

國立臺灣大學工學院工程科學及海洋工程學系


碩士論文

Department of Engineering Science and Ocean Engineering

College of Engineering

National Taiwan University

Master's Thesis



基於圖神經網路之城市交通狀態預測研究：以三種交通系統為例

Graph Neural Network Approach for Urban Traffic State Prediction: Three Transportation Systems Analysis

林子傑

Zih-Jie Lin

指導教授：黃乾綱 博士

Advisor: Chien-Kang Huang, Ph.D.

中華民國 114 年 6 月

June, 2025

國立臺灣大學碩士學位論文
口試委員會審定書

MASTER'S THESIS ACCEPTANCE CERTIFICATE
NATIONAL TAIWAN UNIVERSITY

基於圖神經網路之城市交通狀態預測研究：以三種交
通系統為例

Graph Neural Network Approach for Urban Traffic State
Prediction: Three Transportation Systems Analysis

本論文係林子傑（學號：R10525069）在國立臺灣大學工程科學及海洋工程學系
完成之碩士學位論文，於民國 114 年 05 月 21 日承下列考試委員審查通過及口
試及格，特此證明。

The undersigned, appointed by the Department of Engineering Science and Ocean Engineering on
21st May 2025 have examined a Master's Thesis entitled above presented by LIN, ZIH-JIE (student
ID:R10525069) candidate and hereby certify that it is worthy of acceptance.

口試委員 Oral examination committee:

黃乾綱

(指導教授 Advisor)

張信宏

張恆華

張瑞益

系（所、學位學程）主管 Director:

趙川武

致謝

多花了一點時間在論文上，不過最後還是通過了。首先要感謝我的指導教授黃乾綱老師，提供研究的方向與思路，讓我的研究順利進行。謝謝同屆的怡萱、敬翔和仙惠，有你們的陪伴，在研究這條路上並不苦悶。還要謝謝學弟妹，在口試當天幫助我，讓我的口試順利進行。

最重要的，是要感謝我家人，在研究的日子中偶爾有挫折感，但有家人在背後支持我，讓我無後顧之憂地研究，最終完成這份論文。

摘要

交通運輸已成為現今社會生活中不可或缺的一部分，各國皆致力於發展大眾運輸與共享式載具，以減少交通壅塞並降低運輸成本。準確預測交通狀態有助於優化運輸規劃，提高交通效率。


近年來，許多研究利用圖神經網路（Graph Neural Network, GNN）來預測交通狀態，GNN 能夠同時捕捉時間與空間上的關聯性，為交通狀態預測帶來重大進展。然而，由於大眾運輸與共享式載具站點之間的關係高度動態，如何有效定義空間關係仍是一大挑戰，但現有的 GNN 模型尚未充分考慮空間關係的多樣性。

本研究提出多圖時空轉換器（Multi Graph Spatial Temporal Transformer，MGSTT），能夠有效捕捉不同空間關係下的特徵，並透過將外部因素轉換為嵌入，以提升模型的預測能力。實驗方面，本研究不僅使用常被用於評估的高速公路交通資料集，還自行收集台灣的大眾運輸與共享式交通資料集進行測試，藉此評估模型在不同類型交通數據上的適用性與廣泛性。

關鍵字：深度學習、圖神經網路、時空資料預測、交通資料預測、高速公路、大眾運輸、共享式交通



Abstract



Nowadays, transportation has become a part of daily life in modern society. Many countries develop Transportation has become an essential part of modern society. Many countries are actively developing public transportation and shared mobility solutions to reduce traffic congestion and transportation costs. Accurate traffic state prediction plays a crucial role in optimizing transportation planning and improving efficiency.

In recent years, Graph Neural Networks (GNNs) have been widely used for traffic state prediction due to their ability to capture both spatial and temporal dependencies, leading to significant advancements in this field. However, public transportation and shared mobility systems exhibit highly dynamic relationships between stations, making it challenging to define spatial relationships effectively. Existing GNN-based models have yet to fully consider the diversity of spatial relationships, which limits their predictive performance.

This study proposes the Multi Graph Spatial Temporal Transformer (MGSTT), which effectively captures features under various spatial relationships and enhances predictive performance by embedding external factors. In the experiments, in addition to using commonly adopted highway traffic datasets, this study also collects public transportation and shared mobility datasets from Taiwan to evaluate the model's adaptability and generalizability across different types of traffic data.

Keywords: Deep Neural Network , Graph Neural Network, Spatial-Temporal Data Forecasting, Traffic Data Forecasting, Highway, Public Transportation, Shared Mobility



目次




	Page
致謝	II
摘要	III
Abstract	IV
目次	VI
圖目次	IX
表目次	XII
演算法目次	XV
第一章 緒論	1
1.1 研究背景	1
1.2 研究動機	2
1.3 研究目標與貢獻	2
1.4 論文架構	3
第二章 相關背景知識及文獻	5
2.1 交通狀態預測問題	5
2.2 圖神經網路	6
2.3 時空同步圖形卷積網路	7
2.4 時空融合圖形卷積網路	8
2.5 圖多重注意力網路	8
2.6 時空圖注意力網路	9
2.7 多圖空間注意力機制	10
2.8 整合外部因素	10

第三章	研究方法	13
3.1	實驗流程	13
3.2	建立關係圖	14
3.2.1	空間相鄰圖	14
3.2.2	流量連結圖	14
3.2.3	流量變化相似圖	14
3.2.4	流量分布相似圖	17
3.3	提出模型：多圖時空轉換器	19
3.3.1	強化特徵提取能力	20
3.3.2	替換空間嵌入	21
3.3.3	多圖空間注意力區塊	22
3.3.4	輸出層調整	22
3.3.5	改進測試機制	23
3.3.6	損失函數	24
第四章	研究結果及討論	25
4.1	比較模型	25
4.2	實驗設置	25
4.3	評估指標 (Metric)	26
4.4	在高速公路資料集的比較	27
4.4.1	高速公路資料集—PEMS04、PEMS08	27
4.4.2	PEMS04 資料集的統計分析	32
4.4.3	PEMS08 資料集的統計分析	35
4.4.4	PEMS04 和 PEMS08 資料集實驗結果	39
4.4.5	關係圖對 PEMS04 和 PEMS08 資料集預測結果的影響	41



4.4.6	時空嵌入對 PEMS04 和 PEMS08 資料集預測結果的影響	42
4.4.7	PEMS04 與 PEMS08 資料集於不同預測時間間距下之結果分析	43
4.5	在大眾運輸和共享式交通的比較	49
4.5.1	大眾運輸資料集—MRT	49
4.5.2	MRT 資料集的統計分析	53
4.5.3	共享式交通資料集—Youbike	56
4.5.4	Youbike 資料集的統計分析	59
4.5.5	天氣資料	62
4.5.6	MRT 和 Youbike 資料集實驗結果	65
4.5.7	關係圖對 MRT 和 Youbike 資料集預測結果的影響	65
4.5.8	時空嵌入對 MRT 和 Youbike 資料集預測結果的影響	67
4.5.9	MRT 與 YouBike 資料集於不同預測時間間距下之結果分析	68
4.5.10	MRT 案例分析	72
4.5.11	Youbike 案例分析	76
第五章	結論與未來展望	81
	參考文獻	82
	附錄 A — 不同預測時間間距之結果詳細資料	89
A.1	PEMS04 車流量預測	89
A.2	PEMS04 車速預測	90
A.3	PEMS08 車流量預測	91
A.4	PEMS08 車速預測	92
A.5	MRT 人流量預測	93
A.6	Youbike 借出量預測	94
A.7	Youbike 還入量預測	95



圖目次



2.1	STSGCN 架構	7
2.2	局部空間圖演變	7
2.3	STFGNN 架構	8
2.4	STFGNN 中的擴張卷積	8
2.5	時空融合圖	9
2.6	GMAN 架構	9
2.7	ST-GRAT 架構	10
2.8	多圖空間注意力機制架構，以 2 種空間關係數量為例。	11
3.1	實驗流程。	13
3.2	空間相鄰圖範例	14
3.3	流量連結圖範例，線上的數字代表流量。	15
3.4	DTW 計算過程，(a) 算出兩時間序列的花費矩陣，(b) 根據花費矩陣找出最佳匹配路徑，(c) 最佳匹配路徑代表的序列對應關係	15
3.5	流量變化相似圖範例	17
3.6	生成流量分布相似圖，站點相似度計算範例範例。	18
3.7	模型架構， X 為 Encoder 的輸入， H_e^l 代表 Encoder 中的第 l 層的輸出， Y 代表 Decoder 的輸出， H_d^l 代表 Decoder 中的第 l 層的輸出。	20
3.8	全連階層和逐點卷積示意圖	21
3.9	ST-GRAT 訓練和測試階段進行方式	24
4.1	PEMS 分區圖	28
4.2	PEMS 資料集欄位來源，原始資料僅列出有使用到的，箭頭為資料對應關係。	30
4.3	PEMS04 資料集中各站點每 5 分鐘平均車流量之數據分布，每 30 車輛數為一區間，呈現各區間的個別站點數與累計站點數。	33
4.4	PEMS04 資料集中各站點平均車速之數據分布，每 5 Mph 為一區間，呈現各區間的個別站點數與累計站點數。	33
4.5	PEMS04 資料集中平日與假日每小時車流量之比較。	34


4.6	PEMS04 資料集中平日與假日每小時車速之比較。	34
4.7	PEMS08 資料集中各站點每 5 分鐘平均車流量之數據分布，每 30 車輛數為一區間，呈現各區間的個別站點數與累計站點數。	36
4.8	PEMS08 資料集中各站點平均車速之數據分布，每 5 Mph 為一區間，呈現各區間的個別站點數與累計站點數。	37
4.9	PEMS08 資料集中平日與假日每小時車流量之比較。	37
4.10	PEMS08 資料集中平日與假日每小時車速之比較。	38
4.11	PEMS04 資料集中，各模型在車流量預測上的表現，依不同預測時間間距繪製。由上至下分別為 MAE、MAPE 和 RMSE 的誤差圖。	45
4.12	PEMS04 資料集中，各模型在車速預測上表現，依不同預測時間間距繪製。由上至下分別為 MAE、MAPE 和 RMSE 的誤差圖。	46
4.13	PEMS08 資料集中，各模型在車流量預測上表現，依不同預測時間間距繪製。由上至下分別為 MAE、MAPE 和 RMSE 的誤差圖。	47
4.14	PEMS08 資料集中，各模型在車速預測上表現，依不同預測時間間距繪製。由上至下分別為 MAE、MAPE 和 RMSE 的誤差圖。	48
4.15	台北捷運路線圖	50
4.16	MRT 資料集欄位來源，原始資料僅列出有使用到的，箭頭為資料對應關係。	52
4.17	MRT 資料集中各站點每小時平均人流量之數據分布，每 500 人次為一區間，呈現各區間的個別站點數與累計站點數。	54
4.18	MRT 資料集中平日與假日各小時人流量之比較。	55
4.19	Youbike 資料集欄位來源，原始資料僅列出有使用到的，箭頭為資料對應關係。	58
4.20	Youbike 資料集中各站點每日平均借出量之數據分布，每 50 人次為一區間，呈現各區間的個別站點數與累計站點數。	60
4.21	Youbike 資料集中各站點每日平均還入量之數據分布，每 50 人次為一區間，呈現各區間的個別站點數與累計站點數。	60
4.22	Youbike 資料集中平日與假日各小時借出量之比較。	61
4.23	Youbike 資料集中平日與假日各小時還入量之比較。	61
4.24	天氣資料集欄位來源，原始資料僅列出有使用到的，箭頭為資料對應關係。	64
4.25	台北市和新北市氣象測站位置圖	64

表目次




4.1	MGSTT 的實驗設定值	26
4.2	流量變化相似圖和流量分布相似圖的稀疏度參數設置	26
4.3	實驗環境	26
4.4	PEMS04、PEMS08 資料集整體描述	27
4.5	PEMS 分區列表	28
4.6	PEMS Station 5-Minute 資料欄位	29
4.7	PEMS Station Metadata 資料欄位	30
4.8	PEMS 車道種類	30
4.9	PEMS 資料集交通狀態矩陣	31
4.10	PEMS 額外資訊資料集欄位	31
4.11	PEMS 資料集偵測站點距離， N 為偵測站數量	31
4.12	PEMS04 資料集中車流量與車速之基本資訊統計	32
4.13	PEMS04 資料集中車流量與車速之統計指標	32
4.14	PEMS08 資料集中車流量與車速之基本資訊統計	35
4.15	PEMS08 資料集中車流量與車速之統計指標	36
4.16	PEMS04 與 PEMS08 資料集之預測任務設定	39
4.17	PEMS04 和 PEMS08 資料集預測，提出模型 MGSTT 和其他比較模型預測結果，↓表示指標越低越好，紅字代表最佳結果。	40
4.18	PEMS04 在不同關係圖組合下，車流量預測結果，↓表示指標越低越好，紅字代表最佳結果。	41
4.19	PEMS04 在不同關係圖組合下，車速預測結果，↓表示指標越低越好，紅字代表最佳結果。	41
4.20	PEMS08 在不同關係圖組合下，車流量預測結果，↓表示指標越低越好，紅字代表最佳結果。	41
4.21	PEMS08 在不同關係圖組合下，車速預測結果，↓表示指標越低越好，紅字代表最佳結果。	42
4.22	PEMS04 與 PEMS08 資料集在有無時空嵌入下之預測實驗結果，↓表示指標越低越好，紅字代表最佳結果。	42

4.23	MRT 資料集整體描述	49
4.24	臺北捷運各站分時進出量統計	51
4.25	臺北捷運車站出入口座標	51
4.26	MRT 交通狀態資料集欄位	52
4.27	MRT 額外資訊資料集欄位	52
4.28	MRT 資料集車站距離， N 為車站數	52
4.29	MRT 資料集中人流量之基本資訊統計	53
4.30	MRT 資料集人流量統計資料	54
4.31	臺北市 Youbike 分區列表	56
4.32	Youbike 資料集整體描述	56
4.33	臺北市公共自行車 2.0 租借紀錄資料集欄位	57
4.34	YouBike 2.0 臺北市公共自行車即時資訊資料集欄位	57
4.35	Youbike 2.0 交通狀態資料集欄位	58
4.36	Youbike 2.0 額外資訊資料集欄位	58
4.37	租借站距離列表 csv 檔欄位， N 為租借站數	58
4.38	Youbike 資料集中人流量之基本資訊統計	59
4.39	Youbike 資料集借出量及還入量計資料	59
4.40	中央氣象局觀測站日報表整體資訊欄位	62
4.41	中央氣象局觀測站日報表每小時觀測資料欄位	62
4.42	中央氣象局觀測站資訊資料集欄位	63
4.43	天氣資料集欄位	63
4.44	MRT 與 Youbike 資料集之預測任務設定	65
4.45	MRT 和 Youbike 資料集預測，提出模型 MGSTT 和其他比較模型預測結果，↓表示指標越低越好，紅字代表最佳結果。	65
4.46	MRT 在不同關係圖組合下，人流量的預測結果，↓表示指標越低越好，紅字代表最佳結果。	66
4.47	Youbike 在不同關係圖組合下，借出量的預測結果，↓表示指標越低越好，紅字代表最佳結果。	66
4.48	Youbike 在不同關係圖組合下，還入量的預測結果，↓表示指標越低越好，紅字代表最佳結果。	66
4.49	MRT 和 Youbike 資料集在有無時空嵌入下之預測實驗結果，↓表示指標越低越好，紅字代表最佳結果。	67



4.50 MRT 案例簡述，包含起點、終點，單向平均日運量，以及案例所呈現的時間。	72
4.51 Youbike 案例簡述，包含起點、終點，單向平均日運量，以及案例所呈現的時間。	76
A.1 所有模型在 PEMS04 上進行車流量預測，不同預測時間間距的結果。	89
A.2 所有模型在 PEMS04 上進行車速預測，不同預測時間間距的結果。	90
A.3 所有模型在 PEMS08 上進行車流量預測，不同預測時間間距的結果。	91
A.4 所有模型在 PEMS08 上進行車速預測，不同預測時間間距的結果。	92
A.5 所有模型在 MRT 上進行人流量預測，不同預測時間間距的結果。	93
A.6 所有模型在 Youbike 上進行借出量預測，不同預測時間間距的結果。	94
A.7 所有模型在 Youbike 上進行還入量預測，不同預測時間間距的結果。	95



演算法目次



1	fast-DTW	16
2	生成流量變化相似圖	16
3	生成流量分布相似圖	19
4	MGSTT - 多圖空間注意力區塊	23

第一章 緒論



1.1 研究背景

交通運輸對現今社會有著極重要作用，舉凡經濟、社會、文化都藉此發展，搭乘交通工具在城市之間中移動已成為日常生活中的一部份。隨著交通需求量增加，大眾運輸和共享式交通降低私人載具的使用，進而減少交通擁擠和環境汙染，並降低對特定載具的依賴性，因此各個國家都致力於發展大眾運輸和共享式交通。在運營方面，讓供給和需求保持平衡是很重要的事，當供給大於需求時，會導致資源浪費，增加不必要的成本。而當供給小於需求則會產生排他性，使通勤者不得不花時間等待。

為降低等待時間，交通營運者從硬體與軟體兩方面進行改善。硬體方面，可透過增加車輛數量、縮短班距或優化路線，以減少行車時間。軟體方面，則可藉由調整號誌時序、班次間隔及車輛調度等方式，提升運輸效率。然而，要精準調整這些措施，仰賴一套能準確預測交通狀況的模型，這正是交通狀態預測問題的核心。

任一地的交通狀態不只會受到鄰近地點影響，也會受到先前時間的交通狀態影響。因此如何考慮時間和空間的影響，或著說相關性，在交通狀態預測問題中是非常重要的。近年來，研究者提出不同的方法嘗試解決交通狀態預測問題。最早提出的方法之一是統計學模型，例如 Autoregressive Integrated Moving Average model (ARIMA)、Linear regression、Least Absolute Shrinkage and Selection Operator (LASSO) 和 Vector Autoregression (VAR) [1] [2] [3] [4] [5]。但由於無法處理交通狀態中非線性的相關性，以及不規律性，使得統計模型的結果不理想。隨後，資料探勘和機器學習的方法受到關注，包含 KNN、SVM [5] [6] [7] [8] [9]。這些模型能夠處理不具規律性的交通資料。然而這些模型仰賴特徵工程，需要專業知識和經驗。接著，研究轉向深度學習模型，包含卷積神經網絡 (Convolutional

Neural Network, CNN)、循環神經網路 (Recurrent Neural Network, RNN) [10] [11] [12] [13]。相比機器學習方法，這些模型提升了準確度，但仍存在限制。CNN 側於捕捉空間關係，RNN 則側重於捕捉時間關係，兩者皆無法同時捕捉時間和空間的特徵以及其交互相關性。此外，CNN 適合固定結構的資料，例如圖片和影片，並不適合排列方式不固定的圖形結構。近年來，隨著 GNN 的興起，各種以 GNN 解決交通狀態預測問題的模型相繼被提出，包含 ASTGCN[14]、STSGCN[15]、STFGNN [16] 和 ST-MGAT[17]。GNN 用鄰接矩陣 (Adjacency Matrix) 表示圖形結構，能有效地捕捉時間和空間的交互相關性，使得交通狀態預測問題的結果有大幅度的進步。GNN 的出現為交通狀態預測問題帶來新的思路和解決方法，為交通狀態預測領域的研究帶來新的可能性。

1.2 研究動機

然而，先前的 GNN 模型忽略空間關係的多樣性，僅考慮單一類型的空間關係。在實際中，隨著交通場景的不同，空間關係也隨之改變，且在相同交通場景之下，可能同時存在數種交通關係。此外，交通狀態不僅受自身因素影響，如高速公路的車流量與速度、捷運站點間的人流變化，還會受到氣象、時間、公共活動與突發事件等外部因素影響，例如天氣狀況或是否為工作日。然而，僅少數研究將這些外部因素數據化並納入模型考量。

1.3 研究目標與貢獻

為了解決上述問題，本研究改進 ST-GRAT [18] 模型，提出多圖時空轉換器 (Multi Graph Spatial Temporal Transformer, MGSTT)。在空間特徵提取方面，我們先針對各種空間關係下節點間的特徵進行獨立捕捉，再將所有結果合併。同時，透過收集與整理天氣和時間數據，使模型能學習外部因素，進而提升預測能力。本研究透過加州高速公路資料集驗證所提出模型的預測效能，該資料集為交通預測領域中的標準基準，有助於與既有模型進行客觀比較。此外，為評估模型在不

同應用場景中的通用性，亦納入自行整理之台北捷運與 YouBike 2.0 等在地資料集進行測試，進一步驗證 MGSTT 在不同類型交通系統下的適應性與穩定性。

本研究的主要貢獻如下：

1. 本研究提出能同時捕捉多種關係的 MGSTT 模型，並於加州高速公路資料集上進行實驗，整體表現相較其他模型具一定競爭力，顯示其具備潛在的應用價值。
2. 自行蒐集並整理台灣在地的交通資料集，包含台北捷運與 YouBike 2.0，提供更貼近實務應用的資料來源，並進一步探討模型在不同場域下的通用性。

1.4 論文架構

本論文共分為五章。第一章說明交通狀態預測的背景脈絡，並介紹研究動機、目的與貢獻。第二章整理相關文獻與背景知識，釐清交通狀態預測問題的定義，並深入探討圖神經網路的發展歷程及其在交通領域中的應用方式。第三章說明本研究所提出的模型架構與方法，並說明其相較於既有模型的改良之處。第四章介紹實驗設計流程、所使用的資料集（包含加州高速公路、台北捷運與 YouBike 2.0 等），並呈現各項實驗結果與分析討論。最後，第五章統整研究成果，並提出未來研究可能的發展方向。



第二章 相關背景知識及文獻

本章首先定義交通狀態預測問題，並說明圖神經網路在該問題上的應用方式。接著，介紹四種與本實驗較為相關的模型，最後透過這些模型引出多圖空間注意力機制的概念。

2.1 交通狀態預測問題

交通狀態預測問題是根據過去的觀測資料，預測未來的交通狀態。定義如式 2.1。

$$[X(t-T+1), X(t-T+2), \dots, X(t)] \xrightarrow{f} [Y'(t+1), Y'(t+2), \dots, Y'(t+T')] \quad (2.1)$$

$X(t) \in R^{N \times C}$ 為在時間點 t 的觀測資料， N 代表站點數量， C 代表欄位數量。 $Y'(t) \in R^{N \times C'}$ 代表在時間點 t 的預測值， C' 代表預測欄位數。目標是學習一個函數 f ，根據過去 T 段時間的觀測資料，預測未來 T' 段時間的交通狀態。

觀測數據包含交通、時間及天氣。交通數據來源於道路上的感測器、GPS 軌跡和進出匝門，彙整成車流量、車速、進出人次等數據。時間數據包含星期幾、日期和具體時間，甚至包含是否為國定假日的資料，因為交通狀態在工作日和放假日有顯著的差異。交通狀態受天氣的高度影響，天氣數據包含氣溫、雨量、濕度、氣壓、風速等資料欄位。

常見的交通狀態預測問題有：交通流量預測問題，預測一段時間內經過特定區域或站點的數量，例如：道路車流預測、車站人次預測，以及自行車借還量預測 [2][13][15][16]。交通速度預測問題，預測一段時間內特定區域或站點的平均速度，或利用速度推測行駛時間和是否會壅塞的情況，道路速度預測，道路壅塞預測，以及行駛時間預測都屬於這類型的問題 [19][20]。交通需求預測問題，預測特定服務的使用需求，例如叫車平台需求預測、計程車需求預測以及自行車需求預

測 [21][22]。

2.2 圖神經網路

CNN 適用於歐式空間資料 (data with Euclidean space)，歐式空間資料存在順序且相鄰資料數固定，不適合以圖為基礎的資料。GNN[23] 提出在圖上更新節點特徵的方法，之後，以 GNN 為基礎衍生的模型相繼被提出。包含引入傅立葉轉換的圖卷積網路 (Graph Convolution Network, GCN)[24]、引入 Attention 機制的圖注意力網路 (Graph Attention Network, GAT)[25]。GNN 已經廣泛地應用在以各種問題上 [26]，例如 Graph Matching：判斷兩張 Graph 的相似程度 [27] [28]；Graph Clustering：將點分成數群，群中各點相似性高，不同群之間相異性高 [29] [30]；以及 Text Classification[31] [32]。

由於在圖型結構上的優勢，越來越多關於交通狀態預測問題的研究使用 GNN，上述的圖卷積網路和圖注意力網路為主要研究對象。

圖卷積網路引入傅立葉轉換，利用頻譜域 (Spectral Convolution) 的方法來學習圖結構中的特徵，進而捕捉節點之間的關聯性與訊息傳遞模式。[14] 使用頻譜域捕捉三種不同時間週期的特徵。[33] 將改良過的 Graph Convolution Layer 替代 Gated Recurrent Unit (GRU) 原有的線性層，以便同時捕捉時空特徵。[15] [16] 使用多層 Spatial Convolution 捕捉時空特徵。

圖注意力網路則引入注意力機制，使模型能夠根據節點之間的關聯性，自適應地學習不同鄰居節點的重要程度。[17] [34] 用圖注意力網路捕捉空間相關性。[18] 套用 Transformer 架構，利用 Attention 機制分別計算時間和空間中的相關性。

GNN 將關係圖帶入模型，讓模型學習圖結構。關係圖 $A \in R^{N \times N}$ 表示節點之間的關係，其中 N 代表觀測點數量。關係圖可表示節點間的聯通性與相似性。[35] 使用方向相反的兩張關係圖擷取空間特徵。[36] 使用 Wasserstein Distance 計算任兩點的時間序列的距離。[16] [37] 使用 Dynamic Time Warping (DTW) 演算法，從時間序列的形狀決定相似度。[21] [22] 利用皮爾森係數 (Pearson Coefficient) 計



算兩個時間序列的相關性。此外，有些研究讓模型在訓練中學習關係圖，[33] 提出 Data Adaptive Graph Generation (DAGG) module 從數據中自動推斷點之間的相關性。上述方法並非互斥，一小部分研究同時使用多種關係圖。[37] 將預先定義的關係圖帶入圖卷積操作，再使用門控機制 (Gating Mechanism) 和動態學習的關係圖融合，提高模型捕捉空間相關性的準確度。[16] 同時使用代表連通性和相似性的兩種關係圖。

2.3 時空同步圖形卷積網路

時空同步圖形卷積網路 [15] (Spatial-Temporal Synchronous Graph Convolutional Networks, STSGCN) (如圖 2.1 (a)) 是基於圖卷積網路的模型。STSGCN 認為站點狀態不僅受相鄰站點影響，也受自身在相鄰時間點的變化影響，因而提出局部時空圖以同步捕捉局部時空相關性。空間相鄰圖表示同一時間下的相鄰站點會互相影響，時間相鄰圖則表示同一站點在不同時間點間的影響，最後以局部時空圖為遮罩，學習影響力大小。

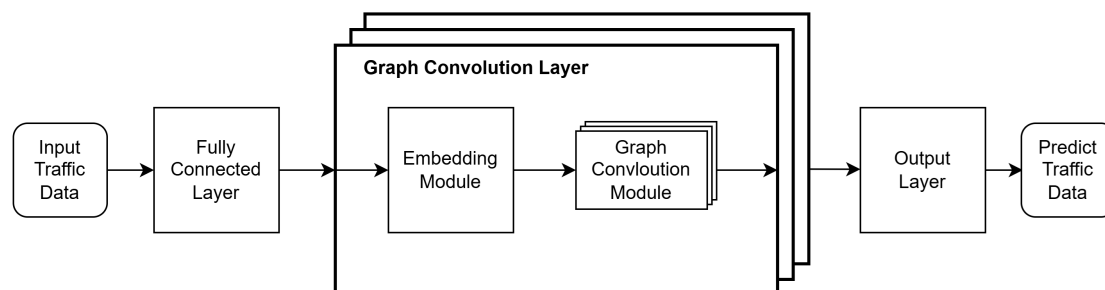



圖 2.1: STSGCN 架構



(a) 局部時空圖

(b) 局部時空圖，矩陣形式

(c) 局部時空圖，實際數值

圖 2.2: 局部空間圖演變

2.4 時空融合圖形卷積網路

時空融合圖形卷積網路 [?] (Spatial-Temporal Fusion Graph Neural Networks, STFGNN) (如圖 2.3) 是從 STSGCN 改進的模型。為了能同時捕捉全局和局部的時空特徵，STFGNN 提出時空融合圖 (如圖 2.5)，在 STSGCN 的局部時空圖基礎上，引入流量變化相似圖，用以表示具有相似流量變化趨勢的站點，該圖使用 Dynamic Time Warping 演算法，計算站點間流量變化趨勢的相似度。此外，STFGNN 引入膨脹率較大的擴張卷積 (Dilated Convolution, 如圖 2.4)，並透過多個圖卷積模組的堆疊，進一步擴展時間軸上的感受野 (Receptive Field)，以擷取長時間的時空依賴性。

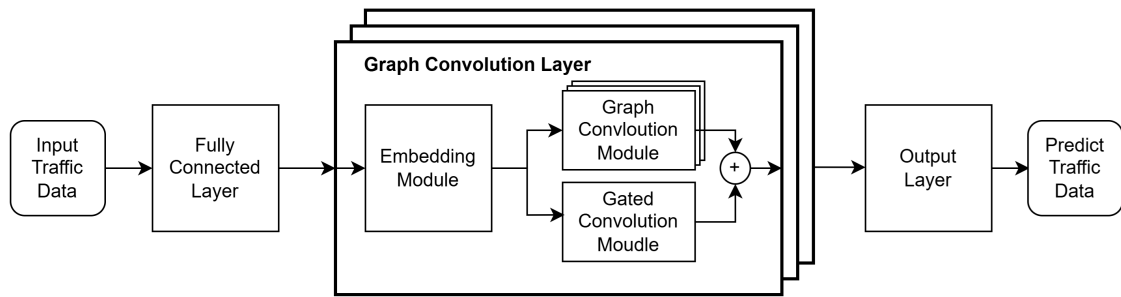


圖 2.3: STFGNN 架構




圖 2.4: STFGNN 中的擴張卷積

2.5 圖多重注意力網路

圖多重注意力網路 [38] (Graph Multi-Attention Network, GMAN) 為圖注意力網路，透過注意力機制捕捉複雜的時空特徵，架構如圖 2.6。GMAN 透過時空嵌入，捕捉時間資訊和圖結構，再將時空嵌入加入時間注意力機制以及空間注意力機制進一步增強模型的時空建模能力。



流量變化相似圖	時間相鄰圖 $T_1 \rightarrow T_2$	時間相鄰圖 $T_1 \rightarrow T_3$	流量變化相似圖
時間相鄰圖 $T_2 \rightarrow T_1$	空間相鄰圖 T_2	時間相鄰圖 $T_2 \rightarrow T_3$	時間相鄰圖 $T_2 \rightarrow T_4$
時間相鄰圖 $T_3 \rightarrow T_1$	時間相鄰圖 $T_2 \rightarrow T_3$	空間相鄰圖 T_3	時間相鄰圖 $T_3 \rightarrow T_4$
流量變化相似圖	時間相鄰圖 $T_2 \rightarrow T_4$	時間相鄰圖 $T_3 \rightarrow T_4$	流量變化相似圖

圖 2.5: 時空融合圖

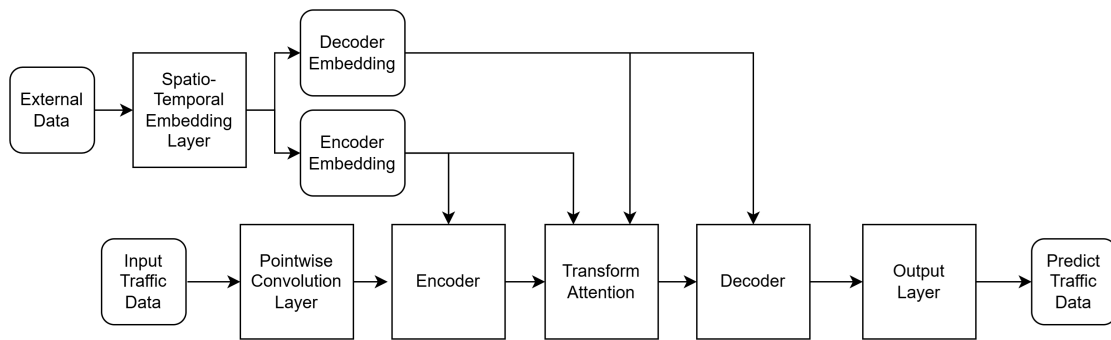


圖 2.6: GMAN 架構

2.6 時空圖注意力網路

時空圖注意力網路 [18] (Spatio-Temporal Graph Attention Network, ST-GRAT) 同樣為圖注意力網路，使用注意力機制捕捉時空特徵，並改自 Transformer。ST-GRAT 將圖視為有向圖，空間注意力區塊由流入注意力頭 (inflow attention heads) 和流出注意力頭 (outflow attention heads) 堆疊而成。這種設計使模型能夠分別關注流入與流出交通的不同資訊，從而更有效地捕捉交通流動的方向性特徵。為了在模型中傳遞邊的信息，ST-GRAT 引入了擴散先驗 (diffusion prior)，記作 DCN ，如式 2.2 所示。

$$DCN(A) = \sum_{k=0}^K \beta_k * A^k \in R^{N \times N} \quad (2.2)$$

A 為輸入矩陣， K 為擴散過程的截斷步數， β 為可學習參數。

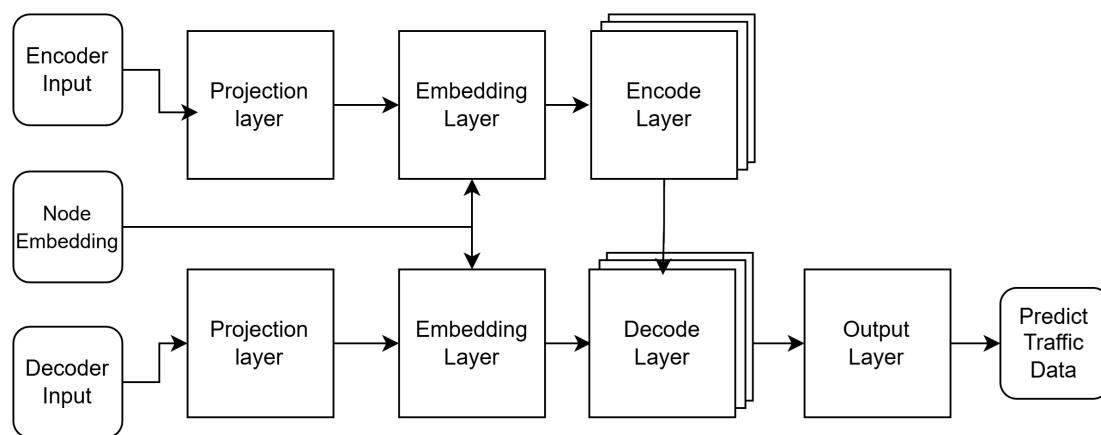


圖 2.7: ST-GRAT 架構

2.7 多圖空間注意力機制

上列提到的四種模型以不同方式將圖的結構輸入模型。其中，STSGCN 和 STFGNN 透過將多種關係圖拼接成更大的圖，以擷取連續時間段的時空特徵；GMAN 和 ST-GRAT 則透過預訓練方式生成關係圖的嵌入，並將其應用於模型訓練。然而，這些方法的限制在於僅能使用固定種類的關係圖，無法根據需求調整關係圖的數量。

Meta Graph Transformer [39] 和 Spatial-Temporal Guided Multi Graph Sandwich-Transformer(STGMT) [40] 則採用多種空間關係來計算注意力機制，本研究將其稱為「多圖空間注意力機制」。這些方法能夠分別擷取不同空間關係下站點之間的特徵，並將計算結果加以整合，以提升模型對空間資訊的理解與適應能力。如圖 2.8 所示，中間層分別與不同的關係圖一起作為輸入，經由空間注意力機制計算後產生對應的輸出，接著透過相加、取最大值等合併機制，最終生成模型的輸出。

2.8 整合外部因素

除了交通狀態資料外，一些研究（如 [22]、[41]、[42]、[43]）將天氣、日期等外部因素數據化並作為模型輸入，以輔助學習更多時空特徵。這些研究通常先

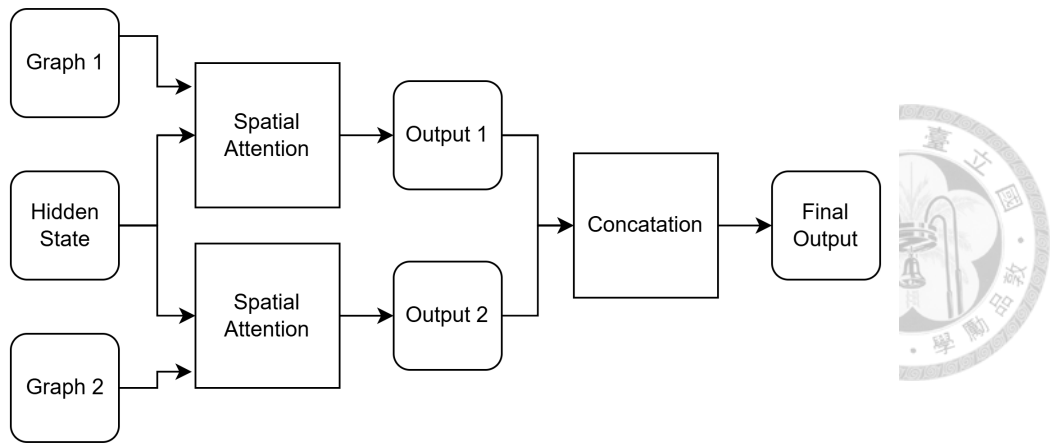


圖 2.8: 多圖空間注意力機制架構，以 2 種空間關係數量為例。

將資料轉換為獨熱向量 (one-hot vector) 或進行正規化處理，接著透過神經網路轉換為嵌入向量，以提升模型的預測能力。



第三章 研究方法



3.1 實驗流程

本研究將實驗流程分為三個部分，如圖 3.1 所示。首先，進行資料收集，涵蓋交通、天氣與時間等資訊。交通資料包含進出量統計與站點經緯度，並進一步轉換為交通狀態資料。本研究選擇兩項外部因素——天氣與時間，其中天氣資料包含氣象站的偵測數據及其經緯度，而時間資料則涵蓋星期幾 (day of the week) 與具體時間。接下來，根據不同的交通場景建立合適的關係圖。最後，將上述三類資料輸入模型，進行評估與預測。

在接下來的章節中，將依序說明實驗流程：節 3.2 說明關係圖的選擇方式，節 3.3 則詳細闡述模型的結構設計。

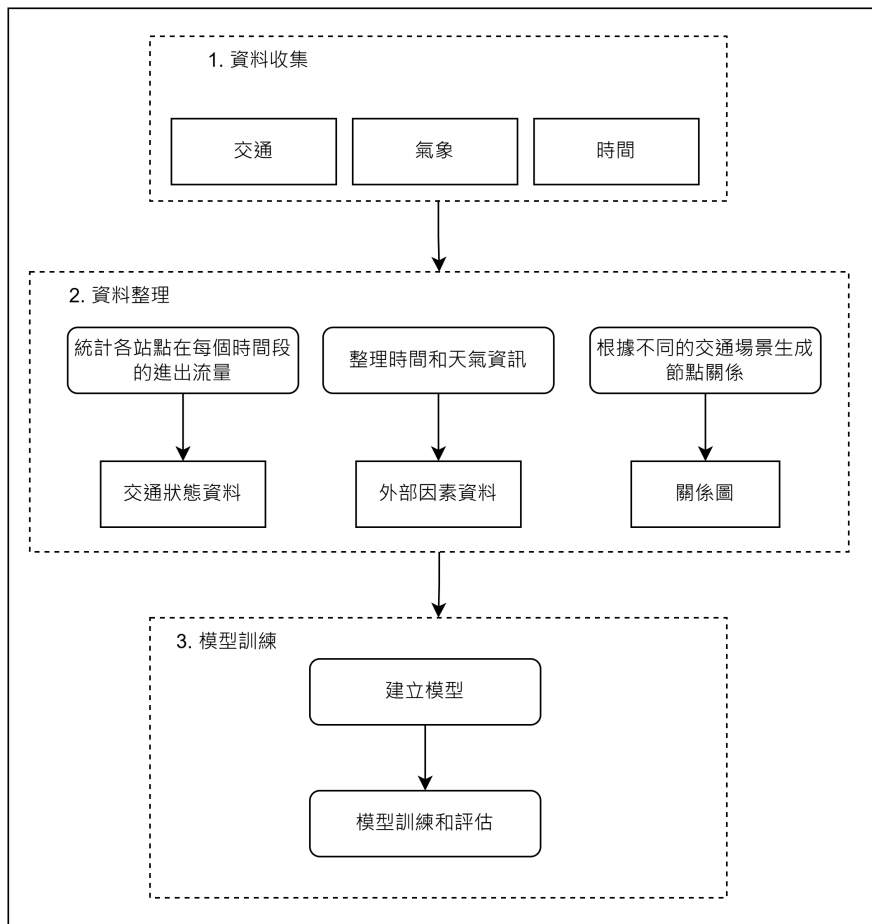


圖 3.1: 實驗流程。

3.2 建立關係圖

本研究針對不同的交通場景下制定不同的空間關係



3.2.1 空間相鄰圖

針對空間上相鄰的兩個節點，例如高速公路上相鄰的偵測站，或鐵道路線上相鄰的兩個車站，本研究在空間相鄰圖中皆視為彼此相連的節點。範例如圖 3.2 所示。





圖 3.2: 空間相鄰圖範例

3.2.2 流量連結圖

在共享式交通中，車站的移動沒有固定的路線，因此本研究提出以流量連結圖取代傳統的空間相鄰圖。空間相鄰圖為有向圖，而在流量連結圖中，若站點 i 有流量通往站點 j ，則建立一條從 i 指向 j 的有向邊，以更貼近實際交通流動情境。範例如圖 3.3 所示。

3.2.3 流量變化相似圖

流量變化相似圖為 STFGNN 中基於 DTW 演算法，計算節點之間相似度而構建的關係圖。DTW 是用來計算兩個序列 X, Y 要對齊所需要花費成本，範例如圖 3.4 所示。首先計算兩個序列的花費成本，再推出兩序列的最佳匹配路徑 Ω (圖 3.4(b))， Ω 可以表示兩序列的匹配關係。



	1	2	3	4
1	0	1	0	0
2	1	0	0	0
3	0	1	0	1
4	1	0	1	0



圖 3.3: 流量連結圖範例，線上的數字代表流量。

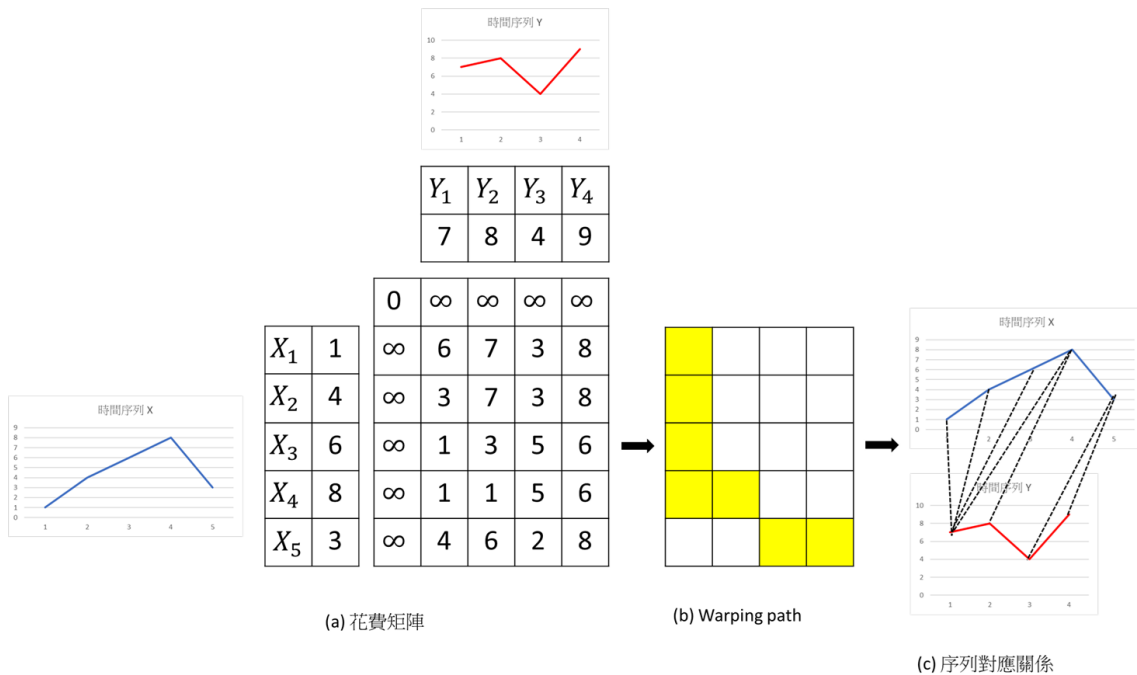


圖 3.4: DTW 計算過程，(a) 算出兩時間序列的花費矩陣，(b) 根據花費矩陣找出最佳匹配路徑，(c) 最佳匹配路徑代表的序列對應關係

DTW 演算法時間複雜度為 $O(N^2)$ ， N 為序列長度，為了降低時間成本，STFGNN 限制最佳匹配路徑的搜尋範圍，公式如式 3.1 所示。

$$\omega_k = (i, j), |i - j| \leq L \quad (3.1)$$

i, j 分別代表序列 X 的第 i 個元素和序列 Y 的第 j 個元素， L 代表限制搜尋的範圍。

修改過後的 DTW 演算法如 演算法 1 所示，該演算法被稱為 fast-DTW。

演算法 1 fast-DTW

Require: 時間序列 $X = (x_1, x_2, x_3, \dots, x_N)$ 、 $y = (y_1, y_2, y_3, \dots, y_M)$

- 1: **for** $i = 1, 2, 3, \dots, N$ **do**
- 2: **for** $j = \max(1, i - L), \dots, \min(M, i + L)$ **do**
- 3: $D(i, j) = |x_i - y_j|$
- 4: **if** $i = 1$ and $j = 1$ **then**
- 5: $D_{cost}(i, j) = D(i, j)$
- 6: **else if** $i=1$ **then**
- 7: $D_{cost}(i, j) = D(i, j) + D_{cost}(i, j - 1)$
- 8: **else if** $j=1$ **then**
- 9: $D_{cost}(i, j) = D(i, j) + D_{cost}(i - 1, j)$
- 10: **else if** $j=i-L$ **then**
- 11: $D_{cost}(i, j) = D(i, j) + \min(D_{cost}(i - 1, j - 1), D_{cost}(i - 1, j))$
- 12: **else if** $j=i+L$ **then**
- 13: $D_{cost}(i, j) = D(i, j) + \min(D_{cost}(i - 1, j - 1), D_{cost}(i, j - 1))$
- 14: **else**
- 15: $D_{cost}(i, j) = D(i, j) + \min(D_{cost}(i - 1, j - 1), D_{cost}(i - 1, j), D_{cost}(i, j - 1))$
- 16: **end if**
- 17: **end for**
- 18: **end for**
- 19: **return** $dist(X, Y) = D_{cost}(n, m)^{\frac{1}{2}}$



本研究使用 fast-DTW 生成流量變化相似圖，如演算法 2 所示。時間序列可為高速公路的車流量，車站的人流量，或是共享單車的租借量。每個節點與距離前 $S\%$ 最相似的點相連。 S 代表流量變化相似圖的稀疏度 (Sparsity)，在圖 3.5 中提供了在不同稀疏度設定下流量變化相似圖的變化情況。

演算法 2 生成流量變化相似圖

Require: 站點個數 N ，時間序列 X ，決定稀疏度參數 S

- 1: 初始化流量變化相似圖的權重矩陣 $W \in R^{N \times N}$ 為 0
- 2: **for** $i = 1, 2, 3, \dots, N$ **do**
- 3: **for** $j = 1, 2, 3, \dots, N$ **do**
- 4: $dist_{i,j} = fast - DTW(X_i, X_j)$ ▷ 請參考演算法 1
- 5: **end for**
- 6: 將 $dist_{i,0}, dist_{i,1}, dist_{i,2}, \dots, dist_{i,N}$ 由小至大排序，選擇前 $k = \lfloor NS \rfloor$ 個值的 index $m = \{m_1, m_2, m_3, \dots, m_k\}$ s.t. $dist_{i,m_1} \leq dist_{i,m_2} \leq dist_{i,m_3} \leq \dots \leq dist_{i,m_k}$ 。
- 7: **for** $j = 1, 2, 3, \dots, k$ **do**
- 8: $W_{i,m_j} = W_{m_j,i} = 1$
- 9: **end for**
- 10: **end for**
- 11: **return** 流量變化相似圖的權重矩陣 W

	1	2	3	4	5
Y	7	8	4	9	5

	X
1	1
2	4
3	6
4	8
5	3


	1	2	3	4	5
1	6	7	3	∞	∞
2	3	7	3	8	∞
3	1	3	5	6	6
4	∞	1	5	6	9
5	∞	∞	2	8	8

(a) 用 fast-DTW 兩點之間距離，以 L=2 為例




	1	2	3	4	5
1	0	3.46	4.47	4.12	3.74
2	3.46	0	4.36	3.32	2
3	4.47	4.36	0	4.58	4.12
4	4.12	3.32	4.58	0	3.61
5	3.74	2	4.12	3.61	0

(b) 所有點對的距離矩陣



(c) 在稀疏度 S=0.2 的結果



(d) 在稀疏度 S=0.4 的結果

圖 3.5: 流量變化相似圖範例

3.2.4 流量分布相似圖

在流量變化相似圖中，本研究將流量變化趨勢相似的站點視為相鄰並建立連線。流量變化可從空間分布與時間分布兩個面向進行分析，因此本研究分別從這兩個方向評估站點之間的流量相似度。

空間方面是依據站點間的流量比例，如式 3.2 所示。

$$L1_{i,j} = \frac{\sum_{t < T} X_{(i,j)}^t}{\sum_{t < T} \sum_{k < N \text{ and } k \neq i} X_{(i,k)}^t} \quad (3.2)$$

$L1_{i,j}$ 代表從站點 i 流出的總流量中，流到站點 j 的比例， $X_{(i,j)}^t$ 代表時刻 t 從站點 i 到站點 j 的流量， T 代表時間間隔數， N 代表站點數。

時間方面是依據不同時段的流量分布比例。本研究將日期區分為平日與假日，並將一天劃分為 24 小時，因此共計 48 個時段。公式式 3.3 所示。

$$L2_{i,T} = \frac{\sum_{k < N} X_{(i,k)}^T}{\sum_{t < T} \sum_{k < N} X_{(i,k)}^t} \quad (3.3)$$

$L2_{i,T}$ 代表從站點 i 流出的總流量中，在時刻 T 流出的比例。

接著，利用這兩種流量比例來計算所有站點之間的相似度，計算公式如式 3.4 和式 3.5 所示。

$$L_i = L1_i | L2_i \quad (3.4)$$

$$ls(i, j) = cosine_similarity(L_i, L_j) = \frac{L_i \cdot L_j}{\|L_i\| \|L_j\|} \quad (3.5)$$

符號 $|$ 代表串接 (concatenation) 操作。

計算範例如圖 3.6 所示。

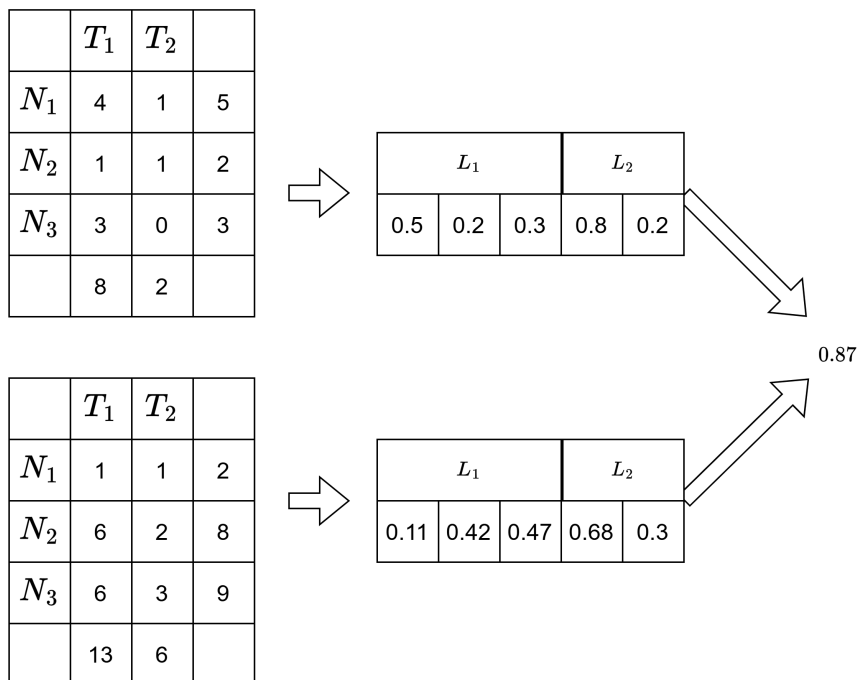


圖 3.6: 生成流量分布相似圖，站點相似度計算範例範例。

最後，利用計算出來的相似度建立流量分布相似圖，如同演算法 2，使用 S 決定圖的稀疏度。

演算法 3 生成流量分布相似圖

Require: 站點個數 N , $L = L_1, L_2, \dots, L_N$, 稀疏度參數 S

```
1: 初始化流量分布相似圖的權重矩陣  $W \in R^{N \times N}$  為 0
2: for  $i = 1, 2, 3, \dots, N$  do
3:   for  $j = 1, 2, 3, \dots, N$  do
4:      $ls_{i,j} = \text{cosine\_similarity}(L_i, L_j)$ 
5:   end for
6:    $ls_{i,j} = 0$ 
7:   將  $ls_{i,0}, ls_{i,1}, ls_{i,2}, \dots, ls_{i,N}$  由大至小排序，選擇前  $k = \lfloor NS \rfloor$  個值的 index
    $m = \{m_1, m_2, m_3, \dots, m_k\}$  s.t.  $\text{similarity}_{i,m_1} \geq \text{similarity}_{i,m_2} \geq \text{similarity}_{i,m_3} \geq \dots \geq \text{similarity}_{i,m_k}$ 。
8:   for  $j = 1, 2, 3, \dots, k$  do
9:      $W_{i,m_j} = W_{m_j,i} = 1$ 
10:  end for
11: end for
12: return 流量分布相似圖的權重矩陣  $W$ 
```



3.3 提出模型：多圖時空轉換器

本研究在 ST-GRAT [18] 的基礎上進行修改，提出多圖時空轉換器（Multi Graph Spatial Temporal Transformer, MGSTT），如圖 3.7 所示。MGSTT 與 ST-GRAT 相比，主要有幾個不同之處。首先，本研究以逐點卷積取代原本的前饋層與線性轉換層，在本節中將以 F 代表逐點卷積。其次，雖然保留了 Positional Embedding，但在空間嵌入部分，本研究替換成透過額外的數據學習特徵，進而生成的時空嵌入，使模型能更有效地捕捉不同站點之間的時空關係。在空間維度上，本研究提出了多圖空間注意力區塊，取代原本的空間注意力區塊，讓模型能夠同時考慮不同類型的空間關係，進一步增強對交通流動特性的理解。最後，在輸出層的設計上，捨棄了 ST-GRAT 的線性輸出方式，改為使用 STSGCN 和 STFGNN 的輸出層，以提升預測表現。此外，ST-GRAT 在測試階段採用自我回歸（autoregressive model）方式進行預測，然而這種方法容易導致錯誤累積（error accumulation），影響長時間序列的預測準確度。因此，MGSTT 避免使用自我回歸機制，以減少錯誤傳播的影響，提升模型在測試時的穩定性。

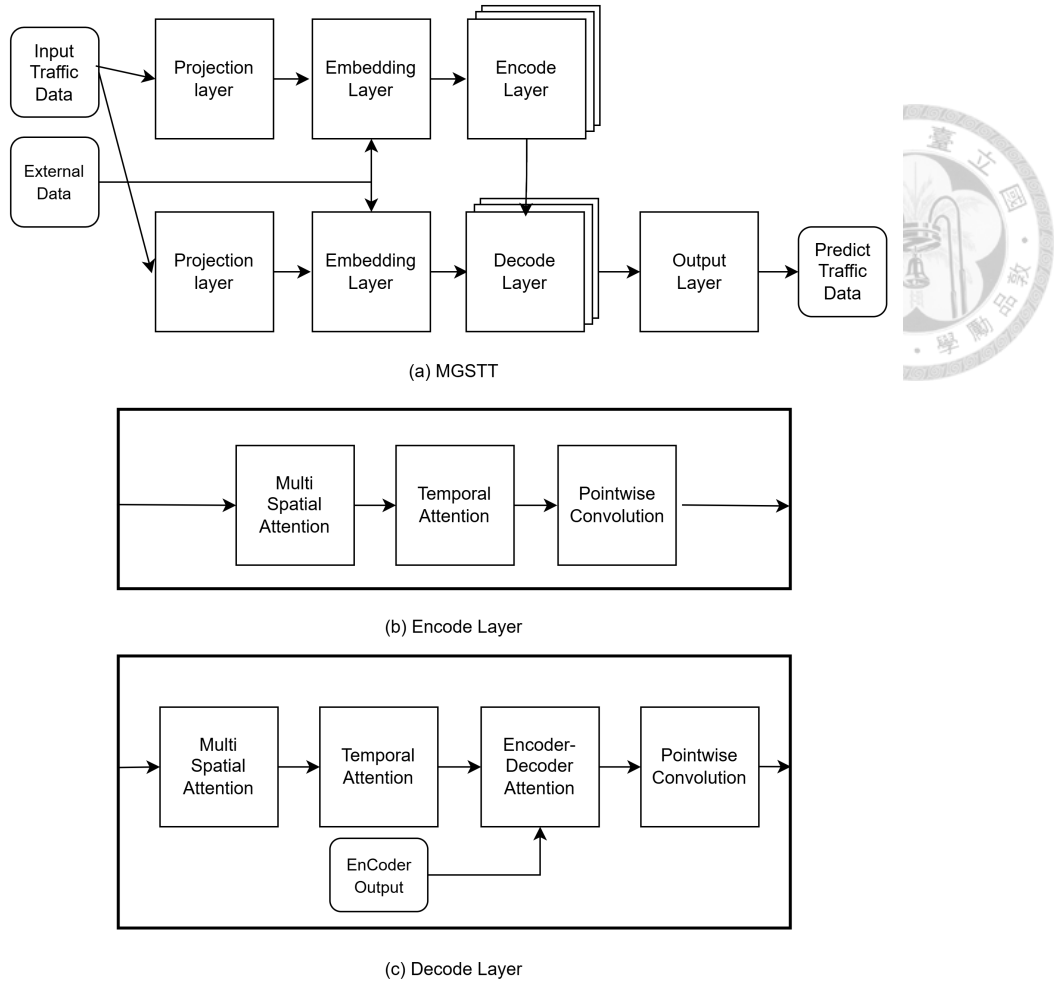


圖 3.7: 模型架構， X 為 Encoder 的輸入， H_e^l 代表 Encoder 中的第 l 層的輸出， Y 代表 Decoder 的輸出， H_d^l 代表 Decoder 中的第 l 層的輸出。


3.3.1 強化特徵提取能力

在 MGSTT 中，本研究以逐點卷積取代全連接層。逐點卷積透過 1×1 的卷積核，在單一站點的特徵維度上進行資訊整合，提升特徵學習的效果。相較於全連接層（如圖 3.8 (a)），逐點卷積（如圖 3.8(b)）不僅能夠以較少的參數量實現相似的特徵轉換，減少計算成本，還能加強模型對特徵間關聯性的捕捉能力，使其更有效地學習站點之間的時空關係，進而提升預測準確度。


逐點卷積的公式如式 3.6 所示。

$$Y_{i,j,k} = \sum_{x=1}^C (X_{i,j,x} \times W_{x,k}) + b_k \quad (3.6)$$

$X \in R^{T \times N \times C_{in}}$ 為輸入， $Y \in R^{T \times N \times C_{out}}$ 為輸出， $W \in R^{C_{in} \times C_{out}}$ 為卷積核。



(a) 全連接層



(b) 逐點卷積

圖 3.8: 全連階層和逐點卷積示意圖

3.3.2 替換空間嵌入

在嵌入層，本研究保留 ST-GRAT 的 Positional Embedding，以產生時間嵌入，公式如式 3.7。

$$PE_{t,i} = \begin{cases} \sin\left(\frac{t}{10000 \frac{i}{D}}\right) & \text{if } i \text{ is even} \\ \cos\left(\frac{t}{10000 \frac{(i-1)}{D}}\right) & \text{if } i \text{ is odd} \end{cases} \quad (3.7)$$

$PE \in R^{N \times D}$ 為時空嵌入， $PE_{t,i}$ 代表第 t 個時間段的第 i 個維度。

相較於 ST-GRAT 用預先訓練的節點嵌入向量學習空間嵌入。本研究認為除了交通狀態本身的因素，一些額外因素，如時間和天氣，也會影響交通。因此本研究改為從額外資料中學習時空特徵。本研究先處理額外資料，將時間資料轉為獨熱序列 (one-hot vector)，天氣資料經過正規化處理。再將處理過的資料 E 施加逐點卷積 (Pointwise Convolution)，以捕捉其時空特徵，進而產生時空嵌入，公式如式 3.8。

$$STE = F(E) \quad (3.8)$$

$STE \in R^{T \times N \times D}$ 為時空嵌入。

最後，透過 Broadcast Add 操作，將空間嵌入、時空嵌入和投射層的嵌入融合，公式如式 3.9。

$$H_E = H + PE + STE \quad (3.9)$$

$H_E \in R^{T \times N \times D}$ 為最終的輸出嵌入表示， $H \in R^{T \times N \times D}$ 為輸入， $PE \in R^{T \times D}$ 為空間嵌入。



3.3.3 多圖空間注意力區塊

道路的交通狀態會受到鄰近道路的影響，而這些影響的強度會隨時間變化而有所不同。此外，即使某些道路並不相鄰，它們仍可能具有相似的交通模式。在空間關係方面，站點之間可能涉及多種不同的交通關聯。因此，有別於 ST-GRAT，本研究參考 Meta Graph Transformer 及 STGMT (節 2.7)，並在多圖空間注意力區塊中提出空間注意力機制，以學習不同類型空間關係下站點之間的關聯性，進一步提升模型對複雜交通模式的捕捉能力。

在多圖空間注意力區塊中，對每一張關係圖 G_i 分別計算對應的注意力值 (Attention Value)，接著將該注意力值與 G_i 進行逐元素相乘，以保留關係圖中的結構信息。最後，將所有關係圖的計算結果相加，以綜合不同空間關係的資訊，進一步增強模型對空間結構的理解與表達能力。完整演算法如 演算法 4 所示。

3.3.4 輸出層調整

本研究認為，若直接使用線性轉換層，難以有效表達不同時間段的交通狀態之間所存在的非線性關聯性，尤其是這些關聯性的強弱程度可能有所不同。因此，我們參考 STSGCN[15] 和 STFGNN[16] 的作法，改採兩層全連接層，並搭配 ReLU 激活函數，並讓模型能夠獨立產生每段時間的預測，進一步提升對時序數據的表達能力與預測準確度。公式如 式 3.10 所示

Require: 中間層表示 $H \in R^{T \times N \times D}$ 、關係圖 G_1, G_2, \dots, G_A

```

1: for  $x = 1, 2, 3, \dots, A$  do
2:   for  $t = 1, 2, 3, \dots, T$  do
3:     for  $k = 1, 2, 3, \dots, N_h$  do
4:       for  $i = 1, 2, 3, \dots, N$  do
5:          $Q_{t,i}^k = F^Q(H_{t,i}^k)$ 
6:          $K_{t,i}^k = F^K(H_{t,i}^k)$ 
7:          $V_{t,i}^k = F^V(H_{t,i}^k)$ 
8:       end for
9:        $Q \leftarrow [Q_{t,1}^k, Q_{t,2}^k, \dots, Q_{t,N}^k]$ 
10:       $K \leftarrow [K_{t,1}^k, K_{t,2}^k, \dots, K_{t,N}^k]$ 
11:       $V \leftarrow [V_{t,1}^k, V_{t,2}^k, \dots, V_{t,N}^k]$ 
12:       $head^k = Softmax(\frac{QK^\top}{\sqrt{d_k}} \circ G_x)V$ 
13:    end for
14:     $H_{s(x,t,:)} = F(Concat(head^1, head^2, \dots, head^{N_h}))$ 
15:  end for  $H_S \leftarrow H_{s(1)} + H_{s(2)} + \dots + H_{s(A)}$ 
16: end for
17:  $H_S \leftarrow H_S + H$ 
18:  $H_S \leftarrow Layer\ Normalization(H_S)$ 
19: return  $H_S$ 

```



$$Y'(t) = ReLU(X^\top W_1(t) + b_1(t))W_2(t) + b_2(t) \in R^{N \times C_{out}} \quad (3.10)$$


其中 $X \in R^{T \times N \times D}$ 為輸入， $X^\top \in R^{N \times TD}$ 為重塑大小後的輸入， t 為預測數據的第 t 段時間， $W_1(t) \in R^{TD \times C_{out}}$, $b_1(t) \in R^{C_{out}}$, $W_2(t) \in R^{C_{out} \times C}$, $b_2(t) \in R^C$ 為可學習參數， T' 代表預測數據的時間。

最後串接所有時間步的預測，如式 3.11， T' 代表預測數據的時間步數。


$$Y = [Y'(1), Y'(2), \dots, Y'(T')] \in R^{T' \times N \times C} \quad (3.11)$$

3.3.5 改進測試機制

ST-GRAT 的解碼器在訓練時採用 Teacher Forcing，即使用實際觀測的資料作為輸入，以提升模型的收斂速度與穩定性（圖 3.9(a)）。然而，ST-GRAT 在測試階段採用自我回歸（autoregressive model）方式進行預測（圖 3.9(b)），然而這種方法容易導致錯誤累積（error accumulation），進而影響長時間序列的預測準確度。



(a) ST-GRAT 訓練階段



(b) ST-GRAT 測試階段

圖 3.9: ST-GRAT 訓練和測試階段進行方式



為了減少這種影響，MGSTT 採用了不同的預測機制，避免自我回歸造成的錯誤傳播，進一步提升模型在測試時的穩定性與準確度。具體而言，本研究讓解碼器的時間序列輸入與解碼器保持一致，使模型在訓練過程中能夠學習如何充分利用完整的歷史資料來進行預測。在測試時，解碼器只需遍歷一次即可輸出所有預測結果，不僅能有效避免錯誤累積的問題，還能大幅降低測試過程的時間成本，提升運算效率。

3.3.6 損失函數

MGSTT 參考 STSGCN[15] 和 STFGNN[16]，採用 Huber Loss 當作損失函數，如式 3.12 所示。

$$L(Y, Y') = \begin{cases} \frac{1}{2}(Y - Y')^2, & \text{if } |Y - Y'| \leq \delta, \\ \delta|Y - Y'| - \frac{1}{2}\delta^2, & \text{otherwise} \end{cases} \quad (3.12)$$

L 為損失函數， Y 為實際數值， Y' 為模型預測數值， δ 為決定異常值的超參數 (Hyperparameter)。

第四章 研究結果及討論



4.1 比較模型

本研究提出的模型和下列模型比較：

- STSGCN：Spatial-Temporal Synchronous Graph Convolutional Networks，利用 Localized Spatial-Temporal Graph 擷取局部時空關聯性。
- STFGNN：Spatial-Temporal Fusion Graph Neural Networks，結合 Gated dilated CNN 和 Graph Convolutional Networks，用來同時捕捉區域和全局的時空關聯性。
- GMAN：Graph Multi-Attention Network，EnCoder-Decoder 架構，利用注意力機制捕捉時間和空間上的相關性。
- ST-GRAT：Spatio-Temporal Graph Attention Network，Transformer 架構，利用注意力機制捕捉時間和空間上的相關性。

4.2 實驗設置

在所有模型，我們使用相同的資料前處理策略。首先，將資料集按照 6:2:2 的比例劃分為訓練集、驗證集和測試集。接著，使用 Sliding Window 技術，將數據轉換為多筆時間長度為 24 的序列，其中前 12 個時間點作為模型輸入，後 12 個時間點則作為預測目標。對於輸入資料，使用平均值和標準差對將其標準化，如式 4.1。

$$norm(X) = \frac{X - mean(X)}{std(X)} \quad (4.1)$$

X 代表輸入資料， $mean(X)$, $std(X)$ 代表 X 的平均值和標準差。

每次實驗迭代 100 次，並保存最後一次的結果進行測試。所有實驗皆重複執行 3 次，最終結果取平均值。

MGSTT 的實驗設定值如表 4.1。

表 4.1: MGSTT 的實驗設定值

參數	配置
編碼層/解碼層數量	3
多頭注意力頭數	8
優化器	Adam
批次大小	16
Huber Loss 中的 δ	2.0



在節 3.2 中，本研究列出 4 種關係圖。本研究設置流量變化相似圖，以及流量分布相似圖當中的稀疏度參數 S 設置如表 4.2 所示。

表 4.2: 流量變化相似圖和流量分布相似圖的稀疏度參數設置

關係圖	稀疏度參數 S
流量變化相似圖	0.01
流量分布相似圖	0.025

所有模型皆用 PyTorch 實作，並部屬到多台機器上實驗，實驗環境如表 4.3 所示。

表 4.3: 實驗環境

流水號	硬體規格
1	Intel(R) Core(TM) i7-8700 CPU @ 3.20GHz GeForce GTX 1080, Memory 8G
2	Intel(R) Core(TM) i7-8700 CPU @ 3.20GHz NVIDIA GeForce RTX 2070, Memory 8G
3	Intel(R) Xeon(R) CPU E3-1230 v5 @ 3.40GHz GeForce RTX™ 2080 Ti TURBO, Memory 11G
4	11th Gen Intel(R) Core(TM) i7-11700K @ 3.60GHz NVIDIA GeForce RTX 3090. Memory 24G
5	11th Gen Intel(R) Core(TM) i7 NVIDIA RTX A6000. Memory 48G
6	11th Gen Intel(R) Core(TM) i7 NVIDIA RTX A6000. Memory 48G

4.3 評估指標 (Metric)

本研究使用 3 個指標評估模型，分別是 Mean Absolute Error (MAE)、Mean Absolute Percentage Error (MAPE)、Root Mean Square Error (RMSE)，公式分別為

式 4.2、式 4.3 和 式 4.4，

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_i - Y'_i| \quad (4.2)$$

$$MAPE = \frac{100\%}{N} \sum_{i=1}^N \frac{Y_i - Y'_i}{Y_i} \quad (4.3)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - Y'_i)^2} \quad (4.4)$$



Y 代表真實數值而 Y' 代表預測數值， N 代表預測資料數。

為了避免 MAPE 值遇到除以 0 的情況，真實數值為 0 的資料不計入。

4.4 在高速公路資料集的比較

本研究選擇 PEMS04 與 PEMS08 作為評估用的資料集，這兩份資料集在相關研究中經常被作為測試資料使用，具備高度的代表性與公信力。資料集整體描述請見表 4.4。

表 4.4: PEMS04、PEMS08 資料集整體描述

資料集名稱	PEMS04	PEMS08
時間範圍	2018.1.1 - 2018.2.28，共 59 天	2016.7.1 - 2016.8.31，共 62 天
時間間隔	5 分鐘（一天 288 個時間段）	同左
站點數量	307	170
交通資料	車流量、平均佔有率、車速，共 3 個欄位	同左
額外資料	一週當中的第幾天、時間，共 2 個欄位	同左

4.4.1 高速公路資料集—PEMS04、PEMS08

Caltrans Performance Measurement System (PEMS) 蒐集並儲存所有加州高速公路相關的數據資料。PEMS 依照地理位置將整體交通資料劃分為 12 個區域（如圖 4.1 與表 4.5 所示）。PEMS 資料集常被作為交通流量預測任務中的測試資料集使用，其中 STSGCN 論文作者已將其整理並公開於¹。該資料涵蓋第 3、4、7 與 8

¹<https://github.com/Davidham3/STSGCN>

區，並依區域編號命名為 PEMS03、PEMS04、PEMS07 和 PEMS08。

由於 PEMS04 與 PEMS08 的平均車流量較高，預測難度相對較大，更具挑戰性。此外，這兩份資料集皆包含車流量、車速與車道佔有率等三種欄位，而 PEMS03 與 PEMS07 僅包含車速資料，相較之下，PEMS04 與 PEMS08 的資料內容較為完整。因此，本研究選擇 PEMS04 與 PEMS08 作為測試資料集。

表 4.5: PEMS 分區列表

編號	區域
1	Eureka
2	Redding
3	Marysville / Sacramento
4	Bay Area / Oakland
5	San Luis Obispo / Santa Barbara
6	Fresno / Bakersfield
7	Los Angeles
8	San Bernardino / Riverside
9	Bishop
10	Stockton
11	San Diego
12	Orange County



圖 4.1: PEMS 分區圖

資料來源：<https://dot.ca.gov/caltrans-near-me>

實驗集的原始資料為：一、PEMS Station 5-Minute²：以 5 分鐘為最小單位，紀錄偵測站整體和各車道測量數據。欄位說明如表 4.6。二、Station Metadata³：偵測站資訊，包含偵測站名稱、經緯度等資訊，欄位敘述如表 4.7，車道種類請參考表 4.8。

本研究將高速公路系統轉換為圖論模型，其中節點代表各偵測站；若兩個偵

²https://pems.dot.ca.gov/?dnode=Clearinghouse&type=station_5min&district_id=3&submit=Submit

³https://pems.dot.ca.gov/?dnode=Clearinghouse&type=meta&district_id=3&submit=Submit

表 4.6: PEMS Station 5-Minute 資料欄位

編號	欄位名稱	欄位個數	格式	說明
1	Timestamp	1	日期	時間段的開始日期和時間，最小刻度為 1 秒
2	Station	1	整數	偵測站編號
3	District	1	整數	分區號碼（見表 4.5）
4	Freeway	1	整數	高速公路代碼
5	Direction of Travel	1	字串	行駛方向，選項為 N,S,E,W
6	Lane Type	1	字串	偵測站車道形式，格式為兩字英文代碼
7	Station Length	1	浮點數	偵測站所涵蓋的長度，最小刻度為 10^{-3}
8	Samples	1	整數	偵測站採集樣本數，最小刻度為 1
9	% Observed	1	整數	從偵測得來的樣本比例（缺失樣本由估算獲得），範圍在 $[0, 100]$ ，單位為%，最小刻度為 1
10	Total Flow	1	整數	偵測站 5 分鐘內通過車輛數，單位為車輛數/5 分鐘，最小刻度為 1
11	Avg Occupancy	1	浮點數	5 分鐘內偵測站平均占用率，範圍在 $[0, 1]$ ，最小刻度為 10^{-4}
12	Avg Speed	1	浮點數	5 分鐘內偵測站平均速度，單位為 Mph，最小刻度為 0.1
13	Lane Samples	8	整數	車道的樣本數，最小刻度為 1
14	Lane Flow	8	整數	5 分鐘內車道的車輛數，單位為車輛數/5 分鐘，最小刻度為 1
15	Lane Avg Occ	8	浮點數	5 分鐘內車道平均占用率，範圍在 $[0, 1]$ ，最小刻度為 10^{-4}
16	Lane Avg Speed	8	浮點數	5 分鐘內車道平均速度，單位為 Mph，最小刻度為 0.1
17	Lane Observed	8	整數	是否有偵測到車道的資料，選項為 0（未測量）、1（測量）

測站在實際路網上相鄰，則在模型中對應的兩個節點之間即建立一條邊，表示其相互連接。

根據前述的網路模型與 MGSTT 架構，本研究將原始資料整理為三種類型的數據，建構出 PEMS04、PEMS08 資料集，如（圖 4.2）所示。包含：一、交通狀態矩陣（表 4.9）：以 5 分鐘為單位，包含車流量、車道佔用率及行駛速度。二、額外資訊：以 5 分鐘為單位，偵測站點的時間資訊（表 4.10）。三、偵測站點距離（表 4.11）：所有相連偵測站的距離，距離由偵測站點的經緯度計算得出。

表 4.7: PEMS Station Metadata 資料欄位

編號	欄位名稱	欄位個數	格式	說明
1	ID	1	整數	偵測站編號
2	Freeway	1	整數	高速公路編號
3	Freeway Direction	1	字串	高速公路方向，選項為 N,S,E,W
4	County Identifier	1	整數	分區號碼(見表 4.5)
5	City	1	整數	城市代碼
6	State Postmile	1	浮點數	最小刻度為 10^{-3}
7	Absolute Postmile	1	浮點數	最小刻度為 10^{-3}
8	Latitude	1	浮點數	緯度，最小刻度為 10^{-6}
9	Longitude	1	浮點數	經度，最小刻度為 10^{-6}
10	Length	1	浮點數	偵測站偵測範圍長度，最小刻度為 10^{-3}
11	Type	1	字串	車道形式，格式為兩字英文代碼(見表 4.8)
12	Lanes	1	整數	車道數，最小刻度為 1
13	Name	1	字串	Station 名稱
14	User IDs1	1	字串	使用者自定義別名
15	User IDs2	1	字串	使用者自定義別名
16	User IDs3	1	字串	使用者自定義別名
17	User IDs4	1	字串	使用者自定義別名



表 4.8: PEMS 車道種類

縮寫(全名)	說明
CD(Coll/Dist)	
CH(Conventional Highway)	常規公路
FF(Fwy-Fwy)	高速公路交界處
HV(HOV)	高乘載車道
ML(Mainline)	主要道路
OR(On Ramp)	入口匝道
FR(Off Ramp)	出口匝道

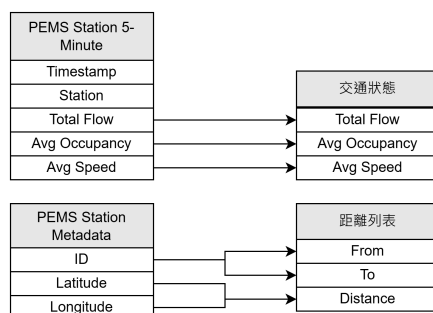


圖 4.2: PEMS 資料集欄位來源，原始資料僅列出有使用到的，箭頭為資料對應關係。

表 4.9: PEMS 資料集交通狀態矩陣

編號	欄位名稱	欄位個數	格式	說明
1	Total Flow	1	整數	偵測站 5 分鐘內通過車輛數，單位為車輛數/5 分鐘，最小刻度為 1
2	Avg Occupancy	1	浮點數	5 分鐘內偵測站平均占用率，範圍在 $[0, 1]$ ，最小刻度為 10^{-4}
3	Avg Speed	1	浮點數	5 分鐘內偵測站平均速度，單位為 Mph，最小刻度為 0.1

表 4.10: PEMS 額外資訊資料集欄位

編號	欄位名稱	欄位個數	格式	說明
1	Weekday	1	整數	一週當中的第幾天，範圍 $[1, 7]$ ，最小刻度為 1
2	Time	1	整數	一天當中的第幾個 5 分鐘，範圍 $[0, 287]$ ，最小刻度為 1

表 4.11: PEMS 資料集偵測站點距離， N 為偵測站數量

編號	欄位名稱	欄位個數	格式	說明
1	From	1	整數	起始偵測站編號，流水號，範圍為 $[1, N]$
2	To	1	整數	結束偵測站編號，流水號，範圍為 $[1, N]$
3	Distance	1	浮點數	兩站之間距離，單位為公里，最小刻度為 0.01

4.4.2 PEMS04 資料集的統計分析

本小節將針對 PEMS04 資料集進行分析，內容包括車流量與車速的基本統計描述，接著從空間面向探討各站點的人流分布情形，最後從時間面向分析平日與假日的使用差異。車流量與車速的基本資訊如表 4.12 所示。

表 4.13 顯示 PEMS04 中車流量與車速的統計分布。整體來看，車流量的分布偏右，並存在極端高值，在尖峰時段，部分站點每 5 分鐘車流量可超過 900 輛；而車速的分布偏左，亦有極端低值，尖峰時段部分站點車速甚至降至 3 Mph。

圖 4.3 呈現各站點每 5 分鐘平均車流量的分布情形，顯示多數站點集中於每 5 分鐘 90 至 300 輛之間；圖 4.4 則為各站點平均車速的分布圖，大多數站點的車速落在 55 至 70 Mph 範圍內。

圖 4.5 與圖 4.6 比較平日與假日的每小時車流量與車速變化。平日時段中，早上 7 至 9 點及下午 14 至 18 點為尖峰時段，車流量約落在 10 萬輛左右，車速則普遍低於 60 Mph；而在假日時，車潮高峰集中於 10 點至 18 點，其中 10 點至 14 點的車流量甚至高於平日。然而整體而言，假日時段的 10 點至 14 點車速仍高於平日，平均車速皆高於 63 Mph，相較之下，平日時尖峰車速則低於 60 Mph，顯示假日交通相對順暢。

表 4.12: PEMS04 資料集中車流量與車速之基本資訊統計

項目	數值
資料天數	59 天
每日時間區段數	288 區段
偵測站點數	307 站
總資料量	車流量與車速各 5.22×10^6 筆

表 4.13: PEMS04 資料集中車流量與車速之統計指標

統計指標	車流量 (車輛數/5 分鐘)	車速 (Mph)
平均值	211.70	63.47
標準差	158.07	8.36
最小值	0.00	3.00
第一四分位數 (Q1)	81.00	62.50
中位數 (Q2)	180.00	65.60
第三四分位數 (Q3)	319.00	67.80
最大值	919.00	85.20




圖 4.3: PEMS04 資料集中各站點每 5 分鐘平均車流量之數據分布，每 30 車輛數為一區間，呈現各區間的個別站點數與累計站點數。

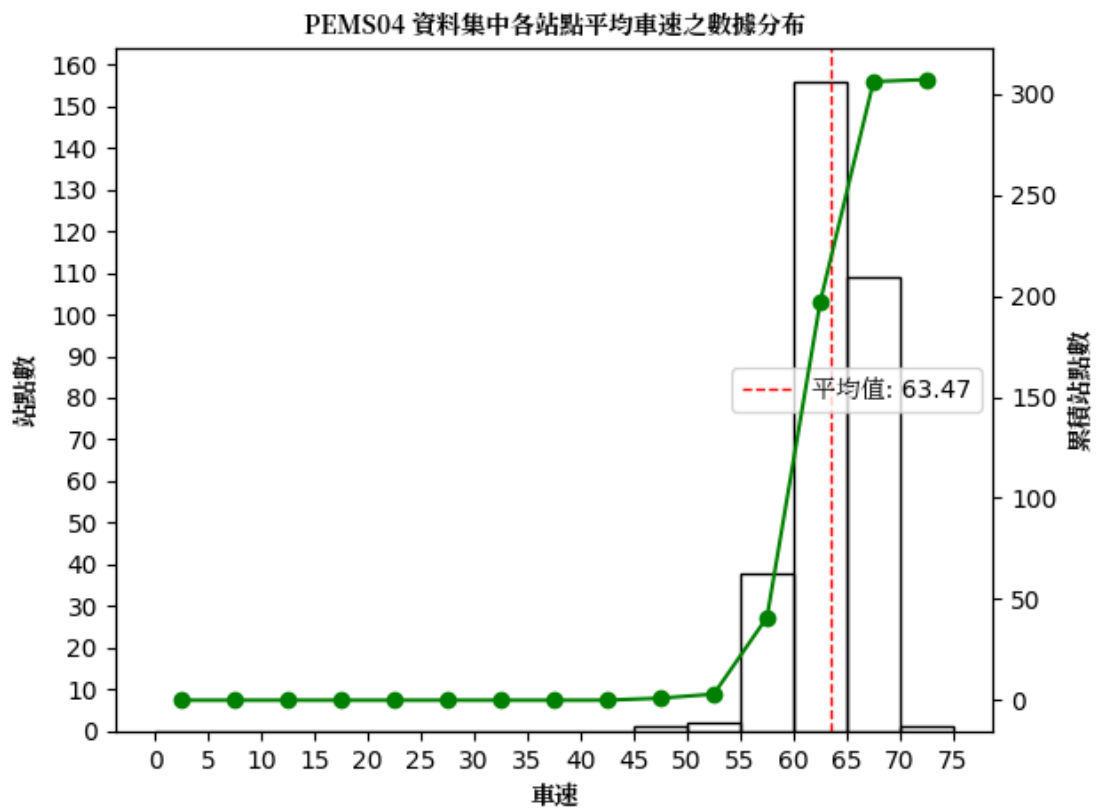


圖 4.4: PEMS04 資料集中各站點平均車速之數據分布，每 5 Mph 為一區間，呈現各區間的個別站點數與累計站點數。




圖 4.5: PEMS04 資料集中平日與假日每小時車流量之比較。

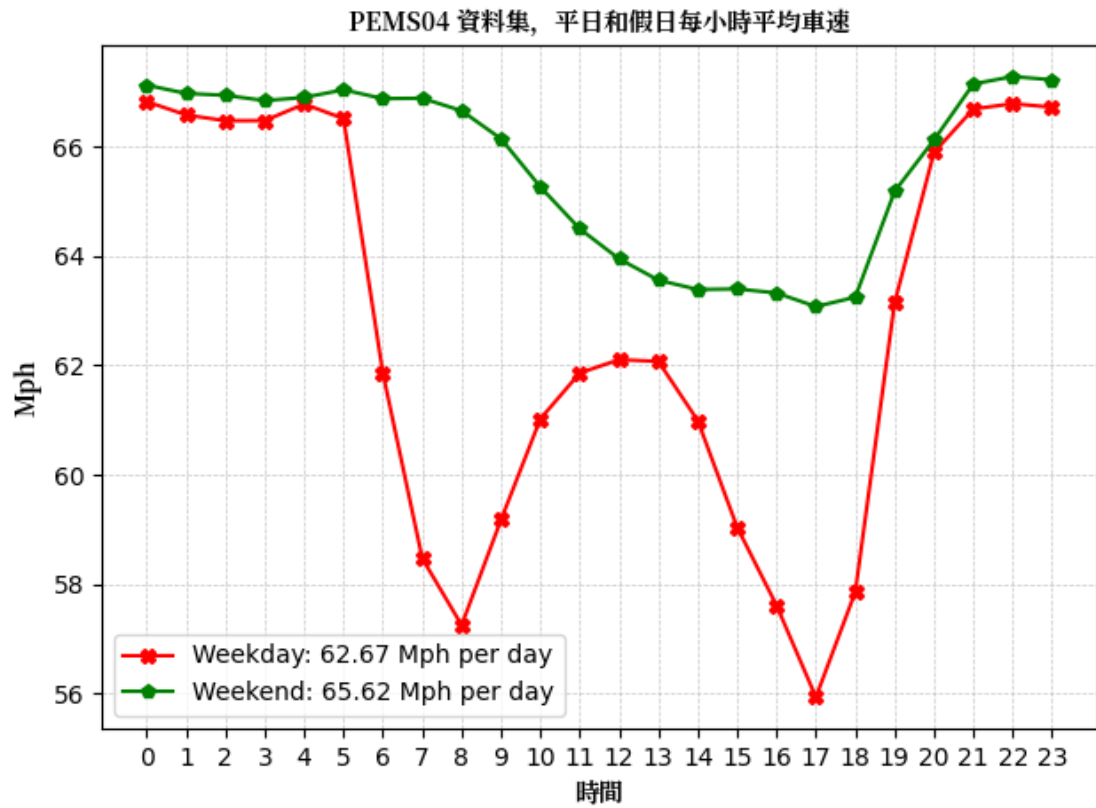


圖 4.6: PEMS04 資料集中平日與假日每小時車速之比較。

4.4.3 PEMS08 資料集的統計分析

本小節將針對 PEMS08 資料集進行分析，內容包括車流量與車速的基本統計描述，接著從空間面向探討各站點的人流分布情形，最後從時間面向分析平日與假日的使用差異。車流量與車速的基本資訊如表 4.14 所示。

表 4.15 顯示 PEMS08 中車流量與車速的統計分布。整體來看，車流量的分布偏右，並存在極端高值，在尖峰時段，部分站點每 5 分鐘車流量可超過 1100 輛；而車速的分布偏左，亦有極端低值，尖峰時段部分站點車速甚至降至 3 Mph。

圖 4.7 呈現各站點每 5 分鐘平均車流量的分布情形，顯示多數站點集中於每 5 分鐘 180 至 300 輛之間；圖 4.8 則為各站點平均車速的分布圖，大多數站點的車速落在 55 至 70 Mph 範圍內。

圖 4.9 與圖 4.10 呈現 PEMS08 資料集中平日與假日的每小時車流量與車速變化情形。平日時段中，早上 7 點至 9 點與下午 14 點至 18 點為交通尖峰時段，車流量約落在 5 萬至 6 萬輛之間。此時段的平均車速在早上約為 61 至 62 Mph，下午 15 點至 18 點則低於 60 Mph。

假日時，車潮高峰集中於上午 10 點至下午 18 點，整體車流量約略高於 5 萬輛。其中，上午 10 點至 14 點的車流量甚至高於平日時段。與 PEMS04 的觀察結果相似，假日時段的 10 點至 14 點車速仍高於平日，平均車速普遍超過 61 Mph，顯示相較於平日，假日的交通狀況較為順暢。

表 4.14: PEMS08 資料集中車流量與車速之基本資訊統計

項目	數值
資料天數	62 天
每日時間區段數	288 區段
偵測站點數	170 站
總資料量	車流量與車速各 3.04×10^6 筆



表 4.15: PEMS08 資料集中車流量與車速之統計指標

統計指標	車流量 (車輛數/5 分鐘)	車速 (Mph)
平均值	230.68	63.76
標準差	146.22	6.65
最小值	0.00	3.00
第一四分位數 (Q1)	110.00	62.60
中位數 (Q2)	215.00	64.90
第三四分位數 (Q3)	334.00	67.40
最大值	1147.00	82.30

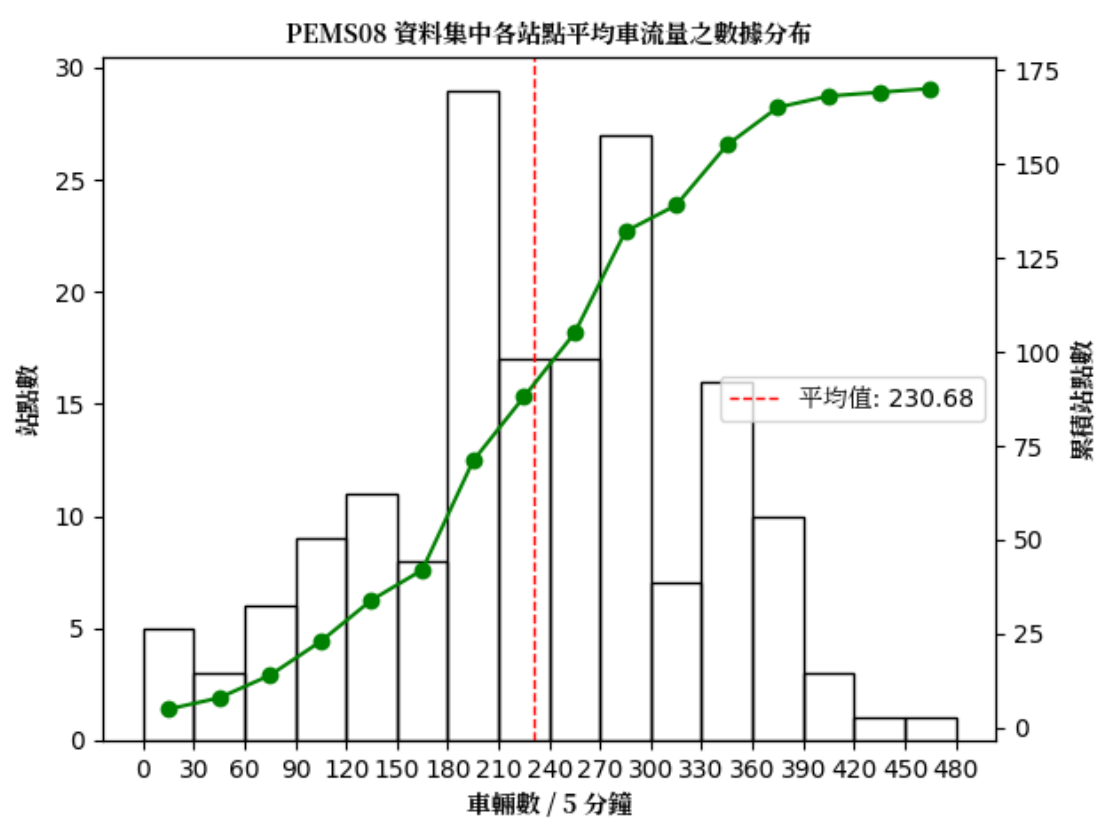


圖 4.7: PEMS08 資料集中各站點每 5 分鐘平均車流量之數據分布，每 30 車輛數為一區間，呈現各區間的個別站點數與累計站點數。

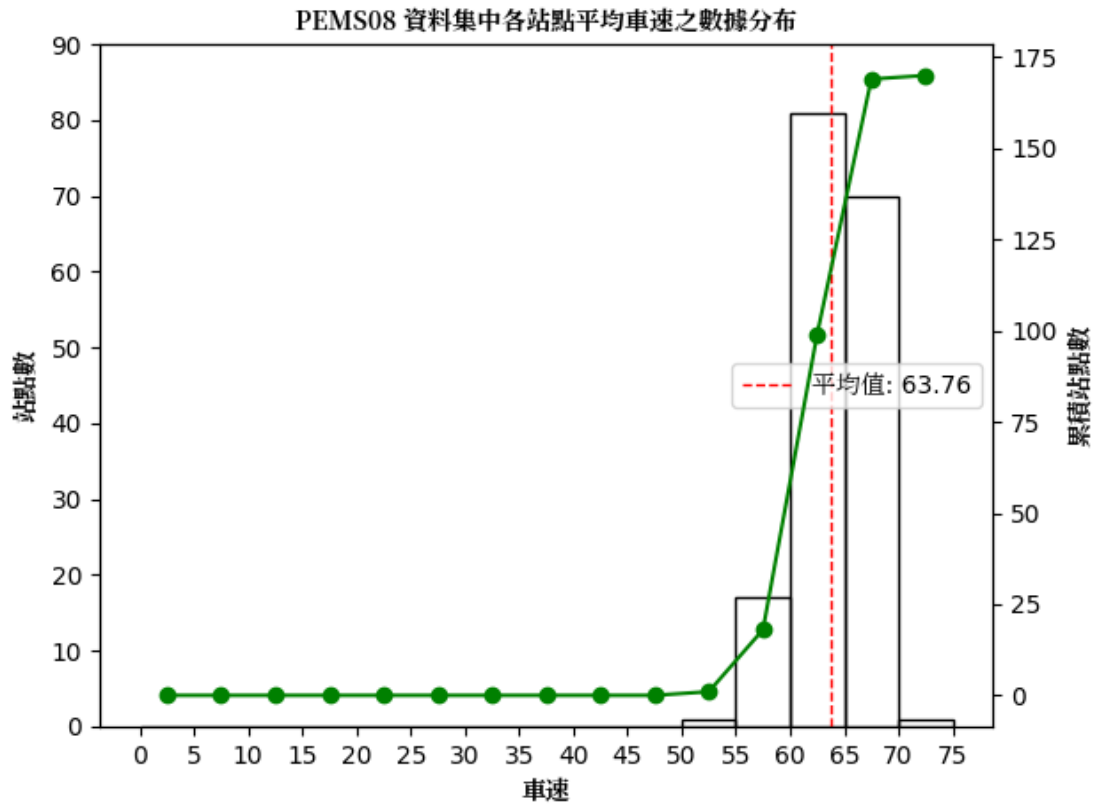


圖 4.8: PEMS08 資料集中各站點平均車速之數據分布，每 5 Mph 為一區間，呈現各區間的個別站點數與累計站點數。

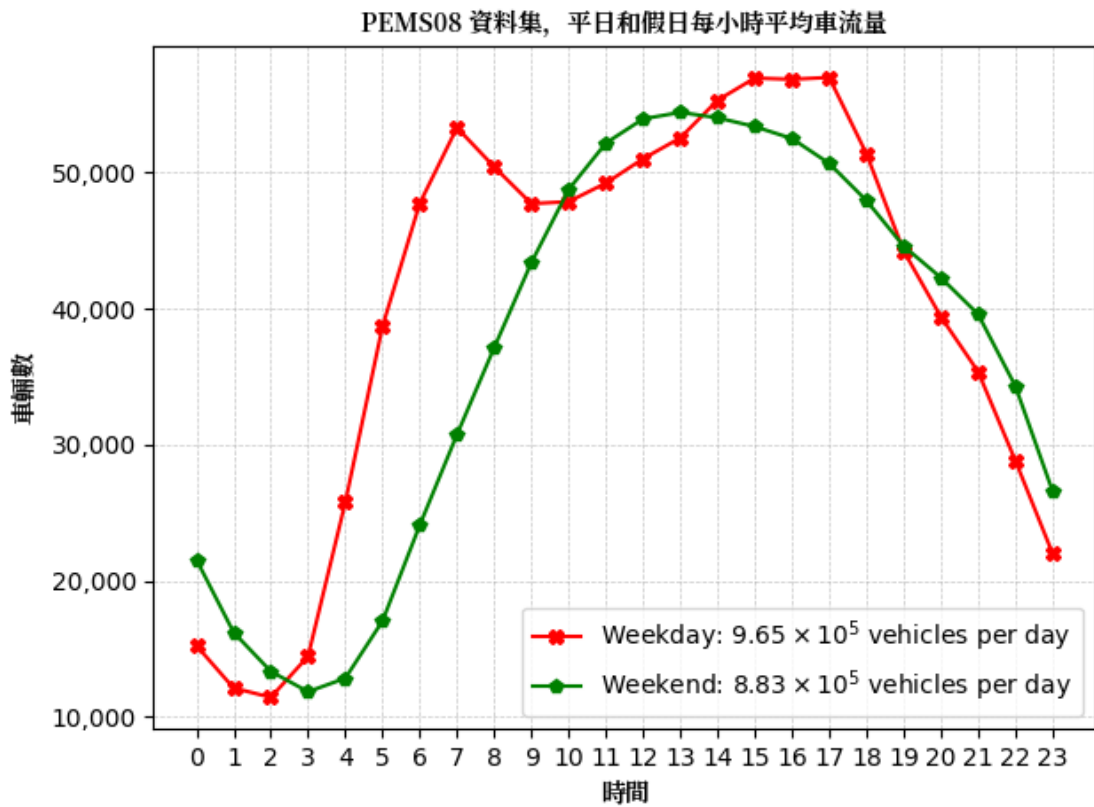


圖 4.9: PEMS08 資料集中平日與假日每小時車流量之比較。




圖 4.10: PEMS08 資料集中平日與假日每小時車速之比較。

4.4.4 PEMS04 和 PEMS08 資料集實驗結果

本研究針對 PEMS04 與 PEMS08 資料集，分別進行車流量與車速的預測實驗，詳列如表 4.16 所示。

在 MGSTT 模型中，PEMS04 與 PEMS08 資料集分別使用空間相鄰圖與流量變化相似圖作為空間關係的建模方式。無論是預測車流量或車速，流量變化相似圖皆以車流量資料作為相似度計算的依據。

表 4.16: PEMS04 與 PEMS08 資料集之預測任務設定

實驗編號	使用資料集	預測目標
1	PEMS04	車流量
2	PEMS04	車速
3	PEMS08	車流量
4	PEMS08	車速

表 4.17 列出 PEMS04 與 PEMS08 兩份資料集的實驗結果。整體而言，STFGNN 在所有資料集上的表現均優於 STSGCN，顯示其藉由考量站點間的相似性與採用門控卷積以捕捉時間相關性，確實能有效提升預測準確度。MGSTT 在所有預測任務中於多項評估指標皆名列前茅，且在多數任務上表現優於 GMAN，證實透過同時建模多種空間關係，能進一步強化模型的預測能力。

另一方面，ST-GRAT 採用自回歸 (autoregressive) 方式進行預測，導致預測誤差隨時間間距逐漸累積，進而降低整體預測準確度，其表現明顯落後於其他模型。相較之下，MGSTT 移除自回歸機制，成功避免誤差隨預測步長擴大，使得模型在穩定性與準確度上皆具優勢。



表 4.17: PEMS04 和 PEMS08 資料集預測，提出模型 MGSTT 和其他比較模型預測結果，↓表示指標越低越好，紅字代表最佳結果。

實驗編號	預測欄位		STSGCN	STFGNN	GMAN	ST-GRAT	MGSTT
1	PEMS04 車流量	MAE(車輛數) ↓	27.43	21.40	20.24	175.13	20.09
		MAPE(%) ↓	19.01	14.13	13.41	308.39	13.16
		RMSE(車輛數) ↓	42.14	33.96	31.76	221.99	31.88
2	PEMS04 車速	MAE(Mph) ↓	2.17	1.69	1.80	3.48	1.66
		MAPE(%) ↓	4.94	3.64	3.95	8.05	3.55
		RMSE(Mph) ↓	4.74	3.81	4.15	6.54	3.88
3	PEMS08 車流量	MAE(車輛數) ↓	21.09	16.80	16.17	143.32	15.44
		MAPE(%) ↓	13.43	10.82	10.15	96.55	9.84
		RMSE(車輛數) ↓	32.39	26.07	25.32	190.83	24.77
4	PEMS08 車速	MAE(Mph) ↓	1.87	1.48	1.52	4.79	1.38
		MAPE(%) ↓	4.36	3.17	3.28	8.75	3.04
		RMSE(Mph) ↓	4.36	3.43	3.59	6.76	3.49

4.4.5 關係圖對 PEMS04 和 PEMS08 資料集預測結果的影響

在本實驗中，本研究透過不同關係圖的組合，分析各種空間關係對模型預測結果的影響。從表 4.18 到表 4.21，列出了 PEMS04 和 PEMS08 實驗結果。

在 PEMS04 與 PEMS08 的車流量預測任務中，移除空間相鄰圖或流量變化相似圖皆會導致錯誤率明顯上升，顯示兩種空間關係對於預測車流量的準確度具有重要影響。然而，在這兩份資料集的車速預測任務中，移除其中任一空間圖對預測結果的影響並不顯著，甚至在 PEMS08 的車速預測中，移除流量變化相似圖後，整體表現反而有所提升。

表 4.18: PEMS04 在不同關係圖組合下，車流量預測結果，↓表示指標越低越好，紅字代表最佳結果。

空間相鄰圖	流量變化相似圖	MAE(人次)↓	MAPE(%)↓	RMSE(人次)↓
√	√	20.09	13.16	31.88
	√	20.35	13.41	32.28
√		20.83	13.70	32.86

表 4.19: PEMS04 在不同關係圖組合下，車速預測結果，↓表示指標越低越好，紅字代表最佳結果。


空間相鄰圖	流量變化相似圖	MAE(人次)↓	MAPE(%)↓	RMSE(人次)↓
√	√	1.66	3.55	3.88
	√	1.67	3.60	3.92
√		1.68	3.61	3.92

表 4.20: PEMS08 在不同關係圖組合下，車流量預測結果，↓表示指標越低越好，紅字代表最佳結果。

空間相鄰圖	流量變化相似圖	MAE(人次)↓	MAPE(%)↓	RMSE(人次)↓
√	√	15.44	9.84	24.77
	√	15.89	10.10	25.65
√		15.61	9.90	24.99

表 4.21: PEMS08 在不同關係圖組合下，車速預測結果，↓表示指標越低越好，紅字代表最佳結果。

空間相鄰圖	流量變化相似圖	MAE(人次) ↓	MAPE(%) ↓	RMSE(人次) ↓
V	V	1.38	3.04	3.49
	V	1.40	3.06	3.53
V		1.37	2.95	3.44



4.4.6 時空嵌入對 PEMS04 和 PEMS08 資料集預測結果的影響

在本項實驗中，本研究探討 MGSTT 中的時空嵌入機制對 PEMS04 與 PEMS08 資料集之預測任務的影響。根據表 4.22 所示，於 PEMS04 與 PEMS08 的車流量預測任務中，移除時空嵌入會使預測結果略微變差；而在車速預測任務中，是否加入時空嵌入對結果影響甚微，幾乎沒有顯著差異。

表 4.22: PEMS04 與 PEMS08 資料集在有無時空嵌入下之預測實驗結果，↓表示指標越低越好，紅字代表最佳結果。

實驗編號	預測欄位		有時空嵌入	無時空嵌入
1	PEMS04 車流量	MAE(車輛數) ↓	20.09	20.12
		MAPE(%) ↓	13.16	13.24
		RMSE(車輛數) ↓	31.88	31.95
2	PEMS04 車速	MAE(Mph) ↓	1.66	1.66
		MAPE(%) ↓	3.55	3.57
		RMSE(Mph) ↓	3.88	3.88
3	PEMS08 車流量	MAE(車輛數) ↓	15.44	15.47
		MAPE(%) ↓	9.84	9.89
		RMSE(車輛數) ↓	24.77	24.88
4	PEMS08 車速	MAE(Mph) ↓	1.38	1.39
		MAPE(%) ↓	3.04	3.06
		RMSE(Mph) ↓	3.49	3.52

4.4.7 PEMS04 與 PEMS08 資料集於不同預測時間間距下之結果分析

模型會根據歷史資料，預測不同時間間距下的交通狀態，例如預測未來 5 分鐘或 10 分鐘後的流量情形。在本節中，本研究將針對 PEMS04 與 PEMS08 資料集的各個預測時間間距，分別呈現對應的預測評估指標。由於 ST-GRAT 的表現與其他模型差距過大，因此未將其結果呈現在圖中。

圖 4.11 分別呈現各模型於 PEMS04 資料集下，車流量預測任務在不同預測時間間距下的 MAE、MAPE 與 RMSE 指標表現，詳細數據請參閱表 A.1。整體而言，ST-GRAT 在預測時間為 5 分鐘時，表現尚可，與 STSGCN 接近。然而，隨著預測時間間距由 10 分鐘擴大至 60 分鐘，ST-GRAT 的預測準確度明顯下滑，三項指標從 5 分鐘時的 24.56, 17.69, 37.73，惡化至 60 分鐘的 206.19, 352.40, 245.66，為所有模型中表現最差者。MGSTT 與 GMAN 表現穩定且優異，MGSTT 在短期預測明顯領先 GMAN，但當預測時間超過 45 分鐘（以 MAE 指標）與 30 分鐘（以 RMSE 指標）時，GMAN 的預測表現逐漸超越 MGSTT。STFGNN 與 STSGCN 則分別排在第三與第四名。

圖 4.12 分別呈現各模型於 PEMS04 資料集下，車速預測任務的評估結果，詳細數據請參閱表 A.2。ST-GRAT 在 5 分鐘預測表現略優於 STSGCN，但隨著時間間距增加，準確率快速下降，整體表現居末。MGSTT 與 STFGNN 分居第一、第二名，其中 STFGNN 的預測準確率隨著時間間距拉長，下降幅度略大於 MGSTT，尤其在 MAE 與 MAPE 指標上，兩者差距逐漸拉大。GMAN 與 STSGCN 則排在第三、四名，而 STSGCN 雖然排名較後，但其預測準確率下降的幅度在所有模型中最小。

圖 4.13 分別呈現各模型於 PEMS08 資料集下，車流量預測任務的指標表現，詳細數據請參閱表 A.3。ST-GRAT 除了在 5 分鐘時能與其他模型相近，隨著時間間距從 10 分鐘至 60 分鐘，其預測表現快速惡化，三項指標從 17.72, 11.22, 27.60 上升至 162.82, 103.28, 208.75，表現明顯落後其他模型。在 MAPE 指標上，最差表

現出現在 20 分鐘 (140.70)。MGSTT、GMAN、STFGNN 與 STSGCN 的整體排序一致，分別為第一至第四名，四者在不同預測時間間距下，表現趨勢相近。

圖 4.14 分別呈現各模型於 PEMS08 資料集下，車速預測任務的評估結果，詳細數據請參閱表 A.4。ST-GRAT 在短期預測 (5 分鐘) 時，能與其他模型抗衡，但時間間距增加後，準確率迅速下降，整體表現墊底。STSGCN 雖為第二差，但在所有模型中，隨著預測時間間距拉長，其準確率下降幅度最小。短期預測時，MGSTT、STFGNN 與 GMAN 排名前三，其中 STFGNN 的準確率會隨預測時間增長而逐步低於 GMAN，特別是在 MAPE 指標。而在 RMSE 指標上，MGSTT 則在 15 分鐘以及之後的準確率低於 STFGNN。

整體而言，本研究針對 PEMS04 與 PEMS08 資料集之車流量與車速預測任務，探討不同預測時間間距下各模型的表現變化。從實驗結果可觀察到，ST-GRAT 雖在短期預測 (如 5 分鐘) 具一定競爭力，但其預測準確率隨時間間距拉長而明顯下降，成為長時間預測中表現最差的模型。相較之下，MGSTT 與 GMAN 在大多數時間間距下皆展現穩定且優異的預測能力，其中 MGSTT 多數時間具領先優勢，而 GMAN 則在部分長時間預測中超越 MGSTT。STFGNN 與 STSGCN 的表現次之，前者整體排名第三，後者雖排名居後，但其準確率下降幅度最小，具穩定性優勢。綜合上述，各模型對時間間距的敏感程度不同，突顯在進行長時間預測任務時，選擇具穩定性與高度通用性的模型具有關鍵影響。

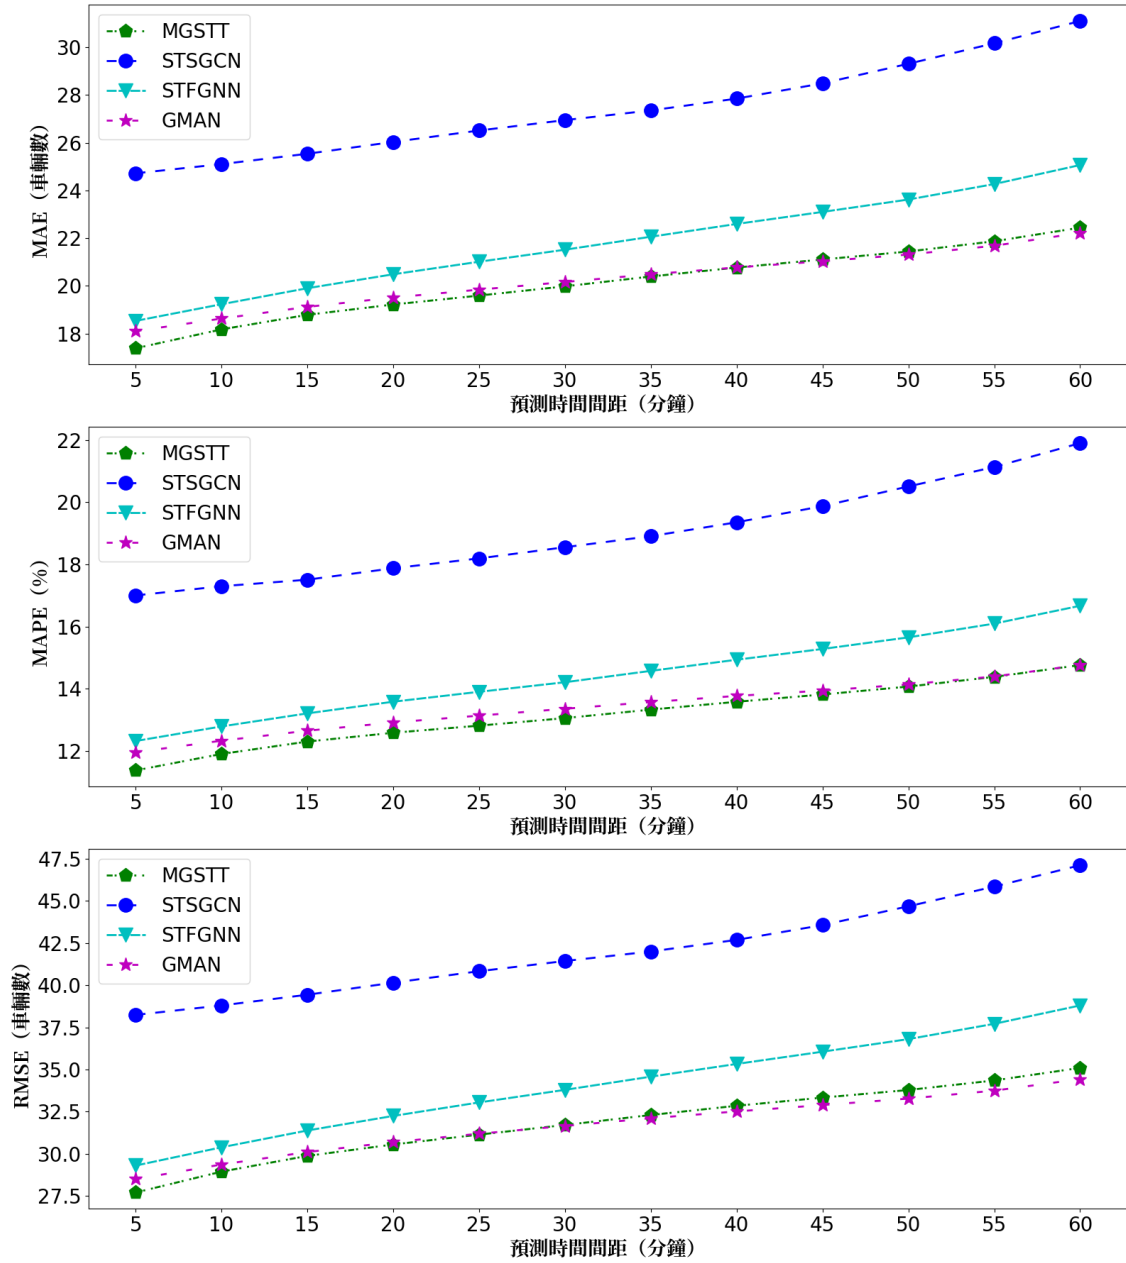


圖 4.11: PEMS04 資料集中，各模型在車流量預測上的表現，依不同預測時間間距繪製。由上至下分別為 MAE、MAPE 和 RMSE 的誤差圖。

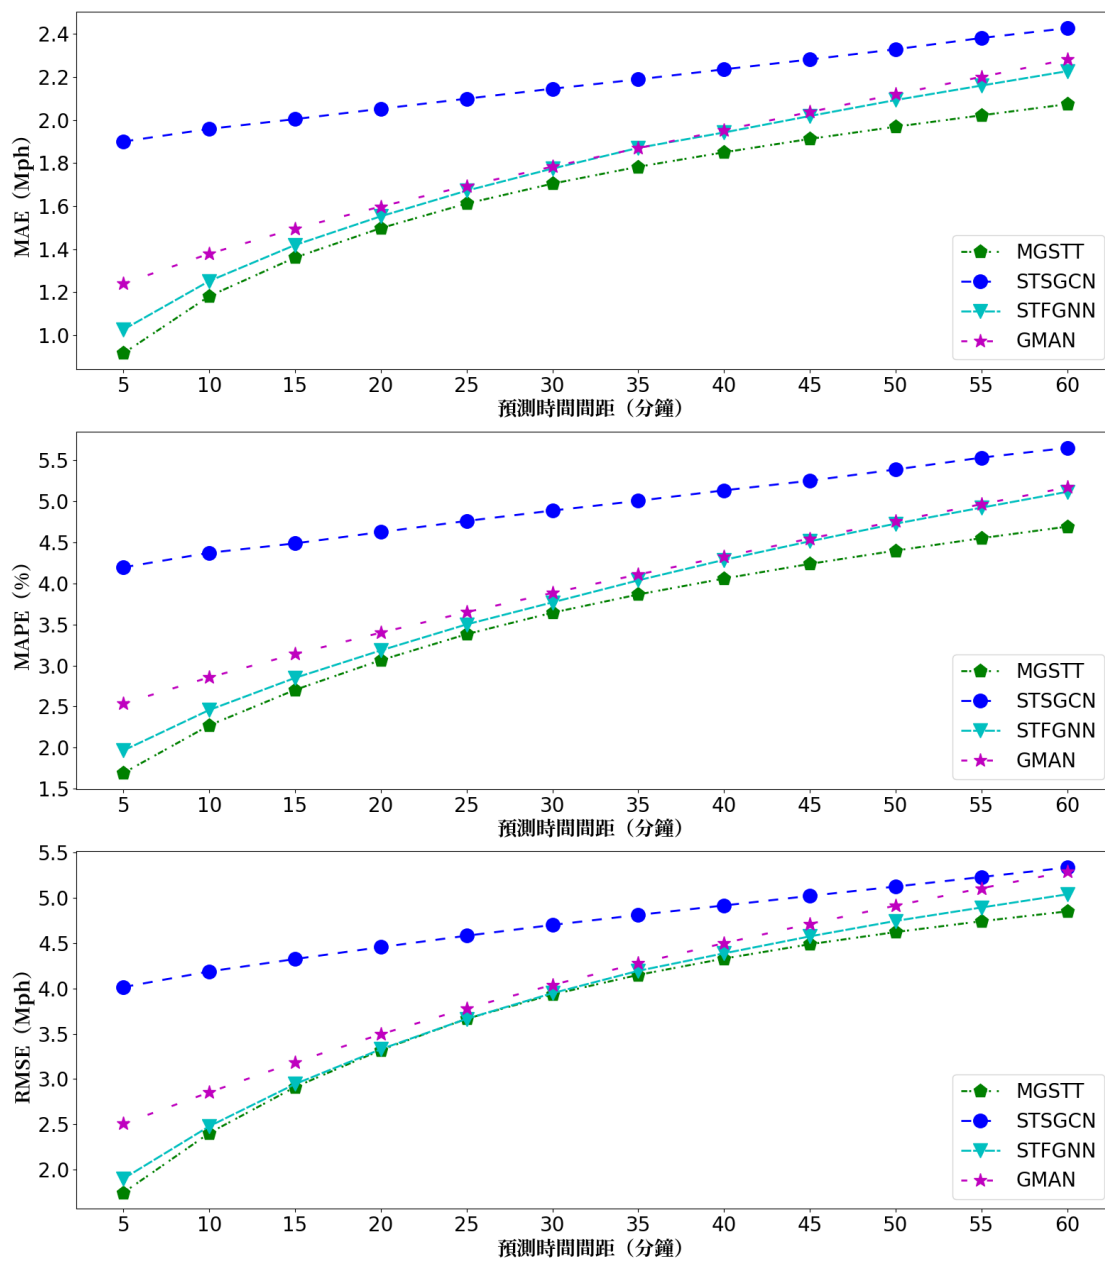


圖 4.12: PEMS04 資料集中，各模型在車速預測上表現，依不同預測時間間距繪製。由上至下分別為 MAE、MAPE 和 RMSE 的誤差圖。

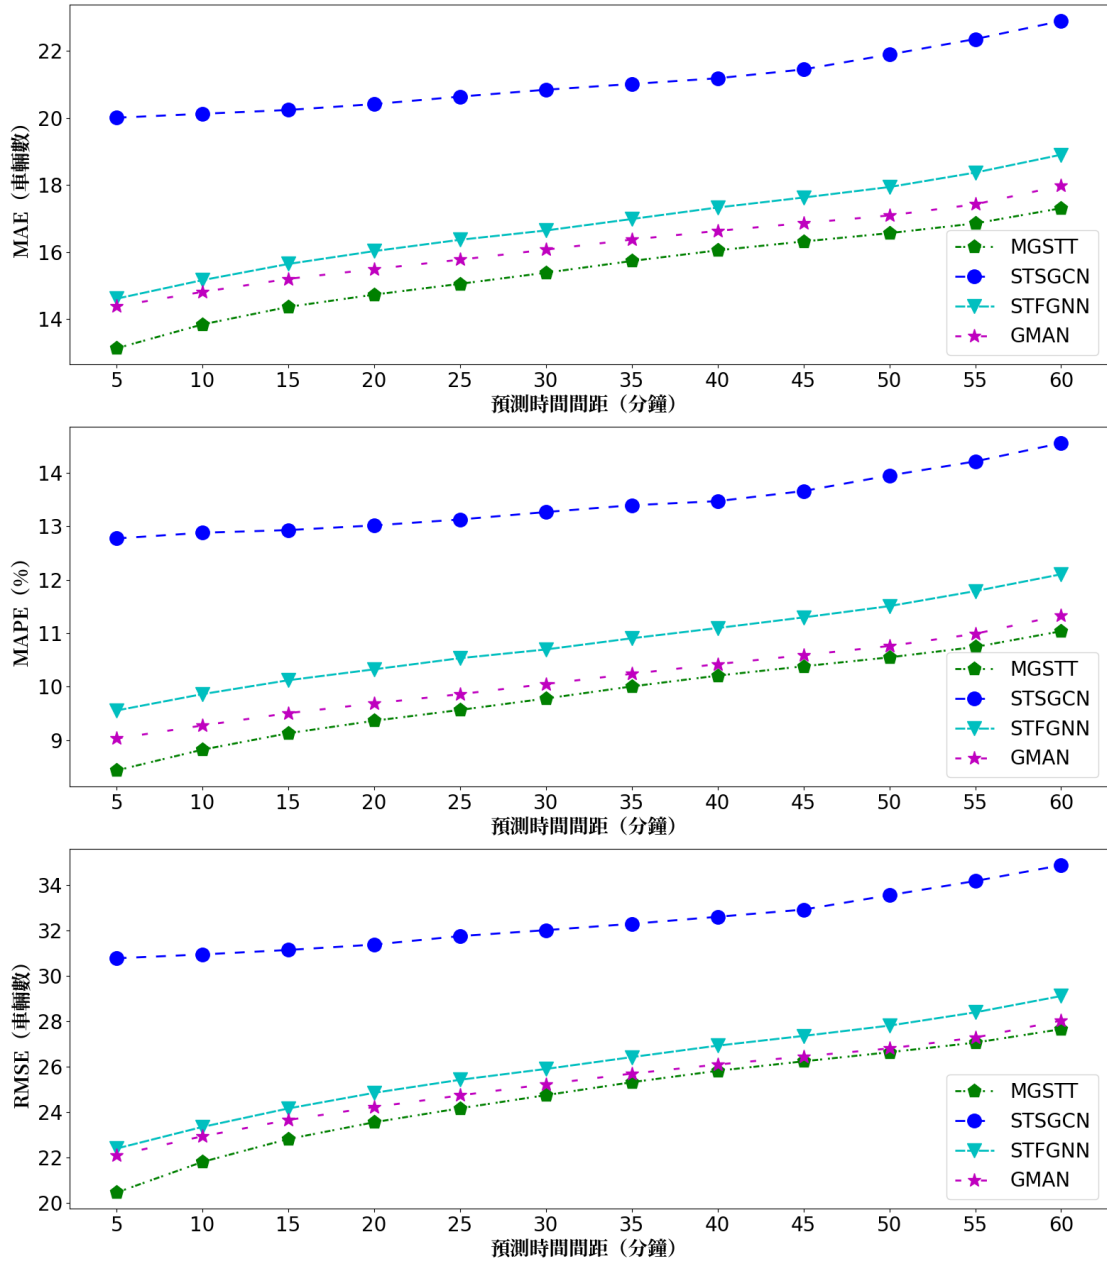


圖 4.13: PEMS08 資料集中，各模型在車流量預測上表現，依不同預測時間間距繪製。由上至下分別為 MAE、MAPE 和 RMSE 的誤差圖。




圖 4.14: PEMS08 資料集中，各模型在車速預測上表現，依不同預測時間間距繪製。由上至下分別為 MAE、MAPE 和 RMSE 的誤差圖。

4.5 在大眾運輸和共享式交通的比較

不同場景的交通狀態差異甚大，例如在高速公路是封閉的，偵測點的交通狀態和鄰近的站點有著強烈的相關性；另一方面，共享式交通允許使用者在任意兩借車站借還車輛，並且任兩站的路徑並非唯一，因此相鄰的借車站相關性並不強。由於場景的差異性，模型可能在一份資料集上表現好，但在另一份資料集上表現很差。部分研究為了測試模型在不同資料上的通用性，使用不同場景的資料集進行評估，以測試模型在不同問題上是否都能達到良好的預測結果 [19][21][22][44]。

同樣地，為了驗證模型的廣泛適用性，本研究採用三種不同類型的資料集進行測試。除了前述的高速公路交通資料集 PEMS04 與 PEMS08 外，另行蒐集位在臺北市與新北市的大眾運輸資料集 MRT，以及位在臺北市的共享式交通資料集 YouBike，以評估模型在多元交通場景中的表現。

4.5.1 大眾運輸資料集—MRT

臺北捷運為臺灣規模龐大的大眾運輸系統，服務範圍涵蓋臺北市與新北市，每日運量超過百萬人次，故本研究選擇其作為大眾運輸的案例資料。路線圖如圖 4.15 所示，本研究聚焦於臺北捷運的六條主要路線，包括文湖線、淡水信義線、松山新店線、中和新蘆線、板南線與環狀線。

本研究自相關網站蒐集台北捷運之進出站資料，經過整理與彙整後建立資料集，並命名為 MRT，MRT 為台北捷運英文全名 Taipei Mass Rapid Transit 的縮寫。該資料集的整體說明如表 4.23 所示。

表 4.23: MRT 資料集整體描述

資料集名稱	MRT
時間範圍	2023.1.1 - 2023.4.30 (共 120 天)
時間間隔	1 小時 (一天 24 個時間段)
站點數量	119
資料欄位	$Outflow_1, Outflow_2, \dots, Outflow_{119}$ 共 119 個欄位
額外資料	氣溫、雨量、一週當中的第幾天、時間，共 4 個欄位



圖 4.15: 台北捷運路線圖

資料來源：<https://www.metro.taipei/cp.aspx?n=91974F2B13D997F1>

原始資料為：一、臺北捷運各站分時進出量統計⁴：一小時內點對點之間的單向人流量（表 4.24）。二、臺北捷運車站出入口座標⁵：各車站出入口資訊，包含出入口名稱、出入口編號、經緯度（表 4.25）。三、中央氣象局觀測站日報表⁶：每小時觀測氣象統計資料，請見小節 4.5.5 描述。

表 4.24: 臺北捷運各站分時進出量統計

編號	欄位名稱	欄位個數	格式	說明
1	日期	1	日期	統計資料日期，最小刻度為 1 天
2	時段	1	整數	統計資料時刻，範圍 [0, 23]，最小刻度為 1
3	進站	1	字串	進站車站
4	出站	1	字串	出站車站
5	人次	1	整數	兩車站單向人次，最小刻度為 1

表 4.25: 臺北捷運車站出入口座標

編號	欄位名稱	欄位個數	格式	說明
1	項次	1	整數	流水號
2	出入口名稱	1	字串	車站名稱 + 出口編號
3	出入口編號	1	整數	單個出口編號為 0，多個出口由 1 開始編號
4	經度	1	浮點數	最小刻度為 10^{-8}
5	緯度	1	浮點數	最小刻度為 10^{-8}
6	是否為無障礙用	1	字串	是、否兩個選項

本研究將台北捷運系統轉換為網路模型，參考圖 4.15，用節點代表捷運車站，同一路線上相鄰的兩站在模型中視為相連的節點。在台北捷運系統中，存在兩對站外轉乘車站，分別為板南線的板橋站與環狀線的板橋站，以及板南線的新埔站與環狀線的新埔民生站；本研究將這些站外轉乘視為兩個相鄰節點。

根據前述的網路模型與 MGSTT 架構，本研究將原始資料整理為三種類型的數據，建構出 MRT 資料集，如圖 4.16 所示。包含：一、交通狀態矩陣：以 1 小時為單位，捷運車站點對點的單向車流（表 4.26）。二、額外資訊：以 1 小時為單位，捷運車站點的天氣數據以及時間資訊（表 4.27）。三、車站距離：所有車站之間距離，使用每個車站用編號最小出口的經緯度當作位置（表 4.28）。

⁴<https://data.gov.tw/dataset/128506>

⁵<https://data.gov.tw/dataset/128428>

⁶<https://e-service.cwb.gov.tw/HistoryDataQuery/index.jsp>

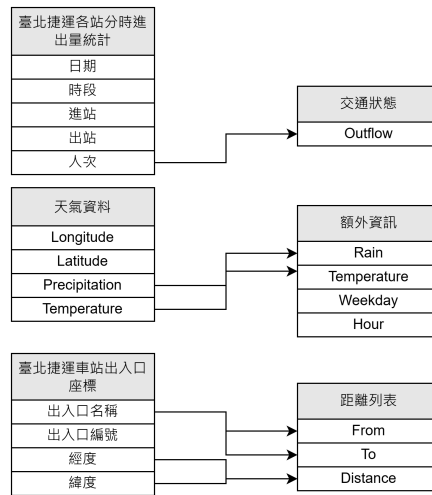


圖 4.16: MRT 資料集欄位來源，原始資料僅列出有使用到的，箭頭為資料對應關係。

表 4.26: MRT 交通狀態資料集欄位

編號	欄位名稱	欄位個數	格式	說明
i	<i>Outflow</i>	119	整數	車站到第 i 個車站一小時內人流量，單位人次/小時，最小刻度為 1

表 4.27: MRT 額外資訊資料集欄位

編號	欄位名稱	欄位個數	格式	說明
1	Rain	1	浮點數	降雨量，最小刻度為 0.1
2	Temperature	1	浮點數	氣溫，最小刻度為 0.1
3	Weekday	1	整數	一週當中的第幾天，範圍 [1, 7]，最小刻度為 1
4	Hour	1	整數	時間，範圍 [0, 23]，單位為小時，最小刻度為 1

表 4.28: MRT 資料集車站距離， N 為車站數

編號	欄位名稱	欄位個數	格式	說明
1	From	1	整數	起點車站編號，範圍為 $[0, N - 1]$ ，最小刻度為 1
2	To	1	整數	終點車站編號，範圍為 $[0, N - 1]$ ，最小刻度為 1
3	Distance	1	浮點數	兩站之間距離，浮點數，單位為公里，最小刻度為 10^{-17}

4.5.2 MRT 資料集的統計分析

本小節將針對 MRT 資料集進行分析，內容包括人流量的基本統計描述，接著從空間面向探討各站點的人流分布情形，最後從時間面向分析平日與假日的使用差異。人流量的基本資訊如表 4.29 所示。

表 4.30 呈現了 MRT 資料集的統計分布，從數據中可以發現，僅有少部分站點之間有人流量產生；在有流量紀錄的站點中，多數流量集中於個位數，其餘數據分布較為分散，最大值可達 1885 人次。

接著本研究從空間的角度分析，計算每個站點每小時的平均人流量，圖 4.17 顯示各站點每小時的平均人流量的數據分布，絕大部分的站每小時的平均人流量在 1500 以下，零星站點介於 1500 到 3000 之間，並且有一個站點超過 5000。也就是說 MRT 資料集中存在一個超級大點。

除了從站點層面進行分析外，本研究也彙整平日與假日的每小時人流量，以探討交通尖峰時段的分布情形，如圖 4.18 所示。平日時，尖峰時段出現在 7 點至 10 點，以及 17 點至 20 點，每小時人流量最高可達 10 萬至 20 萬人次。

假日時的尖峰時段則從 11 點延續至 20 點，每小時人流量超過 10 萬人次，且在 11 點至 17 點之間的時段，假日的人流量甚至高於平日，顯示假日的使用需求相當集中且密集。

表 4.29: MRT 資料集中人流量之基本資訊統計

項目	數值
資料天數	120 天
每日時間區段數	24 區段
偵測站點數	119 站
各站預測欄位數	119 站
總資料量	單向人流量 6.80×10^6 筆



表 4.30: MRT 資料集人流量統計資料

統計量	數值
平均值	5.58
標準差	17.69
最小值	0.00
第一四分位數 (Q1)	0.00
中位數 (Q2)	1.00
第三四分位數 (Q3)	4.00
最大值	1885.00




圖 4.17: MRT 資料集中各站點每小時平均人流量之數據分布，每 500 人次為一區間，呈現各區間的個別站點數與累計站點數。




圖 4.18: MRT 資料集中平日與假日各小時人流量之比較。

4.5.3 共享式交通資料集—Youbike

Youbike 為共享單車服務，提供服務者在特定站點之間，藉由單車移動，其服務範圍遍布台灣各地。本研究收集臺北市 Youbike 的租借資料，臺北市 Youbike 將站點區域分成 13 區，包含 12 個行政區和臺大公館校區，如表 4.31，本研究就將範圍限定於中正區與臺大公館校區的租借站點。經過整理與彙整後建立資料集，並命名為 Youbike。該資料集的整體說明如表 4.32 所示。

表 4.31: 臺北市 Youbike 分區列表

編號	區域
1	臺大公館校區
2	中正區
3	大安區
4	中山區
5	信義區
6	文山區
7	北投區
8	萬華區
9	內湖區
10	松山區
11	南港區
12	大同區
13	士林區

表 4.32: Youbike 資料集整體描述

資料集名稱	Youbike
時間範圍	2023.1.1 - 2023.4.30
時間間隔	1 小時 (一天 24 個時間段)
站點數量	341
資料欄位	<i>outflow, inflow</i> 共 2 個欄位
額外資料	氣溫、雨量、一週當中的第幾天、時間，共 4 個欄位

原始資料為：一、臺北市公共自行車 2.0 租借紀錄資料集⁷：包含所有起點為台北市租借站的租借紀錄（表 4.33）。二、YouBike 2.0 臺北市公共自行車即時資訊資料集⁸：台北市境內所有 Youbike 2.0 租借站即時剩餘車輛數、站名、經緯度等資訊（表 4.34）。三、中央氣象局觀測站日報表⁹：每小時觀測氣象統計資料（表 4.40、表 4.41）。

原始資料為：一、臺北市公共自行車 2.0 租借紀錄資料集¹⁰：包含所有起點為

⁷<https://data.gov.tw/dataset/150635>

⁸https://tcgbusfs.blob.core.windows.net/dotapp/youbike/v2/youbike_immediate.json

⁹<https://e-service.cwb.gov.tw/HistoryDataQuery/index.jsp>

¹⁰<https://data.gov.tw/dataset/150635>

表 4.33: 臺北市公共自行車 2.0 租借紀錄資料集欄位

編號	欄位名稱	欄位個數	格式	說明
1	rent_time	1	日期	借車時間，最小刻度為 1 秒
2	rent_station	1	字串	借車站點名稱
3	return_time	1	日期	還車時間，最小刻度為 1 秒
4	return_station	1	字串	還車站點名稱
5	rent	1	日期	總租用車時間，最小刻度為 1 秒
6	infodate	1	日期	更新資料日期，最小刻度為 1 天

表 4.34: YouBike 2.0 臺北市公共自行車即時資訊資料集欄位

編號	欄位名稱	欄位個數	格式	說明
1	sno	1	字串	租借站編號
2	sna	1	字串	租借站名稱 (中文)
3	total	1	整數	租借站總車位數
4	available_rent_bikes	1	整數	租借站剩餘可租車輛數
5	sarea	1	字串	租借站所在行政區 (中文) (見表 4.31)
6	mday	1	日期	借車點資料更新時間，最小刻度為 1 秒
7	latitude	1	浮點數	租借站所在緯度
8	longitude	1	浮點數	租借站所在經度
9	ar	1	字串	租借站所在地址 (中文)
10	sareaen	1	字串	租借站所在行政區 (英文)
11	snaen	1	字串	租借站名稱 (英文)
12	aren	1	字串	租借站所在地址 (英文)
13	available_return_bikes	1	整數	租借站空位數
14	act	1	整數	借車點啟用狀態，0 代表禁用，1 代表啟用
15	srcUpdateTime	1	日期	系統發布資料時間，最小刻度為 1 秒
16	updateTime	1	日期	更新數據平台後端資料庫時間，最小刻度為 1 秒
17	infoTime	1	日期	借車點資料更新時間，同 mday，最小刻度為 1 秒
18	infoDate	1	日期	借車點資料更新日期，最小刻度為 1 天

台北市租借站的租借紀錄 (表 4.33)。二、YouBike 2.0 臺北市公共自行車即時資訊資料集¹¹：台北市境內所有 Youbike 2.0 租借站即時剩餘車輛數、站名、經緯度等資訊 (表 4.34)。三、中央氣象局觀測站日報表¹²：每小時觀測氣象統計資料，請見小節 4.5.5 描述。

本研究將臺北市 YouBike 系統轉換為網路模型，其中，節點代表各個借車站。由於共享交通系統中並無固定路線，因此本研究不依照地理位置來定義節點之間的連結關係，而是將任意兩個之間有實際流量發生的站點視為相連節點。

根據前述的網路模型與 MGSTT 架構，本研究將原始資料整理為三種類型的數據，建構出 YouBike 資料集，如圖 4.19 所示。包含：一、交通狀態矩陣，以 1 小時為單位，在中正區和臺大公館校區的租車站的還入量和借出量 (表 4.35)，

¹¹https://tcgbusfs.blob.core.windows.net/dotapp/youbike/v2/youbike_immediate.json

¹²<https://e-service.cwb.gov.tw/HistoryDataQuery/index.jsp>

所採用的數據僅包含起點或終點至少一方位於中正區或臺大公館校區內的租借紀錄。二、額外資訊：以 1 小時為單位，租借站的天氣數據以及時間資訊（表 4.36）。三、站點距離：中正區和臺大公館校區的所有站點之間的距離（表 4.37）。

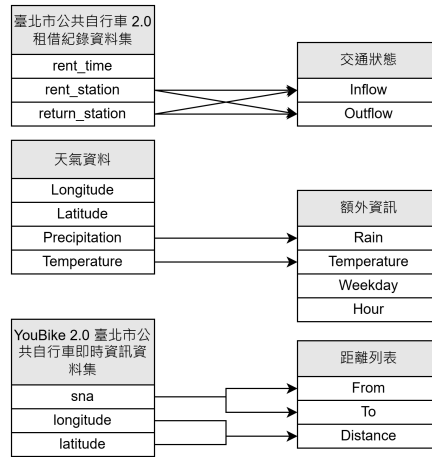


圖 4.19: Youbike 資料集欄位來源，原始資料僅列出有使用到的，箭頭為資料對應關係。

表 4.35: Youbike 2.0 交通狀態資料集欄位

編號	欄位名稱	欄位個數	格式	說明
1	<i>inflow</i>	1	整數	租借站一小時內還入量，單位車輛數/小時，最小刻度為 1
2	<i>outflow</i>	1	整數	租借站一小時內借出量，單位車輛數/小時，最小刻度為 1

表 4.36: Youbike 2.0 額外資訊資料集欄位

編號	欄位名稱	欄位個數	格式	說明
1	Rain	1	浮點數	降雨量，最小刻度為 0.1
2	Temperature	1	浮點數	氣溫，最小刻度為 0.1
3	Weekday	1	整數	一週當中的第幾天，範圍 [1, 7]，最小刻度為 1
4	Hour	1	整數	時間（小時），範圍 [0, 23]，最小刻度為 1

表 4.37: 租借站距離列表 csv 檔欄位， N 為租借站數

編號	欄位名稱	欄位個數	格式	說明
1	From	1	整數	起點租借站編號，範圍為 $[0, N - 1]$ ，最小刻度為 1
2	To	1	整數	終點租借站編號，範圍為 $[0, N - 1]$ ，最小刻度為 1
3	Distance	1	浮點數	兩站之間距離，單位為公里，最小刻度為 10^{-17}

4.5.4 Youbike 資料集的統計分析

本小節將針對 Youbike 資料集進行分析，內容包括借出量和還入量的基本統計描述，接著從空間面向探討各站點的流量分布情形，最後從時間面向分析平日與假日的使用差異。借出量和還入量的基本資訊如表 4.38 所示。

表 4.38: Youbike 資料集中人流量之基本資訊統計

項目	數值
資料天數	120 天
每日時間區段數	24 區段
偵測站點數	161 站
總資料量	借出量和還入量各 4.63×10^5 筆

表 4.38 呈現 YouBike 資料集的統計分布。從數據中可發現，在多數時段，大部分站點並無借出或還入紀錄；而在有流量紀錄的站點中，借還量多集中於個位數，僅少數數值超過 10 輛，其中最高借出量與還入量分別為每小時 109 輛與 107 輛。

本研究接著從空間面向進行分析，計算各站點每小時的平均人流量。圖 4.20 與圖 4.21 顯示各站點每日平均借出量與還入量的分布情形。大多數站點每日的借還量不超過 100 輛，換算每小時約為 4 至 5 輛，顯示整體使用頻率偏低。

除了站點層面的分析外，本研究亦整理平日與假日各時段的借出量及還入量，以探討交通尖峰時段的使用情形，如圖 4.22 和圖 4.23 所示。YouBike 在平日呈現三波高峰，分別為 7 點至 8 點、11 點至 12 點，以及 16 點至 17 點，與通勤與通學時段相符，每小時借還量皆超過 1000 輛；而假日的使用高峰則集中於 11 點至 17 點，每小時借還量約為 750 輛。整體而言，假日的使用量略低於平日。

表 4.39: Youbike 資料集借出量及還入量計資料

統計量	借出量 (車輛數)	還入量 (車輛數)
平均值	3.78	3.59
標準差	5.93	5.60
最小值	0.00	0.00
第一四分位數 (Q1)	0.00	0.00
中位數 (Q2)	2.00	1.00
第三四分位數 (Q3)	5.00	5.00
最大值	109.00	107.00




圖 4.20: Youbike 資料集中各站點每日平均借出量之數據分布，每 50 人次為一區間，呈現各區間的個別站點數與累計站點數。

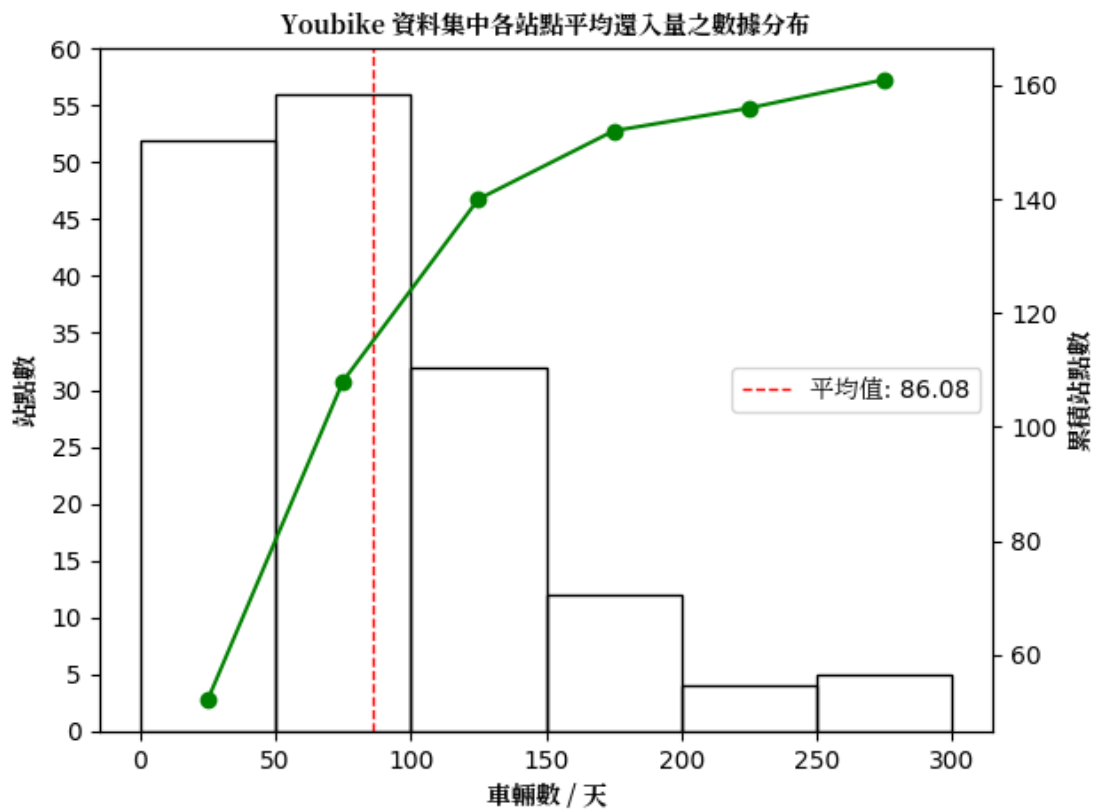


圖 4.21: Youbike 資料集中各站點每日平均還入量之數據分布，每 50 人次為一區間，呈現各區間的個別站點數與累計站點數。




圖 4.22: Youbike 資料集中平日與假日各小時借出量之比較。




圖 4.23: Youbike 資料集中平日與假日各小時還入量之比較。

4.5.5 天氣資料

不同的天氣條件會影響交通工具的使用情形，例如：在高溫天氣下，人們可能不太願意在炎熱的環境中單車，而更傾向選擇搭乘配有冷氣的捷運或公車。相反地，在舒適的氣溫下，人們更可能選擇以自行車為主要的移動工具。而在下雨天，濕滑的路面降低了大眾運輸的便利性，使人們不太願意步行至捷運入口，進而影響搭乘人數。

因此，本研究認為天氣狀況和交通工具的使用情形存在密切的相互關係，雨量 and 氣溫被視為兩個最直接影響人們選擇交通方式的因素，因此從中央氣象局觀測站日報表每小時觀測資料欄位（表 4.41），以及中央氣象局觀測站資訊資料集欄位¹³（表 4.42）整理成天氣資料（圖 4.24、表 4.43）。

表 4.40: 中央氣象局觀測站日報表整體資訊欄位

編號	欄位名稱	欄位個數	格式	說明
1	測站	1	字串	觀測站編號及名稱
2	觀測日期	1	日期	最小刻度為 1 天

表 4.41: 中央氣象局觀測站日報表每小時觀測資料欄位

編號	欄位名稱	欄位個數	格式	說明
1	ObsTime	1	整數	觀測時間，範圍 [1, 24]，最小刻度為 1
2	StnPres	1	浮點數	測站氣壓，單位為 hPa，最小刻度為 0.1
3	SeaPres	1	浮點數	海平面氣壓，單位為 gpm，最小刻度為 0.1
4	Temperature	1	浮點數	氣溫，單位為 °C，最小刻度為 0.1
5	Td dew point	1	浮點數	露點溫度，單位為 °C，最小刻度為 0.1
6	RH	1	整數	相對溼度，單位為 %，最小刻度為 1
7	WS	1	浮點數	風速，單位為 m/s，最小刻度為 0.1
8	WD	1	整數	風向，單位為 °，範圍 [0, 360]，最小刻度為 1
9	WSGust	1	浮點數	最大陣風，單位為 m/s，最小刻度為 0.1
10	WDGust	1	整數	最大陣風風向，單位為 °，範圍 [0, 360]，最小刻度為 1
11	Precp	1	浮點數	降水量，單位為 mm，最小刻度為 0.1
12	PrecpHour	1	浮點數	降水時數，單位為 h，最小刻度為 0.1
13	SunShine	1	浮點數	日照時數，當日累積值，單位為 h，最小刻度為 0.1
14	GloblRad	1	浮點數	全天空日射量，當日累積值，單位為 MJ/m ² ，最小刻度為 0.01
15	Visb	1	浮點數	能見度，單位為 km，最小刻度為 0.1
16	UVI	1	整數	紫外線指數，最小刻度為 1
17	Cloud Amount	1	整數	總雲量，範圍 [0, 10]，最小刻度為 1

¹³<https://e-service.cwb.gov.tw/wdps/obs/state.htm>

表 4.42: 中央氣象局觀測站資訊資料集欄位

編號	欄位名稱	欄位個數	格式	說明
1	站號	1	整數	觀測站編號
2	站名	1	字串	觀測站名稱
3	站種	1	字串	局屬有人站或局屬自動站
4	海拔高度	1	浮點數	單位為公里 (m)
5	經度	1	浮點數	觀測站座標經度，最小刻度為 10^{-6}
6	緯度	1	浮點數	觀測站座標緯度，最小刻度為 10^{-6}
7	城市	1	字串	觀測站所在城市
8	地址	1	字串	測站地址
9	資料起始日期	1	日期	觀測站啟用日期
10	撤站日期	1	日期	觀測站撤除日期，若為現存觀測站則為空值
11	備註	1	字串	無特定資料
12	原站號	1	字串	搬遷前站號，若為新設立則為空值
13	新站號	1	字串	搬遷後站號，若為現存觀測站則為空值



表 4.43: 天氣資料集欄位

編號	欄位名稱	欄位個數	格式	說明
1	Longitude	1	浮點數	觀測站座標經度，最小刻度為 10^{-6}
2	Latitude	1	浮點數	觀測站座標緯度，最小刻度為 10^{-6}
3	Precipitation	1	浮點數	降雨量，最小刻度為 0.1
4	Temperature	1	浮點數	氣溫，最小刻度為 0.1

氣象觀測站與捷運車站及單車租借站之間存在一定的距離，使用差值法來估計能減少實際數值和估計值之間的差距。Nearest-neighbor interpolation 選擇最近的氣象觀測站數據當作目標站點氣象數據；Inverse Distance Weighting 將氣象觀測站到目標站點間的距離作為權重，利用加權平均算出估計值，公式如式 4.5 所示。

$$X = \sum_{i=1}^N w_i x_i \quad (4.5)$$

X 代表估算值， x_i 代表第 i 個氣象觀測站的數值，目標站點數值計算。 w_i 為第 i 個氣象觀測站的權重，計算公式如式 4.6 所示。

$$w_i = \frac{d_i^{-p}}{\sum_{j=1}^N d_j^{-p}} \quad (4.6)$$

d_i 代表第 i 個氣象觀測站到目標站點距離， N 為已知數值個數， p 為人工選定參數，通常為 1 或 2。

上述兩種做法雖然簡單，但是容易受到極值或是氣象觀測站分布影響降低準

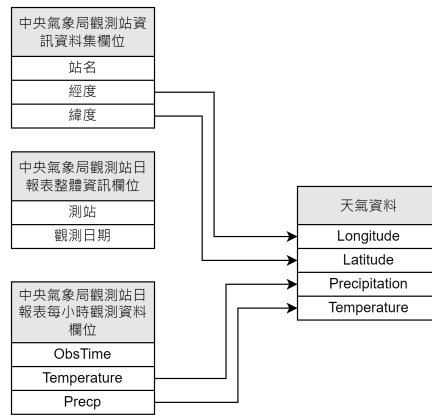


圖 4.24: 天氣資料集欄位來源，原始資料僅列出有使用到的，箭頭為資料對應關係。

確度。Kriging 則做出假設如式 4.7 所示。

$$\hat{z}_0 = \sum_{i=1}^N \lambda_i z_i \quad (4.7)$$

\hat{z}_0 為估算值， N 為已知數值個數， z_i 為第 i 個已知數值， λ_i 為第 i 個已知數值的權重。

λ 是透過最小化變異數計算而得，在計算過程必須考慮已知數值數值在空間上的分布，使估算值能準確地反映數據的分布。鑑於氣象觀測站的稀疏和分布不均勻，本研究採用 Kriging 作為計算捷運站點和 YouBike 租借站的氣溫和雨量的方法。根據捷運車站和 Youbike 租借站的實際位置，研究選擇台北市和新北市的氣象觀測站用於估計特定經緯度的天氣狀態（圖 4.25）。

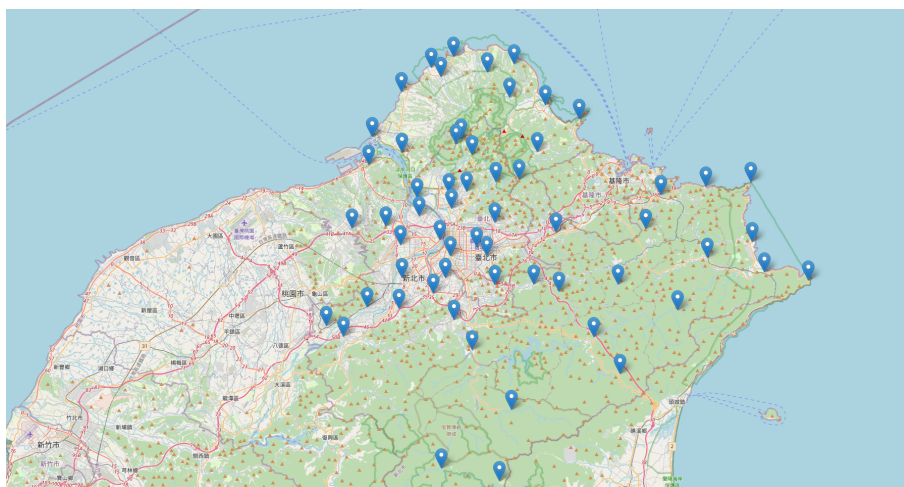


圖 4.25: 台北市和新北市氣象測站位置圖

4.5.6 MRT 和 Youbike 資料集實驗結果

本研究針對 MRT 與 YouBike 資料集進行實驗，其中在 MRT 資料集中預測人流量，而在 YouBike 資料集中則於同一實驗中同時預測借出量與還入量，詳細實驗設定如表 4.44 所示。

在 MGSTT 模型中，MRT 資料集採用空間相鄰圖與流量分布相似圖來建構空間關係，其中流量分布相似圖以人流量資料作為相似度的計算依據。至於 YouBike 資料集，則使用流量連結圖與流量變化相似圖進行建模。實驗結果顯示，相較於還入量，借出量具有較高的變動性與複雜度，因此本研究在流量變化相似圖的相似度計算中，以借出量資料作為依據。

表 4.44: MRT 與 Youbike 資料集之預測任務設定

實驗編號	使用資料集	預測目標
1	MRT	人流量
2	Youbike	借出量、還入量

表 4.45 列出 MRT 與 Youbike 兩份資料集的實驗結果。整體結果和 PEMS04 和 PEMS08 的結果相似，MGSTT 依舊在各個評估指標上優於其他模型，顯示出 MGSTT 在不同場景中的高度通用性。

表 4.45: MRT 和 Youbike 資料集預測，提出模型 MGSTT 和其他比較模型預測結果，↓表示指標越低越好，紅字代表最佳結果。

實驗編號	預測欄位		STSGCN	STFGNN	GMAN	ST-GRAT	MGSTT
1	MRT 人流量	MAE(人次)↓	3.91	3.49	3.84	8.17	3.37
		MAPE(%)↓	58.62	54.97	57.86	90.72	54.45
		RMSE(人次)↓	9.55	8.17	9.71	20.76	7.60
2	Youbike 借出量	MAE(車輛數)↓	3.42	3.16	2.96	5.20	2.99
		MAPE(%)↓	66.09	64.98	66.98	125.74	64.07
		RMSE(車輛數)↓	5.57	5.16	4.67	7.82	4.85
	Youbike 還入量	MAE(車輛數)↓	3.15	2.93	2.70	5.05	2.76
		MAPE(%)↓	63.72	63.00	64.90	124.75	62.08
		RMSE(車輛數)↓	5.09	4.73	4.18	7.63	4.41

4.5.7 關係圖對 MRT 和 Youbike 資料集預測結果的影響

與 PEMS04 及 PEMS08 資料集相同，本研究亦透過不同空間關係圖的組合，探討各種空間關係對模型預測結果的影響。表 4.46 至表 4.48 為 MRT 與 YouBike

資料集的實驗結果。

在 MRT 資料集中，移除空間相鄰圖或流量分布相似圖皆會導致預測誤差上升，顯示這兩種空間關係對預測表現有顯著影響。而在 YouBike 資料集中，移除流量連結圖或流量變化相似圖也會使預測誤差增加，與 MRT 的實驗結果一致，進一步驗證這些空間關係在不同資料集中的重要性。

表 4.46: MRT 在不同關係圖組合下，人流量的預測結果，↓表示指標越低越好，紅字代表最佳結果。

空間相鄰圖	流量分布相似圖	MAE(人次)↓	MAPE(%)↓	RMSE(人次)↓
V	V	3.37	54.45	7.60
	V	3.43	54.94	7.75
V		3.42	54.70	7.70

表 4.47: Youbike 在不同關係圖組合下，借出量的預測結果，↓表示指標越低越好，紅字代表最佳結果。

流量連結圖	流量變化相似圖	MAE(車輛數)↓	MAPE(%)↓	RMSE(車輛數)↓
V	V	2.99	64.07	4.85
	V	3.09	66.66	4.98
V		3.07	64.02	4.97

表 4.48: Youbike 在不同關係圖組合下，還入量的預測結果，↓表示指標越低越好，紅字代表最佳結果。

流量連結圖	流量變化相似圖	MAE(車輛數)↓	MAPE(%)↓	RMSE(車輛數)↓
V	V	2.76	62.08	4.41
	V	2.87	64.83	4.58
V		2.85	62.47	4.57

4.5.8 時空嵌入對 MRT 和 Youbike 資料集預測結果的影響

在本項實驗中，本研究探討 MGSTT 中的時空嵌入機制對 MRT 與 YouBike 資料集預測任務的影響。根據表 4.49 所示，在 MRT 資料集中，移除時空嵌入反而使預測結果略有提升；而在 YouBike 的預測任務中，無論是借出量或還入量，移除時空嵌入會使 MAE 與 RMSE 略微下降，但 MAPE 則上升，整體結果差距不大。

表 4.49: MRT 和 Youbike 資料集在有無時空嵌入下之預測實驗結果，↓表示指標越低越好，紅字代表最佳結果。

實驗編號	預測欄位		有時空嵌入	無時空嵌入
1	MRT 人流量	MAE(人次) ↓	3.37	3.36
		MAPE(%) ↓	54.45	54.16
		RMSE(人次) ↓	7.60	7.55
2	Youbike 借出量	MAE(車輛數) ↓	2.99	2.97
		MAPE(%) ↓	64.07	65.03
		RMSE(車輛數) ↓	4.85	4.79
	Youbike 還入量	MAE(車輛數) ↓	2.76	2.75
		MAPE(%) ↓	62.08	63.31
		RMSE(車輛數) ↓	4.41	4.37

4.5.9 MRT 與 YouBike 資料集於不同預測時間間距下之結果分析

與 PEMS04 以及 PEMS08 資料集相同，在本節本研究將針對 MRT 與 Youbike 資料集的各個預測時間間距，分別呈現對應的預測評估指標。由於 ST-GRAT 的表現與其他模型差距過大，因此未將其結果呈現在圖中。

圖 4.26 分別呈現各模型於 MRT 資料集下，人流量預測任務的指標表現，詳細數據請參閱表 A.5。ST-GRAT 在所有預測時間間距下表現皆不理想，且與其他模型的差距明顯。MGSTT 與 STFGNN 分居第一、第二名，準確率明顯優於其他模型。GMAN 與 STSGCN 則排在第三、四名，且 STSGCN 的預測表現波動幅度相當大，與時間間距呈現不穩定的變化趨勢。

圖 4.27，以及圖 4.28，分別呈現各模型於 YouBike 資料集下，借出量與還入量的預測結果，詳細數據請參閱表 A.6 與表 A.7。由於借出量與還入量的預測結果相似，故合併說明。ST-GRAT 在短期預測表現尚可，然而預測時間間距拉長後，準確率明顯劣於其他模型。MGSTT 與 GMAN 整體表現最佳，兩者在短期預測時由 MGSTT 略勝一籌，但隨著時間間距拉長，GMAN 的 MAE 與 RMSE 增幅較小，尤其在借出量的 RMSE 及還入量的 MAE、RMSE，GMAN 表現超過 MGSTT。然而，在 MAPE 指標上，GMAN 的表現則明顯低於 MGSTT，甚至落後 STFGNN 與 STSGCN。

綜合 MRT 與 YouBike 資料集之預測結果可知，ST-GRAT 在所有任務與預測時間間距下表現普遍不佳，無法與其他模型抗衡。MRT 資料集中，MGSTT 與 STFGNN 準確率明顯領先其他模型，展現優異的預測能力，而 STSGCN 則因其預測表現波動大，穩定性較差。YouBike 資料集中，MGSTT 與 GMAN 整體預測表現最佳，MGSTT 在短期預測具優勢，但隨預測時間增加，GMAN 在 MAE 與 RMSE 指標上的表現逐漸超越 MGSTT，顯示其在長時間預測上的穩定性較佳。不過在 MAPE 指標上，GMAN 表現相對不穩，甚至落後於 STFGNN 與 STSGCN。整體而言，MGSTT 在短期預測具備優勢，而 GMAN 更適合應用於長時間預測任務。




圖 4.26: MRT 資料集中，各模型在客流量預測上表現，依不同預測時間間距繪製。由上至下分別為 MAE、MAPE 和 RMSE 的誤差圖。




圖 4.27: Youbike 資料集中，各模型在借出量預測上表現，依不同預測時間間距繪製。由上至下分別為 MAE、MAPE 和 RMSE 的誤差圖。




圖 4.28: Youbike 資料集中，各模型在還入量預測上表現，依不同預測時間間距繪製。由上至下分別為 MAE、MAPE 和 RMSE 的誤差圖。

4.5.10 MRT 案例分析

本節共探討 4 個 MRT 案例，其中前 2 個為 MGSTT 表現較佳的案例，後 2 個則為 MGSTT 表現相對較差的案例。案例詳細資料如表 4.50 所示。

表 4.50: MRT 案例簡述，包含起點、終點，單向平均日運量，以及案例所呈現的時間。

編號	起點	終點	平均日運量 (人次)	時間
1	台北車站	西門站	5892	2023/4/08 到 2023/4/10
2	中正紀念堂站	台北車站	2709	2023/4/17 到 2023/4/19
3	雙連站	中山站	318	2023/4/18 到 2023/4/20
4	公館站	大坪林站	889	2023/4/10 到 2023/4/12

圖 4.29 顯示台北車站前往西門站的人流量，圖中包含實際數據以及各模型的預測結果。前兩日為週末，尖峰時段落在 11 點至 19 點之間，人流量約為 500 至 800 人次；最後一日為平日，尖峰時段則集中在 17 點至 20 點。整體而言，MGSTT 在週末兩天的預測表現較佳，尖峰時段的預測值與實際數據較為接近；而在平日，則以 STFGNN 對尖峰數值的預測最為貼近實際。

圖 4.30 顯示中正紀念堂站前往台北車站的人流量，三日的尖峰時段皆集中於 16 點至 19 點，實際人流約落在 550 至 600 人次之間。整體預測結果以 MGSTT 與 STFGNN 表現較佳，兩者的預測值多介於 450 至 500 人次之間，但仍與實際值存在約 100 人次的誤差，顯示即使是表現較好的模型，仍有改進空間。

圖 4.31 顯示雙連站前往中山站的人流量，三日皆出現兩波尖峰，分別為 11 點至 13 點與 18 點至 19 點，實際人流量約為 30 至 40 人次。在第一波高峰時段，MGSTT 的預測表現最佳，誤差值控制在 10 人次以內；然而在第二波高峰，多數模型均出現高估情形，預測誤差普遍落在 20 至 30 人次之間。

圖 4.32 顯示公館站前往大坪林站的人流量，三日的尖峰時段皆集中於 17 點至 19 點，實際人流量約為 120 至 140 人次。在此路線中，GMAN 與 STFGNN 的預測結果較為穩定，尖峰時段預測約落在 100 至 110 人次之間，而 MGSTT 的預測值則較低，約為 80 人次左右。

整體來看，不同模型在人流預測任務中的表現會受到路線特性與時間因素影響。在人流波動較為明顯或週末時段，MGSTT 的預測相對貼近實際數據；而在

人流分布較平穩或尖峰時段集中於下班時間的路線上，STFGNN 與 GMAN 表現則較為穩定。從預測誤差來看，目前各模型在部分尖峰時段仍有高估或低估的情形，顯示在複雜通勤行為下，模型對時空動態的掌握仍待強化。




圖 4.29: MRT 資料集的預測範例，顯示從台北車站前往西門站的人流量與模型預測數值。




圖 4.30: MRT 資料集的預測範例，顯示從中正紀念堂站前往台北車站的人流量與模型預測數值。




圖 4.31: MRT 資料集的預測範例，顯示從雙連站前往中山站的人流量與模型預測數值。




圖 4.32: MRT 資料集的預測範例，顯示從公館站前往大坪林站的人流量與模型預測數值。

4.5.11 Youbike 案例分析

本章節共探討 4 個 Youbike 案例，其中前 2 個為 MGSTT 表現較佳的案例，後 2 個則為 MGSTT 表現相對較差的案例。案例詳細資料如表 4.51 所示。

表 4.51: Youbike 案例簡述，包含起點、終點，單向平均日運量，以及案例所呈現的時間。

編號	站點	預測欄位	平均日運量 (車輛數)	時間
1	臺大教研館北側站	借出量	71	2023/4/24 到 2023/4/26
2	臺大樂學館東側站	還入量	190	2023/4/19 到 2023/4/21
3	臺大農化新館西側站	借出量	91	2023/4/17 到 2023/4/19
4	臺大禮賢樓東南側站	還入量	152	2023/4/19 到 2023/4/21

圖 4.33 顯示臺大教研館北側站的 YouBike 借出量，包含實際觀測數據與各模型的預測結果。該站每日的流量高峰時段不固定，最高峰超過 15 輛。在此案例中，MGSTT 是所有模型中，高峰預測最接近實際數值的，特別是在 4 月 24 日 15 點至 16 點，以及 4 月 25 日 11 點這兩個時段。不過 MGSTT 也出現預測明顯偏差的情況，例如 4 月 25 日 8 點至 9 點，預測值與實際值相差超過 15 輛。

圖 4.34 顯示臺大樂學館東側站的 YouBike 還入量，包含實際觀測數據與各模型的預測結果。該站的高峰出現在 8 點至 10 點，以及 11 點至 13 點，還入量超過 15 輛。第一波高峰時段，MGSTT 與其他模型預測皆不理想，誤差範圍可達 10 至 20 輛。但在第二波高峰，MGSTT 的預測表現優於其他模型，有些尖峰預測誤差小於 3 輛。

圖 4.35 顯示臺大農化新館西側站的 YouBike 借出量，包含實際觀測數據與各模型的預測結果。該站高峰集中在 7 點至 9 點，借出量超過 40 輛，其餘時段也會出現數波超過 20 輛的車潮。包含 MGSTT 在內的模型，普遍將高峰時段預測為 11 點至 13 點，與實際尖峰明顯錯位，導致預測誤差極大，最大差距達 60 輛。

圖 4.36 顯示臺大禮賢樓東南側站的 YouBike 還入量，包含實際觀測數據與各模型的預測結果。該站尖峰分布在 7 點至 9 點及 11 點至 14 點，還入量在 25 輛以上，最高甚至超過 61 輛。但 MGSTT 在這些尖峰時段的預測普遍偏低，多數僅預測約 25 輛，顯示模型難以捕捉大幅變動的車潮。

從四個 YouBike 站點的實驗結果來看，MGSTT 模型在部分尖峰時段能提供貼

近實際的預測，尤其在中等流量的情況下表現尚佳。然而，對於車流劇烈變動或高峰時段異常分布的場景，模型的預測能力仍有限，容易出現尖峰錯位或嚴重低估的情況。這顯示目前模型在處理非穩定性高的微型運具資料上仍有改進空間。




圖 4.33: Youbike 資料集的預測範例，顯示臺大教研館北側站的實際借出量與模型預測數值。

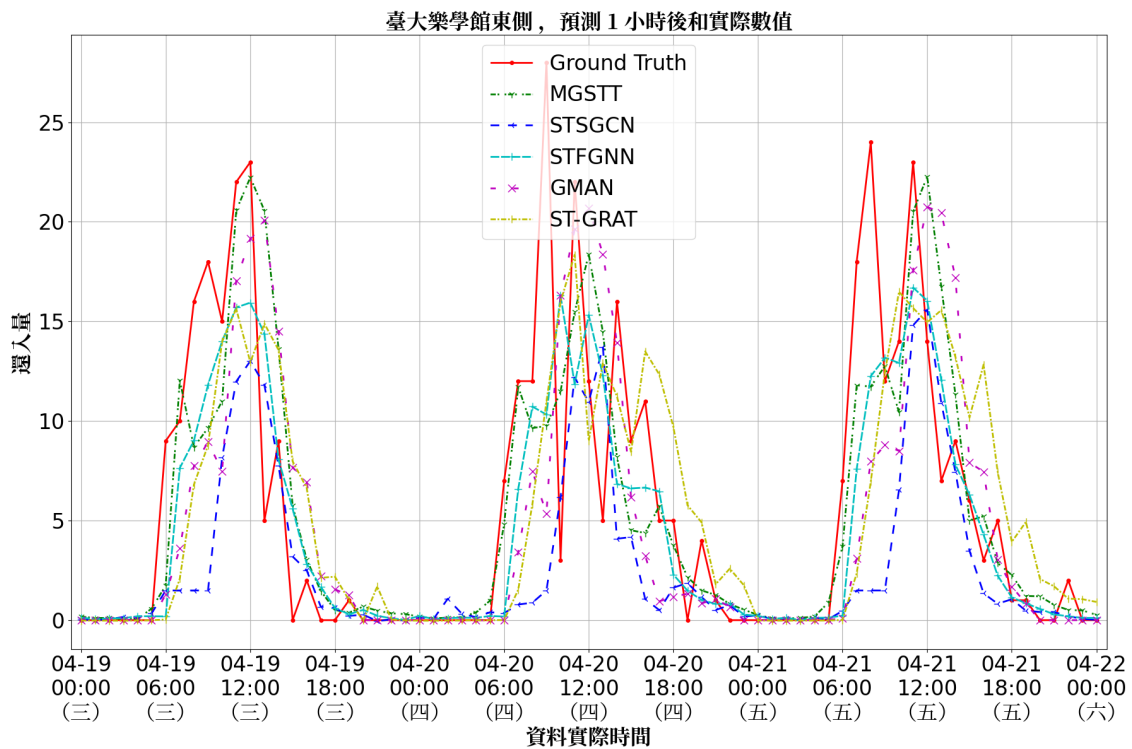


圖 4.34: Youbike 資料集的預測範例，顯示臺大樂學館東側站的實際還入量與模型預測數值。




圖 4.35: Youbike 資料集的預測範例，顯示臺大農化新館西側站的實際借出量與模型預測數值。




圖 4.36: Youbike 資料集的預測範例，顯示臺大禮賢樓東南側站的實際還入量與模型預測數值。



第五章 結論與未來展望

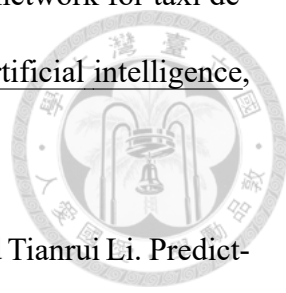
本研究提出 MGSTT，能夠同時捕捉多種空間關係，並引入天氣、氣溫等外部因素，使模型更有效地學習時空特徵。此外，本研究自行收集了兩個與台灣相關的資料集——MRT 與 Youbike，並與加州高速公路車流量資料集 PEMS04 和 PEMS08 一同作為評估基準。實驗結果顯示，MGSTT 在所有資料集中皆表現優異，展現出良好的泛化能力。

本研究僅考慮部分關係圖來捕捉空間特徵，未來可進一步探索更多類型的關係圖，以提升模型對空間結構的學習能力。此外，受限於時間與資料開放性，本研究僅使用 MRT 和 Youbike 這兩個與台灣相關的資料集，未來希望能納入更多資料集，以提升模型的泛化能力與應用範圍。

參考文獻




- [1] 林冠廷. 運用兩階段資料探勘建構 YouBike 站點需求量與還車量預測之研究. Thesis, 2018.
- [2] Haoran Jie, Hetai Zou, and Qinneng Xu. Forecasting daily mrt passenger flow in taipei based on google search queries. In 2021 International Symposium on Computer Science and Intelligent Controls (ISCSIC), pages 46–50. IEEE.
- [3] Billy M Williams and Lester A Hoel. Modeling and forecasting vehicular traffic flow as a seasonal arima process: Theoretical basis and empirical results. Journal of transportation engineering, 129(6):664–672, 2003.
- [4] You-Shyang Chen, Chien-Ku Lin, Su-Fen Chen, and Shang-Hung Chen. Two advanced models of the function of mrt public transportation in taipei. Electronics, 10(9):1048, 2021.
- [5] 溫柏淳. 結合地理資訊系統與機器學習於公共自行車租賃站缺車預測—以臺北市 YouBike 為例. Thesis, 2019.
- [6] 邱鈺懿. 以外掛式類神經網路預測區域 YouBike 站點之租借量. Thesis, 2023.
- [7] 楊子瑄. 臺北市 YouBike 共享單車車數預測系統之實作. Thesis, 2022.
- [8] 吳冠毅. 分類式支援向量迴歸結合粒子群演算法預測 Youbike 車位及車輛數. Thesis, 2018.
- [9] Young-Seon Jeong, Young-Ji Byon, Manoel Mendonca Castro-Neto, and Said M Easa. Supervised weighting-online learning algorithm for short-term traffic flow prediction. IEEE Transactions on Intelligent Transportation Systems, 14(4):1700–1707, 2013.

- 
- [10] Huaxiu Yao, Fei Wu, Jintao Ke, Xianfeng Tang, Yitian Jia, Siyu Lu, Pinghua Gong, Jieping Ye, and Zhenhui Li. Deep multi-view spatial-temporal network for taxi demand prediction. In Proceedings of the AAAI conference on artificial intelligence, volume 32.
- [11] Junbo Zhang, Yu Zheng, Dekang Qi, Ruiyuan Li, Xiuwen Yi, and Tianrui Li. Predicting citywide crowd flows using deep spatio-temporal residual networks. Artificial Intelligence, 259:147–166, 2018.
- [12] Shih-Hsiung Lee and Hsuan-Chih Ku. A dual attention-based recurrent neural network for short-term bike sharing usage demand prediction. IEEE Transactions on Intelligent Transportation Systems, 24(4):4621–4630, 2022.
- [13] Hsuan-Jui Chang and Jin-Tsong Jen. Comparing the prediction accuracy with passenger time series of taipei mrt under different deep rnns. In 2022 IET International Conference on Engineering Technologies and Applications (IET-ICETA), pages 1–2. IEEE.
- [14] Shengnan Guo, Youfang Lin, Ning Feng, Chao Song, and Huaiyu Wan. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting. In Proceedings of the AAAI conference on artificial intelligence, volume 33, pages 922–929.
- [15] Chao Song, Youfang Lin, Shengnan Guo, and Huaiyu Wan. Spatial-temporal synchronous graph convolutional networks: A new framework for spatial-temporal network data forecasting. In Proceedings of the AAAI conference on artificial intelligence, volume 34, pages 914–921.
- [16] Mengzhang Li and Zhanxing Zhu. Spatial-temporal fusion graph neural networks for traffic flow forecasting. In Proceedings of the AAAI conference on artificial intelligence, volume 35, pages 4189–4196.


- [17] K. Tian, J. Guo, K. Ye, and C. Z. Xu. St-mgat: Spatial-temporal multi-head graph attention networks for traffic forecasting. In 2020 IEEE 32nd International Conference on Tools with Artificial Intelligence (ICTAI), pages 714–721.
- [18] Cheonbok Park, Chunggi Lee, Hyojin Bahng, Yunwon Tae, Kihwan Kim, Seungmin Jin, Sungahn Ko, and Jaegul Choo. St-grat: A novel spatio-temporal graph attention network for accurately forecasting dynamically changing road speed. arXiv e-prints, page arXiv:1911.13181, 2019.
- [19] Jiandong Bai, Jiawei Zhu, Yujiao Song, Ling Zhao, Zhixiang Hou, Ronghua Du, and Haifeng Li. A3t-gcn: Attention temporal graph convolutional network for traffic forecasting. ISPRS International Journal of Geo-Information, 10(7):485, 2021.
- [20] Junho Song, Jiwon Son, Dong-hyuk Seo, Kyungsik Han, Namhyuk Kim, and Sang-wook Kim. St-gat: A spatio-temporal graph attention network for accurate traffic speed prediction. In Proceedings of the 31st ACM International Conference on Information & Knowledge Management, pages 4500–4504.
- [21] Bing Yu, Haoteng Yin, and Zhanxing Zhu. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting. arXiv preprint arXiv:1709.04875, 2017.
- [22] Lei Bai, Lina Yao, Salil Kanhere, Xianzhi Wang, and Quan Sheng. Stg2seq: Spatial-temporal graph to sequence model for multi-step passenger demand forecasting. arXiv preprint arXiv:1905.10069, 2019.
- [23] F. Scarselli, M. Gori, A. C. Tsoi, M. Hagenbuchner, and G. Monfardini. The graph neural network model. IEEE Transactions on Neural Networks, 20(1):61–80, 2009.
- [24] Michaël Defferrard, Xavier Bresson, and Pierre Vandergheynst. Convolutional neural networks on graphs with fast localized spectral filtering. Advances in neural information processing systems, 29, 2016.

- [25] Zhengke Sun and Yuliang Ma. Ma2gc: Multi adjacency relationship attention graph convolutional networks for traffic prediction using trajectory data. arXiv preprint arXiv:2401.08727, 2024.
- [26] Jie Zhou, Ganqu Cui, Shengding Hu, Zhengyan Zhang, Cheng Yang, Zhiyuan Liu, Lifeng Wang, Changcheng Li, and Maosong Sun. Graph neural networks: A review of methods and applications. AI open, 1:57–81, 2020.
- [27] Pau Riba, Andreas Fischer, Josep Lladós, and Alicia Fornés. Learning graph distances with message passing neural networks. In 2018 24th International Conference on Pattern Recognition (ICPR), pages 2239–2244. IEEE.
- [28] Yujia Li, Chenjie Gu, Thomas Dullien, Oriol Vinyals, and Pushmeet Kohli. Graph matching networks for learning the similarity of graph structured objects. In International conference on machine learning, pages 3835–3845. PMLR.
- [29] Xiaotong Zhang, Han Liu, Qimai Li, and Xiao-Ming Wu. Attributed graph clustering via adaptive graph convolution. arXiv preprint arXiv:1906.01210, 2019.
- [30] Zhitao Ying, Jiaxuan You, Christopher Morris, Xiang Ren, Will Hamilton, and Jure Leskovec. Hierarchical graph representation learning with differentiable pooling. Advances in neural information processing systems, 31, 2018.
- [31] Hao Peng, Jianxin Li, Yu He, Yaopeng Liu, Mengjiao Bao, Lihong Wang, Yangqiu Song, and Qiang Yang. Large-scale hierarchical text classification with recursively regularized deep graph-cnn. In Proceedings of the 2018 world wide web conference, pages 1063–1072.
- [32] Liang Yao, Chengsheng Mao, and Yuan Luo. Graph convolutional networks for text classification. In Proceedings of the AAAI conference on artificial intelligence, volume 33, pages 7370–7377.



- [33] Lei Bai, Lina Yao, Can Li, Xianzhi Wang, and Can Wang. Adaptive graph convolutional recurrent network for traffic forecasting. Advances in neural information processing systems, 33:17804–17815, 2020.
- [34] Bowen Wang and Jingsheng Wang. St-mgat:spatio-temporal multi-head graph attention network for traffic prediction. Physica A: Statistical Mechanics and its Applications, 603:127762, 2022.
- [35] Petar Veličković, Guillem Cucurull, Arantxa Casanova, Adriana Romero, Pietro Lio, and Yoshua Bengio. Graph attention networks. arXiv preprint arXiv:1710.10903, 2017.
- [36] Shiyong Lan, Yitong Ma, Weikang Huang, Wenwu Wang, Hongyu Yang, and Pyang Li. Dstagnn: Dynamic spatial-temporal aware graph neural network for traffic flow forecasting. In International Conference on Machine Learning, pages 11906–11917. PMLR.
- [37] Bin Lu, Xiaoying Gan, Haiming Jin, Luoyi Fu, and Haisong Zhang. Spatiotemporal adaptive gated graph convolution network for urban traffic flow forecasting, 2020.
- [38] Chuanpan Zheng, Xiaoliang Fan, Cheng Wang, and Jianzhong Qi. Gman: A graph multi-attention network for traffic prediction. In Proceedings of the AAAI conference on artificial intelligence, volume 34, pages 1234–1241.
- [39] Xue Ye, Shen Fang, Fang Sun, Chunxia Zhang, and Shiming Xiang. Meta graph transformer: A novel framework for spatial – temporal traffic prediction. Neurocomputing, 491:544–563, 2022.
- [40] Yanjie Wen, Zhihong Li, Xiaoyu Wang, and Wangtu Xu. Traffic demand prediction based on spatial-temporal guided multi graph sandwich-transformer. Information Sciences, 643:119269, 2023.

- [41] Huaiyu Wan, Shengnan Guo, Kang Yin, Xiaohui Liang, and Youfang Lin. Cts-lstm: Lstm-based neural networks for correlated time series prediction. Knowledge-Based Systems, 191:105239, 2020.
- [42] Junbo Zhang, Yu Zheng, and Dekang Qi. Deep spatio-temporal residual networks for citywide crowd flows prediction. In Proceedings of the AAAI conference on artificial intelligence, volume 31.
- [43] Bowen Du, Xiao Hu, Leilei Sun, Junming Liu, Yanan Qiao, and Weifeng Lv. Traffic demand prediction based on dynamic transition convolutional neural network. IEEE Transactions on Intelligent Transportation Systems, 22(2):1237–1247, 2020.
- [44] Y. Wang, J. Zheng, Y. Du, C. Huang, and P. Li. Traffic-ggcn: Predicting traffic flow via attentional spatial-temporal gated graph neural networks. IEEE Transactions on Intelligent Transportation Systems, 23(10):18423–18432, 2022.





附錄 A — 不同預測時間間距之結果詳

細資料



A.1 PEMS04 車流量預測

表 A.1: 所有模型在 PEMS04 上進行車流量預測，不同預測時間間距的結果。

預測間距 (分鐘)	MAE (車輛數)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
5	17.38	24.72	18.53	18.10	24.56
10	18.17	25.10	19.23	18.63	169.77
15	18.78	25.54	19.90	19.12	169.15
20	19.22	26.03	20.48	19.51	168.72
25	19.59	26.51	21.01	19.84	179.98
30	19.98	26.95	21.51	20.16	188.60
35	20.39	27.35	22.06	20.49	192.04
40	20.77	27.85	22.59	20.77	197.57
45	21.10	28.49	23.10	21.03	198.45
50	21.44	29.31	23.62	21.31	202.56
55	21.87	30.17	24.27	21.68	203.92
60	22.44	31.11	25.07	22.22	206.19

預測間距 (分鐘)	MAPE (%)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
5	11.37	17.00	12.32	11.96	17.69
10	11.90	17.30	12.79	12.33	325.17
15	12.30	17.51	13.21	12.65	310.51
20	12.58	17.87	13.58	12.91	311.77
25	12.81	18.19	13.90	13.13	324.82
30	13.05	18.55	14.21	13.35	336.29
35	13.33	18.90	14.57	13.57	336.67
40	13.58	19.35	14.93	13.77	344.91
45	13.81	19.87	15.28	13.94	342.57
50	14.07	20.50	15.65	14.14	349.22
55	14.38	21.13	16.09	14.39	348.68
60	14.76	21.90	16.67	14.76	352.40

預測間距 (分鐘)	RMSE (車輛數)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
5	27.71	38.24	29.31	28.51	37.73
10	28.95	38.80	30.39	29.37	213.88
15	29.88	39.43	31.39	30.11	211.00
20	30.56	40.14	32.25	30.70	212.66
25	31.14	40.82	33.05	31.20	222.77
30	31.71	41.43	33.80	31.66	230.73
35	32.31	41.99	34.58	32.11	233.89
40	32.85	42.68	35.33	32.52	238.95
45	33.34	43.56	36.06	32.90	239.60
50	33.79	44.67	36.80	33.28	242.91
55	34.35	45.84	37.71	33.75	243.75
60	35.10	47.10	38.80	34.43	245.66

A.2 PEMS04 車速預測

表 A.2: 所有模型在 PEMS04 上進行車速預測，不同預測時間間距的結果。

預測間距 (分鐘)	MAE (Mph)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
5	0.92	1.90	1.03	1.24	1.36
10	1.18	1.96	1.25	1.38	2.86
15	1.36	2.00	1.42	1.50	3.38
20	1.50	2.05	1.55	1.60	3.28
25	1.61	2.10	1.67	1.69	3.51
30	1.70	2.15	1.77	1.78	3.63
35	1.78	2.19	1.87	1.87	3.69
40	1.85	2.24	1.94	1.95	3.77
45	1.91	2.28	2.02	2.04	3.88
50	1.97	2.33	2.09	2.12	3.93
55	2.02	2.38	2.16	2.20	4.13
60	2.07	2.43	2.23	2.28	4.33

預測間距 (分鐘)	MAPE (%)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
5	1.69	4.20	1.97	2.54	2.68
10	2.27	4.37	2.46	2.86	6.65
15	2.70	4.49	2.85	3.14	7.67
20	3.07	4.63	3.18	3.40	7.61
25	3.38	4.76	3.50	3.65	8.19
30	3.64	4.89	3.77	3.88	8.50
35	3.87	5.01	4.04	4.11	8.68
40	4.06	5.13	4.29	4.33	8.88
45	4.24	5.25	4.51	4.55	9.12
50	4.40	5.39	4.73	4.76	9.22
55	4.55	5.53	4.92	4.96	9.56
60	4.69	5.65	5.12	5.17	9.89

預測間距 (分鐘)	RMSE (Mph)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
5	1.75	4.01	1.90	2.51	2.65
10	2.40	4.19	2.48	2.85	5.32
15	2.91	4.32	2.94	3.19	5.92
20	3.32	4.46	3.33	3.49	6.00
25	3.66	4.58	3.66	3.78	6.43
30	3.93	4.70	3.95	4.04	6.69
35	4.15	4.81	4.19	4.28	6.85
40	4.33	4.92	4.39	4.50	7.02
45	4.49	5.02	4.57	4.71	7.20
50	4.62	5.12	4.75	4.91	7.28
55	4.74	5.23	4.89	5.11	7.48
60	4.85	5.33	5.04	5.29	7.67

A.3 PEMS08 車流量預測

表 A.3: 所有模型在 PEMS08 上進行車流量預測，不同預測時間間距的結果。

預測間距 (分鐘)	MAE (車輛數)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
5	13.12	20.01	14.60	14.38	17.72
10	13.83	20.13	15.16	14.80	145.91
15	14.36	20.24	15.64	15.19	150.11
20	14.72	20.42	16.02	15.49	147.42
25	15.05	20.64	16.36	15.77	151.62
30	15.38	20.84	16.64	16.07	152.73
35	15.73	21.02	16.98	16.37	154.89
40	16.05	21.19	17.33	16.63	156.43
45	16.31	21.45	17.62	16.86	158.56
50	16.56	21.90	17.94	17.09	159.89
55	16.85	22.36	18.37	17.42	161.75
60	17.30	22.90	18.90	17.97	162.82

預測間距 (分鐘)	MAPE (%)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
5	8.44	12.77	9.56	9.03	11.22
10	8.82	12.88	9.86	9.28	140.70
15	9.13	12.93	10.12	9.51	109.81
20	9.36	13.01	10.33	9.69	95.44
25	9.57	13.12	10.53	9.86	100.18
30	9.78	13.26	10.70	10.05	96.95
35	10.01	13.39	10.91	10.24	98.94
40	10.21	13.47	11.10	10.42	99.02
45	10.38	13.66	11.30	10.59	101.08
50	10.55	13.95	11.51	10.76	100.23
55	10.74	14.21	11.79	10.99	101.74
60	11.04	14.55	12.10	11.34	103.28

預測間距 (分鐘)	RMSE (車輛數)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
5	20.45	30.77	22.38	22.09	27.60
10	21.79	30.94	23.34	22.92	186.76
15	22.81	31.14	24.15	23.64	193.32
20	23.54	31.37	24.84	24.21	191.00
25	24.16	31.75	25.41	24.73	195.53
30	24.74	32.01	25.89	25.22	196.86
35	25.31	32.29	26.41	25.69	199.33
40	25.81	32.60	26.92	26.09	201.24
45	26.23	32.92	27.35	26.44	203.67
50	26.63	33.55	27.80	26.80	205.23
55	27.05	34.18	28.39	27.28	207.41
60	27.64	34.87	29.11	28.02	208.75

A.4 PEMS08 車速預測

表 A.4: 所有模型在 PEMS08 上進行車速預測，不同預測時間間距的結果。

預測間距 (分鐘)	MAE (Mph)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
5	0.77	1.71	0.93	1.07	1.04
10	0.99	1.75	1.10	1.20	4.92
15	1.15	1.78	1.23	1.30	4.98
20	1.26	1.80	1.34	1.39	5.02
25	1.35	1.83	1.41	1.46	5.06
30	1.42	1.85	1.49	1.52	5.09
35	1.48	1.88	1.55	1.58	5.14
40	1.54	1.91	1.62	1.64	5.18
45	1.58	1.94	1.67	1.70	5.21
50	1.62	1.96	1.74	1.75	5.25
55	1.66	1.99	1.79	1.80	5.28
60	1.71	2.03	1.84	1.86	5.31

預測間距 (分鐘)	MAPE (%)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
5	1.47	3.95	1.86	2.17	2.05
10	1.95	4.06	2.22	2.48	8.88
15	2.33	4.13	2.50	2.72	9.02
20	2.64	4.19	2.84	2.93	9.12
25	2.91	4.26	2.97	3.12	9.20
30	3.13	4.33	3.21	3.28	9.29
35	3.32	4.40	3.35	3.44	9.37
40	3.48	4.46	3.52	3.58	9.46
45	3.63	4.54	3.64	3.71	9.54
50	3.76	4.61	3.86	3.84	9.62
55	3.88	4.68	3.99	3.97	9.68
60	3.99	4.75	4.09	4.09	9.75

預測間距 (分鐘)	RMSE (Mph)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
5	1.52	3.94	1.86	2.24	2.08
10	2.13	4.05	2.31	2.61	6.57
15	2.62	4.13	2.66	2.91	6.69
20	3.01	4.20	2.99	3.16	6.79
25	3.32	4.27	3.19	3.38	6.88
30	3.56	4.33	3.42	3.57	6.96
35	3.76	4.40	3.58	3.74	7.04
40	3.91	4.46	3.76	3.89	7.12
45	4.05	4.52	3.88	4.03	7.19
50	4.16	4.58	4.08	4.16	7.25
55	4.25	4.64	4.20	4.28	7.31
60	4.33	4.70	4.30	4.40	7.37

A.5 MRT 人流量預測

表 A.5: 所有模型在 MRT 上進行人流量預測，不同預測時間間距的結果。

預測間距 (小時)	MAE (人次)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
1	3.28	3.91	3.43	3.84	6.16
2	3.30	3.80	3.42	3.82	7.31
3	3.32	3.79	3.45	3.82	8.16
4	3.34	3.79	3.46	3.82	8.66
5	3.34	3.92	3.47	3.82	9.12
6	3.36	3.95	3.48	3.83	9.61
7	3.38	3.87	3.49	3.83	10.08
8	3.37	3.90	3.48	3.82	10.34
9	3.39	3.94	3.52	3.83	10.50
10	3.42	4.03	3.52	3.84	10.59
11	3.41	4.01	3.55	3.86	10.86
12	3.49	4.01	3.63	3.93	11.07

預測間距 (小時)	MAPE (%)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
1	53.61	58.25	54.33	57.96	81.27
2	53.78	57.69	54.12	57.83	93.59
3	53.93	57.48	54.29	57.63	103.70
4	54.30	57.12	54.56	57.53	110.64
5	54.16	58.61	54.58	57.60	116.75
6	54.32	59.06	54.84	57.70	123.55
7	54.56	58.29	54.89	57.76	131.16
8	54.56	58.81	54.86	57.80	132.94
9	54.63	59.00	55.34	57.84	132.27
10	55.04	59.96	55.55	57.94	130.64
11	54.81	59.58	55.77	58.10	131.95
12	55.74	59.53	56.48	58.58	135.39

預測間距 (小時)	RMSE (人次)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
1	7.26	9.48	7.93	9.70	15.98
2	7.39	9.16	7.93	9.67	18.76
3	7.40	9.08	8.03	9.67	20.13
4	7.45	9.15	8.05	9.66	20.82
5	7.45	9.64	8.11	9.67	21.50
6	7.53	9.71	8.10	9.68	22.31
7	7.65	9.41	8.20	9.68	23.05
8	7.63	9.49	8.07	9.67	23.52
9	7.65	9.66	8.24	9.69	23.84
10	7.83	9.94	8.28	9.70	24.06
11	7.83	9.86	8.39	9.75	24.74
12	8.11	9.92	8.70	9.95	25.44

A.6 Youbike 借出量預測

表 A.6: 所有模型在 Youbike 上進行借出量預測，不同預測時間間距的結果。

預測間距 (小時)	MAE (車輛數)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
1	2.58	3.25	2.75	2.83	3.44
2	2.81	3.30	2.96	2.87	3.75
3	2.90	3.36	3.06	2.90	4.12
4	2.95	3.40	3.13	2.93	4.49
5	3.01	3.43	3.20	2.96	4.88
6	3.05	3.44	3.25	2.98	5.23
7	3.07	3.46	3.26	2.98	5.52
8	3.07	3.47	3.25	2.98	5.78
9	3.08	3.50	3.25	3.00	6.04
10	3.10	3.51	3.28	3.02	6.30
11	3.13	3.49	3.30	3.04	6.44
12	3.10	3.46	3.28	3.05	6.42

預測間距 (小時)	MAPE (%)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
1	56.24	65.01	58.59	62.71	74.96
2	60.87	65.42	62.15	64.46	88.30
3	62.76	65.62	63.71	65.44	99.71
4	63.89	65.77	64.55	66.05	108.99
5	64.54	66.30	65.38	66.64	118.51
6	65.10	66.57	65.87	67.07	128.31
7	65.39	66.58	66.34	67.37	136.90
8	65.35	66.13	66.46	67.77	143.71
9	66.01	66.22	66.60	68.27	150.01
10	66.25	66.38	66.63	68.79	154.35
11	66.40	66.39	66.67	69.16	154.97
12	66.02	66.68	66.80	70.02	150.31

預測間距 (小時)	RMSE (車輛數)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
1	4.13	5.23	4.42	4.46	5.67
2	4.50	5.28	4.75	4.52	5.93
3	4.67	5.41	4.93	4.57	6.34
4	4.77	5.51	5.08	4.62	6.78
5	4.88	5.57	5.18	4.66	7.30
6	4.95	5.58	5.29	4.70	7.72
7	4.98	5.64	5.31	4.69	8.06
8	4.99	5.68	5.27	4.69	8.37
9	5.00	5.77	5.27	4.71	8.72
10	5.05	5.78	5.39	4.76	9.09
11	5.13	5.72	5.46	4.80	9.32
12	5.10	5.65	5.43	4.80	9.35

A.7 Youbike 還入量預測

表 A.7: 所有模型在 Youbike 上進行還入量預測，不同預測時間間距的結果。

預測間距 (小時)	MAE (車輛數)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
1	2.47	3.07	2.65	2.63	3.38
2	2.64	3.09	2.83	2.65	3.73
3	2.71	3.14	2.88	2.66	4.11
4	2.72	3.17	2.91	2.67	4.45
5	2.76	3.19	2.95	2.69	4.82
6	2.80	3.18	2.99	2.71	5.14
7	2.82	3.16	3.02	2.71	5.39
8	2.83	3.16	3.00	2.71	5.59
9	2.83	3.19	2.98	2.72	5.81
10	2.82	3.19	2.98	2.72	6.02
11	2.84	3.16	2.98	2.74	6.13
12	2.82	3.12	2.96	2.75	6.10

預測間距 (小時)	MAPE (%)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
1	56.44	62.60	59.07	61.76	76.22
2	59.59	62.66	60.94	62.82	90.18
3	61.03	62.88	61.74	63.52	101.60
4	61.45	63.26	62.47	63.83	110.73
5	62.02	63.49	62.96	64.51	119.74
6	62.64	63.76	63.39	64.90	128.53
7	62.93	64.11	63.88	65.11	135.80
8	63.26	64.06	64.02	65.43	141.49
9	63.77	64.35	64.07	66.04	146.66
10	64.09	64.37	64.30	66.53	150.62
11	64.18	64.64	64.49	66.92	150.15
12	63.54	64.51	64.69	67.38	145.50

預測間距 (小時)	RMSE (車輛數)				
	MGSTT	STSGCN	STFGNN	GMAN	ST-GRAT
1	3.87	4.98	4.19	4.08	5.56
2	4.23	5.01	4.61	4.13	5.96
3	4.33	5.11	4.68	4.14	6.41
4	4.33	5.17	4.71	4.14	6.83
5	4.40	5.19	4.77	4.17	7.29
6	4.48	5.16	4.85	4.21	7.68
7	4.52	5.09	4.90	4.20	7.97
8	4.52	5.09	4.84	4.20	8.20
9	4.52	5.12	4.79	4.21	8.43
10	4.51	5.12	4.78	4.22	8.69
11	4.56	5.07	4.78	4.24	8.83
12	4.55	4.99	4.77	4.27	8.82