

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

簡介

本專題以智慧農業為研究主題，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。

模型設計方面，本研究使用三種不同方法進行分析：Random Forest（RF）、Long Short-Term Memory（LSTM）、Bayesian Network。本研究目的希望透過 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。

整體架構流程圖



圖一：整體架構流程圖

結果

Random Forest

透過多棵決策樹投票進行分類，可降低過度擬合並提升模型穩定性。將環境資料切割為時間窗口，萃取水質與空氣資料的統計特徵作為輸入，並利用 Gini Importance 分析影響植物異常的重要因子，建立具解釋性的異常預測模型。

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

表一：RF 訓練結果

Long Short-Term Memory

空氣與水質資料屬於時間序列，植物異常多由過去數天環境變化累積造成。透過 LSTM 可學習「過去環境變化」與「當前作物狀態」之間的關係。

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


表二：LSTM 訓練結果

Bayesian Network


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

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


表三：BNN 訓練結果



圖二: RF流程圖




圖三: LSTM流程圖




圖四: Bayesian Network流程圖

效益 - 特徵重要度分析

透過 Random Forest 的 Gini Importance 篩選重要特徵後，進一步進行資料分析。以其中兩個為例，較高的 pH 值與植物異常較有關聯；而 EC 值在正常與異常樣本間差異較小，影響程度相對有限。透過此方式，可協助找出影響植物異常的重要環境因子。



圖五: W1_G03G04水槽pH值_mean



圖六: W2_P01P04水槽EC值_mean

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。
- BNN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。

總結：RF適合作為現階段部署模型；BNN則具備較佳的研究與發展潛力。

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 BNN 與 GCN，融合時序與區域關聯資訊，提高預測準確度與可靠性。



圖七: BNN知識圖譜