

國立臺灣大學工學院土木工程學系



碩士論文

Department of Civil Engineering

College of Engineering

National Taiwan University

Master's Thesis

應用人工智慧遷移學習預測營造工程物價指數

Predicting Construction Cost Index using Artificial
Intelligence and Transfer Learning

邱民翰

Min-Han Chiu

指導教授: 曾惠斌 博士

Advisor: Hui-Ping Tserng, Ph.D.

中華民國 113 年 6 月

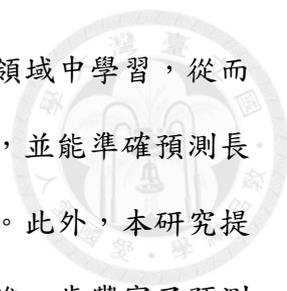
June, 2024





摘要

營建成本超支與工程計價爭議常因材料價格波動而發生，因此需準確預測營建物價，且其可協助預測投標價格、合約管理、估算成本與採購管理等，同時減少工程契約計價爭議。深度學習近年發展快速，但過往較少利用深度學習模型預測營建物價且成果有限，多數研究使用營建物價指數或經濟指標預測短期營建物價。然而，收集經濟指標費時費力，且資料量不足以訓練良好的深度學習模型，而預測短期營建物價與實務較不符合。因此本研究提出使用深度學習結合遷移學習預測營造工程物價指數之框架。利用長短期記憶網絡（Long Short-Term Memory, LSTM）配合預訓練與微調以預測短期與長期之台灣營造工程物價指數，以提升機器學習預測營造工程物價指數之表現。此外，將探討利用單一變數衍生之技術分析指標預測營造工程物價指數之可行性與成效。本研究以營造工程物價總指數、水泥及其製品類指數、金屬製品類指數為目標域，並選擇 7 種匯率作為預選源域，使用 14 種源域選擇方法確定最終源域。模型以 2 層 LSTM 層為基礎，通過預訓練和微調的方法提高預測效能。源域選擇結果顯示，營造工程物價總指數、水泥及其製品類指數之最終源域為新台幣兌日圓之匯率、金屬製品類指數之最終源域為新台幣兌韓元之匯率。預測模型方面，預訓練與微調能夠提升預測營造工程物價指數的效能。在預測營造工程物價總指數與水泥及其製品類指數時，目標域資料集使用技術分析指標比經濟指標好。本研究提出應用預訓練與微調技術預測營造工程物價指數之框架。為首個利用此方法協助預測營造工程物價指數



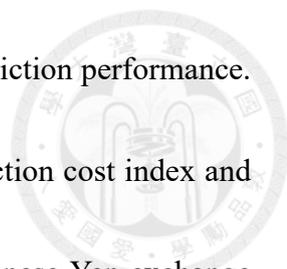
以提高預測表現與泛化能力之研究。這種結合允許模型在新的領域中學習，從而更好地適應不同的營建市場。且此方法優於其他機器學習模型，並能準確預測長期之營造工程物價指數，從而使預測結果更具可靠性和實用性。此外，本研究提出了利用技術分析指標的可行性，並對預測效果進行了探討，進一步豐富了預測方法的多樣性。本研究提出之創新性方法為未來相關研究提供了新的思路，同時也為業界提供了更準確地預測和管理營建成本的手段。這些成果將對營建領域的實踐和研究提供重要參考，有助於提升工程項目的管理效率和成功率。

關鍵字：營建物價預測、長短期記憶模型、遷移學習、預訓練與微調、技術分析指標



Abstract

Construction cost overruns and valuation disputes are common due to fluctuating material prices. Accurate predictions are crucial for forecasting bid prices, contract management, cost estimation, and procurement management. Despite advances in deep learning, its use in predicting construction costs has been limited. Most studies rely on construction cost indices or macroeconomic indicators for short-term forecasts, which are time-consuming and labor-intensive. This study explores the feasibility of technical analysis indicators for more accurate cost predictions and management. It proposes a framework using deep learning and transfer learning, specifically utilizing Long Short-Term Memory (LSTM) networks with pre-training and fine-tuning to predict both short-term and long-term construction cost indices in Taiwan. The research focuses on the general construction cost index, the cement and its products index, and the metal products index as target domains. Seven exchange rates are selected as initial source domains, and 14 source domain selection methods determine the final source domains. The model is based on a two-layer



LSTM architecture, with pre-training and fine-tuning enhancing prediction performance. Results indicate that the final source domain for the general construction cost index and the cement and its products index is the New Taiwan Dollar to Japanese Yen exchange rate. In contrast, for the metal products index, it is the New Taiwan Dollar to Korean Won exchange rate. Pre-training and fine-tuning significantly improve prediction performance. Technical analysis indicators outperform macroeconomic indicators for the general construction cost index and the cement and its products index. This study presents a novel framework for predicting construction costs through pre-training and fine-tuning, marking the first application of this method in the field. This approach allows the model to better adapt to different markets, outperforming other machine learning models and providing more reliable long-term predictions. The study showcases technical analysis indicators in construction cost prediction, offering a more accurate method for cost management and project success.

Keywords: Construction cost forecasting, LSTM, Transfer Learning, pre-training and fine-tuning, Technical Indicator



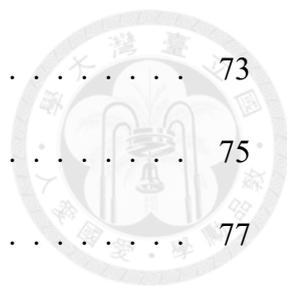
目次

	Page
摘要	iii
Abstract	v
目次	vii
圖次	xi
表次	xiii
第一章 緒論	1
1.1 研究背景與動機	1
1.2 研究目的	7
1.3 論文架構	8
第二章 文獻回顧	9
2.1 營建物價預測	9
2.2 時間序列預測	14
2.2.1 長短期記憶模型	16
2.3 機器學習與遷移學習	20
2.3.1 機器學習介紹	20
2.3.2 遷移學習介紹	22
2.3.3 遷移學習應用概況	27

2.4	文獻回顧小結	29
第三章 研究方法		31
3.1	研究流程與架構	31
3.2	遷移學習方法	31
3.3	定義源域與目標域	33
3.3.1	確定源域選擇方法	34
3.3.2	預選源域	35
3.3.3	決選源域	38
3.4	資料集建立與處理	38
3.4.1	源域資料集建立	39
3.4.2	目標域資料集建立	45
3.4.3	資料集分割	48
3.4.4	最大最小正規化	53
3.4.5	滑動窗口技術	53
3.5	預訓練模型與微調	54
3.5.1	建立長短期記憶模型	55
3.5.2	超參數調整	61
3.5.3	模型評估指標	65
3.6	結果比較方法	66
第四章 研究結果與討論		69
4.1	源域與目標域選擇結果	69
4.2	資料集建立與處理	71
4.2.1	源域資料集建立與處理	71



4.2.2	目標域資料集建立與處理	73
4.3	模型訓練與驗證結果	75
4.4	預測結果	77
4.4.1	預測營造工程物價總指數結果	77
4.4.2	預測水泥及其製品類指數結果	84
4.4.3	預測金屬製品類指數結果	92
4.5	源域資料集時間框架比較	100
4.6	目標域資料集比較	104
4.7	模型比較	106
4.8	研究結果分析與探討	114
4.9	實際應用操作流程	115
第五章	結論與未來研究方向	119
5.1	結論	119
5.2	研究限制	120
5.3	未來研究方向	122
	參考文獻	125



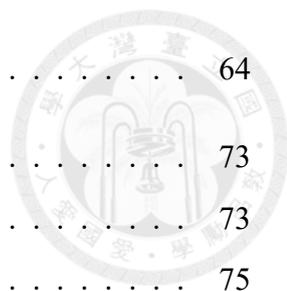




圖次

1.1	營造工程物價指數 [1]	5
2.1	一般神經網路與循環神經網路 [2]	17
2.2	循環神經網路 [3]	17
2.3	長短期記憶模型 [3]	17
2.4	遷移學習示意圖 [4]	23
2.5	遷移學習對模型訓練之影響 [5]	24
3.1	研究流程與架構	32
3.2	預訓練與微調示意圖	32
3.3	源域選擇流程	34
3.4	資料集建立與處理流程	39
3.5	源域資料集分割比例	52
3.6	目標域資料集分割	53
3.7	滑動窗口示意圖	54
3.8	本研究長短期記憶模型架構	57
3.9	本研究預訓練模型示意圖	58
3.10	Model 1 示意圖	58
3.11	Model 2 示意圖	59
3.12	Model 3 示意圖	59
3.13	Model 4 示意圖	59
3.14	Model 5 示意圖	60
3.15	ReduceLROnPlateau 示意圖	63
3.16	CosineAnnealingLR 示意圖	63

3.17 CosineAnnealingWarmRestarts 示意圖	64
4.1 源域資料集分割結果 (TWDJPY)	73
4.2 源域資料集分割結果 (TWDKRW)	73
4.3 目標域資料集分割	75
4.4 預測模型損失曲線	77
4.5 第 12 個月之營造工程物價總指數 (30 分鐘時間框架、資料集一)	85
4.6 第 12 個月之水泥及其製品類指數 (1 天時間框架、資料集一)	92
4.7 第 12 個月之金屬製品類指數 (30 分鐘時間框架、資料集二)	100
4.8 時間框架 30 分鐘之訓練集整體變化程度	103
4.9 時間框架 1 天之訓練集整體變化程度	103
4.10 實際應用流程圖	117





表次

2.1	遷移學習領域 [4]	26
3.1	營造工程物價指數—材料類權重 [6]	34
3.2	源域選擇方法	36
3.3	源域資料集之技術分析指標	40
3.4	源域資料集技術分析指標設定參數	45
3.5	目標域資料集技術分析指標設定參數	47
3.6	過往文獻使用之變數	49
3.7	經濟指標資料集 (1)	50
3.8	經濟指標資料集 (2)	51
3.9	資料集整理	55
3.10	模型種類	62
3.11	模型超參數	64
4.1	營造工程物價總指數源域選擇結果	70
4.2	水泥及其製品類指數源域選擇結果	70
4.3	金屬製品類指數源域選擇結果	70
4.4	源域資料集數量統計	72
4.5	源域資料集分割結果	74
4.6	目標域資料集數量統計	74
4.7	目標域資料集分割結果	75
4.8	預訓練模型訓練與驗證結果	76
4.9	預測模型訓練與驗證結果	76
4.10	第 1 個月營造工程物價總指數 (30 分鐘時間框架、資料集一)	78

4.11	第 3 個月營造工程物價總指數 (30 分鐘時間框架、資料集一)	78
4.12	第 6 個月營造工程物價總指數 (30 分鐘時間框架、資料集一)	79
4.13	第 12 個月營造工程物價總指數 (30 分鐘時間框架、資料集一)	79
4.14	第 1 個月營造工程物價總指數 (1 天時間框架、資料集一)	80
4.15	第 3 個月營造工程物價總指數 (1 天時間框架、資料集一)	80
4.16	第 6 個月營造工程物價總指數 (1 天時間框架、資料集一)	80
4.17	第 12 個月營造工程物價總指數 (1 天時間框架、資料集一)	81
4.18	第 1 個月營造工程物價總指數 (30 分鐘時間框架、資料集二)	81
4.19	第 3 個月營造工程物價總指數 (30 分鐘時間框架、資料集二)	81
4.20	第 6 個月營造工程物價總指數 (30 分鐘時間框架、資料集二)	82
4.21	第 12 個月營造工程物價總指數 (30 分鐘時間框架、資料集二)	82
4.22	第 1 個月營造工程物價總指數 (1 天時間框架、資料集二)	83
4.23	第 3 個月營造工程物價總指數 (1 天時間框架、資料集二)	83
4.24	第 6 個月營造工程物價總指數 (1 天時間框架、資料集二)	83
4.25	第 12 個月營造工程物價總指數 (1 天時間框架、資料集二)	84
4.26	第 1 個月水泥及其製品類指數 (30 分鐘時間框架、資料集一)	85
4.27	第 3 個月水泥及其製品類指數 (30 分鐘時間框架、資料集一)	86
4.28	第 6 個月水泥及其製品類指數 (30 分鐘時間框架、資料集一)	86
4.29	第 12 個月水泥及其製品類指數 (30 分鐘時間框架、資料集一)	86
4.30	第 1 個月水泥及其製品類指數 (1 天時間框架、資料集一)	87
4.31	第 3 個月水泥及其製品類指數 (1 天時間框架、資料集一)	87
4.32	第 6 個月水泥及其製品類指數 (1 天時間框架、資料集一)	88
4.33	第 12 個月水泥及其製品類指數 (1 天時間框架、資料集一)	88
4.34	第 1 個月水泥及其製品類指數 (30 分鐘時間框架、資料集二)	89
4.35	第 3 個月水泥及其製品類指數 (30 分鐘時間框架、資料集二)	89
4.36	第 6 個月水泥及其製品類指數 (30 分鐘時間框架、資料集二)	89
4.37	第 12 個月水泥及其製品類指數 (30 分鐘時間框架、資料集二)	90
4.38	第 1 個月水泥及其製品類指數 (1 天時間框架、資料集二)	90
4.39	第 3 個月水泥及其製品類指數 (1 天時間框架、資料集二)	91
4.40	第 6 個月水泥及其製品類指數 (1 天時間框架、資料集二)	91

4.41	第 12 個月水泥及其製品類指數 (1 天時間框架、資料集二)	91
4.42	第 1 個月金屬製品類指數 (30 分鐘時間框架、資料集一)	93
4.43	第 3 個月金屬製品類指數 (30 分鐘時間框架、資料集一)	93
4.44	第 6 個月金屬製品類指數 (30 分鐘時間框架、資料集一)	94
4.45	第 12 個月金屬製品類指數 (30 分鐘時間框架、資料集一)	94
4.46	第 1 個月金屬製品類指數 (1 天時間框架、資料集一)	94
4.47	第 3 個月金屬製品類指數 (1 天時間框架、資料集一)	95
4.48	第 6 個月金屬製品類指數 (1 天時間框架、資料集一)	95
4.49	第 12 個月金屬製品類指數 (1 天時間框架、資料集一)	96
4.50	第 1 個月金屬製品類指數 (30 分鐘時間框架、資料集二)	96
4.51	第 3 個月金屬製品類指數 (30 分鐘時間框架、資料集二)	96
4.52	第 6 個月金屬製品類指數 (30 分鐘時間框架、資料集二)	97
4.53	第 12 個月金屬製品類指數 (30 分鐘時間框架、資料集二)	97
4.54	第 1 個月金屬製品類指數 (1 天時間框架、資料集二)	98
4.55	第 3 個月金屬製品類指數 (1 天時間框架、資料集二)	98
4.56	第 6 個月金屬製品類指數 (1 天時間框架、資料集二)	98
4.57	第 12 個月金屬製品類指數 (1 天時間框架、資料集二)	99
4.58	源域資料集時間框架比較 (資料集一、營造工程物價總指數)	100
4.59	源域資料集時間框架比較 (資料集二、營造工程物價總指數)	101
4.60	源域資料集時間框架比較 (資料集一、水泥及其製品類指數)	101
4.61	源域資料集時間框架比較 (資料集二、水泥及其製品類指數)	101
4.62	源域資料集時間框架比較 (資料集一、金屬製品類指數)	101
4.63	源域資料集時間框架比較 (資料集二、金屬製品類指數)	102
4.64	目標域資料集比較 (預測營造工程物價總指數)	104
4.65	目標域資料集比較 (預測水泥及其製品類指數)	105
4.66	目標域資料集比較 (預測金屬製品類指數)	105
4.67	模型比較 (營造工程物價總指數、資料集一、MAPE)	108
4.68	模型比較 (營造工程物價總指數、資料集一、MAE)	108
4.69	模型比較 (營造工程物價總指數、資料集一、MSE)	108
4.70	模型比較 (營造工程物價總指數、資料集一、RMSE)	109

4.71	模型比較（營造工程物價總指數、資料集二、MAPE）	109
4.72	模型比較（營造工程物價總指數、資料集二、MAE）	109
4.73	模型比較（營造工程物價總指數、資料集二、MSE）	109
4.74	模型比較（營造工程物價總指數、資料集二、RMSE）	110
4.75	模型比較（水泥及其製品類指數、資料集一、MAPE）	110
4.76	模型比較（水泥及其製品類指數、資料集一、MAE）	110
4.77	模型比較（水泥及其製品類指數、資料集一、MSE）	110
4.78	模型比較（水泥及其製品類指數、資料集一、RMSE）	111
4.79	模型比較（水泥及其製品類指數、資料集二、MAPE）	111
4.80	模型比較（水泥及其製品類指數、資料集二、MAE）	111
4.81	模型比較（水泥及其製品類指數、資料集二、MSE）	111
4.82	模型比較（水泥及其製品類指數、資料集二、RMSE）	112
4.83	模型比較（金屬製品類指數、資料集一、MAPE）	112
4.84	模型比較（金屬製品類指數、資料集一、MAE）	112
4.85	模型比較（金屬製品類指數、資料集一、MSE）	112
4.86	模型比較（金屬製品類指數、資料集一、RMSE）	113
4.87	模型比較（金屬製品類指數、資料集二、MAPE）	113
4.88	模型比較（金屬製品類指數、資料集二、MAE）	113
4.89	模型比較（金屬製品類指數、資料集二、MSE）	113
4.90	模型比較（金屬製品類指數、資料集二、RMSE）	114

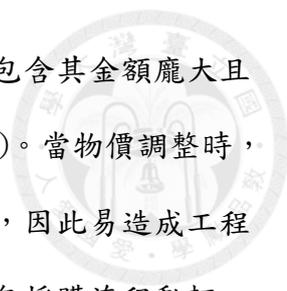


第一章 緒論

1.1 研究背景與動機

營建管理之五大目標為：造價如度、進度如期、品質如式、安全無虞、與環境如常。其中成本的控制是營建管理的主要目標之一，亦是業主、營造商與其他利益相關者努力控制的重點，且成本的預測更是營建廠商的重要課題 [7]。

材料價格波動是導致營建專案成本超支的關鍵因素之一。在營建產業中，營建材料占營建成本比例高，是營建專案成本中的關鍵部分之一。於一般工程之直接成本中，有 54% 為材料成本 [8]。Hwang et al.[9] 也指出材料成本占總專案成本的 25%。因此了解營建材料之價格變動有其重要性。不僅如此，多數的營建專案更面臨著成本超支的風險。Flyvbjerg et al.[10] 回顧 1927 年至 1998 年 20 個國家共 258 個交通建設項目，發現有 86% 的項目面臨成本超支。Aljohani et al. [11] 回顧 17 項國家研究，確定造成成本超支的原因共有 175 項，其中材料價格波動導致成本超支的頻率在所有因素中排名第四位。Hwang et al.[9] 與 Xu and Moon[12] 也指出造成建築成本與預期成本不一致的主要原因之一是材料價格的波動。此外，亦有過往研究運用問卷及訪談調查營建專案成本超支及延宕的原因，結果顯示營建材料價格的上漲是營建專案成本超支的主要原因 [13]，且材料成本和材料價格波動是導致建築成本居高不下的最重要因素 [14]。因此，材料價格波動是營建專案成本超支的主要原因之一，對成本有重大影響。



因物價調整而衍生之工程爭議不在少數。工程契約的特性包含其金額龐大且履約期間長，較為常見之計價方式為總價承包契約（Lump Sum）。當物價調整時，總價承包契約將因承攬金額已定，而無法隨物價調整契約價金，因此易造成工程計價爭議，或是廠商利益受損。不僅如此，一般公家機關之發包採購流程動輒一年以上甚至兩年以上，然而其估價時之材料價格卻採用當時的價格，而未充分考量未來價格波動之情形，因此造成招標困難，以及後續衍生之諸多工程爭議。根據行政院公共工程委員會於民國 111 年之統計資料，調解案件共計 411 件，其中計價爭議有 205 件 [15]，佔整體比例 50%，為數量最多的調解案件，其中就包含因為物價調整使得契約價金變動之爭議。行政院、行政院公共工程委員會、交通部等多個機關亦多次公布物價指數調整相關函釋以解決因物價調整所帶來之爭議，例如行政院於民國 87 年 6 月 4 日次第 2581 會議核定「砂石短缺因應對策」；交通部於民國 87 年 9 月頒訂「交通部暨所屬各機關因應國內砂石價格上漲之物價補償或調整方案」與「交通部及所屬機關工程估驗款隨物價指數調整計價金額實施要點」；行政院於民國 92 年 4 月 30 日頒佈「因應國內鋼筋價格變動之物價調整處理原則」；行政院於民國 93 年 5 月 3 日頒佈「中央機關已訂約工程因應國內營建物價變動之物價調整處理原則」；行政院於民國 97 年 6 月 5 日核定「機關已訂約施工中工程因應營建物價變動之物價調整補貼原則」；工程會於民國 97 年訂定「機關已訂約工程因應營建物價下跌之物價指數門檻調整處理原則」 [16]。此外，亦有許多研究學者探討如何因應物價調整所帶來的契約內容變更的方法 [16-20]。因此準確預測材料價格對於總成本的控制及預測至關重要 [12]。若能事先預測營建材料之價格，將有利於投標價格預測、合約管理、工程成本估計與採購管理等營建管理之各領域，並減少因物價調整而產生之工程契約爭議。

營造工程物價指數反映營建成本水準，但其資料量少不利於機器學習之訓練。營建材料種類繁多，台灣之營建材料價格變動能夠從行政院主計總處編撰之

營造工程物價指數 (Construction Cost Indices, CCI) 查看。營造工程物價指數自 1991 年起由行政院主計總處每個月 5 號發布一次，其編撰之目的是為了衡量營造工程使用之材料及勞務價格變動之情形，作為工程款調整之依據，並提供政策與學術研究之參考資料。營造工程物價指數之基期為點銜接法，目前基期為民國 110 年，銜接點為民國 111 年 12 月，每五年更換基期一次。查價項目以民國 110 年營造工程所投入之成本結構為基準，選取代表性之營造材料及勞務價格作為主要查價項目，共計 115 項。主要透過實地訪查或電話訪查進行查價，而查價頻率則依材料重要性而有所不同，例如鋼筋、砂石等較重要之材料每月逢四之日進行查價，每月共查價三次；其餘材料則每月 14 日查價一次；勞務價格則每月 15 日查價一次。總指數依照拉氏公式 (公式(1.1)-公式(1.3)) 進行計算，其可下分為兩大分類指數—材料及勞務，材料類可再細分為十個中分類指數。此外，依照工程性質編撰土木、建築及相關工程之十種複分類指數 [6]。從過往營造工程物價指數之資料中 (圖 1.1) 能夠發現營建物價變動之劇烈，因此必須要有良好的預測，以幫助合約管理等方面，並減少因物價調整而衍生之計價爭議。營造工程物價指數雖自 1991 年起每月發佈，至今 33 年，資料量仍然只有 396 筆 (截至 2023 年底) [1]。因此利用機器學習模型進行訓練時，可能面臨欠擬合 (under-fitting) 或是過度擬合 (over-fitting) 之問題。

營造工程物價指數之計算方式如下 [6]：

1. 計算各個地區之項目價比：

$$\frac{P_{i,j,k}}{P_{11112,j,k}} = \frac{1}{n_{j,k}} \sum_o \left(\frac{P_{i,j,k,o}}{P_{11112,j,k,o}} \right) \quad (1.1)$$

2. 計算項目價比：



$$\frac{P_{i,j}}{P_{11112,j}} = \frac{\sum_k \left(\frac{P_{i,j,k}}{P_{11112,j,k}} \right) \cdot W_{j,k}}{\sum_k W_{j,k}} \quad (1.2)$$

3. 計算指數：

$$I_{i/110}^{110CH} = \frac{\sum_j \frac{P_{i,j}}{P_{11112,j}} \times (P_{11112,j} \times Q_{110,j})}{\sum_j (P_{11112,j} \times Q_{110,j})} \times I_{11112/110}^{105CH} \quad (1.3)$$

其中 i 為計算期； j 為項目； k 為查價地區； P 為價格； Q 為數量； P_{11112} 為民國 111 年 12 月之價格； $\frac{P_{i,j,k,o}}{P_{11112,j,k,o}}$ 為第 i 期第 j 項目 k 查價地區第 o 花色對 111 年 12 月之價比； $\frac{1}{n_{j,k}}$ 為第 j 項目 k 查價地區之花色數； $\frac{P_{i,j,k}}{P_{11112,j,k}}$ 為第 i 期第 j 項目 k 查價地區對 111 年 12 月之價比； $W_{j,k}$ 為第 j 項目 k 查價地區基期年之地區權數； $P_{11112,j} \times Q_{110,j}$ 為第 j 項目 110 年營造投入數量以 111 年 12 月價格衡量之總投入金額； $I_{11112/110}^{105CH}$ 為 105 年市場籃，以 110 年指數為 100 之 111 年 12 月指數； $I_{i/110}^{110CH}$ 為 110 年市場籃，以 110 年指數為 100 之 i 計算期指數。

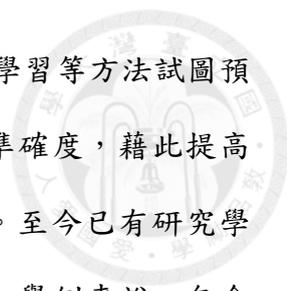
營建物價預測的主要方法包括時間序列分析（例如差分整合移動平均自我回歸模型，Autoregressive Integrated Moving Average Model，簡稱 ARIMA）、計量經濟模型（例如向量自回歸模型，Vector Autoregression Model，簡稱 VAR）、神經網路以及混合模型等方式。然而營建物價為非平穩之時間序列且受到政治、市場條件等多種因素影響，使得上述方法在預測營建物價時存在挑戰 [21]。在眾多方法中，相關研究指出與 ARIMA 及迴歸分析相比，神經網路之表現較好，表示非線性模型之性能比線性模型之性能優良 [22, 23]。然而，應用非線性模型甚至是深度學習模型於營建物價預測之相關研究較為稀少，而使用此類方法之研究成果也有待改進。其次，過往文獻使用之資料集多由營建物價指數或多種的經濟指標組成，然而各個經濟指標之發布日期不一，且資料收集費時費力。最後，過往文獻多為預測未來一個月或是六個月的短期營建物價，少有文獻預測一年甚至是一年以上



圖 1.1: 營造工程物價指數 [1]

的營建物價。有鑒於營建專案時間一般動輒一年以上，因此預測短期之營建物價對於營建專案之幫助較少。眾所周知，營建專案早期決策及規劃之影響力較大，接著影響力會隨時間遞減，因此，若能在專案之初便預測較長期之營建物價，將能對成本控制造成最為顯著之影響。此外，本研究透過訪問泰興工程顧問股份有限公司中具有相關採購經驗之高階主管以了解目前業界使用這些預測營建物價方法之情形。受訪主管透露，目前較少採用這些預測方法的原因有兩點：第一，預測年限較短，與實務採購時程不符；第二，這些預測方法缺乏公信力，因此較少被採用。總的來說，過往預測營建物價之相關研究中，應用深度學習預測營建物價之研究較少，且成果有待改進。此外，多數文獻使用經濟指標，並專注於預測短期之營建物價，較少文獻預測一年以上之營建物價。

目前已有多個領域應用機器學習預測時間序列之走勢，例如能源領域、醫療領域、金融領域等。其中，金融領域之金融商品交易市場動盪劇烈，趨勢不易判



斷。已有許多研究學者利用統計、計量經濟、技術分析、機器學習等方法試圖預測股價趨勢。近年來，如何利用深度學習模型提升股價預測準確度，藉此提高投資報酬率，並降低投資風險是許多人趨之若鶩的研究主題。至今已有研究學者利用機器學習與深度學習模型預測股價，並取得良好成果，舉例來說，包含隨機森林 [24–26]、XGBoost [27, 28]、SVM [26, 29]、LSTM [22, 24, 26, 30]、CNN [22, 26, 31, 32]、GAN [33] 等模型。而營建材料價格與金融商品有許多相似之處，包含都是時間序列資料且為非平穩的、受到多個因素影響，例如市場條件、總體經濟情勢、能源價格、股票市場等。不同之處在於多數金融商品之資料豐富，以股票為例，當時間框架（Timeframe）為 1 天時，一年大約有 250 筆資料；當時間框架為 30 分鐘時，一年大約有 2000 筆資料。而營建物價之資料量則相對較少，以營造工程物價總指數為例，其從 1991 年發布至 2023 年底也僅有 396 筆資料。因此，金融領域之時間序列預測方法無法完全適用於營建物價之預測。

當資料量不足時，遷移學習（Transfer Learning）是機器學習領域的其中一個解決方法，遷移學習是透過源域（Source Domain）的資料幫助目標域（Target Domain）的學習。然而，目前遷移學習多應用於自然語言處理（Natural Language Processing, NLP）任務與電腦視覺（Computer Vision, CV）任務，應用於時間序列相關任務之研究則較為稀少，尤其在工程領域以及金融領域之遷移學習相關的時間序列預測研究更為稀少。

有鑒於營建物價資料較少，而營建物價預測之相關研究多使用經濟指標，並僅預測短期之營建物價。金融領域之時間序列預測因資料量多寡不同而無法完全適用於營建物價預測。遷移學習應用於工程領域與金融領域時間序列預測之相關研究較少。本研究將應用深度學習模型結合遷移學習，並使用經濟指標與股票市場常見之技術分析指標作為資料集，以預測短期與長期之營造工程物價指數，並比較不同資料集之優劣，提供未來應用此預測方法之建議。本研究之結果能夠提

供營建專案預測短期及長期營建物價之方法。此外，本研究應為首個利用遷移學習進行營建物價預測之研究，未來應能依此脈絡發展更多營建物價預測之相關研究，以期提高預測之準確度，提供營建專案成本可靠的估計，建立具有公信力之營建物價預測系統，並減少因物價調整而衍生之工程爭議。

1.2 研究目的

營建物價近年漲勢不斷且波動劇烈，因此準確預測營建物價有其必要性。近年人工智慧（Artificial Intelligence, AI）發展快速，但在營建物價預測之應用仍較為稀少，過往文獻也較少使用深度學習於預測營建物價，且成果有限，資料量較少為其中的原因之一。因此本研究提出利用遷移學習解決資料量不足之問題，並使用深度學習模型預測營建物價，以提高預測之表現。此外，多數文獻使用經濟指標作為特徵以預測短期之營建物價，較少文獻預測一年以上之長期營建物價。然而收集資料不易且耗費時間，因此本研究提出利用股票交易市場常見的單一變數衍生之技術分析指標作為輸入變數之方法，以期取代過往收集資料之繁瑣過程。除此之外，本研究為貼近工程投標、採購發包之時程，因此除了預測短期之營建物價，將預測一年之長期營建物價，使此方法得以與實務更為貼近。總結上述，本研究的目的共有以下四點：

1. 提升應用機器學習技術預測營造工程物價指數的準確性和表現，以更精確地反映市場變動，並提供可靠的數據支持。
2. 預測長期（1年）之營造工程物價指數，增加研究結果的實務應用價值，為決策者提供參考依據。
3. 探討遷移學習技術在營造工程物價指數預測中的可行性與成效，以期發現其在提升預測準確性方面的潛力。

4. 探討利用單一變數衍生之技術分析指標預測營造工程物價指數的可行性與成效，評估其代替經濟指標並提高預測準確性方面的貢獻。



1.3 論文架構

本研究論文共可分為五個章節：第一章描述本研究之背景與動機，以闡述本研究之必要性與貢獻，接著說明研究目的以及本文之整體架構；第二章文獻回顧將針對相關研究領域進行回顧，包含營建物價預測、時間序列預測、遷移學習及其應用概況等三個部分，以了解過往研究脈絡背景；第三章研究方法將說明本研究用於預測營建物價之方法，包含遷移學習之預訓練與微調、資料集建立與處理、使用之模型與訓練方式等細節說明；第四章研究結果將敘述研究之設置、最終結果等，並進行比較分析與討論；最後，第五章將進行本研究之總結，說明研究之限制，並提供未來之研究方向與建議。



第二章 文獻回顧

本研究將針對營建物價預測、時間序列預測、以及遷移學習應用概況進行文獻探討。由營建物價預測現行之發展與缺點，延伸至時間序列預測相關方法，再藉由點出常見之時間序列預測方法與營建物價預測方法之不同，以延伸介紹至遷移學習之應用概況。

2.1 營建物價預測

營建物價預測之方法主要可分為時間序列分析 [9, 34–36]、計量經濟模型 [12, 21, 35, 37, 38]、機器學習 [23, 36, 39–42] 以及混合模型 [43–45] 等四種方法。時間序列分析方法主要為差分整合移動平均自我迴歸模型 (Autoregressive Integrated Moving Average Model, ARIMA)，其為自我回歸 (Autoregressive, AR) 模型與移動平均模型 (Moving Average Model, MA) 之組合，此種方式能透過 AR 理解歷史資料，而 MA 則能理解過去的預測誤差，此外，ARIMA 引入差分使得資料較為平穩。ARIAM 之優點為使用簡單，但是其缺點也同樣明顯，包含其要求時間序列需為平穩的，且其只能用於處理線性關係。計量經濟模型主要為向量自迴歸模型 (Vector Autoregression Model, VAR) 以及向量誤差校正模型 (Vector Error Correction, VEC)。VAR 是擴充了只能用於單變數的 AR 模型，但其不能應用在非平穩時間序列，所以資料要先轉換成平穩時間序列；VEC 則是加了共整合條件的

VAR 模型，因此其可用於非平穩時間序列。然而，VAR 與 VEC 僅處理線性關係，但時間序列與變數間有可能呈現非線性關係。機器學習方法有許多種，例如神經網路 (Neural Network)、支援向量機 (Support Vector Machine, SVM) 等，透過機器學習便能夠處理非線性關係，但其資料量要求多，且算力要求高。

有許多方法能夠預測營建物價，然而營建物價通常是非平穩的時間序列且受多種因素影響，包含政治、市場條件等，使得上述方法在預測營建物價時存在挑戰 [21]。在眾多方法中，神經網路之表現比 ARIMA 及迴歸分析好，表示非線性模型之性能比線性模型之性能好 [22, 23]。然而，過去應用非線性模型甚至是深度學習模型之研究較少。僅有下述一些相關研究利用機器學習模型或深度學習模型預測營建物價。

Williams[39] 開發兩個神經網路模型以預測未來一個月與六個月的營建成本指數變化。輸入特徵主要包含成本指數變化、貸款利率、新屋開工數、月份等四個變數。將神經網路與線性迴歸模型、指數平滑模型進行比較，結果顯示神經網路對營建成本指數變化的預測能力很差，線性迴歸模型、指數平滑模型整體上是比神經網路模型更準確的預測器。

Marzouk and Amin[23] 提出一種識別對價格變化最敏感的建築材料的方法，用於修改合約價格，並使用神經網路預測未來材料價格的變化，以期對未來專案成本做出合理的估計。該研究發現鋼筋混凝土工程中的鋼筋、砌塊工程中的磚塊、保溫工程中的保溫材料、陶瓷工程中的瓷磚、木工程中的木材、鋁材工程中的鋁材、瓷磚工程中的瓷磚、鋼材工程中的鋼材和大理石工程中的大理石對專案成本之影響最大。此外，該研究使用上個月的價格指數與去年的平均總數作為輸入特徵，應用神經網路預測未來一個月的材料價格指數。結果顯示，與其他材料類別相比，對應於鋼筋和鋼材的訓練和測試誤差明顯更高，因為這兩種材料在考

慮的研究期間內的價格變動和價格變動百分比的值最大。而神經網路的平均相對誤差 (Average Relative Error) 平均相對誤差為 1.53%，其性能優於回歸分析。

Cheng et al. [43] 提出 ELSVM 以預測台灣營造工程物價指數，其是由最小平方方法支援向量機 (Least-squares Support Vector Machine, LS-SVM) 和差分進化演算法 (Differential Evolution, DE) 融合發展而來。利用 LS-SVM 來發現影響因素和成本指數之間的潛在關係。應用 DE 搜尋 LS-SVM 最優參數。輸入特徵共有 17 個，可分為四組：經濟、金融、股市和能源。此資料集包含 122 個成本指數的實際值和對應的輸入特徵。共使用 92 筆資料訓練此模型。測試集則包含 30 筆資料。結果顯示，在選擇所有變數的情況下，所提出的模型在均方根誤差 (Root Mean Square Error, RMSE) 和平均絕對百分比誤差 (Mean Absolute Percentage Error, MAPE) 方面都取得了最佳結果。ELSVM 在訓練過程中的 RMSE 和 MAPE 分別為 0.039 和 0.027%。此外，測試過程中 ELSVM 的 RMSE 和 MAPE 分別為 1.354 和 0.915%。

Cao et al.[44] 提出使用自適應結構徑向基底神經網絡智能機 (Self-adaptive Structural Radial Basis Neural Network Intelligence Machine, SSRIM) 預測台灣營造工程物價指數。SSRIM 是 MARS (Multivariate Adaptive Regression Splines, MARS)、徑向基底函數神經網路 (Radial Basis Function Neural Network, RBFNN) 和人工蜂群演算法 (Artificial Bee Colony Algorithm, ABC) 的混合模型，其中 MARS 用於過濾多餘之輸入特徵；RBFNN 作為監督學習機器，建立 CCI 與輸入特徵之間的關係；ABC 搜索 RBFNN 的最佳超參數組合。該研究使用 17 個潛在重要影響因素作為初始輸入特徵，這些因素可分為四組：(1) 經濟、(2) 能源、(3) 金融和 (4) 股票市場。其中以股票市場指數為代表的國際市場狀況。首先使用 MARS 來識別並排除在訓練過程中確定的多餘輸入特徵。接著將剩餘的特徵作為輸入給 RBFNN 進行訓練，並以 ABC 找出最佳的 RBFNN 參數。使用 RMSE 與 MAPE 作為比較模



型精度的基礎。與 MARS、RBFNN、ERBFNN (由 RBFNN 和 ABC 融合而成)、進化最小二乘支援向量機 (EL-SVM)、廣義線性回歸模型 (Generalized Linear Regression, GLR)、ARIMA 進行比較。結果顯示, 所提出的混合模型在測試階段取得了最佳結果, RMSE 和 MAPE 分別為 0.976 和 0.676%, 且 ELSVM 使用 17 個輸入特徵, 而 SSRIM 只使用了 11 個, 表明在收集和更新 CCI 資料所需的時間和工作量方面, 估算者與成本工程師至少可以節省 35%。SSRIM 和 ERBFNN 的性能比較顯示, 通過排除冗餘特徵, MARS 改善了 MAPE 的性能約 18%。ERBFNN 與 RBFNN 的性能比較結果顯示, 透過 ABC 可以提升性能。

Tang et al.[45] 提出一種基於最小平方法支援向量機 (LS-SVM) 和改進粒子群最佳化 (Improved Particle Swarm Optimization, IPSO) 的材料價格預測方法。利用 LS-SVM 對價格預測模型進行訓練與測試後, 採用此模型對未來材料價格進行預測。考慮到標準 PSO 的最佳化過程容易陷入局部最優和早熟收斂, 因此引入平均粒子距離和適應度變異數對 PSO 進行改進。以借助 PSO 優化 LS-SVM 之最佳超參數。最後利用 MATLAB 軟體進行模擬分析, 並對演算法的線上和線下效能進行評估。實際計算實例表明, 利用過去 40 個月的鋼筋價格資訊, IPSO-LS-SVM 預測未來六個月鋼筋價格的 MAPE 為 2.11%、均方誤差 (Mean Square Error, MSE) 為 2.44, 與改進前的 PSO 算法、極端學習機 (Extreme Learning Machines, ELM)、神經網絡、多元線性回歸 (Multiple Linear Regression, MLR) 和時間序列預測進行比較, 此方法具有預測精度高、收斂速度快、泛化能力好的優點。因此, 它可以準確預測建築材料價格, 合理地確定最佳採購時間, 並具有實際應用價值。

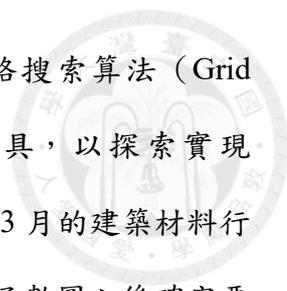
Shiha et al.[40] 利用皮爾森 (Pearson) 相關性檢定和斯皮爾曼 (Spearman) 相關性檢定、共線性測試 (Collinearity test) 以及逐步迴歸辨識鋼材與水泥的領先指標, 並將領先指標作為輸入特徵, 包含消費者物價指數 (Consumer Price Index, CPI)、生產者物價指數 (Producer Price Index, PPI)、失業率 (Unemployment Rate)、國內

生產毛額 (Gross Domestic Product, GDP)、外匯儲備 (Foreign exchange reserves)、美元對埃及鎊匯率 (USDEGP) 和貸款利率 (Lending rates) 等七個變數，接著使用人工神經網路 (Artificial Neural Network, ANN) 作為預測模型，並與多元回歸模型做比較，結果顯示鋼鐵價格預測驗證集的 MAPE 為 10.1%；水泥價格預測驗證集的 MAPE 為 4.3%。多元線性回歸的預測為驗證集產生了相對較高的絕對百分比誤差，範圍從 14% 到 39%。因此，ANN 之預測表現優於多元回歸模型。

Mir et al.[41] 提出利用 ANN 預測瀝青及鋼材的價格區間的模型，採用最優上下界估計 (Optimal Lower Upper Bound Estimation, 最優 LUBE) 方法訓練 ANN，利用上下界的方式量化價格的不確定性。結果顯示，此模型優於 ANN 的單點估計模型以及利用回歸分析所產生的價格區間，而 Optimal LUBE 優於其他的成本函數。

馮重偉 and 江怡萱 [42] 依據文獻回顧確定 19 種影響鋼筋價格之因子，並分別配對 13 種事件之 google 趨勢的搜尋熱度，將資料轉換為圖片的形式，並利用資料增強處理 (將原本的圖片經過旋轉、調整比例尺、偏移、翻轉等方式生成新的圖片) 增加資料量，將圖片輸入至卷積神經網路 (Convolutional Neural Networks, CNN) 進行訓練並預測六個月後的鋼筋價格。結果顯示，在各事件模型中，以「煉鋼業相關污染物標準修訂」以及「國內經濟狀況」的模型準確率 85.4% 為最佳，其次是「中國鋼鐵生產變化」的 83.7%，再來是「外籍移工法令修改」的 83.5%。整體而言，包含事件關鍵字資料之模型相較於只有影響因子的模型，準確率多有提升或接近持平，代表以關鍵字熱度資料來表示無法量化的事件發生為可行的方式，且根據相關係數高低可以過濾部分可能較不相關之關鍵字。

Isikdag et al.[36] 聚焦於建築材料指數的估算。實施了兩種不同類型的分析，分別是 Box-Jenkins (ARIMA) 方法，與非線性自回歸神經網路 (Nonlinear



autoregressive neural network, NARNET)。接著開發了一個網格搜索算法 (Grid Search) 以識別網絡的最佳超參數，和一個相應的軟體工具，以探索實現 NARNET 最準確估算的最佳架構。收集 2013 年 8 月至 2021 年 3 月的建築材料行業指數的所有組成指標，透過檢查自相關函數圖及部分自相關函數圖之後確定要估算之指標。訓練集涵蓋 2013 年 8 月至 2019 年 6 月的時期 (71 個觀測值)，而測試集則涵蓋 2019 年 7 月至 2021 年 3 月的時期 (21 個觀測值)。使用均方根誤差 (RMSE) 和平均絕對誤差 (MAE) 作為模型性能的評價指標。與 ARIMA 模型 (RMSE: 1.0157, MAE: 0.8917) 相比，NARNET 模型 (RMSE: 0.710 和 MAE: 0.585) 的誤差顯著較低。結果還表明，無論時間序列資料的性質和複雜性如何，NARNET 都能成功地模擬資料中的時間相依關係，而這在僅使用 ARIMA 等線性模型的情況下是不可能的。

透過上述應用機器學習與深度學習相關文獻可以發現，目前應用深度學習預測營建物價之相關文獻較少，且其成果還有許多進步空間。此外，多數相關文獻使用經濟指標、市場條件、股票市場等多種特徵作為其資料集，僅少數文獻使用查詢頻率或單變數作為資料集。不僅如此，多數文獻僅預測未來一個月或未來六個月之短期營建物價。但是短期營建物價預測對營建業幫助有限。而多種資料收集將耗費大量人力與時間。本研究為了解深度學習應用於非平穩時間序列之相關方法，因此進行了時間序列預測之相關文獻回顧。

2.2 時間序列預測

應用機器學習與深度學習模型於時間序列預測已被廣泛探討，在能源領域 [46–49]、醫療領域 [50, 51]、金融領域等多個領域中都有大量相關研究。其中，金融領域之時間序列預測與營建物價預測最為相似，因為大部分金融商品（例如股

票、期貨)與營建物價皆屬於非平穩之時間序列,且兩者都受到相同的多個因素影響,例如總體經濟、市場條件、國際情勢、外匯、政治等。因此本小節之時間序列預測相關文獻探討將聚焦於金融領域之時間序列預測。

在金融領域的時間序列預測方面,多數文獻應用機器學習與深度學習模型於匯率預測與股價預測等。目前已有許多研究學者利用機器學習與深度學習模型進行股價預測,並取得了良好的成果。這些模型包括隨機森林(Random Forest) [24–26]、極限梯度提升(eXtreme Gradient Boosting, XGBoost) [27, 28]、支援向量機 [26, 29]、長短期記憶網絡(Long Short-Term Memory, LSTM) [22, 24, 27, 30]、卷積神經網絡(Convolutional Neural Network, CNN) [22, 26, 31, 32]、生成對抗網絡(Generative Adversarial Network, GAN) [33]、以及混合模型 [52, 53]等。其中多數文獻使用之資料集為開盤價(Open)、最高價(High)、最低價(Low)、收盤價(Close)以及成交量(Volume)等五個變數,有部分研究會再加入技術分析指標,少數文獻則會使用基本面資料(例如財務報表)、籌碼面分析(例如外資、自營商、投信等三大法人買賣超資料)、社群媒體文字、總體經濟指標(例如消費者物價指數)等。且有部分文獻會利用小波轉換(Wavelet Transforms) [54]、指數平滑技術 [25]等方法消除原始資料中之隨機性或噪音,以幫助模型之學習,提高最終模型之預測表現。而其輸出則多為下一時間段之收盤價或上漲、下跌之二分類結果。在機器學習模型與深度模型之比較中,Obthong et al.[55]與Goutte et al.[56]指出深度學習模型之預測表現較機器學習模型佳,顯示深度學習模型之優勢。在眾多輸入特徵中,Obthong et al.[55]也指出利用金融新聞與社交媒體作為資料集,進行文字分析或情感分析可提升股價預測之準確度、降低誤差率。最後,眾多股價預測之相關研究指出,在諸多模型之中,長短期記憶模型之預測表現優於其他機器學習模型 [24, 30, 56–59]。

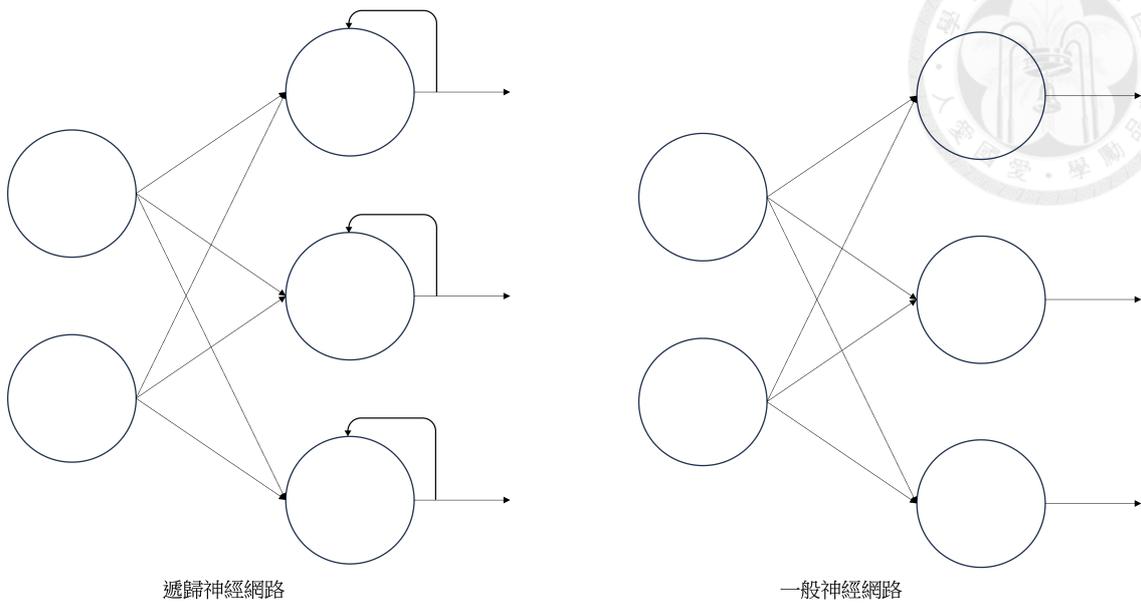
雖然股價預測與營建物價預測之情況相似,兩者皆是非平穩之時間序列,且

受政治、市場條件、匯率等多重因素影響。然而，大部分金融商品具有豐富的資料，以匯率為例，當時間框架為 1 天時，一年大約有 250 筆資料；當時間框架為 30 分鐘時，一年大約有 10,000 筆資料。而營建物價的資料則相對較少，以營造工程物價指數為例，其從 1991 年每個月發佈至 2023 年底也僅有 396 筆資料。因此，金融領域之時間序列預測方法雖多元且成果豐碩，但礙於金融領域之資料量與營建物價之資料量多寡不同，使得金融領域之時間序列預測方法無法完全適用於營建物價預測。

2.2.1 長短期記憶模型

長短期記憶模型（下簡稱 LSTM）為目前時間序列預測中最為常見之模型，且在多篇預測股價之研究中指出 LSTM 之預測表現優於其他機器學習模型 [24, 30, 56–59]。LSTM 模型是由循環神經網路（下簡稱 RNN）演變而來，RNN 是一種深度學習模型。一般神經網路中的神經元輸入與輸出為相互獨立的（圖 2.1），因此其無法處理有順序之資訊，但 RNN 透過添加隱藏狀態與循環結構，理解目前的資訊以及過去的資訊，因此 RNN 能夠在處理序列資料時保留資訊的狀態（圖 2.2）。然而，RNN 面臨梯度消失或梯度爆炸之問題，使其對於較長之序列資料的處理能力受到限制。因此，為了解決此問題，便衍生出了長短期記憶模型 [60]。其透過添加額外的結構來解決 RNN 面臨的問題，從而提高對於長序列資料的處理能力。

LSTM 是為了解決 RNN 梯度消失問題以處理較長之序列資訊演變而來。LSTM 在 RNN 的基礎上加入了記憶單元（Memory Cell）與三個門（Gate）結構，並使用 sigmoid 和 tanh 等激活函數，以及元素乘積和加法等運算，來控制資訊傳遞。透過新增加的這些結構，LSTM 便能夠解決 RNN 面臨之梯度消失問題，使得 LSTM 能夠有效的學習序列中的長期關係。LSTM 模型之架構如圖 2.3 所示。



遞歸神經網路

一般神經網路

圖 2.1: 一般神經網路與循環神經網路 [2]

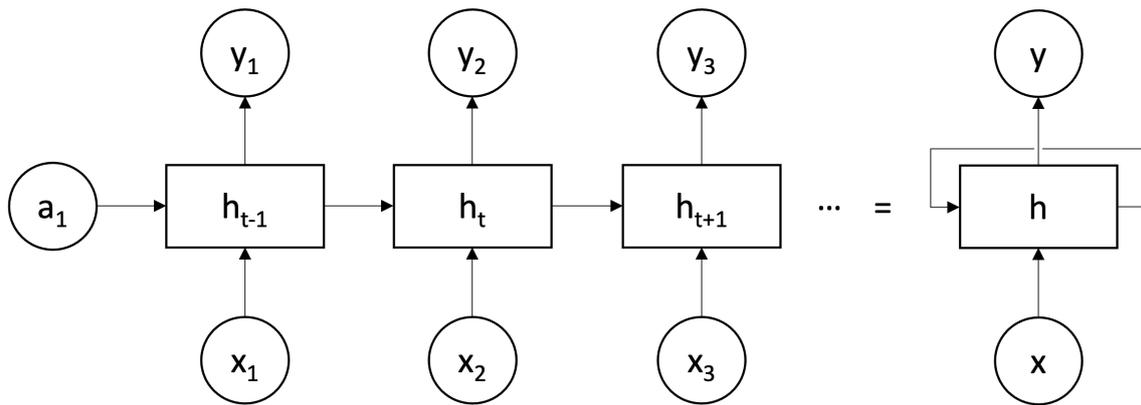


圖 2.2: 循環神經網路 [3]

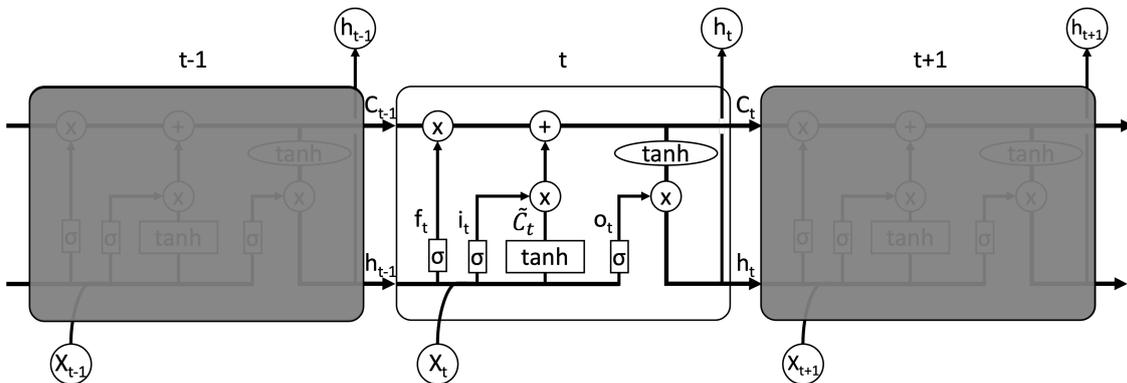
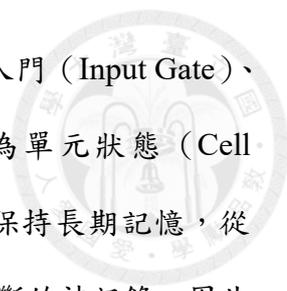


圖 2.3: 長短期記憶模型 [3]



LSTM 模型主要包含記憶單元、遺忘門 (Forget Gate)、輸入門 (Input Gate)、輸出門 (Output Gate)。首先，LSTM 模型的記憶單元又稱為單元狀態 (Cell State)，其能夠在整個序列中傳遞資訊，因此 LSTM 模型能夠保持長期記憶，從而解決 RNN 之梯度消失問題。其次，為了避免不必要的資訊不斷的被記錄，因此利用遺忘門控制哪些資訊應該被遺忘或丟棄，以保持資訊的更新，這有助於模型忽略過去無關的資訊。透過學習遺忘門的權重，LSTM 模型可以動態的決定保留何種過去的資訊。第三，為了更新資訊，因此利用輸入門更新記憶單元，決定哪些新資訊應被記錄至記憶單元中。這將使得模型能有選擇的更新記憶單元的內容，以反映序列中的新資訊。最後，利用輸出門控制哪些資訊應該被輸出，其根據目前的輸入和記憶單元生成模型的輸出。這些門結構透過學習權重來控制記憶單元，使得 LSTM 模型能夠根據序列的不同部分動態的保留和遺忘資訊，以更好的捕捉序列中的長期依賴關係。

透過門結構調控資訊記憶與否是 LSTM 模型之核心概念。單元狀態為連接所有單元的通道，其將資訊不斷地傳遞至下一個單元，圖 2.3 中上方由左至右的直線即代表單元狀態。LSTM 模型之運作流程如下 [60]：

1. 遺忘哪些資訊：LSTM 模型在運作時會先決定哪些資訊要遺忘，這是透過邏輯函數決定從上一層帶進來的資訊，與這一層新增加的資訊有多少比例需被忘掉，而不被帶進下一層。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.1)$$

2. 紀錄新資訊：將新的資料紀錄至單元狀態中。在此將決定什麼資訊應被記錄，並更新單元狀態。

(a) 透過邏輯函數決定哪些資訊需被記錄。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.2)$$



(b) 再透過 tanh 激活函數算出向量，以決定哪些資訊用來更新單元狀態。

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (2.3)$$

3. 接著單元狀態會被更新，此處考慮了上一遺忘步驟的結果 f_t 。

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (2.4)$$

4. 最後決定哪些資訊需被輸出。透過上一步驟之結果 C_t 以及邏輯函數與 tanh 函數決定單元狀態上哪些資訊需被輸出。

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.5)$$

$$h_t = o_t \times \tanh(C_t) \quad (2.6)$$

過往預測營建物價之相關研究較少使用深度學習模型的原因之一應為資料量不足，使得無法利用較為複雜之模型。因為當資料量較少時，可能會發生過度擬合或是欠擬合之問題，使得模型預測表現十分不理想。因此過往研究多利用較為簡單的機器學習演算法，並結合超參數優化演算法等方法，以期提升預測表現。然而，現今人工智慧發展迅速，各式強大模型推陳出新，並廣泛應用於各領域，幫助推進各領域之研究。然而，若因資料量不足而不使用更為強大的模型實屬可惜。因此，本研究為解決因資料量不足而無法使用深度學習模型之困難，將回顧

過往廣泛應用於自然語言處理任務與電腦視覺任務之遷移學習方法。



2.3 機器學習與遷移學習

2.3.1 機器學習介紹

隨著資料生成速度與資料量的爆炸性增長，機器學習 (Machine Learning) 成為現代資料分析與人工智慧領域中的核心技術。機器學習是一種透過資料自動學習並改進的技術，使計算機能夠在沒有明確編寫程式的情況下進行預測或決策。其應用範圍廣泛，涵蓋了圖像辨識、語音辨識、自然語言處理、時間序列預測以及醫療診斷等眾多領域。機器學習技術的成功取決於對大量資料進行有效處理與分析，以及選擇適當的算法及模型以捕捉資料中的模式與趨勢。因此，機器學習不僅是一個理論研究的熱點，也是一個實踐中不斷探索和創新的領域。

在眾多機器學習方法中，監督式學習 (Supervised Learning) 與無監督式學習 (Unsupervised Learning) 是最為常見的兩種方法。監督式學習透過標註資料以訓練模型，使其能夠對新資料進行預測；無監督式學習則在無需標註資料的情況下，透過資料的內在結構進行模式識別。此外，半監督式學習 (Semi-supervised Learning) 和強化學習 (Reinforcement Learning) 也逐漸受到重視，前者結合了少量標註資料和大量未標註資料，後者則通過與環境的交互來學習最佳行動策略。

隨著技術的不斷進步，遷移學習 (Transfer Learning) 作為一種新興的方法，開始在各個領域展現其獨特的優勢。遷移學習旨在利用已有的知識和經驗，將其應用於不同但相關的問題上，從而提高學習效率和效果。這種方法特別適用於資料稀缺或標註困難的情況，並且在許多實際應用中已經展示出顯著的效果。

機器學習的成功實施需要遵循一系列有系統的步驟，這些步驟確保了資料的

有效利用和模型的高效訓練。以下是機器學習的典型流程：



1. 問題定義：首先，明確需要解決的問題以及預期目標。這一步包括確定是分類問題、回歸問題還是其他類型的問題，並定義相關的評估指標以衡量模型的性能。
2. 資料收集：在問題定義之後，收集相關的資料是關鍵。資料可以來自多種來源，包括資料庫、線上資源、感測器或手動收集。確保資料的品質與數量足以支撐後續的模型訓練。
3. 資料預處理：資料收集完成後，需要對資料進行清洗與處理。這一步包括處理缺失值、去除異常值、轉換資料格式以及標準化或正規化資料。資料預處理的品質將直接影響模型的性能。
4. 特徵工程：特徵工程是從原始資料中提取有用特徵的過程，包括特徵選擇和特徵創建。好的特徵能夠顯著提高模型的預測能力和準確性。
5. 資料分割：將資料集劃分為訓練集（Training Set）和測試集（Testing Set），有時還包括驗證集（Validation Set）。訓練集用於模型訓練，測試集用於模型評估，驗證集用於模型超參數調整。
6. 選擇和訓練模型：根據問題類型與資料特性選擇合適的機器學習算法及模型。使用訓練集進行模型訓練，並透過迭代過程不斷優化模型參數，使模型能夠最好地適應訓練資料。
7. 模型評估：使用測試集評估模型的性能，在分類任務中，常用的評估指標包括準確率（Accuracy）、精確率（Precision）、召回率（Recall）、F1 分數（F1 Score）等；在回歸任務中，常用的評估指標包含平均絕對誤差（Mean Absolute Error, MAE）、平均絕對百分比誤差（Mean Absolute Percentage Error,

MAPE)、均方誤差 (Mean Square Error, MSE)、均方根誤差 (Root Mean Squared Error, RMSE)。根據評估結果，確定模型的優劣和改進空間。

8. 模型部署和應用：當模型達到預期性能後，將其部署到實際應用環境中，進行預測或決策。部署過程包括模型轉化、系統整合以及性能測試等。
9. 持續監控和維護：模型部署後，需要對其進行持續監控，確保其在實際應用中保持良好性能。隨著時間的推移，資料可能會發生變化，因此需要定期更新並維護模型，甚至重新訓練模型以應對新資料。

2.3.2 遷移學習介紹

人們在學習新事物與新知識時，往往會從過去的相關知識或經驗來幫助學習現在的新事物與新知識。例如，現在要學習機器學習模型構建時，可以利用過去學習統計學和程式設計的經驗來幫助學習。因為在學習統計學時，已經掌握了資料分析和機率分佈的基本概念；在學習程式設計時，學會了如何編寫與調整程式碼。這些知識可以幫助更快地理解機器學習中的資料預處理、模型訓練和評估等過程。遷移學習 (Transfer Learning) 就是受到人類這種學習方式的啟發而開始發展 [4]。目前在許多機器學習應用領域便是需要此種遷移學習的幫助，例如醫療圖像分析中要取得標記資料可能是非常昂貴且耗時的，因此當我們擁有一個在識別其他類型癌症 (如乳腺癌) 方面訓練良好的模型，這些模型中提取的特徵可以遷移到肺癌診斷模型中。如此便只需較少的肺部電腦斷層 (Computed tomography, CT) 圖像資料即可訓練一個高效的肺癌診斷模型，從而顯著減少了資料標註的工作量和成本。不僅如此，在語音識別領域由於每種方言的語音資料分佈可能不同，因此直接獲取並標記大量的方言語音資料是非常困難且昂貴的。如果我們已經擁有一個在標準語音資料上訓練良好的模型，可以利用這個模型的特徵，將其遷移

到特定方言的語音識別任務中。這樣，即使只有少量的方言語音資料，也能訓練出一個性能優良的語音識別模型，從而大大減少資料收集和標註的工作量。

目前多數表現良好的機器學習模型是在一個假設下運行，即訓練資料與測試資料的特徵空間相同，且分佈相同。然而，現實中並不總能滿足此假設，可能同一個資料集的訓練資料與測試資料就有不同的分佈；或是我們希望一個或多個領域收集資料並訓練模型，然後將此模型應用在不同的需求任務上。若要因此重新收集資料，則代價將會很大甚至是不可能的。因此利用知識的遷移有其必要性，因為遷移學習透過將一個或多個領域中學到的知識遷移到目標領域上，藉此可能可以改善目標任務的學習，儘管訓練和測試中使用的領域、任務和分佈不同 [4, 5, 61–64]。因此，如圖2.4所示，傳統機器學習只專注於單一任務，而遷移學習則是透過過去的知識幫助更快更有效的解決新的且類似的問題 [62]。遷移學習領域中，將先前學習過的知識稱為源域（Source Domain）；現在要解決的新的且類似的問題則稱為目標域（Target Domain）。因此，遷移學習之目標是透過源域的知識改善目標域的學習 [4]。

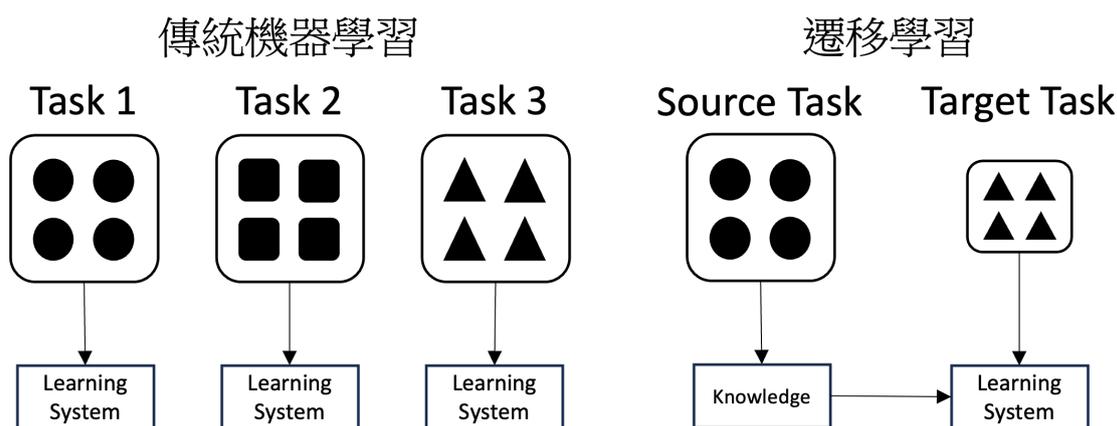


圖 2.4: 遷移學習示意圖 [4]

域 (Domain) D 由特徵空間 (Feature Space) \mathcal{X} 以及邊際機率分佈 (Marginal Probability Distribution) $P(X)$ 所組成，其中 $X = \{x_1, \dots, x_n\} \in \mathcal{X}$ 。例如當學習任務是圖像分類時，將每個像素 (Pixel) 作為一個特徵，那麼 \mathcal{X} 是所有特徵

的空間， x_i 是對應於某些圖像的第 i 個像素， X 是一個特定的學習樣本。當兩個域不同時，則通常具有不同的特徵空間或不同的邊際機率分佈。給定特定域 $D = \{\mathcal{X}, P(X)\}$ ，任務 (Task) 寫作 $T = \{\mathcal{Y}, f(\cdot)\}$ ，其中包含標籤空間 \mathcal{Y} 與目標預測函數 (Objective Predictive Function) $f(\cdot)$ ， $f(\cdot)$ 是從訓練資料學習的而不是透過觀察得到的，其中訓練資料由 $\{x_i, y_i\}$ 的資料對組成，而 $x_i \in \mathcal{X}, y_i \in \mathcal{Y}$ 。 $f(\cdot)$ 在有新的 x 的時候，可以用來預測其相對應的標籤 y 。若以機率之觀點出發， $f(x)$ 可以寫作 $P(y | x)$ 。當任務是圖像分類時，此時的任務就是「分類」；當任務是時間序列預測時，此時的任務就是「預測」，也就是進行回歸。因此遷移學習在本研究中的統一定義為：給定源域 D_S 和源學習任務 T_S 、目標域 D_T 和目標學習任務 T_T ，遷移學習希望利用 D_S 和 T_S 中的知識幫助改進 D_T 中目標預測函數 $f_T(\cdot)$ 的學習，其中 $D_S \neq D_T$ ，或 $T_S \neq T_T$ 。其中源域與目標域的不同包含特徵不同、特徵分佈 (Marginal Distributions) 不同、標籤不同、標籤的分佈 (Conditional Probability Distributions) 不同 [4, 63]。

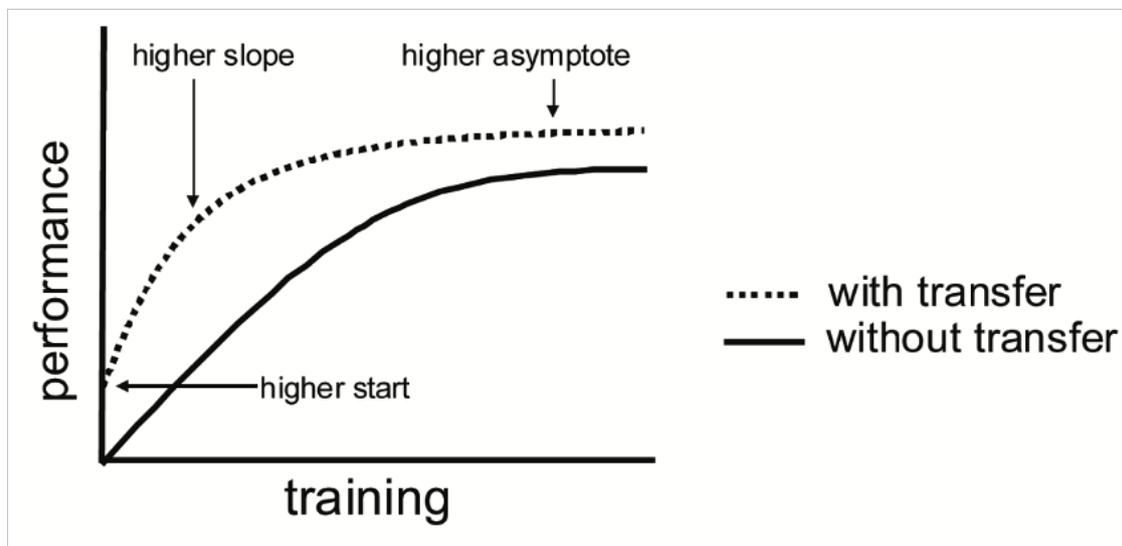


圖 2.5: 遷移學習對模型訓練之影響 [5]

遷移學習可改善機器學習模型訓練的三個方面 (圖2.5)，包含模型的初始表現、模型收斂的時間、以及模型最終的表現 [5]。因此遷移學習主要用在以下三個情境：



- 資料收集困難
- 標籤 (Label) 標記困難、耗時、繁瑣
- 對模型泛化 (Generalize) 能力的要求

源域與目標域的關係會顯著影響遷移學習的有效性，當源域與目標域的特徵空間與分佈相似，且能夠利用遷移學習時，透過遷移源域的知識能夠顯著提升目標域的模型表現 [5]。但並不是任意源域的知識都能夠幫助目標域的學習。已有研究證實了機器學習之間知識遷移的有效性以及負遷移 (Negative Transfer) 的存在 [61, 65, 66]。Shimodaira[67] 證明當源域與目標域的邊際分佈不同時，目標任務模型的表現不會最佳。不僅如此，負遷移被認為是遷移學習領域的一大挑戰 [4, 5, 63]。負遷移是指從源域學習的知識無法提升目標域模型表現，甚至會降低目標域模型的表現 [4, 63, 68]。Weiss et al.[63] 將負遷移定義為：目標任務 T_T ，僅使用 D_T 訓練的預測學習器 $f_{T1}(\cdot)$ ，和使用 D_T 和 D_S 結合的遷移學習訓練的預測學習器 $f_{T2}(\cdot)$ ，當 $f_{T1}(\cdot)$ 的表現大於 $f_{T2}(\cdot)$ 的性能時，稱為負遷移。因此當源域或源任務與目標不夠相關，或者遷移的方法未充分利用彼此間的關係，則遷移學習可能會傷害目標任務的表現，也就是失敗的知識遷移 [4, 5, 68]。負遷移的發生取決於多個因素，包含源域和目標域之間的相關性、模型跨域遷移知識的能力等 [68]。避免負面遷移的方法包含：在學習目標任務時嘗試辨識並拒絕有害的、不相關的源域知識；透過一組候選源任務，選擇最佳源域的資料集或是模型，或是選擇多個好的源域；建立任務間的相似度等 [4, 5]。

應用遷移學習時，主要有三個問題：遷移什麼、如何遷移、以及什麼時候遷移。「遷移什麼」決定哪些知識可以或是需要在不同任務之間遷移；「如何遷移」則是要利用什麼方法、工具來幫助遷移；「何時遷移」則是決定要在什麼情況下進行知識遷移。根據源域、目標域以及源任務、目標任務之間的不同情況，可以將

遷移學習分為三個不同部分，此三個部分與傳統機器學習之不同可參考表2.1[4]：

1. Inductive Transfer Learning：源任務與目標任務不同，源域和目標域可以相同或是不相同。
2. Transductive Transfer Learning：源任務與目標任務相同，但是源域和目標域不同。
3. Unsupervised Transfer Learning：源任務與目標任務不同但相關，而源域與目標域不同但也相關。

表 2.1: 遷移學習領域 [4]

學習方法	源域與目標域	源任務與目標任務
傳統機器學習方法	相同	相同
Inductive Transfer Learning	相同	不相同但相關
Transductive Transfer Learning	不相同但相關	相同
Unsupervised Transfer Learning	不相同但相關	不相同但相關

再根據上述三種遷移學習不同的描述，以及如何遷移的問題，可以將遷移學習的方法歸納為下列四種 [4]：

1. 基於實例的遷移學習方法 (Instance-based Transfer Learning)：假設源域中的某些資料可以透過重新加權或一些不同計算方法，使得這些源域資料能夠在目標域中使用，使得目標域能夠有足夠多的資料進行學習。
2. 特徵表示遷移方法 (Feature-representation-transfer Approach)：透過新的特徵表示方法，以期目標任務的性能能夠顯著提升。例如將源域與目標域的特徵投影至相同的特徵空間等方法。
3. 參數遷移方法 (Parameter-transfer Approach)：假設源任務和目標任務共享某些參數或模型的超參數。

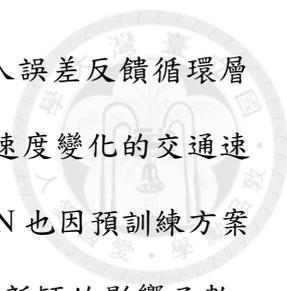
4. 關係知識遷移問題 (Relational-knowledge-transfer Problem)：假設源域和目標域中的資料之間存在一定關係，因此要遷移的知識是資料之間的關係。

除了上述歸納之外，遷移學習在應用方面可以分為四個類別，包含基於神經網路的遷移學習 (Neural Network-based Transfer Learning)、基於貝葉斯的遷移學習 (Bayes-based Transfer Learning)、模糊遷移學習 (Fuzzy Transfer Learning)、以及基於計算智能的遷移學習 (Applications of Computational Intelligence-based Transfer Learning) [62]。

2.3.3 遷移學習應用概況

遷移學習在諸多領域已經取得許多研究成果。若依照任務區分，遷移學習於自然語言處理與電腦視覺任務受到較大的關注，而時間序列相關任務則相對較少 [69]。若依照使用領域區分，在醫療領域、生物序列分析、交通領域、推薦系統、通訊領域等方面皆有所建樹 [63, 68]。

遷移學習應用於時間序列方面，Ribeiro et al.[48] 應用遷移學習在跨建築物的電力預測，其使用相似建築物的電力資料，針對僅有少數歷史資料的建築物進行基於感應器的電力預測。其目標是增加資料變化，以填補由於缺失樣本而產生的空缺，從而達到更準確的預測。此外，Ribeiro et al.[48] 使用了 Hephaestus，一種具有季節性和趨勢調整的跨建築能源預測的遷移學習方法。該研究表明，與僅使用目標資料或使用所有資料但沒有 Hephaestus 相比，所提出的方法可以透過使用其他學校的附加資料，將學校的能源預測準確度提高了 11.2%。Wang et al.[70] 應用遷移學習於交通速度以及塞車源頭的預測與分析，該研究提出一種具有誤差回饋循環卷積神經網路結構 (Error-feedback Recurrent Convolutional Neural Network, eRCNN) 的深度學習方法，用於連續交通速度預測。結果表明，eRCNN 能夠有



效地從相鄰道路段的交通速度資料中提取時空特徵，並且引入誤差反饋循環層對 eRCNN 確實是有益的。且實驗結果證明了在預測具有突變速度變化的交通速度時，將單獨的誤差反饋神經元引入 eRCNN 的有效性。eRCNN 也因預訓練方案而大大增強。不僅如此，該研究基於深度學習模型設計了一種新穎的影響函數，並展示了如何利用它來識別北京環路的擁塞源頭。Shao et al.[71] 應用遷移學習在工業設備故障檢測，該研究提出了一個基於深度卷積神經網路模型的機器故障診斷框架，該框架使用遷移學習來提高模型訓練效率。結果顯示所提出的方法導致更快的訓練速度和更高的準確性。Raghu et al.[50] 與 Strodthoff et al.[51] 將遷移學習應用於醫療方面的檢測，例如將 EEG 時間序列轉換為頻譜圖堆疊，作為卷積神經網路的輸入，以分類癲癇類型 [50]。或是利用心電圖作為 ResNet (Deep Residual Neural Network) 之輸入，以協助醫師診斷 [51]。Cen and Wang[72] 應用遷移學習幫助原油價格預測。該研究利用長短期記憶 (LSTM) 模型擬合原油價格，並提出一種結合先驗知識的資料遷移算法。透過對所提出模型的預測能力進行評估，其對西德克薩斯中級原油 (West Texas Intermediate, WTI) 和布倫特原油 (Brent Crude) 的預測效果進行了實證研究，結果證明了該算法的優勢。Du et al.[46] 開發新的遷移學習方法— AdaRNN (Adaptive Recurrent Neural Network)，AdaRNN 由兩個模組組成，第一個模組稱為時間分佈特徵化 (Temporal distribution characterization)，以更好地表示時間序列中的分佈資訊，第二個模組稱為時間分佈匹配 (Temporal distribution matching)，以減少時間序列中的分佈失配，學習基於循環神經網路的自適應時間序列預測模型，該研究將其用來辨識人類活動、預測空氣品質、家庭用電量和財務分析，並能提高其預測表現。

Ma et al.[73] 應用遷移學習於空氣品質的預測。該研究提出利用深度學習之遷移學習框架，以將知識從較小之時間框架遷移到較大之時間框架。該研究利用雙向長短期記憶模型學習 PM2.5 濃度與空氣品質之長期關係，並應用預訓練與微調



將一小時時間框架學到的知識遷移到一天與一週時間框架上以預測空氣品質。其滑動窗口大小透過自相關分析顯示皆為 5。結果表明，利用預訓練與微調遷移從一小時時間框架學到的知識到一天與一週時間框架，一天時間框架之 RMSE 降低了 36.85%，一週時間框架之 RMSE 下降了 42.58%。一週時間框架於預測表現之改進高於一天時間框架之改進，該研究推測是因為一週時間框架之資料短缺問題較為嚴重，因此遷移學習的幫助更大。且此方法之表現優於其他幾種比較模型，包括 ARIMA、支援向量迴歸 (Support Vector Regression, SVR)、梯度提升決策樹 (Gradient Boosting Decision Tree, GBDT)、循環神經網絡 (Recurrent Neural Networks, RNN)、閘控循環單元 (Gated Recurrent Unit, GRU)、普通長短期記憶模型 (LSTM) 和卷積神經網絡-LSTM (CNN-LSTM)。總的來說，應用預訓練與微調遷移較小時間框架之知識到較大時間框架，有助於提高雙向長短期記憶模型在較大時間框架下的預測準確性。

在金融領域，遷移學習則多用來進行自然語言處理任務，例如文本探勘、情感分析、文本分類等，包含作為財務決策之依據 [74]、公司營收之預測 [75] 等。在時間序列方面的研究與應用則相對較少 [76, 77]。同時，遷移學習應用於時間序列預測方面，在工程領域之相關研究也較為稀少，本研究也未發現使用遷移學習協助預測營建物價之相關研究。

2.4 文獻回顧小結

在營建物價預測方面，應用深度學習之相關研究較少，且其成果有相當大之進步空間。此外，多數文獻利用營建物價指數、材料價格、市場條件、經濟指標、股票市場等作為輸入特徵。然而，收集資料曠日費時且諸多資料之發布日期不一，易造成資料收集之困難。最後，較少文獻預測一年以上之營建物價，而是

預測短期之營建物價。然而，一般工程之期程為一年以上，因此必須要有良好的長期預測，對實務上才較有幫助。

在時間序列預測方面，金融領域有諸多時間序列預測相關文獻，且應用之深度學習模型非常廣泛。然而，金融領域之多數商品具有豐富之歷史資料，例如股價、匯率等，但是營建物價之相關資料則相對較少，因此金融領域中股票價格的時間序列預測相關方法無法完全適用於營建物價之預測。本研究為解決資料量較少而不利於機器學習模型訓練之困難，因此利用遷移學習以幫助模型訓練。

在遷移學習方面，其主要應用於自然語言處理任務與電腦視覺任務，應用於金融領域與工程領域之時間序列預測則相對較少，且沒有相關文獻將遷移學習應用於營建物價預測。此外，Ma et al.[73] 提出利用深度學習之遷移學習框架，以將知識從較小之時間框架遷移到較大之時間框架。

本研究基於上述過往研究不足之處，並解決資料量較少而不利於機器學習模型訓練之困難，因此將利用深度學習模型結合遷移學習之方法，以資料量較多之源域資料集訓練預訓練模型，再利用資料量較少之營建物價相關資料集進行微調後，用以預測營建物價，以期改善其預測表現。Ma et al.[73] 採用之源域與目標域是相同來源，僅時間框架不同。其與本研究之差別在於，本研究之營建物價只有一個月之時間框架，因此將會使用非營建物價之資料作為源域資料集，並利用深度學習模型提取其中之特徵關係，經過營建物價相關之資料集進行微調後，用於預測營建物價。此外，本研究將預測長期營建物價，並利用技術分析指標取代經濟指標，以期減少資料收集時間，並提高預測表現。



第三章 研究方法

3.1 研究流程與架構

本研究將應用深度學習模型以及遷移學習預測營造工程物價指數。本研究採用之遷移學習流程如圖 3.1 所示，共可分為五個部分，包含（一）定義源域與目標域、（二）資料集建立與處理、（三）訓練預訓練模型、（四）微調、（五）測試與比較。首先，為了避免負遷移並提高遷移學習之表現，因此需要針對源域進行選擇，並定義目標域。在完成定義源域與目標域後，便能夠針對源域以及目標域建立各自的資料集並進行相對應的處理，包含按照時間順序與比例進行資料集分割，並在各個資料集內分別進行最大最小正規化，以確保各特徵之尺度相同，最後利用滑動窗口技術將資料集進行包裝。資料集建立並處理完成後，便能夠開始訓練並微調模型，此二步驟均屬於遷移學習之範疇。訓練預訓練模型使用之資料集為源域資料集，並手動進行超參數之調整。接著利用目標域資料集微調預訓練模型，並手動調整超參數。最後，利用測試集進行測試並比較最終的結果。

3.2 遷移學習方法

遷移學習之目標是透過源域的知識改善目標域的學習。遷移學習常見之方法包含基於實例的遷移學習方法、特徵表示遷移方法、參數遷移方法、以及關係知

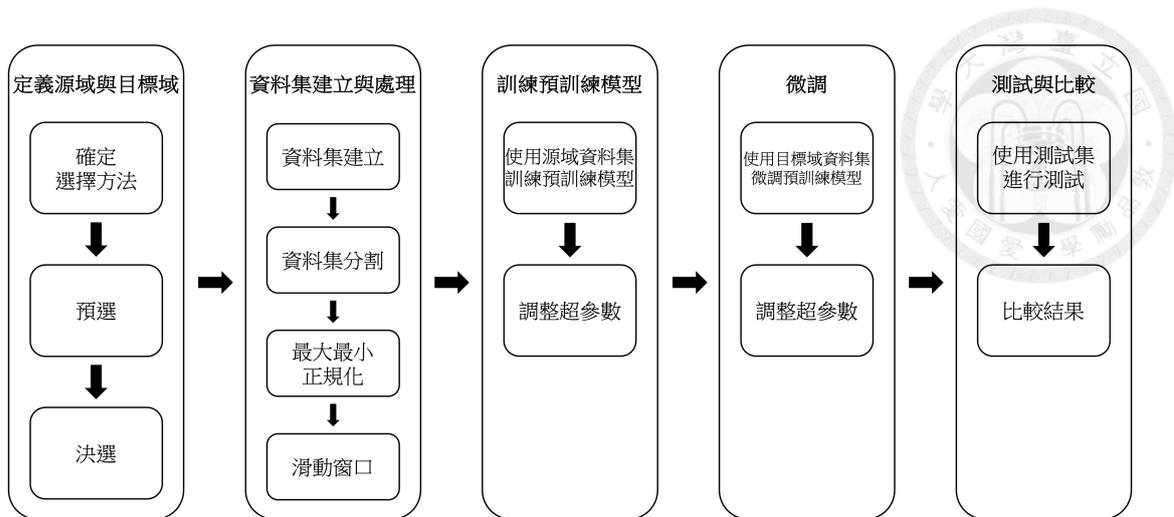


圖 3.1: 研究流程與架構

識遷移問題 [4]。本研究將使用參數轉移方法之一的預訓練 (Pre-training) 與微調 (Fine-tuning)，用以協助預測營造工程物價指數，提高機器學習預測表現。此種方法也屬於基於神經網路的遷移學習。預訓練與微調為常見之機器學習訓練方法，例如圖像辨識、圖像分類中常見的 ResNet50 與 VGG 等模型；自然語言處理中的 BERT (Bidirectional Encoder Representations from Transformers, BERT) 語言模型等即是預先訓練好的模型，後續只需經過微調後便能夠直接應用。本研究將預訓練定義為利用源域之資料預先訓練模型，而預先訓練完成的模型便稱為預訓練模型 (Pre-train Model)；微調之定義為利用目標域之資料針對整個預訓練模型或部分預訓練模型進行再訓練。

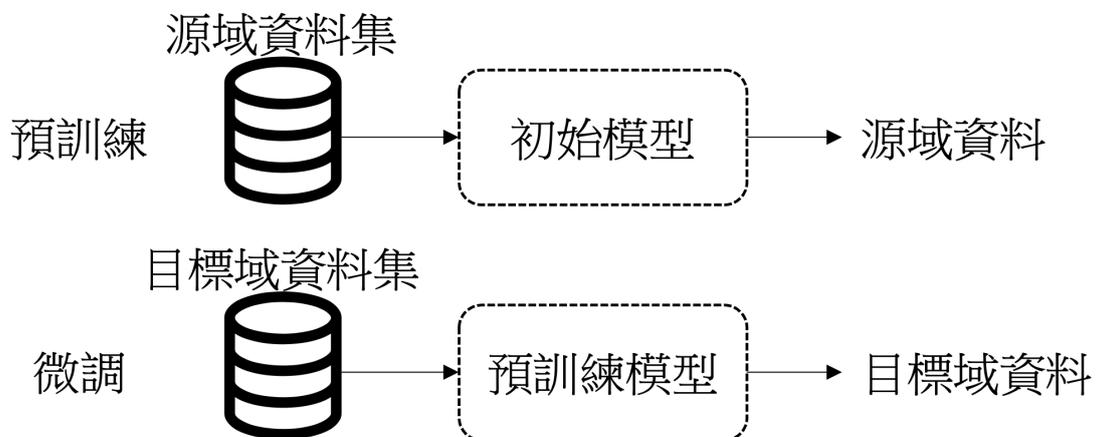


圖 3.2: 預訓練與微調示意圖

於圖3.2中，預訓練是指利用源域資料集，針對初始模型進行訓練，初始模型

表示其參數為隨機初始化，訓練完成後利用源域資料集進行測試，以評估訓練完成後之模型表現。預訓練完成後的模型在本研究中稱為預訓練模型。微調是指利用目標域資料集，針對預訓練模型進行訓練，表示此時模型的初始參數便是預訓練模型之參數，而非隨機初始之參數。接著利用目標域資料集進行測試，以評估訓練完成後之模型表現。

3.3 定義源域與目標域

在正式訓練模型並預測營建物價之前，應先定義本研究之預測標的物，也就是遷移學習中的目標域。本研究之目標域為希望預測之指數，總共預測三個指數，包含：

1. 營造工程物價總指數
2. 營造工程物價指數之材料中分類指數－水泥及其製品類指數
3. 營造工程物價指數之材料中分類指數－金屬製品類指數

透過營造工程物價總指數，能夠概略的了解整體營建產業之物價波動情形，包含材料類與勞務類價格波動，但其可能過於粗略而無法顯示真正的材料物價波動。因此本研究也預測兩個營造工程物價指數之材料中分類指數，包含水泥及其製品類指數、以及金屬製品類指數。選擇此二種指數是因為這是權重較大的兩個材料中分類指數。營造工程物價指數之材料中分類指數權重如表 3.1 所示。

在源域的部分，相關文獻指出透過選擇良好的源域，能夠避免負遷移的發生 [4, 5]。更重要的是，良好的源域選擇有助於提高遷移學習之表現 [66, 78]。H. Xu et al.[66] 研究顯示相關係數越高，源域和目標域的股票價格波動規律越相似，遷移學習的誤差值越小，結果越準確。Li et al.[78] 則是透過餘弦相似度選擇源域，



表 3.1: 營造工程物價指數—材料類權重 [6]

類別	權數 (%)
(一) 水泥及其製品類	141.065
(二) 砂石及級配類	21.142
(三) 磚瓦瓷類	13.911
(四) 金屬製品類	233.420
(五) 木材及其製品類	24.002
(六) 塑膠製品類	19.554
(七) 油漆塗裝類	9.302
(八) 機電設備類	120.193
(九) 瀝青及其製品類	19.067
(十) 雜項類	57.581

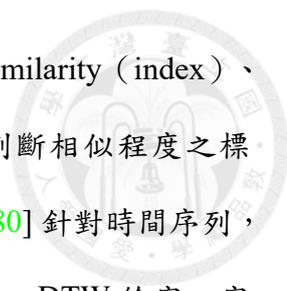
結果顯示，良好的選擇有助於提高遷移學習之表現。因此本研究透過以下三個步驟進行源域選擇（圖3.3），包含確定使用之選擇方法、預選源域、與決選源域。以下小節將針對這三個步驟進行更詳細的說明。



圖 3.3: 源域選擇流程

3.3.1 確定源域選擇方法

王晋东 [79] 整理了 13 種衡量兩個域之間相似程度的方法，包含 Manhattan Distance、Euclidean Distance、Chebyshev Distance、Mahalanobis Distance、Maximum Mean Discrepancy (MMD)、 \mathcal{A} -Distance、Kullback-Leibler (KL) Divergence、Wasserstein Distance、Cosine Similarity、Jaccard Similarity (index)、Pearson Correlation、Spearman Correlation、Kendall Correlation。其中，Maximum Mean Discrepancy (MMD) 是在遷移學習中最常使用的方法。Manhattan Distance、Euclidean Distance、Chebyshev Distance、Mahalanobis Distance、Maximum Mean Discrepancy (MMD)、 \mathcal{A} -Distance、Kullback-Leibler (KL) Divergence、Wasserstein Distance 判斷相似程度



之標準為數值越小表示越相近；Cosine Similarity、Jaccard Similarity (index)、Pearson Correlation、Spearman Correlation、Kendall Correlation 判斷相似程度之標準為數值越大表示越相近。除了上述常見之方法，Fawaz et al. [80] 針對時間序列，提出 Dynamic Time Warping (DTW) 方法以選擇最佳源域資料集。DTW 給定一定限制與規則，並利用動態規劃 (Dynamic Programming) 尋找最佳的時間序列匹配，以計算兩個時間序列的相似程度的方法。其能夠應用於時間序列長度不同。目前已廣泛應用於許多時間序列資料，例如音訊、視訊等。雖然有許多方法能夠應用於源域選擇，但是在遷移學習應用於時間序列預測之相關文獻中，較少文獻提及選擇源域的問題以及最佳的選擇方法。因此，本研究以王晋东 [79] 整理之 13 種方法為基礎並加入 DTW，共使用 14 種方法衡量預選源域與目標域之間的相近程度。

3.3.2 預選源域

在使用上述衡量兩個域之間相似程度的 14 種方法之前，應先縮小選擇源域的範圍，也就是需經過源域預選。台灣為一海島型國家，國內能源以及原物料等資源需依賴進口，例如石油、天然氣、砂石、煉鋼之原物料—鐵礦石與焦煤等，因此匯率波動對這些產品之價格皆會造成影響。根據台灣財政部關務署海關進出口統計網 [81] 之資料顯示，水泥、砂石、鐵礦石、鋼鐵等物品於 2023 年進口量皆達百萬公噸以上，其中鋼鐵更是進口千萬公噸，若以金額計算則是六千萬至一百億美元以上。因此，當匯率波動時，易造成國內鋼鐵、水泥等材料之價格波動。以鋼鐵與鐵礦石之進出口情形為例，根據財政部鋼鐵業原物料耗用通常水準 [82] 顯示，我國 2020 年粗鋼生產量為 2095.8 萬公噸，以高爐生產占 60.6%，電弧爐生產占 39.4%，然高爐煉鋼廠之主要原料為鐵礦石，我國必須全數進口，因其必須含有足夠的鐵成分始能作為原料使用。而粗鋼進口量為 336.5 萬公噸，占我國總粗



表 3.2: 源域選擇方法

方法	描述	判斷標準
Manhattan Distance	兩點於直角坐標系上之絕對軸距總和	越小越好
Euclidean Distance	兩點間直線距離	越小越好
Chebyshev Distance	兩點於直角坐標系上之最大坐標差	越小越好
Mahalanobis Distance	資料間的共變異數距離	越小越好
Maximum Mean Discrepancy (MMD)	為核 (Kernel) 學習方法，量測 reproducing kernel Hilbert space 中的兩點距離	越小越好
A-Distance	建立線性分類器以區分兩個域的 hinge 損失	越小越好
Kullback-Leibler (KL) Divergence	衡量兩個機率分佈間的距離	越小越好
Wasserstein Distance	衡量兩個機率分佈間的距離，表示分佈間轉換的最小成本	越小越好
Cosine Similarity	量測兩個向量夾角餘弦值，以衡量其相似性	越大越好
Jaccard Similarity (index)	量測兩個集合交集大小與聯集大小之間的比例，以衡量其相似性	越大越好
Pearson Correlation	量測兩組資料間之線性相關程度	越大越好
Spearman Correlation	利用單調函數量測兩個變數的相關性	越大越好
Kendall Correlation	比較兩組數值的排序方向以衡量其相似度	越大越好
Dynamic Time Warping (DTW)	針對時間序列被提出來之相似度匹配方法	越小越好

鋼量 14%，其中日本占總進口額的 39%，位居第一。至於營建大宗材料之一的水泥情況，是根據台灣區水泥工業同業公會 2023 年度公會年報 [83] 顯示，2022 年國內水泥消耗量共 1,350 萬公噸，而進口水泥根據財政部關務署 2022 年海關進出口統計量顯示為 340 萬公噸 [81]，占比約 25%。從上述統計資料可以得知營建材料部分需仰賴進口，而煉鋼之原料則須全數進口，因此匯率波動勢必會對國內營建材料造成影響。

除了從國內進口資料得知匯率影響外，相關文獻也指出營建物價與匯率之關聯。遠期外匯契約是管理外匯暴露風險最常見的衍生性金融商品之一，當一個產業或企業受到外匯波動影響較大時，便會使用諸如遠期外匯契約的衍生性金融商品進行避險。有過往研究顯示，國內鋼鐵業受匯率波動的影響較高，因為其最常用遠期外匯契約進行避險，而以整體的營建材料供應商來說，材料供應商使用的衍生性金融商品中，有 71.9% 是使用遠期外匯契約，可見匯率波動對材料供應商而言是一不確定性高的風險 [37]。此外，亦有國內研究利用相關性分析發現，在美元、歐元、日圓以及人民幣四種外匯中，歐元與營造工程物價指數之皮爾森相關性最高 [84, 85]，達到 0.863 的高相關性；人民幣與營造工程物價指數之皮爾森相關係數為 0.768；日圓與營造工程物價指數之皮爾森相關係數則為 0.514，皆達到高度以及中度相關性。

鑑於匯率變動與營建物價具有密切關係，本研究將源域探討範圍限縮於匯率面向。目前，國際主要交易貨幣包括美元 (USD)、日圓 (JPY)、歐元 (EUR)、英鎊 (GBP) 及澳幣 (AUD) 等，同時亦作為各國外匯儲備的主要準備貨幣。根據台灣財政部關務署海關進出口統計網 [81] 於 2023 年之資料顯示，在水泥及其製品類進口方面，日本和中國進口額分別占總進口額的 24.83% 及 11.80%，位居第二及第三；兩國進口額合計佔 36.63%。就金屬進口而言，日本、澳大利亞及中國進口額分別占總進口額的 14.98%、13.65% 及 12.72%，分別排名第二、第三與第四名；中



國、日本、南韓與澳大利亞四國進口額合計佔 47.78%，為前幾大進口來源地區。在磚瓦瓷類進口方面，日本、中國、歐洲區域及美國進口額分別佔總進口額的 25.04%、22.06%、14.30% 及 13.69%，位居前四名；中國、日本、南韓、歐洲地區及美國合計佔 79.58%，為最主要進口來源地區。瀝青類進口方面，日本、美國及南韓進口額分別佔 55.59%、14.34% 及 9.59%，排名前三；中國、日本、南韓及美國四國進口額合計高達 84.57%，為最大宗進口來源地區。上述美元、日圓、歐元、英鎊、澳幣、韓元及人民幣等貨幣，不僅為國際主要交易貨幣，亦與台灣營建材料進口有密切關聯。此外，澳大利亞為全球鐵礦砂等原料出口大國。中國、日本及韓國與台灣均有頻繁經貿往來。因此，本研究的匯率候選源域包括美元兌新台幣 (USDTWD)、歐元兌新台幣 (EURTWD)、英鎊兌新台幣 (GBPTWD)、人民幣兌新台幣 (CNYTWD)、澳幣兌新台幣 (AUDTWD)、新台幣對日圓 (TWDJPY) 及新台幣對韓元 (TWDKRW) 等七種匯率。

3.3.3 決選源域

源域預選完成之後，便可以利用第一步驟—確定選擇方法之 14 種源域選擇方法衡量預選源域與目標域之間的相似程度，並以多數決的投票機制決定最終源域。舉例而言，若營造工程物價總指數在 14 種衡量方法中有 9 種方法顯示營造工程物價總指數與新台幣兌日圓之相似程度最高，則依照多數決之投票機制，營造工程物價總指數之最終源域即為新台幣兌日圓之匯率。

3.4 資料集建立與處理

源域以及目標域定義完成後，便能夠依據源域以及目標域分別建立其資料集，並進行相應的資料處理，如圖 3.4 所示。

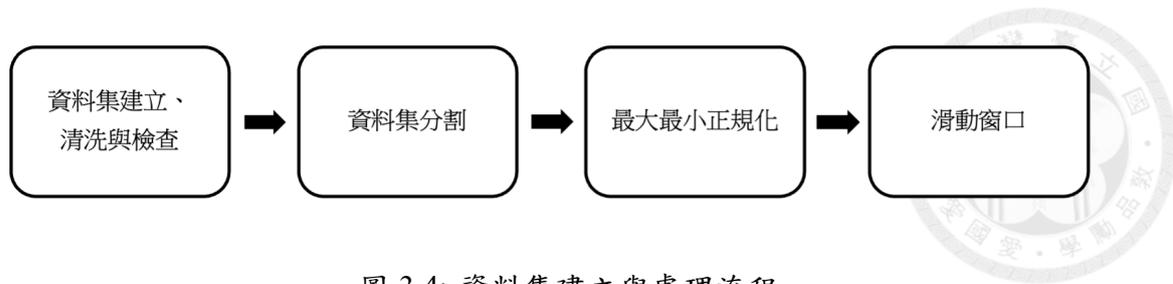


圖 3.4: 資料集建立與處理流程

3.4.1 源域資料集建立

匯率為本研究採用之源域資料，但是其在時間框架（Timeframe）方面有諸多選擇，例如 1 分鐘、5 分鐘、30 分鐘、1 天、1 週等多個時間框架。當時間框架為 1 分鐘時，表示每 1 分鐘便有一筆資料。Velay and Daniel[59] 發現利用 LSTM 檢測股價變化模式時 30 分鐘的時間框架最為適合，且本研究為盡量取得足夠多的資料，因此採用 30 分鐘的時間框架，表示每 30 分鐘有一筆資料。但 30 分鐘時間框架之資料變化幅度小且能夠取得資料之回溯年度有限，且過去預測股價、匯率之相關文獻多以 1 天之時間框架為主，因此加入 1 天的時間框架進行比較。原始之匯率資料包含開盤價、最高價、最低價、收盤價、成交量等五個變數。除此之外，本研究為引入時間性，因此在輸入特徵中加入時間資訊，包含年、月、日、小時、分鐘等五個時間相關之特徵。不僅如此，過往預測股價、匯率之文獻中，常用技術分析指標作為其特徵，例如，Goutte et al. [56] 使用開盤價、收盤價、最高價、最低價、交易量、蠟燭圖、相對強弱指標、簡單移動平均、指數平滑異同移動平均線、威廉指標、隨機指標等特徵，利用多種機器學習與深度學習模型預測股價；Lin et al.[33] 使用移動平均、指數平滑異同移動平均線、布林通道、動量指標等四種技術分析指標與其他多種特徵，利用生成對抗網路預測股價。本研究為了取得更優良之預測表現而擴展資料集，使用股票市場以及過往文獻中常見的 11 種技術分析指標，包含簡單移動平均（Simple Moving Average, SMA）[32, 33, 53, 54, 56, 86, 87]、指數移動平均（Exponential Moving

Average, EMA) [31, 32, 53, 54]、加權移動平均 (Weighted Moving Average, WMA) [32, 53, 87, 88]、相對強弱指標 (Relative Strength Index, RSI) [27, 32, 53, 56, 87, 89]、隨機指標 (Stochastic Oscillator, KD) [27, 56, 87, 89]、指數平滑異同移動平均線 (Moving Average Convergence Divergence, MACD) [27, 32, 33, 53, 54, 56, 87, 89]、乖離率 (Bias Ratio, BIAS)、動量指標 (Momentum) [27, 31, 33, 54, 87]、威廉指標 (Williams %R) [32, 53, 56, 87, 89]、布林通道 (Bollinger Bands) [33, 54]、唐奇安通道 (Donchian Channel)。技術分析指標說明如下。

表 3.3: 源域資料集之技術分析指標

技術分析指標
簡單移動平均 (Simple Moving Average, SMA)
指數移動平均 (Exponential Moving Average, EMA)
加權移動平均 (Weighted Moving Average, WMA)
相對強弱指標 (Relative Strength Index, RSI)
隨機指標 (Stochastic Oscillator, KD)
指數平滑異同移動平均線 (Moving Average Convergence Divergence, MACD)
乖離率 (Bias Ratio, BIAS)
動量指標 (Momentum)
威廉指標 (Williams %R)
布林通道 (Bollinger Bands)
唐奇安通道 (Donchian Channel)

- 簡單移動平均線 (Simple Moving Average, SMA) 是在特定時間對價格進行簡單平均計算。一般透過多條週期不同之 SMA 進行比較，以決定進出場點。

$$SMA = \frac{P_1 + P_2 + \dots + P_n}{n} \quad (3.1)$$

其中 P_n 表示第 n 個價格。 n 為計算平均之週期。

- 指數移動平均線 (Exponential Moving Average, EMA) 是在特定時間對價格進行指數平均。其更重視最近之股價變化，因此最近股價之權重較大。一般

透過多條週期不同之 EMA 進行比較，以決定進出場點。

$$EMA_n = (Close - EMA_{n-1}) \times Multiplier + EMA_{n-1} \quad (3.2)$$

其中 *Multiplier* 為平滑指數，通常為 $\frac{2}{N+1}$ ，*N* 表示計算期數。 EMA_{n-1} 表示前一期的 EMA。*Close* 表示當前的收盤價。

- 加權移動平均線 (Weighted Moving Average, WMA) 是在特定時間對價格進行加權平均。其對最近之股價變化較為敏感，因為最近股價之權重較大。相反的，對於歷史股價的變化則較不敏感。一般透過多條週期不同之 WMA 進行比較，以決定進出場點。

$$WMA = \frac{w_1 \times P_1 + w_2 \times P_2 + \dots + w_n \times P_n}{w_1 + w_2 + \dots + w_n} \quad (3.3)$$

其中， w_i 表示第 *i* 個價格 P_i 的權重。

- 相對強弱指標 (Relative Strength Index, RSI) 主要用於判斷價格變化速度之快慢與變化幅度之大小。RSI 透過計算計算一段時間內股價漲跌之變化，判斷趨勢屬於上漲 (多) 或是下跌 (空)。RSI 值越大表示在此期間上漲機率較大；相反的，RSI 值越小表示在此期間下跌機率較大。RSI 值的範圍介於在 0-100 之間。一般 RSI 值以 70、30 做區分 (或 80、20)，當 RSI 值等於或大於 70 時，表示價格被超買或高估；當 RSI 數值小於或等於 30 時，表示價格被超賣或低估。其計算公式如下。

$$RS = \frac{\text{Average Gain}}{\text{Average Loss}} \quad (3.4)$$

$$RSI = 100 - \frac{100}{1 + RS} \quad (3.5)$$

其中， RS 表示一定期間內之絕對漲幅除以一定期間內之絕對跌幅。

- 隨機指標 (Stochastic Oscillator, KD) 主要用於判斷股價之強弱。隨機指標由 K 值與 D 值組合，以這兩個值判斷目前價格相對於過去一段期間價格的高低變化，即可呈現當天價格目前處於相對高點或低點位置。要計算隨機指標需先計算未成熟隨機值 (Raw Stochastic Value, RSV)，RSV 表示目前收盤價與最近 n 天最高價接近的程度，即是指目前股價與過去 n 天相比屬於強勢或弱勢。其公式如下。

$$RSV = \frac{Close_{today} - Low_n}{High_n - Low_n} \times 100 \quad (3.6)$$

其中， Low_n 與 $High_n$ 表示過去 n 個時期的最低價格與最高價格。如果 RSV 大於 100 表示今日價格大於等於近 n 天的最高價。如果 RSV 小於 100 表示今日價格小於近 n 天的最高價。接著， K 值與 D 值得計算公式如下。

$$K_{today} = K_{yesterday} \times \frac{2}{3} + RSV_{today} \times \frac{1}{3} \quad (3.7)$$

$$D_{today} = D_{yesterday} \times \frac{2}{3} + K_{today} \times \frac{1}{3} \quad (3.8)$$

透過公式可以了解到， K 值會緊隨最近的價格，因此變動的較快，又稱為快線； D 值則會動的較慢，因此又稱為慢線。

- 指數平滑異同移動平均線 (Moving Average Convergence Divergence, MACD) 是計算兩條週期不同的平滑移動平均線 (EMA) 的差離值 (Difference, DIF)，接著再對差離值做指數平滑移動平均，此即為 MACD 線。主要用以判斷價格趨勢。

$$DIF = EMA_n - EMA_m \quad (3.9)$$

$$signal = EMA\{DIF\} \quad (3.10)$$

計算 MACD 時，需先計算差離值，其是長天期與短天期之指數移動平均的相減，表示短天期價格偏離長天期價格的情形。接著再將差離值進行指數移動平均，就會得出訊號線 (Signal)。差離值對價格變動的反應較為迅速，因其只經過一次指數移動平均，因此又稱為快線；訊號線對價格變動反應較為遲緩，因其經過兩次指數移動平均，因此又稱為為慢線。

- 乖離率 (Bias Ratio, BIAS) 表示目前價格水平偏離移動平均線的程度。其計算方式為價格與移動平均線之間的距離程度，即當前價格減去移動平均線值的差。乖離率主要是用來分析是否超買或超賣。

$$BIAS = \frac{P_{now} - MA}{MA} \times 100 \quad (3.11)$$

P_{now} 表示當前價格， MA 表示移動平均。

- 動量指標 (Momentum) 是比較目前價格與 n 日前的價格，主要用於判斷市場的走勢強弱。

$$MOM = \frac{P_{now} - P_n}{P_n} \times 100 \quad (3.12)$$

P_n 表示 n 日以前的價格。

- 威廉指標 (Williams %R) 透過比較價格是否處於超買或超賣的現象，以衡量動量的震盪指標。

$$Williams\%R = \frac{P_{now} - High_n}{High_n - Low_n} \times 100 \quad (3.13)$$

其中， P_{now} 表示當前價格； $High_n$ 與 Low_n 表示過去 n 日的最高價與最低價。

- 
- 布林通道 (Bollinger Bands) 透過判斷價格波動的趨勢和幅度，以幫助交易者確定買賣時機。布林通道主要由三條線組成，分別是：
 - 上通道 (Upper Band)：取一定時期的移動平均線，再加上一定倍數的標準差，通常是取兩倍標準差。
 - 中線 (Middle Band)：即移動平均線，通常是 20 個週期的簡單移動平均。
 - 下通道 (Lower Band)：取一定時期的移動平均線，再減去一定倍數的標準差，通常是取兩倍標準差。

 - 唐奇安通道 (Donchian Channel) 與布林通道類似，透過判斷價格波動的趨勢和幅度，以幫助交易者確定買賣時機。唐奇安通道主要由三條線組成，分別是：
 - 上通道線 (Upper Channel Line)：由最近 n 日的最高價組成，其值等於過去一定時期內的最高價。
 - 中間線 (Midline)：是上通道線和下通道線的中間值，可以是簡單移動平均線、指數移動平均線或其他類型的平均線。
 - 下通道線 (Lower Channel Line)：由最近 n 日的最低價組成，其值等於過去一定時期內的最低價。

本研究使用的源域資料集中各個技術分析指標所採用的參數如表3.4所示。這些設定參數是透過回顧過往文獻並經討論後決定的。以 30 分鐘時間框架日圓匯率的簡單移動平均 (SMA) 為例，表3.4中的參數 3 表示使用 3 個時間段的資料進行簡單平均；5 表示使用 5 個時間段的資料進行簡單平均，以此類推。這些參數即為公式3.1以及各個技術分析指標公式中的 n 。因此，表3.4中的每一個數字或一組

數字（由小括號刮起來的稱為一組）代表了一個特定技術分析指標的參數設定。例如，表3.4中有 5 個簡單移動平均（SMA）的參數，表示使用了 5 條不同參數設定的簡單移動平均線作為特徵。

最終，源域資料集的輸入特徵將包含：匯率原始資料（開盤價、最高價、最低價、收盤價、成交量）、時間性特徵（年、月、日、小時、分鐘）、11 種技術分析指標（包含多個不同參數設定）。由於技術分析指標的參數眾多，最終全部輸入特徵共計有 59 個。這些豐富的特徵有助於提升模型的預測能力。

表 3.4: 源域資料集技術分析指標設定參數

技術指標	參數
簡單移動平均 (Simple Moving Average, SMA)	3, 5, 9, 10, 20
指數移動平均 (Exponential Moving Average, EMA)	3, 5, 9, 10, 20
加權移動平均 (Weighted Moving Average, WMA)	3, 5, 9, 10, 20
相對強弱指標 (Relative Strength Index, RSI)	6, 12
隨機指標 (Stochastic Oscillator, KD)	(fast k period, slow k period, slow d period) (14, 9, 12), (12, 3, 6), (9, 3, 3)
指數平滑異同移動平均線 (Moving Average Convergence Divergence, MACD)	(fast period, slow period, signal period) (12, 26, 9), (9, 12, 9), (6, 12, 3)
乖離率 (Bias Ratio, BIAS)	3, 5, 10, 20, 30
動量指標 (Momentum)	10, 25
威廉指標 (Williams %R)	3, 6, 12, 14, 24
布林通道 (Bollinger Bands)	n = 20
唐奇安通道 (Donchian Channel)	n = 20

3.4.2 目標域資料集建立

本研究之目標域有營造工程物價總指數、水泥及其製品類指數、以及金屬製品類指數。本研究將就各個指數建立兩種目標域資料集，第一種目標域資料集是使用與源域資料集相同的技術分析指標，本研究稱為技術分析指標資料集（資料

集一)；第二種目標域資料集是利用過往文獻使用之各種經濟指標，本研究稱為經濟指標資料集(資料集二)。透過使用兩種不同的資料集，便能夠比較哪一種資料集較適合用於預測營建物價指數。此外，本研究為引入時間性，並與源域資料集之時間性對齊，因此在輸入特徵中加入時間資訊，包含年、月、日、小時、分鐘等五個時間相關之特徵。

首先，技術分析指標資料集採用之技術分析指標，將與源域資料集採用之 11 種常見技術分析指標相同，但為了符合其資料特性，因此在參數設定上會略有不同。此外，本研究之目標域技術分析指標資料集除了使用上述 11 種技術分析指標之外，也加入營造工程物價總指數以及四種權重較大之材料類中分類指數，包含水泥及其製品類指數、金屬製品類指數、機電設備類指數、以及雜項類指數等。本研究於技術分析指標資料集中各個技術分析指標所使用的設定參數如表 3.5 所示。以營造工程物價總指數的簡單移動平均(SMA)為例，表 3.5 中的參數 3 表示使用 3 個月的資料進行簡單平均；5 表示使用 5 個月的資料進行簡單平均，以此類推。這些參數即為公式 3.1 以及各個技術分析指標公式中的 n 。因此，表 3.5 中的每一個數字或一組數字(由小括號刮起來的稱為一組)代表了一個特定技術分析指標的參數設定。例如，表 3.5 中有 5 個簡單移動平均(SMA)的參數，表示使用了 5 條不同參數設定的簡單移動平均線作為特徵。

最終，技術分析指標資料集的輸入特徵將包含：營造工程物價總指數、水泥及其製品類指數、金屬製品類指數、機電設備類指數、雜項類指數、時間性特徵(年、月、日、小時、分鐘)、11 種技術分析指標(包含多個不同參數設定)。由於技術分析指標的參數眾多，最終全部輸入特徵共計有 59 個。這些豐富的特徵有助於提升模型的預測能力。

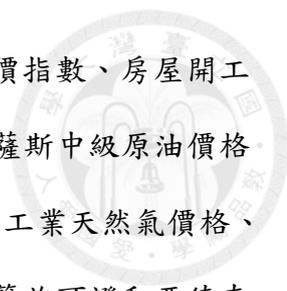
其次，在經濟指標資料集方面，過往預測營建物價之相關文獻中共使用 43 種

表 3.5: 目標域資料集技術分析指標設定參數

技術指標	參數
簡單移動平均 (Simple Moving Average, SMA)	3, 6, 9, 12, 24
指數移動平均 (Exponential Moving Average, EMA)	3, 6, 9, 12, 24
加權移動平均 (Weighted Moving Average, WMA)	3, 6, 9, 12, 24
相對強弱指標 (Relative Strength Index, RSI)	6, 12
隨機指標 (Stochastic Oscillator, KD)	(fast k period, slow k period, slow d period) (14, 9, 12), (12, 3, 6), (9, 3, 3)
指數平滑異同移動平均線 (Moving Average Convergence Divergence, MACD)	(fast period, slow period, signal period) (12, 26, 9), (9, 12, 9), (6, 12, 3)
乖離率 (Bias Ratio, BIAS)	3, 6, 9, 12, 24
動量指標 (Momentum)	10, 25
威廉指標 (Williams %R)	3, 6, 12, 14, 24
布林通道 (Bollinger Bands)	n = 12
唐奇安通道 (Donchian Channel)	n = 20

變數，可以分為能源（3種）、原物料（1種）、總體經濟指標（18種）、市場條件（11種）、股票市場（9種）與其他（1種）等六類。如表 3.6 所示。原物料無論需經過進出口或是加工，往往需要使用一定比例的能源，因此能源價格包含石油、天然氣以及煤炭；原物料方面主要是煉鋼所需之鐵礦石原料；總體經濟指標反映國家內整體經濟環境之處境，因此過往文獻使用了包含消費者物價指數、生產者物價指數等 18 個指標；市場條件反映目前市場就業水準、供給與需求等內容，因此包含個人收入、就業人數等；股票市場能夠反映國際市場之狀況；最後，查詢頻率能夠即時反映當前市場對於各個材料之供給與需求狀況。

過往亦有文獻探討哪些變數為預測營建物價之先行指標，例如 Ashuri et al.[90] 之研究結果顯示消費者物價指數、原油價格、生產者物價指數、國內生產毛額、建築業就業水準、建築許可數、新屋開工數量和貨幣供應量是營造成本指數的先行指標，其中，貨幣供應量和原油價格更是與營建物價存在長期關係的



先行指標。Faghih and Kashani[21] 之研究結果則顯示消費者物價指數、房屋開工數、工業生產者物價指數、鐵礦石價格、建築許可證和西德克薩斯中級原油價格 (WTI) 可能有助於預測未來的瀝青價格；而消費者物價指數、工業天然氣價格、住房開工、個人收入、工業生產者物價指數、鐵礦石價格、建築許可證和西德克薩斯中級原油價格 (WTI) 可能有助於預測未來的鋼鐵價格；就業率、國內生產毛額、住房開工、勞工每小時工資、建築許可證和建築支出被認為可能有助於預測未來水泥價格。Cao et al.[44] 使用 17 個影響因素作為初始輸入特徵以預測台灣之營造工程物價指數，包含躉售物價指數、消費者物價指數、五大銀行貸款利率、美元兌新台幣匯率、領先指標、同步指標、落後指標、製造業新訂單指數、台灣加權股票指數、國際油價、納斯達克綜合指數、美國道瓊工業平均指數、新加坡海峽時報指數、泰國 SET 股票指數、東京日經指數 NK-225、香港恆生指數、韓國加權股票指數、營造工程物價指數等。

本研究為確保有足夠之指標與資料量用於微調與測試，因此將從這些變數中以 2003 年始能取得之台灣的資料建立本研究目標域之經濟指標資料集。最終取得之指標及其來源如表 3.7 與表 3.8 所示，共 53 種，可分為能源 (4 種)、總體經濟指標 (20 種)、市場條件 (10 種)、股票市場 (9 種)、以及營造工程物價指數之材料類中分類指數 (10 種) 等六類。最終，經濟指標資料集的輸入特徵將包含：營造工程物價總指數、53 種經濟指標、時間性特徵 (年、月、日、小時、分鐘)，最終全部輸入特徵共計有 59 個。這些豐富的特徵有助於提升模型的預測能力。

3.4.3 資料集分割

機器學習主要可分為兩個階段，分別是訓練階段以及測試階段。訓練階段主要目的是尋找參數 (或稱為權重)，使得訓練後的模型能夠符合資料特性，而用於尋找參數之資料集稱為訓練集。其次，為了避免參數過度擬合於訓練集，因此在

表 3.6: 過往文獻使用之變數

分類	候選變數	文獻
能源	石油	[7, 21, 41-44, 84, 85, 90-92]
能源	天然氣	[21, 41, 92]
能源	煤炭	[91, 92]
原物料	鐵礦石	[21, 41, 91, 92]
總體經濟指標	消費者物價指數	[12, 21, 40, 41, 43, 44, 84, 90]
總體經濟指標	生產者物價指數	[21, 40-42, 90]
總體經濟指標	就業率	[21, 41]
總體經濟指標	失業率	[40, 90]
總體經濟指標	國內生產毛額	[21, 40, 41, 90]
總體經濟指標	國內生產毛額平減指數	[90]
總體經濟指標	貨幣供應 (M2)	[40, 84, 85, 90]
總體經濟指標	匯率	[40, 42, 44, 84, 85, 92]
總體經濟指標	外匯儲備	[40]
總體經濟指標	國家政策利率	[90]
總體經濟指標	營建物價指數	[12, 23, 44]
總體經濟指標	躉售物價指數	[43, 44, 84, 85]
總體經濟指標	領先指標	[43, 44, 84, 85]
總體經濟指標	同時指標	[43, 44, 84, 85]
總體經濟指標	落後指標	[43, 44, 84, 85]
總體經濟指標	製造業新訂單指數	[43, 44]
總體經濟指標	進口物價指數	[42, 84, 85]
總體經濟指標	出口物價指數	[84, 85]
市場條件	勞工成本	[92]
市場條件	材料價格	[9]
市場條件	黃金價格	[84, 85]
市場條件	建築支出	[21, 41, 90]
市場條件	主要貸款利率	[39, 40, 43, 44, 90]
市場條件	新屋開工數量	[21, 39, 41, 90]
市場條件	建築許可證數量	[21, 41, 90]
市場條件	個人收入	[21, 41]
市場條件	建築工人每小時收入	[21, 41]
市場條件	建築業就業人數	[21, 41, 90]
市場條件	建築業每週工時	[90]
股票市場	台灣加權股票指數	[43, 44, 84, 85]
股票市場	台灣指數期貨	[84, 85]
股票市場	道瓊工業平均指數	[44, 90]
股票市場	那斯達克綜合指數	[43, 44]
股票市場	東京日經指數	[43, 44]
股票市場	韓國加權股票指數	[43, 44]
股票市場	香港恆生指數	[43, 44]
股票市場	新加坡海峽時報指數	[43, 44]
股票市場	泰國 SET 股票指數	[43, 44]
其他	查詢頻率	[38, 42]



表 3.7: 經濟指標資料集 (1)

分類	名稱	資料來源
能源	西德州原油 (WTI) 價格	經濟部統計處
	布蘭特原油 (Brent Crude) 價格	經濟部統計處
	杜拜原油 (Dubi) 價格	經濟部統計處
	OPEC 原油價格	經濟部統計處
總體經濟指標	消費者物價指數	行政院主計總處
	國內生產毛額 (GDP)	行政院主計總處
	GDP 平減指數	行政院主計總處
	失業率	行政院主計總處
	勞動參與率	行政院主計總處
	貨幣供應 (M1A)	中央銀行
	貨幣供應 (M1B)	中央銀行
	貨幣供應 (M2)	中央銀行
	外匯儲備	中央銀行
	匯率 (美元)	Tradingview
	匯率 (歐元)	Tradingview
	國家政策利率 (重貼現率)	中央銀行
	領先指標	國家發展委員會景氣指標查詢系統
	領先指標不含趨勢指數	國家發展委員會景氣指標查詢系統
	同時指標	國家發展委員會景氣指標查詢系統
	同時指標不含趨勢指數	國家發展委員會景氣指標查詢系統
	落後指標	國家發展委員會景氣指標查詢系統
	落後指標不含趨勢指數	國家發展委員會景氣指標查詢系統
	進口物價指數	行政院主計總處
出口物價指數	行政院主計總處	



表 3.8: 經濟指標資料集 (2)

分類	名稱	資料來源
市場條件	勞工成本 (營造工程物價指數-工資類)	行政院主計總處
	個人收入	行政院主計總處薪資平台
	營建工人每小時收入	行政院主計總處薪資平台
	砂石行業每小時收入	行政院主計總處薪資平台
	工業與服務業每小時收入	行政院主計總處薪資平台
	營建工程業就業人數	行政院主計總處薪資平台
	營建工程業每月總工時	行政院主計總處薪資平台
	建築許可證 (以樓地板面積計算)	內政部統計處
	主要貸款利率 (五大銀行平均基準利率)	中央銀行
	黃金價格	Tradingview
股票市場	臺灣加權股價指數	Tradingview
	臺灣加權股價指數期貨	Tradingview
	道瓊工業平均指數	Tradingview
	納斯達克綜合指數	Tradingview
	東京日經平均指數 NK-225	Tradingview
	韓國綜合股票指數	Tradingview
	香港恆生指數	Tradingview
	新加坡海峽時報指數	Tradingview
	泰國 SET 股票指數	Tradingview
營造工程物價指數	(一) 水泥及其製品類	行政院主計總處
	(二) 砂石及級配類	行政院主計總處
	(三) 磚瓦瓷類	行政院主計總處
	(四) 金屬製品類	行政院主計總處
	(五) 木材及其製品類	行政院主計總處
	(六) 塑膠製品類	行政院主計總處
	(七) 油漆塗裝類	行政院主計總處
	(八) 機電設備類	行政院主計總處
	(九) 瀝青及其製品類	行政院主計總處
	(十) 雜項類	行政院主計總處

每次調整權重後，會藉由另一個資料集進行驗證，此一資料一般稱為驗證集。測試階段則是讓訓練後的模型讀取未學習過的資料，以進行模型表現的最終評估，此一資料通常稱為測試集。一般機器學習會以一定比例隨機分割資料集，然而，本研究之營造工程物價指數為時間序列資料，其中各觀測點與其時間點、相連之觀測點具有關聯性。因此資料集分割必須依照時間性排列以一定比例進行分割。

首先，源域資料集之分割比例如圖 3.5 所示，源域訓練集佔整體源域資料集之前面 64%；源域驗證集為訓練集後，整體源域資料的 16%；最後，源域測試集為整體源域資料集之最後 20%。

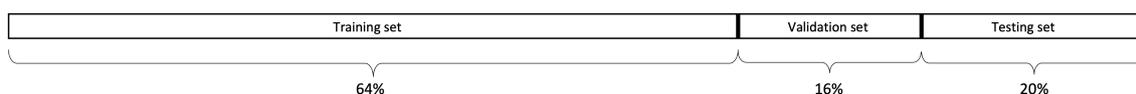


圖 3.5: 源域資料集分割比例

其次，目標域資料集分割的部分，經濟指標資料集自 2003 年至 2023 年底只有 251 筆資料，而技術分析指標資料集自 1993 年至 2023 年底共有 396 筆資料。為了確保目標域之訓練集有足夠資料進行訓練，並確定測試集有相同大小與時間段，以利進行結果比較。因此，本研究之目標域資料集以經濟指標資料集為準，經濟指標資料集之訓練集佔整體資料集之 69%；驗證集為接續之 17%；測試集為最後之 14%。若以時間段來看的話，如圖 3.6 所示。經濟指標資料集之訓練集為 2003 年 1 月至 2017 年 5 月；驗證集為 2017 年 6 月至 2020 年 12 月；測試集為 2021 年 1 月至 2023 年 11 月。而技術分析指標資料集之訓練集為 1993 年 1 月至 2015 年 6 月；驗證集為 2015 年 7 月至 2020 年 12 月；測試集為 2021 年 1 月至 2023 年 11 月。

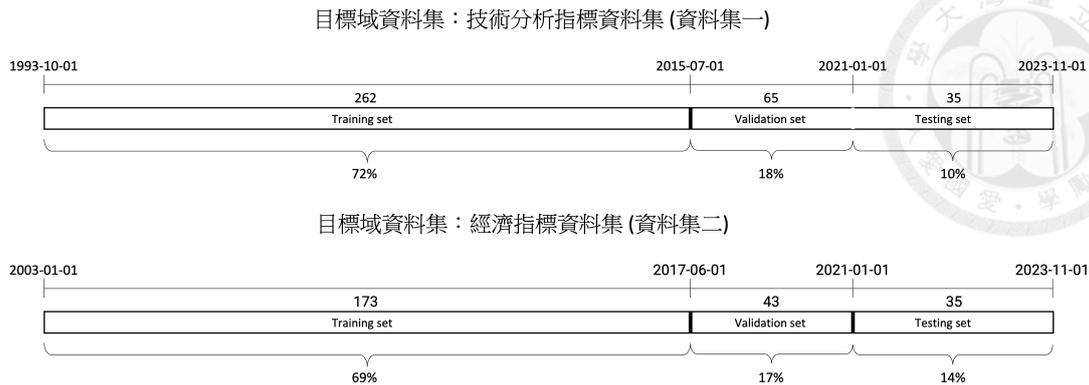


圖 3.6: 目標域資料集分割

3.4.4 最大最小正規化

資料集分割完成之後，在模型訓練之前，應進行資料正規化 (Normalization)，使所有特徵具有相同的尺度，以幫助模型訓練。此步驟需在資料集分割完成後，以避免測試集摻雜訓練集之資訊，造成資料外洩之問題。本研究採用之正規化方法，為時間序列預測中最常見之最大最小正規化 (Min-max Normalization)。最大最小正規化是種常見的資料正規化方法，其將資料的特徵值轉換為一個特定範圍內 $[0, 1]$ ，以確保所有特徵具有相似的尺度。這有助於模型更好地處理資料，並提高模型的性能和穩定性。

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3.14)$$

3.4.5 滑動窗口技術

營建物價為時間序列資料，其中各觀測點與其時間點、相連之觀測點具有關聯性。為了考量資料之時間性，因此運用滑動窗口 (Sliding Window) 技術。滑動窗口透過新增新的資料並刪除舊的資料，以捕捉最近資料的模式 [93–95]。此外，收集大量資料通常所費不貲且耗費時間，且大量的歷史資料也會導致資料管理困

難，並導致計算複雜度的提高，因此使用大量資料訓練模型通常是不可行的。然而，無論何時移動窗口，資料密度或滑動窗口的大小都保持不變。因此，滑動窗口技術能夠限制用於訓練模型的資料量，同時保留了模型的效率和普遍適用性 [96]。Chou and Truong[96] 指出滑動窗口大小為 12 個月時的預測性能最佳。因此本研究之滑動窗口大小設置為 12。而為了盡可能捕捉各觀測點之間的關係，因此移動步長設置為 1。

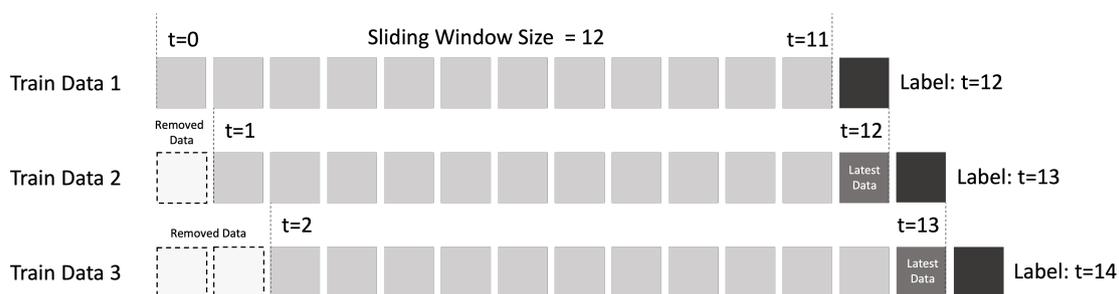


圖 3.7: 滑動窗口示意圖

滑動窗口主要操作如圖 3.7 所示。首先，當預測未來一筆資料時，第一筆訓練資料為 $t = 0$ 至 $t = 11$ 共 12 筆特徵資料，而標籤則是 $t = 12$ 的資料；接著，因為本研究之移動步長設置為 1，因此當讀取第二筆訓練資料時，其特徵資料是從 $t = 1$ 至 $t = 12$ 的 12 筆特徵資料，而標籤則是 $t = 13$ 的資料；接著，當讀取第三筆訓練資料時，其特徵資料是從 $t = 2$ 至 $t = 13$ 的 12 筆特徵資料，而標籤則是 $t = 14$ 的資料，後續便以此類推。透過這種方式處理資料，便能夠達到 [93-95] 中所說的捕捉資料最近的模式，並且能夠維持模型的效率與泛化性 [96]。表 3.9 顯示本研究使用的資料集、其時間框架以及特徵數量。

3.5 預訓練模型與微調

本研究採用的遷移學習方法為預訓練與微調。一般在電腦視覺任務或自然語言處理任務中使用的預訓練模型通常是由過去研究所公開的模型。然而，本研究

表 3.9: 資料集整理

域	資料集	時間框架	特徵類別	特徵數量	滑動窗口大小
源域	源域資料集 1	30 分鐘	匯率原始資料 時間特徵 技術分析指標	59	12
	源域資料集 2	1 天	匯率原始資料 時間特徵 技術分析指標		
目標域	技術分析指標 資料集	1 個月	營造工程物價總指數 水泥及其製品類指數 金屬製品類指數 機電設備類指數 雜項類指數 時間性特徵 技術分析指標		
	經濟指標資料集	1 個月	營造工程物價總指數 時間性特徵 經濟指標		

的營造工程物價指數屬於時間序列，不同時間序列具有獨特特性，因此無法直接套用公開的預訓練模型。因此，本研究先以與營造工程物價指數相似的源域資料集預先訓練一個模型，即本研究所稱之預訓練模型。接著在微調階段，本研究首先保持預訓練模型的參數不變，這意味著模型初始權重並非隨機初始化，而是使用預訓練模型的權重。隨後，我們利用資料量較少的營造工程物價指數資料對預訓練模型進行再次訓練，本研究將此利用目標域資料集再次訓練預訓練模型的過程稱為微調。

本節將會針對本研究使用之深度學習模型、模型種類、超參數調整的方法、與評估方法進行說明。

3.5.1 建立長短期記憶模型

本研究使用之程式語言為 Python，版本為 3.9.18。電腦作業系統為 Linux 20.04。顯示卡為 NVIDIA GeForce RTX 4080 (16GB)。主機板為 AMD A620M PRO RS。深度學習模型使用 Pytorch 框架，Pytorch 版本為 2.1.2。Cuda 版本為

12.1。本研究之 LSTM 模型架構為參考過往預測股價相關文獻所用之 LSTM 架構 [27, 97]，並經本研究反覆試驗調整。本研究之 LSTM 模型架構如圖 3.8 所示，採用兩層 LSTM 層，LSTM 層之隱藏單元數量皆為 50，LSTM 層後有兩層全連接層，第一層全連接層之神經元數量為 50，第二層全連接層之神經元數量為 25。激活函數為整流線性單位函數 (Rectified Linear Unit, ReLU)，其公式如式 3.15 所示。最後全連接層之輸出為單一預測值之營造工程物價指數，例如未來第 1 個月的營造工程物價總指數。每個預測目標對應一個獨立的 LSTM 模型。例如，用於預測未來第 1 個月營造工程物價總指數的模型與用於預測未來 6 個月該指數的模型是獨立的；且用於預測未來第 1 個月營造工程物價總指數的模型與用於預測未來第 1 個月水泥及其製品類指數的模型是獨立的，而各個模型的參數調整也各不相同。這種方法使本研究能夠針對不同的預測時間範圍，採用專門優化的模型，從而提高預測準確性。此外，以預測未來第 1 個月的營造工程物價總指數為例，此預測之時間與標的是由訓練時之時間點與標的決定，若預訓練時的標籤是未來第 1 筆資料，而微調時的標籤也會是未來第 1 個月的營造工程物價總指數，則預測時的單一數值便是未來第 1 個月的營造工程物價總指數。

$$f(x) = \max(0, x) \quad (3.15)$$

本研究係利用預訓練與微調預測營造工程物價指數，以期提升機器學習預測營建物價之表現。因此本研究為比較預訓練與微調後之模型表現是否較佳，因此建立以下數種模型。

- 預訓練模型：預訓練模型係利用源域資料集進行訓練之模型，其模型架構如上一小節所述。其主要用於後續目標域資料微調時之基本模型。預訓練模型之輸入資料為時間框架為 30 分鐘之源域資料集或時間框架為 1 天之源域資

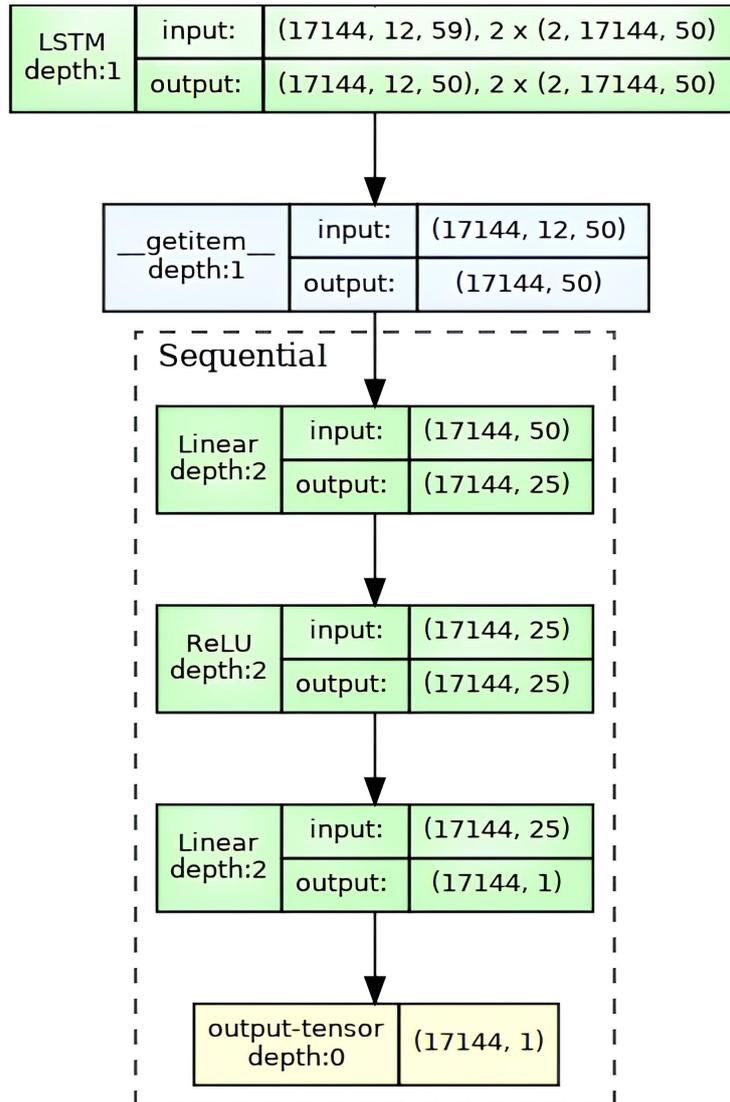


圖 3.8: 本研究長短期記憶模型架構

料集。輸出為未來第 1 筆、或第 3 筆、或第 6 筆、或第 12 筆源域資料，視後續目標域預測之時間而定。舉例來說，若目標域之輸出為未來第 1 個月之目標域資料，則預訓練模型之輸出為未來第 1 筆之源域資料。

源域資料集

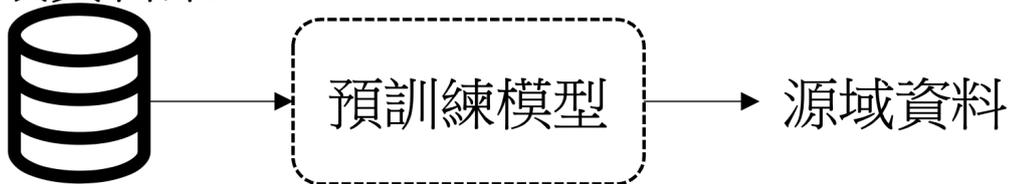


圖 3.9: 本研究預訓練模型示意圖

- Model 1：Model 1 係利用目標域資料集訓練之模型，並用於預測目標域資料。或可將 Model 1 稱為 Base Model。Model 1 的輸入資料為目標域資料集的技術分析指標資料集或經濟指標資料集。其輸出內容為未來第 1 個月、或第 3 個月、或第 6 個月、或第 12 個月的營造工程物價總指數、或水泥及其製品類指數、或金屬製品類指數。預測之指數視訓練使用之資料集為何種指數之資料集而定。舉例來說，若訓練時使用之資料集為水泥及其製品類指數之資料集，則預測內容則為水泥及其製品類指數。

目標域資料集



圖 3.10: Model 1 示意圖

- Model 2：Model 2 係直接利用預訓練模型預測目標域資料。其輸出內容為未來第 1 個月、或第 3 個月、或第 6 個月、或第 12 個月的營造工程物價總指數、或水泥及其製品類指數、或金屬製品類指數。
- Model 3：Model 3 係利用目標域資料集微調整個預訓練模型後，用於預測目

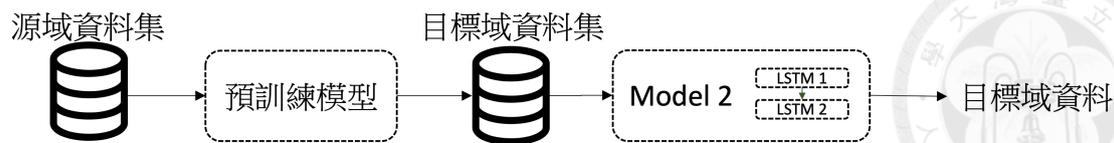


圖 3.11: Model 2 示意圖

標域資料。Model 3 的輸入資料為目標域資料集的技術分析指標資料集或經濟指標資料集。其輸出內容為未來第 1 個月、或第 3 個月、或第 6 個月、或第 12 個月的營造工程物價總指數、或水泥及其製品類指數、或金屬製品類指數。

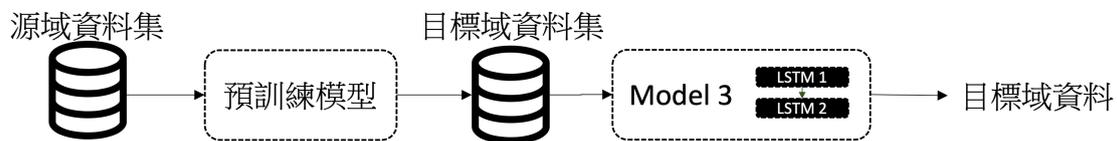


圖 3.12: Model 3 示意圖

- Model 4：Model 4 係利用目標域資料集微調預訓練模型之第二層 LSTM 層後，用於預測目標域資料。Model 4 的輸入資料為目標域資料集的技術分析指標資料集或經濟指標資料集。其輸出內容為未來第 1 個月、或第 3 個月、或第 6 個月、或第 12 個月的營造工程物價總指數、或水泥及其製品類指數、或金屬製品類指數。

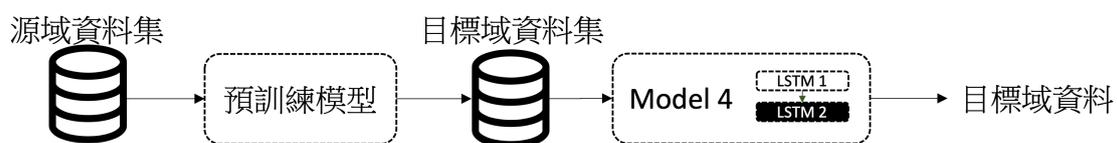


圖 3.13: Model 4 示意圖

- Model 5：Model 5 係利用目標域資料集微調預訓練模型之第一層 LSTM 層後，用於預測目標域資料。Model 5 的輸入資料為目標域資料集的技術分析指標資料集或經濟指標資料集。其輸出內容為未來第 1 個月、或第 3 個月、或第 6 個月、或第 12 個月的營造工程物價總指數、或水泥及其製品類指數、或金屬製品類指數。

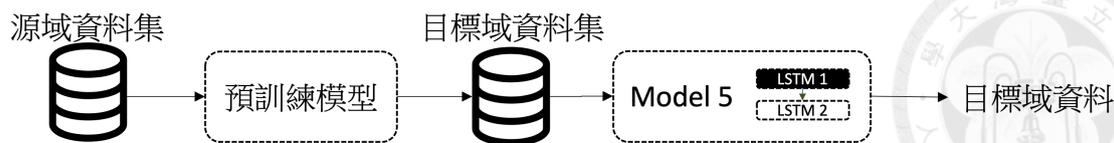


圖 3.14: Model 5 示意圖

透過比較 Model 1 以及 Model 2，能夠了解預訓練模型能否直接用於預測目標域資料。Model 2 之訓練資料中不包含任何目標域資料，因此可以預想其預測表現將會最差。透過比較 Model 1 以及 Model 3，便能了解透過預訓練與微調之遷移學習方法是否能夠提升本研究 LSTM 模型之預測表現。此外，Yosinski et al.[65] 展示了深度學習中各層遷移能力的影響。結果顯示，在圖像分類中，模型前幾層可以是共用層，但是後面幾層則無法共用，但是經過微調之後，所有層應都可以共用，且表現會提升。而在語音辨識任務通常選擇微調前幾層。本研究為了達到最佳預測表現，因此加入 Model 4 以及 Model 5，期待透過微調不同 LSTM 層再提升模型預測表現。此外，由於語音與營建物價皆屬於序列資料，因此本研究預期微調第一層 LSTM 層後之模型表現會較佳，也就是 Model 5 的表現會較突出。

總的來說，本研究之模型可參考表 3.10。本研究預訓練模型之輸入資料為時間框架為 30 分鐘之源域資料集或時間框架為 1 天之源域資料集，每一筆輸入為 12x59，表示滑動窗口大小為 12，特徵共 59 個。輸出內容視後續目標域預測之時間決定，可能是未來第 1 筆、或第 3 筆、或第 6 筆、或第 12 筆源域資料。當預測之標的物為未來第 1 個月之指數時，源域之標籤也會是未來第 1 筆資料；同樣的，當預測之標的物為未來第 3 個月之指數時，源域之標籤也會是未來第 3 筆資料，以此類推。在預測目標域資料之模型方面，Model 1、Model 3、Model 4、與 Model 5 之輸入資料為目標域之技術分析指標資料集或經濟指標資料集，每一筆輸入為 12x59，表示滑動窗口大小為 12，特徵共 59 個。Model 2 直接利用預訓練模型預測目標域資料。Model 1 至 Model 5 之輸出為未來第 1 個月、或第 3 個月、或第 6 個月、或第 12 個月的營造工程物價總指數、或水泥及其製品類指數、或金

屬製品類指數。當微調時使用之資料集為金屬製品類指數之資料集，則預測內容為金屬製品類指數，因此預測之指數是視微調使用之資料集為何種指數之資料集而定。所有模型之滑動窗口大小皆設置為 12。需要注意的是，模型之輸出皆為單一預測數值，表示每個預測目標對應一個獨立的 LSTM 模型。例如，用於預測未來第 1 個月營造工程物價總指數的模型與用於預測未來第 6 個月該指數的模型是獨立的。或是用於預測未來第 1 個月營造工程物價總指數的模型與用於預測未來第 1 個月水泥及其製品類指數的模型是獨立的。

3.5.2 超參數調整

本研究所有模型之超參數皆經過反覆試驗調整。模型優化器 (Optimizer) 為 AdamW。激活函數 (Activation Function) 為 ReLU。在學習率方面，本研究分別使用了三種動態學習率方法，包含 ReduceLRonPlateau、CosineAnnealingLR、CosineAnnealingWarmRestarts。ReduceLRonPlateau 是根據本研究設定之指標自動調降學習率，當損失不再下降 5 個回合 (Epoch) 後自動將學習率降低 0.1 倍，如圖 3.15，因為當模型訓練至後期時，會逐漸接近全局最小值 (Global Minima) 因此適當降低學習率將有助於找到全局最小值，也就是最佳解。第二，CosineAnnealingLR 是將學習率依照 Cosine 週期衰減，並直到設定週期，便又開始往上增加學習率。如圖 3.16。CosineAnnealingL 透過逐步調降，能夠避免模型陷入局部最小值，而逐步提升學習率則有助於提高深度學習模型的泛化性能。最後，CosineAnnealingWarmRestarts 與 CosineAnnealingL 相似，都是依照 Cosine 週期調整學習率，不同之處在於，CosineAnnealingWarmRestarts 在每個設定週期皆從初始學習率重新啟動學習率。如圖 3.17。

本研究也加入丟棄法 (Dropout) 避免過度擬合 [98]。丟棄法在訓練時每一回合皆以一定機率丟棄隱藏層中的神經元，而被丟棄的神經元不會傳遞資訊。因此

表 3.10: 模型種類

	輸入	輸出	是否使用預訓練模型	微調
預訓練模型	時間框架為 30 分鐘之源域資料集或時間框架為 1 天之源域資料集	未來第 1 筆、或第 3 筆、或第 6 筆、或第 12 筆源域資料	無	無
Model 1	目標域資料集之技術分析指標資料集或目標域資料集之經濟指標資料集	未來第 1 個月、或第 3 個月、或第 6 個月、或第 12 個月的營造工程物價總指數、或水泥及其製品類指數、或金屬製品類指數	無	無
Model 2	無	未來第 1 個月、或第 3 個月、或第 6 個月、或第 12 個月的營造工程物價總指數、或水泥及其製品類指數、或金屬製品類指數	是	無
Model 3	目標域資料集之技術分析指標資料集或目標域資料集之經濟指標資料集	未來第 1 個月、或第 3 個月、或第 6 個月、或第 12 個月的營造工程物價總指數、或水泥及其製品類指數、或金屬製品類指數	是	整個預訓練模型
Model 4	目標域資料集之技術分析指標資料集或目標域資料集之經濟指標資料集	未來第 1 個月、或第 3 個月、或第 6 個月、或第 12 個月的營造工程物價總指數、或水泥及其製品類指數、或金屬製品類指數	是	第二層 LSTM 層
Model 5	目標域資料集之技術分析指標資料集或目標域資料集之經濟指標資料集	未來第 1 個月、或第 3 個月、或第 6 個月、或第 12 個月的營造工程物價總指數、或水泥及其製品類指數、或金屬製品類指數	是	第一層 LSTM 層

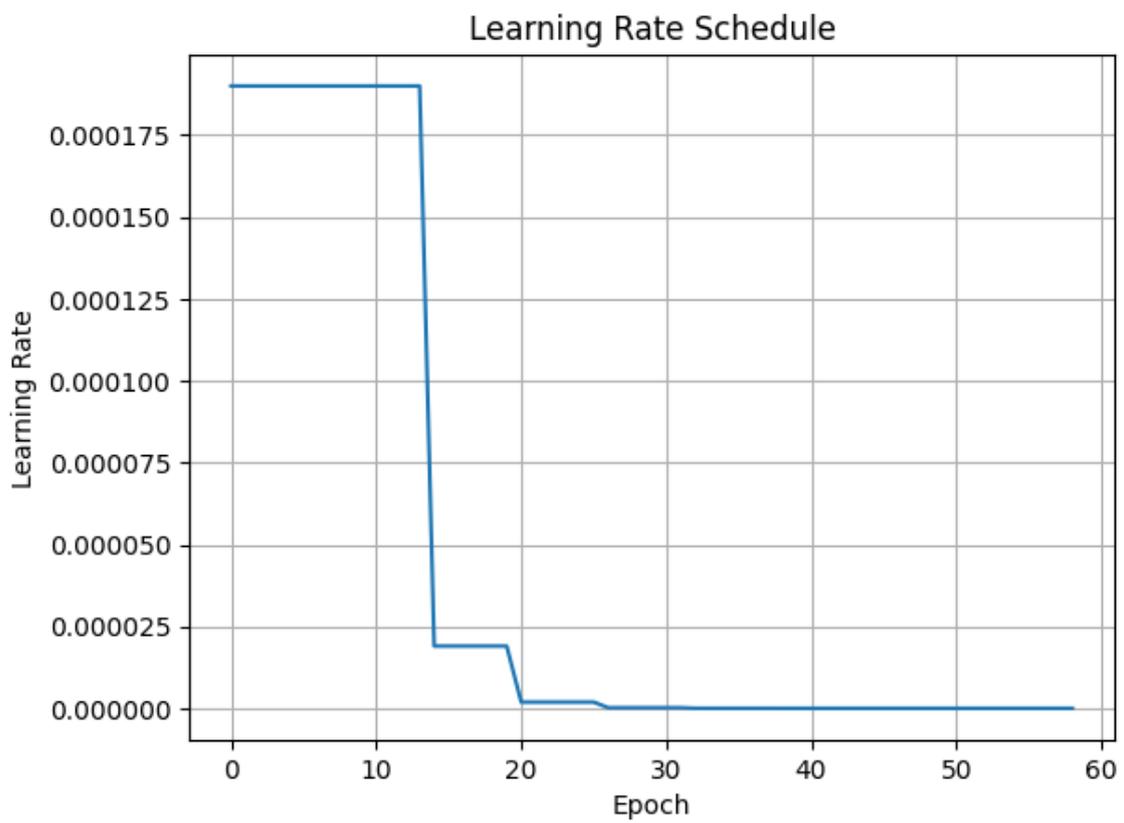


圖 3.15: ReduceLROnPlateau 示意圖

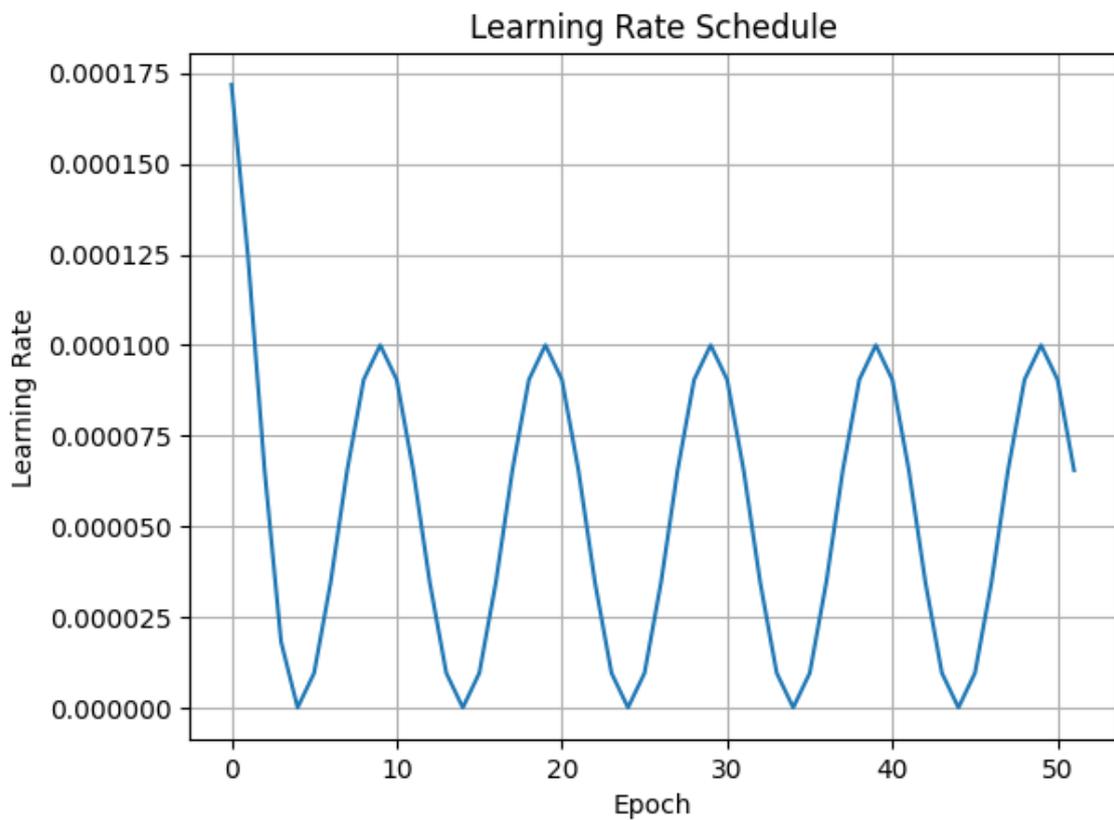


圖 3.16: CosineAnnealingLR 示意圖

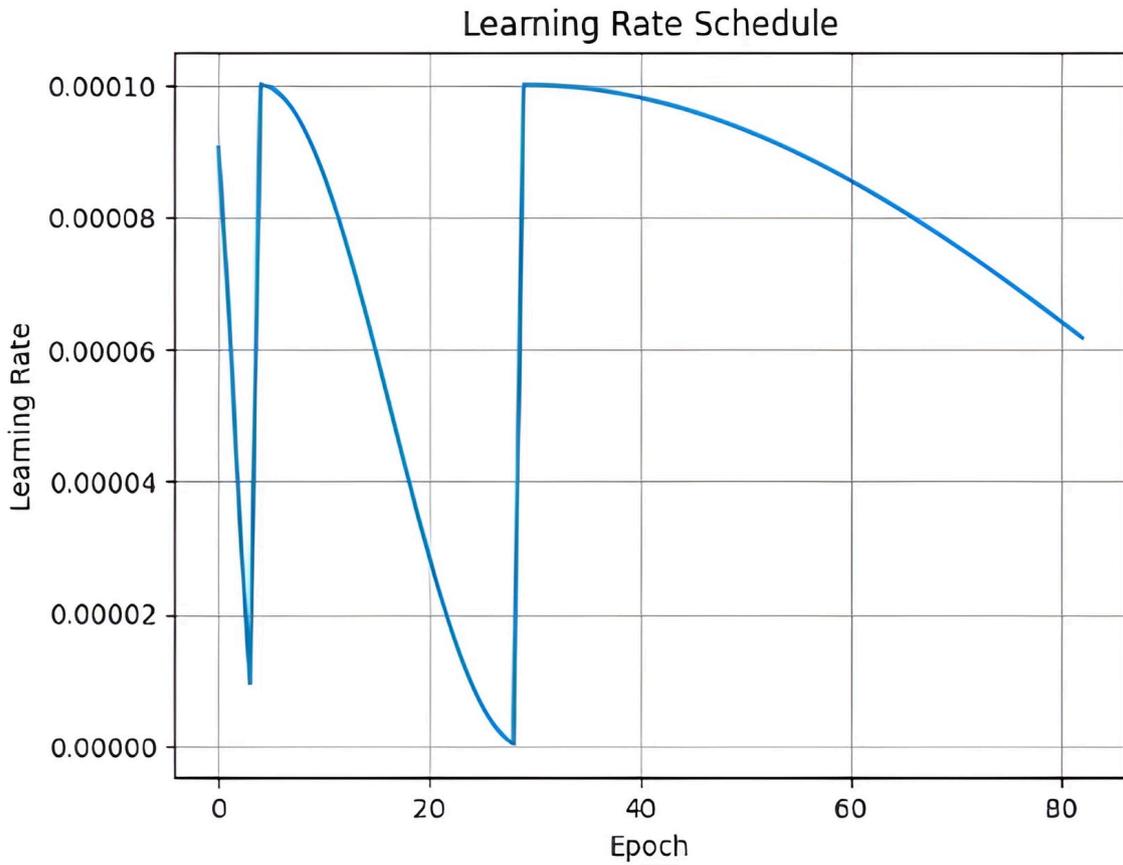


圖 3.17: CosineAnnealingWarmRestarts 示意圖

表 3.11: 模型超參數

	預訓練模型	Model 1	Model 2	Model 3	Model 4	Model 5
Optimizer	AdamW					
Activation Function	ReLU					
Batch Size	8	8	8	1	1	1
Epoch	500					
Early Stop	50					
Dropout	0.2	0.5	0.2	0.9	0.9	0.9
Learning Rate	1E-04	1E-02~1E-03	1E-04	1E-02~1E-06		
Weight Decay	1E-03	1E-02~1E-03	1E-03	1E-01~1E-02		

訓練時便不會出現過度仰賴單一神經元之狀況。藉此避免過度擬合的發生。本研究在所有模型中皆加入丟棄法，其中，預訓練模型之丟棄比例設置為 0.2，因為其資料較為豐富，較不容易過度擬合；Model 1 之丟棄比例經反覆試驗後設置為 0.5；Model 3、Model 4、Model 5 於微調中的丟棄比率則設置為 0.9，以避免因資料過少而造成過度擬合。此外，模型的整個訓練回合 (Epoch) 設置為 500，並且為了避免過度擬合，因此設置早停為 50 個回合。最後，Model 1 與 Model 2 之批次大小 (Batch Size) 經反覆試驗設置為 8；Model 3、Model 4、Model 5 之批次大小經反覆試驗設置為 1。各模型之超參數可參考表 3.11。

3.5.3 模型評估指標

本研究之模型應用於回歸任務，因此使用四種常見於回歸任務之評估指標以評估模型預測表現，包含平均絕對誤差 (Mean Absolute Error, MAE)、平均絕對百分比誤差 (Mean Absolute Percentage Error, MAPE)、均方誤差 (Mean Square Error, MSE)、均方根誤差 (Root Mean Squared Error, RMSE)。以上四種評估指標皆為越小越好。

- 平均絕對誤差 (Mean Absolute Error, MAE) 透過取絕對值計算平均誤差，避免抵銷正負誤差。但其對極值比較不敏感。

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (3.16)$$

其中， \hat{y}_i 為預測值； y_i 為真值； n 為總資料數。

- 平均絕對百分比誤差 (Mean Absolute Percentage Error, MAPE) 透過取絕對值計算平均誤差，並將誤差轉換為百分比，避免受單位影響，且其較為直

觀。但當 y 有 0 時無法使用。

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (3.17)$$

其中， \hat{y}_i 為預測值； y_i 為真值； n 為總資料數。

- 均方誤差 (Mean Square Error, MSE) 透過平方計算平均誤差，避免抵銷正負誤差。但其單位與原始資料不一致，因此解釋時較不直觀。且其因為平方的緣故，因此對於極值較為敏感。

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (3.18)$$

其中， \hat{y}_i 為預測值； y_i 為真值； n 為總資料數。

- 均方根誤差 (Root Mean Squared Error, RMSE) 透過平方計算平均誤差，避免抵銷正負誤差。為使單位與源資料一致，因此將均方誤差取根號。因此解釋時較直觀。均方根誤差也對於極值較為敏感。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (3.19)$$

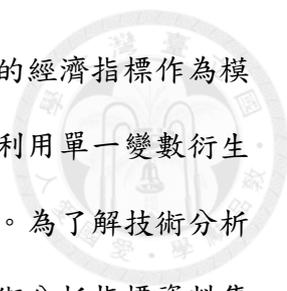
其中， \hat{y}_i 為預測值； y_i 為真值； n 為總資料數。

3.6 結果比較方法

本研究於預測完成後，將進行源域資料集、目標域資料集以及模型的比較，包含：

- 源域資料集比較：比較時間框架為 30 分鐘與 1 天的源域資料集後續模型之預測表現，以提供後續應用之建議。



- 
- 目標域資料集比較：過往預測營建物價之文獻多使用複數的經濟指標作為模型之訓練特徵，但此資料收集費時費力。因此本研究提出利用單一變數衍生之技術分析指標作為特徵以預測營造工程物價指數之方法。為了解技術分析指標能否取代過往使用之總體經濟等指標，將比較使用技術分析指標資料集以及總體經濟指標資料集之模型預測結果。
 - 模型比較：過往預測營建物價相關研究之預測表現有待改進，因此本研究提出結合遷移學習中的預訓練與微調以及深度學習模型—長短期記憶模型之方法以期提升預測表現。為確定利用遷移學習結合長短期記憶模型之方法是否能夠有效提升機器學習應用於營建物價預測方面的表現，因此將本研究之成果與過往之機器學習模型進行比較。比較之機器學習模型包含：
 - ANN
 - 決策樹 (Decision Tree)
 - 隨機森林 (Random Forest)
 - 極限梯度提升 (XGBoost)
 - K-近鄰演算法 (K Nearest Neighbor, KNN)
 - 支援向量機 (Support Vector Machine, SVM)

本研究透過 Scikit-learn 套件建立上述六種機器學習模型，並利用網格搜尋法 (Grid Search) 進行超參數優化，以提升模型預測表現。這些模型之輸入為技術分析指標資料集或經濟指標資料集，並與長短期記憶模型使用相同之資料集分割比例與最大最小正規化，滑動窗口大小同樣設置為 12，移動步長也設置為 1。輸出也與長短期記憶模型相同，為未來第 1 個月、或第 3 個月、或第 6 個月、或第 12 個月的之營造工程物價總指數、或水泥及其製品類指數、或金屬製品類指數的單一預測值，表示一次只會預測未來一個時間

點的一個指數，例如預測未來第 1 個月的營造工程物價總指數。預測之時間點與標的是訓練時之時間點與標的決定，若訓練時的標籤是未來第 1 個月的營造工程物價總指數，則預測時的單一數值便是未來第 1 個月的營造工程物價總指數。



第四章 研究結果與討論

本章將依據第三章研究方法之敘述順序說明本研究之結果，並進行相對應之討論與解釋。本章主要包含源域選擇結果與討論、資料集建立與處理之最終結果，以及預測營造工程物價總指數、水泥及其製品類指數、金屬製品類指數之最終結果。接著，針對源域資料集之時間框架、目標域資料集與各個模型之間進行比較，以提供後續研究與應用之建議。最後針對研究結果進行延伸討論。

4.1 源域與目標域選擇結果

本研究之目標域為營造工程物價總指數、水泥及其製品類指數、與金屬製品類指數。源域選擇方面，本研究使用 14 種衡量兩個域之間相似程度的方法，從 7 種預選源域中以多數決之投票機制決定營造工程物價總指數、水泥及其製品類指數、與金屬製品類指數各自之最終源域。需要注意的是，14 種方法中大多數的方法在進行比較時都要求使用相同長度的時間序列。然而，營造工程物價總指數、水泥及其製品類指數、金屬製品類指數之時間框架皆為 1 個月。因此為使時間序列長度一致，在使用 14 種衡量兩個域之間相似程度的方法時，匯率資料也採用 1 個月之時間框架。源域選擇結果顯示（表4.1），營造工程物價總指數之最終源域為新台幣兌日圓之匯率（TWDJPY），其表現最好之次數為 9 次。水泥及其製品類指數之最終源域為新台幣兌日圓之匯率（TWDJPY），表4.2顯示其表現最好之

次數為 11 次。金屬製品類指數之最終源域為新台幣兌韓元之匯率 (TWDKRW)，表 4.3 顯示其表現最好之次數為 6 次。此處的最佳次數是指在 14 個方法中，有幾個方法顯示其與目標域最為相似。以營造工程物價總指數為例，新台幣兌日圓之匯率 (TWDJPY) 表現最好之次數為 9 次，表示在 14 種方法中有 9 種方法顯示新台幣兌日圓之匯率 (TWDJPY) 波動與營造工程物價總指數最相似。

表 4.1: 營造工程物價總指數源域選擇結果

候選源域	最佳次數
TWDJPY	9
USDTWD	3
EURTWD	2
TWDKRW	2
AUDTWD	1
GBPTWD	1

表 4.2: 水泥及其製品類指數源域選擇結果

候選源域	最佳次數
TWDJPY	11
GBPTWD	4
USDTWD	2
TWDKRW	1

表 4.3: 金屬製品類指數源域選擇結果

候選源域	最佳次數
TWDKRW	6
TWDJPY	4
USDTWD	4
EURTWD	3
GBPTWD	1

根據源域決選結果，新台幣兌日圓之匯率為營造工程物價總指數、與水泥及其製品類指數之最終源域；新台幣兌韓元之匯率為金屬製品類指數之最終源域。表示這兩種匯率在中多數情況下被認為與這三種指數的波動最為相似，或者能夠最好地解釋這些指數的變化。可能的原因推測有幾個方面：

1. 與進口來源國家的經貿往來頻繁：根據台灣財政部關務署 2023 年統計資料

[81] 顯示，日本在金屬、水泥及其製品、磚瓦瓷類及瀝青類等多種營建材料

進口額均位居領先地位。這反映出台灣與日本在營建材料領域存在密切的經貿聯繫，因此新台幣兌日圓匯率波動對台灣營建材料價格影響較為顯著。

2. 區域經濟聯繫：台灣、日本與韓國在地理位置上比較接近，彼此之間可能存在著較為密切的經濟聯繫和產業互動。因此，這些國家之間的貨幣匯率波動可能反映了整個區域經濟環境的變化，對於相關行業的表現具有較好的解釋力。

綜上所述，新台幣兌日圓與新台幣兌韓元的匯率之所以被選為最佳源域，是因為它們與營造工程物價總指數、水泥及其製品類指數、以及金屬製品類指數之間存在著較為密切的關聯，能夠有效的解釋指數的變動。

4.2 資料集建立與處理

4.2.1 源域資料集建立與處理

源域資料集之時間框架可分為 30 分鐘與 1 天。30 分鐘時間框架之原始匯率資料是利用 Tradingview 取得，Tradingview 是一個投資理財的圖表平台和社交網路；1 天時間框架之原始匯率資料是利用 Python 透過 Yahoo Finance 的 API 進行下載。此外，本研究所採用的 11 種技術分析指標是利用 Python 程式語言以及名為 TA-LIB 的 Python 套件進行計算。本研究所取得之源域資料集時間與數量可參考表 4.4。當源域資料集為新台幣兌日圓之匯率且時間框架為 30 分鐘時，所取得的資料是從 2022 年 1 月 3 日 22 點 30 分至 2024 年 3 月 2 日 5 點 0 分，共 26806 筆資料，僅取得從 2022 年至今的資料是因為 Tradingview 限制了可取得的資料數量。當源域資料集為新台幣兌日圓之匯率且時間框架 1 天時，所取得的資料是從 2004 年 1 月 15 日至 2024 年 3 月 7 日，共 5226 筆資料，僅取得從 2004 年至今的資料

是因為這是 Yahoo Finance 可取得的最多資料數量。當源域資料集為新台幣兌韓元之匯率且時間框架 30 分鐘時，所取得的資料是從 2022 年 1 月 3 日 23 點 30 分至 2024 年 3 月 2 日 5 點 0 分，共 26633 筆資料。當源域資料集為新台幣兌韓元之匯率且時間框架 1 天時，所取得的資料是從 2004 年 1 月 15 日至 2024 年 3 月 7 日，共 5228 筆資料。資料取得後依照表 3.4 中的參數計算技術分析指標，以建立源域資料集。

表 4.4: 源域資料集數量統計

源域	時間框架	開始時間	結束時間	總數量
TWDJPY	30 分鐘	2022-01-03 22:30	2024-03-02 05:00	26806
TWDJPY	1 天	2004-01-15	2024-03-07	5226
TWDKRW	30 分鐘	2022-01-03 23:30	2024-03-02 05:00	26633
TWDKRW	1 天	2004-01-15	2024-03-07	5228

源域資料集建立完成後，依照第三章研究方法中提及之分割比例，訓練集佔整體資料集之最前面 64%；驗證集佔後續整體資料集之 16%；測試集佔整體資料集之最後面 20%，並按照時間順序對源域資料集進行分割。源域資料集之分割結果如圖 4.1、圖 4.2 與表 4.5 所示。當源域為新台幣兌日圓之匯率且時間框架為 30 分鐘時，訓練集之時間為 2022 年 1 月 3 日 22 點 30 分至 2023 年 5 月 22 日 13 點 00 分，共 17156 筆資料；驗證集之時間為 2023 年 5 月 22 日 13 點 30 分至 2023 年 9 月 25 日 20 點 30 分，共 4288 筆資料；測試集之時間為 2023 年 9 月 25 日 21 點 00 分至 2024 年 3 月 2 日 5 點 00 分，共 5362 筆資料。當源域為新台幣兌日圓之匯率且時間框架為 1 天時，訓練集之時間為 2004 年 1 月 15 日至 2016 年 12 月 15 日，共 3344 筆資料；驗證集之時間為 2016 年 12 月 16 日至 2020 年 3 月 4 日，共 836 筆資料；測試集之時間為 2020 年 3 月 5 日至 2024 年 3 月 7 日，共 1046 筆資料。當源域為新台幣兌韓元之匯率且時間框架為 30 分鐘時，訓練集之時間為 2022 年 1 月 3 日 23 點 30 分至 2023 年 5 月 22 日 11 點 00 分，共 17045 筆資料；驗證集之時間為 2023 年 5 月 22 日 11 點 30 分至 2023 年 9 月 25 日 12 點 00 分，共 4261 筆

資料；測試集之時間為 2023 年 9 月 25 日 12 點 30 分至 2024 年 3 月 2 日 5 點 00 分，共 5327 筆資料。當源域為新台幣兌韓元之匯率且時間框架為 1 天時，訓練集之時間為 2004 年 1 月 15 日至 2016 年 12 月 15 日，共 3346 筆資料；驗證集之時間為 2016 年 12 月 16 日至 2020 年 3 月 4 日，共 836 筆資料；測試集之時間為 2020 年 3 月 5 日至 2024 年 3 月 7 日，共 1046 筆資料。後續之最大最小正規化與滑動窗口技術就如第三章研究方法中所述。滑動窗口大小設置為 12，移動步長設置為 1。

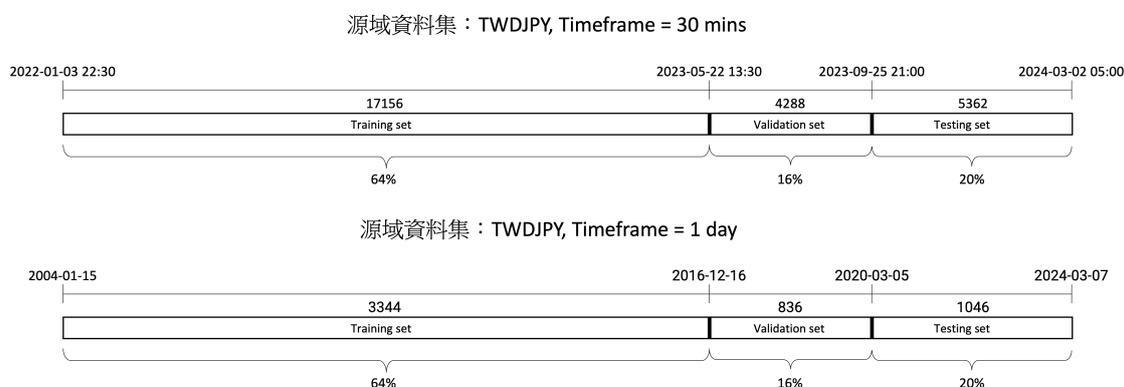


圖 4.1: 源域資料集分割結果 (TWDJPY)

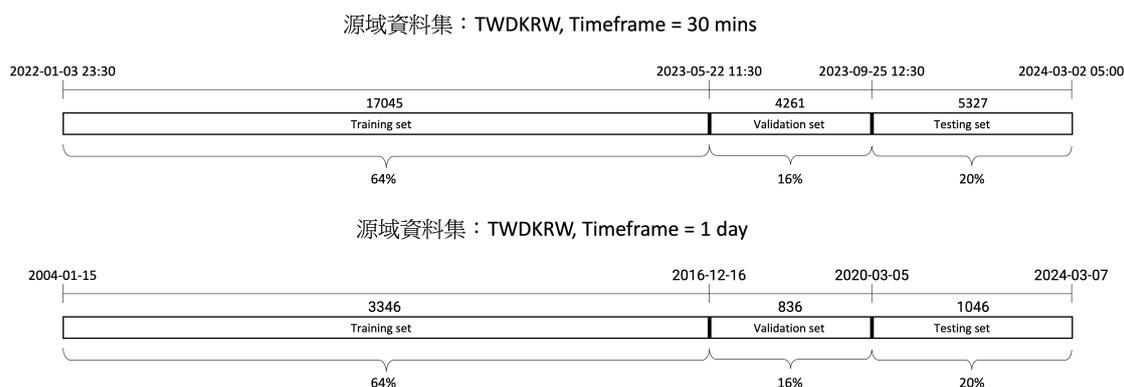


圖 4.2: 源域資料集分割結果 (TWDKRW)

4.2.2 目標域資料集建立與處理

目標域資料集方面，技術分析指標資料集之營造工程物價總指數、水泥及其製品類指數、與金屬製品類指數之時間與數量相同，皆從 1993 年 10 月至 2023 年

表 4.5: 源域資料集分割結果

資料集	時間框架	資料集類別	開始時間	結束時間	總數量
TWDJPY	30 分鐘	訓練集	2022-01-03 22:30	2023-05-22 13:00	17156
		驗證集	2023-05-22 13:30	2023-09-25 20:30	4288
		測試集	2023-09-25 21:00	2024-03-02 05:00	5362
	1 天	訓練集	2004-01-15	2016-12-15	3344
		驗證集	2016-12-16	2020-03-04	836
		測試集	2020-03-05	2024-03-07	1046
TWDKRW	30 分鐘	訓練集	2022-01-03 23:30	2023-05-22 11:00	17045
		驗證集	2023-05-22 11:30	2023-09-25 12:00	4261
		測試集	2023-09-25 12:30	2024-03-02 05:00	5327
	1 天	訓練集	2004-01-15	2016-12-15	3346
		驗證集	2016-12-16	2020-03-04	836
		測試集	2020-03-05	2024-03-07	1046

11 月，共 362 筆資料；經濟指標資料集方面，為配合其他指標之可取得性，因此營造工程物價總指數、水泥及其製品類指數、與金屬製品類指數之資料時間皆從 2003 年 1 月至 2023 年 11 月，共 251 筆資料。技術分析指標資料集之設定參數如表 3.5 所示。經濟指標資料集方面，最終取得之指標及其來源如表 3.7 與表 3.8 所示，共 53 種，可分為能源（4 種）、總體經濟指標（20 種）、市場條件（10 種）、股票市場（9 種）、以及營造工程物價指數之材料類中分類指數（10 種）等六類。

表 4.6: 目標域資料集數量統計

資料集	時間框架	開始時間	結束時間	總數量
技術分析指標資料集	1 個月	1993-10-01	2023-11-01	362
經濟指標資料集	1 個月	2003-01-01	2023-11-01	251

目標域資料集建立完成後，依照第三章研究方法中提及之分割比例，經濟指標資料集之訓練集佔整體資料集最前面 69%；驗證集佔後續整體資料集之 17%；測試集佔整體資料集之最後面 14%，並按照時間順序對源域資料集進行分割，因此經濟指標資料集之訓練集為 2003 年 1 月至 2017 年 5 月，共 173 筆資料；驗證集為 2017 年 6 月至 2020 年 12 月，共 43 筆資料；測試集為 2021 年 1 月至 2023 年 11 月，共 35 筆資料。然而，因為技術分析指標資料集與經濟指標資料集之大小不一致，若依照相同比例分割將導致測試集不同而無法進行比較。因此，為使

測試集相同，技術分析指標資料集的測試集之時間與經濟指標資料集的測試集之時間相同，為 2021 年 1 月至 2023 年 11 月，共 35 筆資料，而技術分析指標資料集之訓練集為 1993 年 1 月至 2015 年 6 月，共 262 筆資料；驗證集為 2015 年 7 月至 2020 年 12 月，共 65 筆資料。目標域資料集之分割結果如圖 4.3 與表 4.7 所示。後續之最大最小正規化與滑動窗口技術就如第三章研究方法中所述。滑動窗口大小設置為 12，移動步長設置為 1。

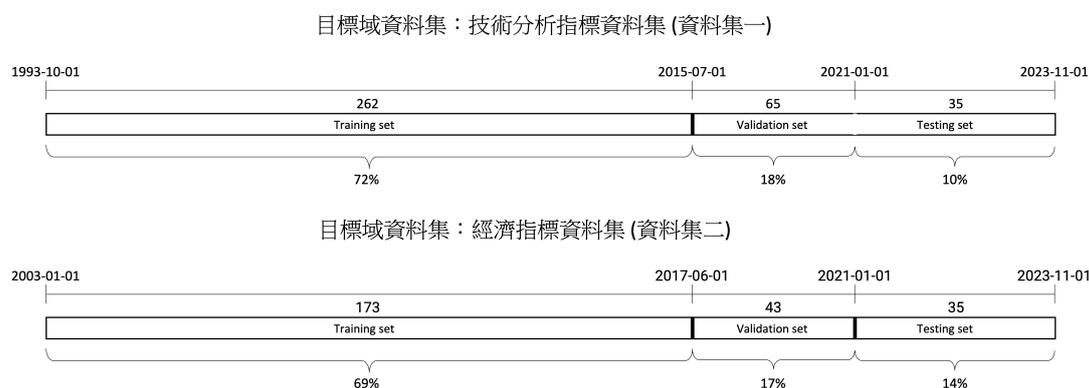


圖 4.3: 目標域資料集分割

表 4.7: 目標域資料集分割結果

資料集	資料集類別	時間框架	開始時間	結束時間	總數量
技術分析指標資料集	訓練集	1 個月	1993-10	2015-07	262
	驗證集	1 個月	2015-08	2020-12	65
	測試集	1 個月	2021-01	2023-11	35
經濟指標資料集	訓練集	1 個月	2003-01	2017-05	173
	驗證集	1 個月	2017-06	2020-12	43
	測試集	1 個月	2021-01	2023-11	35

4.3 模型訓練與驗證結果

本研究之 LSTM 模型包含兩層 LSTM 層以及兩層全連接層，透過手動調整超參數，詳細參數與建立過程請參考第三章。本研究之 LSTM 模型於訓練與驗證階段皆有成功降低損失，表示模型學習表現良好。通常情況下，模型的不佳表現可能源於兩個主要因素：偏差 (Bias) 和方差 (Variance)。以射箭為例，偏差表示箭靶命中點偏離目標中心的程度，而方差則表示多次射擊的箭靶命中點彼此間的

散布程度。因此可推斷，即使方差很小，當偏差很大時，模型表現仍然會不理想。在機器學習中，偏差指的是模型在訓練階段對資料的擬合程度。如果模型無法成功擬合訓練資料，可能的原因包括模型不夠複雜、選擇的超參數不當等。這將導致後續的驗證和測試表現也無法令人滿意。因此，在評估模型的測試表現之前，必須先確保模型在訓練階段有較好的擬合效果。本研究之訓練與驗證表現以預測營造工程物價總指數之模型為例，源域資料集之時間框架為1天，目標域資料集為經濟指標資料集。預測營造工程物價總指數的模型最終訓練與驗證之結果如表4.9所示。損失曲線以預測未來第1個月營造工程物價總指數之Model 4為例，如圖4.4所示。需要注意的是，表4.9中沒有Model 2，這是因為Model 2是直接利用預訓練模型預測營建物價指數，因此其沒有利用目標域資料集進行訓練與驗證的階段，因此沒有訓練與驗證的損失。從表4.8、表4.9與圖4.4可以觀察到本研究之模型於訓練階段與驗證階段皆有成功降低損失，表示模型學習表現良好。

表 4.8: 預訓練模型訓練與驗證結果

MSE						
階段	模型	資料集	1 個月	3 個月	6 個月	12 個月
訓練	預訓練模型	源域資料集	0.000369	0.000594	0.001124	0.001453
驗證	預訓練模型	源域資料集	0.003221	0.005187	0.008199	0.016303

表 4.9: 預測模型訓練與驗證結果

MSE						
階段	模型	資料集	1 個月	3 個月	6 個月	12 個月
訓練	Model 1	經濟指標資料集	0.001198	0.000998	0.000897	0.000984
	Model 3		0.003642	0.002136	0.002194	0.001842
	Model 4		0.005653	0.004169	0.005302	0.005689
	Model 5		0.002761	0.002515	0.003307	0.001630
驗證	Model 1	經濟指標資料集	0.006967	0.008980	0.006790	0.004350
	Model 3		0.044821	0.033452	0.015914	0.005386
	Model 4		0.039399	0.019123	0.016168	0.010948
	Model 5		0.030031	0.026133	0.0176103	0.005675

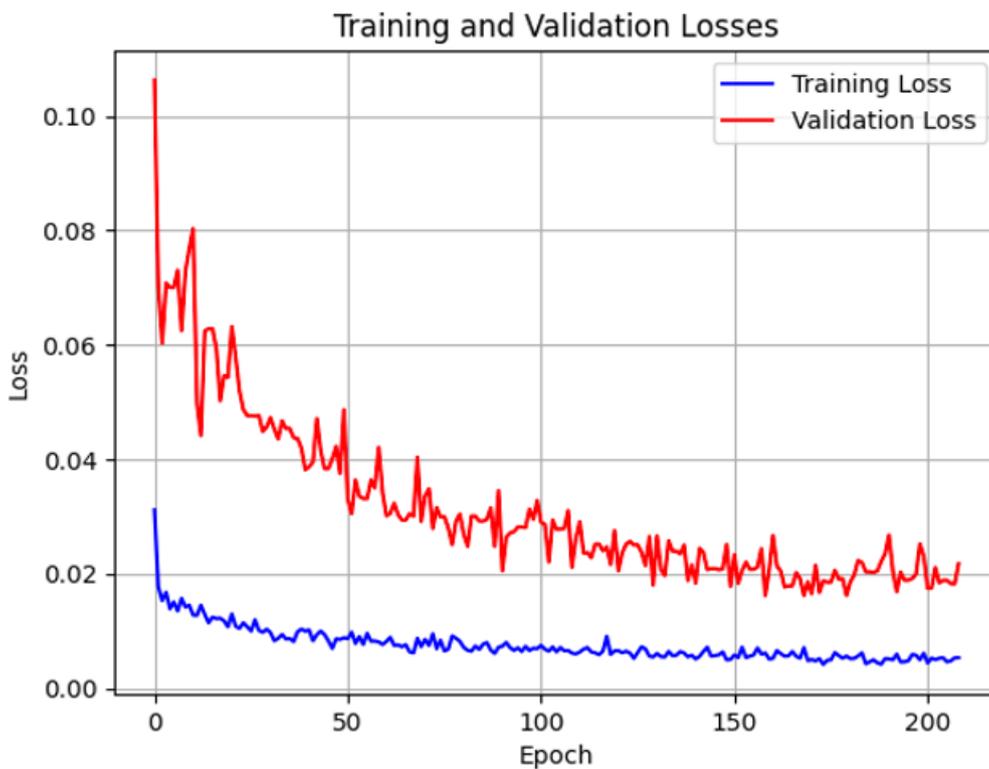


圖 4.4: 預測模型損失曲線

4.4 預測結果

模型訓練並微調完成後，利用測試集進行測試，以評估模型之表現。後續章節將說明營造工程物價總指數、水泥及其製品類指數、與金屬製品類指數之最終預測結果，並比較 Model 1 至 Model 5 之預測表現、源域資料集時間框架、與目標域資料集。此外，為了解本研究所提出之預訓練與微調之方法是否優於過往一般機器學習之預測表現，因此將與一般機器學習進行比較。

4.4.1 預測營造工程物價總指數結果

(1) 30 分鐘時間框架 技術分析指標資料集

當源域資料集之時間框架為 30 分鐘，且目標域資料集為技術分析指標資料集時，預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月的營造工程物價



總指數之結果如表4.10、表4.11、表4.12、表4.13所示。

當預測未來第 1 個月之營造工程物價總指數時（表4.10），相較於一般機器學習方法（Model 1），本研究採用預訓練與微調之方法（Model 3）能夠降低 7.5% 的 MAE、0.14% 的 MAPE、19% 的 MSE、10% 的 RMSE，但是僅微調第一層 LSTM 層時（Model 5）其預測表現最佳，相較於一般機器學習方法，其能夠降低 27% 的 MAE、0.53% 的 MAPE、39% 的 MSE、22% 的 RMSE。

表 4.10: 第 1 個月營造工程物價總指數 (30 分鐘時間框架、資料集一)

未來第 1 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.12	1.95	5.40	2.32	使用 CCI 直接訓練 LSTM
Model 2	2.40	2.22	8.66	2.94	使用源域模型直接預測 CCI
Model 3	1.96	1.81	4.40	2.10	微調整個模型
Model 4	1.69	1.56	3.72	1.93	微調第二層 LSTM 層
Model 5	1.54	1.42	3.30	1.82	微調第一層 LSTM 層

當預測未來第 3 個月之營造工程物價總指數時（表4.11），相較於一般機器學習方法（Model 1），本研究採用預訓練與微調之方法且僅微調第二層 LSTM 層時（Model 4）其預測表現最佳，其能夠降低 7% 的 MAE、0.15% 的 MAPE、11% 的 MSE、6% 的 RMSE。

表 4.11: 第 3 個月營造工程物價總指數 (30 分鐘時間框架、資料集一)

未來第 3 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.32	2.14	6.52	2.55	使用 CCI 直接訓練 LSTM
Model 2	2.85	2.62	10.82	3.29	使用源域模型直接預測 CCI
Model 3	2.31	2.13	8.20	2.86	微調整個模型
Model 4	2.16	1.99	5.82	2.41	微調第二層 LSTM 層
Model 5	2.36	2.17	8.49	2.91	微調第一層 LSTM 層

當預測未來第 6 個月之營造工程物價總指數時（表4.12），相較於一般機器學習方法（Model 1），本研究採用預訓練與微調之方法（Model 3）能夠降低 44% 的 MAE、0.93% 的 MAPE、65% 的 MSE、41% 的 RMSE，且其為最佳之模型，優於僅微調第一層或第二層 LSTM 層之模型。

當預測未來第 12 個月之營造工程物價總指數時（表4.13），相較於一般機器學

表 4.12: 第 6 個月營造工程物價總指數 (30 分鐘時間框架、資料集一)

未來第 6 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.31	2.12	6.22	2.49	使用 CCI 直接訓練 LSTM
Model 2	3.35	3.08	13.64	3.69	使用源域模型直接預測 CCI
Model 3	1.30	1.19	2.16	1.47	微調整個模型
Model 4	2.38	2.19	7.21	2.68	微調第二層 LSTM 層
Model 5	2.14	1.97	6.29	2.51	微調第一層 LSTM 層

習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，其能夠降低 88% 的 MAE、2.43% 的 MAPE、98% 的 MSE、86% 的 RMSE。

表 4.13: 第 12 個月營造工程物價總指數 (30 分鐘時間框架、資料集一)

未來第 12 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	3.01	2.76	9.71	3.12	使用 CCI 直接訓練 LSTM
Model 2	4.84	4.44	25.35	5.04	使用源域模型直接預測 CCI
Model 3	2.94	2.70	9.68	3.11	微調整個模型
Model 4	2.72	2.50	8.00	2.83	微調第二層 LSTM 層
Model 5	0.36	0.33	0.19	0.44	微調第一層 LSTM 層

(2) 1 天時間框架、技術分析指標資料集

當源域資料集之時間框架為 1 天，且目標域資料集為技術分析指標資料集時，預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月的營造工程物價總指數之結果如表 4.14、表 4.15、表 4.16、表 4.17 所示。

當預測未來第 1 個月之營造工程物價總指數時 (表 4.14)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 57% 的 MAE、1.11% 的 MAPE、64% 的 MSE、40% 的 RMSE，且其為最佳之模型，優於僅微調第一層或第二層 LSTM 層之模型。

當預測未來第 3 個月之營造工程物價總指數時 (表 4.15)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 44% 的 MAE、0.95% 的 MAPE、43% 的 MSE、25% 的 RMSE，且其為最佳之模型，優於僅微調第一層或第二層 LSTM 層之模型。

表 4.14: 第 1 個月營造工程物價總指數 (1 天時間框架、資料集一)

未來第 1 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.12	1.95	5.40	2.32	使用 CCI 直接訓練 LSTM
Model 2	2.79	2.58	9.10	3.02	使用源域模型直接預測 CCI
Model 3	0.91	0.84	1.96	1.40	微調整個模型
Model 4	1.04	0.96	2.44	1.56	微調第二層 LSTM 層
Model 5	1.00	0.92	2.37	1.54	微調第一層 LSTM 層

表 4.15: 第 3 個月營造工程物價總指數 (1 天時間框架、資料集一)

未來第 3 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.32	2.14	6.52	2.55	使用 CCI 直接訓練 LSTM
Model 2	3.34	3.08	13.72	3.70	使用源域模型直接預測 CCI
Model 3	1.30	1.19	3.71	1.93	微調整個模型
Model 4	1.55	1.43	4.95	2.22	微調第二層 LSTM 層
Model 5	1.50	1.38	4.88	2.21	微調第一層 LSTM 層

當預測未來第 6 個月之營造工程物價總指數時 (表 4.16)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第二層 LSTM 層時 (Model 4) 其預測表現最佳，其能夠降低 62% 的 MAE、1.31% 的 MAPE、79% 的 MSE、54% 的 RMSE。

表 4.16: 第 6 個月營造工程物價總指數 (1 天時間框架、資料集一)

未來第 6 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.31	2.12	6.22	2.49	使用 CCI 直接訓練 LSTM
Model 2	3.80	3.50	16.80	4.10	使用源域模型直接預測 CCI
Model 3	1.36	1.25	3.68	1.92	微調整個模型
Model 4	0.88	0.81	1.32	1.15	微調第二層 LSTM 層
Model 5	1.58	1.46	4.95	2.22	微調第一層 LSTM 層

當預測未來第 12 個月之營造工程物價總指數時 (表 4.17)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第二層 LSTM 層時 (Model 4) 其預測表現最佳，其能夠降低 55% 的 MAE、1.53% 的 MAPE、81% 的 MSE、56% 的 RMSE。

(3) 30 分鐘時間框架、經濟指標資料集

當源域資料集之時間框架為 30 分鐘，且目標域資料集為經濟指標資料集時，預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月的營造工程物價總指

表 4.17: 第 12 個月營造工程物價總指數 (1 天時間框架、資料集一)

未來第 12 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	3.01	2.76	9.71	3.12	使用 CCI 直接訓練 LSTM
Model 2	5.15	4.72	28.96	5.38	使用源域模型直接預測 CCI
Model 3	1.51	1.38	2.39	1.54	微調整個模型
Model 4	1.34	1.23	1.87	1.37	微調第二層 LSTM 層
Model 5	2.08	1.91	7.72	2.78	微調第一層 LSTM 層

數之結果如表 4.18、表 4.19、表 4.20、表 4.21 所示。

當預測未來第 1 個月之營造工程物價總指數時 (表 4.18)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 27% 的 MAE、0.60% 的 MAPE、32% 的 MSE、18% 的 RMSE，但是僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，相較於一般機器學習方法，其能夠降低 42% 的 MAE、0.94% 的 MAPE、45% 的 MSE、26% 的 RMSE。

表 4.18: 第 1 個月營造工程物價總指數 (30 分鐘時間框架、資料集二)

未來第 1 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.45	2.25	6.78	2.60	使用 CCI 直接訓練 LSTM
Model 2	3.84	3.55	16.23	4.03	使用源域模型直接預測 CCI
Model 3	1.78	1.65	4.59	2.14	微調整個模型
Model 4	2.46	2.28	7.84	2.80	微調第二層 LSTM 層
Model 5	1.41	1.31	3.71	1.93	微調第一層 LSTM 層

當預測未來第 3 個月之營造工程物價總指數時 (表 4.19)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，其能夠降低 43% 的 MAE、1.06% 的 MAPE、59% 的 MSE、36% 的 RMSE。

表 4.19: 第 3 個月營造工程物價總指數 (30 分鐘時間框架、資料集二)

未來第 3 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.68	2.47	7.80	2.80	使用 CCI 直接訓練 LSTM
Model 2	5.64	5.20	34.22	5.85	使用源域模型直接預測 CCI
Model 3	2.04	1.87	5.31	2.30	微調整個模型
Model 4	3.30	3.03	12.80	3.58	微調第二層 LSTM 層
Model 5	1.54	1.41	3.16	1.78	微調第一層 LSTM 層

當預測未來第 6 個月之營造工程物價總指數時 (表 4.20)，相較於一般機器

學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 46% 的 MAE、1.08% 的 MAPE、68% 的 MSE、44% 的 RMSE，且其為最佳之模型，優於僅微調第一層或第二層 LSTM 層之模型。

表 4.20: 第 6 個月營造工程物價總指數 (30 分鐘時間框架、資料集二)

未來第 6 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.57	2.35	7.79	2.79	使用 CCI 直接訓練 LSTM
Model 2	6.39	5.88	42.35	6.51	使用源域模型直接預測 CCI
Model 3	1.39	1.27	2.46	1.57	微調整個模型
Model 4	3.14	2.89	10.93	3.31	微調第二層 LSTM 層
Model 5	1.46	1.35	4.40	2.10	微調第一層 LSTM 層

當預測未來第 12 個月之營造工程物價總指數時 (表 4.21)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，其能夠降低 2% 的 MAE、0.03% 的 MAPE、9% 的 MSE、5% 的 RMSE。

表 4.21: 第 12 個月營造工程物價總指數 (30 分鐘時間框架、資料集二)

未來第 12 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.08	1.91	4.80	2.19	使用 CCI 直接訓練 LSTM
Model 2	7.75	7.11	61.53	7.84	使用源域模型直接預測 CCI
Model 3	2.17	1.99	4.86	2.20	微調整個模型
Model 4	3.42	3.13	12.10	3.48	微調第二層 LSTM 層
Model 5	2.05	1.88	4.35	2.09	微調第一層 LSTM 層

(4) 1 天時間框架、經濟指標資料集

當源域資料集之時間框架為 1 天，且目標域資料集為經濟指標資料集時，預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月的營造工程物價總指數之結果如表 4.22、表 4.23、表 4.24、表 4.25 所示。

當預測未來第 1 個月之營造工程物價總指數時 (4.22)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 53% 的 MAE、1.18% 的 MAPE、53% 的 MSE、32% 的 RMSE，但是僅微調第二層 LSTM 層時 (Model 4) 其預測表現最佳，相較於一般機器學習方法，其能夠

降低 53% 的 MAE、1.19% 的 MAPE、74% 的 MSE、49% 的 RMSE。

表 4.22: 第 1 個月營造工程物價總指數 (1 天時間框架、資料集二)

未來第 1 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.45	2.25	6.78	2.60	使用 CCI 直接訓練 LSTM
Model 2	4.86	4.49	25.31	5.03	使用源域模型直接預測 CCI
Model 3	1.15	1.07	3.16	1.78	微調整個模型
Model 4	1.27	1.18	3.76	1.94	微調第二層 LSTM 層
Model 5	1.15	1.06	1.74	1.32	微調第一層 LSTM 層

當預測未來第 3 個月之營造工程物價總指數時 (4.23)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，其能夠降低 52% 的 MAE、1.28% 的 MAPE、69% 的 MSE、45% 的 RMSE。

表 4.23: 第 3 個月營造工程物價總指數 (1 天時間框架、資料集二)

未來第 3 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.68	2.47	7.80	2.79	使用 CCI 直接訓練 LSTM
Model 2	5.57	5.13	33.91	5.82	使用源域模型直接預測 CCI
Model 3	2.09	1.92	5.46	2.34	微調整個模型
Model 4	3.04	2.80	10.42	3.23	微調第二層 LSTM 層
Model 5	1.30	1.19	2.40	1.55	微調第一層 LSTM 層

當預測未來第 6 個月之營造工程物價總指數時 (4.24)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，其能夠降低 59% 的 MAE、1.38% 的 MAPE、79% 的 MSE、54% 的 RMSE。

表 4.24: 第 6 個月營造工程物價總指數 (1 天時間框架、資料集二)

未來第 6 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.57	2.35	7.79	2.79	使用 CCI 直接訓練 LSTM
Model 2	6.41	5.90	42.60	6.53	使用源域模型直接預測 CCI
Model 3	1.40	1.29	2.51	1.58	微調整個模型
Model 4	3.17	2.91	11.26	3.36	微調第二層 LSTM 層
Model 5	1.05	0.97	1.64	1.28	微調第一層 LSTM 層

當預測未來第 12 個月之營造工程物價總指數時 (4.25)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第一層 LSTM 層

時 (Model 5) 其預測表現最佳，其能夠降低 25% 的 MAE、0.47% 的 MAPE、43% 的 MSE、24% 的 RMSE。

表 4.25: 第 12 個月營造工程物價總指數 (1 天時間框架、資料集二)

未來第 12 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.08	1.91	4.80	2.19	使用 CCI 直接訓練 LSTM
Model 2	8.03	7.37	66.07	8.13	使用源域模型直接預測 CCI
Model 3	2.77	2.54	7.76	2.79	微調整個模型
Model 4	3.39	3.11	12.83	3.58	微調第二層 LSTM 層
Model 5	1.57	1.44	2.75	1.66	微調第一層 LSTM 層

透過上述預測營造工程物價總指數之結果，可以發現 Model 3 之預測表現皆比 Model 1 之預測表現良好，顯示本研究利用預訓練與微調方法之模型預測表現優於一般機器學習之訓練方法。而在這 5 種模型之中，Model 5 是其中較為出色的模型，其表現最佳之次數最多。此外，可以發現 Model 2 是 5 種模型中預測表現最差的，因為其沒有學習任何關於目標域的資訊，因此其表現最差。圖 4.5 顯示當源域時間框架為 30 分鐘、目標域資料集為技術分析指標資料集時，預測未來第 12 個月之營造工程物價總指數的預測結果。可以發現本研究於長期預測之表現良好，尤其是 Model 5 之預測與實際值非常接近，顯示本研究所提出方法之良好預測性能。

4.4.2 預測水泥及其製品類指數結果

(1) 30 分鐘時間框架、技術分析指標資料集

當源域資料集之時間框架為 30 分鐘，且目標域資料集為技術分析指標資料集時，預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月的水泥及其製品類指數之結果如表 4.26、表 4.27、表 4.28、表 4.29 所示。

當預測未來第 1 個月之水泥及其製品類指數時 (表 4.26)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低

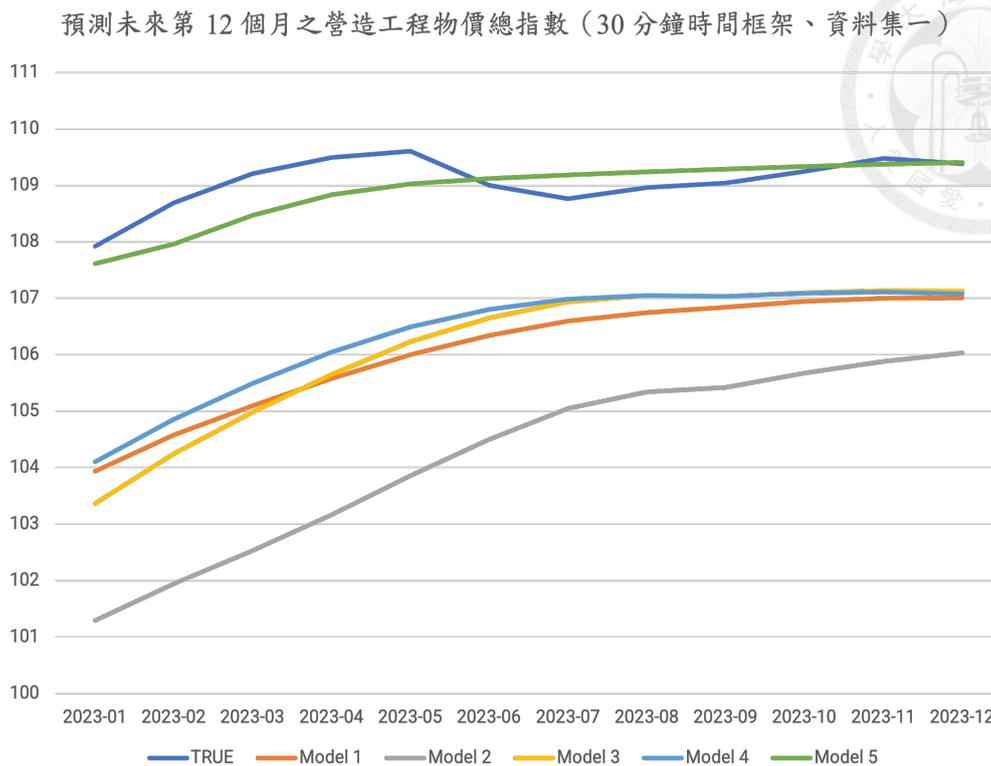


圖 4.5: 第 12 個月之營造工程物價總指數 (30 分鐘時間框架、資料集一)

54% 的 MAE、1.01% 的 MAPE、80% 的 MSE、55% 的 RMSE，但是僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，相較於一般機器學習方法，其能夠降低 70% 的 MAE、1.30% 的 MAPE、88% 的 MSE、65% 的 RMSE。

表 4.26: 第 1 個月水泥及其製品類指數 (30 分鐘時間框架、資料集一)

未來第 1 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.14	1.86	6.75	2.60	使用 CCI 直接訓練 LSTM
Model 2	4.35	3.70	19.94	4.47	使用源域模型直接預測 CCI
Model 3	0.99	0.85	1.36	1.16	微調整個模型
Model 4	1.09	0.95	2.12	1.46	微調第二層 LSTM 層
Model 5	0.64	0.56	0.84	0.92	微調第一層 LSTM 層

當預測未來第 3 個月之水泥及其製品類指數時 (表4.27)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，其能夠降低 50% 的 MAE、0.62% 的 MAPE、61% 的 MSE、38% 的 RMSE。

當預測未來第 6 個月之水泥及其製品類指數時 (表4.28)，相較於一般機器學

表 4.27: 第 3 個月水泥及其製品類指數 (30 分鐘時間框架、資料集一)

未來第 3 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	1.48	1.27	3.26	1.81	使用 CCI 直接訓練 LSTM
Model 2	5.29	4.51	29.40	5.42	使用源域模型直接預測 CCI
Model 3	1.83	1.58	5.39	2.32	微調整個模型
Model 4	0.88	0.77	1.46	1.21	微調第二層 LSTM 層
Model 5	0.74	0.65	1.26	1.12	微調第一層 LSTM 層

習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，其能夠降低 45% 的 MAE、1.13% 的 MAPE、31% 的 MSE、17% 的 RMSE。

表 4.28: 第 6 個月水泥及其製品類指數 (30 分鐘時間框架、資料集一)

未來第 6 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	3.04	2.58	12.43	3.53	使用 CCI 直接訓練 LSTM
Model 2	7.62	6.44	62.59	7.91	使用源域模型直接預測 CCI
Model 3	2.34	2.01	19.93	4.46	微調整個模型
Model 4	3.32	2.82	15.30	3.91	微調第二層 LSTM 層
Model 5	1.69	1.45	8.54	2.92	微調第一層 LSTM 層

當預測未來第 12 個月之水泥及其製品類指數時 (表 4.29)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，其能夠降低 30% 的 MAE、0.73% 的 MAPE、19% 的 MSE、10% 的 RMSE。

表 4.29: 第 12 個月水泥及其製品類指數 (30 分鐘時間框架、資料集一)

未來第 12 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.96	2.47	10.23	3.20	使用 CCI 直接訓練 LSTM
Model 2	11.31	9.42	134.45	11.60	使用源域模型直接預測 CCI
Model 3	3.93	3.27	17.55	4.19	微調整個模型
Model 4	3.84	3.20	19.67	4.43	微調第二層 LSTM 層
Model 5	2.08	1.74	8.29	2.88	微調第一層 LSTM 層

(2) 1 天時間框架、技術分析指標資料集

當源域資料集之時間框架為 1 天，且目標域資料集為技術分析指標資料集時，預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月的水泥及其製品類指數之結果如表 4.30、表 4.31、表 4.32、表 4.33 所示。

當預測未來第 1 個月之水泥及其製品類指數時 (表4.30)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 52% 的 MAE、0.97% 的 MAPE、71% 的 MSE、46% 的 RMSE，但是僅微調第二層 LSTM 層時 (Model 4) 其預測表現最佳，相較於一般機器學習方法，其能夠降低 75% 的 MAE、1.40% 的 MAPE、92% 的 MSE、72% 的 RMSE。

表 4.30: 第 1 個月水泥及其製品類指數 (1 天時間框架、資料集一)

未來第 1 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.14	1.86	6.75	2.60	使用 CCI 直接訓練 LSTM
Model 2	4.51	3.86	21.21	4.60	使用源域模型直接預測 CCI
Model 3	1.02	0.89	1.98	1.41	微調整個模型
Model 4	0.53	0.46	0.54	0.73	微調第二層 LSTM 層
Model 5	0.65	0.57	1.03	1.01	微調第一層 LSTM 層

當預測未來第 3 個月之水泥及其製品類指數時 (表4.31)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第二層 LSTM 層時 (Model 4) 其預測表現最佳，其能夠降低 43% 的 MAE、0.54% 的 MAPE、52% 的 MSE、31% 的 RMSE。

表 4.31: 第 3 個月水泥及其製品類指數 (1 天時間框架、資料集一)

未來第 3 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	1.48	1.27	3.26	1.81	使用 CCI 直接訓練 LSTM
Model 2	6.15	5.25	41.01	6.40	使用源域模型直接預測 CCI
Model 3	1.47	1.26	3.18	1.78	微調整個模型
Model 4	0.84	0.73	1.56	1.25	微調第二層 LSTM 層
Model 5	1.33	1.14	2.17	1.47	微調第一層 LSTM 層

當預測未來第 6 個月之水泥及其製品類指數時 (表4.32)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 67% 的 MAE、1.71% 的 MAPE、82% 的 MSE、57% 的 RMSE，且其為最佳之模型，優於僅微調第一層或第二層 LSTM 層之模型。

當預測未來第 12 個月之水泥及其製品類指數時 (表4.33)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第一層 LSTM 層

表 4.32: 第 6 個月水泥及其製品類指數 (1 天時間框架、資料集一)

未來第 6 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	3.04	2.58	12.43	3.53	使用 CCI 直接訓練 LSTM
Model 2	8.95	7.57	91.01	9.54	使用源域模型直接預測 CCI
Model 3	1.01	0.87	2.27	1.51	微調整個模型
Model 4	3.67	3.14	25.68	5.07	微調第二層 LSTM 層
Model 5	1.83	1.55	4.61	2.15	微調第一層 LSTM 層

時 (Model 5) 其預測表現最佳，其能夠降低 71% 的 MAE、1.74% 的 MAPE、84% 的 MSE、60% 的 RMSE。

表 4.33: 第 12 個月水泥及其製品類指數 (1 天時間框架、資料集一)

未來第 12 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.96	2.47	10.23	3.20	使用 CCI 直接訓練 LSTM
Model 2	14.14	11.76	209.12	14.46	使用源域模型直接預測 CCI
Model 3	3.82	3.17	14.62	3.82	微調整個模型
Model 4	6.91	5.76	69.82	8.36	微調第二層 LSTM 層
Model 5	0.87	0.73	1.63	1.28	微調第一層 LSTM 層

(3) 30 分鐘時間框架、經濟指標資料集

當源域資料集之時間框架為 30 分鐘，且目標域資料集為經濟指標資料集時，預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月的水泥及其製品類指數之結果如表 4.34、表 4.35、表 4.36、表 4.37 所示。

當預測未來第 1 個月之水泥及其製品類指數時 (表 4.34)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 63% 的 MAE、1.68% 的 MAPE、74% 的 MSE、49% 的 RMSE，但是僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，相較於一般機器學習方法，其能夠降低 64% 的 MAE、1.72% 的 MAPE、69% 的 MSE、45% 的 RMSE。

當預測未來第 3 個月之水泥及其製品類指數時 (表 4.35)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 43% 的 MAE、1.19% 的 MAPE、71% 的 MSE、46% 的 RMSE，但是僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，相較於一般機器學習方法，其

表 4.34: 第 1 個月水泥及其製品類指數 (30 分鐘時間框架、資料集二)

未來第 1 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	3.18	2.75	12.02	3.47	使用 CCI 直接訓練 LSTM
Model 2	3.94	3.33	17.98	4.24	使用源域模型直接預測 CCI
Model 3	1.19	1.07	3.17	1.78	微調整個模型
Model 4	1.67	1.46	4.15	2.04	微調第二層 LSTM 層
Model 5	1.14	1.03	3.68	1.92	微調第一層 LSTM 層

能夠降低 59% 的 MAE、1.62% 的 MAPE、79% 的 MSE、55% 的 RMSE。

表 4.35: 第 3 個月水泥及其製品類指數 (30 分鐘時間框架、資料集二)

未來第 3 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	3.27	2.78	12.86	3.59	使用 CCI 直接訓練 LSTM
Model 2	4.86	4.10	25.77	5.08	使用源域模型直接預測 CCI
Model 3	1.86	1.59	3.79	1.95	微調整個模型
Model 4	1.82	1.55	3.67	1.92	微調第二層 LSTM 層
Model 5	1.34	1.16	2.64	1.62	微調第一層 LSTM 層

當預測未來第 6 個月之水泥及其製品類指數時 (表 4.36)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 33% 的 MAE、0.80% 的 MAPE、49% 的 MSE、28% 的 RMSE，但是僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，相較於一般機器學習方法，其能夠降低 50% 的 MAE、1.22% 的 MAPE、66% 的 MSE、42% 的 RMSE。

表 4.36: 第 6 個月水泥及其製品類指數 (30 分鐘時間框架、資料集二)

未來第 6 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	3.02	2.51	11.35	3.37	使用 CCI 直接訓練 LSTM
Model 2	7.20	6.06	52.47	7.24	使用源域模型直接預測 CCI
Model 3	2.01	1.71	5.83	2.41	微調整個模型
Model 4	2.69	2.28	8.48	2.91	微調第二層 LSTM 層
Model 5	1.51	1.29	3.87	1.97	微調第一層 LSTM 層

當預測未來第 12 個月之水泥及其製品類指數時 (表 4.37)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，其能夠降低 32% 的 MAE、0.77% 的 MAPE、51% 的 MSE、30% 的 RMSE。

(4) 1 天時間框架、經濟指標資料集

表 4.37: 第 12 個月水泥及其製品類指數 (30 分鐘時間框架、資料集二)

未來第 12 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.90	2.40	8.75	2.96	使用 CCI 直接訓練 LSTM
Model 2	10.02	8.33	103.52	10.17	使用源域模型直接預測 CCI
Model 3	3.71	3.09	15.14	3.89	微調整個模型
Model 4	3.34	2.78	14.82	3.85	微調第二層 LSTM 層
Model 5	1.96	1.63	4.32	2.08	微調第一層 LSTM 層

當源域資料集之時間框架為 1 天，且目標域資料集為經濟指標資料集時，預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月的水泥及其製品類指數之結果如表 4.38、表 4.39、表 4.40、表 4.41 所示。

當預測未來第 1 個月之水泥及其製品類指數時 (表 4.38)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 69% 的 MAE、1.88% 的 MAPE、86% 的 MSE、62% 的 RMSE，且其為最佳之模型，優於僅微調第一層或第二層 LSTM 層之模型。

表 4.38: 第 1 個月水泥及其製品類指數 (1 天時間框架、資料集二)

未來第 1 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	3.18	2.75	12.02	3.47	使用 CCI 直接訓練 LSTM
Model 2	6.72	5.72	49.56	7.04	使用源域模型直接預測 CCI
Model 3	0.98	0.87	1.69	1.30	微調整個模型
Model 4	1.01	0.90	1.84	1.36	微調第二層 LSTM 層
Model 5	1.14	1.01	2.33	1.53	微調第一層 LSTM 層

當預測未來第 3 個月之水泥及其製品類指數時 (表 4.39)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 56% 的 MAE、1.54% 的 MAPE、74% 的 MSE、49% 的 RMSE，但是僅微調第二層 LSTM 層時 (Model 4) 其預測表現最佳，相較於一般機器學習方法，其能夠降低 72% 的 MAE、2.00% 的 MAPE、91% 的 MSE、70% 的 RMSE。

當預測未來第 6 個月之水泥及其製品類指數時 (表 4.40)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 45% 的 MAE、1.11% 的 MAPE、68% 的 MSE、43% 的 RMSE，但是僅微調第

表 4.39: 第 3 個月水泥及其製品類指數 (1 天時間框架、資料集二)

未來第 3 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	3.27	2.78	12.86	3.59	使用 CCI 直接訓練 LSTM
Model 2	7.05	5.97	51.90	7.20	使用源域模型直接預測 CCI
Model 3	1.45	1.24	3.38	1.84	微調整個模型
Model 4	0.91	0.78	1.14	1.07	微調第二層 LSTM 層
Model 5	1.30	1.12	2.17	1.47	微調第一層 LSTM 層

一層 LSTM 層時 (Mode 5) 其預測表現最佳，相較於一般機器學習方法，其能夠降低 66% 的 MAE、1.64% 的 MAPE、84% 的 MSE、60% 的 RMSE。

表 4.40: 第 6 個月水泥及其製品類指數 (1 天時間框架、資料集二)

未來第 6 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	3.02	2.51	11.35	3.37	使用 CCI 直接訓練 LSTM
Model 2	9.51	8.00	90.81	9.53	使用源域模型直接預測 CCI
Model 3	1.65	1.40	3.68	1.92	微調整個模型
Model 4	1.14	0.97	1.72	1.31	微調第二層 LSTM 層
Model 5	1.02	0.87	1.80	1.34	微調第一層 LSTM 層

當預測未來第 12 個月之水泥及其製品類指數時 (表 4.41)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 45% 的 MAE、1.06% 的 MAPE、47% 的 MSE、27% 的 RMSE，且其為最佳之模型，優於僅微調第一層或第二層 LSTM 層之模型。

表 4.41: 第 12 個月水泥及其製品類指數 (1 天時間框架、資料集二)

未來第 12 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.90	2.40	8.75	2.96	使用 CCI 直接訓練 LSTM
Model 2	12.26	10.20	152.74	12.36	使用源域模型直接預測 CCI
Model 3	1.60	1.34	4.63	2.15	微調整個模型
Model 4	3.37	2.81	18.84	4.34	微調第二層 LSTM 層
Model 5	2.99	2.48	10.88	3.30	微調第一層 LSTM 層

依據預測水泥及其製品類指數之結果，與預測營造工程物價總指數相似的是可以發現 Model 3 之預測表現皆比 Model 1 之預測表現良好，表示本研究利用預訓練與微調方法之模型的預測表現優於一般傳統機器學習之訓練方法。而在這 5 種模型之中，Model 5 是其中較為出色的模型，其表現最佳之次數最多。此外，

Model 2 是 5 種模型中預測表現最差的，因為其沒有學習任何關於目標域的資訊，因此可以預想到其表現將會最差。圖4.6顯示當源域時間框架為 1 天、目標域資料集為技術分析指標資料集時，預測未來第 12 個月之水泥及其製品類指數的預測結果。可以發現本研究於長期預測之表現良好，尤其是 Model 5 之預測與實際值非常接近，顯示本研究所提出方法之良好預測性能。此外，Model 2 完全無法捕捉水泥及製品類指數之趨勢，顯示模型應微調之重要性。

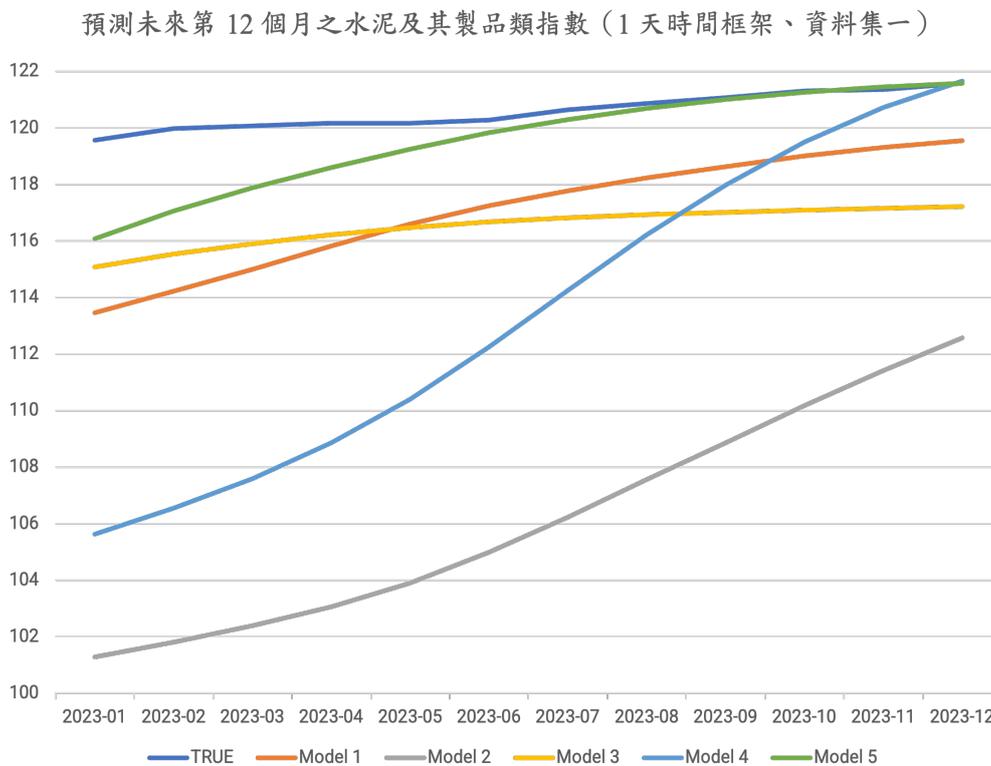


圖 4.6: 第 12 個月之水泥及其製品類指數 (1 天時間框架、資料集一)

4.4.3 預測金屬製品類指數結果

(1) 30 分鐘時間框架、技術分析指標資料集

當源域資料集之時間框架為 30 分鐘，且目標域資料集為技術分析指標資料集時，預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月的金屬製品類指數之結果如表4.42、表4.43、表4.44、表4.45所示。

當預測未來第 1 個月之金屬製品類指數時 (表4.42)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 5% 的 MAE、0.15% 的 MAPE、3% 的 MSE、3% 的 RMSE，但是僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，相較於一般機器學習方法，其能夠降低 6% 的 MAE、0.20% 的 MAPE、5% 的 MSE、3% 的 RMSE。

表 4.42: 第 1 個月金屬製品類指數 (30 分鐘時間框架、資料集一)

未來第 1 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.75	2.63	11.30	3.36	使用 CCI 直接訓練 LSTM
Model 2	6.71	6.55	51.92	7.21	使用源域模型直接預測 CCI
Model 3	2.61	2.48	10.72	3.27	微調整個模型
Model 4	2.75	2.62	10.05	3.17	微調第二層 LSTM 層
Model 5	2.57	2.43	10.73	3.28	微調第一層 LSTM 層

當預測未來第 3 個月之金屬製品類指數時 (表4.43)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降 9% 的 MAE、0.36% 的 MAPE、6% 的 MSE、3% 的 RMSE，且其為最佳之模型，優於僅微調第一層或第二層 LSTM 層之模型。

表 4.43: 第 3 個月金屬製品類指數 (30 分鐘時間框架、資料集一)

未來第 3 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	3.82	3.63	20.74	4.55	使用 CCI 直接訓練 LSTM
Model 2	7.98	7.76	68.28	8.26	使用源域模型直接預測 CCI
Model 3	3.46	3.27	19.58	4.42	微調整個模型
Model 4	4.12	3.95	21.34	4.62	微調第二層 LSTM 層
Model 5	4.56	4.37	26.40	5.14	微調第一層 LSTM 層

當預測未來第 6 個月之金屬製品類指數時 (表4.44)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降 18% 的 MAE、0.53% 的 MAPE、21% 的 MSE、11% 的 RMSE，且其為最佳之模型，優於僅微調第一層或第二層 LSTM 層之模型。

當預測未來第 12 個月之金屬製品類指數時 (表4.45)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第二層 LSTM 層時

表 4.44: 第 6 個月金屬製品類指數 (30 分鐘時間框架、資料集一)

未來第 6 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.95	2.90	11.69	3.42	使用 CCI 直接訓練 LSTM
Model 2	7.77	7.66	69.28	8.32	使用源域模型直接預測 CCI
Model 3	2.42	2.37	9.24	3.04	微調整個模型
Model 4	4.31	4.24	23.32	4.83	微調第二層 LSTM 層
Model 5	4.14	4.07	20.64	4.54	微調第一層 LSTM 層

(Model 4) 其預測表現最佳，其能夠降低 4% 的 MAE、0.08% 的 MAPE、10% 的 MSE、5% 的 RMSE。

表 4.45: 第 12 個月金屬製品類指數 (30 分鐘時間框架、資料集一)

未來第 12 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	1.94	1.93	4.57	2.14	使用 CCI 直接訓練 LSTM
Model 2	6.12	6.09	48.14	6.94	使用源域模型直接預測 CCI
Model 3	1.97	1.95	4.72	2.17	微調整個模型
Model 4	1.86	1.85	4.10	2.03	微調第二層 LSTM 層
Model 5	2.52	2.51	8.34	2.89	微調第一層 LSTM 層

(2) 1 天時間框架、技術分析指標資料集

當源域資料集之時間框架為 1 天，且目標域資料集為技術分析指標資料集時，預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月的金屬製品類指數之結果如表 4.46、表 4.47、表 4.48、表 4.49 所示。

當預測未來第 1 個月之金屬製品類指數時 (表 4.46)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降 11% 的 MAE、0.25% 的 MAPE、23% 的 MSE、12% 的 RMSE，且其為最佳之模型，優於僅微調第一層或第二層 LSTM 層之模型。

表 4.46: 第 1 個月金屬製品類指數 (1 天時間框架、資料集一)

未來第 1 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.75	2.63	11.30	3.36	使用 CCI 直接訓練 LSTM
Model 2	5.65	5.52	36.49	6.04	使用源域模型直接預測 CCI
Model 3	2.45	2.38	8.68	2.95	微調整個模型
Model 4	3.19	3.04	14.74	3.84	微調第二層 LSTM 層
Model 5	2.60	2.51	9.15	3.96	微調第一層 LSTM 層

當預測未來第 3 個月之金屬製品類指數時 (表4.47)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第二層 LSTM 層時 (Model 4) 其預測表現最佳，其能夠降低 18% 的 MAE、0.60% 的 MAPE、41% 的 MSE、23% 的 RMSE。

表 4.47: 第 3 個月金屬製品類指數 (1 天時間框架、資料集一)

未來第 3 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	3.82	3.63	20.74	4.55	使用 CCI 直接訓練 LSTM
Model 2	6.44	6.27	47.53	6.89	使用源域模型直接預測 CCI
Model 3	3.46	3.29	16.96	4.12	微調整個模型
Model 4	3.12	3.03	12.29	3.51	微調第二層 LSTM 層
Model 5	3.72	3.56	17.91	4.23	微調第一層 LSTM 層

當預測未來第 6 個月之金屬製品類指數時 (表4.48)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降 29% 的 MAE、0.88% 的 MAPE、36% 的 MSE、20% 的 RMSE，且其為最佳之模型，優於僅微調第一層或第二層 LSTM 層之模型。

表 4.48: 第 6 個月金屬製品類指數 (1 天時間框架、資料集一)

未來第 6 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.95	2.90	11.69	3.42	使用 CCI 直接訓練 LSTM
Model 2	7.46	7.36	62.11	7.88	使用源域模型直接預測 CCI
Model 3	2.09	2.02	7.47	2.73	微調整個模型
Model 4	3.46	3.40	16.04	4.01	微調第二層 LSTM 層
Model 5	2.57	2.52	9.45	3.07	微調第一層 LSTM 層

當預測未來第 12 個月之金屬製品類指數時 (表4.49)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降 7% 的 MAE、0.15% 的 MAPE、20% 的 MSE、10% 的 RMSE，且其為最佳之模型，優於僅微調第一層或第二層 LSTM 層之模型。

(3) 30 分鐘時間框架、經濟指標資料集

當源域資料集之時間框架為 30 分鐘，且目標域資料集為經濟指標資料集時，預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月的金屬製品類指數之

表 4.49: 第 12 個月金屬製品類指數 (1 天時間框架、資料集一)

未來第 12 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	1.94	1.93	4.57	2.14	使用 CCI 直接訓練 LSTM
Model 2	6.53	6.49	51.91	7.21	使用源域模型直接預測 CCI
Model 3	1.80	1.78	3.64	1.91	微調整個模型
Model 4	3.88	3.86	18.45	4.29	微調第二層 LSTM 層
Model 5	1.81	1.79	3.66	1.91	微調第一層 LSTM 層

結果如表 4.50、表 4.51、表 4.52、表 4.53 所示。

當預測未來第 1 個月之金屬製品類指數時 (表 4.50)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第二層 LSTM 層時 (Model 4) 其預測表現最佳，其能夠降低 19% 的 MAE、0.38% 的 MAPE、62% 的 MSE、39% 的 RMSE。

表 4.50: 第 1 個月金屬製品類指數 (30 分鐘時間框架、資料集二)

未來第 1 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.74	2.53	18.24	4.27	使用 CCI 直接訓練 LSTM
Model 2	6.05	5.81	43.93	6.63	使用源域模型直接預測 CCI
Model 3	2.79	2.59	18.17	4.26	微調整個模型
Model 4	2.23	2.15	6.90	2.63	微調第二層 LSTM 層
Model 5	3.02	2.79	22.75	4.77	微調第一層 LSTM 層

當預測未來第 3 個月之金屬製品類指數時 (表 4.51)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第二層 LSTM 層時 (Model 4) 其預測表現最佳，其能夠降低 19% 的 MAE、0.52% 的 MAPE、42% 的 MSE、24% 的 RMSE。

表 4.51: 第 3 個月金屬製品類指數 (30 分鐘時間框架、資料集二)

未來第 3 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	3.03	2.81	18.77	4.33	使用 CCI 直接訓練 LSTM
Model 2	6.14	5.86	51.33	7.16	使用源域模型直接預測 CCI
Model 3	3.98	3.70	29.84	5.46	微調整個模型
Model 4	2.45	2.29	10.84	3.29	微調第二層 LSTM 層
Model 5	3.32	3.10	22.01	4.69	微調第一層 LSTM 層

當預測未來第 6 個月之金屬製品類指數時 (表 4.52)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 20%

的 MAE、0.48% 的 MAPE、10% 的 MSE、5% 的 RMSE，但是僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，相較於一般機器學習方法，其能夠降低 39% 的 MAE、0.93% 的 MAPE、50% 的 MSE、29% 的 RMSE。

表 4.52: 第 6 個月金屬製品類指數 (30 分鐘時間框架、資料集二)

未來第 6 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.46	2.37	9.39	3.06	使用 CCI 直接訓練 LSTM
Model 2	4.81	4.71	32.02	5.66	使用源域模型直接預測 CCI
Model 3	1.98	1.89	8.44	2.91	微調整個模型
Model 4	1.88	1.80	8.93	2.99	微調第二層 LSTM 層
Model 5	1.50	1.44	4.70	2.17	微調第一層 LSTM 層

當預測未來第 12 個月之金屬製品類指數時 (表 4.53)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 39% 的 MAE、0.44% 的 MAPE、62% 的 MSE、38% 的 RMSE，且其為最佳之模型，優於僅微調第一層或第二層 LSTM 層之模型。

表 4.53: 第 12 個月金屬製品類指數 (30 分鐘時間框架、資料集二)

未來第 12 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	1.15	1.12	2.08	1.44	使用 CCI 直接訓練 LSTM
Model 2	3.85	3.82	16.50	4.06	使用源域模型直接預測 CCI
Model 3	0.70	0.68	0.79	0.89	微調整個模型
Model 4	1.07	1.07	2.27	1.51	微調第二層 LSTM 層
Model 5	1.23	1.21	2.05	1.43	微調第一層 LSTM 層

(4) 1 天時間框架、經濟指標資料集

當源域資料集之時間框架為 1 天，且目標域資料集為經濟指標資料集時，預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月的金屬製品類指數之結果如表 4.54、表 4.55、表 4.56、表 4.57 所示。

當預測未來第 1 個月之金屬製品類指數時 (表 4.54)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 18% 的 MAE、0.37% 的 MAPE、51% 的 MSE、30% 的 RMSE，但是僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，相較於一般機器學習方法，其能夠

降低 22% 的 MAE、0.48% 的 MAPE、59% 的 MSE、36% 的 RMSE。

表 4.54: 第 1 個月金屬製品類指數 (1 天時間框架、資料集二)

未來第 1 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.74	2.53	18.24	4.27	使用 CCI 直接訓練 LSTM
Model 2	5.66	5.39	45.07	6.71	使用源域模型直接預測 CCI
Model 3	2.25	2.16	9.02	3.00	微調整個模型
Model 4	2.69	2.50	15.37	3.92	微調第二層 LSTM 層
Model 5	2.15	2.05	7.57	2.75	微調第一層 LSTM 層

當預測未來第 3 個月之金屬製品類指數時 (表 4.55)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法且僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，其能夠降低 20% 的 MAE、0.53% 的 MAPE、40% 的 MSE、22% 的 RMSE。

表 4.55: 第 3 個月金屬製品類指數 (1 天時間框架、資料集二)

未來第 3 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	3.03	2.81	18.77	4.33	使用 CCI 直接訓練 LSTM
Model 2	5.10	4.79	48.31	6.95	使用源域模型直接預測 CCI
Model 3	3.68	3.51	17.46	4.18	微調整個模型
Model 4	3.69	3.47	24.28	4.93	微調第二層 LSTM 層
Model 5	2.44	2.28	11.33	3.37	微調第一層 LSTM 層

當預測未來第 6 個月之金屬製品類指數時 (表 4.56)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 39% 的 MAE、0.94% 的 MAPE、52% 的 MSE、31% 的 RMSE，且其為最佳之模型，優於僅微調第一層或第二層 LSTM 層之模型。

表 4.56: 第 6 個月金屬製品類指數 (1 天時間框架、資料集二)

未來第 6 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	2.46	2.37	9.39	3.06	使用 CCI 直接訓練 LSTM
Model 2	3.39	3.28	21.11	4.59	使用源域模型直接預測 CCI
Model 3	1.49	1.43	4.53	2.13	微調整個模型
Model 4	2.48	2.43	9.39	3.06	微調第二層 LSTM 層
Model 5	1.69	1.64	4.49	2.12	微調第一層 LSTM 層

當預測未來第 12 個月之金屬製品類指數時 (表 4.57)，相較於一般機器學習方法 (Model 1)，本研究採用預訓練與微調之方法 (Model 3) 能夠降低 35%

的 MAE、0.38% 的 MAPE、53% 的 MSE、32% 的 RMSE，但是僅微調第一層 LSTM 層時 (Model 5) 其預測表現最佳，相較於一般機器學習方法，其能夠降低 36% 的 MAE、0.40% 的 MAPE、67% 的 MSE、42% 的 RMSE。

表 4.57: 第 12 個月金屬製品類指數 (1 天時間框架、資料集二)

未來第 12 個月	MAE	MAPE(%)	MSE	RMSE	Description
Model 1	1.15	1.12	2.08	1.44	使用 CCI 直接訓練 LSTM
Model 2	3.07	3.02	10.48	3.24	使用源域模型直接預測 CCI
Model 3	0.74	0.74	0.97	0.98	微調整個模型
Model 4	2.66	2.63	7.69	2.77	微調第二層 LSTM 層
Model 5	0.73	0.72	0.70	0.83	微調第一層 LSTM 層

在預測金屬製品類指數之結果方面，可以發現 Model 3 之預測表現皆比 Model 1 之預測表現良好，表示預訓練與微調方法之模型的預測表現優於一般傳統機器學習之訓練方法。而在這 5 種模型之中，Model 3 與 Model 5 是較為出色的模型，其表現最佳之次數最多。值得注意的是，不論是預測營造工程物價總指數、水泥及其製品類指數或是金屬製品類指數，Model 5 皆為表現最佳的模型。與過去針對時間序列任務，通常只微調模型前幾層之結論相同。此外，Model 2 是 5 種模型中預測表現最差的，因為其沒有學習任何關於目標域的資訊，因此其表現最差也與預想相同。圖 4.7 顯示當源域時間框架為 30 分鐘、目標域資料集為經濟指標資料集時，預測未來第 12 個月之金屬製品類指數的預測結果。可以發現本研究於長期預測之表現良好，尤其是 Model 3 之預測與實際值之趨勢最為相符，顯示本研究所提出方法之良好預測性能。而 Model 4 與 Model 5 雖與實際值之趨勢也大致相符，但其數值上的誤差較大。此外，Model 2 完全無法捕捉金屬製品類指數之趨勢，顯示預測模型需要經過微調過程之重要性。

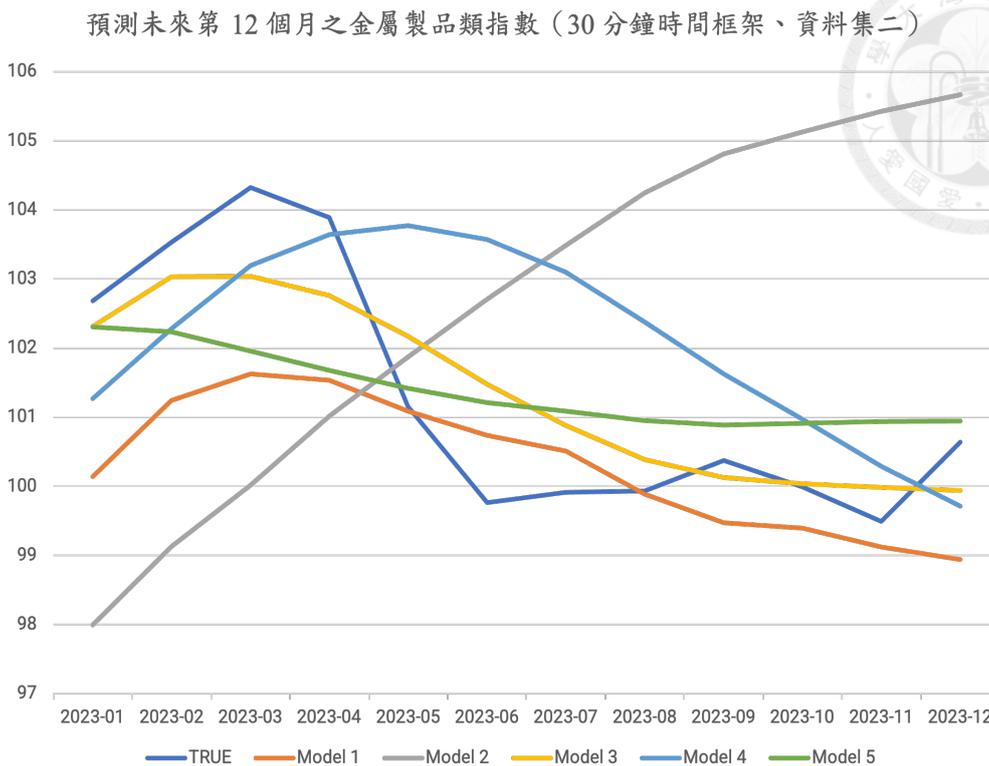


圖 4.7: 第 12 個月之金屬製品類指數 (30 分鐘時間框架、資料集二)

4.5 源域資料集時間框架比較

在源域資料集之時間框架方面，本研究採用 30 分鐘與 1 天之時間框架，透過比較兩種時間框架中預測第 1 個月、第 3 個月、第 6 個月、第 12 個月之最佳模型，便能夠了解哪一種時間框架較為適合作為源域資料集。比較之結果如表 4.58、4.59、4.60、4.61、4.62、4.63 所示。

表 4.58: 源域資料集時間框架比較 (資料集一、營造工程物價總指數)

技術分析指標資料集								
	1 個月		3 個月		6 個月		12 個月	
Timeframe	30-min	1-day	30-min	1-day	30-min	1-day	30-min	1-day
Best Model	Model 5	Model 3	Model 4	Model 3	Model 3	Model 4	Model 5	Model 4
MAE	1.54	0.91	2.16	1.30	1.30	0.88	0.36	1.34
MAPE (%)	1.42	0.84	1.99	1.19	1.19	0.81	0.33	1.23
MSE	3.30	1.96	5.82	3.71	2.16	1.32	0.19	1.87
RMSE	1.82	1.40	2.41	1.93	1.47	1.15	0.44	1.37

透過表 4.58 至表 4.63 之比較，可以發現當源域資料集之時間框架為 1 天時，其

表 4.59: 源域資料集時間框架比較 (資料集二、營造工程物價總指數)

經濟指標資料集								
	1 個月		3 個月		6 個月		12 個月	
Timeframe	30-min	1-day	30-min	1-day	30-min	1-day	30-min	1-day
Best Model	Model 5	Model 5	Model 5	Model 5	Model 3	Model 5	Model 5	Model 5
MAE	1.41	1.15	1.54	1.30	1.39	1.05	2.05	1.57
MAPE (%)	1.31	1.06	1.41	1.19	1.27	0.97	1.88	1.44
MSE	3.71	1.74	3.16	2.40	2.46	1.64	4.35	2.75
RMSE	1.93	1.32	1.78	1.55	1.57	1.28	2.09	1.66

表 4.60: 源域資料集時間框架比較 (資料集一、水泥及其製品類指數)

技術分析指標資料集								
	1 個月		3 個月		6 個月		12 個月	
Timeframe	30-min	1-day	30-min	1-day	30-min	1-day	30-min	1-day
Best Model	Model 5	Model 4	Model 5	Model 4	Model 5	Model 3	Model 5	Model 5
MAE	0.64	0.53	0.74	0.84	1.69	1.01	2.08	0.87
MAPE (%)	0.56	0.46	0.65	0.73	1.45	0.87	1.74	0.73
MSE	0.84	0.54	1.26	1.56	8.54	2.27	8.29	1.63
RMSE	0.92	0.73	1.12	1.25	2.92	1.51	2.88	1.28

表 4.61: 源域資料集時間框架比較 (資料集二、水泥及其製品類指數)

經濟指標資料集								
	1 個月		3 個月		6 個月		12 個月	
Timeframe	30-min	1-day	30-min	1-day	30-min	1-day	30-min	1-day
Best Model	Model 5	Model 3	Model 5	Model 4	Model 5	Model 5	Model 5	Model 3
MAE	1.14	0.98	1.34	0.91	1.51	1.02	1.96	1.60
MAPE (%)	1.03	0.87	1.16	0.78	1.29	0.87	1.63	1.34
MSE	3.68	1.69	2.64	1.14	3.87	1.80	4.32	4.63
RMSE	1.92	1.30	1.62	1.07	1.97	1.34	2.08	2.15

表 4.62: 源域資料集時間框架比較 (資料集一、金屬製品類指數)

技術分析指標資料集								
	1 個月		3 個月		6 個月		12 個月	
Timeframe	30-min	1-day	30-min	1-day	30-min	1-day	30-min	1-day
Best Model	Model 5	Model 3	Model 3	Model 4	Model 3	Model 3	Model 4	Model 3
MAE	2.57	2.45	3.46	3.12	2.42	2.09	1.86	1.80
MAPE (%)	2.43	2.38	3.27	3.03	2.37	2.02	1.85	1.78
MSE	10.73	8.68	19.58	12.29	9.24	7.47	4.10	3.64
RMSE	3.28	2.95	4.42	3.51	3.04	2.73	2.03	1.91

表 4.63: 源域資料集時間框架比較 (資料集二、金屬製品類指數)

經濟指標資料集								
	1 個月		3 個月		6 個月		12 個月	
Timeframe	30-min	1-day	30-min	1-day	30-min	1-day	30-min	1-day
Best Model	Model 4	Model 5	Model 4	Model 5	Model 5	Model 3	Model 3	Model 5
MAE	2.23	2.15	2.45	2.44	1.50	1.49	0.70	0.73
MAPE (%)	2.15	2.05	2.29	2.28	1.44	1.43	0.68	0.72
MSE	6.90	7.57	10.84	11.33	4.70	4.53	0.79	0.70
RMSE	2.63	2.75	3.29	3.37	2.17	2.13	0.89	0.83

後續預測營造工程物價總指數、水泥及其製品類指數、與金屬製品類指數之表現較好，可能原因如下。

- 更能夠反映長期趨勢與週期性波動。1 天的時間框架涵蓋的年份較長 (2004 年至 2024 年)，而 30 分鐘的時間框架涵蓋的年份較短 (2022 年至 2024 年)，因此較大的時間框架能夠更好地反映長期的趨勢和週期性波動。對於涉及總體經濟和行業發展的指數，更長的時間框架可能更能準確地反映長期趨勢和週期性波動。然而，這仍需要有一定量的資料以利模型學習。
- 源域之 1 天時間框架整體訓練集變化程度較大。透過圖 4.8、圖 4.9 可以發現，當時間框架為 1 天時，其訓練集之整體變化程度從 2.5 至 4；然而，當時間框架為 30 分鐘時，其訓練集之整體變化程度僅有 4.1 至 4.7。因此，雖然時間框架為 1 天時之訓練資料較少，僅有 3344 筆或 3346 筆，但因為其訓練集之變化程度較大，因此模型較容易學習其中之差異，帶來更良好的學習效果與表現。
- 源域之 30 分鐘時間框架受到資料噪音影響劇烈。與 1 天時間框架之訓練集資料量 (3344 筆或 3346 筆) 相比，30 分鐘時間框架之訓練資料多達 17156 筆或 17045 筆資料，因此其較容易受到資料噪音的影響，使得模型之學習表現較差 [99]。而較長的時間框架意味著更穩定的資料，減少了短期內的波動和噪音對預測模型的影響。因此能夠提高模型的穩定性和預測準確度。



圖 4.8: 時間框架 30 分鐘之訓練集整體變化程度



圖 4.9: 時間框架 1 天之訓練集整體變化程度

綜上所述，較長的時間框架在預測營造工程物價總指數、水泥及其製品類指數、以及金屬製品類指數時表現更好，這可能是因為它反映了長期趨勢與週期性、降低了資料的噪音和波動，減少了過擬合的風險，同時也更易於資料處理和整合。因此在選擇源域時間框架時，不僅需要考量資料數量的多寡，也應考慮資料噪音、與其穩定性對模型造成之正面與負面效果。後續在本研究之框架下，源域資料集之時間框架應以 1 天為主。

4.6 目標域資料集比較

在目標域資料集方面，本研究採用了兩種資料集，分別是技術分析指標資料集（資料集一）與經濟指標資料集（資料集二）。過往預測營建物價之相關文獻多是利用經濟指標作為模型之輸入特徵，然其收集曠日費時、耗費人力，且資料公佈日期不一。因此本研究期利用技術分析指標替代經濟指標，以避免資料收集之時間與人力成本浪費。透過比較預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月之營造工程物價總指數，以及預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月之水泥及其製品類指數，以及預測未來第 1 個月、第 3 個月、第 6 個月、與第 12 個月之金屬製品類指數的最佳模型，便能夠了解何種資料集較為適合用於預測營造工程物價總指數、水泥及其製品類指數、與金屬製品類指數。其結果如表 4.64、表 4.65、表 4.66 所示。

表 4.64: 目標域資料集比較（預測營造工程物價總指數）

營造工程物價總指數	資料集	最佳模型	MAE	MAPE (%)	MSE	RMSE
第 1 個月	技術分析指標	Model 3	0.91	0.84	1.96	1.40
	經濟指標	Model 5	1.15	1.06	1.74	1.32
第 3 個月	技術分析指標	Model 3	1.30	1.19	3.71	1.93
	經濟指標	Model 5	1.30	1.19	2.40	1.55
第 6 個月	技術分析指標	Model 4	0.88	0.81	1.32	1.15
	經濟指標	Model 5	1.05	0.97	1.64	1.28
第 12 個月	技術分析指標	Model 5	0.36	0.33	0.19	0.44
	經濟指標	Model 5	1.57	1.44	2.75	1.66

表 4.65: 目標域資料集比較 (預測水泥及其製品類指數)

水泥及其製品類指數	資料集	最佳模型	MAE	MAPE (%)	MSE	RMSE
第 1 個月	技術分析指標	Model 4	0.53	0.46	0.54	0.73
	經濟指標	Model 3	0.98	0.87	1.69	1.30
第 3 個月	技術分析指標	Model 4	0.84	0.73	1.56	1.25
	經濟指標	Model 4	0.91	0.78	1.14	1.07
第 6 個月	技術分析指標	Model 3	1.01	0.87	2.27	1.51
	經濟指標	Model 5	1.02	0.87	1.80	1.34
第 12 個月	技術分析指標	Model 5	0.87	0.73	1.63	1.28
	經濟指標	Model 3	1.60	1.34	4.63	2.15

表 4.66: 目標域資料集比較 (預測金屬製品類指數)

金屬製品類指數	資料集	最佳模型	MAE	MAPE (%)	MSE	RMSE
第 1 個月	技術分析指標	Model 3	2.45	2.38	8.68	2.95
	經濟指標	Model 5	2.15	2.05	7.57	2.75
第 3 個月	技術分析指標	Model 4	3.12	3.03	12.29	3.51
	經濟指標	Model 5	2.44	2.28	11.33	3.37
第 6 個月	技術分析指標	Model 3	2.09	2.02	7.47	2.73
	經濟指標	Model 3	1.49	1.43	4.53	2.13
第 12 個月	技術分析指標	Model 3	1.80	1.78	3.64	1.91
	經濟指標	Model 3	0.70	0.68	0.79	0.89

在預測營造工程物價總指數方面，使用技術分析指標資料集之預測表現最為良好；在預測水泥及其製品類指數方面，使用技術分析指標資料集之預測表現最為良好；在預測金屬製品類指數方面，使用經濟指標資料集之預測表現最為良好。在預測金屬製品類指數時，使用經濟指標資料集表現較好的原因可能是：

- 總體經濟因素的重要性：金屬製品在多數工業行業皆為重要材料，因此相較於營造工程物價總指數與水泥及其製品類指數，金屬製品類更容易受到整體經濟因素的影響，例如全球經濟增長、工業生產資料、貨幣政策等因素。這些因素對金屬價格和相關行業的發展有著較大的影響，因此利用經濟指標進行預測可能更為有效。
- 供需和週期性因素：金屬市場往往受到供需關係和週期性波動的影響較大。經濟指標往往能夠反映經濟活動的整體情況和行業的發展趨勢，從而對金屬價格和相關行業的表現具有較好的預測能力。

總的來說，預測營造工程物價總指數和水泥及其製品類指數時，使用技術分析指標資料集之預測結果較佳。相對地，在預測金屬製品類指數時，使用經濟指標資料集之預測結果表現較佳，因為金屬市場受總體經濟因素影響較大，經濟指標能有效反映供需情況和週期性波動。因此，選擇合適的資料集或方法對預測結果影響顯著。綜上所述，由於不同行業與指數受到的影響因素及特點不同，因此在預測時選擇適合的資料集非常重要的。

4.7 模型比較

將本研究所提出之遷移學習結合長短期記憶模型的方法與過往之機器學習模型進行比較，包含人工神經網路 (ANN)、決策樹 (Decision Tree)、隨機森林 (Random Forest)、極度梯度提升樹 (XGBoost)、K-近鄰演算法 (KNN)、支援向量機 (SVM) 等六種較為常見之模型。以確定本研究所提出之方法是否能夠提升機器學習模型預測營建物價指數之表現。

透過將本研究之最佳模型與機器學習模型之預測結果進行比較，便能夠了解本研究所提出之方法是否能夠提升機器學習應用於營建物價預測方面的表現。預測營造工程物價總指數之結果如表4.67、表4.68、表4.69、表4.70、表4.71、表4.72、表4.73、表4.74所示。本研究利用遷移學習之預訓練與微調方法訓練長短期記憶模型之預測表現優於一般機器學習模型。在預測未來第1個月、未來第3個月、未來第6個月、未來第12個月之營造工程物價總指數方面能夠降低50%以上的MAE，以及50%以上的MSE與30%以上的RMSE。顯示本研究所提出方法之良好成效。

預測水泥及其製品類指數之結果如表4.75、表4.76、表4.77、表4.78、表4.79、表4.80、表4.81、表4.82所示。本研究結合預訓練與微調方法及長短期記憶模型以

預測水泥及其製品類指數之表現優於一般機器學習模型。在預測未來第 1 個月、未來第 3 個月、未來第 6 個月、未來第 12 個月之水泥及其製品類指數方面，能夠降低 60% 以上的 MAE，以及 80% 以上的 MSE 與 60% 以上的 RMSE。此結果顯示本研究所提出方法與長短期記憶模型預測營建物價之良好成效。

預測金屬製品類指數之結果如表 4.83、表 4.84、表 4.85、表 4.86、表 4.87、表 4.88、表 4.89、表 4.90 所示。本研究運用預訓練與微調方法訓練長短期記憶模型，當目標域資料集為經濟指標資料集時，其預測未來第 6 個月與第 12 個月營建物價之表現優於一般機器學習模型，能夠降低 20% 以上的 MAE，以及 30% 以上的 MSE 與 15% 以上的 RMSE。顯示本研究所提出方法與長短期記憶模型預測長期金屬製品類指數之良好成效。然而，在預測未來第 1 個月與第 3 個月之金屬製品類指數時，傳統機器學習模型之預測表現較好。

預測營造工程物價指數與水泥及其製品類指數方面，結合預訓練與微調的長短期記憶模型在預測中表現更為出色，其原因可能包括以下幾點：

- 這些指數皆為時間序列資料，而長短期記憶模型在處理時間序列資料方面具有顯著優勢。它能夠有效捕捉時間相關的特徵和模式，使得模型能夠更準確地預測指數變化。
- 預訓練模型在源域資料上進行了充分的預訓練，因此具備了較好的初始參數。隨後的微調過程則針對目標域的特定資料進行了調整，使模型更好地適應目標領域的資料特徵，從而提高了預測的準確度。

在預測金屬製品類指數方面，傳統機器學習模型在預測短期內的第 1 個月和第 3 個月指數時表現更佳。本研究認為，這可能是因為在短期內的預測中，傳統機器學習模型能夠準確地利用當前的資料特徵進行預測，而不需要考慮長期的時間序列模式。

總的來說，長短期記憶模型在處理時間序列資料方面表現優異，特別適用於長期預測。而預訓練過程提供了較好的模型初始參數，有助於後續的微調和預測表現。這種結合方法使模型在應對複雜的時間序列預測任務時更加得心應手，並能夠在多種指數預測中取得良好的效果。

表 4.67: 模型比較 (營造工程物價總指數、資料集一、MAPE)

MAPE (%)	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	3.40	4.22	1.76	1.95
Decision Tree	1.60	3.15	3.93	3.10
Random Forest	1.68	3.20	3.70	3.78
XGBoost	2.67	4.63	6.93	6.23
KNN	3.10	3.65	4.14	3.69
SVM	2.56	3.07	3.44	4.58
LSTM (Model 1)	1.95	2.14	2.12	2.76
Transfer Learning LSTM	0.84	1.19	0.81	1.23

表 4.68: 模型比較 (營造工程物價總指數、資料集一、MAE)

MAE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	3.69	4.59	1.91	2.13
Decision Tree	1.74	3.42	4.25	3.37
Random Forest	1.81	3.48	4.01	4.12
XGBoost	2.87	5.02	7.52	6.79
KNN	3.36	3.96	4.50	4.01
SVM	2.77	3.33	3.74	5.00
LSTM (Model 1)	2.12	2.32	2.31	3.01
Transfer Learning LSTM	0.91	1.30	0.88	1.34

表 4.69: 模型比較 (營造工程物價總指數、資料集一、MSE)

MSE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	18.07	25.38	5.47	5.94
Decision Tree	3.91	15.07	31.73	23.17
Random Forest	5.64	16.12	19.47	19.62
XGBoost	16.60	31.63	64.29	53.86
KNN	13.15	19.16	23.02	19.25
SVM	8.60	14.08	16.83	26.17
LSTM (Model 1)	5.40	6.52	6.22	9.71
Transfer Learning LSTM	1.96	3.71	1.32	0.19

表 4.70: 模型比較 (營造工程物價總指數、資料集一、RMSE)

RMSE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	4.25	5.04	2.34	2.44
Decision Tree	1.98	3.88	5.63	4.81
Random Forest	2.38	4.01	4.41	4.43
XGBoost	4.07	5.62	8.02	7.34
KNN	3.63	4.38	4.80	4.39
SVM	2.93	3.75	4.10	5.12
LSTM (Model 1)	2.32	2.55	2.49	3.12
Transfer Learning LSTM	1.40	1.93	1.15	0.44

表 4.71: 模型比較 (營造工程物價總指數、資料集二、MAPE)

MAPE (%)	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	2.47	4.05	3.48	2.78
Decision Tree	3.10	3.54	2.92	3.07
Random Forest	2.74	3.01	2.82	2.99
XGBoost	3.88	3.18	2.87	4.25
KNN	2.15	2.29	2.21	2.61
SVM	2.06	2.95	3.33	4.29
LSTM (Model 1)	2.25	2.47	2.35	1.91
Transfer Learning LSTM	1.06	1.19	0.97	1.44

表 4.72: 模型比較 (營造工程物價總指數、資料集二、MAE)

MAE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	2.67	4.41	3.80	3.04
Decision Tree	3.36	3.85	3.17	3.34
Random Forest	2.97	3.28	3.07	3.26
XGBoost	4.20	3.46	3.12	4.63
KNN	2.33	2.50	2.41	2.84
SVM	2.24	3.21	3.62	4.68
LSTM (Model 1)	2.45	2.68	2.57	2.08
Transfer Learning LSTM	1.15	1.30	1.05	1.57

表 4.73: 模型比較 (營造工程物價總指數、資料集二、MSE)

MSE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	10.15	22.55	19.19	13.44
Decision Tree	16.00	21.81	17.06	14.24
Random Forest	10.08	11.61	10.37	11.03
XGBoost	19.49	14.14	13.77	22.52
KNN	6.37	7.15	6.68	8.38
SVM	5.73	10.93	13.53	22.23
LSTM (Model 1)	6.78	7.80	7.79	4.80
Transfer Learning LSTM	1.74	2.40	1.64	2.75

表 4.74: 模型比較 (營造工程物價總指數、資料集二、RMSE)

RMSE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	3.19	4.75	4.38	3.67
Decision Tree	4.00	4.67	4.13	3.77
Random Forest	3.18	3.41	3.22	3.32
XGBoost	4.42	3.76	3.71	4.75
KNN	2.52	2.67	2.58	2.89
SVM	2.39	3.31	3.68	4.71
LSTM (Model 1)	2.60	2.79	2.79	2.19
Transfer Learning LSTM	1.32	1.55	1.28	1.66

表 4.75: 模型比較 (水泥及其製品類指數、資料集一、MAPE)

MAPE (%)	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	3.91	5.43	7.20	10.27
Decision Tree	1.56	3.20	2.65	8.57
Random Forest	3.15	4.76	6.84	10.16
XGBoost	2.13	5.66	8.85	9.28
KNN	3.69	4.93	7.34	10.89
SVM	4.51	5.60	7.50	11.91
LSTM (Model 1)	1.86	1.27	2.58	2.47
Transfer Learning LSTM	0.46	0.65	0.87	0.73

表 4.76: 模型比較 (水泥及其製品類指數、資料集一、MAE)

MAE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	4.54	6.34	8.52	12.34
Decision Tree	1.78	3.69	3.12	10.30
Random Forest	3.67	5.57	8.09	12.22
XGBoost	2.46	6.62	10.47	11.15
KNN	4.22	5.73	8.68	13.08
SVM	5.27	6.56	8.88	14.31
LSTM (Model 1)	2.14	1.48	3.04	2.96
Transfer Learning LSTM	0.53	0.74	1.01	0.87

表 4.77: 模型比較 (水泥及其製品類指數、資料集一、MSE)

MSE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	24.23	45.68	81.42	165.02
Decision Tree	4.88	27.61	14.85	111.44
Random Forest	16.43	37.04	75.02	152.21
XGBoost	9.66	54.62	129.99	134.67
KNN	27.05	47.55	90.78	184.81
SVM	31.38	47.99	87.97	216.88
LSTM (Model 1)	6.75	3.26	12.43	10.23
Transfer Learning LSTM	0.54	1.26	2.27	1.63

表 4.78: 模型比較 (水泥及其製品類指數、資料集一、RMSE)

RMSE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	4.92	6.76	9.02	12.85
Decision Tree	2.21	5.26	3.85	10.56
Random Forest	4.05	6.09	8.66	12.34
XGBoost	3.11	7.39	11.40	11.60
KNN	5.20	6.90	9.53	13.60
SVM	5.60	6.93	9.38	14.73
LSTM (Model 1)	2.60	1.81	3.53	3.20
Transfer Learning LSTM	0.73	1.12	1.51	1.28

表 4.79: 模型比較 (水泥及其製品類指數、資料集二、MAPE)

MAPE (%)	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	4.16	5.39	6.54	6.44
Decision Tree	5.49	6.70	4.30	7.74
Random Forest	5.62	5.68	4.32	5.73
XGBoost	5.18	5.75	5.31	7.72
KNN	5.83	6.50	7.44	9.14
SVM	2.40	2.75	5.98	4.33
LSTM (Model 1)	2.75	2.78	2.51	2.40
Transfer Learning LSTM	0.87	0.78	0.87	1.34

表 4.80: 模型比較 (水泥及其製品類指數、資料集二、MAE)

MAE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	4.87	6.38	7.80	7.76
Decision Tree	6.50	7.97	5.12	9.32
Random Forest	6.66	6.75	5.14	6.90
XGBoost	6.07	6.82	6.33	9.29
KNN	6.91	7.72	8.86	11.00
SVM	2.82	3.23	7.14	5.21
LSTM (Model 1)	3.18	3.27	3.02	2.90
Transfer Learning LSTM	0.98	0.91	1.02	1.60

表 4.81: 模型比較 (水泥及其製品類指數、資料集二、MSE)

MSE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	29.82	47.85	68.73	70.05
Decision Tree	52.03	75.39	27.78	87.52
Random Forest	52.57	51.06	27.09	48.09
XGBoost	39.99	50.38	41.35	87.60
KNN	56.09	65.66	79.63	121.22
SVM	9.86	11.88	52.10	27.63
LSTM (Model 1)	12.02	12.86	11.35	8.75
Transfer Learning LSTM	1.69	1.14	1.80	4.63

表 4.82: 模型比較 (水泥及其製品類指數、資料集二、RMSE)

RMSE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	5.46	6.92	8.29	8.37
Decision Tree	7.21	8.68	5.27	9.36
Random Forest	7.25	7.15	5.20	6.93
XGBoost	6.32	7.10	6.43	9.36
KNN	7.49	8.10	8.92	11.01
SVM	3.14	3.45	7.22	5.26
LSTM (Model 1)	3.47	3.59	3.37	2.96
Transfer Learning LSTM	1.30	1.07	1.34	2.15

表 4.83: 模型比較 (金屬製品類指數、資料集一、MAPE)

MAPE (%)	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	3.38	4.31	2.82	6.17
Decision Tree	2.15	2.54	4.22	2.29
Random Forest	2.35	2.71	3.28	2.58
XGBoost	2.40	6.84	6.09	3.29
KNN	3.14	4.26	3.16	2.01
SVM	2.83	3.61	2.92	1.33
LSTM (Model 1)	2.63	3.63	2.90	1.93
Transfer Learning LSTM	2.38	3.03	2.02	1.78

表 4.84: 模型比較 (金屬製品類指數、資料集一、MAE)

MAE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	3.54	4.55	2.91	6.32
Decision Tree	2.24	2.70	4.32	2.32
Random Forest	2.49	2.91	3.34	2.60
XGBoost	2.57	7.34	6.29	3.33
KNN	3.33	4.57	3.28	2.05
SVM	3.03	3.91	3.04	1.36
LSTM (Model 1)	2.75	3.82	2.95	1.94
Transfer Learning LSTM	2.45	3.12	2.09	1.80

表 4.85: 模型比較 (金屬製品類指數、資料集一、MSE)

MSE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	18.71	31.66	17.23	56.45
Decision Tree	7.31	12.32	36.82	8.28
Random Forest	10.49	15.87	18.06	8.37
XGBoost	16.10	108.08	64.52	17.50
KNN	20.09	45.71	18.88	6.35
SVM	20.41	35.78	18.24	2.57
LSTM (Model 1)	11.30	20.74	11.69	4.57
Transfer Learning LSTM	8.68	12.29	7.47	3.64

表 4.86: 模型比較 (金屬製品類指數、資料集一、RMSE)

RMSE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	4.33	5.63	4.15	7.51
Decision Tree	2.70	3.51	6.07	2.88
Random Forest	3.24	3.98	4.25	2.89
XGBoost	4.01	10.40	8.03	4.18
KNN	4.48	6.76	4.34	2.52
SVM	4.52	5.98	4.27	1.60
LSTM (Model 1)	3.36	4.55	3.42	2.14
Transfer Learning LSTM	2.95	3.51	2.73	1.91

表 4.87: 模型比較 (金屬製品類指數、資料集二、MAPE)

MAPE (%)	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	5.18	6.05	5.55	7.93
Decision Tree	2.26	2.08	3.37	1.65
Random Forest	1.92	2.40	1.80	1.19
XGBoost	2.23	2.71	2.04	1.41
KNN	3.51	3.40	2.26	0.90
SVM	3.90	3.95	2.47	1.46
LSTM (Model 1)	2.53	2.81	2.37	1.12
Transfer Learning LSTM	2.05	2.28	1.43	0.68

表 4.88: 模型比較 (金屬製品類指數、資料集二、MAE)

MAE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	5.37	6.28	5.69	8.04
Decision Tree	2.35	2.16	3.47	1.70
Random Forest	2.04	2.55	1.87	1.23
XGBoost	2.32	2.93	2.12	1.44
KNN	3.73	3.65	2.36	0.91
SVM	4.21	4.24	2.59	1.51
LSTM (Model 1)	2.74	3.03	2.46	1.15
Transfer Learning LSTM	2.15	2.44	1.49	0.70

表 4.89: 模型比較 (金屬製品類指數、資料集二、MSE)

MSE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	39.43	57.12	42.72	75.64
Decision Tree	8.84	9.01	21.26	5.69
Random Forest	7.59	10.62	8.18	2.73
XGBoost	9.25	18.95	8.26	5.77
KNN	21.97	26.15	11.84	1.13
SVM	36.96	32.62	14.11	4.87
LSTM (Model 1)	18.24	18.77	9.39	2.08
Transfer Learning LSTM	7.57	11.33	4.53	0.79

表 4.90: 模型比較 (金屬製品類指數、資料集二、RMSE)

RMSE	未來第 1 個月	未來第 3 個月	未來第 6 個月	未來第 12 個月
ANN	6.28	7.56	6.54	8.70
Decision Tree	2.97	3.00	4.61	2.39
Random Forest	2.76	3.26	2.86	1.65
XGBoost	3.04	4.35	2.87	2.40
KNN	4.69	5.11	3.44	1.06
SVM	6.08	5.71	3.76	2.21
LSTM (Model 1)	4.27	4.33	3.06	1.44
Transfer Learning LSTM	2.75	3.37	2.13	0.89

4.8 研究結果分析與探討

本研究使用預訓練和微調的方法訓練長短期記憶模型，以預測營造工程物價指數。研究結果表明，不論是在預測營造工程物價總指數、水泥及其製品類指數，或是金屬製品類指數方面，微調整個預訓練模型 (Model 3) 的預測表現均優於直接利用目標域資料集進行訓練之模型 (Model 1)，顯示預訓練與微調的方法能夠顯著提升長短期記憶模型的預測性能。其次，在 Model 1 至 Model 5 中，微調整個預訓練模型 (Model 3) 與僅微調預訓練模型中的第一層 LSTM 層的模型 (Model 5) 的表現最佳次數最多，因此建議後續應用可以針對此二種模型進行更深入的調整與應用。

本研究在預測未來第 1 個月、第 3 個月、第 6 個月和第 12 個月的營造工程物價總指數、水泥及其製品類指數、以及金屬製品類指數時，其最佳模型的平均絕對百分比誤差 (MAPE) 皆小於 2%。在進行工程專案成本預測時，合理的誤差範圍應該根據使用者能夠容許的風險程度來決定。一般來說，預測誤差應該控制在一個較低的範圍內，以確保預測結果的可靠性和準確性。對於不同的工程項目，容許的誤差範圍可能有所不同，但通常應該盡量控制在 5% 以內，以便於預測結果能夠實際應用於專案管理和決策。根據行政院公共工程委員會於 2023 年 11 月 15 日修訂之《工程採購契約範本》[100] 中第 5 條「契約價金之給付條件」顯示，

中分類指數漲跌幅超過 5% 之部分，於估驗完成後調整工程款；以及營造工程物價總指數漲跌幅超過 2.5% 時，可以就超過之部分，於估驗完成後調整工程款。因此，本研究所提出的模型，其預測誤差遠低於契約中允許調整價金的標準範圍。這意味著使用本研究模型進行營造工程物價指數預測，不僅具有高度的準確性，還能有效降低因物價波動導致的成本預算風險。這對於工程專案管理和預算控制具有重要意義，有助於確保專案的順利進行和資金的合理運用。

在源域資料集的時間框架方面，本研究採用了 30 分鐘和 1 天的時間框架，結果顯示相較於 30 分鐘的源域資料集時間框架，使用 1 天作為源域資料集的時間框架對後續模型的預測表現更佳，因其涵蓋年份較廣，使得其長期趨勢與週期性較容易捕捉，且其資料變化較大、噪音較少，較適合模型訓練。在目標域資料集方面，當預測目標為營造工程物價總指數與水泥及其製品類指數時，相較於使用經濟指標資料集，使用技術分析指標資料集能夠獲得更好的預測結果；而在預測金屬製品類指數時，使用經濟指標資料集則能夠得到更好的預測效果，因金屬產品較容易受到整體市場各產業之影響，因此經濟指標更能反映其變化。

最後，將本研究之方法與傳統機器學習模型進行比較，以驗證本研究方法對營造物價預測的性能提升。結果顯示，採用預訓練和微調結合長短期記憶模型的方法能夠有效提升機器學習在營造物價預測方面的表現。尤其是在預測營造工程物價總指數和水泥及其製品類指數方面，能夠有效降低 50% 以上的平均絕對誤差 (MAE)，表明本研究提出的方法具有顯著的有效性。

4.9 實際應用操作流程

本研究利用預訓練與微調方法幫助預測營造工程物價指數。具體來說，源域為匯率資料，目標域為營造工程物價指數。若要直接應用本研究所提出的模型，

只需按照資料集建立流程建立資料集，即可直接應用本研究之模型進行預測。應用本研究之流程請參考圖4.10。



1. 定義目標域：在實際應用本研究的方法之前，首先需要定義目標域，即預測的對象。
2. 定義預測時間：確定目標域後，根據專案時程確定預測時間，例如預測未來第 12 個月的營造工程物價指數，這樣可以最大限度地幫助專案進行成本估算等工作。
3. 是否重新訓練模型：應決定是直接應用本研究的模型，還是根據專案特性重新訓練模型。如果選擇直接使用本研究的模型，只需建立並處理資料集，即可應用該方法進行營造工程物價指數預測。而如果需要重新訓練模型，則需依照定義源域、預訓練與微調等一系列步驟進行。

(a) 否：如果不需要重新訓練模型，只需建立並處理資料集，便可直接應用模型進行預測。

- i. 資料集建立與處理：收集目標域歷史資料，並計算技術分析指標。對資料集進行預處理，包括處理缺失值、異常值以及資料正規化，確保資料品質和格式一致性，以便於後續的模型預測。
- ii. 模型應用：將模型部署到實際應用環境中，並利用建立完成之資料集進行預測。當新資料（如最新發布的營造工程物價指數）可用時，應及時更新資料集並重新訓練模型，以保持模型的準確性和可靠性。

(b) 是：重新訓練模型需要進行以下步驟。

- i. 定義源域：根據目標域特性重新定義預選源域並利用本研究之方法進行選擇，以確定最終源域。

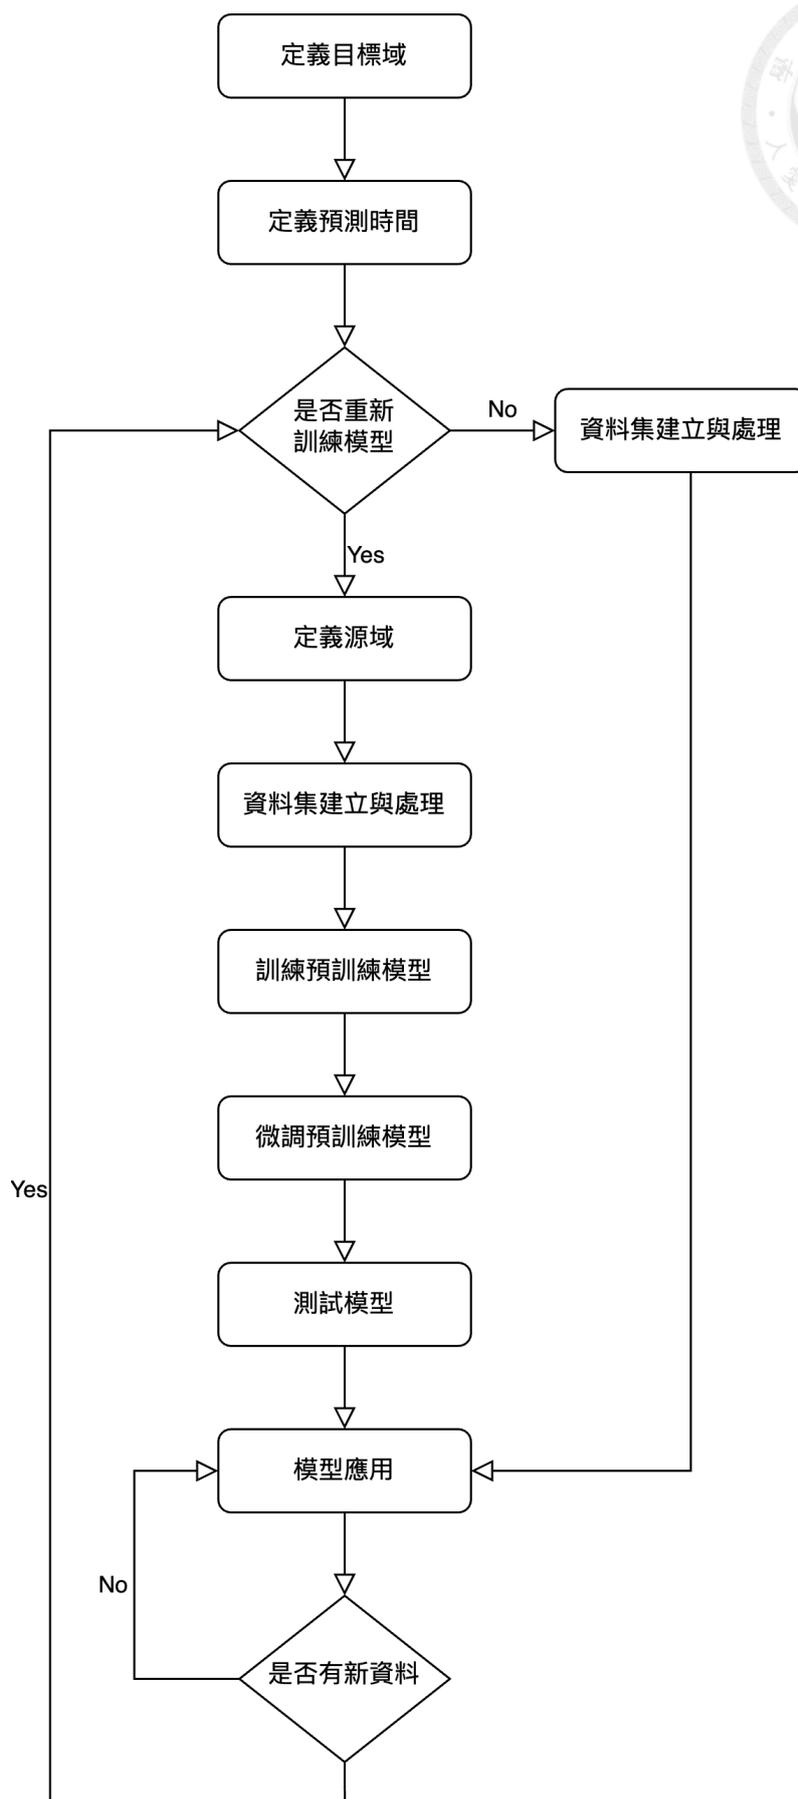


圖 4.10: 實際應用流程圖

- 
- ii. 資料集建立與處理：收集源域與目標域歷史資料，並計算技術分析指標。建立源域資料集與目標域資料集。並對各資料集進行預處理，包括處理缺失值、異常值以及資料正規化，確保資料品質和格式一致性。最後將資料集分割為訓練集、驗證集與測試集。以便於後續的模型訓練。
 - iii. 訓練預訓練模型：利用源域資料集訓練預訓練模型，這有助於模型學習源域資料中的潛在模式和結構。
 - iv. 微調模型：利用目標域資料集對預訓練模型進行微調，這能使模型更好地適應目標域的特定資料和預測需求。
 - v. 測試模型：微調模型後，應利用測試集對模型進行測試，以評估模型在未見過的數據上的表現，確保模型的預測能力和可靠性。
 - vi. 模型應用：模型訓練完成後，將模型部署到實際應用環境中。當新資料（如最新發布的營造工程物價指數）可用時，應及時更新資料集並重新訓練模型，以保持模型的準確性和可靠性。

4. 是否有新資料：根據是否有新資料，決定下一個循環的步驟。當有新資料時，應重新訓練模型以保持模型的最新狀態。

透過上述步驟，即可依照本研究的框架預測其他營造工程物價指數，從而提高預測的精確度和實用性，幫助專案進行達到較為精準的成本估計、投標價格預測等，從而支持營建專案的順利進行。舉例而言，當一個 12 層樓鋼結構國民住宅專案在開始之際，需要估計材料成本時，為了避免後續因物價波動而導致契約價金變動，專案團隊可以利用上述流程進行一年後的型鋼價格預測。這樣可以確保成本估計的準確性，避免契約價金變動，並提升成本預算控制的能力。通過準確的價格預測，專案團隊可以做出更精準的成本估算和投標決策，從而支持整個專案的順利進行。



第五章 結論與未來研究方向

5.1 結論

本研究提出了一種利用預訓練與微調，結合長短期記憶（LSTM）模型預測營建物價指數之方法，以解決營造工程物價指數資料量不足之問題，並填補應用深度學習預測短期與長期營建物價之相關研究的空白。本研究透過 14 種衡量兩個域之間相似程度的方法針對候選源域進行分析比較，從 7 種候選貨幣匯率源域中選出了最適合營造工程物價總指數、水泥及其製品類指數、金屬製品類指數的源域。源域選擇之結果顯示，相較於其他 6 種貨幣匯率資料，新台幣兌日圓的匯率與營造工程物價總指數以及水泥及其製品類指數最為相似；而新台幣兌韓元的匯率與金屬製品類指數最為相似。此外，源域資料集的時間框架可分為 30 分鐘和 1 天，研究結果表明，使用 1 天時間框架的源域資料集對後續模型的預測表現更佳。目標域資料集方面，本研究分別使用技術分析指標資料集與經濟指標資料集，以技術分析指標取代過往文獻常用之總體經濟指標、市場條件等變數，以有效減少資料收集時間與人力成本。透過比較後發現，運用技術分析指標作為資料集預測營造工程物價總指數與水泥及其製品類指數之表現優於使用經濟指標資料集之模型。然而，在預測金屬製品類指數方面，因金屬為市場大宗交易商品之一，其較容易受到總體經濟、市場條件等因素之影響，因此在預測金屬製品類指數時，以經濟指標作為資料集之模型預測表現仍然較佳。



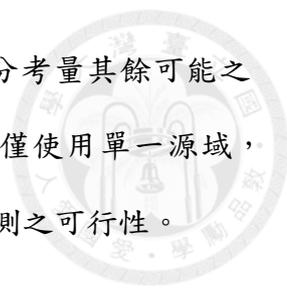
本研究之預測模型採用長短期記憶模型 (LSTM)，其中包含兩層 LSTM 層，後面接兩層全連接層。模型預測結果顯示，本研究所提之方法能夠有效提升機器學習模型預測營建物價之表現，在預測營造工程物價總指數與水泥及其製品類指數時，至少能夠降低 50% 之平均絕對誤差 (MAE)。其中，微調整個預訓練模型與僅微調預訓練模型中第一層 LSTM 層之模型的預測表現最佳。與過往 6 種機器學習模型相比，本研究所提方法之預測表現較優，顯示利用遷移學習訓練深度學習模型預測營建物價之可發展性。

總的來說，本研究為第一個提出利用預訓練與微調結合長短期記憶模型之框架與方法以預測營建物價指數之研究。以解決過往營造工程物價指數資料量較少之難題，並有效提升機器學習應用於營建物價預測之表現。不僅如此，本研究填補利用深度學習模型預測短期與長期營建物價之研究空白，彌補過往預測長期營建物價相關文獻之缺漏，使預測營建物價之方法能與實務方面更為貼合。此外，本研究以技術分析指標替代經濟指標，以避免資料收集之時間與人力成本的浪費。最後，本研究提出了一項創新方法，為未來相關研究開啟了新的思路。同時，本研究提供實際應用本研究方法之流程說明，也為營建業界提供了更準確的預測和管理成本的手段。這些成果對於營建領域的實踐和研究都具有重要的參考價值，能夠提升工程項目的管理效率和成功率。

5.2 研究限制

本研究所用之方法有些許限制，未來應可針對這些限制進行更深入之探討。本研究之限制包含以下幾點：

- 源域選擇限制

- 
- 選擇源域資料時，本研究僅考慮匯率資料，而未充分考量其餘可能之資料來源，例如股價資料、查詢頻率等。且本研究僅使用單一源域，而未考慮使用多元源域（Multi Source Domain）對預測之可行性。
 - 本研究採用之源域選擇方法需有相同之時間序列長度。因此為配合營造工程物價指數之時間序列長度，候選源域於選擇時之時間框架為 1 個月。而不是後續用於訓練預訓練模型之 30 分鐘或 1 天之時間框架。因此無法確定當時間框架為 30 分鐘或 1 天時，候選源域與目標域之間的相似程度。
 - 特徵選擇限制：本研究未考量不同滑動窗口大小對預測結果之影響。此外，對於源域資料集與目標域資料集之特徵沒有進行詳細的特徵篩選。同時，本研究未加入能夠及時反映市場情況的特徵，例如新聞文字分析、查詢頻率等，這些即時數據可能提供更有價值的市場動態信息。
 - 模型限制：本研究中，預訓練模型與後續模型的輸入變數數量需保持一致，這限制了模型在不同數據環境下的靈活性。此外，預訓練模型與後續模型的架構也需相同，這可能限制了模型設計的創新性和適應性，無法充分利用不同模型架構的優勢來提升預測表現。此外，本研究僅使用 LSTM 模型，而未使用其他機器學習模型或深度學習模型。
 - 本研究僅使用預訓練與微調這一遷移學習方法，未考慮其他潛在有效的遷移學習方法，例如基於實例的遷移學習方法（Instance-based Transfer Learning）、特徵表示遷移方法（Feature-representation-transfer Approach）等。這種單一的方法可能限制了遷移學習技術在不同應用場景下的適用性和效果，未能全面探索遷移學習在預測營造工程物價指數中的潛力。

綜上所述，儘管這項研究提出了新的方法並在一定程度上改善了營建物價指

數預測的表現，但仍然存在資料限制、模型泛化能力與實踐應用等方面的限制，需要進一步研究和改進。



5.3 未來研究方向

本研究為首個將遷移學習應用於營建物價預測之研究，後續還有諸多方面能夠改善與發展。本小節針對未來研究提供建議：

- 源域選擇：未來能夠增加源域選擇之範圍，例如股價、查詢頻率等，並且能夠比較何種源域選擇方法較適合用於時間序列資料之營建物價指數。不僅如此，也能夠應用多元源域幫助改善目標域之學習，以期提高模型最終預測表現。
- 特徵選擇：可以考量不同滑動窗口大小對模型預測表現之影響，包含源域之滑動窗口大小與目標域之滑動窗口大小。而在技術分析指標方面，可以對不同的參數設置進行嘗試。並且能夠加入特徵選擇，以期提升模型預測性能，此外，還能夠加入可以即時反映市場心理之特徵，例如文字情感分析、查詢頻率、地點等資訊，以幫助預測之即時性以及特定專案之預測性能。
- 增加預測時間：可以針對不同需求增加預測之時間，且針對政府機關之招標採購時程，應需要預測 2 年以上之營建物價，對應用方面會更有幫助。
- 優化現有模型架構：本研究之模型些許限制，後續應可持續發展此模型以解決輸入變數數量與模型架構之限制。
- 應用不同深度學習模型：可以嘗試不同的深度學習模型，以找出最佳應用的模型，例如可以嘗試應用 CNN、CNN-LSTM、Transformer、N-BEATS、GAN 等模型。但是模型複雜度的提高勢必也需要提高資料的質與量，因此

如何在使用更複雜、可能也夠有效之模型的同時，發展一套方法或策略提高資料的質與量是未來有趣的挑戰。

- 應用不同遷移學習方法：未來可以應用不同的遷移學習方法，例如能夠將源域中的某些資料，透過重新加權或不同的計算方式進行組合，使得源域資料能夠直接在目標域中使用，以更好的幫助目標域進行學習。或是將源域以及目標域的特徵投影到相同的特徵空間等方法。
- 應用元學習 (Meta Learning)：除了應用遷移學習之外，元學習也是值得嘗試之領域。元學習透過在多個任務上學習，使得模型能夠更快地適應新任務，提高預測的準確性和泛化能力，從而為預測任務提供了有效的解決方案，並且能夠學習出適合於不同預測任務的特徵表示和模型結構，從而減少手動特徵工程和模型選擇的工作量。

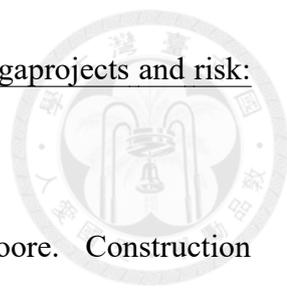
以上這些方向可以為延續本研究提供有價值的指引和啟發，有助於進一步發展和完善營建物價預測的相關研究。

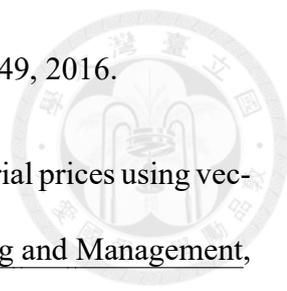




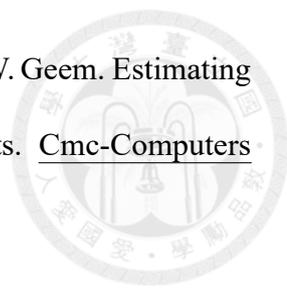
參考文獻

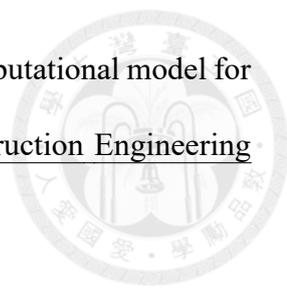
- [1] 行政院主計總處. 營造工程物價指數, 2024.
- [2] Akshay Tondak. Recurrent neural networks (rnn) tutorial: Rnn training, advantages disadvantages (complete guidance), 2023. June 23, 2023.
- [3] Oinkina and Hakyll. Understanding lstm networks, 2015. August 27, 2015.
- [4] S. J. Pan and Q. Yang. A survey on transfer learning. IEEE Transactions on Knowledge and Data Engineering, 22(10):1345–1359, 2010.
- [5] L. Torrey and J. Shavlik. Transfer learning, pages 242–264. IGI Global, 2009.
- [6] 行政院主計總處. 編製方法說明營造工程物價指數. Report, 行政院主計總處, 2023.
- [7] 林秀貞. 國際油價波動對重要營建材料成本影響之研究 -以鋼筋、水泥、砂石、瀝青為例. Thesis, 國立中央大學, 2007.
- [8] 謝政達. 營建成本居高 營建技術新思維. 營建知訊, 430:30–36, 2018.
- [9] S. Hwang, M. Park, H. S. Lee, and H. Kim. Automated time-series cost forecasting system for construction materials. Journal of Construction Engineering and Management, 138(11):1259–1269, 2012.

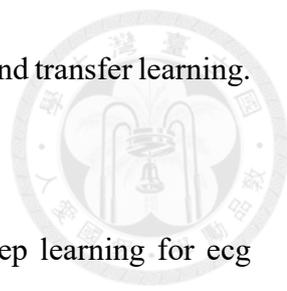
- 
- [10] Bent Flyvbjerg, Nils Bruzelius, and Werner Rothengatter. Megaprojects and risk: An anatomy of ambition. Cambridge university press, 2003.
- [11] Abdulelah Aljohani, Dominic Ahiaga-Dagbui, and David Moore. Construction projects cost overrun: What does the literature tell us? International Journal of Innovation, Management and Technology, 8(2):137, 2017.
- [12] J. W. Xu and S. Moon. Stochastic forecast of construction cost index using a cointegrated vector autoregression model. Journal of Management in Engineering, 29(1):10–18, 2013.
- [13] M. A. Musarat, W. S. Alaloul, M. S. Liew, A. Maqsoom, and A. H. Qureshi. Investigating the impact of inflation on building materials prices in construction industry. Journal of Building Engineering, 32:14, 2020.
- [14] A Uchechukwu Elinwa and Silas A Buba. Construction cost factors in nigeria. Journal of construction engineering and management, 119(4):698–713, 1993.
- [15] 行政院公共工程委員會. 申訴統計資料 111. Report, 行政院公共工程委員會, 2023.
- [16] 羅韋淵. 公共工程契約中物價調整機制之問題研究. Thesis, 國立政治大學, 2009.
- [17] 陳誌泓, 陳信至, and 廖育良. 工程契約中情事變更原則爭議之若干檢討—以臺灣物價調整款爭議為中心 (上). 萬國法律, 249:110–113, 2023.
- [18] 陳誌泓, 陳信至, and 廖育良. 工程契約中情事變更原則爭議之若干檢討—以臺灣物價調整款爭議為中心 (下). 萬國法律, 250:94–97, 2023.
- [19] 黃泰鋒 and 陳麗嘉. 營建物價調整常見爭議問題探討. 工程仲裁, 2008.

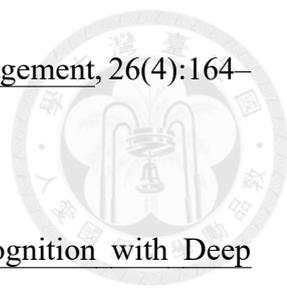
- 
- [20] 劉嘉怡. 從相關判決看物價調整款爭議. 營建知訊, 401:45–49, 2016.
- [21] S. A. M. Faghih and H. Kashani. Forecasting construction material prices using vector error correction model. Journal of Construction Engineering and Management, 144(8):12, 2018.
- [22] M. Hiransha, E. A. Gopalakrishnan, V. K. Menon, and K. P. Soman. Nse stock market prediction using deep-learning models. In S. Singh, V. K. Asari, R. B. Patel, and P. Sidike, editors, Procedia Computer Science, volume 132, pages 1351–1362. Elsevier B.V., 2018.
- [23] M. Marzouk and A. Amin. Predicting construction materials prices using fuzzy logic and neural networks. Journal of Construction Engineering and Management, 139(9):1190–1198, 2013.
- [24] Pushpendu Ghosh, Ariel Neufeld, and Jajati Keshari Sahoo. Forecasting directional movements of stock prices for intraday trading using lstm and random forests. Finance Research Letters, 46:102280, 2022.
- [25] Luckyson Khaidem, Snehanshu Saha, and Sudeepa Roy Dey. Predicting the direction of stock market prices using random forest. arXiv preprint arXiv:1605.00003, 2016.
- [26] Sidra Mehtab and Jaydip Sen. Stock price prediction using convolutional neural networks on a multivariate timeseries. arXiv preprint arXiv:2001.09769, 2020.
- [27] 林楷竣. 以自適應性風險交易策略建構集成式學習投資組合決策系統. Thesis, 國立臺灣科技大學, 2023.
- [28] PHAM TRAN BAO QUY. Multiobjective-optimized construction stock portfolio

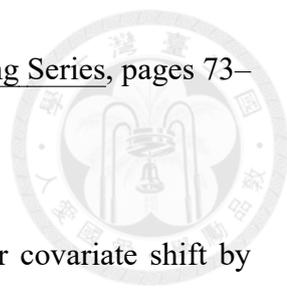
- 
- investment strategy based on profitability prediction. Thesis, 國立臺灣科技大學, 2023.
- [29] Yue-Gang Song, Yu-Long Zhou, and Ren-Jie Han. Neural networks for stock price prediction. arXiv preprint arXiv:1805.11317, 2018.
- [30] Sidra Mehtab, Jaydip Sen, and Abhishek Dutta. Stock price prediction using machine learning and lstm-based deep learning models. In Machine Learning and Metaheuristics Algorithms, and Applications: Second Symposium, SoMMA 2020, Chennai, India, October 14–17, 2020, Revised Selected Papers 2, pages 88–106. Springer, 2021.
- [31] Ehsan Hoseinzade and Saman Haratizadeh. Cnnpred: Cnn-based stock market prediction using a diverse set of variables. Expert Systems with Applications, 129:273–285, 2019.
- [32] A. Maratkhan, I. Ilyassov, M. Aitzhanov, M. F. Demirci, and A. M. Ozbayoglu. Deep learning-based investment strategy: technical indicator clustering and residual blocks. Soft Computing, 25(7):5151–5161, 2021.
- [33] H Lin, C Chen, G Huang, and A Jafari. Stock price prediction using generative adversarial networks. J. Comp. Sci, pages 17,188–196, 2021.
- [34] Ching-Hwang Wang and Yong-Ho Mei. Model for forecasting construction cost indices in taiwan. Construction Management and Economics, 16(2):147–157, 1998. doi: 10.1080/014461998372457.
- [35] Chi-Young Choi, Kyeong Rok Ryu, and Mohsen Shahandashti. Predicting city-level construction cost index using linear forecasting models. Journal of Construction Engineering and Management, 147(2):04020158, 2021.

- 
- [36] U. Isikdag, A. Hepsag, S. I. Biyikli, D. Oez, G. Bekdas, and Z. W. Geem. Estimating construction material indices with arima and optimized narnets. Cmc-Computers Materials Continua, 74(1):113–129, 2023.
- [37] 邱敏鋒. 運用支撐向量機建構營建材料供應商使用衍生性金融商品避險之預測模型. 2008.
- [38] T. Moon and D. H. Shin. Forecasting model of construction cost index based on vecm with search query. Ksce Journal of Civil Engineering, 22(8):2726–2734, 2018.
- [39] Trefor P. Williams. Predicting changes in construction cost indexes using neural networks. Journal of Construction Engineering and Management, 120(2):306–320, 1994.
- [40] A. Shiha, E. M. Dorra, and K. Nassar. Neural networks model for prediction of construction material prices in egypt using macroeconomic indicators. Journal of Construction Engineering and Management, 146(3):16, 2020.
- [41] M. Mir, H. M. D. Kabir, F. Nasirzadeh, and A. Khosravi. Neural network-based interval forecasting of construction material prices. Journal of Building Engineering, 39:13, 2021.
- [42] 馮重偉 and 江怡萱. 結合深度學習及關鍵字搜尋熱度趨勢於臺灣鋼筋價格漲跌幅之預測. 中國土木水利工程學刊, 33(8):595–604, 2021.
- [43] Min-Yuan Cheng, Nhat-Duc Hoang, and Yu-Wei Wu. Hybrid intelligence approach based on ls-svm and differential evolution for construction cost index estimation: A taiwan case study. Automation in Construction, 35:306–313, 2013.

- 
- [44] Minh-Tu Cao, Min-Yuan Cheng, and Yu-Wei Wu. Hybrid computational model for forecasting taiwan construction cost index. Journal of Construction Engineering and Management, 141(4):04014089, 2015.
- [45] B. Q. Tang, J. Han, G. F. Guo, Y. Chen, and S. Zhang. Building material prices forecasting based on least square support vector machine and improved particle swarm optimization. Architectural Engineering and Design Management, 15(3):196–212, 2019.
- [46] Y. Du, J. Wang, W. Feng, S. Pan, T. Qin, R. Xu, and C. Wang. Adarnn: Adaptive learning and forecasting of time series. In International Conference on Information and Knowledge Management, Proceedings, pages 402–411. Association for Computing Machinery, 2021.
- [47] Ngoc-Quang Nguyen. Short-term Prediction of Regional Energy Consumption by Jellyfish Search-Optimized Deep Learning Models. Thesis, National Taiwan University of Science and Technology, 2023.
- [48] M. Ribeiro, K. Grolinger, H. F. ElYamany, W. A. Higashino, and M. A. M. Capretz. Transfer learning with seasonal and trend adjustment for cross-building energy forecasting. Energy and Buildings, 165:352–363, 2018.
- [49] Haixiang Zang, Lilin Cheng, Tao Ding, Kwok W. Cheung, Zhinong Wei, and Guoqiang Sun. Day-ahead photovoltaic power forecasting approach based on deep convolutional neural networks and meta learning. International Journal of Electrical Power Energy Systems, 118:105790, 2020.
- [50] S. Raghu, N. Sriraam, Y. Temel, S. V. Rao, and P. L. Kubben. Eeg based multi-class

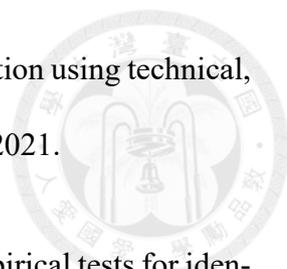
- 
- seizure type classification using convolutional neural network and transfer learning. Neural Networks, 124:202–212, 2020.
- [51] N. Strodthoff, P. Wagner, T. Schaeffter, and W. Samek. Deep learning for ecg analysis: Benchmarks and insights from ptb-xl. IEEE Journal of Biomedical and Health Informatics, 25(5):1519–1528, 2021.
- [52] Hyeong Kyu Choi. Stock price correlation coefficient prediction with arima-lstm hybrid model. arXiv preprint arXiv:1808.01560, 2018.
- [53] 龔千芬 and 郝沛毅. 融合深度神經網路與深層模糊學生支持向量機於股價預測. 資訊管理學報, 29(4):303–333, 2022.
- [54] W. Bao, J. Yue, and Y. Rao. A deep learning framework for financial time series using stacked autoencoders and long-short term memory. PLoS ONE, 12(7), 2017.
- [55] Mehtabhorn Obthong, Nongnuch Tantisantiwong, Watthanasak Jeamwatthanachai, and Gary Wills. A survey on machine learning for stock price prediction: algorithms and techniques, 2020.
- [56] Stéphane Goutte, Hoang-Viet Le, Fei Liu, and Hans-Jörg von Mettenheim. Deep learning and technical analysis in cryptocurrency market. Finance Research Letters, 54:103809, 2023.
- [57] Sidra Mehtab and Jaydip Sen. A robust predictive model for stock price prediction using deep learning and natural language processing. arXiv preprint arXiv:1912.07700, 2019.
- [58] Mahla Nikou, Gholamreza Mansourfar, and Jamshid Bagherzadeh. Stock price prediction using deep learning algorithm and its comparison with machine learning al-

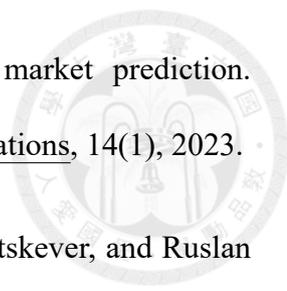
- 
- gorithms. Intelligent Systems in Accounting, Finance and Management, 26(4):164–174, 2019.
- [59] Marc Velay and Fabrice Daniel. Stock Chart Pattern recognition with Deep Learning. 2018.
- [60] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. Neural computation, 9(8):1735–1780, 1997.
- [61] S. Ben-David, J. Blitzer, K. Crammer, A. Kulesza, F. Pereira, and J. W. Vaughan. A theory of learning from different domains. Machine Learning, 79(1-2):151–175, 2010.
- [62] J. Lu, V. Behbood, P. Hao, H. Zuo, S. Xue, and G. Zhang. Transfer learning using computational intelligence: A survey. Knowledge-Based Systems, 80:14–23, 2015.
- [63] K. Weiss, T. M. Khoshgoftaar, and D. D. Wang. A survey of transfer learning. Journal of Big Data, 3(1), 2016.
- [64] C. Tan, F. Sun, T. Kong, W. Zhang, C. Yang, and C. Liu. A survey on deep transfer learning. In Y. Manolopoulos, B. Hammer, V. Kurkova, L. Iliadis, and I. Maglogiannis, editors, Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), volume 11141 LNCS, pages 270–279. Springer Verlag, 2018.
- [65] Jason Yosinski, Jeff Clune, Yoshua Bengio, and Hod Lipson. How transferable are features in deep neural networks? Advances in neural information processing systems, 27:pages 3320–3328, 2014.
- [66] H. Xu, B. Xu, J. He, and J. Bi. Deep transfer learning based on lstm model in stock

- 
- price forecasting. In ACM International Conference Proceeding Series, pages 73–80. Association for Computing Machinery, 2021.
- [67] Hidetoshi Shimodaira. Improving predictive inference under covariate shift by weighting the log-likelihood function. Journal of statistical planning and inference, 90(2):227–244, 2000.
- [68] F. Zhuang, Z. Qi, K. Duan, D. Xi, Y. Zhu, H. Zhu, H. Xiong, and Q. He. A comprehensive survey on transfer learning. Proceedings of the IEEE, 109(1):43–76, 2021.
- [69] E. Otović, M. Njirjak, D. Jozinović, G. Mauša, A. Michelini, and I. Štajduhar. Intra-domain and cross-domain transfer learning for time series data—how transferable are the features? Knowledge-Based Systems, 239, 2022.
- [70] J. Wang, Q. Gu, J. Wu, G. Liu, and Z. Xiong. Traffic speed prediction and congestion source exploration: A deep learning method. In F. Bonchi, J. Domingo-Ferrer, R. Baeza-Yates, Z. H. Zhou, and X. Wu, editors, Proceedings - IEEE International Conference on Data Mining, ICDM, volume 0, pages 499–508. Institute of Electrical and Electronics Engineers Inc., 2016.
- [71] S. Shao, S. McAleer, R. Yan, and P. Baldi. Highly accurate machine fault diagnosis using deep transfer learning. IEEE Transactions on Industrial Informatics, 15(4):2446–2455, 2019.
- [72] Z. Cen and J. Wang. Crude oil price prediction model with long short term memory deep learning based on prior knowledge data transfer. Energy, 169:160–171, 2019.
- [73] J. Ma, J. C. P. Cheng, C. Lin, Y. Tan, and J. Zhang. Improving air quality prediction

- accuracy at larger temporal resolutions using deep learning and transfer learning techniques. Atmospheric Environment, 214, 2019.
- [74] M. Kraus and S. Feuerriegel. Decision support from financial disclosures with deep neural networks and transfer learning. Decision Support Systems, 104:38–48, 2017.
- [75] K. Mishev, A. Gjorgjevikj, I. Vodenska, L. Chitkushev, W. Souma, and D. Trajanov. Forecasting corporate revenue by using deep-learning methodologies. In Proceedings - 2019 3rd International Conference on Control, Artificial Intelligence, Robotics and Optimization, ICCAIRO 2019, pages 115–120. Institute of Electrical and Electronics Engineers Inc., 2019.
- [76] Q. Q. He, P. C. I. Pang, and Y. W. Si. Multi-source transfer learning with ensemble for financial time series forecasting. In J. He, H. Purohit, G. Huang, X. Gao, and K. Deng, editors, Proceedings - 2020 IEEE/WIC/ACM International Joint Conference on Web Intelligence and Intelligent Agent Technology, WI-IAT 2020, pages 227–233. Institute of Electrical and Electronics Engineers Inc., 2020.
- [77] T. T. Nguyen and S. Yoon. A novel approach to short-term stock price movement prediction using transfer learning. Applied Sciences (Switzerland), 9(22), 2019.
- [78] Y. Li, H. N. Dai, and Z. Zheng. Selective transfer learning with adversarial training for stock movement prediction. Connection Science, 34(1):492–510, 2022.
- [79] 王晋东. 迁移学习导论. 电子工业出版社, 2021.
- [80] H. I. Fawaz, G. Forestier, J. Weber, L. Idoumghar, and P. A. Muller. Transfer learning for time series classification. In N. Abe, H. Liu, C. Pu, X. Hu, N. Ahmed,

- 
- M. Qiao, Y. Song, D. Kossmann, B. Liu, K. Lee, J. Tang, J. He, and J. Saltz, editors, Proceedings - 2018 IEEE International Conference on Big Data, Big Data 2018, pages 1367–1376. Institute of Electrical and Electronics Engineers Inc., 2018.
- [81] 台灣財政部關務署. 台灣財政部關務署海關進出口統計網, 2024. May 01, 2024.
- [82] 財政部. 鋼鐵業原物料耗用通常水準. Report, 財政部, 2023.
- [83] 台灣區水泥工業同業公會. 2023 年度台灣區水泥工業同業公會年報. Report, 台灣區水泥工業同業公會, 2023.
- [84] 張清榮 and 游珊蓉. 營造工程物價指數與國內外大宗物資與金融指數相關性研究, 2014.
- [85] 游珊蓉. 營造工程物價指數預測之研究-以徑路分析模式. Thesis, 中華大學, 2015.
- [86] Mehar Vijh, Deeksha Chandola, Vinay Anand Tikkiwal, and Arun Kumar. Stock closing price prediction using machine learning techniques. Procedia Computer Science, 167:599–606, 2020.
- [87] J. Patel, S. Shah, P. Thakkar, and K. Kotecha. Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. Expert Systems with Applications, 42(1):259–268, 2015.
- [88] HS Hota, Richa Handa, and Akhilesh Kumar Shrivastava. Time series data prediction using sliding window based rbf neural network. International Journal of Computational Intelligence Research, 13(5):1145–1156, 2017.

- 
- [89] Shan Zhong and David B Hitchcock. Sp 500 stock price prediction using technical, fundamental and text data. arXiv preprint arXiv:2108.10826, 2021.
- [90] Baabak Ashuri, Seyed Mohsen Shahandashti, and Jian Lu. Empirical tests for identifying leading indicators of enr construction cost index. Construction Management and Economics, 30(11):917–927, 2012. doi: 10.1080/01446193.2012.728709.
- [91] 李呈芳, 王小龍, and 黃依典. 營建工程工料變動對營建產業影響之探討. 萬能學報, 31:193–211, 2009.
- [92] Abimbola Windapo and Keith Cattell. Examining the trends in building material prices: built environment stakeholders’ perspectives. Manage Construct Res Pract, 1:187–201, 2012.
- [93] Vladimir Braverman, Rafail Ostrovsky, and Carlo Zaniolo. Optimal sampling from sliding windows, 2009.
- [94] Jin Yang, Hugues Rivard, and Radu Zmeureanu. On-line building energy prediction using adaptive artificial neural networks. Energy and Buildings, 37(12):1250–1259, 2005.
- [95] Ralf-Peter Mundani, Jérôme Frisch, Vasco Varduhn, and Ernst Rank. A sliding window technique for interactive high-performance computing scenarios. Advances in Engineering Software, 84:21–30, 2015.
- [96] Jui-Sheng Chou and Thi Truong. Sliding-window metaheuristic optimization-based forecast system for foreign exchange analysis. Soft Computing, 23:3545 – 3561, 2019.

- 
- [97] Akash Deep. A multifactor analysis model for stock market prediction. International Journal of Computer Science and Telecommunications, 14(1), 2023.
- [98] Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, and Ruslan Salakhutdinov. Dropout: A simple way to prevent neural networks from overfitting. Journal of Machine Learning Research, 15(56):1929–1958, 2014.
- [99] Yitong Duan, Lei Wang, Qizhong Zhang, and Jian Li. Factorvae: A probabilistic dynamic factor model based on variational autoencoder for predicting cross-sectional stock returns. In Proceedings of the AAAI Conference on Artificial Intelligence, volume 36, pages 4468–4476, 2022.
- [100] 行政院公共工程委員會. 工程採購契約範本 (112.11.15 修正). Government document, 行政院公共工程委員會, 2023.