

應用 LSTM 探討選擇權流動性對市場波動方向之預測

Applying Long Short-Term Memory Networks to Predict Market Trend Based on Options Market Liquidity

陳煜璋(Yi-Chang Chen)

國立屏東大學資訊管理學系

陳泓源(Hong-Yuan Chen)

國立屏東大學資訊管理學系

摘要

本研究旨探討市場臺指選擇權各履約價之買賣方掛單行為，聚焦於其掛單現象進一步分析其市場流動性與其影響期現貨價格波動之現象，並建構以選擇權委買賣價差衡量之流動性指標，並利用長短期記憶網路(Long Short-Term Memory Networks, LSTM)模型結合卷積神經網路(Convolutional Neural Network, CNN)，建立一混合深度學習模型，由市場買賣方之掛單變化預測對未來期現貨價格波動。實證結果顯示，本研究所提之 LSTM 模型可用於預測短線波動，而 LSTM-CNN 模型整體預測效果更優於原 LSTM 模型。整體而言，所提出之模型可提升對市場動態的辨識能力與波動預測準確性，除了有效辨識期貨日內波動方向，並有助於即時掌握市場變化，對交易策略設計與風險管理展現應用潛力。

關鍵字：流動性；波動度；長短期記憶；卷積神經網路

ABSTRACT

This study examines the order submission behaviors of buyers and sellers across different strike prices in the Taiwan Index Options (TXO) market, with a particular focus on order placement phenomena. It further analyzes how these behaviors impact market liquidity and influence price volatility in both futures and spot markets. A liquidity indicator based on option bid-ask spreads is constructed for the purpose of this research. Additionally, a hybrid deep learning model is developed, combining Long Short-Term Memory Networks (LSTM) and Convolutional Neural Networks (CNN), to predict future futures and the spot price volatility based on the changes of buyer and seller orders. Empirical results indicate that the proposed LSTM model is effective in forecasting short-term volatility, whereas the CNN-LSTM hybrid model achieves the superior predictive performance compared to the standalone LSTM model. Overall, the proposed models enhance the identification of market dynamics and improve the volatility prediction. Besides identifying intraday directional movements of futures prices effectively, these two models also demonstrate significant potential ability for the real-time market monitoring, the strategic trading decision-making, and the risk management applications.

Keywords: Liquidity; Volatility; LSTM; CNN

壹、緒論

一、研究背景與動機

臺指選擇權商品分為買權(Call)與賣權(Put)其中買方與賣方所要承擔的成本結構並不相同，買方僅需支付權利金(option premium)即可獲得商品之權利，而賣方則必須繳納相對較高的保證金(margin)以承擔潛在的風險。Brunnermeier & Pedersen(2009)發現當市場風險與波動性升高時，交易者傾向將資金轉向低保證金的商品以降低資金壓力，進而導致流動性供應者(Liquidity Providers)對高保證金商品的報價意願與掛單深度明顯減弱。Zhu et al.(2009)則對流動性供應者提出其定義不僅包含一般投資人與投機者亦涵蓋制度參與者如造市者(Market Makers)，並發現當市場中流動性供應者不足時，造市者所提供的雙邊報價能有效減緩價格劇烈波動。為深入探討此現象所衍生之市場穩定性問題，本研究將從市場流動性的角度進行探討。

市場流動性一直被視為金融市場運作的關鍵要素，不僅影響交易效率與成本更顯著影響價格波動與市場風險。多年來，相當多與流動性相關的文獻均提及，例如，Domowitz et al.(2001)指出波動性增高時，流動性供應者會減少提供的量或要求更高的報酬，造成市場上委託單的量減少和買賣價差過度的擴大，使得市場參與者的交易成本上升影響交易意願進而造成成交量的下降。Viral & Lasse(2005)則說明市場流動性不足的情況，市場參與者因資產無法及時賣出而接受更低的報酬或賣出相對低的價格使其影響市場穩定性。結果皆顯示流動性不足會使市場形成一個惡性循環，對市場的運作效率與穩定性產生負面影響。此外，Cao et al.(2009)提出限價單簿報價間距的概念其定義為限價訂單簿中第 j 階報價與第 $j-1$ 階報價之差，例如最佳第一檔委買價與最佳第二檔委買價之價差，透過計算限價訂單簿報價間距偵測買賣雙方掛單行為以追蹤未來的價格變動。近年來，Munoz et al.(2023)更強調，當市場流動性不足時，掛單稀疏與報價分散會顯著提高交易成本，並降低市場參與意願進而引發價格波動的連鎖反應。綜合而言，市場流動性不僅影響交易效率與成本，更與價格波動及市場風險密切相關。流動性不足將提高交易成本與成交量萎縮，進而引發價格劇烈變動與市場不穩。因此，流動性已成為金融市場中不可忽視的重要議題。

近年來，人工智慧(Artificial intelligence, AI)已廣泛應用於金融交易環境中，其中 AI 領域中的機器學習與深度學習技術被廣泛運用於金融領域，特別是在風險預測與交易策略開發領域，深度學習技術具備識別關鍵隱藏數據的能力。Dakalbab et al.(2024)對金融市場中人工智慧應用進行文獻回顧發現 143 篇相關研究中有逾三成採用深度學習技術，顯示深度學習在金融市場預測中展現出卓越的能力，特別是在處理高頻資料與高度非線性波動的問題上。其中，長短期記憶網路(Long Short-Term Memory, LSTM)與卷積神經網路(Convolutional Neural Network, CNN)因其分別擅長學習時間依賴性與資料中的區域特徵，已被廣泛應用於各類金融預測模型中。例如，Huang et al.(2024)、Dubey & Enke(2025)、Fang & Cai(2025)和 You et al.(2025)在預測虛擬貨幣、股市、黃金等市場中皆採用 CNN-LSTM 混合模型，其預測準確度皆優於其他混合模型與傳統模型，因此本研究採用 CNN-LSTM 混合模型旨在結合卷積網路對資料局部特徵的擷取能

力與 LSTM 對時間序列長短期依賴的學習能力，藉此強化模型對金融市場之預測能力。

二、研究目的

本研究選擇以選擇權市場為研究標的，主因在於其具備高流動性特性(Lin et al., 2016)且買方僅支付權利金，而賣方則需繳納保證金的特殊成本結構，反映出市場中可能存在流動性供需不平衡，適合作為流動性與掛單行為變化的觀察標的。因此擷取選擇權市場訂單簿中流動性供應者之掛單行為變化。過往文獻多聚焦於股票與期貨市場，針對選擇權市場中買賣雙方掛單行為與價格波動進行實證分析的研究相對有限。因此，本研究以臺灣期貨交易所發行之臺指選擇權為分析對象，透過最佳委買與委賣報價資料量化買賣雙方掛單行為，並結合具時間依賴學習能力的 LSTM 與擅長擷取資料局部特徵的 CNN 建構日內價格波動方向預測之模型。此模型具備及早辨識潛在的市場風險力與協助投資人優化交易策略的能，同時補足選擇權市場中高頻流動性相關研究之缺口，為金融實務提供一套結合深度學習技術的即時風險預警機制。

貳、文獻探討

本研究探討流動性對價格波動的影響，並且運用深度學習方法預測未來價格波動。為奠定理論基礎，將回顧相關文獻了解流動性變數與風險管理中的應用價值與分析既有文獻中價格波動以及流動性與價格波動之間的關係，並探討機器學習，洞察過去文獻動態分析之方法。

一、金融商品之流動性

Harold Demsetz 在其 1968 年的論文《The Cost of Transacting》中開創性探討利用買賣價差衡量市場流動性的工具，並表明良好的流動性可以降低交易成本從而提高市場效率。研究顯示，較小的買賣價差表示有更高的市場流動性，因為投資者進入與退出市場的成本較低，從而提高交易意願。並當交易頻率增加時，市場供應者能夠更迅速地成交買賣訂單，使買賣價差縮小，進一步提高市場的流動性。由於 Demsetz 的開創性論文，買賣價差成為衡量市場流動性的關鍵指標。其創新的概念深入探討市場結構和流動性之間的關係，進而促使金融市場微觀結構的研究。

隨著市場研究深入，更多的學者提出對市場微觀結構的研究與偵測流動性風險的方法，除了緒論所提及之 Domowitz et al.(2001)、Zhu et al.(2009) & Munoz et al.(2023)之文獻外，值得一提的是 Bondarenko(2001)透過動態市場微觀結構模型，探討於資訊不對稱情境造市商報價行為對買賣價差之影響，指出當市場處於不完全競爭且存在逆選擇風險時，買賣價差將顯著擴大，造成市場流動性下降與交易成本上升，反映買賣價差在微觀結構中扮演核心角色。進一步地，Chordia et al.(2008)以 NYSE 市場 1993 年至 2002 年的五分鐘高頻交易資料為基礎，建立有效價差與報價價差等指標，發現當市場處於高流動性狀態時，買賣價差明顯縮小，且價格更迅速反映市場資訊，使短期報酬預測力降低，顯示價差變動與市場效率密切相關。

此外，Coppola et al.(2024)運用馬可夫轉換模型分析美歐市場風險狀態，研究中使用包含買賣價差在內的流動性指標組成流動性風險框架，實證結果顯示該架構具備辨

識與預測流動性事件的能力，並可動態分類市場風險等級。Yu et al.(2025)則以中國股票為樣本，提出 HL 指標，其以每日高低價差平方替代高頻報價價差，作為流動性的代理變數，並結合 Amihud 指標等建構綜合流動性指標，實證結果顯示該方法能有效提升對報酬變動的解釋力。

最後，Zhao et al.(2025)利用深圳證交所逐筆與限價單簿資料，提出主動與被動下單失衡指標(API)，證實當市場出現大量主動買入或賣出時，API 上升將導致買賣價差快速擴大並加劇價格波動，說明主動交易壓力與價差結構之間存在強烈的聯動關係。

延續前述文獻的基礎，採用選擇權市場之買賣價差作為流動性衡量指標，並分析其對期貨市場價格波動的影響，探討選擇權市場流動性是否具有解釋波動風險的能力，並為期貨價格預測與風險管理提供理論與實證依據。

二、金融市場之價格波動

市價格波動指的資產價格在特定時間內的變動幅度，價格波動通常以價格的波動範圍或變異程度來衡量。當資產價格的波動幅度越大，代表市場的不確定性與風險越高，因此價格波動被視為衡量金融市場風險的重要指標。

(一)價格波動與流動性之間的關係

近年來，相關文獻開始深入探討市場運作的內部細節，包含資產價格形成、交易機制與參與者行為等因素，研究開始關注市場內部如何影響價格變動與資訊傳遞效率。其中，報價行為、訂單深度、交易量與買賣價差等構成關鍵要素，這些變數會影響市場的流動性並進一步引發價格變動。根據理論推論，當市場流動性充足時，交易成本較低，價格相對穩定；反之，流動性不足時，價格則易受大額交易或外部資訊衝擊而劇烈變動。接著，本研究將對相關文獻進行文獻探討，證實流動性與價格波動之間存在密切的關聯性。

首先，Valenzuela et al.(2015)提出相對流動性指標探討其對未來市場波動性的預測能力。研究資料採用 2008 年 6 月至 7 月伊斯坦堡證券交易所(Istanbul Stock Exchange, ISE)指數成分股之限價單與成交資料。研究透過預測迴歸模型，使用 15 分鐘雙尺度實際波動率(Two-Scale Realized Volatility, TSRV)作為依變數，將相對流動性指標作為自變數，分析兩者之間的關聯性。實證結果顯示，相對流動性對市場波動具顯著預測能力。其中 RLIQ 每上升一個標準差，15 分鐘後的波動性平均下降 4.4 個基點，顯示相對流動性對波動性有預測能力。

Chung & Chuwonganant(2018)則探討市場波動性與股票報酬之間的關係，並聚焦於流動性提供者(liquidity providers)在兩者間的作用。研究資料涵蓋 1990 年至 2012 年，樣本包括美國股市中共逾 10,000 檔股票。實證結果顯示，市場波動性與股票報酬呈顯著負向關係，其中市場波動性提升會導致流動性下降，進而使股票報酬下滑，反映出流動性是波動性影響報酬的中介傳導機制。研究亦發現此關係在高頻交易盛行的環境中更加明顯，顯示當流動性提供者功能被弱化時，波動性對報酬的負面衝擊更加顯著。

相同地，Ma et al.(2018)亦針對市場波動性、流動性衝擊與股票報酬之間的交互關係進行實證分析，資料涵蓋 1990 至 2015 年間全球 41 個國家股票市場的股票共 37,677

檔。研究透過組合排序(portfolio sorts)與迴歸模型偵測流動性衝擊。實證結果顯示，市場波動性會透過流動性變化對股票報酬產生顯著影響，特別是在波動性劇烈的期間更為顯著。研究亦採用類似 Chung & Chuwonganant(2018)的方法，結果發現對市場波動性反應敏感股票，其未來報酬顯著較低於波動性反應不敏感股票。

Xu et al.(2019)探討市場流動性與價格波動性之間的動態交互關係。資料使用中國上證綜合指數股票市場之 5 分鐘高頻資料，期間自 2006 年至 2016 年共 2,673 個交易日。實證結果顯示，市場流動性與價格波動性之間存在顯著關聯，兩者之間的影響具有非線性與狀態持續性，其中在低流動性狀態下，流動性對波動性的影響顯著高於高流動性狀態。此外，這個影響於不同流動性狀態中具備高度持續性，直到出現重大經濟事件，否則其狀態不易轉變。

接著，Bedowska-Sojka & Kliber(2019)探討波蘭股票市場中流動性與波動性之間的因果關係。資料涵蓋 2006 年至 2016 年，資料採用華沙證券交易所(Warsaw Stock Exchange, WSE)41 檔藍籌股。研究分別使用 Granger 因果檢定與 Toda-Yamamoto 因果檢定，分析 WSE 上市股票的流動性與波動性之間的雙向關係，實證結果顯示，多數的情況流動性與波動性是雙向的關係，但流動性更常為因、波動性為果，即流動性變化較常引起波動性變動。兩種因果檢定方法得出的結論一致，皆指出流動性-波動性關係中，較高的流動性使得未來波動性下降，反之，波動性-流動性說明較高的波動性則會限制未來的流動性。

此外，Chulia et al.(2020)針對九個成熟國家股票市場，包含美國、英國、法國與日本等，2000 年至 2016 年為樣本期間，分析流動性共通性與波動性之間的時間變動與雙向因果關係，實證結果顯示，Granger 因果檢定發現波動性變動具有預測流動性共通性的能力，同時流動性共通性的變化也能預測波動性，但此雙向關係僅於金融危機發生期間才達顯著水準。此結果表明於市場衝擊期間，波動性與流動性共通性之間存在強烈的交互影響，並可能形成一種惡性循環，加劇市場不穩定性。

近年來，Nguyen et al.(2020)模擬美國國債日內逐筆交易與限價委託簿資料，特別擷取 2007 年至 2009 年金融危機期間與重要經濟公告公布前後。利用自我迴歸條件期間模型(logarithmic autoregressive conditional duration, Log-ACD)分析流動性、交易量與波動性之間的動態關係。實證結果顯示，三者皆具有高度持續性其中市場流動性與交易量對自身短期變動短期持續性高，而波動性則呈現長期持續性。此外，流動性與交易量對波動性的變化具有顯著解釋力，反之波動性對兩者影響則較小。

Choi & Munro(2022)提出市場流動性的理論模型，並透過實驗方法驗證模型的有效性。研究中採用動態資產市場博弈模型(dynamic asset market model)，分析市場流動性如何影響投資者對資產訊息的敏感度，進而導致市場過度波動，並模擬市場中的市場流動性狀態。實證結果顯示，在低流動性市場中，投資者對資產訊息的敏感度更高，容易因負面訊息產生過度反應，進而導致頻繁的拋售行為，使市場波動加劇。研究亦發現市場參與者在低流動性條件下更容易出現羊群行為(Herd Behavior)與搶先交易行為(Preemptive Selling)，這兩種行為為放大市場價格的波動幅度。研究透過實驗結果驗證理論模型的預測，表示流動性顯著影響波動度。

Tang & Wang(2022)則提出流動性衝擊與價格波動的理論模型，研究採用量化迴歸(Quantile Regression)方法，分析流動性與融資流動性如何影響比特幣價格的波動度。實證結果顯示，流動性與融資流動性的變動具有預測比特幣價格波動的能力，且兩者對價格波動呈現負相關。研究亦發現流動性衝擊對長期波動影響更為顯著。實證結果證明流動性對價格波動有顯著的影響，運用流動性變數設計的交易策略能夠有效改善投資報酬與風險管理能力。

Feng et al.(2023)蒐集涵蓋全球 43 個國家 1990 至 2021 年的長期股票市場資料，使用三種流動性指標分別從交易活躍度、價格對成交量的敏感度與市場冷清程度衡量流動性波動。研究採用過去 36 個月的變異係數衡量流動性的波動性，建構流動性波動度指標。實證結果發現，流動性波動度越高的股票，未來報酬反而越低，即存在顯著的負向流動性波動溢價，更重要的是指出關鍵來自於流動性下降，流動性下降導致未來價格顯著下跌，但是流動性提高對未來價格則沒有顯著的影響。

Zhao et al.(2024)研究 Single-stock ETFs(SSETFs)的波動性與流動性關係時，使用多種流動性變數來衡量市場狀態。實證結果顯示，SSETFs 的流動性普遍低於標的股票，且當標的股票波動性增加時，SSETFs 的流動性顯著地下降，反映市場流動性受標的資產波動影響的現象。

Xu et al.(2024)探討市場流動性對市場波動率預測的影響。實證結果顯示，當市場流動性急劇惡化對未來價格波動具有顯著影響。相對地處於流動性正常狀態時，流動性對價格波動的影響較不顯著。整體而言，流動性不僅有效提升價格波動的解釋力，更作為辨識市場進入危機狀態的領先指標。

最後，Liu et al.(2025)利用五分鐘高頻交易資料，實證分析 Ethereum 自工作量證明(Proof of Work, PoW)轉為權益證明(Proof of Stake, PoS)後的市場變化。研究發現，轉換後市場流動性顯著提升，表現於買賣價差縮小與訂單深度增加。隨著流動性的改善，市場波動性亦明顯下降，顯示流動性提升有助於降低價格波動。結果說明流動性的上升既可改善交易效率，也有穩定價格波動的能力。

綜合而言，不論是傳統股票、ETF 與加密貨幣，流動性與價格波動皆呈現密切的關聯，其亦是解釋與預測市場價格波動的重要關鍵因素，並為本研究結合深度學習模型的預測提供理論支持的輸入變數設計。

(二)價格波動衡量方法

Black & Scholes(1973)提出的選擇權定價模型(Black-Scholes Model)開啟現代金融波動研究的重要起點。該模型假設資產價格服從幾何布朗運動(Geometric Brownian Motion, GBM)，即資產價格隨時間呈現連續的隨機變動，且波動率為固定常數。然而，實際市場中價格波動呈現出許多違反此假設的現象，例如波動叢聚(volatility clustering)與厚尾分布(fat tails)，顯示波動率並非穩定不變。因此後續的研究提出更符合現實的模型，包含 Engle(1982)提出自迴歸條件異方差模型(Autoregressive Conditional Heteroskedasticity, ARCH)，用以偵測波動的動態變化，Bollerslev(1986)進一步將其擴展為廣義自迴歸條件異方差模型(Generalized Autoregressive Conditional Heteroskedasticity, GARCH)，成為金融時間序列中分析波動的主流方法。儘管 GARCH 模型等統計方法

在波動分析上具備解釋力，但仍難以全面刻畫波動的潛在結構與非線性特性。近期研究如 Gunnarsson et al.(2024)文獻回顧指出，人工智慧與機器學習在預測市場波動率方面展現出更高的準確性。然而，目前大多數 AI 模型仍以總體經濟指標或技術指標為主要特徵，對於市場流動性作為影響價格波動的潛在因素，卻較少納入考量。

綜合而言，本研究期望補足現有模型中對流動性變數運用的不足，因此採用流動性作為變數分析價格波動，透過買賣價差與成交量等流動性變數，探討流動性變數與市場波動之間是否具備預測價格波動的能力。

三、機器學習(Machine Learning)於金融市場之應用

機器學習(Machine Learning)的概念最早由 Arthur Lee Samuel 於 1959 年於其論文《Some Studies in Machine Learning Using the Game of Checkers》中提出，將其定義為使計算機具備學習能力，而無需明確編程指令即可自我改進的能力。Samuel 開發自我學習西洋跳棋的程式，使計算機透過大量對弈經驗持續調整策略與評分標準，提升程式西洋跳棋能力，實證計算機可透過經驗學習來優化行為，奠定未來深度學習發展的基礎。

(一)深度學習(Deep Learning)

深度學習是基於人工神經網路(Artificial Neural Network, ANN)的架構，其發展可追溯至 Fukushima(1980)提出的神經感知機(Neocognitron)，為 CNN 的發展奠定基礎。LeCun et al.(1989)將標準反向傳播(Backpropagation)演算法應用於深度神經網路，成功將 CNN 架構應用於手寫郵遞區號(ZIP Code)辨識，證實深度神經網路在特徵提取與辨識任務中的有效性。然而，深度神經網路訓練過程中存在梯度消失(Vanishing Gradient)問題，該問題由 Hochreiter(1991)首次提出，指出在多層神經網路中，反向傳播過程中的梯度會隨著層數增加而快速遞減，導致深層參數難以有效更新，使模型無法捕捉長期依賴關係。為解決此問題，Hochreiter & Schmidhuber(1997)提出長短期記憶網路(Long Short-Term Memory, LSTM)，透過引入記憶單元與門控機制，有效保留長期依賴資訊，使模型在處理時間序列與序列資料時表現顯著提升。

近年來，隨著技術的突破與創新，其中機器學習與深度學習技術被廣泛運用於金融領域，因此許多的研究都聚焦於利用深度學習技術預測股市未來的發展。機器學習在金融領域中，Dakalbab et al.(2024)在金融交易中的 AI 技術的文獻回顧中，將其分為五種類型：分類、迴歸、深度學習、強化學習、深度強化學習，五種類型當中，深度學習在 143 篇論文中佔 30%，是最為廣泛使用的類型，深度學習可以處理大量非結構化的數據，根據 Li & Bastos(2020)回顧股票市場中深度學習技術應用於金融市場預測文獻時發現最廣泛使用的模型為 LSTM，其次為混合模型，再其次為 CNN。因此，將接續探討 LSTM、CNN 與 CNN-LSTM 混合模型於金融市場預測應用之相關研究，作為模型架構之理論基礎。

(二)LSTM、CNN 與 CNN-LSTM 混合模型於金融市場之應用

近年來，Lin et al.(2022)結合小波轉換(Wavelet Transform)、雙向 LSTM(Bi-directional Long Short-Term Memory, Bi-LSTM)、注意力機制(Attention)與 CNN，提出多層次深度學習模型，用於原油期貨價格的預測。研究使用 WTI 與布蘭特原油期貨為樣

本。實證結果顯示混合模型有效解決傳統模型對金融資料處理能力不足的問題。實驗結果證明該方法在預測準確性上顯著優於其他傳統與現代模型。

Kanzari et al.(2023)應用 LSTM 模型，預測美國金融體系的總體經濟不穩定性，並探討情緒變數於預測表現中的貢獻。以 Kansas City 金融壓力指數(Financial Stress Index, FSI)作為不穩定性的衡量指標。實證結果顯示，LSTM 模型可作為監控金融風險的重要工具，特別是面對如 COVID-19 之類極端事件時具備良好預測能力與穩定性。

Xu et al.(2024)則提出新穎的雙向長短期記憶神經網絡-注意力機制模型(Bidirectional Long and Short-Term Memory Neural Network-Attention Mechanism Model, Bi-LSTM-Attention)，用於偵測重大事件對原油市場的影響，並提升價格波動預測的準確度。模型中，LSTM 主要負責學習原油市場的時間序列變動，並提取價格波動的長短期依賴性。由於原油市場受多種因素影響，包括經濟衰退、疫情、地緣政治衝突等高不確定性事件，價格走勢通常呈現出高度的非線性波動，LSTM 透過其記憶單元(Memory Cell)和門控機制(Gate Mechanism)，具備從歷史數據中提取關鍵資訊的能力，可減少短期市場噪音對預測的干擾，並增強對長期趨勢的學習能力。結果顯示 Bi-LSTM-Attention 偵測重大事件對市場的波動方面表現出色，並有效提升價格波動預測的準確度，特別是在發生疫情時或地緣政治衝突這類高不確定性的情境。

Zhang et al.(2024)提出新的混合模型小波變換(Wavelet Transform, WT)-自迴歸移動平均(Autoregressive integrated moving average, ARIMA)-LSTM，用於預測美國、歐洲與亞洲市場的指數期貨收盤價。研究將 ARIMA 與 LSTM 結合，並透過小波變換分解數據，提高預測的穩定性與準確度。其中，LSTM 在模型中扮演關鍵角色，主要負責擷取金融市場的非線性特徵與長短期依賴性，並學習市場價格的波動模式。由於指數期貨市場的價格變動具有強烈的時間依賴性與不確定性，LSTM 具備有效解決傳統時間序列模型難以處理的長期依賴問題，提高預測能力。結果表明，混合模型的預測準確性高於其他傳統方法，並且在市場震盪例如 COVID-19 期間時仍能保持穩定的預測能力。

接著，Huang et al.(2024)使用 CNN-LSTM 混合模型預測比特幣波動性，資料取自 Bitstamp 交易所，涵蓋 2014 至 2021 年的 10 分鐘成交資料。預測目標為未來 1 日、7 日、14 日與 60 日的比特幣實現波動率(Realised Volatility, RV)，輸入變數包含 10 分鐘頻率的 RV 時間序列以及其對應的馬可夫轉移場(Markov Transition Field, MTF)圖像，學習非線性與時間依賴結構。實證結果顯示，CNN-LSTM 模型在各預測期間的表現均優於單一 LSTM 模型與其他傳統方法。此外，研究使用預平均法(pre-averaging)作為資料前處理方法，有效消除高頻資料中的微結構噪音(microstructure noise)，可提高模型的穩定性。

Alghamdi & Alqithami(2025)提出機器學習與深度學習的股市分類架構，用以預測個股在特定時間內是否達成獲利目標。資料取自 Apple、Microsoft、Amazon、Google 與 Tesla 等五家美國科技公司之每日交易資料。預測目標為未來 5 至 25 日內，股票是否於未觸發停損前先達成獲利門檻，並以此將樣本標記為獲利或非獲利。實證結果顯示，深度學習 LSTM 與 TL-LSTM 模型的準確度優於其他傳統機器學習方法。研究亦

發現遷移學習(Transfer Learning)可以顯著縮短訓練時間，從而提高效率。

Fang & Cai(2025)提出用於金融時間序列預測的深度學習模型 DLS-TS-Net，整合 CNN、LSTM、門控循環單元(Gated Recurrent Unit, GRU)與 VAR，學習金融資料中複雜的非線性與長短期依賴關係。研究資料包含 S&P500 指數與道瓊工業指數成分股。預測目標為指數或股價的未來報酬率，透過 CNN 擷取區域特徵、LSTM 與 GRU 學習時間依賴性，VAR 模型則強化模型對線性關係的敏感度。實證結果顯示，DLS-TS-Net 在各移動窗口下的 RMSE 表現優於其他混合模型與統計方法，於投資模擬中展現良好的穩定性與應變能力特別是在極端事件期間，顯示該模型具備高度的實務應用價值。

Rao et al.(2025)提出應用於原油價格預測的機器學習與混合深度學習模型，結合傳統的 GARCH(1,1)模型與深度神經網路 LSTM 與 GRU，學習原油市場價格中的非線性動態與時間依賴結構。研究資料使用多種時間頻率，包括每日、60 分鐘、30 分鐘與 1 分鐘的 Brent 原油價格，預測目標為未來原油價格。實證結果顯示，LSTM 與 GARCH-GRU 混合模型在預測不同時間間隔的原油價格始終優於 GARCH(1,1)與 GARCH(1,1)-LSTM 混合模型，其中 LSTM 模型在整體預測精度略有優勢，而 GARCH (1,1)-GRU 混合模型在 MSE 方面表現更佳。

You et al.(2025)應用 CNN-LSTM 模型來提升黃金價格的預測能力。實證結果發現，CNN-LSTM 模型的總體預測精準度優於單一 LSTM 與其他的混合模型，此外提供 CNN-LSTM 模型協助市場參與者掌握黃金的即時趨勢並為調整投資決策提供更好的預測準確率。

最後，Dubey & Enke(2025)運用鏈上資料結合特徵選擇技術，建立比特幣價格方向預測模型，目標為預測隔日收盤價相對當日收盤價的漲跌方向。資料使用比特幣每日交易與鏈上指標，取自 Glassnode 平台，共使用 196 個鏈上特徵。研究採用三種特徵選擇方法 L1 正則化、Boruta 與主成分分析(Principal Component Analysis, PCA)降低維度與提升模型效能，其中 Boruta 選出的 25 個特徵，預測力最佳。模型方面比較隨機森林、時序卷積網路(Temporal Convolutional Network, TCN)與 CNN-LSTM 模型，實證結果顯示 CNN-LSTM 與 Boruta 的特徵選擇組合在測試期間達到最高準確率。在交易策略模擬中，CNN-LSTM 結合多空策略於樣本外期間年化報酬達 1682.7%，夏普比率 6.47，顯示此模型具備顯著的預測能力與實務應用潛力。

綜合文獻發現，深度學習模型已廣泛應用於金融市場的價格預測，尤其是 LSTM 及其混合模型，皆展現出優於傳統統計模型與傳統機器學習模型的預測能力。LSTM 克服時間序列中的長期依賴問題，結合 CNN 模型對於資料中區域特徵與異常變化的辨識能力提高，實務應用中亦展現更高的穩定性與精準度。無論應用於原油、黃金、比特幣、股價、波動率等，皆顯示混合深度學習架構具備良好的穩定度與實用性。實證成果說明，深度學習技術已成為金融市場投資決策與風險管理的重要參考依據。

叁、研究方法

本研究旨在預測臺灣期貨市場中臺灣加權指數期貨於短時間內的波動方向。因此採用長短期記憶網路(Long Short-Term Memory, LSTM)為主要核心模型，進行分類預

測。模型訓練資料包含選擇權市場的成交量與流動性指標和臺指期的價格與技術指標等特徵，並將臺指期貨未來的最高與最低價格變化作為標的，將市場狀況分為「上漲」、「下跌」與「盤整」三種類型。

一、研究變數定義

資料來源為臺灣期貨交易所提供的資料，選擇權資料包含日期、各履約價之最佳五檔委買與委賣價格、成交價與成交量等資訊；臺指期貨資料則為每筆成交價格。資料收集與預處理完成後將對研究變數進行定義，資料使用各履約價之最佳五檔委買價、委賣價與成交量等資訊；臺指期貨資料採用每筆成交價格。

資料用於衡量市場流動性與價格變動，作為研究模型建構與分析之基礎。選取選擇權履約價方面，本研究聚焦於選擇權市場中買賣雙方的掛單行為，探討選擇權委買價與委賣價對價格形成的影響。考量一般個人交易者受限於資金規模與風險承受能力，通常較少參與履約價偏高的合約。根據 Brunnermeier & Pedersen(2009)之研究，當市場風險上升時，交易者傾向選擇保證金需求較低的商品，導致該價格區間的掛單價差變化更為明顯。因此，本研究選取每日早盤成交價介於 150 點至 250 點間之五檔履約價作為觀察對象，分析掛單行為如何引發流動性風險與改變訂單簿結構，並影響價格波動。

(一)流動性指標

流動性指標之建構使用選擇權市場中的最佳五檔委買價與委賣價，作為衡量市場流動性之核心變數。依據參考文獻中對流動性常見的衡量方式，選擇買賣價差(Bid-Ask Spread)作為代表性指標。此外為提升衡量精準度，本研究不採用單一報價的價差計算，而是考慮五檔報價資訊。買賣價差愈小，代表市場參與者較為積極，成交成本較低，市場流動性愈高；反之，當價差擴大，則表示市場深度不足或資訊不對稱加劇，導致流動性下降。

流動性指標(Liquidity)使用不同履約價之買權與賣權五檔報價資料為基礎，透過計算價差變動衡量市場流動性狀態，計算公式如(3.1.1、3.1.2 與 3.1.3)：

$$Liquidity = \sum_{i \in \{0,50,100,150,200\}} [\Delta CALL_{k+i} + \Delta PUT_{k+i}] \quad (3.1.1)$$

$$\Delta CALL_{K+i} = CALL_{K+i}(P_{ask5} - P_{ask1}) - CALL_{K+i}(P_{bid1} - P_{bid5}) \quad (3.1.2)$$

$$\Delta PUT_{K+i} = PUT_{K+i}(P_{bid1} - P_{bid5}) - PUT_{K+i}(P_{ask5} - P_{ask1}) \quad (3.1.3)$$

其中， K 表示表示基準履約價；
 $i \in \{0,50,100,150,200\}$ 為其的履約價範圍；
 $CALL_{K+i}$ 表示買權 $K + i$ 的履約價；
 PUT_{K+i} 表示買權的 $K + i$ 履約價；
 P_{ask5} 表示委買的最佳第五檔的價格；
 P_{ask1} 表示委買的最佳第一檔的價格；
 P_{bid5} 表示委買的最佳第五檔的價格；
 P_{bid1} 表示委買的最佳第一檔的價格。

(二)最高與最低價格定義

最高與最低價格定義為每一時間點 t 期貨於未來一段時間內的最高價與最低價，作為衡量未來波動幅度之依據，其計算方式如(3.1.4 與 3.1.5)：

$$P_{high} = \max(P_{t+1}, P_{t+2}, \dots, P_{t+30}) \quad (3.1.4)$$

$$P_{low} = \min(P_{t+1}, P_{t+2}, \dots, P_{t+30}) \quad (3.1.5)$$

其中， t 為時間點；
 P_{high} 為時間點 $t+30$ 資料中最高的臺指期成交價；
 P_{low} 為時間點 $t+30$ 資料中最低的臺指期成交價；
 P_{t+1} 為 t 筆之臺指期價格，以此類推。

(三)變化幅度定義

接著計算與當前價格 P_t 與最高價 P_{high} 及最低價 P_{low} 兩者之間的價差，分別定義為向上波動幅度 Δ_{up} 與向下波動幅度 Δ_{down} ，其計算方式如(3.1.6 與 3.1.7)：

向上波動幅度：

$$\Delta_{up} = |P_{high} - P_t| \quad (3.1.6)$$

向下波動幅度：

$$\Delta_{down} = |P_{low} - P_t| \quad (3.1.7)$$

其中， P_t 為當前成交價格。

(四)波動方向選擇

波動方向為定義每個時間點 t 的未來波動方向，根據未來一段時間內的最高價與最

低價，判斷當時市場的趨勢是偏向上漲還是下跌，其計算方式如(3.1.8)：

$$DV_t = \begin{cases} P_{low} - P_t, & \text{if } \Delta_{down} > \Delta_{up} \\ P_{high} - P_t, & \text{if } \Delta_{up} > \Delta_{down} \end{cases} \quad (3.1.8)$$

其中， DV_t 為波動方向。

此公式顯示往下跌的空間大於上漲時，視為下跌趨勢；反之亦然。

(五)三分類規則：

根據波動方向，將每筆資料分類為上漲(1)、下跌(-1)或盤整(0)三種類別，其分類規則如(3.1.9)：

$$Label_t = \begin{cases} 1, & \text{if } DV_t > 30 \\ 0, & \text{otherwise} \\ -1, & \text{if } DV_t < -30 \end{cases} \quad (3.1.9)$$

其中， $Label_t$ 為分類標籤。

本研究聚焦於選擇權市場中買賣方掛單行為，關注每日早盤時段的市場動態，觀察掛單於盤中的委買委賣結構與價格形成的因素。資料擷取買權(Call)與賣權(Put)之五檔履約價，並對應其五檔最佳委買與委賣價格資料(Best 5 Bid/Ask)。價格波動則採用臺指期貨於未來一段時間內之最高與最低價格進行評估，藉此更完整反映其價格變動幅度。並根據波動方向分為上漲、下跌、盤整。

二、深度學習模型設計

本研究透過 LSTM 與 CNN 建構波動預測模型，輸入變數包括流動性指標、選擇權成交量與技術分析指標等。本節將簡要介紹 LSTM 模型與 CNN 模型的原理與其應用方式。

(一)資料預處理

為確保資料品質研究進行多項資料清理，包括排除價格為零、實際委買委賣價格落差過大、選擇權成交量異常，以及資料缺失等狀況，此處理流程有效去除報價錯誤或系統遺漏所造成的異常值，避免對模型學習產生偏誤。

為使變數進行正規化處理，採用特徵標準化(Z-score Normalization)對輸入變數進行預處理，以提升模型訓練之穩定性與收斂速度。Z-score 標準化透過將每筆資料減去該變數的平均值後，再除以該變數的標準差，消除不同變數之間因尺度差異所造成的影響。此方式可避免在訓練過程中尺度較大的變數影響模型的參數更新，進而提升深度學習模型對各項特徵的學習效果與預測準確度。資料處理完成後，將資料集切分為 70%為訓練集，10%為驗證集，20%為測試集，以供模型進行訓練、參數調整及性能評估之用。

(二)LSTM

LSTM 模型透過其內部的門控機制動態學習市場資訊，其中輸入門負責決定當前時間點的資訊是否應被寫入記憶單元，以流動性指標、選擇權成交量為例，當模型偵測到流動性指標上升或成交量劇增等訊號具有潛在預測力時，輸入門會將其納入記憶，有助於辨識未來波動風險；而遺忘門則負責篩選過去的記憶資訊，當先前的市場異常狀態(如短期流動性衝擊)不再具參考價值時，模型會選擇性地將其遺忘，避免干擾後續預測；至於輸出門，則根據記憶單元所累積的歷史特徵，決定當時應輸出多少資訊作為隱藏狀態，影響預測結果。

(三)CNN

建構波動預測模型中，CNN 用於自動提取時間序列資料中的局部特徵，進一步提高模型對價格變動模式的辨識能力。CNN 透過卷積運算可偵測資料中局部區域的變化趨勢與異常結構，對於流動性指標、選擇權成交量等輸入變數，可捕捉短期內的突變訊號與特徵組合之間的交互關係。透過多層卷積核的運算，模型可逐層學習從原始變數中隱含的結構特徵，並保留於後續 LSTM 處理的時間序列特徵中，使整體模型捕捉短期特徵與長期依賴性中達到互補，提升波動性預測的準確性與穩定性。

(四)波動預測模型設計

波動方向預測模型採用 LSTM 模型與 CNN-LSTM 混合模型建構之方法。神經網路架構中，模型訓練參數是指在模型訓練前需手動設定的參數，對模型效能具有關鍵性的影響。本研究透過多次實驗調整找出適合的參數設定。

研究基本參數設定使用每十秒一筆的時間序列資料，移動窗格設定為 120 筆資料，每次向前移動一筆資料。輸入特徵變數共 9 項分為 Call 成交量、Put 成交量、總成交量、Call 流動性指標、Put 流動性指標，總流動性指標、臺指期貨、報酬率與 MA60。接續將介紹 LSTM 模型與 CNN-LSTM 混合模型的參數設計。

1.LSTM 參數設計

LSTM 參數設計方面，模型首先加入一層 LSTM，使用 64 個單元學習時間的動態變化，Dropout 比例設為 0.4 防止過擬合。接著，再加入第二層 LSTM 設定為 32 個單元，同樣設定 Dropout(0.4)。最後，加入一層全連接層(Dense Layer)，設定神經元數量為 32 並使用 ReLU 作為啟動函數，最後輸出層採用 Softmax 函數進行三類別分類。

2.CNN-LSTM 混合模型參數設計

CNN-LSTM 混合模型參數設計首先模型透過卷積層提取輸入資料的特徵。卷積層設置兩層，濾波器(filters)分為 64 與 32，其他設定都一致，卷積核大小(kernel size)為 15，並採用 ReLU 作為啟動函數，使用最大池化層(MaxPooling)，其池化視窗大小設定為 2，Dropout 比例設為 0.4 防止過擬合。接著加入一層 LSTM，使用 64 個單元學習時間的動態變化，Dropout 比例設為 0.4 防止過擬合。接著，再加入第二層 LSTM 設定為 32 個單元，同樣設定 Dropout(0.4)。最後，加入一層全連接層(Dense Layer)，設定神經元數量為 32 並使用 ReLU 作為啟動函數，最後輸出層採用 Softmax 函數進行三類別分類。

訓練方面兩種模型皆使用 Adam 作為優化器，損失函數設定為 Categorical Crossentropy。批次大小(Batch Size)為 128，總訓練輪數(Epochs)為 100，在訓練輪數中

額外設定提早停止機制，防止模型於訓練過程中出現過擬合的現象，檢查驗證損失 (Val_loss) 的變化情況，當驗證損失在連續 5 個訓練週期內無持續改善時，訓練將自動停止，並回到訓練期間表現最佳模型狀態。針對類別不平衡的問題，由於上漲與下跌比例遠少於盤整之比例，模型依照比例計算類別權重，增加上漲與下跌之權重並應用於模型訓練中，以提升預測準確性與穩定性。

三、模型評估方法

模型評估使用準確率(Accuracy)與 F1 分數(F1-score)，準確率衡量模型整體預測正確的比例，F1-score 是精確率(Precision)和召回率(Recall)的加權平均值，強調兩者之間的平衡，同時重視預測的精確率(Precision)與召回率(Recall)，達成降低誤判率與漏判率之間的平衡。

(一)準確率(Accuracy)

準確率衡量模型上漲、盤整與下跌整體預測正確的比例，計算方式如(3.4.1)：

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} * 100\% \quad (3.4.1)$$

(二)F1 分數(F1-score)

F1 分數定義為精確率(Precision)與召回率(Recall)之間的加權平均數，其為衡量測試準確度的標準，數值範圍介於 0 與 1 之間，數值越高代表模型精確率與召回率兩者間表現越佳，計算方式如(3.4.2)：

$$F1-score = 2 * \frac{Precision \cdot Recall}{Precision + Recall} * 100\% \quad (3.4.2)$$

(三)精確率(Precision)

精確率是指被模型預測為正類的樣本中，實際為正類的比例，其衡量方式是模型做出正向預測時做出正確分類的程度，計算方式如(3.4.3)：

$$Precision = \frac{TP}{TP + FP} * 100\% \quad (3.4.3)$$

(四)召回率(Recall)

召回率是指實際為正類的樣本中，被模型正確預測為正類的比例，其衡量模型找出所有正類樣本的能力，計算方式如(3.4.4)：

$$Recall = \frac{TP}{TP + FN} * 100\% \quad (3.4.4)$$

其中，TP 為預測正確且實際也是正類；
 TN 為預測正確且實際也是負類；
 FP 為預測為正類，但實際是負類；
 FN 為預測為負類，但實際是正類。

肆、實證結果

本研究使用臺灣期貨交易所提供之市場資料，資料期間涵蓋 2025 年三月至五月期間。資料對象包括臺指選擇權及周選擇權與臺指期貨之市場 tick 交易資訊，其中選擇權資料涵蓋各履約價的最佳五檔委買與委賣價格、成交價與成交量，而期貨商品部分則為 tick 成交價格。透過選擇權市場的流動性變化作為核心觀察指標，結合深度學習模型進行市場分類，將即時市場狀態區分為「上漲」、「盤整」與「下跌」三種類型。透過模型訓練與測試，驗證流動性訊號對市場方向具備領先效果。實證結果顯示，研究中所提之模型有效掌握盤中市場結構變動，協助投資人即時辨識潛在風險，進而提前規劃風險控管與交易策略。相較於僅依賴價格技術指標的預測方法，提供一種融合市場微結構的前瞻性模型。

實證結果分為兩節進行說明。第一節採用最小平方方法(OLS)分析，探討各變數與市場波動之間的關聯性；第二節則針對所建構的模型進行預測能力的比較與績效評估，分析不同模型的表現差異。

一、特徵相關性分析

本研究價格波動作為依變數，該依變數定義為每 60 筆報價中臺指期最高價與最低價之差的絕對值，代表短期內的市場波動幅度。自變數方面則包含 Call 與 Put 成交量、流動性指標、報酬率。OLS 迴歸相關分析結果如表 1 表示。

表 1：價格波動之 OLS 相關係數表

變數	係數	P 值
Call 成交量	-0.0004	0.789
Put 成交量	-0.0004	0.856
Call 流動性指標	-0.0547	0.000***
Put 流動性指標	-0.0193	0.036***
報酬率	-200.66	0.000***

OLS 迴歸相關分析實證結果顯示，Call 流動性指標係數為-0.0547，且 P 值 <0.001，是所有變數中影響力最大者，顯示市場中 Call 流動性不足時，常伴隨顯著的波動變動。Put 流動性指標係數為-0.0193，且 P 值 <0.001，顯示市場中 Put 流動性不足時亦會引發一定程度的波動變化。整體而言，流動性指標比單純的成交量更能解釋市場參與者的行為對波動的影響。報酬率呈顯著負向關係，係數為-200.66 且 P 值 <0.001，代表當市場下跌時，反而會使短線劇烈波動。Call 與 Put 成交量，P 值分別為 0.789 與 0.856，未達顯著水準，顯示成交量對波動變化的解釋力有限。

綜合分析結果可得，選擇權流動性指標為解釋市場波動的重要因子，其對短期波

動具有顯著的解釋力。雖然選擇權成交量於迴歸模型中未呈現顯著性，但作為市場流動性的重要指標(Datar et al., 1998)，仍具備一定的參考價值與預測潛力。因此研究將選擇權流動性指標與成交量納入深度學習模型中，以學習更複雜的波動特徵，藉此提升市場波動預測準確度。

二、模型分類指標與混淆矩陣分析

本章節評估 LSTM 與其衍生的 CNN-LSTM 模型，使用兩種模型對 5 分鐘與 10 分鐘的波動方向進行預測。透過實證分析，將兩種模型進行分類績效的評估，評估指標包括準確率(Accuracy)、F1 分數(F1-score)、精確率(Precision)與召回率(Recall)。藉由四個指標探討模型在預測市場波動方向的表現。

(一)LSTM 模型

本研究首先使用 LSTM 模型對 5 分鐘後的市場方向進行分類預測。經過模型訓練與驗證，模型在測試集上達到了 89.98% 的準確率，顯示整體分類準確率良好。如表 2 所示，盤整類別訓練樣本較多其預測效果也最佳，其精確率為 0.98，召回率為 0.91，代表模型能有效辨識盤整階段，且錯誤率較低。然而模型判斷上漲與下跌兩類的表現較差，精確率分別為 0.34 與 0.39，召回率皆達到 0.46 與 0.51。

實證結果顯示，模型對預測 5 分鐘後的市場波動方向只比隨機猜測的精準程度些微增加，模型整體 F1-score 為 0.64。顯示 LSTM 模型對預測 5 分鐘後的市場波動方向預測能力不足。

表 2、5 分鐘 LSTM 波動方向預測模型分類結果表

分類指標	下跌	盤整	上漲	模型整體
Precision	0.34	0.98	0.39	0.57
Recall	0.70	0.91	0.73	0.78
F1-score	0.46	0.95	0.51	0.64
樣本數	1,021	28,283	1,027	30,331

本研究透過混淆矩陣(Confusion Matrix)進行分析，觀察模型在不同類別的預測正確性與錯誤分類情形。如表 3 所示，表中橫列為實際分類結果行欄為模型預測結果，模型對於盤整類別的判斷較為穩定，正確分類數為 25834 筆，佔總樣本 91%。然而，盤整類別亦有部分樣本被誤分類為下跌 1316 筆與上漲 1133 筆。在下跌類別中，模型正確預測為下跌的樣本為 712 筆，但有 279 筆誤判為盤整，只有 30 筆誤判為上漲。而上漲類別中，模型正確分類為上漲的樣本為 745 筆，另外有 214 筆被誤分類為盤整，68 筆被誤分類為下跌。

表 3、5 分鐘 LSTM 波動方向預測模型的混淆矩陣表

實際預測	下跌	盤整	上漲
下跌	712	279	30
盤整	1,316	2,5834	1,133
上漲	68	214	745

接著使用 LSTM 模型對 10 分鐘後的市場方向進行分類預測，模型在測試集上達到了 89.96% 的準確率，與預測 5 分鐘後的模型準確率無明顯區別。如表 4 所示，盤整類別

數量最多預測效果也最佳，其精確率為 0.96，召回率為 0.93。模型在判斷上漲與下跌兩類的表現優良，精確率分別為 0.72 與 0.63，召回率皆達到 0.81 與 0.81，模型整體 F1-score 為 0.80。實證結果顯示 LSTM 模型對預測 10 分鐘後的市場波動方向預測能力優異。

表 4、10 分鐘 LSTM 波動方向預測模型分類結果表

分類指標	下跌	盤整	上漲	模型整體
Precision	0.63	0.96	0.72	0.77
Recall	0.81	0.93	0.81	0.85
F1-score	0.71	0.95	0.77	0.81
樣本數	2,898	24,827	2,606	30,331

本研究透過混淆矩陣進行分析，觀察模型在不同類別的預測正確性與錯誤分類情形。如表 5 所示，模型對於盤整類別的判斷較為穩定，正確分類數為 22815 筆，佔總樣本 91%。然而，盤整類別亦有部分樣本被誤分類為下跌，其筆數為 1250 筆與上漲 762 筆。在下跌類別中，模型正確預測為下跌的樣本為 2348 筆，有 505 筆誤判為盤整，只有 45 筆誤判為上漲。而上漲類別中，模型正確分類為上漲的樣本為 2122 筆，有 370 筆被誤分類為盤整，114 筆被誤分類為下跌。

表 5、10 分鐘 LSTM 波動方向預測模型分類混淆矩陣表

實際\預測	下跌	盤整	上漲
下跌	2,348	505	45
盤整	1,250	22,815	762
上漲	114	370	2,122

(二)CNN-LSTM 混合模型

本研究結合 CNN 與 LSTM，構建 CNN-LSTM 混合模型對 5 分鐘後的市場波動方向進行分類預測。實驗結果顯示，CNN-LSTM 模型在測試集上的分類準確率達 94.20%，優於僅使用 LSTM 模型的 89.98%。

如表 6 所示，CNN-LSTM 混合模型與 LSTM 模型一樣也對盤整類別具有高的辨識能力，精確率為 0.96、召回率達 0.98。而在上漲與下跌的類別中，精確率分別為 0.58 與 0.58，召回率分別為 0.54 與 0.38，整體 F1-score 為 0.66。

表 6、5 分鐘 CNN-LSTM 波動方向預測模型分類結果表

分類指標	下跌	盤整	上漲	模型整體
Precision	0.58	0.96	0.58	0.71
Recall	0.38	0.98	0.54	0.63
F1-score	0.46	0.97	0.56	0.66
樣本數	1,021	28,283	1,027	30,331

本研究透過混淆矩陣進行分析，CNN-LSTM 混合模型在各類別間的誤判情形相對較低，展現出良好的市場辨識能力。如表 7 所示，盤整類別的分類表現最為優異，共有 27,628 筆樣本被正確分類，僅有 264 筆誤判為下跌、391 筆誤判為上漲，顯示模型能明確辨識盤整區間。在下跌類別中，模型正確預測 392 筆，但有 621 筆被誤判為盤整，另有 8

筆誤判為上漲；而在上漲類別中，模型正確分類 553 筆，有 453 筆誤判為盤整，21 筆誤判為下跌。

表 7、5 分鐘 CNN-LSTM 波動方向預測模型混淆矩陣表

實際\預測	下跌	盤整	上漲
下跌	392	621	8
盤整	264	27,628	391
上漲	21	453	553

最後，CNN-LSTM 混合模型對 10 分鐘後的市場波動方向進行分類預測。實驗結果顯示，CNN-LSTM 混合模型在測試集上的分類準確率達 90.98%，與僅使用 LSTM 模型的準確度 89.96%，高出 1%。

如表 8 所示，CNN-LSTM 混合模型對盤整類別具有良好的辨識能力，精確率為 0.93、召回率達 0.96。而在上漲與下跌的類別中，精確率分別為 0.78 與 0.78，召回率分別為 0.76 與 0.68。模型整體 F1-score 為 0.79。

表 8、10 分鐘 CNN-LSTM 波動方向預測模型分類結果表

分類指標	下跌	盤整	上漲	模型整體
Precision	0.78	0.93	0.78	0.83
Recall	0.60	0.96	0.75	0.77
F1-score	0.68	0.95	0.76	0.80
樣本數	2,898	24,827	2,606	30,331

本研究透過混淆矩陣進行分析，CNN-LSTM 混合模型在各類別間的誤判情形相對較低。如表 9 所示，盤整類別的分類表現最為優異，共有 23,890 筆樣本被正確分類，僅有 418 筆被誤判為下跌、519 筆誤判為上漲，顯示模型能明確辨識盤整區間。在下跌類別中，模型正確預測 1,749 筆樣本，其中有 1,112 筆被誤判為盤整，37 筆誤判為上漲；而在上漲類別中，模型正確分類 1,956 筆，有 583 筆誤判為盤整，67 筆誤判為下跌。

表 9、10 分鐘 CNN-LSTM 波動方向預測模型混淆矩陣表

實際\預測	下跌	盤整	上漲
下跌	1,749	1,112	37
盤整	418	23,890	519
上漲	67	583	1,956

實證結果顯示，CNN-LSTM 混合模型在預測 5 分鐘市場變動方向時的表現優於單純的 LSTM 模型，其準確率分別為 94.20%與 89.98%，F1 則為 0.66 與 0.64，顯示在分類準確率上具有優勢。然而，在預測 10 分鐘市場變動方向時，兩者表現相近，CNN-LSTM 混合模型與 LSTM 模型的準確率分別為 90.98%與 89.96%，F1 則為 0.79 與 0.80，差異相對不明顯。整體觀察發現，無論是 CNN-LSTM 混合模型或 LSTM 模型，在預測 10 分鐘變動方向時的 F1 分數皆優於 5 分鐘，顯示較長時間頻率的市場變動較為明確，相較於五分鐘提高模型的辨識能力。顯示可能 5 分鐘的市場波動幅度較小，訊號較難以有效辨識。

混淆矩陣結果顯示，CNN-LSTM 混合模型與 LSTM 模型在辨識上漲與下跌趨勢時，較容易誤判為盤整，但誤判為相反方向的情形相對較少。顯示兩種模型僅在趨勢強度較不明確時容易判為盤整，整體而言皆具備良好的市場波動方向辨識能力。

綜合而言，CNN-LSTM 混合模型結合卷積神經網路的特徵提取能力與 LSTM 的時間序列學習特性，具備提升預測效能與分類的表現。於時間頻率中，十分鐘的頻率相對於五分鐘展現出優異的預測結果，因此，本研究推論時間刻度較小導致波動較難以辨識，可能顯示價格波動分類門檻值有著關鍵的作用，未來研究建議進一步探討分類門檻值的設定，優化模型在不同頻率的預測準確度與辨識能力。

伍、結論與建議

本研究聚焦於選擇權市場利用買賣雙方的掛單行為作為流動性衡量依據預測價格波動之方向。選擇權市場具備高度流動性及買賣雙方成本結構差異，適合作為流動性與掛單行為變化之觀察標的。研究中使用流動性指標與成交量等變數等量化數據，以應用 CNN-LSTM 混合模型進行價格波動方向預測。

一、結論

本研究成功驗證選擇權流動性指標對價格波動的影響，實證結果顯示流動性指標顯著影響價格波動。基於流動性與價格波動之間的關聯性將買賣價差作為主要變數，納入深度學習模型中建構日內波動方向預測模型。

日內波動方向預測模型成功對價格波動方向進行預測，實證結果顯示流動性指標與成交量等流動性變數具備預測短期價格波動方向之能力，證實此方法具備市場實務應用潛力。

理論層面貢獻，本研究結合買賣雙方掛單行為的流動性衡量方式與深度學習模型補充現有流動性文獻中對高頻交易與短期風險預測方法的不足，提供新的衡量方式與模型。實務層面貢獻，日內波動方向預測模型可作為即時預警工具，協助投資人提早掌握市場變化，並對交易策略設計與風險管理具有應用價值。

二、未來展望與建議

根據本研究結果建議未來研究之方向，實證結果中選擇權成交量於 OLS 相關性檢定未顯示出顯著性，但根據 Zhao et al.(2024)研究結果顯示成交量與市場波動之間存在顯著相關性。未來研究可接續探討兩者差異之原因，證實選擇權成交量與波動性之間的相關性。

變數選取方面，僅擷取五檔買權與五檔賣權的履約價作為分析依據，可能無法全面反映整體市場的流動性。未來可納入更多履約價進行計算，或結合期貨與現貨之流動性指標與買賣價差等流動性變數，以建構更為完整的風險預警模型。目標變數設計方面，實證結果顯示波動分類門檻值在分類不同頻率資料中具有關鍵影響，未來研究建議進一步探討分類門檻值之設定，可優化模型於不同時間頻率的預測準確度與穩定性。

模型設計方面，即使 CNN-LSTM 模型於本研究中表現優異，仍建議嘗試其他混合深度學習模型如 Transformer、TCN、Bi-LSTM 等進行比較，避免模型過度擬合資料，

並驗證模型穩健性提升於不同資料與市場條件的泛化能力，使實證結果更具完整性與說服力。

參考文獻

- Amihud, Y. (2002). Illiquidity and Stock Returns: Cross-Section and Time-Series Effects. *Journal of Financial Markets*, 5(1), 31–56. [https://doi.org/10.1016/S1386-4181\(01\)00024-6](https://doi.org/10.1016/S1386-4181(01)00024-6)
- Alghamdi, H., & Alqithami, S. (2025). A Robust Machine Learning Framework for Stock Market Classification. *Expert Systems with Applications*, Article 128573. <https://doi.org/https://doi.org/10.1016/j.eswa.2025.128573>
- Black, F., & Scholes, M. (1973). The pricing of options and corporate liabilities. *Journal of Political Economy*, 81(3), 637–654. <https://doi.org/10.1086/260062>
- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroscedasticity. *Journal of Econometrics*, 31(3), 307–327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Bondarenko, O. (2001). Competing Market Makers, Liquidity Provision, and Bid–Ask Spreads. *Journal of Financial Markets*, 4(3), 269–308. [https://doi.org/https://doi.org/10.1016/S1386-4181\(01\)00014-3](https://doi.org/https://doi.org/10.1016/S1386-4181(01)00014-3)
- Brunnermeier, M. K., & Pedersen, L. H. (2009). Market liquidity and funding liquidity. *The Review of Financial Studies*, 22(6), 2201–2238. <https://doi.org/10.1093/rfs/hhn098>
- Chordia, T., Roll, R., & Subrahmanyam, A. (2008). Liquidity and Market Efficiency. *Journal of Financial Economics*, 87(2), 249–268. <https://doi.org/https://doi.org/10.1016/j.jfineco.2007.03.005>
- Cao, C., Hansch, O., & Wang, X. (2009). The Information Content of an Open Limit-Order Book. *Journal of Futures Markets*, 29(1), 16–41. <https://doi.org/https://doi.org/10.1002/fut.20334>
- Chung, K. H., & Chuwonganant, C. (2018). Market Volatility and Stock Returns: The Role of Liquidity Providers. *Journal of Financial Markets*, 37, 17–34. <https://doi.org/https://doi.org/10.1016/j.finmar.2017.07.002>
- Chulia, H., Koser, C., & Uribe, J. M. (2020). Uncovering the Time-Varying Relationship between Commonality in Liquidity and Volatility. *International Review of Financial Analysis*, 69, Article 101466. <https://doi.org/https://doi.org/10.1016/j.irfa.2020.101466>
- Choi, J. H., & Munro, D. (2022). Market Liquidity and Excess Volatility: Theory and Experiment. *Journal of Economic Dynamics and Control*, 139, Article 104442. <https://doi.org/10.1016/j.jedc.2022.104442>
- Coppola, A., Urga, G., & Varaldo, A. (2024). Asset Class Liquidity Risk Indicators. Timing the Risk in the European and US Equity and Bond Markets. *Journal of Financial Stability*, Article 101369. <https://doi.org/10.1016/j.jfs.2024.101369>

- Demsetz, H. (1968). The Cost of Transacting. *The Quarterly Journal of Economics*, 82, 33–53. <https://doi.org/10.2307/1882244>
- Datar, V. T., Naik, N. Y., & Radcliffe, R. (1998). Liquidity and Stock Returns: An Alternative Test. *Journal of Financial Markets*, 1(2), 203–219. [https://doi.org/https://doi.org/10.1016/S1386-4181\(97\)00004-9](https://doi.org/https://doi.org/10.1016/S1386-4181(97)00004-9)
- Dakalbab, F., Talib, M. A., Nasir, Q., & Saroufil, T. (2024). Artificial Intelligence Techniques in Financial Trading: A Systematic Literature Review. *Journal of King Saud University - Computer and Information Sciences*, 36(3), Article 102015. <https://doi.org/10.1016/j.jksuci.2024.102015>
- Dubey, R., & Enke, D. (2025). Bitcoin Price Direction Prediction Using On-Chain Data and Feature Selection. *Machine Learning with Applications*, 20, Article 100674. <https://doi.org/https://doi.org/10.1016/j.mlwa.2025.100674>
- Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50, 987–1007. <https://doi.org/10.2307/1912773>
- Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36(4), 193–202. <https://doi.org/10.1007/BF00344251>
- Feng, F. Y., Kang, W., & Zhang, H. (2023). Liquidity Shocks and the Negative Premium of Liquidity Volatility around the World. *Journal of International Money and Finance*, 139, Article 102966. <https://doi.org/https://doi.org/10.1016/j.jimonfin.2023.102966>
- Fang, Z., & Cai, toby. (2025). Deep Neural Network Modeling for Financial Time Series Analysis. *Big Data Research*, 41, Article 100553. <https://doi.org/https://doi.org/10.1016/j.bdr.2025.100553>
- Gunnarsson, E. S., Isern, H. R., Kaloudis, A., Risstad, M., Vigdel, B., & Westgaard, S. (2024). Prediction of Realized Volatility and Implied Volatility Indices Using AI and Machine Learning: A Review. *International Review of Financial Analysis*, 93, Article 103221. <https://doi.org/https://doi.org/10.1016/j.irfa.2024.103221>
- Hochreiter, S. (1991). *Untersuchungen zu dynamischen neuronalen Netzen* [Diploma thesis, Technische Universität München]. Technische Universität München.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Huang, Z. C., Sangiorgi, I., & Urquhart, A. (2024). Forecasting Bitcoin Volatility Using Machine Learning Techniques. *Journal of International Financial Markets, Institutions and Money*, 97, Article 102064. <https://doi.org/https://doi.org/10.1016/j.intfin.2024.102064>

- Kanzari, D., Nakhli, M. S., Gaies, B., & Sahut, J. M. (2023). Predicting Macro-Financial Instability – How Relevant Is Sentiment? Evidence from Long Short-Term Memory Networks. *Research in International Business and Finance*, 65, Article 101912.
<https://doi.org/https://doi.org/10.1016/j.ribaf.2023.101912>
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, 1(4), 541–551. <https://doi.org/10.1162/neco.1989.1.4.541>
- Lin, W. T., Tsai, S. C., & Chiu, P. (2016). Do Foreign Institutions Outperform in the Taiwan Options Market? *Journal of Financial Markets*, 35, 101–115.
<https://doi.org/https://doi.org/10.1016/j.najef.2015.10.005>
- Li, A. W., & Bastos, G. S. (2020). Stock Market Forecasting Using Deep Learning and Technical Analysis: A Systematic Review. *IEEE Access*, 8, 185232–185242.
<https://doi.org/10.1109/ACCESS.2020.3030226>
- Lin, Y., Chen, K., Zhang, X., Tan, B., & Lu, Q. (2022). Forecasting Crude Oil Futures Prices Using BiLSTM-Attention-CNN model with Wavelet Transform. *Applied Soft Computing*, 130, Article 109723. <https://doi.org/10.1016/j.asoc.2022.109723>
- Liu, B., Prodromou, T., Suardi, S., & Xu, C. (2025). Ethereum’s Merge: Market Liquidity, Efficiency and Volatility in the Proof of Stake Era. *Economics Letters*, 247, Article 112202.
<https://doi.org/https://doi.org/10.1016/j.econlet.2025.112202>
- Ma, R., Anderson, H. D., & Marshall, Ben R. (2018). Market Volatility, Liquidity Shocks, and Stock Returns: Worldwide Evidence. *Pacific-Basin Finance Journal*, 49, 164–199.
<https://doi.org/https://doi.org/10.1016/j.pacfin.2018.04.008>
- Munoz mendoza, J. a., Ferreira, G., & Márquez sanders, V. a. (2023). Liquidity Spillovers in the Global Stock Markets: Lessons for Risk Management. *Global Finance Journal*, 58, Article 100896. <https://doi.org/10.1016/j.gfj.2023.100896>
- Nguyen, G., Engle, R., Fleming, M., & Ghysels, E. (2020). Liquidity and Volatility in the U.S. Treasury Market. *Journal of Econometrics*, 217(2), 207–229.
<https://doi.org/https://doi.org/10.1016/j.jeconom.2019.12.002>
- Rao, A., Sharma, G. D., Tiwari, A. K., Hossain, M. R., & Dev, D. (2025). Crude Oil Price Forecasting: Leveraging Machine Learning for Global Economic Stability. *Technological Forecasting and Social Change*, 216, Article 124133.
<https://doi.org/https://doi.org/10.1016/j.techfore.2025.124133>
- Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 3(3), 210–229. <https://doi.org/10.1147/rd.33.0210>
- Sojka, B. B., & Kliber, A. (2019). The Causality between Liquidity and Volatility in the Polish Stock Market. *Finance Research Letters*, 30, 110–115.
<https://doi.org/https://doi.org/10.1016/j.frl.2019.04.008>

- Tang, T., & Wang, Y. (2022). Liquidity Shocks, Price Volatilities, and Risk-Managed Strategy: Evidence from Bitcoin and Beyond. *Journal of Multinational Financial Management*, 64, Article 100729. <https://doi.org/10.1016/j.mulfin.2022.100729>
- Valenzuela, M., Zer, I., Fryzlewicz, P., & Rheinlander, T. (2015). Relative Liquidity and Future Volatility. *Journal of Financial Markets*, 24, 25–48. <https://doi.org/https://doi.org/10.1016/j.finmar.2015.03.001>
- Xu, Y., Huang, D., Ma, F., & Qiao, G. (2019). Liquidity and Realized Range-Based Volatility Forecasting: Evidence from China. *Physica A: Statistical Mechanics and Its Applications*, 525, 1102–1113. <https://doi.org/https://doi.org/10.1016/j.physa.2019.03.122>
- Xu, Y., Liu, J., Ma, F., & Chu, J. (2024). Liquidity and Realized Volatility Prediction in Chinese Stock Market: A Time-Varying Transitional Dynamic Perspective. *International Review of Economics & Finance*, 89, 543–560. <https://doi.org/10.1016/j.iref.2023.07.083>
- Xu, Y., Liu, T., & Du, P. (2024). Volatility Forecasting of Crude Oil Futures Based on Bi-LSTM-Attention Model: The Dynamic Role of the COVID-19 Pandemic and the Russian-Ukrainian Conflict. *Resources Policy*, 88, Article 104319. <https://doi.org/10.1016/j.resourpol.2023.104319>
- You, W., Chen, J., Xie, H., & Ren, Y. (2025). Which Uncertainty Measure Better Predicts Gold Prices? New Evidence from a CNN-LSTM Approach. *The North American Journal of Economics and Finance*, 76, Article 102375. <https://doi.org/10.1016/j.najef.2025.102375>
- Yu, B., Dong, L., Qin, Z., & Lam, K. S. k. (2025). What Is the Best Composite Liquidity Proxy for Explaining Stock Returns? Evidence from the Chinese Stock Market. *Pacific-Basin Finance Journal*, 91, Article 102686. <https://doi.org/https://doi.org/10.1016/j.pacfin.2025.102686>
- Zhu, M., Chiarella, C., He, X. Z., & Wang, D. (2009). Does the Market Maker Stabilize the Market? *Journal of Financial Economics*, 388(15–16), 3164–3180. <https://doi.org/10.1016/j.physa.2009.04.013>
- Zhang, J., Liu, H., Bai, W., & Li, X. (2024). A Hybrid Approach of Wavelet Transform, ARIMA and LSTM Model for the Share Price Index Futures Forecasting. *The North American Journal of Economics and Finance*, 69, Article 102022. <https://doi.org/10.1016/j.najef.2023.102022>
- Zhao, L., Nguyen, V. H., & Li, C. (2024). The Volatility-Liquidity Dynamics of Single-Stock ETFs. *Finance Research Letters*, 69, Article 106163. <https://doi.org/10.1016/j.frl.2024.106163>
- Zhao, C., Chen, Y., Wu, L., Dai, Y., Chen, E., Wu, L., & Zhang R. (2025). High-Frequency Liquidity in the Chinese Stock Market: Measurements, Patterns, and Determinants. *Pacific-Basin Finance Journal*, 90, Article 102681. <https://doi.org/https://doi.org/10.1016/j.pacfin.2025.102681>