

國立政治大學風險管理與保險學系研究所

碩士論文

利用深度學習圖形辨識技術建置最適投資策略  
- 以台灣股票市場為例

Applying the Stock Chart Pattern Recognition with Deep Learning  
to Construct the Optimal Investment Strategy in Taiwan

指導教授：黃泓智 博士

研究生：陳暉文 撰

中華民國一零八年七月

## 謝辭

轉眼之間，在政大六年的學生歲月終要畫下句點，回首過去，我從不後悔踏入了風管系，更不後悔選擇了精算這條路，在精算的這條路上，受惠於太多人的幫助，讓我一路走來都稱得上順遂。

最想感謝的絕對是一路指導過我的老師們，尤其是黃泓智老師。還記得當初大四的時候因緣際會認識了老師，也在老師的鼓勵下繼續了兩年風管所生涯，兩年來，老師無論是在課業、研究甚至職涯發展上，都給了我莫大的幫助。我很喜歡老師的帶領方式，給我明確的目標，卻也給我極大的發揮空間，在研究的生涯裡，我真的是樂在其中，辛苦但從不後悔。另外也十分感謝楊曉文老師以及王昭文老師，不僅撥空來當口試委員，更是在論文撰寫過程中給予了許多提醒與幫助。

兩年碩班生涯能如此順利，功臣絕對少不了身邊一起努力的同學以及給予幫助的學長姐們。感謝則臻陪我度過了大半碩班歲月，一起歡笑一起難過，最後再一起畢業；感謝惠郁總是不厭其煩的回答我問題，無論一些精算的方向或是後來共同合作的不少計畫，妳真的是個好學姐，更是個好朋友；感謝英豪在碩班兩年的 carry，跟你同組做事總覺得莫名的可靠，碩班生活多了你這個好朋友精采了不少，期待未來工作能繼續共事！最後很感謝鈞銓學長，從加入老師研究團隊以來，不厭其煩也完全不藏私的教了我很多，不但沒有學長的架子，反而很願意跟我們分享或是討論很多事情，能有這篇論文的產出，學長絕對功不可沒！

最後，想好好謝謝我最親愛的家人。謝謝爸爸媽媽從小到大的栽培，隨著自己逐漸懂事，才發現沒有什麼是理所當然，謝謝爸爸媽媽從小給了我如此好的環境與教育，如今學業終於到一個段落，希望兒子有成為你們的驕傲。

曄文 謹識於政大風管所

一百零八年七月

## 摘要

近年來，隨著電腦技術的革新，人工智慧在各領域皆有所突破。其中，圖像辨識可說是人工智慧運用的相當廣泛的一個領域，因此，本研究希望透過深度學習中圖像辨識相關技術，來預測股票線圖在未來的走勢，進一步選出預期報酬較高之股票作為投資組合。

本研究針對股票線圖一共進行兩階段處理，第一階段採用自動編碼器 (Autoencoder) 技術，訓練出可將股票蠟燭圖、成交量圖降維之模型；第二階段則使用多層感知機 (Multiple Perception Layer) 模型對降為後資料進行學習，預測未來股票報酬率，建置投資組合。

最後，本文透過實證分析，回測模型績效，回測期間從 2012 至 2019 共 8 年，回測結果平均年化報酬率達 22.69%，平均年化夏普比為 1.49，明顯優於台灣加權指數表現。

關鍵字：人工智慧、深度學習、自動編碼器、多層感知機、股票線圖、台股

## Abstract

In recent years, with the innovation of computer technology, artificial intelligence has made lots of breakthroughs in various fields. Among them, image recognition can be said to be a really successful one. Therefore, this paper hopes to predict the trend of stock charts through the image recognition skill in deep learning in order to construct the optimal portfolio.

This paper applies two models to predict stock charts. First, an AutoEncoder is used to reduce the candlesticks charts and volume charts from three dimensions to one dimension. We then take these 1D data as input to our second model - Multiple Layer Perception (MLP, supervised learning). We apply MLP model to predict stocks' future returns, thereby constructing the portfolio.

Finally, this paper evaluates the investment strategy through the empirical analysis. In conclusion, the strategy deliver an average annualized return of 22.69% and an average annualized Sharpe Ratio of 1.49, which all outperform than Taiwan Capitalization Weighted Stock Index (TAIEX).

Keywords: Artificial Intelligence、Deep Learning、AutoEncoder、Stock charts、Multiple Layer Perception.

# 目 錄

<b>第一章</b>	<b>緒論</b>	<b>8</b>
第一節	研究動機與研究背景	8
第二節	研究目的	9
第三節	研究流程	10
<b>第二章</b>	<b>文獻探討</b>	<b>11</b>
第一節	深度學習文獻探討	11
第二節	深度學習運用於股票之相關文獻探討	12
<b>第三章</b>	<b>研究方法</b>	<b>14</b>
第一節	資料庫建置	14
第二節	自動編碼器 (AutoEncdoer)	16
第三節	多層感知機 (Multiple Layer Perception)	20
第四節	交易策略建置與應用	25
第五節	績效指標說明	27
<b>第四章</b>	<b>實證結果分析</b>	<b>28</b>
第一節	實證分析樣本來源	28
第二節	固定持有期間績效分析	28
第三節	不固定持有期間績效分析	40
<b>第五章</b>	<b>結論與未來研究方向建議</b>	<b>43</b>
第一節	結論	43
第二節	未來研究方向建議	44
	<b>參考文獻</b>	<b>45</b>
	<b>附 錄</b>	<b>47</b>

## 表 目 錄

表 3-1、多層感知機參數整理	22
表 3-2、多層感知機模型訓練以及測試期間	23
表 3-3、固定持有期間投資組合示意（以固定持有 20 天為例）	25
表 4-1、各建構模型資料期間回測結果	29
表 4-2、各選定結果標準回測結果	31
表 4-3、各激活函數回測結果	33
表 4-4、各持有期間回測結果	34
表 4-5、交易成本對各投資組合之影響	35
表 4-6、各股票檔數回測結果	36
表 4-7、最佳模型回測結果比較表-固定持有期間	39
表 4-8、一般追蹤止損策略回測結果	42
表 4-9、進階追蹤止損策略回測結果	42
附錄 1、不同建構模型資料期間績效比較-各年度	47
附錄 2、不同選定最終結果標準績效比較-各年度	48
附錄 3、不同多層感知機激活函數績效比較-各年度	49
附錄 4、不同投資組合股票檔數績效比較-各年度	50

## 圖目錄

圖 1-1、研究架構	10
圖 2-1、歷年 ILSVRC 冠軍圖片辨識錯誤率	12
圖 3-1、股價蠟燭圖、股票成交量圖	14
圖 3-2、研究方法流程示意圖	15
圖 3-3、自動編碼器 (AutoEncoder) 架構	16
圖 3-4、VGG16 架構圖	17
圖 3-5、本論文所參考之 AutoEncoder 架構示意圖	18
圖 3-6、股價蠟燭圖形還原效果	18
圖 3-7、股價成交量圖形還原效果	19
圖 3-8、多層感知機架構圖	20
圖 3-9、一般追蹤止損示意圖	26
圖 4-1、各建構模型資料期間回測結果-各年度	30
圖 4-2、各選定結果標準回測結果-各年度	32
圖 4-3、各激活函數回測結果-各年度	33
圖 4-4、各股票檔數回測結果-各年度	37
圖 4-5、最佳模型累積報酬率比較-固定持有期間	39

# 第一章 緒論

## 第一節 研究動機與研究背景

### 一、深度學習

近十年來，隨著電腦技術的革新，人工智慧在各領域皆有所突破，包括 2016 年 AlphaGo 擊敗世界圍棋第一人柯潔，以及近期受到熱烈討論的無人車、無人飛機等等，皆是人工智慧的成果。

人工智慧的定義相當廣泛，只要是由人製造出來的機器所表現智慧，都可以稱得上人工智慧，因此無論簡單的計算機或是複雜的神經網絡，都屬於人工智慧範圍，而深度學習，亦是人工智慧的一環。深度學習在近年來的突破，成功讓人工智慧在各領域都有了重大的發展。

深度學習是由多層的神經網絡所構成，因此最早深度學習其實就是一種類神經網絡，是一個在 1980 年代即被提出的理論概念，但當時由於無法解決隨著神經網路層數的增加而產生梯度消失的問題，也導致效果不如其他演算法如 SVM<sup>1</sup>、隨機森林等，因此並不受到重視。直到 2006 年，Geoffrey Hinton 提出了「限制玻爾茲曼機模型」，成功訓練多層神經網路，才讓類神經網路又再次被重視，而 Geoffrey Hinton 也重新將多層的神經網絡命名為深度學習。

雖然成功訓練了深度學習的模型，但在當時深度學習仍存在著巨大的挑戰，尤其是硬體運算能力方面，當時電腦皆是採用 CPU，導致模型訓練的速度極慢，因此深度學習仍然未被重視。直到後來 NVIDIA 推出 GPU，並推出全新運算架構 CUDA，才真正讓深度學習得以大紅大紫。2012 年 10 月，Geoffrey Hinton 的兩位學生就是利用深度學習搭配 GPU 的組合，在史丹佛大學舉辦的 ImageNet 圖

---

<sup>1</sup> 支援向量機 (Support Vector Machine)，是在分類與迴歸分析中分析資料的監督式學習模型與相關的學習演算法。



像識別競賽中，以 16.42% 的錯誤率遠勝第二名的 26.22%，從此，深度學習一躍成為學界業界最火熱研究的技術之一。

## 二、股票型態學

股票市場為一複雜又難以預測的交易環境，影響股價變動的因素相當多，包含基本面、技術面、籌碼面、消息面等等。其中，技術面之分析方法，多是從過去的歷史資料中，以「價」與「量」為基礎，透過圖像化或是量化的方式進行分析。

圖像化的研究方式從 19 世紀後期 Charles Henry Dow 開始，後人將其思想整理成道氏理論，成為了所有市場技術研究的鼻祖，爾後相關理論與分析方法包括艾略特波浪理論、K 線分析及股價排列型態分析等等，都是使用圖像化的方式，時至今日，眾多股市名嘴仍採用股票型態學做為預測市場走勢之依據。

### 第二節 研究目的

有鑑於深度學習技術在近年來的大幅進步，以及在圖像辨識能力上的成功發展，搭配股票型態學長久以來的歷史，本論文期待透過兩者的結合，創造超越大盤的投資組合。

### 第三節 研究流程

確認研究目標後，本論文使用過去 10 年台灣上市、上櫃股票之蠟燭圖及成交由量圖進行深度學習，並從實證結果提出未來研究方向與建議。本論文共分成五個章節，詳細如下：

#### 一、緒論

針對本論文以股票線圖建構深度學習模型的研究動機、目的以及研究流程進行敘述。

#### 二、文獻探討

回顧過去相關文獻並進行統整，包括深度學習模型、股票線圖研究、以及結合兩者之相關研究。希望參考其他學者之研究方法與結果，汲取經驗並找出最適合且具有突破性的研究方法。

#### 三、研究方法

說明本論文之深度學習模型建立過程，以及各參數設定方法，並介紹如何使用建立之模型產生最適投資策略。

#### 四、實證結果

說明模型訓練結果，以及根據台灣經濟新報（TEJ）之股價資料進行投資策略實證分析，並說明及解釋研究成果。

#### 五、結論與未來研究方向

針對本論文之實證結果進行統整，並對未來研究方向給予建議。

本論文之架構圖如下：



圖 1-1、研究架構

## 第二章 文獻探討

本論文運用深度學習技術，預測股票線圖未來走勢，並建立最佳投資策略。本章節將分為兩部分，第一部分為回顧深度學習相關文獻，第二部分則整理過去將深度學習運用於股票線圖之研究，希望汲取過去經驗並訂定本論文之研究方法與目標。

### 第一節 深度學習文獻探討

深度學習一詞最早可追溯至 1950 年代的人工智慧，然而由於當時硬體效能低落與數據量不足的限制，難以在實務上有所運用。Hubel and Weisel (1981) [8] 對於動物視覺系統的處理信息方式有了進一步的發現，也讓科學家們對「模擬人類大腦的運算模型」抱持了高度期待，然而，傳統的類神經網路無法突破多層數的問題，使得學界始終未重視這塊領域。

Hinton, Osindero and Yee (2006) [6] 等人提出限制玻爾茲曼機和深度信念網路兩個概念，成功訓練了多層神經網路，並將其命名為「深度學習 (Deep Learning)」，但此時深度學習仍受限於 CPU 處理器的運算緩慢，在實務運作上仍有難度。Krizhevsky, Sutskever and Hinton (2012) [9] 以深度學習加上 GPU 運算的組合在每年史丹佛大學以 ImageNet 影像資料庫所舉辦的圖片識別競賽 (ImageNet Large Scale Visual Recognition Challenge, ILSVRC) 中一戰成名，從此，深度學習受到學界的重視，開啟了往後深度學習的研究熱潮。

爾後，相當多研究將深度學習運用於圖形視覺技術中。在圖片分類方面，從 Hinton 的兩名學生所提出的 CNN 模型 AlexNet 在 2012 年 ILSVRC 大賽中，將錯誤率大幅降低至 16.42% 後，Szegedy et al. (2014)<sup>2</sup>[14] 與 He et al. (2015)<sup>3</sup>[5] 也分別在 2014 年與 2015 年提出 GoogLeNet 以及 ResNet，成功將錯誤率下降至

---

<sup>2</sup> Google 團隊

<sup>3</sup> Microsoft 團隊

6.7%、3.57%，甚至低於人類辨識錯誤率 5%（如圖 2-1 所示）。另外在人臉辨識部分，Ranjan, Patel and Chellappa（2017）[12]等人使用 CNN 架構為基礎的演算法，能夠精確的偵測出臉部標誌、性別等資訊，也在近日被廣泛運用在各領域中。

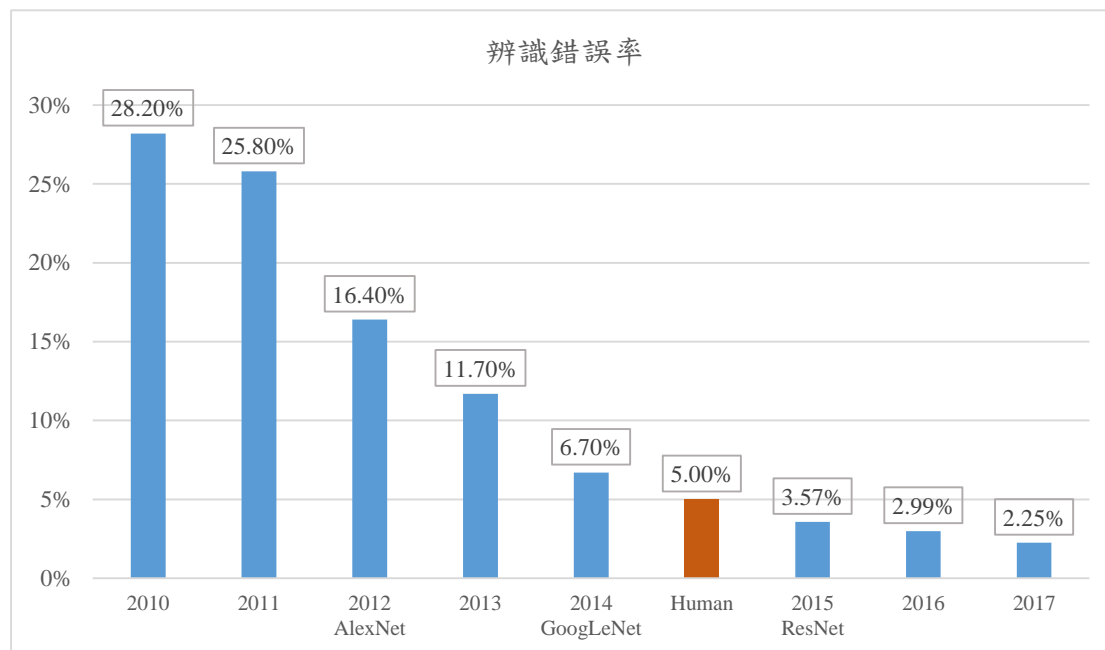


圖 2-1、歷年 ILSVRC 冠軍圖片辨識錯誤率

## 第二節 深度學習運用於股票之相關文獻探討

股票市場一直被認為是十分難以預測的，Fama（1998）[3]認為這是由於市場資訊不完全透明以及存在不理性的投資人導致。也因此，在深度學習蓬勃發展的同時，也有相當多學者將此技術運用至股票市場，希望發展出更好的策略。

Takeuchi and Lee（2013）[15]使用自動編碼器(Autoencoder)來萃取股票價格的特徵，並用來強化動量交易策略<sup>4</sup>，成功使報酬率提高了4.5倍之多。Ding, Zhang, Liu and Duan（2015）[2]等人則使用 CNN 模型預測在重大事件發生後的股價走勢，最後在 S&P 500 的預測準確度上有了 6%的進步。Fischer and Krauss(2017)

<sup>4</sup> 動量交易策略，即預先對股票收益和交易量設定過濾準則，當股票收益或股票收益和交易量同時滿足過濾準則就買入或賣出股票的投資策略。參考自 MBA 智庫百科：<https://wiki.mbalib.com/zh-tw/動量交易策略>。最後更新日期：2019-06-28

[4]則利用長短記憶模型 (Long short-term memory networks, LSTM)，預測 S&P 500 成分股漲跌，並挑選股票建立投資組合，實證結果發現 LSTM 模型比深度神經網絡(Deep Neural Net, DNN)，以及淺層學習如隨機森林(Random Forest, RF)、羅吉斯回歸(Logistic Regression, LOG)，無論在報酬率、標準差、夏普比(Sharpe Ratio)以及準確率上都有較好的表現。

深度學習在圖像辨識上的應用一直都是學術界所努力的議題，Lecun, Bottou, Bengio and Haffner (1998) [10]即提出了卷積神經網絡 (Convolution Neural Network, CNN)，此模型自提出以來被廣泛運用在各種圖像辨識中，獲得極大的成功。Masci, Meier, Cireşan and Schmidhuber (2011) [11]則將自動編碼器技術與卷積神經網絡做結合，提出 Convolution AutoEncoder (CAE) 的模型。因此，除了使用股價或其他股價衍生出的量化指標作為參數建立模型，過去也有許多學者將深度學習應用到股票圖形上。Chen and Chen (2016) [1]使用感知特徵點擷取法(Perceptually Important Point, PIP)以及模板匹配理論(Template Matching Theory)去定義牛市的圖形(Bull-flag Pattern)，並成功在實證中獲得良好的績效。Hu et al. (2018) [7]則針對股票蠟燭圖<sup>5</sup>，利用自動編碼器(AutoEncoder)技術，去萃取圖片特徵，將三維的圖片降維至 1\*512 的單位矩陣後，再進行分群，並再各群中選取夏普比最好之股票組成投資組合，實證結果發現其投資組合穩定度佳且風險低，進一步與富時 100 (FTSE100)以及許多著名基金，如 CCA、VXX、IEO、PXE、PXI 等比較，都有著較好的表現。

---

<sup>5</sup> 圖片包含開盤價 (O)、最高價 (H)、最低價 (L)、收盤價 (C) 等四維資料

### 第三章 研究方法

本章介紹本研究論文之研究方法，本論文使用股價蠟燭圖以及成交量圖作為建模資料，接下來使用自動編碼器 (Autoencoder) 技術，訓練出可將股票蠟燭圖、成交量圖降維之模型，接著將降維後資料作為多層感知機 (Multiple Perception Layer) 模型之輸入層，進一步預測未來股票報酬率，流程示意如圖 3-2。

#### 第一節 資料庫建置

本論文使用台灣上市及上櫃股票之股價及成交量進行繪圖建置資料庫，每張圖共包含 20 天之資料。股價部分根據該股票當日之開盤價、最高價、收盤價、最低價繪製蠟燭圖<sup>6</sup>；成交量部分則依據當日買超或賣超量繪製成交量圖<sup>7</sup>。資料庫包含 2009 年 1 月 1 日起至 2018 年 12 月 31 日止共十年 2,519 個交易日，蠟燭圖與成交量圖各 2,264,580 張，共 5,329,160 張圖。



圖 3-1、股價蠟燭圖、股票成交量圖

<sup>6</sup> 若當日股票收盤價高於開盤價，則蠟燭為紅色，反之則為綠色。

<sup>7</sup> 若當日為買超（買入量大於賣出量）則成交量為紅色，反之則為綠色。

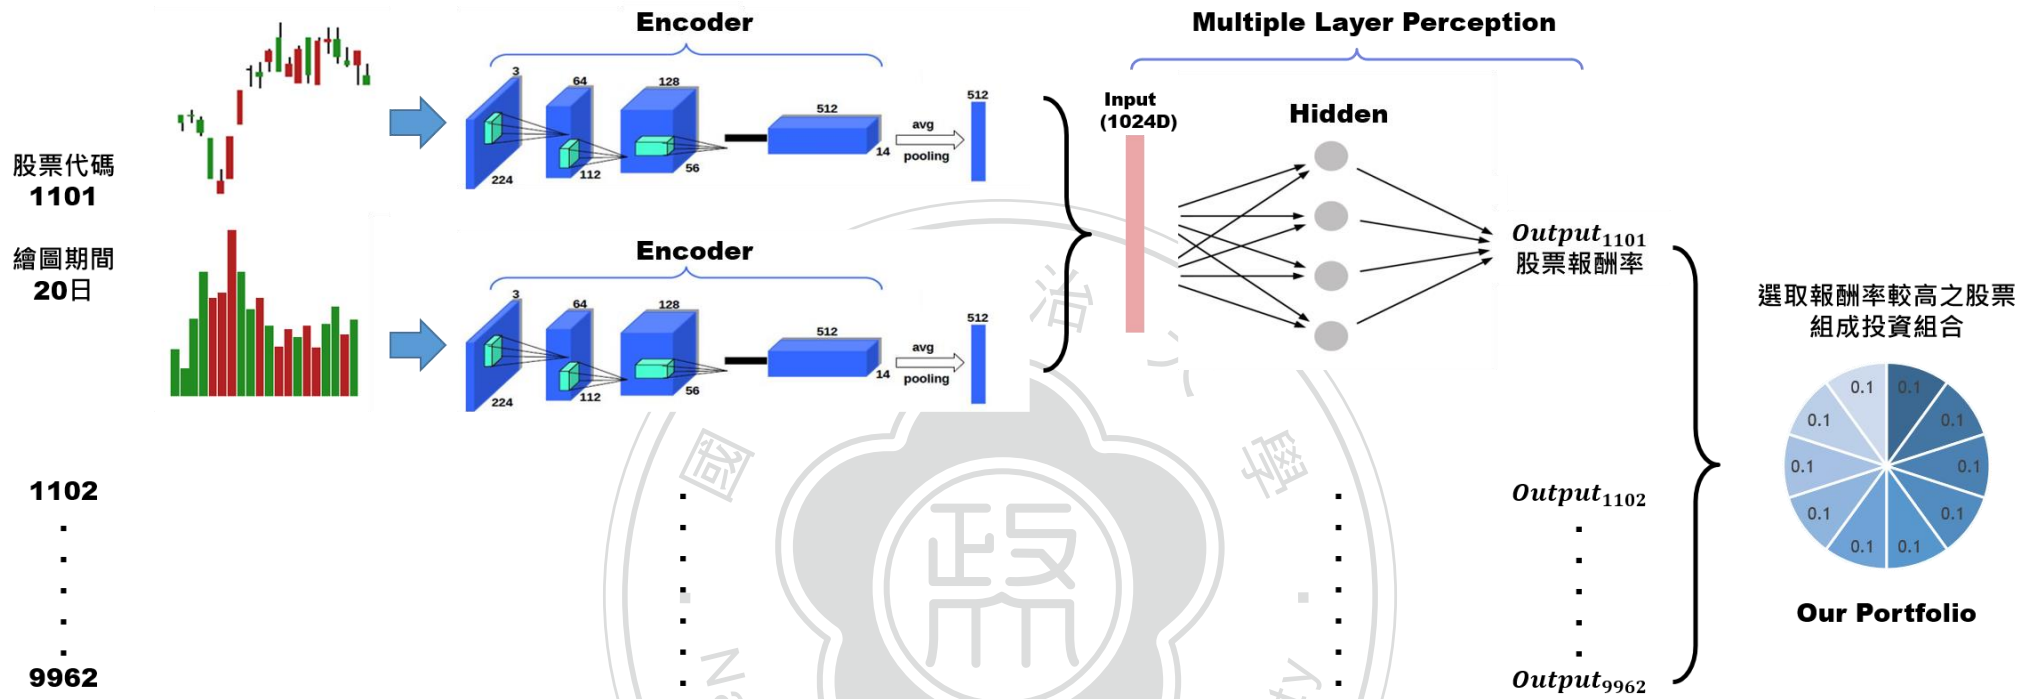


圖 3-2、研究方法流程圖

## 第二節 自動編碼器 (AutoEncoder)

### 一、自動編碼器簡介

自動編碼器 (AutoEncoder, 以下簡稱 AE) 演算法屬於一種非監督式學習的神經網絡 (Neural Network), 其目的是希望透過學習, 以隱藏層中較少的神經元, 去產生與輸入層相同的輸出, 藉此可以降低資料維度, 以及達到特徵萃取 (Feature Extraction) 的效果。

AE 中主要包含編碼器 (Encoder) 以及解碼器 (Decoder) 兩個部分, 如下圖 3-3 所示, 編碼器將輸入層資料壓縮, 使資料以較低的維度呈現, 而 Decoder 網絡可以看做 Encoder 網絡的反射, 再將低維度的資料進行還原。在訓練的過程中, AE 會試著找出最好的權重, 讓資料可以盡量完整還原回去, 也就是讓輸出層盡量等於輸入層, 而一般損失函數則是以輸入和輸出的熵數距離 (Entropy Distance) 來表示。最終, 若輸入數據可以透過自動編碼器模型還原成輸出數據, 且誤差不大, 我們即可以擷取其中 Encoder 部分, 作為資料降維之模型。




圖 3-3、自動編碼器 (AutoEncoder) 架構<sup>8</sup>

<sup>8</sup> Arden Dertat (2017). Applied Deep Learning - Part 3: Autoencoders. <https://towardsdatascience.com/applied-deep-learning-part-3-autoencoders-1c083af4d798>.  
最後更新日期: 2019-06-28



Simonyan and Zisserman (2014) 提出 VGG16 架構，如圖 3-4 所示，其最重要的概念是使用大量  $3 \times 3$  的卷積層，作者認為將較大的卷積層抽換成較小的卷積層可讓資訊量提高，此外，使用較多的較小的卷積層亦可以提高非線性程度，VGG16 成功將預測 ImageNet 資料庫的錯誤率降低至 7.3%，可說是一個十分成功的圖像辨識模型。




圖 3-4、VGG16 架構圖<sup>9</sup>

## 二、本論文建模流程

本文採用 2009 年共張圖，分別就蠟燭圖、成交量圖訓練自動編碼器模型。在 AE 模型中的 Encoder 部分，本論文參考 Hu et al. (2018)，使用預訓練好的 VGG16 網絡，但將最後 4096D 的全連結層 (Fully Connected Layer) 拿掉改使用平均池化層 (Average Pooling Layer) 來製造一個 512D 的矩陣；在 Decoder 的部分，則是使用了七層反卷積網絡 (Deconvolution Network)，將 512D 的矩陣還原至原先輸入層  $224 \times 224 \times 3$  的維度，完整的 AE 模型如圖 3-5 所示。

在模型參數部分，本論文模型 batch size 採用 128，學習速率 (Learning Rate) 則使用 0.1。

<sup>9</sup> Muneeb ul Hassan(2018). VGG16–Convolutional Network for Classification and Detection. <https://neurohive.io/en/popular-networks/vgg16/>. 最後更新日期：2019-06-28

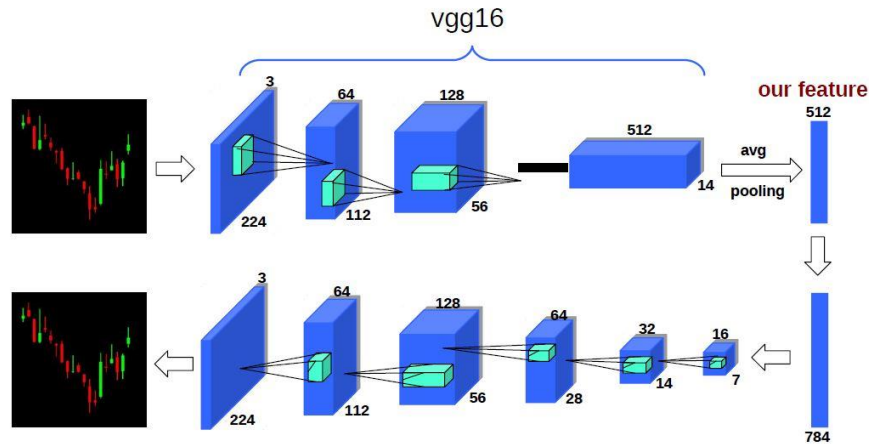


圖 3-5、本論文所參考之 AutoEncoder 架構示意圖

蠟燭圖與成交量圖的自動編碼器模型分別訓練完成後，未來（2009 年後）圖形，皆採用模型進行降維，每一張圖皆可以對應得到一個由蠟燭圖與成交量圖組成的 1024D 矩陣。

以下將分別呈現蠟燭圖以及成交量圖在輸入自動編碼器前之原圖（圖 3-6、圖 3-7），以及還原後之圖形以做比較，從左至右學習次數逐漸增加，可以明顯發現還原後圖形與原圖有愈來愈相似的趨勢。

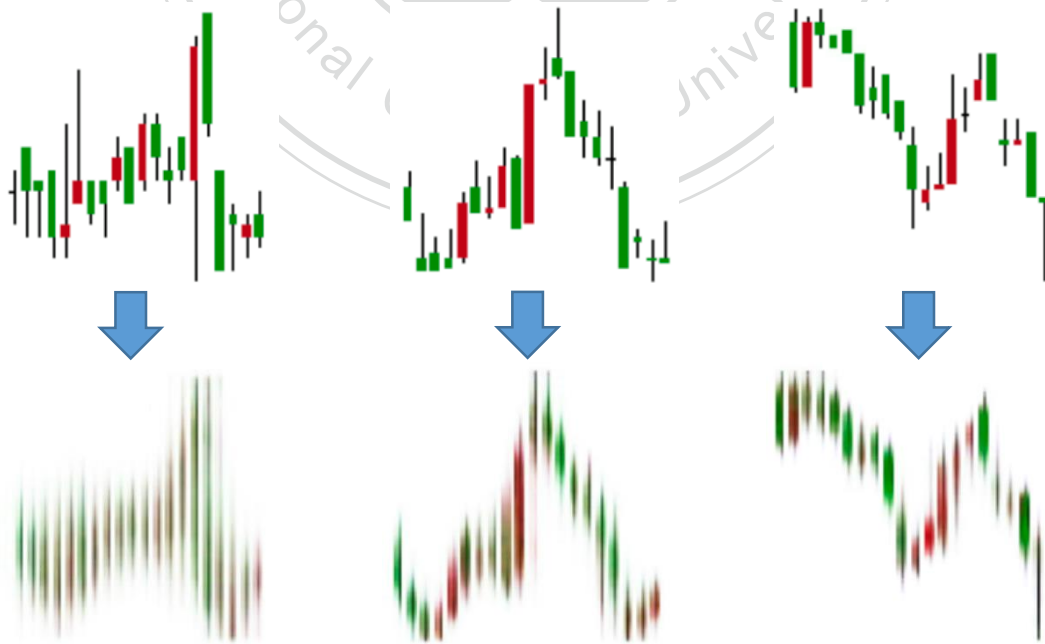


圖 3-6、股價蠟燭圖形還原效果

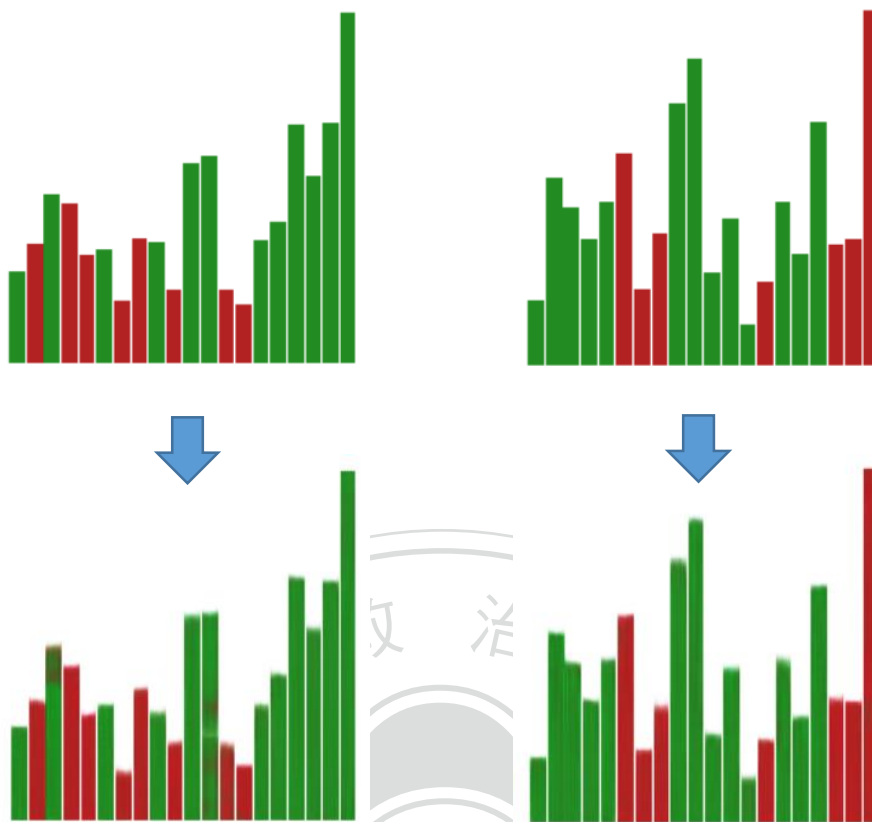


圖 3-7、股價成交量圖形還原效果

### 第三節 多層感知機 (Multiple Layer Perception)

#### 一、多層感知機簡介

多層感知機 (Multiple Layer Perception) 模型屬於神經網絡的一種，其結構包含了輸入層 (Input Layer)、隱藏層 (Hidden Layer) 與輸出層 (Output Layer)，其中，隱藏層數目可從一層至多層不等。

資料從輸入層輸入後，每經過一個節點<sup>10</sup>時，都會通過一個激勵函數 (Activation Function)，針對接收到的輸入，根據權重(w)計算其輸出值，其架構圖如圖 3-8 所示：

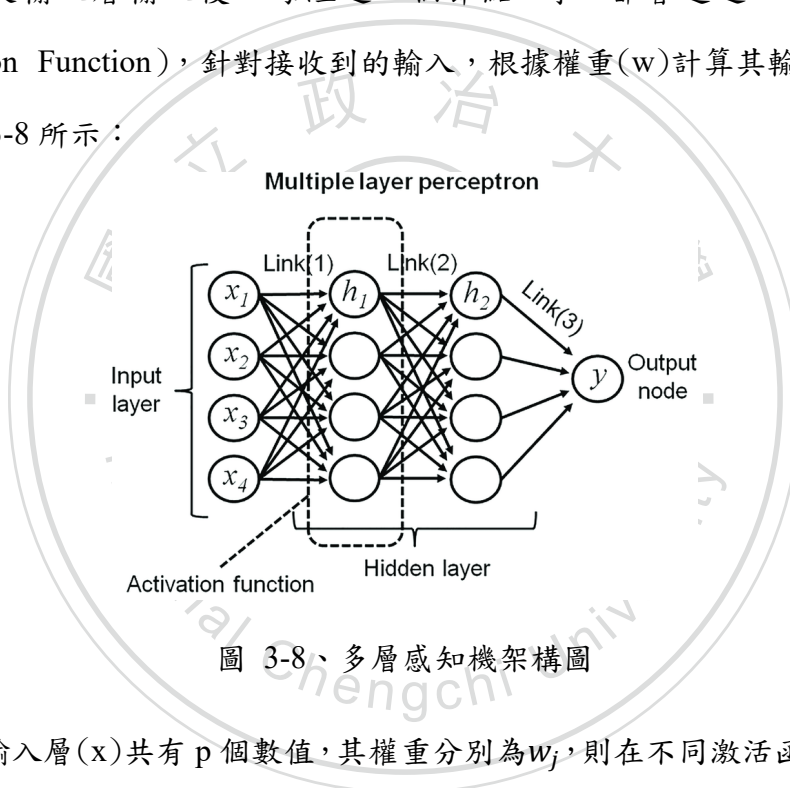


圖 3-8、多層感知機架構圖

假設輸入層(x)共有  $p$  個數值，其權重分別為  $w_j$ ，則在不同激活函數  $f(x)$  下，輸出  $Y$  可表達為：

$$Y = f\left(\sum_{k=0}^p w_{kj}x_k\right)$$

<sup>10</sup> 節點 (unit) 是神經網絡中計算的基本單元，節點會從其他節點 (或外部資訊) 接收輸入，然後根據權重計算後進行輸出

多層感知機常見激活函數包含 Sigmoid、tanh、ReLU 等，其公式分別如下：

$$f(x) = \begin{cases} \frac{1}{(1 + e^{-x})} ,if \text{ activation function} = \text{Sigmoid} \\ \frac{(e^x - e^{-x})}{(e^x + e^{-x})} ,if \text{ activation function} = \text{tanh} \\ \max(0, x) ,if \text{ activation function} = \text{ReLU} \end{cases}$$

在多層感知機中，隱藏層的設置是用來增加網絡複雜度以及解決各變數間非線性的關聯性，但過度的增加隱藏層亦可能導致模型過適(Over-fitting)的問題，因此隱藏層的數目並無固定的單一解可供參考。

## 二、本論文建模流程

本論文透過前一節所提到的自動編碼器模型，將股票蠟燭圖、成交量圖分別降維成 512D 的單位矩陣，再分別對矩陣進行標準化，作為多層感知機模型的輸入層，隱藏層則設置三層，輸出層則使用未來十天及二十天的報酬率分別測試。

另外在激活函數部分，本論文原欲採用 ReLU 函數，但實際使用後發現在學習時，會有過多神經元「死亡<sup>11</sup>」，因此本論文改採用 ReLU 的變形函數 LeakyReLU 以及 ELU 作為隱藏層以及輸入層的激活函數，得到不錯的效果，輸出層則採用 Linear 函數，LeakyReLU 與 ELU 的公式分別如下：

$$\text{LeakyReLU} : f(x) = \max(\alpha x, x), \alpha \in (0,1)$$

$$\text{ELU} : f(x) = \begin{cases} \alpha(e^{-x} - 1), x < 0 \\ x, x \geq 0 \end{cases}$$

<sup>11</sup> 當一個較大的梯度通過 ReLU 神經元，可能造成這個神經元再也不會對任何數據有激活現象，使這個神經元的梯度永遠為 0

損失函數部分本論文使用均方誤差(MSE)作為標準；優化函數(Optimizer)使用 Adam；回調函數(Callback)則使用包括 Earlystopping 以及 ReduceLRonPlateau, Batch size 為 2 的 13 次方, 最後, 由於深度學習中隨機性的原因, 每次結果可能不盡相同, 因此, 本文加入交叉驗證(Cross Validation)的方法來增加模型穩定性, 詳細參數設定整理如下表:

表 3-1、多層感知機參數整理

函數(參數設定)	使用函數(參數)	備註
激活函數	ELU, LeakyReLU and Linear	輸入層以及隱藏層採 ELU 與 LeakyReLU, 輸出層則使用 Linear
損失函數	MSE	無
優化函數	Adam	Beta1=0.9, Beta2=0.999, epsilon= $10^{-8}$
回調函數	Earlystopping, ReduceLRonPlateau	在 Earlystopping 部分, 使用 Val_loss 作為監控指標, 最大容忍值設 10 個 epoch; 在 ReduceLRonPlateau 部分, 同樣使用 Val_loss 作為監控指標, 若 5 個 epoch 無下降, 則將 learning_rate 下降為 0.1 倍。
Batch size	$2^{13}$	無
K-fold 交叉驗證	K=5	無。

### 三、模型資料整理

本論文分別採用移動視窗法(Rolling Window)以及定錨式移動式窗法(Anchored Rolling Window), 取測試年份前一年、兩年以及所有歷史資料作為訓練集, 因此, 除 2009 年資料用於自動編碼器模型訓練, 訓練集資料將從 2010

年開始，而測試集資料則從 2012 年開始<sup>12</sup>，詳細訓練期間以及測試期間整理如下表：

表 3-2、多層感知機模型訓練以及測試期間

模型編號	訓練期間			測試期間
	一年	兩年	所有歷史資料	
1	2011/1/1 } 2011/12/31	2010/1/1 } 2011/12/31	2010/1/1 } 2011/12/31	2012/1/1 } 2012/12/31
2	2012/1/1 } 2012/12/31	2011/1/1 } 2012/12/31	2010/1/1 } 2012/12/31	2013/1/1 } 2013/12/31
⋮	⋮	⋮	⋮	⋮
7	2017/1/1 } 2017/12/31	2016/1/1 } 2017/12/31	2010/1/1 } 2017/12/31	2018/1/1 } 2018/12/31

值得一提的是，使用定錨式移動式窗法時，在後面幾期模型由於資料量過大，因此本論文先行固定訓練資料量<sup>13</sup>，再從過去訓練期間中隨機抽樣此數目之資料進行訓練建立模型。

#### ■ 訓練集資料

首先，將訓練期間所有股票對應之圖形，利用前一節所述之自動編碼器模型進行降維，蠟燭圖與成交量圖分別降維至 512D 的單位矩陣後，再分別進行標準化，標準化方式如下：

$$x_i' = \frac{x_i - \min(x)}{\max(x) - \min(x)}, \quad i = 1, 2, \dots, 512$$

<sup>12</sup> 為方便比較，所有回測期間皆從 2012 年開始

<sup>13</sup> 本論文使用 50 萬筆資料作為每次建立模型之資料量

其中， $x_i$ 代表各變數之原始數值， $\min(x)$ 代表該變數之最小值， $\max(x)$ 代表該變數之最大值， $x_i'$ 代表各變數標準化後之數值。

每一筆訓練資料需有一筆對應的數值結果，本論文分別採用十日、二十日後同一檔的股票之報酬率<sup>14</sup>作為衡量指標，另外，本論文亦針對報酬率做了數值調整，如下所示，其中  $y_i$ 為調整前數值， $y_i'$ 為調整後數值，其公式如下：

$$y_i' = \text{sign}(\sqrt{|y_i|})$$

整理完訓練期間之所有資料與對應之結果後，本論文採取 K-Fold 交叉驗證 (K-Fold Cross Validation) 的方法，將資料隨機分成五組，每次訓練模型採用其中四組作為訓練集 (Training Set)，另外一組做為驗證集 (Validation Set)，總共訓練五次，除了確保每筆資料皆被訓練到，亦透過增加訓練次數來降低深度學習中隨機性，使最終結果較為穩定。

#### ■ 測試集資料

首先，同測試集資料，先使用自動編碼器模型將資料降維，接著將資料標準化，公式同訓練集，值得注意的是，這邊標準化所使用的最大值與最小值，應採用訓練集中同一變數的最大值與最小值，才能與模型匹配使用同一標準來預測。最後，如上所說，本論文採取交叉驗證的方法，同一筆測試資料共會使用五個模型分別預測，最終再取五次預測結果之平均數或中位數作為最終預測結果。

---

<sup>14</sup> 本論文報酬率皆使用收盤價作為判斷指標



## 第四節 交易策略建置與應用

### 一、固定持有期間

前一節介紹多層感知機模型，去預測交易日之股票圖形，在未來固定期間(10日、20日)預期之漲跌，因此，本節所首先建立之交易策略，即固定投資組合持有期間，在第一個交易日買入股票，直到預測期滿(10日、20日)前不再做任何交易，而期滿當日，則無論投資組合中股票漲跌全數賣出，再次運用多層感知機模型選入全新的投資組合。

表 3-3、固定持有期間投資組合示意(以固定持有 20 天為例)

買入日期	賣出日期	選入股票	每檔股票權重
2012/01/02	2012/02/06	1216、1219、1220、1909、2303 2883、3332、4527、5519、8261	0.1
2012/02/06	2012/03/05	1315、2373、2376、2908、4513 5519、5533、6161、6292、9914	0.1
⋮	⋮	⋮	0.1

### 二、不固定持有期間

有鑑於前一段落使用固定持有期間(全買全賣)較不符合一般投資人對於股票之操作模式，因此，本文另外嘗試使用「追蹤止損」的機制來使持有期間不固定。其概念為當股價持續上漲時，選擇繼續持有該檔股票，而一旦股價下跌至止損標準以下，則賣出該檔股票，同時在當日利用多層感知機模型選入新股票。

本研究止損標準的設置分為兩階段，第一階段為單純的追蹤止損，將止損標準設為自買入該檔股票後最高價之一定比例。假設在第一天買入某檔股票，其價格為 100 元，止損比例( $S$ )為 10%，則此時的止損價格為 90 元，之後股價上漲

時指損標準即會隨之提高，如第二天由於股價上漲至 115 元，則新的止損標準即隨之提高至  $115 \times 0.9 = 103.5$  元，最終當股票價格低於止損標準時則選擇賣出股票，如圖 3-9 所示。




圖 3-9、一般追蹤止損示意圖

第一階段的追蹤止損機制雖然實現了止損的概念，但當止損標準較大時，可能產生股價持續在同一區間震盪，長期下來並未達到止損標準，但也未實現資本利得，造成資金浪費，因此，本研究在第二階段定義了新的止損比例 ( $S'$ )，其定義如下：

$$S' = \min(\text{MDD}(N), S)$$

$$\text{MDD}(N) = \frac{\max(\text{過去 } N \text{ 天股價}) - \min(\text{過去 } N \text{ 天股價})}{N \text{ 天前股價}}$$

如此一來，若股價持續在同一區間震盪，則  $\text{MDD}(N)$  將會變小，也就是股票出場標準變得較為嚴格，即可避免股價長期在同一區間震盪之問題。假設第一天買入某檔股票，其價格為 100 元，止損比例 ( $S$ ) 為 10%，忍受期間 ( $N$ ) 為 20 日，則該股票若在接下來一個月都在 98 元至 102 元間震盪，則新的止損比例 ( $S'$ ) 將會調整  $\min\left(\frac{102-98}{100}, 10\%\right) = 4\%$ ，較原先 10% 嚴格。

## 第五節 績效指標說明

### 一、累積報酬率

$$\text{累積報酬率} = \frac{\text{期末帳戶累積金額}}{\text{期初帳戶原始金額}}$$

### 二、年化報酬率

$$\text{年化報酬率} = \left( \frac{\text{期末帳戶累積金額}}{\text{期初帳戶原始金額}} \right)^{\frac{252}{\text{經過總日數}}} - 1$$

### 三、年化標準差

$$\text{年化報酬率標準差} = \sqrt{\frac{\sum (\text{當日帳戶金額成長率} - \text{平均帳戶金額成長率})^2}{\text{經過總日數} - 1}} \times \sqrt{252}$$

### 四、年化夏普比

$$\text{年化夏普比率} = \frac{\text{年化報酬率} - \text{年化無風險利率}^{15}}{\text{年化報酬率標準差}}$$

### 五、最大回撤率

$$\text{最大回撤率}_t = \min \left( \frac{\text{第 } t \text{ 天帳戶價值} - \text{第 } i \text{ 天帳戶價值}}{\text{第 } i \text{ 天帳戶價值}} \right)$$

$$\begin{cases} t = 1, 2, \dots, \text{投資期間天數} \\ i = 1, 2, \dots, t-1 \text{ (投資第一天至投資第 } t-1 \text{ 天)} \end{cases}$$

### 六、平均月周轉率

$$\text{月周轉率} = \frac{\min(\text{當月買入金額}, \text{當月賣出金額})}{\frac{\text{期初資產淨值} + \text{期末資產淨值}}{2}}$$

<sup>15</sup> 年化無風險利率以 1.04% 為基準，參考自台灣五大銀行「台灣銀行、合作金庫銀行、第一銀行、華南銀行及台灣土地銀行」平均一年期定存利率。

## 第四章 實證結果分析

### 第一節 實證分析樣本來源

本論文實證分析樣本取自台灣經濟新報 (TEJ)，期間為 2009 年 1 月 1 日起至 2018 年 12 月 31 日止 10 年共 2,519 個交易日，其中包括台灣上市上櫃股票共 1,854 家公司總計 3,782,235 筆資料。在計算報酬率時，本論文同時加入交易成本讓結果更貼近現實，在買入與賣出時，皆須支付券商交易總額之 1.425% 作為手續費，而賣出股票時，需另外支付交易總額 3% 之證券交易稅。

### 第二節 固定持有期間績效分析

首先，本節將固定股票持有期間，也就是說，一旦多層感知機模型的  $y$  選定為股票未來 (10、20) 天後之漲跌，就會持有該投資組合至 (10、20) 天期滿，並在該日更新整個投資組合，重新選入固定數目之股票數，並進行等權重配置，詳細示意表格可參見表 3-3。

同時，本節也將透過實證分析，分別測試各項可調整變因，去建構最佳多層感知機模型，可調整變因列點如下：

1. 建構模型資料期間：一年、兩年、過去所有資料。
2. 交叉驗證後選定最終結果方法：中位數、平均數。
3. 多層感知機模型中激活函數：ELU、LeakyReLU。
4. 投資組合持有期間：10 日、20 日。
5. 投資組合一次應選入多少股票：5 檔、10 檔、20 檔。

本文將依上列順序，透過回測的方式來尋找最佳組合，為了測試方便，本文在做第一點測試時，先固定變因如下：選定最終結果方法：中位數；激活函數：ELU；投資組合持有期間：20 日；投資組合一次選入股票：10 檔。

## 一、建構模型資料期間

在使用深度學習模型時，大多實證會發現資料量越多可以讓模型訓練的越好越完整，但也有人提出無謂的增加資料量亦可能導致模型中「雜訊」的增加，因此，本文希望透過實證的方式，來驗證使用過去一年、兩年以及過去所有資料做為訓練集，是否對模型的預測能力與實證的績效帶來影響。

由於深度學習中隨機性的原因，每次結果可能不盡相同，因此，本文針對不同期間分別進行 5 次試驗，比較其年化報酬率 ( $\mu$ )、年化標準差 ( $\sigma$ )、以及年化夏普比率 (S)。

從回測結果 (表 4-1) 可以發現，隨著使用資料量增加、期間拉長，年化報酬率有逐漸上升的趨勢，而標準差則有逐步下降的趨勢，導致年化夏普比率有了顯著的增幅，使用過去一年資料回測的夏普比率為 0.99，而使用過去所有資料則為 1.49。

表 4-1、各建構模型資料期間回測結果

	一年資料			兩年資料			所有資料		
	$\mu$	$\sigma$	S	$\mu$	$\sigma$	S	$\mu$	$\sigma$	S
試驗 1	19.80	16.27	1.13	22.25	14.05	1.43	23.11	13.29	1.55
試驗 2	15.84	16.01	0.93	16.66	15.13	1.03	23.09	13.29	1.42
試驗 3	15.82	14.25	1.03	23.62	14.43	1.47	23.85	14.68	1.56
試驗 4	13.86	13.78	0.94	20.54	14.56	1.28	21.04	13.66	1.45
試驗 5	14.83	15.27	0.91	17.89	13.88	1.18	22.35	12.99	1.47
平均	<b>16.03</b>	<b>15.12</b>	<b>0.99</b>	<b>20.19</b>	<b>14.41</b>	<b>1.28</b>	<b>22.69</b>	<b>13.65</b>	<b>1.49</b>

註： $\mu$ 代表年化報酬率， $\sigma$ 代表年化標準差，S代表年化夏普比。

接著，本文進一步將每年度報酬率、標準差以及夏普比率整理比較(圖 4-1)。從年化報酬率來看，訓練資料期間較短，雖然可以在多頭期間<sup>16</sup>獲得不錯的報酬，但在空頭期間<sup>17</sup>則會有明顯的虧損，而訓練資料期間較長，則是可以在每一年度皆獲得穩定的報酬，即使處於空頭，也可讓損失降低，甚至有些許獲利；再來從年化標準差的角度切入，可以發現隨著訓練資料期間拉長，標準差有逐漸下降的趨勢。

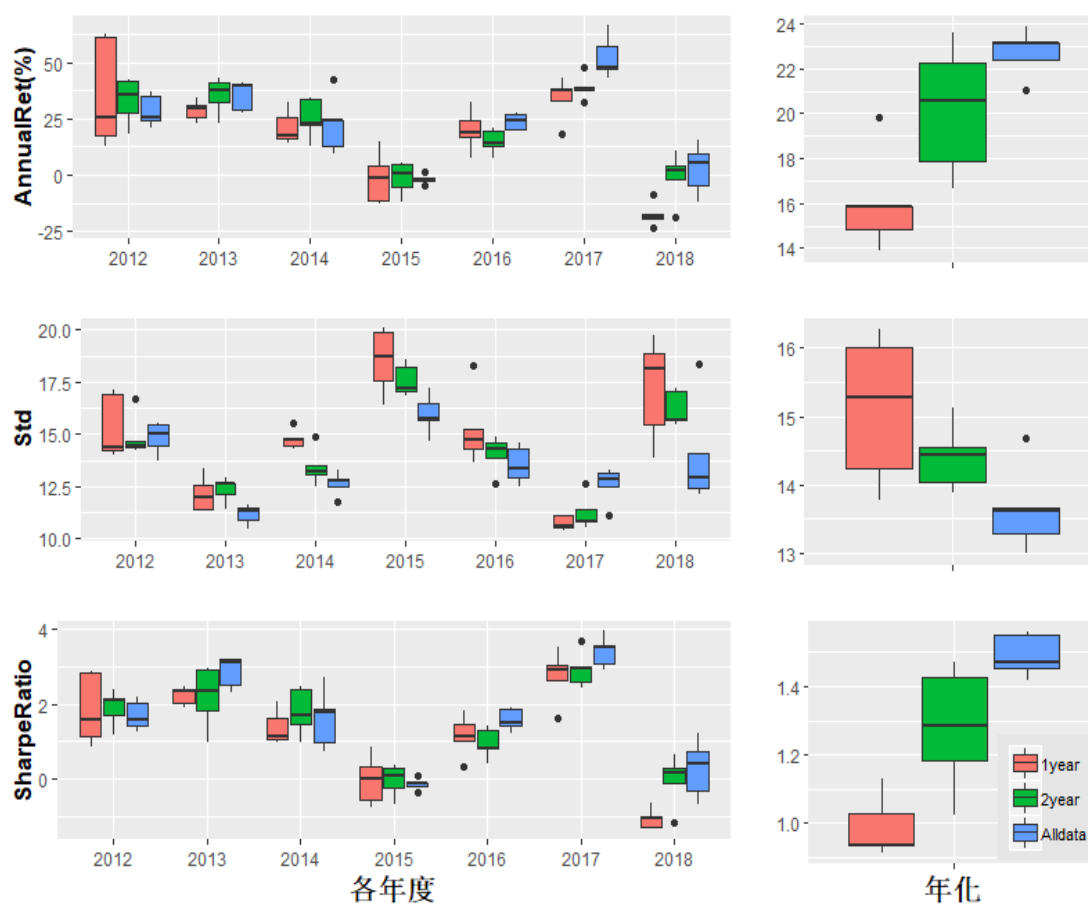


圖 4-1、各建構模型資料期間回測結果-各年度<sup>18</sup>

彙整以上結論，本文推測使用更多、期間更長的資料進行建模，除了有助於增加模型的預測能力（報酬率上升），更重要的是可以增強模型的穩定性（標準差下降），因此接下來本文將採用過去所有資料進行後續試驗。

<sup>16</sup> 本文簡略使用大盤指數作為多空頭判斷，定義 2012、2013、2014、2016、2017 年為多頭間

<sup>17</sup> 方法同前一點，定義 2015、2018 年為空頭期間

<sup>18</sup> 詳細資料請見附錄 1

## 二、交叉驗證後選定最終結果標準

本論文在模型裡加入了交叉驗證的方法希望增強模型的穩定性，因此在每次訓練，皆會同時建立五個模型，分別對同一筆預測資料進行預測，但究竟應該如何決定最終的預測結果，亦會對模型的預測能力造成不小影響，因此，本文分別使用中位數、平均數作為最終預測結果，希望透過實證的方式來判斷何者較為適合。

由於深度學習中隨機性的原因，每次結果可能不盡相同，因此，本文針對兩種不同選定結果標準分別進行 5 次試驗，比較其年化報酬率 ( $\mu$ )、年化標準差 ( $\sigma$ )、以及年化夏普比率 (S)。

從回測結果 (表 4-2) 可以發現，使用平均數作為選定最終結果可能導致報酬率較不穩定，導致年化夏普比也較中位數的結果來的差。進一步針對各年度報酬率、標準差以及夏普比率進行分析 (圖 4-2)，發現使用平均數作為選定最終結果者，在每個年度的報酬率變異較大，使得箱型圖的上下界落差大，因此，就算在標準差部分表現較中位數群組好，最終年化夏普比仍是中位數群組表現較佳。

表 4-2、各選定結果標準回測結果

	平均數			中位數		
	$\mu$	$\sigma$	S	$\mu$	$\sigma$	S
試驗 1	11.11	12.45	0.82	23.11	13.29	1.55
試驗 2	18.65	12.9	1.31	23.09	14.68	1.42
試驗 3	14.24	12.54	1.04	23.85	13.66	1.56
試驗 4	19.21	13.17	1.32	21.04	12.99	1.45
試驗 5	23.59	13.15	1.6	22.35	13.62	1.47
平均	<b>17.36</b>	<b>12.84</b>	<b>1.22</b>	<b>22.69</b>	<b>13.65</b>	<b>1.49</b>

註： $\mu$ 代表年化報酬率， $\sigma$ 代表年化標準差，S代表年化夏普比。

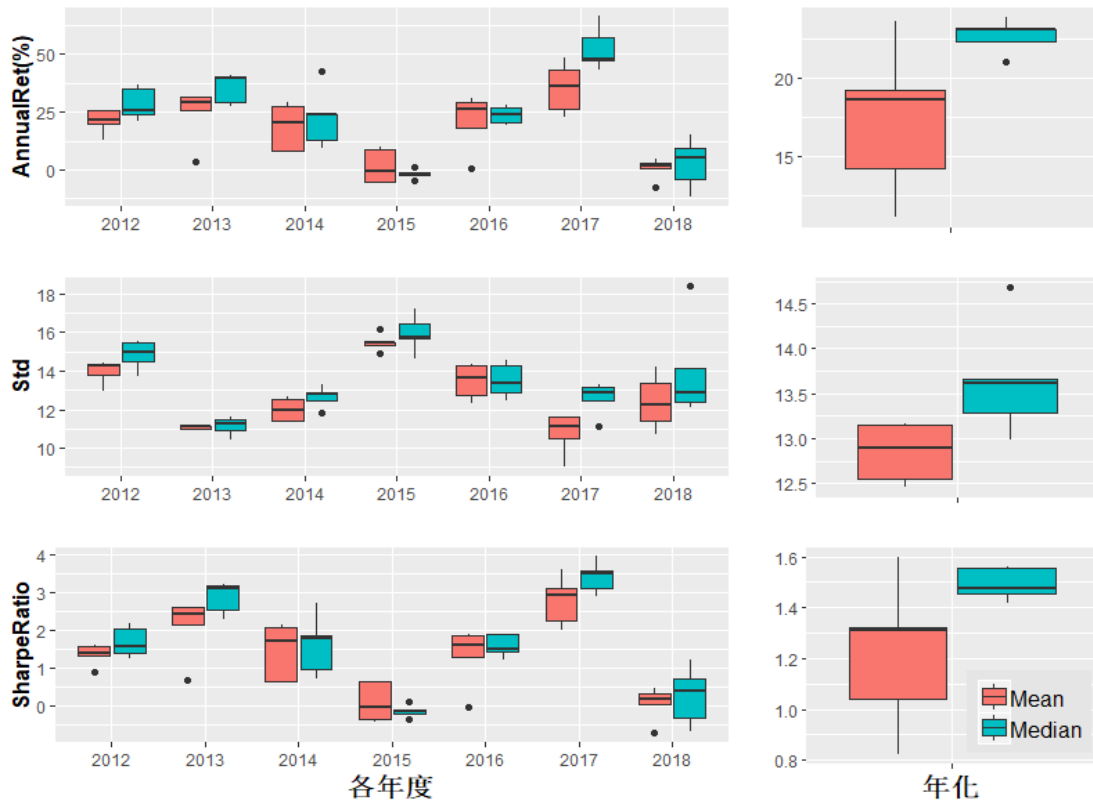


圖 4-2、各選定結果標準回測結果-各年度<sup>19</sup>

### 三、多層感知機激活函數 (LeakyReLU vs ELU)

在第三章第三節中，本文提到使用 LeakyReLU 以及 ELU 函數替代 ReLU 函數可以避免神經元「死亡」的問題，但究竟哪個函數更為適合，並無明確的定論，因此，本文同樣希望透過回測的方式來選擇更適合本文資料型態的激活函數。

由於深度學習中隨機性的原因，每次結果可能不盡相同，因此，本文針對兩種不同激活函數分別進行 5 次試驗，比較其年化報酬率 ( $\mu$ )、年化標準差 ( $\sigma$ )、以及年化夏普比率 (S)。

從回測結果 (表 4-3) 可以發現，使用 LeakyReLU 函數的試驗中，無論在年化報酬率以及年化標準差皆不如 ELU 函數，而從各年度比較 (圖 4-3) 中，亦無發現 LeakyReLU 函數明顯優勢部分，因此，本文後續皆繼續採用 ELU 函數作為多層感知機之激活函數。

<sup>19</sup> 詳細資料請見表附錄 2



表 4-3、各激活函數回測結果

	LeakyReLU			ELU		
	$\mu$	$\sigma$	S	$\mu$	$\sigma$	S
試驗 1	19.45	14.41	1.23	23.11	13.29	1.55
試驗 2	17.51	14.11	1.14	23.09	14.68	1.42
試驗 3	24.73	14.33	1.54	23.85	13.66	1.56
試驗 4	17.73	13.77	1.18	21.04	12.99	1.45
試驗 5	20.01	13.98	1.30	22.35	13.62	1.47
<b>平均</b>	<b>19.89</b>	<b>14.12</b>	<b>1.28</b>	<b>22.69</b>	<b>13.65</b>	<b>1.49</b>

註： $\mu$ 代表年化報酬率， $\sigma$ 代表年化標準差，S代表年化夏普比。

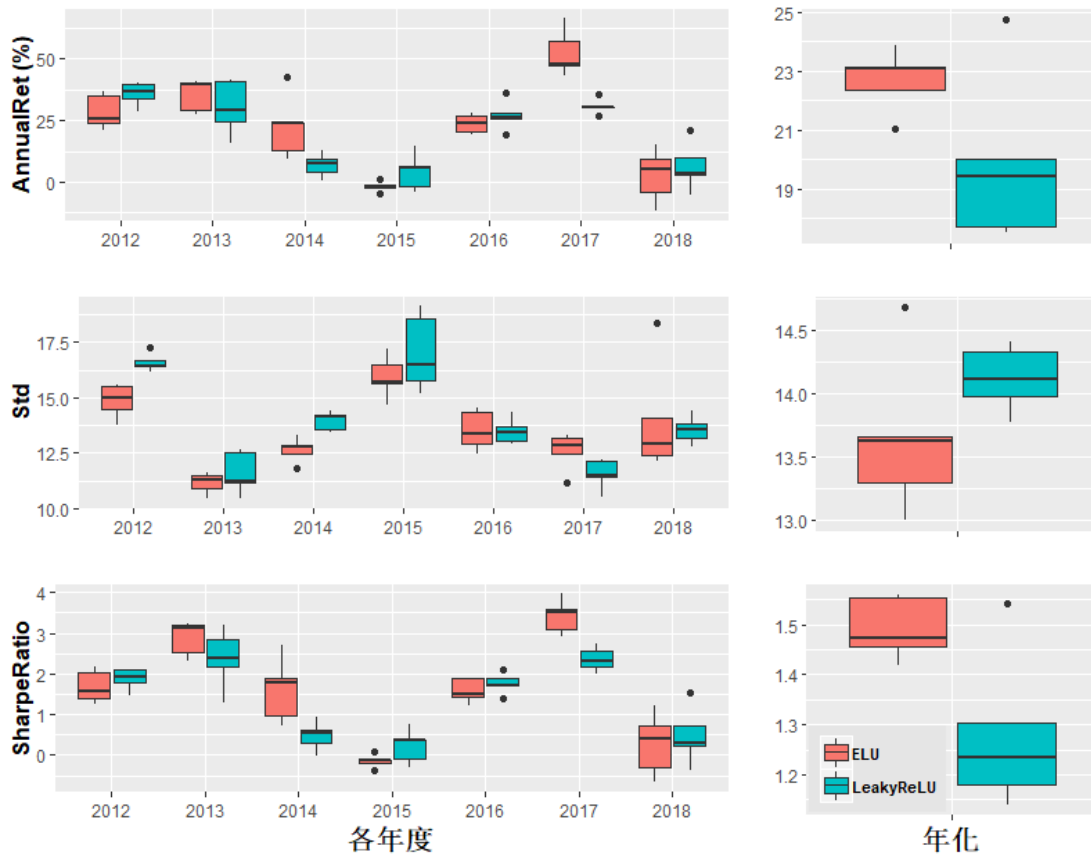


圖 4-3、各激活函數回測結果-各年度<sup>20</sup>

<sup>20</sup> 詳細資料請見表附錄 3

#### 四、投資組合持有期間

本文使用的股票圖形資料庫，包含了 20 天以來的股價以及成交量資料，而究竟 20 天的資料，可以去預測未來的多長時間？因此，本文以 20 天做為上限，分別對 10 天及 20 天進行回測，以實證的方式來尋找最適之持有日期。

由於深度學習中隨機性的原因，每次結果可能不盡相同，因此，本文針對三種投資組合持有期間分別進行 5 次試驗，比較其年化報酬率 ( $\mu$ )、年化標準差 ( $\sigma$ )、以及年化夏普比率 ( $S$ )。

從回測結果 (表 4-4) 可以發現，相較於持有 20 天的群組，持有 10 天的投資組合雖然年化標準差略低，但報酬率卻有明顯的下降且不穩定，本文推測有可能是因為交易成本影響了整體績效，因此本文再進一步去觀察交易成本對績效的影響，本文定義交易成本之影響比率如下：

$$\text{交易成本影響比率}(R) = 1 - \frac{1 + \text{考慮交易成本之年化報酬率}(\mu)}{1 + \text{未考慮交易成本之年化報酬率}(\mu')}$$

表 4-4、各持有期間回測結果

	持有 10 天			持有 20 天		
	$\mu$	$\sigma$	S	$\mu$	$\sigma$	S
試驗 1	16.98	13.58	1.15	23.11	13.29	1.55
試驗 2	9.77	13.55	0.68	23.09	14.68	1.42
試驗 3	9.68	12.93	0.70	23.85	13.66	1.56
試驗 4	16.48	13.57	1.12	21.04	12.99	1.45
試驗 5	16.93	13.32	1.16	22.35	13.62	1.47
<b>平均</b>	<b>13.97</b>	<b>13.39</b>	<b>0.96</b>	<b>22.69</b>	<b>13.65</b>	<b>1.49</b>

註： $\mu$ 代表年化報酬率， $\sigma$ 代表年化標準差，S代表年化夏普比。

從表 4-5 可以發現，在未考慮交易成本時，持有 10 天群組之年化報酬率並無顯著高於 20 天群組，但由於較頻繁交易導致交易成本提升，導致考慮交易成本後年化報酬率 ( $\mu$ ) 下降。因此，本文在固定投資組合持有期間的部分，認為 20 天為較適合之持有期間。

表 4-5、交易成本對各投資組合之影響

	持有 10 天			持有 20 天		
	$\mu$	$\mu'$	$R$	$\mu$	$\mu'$	$R$
試驗 1	16.98	35.26	13.51	23.11	31.52	6.39
試驗 2	9.77	26.32	13.10	23.09	31.96	6.72
試驗 3	9.68	27.55	14.01	23.85	32.89	6.80
試驗 4	16.48	34.17	13.18	21.04	29.54	6.56
試驗 5	16.93	34.51	13.07	22.35	31.59	7.02
<b>平均</b>	<b>13.97</b>	<b>31.56</b>	<b>13.38</b>	<b>22.69</b>	<b>31.50</b>	<b>6.70</b>

註： $\mu$  為考慮交易成本後之年化報酬率， $\mu'$  為未考慮交易成本之年化報酬率

## 五、投資組合股票檔數

本文將選到的股票使用等權重進行資產配置，而在同一投資策略所組成的投資組合中，可以預期當投資組合中股票數目越多時，可以使風險降低，但同時報酬亦可能隨著下降，本文嘗試使用 5 檔、10 檔、20 檔三種組合，觀察其差異與優劣。

由於深度學習中隨機性的原因，每次結果可能不盡相同，因此，本文針對三種不同股票檔數分別做了 5 次試驗，比較其年化報酬率 ( $\mu$ )、年化標準差 ( $\sigma$ )、以及年化夏普比率 (S)。

從回測結果 (表 4-6) 可以發現，隨著持有檔數增加，報酬率雖然下降，但標準差部分亦是呈現下降趨勢，而在夏普比率的部分，持有 10 檔以及 20 檔則表現相當。

表 4-6、各股票檔數回測結果

	持有 5 檔			持有 10 檔			持有 20 檔		
	$\mu$	$\sigma$	S	$\mu$	$\sigma$	S	$\mu$	$\sigma$	S
試驗 1	21.90	17.11	1.18	23.11	13.29	1.55	18.88	10.23	1.64
試驗 2	20.97	16.83	1.15	23.09	14.68	1.42	17.14	10.76	1.43
試驗 3	24.20	17.36	1.28	23.85	13.66	1.56	15.15	10.16	1.34
試驗 4	27.39	16.85	1.46	21.04	12.99	1.45	16.32	10.77	1.36
試驗 5	22.48	16.46	1.25	22.35	13.62	1.47	16.40	9.88	1.48
<b>平均</b>	<b>23.39</b>	<b>16.92</b>	<b>1.26</b>	<b>22.69</b>	<b>13.65</b>	<b>1.49</b>	<b>16.77</b>	<b>10.36</b>	<b>1.45</b>

註： $\mu$  代表年化報酬率， $\sigma$  代表年化標準差，S 代表年化夏普比。

進一步針對各年度報酬率、標準差以及夏普比進行分析 (圖 4-4)，可以發現很明顯的隨著持有股票檔數增加，每年的標準差都有顯著地下降，而報酬率則較不明顯但大致上也是隨著持有檔數增加而下降。值得一提的是，在空頭期間 (2015、

2018)，持有較少的股票檔數能有較好的表現，甚至在逐年回測結果中，持有 5 檔的組合僅在 2015 年的其中一次試驗中報酬小於零。

總結以上，若單就夏普比率作為標準，持有 10 檔或 20 檔並無太大差異，並皆優於持有 5 檔的組合。但在空頭期間，或許持有較少股票檔數會是個不錯避免下檔風險的選擇。

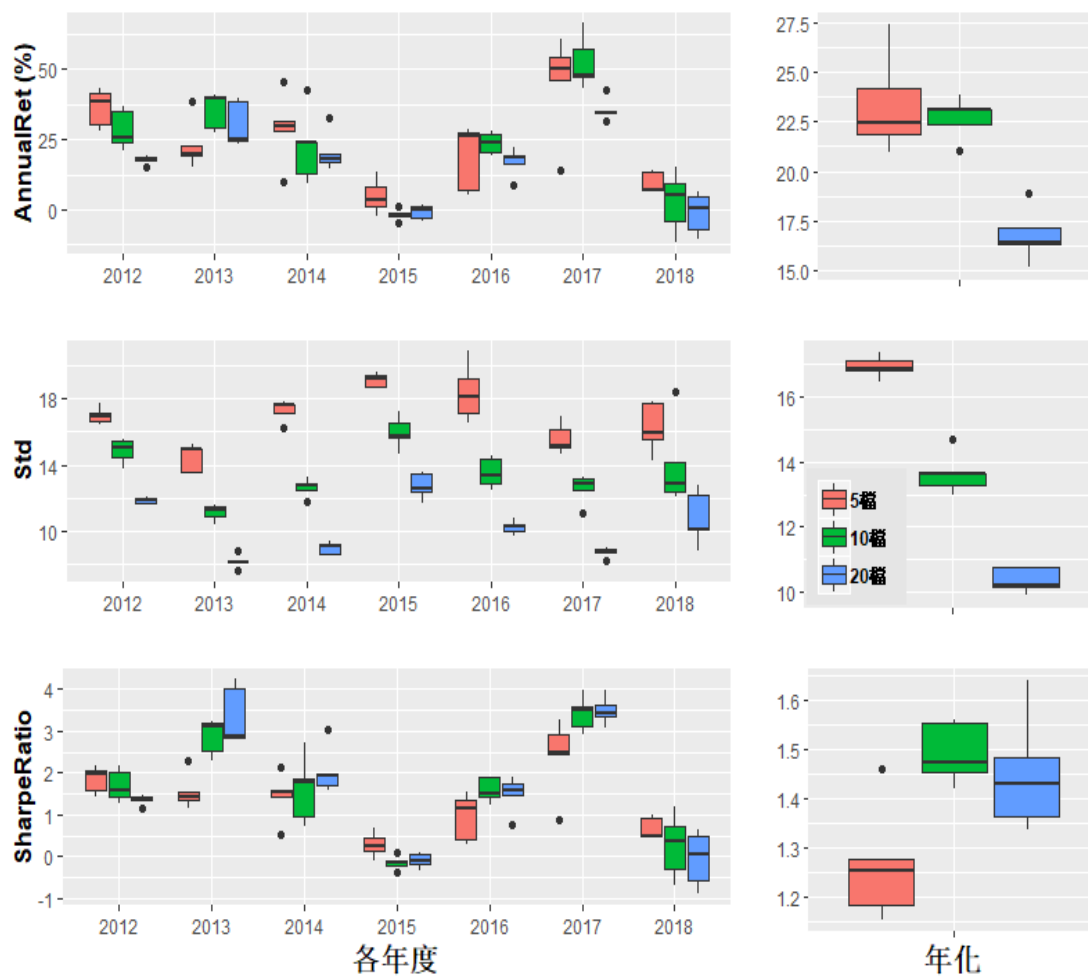


圖 4-4、各股票檔數回測結果-各年度<sup>21</sup>

<sup>21</sup> 詳細資料請見附錄 4

## 六、小結

本章節在固定投資組合持有期間的基礎上，去針對各種可調整變因進行實證分析，分別得到以下結論：

1. 建構模型資料庫期間：使用更多、期間更長的資料進行建模，可以有效增加模型的預測能力以及增強模型的穩定性。
2. 交叉驗證後選定最終結果標準：採用中位數作為標準可以使報酬率的變異較小，因此推論中位數作為標準較平均數好。
3. 多層感知機激活函數：使用 ELU 函數無論在年化報酬率或是年化標準差皆優於 LeakyReLU 函數。
4. 投資組合持有期間：固定持有 10 天的投資組合在未考慮交易成本的報酬率中並無明顯高於持有 20 天的組合，但由於頻繁交易導致交易成本上漲，因此本文認為 20 天為較佳之持有期間。
5. 投資組合股票檔數：若單就夏普比率作為標準，持有 10 檔或 20 檔皆優於持有 5 檔的組合。但持有 5 檔的組合卻能在空頭期間維持些微利潤，是相較其他兩者表現較佳的部分。

以下將套用最佳變因所建置的模型，與台灣加權指數做進一步的分析與比較，以下分別就五次試驗以及台指的累積報酬率繪圖（圖 4-5），並就累積報酬率、年化報酬率、年化標準差、年化夏普比、最大回撤率進行比較。

從回測結果（表 4-7、圖 4-5）可以發現，本論文所使用的投資策略，相較於台灣加權指數，雖然無法有效降低標準差與最大回撤率，但在年化報酬率上有著顯著的成長，也直接導致年化夏普比率明顯的優於加權指數。另外，由於此投資組合為固定持有 20 天（約一個月），因此月周轉率即接近 100%。

圖形辨識策略績效比較  
 回測期間:2012-01-02 至 2018-12-28




圖 4-5、最佳模型累積報酬率比較-固定持有期間

表 4-7、最佳模型回測結果比較表-固定持有期間

	試驗 1	試驗 2	試驗 3	試驗 4	試驗 5	平均	台指
累積報酬率	314.97	314.48	332.47	269.46	297.81	<b>305.84</b>	<b>39.92</b>
年化報酬率	23.11	23.09	23.85	21.04	22.35	<b>22.69</b>	<b>5.07</b>
年化標準差	13.29	14.68	13.66	12.99	13.62	<b>13.61</b>	<b>12.07</b>
年化夏普比	1.55	1.42	1.56	1.45	1.47	<b>1.49</b>	<b>0.33</b>
最大回撤率	-24.57	-29.39	-21.19	-23.92	-23.06	<b>-24.43</b>	<b>-25.70</b>
月周轉率	90.81	92.45	91.76	90.25	91.03	<b>91.26</b>	-

### 第三節 不固定持有期間績效分析

本節將使用第三章第四節所提到的「追蹤止損」模式，將不固定投資組合進出場時間，而是當投資組合中任一股票達到「止損」的標準時，再買入等量之股票。另外，前面亦有提到為了避免股價持續在同一區間震盪，本研究另外加入了止損的條件，建置進階的追蹤止損策略，因此以下將分為兩階段，分別對兩種策略進行回測與分析。

#### 一、一般追蹤止損策略

第一階段共設置四種止損標準，分別為 5%、10%、15%、20%，回測時間為 2012 年至 2019 年，由於深度學習中隨機性的原因，每次結果可能不盡相同，因此，本文分別對四種止損標準進行五次試驗<sup>22</sup>，並針對年化報酬率 ( $\mu$ )、年化標準差 ( $\sigma$ )、年化夏普比率 (S)、最大回撤率 (MDD)、平均月周轉率 (Turnover rate)、總交易筆數、持有天數中位數、單筆交易最大虧損以及單筆交易平均獲利等指標進行分析比較。

從回測結果 (表 4-8) 可以發現，加入追蹤止損策略後，周轉率相較固定持有期間有了明顯的下降，另外，雖然年化標準差與年化報酬率相較固定持有期間亦有下降，但年化夏普比仍維持在 1.2~1.4 之間，仍屬不錯水準，因此本文將此策略定義為一種低風險低報酬的策略。

進一步比較不同止損標準，顯而易見的是隨著止損標準提高，每檔股票持有天數愈長，導致交易筆數以及周轉率下降，另外，雖然止損標準提高，交易勝率以及單筆交易平均獲利也隨之上升，但從最終回測結果的年化報酬率以及年化標準差來看，止損標準嚴格者並無較差，因此本文認為四種止損標準並無明顯優劣，投資人可視其投資偏好進行選擇。

<sup>22</sup> 表 4-9、4-10 呈現之數值為五次試驗取平均後之結果



## 二、進階追蹤止損策略

誠如第三章所提，前階段之策略雖然實現了止損的概念，但當止損標準較大時，可能產生股價持續在同一區間震盪，長期下來並未達到止損標準，但也未實現資本利得，造成資金浪費，因此，本文另外定義了新的止損標準 ( $S'$ ) 如下：

$$S' = \min(MDD(60), S)$$

$S'$  為過去 60 天股價之最大跌幅與原先止損標準取最小值，來防止股票在區間震盪過長時間的問題產生。

從進階止損策略的回測結果 (表 4-9) 可以發現，加入新的止損標準後，除了 5% 的群組周轉率並無明顯上升外，其餘皆有顯著提升，進一步比較四者年化夏普比，發現 5% 群組有了明顯的下降，本文推論是因為 5% 群組原本股票持有天數中位數即低於 60 天，因此加入新的標準卻使用過去 60 天股價最大跌幅做為基準，明顯有失公允，因此本文推論在 5% 的群組不適用新的止損標準。

再進一步分析其餘三個群組，加入新的止損標準後，雖然交易勝率以及單筆交易平均獲利略有下降，但成功地使年化報酬率提升，並且年化夏普比亦維持在相同的水準，因此本文認為，此一新止損標準，是有效且成功的。

表 4-8、一般追蹤止損策略回測結果

止損標準	總交易筆數 (次)	持有天數 中位數 (天)	勝率 <sup>23</sup> (%)	單筆交易 平均獲利 (%)	單筆交易 最大虧損 (%)	年化報酬率 (%)	年化標準差 (%)	年化夏普比 (%)	最大回撤率 (%)	月周轉率 (%)
5%	477	26	44.75	2.97	-12.71	13.77	9.79	1.26	-20.65	49.76
10%	163	79	49.69	7.47	-15.84	13.40	9.43	1.27	-17.57	16.91
15%	93	141	58.80	13.47	-19.13	13.39	9.74	1.22	-14.42	9.31
20%	54	314	64.28	31.15	-21.33	15.90	10.31	1.37	-16.27	5.29

表 4-9、進階追蹤止損策略回測結果

止損標準	總交易筆數 (次)	持有天數 中位數 (天)	勝率 (%)	單筆交易 平均獲利 (%)	單筆交易 最大虧損 (%)	年化報酬率 (%)	年化標準差 (%)	年化夏普比 (%)	最大回撤率 (%)	月周轉率 (%)
5%	492	27	44.39	2.69	-13.31	12.49	9.45	1.18	-19.54	50.73
10%	232	78	50.78	6.40	-15.96	15.67	10.72	1.31	-19.75	25.11
15%	164	126	53.03	8.11	-21.38	14.48	10.93	1.22	-17.51	17.46
20%	139	150	53.43	12.13	-24.39	17.30	11.85	1.31	-18.20	15.08

<sup>23</sup> 勝率 =  $\frac{\text{獲利交易筆數}}{\text{總交易筆數}} \times 100$

## 第五章 結論與未來研究方向建議

### 第一節 結論

在針對股票進行技術分析時，蠟燭圖以及成交量圖一直是非常重要的判斷標準，股票型態學也一直在產學界廣為運用，本研究透過自動編碼器將股票蠟燭圖以及成交量圖進行降維，再使用多層感知機模型去預測未來股價走勢，建置投資組合，希望可以創造超額報酬。

本研究中第一階段先使用自動編碼器模型將股票蠟燭圖以及成交量圖分別進行降維成 512 個特徵，並且能夠將壓縮特徵還原至原圖形，證明自動編碼器模型能夠從原股票圖形中學習並擷取重要特徵。

本研究第二階段則使用多層感知機模型，將前階段所產出的 1024 個特徵做為輸入層資料，進一步去預測該股票未來 10 天或 20 天之股價，並根據預測結果選出預期報酬較高者建置投資組合，接著透過實證分析，去比較多層感知機模型中可調整變因，並藉此選出較佳變因建立最適模型，回測結果平均年化報酬率達到 22.69%，平均年化夏普比則為 1.49，明顯優於台灣加權指數。另外，本文也建立追蹤止損模型使交易策略更貼近實務，實證結果雖然年化報酬率略遜於固定持有期間策略，但亦成功使年化標準差下降，年化標準差則介於 1.2 至 1.4 之間，仍屬不錯之結果。

## 第二節 未來研究方向建議

本研究僅以股票蠟燭圖以及成交量圖建置資料，未來可再加入其他圖形（如股價均線圖），或許能使預測能力更上層樓，另外，受限於時間以及電腦資源，本研究自動編碼器模型僅在期間初始訓練一次，並未考慮隨著時間推移，自動編碼器模型是否能持續將股票線圖降維之問題。

本研究在將圖形降維後，產出 1024 個圖形特徵，再使用多層感知機模型進行預測，未來或許可以將產出的特徵使用其他模型進行預測（如隨機森林、XGBoost、LSTM），探討模型對此特徵之學習能力與差異。

本文僅用 20 天之股價與成交量圖做為資料庫，但投資人使用線圖時，大多不僅僅參考過去 20 天之資料，因此，未來可以考慮將圖形期間拉長，如此不僅可以更貼近實務，同時也可以用更長期間的資料，去預測更長時間股價報酬的趨勢。

本文除了固定持有期間外，另外定義了兩種止損策略，來貼近一般投資人在實務的操作模式，雖然成功達到預期目的，也維持著相當不錯的年化夏普比，但直觀來看年化報酬率相較固定持有期間是有所下降的，換句話說，怎麼在不固定持有期間的策略中，去找到合適的「賣點」，是未來可以繼續努力的方向。

## 參考文獻

- [1] Chen, T. and Chen, F. (2016). An intelligent pattern recognition model for supporting investment decisions in stock market. *Information Sciences*, 346-347, 261-274.
- [2] Ding, X., Zhang, Y., Liu T. and Duan J. (2015). Deep Learning for Event-Driven Stock Prediction. *IJCAI'15 Proceedings of the 24th International Conference on Artificial Intelligence*, 2327-2333.
- [3] Fama, E. F. (1998). Market efficiency, long-term returns, and behavioral finance. *Journal of financial economics*, 49(3), 283-306.
- [4] Fischer, T. and Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654-669.
- [5] He, K., Zhang, X., Ren, S. and Sun, J. (2016). Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- [6] Hinton, G. E., Osindero, S. and Yee, W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
- [7] Hu, G., Hu, Y., Yang, K., Yu, Z., Sung, F., Zhang, Z., ...Miemie, Q. (2018). Deep Stock Representation Learning: From Candlestick Charts to Investment Decisions. *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*.
- [8] Hubel, D. H. and Wiesel, T. N. (1962). Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. *Journal of Physiology*, 160(1), 106-154.

- [9] Krizhevsky, A., Sutskever, I. and Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25(2), 1097-1105.
- [10] Lecun, Y., Bottou, L., Bengio, Y. and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- [11] Masci, J., Meier U., Cireşan, D. and Schmidhuber, J. (2011). Stacked convolutional auto-encoders for hierarchical feature extraction. *Artificial Neural Networks and Machine Learning - ICANN*. 52-59.
- [12] Ranjan R., Patel V. M. and Chellappa R. (2017). Hyperface: a deep multi-task learning framework for face detection, landmark localization, pose estimation, and gender recognition. *The IEEE Transactions on Pattern Analysis and Machine Intelligence*, 41(1), 121-135.
- [13] Simonyan, K. and Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv 1409.1556.
- [14] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A. (2015). Going deeper with convolutions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- [15] Takeuchi, L. and Lee, Y. (2013). Applying Deep Learning to Enhance Momentum Trading Strategies in Stocks. *Stanford Technology Report*.

## 附 錄

附錄 1、不同建構模型資料期間績效比較-各年度

單位 (%)	1年			2年			全期間			TWII
Year	Return	Std	SharpeRatio	Return	Std	SharpeRatio	Return	Std	SharpeRatio	Return
2012	62.13	16.95	2.89	35.32	14.48	2.10	36.81	15.55	2.03	10.75
	61.26	17.11	2.83	27.43	14.40	1.69	35.02	13.74	2.19	
	17.67	14.40	1.13	41.63	14.67	2.39	20.82	15.00	1.27	
	25.62	14.25	1.60	42.03	16.67	2.14	25.65	14.46	1.57	
	12.72	14.04	0.85	18.27	14.25	1.18	24.11	15.48	1.41	
2013	30.70	11.42	2.46	22.55	12.14	1.81	29.22	11.64	2.30	10.70
	34.47	13.38	2.38	40.74	12.92	0.97	40.68	11.30	3.19	
	25.43	12.60	2.01	42.68	12.66	2.95	40.44	11.47	3.13	
	23.13	11.43	1.89	37.55	11.37	2.90	27.54	10.44	2.53	
	29.51	11.95	2.36	32.44	12.66	2.35	39.81	10.89	3.23	
2014	17.65	15.52	1.13	22.60	13.49	1.69	24.15	12.47	1.77	8.07
	16.14	14.80	1.06	12.94	14.90	0.97	42.53	13.31	2.71	
	32.48	14.46	2.08	33.99	12.49	2.47	24.12	11.80	1.88	
	14.13	14.74	0.97	22.19	13.20	1.47	9.20	12.79	0.73	
	25.28	14.34	1.61	33.31	13.07	2.39	12.87	12.85	0.96	
2015	14.64	20.07	0.84	4.76	16.84	0.29	-1.22	14.64	-0.13	-10.09
	-11.07	19.89	-0.56	5.35	18.23	0.37	-1.74	17.21	-0.12	
	-1.04	17.60	0.01	0.55	17.18	0.09	1.26	16.48	0.10	
	-12.76	16.38	-0.77	-5.36	18.61	-0.25	-4.89	15.72	-0.38	
	4.02	18.76	0.31	-11.75	17.03	-0.70	-2.37	15.66	-0.21	
2016	7.54	18.30	0.32	20.93	14.30	1.29	26.70	12.91	1.89	14.04
	32.31	15.22	1.84	12.59	13.85	0.81	19.31	14.56	1.23	
	16.87	13.65	1.03	7.47	14.89	0.41	23.95	14.31	1.51	
	24.35	14.27	1.45	13.85	14.62	0.83	27.70	13.37	1.88	
	19.17	14.76	1.15	19.85	12.64	1.41	20.39	12.47	1.43	
2017	33.24	11.12	2.64	47.80	10.54	3.69	43.04	12.47	2.91	14.77
	18.49	10.52	1.60	32.10	11.38	2.44	46.90	12.86	3.10	
	43.26	10.37	3.52	38.06	10.83	2.98	66.13	13.27	3.96	
	37.64	10.60	3.03	37.71	12.61	2.61	47.58	11.14	3.57	
	38.03	11.14	2.92	38.67	10.81	3.00	57.23	13.18	3.52	
2018	-17.51	18.18	-1.03	2.07	15.68	0.18	5.19	12.90	0.39	-9.18
	-23.57	18.86	-1.36	10.60	15.43	0.67	-11.85	18.38	-0.67	
	-18.81	15.47	-1.28	3.99	17.05	0.29	-4.38	12.41	-0.32	
	-8.85	13.89	-0.65	-18.74	17.22	-1.17	15.40	12.12	1.20	
	-19.58	19.77	-1.04	-2.23	15.65	-0.10	9.20	14.11	0.72	
全期間 (年化)	19.80	16.27	1.13	22.25	14.05	1.43	23.11	13.29	1.55	5.07
	15.84	16.01	0.93	20.54	14.56	1.28	23.09	14.68	1.42	
	15.82	14.25	1.03	23.62	14.43	1.47	23.85	13.66	1.56	
	13.86	13.78	0.94	16.66	15.13	1.03	21.04	12.99	1.45	
	14.83	15.27	0.91	17.89	13.88	1.18	22.35	13.62	1.47	

附錄 2、不同選定最終結果標準績效比較-各年度

單位 (%) Year	Mean			Median			TWII Return
	Return	Std	SharpeRatio	Return	Std	SharpeRatio	
2012	25.59	14.45	1.58	36.81	15.55	2.03	10.75
	21.82	14.35	1.38	35.02	13.74	2.19	
	12.71	12.96	0.91	20.82	15.00	1.27	
	20.05	13.78	1.32	25.65	14.46	1.57	
	25.68	14.27	1.60	24.11	15.48	1.41	
2013	3.44	11.10	0.68	29.22	11.64	2.30	10.70
	31.58	11.20	2.62	40.68	11.30	3.19	
	31.67	10.95	2.63	40.44	11.47	3.13	
	29.25	11.13	2.43	27.54	10.44	2.53	
	25.75	11.01	2.13	39.81	10.89	3.23	
2014	28.96	12.56	2.07	24.15	12.47	1.77	8.07
	20.32	11.44	1.72	42.53	13.31	2.71	
	8.09	11.99	0.61	24.12	11.80	1.88	
	8.28	12.68	0.66	9.20	12.79	0.73	
	27.27	11.39	2.14	12.87	12.85	0.96	
2015	-5.93	14.90	-0.42	-1.22	14.64	-0.13	-10.09
	10.13	15.46	0.64	-1.74	17.21	-0.12	
	-5.00	15.48	-0.38	1.26	16.48	0.10	
	-0.50	16.16	-0.03	-4.89	15.72	-0.38	
	8.86	15.33	0.64	-2.37	15.66	-0.21	
2016	0.29	12.73	-0.06	26.70	12.91	1.89	14.04
	18.31	12.31	1.29	19.31	14.56	1.23	
	30.86	14.27	1.88	23.95	14.31	1.51	
	26.09	14.32	1.61	27.70	13.37	1.88	
	29.27	13.66	1.90	20.39	12.47	1.43	
2017	22.74	9.01	2.25	43.04	12.47	2.91	14.77
	26.26	11.64	1.99	46.90	12.86	3.10	
	35.94	10.51	2.92	66.13	13.27	3.96	
	48.06	11.12	3.60	47.58	11.14	3.57	
	43.16	11.65	3.11	57.23	13.18	3.52	
2018	1.49	11.38	0.16	5.19	12.90	0.39	-9.18
	0.66	13.40	0.05	-11.85	18.38	-0.67	
	-7.32	10.68	-0.74	-4.38	12.41	-0.32	
	4.65	12.23	0.47	15.40	12.12	1.20	
	2.89	14.20	0.30	9.20	14.11	0.72	
全期間 (年化)	11.11	12.45	0.82	23.11	13.29	1.55	5.07
	18.65	12.90	1.31	23.09	14.68	1.42	
	14.24	12.54	1.04	23.85	13.66	1.56	
	19.21	13.17	1.32	21.04	12.99	1.45	
	23.59	13.15	1.60	22.35	13.62	1.47	



附錄 3、不同多層感知機激活函數績效比較-各年度

單位 (%) Year	ELU			LeakyReLU			TWII Return
	Return	Std	SharpeRatio	Return	Std	SharpeRatio	
2012	36.81	15.55	2.03	36.68	16.41	1.93	10.75
	35.02	13.74	2.19	28.30	17.25	1.47	
	20.82	15.00	1.27	40.33	16.43	2.09	
	25.65	14.46	1.57	39.56	16.15	2.09	
	24.11	15.48	1.41	33.68	16.66	1.77	
2013	29.22	11.64	2.30	24.30	10.42	2.18	10.70
	40.68	11.30	3.19	15.66	12.50	1.30	
	40.44	11.47	3.13	41.41	11.22	3.21	
	27.54	10.44	2.53	40.58	12.64	2.83	
	39.81	10.89	3.23	28.97	11.16	2.37	
2014	24.15	12.47	1.77	9.15	14.41	0.61	8.07
	42.53	13.31	2.71	13.02	13.42	0.92	
	24.12	11.80	1.88	7.45	14.18	0.56	
	9.20	12.79	0.73	4.19	14.15	0.31	
	12.87	12.85	0.96	0.69	13.59	-0.01	
2015	-1.22	14.64	-0.13	-1.51	18.54	-0.09	-10.09
	-1.74	17.21	-0.12	6.25	15.79	0.37	
	1.26	16.48	0.10	14.32	19.12	0.77	
	-4.89	15.72	-0.38	-4.02	15.20	-0.32	
	-2.37	15.66	-0.21	6.00	16.50	0.37	
2016	26.70	12.91	1.89	28.10	13.69	1.88	14.04
	19.31	14.56	1.23	25.34	13.41	1.72	
	23.95	14.31	1.51	18.95	12.94	1.40	
	27.70	13.37	1.88	26.15	13.05	1.72	
	20.39	12.47	1.43	36.33	14.36	2.12	
2017	43.04	12.47	2.91	30.50	11.48	2.31	14.77
	46.90	12.86	3.10	30.04	12.20	2.17	
	66.13	13.27	3.96	26.88	12.13	1.98	
	47.58	11.14	3.57	30.34	10.53	2.58	
	57.23	13.18	3.52	35.70	11.39	2.75	
2018	5.19	12.90	0.39	9.87	14.38	0.72	-9.18
	-11.85	18.38	-0.67	2.61	13.55	0.23	
	-4.38	12.41	-0.32	20.88	12.81	1.52	
	15.40	12.12	1.20	-5.36	13.82	-0.37	
	9.20	14.11	0.72	3.33	13.17	0.30	
全期間 (年化)	23.11	13.29	1.55	19.45	14.41	1.23	5.07
	23.09	14.68	1.42	17.51	14.11	1.14	
	23.85	13.66	1.56	24.73	14.33	1.54	
	21.04	12.99	1.45	17.73	13.77	1.18	
	22.35	13.62	1.47	20.01	13.98	1.30	

附錄 4、不同投資組合股票檔數績效比較-各年度

單位 (%) Year	5檔			10檔			20檔			TWII Return
	Return	Std	SharpeRatio	Return	Std	SharpeRatio	Return	Std	SharpeRatio	
2012	42.95	16.61	2.18	36.81	15.55	2.03	15.04	11.73	1.16	10.75
	28.15	17.69	1.44	35.02	13.74	2.19	17.84	12.06	1.34	
	38.22	16.45	1.99	20.82	15.00	1.27	19.33	11.85	1.47	
	41.06	17.14	2.04	25.65	14.46	1.57	18.83	11.96	1.42	
	30.44	16.91	1.60	24.11	15.48	1.41	17.34	11.71	1.34	
2013	19.73	14.99	1.35	29.22	11.64	2.30	24.81	8.11	2.86	10.70
	15.03	13.61	1.15	40.68	11.30	3.19	38.53	8.85	4.01	
	19.14	13.60	1.44	40.44	11.47	3.13	23.39	7.62	2.86	
	38.47	15.23	2.29	27.54	10.44	2.53	39.82	8.27	4.24	
	22.54	14.91	1.53	39.81	10.89	3.23	24.38	8.16	2.80	
2014	27.92	17.13	1.43	24.15	12.47	1.77	32.68	9.41	3.02	8.07
	29.54	16.26	1.60	42.53	13.31	2.71	19.72	9.13	1.97	
	31.59	17.80	1.55	24.12	11.80	1.88	18.03	8.64	1.93	
	45.19	17.60	2.12	9.20	12.79	0.73	14.65	8.48	1.59	
	9.93	17.60	0.52	12.87	12.85	0.96	17.03	9.22	1.69	
2015	13.36	18.69	0.70	-1.22	14.64	-0.13	1.51	12.55	0.10	-10.09
	8.26	19.54	0.44	-1.74	17.21	-0.12	1.08	13.46	0.06	
	-2.52	19.21	-0.08	1.26	16.48	0.10	-3.97	12.38	-0.34	
	1.40	19.35	0.12	-4.89	15.72	-0.38	-2.87	13.52	-0.20	
	3.39	18.69	0.23	-2.37	15.66	-0.21	-0.16	11.69	-0.09	
2016	27.61	19.17	1.35	26.70	12.91	1.89	18.48	10.26	1.58	14.04
	4.94	18.11	0.30	19.31	14.56	1.23	21.89	10.45	1.89	
	25.94	20.82	1.14	23.95	14.31	1.51	16.56	9.70	1.48	
	6.70	17.07	0.39	27.70	13.37	1.88	19.00	10.03	1.73	
	28.32	16.52	1.55	20.39	12.47	1.43	8.82	10.77	0.76	
2017	13.93	15.16	0.88	43.04	12.47	2.91	34.59	8.68	3.44	14.77
	45.73	16.17	2.47	46.90	12.86	3.10	34.85	8.23	3.64	
	54.04	15.02	2.91	66.13	13.27	3.96	42.44	9.05	3.96	
	50.36	16.90	2.46	47.58	11.14	3.57	34.28	8.94	3.34	
	60.61	14.69	3.26	57.23	13.18	3.52	31.20	8.86	3.07	
2018	7.00	17.78	0.46	5.19	12.90	0.39	4.63	10.14	0.47	-9.18
	14.01	15.91	0.92	-11.85	18.38	-0.67	-10.42	12.17	-0.90	
	6.92	17.69	0.50	-4.38	12.41	-0.32	0.58	8.87	0.05	
	13.56	14.25	0.98	15.40	12.12	1.20	-7.28	12.74	-0.58	
	6.48	15.53	0.47	9.20	14.11	0.72	6.23	10.14	0.63	
全期間 (年化)	21.90	17.11	1.18	23.11	13.29	1.55	18.88	10.23	1.64	5.07
	20.97	16.83	1.15	23.09	14.68	1.42	17.14	10.76	1.43	
	24.20	17.36	1.28	23.85	13.66	1.56	16.40	9.88	1.48	
	27.39	16.85	1.46	21.04	12.99	1.45	16.32	10.77	1.36	
	22.48	16.46	1.25	22.35	13.62	1.47	15.12	10.16	1.34	