淡江大學運輸管理學系運輸科學碩士班碩士論文

指導教授：范俊海博士

以深度學習長短時記憶神經網路演算法建立混合車道之機車行為模式

A Study of Using Deep Learning Method(Long Short-Term Memory) to Build Motorcycle Moving Behavior on Urban Mixed Lane

研究生：吳建霆

中華民國 107 年 06 月

誌謝

當初入學給自己許下的承諾,如今終於兌現,在寫致謝的同時心中真的是感慨萬千,我想，要成為一個男子漢的過程就是要說到做到吧!雖然研究所只是短短的兩年，但卻是滿滿收穫的兩年，這一路走來感謝同學、老師、家人，還有最重要的女朋友 妤甄的陪伴，感謝妳在我遇到困難及瓶頸時，給我的鼓勵和加油打氣，妳總是扮演一座搞笑的燈塔，讓我能夠在一片愁雲慘霧中順利地撥雲，見日，就像太陽一樣總是閃耀著，有時溫暖，有時又有點熱到覺得煩(哈)，不過有妳在時，總是充滿著快樂歡笑，感謝有妳的陪伴。這兩年來運科所的薰陶，從一開始的自我懷疑到後來的意志堅定，從中要感謝許多人，雖然人家總說，做論文只能靠自己，但如果沒有身邊同學的互相砥礪，和老師們的課業指導，我想不知要過多久才能著手寫這篇感人肺腑的出師表，有你們，這篇論文才能順利完成，並迎接人生的下一個開始。

首先，感謝指導老師 范俊海 教授 一年半來的指導，感謝范老師的諄諄教誨，和老師相處的過程中常常像是在輕鬆聊天一樣,總是在看似平凡的聊天過程中找到論文的方向及靈感，而對於學生提出的問題，總是不厭其煩的為學生指導，使學生受益良多，也真的很感謝老師在最後所內口試，當學生在台上腦袋一片空白，不知道該如何回應其他老師問題時，老師的即時解圍順利幫我度過難關，對於佛法上的言教與身教，更是令學生刮目相看，老師的處事方式及對待人總是和善的態度，也是學生未來在面對職場挑戰時，所值得效法學習的，在此說聲: 感謝 老師的指導。當然也非常感謝口試期間撥冗前來的中央大學 吳健生 教授，及本校資工系的 洪文彬 教授 擔任口試委員，給予本論文的種種意見及指教，使本論文能更加完善，再來感謝系上的所有老師，雖然我是研究所才過來念運管，但系上老師們課堂上的指導，都讓我受益良多，使我對交通這塊艱深的領域有了深層的了解，再來就是感謝系上處理研究所事務的兩位助教 陳晗和玉婷,兩位時常的課業訊息提醒,及幫忙我們處理複雜的行政流程,感謝兩位的捨己為公,使論文能夠順利的推進。

感謝研究所的各位同班同學們，陳翰、余玄、于婷、舒媛、哲穎、傳育、德安、晨峰、詠熙、欣婷、家敏，還有學長峰銓、聖樺、瑋倫，以及同家的學姊芝凌，大家一起奮鬥的碩二最後的論文衝刺時期，一起在研究室愁眉苦臉的那段日子，一起聊天打屁，一起同仇敵愾，一起喝酒同仇敵愾，一起喝酒聊天打屁愁眉苦臉同仇敵愾的那段快樂鳥日子，永遠不會忘記，也很感謝家敏所外口試的各項協助，東奔西跑辛苦了!對了，還要非常感謝碩一學妹潘家宜，少了妳的幫助，我的論文 DATA 不知要處理到民國幾年，在此永遠感謝您，感謝您為本論文辛勞，也感謝瑞予時常的點心支援，還有，感謝兩位麻吉 杰倫和阿嶽，在我做論文最茫然，最不知如何是好的那段時間，你們的音樂從耳機傳達出來的，是使我克服難關的重要支撐，最後感謝在台南工作打拼的幾位高中麻吉趕文和串串，在我念研究所期間一直問我什麼時候回台南聚聚，到了 6 月也打電話來關心我是否能及時畢業，常常令我感動得痛哭流涕，雖然我要開始上班不能和各位高中兄弟們一起去沖繩，但我心與你們同在，Machi Forever!

雖然念研究所只是短短兩年，不敢說專業知識學到了多少，但我認為收穫最大的，是學到了看待問題及處理問題的方法，從碩一菀蕙老師研方課一直強調的，做論文的動機以及目的，如何找出問題的癥結所在，閱讀論文時找出重點，找出作者嘗試解決的各種狀況，再來討論使用的方法，使我在面臨未來的各種問題時的思路更加清晰，而羅老師的交工課程及系統模擬課程，學到最多的應該是老師的實務精神和嚴謹的態度，劉老師多變量分析的上課內容雖然很容易精神不濟(睡著)，但老師細心及耐心的講解，希望大家都能真正了解的教學步調，真的讓我學到了很多專業知識，陶老師的 ITS 課程，從看似聊天的上課過程及不斷的上台討論，使我漸漸模清研究方向，可以說是使我踏進交通領域的敲門磚。

而最後的最後，要感謝我的家人，我的爸媽還有我老妹，我所有的阿姨們，從我高中畢業後我就離開台南到台北讀書，雖然途中有回台南當兵，但前前後後來台北也過了六到七年的時光，感謝爸媽讓我從來不用為生活費煩惱，感謝爸媽時常的電話關心，淡水寒冷的冬天來臨時，常常寄來的保暖衣物，讓我人在台北也常常感受到家裡的溫暖，尤其是念碩士為論文煩惱惆悵時，老媽的關心總是是使我向前的助推劑，如今成功完成

學業取得碩士學位，希望能夠獻給我的家人，未來人生邁向工作階段，我有空就會多回去陪陪大家!

在此，感謝關心我的所有人，要感謝的人實在太多了，文中沒有寫出來不代表忘記各位及各位給予我的幫助，但礙於篇幅，只能於此歉之，文末也祝福尚未畢業的同學們能夠如期完成，大家一定會畢業的。

吳建霆　肅誌謝忱

民國一百零七年　大暑

于　淡江大學

論文名稱: 頁數: 93

以深度學習長短時記憶神經網路演算法建立混合車道之機車行為模式

校系(所)組別: 淡江大學　　運輸管理學系運輸科學碩士班

畢業時間及提要別:　106 學年度　第 2 學期碩士學位論文提要

研究生: 吳建霆　　指導教授: 范俊海 博士

論文提要內容:

機車為台灣最主要的交通工具之一，特色為行進時不會遵行固定路線，經常會於同一車道內併行或連續超車，在過去針對機車行為研究中，試圖利用單一數學模型解釋機車推進模式及連續超車的各種行為。但本研究認為變化萬千的機車行為模式，若只利用單一模型解釋可能會造成模擬上的困難，且無法體現台灣車流混雜的道路真實情況，故本研究針對台灣機車的特殊行車狀態，於一般市區道路汽機車混合車道中的機車行為模式為研究主體。

本研究利用深度學習運算演算法，建立機車行為模式預測模型，將機車的前進方向及影響機車推進的各項影響參數，建立其輸入與輸出變數的對應關係，並以攝影座標轉換法擷取道路機車座標，以求得更準確之研究數據，為了讓預測結果接近於數值型的座標預測，利用深度學習特殊的運算結構，結合座標及格位概念預測機車的推進行為，研究中將機車的推進行為，依座標詳細計算 25 個推進模式，配合 25 個影響行為參數，在連續的時間序列下建立關係矩陣，設計深度學習的運算結構規則。研究結果，透過模式建立成功將機車行為分成 25 個行進模式，並利用資料後段之 25%與前段 75%進行模式驗證，模式預測程度可達 84%，證明模式預測機車行為確實有可行性，而後續研究可根據本研究之研究成果，蒐集完整的車流資訊執行模擬訓練，以建立完整的車流特性資料庫。

關鍵詞:機車行為模式、深度學習、預測、座標轉換、長短時記憶神經網路

＊依本校個人資料管理規範，本表單各項個人資料僅作為業務處理使用，並於保存期限屆滿後，逕行銷毀。

表單編號：ATRX-Q03-001-FM030-03

Title of Thesis： Total pages: 93

A Study of Using Deep Learning Method(Long Short-Term Memory) to Build Motorcycle Moving Behavior on Urban Mixed Lane

Key word:

Driving Behavior of Motorcycles ,Deep Learning,Prediction,Coordinate, Long Short-Term Memory Network

Name of Institute:

Graduate Institute of Transportation Science, Tamkang University

Graduate date: June 2018

Degree conferred: Master Degree

Name of student: Chien-Tin Wu 吳 建 霆

Advisor: Dr. Chun-Han Fan 范 俊 海 博士

Abstract:

Motorcycle is one of the Taiwan main transportation vehicles, they cannot follow the specific route, and always frequently parallel or overtake in the identical traffic lane. In the past research about motorcycle moving behavior that tring to use a single mathematical model to explain the Motorcycle moving behavior models and the moving behaviors of continuous overtaking. However, this paper considered that it’s difficult to explain and simulate the changeable motorcycles behavior pattern by a single model, and it's unable to reflect the true situation of the mixed urban road in Taiwan. Therefore, this paper is aimed at special driving state of the Motorcycles in Taiwan and behavior pattern in the mixed road of the general urban road is the main research subject.

This paper builds a predictive model of motorcycles moving behavior patterns, using the arithmetic structure with deep learning method. Establish the corresponding relationship between input and output variables of the motorcycles' forward direction and various influence parameters affecting the behavior. To obtain the complete traffic coordinates, using the coordinates of motorcycles with the camera coordinate conversion method, in order to make the prediction result approach the numerical coordinate prediction, using the special arithmetic structure of deep learning integrate coordinate and lattice concept. In the study, the motorcycles moving behavior is calculated in detail according to the coordinates of 25 propulsion modes ,with 25 influencing behavior parameters, establish a relational matrix in a continuous

time series and design the operational structure rules for deep learning .The model result shows that through the establishment of the mode, the motorcycles moving behavior was successfully divided into 25 travel modes, finally to perform pattern verification, divide 25% section of the data ,and verify another 75% . The mode prediction degree can reach 84%, which proves that the model predicts the motorcycles moving behavior is indeed feasible. Subsequent research can collect complete traffic information and perform simulation training based on the results of this research to establish a complete vehicle flow characteristic database.

Keywords: Motorcycle motion model, Deep learning, Prediction , Coordinate conversion, Long short-term memory method

According to “TKU Personal Information Management Policy Declaration“, the personal information collected on this form is limited to this application only. This form will be destroyed directly over the deadline of reservations.

表單編號：ATRX-Q03-001-FM031-02

目錄

第一章 緒論.....1
1.1 研究背景與動機.....1
1.2 研究目的.....2
1.3 研究範圍.....3
1.4 研究流程.....3
1.5 確定問題.....5
第二章 文獻回顧.....6
2.1 微觀車流模型.....6
2.1.1 變換車道與接受間距模型.....6
2.1.2 心理-物理門檻模型.....11
2.1.3 機車微觀模型.....12
2.1.4 微觀車流模型小結.....15
2.2 機車推進模式.....17
2.2.1 神經網路.....20
2.2.2 深度學習網路.....23
2.2.3 常見模型.....25
2.3 文獻小結.....30
第三章 研究方法.....31
3.1 循環神經網路.....31
3.2 長短記憶神經網路(Long Short-Term Memory, LSTM).....35
3.3 LSTM 反向傳遞過程.....43
第四章 資料蒐集與分析.....48
4.1 資料蒐集目的.....48
4.2 資料調查項目.....48

4.3 攝影測量 48
4.3.1 調查地點 49
4.3.2 調查工具 50
4.3.3 拍攝及調查作業 51
4.4 資料處理 52
4.4.1 投影模型 53
4.4.2 調查資料及環境空間分析 60
4.4.3 影響範圍空間定義 62
第五章 模式構建及驗證 68
5.1 模式構建 68
5.1.1 輸入變數 68
5.1.2 輸出變數 73
5.2 參數實驗及驗證 79
第六章 結論與建議 86
6.1 結論 86
6.2 建議 87
參考文獻 89

圖目錄

圖 1.1 研究流程圖.....4
圖 2.1 車輛間距設定.....8
圖 2.2 機車安全範圍.....12
圖 2.3 機車行進路徑.....13
圖 2.4 機車位能圖.....14
圖 2.5 神經網路示意圖.....20
圖 2.6 深層自編碼器結構.....26
圖 2.7 受限波茲曼機.....27
圖 2.8 自編碼器包含之 RBM 結構.....28
圖 2.9 卷積神經網路結構.....29
圖 3.1 循環網路結構示意圖.....32
圖 3.2 循環網路神經元結構示意圖.....32
圖 3.3 Elman 網路.....33
圖 3.4 Jordan 網路.....33
圖 3.5 循環單元展開.....35
圖 3.6 循環神經網路與 LSTM 結構對應關係.....35
圖 3.7 LSTM 記憶塊結構.....36
圖 3.8 記憶塊連結示意圖.....37
圖 3.9 控制開關與各單元之作用關係.....38
圖 3.10 Input Gate 輸出.....39
圖 3.11 Forget Gate 輸出.....40
圖 3.12 Cell 的輸出.....41
圖 3.13 Output Gate 輸出.....42

圖 3. 14 記憶塊各連接點權重.....43
圖 3. 15 LSTM 各連接點梯度值更新算法.....46
圖 4. 1 觀測路段示意圖.....50
圖 4. 2 路段空間幾何圖.....50
圖 4. 3 攝影圖像失真示意圖(圖來源:Tzu-Chang Lee, 2007).....52
圖 4. 4 攝影圖像扭曲.....52
圖 4. 5 相機幾何成像.....54
圖 4. 6 真實世界座標系統.....58
圖 4. 7 像素座標系統.....58
圖 4. 8 機車座標判斷位置.....61
圖 4. 9 機車尺寸所占空間座標.....61
圖 4. 10 資料形式.....62
圖 4. 11 機車橫向移動.....63
圖 4. 12 機車橫向影響變數空間.....63
圖 4. 13 速度與視野關係圖.....64
圖 4. 14 視野角度與橫向空間定義.....65
圖 4. 15 機車完整影響範圍空間定義.....66
圖 4. 16 目標車與範圍空間鄰車.....67
圖 5. 1 The Tensor's Flow at Time-Sequential Order.....70
圖 5. 2 初步實驗訓練結果.....73
圖 5. 3 機車偏移角度示意.....74
圖 5. 4 機車格位移動狀態.....75
圖 5. 5 第二次實驗網路結構示意圖.....76
圖 5. 6 第二次實驗訓練結果.....77
圖 5. 7 第三次實驗網路結構示意圖.....78

圖 5.8 第三次實驗訓練結果.....79
圖 5.9 資料填充排序.....80
圖 5.10 模式訓練圖(一).....81
圖 5.11 預測結果擬合圖(一).....81
圖 5.12 模式訓練圖(二).....82
圖 5.13 預測結果擬合圖(二).....82
圖 5.14 模式訓練圖(三).....83
圖 5.15 預測結果擬合圖(三).....83

國立淡江大學
TAMKANG UNIVERSITY
敦品 實學

表目錄

表 2-1 單一微觀車流模型與機車微觀車流模型比較 16

表 2-2 擠壓函數類型 21

表 4-1 測量工具 51

表 4-2 控制點調查結果 59

表 4-3 計算結果及其誤差 60

表 4-4 歷年機車實體尺寸統計表 61

表 4-5 速率與視野角度關係 64

表 5-1 車流資料編排形式 72

第一章 緒論

1.1 研究背景與動機

根據交通部統計，民國 106 年 8 月，台灣機車數量已經接近 2165 萬輛，機車為台灣最主要的交通工具之一，約佔台灣總車輛數的六成左右(交通部，2017)，其一大特色是車體小且機動性高，在市區道路行駛時，頻繁的加速、減速及不可預測的鑽縫行為等特性，儼然成為台灣交通的一大問題，每年因機車引起的交通事故也逐年增加，故機車的行為特性研究便成了一重要課題。

車流理論主要是分析及模擬，一般市區道路車流的行進模式及運行行為，根據觀測特性分為-巨觀、中觀、微觀等，車流模擬又分為單一車流及混合車流，在現代社會，運具越來越多元的情況下，單一車流模擬已無法表現汽機車混合的真實情況，而如何預測機車騎士的駕駛行為，許多研究以微觀車流模擬為主，車流模擬又大多以單一車流為主，對於多車種的車流模擬也無法有效表現出，機車在一般市區道路獨特的行車特性，所以本研究的探究重點是如何建立有效的預測模式，描述一般市區道路機車駕駛行為。

巨觀模型的車流理論中，主要探討車流的三大特性參數-流量(q)、密度(k)、速率(u)與時間(t)的分布關係，指一段時間或路段內之總體行為模式，巨觀車流模式運作成本較低，分析較為快速容易，可以在較短時間內將一路段的車流狀態以數學式表示之，得出結果可以使研究者，在短時間內大致了解一般道路之車流狀態，然而車流並非單一均質，在混合車流狀態下車輛與車輛間的互動關係會比單一車流複雜許多，針對模擬混合車流行為，特別是汽機車混合車流狀態時，則無法體現台灣機車在車陣中的鑽縫行為，微觀模型可以根據過去對自小客車研究中的跟車模式、間距接受模式、車道變換模式，將機車行為透過各種模式建立預測模型，模擬出較為合理的真實車流情形。

機車行進時，不會遵行於單一車道，可能會在同一車道併行或超車，Wolfram(1983)研究，將細胞自動機的運作機制引入車流模擬中，利用細胞自動機特性模擬一般道路駕駛車輛的隨機選位特性，再將選擇格位的決策行為模式運用各種預測模型帶入，而混合車流模擬研究中，Daganzo (1994; 1995)提出格位傳遞模式(Cell Transmission Model，CTM)，CTM，假設在一均質的系統中，將路段分割為若干格位，格位間皆為獨立，透過設計格位間「儲車空間」，求取最大容納密度，利用格位間的熵變化，決定車輛是否移動至下一格位，機車與汽車在同一道路運行時，各自對於時間與空間的要求皆不相同，車種間對於時間及空間會產生競爭關係，且汽車與機車對於鄰車之互動行為也不同，過去研究對機車跟車型危及變換車道的著墨，離真實車流還是有些差距，目前微觀車流模擬主要還是以汽車為主，雖然國外已經有學者試圖建立一套統一模型來描述機車行為，但對於機車的左右橫移及鑽縫的行為判斷仍有不足之處，要真正模擬出不斷變動機車移動行為龐大的計算過程會使模式變的複雜且繁複，故許多研究將機車的行進模式分為幾種行為類別模擬，但對於時間與空間不斷變動的機車車流來說，只分成幾種行為類別無法解釋複雜的機車移動行為，所以本研究希望透過深度學習理論，建立路段機車間的互動關係，模擬機車行進的真實行為。大多數的車流模擬都依據車道規範，及過去針對汽車開發的跟車模型越來越多預測模型已發展出，無論是規則的更新亦或是決策模式的改變，如何預測機車行為模式為本研究之重要課題。

1.2 研究目的

本研究主要目標為建構混合車流之機車行為模式的預測，建立目標機車與其空間內的鄰車互動關係，預測機車於一般市區道路行駛時的推進行為，透過模型建立及重新定義的影響參數，使機車的推進行為預測更能貼近實際車流。

1. 定義機車環境及周圍影響空間，設計影響機車行為變數，研究目標車對範圍內鄰車因各項參數的不同，目標車所採取之反應。

2. 以座標軸概念重新定義，機車環境及周圍影響空間並設定影響參數，透過攝影座標轉換方法，建立並說明像素點座標轉換為實際道路座標的一系列過程。

3. 建立深度學習演算法，長短時記憶神經網路(Long Short-Term Memory, LSTM)之機車行為模式，研究如何自有限的機車車流資料取得更準確之預測模型，並驗證預測模型的準確性及模式的可轉移性。

1.3 研究範圍

以台北市市區道路忽略汽車及公車，針對機車相互間的互動行為為主，道路上無公車專用道的單向四線道的 100 公尺路段車流，蒐集路段機車任意的跨越車道的穿行行為。

1.4 研究流程

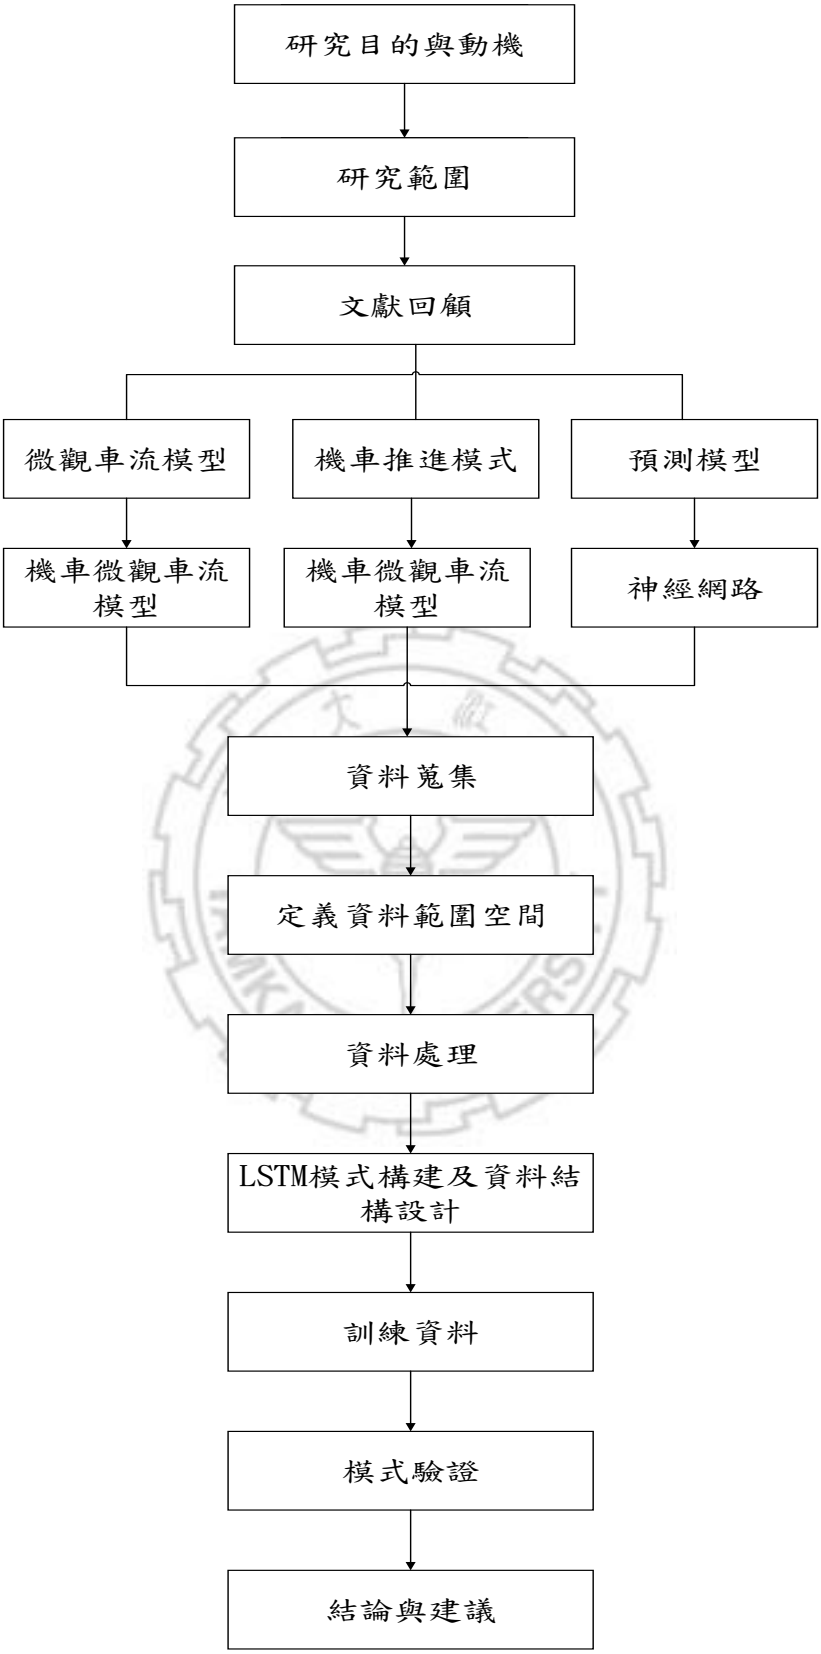
研究目的與動機
研究範圍
文獻回顧
微觀車流模型
機車推進模式
預測模型
機車微觀車流模型
機車微觀車流模型
神經網路
資料蒐集
定義資料範圍空間
資料處理
LSTM模式構建及資料結構設計
訓練資料
模式驗證
結論與建議

圖 1.1 研究流程圖

1.5 確定問題

本研究針對一般市區道路，汽機車混合車流中的機車行為模式為研究主體，隨著台灣機車數量越來越多，機車不會遵行既有的車道行駛，尤其在台北市區汽機車混合車道設置情況下，鑽縫行為會隨時發生，其不可預測的駕駛行為，使過去對混合車流模擬的研究變得越來越不合時宜，所以在執行台灣的道路車流模擬時，勢必無法遵循舊有的的模擬方法，本研究利用深度學習理論以時間序列方式建立機車預測模型，最後透過實際車流的驗證，校估模式的準確性。

第二章 文獻回顧

2.1 微觀車流模型

微觀車流模擬發展至今有多種模擬方法，並圍繞三個課題，分別為:

1. 跟車模型(Car-Following Theory)
2. 變換車道模型(Lane Changing models)
3. 接受間距模型(Gap Acceptance models)

過去汽車為主的單一車流模擬研究中，架構微觀模擬模型時，上述三種決策模式可能會隨時間間隔連續發生，而模擬汽機車混合車流的機車行為時，根據機車行為研究(2015)說明，以上三種行為決策，若用來解釋機車行為則可能會在同一時刻發生，機車行駛於市區道路時常左右橫移及斜向跟車，其特殊的鑽縫行為最有直接關係的模型可能是變換車道模型與接受間距模型，鑽縫行為主要考慮的是，假設機車遭遇前方車輛阻礙，是否左右橫移變換車道換取可容納的位移空間進行超車行為。

2.1.1 變換車道與接受間距模型

跟車模型為單一車道車輛前後跟車行為，指的是一維空間上車輛間的時間與空間的間隔，假設車輛有變換車道行為，此過程會自一維跳脫至二維空間，混合車流狀態下，機車的變換車道行為比一般自小客車更加明顯，機車常受到前方車輛阻礙或不滿意鄰車速度，從而執行變換車道超車，由於機車體積小，機動性及操縱性高，對於前方車輛行為能立即做出反應，故機車並不是遵循傳統變換車道模型中的實體車道運行，準確的說，是經由不斷的橫向偏移取得更大行駛空間求得更大的速度。

Gipps(1986)研究，認為變換車道前的決策行為比變換車道本身還重要，是首先從駕駛者決策發想的學者，該研究提及三個主要的課題，並從三個方向討論駕駛人的變換車道行為，包含:變換車道的可能性(Possible)、必要性(Necessary)及期望(Desirable)，該研

究提到駕駛者會根據前方車輛的間距大小而決定是否超車，接受的間距大小則根據Gipps(1981)的跟車模型判斷。

$$v_n(t+T)=b_nT+\sqrt{\left\{b_n^2T^2-b_n\left[2(x_{n-1}(t)-s_{n-1}-x_n(t))\right]-v_n(t)T-\frac{v_n^2(t)}{\hat{b}}\right\}} \qquad (2.1)$$

其中:

v_n ： 車輛 n 之速度

b_n ： 駕駛者在時間內的最大減速度

T ： 反應時間

$x_n(t)$ ： 在 t 時間，前後車之間程

s_{n-1}:車輛 n 與車輛 n-1 之停等間程。

$\hat{b}$:第 n 輛車駕駛者估計前車之減速度。

該研究說明，駕駛者會希望以期望速度行駛於道路而選擇變換車道，假設變換車道後行車速度得到提升，則駕駛者會接受較小間距，提出幾種變換車道之決策點:

- 車道的選擇
- 改變車道的可能性
- 駕駛者在意圖改變車道前的行為
- 改變車道的急迫性
- 通過的車道與車輛

駕駛人以速度作為變換車道的考量因素，在決策範圍內駕駛人需選擇正確車道，但假設駕駛人的當前速度低於期望值在十秒內的話，駕駛人則會選擇在原車道行駛，此時期望速度便不是變換車道重點，駕駛人的接受間距也會相對縮小。

Yang and Koutsopoulos(1996)等人研究，利用模擬軟體 MITSIM 模擬車道變換模式，設定三個步驟:

1. 確認變換車道的必要性及確認其變化類型

2. 選擇需要車道

3. 假設間距為接受間距則選擇變換車道

變換車道模型及接受間距的判斷則根據 Gipps(1986)模型，該研究在接受間距的判別上也發展一套運作模式。

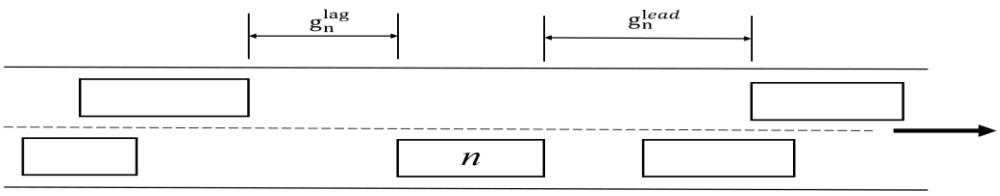

圖 2. 1 車輛間距設定

變換車道可接受之間距公式如下式:

$$g_n^i = g + \varepsilon_n^i \qquad i=lead、lag \tag{2.2}$$

其中:

g_n^i ：駕駛者 n 認為之最小接受間距。

g^i ：平均接受間距。

ε_n^i ：誤差項。

該研究說明駕駛者在迫於變換車道條件時的接受間距，會小於任意變換車道的接受間距，強制變換車道接受間距如下式:

$$g_n^i = \varepsilon_n^i + \begin{cases} g_{\max}^i & x_n \geq x_{max} \\ g_{\min}^i + (g_{\max}^i - g_{\min}^i)\dfrac{(x_n - x_{\min})}{(x_{\max} - x_{\min})} & x_{min} < x_n < x_{max} \\ g_{\min}^i & x_n \leq x_{min} \end{cases} \tag{2.3}$$

其中:

g_n^i: 駕駛者 n 在強制變換車道時之可接受間距

g_{max}^i、$g_{\min}^i$ ：可接受間距之上下限

x_n ：第 n 輛車當前位置

x_{max}、x_{min} ：g_{min}^i到 g_{max}^i之臨界距離

ε_n^i ：誤差項

變換車道模式除了以車道選擇、接受間距為主要模擬方法外，另一種為蒐集車輛個別資料，以預測模型分析的個體選擇模式(Discrete choice-based models)，選擇可能影響車道變換之參數，運用於效用函數中，算出不同車道選擇變換的機率 。

Ahmed(1996、1999)等人研究，蒐集美國地區車輛之變換車道行為，將其模式化以羅吉特模式預測，研究首先將車道變換分為兩個方向，分別為被迫變換車道(Mandatory lane changing)及任意變換車道(Discretionary lane changing)，用兩組實際高速公路車流數據分別發展兩種模式，變換車道模式選定一城市高速公路交流道匯入主要車道部分，當車輛進入主要幹道時，駕駛人必須判斷前方及後方車輛間距才有可能變換車道，任意變換車道研究則選定一四車道快速道路，當駕駛人意圖向左變換車道時，則間距的判斷則根據接受間距模型來判斷是否變換車道，將兩組車流數據及參數共 4335 筆資料建立模式預測。

上述研究將變換車道行為分為兩種模式，分別為被迫變換車道(MLC)、 及任意變換車道(DLC)，Toledo(2007)等人整合兩種模式概念，該研究認為，模式存在兩種問題，其一，這兩種變換車道模式沒有存在較為合理的分辨依據，其二，在許多情況下，強迫變換車道為不可預期狀況，但過去研究假設強迫變換車道狀在已知的情況下會發生，造成許多實際狀況無法分析及校估，所以提出新概念結合兩種狀況，建立新的變數帶入羅吉特模式中，該研究重新定義四項新的解釋變數:

- 周圍環境影響變數:

車輛的周圍的環境及鄰車都會影響駕駛人的行為決策。

- 路徑影響變數:

  目的地、路徑及到達時間，決定可能影響駕駛行為，駕駛人必須改變車道才能按照他們的規劃行駛最佳路徑及正確的車道。

- 經驗影響變數:

  駕駛人的道路認知及偏好會影響變換車道，例如，高速公路近交流道處駕駛人會靠左行駛，以免與車交會。

- 駕駛行為影響變數:

  駕駛人的駕駛習慣及行為特徵等。

國內對汽機車混合車流模型變換車道部分的模擬研究，黃國平(1982)在車輛變換車道的決策加入與前車之偏向角的大小，與前車的偏向角大於目標車道前車的偏向角時才可成立條件，何佳娟(2001)在汽機車混和模擬中的變換車道決策使用上述之偏向角度的計算公式及過程，並設定機車的鄰近車道與機車本身之靜態車寬加上動態側向間距，張維翰(2006)則是參考徐立新(2005)的偏向角設定方法，蒐集車流資料建立多元迴歸模型設定偏向角變換車道模式。

接受間距模型與變換車道行為兩者是密不可分的關係，當變換車道行為發生時，駕駛人會檢視其目標車道的前車與後車距離，也就是可接受間距(Available Gap)與臨界間距(Critical Gap)，Daganzo(1981)探討接受間距與時間的關係，透過資料蒐集，推斷出駕駛人選擇接受間距的最大概似參數，建立普羅比模式預測接受間距參數，將不同駕駛人選擇不同的臨界間距誤差的隨機項算出，接受間距會受到目標車道之前後車之影響，必須在兩者都在接受範圍內才有可能執行超車或變換車道的行為，上述 Gipps(1986)跟車模型接受間距及 Yang and Koutsopoulos(1996)文獻中模擬使用的 lead 及 lag 概念，在個體選擇模式中，Ahmed(1996、1999)等人則說明 lead 及 lag 兩種間距會因為強制變換車道及任意變換車道而有所不同。

2.1.2 心理-物理門檻模型

傳統跟車模式 GM 模型中，敏感度之運算過程會直接與距離產生影響，

$$a_{n-1}(t+\Delta t)=\frac{\alpha[v(t+\Delta t)]^m}{\Delta S(t)^l}[v_n(t)-v_{n-1}(t)] \tag{2.4}$$

也就是說，只要l值不為零，敏感度都會產生作用，對於實際車流狀態並不合理，在心理-物理門檻模型中，將前後車車距定義兩點概念:

- 前後車距離在特定範圍外時，後車不會受前車影響。
- 前後車距離在特定範圍內時，在某些速度與距離下，後車不會受前車影響。

Rainer Wiedemann(1974)以數學模式建構駕駛人的心理及行為門檻，應用在微觀車流模擬中，重新將跟車模式中的刺激反應過程重新分為三階段區分，分別為感知反應區、無感知反應區及無反應區，感知反應的判定在於，與前車車速過慢是否會影響後車行為有關，無反應區則為後車完全不受前車影響，該研究定義四種駕駛模式，分別為跟車模式(Car Following Model)、煞車模式(Braking Model)、漸進模式(Approaching Model)及自由行駛(Free Driving Model)模式，將跟車模式各項參數門檻值以數學模型表示，分別為下列參數:

1. 靜態間距
2. 最小跟車間距
3. 最大跟車間距
4. 感知速差門檻
5. 跟車間距上限
6. 間距漸減速差門檻
7. 間距漸增速差門檻

此模型被應用於車流模擬軟體 VISSIM 的跟車行為模式中，使其更能進真實車流行為，證實了環境及心理確實是影響駕駛行為的因素之一，該研究將真實駕駛情況分類並模式化以數學模型表示之，作為車流模擬模型之參考依據。

2.1.3 機車微觀模型

機車的行進行為不遵循實體車道行駛，機車在一般道路行駛的移動及互動複雜，傳統的單一車流模型不考慮車輛的橫向位移，使得真實的道路機車行為無法被表現出，近年來越來越多研究探討機車的鑽縫行為，對機車行為模式建構模型，試圖在各種模擬模型中體現真實的機車車流行為。

Nguyen(2012)等人提出機車在道路行駛所需要之空間及行為模型，並提出安全空間等概念，假設機車行進時周圍會形成一半橢圓形的空間線，將空間大小分成不同安全等級根據距離、速度、車輛大小、駕駛反應時間設定。

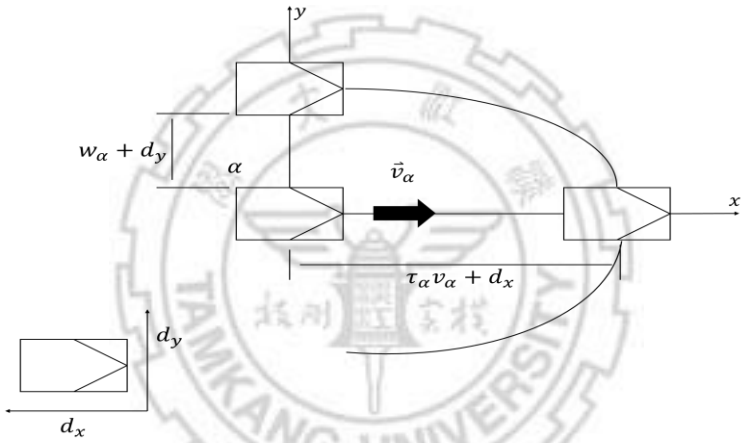

圖 2. 2 機車安全範圍

其中:

τ_α ：鬆弛時間，即為機車α避免與前車撞之反應時間

v_α :機車α之速度

W_α ：機車α與側向機車之距離

整體模式隨速度變化，模式中假設機車α速度為v_α，加減速度則會因鄰車β速度而有所改變，與鄰車β的速度差$v_{\alpha\beta}$就會成為影響機車α安全距離的變量之一，所以加速度公式為: $a_\alpha(t+T_\alpha) = -\nabla_{v_{\alpha\beta}} v_\beta(t)$，公式的意義為當鄰車β逐漸遠離目標機車α時，目標車會加大

安全層級並提升其速度，反之安全層級降低並減速，由上述可知該研究將機車安全空間看作一個半橢圓，加速度模式可以改寫成:

$$a_\alpha(t+T_\alpha) \ = -\nabla_{v_{\alpha\beta}}\left\{Aexp\left[-\left(\frac{x^2}{(\tau_\alpha v_\alpha+d_x)^2}+\frac{y^2}{(W_\alpha+d_y)^2}\right)/B\right]\right\} \qquad (2.5)$$

A 和 B 為該模型之參數，該研究認為不是每台鄰車都會對目標車產生影響，根據周圍鄰車加速度來判斷，$max\{\|\vec{a}_{\alpha1}\|$、$\|\vec{a}_{\alpha2}\|$、.....$\|\vec{a}_{\alpha n}\|\}$，使得此模型相對變得簡單，因為影響機車的行為變得只和機車的加速及減速有關，條件還加入　　跟車角度，駕駛人跟隨前車加速需考慮，與前車角度是否符合該研究所定義之偏向角，也就是駕駛人認為之最安全角度。

過去多篇研究於安全距離及機車間距的設定，會將駕駛人心理因素列入駕駛行為的考量因素中，而 Inagaki and Uchida(2004)將機車左轉及右轉的事故評估加入機車車流模擬之中發展出駕駛人行駛於道路時，會因心理壓力因素對前車及鄰車保持的距離轉換為類似於物理學位能的評估模型(Potential model)，Ishizaka(2010)等人將機車行為設定為三種行進路徑，並利用上述位能模型(Potential model)作為模式基礎。

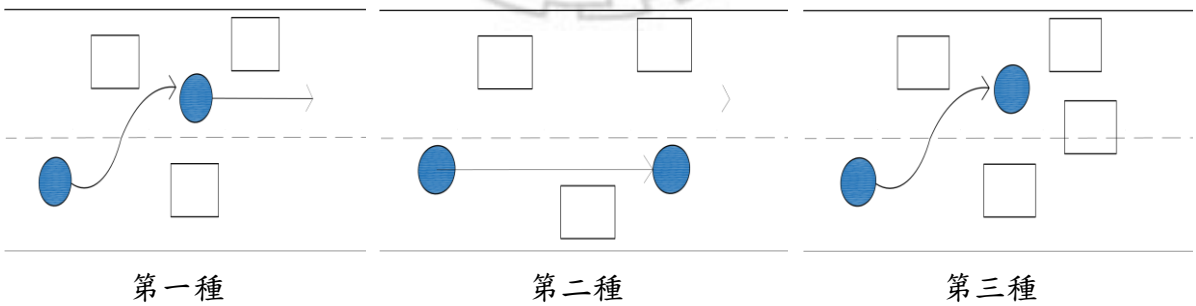

圖 2. 3 機車行進路徑

該研究將機車的移動以能量形式計算，機車的移動特性則會往耗能最少，也就是位能最少的地方走，位能形式則按圖，移動方式劃分參考下圖的三種方式，位能計算公式及步驟則使用該研究發展之對數方程式

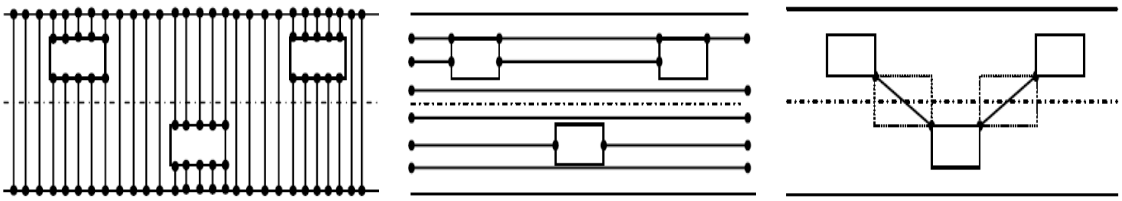

第一種　　第二種　　第三種

圖 2. 4 機車位能圖

利用電腦模擬證實，該模式確實能表現出機車在一般市區道路的行為模式，但模式缺點為該研究將機車的行進模式設定的過於制式，機車在道路上的推進行為有時只是類似於補位的概念，故本研究認為機車駕駛行駛機車時有時並不是以安全為第一考量而是速度。

Huynh(2013)等人研究，運用於行人的模擬模型(Social Force Model)應用於機車的行為模擬，包含使其改變方向和速度的力量，模式假設三種作用力，驅動力(Driving Force)指機車按照需要的方向移動之作用力，排斥力(Repulsive Force) 避免與鄰車或靜止障礙物發生碰撞，吸引力(Attractive Force) 則是機車往目標路線行駛的作用力，該研究將三種作用力依照機車特性重新定義，機車在自由行駛時會往方向$\overrightarrow{e_\alpha}$移動，$\overrightarrow{e_\alpha}$假設為方向之期望值與速率相乘，為期望速度$v_\alpha^0\overrightarrow{e_\alpha}$，可將加速力表示為下列形式:

$$\overrightarrow{F_\alpha^0} = \frac{1}{\tau_\alpha}(v_\alpha^0\overrightarrow{e_\alpha} - \overrightarrow{v_\alpha}) \tag{2.6}$$

τ_α為其鬆弛時間，驅動力提供一個機車前進之動力，值越小表示期望速度越低，而期望速度指的不是到達目的地之速度，而是抵達下一個拐彎點，為了避免相互碰撞及保持安全距離，該研究也提出相似的安全空間概念，假設機車行駛於一般道路時會在周圍形成一橢圓空間，當接近鄰車時會降低行駛速度猶如周圍形成一股排斥力，表示為下列形式:

$$\overrightarrow{F_{\alpha\beta}} = A_{\alpha\beta}e^{-\frac{b}{B_{\alpha\beta}}}\ \overrightarrow{n_{\alpha\beta}} \tag{2.7}$$

其中$A_{\alpha\beta}$、$B_{\alpha\beta}$為參數值，b 值為橢圓半長軸表示下列公式:

$$\mathrm{b} = \frac{1}{2} \times \sqrt{\left(\left\|\overrightarrow{r_{\alpha\beta}}\right\| + \left\|\overrightarrow{r_{\alpha\beta}} - \Delta t \Delta v_{\alpha\beta}(t)\overrightarrow{e_\beta}\right\|\right)^2 - \left(\Delta t \Delta v_{\alpha\beta}(t)\overrightarrow{e_\beta}\right)^2} \tag{2.8}$$

然而機車行駛時不只對鄰車產生作用力，也會對建築物及道路邊界產生作用力，此時需把橢圓半長軸換成與道路邊界距離:$\overrightarrow{r_\alpha} - \overrightarrow{d_{\alpha B}}$，第三為吸引力，

機車行駛時通常會往機車群行駛，該研究認為吸引力與距離和時間有關，吸引力隨時間減少，表示為下列形式:

$$\overrightarrow{W_{\alpha i}} = C_{\alpha i} e^{\frac{d_{\alpha i} - (r_\alpha - r_i)}{D_{\alpha i}}} \overrightarrow{n_{\alpha i}} \tag{2.9}$$

其中:

$d_{\alpha i}$：車輛 α 與車輛 i 之距離。

r_α、r_β：車輛 α 與車輛 i 半徑。

$C_{\alpha i}$、$d_{\alpha i}$：待校估參數。

之後定義各種作用力之邊界條件，只有當受影響車輛與影響車輛之間的距離達到一定值時，斥力和吸引力才發生。

2.1.4 微觀車流模型小結

傳統跟車模型試圖使用簡單的公式模擬車輛在一般路行駛的各種行為，但常忽略駕駛人及車輛之各別特性，程凱健(2014)研究中提到，Gipps 跟車模型在現今複雜的車流狀態來看過於保守，對於安全距離的判定標準有時已不適用，Gipps 模型修正了以往刺激反應方程式的兩項缺點，第一為蒐集的歷史數據好壞對結果會產生很大的影響，第二為刺激反應方程式中的沒有將各別車輛特性參數列入模式考量，將超車行為帶入傳統跟車模式局限於單一車道，從一維空間跳脫至二維空間，發展出變換車道模式，變換車道

為一複雜的隨機過程，駕駛人需在短時間內做出決策，包含是否維持原車道，向左向右變換等，大多數研究變換車道模型不包含其加速減速過程，只和駕駛人之期望速度，前後車的接受間距與臨界間距有關，Ahmed(1996、1999)等人定義出兩種決策方向分別為被迫變換車道(Mandatory lane changing)及任意變換車道(Discretionary lane changing)，將過程整理可以將變換車道分為三項基本流程:

- 變換車道之必要性
- 變換車道後是否符合駕駛人之期望速度
- 間距是否可以執行變換車道

進一步考慮模型合理性及車輛性能等個別因素，使模型貼近真實情況，實驗是否符合現實。

表 2-1 單一微觀車流模型與機車微觀車流模型比較

比較	傳統單一車種微觀車流	機車微觀車流模型
影響車輛	單一車輛	周圍鄰車
維度	一維	二維
路徑選擇	實體車道	虛擬車道
模型基礎	刺激反應模型及物理運動模型	駕駛人心理及周遭影響安全範圍模型
橫向位移	車道變換超車行為	隨時發生
模型困難度	較簡單	較複雜

資料來源:程凱建(2014)

機車微觀模型，過去研究對機車行為描述甚少，上述回顧之機車模式大部分集中於台灣、日本、越南等地，機車不遵循實體車道的行為模式，目前作法是將跟車模型和變換車道模型結合為統一模型探討，更深入研究二維機車微觀車流模型，過去單一車流以

心理反應模式配合物理運動公式為模式基礎，機車模式則加入了鄰車及周遭事物的影響參數，機車的行為模式中，鄰車及周遭事物的影響會明顯於傳統單一車流，且為了尋求最短路徑及獲得期望速度，及避免與前車追撞，在接近前車時會出現變換車道行為，而一般車流不擁擠的情況下，機車傾向隨時變換車道的駕駛行為，以佔有獨立的車道空間，鑽縫行為橫向位移特性會隨時發生，故下列章節文獻將以機車推進模式為主。

2.2 機車推進模式

本章節重點回顧機車推進模式研究，機車在一般道路行駛中的隨機推進特性，如何預測其行為模式及行進路線，過去研究中使用多種模擬方法解決，包含羅吉特模式、類神經模式、模糊理論、細胞自動機模式等，上述研究機車微觀模擬模型中試圖建立一通用的模擬模型描述機車行為，本研究認為機車行為模式偏向一隨機過程。

林育瑞(2002)以類神經演算法建構機車車流模式，該研究將機車尺寸及車道寬度重新定義，將一般市區道路分成若干格位，不定義汽車及機車道，也不定義變換車道行為，改以橫向座標之變化量取代，稱為橫向位移量，該研究發展一整合車流模型，使汽機車在同一模擬平台運行，研究重點在於影響變數設計及選取其影響變數，機車無法使用傳統跟車模型，因駕駛人無法在該車道以預期速度行駛而改變車道，駕駛人變換車道之判斷依據，類神經網路蒐集 1195 筆車流資料資料訓練，蒐集路段車輛之參數為:

- 目標車速率
- 鄰近車輛速率
- 鄰近車輛與目標車速率差
- 鄰近車輛與目標車距離
- 鄰近車之相對位置
- 鄰近車與目標車縱向距離
- 鄰近車與目標車橫向距離
- 鄰近車與車道緣距離

該模式目的在於表現機車車流行為，但不刻意表現變換車道及跟車模式，所以不會有加速率值的產生，將變換車道與跟車合併為橫向位移輸出資料，如此雖可推得機車行進之橫向分量與偏移的角度，但卻無法決定推進橫向分量之方向，研究設計幾項影響橫向變量方向之變數，包括前車與後車之相對速率、橫向距離、縱向距離及前車與車道邊緣的間距，建立一邏輯判斷規則，使機車在遭遇前方車輛阻檔時，選位行為有方向判斷的邏輯依據，研究最後用統計檢定方法驗證其誤差值，得到良好績效，但模式只完成純機車車流模式，未將其他車種行為模式納入模式中，以至於該模式只適用於機車專用道，對於嚴重的汽機車混合現象仍不適用。

謝志偉(2010)提出混合車流格位傳遞模式，為中觀及微觀模式的混合運用方法，格位傳遞模式將道路劃分為若干格位，車輛與車輛間的互動皆在格位內進行，以往格位傳遞模擬混合車流方法是將不同車種以不同當量數轉換，該研究首度提出混合車流的格位傳遞模式，試圖真正模擬混合車流之模擬模型，研究重點在混合車流格位傳遞模式構建，與上述林育瑞(2003)研究以類神經演算法建構的機車車流模式不同為，格位傳遞模式是傳遞車輛與車輛間之互動訊息資料，也就是車輛間之流量(q)、速度(u)、密度(k)與時間(t)關係，各格位間設定可容納之最大車輛數與容量等因素之門檻值，不同車種在格位運行時須考慮其時間與空間分配，不同車種在同一道路行駛會因時間及空間的不同需求產生競爭關係，當汽車在道路空間已處於飽和狀態，機車仍有空間行駛，該研究將不同車種間之競爭關係分為三種:

- 無競爭關係:

  表示兩種混和車種的密度流量皆在限制範圍內，使車輛訊息可以順利傳遞至下一格位。

- 最大流量競爭:

將汽車與機車在格位間的流量函數關係以百分比表示，汽車出現數量越多會壓縮機車數量之百分比，車種間以各自的流量公式及混合流量公式相互影響，比如當汽車數量為零競爭函數則為 100%，表示機車最大流量在無汽車干擾下沒有損耗，反之汽車數量越多則會壓縮機車之流量空間，最大流量公式設定為:

$$\mathrm{i}\,Q_i^c(t) + \alpha \times Q_i^m(t) = Q_i(t) \tag{2.10}$$

其中:

$Q_i^c(t)$為汽車流量

$Q_i^m(t)$為機車流量

α小客車當量數

- 剩餘儲車空間:

  汽車與機車所占格位不同且道路空間有限，在單一車種中的模擬只須看單一車種密度是否已達飽和，但機車在汽車密度已達飽和的狀態下，仍能有空間行駛傳到下個格位內，所以該研究以汽車及汽車所佔之格位數當作基準，並以車當量數的換算為參考依據，之後將擁擠車流衝擊波特性考慮進去。

為了使模式貼近真實，該研究對最大流量與最大儲車空間，訂定不同競爭函數，也就是在同一格內所佔有之通一車種車輛數量，其互動關係會有所不同，為不同車種在車隊中所佔之比例，兩車種比例越接近，車種的分佈越平均互動越激烈，在激烈互動過程中會影響車隊行進速度，進而影響最大流量。

張正達(2012)研究機車在一般道路行駛時，是否會因周圍鄰車而影響行徑行為，該研究不探討個別行為的反應模式，而是將機車影響範圍訂定領地格位，將機車行徑模式分為前進、向左、向右三個方向，當周圍領地被車輛占領時目標機車的推進方向，並將周圍環境空間訂定14個領地格位，蒐集1453筆道路車流資料建立羅吉斯迴歸模式，預測結果有80%的準確率，故具有相當程度可以預測機車於車陣中行進時的推進行為 。

2.2.1 神經網路

類神經網路為一經驗建模的方式，資訊的處理結構設計成模仿生物神經系統的處理方式，藉由不斷的修正模型參數，找出最佳的函數及所需之模型參數，經驗建模在數學技巧上可想像為，自大量的數據中取得最適當之擬合曲線，類神經網路透過網路的輸入與輸出關係，於隱藏層中進行無數次模擬，反覆計算更新修正權重找出最適當的模式，輸出與輸入間的關係特性不需定義複雜的數學模式，而是藉由學習的方式解決，藉由大量資料訓練取得的權重更新方式及調整速度，透過結構上的改變、神經元間的鏈結連接方式，或調整神經元間活化函數之門檻值配合不同的線性搜尋方法等，故神經網路的內部形式常以小單元形式處理節點與節點間的相互關係狀態。

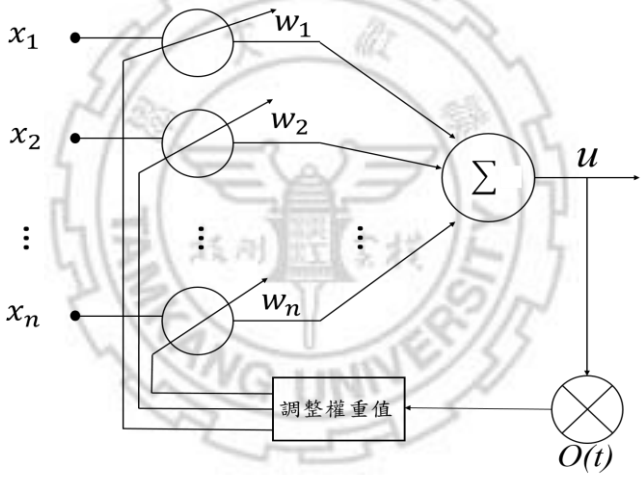

圖 2. 5 神經網路示意圖

神經網路的組成為一大型函數，包含多個輸入與輸出值，而各項參數值就是各連結點的權重值，在訓練過程中權重值會不斷調整，所以函數可以逼近任何的連續函數，以單層的感知器網路為例，假設輸入向量 x，隱藏層單元 h，輸入向量經由輸入單元至隱藏層單元以a_h表示，擠壓函數以θ表示:

$$a_h = \sum_{i=1}^{I} w_{ih} x_i$$

$$b_n = \theta_h(a_h) \tag{2.11}$$

w_{ih}為節點 i 至 h 的權重值，擠壓函數θ視資料類型和網路形式決定，而常見擠壓函數為表 2.2 所示，透過擠壓函數的線性或非線性的集合單元可將函式輸出為非線性分類或線性函數等，所以神經元輸出則根據資料類型決定輸出單元數及使用的擠壓函數類型等。

表 2-2 擠壓函數類型

函數名稱	輸入與輸出	縮寫	說明
硬限制擠壓函數	$a = 0, n \leq 0$ $a = 1, n > 0$	step	將輸出 n 數值控制為 0 或 1，當 n 大於 0 則輸出為 1，否則為 0。
對稱硬限制擠壓函數	$a = -1, n < 0$ $a = 1, n \geq 0$	sgn	將輸出 n 數值控制為 1 或-1，當 n 大於 0 則輸出為 1，否則為-1。
線性擠壓函數	$a = n$	Linear	n 本身為輸出 a
飽和線性擠壓函數	$a = 0, n < 0$ $a = n, 0 \leq n \leq 1$ $a = 1, n > 1$	Ramp	n 小於 0 時輸出為 0，當 n 在 0 到 1 區間時輸出為 n，當 n 大於 1 時輸出為 1。
對數雙彎曲擠壓函數	$a = \frac{1}{1 + e^{-n}}$	Sigmoid	無論 n 值為何，將其值控制於(0,1)的開區間內。
正切雙彎曲擠壓函數	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	Tanh	無論 n 值為何，將其值控制於(-1,1)的開區間內。

資料來源:本研究整理

一、監督式學習(supervised learning):

監督式學習為，在學習過程中所更新的權重，可以不斷地往所給予的訓練範例問題中，逼近其目標值，也就是每一個訓練範例會包含輸入及目標輸入值，而目標輸出值會不斷地監督修正權重值，藉由訓練過程調整鍵結連接度的強弱，來降低輸出值與輸入值之誤差，值至誤差小於臨界值。

二、非監督式學習(unsupervised learning):

非監督式學習只需在訓練過程提供輸入資料，網路會根據輸入向量的特性學習並調整權重，非監督式學習是一種深度學習的特徵過程，利用學習網路找出分類規則，而類神經網路本是一種分類過程，利用數據的特徵找出其本質加以分析，在非監督式學習沒有輸出值分類特性，也就是無誤差值可以表現出改善範圍，所以須配合監督式學習，監督訓練的微調參數，故在訓練過程中找出最適權重及函數的自我修正則為網路學習之重點。

網路的架構型態與網路之學習能力有極大的關係，網路之隱藏層神經元太少，無法處理複雜事件，反之會造成效率不佳及過擬合問題，網路深度大小及結構，則需要視資料型態和所需輸出值之精準度等，網路的形式架構可分為前饋式網路及迴饋式神經網路。

一、前饋式類神經網路(Feedforward):

前饋式類神經網路，為單一向前傳遞之網路架構，所有神經元皆無向後或側向傳遞，通常使用結構為多層前饋網路(Multilayer Feedforward Network)，多層網路和單層網路最大區別在於隱藏層神經元，隱藏層主要功能為加權輸入層之數值，輸入值經加權後加上偏權值，並經過多層數的模擬，便可處理單層網路不能處理的複雜問題。

二、迴饋式類神經網路(Feedback Networks):

迴饋式神經網路主要為迴饋圈之設置，網路架構是將同層神經網路訊號，回傳至同層的其他單元或前一層之神經元作為輸出資料，而迴饋式網路架構通常用於處理動態現象或時間序列，因為在其網路架構上，資料回傳至同層或前層之神經元時會產生對時間

延遲，學習資料更可因為遞迴項的運算加強網路的學習能力，尤其是在非線性的動態系統。

三、網路架構

類神經網路的架構，在於映射出輸入與輸出間關係之數學式，決定權重 W 與偏權值 b 則取決於結構中之訓練過程及模擬過程，在訓練過程中的網路架構則遵循於學習規則，所以各種不同類型的網路結構有其不同的訓練過程及演算法(Algorithm)，輸出及輸入資料類型也是決定網路結構的重要因素，資料必須透過適當轉換，反映問題及其變數之特性，變數的轉換則根據不同網路結構決定不同的轉換函數，學習過程也就是訓練過程(Traning)，而上述提到的監督式學習與無監督式學習，差別在於對權重的搜尋過程，如何從所謂的機器學習跳脫至更深一步的深度學習，最大的差別為此一過程，無亦是網路架構的改變，或是權重的更新及搜尋方式，結構的改變甚至影響輸入及輸出資料之型態。

2.2.2 深度學習網路

深度學習為機器學習的延伸類型，基礎為類神經網路，而與一般機器學習不同的是，深度學習主要探討其學習架構及訓練方式，與類神經網路有著相似的架構，包含輸入層、隱藏層、輸出層等，但並不是將神經網路加深加大即為所謂的深度學習，深度學習探究的是學習技巧和架構，如:限制波茲曼機（Restricted Boltzmann Machine, RBM）、卷積神經網路(Convolutional Neural Network, CNN)、遞歸神經網路(Recurrent Neural Network, RNN)、深度信念網路(Deep Belief Neural Network)等，皆以神經網路為基本概念，但在其結構、訓練方式、梯度計算等皆有所不同，故深度學習本質在於推理，如何於相同的函數底下，應用較少的資料量模擬出合理且準確的結果，在一般機器學習的學習框架下，可能意味著需要大量的輸入及學習資料，而深度學習便可以從有限的資料量得到更好的學習效能，其一就是從訓練網路結構上的改變。

李弘毅(2016)，對深度學習說明，曾有一度，深度學習和多層感知器差異在於，隨機初始化參數叫多層次感知器，用限制波茲曼機(Restricted Boltzmann Machines, RBM)初始化的稱為深度學習，現今的深度學習網路架構為了處理語音辨識及影像辨識，所以隱藏層層數比過去的學習框架來的多，一般認為只要隱藏層層數足夠多，就能夠在固定區間內逼近任何多變量的連續函數，也就是趨近於目標函數，Hochreiter(1991)，研究說明，典型的深層網路，如果層數越多，容易造成梯度消失及梯度爆炸問題(the problem of vanishing or exploding gradient)，該問題為，神經網路在隱藏層中反向傳遞過程的累積誤差會隨著層數的堆疊出現指數衰減或增長現象，造成數值收斂過快或是過度發散，也就是倒傳遞神經網路結構無法利用深層網路運算的主因，在機器學習分類方法中大部分為淺層結構，包含一組輸入層、隱藏層、輸出層，根據 Bengio(2009)定義，深層網路由多層自適應性且非線性的單元組成，也就是神經網路的隱藏層是非線性模式的集合體，所有隱藏層都包含了訓練參數，而理論上淺層網路和深層網路的數學描述是類似的，都能夠透過函數逼近的方式去表達數據間的關係特徵，但在處裡真實情況的複雜問題時，淺層網路所訓練出的函數往往會有表達能力不足等問題，故深層網路概念將許多的相似結構模塊堆疊，並按順序分層訓練，和前饋式網路概念相似，深層網路模塊皆包含一個線性的輸入層，非線性的隱藏層及線性的輸出層，堆疊的過程為經所有層數的輸出向量預測和輸出值向量經過層數的累積成為新的向量，經由不斷的堆疊更新輸入及輸出並更新權重值，深度學習初期設計本質為，透過不斷的堆疊隱藏層數及利用極大量的數據學習提高預測準確率。

隱藏層單元數的設計及層數設定有時依資料類型不斷嘗試及模擬決定，但深度學習一部分的設計結構可以用來設計解決此一問題，如上述所提，受限制波茲曼機(Restricted Boltzmann Machines, RBM)，RBM 網路結構能利用基本模型來構築 Auto Encoder 模型及深層信念網路(Deep Belief Net, DBN)，RBN 可以用來堆疊多個模型結構，為一非監督式模型，主要用途為將資料數據重新編碼後做分類迴歸，故 RBN 為一資料降維方法，能快速找尋資料特徵並使用適合資料之結構形式，深度學習經由不斷的訓練過程調整梯

度值，大多數使用手法為隨機梯度下降，每次只選一組樣本執行梯度下降減少計算量，故可以較容易遇到局部之最優解，在訓練資料過程中將輸出資料批次分割，可以將梯度以小批次最佳化以減少模式計算，卷積神經網路(Convolutional Neural Network, CNN)為目前深度學習最常使用的模型架構，其結構可以看做是由多層特殊結構的感知器網路組成，藉由局部神經元連結可以共享部分權重值，主要針對二維圖像識別設計，特性是可以將資料平移或縮放的情況下保持資料的不變性，但為了使模型有上述特徵所以將網路結構進行了相關限制，包含特徵的提取、特徵輸入及輸出限制，及抽樣的限制等，因網路結構針對圖像設計，所以將多維矩陣進行分層處理，並找出核心矩陣以該矩陣為基礎提取特徵後，並反覆運算分享權重，在學習特徵值的提取上與其他網路結構不同，CNN透過持續減少樣本誤差，修改內部參數不斷地最佳化模型特徵值，所以與大多數訓練模型基於統計學習特徵，也就是在樣本進行分類時就先提許特徵值的學習方式有明顯不同，也使模式更容易執行，透過結構的堆疊重組減少特徵值的提取，可以逐步減少資料的處理量，而深度學習涉及多種的理論基礎，包含矩陣運算、機率理論、結構模型、蒙地卡羅模型及馬可夫鏈等理論，不同的結構模型所使用的模型基礎亦有不同，因網路的生成有時須靠概率計算將運算網路結構模擬出來，如受限波茲曼機(Restricted Boltzmann Machines, RBM)，深層信念網路(Deep Belief Network, DBN)，深層波茲曼機(Deep Boltzmann Machines, DBM)，現有的分類模型中，淺層的模型結構可以解決大部分的分類問題，但面對極大量的資料及複雜的分類計算問題時，淺層網路往往會限制問題處理的能力，造成效率不佳，模式無法收斂等問題，深度學習的本質在特徵學習，而特徵的學習過程可以透過大量的數據或網路模型結構的改變獲得。

2.2.3 常見模型

自編碼器(AutoEncoder)

自編碼器模型主要用來對多維的數據重新編碼進行壓縮處理，將資料降維並處理數據間的編碼轉換，所以通常使用在對深層神經網路建立初步的網路結構，自編碼器通常

具有相對的輸入與輸出，對數據重新編碼與解碼調整向量維度，而自編碼器的結構類似傳統的前饋式神經網路，包含輸入與輸出的映射過程，假設輸入、隱藏層、輸出為 x、h、o，則編碼器公式可以寫作:

$$h(x) = \sigma_h(W_x + b) \tag{2.12}$$

其中:

W:編碼權重矩陣

b:標碼權重偏權值

σ_h(x):擠壓函數

資料重新編碼後需要重新解碼，方能得到資料重建後之數值，所以將輸出函數 o 寫作下列公式:

$$\mathrm{o(x)} = \sigma_o(W' h(x) + b') \tag{2.13}$$

其中:

W':解碼權重矩陣

b':解碼權重偏權值

σ_o(x):擠壓函數

自編碼器可包含多個隱藏層，但須配對編碼與解碼結構神經元，結構須符合對稱結構，隨著隱藏層層數增加為深層自編碼器結構，如圖 2.6 所示，包含 m 個神經元，輸入向量 $\mathrm{x} \in R^m$，對應隱藏層向量$\mathrm{h} \in R^{n_k}$，及輸出向量$\mathrm{o} \in R^m$，

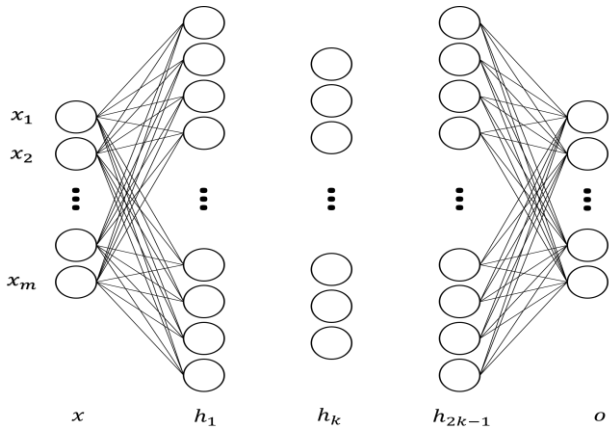

圖 2. 6 深層自編碼器結構

由於結構的類似，自編碼器理應可以透過倒傳遞演算法(BP 演算法)，學習權重及計算誤差值，但得到結果常為不穩定的狀態，甚至設定的網路過於複雜導致模型無法收斂，故使用兩階段的訓練方法，分別為先利用無監督學習訓練將網路結構大致建立出，再利用監督學習訓練將網路結構逐步調整至最佳狀態，故建立自編碼器的核心算法為無監督訓練，訓練過程初期先將網路的權重及誤差偏權值訓育訓練至範圍內，再逐層堆疊建立完整的計算結構。

受限波茲曼機(Restricted Boltzmann Machines, RBN)

波茲曼機通常具有兩層結構，分為可見層及隱藏層的隨機概率模型，單元間的的分布情形為任意的指數分布，如圖 2.7 假設可視層結點數 m，

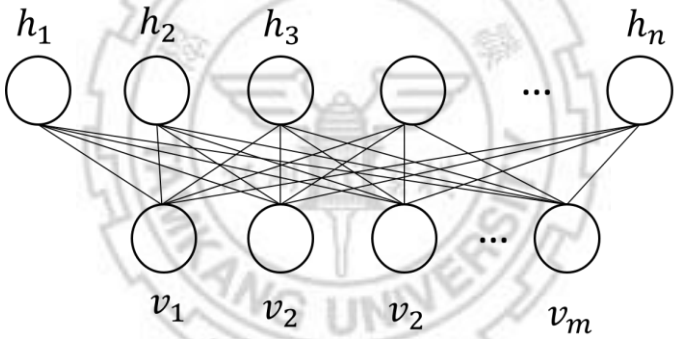

圖 2. 7 受限波茲曼機

其中有 j 個結點的輸入假設為v_j，隱藏層結點數為 n，其中有 i 個輸出結點假設為h_i，則可令可視層的向量為$v = (v_1，v_2，v_3，\ldots，v_m)^T$，隱藏層向量為$h = (h_1，h_2，h_3，\ldots，h_n)^T$，所有的隱藏層結點及可見層結點的單元數值皆為 0、1 的二元數值分布，可表示為∀i，j，$v_j \in \{0，1\}$，$h_i \in \{0，1\}$，將 RBM 的能量函數表示為:

$$\mathrm{E} = (v，\mathrm{h} \mid \theta) = -\sum_{i=1}^{n}\sum_{j=1}^{m} w_{ij} h_i v_j - \sum_{j=1}^{m} a_j v_j - \sum_{i=1}^{n} b_i h_i \tag{2.14}$$

θ為 RBM 的各項參數值，包含隱藏層及可見層間的連接權重值w_{ij}，a_i為可見層之偏權值，b_j為隱藏層之偏權值，則可根據這些參數得出 RBM 的聯合機率分布為下式:

$$p(v,h\,|\,\theta)=\frac{1}{Z(\theta)}e^{-E(v,h|\theta)}=\sum_{v\text{，h}}e^{-E(v,h|\theta)} \tag{2.15}$$

其中$Z(\theta)$為一函數將因子歸一化，則 v 的機率分布 $\underline{P}$(v|θ)可表示為:

$$p(v,h\,|\,\theta)=\frac{1}{Z(\theta)}e^{-E(v\text{，}h|\theta)} \tag{2.16}$$

若將可見層及隱藏層單元的概率分開表示為:

$$p\ (h_j=1\,|\,v,\theta)=\sigma\ (b_j+\sum_i v_j w_{ij}) \tag{2.17}$$

$$p\ (v_j=1\,|\,h,\theta)=\sigma\ (a_j+\sum_i w_i h_i) \tag{2.18}$$

σ為擠壓 sigmoid 函數，而 RBM 為一無監督學習可以做為自編碼器學習訓練過程的一部分，自編碼器結構將每相鄰的兩個層數看做一 RBM 結構堆疊，分別做為其輸出及輸入，如圖 2.8 所示。

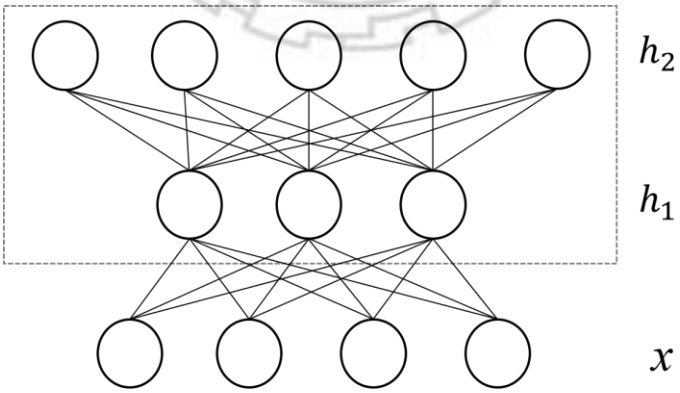

圖 2. 8 自編碼器包含之 RBM 結構

卷積神經網路(Convolutional Neural Network, CNN)

卷積神經網路(CNN)是根據人類的視覺系統構造發展的的網路模型，屬於一多層次結構的學習演算法，透過層級的堆疊可以減少每一次學習循環的過程中的參數量，和一班的神經網路不同的是，CNN 模型每一個層級為二維平面，平面由多個神經元組合而成，所以可以堆疊深度的網路結構，通常網路分為輸入層、卷積層(convolution layer)、下採樣層(downsamping layer)、全連接層(fully-connected layer)、輸出層等構造，通常輸入層為矩陣型態，CNN 網路結構通常發展用來最為圖像辨識，因為其網路結構，如圖 2.9 所示，具有平移、旋轉及尺寸的不變性。

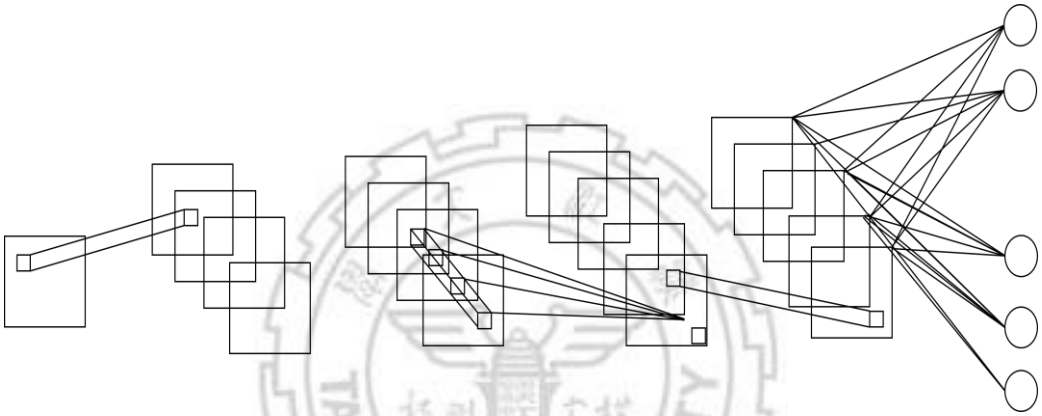

圖 2. 9 卷積神經網路結構

CNN 訓練過程可以分為兩階段，分別為向前傳播及向後傳播階段，首先先從樣本數據中，提取一子樣本數據(x_p, y_p)作為結構核心，再根據核心逐層變化計算其輸出o_p。

$$o_p = F_n(\dots(F_2(F_1(x_p w_1)w_2 \dots)w_n) \tag{2.18}$$

再來計算實際值與計算值之誤差，將誤差反向傳遞不斷地疊代調整，將公式寫作下式:

$$E_p = \frac{1}{2}\sum_j (y_{pj} - o_{pj})^2$$

卷積神經網路特色是可以保持其高度的不變性，保留特徵並可以平行處理，所以對於多維的輸入矩陣可以避免在特徵提取過程中進行過多的重複運算，而共享的權重值也可以有效地的應用，進而減少網路結構的複雜度及縮減運算過程。

2.3 文獻小結

本章節透過三個部分說明車流模式及機車車流模擬，以微觀車流模式探討車輛間的相互影響關係，藉由傳統單一車種車流模型運用至混合車流機車與鄰車間互動模式，說明兩種不同車種模式之間的差異關係，過去對於跟車行為研究試圖用統一模型探討車輛之變換車道及超車行為，包含 Gap 模型及 Gipps 跟車模型等，定義個別的模式需求及找尋其共通點，而模式的最大目標為探尋各項模式之穩定狀態，無論是接受間距或跟車模型，乃至於依據駕駛者心理狀態設計的心理物理模型或刺激反應方程式等，但許多研究成果多著重於汽車的不同狀態的下的車流分析，對於機車車流的接受間距模型或變換車道模型中，變換多端機車行為的各種不穩定的狀態下，有時無法將模式以數學式表示之，雖過去研究也有對汽機車混合車流開發各項模擬研究，但其中的推進邏輯明顯與現實情況有所差異，故本研究目的為發展機車之行為模式，對於機車車流，傳統汽車車流模式的車道觀念並不適用於機車行為，應以不同的邏輯定義機車推進的跟車及變換車道鑽行行為，過去研究中對於機車安全範圍的設定、偏向角的設計、與鄰車的錯車行為的研究皆有其各自論述觀點，本研究參考過去研究對機車的安全空間定義及行為模式，重新定義安全空間設計及推進規則，作為變換車道行為的各項參考依據，並利用二維座標的車輛判別，預測機車於時間序列下的推進行為，對於預測方法本研究回顧林育瑞(2002)、謝志偉(2010)、張正達(2012)等人對於機車的推進行為研究，而本研究試圖利用深度學習的架構方法建構符合機車推進的預測模型，設計輸入與輸出變數並探討變數間的相互關係。

第三章 研究方法

3.1 循環神經網路

機器學習可以從一系列的相關數據中，找出規律並自動分析，利用蒐集的歷史資料尋找其規律特徵，對新的未知數據進行預測，雖然機車及汽車皆行駛於一般市區道路上，但機車在機動性、操作性、道路占用面積、行駛間距等，皆與汽車明顯不同，相較於汽車，機車的駕駛行為更能變化萬千的機車表現個別差異，過往的傳統車流模擬以汽車與機車間的當量轉換方式處理混合車流，此種方式無法有效表現出機車騎士，駕駛行為的個別差異。過去多篇研究試圖對機車建立行為模式，包含機車行駛空間的設定、跟車模型設計、行駛偏向角、側向間距研究等，替機車的行為建立統一模型及預測其行為模式，而對於連續車流的時間與空間關係，周圍鄰車隨時間不斷變動的速度與位置，在過去研究使用的預測模型中，張正達(2012)研究說明，在現實社會的個體選擇模式中，類別型分類模式的結果可能比數值型來有意義，但本研究認為，複雜的機車車流行為模式中，將機車行進模式分成少數幾種行為類別，建立預測模型是不夠的，如何從有限資料中做更精確的分類預測，甚至接近於數值型的分類結果。過去的分類模式中，對特定的資料獲取學習特徵進行分類預測時，往往需要大量資料支撐，而深度學習架構優勢在於，可以利用較少的資源提取大量的學習特徵，在有限的機車行為參數下，預測機車移動模式。

處理時間序列的資料時，資料須依賴過去的時間訊號對新的預測產生合理的數值，前饋式網路結構雖可以分析數據間的相互關係，但無法處理連續的時序資料，循環網路藉由在前饋網路的連接層中加入迴饋層，可以對數據產生記憶效果，故能處理時序資料並建立不同段序列資料間的依賴關係，如圖 3.1 及 3.2 所示。

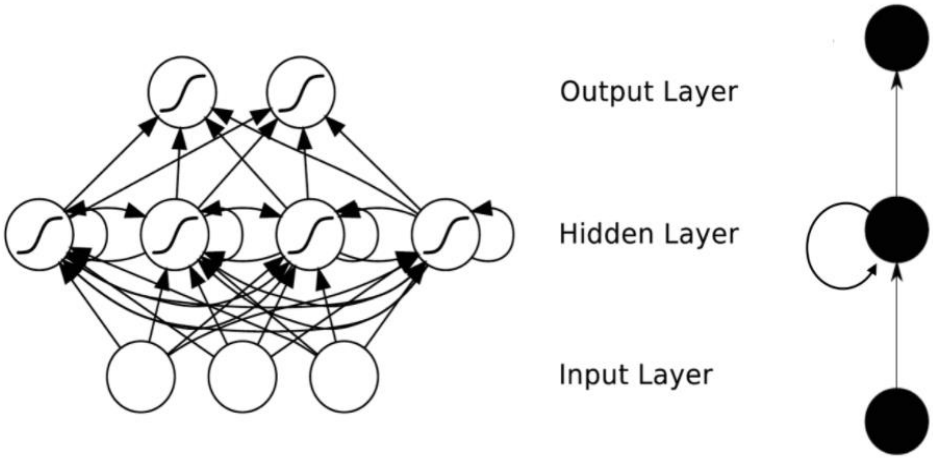

圖 3. 1 循環網路結構示意圖

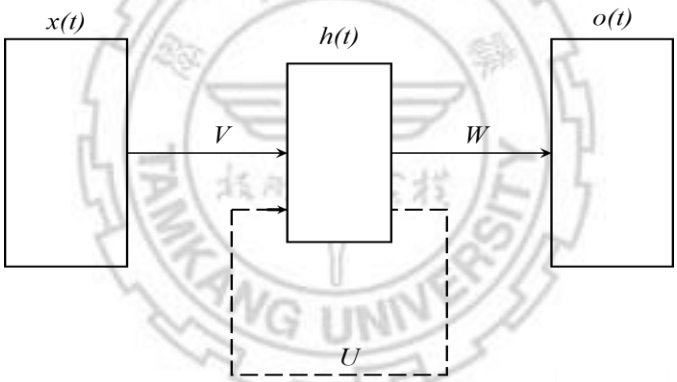

圖 3. 2 循環網路神經元結構示意圖

x(t)、h(t)、o(t)分別為輸入層、隱藏層、輸出層，標準的循環網路結構類型分為 Elman 及 Jordan 網路，Elman 網路結構包含從隱藏層節點至下一時序資料的輸入節點的回饋連接，及前一時序的輸入資料及下一時序輸入資料節點的前饋連接，此結構包含的意思為，上下時序的數據輸入是隱藏層上一個時刻的輸出，如圖 3.3 所示。

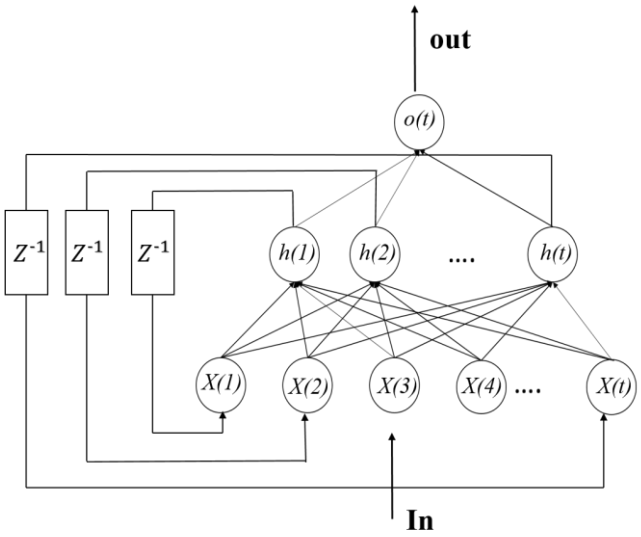

圖 3. 3 Elman 網路

Jordan 網路則包含前一時序輸出層的節點至下一時序輸入層的節點的反饋連結，及前一時序與下一時序訊號的前饋連結，也就是下一時序的輸入訊號包含前一個時序訊號的輸出，而前後時序的連結點允許自回饋，如圖 3.4 所示。

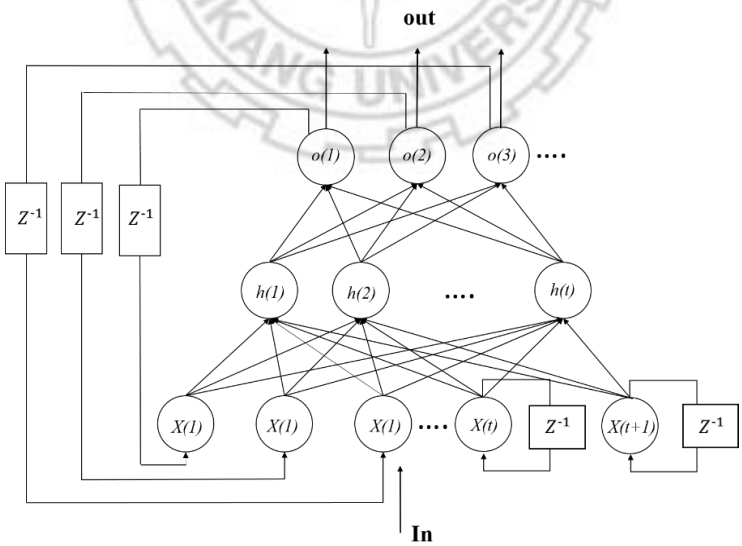

圖 3. 4 Jordan 網路

循環神經網路可用來分析時間序列中的關聯性，處理任意時間的輸入序列，循環網路的深度及長度皆與時間長度相關，依照上圖兩種網路架構所示，輸入向量 *x(t)*及輸出向量 *o(t)*皆依照時間序列排序，資訊會相互依賴並共享權重值，將 Elman 網路計算過程整理為:

$$\begin{cases} h(t) = f(u(t)) = f(Vx(t) + b, t = 0 \\ h(t) = f(u(t)) = f(Vx(t) + Uh(t-1) + b), 1 \le t \le T \\ o(t) = g(v(t)) = g(Wh(t) + a) \end{cases} \tag{3.1}$$

其中 *U* 為隱藏層間的權重值，*W* 為輸入層與隱藏層間的權重值，*h(t)*為隱藏層向量，*b*、*a* 分別代表輸入及輸出層之偏權值，函數 *g* 及 *f* 激活函數，Jordan 網路計算過程整理為:

$$\begin{cases} h(t) = f(u(t)) = f(Vx(t) + b), t = 0 \\ h(t) = f(u(t)) = f(Vx(t) + Uo(t-1) + b), 1 \le t \le T \\ o(t) = g(v(t)) = g(Wh(t) + a) \end{cases} \tag{3.2}$$

其中 U 代表輸出層回饋至輸入層的連接權重值。

循環網路的構造核心是能將先前的訊息連結到當前的計算中，不斷的反向傳遞及訓練，若將 Elman 網路單元展開，如圖 3.5 所示，時序資料會隨著時間拉長而增長，但如果資料時間過長，未來的時序資料無法將後面的新訊息傳遞給較早的輸入，所以當資料有著對時間長期依賴的問題時，循環網路的處理能力會資料長度慢慢減弱，更新的權重也會隨著時間的推移趨近於零，誤差梯度也會累積至一個相當大的數值。

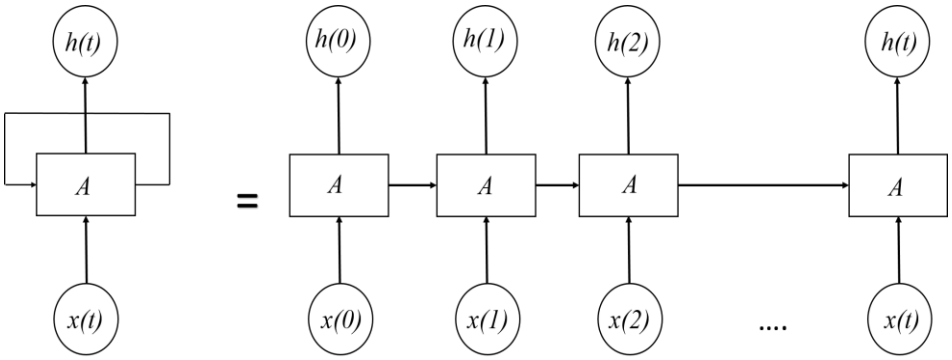

圖 3. 5 循環單元展開

3.2 長短記憶神經網路(Long Short-Term Memory, LSTM)

為避免隨時間增長的車流資料可能導致梯度消失或梯度爆炸問題，本研究運用循環網路的改進模型「長短時記憶神經網路(LSTM Network)」，LSTM 將一般的循環網路隱藏層加入記憶模塊(Memory Block)，使資料梯度不會隨著時間增長消失或爆炸，每一個記憶模塊對應一組輸出及輸入，如圖 3.6 所示，包含記憶單元(Memory Cell)、輸入擠壓函數單元(Input Squation Unit)、輸入門控制單元(Input Gating Unit)、輸入門單元(Input Gate Unit)、輸出門單元(Output Gate Unit)、輸出擠壓函數單元(Output Squation Unit)、輸出門控制單元(Output Gating Unit)，藉由記憶塊，LSTM 模型可以將資料任意延遲，傳送至先前的資料訊號。

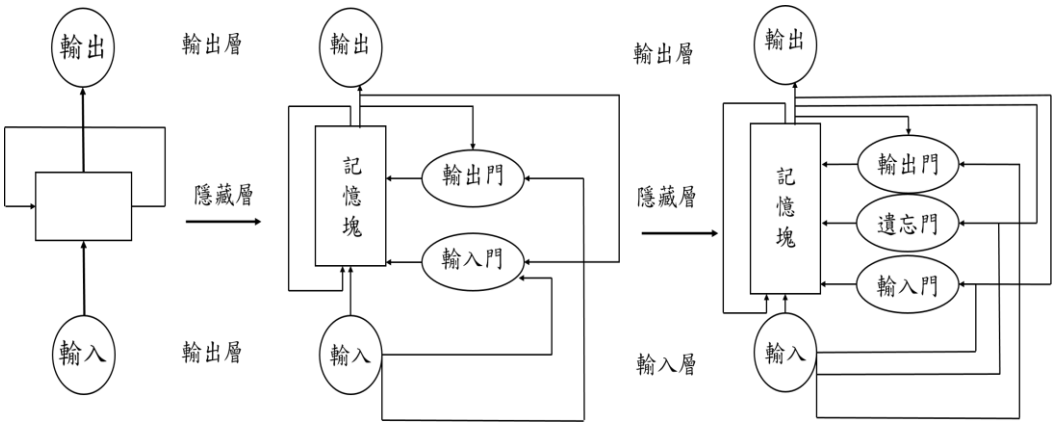

圖 3. 6 循環神經網路與 LSTM 結構對應關係

循環網路使用的擠壓函數為 sigmoid 函數，在 LSTM 的結構則以雙曲正切函數 tanh 取代，擠壓函數在輸入門單元中對資料 *x(t)*進行非線性轉換，轉換為固定範圍內的函數值，並根據設定範圍值決定通過的訊息流，過濾後的向量值 *g(t)*與輸入門單元向量值 *i(t)*內積，而遺忘門則是對 *x(t)*和s_c*(t-1)*的加權值經擠壓函數啟動後，產生向量 *f(t)*，再與的前一刻狀態之向量值s_c*(t-1)*內積，輸入記憶細胞，使記憶細胞狀態刷新，記憶細胞可將目前狀態更新決定記憶塊是否將訊息忘記或刷新，記憶細胞連接一條自迴饋線(Contant Error Carousel, CEC)，並藉由內部線性函數使通過的誤差值調整為常數權重值傳遞，故不會造成梯度爆炸或梯度消失，與上述之向量值結合可表達成函數 $s_c(t) = s_c(t-1) \circ f(t) + i(t) \circ a_c(t)$，輸出門單元為對 *x(t)*及 *h(t-1)*的加權值經 tanh 函數擠壓後產生輸出向量 *o(t)*，輸出擠壓單元對上述$s_c(t)$乘上擠壓函數產生向量 tanh(s_c*(t)*)，經由輸出門控將輸出向量 *o(t)*，及記憶細胞函數經擠壓函數後之向量 tanh(s_c*(t)*)內積，即產生向量值$b_c(t)$，如圖 3.7 所示。

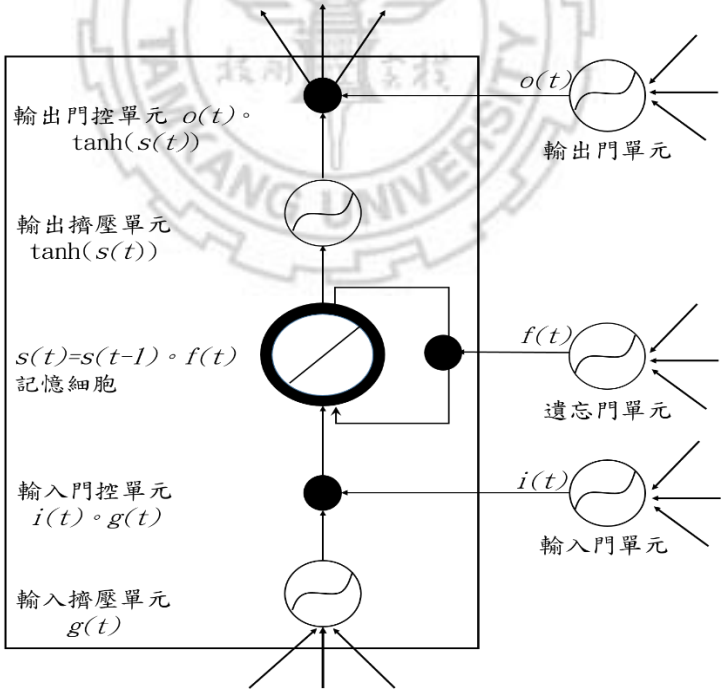

圖 3. 7 LSTM 記憶塊結構

由上述結構圖可知，網路結構包含三個控制開關，故結構在於控制及保存時間長期依賴的輸入及輸出值，部分推導參考 Morris_mao(2015)文章，如圖 3.8 及 3.9 所示。

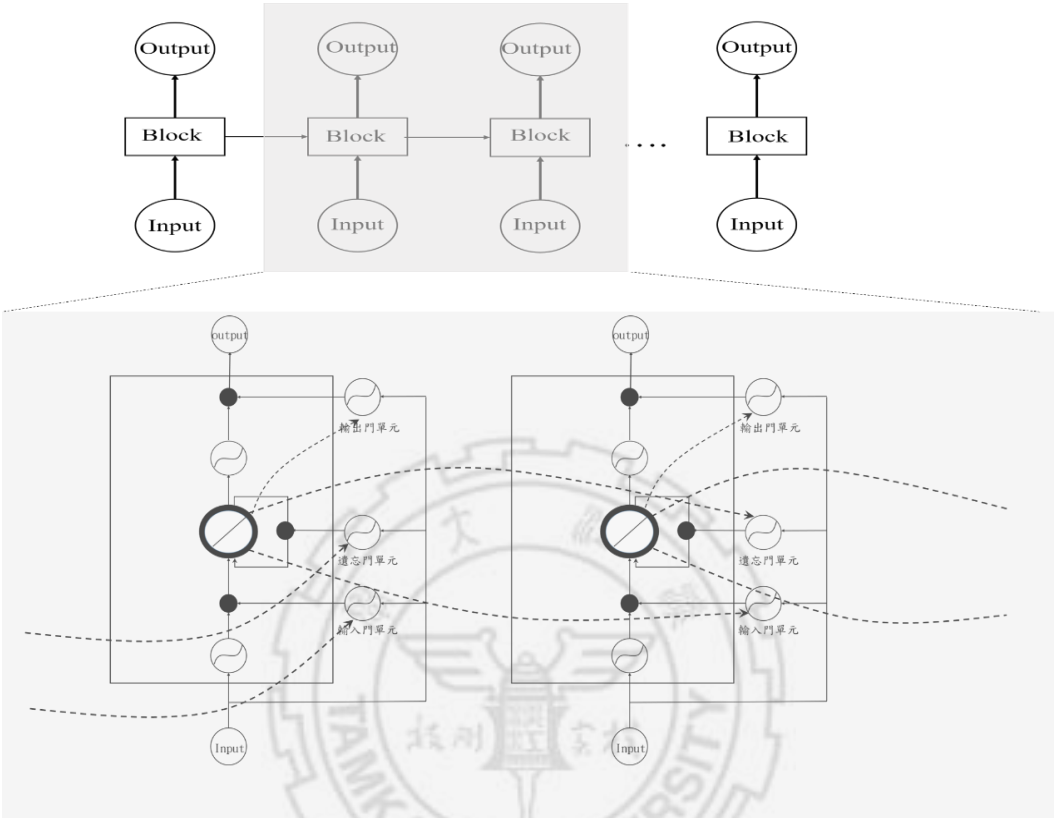

圖 3. 8 記憶塊連結示意圖

根據研究資料形式決定隱藏層大小及及記憶塊個數，本研究資料的 LSTM 隱藏層大小及記憶塊個數估算會在之後章節說明，記憶塊內可能包含多個記憶細胞，假設每個記憶塊只存在一個記憶細胞，則可以將長短時記憶神經網路結構在某一時刻 t 下的計算過程表示為下列計算過程，並將上述控制閥的運算寫作下列之數學式。

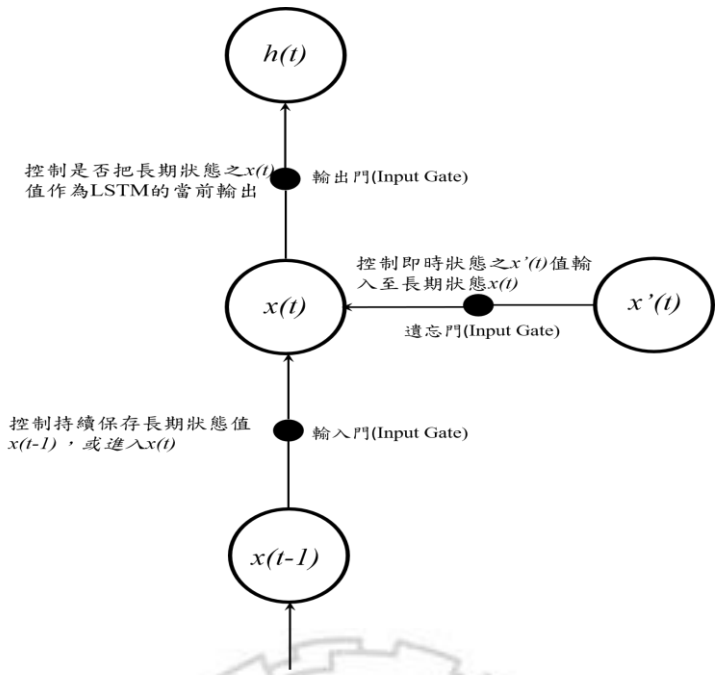

圖 3. 9 控制開關與各單元之作用關係

Input Gate(l)計算為兩個值的輸入，分別為當前時刻值之 Input 值 *x(t)*，及上一個時刻且同一個 Block 內的 Cell 值 *h(t-1)*，故 Input Gate 的輸出值可寫作:

$$i(t) = \sum_{i=1}^{I} w_{il} x(t) + \sum_{c=1}^{c} w_{cl} s_c(t-1)$$

輸出: $b_l(t) = \tanh(i(t))$ (3.3)

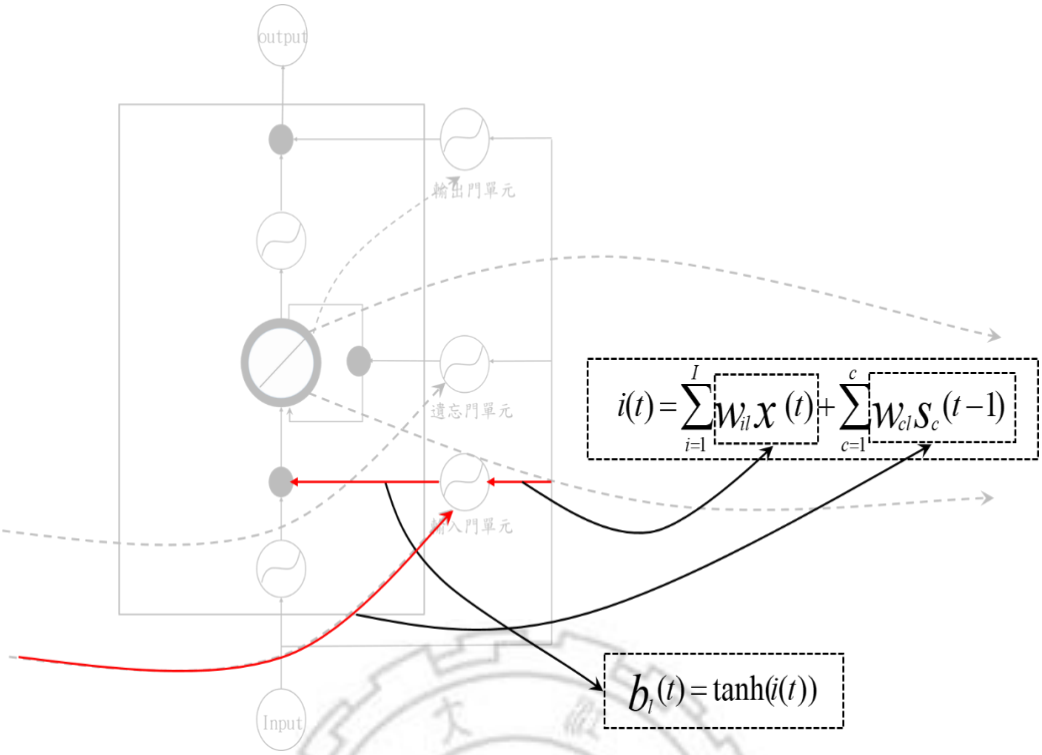

圖 3. 10 Input Gate 輸出

Forget Gate(ϕ)計算為接受當前時刻的 Input 輸入值 *x(t)*，及上一個時刻 Block 內所有的 Cell 值 *h(t-1)*，故 Forget Gate 的輸出值可寫作:

$$f(t)=\sum_{i=1}^{I} w_{i\phi} x(t) + \sum_{c=1}^{c} w_{c\phi} s_c(t-1)$$

輸出: $b_\phi(t)=\tanh(f(t))$ (3.4)

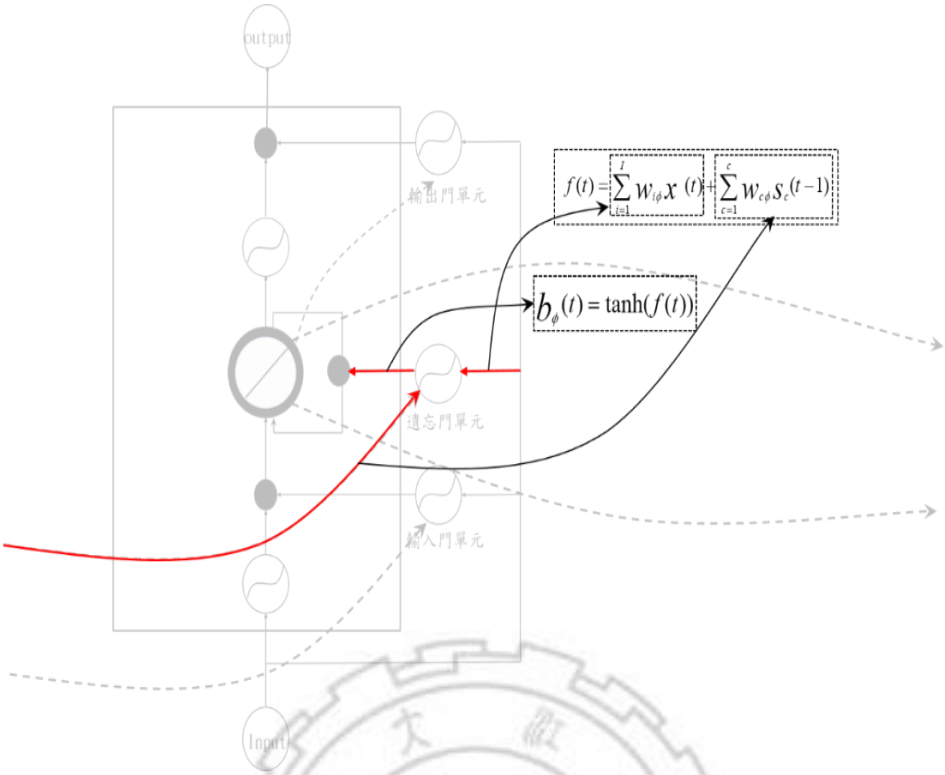

圖 3. 11 Forget Gate 輸出

Cell(c)計算為兩個值的輸入分別為 Input Gate 和 Input 輸入的乘積及 Forget Gate 和上一個時刻之對應 Cell 輸出的乘積，故 Cell 的輸出值可寫作:

$$
\begin{aligned}
a_c(t) &= \sum_{i=1}^{I} w_{ic} x(t) \\
s_c(t) &= b_\phi(t) h(t-1) + b_l(t) \tanh(a_c(t))
\end{aligned}
\tag{3.5}
$$

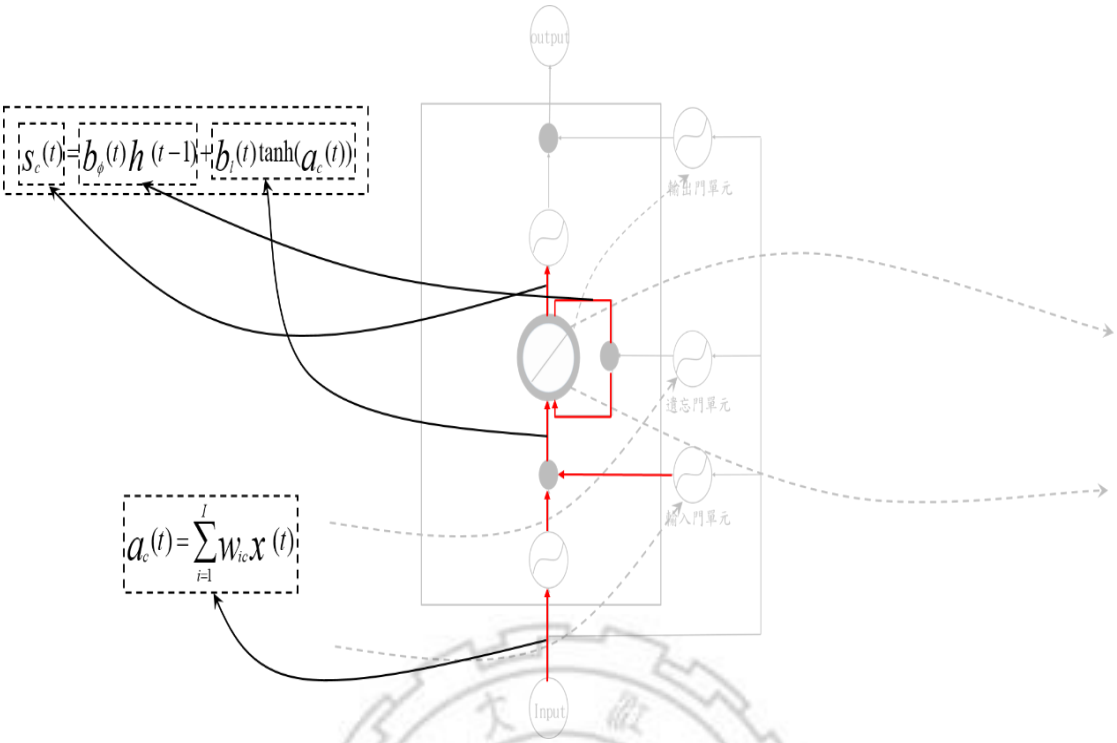

圖 3. 12 Cell 的輸出

分別包含 Cell 的輸出$a_c(t)$及自迴饋$s_c(t)$。

Output Gate(ω)計算為兩的值的輸入，分別為當前時刻的 Input 值 *x(t)*，及當前時刻 Block 內之 Cell 值$h_c(t)$，故 Output Gate 輸出值可寫作:

$$o(t)=\sum_{i=1}^{I} w_{i\omega}x(t)+\sum_{c=1}^{C} w_{c\omega}x\ s_c(t)$$

輸出: $b_\omega(t)=\tanh(o(t))$ (3.6)

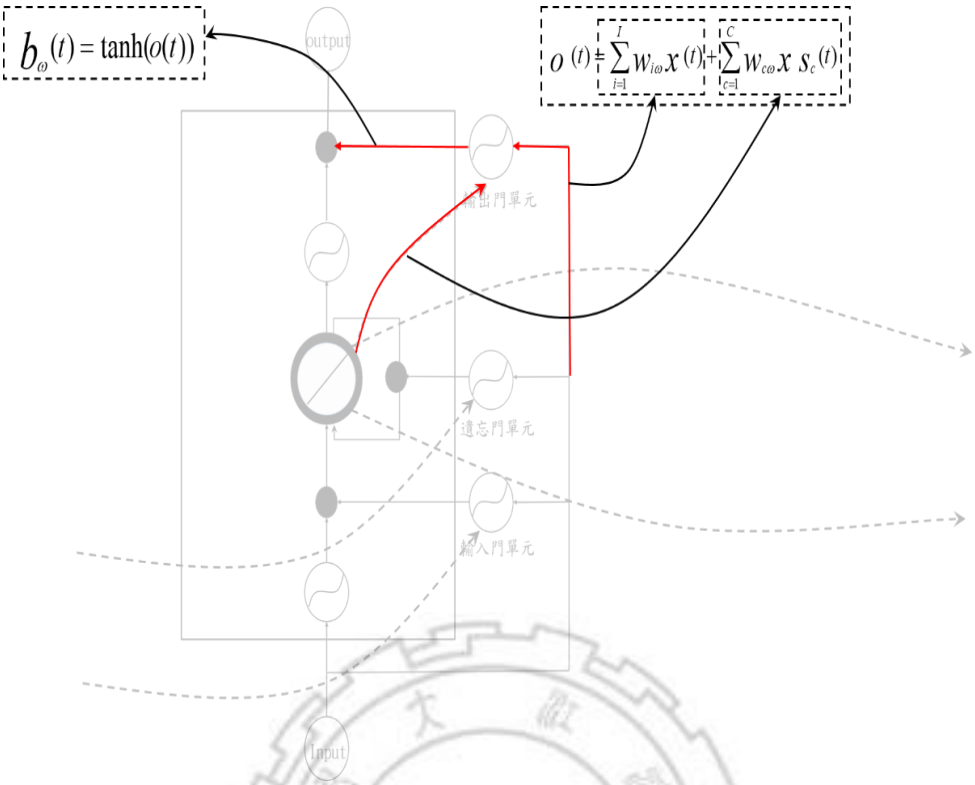

圖 3. 13 Output Gate 輸出

Block(c)的輸出值為 Output Gate 及 Cell 值之乘積，故 Block 的輸出值可寫作:

$$b_c(t) = b_\omega \tanh(s_c(t)) \tag{3.7}$$

3.3 LSTM 反向傳遞過程

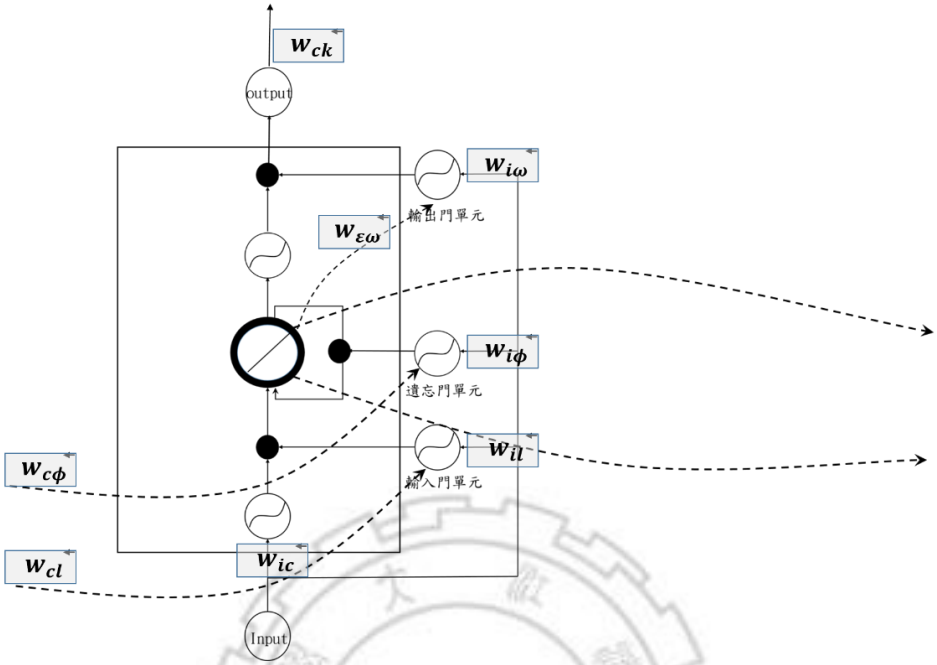

圖 3. 14 記憶塊各連接點權重

LSTM 的反向傳遞過程，目的是為了更新及最佳化權重和偏權值，也是網路學習之重點，以梯度下降法求解並計算對各元素之偏導數，對於神經網路的權重值，透過不斷的訓練樣本尋找相應的梯度，從而得到最佳解，梯度最佳化方法最常用為隨機梯度下降，但根據訓練資料不同還有 Adadeltd 和 RMSprop 等最佳化方法，利用 softmax 函數計算樣本分類於某一類別的機率，並將向量值壓縮至 0 到 1 區間:

$$\text{Softmax Function} = p\,(C_k|x) = y_k = \frac{e_k^a}{\sum_{k'=1}^{K} e_{k'}^a} \tag{3.7}$$

假設網路之輸出值為a_k，若求y_k對a_k之偏導 $\frac{\partial y_k}{\partial a_k} = y_k\delta_{kk'} - y_k y_{k'}$，則對應輸出值$a_k$可得到 Softmax Function $p\,(C_1|x)$、$p\,(C_2|x)$、.....，即為輸入值 x 之分類概率C_1、C_2、.....，得到分類概率後可定義 Loss Function，若 k∈1,2,3….K，分類類別為 k 的機率為y_k，真實值為z_k:

$$\xi(x,z) = -\ln p(z|x) = -\sum_{k=1}^{K} z_k \ln y_k \tag{3.8}$$

算出損失函數後可以運用函數計算每一個輸出類別之更新權重梯度變化。

■ Block 輸出值權重之梯度更新

$$\begin{aligned}
\delta_k(t) &= \frac{\partial \xi(x,z)}{\partial a_k(t)} \\
&= \frac{\partial(-\sum_{k'=1}^{K} z_{k'} \ln y_{k'})}{a_k(t)} \\
&= -\sum_{k'=1}^{K} z_{k'} \frac{\partial \ln y_{k'}}{\partial a_k(t)} \\
&= -\sum_{k'=1}^{K} \frac{z_{k'}}{y_{k'}} \frac{\partial y_{k'}}{\partial a_k(t)} \\
&= -\sum_{k'=1}^{K} \frac{z_{k'}}{y_{k'}} (y_k \delta_{kk'} - y_k y_{k'}) \\
&= -\sum_{k'=1}^{K} \frac{z_{k'}}{y_{k'}} y_k \delta_{kk'} + \sum_{k'=1}^{K} \frac{z_{k'}}{y_{k'}} y_k y_{k'}) \\
&= -z_k + y_k \sum_{k=1}^{K} z_{k'} \\
&= y_k - z_k
\end{aligned} \tag{3.9}$$

從式 3.9 可知每一個預測的輸出類別梯度僅和預測之真實值相關，故 Cell 輸出值權重之梯度可經由連鎖律推導得知:

$$\varepsilon_c(t) = \frac{\partial \xi(x,z)}{\partial b_c(t)} = \sum_{k=1}^{K} \frac{\partial \xi(x,z)}{\partial a_k(t)} \frac{\partial a_c(t)}{\partial b_c(t)} = \sum_{k=1}^{K} \delta_k(t) w_{ck} \tag{3.10}$$

■ Output Gate 輸出值權重之梯度更新

Output Gate 的梯度更新$\delta_w(t)$，藉由對$\xi(x,z)$求 Output Gate 輸出值 *o(t)*偏導數求出:

$$\delta_\omega(t)=\frac{\partial\xi(x,z)}{\partial o(t)}=\frac{\partial\xi(x,z)}{\partial b_c(t)}\frac{b_c(t)}{b_w(t)}\frac{b_w(t)}{o(t)}=\varepsilon_c(t)\tanh(s_c(t))\tanh'(o(t))$$

(3.11)

■ Cell 輸出值權重之梯度更新

先求對輸入值$a_c(t)$之偏導數$\delta_c(t)$:

$$\delta_c(t)=\frac{\partial\xi(x,z)}{\partial a_c(t)}=\frac{\partial\xi(x,z)}{\partial s_c(t)}\frac{\partial s_c(t)}{\partial a_c(t)}=\frac{\partial\xi(x,z)}{\partial s_c(t)}b_l(t)\tanh'(a_c(t))$$

(3.12)

Cell 的梯度更新為四項單元的輸入集合，分別為當前時刻的 Block 輸出值、下一個時刻 Cell、下一個時刻 Input Gate、下一個時刻 Output Gate 的梯度回傳值，寫作下式:

$$\begin{aligned}\varepsilon_s(t)&=\frac{\partial\xi(x,y)}{\partial s_c(t)}\\&=\frac{\partial\xi^t(x,z)}{\partial s_c(t)}+\frac{\partial\xi^{t+1}(x,z)}{\partial s_c(t+1)}\frac{\partial s_c(t+1)}{\partial s_c(t)}+\frac{\partial\xi^{t+1}(x,z)}{\partial i(t+1)}\frac{\partial i(t+1)}{\partial s_c(t)}+\frac{\partial\xi^{t+1}(x,z)}{\partial f(t+1)}\frac{\partial f(t+1)}{\partial s_c(t)}\\&=\left(\frac{\partial\xi(x,z)}{o(t)}\frac{o(t)}{\partial s_c(t)}+\frac{\partial\xi(x,z)}{\partial b_c(t)}\frac{\partial b_c(t)}{\partial s_c(t)}\right)+b_\phi(t+1)\varepsilon_s(t+1)+w_{cl}\delta_l(t+1)+w_{c\phi}\delta_\phi(t+1)\\&=\delta_\omega(t)w_{c\omega}+\varepsilon_c(t)b_\omega(t)\tanh'(s_c(t))+b_\phi(t+1)\varepsilon_s(t+1)+w_{cl}\delta_l(t+1)+w_{c\phi}\delta_\phi(t+1)\end{aligned}$$

故:

$$\delta_c(t)=\varepsilon_s(t)b_l(t)\tanh'(a_c(t))\tag{3.13}$$

■ Forget Gate 輸出值權重之梯度更新

Forget Gate 的梯度更新$\delta_\phi(t)$，藉由對$\xi(x,z)$求 Forget Gate 輸出值 *f(t)*偏導數求出:

$$\delta_{\phi}(t)=\frac{\partial\xi(x,z)}{\partial f(t)}=\frac{\partial\xi(x,y)}{\partial s_c(t)}\frac{\partial s_c(t)}{\partial b_{\phi}(t)}\frac{\partial b_{\phi}(t)}{\partial f(t)}=\varepsilon_c(t)s_c(t-1)\tanh'(f(t))$$

(3.14)

■ Input Gate 輸出值權重之梯度更新

Input Gate 的梯度更新$\delta_l(t)$，藉由對$\xi(x,z)$求 Input Gate 輸出值 *i(t)*偏導數求出:

$$\delta_l(t)=\frac{\partial\xi(x,z)}{\partial i(t)}=\frac{\partial\xi(x,z)}{\partial s_c(t)}\frac{\partial s_c(t)}{\partial b_l(t)}\frac{\partial b_l(t)}{\partial i(t)}=\varepsilon_s(t)\tanh(a_c(t))\tanh'(i(t))$$

(3.15)

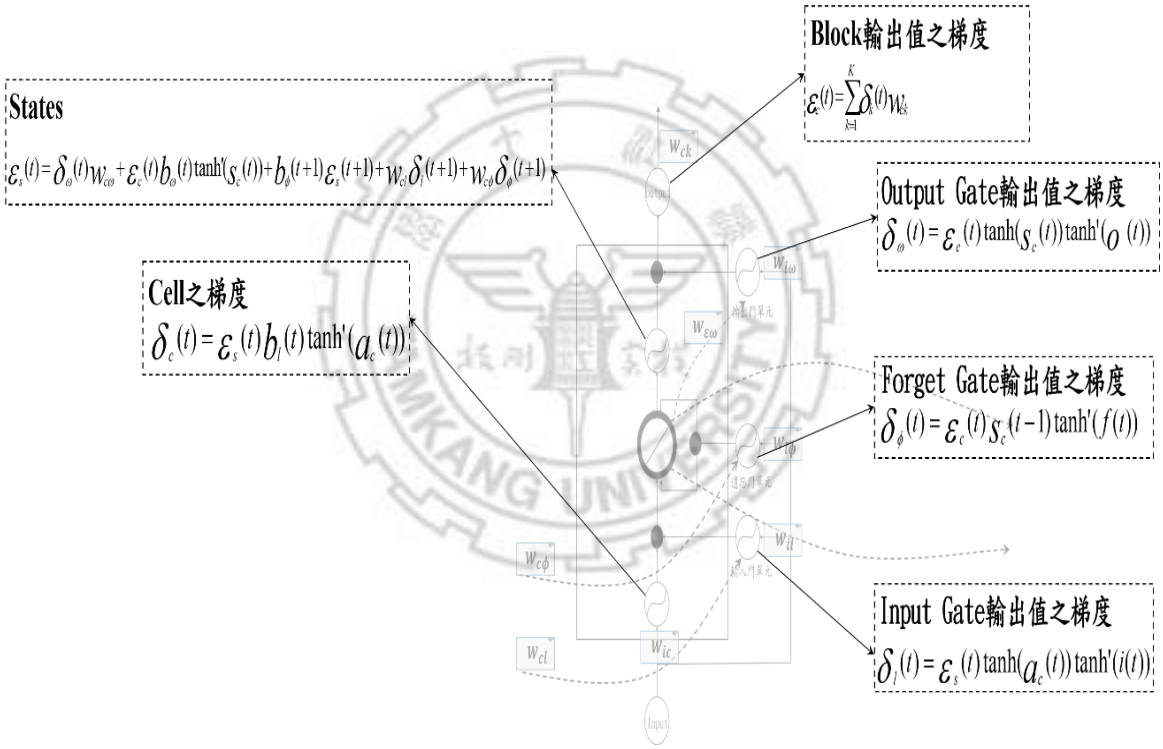

圖 3. 15 LSTM 各連接點梯度值更新算法

LSTM 網路與雖然與循環網路(RNN)乍看下只有將隱藏層替換為記憶模塊的差別，但其內部的連結層構造也是 LSTM 網路重要的一環，由上述章節可知 LSTM 網路的隱藏單元由一系列訊息模組構成，對應儲存的狀態訊息，而在預測長時間的時序資料，相較於歷史資訊有時未來的訊息資料更有用，所以隨著藉由不斷的循環更新訊息，以學習

最佳的特徵過程，也避免梯度消失及爆炸，為此網路結構之主要目的，網路參數的設計在確立整個學習框架過程後確立，訓練網路的數據及參數配置則需透過不斷的網路測試，學習框架的神經元數量，取決於幾種方式，包含:

一、訓練資料數量

二、輸入及輸出單元數量

三、訓練演算法

四、隱藏層之啟動函數類型

五、資料正規化數值

六、學習分類的複雜程度

而多數情形下，隱藏層的最佳數量是沒辦法確定的，許多研究說明了測試隱藏層數量的經驗法則，涉及了訓練權重數量及訓練資料的個數，典型的訓練規則為權重應不超過訓練總數的 1/30，此規則可以避免過多的訓練造成的過擬合問題，但卻忽略正規化的大小等其他構面，所以並沒有確定的理論說明，訓練資料需要多少隱藏單元數量，故最為常見的方法為試誤法，及參考其他相似研究之設計。

第四章 資料蒐集與分析

4.1 資料蒐集目的

本研究探討機車推進行為模式，針對道路機車特性，如速度、位置、及與鄰車間之互動，是否影響機車行進行為等，進一步建立機車車流模式，為了得到真實數據，掌握每時階每輛機車時點的座標變化，及與鄰車的互動型態，透過攝影測量參數轉換法(DLT)，將所拍攝之道路車流影像座標轉換為二維真實座標，資料類型所需的數據可以分為，直接觀察數據，潛在數據及環境數據，而前兩項數據，根據預測模型的開發決定所需要之模型參數，包含機車車流軌跡及鄰車空間數據，根據車流座標點可以進一步換算基本的行為參數，如速度、方向及加速度，甚至是車流密度等。

4.2 資料調查項目

如上述所提，機車車流狀態複雜，以攝影方法取得道路車流資料並進行分析，並從中蒐集時空座標，由座標換算成車流資訊，為避免資料提取錯誤，調查及預蒐集之資料為:

1. 路段基本資料:包含路型、路段長度、寬度及資料的提取範圍等。
2. 機車之真實座標(所設定之路段空間之 X 軸及 Y 軸)。
3. 目標車及其周圍空間鄰車座標。
4. 機車橫移行為
5. 藉由連續點座標及時間差可以換算其移動距離及瞬時速率。
6. 機車流量及密度

4.3 攝影測量

近景攝影測量是利用對近距離目標拍攝圖像，測定被攝目標之幾何特性攝影測量，藉由側向的車流影像拍攝，可獲得一段時間內所有路段車輛之移動軌跡，並提取每台移動車輛之座標變化，相較於高空垂直拍攝，不須找至高點，且拍攝範圍較大，但高空垂

直攝影，只要將路面之直角坐標設定好，可以用較為直接的方式判讀車流座標，比起高空垂直拍攝直觀取點的取座標的方式，側像拍攝方法要經過一系列之線性轉換及定位參數座標點等，但不管是使用哪種攝影方法，如無配合影像辨識技術，大量的車流資料需要以人工取點的方式蒐集為一大缺點。

4.3.1 調查地點

本研究選定承德路七段之路段車流如圖 4.1 所示，選取原因為，本路段為連接淡水區及台北市之主要幹道，機車車流量大且穩定，在尖峰時段時的機車車流能體現機車特殊的鑽縫行為，且路段中有行人陸橋以利在高位架設拍攝工具，道路長度大於五十公尺，方便蒐集觀察數據，衛星圖及實際觀測圖如圖 4.2，調查路段長約 133.56 公尺，寬約 16.42 公尺，單向四車道，車道寬約為 3.5 公尺，最內側車道為左轉道禁行機車，其餘車道為汽機車混合車道。

本研究為拍攝路段車流，實地拍攝方面，選擇該路段之人行陸橋作為拍攝地點，該地點能以正面拍攝路段，而關於側像拍攝及正像拍攝之錄像使用，及為何捨棄側像拍攝法，在下述章節會祥細說明，在收錄大範圍路段的道路車流時，相較於傳統取點法，本研究利用攝影參數轉換法，比傳統取點更能準確掌握機車個別車輛之真實座標，以正面拍攝的路段為設定資料定位點的定位素材，須設定攝影機之拍攝角度，目標為正面迎來之路段車流，配合攝影機架設角度與高度差換算，資料蒐集地點須配合下列要求。

1. 路段為汽機車混合車流且車流量大。
2. 多車道路段。
3. 道路無坡度呈平面矩型。
4. 路段需有地點可以將所設定之多個定位點拍攝至同一畫面中。

圖 4.1 觀測路段示意圖

圖 4.2 路段空間幾何圖

4.3.2 調查工具

因執行攝影測量需實地測量目標路段之路段資訊，包含路寬、路長及設定目標定位點，所以調查工具可分為拍攝工具及現場測量工具。

表 4-1 測量工具

拍攝工具	測量工具
一、DV 攝影機 GZ-VX705SU 一台 二、固定器及腳架 一組	一、測距輪 一組 二、電子全站儀 Leica TCR 802 一台 三、稜鏡組及稜鏡標竿 一組 四、鋁合金腳架 一組 五、水準尺 一個

4.3.3 拍攝及調查作業

選定拍攝地點，本研究拍攝日期為 2018/02/24，上午 8:30 至 9:30 進行拍攝作業，天氣狀況良好且無異常施工，過去研究對於車流研究的影像資料蒐集，所採用之手法大多著重於高樓垂直錄影，而側向面積的偵測，近年來雖然有些車流研究的學者也是運用實地攝影的方式拍攝研究素材，但在資料處理方面卻較少詳細說明攝影測量用於車流資料蒐集的方法，攝影機在對移動中物體進行追蹤定位時，重要的關鍵問題為拍攝鏡頭的失焦變形（Tsai，1987; Hoogendoorn 等人，2003），

而為了將失真變形降至最低，其中一個辦法是將攝影機架設於高處，或利用空拍機進行高空垂直拍攝，但此方法不僅限制研究的調查地點，也會限制錄製的車流範圍，無法呈現道路完整路段，鏡頭失真意味著在某些情況下，攝影機所拍攝的圖像無法精確描繪現實世界中的物體形狀，即是所謂的「鏡頭畸變」造成的影像幾何變形，例如，在現實情況下，一條直線型道路，會因為攝影鏡頭扭曲呈曲線型，且在圖像的邊緣處更為明顯，所以通常攝影測量須克服之最大狀況為調整桶形及枕形失真。

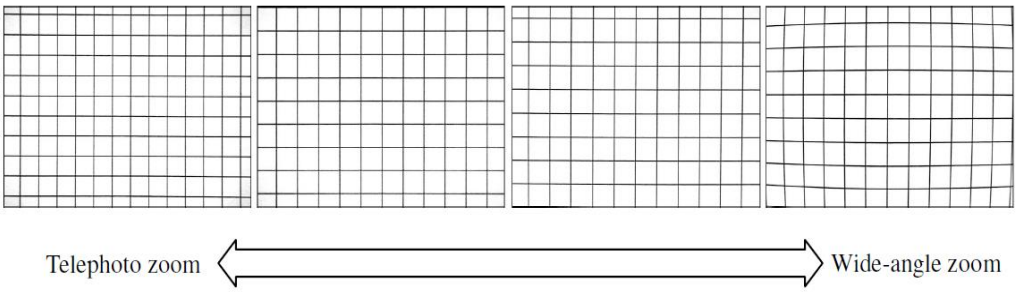

圖 4. 3 攝影圖像失真示意圖(圖來源:Tzu-Chang Lee, 2007)

本研究之資料處理過程利用參數轉換還原圖像失真，而拍攝範圍為了將參數轉換點拍入，採用正像拍攝及側像拍攝，由圖 4.4 可看出圖像上下處的車道兩端及左右圖像邊緣處，已有形變產生。

圖 4. 4 攝影圖像扭曲

4.4 資料處理

本節將說明如何處理拍攝完畢之車流影片檔案，並將檔案進行資料處理的過程，影片拍攝時間約為一個小時，將拍攝之影像處理完畢後，擷取車流影像資料，並以人工方式取點，方可得車流座標檔案，將數位拍攝的車流資料利用影像擷取軟體擷取，並轉換成所需之像素影像檔，本研究以 500 毫秒作為連續車流截取影像，本研究認為車流行為

在 500 毫秒間的變化，已經能充分掌握資訊，如果將截取時間過度分割，雖能更精確的掌握機車的行為變化，但分析工作量會變的龐大，以致於無法觀測出長期車流變化，Nguyen,LX(2012)等人研究說明，機車騎士面對其他車輛變化的平均反應時間約莫 500 毫秒左右，所以本研究以 500 毫秒作為分割，蒐集路段車流資料。

4.4.1 投影模型

追蹤道路車流座標，在資料處理過程需要將影像像素座標點轉換為真實道路座標，側像面積的偵測牽涉三維座標軸關係，雖不考慮車高，但第一次嘗試實驗所使用方法為 6 個定位點的 12 參數轉換法，所以除了平面座標 X 軸及 Y 軸關係外，也將高度 Z 軸考慮進模式，並使用公尺為測量單位，精確度範圍在 10 公分以內，影像解析度的調整，假設使用越高的相片解析度，雖換算之座標值精確度會越準確，但經由評估後，假設對於真實世界座標值之精度要求過於仔細，實際操作上並無任何意義，故本研究參考 Tzu-Chang Lee(2007)研究，將影像畫素調整為 660*990 個像素點進行換算。

攝影測量基本原理為針孔投影之共線性原理，因光線呈直線前進，所以實際物體之目標點 P、成像影像點 Q，及攝影機透視鏡中心點會處於同一直線上，可利用共線方程式之線性交會法，需取得線性方程式之內部及外部參數，也就是攝影機架設位置、姿態角度等，以及攝影機本身之特性參數，而本研究所使用攝影機並非專業測量用之攝影器材，所以攝影機之內外參數的初始值設定無法取得準確值，為本研究之研究限制。所以本研究利用直接線性轉換法(Direct Linear Transformation, DLT)，此法是由共線性方程式推導出，為了讓內參數為不確定值的業餘用非量測攝影機，也能使用於攝影測量，利用矩陣轉換及齊次座標概念推導出的方程組，使用共線方程式，必須先將影像「像素座標」轉換為「像平面座標」後，再轉換為「空間座標」，直接線性轉換法是直接將「像素座標」轉換成「空間座標」，故需求解出「像素」轉換「空間」的多個參數來替代內、外參數值，及像素與實際座標之比例參數以建立線性方程式，上述所提之 6 個參數定位點，則是為求出參數值所設定。

影像座標與真實座標之投影模型轉換應用相機之針孔效應，如圖 4.5 所示。

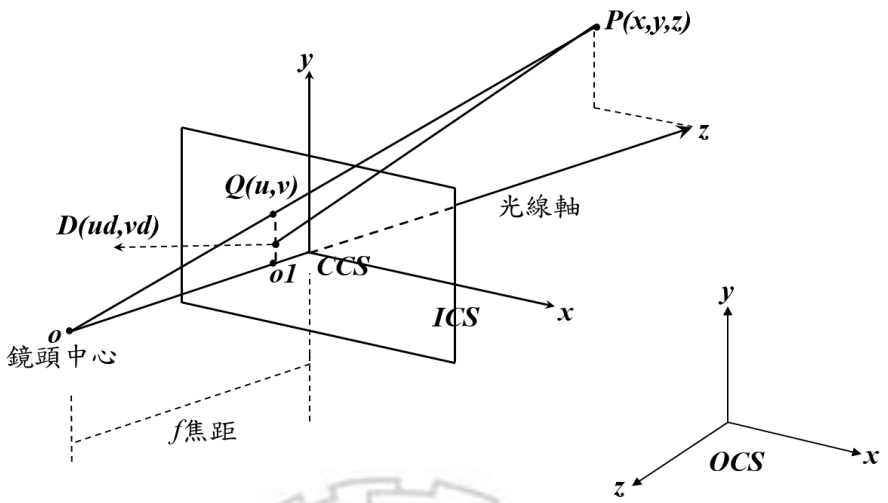

圖 4. 5 相機幾何成像

OCS:物體座標系

CCS:相機座標系

ICS:影像座標系

假設空間上有一 P 點(x,y,z)，而因針孔成像原理 P 點會在同一條線上建立起一座標點 Q(u,v)， Q 點位於其影像平面上，所以可以利用線性轉換齊次座標概念表示為:

$$\begin{bmatrix} ur \\ vr \\ r \end{bmatrix} = \begin{bmatrix} \alpha_{11} & \alpha_{21} & \alpha_{31} & \alpha_{41} \\ \alpha_{21} & \alpha_{22} & \alpha_{23} & \alpha_{24} \\ \alpha_{31} & \alpha_{32} & \alpha_{33} & \alpha_{34} \end{bmatrix} \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix} \tag{4.1}$$

式(4.1)中包含了相機三個外部參數及相機相對於 OCS 的轉動角度轉動角度，將 P 點於 CCS 之座標假設為(x_c, y_c, z_c),且與原始座標(x,y,z)之轉換關係為:

$$\begin{bmatrix} x_c \\ y_c \\ z_c \\ 1 \end{bmatrix} = \begin{bmatrix} w_1 & w_2 & w_3 & t_1 \\ w_4 & w_5 & w_6 & t_2 \\ w_7 & w_8 & w_9 & t_3 \\ 0 & 0 & 0 & 4 \end{bmatrix} \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix} \tag{4.2}$$

其中， t_1 、t_2 、t_3 為相機三個外部參數，及旋轉矩陣:

$$\mathrm{R} = \begin{bmatrix} w_1 & w_2 & w_3 \\ w_4 & w_5 & w_6 \\ w_7 & w_8 & w_9 \end{bmatrix}$$

$$= \begin{bmatrix} \cos\varphi\cos\theta & \sin\varphi\sin\theta & -\sin\theta \\ -\sin\varphi\cos\phi + \cos\varphi\sin\theta\sin\phi & \cos\varphi\cos\phi + \sin\varphi\sin\theta\sin\phi & \cos\theta\sin\phi \\ \sin\varphi\sin\phi + \cos\varphi\sin\theta\cos\phi & -\cos\varphi\sin\phi + \sin\varphi\sin\theta\cos\phi & \cos\theta\cos\phi \end{bmatrix} \tag{4.3}$$

其中， ϕ、θ、ψ 為相對於物體座標系統 OCS 的三個轉旋轉角度。

而將上述相對於 CCS 的 P 點，投影至影像平面上的點假設為(u_F, v_F)，則(x_c, y_c, z_c)與(u_F, v_F)之相對關係則可以用公式改寫:

$$u_F = f\frac{x_c}{z_c} \qquad u_F = f\frac{y_c}{z_c} \tag{4.5}$$

f為有效的焦距長度，將式(4.5)以矩陣表示其轉換關係:

$$\begin{bmatrix} u_F w \\ v_F w \\ w \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & \frac{-1}{f} & 1 \end{bmatrix} \begin{bmatrix} x_c \\ y_c \\ 1 \end{bmatrix} \tag{4.6}$$

最後 CCS 及 ICS 的轉換過程為像素及實際長度座標的比例修正問題，及針孔光軸的修正，假設(u_0, v_0)為相機座標系統之座標相對於拍出之影像座標，σ_u、σ_v表示為像素對水

平或垂直座之縮放比例，以本研究來說就是公尺及像素間的比例換算，可以將轉換公式表示為:

$$u = \frac{u_F}{\sigma_u} + u_0 \qquad v = \frac{v_F}{\sigma_v} + v_0 \tag{4.7}$$

將式(4.7)以矩陣表示其轉換關係:

$$\begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} \frac{1}{\sigma_u} & 0 & u_0 \\ 0 & \frac{1}{\sigma_v} & v_0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_c \\ y_c \\ 1 \end{bmatrix} \tag{4.8}$$

將式(4.6)與式(4.8)部分結合，與式(4.2)成立新式:

$$\begin{bmatrix} \alpha_{11} & \alpha_{21} & \alpha_{31} & \alpha_{41} \\ \alpha_{21} & \alpha_{22} & \alpha_{23} & \alpha_{24} \\ \alpha_{31} & \alpha_{32} & \alpha_{33} & \alpha_{34} \end{bmatrix} = \begin{bmatrix} \frac{1}{\sigma_u} & 0 & u_0 \\ 0 & \frac{1}{\sigma_v} & v_0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & \frac{-1}{f} & 1 \end{bmatrix} \begin{bmatrix} w_1 & w_2 & w_3 & t_1 \\ w_4 & w_5 & w_6 & t_2 \\ w_7 & w_8 & w_9 & t_3 \\ 0 & 0 & 0 & 1 \end{bmatrix} \tag{4.9}$$

此轉換過程會在,相機外部參數經三個角度會經由運算過程抵銷,若在式(4.1)中,令 r=1,則矩陣可得下列兩組方程式:

$$(\alpha_{11} - \alpha_{31}u)x + (\alpha_{12} - \alpha_{32}u)y + (\alpha_{13} - \alpha_{33}u)z + (\alpha_{14} - \alpha_{34}u) = 0$$
$$(\alpha_{21} - \alpha_{31}v)x + (\alpha_{22} - \alpha_{32}v)\mathrm{y} + (\alpha_{23} - \alpha_{33}v)\mathrm{z} + (\alpha_{24} - \alpha_{34}u) = 0 \tag{4.10}$$

取得六個以上之控制點，方能得 12 個以上的方程式解h_{11}..... h_{34}，所以直接線性轉換法(DLT)之數學模式可表示為:

$$\begin{bmatrix} x_1 & y_1 & z_1 & 1 & 0 & 0 & 0 & 0 & -u_1x_1 & -u_1y_1 & -u_1z_1 & -u_1 \\ 0 & 0 & 0 & 0 & x_1 & y_1 & z_1 & 1 & -v_1x_1 & -v_1y_1 & -v_1z_1 & -v_1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_N & y_N & z_N & 1 & 0 & 0 & 0 & 0 & -u_Nx_N & -u_Ny_N & -u_Nz_N & -u_N \\ 0 & 0 & 0 & 0 & x_N & y_N & z_N & 1 & -v_Nx_N & -v_Ny_N & -v_Nz_N & -v_N \end{bmatrix} \begin{bmatrix} \alpha_{11} \\ \alpha_{11} \\ \vdots \\ \vdots \\ \alpha_{34} \end{bmatrix} = 0$$

(4.11)

求解$\alpha_{11} \ldots . \alpha_{34}$等係數為避免全為 0 之特解發生，令$\alpha_{34} = 1$，可得$\alpha_{11} \ldots . \alpha_{34}$之解，將式(4.11)寫成一般式:

$$u = \frac{\alpha_{11}X+\alpha_{12}Y+\alpha_{13}Z+\alpha_{14}}{\alpha_{31}X+\alpha_{32}Y+\alpha_{33}Z+1} \quad v = \frac{\alpha_{21}X+\alpha_{22}Y+\alpha_{23}Z+\alpha_{24}}{\alpha_{31}X+\alpha_{32}Y+\alpha_{33}Z+1} \qquad (4.12)$$

式(4.12)為直接線性轉換數學模式(DLT)，α為模型參數(DLT 參數)，控制點的設定，六個定位點須符合三點不共線，六點不共面之原則，而本研究進行影像側像拍攝時，尋找平面四點以外的其餘兩點定位點時，因全站儀之稜鏡竿長度限制，所以要找到空間上分散的其餘兩點著實困難，經研究及參數換算後得出解決辦法，因本研究之研究對象為機車車流，在定位機車車流座標時，對於速度的換算並不考慮車高，所以只會使用到二維座標，也就是可以直接將 Z 軸忽略，但衍生問題為，假設忽略 Z 軸，則控制參數會減少三個，此時如果繼續使用側像拍攝方法，則剩下的 DLT 參數無法有效替代攝影機之內外部參數，所以需改變拍攝角度，根據 Tzu-Chang Lee(2007)研究，若拍攝路面角度的畫面呈現如圖 4.6，路面平面與影像拍攝畫面呈垂直，則只需要考慮線性縮放，將角度問題降至最低，重新設定完成後，蒐集路面上四個新控制點。

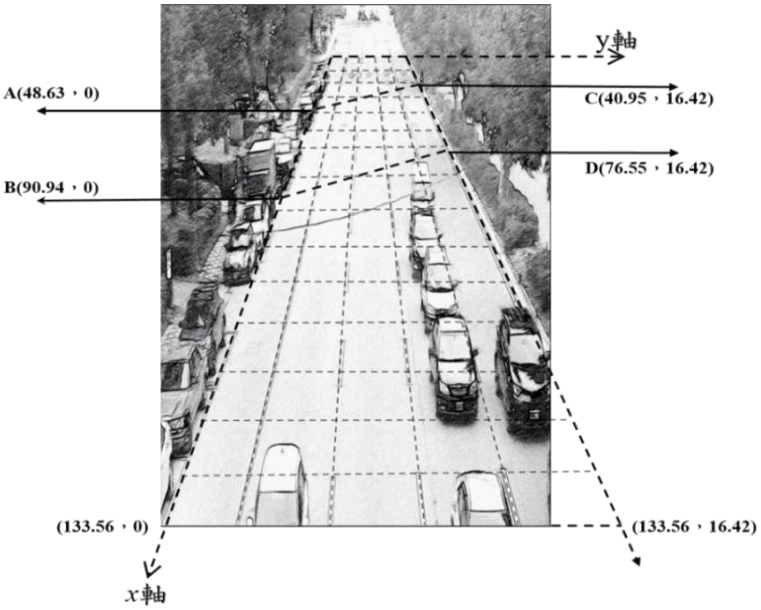

圖 4.6 真實世界座標系統

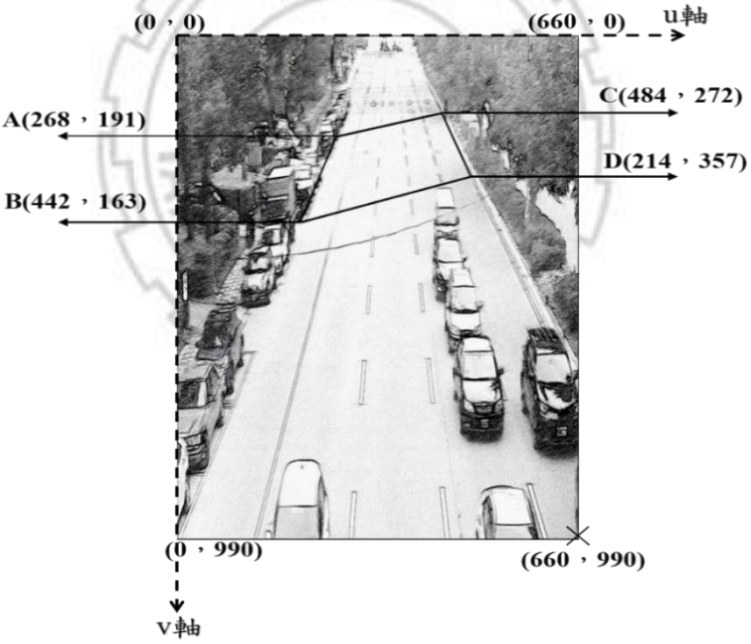

圖 4.7 像素座標系統

現實世界下拍攝的影片失真狀況在乍看下很輕微,但後續還須利用模式計算結果後調整誤差值，並利用誤差平方和檢驗轉換坐標及真實座標，兩平面的坐標系定義如圖 4.7，四個控制點和影像中像素點的對應，如表 4-2 中所示:

表 4-2 控制點調查結果

No.	真實世界座標(公尺)		影像座標(像素點)	
	x	y	u	v
A	48.63	0.00	168	191
B	40.95	16.42	442	163
C	76.55	16.42	484	272
D	90.94	0.00	214	357

將表 4-3 之控制點座標帶回 DLT 模式中，得到八個方程式，忽略 Z 軸並將模式改寫成矩陣形式，DLT 模式中像素座標和實際座標可以相互轉換，參數會依方程式的不同求解不同之係數矩陣，利用 Matlab 求解α值:

$\alpha_1 = 1.432355$ $\alpha_5 = 0.111106$

$\alpha_2 = 16.81199$ $\alpha_6 = 2.566304$

$\alpha_3 = -2318.12846$ $\alpha_7 = 0.834821$

$\alpha_4 = 0.01508$ $\alpha_8 = -847.2206$

$$x = \frac{1.432355u + 16.81199v + (-2318.12846)}{0.01508u + 0.111106v + 1}$$

$$y = \frac{2.566304u + 0.834821v + (-847.2206)}{0.01508u + 0.111106v + 1}$$

表 4-3 計算結果及其誤差

No.	計算值 x	計算值 y	實際值 x	實際值 y
A	48.61156817	-0.000205582	48.63	0.00
B	40.93225512	16.41190684	40.95	16.42
C	76.5177587	16.14256273	76.55	16.42
D	90.90783499	-0.000200483	90.94	0.00

x 值之誤差平方和: 0.002728702

y 值之誤差平方和: 0.07703702

x,y 平方和誤差均小於最初設定之誤差範圍十公分，後續檢驗需利用後續蒐集資料檢驗其誤差值。

4.4.2 調查資料及環境空間分析

建立預測模型的輸入變數，需定義機車環境空間各項基本參數，包含機車及道路基本特性分析，首先定義機車尺寸，根據上述座標轉換取得之機車車輪前緣座標點，如圖 4.8，可根據每輛獨立機車回推佔據道路的空間座標，本研究假設每輛機車隨著時階移動時，所佔據的空間皆相同，根據張振達(2012)研究，調查市面上販售八大品牌(光陽、三陽、YAMAHA、哈特佛、宏佳騰、CPI、比雅久、SUZUKI)機車規格尺寸，及邱德紋(2005)研究，定義的國內機車的車體尺寸，如表 4-4，經評估後，因本研究部分目的為改進張振達(2012)之預測分類的結果，故將機車平均長度定義為長度 1.86 公尺，寬度 0.72 公尺，回推機車空間座標。

圖 4. 8 機車座標判斷位置

表 4-4 歷年機車實體尺寸統計表

文獻種類	長(公尺)	寬(公尺)	高(公尺)
國內各研究採用值	1.33~2.00	0.40~0.80	0.48~1.15
台灣標準	1.80	0.80	1.00
綜合範圍	1.33~2.00	0.40~0.80	0.48~1.15

資料來源:邱德紋(2005)

假設經座標轉換求得機車在真實空間座標一點(x_1, y_1)，如圖 4.9 所示，機車所占空間為 1.86*0.72 長方格，(x_1, y_1)為長方格寬度中心，回推四個座標點分別為 A、B、C、D 四點，

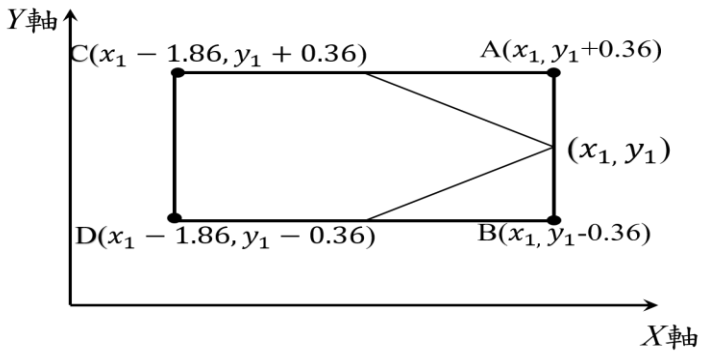

圖 4. 9 機車尺寸所占空間座標

秒	車編號	本車(像素)		真實座標		DISTANCE(m)	SPEED(Km/Hr)
114	40	332	466	103.6907	6.814958	8.786261365	63.26108183
114	41	300	322	85.34444	4.63572712	8.352193807	60.13579541
114	42	330	333	87.32083	6.46001215	8.84503269	63.68423537
114	43	283	218	59.41339	2.06925349	7.370129157	53.06492993
114	44	306	240	66.75302	4.28746833	8.606182425	61.96451346
114	45	329	198	52.99119	5.80648795	7.999247571	57.59458251
114	46	312	180	44.92434	4.03470353	7.830383517	56.37876133
114	47	299	166	37.60741	2.44933319	8.933605906	64.32196252
114	48	284	186	46.84366	1.42108427	5.99273791	43.14771295
114	49	342	230	64.27241	7.01379693	10.17915547	73.28991938
114	50	332	248	69.32112	6.31059405	8.973358903	64.6081841
114	51	331	164	37.7064	5.74486033	8.396826845	60.45715329
114	52	306	118	5.554094	1.95263315	5.591593068	40.25947009
114	53	315	122	9.5372	3.26293195	8.480309435	61.05822793
114	54	328	109	-0.87278	4.73456349	8.358747609	60.18298278
114	55	335	113	3.304715	5.73918486	8.358747609	60.18298278
114.5	37	261	957	127.1289	5.58570982	8.42016139	60.62516201
114.5	38	299	627	115.0829	5.89990103	8.647349156	62.26091392
114.5	40	326	584	112.5213	6.73563166	8.830974477	63.58301623
114.5	41	293	376	93.70979	4.63135224	8.365344689	60.23048176

圖 4. 10 資料形式

4.4.3 影響範圍空間定義

求得機車四座標點後，後續定義周圍鄰車互動情況，利用座標建立機車格位範圍空間，呈現道路之交通狀態，本研究主要探究機車在汽機車混合車道中的個別互動情形，故不考慮鄰車為汽車及公車之影響，探討針對目標車周圍機車之橫向距離及縱向距離的影響參數，而機車環境的安全空間定義，台灣並無明文規定機車安全空間設定，在擁擠車流車車流密度大的情況下，安全空間更是不負存在，但定義鄰車的影響範圍，目標車對範圍空間內之鄰車採取的反應行為，找出最近於目標車輛的左右橫向鄰車距離，需定義範圍空間並提取空間內之機車座標作為影響變數，機車的橫向移動即代表其變換車道意圖，所以橫向位置空間大小就決定機車騎士是否執行偏移行為，根據交通大學(2005)研究機車車流移動，如圖 4.11 所示，機車移動路徑自時間 t 至 t+3 持續偏移時，偏移之最小的移動距離設定為 0.5 公尺開始持續偏移，並在 t+2 時偏移距離增加為 0.7 公尺，約略為本研究之定義車寬 0.76 公尺，而 t+3 時的偏移距離則大於 0.9 公尺，參考該研究定義出機車側向安全空間及其影響範圍空間，如圖 4.12 所示。

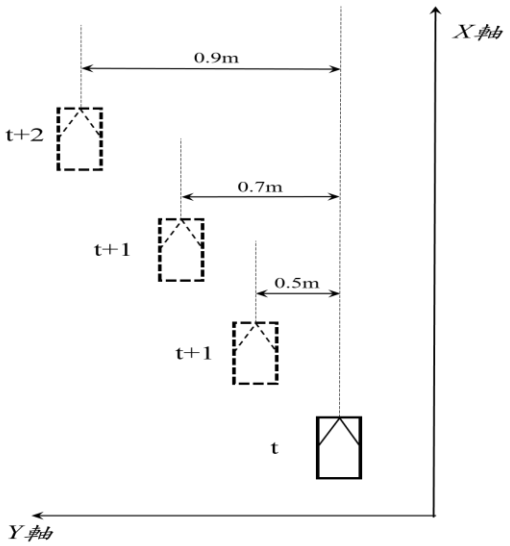

圖 4. 11 機車橫向移動

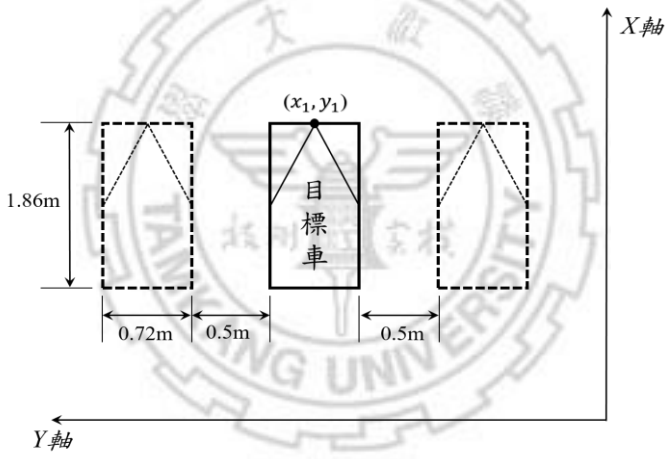

圖 4. 12 機車橫向影響變數空間

將模式套用至影像中對目標車與鄰車的座標的判別，篩選出橫向空間內鄰車座標，可得範圍空間內之輸入變數，縱向間距的影響範圍判定即是機車之跟車距離定義，根據機車騎士的視覺特性設定影響範圍，根據研究機車騎士對於速度與視角的感受會比一般自小客車駕駛更為明顯，人類的視野呈現錐型角度，而隨著視角不同水平面上的視覺效果也會跟著不同，對駕駛者來說速度對於視角及視野範圍的影響是相當大的，U.S. Forest Service(1973)說明，如圖 4.13 所示，速度在 40 Km/Hr 增加到 72 Km/Hr 時，視錐角度會隨著速度增加自 100 度減少至 65 度，當速度增加時近景會因視力範圍縮小而逐漸模糊

消失，注意力也會更集中而將視野焦點引向更遠的前方，所以本研究利用騎乘者視覺的侷限性定義縱向空間，將目標車前方車輛做出區隔判別，找出影響範圍空間，將機車跟車安全距離定義為張振達(2012)以領地效應假設出之距離 0.9 公尺，結合研究定義之橫向安全距離 0.5 公尺及視野角度定義完整周圍空間，如圖 4.14 所示

表 4-5 速率與視野角度關係

行車速度(Km/Hr)	焦距(公尺)	視野角度(公尺)
64	340	60
80	430	55
97	550	45

資料來源:本研究整理

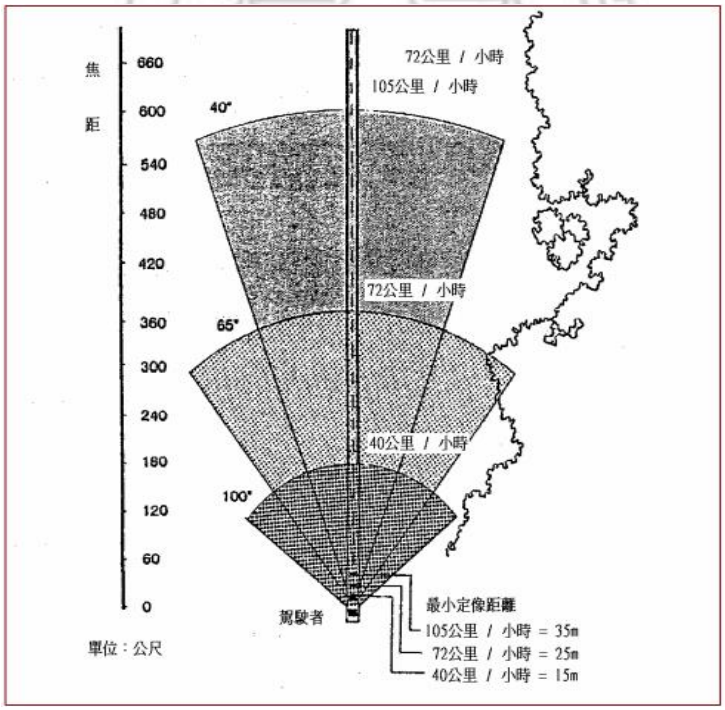

圖 4. 13 速度與視野關係圖

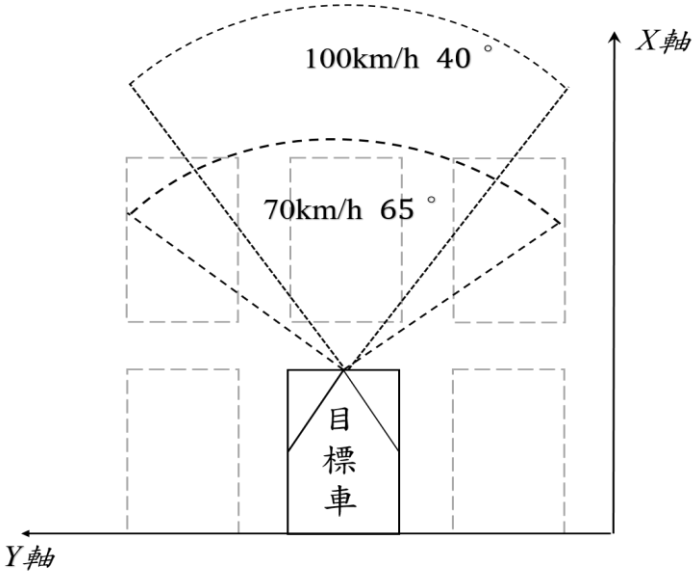

圖 4. 14 視野角度與橫向空間定義

表 4.5 可知視野範圍與速度的影響，影響範圍為 200 公尺以上，早已超越資料之路段長度，由此可知速度與視覺焦距的關係以本研究來說對機車騎士的影響甚小，本路段車輛部分，影響範圍以每時階之最大移動距離來判定，故可將縱向影響空間的最大範圍設定為 10 公尺，配合速度與視角關係與上述縱向空間定義出完整的範圍空間如圖 4.15 所示，分別為五個範圍 A、B、C、D、E。

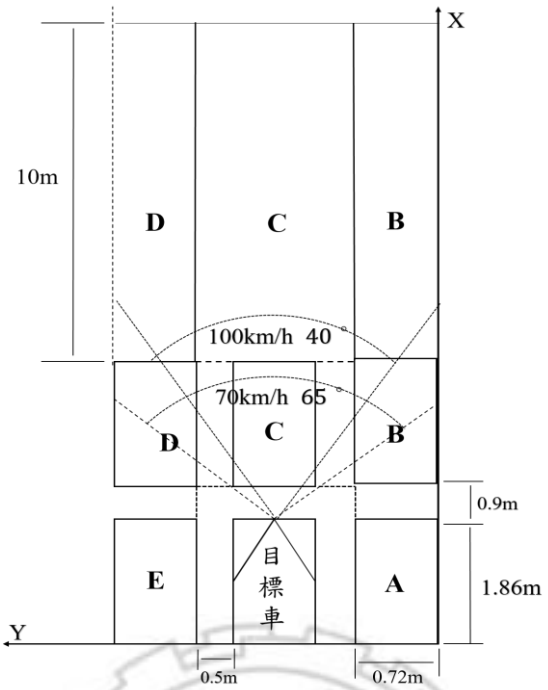

圖 4. 15 機車完整影響範圍空間定義

B、C、D 的空間判定以速度劃分，將目標車依速度分成三個層級空間建立輸入變數，當目標車速度在 70 Km/Hr 及 100 Km/Hr 之間，依角度換算縱向距離為 1.91 公尺，故影響範圍為 65 度之錐型範圍外的 B、C、D 最近影響車輛，當目標車速度大於 100 Km/Hr 時，縱向最大距離為 3.34 公尺，影響範圍為 100 度之錐型範圍外 B、C、D 之最近影響車輛，而當目標車車速小於 70 Km/Hr 時，則視角的錐形角度所換算之橫向距離已經大於左右之影響距離 1.22 公尺，故影響範圍為 B、C、D 之最大矩形範圍，將設定完畢的觀察範圍運用在蒐集的真實道路車流資料，整理上述定義，可假設當一目標車M_1在道路上之實際座標為(x_1, y_1)，速度 75 Km/Hr，如圖 4.16 所示，周圍空間鄰車分別為$M_2(x_2, y_2)$、$M_3(x_3, y_3)$ 、$M_4(x_4, y_4)$ 、$M_5(x_5, y_5)$ 、$M_6(x_6, y_6)$，根據速度與空間定義，M_2影響忽略不計，五個空間內之所有車輛的座標即可求出，而目標車M_1下個時階移動可能有圖 4.16 之四種情況。

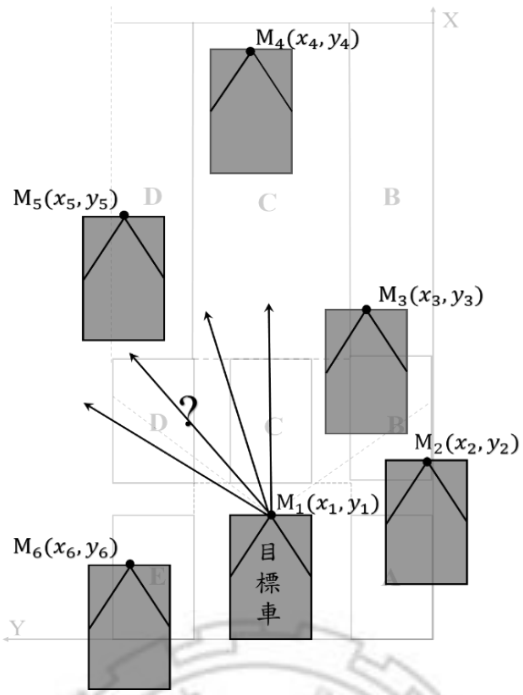

圖 4. 16 目標車與範圍空間鄰車

預測的目標即為目標車M_1之移動情況，故輸入的影響範圍變數即為範圍內四台機車與目標車互動影響之各項參數，根據駕駛經驗機車與前車的縱向跟車模型，主要探究跟車時與前車之相對位置的影響，傳統模型將機車模式運用 Gipps(1981)模型判斷模擬跟車行為，本研究利用速度與視野角度的關係能決定機車之縱向距離影響範圍判定，許義宏(2007)，混合車流巨觀模型研究中說明，並試圖對汽車及機車的跟車模型模式化，但對機車縱向跟車距離並沒有辦法找出一明確之關係式，故本研究以反應時間 0.5 秒及平均車速定義移動距離 10 公尺為影響範圍的最大距離，如圖 4.16 前進方向示意，本研究欲得知機車是否會因變數影響而改變前進方式，建立預測模型預測機車下一時階之前進位置，除了方向外，將機車移動預測至下一個前進之格位空間，下列章節將敘述輸出變數設計。

第五章 模式構建及驗證

5.1 模式構建

為反映機車的真實移動行為，張正達(2012)研究定義周圍鄰車空間作為輸入變數，並利用羅吉斯迴歸建立預測模型預測機車三個推進方向作為輸出值，但限制於模型架構無法將機車的實際推進距離進行有效判斷，以至於無法描述更細微的環境變化，而機車周圍環境空間的互動值，該研究利用二元的變數判斷其實並不足以體現機車周圍鄰車影響距離的互動情形，而在模式的可轉移性方面，希望建立的預測模型能在同一模式下的不同環境空間亦能發揮預測作用，只需調整不同參數值，故本研究希望維持與其相同的架構理念，在方法的運用上更新定義的目標，利用分類強度較強的深度學習中處理時間序列資料有較完善架構的長短時記憶神經網路(LSTM)，預測每個時階點的機車推進，除了定義目標車本身的行為參數外，還有時階內範圍鄰車的互動參數，利用 matlab 2017 b 設計程式訓練結構，找出適用於機車推進之 LSTM 網路結構。

5.1.1 輸入變數

模式將一般市區道路的道路建立真實的座標空間，利用座標軸概念將輸入機車空間單位所小至數值單位，故只需探究資料來源的精確度，機車在道路上所佔據空間由上述章節設定為 1.86*0.72 之長方格單位，假設機車座標(x,y)，找出五個目標空間內的鄰車座標(x’,y’)，從中提取目標參數即輸入變數及輸出變數，模式構建初期考量之輸入變數為:

- 目標車真實座標(x)-(MX)
- 目標車真實座標(y)-(MY)
- 目標車速度(Km/Hr)-(MS)
- 目標車移動距離(m)-(MD)
- A 空間內最近車輛之真實座標(x)-(AX)
- A 空間內最近車輛之真實座標(y)-(AY)
- A 空間內最近車輛之縱向距離(m)-(AH)
- A 空間內最近車輛之橫向距離(m)-(AV)
- B 空間內最近車輛之真實座標(x)-(BX)
- B 空間內最近車輛之真實座標(y)-(BY)
- B 空間內最近車輛之橫向距離(m)-(BH)
- B 空間內最近車輛之縱向距離(m)-(BV)
- C 空間內最近車輛之真實座標(x)-(CX)
- C 空間內最近車輛之真實座標(y)-(CY)
- C 空間內最近車輛之縱向距離(m)-(CH)
- C 空間內最近車輛之橫向距離(m)-(CV)
- D 空間內最近車輛之真實座標(x)-(DX)
- D 空間內最近車輛之真實座標(y)-(DY)
- D 空間內最近車輛之縱向距離(m)-(DH)
- D 空間內最近車輛之橫向距離(m)-(DV)
- E 空間內最近車輛之縱向距離(m)-(EX)
- E 空間內最近車輛之橫向距離(m)-(EY)
- E 空間內最近車輛之縱向距離(m)-(EH)
- E 空間內最近車輛之橫向距離(m)-(EV)

共 24 個輸入變數，LSTM 的結構特性可以有效計算長時間連續狀態的預測變數，將車流資料依時間序列(t+Δt)及車輛編號排列，寫成輸入矩陣，依 LSTM 結構如圖所示，每個時序 t 之資料輸入值矩陣I_i^t為一次的 time step 分割層，而隱藏層狀態h_i^t為多層之 MLP 隱藏層的單元記憶細胞，輸出層o_i^t ，連接各時階層之連接線為時間張量的流動，如圖 5.1 所示。

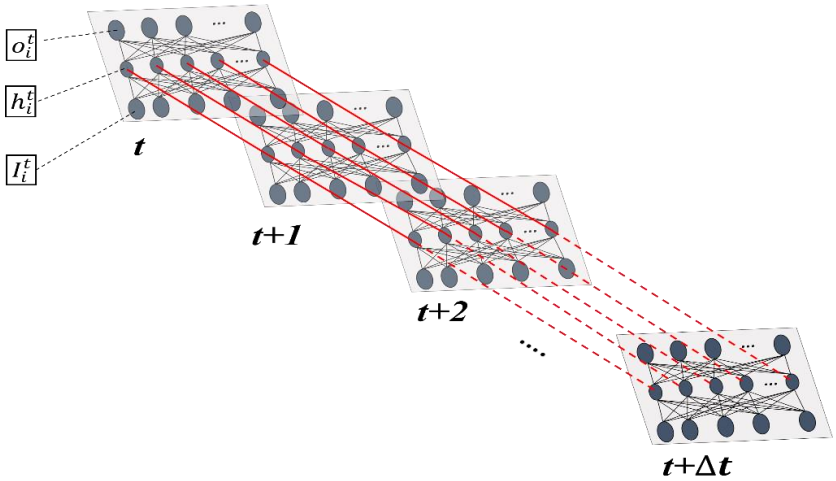

圖 5. 1 The Tensor's Flow at Time-Sequential Order

故將車流資料處理為依時序流動的向量單元，每個時序都有 Input 值，將初始矩陣形式設計成輸入單元為 292*24=7008 的向量矩陣，其中 292 為每 0.5 秒共 292 個時階，24 為上述之 24 個輸入變數，一行輸入矩陣可表示為:

[第 0.5 秒目標車 24 個數據, 第 1 秒目標車 24 個數據, ……, 第 146 秒目標車 24 個數據]

得到長度為 7008*1 的矩陣，一輛機車對應一組 Input 資訊，完整的輸入矩陣可假設共 N 輛機車 T 個時階，故輸入數據為 N*T 之大型矩陣。

$$\begin{bmatrix} 1\text{ 號機車真實座標}x & 1\text{ 號機車真實座標}y & \dots & \dots & 1\text{ 號機車 E 空間橫向距離 m} & 1\text{ 號機車 E 空間縱向距離 m} \\ 2\text{ 號機車真實座標}x & 2\text{ 號機車真實座標}y & \dots & \dots & 2\text{ 號機車 E 空間橫向距離 m} & 2\text{ 號機車 E 空間縱向距離 m} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ N\text{ 號機車真實座標}x & N\text{ 號機車真實座標}x & \dots & \dots & N\text{ 號機車 E 空間橫向距離 m} & N\text{ 號機車 E 空間縱向距離 m} \end{bmatrix}$$

初步實驗矩陣設計用意為，將每一輛編號機車定義為隨著時階存在的車輛，當機車離開該路段，所有資訊數據以 0 表示表示，此矩陣設計用意可以同時訓練每輛機車座佔據之道路時間，進而得知該路段之機車車流狀態，輸出變數設定為個別機車下一個時階(t+1)之座標值(x,y)，每一組編號機車的輸入向量(t)對應下個時階(t+1)之座標值作為輸出向量，輸入及輸出資料設定完成將資料匯入，初步資料部分編排形式為表 5.1 所示，可得知並不是所有的時間點皆為有車狀態，若空間無車，需定義無車時的變數設計，假若將全部

變數設為 0 變數，訓練時便無法有效分辨各個類別空間的變數差異，故將無車時的變數定義以虛擬車輛假設，將無車狀態假設為該空間外之最大距離外之最近車輛，各空間數值可在無車時分辨其差異性，表 5.1 標記部分即為虛擬車輛填充值。

輸出變數方面，本研究認為欲求目標機車之移動狀態及推進模式，最重要的兩個參數即為目標車下一時階速度(Km/Hr)及位置(x,y)，得知這兩項資訊能進一步推算出加速度值及目標車位移程度，設定輸出及輸入變數後設計 LSTM 之網路架構，依初步實驗矩陣設計神經元及隱藏層的編排，進行實驗訓練，多次實驗結果發現，預測位移量的方均跟誤差(RMSE)始終無法調整到較合理的數值，以本研究探討之機車移動行為模式，預測包含推進位置、速度、加速度、橫向位移量等，模式設計將輸出變數設計為預測的位移量及速度，並觀察預測值的波動，經過一系列的數據實驗，經由不斷觀察驗證指標方均跟誤差(RMSE)及遺漏值參數，利用 RMSE 將預測值及實際值整理為客觀的的誤差級距以利比較其預測準確度。

$$RMSE = \sqrt{\frac{1}{n}\sum_{t=1}^{n}(y_t - y_t')^2}$$

其中: y_t為機車推進參數； y_t'為預測值；n 為總樣本數。

初步設計將作數值座標作為輸出變數後，並評估隱藏個數層及層數，多次實驗發現階段模式方均跟誤差(RMSE)無法收斂至較為合理的數值如圖 5.2，將多種組合加以嘗試後，數值型的輸出變數亦無法有效收斂至合理範圍內，重新思考輸入與輸出變數的關係後，故決定重新設計輸出變數。

表 5-1 車流資料編排形式

秒	車編號	目標車座標		移動距離(m)	速度(km/hr)	A 範圍車輛		B 範圍車輛		C 範圍車輛		D 範圍車輛		E 範圍車輛	
		x	*y*			*x*	*y*	*x*	*y*	*x*	*y*	*x*	*y*	*x*	*y*
0.5	1	72.1191	3.91396	9.84707	70.8989	72.119	2.334	87.5600	8.10746	84.879	3.91396	80.5162	4.86837	72.1191	5.4939
1	1	76.487	2.17857	10.7045	77.07308	76.487	0.5985	89.247	0.5985	79.836	2.571	89.247	3.7585	75.875	3.2615
1.5	1	61.6609	3.27445	9.73741	70.10935	59.832	2.6148	87.1307	2.33779	74.421	3.27445	65.3605	4.26271	61.6609	4.854
1.5	2	76.367	7.21665	11.1481	80.26633	76.367	5.6367	89.127	5.6367	84.725	6.915	89.127	8.7966	76.367	8.796
2	1	53.4110	4.40098	9.97366	71.81035	53.411	2.821	71.2707	3.36162	66.171	4.40098	66.171	6.724	52.814	4.8251
2	2	33.1782	5.14410	7.09111	51.05603	31.536	4.314	42.1395	4.78205	45.938	5.14410	39.1687	6.8520	33.1782	6.724
2.5	1	44.5448	7.28018	12.2196	87.98135	44.544	5.7001	57.304	5.7001	570304	7.28018	57.304	8.8601	42.843	8.4638
2.5	2	25.0495	5.77398	7.44096	53.57491	23.958	4.692	41.5360	5.21301	27.0495	5.415	37.809	7.3539	25.0495	7.353
25	3	42.7934	4.65248	8.6923	62.58469	42.793	3.0724	55.553	3.0724	570553	4.65248	51.8534	5.754	41.841	5.6824
3	1	4.10980	5.61718	12.3164	88.67864	2.342	4.621	16.8698	7.1971	16.8698	5.61718	16.869	7.197	4.10980	7.197

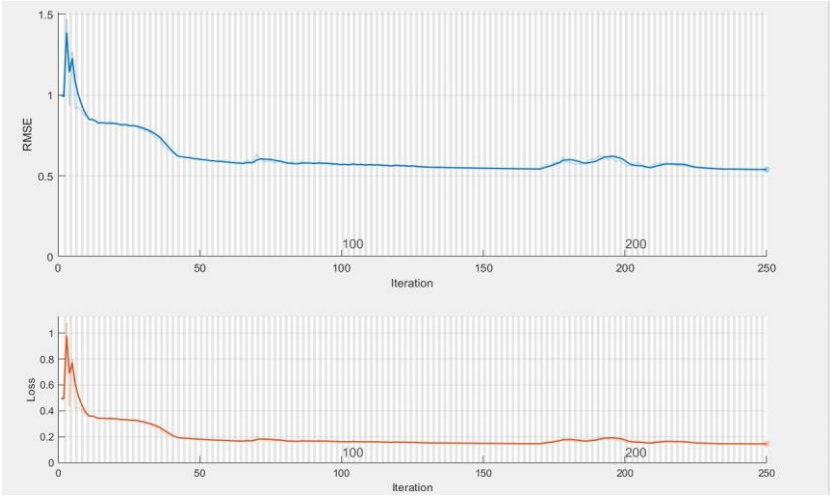

圖 5. 2 初步實驗訓練結果

5.1.2 輸出變數

上述所提之加速度及橫向位移量等數值，只需預測其下一時階之移動位置資訊即可推算出加速度及速度等值，利用推進距離、周圍空間影響範圍、範圍車輛影響間距三者間建立邏輯的相互關係，將數值的輸出結果調整為類別型分類法，設計類別型輸出變數，需考慮幾種形式，包含二為座標的車流模式、機車最大偏向角及行駛距離等因素，將平面座標分類成格位空間處理，假設車輛及周圍環境皆為統一情況，向前推進只需考慮其偏向角及最大推進距離，最大偏向角的決定在於機車在行進中，單位時間內所能偏轉的最大角度，故假設本研究在機車的車速機加速度不受外在因素影響的狀態下，推進長度為每 0.5 秒 S 公尺，在此速率下有一行駛偏向角θ_s，則，θ_s角度的定義為物體作等速運動時的切線角，需找出機車在執行偏移行為時速度與角度關係，如圖 5.3 所示。

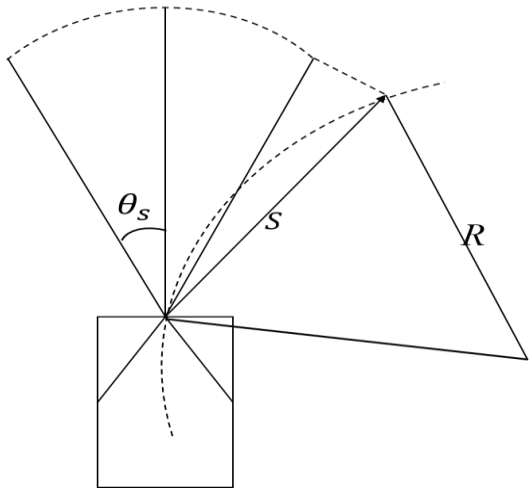

圖 5. 3 機車偏移角度示意

R 為圓周半徑，假設 A 為 0.5 秒之移動距離 S 所對應的圓心角度，A 可經由公式得知:$A = cos^{-1}(1-\frac{s^2}{2R^2})$，求得偏向角度 θ_s=$90^\circ - \frac{180^\circ - A}{2} = \frac{A}{2}$，得知偏向角度後，將前進距離換算成若干格位，格位大小的計算依據最大之轉彎半徑 R 及機車每 0.5 秒之最大推近距離推算，根據公式:$R = \frac{V^2}{g(f+e)} = \frac{V^2}{127(f+e)}$，$V$ 為機車車速，固可推算目標車(t)位置偏移後(t+1)之偏移距離，以本研究之影響距離推算以最大橫向距離定義約為一個車身寬度，即可將機車推進簡化成幾種可能前進之路線，並依格位將 0.5 秒內所有可能前進之格位劃分為圖 5.4 所示。

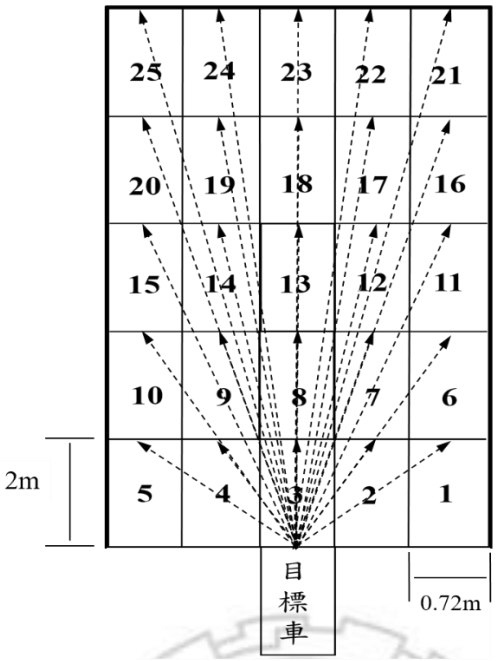

圖 5.4 機車格位移動狀態

如圖 5.5 所示，將輸出變數分為 25 個格位空間，使機車移動分為 25 個推進方向，之後可以根據格位推算機車每 0.5 秒的移動距離，移動速度、加速度等值，將每一輛編號的目標車共 3024 筆車流資料下一時階的移動座標分類至 25 個格位空間，輸入及輸出變數設定完畢後，輸出變資料矩陣形式為:

$$\begin{bmatrix} \text{1 號機車 0.5 秒類別空間} & \text{1 號機車 1 秒類別空間} & \cdots & \cdots & \text{1 號機車 145.5 秒類別空間} & \text{1 號機車 146 秒類別空間} \\ \text{2 號機車 0.5 秒類別空間} & \text{2 號機車 1 秒類別空間} & \cdots & \cdots & \text{2 號機車 145.5 秒類別空間} & \text{2 號機車 146 秒類別空間} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \text{N 號機車 0.5 秒類別空間} & \text{N 號機車 1 秒類別空間} & \cdots & \cdots & \text{N 號機車 145.5 秒類別空間} & \text{N 號機車 146 秒類別空間} \end{bmatrix}$$

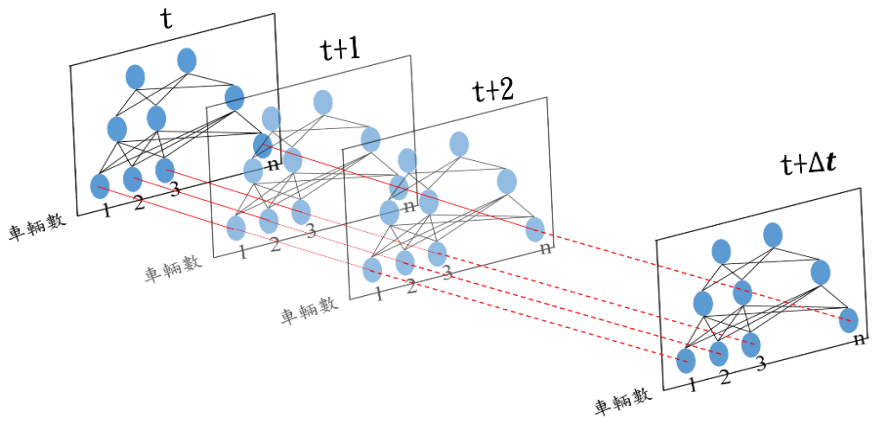

圖 5. 5 第二次實驗網路結構示意圖

輸出變數矩陣對應輸入矩陣之各個時階點的 24 個參數，重新設計程式結構，調整隱藏層，為求模式收斂將輸入變數特徵標準化，針對每一個輸入類別調整。

$$\text{標準化：}\ \hat{x}_{ij} = \frac{x_{ij}-\bar{x}_{ij}}{\sqrt{\frac{\sum_{j=1}^{N}(x_{ij}-\bar{x}_{ij})^2}{(N-1)}}} \tag{5.1}$$

標準化目的為將分散的數據進行統一整理，將數據統一規格化可以讓資料更有效率的判讀，因 LSTM 網路所用之擠壓函數為 *tanh(x)*函數，為避免特徵函數在某一範圍區間對資料產生飽和的不敏感反應，也就是無法對函數激活，造成訓練數值會無法收斂，故將資料進行 Normalization 處理使資料參數能維持在固定區間，而設計批次訓練次數用意為，使網路在各隱藏層間訓練時能學習上一批次的的權重值遺失函數，以利修正梯度，將標準化完畢之輸入資料矩陣建立訓練模式，第二次實驗結果以預測程度準確性表示，參數調整結果如表所示，訓練次數 65 次，並設計批次學習量和學習速率等參數，訓練結果如圖 5.6 所示。

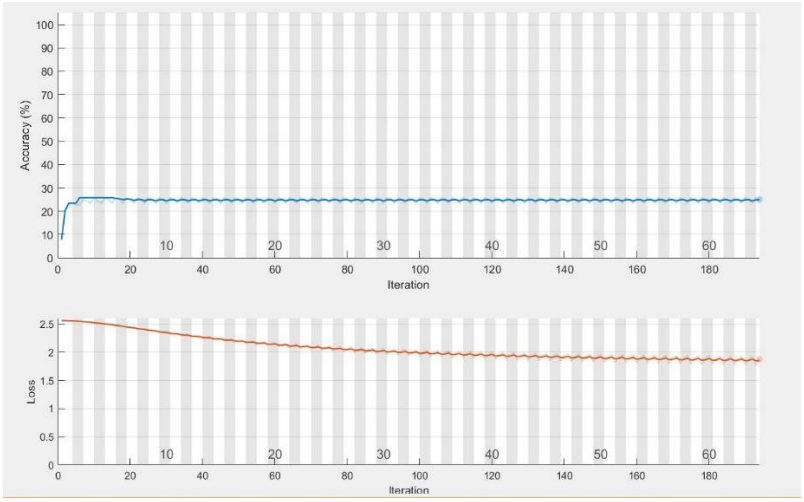

圖 5. 6 第二次實驗訓練結果

第二次實驗結果為圖 5.6 所示，預測準確率只能達到 30%，並不符合預期，分析可能原因為輸出變數設計問題，因長時間的序列資料，目標車不可能存在於同一路段中，但原始的結構設計目的為了使車流資料存在時序性的訓練過程，而將每輛獨立機車當作一序列矩陣，導致長時間的時間序列中只有存在目標車輛的時間範圍內才有參數值產生，其餘皆為空白值填零，導致過多的空白值使模式之預測能力下降，所以衍生問題是變數太多造成模式無法預測，但調整矩陣型態便無法將資料以時間序列處理，故輸入及輸出矩陣的設計條件為依時間序列排序的順序資料，解決長時間資料後續空白值問題，並可以對應輸出矩陣，結合上述理念重新設計輸入矩陣形式，當資料型態依目標車編號進行分類時，雖然可以針對機車個別的時序推進資料訓練，但並無法有效對應輸出矩陣，因輸出變數共分為 25 個移動方向，但同一目標車在有限的連續時間內無法分類出 25 個方向資料，結合上述之問題點重新設計輸入矩陣結構，設計矩陣表示重新設計神經網路的訓練結構及其規則，上述結構對於時間張量的理解及設計理念為，對時間與車輛數建立兩者間的關聯，但此結構需要大量車輛數據以添補空白的時序資料，但本研究使用的攝影測量法，無法於有限時間內收集極大量的資料提升準確度，所以需改變模型的運算結構，為了能使結構有足夠的資料筆數訓練且能依時序性排列，多次實驗後以時間與個別資料數關係建立矩陣形式，再建立同一編號車輛的相互連結關係，將矩陣形式調整為依時間

序列資料 T*N 形式，T 為依時間及 24 個訓練參數排列的 24*t 矩陣，N 為資料筆數，所以網路結構設計為圖 5.7 形式，而輸出矩陣也可對應資料數執行完整的訓練。

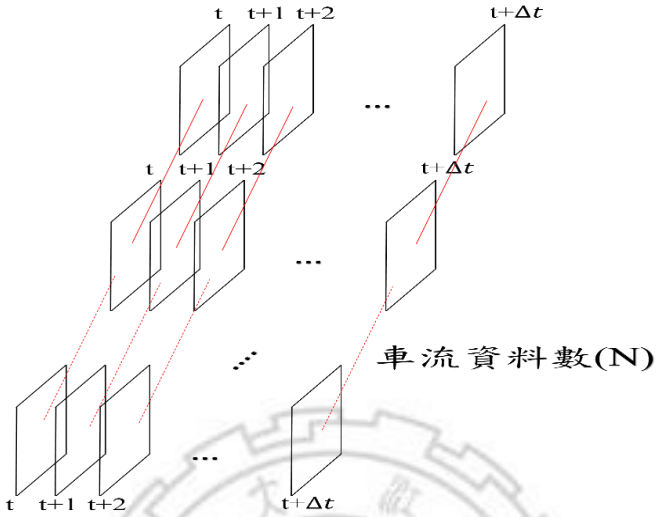

圖 5.7 第三次實驗網路結構示意圖

$$\text{輸入矩陣:}\ \begin{matrix} 1 \\ 2 \\ \vdots \\ \\ N \end{matrix} \begin{Bmatrix} [23*t] \\ [23*t] \\ \vdots \\ \vdots \\ [23*t] \end{Bmatrix} \tag{5.1}$$

資料形式編排如式(5.1)所示，訓練參數設計以訓練次數、隱藏層個數、計算批次量及學習速率等設計，並由訓練參數圖逐步調整以取得最佳參數值，初步訓練參數設定，為了取得更好的預測結果及訓練效率，將資料進行排序並填充資料，第三次實驗初步訓練成果如圖 5.8 所示，雖未執行資料填充整理，但可看出準確率已隨訓練次數上升，可以成功分類初始設定之 25 個輸出結果，表示此矩陣結構得以執行，但是否可得出合理的預測結果，還續後續實驗的參數調整及模式驗證等。

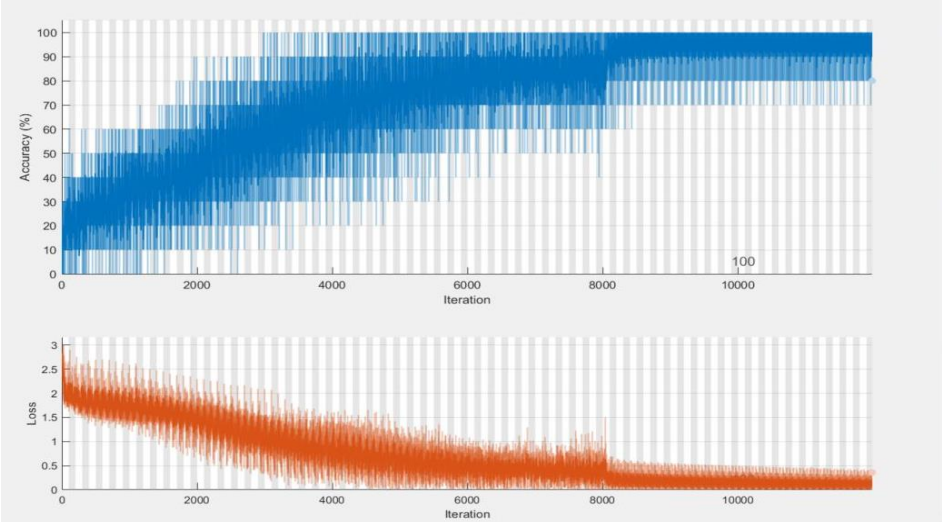

圖 5. 8 第三次實驗訓練結果

圖 5.8 可以看出模式的訓練震盪幅度相當大，收斂結果也尚未趨於穩定狀態，模式訓練過程會連帶影響預測結果，目前結果可以判斷為整個過程趨勢是能將機車推進之 25 個分類方向分出，以達最初的實驗目的，而之後實驗目的為將訓練模式調整為最佳狀態，以提升預測精準度。

5.2 參數實驗及驗證

訓練參數設計需要考慮訓練時間、收斂速度及狀態等因素，在權重初始化方面，通常採用隨機生成方式，如何藉由訓練資料的批次(batch size)處理使權重均勻分布降低訓練次數，當批次數量太小，會造成遺失值函數震盪不收斂，所以網路結構較為複雜時訓練批次設定便會影響網路的收斂成果，以訓練資料形式來說，當資料進行批量處理時可以有效地將資料分層分割，利用分割的資料量逐步進行梯度搜尋，所以需在可接受的訓練時間內確定最小的批次數量，訓練結果又會影響預測值，找尋合理的參數值並達到最佳的預測準度為本章節之目的。

將參數資料分為前 75%，2305 筆訓練資料及後 25%，765 筆驗證資料，檢視預測準確度驗證模式之可行性，以訓練模式之收斂程度及遺失值作為訓練指標，因訓練過程編排會影響預測的精準度，所以須找到一個最佳的參數組合，包含隱藏層節點數量的設計，

及最小批次數量，訓練指標以準確率(Accuracy)及 Loss 值作為兩項參考指標，準確率越高，Loss 值越低表示模式訓練可以將資料進行完善分類訓練，將訓練結果可視化用意為觀察震盪幅度代表模式的收斂情況，以利調整參數。

初步實驗參數，將資料進行分類填充，以填充後之最小批次進行訓練，圖為資料填充後經排序，設定最小批次 30 及隱藏層記憶塊數量 100 個單元結點，最大訓練測迴圈數為 90 迴圈，圖 5.8 看出模式收斂幅度雖已縮減但震盪幅度還是相當大，故調整神經元個數。

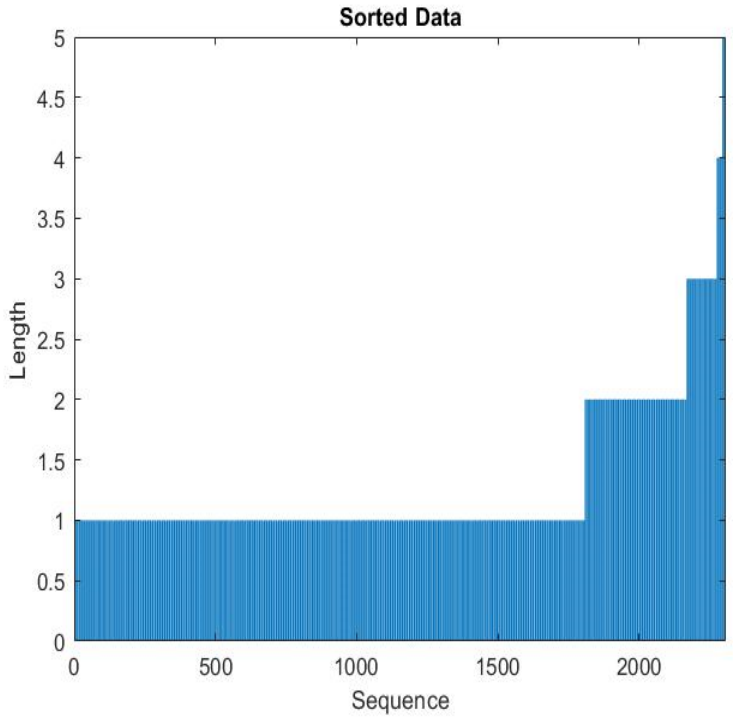

圖 5. 9 資料填充排序

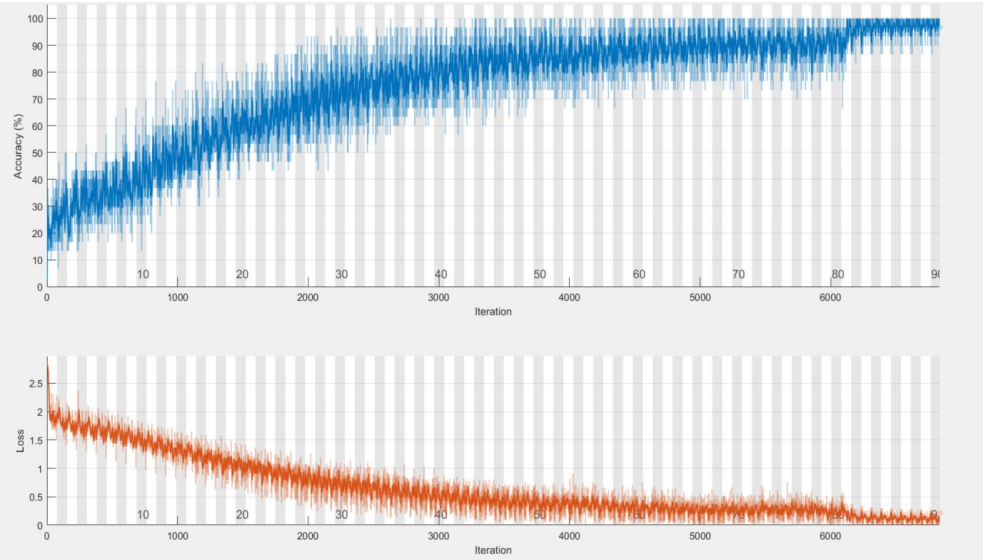

圖 5. 10 模式訓練圖(一)

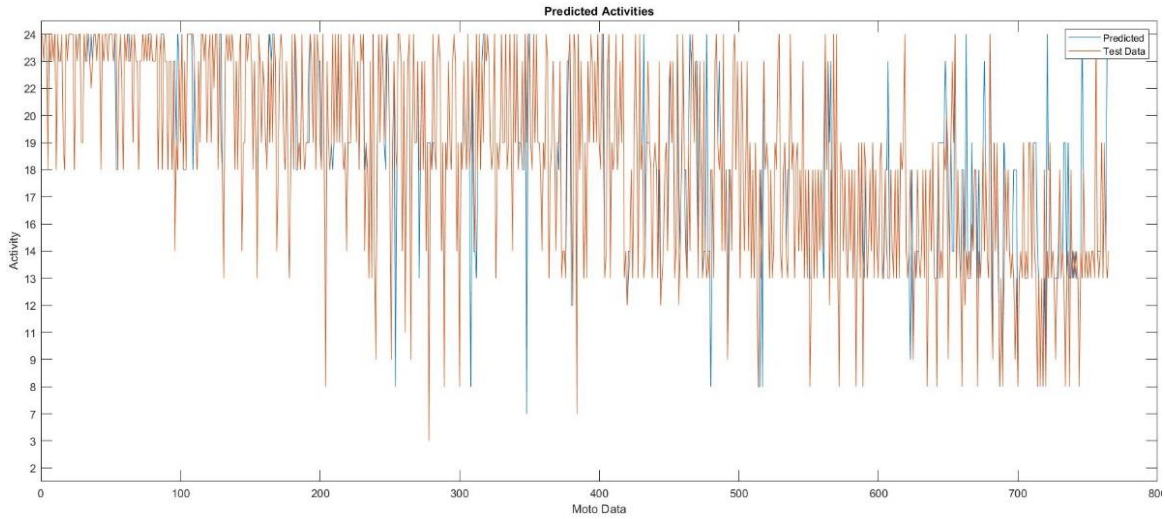

圖 5. 11 預測結果擬合圖(一)

預測結果如圖 5.11 所示，為 84.58%，表示模式有近 8 成 5 的預測能力，但訓練震盪大幅的地擺動表示收斂結果還是不穩定，為了得到完善結果將參數做進一步調整，為了加快模式收斂速度，故擴大梯度搜索範圍，調整梯度下降幅度為 100 批次量，並拉長訓練迴圈次數。

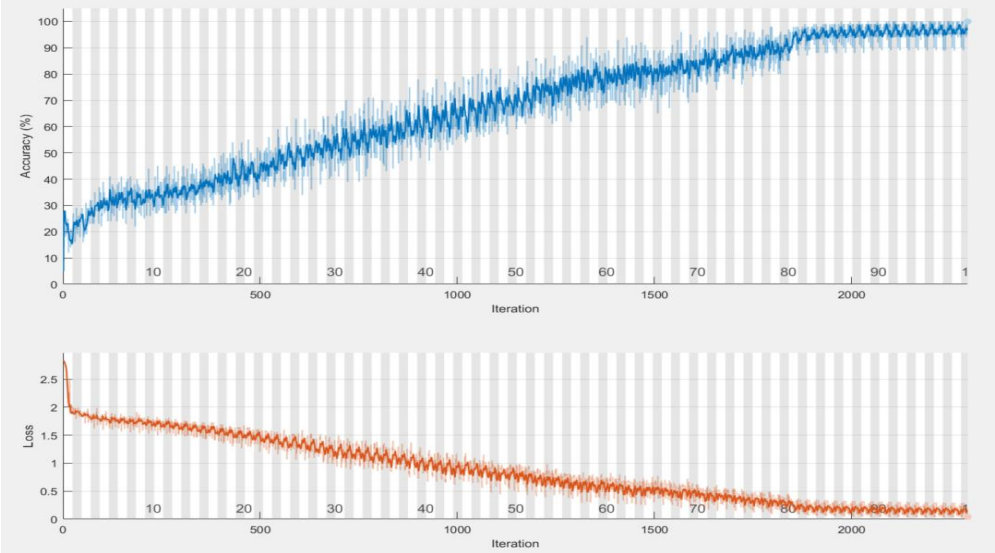

圖 5. 12 模式訓練圖(二)

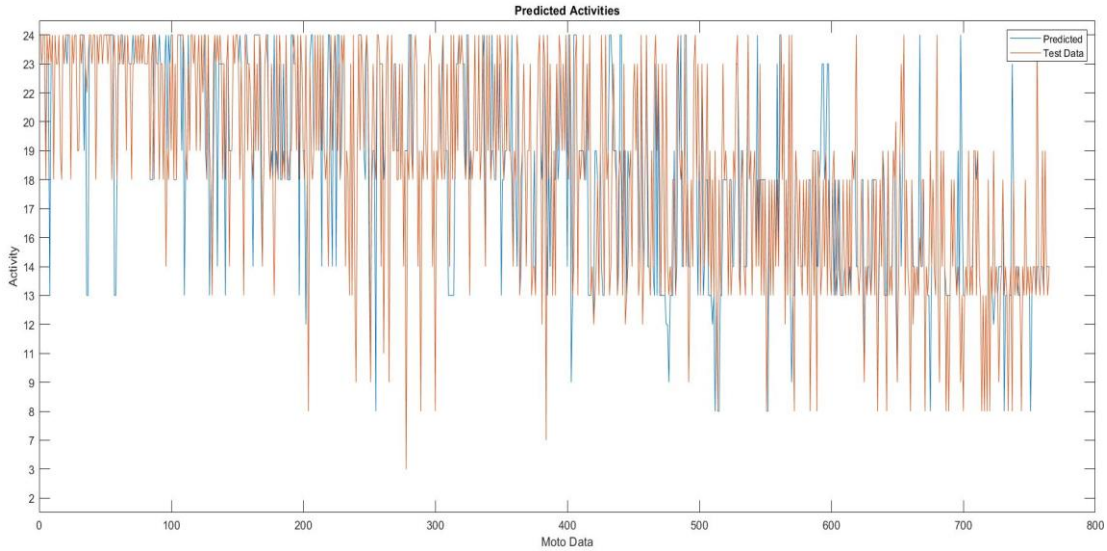

圖 5. 13 預測結果擬合圖(二)

圖 5.12 可看出收斂震盪情況已有改善，所花費訓練時間亦有縮短，所以現階段須探究梯度的下降是否過快問題，倘若收斂速度過快，將影響預測結果的準確度，將測試集數據利用圖實驗訓練參數預測結果如圖，預測結果已下降至 67.71%，表示梯度搜索範圍過大導致預測模式不準確，所以模式訓練最小批次 minibatch 應設定於 30 至 70 之間，

經多次實驗調整隱藏層神經元數將神經元建立為 150 個隱藏神結點，實驗後發現收斂結果反而較差且訓練時間亦會拉長，多次實驗模式的最佳準確率約為 85%左右，訓練過程及訓練次數會依情況不同有所取捨。

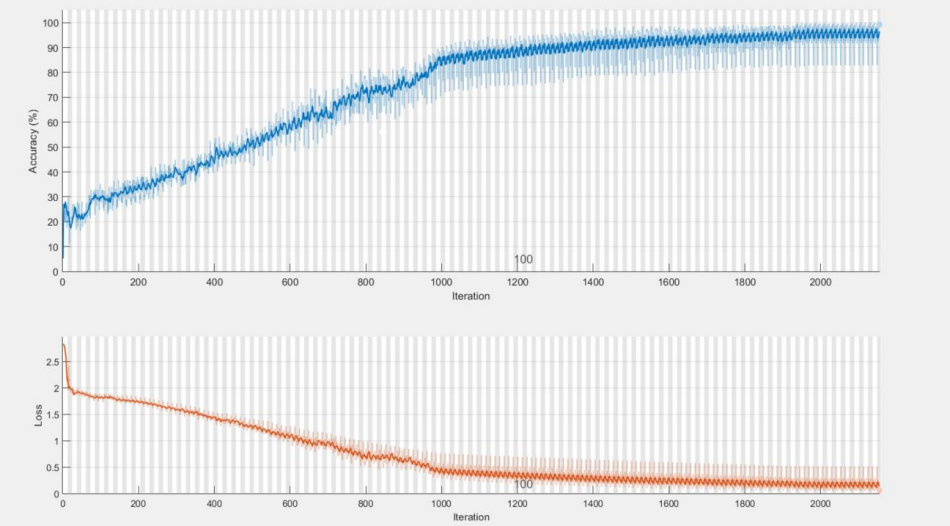

圖 5. 14 模式訓練圖(三)

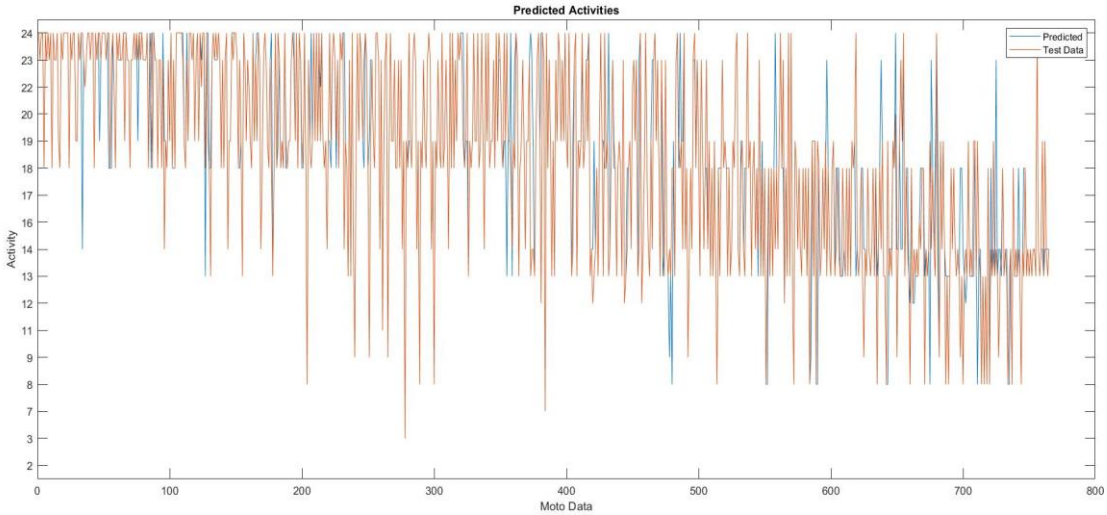

圖 5. 15 預測結果擬合圖(三)

圖 5.14 為調整後之最佳收斂程度預及訓練速度，預測率為 81.7%，本研究認為，若以目前設計的預測模式需提高要再預測準確率，勢必要增加訓練資料，但目前訓練資料

2305 筆資料量，經驗證資料 765 筆測試已有八成以上的準確率，說明模式已具備相當程度的預測能力，後續研究只需加入不同的限制條件參數即可，而本研究主要設計模型的運算結構及輸入輸出變數結構，以預測機車在市區道路行駛時的推進行為模式，預測機車在車道中的推進行為會依據空間內鄰車的資訊不同而造成不同的移動情況，設計預測模型以利後續模擬的使用及開發，本研究利用深度學習較強的分類特性，將誤差控制在範圍內進行分類後設計運算結構，建立一系列的邏輯運算，包含變數設計機車空間定義及推進規則，因 LSTM 的運算結構是建立在 RNN 網路的運算基礎上，所以透過 LSTM 網路記憶塊的運算，可以設置多種運算規則，而上述依機車車流資料預測的動態結果，之後將資料依時序重新整理可得完整的路段機車車流資料。

第六章 結論與建議

6.1 結論

本研究主要以路段機車車流為主要研究對象，建立目標機車與其周圍空間內與鄰車的互動關係，預測機車於一般市區道路行駛時的推進行為，透過模型的建立及定義影響參數，使機車的推進行為預測更能貼近實際車流，預測結果及實驗結論彙整如下:

一、本研究以深度學習長短時記憶演算法(Long Short-Term Memory, LSTM)建立一機車行為推進模式，透過機車影響範圍空間的設計，定義輸出與輸入變數，進而設計變數與網路程式結構 LSTM 演算法建立一系列預測模型。

二、機車車流相較於汽車複雜許多，因此預測機車行為勢必建立新的邏輯規則，本研究探究影響機車行為的橫向及側像鄰車的距離座標，利用機車騎士視野及速度關係建立影響的空間範圍，利用橫向及縱向實際距離作為預測推進的影響參數。

三、本研究捨棄數值型的輸出結果，改以分類結果預測機車的推進行為模式，首先是機車的移動特徵過於動盪及細微，倘若在不斷變動的大量機車車流情況下，數值型輸出變數的運算誤差會使模式動盪過大，因為本研究以每 0.5 秒時階為一筆預測資料，而大量的累積誤差會導致機車的推進行為趨勢不準，另一方面是實驗後大量的輸出值使模式無法收斂至合理範圍，均方根誤差值(RMSE)無法下降至合理範圍內，故本研究的解決方法是先將誤差值設定於範圍內，再利用深度學習演算法的結構特性將誤差範圍縮至最小，以機車的推進方向結合座標格位平台設計 25 個分類格位，如此可推算機車之移動距離、速度及加速度等數值。

四、結合設定之範圍空間內的鄰車各項參數及目標車速度及座標資訊，建立輸入及輸出變數的相互關係後建立預測模型，預測的目標藉由目標車與鄰車的互動行為參數，

作為預測準則，預測目標車之下一步的推進行為，經由參數驗證有 85%～90%以上的預測率，表示模式已具備一定的可信度及預測準確率，模式嘗試控制輸入變數的梯度下降過程及各項訓練參數以達到最佳訓練效率，梯度的下降率及訓練速度對訓練的收斂程度影響較為敏感，所以以 150 至 100 minbatch 設計批次量，minbatch 可以對應於輸入變數的壓縮整理，將資料進行填充排序可以有效提升訓練效率及改善收斂震盪幅度，使模式趨於穩定狀態。

五、LSTM 網路基礎是建立在迴饋式神經網路上的結構，，matlab 可對深度學習結構進行編排，故對記憶塊的編寫可以有多種形式的表現，本研究針對機車車流資料建立時序排列的向量結構對資料執行分類過程，使模式得到可行的分類預測能力。

6.2 建議

一、本研究蒐集路段機車車流方式為攝影測量，經矩陣轉換後再以人工取點方式蒐集機車個別座標資訊，未來研究若配合影像辨識系統將影像座標直接轉換為研究資訊可以減少蒐集樣本時間，本研究利用非專業攝影機蒐集路段車流資料，再經由直接線性轉換法(DLT)求解座標，此法是針對非測量用攝影機所推導的一系列程序公式，精確度可能不及專業測量用攝影機，所以蒐集的車流資料需經過詳細的調整並篩選，將誤差調整至最小，以提升樣本之準確率，未來研究可利用空拍機或專業用測量攝影機配合影像辨識技術得到更準確的車流資料

二、本研究在輸入變數的設計參考張正達(2012)、林育瑞(2002)等人研究，研究證實機車周圍領地空間確實會影響機車的推進行為模式，但影響機車行為變數可能還包含機車騎士之心理因素或外在環境因素等，且機車在針對不同的空間環境下表現出的行為模式也會跟著不同，例如鄰車的車種類別等關係，機車周圍鄰車為公車等大型車輛的互動行為，後續研究可針對車種類別分別訓練模式使模式學習詳細完整的樣本，以使用於任何情況下之機車車流模擬。

三、本研究以承德路七段路段車流為主要實驗路段，因車流資料的蒐集方式以人工取點方式較為耗時，故無法蒐集多個路段車流用以建立完整的訓練模式，但本研究利用深度學習演算法強大的學習能力，能利用有限的資料有效預測路段機車車流的推進行為模式，後續研究可配合影像辨識蒐集不同路段更大量車流資料，建立完整的訓練庫。

四、在輸出變數方面，呼應上述建議因時間及資料數量問題，就算深度學習演算法有極強的運算及推理能力，但無不同狀態亦或是特殊狀態車流資料支撐，可能也無法有效體現各種狀態下的機車推進行為，本研究設定之 25 個格位已經能解釋範圍內大部分機車推進的各類型態，但特殊情況下的推進方式如機車遭遇公車靠站的突然切入等的外在環境因素影響，後續研究可針對此點深入探討。

參考文獻

1. Ahmed, K., Ben, A.M., Koutsopoulos, H.N., Mishalani, R.G. (1996). Models for freeway lane changing and gap acceptance behavior. *Proceedings of 13th International Symposium on Transportation and Trajfic Theory, Lyon France.*

2. Ahmed, K. (1999). Modeling drivers' acceleration and lane changing behavior. *Unpublished doctoral dissertation, Massachusetts Institute of Technology.*

3. Abdelhadi, A., Guy, P. (2007). A Long Short-Term Memory Recurrent Neural Network Framework for Network Traffic Matrix Prediction. *LIP6 / UPMC. Paris, France.*

4. Carlos, F.D. (1981). Estimation of gap acceptance parameters within and across the population from direct roadside observation, *Transportation Research Part B vol. 15. pp.1-15.*

5. Duc, N.H., Manfred, B., Anh, T.V. (2003). Modelling mixed traffic flow at signalized intersection using social force model, *10th EASTS.*

6. Florent, A., Arnaud, D.L.F. (2017). An LSTM Network for Highway Trajectory Prediction. *IEEE 20th International Conference on Intelligent Transportation.*

7. Felix, G. (2001). Long Short-Term Memory in Recurrent Neural Networks. *University Hannover.*

8. Gipps, P.G. (1986). A model for the structure of lane-changing decision, *Transport Research Part B. pp. 403-414.*

9. Ishizaka, T., Fukuda, A. (2010). Development of motorcycle running simulation model under mixed traffic flow and its verification. *12th WCTR.*

10. Jurgen, S. (2014). Deep Learning in Neural Networks: An Overview. *Technical Report IDSIA-03-14.*

11. Nguyen, L.A. (2011). An application of social force approach for motorcycle dynamics. *Journal of the Eastern Asia Society for Transportation Studies.*

12. Rui, F., Zuo, Z., Li, L. (2016). Using LSTM and GRU Neural Network Methods for Traffic Flow Predition. *31st Youth Academic Annual Conference of Chinese Associaton of Automation.*

13. Toledo, T. (2007). Driving Behaviour: Models and challenges, *Transport Review, 27. pp. 65-84.*

14. Tzu-Chang, L. (2007). An Agent-Based Model to Simulate Motorcycle Behaviour in Mixed Traffic Flow. *The degree of Doctor of Philosophy of the University of London and Diploma of the Membership of Imperial College London.*

15. Wiedemann, R. (1974). Simulation des Strassenverkehrsflusses. Schriftenreihe des Instituts für Verkehrswesen der Universität Karlsruhe, *Band 8, Karlsruhe, Germany.*

16. Xiaolei, M., Zhimin, T., Yinhai, W., Haiyang, Y., Yunpeng, W. (2015). Long short-term memory neural network for traffic speed prediction using remote microwave sensor data. *Transportation Research Part C . pp. 187-197.*

17. Yang, Q.I., Koutsopoulos, H.N. (1996). A Microscopic Traffic Simulation for evalution of dynamic traffic management system, *Transportation Research Part C. pp. 113-129.*

18. Yongxue, T., Li, P. (2015). Predicting Short-term Traffic Flow by Long Short-Term Memory Recurrent Neural Network. *IEEE International Conference on Smart City.*

19. 王郁凱，民國九十七年。機車專用道車流模式建立之研究。碩士論文，國立交通大學運輸科技與管理研究所。

20. 王鴻傑，民國一百零二年。汽車及機車於市區道路混合車流行為模式。碩士論文，國立交通大學運輸科技與管理研究所。

21. 交通運輸研究所，民國一百零一年。交通技術研發與人才培育規劃研究。

22. 何家娟，民國九十年。微觀汽、機車混合車流模式之研究。碩士論文，國立交通大學運輸科技管理學系。

23. 林育瑞，民國九十一年。利用類神經網路構建機車車流模式之研究。碩士論文，國立成功大學交通管理研究所。

24. 林日新，民國九十九年。汽機車混合車流模擬—新細胞自動機模型之研發。博士論文，國立交通大學交通運輸研究所。

25. 邱德紋，民國九十四年。構件機車運動推進模式-以魚體運動模型為基礎。碩士論文，私立淡江大學運輸管理學系運輸科學研究所。

26. 范俊海，民國七十九年。影像處理技術建構交通資料蒐集系統之研究。博士論文，國立台灣大學土木工程學研究所。

27. 郭峰豪，民國一百零一年。量子視覺流跟車行為模擬模式建構。碩士論文，國立交通大學運輸科技與管理研究所。

28. 徐立新，民國九十四年。考量跟車及變換車道行為之高快速公路微觀車流模式研究。碩士論文，國立交通大學運輸科技與管理學系。

29. 許義宏，民國九十六年。巨觀混合車流模型構建。碩士論文，國立成功大學交通管理科學研究所。

30. 陳凱勤、張永克、陳宛君、朱玉英、郭書沛、張心怡、廖羽苹、林靜芬，民國一百零一年。車流細胞自動機解析公式與參數較估之研究。研究報告，中華大學運輸科技與物流管理學系。

31. 陳瑄易，民國一百零二年。基於經驗模態分解法之遞迴式赫米特類神經網路預測模型–以短時交通流量預測為例，電腦與通訊第 142 期。

32. 張維翰，民國九十五年。郊區路段微觀混合車流特性分析與模式建立。碩士論文，國立交通大學運輸科技管理學系

33. 張耕碩，民國一百零三年。市區道路可接受側向間隔分析與應用之研究。碩士論文，私立淡江大學運輸管理學系運輸科學研究所。

34. 張正達，民國一百零一年。混合車流運動推進模式之研究-以臨近入口與紅燈號誌為條件。碩士論文，私立淡江大學運輸管理學系運輸科學研究所。

35. 黃國平，民國七十一年。混合車流二為座標模擬模式之建立及驗證。碩士論文，國立台灣大學土木工程學系。

36. 黃家耀、李子璋、陳彥佑、劉品均、羅湘盈、廖家慧、羅聖學、曾家瑜、黃維皓，民國一百零四年。混合車流模擬技術研發。研究報告，國立交通大學運輸科技與管理研究所。

37. 鄒芳諭，民國九十九年。已非測量性相機進行近景攝影測量探討。碩士論文，國立交通大學運輸科技與管理研究所。

38. 程凱建，民國一百零三年。混合車流號誌化路口微觀機車紓解模型之建立。碩士論文，國立台灣大學土木工程系。

39. 謝志偉，民國九十九年。混合車流格位傳遞模式之建立與驗證。碩士論文，國立交通大學交通運輸研究所。

40. 葉怡成，民國一百零四年。現代測量學

41. 羅菀綾，民國九十三年。機車路側淨空容忍度之研究。碩士論文，國立交通大學運輸科技與管理研究所。