

多模型智慧農場活蔬菜 異常之資料分析與預測

Multi-Model Prediction of Vegetable Abnormalities in Smart Farming

組員：廖竑羿 陳樂宇 楊喬卉 | 指導教授：郭軒安

大綱

- 簡介
- 模型設計
- 整體架構流程
- 模型流程圖
- 資料前處理
- 實驗結果與分析
- 結論與未來展望

簡介

產業背景：

垂直農場與植物工廠是智慧農業的重要發展方向，目標在於提升生產效率、節省資源、降低碳排，並透過精準栽培與農產品追溯提升食安。智慧農場則結合科技與農業，提供更高效率的栽培與管理方案。

目前痛點：

- 垂直農場高密度培育植株，不同區域間易出現微氣候差異，使植株生長狀況呈多樣化以及出現生長異常。
- 目前農場多聚焦於環境參數，對植株異常偵測機制建置不足，因此異常徵兆、成因機制無法被有效掌握。
- 植株培育環境與異常情形可能導致最終採收盤重不穩定，甚至影響履約規格、單位面積產值等生產效益。

本專題以智慧農業為主題，目標為利用農場環境資料建立植物異常預測模型，分析水質與空氣環境對植物生長異常之影響，並提前預測缺硼、黃化、徒長、褐化、長勢異常與蟲害等問題。


利用 AI 模型協助農場提前發現異常風險，降低人工巡檢成本，並提升植物栽培品質與生產效率。

模型設計

在模型設計方面，本研究使用三種不同方法進行分析：


1. Random Forest (RF)：作為主要分類模型，並利用 Feature Importance 分析重要環境因子。
2. Long Short-Term Memory (LSTM)：研究中的農業環境數據（空氣、水質）為時間序列資料，作物的異常狀況往往不是單日突發，而是過去數天環境因子累積影響的結果。藉由 LSTM 捕捉此類依賴關係，有效學習「過去 N 天的環境變化 → 當前作物狀態」的映射。
3. BNN 可將環境因子與植物異常建立成知識圖譜，透過節點表示 pH、EC 等特徵，並以箭頭表示條件依賴關係。模型可根據不同環境條件推論異常發生機率，並整理出可解釋的 domain insight

整體架構 流程圖




圖一：整體架構流程圖


模型流程圖



圖二：RF流程圖



圖三：LSTM流程圖



圖四：BN流程圖

資料前處理

- 原始資料

排程資料

- 工單號
- 品種
- 見苗日
- 育苗日
- 栽苗日
- 採收日

空氣資料

- 溫度
- 濕度
- CO2濃度

水質資料

- 溫度
- EC值
- pH值

資料清理
(缺失、異常值)

資料整合

實驗結果與分析

Random Forest 模型分類成效

品項	Accuracy	Recall	Precision	f1-score
缺硼	0.92	0.78	0.59	0.67
黃化	0.98	0.98	0.8	0.88
徒長	0.72	0.72	0.12	0.21
長勢	0.92	0.86	0.92	0.89
黑心	0.73	0.9	0.14	0.24
其他	0.96	0.99	0.88	0.94

表:RF 訓練結果


LSTM 模型分類與預測表現

品項	Accuracy	Recall	Precision	f1-score
缺硼	0.87	0.77	0.33	0.47
黃化	0.93	0.73	0.34	0.46
徒長	0.9	0.66	0.27	0.38
長勢	0.92	0.83	0.7	0.76
黑心	0.88	0.76	0.26	0.39
其他	0.96	0.96	0.74	0.84


表:LSTM 訓練結果

資料分析

透過 Random Forest 的 Gini Importance 篩選重要特徵，進一步進行資料分析。



圖五: W1_G03G04水槽pH值_mean




圖六: W2_P01P04水槽EC值_mean

品項	第一影響因子	第二影響因子	第三影響因子
缺硼	day1_sin_3	day2_air_4	day2_air_7
黃化	day1_air_9	day0_air_2	day0_air_19
徒長	day2_water_2	day1_紅橡木	day0_air_8
長勢	day1_air_25	day1_air_17	day0_air_25
黑心	day1_air_16	day1_綠蘿蔓	day1_冰山綠火焰
其他	day2_幼嫩冰山綠火焰	day0_air_10	day2_air_0

- 缺硼的判斷主要依賴生長週期變化與後期環境條件
- 黃化異常與環境溫度條件密切相關
- 徒長受到灌溉條件與品種特性共同影響，其中水分管理最為關鍵
- 長勢主要依賴環境溫度資料，反映作物對環境品質的敏感度
- 黑心具有明顯的品種效應，環境條件則提供額外的判斷資訊
- 其他類別則具有顯著的品種依賴性，不同天數的溫度也是重要的影響因子

Bayesian Network - 知識圖譜



結果

Random Forest 找出重要風險因子，LSTM 學習時序影響，Bayesian Network 負責因子之間關係。

最終將模型結果轉換為 Domain Insight，進一步產生異常風險預測與改善建議

缺硼風險預測：86%

主要風險因子：

- 水槽 pH 值偏高
- EC 值偏低

建議改善：

- 將 pH 控制於 5.8~6.5
- 將 EC 控制於 1.5~1.7

結論與未來展望

■ 結論

- RF於6項異常中取得4項最佳 F1-score，整體表現最優。
- LSTM在徒長與黑心類別表現較佳，但整體效能較低。
- Bayesian Network表現接近RF，並具備不確定性評估能力，適合智慧農業決策應用。
- 徒長與黑心為各模型共同弱項（F1-score < 0.4），仍有改善空間。

結論與未來展望

■ 未來展望

- 擴充徒長與黑心樣本數，提升少數類別辨識能力。
- 納入更多環境時序資料（如光照）。
- 結合 Bayesian Network 與 GCN，融合時序與區域關聯資訊，提高預測準確度與可靠性。

感謝聆聽