

農作蜜棗損傷原因之高效能分類

王仲佑[†]
國立高雄大學 資訊管理學系
高雄市 台灣
a1073333@mail.nuk.edu.tw

涂凱祺[†]
國立高雄大學 資訊管理學系
高雄市 台灣
a1073348@mail.nuk.edu.tw

楊雅喬[†]
國立高雄大學 資訊管理學系
高雄市 台灣
a1073314@mail.nuk.edu.tw

蔡琇鈞[†]
國立高雄大學 資訊管理學系
高雄市 台灣
a1073316@mail.nuk.edu.tw

楊子賢^{*}
國立高雄大學 資訊管理學系
高雄市 台灣
thyangza1025@nuk.edu.tw

摘要

由於經濟快速成長、產業型態發生轉變以及都市提供的更多就業機會，農村出生的年輕人口逐漸外移。加之我國生育率逐年降低及高齡人口比例漸增，造成農業勞動力老化乃至衰退，因此農業轉型更受重視。近年來深度學習在影像處理的發展，可應用在農業轉型以補足農村勞力短缺。然而這方面的應用，目前僅限於芒果一類的高外銷產值水果，在其他不受重視但具潛力的農作物上的相關研究仍欠缺。本論文以 EfficientNet 深度學習模型為基礎，訓練出一套模型來辨識蜜棗上的損傷原因。實驗數據顯示，透過該系統可以成功辨識蜜棗上八種常見的損傷，AUC (Area Under Curve) 效能衡量指標在測試集上可達 93.1%。本研究可幫助非專業人士辨認影響品質甚劇之損傷原因並對其做後續分級處理，以此提升作業人員的工作效率及準確度，從中減緩農村人口老化對專業勞力的影響並改善作業流程。

關鍵字—多分類任務、深度學習、蜜棗損傷原因

1 引言

根據國家發展委員會在中華民國人口推估 (2020 年至 2070 年) [1] 此份報告中指出，臺灣工作年齡人口 (15 至 64 歲者) 於 2015 年達到最高峰後便逐年減少。由於少子化以及高齡化對社會帶來的嚴重影響，政府推估 2070 年工作年齡人口將較 2020 年減半，且 45 至 64 歲者比例為一半以上。而國家發展計畫 (106 至 109 年四年計畫暨 106 年計畫) [2] 與行政院主計總處民國 106-108 年的臺灣地區歷年就業之行業統計調查 [3] 中指出，臺灣呈現高度都市化發展，為鄉村地區帶來人口及產業流失問題，鄉村地區由於農業式微而呈現衰頹之勢。以上原因造成農林漁牧業的勞動力不足，農民為配合作物產期也只能雇用短期工人，然而短期工人缺乏培訓及相關經驗，無法支援專業工作並造成人才培養上的困難。

近幾年國內逐漸重視農業轉型，例如在生產與養殖方面，資訊工業策進會曾提出「智慧農業數位分身」，不僅可以透過農民依據經驗調整參數進行模擬

預測，還能動態學習農民的經驗知識，進而達到協同運作、決策最佳化 [4]。於食安問題上則有產銷履歷制度，透過資訊系統紀錄農產品從生產到出貨完整過程，以提供消費者購買優質農產品的依據。從上述例子可看出科技跨領域結合農業知識的可能性。

臺灣素有水果王國的美稱，發展精緻水果及建立優良品牌一直為政府的重點經營對象。其中水果外貌的好壞與損傷原因為影響品質的關鍵因素。人工手動對水果外貌及損傷進行分類容易因為長時間作業產生疲勞或是作業人員標準及經驗不一致，發生同等級水果品質不一的情形。因此這項需要眾多專業人力且具有高度重複性的工作，非常適合透過深度學習模型協助以提高工作效率與準確性。目前在此領域的發展上主要聚焦在具有高經濟價值、產量較高且穩定的幾種農作物上，例如愛文芒果 [5] 與金鑽鳳梨 [6]。然而除上述提及的兩種水果外，甚少有相關研究協助其他不受重視但具潛力的農作物。如臺灣蜜棗在年產量與出口量上亦具有一席之地，外表損傷原因也為影響其品質好壞的關鍵，但至今仍沒有一個自動辨識其品質狀況的演算法模型被提出。

本論文以勞動力不足與專業人才培養不易對農業造成的衝擊作為動機，鎖定在臺灣較不受重視但具潛力的農作物蜜棗作為研究對象，擬訓練一套模型辨識影響其品質甚劇的損傷原因，透過科技結合專業農業知識，提供嚴謹標準幫助水果分級人員更有效率地完成品質控管流程，降低專業勞動力不足對果農作業流程的影響程度。實驗數據顯示建構之模型於 AUC 模型效能衡量指標在測試集上達到 93.1%，可辨識八種不同蜜棗損傷原因並分類。

2 文獻回顧

水果等級分類在商業上有很重要的價值，採收期時水果的產量通常很高，為了因應市場價格，農民需要根據該水果的類型、特徵以及外表對其進行分類，但勞動者之收穫成本不僅高昂且相當費時 [7]。同時因為人工檢查可能造成的誤差以及缺乏評估品質的知識，可能會錯誤的分類或是包裝水果，另外由於專業勞力的短缺和勞動力成本的上升，農民承受著需要短時間內快速供貨的壓力。為了建立一個準確、快速且

[†]: 共同第一作者。

^{*}: 通訊作者。

表 1 蜜棗損傷分類

標籤	損傷 1	損傷 2	損傷 3	損傷 4	損傷 5	損傷 6	損傷 7	損傷 8
名稱	薊馬蟲害	幼果期蟲害	皮囊破裂	擦傷	戳劃傷	畸形	著色不佳	藥傷
數量(張)	295	36	1319	490	263	67	10	55
示意圖								

可靠的水果檢測系統以解決上述問題，許多學者提出了不同的水果檢測方法。其中影像是農業科學中相當重要的資訊來源，此技術對於農業的經營與分析有著一定的意義 [8]。

近年來學者們能透過影像訓練深度學習模型來達到分類效果，並且具有一定的準確率及效率。在 EfficientNet [9] 原始論文提到，該模型架構透過 ImageNet [10] 上進行訓練，在下游任務的表現中，相比其他模型準確率及效率更高，因此有許多影像辨識任務使用 EfficientNet 進行訓練。比如在 Gessert 等人 [11] 的研究中使用 EfficientNet 在皮膚鏡影像上進行多分類的任務訓練，透過該模型分辨皮膚病變的種類。另外 Marques 等人 [12] 也透過使用 EfficientNet 在 COVID-19 患者、肺炎患者及正常人的肺部超音波照片上進行模型訓練，該模型在辨識是否為 COVID-19 患者的二分類任務，以及辨識 COVID-19 患者、肺炎患者和正常人的多分類任務中，F1 score 分別達到 99.62% 及 97.11%。而 Atila 等人 [13] 在不同的深度學習模型中於植物葉片病害的影像上進行訓練，發現 EfficientNet 的訓練結果在有效縮小模型大小的同時，準確度 (Accuracy) 上比其他模型提升了 0.1 至 0.6%。

針對透過影像檢測水果表面受損以及其原因之文獻，在 Dubey [14] 的研究中以蘋果作為主要研究對象，並且將檢測方法總結為三個步驟：第一，使用 K-means 對影像進行缺陷分割；第二，提取特徵；第三，透過 Multiclass SVM (Support Vector Machines) 對傳入值進行分類及訓練。最後做到可以辨識蘋果可能罹患的三種疾病 (Apple Blotch、Apple Rot、以及 Apple Scab)，準確度達到 93%。另外一篇基於顏色作為主要特徵進行缺陷檢測並且以蕃茄作為主題的研究分成兩種檢測方式，包括 BER (Blossom End Rot) 的檢測 [15] 與對 BER 和裂縫的檢測 [16]。在檢測 BER 及裂縫方面，顏色特徵被視為各個像素值的一階空間統計量，其中因為影像中的缺陷沒有空間向量概念，因此應考慮缺陷的相對區域 [17]。為了改善蕃茄缺陷檢測，並以低成本實現該分級系統，它選擇提取色彩空間顏色特徵和灰度紋理特徵並將兩者用作主要特徵變量，以建立與蕃茄紅色強度和缺陷的相關性。其中色彩空間通常不受相機傳感器變化影響 [18]，而紋理特徵則捕獲感知紋理的灰度值空間依賴性 [19]。

深度學習透過多個非線性方程式組合形成一塊塊模組，透過傳導計算與目標差異來調整傳輸過程中的非線性函數，並由模型本身反覆試錯進行調整，其運作模式類似人類神經元。當網絡中的神經元數量越多，無論是淺層或是深度神經網路，準確率皆會隨著神經元數量增加呈現成長趨勢。然而當神經元數目相

同時，深度神經網路的表現總是比淺層神經網路更好，因此獲得廣泛應用 [20]。

由上述文獻回顧可知 EfficientNet 作為影像辨識任務的訓練模型，適合用來處理二分類任務以及多分類任務。而針對水果影像進行表面受損及原因判斷的方法具可行性。因此本研究希冀在蜜棗的損傷影像上利用 EfficientNet 深度學習模型為基底進一步進行損傷原因判別。

3 研究資料與方法

3.1 蜜棗資料收集與處理

本研究使用的蜜棗影像資料係於蜜棗分裝地點實地進行拍攝，共計 1023 張照片，並擷取其局部損傷位置影像作為損傷原因分類資料，共計 2535 張局部損傷範圍。蜜棗損傷原因判定係由專業農事人員協助下進行原因分類，而此八種皆為此農作物上常見且影響品質強烈的損傷原因 (表 1)。

本次分類任務於 NVIDIA RTX 2080 Ti GPU 上進行模型訓練。為使個別損傷影像可以順利傳入模型中進行訓練，我們首先將完整蜜棗影像透過人工手動標記方式逐一標記每張原始圖片中各損傷的位置及原因，再透過損傷標記位置從原始圖片擷取局部損傷圖片。由於每張損傷圖片大小不一，為使資料符合 EfficientNet-B0 輸入，我們於資料前處理時將每張圖片周圍進行零填充 (zero-padding) 至圖片滿足長寬比 224×224 或以上的最小正方形後，再重新將圖片大小調整 (resize) 至 224×224 。

在這個資料集中每個損傷原因佔資料集比率懸殊，為非均衡樣本 (表 1)。因此後續會採用影像增強的方式增加樣本的數量，以便於訓練。本研究希冀透過影像辨識技術分析並判斷蜜棗圖片上局部損傷原因。主要採用 EfficientNet [9] 建構分類模型，並使用 ImageNet 預先訓練完的權重，利用本研究之資料集微調 (Fine-tune) 未凍結之層數。為確保模型之穩定性，本研究擬透過正規化 (Regularization) 和隨機關閉神經元 (Dropout) 防止模型的過擬合 (Overfit)，並調整超參數 (Hyperparameter) 以使模型收斂，確保測試之可信度。

3.2 模型架構

EfficientNet [9] 可有效調整網路的寬度、深度以及輸入解析度，並同時保持模型效率。本研究主要使用 EfficientNet-B0 進行蜜棗損傷原因分類的遷移式學習 (Transfer Learning)。有關本研究之模型架構如圖 1 所示。由於本研究資料集為非均衡樣本，因此在進行

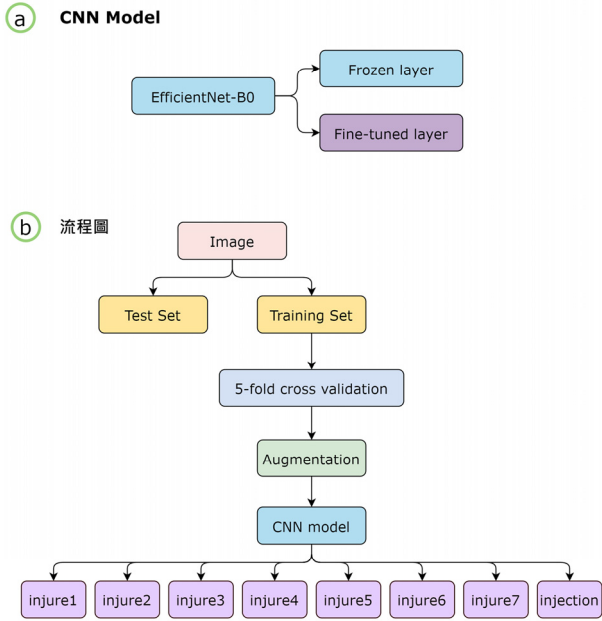


圖 1 研究與模型架構圖

模型訓練之前，透過 Augmenters 影像增強套件 [21] 生成訓練資料，以改善樣本不平衡對模型訓練的影響。

在遷移式學習應用於影像辨識任務中通常更加建議凍結前面的層數，只針對後面幾層重新訓練，這是由於影像辨識的神經網絡前幾層所學習的特徵較普遍，因此適合被遷移至其他影像辨識任務的網絡中，而後幾層所學的大多於任務對象而言為具代表性且抽象的特徵。參照圖 1 - a，在模型微調 (Fine-tune) 的部分，我們首先將整個 EfficientNet-B0 架構的權重凍結，並且從最後面開始解凍，每次解凍一部份的層數，讓其根據傳入的訓練資料以更新更符合特徵的權重，在此過程下重複進行測試。於本研究中總共解凍 EfficientNet-B0 中的最後 5 層進行後續的訓練，最終模型會輸出該影像對應八種損傷原因的機率 (圖 1 - b)，並取其機率最高者作為該影像之主要損傷原因。

3.3 交叉驗證

本研究會使用交叉驗證 (Cross Validation) 將資料集分為 K 份，其中一份作為驗證集 (Validation Set)，剩下的作為訓練集 (Training Set)，重複 K 次。這樣有助於合理嚴謹地評估模型的效果，減少偶發性的結果 (圖 1 - b)。分類模型的評估通常會將預測結果轉化為混淆矩陣 (Confusion Matrix)，其中 TPR (True Positive Rate) 和 FPR (False Positive Rate) 可用於繪製接收者操作特徵曲線 (Receiver Operating Characteristic curve, ROC 曲線)，其曲線下面積稱為 AUC (Area Under Curve)。召回率 (Recall) 和精確度 (Precision) 可用於計算 F1 score。在此研究中，將 AUC 以及 F1 score 作為評估模型預測水準的依據，AUC 的數值越接近 100%，代表模型的分類效果越好。在多分類任務中通常會使用 Micro、Macro 或是 Weighted 的方式計算上述提及的評估指標，在本研究




圖 2 蜜棗損傷分類模型的訓練驗證學習曲線圖

中使用的方法為 Micro，即為將每種損傷原因的混淆矩陣加總之後再計算其餘評估值。

4 研究結果

本研究基於 EfficientNet 深度學習模型進行蜜棗損傷原因的多分類任務，因實驗數據的各分類不平衡現象，我們使用 F1 score 以及 AUC 的結果，以驗證模型的表現力。

在本研究中會先個別計算每一個損傷原因的混淆矩陣，再將所有損傷原因的 TP、FP、FN 相加，並分別記錄為 Total TP、Total FP 以及 Total FN，最後使用 Micro 的方法計算精確度 (Precision) 以及召回率 (Recall)，透過兩者推得 F1 score，公式如下：

$$\text{Precision} = \frac{\text{Total TP}}{\text{Total TP} + \text{Total FP}} \quad (1)$$

$$\text{Recall} = \frac{\text{Total TP}}{\text{Total TP} + \text{Total FN}} \quad (2)$$

$$\text{F1_score} = \frac{2}{\frac{1}{\text{Precision}} + \frac{1}{\text{Recall}}} \quad (3)$$

其中，TP 為模型預測某種損傷原因結果與資料本身所屬損傷原因相符的樣本數量；FP 為資料本身不屬於某種損傷原因，但預測結果錯誤判定其為某種損傷原因的樣本數量；若資料本身屬於特定損傷原因，但預測結果並未判定其為此損傷原因，此情況則稱為 FN。

透過上述公式推導出 F1 score 後，我們進而繪製學習曲線圖來確認模型的訓練狀況是否收斂，並透過隨機搜尋來控制過擬合的現象及尋找最佳參數。由圖 2 可知在訓練資料上，模型在訓練集資料上收斂到約莫 F1 = 0.7 的成績，而在驗證集資料上也收斂至到 F1 = 0.67 的表現。由此學習曲線圖，我們可以得知，此模型已在數值最佳化上達到訓練目的，且此訓練過程並沒有造成過擬合。

我們利用 ROC 曲線來計算 AUC 值，並以此 AUC 值評估整體模型的表現。在圖 3 中的紅線，其為五次交叉驗證中求出的 Micro AUC 之平均，可以看出模型的表現五次平均值達到 93.0%。接著我們在此模型下使用一開始先行切分出的測試集進行損傷原因分類的預測，以測試此模型是否能在未知的資料上進行蜜棗




圖 3 蜜棗損傷分類模型的 ROC 曲線

損傷原因分類任務。結果如圖 3 中藍線所示，測試 AUC 可達到 93.1%。因測試集上 AUC 表現與五次交叉驗證平均之 AUC 相差無幾，可知此模型亦能於未見過的資料集上完成蜜棗損傷原因分類任務。

5 結論

本研究以臺灣農業與新興科技之結合做為出發點，瞄準臺灣精緻農業中，影響水果分級之重要因素水果外觀與損傷，透過樣本集訓練模型學習分類不同損傷原因，以幫助作業人員更精確且嚴謹地進行品質管理任務。蜜棗是具高經濟價值之水果，且外表好壞以及損傷原因與其品質息息相關。本研究以 EfficientNet 為基礎，發展深度學習模型完成蜜棗損傷原因分類任務，由實驗數據可以發現該模型在損傷原因的分類預測上有良好的表現，在測試集上，我們的模型亦能有效辨識蜜棗表面損傷原因。本研究發展出的蜜棗損傷原因分類模型不僅可以幫助工作人員進行更精準的品質管理作業，亦可以減輕他們的工作負擔及降低品質管理人員數量上的需求，改善整體作業流程的進行，對臺灣精緻農業的推行與轉型有所幫助。

參考文獻

- [1] 中華民國國家發展委員會，“中華民國人口推估（2020 至 2070 年）國家發展委員會 2020 年 8 月，” 2020. Accessed: Aug. 15, 2021. [Online]. Available: <https://pop-proj.ndc.gov.tw/download.aspx?uid=70&pid=70>.
- [2] 中華民國國家發展委員會，“國家發展計畫 106 至 109 年四年計畫暨 106 年計畫（核定本）中華民國 106 年 2 月，” 2017. Accessed: Aug. 15, 2021. [Online]. Available: <https://ws.ndc.gov.tw/Download.ashx?u=LzAwMS9hZG1pbmlzdHJhdG9yLzEwL3JlbGZpbGUvMC80MTI1LzZiM2M1OWRlTlYWMtNGY0Zi1hOTRkLTRhMzc1ZWZhNzc2Ni5wZGY%3D&n=5ZyL5a6255m85bGV6KiI55WrLEwNuiHszEwOeW5tOWBm%2BW5tOioiOeVq%2BaaqDEwNuW5tOioiOeVq%2BWFqOaWhy5wZGY%3D&icon=..>
- [3] 行政院主計總處，“歷年臺灣地區歷年就業之行業統計調查（民國 106-108 年），” 行政院主計總處，2019. https://win.dgbas.gov.tw/dgbas04/bc4/manpower/year/t13_o_a.asp?num=10&out=1&yearb=106&year=108&ym=1 (accessed Aug. 15, 2021).
- [4] 財團法人資訊工業策進會，“資策會研發 AI+HI 人機跨智協作「智慧農業數位分身」榮獲美國 R&D 全球百大科技研發獎，” 財團法人資訊工業策進會，2019. https://www.iii.org.tw/Press/NewsDtl.aspx?fm_sqno=14&nsp_sqno=2259.
- [5] 財團法人工業技術研究院，“自動篩果系統:利用 AI 與自動化提高篩果效率，增加 17 億產值 - 資策會服創所，” 財團法人工業技術研究院，2021. https://agtech.coa.gov.tw/Topic/topic_more?id=26724a5343e24737aea2796ac2d43717 (accessed Aug. 15, 2021).
- [6] 財團法人台灣經濟研究院，“智慧選果我最行-金鑽鳳梨快速分級系統-行政院農業委員會農業科技專案計畫服務網，” 行政院農業委員會，Oct. 25, 2008. https://agtech.coa.gov.tw/Topic/topic_more?id=26724a5343e24737aea2796ac2d43717 (accessed Aug. 15, 2021).
- [7] Yoav Sarig, “Mechanized fruit harvesting-Site Specific Solutions. Information and Technology for Sustainable Fruit and Vegetable Production,” 2005. <https://www.yumpu.com/en/document/read/50344670/mechanized-fruit-harvesting-a-site-specific-symposcience> (accessed Jan. 26, 2021).
- [8] S. R. Dubey and A. S. Jalal, “Application of Image Processing in Fruit and Vegetable Analysis: A Review,” *Journal of Intelligent Systems*, vol. 24, no. 4. Walter de Gruyter GmbH, pp. 405–424, Dec. 01, 2015, doi: 10.1515/jisys-2014-0079.
- [9] M. Tan and Q. Le, “Efficientnet: Rethinking model scaling for convolutional neural networks,” in *International Conference on Machine Learning*, 2019, pp. 6105–6114.
- [10] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” *Adv. Neural Inf. Process. Syst.*, vol. 25, pp. 1097–1105, 2012.
- [11] N. Gessert *et al.*, “Skin Lesion Classification Using CNNs with Patch-Based Attention and Diagnosis-Guided Loss Weighting,” *IEEE Trans. Biomed. Eng.*, 2020, doi: 10.1109/TBME.2019.2915839.
- [12] G. Marques, D. Agarwal, and I. dela Torre Diez, “Automated medical diagnosis of COVID-19 through EfficientNet convolutional neural network,” *Appl. Soft Comput.*, vol. 96, p. 106691, 2020, doi: <https://doi.org/10.1016/j.asoc.2020.106691>.
- [13] Ü. Atila, M. Uçar, K. Akyol, and E. Uçar, “Plant leaf disease classification using EfficientNet deep learning model,” *Ecol. Inform.*, vol. 61, p. 101182, 2021, doi: <https://doi.org/10.1016/j.ecoinf.2020.101182>.
- [14] S. R. Dubey, “Automatic recognition of fruits and vegetables and detection of fruit diseases,” *Master's theses*, 2012.
- [15] T. Dhanabal and D. Samanta, “Computerized Spoiled Tamato Detection,” *Int. J. Res. Eng. Technol.*, vol. 2, no. 11, pp. 38–41, 2013.
- [16] M. Rokunuzzaman and J. ayasuriya H. P. W., “Development of a low cost machine vision system for sorting of tomatoes,” *Agric. Eng. Int. CIGR J.*, vol. 15, pp. 173–180, Mar. 2013.
- [17] M. P. Arakeri and others, “Computer vision based fruit grading system for quality evaluation of tomato in agriculture industry,” *Procedia Comput. Sci.*, vol. 79, pp. 426–433, 2016.
- [18] S. Shafiee, S. Minaei, N. Moghaddam-Charkari, and M. Barzegar, “Honey characterization using computer vision system and artificial neural networks,” *Food Chem.*, vol. 159, pp. 143–150, Sep. 2014, doi: 10.1016/j.foodchem.2014.02.136.
- [19] D. Ireri, E. Belal, C. Okinda, N. Makange, and C. Ji, “A computer vision system for defect discrimination and grading in tomatoes using machine learning and image processing,” *Artif. Intell. Agric.*, vol. 2, pp. 28–37, Jun. 2019, doi: 10.1016/j.aiaa.2019.06.001.
- [20] F. Seide, G. Li, and D. Yu, “Conversational speech transcription using context-dependent deep neural networks,” 2011.
- [21] TensorFlow, “tf.keras.preprocessing.image.ImageDataGenerator,” *TensorFlow*, 2021. https://www.tensorflow.org/api_docs/python/tf/keras/preprocessing/image/ImageDataGenerator#args.