

# 基於類神經網路之太陽光電系統模型建置研究

<sup>1</sup> 蔡孟伸

<sup>1</sup> 台北科技大學自動化科技研究所 教授  
[mstsai@ntut.edu.tw](mailto:mstsai@ntut.edu.tw)

<sup>2</sup> 許毅冠

<sup>2</sup> 台北科技大學自動化科技研究所 碩士研究生  
[summit712@gmail.com](mailto:summit712@gmail.com)

## 摘要

太陽能光電系統為一般陽光充足地區最普遍也是最常用的綠色能源系統，對於其模擬建構而言，若以電力電子原理技術角度建立模型，不僅僅需要模擬太陽能光電轉換板的物理特性，也需考量到後端太陽能逆變器功能及其中擁有的最大功率追蹤演算法，需要輸入在模擬軟體(如：PSIM)元件不在少數，其複雜度也相對較高，且影響其系統能源輸出的參數亦多，要完整實現是相當困難的；本文將以倒傳遞類神經網路為其演算法，藉由 MATLAB 軟體，經過調變輸入訓練參數種類及擴大訓練資料量來訓練類神經模型，並計算 MSEs 和 RMSEs 評估倒傳遞類神經網路是否真的能模擬並聯型太陽能發電系統真實的能量輸出。

**關鍵詞：**太陽能系統，最大功率追蹤，倒傳遞類神經。

## Abstract

The photovoltaic system is most popular green energy in sunny area. But for simulation, if we want to simulate it base on power electronic theory, there too many elements and factors need to be included.

So we try to use the neural network for build photovoltaic system model by MATLAB. We will change different types and different amount of data on model input side for train neural network, finally we will calculate MSEs and RMSEs between neural network output and real measured power value.

**Keywords:** Photovoltaic 、 MPPT 、 Back-propagation Neural Network 。

## 1. 前言

隨著工業、科技的蓬勃發展，使得能源的

需求越來越大，隨著石油危機後，能量的來源議題漸漸的被熱烈討論；所以尋找替代性、可再生性的能源變成炙手可熱的研究方向，其中以太陽能光電系統被安裝的普及度與市場接受度為最高，其投資金額也為最大(圖 1)[3]，但影響太陽能系統輸出發電量的參數為有溫度、日照量、雲量、經緯度……等等，也因為影響太陽能系統輸出的參數眾多，若再考量到後端能量轉換設備(power converter)應用不同，而衍生的模型又更多。

在電力電子領域的模擬，並聯型太陽能光電系統的模擬需要非常多的元件與複雜的計算，為了簡化模擬的複雜度，本文採用倒傳遞類神經演算法來模擬併聯型太陽能系統一日的發電功率，在不同的時間點不同的日照量，系統追隨各個影響變因而改變最後的輸出計算值，達到準確模擬之效果。

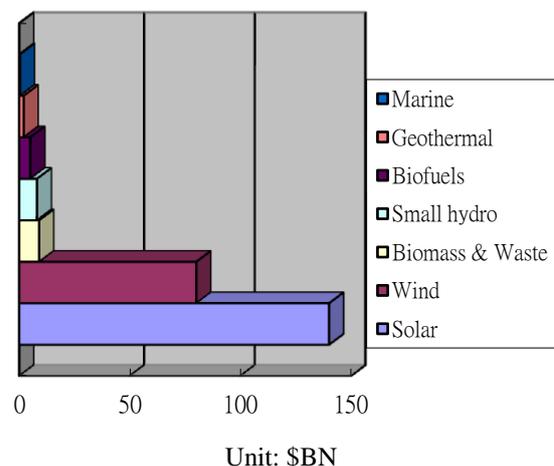


圖 1. 全球再生能源投資金額(2012 年)

因為其影響太陽能光電系統輸出功率大小的參數眾多，所以要比較並收斂影響類神經系統的輸入參數與選定其地區性做為指標，對於系統模擬而言可以達到較好的結果，可做為初期的併聯型太陽能系統架設之經濟效益的評估有相當大的幫助。

多數已經提出報告皆討論各項參數融入類神經網路模擬併聯型太陽能系統，經過調整權

重後求其準確的輸出計算值表現，企圖使用類神經網路訓練出單一模型，完整地呈現出並聯型太陽能發電系統各個特性，但由於季節、天候、地區性的原因，使其無法以單一類神經模型可以完整的呈現出太陽能系統，所以選擇性地讓其類神經模型因為輸入參數的不同選擇不同的類神經模型，便可以輕易得到準確的輸出功率計算值。

## 2. 並聯型太陽能發電系統

一般並聯型太陽能發電系統其包含的元件有太陽能光電轉換板與太陽能逆變器，其系統大致架構圖如圖 2 所示。

所有元件，最容易受到外在因素影響系統輸出能量大小的元件非太陽能光電轉換板莫屬。從太陽能板官方規格數據中，由圖 3 可以得知太陽能板對於不同日照量，其轉換輸出功率和日照量是成正比；再觀察圖 4 可以得知太陽能板輸出電壓對於溫度是成反比，簡而言之在額定範圍內，越高的日照量將產生越大的能量，越高的操作溫度其輸出能量反而將低。

太陽能逆變器是由電力電子技術所構置而成的能源轉換器，可以將太陽能光電轉換板的直流電源轉換符合交流市電(grid)的能源轉換，並使輸出交流電源追隨市電震幅與頻率的改變，另輸入端也針對太陽能光電轉換板做最大功率點之追蹤；因為逆變器是大多是由半導體元件來構成，所以在高溫環境下必須做 de-rating 操作，來確保設備穩定輸出，逆變器在 de-rating 操作中溫度與功率輸出關係圖如圖 5 表示。

一般逆變器需要操作在戶外環境，所以設計其防水防塵的等級大多在 IP65，當環境溫度上升或是操作功率較大時，就需要倚靠設備後方大型散熱鰭片(如圖 6)來釋放多餘的熱能，故散熱鰭片的溫度也是評估逆變器是否操作在 de-rating 的量測點。

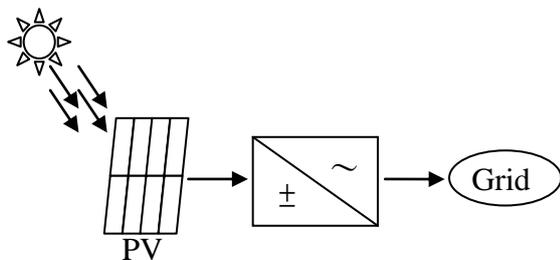


圖 2. 並聯型太陽能發電系統示意圖

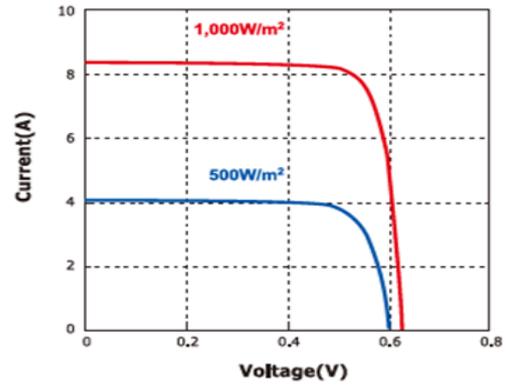


圖 3. 太陽能板曲線-日照量與電壓/流

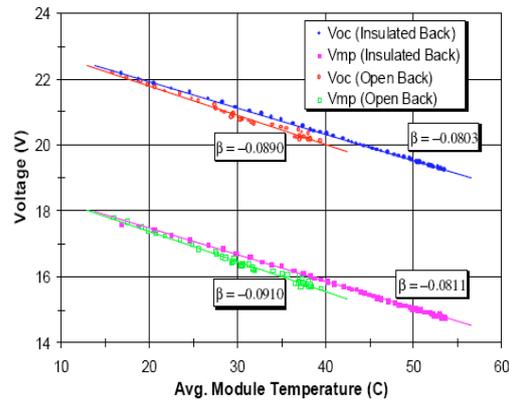


圖 4. 太陽能板曲線 - 溫度與電壓

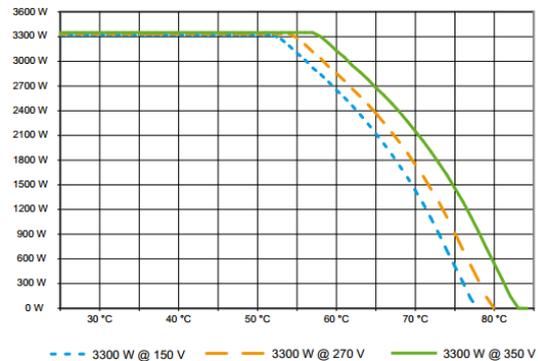


圖 5. 太陽能逆變器與溫度關係表

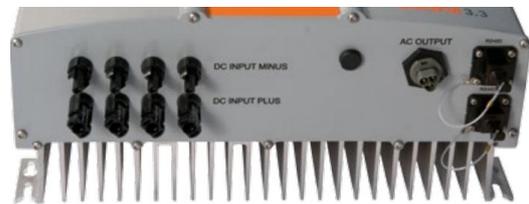


圖 6. 太陽能逆變器之散熱鰭片

## 3. 倒傳遞類神經網路

類神經網路是模仿生物神經網路所發展出來的演算法，其研究可溯至 1940 年代 Warren McCulloch 和 Walter Pitts 的主張[4]，他們從原理上證明了類神經網路可以計算任何數學上

或邏輯上的函數功能，所以對一般用於簡化非線性及複雜模型之設計有很大的幫助。

本實驗使用倒傳遞類神經網路 (Back-Propagation Neural Network, BPNN) 是屬於監督式學習網路 (Supervised Learning Network) 的一種，即在網路學習過程中以使能量函數最小化來監督網路加權值的調整，所形成的網路結構能將已知的輸入值，轉換成為接近實際輸出值的推論輸出值，且準確性為最高的。因此 BPNN 非常適用於診斷、預測等問題的應用上，且它也是目前類神經網路學習模式中最具代表性且應用最普遍的模式。

本論文的研究方法便是建構在 BPNN 上來進行併聯型太陽能系統 (太陽能光電轉換板與太陽能逆變器) 的模擬，針對倒傳遞類神經訓練輸入參數的種類與訓練輸入參數的數量進行評估，試圖找出最少的資料種類與最恰當的訓練資料量讓類神經模型可以充分訓練，準確地計算輸出功率值。

以神經元基本應用，皆是多輸入端神經元，以下介紹為多輸入端神經元模型 (如圖 7)。

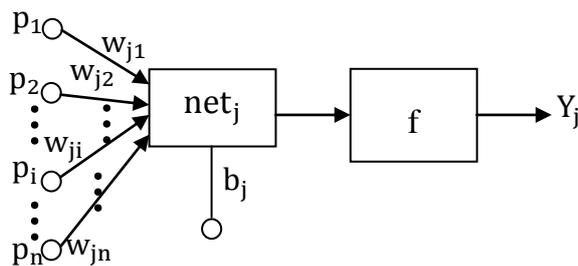


圖 7. 神經元示意圖

$p_i$  : 輸入向量各個分量。

$w_{ji}$  : 神經元的各個權重值。

$b_j$  : 偏置。

$f$  : 傳遞函數，通常為非線性函數。

$Y_j$  : 神經元輸出。

$net_j$  : 輸入向量與權重乘積。

右上圖 (圖 8) 介紹本實驗之類神經網路大致上分為三層：輸入層 (input layer)、隱藏層 (hidden layer)、輸出層 (output layer)，利用 MATLAB 軟體 [1,2] 之 nntool 輸入層中輸入所需之資料，讓其訓練後計算其輸出層資料。

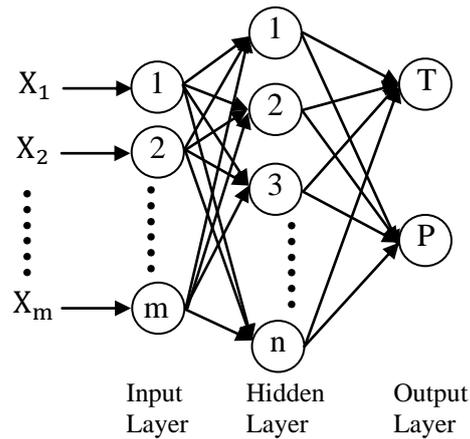


圖 8. 類神經網路示意圖

#### 4. 模擬實驗

如參考文獻 [7] 中，類神經模型訓練需要較多的資料量，且擁有風速當做訓練參數之一，但是以太陽能系統中風速對於系統較無直接影響，故本模擬將呈現出訓練資料種類較少及訓練資料量較少，試歸類出最適合訓練類神經模型的輸入參數，與最少之資料量定義。

從太陽能系統設置案廠中記錄的數據擁有時間、內部溫度 ( $^{\circ}\text{C}$ )、散熱片溫度 ( $^{\circ}\text{C}$ )、外接溫度 ( $^{\circ}\text{C}$ )、日照量  $I_{rr}$  ( $\text{W}/\text{m}^2$ )，輸出功率 ( $\text{W}$ )，共六種數據；將其前五種數據視為類神經網路的輸入參數 (training data)，時間與功率 ( $\text{W}$ ) 為目標參數 (target data) 用以訓練類神經網路，其中改變輸入參數之種類與不同輸入天數的資料量，觀察出何種搭配下對於類神經網路的輸出值與實際值其誤差量最小。

在資料庫中記錄者五種數據：時間、日照量、外接溫度、散熱片溫度、內部溫度，以下說明各參數定義：

- I. 時間：紀錄太陽能系統運轉時間，紀錄時間起迄為 AM 05:00~ PM 07:30。
- II. 日照量：記錄在時間區間內之日照量強度。
- III. 外接溫度：係指記錄在太陽能模組在工作中的溫度。
- IV. 散熱片溫度：係指太陽能逆變器後方散熱片溫度。
- V. 內部溫度：係指太陽能逆變器中之溫度。

原始資料每日記錄 14.5 個小時，以每 30 秒做為資料取樣頻率，後處理將每一種參數各求 5 分鐘之平均值，總計一日資料量記錄筆數為 174 筆。

模擬實驗分成兩大部分：

1. 利用一日(20130306)之資料量來訓練倒傳遞類神經的模型，並以另一日(20130326)做為測試的目標，並將原輸入訓練資料由五組資料量依序遞減至二組，檢視比對哪一個排列組合對於(20130326)資料測試後其倒傳遞類神經輸出值與實際輸出值誤差度最低？
2. 延續使用實驗一之結果，確認訓練參數種類為兩種，原實驗一使用訓練資料只有一天(174 筆)資料，將輸入訓練資料天數增加，依序測試藉由多少天數資料輸入做為訓練，測試資料與實驗一使用相同一天(20130326)之數值，比較由多少天數模擬輸出能量與實際測量值其中間誤差量較低？

本模擬數據在輸入倒傳遞類神經模型前，皆透過正規化(normalization)之前處理，本模擬之正規化係將資料庫中每種數值中個別取出極大值來假設為 1、極小值假設為 0，後再將其輸入至倒傳遞類神經網路做訓練及測試，比較類神經運算輸出值與實際量測值之誤差值。

模擬實驗之準確度將以誤差值大小來判斷，誤差值須先計算出平均誤差平方 MSEs(mean square errors)(4.1)後求得平均誤差平方根 RMSE(root mean square errors)(4.2)來做比較，其計算值越小，表示類神經網路計算值與系統實際量測值中越接近，準確度越高，也代表倒傳遞類神經網路可以準確地建置出並聯型太陽能發電系統模型。

$$MSEs = \frac{\sum_{j=1}^k (Y_j - Y'_j)^2}{k} \quad (4.1)$$

Y：並聯型太陽能發電系統實際量測值

Y'：倒傳遞類神經網路模擬計算值

$$RMSEs = \sqrt{MSEs} \quad (4.2)$$

實驗一：輸入參數種類與輸出計算值準確度模擬

利用同一天(20130306)的資料，將之分成訓練資料(時間、內部溫度、散熱片溫度、外接溫度、日照量)以及目標資料(時間、功率)，放進倒傳遞類神經網路訓練後測試。

此實驗分為四種，改變類神經網路的輸入參數，依序訓練的參數種類如(表 2)所示，觀察訓練參數多寡是否會影響類神經的輸出

準確度，也檢視各項參數影響輸出準確度之程度。

表 2. 訓練參數種類數量明細

訓練參數種類數量	項目名稱				
	時間	日照量	外接溫度	散熱片溫度	內部溫度
5 種	時間	日照量	外接溫度	散熱片溫度	內部溫度
4 種	時間	日照量	外接溫度	散熱片溫度	
3 種	時間	日照量	外接溫度		
2 種	時間	日照量			

實驗一結果如表 3 所示：

表 3 顯示，在輸入 5 種參數時其輸出計算值並非最佳；最佳的輸出在輸入 4 種訓練參數的模型，但是比較各種不同輸入情況，在輸入為 2 種的模型，準確度沒有比輸入 4 種的模型落差太多，故延用輸入參數 2 種的模型來實做實驗二輸入訓練資料量對輸出計算值準確度的模擬實驗。

表 3. 訓練參數種類數量與輸出能量之誤差比較表

訓練參數種類數量	RMSEs
5 種	4.32E-03
4 種	2.41E-03
3 種	2.69E-03
2 種	2.75E-03

實驗二：輸入訓練資料量對輸出計算值準確度的模擬

沿用實驗一之結論，輸入參數為 2 種參數為第一考量並擴大輸入類神經之資料量，由 1~5 天做測試，檢視各個不同天數資料量對於類神經網路的輸出計算值之誤差度變化，將實驗結果記錄於表 4。

表 4 訓練天數誤差列表

訓練天數	RMSEs
1 天	2.41E-02
2 天	1.74E-02

3 天	1.01E-02
4 天	9.75E-03
5 天	9.82E-03

表 4 顯示在越多天數的資料量輸入，可以減少類神經網路輸出計算值的誤差量；但檢視 4 天與 5 天之 RMSEs，其誤差量差異並不大，在短期資料訓練類神經模型的前提下可以使用 4 天的資料量做為訓練，可以得到相當準確的輸出計算值。

下方圖示說明倒傳遞類神經網路在輸入訓練資料量分別為 1 天與 5 天的情況，不同模型對於輸出計算值與實際量測值間的誤差量。

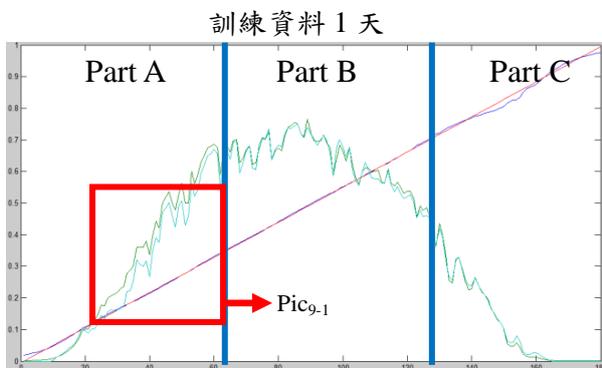


圖 9. 神經網路輸出與實際值  
(訓練資料量 1 天)

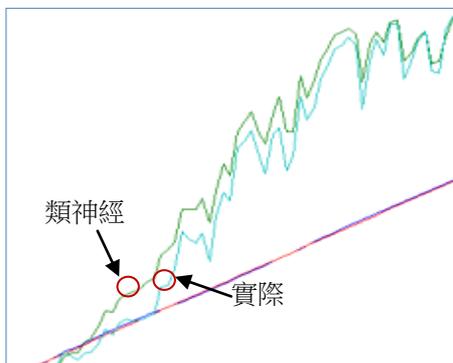


圖 10. 類神經網路局部放大圖(Pic<sub>9,1</sub>)  
(訓練資料量 1 天)

圖 10 中上方綠線代表類神經網路經過訓練後的計算值，下方藍線則代表為太陽能系統實際量測值；由圖 10 觀察出網路在圖 9 中 part A 部分計算值與實際量測值誤差較大，但其趨勢還是相似的。

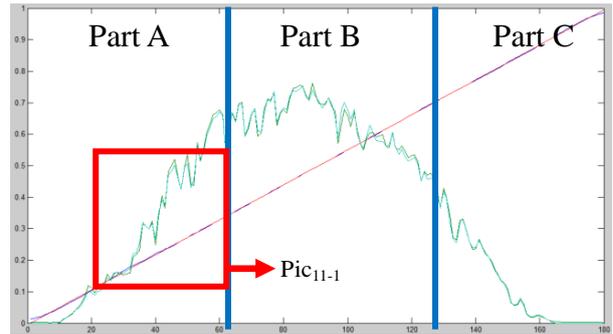


圖 11 神經網路輸出與實際值  
(訓練資料量 5 天)

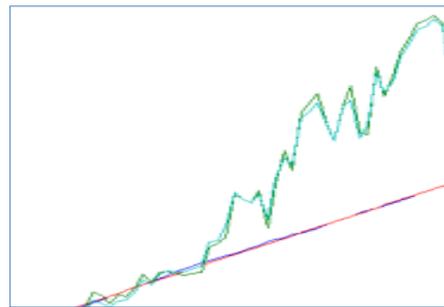


圖 12. 類神經網路局部放大圖(Pic<sub>11,1</sub>)  
(訓練資料量 5 天)

由圖 12 放大圖來觀察，類神經網路經過較大(5 天)的資料做為訓練後，確實將原圖 9 part A 調整為圖 11 part A，由圖顯示這部分透過大量資料訓練後類神經網路可以計算出更準確的輸出。

## 5. 結論

本模擬實驗得知倒傳遞類神經網路表現出整個並聯型太陽能發電系統的模型特色。在這樣的系統你並不需要得直有關太陽能光電板及太陽能逆變器的資訊，只僅僅需要收集相關天氣資訊及其系統的輸出能量，便可以透過訓練將倒傳遞類神經訓練成其模型。

由上述模擬得知，倒傳遞類神經可以藉由相關參數輸入做訓練，進而模擬併聯型太陽能發電系統，在特定天候的假設前提下，可以得到相當準確的模擬。進而討論輸入參數種類多寡與輸入資料量天數的搭配，可以讓倒傳遞類神經獲得更佳的表现。

由模擬結果得知藉由一些簡易的參數輸入，再擴大輸入資料量來做訓練，便可以得到相當準確的結果，以本實驗數據而言，可以大膽假設短期倒傳遞類神經模型模擬併聯型太陽能系統，在這樣的天氣型態下只需要時間、溫度、日照量在 4 天的訓練量，可以得到很好的表現。

再者本模擬實驗之倒傳遞類神經模型只選擇一種品牌組合的並聯型太陽能發電系統，對於其他種組合由於資料來源不足尚無法確認是否各個組合是否可以由同一種類神經模型試用之，或是需要重新訓練類神經之模型。在其太陽能光電板中的模型也可以和文件[5,6]做比較，確認類神經網路訓練後之特性與實際上差異。

### 參考文獻

- [1] 葉怡成，應用類神經網路，儒林圖書有限公司，1999 年 4 月。
- [2] 葉怡成，類神經網路模式應用與實作，儒林圖書有限公司，2001 年 4 月。
- [3] Renewables 2013 Global Status Report  
<http://fs-unep-centre.org/publications/global-trends-renewable-energy-investment-2013>.
- [4] Martin T.Hagan, Howard B.Demuth, Mark Beale, "Neural Network Design," THOMSON, 1996.
- [5] King D, Boyson W, Kratochvil J, "Photovoltaic Array Performance Model". SAND2004-3535. Sandia National Laboratories 2004.
- [6] De Soto W, Klein S, Beckman W, "Improvement and validation of a model for photovoltaic array performance". Solar Energy, vol. 80, pp. 78-88, Jan. 2006.
- [7] Daniel M. Riley, Ganesh K. Venayagamoorthy, "Characterization and Modeling of a Grid-Connected Photovoltaic System Using a Recurrent Neural Network," IEEE Proceedings of International Joint Conference on Neural Networks, 2011.