

# 2023 年臺灣國際科學展覽會 優勝作品專輯

作品編號 100007

參展科別 工程學

作品名稱 影像辨識 PCB 電路板回收定價機

得獎獎項

就讀學校 臺北美國學校

指導教師 Jonathan Hsu

作者姓名 廖元麒

關鍵詞 物件辨識、再生金屬、電子廢棄物

## 作者簡介



你好，我是就讀台北美國學校 12 年級的 Ryan。

自從在八年級加入學校的機器人社後，我就對工程學產生極大的興趣，平時常常與一群志同道合的朋友一起在實驗室鑽研相關領域的知識。

不過，我認為工程學最神奇的地方是其幫助人們的能力。從古代的造紙術到現代的網路，工程學的進步一直帶領人們走向更好的生活。我希望本次研究學到的經驗能夠幫助我在未來幫助人類。

## 英文摘要

Due to the current state of global warming, there is an increasing desire to achieve carbon neutrality and Circular Economy. Waste electronics, containing valuable metals like aluminum and copper, is full of recycling potential. This research implements a prototype equipped with an object detection algorithm able to detect components on a printed circuit board (PCB) using YOLO. By combining the algorithm with a database of metal recycling prices, an infrared camera, and a PID controller with vision feedback for conveyor control, the machine is capable of estimating the price of a waste PCB. Results showed that the machine has a significant effect in recycling copper and aluminum. This research aims to make the public recognize the potential of waste electronics in order to bolster the desire to recycle. This increases the amount of secondary metal produced, which helps toward achieving carbon neutrality.

## 中文摘要

因應氣候變遷碳，國際興起碳中和與循環經濟熱潮，而廢棄電子垃圾就像是一座城市礦山，蘊藏豐富的回收價值。本研究運用深度學習物件偵測來辨識廢棄 PCB 電路板上的有價值零件，以 YOLO 物件辨識方法建了一個 AI 影像辨識電子零件模型程式、常見 PCB 電子零件的金屬成分含量、紅外線影像處理，以及運用 PID 控制和圖像處理來控制傳送帶。實作出一個能估算廢棄電路板回收價值的原型機。其結果顯示對於鋁金屬和銅金屬有相顯著的回收效果。本研究希望讓大眾意識到廢棄家電的潛在價值，增進電子廢棄物意願，促進再生金屬產量，實現碳中和終極目標。

# 壹、前言

## 一、研究動機

根據近年的研究資料顯示，全球每年大約製造五千萬噸的電子垃圾，且預計在 2030 年會達到七千萬噸。台灣是世界上最大的電子產品製造國之一，加之現今電子設備如手機、筆電等產品的汰換速度很快，每年國內有大量的電子垃圾產生。

這些電子垃圾若處理不當，會造成許多問題：

- 電路板中的重金屬可能會造成土壤重金屬汙染，衍生許多健康問題。
- 全球持續上升的電子產品需求，迫使開採更多原生金屬，冶煉過程中造成更多的碳排放。



圖一：廢棄電路板(取自 [https://www.digitimes.com.tw/iot/article.asp?cat=158&id=0000515764\\_kmy80ayq5nrpcf5snlsr2](https://www.digitimes.com.tw/iot/article.asp?cat=158&id=0000515764_kmy80ayq5nrpcf5snlsr2))

**再生金屬**指的是使用工業製造過程中廢棄金屬或金屬廢料，來取代原生礦石資源作為冶煉金屬的來源。電子垃圾在回收後有非常高的經濟價值，一般常見的 **PCB** 中都會含有如鋁、銅、金等工業用或貴金屬，能以較簡單的製程與較少的石化燃料能源需求來進行再製造。

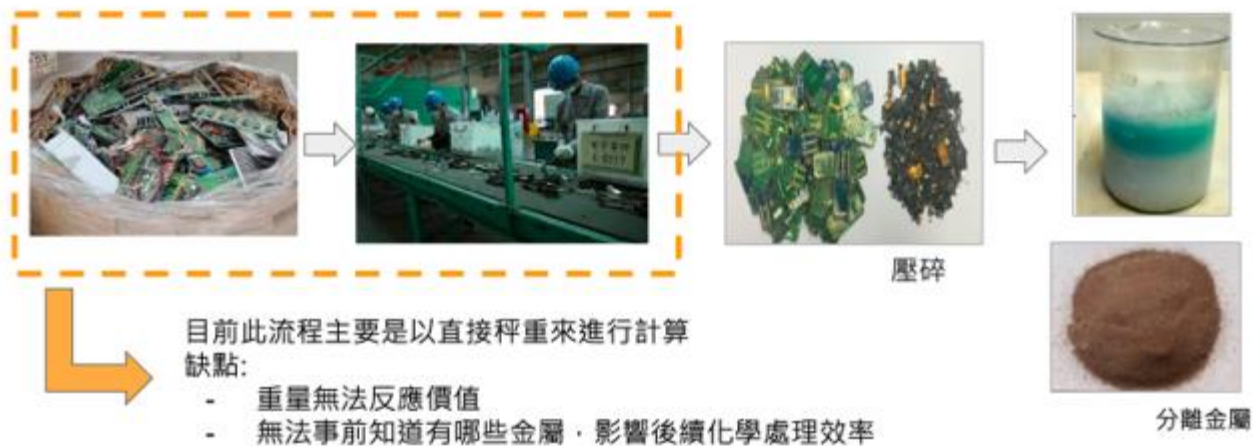
下表是原生金屬(**primary metal**)和再生金屬(**secondary metal**)製造過程中所產生的碳排比較，可以看得出來再生金屬有著非常明顯的**低碳排優勢**，以鋁金屬來看相差高達**19 倍**。再生金屬相比原生金屬可以減少非常多的碳排放，並幫助減緩全球暖化並實現碳中和。

單位生產重量之碳排放量比較	
金屬種類	原生金屬：再生金屬
鋁	19.0 : 1
銅	2.45 : 1
鐵	2.01 : 1

表一：再生金屬與原生金屬單位碳排比較

## 二、研究目的

目前廢棄 PCB 處理方法多為大量集中後粉碎，進入化學溶液解析，過程中需要進行多道制式手續驗證提取，若能提前得知所含金屬比例，將有助於提升後續處理效率。



圖二：傳統廢棄 PCB 處理方式(作者整理)

因此，本研究想要研發一台機器，能夠未來和相關業者或大型社區合作，而目前觀察主要回收採集型式還是以產線流水線回收作業為主，因此將以傳送帶為雛形進行開發，而一般流水

線作業中人力成本占總成本比例很高，本研究也在思考自動化能透過自動化進行分類，該系統具有以下功能：

- 可實時(**real time**)用影像辨識的方式來深度分析廢棄 **PCB** 板上的電子零件
- 運算模型能夠針對零件進行位置和種類標註
- 分析 **PCB** 板的內含金屬回收價值並計算做為分類依據。
  - 探討機器人視覺系統的其他可行方案，包含像紅外線等
- 整個流程全自動化，進行任務，包含定位、拍照、傳送帶運作等。

## 貳、研究方法或過程

### 一、研究設備及器材

#### (一)、軟體設備

- **Google Colaboratory** 編程環境：<https://colab.research.google.com/> 主要為 **Google** 所開發的一套 **Python** 雲端運算平台，並能調用 **GPU** 來加速運算，在本研究中主要用於 **YOLO** 模型的建立。
- **Arduino** 編譯器：運用可編程開發板串接硬體，使用 **C** 語言，在本研究中主要用於馬達控制與 **PID** 相關指令。
- **Anaconda** 編程環境：**Anaconda** 是一個免費開源的 **Python** 發行版本，內建了許多資料科學(**data science**)研究時常用的工具。在本研究中，主要執行後面階段的 **Python** 辨識實測、整合攝影機鏡頭拍照、**Arduino** 串列控制等。
- **OpenCV**：**Open Source Computer Vision Library** 是一個跨平台的電腦視覺庫，常應用於物體辨識或圖像分割等影像處理領域。本研究將用它來進行圖像分割、遮罩等工作。

#### (二)、硬體設備

- **USB 攝影機**：拍攝 **PCB** 照片
- **紅外線攝影模組**：無濾鏡之鏡頭 搭配 **850nm** 陣列 **LED** 照射

- 馬達驅動板：能控制馬達轉速
- 可編程開發板：使用 **Arduino ESP32** 來控制馬達驅動板
- 直流馬達：標準電壓 **12V**
- 電源供應器：提供馬達與開發板電源。

## 二、研究架構

從三個面向來進行研究，並預先思考問題。

(一)、物件偵測技術：如何提升判別精準度、太小的零件怎麼處理

(二)、傳送帶：如何透過傳送帶上的畫面，進行一些資料預處理的工作，以及更精準的停靠在良好的拍攝位置。

(三)、實物推算：影像偵測出來的結果，如何去與真實拆解後的金屬含量結果做比較，能有一套計算方法。



圖三：研究架構(作者整理)

## 三、研究相關理論

(一)、人工智慧與深度學習

機器學習 (**Machine Learning**) 是研究電腦計算機如何實現人類的學習行為，以獲取新的知識或技能。這當中有許多演算法模型，其中神經網路是參考人類大腦運作方式，神經元好比人的大腦神經細胞，是整個模型網路的基本單元。


一般的神經網路由三個部分組成，分別是輸入層 (**Input Layers**)、隱藏層 (**Hidden Layers**) 以及輸出層 (**Output Layers**)。

1. 輸入層：輸入資料 (**Data**) 的特徵值 (**Features**)，以本研究而言，就是提供各種 PCB 電路板圖片轉化後的數值，以及對應的零件特徵或零件類別。

2. 隱藏層：透過神經元 (**Neuron**) 組成，模擬各種非線性的複雜函數運算，試圖表示出輸入層與輸出層之間的函數運算關係。

3. 輸出層：經過隱藏層的運算所得到的預測值，我們藉由縮小預測值與實際標註值 (**Label**)，更新我們隱藏層的參數，最終訓練出一組權重 (**weights**)。而權重就可以被拿來做演算法的適用和評估比較。

4. 本研究選用卷積神經網路 (**Convolution Neural Network**, 簡稱 **CNN**)，它是目前深度神經網路 (**Deep Neural Network**) 領域的主力，有著卷積 (**convolution**)、池化 (**pooling**) 等步驟。



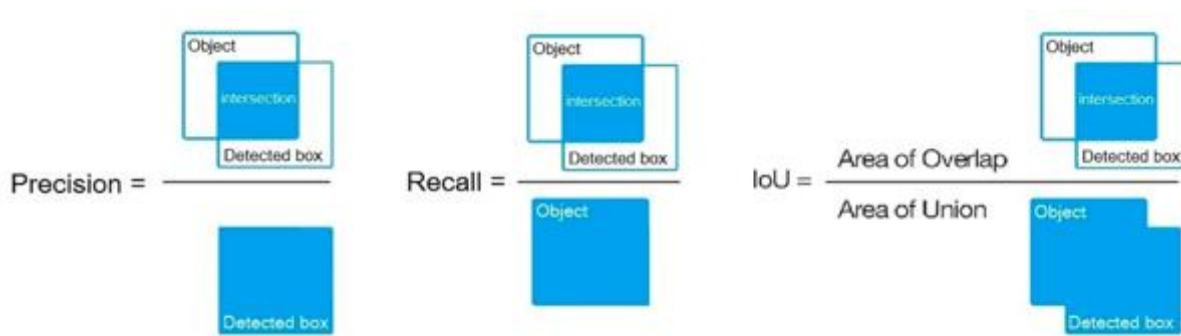
圖四：CNN 卷積神經架構 (Yann LeCun 1998)

## (二)、圖像辨識物件偵測

物件偵測 (**Object Detection**) 是指在照片或影片等圖像內容中，用框標出物件的類別。在 YOLO 物件偵測方法屬於 **One-Stage**，即影像中物件的位置與物件所屬類別資料可以同時輸出。



YOLO 使用網格化來預測物件，每個網格預測邊界框(bounding box)和所屬類別的概率，邊界框會輸出包括正中心點座標(X,Y)、邊框的長(L)和寬(W)，以及信心指數(confidence)。而另一個跟判定結果有關的參數是 IOU(Intersection of confidence)，表示模型預測與正確值的交疊面積狀況。YOLO 於 2015 年 6 月由 Joseph Redmon 首次提出，陸續又有 YOLOv2 和 YOLOv3，而本研究利用 YOLO v4 是在 2020 年 4 月時由俄羅斯的 Alexey Bochkovskiy，以及台灣中央研究院資訊所的廖弘源所長與王建堯博士所開發。本研究將利用 YOLO 進行 PCB 局部位置的特徵零件做物件偵測，並利用 IoU(Intersection over union)概念和 AP: average precision，該數值是用來判斷單一類別的平均準確率，本研究探討 9 種零件(9 種類別)，故採用 mAP 值，即把所有類別的 AP 再取平均。



圖五：IoU 說明(取自 <https://github.com/AlexeyAB/darknet>)

## 四、研究過程

### (一)、影像資料搜集

本研究欲訓練模型來辨識 9 種類別的零件：HDMI、USB 接頭、DB9、電解電容、多層陶瓷電容(MLCC)、RJ45 網路接頭、IC 處理器、銅散熱器和鋁散熱器。

並以手工拆解零件，進行分量測。


		
HDMI 接頭	USB 接頭	DB9/RS232
		
電解電容	MLCC 多層陶瓷電容	RJ45
		
IC 處理器	散熱片(鋁)	散熱片(銅)



電容拆解圖



USB-B 拆解圖



RJ-45 拆解圖



電容中鋁的含量 (公克)

各種零件的金屬含量表：

經由拆解或面積/體積/製程換算，簡易建立一個金屬含量表格，請見表二。

種類	鋁 (毫克)	銅 (毫克)	鐵 (毫克)
IC	0	0.016	0
鋁製散熱鰭片	900	0	0
銅製散熱鰭片	0	5500	0
MLCC	0	38	0
電容	350	0	0
USB	0	600	1500

HDMI	1600	0	0
DB9	200	500	4300
RJ45	2200	0	0

表二：零件金屬含量（作者整理）

## （二）、AI 物件偵測模型建立

1. PCB 資料搜集：我們以網路資料找到一些 PCB 照片，並設法讓電路板零件資料標註：使用 **labelimg** 來進行 PCB 照片上各零件的標註，其資料內容為 1. 框選(**bounding box**)座標位置 2.零件類別 **index** 值，做為之後輸入層的資料。本研究最終以 **92 張照片**來進行訓練。

2. 製作 YOLO 訓練資料所需檔案資料夾，以 **cfg** 檔作為設定模型參數資料。

3. 在 **Google Colaboratory** 編程環境進行模型運算，並調用 **RAM** 和 **GPU**。

YOLO 訓練時，在評判物件偵測的成效上，本研究使用 **mAP**(mean average precision) 指標。物體識別的 **IoU** 為物體建模時標記的範圍，去除以預測系統偵測到的範圍，即這兩個集合的交集和聯集之間的比例(**AP, average precision**)。mAP 便是所有類別 **AP** 加總的平均值。



圖六：使用 labeling 進行物件標註

```

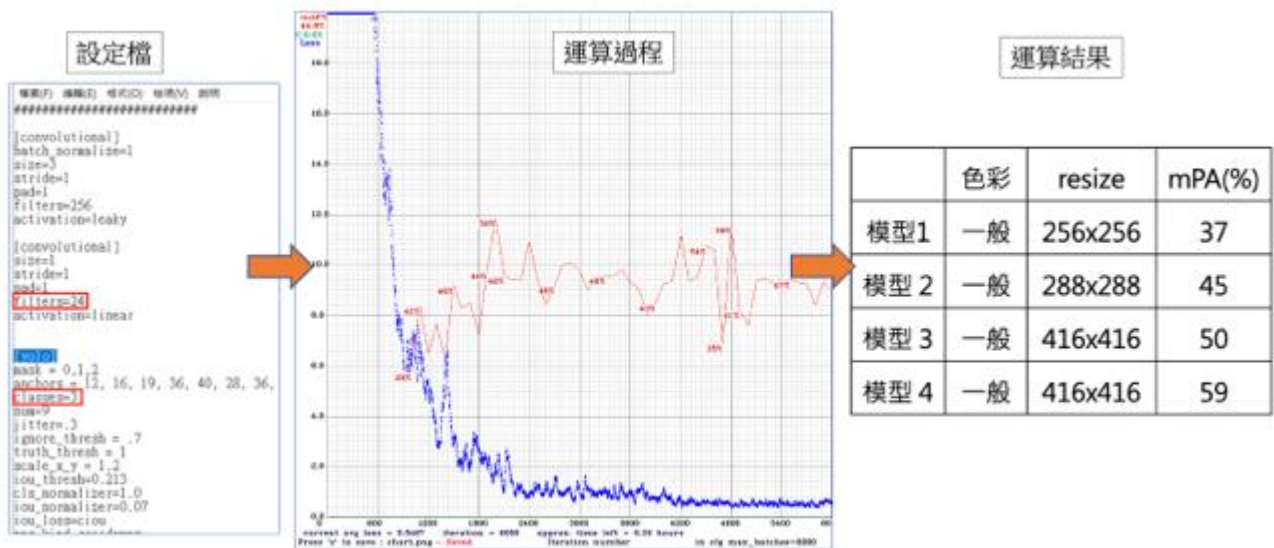
! /content/darknet/darknet_detector train /content/board/data/board_data /content/board/cfg/yolov4-board.cfg /content/board/cfg/yolov4-board.conv.137 -dont_show -map
Streaming output truncated to the last 5000 lines.
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 154 Avg (IOU: 0.736783), count: 8, class_loss = 0.825312, iou_loss = 8.872444, total_loss = 9.697757
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 161 Avg (IOU: 0.600000), count: 1, class_loss = 0.000014, iou_loss = 0.600000, total_loss = 0.600014
total_box = 11012031, rewritten_box = 9.358675 *
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 139 Avg (IOU: 0.709549), count: 31, class_loss = 4.181622, iou_loss = 331.387115, total_loss = 335.568737
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 150 Avg (IOU: 0.811305), count: 8, class_loss = 1.124608, iou_loss = 4.529130, total_loss = 7.653738
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 161 Avg (IOU: 0.783779), count: 1, class_loss = 0.204657, iou_loss = 0.179846, total_loss = 0.484503
total_box = 11012049, rewritten_box = 9.358678 *
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 139 Avg (IOU: 0.774165), count: 33, class_loss = 7.395109, iou_loss = 522.389331, total_loss = 529.784444
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 150 Avg (IOU: 0.813215), count: 8, class_loss = 0.009887, iou_loss = 18.113263, total_loss = 18.123150
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 161 Avg (IOU: 0.600000), count: 1, class_loss = 0.003379, iou_loss = 0.600000, total_loss = 0.603379
total_box = 11012119, rewritten_box = 9.358678 *
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 139 Avg (IOU: 0.848113), count: 38, class_loss = 3.489423, iou_loss = 319.381608, total_loss = 322.871031
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 150 Avg (IOU: 0.793722), count: 17, class_loss = 1.405824, iou_loss = 25.883317, total_loss = 27.289142
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 161 Avg (IOU: 0.600000), count: 1, class_loss = 0.003372, iou_loss = 0.600000, total_loss = 0.603372
total_box = 11012183, rewritten_box = 9.358674 *
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 139 Avg (IOU: 0.784117), count: 37, class_loss = 1.733650, iou_loss = 432.139771, total_loss = 433.873413
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 150 Avg (IOU: 0.783782), count: 13, class_loss = 0.736912, iou_loss = 13.938994, total_loss = 14.675906
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 161 Avg (IOU: 0.793162), count: 2, class_loss = 0.086854, iou_loss = 1.242903, total_loss = 1.329741
total_box = 11012215, rewritten_box = 9.358674 *
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 139 Avg (IOU: 0.844337), count: 43, class_loss = 4.563841, iou_loss = 349.331299, total_loss = 353.895142
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 150 Avg (IOU: 0.713188), count: 8, class_loss = 2.425248, iou_loss = 10.794203, total_loss = 13.219443
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 161 Avg (IOU: 0.600000), count: 1, class_loss = 0.000000, iou_loss = 0.600000, total_loss = 0.600000
total_box = 11012288, rewritten_box = 9.358673 *
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 139 Avg (IOU: 0.788773), count: 49, class_loss = 5.197587, iou_loss = 648.840820, total_loss = 654.038391
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 150 Avg (IOU: 0.819969), count: 6, class_loss = 0.009151, iou_loss = 7.670241, total_loss = 7.679395
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 161 Avg (IOU: 0.600000), count: 1, class_loss = 0.000008, iou_loss = 0.600000, total_loss = 0.600008
total_box = 11012322, rewritten_box = 9.358673 *
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 139 Avg (IOU: 0.651173), count: 29, class_loss = 4.793244, iou_loss = 381.948451, total_loss = 386.741725
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 150 Avg (IOU: 0.822181), count: 10, class_loss = 0.909974, iou_loss = 12.191438, total_loss = 13.091413
v3 [iou loss, Normalizer: (iou: 0.07, obj: 1.50, cls: 1.00) Region 161 Avg (IOU: 0.851882), count: 3, class_loss = 0.712093, iou_loss = 2.798035, total_loss = 3.510127
total_box = 11012345, rewritten_box = 9.358670 *

```

圖七：Model training on Google Colaboratory

實際上每次數據都耗費數十小時進行，過程如圖所示。






圖八：YOLO 訓練過程(作者整理)

### (三)、紅外線影像處理

除了上述可見光影像外，根據論文近紅外光(800–1100nm)在機器視覺中的應用亦扮演重要角色。由於高解析度的紅外線攝影機價格不菲，在本研究中，我們選擇比較低成本的操作方式，使用一般有簡單夜視功能的鏡頭（感光元件是 CMOS），沒有紅外光濾片，500 萬像素。透過另外使用 850nm 波段的 LED 陣列燈源，增加紅外線波段的照射比例，並於暗室拍攝，藉此來逼近近紅外光攝影的效果。




圖九：紅外線攝影零組件(由作者製作)

而紅外光實驗可以在黑暗中進行，能避免一些金屬反光問題，因為通常日光下的反光會呈現一區白亮點，代表著一個區塊的 RGB 值偏白色，在圖像解析上會產生數值問題。運用紅外線可以減緩這樣的現象發生。我們以紅外線照片來另外訓練一個 YOLO 模型，來進行後續實測。

#### (四)、傳送帶 PID 控制

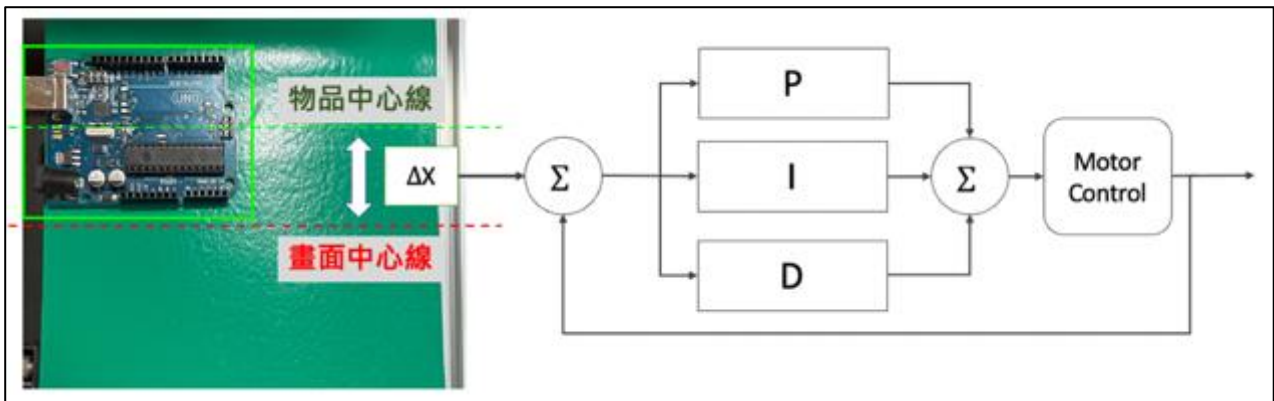
在實際測試時會發現，有時待測物可能因形狀大小差異，並不會停在鏡頭的中央，可能因此產生視角的差異，影響判別。本研究欲改善此問題，想到利用 PID 控制法結合圖像輪廓辨識，來自動調整傳送帶。

而輪廓邊緣的做法是利用 OpenCV 將圖圖像二值化處理，並利用 `findContours` 找出同樣數值的等高線，並圍成一個圖形。



圖十：圖像輪廓線與邊緣處理

PID 控制器是一個常見的閉環控制器，由比例單元、積分單元、和微分單元組成，可以根據當前值跟目標值的誤差(**error**)計算輸出，讓當前值趨向目標值，減少誤差。在本機器中，主要邏輯是目標將 **error** 控制在離畫面中心線  $\pm 10\text{px}$ (像素)以內，當取得即時的 **error**，經由 PID 運算，可以輸出一個馬達 PWM 控制數值，此時可以對馬達進行速度和正反轉的微調控制。

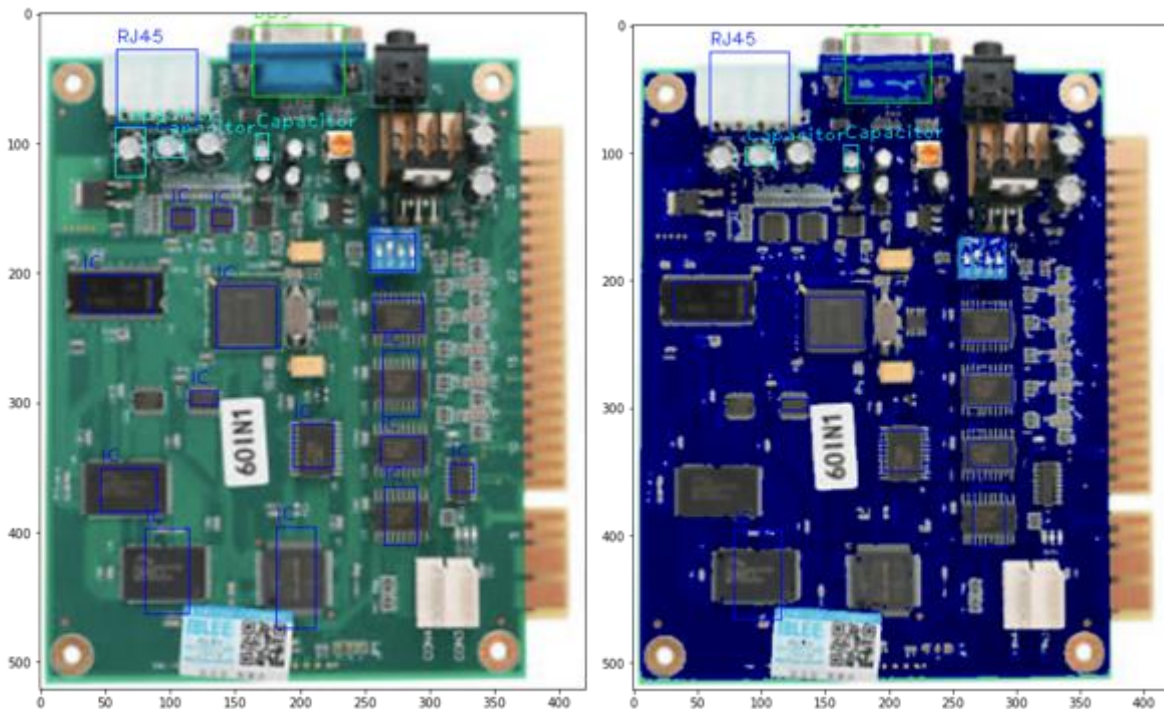


圖十一：本研究傳送帶 PID 控制邏輯

#### (五)、其他圖像技術

本研究也探討透過遮罩 **Mask** 的方法來增加重點項目的暴露，比方將 **PCB** 底板或不重要的圖像位置用單一顏色屏蔽掉。因為發現許多數目標零件，多以黑色、白色、銀色居多。

其方法是透過整體像素的 **RGB** 值，針對特定範圍進行過濾。透過比較不同遮罩顏色來觀察，是否對於辨識效能有影響。不過經過比較後，由於 **PCB** 種類過多，顏色過於複雜，難以用單一遮罩顏色方式取得良好的屏蔽效果。



圖十二：遮罩效果，左邊為未遮罩，右邊為藍色遮罩



## 參、研究結果與討論

### 一、YOLO 模型比較


#### (1) mAP 探討

在 YOLO 的計算裡，圖片的 **resize** 資料須為 **32** 的倍數，因此本研究使用 **256**、**288** 和 **416** 進行比較，最終本研究取出超過 **mAP** 大於 **35** 的模型，進行探討和外部資料測試，在測試的結果上，本研究僅挑出判斷正確的元件情形，誤判者不列在統計裡：

從實測資料可以發現，**mAP** 高的模型，在各種元件的診斷上都有明顯較高的識別率。

	色彩	width/height	mAP(%)
Model1	一般	256x256	37
Model 2	一般	288x288	45
Model 3	一般	416x416	50
Model 4	一般	416x416	59

在實測上面我們以 **11** 個外部 **PCB** 照片來做測試，列出模型有偵測到的元件種類 (**HDMI** 與散熱器因數量不多，未採計進來，並作統計排列。



圖十三：各模型實測數據





## 二、圖片分割作法


利用 Python OpenCV 套件進行圖片切割，探討較小面積單位照片：

以下列出兩個實測案例，將圖片分割成 2x2 共 4 張子圖片進行判讀，可以發現幾個現象：


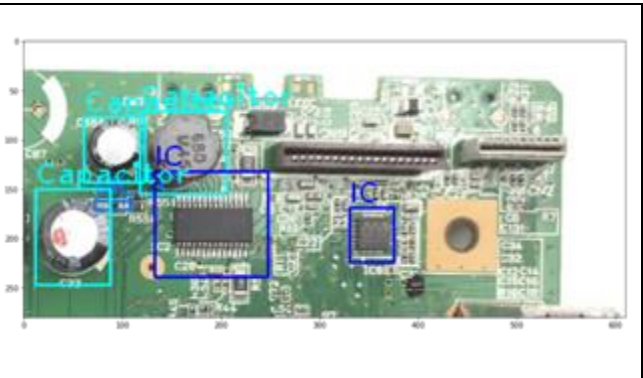
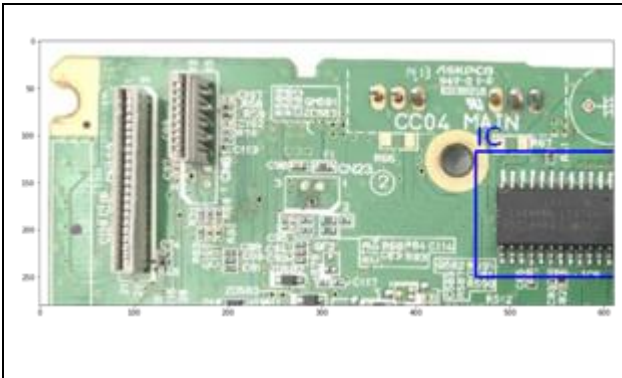

- 即使元件因圖片分割關係被切掉一部分，還是可以就分類出來。
- 圖片分割後，相對來說元件比例變大，也容易被當成其他元件造成誤判。







□



### 三、紅外線圖像建模

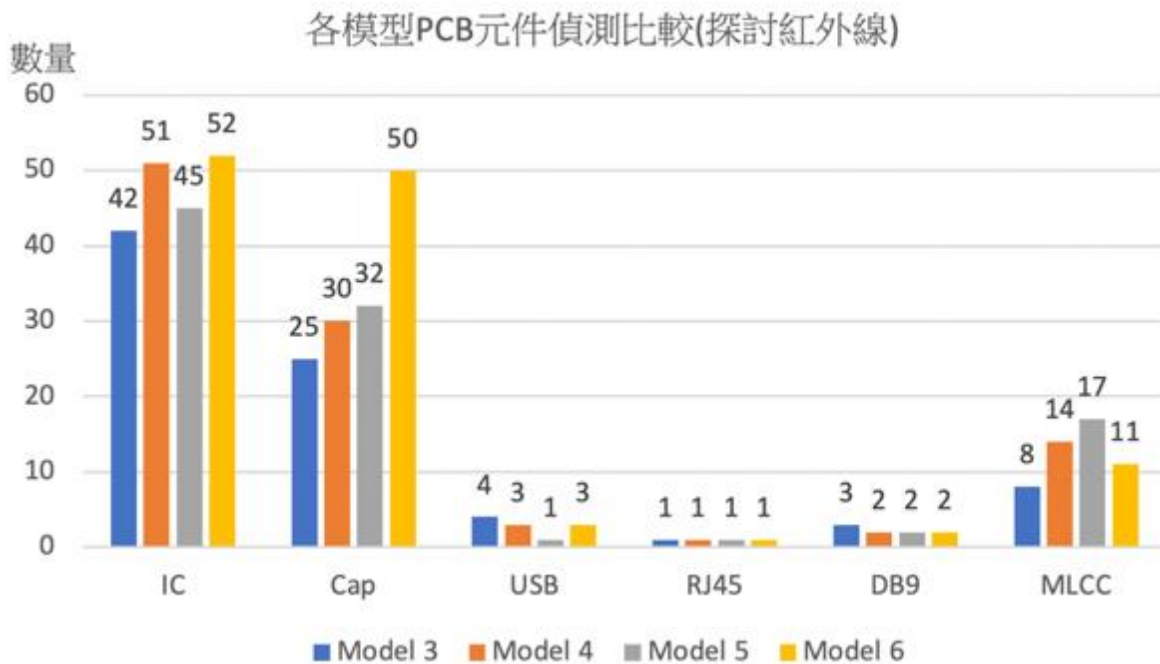
以紅外線攝影方式所說得之照片來建立模型，其實驗記錄如下：

根據前面一般照片的經驗，紅外線圖像選擇以 **resize 416** 來進行，本研究挑出兩個 **mAP** 較高的模型，以下稱 **Model 5** 和 **Model 6**：


	色彩	width/height	mAP(%)
Model 5	紅外光	416x416	45
Model 6	紅外光	416x416	53

紅外線圖像模型實測上有幾個發現：

- (1) 在物件分類上，對於較大塊的 **IC** 元件，有較高的成功識別機率。
- (2) 針對黑色的電解電容，有非常好的識別能力，能挑出較多的數量。
- (3) 一般 **PCB** 上面會有一些像是標籤紙、上膜(**coating**)透明材質反光、紋印字等問題。在可見光的環境下比較可能造成問題。這些貼紙或上膜的材質在紅外線照射下，因其不反射紅光的特型，特徵都會被抹除。




圖十五：各模型比較，加入紅外線圖像模型(Model 5, 6)




正確 IC\*3 Capacitor\*2



正確 IC\*1 Capacitor\*2



正確：IC\*2



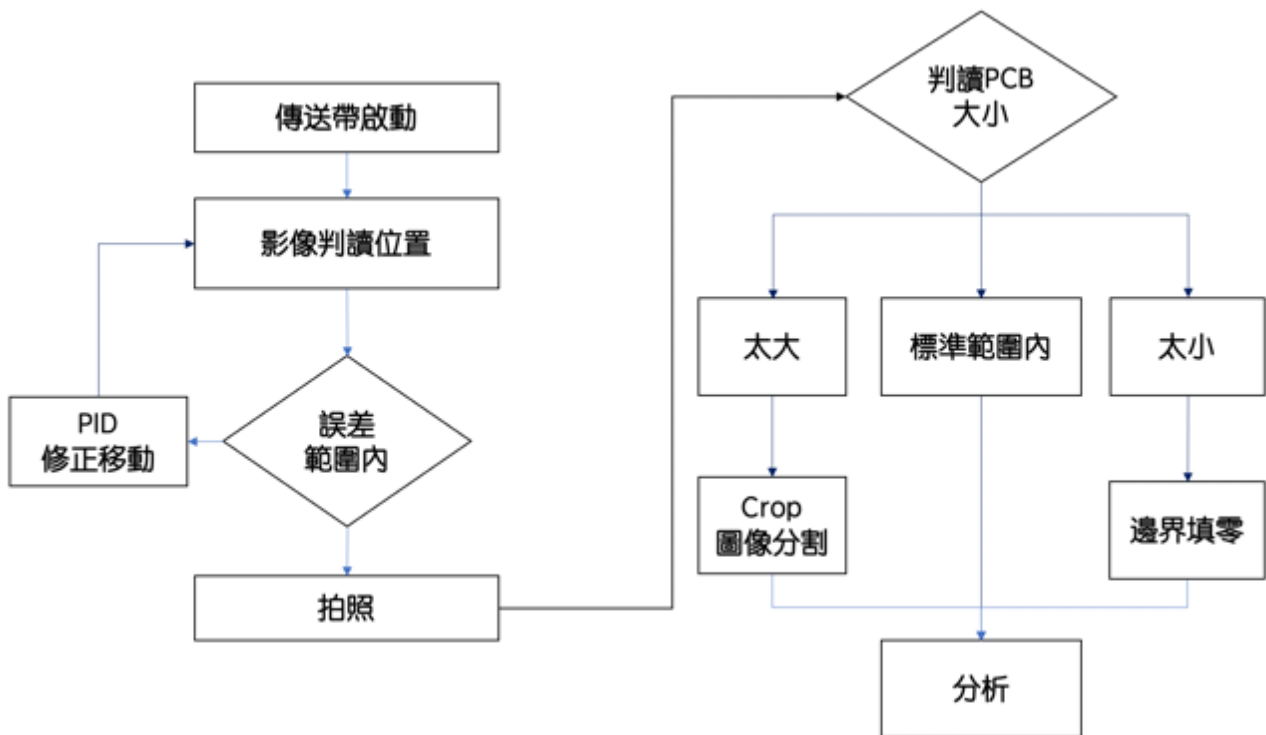
正確：IC\*1 USB\*1

圖十六：同一待測物在一般光線和紅外光下的偵測差異

#### 四、原型機開發

##### (一) 原型機傳送帶與攝影機運作流程

其工作流程如下圖，整個傳送帶長度是 60cm，現階段完成一片 PCB 板的偵測約 8 秒鐘 (含傳送帶運作時間)。

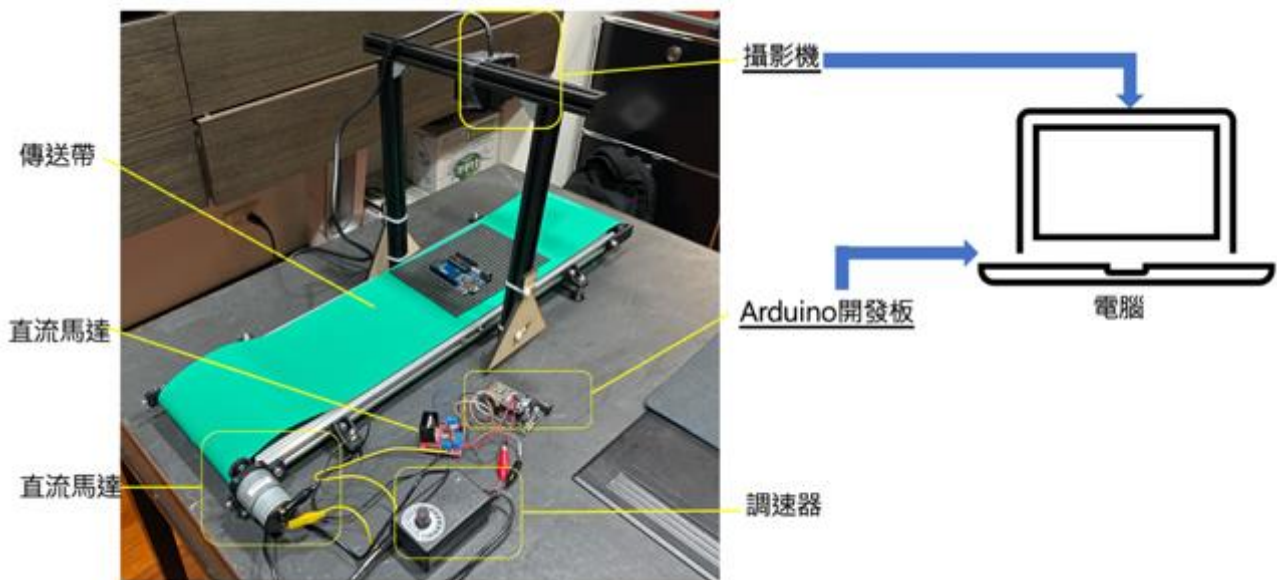


圖十七：原型機工作流程圖

## (二) 執行步驟

1. 開啟 **Anaconda** 執行主 **Python** 程式以串列溝通套件 **pyserial** 來下指令給 **Arduino** 開發板程式執行馬達轉動後，當物體正確出現在畫面中央時，以連接在筆電的 **web camera** 進行拍攝照片。
2. 當啟動拍攝照片資料後(1080P 畫質)，照片會回傳到存放在筆電的模型測試程式進行分析，模型將結果存成一文字 **txt** 檔案
3. 利用 **C** 語言解析該 **txt** 檔案，搭配金屬重量資訊進行評鑑後，回傳給可編程開發板進行後續分類動作。





圖十八：PCB 回收機原型架設

```

import serial
from time import sleep
import sys

#COM_PORT = 'COM4' # 請自行修改序列埠名稱
COM_PORT = '/dev/cu.usbserial-0001'
BAUD_RATES = 9600
ser = serial.Serial(COM_PORT, BAUD_RATES)

net = cv2.dnn.readNetFromDarknet("yolov4.cfg", "yolov4_board.weights") #載入模型，可更改權重檔名

layer_names = net.getLayerNames()
output_layers = [layer_names[i - 1] for i in net.getUnconnectedOutLayers()]
classes = [line.strip() for line in open("board.names")]#讀類別
colors = [(0,0,255), (255,0,0), (0,255,0),(120,120,255), (255,255,0), (0,255,120),(120,0,255), (0,255,255), (255,

cv2.namedWindow("frame")
cap = cv2.VideoCapture(0)#0表示內建攝影機，數字1為外接式
while(cap.isOpened()):
    ret, img = cap.read()
    if ret == True:
        cv2.imshow("frame", img)
        k = cv2.waitKey(100)#等待時間內按下z鍵
        if k == ord("z") or k == ord("Z"):
            cv2.imwrite("test_for_mask.jpg", img)
            break

```

圖十九：python 程式碼之串列/攝影機溝通

在實測上，以的模型來偵測一塊大小約一個 10x8 公分的小 PCB 板，能正確偵測出 (已扣除誤判者)：USB 接頭 2 個、IC 處理器 3 個、電解電容 11 個，即總共能提出 3.85 克的鋁、1.5 克的銅、3.01 克的鐵，總計 8.36 克的金屬。





圖二十：偵測後，回收金屬含量統計

## 六、討論

(一)在模型訓練上，針對不同的圖片 **resize**，可以得出不同的 **mAP** 比例。在實驗過程中，圖片 **resize** 長寬為 **416x416** 為較高者，有機會取得更高的 **mAP** 值，但相對訓練的所花費時間也久。

(二)在實測上，針對同樣的測試 **PCB** 板，隨著模型擁有較高 **mAP** 值，能挑出越多的零件。

(三)在零件辨識結果上，以 **IC** 處理器和電解電容這兩者有最高的辨識率。

(四)本研究發現較小的物件(**small component**)，可能是因為輸入圖片被 **resize** 後，其解析度變低，以致於無法辨識，於是導入圖片分割技術，將原圖進行分割後，在小張圖片上能辨識出更多物件，不過也增加誤判的情形。

(五)依據實驗結果，紅外線圖像 **Model 5**、**Model 6**，針對 **IC** 元件和電解電容元件的辨識能力，比其他模型來的高。

## 肆、結論

一、本實驗使用 YOLO 建立 PCB 零件辨識模型，並選擇常見的 9 種零件作為訓練目標，模型 mAP 最高可達 59。

二、針對 **small component** 如較小的電容和 **IC**，透過圖片分割方法，能有效增加辨識的總物件數量。

三、在傳送帶定位上，透過 **PID**、偵測邊緣和輪廓的方式，能夠自動調整將待測物移動到畫面中心，藉此提高偵測識別率。

四、紅外線圖像模型能起到輔助搭配的作用，特別是大顆 **IC** 或 **MCU** 的偵測上，能有較好的表現。

五、在回收價值上，依照目前辨識出 **IC**、**USB** 和電容為主來看，將有助於提升銅和鋁的再生金屬貢獻量。

本研究在影像辨識 **PCB** 電路板回收流程，已實際完成每個環節之技術研發，並能以自動化方式進行，透過一般拍攝與紅外線拍攝雙重的確認，以及大圖分割作法，可以有效增進辨識零件的數量，提高電子廢棄物的回收價值數據化能力。

## 伍、參考資料

- 一、黃靖萱、管嫻媛(2021), 一支 iPhone 背後的零碳生存戰, 商業週刊, 1761 期。
- 二、北美智權報(2021), 2030 年全球電子垃圾將達 7470 萬噸 ICT 產業加速循環經濟應用, 取自 <https://udn.com/news/story/6871/5984890>
- 三、鄧文淵, Python 機器學習超進化: AI 影像辨識跨界應用實戰, 1 版, 碁峰資訊股份有限公司, 2020
- 四、吳尚軒(2021), 使用 YOLO 辨識金屬表面瑕疵, 中央大學 生物醫學工程研究所
- 五、Google(2021)。鋁合金的奧秘: 為 Google 產品打造全新的再生合金, 取自 <https://sustainability.google/intl/zh-TW/progress/projects/recycled-aluminum/>
- 六、The Global E-waste Monitor (2020) from [https://ewastemonitor.info/wp-content/uploads/2020/11/GEM\\_2020\\_def\\_july1\\_low.pdf](https://ewastemonitor.info/wp-content/uploads/2020/11/GEM_2020_def_july1_low.pdf)
- 七、Environmental Progress Report (2021,March).from [https://www.apple.com/environment/pdf/Apple\\_Environmental\\_Progress\\_Report\\_2021.pdf](https://www.apple.com/environment/pdf/Apple_Environmental_Progress_Report_2021.pdf)
- 八、Design of a Proper Recycling Process for Small-Sized E-waste(2015) from 12th Global Conference on Sustainable Manufacturing

## 【評語】 100007

1. 本作品由產業議題出發，正視永續問題，具有重要性，值得肯定。
2. 系統的搭建和模型的訓練，說明屬完整。

電子零件的種類繁多，不少同一類元件的封裝也具有極大差異，建議進一步討論零件種類增加時對模型辨識能力和運算效能的影響。

3. 回收金屬的價值具有差異性，建議可進一步討論高價金屬和對環境具危害性元件的辨識。