

逢甲大學學生報告 ePaper

運用深度學習方法預測公車旅行時間之初探
**Using Deep Learning Method to Prediction Bus
Travel Time**

作者：廖湘綺、劉柏孜、蕭伊真、余容瑤

系級：運物三乙

學號：D0613224、D0651269、D0651481、D0613313

開課老師：蘇昭銘

課程名稱：專題研究

開課系所：運輸與物流系

開課學年： 108 學年度 第 2 學期

中文摘要

近年來隨著科技蓬勃發展，運用各種深度學習演算法投入於各項研究產業中都有些重大突破，而在交通運輸產業上，也結合先進科技技術、資訊來掌握資料的蒐集、應用、傳遞，目的是希望能提供給使用者更好的服務品質，其中的核心價值在於能安全情況下即時提供民眾真正所需的需求，藉此需要透過過去的資料進行預測，分析未來可能所產生的變化，及時提供資訊服務大眾，因此本研究利用長短期記憶 LSTM 演算法，建立多變項模式預測 6702 路線各班次總旅行時間及站點間之旅行時間，在旅行時間資料中使用過去總旅行時間，預測未來 7 天路線之總旅行時間及區間旅行時間，觀察加入節慶、星期、雨量變數之預測變化，並將預測模式之結果透過平均絕對百誤差 MAPE 比較進行參數調整，得出最佳之預測模式預測未來 7 天旅行時間，經本研究發現最佳之預測模式平均絕對百誤差 MAPE 為 3.67%，表示模式預測結果為極佳。

關鍵字：長短期記憶、旅行時間、深度學習

Abstract

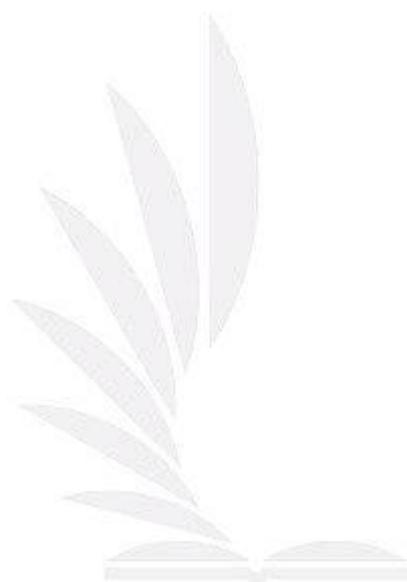
In recent years, with the vigorous development of science and technology, the use of various deep learning algorithms to invest in various research industries has some major breakthroughs. In the transportation industry, advanced technology and information are also used to master the collection, application and transmission of data. The purpose is to provide users with better service quality. The core value is to provide users with real needs in real time under safe conditions. This requires forecasting through past data and analyzing possible changes in the future. Provide information to the public in time. Therefore, this study uses LSTM algorithm to establish a multi-variable model to predict the total travel time of each shift of the 6702 route and the travel time between stations. The past total travel time is used in the travel time data. Predict the total travel time and interval travel time of the route in the next 7 days, observe the forecast changes by adding the festival, week, and rainfall variables, and adjust the parameters of the forecast model results through the average absolute error MAPE comparison to obtain the best forecast model To predict the travel time in the next 7 days, this study found that the best prediction model has an average absolute hundred error MAPE of 3.67%, indicating that the model prediction results are excellent.

Keyword : Deep Learning 、 LSTM 、 Travel Time

目 次

第一章 前言.....	5
1.1 研究緣起.....	5
1.2 研究目的.....	5
1.3 研究範圍.....	6
1.4 研究流程.....	7
第二章 文獻回顧.....	9
2.1 深度學習在交通之應用.....	9
2.2.1 深度神經網路 (Deep Neural Networks, DNN).....	12
2.2.2 人工神經網路 (Artificial neural network, ANN).....	12
2.2.3 卷積神經網路 (Convolutional neural network, CNN).....	13
2.2.4 循環神經網路 (Recurrent neural network, RNN).....	14
2.2.5 長短期記憶演算法 (<i>Long short-term memory</i> , LSTM).....	14
2.3 綜合討論.....	15
第三章 資料清理.....	18
3.1 PTX 平台公車動態(AI)資料.....	18
3.2 天氣觀測資料.....	19
3.3 行政院人事行政局初公布之 109 年日曆表.....	20
3.4 統整資料格式.....	21
第四章 預測模式建構.....	22
4.1 Python 介紹.....	22
4.1.1 Keras 套件.....	22
4.1.2 Tensorflow 套件.....	22
4.1.3 Numpy 套件.....	23
4.1.4 Pandas 套件.....	23
4.1.5 Matplotlib 套件.....	23
4.2 旅行時間預測模式建構.....	23
4.3 損失函數評估.....	24
4.3.1 各模式損失函數評估.....	24
4.4 變數與參數分析.....	27
4.4.1 變數調整.....	27
4.4.2 MAPE 預測能力量表.....	28
4.4.3 參數調整.....	29
4.5 模式比較.....	94
4.6 歷史平均模型.....	96
4.7 模式預測.....	97
4.8 綜合討論.....	99

4.8.1 與文獻誤差比較	99
4.8.2 與現況誤差比較	100
4.8.3 綜合分析	100
第五章 加值應用分析.....	101
5.1 旅行時間預報	101
第六章 結論建議.....	104
6.1 結論	104
6.2 建議	105
第七章 參考文獻.....	107



第一章 前言

本章節將說明本研究欲運用深度學習方法預測公車旅行時間之研究緣起，透過緣起與目的確立研究之公車路線範圍，確立研究範圍後著手進行資料蒐集，最後彙整出本研究整題方向之流程圖。

1.1 研究緣起

隨著科技技術發展日漸蓬勃，許多研究投入於運用深度學習方法來解決所面對的各項問題，例如：「使用 LSTM 方法進行股票預測，CNN 方法進行影像辨識等」，這些演算法不僅限於應用在經濟產業、醫療產業上，目前在交通運輸行業中，也透過深度學習方進行 AI 影像辨識計算各車種交通量、語音辨識讓車輛系統可以透過聲音進行導航、以及航空客流量預測讓業者端提早接受到資訊，提供民眾更完善的服務，因此深度學習發展已被廣泛運用於各行各業的領域，愈多大數據資料也被應用來預測未來趨勢發展，不論對於供給方、需求方都能夠透過這些資訊，做及時策略行動之擬定，因此本研究將利用公車動態資料(A1)，利用 LSTM 深度學習方法進行 6702 路線總旅行時間預測，並將認為之可能因子做為影響總旅行時間的變數，帶入深度學習模式中加以訓練，預測未來 7 天路線總旅行時間，於訓練過程中調整輸入層、隱藏層、(訓練次數)epochs、(每一批次訓練比數)batch_size，並將預測模式之結果透過平均絕對百誤差(MAPE)比較進行參數調整，得出最佳之預測模式預測未來 7 天總旅行時間。

1.2 研究目的

(1) 建立深度學習之旅行時間預測模式

透過文獻、書籍及電腦教學影片，學習 python 程式之相關實務應用，建立深度學習之旅行時間預測模式，利用 LSTM 演算法使用歷史資料之總旅行時間進行訓練，將訓練完成後的模式儲存，當未來有新資料提供時可使用訓練完成的模型加以預測。

(2) 調整影響變數之差異分析

模式建置完成，加入影響之變數比較各模式之差異，變數包括過去的旅行時間資料、節慶、星期、雨量，目的是為了看出各個變數加入後模式誤差值變化差異，選定誤差最小之變數預測模式。

(3) 預測模式之參數分析

選定誤差最小之預測模式，將逐一針對其參數進行調整，調整項目包括隱藏層神經元、epochs、batch_size，透過參數敏感度調整，找出誤差最小之預測模式，將模式帶入測試集進行預測。

(4) 進行總旅行時間預測

將取出測試資料進行預測，評估預測值與實際值之誤差，並且與現況歷史平均做對比，觀察預測值與現況之差異。

1.3 研究範圍

本研究透過 PTX 政府開放平台中，選定 6702 客運路線，由起站員林站至終點站車埕站，每天對開 3 班次，員林站發車為 09:40、17:10、18:40，車程發車為 16:10、11:50、13:50，如表 1 之 6702 路線時刻表所示，並利用 108 年 1 月 1 日至 108 年 2 月 11 日之公車動態定時資料，計算各班次每日之總旅行時間，並進一步分員林-卓乃潭、卓乃潭-田中、田中-車程，三段站點間各班次之旅行時間，作為模式之訓練與測式資料。

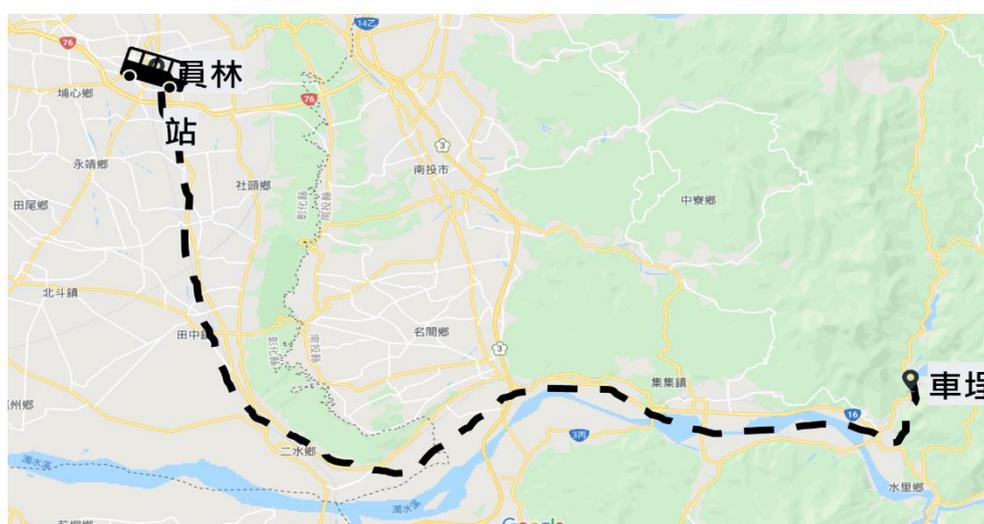


圖1、6702路線圖

表1、6702路線時刻表

6702 路線員林-車程	
員林 開	車程 開
09:40	06:10
17:10	11:50
18:40	13:50

1.4 研究流程

研究主題擬定後，訂定研究目標，進行相關資料以及文獻蒐集，包括 6702 路線動態定時資料、員林站、二水站天觀測資料、國定假日資料，參考國內外文獻內容選擇所帶入之變數、作法經驗，瞭解影響客運路線旅行時間之相關因素，透過 Python 程式建立 LSTM 演算模式，將所選之變數帶入模式中進行訓練，觀察在不同資料變數下模式，以及調整參數後模式之誤差結果，針對誤差最小的模式與傳統統計現況分析比對實際值與預測值，以及實際值與現況之平均絕對百誤差，比較利用 LSTM 深度學習演算法與統計分析現況之差異，最後選擇最佳模式進行預測未來 7 天之旅行時間，作為加值應用結果，提供供給方、需求方做及時策略行動之擬定，圖*為本研究流程圖。

(1) 擬定研究主題

(2) 設立目標與方向

擬定主題與範圍界定後，訂定研究方向與研究目標。

(3) 資料蒐集及文獻回顧

蒐集了國內與國外相關之文獻作為參考，選定本研究所帶之變數，瞭解影響客運路線旅行時間之相關因素，並針對 6702 公車旅行時間資料作為訓練、預測依據，建立 LSTM 深度學習模式。

(4) Python 語法應用

透過文獻、書籍及電腦教學影片等學習方法，了解 Python 程式之語法應用，並以 Visual code、Spyder 撰寫 Python 程式，利用程式內相關套件之應用，如：matplotlib 繪圖套件、numpy 陣列物件對資料行運算、pandas 基於 numpy 的資料分析工具，透過 python 內建之套間應用，將蒐集之資料分為訓練集與測試集，建立 LSTM 深度學習模式。

(5) 研究方法

經過文獻蒐集後發現應用於旅行時間預測可使時間序列分析、LSTM 模型預測，因此本組將於第二章節詳細介紹各方法之預測應用，而最後本組選定之研究方法為 LSTM 深度學習模型，於第二章節一同說明。

(6) 模式訓練

在 LSTM 深度學習模型架構建立完成後，將針對變數資料對模式進行訓練，觀察於不同變數資料下模式訓練結果，同時進行參數調整，找出誤差最小且穩定行最高之預測模式，本研究利用過去 32 天旅行時間資料，預測未來 7 天的旅行時間。

(7) 模式比較

模型評估運用平均絕對百誤差(MAPE)進行衡量評估，讓誤差值範圍越小模式準確度越高，並觀察實際值與預測值、實際值與現況之誤差結果。

(8) 加值應用

依據 LSTM 深度學習模型誤差評估，將利用最佳之預測模式，輸出預測

結果，進行後續加值應用呈現。

(9) 結束

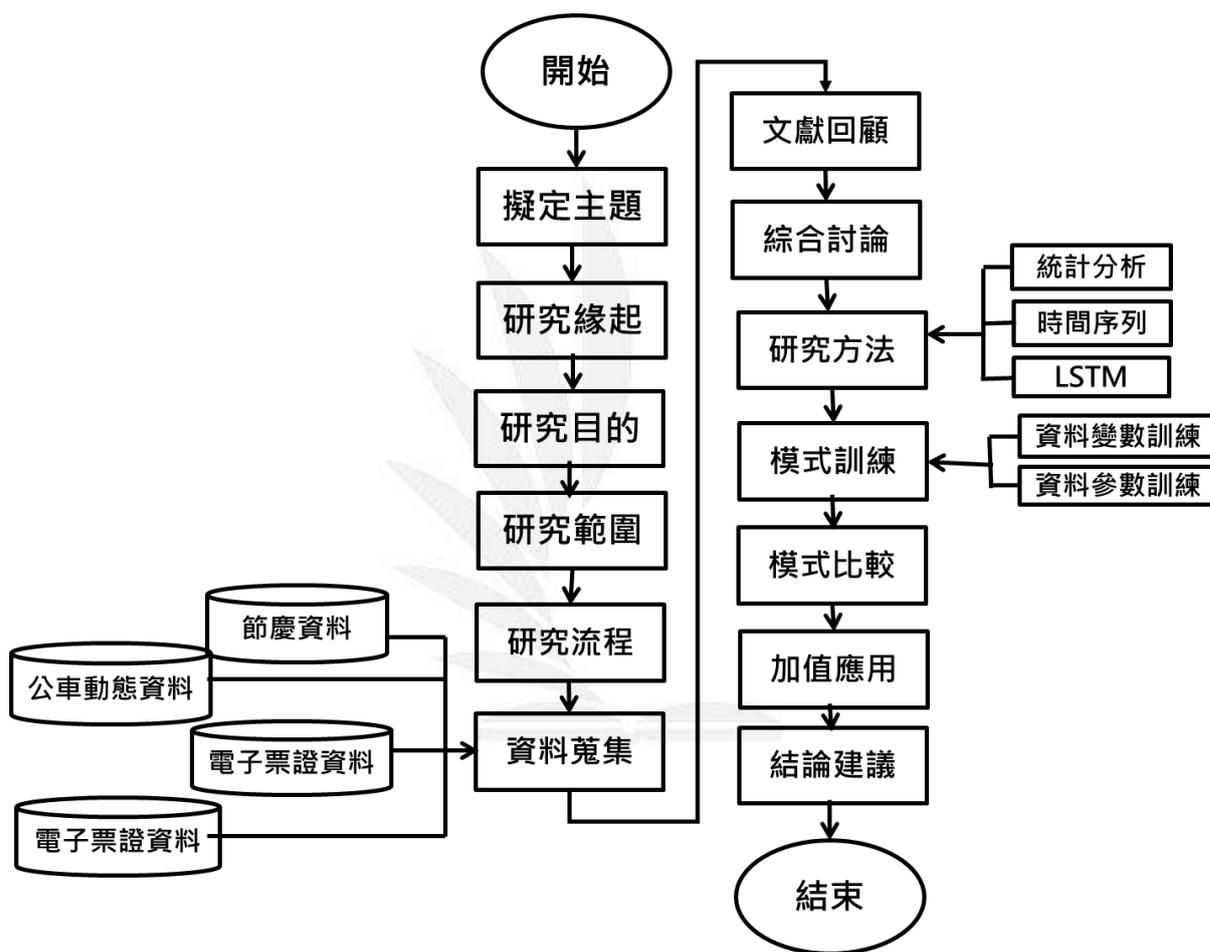


圖2、本研究流程圖

第二章 文獻回顧

本章節為進一步探討深度學習在交通方上之相關研究，參考下表列出之文獻之模式及數距應用，除了參考國內之研究外同時將參考國外文獻，了解各種深度學習之模式，並參考文獻中應用於模式之變數及參數選擇，最後歸納出相關文獻重點，作為本研究後續之參考。

2.1 深度學習在交通之應用

許尹馨(2010)，探討高雄市車歷史最為悠久 12 路公車，在捷運通車前後之運量變化，以及運量增減之相關性，文獻中與捷運紅線南段(高雄車站 -小港站)之服務範圍有相當大之重疊性，而此區域又為人口較密集、商業活動發達區域，公車相較於捷運，其班距、行車速率、舒適性均較差，加上高雄捷運於通車首月推出免費乘車之促銷方案，吸引乘客搭乘，藉此探討 12 路之乘客可能有所轉移，而透過統計方法分析高雄市公車 12 路 97-99 年每月營運資料表、每月運量成長率圖及每月營運里程與運量走勢圖發現捷運紅線至 97 年 4 月份開通後，運量變化與 12 路公車之相關性並不高，亦可能是來自於其他公車路線或私人運具使用者所影響。

葉清江(2011)，結合經驗模態分解法與類神經網路在股價預測之應用，預測模型使用五項評估指標 MAPE、RMSE、MAD、DS、CD，並根據學者(Lewis 1982)將 MAPE 分為四種等級，當 MAPE 值 $< 10\%$ 時，即表示其實際與預測的誤差越小，所以有較佳的預測能力；主要分為 4 個類別由好至壞為極佳、優良、合理、不正確。

Yu(2016)，以中國大連市之數據預測未來一段時間的公車運量，研究範圍為 2005 年 9 月 11 日至 14 日，以及 8 條公車路線和 160 輛公車之調查數據，因傳統方式受到許多限制及影響，需要更多的數據、人力及成本，且無法預測長期的公車運量變化，因而此研究使用人工神經網路 (Artificial Neural Network, ANN) 模式，注重於土地使用及建築分布情形，將各交通區土地使用情況分為三類，包含住宅、商業及工業區，以居住人口數、區域面積、公車之可及性、區域間之距離、各站點下車人數為參數，輸入於 ANN 模式中自主學習，經由大量神經元之連接、分析及加權，結果輸出一交通區至另一交通區之公車運量，分析結果為 ANN 模型比非線性迴歸模式更準確，其中誤差為 5%，結果顯示人工神經網絡模型的準確性較高，而其中模式並未將住宅等級及城市中交通位置區分，為未來可探討之方向。

何承遠(2017)，利用台中市公車電子票證交易紀錄和台中市政府及中央氣象局的開放資料分析台中市與霧峰區公車乘客量，台中市霧峰區擁有完整公路系統，為台中市南端交通樞紐，研究範圍為 100 號、100 副、107 號、50 號、53 號、59 號、281 號、151 號、108 號公車，共九條行經霧峰區之主要公車路線，參考公車路線圖，可看出大部分的公車都是經由大里橋後匯聚到中潭公路。如果要考

慮成本及時間，那麼從這邊下手是一個關鍵。在天氣變化多少會影響交通，因此為探討天氣因素如降雨、風速、能見度等，分析其因素對公車運量之影響及關聯，透過統計方法分析霧峰 4, 5, 6 月每日降雨量與台中市公車搭乘人數關係圖以及每月降雨量與台中市公車霧峰區搭乘人數關係圖，發現天氣變化和公車乘客量，兩者間並無依存性跟關聯性。2015 年台中市霧峰區整體公車乘客量平均每季約有 2 千萬人次，至於霧峰區各公車路線的總乘客量，前三名(100 號(含副線)、53 號和 50 號)涵蓋八成二的乘客。若換算成每班次平均乘客量會間接佐證霧峰區公車主幹道重疊的地方造成部分幹道供大於求的現象。另一方面，部分公車的平平均人數僅為十多位乘客，甚至不到十位，未來調整路線時或許可提出研究。

Liu(2017)，透過深度神經網路(Deep Neural Networks, DNN)方法為基礎，以及結合自動編碼器中的稀疏性限制(Sparse Autoencoder, SAE)，可以深度提取嵌入在輸入中的非線性特徵，並將一周中的一天，一天中的小時和假日的時間、入站、出站、票證的場景特徵，以及以前的平均乘客流量和實時乘客流量的客流功能為輸入參數，合併訓練為不同自動編碼器 SAE，作為數據初始化監督 DNN。文獻在第一階段，將這些功能組合併訓練為不同的堆疊式自動編碼器 (SAE)。在之後的階段中，將預訓練的 SAE 進一步用於將實時作為運量標籤數據初始化監督 DNN，應用混合模型 (Sparse Autoencoder Deep Neural Networks, SAE-DNN)，並以廈門市四個公車捷運系統(Bus Rapid Transit, BRT) 站作為客流預測為例進行評估，文獻結果實驗結果說明，針對所提出的方法能夠為具有不同客流輪廓的不同 BRT 車站提供更準確，並通用的客流預測模型。

Zhu(2018)，利用電子票證數據與深度學習(Deep Learning)方法，將地鐵每日出入境客流量進行預測，分析範圍為上海地鐵 2015 年 4 月 1 日至 30 日之電子票證數據，結合 5 個主要動態因素對軌道交通車站客流和出入境旅客流量的影響，如:天氣數據，大氣溫度數據，節假日數據，地面索引數據和高架道路數據，並通過數據縮減來計算各個鐵路運輸站的每日入口客流量和每日出口客流量，驗證了本文獻提出模型的訓練誤差，根據文獻中預測曲線可知，在基於一個隱藏層下上海大柏樹站出站客流預測結果為 17489 人，實際出口客流量為 18108 人，預測誤差為 3.42%，表示預測誤差和準確性均高於目前已知預測方法的模型。

Han(2019)，以中國上海範圍內之地鐵短期流量為測試數據，使用 2015 年 4 月 1 日至 4 月 30 日之資料，範圍涵蓋 289 個地鐵站及 14 條地鐵路線，在此期間，每天大約有 900 萬張刷卡記錄。於研究方法中，因為客流量受複雜的空間依賴關係 (附近和遙遠) 和時間依賴關係 (最近和周期性) 的影響，因此不使用卷積神經網路 (Convolutional Neural Networks, CNN)，而將城市地鐵網絡轉換為圖形，並使用圖卷積神經網路 (Graph Convolutional Neural Networks, GCNN) 進行預測，將時間區分為三個模式，包含最近、每天、每周之地鐵流入、流出量，與其空間遠、近之參數，使用 Python 建立地鐵時空圖卷積神經網路模型 (Spatiotemporal graph convolutional neural networks for metro, STGCNNmetro) 以預測短期流量，最後比較七個基線模型與實際流量之誤差值，得到 STGCNNmetro 優於其他模型之情形，結論得知其大部分預測誤差值與實際值呈

正相關，少數站點均方根誤差(root-mean-square error, RMSE)異常高，為未來模式優化之探討方向。

Niklas (2019)，使用卷積神經網絡 (CNN) 及長期短期記憶 (LSTM)，預測公車旅行時間，公車旅行時間預測的早期方法依靠歷史平均模型和線性迴歸，歷史平均模型的主要缺點是會慢慢收斂於旅行時間的變化，但是在計算成本和輸入數據需求方面的簡單性使得歷史平均模型在行業中廣泛使用，文章內引用 Shi 等人 (2015 年) 的 ConvLSTM 卷積遞迴神經網路模型，此模型為 LSTM 及 CNN 之結合，能夠捕捉時間及空之關係，並使用哥本哈根市公車 2017 年 5 月至 2017 年 10 月行駛時間觀測值數據集，比較多種模行之 RMSE、MAE 及 MAPE 誤差值，經結果證明 ConvLSTM 的模型優於 Google Traffic 等模型，並建議可研究交通事故、節慶、假日和大事件對旅行時間預測之影響。

Ran(2019),提出了一種基於 LSTM 的具有注意力機制的旅行時間預測方法，以樹狀結構呈現提出的模型，所提出的模型用注意機制代替了樹形結構，用於標準長短期記憶的展開方式，以構造長短期記憶的深度並建模長期依存關係，注意機制在每個長短期存儲單元的輸出層之上。離開時間被用作注意機制的方面，並且注意機制將離開時間整合到所提出的模型中，使用 AdaGrad 方法訓練提出的模型，英國公路協會提供的數據集，其數據集提供高速公路 15 分鐘內的平均旅行時間，其選擇 2015 年 3 月 1 日至 2015 年 3 月 31 日為實驗，實驗結果表明，LSTM 之 MAPE 為 5.95%，與其他模型相比，該模型可以實現更高的準確性。後續可與本研究之預測誤差進行評估比較。

Marko(2019)，提出了一種基於歷史數據並根據公交網絡數據模型預測出行時間的方法，比較了總線網絡劃分的四種不同方法。在 192,000 個公交車位置數據點的基礎上，比較了 4 個不同數據模型，分為 4 個不同時間段的觀測和預測行駛時間結果，結果表明，數據網絡的選擇會實時影響公交車站到站時間的預測準確性。將旅行時間劃分為時間段也會影響預測準確性。

2.2 深度學習方法

在機器學習的分支下，深度學習是以人工神經網路為架構並建立學習的目標，而基本常見的架構可分成人工神經網路 (Artificial neural network, ANN) 卷積神經網路 (Convolutional neural network, CNN) 遞迴神經網路 (Recurrent neural network, RNN) 及深度神經網路 (Deep Neural Networks, DNN)，一種電腦模擬大腦結構並以多層次去學習演算，每一層中有多個神經元組成，神經元接受一個數據的輸入並乘上一個權重，再加上一個偏值，最後透過線性或非線性轉換產生一個輸出。舉例來說要辨識一張含有人的圖片，機器學習的模型需要有具備類似的特徵，並透過分層結構去進行認知訓練，每一層提取不同方面的特徵和認知權重輸入到下一層的結構。

2.2.1 深度神經網路 (Deep Neural Networks, DNN)

類神經網路(Neural Networks, NN)為深度學習之基礎，為模仿生物神經系統之數學模型，因此在類神經網路中，通常會有數個階層，其中包括了輸入層、隱藏層及輸出層，若隱藏層多於二時，則稱為深度神經網路(DNN)，其每個階層中會有數十到數百個神經元，神經元會將上一層神經元的輸入加總後，進行活化函數(Activation function)的轉換，當成神經元的輸出，每個神經元會跟下一層的神經元有特殊的連接關係，使上一層神經元的輸出值經過權重計算後傳遞給下一層的神經元，而為了模擬生物的神經網路，活化函數通常是一種非線性的轉換。傳統之類神經網路(Neural Networks, NN)使用的活化函數為 Sigmoid 函數或雙曲正切函數(hyperbolic tan, tanh)，但因 Sigmoid 函數的學習效果比較差，因此在 DNN 中，常會使用 ReLU 函數(Rectified linear unit)。此參數設定皆是在使用深度神經網路前需要由人力設定好的，參數設定的好壞也是大大影響到 DNN 模式的效能表現，因此深度神經網路之學習和訓練過程目標為找到最佳的權重設定，得到準確之輸出值。

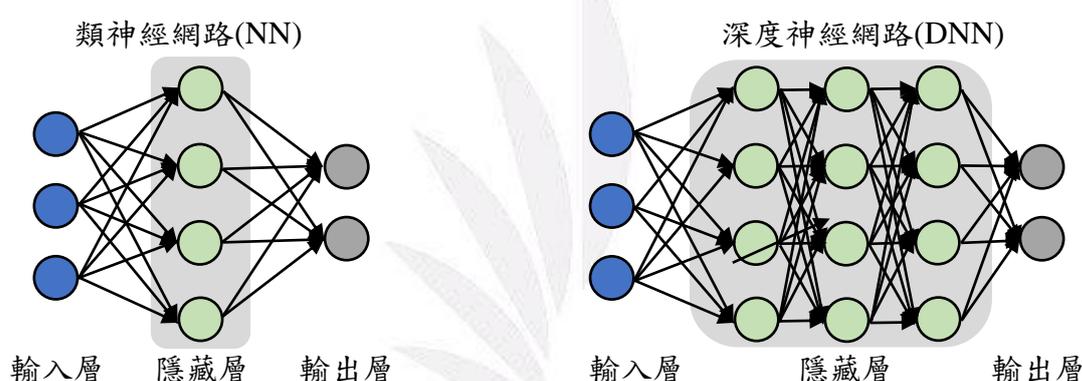


圖3、類神經網路與深度神經網路

2.2.2 人工神經網路 (Artificial neural network, ANN)

人工神經網路 (Artificial Neural Network, ANN) 是一種運算模型，由大量的神經元之間相互連接構成。每個節點代表一種特定的輸出函式，稱為啟用函式 (activation function)。它是一個能夠學習及總結歸納的系統，也就是說可以透過已知資料的實驗運用來學習和歸納總結，通過對局部情況的對照比較，推理產生一個可以自動辨識的系統，與之不同的是基於符號系統下的學習方法，它們也具有推理功能，只是它們是建立在邏輯演算法的基礎上，也就是說它們之所以能夠推理，基礎是需要有一個推理演算法則的集合。而主要是透過使用數個微處理器，用來當做人腦之中的神經元，組成人腦的神經網路結構型態，然後選定一個數學推論出來的演算法，將這演算法置入這個類神經網路中，最後選定所要讓類神經網路學習的東西，轉成類神經網路所能接受的型態，經由介面輸入，則類神經網路就開始學習，並且自己調整每個神經元之間的加權值，直到符合你所要學習的目標。

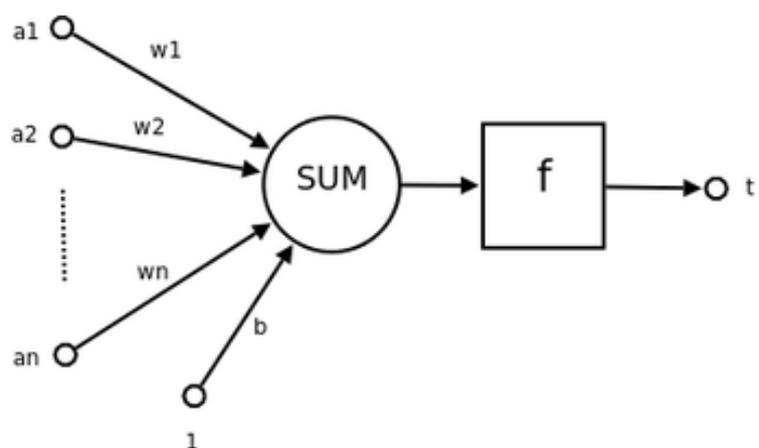


圖4、人工神經網路

2.2.3 卷積神經網路 (Convolutional neural network, CNN)

卷積神經網路 (Convolutional neural network, CNN) 主要應用在圖片、語言、影像辨識層面，在 2016 年 AlphaGo 與世界圍棋高手對弈打敗人類運用就是 CNN 技術，而卷積神經網路透過檢測垂直邊緣與水平邊緣得知資料傳輸訊息及內容，舉例來說：圖 5 黑白圖片 6*6 相素、0 代表暗色區、10 代表亮色區利用卷積多層運算後得到 0 在左右兩側暗色區，藉此識別圖像邊緣，因此卷積神經網路中把圖 6 卷積核(filter)當成需要學習的參數，而 CNN 訓練的目標就是去理解參數，在這階段稱為卷積層 (Convolution layer)，卷積層中也可利用 Padding 填充、Stride 卷積步長來改變輸出圖形的大小，並進入透過池化層(Pooling layer)，池化層會將輸入的圖片尺寸縮小，以減少每張圖片不重要的部分，保留重要的特徵，最後將特徵資訊丟到全連結層(Full connected layer)來進行分類，各連結的權重 (weight) 在同層中是相同且共享的，然而全連結層的每個神經元與上層神經元之間彼此相連接，都有其獨立且相異的權重值，針對所有值對不同選項所分類，將會連結強度 (connection strength) 的方式來表示結果。

10	10	10	0	0	0
10	10	10	0	0	0
10	10	10	0	0	0
10	10	10	0	0	0
10	10	10	0	0	0
10	10	10	0	0	0

圖5、黑白圖片6*6*1

1	0	-1
1	0	-1
1	0	-1

圖6、卷積核

0	30	30	0
0	30	30	0
0	30	30	0
0	30	30	0

圖7 黑白圖片4x4

2.2.4 循環神經網路 (Recurrent neural network, RNN)

遞迴神經網路主要為有效處理序列資料，並在每階段的時間中新增資訊，同時向先前輸出的資訊新增加權值，表示這些神經元都具備先前的記憶，反饋給下一時間之神經元，以下方舉例說明:左邊部分 A 代表區塊， X_t 代表輸入的字串或者時間序列的資料，t 代表有時間先後的關係， h_t 代表輸出，因此 A 區塊呈現遞迴呼叫自己的方式，有輸入記憶的資料再輸出自己本身，像是序列和串列的 RNN，有時間序列的關係，更深入探討在時間 t 的時候 X 為輸入的資料，因此可以假設一開始 X_0 中輸入“這電影”、 X_1 輸入“是”、 X_2 輸入“很好看”，表示訓練三個文法主詞、動詞、形容詞關係而組合成的句子，透過從時間 0 輸入類神經中“這電影”並記錄在 X_0 ，時間 1 為“是”記錄在 X_1 ，時間 2 輸入“很棒”，利用神經元時間序列輸出，可得到類神經元架構為正向預測結果。

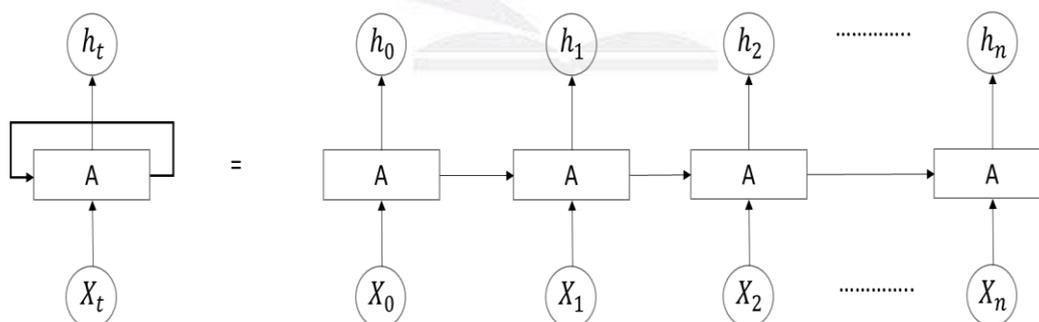


圖8、循環神經網路

2.2.5 長短期記憶演算法(Long short-term memory,LSTM)

使用 RNN 循環神經網路進行序列資料的訓練時，因神經元累積的訊息不斷循環往返，而目前優化神經網路的優化器(Optimizers)是基於反向更新權重，調整參數以來降低損失函數的方法，故神經網路更新的層之權重再回傳時誤差就可能加大或減少，隨著層的增加可能出現錯誤的梯度，因此可能會產生梯度消失

或梯度爆炸的問題，RNN 會變得更加難以處理或無法訓練。為了解決此問題 Hochreiter 和 Schmidhuber 在 1997 年開發 LSTM(long-short term memory networks) 以解決梯度消失的問題。

在處理長序列資料上，RNN 的長期記憶不足，無法記得資料長期的規律性，而 LSTM 是用來改善此缺點，為之後的時間點保存資訊，防止過於久遠的資訊在處理過程中消失。

LSTM 縱向有一條主線記憶乘載資料流貫穿所有單元(cell state)，結合輸入連接和循環連結，影響到下一個時間點的狀態，每一個單元中有三個小閘門(gate) 都有各自的權重矩陣，透過這個小閘門來做記憶控制，而第一層邏輯式是決定哪些資料要忘掉的權重，第二步是將帶進來的新資料紀錄到單元中，第三步是透過 tanh 激勵函數算出一個向量，在進行單元更新，最後再輸出資料到主線記憶中。

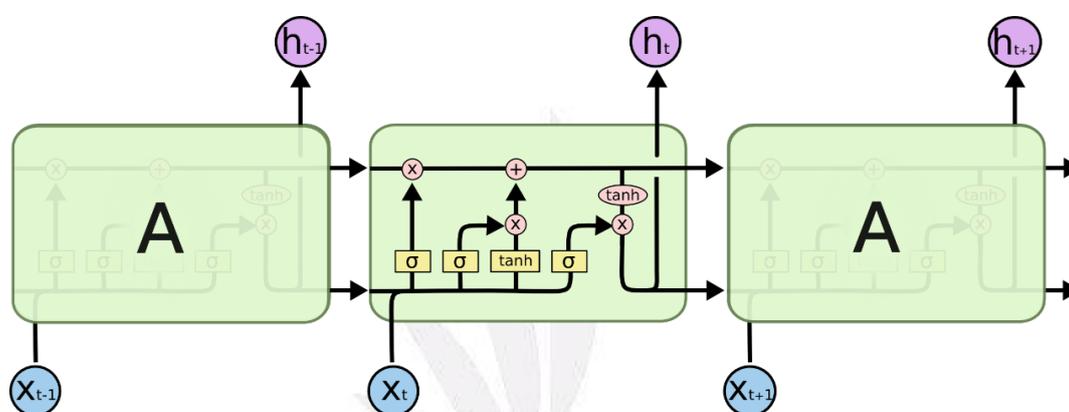


圖9、長短期記憶演算法

來源colah's blog文章

2.3 綜合討論

透過上述文獻回顧發現各文章所應用之影響運量及旅行時間預測因素，以及深度學習之模式，統整各文獻研究方法及考慮因素如表 3、表 4 所示，發現於旅行時間預測皆以 LSTM 模型為基礎，擁有解決梯度爆炸以及長時間記憶之優點，因而選擇 LSTM 為本研究之主要模型，其中旅行時間預測變數多以旅行時間及時間特性作為變數，並未包含節慶及天氣因素，藉此本組將透過資料開放平台中取得旅行時間及天氣資料，並加入星期及節慶作為變數，探討於不同變數之誤差值，並使用 Python 程式撰寫模式，深入瞭解其語法結構並且進行相關因素之參數設定，觀察輸入之變數及模式參數對預測結果之影響及變化。

表2、文獻研究方法及考慮因素統整表(運量預測)

作者及年份	研究方法	考慮因素									
		人口數	人口密度	運量	行駛速率	班距	班次	土地使用	時間特性	節慶	天氣
何承遠(2017)	統計圖表分析			✓							✓
許尹馨(2009)	統計圖表分析			✓	✓	✓	✓				
黃士鴻(2010)	小平方法之實證估計法、線性模型、雙對數迴歸	✓	✓	✓							
Yu(2016)	ANN			✓				✓			
Liu(2017)	DNN			✓					✓		
Zhu(2018)	深度學習			✓						✓	✓
Yong Han(2019)	STGCNNmetro			✓				✓	✓		

表3、文獻研究方法及考慮因素統整表(旅行時間)

作者及年份	研究方法	考慮因素							
		旅行時間	行駛速率	班距	班次	時間特性	節慶	天氣	障礙物
Niklas (2019)	ConvLSTM 卷積遞迴神經 網路	✓				✓		✓	
Ran(2019)	LSTM	✓				✓			
Marko(2019)	LSTM	✓	✓			✓			✓

第三章 資料清理

本章節將說明本研究蒐集相關變數資料，包括 PTX 平台公車動態(A1)資料計算 6702 路線旅行時間，天氣觀測站雨量資料觀察是否降雨，行政院人事行政總處公布之 109 年日曆表查驗國定假日之日期，最後將蒐集之資料進行清理與統整，於下方逐一說明。

3.1 PTX 平台公車動態(A1)資料

由交通部開放之公共運輸整合資訊流通服務平臺上蒐集 6702 路線 109 年 1 月 1 日至 109 年 2 月 11 日之公車動態(A1)資料，資料項目包括路線代碼、去返程、站牌名稱、站序代碼、車機時間、進站離站等資訊，本研究透過站序、站牌名稱、車機時間對照現有班表時刻加入班次，計算每天於各班次之總旅行時間，資料清理流程如下。

(1) 去返程資料劃分

將去返程資料劃分，利用車機時間對照班表發車時間加入班次。

(2) 依照班次計算每天總旅行時間

班次劃分後將站序排序，計算各站之時間差異。

(3) 計算總旅行時間

利用當日抵達各站之時間差，進行加總。

站序	站牌中文	站牌英文	站序代碼	車機時間	進站時間	離站時間
1	生物中心	Endemic S	84	2	0	0
2	大丘園	Daqiyuan	52	2	0	0
3	坑口	Kengkou	44	2	0	1
4	二水站	Ershui Stati	57	2	0	0
5	頂樂園	Dingleyuar	66	2	0	1
6	水門	Shuimen	47	2	0	0
7	泰山	Taishan	68	2	0	1
8	草埔	Caoling	71	2	0	0
9	金山新城	Jinshan Xit	92	2	0	1
10	下坑口	Xiakengko	45	2	0	0
11	新厝仔	Xincuozi	8	2	0	0
12	陳外科	Chen Surge	76	2	0	1
13	十字路	Shizi Road	74	2	0	0
14	中集公司	Zhongji Cc	63	2	0	0
15	仁和	Renhe	26	2	0	0
16	水門	Shuimen	47	2	0	1
17	上豐	Shangfeng	38	2	0	1
18	頂埔仔	Dingpuzi	45	2	0	1
19	國校前	Guoxiaoqi	58	2	0	1

圖10、公車動態A1資料

運用深度方法預測公車旅行時間之初探

站號	中文站名	路線	經	過	進站	離站	車	梯	時間	ISO8601	來源	端	平台	接收	資料	代表	日期	時間	班次	旅行	時間	數值	旅行	時間	起站	站	站	總	旅行	時間	星期	計	費	站	旅行	時間
1	員林站	1	1	2019/1/1	09:39	2019/1/1	09:39	2019/1/1	09:39	2019/1/1	2019/1/1	09:39	1	0.002083333	3	星期二	22																			
2	員林醫院	2	1	2019/1/1	09:42	2019/1/1	09:42	2019/1/1	09:42	2019/1/1	2019/1/1	09:42	1	0.000694444	1	星期二																				
3	員林家商	3	1	2019/1/1	09:43	2019/1/1	09:43	2019/1/1	09:43	2019/1/1	2019/1/1	09:43	1	0.001388889	2	星期二																				
4	龍明新村	4	1	2019/1/1	09:45	2019/1/1	09:45	2019/1/1	09:45	2019/1/1	2019/1/1	09:45	1	0.000694444	1	星期二																				
5	頂大橋	5	1	2019/1/1	09:46	2019/1/1	09:46	2019/1/1	09:46	2019/1/1	2019/1/1	09:46	1	0.001388889	2	星期二																				
6	大橋	6	1	2019/1/1	09:46	2019/1/1	09:46	2019/1/1	09:46	2019/1/1	2019/1/1	09:46	1	0.001388889	2	星期二																				
7	大明里	7	1	2019/1/1	09:48	2019/1/1	09:48	2019/1/1	09:48	2019/1/1	2019/1/1	09:48	1	0.000694444	1	星期二																				
8	新厝仔	8	1	2019/1/1	09:48	2019/1/1	09:48	2019/1/1	09:48	2019/1/1	2019/1/1	09:48	1	0.000694444	1	星期二																				
9	新雅路	9	1	2019/1/1	09:49	2019/1/1	09:49	2019/1/1	09:49	2019/1/1	2019/1/1	09:49	1	0.000694444	1	星期二																				
10	新雅路	10	1	2019/1/1	09:50	2019/1/1	09:50	2019/1/1	09:50	2019/1/1	2019/1/1	09:50	1	0.000694444	1	星期二																				
11	下坊橋頭	11	1	2019/1/1	09:52	2019/1/1	09:52	2019/1/1	09:52	2019/1/1	2019/1/1	09:52	1	0.001388889	2	星期二																				
12	社寮國中	12	1	2019/1/1	09:53	2019/1/1	09:53	2019/1/1	09:53	2019/1/1	2019/1/1	09:53	1	0.000694444	1	星期二																				
13	廟前	13	1	2019/1/1	09:54	2019/1/1	09:54	2019/1/1	09:54	2019/1/1	2019/1/1	09:54	1	0.000694444	1	星期二																				
14	市場	14	1	2019/1/1	09:56	2019/1/1	09:56	2019/1/1	09:56	2019/1/1	2019/1/1	09:56	1	0.001388889	2	星期二																				
15	崙雅	15	1	2019/1/1	09:57	2019/1/1	09:57	2019/1/1	09:57	2019/1/1	2019/1/1	09:57	1	0.000694444	1	星期二																				
16	美雅	16	1	2019/1/1	09:59	2019/1/1	09:59	2019/1/1	09:59	2019/1/1	2019/1/1	09:59	1	0.001388889	2	星期二																				
17	里仁村	17	1	2019/1/1	10:00	2019/1/1	10:00	2019/1/1	10:00	2019/1/1	2019/1/1	10:00	1	0.000694444	1	星期二																				
18	隆力麵	18	1	2019/1/1	10:01	2019/1/1	10:01	2019/1/1	10:01	2019/1/1	2019/1/1	10:01	1	0.000694444	1	星期二																				
19	頂潭	19	1	2019/1/1	10:01	2019/1/1	10:01	2019/1/1	10:01	2019/1/1	2019/1/1	10:01	1	0	0	星期二																				

圖 11、旅行時間計算

3.2 天氣觀測資料

由觀測資料查詢網中蒐集 109 年 1 月 1 日至 109 年 2 月 11 日之天氣資料，蒐集之站點為員林站、水里站，且天氣測站距離站點 1.5 公里範圍內，資料項目包括氣溫、相對濕度、降水量、測站氣壓等，因本研究只考慮降水量的部分，但限於降水量無法預測，當天才可得知降水狀況，因此特殊情況本研究之降雨變數採用會降雨帶入(1)、不會降雨帶入(0)來進行預測。

觀測時間 (hour)	測站氣壓 (hPa)	海平面氣壓 (hPa)	溫度 (°C)	露點溫度 (°C)	相對濕度 (%)	風速 (m/s)	風向 (360degree)	最大陣風 (m/s)	最大陣風風向 (360degree)	降水量 (mm)	降水時數 (hr)	日照時數 (hr)	全天空日射量 (MJ/m²)	能見度 (km)	紫外線指數	總雲量 (0~10)
ObsTime	StnPres	SeaPres	Temperature	Td dew point	RH	WS	WD	WSGust	WDGust	Precp	PrecpHour	SunShine	GloblRad	Visb	UVI	Cloud Amount
01	1016.8	...	9.3	...	99	0.0	0	0.0
02	1018.3	...	8.8	...	99	0.0	0	0.0
03	1016.0	...	8.7	...	99	0.0	0	0.0
04	1017.8	...	8.3	...	99	0.0	0	0.0
05	1016.0	...	8.2	...	99	0.0	0	0.0
06	1018.6	...	8.1	...	99	0.1	0	0.0
07	1019.1	...	7.8	...	99	0.3	199	0.0
08	1019.4	...	11.6	...	99	0.0	0	0.0
09	1019.8	...	15.3	...	61	0.3	297	0.0
10	1019.7	...	18.5	...	47	0.4	310	0.0
11	1019.3	...	20.1	...	40	0.8	300	0.0
12	1018.5	...	20.8	...	42	0.8	283	0.0
13	1017.4	...	21.2	...	39	0.8	288	0.0
14	1016.6	...	21.3	...	36	1.2	8	0.0
15	1016.0	...	21.4	...	37	1.7	344	0.0
16	1015.8	...	20.4	...	45	1.4	332	0.0

圖 12、天氣觀測資料

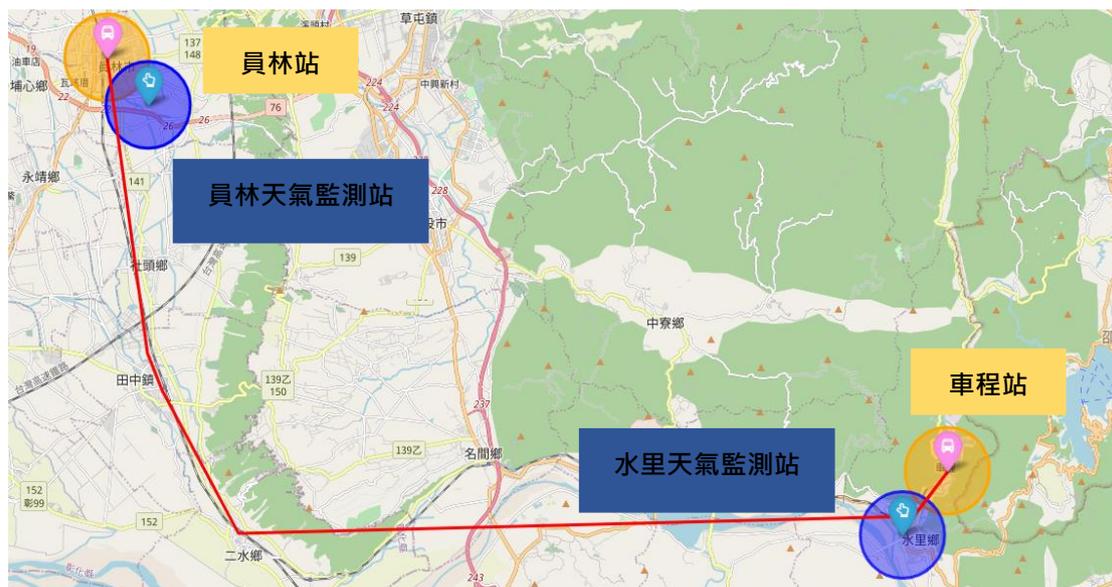


圖13、天氣監測站

3.3 行政院人事行政局初公布之 109 年日曆表

利用人事行政局之行事曆蒐集 109 年 1 月 1 日至 109 年 2 月 11 日之節慶資料，將國定假日作為本研究帶入之節慶變數，若為國定假日變數為 1，非國定假日變數為 0，進行後續模式訓練及預測。

表4、人事行政局之行事曆

109 年人事行政局之行事曆		
節日名稱	日期	假期天數
元旦	2018/12/29-2019/1/1	4 天
春節	2019/2/2-2019/2/10	9 天

3.4 統整資料格式

根據上述資料蒐集、清理，將旅行時間資料、降雨資料、星期資料、節慶資料彙整於 csv 檔案，依照各班次劃分檔案，將日期命為 date、旅行時間命為 time、星期由 Monday 至 Sunday、節日命為 hol，降雨命為 rain，匯入 Python 中進行預測模式建構。

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R
1	date	time	hol	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	rain							
2	2019/1/1	115	1	0	0	1	0	0	0	0	0							
3	2019/1/2	93	0	0	0	0	1	0	0	0	0							
4	2019/1/3	105	0	0	0	0	0	1	0	0	0							
5	2019/1/4	114	0	0	0	0	0	0	1	0	0							
6	2019/1/5	97	0	0	0	0	0	0	0	1	0							
7	2019/1/6	107	0	0	0	0	0	0	0	0	1							
8	2019/1/7	111	0	1	0	0	0	0	0	0	0							
9	2019/1/8	107	0	0	1	0	0	0	0	0	0							
10	2019/1/9	113	0	0	0	0	1	0	0	0	0							
11	2019/1/10	106	0	0	0	0	0	1	0	0	0							
12	2019/1/11	115	0	0	0	0	0	0	1	0	0							
13	2019/1/12	104	0	0	0	0	0	0	0	1	0							
14	2019/1/13	122	0	0	0	0	0	0	0	0	1							
15	2019/1/14	104	0	1	0	0	0	0	0	0	0							
16	2019/1/15	97	0	0	1	0	0	0	0	0	0							
17	2019/1/16	103	0	0	0	1	0	0	0	0	2.5							
18	2019/1/17	104	0	0	0	0	0	1	0	0	0							
19	2019/1/18	112	0	0	0	0	0	0	1	0	0							
20	2019/1/19	114	0	0	0	0	0	0	0	1	0							

圖14、變數資料格式

第四章 預測模式建構

本章節將利用蒐集之資料，透過 Python 建立 LSTM 深度學習之預測模式，因此於 4.1 節將介紹 Python 工具，以及本研究所使用之相關套件應用，4.2 節說明旅行時間預測模式之建構方式流程，4.3 節說明資料帶入的變數、參數調整過程。

4.1 Python 介紹

Python 為一套直譯式且利用物件導向的程式語言，直譯式代表程式中會一次一行將指令執行，直到發生錯誤或結束才會停止，而物件導向則代表以物件為多個具有互動關係的集合，舉例來說：車子、輪胎、引擎皆為物件，車子是由輪胎和引擎所構成的，物件之間彼此是存在相互關係，Python 相較 C 語言、Java 語言，優勢在於語法簡單好學、長度短不像其他語言來的繁瑣，例如：在 Java 語言中輸出一個字是 `System.out.println()`，而 Python 只要輸入 `print()` 即可，使剛入門新手人容易操作，因此本研究將透過 Visual Studio Code 編輯器建立 LSTM 深度學習預測模式，透過網路教學、書籍參閱等方式，由基礎開始學習操作。

4.1.1 Keras 套件

Keras 是 Python 深度學習的框架，提供便利的方式去定義和訓練幾乎所有類型的深度學習模型，主要有幾個特點，第一是允許相同的程式碼在 CPU 或 GPU 上無縫運行，第二是有易懂的 API，使用者可以很容易的快速搭建深度學習神經網路框架的雛形，第三是支援任意神經網路的架構，包刮多元輸入或多元輸出的模型、神經層共享、模型共享等。而因 Keras 是一個建模層次的程式庫，提供深度學習開發的高階模組，所以無法處理低階作業、微分、張量運算等，所以需要仰賴其他外掛程式到 keras 中，如 Tensorflow，下方為 Keras 的主要開發流程。

- (1) 定義訓練的資料
- (2) 定義神經網路模型的 layers，以便將輸入資料對應到預測值
- (3) 選擇損失函數、優化器和監控的評量準則來建立學習過程
- (4) 呼叫模型中的 `fit()` 方法來重複訓練資料

4.1.2 Tensorflow 套件

Tensorflow 為 Google Brian 所開發的套件，也是現今流行的深度學習的框架，主要支援多種程式語言例如 python、JavaScript、C ++、Java 等，該框架可以在 CPU、GPU 或 TPU 上運行，適合建立深度學習架構，方便於資料整合，可以進行圖形輸入、SQL 表和影像，Tensorflow 有幾項優點，如可用來計算圖模型，可以從中簡易的調配參數改善模型，也是較靈活的架構，因開發人員可以使用 Tensorflow 較原始的 API 來開發自己的模型，也可以搭配較高級學習框架如 Keras 的 API 來開發模型。另外在應用方面，舉 Google 執行文字和語音搜索、語言翻

譯和圖像搜索的應用為例，因為 TensorFlow 擅長處理分類和推理預測的模式，所以 Google 將應用為搜索結果的排序，經由訓練神經網路的經分類推算輸出後能有更好搜尋結果，讓大眾容易取得所需資訊，在 Google 翻譯上，Tensorflow 經由分類並改進語音辨識和語音合成，在語音輸出上可以有更自然的發音。

4.1.3 Numpy 套件

在使用 Python 進行數分析時，使用 Numpy 與 Pandas 會比 Python 中自帶的列表(list)或者是字典(dictionary)的運算相對快很多，而 Numpy 底層是基於 C 語言得實作，所以能快速操作多重維度的陣列，且具備平行處理的能力，可以操作大型的矩陣，而 Python 其他相關資料科學的相關套件，也都是奠基在 Numpy 的基礎上。

4.1.4 Pandas 套件

在基於 Numpy 上的精進改良版，用於數據分析，可以處理和 Excel 表相似的表格數據，csv 檔案讀取、刪減、增加、欄位替換等，處理有序列與無序列的時間序列數據、帶行列標籤的矩陣數據、統計數據等，而其中主要常用的的數據結構包含一維數據 Series 和二維數據 DataFrame 表格型的數據結構，其每列可以是不同的資料型別，例如數值、字串等，另外 Pandas 有幾項優勢，例如可以處理浮點數與非浮點數的缺失數據，自動對其數據、將 Python 與 Numpy 中不規則排列或不同索引的數據轉換成表格呈現，是更直觀可清楚呈現數據。

4.1.5 Matplotlib 套件

Matplotlib 是 MATLAB、Plot 和 Library 的簡稱，應用於資料科學和機器學習的視覺化呈現，是模仿 MATLAB 建立的繪圖庫，其中也應用到 Numpy 的相關代碼，目的為提高大量資料處理，可處理二維和三維的圖表，可繪製折線圖、直方圖、散佈圖、圓餅圖和盒狀圖等，而 Matplotlib 套件大部分的功能是透過 Pyplot 模組提供，使用上會用到其提供之函數。

4.2 旅行時間預測模式建構

利用 Visual Studio Code 編輯器將上述彙整之訓練集資料匯入，各班次各別執行情況下，載入 numpy、pandas、matplotlib 套件，資料匯入時須分為訓練集、測試集，訓練集作為模式訓練之用，測試集作為模式預測之用，因此於模式建構時採用訓練資料作為模型訓練，訓練集檔案成功匯入進行讀檔及標準化動作，讓資料標準化目的是為了讓變數資料的單位統一，變數項目包括過去 7 天旅行時間、星期、節慶、降雨，各項變數的單位皆不相同，因此需要標準化動作，之後將旅行時間資料以每 7 天為一個範圍，預測 1 天逐步往下移動訓練，因每個時間步輸出受於上個時間步的影響時間步之間存在相互關係，建立 LSTM 核心架構層中利用 Sequential 序貫模型，將輸入層、隱藏層、輸出層堆疊，於輸入層放入變數，開始訓練預測模型，將訓練完成之模式評估其損失函數，匯入測試集資料進行預測，最後將預測值與現況比對誤差結果。

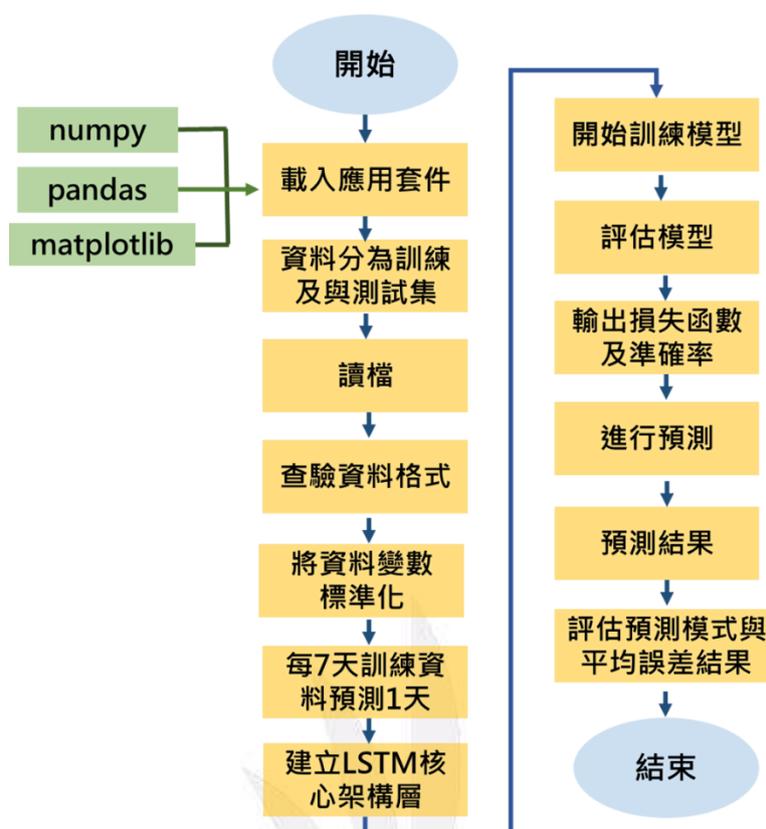


圖15、旅行時間預測模式建構

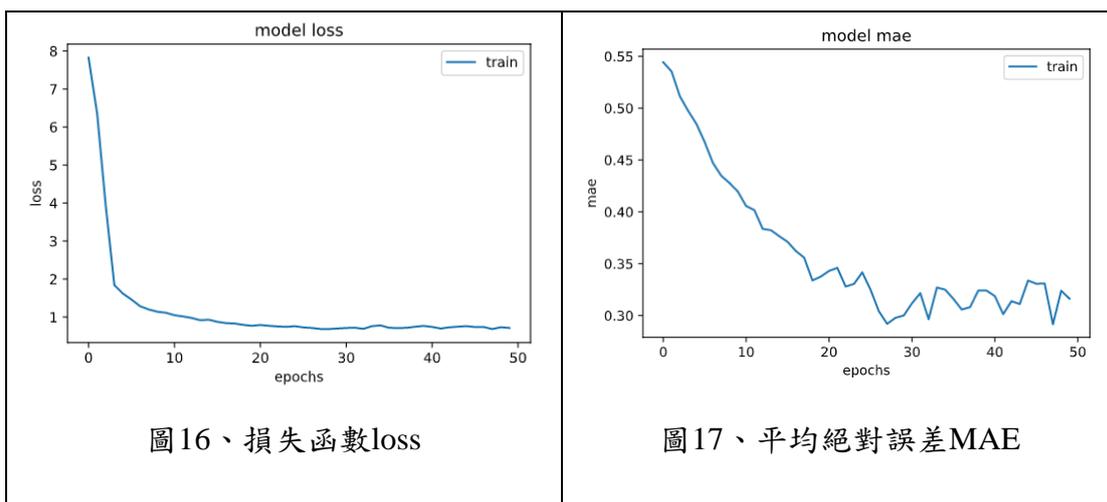
4.3 損失函數評估

深度學習方法皆須要使用損失函數去找到某個函數的極值，這些極值可能是最大化或最小化，稱為目標函數，損失函數(loss)用以衡量神經網路在訓練資料上的表現，讓網路訓練時能朝向正確的方向進行修正，若損失函數隨著訓練次數下降，代表模型訓練成果良好，此模型才能夠進行後續測試資料之預測，若損失函數隨著訓練次數逐漸上升，則顯示其模式訓練成果不佳，需針對模式內容進行重新調整，因此藉由上述損失函數之評估方式，加以衡量本研究訓練模型之優劣，以進行後續之預測。

4.3.1 各模式損失函數評估

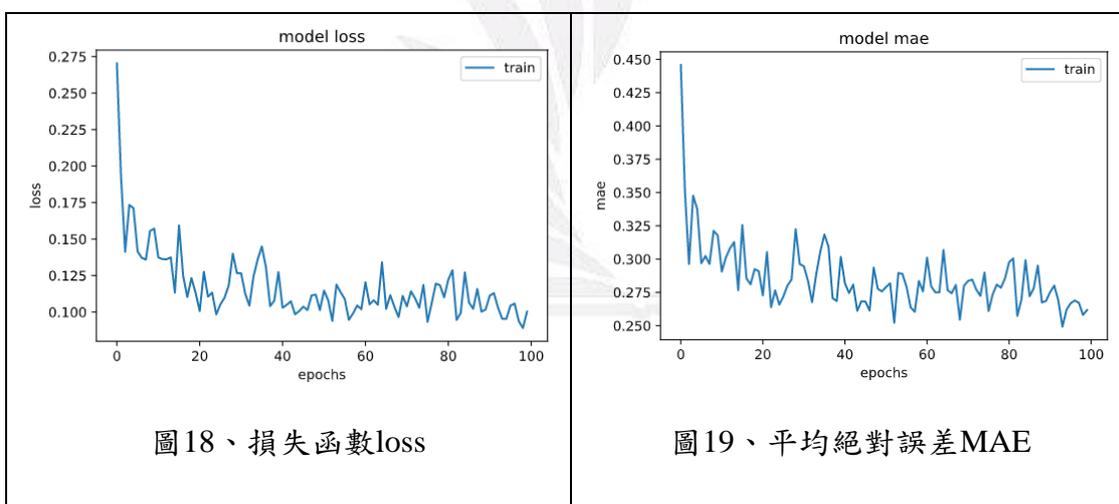
(1) (員林 \leftrightarrow 車埕)第一班次損失函數評估

本研究採用損失函數(loss)及平均絕對誤差(MAE)雙重評估方式確保訓練模型之成效，透過訓練資料進行損失函數評估，發現員林-車埕第一班次損失函數隨著訓練次數增加而呈現下降趨勢，表示模型訓練成果良好，並藉由平均絕對誤差 MAE，觀察其訓練資料確實呈現下降趨勢，以利進行後續之預測。



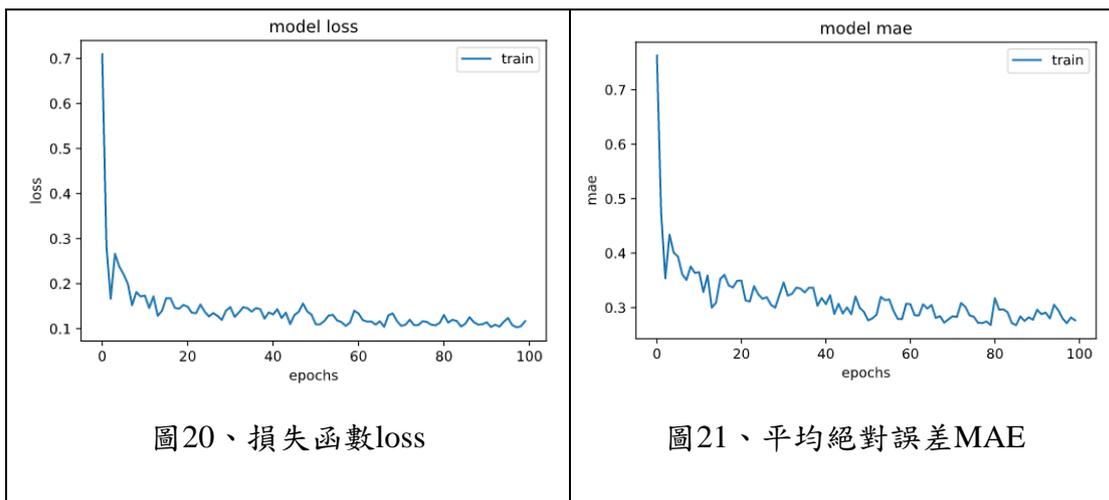
(2) (員林 \leftrightarrow 卓乃潭)第一班次損失函數評估

員林-卓乃潭區間之模型訓練同樣使用損失函數(loss)及平均絕對誤差(MAE)雙重評估方式確保訓練模型之成效，透過訓練資料進行損失函數評估，發現員林-卓乃潭第一班次損失函數隨著訓練次數增加而呈現下降趨勢，表示模型訓練成果良好，並藉由平均絕對誤差 MAE，觀察其訓練資料確實呈現下降趨勢，以利進行後續之預測。



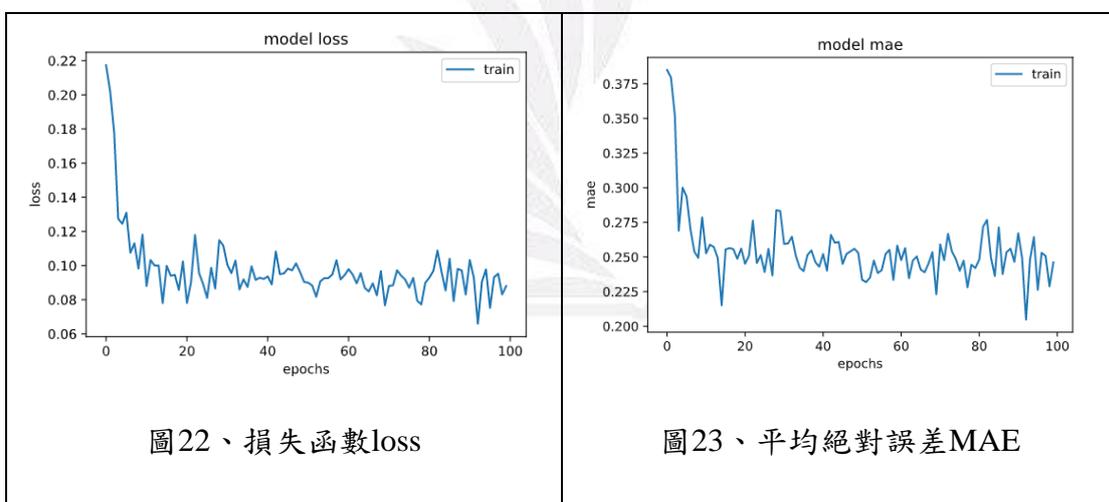
(3) (卓乃潭 \leftrightarrow 田中)第一班次損失函數評估

卓乃潭-田中區間之模型訓練同樣使用損失函數(loss)及平均絕對誤差(MAE)雙重評估方式確保訓練模型之成效，透過訓練資料進行損失函數評估，發現卓乃潭-田中第一班次損失函數隨著訓練次數增加而呈現下降趨勢，表示模型訓練成果良好，並藉由平均絕對誤差 MAE，觀察其訓練資料確實呈現下降趨勢，以利進行後續之預測。



(4) (田中 \leftrightarrow 車程)第一班次損失函數評估

田中-車程區間之模型訓練同樣使用損失函數(loss)及平均絕對誤差(MAE)雙重評估方式確保訓練模型之成效，透過訓練資料進行損失函數評估，發現田中-車程第一班次損失函數隨著訓練次數增加而呈現下降趨勢，表示模型訓練成果良好，並藉由平均絕對誤差 MAE，觀察其訓練資料確實呈現下降趨勢，以利進行後續之預測。



4.4 變數與參數分析

4.4.1 變數調整

本研究所帶之變數項目包括過去 7 天旅行時間、星期、節慶、有無降雨，來進行調整，分為無降雨模式 1、有降雨模式 2，觀察放入降雨變數預測模式之變化，模式 1 帶入之變數包括過去 7 天旅行時間、星期、節慶，模式 2 帶入變數包括過去 7 天旅行時間、星期、節慶、降雨，且兩者模式皆預測員林至車埕總旅行時間，如表 6，且因為放入資料的變數不同須要改變 LSTM 核心層內模式的輸入值。

表5、模式變數項目

模式	變數項目	預測
模式 1	過去 7 天旅行時間、 星期、節慶	旅行時間
模式 2	過去 7 天旅行時間、 星期、節慶、降雨	旅行時間

模式 1 中所帶入之變數包括過去 7 天旅行時間、星期、節慶，過去 7 天旅行時間每一天皆為變數因此變數值為 7，星期分為 Monday 至 Sunday 變數值也為 7，節慶則為一個變數為 1，因此於模式 1 預測模式中 共有 15 個變數輸入。



圖24、多變模式1變數輸入值

模式 2 中所帶入之變數包括過去 7 天旅行時間、星期、節慶、降雨，過去 7 天旅行時間每一天皆為變數因此變數值為 7，星期分為 Monday 至 Sunday 變數值也為 7，節慶與降雨則各為一個變數，因此於模式 2 預測模式中 共有 16 個變數輸入。



圖25、多變模式2變數輸入值

詳細變數值帶入如圖 26，使用模式 2 為例，days 代表過去 7 天的旅行時間，加 9 代表有星期、節慶、降雨的變數，因此在 LSTM 核心層輸入共有 16 個變數項目。

```
# LSTM Training
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense, Dropout, Flatten
from tensorflow.keras.utils import plot_model

reshape_size = days+9
model = Sequential()

model.add(LSTM(units = 16, return_sequences = True, input_shape = (reshape_size, 1), dropout=0.2))
model.add(Flatten())
model.add(Dense(units = 400))
#model.add(Dense(units = 400))
model.add(Dense(units = out_days))
model.compile(optimizer = 'adam', loss = 'mean_squared_error')
model.summary()
plot_model(model, 'model.png')
```

The image shows a screenshot of Python code for training an LSTM model. Two yellow arrows point from a blue box labeled '資料放入的變數' to the code. One arrow points to the line 'reshape_size = days+9', which is circled in red. The other arrow points to the line 'model.add(LSTM(units = 16, return_sequences = True, input_shape = (reshape_size, 1), dropout=0.2))', where 'units = 16' is circled in red.

圖26、變數輸入值

4.4.2 MAPE 預測能力量表

根據 Lewis 1982 提出之 MAPE 分為四種等級，等級由好至壞為極佳、優良、合理、不正確，當 MAPE 值 $< 10\%$ 時，即表示其實際與預測的誤差越小，所以有較佳的預測能力； $10\% < \text{MAPE 值} < 20\%$ 代表優良， $20\% < \text{MAPE 值} < 50\%$ 代表合理，MAPE 值 $> 50\%$ 代表不正確，因此本研究將參照 Lewis 提出之 MAPE 預測量表作為模式評估依據。

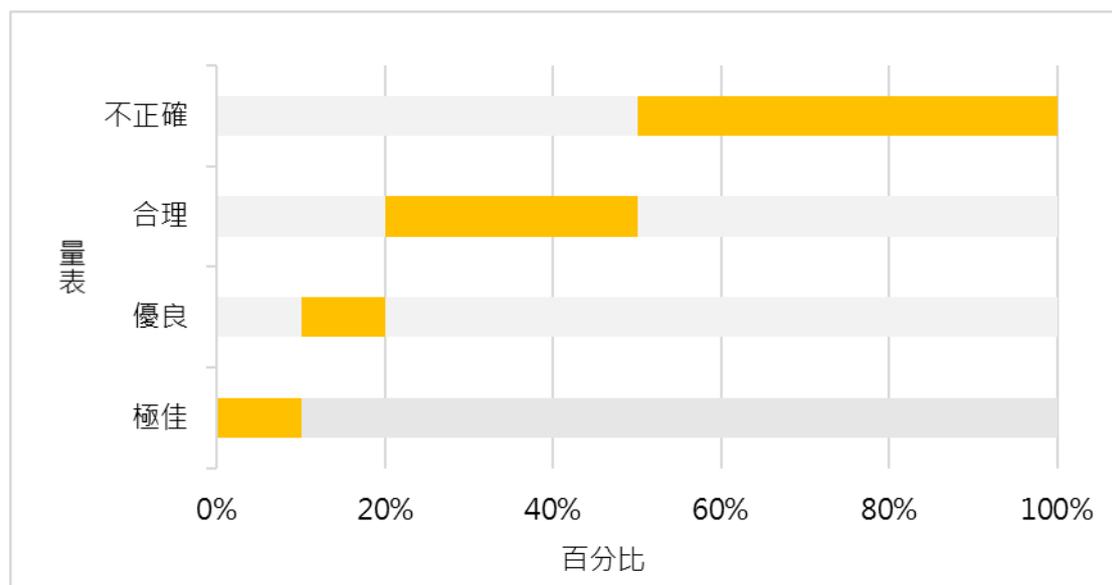


圖 27、預測能力尺度量表

4.4.3 參數調整

訓練模式建置完成，將進行參數調整，利用加入隱藏層、調整隱藏層神經元、訓練次數 epochs、每一批次訓練筆數 batch_size 等方式，觀察參調整後總旅行時間預測模式與區間旅行時間模式之敏感度情況，藉由變數變化、參數調整找出最佳之預測模式，表格中將說明各班次模式 1、模式 2 調整參數之變化。

1. 員林-車埕預測模式參數調整

(1) 員林-車埕第一班次(模式 1)

表 6 為模式 1 員林-車埕第一班次總旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 7.2508%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 6.8452%。

表6、模式1員林-車埕第一班次

員林-車埕第一班次			
	輸入層	隱藏層	MAPE
模式 1	15	50	7.5648
		100	7.2508
		200	8.8550
		300	8.2497
		400	8.2378
		500	8.5696

表7、加入隱藏層2變化

員林-車埕第一班次				
	輸入層	隱藏層 1	隱藏層 2	MAPE
模式 1	15	100	10	7.9865
			20	7.1343
			30	6.9304
			40	6.8452
			50	7.1123

將誤差值最小之模式 6.8452%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 200，batch_size 為 20 的情況下誤差為 6.7834%，因此在模式 1 員林-車埕第一班次總旅行時間最佳之預測模式為輸入層=15，隱藏層 1=100，隱藏層 2=40，epochs=200，batch_size=20，MAPE 為 6.7834%。

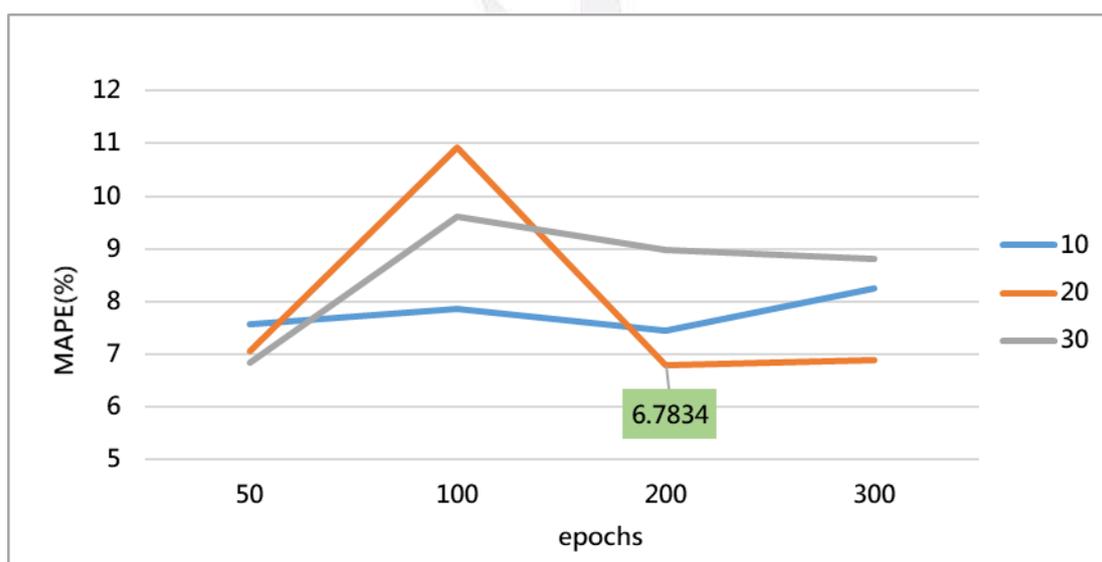


圖28、員林-車埕第一班調整epochs、batch_size (模式1)

(2) 員林-車埕第一班次(模式 2)

表 8 為模式 2 員林-車埕第一班次總旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 7.1848%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 6.9017%。

表8、模式2員林-車埕第一班次

員林-車埕第一班次				
模式 2	輸入層	隱藏層	MAPE	
	16		50	7.1848
			100	7.8388
			200	8.6063
			300	8.5666
			400	9.1365
			500	9.2798

表9、加入隱藏層2變化

員林-車埕第一班次					
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE	
	16	50		10	7.4654
				20	7.8553
				30	7.0332
				40	7.1844
				50	6.9017

將誤差值最小之模式 6.9017%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 100，batch_size 為 20 的情況下誤差最小為 6.859%，因此在模式 2 員林-車埕第一班次總旅行時間最佳之預測模式為輸入層=16，隱藏層 1=50，隱藏層 2=50，epochs=100，batch_size=20，MAPE 為 6.7834%。

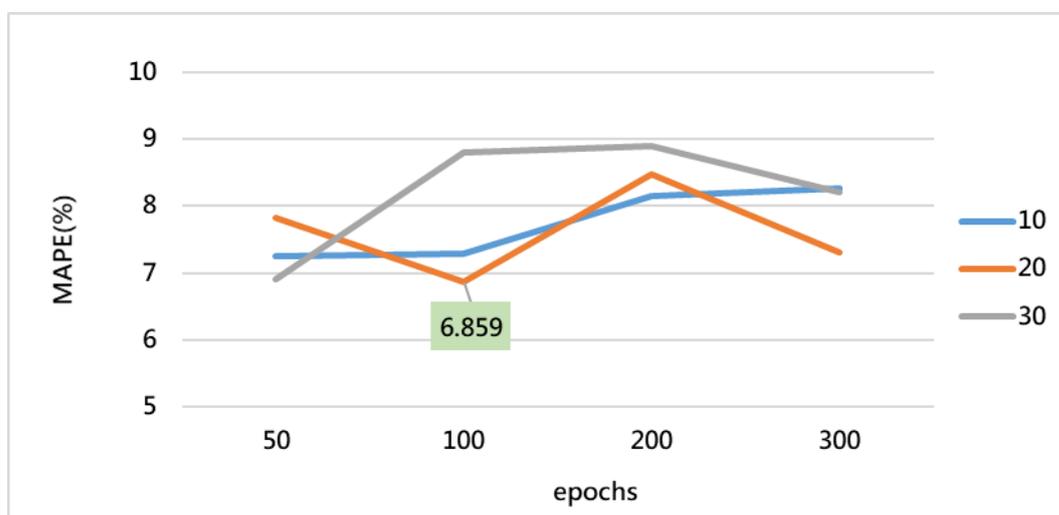


圖29、員林-車埕第一班調整epochs、batch_size (模式2)

(3) 員林-車埕第二班次(模式 1)

表 10 為模式 1 員林-車埕第二班次總旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 6.6824%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 5.5824%。

表10、模式1員林-車埕第二班次

員林-車埕第二班次				
模式 1	輸入層	隱藏層	MAPE	
	15		50	6.6824
			100	7.9185
			200	7.0285
			300	7.1419
			400	8.6256
			500	7.3777

表11、加入隱藏層2變化

員林-車埕第二班次					
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE	
	15	50		10	6.8633
				20	6.9040
				30	8.0664
				40	7.1614
				50	5.5824

將誤差值最小之模式 5.5824%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 5.5824%，因此在模式 2 員林-車埕第二班次總旅行時間最佳之預測模式為輸入層=15，隱藏層 1=50，隱藏層 2=50，epochs=50，batch_size=30，MAPE 為 5.5824%。

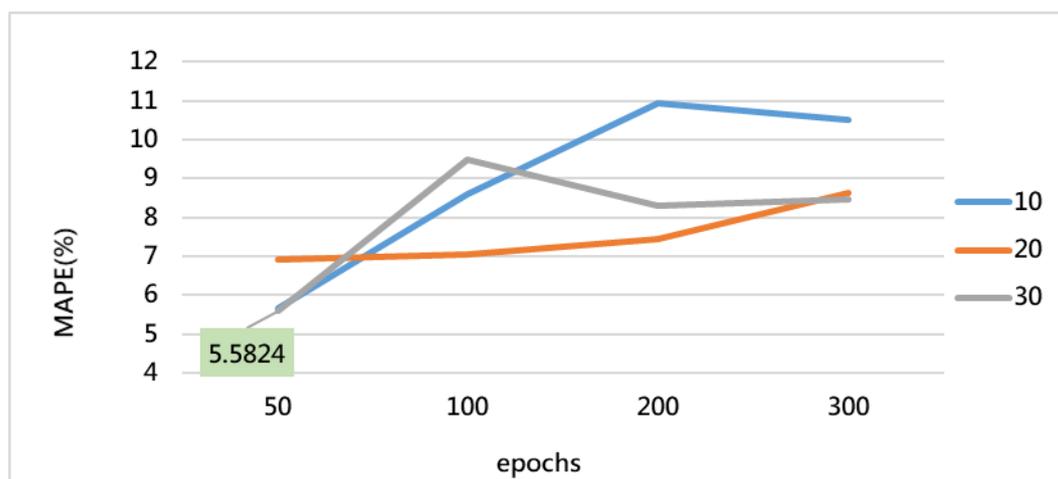


圖30、員林-車埕第二班調整epochs、batch_size (模式1)

(4) 員林-車埕第二班次(模式 2)

表 12 為模式 2 員林-車埕第二班次總旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 6.4232%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 6.4983%，因此選擇誤差最小之 6.4232% 做 epochs、batch_size 變化調整。

表12、模式2員林-車埕第二班次

員林-車埕第二班次			
模式 2	輸入層	隱藏層	MAPE
	16	50	6.9756
		100	7.4584
		200	6.5418
		300	8.2926
		400	6.4232
		500	7.2455

表13、加入隱藏層2變化

員林-車埕第二班次				
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE
	16	50	10	8.1644
			20	6.4983
			30	7.8715
			40	7.7644

			50	7.1113
--	--	--	----	--------

將誤差值最小之模式 6.4232%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 100，batch_size 為 10 的情況下誤差最小為 5.8222%，因此在模式 2 員林-車埕第二班次總旅行時間最佳之預測模式為輸入層=16，隱藏層 1=50，epochs=100，batch_size=10，MAPE 為 5.8222%。

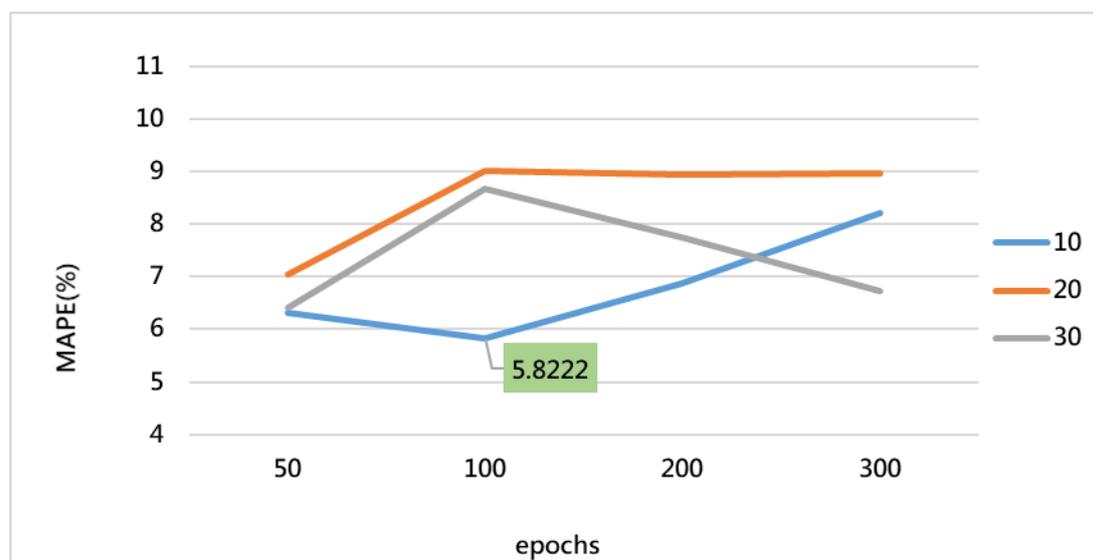


圖31、員林-車埕第二班次調整epochs、batch_size (模式2)

(5) 員林-車埕第三班次(模式 1)

表 14 為模式 1 員林-車埕第三班次總旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 6.7342%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 6.6958%，因此選擇誤差最小之 6.6958%做 epochs、batch_size 變化調整。

表14、模式1員林-車埕第三班次

員林-車埕第三班次			
模式 1	輸入層	隱藏層	MAPE
	15		50
100			6.7342
200			6.8384
300			6.9391
400			6.7355
500			6.8157

表15、加入隱藏層2變化

員林-車埕第三班次				
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE
	15	400	10	6.8321
20			6.7507	
30			7.0347	
40			6.7488	
50			6.6958	

將誤差值最小之模式 6.6958%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 6.6958%，因此在模式 1 員林-車埕第三班次總旅行時間最佳之預測模式為輸入層=15，隱藏層 1=50，隱藏層 2=400，epochs=50，batch_size=30，MAPE 為 6.6958%。

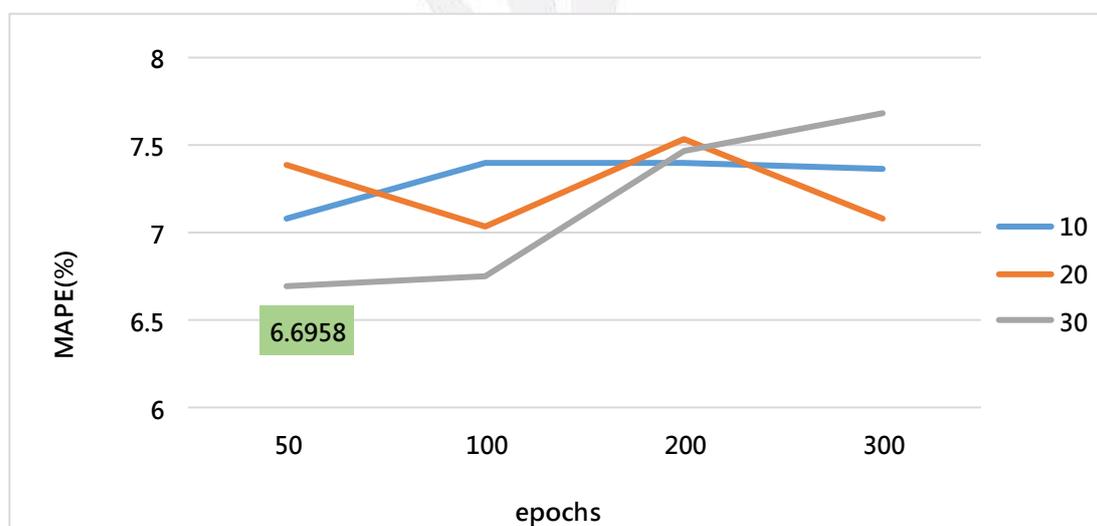


圖32、員林-車埕第三班調整epochs、batch_size (模式1)

(6) 員林-車埕第三班次(模式 2)

表 16 為模式 2 員林-車埕第三班次總旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 6.7438%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 6.7878%，因此選擇誤差最小之 6.7438%做 epochs、batch_size 變化調整。

表16、模式2員林-車埕第三班次

員林-車埕第三班次				
模式 2	輸入層	隱藏層	MAPE	
	16		50	6.7665
			100	6.8741
			200	6.7438
			300	7.3482
			400	6.9691
			500	6.8992

表17、加入隱藏層2變化

員林-車埕第三班次					
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE	
	16	200		10	7.2926
				20	7.1789
				30	6.9570
				40	6.9721
				50	6.7878

將誤差值最小之模式 6.7438%，改變 epochs 訓練次數由 50、100、200，每一批次訓練筆數 batch_size 由 10、20、30，觀察參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 6.7438%，因此在模式 2 員林-車埕第三班次總旅行時間最佳之預測模式為輸入層=16，隱藏層 1=200，epochs=50，batch_size=30，MAPE 為 6.7438%。

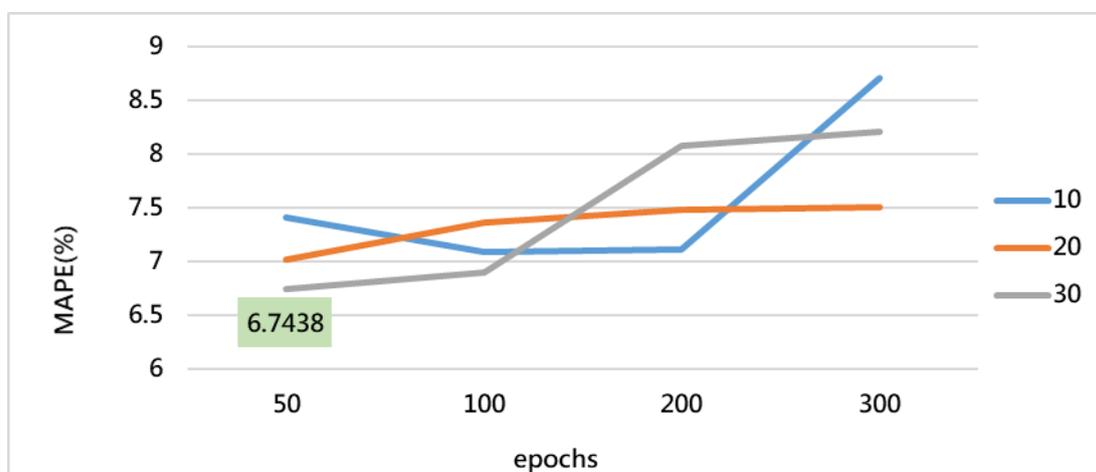


圖33、員林-車程第三班調整epochs、batch_size (模式2)

(7) 車埕-員林第一班次(模式 1)

表 18 為模式 1 車埕-員林第一班次總旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 4.8321%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 4.8295%，因此選擇誤差最小之 4.8295% 模式做 epochs、batch_size 變化調整。

表18、模式1車埕-員林第一班次

車埕-員林第一班次				
模式 1	輸入層	隱藏層	MAPE	
	15		50	4.8321
			100	4.8515
			200	4.8479
			300	4.8473
			400	4.8838
			500	4.8385

表19、加入隱藏層2變化

車埕-員林第一班次					
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE	
	15	50		10	4.8295
				20	4.8993
				30	4.8619
				40	4.8535
				50	4.8509

將誤差值最小之模式 4.8295%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 4.8295%，因此在模式 1 車埕-員林第一班次總旅行時間最佳之預測模式為輸入層=15，隱藏層 1=50，隱藏層 2=10，epochs=50，batch_size=30，MAPE 為 4.8295%。

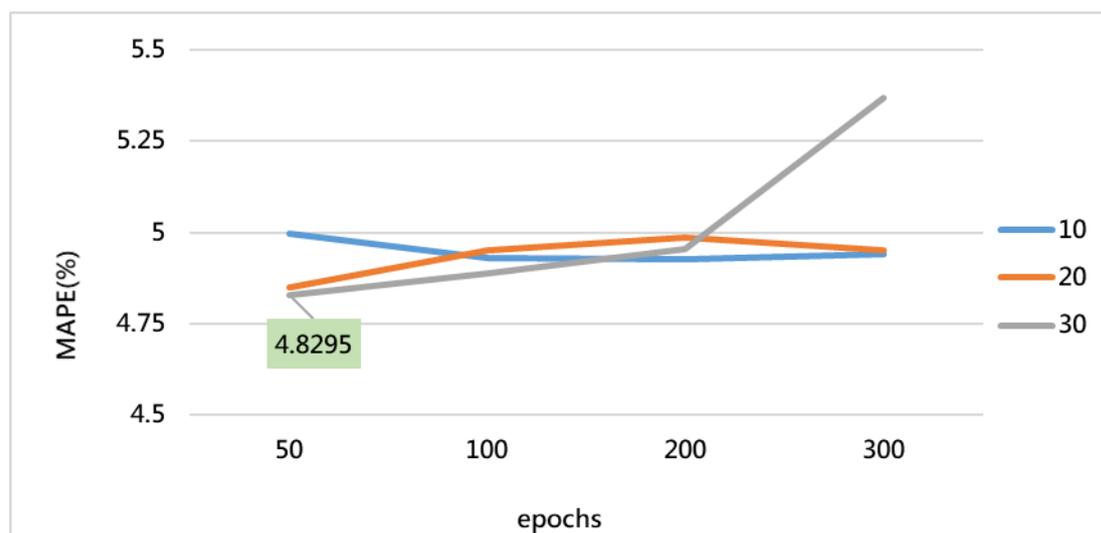


圖34、車埕-員林第一班調整(模式1)epochs、batch_size

(8) 車埕-員林第一班次(模式 2)

表 20 為模式 2 車埕-員林第一班次總旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 4.8518%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 4.9081%，因此選擇誤差最小之 4.8518% 模式做 epochs、batch_size 變化調整。

表20、模式2車埕-員林第一班次

車埕-員林第一班次			
	輸入層	隱藏層	MAPE
模式 2	16	50	5.0897
		100	4.8567
		200	4.8932
		300	4.8518
		400	4.9042
		500	5.0048

表21、加入隱藏層2變化

車埕-員林第一班次				
	輸入層	隱藏層 1	隱藏層 2	MAPE
模式 2	16	50	50	4.9434
			100	4.9081
			150	4.9767
			200	4.9899
			250	5.0287
			300	4.9199

將誤差值最小之模式 4.8518%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀察參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 4.8518%，因此在模式 2 車埕-員林第一班次總旅行時間最佳之預測模式為輸入層=16，隱藏層 1=50，epochs=50，batch_size=30，MAPE 為 4.8518%。

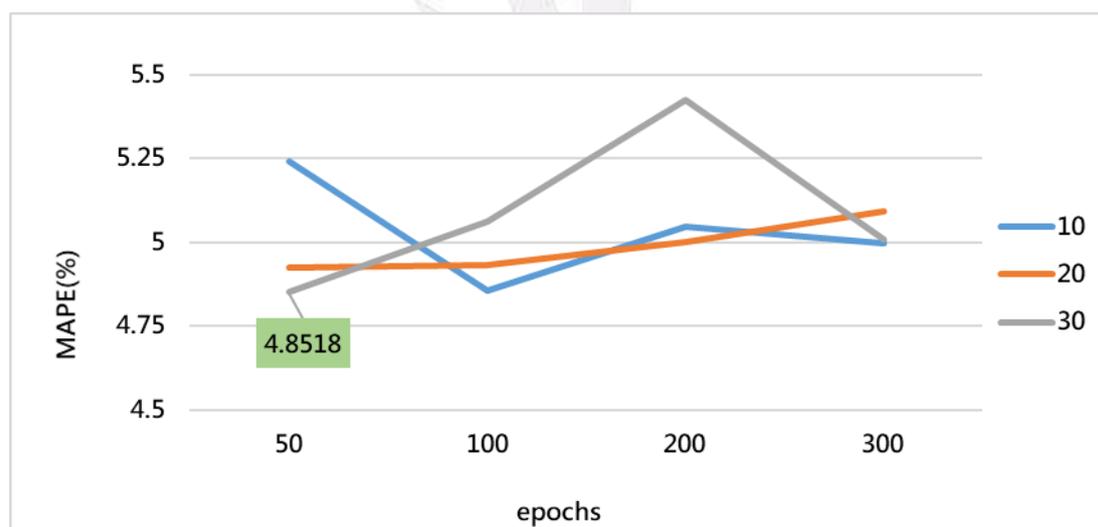


圖35、車埕-員林第一班調整epochs、batch_size (模式2)

(9) 車埕-員林第二班次(模式 1)

表 22 為模式 1 車埕-員林第二班次總旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 6.3672%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 6.3997%，因此選擇誤差最小之 6.3672% 模式做 epochs、batch_size 變化調整。

表22、模式1車埕-員林第二班次

車埕-員林第二班次				
模式 1	輸入層	隱藏層	MAPE	
	15		50	6.4311
			100	6.3926
			200	6.4160
			300	6.4635
			400	6.3672
			500	6.8129

表23、加入隱藏層2變化

車埕-員林第二班次					
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE	
	15	400		50	6.3997
				100	6.4000
				200	6.4380
				300	6.4023
				400	6.4462

將誤差值最小之模式 6.3672%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 6.3672%，因此在模式 1 車埕-員林第二班次總旅行時間最佳之預測模式為輸入層=15，隱藏層 1=400，epochs=50，batch_size=30，MAPE 為 6.3672%。

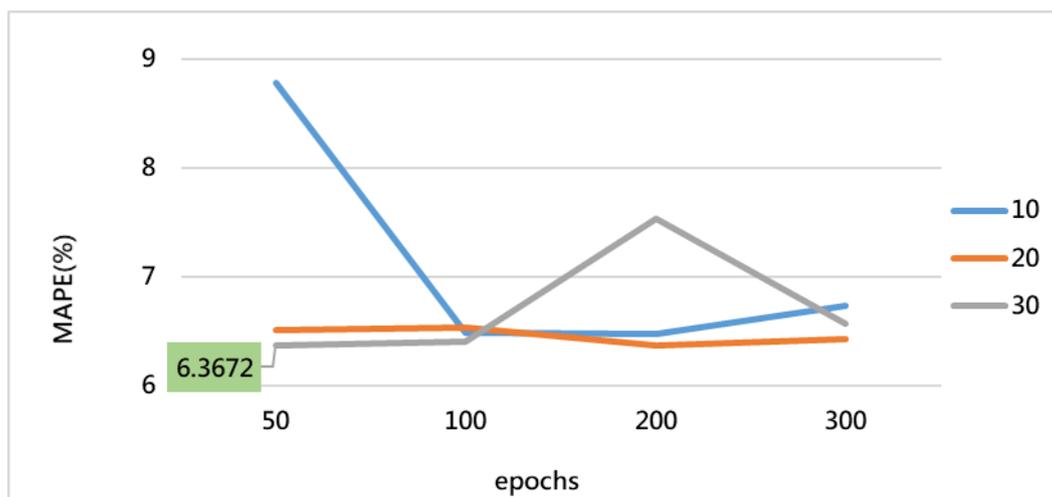


圖36、車埕-員林第二班調整epochs、batch_size (模式1)

(10) 車埕-員林第二班次(模式 2)

表 24 為模式 2，車埕-員林第二班次總旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 4.8383%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 4.8421%，因此選擇誤差最小之 4.8383% 模式做 epochs、batch_size 變化調整。

表24、模式1車埕-員林第二班次

車埕-員林第二班次			
	輸入層	隱藏層	MAPE
模式 2	16	50	4.8741
		100	4.9835
		200	4.8383
		300	4.8711
		400	4.8509
		500	4.9526

表25、加入隱藏層2變化

車埕-員林第二班次				
	輸入層	隱藏層 1	隱藏層 2	MAPE
模式 2	16	200	50	4.8421
			100	4.8749
			150	4.9078

			200	4.9210
--	--	--	-----	--------

將誤差值最小之模式 4.8383%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 4.8383%，因此在模式 2 車埕-員林第二班次總旅行時間最佳之預測模式為輸入層=16，隱藏層 1=200，epochs=50，batch_size=30，MAPE 為 4.8383%。

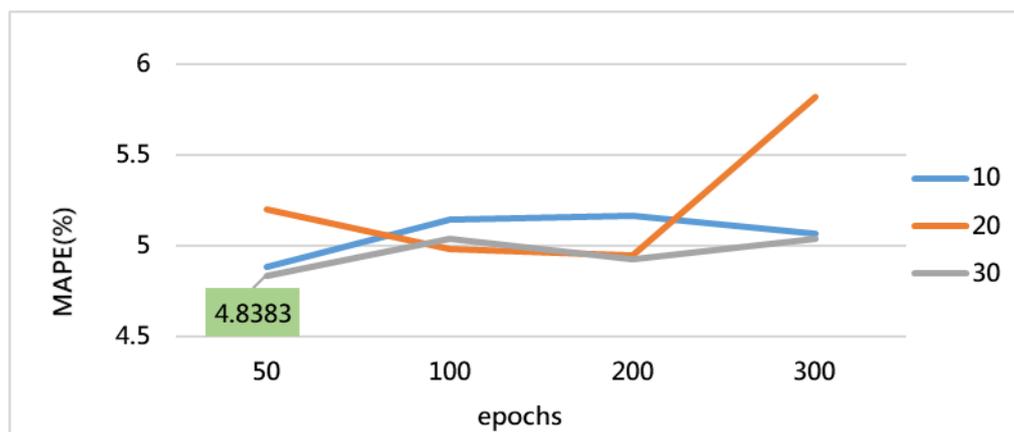


圖37、車埕-員林第二班調整epochs、batch_size (模式2)

(11) 車埕-員林第三班次(模式 1)

表 26 為模式 1，車埕-員林第三班次總旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 4.7507%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 4.7623%，因此選擇誤差最小之 4.7507% 模式做 epochs、batch_size 變化調整。

表26、模式1車埕-員林第三班次

車埕-員林第三班次			
	輸入層	隱藏層	MAPE
模式 1	15	50	4.9492
		100	4.7844
		200	4.7557
		300	4.7507
		400	4.7802
		500	4.7551

表27、加入隱藏層2變化

車埕-員林第三班次				
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE
	15	300	50	4.7623
			100	4.7645
			150	4.7687
			200	4.7850
			250	4.8735
			300	4.9254

將誤差值最小之模式 4.7507%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 100，batch_size 為 10 的情況下誤差最小為 4.7448%，因此在模式 1 車埕-員林第三班次總旅行時間最佳之預測模式為輸入層=15，隱藏層 1=300，epochs=100，batch_size=10，MAPE 為 4.7448%。

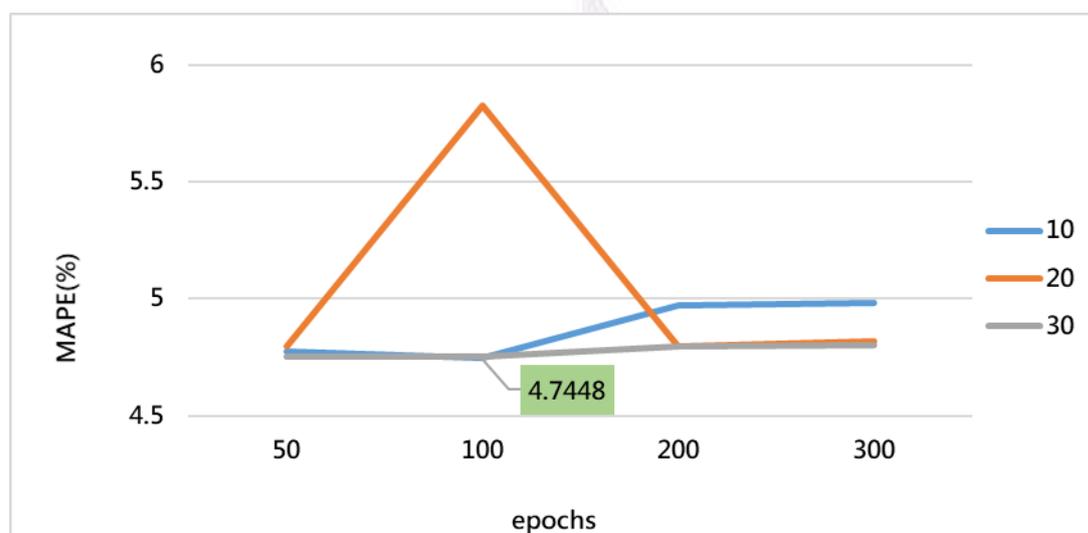


圖38、車埕-員林第三班調整epochs、batch_size (模式1)

(12) 車埕-員林第三班次(模式 2)

表 28 為模式 2，車埕-員林第三班次總旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 4.7379%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 4.8036%，因此選擇誤差最小之 4.7379% 模式做 epochs、batch_size 變化調整。

表28、模式2車埕-員林第三班次

車埕-員林第三班次

模式 1	輸入層	隱藏層	MAPE
	16		50
100			4.7379
200			4.8646
300			4.7477
400			4.9277
500			4.7965

表29、加入隱藏層2變化

車埕-員林第三班次				
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE
	16	16	100	20
40				4.9457
60				5.0865
80				4.7986
100				4.8355

將誤差值最小之模式 4.7379%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 4.7379%，因此在模式 2 車埕-員林第三班次總旅行時間最佳之預測模式為輸入層=16，隱藏層 1=100，epochs=50，batch_size=30，MAPE 為 4.7379%。

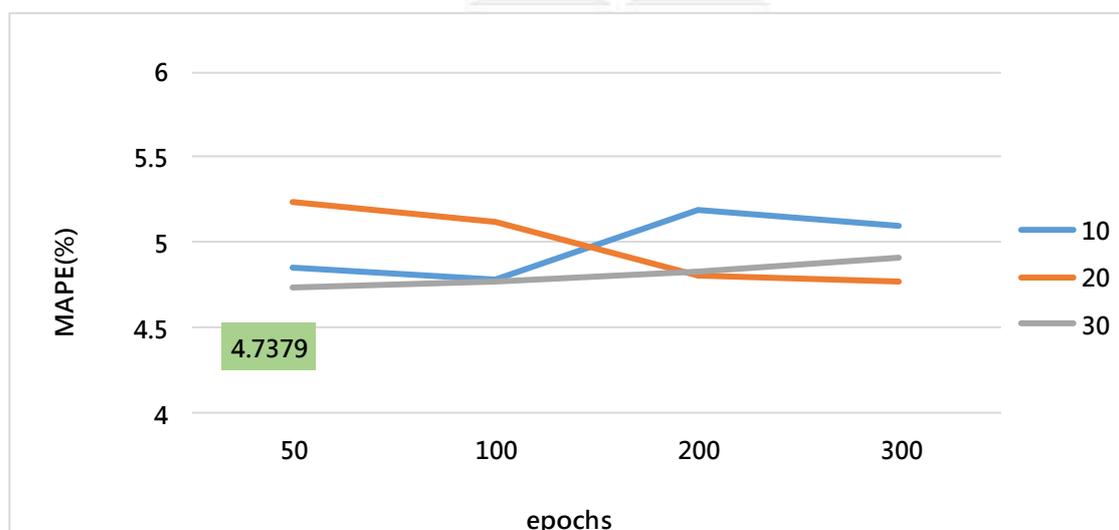


圖39、車埕-員林第三班調整epochs、batch_size (模式2)

2. 員林-卓乃潭預測模式參數調整

(1) 員林-卓乃潭第一班次(模式 1)

表 30 為模式 1，員林-卓乃潭區間第一班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 4.6593%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 4.6370%，因此選擇誤差最小之 4.6370% 模式做 epochs、batch_size 變化調整。

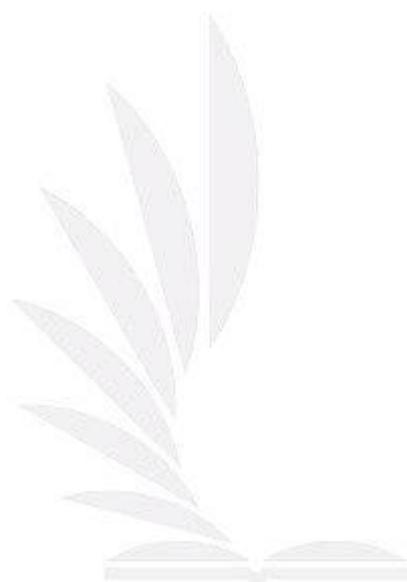


表30、模式1員林-卓乃潭第一班次

員林-卓乃潭第一班次				
模式 1	輸入層	隱藏層	MAPE	
	15		50	4.6593
			100	4.8523
			200	4.8366
			300	4.8102
			400	4.9727
			500	4.9287

表31、加入隱藏層2變化

員林-卓乃潭第一班次					
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE	
	15	50		10	5.5002
				20	4.6370
				30	4.6637
				40	4.7052
				50	4.7587

將誤差值最小之模式 4.6370%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 200，batch_size 為 30 的情況下誤差最小為 4.5804%，因此在模式 1 員林-卓乃潭第一班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=50，隱藏層 2=20，epochs=200，batch_size=30，MAPE 為 4.5804%。

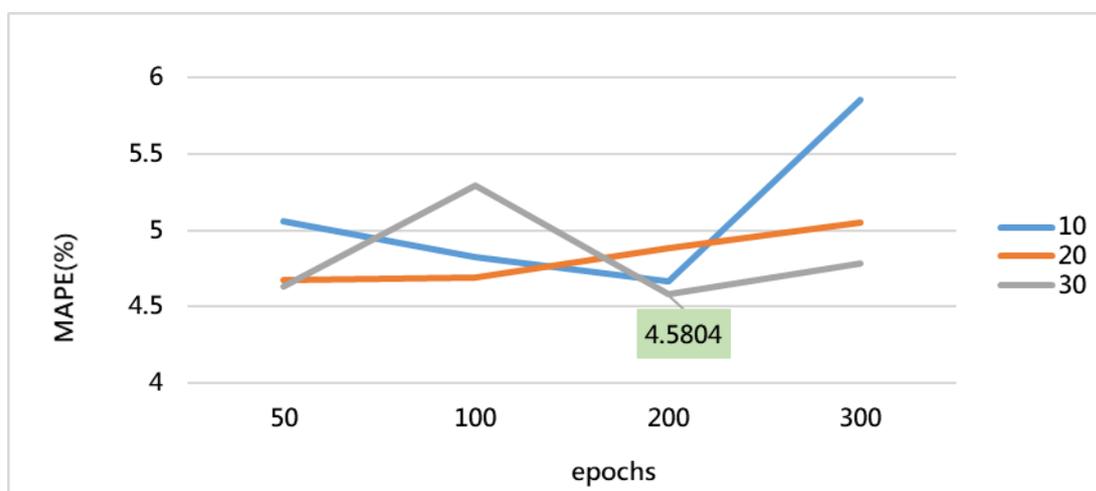


圖40、員林-卓乃潭第一班調整epochs、batch_size (模式1)

(2) 員林-卓乃潭第一班次(模式 2)

表 32 為模式 2，員林-卓乃潭區間第一班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 4.6119%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 4.6286%，因此選擇誤差最小之 4.6119% 模式做 epochs、batch_size 變化調整。

表32、模式2員林-卓乃潭第一班次

員林-卓乃潭第一班次				
模式 2	輸入層	隱藏層	MAPE	
	16		50	4.6119
			100	5.3249
			200	4.7750
			300	5.0844
			400	4.7504
			500	4.7593

表33、加入隱藏層2變化

員林-卓乃潭第一班次					
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE	
	16	50		10	4.6286
				20	4.6667
				30	4.7562
				40	4.7083
				50	4.6785

將誤差值最小之模式 4.6119%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 4.6119%，因此在模式 2 員林-卓乃潭第一班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=50，epochs=50，batch_size=30，MAPE 為 4.6119%。

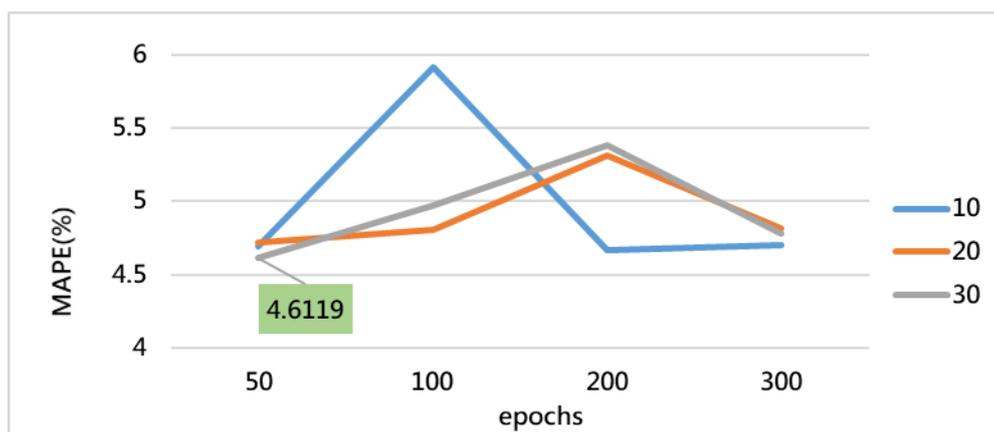


圖41、員林-卓乃潭第一班調整epochs、batch_size (模式2)

(3) 員林-卓乃潭第二班次(模式 1)

表 34 為模式 1，員林-卓乃潭區間第二班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 11.5932%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 11.6722%，因此選擇誤差最小之 11.5932% 模式做 epochs、batch_size 變化調整。

表34、模式1員林-卓乃潭第二班次

員林-卓乃潭第二班次			
模式 1	輸入層	隱藏層	MAPE
	15	50	13.1105
		100	14.4300
		200	12.4911
		300	11.5932
		400	12.8169
		500	12.3154

表35、加入隱藏層2變化

員林-卓乃潭第二班次				
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE
	15	300	50	12.5041
			100	13.0082
			150	11.8283
			200	11.6722
			250	12.9881

			300	12.1939
--	--	--	-----	---------

將誤差值最小之模式 11.5932%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 10 的情況下誤差最小為 11.1288%，因此在模式 1 員林-卓乃潭第二班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=300，epochs=50，batch_size=10，MAPE 為 11.1288%。

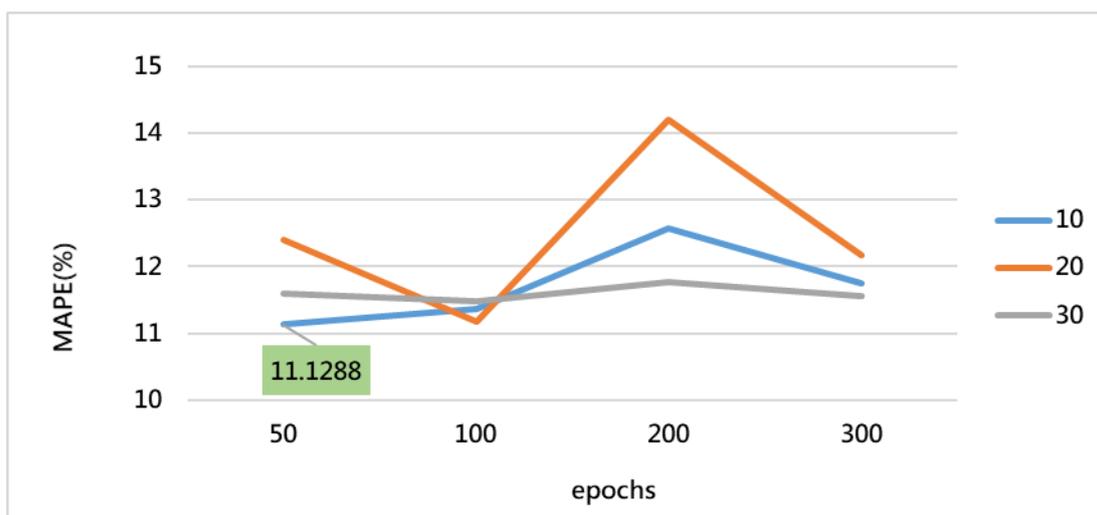


圖42、員林-卓乃潭第二班調整epochs、batch_size (模式1)

(4) 員林-卓乃潭第二班次(模式 2)

表 36 為模式 2，員林-卓乃潭區間第二班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 12.2993%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 12.6236%，因此選擇誤差最小之 12.2993% 模式做 epochs、batch_size 變化調整。

表36、模式2員林-卓乃潭第二班次

員林-卓乃潭第二班次			
	輸入層	隱藏層	MAPE
模式 2	16	50	12.2993
		100	13.3018
		200	13.4920
		300	12.5523
		400	13.6322
		500	12.6322

表37、加入隱藏層2變化

員林-卓乃潭第二班次				
	輸入層	隱藏層 1	隱藏層 2	MAPE
模式 2	16	50	10	13.6611
			20	14.4367
			30	12.6600
			40	12.6236
			50	13.3215

將誤差值最小之模式 12.2993%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 300，batch_size 為 10 的情況下誤差最小為 10.8914%，因此在模式 2 員林-卓乃潭第二班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=50，epochs=300，batch_size=10，MAPE 為 10.8914%。

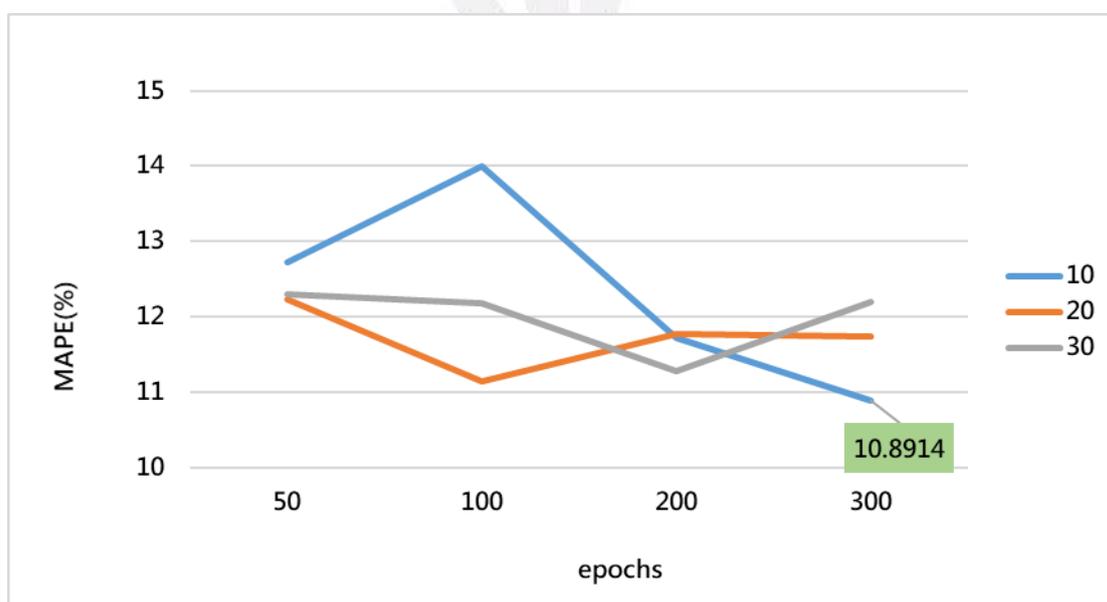


圖43、員林-卓乃潭第二班調整epochs、batch_size (模式2)

(5) 員林-卓乃潭第三班次(模式 1)

表 38 為模式 1，員林-卓乃潭區間第三班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 3.7364%，因此固定隱藏層 1，多加隱藏層 2 進行調整，

發現加入第二層隱藏層 MAPE 誤差值最小之模式為 3.7727%，因此選擇誤差最小之 3.7364% 模式做 epochs、batch_size 變化調整。

表38、模式1員林-卓乃潭第三班次

員林-卓乃潭第三班次			
模式 1	輸入層	隱藏層	MAPE
	15	50	4.1329
		100	4.6094
		200	4.4802
		300	4.7646
		400	3.7364
		500	4.0255

表39、加入隱藏層2變化

員林-卓乃潭第三班次				
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE
	15	400	50	3.8690
			100	4.2852
			200	3.7727
			300	4.1560
			400	4.4392

將誤差值最小之模式 3.7364%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 100，batch_size 為 10 的情況下誤差最小為 3.6786%，因此在模式 1 員林-卓乃潭第三班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=400，epochs=100，batch_size=10，MAPE 為 3.6786%。

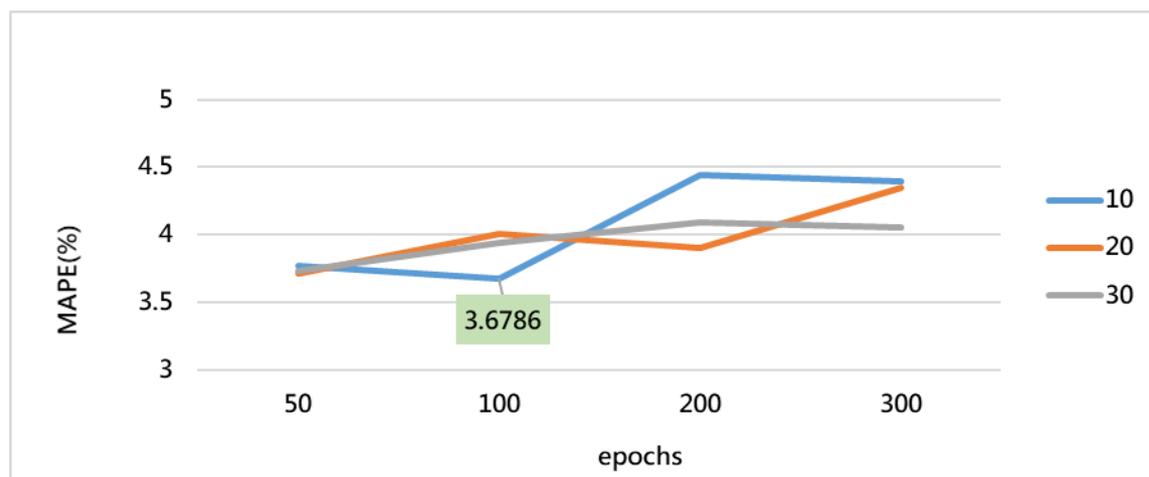


圖44、員林-卓乃潭第三班調整epochs、batch_size (模式1)

(6) 員林-卓乃潭第三班次(模式 2)

表 40 為模式 2，員林-卓乃潭區間第三班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 3.7121%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 3.7767%，因此選擇誤差最小之 3.7121% 模式做 epochs、batch_size 變化調整。

表40、模式1員林-卓乃潭第三班次

員林-卓乃潭第三班次			
模式 2	輸入層	隱藏層	MAPE
	16		50
100			3.8911
200			3.9382
300			3.8694
400			3.8379
500			3.7121

表41、加入隱藏層2變化

員林-卓乃潭第三班次				
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE
	16		500	50
100				3.8176
200				3.8216
300				3.7767
400				3.9300

將誤差值最小之模式 3.7121%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 3.7121%，因此在模式 2 員林-卓乃潭第三班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=500，epochs=50，batch_size=30，MAPE 為 3.7121%。

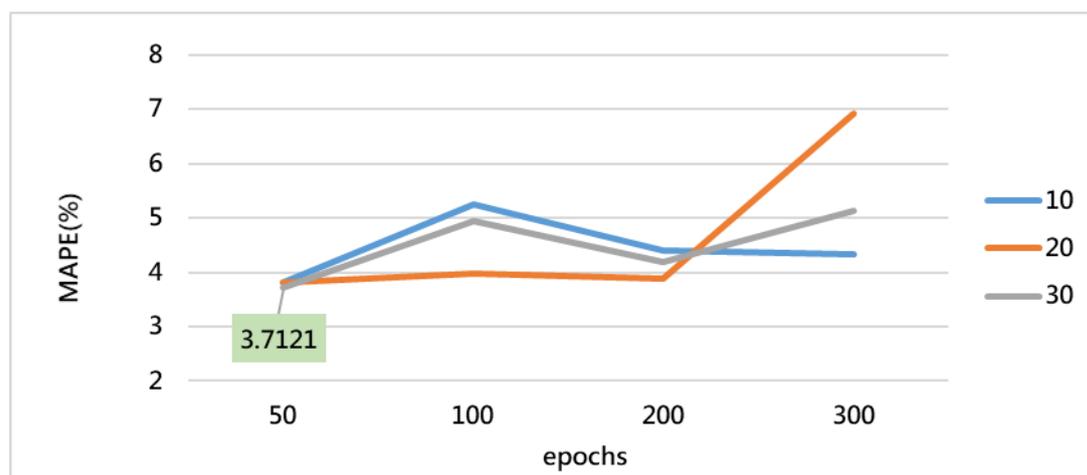


圖45、員林-卓乃潭第三班調整epochs、batch_size (模式2)

(7) 卓乃潭-員林第一班次(模式 1)

表 42 為模式 1，卓乃潭-員林區間第一班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 12.7621%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 12.7452%，因此選擇誤差最小之 12.7452% 模式做 epochs、batch_size 變化調整。

表42、模式2卓乃潭-員林第一班次

卓乃潭-員林第一班次			
模式 1	輸入層	隱藏層	MAPE
	16		50
100			12.7668
200			12.7677
300			12.7768
400			12.7684
500			12.7621

表43、加入隱藏層2變化

卓乃潭-員林第一班次				
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE
	16	500	100	12.7452
			200	12.7918
			300	12.8954
			400	12.8462
			500	12.7634

將誤差值最小之模式 12.7452%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 12.7452%，因此在模式 2 卓乃潭-員林第一班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=500，epochs=50，batch_size=30，MAPE 為 12.7452%。

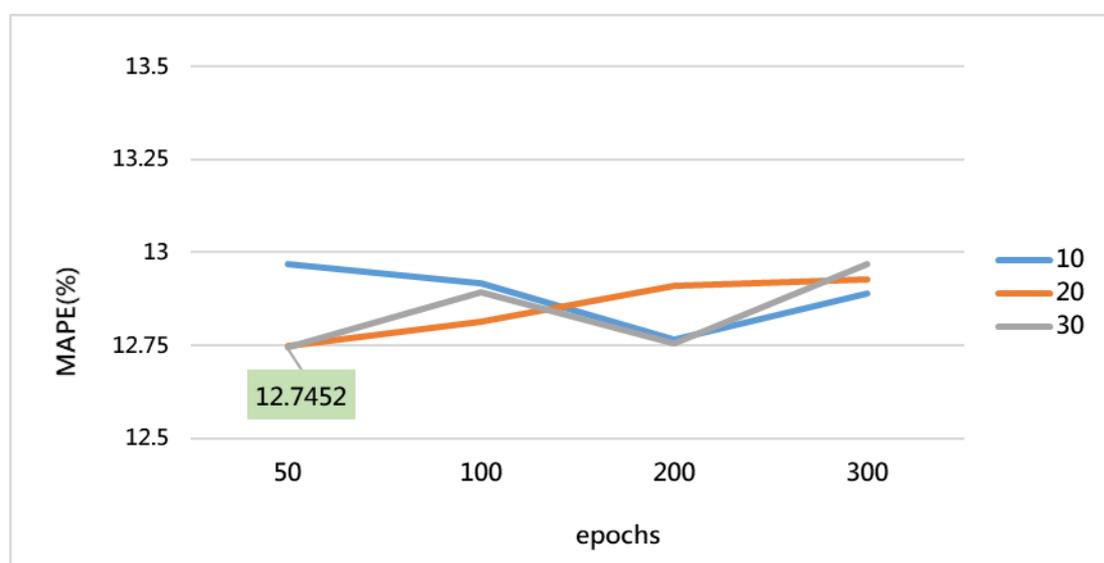


圖46、卓乃潭-員林第一班調整epochs、batch_size (模式1)

(8) 卓乃潭-員林第一班次(模式 2)

表 44 為模式 2，卓乃潭-員林區間第一班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 12.7463%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 12.7419%，因此選擇誤差最小之 12.7419% 模式做 epochs、batch_size 變化調整。

表44、模式2卓乃潭-員林第一班次

卓乃潭-員林第一班次			
模式 2	輸入層	隱藏層	MAPE

	16	50	12.7507
		100	12.7488
		200	12.7587
		300	12.7676
		400	12.7652
		500	12.7463

表45、加入隱藏層2變化

卓乃潭-員林第一班次				
	輸入層	隱藏層 1	隱藏層 2	MAPE
模式 2	16	500	100	12.7419
			200	12.7794
			300	12.7699
			400	12.7587
			500	12.7488

將誤差值最小之模式 12.7419%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 12.7419%，因此在模式 2 卓乃潭-員林第一班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=500，epochs=50，batch_size=30，MAPE 為 12.7419%。

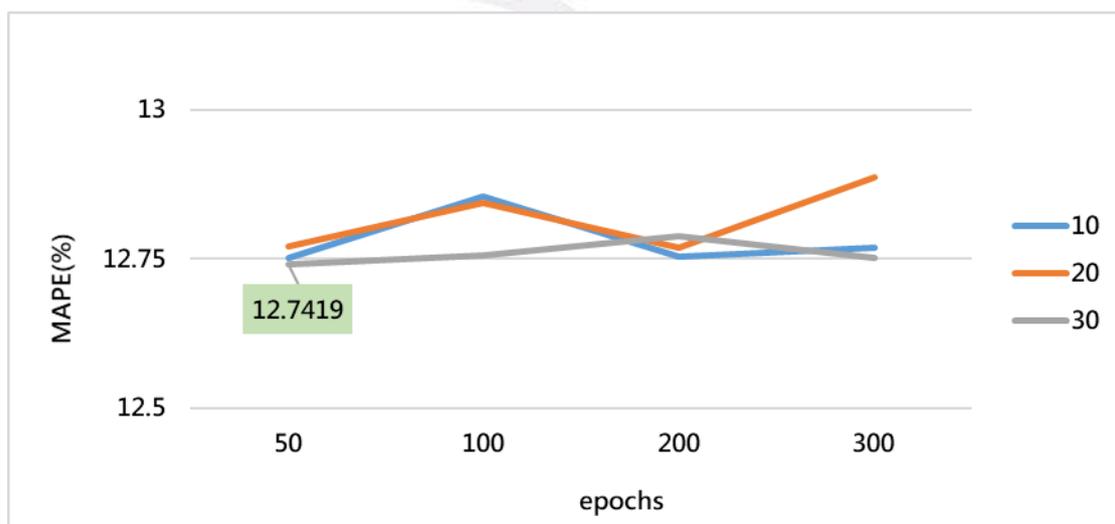


圖47、卓乃潭-員林第一班調整epochs、batch_size (模式2)

(9) 卓乃潭-員林第二班次(模式 1)

表 46 為模式 2，卓乃潭-員林區間第一班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 9.7839%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 9.9938%，因此選擇誤差最小之 9.7839% 模式做 epochs、batch_size 變化調整。



表46、模式1卓乃潭-員林第二班次

卓乃潭-員林第二班次				
模式 1	輸入層	隱藏層	MAPE	
	15		50	9.9974
			100	10.5723
			200	9.9975
			300	10.0295
			400	10.3787
			500	9.7839

表47、加入隱藏層2變化

卓乃潭-員林第二班次					
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE	
	15	500		100	9.9938
				200	10.3077
				300	10.5671
				400	11.3523
				500	10.7613

將誤差值最小之模式 9.7839%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 10 的情況下誤差最小為 9.2324%，因此在模式 1 卓乃潭-員林第二班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=500，epochs=50，batch_size=10，MAPE 為 9.2324%。

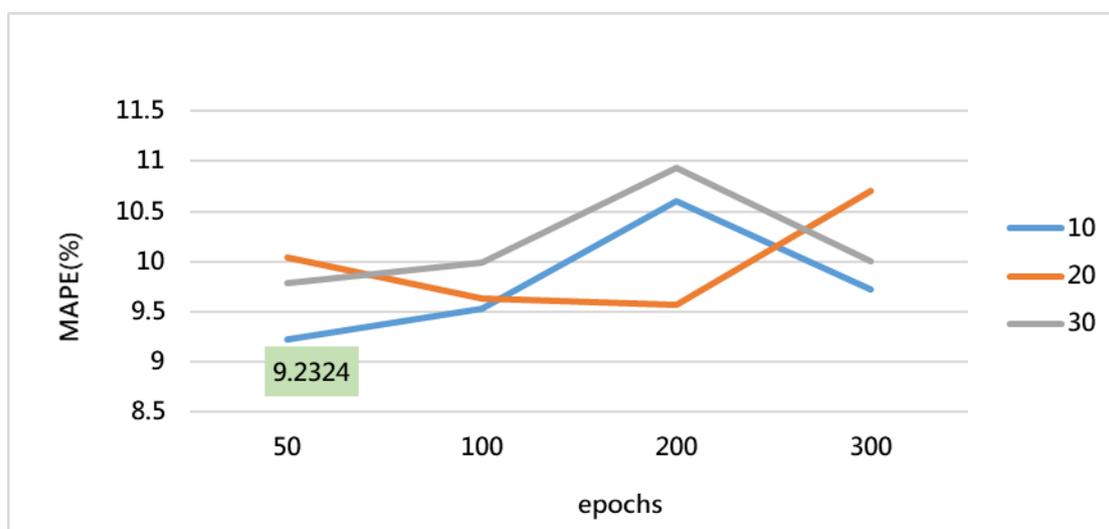


圖48、卓乃潭-員林第二班調整epochs、batch_size (模式1)

(10) 卓乃潭-員林第二班次(模式 2)

表 48 為模式 2，卓乃潭-員林區間第一班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 9.1213%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 9.6734%，因此選擇誤差最小之 9.1213% 模式做 epochs、batch_size 變化調整。

表48、模式2卓乃潭-員林第二班次

卓乃潭-員林第二班次				
模式 2	輸入層	隱藏層	MAPE	
	16		50	9.1749
			100	9.1213
			200	9.3303
			300	9.7488
			400	9.8798
			500	10.9342

表49、加入隱藏層2變化

卓乃潭-員林第二班次					
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE	
	16	100		100	9.7098
				200	9.6734
				300	10.5059
				400	10.5898
				500	9.9983

將誤差值最小之模式 9.1213%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 9.1213%，因此在模式 2 卓乃潭-員林第二班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=100，epochs=50，batch_size=10，MAPE 為 9.2324%。

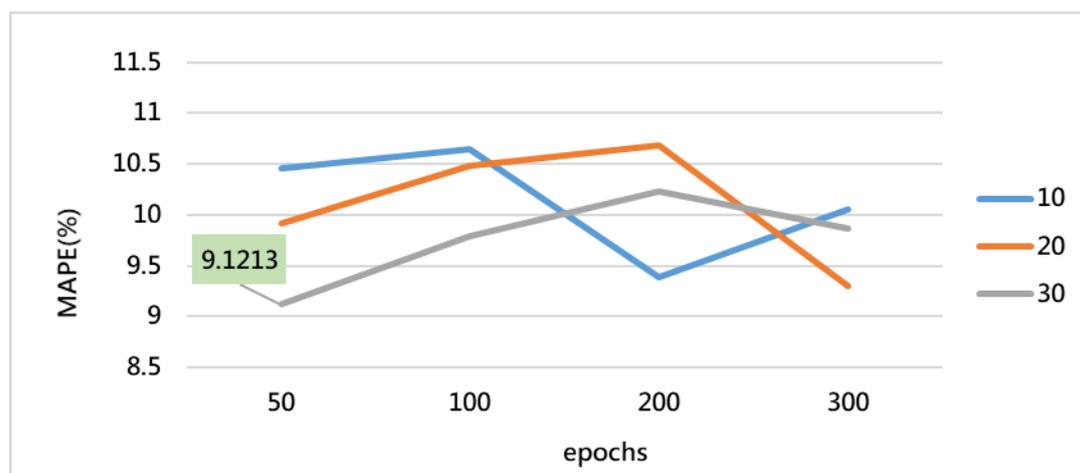


圖 49、卓乃潭-員林第二班調整 epochs、batch_size (模式 2)

(11) 卓乃潭-員林第三班次(模式 1)

表 50 為模式 1，卓乃潭-員林區間第三班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 4.2160%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 4.1684%，因此選擇誤差最小之 4.1684% 模式做 epochs、batch_size 變化調整。

表 50、模式 1 卓乃潭-員林第三班次

卓乃潭-員林第三班次			
模式 1	輸入層	隱藏層	MAPE
	15	15	50
100			4.2160
200			4.3027
300			4.2546
400			4.3648
500			4.3570

表 51、加入隱藏層 2 變化

卓乃潭-員林第三班次				
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE
	15	15	100	100
200				4.4678
300				4.2195
400				4.4639

			500	4.3483
--	--	--	-----	--------

將誤差值最小之模式 4.1684%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 20 的情況下誤差最小為 4.163%，因此在模式 1 卓乃潭-員林第三班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=100，epochs=50，batch_size=20，MAPE 為 4.163%。

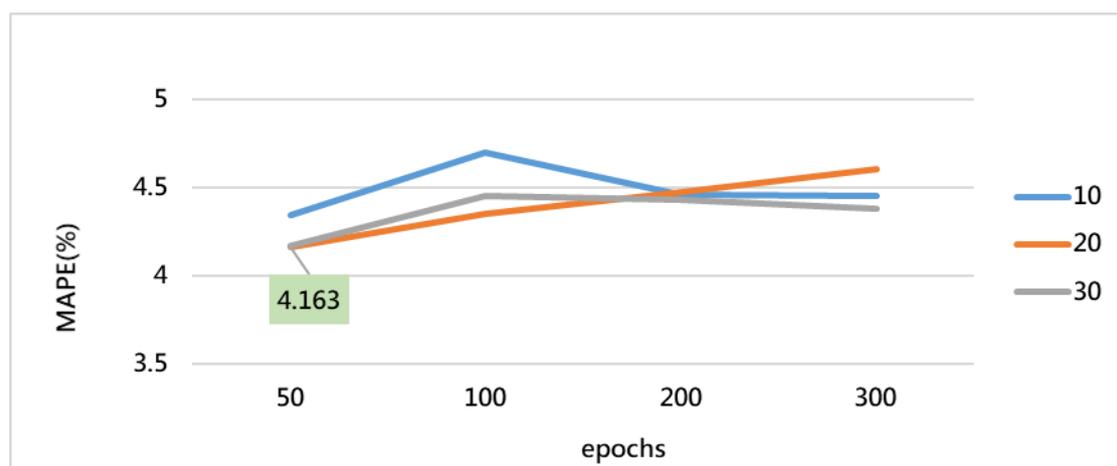


圖50、卓乃潭-員林第三班調整epochs、batch_size (模式1)

(12) 卓乃潭-員林第三班次(模式 2)

表 52 為模式 2，卓乃潭-員林區間第三班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 4.1276%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 4.1638%，因此選擇誤差最小之 4.1276% 模式做 epochs、batch_size 變化調整。

表52、模式2卓乃潭-員林第三班次

卓乃潭-員林第三班次			
模式 2	輸入層	隱藏層	MAPE
	16	50	4.2626
		100	4.1276
		200	4.2606
		300	4.3554
		400	4.7587
		500	4.3514

表53、加入隱藏層2變化

卓乃潭-員林第三班次				
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE
	16	100	100	4.2840
			200	4.2360
			300	4.1638
			400	4.6078
			500	4.3410

將誤差值最小之模式 4.1276%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 4.1276%，因此在模式 2 卓乃潭-員林第三班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=100，epochs=50，batch_size=30，MAPE 為 4.1276%。

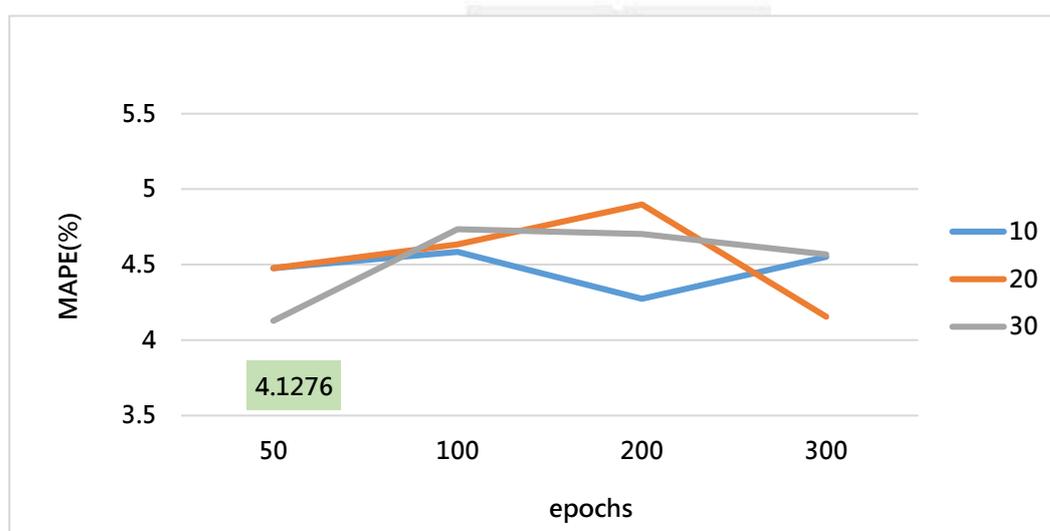


圖51、卓乃潭-員林第三班調整epochs、batch_size (模式2)

3. 卓乃潭-田中預測模式參數調整

(1) 卓乃潭-田中第一班次(模式 1)

表 54 為模式 1，卓乃潭-田中第一班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 14.1294%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 14.1275%，因此選擇誤差最小之 14.1275% 模式做 epochs、batch_size 變化調整。

表54、模式1卓乃潭-田中第一班次

卓乃潭-田中第一班次				
模式 1	輸入層	隱藏層	MAPE	
	15		50	16.4950
			100	17.0238
			200	15.1407
			300	14.8286
			400	14.1294
			500	14.1302

表55、加入隱藏層2變化

卓乃潭-田中第一班次					
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE	
	15	400		50	14.7828
				100	14.1275
				200	14.3617
				300	14.1472
				400	14.4393

將誤差值最小之模式 14.1275%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 14.1275%，因此在模式 1 卓乃潭至田中第一班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=400，隱藏層 2=100，epochs=50，batch_size=30，MAPE 為 14.1275%。

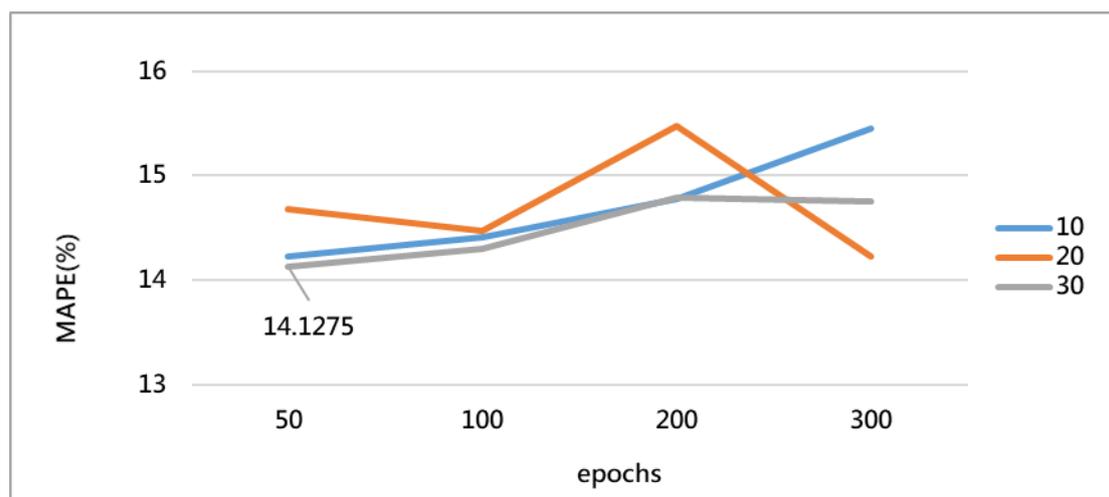


圖52、(卓乃潭-田中)第一班調整epochs、batch_size(模式1)

(2) 卓乃潭-田中第一班次(模式 2)

表 56 為模式 2，卓乃潭-田中第一班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 14.2687%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 14.1271%，因此選擇誤差最小之 14.1271% 模式做 epochs、batch_size 變化調整。

表56、模式2卓乃潭-田中第一班次

卓乃潭-田中第一班次			
模式 2	輸入層	隱藏層	MAPE
	16	16	50
100			14.2687
200			14.6857
300			14.6225
400			14.5115
500			14.5150

表57、加入隱藏層2變化

卓乃潭-田中第一班次				
	輸入層	隱藏層 1	隱藏層 2	MAPE
模式 2	16	100	20	17.5933
			40	14.1271
			60	15.8485
			80	14.6742
			100	15.2997

將誤差值最小之模式 14.1271%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 14.1271%，因此在模式 2 卓乃潭至田中第一班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=100，隱藏層 2=40，epochs=50，batch_size=30，MAPE 為 14.1271%。

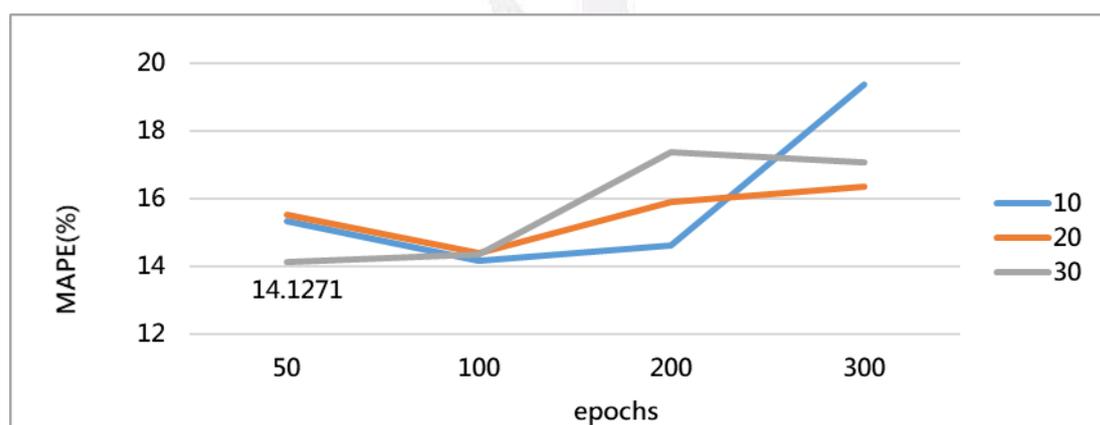


圖53、(卓乃潭-田中)第一班調整epochs、batch_size(模式2)

(3) 卓乃潭-田中第二班次(模式 1)

表 58 為模式 1，卓乃潭-田中第二班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 16.7714%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 16.4301%，因此選擇誤差最小之 16.4301% 模式做 epochs、batch_size 變化調整。

表58、模式1卓乃潭-田中第二班次

卓乃潭-田中第二班次			
模式 1	輸入層	隱藏層	MAPE
	15	50	16.7714
		100	16.8117
		200	16.9213
		300	17.4486
		400	17.5303
		500	17.5828

表59、加入隱藏層2變化

卓乃潭-田中第二班次				
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE
	15	50	10	16.5022
			20	16.4301
			30	17.7940
			40	17.3599
			50	17.2103

將誤差值最小之模式 16.4301%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 16.4301%，因此在模式 1 卓乃潭至田中第二班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=50，隱藏層 2=20，epochs=50，batch_size=30，MAPE 為 16.4301%。

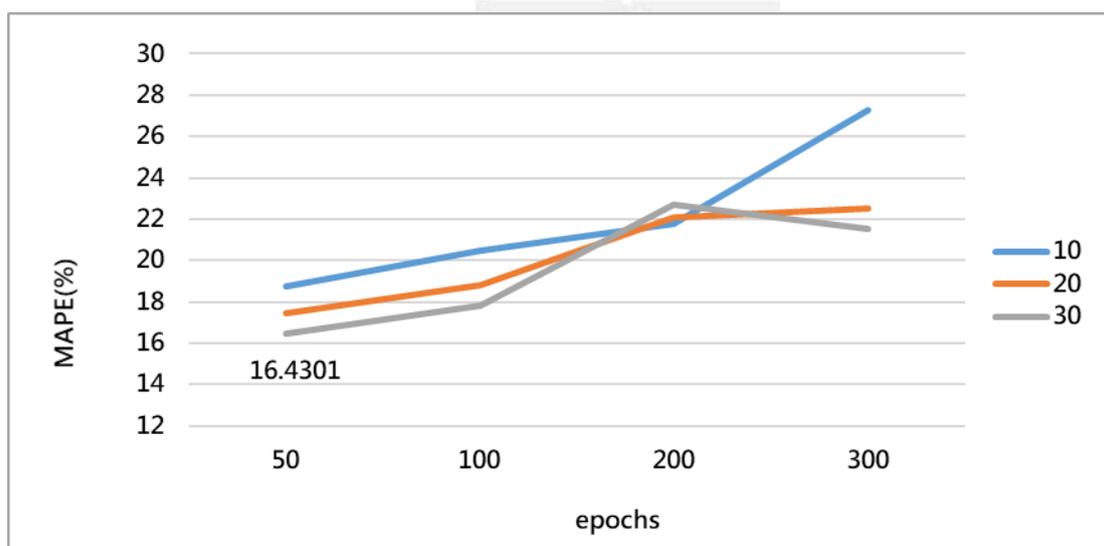


圖 55、(卓乃潭-田中)第二班調整 epochs、batch_size(模式 1)

(4) 卓乃潭-田中第二班次(模式 2)

表 60 為模式 2，卓乃潭-田中第班二次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 17.1285%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 17.6149%，因此選擇誤差最小之 17.1285% 模式做 epochs、batch_size 變化調整。

表60、模式2卓乃潭-田中第二班次

卓乃潭-田中第二班次				
模式 2	輸入層	隱藏層	MAPE	
	16		50	17.9227
			100	18.5021
			200	18.1356
			300	17.1285
			400	21.3409
			500	18.6218

表61、加入隱藏層2變化

卓乃潭-田中第二班次					
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE	
	16	300		50	17.6472
				100	26.9878
				150	19.0321
				200	20.8130
				250	20.9087
				300	17.6149

將誤差值最小之模式 17.1285%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 17.1285%，因此在模式 2 卓乃潭至田中第二班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=300，epochs=50，batch_size=30，MAPE 為 17.1285%。

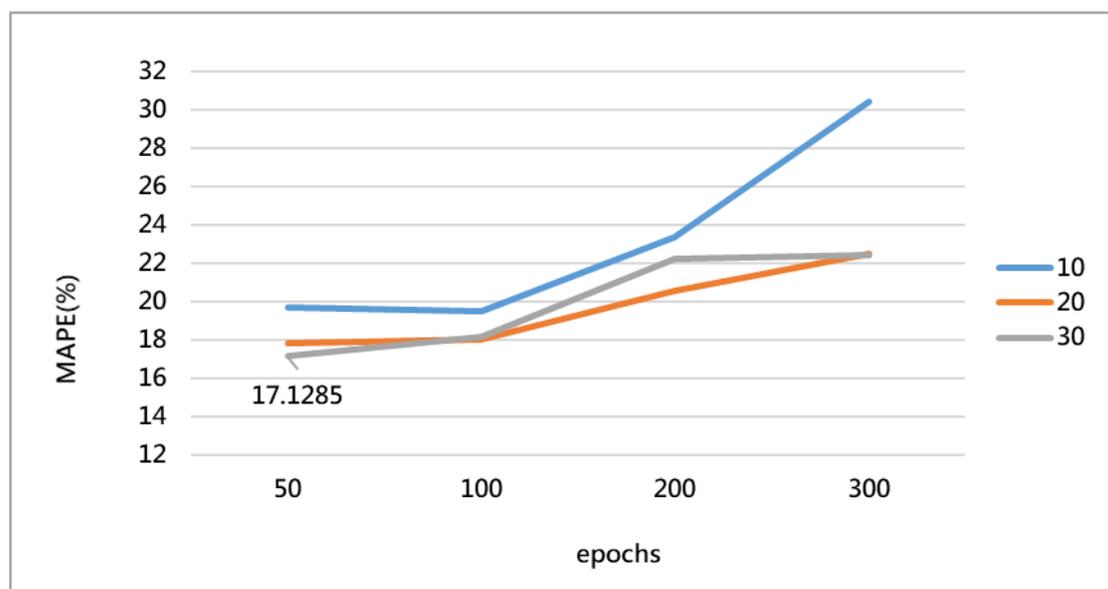


圖56、(卓乃潭-田中)第二班調整epochs、batch_size(模式2)

(5) 卓乃潭-田中第三班次(模式 1)

表 62 為模式 1，卓乃潭-田中第三班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 11.7365%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 12.4379%，因此選擇誤差最小之 11.7365% 模式做 epochs、batch_size 變化調整。

表62、模式1卓乃潭-田中第三班次

卓乃潭-田中第三班次			
	輸入層	隱藏層	MAPE
模式 1	15	50	13.1594
		100	12.3816
		200	12.7055
		300	11.7365
		400	13.1269
		500	13.6769

表63、加入隱藏層2變化

卓乃潭-田中第三班次				
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE
		15	300	50
	100			12.4379
	150			12.5160
	200			12.9044
	250			14.5534
	300			13.1845

將誤差值最小之模式 11.7365%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 100，batch_size 為 20 的情況下誤差最小為 11.7260%，因此在模式 1 卓乃潭至田中第三班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=300，epochs=100，batch_size=20，MAPE 為 11.7260%。

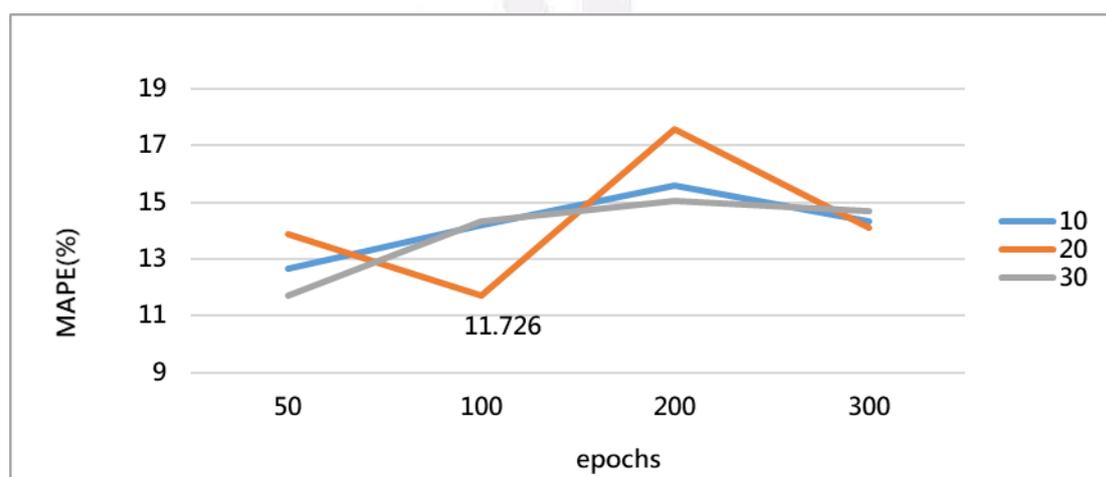


圖57、(卓乃潭-田中)第三班調整epochs、batch_size(模式1)

(6) 卓乃潭-田中第三班次(模式 2)

表 64 為模式 1，卓乃潭-田中第三班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 13.2581%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 14.1050%，因此選擇誤差最小之 13.2581% 模式做 epochs、batch_size 變化調整。

表64、模式2卓乃潭-田中第三班次

卓乃潭-田中第三班次				
模式 2	輸入層	隱藏層	MAPE	
	16		50	13.2581
			100	14.9004
			200	13.8853
			300	14.9080
			400	15.1076
			500	14.4831

表65、加入隱藏層2變化

卓乃潭-田中第三班次					
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE	
	16	50		10	14.3970
				20	15.7786
				30	16.1481
				40	14.1050
				50	16.4514

將誤差值最小之模式 13.2581%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 300，batch_size 為 20 的情況下誤差最小為 13.0249%，因此在模式 2 卓乃潭至田中第三班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=50，epochs=300，batch_size=20，MAPE 為 13.0249%。

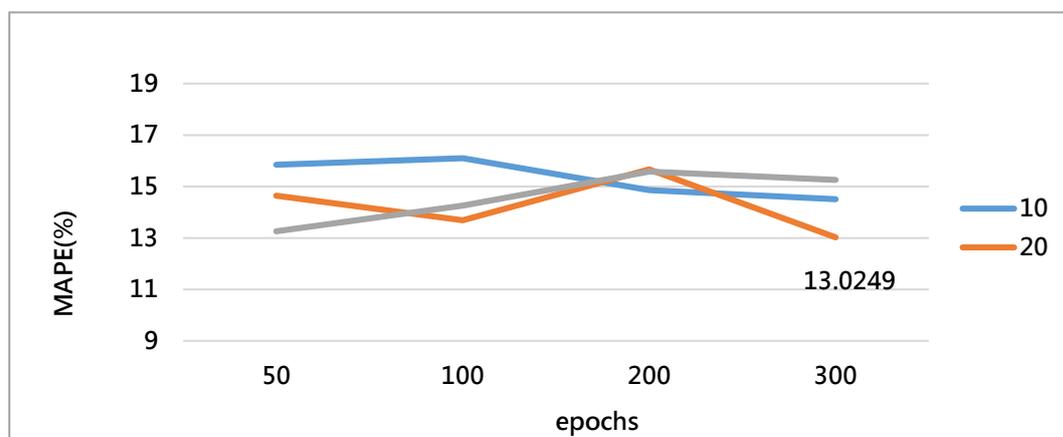


圖58、(卓乃潭-田中)第三班調整epochs、batch_size(模式2)

(7) 田中-卓乃潭第一班次(模式 1)

表 66 為模式 1，田中-卓乃潭第一班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 17.7243%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 17.5804%，因此選擇誤差最小之 17.5804% 模式做 epochs、batch_size 變化調整。

表66、模式1田中-卓乃潭第一班次

田中-卓乃潭第一班次				
模式 1	輸入層	隱藏層	MAPE	
	15		50	21.0465
			100	19.3238
			200	18.3109
			300	17.7824
			400	17.7243
			500	18.4017

表67、加入隱藏層2變化

田中-卓乃潭第一班次					
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE	
	15	400		50	17.5804
				100	18.7513
				200	19.0970
				300	18.3882
				400	20.6975

將誤差值最小之模式 17.5804%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 17.5804%，因此在模式 1 田中至卓乃潭第一班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=400，epochs=50，batch_size=30，MAPE 為 17.5804%。

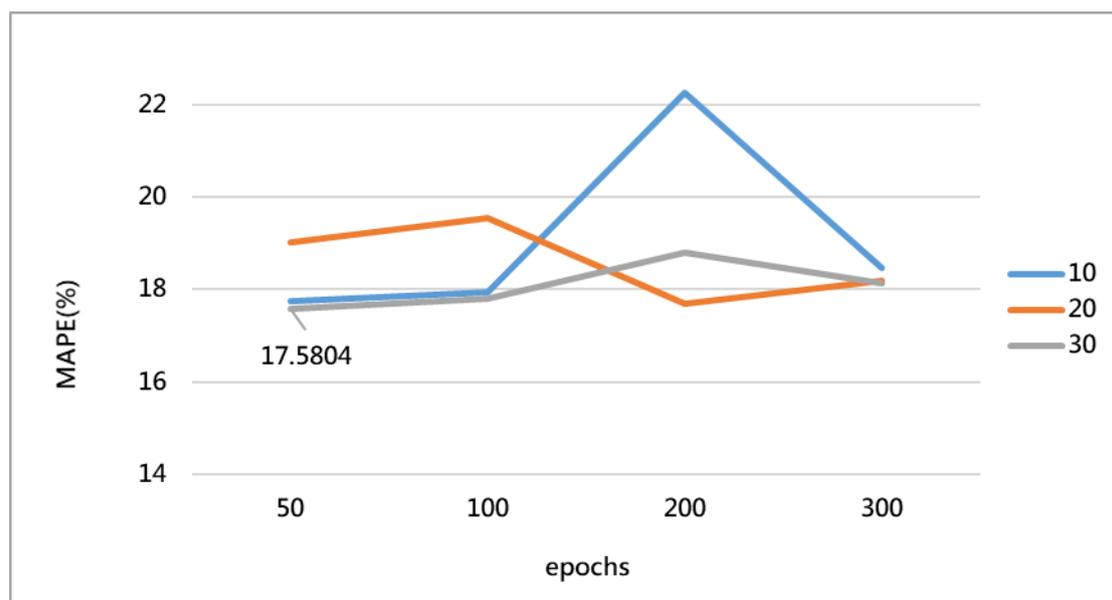


圖59、(田中-卓乃潭)第一班調整epochs、batch_size(模式1)

(8) 田中-卓乃潭第一班次(模式2)

表 68 為模式 2，田中-卓乃潭第一班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 29.2683%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 27.9935%，因此選擇誤差最小之 27.9935% 模式做 epochs、batch_size 變化調整。

表68、模式1田中-卓乃潭第一班次

田中-卓乃潭第一班次			
	輸入層	隱藏層	MAPE
模式 2	16	50	34.6145
		100	35.0183
		200	32.1884
		300	29.2683
		400	30.7752
		500	32.8315

表69、加入隱藏層2變化

田中-卓乃潭第一班次				
	輸入層	隱藏層 1	隱藏層 2	MAPE
模式 2	16	300	50	27.9935
			100	30.9819
			150	30.4351
			200	28.1465
			250	31.2828
			300	28.1176

將誤差值最小之模式 27.9935%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀察參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 27.9935%，因此在模式 2 田中至卓乃潭第一班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=300，epochs=50，batch_size=30，MAPE 為 27.9935%。

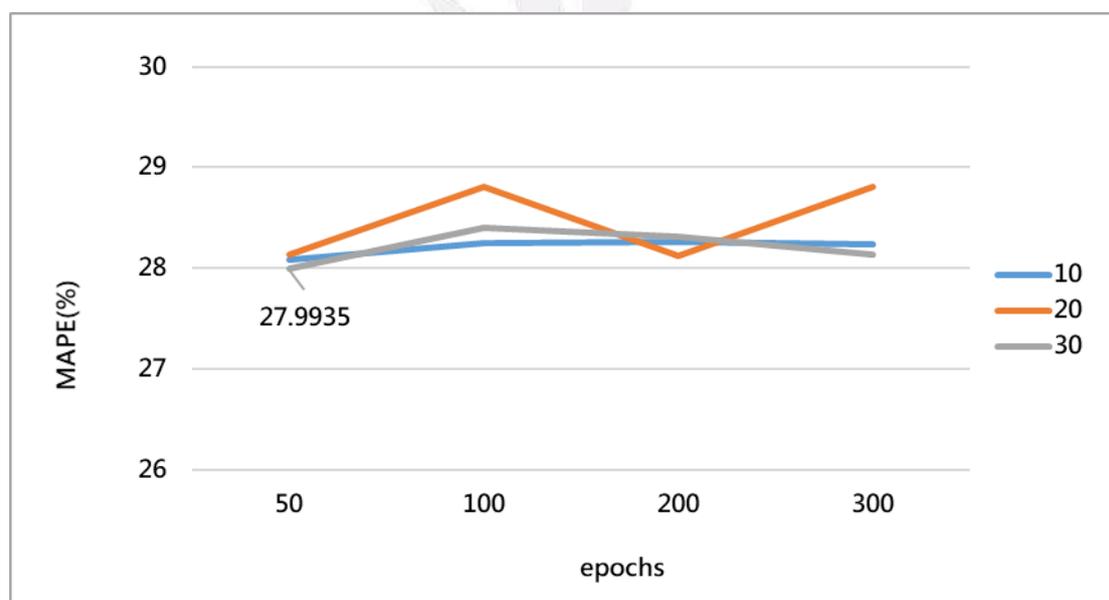


圖60、(田中-卓乃潭)第一班調整epochs、batch_size(模式1)

(9) 田中-卓乃潭第二班次(模式 1)

表 70 為模式 1，田中-卓乃潭第二班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 14.5250%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 14.6231%，因此選擇誤差最小之 14.5250% 模式做 epochs、batch_size 變化調整。

表70、模式1田中-卓乃潭第二班次

田中-卓乃潭第二班次			
模式 1	輸入層	隱藏層	MAPE
	15	15	50
100			14.9106
200			15.2465
300			14.7705
400			15.3186
500			15.4585

表71、加入隱藏層2變化

田中-卓乃潭第二班次				
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE
	15	15	400	50
100				14.9678
200				14.8314
300				14.6231
400				14.6955

將誤差值最小之模式 14.5250%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀察參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 17.5804%，因此在模式 1 田中-卓乃潭第二班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=50，epochs=50，batch_size=30，MAPE 為 17.5804%。

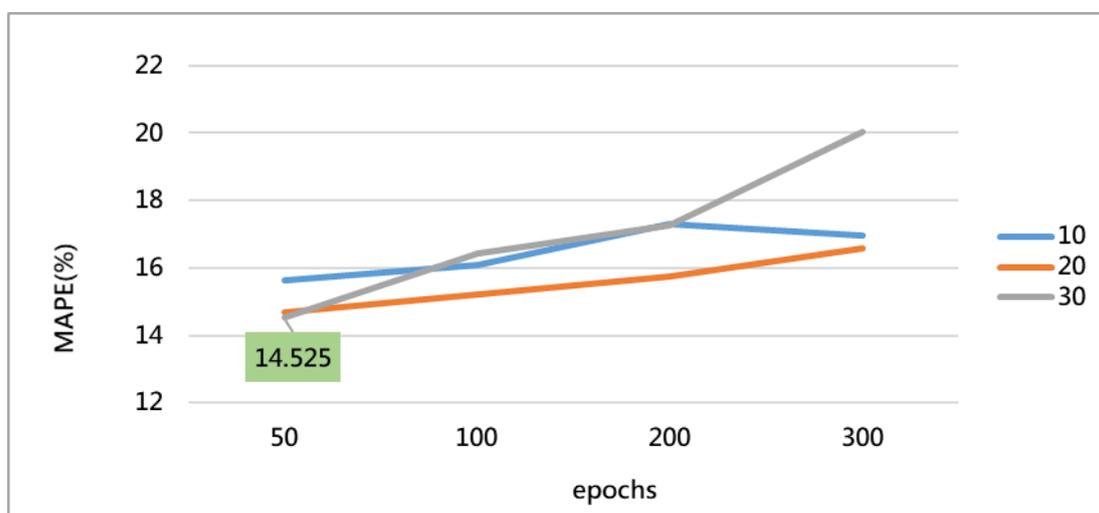


圖61、(田中-卓乃潭)第二班調整epochs、batch_size(模式1)

(10) 田中-卓乃潭第二班次(模式 2)

表 72 為模式 2，田中-卓乃潭第二班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 15.1479%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 16.1180%，因此選擇誤差最小之 15.1479% 模式做 epochs、batch_size 變化調整。

表72、模式1田中-卓乃潭第二班次

田中-卓乃潭第二班次				
模式 2	輸入層	隱藏層	MAPE	
	16		50	15.5225
			100	17.3141
			200	15.2908
			300	15.7076
			400	15.1479
			500	15.6604

表73、加入隱藏層2變化

田中-卓乃潭第二班次					
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE	
	16	400		50	16.8165
				100	16.1180
				200	16.8440
				300	16.2651
				400	16.2083

將誤差值最小之模式 15.1479%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 13.0249%，因此在模式 2 田中-卓乃潭第一班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=400，epochs=300，batch_size=20，MAPE 為 13.0249%。

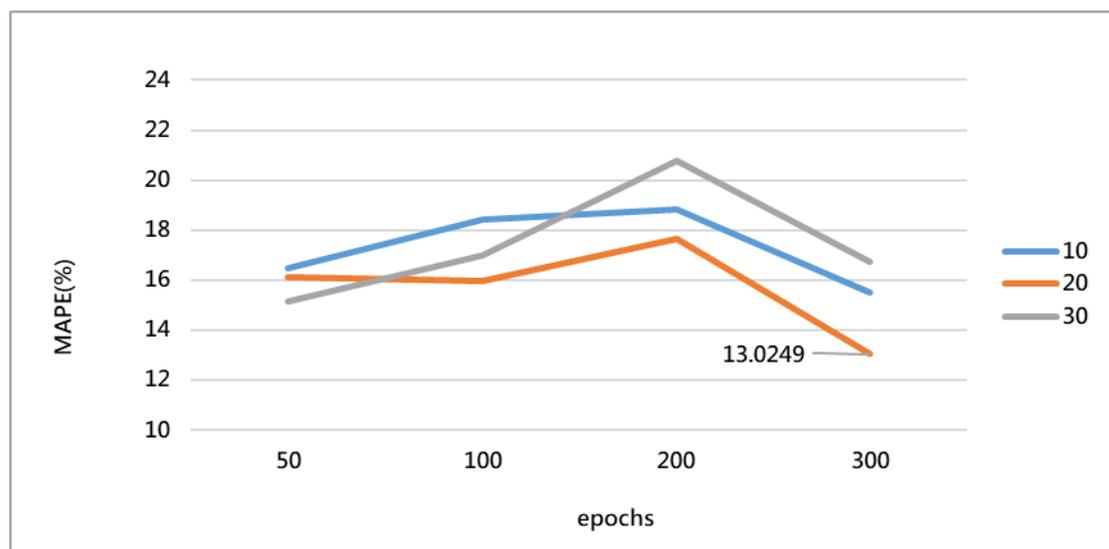


圖62、(田中-卓乃潭)第二班調整epochs、batch_size(模式2)

(11) 田中-卓乃潭第三班次(模式 1)

表 74 為模式 1，田中至卓乃潭第三班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 19.9251%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 20.0931%，因此選擇誤差最小之 19.9251% 模式做 epochs、batch_size 變化調整。

表74、模式1田中-卓乃潭第三班次

田中-卓乃潭第三班次			
	輸入層	隱藏層	MAPE
模式 1	15	50	20.2795
		100	19.9251
		200	19.9934
		300	20.1200
		400	20.2794
		500	20.0764

表75、加入隱藏層2變化

田中-卓乃潭第三班次				
	輸入層	隱藏層 1	隱藏層 2	MAPE
模式 1	15	400	50	20.1783
			100	20.0931
			200	20.1718
			300	20.0973
			400	20.3306

將誤差值最小之模式 19.9251%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 200，batch_size 為 20 的情況下誤差最小為 19.7964%，因此在模式 1 田中-卓乃潭第三班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=100，epochs=200，batch_size=20，MAPE 為 19.7964%。

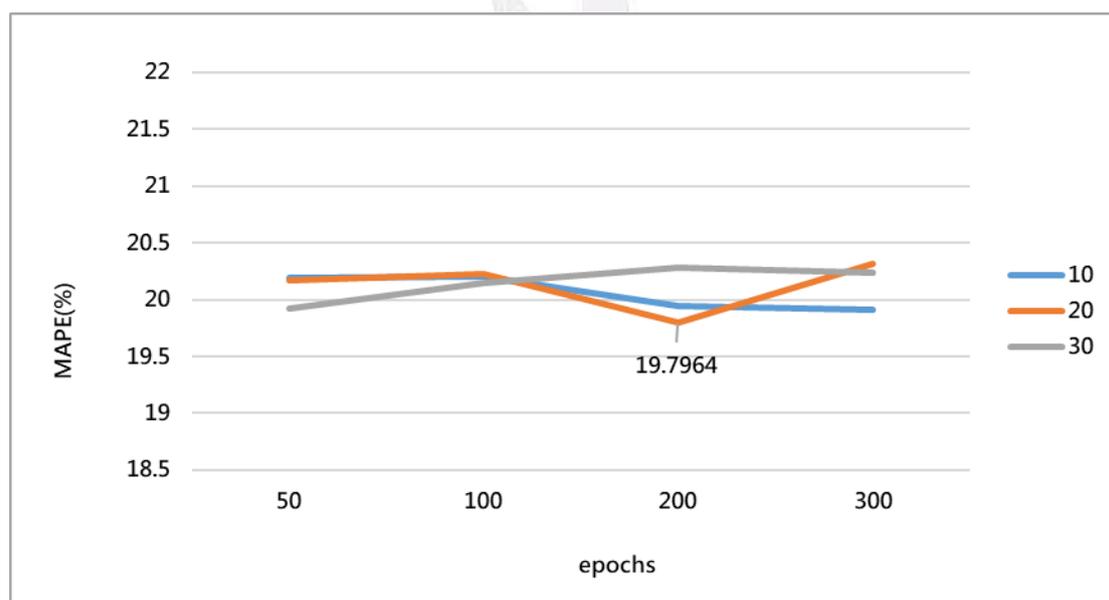


圖63、(田中-卓乃潭)第三班調整epochs、batch_size(模式1)

(12) 田中-卓乃潭第三班次(模式 2)

表 76 為模式 2，田中-卓乃潭第三班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 20.0863%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 20.0153%，因此選擇誤差最小之 20.0153% 模式做 epochs、batch_size 變化調整。

表76、模式1田中-卓乃潭第三班次

田中-卓乃潭第三班次				
模式 2	輸入層	隱藏層	MAPE	
	16		50	20.3855
			100	20.2079
			200	20.1538
			300	20.0863
			400	20.2555
			500	20.2672

表77、加入隱藏層2變化

田中-卓乃潭第三班次				
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE
	16	300	50	20.0153
			100	20.4609
			150	20.1743
			200	20.2148
			250	20.1490
			300	20.1292

將誤差值最小之模式 20.0153%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 200，batch_size 為 20 的情況下誤差最小為 19.7964%，因此在模式 2 田中-卓乃潭第三班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=300，隱藏層 2=50，epochs=200，batch_size=20，MAPE 為 19.7073%。

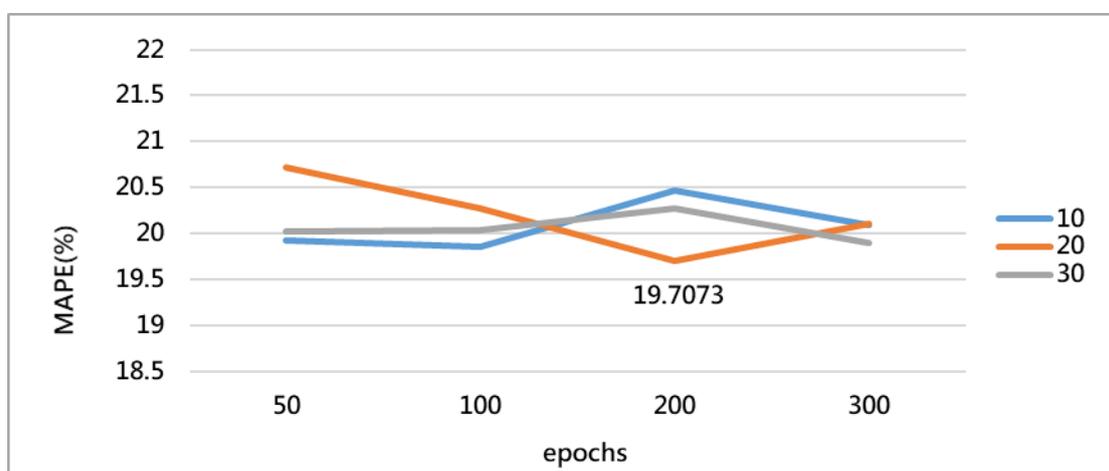


圖64、(田中-卓乃潭)第三班調整epochs、batch_size(模式2)

4. 田中-車埕預測模式參數調整

(1) 田中-車程第一班次(模式 1)

表 78 為多變數模 1，田中-車程第一班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=20 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 14.2178%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 14.4105%，因此選擇誤差最小之為 14.2178% 模式做 epochs、batch_size 變化調整。

田中-車程第一班次				
模式 1	輸入層	隱藏層	MAPE	
	15		50	15.6148
			100	16.2884
			200	14.7610
			300	17.3543
			400	14.2178
			500	14.3098

表78、模式1田中-車程第一班次

田中-車程第一班次					
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE	
	15	400		50	14.5629
				100	15.7185
				200	14.5754
				300	14.4105
				400	14.6655

表79、加入隱藏層2變化

將誤差值最小之模式 14.2178%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 20 的情況下誤差最小為 14.1277%，因此在模式 2 田中-車程第一班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=400，epochs=50，batch_size=20，MAPE 為 14.1277%。

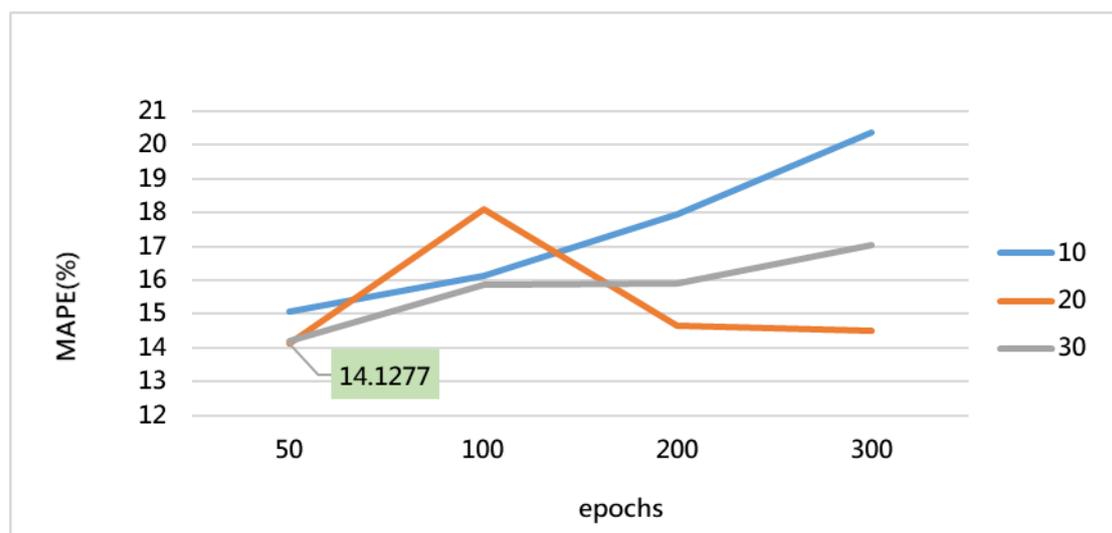


圖65、田中-車程第二班參數調整epochs、batch_size (模式1)

(2) 田中-車程第一班次(模式 2)

表 80 為多變數模 2，田中-車程第一班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 14.1275%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 14.1578%，因此選擇誤差最小之為 14.1275% 模式做 epochs、batch_size 變化調整。

表80、模式2田中-車程第一班次

田中-車程第一班次			
模式 2	輸入層	隱藏層	MAPE
	16	16	50
100			14.9126
200			14.8636
300			14.6248
400			14.1275
500			14.2968

表81、加入隱藏層2變化

田中-車程第一班次				
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE
	16	400	50	14.1578
			100	14.6954
			200	14.9070
			300	15.0880
			400	15.3050

將誤差值最小之模式 14.1275%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 14.1275%，因此在模式 2 田中-車程第一班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=400，epochs=50，batch_size=30，MAPE 為 14.1275%。

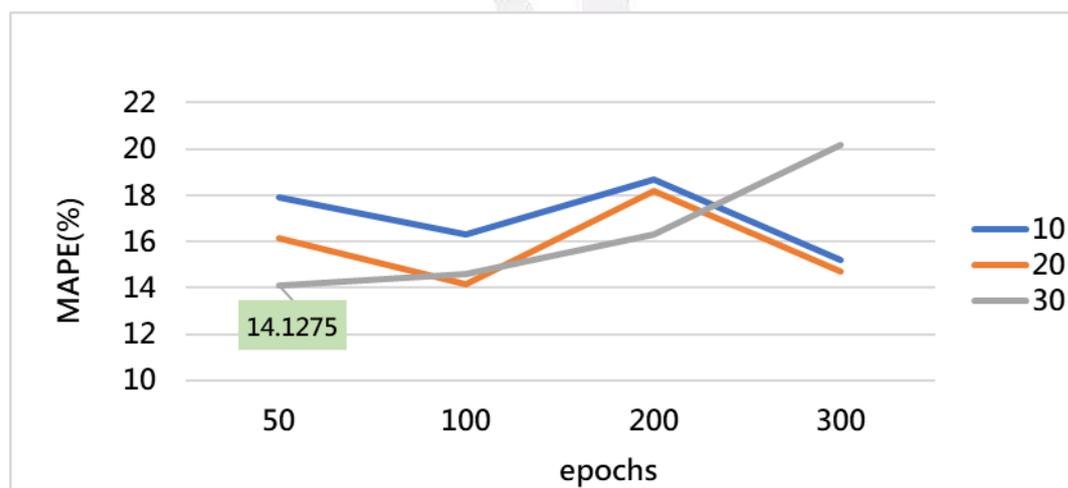


圖66、田中-車程第一班參數調整epochs、batch_size (模式2)

(3) 田中-車程第二班次(模式 1)

表 82 為多變數模 1，田中-車程第二班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 6.1763%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 6.1573%，因此選擇誤差最小之為 6.1573% 模式做 epochs、batch_size 變化調整。

表82、模式1田中-車程第二班次

田中-車程第二班次			
模式 1	輸入層	隱藏層	MAPE
	15	50	6.2058
		100	6.2880
		200	6.1846
		300	6.1955
		400	6.1763
		500	6.2905

表83、加入隱藏層2變化

田中-車程第二班次				
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE
	15	400	50	6.1573
			100	6.2163
			200	6.4309
			300	6.2500
			400	6.2973

將誤差值最小之模式 6.1573%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 6.1573%，因此在模式 1 田中-車程第二班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=400，epochs=50，batch_size=30，MAPE 為 6.1573%。

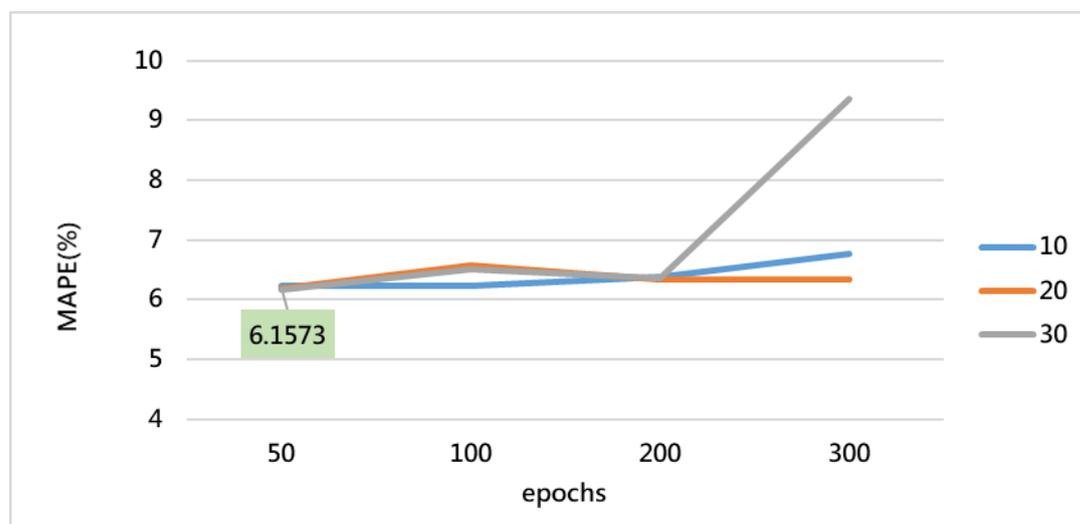


圖67、田中-車程第二班參數調整epochs、batch_size (模式1)

(4) 田中-車程第二班次(模式 2)

表 84 為模式 2，田中-車程第二班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 6.1686%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 6.1965，因此選擇誤差最小之為 6.1686% 模式做 epochs、batch_size 變化調整。

表84、模式2田中-車程第二班次

田中-車程第二班次			
模式 2	輸入層	隱藏層	MAPE
	16	50	6.1686
		100	6.4572
		200	6.1773
		300	6.3454
		400	6.2115
		500	6.2487

表85、加入隱藏層2變化

田中-車程第二班次				
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE
	16	50	10	6.1965
			20	6.2201
			30	6.2483
			40	6.3142
			50	6.2116

將誤差值最小之模式 6.1686%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 6.1686%，因此在模式 2 田中-車程第二班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=50，epochs=50，batch_size=30，MAPE 為 6.1686%。

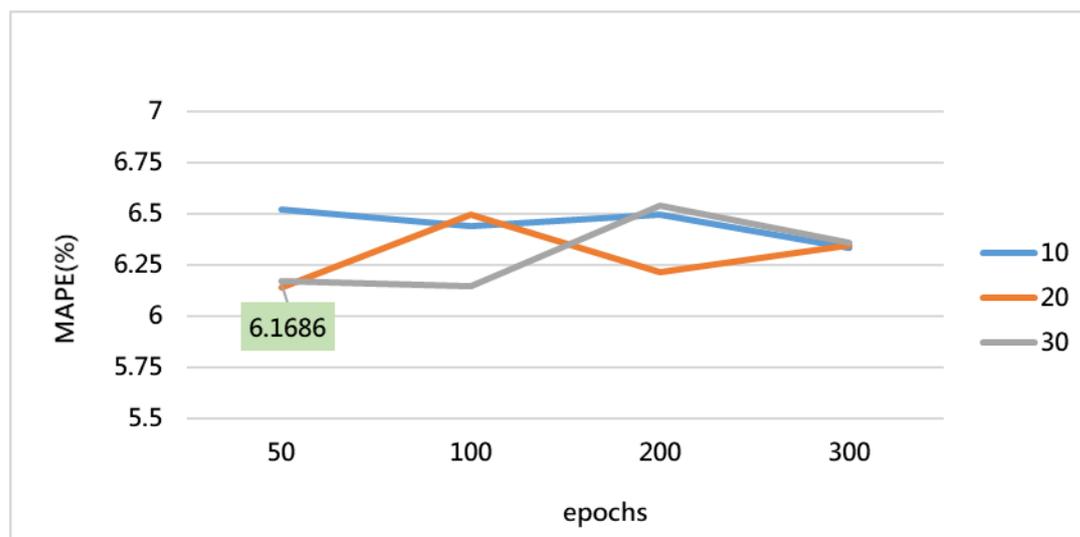


圖68、田中-車程第二班參數調整epochs、batch_size (模式2)

(5) 田中-車程第三班次(模式 1)

表 86 為多變數模 1，田中-車程第三班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 10.1100%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 10.8453%，因此選擇誤差最小之為 10.1100% 模式做 epochs、batch_size 變化調整。

表86、模式1田中-車程第三班次

田中-車程第三班次			
	輸入層	隱藏層	MAPE
模式 1	15	50	11.7757
		100	10.1100
		200	12.4610
		300	12.0218
		400	11.3516
		500	11.7518

表87、加入隱藏層2變化

田中-車程第三班次				
	輸入層	隱藏層 1	隱藏層 2	MAPE
模式 1	15	100	20	11.0110
			40	11.0824
			60	13.6630
			80	10.8453
			100	12.3985

將誤差值最小之模式 10.1100%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 10.1100%，因此在模式 1 田中-車程第三班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=100，epochs=50，batch_size=30，MAPE 為 10.1100%。

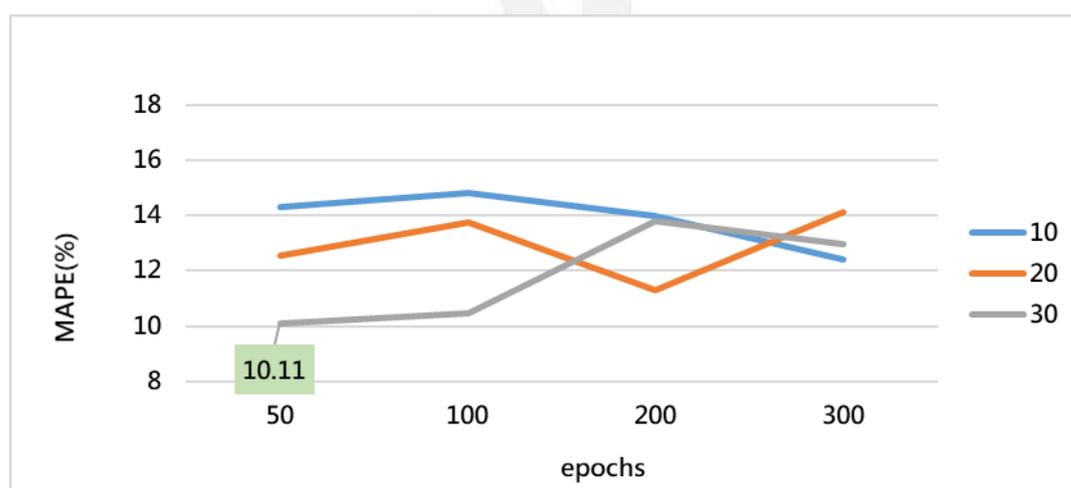


圖69、田中-車程第三班參數調整epochs、batch_size (模式1)

(6) 田中-車程第三班次(模式 2)

表 88 為多變數模 2，田中-車程第三班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 10.0359%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 10.1972%，因此選擇誤差最小之為 10.0359% 模式做 epochs、batch_size 變化調整。

表88、模式2田中-車程第三班次

田中-車程第三班次			
模式 2	輸入層	隱藏層	MAPE
	16	50	10.0359
		100	12.0205
		200	11.6984
		300	10.5354
		400	13.0338
		500	12.5532

表89、加入隱藏層2變化

田中-車程第三班次				
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE
	16	50	10	13.2489
			20	10.7506
			30	10.1972
			40	11.8773
			50	10.7673

將誤差值最小之模式 10.0359%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 10.0359%，因此在模式 2 田中-車程第三班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=50，epochs=50，batch_size=30，MAPE 為 10.0359%。

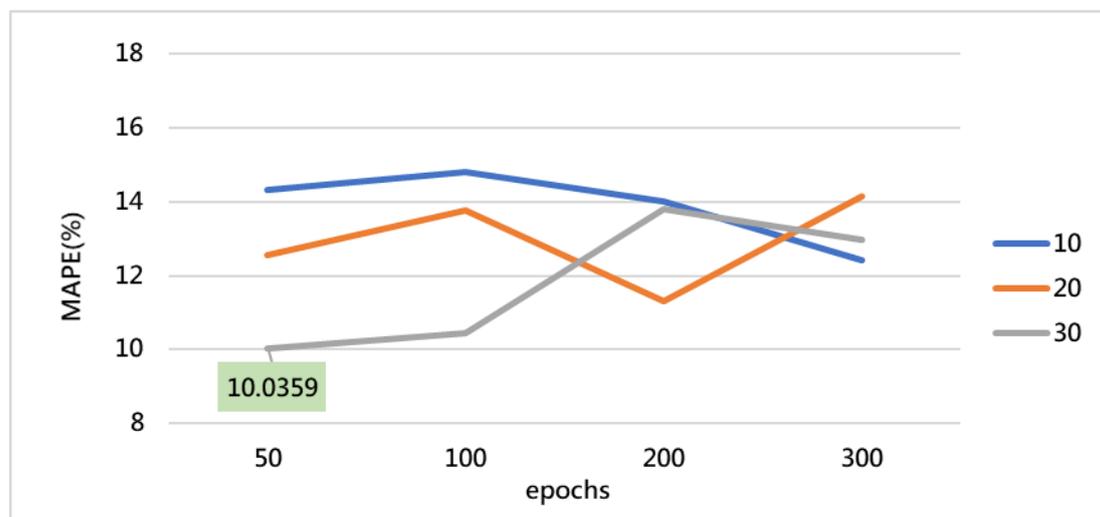


圖70、田中-車程第三班參數調整epochs、batch_size (模式2)

(7) 車程-田中第一班次(模式 1)

表 90 為多變數模 1，車程-田中第一班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 4.4587%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 4.3209%，因此選擇誤差最小之為 4.3209% 模式做 epochs、batch_size 變化調整。

表90、多變數模1車程-田中第一班次

車程-田中第一班次			
模式 1	輸入層	隱藏層	MAPE
	15	50	5.3549
		100	4.7878
		200	4.5827
		300	4.9910
		400	4.4587
		500	4.5315

表91、加入隱藏層2變化

車程-田中第一班次				
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE
	15	400	50	4.3261
			100	4.4906
			200	4.3736
			300	4.4290
			400	4.3209

將誤差值最小之模式 4.3209%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 200，batch_size 為 10 的情況下誤差最小為 4.1804%，因此在模式 1 車程-田中第一班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=400，epochs=200，batch_size=10，MAPE 為 4.1804%。

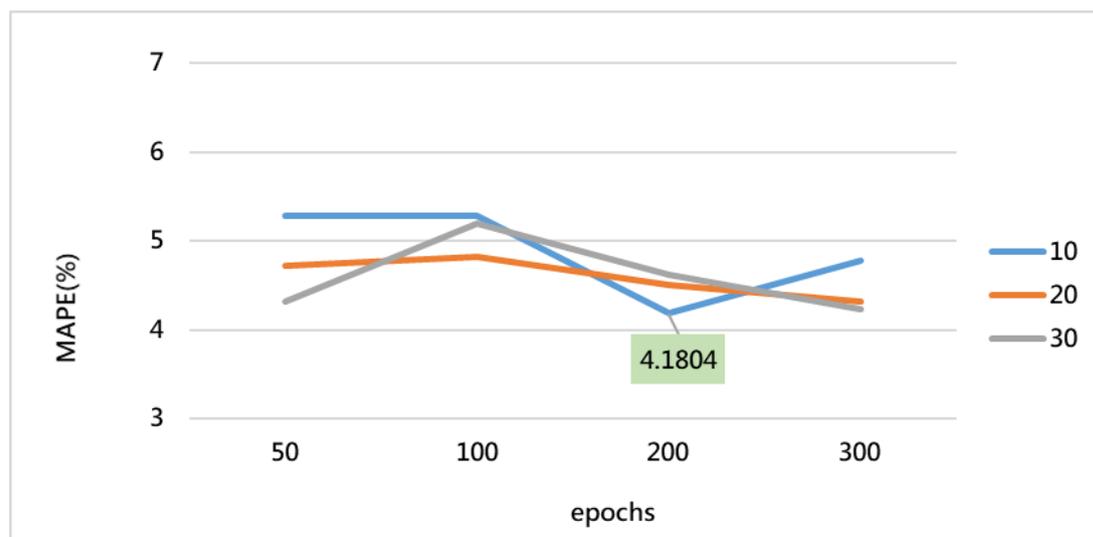


圖71、車程-田中第一班參數調整epochs、batch_size (模式1)

(8) 車程-田中第一班次(模式2)

表 92 為多變數模 2，車程-田中第一班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 4.4751%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 4.2180%，因此選擇誤差最小之為 4.2180% 模式做 epochs、batch_size 變化調整。

表92、多變數模2車程-田中第一班次

車程-田中第一班次			
	輸入層	隱藏層	MAPE
模式 2	16	50	5.2161
		100	5.3363
		200	4.8530
		300	4.5488
		400	4.4751
		500	4.8860

表93、加入隱藏層2變化

車程-田中第一班次				
	輸入層	隱藏層 1	隱藏層 2	MAPE
模式 2	16	400	50	4.4946
			100	4.5467
			200	4.2180
			300	4.2267
			400	4.4036

將誤差值最小之模式 4.2180%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 100，batch_size 為 10 的情況下誤差最小為 4.0994%，因此在模式 2 車程-田中第一班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=400，epochs=100，batch_size=10，MAPE 為 4.0994%。

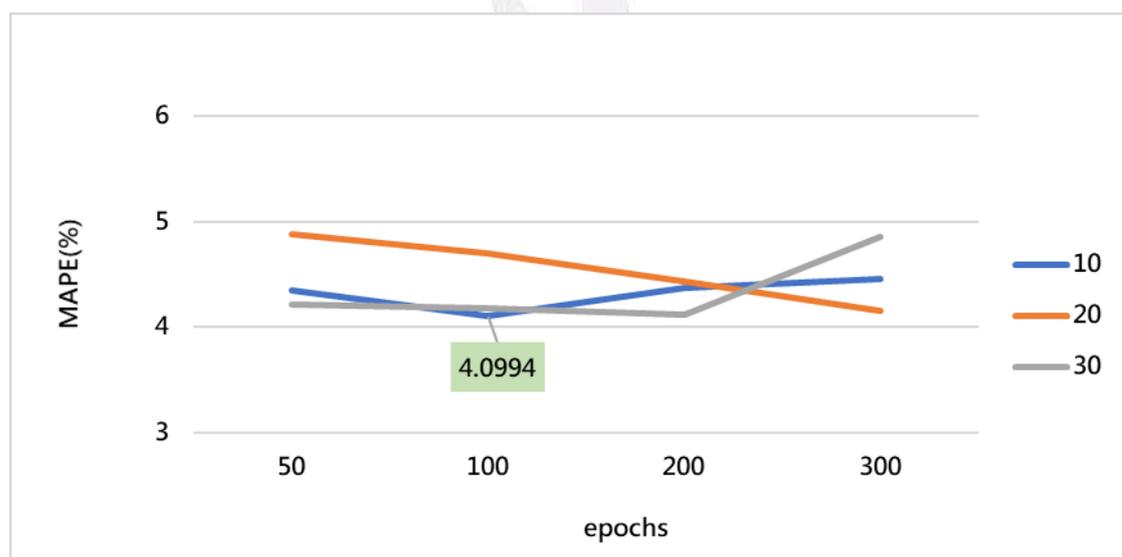


圖72車程-田中第一班參數調整epochs、batch_size (模式2)

(9) 車程-田中第二班次(模式 1)

表 94 為多變數模 1，車程-田中第二班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 7.8010%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 8.2799%，因此選擇誤差最小之為 7.8010% 模式做 epochs、batch_size 變化調整。

表94、多變數模1車程-田中第二班次

車程-田中第二班次			
模式 1	輸入層	隱藏層	MAPE
	15	15	50
100			8.6876
200			7.8010
300			8.3139
400			9.1814
500			8.9804

表95、加入隱藏層2變化

車程-田中第二班次				
模式 1	輸入層	隱藏層 1	隱藏層 2	MAPE
	15	15	200	50
100				9.0962
150				8.2799
200				9.1814

將誤差值最小之模式 7.8010%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 7.8010%，因此在模式 1 車程-田中第二班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=200，epochs=50，batch_size=30，MAPE 為 7.8010%。

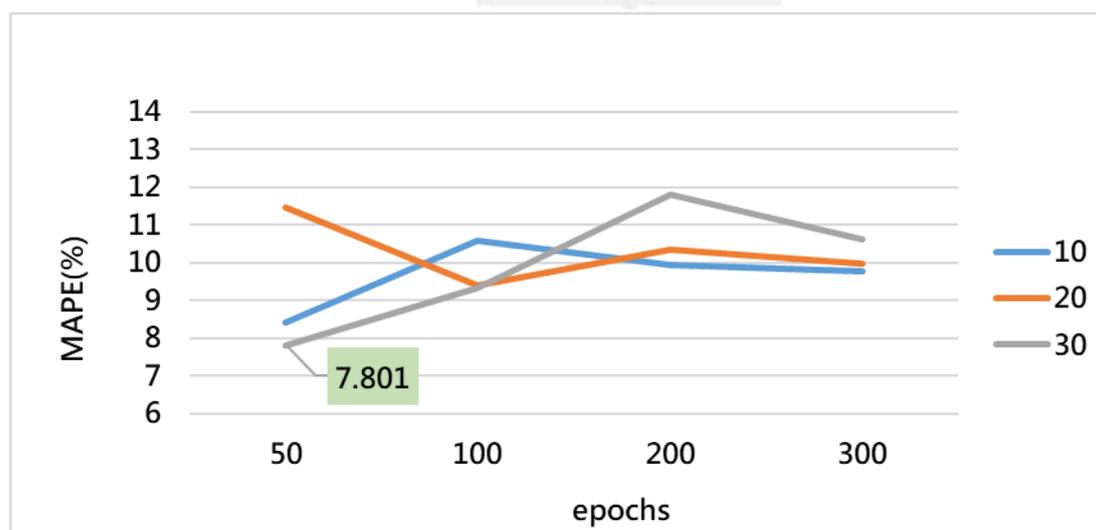


圖73、車程-田中第二班參數調整epochs、batch_size (模式1)

(10) 車程-田中第二班次(模式 2)

表 96 為多變數模 2，車程-田中第二班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 7.6258%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 6.9237%，因此選擇誤差最小之為 6.9237% 模式做 epochs、batch_size 變化調整。

表96、多變數模2車程-田中第二班次

車程-田中第二班次			
	輸入層	隱藏層	MAPE
模式 2	16	50	7.6258
		100	8.7345
		200	7.9629
		300	8.0816
		400	7.9367
		500	8.0574

表97、加入隱藏層2變化

車程-田中第二班次				
	輸入層	隱藏層 1	隱藏層 2	MAPE
模式 2	16	50	10	6.9237
			20	8.0093
			30	7.8521
			40	7.9531
			50	8.0630

將誤差值最小之模式 6.9237%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 6.9237%，因此在模式 2 車程-田中第二班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=50，隱藏層 2=10，epochs=50，batch_size=30，MAPE 為 6.9237%。

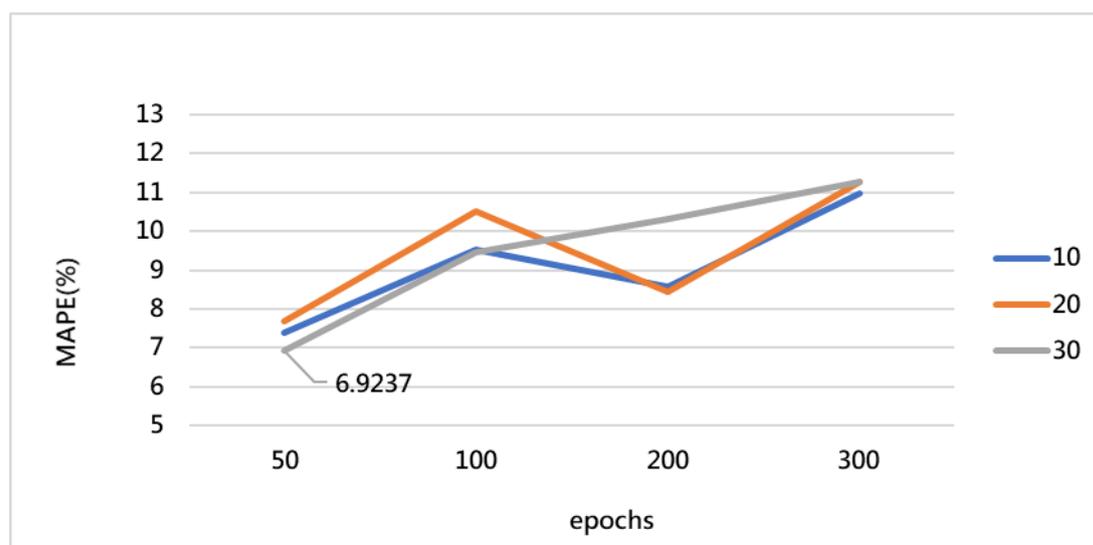


圖74、車程-田中第二班參數調整epochs、batch_size (模式2)

(11) 車程-田中第三班次(模式 1)

表 98 為多變數模 1，車程-田中第三班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 7.4308%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 7.5202%，因此選擇誤差最小之為 7.4308% 模式做 epochs、batch_size 變化調整。

表98、多變數模1車程-田中第三班次

車程-田中第三班次			
	輸入層	隱藏層	MAPE
模式 1	15	50	7.6142
		100	7.4308
		200	7.5532
		300	7.6612
		400	7.5592
		500	7.5568

表99、加入隱藏層2變化

車程-田中第三班次				
	輸入層	隱藏層 1	隱藏層 2	MAPE
模式 1	15	100	20	7.6065
			40	7.5202
			60	7.5346
			80	7.5924
			100	7.6412

將誤差值最小之模式 7.4308%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 7.4308%，因此在模式 1 車程-田中程第三班次旅行時間最佳之預測模式為輸入層=15，隱藏層 1=100，epochs=50，batch_size=30，MAPE 為 7.4308%。

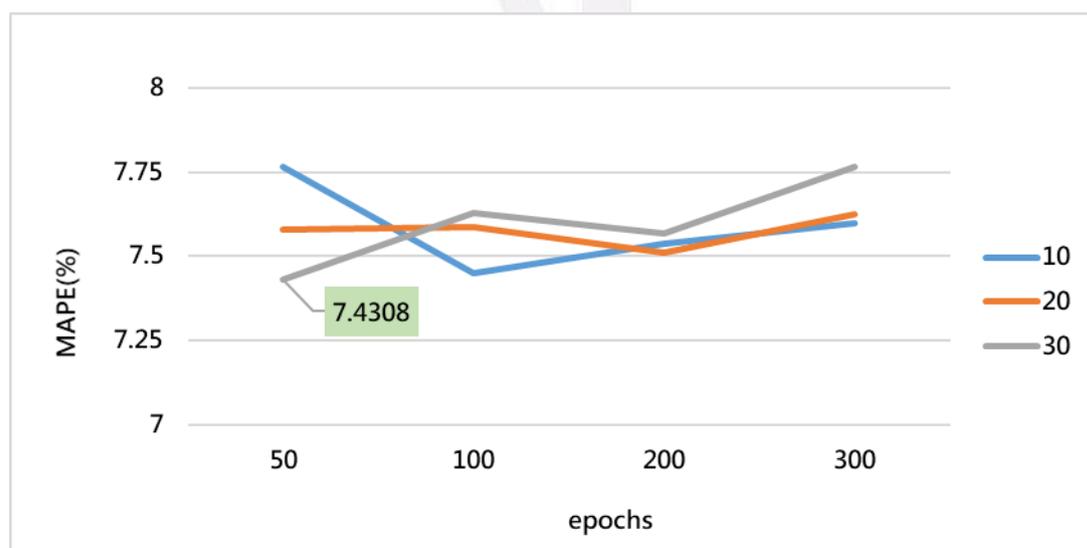


圖75、車程-田中第三班參數調整epochs、batch_size (模式1)

(12) 車程-田中第三班次(模式 2)

表 100 為多變數模 2，車程-田中第三班次旅行時間參數變化結果，固定訓練次數 epochs=50、每一批次訓練筆數 batch_size=30 的情況下，調整隱藏層參數發現 MAPE 誤差最小為 7.3923%，因此固定隱藏層 1，多加隱藏層 2 進行調整，發現加入第二層隱藏層 MAPE 誤差值最小之模式為 7.4601%，因此選擇誤差最小之為 7.3923% 模式做 epochs、batch_size 變化調整。

表100、多變數模2車程-田中第三班次

車程-田中第三班次			
模式 2	輸入層	隱藏層	MAPE
	16	50	7.4267
		100	7.3923
		200	7.4654
		300	7.6053
		400	7.7448
		500	7.5810

表101、加入隱藏層2變化

車程-田中第三班次				
模式 2	輸入層	隱藏層 1	隱藏層 2	MAPE
	16	100	20	7.5173
			40	7.4601
			60	7.5354
			80	7.5527
			100	7.5685

將誤差值最小之模式 7.3923%，改變 epochs 訓練次數由 50、100、200、300，每一批次訓練筆數 batch_size 由 10、20、30，觀查參數調整結果，發現在 epochs 為 50，batch_size 為 30 的情況下誤差最小為 7.3923%，因此在模式 2 車程-田中程第三班次旅行時間最佳之預測模式為輸入層=16，隱藏層 1=100，epochs=50，batch_size=30，MAPE 為 7.3923%。

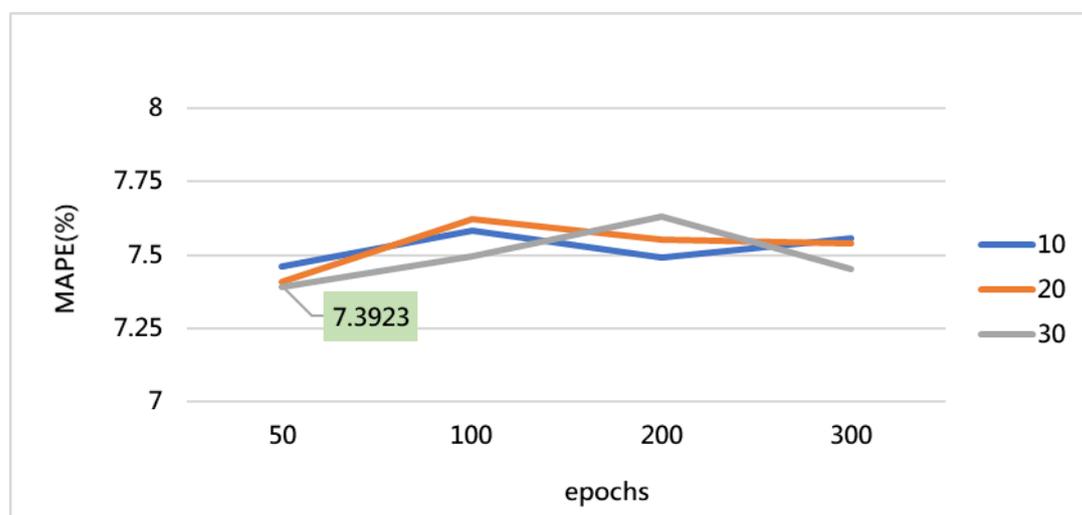


圖76、車程-田中第三班參數調整epochs、batch_size (模式2)

4.5 模式比較

(1) 總旅行時間(員林 \leftrightarrow 車程)各班次模式 MAPE 比較圖

根據 4.3.2 節參數調整結果，將各班次模式 1、模式 2 總體旅行時間統整，發現於模式 2 中車埕-員林第三班次，MAPE 4.7379% 為最小誤差，因此總旅行時間最佳之預測模式將統一調整輸入層=16，隱藏層 1=100，epochs=50，batch_size=30，作為總旅行時間之預測模式。

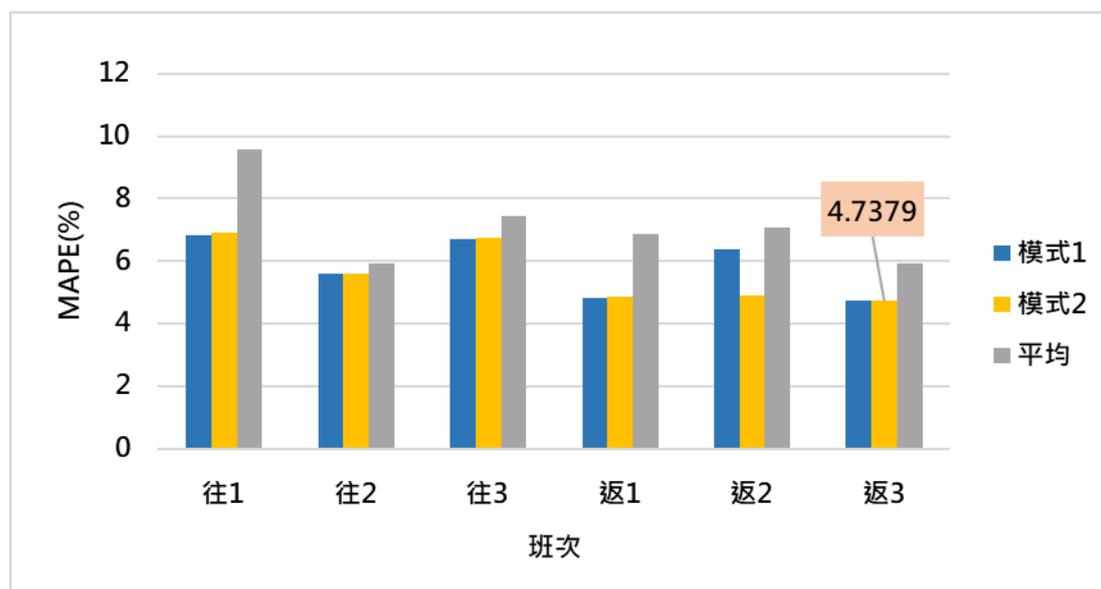


圖77、總旅行時間(員林 \leftrightarrow 車程)各班次模式MAPE比較圖

(2) (員林 \leftrightarrow 卓乃潭)各班次卓乃潭模式 MAPE 比較圖

根據 4.3.2 節參數調整結果，將各班次模式 1、模式 2(員林 \leftrightarrow 卓乃潭)區間旅行時間統整，發現於(員林 \leftrightarrow 卓乃潭)區間旅行時間中，模式 1 員林-卓乃潭第三班次，MAPE 3.6786% 為最小誤差，因此於(員林 \leftrightarrow 卓乃潭)區間旅行時間最佳之預測模式將統一調輸入層=15，隱藏層 1=400，epochs=100，batch_size=10，作為總旅行時間之預測模式。

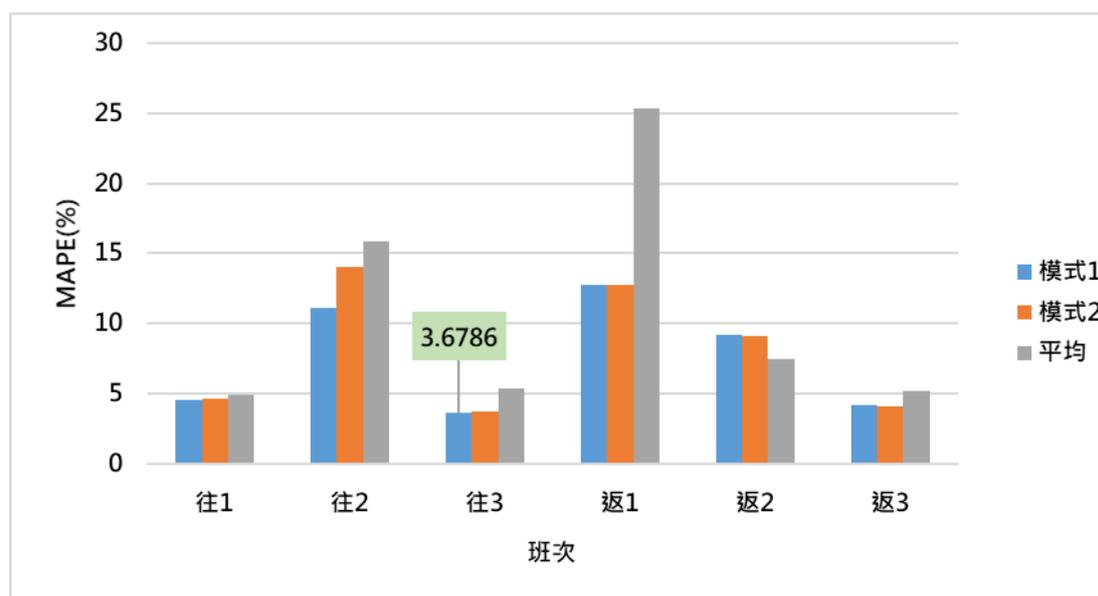


圖78、(員林←→卓乃潭)各班次旅行時間模式MAPE比較圖

(3) (卓乃潭←→田中)各班次旅行時間模式 MAPE 比較圖

根據 4.3.2 節參數調整結果，將各班次模式 1、模式 2(卓乃潭←→田中)區間旅行時間統整，發現於(卓乃潭←→田中)區間旅行時間中，模式 1 卓乃潭-田中第三班次，MAPE 11.726%為最小誤差，因此於(卓乃潭←→田中)區間旅行時間最佳之預測模式將統一調為輸入層=15，隱藏層 1=300，epochs=100，batch_size=20，作為總旅行時間之預測模式。

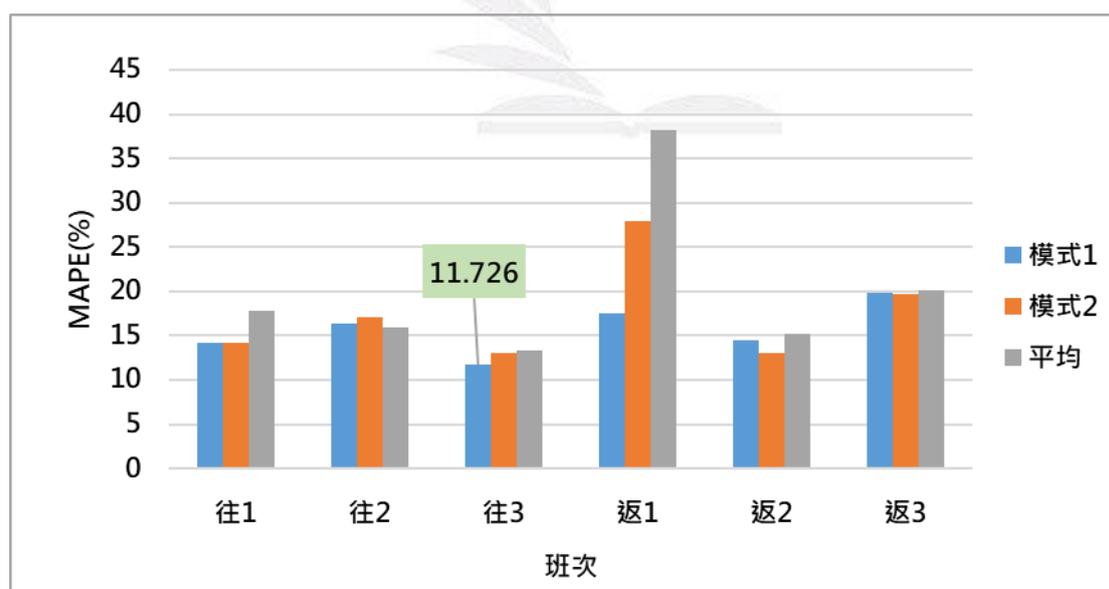


圖79、(卓乃潭←→田中)各班次旅行時間模式MAPE比較圖

(4) (田中 \leftrightarrow 車埕)各班次旅行時間模式 MAPE 比較圖

根據 4.3.2 節參數調整結果，將各班次模式 1、模式 2(田中 \leftrightarrow 車埕)區間旅行時間統整，發現於(田中 \leftrightarrow 車埕)區間旅行時間中，模式 1 車埕-田中第一班次，MAPE 4.0994%為最小誤差，因此於(田中 \leftrightarrow 車埕)區間旅行時間最佳之預測模式將統一調為輸入層=16，隱藏層 1=400，epochs=100，batch_size=10，作為總旅行時間之預測模式。

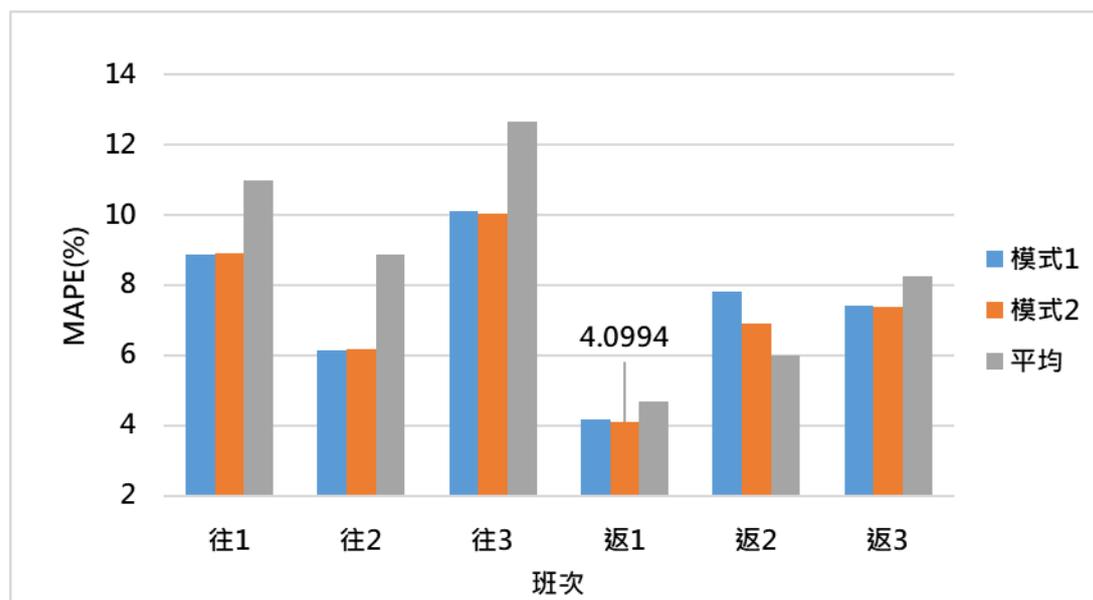


圖80、(田中 \leftrightarrow 車埕)各班次旅行時間模式MAPE比較圖

4.6 歷史平均模型

為了評估 LSTM 深度學習預測模式與傳統統計現況之誤差，計算預測集 7 天之各班次總體旅行時間、區間旅行時間，於歷史平均模計算上採用平日的平均，與假日的平均來做區分，並與深度學習預測模式比較 MAPE 誤差結果，圖* 為總旅行時間第一班次模式 2，根據平假日計算其平均，2 月 5 日至 2 月 8 日及 2 月 11 為平日，因此平均預測之旅行時間相同，2 月 9 月即 2 月 10 日則為假日，因而平均預測之旅行時間相同，各模式依照上述方式計算其平均預測之旅行時間，並與實際值計算誤差值，比較 LSTM 模式與歷史平均模式之預測成效。

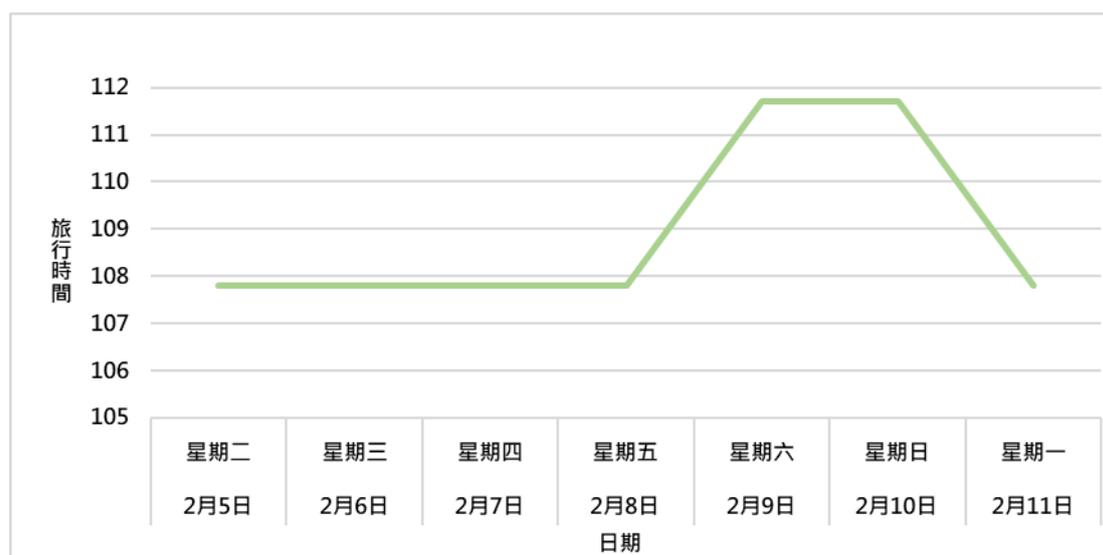


圖81、總旅行時間(員林→車埕)第一班次歷史平均模型

4.7 模式預測

(1) (員林↔車程)總旅行時間模式預測誤差結果

由 4.3 節選定(員林↔車程)總旅行時間最佳之預測模式，將利用最佳模式預測各班次總旅行時間，同時評估預測值與現況 MAPE 誤差結果，以整體來說發現預測值 MAPE 誤差由 4.8657%-7.0541%範圍之間，相差 2.1884%，而現況 MAPE 誤差由 5.9281%-9.5671%，相差 3.6391%，因此 LSTM 深度學習預測模式與傳統統計平均相比，MAPE 誤差範圍呈現較穩定，且浮動趨勢相對較小。

表102、(員林↔車程) 總旅行時間預測值與現況MAPE誤差

(員林↔車程)		
班次	預測值	現況
員林→車程第一班	6.6617	9.5671
員林→車程第二班	6.5682	5.9280
員林→車程第三班	7.0541	7.4351
車埕→員林第一班	5.0444	6.8842
車埕→員林第二班	4.8657	7.0909
車埕→員林第三班	4.9864	5.9160

(2) (員林←→卓乃潭)區間旅行時間模式預測誤差結果

由 4.3 節選定(員林←→卓乃潭)區間旅行時間最佳之預測模式，將利用最佳模式預測各班次總旅行時間，同時評估預測值與現況 MAPE 誤差結果，以整體來說發現預測值 MAPE 誤差由 4.5288%-12.7586%範圍之間，相差 8.2298%，而現況 MAPE 誤差由 4.8962%-25.7369%，相差 20.8407%，因此 LSTM 深度學習預測模式與傳統統計平均相比，MAPE 誤差範圍呈現較穩定，且浮動趨勢相對較小。

表103、(員林←→卓乃潭)區間旅行時間預測值與現況MAPE誤差

(員林←→卓乃潭)		
班次	預測值	現況
員林→卓乃潭第一班	4.6825	4.8962
員林→卓乃潭第二班	10.7458	15.8235
員林→卓乃潭第三班	3.7341	5.3951
卓乃潭→車埕第一班	12.7586	25.7369
卓乃潭→車埕第二班	9.6965	7.4773
卓乃潭→車埕第三班	4.5288	5.1594

(3) (卓乃潭←→田中)區間旅行時間模式預測誤差結果

由 4.3 節選定(卓乃潭←→田中)區間旅行時間最佳之預測模式，將利用最佳模式預測各班次總旅行時間，同時評估預測值與現況 MAPE 誤差結果，以整體來說發現預測值 MAPE 誤差由 11.7260%-19.874%範圍之間，相差 8.148%，而現況 MAPE 誤差由 13.3899%-38.1633%，相差 24.7744%，因此 LSTM 深度學習預測模式與傳統統計平均相比，MAPE 誤差範圍呈現較穩定，且浮動趨勢相對較小。

表104、(卓乃潭←→田中)區間旅行時間預測值與現況MAPE誤差

(卓乃潭←→田中)		
班次	預測值	現況
卓乃潭→田中第一班	14.1296	17.8268
卓乃潭→田中第二班	18.3842	15.3908
卓乃潭→田中第三班	11.7260	13.3889
田中→卓乃潭第一班	17.6531	38.1633
田中→卓乃潭第二班	15.2048	15.2376
田中→卓乃潭第三班	19.8741	20.0595

(4) (田中←→車埕)區間旅行時間模式預測誤差結果

由 4.3 節選定(田中←→車埕)區間旅行時間最佳之預測模式，將利用最佳模

式預測各班次總旅行時間，同時評估預測值與現況 MAPE 誤差結果，以整體來說發現預測值 MAPE 誤差由 4.0094%-11.9793% 範圍之間，相差 7.969%，而現況 MAPE 誤差由 4.6690%-12.6580%，相差 7.989%，因此 LSTM 深度學習預測模式與傳統統計平均相比，MAPE 誤差範圍呈現較穩定，且浮動趨勢相對較小。

表105、(田中↔車埕)區間旅行時間預測值與現況MAPE誤差

(卓乃潭↔田中)		
班次	預測值	現況
田中→車埕第一班	10.7465	10.9787
田中→車埕第二班	6.3329	8.8831
田中→車埕第三班	11.9793	12.6580
車埕→田中第一班	4.0094	4.6690
車埕→田中第二班	7.4636	6.0039
車埕→田中第三班	7.5597	8.2533

4.8 綜合討論

4.8.1 與文獻誤差比較

經由上述車程-員林之總旅行時間，及車程-卓乃潭、卓乃潭-田中及田中-車埕三個區間之旅行時間預測，透過變數中有無降雨資料，及參數中神經元數量、隱藏層數量、訓練次數及每批次訓練之筆數的調整，找出經預測後誤差值 MAPE 最小之模式，並且統整文獻回顧中，預測旅行時間之最小誤差值與本研究之結果進行比較，於表 106 可發現，Niklas 等人之研究中最小之 MAPE 為 4.04%，Ran 等人之研究中最小之 MAPE 為 5.95%，本研究最小誤差值之模式為員林至卓乃潭第三班次模式一，其 MAPE 為 3.67%，於 MAPE 尺度量表中皆代表預測結果極佳，與其他文獻相比，本研究之預測成果良好。

表106、文獻及本研究MAPE統整表

作者	模型	MAPE
Niklas	ConLSTM	4.04%
Ran	LSTM NN	5.95%
本研究	LSTM	3.67%

4.8.2 與現況誤差比較

經由上述車程-員林之總旅行時間，及車程-卓乃潭、卓乃潭-田中及田中-車埕三個區間之旅行時間預測，計算預測結果與實際值之誤差值，除了與各文獻之誤差相比，也與現況預測模式進行比較，現況預測模式為使用歷史平均預測未來旅行時間，而本研究最小誤差值之模式為員林至卓乃潭第三班次模式一，其 MAPE 為 3.67%，同一模式及班次現況預測之 MAPE 則為 5.39%，於表 107 中，LSTM 模式預測結果較現況預測之 MAPE 小，顯示使用 LSTM 模型可更精準的預測旅行時間。

表107、現況及本研究MAPE統整表

作者	模型	MAPE
本研究	LSTM	3.67%
現況	歷史平均	5.39%

4.8.3 綜合分析

(1) 模式訓練的損失函數隨著訓練次數增加而呈現下降趨勢

於旅行時間預測前，使用損失函數評估訓練模型之優劣，經上述章節中之分析可發現預測值與實際值之損失函數與平均絕對誤差皆隨著訓練次數增加而呈現下降趨勢，代表模型訓練結果良好，後續才得已匯入測試資料進行預測，以防訓練模型之誤差影響最終之預測結果。

(2) 透過參數調整找出最適合的模式進行預測

於上述章節中，本研究分析不同之變數，將有無降雨資料分為模式一與模式二，觀察其變數對於預測結果之誤差影響，並且調整 LSTM 模型之參數，包括神經元數量、隱藏層數量、訓練次數及每批次訓練之筆數，經由參數的調整，找出各模式、各班次預測結果與實際值計算之最小誤差值模式，並使用最佳之預測模式進行各班次之旅行時間預測。

(3) LSTM 預測模式相較於平均預測誤差來的小

現況旅行時間使用歷史平均計算預測未來旅行時間，本研究則使用 LSTM 時間序列之深度學習模型進行旅行時間之預測，由上述章節中，與現況計算之誤差值相比，LSTM 模型之預測值與實際值計算之 MAPE 誤差與現況預測結果之誤差值要小，顯示本研究之 LSTM 模型預測旅行時間結果較現況預測之結果要準確。

第五章 加值應用分析

本章節說明本研究依據模式預測結果進行旅行時間預測之加值應用，利用網頁方式呈現未來 7 天 6702 路線總旅行時間與區旅行時間之變化，提供使用者做後續行程規劃之運用。

5.1 旅行時間預報

旅行時間預報網站由線上網頁製作 wix 網站(www.wix.com)，由該網誌提供的樣板模式進一步的去編排網站樣式，該網站也有提供後端服務，可以藉由後端數據分析，了解使用此網站使用者的瀏覽次數以及訪客數量，經由點選視窗後了解到使用者多停留在哪一個頁面，藉此可以知道使用者多數的需求是如何，例如點選日期為假日次數的比較多，就得知使用者的偏好為何，而網頁下方也設置線上聯絡方式，若使用者有問題也可以直接詢問，有建議也可以直接的提出，可以更直接的去改善網頁。



圖82、網頁後台數據管理呈現

由網頁版面的背景製作是運用到 Adobe illustrator 去進行設計編排，設計構想是想呈現出搭乘大眾運輸交通工具遊玩台灣，搭配本研究經由時間序列所預測出的旅行時間，進一步製作旅行時間預估到站時間的頁面呈現，可以預先知道到站時間，方便規劃自己的行程，掌握時間方便旅客轉乘，而一開始的歡迎頁面下方是以投影片的方式呈現出預報，可以更直接的瀏覽到未來一周的旅行到站時間。



圖83、旅行時間預報主頁面

在網頁左上方更多之資訊欄，可以到網頁次頁面之旅行時間預報頁面下載圖資料廖，至日期點選畫面，由顏色區別直覺式的方式呈現，用超連結的方式連結到資料庫，使用者點選日期後可以自由下載所需資訊，而點選範圍也設定為未來一周內之時間才能下載資料，使用者可以儲存到裝置內方便記錄存取。

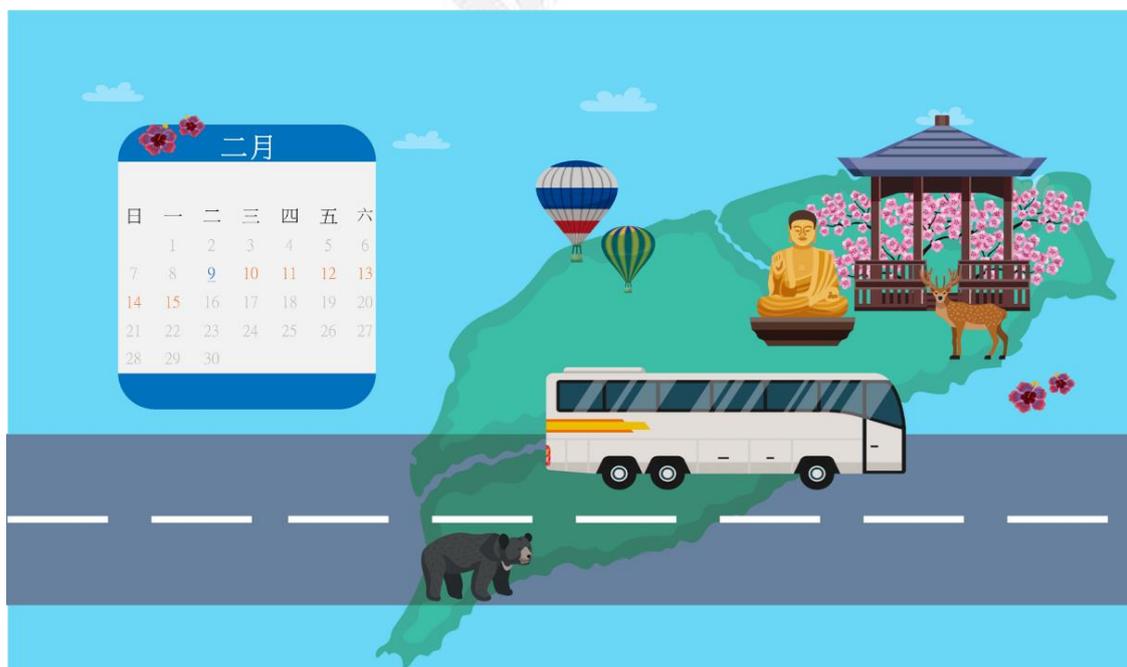


圖84、旅行時間日期點選頁面

旅行時間預估呈現為 6702 員林至車埕總體旅行時間預估，一天往返六班次，第一班至第三班由數字 1~3 呈現，而左邊時刻呈現為發車時間，右邊時刻呈現為預估到站的時間，箭頭方向軸的顏色代表旅行時間的長短，綠色箭頭代表為預測時間小於 105 分鐘，較平均旅行時間快，黃色箭頭為 105~114 分鐘以內，紅色箭頭為預測時間 115 分鐘以上，使用者可以用直觀的方式去選擇適合的班次去搭乘。



圖85、旅行時間預估到站

第六章 結論建議

本章節依據前五章節統整說明本研究建立 LSTM 深度學習模式之結論建議，利用變數及參數進行調整變化，觀察影響旅行時間因子之變數及參數，找出最佳之預測模式，運用最佳模式預測未來 7 天總旅行時間及區間旅行時間，結果發現使用 LSTM 深度學習之最佳預測模式平均百分誤差(MAPE)為 3.67%，與過去文獻之最佳預測模式、現況歷史平均相比本研究預測模式結果良好，並針對預測結果做加值應用提供使用者作後續行程規劃，最後根據研究中發現之問題提出建議方向。

6.1 結論

藉由本次研究瞭解建立 LSTM 深度學習旅行時間模式，利用 Python 相關套件 Numpy、Pandas、Matplotlib 作為運用，且資料匯入時須分為訓練集、測試集，透過標準化讓變數資料單位統一，使用變數包括(過去旅行時間、星期、節慶、降雨)，於研究過程中資料使用有無降雨而非雨量資料原因受限於雨量資料無法即時得知，因此使用有無降雨來做替代，建立 LSTM 核心架構 Sequential 序貫模型，將輸入層、隱藏層、輸出層堆疊，並於輸入層放入變數訓練預測模型，使用損失函數(loss)、平均絕對誤差(MAE)雙重指標，觀察模型是否隨訓練次數增加而呈現下降趨勢，評估訓練模型優劣，確保模式訓練良好，並進行參數(隱藏層神經元數量、epochs、batch_size)調整找出誤差最小之總旅行時間及區間旅行時間預測模式，運用最佳模式預測未來 7 天總旅行時間及區間旅行時間作為後續加值應用，且由綜合討論發現 LSTM 模式與過去有關預測旅行時間文獻相比平均百分誤差(MAPE)預測結果還不錯，與現況歷史平均相比平均百分誤差(MAPE)來的好，代表與現況相比使用 LSTM 深度學習預測結果更為良好，預測更為準確，預測結果結論彙整如下。

(1) 建立深度學習之旅行時間預測模式

透過文獻、書籍及電腦教學影片，瞭解 LSTM 深度學習之相關實務應用，建立旅行時間預測模式，使用公車動態(A1)資料計算總旅行時間進行模式訓練，運用 Python 相關套件 Numpy、Pandas、Matplotlib 作為輔助，建立 LSTM 核心架構 Sequential 序貫模型，將輸入層、隱藏層、輸出層堆疊，將訓練完成後的模式儲存，當未來有新資料提供時可使用訓練完成的模型加以預測，同時透過用損失函數(loss)、平均絕對誤差(MAE)觀察模式訓練結果，發現研究中之損失函數確實隨訓練是數增加而呈現下降趨勢，表示模式結果訓練良好。

(2) 調整影響變數之差異分析

模式建置完成，加入影響之變數比較各模式之差異，變數包括過去的旅行時間資料、節慶、星期、降雨，目的是為了看出各個變數加入後，模式因變數而影響而導致預測結果不同變化，因此研究中使用模式 1 過去旅行時間、節慶、星期，與模式 2 過去旅行時間、節慶、星期、降雨，觀察其總旅行時間、區間旅行時間誤差變化結果，並選定誤差最小之變數預測模式，進行後續參數調整，研究中發

現模式中加入降雨特徵變化並不明顯，因為蒐集資料樣本少，導致訓練特徵變化並不明顯，因此建議取得更多資料進行訓練，詳述建議於 6.2 節中進行說明。

(3) 預測模式之參數分析

透過變數變化選定誤差最小之預測模式，將逐一針對其參數進行調整，調整項目包括隱藏層神經元數量、(訓練次數)epochs、(每一批次訓練筆數)batch_size，透過參數調整，找出總旅行時間、區間旅行時間中誤差最小之預測模式，並將模式帶入測試集進行後續預測。

(4) 旅行時間預測

透過變數、參數變化調整找出最佳之預測模式，並利用 MAPE 評估預測值與實際值之誤差，其最佳之預測模式 MAPE 為 3.67%，於 MAPE 尺度量表中代表預測結果極佳，與現況歷史平均 MAPE 5.39% 做對比，發現 LSTM 預測模式相較歷史平均預測結果為良好，使用最佳之預測模式將測試資料進行總旅行時間、區間旅行時間預測，呈現未來 7 天旅行時間之變化，並延伸做後續之加值應用。

(5) 加值應用分析

將模式預測結果進行旅行時間預測之加值應用，利用網頁方式呈現未來 7 天 6702 路線總旅行時間與區間旅行時間之預報，網頁中提供點選方式搜尋欲搭乘之日期，使用超連結的方式連結到資料庫，點選日期後可以自由下載所需資訊，點選範圍之設定為未來一周內之時間才能下載資料，以提供使用者做未來行程規劃之運用參考。

與研究中發現降雨對旅行時間的影響變化不大，因為研究中所選取之資料範圍多為晴天，加上模式訓練時資料量不夠無法有效訓練到有無降雨的特徵，導致降雨變數對旅行時間的影響變化不大的原因，因此將提供下列三項建議作為後續研究之應用。

6.2 建議

(1) LSTM 模式結構調整。

建立 LSTM 核心架構層中，除了變數改變，參數調整外，仍可加入一些 Dropout(丟棄法)於訓練期間應用，因為丟棄法主要將部分特徵資料丟棄，防止神經元訓練會有過擬合狀態，過擬合代表訓練資料過於符合實際資料狀態，表示於測試上會相較訓練時來的差，因此未來後續深度學習研究中建議針對 LSTM 模式結構進行調整應用。

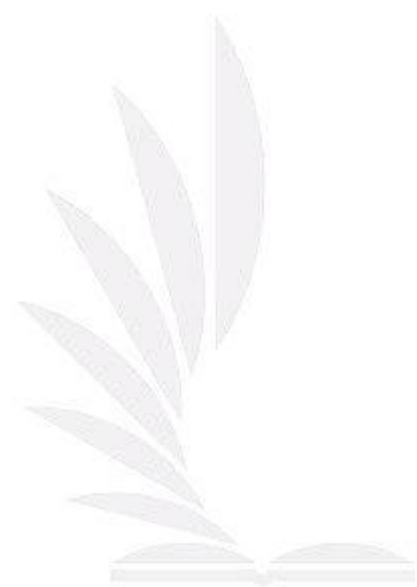
(2) 放入可能影響旅行時間之變數。

本研究使用之變數使用變數包括過去旅行時間、星期、節慶、降雨，於未來

有關旅行時間之深度學習研究可加入氣溫、不同時段車流量、路上障礙物影響(號誌控制)等變數觀察期變化影響。

(3) 取得更多資料筆數。

研究中發現蒐集資料筆數少，導致降雨變數特徵變化並不明顯，因為深度學習模型的學習特徵能力，是依賴大量訓練資料，在樣本少的情況下，其特徵中的資訊變得相當重要，因此於資料少的情況下可能導致特徵變化會較不明顯，同時為了防止模型在訓練中學習到錯誤的訊息，最佳的方法就是取得更多資料來做訓練，且接受更多資料訓練的模型在普適性方面會表現得更好，普適性代表已經訓練過的模型對未見過的資料的預測能力，未來後續深度學習研究中建議可使用更多資料數量作為訓練運用。



第七章 參考文獻

何承遠等人(2017)。台中公車乘客量分析-以霧峰區為例。國立交通大學訊工程學系。

黃士鴻(2010)。大眾運輸需求因素之探討-以台北捷運為例。東海大學經學系碩士論文。

許尹馨(2009)。高雄市公車 12 路運量之研究分析。高雄市公共汽車管理處。

Han, Y., Wang, S., Ren, Y., Wang, C., Gao, P., Chen, G. (2019). Predicting Station-Level Short-Term Passenger Flow in a Citywide Metro Network Using Spatiotemporal Graph Convolutional Neural Networks, ISPRS Int. J. Geo-Inf.

Liu, L., Chen, R-C. (2017). A novel passenger flow prediction model using deep learning methods, Transportation Research Part C: Emerging Technologies Volume 84, Pages 74-91.

Marko, C., Marjan, L. (2019). Bus arrival time prediction based on network mode.

Niklas, C. P., Filipe, R., Francisco, C.P. (2019). Multi-output Bus Travel Time Prediction with Convolutional LSTM Neural Network.

Ran, X., Shan, Z., Fang, Y., Lin, C.(2019). An LSTM Based Method with Attention Mechanism for Travel Time Prediction.

Yu, S. Y. W., Shang, C., and Zhang, S. (2016). Prediction of bus passenger trip flow based on artificial neural network, Advances in Mechanical Engineering, Vol. 8(10), 1-7.

Zhu, H., Yang, X., Wang, Y. (2018). Prediction of Daily Entrance and Exit Passenger Flow of Rail Transit Stations by Deep Learning Method, Journal of Advanced Transportation Volume.