，規劃最短路徑的問題稱為旅行推銷員問題；農場機器人與無人機則必須在不只包含平面、也包含高度的立體空間中解決這個問題。因此，這項任務稱為三維旅行推銷員問題，英文3D Traveling Salesman Problem，簡稱3D-TSP。當目標點超過二十五個、三十個時，可能的組合會在轉瞬間激增；遺傳演算法等長久以來使用的搜尋方法，不是耗費過多時間計算，就是經常停在並非真正最佳的答案上。

在強化學習出現以前，並非沒有人嘗試解決這個問題。模仿螞蟻覓食時彼此追隨氣味軌跡習性的蟻群演算法，以及仿效鳥群結隊飛行的粒子群演算法，都曾被使用。這類方法從昆蟲或鳥類的群體行為借用規則，確有其說服力；然而，一旦目標點增加、障礙物隨時出現，實際田間的機器人就必須漫無止境地停在原地，等待計算完成。強化學習不遵循預先訂好的規則，而是從無數次嘗試中自行找出規則；它接手這項工作，一個很現實的原因在於，每塊田、每個季節的條件都不同，人類不可能逐一重新編寫規則。

重新解決這個問題的方法，是把強化學習與指標網路結合起來。強化學習不會事先提供標準答案，而是為自行嘗試的結果評分，讓模型逐步進步。指標網路不會憑空產生下一個目的地，而是像用手指指向目標一般，從已輸入的座標中挑出一個。兩者結合後的架構，可以比喻為演員與評論家。稱為Actor的神經網路擔任演員，逐一提出下一個要造訪的座標順序；稱為Critic的神經網路則扮演評論家，預先評估這項提議整

體上會成為多有效率的路徑。演員參考評論家的評分，一點一點修正下一次提議；這個過程重複數千次後，逐漸練就挑選更短路徑的能力。

為了讓判斷更精細，系統還加入幾項機制。多頭自注意力讓每一個座標同時比較自己與所有其他座標有多近、位於哪一個方向；距離編碼則事先以數值計算座標之間實際的歐幾里得距離，再把結果交給神經網路當作參考資料。再加入動態指數移動平均，英文縮寫為DEMA，就能對最近走過的路徑給予更高權重，逐漸淡忘較久以前的路徑，持續更新判斷。AC-RL-PtrNet模型是這項組合的實際案例，它在中國開發，並實際搭載於菊科作物紅花的採收機器人。此模型使用長短期記憶，英文縮寫為LSTM，讀取輸入的三維座標序列；Critic神經網路則加入層正規化與殘差連接，避免學習過程失去穩定。為減少計算量，LSTM的閘門與全連接層採用結構化剪枝，像修剪樹枝一樣剪除不必要的連接，在縮小模型的同時，避免判斷準確度大幅下降。

搭載這個模型的採收機器人，曾在中國新疆地區的實際紅花田進行現地試驗。這部機器人採用多支手臂並排的平行架構，將一條路徑切分成數個區段，由各支手臂同時負責，以提高作業速度。試驗在種植油紅1號與雲紅5號兩個品種的田區進行，條件為二十五個目標點。把遺傳演算法與這個模型並列測試後，路徑長度縮短9.56%，作業時間減少5.43%。當目標點增加到三十一個、條件變得更密集複雜時，差距進一步擴大，路徑長度縮短20.17%，作業時間最多減少29.70%。這可以解讀為，目標越多、彼此越糾結，學習所得的判斷就比人為決定的順序帶來更大的差異。

路徑最佳化並不只是在決定造訪順序。整平田地的地形整平作業，或設計移動路徑本身的領域，會採用近端策略最佳化，英文縮寫為PPO的強化學習方法。PPO不會一次大幅改變策略，而是每次只做小幅修正，避免學習突然崩潰。使用這項方法，可以同時朝縮短移動距離與減少必須挖起搬運土方量的方向規劃路徑，讓機器人減少移動並延長電池使用時間。整平土地與在土地上往來，看似是兩個不同的問題，最後卻都能在同一套強化學習架構中一併解決。

路徑規劃得再好，機器人若不知道自己的精確位置，仍然沒有用。地面自主行駛機器人搭載RTK-GPS，以基地臺訊號校正衛星導航系統的誤差，將定位誤差壓到2公分以下；並以測量雷射往返時間的光達，以及在彩色影像之外加入距離資訊的RGB-D相機，立體描繪周遭地形。把兩部立體視覺相機並排後，可以利用兩個視點的視差獲得距離感，進而把果實或莖的位置，從相機所見的座標轉換為機器手臂運動的座標。超音波距離感測器則負責在機器人於畦溝盡頭轉向，或視線受阻的瞬間，防止它撞上其他障礙物或翻覆。

自主行駛機器人的機身內，還密集裝著許多需要細心照料的小型感測器。測量12伏特電池電壓的感測器即時顯示剩餘電量；電磁閥控制器則像守門人，憑一道電氣訊號開關噴嘴。裝在永磁直流齒輪馬達上的編碼器，計算車輪轉了幾圈，再反推機器人實際

移動了多遠；測量氣壓與水壓的感測器則監視噴灑裝置內部壓力是否超出規定範圍。路徑再精細，如果這些不起眼的感測器沒有各司其職，計算出的數字就無法化為實際車輪與噴嘴的動作。

天空中的無人機，補上地面爬行機器人遺漏的部分。從無人機連續多日拍攝的多光譜影像取得的植生指數，也可用來找出罹病葉片，但此處的用途不同。把同一項指標疊加讀取整片田地後，就能製作處方圖，英文稱為Prescription Map，在各區顯示雜草聚集的機率。這張地圖會配合雜草生長速度，每隔數日重新繪製以維持最新狀態。無人機拿到這張地圖後，接著就要決定實際應沿著哪一條路線飛行。

以像素為單位細密分辨作物與雜草相接邊界的工作，由能同時讀取脈絡的雙分支卷積神經網路負責。邊界確認後，稱為AWTPO的階段使用改良型戴克斯特拉演算法，從多個候選路徑中找出能少用燃料、電池與攜帶藥劑重量的路線。戴克斯特拉演算法原本是一種古老的尋路方法，用來在行經多個車站的地鐵路線中找出最快轉乘路徑；在這裡，它把車站換成田間座標，把轉乘時間換成燃料與電池耗用量，再用相同方式計算。無人機沿著這條路線飛行，只在通過雜草叢生區段時打開噴嘴施藥，整套系統就此完成。

噴嘴前另裝有一雙眼睛，能即時測量雜草叢的大小。雜草聚集面積超過1.5平方公尺時，稱為VRMDWN的變量微噴灑裝置便會啟動。噴灑粒徑可在100微米至400微米之間調整，噴灑量也會在每分鐘0.12公升至0.35公升之間同步改變。雜草密集聚集處噴出較粗、較多的藥液；稀疏處則噴得較細、較少。藥劑噴完後，工作仍未結束。防治完成後第7天、第14天與第28天，系統都會再次拍攝影像，與過去的復發紀錄疊合比較。PTWRP階段利用這些資料，以稱為Q-learning的強化學習方法，預先判斷哪些位置較可能再次長出雜草。

預測雜草再次萌發的位置，不像防治本身那麼顯眼，實際效益卻不小。如果沒有預測，栽培者即使完成防治，仍必須每隔幾天重新巡視整片田地，親眼確認雜草是否再生。PTWRP產生的預測圖把需要回頭查看的範圍縮小到幾個區域，大幅減少下一次無人機飛行或人員巡查所需的時間。防治作業的性質，也從一次完成的一次性工作，轉變為反覆進行預測與確認的循環。

要讓無人機與地面機器人找到正確路徑，必須先把不同感測器以各自方式測得的位置對齊至同一基準。衛星導航系統提供的經緯度、光達與相機讀取的機器人相對座標，以及機器手臂運動的關節座標，各自具有不同的原點與方向。這些座標必須經過座標系統轉換，疊合到同一張田地圖上，無人機找出的雜草位置，才不會與地面機器人實際開啟噴嘴的位置錯開。只要這項對齊稍有偏差，費心計算出的最佳路徑也會成為走過錯誤畦溝的白費功夫。

這套系統曾在真實麥田進行試驗。在一塊12公頃的商業小麥田中，從種子發芽到抽穗前的90天內，無人機持續拍攝影像並運行這套系統。AWTPO規劃的飛行路徑把無人機飛行時間縮短至17.5分鐘；VRMDWN的標靶噴灑則把除草劑用量降到每公頃0.68公升，比傳統全面噴灑減少32%。免於遭雜草奪走的產量增加18%至22%。相較於對整片田地噴灑相同藥量，只在需要的位置施放精確藥量的方式，顯然在除草劑用量與產量兩方面都造成明確差異。

路徑只縮短幾分鐘，數字看似不大，在田間累積起來卻完全不同。機器人一天能工作的時間，取決於電池容量與日照時數；每一趟往返省下的時間，到一天結束時，就會變成多巡走幾條畦溝的餘裕。一個人一天能監督多少機器人與無人機，最後也取決於這份餘裕；路徑越短，就越能以相同人力管理更廣大的農場。緊急轉向或不必要地反覆經過同一區段的動作減少後，人與機器人在同一田間工作時的碰撞風險也會隨之降低。

單架無人機的精密判斷，延伸到多架無人機成群行動時，才能真正展現力量。若由一架無人機獨自從頭到尾巡查廣大田地，往往會有一些區域還來不及飛完，電池就已耗盡；多架無人機分區同步飛行，則能在相同時間內巡查數倍面積。進入2026年後，防治無人機正擺脫只有少數農家使用的特殊設備定位，轉為搭載大容量藥箱與人工智慧、廣泛普及的主流設備。由Pegasus Robotics經銷的XAG P150，利用四具旋翼產生的下洗氣流均勻散布藥劑，並具備人工智慧偵測功能，可自行辨識1.5公尺至90公尺範圍內的障礙物。海利奧推出的HYL-150 ARES則是一款以集群飛行為重點的飛行器，可搭載約50公斤藥劑，每小時為超過20公頃的面積施藥。這類集群飛行之所以可行，是因為每架無人機都以機載電腦互傳訊號，協同使用多光譜相機、噴灑藥箱與衛星導航訊號。海利奧採用由一名操作員同時監督三架無人機所組成機群的方式，獲得美國聯邦航空總署核准；依此方式，一個人一天可以巡查數千英畝的田地。無人機自行劃分區域並協調方向與速度，這類核准案例顯示，由一個人同時監督多架飛行器的集群飛行，已經在現場實際運作。

人與機器人在同一片田地共同工作的時間也在增加。當無人機低空飛行進行防治時，如果有人位於同一條畦溝，超音波感測器與視覺相機持續偵測其動作，降低速度或改變路徑。目前由一名操作員同時監看多架無人機或機器人的方式，會把多架飛行器的狀態一併顯示在單一畫面上；其中任何一架出現異常時，不漏看訊號便成為監督人員的新任務。機器自行決定路徑的情況越多，人的角色似乎就越會從直接操控的雙手，轉為環顧全局的雙眼。

在樹木上下密集交錯的果園裡，地面機器人往往比無人機更普遍。電動自主行駛噴灑機器人OrcBOT以RTK-GPS與立體相機同時讀取自身位置與樹形，並以YOLOv5神經網路即時判斷茂密葉片所構成的樹冠是否存在。中央電子控制裝置依據這項判斷分別

開關左右噴嘴，在沒有樹木的空白區段完全不噴藥。系統另加入10千伏特電壓，使噴灑粒子帶上靜電；就像冬天脫下毛衣時頭髮黏在毛衣上一樣，帶電粒子會深入葉片背面或樹枝內側並附著其上。傳統噴霧機容易讓藥劑只落在迎風面的葉片正面，直接略過後方；帶靜電的粒子則多了一股吸引附著的力量，無論葉片朝向哪個方向，都會被吸過去。

這部機器人在土耳其安卡拉大學農學院果園進行實際試驗，已取得結果。噴灑粒子的直徑介於150微米至167微米，符合美國農業工程師學會訂定的細粒徑規範ASAE S572.1。葉片表面附著藥劑的比例，也就是樹冠覆蓋率，平均為55%，最高達57%。與傳統牽引機噴霧機相比，藥劑使用量減少49%至72%，且經統計確認，這項差異很難視為偶然。由人工駕駛牽引機噴灑時，每小時作業成本為19.70美元；改由機器人執行後，降至每小時0.76美元，減幅接近95%。

以公頃為單位廣闊延伸的麥田雜草，與果園裡一棵棵樹上的病蟲害，連應噴施藥劑的形態都不相同。VRMDWN只挑選田間零星散布的雜草叢噴灑，目標小而目標之間完全留白；OrcBOT則必須像包覆整棵樹一樣噴灑，目標較大，且藥劑必須在目標內均勻觸及葉片背面。面對雜草，關鍵在於用地圖精確分辨它們位於何處；面對樹木，關鍵則在於讓藥劑多均勻地進入位置已知的樹冠內部。兩項技術表面上都屬自主防治，實際要解決的問題卻各有不同面貌。

自主行駛技術不只進入大型農場，也開始走進小塊田地。一部由PIC微控制器驅動的小型機器人，只要更換模組就能執行多種工作。裝上250公克的種子箱，可按固定間距一次播下一粒種子，進行精準點播；裝上500毫升的通用幫浦噴嘴，可只在需要的位置標靶施藥；裝上低碳鋼製成的薄刀片，還能在植株之間往來，以機械方式除草。只憑一顆電池與一個微控制器，就能完成這三項工作的迷你機器人，正成為無力購置大型農機的小規模農家可選擇的替代方案。

所有這些神經網路在進入田間前，都會先在PyTorch或TensorFlow等平台上，以Adam或AdamW最佳化方法完成訓練。訓練完成的模型會轉換為ONNX或TensorRT格式，移植到NVIDIA Jetson Xavier NX、Jetson Nano、Raspberry Pi 5，或工業用PLC控制器等手掌大小的裝置上，以輕量化型態重生。實際求解含有二十五個至三十一個目標點的三維旅行推銷員問題，所需時間不到數十毫秒，因此幾乎感覺不到機器人停下來等待計算的時間。無人機以每秒5公尺飛行並進行防治時，也會同步執行運動規劃，事先把噴嘴開關所需的短暫延遲計算在內。

這套系統是否真的實用，要以多項指標一併衡量。路徑比傳統演算法縮短多少的路徑縮減率、作業提早多少完成的作業時間減少率、邊緣裝置計算路徑所需的延遲時間，以及節省多少電池與燃料的能源節省率，是評估機器人與無人機本身動作的指標。在此之外，還會加入每公頃除草劑減量、樹冠覆蓋率、噴灑粒徑、作物與雜草邊界的誤

分類率、保住的產量比例，以及預先判斷防治後雜草再生準確程度的復發預測準確率，用來顯示系統是否為農作帶來實際利益。相機區分雜草與作物的能力，要用幾個數字再次確認，其中檢視模型標示的雜草區域與實際雜草區域重疊程度的IoU，類似把兩枚印章蓋在同一位置，測量彼此重疊多少；在多個閾值下測得精確率並取平均的mAP，則近似於在不同條件下重複蓋章多次後計算平均值。精確率是被判定為雜草者當中，實際確為雜草的比例，召回率則是實際雜草中沒有漏掉、成功找出的比例；把兩者合而為一的F1分數，負責辨別只偏重其中一方的判斷。這三層指標中，任何一項單獨表現良好，都不足以讓系統成為田間值得信賴的工具；路徑、防治與辨識三個輪子必須一同轉動，才能在現場奏效。

即使已有這些成果，前方仍有多道難關。到目前為止，多數結果都帶著一項限制，也就是成績通常只來自某一塊特定田地。在新疆紅花田學會的順序判斷，不能保證在樹距與地形截然不同的蘋果園裡仍然適用。作物高度、栽植間距與土地坡度一旦改變，最短路徑的形狀本身也會不同；只有累積更多涵蓋多種作物與地形的試驗結果，路徑最佳化模型才可能從特定田地的工具，走向能在多種田地通用的工具。

目前的三維旅行推銷員問題演算法與飛行路徑計算，大多假設田地平坦或整齊；在坡度陡峭或障礙物混雜的區域，常常無法直接適用。風速超過每秒4.5公尺，或遇到霧、雨與濃雲時，多光譜影像品質會下降，無人機飛行位置也可能出現約1公尺的誤差，導致誤判雜草位置，或把藥噴到錯誤的畦溝。現行作法必須挑選晴朗無風的日子作業；惡劣天候若持續，就有錯過防治時機的風險。在這類日子裡，仍需要人親自到田間目視確認，重新安排防治時間。

無人機與地面機器人的機身條件，也是造成限制的因素。試驗所用無人機最長飛行時間約22分鐘，藥劑載量也只有約1.2公升；若要不間斷巡查廣大田地，就會頻繁穿插更換電池與補充藥劑的時間。在人手動更換電池、重新裝滿藥箱的幾分鐘內，無人機只能放在田地一角，無法升空。為填補這段空檔，能在地面移動並更換電池的行動充電裝置，以及由無人機與地面機器人分擔不同任務、彼此合作的異質集群控制技術，正成為下一項課題。若把建置充電設施的成本納入計算，農場越大，首次導入這項技術的負擔也越不容忽視。只有建立一套讓空中與地面機器人分別承擔擅長工作，並自動銜接彼此作業的系統，這項技術才可能超越目前的試驗田規模，直接移植到遠為廣大的農場。

必須在田地中央處理複雜計算，也是阻礙之一。強化學習路徑計算或同時處理多項任務的視覺模型，運算量龐大；在以電池驅動的小型裝置上，判斷可能出現延遲。減少運算量的量化與剪枝，以及加裝NPU或FPGA等專用晶片的方法，持續被研究用來緩解這個問題。該在運算資源與準確度之間選擇什麼平衡點，最後只能依田地大小與作物價值，由每戶農家作出不同答案。

最後留下的是信任問題。強化學習模型為什麼選擇那條路徑，又為什麼只決定在那些位置施藥，栽培者目前仍缺乏親眼確認理由的適當方法。如果把Grad-CAM或SHAP等能以影像呈現判斷依據的可解釋人工智慧技術植入系統，栽培者就能自行判斷要直接遵循機器人的選擇，或重新檢視。再把每年的防治紀錄與雜草再生位置累積起來，回饋為知識，就可能追蹤土壤與雜草生態在數年間緩慢變化的趨勢。只有累積這份信任，才能從目前仍由人類蓋下最後確認章的半自主方式，轉向完全脫離人手的自主方式。

要讓這項技術擴散到廣大農場，還有幾項課題必須解決。建立讓栽培者親眼確認強化學習所選路徑與防治判斷依據的方法，以及縮短每逢電池與藥劑耗盡便出現的作業空檔，都是尚未完成的課題。在多架無人機互傳訊號並劃分區域的集群飛行中，訊號一旦中斷，各飛行器仍可能失去彼此位置，造成航路重疊或互相碰撞。現行監督方式由一名操作員同時查看多架飛行器的畫面，其實效取決於能多快察覺通訊中斷的飛行器，並讓它安全停止。

資料來源與參考文獻

學術論文

1. Adewumi, A., & Saraswat, D. (2026). 人工智慧與邊緣運算於精準雜草控制之綜合回顧. Artificial Intelligence and Applications. <https://doi.org/10.47852/bonviewAIA62028867>
2. Choudhari, A., Katkar, R., Gupta, M., Wathe, N., Kakde, S., & Poyam, P. (2025). 無人機智慧農業場景中自主精準雜草偵測、處理與復發預測之整合式時空深度學習架構設計. International Journal of Applied Mathematics, 38(2s), 1339-1366.
3. CropLife. (2026). 7款2026年值得關注的農業噴灑無人機. CropLife. <https://www.croplife.com/iron/sprayers/7-agricultural-spray-drones-to-watch-in-2026/>
4. Gerdan Koc, D., Koc, C., & Comakli, M. (2025). 人工智慧驅動的精準果園自主噴灑機器人. 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). 用於播種、噴灑與除草的自主農業機器人. 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：採用DEMA注意力強化序列最佳化的紅花採摘機器人強化學習. Smart Agriculture, 8(2), 200-219. <https://doi.org/10.12133/j.smartag.SA202506004>
7. Logeshwaran, J., et al. (2026). 結合視覺人工智慧的精準農業嵌入式無人機群. International Journal of Computer Applications, 187(115), 42-43.
8. The Robot Report. (2026). 無人機群：實際如何運作，以及哪些產業應該關注. The Robot Report. <https://www.therobotreport.com/drone-swarms-how-they-actually-work-and-what-industries-should-care/>

演講與影音資料

1. Food and Agriculture Organization (FAO). (2025). 與數位FAO及農業資訊學環遊世界：雪梨. YouTube. <https://www.youtube.com/watch?v=tbFEk73816U>

2. PhD Navigator. (2025). ICT研究的抽樣技術 | 農業用能源最佳化田間機器人. YouTube.
https://www.youtube.com/watch?v=jJerj_N7ALQ
3. World AgriFood Innovation Conference (WAFI). (2026). WAFI2026全球農食創新巡迴展啟動活動暨首場巡迴展. YouTube. https://www.youtube.com/watch?v=U5CRrIR_Rrg
4. 茶柱. (2026). 20260120 茶園智慧農業：川崎技研、落合刃物、寺田製作所. YouTube.
<https://www.youtube.com/watch?v=zmFbOC5RcJU>
5. 臉書李載榮. (2025). A88私密資策會衛星精準農業AI導入工作坊桃園AI衛星多光譜圖像與無人機應用. YouTube.
<https://www.youtube.com/watch?v=dtT3bafdKgw>
6. Trimble Geospatial. (2026). eCognition網路研討會：深度學習、無人航空載具與精準農業. YouTube.
<https://www.youtube.com/watch?v=alrseDYV8Lo>
7. Society of Precision Agriculture Australia SPAA. (2025). Grain Automate全國網路研討會：鋪設農場自主化之路. YouTube. <https://www.youtube.com/watch?v=nZnsWgvs6-g>
8. Agri Coaching Chandigarh. (2026). 2026數位農業任務 | 人工智慧、無人機、農業堆疊與智慧農業 | 時事. YouTube. <https://www.youtube.com/watch?v=al2rsTZBwMA>

第3章

智慧溫室與設施園藝環境控制（CEA）

3.1

基於物聯網的多感測器監測與智慧環境量測

全球部署的LoRaWAN低功耗物聯網裝置已遍及70個國家，總數超過1億2,500萬個，相關市場規模在2026年估計達142億5,000萬美元。美國內布拉斯加大學研究團隊報告指出，只靠即時監測土壤水分，就能將用水量最多降低35%。溫室內同樣需要密集量測。塑膠溫室的地面高度與視線高度之間，溫度可能相差三、四度，靠近屋頂處還會形成另一層高溫空氣。溫室支柱一側裝著一個手掌大小的白色盒子，裡面的溫度與濕度數值每隔幾秒就更新一次，這些數值決定當晚通風窗是否開啟、暖氣是否運轉，以及灌溉系統是否啟動。

溫室裡真正需要管理的並不只有氣溫。空氣溫度與相對濕度、二氧化碳濃度、日照量，也就是量測光合作用實際使用波段的光量，稱為光合作用光子通量密度，以及水耕養液的電導度與氫離子濃度、土壤或介質中殘留的水分、水槽水溫，若是儲藏庫，連乙烯氣體都會一起變動。這些數值並非各自獨立。打開通風窗降低溫度時，濕氣與二氧化碳也會同時逸散；開啟暖氣時，不只溫度上升，相對濕度還會急遽下降。增加供水會提高介質含水量，卻也可能連帶提高根部周圍的空氣濕度，助長黴菌形成。因此，溫室微氣候，也就是小空間內的氣候，不能被視為一次只控制一項變數的獨立開關集合，而必須當成多項變數隨時彼此牽動的非線性、時變耦合系統。

一旦這個平衡崩解，損害很快就會顯現。溫度只要偏離適宜範圍幾天，莖就可能徒長，花芽也可能掉落，而高濕度若持續整夜，葉片背面會凝結水滴，為真菌與白粉病病原菌繁殖創造有利條件。只要一次坐果失敗或病害爆發，就可能侵蝕整季收成。因此，光靠栽培者的直覺與經驗已不夠，密集部署在溫室各處的物聯網（IoT）感測器，必須與讀取數值並即時判斷的人工智慧運算配合。如果感測器是眼睛與皮膚，背後的運算就是衡量每一刻狀況並選擇下一步行動的判斷力。

問題在於，溫室裡若只有一個感測器，這項判斷便無法正常運作。通風扇正前方與溫室另一側角落的氣流速度不同，茂密作物冠層上方與下方陰影處的溫度也可能相差數度。靠近溫室牆面的邊緣與中央所經歷的氣候同樣不同。若把單一感測器的代表值當成整座溫室的數值，並據此決定加熱或通風，距離感測器較遠的區域就可能無人照料，導致作物徒長或萎凋。如何處理這種空間不均勻性，仍是溫室量測設計的核心課題。

實際裝進溫室的感測器清單相當長。空氣方面，DHT11與DHT22溫濕度感測器量測攝氏零下40度至80度、相對濕度0%至100%的範圍，旁邊還有WQX-TH溫濕度感測

器。水槽內放置DS18B20水溫感測器，WQX-L光量感測器量測0至157,286勒克斯的光照，WQX-R與UV感測器則量測每平方公尺0至2,000瓦的紫外線。土壤或介質中殘留的水分由FC-28或YL-69水分感測器量測，空氣中的二氧化碳濃度則由利用紅外線被氣體吸收程度的非分散式紅外線（NDIR）感測器負責。水耕養液中插入同時量測電導度（EC）與氫離子濃度（pH）的感測器；收穫農產品進入低溫流通時，還會另裝感測器偵測水果釋放的乙烯氣體。單一感測器的價格只有幾千至幾萬韓元，不算昂貴，但這些感測器聚在一起，就形成一張能讀取溫室全部呼吸的網。

供電方式是另一項決定感測器節點壽命的問題。在溫室屋頂或介質旁等難以另拉電源插座的位置，常使用配有小型太陽能板與蓄電池的節點，電路平時進入休眠，只在預定時間短暫喚醒、讀取數值，再重新休眠，因此一次充電便能運作數月。灌溉幫浦、通風扇等實際執行動作的致動器一開始就接上商用電源，只有旁邊的感測器節點以低功耗電池獨立運作。為了連傳輸所耗的電力也一併節省，讀值常先累積一段時間再整批傳送，而不是每次量測都立即傳輸，如果這項折衷沒有調整好，電池會比預期更早耗盡，感測器可能恰好在需要判斷的時刻停止運作。

溫室外也需要眼睛。把JNGW100氣象觀測裝置與WQX光譜感測器設在溫室外，就能每隔1分鐘取得外部空氣的溫度、濕度、露點與日射量。日本農業研究機構製作的網格農業氣象資料、WeatherAPI、美國國家航空暨太空總署的NASA POWER、聯合國糧食及農業組織的FAO CLIMWAT等海外公開資料，也會即時匯入，並把未來幾天的天氣預報值一併送入控制模型。光靠溫室內感測器無法事先知道寒流或熱浪將至，因此把外部氣象資料與室內感測器數值並列檢視，正逐漸成為理所當然的程序。哪怕只提前一小時知道何時應關閉通風窗，與等數值升高後才得知相比，都可能是決定作物命運的差異。

這些數字也不全來自空氣。所謂「會說話的植物法」（speaking plant approach），是讀取作物本身發出的訊號。將進入與離開溫室的空氣二氧化碳濃度差乘以氣流量，就能每5分鐘計算整片作物冠層透過光合作用吸收多少二氧化碳，以及夜間呼吸釋放多少二氧化碳。同樣地，把水蒸氣濃度差乘以氣流量，便能在不接觸任何一片葉子的情況下，估算葉片釋放的水量，以及葉面微小孔隙，也就是氣孔的開啟程度。如果溫度計是量測房間空氣的工具，這套方法便是把作物本身變成一部活的量測儀器。

感測器數值會經過好幾層傳遞。現場最前端使用STM32或ESP32、配有Wi-Fi的ESP8266模組，或讓Arduino Uno與Arduino Nano兩臺裝置分工的組合。Arduino Uno收集感測器數值並直接操作致動器時，旁邊的Arduino Nano負責與網頁伺服器通訊，並在顯示器上繪製圖表，這種分工能讓其中一側停止時，另一側仍可持續運作。溫室內的節點透過工業界長期使用的RS485有線方式，或ZigBee無線感測器網路交換數值，若要將數值送往中央伺服器或雲端，便依序使用4G DTU、GPRS、LPWAN與

Wi-Fi等通訊網路。如此一來，溫室現場的小型顯示器、辦公室電腦與栽培者的手機App，都能在同一時間收到相同數字。

在工業現場長期獲得驗證的RS485配線，能在不受濕氣或電磁干擾影響的情況下可靠傳送數值，但每次溫室配置改變時都必須重新拉線，相當不便。ZigBee等無線感測器網路不需要配線，適合栽培方式經常改變的溫室，但鋼骨與水槽等阻擋無線電波的障礙物，可能造成數值中斷或延遲抵達。因此，實務上通常不會只統一使用其中一種，而是把兩種方式結合：核心區段採有線連接，只有經常變動的區段才以無線補足。

在這些技術之中，稱為LoRaWAN的低功耗長距離通訊網路，也就是LPWAN，短短幾年間已從實驗室技術轉為產業規模的基礎設施。截至2026年，全球LoRaWAN物聯網市場估計達142億5,000萬美元，預計到2035年每年成長34.7%。目前LoRaWAN裝置已部署於70個國家，總數超過1億2,500萬個。這套網路使用一顆電池就能撐過數年，還能把數值送到數公里之外，因此連難以新拉電線的塑膠溫室或露天田地角落，也能布設感測器。

2026年一項明顯趨勢，是運算從雲端移往現場的通訊中繼裝置，也就是閘道器。系統不再把每個感測器數值都送往遠端伺服器等待答案，而是在閘道器中裝入輕量人工智慧模型，讓它立即判斷。這同時減少與伺服器通訊所花的時間和費用。美國內布拉斯加大學研究團隊的實驗顯示，以這種方式即時監測土壤水分，據報可將用水量最多降低35%。感測器不只讀取數值，而是把讀值直接轉為判斷。

然而，不可能在溫室每個角落都布設昂貴感測器。另一種方法是只安裝少數感測器，再以運算繪製整座溫室的三維氣候圖。所謂計算流體力學（CFD），是在電腦中模擬空氣與氣體如何於溫室內實際流動及混合，就像把天氣預報圖搬進溫室這個狹小空間。若再搭配機器學習模型，例如把讀取影像的卷積神經網路（CNN）、追蹤時間變化的時間卷積神經網路（TCN），以及在多個候選值中尋找最佳值的粒子群最佳化（PSO）結合起來的DeepCFD-OptNet，或隨機森林、支援向量迴歸（SVR）、深度神經網路（DNN），只憑少數感測器數值，也能合理重建溫室各處的溫度與二氧化碳分布。這項重建通常每隔幾分鐘重新計算並更新地圖，因此即使是沒有感測器的區域，也能推估接近剛才狀況的數值。運算填補了感測器布設成本與量測精度之間的拉鋸。

刻意把同一個數值量測兩、三次的冗餘設計，是維護量測精度的另一種方法。若系統只靠一個感測器量溫度，感測器一故障，整座溫室就會閉著眼睛運作，但若在同一區域重疊布設性能略有不同的兩、三個感測器，便能比較數值，判斷哪一個最接近故障。有時，多個便宜感測器比一個昂貴感測器更能抵禦故障，因此設計者必須依溫室規模與預算，決定哪些數值要以幾層重疊量測。只有具備這種重疊讀值，後文所述的自適應卡爾曼濾波器才能發揮作用。

數值不一定總會準時抵達。短暫通訊中斷或感測器故障會在資料中留下缺口。缺口若很短，不超過10個時間步，便以前後向線性插值，在中斷前最後一個數值與恢復連線後第一個數值之間畫直線補齊。缺口若超過10個時間步，只用這種方法就顯得勉強，因此會使用動態時間規整（DTW），從過去紀錄中尋找與目前走勢相似的區段，再匯入該模式填補空白。這就像日記少了一頁時，翻查去年同一季節、天氣相近那天的紀錄來補上。

除了填補缺值，還有數值突然飆高或波動的問題。在潮濕多塵的溫室環境裡，感測器常會瞬間吐出毫無道理的數值。自適應卡爾曼濾波器會用來平滑這些數值。卡爾曼濾波器分別給剛由感測器讀到的稍微不穩定數值，以及根據前一段趨勢推估的預期值配置權重，再悄悄收斂到兩者之間的某一點，其原理與衛星訊號晃動時，導航系統仍會參考先前速度與方向，穩定車輛位置的計算相同。之所以稱為「自適應」，是因為濾波器會自行調整對各感測器的信任程度。新讀值與預期值相差越大，該感測器的權重就降得越低，其他感測器的權重則提高，避免整個判斷只因某一個感測器暫時受到濕氣或灰塵干擾而動搖。

中國西北部寧夏恆生育苗基地的一座典型雙膜日光溫室，是這套濾波器的實際測試場域。溫室內分散配置四組WQX-TH、WQX-L與WQX-R光譜感測器，外部另設一座氣象站。不同位置的感測器同時傳來數值後，先由自適應卡爾曼濾波器平滑處理，後續的溫濕度預測，以及自動開關加熱與通風設備的決策，就變得穩定許多。如果量測階段沒有去除雜訊，無論上層疊加多精密的判斷邏輯，基礎都會搖晃。

即使經過平滑處理，這些數值仍不能直接送入運算，因為單位彼此不同。溫度用攝氏度、濕度用百分比、光照用勒克斯、二氧化碳用ppm、酸鹼值用pH，各自尺度都不同。最小值與最大值正規化會把它們重新縮放到0與1之間，轉成能並列比較的數值。道理就像把不同國家的貨幣換算成同一種基準貨幣，再比較商品價格。完成這道程序後，這些數值才能成為機器學習管線的輸入。

數值經過平滑處理並對齊尺度後，就該把它們轉為實際動作。這項工作由現場的NodeMCU ESP8266或Raspberry Pi、配有本地Qt畫面的控制終端，有時再加上雲端伺服器共同分擔，從讀值抵達到作出決定，最多只需幾秒，有時更快。決定完成後，命令透過繼電器模組直接送往灌溉幫浦、通風扇、遮陽幕、二氧化碳補充系統、噴霧噴嘴與LED補光燈。感測器盒子上的綠燈所產生的一個數字，幾秒後就在溫室另一端化成風扇轉動。

量測值一旦儲存並顯示，便獲得另一種用途。經過閘道器的數值累積在時間序列資料庫中，栽培者可在網頁或手機螢幕上，一眼查看過去一天或一週的溫濕度圖表。數值若越過預先設定的危險門檻，簡訊或App通知會立即發出警告，因此栽培者不必整夜

守在溫室裡，也能爭取時間處理寒流或停電等突發狀況。長期紀錄日後可與產量或病害發生情況比較；對需要認證或追溯履歷的農產品而言，也能成為栽培過程的證明。

印尼Sandibuana Farm與Purwosari兩座商業水耕萵苣溫室，完整展現了這套流程。現場安裝DHT11溫濕度感測器、DS18B20水溫感測器、FC-28土壤水分感測器，以及pH與EC養液感測器，再透過NodeMCU ESP8266閘道器收集數值並傳送到雲端資料庫。四個月內累積了15,492筆數值，日後成為預估產量與自動調節環境之決策系統的基礎資料。這個案例證明，只靠幾個感測器與便宜的Wi-Fi模組，也能建立商業溫室規模的資料基礎。

韓國江原大學一座面積300平方公尺的冬季溫室也有相似架構。這座溫室配備顆粒燃料鍋爐、蓄熱槽與管軌加熱設備，並以JNGW100外部氣象裝置及設在室內各處的熱電偶感測器，透過GL840記錄器每1分鐘完整記錄一次數值。只有這些密集累積的紀錄，才能讓預測式加熱判斷成為可能，在嚴寒到來前數小時預先加熱蓄熱槽的熱水。把量測間隔縮短到1分鐘，本身就是任何精密判斷邏輯建立前必須先具備的基礎。

日本愛知縣農業創新計畫測試的智慧噴霧控制案例，顯示多加一個感測器會帶來什麼變化。系統不只查看溫室內溫濕度，還讀取外部日射強度，也就是陽光照射強弱，再把這些數值結合起來，即時計算以一個數字表示空氣有多乾渴的飽和水氣壓差（VPD）。陽光突然增強、這個數字迅速升高時，系統會短暫噴霧，只噴到葉片不致濕透的程度，以緩和作物承受的壓力，栽培者則透過智慧型手機App直接觀看變化。把溫度與濕度等個別數值合在一起，產生新的數字，正接近「智慧」量測一詞所指的實際樣貌。

臺灣高雄的大型多層栽培架與垂直農場案例，顯示感測器網路逐層堆疊後還能看見什麼。這些農場把蘭花與水耕蔬菜分置於多層架上，每格層架都另裝溫濕度、pH與水分感測器，再把數值集中到中央現場控制箱與雲端監測畫面。上層與下層接收到的光線和通風不同，因此原本把整座溫室視為一體的量測方式，被細分到每一層。系統還一併量測用電與用水量，在畫面上繪出碳排放，使感測器不只呈現作物狀態，也兼任揭示整座農場營運效率的儀表板。

即使系統設計完善，仍有薄弱環節。溫室內相對濕度經常超過90%，每次噴藥都會散布腐蝕性氣體，灰塵與水滴還會黏在一起，在這種環境中，感測器靈敏度會隨時間逐漸鈍化。這種現象稱為漂移，意指溫室內實際溫度不變，只有感測器顯示的數字慢慢偏離。為了避免漂移，研究人員正同時開發無須人工重新調整、可比較多個感測器數值並自行校準刻度的軟體，以及塗上耐用奈米材料、能阻擋水分與灰塵的感測器。

定期校正同樣不可或缺。新感測器第一次安裝時，會以初始校正把製造商的基準讀值與現場實際值對齊；此後每隔幾個月，再用數值已獲確認的標準溶液或標準光源重新調整刻度。濕度感測器常見的做法，是暫時放進能維持固定濕度的飽和溶液，例如鹽

類溶液，再以該讀值作為基準。為了不讓人反覆走遍溫室執行這項繁瑣工作，軟體校正正逐步接手一部分任務，透過比較不同感測器讀值，找出已偏離的那一個。

如何劃分空間並配置感測器，仍是另一項尚未解決的課題。溫室越大，通風扇前方與溫室中央之間，以及作物冠層上部與下部之間的氣候差異就越大，把感測器以相同間距排列成規則網格，很可能錯過溫差最大的區域。正在研議的替代方案，是結合分層抽樣與基於CFD的重建：先把溫室分區，再以不同密度配置感測器。決定在哪裡放多少個感測器，正變得與選擇使用哪一種感測器同樣重要。

試圖把不同製造商的感測器、可程式邏輯控制器（PLC）與各類控制器整合在一起時，常因通訊語言不同而造成數值錯位，甚至完全無法連線。每當農場添購新設備，都得先確認能否與既有設備相容，負擔也由此而生。為解決這個問題，產業現場廣泛使用的標準通訊協定OPC UA、日本農業資料共享平台WAGRI，以及把物聯網導入農業的IoP雲端等共同標準，正逐漸普及。除了統一標準，也必須設計容易理解的畫面與操作方式，讓未學過工程的栽培者幾天內就能上手。

部署到現場的人工智慧運算會碰到哪些實際困難，不能只從測試準確率看清。致動器收到命令到真正動作之間有明顯延遲，風與震動等物理因素也會在意想不到的時刻介入。通訊只要短暫中斷，閘道器就不能無限等待雲端答案，因此現場至少要保留最低限度的判斷邏輯。即使使用便宜的微控制器，也能可靠執行這些判斷，是下一個目標。

隨著運算移入閘道器成為趨勢，裝在裡面的人工智慧模型也必須變得更小、更輕。把數字縮減為8位元以降低運算負擔的量化，以及把大型模型所學知識轉移到小型模型的知識蒸餾，正被進一步改良作為解法。選擇感測器、供應電力、鋪設通訊網路、填補缺值、過濾雜訊、對齊尺度，每一項分開看似都很細小，但只要漏掉一項，建立在上面的所有判斷都會動搖。溫室支柱上感測器盒子的讀值，必須先補齊缺口、去除雜訊、對齊尺度，幾秒後才會成為驅動風扇、幫浦與燈具的決定。

白色盒子裡的感測器是否真的讀到正確數值，是另一個問題。栽培者手中拿著裝有透明液體的小瓶，瓶內酸鹼值精準調整為pH 4、7與10，再依序把感測器尖端浸入其中，把畫面上的數字調整到標準值，這項工作就是檢查與校正。電導度感測器同樣會浸入電導度已知的標準溶液，以重新設定刻度。校正一次並不代表工作結束，每當季節轉換，且至少每隔幾個月，就必須重做。若半年或一年沒有檢查與校正，感測器仍會持續產生數字，但隨時間經過，那些數字會逐漸偏離它們聲稱代表的數值。因此，農場會另行保存校正紀錄，記下每個感測器何時以哪一種標準完成校正，只有這份紀錄，日後才能分辨哪些時段的資料可以信任，哪些應存疑。

當多個感測器重疊時，還需要規則決定該信任哪一個。若同一區域並排放置三個溫度感測器，其中兩個讀值接近攝氏24度。剩下一個單獨顯示31度時，系統會採用獲得

多數支持的兩個數值，把異常值列入觀察名單。像是溫度在10秒內跳升超過5度這種現實中不太可能發生的變化，也會以相同方式濾除。被標記的感測器不會立即拆除，而是再觀察幾天，只有相同偏差反覆出現時才確認故障。一次尖峰可能只是灰塵恰巧飄過造成的偶發事件，但反覆偏離就必須視為感測器本身的問題。

以插值補上的數值必須加上標記。不論是用直線連接，還是從相似的過去模式匯入，這些數字都不是感測器實際量到的讀值，而是經由運算推估的數值。若沒有標記，數月後比較環境紀錄與產量時，推估值與實測值可能混在一起，使結論走向錯誤。更棘手的情況是，中斷原因不是通訊斷線，而是水管凍結或幫浦停止等真正故障，插值卻用平順數字補上空白，把問題藏起來。因此，缺口一旦持續超過設定時間，除了插值之外還必須發出現場檢查警示，防止運算悄悄掩蓋問題。

設計通訊網路時，不只要決定鋪多少線路，也要決定系統如何承受訊號中斷。無線感測器節點若失去與閘道器的連線，會暫時把讀值存進內建記憶體，而不是讓它消失，待連線恢復後再一次上傳積欠資料。採用節點彼此中繼訊號的網狀配置時，即使鋼柱擋住無線電波，仍能經由鄰近節點繞行。有線區段不需要這種繞路，但纜線本身一旦斷裂就沒有替代方案，因此重要的主幹纜線常會在旁邊另鋪一條備援線路。

栽培者觀看的畫面若只排列數字，幾乎沒有用處。正常範圍標成綠色、需要注意標成黃色、必須立即處理標成紅色，才能一眼判斷溫室狀態。問題在於警報太常響，栽培者可能在真正重要的時刻忽略通知。因此，門檻會分成不同等級：小幅波動只在畫面上安靜顯示，只有多個數值同時進入危險範圍，或同一警告持續超過設定時間，才會傳送手機通知。有些場域若第一次通知未獲回應，過一段時間後會提升處置層級，直接撥打電話。畫面一角還會把1小時與1天後的預測值畫在目前讀值旁邊，幫助栽培者在數字升高前先行處理，而不是事後應對。

如果這些裝置只能由預算充裕的大型農場使用，成果就只完成一半。感測器、閘道器與軟體訂閱費加總後，很容易高到讓小型農場卻步；設備裝好後，鄉村地區也很難找到故障時能前來維修的技術人員。遠端操作幫浦與通風窗的系統固然方便，卻也帶來外部人士未經授權存取與操控的風險。若有人在隆冬入侵系統並打開通風窗，整座溫室可能在幾小時內凍結。另一項尚未解決的問題是，多年環境與生長紀錄沒有留在創造其價值的栽培者手中，反而被鎖在設備商伺服器裡，農場只要換用其他公司設備，整段紀錄就會隨之中斷。設備購置成本、維修人力、遠端控制安全與資料可攜性，仍是這項技術必須解決的課題。

資料來源與參考文獻

學術論文

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.

報告與網路資料

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/>

演講與影音資料

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

數位孿生與 AI 智慧環境、生長最佳化

數位孿生（Digital Twin）是一項把感測器即時傳送的氣溫、濕度、二氧化碳濃度、土壤水分等資料，結合到在電腦中完整重現實際溫室結構與設備的虛擬模型，預先計算溫室內環境未來將如何變化的技術。開啟屋頂通風窗或調整灌溉閥門等措施，會先套用在螢幕中的模型上，以運算確認結果，之後才把同樣命令送往實際溫室設備。它之所以稱為孿生，是因為會隨著時間與溫室狀態一起變動。

數位孿生並不只是一張照著溫室製作的三維影像。如果模型只有外觀相似，一張照片就足夠，根本不必計算。真正的核心，是一具持續運轉的引擎，計算溫室內的空氣、土壤，以及其中生長的植物如何隨時間改變。這具引擎的中心，是國際廣泛使用的作物生長模型DSSAT，也就是農業技術移轉決策支援系統4.8版。它每天計算葉片透過光合作用製造的養分如何分配到根、果實等各部位，根從土壤吸收水分與養分的速度，以及植物對高溫、乾旱等壓力的反應程度。栽培者在螢幕上開關窗戶時，引擎會反映變化重新運算，預先顯示明天這座溫室的番茄莖會再變粗多少、葉片會再下垂多少。

在溫室內，氣溫與濕度、二氧化碳濃度與日照強度、土壤或介質中的水分與肥料，不會各自獨立移動，而是一起交互牽動。打開窗戶時，氣溫和濕度一同下降，二氧化碳逸散到外部的速度也會改變。這種關係與轉動一個把手，水壓和水溫便同時改變的淋浴設備沒有兩樣。溫度達到設定值便開啟風扇、下降後再關閉的傳統開關式控制，追不上這種交互作用。反應總慢一步，供暖費用與用水就因這一步延遲而浪費，植物還得一連數日忍受不必要的高溫、低溫或乾燥。數位孿生與人工智慧控制之所以走入溫室技術核心，原因就在這裡。只有在移動實際窗戶與閥門前先於螢幕中運算，才能及時掌握這些相互糾纏的反應。

數位孿生最能展現價值的時刻，是栽培者測試從未嘗試過的措施時。如果在真實溫室測試比平常大幅增強補光會發生什麼事，或把灌溉時間提前兩小時會如何改變果實大小，至少要一季，最久甚至要一年才能知道結果。期間若判斷錯誤，當年收成就會直接損失。但在螢幕裡的孿生溫室，同一項措施幾分鐘內就能先以運算跑過一遍，結果不好便復原即可。道理就像新手飛行員在登上真正飛機前，先在飛行模擬器裡反覆犯錯。光是擁有一個可以失敗的練習場，栽培者便能更大膽測試過去猶豫不決的措施。

人不可能晝夜不停照看所有計算與判斷。因此，研究人員製作了代替人監看溫室並作出判斷的人工智慧代理。中國研究團隊提出的AgriAgent就是一例。這套系統不只是

回答問題的聊天機器人，更像常駐溫室的新手栽培者。它模仿先讀儀表板、記住上週採取過哪些措施，必要時翻開厚重栽培手冊，最後才轉動閥門的態度。AgriAgent的核心判斷功能由名為Qwen2.5的大型語言模型（LLM, Large Language Model）負責，並排測試15億、30億與70億參數三種不同規模的模型。參數就是模型內經由學習決定數值的數字，數量越多，模型能區分並記住的情境就越多，判斷也越細緻。

AgriAgent每7天依序經歷一次感知、記憶、檢索、推理、行動五個階段。感測器資料首先形成由12個數字整理而成的狀態值。內容包括土壤水量、土壤氮與有機質含量、當日平均與最高溫度、每日降雨量與風速、空氣中的二氧化碳濃度、光合作用真正使用的光強度、播種後經過天數，以及把缺水與生長延遲各自表示為單一分數的兩項壓力指數。一套稱為格式轉換器的裝置，把這些數字改寫成人能閱讀的句子，再附上過去紀錄與後文說明的檢索結果，交給人工智慧模型。逐句展開12個數字，說穿了就是把作物現在多渴、生長得多好翻成人話。這個程序把一張滿是數字的表格，轉為人能立刻看懂的短篇報告。

農業有許多只出現在教科書裡的細節知識，再大的語言模型也不可能全數記住。AgriAgent不會把這些知識整本背下來，而是在需要時翻開厚書，找到恰好合用的一頁。為了使用這種稱為檢索增強生成、英文縮寫RAG（Retrieval-Augmented Generation）的方法，研究團隊以光學字元辨識（OCR）把農學教材與技術手冊的510萬字轉成數位文件，再從中挑出可用的440萬字，切分成小段整理。每一段都附上標籤，標明取自哪一章哪一節。一個名為bge-large-zh的768維嵌入模型，也就是把句子轉為數值向量、讓意思相近的句子靠在一起的模型，會找出語意相通的段落，再加上檢查字詞是否完全一致的搜尋，選出最符合當前情況的5份文件交給人工智慧。

人工智慧拿到文件後不會立刻回答，而是逐步進行。它先判斷現在是發芽期，還是開花結果期，再檢查是否缺水或生長遲緩，最後根據這些判斷決定命令。這就是思維鏈（Chain-of-Thought）方式，像人不會只用心算丟出答案，而是逐行寫下解題過程。結論會整理成JSON標準格式資料，由6個數值組成：灌溉量、補光強度、通風狀態、加熱狀態、施肥量與二氧化碳釋放量。灌溉量設定在每小時0至30毫米，補光設定為平常的0%至200%，施肥量則設定在每公頃0至50公斤。稱為工具執行器的最後確認程序，會再次檢查這些數字是否超出安全範圍，把越界值削回範圍內，之後才把命令送往DSSAT引擎或實際溫室設備。

假設某個星期一早晨，感測器顯示土壤水量少於平常，白天最高溫比往年高3度。缺水壓力指數也升到接近危險訊號。AgriAgent會把這組數值，與目前正值果實膨大期的事實，以及知識庫中「這個時期土壤乾燥容易造成生理障礙」的文字一起閱讀。結論會集中到提高灌溉量，並略微降低正午補光，減輕葉片負擔。人類栽培者可能靠經驗與直覺作出這項判斷，AgriAgent則以數字與文件為依據，在幾秒內整理完成。

設備隨時可能故障。假設灌溉裝置停止，無法再向土壤供水。人可能因此慌張，但 AgriAgent 會用追究因果的推理能力尋找其他路徑。它能調整通風與加熱，減緩葉片蒸散失水速度，再增加二氧化碳釋放量以協助光合作用，部分抵銷缺水造成的損害。這種應對方式，就像廚師發現冰箱少了一樣食材，便調整其他材料比例，仍完成同一道料理。在人員趕來修理閥門前，作物可藉由這項臨時調整避開最壞情況。

要確認這種判斷是否可信，必須事先用極端天氣測試。研究團隊依據1994年至2023年的30年氣象資料，製作正常、波動、極端三種強度的虛擬天氣，共準備90種年度情境。極端情境包含多重災害：連續20天高溫乾燥、超過80毫米暴雨集中在5天內降下，以及乾燥20天後立刻接上10天暴雨的急遽反轉。讓 AgriAgent 經歷這些情況後，再觀察作物是否存活、能撐到什麼程度。在真實溫室很難遇到的最壞組合，可以在螢幕裡毫無風險地反覆經歷。

所謂恢復力高，指的是一幅具體畫面。在連續20天炎熱乾燥的情境中，訓練不足的控制方法一旦讓壓力指數進入危險區，之後就很難恢復，作物會直接萎凋。AgriAgent 則在缺水初期逐步增加灌溉與補光，把壓力指數鎖在低檔；後續暴雨突然來襲的急遽反轉區段，也迅速增加通風，減輕過濕損害。面對最惡劣天氣，它仍沒有放棄，而是每一刻都依情況持續作出稍微更好的選擇。

進入溫室的並不只有像 AgriAgent 這樣處理語言的人工智慧。使用已久的人工神經網路（ANN, Artificial Neural Network）與支援向量機（SVM, Support Vector Machine），也負責讀取微氣候。兩者都是從數值資料中尋找模式的統計型程式，透過名為 Orange 的資料分析工具，同時查看溫室內溫度、濕度與紫外線強度，再把目前狀態分為適當、過量、缺乏三類之一。分類準確率達99.99%。判斷一萬次可能才錯一次，比人每次用眼睛查看儀表板密集得多。

溫度與濕度在一天之內起伏劇烈，也會彼此影響，因此很難預測。陽光短暫被雲遮住後又重新露出，溫室內數值也會細微晃動。研究團隊先對不同位置的感測器數值套用自適應卡爾曼濾波器，壓低這些擺動雜訊。程序就像拍照時補償手震、減少模糊。只有去除雜訊後的數值，才不會讓下一個預測模型朝錯誤方向學習。

去除雜訊後，再用灰狼最佳化（GWO, Grey Wolf Optimizer）調整預測神經網路的細部設定。就像灰狼群從多個方向逐漸包圍獵物，這套方法會反覆縮小多組候選設定值，找出合適組合。在如此調整完成的 LSTM 長短期記憶（Long Short-Term Memory）神經網路中加入注意力（Attention）機制，就能從過去幾小時紀錄裡挑出對目前預測真正重要的時刻並提高權重。這套組合可一次預測未來幾小時內溫室溫濕度將如何變化。

無論預測多準，如果不能轉成實際開關供暖設備的判斷，就沒有用。資料驅動預測控制，簡稱DDPC（Data-Driven Predictive Control），是一種預先知道即將變冷，在寒流抵達前先加熱水的做法。韓國江原道春川一座300平方公尺溫室進行了現場測試，裡面裝有顆粒燃料鍋爐、蓄熱槽與管軌加熱設備，每隔1分鐘收集一次資料。一種比LSTM輕量的神經網路GRU（Gated Recurrent Unit），反覆學習最近7天共10,080筆量測值，再用下一天資料確認性能。模型會在寒流來臨前1至3小時預報溫室內氣溫將下降，並依預報提前啟動鍋爐與熱水閥門。結果既防止溫度降到作物可承受的最低溫以下，也減少不必要的加熱，節省燃料費。

加熱與產量經常是往相反方向拉扯的力量。溫度調高一些，作物長得更快、結果更多，但鍋爐會不停運轉並消耗燃料。反過來節省加熱，燃料費雖降低，受低溫折磨的作物卻會生長遲緩或掉花芽，最後在產量上蒙受損失。數位孿生不會把這兩項目標分開計算，而是疊在同一畫面上。用相同冬季情境分幾個等級改變加熱強度，就能找出燃料費損失與產量損失總和最小的溫度。春川溫室的GRU型DDPC只在寒流前短暫啟動鍋爐，勉強守住最低溫，正是即時重新尋找這個交會點的運算結果。

這些預測模型的能力可用幾個數字確認。決定係數以R平方表示，在0到1之間顯示預測值與實際值有多接近，越接近1代表越吻合。這次的微氣候預測模型得到0.77至0.93的數值。春川溫室的GRU型加熱控制模型，以均方根誤差RMSE計算，誤差約為攝氏1.43度。只差溫度計約一格半，用於加熱控制已有足夠精度。把溫室狀態分為適當、過量、缺乏的分類模型，在AUC-ROC指標中得到0.988至0.991，代表幾乎不會混淆三種狀態。

AgriAgent的能力已在多種作物上接受測試。研究團隊在DSSAT型數位孿生上選了玉米、粟、甜菜、番茄、大白菜五種不同作物。玉米代表使用陽光效率格外高的光合作用途徑作物，粟代表耐旱作物，甜菜食用根部，番茄食用果實，大白菜食用葉片，因此均衡代表不同生長方式的作物。90種天氣情境乘以3個強度，一共進行450次完整生長期模擬。相較於沒有人為介入的自然生長，70億參數模型明顯提高玉米、粟與甜菜的收穫乾重。發芽期出現低溫警報時，它還自行把補光介入強度拉高到120%，減少寒害。隨著參數從15億、30億增加到70億，控制性能也依序提升。

以一段玉米模擬為例，代理會先計算播種後經過幾天，判斷目前是剛萌芽的出苗期，還是抽穗期。同樣的低溫，播種後第10天遇到，與穗部正在成熟時遇到，對作物造成的打擊不同，因此若誤判生長階段，再準確的溫度預測也會導向錯誤處方。實際測試中，代理能在低溫警報前提高補光，也正因先完成了生長階段判斷。它不只計算日期，還會讀出那個日期對作物體內有何意義。

數位孿生沒有停留在實驗室，也已用於真實商業農場。印尼Sandi Buana Farm栽培水耕萵苣時，從量測溫度、濕度、EC與酸鹼值的高解析度感測器收集15,492筆樣本。

EC是透過水的導電程度，量測肥料成分溶解了多少的數值；酸鹼值則表示水有多酸或多鹼。這些資料送入機器學習預測演算法後，系統會自動協調萵苣產量與栽培環境變數，無須人員逐項調整，也能維持適當水分與肥料濃度。這座農場證明，即使沒有任何實驗室模擬，只靠現場累積的數字也能建立判斷系統。

在數位孿生上運作的語言模型代理，與更早就用於溫室的統計型預測模型，並非競爭關係，更像職責不同的同事。代理同時讀取生長階段與多項變數，從大局平衡灌溉、施肥與補光；ANN、SVM及LSTM系列模型則負責抓住每分每秒變化的溫濕度。實際現場常由兩個層次重疊運作，自然形成分工：重大判斷由代理作出，再由統計模型逐秒微調。一方決定是否開啟屋頂通風窗，另一方則在窗戶打開後逐秒監看溫度是否與預期不同。若只有其中一個層次，就會淪為只有半套的判斷，不是看對大局卻錯過瞬間波動，就是抓住瞬間卻看不懂整季走勢。

把在一座溫室驗證的代理擴展到10座、100座，並不像算術那麼簡單。每座溫室的朝向、材料與周邊建築陰影不同，相同命令會產生不同結果。因此，把代理導入新溫室時，常會在最初幾週設置適應期，另外學習這座溫室獨有的習性。既有溫室累積的知識庫與判斷習慣作為底稿，再隨新現場數字累積，一點一點重新調整。

這股趨勢不只出現在幾項局部實驗。最近研究提出把數位孿生放成線上模擬器，與大型語言模型代理連為一個閉迴路，在命令送往實際設備前，即時驗證是否安全。結果證明，語言模型即使在必須完全配合時間流動作出判斷的迴路裡，也能發揮作用。另有智慧溫室實作把無線感測器與致動器通訊網路連上孿生軟體，遠端監測並自動控制微氣候與灌溉，還預先找出病害發生可能性。栽培者不必跨過溫室門檻，就能確認當前狀態，先在螢幕裡測試一項措施，再實際套用。2026年還出現把作物生長模型與自主氣候控制連為一體的資料驅動溫室管理方式，顯示數位孿生正從展示用模型，轉為兼具判斷與執行功能的工具。

栽培者實際面對的是一面彩色儀表板。12個狀態值與6個控制命令，以圖表和長條圖並列顯示，旁邊附上一、兩句話，摘要人工智慧為何下達這項命令。栽培者閱讀文字後可保持原樣，不滿意時也能手動修改數字再送回。代理的判斷在人工最後簽核前都只是草案，這項原則直接融入畫面設計。

這套系統建立前，栽培者每天清晨都得拿著手電筒巡視溫室，逐一查看溫度計。寒流警報發布的夜晚，每兩、三小時醒來檢查鍋爐也不罕見。數位孿生與代理接手這些重複勞動後，栽培者的一天改變了，只有發生問題時才被叫到螢幕前。整夜平安，早晨便在沒有一則警報的情況下到來；若有任何異常，手機會在那一刻響起。人工巡查消失了，但計算接手了這份工作。

這並不表示技術已經完成。把在DSSAT型數位孿生裡驗證的控制方法原封不動搬到真實溫室，運算與現實便開始偏離。致動器收到命令到真正動作所需的時間、老舊感測器數值逐漸產生的偏差、溫室角落與中央的溫差，以及未預期的外部衝擊，都會在螢幕計算與實際結果之間製造缺口。研究人員稱之為模擬到現實落差（Sim-to-Real Gap），並試圖透過事先讓孿生經歷更嚴苛情境的訓練，以及部署現場後持續學習來填補。稱為LoRA的微調方法，不必重新訓練整個大型模型，只需略微轉動幾個旋鈕便能配合新現場，因此被視為適合這種持續學習的工具。

技術再精密，如果沒有人能操作，最後仍只是放在溫室角落的裝飾品。是否照單全收AgriAgent的判斷，還是依多年經驗手動改數字，最終由栽培者決定。這種信任無法一夕建立，只有代理連續幾個栽培季都未犯大錯，才會逐漸變厚。親眼看過螢幕中的孿生與真實溫室出現幾次不同動作的栽培者，之後即使預測再準，也不會完全照信。

要運行70億參數模型，需要昂貴的GPU伺服器與不中斷的通訊網路。這些條件對資本不充裕的農場構成門檻，每次通訊往返也會造成判斷延遲。為了解決問題，研究人員同時使用把模型中每個數字以更少位元表示及儲存的量化（INT8），以及把大型模型學到的判斷方式教給小型模型的知識蒸餾（Knowledge Distillation）。就像能力出色的前輩整理訣竅傳給後輩，70億模型的判斷習慣會移植到15億或30億規模的小型模型，讓它們也能在溫室現場的便宜設備上運作。縮小後的模型不用把資料送到雲端，就能在溫室旁的小型電腦完成判斷。只有讓個別小農的一座溫室也能運行代理，這項技術才不會成為少數大型農場專用的工具。

提高產量、節省能源、減少用水與碳排放的目標經常彼此衝突。加強補光會提高產量，電費卻也同時上升。為了不讓代理在多重目標中只偏向一方，研究人員持續設計多層獎勵計算方式。栽培者也必須能直接在螢幕上確認人工智慧為何決定此時開窗，以及判斷依據為何。判斷過程若像黑箱般隱藏，模型再準也難以放心交付現場工作。數位孿生與智慧控制若要離開實驗室，成為一般溫室的日常工具，仍需要更多提升可解釋性的研究。

資料來源與參考文獻

學術論文

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.

報告與網路資料

1. arXiv. (2025). 基於線上模擬器的數位孿生與大型語言模型代理之閉迴路溫室控制驗證研究.
<https://arxiv.org/pdf/2507.07115>
2. Springer. (n.d.). 智慧溫室數位孿生實作：基於無線感測器與致動器通訊網路的微氣候遠端監測與病害預測研究.
https://link.springer.com/chapter/10.1007/978-981-99-0252-1_5
3. PLOS ONE. (n.d.). 數位孿生溫室的遠端狀態監測與虛擬措施驗證研究.
<https://journals.plos.org/plosone/article?id=10.1371%2Fjournal.pone.0344946>
4. ScienceDirect. (2026). 結合作物生長模型與自主氣候控制的資料驅動適應型溫室管理研究.
<https://www.sciencedirect.com/science/article/pii/S2590005626000445>

演講與影音資料

1. 高雄農來訊. (2025). 114年高雄智慧農業年度成果發表暨研討會. YouTube.
<https://www.youtube.com/watch?v=1Edc6pP4HnU>
2. Kanal Pengetahuan Fakultas Teknologi Pertanian UGM. (2025). Artificial Intelligence in Smart Greenhouses: Enhancing Crop Monitoring and Environmental Control. YouTube.
<https://www.youtube.com/watch?v=zFP6Nm4i4Ec>
3. WiseFood Project. (2025). WiseFood and STELAR Webinar: Empowering Agrifood Apps With LLM-Based Dataset Search and Integration. YouTube. https://www.youtube.com/watch?v=Keqo17qBr_g
4. Regace Project. (2026). Agrivoltaics in Greenhouses - Turning Sunlight into Energy & Crops. YouTube.
<https://www.youtube.com/watch?v=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

資料驅動的精準農業與決策支援

4.1

智慧灌溉與肥料供應最佳化

智慧灌溉系統裡，打開閥門的不是人，而是插在土壤中的感測器與在雲端伺服器運作的預測模型。系統計算土壤有多乾、白天溫度升到多高、明天下雨機率是多少，再決定何時灌溉、供應多少水。美國內布拉斯加州的田間試驗中，使用這類灌溉排程工具的玉米田節省29%至43%的用水，大豆田節省10%至37%，兩者產量仍與傳統方式相近。

在傳統農業中，何時供應多少水與肥料，取決於栽培者熟練的手感與固定時間表。可能每天早上6點開水，每月混一次肥料。問題是土壤與天空不按時間表行動。有些日子，土壤已經潮濕，仍有更多水倒下去，讓根部沒有呼吸空間；另一些日子，乾裂的土壤卻無人過問，作物因而萎凋。過量水分深入地下時會帶走土壤，溶在水裡的氮與磷也會流入溪川。隨著氣候變遷加劇乾旱與暴雨交替，依賴直覺和時間表的灌溉施肥，造成的損失越來越大。

智慧灌溉與肥料供應最佳化，就是為減少這些損失而設計的技術。它把土壤水分感測器、氣象觀測設備、物聯網，也就是讓多個裝置透過網際網路連線並交換資訊的通訊網路，以及機器學習預測模型整合為一套系統。系統從多個角度量測水分如何在土壤、空氣與作物之間移動，計算隨作物生長階段改變的水分與養分需求，把感測器資料和天氣預報送入模型，預測未來幾天需求，再把結果交給實際操作閥門與幫浦的雲端伺服器。中國東北地區的一項統合分析顯示，以滴灌與灌溉施肥取代傳統灌溉及施肥方式後，作物產量、水分生產力與氮利用效率一併提升（Li et al., 2021）。這項結果說明，直接在根前精準輸送所需量，比把水撒遍整片田地更好。

內布拉斯加州的田間試驗，把栽培者平常使用的方法與並行運作的商用灌溉排程工具進行比較。結果使用的水大幅減少，產量卻相同。也有案例報告，AI排程持續監看感測器數值，並在各生長階段調整判斷，最多可節水87.97%。但這項數字是在特定作物與特定條件下觀察到的上限，不能假設原樣適用於每座農場。

科學家把土地、天空與作物交換水分的連續關係稱為土壤－植物－大氣連續體（SPAC, Soil-Plant-Atmosphere Continuum）。水從土壤流向根，從根流向莖葉，再由葉片回到空氣。決定水流速度的並不只有土壤含水量。溫度高、風強、陽光猛烈時，水從葉片快速蒸發，根也會更快從土壤吸水。由土壤蒸發的水與葉片蒸散的水合稱蒸發散（ET），灌溉系統會持續量測溫度、濕度、太陽輻射、風速與降雨，估算這

個數值。電容式或電阻式水分感測器埋在土壤不同深度，同時查看表土與根真正抵達深度的水分。系統把資料疊在一起，描繪當下田裡還剩多少水。

作物從出生到死亡，需要的水與肥料並不相同。種子發芽時只需少量水；進入營養生長期、植株旺盛生長後，需求會急遽增加。開花期缺水會落花，坐果與膨大期即使稍微缺水，也會讓果實變小或裂果。有些作物進入成熟期反而要減少供水，才能提高糖度。研究人員用發育量指數（DVI，將作物發育程度表示為單一數字的指標）呈現這些變化。先把目前發育程度表示成0到1之間的數字，再與各階段設定的水分壓力門檻比較。氮、磷、鉀等肥料成分也依相同邏輯，為各生長階段計算不同濃度與用量。這套方法從根本上不同於全年供應相同用量的單一時間表。

人很難用手算完所有物理資料與生長資料。變數增加到10個、20個後，很難判斷哪一項是當前情況的決定因素。過去幾年間，機器學習模型開始在溫室與露天田地接手這些計算。模型以感測器送來的數字和氣象機構預報為輸入，判斷此刻是否需要灌溉，如果需要，應供應幾公升。選擇哪種模型，取決於農場的作物與規模、收集的資料類型，以及收集期間長短。

隨機森林是使用最廣泛的模型之一。如名稱所示，它種下許多決策樹形成森林，讓每棵樹的判斷投票，再依多數決得出結論。即使土壤水分、溫度、濕度、降雨量、土壤類型與作物類型等變數彼此交纏，仍能產生穩定結果。印度研究團隊在網路平台上測試這套模型時，使用者輸入田地條件，便會得到是否需要灌溉的肯定或否定答案；需要時，系統還會估算具體水量，約25公升（Ajay Kumar et al., 2026）。印尼研究團隊則在種植芥菜與萵苣的菜園安裝NodeMCU微控制器、溫度感測器和即時時鐘模組，收集1,200筆紀錄，再用同一套隨機森林演算法自動開關灌溉閥門（Pradasari et al., 2026）。這個模型不容易過度擬合，也就是只符合訓練資料、到了真實田地就失靈，因此在現場經常獲得採用。

決策樹模型在決定施肥量方面展現優勢。一個例子是EcoGrow，這個雲端平台依據斯里蘭卡農業部園藝作物研究發展所（HORDI）發布的傳統指南建置。使用者輸入作物種類、栽培地區、土壤特性、灌溉間隔、氣候區與施肥時間，平台便會說明每公頃應混合多少公斤尿素、重過磷酸鈣（TSP）與氯化鉀（MOP）三種肥料。模型以涵蓋32種園藝蔬菜作物的1,535筆紀錄訓練，準確率達97.39%，並憑此成績獲選實際部署。EcoGrow更進一步，把尋找附近肥料零售商的功能，與回答施肥方法問題的AI聊天機器人，也就是自動以對話方式回應的程式，放在同一畫面。農民不必親自翻找數字表格，就能依螢幕顯示配方混肥。

另一種方法把線性迴歸與深度神經網路（DNN，一種堆疊多層以學習複雜模式的人工神經網路）結合。線性迴歸畫出一條近似直線，呈現土壤水分隨時間下降的斜率。深度神經網路再加上一張照片。卷積神經網路（CNN）將土壤照片分成沖積土、黑土、

黏土、紅土等類型，再把這項判斷與天氣資料及氮、磷、鉀濃度量測值結合，提出肥料處方。用眼睛分辨土壤外觀與計算數值資料的能力，就這樣放進同一個模型。

水稻栽培會使用強化學習。強化學習持續觀察一項行動帶回的獎勵，經由反覆嘗試自行找出更好的行動。模型取得天氣預報資料後，依馬可夫決策過程，也就是只查看當前狀態來決定下一步行動的數學框架，學習何時灌溉最有利。模型把DVI追蹤與乾濕交替灌溉（AWD，一種讓稻田反覆淹水，再乾到土面露出的灌溉方式）結合，在抽穗等對水敏感的時期精準供應所需量，同時節水（Chen et al., 2021）。傳統水稻栽培會讓稻田持續淹水，這項結果卻顯示，精細控制乾燥與淹水循環，反而對水稻更有利。

這些模型在真實田地運作時，程序大致相似。先填補感測器資料缺值，把數值正規化到0與1之間，再把作物或土壤類型等文字值轉為數字。模型預先在伺服器外以整理後資料完成訓練，只將訓練完成的模型上傳雲端伺服器。田間感測器節點每隔1至15分鐘向伺服器傳送新數值，伺服器一收到，就執行推論，判斷是否灌溉與施肥。決定經物聯網閘道器送出，啟動繼電器開關，實際供應的水量再由脈衝水表，也就是每次水流通過便計數一次短促電訊號的水表，重新量測並記錄在資料庫。只有預測、執行、再次量測的循環不中斷，才構成一套智慧灌溉系統。

仔細查看埋在田裡的每個感測器，就能知道判斷從何開始。FC-28與YL-69等多個電容式或電阻式水分感測器，埋在土壤不同深度。表土水分與根部深度水分的乾燥速度不同，只量一個位置很容易錯過實際狀況。再加上DS18B20溫濕度感測器與DS3231即時時鐘模組，留下土壤在何時何分達到某一溫度的精確紀錄。

養液栽培，也就是不用土、把肥料溶在水中直接送到根部的水耕農場，需要另一套感測器。電導度（EC）感測器量測溶解肥料鹽類的總濃度；pH感測器量測水呈酸性或鹼性；另有氮、磷、鉀濃度感測器，再加上總溶解固體（TDS）感測器。電導度過高時，滲透壓逆轉會使水分從根細胞向外流出，造成類似根部乾枯的損害；太低則代表養分不足。酸鹼值若離開各作物規定的狹窄範圍，根部吸收養分的通道本身就會被阻斷。養液栽培場的控制程式，以電導度與酸鹼值為基準，計算應向水槽加入多少濃縮肥料和酸液；數值一離開允許範圍，便自動啟動幫浦修正。

只靠田裡感測器還不夠。系統會一次匯入累積40年以上的歷史氣象資料庫、土壤調查資料、超過30,000種作物品種資訊，以及7天天氣預報。它從WeatherAPI、美國國家航空暨太空總署的NASA POWER、聯合國糧食及農業組織的FAO CLIMWAT等外部服務，即時取得氣溫與降雨機率；若預報明天下雨，便能預先減少今晚灌溉量。天空中，無人機搭載多光譜相機與可見光—近紅外線（Vis-NIR）光譜設備，低空飛越田地，記錄作物葉片顏色與反射光。即使人眼看來仍很健康的葉片，開始缺乏氮、鉀或鎂時，反射特定波長光線的程度就會先改變。以診斷施肥推薦系統（DRIS, Diagnosis

and Recommendation Integrated System) 分析反射光資料，可在可見症狀出現前找出缺乏哪種養分。把蘋果園無人機資料連上灌溉施肥模型的一項試驗中，無須摘葉送往實驗室，就能從空中預先辨識缺氮 (Sun et al., 2023)。

田裡量到的數字送往伺服器，也要經過多個層次。ESP32、NodeMCU ESP8266、Arduino、PIC等低價微控制器位於田間節點，讀取感測器數值。這些數值再透過Wi-Fi、工業現場常用的RS485有線匯流排、以低功耗涵蓋廣大區域的LPWAN、第四代行動通訊模組，以及用少量電力交換短訊息的MQTT通訊協定送往雲端。伺服器端設有Firebase即時資料庫、FastAPI、Flask等後端，其上運行以Scikit-learn、Pandas與NumPy等程式庫撰寫的機器學習程式碼。栽培者不必了解整段流程。只要查看網站或手機顯示的儀表板即可。印度馬哈拉施特拉邦一個平台以馬拉地語、印地語與英語顯示介面，讓難以閱讀英語說明的農場也能取得灌溉與施肥建議 (Shriwas et al., 2026)。

雲端作出的決定必須回到田間，才會產生實際效果。伺服器決定灌溉後，訊號經物聯網閘道器送到田間的數位繼電器，繼電器開關幫浦，並開關各區閥門。可改變水流粗細的可變式噴嘴，讓同一組管線能向不同區域供應不同水量。過去由人手轉動的水龍頭，如今由電子訊號開關。每次循環中，訊號都從土壤感測器出發，繞行雲端，再回到土壤。

有些系統會加上相機。一套整合ESP32感測器終端、ESP32-CAM影像感測器與FastAPI伺服器的自適應灌溉系統，不只量測溫度、濕度與土壤水分，還用相機監看作物狀態 (Ramya et al., 2026)。灌溉開始後，脈衝水表計算實際流過管線的水量，再把數字傳回伺服器。系統不會在下達命令後結束，而是確認命令究竟執行了多少，完成閉迴路控制結構。這就像依說明書組裝零件後，最後仍用手確認螺絲是否真的鎖緊。

日本農機公司久保田把這套系統商品化，命名為ZeroAgri。溫室內土壤感測器資訊與天氣預報資料送往雲端，伺服器計算最佳灌溉水量與肥料量並自動供應。鋪設覆蓋物的柑橘園則反向使用同一套土壤水分視覺化技術。目的不是節水，而是刻意把土壤乾燥到適當程度，讓果樹承受輕微壓力，藉此提高果實糖度。供應更多水與供應更少水的技術，為不同目的使用相同感測器與雲端。

幾個數字可顯示系統是否正常運作。預測是否需要灌溉或應使用哪種肥料的分類模型，以準確率、精確率、召回率等指標評分，EcoGrow的97.39%就是一項準確率。預測土壤水分等連續值的模型，使用平均絕對誤差 (MAE) 與均方根誤差 (RMSE) 量測觀測值和預測值之差。這些數字再漂亮，技術是否真的幫助農業仍需以其他標準重新衡量。水分利用效率 (WUE) 表示使用1立方公尺水能生產多少作物；氮利用效率

(NUE) 表示使用1公斤氮肥能增加多少作物生物量。實際節省多少水與肥料，比AI模型的準確率更接近這項技術的真正價值。

只把規定用量直接送到根前的做法稱為灌溉施肥，也就是把肥料溶在灌溉水中送往根區。英文fertigation是irrigation與fertilization兩字結合而成。傳統方法把肥料撒遍整個土表後再供水，灌溉施肥則讓溶在水裡的肥料經滴灌管線，只送到根真正佔據的狹窄區域。義大利無土草莓栽培試驗中，感測器型灌溉施肥管理同時提升資源利用與作物表現 (Bonelli et al., 2024)。中國東北田間試驗也報告，滴灌與施肥技術結合後，養分和水分利用效率都提高 (Fan et al., 2020)。水若撒遍全田，肥料也會同樣分散，氮滲入根無法觸及的深層土壤，就直接流失。精準送到狹窄區域，能從源頭防止這種損失。

不摘葉也能判斷養分狀態的努力，不只限於無人機拍攝的照片。一項設施番茄節水栽培試驗，也就是在塑膠溫室或玻璃溫室等有屋頂設施內進行的栽培，探索利用結合可見光與近紅外線的高光譜影像設備，無損估算葉片含氮量的方法 (Hu et al., 2025)。把節水灌溉與葉片氮狀態一起監測，就能更早發現水分與養分短缺何時開始重疊。傳統方法要摘葉放入實驗室分析儀，需要時間，等待期間作物已進入下一個階段。若只用相機照射葉片便能估算氮狀態，灌溉施肥決策就可立即作出，不必延遲一、兩天。

另一股趨勢服務無力負擔昂貴伺服器的小型農場。研究正探討在資源有限的農場部署低價、低功耗邊緣AI與TinyML，也就是縮小到連極小微控制器都能運行的人工智慧模型。資料不必每次送到雲端等待回應，而是在田裡的小型裝置立即完成判斷。這種本地自足型AI，最適合通訊容易中斷的偏遠地區，以及網路費用造成負擔的農場。結合物聯網裝置與機器學習的智慧灌溉系統研究，一再證實只靠便宜感測器與微控制器也能自動灌溉 (Kathilkar et al., 2026)。設備價格已大幅下降，剩下的課題看來是增加懂得操作設備的人數。

長期留在田裡的感測器會隨時間變得不可靠。經常施肥的土壤累積更多鹽分，水分與微生物薄膜黏附在感測器表面，使水分與電導度感測器靈敏度逐漸降低。剛安裝時準確的讀值，幾個月後可能低於或高於真實值，這就是漂移，也就是量測值隨時間逐漸偏離原始基準。若漂移數週未被發現，系統可能一直命令向已經夠濕的土壤供水。為防止這種情況，能由軟體自動重新對齊感測器數值的自我校正式虛擬感測器技術，以及使用耐腐蝕奈米材料的感測器，正持續研究。與其定期擦拭長期接觸土壤後變霧的窗戶，不如換成一開始就不會變霧的材料，道理相同。

單一感測器能代表的土地面積，比想像中小。廣闊露天田地或大型溫室裡，土壤性質、坡度與作物葉片密度會隨區域不同，同一時刻，某一區可能潮濕，另一區卻乾燥。若只依一個點感測器，向全田供應相同水量，濕的地方會更濕，乾的地方仍然乾。即使同在一座溫室，入口附近畦列與深處畦列接收的陽光和風也不同，因此不能因為作物

都在同一屋頂下，就只信一個感測器。把無人機多光譜影像、空間插值與地面感測器資料即時整合的多尺度融合技術，被視為下一階段課題。

設備降價不代表導入就毫不費力。ESP32等零件便宜許多，但要把它們組起來，並針對特定農場重新調整模型，仍需付出相當多工作。學習與熟悉農務完全不同的畫面和數字，本身就是實際導入障礙。為降低門檻，系統加入直覺式手機介面、AI聊天機器人與多語音聲引導。與購買機器的成本相比，熟悉機器的成本仍高得多。

只用過去資料訓練的模型，碰到從未經歷的情況就會不穩。遇上前所未有的熱浪或突然乾旱，受歷史資料固定的模型可能給出荒謬答案。為修正弱點，研究人員正探討線上自適應學習，讓模型持續吸收新進田間資料並自行更新。若再結合DSSAT或AquaCrop等模擬作物完整生理反應的生物物理作物模型，就能進行多目標最佳化，同時滿足節水與保護產量。感測器與AI再精密，對手仍是每次都換一張面孔到來的天氣。

同時滿足多項目標的計算並不限於理論，而會先在實際栽培地的試驗區驗證。重複控制試驗中，溫室一區用傳統方式供水，旁邊另一區只供應AI計算的水量，再比較兩區產量與用水。只有累積這些試驗，才能區分特定條件下的上限數字，以及多數農場可期待的平均減幅。若沒有像內布拉斯加案例那樣坦率驗證數字的程序，新技術很難取得農民信任。

土壤連續體的物理量量測、生長階段模型、多種機器學習模型推論與雲端決策，最後累積成一個開關閥門的命令。節省水與肥料的決定，交給土中每個感測器送來的數字，以及讀取數字的程式碼。隔天早晨，栽培者在手機查看前一晚供應了幾公升、幾點供應，只有圖表出現異常尖峰時，才穿上雨鞋走進田裡。栽培者的角色，已從親自作出每一次灌溉判斷，縮小為事後檢視系統的決定。

資料來源與參考文獻

學術論文

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>

演講與影音資料

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). Climate Change and the Future of Agriculture: The Importance of Data-Driven Agriculture Using ICT and IoT [Online Seminar Video]. YouTube. <https://www.youtube.com/watch?v=iqLmEFT1wZo>
3. 農林水産省(MAFF). (2025). Chugoku-Shikoku Regional Smart Agriculture Promotion Forum 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). FY2025 NARO Mesh Agricultural Weather Data Analysis Challenge! YouTube. <https://www.youtube.com/watch?v=w1SrS3iwA4E>

報告與新聞

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). [AI灌溉排程與內布拉斯加田間試驗比較研究相關資料]. <https://www.sciencedirect.com/science/article/pii/S2772375525002151>
3. arXiv. (2026). [在農業現場部署低價、低功耗邊緣AI與TinyML之趨勢相關資料]. <https://arxiv.org/pdf/2603.15085>

4.2

時空資料融合與流通及品質管理

凌晨4點，一輛冷藏車駛入南部某農產品物流中心的卸貨區。棧板上堆放的每箱草莓都貼有指甲大小的電子資料記錄器，車門一開，顯示器上的數字便從接近冰點猛升至將近攝氏10度，幾分鐘後車門關上，數字才緩緩下降。這些短暫的溫度波動，每一次都會實際縮短草莓剩餘的保存期限。草莓從離開田間到進入消費者的冰箱，量測溫度、濕度與氣體濃度的感測器隨著流通階段轉換，不斷交換資料。

問題在於，衛星、無人機與地面感測器以不同週期蒐集資料。衛星每4至10天返回同一軌道，一次掃描數百公頃。無人機只在有人決定起飛的日子作業，卻能細密拍攝小至手掌般的區域。設置在田間與溫室的地面感測器則以數秒為間隔，不停產生讀值。將三種設備的紀錄疊合時，時間與空間尺度彼此不同，無法讀成一幅連貫的影像。精準農業的產量預測與災害預警之所以經常失準，正是因為這些尺度差異。

產業界把對齊這些尺度的工作稱為氣候智慧型農業，也就是CSA資料管線。衛星的光學及多光譜影像、無人機的高解析度影像、地面感測器的即時讀值，先在相同座標與時間尺度上完成時空對齊，接著由混合式深度學習與圖神經網路，也就是GNN，將它們合併成一股資料流，其中GNN把每塊農田表示為節點，把相鄰農田的關係表示為連線，並從這種網狀結構學習。融合後的資料會預先找出可能發生乾旱逆境或病蟲害擴散的區域，再依當年氣象情境計算合適的播種與採收時機及預期產量。

檢視目前使用的幾種模型，可以更容易掌握這套網路的結構。AMSTF，也就是自適應多光譜時空融合模型，與GNN及長短期記憶神經網路，也就是LSTM，組成的混合模型，會把衛星和無人機在不同時間取得的多光譜影像，與地面氣象及土壤時間序列結合，高精度估算作物生長的時空變化與最終產量。串接XGBoost、CatBoost、LSTM三種演算法的融合模型，則使用溫度、降雨、濕度等氣象變數的時間序列、農藥投入量，以及常態化差異植生指數，也就是NDVI，透過迴歸預測產量。另一種使用視覺轉換器，也就是ViT的管線，會把衛星、無人機、地面感測器，甚至工作人員智慧型手機相機取得的影像切成小區塊，透過自注意力比較彼此關聯程度並進行學習，最後產出田區層級的作物診斷圖與氣候應變處方。這些模型的測試中，表示實測值與預測值吻合程度的決定係數通常介於0.85至0.95，而有一份報告指出，因作物邊界被錯分為不同區域而造成的空間誤分類率，從9.8%至12.3%降至5.4%。這些數字背後，是把尺度不同的三類感測器讀值放到同一基準上所需的繁重對齊工作。

自注意力這個詞聽來陌生，但可以用教室裡的小組作業理解。每位學生判斷自己應該多仔細傾聽其他同學，再逐步修正自己的意見，過程與此相似。模型會判斷衛星影像中的某一區域，和無人機影像中的另一區域及地面感測器讀值有多大關聯，為這些關係分配權重，再把權重用於最後決策。它和傳統統計模型不同，並非遵循人事先設定的規則，而是讓資料教模型哪些部分值得多留意。

疊圖在實務上如何使用，看一個畫面便容易理解。農場管理者的平板電腦把整片農田顯示成綠、黃、紅斑駁交錯的地圖，紅色區域表示衛星偵測到水分逆境，近距離無人機影像又確認葉片出現捲曲。若地面感測器進一步顯示該區土壤水分確實降至臨界值以下，模型便會警告，病蟲害可能在3天內從這裡開始擴散。衛星、無人機、地面感測器三層證據必須匯聚，才能產生這一則警告，這就是精準農業資料管線的實質內容。

這套管線建立在衛星、無人機、地面感測器三個系統的實體設備上。衛星方面，Sentinel-2、Landsat等多光譜衛星一次掃描超過1,000公頃農地，定期推導NDVI、GNDVI、SAVI等植生指數與土壤水分分布。衛星感測器的優勢，是能以約為無人機20%的成本監測如此廣大的面積。無人機則以細得多的尺度檢查小面積區域。當地面取樣距離小於每像素5公分時，它會拍攝近紅外光、紅邊波段，有時還包括高光譜影像，把萎凋異常區、雜草蔓延區，以及田區內葉片形態差異放在同一張圖上。這張圖稱為處方圖，不再像過去那樣在整塊田施用相同數量，而是告訴農民只在需要的地方，投入需要的分量。

地面上，分布於溫室與露天農田的感測器即時量測溫度、濕度、二氧化碳濃度、土壤水分、電導度，也就是EC、酸鹼值，也就是pH，以及光照。長達40年的歷史氣象紀錄、每週預報、細網格農業氣象資料、土壤調查資料，以及收錄超過30,000種作物品種的資料庫，接著透過雲端管線匯集。過去農民只能查看單一田區的讀值，現在可以同時打開全國氣象圖與品種特性表，從中定位自己的田區。農機也發生變化。日本已有案例在茶樹修剪機等專用農機上安裝PLC，也就是控制機械的小型電腦、GPS與自動轉向感測器，把作業時間、行駛距離、速度、作業高度及寬度自動上傳雲端。川崎機工、落合刃物工業、寺田製作所參與的茶園管理計畫累積作業紀錄後，可以視覺化呈現不同農場之間的作業特性與田區條件差異。衛星與無人機從空中俯視，農機紀錄則保存地面留下的足跡，日後可用來追查流通履歷。

這些特性各異的資料收集到同一處後，還必須加工處理。衛星影像因雲層遮蔽形成的空缺，以及感測器短暫停止運作留下的遺漏值，會用自適應卡爾曼濾波這種統計技術補齊並濾除雜訊。資料再經常態化，使數值落在0至1之間，並透過旋轉或翻轉影像進行資料增強，擴大樣本，避免訓練資料偏向一側，完成進入模型前的準備。以上是作物在田間生長期間的故事。作物採收裝箱後，同一套邏輯會轉向另一個目標。此時量

測的不是生長而是腐敗，追蹤的不是植生指數而是溫度與乙烯氣體，但把不同設備的不同尺度合併後再做決策，原理並未改變。

貼在草莓箱上的資料記錄器只量測溫度。商用冷鏈管理箱如今愈來愈常同時配備溫度計、濕度計、二氧化碳感測器、乙烯氣體感測器，以及用顏色變化顯示新鮮度的疏水性指示標籤。無須切開果肉便能判定糖度與酸度的近紅外光譜儀，及偵測表面損傷的3D視覺相機，也加入這套設備。這些裝置的共同點，是完全不接觸也不損傷表面。即使不開箱，也能讀取車內一盤草莓的糖度、損傷與新鮮度。

把這些設備產生的訊號合併成一個判斷，具代表性的模型是協同注意力卷積循環網路，也就是Co-ACRN。中國江南大學研究團隊在2026年發表的這套模型，會同時接收冷鏈運輸期間累積的溫度、濕度、二氧化碳、乙烯時間序列資料，以及疏水性指示標籤影像。前端的協同注意力模組會對齊影像與感測器資料流的時間軸。後端的自注意力模組再檢視已對齊的資訊，納入整體脈絡，以非破壞方式即時產出蔬果新鮮度分數。新鮮度分數的計算公式很直觀，用100減去缺陷佔總表面積的百分比。沒有缺陷的產品分數接近100，腐壞一半的產品則降至50左右。

這類多感測器融合不限於江南大學的案例。結合溫度、相對濕度、乙烯、二氧化碳、箱體承受的震動、位置資料、影像特徵與光譜訊號，已成為保存期限預測模型的常見方法。產業評估通常把三種應用列為可立即優先導入的項目，包括電腦視覺分級、以物聯網為基礎的冷鏈監測，以及保存期限預測。相機與感測器可以加裝在現有物流設施上，不必全面汰換，但改變栽培方式本身需要更長時間。理論再耀眼，技術終究要裝上管線、冰箱、卡車這些老舊硬體，因此通常會先從較容易介入之處導入。

美國冷鏈設備公司DeltaTrak把預測式保存期限分析描述為改變冷鏈新鮮度管理方式的技術。這類分析通常即時收集冷藏貨櫃的感測器讀值，預先告知出貨商與零售商，每箱產品進入商店貨架前還剩多少時間。椰棗等難以只從外觀判斷內部狀態的水果，則採用另一種方法。已有研究利用多通道氣體感測器，讀取果肉成熟時釋出的氣味分子組合，再把數值輸入機器學習模型估算保存期限。成熟與腐壞的果實會釋出不同組合的氣味分子，機器把這些差異讀成氣體感測器的電訊號模式。

分級工作展現另一種方法組合。日本新潟縣的西洋梨品牌Le Lectier，使用結合GCBlock的Mask R-CNN影像分割模型，以像素為單位切分梨子表面的缺陷與污染區域。擷取出的污染面積比例不會直接轉成等級，而是先經過一種稱為模糊邏輯的方法。模糊邏輯是一種處理冷熱之類無法截然劃分界線的計算方法。污染3%可以明確判為高等級，30%可以明確判為低等級，但介於兩者之間的模糊數值，會像人類檢查員的目視判斷一樣，把機率分配到數個等級。得出的數值會進入含有專家經驗規則的模糊推論系統，自動決定最終等級。

最終等級分為四級，從蓋有紅色印章的最高等級「赤秀」，往下依序為「青秀」、達到可接受水準的「良」，以及難以作為商品販售的「無印」。過去有人整天逐顆翻動梨子並蓋章，如今相機與模糊規則接下了這份工作。由於每種水果的特性不同，產業界不會使用單一統一模型。芒果、番茄、奇異果的果皮厚度、顏色與軟化速度不同，因此會使用DenseNet、EfficientNet系列模型，同時分級外觀與內部成熟度。西洋梨以表面缺陷決定等級，番茄更看重顏色，奇異果更看重硬度，分級標準本身會隨水果而異。

這些評估模型的測試結果往往相當高。準確率、精確率、召回率、F1分數等分類效能指標，經常落在95%至99%，研究也會報告量測缺陷區域分割精度的mAP與IoU。mAP會在多個臨界值上取平均，衡量模型找出的缺陷位置和實際缺陷位置重疊得多接近，而IoU則用兩個區域的重疊面積除以聯集面積，數值愈接近1，代表分割愈精確。從數值來看，機器給出的分數已達到足以與過去人工目視分選相比的水準。

這項變化的影響不只在減少人力。人工檢查員上午與下午的專注程度不同，反覆作業養成的習慣，也可能使同一顆梨子在不同日子得到略微不同的等級。相機與模糊規則不會疲倦，整天、整季都維持相同標準。不過，人們經年累月獲得的細微感覺，例如一顆水果外表完好、內部卻可能已經變軟，機器能否完全比擬，仍有待觀察。

農產品完成分級後，會直接進入庫存與追溯管理。田間或溫室採收的農產品依籃子或鐵架分組，每個單位都會取得條碼、QR碼或智慧標籤。臺灣高雄的智慧農業計畫是具代表性的案例。計畫利用貼在藍色塑膠籃或鐵架上的標籤，把田區批次庫存即時上傳資料庫，並把溫室環境警報自動連結至政府的農產品產銷履歷制度。多層栽培架與物流倉庫的空間使用率也有改善。每個標籤都提供一條查核箱件來源與移動路徑的線索。

發生事故時，追蹤功能便會派上用場。國合會在2025年介紹的案例中，農場生產資料與食材供應商資料透過單一商圈地圖平台串接。若學校營養午餐發生食品安全問題，系統會立即追查該餐食材來自哪位農民的田區。接著，系統會找出所有收受同一農場產品的其他學校，以便立刻採取預防措施。方法已從事故發生後查找原因，轉為在事故擴散前先確認關聯範圍。

掃描農產品批號，螢幕便會顯示該箱產品的田區與採收日期，以及它經過哪些卡車與物流倉庫。錯誤配送的書籍或工業產品可以召回，但腐壞農產品一旦端上餐桌便無法收回。因此，追溯系統的價值不在事故後收拾殘局，而在事故蔓延前，能以多快速度把影響控制在狹窄範圍內。

單一保存期限預測值仍只是片段資訊。如今出現模組化系統，把保存期限預測、美國《食品安全現代化法案》要求的追溯，以及碳排放計算放在同一資料基礎上，讓生產

者、出貨商與零售商查看同一個畫面。過去要分別登入數個系統，如今改為存取同一資料基礎。2018年前後以預測分析為中心的採後管理技術，此後逐漸轉向區塊鏈與數位孿生，輕量化人工智慧TinyML則在電力或通訊基礎設施受限的現場支援追溯與資訊揭露。當保存期限、履歷與碳排放同時出現在一個畫面上，新鮮度劣化風險與追溯缺口，便愈來愈常在同一時間、同一箱產品上浮現。

物流倉庫裡，YOLOv5、YOLOv8等深度學習物件偵測模型會即時計算進出箱數，再把結果連接到複製整座倉庫的虛擬模型，也就是數位孿生。管理者即使坐在辦公室螢幕前，也能確認每個貨架堆了什麼、數量多少，以及哪些區域的溫度或濕度讀值超過臨界值。發現問題時，管理者可以先在虛擬模型中測試介入方式，結果可接受後，再對實體倉庫採取相應行動。

數位孿生是重現物流倉庫實際狀態的虛擬模型。每一箱新進倉產品，以及溫度稍微升高的每一座貨架，都會即時反映在虛擬畫面上，管理者可以放大查看任何區域。實體溫度計與虛擬畫面的數字若開始分歧，可能代表感測器故障或通訊延遲。管理者因而可以同時查看實體倉庫與虛擬模型。

凌晨物流中心驟升的溫度值，最後會化為這幅虛擬畫面上的一個資料點。每次卡車開門造成的短暫尖峰，肉眼看來或許微不足道，在數位孿生中卻會留下紀錄，管理者可以比較卡車當天開門幾次，溫度是否比其他車輛更常波動。若某輛車出現異常惡劣的模式，紀錄便能促使人員檢查冷藏設備。零散讀值看不出的模式，要等資料累積後才會浮現。

日本高知縣的植物物聯網，也就是IoP SAWACHI雲端，把這個概念擴展到整個地區。它把超過1,600座溫室的環境資料，以及超過3,000家農場的出貨資料，連接至日本國家農業資料平台WAGRI，再運行16套分析模型，預測區域總出貨量並安排流通時程。過去逐一記在各農場的出貨資訊，已擴大成用來預測高知縣整體出貨量與調整流通時程的資料。和各農場分別估算下週出貨量的舊做法相比，這種方式更接近同時查看整個地區的供需，再排定先後順序。

這些案例中反覆出現的指標，可以歸納為幾類。空間使用率量測多層栽培架與物流倉庫被填滿的程度，生產流通追溯率量測發生問題時，成功追查到生產農場與配送目的地的案例佔比，減量率則量測精準處方與管理所減少的農藥和能源用量。高雄栽培架與臺灣學校營養午餐追溯案例的成果，經常換算成這三類數字之一。每個數字單獨看來或許不大，但倉庫空間一次次多用一些，事故一次次提早數日發現，對農場整體利潤會產生實質影響。

西洋梨、芒果、草莓各自需要訓練不同模型，是這個領域的隱藏成本。生產區若栽培超過10種產品，便要建立超過10套模型，每一季還要用新資料重新訓練。作物有多

少種，就要維護、更新多少套模型，負擔相當沉重，大型流通業者以外的企業可能難以承擔這筆成本。因此，研究方向似乎正轉向建立可跨多種水果運作的單一基礎模型，只針對各種水果調整最後的決策階段。

無論預測、分級與追溯多麼精確，最終決策仍由人作出。即使模型判定為無印等級，或警告病蟲害將在3天內擴散，現場管理者仍須決定是否丟棄該箱產品，或何時施用防治藥劑。資料管線、分級模型與流通追溯系統迅速且準確地準備決策所需資訊，接下來要做什麼、怎麼做，則由人決定。科技改變了判斷材料的品質與取得速度，判斷本身仍是人的責任。

截至目前談到的案例橫跨臺灣、中國、日本與美國。面對冷藏車、冷藏倉庫、供膳場所裡相同的問題，各國以略有不同的比例組合衛星資料、相機與氣體感測器，提出各自的答案。使用的語言與政府組織不同，目標卻一致，都要捕捉溫度驟升的瞬間，提早數日找出一箱腐壞產品。認為科技正跨越國界，朝相近方向匯流，並不為過。

不過，這些系統彼此之間仍無法順暢溝通。臺灣的農產品生產追溯制度、日本WAGRI、美國《食品安全現代化法案》，分別使用不同欄位與編碼系統記錄履歷。一國栽培的農產品跨境銷售時，仍需投入大量人工，把紀錄轉移到不同帳冊。除非建立共同標準，使同一批號在每個國家都代表相同意義，跨境追溯的最後一段流程，短期內恐怕仍須經過人手。

這幅圖景尚未完整。衛星每隔數日一次的觀測、偶爾起飛的無人機、以秒為單位的地面感測器紀錄，三者之間的尺度差異，即使透過時空插值與生成式人工智慧進行高解析度重建研究，仍未完全解決。冷鏈箱內的高濕度、鏡頭凝結的霧氣、上下波動的氣體濃度，會逐漸扭曲光學與氣體感測器的讀值。如同眼鏡起霧後視線變得模糊，感測器遇到濕氣，也無法準確讀取原本的目標值。解決這個問題，似乎需要由軟體自動修正數值的校正演算法，以及耐濕的表面材料。

農場蒐集的資料歸誰所有、如何定價及交易，還有如何訂立規則，在用區塊鏈防止竄改的同時保障農民權利，這些問題看來需要制度而非技術來處理。另一項未來課題，是在物流倉庫的數位孿生中加入可解釋人工智慧，讓機器用文字告訴現場管理者，為何把這箱產品判為無印等級。農民只拿到等級卻不知道原因，可能因看不見判斷依據而感到困惑。當分級主體從人轉向機器，系統也必須說明機器查看了什麼，又如何得出判斷。

冷藏車溫度記錄器產生的資料，會透過同一條管線，連接衛星影像、物流倉庫的數位孿生，以及供膳場所的履歷查詢畫面。在這種結構中，任何一個階段的紀錄中斷或出錯，其餘階段的判斷也會跟著失準。尚待處理的工作，是統一各國不同的追溯編碼系統，並降低溫度、濕度與氣體感測器等怕潮設備的量測誤差。

資料來源與參考文獻

學術論文

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.

報告與線上資料

1. CABI Digital Library. (2026). 人工智慧採後管理與保存期限預測趨勢回顧. 『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). 多通道氣體感測器椰棗保存期限估算機器學習模型相關資料. *PubMed Central*. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC12252097/>
4. 整合保存期限預測、追溯與碳會計的模組化資料型系統初步論文. (2026). *arXiv*. <https://arxiv.org/pdf/2511.05920>

演講與影音資料

1. 高雄農來訊. (2025). 114年高雄智慧農業年度成果發表暨研討會. YouTube. <https://www.youtube.com/watch?v=1Edc6pP4HnU>
2. 氣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

基於 AI 的數位表型分析與育種生物工程

5.1 高通量作物表型分析

懸掛在溫室天花板軌道上的龍門設備，每次經過盆栽前方時，都會用多台相機從不同角度拍照，再匯集這些照片，自動建立每株植物的立體模型。過去人員拿著捲尺在溫室來回走動、花上一整天進行的量測，這套設備能在一夜之間對數千個盆栽完成。近年來，從照片重建立體模型的運算速度也大幅提高。2026年發表的3D基礎模型，將平均6分31秒的重建時間縮短到1.58秒，而3D高斯潑潑法達到每秒6.39個影格的處理速度。

機器以這種方式量測植物外觀的工作稱為表型分析。種子裡的遺傳資訊在實際長成的植物上表現為株高、葉片大小、莖粗與罹病痕跡等形態，這些特徵稱為表型，而量測與記錄這些特徵的整套工作就是表型分析。長久以來，這項工作都由人員負責。育種人員親自用捲尺量株高，以肉眼查看葉色並為病害程度分級，有時還會拔起整株植物秤重。人工作業會因當天的狀態與觀察能力產生誤差，而且測試一個品種就涉及數千到數萬個品系，因此從一開始就不可能在整個生育期觀察全部個體。育種現場早已知道這個瓶頸，卻一直缺少合適的突破工具。

感測工程、機器人與人工智慧共同製造了這項工具。雷射與相機代替人員量測植物，無人機與輪式機器人走遍田間和溫室各處收集照片與影片，深度學習則從影像中辨識葉片和果實。這三者結合而成的技術稱為高通量作物表型分析，英文為 High-Throughput Phenotyping，通常簡稱HTP。若與人員一天量測一百個盆栽的速度相比，HTP設備能在同樣時間內量測數千個，而且不會碰觸盆栽或摘下葉片。談到智慧育種時總會提及這項技術，原因是篩選優良品種的第一步是精確量測，而HTP把這一步交給機器完成。

HTP的核心原理，是在不傷害溫室與田間植物群落的情況下，快速拍攝其立體結構與光反射特性，再把資料放進基因、環境和外觀相互作用的架構中轉換成數值。同一批種子在供水較多和較少的田區也會長得不同。外觀不是只由一個基因決定，而是基因與環境共同造成的結果。育種人員取基因型、環境與表型的首字母，把這種關係稱為 $G \times E \times P$ ，而HTP負責補上其中最難量測的最後一項，也就是表型。若缺少表型，無論基因圖譜畫得多好，都無法確認它在實際田間是否正確。

雷射掃描是拍攝立體結構的常見方法之一。光達（LiDAR）發射雷射並以微秒為單位量測光線撞擊物體後返回所需的時間，藉此計算距離，再把數百萬個距離值標成座標

，讓每個點匯聚成仿照植物外形的立體影像。這些點的集合稱為點雲，原理類似以無數沙粒般細小的點拼出臉部輪廓的馬賽克。PhenoSpex的PlantEye F600是具代表性的雷射掃描器，能建立點距僅0.1毫米的高密度點雲。這套設備配備同時量測近紅外光與紅光反射率的感測器，因此在取得立體形狀的同一刻，也能算出顯示葉片健康程度的常態化差異植生指數（NDVI）。把彩色影像與距離資訊放在同一張圖中的RGB-D深度感測器、疊合兩台以上相機的照片並依視差計算距離的立體視覺，以及拼接多角度照片的多視角立體重建（Multi-View Stereo, MVS），也都用於相同目的，而這些方法與人的雙眼判斷距離的原理相似。

電腦會從取得的點雲中，自動擷取過去由人員使用捲尺量得的數值。株高、葉片覆蓋面積、葉片伸展角度、莖粗以及葉片重疊形成的體積，這些過去必須逐項手工量測的項目，如今分析一份點雲就能一併算出。若每天在同一時間量測數千個盆栽，顯示植物每日生長幅度的生長曲線也會自動繪出。需要處理遠大於溫室的田地時，只靠這種地面掃描器仍不夠，還需要一雙從空中俯視的眼睛。

這雙眼睛由無人飛行載具UAV擔任。低空飛越田地的無人機會同時搭載超過2,000萬像素的超高解析度彩色相機，以及把藍光、綠光、紅光、紅邊和近紅外光分成五個波段拍攝的多光譜感測器。設備還可加入把400至1000奈米之間的光細分後拍攝的高光譜感測器，以及以色彩顯示表面溫度的熱影像感測器。MicaSense的多光譜感測器是無人機上常見、用來拍攝這五個波段的設備。收集到的影像會轉換成顯示整片田地由葉片覆蓋多少的植生覆蓋率，以及NDVI、GNDVI與SAVI等植生指數。罹病或乾枯的葉片反射較少近紅外光，也無法吸收紅光，而健康綠葉中的葉綠素會吸收紅光並強烈反射近紅外光，因此兩個波段的反射量差異能以一個數值顯示葉片的健康程度。一架無人機在低空飛行數小時，就能掃過數十公頃田地完成植生指數地圖，並以顏色標出停止生長的區塊位置。

從照片和點雲中分離葉片、花朵與果實的工作由深度學習負責。CNN、視覺轉換器（Vision Transformer, ViT）與圖神經網路（Graph Neural Network, GNN）等模型承擔這項工作，而在一張影像中逐像素沿著物體邊界描繪並切出的作業稱為實例分割。可以把它理解為將一個玉米穗、旁邊的另一個玉米穗，再旁邊的一片葉子標為不同物體的工作。若在數天或數週內，從同一位置反覆拍攝切出的器官，就能循時間追蹤葉片展開和果實膨大的速度，而這些變化可用來預先估計總重量、生物量與最終產量。

在中國河南省的一處玉米田，這種實例分割已實際穿梭於田間。輪式地面自主移動機器人UGV緩慢行經玉米行間，以前方的大型全景相機掃視左右。正午陽光不斷變化，上層葉片又遮住下方玉米穗，即使用肉眼也不容易數清長了多少穗。部署於此的CornYOLO模型以輕量神經網路YOLO11n為骨幹，並加上影格重組模組（FRM），連被葉片遮住、只露出一半的玉米穗也能找到。作為準確度指標的平均精度（mAP）

達91.5%，可視為已達到與人工目視計數相當的程度。機器人繞田一周時，每株玉米有幾個穗、位於何處都會自動累積成表格，這份表格直接成為篩選產量相關性狀的基礎資料。

觀察玉米與稻作的開花時間也使用類似方法。把YOLOv5與視覺轉換器套用到無人機從上方拍攝的群落影像，就能依雄穗（Tassel）伸出多少，分成尚未開花、剛開始開花與已完全盛開三個階段自動辨識。匯整結果後，顯示整個田區目前處於哪個生育階段的生育指數會自動算出，讓過去人員每隔幾天巡田並憑目測判斷的開花期，可以用更密集的時間間隔重新確認。對育種人員而言，開花時間是決定哪些品系彼此雜交的標準，而這項標準只要精確到每天，就會改變雜交設計的成功率。

不是每個農場都有條件重新建立CornYOLO之類的專用模型，因此任何人都能下載使用的開源工具也在發展。PlantCV v2把分析影像中葉片顏色與形狀的程序寫成腳本，使用者只要放入自己的照片，就能自動取得葉面積、冠層體積與變色比例。kmSeg以K-means統計方法把顏色分成數群，藉此區分植物與背景，PhenoImage則大量處理葉綠素受光後產生的螢光影像。即使研究經費不充裕的大學實驗室，也能藉這些工具進行接近大型企業水準的表型分析。

溫室內已把設置龍門架或軌道的固定式設備確立為標準。LemnaTec、PhenoSpex與Field Scanalyzer等公司的設備，會在溫室或有屋頂的試驗田鋪設軌道，於指定時間自動運送數千個盆栽或試驗小區通過掃描器下方。機器依照人員指定的順序和時間日夜運轉，因此凌晨3點也能用與中午12點相同的條件再次量測同一盆栽。這種重複性無法由人工仿效，卻正符合每天必須在相同角度與亮度下拍攝同一株植物的表型分析需求。

在溫室外沒有屋頂的廣大田地裡，情況不同。面積大到無法鋪設軌道，因此配備即時動態定位RTK-GPS導航、位置誤差控制在2公分以內的無人機與地面機器人會取代軌道設備。無人機從空中掃描廣大區域，地面機器人則從群落下方的視線高度近距離查看玉米穗，兩者分工後能在數天內巡查種有數千個品系的整座育種試驗田。兩台設備交換的位置資訊位於同一座標系，因此日後也能把無人機從上方取得的資料與機器人從側面取得的資料疊合在一起。

針對設備採購預算有限的現場，也已出現低成本替代方案。MVS-Pheno、LITERAL等裝置，以及只在Arduino微控制器上連接幾台相機的小型設備，也能進行3D重建。價格只有商用龍門設備的數十分之一，卻足以讓小型實驗室或一個農場自行掃描一小塊田地。現在即使沒有昂貴設備也能開始進行表型分析。

目前談到的設備都量測地面以上的可見部位。根系埋在土中，情況完全不同，而MultipleX-Lab與RhizoPot等裝置把植物種在透明管內，讓光線穿過管壁拍攝根系陰

影，以此解決問題。它們不必拔起根系，就能隨時間反覆記錄側根向四面伸出多少條以及深入多深，因此可用於篩選抗旱根系結構的育種。這些裝置從地下補足只看地上部影像無法取得的資訊。

無論相機多精密，拍攝的影像仍會同時包含土壤、礫石、雜草與陰影等雜訊。第一階段會用改變色彩空間的算式，以及ExG與CVI等指標分開綠色植物和其他物體，再配合沿地形篩選的拓撲濾波。點雲包含的點太多，若直接處理會超出電腦負荷，因此先通過為植物學習去除雜訊的Plant-denoising-net（PDN），以及均勻刪減點數的自組織映射降採樣（SOM Down-sampling），縮小到容易處理的規模。必須連一粒土和淡淡的陰影都濾除，下一階段才能處理只留下植物的乾淨形態。未經這種整理的原始點雲會混入雜訊，干擾下一階段的計算。

從多張去除雜訊的照片重建一株植物的立體形狀時，會同時使用多視角立體重建演算法，以及能更敏銳找出邊界的視覺轉換器Edge_MVS-Former。建立的3D模型再通過TrackPlant3D等實例分割神經網路，把莖和葉逐一分離並整理成器官單位。問題在於速度。舊方法接收數十張照片後，要花數分鐘才能完成一個整齊的立體模型，而在每天必須重新拍攝數千個溫室盆栽的育種現場，這幾分鐘不斷累積，成為佔去整天排程的負擔。

神經輻射場NeRF（Neural Radiance Field）為速度問題提供了線索。NeRF把數張不同角度拍攝的照片輸入神經網路，讓網路自行學習推測從3D空間任一位置朝任一方向觀看時，該處的色彩與光線強度。神經網路會合理補上照片之間的空隙，也就是相機未拍到的角度，因而建立比過去自然得多的立體場景。可是每次要繪製畫面上的一個點，都必須逐一詢問神經網路，因此長期背負著精密但緩慢的評價。2026年發表的3D基礎模型正面推翻了這項評價。它先大量學習多種植物的影像，收到新植物照片時直接移用既有學習結果，把平均6分31秒的重建時間縮短到1.58秒，同時維持形狀準確度與表型數值。

另一種提高速度的方法是3D高斯潑灑，也稱3DGS。NeRF每次都向神經網路詢問顏色，3DGS則預先把植物表面塑造成數十萬個小而模糊的半透明團塊，再像散布染色棉團一樣，同時攤到畫面上完成影像。只要計算每個團塊的位置、顏色與模糊程度，顯示卡就能直接處理繪圖，無須經過神經網路的問答程序。在與既有方法Instant-NGP及Nerfacto的比較實驗中，3DGS達到每秒6.39個影格，而這項結果促使3D表現方法的重心從神經網路轉向這類顯式結構。

從多台相機拍攝的影像中，把每株植物區分為不同個體，至今仍不容易。PlantSegNeRF把不同視角影像中相同器官的配對程序結合到神經輻射場，即使樣本很少或遇到未見過的作物種類，也能分出個體層級的3D點雲。研究人員也已讓機器人自行判斷下一次從哪個角度拍攝能取得更多新資訊，名為SSL-NBV的方法採用不必

逐一提供答案的自監督學習，使機器人不需人員每次指定，就能自行選擇下一個相機位置。為了以物理上正確的比例建立實際田間規模的點雲，也有人提出五階段處理程序，依序包括拍攝影像的資料取得、區分植物與背景的語意分割、先建立少量點的稀疏重建、密集補點的稠密重建，最後是擷取表型性狀。

研究人員隨後也把大量出現的方法放在一起比較。2026年，國際期刊Frontiers in Plant Science刊登一篇回顧論文，彙整比較田間條件下以點雲為核心的3D作物表型研究，而期刊Sensors也在相近時期發表整理各類3D重建技術的回顧。兩篇回顧共同指出的趨勢，是重心正從依賴單一昂貴設備的時代，轉向組合多台低價相機與高速軟體的時代。

多種方法能否在實際環境中使用，要用數項指標確認。玉米穗或葉片等目標的辨識表現以平均精度（mAP）衡量，切出葉片的邊界與真實邊界重疊多少則以IoU重疊比率衡量。雷射或相機建立的立體模型與尺量實際尺寸的差距，以均方根誤差RMSE標示到毫米，而現場小型電腦處理一張影像所需的時間及每秒處理張數，則是判定能否即時運作的標準。破壞性調查直接量得的重量或株高，與只用影像估出的數值彼此吻合多少，以決定係數表示，而多項研究的決定係數已超過0.75，逐漸形成影像量測足以取代破壞性調查的依據。開花階段或病害等級這類不是數字而是分級的性狀，另以F1分數與混淆矩陣驗證。

相機與機器人每天產生的照片、點雲和數值種類各異，規模也不同，研究人員若要共享，就需要一套整理好的約定。這套約定的基本架構是FAIR原則。它包含可尋得（Findable）、可存取（Accessible）、不同程式之間可互通（Interoperable），以及日後能再使用（Reusable）四項條件。為感測器拍攝的原始影像、處理後的3D點雲、拍攝時間與位置、最後擷取的表型數值，全都加上何時、何地、拍攝何物的標籤並整理到中央資料庫，就是實踐FAIR原則的方法。

PHIS（Phenotyping Hybrid Information System）是把這項原則落實為具體系統的案例。PHIS採用Plant Ontology（PO）標準術語體系，為溫室或田間中的每個試驗對象、感測器與事件分配唯一名稱。盆栽從溫室一側移到另一側、葉片出現斑點，乃至溫度感測器的讀值，全都以唯一永久識別碼URI連接，因此幾年前的試驗資料和本月資料可以依同一標準比較。這種識別碼體系在試驗資料層級實現了FAIR原則所要求的互通性與再使用性。

與PHIS搭配的OpenSILEX，是把分散各處的表型資料及處理這些資料的網路服務，連接到同一條標準通道的軟體架構。國際學界也另行規定記錄表型試驗時至少必須保留哪些資訊，而名為MIAPPE（Minimum Information About a Plant Phenotyping Experiment）的規範，要求完整記錄試驗地點、日期、栽培條件與量測方法，PHIS和OpenSILEX等系統都把它作為基礎架構。處理田間試驗環境、農作紀錄和氣象資料

的ICASA Version 2.0標準也用於類似目的。不同國家和大學實驗室各自使用不同名稱的資料，會由這幾套規範轉換成共同語言。

整理好的表型資料要與基因體資料結合，價值才會提高。CropGS-Hub與PHENOPSIS DB等資料庫把基因體資訊和高通量表型資料集中在一處，讓基因體選拔（Genomic Selection）模型不必分別尋找兩類資料，就能直接銜接使用。如果表型資料庫未遵循標準規範，量測外觀與讀取基因的技術就會採用不同格式和規格，甚至無法完成與基因體資料的連接工作。

在實際使用PhenoSpex PlantEye的溫室裡，一台掃描器每天經過相同盆栽，逐日累積冠層高度、葉面積與葉片傾斜角度。這些數值會原樣複製到電腦裡的虛擬溫室，也就是數位孿生（Digital Twin），在畫面中建立與實體溫室並行生長的第二座溫室。栽培管理人員反向計算畫面中的虛擬植物需要多少水和養分，以決定實體溫室供液閥門開關的時間與供應量。植物不會開口說口渴，葉片傾角與冠層體積的變化會代替它傳遞訊息。

在種植大豆與冬小麥的育種試驗田，一架無人機會同時搭載多光譜感測器和光達飛行。以不同權重合併計算冠層高度與葉片顏色資訊，就能相當精確地估計田間地上部生物量及其中的氮含量。收穫期還能以群聚計算法，自動數出影像中彼此重疊的大豆莢，因而在翻耕田地並實際秤重之前，先靠一張無人機影像篩出可能高產的品系。

處理花卉與果樹的大型研究機構會同時導入OpenSILEX和PHIS，以承擔整批資料。每天累積數萬張彩色照片、3D影像、感測器即時傳送的數值與各品種基因型資訊都匯入同一系統，而Plant Ontology標準名稱標籤消除了不同研究團隊對同一盆栽使用不同名稱造成的混亂。尋找與分享資料的程序減少後，研究人員能直接進入下一階段，把人工智慧育種模型接上資料。標準化不會直接產生亮眼成果，卻能顯著縮短獲得成果所需的時間。

儘管已有這些成果，仍有多項問題尚未解決。作物長大並形成茂密群落後，上層葉片會遮住下方花朵、果實與病徵，因此只把一台相機或雷射掃描器架在上方，經常完全看不到下層性狀。目前較可行的解法，是由地面機器人和無人機從不同角度共同拍攝，並改進點雲修復運算，利用周圍資訊補齊因遮蔽而未拍到的葉片。在一張整片葉子完全消失的影像中完美還原葉形仍很困難，但現場判斷認為，即使只有估計值也遠勝於完全沒有資料。

資料量也是阻礙。解析度0.1毫米的點雲或包含數百個波段的高光譜影像，每一份都可能膨脹到GB規模，讓設在田邊的小型電腦難以即時處理。從刪減點數的降採樣、把大型神經網路知識移到小型網路的知識蒸餾（Knowledge Distillation），到把人工智慧運算專用晶片NPU直接裝進設備的硬體加速，各種縮減資料或加快運算的方法

正同步研究。設備越輕量，越能在田間立即提出答案，因此這場減重競爭在未來一段時間仍會持續。

戶外天候也常使人工智慧判斷失準。在強烈直射陽光下，葉面會反白而失去色彩資訊，風使葉片晃動時，同一片葉子在每張照片裡呈現不同形狀，雲層通過導致亮度不斷改變時，剛完成訓練的模型也可能在下一張影像迷失。把在溫室等光線與風受控環境中訓練的模型直接移到露天田地，準確度常會大幅下降，這種現象稱為領域偏移（Domain Shift）。主要處理方法包括在人為混合多種天候與光線條件後擴增訓練資料，以及依新環境重新調整模型的領域適應（Domain Adaptation）。未在實驗室外接受準確度驗證的模型，終究可能只成為適用於溫室內的不完整成果。

目前介紹的技術幾乎全都朝向地面上的葉片與果實，因此在同一條管線中連地下根系一起追蹤的整合表型分析，被列為下一項課題。人們也要求發展可解釋人工智慧（Explainable AI, XAI），讓使用者看懂人工智慧看了哪張影像，以及為何把該株植物判為罹病或高產。Grad-CAM與SHAP等技術會用熱圖的色彩顯示神經網路判斷時關注影像的哪些區域，只有具備這類視覺資料，育種人員才可能相信機器的判斷並制定下一輪雜交計畫。龍門設備經過後，留下的不是幾張照片，而是數百萬個座標值及從中擷取的性狀數值。這些數值依標準規範整理後，就能跨越數棟溫室，與其他國家研究機構的資料連接。育種人員因而可以用數值確認帶有特定基因的種子在不同田地如何生長。

資料來源與參考文獻

學術論文

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、中瀧太、戸田陽介。（2025）。〈「AI時代」の作物學研究〉。《日本作物學會紀事》，94(3)，329-330。

8. 大澤央、齋藤正博、八木岡敦。(2026)。<〈運用物件偵測AI開發甜玉米適收期預測技術〉。《農業食料工學會誌》，88(2)，85-91。
9. arXiv. (2026). 以3D基礎模型進行超高速作物重建並維持表型準確度的研究。<https://arxiv.org/abs/2607.01753>
10. arXiv. (2025). PlantSegNeRF：基於多視角影像實例對應的通道結合神經輻射場進行植物3D實例點雲重建。
<https://arxiv.org/pdf/2507.00371>
11. arXiv. (2024). SSL-NBV：以自監督學習選擇下一最佳視角的機器人植物3D重建研究。
<https://arxiv.org/pdf/2410.14790>
12. Frontiers in Plant Science. (2026). 田間條件下基於點雲的3D作物表型分析比較回顧。
<https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2026.1731852/full>
13. Sensors. (2026). 作物表型分析用3D重建技術綜合回顧。<https://doi.org/10.3390/s26092730>

演講與影音資料

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

預測育種與智慧生物育種技術

作物育種起源於表型選拔，也就是栽培者走進田間，只依肉眼可見的外觀挑選優良個體。後來，人們加入孟德爾遺傳定律與統計方法，計算親本與後代之間的表現，並確立了把基因特定位置當作標記、預先篩選目標性狀的分子標記輔助選拔（Marker-Assisted Selection, MAS）。接著出現一次讀取散布於整個基因體數萬個標記的基因體選拔（Genomic Selection, GS），提高了選拔準確度，也縮短了栽培一個世代再進入下一世代的時間。這套方法在種子尚未播入土中之前，就向育種人員提供其生長後可能收穫多少的預測值，這個值稱為基因體估計育種值（Genomic Estimated Breeding Value, GEBV）。它是只依每顆種子的遺傳資訊計算出的預測值。

問題出在產量這類由多個基因共同參與的性狀。株高或抗病性可能由一兩個基因決定，產量卻牽涉數百至數千個效果微小的基因，而且即使是同一顆種子，這些關係也會因種在哪一塊田而有不同表現。同一品種在乾旱田區可能表現不佳，在水分充足的田區卻可能有好成績。基因與環境相互影響的關係稱為基因型與環境交互作用（Genotype by Environment Interaction, $G \times E$ ），只使用基因體選拔，很難精密解析這種交互作用。智慧生物育種因此出現，把栽培環境資訊連同基因體和表型一起納入計算。

智慧生物育種是一種把基因體學（Genomics）、表型體學（Phenomics）與環境體學（Enviromics）三類資料，一起輸入同一個人工智慧模型的方法。基因體是種子天生具有的遺傳資訊，表型是種子生長後實際呈現的株高、葉色和產量，環境體則是作物生長田區的氣溫、降雨量與土壤性質。分開來看時，三者只是零散資訊，但讓它們通過人工神經網路的多個層級，匯入同一個潛在空間（Latent Space，也就是將不同類型資料壓縮到同一座標上比較的空間），就能看出彼此如何關聯。研究人員可以在實際播種前，先在電腦裡描繪哪種基因型在何種田地會有什麼表現。育種人員只看畫面上的排名表就能選出二十個品系，是因為這些運算早已在背後完成。

氣候變遷使乾旱與熱浪日益頻繁，預先篩出在特定環境中仍能保持穩定的品種，已成為育種核心課題。為此建立的整合基因體與環境體預測系統（Integrated Genomic-Enviromic Prediction, iGEP），會把過去氣象資料、未來氣象展望、土壤性質與位置資訊，連同基因體單一核苷酸多型性（Single Nucleotide Polymorphism, SNP，也就是個體間基因序列只有一個字母不同的變異）圖譜，輸

入多層神經網路。系統把目標栽培地區和氣候帶合稱為目標環境群（Target Population of Environments, TPE），並預先估計特定基因型在該環境群遭遇乾旱或高溫等極端條件時能支撐多久、產量多少。不必種到實際田間並等待數月，就能在一定程度上判斷哪個品種可承受明年夏季的熱浪。

有些系統還加入完整模擬作物生理作用的生長模型。APSIM與DSSAT等作物生長模型，以物理和化學方程式描述陽光、溫度和水如何轉化為葉片和果實，而把這種生長模型與基因體預測模型連接的基因體作物模型（CGM-G2P），則模擬特定基因經過哪些生理作用形成產量。傳統統計模型只顯示數值之間的相關性，這種方法則在釐清基因於植物體內實際執行何種功能的同時做出預測，因此育種人員收到預測值後，可以逐步追查其依據。

所有運算都需要資料。支援預測育種的資料中，最底層是基因體本身。研究人員以次世代定序（NGS）和一次讀取較長區段的第三代定序技術重新讀取整個基因體，找出單一核苷酸多型性、插入缺失（InDel），以及大型結構整體改變的結構變異（Structural Variant, SV）。由於一張單一品種的基因體圖譜並不足夠，研究人員還會使用疊合多個品系基因體製成的泛基因體（Pangenome）圖譜。基因實際表現量的轉錄體學（Transcriptomics）、蛋白質數量的蛋白質體學（Proteomics）、代謝物的代謝體學（Metabolomics），以及基因序列不變、只有表現與否改變的表觀遺傳學（Epigenetics）資料，也會隨時間逐層累積。

田間取得的環境體資料同樣密集。設於田區的物聯網感測器、涵蓋全國的密集網格農業氣象資料、美國國家航空暨太空總署的NASA POWER衛星資料，以及記錄土壤性質的土壤調查資料庫會匯集在一起，依時間累積每日最低與最高氣溫、積溫、顯示空氣乾燥程度的飽和水氣壓差（Vapor Pressure Deficit, VPD），以及土壤水分和氮、磷、鉀濃度。若要讓不同機構和國家的研究人員共同使用這些資料，必須先統一格式。因此，可尋得（Findable）、可存取（Accessible）、可與其他程式互通（Interoperable）及可再使用（Reusable）四項FAIR原則，成為資料管理標準。交換育種資料的共通規格BrAPI（Plant Breeding API）和作物栽培資料標準ICASA獲得採用後，不同研究機構累積的資料現在可依標準規格彼此交換。

這些資料會放上Breedbase、OpenSILEX與CropGS-Hub等整合平台，整理成可在同一畫面搜尋基因體、表型與環境體的知識基礎。散落於論文與舊育種筆記中的知識也不會繼續埋沒。PlantConnectome等文字分析人工智慧會掃描數萬篇論文，自動找出哪些基因被提到與哪些性狀相關，再把關係整理成以點和線繪製的知識圖譜（Knowledge Graph）。即使是幾十年前退休的育種人員手寫筆記裡的一筆觀察，如今也能一次搜尋叫出。

即使資料不斷累積，從中找出有用模式仍是另一項工作。早期基因體預測由GBLUP（Genomic Best Linear Unbiased Prediction）和RKHS（Reproducing Kernel Hilbert Space）等統計模型負責。兩種模型都以方程式計算數萬個標記各自對性狀貢獻多少，再加總貢獻度，算出個體的預期表現。隨著以多個問題像樹枝分岔般逐步縮小答案範圍的隨機森林（Random Forest）、逐步減少誤差以改善預測的極端梯度提升（Extreme Gradient Boosting, XGBoost）、支援向量機（Support Vector Machine, SVM）及LASSO迴歸等機器學習技術加入，預測範圍也擴大。面對數萬個標記，這些統計與機器學習模型仍能篩出真正重要的數百個，並把其餘部分當作雜訊濾除。

深度神經網路在統計模型之後出現。用於大豆育種的SoyDNGP把基因體資訊排列成立體影像，再通過3D卷積神經網路（3D CNN），預測產量、收穫期、油脂與蛋白質含量。可一次輸入多種體學資料的DNNP、以水稻、玉米、棉花和小米四種作物共五十三項農業性狀測試效能的CropARNet、結合卷積神經網路和自注意力機制（Self-Attention，也就是自行決定輸入值中哪些部分需要更高權重的計算方式）的Cropformer，以及處理基因型與表型之間扭曲非線性關係的DPCformer相繼發表，使預測效能逐步提升。這些模型可以捕捉基因彼此抑制或增強的上位性（Epistasis）效應。這種數值不是只把兩三個基因的效果相加就能得到。

AutoGP和可同時計算多項性狀的MtCro等模型，用於玉米、水稻和小麥等已長期累積資料的作物，一次運算就能同時產出產量、抗病性與穀粒品質。模型層數越深，越容易陷入過度擬合（Overfitting），也就是連訓練資料的細微特徵都記住，在測試資料上表現良好，卻與實際現場不符。為防止這個問題，人們同時使用隨機關閉神經網路節點的Dropout，以及壓制運算值避免過度增大的L2正規化等技術。越新的模型越不只強調準確度，研究慣例正轉向同步報告模型在未曾見過的田區中能否維持穩定表現。

讀取基因體的人工智慧再向前一步，開始像學習人類語言一樣，把基因鹼基序列本身視為語言。AgroNT（Agro-Nucleotide Transformer）與FloraBERT會以自監督學習（Self-Supervised Learning）預先訓練，無需提供正確答案，就能自行學習位於基因前後、調控表現的非編碼區，也就是啟動子與增強子的鹼基序列。完成訓練的模型即使收到從未見過的新植物物種鹼基序列，也能立即找出基因表現量與調控區的活性程度。更進一步的PlantCaduceus同時學習親緣關係相距甚遠的十六種被子植物基因體，並以比監督式學習模型更高的準確度，揭示基因為何在漫長演化過程中保留某段序列。

人工智慧的介入已從預測進入直接改寫基因體。開發團隊稱為首款植物用平台的OpenCRISPR-1，先以大量既有資料學習CRISPR-Cas基因剪刀的3D立體結構與鹼基

序列，再自行設計自然界從未存在的新切割酶和導引RNA，也就是把剪刀帶到目標位置的短遺傳序列gRNA。這種方法的價值，在於比直接採用天然切割酶更能減少切到錯誤位置的脫靶（Off-target）副作用。基因編輯必須只精確切開目標位置，因此這項精準度決定成敗。

整合所有預測與設計能力的大型育種基礎模型（Breeding Foundation Model）也正在建立。就像學習人類語言的大型語言模型，育種基礎模型也遵循擴展定律（Scaling Law），模型規模、訓練資料量與運算量同步增加時，效能會按可預測的幅度提升。規模跨過某個門檻後，模型會突然具備過去無法執行工作的湧現能力（Emergent Abilities）。何時跨過門檻無法預知。可逐步推理同時編輯多個基因時，該組合會對整株作物造成何種影響的思維鏈（Chain-of-Thought）能力，就是一個例子。可是模型越大，越難擺脫以自信口吻給出看似合理卻錯誤答案的幻覺（Hallucination），因此會搭配檢索增強生成（Retrieval-Augmented Generation, RAG），要求模型回答前先搜尋經認證的育種資料庫。低秩適應（Low-Rank Adaptation, LoRA）則不用從頭重新訓練整個模型，只調整數個運算路徑，因此即使沒有昂貴伺服器，也能另行製作符合特定作物與地區的版本。

完成訓練的模型實際產出預測值的過程，大致分成兩個階段。離線階段先把整合基因體、表型與環境體的龐大資料，分配到由數百、數千張GPU組成的伺服器叢集，使用3D平行化技術與ZeRO，也就是減少記憶體浪費、讓有限設備也能訓練大型模型的最佳化技術，花數週訓練模型。訓練完成後，模型進入線上階段，接收實際育種現場列為候選的母本與父本品系基因體圖譜，以及目標栽培地的氣象情境。電腦會預先測試數萬種雜交組合表現，並在數秒內完成虛擬雜交篩選（In-silico Cross Screening）。畫面上的排名表，正是這種數秒運算徹夜反覆執行多次的結果。過去必須種入實際田地、完整培育一個世代才能知道的答案，現在播種前就能先在電腦裡取得。

數項數值可用來確認預測是否可靠。顯示實際成績與模型預先計算值同步變動程度的預測準確度，以0.70至0.85為目標。顯示整體表現差異中模型可解釋比例的決定係數，以0.75至0.90為標準。產量、抽穗日期與株高等會形成實際數字的性狀，會再用預測值和實測值差距的平均絕對誤差（MAE），以及將差距平方後取平均的均方根誤差（RMSE）確認。罹病葉片的辨識準確度，以精確率，也就是預測為病葉者中實際罹病的比率，與召回率，也就是實際病葉中模型找出的比率，以及合併兩者的F1分數衡量，基因剪刀切割目標位置的準確度則分別以目標位置切割比率的正靶效率，及切到錯誤位置的脫靶率衡量。

育種人員還關注另一項指標。這項指標要看準確度實際讓品種改善得多快。稱為遺傳增益速率的數值，是把每次選拔的嚴格程度、預測準確度及該性狀剩餘的遺傳差異相乘，再除以從一個世代進入下一世代所需的時間。世代間隔越短、預測越準確，同一

期間的品種改善幅度就越大。研究人員也會查看遺傳力，也就是性狀總差異中基因所佔比重，遺傳力越高，代表該性狀越多由基因而不是環境決定，選拔效果也會更大。SeedBench等讓多個大型模型同場競爭的共通測試集已經建立，可以用標準化指標比較哪些模型在基因搜尋、表型解讀和雜交設計方面都有良好表現。

這種運算改變實際田間的案例，可在國際農業研究諮商組織（CGIAR）所屬的國際玉米小麥改良中心（CIMMYT）看到。東非與拉丁美洲多地的玉米和小麥育種計畫，採用了整合全基因體標記資料、無人機多光譜指標與氣象逆境紀錄的預測育種系統，在乾旱與高溫嚴重的條件下，產量與耐旱性預測準確度比既有統計模型提高約15%至25%。戶外試驗田的區塊數減少，雜交後取得下一世代所需的時間也縮短到約一半。在非洲下一個可能更乾旱的種植季到來前，研究人員已能在實際播種前先篩出可以承受的品系。

在大豆育種現場，SoyDNGP已經以公開的網路服務運作。育種人員上傳品系的基因體資料後，3D卷積神經網路會計算產量、收穫期、油脂與蛋白質含量，自動選出有潛力的親本組合。處理玉米、水稻與小麥的CropGS-Hub和AutoGP平台也以類似方式，把基因型與表型資料結合在網路資料庫，開放任何研究人員連線執行虛擬雜交模擬。一間實驗室花數年累積的資料，可以立即由地球另一端的研究機構接續使用。

Syngenta與InstaDeep把共同開發的AgroNT用於多種植物的調控序列，不必種下一顆種子，就先依基因對環境變化的敏感程度完成排序。模型一次計算數千個潛在調控區的權重，建立設計氣候韌性品種所需的分子層級依據。種子公司與人工智慧企業合作的案例日益常見，這項事實本身就顯示技術已走出實驗室，開始成為商業育種工具。合作成果不只留在論文中，而是放進實際育種管線，因而具有不同分量。

OpenCRISPR-1設計的基因剪刀，已成功精確編輯負責作物抗旱性與抗病性的基因。結果顯示，它比直接使用天然切割酶更能減少碰觸錯誤位置的副作用。現在，從一顆種子的基因體中只挑出目標行與目標字元進行修正，已從可能性變成獲得驗證的結果。這項成果能否在實驗室外的田地中跨越數個世代維持，仍須再經過幾個種植季才能確定。

在日本高知縣，名為SAWACHI的雲端平台，把超過1,600座溫室的環境資料與3,000個農場的生產紀錄，連接到國家農業大數據網WAGRI，執行預測生長與產量的人工智慧模型，並評估候選育種品系對實際現場的適合程度。日本愛知縣則把另一類人工智慧用於改良康乃馨品種。研究人員釐清康乃馨基因表現在環境條件或繁殖過程中變動、導致花瓣顏色改變的表觀遺傳現象，並把這項知識用於精確篩選具有目標顏色的新品種。彙整數千座溫室的資料與深入研究一種花瓣顏色的遺傳機制，雖然規模不同，卻在同一個預測育種架構中並行。

成果明確，尚待解決的問題也同樣明確。在溫室或電腦虛擬環境中訓練的模型，面對從未遭遇的異常氣候，或多種逆境同時發生的複合環境時，預測能力有時會大幅降低。虛擬空間與實際田間的差距稱為模擬與現實落差（Sim-to-Real Gap），而模型遇到訓練期間未見條件時判斷不穩的領域偏移（Domain Shift）現象，是造成差距的原因。要縮小問題，必須持續加入從更多元環境取得的資料，並建立能依現場傳入資料自行更新模型的線上適應式學習系統。

模型無法說明為何得出答案，也是難以處理的問題。深度神經網路雖有很高的準確度，卻無法用育種人員聽得懂的生物學依據，解釋為何推薦某個雜交組合。這類模型會下判斷，卻像把抵達判斷的路徑藏在箱子裡，因此稱為黑箱（Black-box）。為打開黑箱，研究人員持續開發SHAP與Grad-CAM等解釋技術，並連接知識圖譜，為預測結果附上生物學因果關係。只要無法親眼確認依據，無論準確度多高，都很難完全取得經驗豐富育種人員的信任。

運算成本也會阻礙發展。訓練和執行具有數十億個參數的育種基礎模型，需要昂貴的GPU伺服器，因此難以取得這類設備的小型研究機構和微型育種企業，連接近這項技術都不容易。把模型運算值縮成幾個整數、使模型輕量化的量化，以及把大型模型所學知識轉移到小型模型的知識蒸餾（Knowledge Distillation），正朝降低這道門檻的方向研究。租用雲端伺服器也是一種方法，但不少企業不願把育種資料交給外部伺服器。能否負擔一台伺服器的價格，正在成為能否接觸最新育種技術的另一條界線。

最後留下的障礙是人才。同時熟悉先進人工智慧演算法、分子遺傳學與田間農學的跨域人才仍然少見，因而拖慢實驗室成果轉化為實際田間品種改良的速度。對人工智慧設計的基因編輯作物應如何審查和核准，以及資料和模型所有權應歸誰的法律與制度，也尚未跟上技術發展。無論預測與設計種子的能力多強，若沒有負責審查和承擔責任的人員與規則，通往田間的道路仍然受阻。

資料來源與參考文獻

學術論文

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、中瀧洸太、戸田陽介。(2025)。〈AI時代の作物學研究〉。《日本作物學會紀事》，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：基於自注意力機制與深度殘差網路的基因體選拔模型。(n.d.). ScienceDirect.
<https://www.sciencedirect.com/science/article/pii/S2772899425000242>
9. Cropformer：結合卷積神經網路與自注意力機制的作物表型預測模型。(n.d.). ScienceDirect.
<https://www.sciencedirect.com/science/article/pii/S2590346224006448>
10. DPCformer：以卷積神經網路與自注意力預測基因型與表型非線性關係的模型。(n.d.). arXiv.
<https://arxiv.org/html/2510.08662v1>
11. PlantCaduceus：基於十六種被子植物基因體預訓練的多物種植物DNA語言模型。(n.d.). Computomics.
<https://www.computomics.com/news-reader/foundation-models-in-plant-breeding-an-introduction-copy.html>
12. AI breeder：作物育種用基因體預測人工智慧研究。(n.d.). ScienceDirect.
<https://www.sciencedirect.com/science/article/pii/S2949952623000109>

演講與影音資料

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=FWcxEC90JA>
3. WAF. (2025). WAF interactive webinar on biotechnology and AI contributions to plant breeding [Video]. YouTube. <https://www.youtube.com/watch?v=xkVT9D7Nqy0>
4. 農業農村資訊通信環境整備準備會。(2026)。〈在地區共享資料：農業資料運用最前線、資料驅動農業WAGRI與IoP雲端（SAWACHI）的Next次世代設施園藝系統，第5次線上研討會〉[Video]. YouTube.
<https://www.youtube.com/watch?v=k8Qvv6CKB2A>
5. 愛知縣農業水產局。(2026)。〈愛知農業創新計畫2027技術提案招募說明會〉[Video]. YouTube.
<https://www.youtube.com/watch?v=jpkoNqscGu8>

請支持本書

如果本書對您有所幫助，歡迎透過 PayPal 支持後續翻譯、
公開版本製作與開放的 AI 知識計畫。



PayPal

<https://paypal.me/kimkjkj>

請掃描 QR 碼，或開啟上方連結。