

# 以 CNN 與 YOLO 探索 PCB 異常檢測

## 動手實作的電腦視覺 PoC


我想搞懂工業視覺異常檢測怎麼運作，於是動手做了一個小 PoC。我使用公開的 VisA PCB 資料集，用 CNN 特徵建立正常影像模型，測試 ROI 計分與穩健性，再訓練監督式 YOLO。這裡記錄了我的嘗試、成敗與實際收穫。

Yu-Chen (Leon) Lai / Computer Vision

<https://leonlaiyc.github.io/industrial-visual-anomaly-detection/zh-tw/>

● 實驗中的真實影像

CNN / PCB2



PCB2 / 成功檢出的異常。正常影像建模流程產生的熱圖；虛線為計分區域。

# 三個階段，不同的解法與考驗。

三輪探索串起同一段學習歷程。PCB1、PCB2、PCB3 與 PCB4 是四種不同的電路板資料集。它們各自獨立，使用不同的測試集，並不是把全部資料混在一起訓練同一個模型。

A

PCB1

CNN 基準方法

只學習正常外觀，能找出沒見過的瑕疵嗎？

僅以正常影像建模

資料檢視

↓

方向校正與影像對位

↓

預訓練 WideResNet-50-2 特徵

↓

逐位置高斯模型 / 馬氏距離

↓

影像異常分數與熱圖

方向、影像對位與背景干擾，是基準方法的主要挑戰。

先理解資料，再調整模型。

B

PCB2 / PCB3

改善與壓力測試

前處理能降低干擾，同時避免引入新的失敗模式嗎？

PCB2 與 PCB3 分開實驗

CNN 基準方法

↓

電路板 ROI 計分

↓

門檻校準

↓

受控光照修正實驗

↓

穩健性評估與工程決策

PCB2 測試 ROI 範圍計分；  
PCB3 則獨立測試光照修正的效果。

把圖片調亮、調暗、改變對比或模糊，測試對檢測結果的影響。

C

PCB4

監督式 YOLO

有了瑕疵樣本與標註，影像檢測會有什麼不同？

使用瑕疵標註訓練

PCB4 瑕疵標註

↓

遮罩轉換為邊界框

↓

YOLOv8s / YOLO11s 訓練

↓

校準與影像層級檢測

↓

失敗案例與影像擷取混淆分析

YOLO 使用瑕疵標註訓練，採用單一 defect 類別；前面的 CNN 方法只用正常影像建模。


除了看模型得分，還要確認瑕疵位置有沒有框對。

實際發生了什麼

## 從翻車的地方與壓力測試中學到的事。


只選幾個來自凍結分數紀錄的代表性結果。每個發現都保留所屬資料集與評估條件。

### A 先建立正常外觀的模型




PCB1 正常影像：上排為原始影像，下排為對位後裁切。

### B 優化之後，再進行亮度測試



PCB2 誤報案例：正常影像仍觸發 ROI 模型。

### C 理解監督資訊帶來什麼



PCB4 標註檢查：紅色為訓練框、青色為真值遮罩；這是標註，不是模型預測。

#### 想釐清

不使用瑕疵訓練標籤，預訓練 CNN 特徵能辨識異常嗎？

#### 嘗試方法

檢視與對位 PCB1 影像，再於特徵圖各位置建立高斯模型。

#### 實際結果

原始 PCB1 基準方法檢出 72/100 張瑕疵測試影像（瑕疵檢出率 72%）。熱圖與誤報案例呈現了對位與背景造成的影響。

#### 我的收穫

最高異常分數可能來自背景，而不是瑕疵。要一起檢查影像與計分區域。

#### 想釐清

只在電路板內計分，加上光照修正，能減少誤報嗎？

#### 嘗試方法

在 PCB2 評估 ROI 計分；在 PCB3 另做受控光照修正實驗，搭配門檻校準與穩健性檢查。

#### 實際結果

PCB2：正常測試影像誤報率由 13% 降至 3%，瑕疵檢出率維持 80%。  
PCB3：修正在部分光照條件下有效，卻使模糊影像的誤報明顯增加，因此未採用候選方法。

#### 我的收穫

先解決干擾源，再看代價。優化單一條件，不代表整體變得更穩健。

#### 想釐清

使用已標註瑕疵，影像層級檢測會如何改變？

#### 嘗試方法

將 PCB4 瑕疵遮罩轉成邊界框，訓練 YOLOv8s 與 YOLO11s；使用單一 `defect` 類別與保留瑕疵 fold 評估。

#### 實際結果

觀察到的影像層級瑕疵檢出率：YOLOv8s 98%、YOLO11s 95%。此監督式設定下檢出率較高，但也發現亮度混淆、對未見瑕疵類型的泛化較弱，以及定位限制。

#### 我的收穫

判定影像有瑕疵，不代表框能精準定位瑕疵。這是探索性研究，不能據此斷言哪種架構較優。

CNN 只用正常影像建模，YOLO 則使用瑕疵標註。兩者的資料集與實驗條件不同，無法直接拿來比較模型優劣。

## 下次實作，我會記住這四件事。

01

### 資料品質與前處理很重要。

信任分數之前，先檢查方向、對位、電路板遮罩與影像條件。

03

### 更好的指標，可能帶來意外代價。

PCB3 光照修正改善部分條件，卻引入模糊影像的失敗模式。

02

### 別急著把模型做複雜，先找出問題根源。

誤報影像幫助我辨識背景干擾，也促成 ROI 計分的嘗試。

04

### 模型選擇取決於資料、標註與目標。

正常影像建模與監督式檢測回答不同問題，也需要不同證據。

#### 探索程式與證據

### 精簡的展示，背後有完整技術紀錄。

來源庫保留真實程式、實驗流程、資料切分說明、分數紀錄、模型比較限制、稽核證據與 D5 時間線。

前往技術來源庫 (<https://github.com/leonlaiyc/industrial-visual-anomaly-detection>)

使用公開 VisA 基準影像；尚未在真實製造產線影像上驗證，也不宣稱已具備正式上線條件。開發過程使用 AI 輔助。

影像：VisA、Amazon Science · Zou 等人，ECCV 2022 · CC BY 4.0。圖像經對位、裁切、縮放及疊圖處理；不代表原作者背書。

資料集與論文 CC BY 4.0