

國立政治大學金融學系

碩士學位論文

雙動能策略與權重平滑效果之應用

Application of Dual Momentum Strategy and Weight Smoothing Effect



指導教授：廖四郎 博士

研究生：李芷瑜

中華民國一一一年六月

摘要

過去研究發現資產配置策略對投資組合的貢獻程度高達九成以上；而報酬預測是建構投資組合最核心的議題。本篇論文分析美國 ETF 市場資料，主要探討建構投資組合的策略及工具，創新動能投資策略並善用人工智慧科技的特性設計權重分配的規則，歸因四種投資組合的動能效果及權重效果，最後測試投資組合的穩健性及風險耐受性。戰略性資產配置(Strategic Asset Allocation)藉由動能的訊號產生的事件機率進行大類資產權重配置，能有效降低投資組合的整體風險，說明時間序列動能因子具有風險擇時的能力；戰術性資產配置(Tactical Asset Allocation)使用 Black-Litterman 模型結合長時間短期記憶神經網路轉換報酬分配來提高預測的準確度，其中長時間短期記憶神經網路預測準確率高達六成。研究結果發現，用以決定風險性資產權重的橫截面動能效果非常顯著，即便持有的資產屬於的投資組合類別(例如產業代表性 ETF)，仍有機會透過動能效果增加額外的報酬，其中規避突發風險性衝擊的效果則來自於風險性資產池中納入避險性資產，說明同時具報酬與風險擇時的能力。因此本文建議投資人可以動態方式調整股債的權重來規避風險的衝擊，並搭配橫截面動能策略追求最大化目標報酬。

關鍵詞：資產配置、雙動能投資策略、支援向量機、Black-Litterman 模型、長時間短期記憶模型、動能效果、權重效果。

Abstract

There is evidence that asset allocation strategies contribute more than 90% to investment portfolios, and return prediction is the core issue in portfolio construction. We conducted a data analysis in US ETF market, and focused on portfolio construction strategies and methods, including innovating dual momentum strategies, designing the rules of weight allocation by using the characteristics of artificial intelligence technology, and attributing the momentum effect and weight effect of investment portfolios. Finally, Robustness test and t-student test were used for statistical analysis. Strategic Asset Allocation is weighted based on the probability of events generated by momentum signals, which can reduce the overall risk of the investment portfolio effectively. It shows that time series momentum factor has the ability to market timing. On the other hand, Black-Litterman model combined with LSTM in Tactical Asset Allocation can be used to transform the distribution of returns, and improve the accuracy of prediction. Among them, prediction accuracy of LSTM is about 60%. The empirical results show that cross-sectional momentum effect used to determine the weight of risky assets is very significant. Even though the assets belong to an investment portfolio category (such as ETFs), there is still an opportunity to increase excess returns through the momentum. The principal conclusion was that investors can avoid the impact of risks through allocating the weight of stocks and bonds dynamically, and maximize the target returns by cross-sectional momentum strategy.

Keywords : Asset Allocation, Dual Momentum Strategy, SVM, Black-Litterman Model, LSTM, Momentum Effect, Weighted Effect

目錄

第一章	緒論	1
第一節	研究動機	1
第二節	研究架構	2
第二章	文獻探討	3
第一節	動能因子投資策略	3
第二節	現代投資組合理論	4
第三章	研究方法	6
第一節	研究流程	7
第二節	資料來源及樣本敘述統計	8
第三節	雙動能投資策略	9
第四節	支援向量機分類模型	10
第五節	Black-Litterman 模型	12
第六節	投資組合建構及績效衡量	19
第四章	實證結果	23
第一節	機器學習實證效果	23
第二節	投資組合績效評估	27
第三節	動能因子擇時效果	32
第五章	結論	34
	參考文獻	35

表目錄

表 3-1 標的資產清單	8
表 3-2 標的資產敘述統計	8
表 3-3 投資組合四象限	20
表 3-4 績效衡量指標	21
表 4-1 混淆矩陣	25
表 4-2 樣本混淆矩陣	26
表 4-3 策略績效報表	28
表 4-4 策略績效報表	29
表 4-5 策略月超額報酬統計檢定	31
表 4-6 四象限風險評估	33



圖目錄

圖 3-1 Black-Litterman Model 架構圖	13
圖 3-2 LSTM Model 架構圖	16
圖 4-1 樣本期間	23
圖 4-2 LSTM Model 架構圖	24
圖 4-3 動態策略配置圖	27
圖 4-4 累積報酬回測圖	30



第一章 緒論

第一節 研究動機

在 COVID-19 疫情全球性的擴展下市場動盪難測，人類生活狀態的省思和改變都非同尋常的情況，也造成資產分配決策極具挑戰性和影響力。為了保持社交距離及保障社會健全的發展，付出的代價是經濟活動的急劇減少，金融市場一直在瘋狂地調整以適應這種新的和不確定的現實。面對突發而至的衝擊並歷經後疫情時代的經濟擴張，投資的熱度隨之興起，有趣的現象是，客群與目標的種類出現明顯的劃分，政策推動與數位便利性促使投資族群年輕化；保守的投資人傾向尋求更加穩健的投資組合；退休基金成為長期資金保衛戰，上述種種跡象顯示資產配置的需求更甚過往。以退休基金為舉例，國家發展委員會預計 2025 年台灣將進入超高齡化社會，近 20% 老年人口將成為資產配置領域中主要的需求者。雖然特定目標資產配置需求日增，本研究非以目標資產配置為主軸，而是提供雙動能投資的脈絡，採取 AI 科技融合戰略性策略 (Strategy Asset Allocation) 及戰術性策略 (Tactical Asset Allocation) 的配置，積極透過市場擇時及權重配置手段來應變市場的循環，有效避免動能崩跌的衝擊，並以穩定的投資方式累積資本的需求。

觀察資產配置領域成長的現象啟發了研究的主要方向，研究的工具也在疫情的推動下，選擇以新興人工智能的角度出發，利用機器學習的方式萃取金融市場的特性，在科學的方式下讓資產配置更具智慧性，汲取永續金融、金融創新、普惠金融的精神，本研究希望培養更具深度的思維：疫情的省思轉換成為對投資健康的心態、具有接納新穎想法的智慧以及真正能落實研究的貢獻。綜合以上動機歸納出本研究的方向與目的：(1) 雙動能投資策略規避下方風險的有效性，(2) 機器學習在戰術性策略及戰略性策略配置的穩定性，(3) 檢定並觀察四種投資組合未來的發展性。

第二節 研究架構

本研究以近年來逐漸受到財務學領域重視的行為財務學為切入點，闡述整個投資架構的設計及選取的投資流程。當市場存在雜訊交易者，常常過度反應或不足反應資訊而使股價暫時偏離真實價值，這便可能是動能策略奏效的原因。多數研究討論，投資人短期對市場資訊反應不足，長期易反應過度；抑或是承擔了某種風險而至，非理性的投資人情緒 (Investor Sentiment) 乃造就了無效率的市場環境，對於動能效果所帶來的可觀回報是值得期許的，因此本篇研究選擇以動能作為資產配置的主軸，輔以雙動能策略降低波動度及規避黑天鵝事件的目的來架構整個資產配置的模型。

雙動能策略可拆分為兩個步驟，本研究為兩個階段的步驟設計權重配置的方式。第一個階段為戰略性資產配置框架，使用支援向量機(SVM)二元事件的機率在風險性資產與固定收益資產中作為設定權重的機制；第二個階段屬於戰術性資產配置框架，深入風險性資產類別內的設定標的資產的資金配置，透過 Black-Litterman 模型為多個風險性資產的分配資金權重，其中 Black-Litterman 模型可以加入投資人的觀點進而優化對報酬率的預期，投資人觀點仰賴該投資人對市場環境的主觀見解，為了避免過度自信(Overconfidence)及自我歸因的偏誤，因此選擇通過機器學習的方式來建構觀點矩陣，取以長時間短期記憶神經網路(LSTM)記憶時間序列資料之長處來解構特徵的訊號。以上述兩個步驟建構投資組合，對四種投資組合績效做歸因分析及假設檢定，可以觀察出時間序列動能在戰略性資產配置及橫截面動能在戰術性資產配置的效果。

本文共分為五大章節，第一章為緒論，介紹研究動機、目的及架構；第二章文獻探討模型的發展，主要分為動能投資策略及現代投資組合理論兩個小節；第三章詳細說明研究流程及方法，包含雙動能策略的過程、支援向量機的原理、Black-Litterman 模型的框架、長時間短期記憶神經網路的演算法，最後說明四種投資組合的建構；第四章以實證結果為主，涵蓋機器學習的結果、績效的比較及動能擇時效果的探討；最後第五章為本文的結論。

第二章 文獻探討

第一節 動能因子投資策略

價格偏離的現象時常被視為市場機制的異常，許多因子從一開始擁有超額報酬而後來因子顯著性的消逝，顯示因子發展程度及市場效率性會改善市場異常的現象。Jegadeesh and Titman (1993) 說明「買入過去一段期間股價表現良好的股票，並賣出過去一段時間股價表現不佳的股票」的交易策略有顯著的異常報酬，做為動能投資想法的起源。雖然 Fama and French (2015) 五因子模型中，提出動能因子不具顯著的反駁，但動能的異常現象卻顯現於各商品市場。Menkhoff et al. (2012) 說明橫截面貨幣動量具有反應不足和隨後反應過度的證據，以基本的貨幣交易技術規則顯示報酬略低，並且該基準交易策略與動量策略的相關性是相當小。Asness, Moskowitz, and Pedersen (2013) 在不同的市場及不同資產類別中發現一致的價值和動能報酬溢價，說明價值和動能回報在資產類別之間的相關性更強，但在資產類別內部價值和動量回報彼此呈負相關。

時間序列動能緣起於技術分析的使用，許多研究發現時間序列動能比橫截面的動能效果穩健。Moskowitz, Ooi, and Pedersen (2012) 時間序列動能在許多不同的資產類別中表現相對強勁且一致，風險因素的干擾甚小，且在極端時期表現良好。Bird, Gao, and Yeung (2017) 由於動能信號的訊息集中在收益分佈的尾部，加上橫截面動能在市場熊市時易選擇贏家的股票，反而在市場強勁時選擇虧損的股票，因此建議使用時間序列動能來實現動能效果。儘管動能溢價相當顯著，動能策略仍有幾個實務上的挑戰，包含高周轉率及突發的市場崩跌(Momentum Crash)，對此也有研究透過估計波動度的訊號來降低動能交易的周轉率，及波動度縮放方法(Volatility Scaling Method)來做避險。

Antonacci (2011, 2013, 2017) 首次提出雙動能策略，結合時間序列動能及橫截面動能的策略設計，說明絕對動量(時間序列)和相對動量(橫截面)可以提高回報，但絕對動能在減少波動性和對最大回撤避險的功能相對強大。其中 Antonacci (2017) 文獻

提到雙動能策略的優勢：時間序列動能的持續性有助於降低周轉率；相對動量可以利用上方波動性將其轉化為非凡的回報，同時減少下行波動性相關的潛在風險；雙動能策略提供轉倉的靈活性，且有助於捕捉風險溢酬。

在雙動能策略架構下 Ha and Fabozzi (2022) 提出替代的資產配置框架，以歷史模擬法及蒙地卡羅法對雙動能進行情境測試，並使用多個形成期間建構生命週期基金 (Target Date Funds)。退休基金最大隱憂在於風險性資產在退休時間點前，若遭受巨大損失會導致不良的後果，而動能疊加的方式可以被視為一種退休投資解決方案，反映了動能效果的時間變動性質，有效保護資產的下方風險。本研究基於 Ha, and Fabozzi (2022) 雙動能資產配置的想法，使用機器學習的特性劃分戰略性資產配置及戰術性資產配置的權重設置，並同時對所建構的投資組合進行歸因測試。

第二節 現代投資組合理論

現代投資組合理論 (Modern Portfolio Theory) 發展於 50 至 60 年代，最具代表為 Markowitz (1952) 提出平均數-變異數模型，利用效用函數的凹函數及單調性來隱含投資者對預期報酬及變異數的偏好，說明投資人不應以極大化報酬率為目標，並同時考慮報酬與風險組合進行權重的調整。在所有可投資組合中，尋找給定投資組合報酬下極小化變異數的標的權重，或是尋找給定投資組合變異數下極大化報酬的標的權重，此部分投資組合所形成集合稱為效率前緣 (Efficient Frontier)。

平均數-變異數模型排除投資人對高階動差的生疏，利用一階動差及二階動差的統計量足以框架整個投資組合模型的架構，使建構投資組合在理論上深具財務經驗的意義，被廣泛運用於資產配置領域中。然而實證下，單純使用平均數-變異數模型的效果不佳，Frost and Savarino (1988) 提及原因可能來自於對報酬與風險的未知，必須仰賴估計方式來建構模型，並說明對投資組合設定權重上限可以減少估計偏差以提高投資組合的績效，歷史估計不適合做為平均數-變異數模型唯一的輸入；另外研究顯示期望報酬率的微小調整會導致平均數-變異數模型中最優投資組合發生巨大變化的趨

勢，Black and Litterman (1990) 透過國際資產配置模型來說明參數敏感度的解決方法。在估計誤差未調整下，Eichhorn, Gupta, and Stubbs (1998) 建議使用限制式來降低估誤差的敏感性。Scherer (2002) 透過投資組合重新採樣的方式，說明效率前緣的演算法傾向選擇具有吸引力特徵(高報酬、低風險或低相關性) 的資產，因此該過程最大化了估計誤差對投資組合的影響。

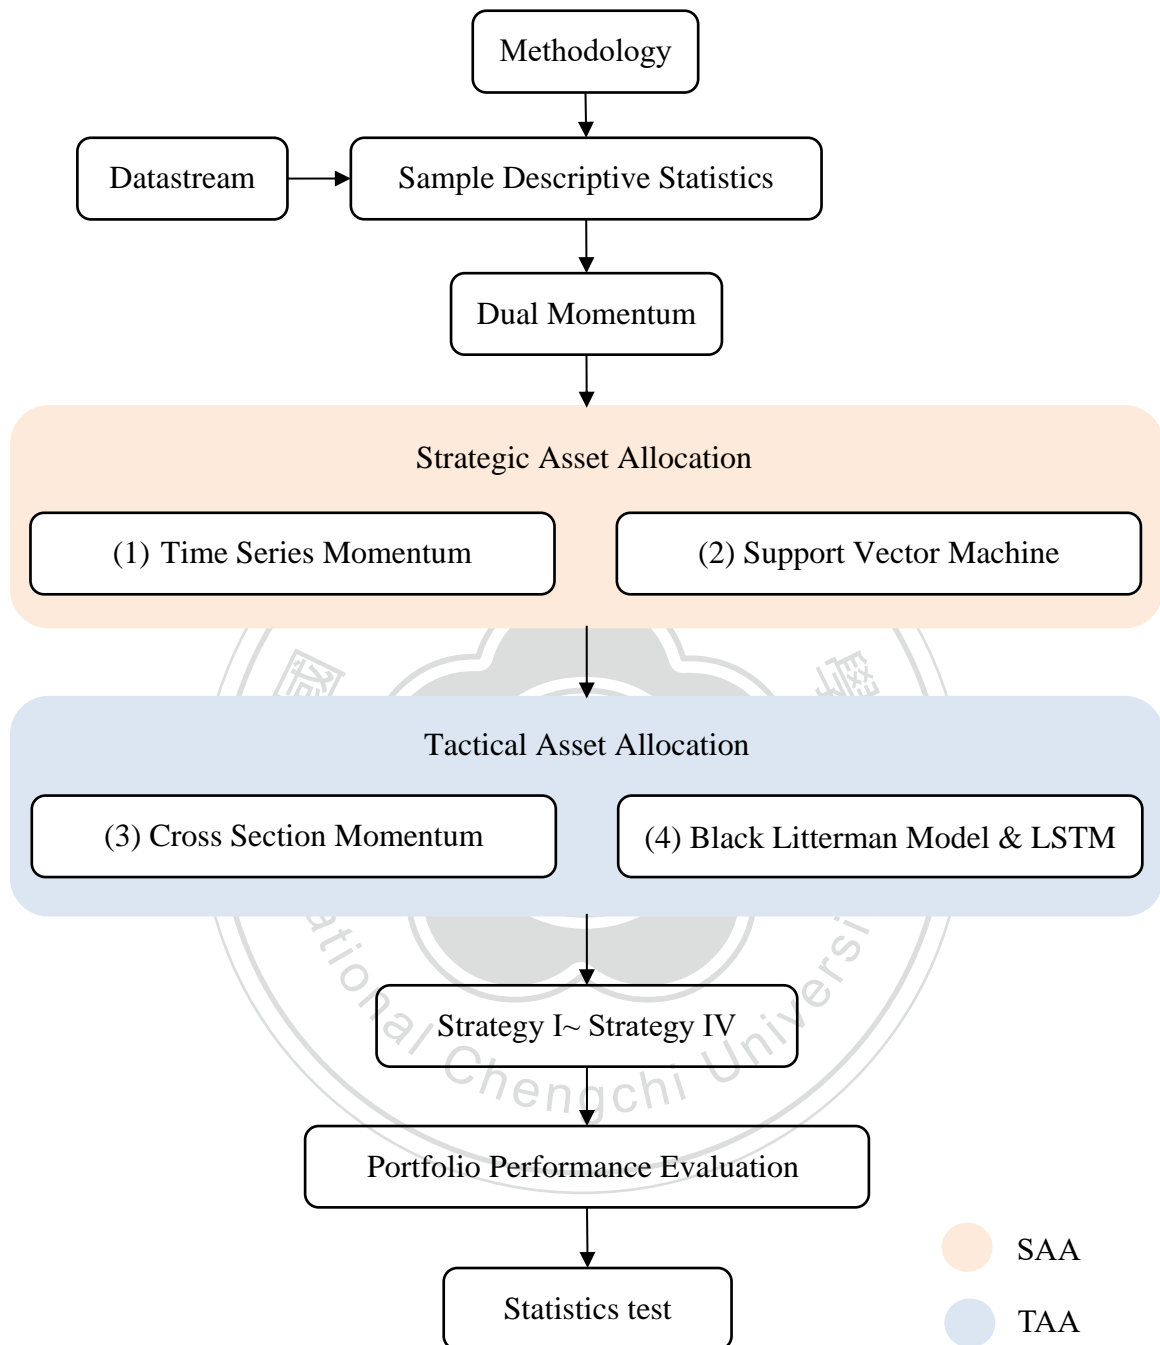
經過相關文獻探討後，可以發現 Markowitz (1952) 存在許多實務上限制，同時多數研究亦提供模型優化的解決方法。為了可以同時考慮估計式及限制式的影響程度，本研究採用 Black and Litterman (1992) 提出 Black-Litterman 模型，模型提供輸入投資人前景觀點的管道，貝式定理協助在歷史資訊與未來預期觀點中重新平衡估計度量，來優化投資人對報酬率及波動度的資訊。最佳化過程使用夏普比率做為目標函式，並設定投資組合不得有放空部位，將此模型設計為投資策略權益資產權重平滑的過程。

第三章 研究方法

本章內容區分為六小節，第一節說明整體研究框架。第二節說明資料來源及樣本敘述統計。第三節以雙動能投資策略建構基準投資組合。第四節介紹支援向量機在雙動能策略中時間序列動能(time-series momentum)上權重的應用。第五節介紹 Black-Littman 模型結合長時間短期記憶神經網路建構投資人看法矩陣，並將模型使用於橫截面動能(cross-sectional momentum)的權重配置，以及最佳化投資策略的方法。第六節總結以雙動能策略基礎下建構四種的投資組合，衡量本篇研究所建構的投資組合是否超越大盤，以及設定四種投資組合績效統計量化分析的方式與標準。



第一節 研究流程



備註 1：戰略性資產配置(Strategic Asset Allocation, SAA)屬於大類資產決定權重配置的框架，在本文分為固定收益資產及風險性資產；戰術性資產配置(Tactical Asset Allocation, TAA)屬於在特定大資產類別中決定配置標的資產的過程，在本文中主要探討風險性資產類別。

備註 2：策略I由(1)Time Series Momentum 及(3) Cross Section Momentum 權重配置工具組成；策略II由(2) Support Vector Machine 及(3) Cross Section Momentum 權重配置工具組成；策略III由(2) Support Vector Machine 及(4) Black Litterman Model & LSTM 權重配置工具組成；策略IV由(1)Time Series Momentum 及(4) Black Litterman Model & LSTM 權重配置工具組成。

第二節 資料來源及樣本敘述統計

本篇研究資料來源於 Data-Stream，樣本期間為 2007 年 1 月 1 日至 2022 年 3 月 31 日，使用月報酬頻率資料，投資組合再平衡以一個月為單位。本研究參考 Ha and Fabozzi (2022) 文獻概念，選擇美國市場中流動性較高、不同產業特性代表的四檔 ETF 作為權益類別的標的資產，債券標的資產為 iShares iBoxx \$ Inv Grade Corporate Bond ETF (LQD)，其中商品代號、名稱及代表的資產類別如(表 3-1)所示。

表 3-1 標的資產清單

代號	商品名稱	代表資產類別
LQD	iShares iBoxx \$ Inv Grade Corporate Bond ETF	債券
QQQ	NASDAQ- 100 Index Tracking Stock ETF	科技
MDY	S&P MidCap 400 Index ETF	小型
GLD	SPDR Gold Shares ETF	黃金
XLFF	Financial Select Sector SPDR ETF	金融

表 3-2 標的資產敘述統計

	LQD	QQQ	MDY	GLD	XLFF
Mean (% per month)	0.091957	1.292976	0.789837	0.682168	0.366264
Std (% per month)	2.161062	5.209226	5.280049	5.003178	6.757716
Correlation					
Bond	1.000000	0.321469	0.333460	0.284579	0.244472
NQ100	0.321469	1.000000	0.839042	0.038016	0.703628
SP400	0.333460	0.839042	1.000000	0.072652	0.837600
GOLD	0.284579	0.038016	0.072652	1.000000	-0.069832
FIN	0.244472	0.703628	0.837600	-0.069832	1.000000

使用機器學習的統計方法作為建構投資組合的工具，選取 CBOE Volatility Index(VIX)、Yield Spread (T10Y3M)、Tips Spread (T10YIE)三大經濟指標來描述市場狀態，並加入上述各自資產的動能因子作為特徵因子資料，三大經濟指標資料來源為 Federal Reserve Economic Data (FRED)。表 3-2 為標的資產全樣本月報酬率的敘述統計，由平均數及標準差觀察可見，債券型 ETF 的歷史波動度與報酬相對權益型 ETF

低，QQQ 擁有最高的平均報酬率。有趣的是，XLF 金融資產類股 ETF 作為穩定投資組合價值波動的功能，在歷史數據中反而具有相對高波動度和相對低報酬率，並與黃金 ETF 呈現負相關性，而黃金與其他資產相關性非常低，兩者不同特性的資產類別期許在投資組合中，適應不同狀態發揮其避險的功能。

第三節 雙動能投資策略

Antonacci (2017) 價格動能在僅做多的策略下高度依賴市場狀態，當以多頭動能作為進場依據時，只有在相對動能與絕對動能皆為正時才需要做多，提出結合相對動能和絕對動能稱之為雙動能策略。Ha and Fabozzi (2022) 將雙動能投資策略使用於資產配置的領域，並對假設資本市場股債反向相關，說明特定時段的資產報酬率若高於固定收益資產報酬時，則時間序列動能為正，反之為負的時間序列動能。當時間序列動能為正時，持有該風險性資產的長部位直到時間序列動能訊號轉為負；當時間序列動能轉為負時，則賣出原有風險性資產的長部位，並轉而持有固定收益資產的長部位，過程中僅於動能出現訊號時改變資產的配置，交易演算法如下：

$$\text{if } \prod_{t=j}^{j+n} R_{t,i} > \prod_{t=j}^{j+n} R_{f,t}, \text{ then } R_{t+1},$$
$$\text{otherwise } R_{f,t+1},$$

其中 i 為風險性資產； R_f 為固定收益資產代表； n 為過去 n 個期間的累積報酬率。

當時間序列動能為正，即將所有資產 100% 配置在風險性資產中，固定收益資產的資金權重為 0%，此時啟動橫截面動能做為第二階段的動能訊號，進行風險性資產中的資產配置，因此，股債配置的基礎建立在時間序列的訊號上。

當啟動橫截面動能的訊號時，便是在風險性資產中決定各個資產的權重，同樣以動能因子的正訊號作為配置資產決策的依據，Antonacci (2017) 選擇以該期表現最佳的風險性資產做為下一期投資的標的。總結上述雙動能策略步驟，第一步驟先判斷時間序列動能的正或負，當該期所有風險性資產都是負的時間序列動能時，下一期即

100%投資於固定收益資產中；當任何一風險性資產顯示正的時間序列動能訊號時，下一期即投資於價格動能表現最強勁(橫截面動能為正)的標的，演算法如下：

$$\forall i, \text{ if } \prod_{t=j}^{j+n} R_{t,i} \leq \prod_{t=j}^{j+n} Rf_t, \text{ then invest } Rf_{t+1},$$

$$\exists i, \text{ if } \prod_{t=j}^{j+n} R_{t,i} > \prod_{t=j}^{j+n} Rf_j, \text{ then invest } \max \{R_{t+1,i}\},$$

and get a return at $t + 2$ of that security,

其中*i*為第*i*個風險性資產，*n*為過去*n*期的累積報酬。

本篇研究以雙動能投資策略建構投資組合，基準投資組合依照雙動能投資的方式根據動能訊號來轉移資產的類別，基於月頻率下再平衡投資組合。考量市場波動劇烈時訊號可能在短期內反轉多次，所產生的資產流動性及資金移轉的成本，因此本篇研究結合支援向量機分類模型及 Black-Littman 模型改變雙動能策略配置權重的方式，透過機器學習及資產配置模型來平滑資金權重集中度的問題。

雙動能策略分為兩大投資步驟，兩大步驟皆以動能為出發點做資產配置，雖然 Antonacci (2017) 提及雙動能策略可以大量降低周轉率，但以共同基金或退休基金的規模而言，大規模資金轉移可能造成市場流動性問題，也會產生可觀的交易成本，反而抵銷了大部分動能溢價所帶來報酬。因此為了降低在同一個時間點大量資金的轉移對投資組合及市場所產生的衝擊，本篇研究以動能作為特徵因子，與雙動能策略最大的不同在於，透過模型加入資產未來的狀態形成今日的預期報酬，大類資產配置使用支援向量分類模型及風險性資產配置使用 Black-Littman 模型，分別產生兩階段資產的權重，於下兩節分別介紹兩種模型及兩種模型建構的投資組合所參與的重要環節。

第四節 支援向量機分類模型

雙動能策略首先考慮時間序列動能，兩種代表性資產包含風險性資產及固定收益資產類別，上一節提到當時間序列動能訊號改變時，資金全數在風險性資產及固定收

益資產進行轉移，在股債反向變動的前提下，我們預期兩種資產所代表的市場屬性不同。風險性資產動能強勁背後反應的是相對低利率環境、經濟規模持續擴張且資本市場相對穩定成長的狀態；而固定收益資產動能強勁，則表示利率環境相對緊縮、借貸成本上升、經濟和資本市場緩步成長。對此選擇透過分類器對資產狀態做預期，將代表性的總體經濟指標包含 CBOE Volatility Index(VIX)、Yield Spread (T10Y3M)、Tips Spread (T10YIE)，並加入個別標的資產三個月的動能因子作為對經濟環境狀態的描述，以預測未來一個月風險性資產與固定收益資產的表現。

本篇研究選擇支援向量機作為分類模型，支援向量機 (Support Vector Machine, SVM) 是由 Cortes and Vapnik (1995) 提出，是一種基於統計學習理論基礎的機器學習模型，針對小樣本、非線性、高維度與局部最小點等問題具有相對的優勢。承如 Israel, Kelly, and Moskowitz (2020) 提及金融市場具有相對為小樣本(應變數數量)及低信噪比(Signal-to-noise Ratios)的特性，因此研究工具選擇非傳統的統計模型，而是選擇以機器學習作為分析的工具，希望透過支援向量機可以捕捉非線性關係的特性，替複雜多變的金融市場進行分類。

支援向量機屬於監督式學習，以當前時刻的一組總體經濟數據，加上四檔權益資產及一檔債券資產過去三個月動能作為支援向量機的特徵因子，並預測一個月後權益市場及債券市場的相對表現。支援向量機的預測值設定如下：

$$Y = \begin{cases} 0, & \text{時間序列動能為負} \\ 1, & \text{時間序列動能為正} \end{cases}$$

輸入測試集特徵資料，分類器將資料轉化為該組樣本發生於二元類別的機率，且二元類別機率總值為 1，機器學習多數預設 0.5 作為分類機率的閾值，並回傳估計值 0 或 1。上一節提及，研究希望透過機器學習建立資產權重分配的機制，所採用的估計數據改以使用該組數據對應的二元類別發生的機率值。可以合理的解釋，當估計值為 1，發生時間序列動能為正的機率大於 0.5，即權益市場動能相對債券市場動能強

動的機率大於 0.5，將其機率的特性轉化成資產配置的權重，符合權重總和為 1 在資產配置上的要求，同時可以描述當投資人相信事件發生所估計的機率，直觀的將機率對應比重的資源配置在該事件上。舉例來說，當時間序列為正的機率為 0.65，該機率大於 0.5 回傳估計值為 1，策略對權益市場的權重配置不為 1，而是採取機率 0.65 作為權重配置的比例。

第五節 Black-Litterman 模型

上一節說明如何設計第一個階段時間序列動能在權重上平滑的方式作為大類資產配置的過程，尚未決定如何配置橫斷面動能在權益市場下權重的機制。本章節介紹 Black-Litterman 模型結合機器學習的方式，建立風險性資產內各資產權重分配方式。Black-Litterman 模型最初由 Black and Litterman (1990) 提出，由 Sharpe (1964) 提出 CAPM 及 Sharpe (1974) 逆向最佳化(reverse optimization)推算當前市場的狀態，加入投資人對各資產未來的觀點來調整對報酬的預期，以及結合 Markowitz (1952) 平均數-變異數架構，降低投資組合的敏感度及優化投資組合的權重配置。

在 Markowitz (1952) 平均數-變異數架構中，實證結果常有權重過度集中化於特定標的的問題，模型對估計參數包含預期報酬率及共變異數也具有高度參數敏感性，即當預期報酬與相關係數微幅變動時，會發生權重劇烈變動的現象。Frost and Savarino (1988) 文獻指出歷史估計的預期報酬率有高估的現象，而共變異數矩陣則有低估的狀況，Scherer (2002) 投資組合權重傾向配置在高估報酬及低估變異數的標的。Chopra and Ziemba (2013) 文獻指出估計報酬平均數的平均誤差是估計變異數及共變異數的十倍，變異數平均估計誤差是共變異數的兩倍，因此在平均數-變異數架構下最佳化權重可能有 estimation-error-maximization 的現象。

基於上述因素，選用 Black-Litterman 模型結合長時間短期記憶神經網路，改變過往對未來報酬預測的方式，採用預測上漲或下跌及漲跌的幅度，善用 Black-Litterman 模型可加入投資人觀點的特性，來調整我們對標的表現的預期。長時間短期記憶神經

網路(Long-Short Term Model, LSTM)可以學習不同時點之間的資料相關性，並將跨時間點資訊壓縮成低維度的訊號進行特徵萃取，使用機器學習分析提高預測的準確度。

Idzorek (2007) 首度以實際數據逐步分析 Black-Litterman 模型(圖 3-1)，本章節參考該文獻將模型流程分成三大部分介紹。首先，介紹先驗分配的參數估計及隱含市場報酬概念；其次，說明如何透過長時間短期記憶神經網路將投資人觀點收納，並形成觀點矩陣；接著，介紹以貝氏估計結合預期報酬的先驗機率分配與投資人的觀點機率分配，兩者加權後形成的後驗分配；最後介紹導出後驗分配後所選用投資組合優化器。

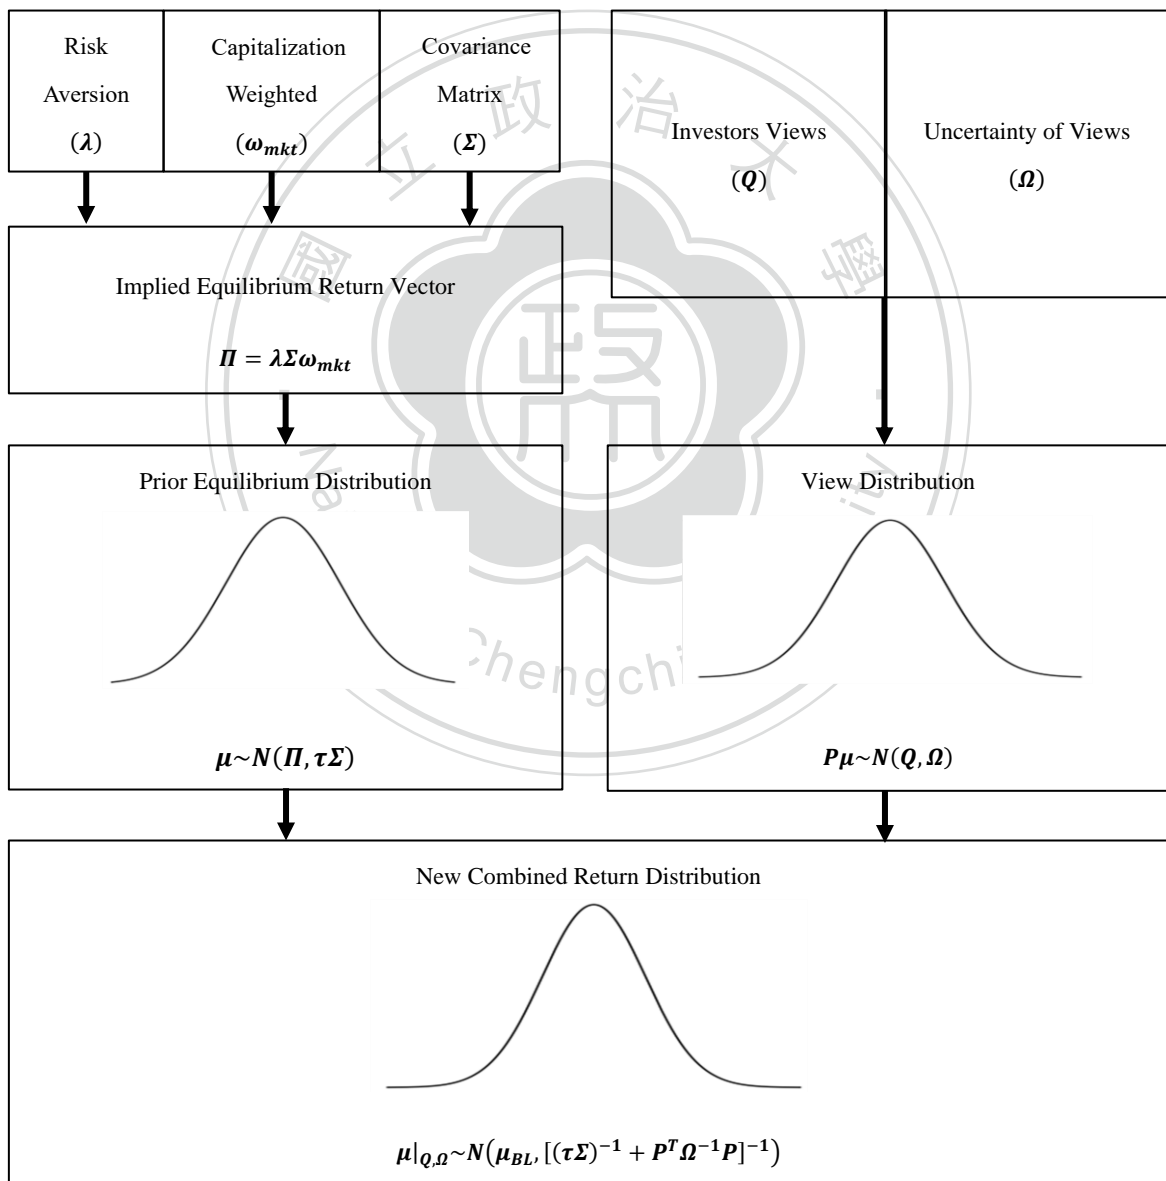


圖 3-1 Black-Litterman Model 架構圖

一、 預期報酬率的先驗分配

投資組合有 N 種資產，其收益率為 $R = \{R_1, R_2, \dots, R_N\}$ ，假設 N 種資產的報酬率服從聯合常態分配，即 $R \sim N(\mu, \Sigma)$ ，其中 μ 、 Σ 為各資產預期收益率及共變異數的估計值。現在假設估計向量也是隨機變數(式 3.1)，並服從常態分配：

$$\mu \sim N(\Pi, \tau\Sigma) \quad (3.1)$$

其中 Π 為先驗預期收益期望值的平均數，為市場均衡超額報酬向量，是 μ 的估計值。 τ 為調整因子，代表估計值的不確定性，通常設為樣本數的倒數，若無估計誤差則 $\tau = 0$ 。

參數估計的準確度及有效性會決定模型的穩定性，為了解決平均數-變異數模型對參數敏感度的問題，先後有學者提出不同估計報酬的形式，例如歷史報酬估計、調整風險後報酬估計、各資產平均報酬估計等，Black and Litterman (1992) 透過實證顯示，投資組合最佳化的過程缺少限制式狀態下，將導致投資組合出現極端權重，也不符合實務權重配置的需求。基於歷史資料建構的基礎，我們相信過去各資產收益率的分佈能複製到未來，但現實中的黑天鵝事件或未預期的變化可能導致市場反應不同於歷史狀態，使模型效用未如預期。然而後續研究非摒棄平均數-變異數模型的價值，轉而以平均數-變異數模型作為市場均衡的出發點，以各資產在市場的份額反推市場要求的隱含報酬率，該基礎即為 Markowitz (1952) 架構下的最佳化效用函數(式 3.2)：

$$\max_{\omega} \omega^T \mu - \frac{1}{2} \omega^T \lambda \Sigma \omega \quad (3.2)$$

μ ： N 個資產的預期報酬率的向量。

ω ：投資組合 N 個資產的權重向量。

Σ ：報酬率的共變異數矩陣。

λ ：風險趨避係數(例如： $\lambda = 2.24$)。

假設預期報酬率及共變異數矩陣非經投資人觀點做調整，將最佳化目標式直接帶入 μ 、 Σ 、 λ 已知參數即可得封閉解 ω^* (式 3.3)，其中 λ 在本中 Donthireddy (2018) 設定為 2.24，屬於平均投資人的風險偏好。

$$\omega^* = (\lambda\Sigma)^{-1}\mu \quad (3.3)$$

若假設投資人在市場均衡狀態下，皆持有市值加權的投資組合，以市值加權計算各資產市場權重比例可得 ω_{mkt} ，使用逆向最佳化方式帶入 ω_{mkt} 、 Σ 、 λ ，反推導可得隱含報酬率 Π (式 3.4)，隱含報酬率代表投資人在不具有任何投資觀點且市場均衡的狀態下，持有市值加權投資組合所要求的投資報酬率，同時也作為先驗分配估計式。

$$\Pi = \lambda\Sigma\omega_{mkt} \quad (3.4)$$

二、長時間短期記憶神經網路

Black-Litterman 模型的核心特色，可以加入投資人的主觀預期，在預測階段同樣選擇使用機器學習的模型，長時間短期記憶神經網路在預測模型中屬於更複雜且非線性的統計模型，可以記憶特定時間長度的數值，區塊中設有閘門構造能夠決定輸入資訊是否重要到能被記住及能不能被輸出。LSTM 結構中包含遺忘門(Forget gate)、輸入門(Input gate)、記憶單元(Memory cell or Cell state)及輸出門(Output gate)，通過三個控制門決定訊息的儲存以及遺忘，改善了循環神經網路(RNN)在訓練過程時，持續傳遞記憶而可能出現的梯度消失或爆炸問題。

三個閘門中，遺忘門(f_t)過濾並控制過去記憶的訊息(c_{t-1})是否繼續被記憶或遺忘；輸入門(i_t)控制當期新的訊息進入記憶單元的多寡；記憶單元(c_t)可以透過遺忘門及輸入門來更新舊的與新的資訊，保留重要訊息並繼續傳遞至輸出閘門；最後輸出門(o_t)決定 LSTM 單元輸出結果(h_t)。LSTM 單元組成元素的數學式如下：

$$f_t = \sigma_g(W_f[x_t, h_{t-1}] + b_f)$$

$$i_t = \sigma_g(W_i[x_t, h_{t-1}] + b_i)$$

$$o_t = \sigma_g(W_o[x_t, h_{t-1}] + b_o)$$

$$c_t = f_t \otimes c_{t-1} + i_t \otimes \sigma_c(W_c[x_t, h_{t-1}] + b_c)$$

$$h_t = o_t \otimes \sigma_h c_t$$

LSTM 傳輸原理繼承神經網路資料傳輸模式，經過前向傳播法(Forward Propagation)得到模型輸出值，由輸出值與實際標籤組相互對應，再進行反向傳播法(Back Propagation)調整模型參數值包含權重(W)及偏差值(b)，資料可以透過批次(Batch Size)訓練來決定模型更新參數的次數，直到所有樣本集完成一次訓練(Epoch)，並經過多次重複的訓練過程，LSTM 結構如(圖 3-2)所示。

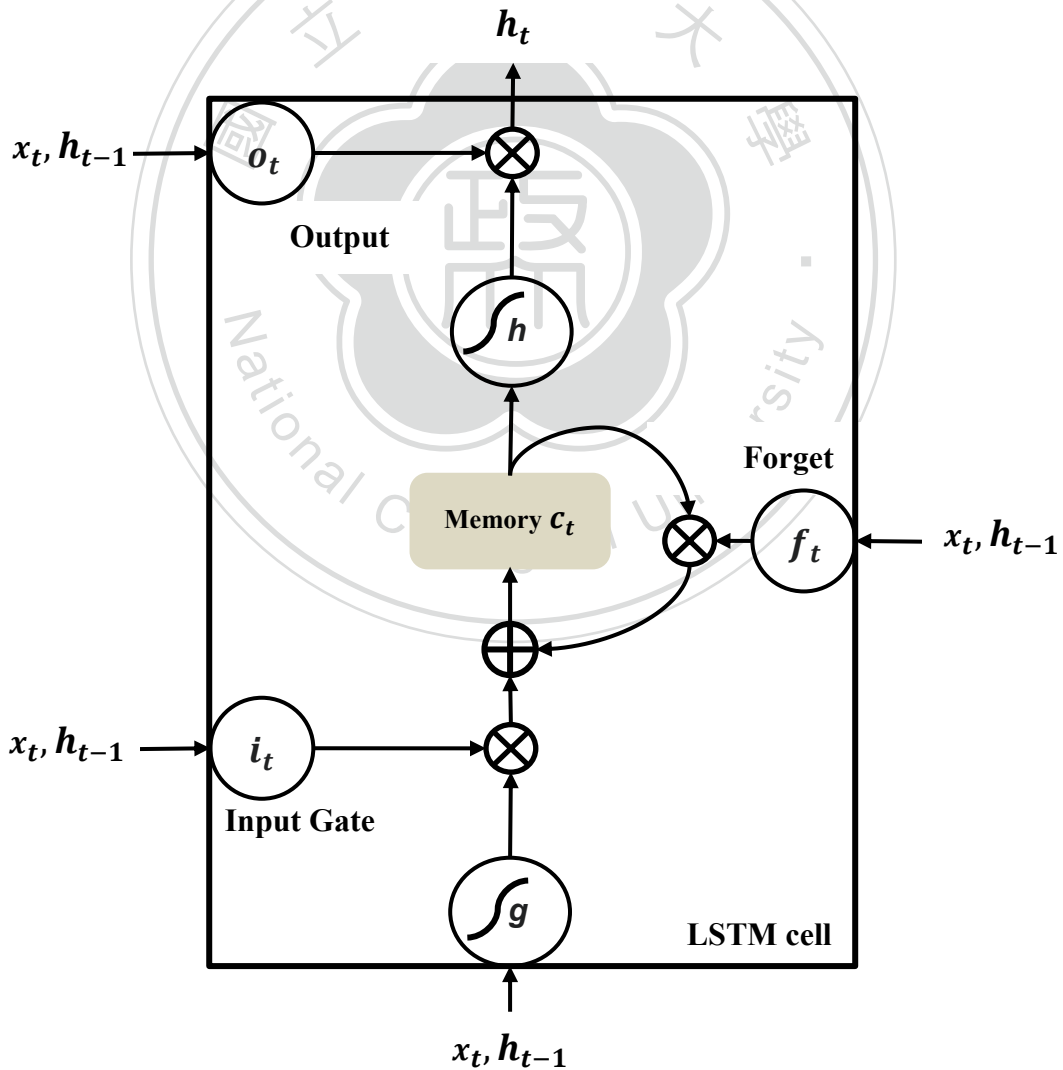


圖 3-2 LSTM Model 架構圖

三、 投資人觀點矩陣

投資人觀點可區分為絕對觀點(Absolute views)及相對觀點(Relative views)，本文以長時間短期記憶神經網路作為預測資產未來表現的工具，因此主要使用絕對觀點的模式建構觀點矩陣，觀點矩陣表達如(式 3.5)：

$$P\pi = Q + \varepsilon \quad \text{or} \quad P\mu \sim N(Q, \Omega) \quad (3.5)$$

P：觀點係數矩陣， $K \times N$ 矩陣。

π ：N個資產的預期報酬， $N \times 1$ 行向量。

Q：K個觀點的預期報酬， $K \times 1$ 行向量。

ε ：K個觀點的誤差項， $K \times 1$ 行向量， $\varepsilon \sim N(0, \Omega)$ 。

其中 Ω 為看法向量Q的共變異數矩陣，表示投資者的觀點與真實情況的差距，本文使用 He and Litterman (1999) 設定 $\Omega = \text{diag}(P(\tau\Sigma)P^T)$ ， Ω 為 $K \times K$ 的對角矩陣。

形成投資人觀點矩陣的預測觀點採用 Donthireddy (2018) 提出的方法，根據市場的波動性來設置Q矩陣，考量報酬率具隨機漫步的特性，在直接預測上有一定的難度，因此採用錨定效果的方式，透過市場均衡作為起始點的，投資人從當前市場均衡開始，加入預期對資產未來價格變動的方向及幅度，模型預測的參數是在預期報酬率下未來波動度的方向及幅度，以方程式(式 3.6)表示：

$$Q(\kappa) = (P\pi)(\kappa) + \eta_{\kappa}\sqrt{(P\Sigma P^T)(\kappa, \kappa)}, \quad \kappa = 1, 2, \dots, K \quad (3.6)$$

其中 $\eta_{\kappa} \in \{-2, -1, 1, 2\}$ ，分別定義為劇烈看跌、看跌、看漲、劇烈看漲。因此模型預測參數為 η_{κ} ，為了使預測具效率性，使用二元預測為基礎，並將 η_{κ} 分為兩階段預測。首先預測報酬未來的方向是上漲或下跌，以 Y_1 作為預測變數；其次搭配預期報酬上漲或下跌方向的幅度，以 Y_2 作為第二個預測變數，以 $\eta_{\kappa} = Y_1 \times Y_2$ 呈現共有四種預測組合，兩階段預測值設定如下：

$$Y_1 = \begin{cases} 1, & \text{預期報酬為正} \\ -1, & \text{預期報酬為負} \end{cases}$$

$$Y_2 = \begin{cases} 1, & Z_t = \frac{|R_t - \bar{R}_{t,22}|}{\sigma_{t,22}} \leq 1 \\ 2, & Z_t = \frac{|R_t - \bar{R}_{t,22}|}{\sigma_{t,22}} > 1 \end{cases}$$

四、 預期報酬率的後驗分配

結合預期報酬期望值的先驗分配及投資者觀點分配，經過 Bayesian Theorem 推導預期報酬期望值的後驗分配。即當投資人具有特定資產觀點時，主觀觀點可以影響先驗資訊的比重。我們可以由方程式觀察， $(\tau\Sigma)^{-1}$ 為來自先驗分配資訊的比重， $P^T\Omega^{-1}P$ 為投資人對主觀看法的重視程度，因此對兩者分配的信心程度將決定預期報酬期望值後驗分配調整後的型態，後驗分配如(式 3.7)：

$$\mu|Q,\Omega \sim N(\mu_{BL}, \Sigma_{BL}^{\mu}) \quad (3.7)$$

$$\mu_{BL} = [(\tau\Sigma)^{-1} + P^T\Omega^{-1}P]^{-1}[(\tau\Sigma)^{-1}\pi + P^T\Omega^{-1}Q]$$

$$\Sigma_{BL}^{\mu} = [(\tau\Sigma)^{-1} + P^T\Omega^{-1}P]^{-1}$$

最後我們將預期報酬期望值的後驗分配轉換為預期報酬率的後驗分配 (Posterior Distribution)，其中 Z 為誤差項， $Z \sim N(0, \Sigma)$ 。預期報酬率後驗分配變異數為預期報酬率的變異數加上預期報酬期望值後驗分配的變異數，後驗分配為(式 3.8)：

$$R|Q,\Omega \sim N(\mu_{BL}, \Sigma_{BL}) \quad (3.8)$$

$$R|Q,\Omega = \mu|Q,\Omega + Z$$

$$\Sigma_{BL} = \Sigma + \Sigma_{BL}^{\mu}$$

五、投資組合優化器

經由 Black-Litterman 模型，以過去資訊為基準加入未來觀測的預期，使投資人不再定錨於已發生的訊息，重新評價對報酬的分佈。最後本篇以夏普比率(式 3.9)作為投資組合最佳化的目標函數，考量該投資組合可以使用於儲蓄型資產配置或退休基金等投資策略，演算法中加入不得放空的限制，且權重總和為 1。而 Black-Litterman 模型運用於雙動能投資策略中雖存在平滑權重的功能，但並非強烈限制權重需均衡分配，因此對單一投資標的不設定權重比例上限。

$$\begin{aligned} \max_{\omega} \quad & \frac{\omega^T \mu}{\omega^T \Sigma \omega} \\ \text{s.t.} \quad & 0 \leq \omega \leq 1, \quad \omega^T = 1 \end{aligned} \quad (3.9)$$

第六節 投資組合建構及績效衡量

總結上述研究方法將本章節分為三個部分做討論。首先介紹上述研究方法所建構的投資組合，投資策略建構基礎參考 Brinson, Hood, and Beebower (1986) 的象限結構，將雙動能投資策略兩階段投資過程透過權重配置機制的重新組成四個投資組合。接著介紹如何衡量四種投資組合的績效、風險及報酬狀態。最後說明如何採取量化分析的方式評估投資策略的特性及預期的效果。

一、投資策略建構投資組合

本研究論文以 S&P500 成分類股作為選股參考的資產池，但並非直接選用 S&P500 中的成分股作為資產標的，而是以產業為代表來選取代表性產業標的，包含納茲達克 100 ETF 科技類股指標、S&P400 ETF 中小型類股、黃金 ETF 以及金融類股 ETF，其中以黃金及金融為權益市場的避險標的，作為權益市場的抗跌的保護機制；而投資等級公司債 ETF 則作為債券市場的代表。

雙動能策略在 Ha and Fabozzi(2022) 文獻中說明兩階段對債券市場及資本市場的投資策略皆以全數投入資本作為資產配置的方式，在本篇論文中稱之為資金全投入的類別(Weighted All In)；當資產配置的金額非常龐大時，大量的資金移轉可能會帶來巨大的交易成本，因此通過上述研究方式，考量兩階段權重配置的特性與適用性，分別使用支援向量機及 Black-Litterman 模型來改變資產權重的完全集中度，透過其他工具配置權重的投資方式，將此類別稱之為權重平滑的類別(Weighted Smooth)，表 3-3 為投資策略四象限的框架。最後說明設定的研究目的，預期兩階段的權重效果是否能捕捉超額溢酬、達成保護下檔風險、降低交易成本等功能。

表 3-3 投資組合四象限

		Tactical Asset Allocation	
		Cross Section Momentum (Weighted All In)	Black-Litterman Model (Weighted Smooth)
Strategy Asset Allocation	Time Series Momentum (Weighted All In)	Strategy I	Strategy IV
	Support Vector Machine (Weighted Smooth)	Strategy II	Strategy III

- 策略I: 當時間序列動能訊號為負值時，100%資金投資於債券 ETF；當時間序列動能訊號為正時，資金全數轉為投入權益市場，並 100%投資於橫截面動能訊號為正的權益市場標的 ETF。
- 策略II: 定義以支援向量機預測取得的二元事件發生機率，作為大類資產配置的權重配置比例，其中權益市場時間序列動能為正的機率所對應的權重比率，以該比例全數投資於橫截面動能為正的資產 ETF。

- 策略III: 定義以支援向量機預測取得的二元發生機率，作為大類資產配置的權重配置比例，其中風險性資產內以 Black-Litterman 模型來配置權益市場的資產權重。
- 策略IV: 當時間序列動能訊號為負值時，100%資金投資於債券 ETF；當時間序列動能訊號為正時，資金全數轉為投入權益市場，並以 Black-Litterman 模型來配置權益市場的資產權重。

二、 投資組合績效評估標準

上述提及研究基於參考 S&P500 成分類股代表性產業來選取樣本，因此所建構的四個投資組合皆同時以 S&P500 Index ETF 作為基準投資組合(Benchmark Portfolio)，分別以下表中的績效評估標準來衡量。報酬狀態以累積報酬率、平均年化報酬率來衡量；風險估計指標為年化標準差及最大回測比率(MDD)；風險調整後報酬比率包含夏普比率(Sharpe Ratio)、索提諾比率(Sortino Ratio)、卡瑪比率(Calmar Ratio)、資訊比率(Information Ratio)；最後計算投資組合交易成本的承受度。表 3-4 呈現各績效評指標：

表 3-4 績效衡量指標

投資組合績效指標	指標公式
累積報酬率	$\tilde{r} = \prod_{t=1}^T (1 + r_t) - 1$
平均年化報酬率	$\bar{r} = \frac{1}{T} \sum_{t=1}^T r_t$
年化標準差	$\sigma = \sqrt{\frac{1}{T} \sum_{t=1}^T (r_t - \bar{r})^2}$
最大回測比率	$MDD = \max_{\tau \in (0, T)} (0, \max_{t \in (0, \tau)} (0, -r_{\{t, \tau\}}))$
夏普比率	$Sharpe Ratio = \frac{\bar{r} - r_f}{\sigma}$
索提諾比率	$Sortino Ratio = \frac{\bar{r} - r_f}{DR}$
卡瑪比率	$Calmar Ratio = \frac{\bar{r} - r_f}{MDD}$
資訊比率	$Information Ratio = \frac{\bar{r}_{portfolio} - \bar{r}_{benchmark}}{\sigma_{p,b}}$

三、 數據結果量化分析方法

上述績效評估方式初步提供投資人識別投資組合優劣的基準，進一步可以通過統計檢定來證實投資組合建構的策略具有特定特徵的統計顯著性。前述說明投資組合以月頻率再平衡其權重，並以樣本外期間的月報酬作為樣本點，因此四象限的投資組合同時各自擁有相同數量的樣本點。本研究以 t 檢定(Student's t-test)來分析，一個假設為四個投資組合相對於基準投資組合超額報酬的顯著性；同時也測試不同類別資產的權重效果及同一類別資產內的權重效果。預期雙動能投資策略超額報酬具有統計顯著性，並且透過權重平滑的兩種方式在四種投資組合間顯著創造具有報酬溢價的投資策略。本文設定的統計假設：(1)四種投資組合相對於基準投資組合超額報酬是否異於零。(2)四象限組間或組內權重配置的效果是否有效捕捉超額報酬。



第四章 實證結果

第一節 機器學習實證效果

一、 機器學習的樣本區間

樣本全區間為 2007 年 1 月 1 日至 2022 年 3 月 31 日，以約 8：2 切割樣本全集，訓練集資料為 2007 年 1 月至 2018 年 12 月；測試集資料為 2019 年 1 月至 2022 年 3 月。其中訓練集資料包含 2008 年金融風暴、2011 年歐債危機、2018 年升息及貿易戰等多次空頭危機，測試集資料則包含 2020 年疫情重創下的發生四次熔断的股災。兩區間樣本同時都涵蓋牛市及熊市的股市環境，希望更貼切刻劃同一種模型對不同時期經濟環境的適應性。圖 4-1 為樣本採用區間。




圖 4-1 樣本期間

二、 模型架構與參數設定

投資策略建構過程中所使用的兩種機器學習模型皆使用二元類別預測。而許多研究相信，總經指標加入個體狀態可以有效預測未來資產的趨勢。因此兩種機器學習同時使用 CBOE Volatility Index(VIX)、Yield Spread (T10Y3M)、Tips Spread (T10YIE)總體經濟指標，再分別加入不同時間的動能因子作為特徵值。考量在大類資產中動能持續相對持久，在股債動能預測的階段，選用三個月動能因子的信號來切換資產類別；在風險性資產配置權重階段，則選用一個月動能因子來切換權益資產的類別。

分類模型使用 sigmoid 函數將預測的結果轉換為機率值，並透過交叉熵的損失函數調整模型的架構。支援向量機模型架構相對簡易，在投資流程上以該事件發生可能性可以轉換成機率的特性運用於權重配置上，因此未調整模型參數來要求更高的預測準確性。而長時間短期記憶神經網路運用於投資人預測觀點，對模型架構的完整度要求相對較高，選擇適當的迭代次數(Epoch)以免過度配適(Overfitting)，優化器部分則以隨機梯度下降法 (Stochastic Gradient Decent)作為優化參數的演算法，LSTM 架構如(圖 4-2)。

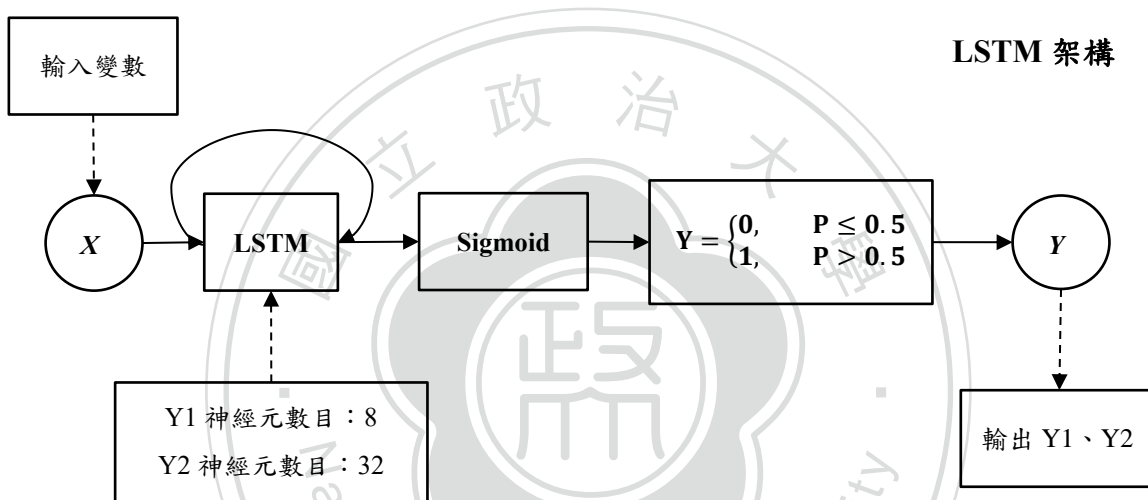


圖 4-2 LSTM Model 架構圖

三、 機器學習的效能估計

Breiman et al. (2001) 使用機器學習預測重點是在面對未知數據模型時，最大限度地提高預測準確性，機器學習與傳統統計目標的主要區別在於估計已知的數據生成模型並進行假設檢驗。Israel, Kelly, and Moskowitz (2020) 說明當更準確地描述現實世界的複雜性的好處超過模型帶來的潛在成本(過度擬合模型)時，研究人員會傾向相信模型的應用能力。因此在評估機器學習的效能上，本文著重說明模型預測的準確性。

在機器學習的領域中，混淆矩陣(Confusion Matrix)常被使用於衡量分類模型預測的表現，在建構投資組合的過程中，使用支援向量機及長時間短期記憶神經網路做為

雙動能策略的預測模型。在大類資產配置的階段，支援向量機雖具有預測功能，但策略設計採用二元預測的機率值作為投資流程的權重，而未使用預測值於模型參數中，因此不深入討論該階段支援向量機的預測準確性，本文僅衡量使用於 Black-Litterman 模型中長時間短期記憶神經網路的預測準確性。

表 4-1 混淆矩陣

	Predicted Negative	Predicted Positive
Actual Negative	TN (True Negative)	FP (False Positive)
Actual Positive	FN (False Negative)	TP (True Positive)

混淆矩陣用以描述在各類別下，對模型經過學習後預測的結果做次數統計。如(表 4-1)，每一列(Row)為樣本的劃分的實際類別；每一行(Columns)為在給定真實類別下，樣本預測的類別。TN 代表真實類別為 Negative 且預測類別為 Negative 的樣本數量；FP 代表真實類別為 Negative 但預測類別為 Positive 的樣本數量；FN 代表真實類別為 Positive 但預測類別為 Negative 的樣本數量；TP 代表真實類別為 Positive 且預測類別為 Positive 的樣本數量。準確率(Accuracy)為正確預測的樣本數($TN+TP$)占總樣本數的比例。

表 4-2 為訓練集與測試集的混淆矩陣，風險性資產在觀點矩陣中採用絕對觀點矩陣的方式，每一檔 ETF 資產的預測觀點經由相同的 LSTM 模型訓練後各自產生，由兩種預測值產生預期報酬變動的方向及幅度。從表中可觀察，在未來一個月報酬方向的分類問題上(Y1)，模型在 GLD 及 FIN 兩種資產的猜測上漲與下跌的數量比較均衡，在 MDY 及 QQQ 兩種資產猜測方向集中在上漲的趨勢，猜測上漲次數中真實為上漲的機率($TP/(FP + TP)$)平均高於六成，可推論市場處於多頭的狀態，兩種資產與大盤相關性高於九成，市場因子 Beta 較高，屬於系統性風險強勁的資產；在預測未來一個月報酬的漲跌幅度問題上(Y2)，準確率雖然高於五成，但模型預測值集中在漲幅兩

個標準差的類別，可以歸納出兩個問題：(1)模型預測報酬方向與漲跌幅度的適用性，萃取特徵因子模擬市場環境時，特徵因子所提供的資訊適用於預測方向或是預測漲跌幅度。(2)使用同一種預測模型，模型設定預測樣本漲跌幅波動期間的特性是否足夠被清楚分類。觀察 Donthireddy (2018)混淆矩陣的結果，預測漲跌幅度的準確率平均高於預測方向的準確率，若假設同一種模型(特徵因子相同)同時適用於預測報酬的方向及漲跌幅度，設定預測的期間不同可能影響樣本期間是否具有分類的差異性，導致模型選擇偏向預測特定類別來達成較高的準確率。另外可能受到模型特徵因子選取的影響，根據本研究結果推論總體經濟因子提供相對深入的漲跌資訊，可以作為資產未來可能上漲或下跌的佐證；而預測漲跌幅度可以考慮嘗試加入交易量能相關的因子來設定模型輸入，提供除了經濟資訊以外價量的資訊，來提高預測漲跌幅度模型的適用性。

表 4-2 樣本混淆矩陣

ETF	Classification Y1					Classification Y2					
	TN	FP	FN	TP	Accuracy	TN	FP	FN	TP	Accuracy	
Training	MDY	18	1130	2	1805	0.6169	29	1306	19	1601	0.5516
	QQQ	54	954	23	1924	0.6694	5	1362	1	1587	0.5387
	GLD	559	814	268	1314	0.6338	0	1365	0	1590	0.5381
	FIN	482	804	289	1380	0.6301	82	1269	69	1535	0.5472
Testing	MDY	69	206	59	445	0.6598	7	349	0	423	0.5520
	QQQ	18	222	52	487	0.6483	6	356	1	416	0.5417
	GLD	106	231	83	359	0.5969	0	354	0	425	0.5456
	FIN	37	237	67	438	0.6098	22	329	16	412	0.5571

儘管上述討論了模型設定可能面臨的問題，但對本次研究的結果還是非常的有信心的，初步可以理解 CBOE Volatility Index (VIX)、Yield Spread (T10Y3M)、Tips Spread (T10YIE)三大經濟指標提供資本市場發展的脈絡，當 VIX 指數上升、Yield Spread 及 Tips Spread 有反轉的現象時，市場處於相對危機的狀態，同時模型參考各資產的動能力量，平均預測方向準確度超過六成。將此數據輸入 Black-Litterman 模型的投資人觀點矩陣，並設定 τ 為 0.05 代表估計值的不確定性，最後可以得到後驗分配作為資產配置的參數。

第二節 投資組合績效評估

不考慮賦稅的前提下，極大化夏普比率投資組合在任何績效比率皆優於極大化效用函數，兩者優化器的結果呈現相同的現象，因此本研究以極大化夏普比率數據實證說明。根據雙動能投資的演算流程，實現兩種分類機器學習在投資流程的權重配置，圖 4-3 為四種策略的動態權重配置圖，可以觀察投資策略的權重分配的差距。表 4-3 可以發現，策略I及策略II表現明顯優於大盤，三年累積報酬高達 0.8、22%年化報酬率、1.19 的夏普比率以及 1.2 的卡馬比率，風險衡量指標年化波動度及最大回撤比率都相對大盤風險小；表 4-4 為策略III及策略IV的績效表，0.194 年化報酬率高於大盤水準，波動度及最大回撤比率高於大盤基準，調整後風險與大盤表現雷同。上述績效衡量指標未考慮交易手續費，本研究以表格最後一欄(Columns)表達每一種投資組合在設定交易次數下，投資組合再平衡一次平均可承擔多少手續費額度。考慮本研究設定月平衡為標準，顯示平均有多少年化超額報酬率可承受每年 12 次的投資組合再平衡，策略I及策略II平均而言可以承擔 0.0189 的交易手續費；策略III及策略IV平均而言可以承擔 0.0161 的交易手續費，四種策略相對 SP500 ETF 有額外的溢價貼水。

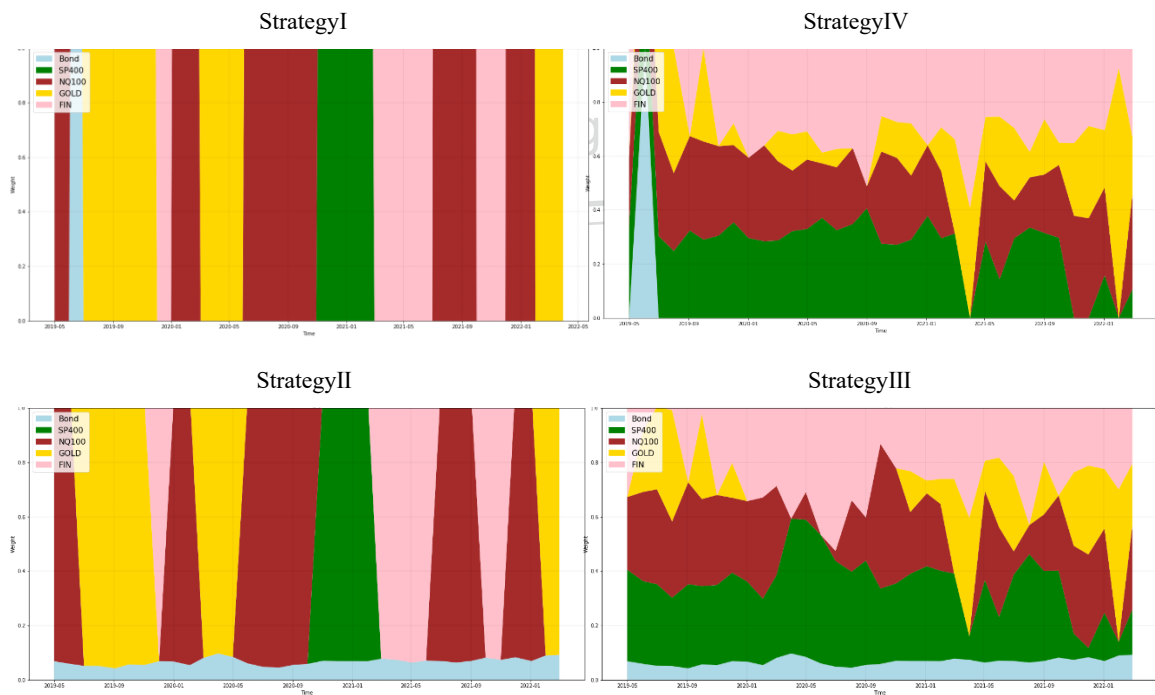


圖 4-3 動態策略配置圖

表 4-3 策略績效報表

Year	Cumulative		Mean Return	Standard Deviation	Max drawdown	Sharpe Ratio	Sortion Ratio	Calmar Ratio	Information Ratio	Trade Cost for No Excess Return (%)	
	Return	Return								Ratio	Ratio
2019	-0.0019	0.0069	0.1389	-0.0901	0.0493	0.0787	0.0222	-0.0462	0.0572		
2020	0.4849	0.4261	0.2446	-0.1921	1.7384	2.7351	2.4219	0.0445	3.5506		
2021	0.8849	0.2539	0.1746	-0.0966	1.4510	2.4817	3.0363	0.0031	2.1157		
2022	0.8368	-0.0798	0.2172	-0.1508	-0.3643	-0.5801	-0.9070	0.0187	-0.6649		
2019-2022	0.8368	0.2275	0.1988	-0.1921	1.1436	1.8357	1.2129	0.0147	1.8961		
2019	0.0439	0.0740	0.1438	-0.1018	0.5131	0.8521	0.7028	-0.0239	0.6166		
2020	0.5228	0.4036	0.2326	-0.1953	1.7317	2.7282	2.2426	0.0409	3.3635		
2021	0.8963	0.2324	0.1613	-0.0891	1.4384	2.4550	3.0041	-0.0089	1.9371		
2022	0.8465	-0.0865	0.2002	-0.1426	-0.4286	-0.6772	-0.9438	0.0182	-0.7207		
2019-2022	0.8465	0.2274	0.1890	-0.1953	1.2025	1.9381	1.2041	0.0151	1.8950		
2019	0.0947	0.1423	0.1275	-0.0662	1.1125	1.6840	2.3877	-	1.1859		
2020	0.2716	0.2058	0.3345	-0.3410	0.6140	0.9125	0.4440	-	1.7146		
2021	0.6154	0.2480	0.1308	-0.0542	1.8921	3.2121	5.3853	-	2.0664		
2022	0.5404	-0.1677	0.2112	-0.1287	-0.7875	-1.3686	-1.5423	-	-1.3973		
2019-2022	0.5404	0.1737	0.2276	-0.3410	0.7626	1.1433	0.4767	-	1.4473		

備註：表格為策略I及策略II與基準投資組合(SP500 ETF)日資料(年化)的年度績效表，包含2019至2022年的年度績效評估及全樣本測試期間(2019年至2022年)的整體績效，其中無風險利率設定為0，績效未考慮稅賦及交易費用，最後一欄(Columms)表示當投資組合每年再平衡12次，平均每次再平衡投資組合有多少超額報酬額度可以負擔手續費用。

表 4-4 策略績效報表

Year	Cumulative		Mean	Standard	Max	Sharpe Ratio	Sortion	Calmar	Information	Trade Cost
	Return	Return	Return	Deviation	drawdown	Ratio	Ratio	Ratio	Ratio	for No
										Excess
										Return (%)
Strategy III	2019	0.1059	0.1547	0.1046	-0.0819	1.4753	2.3294	2.1571	0.0103	1.2893
	2020	0.2802	0.2080	0.3507	-0.3565	0.5919	0.8822	0.4135	0.0018	1.7335
	2021	0.5848	0.2221	0.1305	-0.0501	1.6981	2.8986	5.1793	-0.0259	1.8508
	2022	0.6320	0.1311	0.1656	-0.0849	0.7850	1.3617	1.3011	0.1183	1.0921
2019-2022	0.6320	0.1940	0.2299	-0.3565	0.8432	1.2584	0.5217	0.0152	0.0152	1.6165
Strategy IV	2019	0.1515	0.2147	0.1041	-0.0773	2.0560	3.4298	3.2299	0.0670	1.7890
	2020	0.3304	0.1984	0.3284	-0.3416	0.6028	0.8943	0.4266	-0.0059	1.6531
	2021	0.6171	0.2026	0.1214	-0.0470	1.6652	2.8314	5.0090	-0.0471	1.6885
	2022	0.6473	0.0858	0.1544	-0.0810	0.5514	0.9542	0.8156	0.1018	0.7150
2019-2022	0.6473	0.1940	0.2158	-0.3416	0.8984	1.3394	0.5553	0.0158	0.0158	1.6164
SP500	2019	0.0947	0.1423	0.1275	-0.0662	1.1125	1.6840	2.3877	-	1.1859
	2020	0.2716	0.2058	0.3345	-0.3410	0.6140	0.9125	0.4440	-	1.7146
	2021	0.6154	0.2480	0.1308	-0.0542	1.8921	3.2121	5.3853	-	2.0664
	2022	0.5404	-0.1677	0.2112	-0.1287	-0.7875	-1.3686	-1.5423	-	-1.3973
2019-2022	0.5404	0.1737	0.2276	-0.3410	0.7626	1.1433	0.4767	-	-	1.4473

備註：表格為策略III及策略IV與基準投資組合(SP500 ETF)日資料(年化)的年度績效表，包含2019至2022年的年度績效評估及全樣本測試期間(2019年至2022年)的整體績效，其中無風險利率設定為0，績效未考慮稅賦及交易費用，最後一欄(Columns)表示當投資組合每年再平衡12次，平均每次再平衡投資組合有多少超額報酬額度可以負擔手續費用。

根據績效表現(圖 4-4)，明顯觀察出四種投資組合呈現兩種投資趨勢，分別為策略I及策略II有相似表現與策略III及策略IV有相似表現。分析投資組合四象限發現，策略I及策略II屬於未使用 Black-Litterman 模型配置風險性資產的權重，保留橫截面動能的信號演算流程，兩投資組合皆在配置股債比例後，將分配於權益資產的資金全數投入動能最佳資產；策略III及策略IV依照 Black-Litterman 模型配置風險性資產的權重，通過統計檢定觀察投資組合策略是否具特徵的統計顯著性。表 4-5 為投資組合相對基準投資組合月報酬率的統計資訊，策略I及策略II同時通過統計顯著性，表示兩者月報酬率相對 SP500 顯著異於零，投資組合表現優於大盤；研究同時對超額報酬的貢獻來源相當感興趣，因此檢定四象限投資組合報酬的組間及組內差異。

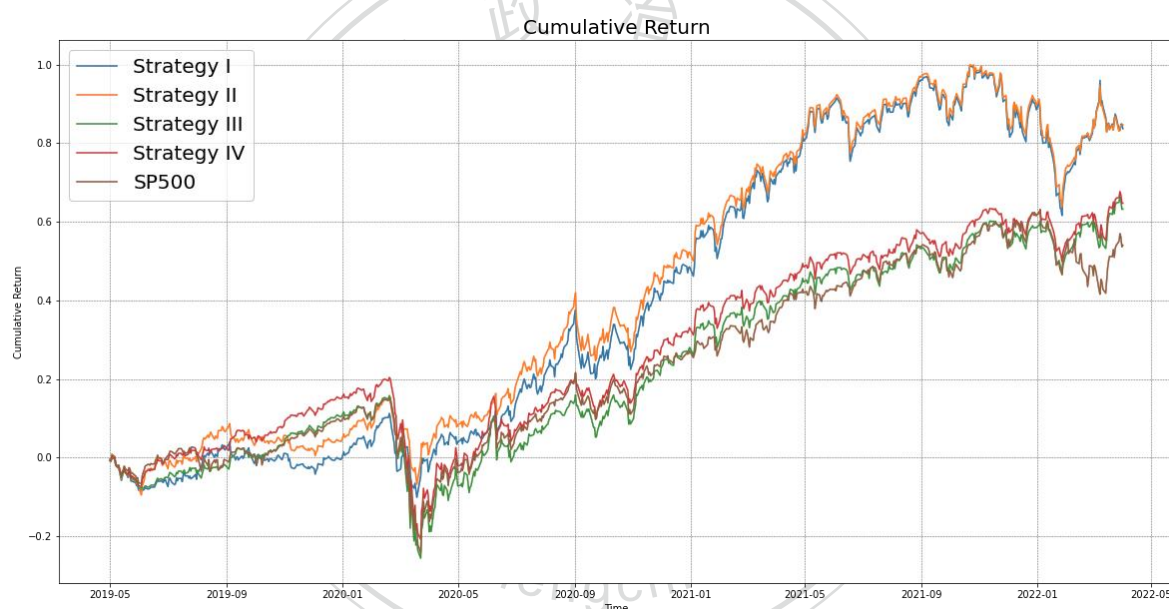


圖 4-4 累積報酬回測圖

觀察特定環節資產配置的效果，以戰略性資產配置(SAA)步驟為例，透過支援向量機可以配置股債的資金比重，在給定橫截面動能配置類別或是 Black-Litterman 模型類別下，觀察使用支援向量機配置股債資金的效果如何；同樣地，在戰術性資產配置(TAA)步驟去觀察 Black-Litterman 模型配置權重的效果，然而檢定設計以右尾分配為主，策略I績效及策略II明顯優於策略III及策略IV，因此研究反向假設為是否單純使用橫截面動能效果的投資組合表現能優於使用 Black-Litterman 模型來配置風險性資產，該假設分為使用時間序列動能及使用支援向量機兩組來觀察組內差異。

表 4-5 策略月超額報酬統計檢定

	Benchmark SP500					TAA (Momentum)					
						SAA (SVM)			TAA (Momentum)		
	Strategy I	Strategy II	Strategy III	Strategy IV	BL Model	Momentum	BL Model	Momentum	SVM	SAA (SVM)	TAA (Momentum)
Median Return	0.2764	0.2273	-0.0258	-0.0173	0.0218	-0.0274	0.0218	0.2594	0.1778	-0.0122	0.2116
Mean Return	0.3270	0.2605	0.0126	-0.0202	0.0329	-0.0665	0.0329	0.3473	0.2479	-0.0168	0.2976
Standard Deviation	0.1787	0.1715	0.0796	0.0647	0.0402	0.0623	0.0402	0.1697	0.1862	0.0543	0.1715
Skewness	0.9319	1.0892	0.6230	-0.3099	5.0609	-5.5707	5.0609	1.3187	0.9513	-3.4133	1.4465
Kurtosis	3.2156	3.5820	2.9413	1.8508	29.0210	32.5916	29.0210	3.9268	4.1908	36.2260	4.2965
T-Statistic	3.1253	2.5946	0.2708	-0.5344	1.3966	-1.8234	1.3966	3.4953	2.2733	-0.7530	4.2208
P-Value	0.0018***	0.0069***	0.3941	0.7018	0.0857	0.9616	0.0857	0.0007***	0.0146**	0.7730	0.0000***

備註 1：表格為四種投資組合相對基準投資組合(SP500 ETF)超額報酬的顯著性；SSA(SVM)欄位(Columns)觀察在 Cross Section Momentum 組別和 BL Model 組別在使用 SVM 配置權重的效果，TAA(Momentum) 欄位(Columns)觀察在 Time Series Momentum 組別和 SVM 組別使用 Cross Section Momentum 信號配置權重的效果；最後兩欄分別觀察 SVM 和 Cross Section Momentum 不分組別配置權重的效果。

備註 2：***代表顯著水準 $\alpha = 0.01$ ；**代表顯著水準 $\alpha = 0.05$ ；*代表顯著水準 $\alpha = 0.1$ 。

由(表 4-5)發現,不論大類資產使用哪一種股債配置方式(時間序列動能或是支援向量機),使用橫截面動能配置在戰術性資產配置(TAA)的效果能通過 $\alpha = 0.01$ 顯著性測試,最後一欄TAA(Momentum)整體效果的檢定也顯示相同的測試結果;相對在SAA環節上是否進行股債權重平滑手段,其效果則非能顯著反映在報酬績效上。因此究其最大化報酬的需求可以推論,當週轉率控制在適當可接受的範圍(例如一年12次再平衡投資策略),選擇使用雙動能策略投資流程做資產配置,第一階段無論是否改變股債資金配置的機制,都建議可以在風險性資產配置(TAA)環節單純使用橫截面動能演算方式,將所有權益資金比重投入動能最佳的權益型資產,並利用再平衡的時間點進行動能因子擇時的需求,轉換成該時期動能相對強勁的資產,達成績效最佳化目標。

儘管風險性資產配置的工具 Black-Litterman 模型無法通過統計顯著性,在報酬數據的統計下(表 4-4),加入風險性資產權重配置的表現仍是優於大盤報酬,從整體風險觀察,會認為策略III及策略IV風險分散效果沒有大盤好,但從年度數據發現,2019年、2021年、2022年的整體風險都小於大盤的年化標準差,2020年的疫情衝擊影響投資組合的累積表現,說明投資組合對突發風險衝擊的忍受度非常低,嚴重降低分散風險的能力;2022年初烏俄戰爭及經濟緊縮的趨勢,策略III及策略IV尚能有0.1311及0.0858的平均報酬率,整體風險及最大回撤比率相較大盤小,可見Black-Litterman模型仍可在熊市中獲得較佳的資產配置表現,推論由於Black-Litterman模型仰賴投資人觀點的預期,當機器學習在突發性且劇烈的風險衝擊中預測失效時,將使投資組合受到強烈衝擊,但若處於市場趨勢穩定發展的狀態卻是一種值得肯定的配置手段。

第三節 動能因子擇時效果

有鑑於投資人除了要求報酬極大化之外,也同時關心風險發生的機率及價值損失的程度。若遭受突發的風險因素也會立刻衝擊投資組合的流動性,因此基於風險的角度再次分析四種投資組合的表現,表 4-6 為策略四象限圖中每一種策略的波動度及最大回檔比率。從整體的績效的角度而言,平均績效表現上策略I及策略II相對優勢於策

略III及策略IV，從年度表現來觀察，發現四種策略最大回撤比率愈最大波動度皆落在2020年，該年為疫情重創初期且美股發生股市熔断的期間，策略I及策略II最大回撤比率遠遠小於大盤下方風險測量值(-0.3410)，年化後的平均報酬率高達0.4，2019年至2020年累積報酬為0.4至0.5的水準，而策略III及策略IV僅0.2至0.3，說明黑天鵝事件對投資組合的累積績效有深遠的影響，一旦系統性風險發生，投資組合會在短期之內虧損完長期資金累積的回報。經過實證發現策略I及策略II同樣遭受系統性衝擊影響，但衝擊的程度相對小，累積報酬的力道雖然減緩，但報酬仍穩定成長。

表 4-6 四象限風險評估

(Std, MDD) Year 2020		Tactical Asset Allocation	
		Cross Section Momentum (Weighted All In)	Black-Litterman Model (Weighted Smooth)
Strategy Asset Allocation	Time Series Momentum (Weighted All In)	Strategy I (0.1988, -0.1921)	Strategy IV (0.2299, -0.3565)
	Support Vector Machine (Weighted Smooth)	Strategy II (0.1890, -0.1953)	Strategy III (0.2158, -0.3416)

上一節說明 Cross Section Momentum 有效捕捉超額報酬，雖然支援向量機配置方式(策略II、III)不具統計顯著性，策略II相比單純雙動能投資策略(策略I)整體有相對小的波動度。從上述動能衝擊事件發現，策略I、II風險性資產經過橫截面動能轉換後資金投入 GLD ETF(圖 4-5)，風險衝擊規避的效果來自於橫截面動能效果，雖然動能因子顯示該時期風險性資產表現比固定收益資產類別好，一旦發生未預期的風險衝擊事件，風險性資產中的避險資產反而成為避險的後盾。因此推測在時間序列動能信號的推動下，動態加入特定比例的固定收益資產，可以隨時間變化保護風險性資產動能波動時期，增加投資組合穩定性，在牛市時橫截面動能疊加有助於增加投資組合的終值；在動能劇烈崩跌時仍可以風險性資產中的避險性資產作為動能崩跌的最後一道防線。

第五章 結論

本文使用雙動能策略的脈絡建構四種投資組合，善用人工智慧科技及設計投資流程的技術改良權重配置的機制，透過四種投資組合的績效回報來觀察策略實踐的優勢。戰略性資產配置可以透過時間序列動能的訊號動態調整股債的權重，將高報酬的優勢依據科學機率適當轉換成保護風險性資產風險的強大後盾，說明時間序列動能因子具有風險擇時的能力；在研究樣本期間內，長時間短期記憶神經網路預測漲跌方向的平均準確率有六成，預測漲跌幅度準確率平均有五成，兩者使用相同的特徵因子及萃取因子模型，差距近一成的預測準確率，研究推論可能是漲跌幅預測期間設定的差異，或是同一組特徵因子預測模型應適用不同特性的預測變數，因此發現機器學習的預測變數對特徵因子的選取具高敏感性。本篇論文最大的貢獻在於創新動能投資的流程及權重配置的機制，四種投資組合背後反映四種投資策略，根據四象限的設計及檢定測試歸因動能效果及權重效果，研究發現橫截面動能訊號決定風險性資產權重的動能效果非常顯著，即便持有的資產屬於的投資組合類別(例如產業代表性 ETF)，仍有機會透過動能效果增加超額報酬，其中規避突發風險性衝擊的效果則來自於風險性資產池中納入避險性資產，因此說明同時具報酬與風險擇時的能力；時間序列動能訊號應用於股債動態配置的權重效果則具有穩定風險承受的能力，因此建議投資人可以動態調整固定收益資產的權重規避風險衝擊，並配合橫截面動能策略來追求最大化目標報酬。

本研究透過投資流程的設計及擇時的效果捕捉超額績效，然而資產配置屬於大型的投資分析過程，需要多方考慮建構投資組合的相關細節，因此研究過程中也發現可以持續耕耘的部分。實證結果發現，機器學習傾向猜測劇烈的漲跌幅度，因此建議可以設定預測更短的區間或使用量能相關的特徵變數來捕捉波動震幅的趨勢；支援向量機配置在固定收益資產的預測機率(比重)落在小於 0.2 的範圍，可以嘗試使用不同分類器的機率值，利用機率值的範圍設計適用不同客群的投資組合；本次研究未使用移動樣本的窗格及特定選股依據，因此未來研究可加入滑動窗格，隨時間考慮市場的結構性來設定預測的模型，並將選股流程納入資產配置的過程增加投資組合的強健性。

參考文獻

- Antonacci, G. (2011), "Optimal Momentum: A global cross asset approach," Available at SSRN: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1833722.
- Antonacci, G. (2013), "Absolute momentum: A simple rule-based strategy and universal trend-following overlay," Available at SSRN: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2244633.
- Antonacci, G. (2017), "Risk premia harvesting through dual momentum," *Journal of Management & Entrepreneurship*, 2(1), 27-55.
- Asness, C. S., Moskowitz, T. J., & Pedersen, L. H. (2013), "Value and momentum everywhere," *The Journal of Finance*, 68(3), 929-985.
- Bird, R., Gao, X., & Yeung, D. (2017), "Time-series and cross-sectional momentum strategies under alternative implementation strategies," *Australian Journal of Management*, 42(2), 230-251.
- Black, F., & Litterman, R. (1990), "Asset allocation: combining investor views with market equilibrium," *The Journal of Fixed Income*, 1(2), 7-18.
- Black, F., & Litterman, R. (1992), "Global portfolio optimization," *Financial Analysts Journal*, 48(5), 28-43.
- Breiman, L. (2001), "Statistical modeling: The two cultures (with comments and a rejoinder by the author)," *Statistical Science*, 16(3), 199-231.
- Brinson, G. P., Hood, L. R., & Beebower, G. L. (1986), "Determinants of portfolio performance," *Financial Analysts Journal*, 42(4), 39-44.
- Chopra, V. K., & Ziemba, W. T. (2013), The effect of errors in means, variances, and covariances on optimal portfolio choice, *In Handbook of the fundamentals of financial decision making: Part I* (pp. 365-373).
- Cortes, C., & Vapnik, V. (1995), "Support-vector networks," *Machine Learning*, 20(3), 273-297.
- Donthireddy, P. (2018), "Black-Litterman Portfolios with Machine Learning derived Views," ResearchGate, Retrieved March 12, 2022, from https://www.researchgate.net/publication/326489143_Black-Litterman_Portfolios_with_Machine_Learning_derived_Views.
- Eichhorn, D., Gupta, F., & Stubbs, E. (1998), "Using constraints to improve the robustness

- of asset allocation,” *Journal of Portfolio Management*, 24(3), 41-48.
- Fama, E. F., & French, K. R. (2015), “A five-factor asset pricing model,” *Journal of Financial Economics*, 116(1), 1-22.
- Frost, P. A., & Savarino, J. E. (1988), “For better performance: Constrain portfolio weights,” *Journal of Portfolio Management*, 15(1), 29-34.
- Ha, S., & Fabozzi, F. J. (2022), “Dual Momentum: Testing the Dual Momentum Strategy and Implications for Lifetime Allocations,” *The Journal of Portfolio Management*, 48(4), 282-301.
- Idzorek, T. (2007), A step-by-step guide to the Black-Litterman model: Incorporating user-specified confidence levels, *In Forecasting expected returns in the financial markets* (pp. 17-38). Academic Press.
- Israel, R., Kelly, B. T., & Moskowitz, T. J. (2020), “Can Machines 'Learn' Finance?,” *Journal of Investment Management*, 18(2), 23-26.
- Jegadeesh, N., & Titman, S. (1993), “Returns to buying winners and selling losers: Implications for stock market efficiency,” *The Journal of finance*, 48(1), 65-91.
- Litterman, R., & He, G. (2002), “The intuition behind black-litterman model portfolios,” Available at SSRN: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=334304.
- Markowitz, H. (1952), “Portfolio selection,” *The Journal of Finance*, 7(1), 77-91.
- Menkhoff, L., Sarno, L., Schmeling, M., & Schrimpf, A. (2012), “Currency momentum strategies,” *Journal of Financial Economics*, 106(3), 660-684.
- Moskowitz, T. J., Ooi, Y. H., & Pedersen, L. H. (2012), “Time series momentum,” *Journal of Financial Economics*, 104(2), 228-250.
- Scherer, B. (2002), “Portfolio resampling: Review and critique,” *Financial Analysts Journal*, 58(6), 98-109.
- Sharpe, W. F. (1964), “Capital asset prices: A theory of market equilibrium under conditions of risk,” *The Journal of Finance*, 19(3), 425-442.
- Sharpe, W. F. (1974). “Imputing expected security returns from portfolio composition,” *Journal of Financial and Quantitative Analysis*, 9(3), 463-472.