

中華民國第 65 屆中小學科學展覽會

作品說明書

高級中等學校組 工程學科(一)

團隊合作獎

052308

水污染智能偵測系統

學校名稱： 高雄市立高雄高級工業職業學校

作者： 職二 蔡季蓁 職二 鄭穎鴻 職二 陳冠翔	指導老師： 鄭家和 王志偉
---	-----------------------------

關鍵詞： 「光電機智」整合、分光光度法、類神經網路

作品名稱：水污染智能偵測系統

摘要

磷污染及重金屬的累積被確認為引發水體富營養化及生態毒性的關鍵因素，對接觸受污染水的動物和人類造成危害[1]。磷酸鹽作為磷污染的主要形式，傾向於促進藻類的過量繁殖，而重金屬離子因其高度毒性及生物累積性，對水生生物的影響尤為嚴重。由於一般檢驗方式過於耗時、費力，所以我們想研究出可以實現快速檢測出水是否遭受到污染的系統。

本作品將化學、光學、電機、機械、AI、微電腦領域知識進行「光-電-機-智」深度整合，使用AI輔助補償演算法提高作品方便性，提升水溶液的定性定量分析效率，使本作品能快速檢測水源是否遭受磷或重金屬鉛污染，並且計算濃度，無需將樣本送回實驗室，捕捉污染動態。降低成本與操作門檻，達到良好監測及做好水土保持。

壹、前言

一、研究動機

隨著工業化、城市化及農業發展的加速，水體中磷[1]與重金屬污染問題日益嚴重。磷作為促進富營養化的關鍵因子，引發了藻類的過量繁殖，進而導致水體缺氧及生態失衡；同時，重金屬因其高度毒性及生物累積性，對水生生物和人類健康均構成潛在威脅。

水污染主要來源於農業化肥流失[1]、工業廢水排放以及生活污水。這些污染源具有分散性、間歇性和複雜性，使得傳統的實驗室檢測方法難以應對：

時間滯後：實驗室檢測需要採樣、運輸、分析，耗時長，無法即時反映水質變化。

成本高昂：專業設備與試劑價格昂貴，且需要技術人員操作，難以普及。

空間限制：實驗室檢測無法現場連續監測，難以捕捉污染事件的動態變化。

二、 研究目的

為了解決上述問題，我們決定開發一種水污染監測的智慧型光學檢測器[2]。這一設備的設計初衷是：能夠在現場快速檢測磷與重金屬的含量，無需將樣本送回實驗室，降低成本與操作門檻，讓更多單位能夠負擔並且使用。

三、 文獻回顧

（一）磷：

常被稱為天使與魔鬼的元素，其由十七世紀的德國商人亨尼格·布蘭德（Henning Brand）第一個發現磷元素[3]，用途十分廣泛（如圖1），近年來，隨著工業化與農業集約化的快速發展，水體中的磷污染（如圖2）問題日益嚴重。磷作為一種關鍵營養元素，雖然對生物生長至關重要，但過量的磷排放會導致水體優養化，引發藻類大量繁殖，消耗水中氧氣，破壞生態平衡，甚至威脅飲用水安全，故磷污染的控制已成當務之急。



圖1 磷的常見應用(資料來源:作者自行繪製)

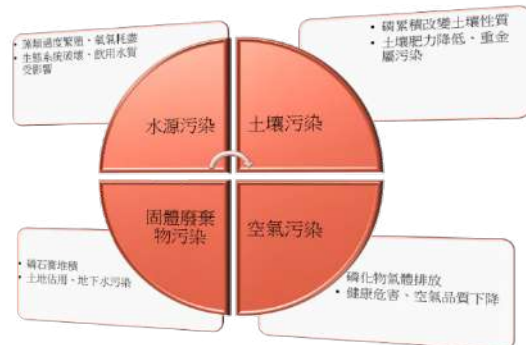


圖2 磷的常見污染(資料來源:作者自行繪製)

（二）重金屬污染：

近年來，水體污染中重金屬及其化合物的生物累積性與環境持久性特徵，已受到國際環境毒理學界的嚴密關注，此類物質可經由食物鏈傳遞產生生物放大效應，並通過氧化、遺傳調控及離子通道干擾等分子機制誘發多系統病理損傷。以下針對主要重金屬物種進行闡述：

砷 (As)

雖然不是典型重金屬，但飲用含砷水會讓身體DNA修復過程出現錯誤。長期暴露可能導致皮膚癌等燒毀現象，國際癌症機構已列為最高風險等級[4]。

鉛 (Pb)

鉛暴露被認為對中樞與周邊神經系統、血液及腎臟造成損害。孕婦在鉛暴露環境中，其早產與流產風險被顯著增加；胎兒發育遲緩的情形亦被觀察，研究顯示每5μg/dL血鉛濃度，嬰兒神經缺陷風險加倍[5]。

鎘 (Cd)

鎘的生物毒性呈現明顯的器官特異性，鎘之長期累積被證實與腎功能障礙、蛋白尿及貧血等狀態有關。骨骼中鈣磷流失與骨質軟化的現象，亦被觀察到。兒童骨骼與神經系統發育受損，以及肺癌風險增加的情形，均與鎘暴露相關。鎘之致癌性亦已被列為第一類致癌物，日本「痛痛病」案例顯示，鎘污染會讓腎臟的過濾系統完全失效[6]。

汞 (Hg)

汞的毒性作用主要與中樞及周邊神經系統損傷相關。顫抖、感覺異常與記憶力減退等神經症狀，已被多項研究所報導。此外，腎臟及呼吸系統症狀亦被指出與汞中毒有關。汞之生物可利用性與環境風險，已被認定為極具威脅性。

(三) 分光光度法：

本作品目的為開發一種高效檢測方式故採用分光光度法。

1. 分光光度法 (Spectrophotometry) [4][5] 是一種利用物質對特定波長光的吸收來進行定性和定量分析的方法。當光線通過樣品時，樣品中的分子會選擇性地吸收特定波長的光，導致透射光的強度減弱，這種吸收與樣品的濃度和性質有關。光度計測量樣品吸收光線的方式大致可以分成以下幾個步驟：

- (1) 先把光線分解成不同顏色的光。
- (2) 從中挑選出特定波長的光。
- (3) 讓單一色光穿過樣品。
- (4) 測量光穿過樣品後的強度，再轉換成數值。
- (5) 最後就能得到樣品對這個光的吸收程度。



圖 3：分光光度法架構設定流程圖(資料來源:作者自行繪製)

2.定性分析

分光光度法的定性分析[10][11]是根據物質對特定波長光的吸收特性來判斷其組成。例如，每種物質在不同波長下的吸收光譜是獨特的，類似於「光學指紋」。通過測量樣品的吸收光譜並與已知標準光譜比對，就可以確認樣品中的成分。

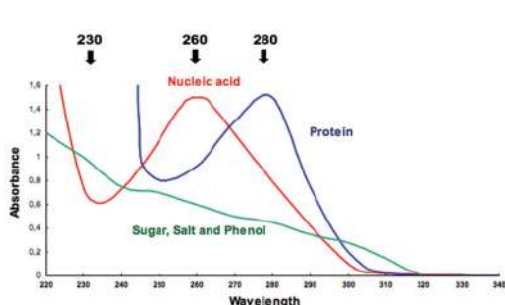


圖 4：核酸、蛋白質光譜圖[20]

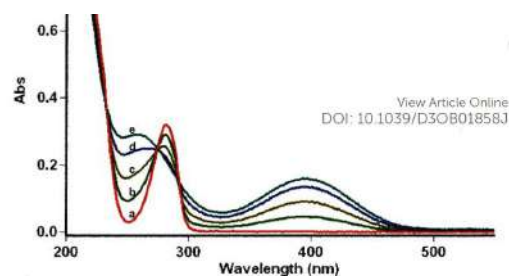


圖 5：磷緩衝鹽水UV光譜圖[21]

3.定量分析：

定量分析則是通過測量樣品對特定波長光的吸收程度來確定其濃度。當樣品濃度增加時，吸收光的程度也會增強。這種關係可以用 朗伯-比爾定律（Beer-Lambert Law）來表示：

透過透射率（Transmittance, T ）來表示吸光度（Absorbance, A ）。透射率定義為透射光強度與入射光強度的比值：

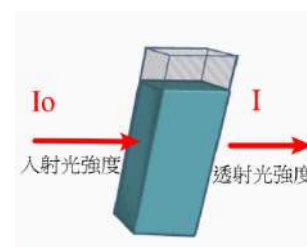


圖 6 光通過溶液示意圖 (自行繪製)

$$T = \frac{I_o}{I}$$

其中：

I_o ：入射光強度（光進入樣品前的強度）

I ：透射光強度（光穿過樣品後的強度）

吸光度（ A ）與透射率（ T ）的關係為： $A = -\log T$

最後透過比爾定律，吸光度與溶液濃度成正比關係，算出溶液濃度。

（四）樹莓派 pigpio library 對步進馬達之脈波控制

1. 軟體方式產生脈波：

在步進馬達應用中，根據步進電機每接收到一個脈衝便會移動一定角度的原理，控制系統常以發送固定數量之脈衝來實現精確定位。通常步進馬達驅動器可設定旋轉 360° 所需之脈衝數，稱為解析度。例如，若解析度設定為 2000，則發送 2000 個脈衝可使電機完成 360° 之旋轉；解析度越高，則最小可控移動角度越小，進而達到更高之控制精度。

在樹莓派一般的作法裡，採用軟體方式[12]產生脈衝波形來驅動步進電機，但這種方法不可避免地受到中斷、多線程調度等因素的干擾，進而導致產生的脈衝頻率偏低。以表2 為例說明：若每個脈衝週期由高電平延遲 0.005 秒與低電平延遲 0.005 秒構成，總週期約為 0.01 秒，對應的頻率為 $1/0.01 = 100 \text{ Hz}$ 。若根據此頻率，且假設旋轉 360° 所需的脈衝數為 2000 個，則整圈旋轉將耗時 $2000 \div 100 = 20$ 秒，這明顯低於步進電機應達到的理想轉速。

表1 軟體脈波產生說明表 (資料來源：研究者自行收集)

說明	程式碼
<p>pulseDelay = 0.005S</p> <p>$T = 0.005 + 0.005 = 0.01\text{S}$</p> <p>$F = 1/T = 100\text{Hz}$</p> <p>步進馬達轉1圈 = $2000/100 = 20\text{S}$</p>	<pre>sendPulses(int numPulses, int pulseDelay) { for (int i = 0; i < numPulses; i++) { digitalWrite(STEP_PIN, HIGH); delayMicroseconds(pulseDelay); digitalWrite(STEP_PIN, LOW); delayMicroseconds(pulseDelay); } }</pre>

若將縮短 `delay` 的延遲時間以期提高脈衝頻率，當延遲值縮小到一定程度後，軟體產生脈衝的機制將因硬體與系統調度上的極限而無法繼續正常工作。因此，僅靠減少延遲時間並不足以解決轉速過慢的問題，這也是樹莓派以軟體生成脈衝波形在高頻驅動應用中面臨的重要缺陷之一，這不符合本作品所需。

2.硬體方式產生脈波(pigpio PWM LIBRARY) [13]:

在工業自動化控制領域，精確的脈衝寬度調製(PWM)波形生成技術對運動控制系統具有關鍵作用。傳統軟體PWM方案在頻率精度與輸出頻率有技術限制，樹莓派改用基於pigpio函式庫的硬體級解決方案。實現高頻波形生成能力，加速本作品測量溶液的時間。pigpio.pi() 實現硬體 PWM生成步驟如表 2 所示:

表2 pigpio.pi() 實現硬體 PWM生成步驟(資料來源：研究者自行收集)

步驟	說明	程式碼										
1.定義波形	<p># 設定脈衝持續時間(單位:微秒)100μs</p> <p># 構建脈衝序列:先輸出高電平,再輸出低電平</p> <pre>on 100us (1<<GPIO, 0, 100) oooooooooooo oooo o o o o o o oooo oooooooooo off 100us (0, 1<<GPIO,</pre> <p># 添加該序列到波形生成器中</p> <p>T = 100+100 = 200μs</p> <p>F = 1/T = 5KHz</p>	<pre>delay_time = 100 my_pulse = [] my_pulse.append(pigpio.pulse(1<<GPIO, 0, delay_time)) my_pulse.append(pigpio.pulse(0, 1 <<GPIO, delay_time)) pi.wave_add_generic(my_pulse)</pre>										
2.波形建立	<p># 透過 wave_create() 取得波形識別碼以供後續使用</p>	<pre>wid = pi.wave_create()</pre>										
3.波形鏈播放	<p>函數 wave_chain()可用於連續播放一系列預先建立之波形,而我們使用命令 255 0 單獨發送單一波形。</p> <table><tr><th>命令</th><th>作用</th></tr><tr><td>255 0</td><td>開始一個波形序列</td></tr><tr><td>255 1 xy</td><td>循環播放 x + y×256 次數</td></tr><tr><td>255 2 xy</td><td>延遲 x + y×256 微秒</td></tr><tr><td>255 3</td><td>進入永久循環播放</td></tr></table> <p>使用(255, 0)開啟一個波形序列</p>	命令	作用	255 0	開始一個波形序列	255 1 xy	循環播放 x + y×256 次數	255 2 xy	延遲 x + y×256 微秒	255 3	進入永久循環播放	<pre>#生成2400個脈波為例 stepper_num =2400 st_y,st_x = divmod(stepper_num,256) chain = [255, 0, wid, 255, 1, st_x, st_y] #256*9=2304 + 96 = 2400 pi.wave_chain(chain)</pre>
命令	作用											
255 0	開始一個波形序列											
255 1 xy	循環播放 x + y×256 次數											
255 2 xy	延遲 x + y×256 微秒											
255 3	進入永久循環播放											

（五）類神經網路：

類神經網路是一種模仿生物神經系統運作的計算模型，由多層「神經元」（Neural Units）組成，透過「學習」數據中的特徵來完成任務（如分類、預測）。其核心原理是：在層次結構方面可分為輸入層（接收數據）、隱藏層（提取特徵）、輸出層（產生結果）。並以非線性激活函數（如ReLU、Sigmoid），賦予模型非線性能力，以擬合複雜關係，最後是反向傳播：透過計算預測誤差並反向調整權重（梯度下降），逐步優化模型。

因本系統分別使用全連結層與卷積層分別對光學數據進行訓練，所測得的光學數據是以表格方式呈現數據，其表現不佳，故將數據預處理為吸光度光譜圖，再使用卷積層訓練，得到良好效果。其兩種結構分析如下：

表3 全連接層 vs. 卷積層(資料來源：研究者自行收集)

特性	全連接層	卷積層
參數量	龐大（與輸入/輸出維度平方相關）	極少（與卷積核大小相關）
特徵提取	全局線性組合，無空間關聯性	局部區域特徵，保留空間結構
適用數據	向量化數據（如表格、簡單分類）	網格狀數據（圖像、語音、時序）
計算效率	低（高維數據下不可行）	高（參數共享+局部操作）
過擬合風險	高（參數量多需大量數據）	低（參數少，泛化能力強）

（六）常用分類預訓練模型：

經研究表明，卷積神經網路（CNN）和視覺Transformer（ViT）在影像處理中表現優異，但要選擇那一種架構進行模型訓練則取決於資料規模和運算資源。基本CNN適合小型資料集，ResNet-50和SENet在大型資料集上表現良好，EfficientNet-B7和ViT-B16在高精度要求下更具優勢，但計算成本較高。底下分述五種常見圖形辨識訓練架構：

1. 基本CNN

1998年LeCun[14]提出的LeNet-5是早期的成功案例，旨在自動化特徵提取，取代傳統手工設計特徵，利用卷積操作的空間不變性，適合小型資

料集如MNIST。基本CNN透過多層卷積層擷取影像特徵，分層化空間維度，對全連接層進行分類，適用於簡單影像分類任務。

2. ResNet-50

2016年時提出深層網絡能學習複雜特徵[15]，但傳統深網訓練困難，而跳躍連接保持權重流動，允許訓練152層網絡，贏得了2015年ILSVRC分類競賽冠軍。esNet-50透過殘差區塊和跳躍連接解決深層網路的梯度消失問題，適合大規模影像分類任務，如ImageNet。

3. SENet

2018年Hu等人提出[16]，旨在提升特徵選擇能力，2017年ILSVRC分類挑戰中表現優異，僅增加少量運算成本，適用於多種CNN架構。SENet在CNN基礎上添加Squeeze-and-Excitation塊，動態重新校準特徵通道，增強網路專注於重要特徵，適用於高精度分類。

4. EfficientNet

2019年Tan和Le提出[17]，傳統擴展方法效率低，複合縮放優化資源利用率，B7在ImageNet上達到84.3%-1精度，適合高精度任務如自動駕駛。EfficientNet-B7使用模組化縮放方法擴展網路深度、寬度和分辨率，達到高精度影像分類，適合資源容量環境。

5. Transformer

2020年Dosovitskiy等人提出[18]，Transformer在自然語言處理成功，應用於視覺任務，JFT-300M預訓練後在ImageNet上達到85.2%的精度，捕捉長距離依賴性。ViT-B16將影像分割為16x16補丁，作為令牌輸入變換器編碼器，捕捉全域依賴，適合大規模資料集影像分類。

貳、研究設備及器材

一、 作品硬體介紹

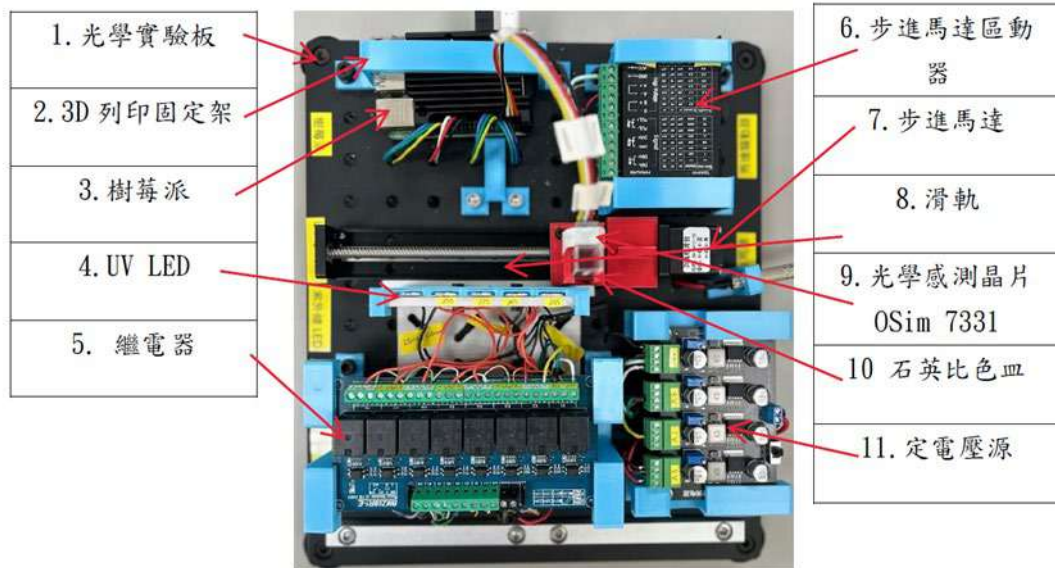


圖 7：硬體元件分布圖(作者自行繪製)

1. 光學實驗板：光學實驗室專用多孔鋁板光學鋁合金麵包板。
2. 3D列印固定架：透過支架來固定相關設備在光學板上。
3. 樹莓派：微電腦、為本系統整合與運作控制中心。
4. UV LED：波長255nm、265nm、275nm、295nm、310nm LED
5. 繼電器：讓樹莓派控制12V、9V、7V、5V 加上LED。
6. 步進馬達驅動器：TB6600 驅動步進馬達，控制正反轉。
7. 步進馬達：移動滑軌。
8. 滑軌：移動受測溶液至對應LED。
9. OSRAM AS7331 IC：提供三個獨立的UVA、UVB和UVC通道，可透過光電二極體將光輻射訊號轉換為數位收據，以實現連續或觸發型的測量。
10. 石英比色皿（高透度、耐酸鹼）：放置受測化學元素溶液。
11. 定電壓源：提供12V、9V、7V、5V電壓給系統相關設備。

二、 周邊相關設備介紹

1. 3D 列印機：
2. AI 模型訓練設備(PC、顯卡 3060)

參、研究方法

一、 研究流程：

本研究是一種問題導向跨技術架構，以系統性思考將技術重組策略整合成作品，從真實需求找出問題出發，定義目前技術可以應用的場景，再參考文獻，轉化為技術應用的靈感，整合光學、化學、電機、機械、人工智能、微電腦週邊控制等領域知識進行問題解決，接著拆解分光光度法相關技術模組，分析其限制與改進空間，重新定義本系統架構，最後深度整合後，完成本作品。

二、 架構圖與電路圖：

依照設計的功能繪出本系統的架構如圖8與電路如圖9所示。

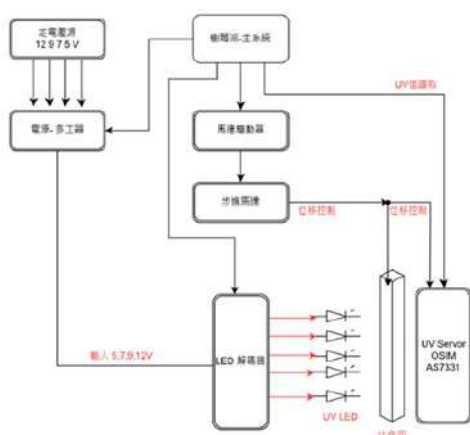


圖 8：系統架構圖(作者自行繪製)

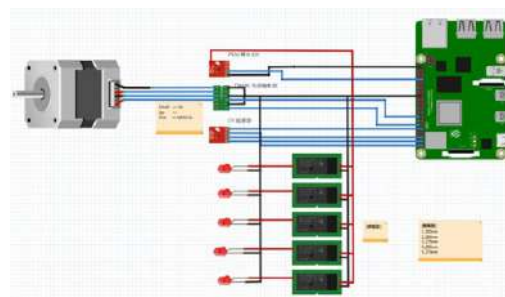


圖 9：系統模組接線圖(作者自行繪製)

三、 光源接收與計算：

(一) OSRAM AS7331 感光晶片：

AS7331是三通道感測器，使用干涉濾光片對UV-A(315nm-410nm)、UV-B(280nm-315nm)和UV-C(240nm-280nm)波段的輻射產生精確表徵的響應。濾光片也能優異地抑制環境可見光和近紅外線光源的干擾，在平時操作系統時，晶片在無UV LED燈照射下，在室內背景光源下其讀值為0，這讓本系統的UV數據讀值更加的準確。

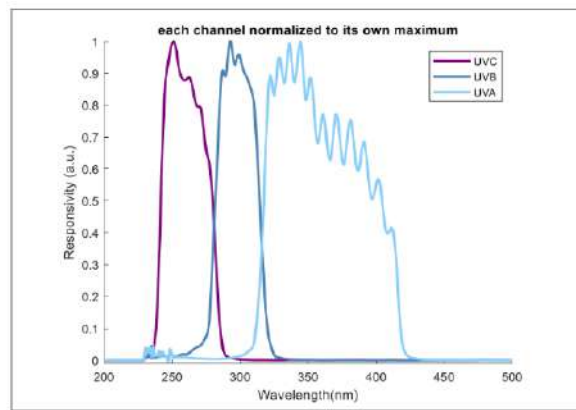


圖 11：晶片感測UV響應圖(資料來源：官網技術手冊amsOsram_AS7331_DS001047_1-00.pdf)

(二) OSRAM AS7331 晶片數據讀取方式：

晶片的通訊協議（通常是 I²C 或 SPI）。表 4 是讀取數據的基本流程：

表 4：晶片數據讀取說明表(資料來源：研究者自行收集)

操作步驟	說明
1. 硬體連接	VDD：接樹莓派的 3.3V 電源。 GND：接樹莓派的 GND。 SDA：接樹莓派的 SDA（GPIO2）。 SCL：接樹莓派的 SCL（GPIO3）。
2. 檢測晶片 I ² C 地址	sudo i2cdetect -y 1 (默認 I ² C 地址為 0x39)
3. 讀取數據	例：利用呼叫smbus庫讀取 UVA數據 AS7331_ADDR = 0x39 Data=bus.read_i2c_block_data(AS7331_ADDR, AS7331_REG_UVA_DATA, 2)
4. 數據解析	根據官方數據手冊轉換，單位: $\mu\text{W}/\text{cm}^2$

四、滑軌移動距離計算

(一) 硬體設備規格表：

表5：硬體設備規格表(資料來源：研究者自行收集)

設備名稱	規格
滑軌	T6*12-150 (滑杆直徑:6mm 轉一圈移動:12mm 有效移動距離:150mm)
步進馬達	尺寸:28mm × 30mm 步距角:1.8° 步數 200 步 (1.8°) 轉一圈
步進馬達驅動器	細分數：1/8, 驅動電流1A
UV LED間距	18mm

(二) 軟體設計：

依硬體規格及實際需求進行程式的設計，因UV LED 3D列印固定架如圖11所示，其間距為 18mm，依步進馬達與滑軌需求，樹莓派需派送 2400 的脈波，方能移動18 mm，計算方式如表7所示：

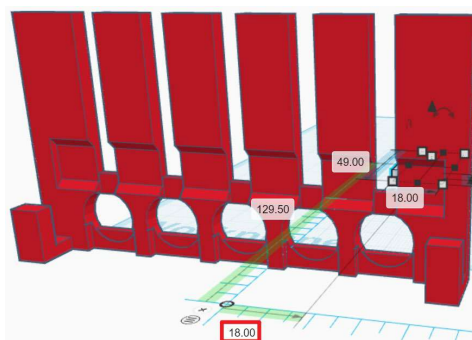


圖11 LED 固定架3D圖(資料來源：研究者自行繪製)

表7 滑軌移動18mm 計算說明表(資料來源：研究者自行收集)

需求設備	說明
步進馬達轉一圈	$(\frac{1.8^\circ}{\text{步}}) * 200 \text{步} = 360^\circ = 12\text{mm}$ (造成滑軌移動12mm)_
TB6600細分數 1/8	move 12mm = $200 * 8 = 1600 \text{ pulse}$
LED間距 18mm	$18\text{mm} * \frac{1600\text{Pulse}}{12\text{mm}} = 2400 \text{ pulse}$
樹莓派	<ol style="list-style-type: none"> 硬體連接: 滑軌方向 DIR = 8-rpi <-> TB6600 DIR 脈波 PUL = 18-rpi <-> TB6600 PUL 定義 1 個脈波(高電位 100us , 低電位 100us) <pre> on 100us {1<<GPIO, 0, 100} oooooooooooo oooo o o o o oooooooooooo oooo off 100us {0, 1<<GPIO, 100}] </pre> 使用 pigpio 庫的服務，產生 2400 個自定脈波送至 TB6600 即可讓滑軌移動 18mm

五、 功能設計

為達到作品快速簡測目標，依照分光光度法原理依其模組架構拆解並重新設計與製作本系統，其對照表如表 7 所示：

表7 分光光度法原理與本系統設計架構對照表

分光光度法原理		本系統設計原理
光源發射光： 光通過單色器： 選擇特定波長的光：	↔	多顆 不同波長 UV LED 255nm,265nm,275nm, 295nm,310nm
光通過比色皿中的樣品：	↔	移動 比色皿至對應的UV LED
樣品吸收部分光	↔	樣品吸收部分光
檢測器接收透過光 (光敏電阻)	↔	檢測器接收透過光 (OSRAM AS7331 IC)
訊號處理晶片-特製晶片 (測量透過光強度、計算吸光度)	↔	訊號處理晶片-樹莓派 (測量透過光強度、計算吸光度、分析樣品濃度、 AI分析、圖表輸出、警報LINE)

六、系統程式設計流程圖

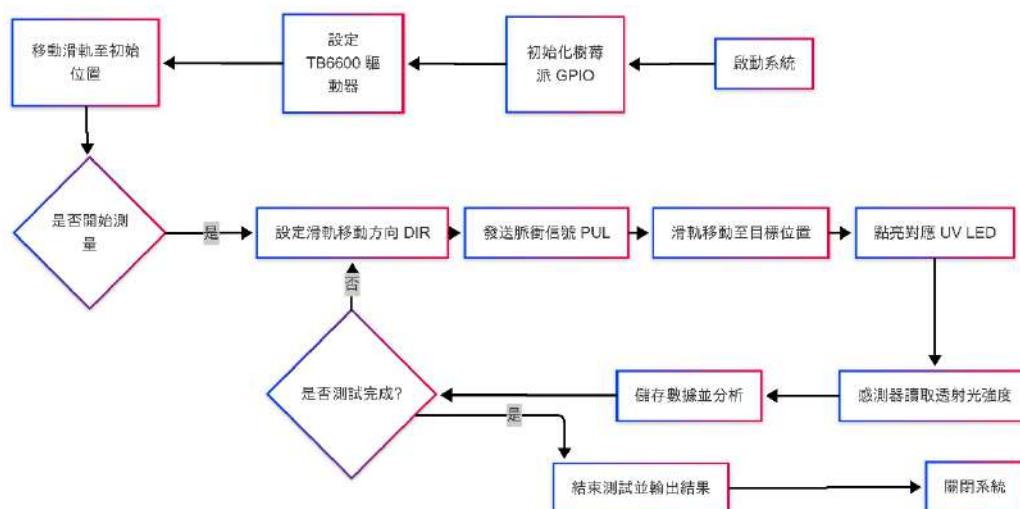


圖 12：讀取比色皿化學元素吸光度程式流程圖(資料來源：作者自行繪製)

七、光學測量數據收集及分析

(一) 光學測量數據資料收集

本作品以重金屬與磷酸鈉為實驗目標時，開始實驗時為避免過系統參數調教失敗，故在測驗系統的調教測試期，先以牛奶來測量蛋白質試驗，避免實驗廢水造成水源污染，於系統架構軟硬體皆測試完善後，再以磷酸、鉛、檸檬、

菊花等進行大量的光學資料測量。

表 8：光學測量參數一覽表(資料來源：研究者自行收集)

光學測量溶液	
溶質	1.牛奶 2.磷酸鈉 3.鉛 4.檸檬 5.菊花
溶劑	1.去離子水 2.Ro 水 3.家用自來水 4.地下水 5.河川水
溶液濃度	16000ppm,10000ppm、8000ppm、4000ppm、2000ppm、1000ppm、800ppm、400ppm、200ppm、100ppm
LED 光度控制	12V、9V、7V、5V



圖 14：磷酸溶液(資料來源：作者自行拍攝)



圖 15：五種溶劑(資料來源：作者自行拍攝)

其中以調製去離子水-磷酸鈉濃度10000ppm為例，說明如下：

1. 計算磷酸鈉與磷酸根的需求量

a.磷酸鈉的分子量 (Molar Mass)

$$Na_3PO_4 = (3 \times 22.99) + 30.97 + (4 \times 16.00) = 163.94 \text{ g/mol}$$

b.磷酸鈉的 10,000 ppm 溶液

$$\frac{10,000 \text{ mg } Na_3PO_4}{1,000} = 10.000 \text{ g } Na_3PO_4$$

所以需要 10 g 磷酸鈉溶於 1 L 水中。

2. 調配步驟：

- 稱量磷酸鈉: 電子天平精確稱量 10g
- 溶解磷酸鈉: 將量好的磷酸鈉加入水中，並攪拌至完全溶解
- 轉移至 1L 容量瓶，稀釋至刻線，溶液即為 10,000ppm
- 混合均勻：密封瓶口並充分搖勻

e. 標記與存放：試劑瓶上標記 10,000 ppm Na_3PO_4

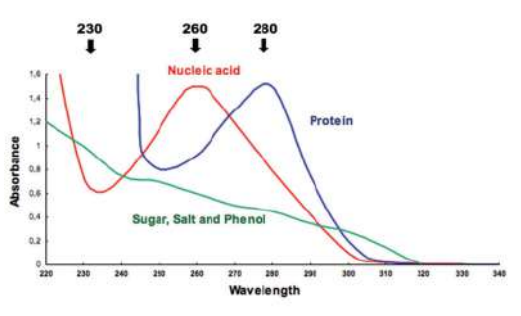
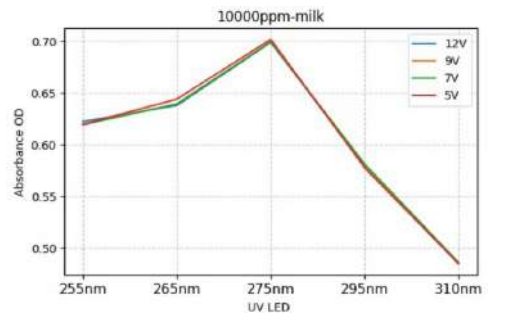
(二)光學實驗數據分析

經大量實驗所得數據，我們將針對其數據進行定性與定量分析：

(1)定性分析：

將蛋白質光學實驗所得數據，依其吸光度繪製光譜圖，與理論光譜相近，後續系統 A I 模型亦依據波形進行訓練與判斷。

表9 蛋白質理論光譜圖與本系統光學測量光譜圖對照表(資料來源：研究者自行收集)

藍色曲線是蛋白質(protein)UV 光譜圖	本系統蛋白質UV 光學測量光譜圖
 <p>(資料來源:核酸、蛋白質光譜圖[20])</p>	 <p>(資料來源:作者自行繪製)</p>
兩圖 λ_{max} 皆在 280 nm 附近，本系統測量數據與波形與理論值相同	

(2)定量分析

1.依 λ_{max} 為 275 nm 12V 之測量值，將 100ppm – 10000ppm 之吸光度整理後可得圖 16 為蛋白質濃度與吸光度分析表，依表中資料，100ppm 到 1000ppm 之間為線性關係，2000ppm 以上為非線性，故計算濃度時，採用 100-1000ppm 線段，若測量濃度超過 2000ppm，則將水樣稀釋 1/10，計算出濃度後再乘以 10 原還原來的濃度。

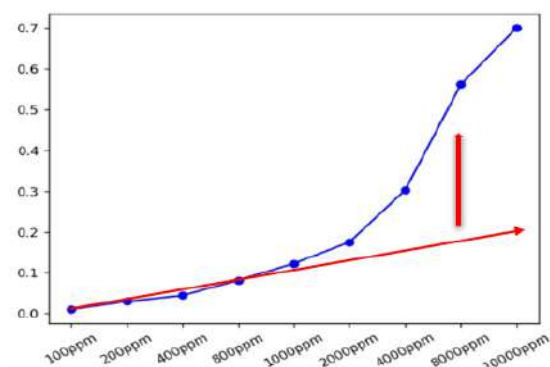


圖16 蛋白質濃度及吸光度分析(高濃度出現正偏離) (資料與圖片來源:作者自行繪製)

3. 蛋白質溶液濃度曲線擬合公式計算

從圖17中,可看出三次多項式在誤差指標RMSE=15.37和擬合度 ($R^2 = 0.998$) 上均表現最佳,但其三次項係數極大 ($-1171997.58x^3$),且使用使用4個參數的模型去擬合5個實驗數據點,其過擬合的風險相當高,故不採用。依RMSE和 R^2 數據考量,採用4個參數的模型去擬合5個實驗數據點,其過擬合的風險相當高,故不採用。依RMSE和 R^2 數據考量,採用二次多項式 $y = -5157.23x^2 + 10160.63x + -40.63$ (其中y為濃度,x為吸光度) 做為蛋白質的定量分析函數。

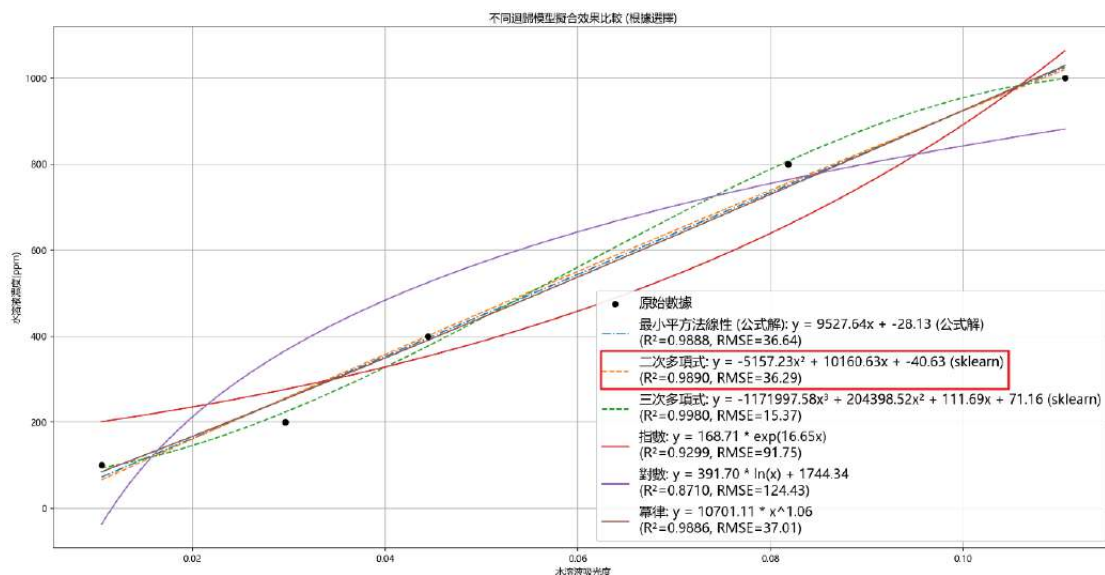


圖17 蛋白質溶液濃度擬合曲線(資料與圖片來源:作者自行繪製)

3.重金屬(鉛)溶液濃度曲線擬合公式計算

鉛擬合公式若採用三次多項式亦有過擬合之可能性,故亦採用二次多項式:

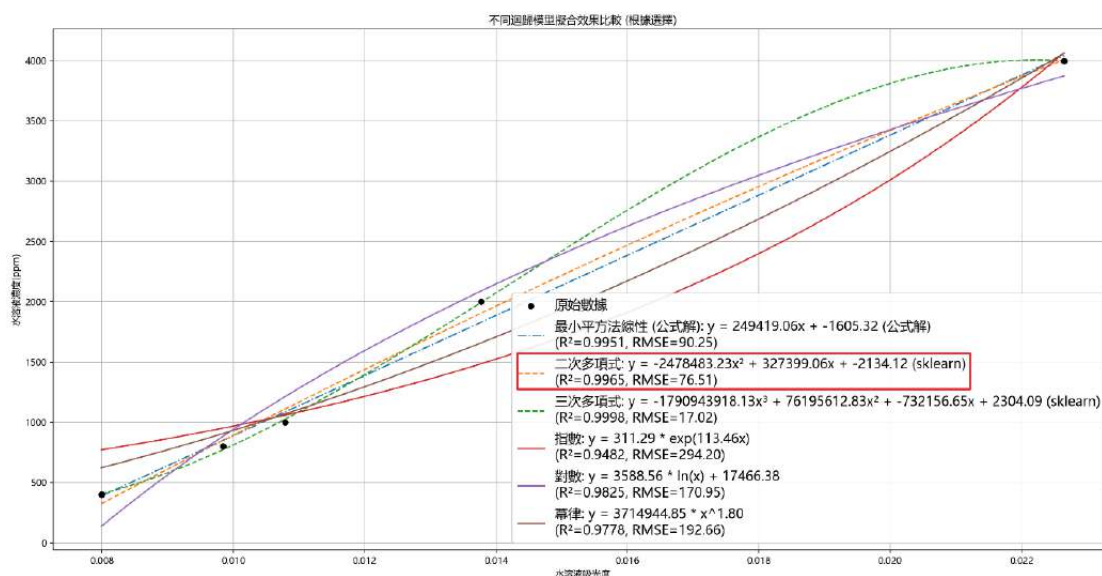


圖18 鉛溶液濃度擬合曲線(資料與圖片來源:作者自行繪製)

$$y = -5083.59x^2 + 23103.28x + 23.65$$

4. 磷酸鈉溶液濃度曲線擬合公式計算

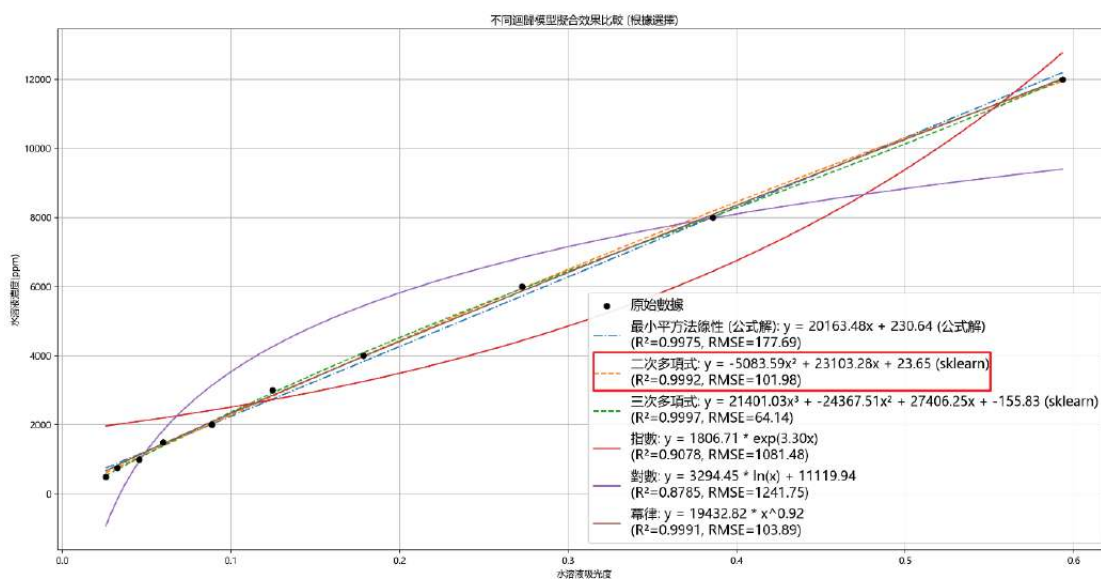


圖18 磷酸鈉溶液濃度擬合曲線(資料與圖片來源:作者自行繪製)

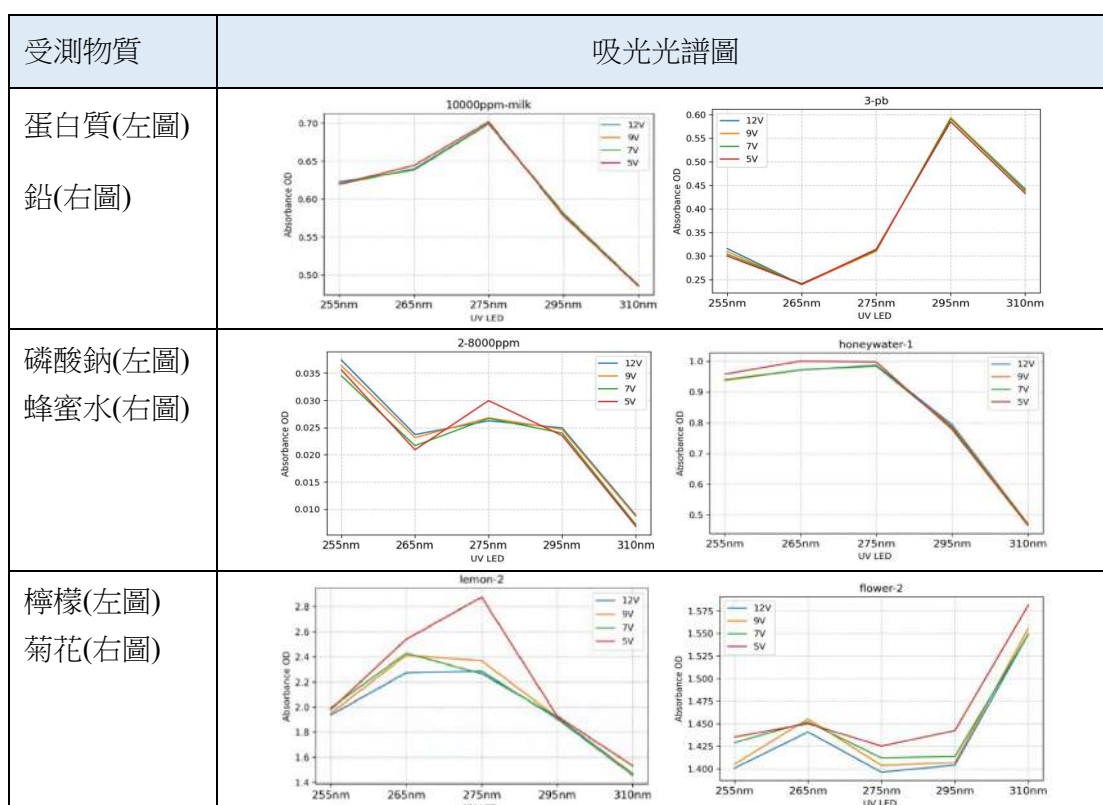
磷酸鈉溶液濃度曲線擬合公式計算採用二次多項式:

$$y = -2478483.23x^2 + 327399.06x + -2134.12$$

(3) 本系統測得各種元素之吸光光譜圖

本系統依照表 10 中的各元素不同光譜圖進行定性分析。

表10 各種元素之吸光光譜圖(資料與圖片來源:作者自行繪製)

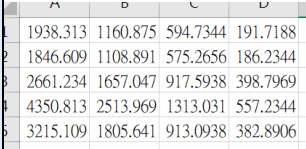



九、溶液定性—AI模型訓練與設計

(一)採用卷積模型訓練

本系統主要使用 PyTorch 進行 CNN 模型訓練和設計，因使用原始光學數據進行 3 層全連結層進行訓練，所得模型辨識率不佳，故將原始數據轉成吸光光譜圖後，所得模型辨識率得到大幅提昇，訓練模式比照如表 11 所示：

表 11：pytorch 模型訓練一覽表(資料與圖片來源:作者自行繪製)

數據預處理	無 	將原始數據 轉成 吸光度光譜圖 
架構	全連結層 Fully connected	卷積神經網路 CNN
數據分割	光學實驗數據中，5v 的數據失真不採用 訓練集:70% 驗證集:15% 測試集:15%	
模型辨識率	辨識率 低	辨識率 高

(二) 進行常見模型架構訓練

因採用CNN本研究選用五種模型：Basic CNN、ResNet50、SENet、EfficientNet B3、transformer_b16，對本設備經光學實驗所測得的數據進行訓練，將原始數據集劃分為訓練集、驗證集和測試集，比例為70%訓練，15%驗證，15%測試。所得數據如表12所示：

表 12 五種模型訓練比較表 epoch 100(資料與圖片來源:作者自行繪製)

數據集	效能表現
訓練集與驗證集效能	
訓練時間比照表	
測試集效能	

原本期望透過大型模型架構進行訓練可得到較高的準確度，但實際並非如此，經討論得下面結果：

1. 折線圖主要由水平/垂直線段、交點、趨勢線構成，屬於低階幾何特徵（如邊緣、角點）豐富但整體結構簡單的圖像類型。CNN 的局部特性能夠有效捕捉這些線條的局部變化（例如 N 形曲線的斜率變化），而 Efficient-B3 作為深層模型可能過度學習複雜且非必要的特徵。
2. 本研所得數據集較小，Efficient-B7 的龐大參數量和深度會導致過擬合，而簡單 CNN 的參數少、泛化能力更強。
3. 為探究與證實大型架構表現不佳原因，本研究使用類激活熱力圖(表15)，其能觀察模型對影像辨識的關鍵位置，經觀察訓練模型之熱力圖後，因圖形結構簡單故其熱點均在曲線上，無需反覆提取特徵。

而使用多層特徵圖(表16) 探究時，發現較多的訓練層，雖可提取更細粒度的卷積特徵，但過度學習非必要的特徵反而使圖像的整體性辨識不佳進而導致準確度下降，故在經歷5種模型的訓練後，反而Basic CNN得到不錯的表現。

4. 在使用大模型也無法準確度後，經討論覺得有可能是因為標籤問題造成，故轉向原始光學數據進行標籤清洗研究。

表 13 菊花與鉛 熱力圖(資料來源：研究者自行收集)

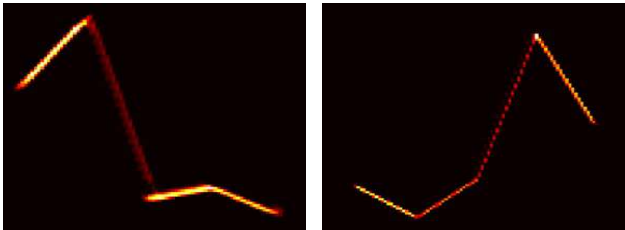




































物品	熱力圖	
菊花與鉛 熱力圖	 <p>(圖片來源:作者自行繪製)</p>	
文獻[19]中貓狗 辨識之關鍵熱力 圖	 <p>(i) Grad-CAM 'Dog' (c) Grad-CAM 'Cat'</p> <p>(圖片來源: 文獻[19])</p>	

表 14 CNN 與 EfficientNet-B3 各層特徵比較表(資料與圖片來源:作者自行繪製)

































架構	layer	菊花水溶液 吸光光譜圖 各層卷積特徵				
CNN	1					
	2					
	3					
EfficientNet B3	12					
	87					
	167					
	272					

(三) 原始訓練數據進行標籤清洗

訓練集標籤的正確性直接影響了監督學習模型所學到的特徵表達和決策邊界的準確性。保證標籤正確不僅是提高模型性能的前提，也是保證模型在實際應用中能夠穩定運行、正確預測的基石。

多項研究表明，訓練集中的標籤錯誤是導致模型在驗證集和測試集上性能下降的重要原因之一。相對而言，數據清洗(表 33) 為針對鉛分類之訓練集進行異常數據清洗與標籤校正有助於提高模型在未知數據上的預測準確率和穩定性。

表15 鉛之吸光光譜圖異常數據對照表(資料來源：研究者自行收集)

異常數據 (資料刪除)								
正常數據								
								
								

(四) 標籤清洗後的訓練模型各其參數調教

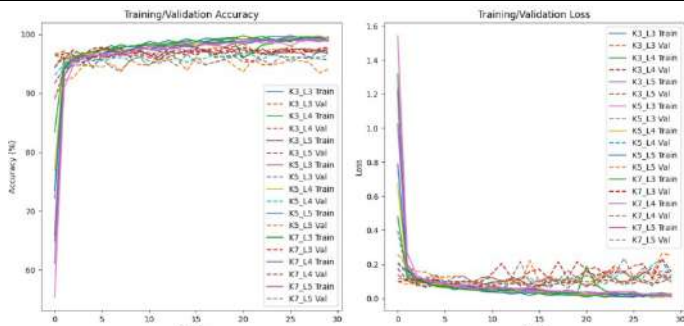
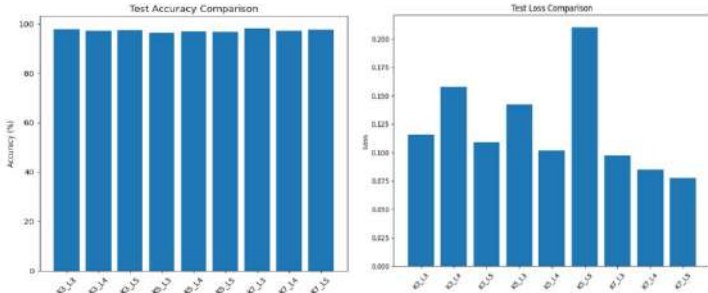
光學實驗每一筆數據皆需精準操作與調配，而化學水溶液各種濃度調配過程步驟繁多容易出錯且會受其它化學物質干擾影響其表現特性，這些都會造成該筆數據失真進而形成訓練集錯誤的標籤，故經人工檢視清洗後，發現準確性提昇，清洗前準確率約為91.2%，清洗後準確率提高至96.7%。

學習率與卷積核尺寸對模型訓練穩定性、收斂速度及最終分類準確率有著重大的影響。另外實驗結果與理論分析均表明：過高或過低的學習率均會導致模型性能不穩定或收斂過慢；且卷積核尺寸則直接影響特徵提取的尺度和參數數量。通過比較不同設置下的實驗數據，本研究試採用綜合調節策略，希望在根據具體應用情境選擇最佳的超參數配置，以達到精度與計算效率的平衡。最後本研究將對CNN之 `kernel_size`，`layer`，`learning rate`，進行最後測試，取得最佳模型做為本作品的定性分析模型。

1. 3 種 `kernel` x 3 種 `layer` 比較

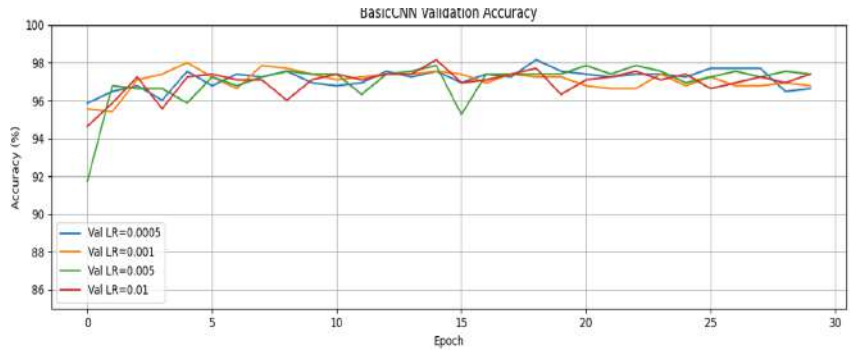
考量下表數據表現，最終我們採用 `kernel_size` 為7，5層卷積層之訓練模型，如表16所示：

表16 3種`kernel` x 3種`layer` = 9種模型 比較表(圖片來源:作者自行繪製)

	Kernal_size = 3, 5, 7 CNN Layer 訓練層數 = 3, 4, 5層
訓練與 驗證 acc,loss 分析表	
測試集 acc,loss	

2. 4 種 learning rate 比較 (表 17)

表 17 4種 learning rate 比較表(圖片來源:作者自行繪製)

ACC比較 表																					
測試集 ACC比較 圖表	<table><tr><th>Model</th><th>LR</th><th>Test Acc</th><th>Time</th></tr><tr><td>BasicCNN</td><td>0.0005</td><td>96.02%</td><td>998.5s</td></tr><tr><td>BasicCNN</td><td>0.0010</td><td>96.48%</td><td>999.0s</td></tr><tr><td>BasicCNN</td><td>0.0050</td><td>96.48%</td><td>1000.3s</td></tr><tr><td>BasicCNN</td><td>0.0100</td><td>96.18%</td><td>1003.4s</td></tr></table>	Model	LR	Test Acc	Time	BasicCNN	0.0005	96.02%	998.5s	BasicCNN	0.0010	96.48%	999.0s	BasicCNN	0.0050	96.48%	1000.3s	BasicCNN	0.0100	96.18%	1003.4s
Model	LR	Test Acc	Time																		
BasicCNN	0.0005	96.02%	998.5s																		
BasicCNN	0.0010	96.48%	999.0s																		
BasicCNN	0.0050	96.48%	1000.3s																		
BasicCNN	0.0100	96.18%	1003.4s																		

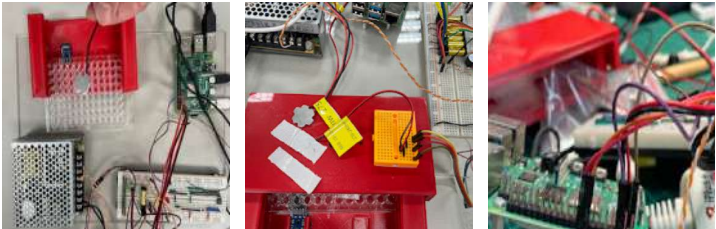

3. 綜合上面實驗數據，Basic CNN 5 層 layer，kernel_size=7，learning rate= 0.001 訓練模型，最終為本作品的定性分析模型。

肆、研究結果

一、原型製作與測試

表 18 為本作品第一代以及第二代的構造，經歷不斷的測試所發現的缺點如表 19 所示，進行多次的改進後得到最終的成品。

表 18：原型製作與測試說明表(資料來源：研究者自行拍攝)

步驟	說明
硬體製作	UV 光源模組：固定 UV LED 陣列。 微電腦晶片：使用樹莓派透過繼電器控制 LED。 外殼設計：使用 3D 列印
軟體開發	編寫程式，實現數據採集、處理與傳輸功能。
初步測試	測試光學系統的靈敏度與穩定性。
第 1 代原型機 手動、3 LED	
第 2 代原型機 手動滑軌 5 LED	

二、優化與改進(硬體成品)

表 19：優化與改進(硬體成品)說明表(資料來源：研究者自行拍攝)

步驟	說明
問題發現	<ol style="list-style-type: none"> 1. 手動移動滑軌數據不穩 2. 底層不穩 3. LED 供電不穩 4. 光學數據不易辨識
改進措施	<ol style="list-style-type: none"> 1. 步進馬達自主移動提高準確度。 2. 使用實驗室光學實驗多孔板。 3. 使用定電壓模組改善。 4. 導入AI訓練提高辨識率。
第3代(成品)	

三、系統運行流程圖

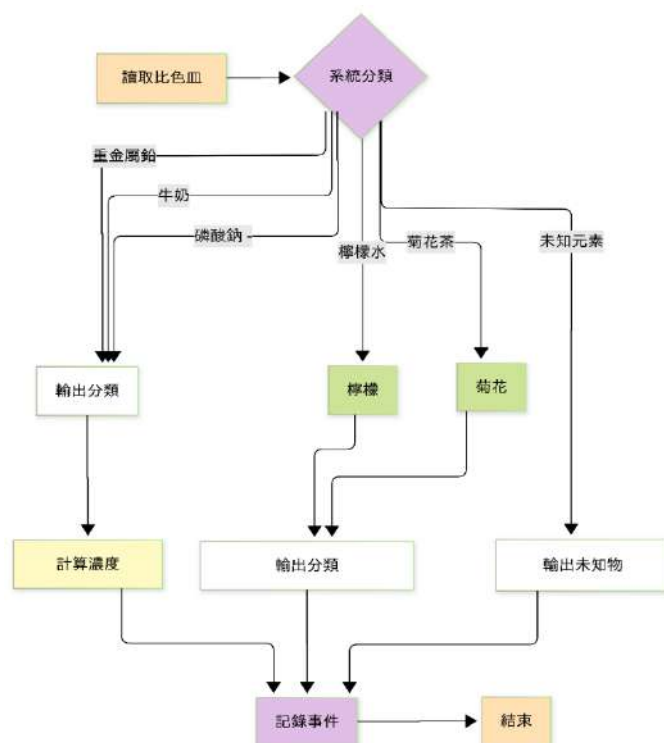


圖17 系統運行流程圖(資料來源:作者自行繪製)

四、作品功能說明

表 22：作品功能說明表(資料與圖片來源:作者自行繪製)

步驟	說明
檢測溶液元素 (定性分析)	使用者將水樣倒入比色皿。 UV LED 照射水樣，光譜感測器測量 UV 吸收數據。 透過 AI 進行定性分析 系統根據比爾定律計算水溶液含量，顯示測試結果。
檢測溶液濃度 (定量分析)	依所測得光學數據代入計算所得擬合線性公式可得待測溶液濃度
操作畫面與步驟	<p>水污染智能偵測系統</p> <p>1.輸入實驗名稱</p> <p>2.產生連結</p> <p>3.生成圖表&識別水溶液</p> <p>操作畫面與步驟</p> <p>(資料來源:作者自行繪製)</p>

伍、討論

一、蛋白質與磷酸鈉之吸光度，於5V電壓時的(紅色線條)光譜，明顯與其它高亮度之數據相較下，出現不穩現象，故在訓練模型與後續定性分析皆不採用此(5V時)數據。

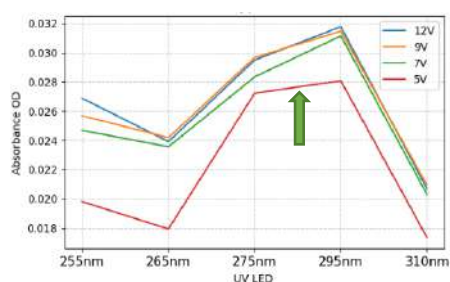


圖18 蛋白質200ppm吸光光譜圖(作者自行繪製)

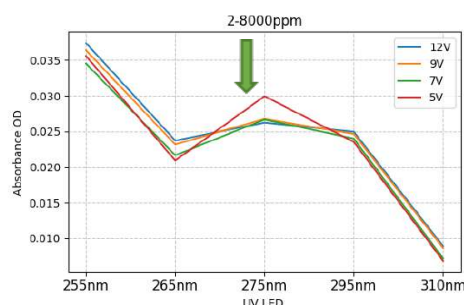


圖22 磷酸鈉8000ppm 吸光光譜圖 (作者自行繪製)

二、吸光度正偏離

根據比爾定律，則溶液的吸光度與其濃度呈線性關係，但實際工作曲線並非直線，特別是濃度較高時，這樣現象稱為偏離朗伯-比爾定律。其偏離原因為，當濃度較高時，蛋白質分子因部分電荷中和而容易聚集（如疏水作用主導），形成聚集体，增加光散射（正偏離），從而改變它們的吸光能力，引起對朗伯-比爾定律的偏離。表 23 吸光度正偏離分析表,而蛋白質在純水中因 結構複雜性、聚集傾向，導致吸光度正偏離，鉛離子則因 簡單的離子態與穩定的溶劑化結構 符合比爾定律。此差異本質上源自兩類物質的分子層級特性。

表 23 吸光度正偏離分析表(資料與圖片來源:作者自行繪製)

元素	鉛	蛋白質
吸光濃度 關係圖		
因素分析	簡單的離子態與穩定的溶劑化結構→符合比爾定律	因結構複雜性、聚集傾向，導致高濃度時吸光度正偏離→偏離朗伯-比爾定律

三、水溶液定量擬合曲線

1. 基於 R^2 和MSE的理由：

二次多項式在多個水溶液曲線展現了極佳的擬合效果。其 R^2 值僅次於三次多項式模型，但顯著優於冪函數模型和指數模型。其MSE值也非常低，表明該模型能夠很好地捕捉數據的潛在趨勢。

2. 基於參數數量和泛化能力的理由：

冪函數模型在所有關鍵標準之間取得了最佳的平衡：它提供了出色的擬合效果，具有較低的複雜性（意味著對此小型數據集具有良好的泛化潛力），並且擬合速度快。冪函數模型僅有2個參數。對於一個僅包含10個觀測點的數據集而言，這是一個非常理想的參數數量。與擁有4個參數的三次多項式模型和3個參數的二次多項式模型相比，冪函數模型的參數數量顯著減少了過擬合的風險。

3. 總體平衡：

在冪函數與二次多項式模型之間的決擇讓我們猶豫不決。起初，我們傾向於選擇冪函數作為定量模型，因其在擬合優度、低複雜度及泛化能力方面展現了出色的綜合平衡。然而，經過深入考量 R^2 值和 MSE 這兩項核心擬合指標，我們最終選擇採用二次多項式模型。

陸、結論

本系統展現了以下核心優勢，使其在水污染監測領域具有高度應用價值與潛力：

創新整合與智能化：本作品的「光-電-機-智」整合是一大亮點。從硬體層面的精密光路設計、感光晶片（OSRAM AS7331）的精準讀取、樹莓派對步進馬達的硬體 PWM 脈波控制，到軟體層面的 AI 輔助補償演算法與用戶友好的操作介面，均體現了跨領域技術的深度融合。AI 的導入不僅提高了辨識率，更為複雜光譜數據的解讀提供了智能化解決方案，有效克服了傳統方法中人工判讀的主觀性與低效率。

便攜低耗與實用性：相較於大型實驗室儀器，本系統設計緊湊，可搭配行動電源進行現場即時機動監測。這不僅大幅降低了單次檢測的成本與時間（無需樣本送實驗室），也突破了傳統定點監測的空間限制，使其能更靈活地應對突發性污染事件，並有潛力透過污染濃度梯度分析進行污染源的初步溯源。

科學探究與擴展性：研究過程從理論探討（如朗伯-比爾定律、不同 AI 模型的比較）、實驗設計（多種溶劑與濃度測試、光學參數調整）到數據分析（如高濃度正偏離現象的探討、擬合曲線的選擇），其科學探究精神為系統所建立的模組化架構與 AI 分析框架，也為未來擴展至更多種類污染物檢測奠定了良好基礎。

綜上所述，本「水污染智能偵測系統」不僅成功克服了傳統檢測方式的多項難題，更以其高效、智能、便攜、經濟的特性，為水環境保護提供了一種創新的技術手段。其在科學研究的前瞻性、技術整合的巧妙性以及實際應用的廣泛性方面均表現卓越，相信能為水污染防治貢獻實質力量

柒、參考文獻

- [1]愛丁堡大學(2022),我們的磷未來,<https://www.opfglobal.com/>
- [2]邱煒杰(2018),光譜儀應用於磷酸鹽濃度檢驗之評估,國立暨南國際大學光電科技碩士論文
- [3]WIKI,磷,<https://reurl.cc/oVnMVj>
- [4] 國家環境毒物研究中心(2021),砷,<https://reurl.cc/nq93qD>
- [5] 國家環境毒物研究中心(2021),鉛,<https://reurl.cc/nq93YX>
- [6] 國家環境毒物研究中心(2021),鎘,<https://reurl.cc/NbkMNm>
- [7] 陸峰,林培英,楊根金(2002) 藥物分析色譜分析前處理技術的新進展-藥學實務雜誌
- [8] 王斌,楊慧中(2015) 一種水質總磷線上檢測的光譜資料處理方法, researching.cn
- [9]黃昱智(2024),基於機器學習之太陽能發電系統全域最大功率追蹤技術,國立臺灣科技大學碩士論文
- [10] 陳江,金新華,週均,吳惠英,吳傑(2011), ICP-OES 測定廢水中總磷,[https://www.iwt.cn](http://www.iwt.cn)
- [11] 新國科技(2024), 淺談紫外光可見光光譜的應用, <https://reurl.cc/46AzOj>
- [12]The daylight(2022), [樹莓派] 使用pigpio傳送指定數量的脈衝訊號,<https://reurl.cc/Q5yq2o>
- [13] pigpio library, <https://abyz.me.uk/rpi/pigpio/faq.html>
- [14] LeCun, Y., et al. (1998). Gradient-Based Learning Applied to Document Recognition. Proceedings of the IEEE.
- [15] He, K., et al. (2016). Deep Residual Learning for Image Recognition.
- [16] Hu, J., et al. (2018). Squeeze-and-Excitation Networks.
- [17] Tan, M., & Le, Q. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. ICML.
- [18] Dosovitskiy, A., et al. (2020). An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. arXiv.
- [19] HangZhou,(2019), CNN可視化之類活化熱力圖Grad-CAM,<https://reurl.cc/XZd83M>
- [20] Martin Armbricht, Detection of contamination in DNA and protein samples by photometric measurements, <https://reurl.cc/6KmW0y>
- [21] M. Largeron and B. Deguin, Organic & Biomolecular Chemistry,ROYAL SOCIETY OF CHEMISTRY期刊

【評語】 052308

1. 本作品欲探討工業、家庭、農業廢水中有害物質或重金屬的濃度，強調可攜性、操作簡單、低成本，利用分光度計的原理，選擇五種波段的光，以便繪製出待測物的光學指紋。後續使用 AI 模型判讀光譜，期盼提高判讀效率跟正確性。
2. 參賽選手對於分光原理熟悉，投入 AI 演算法比較，找出最適合的光譜判斷的方法，助於最後判斷。建議未來應考量系統極限，有助於收斂該系統的應用情境。
3. 作品說明書應助於大眾理解研究之動機與影響力，期許參賽選手對於科學敘事與論說文撰寫更為嚴謹。

作品海報



水污染智能偵測系統

摘要

磷污染及重金屬的累積已被確認為引發水體富營養化及生態毒性的關鍵因素，對水生生態系統及人類健康構成顯著風險。磷酸鹽作為磷污染的主要形式，傾向於促進藻類的過量繁殖，而重金屬離子因其高度毒性及生物累積性，對水生生物的影響尤為嚴重。本作品將化學、光學、電機、機械、AI、微電腦領域知識進行「**光-電-機-智**」深度整合，創造系統價值，並使用AI輔助補償演算法，提升水溶液的定性定量分析效率，使本作品能快速檢測水源是否遭受磷或重金屬鉛污染，並且計算濃度，無需將樣本送回實驗室，捕捉污染動態。降低成本與操作門檻，達到良好監測及做好水土保持

壹、前言－研究動機

水污染主要來源於農業化肥流失[1]、工業廢水排放以及生活污水。這些污染源具有分散性、間歇性和複雜性，使得傳統的實驗室檢測方法難以應對：

時間滯後：實驗室檢測需要採樣、運輸、分析，耗時長，無法即時反映水質變化。

成本高昂：專業設備與試劑價格昂貴，且需要技術人員操作，難以普及。

空間限制：實驗室檢測無法現場連續監測，難以捕捉污染事件的動態變化。

壹、前言－文獻探討

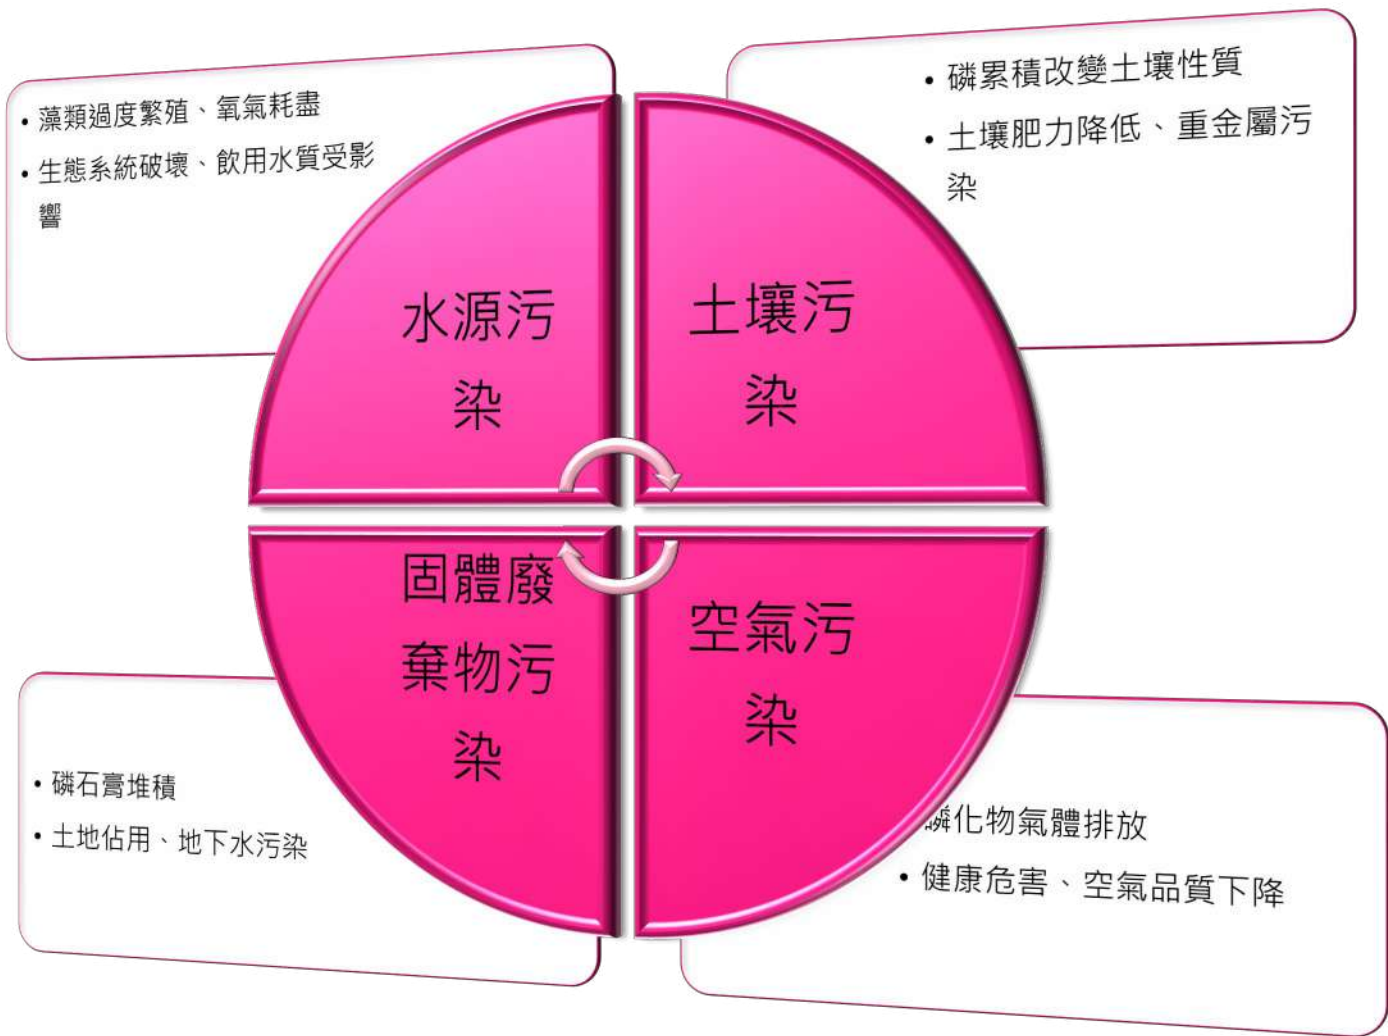


圖:磷常見污染

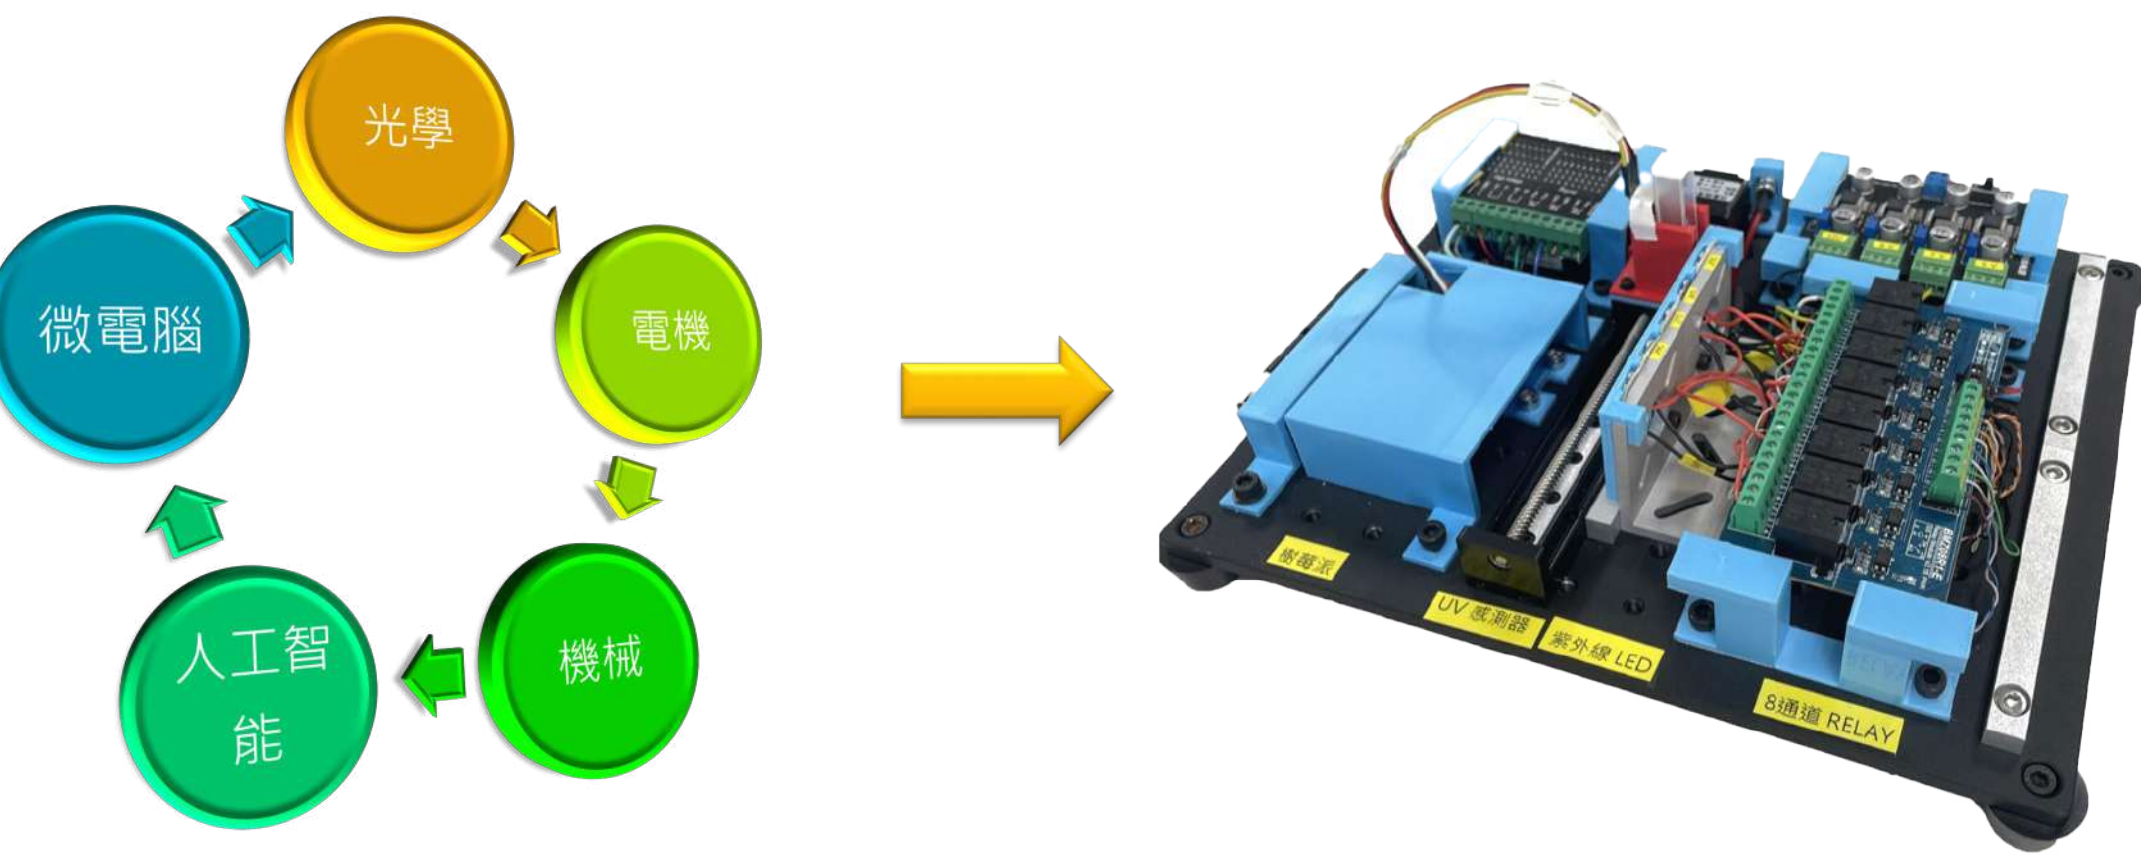


圖:光電機智整合

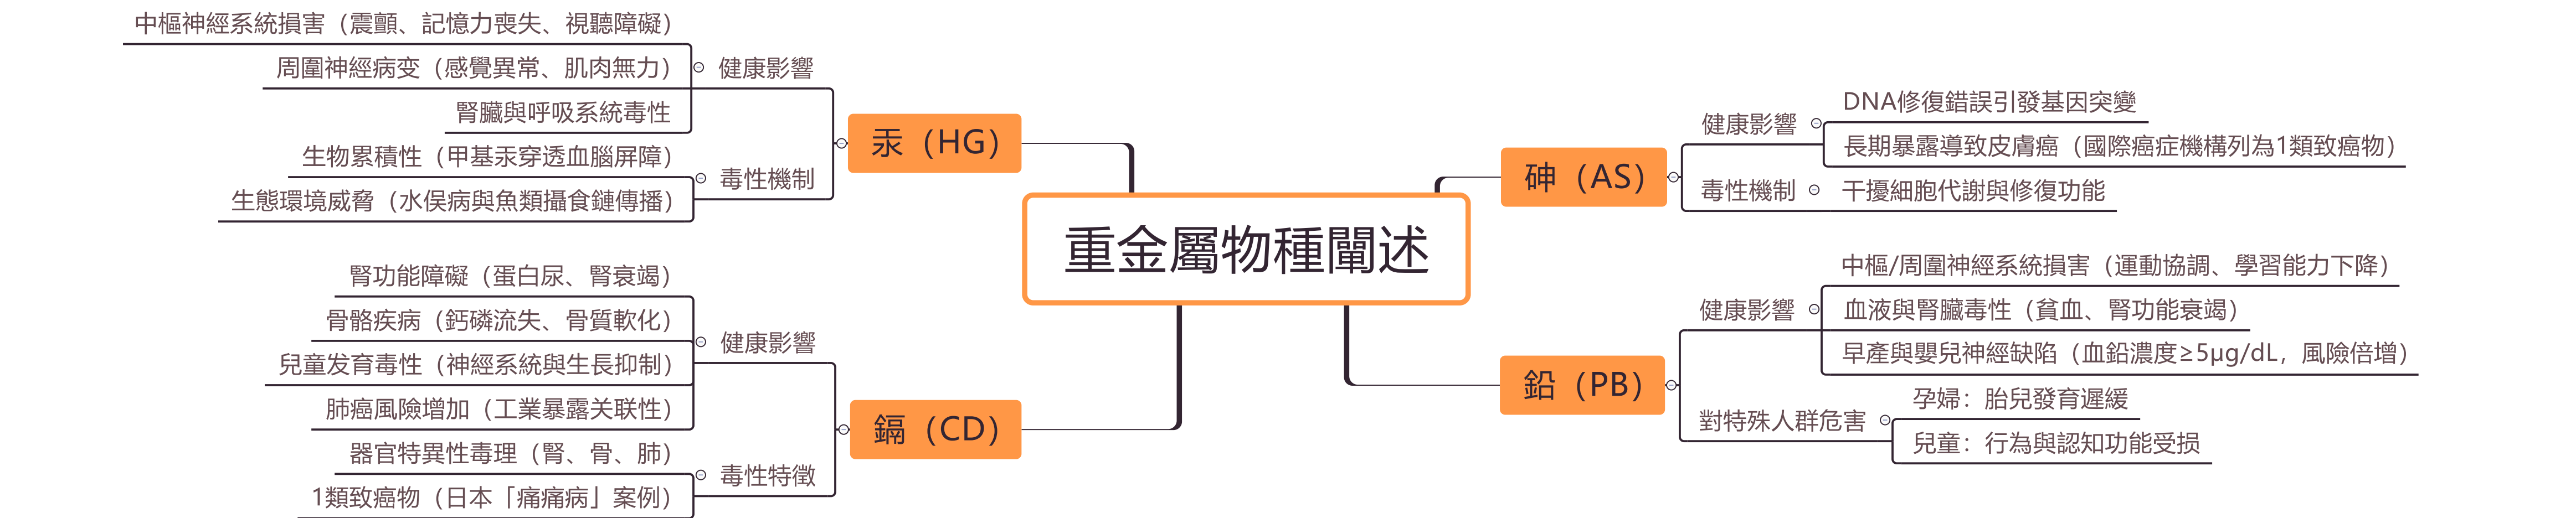


圖:重金屬污染

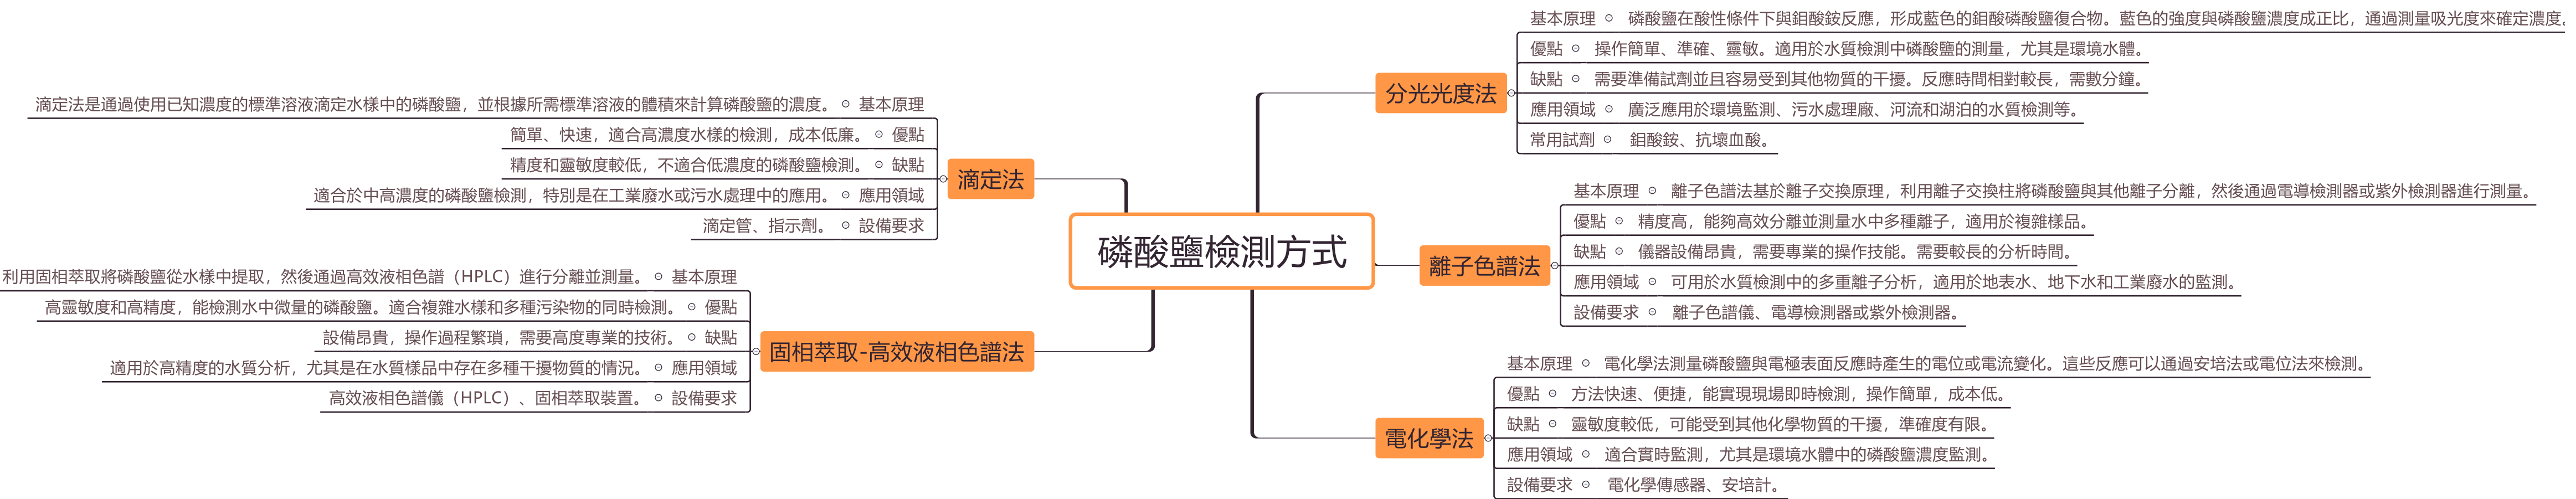


圖:化學元素檢測方式

分光光度法的定性分析是根據物質對特定波長光的吸收特性來判斷其組成。例如，每種物質在不同波長下的吸收光譜是獨特的，類似於「光學指紋」。通過測量樣品的吸收光譜並與已知標準光譜比對，就可以確認樣品中的成分。

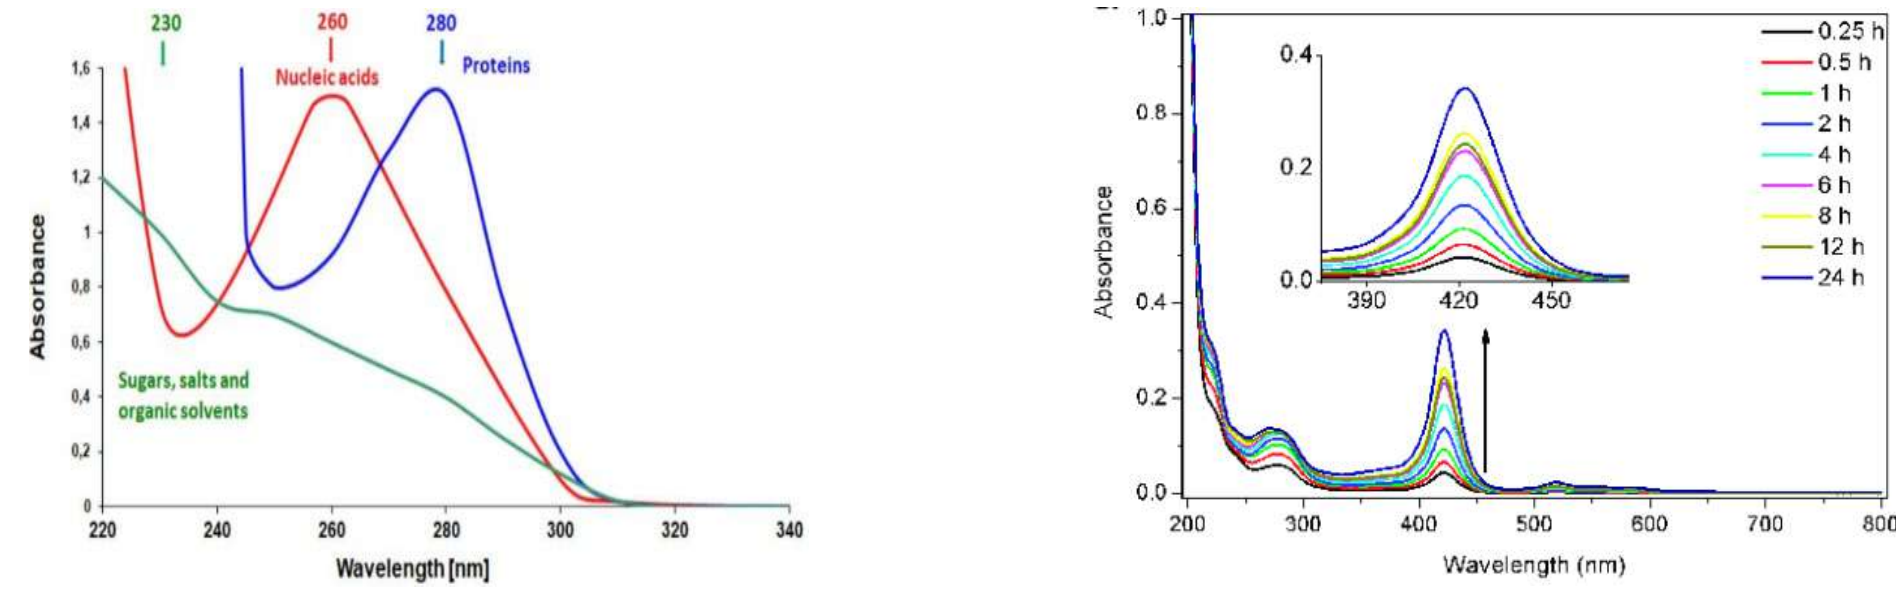
定量分析則是通過測量樣品對特定波長光的吸收程度來確定其濃度。當樣品濃度增加時，吸收光的程度也會增強。這種關係可以用比爾定律來表示

$T = I_0 / I$

其中：

- I_0 ：入射光強度（光進入樣品前的強度）
- I ：透射光強度（光穿過樣品後的強度）

吸光度（A）與透射率（T）的關係為： $A = -\log_{10} T$



蛋白質光譜圖 from文獻 [20] 磷緩衝鹽水UV光譜圖 from文獻 [21]

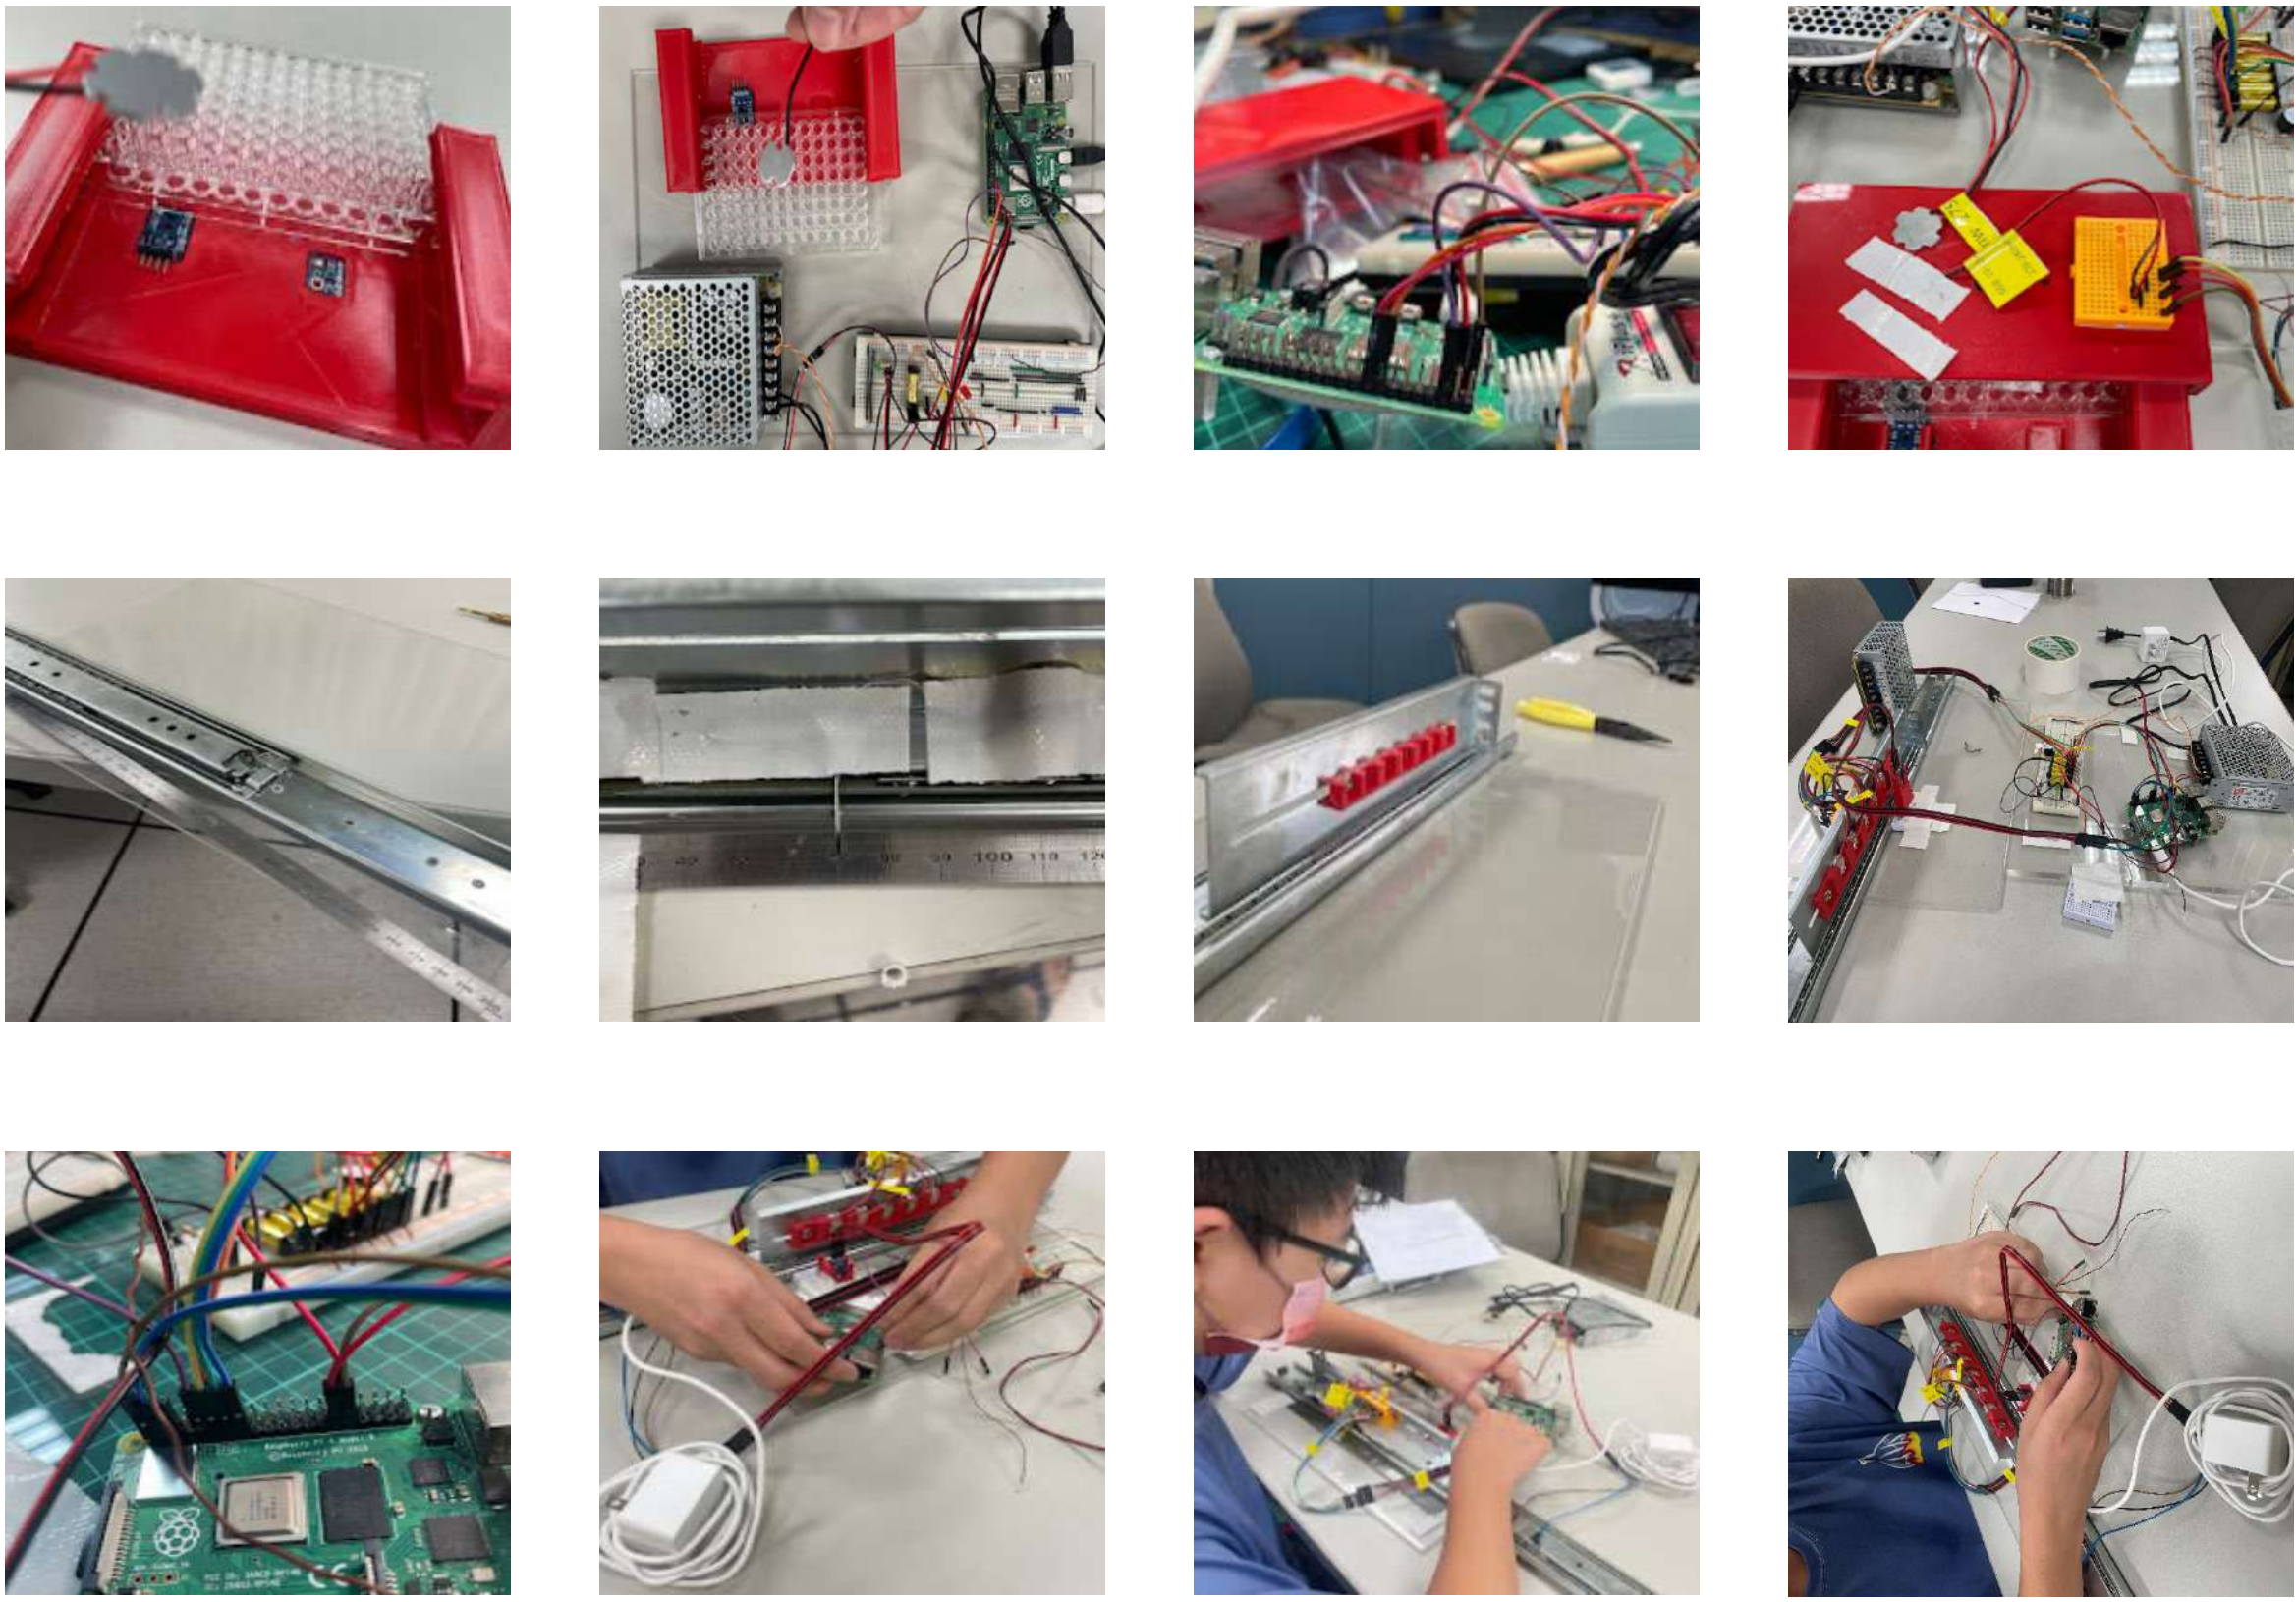
圖:分光光度法- 定性原理

圖:分光光度法- 定量原理

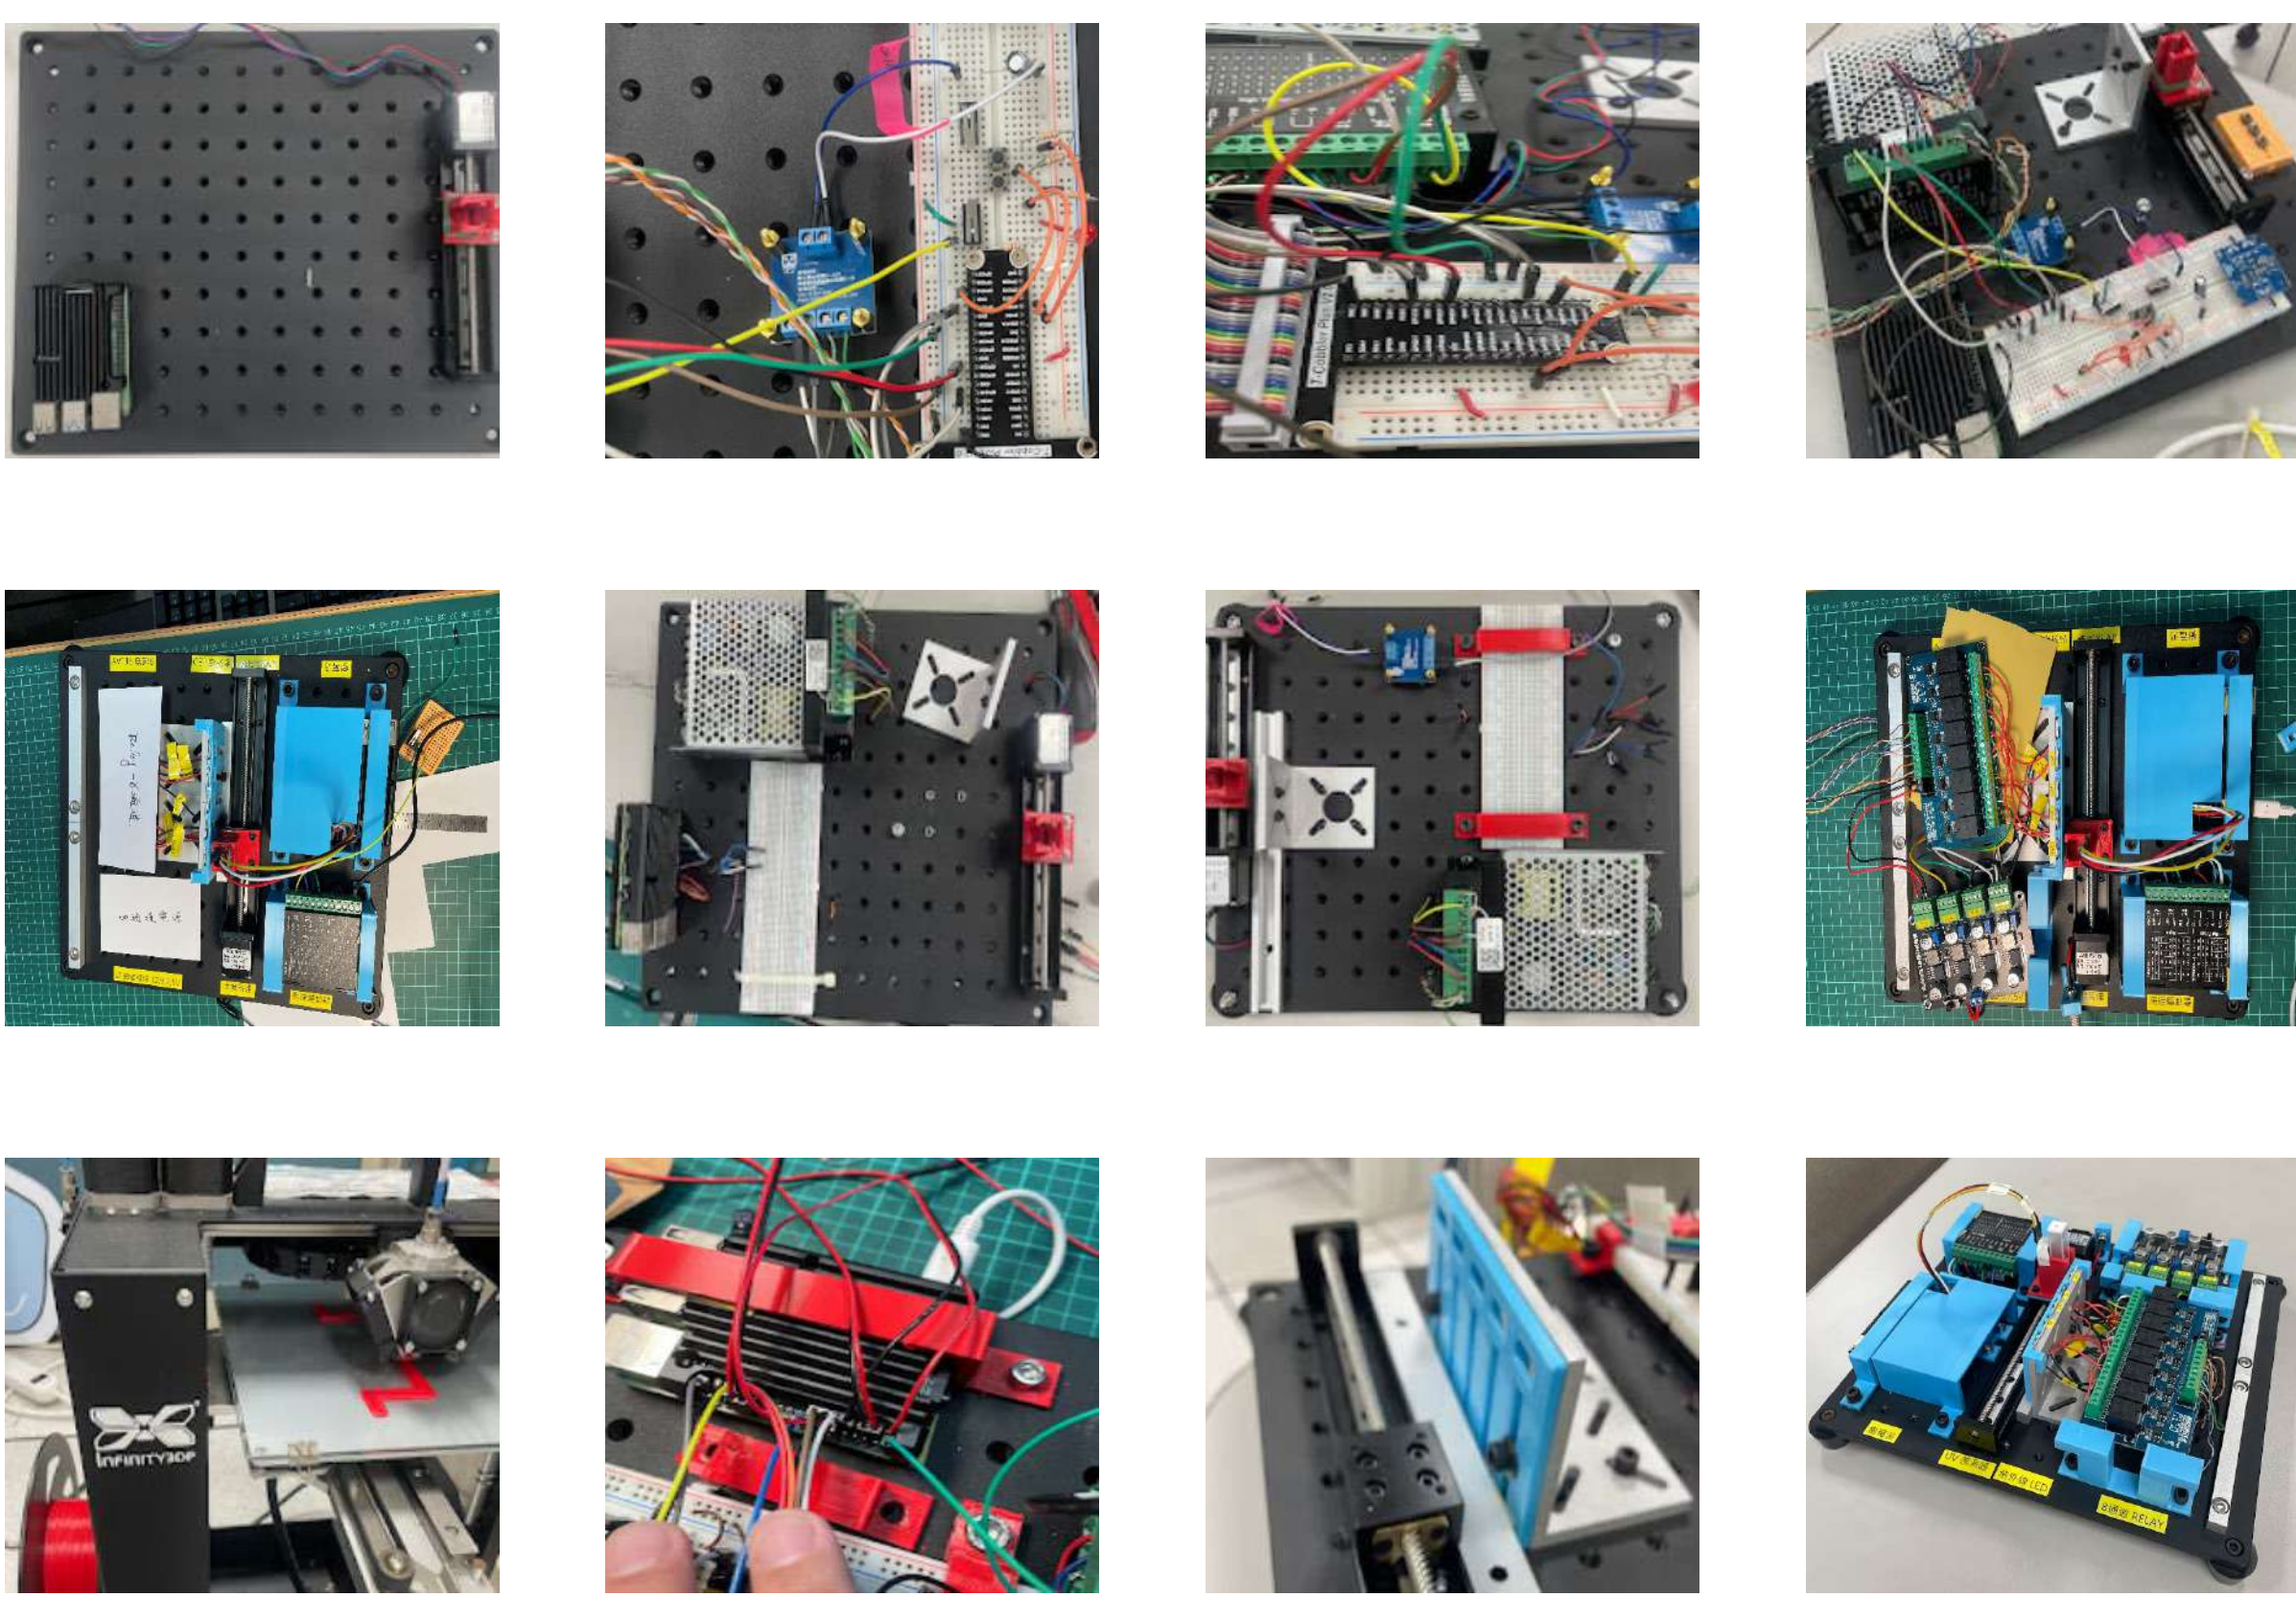
分光光度法原理 → 本系統設計架構比照表		
光譜儀		本系統設計原理
光源發射光：		多顆不同波長 UV LED 255nm, 265nm, 275nm, 295nm,310nm
光通過單色器：		移動 比色皿至對應的UV LED
選擇特定波長的光：		樣品吸收部分光
光通過比色皿中的樣品：		檢測器接收透過光
樣品吸收部分光		(光學 晶片 OSRAM AS7331 IC)
檢測器接收透過光 (光敏電阻)		訊號處理晶片-樹莓派 (測量透過光強度、計算吸光度、 AI分析、圖表輸出)
訊號處理晶片-特製晶片 (測量透過光強度、計算吸光度)		

以上圖表皆為作者自行繪製

初代原型機



優化與成品



參、過程研究或方法

溶液比色皿 - 滑軌移動計算

需求設備	說明
步進馬達轉一圈	$(\frac{1.8^\circ}{步}) * 200步 = 360^\circ = 12mm$ (造成滑軌移動12mm)_
TB6600細分數 1/8	move 12mm = 200*8 = 1600 pulse (need)
LED間距 18mm	$18mm * \frac{1600Pulse}{12mm} = 2400 pulse$
樹莓派	1. 硬體連接: 滑軌方向 DIR = 8-rpi <-> TB6600 DIR 脈波 PUL = 18-rpi <-> TB6600 PUL 2. 定義1個脈波(高電位100us, 低電位 100us) on 100us (1<<GPIO, 0, 100) oooooooooooo oooo o o o o o oooo oooooooooo off 100us (0, 1<<GPIO, 100)] 3. 使用pigpio 庫的服務, 產生2400個自定脈波送至TB6600即可讓滑軌移動18mm

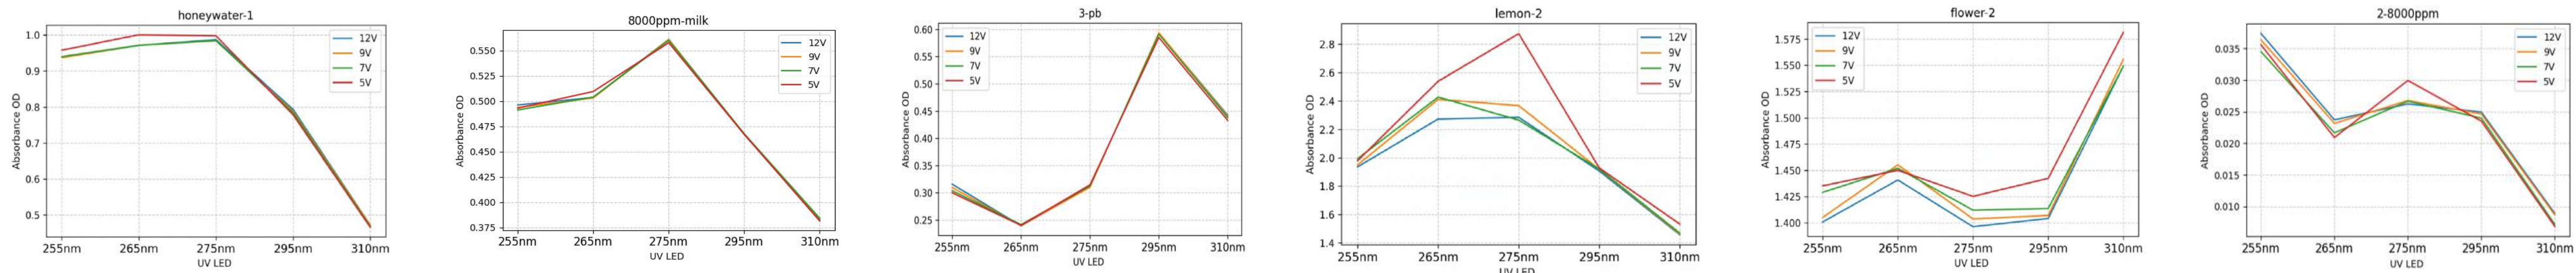
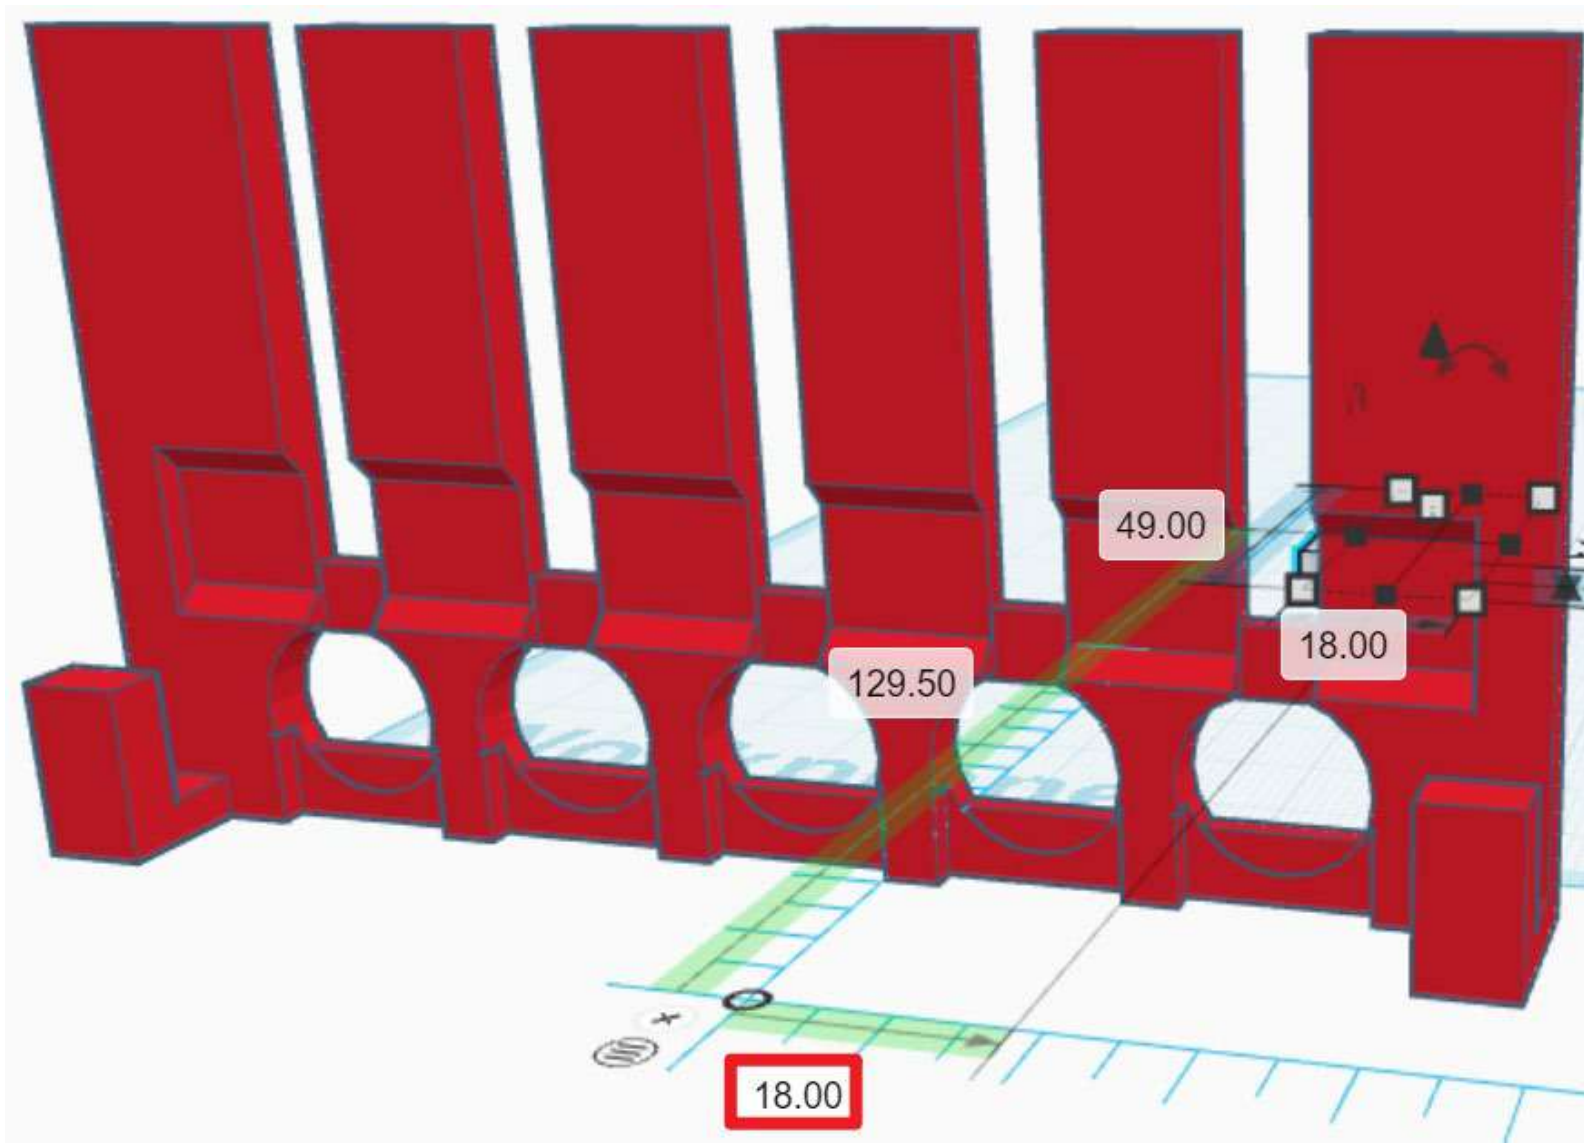


圖:本系統由測量並繪製各元素光譜圖

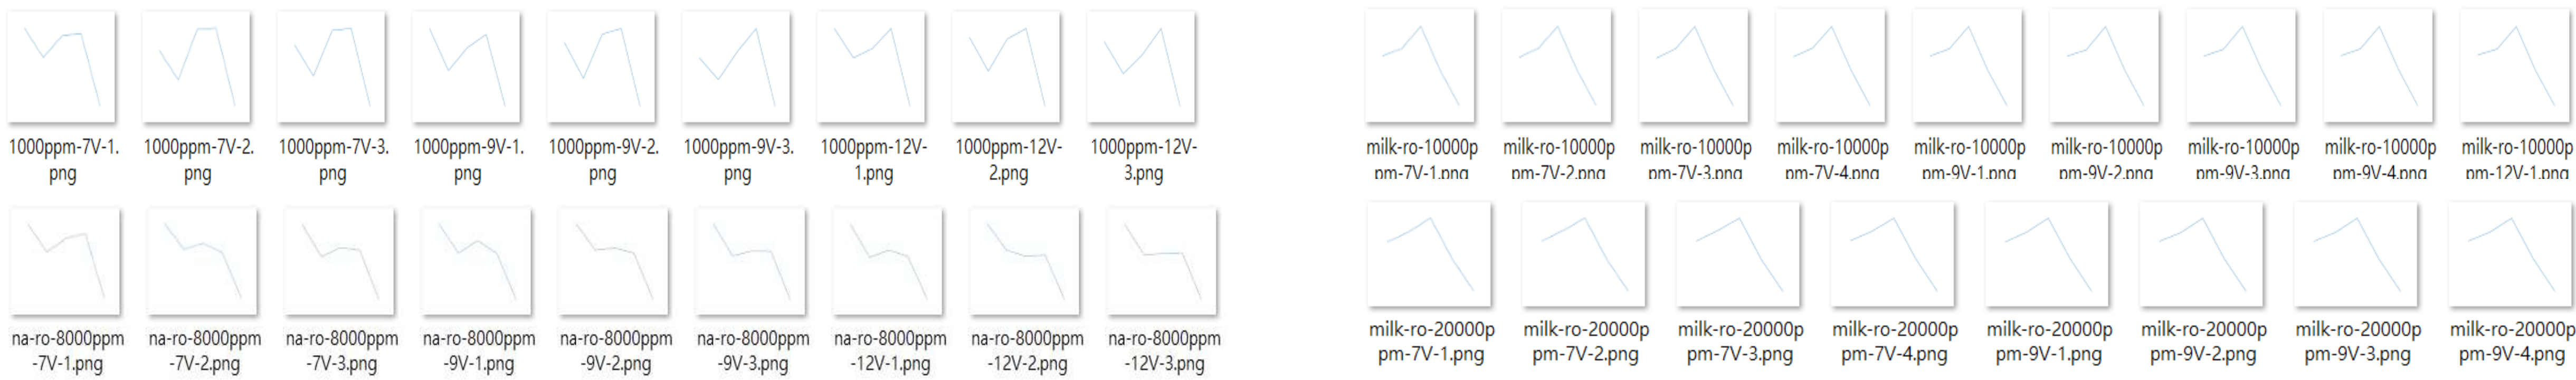


圖:原始數據 轉成縮圖後 → 再進行CNN模型 訓練 → 定性分析

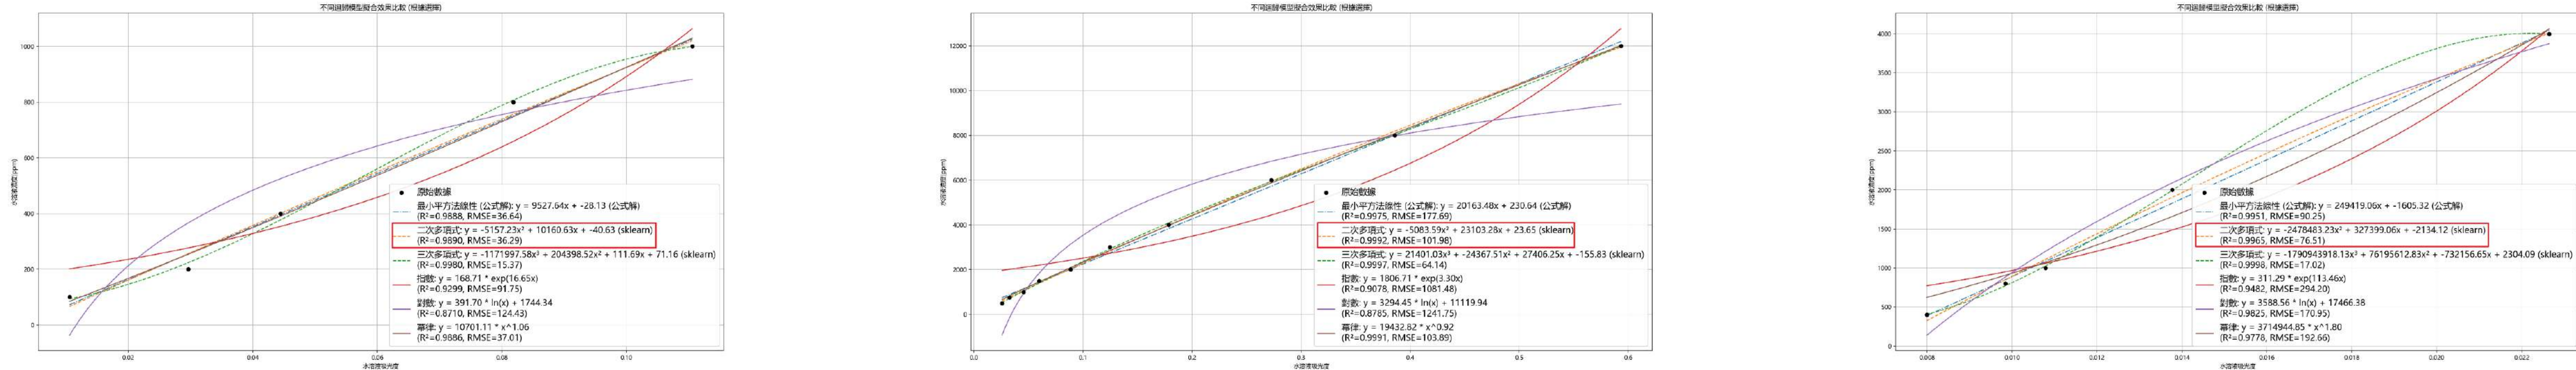
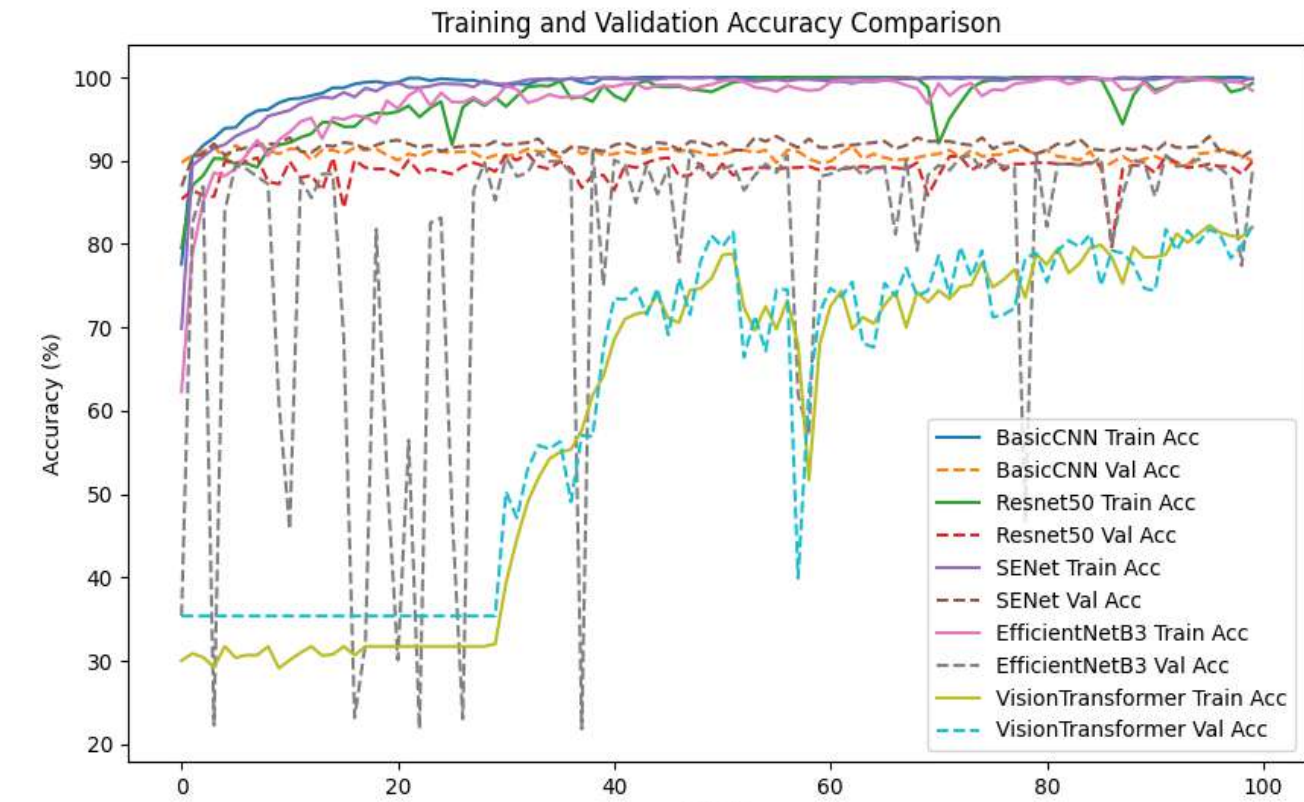
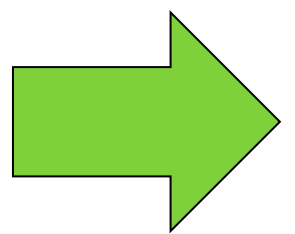
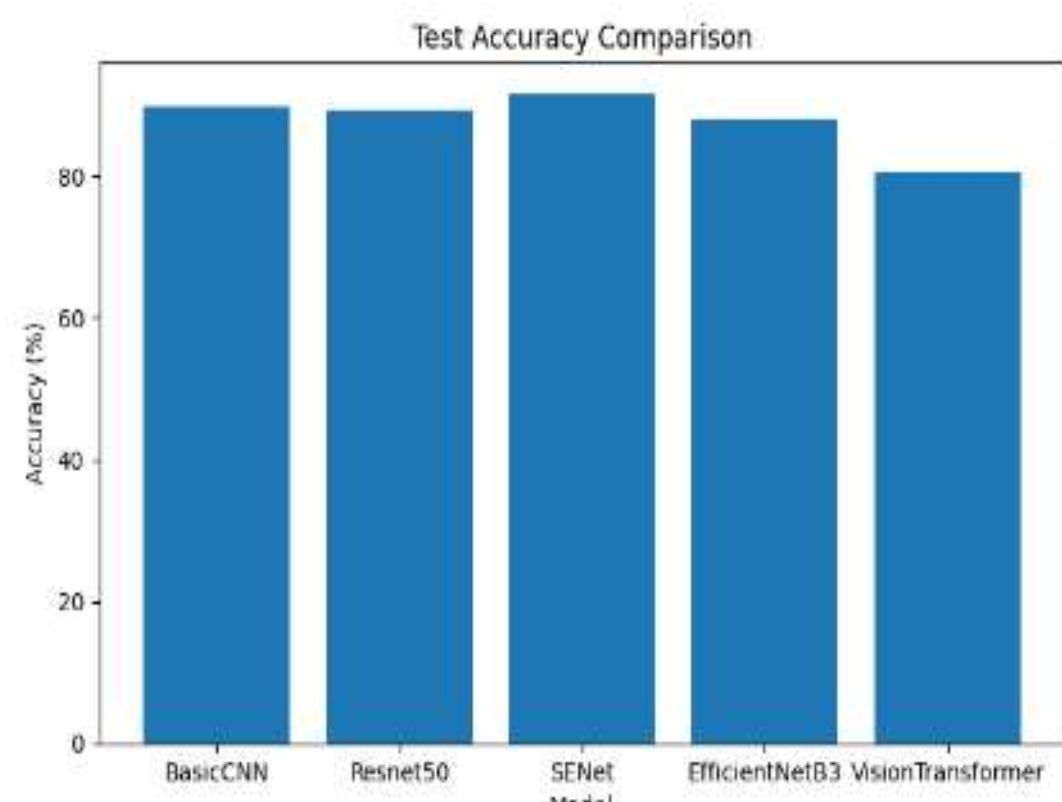
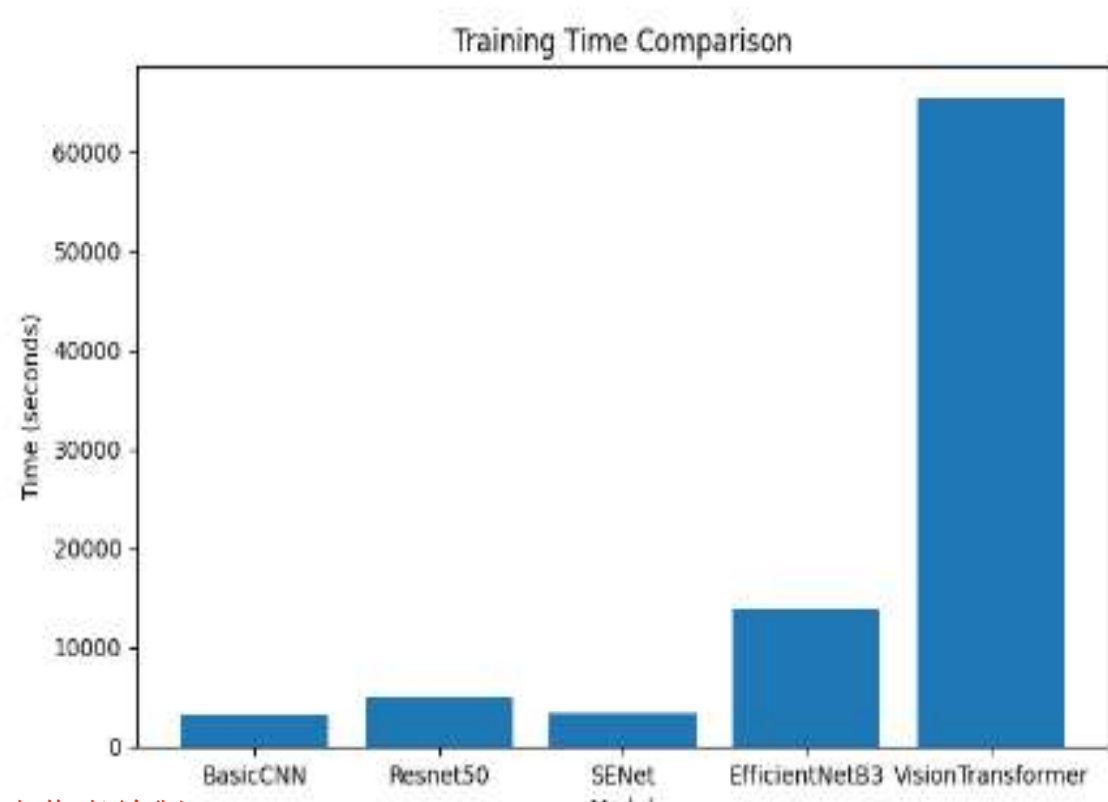


圖:各元素吸光與濃度關係圖 → 定量分析

70% 訓練集 15%驗證集
15%測試集
CNN ResNet SeNET
EfficentNet-B3 ViT



海報圖表皆由作者繪製



參、研究過程或方法

貓狗辨識之
關鍵熱力圖
from文獻[19]

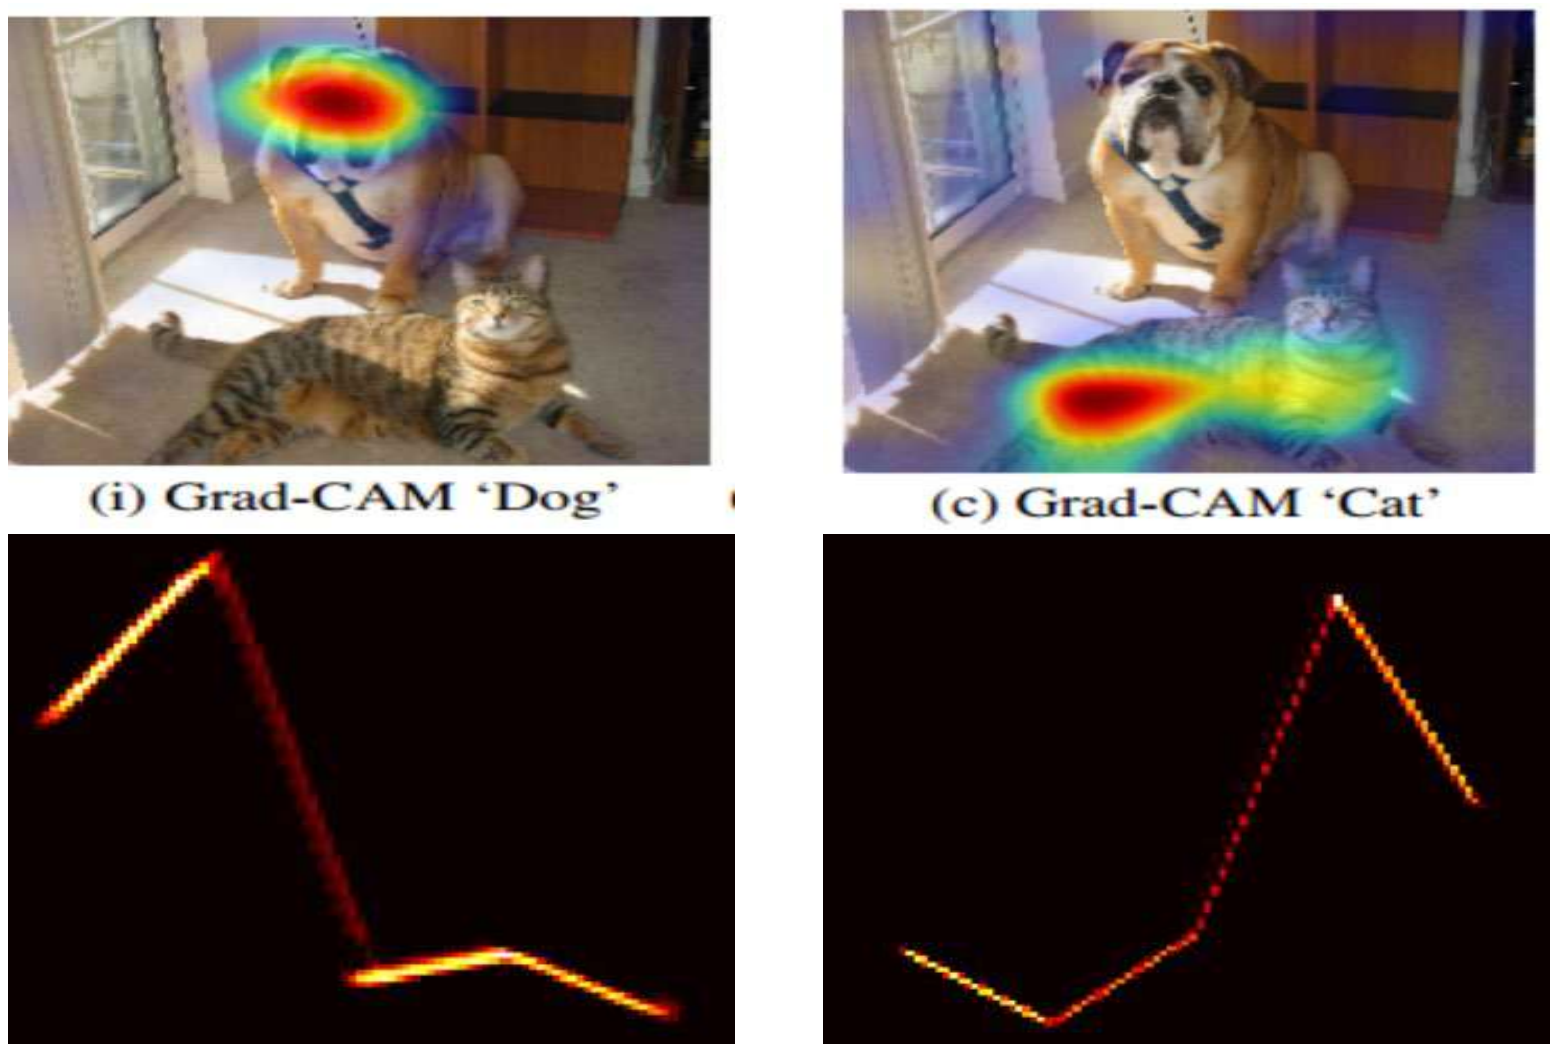


圖:熱力圖

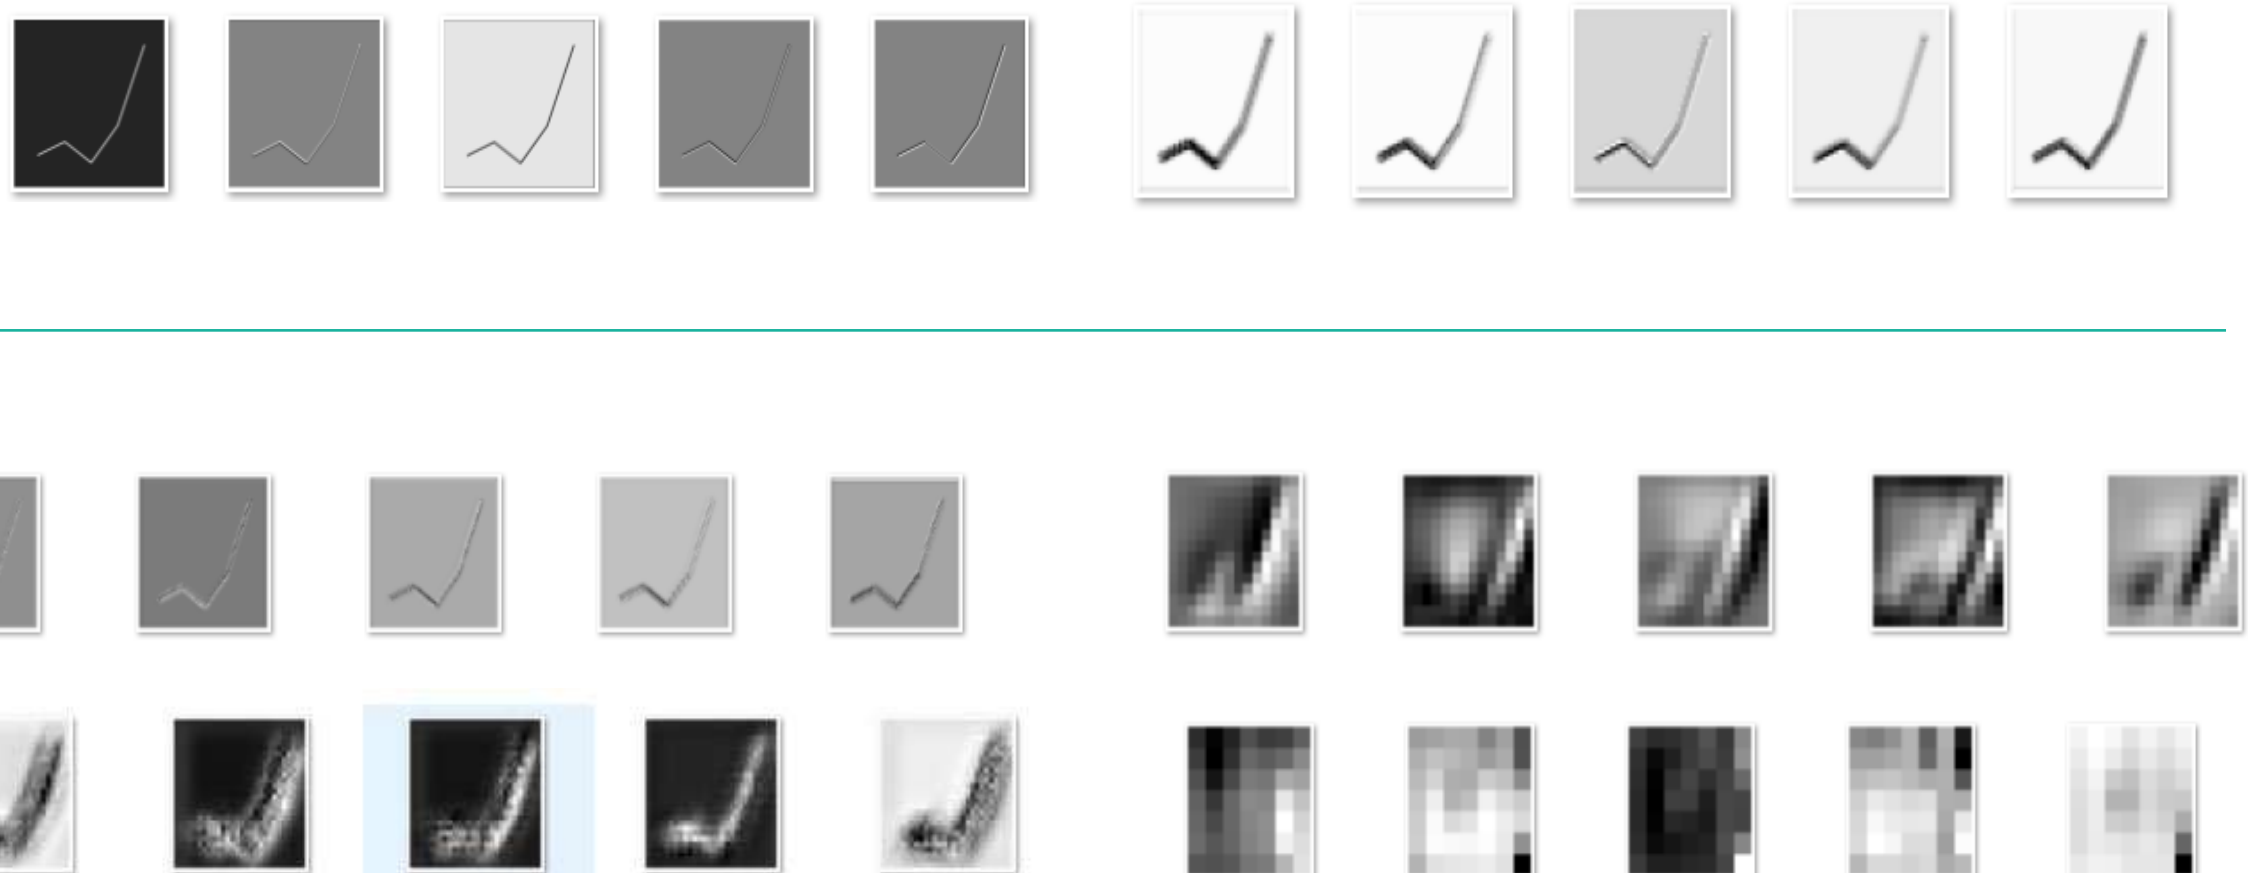


圖:CNN & EfficientNeT B3 各層卷積特徵

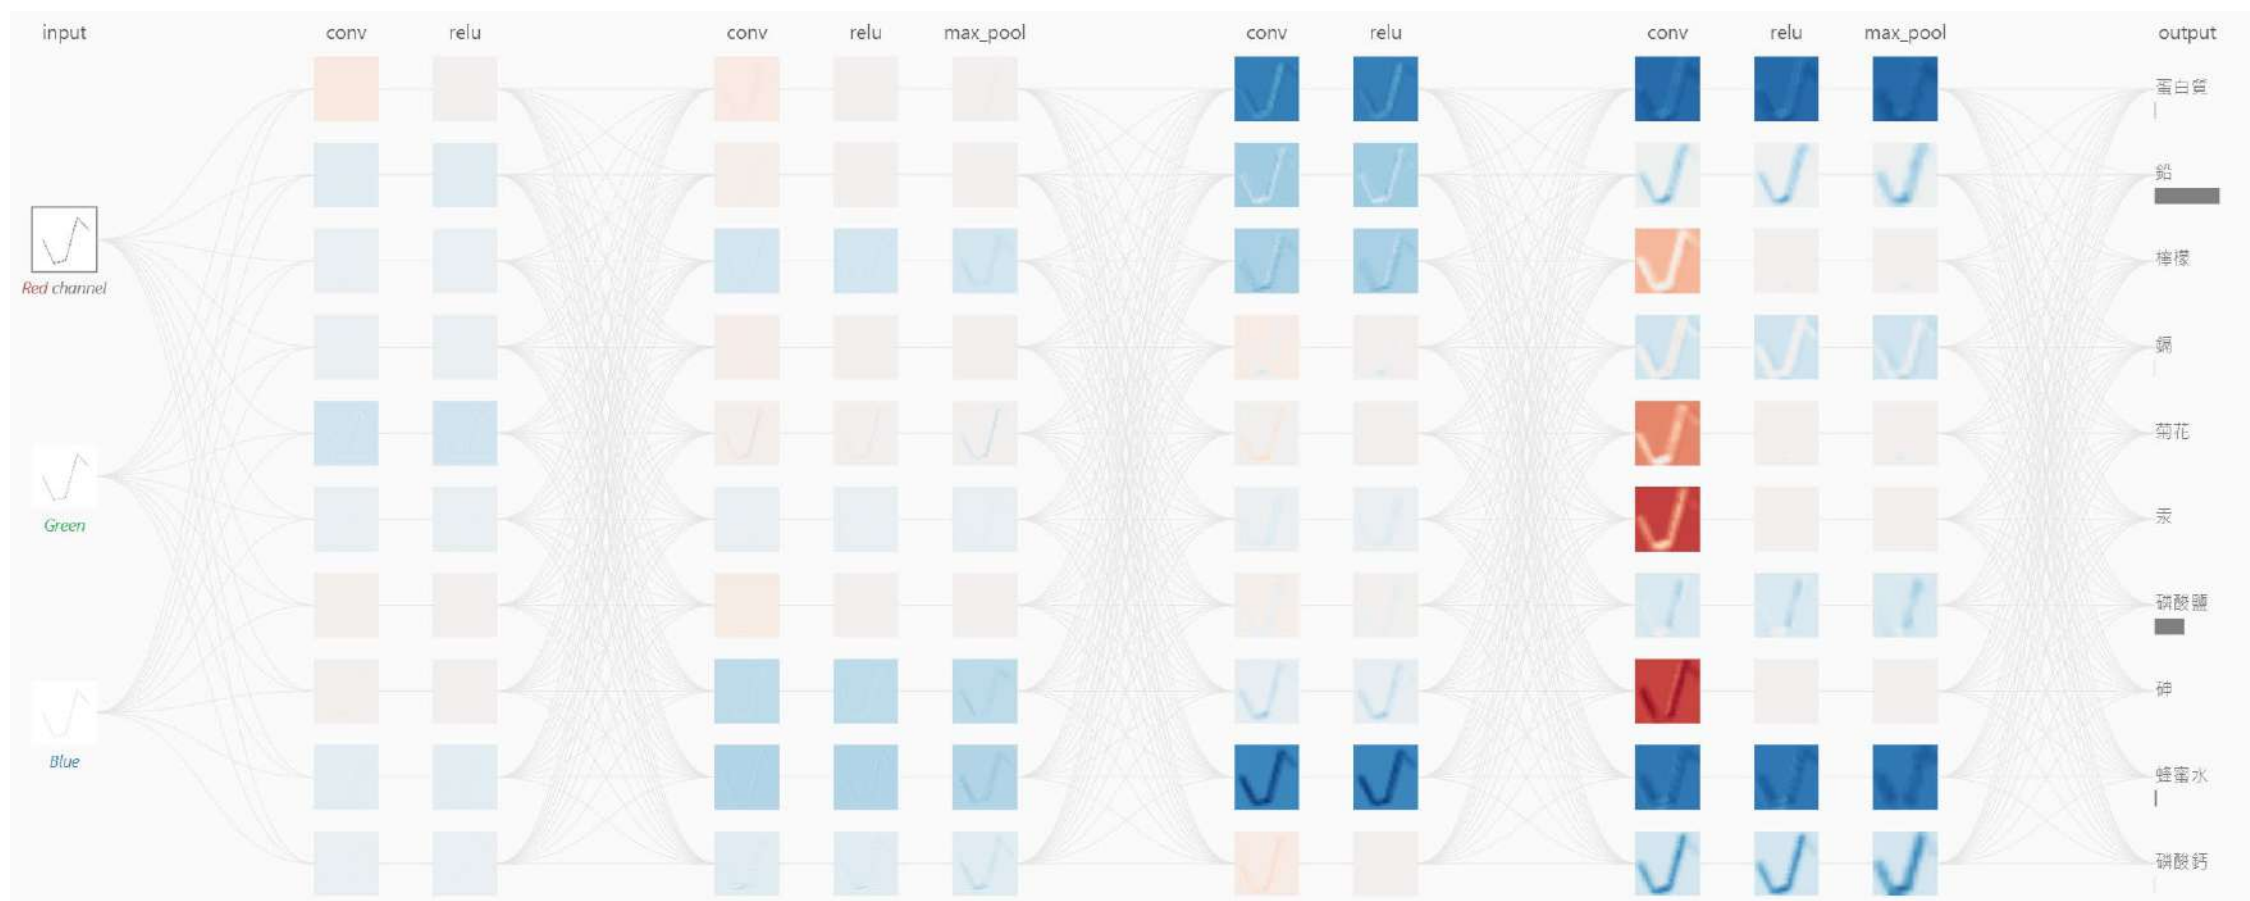
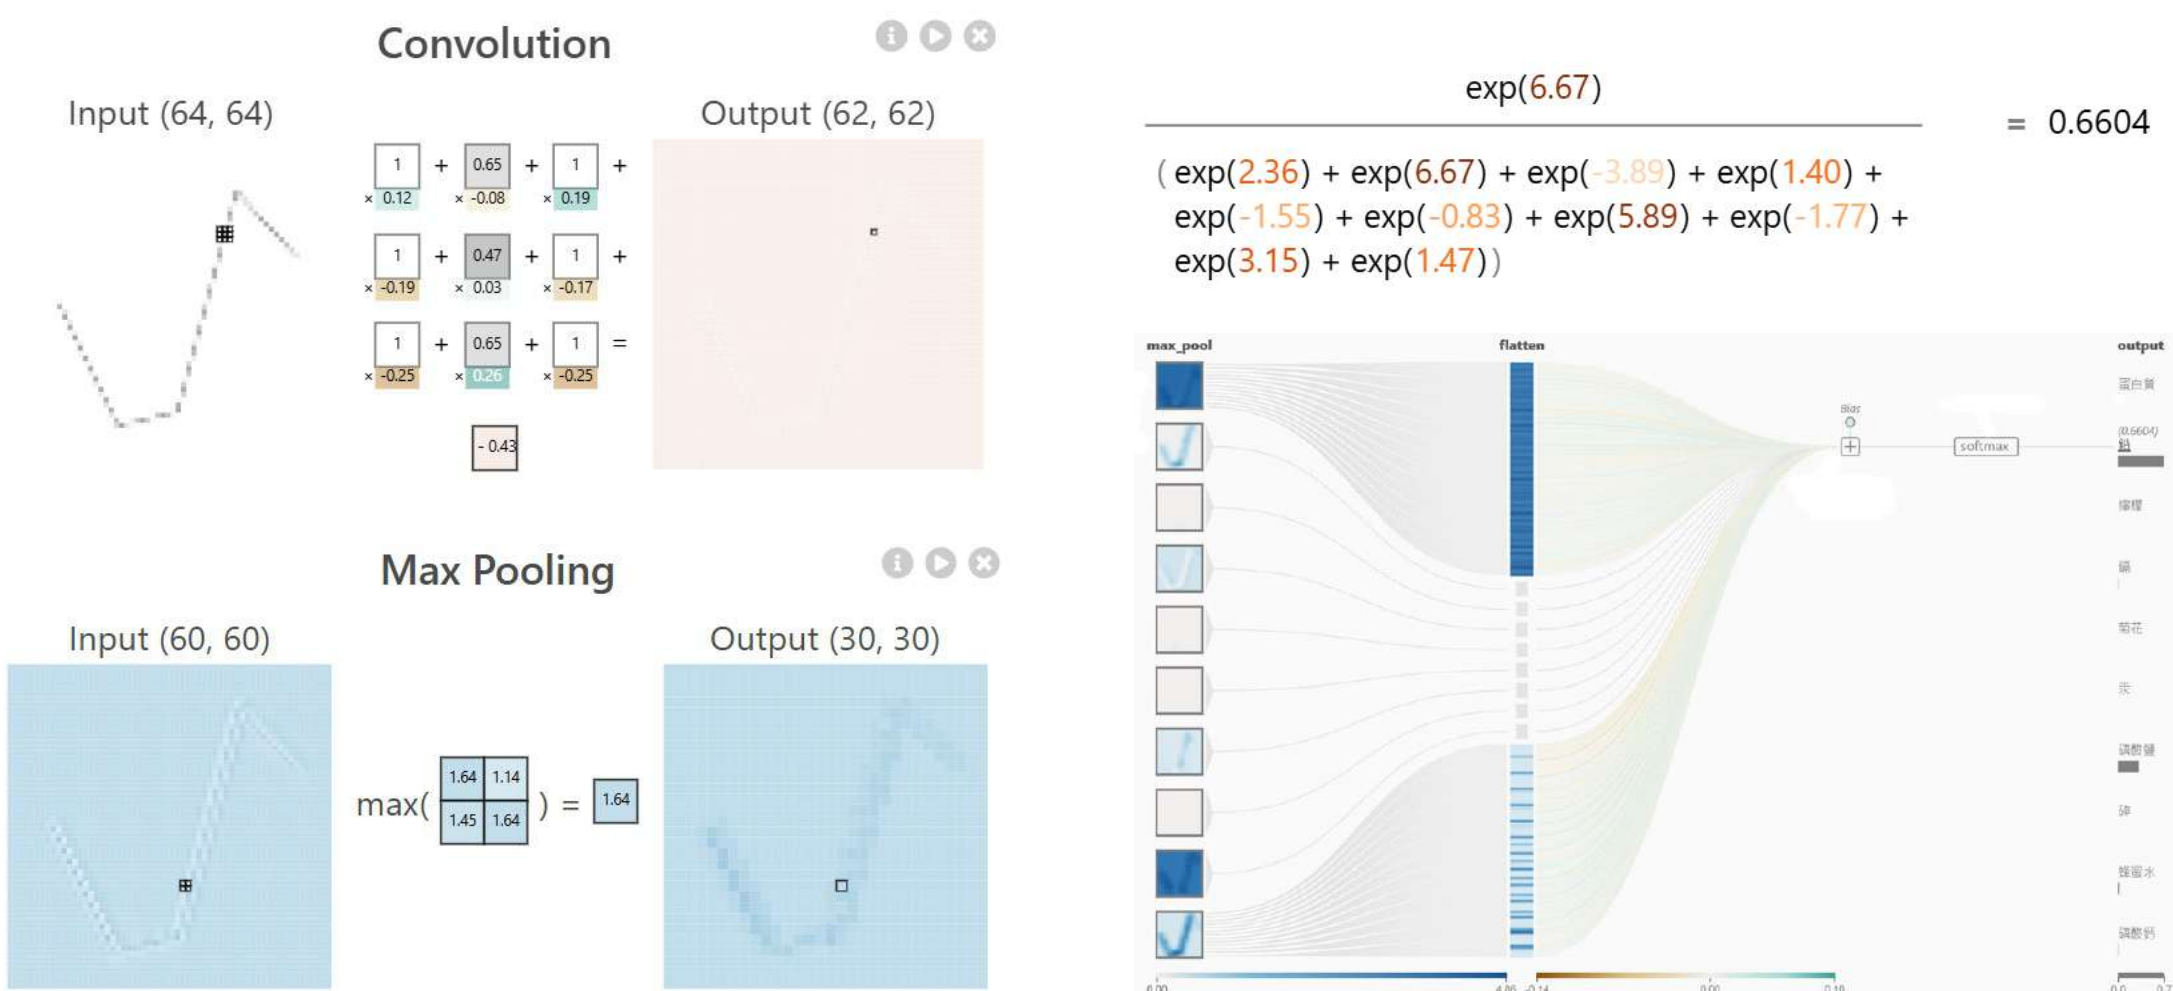
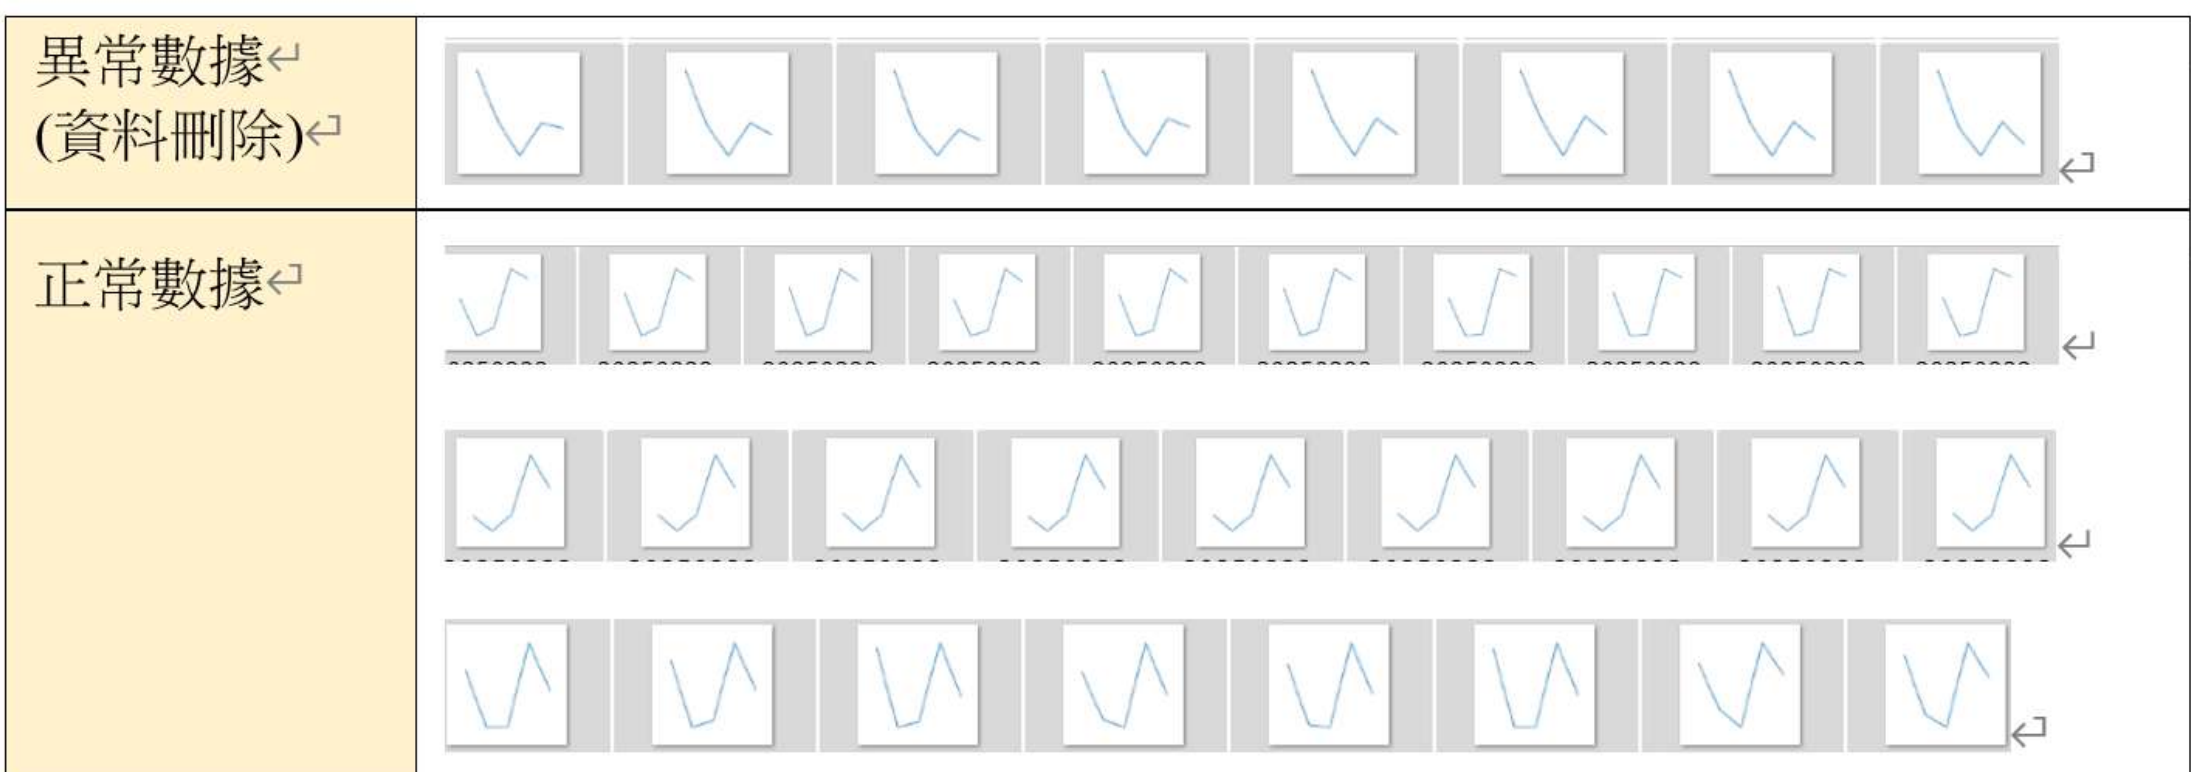


圖: 鉛-CNN-架構圖



圖：鉛- 卷積-池化-分類圖



圖：標籤清洗

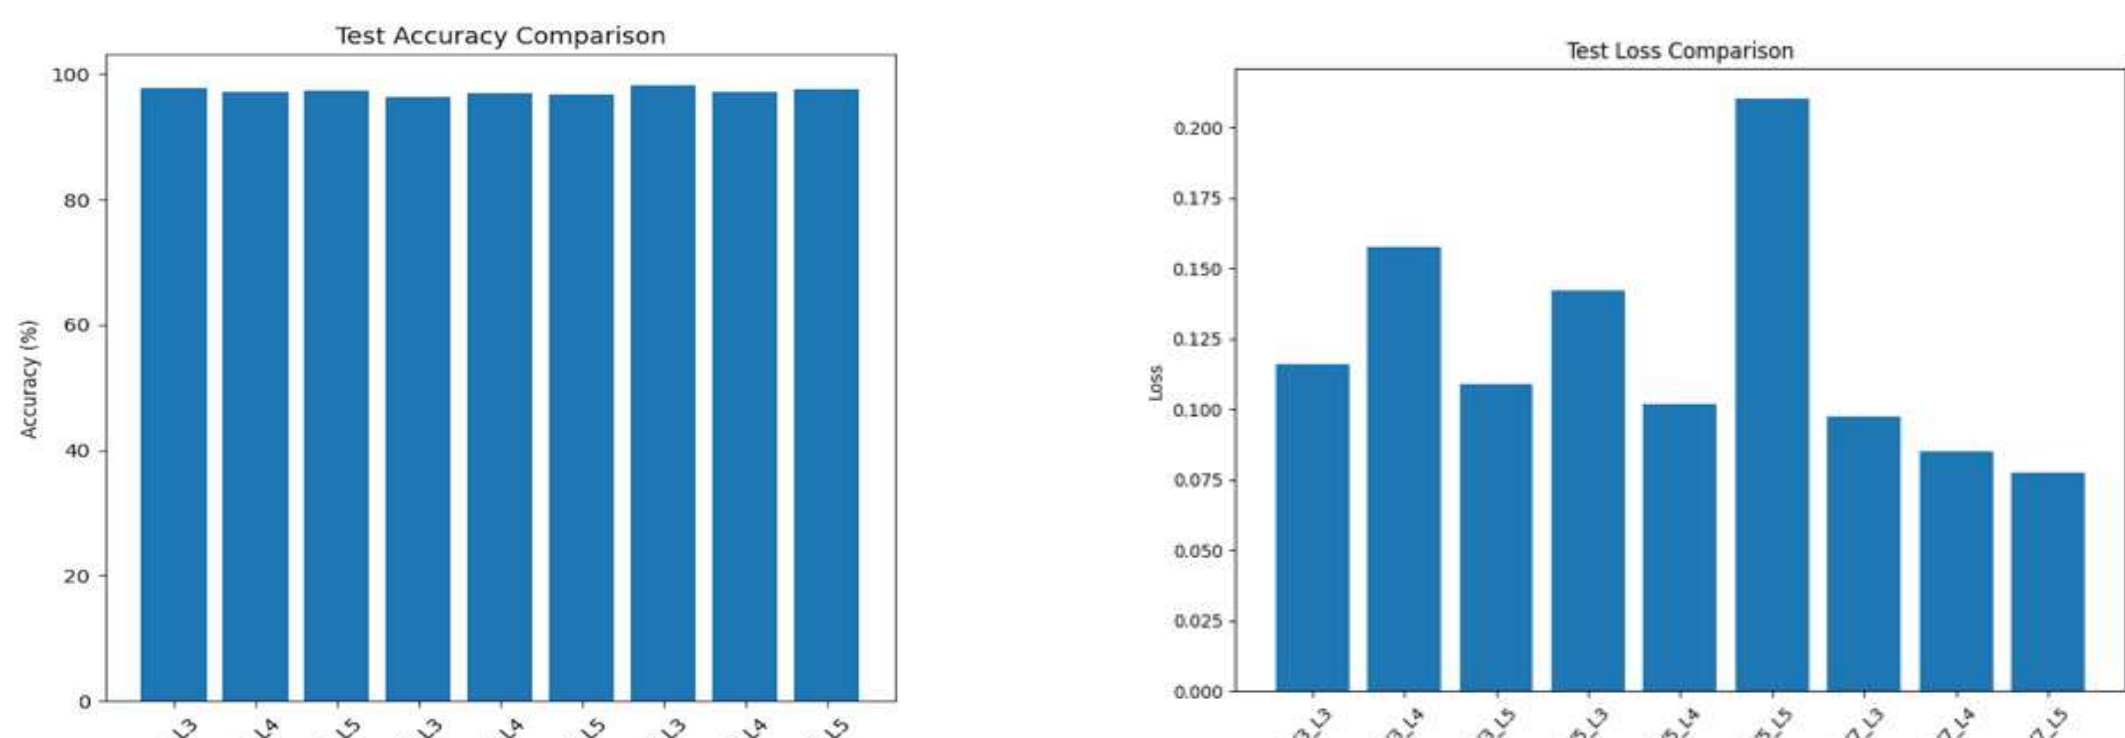
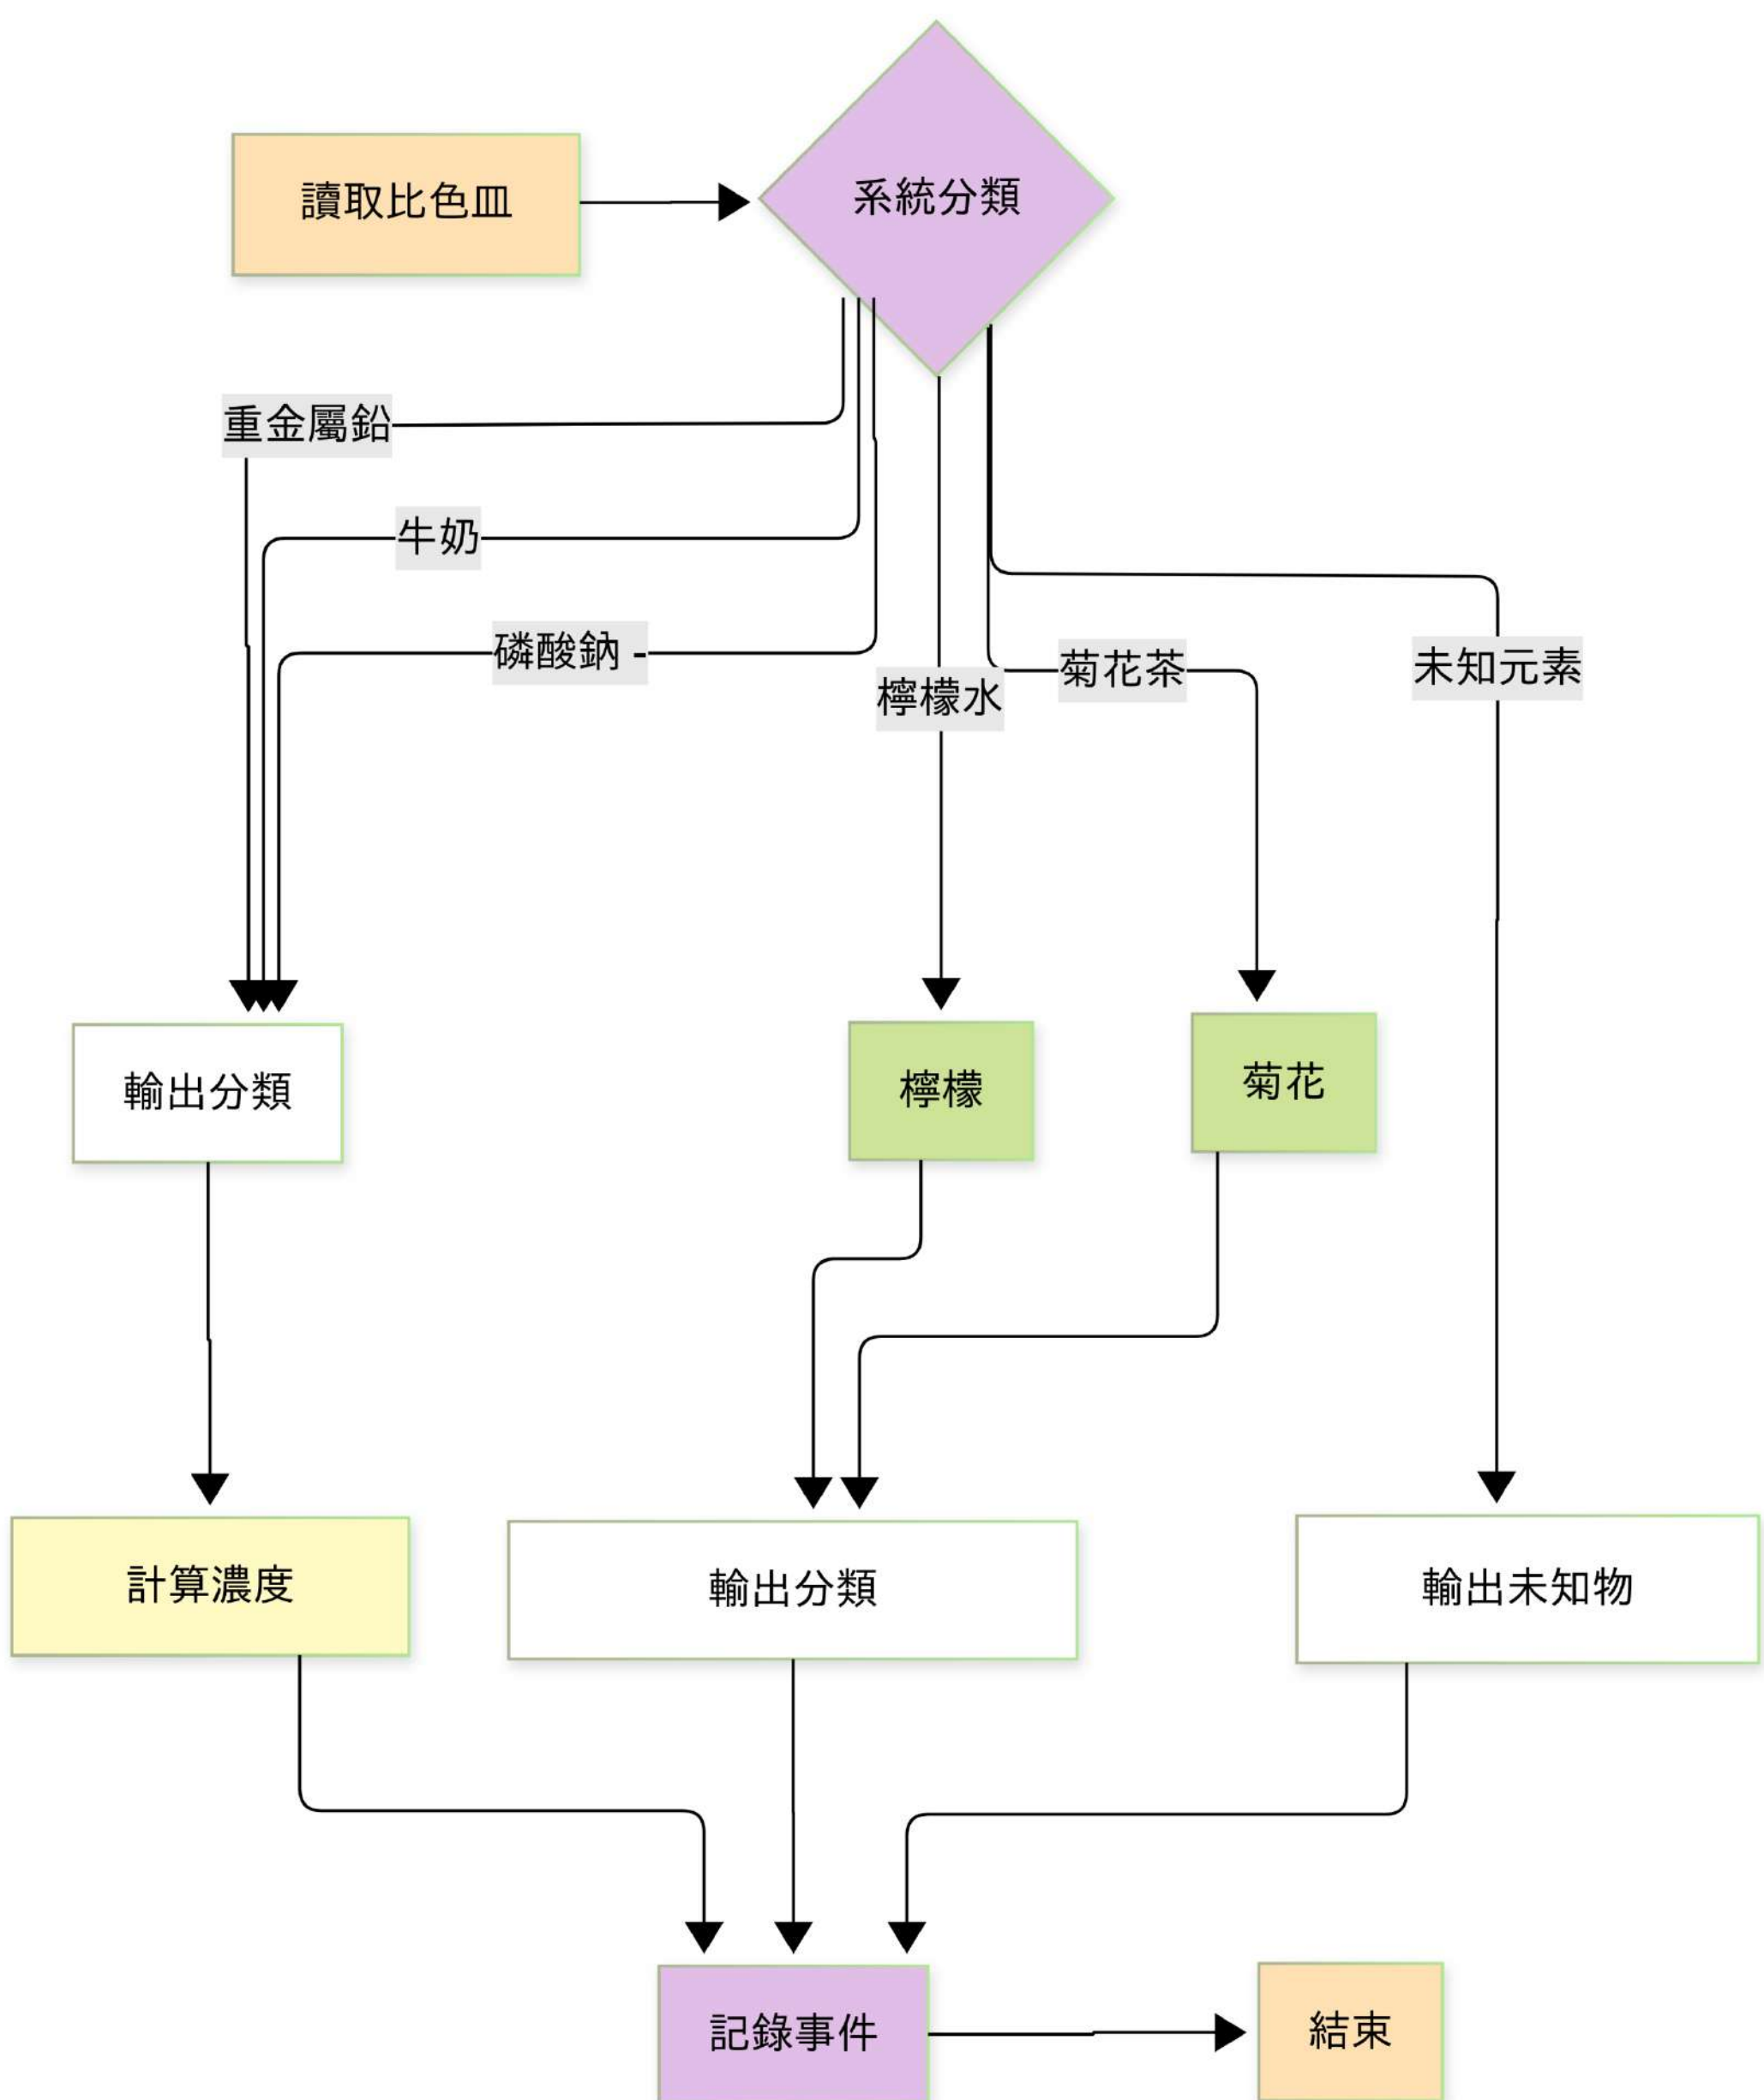


圖:標籤清洗後的訓練模型各其參數調教

肆、討論



圖：系統運作流程圖

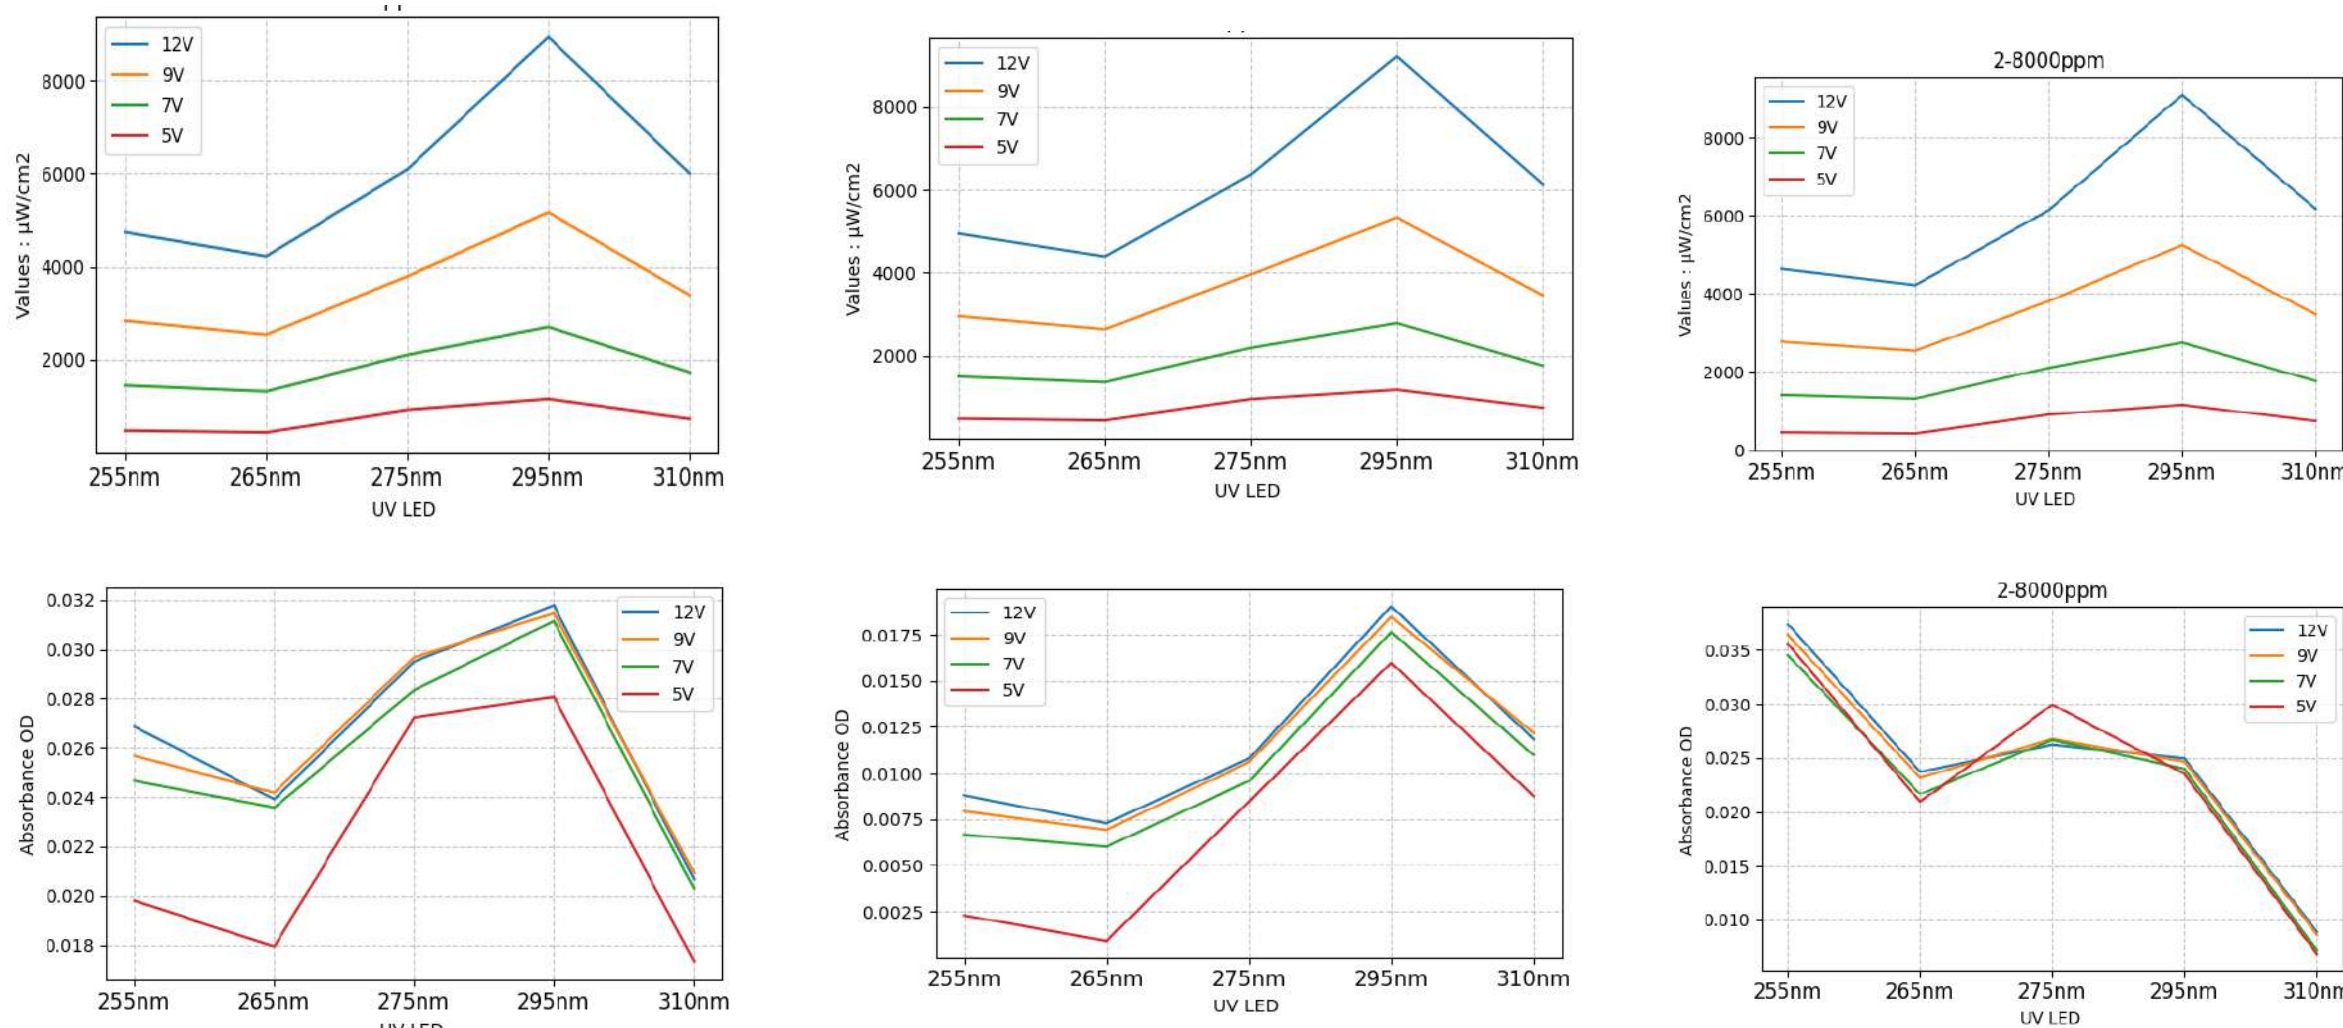


圖:吸光度在低電量低照度出現誤差

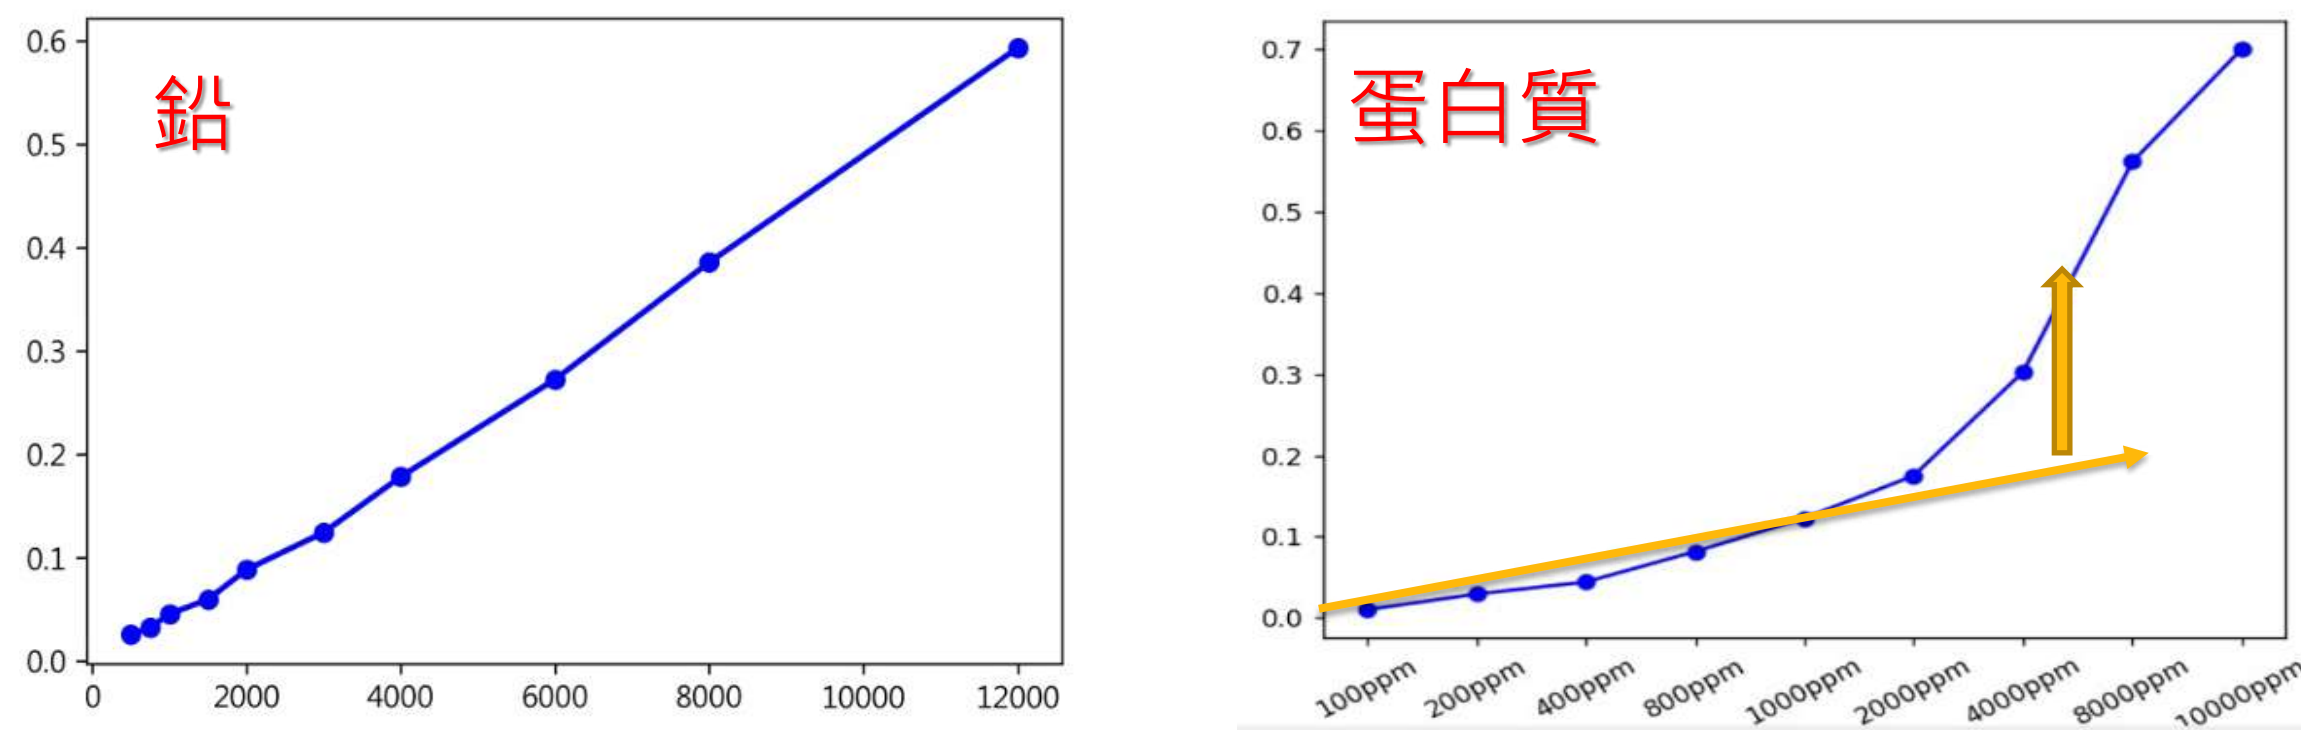


圖:偏離朗伯-比爾定律

伍、結論

 **創新整合與智能化**→「光-電-機-智」整合，結合精密硬體設計與AI智能演算法，實現跨領域技術深度融合，有效提升辨識精度並克服傳統人工判讀的局限性。

便攜低耗與實用性→緊湊設計支援行動電源，實現現場即時監測，大幅降低檢測成本與時間，突破定點監測限制，靈活應對突發污染事件並具備污染溯源潛力。

🔬 科學探究與擴展性→從理論到實驗的完整科學探究，建立模組化架構與AI分析框架，為未來擴展至多種污染物檢測奠定良好基礎。