

基於工業級瑕疵檢測模型的異常檢測系統

Anomaly Detection System Based on an Industrial-Grade Defect Detection Model

專題組員：曾鈺珊、李彥霆

專題編號：PRJ-NTPUCSIE-113-013

執行期間：113年09月至114年06月

1. 摘要

本研究旨在研究基於工業級瑕疵檢測模型的零件異常檢測系統。其中模型通過學習工業零件的正常樣本圖像進行訓練，並於訓練完成後能準確識別輸入零件的多面圖像中可能存在的異常情況。此模型的目標在於提高工業零件生產過程中的瑕疵檢測效率與準確性，進一步降低檢測的成本與錯誤率，以及改善傳統 AOI 在收集與標註瑕疵樣本上的成本。

2. 簡介

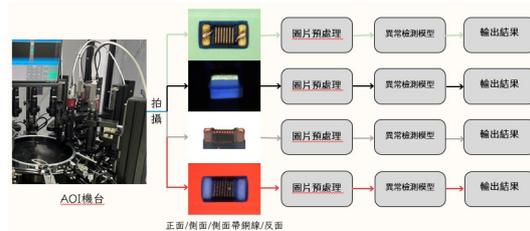
在工業零件的生產過程中，瑕疵檢測是確保產品品質的關鍵環節。現有的自動化檢測技術雖具備一定的應用潛力，但在面對多樣化元件結構與複雜瑕疵類型時，往往難以取得穩定的檢測表現。且目前應用於工業缺陷檢測的技術也面臨著其他的難點，例如：瑕疵樣本匱乏、瑕疵類型未知、瑕疵判斷的主觀性等[2]。導致許多現有的瑕疵檢測方法無法同時滿足高泛化度、高精度、高處理速度等要求。

隨著深度學習技術的快速發展，基於正常樣本去訓練模型的異常檢測方法逐漸受到關注。因此，本研究希望通過引入基於正常樣本去訓練的異常檢測模型，針對工業零件的異常檢測需求，嘗試解決現有技術的瓶頸問題。

3. 專題進行方式

(1) 流程總覽(圖一)

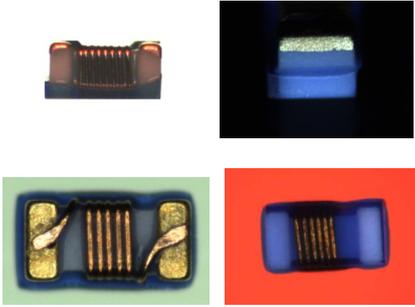
首先由 AOI 機台對電感器進行拍攝，並將影像進行預處理。預處理完成後，再將該影像傳至模型當中，由模型判別該零件是否有異常的部分，並回傳該結果至 AOI 機台，AOI 將由回傳結果把電感器進行分類(分類為 OK/NG)。



圖一、系統流程圖

(2) 資料來源與拍攝

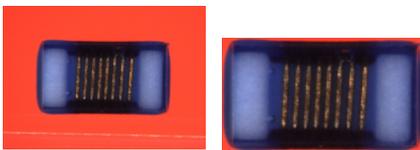
在本次實驗中，我們所使用的資料集來源為合作廠商提供之電感器影像(圖二)，其中涵蓋四種視角：正面(綠底)、側面(黑底)、側面帶銅線(白底)、反面(橘底)，以確保模型能辨識不同角度之缺陷。



圖二、電感器之各個面向

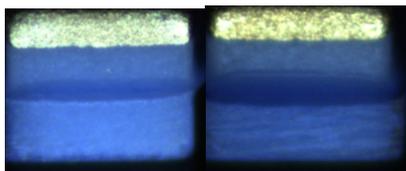
(3) 影像預處理

- 去背：移除非電感器的區域，只保留零件本體，降低背景灰塵與雜訊干擾。(圖三)

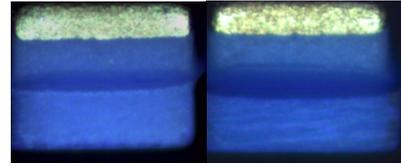


圖三、去背前(左)、去背後(右)

- 色調統一：由於不同批次影像色調可能出現偏差(圖四)，透過色彩校正將所有正常樣本統一至相同色域(圖五)，減少因光照或相機設定差異導致的誤判。



圖四、樣本之色彩差異

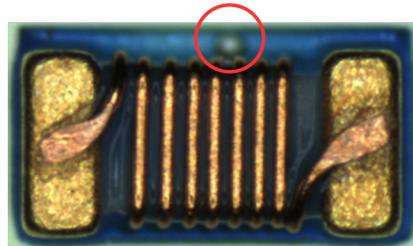


圖五、統一色調減少差異

- 正常樣本篩選：將含有「可接受範圍內小瑕疵」(圖六)的影像剔除，僅以「完美無瑕」(圖七)之照片作為訓練集；同時保留「小瑕疵 NG」與「大瑕疵 NG」影像作為測試評估之用。



圖六、完美無瑕之樣本



圖七、含可接受小瑕疵之樣本

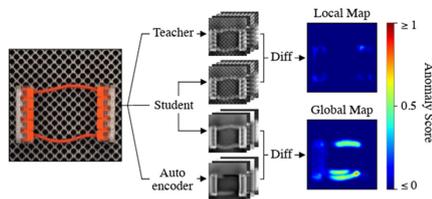
(4) EfficientAD 模型架構[1]

在本研究中，我們決定使用 EfficientAD 模型作為我們異常檢測模型。其中原因為該模型在執行速度以及精準度上都優於其他基於正常樣本進行訓練之異常檢測模型。

該模型架構結合學生老師模型 (Student-Teacher Model) 與自編碼器 (Autoencoder) 的設計，讓該模型可以分別針對局部結構性異常 (如表面刮痕) 與全局邏輯性異常 (如零件缺失或排列錯誤) 進行檢測。

A. 自編碼器

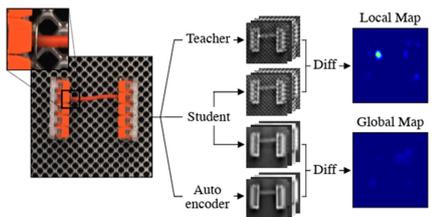
- 編碼階段 (Encoder)：將輸入影像壓縮為低維特徵，強調整體結構資訊。
- 解碼階段 (Decoder)：嘗試重建輸入影像。若輸入含大範圍結構異常(如零件缺失、排列不當)，解碼器與學生模型的重建誤差將明顯上升，形成全域異常圖 (Global Map)。(如圖八)



圖八、由自編碼器與學生模型捕捉到之全局異常(Global Map)

B. 學生 - 教師模型

- 教師網路 (Teacher)：採用預訓練模型，能精準重建正常樣本之特徵。
- 學生網路 (Student)：在訓練階段學習模仿教師網路的輸出。當影像出現細微刮痕、表面瑕疵時，學生網路無法完全重現教師特徵，於瑕疵區域造成顯著的特徵差異，形成局部異常圖 (Local Map)。(如圖九)

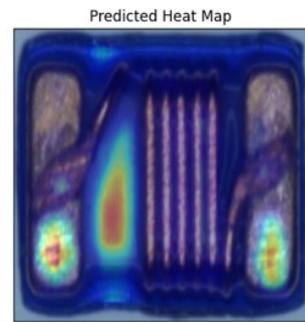


圖九、由學生-教師模型捕捉到之局部異常(Local Map)

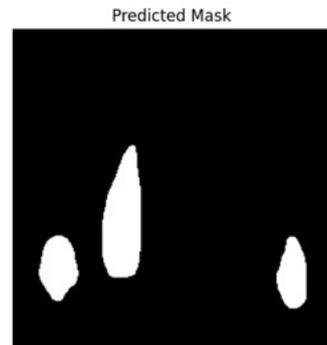
C. 異常圖融合

將全域異常圖與局部異常圖加權融合，得到最終異常熱圖 (Anomaly Heatmap) (圖十)，並據此計算整張影像之異常分數，判定是否為異常及其位置。

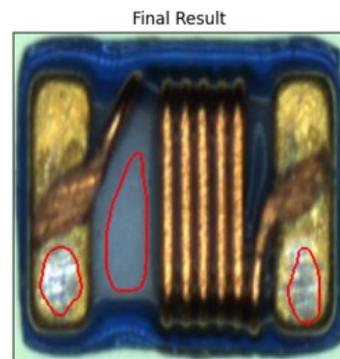
最後根據閾值設定，輸出一張 Predicted mask(圖十一)，以及另一張根據 Predicted mask 所圈選出的異常結果圖。(圖十二)



圖十、異常熱圖，其中異常分數越高處，顏色越靠近紅色



圖十一、Predicted mask

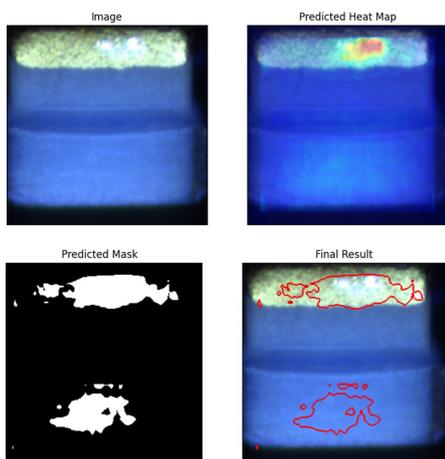


圖十二、最終結果

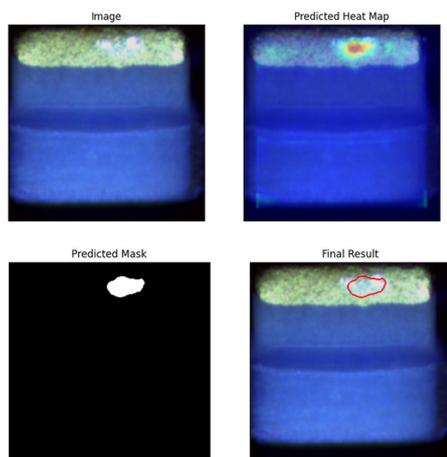
4. 主要成果與評估

(1) 預處理優化之結果

- 色調統一：成功降低因金屬高光或藍色膠面造成的誤判(圖十三)，使局部異常熱圖在無瑕疵區域維持接近零分數(圖十四)。

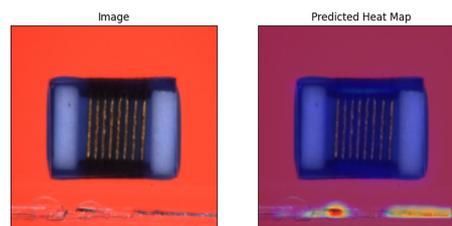


圖十三、未將資料集做色調統一，模型會在正常部位誤判為瑕疵



圖十四、將資料集做色調統一後，在亂圈的部分有顯著改善

- 背景去除：移除非零件區域後，明顯降低因背景灰塵或反光點引起的誤檢(圖十五)，誤判率大幅下降。



圖十五、將背景雜訊誤檢為瑕疵

(2) 實測結果的統計與觀察

施測結果如下表一。

從下表一中的結果我們發現，在側面帶銅線的樣本分類中，資料集在經過預處理之後，表現變得比沒有預處理還要差。同時，在側面樣本中，資料集在未被預處理前的誤殺率非常高，而預處理過後的表現則是誤殺大幅降低、但是漏檢率卻也同時上升。而在其他面向中，我們發現經過資料預處理後，整體的表現都有優化的傾向。

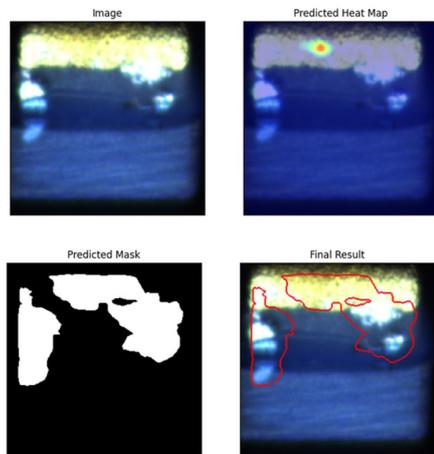
經過觀察，我們發現模型在金屬光澤上會非常敏感，導致會將金屬面的反光誤判成刮痕。這是誤殺率在側面以及側面帶銅線的部分會較高的主因。

| | | 漏檢率 | 誤殺率 |
|-------|---------|-------|-------|
| 正面 | 大瑕疵 | 0% | 1.26% |
| | 小瑕疵 | 0.83% | |
| | 未預處理資料集 | 1.4% | 3.62% |
| 背面 | 大瑕疵 | 0% | 8% |
| | 小瑕疵 | 2.24% | |
| | 未預處理資料集 | 3.6% | 7.3% |
| 側面 | 大瑕疵 | 0% | 12.6% |
| | 小瑕疵 | 13.5% | |
| | 未預處理資料集 | 0.5% | 53.2% |
| 側面帶銅線 | 有預處理資料集 | 4.6% | 1.2% |
| | 未預處理資料集 | 0.92% | 0.5% |

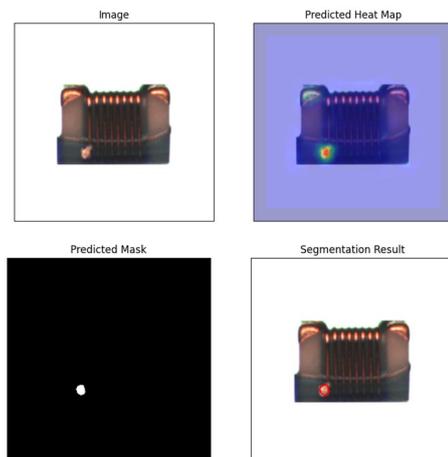
表一、模型在所有面向之漏檢率以及誤殺率

(3) 案例展示

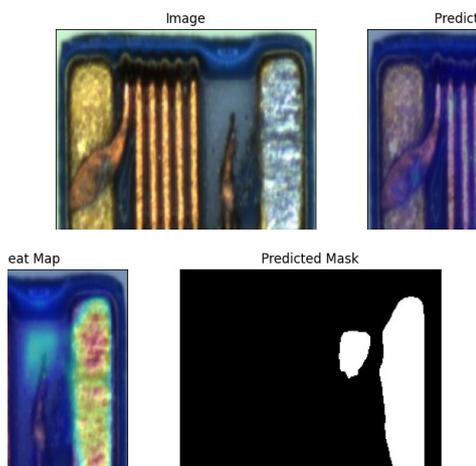
以下案例展示依序皆為：原圖、異常熱圖、Predicted mask、最終結果。



案例一、側面之大型刮痕瑕疵



案例二、側面帶銅線之小型瑕疵



案例三、正面之大刮痕與銅線斷裂

5. 結語與展望

即使將我們所定義的正常樣本作為訓練資料，模型的表現可能還是會不如我們預期的好。而透過本次研究，我們發現資料的品質以及預處理方式對基於正常樣本進行訓練的模型的表現有一定程度的影響。經過預處理過後的模型在多數面向上的表現會更加優秀。

雖然目前在側面瑕疵檢測的準確度仍然不高，經觀察發現模型會對於金屬反光處非常敏感，因此未來或許可以透過將藍色膠面與金屬面分開訓練並檢測瑕疵，來改善上述的問題。

最後根據我們的統計結果，總結來說，嚴謹的影像預處理（去背+色調統一），能夠讓我們在僅用正常樣本訓練的情況下，同時偵測電感器的大範圍與細微瑕疵，並達成高準確度與低延遲。因此我們認為，將基於正常樣本進行訓練的模型未來應用在工業生產上，是有著極大的可行性的。

6. 銘謝

由衷的感謝指導教授以及系上實驗室的學長們提供的所有指教以及協助，讓我們能夠順利完成本次專題研究。

7. 參考文獻

[1] Kilian Batzner, Lars Heckler, Rebecca König. "EfficientAD: Accurate Visual Anomaly Detection at Millisecond-Level Latencies" 25 Mar 2023.

<https://arxiv.org/abs/2303.14535v3>

[2] 什麼是 AOI? AOI 的優勢與弱勢?

<https://www.solomon-3d.com/tw/blog/what-is-aoi/>