

國立交通大學
高階主管管理碩士學程
碩士論文

以類神經網路建構上市櫃公司危機預警模型之研究

The Study of Constructing an Early Warning Model for Financial Crisis by Using Artificial Neural Network Method

研究生：蔡興華

指導教授：王克陸 博士

中華民國 九十三年 六月

中文摘要

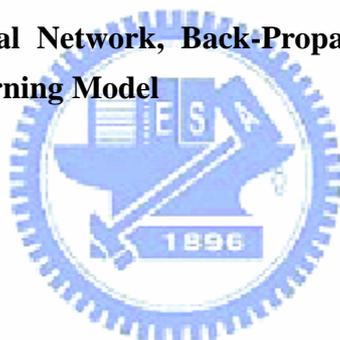
本研究的目的是在於利用倒傳遞類神經網路建立上市櫃公司的危機預警模型，用於預測企業是否會在未來的某個年度發生危機。其中危機定義的範圍，限制於上市櫃公司的股票被證交所改列為全額交割股或被處以停止交易時。由於類神經網路模型同時考慮了線性與非線性關係，且其具有高速計算能力、高容記憶能力、學習能力、及容錯能力，相較於傳統的區別分析研究方法，應該會有較高的預測正確率。因此除了建立倒傳遞類神經網路預警模型之外，亦使用相同的樣本建立羅吉斯迴歸預警模型，以比較兩者的預測能力。利用目標年度前一年、前二年、及前三年的財務比率數據，建立的個別模型，倒傳遞類神經網路預警模型的預測正確率較羅吉斯迴歸模型有更佳的預測能力。其預測值與實際值的擬合程度較好，誤差較小。此外，觀察兩種預警模型三種年度模型的預測結果，可以發現愈是遠期的資訊，在預測的效果上愈差。

關鍵字：類神經網路、倒傳遞、羅吉斯迴歸、財務危機、預警模型

英文摘要

The purpose of this research is to construct an early warning model for financial crisis of the listed companies by using artificial neural network (ANN) with back propagation (BP) algorithm. ANN has error tolerance ability, learning ability, high speed computational ability, and high-volume memorizing ability. It also considers both linear and nonlinear relationship at the same time. To compare with the traditional method, we also adopt logistic regression method to build early warning model. Results show that the accuracy rate in forecasting financial crises is superior for ANN model than that of logistic model.

Keyword : Artificial Neural Network, Back-Propagation, Logistic Regression, Financial Crisis, Early Warning Model



誌 謝

感謝王克陸老師指導我、協助我，讓我能順利完成我的的論文，在此深表謝忱；感謝交大 EMBA 三屆陳朝煌學長的鼓勵，讓我能有機會到交大學習，獲得成長的喜悅；期間內人曹之媛女士的支持及信杰的協助一併在此致謝。



目錄

中文摘要	i
英文摘要	ii
誌謝	iii
目錄	iv
圖目錄	v
表目錄	vi
一、緒論	1
1.1 研究動機.....	1
1.2 研究目的.....	2
1.3 研究範圍及限制.....	2
1.4 論文架構及流程.....	3
二、文獻回顧及探討	5
2.1 危機的定義範圍.....	5
2.2 財務比率變數.....	6
2.3 相關危機預警模型文獻回顧.....	12
2.4 類神經網路危機預測模型文獻.....	19
三、研究方法	21
3.1 類神經網路 - 倒傳遞法.....	21
3.2 羅吉斯迴歸概述.....	35
四、研究設計及結果	37
4.1 研究設計.....	37
4.2 數據蒐集與整理.....	39
4.3 分析結果與比較.....	40
五、結論與建議	47
5.1 結論.....	47
5.2 建議.....	48
參考文獻	49
中文部分.....	49
英文部分.....	50
附錄 一 危機與正常公司樣本配對表	52

圖目錄

圖 1 論文流程圖	4
圖 2 簡單神經元模式	22
圖 3 單層類神經網路架構	24
圖 4 兩層類神經網路架構	25
圖 5 雙彎曲函數圖形	27
圖 6 實驗網路架構	38



表目錄

表 1 解釋變數彙整表	7
表 2 類神經網路-前一年模型預測結果	41
表 3 類神經網路-前二年模型預測結果	42
表 4 類神經網路-前三年模型預測結果	42
表 5 羅吉斯迴歸-前一年模型預測結果	43
表 6 羅吉斯迴歸-前二年模型預測結果	44
表 7 羅吉斯迴歸-前三年模型預測結果	45
表 8 兩種模型之預測正確率及誤差均方根合併列表	46



一、緒論

1.1 研究動機

企業經營者與投資人皆不願意見到公司的股票被證交所打入全額交割股或處以停止交易，對經營者而言，這代表的是企業管理不善，導致公司淨值低於資本額的一半，公司存在著可能倒閉的隱憂，而經營者則可能遭到撤換；對投資人而言，這代表的是所投資的股票，將在其他投資人的拋售下，造成損失，價格極有可能低於面值的一半，而在流動性不足下，投資人更可能會遇到無法迅速變現的困境，為求脫手而誘使股票必須再次跌價。因此若能以較長期的資料事先監控上市櫃公司未來股票是否會被列入全額交割股，將可說是分析股票的重要工作。若能建立一套準確度高的預警模型，除了投資人外，基金管理者及任何內外部關係人將可以避免錯誤的判斷發生。在國內外文獻中，都是利用公司的財務比率預測是否會發生危機，顯示經營不善將可以由財務比率中看出端倪，因此在預測公司是否被列入全額交割股時，將使用財務比率作為模型的參數。定義本研究的問題後，則必須找到一個比較適合的研究方法來解決問題。一般的統計方法是屬於線性模型，如複迴歸分析、羅吉斯迴歸分析、區別分析等，要符合特定的母體分配假設。真實世界中，若只採用線性模型，將錯失非線性關係的重要資訊，而在數據方面，也常不符合特定分配，如常態分配。因此，一方面傳統的方法無法滿足我們的要求，一方面隨著電腦運算速率以及演算法的進步，本研究將使用的類神經網路模型來進行危機預測。

1.2 研究目的

本研究的目的，在於發展一個以財務比率為參數的類神經網路模型來預測上市櫃公司是否將會被改列為全額交割股或暫停交易。首先將選取的上市櫃公司分為兩類，一類是股票沒有被改列為全額交割股或暫停交易的公司，另一類則是股票被改列為全額交割股或暫停交易的公司，再利用類神經網路的學習能力，並以選定的數據來進行預警模型的訓練、修正、驗證及設立。一旦預警模型被建立，最直接的獲益人將是投資人。

此外，由於類神經網路模型同時考慮了線性與非線性關係，具有高速計算能力、高容記憶能力、學習能力、及容錯能力，相較於傳統的區別分析，應當會有較佳的預測準確度。除了建立類神經的預警模型，也拿之與一般在區別分析中常用的羅吉斯迴歸模型來進行比較。類似 Udo(1993)所採用的方式，本研究驗證兩者在特定的樣本下，以何者成功預測的百分比高，來作為準確度比較的依據。

1.3 研究範圍及限制

在真實世界的客觀條件下，本研究不得不設定研究的範圍及限制。在研究對象方面，選擇的是以上市櫃公司為研究母體，，而不是由任何只是登記有案的公司來取樣，這完全是基於非上市公司資料在公正上的質疑以及合法取得的困難。在產業分佈方面，幾乎遍及所有的產業，只排除了銀行證券相關產業，主要原因是其會計財報的特殊性，不同於一般產業，其無法提供本研究所設定眾多的自變數。在解釋變數的選取上，為避免任意選擇無謂的變數，本研究選擇了國際期刊文獻所使用過的財務比率。就數據的期別資料而言，使用的是年度的資料。而在可能出現遠期的延遲影響的效果之下，我們不只使用危機事件前一年的各項財務比率，而是也加入了事件發生前二及前三年的各項財務比率，建立三種年度模型，不同年度但名稱相同的財務比率代表的是不同的解釋變數。

1.4 論文架構及流程

在本文的架構中，如【圖 1】所示，最初的第一章的緒論說明了研究的動機、目的以及研究範圍。第二章的文獻回顧將介紹本研究中危機的定義範圍，採用的財務比率、概述相關的危機區別分析模型及其文獻、以及應用類神經網路的危機預警模型之相關文獻。在第三章的研究方法中，將介紹本研究所使用的類神經網路倒傳遞法(back-propagation)模型的發展及實證應用，另外也將簡介羅吉斯迴歸模型。在第四章的研究設計及結果，首先將進行實證研究的設計、及數據的蒐集與處理，再者將介紹所獲得的類神經網路和羅吉斯迴歸兩種危機預警模型結果，而結果包含了兩種相關指標 - 預測正確率及誤差均方根，進一步地也利用這兩個指標比較兩者的預測正確率。第五章則是本研究的結論及後續的研究建議，說明本研究的成果，提及未來研究範圍可擴展之處以及在研究限制上的釋放。



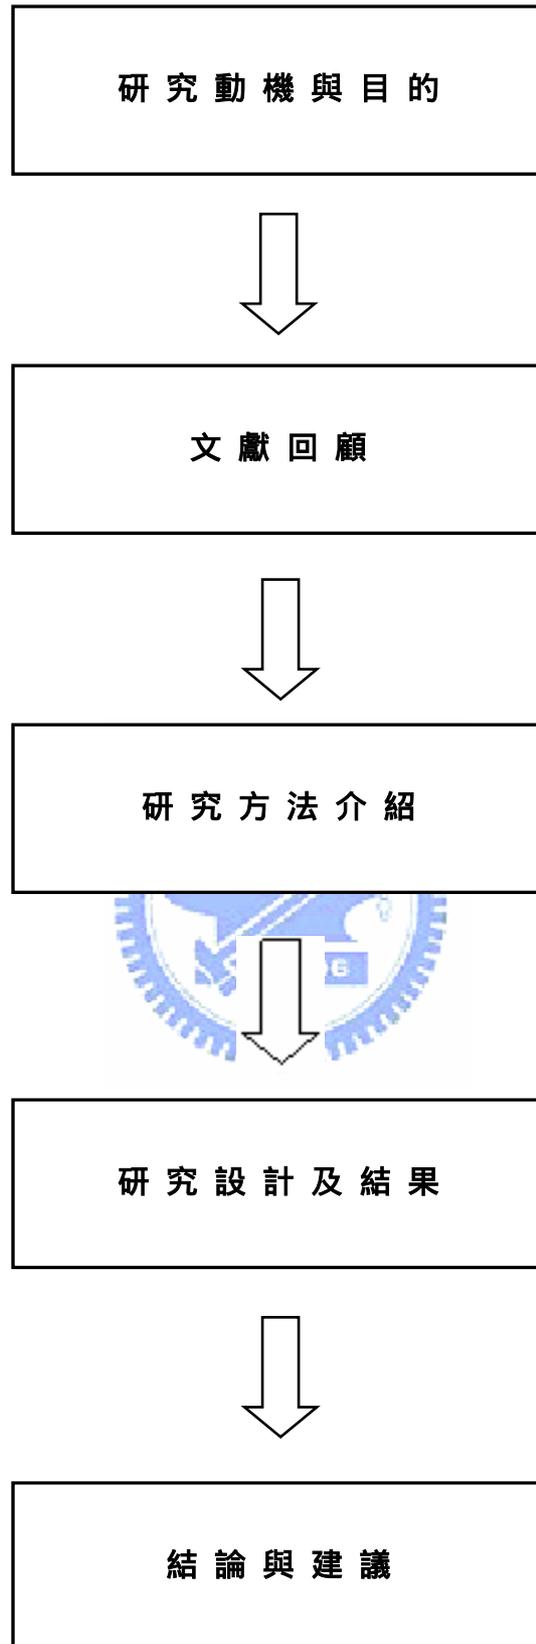


圖 1 論文流程圖

二、文獻回顧及探討

2.1 危機的定義範圍

本研究將危機的認定範圍，限制在上市櫃公司股票第一次被證券交易所改列為全額交割股的發生，或第一次被處股票暫停交易，且在這兩種情況發生前並未出現過危機。在文獻上對於危機有不同的組合定義，係由全額交割股、停止交易、下市、及經法院裁定重整等事件合併定義而成。但是，由於股票在下市之前可能即有跡可循，常常先被處以變更交易方式，或暫停交易等。在此時的股價常低於票面值，已造成投資人重大的股票跌價損失，而不必等到下市發生。因此，本研究不將下市處份列為危機的定義範圍。

2.1.1 改列為全額交割股的條件

當上市櫃公司股票被改列為全額交割股時，皆根據台灣證交所的規定。台灣證券交易所股份有限公司營業細則第四十九條指出，上市公司有下列情事之一者，對其上市之有價證券得變更原有交易方法為全額交割：

1. 其依證券交易法第三十六條規定公告並申報之最近期財務報告或投資控股公司之合併財務報告顯示淨值已低於實收資本額二分之一者。
2. 未於營業年度終結後六個月內召開股東常會完畢者，但有正當事由經報請公司法主管機關核准，且於核准期限內召開完畢者，不在此限。
3. 其依證券交易法第三十六條規定公告並申報之年度或半年度財務報告或投資控股公司之合併財務報告，因未依有關法令及一般公認會計原則編製或揭露，或因委任人，受查者之限制，致會計師未能實施必要之查核程序，經其簽證會計師出具未能將其保留之原因充分揭露或未能將可能影響之科目及其應調整金額充分揭露之保留意見者。
4. 違反上市公司重大訊息查證暨公開相關章則規定，經通知補行辦理公開程序，未依限期辦理且個案情節重大者。
5. 董事或監察人累積超過三分之二(含)以上受停止行使董事或監察人職權之假處分裁定。

6. 本公司基於其他原因認有必要者。

2.1.2 處停止交易的條件

上市公司股票的暫停交易，係按台灣證券交易營業細則第 50 條的規定。其內容如下：上市公司有左列情事之一者，對其上市之有價證券應由本公司依證券交易法第一百四十七條規定報經主管機關核准後停止其買賣；或得由該上市公司依第五十條之一第二項規定申請終止上市：

1. 未依法令規定期限辦理財務報告或財務預測之公告申報或投資控股公司檢送之財務報告未再編製合併財務報告者。
2. 有公司法第二百八十二條之情事，經法院依公司法第二百八十七條第一項第五款規定對其股票為禁止轉讓之裁定者。
3. 檢送之書表或資料，發現涉有不實之記載，經本公司要求上市公司解釋而逾期不為解釋者。
4. 在本公司所在地設置證券過戶機構後予以裁撤，或虛設過戶機構而不辦過戶，並經本公司查明限期改善而未辦理者。
5. 其依證券交易法第三十六條規定公告並申報之財務報告或有投資控股公司之合併財務報告，有未依有關法令及一般公認會計原則編製，且情節重大，經通知更正或重編而逾期仍未更正或重編者；或其公告並申報之年度或半年度財務報告或投資控股公司之合併財務報告，經其簽證會計師出具無法表示意見或否定意見之查核報告者，但會計師因對繼續經營假設或被訴事件等產生疑慮而出具無法表示意見之查核報告者，不在此限。
6. 違反上市公司重大訊息查證暨公開等相關章則規定，個案情節重大，有停止有價證券買賣必要之情事者。
7. 其他有停止有價證券買賣必要之情事者。

2.2 財務比率變數

在解釋變數方面，本研究選取了過去相關的財務危機模型文獻中，屬於在檢定上顯著的二十三個財務比率，整理於【表 1】。這些比率可歸類為流動性、獲利性、財務槓桿、市場結構、管理效率性、以及活動性等指標。

表 1 解釋變數彙整表

自變數	代表之財務比率	指標類別	曾引用的文獻
X ₁	現金對流動負債比率	流動性	Beaver (1966)、Edmister (1972)、Gombola et al. (1966)
X ₂	現金對總資產比率	流動性	Beaver (1966)、Gombola et al. (1987)
X ₃	流動比率	流動性	Beaver (1966)、Altman et al. (1977)、Gombola et al. (1966)
X ₄	流動資產對總資產比率	流動性	Beaver (1966)、Lo (1986)、Gombola et al. (1987)
X ₅	淨營運資金對總資產比率	流動性	Beaver (1966)、Altman (1968)、Ohlson (1980)、Theodossiou (1993)
X ₆	淨營運資金對銷貨收入比率	流動性	Edmister (1972)
X ₇	速動比率	流動性	Beaver (1966)
X ₈	銷貨毛利對銷貨收入比率	獲利性	Theodossiou et al. (1999)
X ₉	淨利對股東帳面價值比率	獲利性	Theodossiou et al. (1999)
X ₁₀	淨利對固定資產比率	獲利性	Theodossiou et al. (1999)
X ₁₁	淨利對總資產比率	獲利性	Beaver (1966)、Ohlson (1980)、Lo (1986)、Gombola et al. (1987)
X ₁₂	營業利益對固定資產比率	獲利性	Theodossiou et al. (1999)
X ₁₃	營業利益對銷貨收入比率	獲利性	Theodossiou et al. (1996)
X ₁₄	營業利益對總資產比率	獲利性	Altman (1968)、Altman et al. (1977)、Theodossiou (1993)
X ₁₅	保留盈餘對總資產比率	獲利性	Altman (1968)、Altman et al. (1977)
X ₁₆	長期負債對總資產比率	財務槓桿	Beaver (1966)、Altman (1968)
X ₁₇	總負債對總資產比率	財務槓桿	Ohlson (1980)、Gombola et al. (1987)、Theodossiou et al. (1996)
X ₁₈	市值對總負債比率	市場結構	Altman (1968)
X ₁₉	應收帳款對流動資產比率	管理效率	Theodossiou et al. (1999)
X ₂₀	應收帳款對銷貨收入比率	管理效率	Beaver (1966)、Gombola et al. (1987)
X ₂₁	固定資產對總資產比率	營運槓桿	Theodossiou (1993)

X_{22}	存貨對銷貨收入比率	管理效率	Beaver (1966)、Edmister (1972)、 Theodossiou (1993)、 Theodossiou et al. (1996)
X_{23}	銷貨收入對總資產比率	活動性	Altman (1968)、Gombola et al. (1987)

資料來源：整理自Theodossiou & Kahya(1999)的研究

茲將各變數分述如下：

1. 現金對流動負債比率(Cash to Current Liabilities)：

此比率比速動或流動比率更能測驗出一企業之即期償債能力，屬於流動性的測試指標。文獻中使用這個指標的學者有 Beaver (1966)、Edmister (1972) 及 Gombola et al. (1966)等。

2. 現金對總資產比率(Cash to Total Assets)：

呈現現金在總資產中所佔的比重，比重愈高，資金調度的靈活性愈大，屬於流動性的測試指標。文獻中使用這個指標的學者有 Beaver (1966)及 Gombola et al. (1987)等。

3. 流動資產對流動負債比率(Current Assets to Current Liabilities)：

即流動比率，屬於流動性的測試指標。經常被用來作為企業短期償債能的指標，實務上以達到 150%以上為宜，比率愈大，流動負債獲得償還的可能性愈大。文獻中使用這個指標的學者有 Beaver (1966)、Altman et al. (1977)及 Gombola et al. (1966)等。

4. 流動資產對總資產比率(Current Assets to Total Assets)：

屬於流動性的測試指標。流動資產所佔的比重愈大，企業資金運用可以更靈活。文獻中使用這個指標的學者有 Beaver (1966)、Lo (1986)及 Gombola et al. (1987)等。

5. 淨營運資金對總資產比率(Net Working Capital to Total Assets)：

屬於流動性的測試指標。淨營運資金等於流動資產減去流動負債，因此淨營運資金更名為企業所靈活運用。文獻中使用這個指標的學者有

Beaver (1966)、Altman (1968)、Ohlson (1980)及 Theodossiou (1993)等。

6. 淨營運資金對銷貨收入比率(Net Working Capital to Sales) :

屬於流動性的測試指標。文獻中使用這個指標的學者有 Edmister (1972)。

7. 速動資產對流動負債比率(Quick Assets to Current Liabilities) :

即速動比率，屬於流動性的測試指標，用以檢測企業在短期內可變現償還流動負債的能力，速動比率越高，表示企業短期償債能力越佳。而其中速動資產包括了現金 有價證券 應收票據 應收帳款等易變現之資產(流動資產 - 存貨 - 預付款項 - 其他流動資產)。文獻中使用這個指標的學者有 Beaver (1966)。

8. 銷貨毛利對銷貨收入比率(Gross Profit to Sales) :

用以測度企業產銷效能，屬於獲利性的測試指標。就經營績效衡量觀點而言，比率愈高者佳。因為愈高表示銷貨成本愈低，企業所獲得的利潤也愈多。文獻中使用這個指標的學者有 Kahya et al.(1999)。

9. 淨利對股東帳面價值比率(Net Income to Book Value of Equity) :

用以測度企業自有資本運用效能，屬於獲利性的測試指標。比率愈高，表示企業當局運用股東權益之效率高。文獻中使用這個指標的學者有 Kahya et al.(1999)。

10. 淨利對固定資產比率(Net Income to Fixed Assets) :

用以測度企業固定資產運用效能，屬於獲利性的測試指標。比率愈高，表示企業當局運用固定資產之效率高。文獻中使用這個指標的學者有 Kahya et al.(1999)。

11. 淨利對總資產比率(Net Income to Total Assets) :

用以測度企業總資產的運用效能，屬於獲利性的測試指標。比率愈高，表示企業當局運用總資產之效率高。文獻中使用這個指標的學者有 Beaver

(1966)、Ohlson (1980)、Lo (1986)及 Gombola et al. (1987)。

12. 營業利益對固定資產比率(Operating Income to Fixed Assets) :

同樣是用以測度企業固定資產運用效能，屬於獲利性的測試指標。比率愈高，表示企業當局運用固定資產之效率高。文獻中使用這個指標的學者有 Kahya et al.(1999)。

13. 營業利益對銷貨收入比率(Operating Income to Sales) :

屬於獲利性的測試指標，用以測度企業的經營效能，比例愈高者佳。文獻中使用這個指標的學者有 Theodossiou et al. (1996)。

14. 營業利益對總資產比率(Operating Income to Total Assets) :

屬於獲利性的測試指標，同樣是用來測度企業的經營效能，比例愈高者佳。文獻中使用這個指標的學者有 Altman (1968)、Altman et al. (1977) 及 Theodossiou (1993)等。

15. 保留盈餘對總資產比率(Retained Earnings to Total Assets) :

屬於長期獲利性的測試指標，用來測度企業的長期經營效能，比例愈高者佳。文獻中使用這個指標的學者有 Altman (1968)以及 Altman et al. (1977)。

16. 長期負債對總資產比率(Long-term Debt to Total Assets) :

屬於財務槓桿指標，用以測度企業資產中由債權人提供資金比率的大小，本比率並無最佳值，因為當此比率高時，可能是有些公司為把握出現的投資機會所導致，因此比率高並不一定代表公司正處於危機之中，或將來更可能發生危機。文獻中使用這個指標的學者有 Beaver (1966)以及 Altman (1968)。

17. 總負債對總資產比率(Total Liabilities to Total Assets) :

即負債比率，屬於財務槓桿指標，用以測度企業資產中由債權人提供資金比率的大小。就財務結構觀點而言，本比率愈低，對債權人的保障也愈大。總負債包含了長短期的負債，當總負債過高時，將有無法支付的窘

境。文獻中使用這個指標的學者有 Ohlson (1980)、Gombola et al. (1987) 及 Theodossiou et al. (1996)。

18. 市值對總負債比率(MVE to Total Liabilities) :

屬於市場結構指標，若企業的總負債愈多，且市值愈小，此比率將愈小，這代表企業進行的舉債融資，在投資人的眼裡，並沒有使得公司市值增加，反而代表的是經營績效不佳。文獻中使用這個指標的學者有 Altman (1968)。

19. 應收帳款對流動資產比率(Accounts Receivable to Current Assets) :

屬於管理效率性指標。在正常經營狀況下，應收帳款愈少，代表著有愈少的帳款會成為壞帳，帳目管理較有效率。文獻中使用這個指標的學者有 Kahya et al. (1999)。

20. 應收帳款對銷貨收入比率(Accounts Receivable to Sales) :

屬於管理效率性指標。應收帳款愈少，愈少壞帳發生，且現金相對較多，流動性更好。文獻中使用這個指標的學者有 Beaver (1966) 以及 Gombola et al. (1987)。

21. 固定資產對總資產比率(Fixed Assets to Total Assets) :

屬於營運槓桿指標。用以測度企業總資產中固定資產所佔比率的大小，但並無一定的標準，視行業特性而異。就資金的運用觀點而言，比率愈小愈好。文獻中使用這個指標的學者有 Theodossiou (1993)。

22. 存貨對銷貨收入比率(Inventory to Sales) :

屬於管理效率性指標。此比率愈低愈好，代表較少資金積壓在存貨上。文獻中使用這個指標的學者有 Beaver (1966)、Edmister (1972)、Theodossiou (1993) 及 Theodossiou et al. (1996) 等。

23. 銷貨收入對總資產比率(Sales to Total Assets) :

屬於活動性指標。文獻中使用這個指標的學者有 Altman (1968) 以及 Gombola et al. (1987)。

2.3 相關危機預警模型文獻回顧

2.3.1 單變量分析法

在屬於質因變數的財務分類預測之研究中，最早使用單變量統計方法來進行實證的是 Beaver(1966)。單變量分析法係利用單一的財務指標(財務比率)配合二分類檢定法(Dichotomous Classification Test)來作為衡量的工具，其進行區分的過程為分別將企業失敗前各年所計算而得之財務比率之大小順序排列，以便觀察失敗企業與未失敗企業的分佈情形，從而尋求一最佳失敗與未失敗的分界點，使分類錯誤的百分比最低。找出最佳分類點後，即可挑出錯判的企業，藉而求得歸類錯誤率。此種方法是利用無母數統計方法之 Mann-Whitney-Wilcoxon 檢定法的創意。

其後 Beaver(1968)又以單變量分析法為模式，對財務危機公司進行預測研究。其蒐集樣本公司的財務比率資料為自變數，分析失敗前一至三年財務比率如負債比率、速動比率、資產報酬率，並以此作為預測之因子。Beaver 認為，由於市場效率的不完全，最符合現實的模式最有效，也就是簡單模型可能較好。依其實證所得財務危機發生前一、二、三年的預測準確率分別為 87%、79%、77%。

2.3.2 多變量區別分析法

由於企業的財務特性是表現在多方面的，而如單變量分析法只使用單一的財務指標似乎太簡陋了，沒有任何一個財務指標可健全到概括所有的財務特性。因此，即有學者主張應該利用多重指標來建立預測模型。

Altman(1968)是首先利用逐步多元區別分析(Stepwise Multiple Discriminant Analysis)建立失敗預測模型的學者，其將二十二個財務比率逐步萃取，最後得出五種最具共同預測能力的財務比率，構成一條類似迴歸方程式的區別函數，如下所示，可產生一綜合性指標，稱之為 Z Score，

$$Z = 0.012X_1 + 0.014X_2 + 0.033X_3 + 0.0064X_4 + 0.999X_5$$

其中， X_1 ：營運資金/總資產

X_2 : 保留盈餘/總資產

X_3 : 息前稅前盈餘/總資產

X_4 : 權益市值/總負債

X_5 : 銷貨淨額/總資產。

在分類時以歸類錯誤總合最小一點作為預測失敗與成功的分界點，利用驗證樣本所求得的Z Score視是否大於分界點而將企業歸類為成功或失敗。在Altman研究中，Z score的臨界值為2.675，若大於該值則為正常公司，否則判定為失敗企業。

Altman et al.(1977)將Altman的Z Score模型加以擴充修改，將自變數擴充為另外七個，分為「資產報酬率」、「盈餘穩定性」、「利息保障倍數」、「保留盈餘對總資本比」、「流動比率」、「普通股帳面價值對總資產帳面價值比」以及「公司規模」，並用以建立「ZETA」模式。此模式在失敗前一年有高達96%的預測能力。

Deakin(1972)合併Beaver和Altman的研究。隨機抽取1964~1970年間正常與危機公司各三十二家進行研究，且利用Beaver研究中具有顯著區別能力的十四項財務比率，分別為每一年建立二次式區別函數模型(Quadratic Function)。其研究顯示，其區別效果的正確率達80%，雖自第四年起即明顯下降，但還是比單變量分析來的佳。

Blum(1974)首次對企業失敗建立了一套理論架構，認為企業為流動性資產之儲水槽(Reservoir of Liquid Assets)，當任一情況發生使得水槽的水減少時，企業發生失敗的機率將增加。其研究1954~1968年間，一百一十五家失敗公司按行業、員工數及銷貨淨額為標準配對一百一十五家正常公司，建立多變量區別模型，而變數的選取和以往不同的地方是以現金流量的概念，並考慮比率的趨勢、變異性指標(Variability Indicators)。研究顯示「現金流入量/負債總額」、「淨值/負債總額」與「兩年速動資產/存貨」的趨勢三項變數最具區別能力。而模型在失敗發生前一年與前二年的正確區別率分別為94%和80%。

何太山(民國66年)為國內第一位運用多變量區別分析建立銀行放款信用評分制度。其研究1975~1976上半年度間，自兩銀行中選擇五十五家信用優良戶，與五十二家信用不良戶，再從中抽取三十家為原始樣本，其餘為保留樣本，並以七個變數建立區別模型，研究顯示，正確區別率原始樣本與保留樣本分別為83%與91%。

2.3.3 Probit 模型

適用於二分類選擇的 Probit 模型，也可以是一種建立財務危機預測的方法，其屬於質應變數迴歸模型(Qualitative Dependent Variable Regression Model)。和古典迴歸模型不同之處在於質應變數為間斷型數值，而傳統迴歸模型之應變數為連續型。由於質應變數迴歸模型的應變數具有二項分配性質，其誤差項亦會有二項分配性質，與古典之常態假設不同。因此無法利用普通最小平方法來處理此種迴歸問題，而必須採用一般化最小平方法(Generalized Least Square Method, GLS)。又 GLS 所求得之估計值並無法保證落在 0 與 1，違反二分類假設。Probit 模型將此估計值經由標準常態分配的轉換，而成機率形態，亦即將模型轉換成事件發生之機率，同時為了使事件發生的機率為原模式之非遞減函數，故以機率分配之累積函數來表示事件發生之機率，其值將介於 0 與 1 之間。在應用時必須設定一機率臨界值 Z^* ，當 Probit 模型求出的機率值大於 Z^* ，即可視為事件發生；反之，則無事件發生¹。

陳明賢(民國 75 年)選擇了 11 家危機公司與 19 家正常公司作為樣本，利用 Probit 模型進行區別分析，其危機發生前五年的預測能力分別在 80~93.3%之間。其研究並發現以流動比率，營運資金對總負債，以及固定資產對淨值比率等之 Probit 模式，進行危機企業之預測。在預測能力及穩定性方面均較國外研究 Altman(1968)佳。

2.3.4 羅吉斯模型

羅吉斯模型與 Probit 模型在學理上相當類似，不同之處在於後者機率估計係經由標準常態分配的轉換而得，而前者則是使用羅吉斯分配(Logistic Distribution)。同樣地，在應用上必須設定臨界值，以辨別事件的發生與否。此模型的內容在本文第三章會有更詳細的介紹。

Ohlson(1980)認為在一般線性迴歸或判定分析中，需假設誤差項符合多變量常態分配，而 Logistic 模型的優點在於不論自變數或母體為間斷、連續或混合都可引用以為分析，且當自變數母體為未知或非常態時，使用

¹ 有關 Probit 模型更詳細的介紹請見 Kaplan & Urwitz (1979) 的論文。

羅吉斯模型處理判別分析較為可靠。其採取九個財務比率，包括公司規模、負債比率、淨營運資金比率、流動比率倒數、破產與否虛擬變數值、資產報酬率、最後兩年虧損與否虛擬變數值、純益變動率等。其研究結果顯示，失敗前一年的預測準確率高達 96.12%。

張正忠(民國 88 年)首先採用瀑布羅吉斯模式(Cascaded logistic model)進行預警模式之建構，並採三大構面去剖析公司是否會發生危機之指標，分別為財務比率構面、產業因素構面、及其他質性及量性因素構面，並進一步採用動態分析之方式，深入瞭解公司發生危機前財務狀況之變化時點。研究結果指出，整合得到的瀑布羅吉斯模型，其正確分類率及預測能力皆較各類型變數單獨建立之模型來的好，也顯示出此模型具有不錯的實用性。其前三年模型的預測正確率分別為 80%、76%、以及 75%。

白欽元(民國 91 年)利用羅吉斯迴歸搭配主成份分析，探討從量化的財務資料中建構出適用於中小企業的財務危機預警模式。模型中選取各三十家失敗與正常公司，及十八財務比率。在其不同子模式的研究結果顯示，整體預測正確率達 85%以上，對危機企業預測正確率最低亦有 83.3%，且發現以主成份分析後，資料構面經過縮減，對危機預警模型的解釋與預測能力有提高的效果。



2.3.5 CUSUM 財務危機預警模型

多變量CUSUM(Cumulative Sum)是一種時間數列研究方法，源自於品質管制方法上的生產品質監督系統，可以建立出一CUSUM管制圖，此方法最早經由Theodosiou(1993)的引用，結合Vector ARMA模型而建立動態化財務危機預警模式的主要架構。其主要的概念是在於研究者獲得一組符合某種分配的樣本後，常常可發現這組樣本可再分成幾個子樣本，雖然這些子樣本符合相同的分配，但是確有不同分配參數，此差異即可作為分類財務危機與正常公司的參考。已知財務危機與正常公司具有相同分配但俱有不同的參數，當接受偵測的企業之財務指標變數由符合原來正常公司參數的分配，是否動態偏離到另一具有不合格參數的同類分配時，即可判斷危機的發生與否。在應用時，不同參數的分配將有不同的CUSUM值，當企業之CUSUM值超出某危機臨界值L時，即可預期此企業會發生財務危機。CUSUM模式與

其他統計模式最大的不同處在於其不僅反映當期的財務狀況，也延續了前期的財務狀況變化，可充份表達財務危機循序發生的概念。

Theodossiou & Kahya(1999)以時間序列累積和的統計方法論為基礎，建構美國證交所和紐約證交所之製造業與零售業的定態財務危機模型。使用期望成本函數為最小之類神經網路型態搜尋方法來選變數，考慮變數由 54 個變數的集合選出的，包含二十七個原始變數及其一階差分。搜尋方法所使用的另一準財是隨時間模型的定態性，因為過去財務危機模型的財務變數大部分具有隨時間績效惡化的非定態情形。搜尋方法設計為每次允許每一種類變數一個解釋變數進入模，因為包含兩個以上相同種類的變數不被預期顯著增進模績效。最佳定態累積和模型藉由包含四個解釋變數的搜尋程序產生「平減總資產取對數的變動」、「存貨銷貨收入比率的變動」、「固定資產總資產比率的變動」、「營運收入 銷貨收入比率的變動」，模型表現結果和最要非定態模型一樣皆具有良好的平均績效。此模型具有區別公司財務變數之變動是因為「序列相關」，或是因為「財務危機所導致平均數結構永久轉變」的能力。檢定結果顯示模型隨時間是穩健的，而且優於以線性判別分析與邏輯特統計方法為基礎的模型。

徐淑芳(民國 87 年)以多變量 CUSUM 時間序列分析建立預警模式，採用多構面、較長期的財務資訊，以提高模式預警能力。採用因素分析萃取因素後再以因素分析轉換的結果建立預警式，涵蓋較廣泛的相關資訊，提高模式預警能力。實證顯示可達到 90.48%的預測正確率。

張隆鐘(民國 82 年)針對掌握長時間以來序列性發生的財務危機訊息，以多變量 CUSUM 模式為基礎，發展一套動態化財務危機預警模式，用以進行財務危機之控制與預防。其以國內股票上市公司為樣本母體，進行動態化預警模式的實證研究，研究結果顯示，(1)財務危機企業之存貨對銷售額比率與固定資產對總資產比率，平均而言高於財務健全企業之比率。(2)財務危機企業之每股盈餘對每股市價比率、營運資金對總資產比率、與營業利益 對總資產比率，平均而言低於財務健全企業之比率。(3)經以兩家財務危機企業之財務資料做模式驗證的結果，財務危機企業之累積 CUSUM 分數，在時間變化過程中呈現出急速退化的現象，其在變更股票交易方式之前，累積 CUSUM 分數即已退化至危機臨界值以下。

2.3.6 EWMA 模型

EWMA類似CUSUM模式係源自於品質管制學門中，統計製程管制 (Statistical Process Control, 簡稱SPC)是監控制程品質非常重要的一種方法，其利用樣本資料來監視製程變動的情形，以期儘早發現製程之異常現象再著手進行製程之改善，以減少不必要的品質損失。傳統的管制圖 - 蕭華特管制圖 (Shewhart Control Chart) 是利用個別之樣本觀測值藉以判斷製程是否在管制的狀態內，由於此一管制方法只考慮用個別觀測值來偵測製程的變動，故適用於對製程較大變動之偵測；然而，對於微量變動，便無法快速偵測出異常。為了改善此缺點，Robert (1959) 提出指數加權移動平均管制圖 (Exponentially Weighted Moving Average Control Chart, 簡稱EWMA管制圖)，此係將資料中的每一觀測值給予其權數，並透過加權平均的觀念將過去資料之訊息考慮進來，以使得權數呈指數遞減之形式，因而當時稱作幾何移動平均管制圖 (Geometric Moving Average Control Chart)。EWMA為一特殊時間序列模型，除了在品質管制上有監控品質的功能外，也可用於財務危機的預測，具有較CUSUM管制圖易於解讀的優點。EWMA模式是採用加權的概念，首先利用VARMA中參數估計的結果帶入其計算式中求得EWMA值，而當EWMA值落到下界-L以下，則會被判定為危機公司。

金慧貞 (民國 90 年) 首先採用多變量 EWMA 模式，進行財務危機預警模式之建立，再進一步驗證此模式之預測能力。實證結果顯示，總體來說，EWMA 模式在測試樣本方面之預測正確率為 85.71%，顯示此模式具有不錯的預測能力，且與其他相關研究常用之 CUSUM 模式有類似的表現。

2.3.7 比例危險模型

Cox 於 1972 年提出比例危險模式 (Proportional Hazards Models, PHM)，屬於隨機過程模型 (Stochastic Process Model)，但其假設時間函數不會影響危險率 (Hazard Rate)，而危險率為計算存活機率的主要參數。此模型主要是利用修正的存活函數 (Survival Function) 求出各樣本存活機率或失敗機率 (存活機率與失敗機率的和為一)，並設定一臨界值，其值可以是下市公司佔樣本之比例，當個別樣本的失敗機率大於臨界值時，即

歸類為失敗;反之為存活。此模型首先利用 Cox 迴歸分析(Cox's Regression Model)求得上市公司有哪些公司指標或市場因素會影響日後其存活,在得出哪些變數為顯著後,即用以修正存活函數,並求得各公司樣本的存活機率,預測上市公司是否歸類為存活。

王宗興(民國 90 年)於台灣上市公司股票上市後存活分析中,利用 Cox(1972)提出的比例危險模型進行台灣上市公司股票上市後存活分析實證研究。此乃國內首篇研究文獻以上市公司上市時點的「公司屬性」與「市場特質」等可能影響存活反應的預後因子(Prognostic Factor)來分析預測上市後在交易所的存活期。係利用台灣 238 家上市公司股票樣本進行分析,觀察樣本截至九十一年三月底,共計二十六家存活失敗終止上市,二百一十二家仍舊存活於證券交易所掛牌買賣。實證顯示,上市時的發行規模、內部人持股比例及初始股價報酬率與上市後存活期具有顯著相關,可作為解釋上市存活能力的預後因子,且正確區別能力達 65.55%。

2.3.8 加速失敗時間模型

類似於比例危險模型,加速時間模型(Accelerated Failure Time Model)也發始於 Cox(1972),屬於隨機過程模型,但重視的是時間對相關參數的影響,假設了危險率除了分別受時間及共變數之影響外,與此二者的交互作用也有相關,且不同的機率分配設定,有其不同的危險率相對應,常用的分配如 Gamma, Weibull, Lognormal, Exponential Distribution 等。在區別預測方面與比例危險模型相同,是以危機公司佔樣本之比例為臨界值,比較由模型所求得之失敗機率。

蔡龍學(民國 80 年)於上市公司財務預警模式研究中,應用加速失敗時間模型,以一百零九家上市公司為樣本,挑選二十項財務比率,以因素分析萃取出主要變數。其結果顯示,失敗企業具有一些特質與正常企業不同,如流動性偏低、舉債比率過高、企業經營能力低落與獲利能力不佳等特質。在失敗前一年模式中的預測正確率為 80.73%,其前二年模式中的預測正確率為 80.73%。在有關失敗時點的預測,實證結果顯示預測之存活期間往往低於實際存活期間。

陳渭淳(民國 89 年)於上市公司失敗預測之實證研究中,考慮個別失敗

企業存活函數，利用 GGD 母系下四種分配(Gamma, Weibull, Lognormal, Exponential)及具非單調危險函數特質之 Loglogistic 分別進行配適度測試、存活相依性檢定、影響存活期間因子判定與失敗危險函數估計及失敗時點預測。利用加速失敗時間模型建立本土化的失敗預測，實證結果顯示董事會結構特性、速動比率具有顯著相關性，其模型的預測正確率為 56.67%。

2.4 類神經網路危機預測模型文獻

Salchenberger et al. (1992) 利用倒傳遞網路模型來發展儲貸機構 (Savings and Loan Associations) 的倒閉預警模型。模型結構為一個輸入層，一個內含三個結點的隱藏層，以及一個輸出層。在自變數的選擇方面，則與在研究中做為比較預測能力的羅吉斯模型一樣，引用了五個財務比率。該研究蒐集了兩百家財務比率樣本做為模型訓練用，其中倒閉與非倒閉機構各一百家。另外也蒐集了四百零四家樣本做為模型驗證用，其中倒閉者七十五家，非倒閉者三百二十九家。研究結果顯示，在以 0.5 作為區別值 (Cutoff) 或稱判別值 (Threshold Value) 時，倒傳遞網路的準確度是 96.8%，羅吉斯模型則是 94.3%。在區別值是 0.2 時，前者是 95.8%，後者則是 92.3%。

Tam & Kiang(1992) 利用類神經網路進行銀行危機的預測，並與傳統的危機模型比較預測準確度。該研究使用的類神經網路倒傳遞模型，結構為一個輸入層，一個內含十三個結點的隱藏層，以及一個輸出層。在自變數及樣本的選取方面，使用了銀行危機預測文獻中曾舉用過共十九種財務比率，並找了各五十九家的倒閉與非倒閉銀行，共一百一十八家銀行作為模型的訓練樣本，且另找了各二十二家的倒閉與非倒閉銀行，共四十四家銀行作為模型的準確度的測試樣本。研究結果顯示，針對測試樣本利用前一年的財務比率進行銀行倒閉預測的失敗率只有 14.8%，也較多變量區別分析模型的 15.9% 及羅吉斯模型的 18.2% 為低。

Udo(1993) 在其預測公司倒閉的研究中，利用了倒傳遞網路做為其危機預警模型，該模型引用了十六個其它較早文獻曾使用過的財務比率做為釋解變數。網路結構亦為三層，其中隱藏層含有四個節點。在樣本的選取

上，選擇了各 200 家的倒閉與非倒閉公司，共 400 家公司作為模型的訓練樣本，且另找了各 50 家的倒閉與非倒閉公司，共 100 家公司作為模型的準確度的測試樣本。研究結果顯示，利用訓練出來的倒傳遞模型來對測試樣本進行預測，發現前一年的財務比率的準確度高達 94.7%，前二年的財務比率則是 82%，而一般迴歸模型則分別為 80%及 72%。

Atiya(2001) 蒐集了四百四十四家倒閉公司及七百一十六家非倒閉公司，共一千一百六十家公司。其中選取訓練樣本四百九十一家，驗證樣本六百六十九家，且兩者中倒閉公司對非倒閉公司比率皆為 62%。類神經網路模型依所選用的自變數而分為以「財務比率為基礎」以及「以價格比率為基礎」兩類自變數集合模型，而在財務比率的選取時間上，則遍及了被預測時點的前一個月至三十六個月廣泛的期間，並粗分為(1)六個月以內、(2)六至十二個月、(3)十二至十八個月、(4)十八至二十四個月、(5)超過二十四個月五種集合。因此其預測模型依不同變數集合、不同時間集合將有 $2 \times 5 = 10$ 種。研究結果顯示，「財務比率為基礎」模型的預測準確率依時間分別為(1)90.77%、(2)87.04%、(3)80.95%、(4)65.63%及(5)57.14%；「以價格比率為基礎」模型的預測準確率依時間分別為(1)86.15%、(2)81.48%、(3)74.60%、(4)78.13%及(5)66.67%。

楊浚泓(民國 90 年)於考慮財務操作與合併報表後之財務危機預警模式中，除了採用傳統的財務比率外，亦增加了大股東質押比、子公司購回母公司股票、及短期投資比例三項財務操作變數，並考慮合併報表與一般報表的差異性。實證顯示，加入了財務操作指標後，在類神經網路預測模式下整體公司的正確預測率由 90.625%提升到 93.75%。

唐筱菁(民國 90 年)於整合財務比率與智慧資本指標建構企業危機預警系統- MARS 與類神經網路之應用中，透過無母數方法 - 多元適應性雲形迴歸及人工智慧工具 倒傳遞類神經網路方法的使用，建立一整合財務比率及智慧資本指標的企業危機診斷模型。實證結果顯示，加入智慧資本指標有助於偵測企業危機的發生，提昇模型鑑別效果；而二階段整合模式無論在個別或整體判別正確率均優於單一模式之結果。各種模式的預測率均在 75%以上。

三、研究方法

本研究主要是利用類神經網路來建立危機預警模型。類神經網路有兩個主要的特徵：第一，神經網路具有可適應性(Adaptive)及可學習(Trainable)的功能。第二，神經網路是一巨型平行處理系統，俱有高速運算及容錯運算的特性。在本研究的實證過程中，採用的是多層型類神經網路並搭配倒傳遞演算法進行模型的訓練，以求達到最佳的預測準確度。此外，也將利用傳統上預測效果最佳的羅吉斯迴歸，配合逐步求解法後建立另一危機預警模型，用以作為類神經網路在預測準確度上的比較。

3.1 類神經網路 - 倒傳遞法

本節將介紹倒傳遞類神經網路的發展，首先是自然界的腦神經網路的運作，再來則是類神經網路如何模倣腦神經網路的運作而建立的運作模式，最後則是介紹倒傳遞類神經網路的演算法及其在財務上的應用。



3.1.1 腦神經網路

神經網路(Neural Network)是用來指明連接各個神經元(Neuron)的網路。神經元主要由神經細胞核(Soma)、神經軸(Axon)、神經樹(Dendrites)、及神經節(Synapses)所構成。人腦中主管思考辨識的大腦皮層中，大約含有 10^{11} 個神經細胞，細胞間利用神經樹相連，相接的點即為神經節，每個細胞大約有一千個神經節，神經節可說是神經網路上的記憶體，神經網路上的知識是貯存在這節點上的，而兩細胞間的信號係經由神經樹所傳遞。神經網路俱有學習的功能，當外界刺激神經細胞而產生的信號電流通過兩神經樹上的神經節時，會去改變節點上的權重(是一種化學能)，在人的認知及辨識學習過程中，外界變化的刺激所產生的電流反覆在網路上流動時，節點上的權重會隨之改變，然而會慢慢的趨向穩定，此時學習即告完成。往後當外界進入的信號電流值與貯存在神經網路上的權值相符時，外界的事物便會為神經網所辨識出來。大腦因為有這樣複雜連結架構，所以被公認為世界上最複雜的生物機械。

3.1.2 類神經網路

類神經網路(Artificial Neural Networks, ANN)是從生物學上所得到的靈感，主要是模仿腦神經網路(Neural networks, NN)的架構，利用簡單神經元式的處理器(Neural Processor)，組成大量平行計算架構(Massive Parallel Architecture)。主要的想法是來自於人腦在圖型及語音辨識方面遠比數位電腦來的優秀，科學家認為人腦中必定有某種計算原理，才能完成這種高速的圖型及語音辨識。類神經網路即是要了解這種計算原理，以設計出功能強大的計算系統。隨著神經解剖學及神經生理學、心理學的進步，科學家可以利用有關腦神經組織的運作方式，建立數學模型及學習法則，來模擬腦神經的功能。在 1943 年，McCulloch 和 Pitts 首次提出類神經網路之系統研究。在 1947 年，他們以圖形辨識作為網路探討之範例。他們所研究的系統架構，大都如下圖所示之簡單神經元模式²。

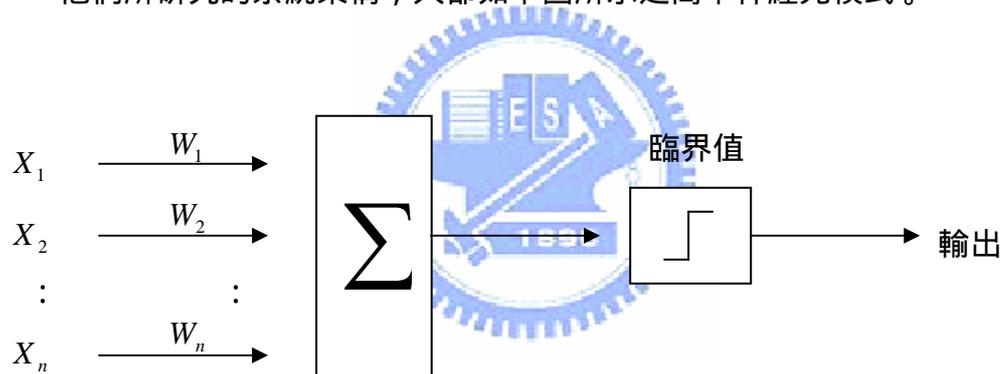


圖 2 簡單神經元模式

類神經網路架構中存在着所謂的類神經元(Artificial Neuron)，用以模仿腦神經元簡單的特性，當信號傳入神經元，每個輸入的信號皆乘上其所對應出的已訓練權衡值，所有經過權衡值的信號相加後，即可以進行辨別工作。在 1949 年時，Hebb 提出了學習法則(Learning Algorithm)，在當時是最早且唯一用科學方法證明類神經網路具學習能力的學者，為類神

²有關類神經網路的發展史更詳細的介紹，請見盧炳勳等(民國 81 年)著之「類神經網路理論與應用」以及靳蕃等(民國 81 年)著之「神經網路與神經計算機」。

經網路訓練法則的鼻祖，今天大部分更複雜更有效率的訓練法則都是從 Hebb 所提出的學習法則所演變而來。該法則介紹了權衡值會根據來源及目的神經元的輸出而進行調整，其調整方式如下式所示：

$$W_{ij}(n+1) = W_{ij}(n) + \alpha \text{OUT}_i \text{OUT}_j$$

其中，

$W_{ij}(n)$ ：調整之前第 i 個神經原至第 j 個神經原之間的權衡值，

$W_{ij}(n+1)$ ：調整之後第 i 個神經原至第 j 個神經原之間的權衡值，

α ：學習速率常數，

OUT_i ：第 i 個神經原的輸出，同時它也是第 j 個神經原的輸入，

OUT_j ：第 j 個神經原的輸出。

類神經網路架構上可分為單層網路 (Single Layer Artificial Neural Networks) 及多層網路 (Multilayer Artificial Neural Networks)。雖然單一個類神經元具有簡單的圖樣辨識能力，然而真正具有神經計算功能則必須將類神經元連接成類神經網路，最簡單的網路是由一群類神經元組成單層網路，如【圖 3】所示，此為一層的類神經網路，由下至上看似是兩層網路，但下邊的圓點其作用只是負責分配輸入信號，並無計算的能力，所謂的一層是指一組權衡值與其後所連接的神經元而言因此在類神經網路的定義中，輸入層不可算為一層，在此為方便說明，故標為輸入層。若輸出向量 Y 沒有再經特定函數轉換，則將等於輸入向量 X 乘以加權值向量 W 。輸入向量融入權衡值後即提供為輸出層的輸入值，而由於輸出層已是最後一層，故此輸入值將等於輸出層的輸出值，由圖中可見每個輸入向量皆會參與輸出層上各節點的計算。

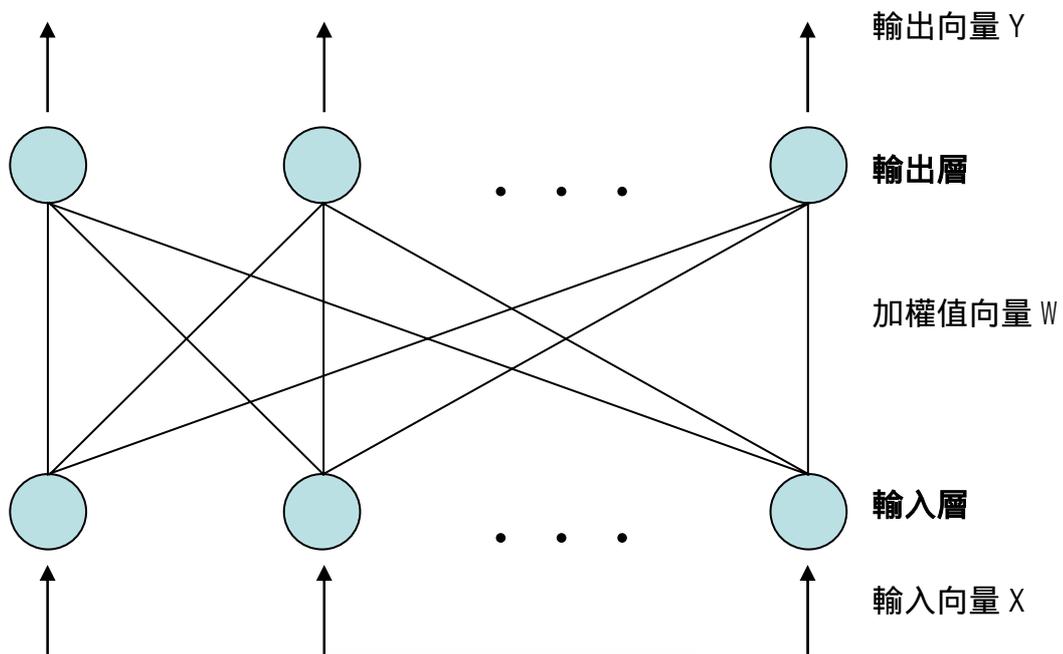


圖 3 單層類神經網路架構

多層類神經網路係將類神經元排列，以模仿腦神經分層式的結構，這些多層類神經網路的能力已經被證明比單層類神經網路具備有更強大的計算能力。多層類神經網路可以由兩個以上的單層網路串接而成，將前一層的輸出信號作為下一層的輸入信號，經處理後再次輸出信號。以兩層類神經網路為例，可如【圖 4】所示，由輸入向量至隱藏層為一層，由隱藏層至輸出層為第二層，同樣地，在圖中的輸入層只是為方便說明輸入向量的位置，其並不代表為一層。輸入向量中的每一個成分皆參與隱藏層中各節點上輸入值的計算，此輸入值又將作為隱藏層中各節點的輸出值，隱藏層的各輸出值又繼續參與下一層，亦即輸出層各節點上輸入值的計算，此第二個輸入值又將等於輸出層的最後輸出值。

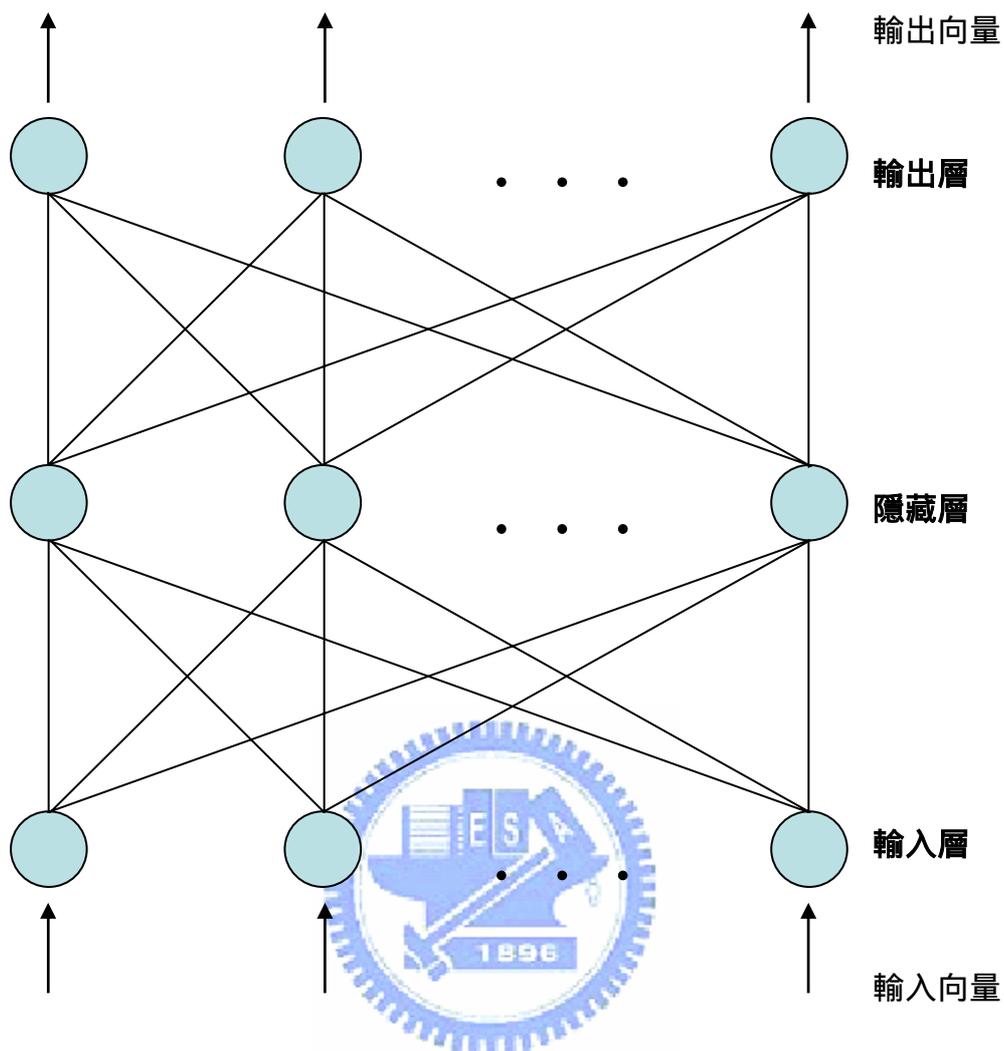


圖 4 兩層類神經網路架構

類神經網路在訓練上可分為監督式訓練(Supervised Training)及非監督式訓練(Unsupervised Training)，監督式的訓練必須事先知道目標向量(Target Vector)，將輸入向量跟目標向量兩者稱為一個訓練對(Training Pair)。一個類神經網路的訓練經常需要很多的訓練對，當一組輸入向量放進去之後，就可以計算網路的輸出，並比較目標向量，而計算兩者之間的誤差。此誤差會由後往前一層一層的傳遞，權衡矩陣就會依據某種學習法則來調整，以便達到誤差最小。訓練對一組組餵進去，每次計算其誤差並調整權衡矩陣，一直到全部的訓練對都餵進去之後，計算全體的誤差總和，若低於某一容忍值則訓練完成，否則需重複此一程序一直到收斂為止。雖然監督式的訓練已經有很多成功的運用例，但是它仍被批評在生物學上很難實行，因為很難想像腦子裡面的訓練機構能夠比較正確的

輸出跟真實的輸出，並將誤差往後傳遞回去。如果腦子裡面有這種機構，那目標向量又從何而來呢？非監督式訓練比較接近生物神經系統的學習方式，它是由 Kohonen 等科學家所研究出來，它不需要目標輸出向量，因此不用跟實際輸出向量比較，訓練資料純粹由輸入信號組成。訓練的法則是修正網路的權衡矩陣以產生一致的輸出向量，所謂一致的輸出向量就是不論是輸入訓練向量或接近訓練向量都會得到相同的輸出向量。這種訓練的方式是將訓練資料及與其統計性質相類似的向量歸為一類，將某一類的訓練資料輸入，會得到一個輸出向量，但是訓練之前無法得知該訓練資料會產生怎樣的輸出向量。因此，在完成網路的訓練之後，必須將網路轉換成較易理解的型式，而這工作並不難，確認一個網路的輸入-輸出之間的關係非常簡單。

3.1.3 倒傳遞學習法

在倒傳遞法(Back-propagation)出現以前，1970 年代至 1980 年代初期類神經網路的研究領域曾陷入低潮，原因是當時研究的單層的類神經網路不能求解許多用普通方法就可以解得的簡單問題。當時也曾考慮以多層的類神經網路來求解，但在訓練上卻苦無合理的學習法則，因為必須有目標向量才能進行訓練，但多層網路中的隱藏層卻無目標向量，以致無法以那時的學習法則進行訓練，一直到倒傳遞學習法的發明才解決這個問題。倒傳遞學習法的出現，對於類神經網路的復甦扮演極重要的角色，它對於多層網路的訓練不愧是一種非常有系統的方法，唯一的限制是其數學式較難理解。但不可否認的是該學習法的成就是非常顯著的，其延伸了類神經網路的應用範圍，非常多的運用已被各種研究領域所開發出來。倒傳遞學習法目的是調整權衡值，使得一群輸入加進去後能夠產生想要的輸出。其利用縮小誤差為依據以調整權衡值，而縮小誤差的方法則是所謂的「最陡坡降法(The Gradient Steepest Descent Method)」。此外，為了能在模型中應用最陡坡降法，倒傳遞法將輸出值以平滑可微分的轉換函數進行轉換。以下將詳細介紹倒傳遞法³。

³ 倒傳遞法的介紹及數學推導參考自葉怡成(民國 82 年)所著「類神經網路模式應用與實作」。

1. 網路架構

倒傳遞類神經網路的架構同樣地如【圖四】所示，包括了以下各層：

輸入層：用以表現網路的輸入變數，其處理單元數目依問題而定。使用線性轉換函數，即 $f(x) = x$ 。在此為方便說明，把輸入層亦視為一層。

隱藏層：用以表現輸入處理單元間的交互影響，其處理單元數目並無標準方法可以決定，經常需以試驗方式決定其最佳數目。使用非線性轉換函數。網路可以不只一層隱藏層，也可以沒有隱藏層。

輸出層：用以表現網路的輸出變數，其處理單元數目依問題而定。使用非線性轉換函數。

倒傳遞網路最常用於轉換輸出值的非線性轉換函數為雙彎曲函數

(Sigmoid Function), $f(x) = \frac{1}{1+e^{-x}}$, 函數圖形如【圖 5】所示，此函數當自變數趨於正負無限大時，函數值趨於常數，其函數值域在 $[0, 1]$ 之間。

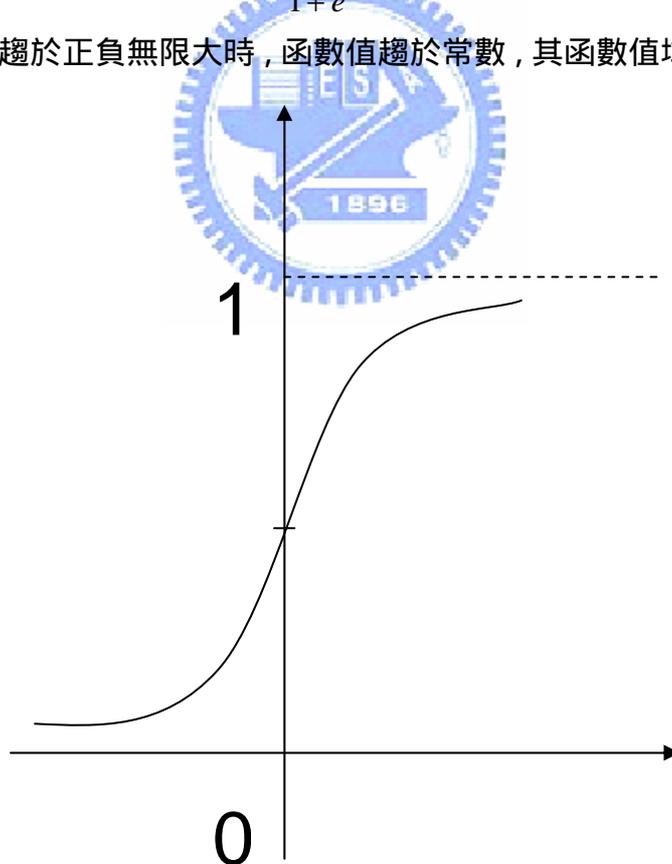


圖 5 雙彎曲函數圖形

2. 訓練步驟概述

在一個包含了一個輸入層、多個隱藏層、及一個輸出層的多層網路中，訓練倒傳遞網路需要以下步驟：

- (1) 從被訓練組中選擇一個訓練對(一對輸入向量和目標向量)，送到網路的輸入層。
- (2) 計算網路的輸出
- (3) 計算網路輸出與目標值的之間的誤差。
- (4) 依據某種方式來調整網路的權衡值，使得誤差最小。
- (5) 針對每一個訓練重複步驟 1 至 4，直到整組的誤差在一個容忍值以下。

在上述步驟中，存在著順向傳遞(Forward Pass)及逆向傳遞(Reverse Pass)兩種傳遞方式。之中的步驟 1 及 2 為順向傳遞，傳遞方法是信號由輸入層進入網路後，由第一層乘上權衡值後計算而得到輸出，此輸出被當成後一層的輸入，到達後一層後乘上該層權衡值而再次得到輸出，如此一層一層地傳遞下去，直至到達輸出層為止。步驟 3 及 4 則是逆向傳遞，是指誤差信號往後傳遞，逆向的一層一層的傳遞，到達各層時即調整該層的權衡值。利用誤差信號往後傳遞的方法，解決了隱藏層無目標向量即無法訓練多層網路的問題。

3. 網路演算法

以下將說明倒傳遞演算法如何應用一個訓練範例的一輸入值向量 X ，與一目標輸出向量 T ，修正網路加權值 w ，而達到學習的目的。在倒傳遞網路中，第 n 層的第 j 個單元的輸出值為第 $n-1$ 層 i 個單元輸出值的非線性函數：

$$A_j^n = f(\text{net}_j^n) \quad (1)$$

$$\text{其中 } \text{net}_j^n = \text{集成函數} = \sum_i W_{ij} A_i^{n-1} - \theta_j \quad (2)$$

f = 轉換函數

i = 第 $n-1$ 層的單元數

$j =$ 第 n 層的單數。

由於監督式學習旨在降低網路輸出單元目標輸出與推論輸出值之差距，所以一般以下列的誤差函數表示學習的品質：

$$E = (1/2) \sum_j (T_j - A_j)^2 \quad (3)$$

其中 $T_j =$ 輸出層目標輸出值

$A_j =$ 輸出層推論輸出值。

因此網路的學習過程變成上述能量函數最小化的過程，通常以最陡坡降法來使能函數最小化，即每當輸入一個訓練範例，網路即小幅調整加權值的大小，調整的幅度和誤差函數對該加權值的敏感程度成正比，即與誤差函數對加權值的偏微分值小成正比：

$$\Delta W_{ij} = -\eta \cdot \frac{\Delta E}{\Delta W_{ij}} \quad (4)$$

其中 W_{ij} 是介於第 $n-1$ 層的第 i 個處理單元，與第 n 層的第 j 個處理單元間的連結加權值。

$\eta =$ 學習速率 (Learning Rate)，控制每次以最陡坡降法最小化誤差函數的步幅。

而 $\partial E / \partial W_{ij}$ 可用微積分學的連鎖法則而得

$$\frac{\partial E}{\partial W_{ij}} = \left(\frac{\partial E}{\partial net_j^n} \right) \left(\frac{\partial net_j^n}{\partial W_{ij}} \right) \quad (5a)$$

$$\frac{\partial E}{\partial W_{ij}} = \left(\frac{\partial E}{\partial A_j^n} \right) \left(\frac{\partial A_j^n}{\partial net_j^n} \right) \left(\frac{\partial net_j^n}{\partial W_{ij}} \right) \quad (5b)$$

其中

$$\frac{\partial net_j^n}{\partial W_{ij}} = \frac{\partial}{\partial W_{ij}} \left(\sum_k W_{kj} A_k^{n-1} - \theta_j \right) = A_i^{n-1} \quad (6)$$

$$\frac{\partial A_j^n}{\partial net_j^n} = \frac{\partial}{\partial net_j^n} f(net_j^n) = f'(net_j^n) \quad (7)$$

而 $\frac{\partial E}{\partial A_j^n}$ 則可分為二種情況：

(1) 第 n 層即為最終層，即網路的輸出層：

將第(3)式代入第二項得

$$\frac{\partial E}{\partial A_j^n} = \frac{\partial}{\partial A_j^n} \left[(1/2) \sum_k (T_k - A_k^n)^2 \right] = -(T_j - A_j^n) \quad (8)$$

(2) 第 n 層不是最終層，是網路的隱藏層之一，可利用連鎖律得：

$$\frac{\partial E}{\partial A_j^n} = \sum_k \left(\frac{\partial E}{\partial net_k^{n+1}} \right) \left(\frac{\partial net_k^{n+1}}{\partial A_j^n} \right) \quad (9)$$

將第(2)式代入第二項得

$$\frac{\partial net_k^{n+1}}{\partial A_j^n} = \frac{\partial}{\partial A_j^n} \left(\sum_i W_{ik} A_i^n - \theta_k \right) = W_{jk} \quad (10)$$

為了簡明定義

$$\frac{\partial E}{\partial net_k^n} = -\delta_k^n \quad (11)$$

將第(10)、(11)式代入第(9)式得

$$\frac{\partial E}{\partial A_j^n} = -\sum_k \delta_k^{n+1} \cdot W_{jk} \quad (12)$$

總結 $\frac{\partial E}{\partial W_{ij}}$ 可分成二種情況：

(1) W_{ij} 處於輸出層與隱藏層之間

將第(6)、(7)、(8)式代入第(5b)式得

$$\frac{\partial E}{\partial W_{ij}} = -(T_i - A_j^n) \cdot f'(net_j^n) \cdot A_i^{n-1} \quad (13)$$

若將第(6)式、(11)式代入第(5a)式得

$$\frac{\partial E}{\partial W_{ij}} = -\delta_j^n \cdot A_i^{n-1} \quad (14)$$

比較第(13)式與第(14)式得

$$\delta_j^n = (T_i - Y_i) \cdot f'(net_j^n) \quad (15)$$

(2) W_{ij} 處於隱藏層與隱藏層之間

將第(6)、(7)、(12)式代入第(5b)式得

$$\frac{\partial E}{\partial W_{ij}} = \left[-\sum_k \delta_k^{n+1} \cdot W_{jk} \right] \cdot f'(net_j^n) \cdot A_i^{n-1} \quad (16)$$

另可將第(6)、(11)式代入第(5a)式得

$$\frac{\partial E}{\partial W_{ij}} = -\delta_j^n \cdot A_i^{n-1} \quad (17)$$

比較第(16)式與第(17)式得

$$\delta_j^n = \left[\sum_k \delta_k^{n+1} \cdot W_{jk} \right] \cdot f'(net_j^n) \quad (18)$$

因此不論 W_{ij} 處於輸出層與隱藏層之間，或 W_{ij} 處於隱藏層與隱藏層之

間， $\frac{\partial E}{\partial W_{ij}}$ 均可寫成通式

$$\frac{\partial E}{\partial W_{ij}} = -\delta_j^n \cdot A_i^{n-1} \quad (19)$$

其中

A_i^{n-1} = W_{ij} 所連接之較低層的處理單元之輸出值

δ_j^n = W_{ij} 所連接之較上層的處理單元之差距量

=若連接的是輸出層與隱藏層，則 $\delta_j^n = (T_i - Y_i) \cdot f'(net_j^n)$ ；若連接的

是隱藏層與隱藏層，則為 $\delta_j^n = \left[\sum_k \delta_k^{n+1} \cdot W_{jk} \right] \cdot f'(net_j^n)$ 。

將第(19)式代入第(4)式得

$$\Delta W_{ij} = \eta \cdot \delta_j^n \cdot A_i^{n-1} \quad (20)$$

此式即倒傳遞演算法之關鍵公式。

如果非線性轉換函數使用雙彎曲函數(Sigmoid Function)

$$f(x) = \frac{1}{1 + e^{-net_j}} \quad (21)$$

$$\text{則 } f'(net_j) = f(net_j) \cdot [1 - f(net_j)] \quad (22)$$

將第(22)式代入第(20)式得

δ_j^n =若連接的是輸出層與隱藏層，則 $\delta_j^n = (T_j - Y_j) \cdot Y_j(1 - Y_j)$ ；

若連接的是隱藏層與隱藏層，則 $\delta_j^n = \left[\sum_k \delta_k^{n+1} \cdot W_{jk} \right] \cdot H_j \cdot (1 - H_j)$ 。

其中 Y = 輸出層處理單元的輸出值。

H = 隱藏層處理單元的輸出值。

同理可證

$$\Delta\theta = -\eta \cdot \delta_j^n \quad (23)$$

此學習過程通常以一次一個訓練範例的方式進行，直到學習完所有的訓練範例，稱為一個學習循環，一個網路可以將訓練範例反復學習數個學習循環，直至達到收斂。

4. 倒傳遞法學習步驟的數學模式

數學表達的倒傳遞學習步驟如下：

- (1) 設定網路參數。
- (2) 以均佈隨機亂數設定權衡值矩陣 $W_{_xh}$ 及 $W_{_hy}$ ，與偏權值向量 $\theta_{_h}$ 及 $\theta_{_y}$ 初始值。
- (3) 輸入一個訓練範例的輸入向量 X ，與目標向量 T 。
- (4) 計算推論輸出向量 Y 。

(a) 計算隱層輸出向量 H

$$net_h = \sum_i W_{_xh_{ih}} \cdot X_i - \theta_{_h}$$

$$H_h = f(net_h) = \frac{1}{1 + \exp^{-net_h}}$$

(b) 計算推論輸出向量 Y

$$net_j = \sum_h W_{_hy_{hj}} \cdot H_h - \theta_{_y}$$

$$Y_j = f(net_j) = \frac{1}{1 + \exp^{-net_j}}$$

(5) 計算差距量 δ

(a) 計算輸出層差距量 δ

$$\delta_j = Y_j(1 - Y_j)(T_j - Y_j)$$

(b) 計算隱藏層差距量 δ

$$\delta_h = H_h(1 - H_h) \sum_j W_{hy_{hj}} \delta_j$$

(6) 計算加權值矩陣修正量 ΔW , 及偏權值向量修正量 $\Delta\theta$

(a) 計算輸出層加權值矩陣修正量 ΔW_{hy} , 及偏權值向量修正量 $\Delta\theta_{y_j}$,

$$\Delta W_{hy_{hj}} = \eta \delta_j H_h$$

$$\Delta\theta_{y_j} = -\eta \delta_j$$

(b) 計算隱藏層加權值矩陣修正量 ΔW_{xh} , 及偏權值向量修正量 $\Delta\theta_{h_i}$,

$$\Delta W_{xh_{ih}} = \eta \delta_h X_i$$

$$\Delta\theta_{h_i} = -\eta \delta_h$$

(7) 更新加權值矩陣 W , 及偏權值向量 θ

(a) 更新輸出層加權值矩陣 W_{hy} , 及偏權值向量 θ_{y_j}

$$W_{hy_{hj}} = W_{hy_{hj}} + \Delta W_{hy_{hj}}$$

$$\theta_{y_j} = \theta_{y_j} + \Delta\theta_{y_j}$$

(b) 更新隱藏層加權值矩陣 W_{xh} , 及偏權值向量 θ_{h_i}

$$W_{xh_{ih}} = W_{xh_{ih}} + \Delta W_{xh_{ih}}$$

$$\theta_{h_i} = \theta_{h_i} + \Delta\theta_{h_i}$$

(8) 重覆步驟(3)至(7) , 直到收斂(誤差不再有明顯變化)或執行一定數目

的學習循環。

4. 在財務領域的應用

雖然最是在科學領域，但倒傳遞類神經網路在財務預測領域上的應用已是非常廣泛，可由葉怡成(民 86)所整理其在財務管理相關之預測用途上得知。這些用途簡述如下：

(1) 國庫券利率預測

係利用消費者物價指數、國民生產毛額、M2 貨幣供給率等指標作為輸入變數，即輸入層的結點數，並採用國庫券利率的多季移動平均值作為輸出變數，即輸出層的結點數，搭配適當的隱藏層後，以現有的實際數據經訓練，建立國庫券利率預測模型，可用以預測未來的利率走勢。

(2) 收盤指數預測

利用前一日、前二日、或前三日以上的開盤指數、最高指數、最低指數、收盤指數、及成交值等作為輸入變數，並以目標日之收盤指數變化率作為輸出變數，如此建立了收盤指數預測系統，可供投資人進行投資決策。

(3) 個人信用評估

利用孩子數目、職業別、房屋數、月收入、月支出、銀行帳戶數、銀行信用卡數、付款情形等作為輸入變數，以付款分類作為輸出變數，如{1,0,0}代表拖延很久才付款，{0,1,0}代表拖延數日才付款，{0,0,1}代表準時付款，可看出此時的輸出層為三個節點數。如此建立的模型可用以預測一個信用卡申請人的付款信用。

(4) 債券評等

可以利用一家企業的財務比率，如負債/(現金+資產)、銷貨/淨值、流動資動資本、過去的收益成長、負債率、利潤/固定成本等，作為輸入變數，而信用等級分類則作為輸出變數，如此所建立的模型，企業將可用以預測新發行債券的評等，並進而訂立其發行利率，避免因高估利率而增加成本，或低估而導致發行成果不佳。

3.2 羅吉斯迴歸概述

羅吉斯迴歸模型 (Logistic Regression Model)，在統計分析應用已有很多年，羅吉斯迴歸早期由J.Berkson 於1944年所創，但是從1967年以後，羅吉斯迴歸才漸漸普遍，現在對於二元的離散資料，尤其在醫學、生物統計方面使用較為廣泛，後續學者加以推廣應用於行銷及財務中，羅吉斯迴歸分析與區別分析同樣都可以解決分類變數的問題，但就分析方法及使用限制而言，使用區別分析時所有的解釋變數皆需符合常態分配，而羅吉斯迴歸分析方法則不必受到常態分配的限制，使用彈性較大。迴歸分析是描述一個應變數與一個或多個預測變數之間的關係式，它是資料分析最重要的工具，當我們探討結果的應變數是離散型，其分類只有兩類或少數幾類時，以羅吉斯迴歸做分析，在很多領域已變成標準的分析方法。Logistic 迴歸分析的目的有二，一在求取具顯著解釋能力的自變數，二是透過所構建的模式，利用自變數來預測應變數發生的機率。

在本研究中，將應變數 Y 定義為“是否發生財務危機”，它是一個離散變數，企業發生財務危機時，其值為1；企業財務正常時則為0。兩種變數的關係可以由下列多項式表示：

$$Y = f(X) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_k X_k ,$$

今令 P 表示為成功 ($Y = 1$) 的機率，它受自變數 X_i 所影響。假設 P 與 X_i 的關係滿足下式，即

$$P = \frac{e^{f(x)}}{1 + e^{f(x)}} ,$$

則其失敗的機率為

$$1 - P = \frac{1}{1 + e^{f(x)}} ,$$

將成功的機率與失敗的機率兩者相除可得：

$$\frac{P}{1 - P} = e^{f(x)}$$

此即所謂的優勢比 (Odd Ratio)。

取對數後可得

$$\ln\left(\frac{P}{1 - P}\right) = f(X) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_k X_k ,$$

此種轉換方式稱為羅吉轉換 (Logit Transformation)。當求得係數 β_i 後，

即可由下式求得 P 值：

$$P = \frac{e^{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k}}{1 + e^{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k}},$$

在應用時必須設定一判定值(Threshold Value)，其值常被設為為0.5。當羅吉斯迴歸模型所獲得的 P 值大於0.5時，則將此次試驗分類為成功 ($Y=1$)；相反地，若輸出值小於0.5時，則分類為失敗 ($Y=0$)。至於 β_i 的求法，則必須使用概似函數 $L(\beta_0, \beta_1, \dots, \beta_k)$ ，將此函數取對數後，再分別對各係數 β_i 進行微分後令為0，則可得到一聯立方程組，即可用以求得係數 β_i 。很不幸地，聯立方程組中的各式皆非係數 β_i 的線性式，很難得解。解決辦法是利用逐步求解法，藉助統計軟體一步一步的解出。⁴



⁴ 相關的解法請見陳順宇(民國 89 年)所著之「迴歸分析」。

四、研究設計及結果

4.1 研究設計

本研究主要是利用較早的年度財務數據來預測危機的發生，為了要建立預警模型，需要將危機與正常的公司樣本同時放入模型加以訓練，兩種公司所採用的財務比率皆相同，共有 23 個財務比率作為自變數，並以是否發生危機為應變數。若以年度別區分模型，則共有危機前第一年、危機前第二年、及危機前第三年三種。例如當某公司在九十三年時發生危機，則危機前一年代表的是九十二年；危機前二年代表的是九十一年；危機前三年代表的則是九十年。往後本文將以前一年模型、前二年模型、及前三年模型稱之。此外，在每一年度模型中，主要是以類神經網路來建立預警模型，並利用羅吉斯迴歸建立另一對照模型，以比較兩者的預測準確度。兩種模型設計分述如下：

4.1.1 類神經網路模型設計

本研究所使用前文所述的二十三個年終財務比率作為自變數，以企業是否被打入全額交割股作為應變數，被列入者以數值 1 表示，未列入者以 0 表示。在網路的設計上，使用了「23-5-1」的兩層式網路，以倒傳遞學習法進行模型的訓練，網路中包含了一個輸入層、一個隱藏層、及一個輸出層，如【圖 6】所示。輸入層共使用了二十三個結點，分別代表了二十三個財務比率。隱藏層則任意的選擇了五個結點，以作為連結輸出入層之用。輸出層只有一個結點，用以輸出違約與否的預測值。在操作時，必須設定一判別值以判定是否會發生危機，在此設定判別值為 0.5，大於 0.5 則相當於將預測值歸類為 1，即預測企業將發生危機；反之，若小於 0.5 則歸類為 0，即將企業歸類為正常。

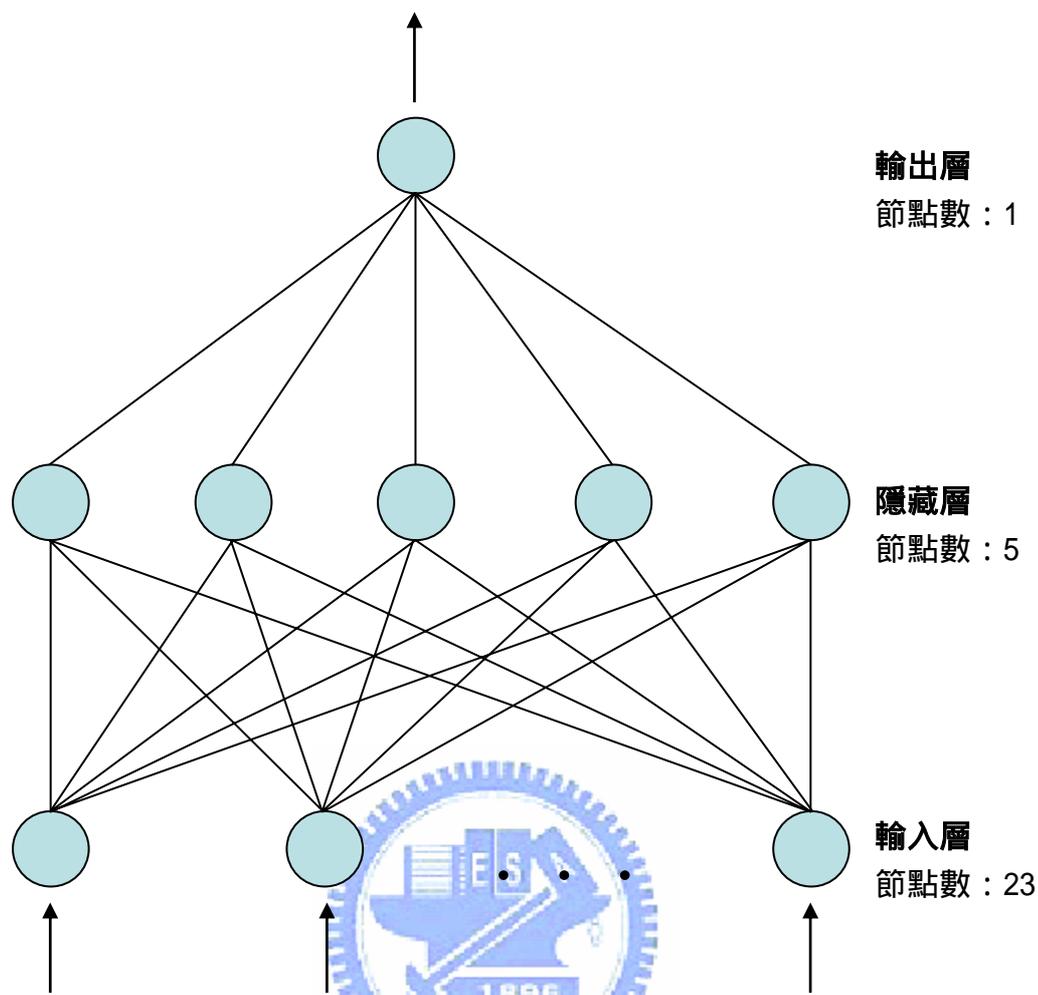


圖 6 實驗網路架構

不同於一般的迴歸模型，訓練出來的類神經預警模型並不能產生簡單如線性迴歸式的式子。類神經網路在各個結點皆產生最後訓練出的加權值，一層一層順向傳遞以輸出預測值，其利用各結點上權數，雖可以列出數學模型，但當網路很龐大，如不只一個隱藏層，或是每一層上的結點數眾多時，則數學模型將是非常的複雜。幸運的是，現今的類神經網路套裝軟體在訓練出最後的預警模型後，皆會將各結點的加權值予以記錄，要進行新資料的預測時，只要輸入新數據即可獲得預測值，因而在研究中可以不必大費周章地將危機預警的數學模型明列出來。本研究所使用的類神經網路軟體為 Qnet2000。

在建立預警模型時，必須將數據分為三組，第一組為模型建立組，建立初步的模型；第二組為模型修正組，利用增加的數據以修正模型；第三

組為驗證組，用以檢驗模型的預測準確度是否夠好。由於本研究的對象並非某個別產業，而是包含除了證券金融業以外的一般產業，因此為了降低誤差，不管是模型建立組、修正組或是驗證組的樣本，都必須有相同的產業分佈。

4.1.2 羅吉斯迴歸模型設計

在羅吉斯迴歸預警模型方面，一樣是使用二十三個財務比率作為自變數，並以是否發生危機(1 或 0)為應變數。模型的產生過程中，利用了逐步求解法，剔除不必要的自變數，求取最簡要的預測模型，後文將列出三個年度的羅吉斯預警模型。由於此模型的測預值輸出同樣經過羅吉斯轉換，因此也需要設定判別值，以進行企業會發生危機與否的歸類，判別值的設定為 0.5。在危機發生以 1 表示(即為成功試驗)及正常以 0 表示(即為失敗試驗)的設定下，羅吉斯迴歸法的判定準則是將預測值大於 0.5 的企業歸類為危機發生(成功試驗)，小於 0.5 則為正常(失敗試驗)。本研究所使用的羅吉斯迴歸軟體為 SAS。

在建立預警模型時的數據分組方面，此模型只需將數據分為兩組，第一組為模型建立組；第二組為驗證組。其中，模型建立組的數據等於類神經網路建立模型時的第一組和第二組的合併數據。而驗證組則和類神經網路的第三組相同。同樣地，在模型建立組和驗證組內的產業分佈比率皆相同。

4.2 數據蒐集與整理

4.2.1 資料蒐集

本研究使用的財務比率數據，皆來自於經濟新報資料庫，部分利用其整理的現在或曾經上市櫃公司的財務報表，經轉換會計科目金額為財務比率而得；部分則直接取自其整理的財務比率。這些上市櫃公司中的產業分佈，如前述，唯一不包含的是銀行金融相關產業，這是由於這類產業，在

財報上無法產生達二十三個財務比率的數據，因其並無一般產業的存貨，且其資產與負債也和一般產業的性質不同，故無法與其他的一般產業比較。此外，所選用的是年度資料，包括了目標年份的前三個年份，係用以建立三種不同的年度模型。而目標年份(即所選企業發生危機的年份)介於1982年至2003年。在蒐集公司樣本時，除了危機公司的數據，本研究亦蒐集相對應的正常公司數據，其配對原則為，一家危機公司搭配一家相同產業、相同年份(即危機年份)、及相同規模的正常公司(資產相近)。

4.2.2 資料整理

剔除了上櫃年份不足三年，以及部分財務數據有所遺漏的公司後，本研究共整理出99家的危機公司，除了絕大部分為股票第一次被改列為全額交割股的上市櫃公司，也包含了少部分第一次被停止交易的公司。另外在配對原則之下，也選取了99家的正常公司樣本。在用以建立類神經網路模型的分組設計上，共分成三組，每一組各包含33筆危機與33筆正常公司，共66筆數據，每一組中的產業比重皆相同，第一組用以建立模型，第二組用以修正模型，而第三組則用以驗證模型。在用以建立羅吉斯迴歸模型的分組設計，則共分為兩組，第一組用來建立模型，內含數據完全可同於類神經網路模型的第一組及第二組的相加的所有數據，包含了66筆危機與66筆正常公司，共132筆數據。第二組則完全與類神經網路的第三組相同，危機與正常公司加總共66筆數據。

4.3 分析結果與比較

在本節將介紹兩種模型的預測結果，除了使用預測正確率外，亦使用了誤差均方根(Root-mean-square Error, RMSE)作為預測能力指標。誤差均方根的求法如下式所示：

$$RMSE = \sqrt{\frac{\sum_k (T_k - Y_k)^2}{N}}$$

其中的 T 為驗證組的實際目標值(即0或1)， Y 則為預測目標值(非機率值)

P)。此值愈小，代表的是模型的擬合程度或預測能力愈佳。

4.3.1 類神經網路模型預測結果

利用由建立組及修正組數據所訓練出來類神經網路模型，對驗證組進行預測，本研究獲得三種年度模型的預測結果如下：

1. 前一年模型的預測結果

前一年模型的預測正確率達到 84.85%，如【表 2】所示，66 家公司中共有 56 家公司預測成功。實際上正常的 33 家公司中，被預測為正常的有 29 家，被錯認為危機的有 4 家；實際上危機的 33 家公司中，被預測為危機的有 27 家，而被錯認為正常的有 6 家。此外，由模型的輸出結果，可以獲得另一個預測能力指標 - 誤差均方根(Root-mean-square Error)，前一年模型的誤差均方根為 0.409671。

表 2 類神經網路-前一年模型預測結果



		預測結果		
		正常	危機	正確率
實際狀況	正常	29	4	84.85% (56/66)
	危機	6	27	

2. 前二年模型的預測結果

前二年模型的預測正確率為 77.27%，如【表 3】所示，66 家公司中共有 51 家預測成功。其中，實際上正常的 33 家公司中，被預測為正常的有 28 家，被錯認為危機的有 5 家；實際上危機的 33 家公司中，被預測為危機的有 23 家，而被錯認為正常的有 10 家。此外，由模型的輸出結果，可以獲得前一年模型的誤差均方根為 0.425003。

表 3 類神經網路-前二年模型預測結果

		預測結果		
		正常	危機	正確率
實際狀況	正常	28	5	77.27% (51/66)
	危機	10	23	

3. 前三年模型的預測結果

前三年模型的預測正確率為 75.76%，如【表 4】所示，66 家公司中共有 50 家預測成功。其中，實際上正常的 33 家公司中，被預測為正常的有 22 家，被錯認為危機的有 11 家；實際上危機的 33 家公司中，被預測為危機的有 28 家，而被錯認為正常的有 5 家。此外，由模型的輸出結果，可以獲得前一年模型的誤差均方根為 0.487909。

表 4 類神經網路-前三年模型預測結果

		預測結果		
		正常	危機	正確率
實際狀況	正常	22	11	75.76% (50/66)
	危機	5	28	

4.3.2 羅吉斯迴歸模型預測結果

本研究利用逐步求解法，挑出重要變數且剔除不必要的變數，使得羅吉斯迴歸模型成為最簡化的模式，各年度模型及其預測正確率分述如下：

1. 前一年模型預測結果

搭配逐步求解法簡化後所獲得的前一年模型，可表示成迴歸式：

$$Y = (-16.8692) - 24.7339X_{11} + 28.7827X_{17} ,$$

其中，

X_{11} ：淨利對總資產比率

X_{17} ：總負債對總資產比率。

在模型的解釋方面，由模型可知解釋變數「淨利對總資產比率」愈高，則應變數值愈小，代表愈不會發生危機。而「總負債對總資產比率」愈高，則應變數值愈大，代表愈容易發生危機，這兩者的解釋皆是合理的。此模型的預測正確率為 83.33%，如【表 5】所示，66 家公司中共有 55 家預測成功。其中，實際上正常的 33 家公司中，被預測為正常的有 25 家，被錯認為危機的有 8 家；實際上危機的 33 家公司中，被預測為危機的有 30 家，而被錯認為正常的有 3 家。此外，由模型的輸出結果，可以獲得前一年模型的誤差均方根為 0.661998。

表 5 羅吉斯迴歸-前一年模型預測結果

		預測結果		
		正常	危機	正確率
實際狀況	正常	25	8	83.33% (55/66)
	危機	3	30	

2. 前二年模型預測結果

搭配逐步求解法簡化後所獲得的前二年模型，可表示成迴歸式：

$$Y = (-4.8733) - 28.4173X_{14} - 6.0778X_{16} + 12.1022X_{17} ,$$

其中，

X_{14} ：營業利益對總資產比率

X_{16} ：長期負債對總資產比率

X_{17} ：總負債對總資產比率。

在模型的解釋方面，由模型可知解釋變數「營業利益對總資產比率」愈高，則應變數值愈小，代表愈不會發生危機。而長期負債對總資產比率愈高，則應變數值愈小，代表愈不會發生危機，可能長期負債較大表示隱含有較佳的投資機會，獲得更高的利潤。而總負債對總資產比率愈高，則應變數值愈大，代表愈易發生危機。此模型的預測正確率為 75.76%，如【表 6】所示，66 家公司中共有 50 家預測成功。其中，實際上正常的 33 家公司中，被預測為正常的有 25 家，被錯認為危機的有 8 家；實際上危機的 33 家公司中，被預測為危機的有 25 家，而被錯認為正常的有 8 家。此外，由模型的輸出結果，可以獲得前一年模型的誤差均方根為 0.705768。

表 6 羅吉斯迴歸-前二年模型預測結果

		預測結果		
		正常	危機	正確率
實際狀況	正常	25	8	75.76% (50/66)
	危機	8	25	

3. 前三年模型預測結果

搭配逐步求解法簡化後所獲得的前三年模型，可表示成迴歸式：

$$Y = (-2.0592) - 19.7299X_{11} + 5.0957X_{17} ,$$

其中，

X_{11} ：淨利對總資產比率

X_{17} ：總負債對總資產比率。

此模型的預測正確率為 72.73%，如【表 7】所示，66 家公司中共有 48 家預測成功。其中，實際上正常的 33 家公司中，被預測為正常的有 24 家，被錯認為危機的有 9 家；實際上危機的 33 家公司中，被預測為危機的有 24 家，而被錯認為正常的有 9 家。此外，由模型的輸出結果，可以獲得前一年模型的誤差均方根為 0.709954。

表 7 羅吉斯迴歸-前三年模型預測結果

		預測結果		
		正常	危機	正確率
實際狀況	正常	24	9	72.73% (48/66)
	危機	9	24	

4.3.3 比較分析

比較兩模型的預測正確率，如【表 8】整理所示，利用倒傳遞學習法的類神經網路模型，其預測正確率依年度而分，前一年至前三年模型分別為：84.85%、77.27%、及 75.76%。而羅吉斯迴歸模型則分別為：83.33%、75.76%、及 72.73%。可看出兩者在各年度模型的比較，皆是類神經網路較佳。此外，可以發現這兩種模型在不同時間的預測能力，皆是愈遠期，正確率愈低。在三種年度模型中，類神經網路模型與羅吉斯迴歸模型皆是前一年的預測能力最好，前二年的次之，前三年的則最差。在比較兩模型的誤差均方根方面，類神經網路模型前一年至前三年模型分別為：0.409671、0.425003、及 0.487909。而羅吉斯迴歸模型則分別為：0.661998、0.705768、及 0.709954。同樣地，皆是類神經網路較佳，表示模型的擬合程度較好，誤差較小。就三種年度模型而言，亦可看出前一年模型的誤差均方根最小。由以上可知，誤差均方根有隨預測正確率增加而減小的現象，可合乎直覺上的判斷。

表 8 兩種模型之預測正確率及誤差均方根合併列表

		前一年模型	前二年模型	前三年模型
類神經網路	預測正確率	84.85% (56/66)	77.27% (51/66)	75.76% (50/66)
	誤差均方根	0.409671	0.425003	0.487909
羅吉斯迴歸	預測正確率	83.33% (55/66)	75.76% (50/66)	72.73% (48/66)
	誤差均方根	0.661998	0.705768	0.709954

五、結論與建議

5.1 結論

上市櫃公司的危機預警模型，可以提供股票市場的參與者預警資訊，避免其蒙受資本損失。本研究利用了倒傳遞類神經網路建立了預警模型，可用以預測企業股票被列為全額交割股的危機。主要獲得的分析結果有三點：

第一，利用倒傳遞類神經網路可建立高正確率的預警模型，其前一年至前三年模型的預測正確率分別為：84.85%、77.27%、及 75.76%。經由比較發現，這些預測正確率也分別較對照的羅吉斯迴歸模型佳。

第二，利用倒傳遞類神經網路可建立低誤差均方根的預警模型，誤差均方根方面則分別為：0.409671、0.425003、及 0.487909 經由比較發現，這些預測正確率也分別較對照的羅吉斯迴歸模型小。

第三，由本研究所建立的類神經網路模型及羅吉斯迴歸模型可以發現，利用愈遠期的數據來預測危機，其效果愈差。

在本研究選定的研究範圍之內，由分析結果可以得知所發展的危機預警模型有不錯的辨識能力，而且相較於傳統上常使用的羅吉斯迴歸預警模型，亦有較佳的效果。但是必須注意的是，倒傳遞類神經網路並不能進行解釋變數的篩選，無法得到簡要的模型，而必須存在一龐大而複雜的模式。但是羅吉斯迴歸模型則可以進行變數的篩選，如在本研究中供對照的羅吉斯模型，其前一年模型可以簡化為兩個自變數，前二年為三個，而前三年則為兩個。因此利用類神經網路所得到的預警模型，並不能指出那些是必要的變數，而那些則不是。

5.2 建議

本研究在危機預警模型的建立過程中，設定了許多的研究限制及範圍。這些限制有待更進一步的釋放，以求得更合理的研究結果。對於未來可能更深入研究的建議，有以下兩個方向可以提及：

1. 解釋變數的選取

迴歸模型常常存在著如何選取解釋變數的爭議，因為在選取上會有研究者太過主觀的意見，導致遺漏一些必要的自變數或使用太多不必要的自變數，除非搭配其他的統計方法，如因素分析法等，以挑選適當變數，否則將形同黑箱作業。而在類神經網路模型中，更是存在著這種問題，在本研究中變通的方式為採用文獻中分析顯著的財務比率變數，儘量蒐集以做為自變數選取的依據。而為何不使用因素分析法先行篩選，以除去多餘的變數，主要是在於類神經網路模型考慮了所有線性與非線性的關聯性，若以一般統計方法求得顯著的變數，則極有可能去除了非線性關聯的變數。此外，相同於統計模型，在類神經網路模型中亦很有可能遺漏了應該考慮的變數。因此，在類神經網路模型中如何選取變數，必須做更深入的試驗。

2. 研究對象的選擇

由於國內的上市櫃公司發生危機的可用樣本太少，如資料遺失或不足等原因而被剔除，而在產業的分佈上亦不夠均勻，危機公司與正常公司的配對難以嚴謹，以致本研究所建立的模型在預測效果上可能大打折扣，這有賴未來資料的增加，以及可取得資料能有較高的完整性，才能有改善的空間。此外，本研究中並沒有將證券金融業納入，主要是著眼於放入此產業後，則必須將某些證券金融業沒有的財務比率去除，將可能導致整個模型的解釋力不足。然而未來亦可以這類產業為研究對象，搭配適宜的財務指標，如增加逾放比，並剔除存貨相關指標等。在資料的數量足夠後，即可只針對證券金融業建立危機預警模型。當然其他的個別產業若有足夠的數據，也將以之建立預警模型，可以比較是否個別產業的危機預警模型，會比合併產業的預警模型，存在較佳的預測能力。

參考文獻

中文部分

1. 王宗興，「台灣新上市公司股票上市後存活分析」，國立中山大學財務管理學系研究所，碩士論文，民國 90 年。
2. 白欽元，「國內中小企業財務危機預警模型之研究」，國立交通大學經營管理研究所，碩士論文，民國 91 年。
3. 何太山，「運用區別分析建立商業放款信用評分制度」，政治大學企業管理研究所，碩士論文，民國 66 年。
4. 金慧貞，「多變量 EWMA 財務危機預警模式之應用」，朝陽科技大學財務金融系碩士班，碩士論文，民國 90 年。
5. 唐筱菁，「整合財務比率與智慧資本指標建構企業危機預警系統-MARS 與類神經網路之應用」，輔仁大學金融研究所，碩士論文，民國 90 年。
6. 徐淑芳，「台灣上市公司財務危機預警 應用多變量 CUSUM 時間序列分析」，國立東華大學企業管理學系，博士論文，民國 87 年。
7. 張正忠，「台灣上市公司財務危機預警模式之建立-瀑布羅吉斯模型之應用」，國立交通大學經營管理研究所，碩士論文，民國 88 年。
8. 張隆鐘，「多變量 CUSUM 與狀態空間模式之應用 - 財務危機預警模式之建立」，國立中興大學統計學研究所，碩士論文，民國 82 年。
9. 陳明賢，「財務危機預測之計量分析研究」，國立台灣大學商學研究所，碩士論文，民國 74 年。
10. 陳渭淳，「上市公司失敗預測之實證研究」，國立台北大學企業管理學系，博士論文，民國 89 年。
11. 陳順宇，迴歸分析，第三版，華泰書局，民國 89 年。
12. 楊浚泓，「考慮財務操作與合併報表後之財務危機預警模式」，國立中央大學財務管理研究所，碩士論文，民國 90 年。
13. 葉怡成，類神經網路模式應用與實作，儒林圖書公司，台北，民國 82 年。
14. 葉怡成，應用類神經網路，儒林圖書公司，台北，民國 86 年。
15. 靳蕃、範俊波、譚永東，神經網路與神經計算機原理．應用，儒林圖書公司，台北，民國 81 年。
16. 蔡龍學，「上市公司財務預警模式-加速失敗時間模型之應用」，淡江大學金融研究所，碩士論文，民國 80 年。
17. 盧炳勳、曹登發，類神經網路理論與應用，全華科技圖書公司，民 81 年。

英文部分

1. Altman, E. I., 1968, "Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy", *Journal of Finance*, Vol. 23, No. 4, pp. 589-609.
2. Altman, E.I., Haldeman, R. G. and Narayanan, P., 1977, "Zeta Analysis, a New Model for Identifying Bankruptcy Risk of Corporation", *Journal of Banking and Finance*, Vol. 1, No. 1, pp.29-54.
3. Atiya, A.F., 2001, "Bankruptcy Prediction for Credit Risk Using Neural Networks: A Survey and New Results", *IEEE Transactions on Neural Networks*, Vol. 12, No. 4, pp. 929-935.
4. Beaver, W. H., 1966, "Financial Ratios as Predictors of Failure", *Journal of Accounting Research Supplement*, Vol. 4, pp. 71-111.
5. Beaver, W.H., 1968, "Market Price, Financial Ratio, and the Prediction of Failure", *Journal of Accounting Research*, Autumn, pp. 179-192.
6. Blum, M., 1974, "Failing Company Discriminant Analysis", *Journal of Accounting Research*, Vol.12, No. 1, pp.1-25.
7. Deakin, E. B., 1972, "A Discriminant Analysis of Predictors of Business Failure", *Journal of Accounting Research*, Vol.10, No.1, pp.167-179.
8. Edmister, R. O., 1972, "An Empirical Test of Financial Ratio Analysis for Small Business Failure Prediction", *Journal of Financial and Quantitative Analysis*, Vol. 7, No. 2, pp.1477-1493.
9. Gombola, M. J., Haskins, M. E., Ketz, J. E., and Williams, D. D., 1987, "Cash Flow in Bankruptcy Prediction", *Financial Management*, Vol. 16, No. 4, pp.55-65.
10. Kaplan, R. and Urwitz, G., 1979, "Statistical Models of Bond Ratings: A Methodological Inquiry", *Journal of Business*, Vol. 52, pp. 231-262.
11. Lo, A.W., 1986, "Logit Versus Discriminant Analysis : A Specification Test and Application to Corporate Bankruptcies", *Journal of Econometrics*, Vol. 31, No. 2, pp.151-178.
12. Ohlson, J.A., 1980, "Financial Ratios and the Probabilistic Prediction of Bankruptcy", *Journal of Accounting Research*, Vol. 18, No. 1, pp. 109-131.
13. Salchenberger, L. M., Cinar, E. M., and Lash, N. A., 1992, "Neural Networks: A New Tool for Predicting Thrift Failures", *Decision Sciences*, Vol. 23, pp. 899-916.
14. Tam, K. Y. and Kiang, M. Y., 1992, "Managerial Applications of Neural Networks: The Case of Bank Failure Predictions", *Management Science*, Vol.38, No.7, pp. 926-947.
15. Theodossiou, P., 1993, "Predicting Shifts in the Mean of a Multivariate Time

- Series Process: An Application in Predicting Business Failures”, *Journal of the American Statistical Association*, Vol. 88, No. 442, pp.441-449.
16. Theodossiou, P., Kahya, E., Saidi, R. and Philippatos, G., 1996, “Financial Distress and Corporate Acquisitions: Further Empirical Evidence”, *Journal of Business Finance and Accounting*, Vol. 23, No. 5,6, pp. 699-719.
17. Theodossiou, P. and Kahya, E., 1999, “Predicting Corporate Financial Distress: A Time-Series CUSUM Methodology”, *Review of Quantitative Finance and Accounting*, Vol.13, No. 4, pp.323-345.
18. Udo, G., 1993, “Neural Network Performance On the Bankruptcy Classification Problem”, *Computers & Industrial Engineering*, Vol. 25, No. 1-4, pp. 377-380.



附錄 一 危機與正常公司樣本配對表

危機公司名稱	危機年	正常公司名稱
1106 永康	1984	1104 環泥
1203 味王	2000	1217 愛之味
1206 台鳳	2000	1239 味丹
1209 益華	2000	1218 泰山
1212 中日	2003	1215 卜蜂
1221 久津	2003	1213 大飲
1222 源益	2000	1210 大成
1224 惠勝	2001	1220 台榮
1225 福懋油脂	2000	1219 福壽
1228 台芳	1999	1227 佳格
1407 華隆	2002	1440 南紡
1422 民興	2001	1451 年興
1424 新東	1982	1435 中福
1425 福昌	1997	1476 儒鴻
1429 新奇	1985	1417 嘉裕
1431 新燕	2001	1419 新紡
1438 裕豐	2001	1441 大東
1450 新藝	2002	1456 怡華
1458 嘉畜	2002	1459 聯發
1462 東雲	2001	1409 新纖
1601 台光	1999	1611 中電
1602 太電	2003	1605 華新
1613 台一	2002	1612 宏泰
1805 凱聚	2003	1806 冠軍
1807 羅馬	2002	1809 中釉
1808 國賓瓷	1999	1810 和成
1908 萬有	1998	1905 華紙
2003 同光	1993	2022 聚亨
2005 友力	1999	2033 佳大
2014 燁隆	2001	2023 燁輝
2016 名佳利	2001	2009 第一銅
2019 桂宏	2000	2015 豐興
2024 志聯	2001	2032 新鋼

危機公司名稱	危機年	正常公司名稱
2025 千興	2002	2034 允強
2101 南港	1995	2106 建大
2202 三富	1997	2206 三陽
2304 誠洲	2001	2305 全友
2309 國勝	1992	2312 金寶
2318 佳錄	2003	2365 昆盈
2326 亞瑟	2001	2366 亞旭
2342 茂矽	2003	5346 力晶
2348 力捷	2002	2361 鴻友
2350 環電	1999	2331 精英
2358 美格	2001	2354 華升
2506 太設	2003	2515 中工
2512 寶建	2002	2509 全坤
2517 長谷	2002	2530 華建
2518 長億	2002	2511 太子
2521 宏總	2003	2505 國揚
2522 啟阜	1999	2535 達欣工程
2525 寶祥	2002	2547 日勝生
2528 皇普	2003	2548 華固
2529 仁翔	2000	2527 宏環
2537 春池	2002	2543 皇昌
2538 基泰	2002	2514 龍邦
2539 櫻建	2002	2546 根基
2540 林三號	2003	1614 三洋
2703 華國	2000	2706 第一店
2902 中信	2001	2904 匯僑
3053 鼎營	2003	3047 訊舟
4403 東榮工	2001	4413 赤崁
4801 景泰	2002	1802 台玻
5011 久陽	2002	5015 華祺工業
5307 耀文	2003	5318 佳鼎
5313 皇旗	2000	5386 青雲國際
5336 華特	2001	2441 超豐
5344 立衛	2002	2369 菱生
5347 世界先進	2003	3006 晶豪科
5348 系通	2001	5353 台林

危機公司名稱	危機年	正常公司名稱
5385 瑩寶	2002	3031 佰鴻
5502 龍田	2002	5514 三豐
5503 榮美開發	2001	5512 力麒
5504 信南	2001	5520 力泰
5505 和旺	2002	5508 永信建設
5529 訊嘉	2002	5534 長虹
5702 統合	2002	5703 亞都麗緻
5901 中友	2002	2905 三商行
8701 正豐	1996	1712 興農
8702 羽田	1996	2611 志信
8704 大業	1999	6178 振遠
8706 金緯	1999	4402 福大
8707 中精機	1999	4513 福裕
8709 峰安	1999	5006 高鋁
8711 大穎	1999	1711 永光
8712 國產車	1999	2204 中華
8715 中強	1999	2442 美齊
8716 尖美	2000	2520 冠德
8717 瑞圓	1999	2516 新建
8718 工礦	2000	1307 三芳
8719 宏福	1999	2523 德寶
8720 元富	2001	1603 華電
8722 尚德	2001	8905 裕國
8724 立大	1999	1235 興泰
8725 三采	2001	5533 皇鼎建設
8913 華夏租賃	2003	2373 震旦行
9903 光男	1994	9904 寶成
9906 興達	2001	9905 大華
9913 美式	1999	9935 慶豐富
9922 優美	2001	2374 佳能