

SMT 製程參數最佳化之分析

洪永祥、鄭淑萍、陳科淳、葉瑾華、林志諭

服務機構；國立勤益技術學院

E-mail：hys502@ncit.edu.tw

摘要

印刷電路板之組裝技術，近年來已由傳統之人工插件之波焊 (Wave Soldering) 作業方式，改為可直接黏著於印刷電路版(Printed Circuit Board；PCB)上的表面黏著技術(Surface Mount Technology；SMT)。表面黏著技術儼然成為現代電子組裝技術的主流由於表面黏著技術生產製程涉入機器、材料、製造環境等多重變因，及其他製程因素如：合適之鋼板開孔形狀及錫膏特性、刮刀的材質、壓力、角度及速度等等，均對錫膏印刷製程有相當重要及直接的影響。本研究，所提出之工程分析折方法，於田口實驗首建立控制因子與品質特性間的實驗數據，再以BPNN建立SMT錫厚差之模擬系統，藉此模擬系統不僅可準確的預測出各實驗因子，在不同水準組合下的錫厚差，還可節省大幅的實驗成本，並此基礎作為GA演算法的模擬工具尋找最佳的錫厚輸出品質，避免材料浪費，並有效降低生產成本也使產品之良率獲得穩定之提升。依據本研究最佳參數水準所預測出之錫厚差值為0.16286，經實驗證明其成果優於田口實驗設計之結果。

關鍵詞：

錫膏印刷、表面黏著組裝技術、田口實驗設計、類神經網路、基因演算法則

1. 前言

由於電子產品近年來已趨向輕、薄、短、小，體積小、功能強，為因應市場所需，唯一的方法只有將電子零件縮小，繼而取代傳統零件發展出SMT，並可直接黏著於PCB上，且PCB為縮小面積也從單層板發展成多層板，所以並無多餘空間和多餘貫穿孔給傳統零件。為將SMD元件附著PCB上，而因應發展出SMT技術。在面對先進的SMT技術時對印刷製程的要求正與日俱增。愈來愈細小的元件接腳距，逐漸增加的元件密度及先進的接腳設計都使得製程控制上難度不斷提昇。因此混合使用先進的材料及印刷技術再加對製程的控制對於提升SMT製程技術是為關鍵的議題之一。

SMT又稱表面封裝技術。是以錫膏為黏著介面，將表面黏著元件 (Surface Mount Device, SMD) 焊在印刷電路板或基板表面的封裝組合技術，是屬於電子裝

配技術中的一種。SMT產品在液晶顯示器（LCM）為主要的半成品之一，其主要功能是在驅動顯示器的相關元件的搭載，其常見基材有軟性印刷電路版（FPC）及一般印刷電路版（PCB），因LCM產品顯示趨勢為多樣化及體積縮小化，因軟性印刷電路版（FPC）較印刷電路版（PCB）輕、薄、具有繞折性，故應用在LCM產品設計上其需求量也為日漸增，但因材質較軟故其印刷錫膏量之穩定性相較於印刷電路版（PCB）差。在表面黏著製程中，由於機器的自動化加上複雜的生產變數，往往一個疏忽即可能造成不良品的產生。根據文獻及工業報告指出，52%~71%的表面黏著技術的瑕疵導因於錫膏印刷製程[12][11]，其中錫膏量被認為是影響SMT印刷製程中最重要品質特性之一[7]。SMT在製造流程上包含了三個基本階段，分別為錫膏印刷、電子元件黏貼及迴焊過程。印刷錫膏量的穩定性之探討就顯的重要，其穩定性越佳則SMT產品的可靠度就越佳，其短斷路之現象就越少品質越佳[8][10]。影響錫膏厚度因素非常複雜，本研究依據生產工程師所提供的參數（A）刮刀材質、（B）刮刀角度、（C）刮刀速度、（D）刮刀壓力、與（E）基板與鋼板間作為實驗的控制因子，並以錫厚的高低落差品質特性衡量產品品質，當錫厚差越小則表時均勻度越佳屬於望小品質特性(Small the Better; SNB)。

2. 文獻探討

穩健設計(Robust Design)乃是一種透過工程最佳化的方式來進行品質改善的方法，可用來改善目前的科技、產品與製程設計，其目標乃在追求穩健性。田口品質工程乃是以工程的角度與成本效益的觀念，在產品或製程設計時就考慮品質問題，藉以提升產品的績效 [6]。參數設計(Parameter Design)是田口品質工程最佳化的方法，由工程人員依據專業知識、經驗與相互討論，決定相關的製程參數，經由直交表(Orthogonal Arrays)設計來執行實驗，使產品對於雜訊因子(Noise Factor)干擾敏感度較低，以減少產品品質變異。藉以取得最佳系統品質特性且對所有內在不确定性或外在雜訊及干擾最不敏感的最佳參數組合，並且能夠得到實驗進行系統參數與品質特性間的關係。類神經網路(Neural Network; NN)是一種計算系統，包括軟體和硬體並使用大量簡單相連的人工神經元(Neuron)來模仿生物神經網路的能力；人工神經元是生物神經元的簡單模擬，它從外界環境或是其他的人工神經元取得資訊，加以簡單的運算，並輸出其計算之結果到外界環境或是其他人工神經元[4]。類神經網路它可以利用一組資料範例，即系統輸入與輸出所組成的資料，建立系統模型（輸入與輸出間的關係）。有了這樣的系統模型便可用於推估、預測、決策、診斷。故已在許多領域被應用於傳統的規則性運算法則或統計方法無法處理的非規則性問題，並獲得相當的成功[3]。NN之功能包括：1) 分類功能 2) 歸納功能 3) 關聯功能 4) 推理功能 5) 預測與最佳化功能。其中預測與最佳化功能乃是利用網路連結形式及權重之變化，其過程依推論過程→學習過程→訓練範例過程→學習演算法過程以求得預測值或是最佳解。基因演算法為一函數最佳化工具，常被用來解決解空間大、以及需要求全域最佳解的問題，是搜尋目標函數極值的一個方法。透過電腦來模擬自然界的演化過程，由一群族群以隨機配對的方式產生下一代，基因演算法雖然是一種雖機的搜尋模式但並非完全盲目進

行，而是根據每一代族群所累積的資訊來對搜尋空間做修正並產生較合理的解。在基因演算法中，用以表示可能的解染色體，是由基因(Gene)所組成。通常各個基因是利用一串二進位的字元(Binary string)來表示，並且經由選擇(Selection)、交配(Crossover)及突變(Mutation)此三種機制來完成演化的過程[1,2,6]。Grefenstette 曾提出如何選擇基因演算法中的族群大小以使控制參數達到最佳化，其實驗結果顯示每個族群10 到160 組染色體為最佳[9]，類似的研究可參考[5]。

3.參數最佳化設計

3.1 直交表數值之建構

於眾多影響錫膏厚度因素中，挑選出最適宜的五個操控因子，作為本研究變數因子。分別為：(A)刮刀材質、(B)刮刀角度、(C)刮刀速度、(D)刮刀壓力、與(E)基板與銅板間，各個變數因子中，自有兩個水準別，相關數據如下表 1 所示。將所取得之錫厚值以倒傳遞類神經網路進行學習，以作為日後進行基因演算法則的一適應值參考依據。

表1、各因素參數水準表

| 實驗因子 | 水準 1 | 水準 2 |
|--|------|------|
| A.刮刀材質 | 鋼 | 橡膠 |
| B.刮刀角度 (°C) | 45 | 60 |
| C.刮刀速度 (rpm) | 5 | 10 |
| D.刮刀壓力(Mpa) | 0.04 | 0.08 |
| E.基板與銅板間隙(μm) | 400 | 800 |
| 實驗產品的品質特性： 錫厚差 = 量測值 - 錫膏厚度基準 (150um) → 望小值 (0) | | |

3.2 標準化轉換數值

由於在轉換到類神經網路學習的過程中，數值的大或小都會影響到各神經元之間的權重值，故需將各個神經元輸入端的數值進行標準化過程，以確保類神經網路經由這些標準化的數值較為精準。將各個數值設定在〔0,1〕之間，其中1表示最大值以確保各個數值能夠座落於其中，以下列標準化公式：

$$factor_level_{(new)} = \frac{factor_level_{(old)} - \min}{\max - \min} \dots\dots\dots (1)$$

標準化過程如下：

因子A的水準1、2為鋼材與塑膠，為非連續變數，故將因子A的水準1“鋼材”編碼為“1,1,1”；水準2“ 塑膠”編碼為“0,0,0”，皆為3個變數項，因此總實驗因子數增加為7個因子。標準化時前3個實驗因子維持不變，後4個實驗因子依公式4.1所示，其上、下界依據工程師所提供機台能力界限如表2，並將因子水準皆轉換成[0~1]

的數值。由於前3因子維持不變，僅顯示後4個因子之標準化數值，其編碼後結果如表3所示。

表 2 標準化之上、下界

| | Min | Max |
|---------------|------|------|
| Factor B | 30 | 75 |
| Factor C(°C) | 1 | 14 |
| Factor D(Mpa) | 0.01 | 0.12 |
| Factor E(μm) | 150 | 1200 |
| 觀測值 | 1 | 70 |

表 3 水準編碼標準化後數值

| Factor | | | | | | | 觀測值 |
|--------|---|---|----------|----------|----------|----------|----------|
| A | | B | C | D | E | | |
| 1 | 1 | 1 | 0.333333 | 0.307692 | 0.272727 | 0.238095 | 1 |
| 1 | 1 | 1 | 0.333333 | 0.692308 | 0.636364 | 0.619048 | 0.826087 |
| 1 | 1 | 1 | 0.666667 | 0.307692 | 0.272727 | 0.619048 | 0.42029 |
| 1 | 1 | 1 | 0.666667 | 0.692308 | 0.636364 | 0.238095 | 0.246377 |
| 0 | 0 | 0 | 0.333333 | 0.307692 | 0.636364 | 0.619048 | 0.057971 |
| 0 | 0 | 0 | 0.333333 | 0.692308 | 0.272727 | 0.238095 | 0.130435 |
| 0 | 0 | 0 | 0.666667 | 0.307692 | 0.636364 | 0.238095 | 0 |
| 0 | 0 | 0 | 0.666667 | 0.692308 | 0.272727 | 0.619048 | 0.130435 |
| 1 | 1 | 1 | 0.333333 | 0.307692 | 0.272727 | 0.238095 | 0.797101 |
| 1 | 1 | 1 | 0.333333 | 0.692308 | 0.636364 | 0.619048 | 0.826087 |
| 1 | 1 | 1 | 0.666667 | 0.307692 | 0.272727 | 0.619048 | 0.637681 |
| 1 | 1 | 1 | 0.666667 | 0.692308 | 0.636364 | 0.238095 | 0.376812 |
| 0 | 0 | 0 | 0.333333 | 0.307692 | 0.636364 | 0.619048 | 0.188406 |
| 0 | 0 | 0 | 0.333333 | 0.692308 | 0.272727 | 0.238095 | 0.028986 |
| 0 | 0 | 0 | 0.666667 | 0.307692 | 0.636364 | 0.238095 | 0.101449 |
| 0 | 0 | 0 | 0.666667 | 0.692308 | 0.272727 | 0.619048 | 0.15942 |

3.3 以 MATLAB 建構倒傳遞類神經網路

在MATLAB 7.0 版本中，所附載的Neural Network Toolbox 4.0，將類神經網

路研究應用的領域完整涵蓋，其中包含各種類神經網路演算法於函數的工具箱，讓使用者在設計與模擬類神經網路模型時更有效率。

在建構完網路結構後，可以看到網路結構的圖形，如圖 1 所示。由圖 1 可知本研究為三個隱藏層的圖形，輸出層的部分只有一個輸出值，此即為所探討的錫膏厚度的網路結構，其中隱藏層的轉移函數類型為 LOGSIG，而輸出層的轉移函數為 PURLIN 非線性轉換函為雙彎曲函數(Sigmoid Function)。

$$f(x) = \frac{1}{1 + e^{-x}} \dots\dots\dots(2)$$

(其中 e 為自然對數)

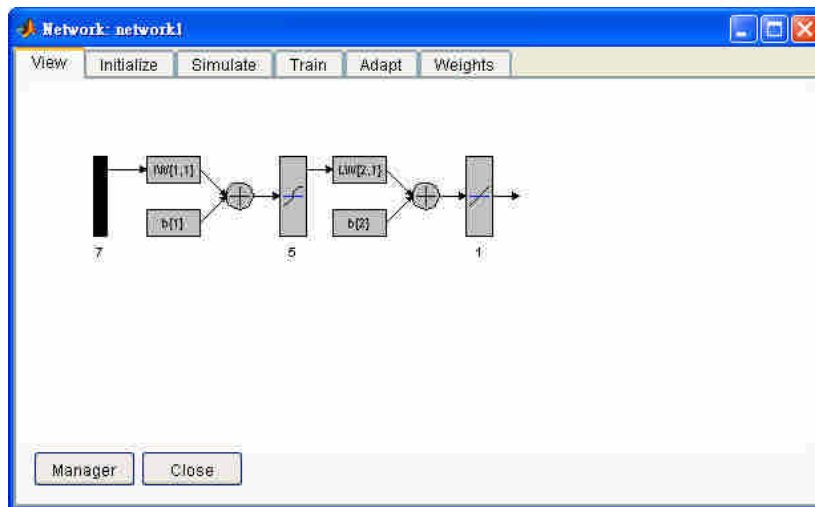


圖 1 BPNN 之網路結構

經過 BPNN 網路訓練參數設定及藉由網路訓練數據的設定檔做為網路學習的來源路徑，即可完成建構類神經網路學習平台，並得到各個數據值，包含：1、輸入層到隱藏層的權重值 2、隱藏層到輸出層的權重值 3、隱藏層的閾值 4、輸出層的閾值等四個主要的數值指標。下圖 2 為類神經網路所學習的指標圖示，本研究之 BPNN 網路訓練結果誤差 MSE=0.0047409，且網路在經過第 6 次的訓練後達到收斂。通常會在數次的網路學習後，取其最佳的數值，及學習指標越接近 0 的時候越是有不錯的表現值。




圖 2 類神經網路學習指標圖

3.4 網路學習的各相關權重

如前所述，本研究網路學習過程中，所採用的結構為一個7-5-1。下一步驟之基因演算法所需使用的適應性函數，是用來決定之一個染色體對於問題所處環境條件的適合程度，即用以衡量每個染色體好壞的判定標準。本研究所設計之適應性函數如公式3所示

$$Y = -.24384 \times 1 / (1 + \exp(-2.3914 \times X_1 + 3.0198 \times X_2 - 2.5722 \times X_3 - 6.2912 \times X_4 - 4.8049 \times X_5 + 12.162 \times X_6 + 2.6943 \times X_7 + 1.7654)) - .9846 / (1 + \exp(3.8918 \times X_1 + .50103 \times X_2 + 3.4608 \times X_3 + 5.0498 \times X_4 - 3.0402 \times X_5 - 11.47 \times X_6 + 9.3186 \times X_7 - 5.1018)) - .1268e-1 / (1 + \exp(1.6575 \times X_1 - 2.3986 \times X_2 + 3.9452 \times X_3 + .91872 \times X_4 + 7.2118 \times X_5 + 9.2132 \times X_6 + 2.3736 \times X_7 - 14.661)) - .9577 / (1 + \exp(3.97 \times X_1 - 4.297 \times X_2 + .85042 \times X_3 - 6.3336 \times X_4 + 7.4994 \times X_5 + 3.4146 \times X_6 - 1.86 \times X_7 + 1.871)) - .6594e-1 / (1 + \exp(-.61262 \times X_1 - 2.9891 \times X_2 - .503e-3 \times X_3 - 10.159 \times X_4 + 5.6534 \times X_5 + 8.9405 \times X_6 - 7.0918 \times X_7 + .9243e-1)) + 1.1966 \dots \dots \dots (3)$$

3.4 最佳製程參數搜尋

基因演算法為一函數最佳化工具，常被用來解決解空間大、以及需要求全域最佳解的問題。透過電腦來模擬自然界的演化過程，由一群族群以隨機配對的方式產生下一代，基因演算法雖然是一種雖機的搜尋模式但並非完全盲目進行，而是根據每一代族群所累積的資訊來對搜尋空間做修正並產生較合理的解。在基因演算法中，用以表示可能的解染色體，是由基因(Gene)所組成。通常各個基因是利用一串二進位的字元(Binary string)來表示，並且經由選擇(Selection)、交配(Crossover)及突變(Mutation)此三種機制來完成演化的過程。

本研究採用 100 組染色體，複製的方法使用較常見的輪盤法(Roulette Wheel method)，其根據族群裡每個染色體適應度所佔的百分比，來決定其被挑選的機率，交配選用有雙點交配(Two-point crossover)法，在所選出的兩字串中，隨機的選取兩

個交配點，並交換兩個字串中兩個交配點間的所有字元。一般而言，交配率的高低會影響母代能否繼續生存於下一世代的機率。交配率愈高，母代會被強迫以子代取代。交配率愈低，則產生子代的比率則會較低。交配率設定為0.01，突變率為0.75。

本研究主要目的為建構一具穩健特性的SMT製程參數數值設計平台，藉由類神經網路與基因演算法的應用去建構一完整的穩健品質的實驗模式，找出最適參數數值，並可做為日後準則性的建議數值。將取得之田口實驗數據做進一步分析，用類神經網路建構系統模型，並使用基因演算法作為最佳化演算工具，逐步找出最佳參數值。本實驗模擬結果如表4所示：

表4 模擬預測結果

| Factor \ Level | GA 最佳化 | 工程實務上 |
|----------------|-----------|----------|
| A | 0.19615 | 0 |
| | 0.97754 | 0 |
| | 0.57751 | 0 |
| B | 0.7048 | 0.7048 |
| C | 0.44564 | 0.44564 |
| D | 0.94582 | 0.94582 |
| E | 0.012837 | 0.012837 |
| 觀測值 | 0.0078556 | 0.16286 |

由上表4可知，基因演算法所預測出實驗因子A.(刮刀材質)最佳數值為0.19615、0.97754、0.57751。但實驗因子A為類別水準，實務上只有“0,0,0”或“1,1,1”，研究分別以Type I “0,0,0”及Type II “1,1,1” 作為實際參數設計的輸入，重新進行模擬，所得結果分別為0.16286與3.2770如表5.1所示。根據田口實驗數據，其第四次與第六次的觀測值分別為1跟8，我們取此兩次之值與本組調整後數據作比較，其結果如表5所示：

表5 調整後最佳參數值之比較

| Factor \ Level | GA | | 田口實驗 |
|----------------|---------|---------|------|
| | 調整後最佳參數 | | |
| | Type I | Type II | |
| A | 0 | 1 | 0 |
| | 0 | 1 | 0 |
| | 0 | 1 | 0 |
| B | 61.716 | 61.716 | 60 |
| C | 6.7933 | 6.7933 | 5 |
| D | 0.11404 | 0.11404 | 0.08 |
| E | 163.48 | 163.48 | 400 |

| | | | |
|----------|---------|--------|-------|
| 模擬錫厚差預測值 | 0.16286 | 3.2770 | Max=8 |
| | | | Min=1 |

根據GA參數Type I 及Type II 模擬結果，本研究所預測出之錫厚差值分為0.16286及3.2770，在望小品質特性目標下，我們選擇Type I 的0.16286這組最佳參數值來與田口實驗作比較，其結果優於田口之實驗設計之錫厚差值。

本研究，所提出之工程分析方法，最重要的步驟是先以BPNN建立SMT錫厚差之模擬系統，藉此模擬系統，不僅可準確的預測出各實驗因子，在不同水準組合下的錫厚差，還可節省大幅的實驗成本。並此基礎作為GA演算法的模擬工具尋找最佳的錫厚輸出品質。

4.結論

一般類神經網路在模擬或學習數值上，常以最原始收集或實驗的方式取得數據，再將之建構網路型態。但本研究是直接延續所取得之田口實驗配置結果，作為建構倒傳遞神經之資料，少了繁瑣的實驗實作與節省了成本。反之，因為為延續之測驗，故田口實驗部分所取得之參數數據輸出值，也許易受於各種環境因素之影響，諸如：當時之風量、氣溫溫度、空氣溼度等等特性，因而可能會影響實驗結果之輸出值，進而影響本次研究之分析結果。

本研究利用類神經來改善來SMT製程錫厚度問題，在驗證中可明顯得知利用類神經網路及基因演算法所得到的結果，比田口實驗設計來得穩定，證實了類神經網路此手法較優於田口方法。

做此研究時，對基因演算法及MATLAB軟體的運用尚未很熟悉，所以尚有進步的空間，且因受時間及篇幅限制，僅對取得之田口資料做分析，做出之結果也未做實務上之測試及驗證，故未來可作進一步的探討，以證實利用類神經網路監控製程的可行性。

參考文獻

- 1.周鵬程，遺傳演算法原理與應用－活用 Matlab，全華書局。
- 2.張啟仲，「利用基因演算法改善自動網格切割」，國立中山大學電機工程學系碩士論文，(2003)。
- 3.張斐章、張麗秋、黃浩倫，類神經網路理論與實務，東華書局，(2003)。
- 4.葉怡成，類神經網路模式應用與實作，儒林圖書公司，(1993)。
- 5.簡士期，「族群數可變型基因法則之探討」，交通大學控制工程研究所碩士論文，(1996)。

- 6.蘇朝敦，「品質工程」，中華民國品質學會，(2002)。
- 7.Burr, D., “Solder paste inspection: process control for defect reduction,” *Proceedings of International Test Conference*, pp. 1036 ,(1997).
8. Danielsson, H., *Surface Mount Technology with Fine Pitch Components*, Chapman & Hall, New York, (1995).
- 9.J. J. Grefenstrtte, “Optimization of control parameters for geneticalgorithms,” *IEEE Trans. System, Man, Cybern.*, 16(1), 122-128, (1986).
10. Lau, J. H., “Handbook of Fine Pitch Surface Mount Technology,” Van No strand Reinhold, Chapter 1, New York, (1994).
11. Pan, J., G. L. Tonkay, R. H. Storer, R. M. Sallade and D. J. Leandri, “Critical variables of solder paste stencil printing for micro-BGA and fine pitch QFP, ” *Proceedings of IEEE/CPMT International Electronics Manufacturing Technology Symposium*, pp. 94-101, (1999).
- 12.Richard, S. C., “The complete solder paste printing processes,” *Surface Mount Technology*, Vol. 13, No. 1, pp. 6-8, (1999).