

國立臺灣大學管理學院財務金融學系



碩士論文

Department of Finance
College of Management
National Taiwan University
Master Thesis

基於限價委託簿，使用深度學習模型預測比特幣期貨
之未來價格漲跌

Predicting Bitcoin Futures Price Movements by Deep
Learning Based on the Limit Order Book

陳韋勳

Wei-Shiun Chen

指導教授：呂育道 博士

Advisor: Yuh-Dauh Lyuu, Ph.D.

中華民國 112 年 7 月

July 2023

國立臺灣大學碩士學位論文

口試委員會審定書

基於限價委託簿，使用深度學習模型預測比特幣期貨
之未來價格漲跌

Predicting Bitcoin Futures Price Movements by Deep
Learning Based on the Limit Order Book

本論文係陳韋勳君 (R10723058) 在國立臺灣大學財務金融學所完成之碩士學位論文，於民國 112 年 7 月 14 日承下列考試委員審查通過及口試及格，特此證明。

口試委員：

呂育通

(簽名)

(指導教授)

謝嘉

金國興

陸裕音

王紹智

(簽名)

系主任、所長



誌謝

在碩士論文的撰寫過程中，我要衷心感謝我的指導教授呂育道老師。您的悉心指導與無私支持讓我能夠在這學術旅程中不斷成長。您給予我的信任和鼓勵，讓我敢於探索新領域，並克服種種困難。

接著，我想向我的朋友們表達誠摯的謝意。你們的幫助和鼓勵是我學習的動力，我感激你們不辭辛勞地給予建議和支持。有你們的陪伴，我的求學之路更加豐富多彩。

最重要的是，我要深深感謝我的父母。感謝你們給予我進修碩士學位的機會和無盡的支持。你們的愛意和無私奉獻讓我能夠勇敢面對挑戰，並堅持追求夢想。沒有你們，我無法走到今天的這一步。

在此，我也要感謝所有關心支持我的人們。你們的鼓勵和支持是我求學路上的珍貴財富，是我不斷進步的動力。謝謝你們的關愛，願我們的情誼長存，共同見證更美好的時刻。

衷心感謝大家!

摘要

近年來比特幣期貨市場發展迅速，成為投資人熱門的領域之一，本研究採用經過傳統金融市場驗證的深度學習模型 DeepLOB，利用幣安交易所的比特幣期貨限價委託簿預測該市場未來價格的漲跌。透過與傳統線性模型的比較，發現 DeepLOB 模型具有更準確的預測能力，顯示其在擷取市場特徵和捕捉趨勢方面表現得更優異。此外，由於 DeepLOB 模型使用的限價委託簿表示法會導致其不穩定的預測結果，本研究採用 Wu、Mahfouz、Magazzeni 和 Veloso 提出的限價委託簿穩健表示法來取代模型原始的方法，實驗結果顯示新的表示法有助於提升 DeepLOB 模型的預測能力。

總體而言，本研究顯示 DeepLOB 模型在幣安交易所的比特幣期貨市場中比傳統線性模型表現得更優異，且透過使用限價委託簿穩健表示法可以進一步提升預測準確度。這些結果為投資人提供有益的參考，協助他們在比特幣期貨市場中做出更明智的決策。

關鍵字：比特幣期貨、幣安交易所、限價委託簿、DeepLOB、穩健表示法

ABSTRACT



In recent years, the Bitcoin futures exchanges have experienced rapid development and have become a popular area for investors. This thesis applies the DeepLOB, a deep learning model validated in traditional financial markets. It utilizes the limit order book of Bitcoin futures from the Binance exchange to forecast futures price movements. Through a comparison with traditional linear models, it is found that the DeepLOB model demonstrates more accurate predictive capabilities, indicating its superior performance in capturing market features and trends.

The original representation of the limit order book in the DeepLOB model can lead to unstable predictions. This thesis adopts the robust representation of Wu, Mahfouz, Magazzeni and Veloso (2021). Experimental results show that the new representation contributes to improving the predictive capabilities of the DeepLOB model.

Overall, this thesis demonstrates that the DeepLOB model outperforms traditional linear models for the Bitcoin futures traded on the Binance exchange, and the robust limit order book representation further enhances accuracy in prediction. These findings provide valuable insights for investors, assisting them in making more informed decisions in the Bitcoin futures markets.


Keywords: Bitcoin futures, Binance exchange, limit order book, DeepLOB, robust representation

目錄



口試委員會審定書	i
誌謝	ii
摘要	iii
ABSTRACT	iv
目錄	v
圖目錄	vii
表目錄	viii
第一章 緒論	1
1.1 研究動機與簡介	1
1.2 論文架構	3
第二章 背景知識	4
2.1 模型介紹	4
2.1.1 羅吉斯迴歸	4
2.1.2 前饋神經網路	5
2.1.3 卷積神經網路	6
2.1.4 遞迴神經網路	8
2.1.5 DeepLOB	10
2.2 限價委託簿的穩健表示法	13
第三章 實驗方法	15
3.1 實驗設計	15
3.2 實驗資料	15
3.2.1 資料來源	15
3.2.2 資料切割	16
3.2.3 資料正規化	17
3.3 預測目標值設計	17
3.4 模型績效評比指標	20

第四章	實驗結果	21
4.1	實驗一結果	21
4.2	實驗二結果	23
第五章	結論與後續研究	25
5.1	結論	25
5.2	後續研究	25
參考文獻		27



圖目錄

圖 2.1、DEELOB 模型架構圖[6].....	10
圖 2.2、CNN 模塊運作示意圖[13].....	11
圖 2.3、INCEPTION 模塊運作示意圖[13].....	12
圖 2.4、原始限價委託簿表示法出現插單後的結果示意圖	13
圖 2.5、限價委託簿穩健表示法出現插單後的結果示意圖	14
圖 3.1、幣安提供的比特幣期貨限價委託簿示意圖	16
圖 4.1、(左) 羅吉斯迴歸模型的混淆矩陣；(右) DEELOB 模型的混淆矩陣	22
圖 4.2、(左) 使用原始表示法的 DEELOB 模型的混淆矩陣；(右) 使用穩健表示法的 DEELOB 模型的混淆矩陣	24



表目錄

表 4.1、羅吉斯迴歸模型預測漲、持平、跌的次數和比例	21
表 4.2、DEEPLOB 模型預測漲、持平、跌的次數和比例.....	21
表 4.3、使用原始表示法的 DEEPLOB 模型預測漲、持平、跌的次數和比例.....	23
表 4.4、使用穩健表示法的 DEEPLOB 模型預測漲、持平、跌的次數和比例.....	23

第一章 緒論



1.1 研究動機與簡介

近年來加密貨幣市場的蓬勃發展引起了全球投資者的關注，其中，比特幣期貨的交易量呈現快速增長的趨勢[4]。在這個市場中，價格波動巨大，投資者需要對未來的價格變化進行準確預測，以制定合理的投資策略。

限價委託簿是一種常見的交易工具，它反映了市場上交易者的意向和需求，對於預測價格變化具有重要的參考價值[1]。然而，傳統的預測方法往往難以捕捉到這種複雜的市場結構和交易者行為，因此需要引入先進的機器學習技術來提高預測準確率。

根據 Zaznov、Kunkel、Dufour 和 Badii 調查，股價預測研究的早期常使用傳統的數學和統計模型，例如隱馬可夫模型 (hidden Markov model, HMM)、線性迴歸和基本機器學習模型，如反向傳播神經網路 (backpropagation neural network) 和支持向量機 (support vector machine, SVM)。然而，近年來股票預測模型已發展成更深層次的機器學習模型，且通常具有更複雜的結構，例如卷積神經網路 (convolutional neural network, CNN) 和長短期記憶模型 (long short-term memory model, LSTM)。最近的研究中，一些作者提出了深度學習模型的特制組合，這些模型由不同類型的層組成[12]，例如結合卷積和長短期記憶層的模型，像是 Zhang、Zohren 和 Roberts 提出的 DeepLOB 模型[13]。

卷積神經網路在圖像識別領域取得了顯著的成果，其具有優秀的特徵擷取能力。長短期記憶模型特別擅長處理序列數據，它可以記住過去的信息並能夠在需要時快速提取[2]。將卷積神經網路和長短期記憶模型這兩種深度學習模型結合使用，可以綜合利用兩種模型的優點來預測比特幣期貨價格的未來漲跌走勢。卷積神經網路可以有效地從限價委託簿等市場信息中擷取特徵，挖掘出更深層次的市場規

律，而長短期記憶模型可以更好地捕捉價格趨勢的演化過程，並且具有較好的序列建模和長期記憶能力。因此，結合這兩種模型進行比特幣期貨價格預測，可以綜合利用它們的優點，提高預測的準確性。

為了進一步驗證這類模型的預測力，本研究使用幣安交易所提供的比特幣期貨限價委託簿數據進行訓練和測試，從而綜合考慮市場的動態變化和價格變化的時序性。透過對大量的市場數據進行訓練和調整模型參數，本研究期望能夠得到更加準確和穩定的比特幣期貨價格預測結果，並為投資者提供更好的決策參考。



1.2 論文架構

本研究的架構如下所述：第一章是緒論，旨在說明研究的動機和簡介；第二章是背景知識，介紹所使用模型的特點和架構以及介紹實驗中使用的限價委託簿表示法；第三章是實驗方法，其中包括對實驗設計和細節的說明；第四章是實驗結果，呈現並解釋實驗結果。最後，第五章是結論與未來後續研究方向，總結了本研究的主要結論並提出未來可能的研究方向。

第二章 背景知識



2.1 模型介紹

2.1.1 羅吉斯迴歸

羅吉斯迴歸 (logistic regression) [5]是一種統計學習方法，主要應用於二元分類 (binary classification) 任務。它假設因變數 (dependent variable) Y 與自變數 (independent variable) X 之間存在線性關係，通過應用 sigmoid 函數，線性結果被轉換到 $[0,1]$ 的區間內，用以表示 $Y = 1$ 的機率。

羅吉斯迴歸模型的數學表達式為：

$$P(Y = 1|X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p)}} \quad (2.1.1)$$

其中， $P(Y = 1|X)$ 表示當自變數 X 給定時，因變數 Y 為 1 的機率； β_0 是截距項； $\beta_1, \beta_2, \dots, \beta_p$ 是自變數的權重參數； X_1, X_2, \dots, X_p 是自變數的值。

當有多個因變數時，可以擴展為多元羅吉斯迴歸 (multinomial logistic regression) 模型，其數學表達式為：

$$P(Y = k|X) = \frac{e^{\beta_{k0} + \beta_{k1} X_1 + \beta_{k2} X_2 + \dots + \beta_{kp} X_p}}{\sum_{j=1}^K e^{\beta_{j0} + \beta_{j1} X_1 + \beta_{j2} X_2 + \dots + \beta_{jp} X_p}} \quad (2.1.2)$$

其中， $P(Y = k|X)$ 表示當自變數 X 給定時，因變數 Y 等於 k 的概率； K 是因變數 Y 的類別數量； $\beta_{k0}, \beta_{k1}, \beta_{k2}, \dots, \beta_{kp}$ 是自變數對應於 $Y = k$ 的權重參數； $\sum_{j=1}^K e^{\beta_{j0} + \beta_{j1} X_1 + \beta_{j2} X_2 + \dots + \beta_{jp} X_p}$ 是所有類別的總和，用於將所有 $P(Y = k|X)$ 總和歸一化。

羅吉斯迴歸通常使用最大似估計方法 (maximum likelihood estimation) 進行訓練，透過最大化似然函數 (likelihood function)，找到最符合觀察數據的模型參數。使用梯度下降法 (gradient descent) 迭代調整參數值，直到達到最大似然函數。



2.1.2 前饋神經網路

前饋神經網路 (feedforward neural network) [9] 是一種機器學習模型，主要應用於分類和迴歸任務。它由神經元和權重連結組成，神經元按照層次組織成神經網路，每層神經元與下一層之間的連結都是一組權重，用來控制信號在網路中的傳播和轉換。前饋神經網路由輸入層、隱藏層和輸出層組成，其中隱藏層可以有多層。每個神經元的輸出是由上一層的所有神經元的輸出和權重加權相加，再通過一個非線性函數進行轉換，例如 sigmoid 函數、ReLU 函數等得到。最後，通過輸出層產生預測結果。

在多類別分類任務中，可以使用 softmax 函數作為輸出層的非線性函數，以產生各個類別的機率分佈。假設神經網路有 L 層，第 l 層有 n^l 個神經元，用 z^l 表示第 l 層的輸入向量， a^l 表示第 l 層的輸出向量， W^l 表示第 l 層到第 $l+1$ 層的權重矩陣， b^l 表示第 $l+1$ 層的偏置向量， f 表示神經元的非線性函數。那麼，神經網路的正向傳播可以表示為：

$$z^{l+1} = W^l a^l + b^l \quad (2.1.3)$$

$$a^{l+1} = f(z^{l+1}) \quad (2.1.4)$$

其中， a^0 表示輸入層的輸入向量。

對於一個 K 個類別的分類任務，輸出層的激活函數可以使用 softmax 函數：

$$a_k^l = \frac{e^{z_k^l}}{\sum_{i=1}^K e^{z_i^l}} \quad (2.1.5)$$

前饋神經網路在訓練過程中通常使用反向傳播算法 (backpropagation algorithm) 進行權重更新，以最小化損失函數。常見的損失函數包括交叉熵 (cross-entropy) 和均方誤差 (mean squared error, MSE)。反向傳播算法通過計算損失函數對權重和偏置的梯度，然後利用梯度下降法 (gradient descent) 進行權重更新，直到收斂。



2.1.3 卷積神經網路

卷積神經網路 (convolutional neural network, CNN) [8]是一種廣泛應用於圖像分類和目標檢測任務的深度學習模型。卷積神經網路的特點是利用卷積 (convolutional) 運算進行特徵擷取，透過池化 (pooling) 操作進行特徵降維，最後通過全連接層 (fully connected layer) 進行分類。

卷積神經網路的核心是卷積層 (convolutional layer)，其運作方式是通過卷積運算擷取圖像特徵，從而實現圖像分類和識別等任務。卷積運算是一種將圖像的小區域與卷積核進行乘積累加的操作，卷積核通常是一個小的正方形矩陣，其中的元素稱為權重。卷積核的大小和權重可以根據任務的需要進行調整。

假設輸入的圖像是一個 $n \times n$ 的二維矩陣，卷積層包含 m 個卷積核 (kernel)，每個卷積核都是一個 $k \times k$ 的二維矩陣，卷積操作就是將卷積核與圖像進行點積運算 (dot product operation)，得到一個新的特徵圖。卷積操作的公式如下：

$$y_{i,j} = \sum_{a=0}^{k-1} \sum_{c=0}^{k-1} x_{i+a,j+c} \cdot w_{a,c} + b \quad (2.1.6)$$

其中， $y_{i,j}$ 表示新特徵圖在第 i 列、第 j 行的值； $x_{i,j}$ 表示輸入圖像在第 i 列、第 j 行的值； $w_{a,c}$ 表示卷積核在第 a 列、第 c 行的權重值； b 是偏置項。

卷積神經網路的另一個重要組件是池化層 (pooling layer)，它的作用是将卷積層輸出的特徵圖進行降維，從而減少計算量和避免過度擬合。池化層通常採用最大池化 (max pooling) 或平均池化 (average pooling) 等方法進行操作，它的卷積核大小和步長可以進行調整。池化操作的公式如下：

$$y_{i,j} = \max_{a=0}^{p-1} \max_{c=0}^{p-1} x_{i \times p + a, j \times p + c} \quad (2.1.7)$$

其中， $y_{i,j}$ 表示新特徵圖在第 i 列、第 j 行的值； $x_{i,j}$ 表示輸入圖像的在第 i 列、第 j 行的值； p 是池化區域的大小。

卷積神經網路的最後一個組件是全連接層 (fully connected layer)，它通常是一個多層感知器 (multi-layer perceptron, MLP)，用於實現分類和識別等任務。全連接

層接收前一層的輸出作為輸入，然後通過激活函數進行非線性變換，最終產生輸出。全連接層的輸出可以通過 softmax 函數進行歸一化，從而得到每個類別的預測機率值。

在訓練過程中，卷積神經網路通常使用反向傳播算法進行權重更新，以最小化損失函數。常見的損失函數包括交叉熵 (cross-entropy) 和均方誤差 (mean squared error, MSE)。反向傳播算法通過計算損失函數對權重和偏置的梯度，然後利用梯度下降算法 (gradient descent) 進行權重更新，直到收斂。



2.1.4 遞迴神經網路

遞迴神經網路 (recurrent neural network, RNN) [7] 是一種能夠處理序列數據的深度學習模型，擅長捕捉序列中的時間依賴關係。遞迴神經網路的特點是將上一個時間步的輸出作為當前時間步的輸入，同時使用一個隱藏狀態來保存先前的信息。它具有遞迴的特性，因為當前的輸出會在下一個時間步被作為輸入使用，因此可以將信息在時間上傳遞，並且在不同時間步之間共享權重參數。

具體來說，在遞迴神經網路的每一個時間步，都會計算一個隱藏狀態 h_t 和當前時間步的輸出 y_t 。假設當前時間步的輸入為 x_t ，隱藏狀態和輸出的計算方式如下：

$$h_t = \sigma(W_{xh}x_t + W_{hh}h_{t-1} + b_h) \quad (2.1.8)$$

$$y_t = \text{softmax}(W_{hy}h_t + b_y) \quad (2.1.9)$$

其中， W_{xh} 、 W_{hh} 、 W_{hy} 分別是輸入到隱藏狀態、隱藏狀態到隱藏狀態、隱藏狀態到輸出的權重矩陣； b_h 、 b_y 分別是隱藏狀態和輸出的偏置項； $\sigma(\cdot)$ 是 sigmoid 函數； $\text{softmax}(\cdot)$ 是 softmax 函數。

然而，由於遞迴神經網路存在梯度消失和梯度爆炸等問題，導致長序列的建模效果不佳。為了解決這些問題，人們提出了許多變體，其中一個是長短期記憶模型 (long short-term memory, LSTM) [3]。

長短期記憶模型是一種特殊的遞迴神經網路，它具有三個門控制器，分別是輸入門、遺忘門和輸出門。輸入門控制著當前輸入的加入程度，遺忘門控制著上一個時間步隱藏狀態的遺忘程度，輸出門則控制著當前隱藏狀態的輸出程度。長短期記憶模型的計算方式如下：

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \quad (2.1.10)$$

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \quad (2.1.11)$$

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \quad (2.1.12)$$

$$g_t = \tanh(W_c \times [h_{t-1}, x_t] + b_c) \quad (2.1.13)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t \quad (2.1.14)$$

$$h_t = o_t \odot \tanh(c_t) \quad (2.1.15)$$

其中， i_t 、 f_t 和 o_t 分別代表輸入門、遺忘門和輸出門的值； g_t 代表當前的記憶狀態； c_t 代表當前的輸入值； \hat{h}_t 代表當前的隱藏狀態； W_i 、 W_f 、 W_o 和 W_c 分別代表輸入、遺忘、輸出和記憶矩陣； b_i 、 b_f 、 b_o 和 b_c 分別代表對應的偏置項； σ 表示 sigmoid 函數； \odot 表示阿達瑪乘積 (Hadamard product)。

透過這些公式，長短期記憶模型可以對序列數據進行建模，並且能夠有效地解決遞迴神經網路存在的梯度消失和梯度爆炸問題，進而獲致更佳的效果。



2.1.5 DeepLOB

DeepLOB 由 Zhang、Zohren 和 Roberts 提出，是一個針對金融市場進行預測的深度學習模型，它利用原始的限價委託簿數據預測市場未來的漲跌趨勢[13]。

DeepLOB 模型已被證實在美股等傳統金融市場中具有良好的預測能力[6,13]。

該模型採用了包含 CNN 模塊和 Inception 模塊的網路，能夠有效地擷取數據中時間和空間的相關特徵。這些模塊的輸出被傳入 LSTM 層進行處理，以處理數據中長期的時序關係，最終輸出預測市場趨勢的分類。DeepLOB 模型的優點在於可以處理限價委託簿這類複雜和非線性的資料，從中自主學習擷取市場特徵和捕捉時序關係，從而在金融市場預測方面取得良好的效果[6]。




圖 2.1、DeepLOB 模型架構圖[6]

圖 2.1 是 DeepLOB 模型的架構，由以下組成[6]：

- 輸入：由原始的限價委託簿組成，包含最佳 L 檔的買賣委託價格和掛單量，同時帶有一個時間長度為 T 的回溯窗口。因此，在時間 t 的輸入是一個大小為 $T \times 4L$ 的矩陣，如下式：

$$\{x_{t-\tau}\}_{\tau=0,\dots,T-1} = \left\{ \left(p_{a,t-\tau}^{(l)}, v_{a,t-\tau}^{(l)}, p_{b,t-\tau}^{(l)}, v_{b,t-\tau}^{(l)} \right) \right\}_{\tau=0,\dots,T-1, l=1,\dots,L} \quad (2.1.16)$$

其中， $p_{a,t-\tau}^{(l)}$ 是第 l 檔的委託賣價； $v_{a,t-\tau}^{(l)}$ 是第 l 檔的委託賣量； $p_{b,t-\tau}^{(l)}$ 是第 l 檔的委託買價； $v_{b,t-\tau}^{(l)}$ 是第 l 檔的委託買量；本研究中選擇 L 為 10 和 T 為 60。

- CNN 模塊：針對限價委託簿的空間和時間維度，使用不同大小的卷積核擷取特徵。在空間維度中，使用維度為 1×2 和 1×10 的卷積核整合委託簿層內和層與層之間的訊息；在時間維度中，使用維度為 4×1 的卷積核進行平滑操作。詳細操作如圖 2.2。

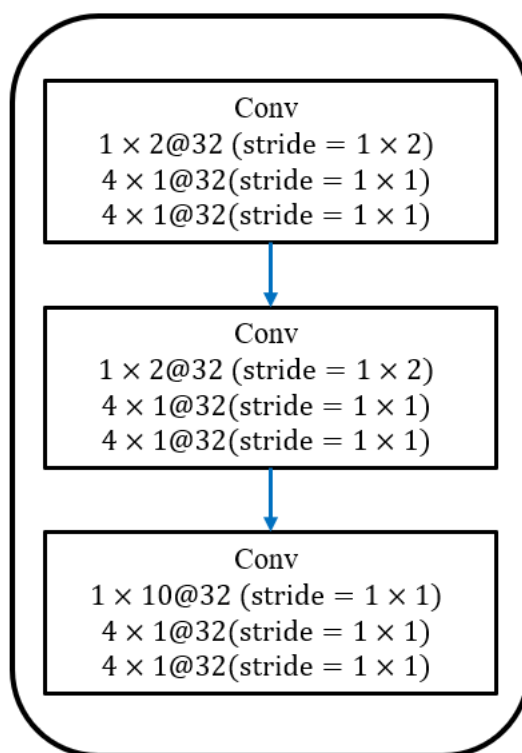


圖 2.2、CNN 模塊運作示意圖[13]

其中，Conv 表示卷積運算； $1 \times 2@32$ 表示使用 32 個大小為 1×2 的卷積核進行卷積運算；stride = 1×2 表示卷積核移動方式為 1×2 。

- Inception 模塊：針對 CNN 模塊的輸出，應用不同長度的卷積核來擷取時間相關的特徵，其中包括 1×1 、 3×1 和 5×1 的卷積核。每個卷積核可以視為不同時間長度的加權移動平均值，概念上類似於交易員使用的技術分析方法。詳細操作如圖 2.3。

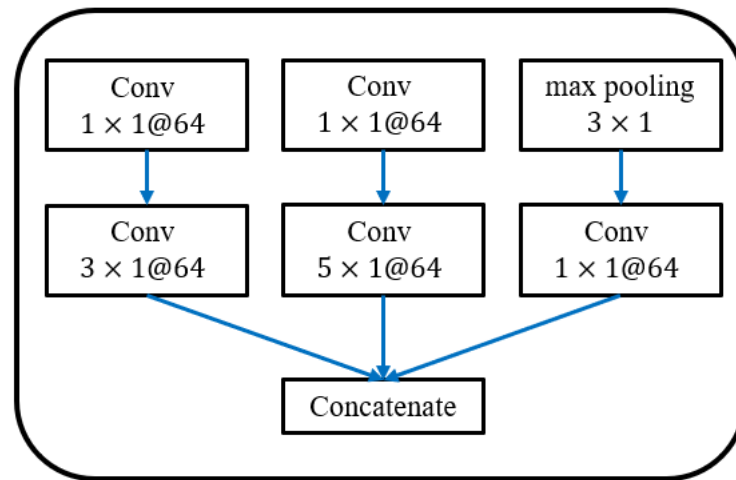



圖 2.3、Inception 模塊運作示意圖[13]

其中，Conv 表示卷積運算；max pooling 表示使用最大池化操作；Concatenate 表示將輸入的矩陣串接在一起。

- LSTM：針對由 Inception 模塊生成的多維時間序列，通過長短期記憶網路學習數據之間的時序關係，最後生成 h 步以後的漲跌趨勢預測。本研究設置 h 為 60。



2.2 限價委託簿的穩健表示法

DeepLOB 模型使用的限價委託簿表示法會導致其不穩定的預測結果，尤其是在出現插單的情況時，容易導致不穩定的預測結果。當出現小額插單時，後續資料會往右橫移，使資料發生巨大變化，從而導致模型預測出截然不同的結果。如圖 2.4 顯示，在 $t+1$ 時間點插入 1 單位價位在 10.2 的賣單，會導致原本的賣單數據都往右移，以 L1-norm 來說 t 時間點和 $t+1$ 時間點這兩筆數據的變化達到 99.3，由於這兩筆數據差異很大，模型預測出來的結果會有差異。


	$p_a^{(1)}$	$v_a^{(1)}$	$p_b^{(1)}$	$v_b^{(1)}$	$p_a^{(2)}$	$v_a^{(2)}$	$p_b^{(2)}$	$v_b^{(2)}$	$p_a^{(3)}$	$v_a^{(3)}$	$p_b^{(3)}$	$v_b^{(3)}$	$p_a^{(4)}$	$v_a^{(4)}$	$p_b^{(4)}$	$v_b^{(4)}$
Time t	10.1	100	9.9	100	10.3	100	9.8	100	10.4	100	9.6	100	10.5	100	9.5	100
Time $t+1$	10.1	100	9.9	100	10.2	1	9.8	100	10.3	100	9.6	100	10.4	100	9.5	100

圖 2.4、原始限價委託簿表示法出現插單後的結果示意圖

此限價委託簿的表示法會影響模型的預測能力[6,11]。為了解決此問題，本研究採用 Wu、Mahfouz、Magazzeni 和 Veloso 提出的限價委託簿穩健表示法[11]，取代原本的表示法 (2.1.16)，新的表示法為：

$$\begin{aligned}
 & \{x_{t-\tau}\}_{\tau=0,\dots,T-1} \\
 & = \left\{ \left(s_{b,t-\tau}^{(W)}, s_{b,t-\tau}^{(W-1)}, \dots, s_{b,t-\tau}^{(1)}, s_{a,t-\tau}^{(1)}, \dots, s_{a,t-\tau}^{(W-1)}, s_{a,t-\tau}^{(W)} \right) \right\}_{\tau=0,\dots,T-1}
 \end{aligned} \tag{2.2.1}$$

其中， $s_{b,t-\tau}^{(W)}$ 代表距離中價 W 個最小跳動點的委託買量， $s_{a,t-\tau}^{(W)}$ 代表距離中價 W 個最小跳動點的委託賣量。



Wu、Mahfouz、Magazzeni 和 Veloso 指出這種改良方式，可以避免插單導致的模型不穩定性[11]。將圖 2.4 的限價委託簿原始表示法改成使用穩健表示法，透過計算出中價為 $(10.1 + 9.9)/2 = 10.0$ ，新的限價委託簿表示法如圖 2.5。

	$s_b^{(4)} = 9.6$	$s_b^{(3)} = 9.7$	$s_b^{(2)} = 9.8$	$s_b^{(1)} = 9.9$	$s_a^{(1)} = 10.1$	$s_a^{(2)} = 10.2$	$s_a^{(3)} = 10.3$	$s_a^{(4)} = 10.4$
Time t	100	0	100	100	100	0	100	100
Time $t+1$	100	0	100	100	100	1	100	100

圖 2.5、限價委託簿穩健表示法出現插單後的結果示意圖

可以觀察到限價委託簿穩健表示法在面對有小額插單的情況下，以 L1-norm 來說 t 時間點和 $t + 1$ 時間點這兩筆數據的變化僅有 1，表示這兩筆數據差異很小。因此，將這兩筆資料分別放進 DeepLOB 模型中，會產生相近的結果。

第三章 實驗方法



3.1 實驗設計

本研究旨在探討比特幣期貨的漲跌預測問題。鑒於限價委託簿的複雜性和金融時間序列中前後關係的重要性，本研究採用結合卷積神經網路和長短期記憶層的 DeepLOB 模型。期望該模型能夠有效擷取限價委託簿中的空間資訊和捕捉時序變化，學習比特幣期貨市場的特點和趨勢，從而提高預測的準確性和能力。

此外，由於原始限價委託簿的表示方式會導致模型預測的不穩定性，本研究採用 Wu、Mahfouz、Magazzeni 和 Veloso 提出的限價委託簿穩健表示法來取代模型原始的表示法[11]，以提升模型的預測能力。

為了達到研究目的，本研究設計了兩個實驗。第一個實驗是比較 DeepLOB 模型和傳統線性模型-羅吉斯迴歸模型在預測比特幣期貨未來價格漲跌方面的能力，以驗證 DeepLOB 模型在該市場的預測能力。第二個實驗是比較採用限價委託簿穩健表示法和採用原始表示法的 DeepLOB 模型在比特幣期貨市場中的預測能力，以驗證新的表示法是否能提升模型的預測能力。通過這些實驗，本研究期望更深入地理解比特幣期貨市場的變化趨勢，為投資者提供更準確和有用的信息，以幫助他們做出明智的決策。

3.2 實驗資料

3.2.1 資料來源

本研究使用的比特幣期貨歷史限價簿資料是從幣安交易所取得。¹資料取自 2022 年 12 月 1 日至 2022 年 12 月 31 日，共 31 日。資料取樣單位為秒，也就是每

¹幣安交易所官網 (<https://www.binance.com/en>)



秒對比特幣期貨限價簿做一次快照 (snapshot)，其中包含上下二十檔的買賣價格和掛單量，如圖 3.1。

time	bp1	bs1	bp2	bs2	bp3	bs3	...	ap18	as18	ap19	as19	ap20	as20
2022-12-01 00:00:01	17153.3	8.643	17153.2	0.002	17153.1	0.1	...	17155.7	0.009	17155.8	0.006	17155.9	0.742
2022-12-01 00:00:02	17153.3	8.202	17153.2	0.002	17153.1	0.1	...	17155.7	0.009	17155.8	0.006	17155.9	0.742
2022-12-01 00:00:03	17153.3	8.190	17153.2	0.002	17153.1	0.1	...	17155.7	0.009	17155.8	0.006	17155.9	0.742
2022-12-01 00:00:04	17152.0	1.160	17151.9	1.937	17151.8	0.9	...	17155.4	0.305	17155.5	0.009	17155.6	2.256
2022-12-01 00:00:05	17152.0	1.160	17151.9	1.937	17151.8	0.9	...	17155.4	0.305	17155.5	0.009	17155.6	2.256

圖 3.1、幣安提供的比特幣期貨限價委託簿示意圖

其中，bp1 和 bs1 分別代表第一檔的委託買價和其掛單量；bp2 和 bs2 則是第二檔的委託買價和其掛單量，依此類推，ap18 和 as18 代表第十八檔的委託賣價和其掛單量。

3.2.2 資料切割

在機器學習中，資料集是非常重要的，它決定了機器學習模型的能力和表現。為了讓模型更加準確和穩定，資料集通常會被切割為訓練集、驗證集和測試集。訓練集是模型進行訓練時使用的資料集，其目的是為了讓模型學習到資料集中的特徵和關聯性，以便後續預測。驗證集是用於調整模型超參數的資料集，超參數是指需要手動設定的模型參數，例如學習率、正則化參數等。通過驗證集來評估模型的表現，並選擇最佳超參數，可以有效地防止模型過度擬合訓練集。最後，測試集是用於最終評估模型性能的資料集。測試集的資料與訓練集和驗證集不同，是模型未曾接觸過的資料，它的目的是測試模型的泛化能力，並且確保模型的表現在真實應用中具有可靠性[2]。



本研究的原始資料區間為 2022 年 12 月 1 日至 2022 年 12 月 31 日，共 31 日。將 12 月 1 日至 12 月 21 日的資料分為訓練集，12 月 22 日至 12 月 26 日分為驗證集，最後將 12 月 27 日至 12 月 31 日分為測試集。

3.2.3 資料正規化

使用羅吉斯迴歸或神經網路等模型進行分類或回歸任務時，對資料進行正規化可以提高模型的性能和穩定性。正規化的目的是縮放特徵值，以便所有特徵都具有相似的重要性，提高模型的訓練速度和收斂性。此外，當特徵值的範圍非常大或非常小時，模型可能會受到數值不穩定性的影響，例如梯度爆炸或消失。進行正規化可以調整特徵的尺度，使其適合於模型訓練時的計算[2]。

常見的正規化方式包括標準化 (z-score normalization) 和歸一化 (min-max normalization)，它們都是將原始特徵值縮放到一個固定的範圍內。

標準化會將特徵值縮放到平均值為 0，標準差為 1 的範圍內，數學式如下：

$$x_{\text{norm}} = \frac{x - \mu}{\sigma} \quad (3.2.1)$$

其中， x 是原始特徵值， μ 是該特徵的平均值， σ 是該特徵的標準差。

歸一化會將特徵值縮放到 [0,1] 的範圍內，數學式如下：

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (3.2.2)$$

其中， x 是原始特徵值， x_{\min} 和 x_{\max} 分別是該特徵的最小值和最大值。

本研究採用標準化的方式對資料集進行正規化。為了避免資料集使用到未來資訊，本研究先計算出訓練集的平均值和標準差，再以此對訓練集、驗證集和測試集進行標準化。

3.3 預測目標值設計

在設計模型要預測的未來目標值前，本研究先計算出 t 時間點時的中價 p_t ，其數學式如下：



$$p_t = \frac{p_a^{(1)}(t) + p_b^{(1)}(t)}{2} \quad (3.3.1)$$

其中， $p_a^{(1)}(t)$ 為 t 時間點時第一檔委託賣價； $p_b^{(1)}(t)$ 為 t 時間點時第一檔委託買價。

然而，倘若使用中價計算報酬率作為模型要預測的未來目標值，會因為比特幣期貨市場的波動很大，導致此預測目標值充斥許多雜訊。因此，本研究採用與 Zhang、Zohren 和 Roberts 相同的設計方式，使用以下這種能使預測目標值更加穩定和連續的方式來計算價格的漲跌走勢，並作為模型要預測的未來目標值[13]。首先，計算過去 k 個時間點的平均中價 $m_-(t)$ 和未來 k 個時間點平均中價 $m_+(t)$ ，分別是：

$$m_-(t) = \frac{1}{k} \sum_{i=0}^{k-1} p_{t-i} \quad (3.3.2)$$

$$m_+(t) = \frac{1}{k} \sum_{i=1}^k p_{t+i} \quad (3.3.3)$$

將 $m_+(t)$ 與 $m_-(t)$ 相減便得出在 t 時間點時的價格變化 $l_t(t)$ 。

$$l_t(t) = m_+(t) - m_-(t) \quad (3.3.5)$$

最後，設定一個閾值(α)，定義 $l_t(t) < -\alpha$ 為跌，標記為-1；定義 $l_t(t) > \alpha$ 為漲，標記為1；介於之中為持平，標記為0。這些數值將會是模型需要利用學習去預測的未來目標值。

閾值(α)的選擇會影響預測目標值在個類別的數量。當各類別的數量很不平衡時，使用神經網路進行分類可能會產生一些問題。首先，由於某些類別的樣本數量很少，模型可能會偏向預測數量較多的類別，而忽略數量較少的類別。這是因為在訓練時，模型會根據整體的損失函數進行優化，而數量較多的類別的損失貢獻較大，因此模型就會優先學習預測該類別。其次，當模型在預測數量較少的類別時，表現可能會較差。這是因為在訓練時，模型沒有足夠的樣本來學習如何區分這些類別，從而導致預測效果不佳[10]。

因此，本研究通過設置持平類別占 40%，使上漲和下跌類別各占約 30%，以解決這些問題。





3.4 模型績效評比指標

比較不同機器學習模型的預測能力時，通常會使用樣本外正確率 (out-of-sample accuracy) 進行比較。樣本外正確率是指模型在一個未曾見過的測試數據集上，其能預測正確的樣本數量占總樣本數的比例。然而，單純比較正確率可能會存在一些問題。

模型在各個類別的預測數量可能不均衡，會使模型過於依賴某種類別。因此，需要觀察模型在各類別的預測數量，以判斷其預測行為是否合理。

另外，在不同的應用場景中，不同類別預測錯誤的影響程度是不同的。因此，需要透過混淆矩陣 (confusion matrix) 來觀察模型在各類別的預測行為。混淆矩陣是一個正方形矩陣，其中每一列代表實際類別，每一行代表預測類別。對角線上的數字表示模型預測正確的樣本比例，而非對角線上的數字表示模型預測錯誤的比例。透過混淆矩陣，可以很清楚地看到模型在每種類別上的預測行為，從而判斷模型是否存在對某些類別預測錯誤的偏差。

第四章 實驗結果



4.1 實驗一結果

本實驗比較了羅吉斯迴歸模型和 DeepLOB 模型在預測比特幣期貨未來價格漲跌方面的表現。樣本外測試採用 2022 年 12 月 27 日至 12 月 31 日的秒級資料，總共包括 431,042 筆資料。

實驗結果顯示，DeepLOB 模型在樣本外正確率高達 60.22%，相對地，羅吉斯迴歸模型的正確率僅有 51.72%。這表示 DeepLOB 模型的預測精準度明顯優於羅吉斯迴歸模型。

接著觀察兩模型在預測各個類別時的行為，羅吉斯迴歸模型預測漲、持平、跌三者分別的次數和比例如表 4.1。DeepLOB 模型預測漲、持平、跌三者分別的次數和比例如表 4.2。

	漲	持平	跌
次數	82,063	248,088	100,891
比例	19.04%	57.56%	23.41%

表 4.1、羅吉斯迴歸模型預測漲、持平、跌的次數和比例

	漲	持平	跌
次數	119,388	189,678	121,976
比例	27.70%	44.00%	28.30%

表 4.2、DeepLOB 模型預測漲、持平、跌的次數和比例

根據數據顯示，羅吉斯迴歸模型的預測偏向於持平這一類別，占比達 57.56%。相比之下，DeepLOB 模型則更均衡地預測三種類別，其中持平這一類別的預測比例為 44.00%，比羅吉斯迴歸模型低 13.56%。因此，DeepLOB 模型的預測行為表現較優秀，因為它能夠廣泛預測不同的類別，而不是過度依賴某一類別的預測結果。

進一步觀察兩模型預測樣本外的混淆矩陣，分析模型在各個目標類別中的預測行為。其中，橫軸為真實目標值，縱軸為預測目標值，數值代表模型的預測類別中屬於真實漲、持平、跌三者的比例。根據圖 4.1，DeepLOB 模型在漲、持平、跌三種類別的預測精準度均優於羅吉斯迴歸模型，這表示 DeepLOB 模型全方面表現得更準確。

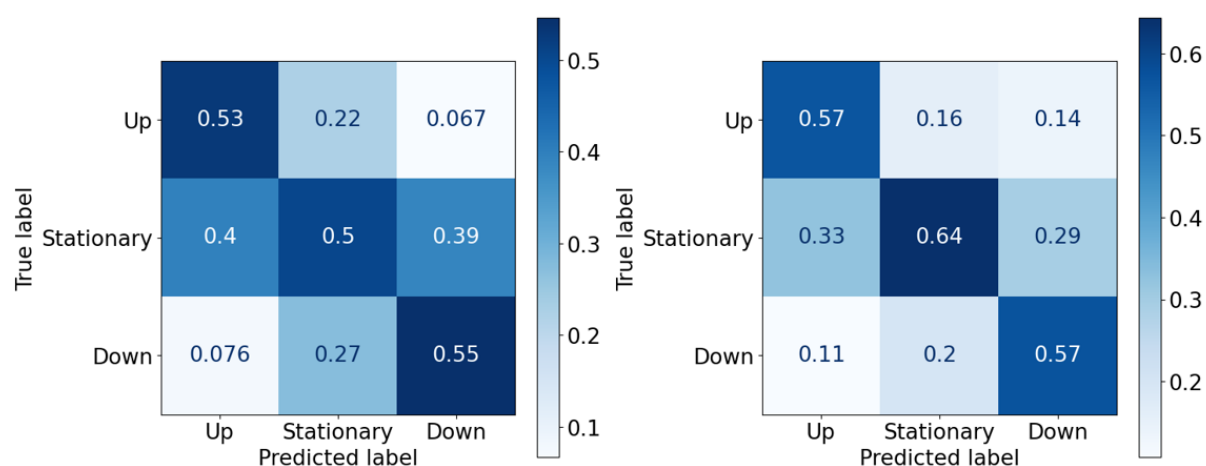


圖 4.1、(左) 羅吉斯迴歸模型的混淆矩陣；(右) DeepLOB 模型的混淆矩陣

綜合以上分析，本實驗得出結論：在預測比特幣期貨的動態變化中，DeepLOB 模型的預測能力上顯著優於羅吉斯迴歸模型，其中，DeepLOB 模型能夠更均衡地預測不同類別，並且全面地在各目標類別中更準確。因此，DeepLOB 模型比傳統線性模型更適用在比特幣期貨市場的預測任務。



4.2 實驗二結果

為提升 DeepLOB 模型在預測比特幣期貨方面的穩定性，本研究採用 Wu、Mahfouz、Magazzeni 和 Veloso 提出的限價委託簿穩健表示法來取代模型原始的表示法[11]。本實驗旨在驗證採用新表示法的 DeepLOB 模型在預測比特幣期貨方面的能力是否有所提升。具體而言，本研究比較使用穩健表示法和原始表示法的 DeepLOB 模型在預測比特幣期貨方面表現的差異。

實驗結果顯示，相比使用原始表示法的 60.22%，使用穩健表示法的 DeepLOB 模型在樣本外的準確率提升 1.58%，達到 61.80%，這表示使用穩健表示法有助於提升 DeepLOB 模型在預測比特幣期貨市場的準確性。

接著觀察兩模型在預測各個類別時的行為，使用原始表示法的 DeepLOB 模型對於漲、持平、跌三種情況的預測次數和比例如表 4.3。使用穩健表示法的 DeepLOB 模型對於漲、持平、跌三種情況的預測次數和比例如表 4.4。

	漲	持平	跌
次數	119,388	189,678	121,976
比例	27.70%	44.00%	28.30%

表 4.3、使用原始表示法的 DeepLOB 模型預測漲、持平、跌的次數和比例

	漲	持平	跌
次數	112,157	219,693	99,192
比例	26.02%	50.97%	23.01%

表 4.4、使用穩健表示法的 DeepLOB 模型預測漲、持平、跌的次數和比例

根據數據顯示，相較於使用原始表示法，使用穩健表示法的模型更傾向於預測持平類別，導致預測跌類別的次數減少，這可能會使一些潛在的投資機會被錯過。

進一步觀察使用原始表示法和使用穩健表示法的模型在預測樣本外的混淆矩陣方面的表現，分析模型在各個目標類別中的預測行為。根據圖 4.2，使用穩健表示法的 DeepLOB 模型對於預測漲和跌的正確率比使用原始表示法的有所提高，而對於預測持平的正確率則保持不變。

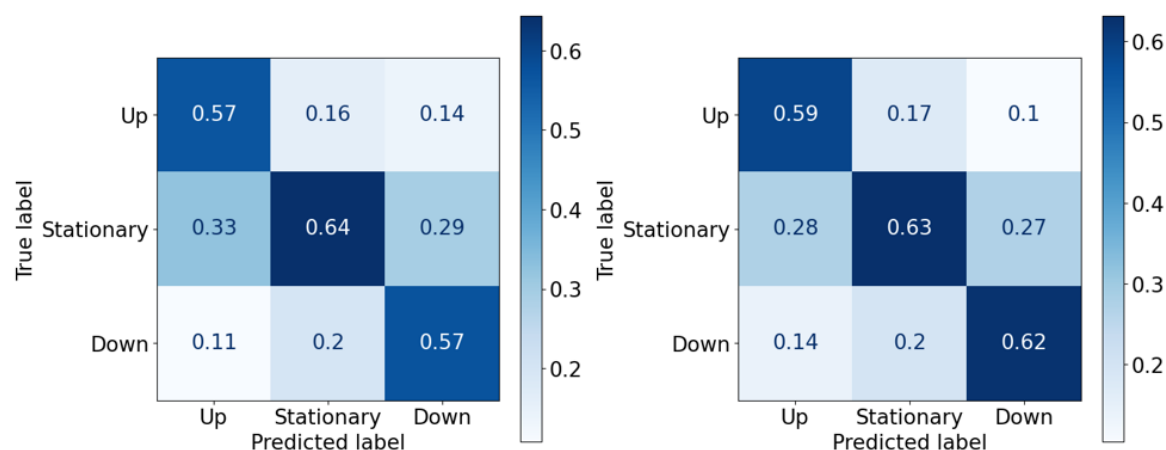


圖 4.2、(左) 使用原始表示法的 DeepLOB 模型的混淆矩陣；(右) 使用穩健表示法的 DeepLOB 模型的混淆矩陣

因此，綜合以上結果，本研究可以得出結論：使用限價委託簿穩健表示法對 DeepLOB 模型在預測比特幣期貨市場方面的表現有所提升，尤其是在預測漲和跌方面的正確率。然而，穩健表示法也會導致 DeepLOB 模型更傾向於預測持平類別，進而可能錯過一些潛在的投資機會。

第五章 結論與後續研究



5.1 結論


近年來比特幣期貨市場的快速發展已引起投資人的廣泛關注，因此，本研究旨在使用深度學習模型來預測比特幣期貨市場的價格變化。為了達到這個目標，本研究採用經過傳統金融市場驗證的深度學習模型 DeepLOB，該模型以幣安交易所的比特幣期貨限價委託簿作為輸入數據，用於預測該市場未來價格的漲跌。透過與傳統線性模型的比較，實驗一結果顯示 DeepLOB 模型不僅具有較高的樣本外正確率，其能夠更均衡地預測不同類別，並且在各目標類別中均表現更準確，說明其在擷取市場特徵和捕捉趨勢方面表現更優異。

此外，由於 DeepLOB 模型使用的限價委託簿表示法會導致其不穩定的預測結果，本研究採用 Wu、Mahfouz、Magazzeni 和 Veloso 提出的限價委託簿穩健表示法來取代模型原始的方法[11]。實驗二結果顯示，使用此穩健表示法可以有效地提高 DeepLOB 模型的預測能力，尤其是提升預測漲和跌方面的預測正確率，從而使模型能更準確地預測比特幣期貨市場的價格變化。

綜合上述，本研究顯示 DeepLOB 模型在幣安交易所的比特幣期貨市場中比傳統線性模型表現更優異，且透過使用限價委託簿穩健表示法，可以進一步提高預測準確度。這些結果為投資人提供了有益的參考，有助於他們在比特幣期貨市場中做出更明智的決策，提高他們的收益率。此外，本研究結果還表明，深度學習模型具有應用於加密貨幣市場預測的潛力，並為未來相關研究提供了一些啟示。

5.2 後續研究

本研究的未來研究方向可以依據 DeepLOB 模型預測的價格漲跌訊號建立交易策略，並進行回測分析，以驗證此模型是否可以在真實世界中獲利。研究者可以考



量實際交易中的交易手續費、摩擦成本等實務問題，使分析結果更符合真實世界情況。若實證結果顯示 DeepLOB 模型的預測能力可以轉化為實際獲利，將對投資人在比特幣期貨市場中制定交易策略提供更有價值的參考。此外，未來研究也可以考慮探討其他深度學習模型在比特幣期貨市場預測中的應用，比較不同模型之間的優缺點，進而提高預測能力和交易獲利性。

參考文獻



- [1] Foucault, T., Kadan, O., & Kandel, E. (2005). Limit order book as a market for liquidity. *Review of Financial Studies*, 18(4), 1171–1217.
- [2] Géron, A. (2022). *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow*. Sebastopol, CA: O'Reilly Media.
- [3] Graves, A. (2012). *Long Short-Term Memory*. Berlin, GER: Springer.
- [4] Hung, J. C., Liu, H. C., & Yang, J. J. (2021). Trading activity and price discovery in Bitcoin futures markets. *Journal of Empirical Finance*, 62, 107–120.
- [5] Kleinbaum, D. G., Dietz, K., Gail, M., Klein, M., & Klein, M. (2002). *Logistic Regression*. New York: Springer-Verlag.
- [6] Lucchese, L., Pakkanen, M., & Veraart, A. (2022). The short-term predictability of returns in order book markets: a deep learning perspective. *arXiv preprint arXiv:2211.13777*.
- [7] Medsker, L., & Jain, L. C. (Eds.). (1999). *Recurrent Neural Networks: Design and Applications*. London: CRC Press.
- [8] O'Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*.
- [9] Svozil, D., Kvasnicka, V., & Pospichal, J. (1997). Introduction to multi-layer feed-forward neural networks. *Chemometrics and Intelligent Laboratory Systems*, 39(1), 43–62.
- [10] Wang, C., Deng, C., & Wang, S. (2020). Imbalance-XGBoost: leveraging weighted and focal losses for binary label-imbalanced classification with XGBoost. *Pattern Recognition Letters*, 136, 190–197.
- [11] Wu, Y., Mahfouz, M., Magazzeni, D., & Veloso, M. (2021). Towards robust representation of limit orders books for deep learning models. *arXiv preprint*

arXiv:2110.05479.

- [12] Zaznov, I., Kunkel, J., Dufour, A., & Badii, A. (2022). Predicting stock price changes based on the limit order book: a survey. *Mathematics*, 10(8), 1234.
- [13] Zhang, Z., Zohren, S., & Roberts, S. (2019). DeepLOB Deep convolutional neural networks for limit order books. *IEEE Transactions on Signal Processing*, 67(11), 3001–3012.

