

自適應性類神經模糊推論系統於客製化生產環境之預測應用

王文派

國立勤益科技大學工業工程與管理系
教授
wangwp@ncut.edu.tw

邱俊智

國立勤益科技大學工業工程與管理系
研究生
s49815024@student.ncut.edu.tw

摘要

由於全球化市場競爭激烈、資訊科技蓬勃發展、產品生命週期縮短，客製化已成為生產系統中的主流，導致顧客需求的不確定與多變性驟增，造成廠商無法應用傳統預測模式來進行準確的顧客需求預測。本文提出以自適應性類神經模糊推論系統為基礎之預測模式，自動對新的組合變數之隸屬度函數作適當的調整與修正，並找出真正的模糊規則庫。即利用類神經網路的學習功能，導入環境變數，成為類神經網路的輸入變項，歸納出模糊規則與歸屬函數，使模糊決策規則庫能適應環境變遷而調整。以類神經模糊系統執行資料分析，預測需求之項目與數量的發生可能性，進而以此資訊為基礎，管理者可擬訂合適的生產作業管理相關規劃與排程活動。並藉由實際案例與倒傳遞類神經網路及傳統的迴歸分析模式做比較，結果顯示本文所提方法具較佳之預測準確度。
關鍵詞：預測、客製化、類神經模糊系統、倒傳遞類神經網路、迴歸分析。

Abstract

Because of the drastic globalization, rapid development in IT and shortening product life cycle customization has neatly turned into the mainstream of production management. It leads to considerable increases in product diversity and demand uncertainty that incur incorrect outcomes in applying traditional forecasting techniques. This paper therefore proposes a forecast mechanism based on adaptive neuro-fuzzy inference system (ANFIS) to solve the problem of predicting demands under customization environments. The inference ability of fuzzy theory and learning capability of neural network

are capable of properly adjusting new combinations of fuzzy rules and membership function automatically via ANFIS. It enables fuzzy rule base an adaptation of environment changes, and provides dependable forecasts for managers to determine suitable plans and scheduling activities. Especially we compare results with the traditional regression analysis and back-propagation algorithm, and obtain preferable forecasts.

Keywords: Forecasting, customization, neuro-fuzzy, back-propagation, regression analysis.

1. 緒論

在現今全球化經營環境中，由於市場競爭激烈，產品變化快速且生命週期短，客製化遂成為顧客訂單需求之趨勢。製造商為了迎合產品的時效性以及避免資金的積壓及滿足顧客需求多樣性，大多採接單後製造(Make-to-order; MTO)或接單後組裝(Assemble-to-order; ATO)為主要生產的模式。製造商使用此兩種生產模式，除了追求交期的縮短及產品品質提升外，尚須加強對於訂單的應變能力，因此如何強化訂單預測之準確性就成為管理人員重要的課題之一。

預測活動可謂為企業營運之首，好的需求預測，不但能讓管理決策者能對未來的需求動燭先機，也可使後續的生產規劃更為順暢，如此，不但能降低營運成本及風險，更可以提升服務水準；反之，則會造成生產線停工或是在製品(work in process)過多的情形，並積壓資金的使用，因此，建構準確性較高的需求預測模式，是生產規劃成功與否之關鍵。基於現今市場訂單需求不穩定之現象，傳統預測模式所得之數量與實際需求容易出現較大落差，對於製造商擬定後續的產能規劃，備料安排及交期的

掌控，皆造成極大的困擾與錯誤。

王在欣[1]指出，當企業面對下游之市場需求不確定時，最普遍的作法，便是利用銷售歷史紀錄來預測未來可能之銷售量，再運用「預測性生產」的方式來進行產品之製造及配送，如此可使企業享有製造與配送之規模經濟，並縮短顧客之等待時間，在需求產生時可立即供應產品。然而時至今日，面對客製化需求所造成產品種類激增的情況，除產品複雜度的提高意味著更高之製造成本，以及因產品種類繁雜、管理不易而造成供應鏈作業效率低落外，多種不同版本產品的需求預測，對企業而言更是一場夢魘，而預測性生產應用在如電腦及其週邊等高科技產品時，所造成之誤差亦往往在百分之四百以上。由此可見，傳統的預測模式已無法因應需求不確定的銷售預測活動。

眾多學者所探究之需求預測方法不外乎有定性分析、時間序列分析、指數平滑法、迴歸分析、人工智慧等方式，希望藉由歷史訂單需求的資訊來建構所需的預測模式，比較其中較佳的方法，以提供製造商獲取較準確的預測資訊，降低預測誤差，成為後續產能規劃可靠的依據，以降低不必要的成本及損失。然而，在接單式生產系統中，需求預測的準確性攸關生產規劃是否完善之關鍵所在。洪國智[8]認為「需求預測」是業界視為關鍵的一個訊息指標，合理可靠的預測，可以提早知道訂單的需求數量，並成為企業有效掌控企業資源的工具。周湘蘭[5]亦認為較佳的預測模式可給予企業信賴及遵循的依據，不但能整合需求及供給之資訊，進一步可減少庫存及延遲成本，以追求企業的利潤最大。因此，如何有效的運用歷史訂單需求資訊進行預測活動，增加預測產量之準確性，可讓後續之產能及排程規劃更加穩健可靠，亦可減少庫存成本與延遲交貨之損失，並提高企業之獲利能力，著實成為管理人員所關注的焦點。

近來，資訊科技日新月異，歷史資料能否有效地蒐集、分析，並從中去蕪存菁，擷取有用或適用的訊息加以應用，遂成為優良決策的關鍵所在。隨著人工智慧方法之興起，使得這些資料能有效運用的空間變大，而如何從大量資料中萃取過濾，將有效的資訊為己所用，便成為現今重要的研究方向。在眾多人工智慧技術當中，應用類神經網路、模糊結合類神經網路等方法在生產預測上，亦有許多成功之研究。

從文獻中可知[2]，結合模糊邏輯明確表示

技術知識的能力與類神經網路的學習能力，能進行學習調整，且可執行語義推論，以具可讀性的語言規則陳述探勘所得之知識。對提升資料探勘與分析，及預測技術確實有其優勢能力。Sugeno[21][22]所提出之模糊模型特色，是可以由輸入輸出的範例中，有系統的產生 if-then 的前提及推論，而 Sungeno 可以由類神經網路架構來替代，此類神經網路架構則稱為「自適應性網路模糊推論系統」(Adaptive Network-Based Fuzzy Inferenc System; ANFIS)，而使用 ANFIS 的好處是可以利用類神經網路學習演算法，來幫助我們決定 Sungeno 模糊規則之前提及推論的參數；也就是讓 Sugeno 模糊模型具有自我學習的能力，自行調整出最佳的模糊規則。因此本研究之主要目的在於藉由 ANFIS，對已知的訂單資料進行分析與探勘，利用歷史訂單資料經由 ANFIS 學習機制，訂出資料的關聯規則，並且依此建構出所需的預測模式，以期能準確的預測出下期的需求數量，以便生產系統得以提前進行必要之原物料準備作業及後續的產能與排程規劃，使需求不確定性對生產系統的影響降至最低。模式建置後，將之應用於製造業的實際訂單資料予以測試，利用類神經網路進行學習，再以專家意見修改模糊規則，驗證模式的可行性，並與倒傳遞類神經網路以及傳統的迴歸分析模式進行預測準確性之比較。

2. 文獻探討

分別就傳統之銷售預測方法及人工智慧預測方法兩方面著手探討與本研究相關的文獻。

2.1 傳統銷售預測方法

所謂預測是利用歷史資料為基礎，透過分析真實情況的變化，以了解變化的原因及其影響狀態，藉由模式的建立預估和推論未來或未知的情況。由於競爭市場的特性，企業必須盡可能的壓低成本以提升競爭力，為此，企業紛紛開始利用銷售預測技術獲得產品可能之銷售量，事先規劃生產排程與庫存量以減少生產成本與提高生產的穩定性和服務水準。為因應現實中各種情形，預測方法十分多樣化。以下為常用預測方法的概述[6]。

◆ 統計方法：

一般產業大多以統計作為其預測方法。在進行統計預測時，通常是將歷史資料繪製成圖，以觀察判斷數列的歷史走勢，並將其分類。此

外，歷史數據可能受到不正常因素的干擾，因此必須先去除某些差異非常大的資料，或應用其他方法來將資料作修整處理，以增加原始數據的可用性及可靠度。如果歷史資料呈現函數型態，如水平型態、線型趨勢、二次或三次型式，可利用迴歸分析等方法來預測。而時間數列及其相關的統計方法，如指數平滑法、傅立葉序列分析、ARIMA 等，以其系統化的特質，找出理想之預測值。不同研究對象，各有其合適之方法與模型。另外，結合數種統計方法而成的整合性預測模式，也提供了另一優良的模式以解決實際資料之預測。

◆ 定性分析

現實生活中，影響預測的因素不只定量因素，還包含定性的因素。而此法通常使用判斷和評等技巧，將定性資料轉換為定量的估計，以便進行預測。此法的要點為，在估記的過程中保持邏輯、不偏差，以對所有的情報客觀的判斷。此一類的預測方法，諸如行銷研究、小組意見法、想像預測法、德爾菲法與市場調查等，主要是匯集專家或客戶群的意見，經由人為的蒐集、觀察與分析，來探討問題的經濟面行為。

◆ 因果預測法

將一序列和其它序列之間的關係模式化，來預測未來。例如傢俱銷售之預測，可以根據經濟指標：如新婚住宅、個人所得、新婚數目，和新屋主數目等之間的關係。這些外部變數稱為獨立變數，而家俱銷售變數稱為應變數。一般而言，因果模式需經過連續的修正，找出相關變數，以使系統變為可用。

◆ 時間序列分析法

以時間先後為分類基準的統計數列，其有兩個變數：自變數為時間，應變數為各時點所對應的數量或數值。就意義而言，時間序列的資料並不符合迴歸分析的基本假設條件，因時間序列的資料並非隨機抽取，而且在每一個時點只能出現一種數值，故不符合迴歸分析之條件，但其觀念大致上與迴歸分析相似。利用時間序列作預測的一個基本假設為，未來的數值能經由過去的數值所估計，而根據不同性質的序列資料，可用不同的方法，如：移動平均法、指數平滑法等，以找出適合的模式。因此在選擇模式前，必須對資料作分析工作，尋找其潛在的趨勢，方能獲得一個好的預測模式。

2.2 人工智慧法

人工智慧是指電腦具有人類智慧完成推理、學習和自我改善的功能之能力。人工智慧的運作過程，是將人類對問題所引起的刺激，進行推理、解決問題、學習、判斷及思考決策等過程，並將其分解成一些基本步驟。再透過程式設計，將這些人類解決問題的過程模組化或公式化，使電腦具有一結構的方法，以設計或應付更複雜的特殊問題。廣義的人工智慧包含領域很廣，如模式認知、專家系統、類神經網路、遺傳演算法、認知學習、案例式推理等。

2.2.1 模糊理論 (Fuzzy Theory)

模糊理論是由 Zadeh 教授所提出的，其設計為將人類的經驗認知，轉化為模糊的判斷規則，並以數學函數將其隸屬度予以量化，最後推論出控制量的大小。模糊集合理論由於簡明且類似人類的推論，愈來愈被頻繁的使用於智慧系統。

由於龐大資料庫與資料倉儲的廣泛使用，從交易中找出有用的資訊與知識成為重要的研究領域；資料採礦的技術能利用對訓練樣本的探勘和分析，找出有用的樣式與分類規則，而傳統的資料探勘方法使用二元值確認交易之間的關聯，以及僅於單一的概念層找出規則，但這樣的方式未必能適用於充滿不確定性的真實世界。因此能夠以語義術語解釋事件發生機率或數量大小的模糊理論被提出來應用於資料探勘中。

模糊集合 (Fuzzy set) 必須經由隸屬函數 (membership function) 才能進行量化，如此才能透過精確的數學方法分析及處理模糊性的資訊。隸屬函數為模糊理論的基本概念，其數值介於 0 到 1，用以描述模糊集合的性質，表示元素隸屬的程度。通常利用模糊理論解決問題的關鍵即在於隸屬函數的建立，在系統設計的初期，首先須決定採用何種形狀的歸屬函數設定起始的參數，以大略的隸屬函數透過模擬、修正、不斷地調整驗證，終至於實際達到系統設計的要求。

經由上述的概念，便可依據專家經驗或是訓練樣本建構模糊規則庫。每條模糊規則是以 IF-THEN 的條件敘述形式來表示。IF 被稱作前件部，或稱前提部份，提供判斷這個語句成立與否的條件，而 THEN 則稱作後件部，或稱結論部份，用以表現符合條件的結果。模糊規則庫的建立步驟如下：

- Step1. 選擇適當的受控訊號，作為輸入變數。
- Step2. 定義隸屬函數的個數與形狀。
- Step3. 將輸出變數的論域設定在相對於零的等距兩邊。
- Step4. 模糊化。
- Step5. 規則庫的建立。

Step6. 模糊推論。

Step7. 解模糊化。

表 1. 模糊理論研究應用文獻整理

作者年份	研究主題與重要論述
Bersini and Bontempi 1997[14]	研究主題：Now comes the time to defuzzify neuro-fuzzy models 重要論述： 模糊模式能夠經由像專家系統一樣的產生規則，在數學真實的連續特性與人類語言的間斷特性中達成協調，以描繪數學輸入與輸出之間的映對關係。尤其是在面對多變數問題時；而類神經模糊模式則能強化此方面的能力。
陳彥良 等人 2001[9]	研究主題：在包裹式資料庫中挖掘數量關聯規則 重要論述： 利用模糊技術於包裹資料庫中挖掘關聯規則的方法。除了分析一般常見的交易項目之關聯外，同時考量了購買數量的影響。文中將模糊理論應用於指定項目數量的區間，用以產生具有語意的關聯規則，對於行銷策略的制定更有參考價值，且也證明了模糊理論於銷售預測領域的適用性。
Hong 等人 2003[17]	研究主題：Fuzzy data mining for interesting generalized association rules 重要論述： 從數量資料中建置模糊一般性規則之問題。設計一複雜的模糊資料探勘演算法，以處理以數量作為分類的資料；藉由修改 Hong 的方法，將數量值轉譯為語言術語。每個項目探勘過程中以單一語言術語作為最大基數，故模糊分割的數目和起始項目相同。經由修改 Srikant and Agrawal 的方法找出模糊規則，管理等級制的模糊項目。
Hu 等人 2003[18]	研究主題：Finding fuzzy classification rules using data mining techniques 重要論述： 提出利用對訓練樣本的探勘和分析，對資料探勘的技術，找出有用的樣式與分類規則，並以 Apriori 演算法為基礎的資料探勘技術，用以找出模糊分類規則。

模糊系統已普遍應用於模糊控制器(如洗衣機、六軸運動平台、消費性電子產品...等)、土木工程(如結構工程、大地工程、材料工程、營建工程與管理...等)、資料庫系統(如醫療診

斷、人力資源管理、投資決策...等)、機器學習與資料探勘(如機器人、語音辨識...等)[3]。表 1 彙整近期模糊理論應用於歸納資料關聯規則之相關應用。

2.2.2 類神經網路 (Neural Network)

類神經網路是一種計算系統，包括軟體與硬體，它使用大量簡單的相連人工神經元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，它從外界環境或者其它人工神經元取得資訊，並加以非常簡單的運算，並輸出其結果到外界環境或者其他人工神經元。

近年來，在銷售預測領域中，傳統方法漸不敷使用之際，許多模仿生物界特性的演算法不斷被提出，而類神經網路即為使用大量的人工神經元模擬人類大腦神經結構的資訊處理系統。而使用類神經網路的優點有[13]：

- ◆ 具有過濾能力。
- ◆ 具有適應學習能力。
- ◆ 真正的多輸入多輸出系統。

以上三點是針對類神經網路與統計經驗建模系統所做的比較，這些優點都是統計經驗模式所沒有的能力。當然，類神經網路電腦運算速的大幅提升，網路的計算速度也跟著增強許多，高速的計算能力也是類神經網路的優點之一。而葉怡成[11]也認為類神經具有高速計算能力、高度記憶能力、學習能力和容錯能力等優點，與傳統模式相比，類神經網路不需指定出特定的函數型式，且資料不需限定在某種特定的統計分配假設上，故在處理問題上較統計模式有更多的應用空間。

表 2. 類神經網路研究應用文獻整理

作者年份	研究主題與重要論述
Thiesing and Vomberger 1997[16]	研究主題：Sales Forecasting Using Neural Networks 重要論述： 應用以倒傳遞演算法訓練的類神經網路，考量了價格指標、廣告、活動、連續假日與季節性等因素，預測德國某超市中關於 20 項商品的週需求，且發現類神經網路的準確率要比統計上的移動平均法與業界常使用的簡易法更為良好。

謝文凱 2007[12]	<p>研究主題：應用類神經網路於造紙業計畫型生產之研究。</p> <p>重要論述： 運用類神經網路在預測上優越能力，學習現有資料之關連性進行需求預測模式之建構，以供決策者執行生產規劃之依據。研究中，使用二次預測、二次生產規劃之方法，除了修正原先生產模式外，並擴增資料年份，再擴增以不同類神經網路之預測方式(1.倒傳遞模式(BPN) 2.徑向基底模式(RBF))來探討此二次預測、二次生產規劃生產模式是否優於原先模式，以架構確認此新二次生產規劃模式之實用性。</p>
-----------------	--

類神經網路亦已普遍應用於工業工程方面(如資料分析、故障診斷、決策諮詢、製程監控...等)、商業金融方面(如商業決策、商業預測、商業分析...等)、科學與資訊方面(如醫學疾病診斷、醫學影像診斷、氣象預測、專家系統...等) [11]。表 2 彙整類神經網路應用之相關研究。

2.2.3 類神經模糊系統(Neuro-Fuzzy system, NFS)

類神經網路(Neural Network)與模糊理論(Fuzzy Theory)目前均被成功地應用在各個不同的領域上，同時也是目前研究上的一個熱門課題。類神經網路雖具有學習的能力，但其運作的狀態卻是「黑箱作業」，將從資料中歸納得來的概念隱藏於網路參數中，並轉換成只有電腦懂的規則語言，對人類來說難以理解、使用，即無法從中解讀某一特定行為的原因，也無法以人工方式修正特定的期望行為，這也是目前類神經網路較少應用於商業領域的原因，而模糊系統雖然能以簡單易懂的 IF-THEN 規則來描述所期望的系統行為，也能利用已有的技術知識修正系統。但模糊系統的應用有兩個問題：如何決定模糊規則與如何設定隸屬函數。有兩種方法較常被使用：一個方法為直接從有經驗的操作者處獲取知識，將其轉譯為模糊規則，然而這方法執行起來有其困難處且曠日費時，操作者不一定能明確的描述自己的知識；另一方法為利用機器學習技術從資料數據中取得模糊規則，知識可從過程中自動取得，或是由樣本案例中歸納出來；但在數據資料集合愈來愈龐大的環境趨勢，使用者從眾多資料中尋求模糊 IF-THEN 規則時，可能須耗費相當長的時間。於是近年來，許多研究皆致力於

模糊推論系統的改善，於是 Chen and Zhang 於 2005 研究提出[15]，考量資料相互的關聯性，才能建構出較合適的推論系統。

類神經網路與模糊系統之共通點及差異性可歸納出下面幾點：[4]

1. 兩者均是用來模擬人類的大腦。在這方面，類神經扮演的角色便是仿造大腦中細胞的行為。即大腦中的生理結構等較低階的部份。相對的，模糊邏輯(Fuzzy logic)則是用來模擬人類的心智，推理等屬於心理成份的部份。如果我們把類神經網路比喻成大腦的硬體成份，則模糊邏輯就好像軟體部份，藉由兩者間的相輔相成，便能描述人類的種種思考行為。
2. 知識的分散式表示(Distributed representation)，就類神經網路而言，所貯存的知識被分散在節點(Node)與鏈結值(Link)。而模糊系統的一個元件，則是由不同模糊集合(Fuzzy set)上的不同的歸屬程度(Membership grade)所表達。
3. 兩者均是可以訓練的動態系統，並且在不須要知道一個連續函數的輸入，輸出間的數學關係下，便能估測此一函數。這種特性使它們適合應用在控制領域上。
4. 均具有歸納(Generalization)能力及容錯能力，由於知識的分散式表示以及均屬於平行架構，使得兩者均有好的容錯能力。即當本身架構受到損害時，均能展現相當強韌性(Robustness)。
5. 具有處理現實生活中因為資料的不確定或不精確等所造成的問題。儘管類神經網路與模糊系統有許多的相似性，在細微的部份，兩者還是有些差別。兩者的差異在於：如何由取樣點估測一個函數，如何表示及儲存這些取樣點，對於結構上的知識的表示與編碼方式，以及由輸入對應到輸出等等。

表 3.類神經模糊網路研究應用文獻整理

作者年份	研究主題與重要論述
Thomassey 等人 2005 [23]	<p>研究主題：A Short and Mean-term Automatic Forecasting System- Application to Textile Logistics.</p> <p>重要論述： 紡織業為品項繁雜、歷史資料短暫且影響因素眾多的特殊環境，而傳統的銷售預測模式在這樣的情況下通常會因解釋變數而被強烈的干擾，於是採用模糊技術與類神經模糊方法分別建構中期短預測與短</p>

	<p>期預測模式。經由以ANFIS調整中期預測的短期預測模型，類神經模糊網路具有更好的解釋性且允許使用者調整部份的參數，例如輸入隸屬函數；因此可減少訓練所需的資料數量且維持類神經網路的適應與學習特色。文中以三年(156週)、322個項目的資料進行測試，以實際銷售資料、中期預測模式的最近一周預測值與未來的預測值作為短期預測模式的輸入資料，最後將預測結果與傳統的幾種模式比較，證實ANFIS的確在銷售預測方面有很好的成效。</p>
<p>曾治瑋 2009 [10]</p>	<p>研究主題：應用適應性模糊類神經系統於台灣地區汽車銷售預測</p> <p>重要論述： 使用三種時間數列模型 Box-Jenkins 模型(Autoregressive Integrated Moving Average Model, ARIMA)、類神經網路模型(Artificial Neural Network, ANN)與適應性模糊類神經推論系統(Adaptive Network-Based Fuzzy Inference System, ANFIS)去預測各階層之汽車銷售量。在使用三種時間數列模型之下，其實證結果顯示，利用適應性模糊類神經推論系統(ANFIS)優於其它兩種預測方法。</p>

類神經網路與模糊邏輯彼此是互補的技術，兩者之間有許多的相似性，而這種相似性提供了兩者間結合的可行性。張智星教授提出混合式模型的解決方案—「適應性類神經模糊推論系統(ANFIS)」，即整合類神經網路的學習能力，透過數據資料進行自我學習，模糊規則庫的可解性與準確性能夠同時得到提升。由於此方法確實能夠有效的強化模糊推論系統，故此類神經模糊系統立即受到相當的重視，遂成為人工智慧的熱門研究領域。表3彙整類神經模糊網路應用於銷售預測上之相關研究。

3.研究方法

為了解決當資料龐大時，模糊規則與隸屬函數不易得到的問題，且使推論系統具有能適應環境的學習能力，本研究採用由張智星教授於1992年提出的適應性類神經模糊推論系統(Adaptive Network based Fuzzy Inference

System, ANFIS)。此系統以傳統模糊理論為基礎，再整合類神經網路作為架構，其特性為能夠解決在傳統模糊控制設計中，必須依賴使用者的知識與經驗，重複調整歸屬函數才能達到減小誤差、增進效能之缺點；且能利用學習能力，建構出模糊 IF-THEN 規則，並逐漸的調適出適當的歸屬函數來滿足所要的模糊推論輸入輸出關係。

3.1適應性類神經模糊推論系統架構(ANFIS)

假設模糊推論系統有兩個輸入變數 x 、 y 與單一輸出 A_i, B_i, f ，為語意變數值；採用一階 Sugeno 模糊模式，其模糊規則集合可表示如下：

rule 1: IF x is A_1 and y is B_1 , then $f_1 = p_1x + q_1y + r_1$, 其
rule 2: IF x is A_2 and y is B_2 , then $f_2 = p_2x + q_2y + r_2$.
中 p, q, r 皆為實數。

ANFIS 之架構如圖 2 所示，其各層說明如下[20]：




圖2. ANFIS系統架構 [19]

第一層 輸入層：每一節點 i 皆為適應性節點，其節點函數：

$$\begin{aligned} O_{1,i} &= \mu A_i(x), & \text{for } i=1, 2, \text{ or} \\ O_{1,i} &= \mu B_{i-2}(y), & \text{for } i=3, 4, \end{aligned} \quad (1)$$

其中 $O_{1,i}$ 是表示輸入值 x 或 y 相對於模糊集合 A_i, B_i 之隸屬度。可使用任何的隸屬函數；此層之參數稱為「前項參數」。

第二層 規則層：皆為固定節點，以 Π 作為標記，其輸出值為所有輸入訊號之乘積：

$$O_{2,i} = w_i = \mu A_i(x) \mu B_i(y), \quad i=1, 2 \quad (2)$$

每個節點的輸出值，代表規則的觸發強度。

第三層 正規劃層：皆為固定節點，以 N 為標記，節點 i 計算出第 i 條規則相對於所有規則之觸發強度的比率。

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (3)$$

此層之輸出值，稱作正規化觸發強度 (normalized firing strength)

第四層 結果推論層：每個節點 i 為適應性節點，其函數為：

$$O_{3,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad i = 1, 2 \quad (4)$$

其中 \bar{w}_i 為 Layer 3 之輸出， $\{p_i, q_i, r_i\}$ 為節點的參數集合。此層之參數稱為「後項參數」。

第五層 輸出層：只有單一的固定節點，以 Σ 為標記。其輸出值為所有前層訊號之加總：

$$= O_{5,1} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (5)$$

當前項參數之值皆固定時，全體之輸出可以後項參數的線性組合來表示：

$$\begin{aligned} f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\ &= \bar{w}_1 (p_1 x + q_1 y + r_1) + \bar{w}_2 (p_2 x + q_2 y + r_2) \\ &= (\bar{w}_1 x) p_1 + (\bar{w}_1 y) q_1 + (\bar{w}_1) r_1 + (\bar{w}_2 x) p_2 + (\bar{w}_2 y) q_2 + (\bar{w}_2) r_2 \quad (6) \end{aligned}$$

而在模糊推論系統(FIS)的建構方面，由於資料探勘的理念為資料的屬性與數量愈龐大愈能從中找出有用的潛藏知識，但若以網格分群(Grid partition)的方式，模糊規則將會隨著資料特徵的數量而呈指數增加，造成分析的不易，故本研究建議採取減法分群(Subtractive Clustering)的方式，能夠以最精簡的規則數量建構模糊系統。

考慮在 m 維度空間中， n 個資料點 $\{x_1, \dots, x_n\}$ 的聚集，假設資料點已正規化，每一資料點皆為群集中心的候選者，資料點 x_i 的密度衡量可定義為：

$$D_i = \exp\left(-\frac{\|x_i - x_j\|^2}{(r_a/2)^2}\right) \quad (7)$$

其中半徑 r_a 為正常數，作為鄰近的定義，當資料點有許多的鄰近資料點時，則將有很高的密度值。計算出每個資料點的密度後，以擁有最高密度的資料點作為第一個群集中心；令 x_{c1} 為被選出的資料點， D_{c1} 為其密度，則對於每個資料點的下一密度衡量之公式為：

$$D_i = D_i - D_{c1} \exp\left(-\frac{\|x_i - x_j\|^2}{(r_b/2)^2}\right) \quad (8)$$

r_b 通常較 r_a 大，一般建議設為 1.5 倍；靠近第一個群集中心的資料點將會稍微降低密度，因此不會被選為第二個群集中心。重複上述的程序，直至產生一定數量的群集中心。

設第 i 個群集的中心為 c_i ， c_i 可分解為兩個向量元件： p_i, q_i 。 p_i 為輸入部分，包含了 c_i 的前 N 個要素； q_i 為輸出部分，包含了 c_i 的後面 $M-N$ 個要素。當給予輸入向量 x 時，其對於模糊規則 i 的滿足度定義為：

$$u_i = \exp\left(-\frac{\|x - p_i\|^2}{(r_a/2)^2}\right) \quad (9)$$

建立初始的 FIS 後，便可發揮 ANFIS 之異於傳統模糊理論的優勢能力，利用類神經網路的學習特性對資料執行訓練，調整隸屬函數與模糊規則庫。經過優化程序後的 FIS，其準確率將能夠獲得提升。在 ANFIS 中，提供兩種學習法：混合式學習演算法 (Hybrid Learning Algorithm) 和倒傳遞學習演算法 (back-propagation Learning Algorithm)。

混合法：當訊號向前傳導至第四層時，經由最小平方方法 (Least squares estimate) 得到後項參數；得到的誤差訊號將逆向回傳，經由梯度下降法 (Gradient Descent) 更新前項參數。當前項參數已達到優化的條件時，則混合法之收斂速度將快於倒傳遞法。

倒傳遞法：由最後一層開始將誤差傳回，經由最陡坡降法 (steepest descent) 降低每一層的誤差，更新神經網路之權值。

3.1.1 ANFIS 模式限制

ANFIS 比傳統的模糊推論系統要複雜許多，且並不是對所有的模糊推理系統皆可使用，必須滿足以下的限制 [18]：

1. 一階或零階的 Sugeno 型式。
2. 單輸出；使用加權平均法 (weighted average) 進行解模糊化 (所以的輸出隸屬函數須為同型態：線性或常數)。
3. 不同規則不得使用同一隸屬函數；即輸出隸屬函數的數目必須等同規則的數目。
4. 每條規則之權重相同。
5. ANFIS 對所有基本模糊推論的自訂選項並非全部允許，建議使用內建提供的隸屬函數和解模糊化函數。

Sugeno是以多項式的方式來表示各項規則的結論項，並以加權平均法則的方式解模糊化，獲得系統最後的輸出值。由於輸出為一多項式的樣式，故不像Mamdani 模式需要再經過複雜的解模糊化過程。推論過程如圖1。




圖1. Sugeno模糊推論模式 [19]

加權平均法是將輸入變數進行線性組合後，乘上各個模糊規則的後半部權重，再平均而得之，其特點為適用於網路調適與訓練，ANFIS即屬於此類。

3.1.2 模式應用程序

Step1. 導入歷史資料

將訂單之資料設為輸入參數，例如期數、當期數量，下一期數量。在 ANFIS 中，會自動認定最後一欄之資料作為輸出。將歷史資料整理為 ANFIS 所需之格式後，導入 ANFIS 作為訓練資料。

Step2. 建立模糊推論系統 (FIS)

ANFIS 提供兩種分群方法：網格式分割 (Grid partition) 與減法分群 (Subtractive Clustering)，若資料空間為高維度 (大於 5 個)，使用網格式分群將使規則之數量大幅增加，失去適用性；故本研究採取減法分群的方式，能夠以最少的規則數量建立起初始的模糊推論系統。但有時由於實務資料的特性或是任務的性質，ANFIS 建立的 FIS 不一定能合乎所需，故亦可重新編輯隸屬函數或是自行建立 FIS。

Step3. 執行類神經網路訓練

經由上述的步驟得到了初始的 FIS，但此時 FIS 的隸屬函數與規則庫的適用性可能並不高；故加以使用類神經網路執行訓練以提升模糊規則庫之準確率。學習方法可選擇使用混合法或是倒

傳遞法，並設定誤差容限與訓練次數作為訓練停止之準則。

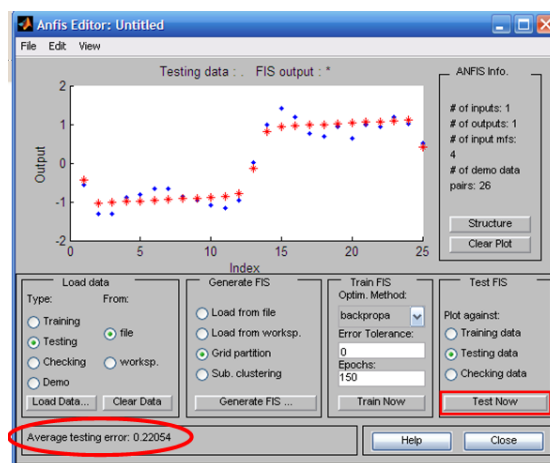


圖 3. ANFIS 輸出值與誤差

Step4. 得到明確輸出值

至此模式已建置完成，執行完畢後可獲得經優化後的模糊規則庫以及一明確輸出值，此輸出值即為緊急訂單可能發生之項目或是數量。使用者可再導入另一組資料以測試模式之準確性，或是直接在模式中輸入新的參數資料即可獲得所希望預測參數之輸出值。由於 ANFIS 之限制，只能有單一輸出值，因此必須分別針對項目與數量執行兩次分析程序。

3.2 倒傳遞類神經網路(Back propagation)

倒傳遞類神經網路是目前類神經網路學習模式中最具代表性，應用實務最普遍的模式。倒傳遞類神經網路屬於監督式學習網路，因而適合診斷、預測等應用。類神經網路訓練的目的是調整權衡值，訓練是架設輸入向量跟目標向量成對，成為一個訓練對 (training pair)。

3.2.1倒傳遞類神經網路架構

倒傳遞類神經網路共有三層架構分別為輸入層、隱藏層及輸出層，圖4為倒傳遞類神經網路架構。

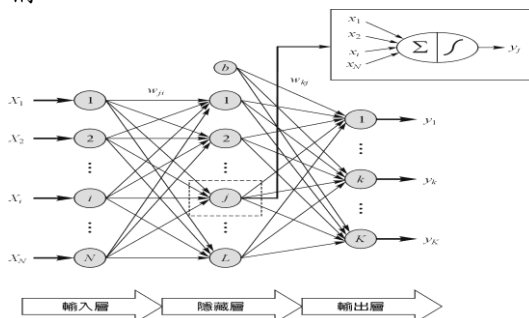


圖4. 倒傳遞類神經網路架構

1. 輸入層：用以輸入外在環境的訊號值，其處理單元數目依問題而定，以能夠完全表現各問題分類中之特性為目的。

2. 隱藏層：用以表現輸入處理單元間的交互影響，與問題的內在結構的能力，其處理單元數目並無系統化方法可循，通常須以試誤法來決定其最佳數目。轉換函數使用非線性轉換函數。每個網路中其隱藏層可以不只一層，也可以無隱藏層。

3. 輸出層：用以輸出訊號給外在環境，其處理單元數目依問題的目的而定。該層之轉換函數使用非線性轉換函數。

3.2.2 倒傳遞類神經網路演算法

倒傳遞基本原理是利用最陡坡降法的觀念，將誤差函數予以最小化，直到網路能夠逼近一個預測值，或是能夠用在指定的輸入下聯想輸出向量。標準的倒傳遞演算法是一種梯度下降(Gradient Decent)演算法，亦即網路的權重值是沿著誤差函數的負的梯度方向移動著，「倒傳遞」此術語是指針對非線性多層網路內計算梯度的方法。倒傳遞類神經網路是以能量函數之誤差信號，利用倒傳遞演算法修正網路參數，進而降低輸出和目標值之誤差，所以一般以下列誤差函數（或稱能量函數）表示學習的品質，其方程式如下所示：

$$E = \frac{1}{2} \sum_j (T_j - Y_j)^2 \quad (1)$$

T_j 為輸出層第 j 個運算元的目標輸出值。

Y_j 為輸出層第 j 個運算元的推論輸出值。

倒傳遞神經網路學習法步驟如下[11]：

step 1. 設定網路參數。

step 2. 以亂數設定加權值矩陣與偏權值向量。

step 3. 輸入訓練範例的輸入向量，與輸出目標向量。

step 4. 計算推論輸出向量 Y 。

(1). 計算隱藏層輸出向量 H

$$\begin{aligned} net_j &= \sum W_{ij} X_i - \theta_j \\ H_j &= f(net_j) \end{aligned} \quad (2)$$

(2). 計算推論輸出向量 Y

$$\begin{aligned} net_k &= \sum W_{jk} H_j - \theta_j \\ Y_k &= f(net_k) \end{aligned} \quad (3)$$

step 5. 計算差距量 δ

(1). 計算輸出層差距量

$$\delta_k = (T_k - Y_k) * f'(net_k) \quad (4)$$

(2). 計算隱藏層差距量

$$\delta_j = \left(\sum_k \delta_k W_{jk} \right) * f'(net_j) \quad (5)$$

step 6. 更新加權值矩陣，及閾值向量：

(1). 更新輸出層加權值矩陣，及閾值向量。

$$\begin{aligned} W_{jk} &= W_{jk} + \eta \delta_k H_j + \alpha \Delta W_{jk} (n-1) \\ \theta_k &= \theta_k - \eta \delta_k + \alpha \Delta \theta_k (n-1) \end{aligned} \quad (6)$$

(2). 更新隱藏層加權值矩陣，及閾值向量。

$$\begin{aligned} W_{ij} &= W_{ij} + \eta \delta X_i + \alpha \Delta W_{ij} (n-1) \\ \theta_j &= \theta_j - \eta \delta_j + \alpha \Delta \theta_j (n-1) \end{aligned} \quad (7)$$

step 7. 重覆步驟3 至步驟6，直到收斂。

3.3 Neural Network Toolbox 的應用程序

本研究使用 MATLAB 7.4 應用軟體之 Neural Network Toolbox 4.0 模組進行銷售預測，且本研究使用倒傳遞網路來建立網路架構，標準的倒傳遞演算法是一種梯度下降（Gradient Decent）演算法。NNTool 使用的步驟如下：[13]

Step 1. 將原始資料導入 MATLAB 工作空間中

Step 2. 將 MATLAB 工作空間中的變數輸入 nntool

Step 3. 創建網路：決定在倒傳遞演算法中所需使用到的各種參數，各種參數包含，網路的類型、網路輸入範圍、選取訓練函數、選取適應性學習函數選取性能函數..等。

Step 4. 訓練網路：透過自我學習不斷的修改的權重值和偏權值。

Step 5. 模擬網路：驗證創建網路的準確度，與測試數據的誤差。

4. 預測模型釋例及結果分析

為了驗證預測模式的準確性，藉由兩個實際案例的訂單資料做分析。應用 ANFIS、倒傳遞類神經網路及迴歸分析模式來進行預測模式的建構與驗證其準確性。

4.1 應用 ANFIS 預測顧客訂購數量

1、 先將訂單資料各種產品作一分類，將各種產品的期數及當期訂購數量作為輸入參數 x_1, x_2 ，將下一期的訂購數量作為輸出參數。

2、 以減法分群建立初始 FIS。但由於系統建

立之輸出函數不符本研究需求，故以手動方式，重新設定 FIS，並修改最終輸出之部分程式，由於有多種產品，每種產品之 FIS 均需手動方式設定，其網路架構只列舉其中一項產品當範例如圖 5。

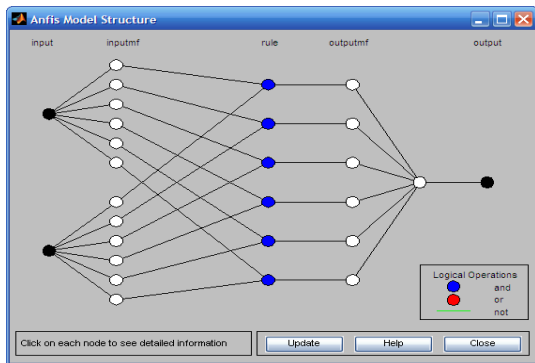


圖 5. 某產品 ANFIS 網路架構

由於混合演算法將對網路參數作較大之變動、且預測出之訂購值容易出現負值，故較不適用於使用者自行修訂隸屬函數之模式，故以倒傳遞學習演算法執行 150 次學習週期的訓練，調整 FIS 的隸屬函數與規則庫，獲致經優化後的模糊規則庫。使用者可經由輸入產品的期數及當期訂購數量屬性，透過隸屬函數的轉換，判斷下筆訂單的訂購量為多少，以每種產品測試。

- 3、以類神經網路訓練，對 FIS 進行優化。由於混合演算法會對手動設計之函數造成較大變動，故採用倒傳遞演算法執行訓練程序。
- 4、訓練完畢後，即可得最終明確輸出值。

4.2 應用倒傳遞類神經網路預測訂購數量

為比較 ANFIS 與倒遞類神經網路於客製化生產環境之預測差別，使用近年來預測很常使用的倒傳遞類神經網路的方法來進行預測。

本研究採用 Matlab7.4 Neural Network Toolbox 進行模型建構。其倒傳遞神類神經網路架構如圖 6 所示。




圖 6. MATLAB 倒傳遞神類神經網路架構[13]

1. 決定輸入值：與 ANFIS 所設定之輸入資料相同。

2. 創建網路模型：本研究的網路模型架構為一個隱藏層以及一個輸出層。
3. 隱藏層的節點個數：本研究使用隱藏層節點數為 10 個，輸出節點數為 1 個。
4. 轉移函數：隱藏層內採用具雙彎曲轉移函數的神經元，輸出層則採用具線性轉移函數的神經元。

其他參數設定：本研究採用 BFGS 演算法 (trainbfg)，此演算法的訓練參數為表 4。

表 4. 倒傳遞類神經網路參數設定

訓練參數	內定值	訓練參數	內定值
epochs	150	beta	0.1
show	25	delta	0.01
goal	0	gama	0.1
time	Inf	low_lim	0.1
min_grad	1e-006	up_lim	0.5
max_fail	5	maxstep	100
searchFcn	'srchbac'	Minstep	1e-006
scale_tol	20	bmax	26
alpha	0.001	batch_frag	0

4.3 應用迴歸方法分析預測訂購數量

為了說明 ANFIS 適用於此領域之問題，採用預測問題中常被使用的迴歸分析方法來做比較。在此使用 MINITAB 14 來建構迴歸模型如圖 7。

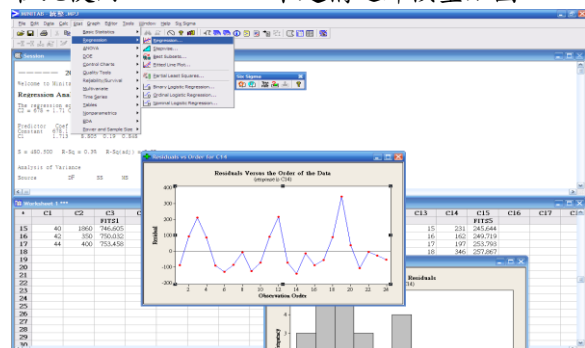


圖 7. MINITAB 14 預測迴歸模式建構

4.3 釋例結果

本研究以兩種類型的案例，根據三種預測方法以比較之絕對均方差之優劣，在 Case 1 的類神經資料訓練量上分為訓練訂單資料八期預測後八期及訓練資料十三期預測後三期做為區分，目的是為了比較資料量的多寡對於 ANFIS 關聯規則的建立與預測模式的準確度是否有影響。其結果分析均以 MAD 為基準來做比較。Case 1 分為訓練 8 期預測 8 期訓練八期，及預測 13 期預測後 3 期，以及訓練 8 期僅預測最後 3 期，而 Case 2 則只有訓練前面十二期資料預測後十一期訂單一種模式，兩種 Case 主要是以資料量的一半來做訓練，一半做為

測試數據，預測誤差之比較彙整於表5。

表5. 各方法、類型誤差比較總表

釋例類型	產品 訂單	ANFIS (backprop)	ANFIS (hybrid)	迴歸 分析	倒傳遞 類神經 網路
Case 1 (8 期)*	1c46a	659	1808	844	796
	w78e52	450	730	473	466
	w78	617	837	597	431
	w78e54	251	364	302	328
	總平均 MAD	495	935	554	506
Case 1 (3 期)	1c46a	583	1622	782	688
	w78e52	513	431	600	580
	w78	349	1696	842	736
	w78e54	330	719	509	528
	總平均 MAD	444	1117	684	633
Case 1**	1c46a	631	—	—	—
	w78e52	671	—	—	—
	w78	961	—	—	—
	w78e54	451	—	—	—
	總平均 MAD	755	—	—	—
Case 2 (11 期)	seyc-11 43	83.75	—	84.68	87.15
	seyc-21 43	21.39	—	34.59	23.14
	總平均 MAD	52.57	—	59.63 5	55.145

*：平均預測誤差期數。**：訓練八期資料預測最後三期。

4.4 結果分析與討論

根據表5之彙整結果，本研究將提出以下七點論點。

1. 不使用 ANFIS(hybrid)預測而使用 ANFIS(倒傳遞類神經網路)訓練的原因有二：其一，實際跑出來之表需求預測值會出現負值。其二，以整體預測結果來說，大部份預測求預測值比使用倒傳遞類神經網路預測出來之結果差，甚至比迴歸預測還要差。
2. 以 ANFIS 與迴歸分析預測 Case 1 預測結果比較，其比較基準為 MAD，如表 6。以 ANFIS(倒傳遞類神經網路)預測所得大部分較佳，總體而言，以 ANFIS 預測 Case 1 之預測結果優於迴歸預測 11.92%(八期)、54.05%(三期)。

表 6. ANFIS、迴歸分析預測差異比較

釋例 類型	預測 方法	8 期平 均 MAD*	差異 百分比 ** (8 期)	3 期 平均 MAD	差異 百分比 (3 期)
Case 1	迴歸 分析	554	11.92%	684	54.05%
	ANFIS	495	—	444	—

*：平均誤差是由 Case 1 之四種產品個別誤差平均而得，總共訂單資料共有十六筆，分為訓練 8 筆訂單(即預測 8 筆)和訓練 13 筆(即預測 3 筆)來做釋例。

**：以 ANFIS 為基準，計算差異百分比。

3. 使用 ANFIS 預測(8 期)在 Case 1 比迴歸預測差的解有一例，如表 7，其預測誤差比迴歸差 3.24%，但經過增加資料訓練(13 期)後，ANFIS 所得到的預測誤差也比迴歸好很多，變成優於迴歸分析 141.26%，由此可得知，在執行資料訓練時，足夠的歷史資料量也是考慮的重點之一。

表 7. ANFIS、迴歸分析單項產品預測差異比較

訂單 項目	方法	8 期 平均誤 差	差異 百分比 *	3 期 平均誤 差	差異 百分比
W78	迴歸平 均 MAD	597	-3.24%	842	141.26%
	ANFIS 平均 MAD	617	—	349	—

*：以 ANFIS 為基準，計算差異百分比。

4. 以 ANFIS 倒傳遞類神經網路預測 Case 1 預測結果比較，如表 8，其結果以 ANFIS 優於倒神經類神經網路預測結果，其比較之基準以 MAD 來做比較，ANFIS 優於倒傳遞類神經網路 2.22%(八期)、42.57%(三期)。
5. 以 Case 1 來說，在預測方法為 ANFIS，訓練八期訂單數據及訓練十一期訂單數據，在比較之其預測之平均誤差，ANFIS 訓練十一期之預測模型優於訓練八期之預測模型，其準確度增加 70.05%，如表 9。說明在 ANFIS 訓練過程來說，訓練之資料量的增加有助於整體預測模型的準確度增加，並且也可看出，ANFIS 在增加五期訓練資料後，預測模式之準確度大大的增加，代表 ANFIS 在增加資料訓練後，預測模型的反應速度佳。

表 8. ANFIS、倒傳遞類神經網路預測差異比較

釋例類型	預測方法	8 期平均誤差*	8 期差異百分比**	3 期平均誤差	3 期差異百分比
Case 1	倒傳遞類神經網路	506	2.22%	633	42.57%
	ANFIS	495	—	444	—

*：以 ANFIS 為基準，計算差異百分比。

表 9. ANFIS 訓練資料期數不同比較

釋例類型	預測方法	訓練 8 期	訓練 13 期	訓練差異百分比*
Case 1	ANFIS	755	444	70.05%

*：以 ANFIS 為基準，計算差異百分比。

6. 以兩個 Case 之訂單型態相比較，Case 2 之訂單資料需求波動較為穩定，以 Case2 的預測結果來看，ANFIS 預測結果還是優於迴歸分析及倒傳遞類神經網路，如表 10，其差異百分比分別為 13.43%、4.9%。

表 10. 類型 2 各方法預測誤差比較

釋例類型	預測方法	12 期*	差異百分比 (12 期)
Case 2	迴歸分析	59.635	13.43%
	倒傳遞類神經網路	55.145	4.9%
	ANFIS	52.57	—

*：平均誤差是由 Case 2 之 2 種產品個別誤差平均而得，總共訂單資料共有 23 筆，分為訓練 12 筆訂單(即預測 11 筆)來做釋例。

表 11. 類型 1.2 預測誤差比較

預測方法	Case 1 總平均誤差*	Case 2 總平均誤差	差異百分比**
迴歸分析	510	59.635	88.31%
倒傳遞類神經網路	506	55.145	89.10%
ANFIS	495	52.57	89.37%

*：比較兩個 Case 預測誤差，其中 Case 1 以訓練 8 期為基準來做比較，其原因為兩個 Case 之測試資料量較接近，所求得誤差較具比較性。

**：以 Case 1 為基準，計算差異百分比。

7. 以兩個 Case 之預測結果來看，Case 2 之預測誤差明顯小於 Case 1，本研究採用的三種方法，皆是以 Case 2 之預測誤差較小，所得到的預測之差異百分比分別為 88.31%、89.10%、89.37%，如表 11。說明需求預測在訂單資料需求波動較平穩時，所產生的預測也是較準確的。

5. 結論與建議

目前競爭激烈的環境，客戶要求的服務水準不斷提升，而對於訂單的承接能力與達交率已成為極重要的競爭指標。故本研究目標著重於經由對過往資料的分析，針對客製化的生產環境下的顧客需求訂單作出準確之預測，採用目前被廣為應用的自適應性類神經模糊推論系統，經由對資料的分析，並利用類神經網路的學習能力，建立模糊規則庫，以此預測顧客訂單需求數量，作為決策者之參考依據。本研究藉由實際案例與倒傳遞類神經網路以及傳統的迴歸分析模式進行比較，結果顯示 ANFIS 之預測模式具有較佳之準確度。在訓練網路資料方面，實驗結果顯示，資料量越多，ANFIS 較容易找到關聯規則，在預測方面也較準確。如此成果相信對於生產排程的安排以及管理者之決策有參考價值，可幫助增加排程的穩健性，提高服務水準。未來本研究還可以更進一步探究與灰關聯預測以及多變量迴歸預測之比較，建置更為完備之預測機制，以期提升客製化生產系統之預測能力，使企業營運更臻完善。

致謝

本研究感謝國科會專題研究計畫的經費支持，計畫編號：NSC97-2410-H-167-008-MY2。

參考文獻

1. 王在欣，*需求不確定下供應鏈延遲策略最適化之研究*，國立成功大學交通管理科學研究所碩士論文，2004。
2. 王進德，*類神經網路與模糊控制理論入門與應用*，全華圖書股份有限公司，2006。
3. 李允中，王小璠，蘇木春，*模糊理論及其應用*，台北：全華圖書股份有限公司，2002。
4. 吳琮璠、清佳，2000。*資訊管理-理論與實務*，智勝文化事業股份有限公司四版。
5. 周湘蘭，*類神經網路在多重產品需求預測上之應用*，元智大學工業工程與管理研究所碩士論文，2002。
6. 林隆儀、羅文坤、鄭英傑，*新產品行銷策略*，

- 超越企管顧問股份有限公司，1991。
7. 秉昱科技譯，**模糊邏輯與類神經模糊 實例說明**，儒林圖書有限公司，2000。
 8. 洪國智，**模糊倒傳遞網路於印刷電路板生產預測之應用**，元智大學工業工程與管理研究所碩士論文，2004。
 9. 陳彥良，凌俊青，許秉瑜，**在包裹式資料庫中挖掘數量關聯規則**，資訊管理學報，第七卷第二期，215-229，2001。
 10. 曾治璋，**應用適應性模糊類神經系統於台灣地區汽車銷售預測**，國立臺灣科技大學工業工程與管理研究所碩士論文，2009。
 11. 葉怡成，**類神經網路模式應用與實作**，儒林圖書有限公司，2000。
 12. 謝文凱，**應用類神經網路於造紙業計畫型生產之研究**，國立台灣科技大學自動化及控制研究所碩士論文，2007。
 13. 羅強華，**類神經網路-MATLAB的應用**，高立圖書有限公司，2005。
 14. Bersini H., Bontempi G., Now comes the time to defuzzify neuro-fuzzy models, *Fuzzy Sets and Systems*, 90,2, 161-170, 1997 .
 15. Chen, D. W., Zhang, J. P., **Time series prediction based on ensemble ANFIS**, 2005 International Conference on Machine Learning and Cybernetics, 6, 3552-3556, 2005.
 16. Thiesing, F. M., Vornberger, O., **Sales Forecasting Using Neural Networks**, International Conference on Neural Networks, 4, 2125-2128, 1997.
 17. Hong, T. P., Lin, K. Y., Wang, S. L., Fuzzy data mining for interesting generalized association rules, *Fuzzy Sets and Systems*, 138(2), 255-269, 2003.
 18. Hu, Y. C., Chen, R. S., Tzeng, G. H., Finding fuzzy classification rules using data mining techniques, *Pattern Recognition Letters*, 24(1-3), 509-519, 2003.
 19. Jang, J. S. R., Sun, C. Mizutani, T. E., **Neuro-Fuzzy and Soft Computing**, Prentice-Hall, 1997.
 20. Tu, K. Y., Liao, C. S., **Application of ANFIS for Frequency Syntonization Using GPS Carrier-Phase Measurements**, Frequency Control Symposium, 2007 Joint with the 21st European Frequency and Time Forum, IEEE International, 933-936, 2007.
 21. Sugeno, M. and Tanaka, K., Successive Identification of a Fuzzy Model and its Applications to Predictions of Complex Systems, *Fuzzy Sets and Systems*, 42(3), 315-334, 1991.
 22. Sugeno, M., Yasukawa, T., A., Fuzzy- Logic-Based Approach to Qualitative Modeling, *IEEE Transactions on Fuzzy System*, 1(1), 7-31, 1993.
 23. Thomassey, S., Happiette, M., Castelain, J. M., A Short and Mean-term Automatic Forecasting System—Application to Textile Logistics, *European Journal of Operational Research*, 161(1), 275-284, 2005.