

# 基於物件偵測的咖啡瑕疵豆辨識技術

\*鍾維哲、楊榮林

南臺科技大學電子工程系

\*ma730105@stust.edu.tw

## 摘要

咖啡早已是人們生活的一部分，但要產出一杯好咖啡的過程是非常繁瑣複雜的，為了確保所烘焙出來的咖啡品質符合需求，咖啡瑕疵豆剔除一定得在咖啡生豆烘焙前完成，然而，瑕疵豆剔除流程通常是經由人工手挑完成，這是一個極為耗費時間的必要流程，如果可以有效改進當前的方法，它將降低將一杯好咖啡端上餐桌的最終成本。因此，本研究希望藉由深度學習物件偵測技術來降低人力成本，物件檢測技術可以對目標進行分類並從圖像中標定其位置，利用該技術與硬體機構及電控元件有效結合，咖啡瑕疵豆的剔除將可被自動化。本研究結果顯示在 5 種分類的訓練資料，訓練 25,000 次的模型中呈現較好的效果，平均準確度達到.54，且在好咖啡豆的分類辨識上平均準確度也達.80。因此，本研究已完成該模型與電腦視覺結合的設計，能有效快速的辨識瑕疵豆及其位置，未來搭配自動咖啡豆剔除的機構設計，將有助於開發低成本的瑕疵豆自動剔除設備。

**關鍵詞：**深度學習、物件偵測、咖啡瑕疵豆

## Defect Inspection of Green Coffee Beans Using Object Detection

\*Wei-Che Chung, Jung-Lin Yang

Department of Electronic Engineering, Southern Taiwan University of Science and Technology

### Abstract

Coffee has become a part of people's lives, but good coffee production is very complicated. In order to ensure the quality of roasted coffee, defective coffee beans must be removed before roasting. However, the traditional manual removal of defective beans is a time-consuming and laborious process. If the current method could be improved, it would reduce the cost of the final process of getting a cup of coffee to the table. Therefore, this research hopes to use deep learning object detection technology to reduce labor costs. Object Detection technology can classify the target and find the position from the image. If it can be effectively integrated with hardware equipment, it would be able to automatically remove defective coffee beans. The research results show five types of training data, among which the model with 25,000 training steps can achieve .54 mean average precision, and the average precision can achieve as high as .80 in the good coffee categories. Moreover, this model has been combined with computer vision to assist users in identifying, locating, and removing defective coffee beans, thereby improving the overall picking speed. In the future, it can be combined with hardware architecture to complete automated picking.

**Keyword:** Deep Learning, Object Detection, Defective Beans

Received: Dec. 15, 2021; first revised: Mar. 21, 2022, accepted: Apr. 2022.

Corresponding author: W.-C. Chung, Department of Electronic Engineering, Southern Taiwan University of Science and Technology, Tainan 710031, Taiwan.

## 壹、研究背景

國際咖啡組織 (International Coffee Organization, ICO) 是咖啡生產國間的協調機構，其主要的任務就是要即時應對全球咖啡產業所面臨的挑戰，ICO 會員國包含了生產及消費的國家，該組織代表了全球 98% 的咖啡產量，同時也擁有 67% 全球消費量。國際咖啡組織(ICO, 2018)咖啡市場規模報告顯示，ICO 會員國咖啡出口總量從 2010 年的 582 萬公噸，逐年攀升至 2018 年的 736 萬公噸 (圖 1)，而這驚人的成長趨勢依舊持續中[1]。依中華民國財政部海關進出口(財政部, 2019)統計，台灣於 2019 年進口將近 3.8 萬公噸生豆 (圖 2)，總價值高達 1.81 美元的進口咖啡造就了另一項世界第一[2]，台灣咖啡館密度位居全球之冠且每年超過 28 億杯咖啡消費量。咖啡生豆在出口前都會依瑕疵豆比例進行分級，雖然各國分級的方法及標準不同，但其基本精神就是瑕疵豆含量越低，咖啡生豆的等級別當然就越高，價格也就會因而水漲船高。除了價格因素外，其實我們更關注的是瑕疵豆所造成的健康影響，瑕疵豆對咖啡風味及口感的影響是所有烘豆師的惡夢，加上在儲放及運輸過程中環境變因造成赭麴毒素 (Ochratoxin A, OTA) 的生成，這些被感染的瑕疵豆不但會破壞風味同時會嚴重影響人體健康，更可怕的是攝氏 200 度以上的烘豆鍋爐溫度也無法完全去除赭麴毒素的威脅，因此烘豆前的挑豆處理是「好」咖啡豆的基本，至於好咖啡豆可否變成一杯好喝的咖啡，就得仰賴後續的生豆「烘焙」及咖啡「萃取」。

圖 1

ICO 會員國咖啡豆出口量

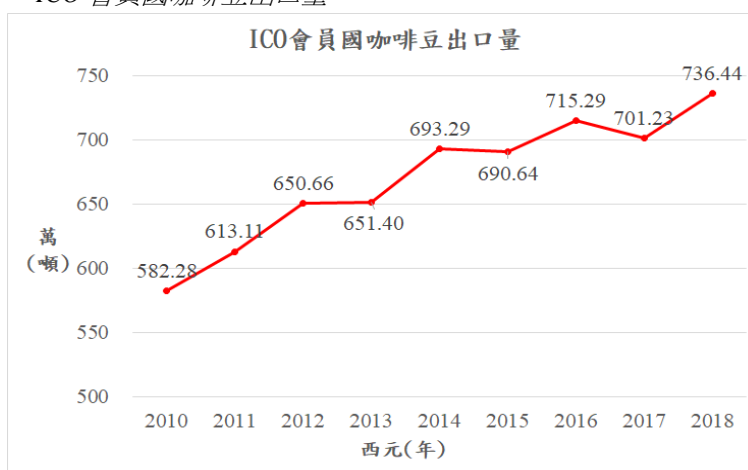




圖 2

台灣咖啡進口量



造就好咖啡生豆的「挑豆」並非一次性的處理工作，從咖啡生豆生產國出口前的大批量挑豆處理，乃至咖啡烘焙前的高精準度瑕疵豆剔除，甚至烘焙之後也可能進行精緻化的挑豆，不管是哪一個階段的瑕疵豆剔除，都是非常耗時費力且暫時無法由機器取代的工作，因此，好咖啡的生成通常意味著多重成本的疊加，大部分主要咖啡生產國都具有大規模栽種及低人力成本的優勢，不管是在咖啡的種植、採摘、及生豆處理，都使得國內咖啡農難以與進口咖啡豆競爭。挑豆的時間點可分成出口前、烘焙前、及烘焙後如圖 3，出口前的瑕疵豆因為數量龐大因此剔除標準較為寬鬆，瑕疵物件大都為樹枝、小石子、咖啡殼等自然界產物，當然還包括各式生豆處理法所產生的瑕疵豆，這個階段的瑕疵豆剔除直接影響到生豆的出口價格，但因為數量龐大瑕疵豆的比例不得不限度的放鬆。烘焙前瑕疵豆剔除的需求主要取決於烘豆師，以標榜高檔精品咖啡的咖啡廳這個步驟是必要的，當然是否真的有進行這一個階段的挑豆是無法可管的，我們只能夠選擇相信咖啡館的烘豆師。烘豆前之所以需要再次挑豆是因為，保存過程所產生的破碎豆、蟲柱豆、或發黴豆，雖說數量不見得會非常多但只要參進同一鍋爐烘焙的咖啡豆，輕則導致燒焦和烘焙不均影響到品味口感，更可怕的是可能造成影響健康的壞咖啡。此外，某些高檔的精品咖啡豆在烘焙完後，還會再進行一次挑豆的處理，因為部份咖啡瑕疵豆無法從外觀分辨，通常必須要在高溫烘焙之後才會現出原形，既然標榜高檔當然就容不下任何的瑕疵，所以這個烘焙後的挑豆專為金字塔頂端客群需求而生。

圖 3  
挑豆流程圖



咖啡生豆是僅次於石油的第二大國際貿易商品，一直以來有關於咖啡的研究本就非常之多，當然這也包括對咖啡瑕疵豆自動判讀的研究，(Arboleda et al., 2018) 採用電腦視覺對咖啡黑豆影像進行處理，藉由萃取出正常豆與黑豆的 RGB 進行好壞生豆判別[3]，(Pizzaia et al., 2018) 及 (Pinto et al., 2017) 則是結合了影像視覺及人工神經網路來強化瑕疵豆識別及分類[3][5]，Jonathan Huang 等人[5]於 2017 年提出的「Speed/Accuracy Trade-Offs for Modern Convolutional Object Detectors」，如同其他研究都明確指出自動化判讀瑕疵豆是可行的，該研究還針對不同物件偵測模型與不同 CNN 模型的搭配組合進行綜合分析，在相同的資料訓練下各物件偵測模型的辨識速度、辨識精準度、及所需硬體資源皆有詳細分析。

咖啡身為國際貿易重要經濟農作物之一，國際咖啡組織的報告也顯示全球總產值及需求皆逐年上升，然而時至今日最有效的瑕疵豆剔除依然仰賴大量人力，對於強調友善種植環境及自然農法的台灣咖啡農，咖啡生豆處理過程居高不下的人力成本，使得台灣咖啡很難在國際舞台上長久立足，雖然曾有有機咖啡農場在國際場合展露頭角，但畢竟是麟毛鳳爪難以形成具規模的產業。因此台灣咖啡若想走進國際市場，那從樹上咖啡果至桌上一杯咖啡的每個階段，都得完成一定程度的自動化甚至智慧化，否則以台灣小規模的精緻咖啡農業很難有長遠的發展。本研究計畫所提出的基於深度學習 (Deep Learning) 的瑕疵豆辨識技術，就是希望藉由成熟的物件偵測 (Object Detection) 技術來取代挑豆員工的雙眼，一來可以避免長時間工作所產生的視覺疲勞，同時也可以強化對瑕疵豆辨識的判斷標準，我們的研究顯示在不對咖啡豆手動翻轉的前提下，經過訓練後的物件偵測模型表現不亞於經驗老道的挑豆人員。搭配本研究提出的瑕疵豆辨識技術及生豆剔除機構，不但可以有效的降低人力成本，更可以確實的為烘豆前的生豆把關，自家烘焙的精品咖啡店就不用因為成本考量而在「挑」與「不挑」間難以取捨，畢竟不賺錢的生意是無法長久經營的。

## 貳、研究方法

一杯好的咖啡所需的工序卻是相當繁瑣，其中為了確保咖啡烘培後的整體風味及品質，咖啡生豆的瑕疵豆剔除是必要的前置程序。傳統人力剔除瑕疵豆是非常耗時費工的流程，如果能夠改善當前的方法，將可以降低許多人力成本，因此本研究希望以深度學習的物件偵測技術，有效降低瑕疵豆剔除的人力成本。物件偵測技術可以從影像中找尋目標的分類結果的位置，這樣的結果若有效的結合硬體裝置，將能以自動化方式進行挑豆。研究結果顯示，5種分類的模型在訓練20,000次中平均準確度可達.54mAP，而針對好的咖啡豆類別準確度可達.80AP，因此該模型的成果可結合影像視覺，輔助使用者進行咖啡生豆的瑕疵豆剔除，透過模型進行影像辨識及定位，提升整體挑豆速度。未來可結合硬體架構，完成自動化挑豆。

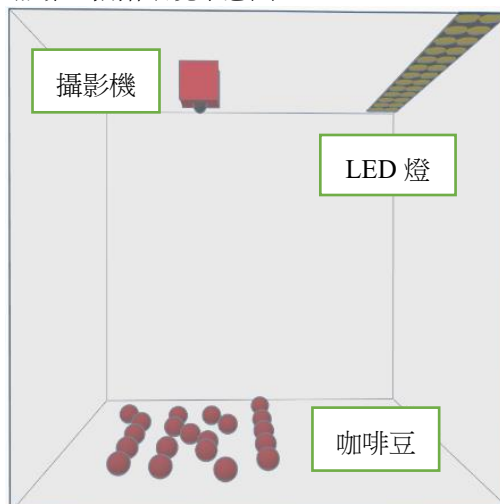
本研究以物件偵測技術做為檢測瑕疵豆的方法，針對烘焙前的瑕疵豆進行辨識，使用蘇門達臘咖啡生豆為樣本，該支豆子中混和水洗法及特殊處理兩種，特殊處理的豆子偏淺咖啡色，且部分表面呈現斑點狀；水洗法豆子顏色偏淺綠，兩種處理法豆子能以人眼大略分辨出。在瑕疵豆方面，對於特殊處理的豆子表面斑點則正常；水洗法而言，表面生成斑點或顏色偏黑，有可能為蟲蛀或發霉。設想未來可套用於自動化平台檢測及挑除，因此以物件偵測技術作為辨識核心，一方面進行分類，另一方面能夠從暗盒中找出正確位置。資料收集方面以200g咖啡豆隨機採樣，訓練資料從該中獲取150g咖啡豆，測試資料則為剩下50g咖啡豆，樣本皆包含兩種處理法及各類瑕疵豆，物件偵測訓練框架選用Tensorflow所提供的API，模型選用SSD\_MobileNet\_V2進行訓練及推論。

本研究預想將模型訓練結果套用至邊緣運算裝置上，類似裝置如Raspberry pi、Nvidia系列的Jetson Nano、Jetson TX2，這些裝置具有體積小、低功耗的特性，能夠作為許多辨識核心的主板，透過相關邊緣運算套件結合硬體組件，實作完整挑豆系統裝置。因此在物件偵測模型選用速度快的模型而非準確率高的模型。

### 一、資料收集

影像的差異會影響模型的好壞，多樣化的影像雖然可以提升泛用度，但在資料量少的情況可能導致模型成效不彰，有鑑於本研究中的咖啡豆數量不多，因此以一種穩定固定光源的環境進行影像收集。於資料收集前建立一個與環境光源隔絕的暗箱如圖4，將拍攝物放置於暗箱中，透過暗箱中的光源打光，形成一種環境光源穩定的區域。暗箱內部以單條LED打光，將攝影機置於可完整拍攝咖啡豆為基準，攝影機方面使用羅技C-525，該攝影機具有720p的解析度及自動對焦的功能。

圖4  
咖啡豆拍攝環境示意圖



本研究使蘇門答臘咖啡豆為訓練及測試的樣本，該支咖啡豆中包含水洗及特殊處理的咖啡豆，特殊處理法的豆子呈現黃褐色，少部分瑕疵因與豆色相近，較難辨別出是否為瑕疵豆；水洗法的豆子呈現淺綠色、瑕疵豆較少且瑕疵明顯。豆子中包含好、蟲蛀、壞、圓豆、碎豆...等咖啡豆，瑕疵豆部分除特別分類的類群外，其餘皆為壞的類別如圖 5。從樣本中取 5g 咖啡豆進行拍攝，瑕疵豆及正反面隨機出現，每張影包含 20 至 30 顆咖啡豆，放置時將咖啡豆撥散，避免相互重疊，導致資料標註時不易，拍攝一次後將所有咖啡豆手動翻面，拍攝咖啡豆的另外一面。影像解析度為 640 x 480 全彩，總共資料影像張數為 62 張，影像中的咖啡豆數量為 1,538 顆；測試影像張數為 18 張，影像中咖啡豆數量為 484 顆，每張圖片中出現的瑕疵豆數量、種類均為隨機。

圖 5  
咖啡豆種類

種類	水洗豆		特殊豆	
好				
蟲蛀				
壞				
圓豆				
碎豆				

## 二、資料量及物件標註

訓練物件偵測模型前需要獲取影像中目標的分類及座標，獲取方法使用 Tzutalin (2015) 分享的 Label Image 工具[7]，該工具可以讓使用者方便獲取目標的座標及分類，並自動記錄相關參數。

本研究訓練四種物件偵測模型，其中三種為不同分類數量的模型，第四種為分類數量 5 種但樣本比例平均的模型，由於部分的瑕疵豆同時包含 2 個以上的瑕疵，本研究在判斷瑕疵豆的優先順序分別為圓豆及破碎豆、蟲蛀豆、壞豆。第一種模型為 14 種分類，依照影像中咖啡豆的處理法及正反面進行分類，其中圓豆及破碎豆的瑕疵豆不分正反面，主因為該類型的瑕疵豆是以形狀作為明顯瑕疵，且影像中有時難以辨別正反面；第二種模型為 8 種分類，不區分處理法的情況下，將兩類咖啡豆視為同類別；第三種與第四種同為 5 種分類，由於在挑豆中凡為瑕疵豆均該挑除，因此將蟲蛀豆與壞豆歸為一類，並將圓豆及破碎豆合為一類，各資料分類請參考表 1。

本研究將收集到的影像，訓練資料 62 張、測試資料 18 張進行資料擴增，將原始圖片及標籤透過水平翻轉、垂直翻轉、旋轉 180 度三種方式增加資料量如表 2。擴增後結果訓練資料共 248 張影像共 6,152 顆咖啡豆；測試資料 72 張影像共 1,936 顆咖啡豆。

訓練模型時，需以少部分資料檢測模型的訓練狀況，因此從訓練資料中隨機取 10% 數量做為驗證樣本，其完整資料樣本數量為訓練資料 224 張、驗證資料 24 張、測試資料 72 張。並統計四種不同分類的樣本數量如表 3、表 4、表 5、表 6。

表 1

物件資料分類

14 種分類														
處理法	特殊處理法						水洗法						兩種處理法	
分類	正面好	正面蟲	正面壞	背面好	背面蟲	背面壞	正面好	正面蟲	正面壞	背面好	背面蟲	背面壞	圓豆	破碎豆
8 種分類														
分類	正面好	正面蟲	正面壞	背面好	背面蟲	背面壞	圓豆	破碎豆						
5 種分類														
分類	正面好	正面壞	背面好	背面壞	及圓豆 破碎豆									

表 2

資料擴增方式




表 3

14 種分類中各類別的物件數量

處理法	特殊處理法						水洗法						兩種處理法	
分類	正面好	正面蟲	正面壞	背面好	背面蟲	背面壞	正面好	正面蟲	正面壞	背面好	背面蟲	背面壞	圓豆	破碎豆
訓練	843	112	209	1135	175	147	1015	201	68	989	160	20	352	130
驗證	69	12	19	113	25	21	109	15	8	111	36	0	44	14
測試	328	8	84	400	72	72	324	56	28	280	72	8	156	48

表 4

8 種分類中各類別的物件數量

分類	正面好	正面蟲	正面壞	背面好	背面蟲	背面壞	圓豆	破碎豆
訓練	1858	313	277	2124	335	167	352	130
驗證	178	27	27	224	61	21	44	14
測試	652	64	112	680	144	80	156	48

表 5

5 種分類中各類別的物件數量

分類	正面好	正面壞	背面好	背面壞	圓豆 及破碎豆
訓練	1858	590	2124	502	482
驗證	178	54	224	82	58
測試	652	176	680	224	214

表 6

5 種分類中平均樣本的物件數量

分類	正面好	正面壞	背面好	背面壞	圓豆 及破碎豆
訓練	500	500	500	500	480
驗證	50	50	50	50	50
測試	150	150	150	150	150

### 三、模型訓練及硬體配置

模型訓練框架使用 TensorFlow Object Detection API 框架[8]，該 API 提供許多現有的物件偵測模型，使用者無須自行建立模型架構，只需做好環境設定及資料樣本的處理，即可按照 API 的操作訓練模型，相關模型提供如表 7。本研究模型選用 `ssd_mobilenet_v2_coco` 做訓練，僅針對不同訓練次數、不同分類數量的樣本做訓練，並未修改內部相關模型設計參數。訓練參數設定以 3 種不同分類數，及每 5,000 次訓練作為一次停止點，總共訓練 35,000 次，共 7 個階段，從中擇優出作為系統的辨識雛型，其餘模型的參數調校，均按照 TensorFlow 所提供的物件偵測模型參數預設值。

模型訓練環境配置，CPU：Intel I7-6700、GPU：Nvidia GeForce 1060 6GB、RAM：16GB DDR4-2133；Tensorflow-gpu：1.11.0、CUDA：9.0、cuDNN：7.6.1。

表 7

Tensorflow Object Detection 提供的物件偵測模型

COCO_trained models			
Model name	Speed (ms)	COCO mAP	Outputs
<code>ssd_mobilenet_v1_coco</code>	30	21	Boxes
<code>ssd_mobilenet_v1_0.75_depth_coco</code> ☆	26	18	Boxes
<code>ssd_mobilenet_v1_quantized_coco</code> ☆	29	18	Boxes
<code>ssd_mobilenet_v1_0.75_depth_quantized_coco</code> ☆	29	16	Boxes
<code>ssd_mobilenet_v1_ppn_coco</code> ☆	26	20	Boxes
<code>ssd_mobilenet_v1_fpn_coco</code> ☆	56	32	Boxes
<code>ssd_resnet_50_fpn_coco</code> ☆	76	35	Boxes
<code>ssd_mobilenet_v2_coco</code>	31	22	Boxes
<code>ssd_mobilenet_v2_quantized_coco</code>	29	22	Boxes
<code>ssdlite_mobilenet_v2_coco</code>	27	22	Boxes
<code>ssd_inception_v2_coco</code>	42	24	Boxes
<code>faster_rcnn_inception_v2_coco</code>	58	28	Boxes
<code>faster_rcnn_resnet50_coco</code>	89	30	Boxes
<code>faster_rcnn_resnet50_lowproposals_coco</code>	64		Boxes

(下頁續)

Model name	Speed (ms)	COCO mAP	Outputs
rfcn_resnet101_coco	92	30	Boxes
faster_rcnn_resnet101_coco	106	32	Boxes
faster_rcnn_resnet101_lowproposals_coco	82		Boxes
faster_rcnn_inception_resnet_v2_atrous_coco	620	37	Boxes
faster_rcnn_inception_resnet_v2_atrous_lowproposals_coco	241		Boxes
faster_rcnn_nas	1833	43	Boxes
faster_rcnn_nas_lowproposals_coco	540		Boxes
mask_rcnn_inception_resnet_v2_atrous_coco	771	36	Masks
mask_rcnn_inception_v2_coco	79	25	Masks
mask_rcnn_resnet101_atrous_coco	470	33	Masks
mask_rcnn_resnet50_atrous_coco	343	29	Masks

## 參、模型訓練結果

依據本研究提出的方法訓練模型，各模型均以各自的資料集進行驗證及測試，並以 TensorBoard 視覺化結果，包含訓練的誤差、驗證及測試的 mAP (mean Average Precision)，並分析各模型的好壞，總共訓練 35,000 次，並於每 5000 次進行驗證及測試。

依圖 6 結果所示，14 種分類的模型在訓練次數 25,000 時最優異，總誤差 (Total Loss) 約在 1.1，而驗證及測試結果如圖 7，驗證結果在訓練 25,000 次時準確度約 .99mAP，測試結果為 .3mAP；8 種分類模型依圖 6 所示，訓練總誤差在 20,000 及 35000 時較優異，總誤差分別為 1.5 及 1.3，而根據圖 8 驗證及測試結果，訓練次數 20,000 的準確度約 .38mAP，相比 14 種分類的最高 mAP 上升了 .08mAP；5 種分類模型依圖 6 所示，訓練總誤差在訓練 20,000 次時最低約為 1.4，根據圖 9 驗證及測試結果中，訓練次數在 20,000 時準確度已達 0.54mAP，相比 8 種分類模型上升了 .16mAP；在平均樣本數的 5 種分類模型依圖 6 所示，在訓練次數 20,000 時誤差最小約為 2.1，但相較於其他模型訓練時的誤差卻是大了許多，根據圖 10 所示，驗證結果的最高 mAP 僅有 .50 左右，且在測試結果中僅有 0.2mAP 並無上升跡象。

圖 6

四種模型訓練結果

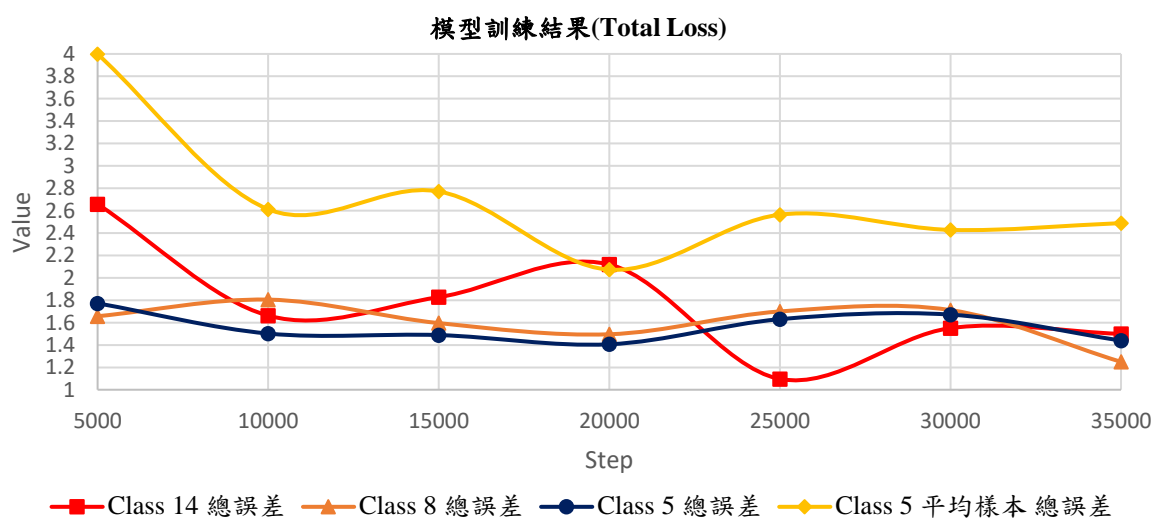




圖 7

14 種分類驗證及測試結果 ( $IOU \geq 0.5$ )




圖 8

8 種分類驗證及測試結果 ( $IOU \geq 0.5$ )

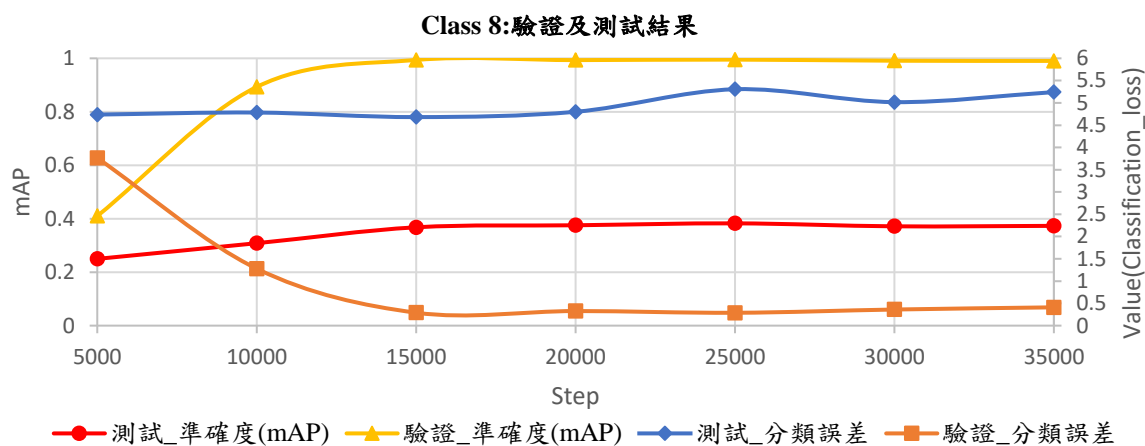


圖 9

5 種分類驗證及測試結果 ( $IOU \geq 0.5$ )

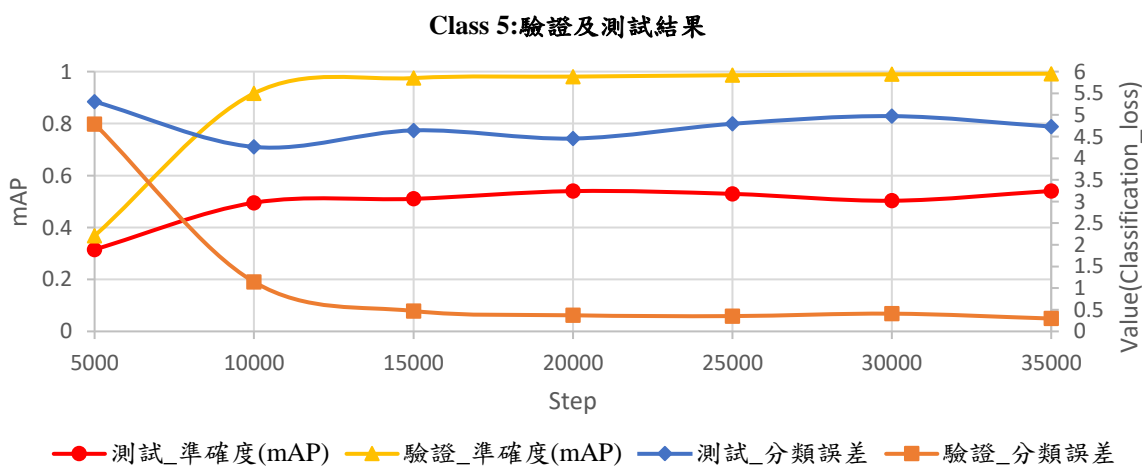



圖 10

5 種分類平均樣本驗證及測試結果 ( $IOU \geq 0.5$ )

根據結果可得知，5 種分類的模型在本研究中準確度最高達.54mAP，進一步分析該模型中各類別的準確度，依照圖 11 所示，針對好的咖啡豆的測試結果準確度均達.80AP 左右，雖然其他類別的準確度不高，但若採用二分法進行挑豆，未被模型判斷為好的咖啡豆皆視為瑕疵豆，該模型依舊可以協助使用者進行挑豆。5 種分類平均樣本中，原用意是為了觀察是否能讓各類別 AP 能夠平均，但依照圖 12 結果所示，好的咖啡豆 AP 僅有.10 至.15 左右，刻意平均樣本數而忽略了訓練資料的數量，導致模型的訓練結果準確度低落。

從 14 種分類、8 種分類及 5 種分類的模型中，在分類數量縮減的情況下，每個單一類別的訓練資料上升，使得模型的準確度逐漸上升，但在平均樣本數中各類別僅 150 個物件的情況下，在這樣低樣本的情況導致測試結果僅有.20mAP。

圖 11

5 種分類中測試結果各分類 AP

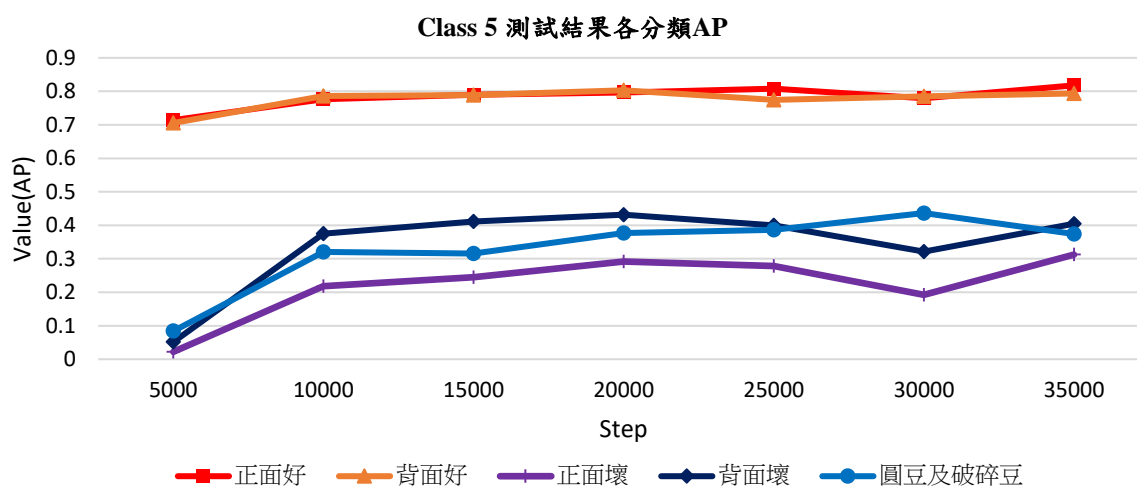



圖 12

5 種分類平均樣本中測試結果各分類 AP



## 肆、結論及未來展望

本研究提出以物件偵測技術辨別咖啡瑕疵豆，透過進行咖啡豆瑕疵豆的分類辨識及定位，試圖解決瑕疵豆影響咖啡風味、赭麴毒素對人體的危害及人力挑選等問題。透過 Tensorflow 的物件偵測 API，以 ssd\_mobilenet\_v2\_coco 作為訓練咖啡豆的辨別模型，進行訓練四種不同分類的資料集，並驗證及測試模型的成效，本研究在 5 種分類訓練次數 20,000 的模型最優異，測試資料中平均 mAP 達到 .50 左右，好的咖啡豆類別 AP 達到 .80，而這樣的準確度在實際挑豆上，可望協助使用者挑除咖啡瑕疵豆。

傳統人力挑選咖啡瑕疵豆耗時耗工，多數研究力求自動化方式解決，物件偵測除了辨識外亦可定位物件在影像中的位置，有鑑於本研究已完成辨識端的模型，未來將針對物件偵測模型的特性，規劃一種自動化挑豆平台，透過攝影機拍攝待測咖啡豆的影像，透過物件偵測模型進行推論，將推論結果結合自動化控制剷除掉瑕疵豆，或者挑選出好的咖啡豆。

## 參考文獻

- [1] 全球咖啡協會統計數據。 [http://www.ico.org/new\\_historical.asp?section=Statistics](http://www.ico.org/new_historical.asp?section=Statistics)
- [2] 海關進出口統計 - 關港貿單一窗口查詢系統。 <https://portal.sw.nat.gov.tw/APGA/GA30;APGAJSESSIONID=XQCdp1zHwShJhm8flpGSWpZJYIB8wYTGqzy6SW2jX6QLZmXxLK6t!1701022989>
- [3] E.R. Arboleda, A.C. Fajardo, & R.P. Medina (2018, May 11–12). An image processing technique for coffee black beans identification. *IEEE International Conference on Innovative Research and Development (ICIRD)* (pp.1–5), Bangkok, Thailand. <https://doi.org/10.1109/ICIRD.2018.8376325>
- [4] J.P.L. Pizaia, I.R. Salcides, G.M. de Almeida, R. Contarato, & R. de Almeida (2018, Nov. 12–14). Arabica coffee samples classification using a Multilayer Perceptron neural network. *2018 13<sup>th</sup> IEEE International*

- Conference on Industry Applications (INDUSCON)* (pp.80–84), Sao Paulo, Brazil. <https://doi.org/10.1109/INDUSCON.2018.8627271>
- [5] C. Pinto, J. Furukawa, H. Fukai, & S. Tamura. (2017, Aug. 16–18). Classification of Green coffee bean images basec on defect types using convolutional neural network (CNN). *2017 International Conference on Advanced Informatics, Concepts, Theory, and Applications (ICAICTA)* (pp.1–5), Denpasar, Indonesia. <https://doi.org/10.1109/ICAICTA.2017.8090980>
- [6] J. Huang, V. Rathod, C. Sun, M. Zhu, A. Korattikara, A. Fathi, I. Fischer, Z. Wojna, Y. Song, S. Guadarrama, & K. Murphy. (2017, July 21–26 ). Speed/accuracy trade-offs for modern convolutional object detectors. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*(pp.3296–3297), Honolulu, HI, United States. <https://doi.org/10.1109/CVPR.2017.351>
- [7] Tzotalin. Label Image Tool. <https://github.com/tzotalin/labelImg>
- [8] Tensorflow Object Detection API. [https://github.com/tensorflow/models/tree/master/research/object\\_detection](https://github.com/tensorflow/models/tree/master/research/object_detection)