

基於深度卷積神經網路之印刷電路板影像瑕疵分類

Defect Classification of Printed Circuit Board Based on Deep Convolutional Neural Networks

賴威豪

工業技術研究院

WeiHaoLai@itri.org.tw

曾紹峯

工業技術研究院

tseng@itri.org.tw

摘要

現今印刷電路板產業蓬勃發展，生產逐漸精密化且佈線密度也愈趨愈複雜，為了提升印刷電路板製程的品質必須要進行有效率的檢測。傳統是以人工目視檢測印刷電路板上的瑕疵，不僅耗時且誤判率也可能隨人的精神狀態而起伏，再加上以人工目視檢測的誤判率也因電路板密度提升有逐年上升的趨勢，因此廠商開始引入自動光學檢測系統來輔助人員作業。然而現今以影像辨識為主的自動光學檢測系統為了達到接近百分之百檢出率，往往會造成高誤判率，使得被機器挑出的候選影像大多是假缺陷，因此本研究嘗試應用以卷積神經網路的方法加強電路板瑕疵分辨任務，目的是降低自動光學系統造成的高誤判率現況。我們希望能藉卷積神經網路對圖像分類領域所帶來突破性的研究成果也一併套用至自動光學檢測技術領域上，此篇論文應用了幾種較為著名的卷積網路架構，像是 LeNet、AlexNet、VGG、GoogLeNet、ResNet 等等，將自動光學檢測系統挑選出來的印刷電路板影像作為訓練資料集，並且在分類真缺陷和假缺陷的任務中獲得了 97.12% 的準確率，亦證明卷積神經網路是可以被應用在印刷電路板瑕疵分類上。

關鍵字: 印刷電路板、瑕疵分類、深度學習、卷積神經網路

Keywords: printed circuit board, defect classification, deep learning, convolutional neural network

壹、前言

印刷電路板(printed circuit board, PCB)是各式電子產品中關鍵零組件，凡舉電子錶、手機、相機、液晶螢幕和電腦組件等等生活所及之產品皆有其蹤影，在整個消費性電子產業中是不可或缺的重要基礎元件。而印刷電路板生產過程中會依照電路設計將欲連接之電子零組件的佈線製成多層線路樣板，每個內層板經過印刷和蝕刻之機械加工流程後再對其表面做視覺檢驗[1]。然而傳統以純人力來完成各項檢驗工程已經無法滿足大量生產的需求，並且人員也可能會受疲勞、情緒或者主觀意識影響檢驗的好壞。為了讓產品有更好的生產良率，勢必要對製程的檢測做好管制，所以近年來各家廠商開始推出自動光學檢測(Automated Optical Inspection, AOI)設備，目的則是希望透過新技術把關品質進而帶動獲利的上升。

自動光學檢測流程是利用光學儀器取得受測物體表面的狀態，再應用機器視覺相關技術來檢測是否有異常，接下來通過顯示器或其他自動標示方法來供人員判別，整體測試流程中

大部分都可自動化執行，除了能節省人力成本也能降低人為檢測時的誤判率，在印刷電路板產業中持續發展自動光學檢測已是廠商維持競爭力的一種趨勢。然而整體自動化流程中雖然逐漸可以達成近百分之百的檢出率，但仍舊存在高誤判率的狀況，也就是除了真缺陷被檢測出來之外也會包含大量的假缺陷，因此現今的作法通常是標示所有可能有缺陷瑕疵的電路板，再經過檢測人員作最終篩選，確認是否可進行整修或作廢棄處理。透過自動光學檢測找出的印刷電路板缺陷，拍攝其所在位置的影像實際可分為真缺陷和假缺陷，像是缺口、斷線、突出和短路等等會影響電子線路發揮應有的功能，因而無法出產為產品的統稱真缺陷類別；相反地，像是黏膠異物、碎屑或是表面變色等等，可由人工修補或被判定不影響電路功能的則歸為假缺陷，所以最終仍可以製為產品。在實際的應用狀況，無論是人工目視或是機器輔助，真缺陷以及假缺陷的分類會衍生出了兩個問題，若真缺陷被錯誤地分類為假缺陷而製成產品，那麼直到最後驗收才發現就只能報廢處理，相對來說若是假缺陷被錯誤地分類為真缺陷，那麼就會浪費掉原本可作為成品的元件，因而降低正常產品的生產率。

為了更進一步地將誤判率降低，在自動光學檢測流程中會進一步用影像處理的方法處理機器標示出來可能是真假缺陷的影像，最普遍的作法是使用參考影像比對法，其中[2]提出的方法欲解決短路缺陷，透過電路板通電以及短路區域會發熱的特性，拍攝通電後的紅外線影像再進行差異比對。[3]的作法將缺陷影像與參考影像作 XOR 運算，計算後得到帶有雜訊的影像，再使用 Haar 小波轉換將高頻的雜訊濾除後做比對並找出缺陷圖形。然而取得光學設備拍攝的標準參考影像其代價十分昂貴，任何欲檢測的缺陷影像都必須提供其相對的參考影像，而這些參考影像要事先動用可觀的人力來建立。也有不使用參考影像的做法像是[4]所提出的特徵萃取方法，利用卷積神經網路(convolutional neural network, CNN)對輸入的缺陷影像作運算並從中提取卷積特徵，再利用 SVM 方法對卷積特徵做分類。

在電腦視覺領域中影像特徵提取和分類一直都是基礎且最重要的方向，以前經典的特徵提取的計算方法，像是 SIFT (Scale-Invariant Feature Transform)、HOG(Histogram of Oriented Gradient)等等特徵都被證明有良好的表達效果，然而這些人工設計的方法始終有泛化性問題，在 2011 年左右 ImageNet 圖像分類比賽中最好的結果也有 26%的誤判率，但是隔年 Krizhevsky 等人[5] 提出的 AlexNet 取得了巨大的進步成果，將誤判率降低至 16%，並且每年的 ImageNet 冠軍不斷的刷新紀錄，在 2015 年之後誤判率甚至低於人類平均的辨識誤判率 5.1%，這也使得卷積神經網路受到極大的關注。


回歸原來自動光學檢測的目的無非就是想盡早地發現瑕疵並有相對應的處理，使生產的效益最大化，因此無論是以何種方法應用到印刷電路板缺陷分類都是值得一試的。本篇論文主要探討的是以卷積神經網路為主的方法，憑藉卷積神經網路對圖像分類領域所帶來突破性的研究成果，我們嘗試在印刷電路板之光學影像的缺陷分類中，應用現今較為流行的幾種卷積神經網路架構，探討其優缺點以及嘗試分析並找出適用於自動光學檢測中印刷電路板缺陷分類的網路架構。

貳、缺陷種類及定義


印刷電路板缺陷影像中能分為真缺陷和假缺陷，其中根據影像呈現的顏色和形狀可劃分成幾種不同的類別，然而以人眼可以將之歸為同一類的缺陷可能在影像上有截然不同的樣貌，使得缺陷分類的任務更加困難。舉例來說，圖一(a)和圖一(b)都是分類為缺口但在邊緣區域的顏色強度卻不一樣；圖一(g)和圖一(h)則是分類為變色但是發生位置一個在線路上另一個卻在電路板上。

真缺陷會引起與實際電路設計不符的表現，參考圖一(a)至圖一(e)種類代表，對於檢測人員來說這些是必須挑出來的瑕疵。假缺陷則通常會有與正常的線路不太一樣的顏色，像是圖一(f)至圖一(i)種類，檢測人員會評估這些瑕疵是否能做修補再重回製程生產。


本篇論文使用的印刷電路板瑕疵影像資料集是先透過自動光學檢測之機器挑選出來的，總共分為五個類別：正常、皮屑、髒污、殘膠和線路異常，已經先由檢測人員確定每張影像的所屬類別，其中我們將缺口、斷路、突出和短路視為線路異常類別。




(a)缺口




(b)缺口




(c)斷路




(d)短路




(e)突出




(f)殘膠



(g)變色



(h)變色




(i)皮屑

圖一、印刷電路板缺陷

參、架構流程

在自動光學檢測流程中通常分為三大類模組，分別是電路板對位模組、特徵提取模組和特徵比對模組，藉由自動化流程可以得到許多可能包含瑕疵的候選區域影像，通常這些候選影像仍需要人工進行目視檢測才能知道是真缺陷或假缺陷。

圖二為本文之自動光學檢測流程，本文在自動光學檢測中額外加入的神經網路檢測模組，目的是為了輔助人工目視檢測，此模組的輸入是自動光學檢測後所標示的候選區域影像，而輸出則是判定影像是真缺陷或假缺陷，而後面的實驗會再分析此模組的可行性。




圖二、自動光學檢測流程

肆、卷積神經網路

最早出現之卷積神經網路雛形是 1998 年 LeCun 等人提出的 LeNet[6]，其採用基於梯度的反向傳播演算法(gradient-based back-propagation)進行監督式訓練，最大的特色是交互使用卷積層(convolutional layer)和池化層(pooling layer)將原始影像轉換並得到特徵圖，再透過全連接層(fully connected layer)對各特徵表達進行分類，而此架構對手寫字母辨識的成功開啟了學術界對神經網路的關注，並且也建立卷積網路模型的雛型，圖三示意。

之後 Krizhevsky 等人提出的 AlexNet[5]贏得了在 2012 年 ILSVRC 圖像辨識冠軍，更證明卷積神經網路可以應用在大型的圖像辨識任務，其設計的網路架構約有 65 萬個神經元和 6000 萬個訓練參數，遠遠超過 LeNet 的規模。除此之外作者亦提出了 dropout 層解決過擬合(overfitting)問題以及使用 GPU 做神經網路的訓練，使訓練速度提升了十倍以上(相比只使用 CPU 來說)，因此神經網路的研究漸漸不再被侷限於硬體性能，至此後續數年研究進行得如火如荼。



圖三、卷積神經網路

Simonyan 等人在 AlexNet 的基礎上提出了 VGG 網路架構[7]，其針對卷積神經網路深度的研究發現越深的網路帶來越好的分類結果，但深度增加並非沒有限制，若在適當深度下繼續增加網路層數則會產生梯度消失(gradient vanishing)問題，並且連帶出現訓練誤差加大的網路退化現象[8]，實驗結果說明層數設定在 16 或 19 層為最佳。

接下來 2014 年 ILSVRC 圖像辨識比賽的獲勝者是由 Google 的 Szegedy 等人提出的神經網路架構 GoogLeNet[9]，不著墨於增加網路深度而是特別對結構進行優化，其使用了由 1×1 、 3×3 和 5×5 不同大小的卷積核組合而成的 inception 模組，目的是減少總參數量以及在同層的特徵圖上用不同比例的卷積運算提出更多樣的資訊，在 ImageNet 資料集之準確率比 AlexNet 高十百分比而且參數量只有它的約九分之一。在此之後 Szegedy 等人又提出了改良的 GoogLeNet v2[10]，特色是使用批量歸一化(Batch Normalization)提升網路收斂速度以及準確率。

由於 Simonyan 等人[7]指出層數越多的網路架構需要訓練的參數就越多，並且使網路學習得更完善，但是也會面臨到深層網路退化問題，因此 He 等人提出 ResNet[11]以及 ResNet-v2[12]，藉由殘差單元(residual unit)內的恆等映射(identity mapping)，略過部分可能沒有經過完善訓練的網路層，藉此解決網路退化問題並建構非常深的網路架構以提高性能，因此該作者團隊也在 2015 年 ILSVRC 圖像辨識比賽獲得優勝。

前幾段落敘述了現今在 ILSVRC 圖像辨識比賽中最著名的幾種神經網路架構，表一整理出上述各網路架構提出的特殊之處以及解決了何種難題，然而衍生出來是卷積神經網路的泛用性問題，由於卷積神經網路需要設置的參數非常多，到目前為止的研究大多是基於經驗和實際操作後所得到的結果，也就是說這些在 ILSVRC 比賽獲得優勝的網路架構可否轉移到不同的應用上仍需要商榷，因此回歸到本文期望是應用卷積神經網路在自動光學檢測流程上辨識出印刷電路板影像是真瑕疵或假瑕疵，我們將套用這些網路架構及其文獻提及之參數來驗證以同樣的網路架構但是應用在不同領域上所帶來的差異。

網路架構	總參數量	特色	解決之問題
LeNet	0.43 M	convolutional layer	提出卷積架構並使神經網路
AlexNet	60 M	LRN layer, dropout layer	應用在更大的影像任務上和嘗試減少過擬合現象
VGG16	138 M	3x3 kernel, no LRN layer	對網路深度進行研究並發現往深層網路退化現象
GoogLeNet v1	6.8 M	inception module	提出 inception 模組對優化網路
GoogLeNet v2	13.6 M	batch normalization(BN)	改善 inception 模組和提出 BN 層異加快網路收斂
ResNet 50	25.6 M	identity residual block	透過恆等映射減輕深層網路退化現象

表一、各卷積神經網路總述

伍、實驗

本文針對前章節所提到的卷積網路架構實際進行訓練以及統計分類結果，我們使用的資料集為自動光學流程中被機器挑選出來需要人工檢視的印刷電路板候選區域，總共有五種類別(細節已於第貳章敘述)，其中前四種類別是假缺陷，最後一種則是真缺陷，資料集總共有 2468 張影像寬高為 320 x 240 的缺陷候選影像，而各類別影像數量如表二所示。我們拿 80% 做為訓練資料集，20% 作為測試資料集用以衡量結果好壞，實驗使用的軟體是 TensorFlow 程式庫[13]，硬體則是使用單張 Nvidia Maxwell Titan X 顯示卡。

	正常	皮屑	髒污	殘膠	線路異常
總張數	832	344	624	396	271
訓練資料集(80%)	666	276	500	317	217
測試資料集(20%)	166	68	124	79	54

表二、資料集一覽

一、參數設置


表三是本次實驗之網路規模和設定，除了 VGG16 以及 ResNet50 參數稍作修改，其餘架構之設置皆參照各篇文獻上記載之數值。VGG 文獻設置批次數量(batch size)為 256 但其參數量過多無法使用單張顯示卡設備達成而改為 64，相同問題也出現在 ResNet 中，我們將批次數量從 256 改為 128。另外 GoogLeNet v1 版本並沒有提及相關參數設置之數據，因此本實驗採用與 GoogLeNet v2 版本相同之設定。其他像 VGG 文獻提到對數據增強(data augmentation)的作法，是使用 S 參數做多次調整達到不同的模型訓練，總共設定 S=256 以及 S=384 做為輸出模型，在我們的實驗中則改為只用 S=256 但代替的是對其做更多的訓練疊代。本實驗中各神經網路訓練統一為 348 epochs (將訓練集全部訓練一次代表 1 epoch)，此設定比各篇論文內提到的次數要來的多，倘若結果統計上若有出現網路退化之現象，我們會以該網路呈現之最佳狀態作為衡量準則。

Network	Data augmentation	Batch size	Initial learning rate	learning rate scheme
LeNet	none	no batch	0.0005	隨 epoch 越多逐漸除 2 遞減至 0.00001
AlexNet	random cropping, horizontal flips	128	0.01	手動調整三次每次除 10 至 0.00001
VGG16	random cropping, horizontal flips, intensity adjustment	64	0.01	根據驗證集沒有進步時調整， 共調整三次每次除 10 至 0.00001
GoogLeNet v1	same as below			
GoogLeNet v2	random aspect ratio, random cropping, horizontal flips, intensity adjustment	32	0.045	使用指數衰減下降作調整
ResNet50	random cropping, horizontal flips, image standardization	128	0.1	根據特定 epoch 除 10 共兩次至 0.001

表三、各卷積神經網路參數設定

二、結果與分析

圖四是各網路架構對測試資料集中每一張候選影像所預測之結果統計，採用 top-1 衡量標準，也就是預測類別必須準確的符合真正類別才算成功辨識，圖內的兩軸分別是垂直軸為準確率(accuracy)以及水平軸為 epoch 次數，從圖中得知三種神經網路架構 AlexNet、VGG16 以及 ResNet50 的表現比較好，而另外三種網路架構的表現則差強人意。



圖四、各神經網路準確率表現

探究模型表現較差有兩大因素:神經網路參數量不足以記錄此模型分布以及學習到的特徵不能代表此模型分布。由於 LeNet 架構設計是針對 MNIST 手寫數字，其輸入寬高是 28 x 28 的影像，並且只有 7 層結構約 0.43M 參數量相比其他架構是非常小型的，而印刷電路板候選影像則是 320 x 240，所以可能會損失掉重要的資訊導致特徵沒有學習完備，因此綜合這些因素使得 LeNet 在此應用上的準確率不高。另外根據 Szegedy 等人提出的 GoogLeNet v1[9]及 v2[10]版本在 1000 類別的 ImageNet 資料集的表現都非常亮眼，然而 GoogLeNet v1 和 v2 卻在本次實驗中並列在低準確率的行列，這樣有趣的現象使我們懷疑是否是因為該篇作者對於資料增強的作法採用的是隨機擷取長寬比所導致，目的是想在原來的應用中學到更多不同型變的特徵，因此為了得知該方法是否會影響印刷電路板瑕疵的分辨，我們追加了實驗而用的資料增強策略則改為和 ResNet50 一樣，並且也對初始學習率(initial learning rate)做調整(從 0.045 改為 0.0045 防止梯度爆炸現象)，接下來表四列出兩者前後不同的資料增強策略帶來的結果，雖然 v1 版本不增反降但 v2 版本卻從很低的準確率躍升成 84.4%，由此可見僅僅改變了資料增強的方法就可以有這麼大的差距，這也說明不是同一種設定就可以直接對應到不同資料集上，也許該論文設定的數值對於我們自己的應用反而是比較糟糕的設定，因此微調參數之關鍵很大原因取決於應用的資料集。

	GoogLeNet v1	GoogLeNet v2
original approach	23.0%	28.1%
New approach	19.3%	84.4%

表四、改變資料增強的準確率列表

三、印刷電路板真假缺陷辨識

本篇論文最終的目的是分辨出印刷電路板候選影像中是真缺陷還是假缺陷，根據圖四之呈現，我們在表五整理出各神經網路最好的準確率發生點，可以看到 ResNet50 是六種架構表現最好，在約 307 epochs 有 93.4%的準確率(百分比表示)，因此接下來鎖定 ResNet50 做分析。

	LeNet	AlexNet	VGG16	GoogLeNet v1	GoogLeNet v2	ResNet50
accuracy(%)	19.6%	85.5%	87.0%	23.0%	28.1%	93.4%
~epochs	348	348	321	309	333	307

表五、最高準確率及發生時間

對於分辨真缺陷和假缺陷的統計方式為將預測出來的結果若是類別一到類別四則視為假缺陷，而預測出來是第五類別則是真缺陷，表六和表七可以看到將原本五類別分類合併為真假缺陷兩類別分類所帶來的各項統計(使用百分比表示)，由此得知使用了 ResNet50 網路架構對於印刷電路板真或假缺陷的分類準確率(accuracy)高達 97.12%，另外精準度(precision)及召回率(recall)數值也相當高，換句話說此分類器的預測結果擁有良好的穩定性。

		groundtruth		預測準確率
prediction		假缺陷	真缺陷	
	假缺陷	383	5	98.71%
	真缺陷	9	94	91.26%

表六、真假缺陷各類別預測準確率

	Accuracy	Precision	Recall	F1-measure
ResNet50	97.12%	98.71%	97.70%	98.20%

表七、真假缺陷之數學統計

陸、結論

此篇論文證明了卷積神經網路可以被應用在自動光學檢測中需要經由人力目視檢測的部分，且在分辨候選影像是真缺陷及假缺陷的任務中有 97.12% 的準確率。另一方面我們也驗證了原本為 ImageNet 資料集設計並在 ILSVRC 比賽中獲得獎項的各種網路不一定適用在印刷電路板的瑕疵資料集上，另外我們針對 GoogLeNet 兩個版本的網路架構，調整不同的資料增強策略，發現一個仍非常不理想但另一個有出現谷底反彈的情況。本文在分成五個類別的印刷電路板瑕疵資料集上訓練出一個表現優異的卷積神經網路模型，並且也能再針對分成真或假缺陷的檢測上，但如何使用某架構或如何設定什麼樣的參數尚缺乏完整的研究論述，這也是目前神經網路領域中較為匱乏的地方。倘若能更全面性了解神經網路其背後的原理和涵義，會使得真假缺陷檢測的神經網路輸出更可靠的預測結果，在未來也將可以繼續推廣應用在更加複雜以及更多類別的印刷電路板瑕疵檢測上。

柒、參考文獻

- [1] P. Dutta, "Printed Circuit Board Design Flow Methodology," <http://www.cs.berkeley.edu/~prabal/teaching/cs194-05-s08/cs194-designflow.ppt>, Accessed: 25-Jul-2017.
- [2] S. Maeda, M. Ono, H. Kubota, and M. Nakatani, "Precise detection of short-circuit defects on TFT substrate by infrared image matching," *Systems and Computers in Japan*, vol. 30, no. 12, pp. 72–84, Nov. 1999.
- [3] 陳璋琪, "應用小波理論於印刷電路板缺點之檢測," 碩士論文, 成功大學電機工程研究所, 2003 年六月.
- [4] Y. Takada, T. Shiina, H. Usami, Y. Iwahori and M. K. Bhuyan, "Defect Detection and Classification of Electronic Circuit Boards Using Keypoint Extraction and CNN Features," in *The Ninth International Conferences on Pervasive Patterns and Applications*, Athens, Greece, 2017, pp. 113–116.

- [5] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," in *Proceedings of the 25th International Conference on Neural Information Processing Systems*, 2012, pp. 1097-1105.
- [6] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, Vol. 86, no. 11, pp. 2278 - 2324, Nov. 1998.
- [7] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," in *3rd International Conference on Learning Representations (ICLR2015)*, San Diego, USA, 2015, pp. 1-14.
- [8] K. He and J. Sun, "Convolutional Neural Networks at Constrained Time Cost," in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, 2015, pp. 5353-5360.
- [9] C. Szegedy *et al.*, "Going deeper with convolutions," in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, 2015, pp. 1-9.
- [10] S. Ioffe and C. Szegedy, "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift," in *Proceedings of the 32nd International Conference on Machine Learning (ICML-15)*, Lille, France, 2015, pp. 448-456.
- [11] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 2016, pp. 770-778.
- [12] K. He, X. Zhang, S. Ren, and J. Sun, "Identity mappings in deep residual networks," in *The 14th European Conference on Computer Vision*, Amsterdam, The Netherlands, 2016, pp. 630-645.
- [13] "TensorFlow — an Open Source Software Library for Machine Intelligence." [Online]. Available: <https://www.tensorflow.org/>, Accessed: 21-Jul-2017.