

南華大學科技學院資訊管理學系

碩士論文

Department of Information Management

College of Science and Technology

Nanhua University

Master Thesis

特徵縮放於深度學習股市價格預測之影響

The Effect of Feature Scaling on Deep Learning Stock Market

Price Prediction

丁麗文

Li-Wen Ting

指導教授：王佳文 博士

Advisor: Jia-Wen Wang, Ph.D.

中華民國 111 年 7 月

July 2022

# 口試合格證明

南華大學  
科技學院資訊管理學系  
碩士學位論文

特徵縮放於深度學習股市價格預測之影響  
The Effect of Feature Scaling on Deep Learning Stock  
Market Price Prediction

研究生： 丁麗文

經考試合格特此證明

口試委員： 陳智賢  
陸海文  
王作文

指導教授： 王作文

系主任(所長)： 陳信良

口試日期：中華民國 111 年 6 月 15 日

# 著作財產權同意書

## 南華大學資訊管理學系碩士論文著作財產權同意書

立書人： 丁麗文 之碩士畢業論文

中文題目：

特徵縮放於深度學習股市價格預測之影響

英文題目：

The Effect of Feature Scaling on Deep Learning Stock Market Price Prediction

指導教授：王佳文 博士

學生與指導老師就本篇論文內容及資料其著作財產權歸屬如下：

- 共同享有著作權
- 共同享有著作權，學生願「拋棄」著作財產權
- 學生獨自享有著作財產權

學 生： 丁麗文 (請親自簽名)

指導老師： 王佳文 (請親自簽名)

中華民國111年7月8日

指導教授推薦函

南華大學碩士班研究生

論文指導教授推薦函

資訊管理系碩士班丁麗文君所提  
之論文

係由本人指導撰述，同意提付審查。

指導教授 班級

111年7月8日

## 致謝

大學時就在南華生活了，從大學專題製作很高興遇到指導教授王佳文老師，老師除了課堂上的指導外，對我的狀況也時常關心，很慶幸在研究所撰寫論文這兩年老師對我的體諒、包容和教導，平常相處中，也學習許多待人處事的態度。當我遇到問題時，老師也會適時給予寶貴意見，也很感謝老師在我對自己迷茫的時候鼓勵我給我一些建議方向。

在讀研究所這條路上我要感謝很多人，感謝一直照顧我的資管系師長對我的教導與鼓勵，感謝我的研究所同學們在就學期間一起鼓勵、一起創立Python家族、一起談天說笑給彼此留下美好回憶。我還要感謝與我一起在系辦幫忙的學弟妹們，如果不是你們我可能研究所也沒辦法過得如此精采。還要感謝處室中的姐姐及哥哥，時常會關心我的論文進度，當我遇挫時，給我建議與分享他們的經驗。

最後，要感謝我的家人，擁有你們的支持、鼓勵與陪伴我才能安心地度過生命的每一個階段，也因為你們才能在我求學的階段沒有後顧之憂。最後，謹以本篇論文獻給所有曾經幫助過我的人，在此獻上最誠摯的謝意。

# 特徵縮放於深度學習股市價格預測之影響

學生：丁麗文

指導教授：王佳文 博士

南 華 大 學 資 訊 管 理 學 系 碩 士 班

## 摘要

近年來機器學習與深度學習模型在巨量資料分析和科技金融方面取得了顯著的成效。時間序列分析主要是利用歷史資料預測未來走勢，然而過去時間序列相關研究較少探討特徵縮放的影響性。本研究利用常見的技術指標，並結合不同特徵縮放及深度學習演算法進行股市價格預測分析。在實證方面利用台灣證券交易所 (TWSE) 的 A 公司 2015 年到 2019 年實際股票資料進行驗證，並進行比較分析。綜合上述，本研究目的如下：

- (1) 探討使用不同特徵縮放對於遞迴神經網路準確度影響
- (2) 探討加入常見技術指標是否可提高遞迴神經網路準確度
- (3) 驗證傳統 ARIMA 模型與遞迴神經網路預測準確度之比較
- (4) 探討不同神經元數及層數對於預測準確度之影響
- (5) 實際採用 2015-2019 年 A 公司實際股票資料來進行實例驗證

關鍵字：特徵縮放、深度學習、股市價格、技術指標

# The Effect of Feature Scaling on Deep Learning

## Stock Market Price Prediction

Student: Li-Wen Ting

Advisor: Jia-Wen Wang, Ph.D.

Department of Information Management

Nanhua University

Master Thesis

### **Abstract**

In recent years, machine learning and deep learning models have achieved significant success in huge data analysis and technology finance. Time series analysis is mainly used to predict future trends using historical data, however, the impact of feature scaling has been less explored in past time series-related studies. This study uses common technical indicators and combines different feature scaling and deep learning algorithms to conduct stock market price prediction analysis. Empirical validation is conducted using actual stock data from 2015 to 2019 of A companies on the Taiwan Stock Exchange (TWSE), and comparative analysis is performed.

The purpose of this study is as follows :

- (1) The effect of using different feature scaling on the accuracy of recursive neural networks.
- (2) To investigate whether the inclusion of common technical indicators can improve the accuracy of recurrent neural networks.
- (3) A comparison of the prediction accuracy of the traditional ARIMA model with that of the recurrent neural network.

(4) Investigate the effect of different parameters on prediction accuracy

(5) Using an actual stock dataset as an experimental case.

**Keywords:** Feature Scaling, Deep Learning, Stock Market Price, Technical

Indicators





## 目錄

著作財產權同意書 .....	I
指導教授推薦函 .....	II
致謝 .....	III
摘要 .....	IV
Abstract .....	V
目錄 .....	VII
圖目錄 .....	IX
表目錄 .....	X
<b>第一章 緒論 .....</b>	<b>1</b>
第一節 研究背景與動機 .....	1
第二節 研究目的 .....	3
第三節 研究結構 .....	3
<b>第二章 文獻探討 .....</b>	<b>4</b>
第一節 時間序列 .....	4
第二節 整合移動平均自迴歸模型 .....	4
第三節 深度學習簡介 .....	5
第四節 預測模型與股市價格分析相關文獻 .....	9
第五節 股市技術指標介紹及相關文獻 .....	10
<b>第三章 特徵縮放預測分析模型 .....</b>	<b>19</b>
第一節 研究架構 .....	19
第二節 特徵縮放 .....	23

第三節	個案介紹及實驗設計說明.....	26
<b>第四章</b>	<b>資料分析與結果.....</b>	<b>29</b>
第一節	資料分析.....	29
第二節	研究發現與討論.....	52
<b>第五章</b>	<b>結論與建議.....</b>	<b>54</b>
第一節	結論.....	54
第二節	未來展望.....	55
<b>參考資料.....</b>		<b>56</b>
一、	中文文獻.....	56
二、	英文文獻.....	57
<b>附錄.....</b>		<b>66</b>
附錄 A：	單一指標分析結果.....	66
附錄 B：	多指標分析結果.....	76
附錄 C：	多指標單因子變異數分析結果.....	86

## 圖目錄

圖 1-1 人工智慧的界定與發展.....	1
圖 2-1 RNN 展開架構圖 .....	6
圖 2-2 RNN 內部計算構造.....	7
圖 2-3 LSTM 架構示意圖 .....	8
圖 2-4 GRU 架構示意圖 .....	9
圖 3-1 研究架構圖.....	20
圖 3-2 單一指標模型示意圖 .....	26
圖 3-3 多指標模型示意圖 .....	26
圖 4-1 特徵縮放模型 LOSS 變化圖.....	29
圖 4-2 模型預測效果 .....	30

## 表目錄

表 2-1 技術指標文獻回顧 .....	16
表 3-1 技術指標的名稱及代號 .....	20
表 3-2 參數設定 .....	27
表 4-1 ARIMA (1,1,0) 模型預測比較 (非還原值) .....	31
表 4-2 模型預測比較表 .....	31
表 4-3 不同特徵縮放方法在預測準確度層數之差異分析摘要表 (單一全部) ....	33
表 4-4 不同層數在預測準確度特徵縮放方法之差異分析摘要表 (單一全部) ...	35
表 4-5 不同特徵縮放方法在遞迴神經網路預測準確度之差異分析表 (一層)	36
表 4-6 不同遞迴神經網路在特徵縮放方法預測準確度之差異分析表 (一層)	37
表 4-7 不同特徵縮放方法在遞迴神經網路預測準確度之差異分析表 (二層)	39
表 4-8 不同遞迴神經網路在特徵縮放方法預測準確度之差異分析表 (二層)	41
表 4-9 不同遞迴神經網路在特徵縮放方法預測準確度之差異分析表 (三層) .	43
表 4-10 不同特徵縮放在遞迴神經網路預測準確度之差異分析表 (三層) .....	45
表 4-11 不同模型與特徵方法之深度學習預測結果的描述統計 (單一指標全部)	47
表 4-12 不同模型與特徵方法之深度學習預測結果的描述統計 (多指標全部) .	49
表 7-1 單一指標分析-一層 .....	66
表 7-2 單一指標分析-二層 .....	67
表 7-3 單一指標分析-二層 (續) .....	68
表 7-4 單一指標分析-三層 .....	69
表 7-5 單一指標分析-三層 (續) .....	70
表 7-6 單一指標分析-三層 (續) .....	71
表 7-7 單一指標分析-三層 (續) .....	72

表 7-8 單一指標分析-三層 (續) .....	73
表 7-9 單一指標分析-三層 (續) .....	74
表 7-10 單一指標分析-三層 (續) .....	75
表 8-1 多一指標分析-一層 .....	76
表 8-2 多一指標分析-二層 .....	77
表 8-3 多一指標分析-二層 (續) .....	78
表 8-4 多一指標分析-三層 .....	79
表 8-5 多一指標分析-三層 (續) .....	80
表 8-6 多一指標分析-三層 (續) .....	81
表 8-7 多一指標分析-三層 (續) .....	82
表 8-8 多一指標分析-三層 (續) .....	83
表 8-9 多一指標分析-三層 (續) .....	84
表 8-10 多一指標分析-三層 (續) .....	85
表 9-1 不同特徵縮放方法在層數預測準確度之差異分析摘要表 .....	86
表 9-2 不同層數在特徵縮放方法預測準確度之差異分析摘要表 .....	87
表 9-3 不同特徵縮放方法在遞迴神經網路預測準確度之差異分析表 (一層) .....	88
表 9-4 不同遞迴神經網路在特徵縮放方法預測準確度之差異分析表 (一層) .....	89
表 9-5 不同特徵縮放方法在遞迴神經網路預測準確度之差異分析表 (二層) .....	90
表 9-6 不同遞迴神經網路在特徵縮放方法預測準確度之差異分析表 (二層) .....	91
表 9-7 不同特徵縮放方法在遞迴神經網路預測準確度之差異分析表 (三層) .....	92
表 9-8 不同遞迴神經網路在特徵縮放方法預測準確度之差異分析表 (三層) .....	93

# 第一章 緒論

## 第一節 研究背景與動機

人工智慧 (artificial intelligence, AI) 指的是藉由使用人們所製造具有計算功能的機器使其擁有智能的去學習歸納、演算、分類，在近幾年間人工智慧 (AI) 迅速的演進使其科技發展、學術研究相互連接應用，但人工智慧的定義早在 1956 達特茅斯 (Dartmouth) 學會上就已提出確立了，其中在這六十年間人工智慧的發展經歷了三次的衰退期與繁盛期，但每一次的衰退後也因創新演算法的開發，使其能再次的演進繁華，由上個世紀 70 年代的反向傳播法 (Backpropagation) 至 90 年代後開發的一系列的機器學習，在這些演進中隨著演算法、模型的創新、改良，至今限制玻爾茲曼機 (Restricted Boltzmann Machine, RBM) 模型與深度信念網路 (Deep Belief Network, DBN) 的開發使其原先的神經網路能被更深層化的成功訓練 (Hinton & Salakhutdinov, 2006)，因此深度學習開始慢慢出現了，但這也使得在人工智慧界定裡的機器學習、深度學習及其相關的應用有著較為模糊的界線關係與定義，由圖 1-1 可以清楚的解釋三者的相關性，可以從圖 1-1 中得知(林逸青等,2019)，AI、機器學習、深度學習，之間的關係基本皆歸類於 AI 之中，只是因為時代的演進、演算法的創新，是得 AI 的基礎有層次性的延伸，進而發展出了更多相關的技術知識、學習模組。

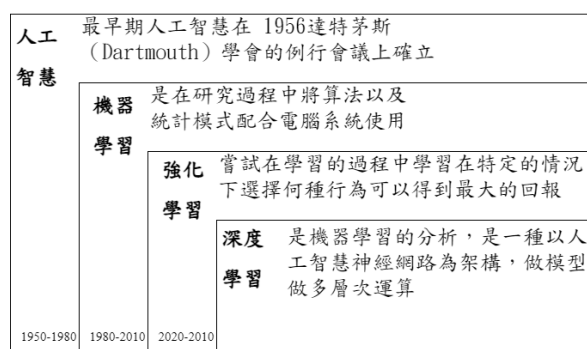


圖 1-1 人工智慧的界定與發展

近年來機器學習與深度學習模型在巨量資料分析和科技金融方面取得了顯著的成效(林逸青, 2019)。對於需要分析大數據的時代, 使用深度學習處理資料及分析數據已是一種優勢。隨著演算法不斷的優化、電腦設備效能提升, 加快了運算速度, 發現許多學者利用深度學習建立模型用以預測各類型金融商品, 在深度學習文獻中, 以利用歷史資料預測股價走勢最為熱門(Singh & Srivastava, 2017; Fischer & Krauss, 2018)。

股票價格的預測研究也是這幾十年來一直持續不懈的趨勢, 過去研究認為基於統計方法和歷史數據, 股票市場的變動是具有可預測性(Morgenstern, 1970)。利用歷史財務數據進行時間序列分析, 確認金融時間序列的歷史數據走勢, 是許多研究的主軸(Marszałek & Burczyński, 2014; Mills & Markellos, 2008), 但是影響股票價格的因素有很多, 因此在金融研究中股市預測被認為是最相關但最具挑戰性的任務之一(Chen & Hao, 2017)。

在以往的研究中多數學者使用遞迴神經網路進行股票預測分析(Chen et al., 2019; Kimoto et al., 1990; Gencay, 1996; Yim, 2002), 都未說明不同特徵縮放方法對預測模型的影響性。特徵縮放也稱為標準化是數據預處理過程中的一個步驟, 使數據轉化到特定的範圍內, 特徵縮放有助於模型收斂速度, 特徵縮放是使用機器學習和深度學習進行的實驗的共同要求(Thara et al., 2019)。然而在過去股市的研究上較少研究會去探討不同神經元數及層數是否會影響遞迴神經網路預測準確度。綜合上述的觀點, 本研究提出不同特徵縮放方法別放入不同神經元數及層數、遞迴神經網路進行預測準確度結果分析, 試圖了解不同特徵縮放、神經元數及層數對遞迴神經網路預測準確度之影響。

## 第二節 研究目的

本研究利用台灣證券交易所 (TWSE) 的股票資料,並利用文獻探討法針對常見股市價格技術指標進行挑選,最後利用文獻探方法選出 15 個常見技術指標,再利用深度學習 (RNN、LSTM、GRU) 及結合不同特徵縮放進行股市價格預測分析,最後使用均方誤差 (Mean-Square Error, MSE)、均方根誤差 (Root-Mean-Square Error, RMSE)、平均絕對百分比誤差 (Mean Absolute Percentage Error, MAPE) 來進行結果評估。本研究的目的有以下幾點：

- (1) 使用不同特徵縮放對於遞迴神經網路準確度影響
- (2) 探討加入技術指標是否可提高遞迴神經網路準確度
- (3) 驗證傳統 ARIMA 模型與遞迴神經網路預測準確度之比較
- (4) 探討不同神經元數及層數對於預測準確度之影響
- (5) 實際採用 2015-2019 年 A 公司實際股票資料來進行實例驗證

## 第三節 研究結構

本研究共分為五個章節,第一章為緒論:主要闡述研究背景動機與目的,第二章為文獻探討:主要介紹時間序列、整合移動平均自迴歸模型、深度學習簡介介紹、預測模型與股市價格分析相關文獻、股市技術指標介紹及相關文獻,第三章為特徵縮放預測分析模型:介紹本研究之架構與流程、特徵縮放說明及介紹、個案說明及實驗設計說明,第四章為資料分析與結果:採用 A 公司 2015~2019 年股票資料進行實驗分析,第五章為結論:說明本研究之發現並提出未來展望。



## 第二章 文獻探討

在本章節主要分為五個部分，第一節為時間序列、第二節為整合移動平均自迴歸模型、第三節為深度學習簡介、第四節為預測股票價格相關文獻、第五節為股市技術指標介紹與相關文獻。

### 第一節 時間序列

時間序列不是分析方法的名稱，而是一種常見的數據類型，主要是利用歷史資料進行未來預測分析。時間序列分析通常應用於經濟、金融、零售和其他價格、貨幣和匯率隨時間不斷變化的行業，目前時間預測廣泛被使用，例如股價預測、電力預測等等。時間序列常見為三個特性：季節性、趨勢性和隨機性（簡禎富、許嘉裕，2014）。季節性模式是短期循環在序列中重複，當時間序列受季節性原因，季節性具有固定且可預測的頻率。在趨勢模式中，數據隨著時間而增減變化而呈現上升或下降的緩慢趨勢，而造成一種有系統性的變動傾向，換句話說，時間數列呈現出緩慢而有規律的變化。隨機性是序列中因隨機偏差造成無法預測的現象，例如：不規則的、系統的、短期波動。

### 第二節 整合移動平均自迴歸模型

整合移動平均自迴歸模型（Autoregressive Integrated Moving Average model, ARIMA）由 Box 和 Jenkin 在 1976 年提出，它可以用來預測非季節性靜止的時間序列數據。ARIMA 可以分為三個部分：自迴歸模型（Autoregressive model）、移動平均（Moving average, MA）及 ARIMA。ARIMA 模型由 3 個參數組成： $p, d, q$ ，其中參數  $p$  代表自回歸（AR）項數，參數  $q$  為移動平均（MA）項數，參數  $d$  為使用時間序列成為平穩序列所需的差分。ARIMA 公式說明如下（楊旻叡，2021）：

$$\varphi(B)z_t = \phi(B)\nabla^d z_t = \theta_0 + \theta(B)a_t \quad (1)$$

其中 $\theta_0$ 為常數， $a_t$ 為白噪聲， $z_t$ 為時間  $t$  的離散時間序列值， $B$  為向後位移運算子， $\varphi(B)$ 為平穩自回歸運算子， $\theta(B)$ 為移動平均運算子， $\phi_1 \cdots \phi_p$ 為自回歸係數， $\theta_1 \cdots \theta_q$ 為移動平均係數。

### 第三節 深度學習簡介

深度學習(Deep Learning, DL)是一種基於人工類神經網路(Neural Network)的機器學習技術，對資料進行多層表徵學習的演算法 (Bengio et al., 2013)。其特點是用非監督式學習或是半監督式學習的特徵學習與分層特徵提取高效演算法來替代人工取得特徵 (Song & Lee, 2013)。以往傳統的機器學習技術在處理原始資料的能力有其難以突破的限制，通常需要相關領域的專家對原始數據進行諸多的研究分析後，再利用人工設計提取資料特徵的演算法，而與之前相比深度學習這種基於數據而自動提取特徵並校正模型內部結構的自適應系統，在對高維度複雜資料建模與數據資料準確度等方面有相當大的優勢。

深度學習經過長時間的發展，直至目前已有多種神經網路架構應用在各領域，在圖像辨識、語音識別、自然語言處理與時間序列分析等領域皆有傑出的突破表現 (Zhang & Chen, 2017; Agarwalla & Sarma, 2016; Vathsala & Holi, 2020)。時間序列分析的主要目的是根據已有的歷史數據預測未來的價值。而循環式類神經網路恰巧符合時間序列之特性，其中有幾種變體模型如循環式神經網路(Recurrent Neural Networks, RNN)、長短期記憶神經網路(Long Short-Term Memory, LSTM)、門控循環網路單元(Gated Recurrent Unit, GRU)等，下列針對這三種模型進行介紹：

#### (一)、 循環式類神經網路 (Recurrent Neural Network, RNN)

循環式神經網路 (Recurrent Neural Network, RNN) 源於 Saratha Sathasivam

在 1982 年提出的 Hopfield 網絡 (Hopfield, 1982)。傳統的機器學習算法嚴重依賴人工特徵提取，使得特徵提取在圖像識別、語音識別和自然語言處理遇到瓶頸 (Wei et al., 2011; Zheng & Zheng, 2019)。而全連接神經網絡也有參數過多、無法利用數據中的時序等問題。隨著 RNN 更有效結構的提出，序列信息和語義訊息的深度表達能力數據挖掘得到充分利用。RNN 在語音識別 (Zhang & Chen, 2017; Agarwalla & Sarma, 2016)、機器翻譯、時間分析方面有良好表現 (Vathsala & Holi, 2020)。時間序列分析的主要目的是根據已有的歷史數據預測未來的價值。RNN 是時間序列分析中最重要的神經網絡之一。RNN 具有記憶先前結果的特點，但由於數據對 RNN 的長期依賴，在模型訓練中出現了梯度消失和爆炸的問題 (Yin & Shao, 2019)，因此後續有其他學者提出方法上的改良。

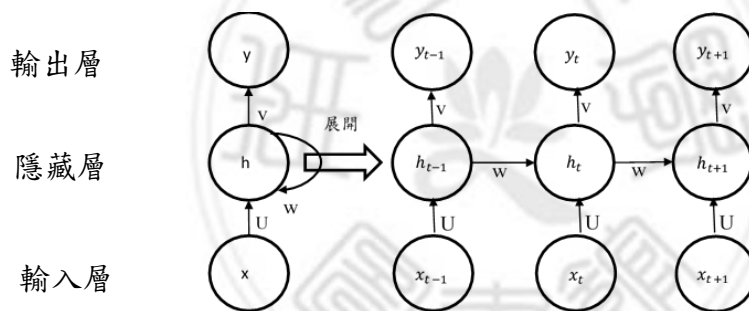


圖 2-1 RNN 展開架構圖

上圖 2-1 為 RNN 展開架構圖，該圖中  $x$  為輸入向量， $y$  為輸出向量， $h$  則是為保留 RNN 內部的狀態向量， $t$  為時步參數， $t-1$  為上一步， $t+1$  為下一步 (谷岡広樹, 康鑫, 2019)。




圖 2-2 RNN 內部計算構造

圖 2-2 為單純 RNN 計算模型方法，在時間點 step  $t$  的輸入向量  $x_t$ ，與更新前內部狀態向量  $h_{t-1}$  連結，成為  $[x_t, h_{t-1}]$  形式的較長向量，而將它作為輸入的激勵函數  $\sigma$ ，其輸出為內部狀態向量  $h_t$ 。

新的內部向量  $h_t$ ，在下一個 step 經由內部迴路傳遞的同時，成為第 2 層的全連結層之輸入向量。在第 2 層的全連結層裡，使用激勵函數  $\sigma$ ，得到 step  $t$  時間點的輸出向量  $y_t$ 。

RNN 公式說明如下（谷岡広樹, 康鑫, 2019）：

$$h_t = \sigma_h (W_h \times [h_{t-1}, x_t]) \quad (2)$$

$$y_t = \sigma (W_y \times h_t) \quad (3)$$

## (二)、長短期記憶神經網路 (Long Short-Term Memory, LSTM)

為了克服梯度消失與梯度爆炸問題，Hochreiter 和 Schmidhuber 於 1997 年提出了長短期記憶神經網路 (Hochreiter & Schmidhuber, 1997)。長短期記憶神經網路 (LSTM) 是循環式神經網路 (RNN) 架構的變體之一，LSTM 非常適合時間序列數據進行分類、處理和預測，因為時間序列中的重要事件之間可能存在未知持續時間的滯後。LSTM 架構，主要由輸入閘、輸出閘、遺忘閘和記憶閘組成，遺忘閘決定從神經元傳遞的訊息或丟棄的訊息，輸入閘決定在神經元狀態中存儲哪些新訊息，而輸出閘調節每個神經元的輸出。

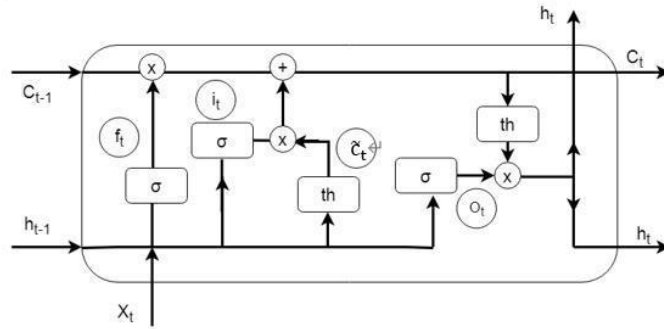


圖 2-3 LSTM 架構示意圖

LSTM 結構內處理演算公式說明如下 (Hochreiter & Schmidhuber, 1997) :

$$\text{輸入閘 (Input Gate)} : i_t = \sigma_g (W_i x_t + U_i h_{t-1} + b_f) \quad (4)$$

$$\text{輸出閘 (Output Gate)} : o_t = \sigma_g (W_o x_t + U_o h_{t-1} + b_o) \quad (5)$$

$$\text{遺忘閘 (Forgotten Gate)} : f_t = \sigma_g (W_f x_t + U_f h_{t-1} + b_f) \quad (6)$$

$$\text{記憶閘 (Memory Gate)} : c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (7)$$

$$\text{記憶神經元 (Memory neurons)} : \tilde{c}_t = \sigma_h (x_t W_c + h_{t-1} U_c + b_c) \quad (8)$$

$$\text{隱藏狀態 (Hidden status)} : h_t = O_t * \sigma_h (c_t) \quad (9)$$

其中  $x_t$  為在時間  $t$  時輸入之資料， $h_t$  為時間  $t$  時自隱藏層計算完之輸出， $W_i$ 、 $W_g$ 、 $W_f$ 、 $W_c$ 、 $U_i$ 、 $U_o$ 、 $U_f$ 、 $U_t$  為輸入閘、輸出閘、遺忘閘、記憶神經元權重參數， $b_f$ 、 $b_o$ 、 $b_i$ 、 $b_c$  為輸入閘、輸出閘、遺忘閘、記憶神經元偏移參數， $\sigma_g$ 、 $\sigma_h$  為活化函數， $\sigma_g$  為 sigmoid 函數， $\sigma_h$  為 tanh 函數。

### (三)、 門控循環網路單元 (Gated Recurrent Unit, GRU)

Kyunghyun Cho 於 2014 年提出門控循環網路單元 (Gated Recurrent Unit, GRU)，GRU 原理與長短期記憶神經網路 (LSTM) 相同，但它合併了輸入閘和遺忘閘。因此，GRU 可以被描述為一種比 LSTM 需要更少參數的更簡單的門控機制 (Chung et al., 2015)，這使得 GRU 運行起來更迅速。GRU 更擅長記住最近的過去訊息而不是遙遠的過去來執行當前任務，並且最近的數據點自然比舊的數

據點更具預測性 (Chollet & Allaire, 2018)。GRU 由重置閘和更新閘組成。重置閘將新輸入與之前的內存匹配，也就是說，它決定了應該忘記多少先前的信息。另一方面，更新閘控制記憶訊息的保留與更新，它的工作原理類似於 LSTM 中的遺忘閘和輸入閘。

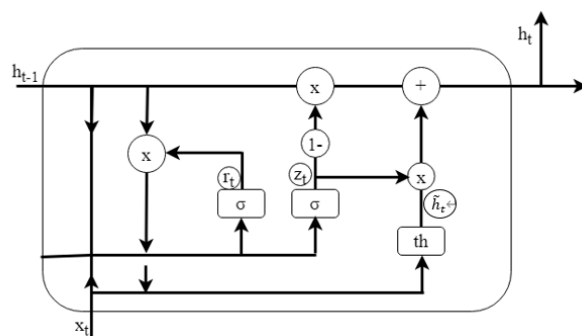


圖 2-4 GRU 架構示意圖

GRU 結構內處理演算公式說明如下 (Busari & Lim, 2021)：

$$\text{更新閘 (Update Gate): } z_t = \sigma_g (W_z x_t + U_z h_{t-1} + b_z) \quad (10)$$

$$\text{重設閘 (Reset Gate): } r_t = \sigma_g (W_r x_t + U_r h_{t-1} + b_r) \quad (11)$$

$$\text{候選隱藏狀態: } \tilde{h}_t = \phi_h (W_h x_t + U_h (r_t \odot h_{t-1}) + b_h) \quad (12)$$

$$\text{隱藏狀態: } h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (13)$$

其中  $x_t$  為在時間  $t$  時輸入向量， $h_t$  為輸出向量， $W$ 、 $U$  為參數矩陣， $b$  為參數向量， $\sigma_g$ 、 $\phi_h$  為激活函數， $\sigma_g$  為 sigmoid 函數， $\phi_h$  為雙曲函數（雙曲正切）。

#### 第四節 預測模型與股市價格分析相關文獻

近年來，人們越來越關注機器學習是否能有效地應用於金融研究。其能夠從數據中提取抽象特徵，並在不依賴計量經濟學假設和人類專業知識的情況下，識別隱藏的非線性關係，使得機器學習作為現有模型和方法的替代方案特別具有吸引力 (Chong et al.2017)。

Selvin 等 (2017) 使用 LSTM、RNN 和卷積神經網路 (Convolutional Neural Network, CNN) 模型，利用移動式滑窗進行印度 NIFTY50 中幾家公司股票價格的預測，比較何種模型較佳的預測力，結果顯示 CNN 在預測極短時間下，做出較佳的預測結果。鄭允中 (2017) 的實驗結果顯示，LSTM 相較於傳統的金融模型有著較高的準確率並優良於 RNN，而加入 dropout 層也能夠有效避免過度擬合導致的問題。鐘毅 (2020) 使用台灣加權股票指數十年盤後日資料與多種技術指標為樣本集，使用特徵縮放進行資料預處理，進行長 LSTM、RNN 及 GRU 混淆矩陣精確度之比較，最後在分辨上漲下跌方向上得到較好的結果，進一步證明深度學習方法應用於台灣大盤股票之可行性。Adebiyi 等 (2014) 使用 ARIMA 與人工神經網路 (Artificial Neural Network, ANN) 模型進行預測比較，以戴爾科技 1988 年到 2011 年的股價日資料進行，結果發現以類神經網路的預測能力較好。Namin 和 Namin (2018) 將 ARIMA 及 LSTM 進行預測道瓊、恆生、那斯達克、日經平均、S&P500 指數與上市公司的股票進行預測比較，結果則 LSTM 優於 ARIMA。

綜合上述，在以往的研究中多數學者將類神經網路與傳統的 ARIMA 模型做比較 (Kimoto & Asakawa, 1990; Gencay, 1996; Yim, 2002)，研究發現類神經網路相較於傳統的 ARIMA 模型，對於容錯能力有著更佳的表现，但也有學者研究發現傳統 ARIMA 模型優於類神經網路 (李培煜, 2021; Yamak et al, 2019)，因此，本研究試圖進一步去探索上述文獻關於傳統 ARIMA 模型優於類神經網路模型的矛盾觀點。本研究使用台灣證券交易所 (TWSE) 的股票數據對時間序列股票預測進行的實證研究。

## 第五節 股市技術指標介紹及相關文獻

技術分析是指研究過去金融市場的資訊，來預測價格的趨勢與決定投資的策略。Murphy (1999) 指出技術分析法建立在三個基本前提假設上，第一：股票市

場價格已經充分反映所有訊息，其二為：隨著趨勢移動的價格，其三為：歷史慣性重複。因此，股票價格和成交量的變化可以反映投資人的行為模式，用以推論股價之短期走勢或長期趨勢，用於決定進出場時機點，以期獲取異常報酬。

過去技術指標文獻中，分為基本面及技術面，以技術面分析加上深度學習方法的預測方法較為精準。廖凡宇（2009）運用類神經網路，並將台灣（ETF50）「指數股票型證券投資信託基金」做為股票歷史資料庫，使用類神經網路配合八項投資技術分析指標（隨機指標（KD）、相對強弱指數（RSI）、移動平均線（MA）、指數平滑異同移動平均線（MACD）、威廉指標（W%R）、買賣氣勢指標（AR）&買賣意願指標（BR）、動量指標（MTM）、每一家加權股價指數點數成交值（TAPI））來建構一個預測股票市場漲跌趨勢之智慧型預測模式。Kara 等（2011）運用類神經網路和支援向量機，使用 10 個技術指標預測伊斯坦布爾證券交易所（ISE）國家 100 指數的表現。Laboissiere 等（2015）利用類神經網路進行股價預測，以聖保羅證券交易所的巴西配電公司股價作為研究，並以平均絕對誤差（MAE）、平均絕對百分比誤差（MAPE）和均方根誤差（RMSE）進行效能評估。陳紀安（2021）研究以寶塔線為核心，搭配常見的技術分析指標：移動平均線（MA）、布林帶寬（BBW）、隨機指標（KD）與成交量組成八種交易策略，以驗證使用寶塔線搭配技術分析指標之策略是否在實務上有其使用價值，實證結果顯示，所有策略均能有效獲取正報酬，其中，以寶塔線搭配隨機指標（KD）與成交量為最佳策略。陳振東和謝政翰（2019）技術分析是可讓投資人利用過去的價格資訊而獲得超額的報酬，顯示了技術指標在台灣股票市場上確實有其效用存在。Ayala 等（2021）應用技術指標與機器學習方法相結合，以產生能夠產生更穩健信號的交易決策。他們表明，雜交提高了利潤，減少了交易次數，降低了虧損風險。Yang 等（2022）將技術分析與組懲罰邏輯回歸相結合，提出了組 SCAD/MCP 懲罰邏輯回歸與技術指標來預測股票價格的上漲和下跌趨勢，提高預測精度，為投資者帶來巨大的



經濟效益。

股市市場上較著名之技術指標有移動平均 (Moving average, MA)、指數平滑異同移動平均線 (Moving Convergence-Divergence, MACD)、相對強弱指數 (Relative Strength Index, RSI)、隨機指標 (Stochastic Oscillator, KD) 等等，以下會分別介紹各個技術指標：

(一)、 移動平均 (Moving average, MA )

移動平均線為 Richard Donchian 與 J.M.Hurst (1970) 在《The Profit Magic of Stock Transaction Timing》書中，將移動平均的概念運用在股市上，移動平均線代表過去一段時間裡平均成交量價格，主要目的用來判斷預測市場現在跟未來的趨勢。移動平均線有三個重要特性 (1) 短長線交叉出現買賣訊號、(2) 移動平均線為落後指標、(3) 檢視股價之支撐或阻力。

(二)、 隨機指標 (Stochastic Oscillator, KD)

隨機指標又稱 KD 指標 (原名 %K & %D)，是由 George Lane 在 1957 年提出原始公式，並在 1986 年提出修正公式。KD 指標融合強弱指標與移動平均線的優點。它藉由收盤價與價格的波動範圍，預測價格趨勢反轉時間。

KD 計算步驟如下：

(1) 計算未成熟隨機值 (Raw Stochastic Value, RSV)：

$$RSV_t = \frac{C_n - L_n}{H_n - L_n} \quad (14)$$

其中  $n$  為交易期間 (一般以 9 日為基準)； $C_n$  為第  $n$  日的收盤價， $H_n$  和  $L_n$  分別是過去  $n$  日內的最高價和最低價。

(2) 計算  $k$  值與  $D$  值：

$$K_t = \frac{m-1}{m} \times K_{t-1} + \frac{1}{m} \times RSV_t \quad (15)$$

$$D_t = \frac{m-1}{m} \times D_{t-1} + \frac{1}{m} \times K_t \quad (16)$$

其中  $m$  為指數移動平均（一般以 3 日為基準）

若如無前一日  $K$  值或  $D$  值，初始值設為 50 帶入計算

(三)、 指數平滑異同移動平均線（Moving Convergence-Divergence, MACD）

指數平滑異同移動平均線（MACD）是 Gerald Appel 於 1970 年提出，利用收盤價短期與長期指數移動平均即將收斂或發散的徵兆，用來判斷賣進、賣出時機的技術指標。

MACD 計算步驟如下：

(1). 計算每日需求指標（Demand Index, DI）：

$$DI_t = \frac{(H + L + 2 \times C)}{4} \quad (17)$$

(2). 計算短期和長期的指數移動平均，通常短期為 12 日、長期 26 日：

$$EMA_t(n) = \frac{EMA_{t-1} \times (n-1) + DI_t \times 2}{n+1} \quad (18)$$

(3). 計算差離值（Differential Value, DIF）：

$$DIF_t = EMA_t(12) - EMA_t(26) \quad (19)$$

(4). 計算 MACD 值（取 DIF 值  $n$  日指標移動平均，通常為 9 日）

$$MACD_t(9) = \frac{MACD_{n-1} \times (n-1) + DIF_t \times 2}{n+1} \quad (20)$$

其中  $H$  為最高價； $L$  為最低價； $C$  為收盤價。

(四)、 相對強弱指數（Relative Strength Index, RSI）

相對強弱指數（RSI）是技術分析威列斯·威爾德 1978 年提出，RSI 的理論基礎是先行指標的一種，它是以某段期間股價平均漲幅與平均跌幅所計算的數值，可看出股價觀測時間內股票價格強勢或弱勢的指標。由於計算方式的限制，不論股價或指數如何變動，RSI 都僅能在 0~100 之間起伏，因此更能方便參考使用，

為國內應用最普遍的技術指標。

RSI 計算公式如下：

$$RS = \frac{AU_n}{AD_n} \quad (21)$$

$$RSI = \left(1 - \frac{1}{1+RS}\right) \times 100\% \quad (22)$$

其中 RS 為相對強度 (Relative Strength, RS)；n 是經過的交易時間，一般以 9 或 14 日為基準，本研究以 14 日為基準；AUn 表示 n 日內收盤價上漲點數的平均數；ADn 表示 n 日內收盤價下跌點數的平均數。

#### (五)、 威廉指標 (Williams%R , W%R)

威廉指標由家拉里·威廉斯於 1973 年提出，屬於振盪指標，是依價格的擺動點來度是否超買或超賣的現象，提供市場趨勢反轉的訊號。

W%R 計算公式如下：

$$W\%R = \frac{H_n - C_n}{H_n - L_n} \times 100\% \quad (23)$$

其中 n 是交易者設定的交易期間 (常用為 14 天)； $C_n$  為第 n 日的最新收盤價； $H_n$  是過去 n 日內的最高價； $L_n$  是過去 n 日內的最低價。

#### (六)、 乖離率 (BLAS)

乖離率判別目前股價是否過度上漲或者是過度下跌的技術指標。可分為正乖離率與負乖離率，若股價在移動平均線之上，乖離率會為正值，正值越大時，代表大多數投資者皆處於獲利狀態且獲利頗豐富，稱為正乖離率；股價在移動平均線之下，乖離率會為負值，負值越大時，代表大多數投資者虧數越為嚴重則為負乖離率。

BIAS 計算公式如下：

$$BIAS_n = \frac{Close - MA_n}{MA_n} \times 100\% \quad (24)$$

其中 Close 為當日收盤價； $MA_n$  為  $n$  日移動平均價， $n$  依需求自訂日數，一般設定 3 日和 6 日。

(七)、 布林通道 (Bollinger Bands, BBands)

布林通道也稱為布林帶、保力加通道、包寧傑帶狀，或布歷加通道，是由約翰·包寧傑於 1980 年提出，屬於中長期指標。布林通道結合了移動平均和標準差的概念，產生三條軌道線組成的帶狀通道分析價格及趨勢。「中軌」為價格的平均成本，「上軌」和「下軌」可分別視為價格的壓力線和支撐線。

Bollinger Bands 計算步驟如下：

(1). 計算中軌：即收盤價  $n$  日簡單移動平均數 (Simple Moving Average, SMA)

$$SMA_t(n) = \frac{C_t + C_{t-1} + \dots + C_{t-n+1}}{n} \quad (25)$$

(2). 計算收盤價及中軌 (SMA) 的標準差 (Standard Deviation, SD)

$$SD_t(n) = \frac{\sqrt{(C_t - SMA_t)^2 + \dots + (C_{t-n+1} - SMA_{t-n+1})^2}}{n} \quad (26)$$

(3). 計算上軌 (Bollinger Up)

$$BollingerUp_t(n) = SMA_t(n) + K \times SD_t(n) \quad (27)$$

(4). 計算下軌 (Bollinger Down)

$$BollingerDown_t(n) = SMA_t(n) - K \times SD_t(n) \quad (28)$$

其中  $C$  為收盤價； $n$  為區間天數，通常取 20 日 (月均線)； $K$  為 2。

(八)、 真實波動幅度均值 (Average True Range, ATR)

真實波動幅度均值是由美國機械工程師、技術分析師威勒斯·威爾德 (J. Welles Wilder) 所發展出來的技術分析指標，以  $N$  天的指數移動平均數平均後的交易波動幅度。

Average True Range 計算步驟如下：

(1). 計算出 TR (即當天的真實波幅)，計算公式如下：

$$TR = \max(H_t, C_{t-1}) - \min(L_t, C_{t-1}) \quad (29)$$

其中  $H_t$  表 t 日最高價； $L_t$  表 t 日最低價； $C_{t-1}$  表 t-1 日收盤價； $H_t$  恆大於  $L_t$

(2). 計算 ATR，計算公式如下：

真實波動幅度均值便是「真實波動幅度」之 n 日指數移動平均數，一般設定 14 日和 21 日。

$$ATR = EMA_{(TR, n)} \quad (30)$$

綜合上述本研究整理常見技術指標之文獻，並加入開盤價、最高價、最低價及當期收盤價，整理如下表 2-1，彙整出 18 個特徵變數及 1 個預測目標，進行資料預處理，詳細過程請參閱第三章。

表 2-1 技術指標文獻回顧

技術指標	介紹	應用文獻
移動平均線 (MA)	對特定期間的收盤價進行簡單平均化的計算	Alhashel et al. (2018)
		Chen et al. (2014)
		Gorenc Novak 與 Velušček (2016)
		Henrique et al. (2018)
		Laboissiere et al. (2015)
		Lahmiri (2014)
		Patel et al. (2015)
		Weng et al. (2017)
		陳紀安 (2021)
		廖凡宇 (2009)
隨機指標 (KD)	KD 指標融合強弱指標與移動平均線的優點。它藉由收盤價與價格的波動範圍，預測價格趨勢反轉時間	Alhashel et al. (2018)
		Chang et al. (2012)
		Chen et al. (2014)
		Laboissiere et al. (2015)
		Lahmiri (2014)
		Nakano et al. (2018)

		Oliveira et al. (2013) Yu et al. (2009) 廖凡宇 (2009) 鄭健毅 (2010)
相對強弱指數 (RSI)	以某段時間，股價平均漲幅與平均跌幅所計算出來的數值，可看出股價觀測時間內股票價格強勢或弱勢的指標	Alhashel et al. (2018) Chen et al. (2014) Gorenc Novak 與 Velušček (2016) Henrique et al. (2018) Lahmiri (2014) Nakano et al. (2018) Patel et al. (2015) Weng et al. (2017) 廖凡宇 (2009) 鄭健毅 (2010)
指數平滑異同移動平均 (MACD)	應用快速與慢速的平滑移動平均線 (EMA)，計算兩者之間的差離值 (DIF) 收斂或發散的徵兆，判斷買賣股票的時機與訊號	Alhashel et al. (2018) Chang et al. (2012) Chen et al. (2014) Chiang et al. (2016) Creamer (2012) Lahmiri (2014) Nakano et al. (2018) Patel et al. (2015) 廖凡宇 (2009) 鄭健毅 (2010)
威廉指標 (Williams %R)	運用股市的擺動點來量度其超買超賣現象，可以量度循環期內的高點或低點，提出有效率的投資訊號，其為一有效的短期指標	Alhashel et al. (2018) Chang et al. (2009) Chang et al. (2012) Chen et al. (2014) Huang & Tsai (2009) Kara et al. (2011)

		Kim&Han (2000)
		Ticknor (2013)
乖離率 (BIAS)	利用股價和均線的距離，用來衡量目前股價偏離移動平均線的程度	Chang et al. (2009)
		Chang et al. (2012)
		Chang& Fan (2008)
		Chen et al. (2014)
		Huang & Tsai (2009)
真實波動幅度 均值 (ATR)	主要用於分析價格的波動性，亦及價格的變動程度。	Henrique et al. (2018)
		Vanstone& Finnie (2010)
布林通道 (BBands)	結合了移動平均線以及標準差之概念，基本型態為頂端、中間以及下端三部分，而中間為股價的平均成本、上端以及下端分別為壓力線以及支撐點	Lahmiri (2014)
		Prasetijo et al. (2017)
		盧廷宇 (2011)

資料來源：本研究整理

### 第三章 特徵縮放預測分析模型

過去學者利用傳統整合移動平均自迴歸模型 (Autoregressive Integrated Moving Average model, ARIMA) 及深度學習長短期記憶神經網路 (Long Short-Term Memory, LSTM) 進行股市價格預測分析, 結果顯示傳統 ARIMA 模型優於類神經網路 (李培煜, 2021; Yamak et al, 2019), 這於部分文獻 (Kimoto & Asakawa, 1990; Gencay, 1996; Yim, 2002) 研究發現有矛盾, 因此引發本研究想進一步探討驗證, 比較傳統 ARIMA 模型與類神經網路於時間序列上的預測準確度。且過去研究並沒針對特徵縮放方法、遞迴式類神經網路的交互影響進行討論。本研究利用常見的技術指標, 並結合不同特徵縮放及深度學習演算法進行股市價格預測分析。本研究的貢獻有以下幾點: (1) 使用不同特徵縮放方法對遞迴神經網路預測準確度之影響 (2) 探討加入常見技術指標是否可以提高遞迴神經網路準確度 (3) 探討不同神經元數及層數對於遞迴神經網路預測準確度之影響 (4) 實際採用 2015-2019 年 A 公司實際股票資料來進行實例驗證, 以下章節將會一一說明。

#### 第一節 研究架構

本研究資料來源為台灣證券交易所 (TWSE) 的股票資料, 同時彙整 18 個常見股市價格的技術指標, 利用特徵縮放與深度學習進行預測分析, 最後利用均方誤差 (Mean-Square Error, MSE)、均方根誤差 (Root-Mean-Square Error, RMSE)、平均絕對百分比誤差 (Mean Absolute Percentage Error, MAPE) 來結果評估, 以下則是研究架構之步驟說明。



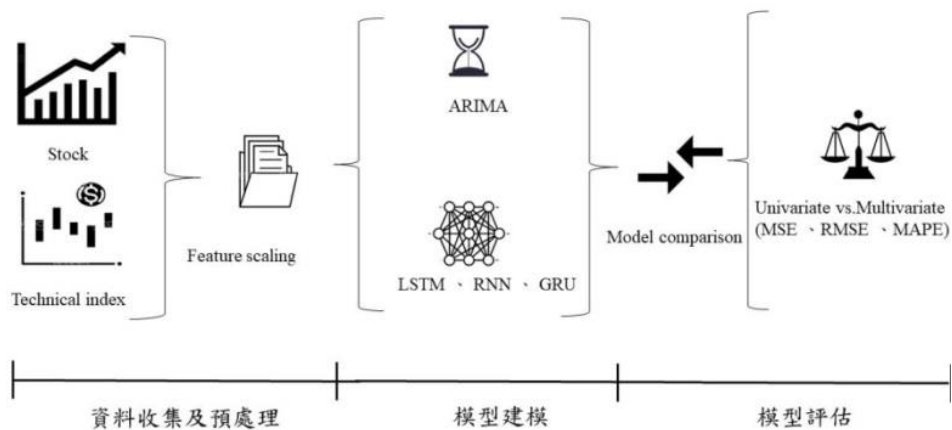


圖 3-1 研究架構圖

#### 步驟 1：單一指標與多指標選取

本研究利用取台灣證券交易所 (TWSE) 股票資料，爬取 A 公司的歷史股票數據。我們使用 2015/01/05 至 2019/12/31 期間的數據作為股票數據，共 1223 筆。每一筆包含每日日期、開盤價、最高價、最低價、收盤價、交易量，所有的歷史交易資料皆由試算表儲存。

將技術指標計算公式撰寫成程式碼，進行計算。本研究彙整文獻中出現次數較高的 18 個技術指標 (分別為 A01 至 A18)，如表 3-1 所示。「下一期股價」是本研究的預測變數為 Y，以預測股價的趨勢。

表 3-1 技術指標的名稱及代號

名稱	代號
開盤價 (元)	A1
最高價 (元)	A2
最低價 (元)	A3
14 日相對強弱指標 (RSI)	A4

5日平均線 (MA5)	A5
10日平均線 (MA10)	A6
20日平均線 (MA20)	A7
14日威廉指標 (W%R)	A8
6日乖離率 (BIAS6)	A9
12日乖離率 (BIAS12)	A10
9日快速隨機指標 (K9)	A11
9日慢速隨機指標 (D9)	A12
9日指數平滑異同移動平均線 (MACD)	A13
真實波動幅度均值 (ATR)	A14
20日布林通道-上軌 (Bollinger Up)	A15
20日布林通道-下軌 (Bollinger Down)	A16
20日布林通道-中軌 (SMA)	A17
當期收盤價	A18
下一期收盤價	Y

資料來源：本研究整理

## 步驟 2：數據預處理與特徵縮放

在此階段檢查原始數據，將空缺數據進行補齊或剔除，便於進行模型訓練與測試。考慮到預測的數值，需符合常態分佈有利於模型的學習和預測值輸出，而收盤價數據不能滿足此條件，因此需要在原始數據輸入模型之前進行特徵縮放。本研究所用的特徵縮放方法包含標準分數 (StandardScaler)、四分位距標準化 (RobustScaler)、極大極小標準化 (MinMaxScaler)，特徵縮放的詳細介紹在 3.2 節說明。

### 步驟 2.1：滑動窗口

股票資料序列排序，輸入於深度學習模型，我們必須經過以下轉換格式，假設給定時間序列  $N$  天的長度，預測第  $N+i$  天的股票價格  $Y_i$ ，時間從  $i$  到  $i+N-1$  天的股價資料表示為  $X_i$ :  $[X_i, \dots, X_{i+N-1}]$ ，預測的資料為  $Y_i$  而  $(X_i, Y_i)$  被用作深度學習神經網路的輸入。本研究採用四期的滑動窗口

### 步驟 3：模型訓練

經過資料預處理後，本研究使用四種深度學習建立模型。深度學習包含循環式類神經網路 (Recurrent Neural Network, RNN)、長短期記憶神經網路 (Long Short-Term Memory, LSTM)、門控循環網路單元 (Gated Recurrent Unit, GRU) 及整合移動平均自迴歸模型 (Autoregressive Integrated Moving Average model, ARIMA)。

### 步驟 4：評估比較

本研究選以均方誤差 (Mean-Square Error, MSE)、均方根誤差 (Root-Mean-Square Error, RMSE) 及平均絕對百分比誤差 (Mean Absolute Percentage Error, MAPE) 分析法來評估模型 (Cheng & Ma, 2015; Jun & Cheng, 2017; Ma & Cheng, 2016)，請參閱公式 (32) ~ (34)，其值越小則表示實際值和預測值的誤差值越小，說明其準確度表現越佳。

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (32)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (33)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad (34)$$

其中  $n$  為樣本數， $y_i$  為實際值， $\hat{y}_i$  為預測值。

## 第二節 特徵縮放

特徵縮放也稱為標準化是數據預處理過程中的一個步驟，使數據轉化到特定的範圍內，特徵縮放有助於模型收斂速度，特徵縮放是使用 Keas 學習和深度學習進行的實驗的共同要求。特徵縮放有許多不同的方法用於數據集的特徵縮放，最常用有：StandardScaler、MinMaxScaler、Normalizer 和 RobustScaler (Thara et al., 2019)。然而在過去文獻中並沒有說明使用不同特徵縮放方法對預測模型的影響，因此本研究想探討特徵縮放如何影響預測模型的性能。以下將介紹本研究所使用之特徵縮方法：

### (一)、標準分數 (StandardScaler)

StandardScaler 稱為標準分數又稱為 Z-score，主要是以標準差為單位來表示一項數值在所有數據中所處的相對位置，標準差主要是用來測量一組數值的離散程度，一個較大的標準差，代表大部分的數值和其平均值之間差異較大；一個較小的標準差，代表這些數值較接近平均值。若某一筆數據的值低於平均值，則經過 StandardScaler 標準化後的值會是負值，反之則為正值，而 StandardScaler 的公式是將原始數值先扣掉平均值後再除以標準差，將所有數據都按照此公式轉換後，便能將所有數據進行縮放，以達到特徵縮放的目的 (黃星瑋, 2018)。

$$z = \frac{x - \mu}{\sigma} \quad (35)$$

其中， $z$  是特徵的變換值； $x$  是原始值； $\mu$  是平均值； $\sigma$  是標準差。

### (二)、極大極小標準化 (MinMaxScaler)

MinMaxScaler 標準化方法會對原始數據進行線性變換，很明顯，當  $x$  為最大值時，會被轉換為 1；當  $x$  為最小值時，對應的新值為 0；整組數據會分布在從 0

到 1 的區間內，而數據的分布形態並不會發生變化（黃星璋，2018）。

$$x_{new} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (36)$$

其中  $x$  為原始數據； $x_{min}$  為數據最小值； $x_{max}$  數據最大值。

#### (三)、四分位距標準化 (RobustScaler)

RobustScaler 方法對於數據中心化和數據的縮放性有著更強的參數調節能力，它的方法與 MinMaxScaler 幾乎相似，但它使用四分位數範圍（Thara et al., 2019）。

$$x_{new} = \frac{x - median}{IQR} \quad (37)$$

其中  $x$  為樣本的某個值；Median 為樣本中位數；IQR：樣本四分位距。

#### (四)、資料預處理

在過去的文獻中，許多研究都使用特徵縮放作為預處理步驟並建立預測模型，像 Tsantekidis 等人（2017）提出了一種從原始 LOB 數據中提取靜態特徵的新方法，使用 StandardScaler 標準分數來轉換相對標準分數，用於不同的 DL、ML 模型，即 SVM、多層感知器（Multilayer Perceptron, MLP）、CNN 和 LSTM，實驗證明所提出的特徵方法明顯優於原始價格特徵。Zhang 等人（2019）開發了一個大規模的深度學習模型，該架構利用卷積濾波器來捕獲 LOB 的空間結構以及 LSTM 來捕獲更長的時間依賴性，使用倫敦證券交易所的一年市場報價來測試我們的模型，數據使用 StandardScaler 及 MinMaxScaler 為數據進行轉換，結果顯示該模型為各種工具提供了非常穩定的樣本外預測精準度。

Sethia 和 Raut（2019）對 LSTM、GRU、ANN 和 SVM 模型進行了性能比較，數據使用 MinMaxScaler 對數據集進行轉換，然後進行極小極大縮放和降維，最後使用自定義指標（如樂觀和悲觀比率以及回報率）比較不同模型在該數據集上的性能。Li 等人（2019）提出了一種用於股票價格預測的新型深度神經網 DP-LSTM，

研究中為了檢測股票價格模式，需要對股票價格數據使用 MinMaxScaler 對數據集進行轉換，在預測結果中發現均方誤差 (MSE) 有顯著提升。Ding 和 Qin (2020) 提出了一種基於 LSTM 的多輸入多輸出關聯深度循環神經網路模型，其為了避免不同計量單位的影響，將所有的指標數據利用特徵縮放方法為同一範圍，使用 MinMaxScaler 方法。

Thara 等人 (2019) 提出了一種使用傳統神經網路的自動癲癇發作檢測方法，使用機器學習分類器 (SVM、KNN) 與深度神經網路進行實驗。研究中使用四種不同特徵縮放 (StandardScaler、MinMaxScaler、Normalizer、RobustScaler) 對數據集進行轉化。從實驗結果可以看出 StandardScaler 和 RobustScaler 有優秀的表現。Luu 等人 (2022) 應用了一個混合框架，結合了 Stokes-Mueller 分解方法和各種人工智能 (Artificial Intelligence, AI) 模型來檢測 SCC、BCC 和黑色素瘤皮膚癌。使用九種不同的人工智能模型，其中這些模型已經使用十二種不同的預處理方案 (三種特徵縮放：Standardization, MinMaxScaler 及 RobustScaler、三種 PCA 降維方法和六種組合特徵縮放/PCA 方法) 進行了訓練和測試。結果表明，在對輸入參數進行適當預處理的情況下，所有考慮的 AI 模型都實現了至少 90% 的分類準確度 (F1 分數)。

經由上述文獻可以發現深度學習使用不同預處理方法會影響預測準確度，因此本研究提出三種特徵縮放方法進行比較，試圖了解不同特徵縮放方法對深度學習預測是否有影響，並將數據進行特徵縮放後之數值放入深度學習模型進行股市預測分析。

### 第三節 個案介紹及實驗設計說明

#### 一、 個案介紹

A 公司是台灣一家半導體製造公司，成立於 1987 年，是全球第一家、以及最大的專業積體電路製造服務企業，專注於晶圓專業製造服務之本業，以卓越的製造與服務能力為核心競爭優勢，致力於提供全球半導體廠商極大型及超大型積體電路晶圓製造晶圓針測、包裝及測試、光罩製作、設計支援服務等全系列的各項服務。本研究使用台灣證券交易所 (TWSE) 的股票資料，收集 A 公司的歷史股票數據。本研究使用 2015/01/01 至 2019/12/31 期間的數據作為股票數據，共 1223 筆，數據集的前 70% 做為訓練數據，其餘的 30% 做為測試數據。

#### 二、 模型設計

本研究設計單一指標與多指標進行預測分析比較，驗證常見技術指標是否可以提高模型準確度?本研究單一指標以台灣證券交易所 (TWSE) 的 A 公司歷史股票資料中以收盤價為主，如圖 3-3 所示，多指標利用彙整文獻中出現次數較高的 18 個技術指標進行預測分析，如圖 3-4 所示，詳細說明已在 3.1 節討論。




圖 3-2 單一指標模型示意圖

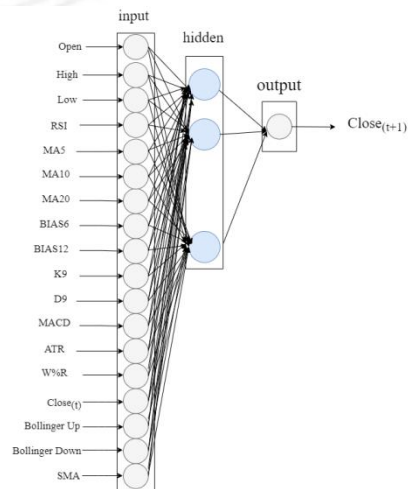


圖 3-3 多指標模型示意圖

### 三、 模型建模及參數設定

#### (一)、 整合移動平均自迴歸模型

整合移動平均自迴歸模型 (ARIMA) 模型建立需先做參數的評估。利用數據之自我相關函數 (Sample Autocorrelation Function, ACF) 判斷數據是否為穩定，需做差分平穩，此時所代表之  $d$  值，即為數據所需取差分之次數。接者使用 AIC 值估計出參數  $(p,d,q)$  中的  $(p,d)$  值後進行建模預測評估。

#### (二)、 遞迴式神經網路

根據 David (1994) 之研究，其所提出必須透過試誤法 (Trial and Error) 不斷嘗試，才可能找出最合適之神經元個數。因此本研究對遞迴式神經網路 (RNN、LSTM、GRU) 參數設定，以模型網路層數 (1~3 層)、Adaptive Moment Estimation (Adam) 為優化器、MSE 為損失函數、激活函數為 sigmoid 函數，batch size 設定為 20，神經元數為 32、64、128 與 256 搭配組合，丟棄率皆為 0.2，及一個輸出層作為預測結果輸出，預測值為股票收盤價，如下表 3-2。在參數設定的參數組合總和共 84 組 (請參閱附錄 A，附錄 B)，並每各參數組合應用於遞迴神經網路搭配不同特徵縮放方法，進行評估模型的預測準確度。

表 3-2 參數設定

參數名稱	設定
模型	RNN、LSTM、GRU
神經元數	32、64、128 與 256
層數	1~3
優化器	Adam
損失函數	MSE
激活函數	sigmoid



丟棄率 (Dropout)	0.2
batch size	20

資料來源：本研究整理



## 第四章 資料分析與結果

本章節將透過台灣證券交易所 (TWSE) 的蒐集 A 公司股票資料，資料收集時間為 2015 年 1 月至 2019 年 12 月底每日股票資料，共 1223 筆。本研究為了(1) 探討不同特徵縮放是否會影響深度學習模型準確度，因此本研究提出三種特徵縮放方法進行驗證分析；(2) 探討加入常見技術指標是否會提高模型預測準確度，因此本研究設計兩種模型分別為單一指標及多指標進行驗證分析，詳細介紹已在 3.4 節說明；(3) 驗證傳統 ARIMA 模型與遞迴神經網路預測準確度之比較，(4) 探討不同神經元數及層數對於預測準確度之影響，最後利用均方誤差 (Mean-Square Error, MSE)、均方根誤差 (Root-Mean-Square Error, RMSE)、平均絕對百分比誤差 (Mean Absolute Percentage Error, MAPE) 來進行模型預測結果評估。

### 第一節 資料分析

#### 一、實驗分析

在實驗分析部份，本研究主要針對兩點來進行評估：(1) 觀察 Loss 值變化；(2) 查看模型訓練效果。訓練模型過程將 Loss 值數據作為可視化的圖呈現，有助於研究者理解該模型訓練的過程是否達到收斂，以及是否有過度學習的情況。




圖 4-1 特徵縮放模型 LOSS 變化圖

下圖為模型預測效果，本研究將資料集的實際值以及預測值作視覺化圖型顯示，做為預測效能之參考，請參閱圖 4-2。




圖 a:RNN 模型預測效果 圖 b:LSTM 模型預測效果 圖 c:GRU 模型預測效果

圖 4-2 模型預測效果

## 二、方法評估

本研究選用以均方誤差 MSE (Mean-Square Error) 及均方根誤差 RMSE (Root-Mean-Square Error) 分析法來評估模型，根據 David (1994) 之研究，其所提出必須透過試誤法 (Trial and Error) 不斷嘗試，才可能找出最合適之神經元個數。依據本研究模型設計分為單指標及多指標分別進行實驗分析，並將實驗結果預測進行比較。為了驗證本研究的準確度與分析，因此在後續研究比較採用兩個部分進行評估：(1) 傳統整合移動平均自迴歸模型 (Autoregressive Integrated Moving Average model, ARIMA) 與遞迴式神經網路 (RNN、LSTM、GRU) 預測能力之比較；(2) 不同參數的比較。

### ● ARIMA 與特徵縮放比較

表 4-1 本研究參考過去文獻針對傳統 ARIMA 模型與深度學習進行比較分析 (李培煜,2021)，研究中的基準參考過去文獻設定為 ARIMA (1,1,0)。並且使用不同特徵縮放方法進行分析比較。由表 4-1 可以發現可發現使用不同特徵縮放方法會去影響模型預測準確度。

表 4-1 ARIMA (1,1,0) 模型預測比較 (非還原值)

方法	測試集 MSE
StandardScaler	0.00426580
MinMaxScaler	0.00020546
RobustScaler	0.00144028

資料來源：本研究整理

● 參數調整說明-激活函數

本研究依過去文獻的五種模型進行調整(李培煜,2021)，主要調整神經元數、連接層及是否使用丟棄率，本研究並更改 sigmoid 函數做為激活函數，使用 StandardScaler 特徵縮放方法，實驗結果如下表 4-2。由此表可發現使用 sigmoid 函數的方法表現較佳，因此本研究後續比較皆採用 sigmoid 為激活函數。

表 4-2 模型預測比較表

編號	神經元數	連接層	丟棄層 (0.2)	基準點	測試集 MSE		
					LSTM (本研究)	GRU (本研究)	RNN (本研究)
1	1024	1	0	45.12	17.16	15.03	20.02
2	2048	1	0	22.62	19.32	17.64	15.03
3	1024	3	0	162.41	14.99	31.07	23.19
4	1024	1	1	32.79	16.43	14.13	19.24
5	2048	3	1	542.21	76.82	32.52	12.31

備註：

- 1.李培煜 (2021) 激活函數 SELU
- 2.本研究改 sigmoid 做為激活函數，使用 StandardScaler 特徵縮放方法

- 遞迴神經網路與特徵縮放比較

此部分主要探討 (1) 特徵縮放在不同層數的差異分析及 (2) 特徵縮放在遞迴神經網路的差異分析，本研究將以變異數分析進各項資料分析；以了解特徵縮放方法與遞迴神經網路各構面差異情形；

- (一)、 特徵縮放在不同層數的差異分析

本研究在參數設定層數為 1~3 層，因此本研究想探討是否因層數變異的不同而有所差異。

- (1) 以層數變化觀察差異情形

由表 4-3 得知，在特徵縮放的「一層」構面上，組別同值，變異數分析 ( $F=1.46$ ,  $p=0.28>0.05$ ) 未達顯著水準，顯示出特徵縮放的「一層」構面沒有差異。

在特徵縮放的「二層」構面上，均等平均數的 Robust 檢定 Brown-Forsythe 及 Welch 統計量之  $p$  值小於 0.05 (顯著)，進行事後比較，經由 Games-Howell 檢定得到特徵縮放「MinMaxScaler」與「StandardScaler」顯著高於「RobustScaler」。

在特徵縮放的「三層」構面上，均等平均數的 Robust 檢定 Brown-Forsythe 及 Welch 統計量之  $p$  值小於 0.05 (顯著)，進行事後比較，經由 Games-Howell 檢定得到特徵縮放「MinMaxScaler」顯著高於「StandardScaler」顯著高於「RobustScaler」。

表 4-3 不同特徵縮放方法在預測準確度層數之差異分析摘要表 (單一全部)

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F	事後 檢定
一層	1.StandardScaler	12	36.89	402.96	126.44	116.55	3.26	1.46	
	2.RobustScaler	12	20.55	230.70	66.67	59.08			
	3.MinMaxScaler	12	28.01	246.94	97.64	70.45			
二層	1.StandardScaler	48	50.07	547.38	177.94	110.43	12.02*	14.93 <sup>註2</sup>	3、1>2
	2.RobustScaler	48	16.79	315.86	77.70	71.87			
	3.MinMaxScaler	48	30.88	778.67	226.22	187.33			
三層	1.StandardScaler	192	27.55	1549.91	302.83	245.88	49.00*	42.74 <sup>註2</sup>	3>1>2
	2.RobustScaler	192	19.39	869.91	167.21	144.22			
	3.MinMaxScaler	192	47.44	5082.78	577.09	714.15			

備註：

1.\*  $\alpha < 0.05$

2. 組別不同質，改採 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05 (顯著)，進行事後較

3. 因本研究使用 MSE 作為預測準確度判斷, MSE 越小代表越好

(2) 以不同特徵縮放觀察差異情形

由表 4-4 得知，在層數的「StandardScaler」構面上，均等平均數的 Robust 檢定 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05 (顯著)，進行事後比較，經由 Games-Howell 檢定得到層數「三層」顯著高於「一層」。

在層數的「RobustScaler」構面上，在均等平均數的 Robust 檢定 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05 (顯著)，進行事後比較，經由 Games-Howell 檢定得到顯示層數「三層」顯著高於「二層」、「一層」。

在層數的「MinMaxScaler」構面上，在均等平均數的 Robust 檢定 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05 (顯著)，進行事後比較，經由 Games-Howell 檢定得到顯示層數「三層」顯著高於「一層」。

表 4-4 不同層數在預測準確度特徵縮放方法之差異分析摘要表 (單一全部)

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F	事後 檢定
StandardScaler	1.一層	12	36.89	402.96	126.44	116.55	5.72 <sup>*</sup>	8.74 <sup>註2</sup>	3>1
	2.二層	48	50.07	547.38	177.94	110.43			
	3.三層	192	27.55	1549.91	302.83	245.88			
RobustScaler	1.一層	12	20.05	230.70	66.67	59.08	11.05 <sup>*</sup>	11.28 <sup>註2</sup>	3>2、1
	2.二層	48	16.79	315.86	77.70	71.87			
	3.三層	192	19.39	869.91	167.21	144.22			
MinMaxScaler	1.一層	12	28.01	246.94	97.64	70.45	9.27 <sup>*</sup>	8.34 <sup>註2</sup>	3>1
	2.二層	48	30.88	778.67	226.22	187.33			
	3.三層	192	47.44	5082.78	577.09	714.15			

備註：

1. <sup>\*</sup>  $\alpha < 0.05$

2. 組別不同質，改採 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05 (顯著)，進行事後較

3. 因本研究使用 MSE 作為預測準確度判斷, MSE 越小代表越好



(二)、 特徵縮放在遞迴神經網路的差異分析

本研究在參數設定層數為 1~3 層，本研究分別利用層數做為區隔，分別探討分析使用不同特徵縮放方法與遞迴神經網路準確度，是否因特徵縮放方法變異數的不同而有所差異。

(1). 層數為一層

a：以遞迴神經網路觀察差異情形

由表 4-5 所示；從表中資料可知：遞迴神經網路三個構面之 F 值均未達顯著水準。

表 4-5 不同特徵縮放方法在遞迴神經網路預測準確度之差異分析表（一層）

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F
RNN	1.StandardScaler	4	36.89	274.96	155.96	116.17	1.84	0.51
	2.RobustScaler	4	44.12	230.70	103.30	87.93		
	3.MinMaxScaler	4	34.02	163.78	94.14	69.61		
LSTM	1.StandardScaler	4	44.72	402.96	145.44	172.11	3.44	0.94
	2.RobustScaler	4	27.53	120.89	58.76	43.27		
	3.MinMaxScaler	4	91.51	246.94	155.48	68.61		
GRU	1.StandardScaler	4	54.66	143.50	77.94	43.72	3.06	2.37
	2.RobustScaler	4	20.05	54.19	38.18	15.35		
	3.MinMaxScaler	4	28.01	62.29	43.30	15.32		

備註：

1\*  $\alpha < 0.05$

2.因本研究使用 MSE 作為預測準確度判斷,MSE 越小代表越好

b：以不同特徵縮放方法觀察差異情形：

由表 4-6 所示；從表中資料可知：遞迴神經網路三個構面之 F 值均未達顯著水準。

表 4-6 不同遞迴神經網路在特徵縮放方法預測準確度之差異分析表（一層）

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F
StandardScaler	1.RNN	4	36.89	274.96	155.96	116.17	3.38	0.48
	2.LSTM	4	44.72	402.96	145.44	172.11		
	3.GRU	4	54.66	143.50	77.94	43.72		
RobustScaler	1.RNN	4	44.12	230.70	103.30	87.93	2.73	1.36
	2.LSTM	4	27.53	120.89	58.76	43.27		
	3.GRU	4	20.05	54.19	38.11	1535		
MinMaxScaler	1.RNN	4	34.02	163.78	94.14	69.61	6.15	3.87
	2.LSTM	4	91.51	246.94	155.48	68.61		
	3.GRU	4	28.01	62.29	43.30	15.32		

備註：

1\*  $\alpha < 0.05$

2.因本研究使用 MSE 作為預測準確度判斷,MSE 越小代表越好

(2). 層數為二層

a：以遞迴神經網路觀察差異情形

由表 4-7 得知，特徵縮放的「RNN」構面上，在均等平均數的 Robust 檢定 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05（顯著），進行事後比較，經由 Games-Howell 檢定得到特徵縮放「MinMaxScaler」顯著高於「RobustScaler」。

在特徵縮放的「LSTM」構面上，因組別具有同值，變異數分析（ $F=16.54$ ， $p=0.00<0.05$ ）達到顯著，經 Scheffé 法事後比較，顯示特徵縮放「MinMaxScaler」顯著高於「RobustScaler」與「StandardScaler」。

在特徵縮放的「GRU」構面上，在均等平均數的 Robust 檢定 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05（顯著），進行事後比較，經由 Games-Howell 檢定得到特徵縮放「StandardScaler」顯著高於「RobustScaler」顯著高於「MinMaxScaler」。

表 4-7 不同特徵縮放方法在遞迴神經網路預測準確度之差異分析表（二層）

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F	事後 檢定
RNN	1.StandardScaler	16	55.58	547.38	162.52	142.17	18.81*	5.30 <sup>註2</sup>	3>2
	2.RobustScaler	16	27.40	202.85	77.84	55.64			
	3.MinMaxScaler	16	30.88	778.67	290.57	283.99			
LSTM	1.StandardScaler	16	50.07	380.85	169.37	88.24	1.38	16.54 <sup>註3</sup>	3>1、2
	2.RobustScaler	16	27.31	315.86	119.13	92.90			
	3.MinMaxScaler	16	190.64	387.41	280.88	58.91			
GRU	1.StandardScaler	16	69.62	454.27	201.92	96.26	5.52*	25.19 <sup>註2</sup>	1>3>2
	2.RobustScaler	16	16.79	93.88	36.14	28.05			
	3.MinMaxScaler	16	41.98	262.31	107.21	55.92			

備註：

1.\*  $\alpha < 0.05$

2.組別不同質，改採 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05（顯著），進行事後較

3.事後檢定使用 Scheffé 方法

4.因本研究使用 MSE 作為預測準確度判斷，MSE 越小代表越好

b：以不同特徵縮放方法觀察差異情形：

由表 4-8 得知，在遞迴神經網路的「StandardScaler」構面上，組別同值，變異數分析 ( $F=0.57$ ,  $p=0.56>0.05$ ) 未達顯著水準，顯示不同特徵縮放方法在預測準確度遞迴神經網路「StandardScaler」構面沒有差異。

在遞迴神經網路的「RobustScaler」構面上，在均等平均數的 Robust 檢定 Brown-Forsythe 及 Welch 統計量之  $p$  值小於 0.05 (顯著)，進行事後比較，經由 Games-Howell 檢定得到遞迴神經網路「LSTM」顯著高於「GRU」。

在遞迴神經網路的「MinMaxScaler」構面上，在均等平均數的 Robust 檢定 Brown-Forsythe 及 Welch 統計量之  $p$  值小於 0.05 (顯著)，進行事後比較，經由 Games-Howell 檢定得到遞迴神經網路「RNN」與「LSTM」顯著高於「GRU」。

表 4-8 不同遞迴神經網路在特徵縮放方法預測準確度之差異分析表（二層）

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F	事後 檢定
StandardScaler	1.RNN	16	55.58	547.38	162.52	142.17	1.48	0.57	
	2.LSTM	16	50.07	380.85	169.37	88.24			
	3.GRU	16	69.62	454.27	201.92	96.26			
RobustScaler	1.RNN	16	27.4	202.85	77.84	55.64	8.7*	6.61 <sup>註2</sup>	2>3
	2.LSTM	16	27.31	315.86	119.13	92.90			
	3.GRU	16	16.79	93.88	36.14	28.05			
MinMaxScaler	1.RNN	16	30.88	778.67	290.57	283.99	31.42*	5.86 <sup>註2</sup>	1、2>3
	2.LSTM	16	190.64	387.41	280.88	58.91			
	3.GRU	16	41.98	262.31	107.21	55.92			

備註：

1.\*  $\alpha < 0.05$

2 組別不同質，改採 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05（顯著），進行事後較

3.因本研究使用 MSE 作為預測準確度判斷,MSE 越小代表越好

(3). 層數為三層

a：以遞迴神經網路觀察差異情形

由表 4-9 得知，在遞迴神經網路的「StandardScaler」構面上，均等平均數的 Robust 檢定 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05（顯著），進行事後比較，經由 Games-Howell 檢定得到遞迴神經網路「LSTM」顯著高於「RNN」。

在遞迴神經網路的「RobustScaler」構面上，均等平均數的 Robust 檢定 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05（顯著），進行事後比較，經由 Games-Howell 檢定得到遞迴神經網路「LSTM」顯著高於「GRU」與「RNN」。

在遞迴神經網路的「MinMaxScaler」構面上，在均等平均數的 Robust 檢定 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05（顯著），進行事後比較，經由 Games-Howell 檢定得到遞迴神經網路「RNN」顯著高於「LSTM」與「GRU」。

表 4-9 不同遞迴神經網路在特徵縮放方法預測準確度之差異分析表 (三層)

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F	事後 檢定
StandardScaler	1.RNN	64	61.01	1183.72	378.46	245.82	9.97*	6.96 <sup>註2</sup>	1>2
	2.LSTM	64	31.58	426.31	221.51	102.36			
	3.GRU	64	27.55	1549.91	308.51	315.94			
RobustScaler	1.RNN	64	36.07	448.15	130.83	94.87	5.44*	9.51 <sup>註2</sup>	2>3、1
	2.LSTM	64	32.01	609.81	228.35	133.03			
	3.GRU	64	19.39	869.91	142.43	174.92			
MinMaxScaler	1.RNN	64	70.44	5082.78	947.90	1012.02	40.31*	17.25 <sup>註2</sup>	1>2、3
	2.LSTM	64	73.88	1317.94	511.37	194.76			
	3.GRU	64	47.44	4096.26	272.01	495.46			

備註：

1. \*  $\alpha < 0.05$

2. 組別不同質，改採 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05 (顯著)，進行事後較

3. 因本研究使用 MSE 作為預測準確度判斷, MSE 越小代表越好



b. 以不同特徵縮放方法觀察差異情形：

由表 4-10 得知，在特徵縮放的「RNN」構面上，均等平均數的 Robust 檢定 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05（顯著），進行事後比較，經由 Games-Howell 檢定得到特徵縮放「MinMaxScaler」顯著高於「RobustScaler」與「StandardScaler」。

在特徵縮放的「LSTM」構面上，均等平均數的 Robust 檢定 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05（顯著），進行事後比較，經由 Games-Howell 檢定得到特徵縮放「MinMaxScaler」顯著高於「RobustScaler」與「StandardScaler」。

在特徵縮放的「GRU」構面上，因組別具有同值，變異數分析（ $F=3.9$ ， $p=0.02<0.05$ ）達到顯著，經 Scheffé 法事後比較，顯示特徵縮放「StandardScaler」顯著高於「RobustScaler」。

表 4-10 不同特徵縮放在遞迴神經網路預測準確度之差異分析表 (三層)

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F	事後 檢定
RNN	1.StandardScaler	64	61.01	1183.72	378.46	245.82	65.57*	30.82 <sup>註2</sup>	3>1、2
	2.RobustScaler	64	36.07	448.15	130.83	94.87			
	3.MinMaxScaler	64	70.44	5082.78	947.9	1012.02			
LSTM	1.StandardScaler	64	31.58	426.31	221.51	102.36	6.91*	79.47 <sup>註2</sup>	3>1、2
	2.RobustScaler	64	32.01	609.81	228.35	133.03			
	3.MinMaxScaler	64	73.88	1317.94	511.37	194.76			
GRU	1.StandardScaler	64	27.55	1549.91	308.51	315.94	1.21	3.9 <sup>註3</sup>	1>2
	2.RobustScaler	64	19.39	869.91	142.43	174.92			
	3.MinMaxScaler	64	47.44	4096.26	272.01	495.46			

備註：

1.\*  $\alpha < 0.05$

2.組別不同質，改採 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05 (顯著)，進行事後較

3.事後檢定使用 Scheffé 方法

4.因本研究使用 MSE 作為預測準確度判斷,MSE 越小代表越好

藉由下表 4-11 單一指標敘述統計，可以觀察到在單一指標在模型 RNN，MSE 最小值在 RobustScaler 第二層為 27.4，標準差為 55.64；模型 LSTM，MSE 最小值在 RobustScaler 第二層為 27.31，標準差為 92.9；模型 GRU，MSE 最小值在 RobustScaler 第二層為 16.79，標準差為 28.05。綜合上述分析，可以發現 RobustScaler 第二層較為穩定且標準差波動範圍較小，因此本研究在單一指標較推薦 RobustScaler 第二層為最佳狀態。另外由表 4-11 單一指標敘述統計表與表 4-12 多指標描述統計表互相比較，結果顯示加入多指標沒有提高模型預測準確度，因此本研究就不在進行多指標介紹及分析（多指標相關分析結果請參閱附錄 C）。



表 4-11 不同模型與特徵方法之深度學習預測結果的描述統計（單一指標全部）

模型	特徵方法	層數	最小值	最大值	平均數	中位數	標準差	變異數
RNN	StandardScaler	一層	<b>36.89</b>	274.96	155.96	155.99	116.17	13496.50
		二層	55.58	547.38	162.52	98.44	142.17	20212.39
		三層	61.01	1183.72	378.46	348.77	245.82	60429.71
		特徵縮放方法比較	36.89	1183.72	326.73	262.03	242.23	58676.04
	RobustScaler	一層	44.12	230.70	103.30	69.20	87.93	7731.53
		二層	<b>27.40</b>	202.85	77.84	59.36	55.64	3096.10
		三層	36.07	448.15	130.83	102.99	94.87	8999.88
		特徵縮放方法比較	27.40	448.15	119.43	91.03	90.09	8116.49
	MinMaxScaler	一層	34.02	163.78	94.14	89.39	69.61	4845.43
		二層	<b>30.88</b>	778.67	290.57	172.58	283.99	80649.56
		三層	70.44	5082.78	947.90	558.42	1012.02	1024182.68
		特徵縮放方法比較	30.88	5082.78	782.04	370.10	939.53	882722.38
LSTM	StandardScaler	一層	44.72	402.96	145.44	67.03	172.11	29620.82
		二層	50.07	380.85	169.37	163.79	88.24	7785.55
		三層	<b>31.58</b>	426.31	221.51	211.44	102.36	10477.18
		特徵縮放方法比較	31.58	426.31	207.96	199.46	105.11	11047.25
	RobustScaler	一層	27.53	120.89	58.76	43.31	43.27	1872.14

		二層	<b>27.31</b>	315.86	119.13	78.39	92.90	8629.62
		三層	32.01	609.81	228.36	183.98	133.03	17697.71
		特徵縮放方法比較	27.31	609.81	199.48	165.56	133.80	17902.52
	MinMaxScaler	一層	91.51	246.94	155.48	141.73	68.61	4706.82
		二層	190.64	387.41	280.88	287.57	58.91	3470.52
		三層	<b>73.88</b>	1317.94	511.37	443.78	194.76	37932.23
		特徵縮放方法比較	73.88	1317.94	450.52	421.94	205.40	42187.42
	StandardScaler	一層	54.66	143.50	77.94	56.80	43.72	1911.37
		二層	69.62	454.27	201.92	190.50	96.26	9266.22
		三層	<b>27.55</b>	1549.91	308.51	195.08	315.94	99817.43
		特徵縮放方法比較	27.55	1549.91	277.23	191.04	285.08	81270.49
GRU	RobustScaler	一層	20.05	54.19	38.12	39.12	15.35	235.57
		二層	<b>16.79*</b>	93.88	36.14	23.38	28.05	786.66
		三層	19.39	869.91	142.43	70.92	174.92	30596.02
		特徵縮放方法比較	16.79	869.91	117.21	48.27	159.48	25432.84
	MinMaxScaler	一層	<b>28.01</b>	62.29	43.30	41.46	15.32	234.63
		二層	41.98	262.31	107.21	90.91	55.92	3127.37
		三層	47.44	4096.26	272.01	220.05	495.46	245477.39
		特徵縮放方法比較	28.01	4096.26	229.73	162.38	439.14	192847.05

\*代表最小值

資料來源：本研究整理

表 4-12 不同模型與特徵方法之深度學習預測結果的描述統計（多指標全部）

模型	特徵方法	層數	最小值	最大值	平均數	中位數	標準差	變異數
RNN	StandardScaler	一層	397.95	577.84	497.08	506.26	92.09	8480.15
		二層	157.29	496.52	296.92	266.93	146.15	21360.46
		三層	<b>119.22</b>	196.86	152.87	147.70	38.73	1500.38
		特徵縮放 方法比較	119.22	577.84	315.62	266.93	174.01	30279.67
	RobustScaler	一層	343.73	1778.34	716.53	583.92	413.31	170829.13
		二層	175.34	1414.47	607.08	419.42	352.81	124471.60
		三層	<b>108.91</b>	547.55	267.08	185.11	159.19	25342.57
		特徵縮放 方法比較	108.91	1778.34	530.23	432.07	373.81	139733.38
	MinMaxScaler	一層	379.21	2797.21	1045.00	896.05	547.62	299889.49
		二層	221.15	2990.04	976.37	831.69	616.14	379634.11
		三層	<b>85.18</b>	2060.24	422.49	211.64	472.59	223342.23
		特徵縮放 方法比較	85.18	2990.04	814.62	695.50	613.09	375879.39
LSTM	StandardScaler	一層	203.18	669.32	382.84	329.42	208.53	43484.24
		二層	<b>56.25</b>	422.06	203.13	167.10	155.41	24151.39

	三層	183.26	286.04	227.27	219.89	48.41	2343.29
	特徵縮放 方法比較	56.25	669.32	271.08	225.37	161.26	26003.72
RobustScaler	一層	<b>98.09</b>	1717.9	1013.88	1130.38	515.12	265344.77
	二層	190.31	845.41	626.09	668.59	189.66	35971.52
	三層	171.45	610.86	369.02	327.44	129.86	16864.41
	特徵縮放 方法比較	98.09	1717.9	669.66	603.29	416.29	173299.07
MinMaxScaler	一層	103.55	2060.31	864.19	820.88	501.65	251648.67
	二層	<b>97.87</b>	2511.08	1001.49	1060.39	547.96	300260.49
	三層	396.88	1278.84	669.09	648.16	199.92	39969.91
	特徵縮放 方法比較	97.87	2511.08	844.92	801.12	462.52	213925.09
GRU	一層	235.72	395.08	293.24	271.09	73.88	5458.56
	二層	<b>115.74</b>	264.91	181.40	172.47	62.19	3867.45
	三層	225.14	341.21	261.53	239.89	54.03	2919.10
	特徵縮放 方法比較	115.74	395.08	245.39	238.77	75.87	5756.11
RobustScaler	一層	<b>75.59</b>	1167	656.45	734.47	271.46	73688.71
	二層	223.84	990.11	423.66	400.40	175.22	30703.68

MinMaxScaler	三層	279.28	1478.73	677.94	613.83	342.60	117373.81
	特徵縮放 方法比較	75.59	1478.73	586.02	516.97	290.37	84315.78
	一層	114.15	1640.54	836.90	831.21	397.56	158056.61
	二層	<b>47.41*</b>	1335.66	665.90	588.31	317.20	100615.36
	三層	118.73	2562.66	469.12	339.26	419.10	175641.46
	特徵縮放 方法比較	47.41	2562.66	657.31	550.06	407.37	165954.06

\*代表最小值

資料來源：本研究整理



## 第二節 研究發現與討論

### (一)、 特徵縮放對於深度學習準確度影響

本研究使用了三種不同特徵縮放方法進行預測分析之比較，經由表 4-11，可以發現在相同數據集上使用不同特徵縮放會影響模型之準確性。然而在過去特徵縮放主要著重在多指標上，在本研究實驗分析可以發現在單一指標使用不同特徵縮放也具有影響性。本研究三種特徵縮放方法中 RobustScaler 方法預測準確性表較優異，因此可以得出結論，與 MinMaxScaler 和 StandardScaler 相比，RobustScaler 方法提供了更好的精準度。因此，本研究試圖進一步去了解 RobustScaler 特徵縮放方法表現優異的原因及分析特徵縮放方法的優缺點。

- (1). 標準分數 (StandardScaler)：經由公式 (35) 轉換，數據集符合標準正態分佈，即均值为 0，標準差為 1，如果數據集上有極端值計算，平均值和標準差會受到影響。
- (2). 極大極小標準化 (MinMaxScaler)：將特徵縮放到特定的最大值和最小值之間，換句話說，也就是對數據集進行線性轉換，讓所有特徵都剛好在 0 到 1 之間，適用於分布範圍較穩定的數據集，當數據加入導致最大值/最小值變化，需要重新定義，加上極端值會影響最大值或最小值，因此這個特徵方法對於極端值非常敏感。
- (3). 四分位距標準化 (RobustScaler)：RobustScaler 使用的是中位數和四分位距，而不是平均值和標準差。這樣 RobustScaler 會忽略極端值，減少極端值造成的影響，在這種情況下，中位數和四分位距通常會給出更好的結果。

### (二)、 加入常見技術指標並無提高模型準確度

由表 4-11 與表 4-12 進行探討，發現加入常見技術指標進行預測分析預測準確度皆大於單一指標預測準確度，由此結果發現加入常見技術指標未必會增加模

型準確性，而且台灣的股票市場屬於消息面，會隨著環境及國際事件等等因素導致去影響投資者心情判斷間接導致股市價格波動。

### (三)、 在此次數據中，ARIMA 預測表現較佳

經由實驗分析，表 4-2 本研究遞迴神經網路與表 4-1 ARIMA 中使用 StandardScaler 特徵縮放方法測驗集 MSE 相比，結果顯示 ARIMA 測驗集 MSE 小於本研究遞迴神經網路。

### (四)、 其他發現與討論

在過去文獻中 (Bengio & LeCun, 2007)，參數一樣的情況下，模型層數多比起層數少的效果更好，因神經網路中的層越多，代表對輸入提取特徵層次越高。在神經網路中，後一層神經元數的輸入是前一層輸出的加權後的值，前一層的特徵在後一層就被抽取出來了，模型學習的過程就是調節和優化各連接權重和閾值的過程。層數較少表示的提取特徵層次不高，而層數越多，提取特徵層次越高。本研究經由上述實驗分析結果，可以發現層數增加不一定能提高模型準確性（請參閱表 4-11），因此遞迴式神經網路（RNN、LSTM、GRU）中，層數和神經元數並不是完全對立的關係，增加層數和神經元數都是在增加可學習參數的個數，研究者在實驗中過程中必須考量層數與神經元數的平衡。本研究認為為層數功能是提取特徵，當層數少的時候預測效果不佳，可以增加層數提高預測準確度，但如果盲目的增加層數，很容易造成過度凝合，所以不是增加層數，預測準確就一定

會越好。

## 第五章 結論與建議

### 第一節 結論

深度學習是近年來熱門的趨勢,有許多學者應用在各領域中都有良好的表現,在深度學習文獻中,預測股市價格趨勢最為熱門,股市價格具有時間序列分析特性,然而在過去股市相關研究中,大多數學者都在探討模型之間的預測精準度,較少探討特徵縮放的影响性。因此本研究利用常見的技術指標,並結合不同特徵縮放及深度學習演算法進行股市價格預測分析。

本研究收集 A 公司股票數據 (2015/01/05 至 2019/12/31) 進行實驗分析,下一期股價作為預測變數,收盤價為本研究特徵變數,本研究為了 (1) 探討不同特徵縮放是否會影響深度學習模型準確度,因此本研究提出三種特徵縮放方法進行驗證分析;(2) 探討加入技術指標是否會提高模型預測準確度,因此本研究設計兩種模型分別為單一指標及多指標進行驗證分析;(3) 驗證傳統 ARIMA 模型與遞迴神經網路預測準確度之比較,(4) 探討不同神經元數及層數對於預測準確度之影響,最後利用均方誤差 (Mean-Square Error, MSE)、均方根誤差 (Root-Mean-Square Error, RMSE)、平均絕對百分比誤差 (Mean Absolute Percentage Error, MAPE) 來進行模型預測結果評估。經由本實驗驗證分析得知,不同特徵縮放方法與神經元數皆會影響遞迴神經網路預測準確度。

綜合上述,本研究貢獻如下:

- (1) 使用不同特徵縮放對於遞迴神經網路準確度影響
- (2) 探討加入技術指標是否可提高遞迴神經網路準確度
- (3) 驗證傳統 ARIMA 模型與遞迴神經網路預測準確度之比較
- (4) 探討不同神經元數及層數對於預測準確度之影響
- (5) 實際採用 2015-2019 年 A 公司實際股票資料來進行實例驗證

## 第二節 未來展望

未來改進的地方，本研究在選擇技術指標是依據文獻探討的方式去挑選，沒有去驗證技術指標彼此之間及收盤價相關性，可能這也是導致本研究進行多指標無法提高遞迴神經網路預測準確度原因，因此建議未來研究者在研究中可以事先進行驗證，在進行多指標預測分析也許預測結果會更佳準確。此外,本研究主要以 A 公司的歷史股票數據及常見技術指標進行驗證分析,建議未來學者可以同時增加不同股票或不同性質的數據及增加其他常見指標進行驗證分析。



# 參考資料

## 一、中文文獻

李培煜 (2021)，時間序列 ARIMA 與深度學習 LSTM 預測模型之比較：以台灣股票市場為例，東吳大學數學系碩士所碩士論文

谷岡広樹, 康鑫(2019)，深度學習入門教室：6 堂基礎課程 + Python 實作練習，Deep Learning、人工智慧、機器學習的理論和應用全圖解, 臉譜, 204-239

林逸青, 謝孟芬, & 徐旺興. (2019). 以深度學習建構股價預測模型：以台灣股票市場為例. 當代商管論叢, 4(1), 35-59.

陳紀安 (2011)，技術分析於台灣五十指數成分股之績效實證，國立中山大學財務管理學系研究所碩士論文

陳振東,&謝政翰 (2019) 應用機器學習與模糊推論於股價漲跌預測之研究. 資訊管理學報, 26 (2), 153-177.

黃星瑋 (2018)，正規化與變數篩選在破產領域的適用性研究，國立中央大學資訊管理學系研究所碩士論文

楊旻叡 (2021)，結合改良 a-Sutte 指標與 ARIMA 之集成模型在美國 COVID-19 確診人數之預測，國立雲林科技大學資訊管理系研究所碩士論文

廖凡宇 (2009)，以類神經網路在股價預測之研究，國立虎尾科技大學資訊資訊管理研究所碩士論文

鄭允中 (2017)，基於長短期記憶遞迴類神經網路之新台幣兌美元匯率預測模型，國立台灣大學資訊工程研究所碩士論文

鄭健毅 (2010)，應用 SVR 支援向量迴歸模式來進行電子產業股價預測，明新學校財團法人明新科技大學工業工程與管理研究所碩士論文

盧廷宇 (2012) , 利用倒傳遞類神經網路結合保力加通道支援外匯交易決策, 大同大學資訊經營管理學系研究所碩士論文

簡禎富, 許嘉裕 (2014) . 資料挖礦與大數據分析. Qian cheng wen hua shi ye you xian gong si.

鐘毅 (2020) , 以深度學習 LSTM 方法進行台灣加權股價指數預測, 國立交通大學科技管理研究所碩士論文

## 二、英文文獻

Adebiyi, A. A., Adewumi, A. O., & Ayo, C. K. (2014) . Comparison of ARIMA and artificial neural networks models for stock price prediction. *Journal of Applied Mathematics*, 2014.

Agarwalla, S., & Sarma, K. K. (2016) . Machine learning based sample extraction for automatic speech recognition using dialectal Assamese speech. *Neural Networks*, 78, 97-111.

Alhashel, B. S., Almudhaf, F. W., & Hansz, J. A. (2018) . Can technical analysis generate superior returns in securitized property markets? Evidence from East Asia markets. *Pacific-Basin Finance Journal*, 47, 92-108.

Ayala, J., García-Torres, M., Noguera, J. L. V., Gómez-Vela, F., & Divina, F. (2021) . Technical analysis strategy optimization using a machine learning approach in stock market indices. *Knowledge-Based Systems*, 225, 107119.

Bengio, Y., & LeCun, Y. (2007) . Scaling learning algorithms towards AI. *Large-scale kernel machines*, 34 (5) , 1-41.

Bengio, Y., Courville, A., & Vincent, P. (2013) . Representation learning : A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35 (8) , 1798-1828.

- Busari, G. A., & Lim, D. H. (2021). Crude oil price prediction : A comparison between AdaBoost-LSTM and AdaBoost-GRU for improving forecasting performance. *Computers & Chemical Engineering*, 155, 107513.
- Chang, P. C. (2012). A novel model by evolving partially connected neural network for stock price trend forecasting. *Expert Systems with Applications*, 39 (1), 611-620.
- Chang, P. C., & Fan, C. Y. (2008). A hybrid system integrating a wavelet and TSK fuzzy rules for stock price forecasting. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 38 (6), 802-815.
- Chang, P. C., Liu, C. H., Lin, J. L., Fan, C. Y., & Ng, C. S. (2009). A neural network with a case based dynamic window for stock trading prediction. *Expert Systems with Applications*, 36 (3), 6889-6898.
- Chen, C. C., Kuo, Y. C., Huang, C. H., & Chen, A. P. (2014). Applying market profile theory to forecast Taiwan Index Futures market. *Expert Systems with Applications*, 41 (10), 4617-4624.
- Chen, Y. S., Cheng, C. H., & Tsai, W. L. (2014). Modeling fitting-function-based fuzzy time series patterns for evolving stock index forecasting. *Applied intelligence*, 41 (2), 327-347.
- Chen, Y., & Hao, Y. (2017). A feature weighted support vector machine and K-nearest neighbor algorithm for stock market indices prediction. *Expert Systems with Applications*, 80, 340-355.
- Chen, Y., Lin, W., & Wang, J. Z. (2019). A dual-attention-based stock price trend prediction model with dual features. *IEEE Access*, 7, 148047-148058.
- Cheng, J. C., & Ma, L. J. (2015). A data-driven study of important climate factors on the achievement of LEED-EB credits. *Building and environment*, 90, 232-244.

- Chiang, W. C., Enke, D., Wu, T., & Wang, R. (2016). An adaptive stock index trading decision support system. *Expert Systems with Applications*, 59, 195-207.
- Chollet, F., & Allaire, J. J. (2018) . *Deep Learning mit R und Keras : Das Praxis-Handbuch von den Entwicklern von Keras und RStudio*. MITP-Verlags GmbH & Co. KG.
- Chong, E., Han, C., & Park, F. C. (2017) . Deep learning networks for stock market analysis and prediction : Methodology, data representations, and case studies. *Expert Systems with Applications*, 83, 187-205.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2015, June) . Gated feedback recurrent neural networks. *In International conference on machine learning* (pp. 2067-2075) . PMLR.
- Creamer, G. (2012) . Model calibration and automated trading agent for euro futures. *Quantitative Finance*, 12 (4) , 531-545.
- Davies, P. C. (1994). Design issues in neural network development. *Neurovest Journal*, 5, 21-25.
- De Oliveira, F. A., Nobre, C. N., & Zárate, L. E. (2013) . Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index–Case study of PETR4, Petrobras, Brazil. *Expert systems with applications*, 40 (18) , 7596-7606.
- Ding, G., & Qin, L. (2020) . Study on the prediction of stock price based on the associated network model of LSTM. *International Journal of Machine Learning and Cybernetics*, 11 (6) , 1307-1317.
- Fischer, T., & Krauss, C. (2018) . Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270 (2) , 654-669.



- Gencay, R. (1996). Non-linear prediction of security returns with moving average rules. *Journal of Forecasting*, 15 (3), 165-174.
- Gorenc Novak, M., & Velušček, D. (2016). Prediction of stock price movement based on daily high prices. *Quantitative Finance*, 16 (5), 793-826.
- Clive William John Granger, Oskar Morgenstern. (1970). *Predictability of stock market prices* (p. 34). Lexington, MA: Heath Lexington Books.
- Henrique, B. M., Sobreiro, V. A., & Kimura, H. (2018). Stock price prediction using support vector regression on daily and up to the minute prices. *The Journal of finance and data science*, 4 (3), 183-201.
- Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *science*, 313(5786), 504-507.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9 (8), 1735-1780.
- Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of sciences*, 79 (8), 2554-2558.
- Huang, C. L., & Tsai, C. Y. (2009). A hybrid SOFM-SVR with a filter-based feature selection for stock market forecasting. *Expert Systems with applications*, 36 (2), 1529-1539.
- Jun, M. A., & Cheng, J. C. (2017). Selection of target LEED credits based on project information and climatic factors using data mining techniques. *Advanced Engineering Informatics*, 32, 224-236.
- Kara, Y., Boyacioglu, M. A., & Baykan, Ö. K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert systems with*

*Applications*, 38 ( 5 ) , 5311-5319.

Kim, K. J., & Han, I. ( 2000 ) . Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index. *Expert systems with Applications*, 19 ( 2 ) , 125-132.

Kimoto, T., Asakawa, K., Yoda, M., & Takeoka, M. ( 1990, June ) . Stock market prediction system with modular neural networks. In *1990 IJCNN international joint conference on neural networks*( ( pp.1-6 ) ) . IEEE.

Laboissiere, L. A., Fernandes, R. A., & Lage, G. G. ( 2015 ) . Maximum and minimum stock price forecasting of Brazilian power distribution companies based on artificial neural networks. *Applied Soft Computing*, 35, 66-74.

Lahmiri, S. ( 2014 ) . Entropy-based technical analysis indicators selection for international stock markets fluctuations prediction using support vector machines. *Fluctuation and Noise Letters*, 13 ( 02 ) , 1450013.

Li, C., Song, D., & Tao, D. ( 2019, July ) . Multi-task recurrent neural networks and higher-order Markov random fields for stock price movement prediction : Multi-task RNN and higer-order MRFs for stock price classification. In *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining* ( 1141-1151 ) .

Li, X., Li, Y., Yang, H., Yang, L., & Liu, X. Y. ( 2019 ) . DP-LSTM : Differential privacy-inspired LSTM for stock prediction using financial news. *arXiv preprint arXiv* : 1912.10806.

Luu, T. N., Phan, Q. H., & Le, T. H. ( 2022 ). Classification of human skin cancer using Stokes-Mueller decomposition method and artificial intelligence models. *Optik*, 249, 168239.

Ma, J., & Cheng, J. C. ( 2016 ) . Identifying the influential features on the regional

- energy use intensity of residential buildings based on Random Forests. *Applied energy*, 183, 193-201.
- Marszałek, A., & Burczyński, T. (2014) . Modeling and forecasting financial time series with ordered fuzzy candlesticks. *Information sciences*, 273, 144-155.
- Mills, T. C., & Markellos, R. N. (2008) . *The econometric modelling of financial time series*. Cambridge university press.
- Morgenstern, O. (1970) . *Predictability of stock market prices*. Heath Lexington Books.
- Murphy, J. J. (1999) . *Technical analysis of the financial markets : A comprehensive guide to trading methods and applications*. Penguin.
- Nakano, M., Takahashi, A., & Takahashi, S. (2018) . Bitcoin technical trading with artificial neural network. *Physica A : Statistical Mechanics and its Applications*, 510, 587-609.
- Patel, J., Shah, S., Thakkar, P., & Kotecha, K. (2015). Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. *Expert systems with applications*, 42 ( 1 ) , 259-268.
- Prasetijo, A. B., Saputro, T. A., Windasari, I. P., & Windarto, Y. E. (2017, October) . Buy/sell signal detection in stock trading with bollinger bands and parabolic SAR : With web application for proofing trading strategy. In *2017 4th International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE)* (pp. 41-44) . IEEE.
- Saravanan, D., & Kumar, K. S. (2021) . Improving air pollution detection accuracy and quality monitoring based on bidirectional RNN and the Internet of Things. *Materials Today : Proceedings*.
- Selvin, S., Vinayakumar, R., Gopalakrishnan, E. A., Menon, V. K., & Soman, K. P.

- (2017, September) . Stock price prediction using LSTM, RNN and CNN-sliding window model. In *2017 international conference on advances in computing, communications and informatics (icacci)* (pp. 1643-1647) . IEEE.
- Sethia, A., & Raut, P. (2019) . Application of LSTM, GRU and ICA for stock price prediction. In *Information and communication technology for intelligent systems* (pp. 479-487) . Springer, Singapore.
- Siarni-Namini, S., Tavakoli, N., & Namin, A. S. (2018, December) . A comparison of ARIMA and LSTM in forecasting time series. In *2018 17th IEEE international conference on machine learning and applications (ICMLA)* (pp. 1394-1401) . IEEE.
- Singh, R., & Srivastava, S. (2017) . Stock prediction using deep learning. *Multimedia Tools and Applications*, 76 (18) , 18569-18584.
- Song, H. A., & Lee, S. Y. (2013) . Hierarchical Representation Using NMF, Neural Information Processing, Vol. 8226 of the series Lectures Notes in Computer Science.
- Thara, D. K., PremaSudha, B. G., & Xiong, F. (2019) . Auto-detection of epileptic seizure events using deep neural network with different feature scaling techniques. *Pattern Recognition Letters*, 128, 544-550.
- Tsantekidis, A., Passalis, N., Tefas, A., Kannianen, J., Gabbouj, M., & Iosifidis, A. (2017, July) . Forecasting stock prices from the limit order book using convolutional neural networks. In *2017 IEEE 19th conference on business informatics (CBI)* (Vol. 1, pp. 7-12) . IEEE.
- Vanstone, B., & Finnie, G. (2010) . Enhancing stockmarket trading performance with ANNs. *Expert Systems with Applications*, 37 (9) , 6602-6610.
- Vathsala, M. K., & Holi, G. (2020) . RNN based machine translation and transliteration

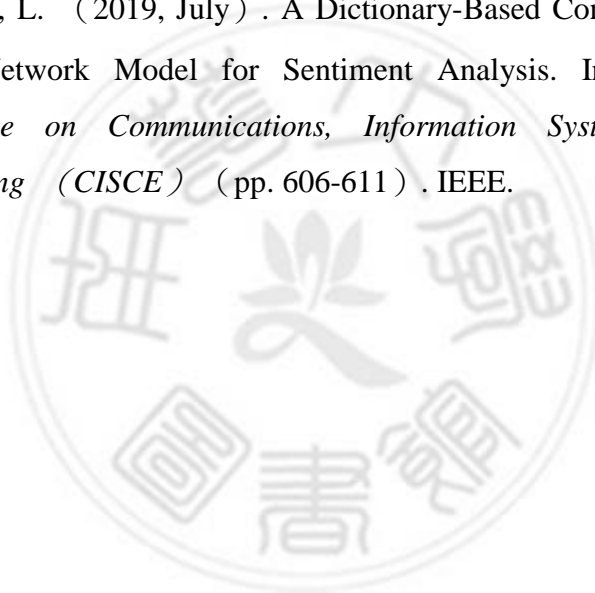
- for Twitter data. *International Journal of Speech Technology*, 23 ( 3 ) , 499-504.
- Wei, X., Zhang, L., Yang, H. Q., Zhang, L., & Yao, Y. P. ( 2021 ) . Machine learning for pore-water pressure time-series prediction : Application of recurrent neural networks. *Geoscience Frontiers*, 12 ( 1 ) , 453-467.
- Weng, B., Ahmed, M. A., & Megahed, F. M. ( 2017 ) . Stock market one-day ahead movement prediction using disparate data sources. *Expert Systems with Applications*, 79, 153-163.
- Y.C. Zheng, Y.H. Zhu, M.Q. Ji, R.P. Wang, X.F. Liu, M.D. Zhang, J. Liu, X.C. Zhang, C.H. Qin, L. Fang, S.H. Ma. ( 2020 ) . A learning-based model to evaluate hospitalization priority in COVID-19 pandemics. *patterns*, 1 ( 6 ) , 100092.
- Yamak, P. T., Yujian, L., & Gadosey, P. K. ( 2019, December ). A comparison between arima, lstm, and gru for time series forecasting. In *Proceedings of the 2019 2nd International Conference on Algorithms, Computing and Artificial Intelligence* ( pp. 49-55 ) .
- Yang, Y., Hu, X., & Jiang, H. ( 2022 ) . Group penalized logistic regressions predict up and down trends for stock prices. *The North American Journal of Economics and Finance*, 59, 101564.
- Yim, J. ( 2002, June ) . A comparison of neural networks with time series models for forecasting returns on a stock market index. In *International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems* ( pp. 25-35 ) . Springer, Berlin, Heidelberg.
- Yin, Q., Zhang, R., & Shao, X. ( 2019 ) . CNN and RNN mixed model for image classification. In *MATEC web of conferences* ( Vol. 277, p. 02001 ) . EDP Sciences.
- Yu, L., Chen, H., Wang, S., & Lai, K. K. ( 2008 ). Evolving least squares support vector

machines for stock market trend mining. *IEEE Transactions on evolutionary computation*, 13 ( 1 ) , 87-102.

Zhang, Y., Yu, D., & Chen, G. ( 2017 ) . Advanced Recurrent Neural Networks for Automatic Speech Recognition. In *New Era for Robust Speech Recognition* ( pp. 261-279 ) . Springer, Cham.

Zhang, Z., Zohren, S., & Roberts, S. ( 2019 ) . Deeplob : Deep convolutional neural networks for limit order books. *IEEE Transactions on Signal Processing*, 67 ( 11 ) , 3001-3012.

Zheng, J., & Zheng, L. ( 2019, July ) . A Dictionary-Based Convolutional Recurrent Neural Network Model for Sentiment Analysis. In *2019 International Conference on Communications, Information System and Computer Engineering (CISCE)* ( pp. 606-611 ) . IEEE.



## 附錄

### 附錄 A：單一指標分析結果

表 7-1 單一指標分析-一層

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
32	StandardScaler	233.93	15.29	3.80	402.96	20.07	4.94	143.50	11.98	3.02
	RobustScaler	230.70	15.19	3.92	120.89	10.99	2.94	<b>46.86</b>	6.85	2.01
	MinMaxScaler	163.78	12.80	4.20	91.51	9.57	2.67	48.62	6.97	2.09
64	StandardScaler	274.96	16.58	4.14	74.28	8.62	2.44	57.14	7.56	2.20
	RobustScaler	45.37	6.74	2.04	<b>27.53</b>	5.25	1.72	54.19	7.36	2.20
	MinMaxScaler	34.02	5.83	1.83	167.08	12.93	3.46	62.29	7.89	2.42
128	StandardScaler	78.04	8.83	2.47	44.72	6.69	2.26	56.46	7.51	2.28
	RobustScaler	44.12	6.64	2.07	55.63	7.46	2.33	<b>31.37</b>	5.60	1.78
	MinMaxScaler	144.28	12.01	3.74	246.94	15.71	4.25	28.01	5.29	1.67
256	StandardScaler	36.89	6.07	1.86	59.78	7.73	2.75	54.66	7.39	2.65
	RobustScaler	93.02	9.64	3.31	30.99	5.57	1.81	<u>20.05</u>	4.48	1.52
	MinMaxScaler	34.49	5.87	1.91	116.38	10.79	2.85	34.29	5.86	1.82

資料來源：本研究整理

表 7-2 單一指標分析-二層

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
32,32	StandardScaler	381.57	19.53	4.67	258.94	16.09	4.11	74.51	8.63	2.59
	RobustScaler	198.99	14.11	3.62	39.74	6.30	2.01	<b>20.09</b>	4.48	1.52
	MinMaxScaler	73.03	8.55	2.56	211.00	14.53	3.73	157.77	12.56	3.37
32,64	StandardScaler	340.77	18.46	4.45	203.52	14.27	3.64	220.77	14.86	4.61
	RobustScaler	202.85	14.24	3.67	45.89	6.77	2.16	<b>20.43</b>	4.52	1.53
	MinMaxScaler	170.94	13.07	4.23	241.29	15.53	4.04	162.16	12.73	3.47
32,128	StandardScaler	70.26	8.38	2.19	241.81	15.55	3.98	454.27	21.31	6.79
	RobustScaler	62.96	7.93	2.37	35.48	5.96	2.03	<b>22.99</b>	4.79	1.62
	MinMaxScaler	174.21	13.20	4.10	297.90	17.26	4.51	135.27	11.63	3.11
32,256	StandardScaler	112.99	10.63	2.62	108.95	10.44	2.82	190.02	13.78	4.20
	RobustScaler	82.97	9.11	2.66	62.74	7.92	2.36	<b>23.01</b>	4.80	1.66
	MinMaxScaler	49.04	7.00	2.35	207.59	14.41	3.66	97.61	9.88	2.73
64,32	StandardScaler	547.38	23.40	5.69	164.58	12.83	3.37	190.98	13.82	4.72
	RobustScaler	138.44	11.77	3.17	27.31	5.23	1.76	<b>24.14</b>	4.91	1.62
	MinMaxScaler	36.91	6.08	1.91	220.33	14.84	3.86	262.31	16.20	4.27
64,64	StandardScaler	137.89	11.74	2.83	198.92	14.10	3.70	188.18	13.72	4.44
	RobustScaler	42.78	6.54	2.10	92.10	9.60	3.08	<b>23.75</b>	4.87	1.59
	MinMaxScaler	63.49	7.97	2.49	343.64	18.54	4.75	157.42	12.55	3.35
64,128	StandardScaler	69.87	8.36	2.14	380.85	19.52	6.09	268.63	16.39	5.09
	RobustScaler	92.83	9.63	3.04	315.86	17.77	4.00	<b>18.45</b>	4.30	1.43
	MinMaxScaler	439.78	20.97	7.71	252.72	15.90	4.03	72.71	8.53	2.34
64,256	StandardScaler	55.58	7.46	2.09	81.51	9.03	2.59	258.73	16.09	3.71
	RobustScaler	36.40	6.03	2.03	144.45	12.02	3.80	<b>22.03</b>	4.69	1.56
	MinMaxScaler	721.32	26.86	9.52	190.64	13.81	3.49	97.06	9.85	2.64
128,32	StandardScaler	234.12	15.30	3.60	191.71	13.85	3.55	233.69	15.29	5.52
	RobustScaler	52.00	7.21	2.12	77.39	8.80	2.93	<b>18.88</b>	4.35	1.47
	MinMaxScaler	189.69	13.77	4.80	320.92	17.91	4.58	72.15	8.49	2.33



表 7-3 單一指標分析-二層 (續)

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
128,64	StandardScaler	94.17	9.70	2.47	150.21	12.26	3.32	250.34	15.82	5.45
	RobustScaler	63.68	7.98	2.47	288.59	16.99	5.40	<b>16.79</b>	4.10	1.37
	MinMaxScaler	139.72	11.82	4.03	299.60	17.31	4.36	84.75	9.21	2.52
128,128	StandardScaler	89.36	9.45	2.69	75.30	8.68	2.49	293.54	17.13	5.05
	RobustScaler	77.26	8.79	2.92	59.93	7.74	2.36	<b>27.92</b>	5.28	1.63
	MinMaxScaler	735.91	27.13	8.50	339.31	18.42	4.61	56.25	7.50	2.12
128,256	StandardScaler	73.23	8.56	2.50	261.85	16.18	4.84	69.62	8.34	2.15
	RobustScaler	<b>43.66</b>	6.61	2.05	186.84	13.67	3.52	93.48	9.67	2.63
	MinMaxScaler	778.67	27.90	10.18	246.24	15.69	3.89	77.57	8.81	2.40
256,32	StandardScaler	147.48	12.14	2.87	86.44	9.30	2.66	119.98	10.95	3.00
	RobustScaler	55.76	7.47	2.28	79.38	8.91	2.60	<b>34.01</b>	5.83	2.05
	MinMaxScaler	675.27	25.99	8.20	277.23	16.65	4.21	104.05	10.20	2.74
256,64	StandardScaler	81.73	9.04	2.33	92.31	9.61	2.76	161.10	12.69	3.51
	RobustScaler	39.99	6.32	1.98	136.51	11.68	3.30	<b>29.97</b>	5.47	1.74
	MinMaxScaler	34.55	5.88	1.92	387.41	19.68	4.80	41.98	6.48	1.96
256,128	StandardScaler	102.70	10.13	2.92	50.07	7.08	2.08	160.47	12.67	3.47
	RobustScaler	<b>27.40</b>	5.23	1.79	68.00	8.25	2.34	88.45	9.40	2.45
	MinMaxScaler	335.66	18.32	6.49	308.81	17.57	4.32	73.64	8.58	2.33
256,256	StandardScaler	61.20	7.82	2.36	162.99	12.77	3.13	95.87	9.79	2.51
	RobustScaler	<b>27.40</b>	5.23	1.82	245.82	15.68	3.60	93.88	9.69	2.55
	MinMaxScaler	30.88	5.56	2.01	349.40	18.69	4.58	62.67	7.92	2.24

資料來源：本研究整理

表 7-4 單一指標分析-三層

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
32,32,32	StandardScaler	440.48	20.99	20.99	383.33	19.58	4.94	200.66	14.17	3.78
	RobustScaler	222.65	14.92	3.76	206.35	14.37	3.64	<b>29.09</b>	5.39	1.76
	MinMaxScaler	205.52	14.34	4.33	313.10	17.69	4.54	342.19	18.50	4.88
32,32,64	StandardScaler	865.36	29.42	7.20	244.03	15.62	4.01	245.96	15.68	3.99
	RobustScaler	161.51	12.71	3.19	180.11	13.42	3.52	<b>113.02</b>	10.63	3.37
	MinMaxScaler	156.82	12.52	3.78	320.87	17.91	4.60	258.77	16.09	4.11
32,32,128	StandardScaler	385.69	19.64	4.53	357.56	18.91	4.75	193.43	13.91	3.46
	RobustScaler	<b>87.16</b>	9.34	2.63	298.44	17.28	4.73	187.62	13.70	4.01
	MinMaxScaler	779.26	27.92	9.09	385.68	19.64	5.29	444.50	21.08	5.53
32,32,256	StandardScaler	228.21	15.11	3.96	365.25	19.11	4.73	125.38	11.20	3.11
	RobustScaler	<b>112.34</b>	10.60	2.90	482.60	21.97	5.92	227.27	15.08	4.84
	MinMaxScaler	140.83	11.87	3.86	429.59	20.73	5.38	229.81	15.16	4.00
32,64,32	StandardScaler	395.28	19.88	4.75	359.91	18.97	4.67	186.28	13.65	3.32
	RobustScaler	362.27	19.03	4.70	264.90	16.28	4.76	<b>26.27</b>	5.13	1.70
	MinMaxScaler	121.59	11.03	3.37	243.00	15.59	3.99	358.72	18.94	4.91
32,64,64	StandardScaler	880.56	29.67	7.06	342.42	18.50	4.61	182.45	13.51	3.41
	RobustScaler	114.43	10.70	2.92	220.48	14.85	3.84	<b>49.55</b>	7.04	2.22
	MinMaxScaler	105.34	10.26	3.23	326.70	18.07	4.74	413.63	20.34	5.69
32,64,128	StandardScaler	200.71	14.17	3.40	200.00	14.14	3.55	211.84	14.55	3.75
	RobustScaler	219.09	14.80	4.82	415.53	20.38	5.48	<b>135.71</b>	11.65	3.40
	MinMaxScaler	152.54	12.35	4.13	408.82	20.22	5.28	311.71	17.66	4.50
32,64,256	StandardScaler	495.72	22.26	5.47	426.31	20.65	5.66	215.74	14.69	3.77
	RobustScaler	322.05	17.95	4.56	293.92	17.14	4.69	<b>34.09</b>	5.84	2.02
	MinMaxScaler	174.12	13.20	4.32	347.88	18.65	4.74	377.00	19.42	5.04
32,128,32	StandardScaler	971.74	31.17	7.79	305.93	17.49	4.42	183.86	13.56	3.46
	RobustScaler	164.30	12.82	3.22	161.67	12.72	3.39	<b>115.71</b>	10.76	3.47
	MinMaxScaler	131.14	11.45	3.60	514.89	22.69	5.72	169.42	13.02	3.74

資料來源：本研究整理

表 7-5 單一指標分析-三層 (續)

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
32,128,64	StandardScaler	696.81	26.40	6.34	195.62	13.99	3.71	161.41	12.70	3.14
	RobustScaler	148.50	12.19	3.11	173.16	13.16	3.51	140.11	11.84	3.98
	MinMaxScaler	<b>92.97</b>	9.64	3.07	360.66	18.99	4.86	287.06	16.94	5.03
32,128,128	StandardScaler	141.80	11.91	3.06	276.81	16.64	4.16	205.51	14.34	3.82
	RobustScaler	291.74	17.08	5.40	342.78	18.51	5.00	<b>36.17</b>	6.01	1.92
	MinMaxScaler	220.54	14.85	5.12	438.54	20.94	5.44	87.82	9.37	2.61
32,128,256	StandardScaler	129.03	11.36	2.83	261.39	16.17	3.92	348.00	18.65	6.11
	RobustScaler	57.14	7.56	2.24	348.43	18.67	5.00	<b>32.98</b>	5.74	1.76
	MinMaxScaler	369.90	19.23	6.69	441.83	21.02	5.78	206.40	14.37	3.77
32,256,32	StandardScaler	456.33	21.36	4.90	320.91	17.91	4.48	123.80	11.13	2.85
	RobustScaler	392.13	19.80	4.74	126.08	11.23	3.00	146.58	12.11	3.06
	MinMaxScaler	498.41	22.33	7.37	412.23	20.30	5.10	114.21	10.69	2.94
32,256,64	StandardScaler	175.76	13.26	3.14	130.48	11.42	2.98	163.26	12.78	3.25
	RobustScaler	76.08	8.72	2.55	251.16	15.85	4.22	<b>36.63</b>	6.05	1.82
	MinMaxScaler	1309.29	36.18	12.51	471.71	21.72	5.41	141.75	11.91	3.35
32,256,128	StandardScaler	122.83	11.08	2.77	154.29	12.42	3.13	171.74	13.11	3.80
	RobustScaler	57.03	7.55	2.36	85.74	9.26	2.73	<u><b>19.39</b></u>	4.40	1.50
	MinMaxScaler	203.49	14.26	4.85	427.91	20.69	5.12	55.09	7.42	2.39
32,256,256	StandardScaler	144.83	12.03	3.08	195.01	13.96	3.64	207.10	14.39	3.44
	RobustScaler	127.82	11.31	3.49	246.91	15.71	4.02	<b>28.89</b>	5.38	1.81
	MinMaxScaler	1760.00	41.95	14.49	462.85	21.51	5.53	153.40	12.39	3.24
64,32,32	StandardScaler	1183.72	34.41	8.53	339.07	18.41	4.61	237.64	15.42	4.72
	RobustScaler	173.35	13.17	3.28	221.81	14.89	3.90	<b>43.78</b>	6.62	2.14
	MinMaxScaler	185.28	13.61	4.70	342.78	18.51	4.77	226.72	15.06	4.30
64,32,64	StandardScaler	757.57	27.52	6.90	311.12	17.64	4.37	157.86	12.56	3.05
	RobustScaler	90.08	9.49	2.80	266.80	16.33	4.45	<b>37.14</b>	6.09	1.99
	MinMaxScaler	143.78	11.99	3.82	450.36	21.22	5.37	423.60	20.58	5.31

資料來源：本研究整理

表 7-6 單一指標分析-三層 (續)

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
64,32,128	StandardScaler	224.00	14.97	3.56	321.21	17.92	4.51	132.88	11.53	2.93
	RobustScaler	138.63	11.77	3.31	609.81	24.69	7.01	154.45	12.43	3.49
	MinMaxScaler	<b>121.05</b>	11.00	3.64	416.29	20.40	5.26	226.70	15.06	3.88
64,32,256	StandardScaler	260.16	16.13	3.78	248.41	15.76	3.84	115.09	10.73	2.83
	RobustScaler	<b>62.28</b>	7.89	2.42	428.02	20.69	5.40	129.23	11.37	3.96
	MinMaxScaler	1730.45	41.60	14.15	479.36	21.89	5.87	360.76	18.99	4.80
64,64,32	StandardScaler	831.03	28.83	6.73	374.46	19.35	4.94	202.01	14.21	3.44
	RobustScaler	123.36	11.11	3.07	180.15	13.42	3.50	<b>57.60</b>	7.59	2.27
	MinMaxScaler	144.23	12.01	3.95	412.83	20.32	5.30	263.38	16.23	4.23
64,64,64	StandardScaler	795.40	28.20	6.73	287.23	16.95	4.24	191.09	13.82	3.57
	RobustScaler	94.72	9.73	2.83	164.96	12.84	3.43	<b>41.55</b>	6.45	1.92
	MinMaxScaler	70.44	8.39	2.79	372.71	19.31	5.40	240.03	15.49	3.96
64,64,128	StandardScaler	219.78	14.83	3.53	256.29	16.01	3.99	196.72	14.03	3.64
	RobustScaler	131.97	11.49	3.44	319.28	17.87	4.71	<b>63.97</b>	8.00	2.16
	MinMaxScaler	102.76	10.14	3.13	460.98	21.47	5.30	259.16	16.10	4.19
64,64,256	StandardScaler	108.27	10.41	2.76	253.25	15.91	3.90	283.80	16.85	5.27
	RobustScaler	<b>66.45</b>	8.15	2.44	378.80	19.46	5.05	92.55	9.62	2.99
	MinMaxScaler	1882.01	43.38	13.81	493.56	22.22	5.62	264.62	16.27	4.18
64,128,32	StandardScaler	604.39	24.58	5.54	397.97	19.95	5.06	101.21	10.06	2.61
	RobustScaler	448.15	21.17	5.14	166.16	12.89	3.47	<b>42.42</b>	6.51	1.94
	MinMaxScaler	118.72	10.90	3.41	404.81	20.12	5.12	204.58	14.30	3.76
64,128,64	StandardScaler	435.34	20.86	4.81	175.85	13.26	3.50	196.97	14.03	3.55
	RobustScaler	135.30	11.63	3.01	148.56	12.19	3.31	<b>24.14</b>	4.91	1.63
	MinMaxScaler	216.08	14.70	4.96	417.01	20.42	5.08	102.29	10.11	2.99
64,128,128	StandardScaler	194.48	13.95	3.39	198.87	14.10	3.53	367.77	19.18	5.63
	RobustScaler	81.29	9.02	2.54	289.62	17.02	4.48	<b>29.95</b>	5.47	1.72
	MinMaxScaler	91.49	9.56	2.99	498.60	22.33	5.68	162.59	12.75	3.32

資料來源：本研究整理

表 7-7 單一指標分析-三層 (續)

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
64,128,256	StandardScaler	98.20	9.91	2.62	205.03	14.32	3.51	50.88	7.13	2.54
	RobustScaler	45.92	6.78	2.09	306.57	17.51	4.54	<b>24.11</b>	4.91	1.69
	MinMaxScaler	3171.98	56.32	19.40	445.55	21.11	5.37	108.28	10.41	2.75
64,256,32	StandardScaler	715.17	26.74	6.24	220.53	14.85	3.94	275.90	16.61	4.41
	RobustScaler	116.13	10.78	2.98	133.38	11.55	3.29	<b>88.54</b>	9.41	2.99
	MinMaxScaler	139.83	11.82	3.63	409.32	20.23	5.13	128.92	11.35	3.37
64,256,64	StandardScaler	405.85	20.15	4.58	129.38	11.37	3.03	27.55	5.25	1.65
	RobustScaler	98.48	9.92	2.79	189.71	13.77	3.65	69.46	8.33	2.31
	MinMaxScaler	536.15	23.15	8.54	436.10	20.88	5.08	<b>62.94</b>	7.93	2.26
64,256,128	StandardScaler	166.39	12.90	3.12	111.08	10.54	2.88	1466.06	38.29	11.51
	RobustScaler	336.97	18.36	6.31	99.34	9.97	2.73	<b>75.15</b>	8.67	2.36
	MinMaxScaler	2170.45	46.59	16.18	360.07	18.98	4.69	80.73	8.99	2.46
64,256,256	StandardScaler	137.35	11.72	2.98	148.85	12.20	3.18	603.19	24.56	6.82
	RobustScaler	<b>84.27</b>	9.18	2.63	377.54	19.43	5.68	144.35	12.01	2.98
	MinMaxScaler	1638.70	40.48	13.72	434.32	20.84	5.35	114.62	10.71	2.94
128,32,32	StandardScaler	704.10	26.53	6.42	381.77	19.54	4.82	159.25	12.62	3.33
	RobustScaler	109.38	10.46	3.00	134.64	11.60	3.22	<b>59.10</b>	7.69	2.70
	MinMaxScaler	226.28	15.04	4.85	429.88	20.73	5.26	297.75	17.26	4.86
128,32,64	StandardScaler	266.57	16.33	3.84	339.46	18.42	4.61	152.75	12.36	3.40
	RobustScaler	107.49	10.37	3.20	154.43	12.43	3.32	<b>41.45</b>	6.44	2.28
	MinMaxScaler	1096.09	33.11	12.27	393.93	19.85	5.17	214.72	14.65	4.04
128,32,128	StandardScaler	129.03	11.36	3.12	196.38	14.01	3.55	129.19	11.37	3.03
	RobustScaler	64.95	8.06	2.35	384.58	19.61	5.11	<b>46.99</b>	6.85	2.33
	MinMaxScaler	602.77	24.55	6.96	597.51	24.44	6.01	248.41	15.76	4.38
128,32,256	StandardScaler	433.18	20.81	6.22	309.51	17.59	4.35	192.01	13.86	4.16
	RobustScaler	<b>51.43</b>	7.17	2.34	516.89	22.74	6.04	436.08	20.88	5.74
	MinMaxScaler	2195.11	46.85	14.87	658.66	25.66	6.49	305.83	17.49	4.62

資料來源：本研究整理

表 7-8 單一指標分析-三層 (續)

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
128,64,32	StandardScaler	549.39	23.44	5.53	276.79	16.64	4.14	166.43	12.90	3.47
	RobustScaler	310.54	17.62	4.33	169.77	13.03	3.64	<b>81.25</b>	9.01	2.80
	MinMaxScaler	175.37	13.24	3.92	387.46	19.68	4.86	243.19	15.59	4.07
128,64,64	StandardScaler	351.94	18.76	4.38	202.17	14.22	3.76	177.77	13.33	3.30
	RobustScaler	129.33	11.37	3.76	141.84	11.91	3.20	<b>41.58</b>	6.45	2.24
	MinMaxScaler	580.69	24.10	7.89	435.53	20.87	5.29	301.76	17.37	4.72
128,64,128	StandardScaler	139.95	11.83	2.97	319.90	17.89	4.48	262.85	16.21	4.93
	RobustScaler	192.74	13.88	4.55	336.56	18.35	4.80	<b>44.24</b>	6.65	1.91
	MinMaxScaler	5082.78	71.29	22.57	503.23	22.43	5.74	165.62	12.87	3.34
128,64,256	StandardScaler	317.27	17.81	5.26	207.49	14.40	3.56	57.97	7.61	2.06
	RobustScaler	52.42	7.24	2.25	148.39	12.18	3.22	<b>31.11</b>	5.58	1.75
	MinMaxScaler	2346.79	48.44	17.79	545.53	23.36	5.83	217.87	14.76	3.80
128,,128,32	StandardScaler	421.81	20.54	4.66	196.21	14.01	3.77	180.67	13.44	3.44
	RobustScaler	152.31	12.34	3.38	<b>76.44</b>	8.74	2.53	311.53	17.65	4.90
	MinMaxScaler	293.85	17.14	5.26	648.29	25.46	6.33	92.25	9.60	2.88
128,128,64	StandardScaler	191.03	13.82	3.31	136.96	11.70	3.31	184.54	13.58	3.34
	RobustScaler	75.69	8.70	2.61	399.51	19.99	5.52	<b>35.71</b>	5.98	1.83
	MinMaxScaler	534.04	23.11	7.91	636.08	25.22	6.26	136.59	11.69	3.26
128,128,128	StandardScaler	206.18	14.36	3.50	104.62	10.23	2.81	348.00	18.65	4.37
	RobustScaler	63.46	7.97	2.40	380.33	19.50	5.25	<b>24.72</b>	4.97	1.58
	MinMaxScaler	2480.38	49.80	14.91	426.86	20.66	5.21	124.34	11.15	2.96
128,128,256	StandardScaler	395.82	19.90	5.76	222.92	14.93	4.13	38.44	6.20	1.75
	RobustScaler	<b>36.07</b>	6.01	1.94	401.91	20.05	5.17	53.73	7.33	2.51
	MinMaxScaler	1101.78	33.19	11.20	567.43	23.82	5.89	102.84	10.14	2.96
128,256,32	StandardScaler	409.29	20.23	4.68	43.65	6.61	2.04	170.21	13.05	3.07
	RobustScaler	<b>108.66</b>	10.42	2.78	138.73	11.78	3.32	248.44	15.76	4.13
	MinMaxScaler	416.22	20.40	6.98	228.64	15.12	3.94	106.53	10.32	2.91

資料來源：本研究整理

表 7-9 單一指標分析-三層 (續)

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
128,256,64	StandardScaler	259.15	16.10	3.72	64.56	8.03	2.39	426.90	20.66	6.34
	RobustScaler	75.64	8.70	2.56	133.71	11.56	3.27	<b>72.38</b>	8.51	2.28
	MinMaxScaler	1154.77	33.98	11.85	404.82	20.12	5.36	113.84	10.67	2.91
128,256,128	StandardScaler	109.55	10.47	2.68	179.46	13.40	3.69	328.00	18.11	4.39
	RobustScaler	<b>62.85</b>	7.93	2.40	111.11	10.54	2.84	105.34	10.26	2.59
	MinMaxScaler	1120.82	33.48	10.84	514.95	22.69	5.60	155.68	12.48	3.46
128,256,256	StandardScaler	108.68	10.43	2.84	251.24	15.85	4.17	979.84	31.30	10.30
	RobustScaler	<b>47.46</b>	6.89	2.20	117.09	10.82	2.95	180.02	13.42	3.32
	MinMaxScaler	2133.19	46.19	17.57	750.81	27.40	6.83	229.35	15.14	3.83
256,32,32	StandardScaler	404.27	20.11	4.66	88.79	9.42	2.78	84.18	9.17	2.76
	RobustScaler	136.98	11.70	3.24	187.80	13.70	3.80	<b>26.95</b>	5.19	1.76
	MinMaxScaler	735.28	27.12	9.25	442.00	21.02	6.00	389.39	19.73	5.18
256,32,64	StandardScaler	264.04	16.25	3.91	130.70	11.43	3.21	134.81	11.61	3.45
	RobustScaler	<b>75.01</b>	8.66	2.54	101.68	10.08	2.98	399.21	19.98	4.67
	MinMaxScaler	2287.53	47.83	16.52	770.19	27.75	7.28	291.64	17.08	4.39
256,32,128	StandardScaler	481.65	21.95	6.09	105.51	10.27	3.02	123.14	11.10	2.92
	RobustScaler	<b>65.92</b>	8.12	2.46	393.00	19.82	5.12	283.43	16.84	5.19
	MinMaxScaler	2645.80	51.44	14.59	911.66	30.19	7.55	231.16	15.20	3.85
256,32,256	StandardScaler	561.55	23.70	7.66	217.72	14.76	4.02	322.14	17.95	4.44
	RobustScaler	326.20	18.06	5.61	484.57	22.01	5.75	364.34	19.09	6.11
	MinMaxScaler	3615.08	60.13	20.63	831.32	28.83	7.27	<b>274.84</b>	16.58	4.13
256,64,32	StandardScaler	397.89	19.95	4.67	142.86	11.95	3.31	157.65	12.56	3.22
	RobustScaler	144.92	12.04	3.46	65.41	8.09	2.40	<b>105.65</b>	10.28	2.61
	MinMaxScaler	316.78	17.80	5.53	761.77	27.60	6.84	238.91	15.46	3.97
256,64,64	StandardScaler	263.89	16.24	3.85	49.02	7.00	2.26	256.08	16.00	3.91
	RobustScaler	<b>92.41</b>	9.61	2.81	96.69	9.83	2.83	419.07	20.47	5.25
	MinMaxScaler	1644.33	40.55	14.48	752.05	27.42	6.80	222.22	14.91	3.82

資料來源：本研究整理

表 7-10 單一指標分析-三層 (續)

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
256,64,128	StandardScaler	228.58	15.12	3.86	215.39	14.68	4.00	311.12	17.64	3.99
	RobustScaler	<b>42.45</b>	6.52	2.09	255.66	15.99	4.21	352.15	18.77	4.50
	MinMaxScaler	1125.31	33.55	10.40	737.13	27.15	6.79	243.14	15.59	4.00
256,64,256	StandardScaler	345.59	18.59	5.58	38.58	6.21	2.15	558.32	23.63	7.18
	RobustScaler	156.03	12.49	3.64	62.92	7.93	2.38	<b>21.12</b>	4.60	1.55
	MinMaxScaler	999.07	31.61	11.39	690.26	26.27	6.86	217.78	14.76	3.68
256,128,32	StandardScaler	422.01	20.54	4.66	<b>39.53</b>	6.29	1.98	395.14	19.88	5.50
	RobustScaler	88.46	9.41	2.91	42.17	6.49	2.20	869.91	29.49	7.93
	MinMaxScaler	627.64	25.05	8.01	575.15	23.98	5.86	102.73	10.14	2.78
256,128,64	StandardScaler	412.40	20.31	4.74	<b>31.58</b>	5.62	1.91	552.98	23.52	5.38
	RobustScaler	115.96	10.77	3.27	134.57	11.60	3.32	285.39	16.89	4.37
	MinMaxScaler	812.23	28.50	9.58	812.41	28.50	7.02	106.07	10.30	2.76
256,128,128	StandardScaler	285.89	16.91	4.06	99.21	9.96	2.92	460.48	21.46	5.90
	RobustScaler	<b>57.18</b>	7.56	2.32	76.35	8.74	2.53	109.22	10.45	2.64
	MinMaxScaler	370.29	19.24	6.98	562.35	23.71	5.88	128.67	11.34	3.18
256,128,256	StandardScaler	484.88	22.02	7.02	183.74	13.55	3.87	1087.76	32.98	9.69
	RobustScaler	46.91	6.85	2.23	174.10	13.19	3.54	<b>37.14</b>	6.09	1.83
	MinMaxScaler	681.56	26.11	9.41	580.34	24.09	5.90	200.18	14.15	3.68
256,256,32	StandardScaler	415.68	20.39	4.62	226.86	15.06	4.24	960.78	31.00	9.40
	RobustScaler	91.97	9.59	2.70	<b>45.05</b>	6.71	2.08	781.603	27.96	5.81
	MinMaxScaler	1207.31	34.75	11.92	903.51	30.06	7.52	285.33	16.89	4.68
256,256,64	StandardScaler	210.10	14.49	3.49	139.39	11.81	3.23	1055.05	32.48	8.59
	RobustScaler	48.19	6.94	2.26	95.73	9.78	2.72	586.96	24.23	7.36
	MinMaxScaler	1574.12	39.68	14.42	73.88	8.60	2.70	<b>47.44</b>	6.89	2.06
256,256,128	StandardScaler	120.82	10.99	2.89	347.81	18.65	4.71	1549.91	39.37	12.29
	RobustScaler	58.86	7.67	2.38	<b>32.01</b>	5.66	1.86	160.18	12.66	2.95
	MinMaxScaler	1295.01	35.99	12.37	1317.94	36.30	9.15	95.05	9.75	2.95
256,256,256	StandardScaler	61.01	7.81	2.36	189.09	13.75	3.54	47.09	6.86	2.45
	RobustScaler	41.69	6.46	2.11	242.61	15.58	4.15	<b>21.82</b>	4.67	1.50
	MinMaxScaler	302.21	17.38	5.67	735.30	27.12	6.75	4096.26	64.00	24.13



附錄 B：多指標分析結果

表 8- 1 多一指標分析-一層

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
32	Z-Score	439.46	20.96	6.37	669.32	25.87	7.35	395.08	19.88	6.31
	RobustScaler	496.52	22.28	6.17	422.06	20.54	7.04	<b>181.35</b>	13.47	4.56
	Max-Min	196.86	14.03	5.08	286.04	16.91	4.23	225.14	15.00	4.60
64	Z-Score	577.84	24.04	6.60	401.52	20.04	6.05	300.36	17.33	5.66
	RobustScaler	305.30	17.47	5.43	180.40	13.43	4.80	264.91	16.28	5.52
	Max-Min	<b>173.97</b>	13.19	3.70	192.23	13.86	3.67	248.48	15.76	5.10
128	Z-Score	573.05	23.94	6.65	257.32	16.04	5.17	235.72	15.35	5.09
	RobustScaler	228.55	15.12	4.37	<b>56.25</b>	12.50	4.38	163.59	12.79	4.28
	Max-Min	121.43	11.02	3.50	247.55	15.73	3.93	341.21	18.47	6.34
256	Z-Score	397.95	19.95	5.09	203.18	14.25	5.05	241.81	15.55	4.95
	RobustScaler	157.29	12.54	4.02	153.80	12.40	4.47	<b>115.74</b>	10.76	3.90
	Max-Min	119.22	10.92	3.53	183.26	13.54	3.67	231.30	15.21	4.80

資料來源：本研究整理

表 8-2 多一指標分析-二層

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
32,32	StandardScaler	435.19	20.86	5.00	1212.75	34.82	8.99	825.56	28.73	8.23
	RobustScaler	400.60	20.02	5.74	766.00	27.68	8.00	284.89	16.88	5.56
	MinMaxScaler	315.90	17.77	5.33	<b>254.09</b>	15.94	4.26	279.28	16.71	4.53
32,64	StandardScaler	633.71	25.17	6.09	1302.45	36.09	9.80	741.12	27.22	8.26
	RobustScaler	1414.47	37.61	10.09	661.40	25.72	7.40	498.11	22.32	6.72
	MinMaxScaler	<b>120.97</b>	11.00	3.26	321.59	17.93	4.61	877.92	29.63	9.00
32,128	StandardScaler	677.34	26.03	6.12	1660.00	40.74	11.51	800.53	28.29	8.17
	RobustScaler	981.85	31.33	8.03	845.41	29.08	8.10	401.33	20.03	6.43
	MinMaxScaler	<b>177.31</b>	13.32	3.71	227.12	15.07	3.85	572.50	23.93	6.25
32,256	StandardScaler	713.39	26.71	5.84	1717.90	41.45	12.17	1167.00	34.16	10.57
	RobustScaler	428.95	20.71	4.83	841.03	29.00	8.02	459.67	21.44	6.28
	MinMaxScaler	547.55	23.40	7.72	<b>319.57</b>	17.88	5.28	730.61	27.03	7.23
64,32	StandardScaler	473.11	21.75	5.27	1032.95	32.14	9.11	727.82	26.98	8.29
	RobustScaler	387.04	19.67	5.70	675.77	26.00	7.62	333.27	18.26	6.05
	MinMaxScaler	<b>322.23</b>	17.95	5.06	500.88	22.38	6.04	405.58	20.14	5.23
64,64	StandardScaler	519.12	22.78	6.12	1192.64	34.53	9.44	446.53	21.13	6.07
	RobustScaler	1109.58	33.31	8.45	725.09	26.93	7.71	237.94	15.43	5.12
	MinMaxScaler	<b>135.60</b>	11.64	3.25	411.88	20.29	5.51	655.15	25.60	7.43
64,128	StandardScaler	943.63	30.72	7.61	1586.59	39.83	11.69	516.12	22.72	6.50
	RobustScaler	409.89	20.25	4.87	798.91	28.26	8.04	399.47	19.99	6.54
	MinMaxScaler	<b>108.91</b>	10.44	3.05	171.45	13.09	3.72	698.10	26.42	7.07
64,256	StandardScaler	343.73	18.54	4.24	1047.77	32.37	8.86	341.70	18.49	4.88
	RobustScaler	368.18	19.19	5.99	682.00	26.12	7.31	524.07	22.89	7.06
	MinMaxScaler	532.49	23.08	7.30	<b>281.93</b>	16.79	4.68	1441.97	37.97	11.31
128,32	StandardScaler	709.00	26.63	7.23	322.37	17.95	4.23	768.70	27.73	8.64
	RobustScaler	1026.53	32.04	7.67	762.22	27.61	8.02	410.15	20.25	6.46
	MinMaxScaler	<b>166.59</b>	12.91	3.57	338.17	18.39	4.43	517.81	22.76	6.63

資料來源：本研究整理

表 8-3 多一指標分析-二層 (續)

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
128,64	StandardScaler	1778.34	42.17	12.05	1302.86	36.10	11.00	687.53	26.22	8.27
	RobustScaler	391.46	19.79	4.63	622.69	24.95	7.46	513.08	22.65	7.19
	MinMaxScaler	<b>152.08</b>	12.33	3.68	333.29	18.26	4.64	404.79	20.12	5.12
128,128	StandardScaler	735.21	27.11	6.46	347.20	18.63	5.37	921.96	30.36	9.46
	RobustScaler	490.66	22.15	5.28	623.53	24.97	7.19	366.73	19.15	6.21
	MinMaxScaler	<b>115.41</b>	10.74	3.31	287.90	16.97	4.47	663.31	25.75	7.05
128,256	StandardScaler	534.12	23.11	5.15	<b>201.80</b>	14.21	3.74	615.73	24.81	8.17
	RobustScaler	314.17	17.72	4.71	268.42	16.38	4.69	223.84	14.96	4.86
	MinMaxScaler	319.21	17.87	5.83	297.02	17.23	4.31	710.74	26.66	6.97
256,32	StandardScaler	1615.49	40.19	11.63	1068.11	32.68	10.05	268.23	16.38	5.05
	RobustScaler	746.58	27.32	6.68	<b>190.31</b>	13.80	3.84	403.80	20.09	6.36
	MinMaxScaler	192.91	13.89	4.31	595.72	24.41	6.01	454.26	21.31	5.10
256,64	StandardScaler	405.74	20.14	5.71	876.64	29.61	9.32	747.29	27.34	8.33
	RobustScaler	714.55	26.73	6.93	519.98	22.80	6.77	<b>339.77</b>	18.43	6.19
	MinMaxScaler	507.31	22.52	7.88	443.67	21.06	5.69	387.92	19.70	4.72
256,128	StandardScaler	507.83	22.54	5.52	1251.98	35.38	10.86	851.74	29.18	9.41
	RobustScaler	353.49	18.80	4.82	454.50	21.32	6.28	392.27	19.81	6.38
	MinMaxScaler	<b>135.63</b>	11.65	3.56	509.16	22.56	5.72	568.42	23.84	5.91
256,256	StandardScaler	439.57	20.97	4.98	<b>98.09</b>	9.90	3.33	75.59	8.69	3.10
	RobustScaler	175.34	13.24	3.96	580.21	24.09	7.04	990.11	31.47	10.76
	MinMaxScaler	423.16	20.57	6.78	610.86	24.72	5.74	1478.73	38.45	12.33

資料來源：本研究整理

表 8-4 多一指標分析-三層

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
32,32,32	StandardScaler	634.94	25.20	5.72	1417.76	37.65	10.43	1274.30	35.70	10.32
	RobustScaler	370.95	19.26	4.81	1079.76	32.86	9.13	991.53	31.49	9.31
	MinMaxScaler	<b>201.20</b>	14.18	4.47	431.07	20.76	5.35	345.13	18.58	4.72
32,32,64	StandardScaler	450.92	21.23	5.07	1317.91	36.30	10.07	1277.88	35.75	10.51
	RobustScaler	836.42	28.92	7.37	1079.52	32.86	9.11	559.82	23.66	6.65
	MinMaxScaler	346.49	18.61	4.99	486.56	22.06	5.70	<b>288.09</b>	16.97	4.39
32,32,128	StandardScaler	1260.03	35.50	9.58	1555.54	39.44	11.21	829.91	28.81	7.68
	RobustScaler	1226.05	35.02	8.52	1650.02	40.62	12.23	660.55	25.70	7.00
	MinMaxScaler	<b>146.56</b>	12.11	3.38	473.27	21.75	5.24	213.66	14.62	3.85
32,32,256	StandardScaler	715.05	26.74	6.22	1131.33	33.64	8.89	1334.15	36.53	10.57
	RobustScaler	803.42	28.34	6.71	1123.16	33.51	9.22	1080.78	32.88	10.39
	MinMaxScaler	1606.58	40.08	13.19	542.63	23.29	6.03	<b>201.58</b>	14.20	3.77
32,64,32	StandardScaler	472.76	21.74	5.37	1157.72	34.03	9.24	1048.87	32.39	9.79
	RobustScaler	323.66	17.99	4.55	1181.88	34.38	9.35	622.97	24.96	7.30
	MinMaxScaler	397.68	19.94	5.77	467.88	21.63	5.14	<b>276.64</b>	16.63	4.62
32,64,64	StandardScaler	1469.49	38.33	10.52	986.70	31.41	8.25	1227.61	35.04	10.93
	RobustScaler	959.58	30.98	8.41	1234.60	35.14	9.76	1066.73	32.66	10.10
	MinMaxScaler	<b>188.66</b>	13.74	3.67	460.86	21.47	5.38	339.95	18.44	4.75
32,64,128	StandardScaler	1676.70	40.95	11.53	1397.92	37.39	9.82	1561.18	39.51	11.96
	RobustScaler	1002.16	31.66	7.70	1102.85	33.21	9.02	826.37	28.75	8.75
	MinMaxScaler	<b>122.43</b>	11.06	3.21	489.67	22.13	5.71	282.82	16.82	4.64
32,64,256	StandardScaler	908.72	30.14	7.05	956.50	30.93	7.86	580.52	24.09	6.07
	RobustScaler	671.63	25.92	5.68	1261.53	35.52	9.94	545.91	23.36	6.29
	MinMaxScaler	1088.81	33.00	10.75	575.02	23.98	5.97	<b>319.34</b>	17.87	4.59
32,128,32	StandardScaler	486.50	22.06	5.17	1386.66	37.24	10.30	1125.63	33.55	10.17
	RobustScaler	838.61	28.96	8.15	1113.78	33.37	9.28	418.48	20.46	6.08
	MinMaxScaler	340.82	18.46	5.73	721.84	26.87	6.93	<b>268.37</b>	16.38	4.41

資料來源：本研究整理

表 8-5 多一指標分析-三層 (續)

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
32,128,64	StandardScaler	1122.88	33.51	8.96	1533.66	39.16	11.39	1005.49	31.71	9.55
	RobustScaler	1463.15	38.25	9.79	1105.61	33.25	9.06	581.73	24.12	6.61
	MinMaxScaler	<b>171.43</b>	13.09	3.74	483.66	21.99	5.19	273.50	16.54	4.57
32,128,128	StandardScaler	1091.66	33.04	7.82	331.59	18.21	4.34	544.85	23.34	5.75
	RobustScaler	698.50	26.43	6.13	1150.13	33.91	9.36	692.12	26.31	7.85
	MinMaxScaler	<b>120.37</b>	10.97	3.28	446.60	21.13	5.08	255.02	15.97	4.21
32,128,256	StandardScaler	546.55	23.38	5.88	2060.31	45.39	13.93	801.86	28.32	8.10
	RobustScaler	377.88	19.44	4.71	1171.50	34.23	9.39	421.24	20.52	5.37
	MinMaxScaler	<b>126.82</b>	11.26	3.78	429.69	20.73	5.04	190.93	13.82	3.74
32,256,32	StandardScaler	1874.75	43.30	11.88	1423.10	37.72	10.82	1102.41	33.20	9.90
	RobustScaler	1174.58	34.27	8.14	1054.19	32.47	8.94	547.06	23.39	6.52
	MinMaxScaler	<b>139.77</b>	11.82	3.43	496.38	22.28	5.40	322.34	17.95	4.65
32,256,64	StandardScaler	1086.04	32.96	9.52	1486.85	38.56	11.49	608.10	24.66	6.20
	RobustScaler	1415.13	37.62	10.07	364.15	19.08	5.25	994.07	31.53	9.60
	MinMaxScaler	<b>192.55</b>	13.88	3.90	951.46	30.85	7.19	169.89	13.03	4.10
32,256,128	StandardScaler	907.95	30.13	7.36	424.96	20.61	4.69	849.99	29.15	8.48
	RobustScaler	824.61	28.72	7.21	826.97	28.76	7.24	601.29	24.52	7.37
	MinMaxScaler	131.96	11.49	3.93	462.50	21.51	5.23	<b>118.73</b>	10.90	3.35
32,256,256	StandardScaler	1644.38	40.55	11.77	1644.91	40.56	11.97	1462.86	38.25	11.98
	RobustScaler	834.95	28.90	7.68	1353.42	36.79	10.00	460.52	21.46	6.14
	MinMaxScaler	<b>214.16</b>	14.63	4.27	537.16	23.18	5.49	332.57	18.24	4.78
64,32,32	StandardScaler	609.56	24.69	5.76	1131.74	33.64	9.18	916.08	30.27	8.85
	RobustScaler	423.38	20.58	5.26	1122.80	33.51	9.53	960.99	30.07	9.77
	MinMaxScaler	<b>206.45</b>	14.37	3.79	502.55	22.42	5.36	264.04	16.25	4.16
64,32,64	StandardScaler	379.21	19.47	4.77	1387.79	37.25	10.43	1036.55	32.20	9.93
	RobustScaler	334.48	18.29	4.64	945.19	30.74	8.82	904.20	30.07	9.77
	MinMaxScaler	<b>254.36</b>	15.95	4.18	540.24	23.24	5.62	323.19	17.98	4.64

資料來源：本研究整理

表 8-6 多一指標分析-三層 (續)

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
64,32,128	StandardScaler	1123.38	33.52	8.38	1623.72	40.30	11.50	572.93	23.94	5.77
	RobustScaler	1015.64	31.87	7.34	1243.89	35.27	10.12	857.51	29.28	8.66
	MinMaxScaler	<b>233.29</b>	15.27	4.28	535.65	23.14	5.71	264.45	16.26	4.33
64,32,256	StandardScaler	729.40	27.01	6.15	1619.36	40.24	11.95	618.21	24.86	6.23
	RobustScaler	692.50	26.32	6.63	995.61	995.61	8.68	972.27	31.18	9.65
	MinMaxScaler	1127.50	33.58	9.43	655.67	25.61	6.14	<b>214.82</b>	14.66	3.78
64,64,32	StandardScaler	471.62	21.72	6.32	1167.34	34.17	9.63	1380.87	37.16	11.11
	RobustScaler	1007.10	31.73	7.74	923.28	30.39	8.58	751.39	27.41	8.55
	MinMaxScaler	<b>311.51</b>	17.65	4.58	680.23	26.08	7.98	351.81	18.76	4.58
64,64,64	StandardScaler	544.63	23.34	6.76	1370.23	37.02	10.35	1298.94	36.04	11.19
	RobustScaler	1185.50	34.43	8.23	913.95	30.23	8.52	761.87	27.60	8.28
	MinMaxScaler	<b>193.87</b>	13.92	4.71	396.88	19.92	4.80	194.80	13.96	3.80
64,64,128	StandardScaler	1327.61	36.44	9.41	341.81	18.49	4.49	532.00	23.07	5.98
	RobustScaler	736.36	27.14	6.08	1027.17	32.05	8.97	580.35	24.09	6.89
	MinMaxScaler	<b>120.56</b>	10.98	3.22	512.57	22.64	5.38	208.06	14.42	4.09
64,64,256	StandardScaler	519.34	22.79	5.53	639.02	25.28	6.22	491.74	22.18	5.92
	RobustScaler	469.06	21.66	5.06	975.76	31.24	8.83	1152.77	33.95	10.50
	MinMaxScaler	2060.24	45.39	16.35	540.51	23.25	6.32	<b>239.24</b>	15.47	3.99
64,128,32	StandardScaler	704.46	26.54	7.57	1315.59	36.27	10.27	1245.17	35.29	10.58
	RobustScaler	801.93	28.32	6.59	1626.05	40.32	11.64	382.90	19.57	5.20
	MinMaxScaler	<b>130.34</b>	11.42	3.73	543.07	23.30	5.67	379.86	19.49	5.37
64,128,64	StandardScaler	1265.38	35.57	10.44	229.97	15.16	4.06	447.35	21.15	5.12
	RobustScaler	834.35	28.89	6.86	2146.46	46.33	13.79	375.45	19.38	5.42
	MinMaxScaler	<b>208.40</b>	14.44	4.15	479.57	21.90	5.70	447.75	21.16	5.08
64,128,128	StandardScaler	537.74	23.19	6.71	935.58	30.59	8.00	546.11	23.37	5.92
	RobustScaler	937.61	30.62	6.83	1050.22	32.41	8.92	668.57	25.86	7.41
	MinMaxScaler	<b>136.98</b>	11.70	3.30	426.34	20.65	4.88	172.72	13.14	3.58

資料來源：本研究整理

表 8-7 多一指標分析-三層 (續)

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
64,128,256	StandardScaler	630.95	25.12	6.18	473.87	21.77	6.56	989.75	31.46	8.90
	RobustScaler	633.11	25.16	6.16	1382.11	37.18	11.27	390.74	19.77	5.83
	MinMaxScaler	496.96	22.29	6.08	573.18	23.94	5.58	<b>344.39</b>	18.56	4.57
64,256,32	StandardScaler	1648.51	40.60	10.94	676.29	26.01	7.40	905.13	30.09	9.09
	RobustScaler	1051.01	32.42	8.63	1248.68	35.34	9.83	849.82	29.15	8.83
	MinMaxScaler	<b>184.81</b>	13.59	3.61	421.96	20.54	5.07	412.02	20.30	4.85
64,256,64	StandardScaler	2595.48	50.95	16.33	802.84	28.33	8.31	722.82	26.89	7.83
	RobustScaler	1969.16	44.38	13.42	1066.58	32.66	9.75	360.68	18.99	5.36
	MinMaxScaler	<b>111.08</b>	10.54	3.32	669.70	25.88	5.86	336.16	18.33	4.75
64,256,128	StandardScaler	1368.16	36.99	9.35	230.58	15.19	4.00	1002.75	31.67	8.95
	RobustScaler	501.45	22.39	5.11	<b>120.12</b>	10.96	3.22	633.63	25.17	8.13
	MinMaxScaler	372.87	19.31	6.48	531.59	23.06	5.35	159.89	12.64	3.57
64,256,256	StandardScaler	884.14	29.73	7.94	516.65	22.73	6.24	244.95	15.65	4.18
	RobustScaler	494.37	22.23	5.97	674.79	25.98	6.78	<b>159.48</b>	12.63	4.22
	MinMaxScaler	312.99	17.69	5.20	923.19	30.38	6.75	390.37	19.76	5.07
128,32,32	StandardScaler	396.39	19.91	4.71	1043.05	32.30	8.58	1062.07	32.59	9.63
	RobustScaler	1040.99	32.26	9.01	953.04	30.87	8.74	1232.47	35.11	11.81
	MinMaxScaler	246.16	15.69	4.19	495.72	22.26	5.36	<b>191.54</b>	13.84	3.69
128,32,64	StandardScaler	679.86	26.07	7.31	1404.16	37.47	10.78	698.38	26.43	6.90
	RobustScaler	1122.90	33.51	8.31	859.51	29.32	8.26	571.26	23.90	6.39
	MinMaxScaler	229.74	15.16	3.94	640.64	25.31	6.13	155.65	12.48	3.43
128,32,128	StandardScaler	873.17	29.55	6.93	523.45	22.88	6.25	1603.88	40.05	12.15
	RobustScaler	660.27	25.70	5.73	843.86	29.05	8.08	765.76	27.67	8.50
	MinMaxScaler	653.63	25.57	7.58	687.84	26.23	6.47	<b>326.61</b>	18.07	4.44
128,32,256	StandardScaler	632.60	25.15	6.17	428.16	20.69	5.54	592.37	24.34	6.69
	RobustScaler	492.39	22.19	5.57	1244.90	35.28	10.27	1335.66	36.55	11.82
	MinMaxScaler	1232.71	35.11	10.96	685.01	26.17	6.49	<b>275.85</b>	16.61	4.16

資料來源：本研究整理

表 8-8 多一指標分析-三層 (續)

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
128,64,32	StandardScaler	574.54	23.97	6.47	1431.37	37.83	11.16	1219.13	34.92	10.43
	RobustScaler	756.02	27.50	7.37	1297.35	36.02	10.40	435.75	20.87	5.98
	MinMaxScaler	<b>159.23</b>	12.62	3.41	727.53	26.97	6.74	360.15	18.98	4.78
128,64,64	StandardScaler	1033.45	32.15	9.16	1444.96	38.01	11.15	358.14	18.92	4.61
	RobustScaler	1955.88	44.23	12.05	1232.41	35.11	10.04	405.24	20.13	5.47
	MinMaxScaler	<b>122.54</b>	11.07	3.21	659.86	25.69	6.06	332.11	18.22	5.21
128,64,128	StandardScaler	820.83	28.65	6.71	890.91	29.85	9.09	1039.25	32.24	9.71
	RobustScaler	545.92	23.37	5.16	664.92	25.79	7.03	480.18	21.91	6.09
	MinMaxScaler	<b>190.40</b>	13.80	5.11	538.20	23.20	5.66	324.82	18.02	4.42
128,64,256	StandardScaler	532.12	23.07	7.66	812.38	28.50	8.90	1142.38	33.80	10.33
	RobustScaler	<b>262.92</b>	16.21	4.25	1025.31	32.02	8.74	498.37	22.32	6.63
	MinMaxScaler	2032.49	45.08	15.95	541.52	23.27	5.42	374.85	19.36	4.83
128,,128,32	StandardScaler	819.77	28.63	9.09	318.25	17.84	4.79	570.14	23.88	6.64
	RobustScaler	2990.04	54.68	17.69	1366.84	36.97	10.65	689.78	26.26	7.67
	MinMaxScaler	<b>290.39</b>	17.04	4.74	732.14	27.06	6.25	432.30	20.79	4.95
128,128,64	StandardScaler	1869.80	43.24	12.22	350.06	18.71	4.80	548.34	23.42	6.48
	RobustScaler	739.60	27.20	6.13	617.88	24.86	6.32	363.54	19.07	5.62
	MinMaxScaler	<b>103.96</b>	10.20	3.38	725.87	26.94	6.37	338.57	18.40	4.53
128,128,128	StandardScaler	657.50	25.64	6.33	240.84	15.52	4.24	1130.17	33.62	9.66
	RobustScaler	837.16	28.93	6.68	140.96	11.87	3.78	1052.74	32.45	10.14
	MinMaxScaler	<b>133.93</b>	11.57	3.98	672.62	25.93	6.03	445.18	21.10	5.11
128,128,256	StandardScaler	734.98	27.11	6.63	784.05	28.00	8.54	1089.87	33.01	9.44
	RobustScaler	330.28	18.17	4.38	<b>141.86</b>	11.91	3.35	594.88	24.39	7.50
	MinMaxScaler	961.13	31.00	11.12	638.10	25.26	5.83	617.83	24.86	7.98
128,256,32	StandardScaler	1749.87	41.83	11.75	372.14	19.29	5.37	551.77	23.49	6.19
	RobustScaler	1366.42	36.97	9.22	2338.15	48.35	14.22	996.82	31.57	9.71
	MinMaxScaler	<b>85.18</b>	9.23	2.90	1055.27	32.48	7.42	598.06	24.46	5.94

資料來源：本研究整理



表 8-9 多一指標分析-三層 (續)

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
128,256,64	StandardScaler	919.51	30.32	8.29	237.53	15.41	4.39	659.65	25.68	7.00
	RobustScaler	2363.34	48.61	15.05	1362.80	36.92	11.37	417.71	20.44	6.13
	MinMaxScaler	<b>125.78</b>	11.22	3.82	1145.35	33.84	7.54	560.78	23.68	5.90
128,256,128	StandardScaler	1653.68	40.67	11.10	219.09	14.80	3.79	405.99	20.15	5.48
	RobustScaler	324.93	18.03	6.00	418.28	20.45	5.40	<b>217.35</b>	14.74	4.85
	MinMaxScaler	363.20	19.06	6.88	599.75	24.49	5.62	347.03	18.63	4.62
128,256,256	StandardScaler	808.44	28.43	7.90	536.48	23.16	5.91	309.16	17.58	4.84
	RobustScaler	<b>221.15</b>	14.87	5.25	539.93	23.24	7.16	352.36	18.77	5.52
	MinMaxScaler	766.77	27.69	8.75	1278.84	35.76	7.84	489.26	22.12	5.54
256,32,32	StandardScaler	725.84	26.94	6.92	1448.47	38.06	11.38	658.74	25.67	6.34
	RobustScaler	1670.28	40.87	11.14	1843.11	42.93	12.78	1285.84	35.86	11.26
	MinMaxScaler	<b>208.27</b>	14.43	3.97	755.42	27.48	6.74	400.03	20.00	4.81
256,32,64	StandardScaler	815.00	28.55	7.83	232.94	15.26	3.90	1640.54	40.50	12.18
	RobustScaler	829.02	28.79	6.76	422.48	20.55	5.66	1148.13	33.88	10.88
	MinMaxScaler	139.71	11.82	3.90	712.38	26.69	6.58	461.29	21.48	5.52
256,32,128	StandardScaler	1252.64	35.39	8.63	248.82	15.77	4.02	1445.14	38.01	10.98
	RobustScaler	507.40	22.53	5.11	2511.08	50.11	15.65	1225.32	35.00	11.14
	MinMaxScaler	1878.68	43.34	15.00	659.98	25.69	6.10	<b>438.43</b>	20.94	4.98
256,32,256	StandardScaler	833.59	28.87	6.89	1146.29	33.86	10.07	720.24	26.84	6.88
	RobustScaler	352.12	18.76	4.93	<b>99.33</b>	9.97	3.24	407.69	20.19	5.47
	MinMaxScaler	590.03	24.29	7.83	827.82	28.77	7.04	713.82	26.72	6.33
256,64,32	StandardScaler	925.89	30.43	8.00	912.13	30.20	9.34	1528.94	39.10	11.78
	RobustScaler	606.30	24.62	6.84	1784.85	42.25	12.40	500.91	22.38	6.23
	MinMaxScaler	<b>289.92</b>	17.03	4.63	799.40	28.27	6.84	527.14	22.96	5.52
256,64,64	StandardScaler	2067.34	45.47	13.75	397.35	19.93	5.80	423.78	20.59	4.95
	RobustScaler	1448.84	38.06	9.86	343.09	18.52	5.08	301.84	17.37	4.73
	MinMaxScaler	<b>110.53</b>	10.51	3.18	901.59	30.03	7.28	314.13	17.72	4.47

資料來源：本研究整理

表 8-10 多一指標分析-三層 (續)

神經元數		RNN			LSTM			GRU		
		MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
256,64,128	StandardScaler	1268.73	35.62	9.10	438.24	20.93	6.37	987.91	31.43	8.97
	RobustScaler	1333.25	36.51	9.48	2200.46	46.91	14.26	1084.88	32.94	9.82
	MinMaxScaler	<b>377.84</b>	19.44	5.30	749.83	27.38	6.56	519.03	22.78	5.56
256,64,256	StandardScaler	548.90	23.43	6.85	513.17	22.65	7.06	<b>114.15</b>	10.68	2.97
	RobustScaler	390.25	19.75	5.36	136.90	11.70	3.70	340.23	18.45	5.82
	MinMaxScaler	956.33	30.92	10.77	873.71	29.56	7.22	1520.22	38.99	10.88
256,128,32	StandardScaler	1037.87	32.22	9.98	829.38	28.80	9.45	837.96	28.95	8.25
	RobustScaler	1782.15	42.22	13.75	369.61	19.23	6.32	422.42	20.55	6.10
	MinMaxScaler	<b>224.80</b>	14.99	4.03	857.77	29.29	6.77	630.57	25.11	6.11
256,128,64	StandardScaler	2041.79	45.19	13.78	1184.18	34.41	10.46	369.88	19.23	5.21
	RobustScaler	1394.10	37.34	10.61	417.08	20.42	5.49	564.54	23.76	6.99
	MinMaxScaler	<b>181.48</b>	13.47	3.58	926.58	30.44	7.29	630.44	25.11	6.54
256,128,128	StandardScaler	927.60	30.46	7.96	107.83	10.38	2.98	194.68	13.95	3.81
	RobustScaler	381.14	19.52	5.48	<b>183.16</b>	13.53	3.96	327.44	18.10	5.65
	MinMaxScaler	209.12	14.46	4.42	891.73	29.86	7.07	689.37	26.26	7.72
256,128,256	StandardScaler	769.20	27.73	6.64	401.29	20.03	6.05	327.08	18.09	4.81
	RobustScaler	307.61	17.54	4.31	<b>97.87</b>	9.89	3.27	179.06	13.38	4.02
	MinMaxScaler	334.41	18.29	5.10	968.78	31.13	7.38	1050.56	32.41	8.26
256,256,32	StandardScaler	1243.86	35.27	10.64	683.90	26.15	8.02	<b>232.03</b>	15.23	4.29
	RobustScaler	2337.21	48.34	13.59	811.22	28.48	8.31	674.24	25.97	7.52
	MinMaxScaler	676.91	26.02	9.85	979.93	31.30	7.39	1219.73	34.92	9.35
256,256,64	StandardScaler	2260.32	47.54	13.92	344.08	18.55	5.28	367.68	19.18	4.81
	RobustScaler	1720.65	41.48	11.25	277.65	16.66	4.58	534.00	23.11	6.24
	MinMaxScaler	<b>187.65</b>	13.70	4.23	912.84	30.21	6.93	1721.58	41.49	12.18
256,256,128	StandardScaler	2797.21	52.89	17.08	603.56	24.57	7.36	312.41	17.68	4.75
	RobustScaler	2609.51	51.08	15.80	1157.15	34.02	10.25	<b>47.41</b>	6.89	2.46
	MinMaxScaler	133.58	11.56	3.80	967.49	31.10	7.14	2562.66	50.62	17.34
256,256,256	StandardScaler	918.92	30.31	8.17	103.55	10.18	2.99	832.51	28.85	7.84
	RobustScaler	1899.06	43.58	12.02	1076.67	32.81	10.74	1330.29	36.47	12.08
	MinMaxScaler	844.09	29.05	9.19	<b>823.13</b>	28.69	6.44	1551.70	39.39	12.06

附錄 C：多指標單因子變異數分析結果

表 9-1 不同特徵縮放方法在層數預測準確度之差異分析摘要表

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F	事後 檢定
一層	1.StandardScaler	12	203.18	669.32	391.05	152.49	3.06	8.05*	1>2,3
	2.RobustScaler	12	56.25	496.52	227.15	127.31			
	3.MinMaxScaler	12	119.22	341.21	213.89	63.94			
二層	1.StandardScaler	48	75.59	1778.34	795.62	433.20	6.08*	14.16 <sup>註2</sup>	1>2,3
	2.RobustScaler	48	175.34	1414.47	552.28	263.65			
	3.MinMaxScaler	48	108.91	1478.73	438.01	286.52			
三層	1.StandardScaler	192	103.55	2797.21	915.36	492.57	10.4*	40.62 <sup>註2</sup>	1,2>3
	2.RobustScaler	192	47.41	2990.04	881.25	529.96			
	3.MinMaxScaler	192	85.18	2562.66	520.23	395.33			

備註：

- 1.\*  $\alpha < 0.05$
2. 組別不同質，改採 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05 (顯著)，進行事後較
3. 因本研究使用 MSE 作為預測準確度判斷, MSE 越小代表越好

表 9-2 不同層數在特徵縮放方法預測準確度之差異分析摘要表

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F	事後 檢定
StandardScaler	1.一層	12	203.18	669.32	391.05	152.49	6.02 <sup>*</sup>	7.67 <sup>註2</sup>	3、2>1
	2.二層	48	75.59	1778.34	795.62	433.20			
	3.三層	192	103.55	2797.21	915.36	492.57			
RobustScaler	1.一層	12	56.25	496.52	227.15	127.31	12.72 <sup>*</sup>	17.69 <sup>註2</sup>	3>2>1
	2.二層	48	175.34	1414.47	552.28	263.65			
	3.三層	192	47.41	2990.04	881.25	529.96			
MinMaxScaler	1.一層	12	119.22	341.21	213.89	63.94	5.84 <sup>*</sup>	4.5 <sup>註2</sup>	3>1
	2.二層	48	108.91	1478.73	438.01	286.52			
	3.三層	192	85.18	2562.66	520.23	395.33			

備註：

1<sup>\*</sup>  $\alpha < 0.05$

2.組別不同質，改採 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05 (顯著)，進行事後較

3.因本研究使用 MSE 作為預測準確度判斷,MSE 越小代表越好

表 9-3 不同特徵縮放方法在遞迴神經網路預測準確度之差異分析表（一層）

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F	事後檢定
RNN	1.StandarScaler	4	397.95	577.84	497.08	92.09	2.15	11.44 <sup>註3</sup>	1>3
	2.RobustScaler	4	157.29	496.52	296.92	38.73			
	3.MinMaxScaler	4	119.22	196.86	152.88	174.01			
LSTM	1.StandardScaler	4	203.18	669.32	382.83	208.53	1.9	1.63	
	2.RobustScaler	4	56.25	422.06	203.13	155.41			
	3.MinMaxScaler	4	183.26	286.04	227.27	48.41			
GRU	1.StandardScaler	4	235.72	395.08	293.25	73.88	0.2	3.26	
	2.RobustScaler	4	115.74	264.91	181.4	62.19			
	3.MinMaxScaler	4	225.74	341.21	261.39	54.03			

備註：

1.\*  $\alpha < 0.05$

2 組別不同質，改採 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05（顯著），進行事後較

3.事後檢定使用 Scheffé 方法

4.因本研究使用 MSE 作為預測準確度判斷,MSE 越小代表越好

表 9-4 不同遞迴神經網路在特徵縮放方法預測準確度之差異分析表（一層）

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F	事後 檢定
StandardScaler	1.RNN	4	397.95	577.84	497.08	92.09	2.207	2.18	
	2.LSTM	4	203.18	669.32	382.84	208.53			
	3.GRU	4	235.72	395.08	293.24	73.89			
RobustScaler	1.RNN	4	157.29	496.52	296.92	146.15	1.02	0.92	
	2.LSTM	4	56.25	422.06	203.13	255.41			
	3.GRU	4	115.74	264.91	181.15	62.19			
MinMaxScaler	1.RNN	4	119.22	196.86	152.87	38.73	0.18	5.48 <sup>註3</sup>	3>1
	2.LSTM	4	183.26	286.04	227.53	48.41			
	3.GRU	4	225.14	341.21	261.53	54.03			

備註：

1.\*  $\alpha < 0.05$

2.組別不同質，改採 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05（顯著），進行事後較

3.事後檢定使用 Scheffé 方法

4.因本研究使用 MSE 作為預測準確度判斷,MSE 越小代表越好

表 9-5 不同特徵縮放方法在遞迴神經網路預測準確度之差異分析表（二層）

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F	事後 檢定
RNN	1.StandardScaler	16	343.73	1778.34	716.53	413.32	2.768	8.223 <sup>註3</sup>	1、2>3
	2.RobustScaler	16	98.09	1717.90	1013.88	515.12			
	3.MinMaxScaler	16	75.59	1167.00	656.47	271.46			
LSTM	1.StandardScaler	16	175.34	1414.47	607.08	352.81	11.273 <sup>*</sup>	15.898 <sup>註2</sup>	1>2、3
	2.RobustScaler	16	190.31	845.41	626.10	189.67			
	3.MinMaxScaler	16	223.84	990.11	423.65	175.23			
GRU	1.StandardScaler	16	108.91	547.55	267.08	159.20	2.038	4.304 <sup>註3</sup>	1>2、3
	2.RobustScaler	16	171.45	610.86	369.02	129.86			
	3.MinMaxScaler	16	279.28	1478.73	677.94	342.59			

備註：

1.\*  $\alpha < 0.05$

2.組別不同質，改採 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05（顯著），進行事後較

3.事後檢定使用 Scheffé 方法

4.因本研究使用 MSE 作為預測準確度判斷,MSE 越小代表越好

表 9-6 不同遞迴神經網路在特徵縮放方法預測準確度之差異分析表（二層）

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F	事後 檢定
StandardScaler	1.RNN	16	343.73	1778.34	716.53	413.32	2.22	3.45	
	2.LSTM	16	98.09	1717.90	1013.88	515.12			
	3.GRU	16	75.59	1167.00	656.47	271.46			
RobustScaler	1.RNN	16	175.34	1414.47	607.08	352.81	7.21*	3.13	
	2.LSTM	16	190.31	845.41	626.10	189.67			
	3.GRU	16	223.84	990.11	423.65	175.23			
MinMaxScaler	1.RNN	16	108.91	547.55	267.08	159.20	3.04	13.76 <sup>註2</sup>	3>2.1
	2.LSTM	16	171.45	610.86	369.02	129.86			
	3.GRU	16	279.28	1478.73	677.94	342.59			

備註：

1.\*  $\alpha < 0.05$

2 組別不同質，改採 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05（顯著），進行事後較

3.事後檢定使用 Scheffé 方法

4.因本研究使用 MSE 作為預測準確度判斷,MSE 越小代表越好



表 9-7 不同特徵縮放方法在遞迴神經網路預測準確度之差異分析表 (三層)

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F	事後檢定
RNN	1.StandardScaler	64	379.21	2797.21	1045.00	547.62	2.61	24.77 <sup>註3</sup>	1、2>3
	2.RobustScaler	64	221.15	2990.04	976.37	616.14			
	3.MinMaxScaler	64	85.18	2060.24	422.49	472.59			
LSTM	1.StandardScaler	64	103.55	2060.31	864.19	501.65	22.01 <sup>*</sup>	9.05 <sup>註2</sup>	2、1>3
	2.RobustScaler	64	97.87	2511.08	1001.49	547.96			
	3.MinMaxScaler	64	396.88	1278.84	669.09	199.92			
GRU	1.StandardScaler	64	114.15	1640.54	836.90	397.56	2.31	14.98 <sup>註3</sup>	1>2>3
	2.RobustScaler	64	47.41	1335.66	665.90	317.20			
	3.MinMaxScaler	64	118.73	2562.66	469.12	419.10			

備註：

1.\*  $\alpha < 0.05$

2 組別不同質，改採 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05 (顯著)，進行事後較

3.事後檢定使用 Scheffé 方法

4.因本研究使用 MSE 作為預測準確度判斷,MSE 越小代表越好

表 9-8 不同遞迴神經網路在特徵縮放方法預測準確度之差異分析表 (三層)

構面	變數	個數	最小值	最大值	平均數	標準差	Levene 統計量	F	事後 檢定
StandardScaler	1.RNN	64	379.21	2797.21	1045.00	547.62	2.85	3.46 <sup>*</sup>	
	2.LSTM	64	103.55	2060.31	864.19	501.65			
	3.GRU	64	114.15	1640.54	836.90	397.56			
RobustScaler	1.RNN	64	221.15	2990.04	976.37	616.14	7.05 <sup>*</sup>	8.595 <sup>註2</sup>	2、1>3
	2.LSTM	64	97.87	2511.08	1001.49	547.96			
	3.GRU	64	47.41	1335.66	665.90	317.20			
MinMaxScaler	1.RNN	64	85.18	2060.24	422.49	472.59	5.90 <sup>*</sup>	7.51 <sup>註3</sup>	2>3、1
	2.LSTM	64	396.88	1278.84	669.09	199.92			
	3.GRU	64	118.73	2562.66	469.12	419.10			

備註：

1.\*  $\alpha < 0.05$

2.組別不同質，改採 Brown-Forsythe 及 Welch 統計量之 p 值小於 0.05 (顯著)，進行事後較

3.事後檢定使用 Scheffé 方法

4.因本研究使用 MSE 作為預測準確度判斷,MSE 越小代表越好