

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：陶冶中 博士

藉由數位錄影資料辨識公路客運司機駕駛行為之研究

**A Study on Recognizing Highway Bus Driver's Behavior by
Using Digital Video Data**

研究生：羅家偉 撰

中華民國 110 年 06 月

謝辭

研究所生涯，說快不快說慢也不慢，一轉眼就畢業了。身為宜蘭在地子弟，深感宜蘭一直以來交通之不便。因此，這幾年來在葛瑪蘭汽車客運公司服務，本人深感能為提昇宜蘭的交通、觀光及運輸貢獻一份心力，是身為公司一員的我，內心之深深的榮耀。然而，由於本人非本科系畢業，在葛瑪蘭服務的職涯中，深感理論與實務基礎的不足，也受到同為在大學中擔任教授之大哥建議，讓我決定重新回到學校學習，因而有幸進入本系，成為淡江運管的一員。

在學習過程中雖然有很多不懂的相關知識，甚至對系上老師各種研究專長皆不甚了解，但在選擇陶冶中老師並加入其所率領的陶家班後，感到學習新事物的美好。雖然在就讀的過程中也曾經想過放棄，但受到老師與學長姊的鼓勵，讓我重拾我的堅強意志力，如今讓我終於能得到順利畢業的果實！

在研究所的歷程中，除了讓我學習交通運輸之相關知識外，最重要的是了解到一個人的成就，需要團隊的合作與很多貴人的相助，才能完成今日論文。所以在此，要非常感謝亭愷學長的輔導與指導，讓我學習到很多撰寫論文的技巧，也感謝銘倫、偉豪學弟在校內的事物協助，以及柏元學弟指導我如何快速解答學科考之各種題型，讓我順利通過考試。

當然，最感謝的是，當我在研究上遇到瓶頸時，皆會細心指導、耐心說明的指導教授陶冶中老師，透過陶老師不斷提點我，以引發我的學習動機及正向思考能力，並了解如何以嚴謹及正確的態度看待一篇研究的完成，才得以完成本篇論文。

論文名稱：藉由數位錄影資料辨識公路客運司機駕駛行為之研究

頁數：73

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：109 學年度第 2 學期碩士學位論文提要

研究生：羅家偉

指導教授：陶冶中 博士

論文提要內容：

目前多數客運業者多已裝設閉路電視攝影機於客運車輛，可針對司機行車行為進行錄影，本研究認為若能善用這些錄影資料來辨識司機異常之駕駛行為，則有助於輔導司機避免發生不良駕駛行為而提升行車安全。

在現場環境硬體與運算資源之條件下，本研究選定葛瑪蘭客運公司作為實證分析對象，經訪談該公司高階主管，決定採用後台駕駛影像資料進行司機駕駛行為影像辨識模型訓練與建構，並使用 R 語言開發工具建構卷積神經網路(CNN)模型，同時進行模型測試與修正，最終模型辨識率可達 94%，具良好之辨識能力，顯示透過影像辨識方式分析客運司機行車間之行為，證明可行。

為使辨識結果可應用於管理輔助，本研究加入後台之營運資料，並以視覺化軟體 Power BI 進行呈現，最後建立一有助於客運業者管理、輔導司機正常駕駛之決策輔助機制，以此提升安全效益。例如：針對過勞人員進行溝通與了解是否個人私下作息不正常，又或身體健康發生問題，需要透過排班調整進行改善、或是針對不良駕駛行為之司機進行勸導並勒令改善不良行為等，進而提升行車安全。

關鍵字：駕駛行為、數位錄影資料、卷積神經網路、資料視覺化

*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:73

A Study on Recognizing Highway Bus Driver's Behavior by Using Digital Video Data

Key word: *Driver Behavior, Digital Video Data, Convolutional Neural Networks, Data Visualization*

Name of Institute:

Graduate Institute of Transportation Science, Tamkang University

Graduate date: *June, 2021*

Degree conferred: *Master Degree*

Name of student: *Chia-Wei Lo*
羅家偉

Advisor: *Dr. Chi-Chung Tao*
陶冶中 博士

Abstract:

Current highway bus operators have installed in-vehicle CCTVs to record bus driver's behavior during transportation. It will be meaningful to enhance safety if these digital video data can be used to help bus drivers to avoid from abnormal driving behavior.

Considering on-site hardware and computational resources this study has chosen Kamalan bus company as the use case for empirical analysis. Having discussed with top managers at Kamalan bus company, this study used R language to present a CNN-based model with continuous iterations and tests. Empirical results showed that the accurate rate reached 94% and achieved the goal of feasibility of recognizing bus driver's behavior by using digital video data.

With the help of visualization tool Power BI this study used rear-end operation data to map with bus driver's behavior results. It is proven that Kamalan bus company awards recognition to this model because of positive responses of bus drivers in company. For example, overloaded bus drivers will be interviewed to understand why they performed abnormal driving behavior. Personal persuade measures or rescheduling work shit may be taken to improve driving behavior for transportation safety.

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 研究目的與限制.....	3
1.2.1 研究目的.....	3
1.2.2 研究限制.....	4
1.3 研究範圍與流程.....	5
第二章 文獻回顧.....	7
2.1 駕駛異常行為.....	7
2.2 影像辨識.....	14
2.2.1 影像處理.....	14
2.2.2 圖像分析.....	15
2.2.3 移動物體偵測技術.....	16
2.2.4 色彩空間.....	18
2.2.5 灰階與影像二值化.....	19
2.3 深度學習.....	20
2.3.1 人工神經網路.....	20
2.3.2 深度學習.....	23
2.4 公路客運服務評鑑.....	25
2.5 文獻評析與小結.....	26

第三章 研究方法.....	27
3.1 影像資料蒐集與處理.....	28
3.2 異常行為辨識.....	29
3.2.1 卷積神經網路.....	29
3.2.2 卷積神經網路模型.....	38
3.3 資料視覺化.....	45
第四章 實證分析.....	47
4.1 實證分析流程.....	47
4.2 影像資料集、資料預處理.....	49
4.3 卷積神經網路.....	51
4.3.1 輸入層.....	51
4.3.2 卷積層.....	51
4.3.3 激活函數.....	52
4.3.4 池化層.....	53
4.3.5 影像特徵攤平與全聯接層.....	53
4.3.6 丟棄層.....	54
4.4 分類預測.....	56
4.5 管理意涵.....	59
第五章 結論與建議.....	65
5.1 結論.....	65
5.2 建議.....	66
參考文獻.....	67

圖目錄

圖 1.3 研究流程圖.....	6
圖 2.1 駕駛異常行為分類架構圖.....	10
圖 2.2 RGB 圖片結構.....	18
圖 2.3 影像二值化.....	19
圖 2.4 神經元結構.....	22
圖 2.5 人工神經網路架構.....	22
圖 3.1 實證架構流程.....	27
圖 3.2 影像轉換與判斷.....	29
圖 3.3 卷積神經網路比對影像.....	30
圖 3.4 影像特徵的組成.....	30
圖 3.5 卷積運算.....	31
圖 3.6 不同影像的卷積結果.....	31
圖 3.7 池化.....	32
圖 3.8 池化後保留的特徵.....	33
圖 3.9 線性整流激活函數機制說明.....	33
圖 3.10 使用線性整流激活函收斂計算結果.....	34
圖 3.11 卷積、池化、激活步驟獲得特徵影像.....	34
圖 3.12 卷積神經網路計算人臉影像的特徵結果.....	35
圖 3.13 倒傳遞層中針對權重與誤差的選擇.....	36
圖 3.14 卷積神經網路整體流程.....	37
圖 3.15 影像攤平與神經網路學習判斷影像.....	37
圖 3.16 CNN 基本運算架構.....	38
圖 3.17 常用激活函數及其函數圖像.....	41

圖 3.18 傳遞神經網路架構.....	42
圖 3.19 卷積神經網路運作流程.....	44
圖 3.20 Power BI 儀錶板示意畫面	46
圖 4.1 實證分析流程圖.....	48
圖 4.2 影像訓練資料(部分).....	50
圖 4.3 CNN 運算流程	51
圖 4.4 卷積運算示意圖.....	52
圖 4.5 ReLU 線性整流函數.....	52
圖 4.6 最大池化操作.....	53
圖 4.7 池化影像的攤平.....	54
圖 4.8 Dropout 機制示意圖	54
圖 4.9 影像預處理流程語法設計(部分).....	56
圖 4.10 CNN 執行過程(部分)	57
圖 4.11 CNN 模式訓練測試震盪圖(60 次)	57
圖 4.12 預測分類結果(部分).....	58
圖 4.13 客運司機正常、異常駕駛行為與管理儀表板圖.....	59
圖 4.14 到站駕駛員不合格動作統計總表.....	60
圖 4.15 單一到站駕駛員不合格動作統計.....	60
圖 4.16 到站駕駛員與累計行車時間儀表板.....	61
圖 4.17 單一到站駕駛員與累計行車時間儀表板.....	61
圖 4.18 到站駕駛員各別異常行為分析統計.....	62
圖 4.19 以累計行車時間分析主要異常駕駛行為.....	63
圖 4.20 從出發時間分析累計異常駕駛行為.....	63

表目錄

表 2-1 物體追蹤方法	17
表 4-1 影像訓練資料集	49



第一章 緒論

1.1 研究背景與動機

民國 67 年 10 月國道一號中山高速高路全線通車，主線北起基隆南至高雄，縱貫串聯起西部各主要都市城鎮，肩負台灣陸路交通南北往來的疏運重任。爾後國道交通量也隨著路網規模持續地擴張成長，時至今日，公路客運成為我國最主要的城際運輸服務之一。因多使用大客車載客，故發生交通意外事故時，常導致大量人員傷亡。根據統計資料顯示，人為因素是造成道路交通傷亡事故的最主要肇事原因，逾 9 成 8 的事故肇因為駕駛人過失。

公路客運為重要的日常運輸系統，影響公眾安全甚鉅，因此客運司機之駕駛行為管理將對提升整體行車安全至關重要。在早期的研究中，多透過行車速度、油量、組件消耗的程度觀察駕駛行為的優劣，然而隨著科技日新月異，資訊、通訊技術發展成熟，促使國內愈來愈重視智慧運輸系統(Intelligent Transportation System, ITS)之應用以及相關政策的推廣。目前客運業者多採用數位行車紀錄器，即是希望能在車輛行駛過程中詳細的紀錄駕駛行為，以便持續改善駕駛行為，達到增進安全之目的。

人工智慧(Artificial Intelligence, AI)的緣起可追溯至 1956 年由約翰·麥卡錫(John McCarthy)所召開的達特茅斯會議(Dartmouth workshop)，是一種透過機器執行設計過的程式，使其履行如：識別、認知、分類與決策等宛若人類智能行為的一種技術。機器學習(Machine Learning, ML)是人工智慧技術的分支之一，透過給予機器大量的資料並藉由演算法進行學習、訓練，使其從資料中學習得出規律，達到進行預測或分析的方法，可分為「學習/訓練」及「推論/預測」兩個階段。

近代科技發展迅速，硬體設備與軟體效能大幅提升；無線網路技術成熟，使數據得以在雲端儲存、計算，促使機器學習相關應用於近年產生爆炸性的發展，其中以圖像、影像辨識在近年尤為重要。深度學習(Deep Learning, DL)是實現機器學習的一種演算法，採用模擬人類大腦功能的人工神經網路(Artificial Neural

Network, ANN)做為演算基礎，自動地萃取出圖片、聲音、文本等資料所表述意義特徵並加以分類，經由逐層之學習、反覆判別處理，期許最終能得出與人類類似的反饋，其學習深度取決於類神經網路(Neural Network)的構造。在圖像、影像辨識的應用上，除較傳統機器學習方法有更好的表現能力外，亦體現在其預測與運算速度結果上。

綜合上述，本研究擬藉由駕駛數位影像資訊，結合深度學習演算法建立司機駕駛行為模型，運用深度學習辨識司機之異常駕駛行為，如：打瞌睡、使用手持裝置、與乘客爭執...等並加以歸納，再根據歸類結果提出駕駛行為預警之依據，供決策者參考、了解問題之所在，以提出改善、檢討策略進而提升運輸服務之安全。



1.2 研究目的與限制

1.2.1 研究目的

基於前述之研究背景與動機，本研究將以我國公路客運駕駛數位影像為輸入資料，藉由深度學習辨識影像，針對駕駛行為進行分析，並歸納異常行為分類模型，以便決策者在決策時之分析參考輔助。

一、利用公路客運業者提供之駕駛數位影像資料，建立駕駛數位圖像資料庫。

本研究運用客運業者提供之駕駛數位影像資料，採人工方式將數位影像資料擷取為圖像資訊，建立駕駛數位圖像資料庫。

二、人工處理駕駛數位影像，將其轉換為訓練圖像資料，並根據司機行為制定標籤，以此建立駕駛行為訓練資料集。

本研究將以人工檢視駕駛數位影像資料庫，根據數位影像內容針對駕駛行為進行分類，並給予圖像標籤，供深度學習算法辨識分析之依據。

三、利用深度學習演算法分類駕駛行為，透過實測分類建構駕駛異常行為預警模型。

本研究將利用深度學習演算法，利用圖像辨識技術將駕駛行為進行分類，分析與了解駕駛異常行為之主要類型，並以此構建異常行為預警模式，提升行車安全。

四、串接資料庫、深度學習圖像辨識分析模型、資料視覺化介面之整體流程，構建視覺化畫面呈現駕駛異常行為統計資訊。

經由程式串接駕駛數位影像資料庫、分析引擎，將結果存回資料庫後，與資料視覺化介面進行介接，使決策者得於視覺化畫面了解駕駛異常行為之相關資訊。

1.2.2 研究限制

基於前述之研究目的，本研究將選定某一客運業者進行資料蒐集，並結合與現場端執行人員、決策管理層人員討論，擬定後續影像分析之方向，惟因選定之客運業者尚未建立完整之影像分析硬體資源與演算環境，且依據影像分析成果而設立之獎懲機制，仍需經內部管理階層討論、決議，始能定案，因此本研究具有以下限制：

一、 採用該客運業者後台之司機行車間影像資料進行分析，然受限於目前業者尚未具備完善之硬體資源環境，故採用後台下載錄影再另外進行深度學習模型訓練與辨識。

二、 影像辨識成果仍產生細微誤差，目前較不適合直接使用於獎懲機制判斷之依據，僅供輔助參考之用。



1.3 研究範圍與流程

本研究流程架構分別為確認研究動機與目的、現況分析與文獻回顧、確立研究架構與方法、實證分析及提出結論建議。各階段步驟說明如下：

一、 確認研究目的與範圍

本研究首先針對客運業者提供之駕駛數位影像進行蒐集，並以人工處理駕駛數位影像資料，歸納駕駛異常行為分類標籤；根據文獻回顧結果，研究範圍將駕駛異常行為初步分為「使用行動裝置通話」、「使用手持行動裝置」、「疲勞駕駛」、「聊天」、「分神」...等。

二、 現況分析與文獻回顧

針對研究課題進行現況及相關文獻之蒐集與整理，釐清問題之所在，藉此奠定本研究的觀念性架構基礎。文獻回顧內容包含三大部分：(1) 駕駛異常行為；(2) 影像偵測技術；(3) 深度學習；最後彙整出研究文獻小結與評析。

三、 研究方法

應用卷積神經網路 (Convolutional Neural Networks, CNN) 進行駕駛異常行為分類，根據現況分析與文獻回顧界定研究範圍，建立本研究之實證分析架構圖，並參考相關學者提出之原理、經驗法則、研究結果。

四、 實證分析

本研究藉客運業者提供之駕駛行車影像資料，以人工處理為圖像資料並註記標籤，建立資料庫存放，後運用卷積神經網路模型辨識駕駛於行車間之偏差行為，以視覺化方式呈現統計資料，探討駕駛常見偏差之行為、發生路段、時間、路線班次等資訊，以輔助決策者改善行車安全。

五、 結論與建議

依據實證分析結果，彙整提出本研究之結論與後續建議。本研究之研究流程如圖 1.3 所示：




圖 1.3 研究流程圖

第二章 文獻回顧

2.1 駕駛異常行為

依據陳信丞(2014)的研究整理，營業大客車通常被納入車隊管理，並操作駕駛訓練措施，但其事故發生率仍為小客車之 6~7 倍，且其載客數量大，當發生交通事故時，造成之危險與傷亡程度亦較其他車種高。

根據世界衛生組織(WHO)的統計，全球每年約有 135 萬人因道路交通事故而喪命；內政部警政署所發布之道路交通事故肇事原因分類及傷亡人數統計資料中則顯示：在台灣每年約有 2,000 人於遭逢交通事故後的 24 小時內死亡。綜觀過去的相關研究得知，道路交通事故的肇因一般可歸類為以下三種因素以及各要因間之交互影響關係：人為因素(Human Factors)、車輛因素(Vehicle Factors)、道路環境因素(Road Environment Factors)，其中人為因素是造成道路交通傷亡事故的最主要肇事原因。自民國 92 年起，A1 類與 A2 類道路交通事故之肇因年年逾 9 成 8 為駕駛人過失，如：車輛操作不當、使用行動電話、身心健康問題...等；以車種別肇事率而言，大貨車、小貨車、大客車及營業小客車較高，顯示職業駕駛基於工時較長、長時間固定坐姿等工作特性，可能導致駕駛疲勞進而影響其駕駛行為，交通事故隨之容易發生。

駕駛在行車過程中就如同一部資訊處理器，對駕車過程中所遇上的各種情況予以相對應的處理(Shinar, 1978)，然而駕駛的資訊處理、感知決策能力會受長途且單調的駕駛環境影響而下降，易出現分心、注意力不集中的情形，使得碰撞等意外風險上升(Anderson 和 Horne, 2006)。此外，影響駕駛行為之因素甚多，其中最主要的兩個因素為駕駛技能(Driving Skill)與駕駛風格(Driving Style)(Elander 等人, 1993)。前者是駕駛駕馭車輛與即時地對周圍環境做出安全、適切判斷的反應能力(Sundström, 2011)；後者則是駕駛習慣的開車方式，受人格特質及個人觀念影響而改變(Taubman-Ben-

Ari 等人, 2004)。

陳少昶(1997)提出交通事故發生一定有一方或多方因故意或過失，而未能遵守相關交通法規之規定，以致產生交通事故，認為違規行為與交通事故發生有因果關係；張宏銘(2003)研究探討違規項目與交通事故主要肇因及事故類型之間的關聯性，發現駕駛人若經常性違反某違規項目者，其後一旦發生交通事故，其肇事原因相似其違規項目的機率相當高，顯示駕駛違規行為與交通事故主要肇因之間存在著關聯性。

Goldenbeld 等人(2013)表示在一項利用荷蘭 2005 至 2009 年交通違規紀錄與 2009 年 1,152,218 件交通事故資料的研究中，分析後發現駕駛每年犯 2 次以上違規行為相比每年只有 1 次違規行為者涉及更多的道路交通事故，可知交通違規行為的增加會提高交通事故發生的風險。

Abegaz 等人(2014)指出交通事故會造成傷亡的原因是由於駕駛人行為、車輛特性、道路幾何設計及環境狀態等各項因素交互作用下所導致的，該研究利用邏輯迴歸，分析出各因素對造成交通事故傷亡的影響程度，結果顯示有超速行駛、酒後駕車或疲勞駕駛傾向之駕駛人，是發生致命傷害交通事故的重要因素。

Penmetsa 和 Pulugurtha(2017)指出駕駛人多半存有僥倖心態，認為自己的違規行為不會導致交通事故的發生，然而經由其研究發現約有 51% 的事故是由於違反交通規則行為所引發，其中嚴重受傷事故中約有 74% 都與交通違規行為有關。該研究又以駕駛年齡進行敘述性統計分析發現，有超過 70 % 的小於 18 歲及大於 80 歲的駕駛所造成的交通事故均是源於違反交通規則，相較之下 19 至 79 歲的中壯年駕駛僅佔 50 % 的比例，可見當青少年及高齡者違反交通規則時，將更容易引發交通事故的發生。由此可知，駕駛違規行為是引發傷亡交通事故的重要因素，且青少年及高齡者之交通違規行為相對於中壯年者，對交通事故的發生有較高的風險。

公路客運為重要的民生運輸服務，職業駕駛在行駛期間之不當駕駛行為對於自身與其他用路人皆具有相當風險，故對於其駕駛行為進行分析與歸納更為重要。根據本研究訪談葛瑪蘭客運內部人員得知，目前客運業者在司機訓練上雖有完整的教育訓練，但司機的行車狀況卻仍須由場站人員監控，且駕駛行為量化困難，使其難以作為績效指標進行管理。本研究以此為基礎，透過文獻回顧蒐集司機常見異常行為類型及影響因素，未來將結合葛瑪蘭客運內部人員訪談與異常行為類型建立初步標籤，採人工處理影像資料時，再根據情況調整、增加標籤類型，以便後續研究使用。

駕駛行為(Driving Behavior)是交通安全領域中被廣為討論的重要議題之一，Reason 等人(1990)定義駕駛異常行為是道路上的不良(bad)與糊塗(silly)行為，並按其危險程度之輕重依序分為以下三類：

疏失(Lapses)：使駕駛自身陷入窘境但不會對其他用路人之安全構成威脅，成因是駕駛粗心做出錯誤動作或散漫不夠專注。

錯誤(Errors)：可能會對其他用路人之安全構成威脅，因駕駛的錯誤判斷或觀察不周等造成實際的駕車表現與其所預期之控制結果間有所落差。

違規(Violations)：必定會對其他用路人之安全構成威脅，是駕駛蓄意違反行車規範或因無知而做出違法行為所致。

爾後國內外學者們以 Reason 等人發表的研究為基礎，針對異常駕駛行為提出各自的見解並加以分類，不論造成異常行為的原因來自駕駛文化差異或是駕駛情緒因素，主要還是分為疏失、錯誤、違規三類(Rimmö 和 Åberg, 1999； Westerman 和 Haigney, 2000；Xie 和 Parker, 2002；Sullman 等人, 2002；Lajunen 等人, 2003；尹維龍, 2005；黃仲平, 2010)，分類架構如圖 2.1。




圖 2.1 駕駛異常行為分類架構圖

Reason 等人(1990)與 Parker 等人(1992)以英國駕駛為對象進行的研究結果均顯示：交通事故發生的機率與違規行為有顯著關聯，但與疏失及失誤間沒有顯著相關；然而 Chang 和 Yeh(2007)探討國人之駕駛危險行為與交通事故關聯的研究成果則指出：上述三類異常駕駛行為皆會使得交通事故的發生率明顯增長。

為將可能造成交通傷亡事故的人為因素進行系統性分類，Reason 等人(1990)發展出一套駕駛行為問卷(Driver Behavior Questionnaire, DBQ)以探討駕駛發生異常駕駛行為的頻率，其研究結果顯示：相較於女性駕駛，男性較常發生違規駕駛行為，反之女性則較常發生疏失或錯誤駕駛行為。另一方面，失誤、違規行為的發生頻率會分別隨駕駛經驗的累積及年齡之增加而減少。

其後 Westerman 和 Haigney(2000)為瞭解駕駛人在不同壓力下會產生哪些異常駕駛行為，以 Reason 等人提出的駕駛行為問卷(DBQ)為基礎，加入 Gulian 等人 (1989)之駕駛壓力情緒研究開發駕駛行為量表(Driving Behaviour Inventory, DBI)進行研究，透過 DBQ 與 DBI 的交叉分析證實：當駕駛人壓力大時會出現較多的疏忽、錯誤及違規行為，負面駕駛情緒會導致異常駕駛行為的發生頻率。而 Britt (2006)亦透過 DBQ 與 DBI 對希臘民眾進行研究，同樣得到駕駛人處於高壓狀態下會因缺乏耐心引發失誤及違規行為，進而導致交通事故的結論。

Rimmö 和 Åberg(1999)認為事故的發生與駕駛一連串的執行行為結果有所關連，故由心理學的角度出發，將 Zuckerman(1994)所提出的人格特質測量工具—感官刺激尋求量表(Sensation Seeking Scale, SSS)導入駕駛行為問卷(DBQ)中進行研究，發現感官刺激尋求和異常駕駛行為有顯著相關，具有感官刺激尋求特質的駕駛有追求快感、低估風險的傾向，較容易做出異常駕駛行為，特別是失誤與違規兩種行為常與交通事故有直接的關聯。

Beanland 等人(2014)將駕駛行為問卷(DBQ)與美國精神疾病診斷準則手冊 (The Diagnostic and Statistical Manual of Mental Disorders, DSM)結合，藉由人格特質來預測美國大學生可能發生的駕駛異常行為類型，研究發現駕駛行為和敵意(Hostility)性格有明顯之關聯，具有五大人格類別中的對抗(Antagonism)、失控(Disinhibition)或是負向情感(Negative affectivity)特質的人最容易發生違規行為。

Spolander(1983)將駕駛技巧分成能流暢地駕馭車輛達安全駕駛目標的技術性駕駛操作技能(Technical Driving Skills)與面臨緊急事故風險時做出相應處置以防範未然的防衛性駕駛能力(Defensive Driving Skills)兩大類型，建構涵蓋了 13 個問項之駕駛技能調查表 (Driver Skill Inventory, DSI) 用以衡量駕駛的駕車技能。

Lajunen 和 Summala(1995)將 Spolander 的駕駛技能調查表(DSI)與 Gulian 等人之駕駛行為量表(DBI)結合加以修改，由 28 個問項以因素分析法探究評斷駕駛經驗和駕車技巧、安全感知間的因果關係，得知男性以及經驗較豐富的駕駛都有較優異、流暢的車輛駕馭表現，而安全感知最高的駕駛族群則是駕駛經驗貧乏的女性。此版本的 DSI 量表在今日最常被用於相關研究上。

Parker 等人(2002)運用 DBQ 針對 50 歲以上駕駛進行駕駛異常行為與事故關聯性之研究，並將事故分為主動事故(Active Accidents, 衝撞其他車輛)及被動事故(Passive Accidents, 被其他車輛衝撞)兩類，結果顯示高齡駕駛的疏忽行為發生次數遠高於其他年齡層之駕駛，被動事故的次數隨其年歲增長而增多，然主動事故之次數卻隨之減少，顯示知覺感受力、注意力等隨著年齡退化的同時也進而對駕駛技能造成影響。

國內研究方面，陳信丞 (2014) 指出，經人因特性分析調查駕駛人駕駛績效降低因素可概括為：飲酒習慣、疲勞程度、睡眠時數、疾病、人格特質、發車間休息時間、凌晨排班等；葉名山等人 (2018) 在其調查研究表示：陳芳正 (2005) 的研究中指出車輛行駛速度、年齡、休息時間與駕駛績效有關；黃仲平 (2010) 在其研究中提到性別、負面情緒、自信、年齡、平均駕駛時間、駕駛技術等與駕駛績效有關。在相關研究中，可見駕駛異常行為影響行車績效之相關因素包含：駕駛經驗、資歷、年齡與生理差異、疲勞程度等。

綜合國內外文獻的回顧，得知影響駕駛行為的因素有性別、年齡、駕駛技巧、駕駛經驗、情緒反應、心理壓力、人格特質...等，而駕駛行為的研究方式多採問卷或量表為主，除了上述的駕駛行為問卷(DBQ)、駕駛行為量表(DBI)、駕駛技能調查表(DSI)外，亦有 French 等人(1993)所發展的駕駛風格問卷(Driving Style Questionnaire, DSQ)、由 Owsley 等人(1999)提出之駕駛習慣問卷(Driving Habits Questionnaire, DHQ)、Deffenbacher 等人(1994, 2001)的駕駛人憤怒量表(Driving Anger Scale, DAS)以及憤怒駕駛傾

向量表(Propensity for Anger Driving Scale, PADS)、Taubman-Ben-Ari 等人 (2004)創的多面向駕駛風格量表(Multidimensional Driving Style Inventory, MDSI)...等。

由於本研究旨在於以影像辨識分析駕駛異常行為進行回報與統計，即借助機器針對駕駛出現不當駕駛行為時進行認知，不當駕駛行為如：頭部偏擺、接聽或播送手機、使用手機、吸菸、分神、講話、打瞌睡等行為 (張銘方，2017；翁銘聰等人，2008)，皆有可能提升駕駛風險，產生用路危害。

本研究將參考前述文獻所提及客運司機之駕駛偏差行為作為後續研究圖像辨識分類之基礎 (標籤)，並納入司機個人因素，如：年齡、性別、資歷、排班間隔、值班時間長短等作為參考因素，在後續研究中將以視覺化畫面呈現駕駛異常行為辨識次數與個人因素，以便決策者了解駕駛異常行為與個人因素之關係，從而進行調整、決策。



2.2 影像辨識

處理數位影像需要極大之演算能力及儲存空間，因此其發展深受電腦演進之影響，首次有意義之電腦數位影像處理於 1960 年實現，之後隨著電腦發展、積體電路使用，影像處理技術始廣泛應用於各個領域。

2.2.1 影像處理

近年由於資訊科技發展，影像處理(Image Processing)技術相較早年有顯著的提升，除因硬體設備的計算速度與影像處理技術發展漸趨成熟外，用於辨識影像的理論、演算法也相繼被提出，促使影像處理技術急遽進步。影像處理在定義上為「透過設備擷取二維影像資訊，再由數位電腦對影像進行處理、分析、轉換、解譯，以改進影像的品質並將原本存在圖像中的重要訊息強化，再從中萃取出有用資訊，成為可應用的資料以利後續研究分析。」，結合多種技術如：人工智慧、深度學習，具有快速、準確與高效率之特性。在各種領域之中，經常擔任辨識(Recognition)與分類(Classification)之責，已開發的應用如：車牌辨識(數字分類)、人臉辨識(臉部特徵分類)、行為辨識(動作分類)等，使得影像處理成為各範疇的重要研究技術。影像處理與深度學習網路技術結合於交通領域的智慧應用除了車牌辨識外，尚有路口溢流、交通標誌偵測、車輛速度預警、違規停車判斷、國道安全監控等。

影像處理涵蓋的範圍十分廣泛，整體來說主要的原理與方法包含影像的數位化(A/D Image Transform)、影像的增強與復原(Image Enhancement and Restoration)、影像編碼與壓縮(Image Encoding and Compression)、影像切割(Image Segmentation)、影像的表示與描述(Image Representation and Description)、影像特徵匹配(Image Feature Matching)等等。Gonzalez 和 Woods(2018)將數位影像處理分為低、中、高三個階級。低階為減少雜訊、增加對比；中階處理包含切割與描述影像中物體的性質與特徵；高階處理則涉及認知與識別影像物件。

以傳統的相機與軟片所攝得的影像稱為「類比影像」。這種影像是以連續調的方式形成，連續調的變化好比音響的調音量裝置，音量大小的控制是透過轉動旋鈕，以平滑無段的方式調節；而類比影像就是以一種由亮到暗，漸層變化的連續光點所組成。所謂數位化影像處理（Digital image processing，簡稱 DIP），即是使用電腦來處理二維（2D）影像，但是類比影像在作處理前，必須先將資料「數位化」，也就是需要先把影像資料轉換成電腦能看得懂的「0」與「1」，其作法是先將影像的全部位置「取樣」，再分析並記錄其每一點約「亮度」、「顏色」與「位置」等。在影像中取樣的每一點稱為「像素」（Pixel），構成影像的像素，就像把圖像分割成許多小方格後的單位方格一樣，每個像素都有特定的位置、顏色、亮度等資料，將此資料換成數據，以陣列（Array）方式存入電腦中以便處理。這就是 DIP 的原理。

2.2.2 圖像分析

近年來人工智慧在影像辨識取得巨大的突破，以往需要專家人工選取特徵再進行影像辨識，在深度學習技術與硬體運算資源協助下，已可透過大量資料進行自動化特徵學習，大幅降低開發影像辨識應用的門檻許多影像辨識應用需要大量人力進行。透過電腦視覺、機器學習與深度學習技術，學習專業人員的視覺辨識能力，自動判讀影像中的關鍵資訊，各產業可透過智慧影像系統輔助，提升影像辨識準確度、降低人工判讀時間，並延伸與其他系統整合發展創新的服務影像處理，提升工作流程準確度與處理量。

在日常生活中的應用層面五花八門，如：衛星影像判讀、電影特效製作、醫療影像分析、虛擬實境、指紋比對、臉部辨識、手寫字體辨識、動態物體追蹤...等，因圖像屬於二維資訊，一個影像可以定義成一個二為的數學連續函數 $f(x,y)$ ，其中 x 與 y 為平面座標，函數 f 在任一組座標 (x,y) 處的振幅(amplitude)稱影像在該點的強度。故需要借助電腦做數位轉換，計算處理方法也相對複雜，常見的處理方式包含強化資訊顯著性、提升對比、

灰階化、雜訊去除、影像分割、二值化、特徵讀取...等，之後再透過機器進行判斷其分類。李佩珊 (2012)，在其研究中以辨識手掌為其研究主旨，透過手指到指骨間所形成的面積做為影像特徵，將其轉換為二值影像並構建圖像資料庫，進而達到辨識手掌差異之目的；陳奕瑄 (2018) 在其研究中透過將實驗用的植物圖片以 RGB 模型處理後，再進行灰階、二值化處理，使像素值得介於[0,1]間，後再透過背景補色、增加訓練資料等方式提升分類準確度。

2.2.3 移動物體偵測技術

目前最常見的影像偵測技術為針對移動物體進行偵測，一般多用於監控系統，當畫面產生變化時，可減少影像紀錄對硬體空間的無謂使用。林宥豪、蔡玉娟 (2018)的研究中指出其主流方法包含：光流法 (Optical Flow)、影像相減 (Temporal Differencing)、背景相減 (Background Subtraction)...等。

光流法是指影像中的物體移動產生的光影變化的分布情形；影像相減是指將影像擷取為圖片，將圖片進行相減後若為 0，表示物體靜止，反之則表示物體移動，並利用產生值的區域作為物體移動的辨識區域；背景相減在原理上與影像相減類似，做法是選擇未移動物體的圖片作為背景，有移動物體的圖片作為前景，兩者進行相減後的值為 0 時表示物體未移動 (或是物體未進入該畫面)，反之則表示有。移動物體偵測技術是透過將物體現在位置與過去位置進行比對，可用來追蹤連續畫面的物件、應用於追蹤人臉或是肢體動作變化。根據姚文翰等人 (2005) 在其研究中之整理如下：

表 2.1 物體追蹤方法

區域式追蹤	Region-Based Tracking	根據目標移動的區域變化，與原本的區域比對來追蹤目標，並將影像位置發生變動的區域視為物體產生移動。
主動式輪廓追蹤	Active Contour-Based Tracking	將物體繪製邊界輪廓來表示，追蹤邊界輪廓在連續影像中的變化。
特徵追蹤	Feature-Based Tracking	以物體特徵為基礎進行特徵變化追蹤的方法，透過萃取物體特徵，比對連續影像間，特徵的差異來達到目的。
模型追蹤	Model-Based Tracking	利用已知的連續影像中的物體特徵建立模型，並利用模型預測未來影像的變化，後透過比對影像的差異達到追蹤目的。

2.2.4 色彩空間

人眼能檢測到波長介於 400nm 至 700nm 間的可見光，所看到的色彩是由不同比例的紅(Red)、綠(Green)、藍(Blue)三種色光混合而出的結果。1931 年國際照明委員組織(CIE)指定下列三種光譜波長為三原色：紅色=700nm，綠色=546.1nm，藍色=435.8nm。在影像處理技術中，色彩空間是將影像以值表示顏色組成的數學模型，在該領域中最為知名的模型分別為 RGB 三原色光模型、HSV 色彩空間模型以及 YCbCr 模型等三種，其分別是以(1)將像素顏色分為紅色、綠色以及藍色的三原色光模型 RGB (Red、Green、Blue, RGB)、(2)將影像以色相、飽和度、明亮程度表示色彩空間模型 HSV (Hue、Saturation、Value, HSV)、(3)以亮度、紅色與藍色偏移量表是的 YCbCr 模型 (Y：亮度、Cb：藍色濃度偏移量、Cr：紅色濃度偏移量)等三種。因機器學習為主的影像辨識技術多將影像以向量表示以便後續處理時使用，因此在表示像素顏色組成時以紅、綠、藍為主，並以 0~255 整數值的 RGB 三原色模型再轉換上更為直觀，故該模型亦為最常被使用於影像辨識前處理時的模型，RGB 三原色模型表示圖片的方式可見如圖 2.2 所示。




圖 2.2RGB 圖片結構

2.2.5 灰階與影像二值化

彩色影像包含了許多資訊，若是採用彩色影像處理，則需分別對紅、綠、藍三色做分析，對於需應用於講求速度之演算法將造成不小負擔，為了降低影像的資訊量與複雜度，多將影像目標與背景分開，並加以轉化以利機器進行演算處理。灰階 (Grey Level) 是計算機領域中，表示影像顏色的一種方法，有 256 種深淺組合。為了提高人像動作特徵的識別度，在影像辨識前須將彩色的影像進行灰階化處理，將像素以 RGB 模型轉換成數值後，根據 0~255 表示，轉換公式表示如下：

$$\text{Gray} = R*0.299 + G*0.587 + B*0.114$$

影像二值化是指將影像透過如 RGB 模型進行轉換後，設定門檻值 (Threshold) 將影像轉換為黑白影像。若像素大於門檻值設為背景 (255)，反之則設為前景 (0)，轉換結果如圖 2.3 所示。




圖 2.3 影像二值化

2.3 深度學習

深度學習為機器學習領域下的一種技術，在目前的研究與應用中，多以準備訓練資料使機器認識規則，再將測試資料交付機器，讓機器根據規則進行分類、預測。無論是在影像或是文本的分析與應用上，機器學習皆以將辨識與分析的物件轉換為數值 (特徵化)，如機器學習技術應用在影像辨識時，多會先經過色彩空間、灰階或是二值化的處理，其主因即在於取得圖片的辨識函數，使機器得以認識資料的組成。本研究以深度學習演算法為主要的機器學習方法，此章節將整理深度學習的相關文獻。

2.3.1 人工神經網路

類神經網路為今日非常重要且被廣泛應用的一門技術，屬於人工智慧的一個分支，根植於神經科學、數學、思維科學、人工智慧、統計學、物理學、電腦科學以及工程科學，由儲存在網路內部的大量神經元通過節點連線權組成的一種資訊響應網狀拓撲結構，它採用了並行分散式的訊號處理機制，因而具有較快的處理速度和較強的容錯能力。神經網路模型旨在模仿人腦結構及其功能的資訊處理系統，可由神經網路從外界環境獲取的知識加以學習得來知識或透過內部神經元的連線強度(即突觸權值)儲存獲取知識等兩方面來模擬大腦。

類神經網路用於模擬人腦神經元的活動，包括對資訊的加工、處理、儲存、和搜尋...等，具有強大的學習和適應能力、自組織、非線性和運算高度並行的能力，解決了傳統人工智慧對於直覺處理方面的缺陷，例如對非結構化資訊、語音模式識別等的處理，使之成功應用於神經專家系統、組合優化、智慧控制、預測、模式識別等領域。

其原理是利用數學模型模擬人類腦神經系統思考機制、判斷方式與組成構造，透過各階層 (隱藏層) 所包含的眾多人工神經元 (Artificial neuron) 與下層的神經元連接，並將上層的神經元輸入、加總、權重計算與透過活化函數 (Activation function) 轉換並輸出結果，使其得用於語音辨識、文本

分類、影像辨識等問題；葉怡成 (2003) 於其研究中指出類神經網路是由軟體與硬體組成的計算系統，其使用大量函數作為人工神經元以模仿人類神經網路的結構，其可透過外界環境或神經網路中其它人工神經元取得資訊並運算，並透過層層運算後將結果輸出，其函數可表示如下：

$$\alpha = \sigma\left(\sum_k a_k w_k + b\right)$$

在人體中，神經系統掌管人類所有行為動作，監督、調整、管理人體的各個部分，依照功能而言，神經系統主要有下列三項功能：

受器接收訊號(Sensory Input)：身體的感受器將自外界接收感受到的刺激與資訊傳入神經系統中。

整合(Integration)：將傳入的訊號進行分析處理，並進而判斷對此外界刺激應做出哪種適宜之反應動作或防禦措施。

動器產生動作(Motor Output)：即神經系統的輸出，將整合階段中的判斷結果傳給動器，讓身體對於外界刺激做出適當的回應。

上述三項功能分別可對應至類神經網路架構中的輸入層、隱藏層、輸出層(蘇昭安，2003)：

輸入層(Input Layer)：由多個節點(神經元)組成，在網路架構中負責接收資料並輸入訊息，輸入變數視輸入內容而定。

隱藏層(Hidden Layer)：介於輸入層與輸出層之間，負責類神經網路處理問題時各單元彼此間之交流，通常以多次試驗的方式決定所使用的線性轉換函數的最佳數目。隱藏層層數之多寡並無一名定之標準，一般而言擁有較多隱藏層的類神經網路可以處理複雜程度較高的問題，然而隱藏層過多也隱含網路在學習過層中難以收斂之隱憂。

輸出層(Output Layer)：在網路架構中負責輸出訊息，通常僅有一層，輸出變數視輸出內容而定。

Neuron

$$z = a_1 w_1 + \cdots + a_k w_k + \cdots + a_K w_K + b$$




圖 2.4 神經元結構




圖 2.5 人工神經網路架構

2.3.2 深度學習

深度學習一言以蔽之即是透過深層的運算網路使機器求解能力上升，其概念最早可追溯至 1960 年代科學家希望以電腦模擬人類思考方式，建構可獲得學習與判斷能力的數學模型，但受限於當時理論尚未成熟，使類神經網路的概念仍難跳出線性問題求解，並且受限於當時硬體算力不足，使本質上是函數集合的類神經網路演算法難以運用於非線性問題的求解，以至於後續以神經網路相關的研究進入寒冬，並將方向朝以二元方式結合向量超平面空間作為求解方式的機器學習領域前進。

但在其中也有持續多年並未放棄類神經網路研究之知名學者，2006 年多倫多大學的 Hinton 等人在經過多年鑽研，提出由電腦將樣本數據通過多層次之深度網路結構進行學習，以輸出結果之深度學習概念。由於早期類神經網路設計為針對隱藏層的權重採隨機初始化的方式，期望以此方式得到公正的學習過程，但也因此使整個網路在求解時易在局部最小值停止運算並輸出結果(收斂)，使局部最小值求解避免的問題在早期的類神經網路研究中始終是一大難題；Hinton 根據此問題為基礎，提出以無監督的預測式訓練方法，透過聚類方式優化網路權重再進行微調，大幅度提升深度學習技術的發展。此理論亦影響目前多種深度學習演算法，在實際應用中，若以影像數據為例，人類的大腦對於眼睛接收到的影像資訊處理順序為：物體的邊緣檢測及其初步的外型，並根據認知形成複雜形狀。

類神經網路的主要工作是建立模型和確定權值，是一個具有學習能力的系統，可以發展知識，甚至能超越設計者原有的知識水平。通常類神經網路的學習和訓練需要一組輸入資料和輸出資料對，選擇網路模型和傳遞、訓練函式後，類神經網路計算得到輸出結果，根據實際輸出和期望輸出之間的誤差進行權值的修正，在網路進行判斷的時候就只有輸入資料而沒有預期的輸出結果。

具體的學習內容隨系統所處環境(即輸入訊息之情況)而異，系統可以自動發現環境特徵和規律性，具有更近似於人腦的功能。類神經網路一個相當重要的能力是其網路能通過它的神經元權值和閾值的不斷調整從環境中進行學習，直到網路的輸出誤差達到預期的結果，即可認定為訓練結束。對於這樣一種多輸入、單輸出的基本單元可進一步從生物化學、電生物學、數學等方面給出描述其功能的模型。利用大量神經元相互連線組成的人工神經網路，將顯示出人腦的若干特徵，人工神經網路也具有初步的自適應與自組織能力。

根據陳翰 (2018) 於其研究中整理，深度學習的類神經網路是透過多個非線性網路疊加，並按照編碼解碼情況可分為三類：編碼器(Encoder)、解碼器(Decoder)或是兩者皆具，前者提供自輸入至特徵空間的向上映射，後者則以盡可能接近原始輸入值為目標，將隱含之特徵值映射至輸入；目前主流的深度學習神經網路模型可以分為以下三種：

1. 前饋式深度網路 (Feed Forward Deep Networks, FFDN)：以編碼器為主的結構，由多個編碼器層疊加而成，最為知名的類型便是現今的卷積神經網路(Convolutional Neural Networks, CNN)。
2. 回饋式深度網路 (Feedback Deep Networks, FBDN)：以解碼器為主的結構，由多個解碼器層疊加而成，如最知名的類型是遞歸神經網路(Recurrent Neural Network, RNN)。
3. 雙向式深度網路 (Bidirectional Deep Networks, BDDN)：包含編碼器、解碼器的類神經網路結構，透過多個層相互構成，如深度玻次曼機(Deep Boltzmann Machines, DBM)、深度信任網路 (Deep Belief Networks, DBN)等。

2.4 公路客運服務評鑑

現行國內公路客運評鑑制度之主管機關為各縣市政府，其委託顧問公司每兩年辦理一次，整體的評鑑指標共分成五大類二十一項指標：1.「場站設施與服務」：包括 A1 停車空間、A2 班車停靠、A3 乘車服務資訊、A4 站牌服務資訊，2.「運輸工具設備與安全」：B1 車齡比例指標、B2 公車資訊服務設施指標、B3 車輛設備及紀錄、B4 舒適與噪音、B5 動態系統，3.「旅客服務品質與駕駛員管理」：C1 準點性、C2 駕駛員出勤管理、C3 乘客滿意度、C4 申訴處理，4.「公司經營與管理」：D1 監督管理、D2 教育訓練人次及成果、D3 路線查核、D4 政策配合、D5 積極作為、D6 調查缺失改善情況、D7 駕駛員健康管理，5.「無障礙設施」：E1 無障礙設施。

本研究認為現行公路客運評鑑制度之安全議題雖有設立評鑑項目，但數量偏少，應就以下面向深入探討：

1. 評鑑項目中屬於安全評估項目者為「B 運輸工具設備與安全」，且大部分評分基準（評分項目）著重於運具車內設備之裝設有無，但根據警政署統計室的資料中顯示，在各類的交通事故中 94%的比例皆為駕駛人過失導致，故在安全評分基準中應增加駕駛安全行為之評估項目。
2. 評鑑項目在「B 運輸工具設備與安全」中並未列出與安全駕駛行為相關的評分項目，且有相關項目皆分散在「C 旅客服務品質與駕駛員管理」、「D 公司經營與管理」之中。另外，在分數佔比方面，屬於安全駕駛行為的評估分數僅佔 22%。
3. 目前公車營運服務指標評鑑過程，並未強制在「運輸工具設備與安全」以及「旅客服務品質與駕駛員管理」兩者要求業者提供內部控管之行車營運管理記錄資料，僅依據每年定期之主動式評鑑結果，且皆委由人工方式隨機抽查駕駛員之行為。

4. 根據公路總局統計 108 年公路客運使用人次為 128,414,214 人次，總行駛次數 7,042,289 次，採用乘客問卷調查僅能搜集少數意見，並無法完整反映駕駛員的駕駛行為，亦無法累積長時間監控駕駛員行為數據的紀錄。若採人工查閱方式在調閱資料時亦往往因設備問題而產生資料不全的情形。雖有若干巨量影像與行車資料但因缺乏智慧分析技術，導致評估結果的不周全而無法反映實際情況。

2.5 文獻評析與小結

本研究經由文獻回顧與客運業者訪談，整理駕駛異常行為標籤，後運用客運業者提供駕駛影像資料，以人工先針對影像資料進行標記，建立訓練資料集；後對標記影像進行預處理、不良行為分類、辨識異常行為次數，並將結果存於資料庫中，再運用視覺化工具，使客運業者得透過視覺化畫面，掌握駕駛異常行為統計資料，最後根據呈現內容制定評估與考核機制，以作為未來決策擬定輔助之依據。

第三章 研究方法

本研究考慮受訪之客運業者尚未具備完善之駕駛人行車間影像上傳、下載與即時分析之硬體資源與運算環境，故本研究以後台下載並取得客運業者提供之駕駛影像資料為分析對象，並結合第一線場站人員訪談歸納之駕駛異常行為類型歸納資料，作為影像辨識基礎之標籤，透過程式以建構駕駛異常行為辨識之視覺化管理系統，再由視覺化畫面呈現駕駛異常行為累積次數與其他相關統計資料，以供客運業者做為決策輔助使用。其流程可概括為：資料蒐集、影像預處理、人工檢視並給予資料標籤、建立訓練資料與測試資料、建構模型、資料分析、資料視覺化等步驟，考慮最後資料需與視覺化系統對接，因此將建構資料庫儲存訓練、測試與分析結果，視覺化之呈現主要目的在於歷史性資料統計與分析，以週期性或中長期性質的資料回顧作為管理決策輔助資訊提供給客運業者，輔助其決策，系統流程如圖 3.1 所示。




圖 3.1 實證架構流程

3.1 影像資料蒐集與處理

本研究欲藉由客運業者提供之駕駛行車行為影像資料，透過人工將駕駛異常行為影像擷取為圖片後，針對異常行為影像進行歸納，如：講電話、分神、喝飲料、滑手機...等，建構標籤後產生訓練資料集合與資料分析模組處理影像。本研究預計採用 R 語言作為分析引擎開發軟體，R 語言具有相當多元之軟體，關於圖像辨識與處理的常見軟體包含：mxnet、shiny、imager...等。這些軟體可實現 R 語言在深度學習影像辨識之目的，軟體可完成深度學習中所需之資料格式轉換、隱藏層、池化層...等參數設定，並進行分類結果的輸出。

整體的功能為：(1) 資料收集－透過人工給予影像標籤，並建立標籤規則；(2) 資料與處理－根據標籤規則建立訓練資料集之資料庫，並將影像處理為 RGB 色彩模型，後以灰階法將影像標準化；(3) 卷積神經網路駕駛異常行為影像偵測－透過資料集訓練出判斷異常行為之模型；(4) 異常行為識別與統計－透過模型計算資料集中駕駛出現異常行為之次數，並將統計結果紀錄於資料庫中；(5) 視覺化系統－結合客運業者相關之駕駛與路線資料，提供駕駛異常行為與行車狀況統計資訊之視覺化系統，以利決策者定期掌控與改善營運績效。

3.2 異常行為辨識

3.2.1 卷積神經網路

首先說明卷積神經網路 (Convolutional Neural Networks, CNN) 的運作原理，Brandon R. 於其個人研究中所提及，卷積神經網路相較過去機器學習算法，最大的差異在於結合卷積層與神經網路層，分別進行影像特徵的取值以及計算其信任度，以判斷輸入影像所屬的分類，以下引用 Jimmy Lin 於其網站中針對卷積神經網路原理的說明：

1. 影像轉換

再進行影像比對前，首先會對影像的像素組成進行處理，根據使用的色彩模型轉換為量值，如圖 3.2 即是將兩張影像以黑白二值化後進行表示，再影像轉換為量值後，便可透過演算法進行計算，以判斷其相似度信任值。




圖 3.2 影像轉換與判斷

2. 特徵表現與比對

在獲取影像的量值後，卷積神經網路會開始比對兩張圖片裡的各個局部區域，並根據預先設定的參數決定每次比對局部區域的範圍大小、比對的順序移動步數等，這些被參數決定的區域被稱為特徵(Features)，如圖 3.3 所示，根據預先設定的比對範圍，最終卷積神經網路會根據順序掃描完整

圖片，並進行比對。

特徵在呈現上可如圖 3.4 所示，將影像像素轉換為量值後，以黑、白為{-1,1}的方式簡單進行量化，即可獲得矩陣；透過矩陣的計算可比對每個區域間的相似度。




圖 3.3 卷積神經網路比對影像




圖 3.4 影像特徵的組成

3. 卷積計算

卷積神經網路與傳統機器學習演算法最大的差異，可以說就是體現在導入卷積計算的部分，相比傳統機器學習演算法需要大量的前置作業進行特徵的評估與試誤後的調整，卷積神經網路則改善此部分，其在每次分辨影像時會按照設定的參數順序比對影像的各個部分，因此種方式將造成大量的運算資源需求，甚至造成運算停止，故引入一套篩選機制，便是卷積(convolution)，也是卷積神經網路算法名稱的由來。

卷積的基本原理便是計算影像中的特徵與卷積核特徵的相似度，只要將影像與卷積核各個像素的量值計算，便能獲得計算後影像的相似度結果，計算局部區域的相似度越高則越趨近於 1，反之則趨近於-1，如圖 3.5 所示。




圖 3.5 卷積運算




圖 3.6 不同影像的卷積結果

4. 池化

卷積神經網路在完成卷積後，會進一步進行影像的壓縮，以獲得並保留影像中具有特徵的重要資訊，其作法是根據設定的參數決定每次要選取的範圍、池化的原則以及每次池化的移動間格等，如圖 3.7 所示，即是採用 2*2 大小的區域，每次位移 2 步，如此便會在原本的 [0.77, -0.11, -0.11, 1.00] 矩陣中選出最大值的 1.00，並接續移動兩間格，最終會生成如圖 3.8 所示之壓縮後具有重要資訊的特徵影像。




圖 3.7 池化

通常池化的作法有分為最大池化、最小池化以及平均池化三種方式，其分別是根据選取區域中的最大值、最小值以及乘積平均值進行取值，經過池化後的影像，包含的像素數量會下降，但因前述的三種池化機制，實際上會保留每個範圍內最具特徵或最不具特徵的影像，此種作法除降低機器的運算壓力以外，同時也保留了特徵值，在結合卷積的過程，便改善傳統做法中耗費大量時間與人力去定義特徵的情況；即池化後獲得的資訊將更集中在影像中是否存在相符或不相符的特徵，可幫助機器更好的判斷影像中是否包含某個特徵，而不需耗費資源計算特徵在二維平面上的位置。在一般情況下，無論池化或是卷積，通常選取範圍多以 2*2 或 3*3 為主。




圖 3.8 池化後保留的特徵

5. 激活函數

激活函數是在計算過程中用於收斂影像像素特徵的機制，可避免卷積神經網路在計算過程中遭遇無限大或趨近於 0 的情形，亦可減少陷入局部解或是維度災難的情形；圖 3.9 即是使用線性整流單元 (Rectified Linear Unit, ReLU) 進行計算，此激活函數的機制是將所有負數的結果轉換為 0，計算結果如圖 3.10 所示。




圖 3.9 線性整流激活函數機制說明




圖 3.10 使用線性整流激活函收斂計算結果

6. 深度學習

卷積神經網路在名稱上其實可分為卷積、神經網路兩個部分，卷積的部分包含前述的卷積、池化、激活函數等步驟，基本的順序可如圖 3.11 所示。即是說根據卷積步驟的不同，越是高層的特徵包含的特徵越複雜、也越趨近於原始圖像，而越是經過計算的低層特徵，則多以簡單的特徵組成，如圖 3.12 所示。




圖 3.11 卷積、池化、激活步驟獲得特徵影像




圖 3.12 卷積神經網路計算人臉影像的特徵結果

7. 倒傳遞 (backpropagation)

根據前述的步驟，卷積神經網路演算法主要是透過倒傳遞神經網路進行特徵的學習與判斷，在實務上通常需要先針對預計辨識的應用領域影像進行標記，即是由人工先針對與預計辨識項目的相關領域影像，預先進行蒐集、標記或是定義其分類，接著在以一個初始的卷積神經網路進行訓練，並隨機決定其像素取值、特徵、權重、神經網路全連接層等參數值，並開始進行訓練。

經過卷積神經網路的處理，每張影像最終都會透過神經網路的全連接層進行所屬類別的投票，也就是計算其信任度後進行分類。而卷積神經網路則透過其計算的結果與人工標出的分類進行比對，並從這些誤判-也就是誤差中判斷好的特徵與權重。在實務上可以透過調整參數來獲得不同的特徵與權重，降低全連接層學習時產生的誤差，並透過每次的調整重新進行誤差計算，卷積神經網路會保留有成功降低誤差的特徵與權重；在反覆的訓練過程中，個別影像中的誤判會逐漸將低，共通的特徵與權重則會被保留，理論上若有足夠多與辨識需求相似的已標記影像，這些特徵與權重最終會趨近適用於與辨識需求領域相同的穩定狀態，即是模型。




圖 3.13 倒傳遞層中針對權重與誤差的選擇

8. 計算與判斷

在進行到神經網路進行信任度計算的結果前，卷積神經網路會將特徵影像拉成一組向量，此步驟被稱為攤平 (Flatten)，攤平後的向量以一維表示，並由神經網路進行計算，在卷積神經網路中通常採用全連接方式進行計算，同時也會加入相應的 Dropout 機制，以避免學習結果過度擬合，最終會獲得如圖 3.14 所示之結果。從圖中可以發現輸入進去的影像在經過卷積神經網路一連串的步驟與計算後，最終獲得預測機率結果。整體來說，卷積神經網路的流程可以圖 3.15 表示。




圖 3.14 卷積神經網路整體流程




圖 3.15 影像攤平與神經網路學習判斷影像

3.2.2 卷積神經網路模型

卷積神經網路 (Convolutional Neural Networks, CNN) 是目前深度神經網路 (Deep Neural Network, DNN) 領域的發展主力，自 2012 年 ILSVRC 競賽 (ImageNet Large Scale Visual Recognition Competition, ImageNet 大規模視覺識別挑戰賽) 中，由 Hinton 等人提出的具深度神經網路結構並結合 ReLu 激勵函數、Dropout 機制的 AlexNet 在辨識結果上一舉打敗了制霸多年以 SVM 為主的傳統機器學習模型，其採用 GPU 作為運算資源的方法使深層網路所需的大量算力問題得以解決，而 ReLu 激勵函數、Dropout 機制亦改善過去受限於局部求解的問題，使深度學習在世人眼中大放異彩，後續相關研究與應用亦多以此為主進行拓展，至近年知名之物件偵測演算法 Yolo 亦同。

典型的卷積神經網路運算架構如圖 3.16 所示：包含輸入層 (input)、卷積層 (convolution)、池化層 (pooling)、激活函數 (activation function)、全聯接層 (full connected layers)、輸出層 (output)，下面針對網路架構逐步介紹。




圖 3.16 CNN 基本運算架構

1. 輸入層(input)

先由人工對影像進行處理、標記，建構訓練資料集後，由演算法將影像轉換為提取出每個影像的特徵矩陣 T ，將每個影像 T 根據其大小、維度、像素等進行計算、抽取特徵，將所有影像表示為 $w_1, w_2, w_3, \dots, w_d$ ，因此訓練影像特徵矩陣 T 可表示為：

$$T : \{w_1, w_2, w_3, \dots, w_d\}$$

$$w_i : \{m_{i1}, m_{i2}, m_{i3}, \dots, m_{iv}\} \quad i \in \{1, d\}$$

$$w_{i:d} = w_1 + w_2 + w_3 + \dots + w_d$$

獲得矩陣 T 後，由演算法透過卷積層、池化層繼續針對影像的特徵進行提取，以獲取影像特徵矩陣。

2. 卷積層 (convolution)

接續前一步驟，當影像經過處理轉換為矩陣後，CNN 演算法根據設定的卷積層數、卷積核的大小，將影像進行特徵的提取；在此卷積層的工作是透過設定的卷積核大小以及每次移動的步數範圍，將輸入的圖像縮小並提取特徵，以取代過去人工進行特徵選取的工作，並且達到加速運算目的；在將前述矩陣 T 作為輸入後，卷積核以行、列方向進行移動，透過卷積層中的卷積核 $C_1, C_2, C_3, \dots, C_m$ ，能夠更加完全且自動取得影像特徵，並降低提取過程中未能選擇到特徵項目的偶然性，卷積核可表示如下：

$$C = \begin{bmatrix} c_{11} & c_{12} & \dots & c_{1v} \\ c_{21} & c_{22} & \dots & c_{2v} \\ \vdots & \vdots & & \vdots \\ c_{k1} & c_{k2} & \dots & c_{kv} \end{bmatrix}$$

本層將影像矩陣 T 從上至下順序，分別與 C 進行運算，最終可得縮小後並具特徵的影像矩陣 T_p ：

$$T_p = \begin{bmatrix} m_{p1} & m_{p2} & \cdots & m_{pv} \\ m_{p+1,1} & m_{p+1,2} & \cdots & m_{p+1,v} \\ \vdots & \vdots & & \vdots \\ m_{p+k-1,1} & m_{p+k-1,2} & \cdots & m_{p+k-1,v} \end{bmatrix}$$

如上所述，卷積層在 CNN 演算法中是針對影像矩陣 T 自動且標準的取得影像特徵的過程，並於卷積結束後得到進一步的影像特徵矩陣，該特徵矩陣會由演算法通過卷積層比對輸入並進行轉換，最後可獲得具有局部特徵簡化性質的整體特徵內容。

3. 池化層 (pooling)

在獲得進一步的影像特徵矩陣後，演算法將傳遞 m 個 $R^{(d-k+1) \times 1}$ 矩陣至池化層，並將於此層進行特徵的展開以便後續作為神經網路輸入使用，池化層的代表方式如下：

$$\text{pooling} = (S_{(d-k+1) \times 1}) = \alpha(S_1, S_2, S_3, \dots, S_{d-k+1})$$

其中， α 表示不同的池化方式，目前來說主要的池化方式包含：最大持化 (Max pooling) 與最小池化 (Min pooling)、平均池化等；CNN 在算法特性上是具有自動選擇特徵並結合神經網路進行分類的性質，因此參數的設定、調校等通常會根據輸出的結果再進行調整，故難以比較池化方式的好壞。CNN 演算法會在池化層將卷積層輸出的特徵矩陣轉換成向量 P，可表示如下：

$$p = (P_1, P_2, P_3, \dots, P_M)$$

綜上所述，在透過卷積層與池化層對影像矩陣 T 進行卷積、特徵提取、池化後得到特徵向量 P，再將該向量 P 傳遞至類神經網路層，由類神經網路層進行學習、計算其所屬分類的機率，從而判斷其內容。

4. 激活函數 (activation function)

在進行深度學習的過程中，若將其函數計算的方式想像為是「一百個人對同一個題目進行的回答」，則勢必會有不同學習解答出來的情況，這些情況即是運算過程中產生的誤差值，而隨著學習的次數產生的誤差值累積，最後便會造成結果輸出的不良；Hinton 等人在提出深度學習概念的同時，亦同時提出引進激活函數以解決因 CNN 演算法特性造成的梯度爆炸問題，目前主流的函數包含：S 函數 (Sigmoid function)、雙曲正切函數 (tanh function)、線性整流函數 (Rectified Linear Unit, ReLU)等，激活函數的目的是將輸出的值標準化於同一個區間中，使輸出值在被限縮於相同範圍的同時，減少運算所需的資源；在上述的三種函數中，又以 ReLU 因僅保留 0 以上數值的特性，在 CNN 演算法取特徵上更為直觀，因此較其他函數更常被使用，在後續的相關應用也有良好的效果。




圖 3.17 常用激活函數及其函數圖像

5. 全聯接層 (full connected layers)

根據前述內容，當影像矩陣 T 經由卷積、池化層重複運算後，CNN 演算法會得到向量 P ，並將向量 P 利用類神經網路進行分類計算的預估，目前與 CNN 相關演算法也有採用其他的類神經網路，包含：前饋式神經網路、雙向神經網路以及經典的倒傳遞神經網路等，本研究選擇倒傳遞神經網路作為 CNN 演算法最後步驟，倒傳遞神經網路的特性是對降維簡化後的 N 個輸入，在全聯接層計算誤差後更新權重得到最終解，圖 3.18 為傳遞神經網路架構。




圖 3.18 傳遞神經網路架構

倒傳遞神經網路在深度學習中的原理，是利用目標輸出值(Target Output)與實際輸出值(Actual Output)相減後的差值程度調整權重，其誤差值可定義如下：

$$E = \frac{1}{2} \sum_{i=1}^m (t_i - o_i)^2$$

其中， t_i 是目標輸出值、 o_i 是實際輸出值，透過兩者的相減以表示差異程度，而為使誤差最小以提升學習結果，需再加入一個權重調整誤差值，可表示如下：

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}}$$

其中 w_{ij} 是神經元間的權重、 η 是學習率(Leaming Rate)，通常會定義其介於[0,1]，因此接續層的輸出可以下表示：

$$o_i = f(net_i), \quad net_i = \sum_{j=1}^n w_{ji} x_j$$

再對誤差值 E 對 w_{ji} 進行梯度值計算：

$$\begin{aligned} \frac{\partial E}{\partial w_{ji}} &= \frac{\partial E}{\partial net_i} \frac{\partial net_i}{\partial w_{ji}} = \frac{\partial E}{\partial net_i} x_j \\ \frac{\partial E}{\partial net_i} &= \frac{\partial E}{\partial o_i} \frac{\partial o_i}{\partial net_i} = -(t_i - o_i) f'(net_i) \end{aligned}$$

透過上述運算可得：

$$\frac{\partial E}{\partial w_{ij}} = -(t_j - o_j) f'(net_j) x_i$$

最後將原來的加權值加上其改變量 $w_{ij} = w_{ij} + \Delta w_{ij}$ ，即獲得輸出值。根據上述過程，影像矩陣 T 實際上在 CNN 演算法中，先後透過卷積、池化層獲取特徵值，在由類神經網路計算與學習，最後得到分類結果，整體流程可如圖 3.19 所示。




圖 3.19 卷積神經網路運作流程



3.3 資料視覺化

隨著數據應用發展，資料視覺化是近年漸受重視的一個領域，主要用戶以企業客戶為大宗；過去資料視覺化的目的是將整個組織中的重要資訊，以結構化資料的方式經過專門討論後設計而成，並以統計圖表進行呈現，使決策者得透過統計圖表了解企業內、外部的資源變化趨勢，以此輔助決策。

由於近年科技發展迅速，使企業需要關注的結構化資料呈現大幅度的上升，相較早期以單一維度了解資源變化的方式，現今資料視覺化更重視將資料結構化後表示其關聯性的呈現；因應此趨勢，資料視覺化工具也陸續開放用戶可自行進行部署後，再與供應商聯繫選擇部署規模，在此其中也特別為人所知的視覺化工具分別為 Tableau 與 Power BI 兩種，前者出現時間早於 Power BI，但因早期沒有免付費版可供用戶使用外，目前 Tableau 雖有提供 Public 版供一般使用，但功能上相較付費版本差異甚大，並且再資料視覺呈現的多元性上，也不如 Power BI 直觀。

Power BI 是微軟所開發之資料視覺化工具，再一般使用狀況下不需付費，用戶可透過 Power BI Desktop 建構需要的儀表板內容，並設計其與資料庫聯繫方式，若需要將其部署至企業內部使用，則可與經銷代理商聯繫，根據企業規模或使用程度制定付費程度後，即可讓擁有授權帳戶的使用者登入後觀看儀表版內容，大幅度減少環境部署所耗費的資源，並可從管理決策的角度了解企業運作狀況，其他常見的資料視覺化工具/軟體包含：D3.js、Plotly、Microstrategy、Fine Report 等，本研究考慮軟體的取得性與資料介接的容易程度，採用 Power BI 製作視覺化系統，Power BI 相較其他視覺化軟體，在使用與發佈上更為靈活方便，如圖 3.20 所示。




圖 3.20 Power BI 儀錶板示意畫面



第四章 實證分析

在現場環境硬體與運算資源之條件下，本研究之實證分析，決定採用葛瑪蘭客運公司之駕駛行車影像資料，由人工選取一定時間影像資料後，以 R 語言撰寫 CNN 演算法，透過演算法完成影像輸入、預處理等步驟建立卷積神經網路構建模型，並將客運司機駕駛正常、異常行為影像資料輸入使模型進行學習與預測工作，期望能藉此驗證可用於管理客運司機行車中正常、異常行為之分析流程，使決策者可藉此流程評估改善方案及決策輔助之用。

4.1 實證分析流程

本研究是以葛瑪蘭客運司機於行車間之影像資料進行處理與分析，透過 R 語言程式將駕駛行為影像資料轉檔後，透過人工將影片中的駕駛行為進行分類，擷取圖片建立駕駛行為訓練資料；而後再串接 Keras、EBImage、Numpy 等各種 R 語言套件，建置卷積神經網路模型，將駕駛行為訓練資料以 9:1 的比率，進行模型的訓練與預測，模型輸出的結果約落於 90%~94% 之間，表示模型在辨識司機行為動作上可以信賴。為了加強在管理層面上的應用與深度，亦將透過 Power BI 視覺化軟體，結合葛瑪蘭客運公司的行車資料、駕駛不良行為發生次數等資訊進行呈現，以此可構建一事後管理決策流程，從而提升企業管理效益。




圖 4.1 實證分析流程圖

4.2 影像資料集、資料預處理

本研究根據葛瑪蘭客運所提供去個資化後之司機影像資料作為本研究實證資料，資料蒐集時間為民國 108 年 12 月 1 日~12 月 30 日間，影像資料來自葛瑪蘭客運大客車輛前車門右上方之閉路電視攝影機，錄影軟體以每 15 分鐘為單位紀錄司機行為，因車內閉路電視攝影機為全時錄影，對於錄存空間消耗相當大，故原始檔案皆以 h.264 格式儲存以減少錄存空間。

本研究將影像轉檔為 MJPEG 格式後，再利用軟體以每秒 30 幀輸出；考慮本研究主要目的為實證此分析流程有助於客運企業內部管理駕駛人正常、異常行為，以及受限於現有之運算設備能力上限，故先以程式大量篩除相近之圖片，再以人工每次隨機選取圖片篩選，最終整理本實驗資料集共 7 個異常、1 個正常類別，1260 張圖片進行分析，以下為本實驗之影像資料集分類。

表 4.1 影像訓練資料集

訓練資料集	意涵	數量	類別
正常	雙手握方向盤，身體靠後，正視前方開車	108	正常
東張西望、轉頭、回頭	頻繁東張西望，未專注前方	60	疏失
跟他車司機打招呼	伸手或向窗外探頭與他車司機打招呼	80	疏失
疲勞駕駛	打哈欠、用手遮嘴巴、揉眼睛、伸懶腰等動作	66	錯誤
不合格駕駛動作、肢體動作	翹腳、單手開車、揮手等	176	錯誤
雙手未握住方向盤	雙手放開方向盤、雙手手肘靠在方向盤上，未雙手握住方向盤	110	錯誤
邊開車邊吃東西、喝飲料	吃便當、喝飲料等	296	錯誤
使用手機、平板	滑手機、講電話、聊天等	368	違規

在獲得影像訓練資料集後，接著需要將影像轉換為機器可以辨識、計算之格式，此亦透過 R 語言完成，圖 4.2 即為將影像訓練資料輸入後的結果。




圖 4.2 影像訓練資料(部分)



4.3 卷積神經網路

本研究以 R 語言為開發工具，撰寫 CNN 演算法以對客運司機行車行為進行辨識，需預先安裝 Keras、Tensorflow、Anacoda 等擴充程式庫，使 R 具有 CNN 的開發環境，CNN 對於司機正常、異常駕駛行為影像資料的分析流程如圖 4.3 所示，本研究使用兩層卷積層與倒傳遞神經網路的結構來對司機行為影像資料進分類預測，相關說明如後。




圖 4.3 CNN 運算流程

4.3.1 輸入層

本研究將前述以分類歸納整理之駕駛人正常、異常行為影像資料共 1260 張影像，以 9：1 方式區隔訓練與測試資料，以驗證模型準確度；輸入資料後，透過演算法將輸入之司機正常、異常駕駛行為影像資料轉換，並開始進行卷積、池化等提取特徵之步驟。

4.3.2 卷積層

在完成資料輸入後與影像處理後，演算法將影像轉換為矩陣，並進入卷積層開始對影像做卷積以提取特徵，本研究設定為 2 層卷積層，並採用 3×3 卷積核，設定每次步移 3 單位進行卷積步驟，卷積層運算流程如圖 4.4 所示，演算法將影像預處理後取得影像矩陣 I ，以每次 3×3 大小擷取影像並與卷積核 K 進行計算，可獲得 $I*K$ 大小之特徵影像。




圖 4.4 卷積運算示意圖

4.3.3 激活函數

如文獻回顧內容所述，激活函數在由 Hinton 提出加入深度學習使用後，對於惟整體演算法的辨識能力皆有顯著的提升；本研究使用 ReLU 函數，如圖 4.5 所示，其亦為相當常用於影像辨識之激活函數。




圖 4.5 ReLU 線性整流函數

4.3.4 池化層

在經過卷積層運算與設定激勵函數類型後，接續便需針對池化方式進行設定，如文獻回顧所述，池化方式主要包含三種，分別為最小池化、最大池化、平均池化等，由於 CNN 演算法對影像的分類預測是透過類神經網路進行，難從前端部分去預測、評估設定之參數對於準確率的直接影響，相關研究亦多以試誤法就輸出結果進行參數的在調校與設定；據此，本研究針對選取最大池化方式對卷積後之影像特徵進行提取，以降低輸入矩陣維度，並從中得到最能代表該矩陣的特徵(即為矩陣中的最大值)，本研究最大池化方式如圖 4.6 所示，以 2*2 大小過濾器逐步計算範圍內之最大值，並輸出池化影像。




圖 4.6 最大池化操作

4.3.5 影像特徵攤平與全聯接層

經由卷積、池化層的運算可使輸入的影像資料在降維的同時也具有特徵，後續便須將影像輸入至倒傳遞神經網路進行計算與預測；為使倒傳遞神經網路可以進行計算，尚須針對影像矩陣進行攤平步驟，如圖 4.7 所示。演算法會將池化的影像轉換為向量，此步驟即為圖中所示之攤平層(Flatten)，並可被倒傳遞神經網路(BPNN)演算法進行全聯接層，計算誤差後更新權重，則可得到最後解。




圖 4.7 池化影像的攤平

4.3.6 丟棄層

為避免 CNN 演算法在訓練時發生過擬合(overfitting)情況，Hinton 等人提出在卷連接層中加入丟棄(dropout)機制，其透過演算法亂數對類神經網路架構中的神經元進行啟閉，增加亂數學習性以防止各神經元計算之特徵相互適應，以此提升輸出結果，如圖 4.8 所示。




圖 4.8 Dropout 機制示意圖

圖 4.8 左側為一般的類神經網路，右側則是使用前述 dropout 機制由演算法亂數決定啟閉神經元的結構，以打叉的方式顯示神經元關閉，由此方式在類神經網路運算時，神經元以機率隨機進行開啟予關閉，使整個類神經網路的參數更新機制不再以固定神經元為主，由此可防止各神經元間相互適應，減少過擬合問題的發生。



4.4 分類預測

根據前述內容分別說明 CNN 演算法在其結構各層之運作方式與功能，本節將就本研究於 R 語言為開發工具實作之卷積神經網路 CNN 預測結果進行說明，期望以此作為辨識客運司機於行車間之正常、異常行為影像方法，並以此作為決策輔助之依據。

關於參數設定部分，首先在卷積層採用 3*3 大小的卷積核，並採用 ReLU 激活函數加強模型在卷積訓練過程中的收斂能力，考慮硬體資源限制，輸入圖片大小設定為 100*100，模型將針對輸入的影像進行縮放，於池化層，經測試後採用最大池化層在模型準確率上表示較佳，每次池化計算範圍大小為 2*2，學習率設定為 0.25，如圖 4.9 所示。

```
# CNN Model
model%>%
  layer_conv_2d(filters = 32,
                kernel_size = c(3,3),
                activation = 'relu',
                input_shape = c(100, 100, 3)) %>%
  layer_conv_2d(filters = 32,
                kernel_size = c(3,3),
                activation = 'relu') %>%
  layer_max_pooling_2d(pool_size = c(2,2)) %>%
  layer_dropout(rate = 0.25) %>%
  layer_conv_2d(filters = 64,
                kernel_size = c(3,3),
                activation = 'relu') %>%
  .....

# Convolutional Neural Networks
# Load packages
library(tensorflow)
library(keras)
library(EBImage)
# Read Images
setwd('C:/Users/[redacted]/Desktop/R CNN/')
pic1 <- list.files( './Test')
train <- list()
for (i in 1:1260) {train[[i]] <- readImage(pic1[i])}
pic2 <- list.files( './Train')
test <- list()
for (i in 1:8) {test[[i]] <- readImage(pic2[i])}
# Explore...
```

圖 4.9 影像預處理流程語法設計(部分)

執行 R 語言開發環境建置之 CNN 演算法，R 將每次進行預測之相關結果以如圖 35 方式進行輸出，本研究經反覆測試後，將迭代次數設定為 60 次，其因為在第 35 次迭代時，辨識準確率逾 9 成，至第 40 次迭代期間漸趨穩定，最終可達 94%，其結果已達標，故停止迭代，以下為迭代過程與模型停止運算之最終辨識結果，如圖 4.10~12 所示。

```

0 [=====] - 15s 64ms/sample - loss: 0.9712 - acc: 0.7042 - val_loss: 2.5294 - val_acc: 0.3750
12/60
0 [=====] - 13s 56ms/sample - loss: 0.7646 - acc: 0.7458 - val_loss: 2.9870 - val_acc: 0.3750
13/60
0 [=====] - 13s 56ms/sample - loss: 0.7268 - acc: 0.7542 - val_loss: 2.2308 - val_acc: 0.3750
14/60
0 [=====] - 13s 55ms/sample - loss: 0.6447 - acc: 0.7833 - val_loss: 2.8498 - val_acc: 0.3750
15/60
0 [=====] - 13s 55ms/sample - loss: 0.4924 - acc: 0.8208 - val_loss: 3.5645 - val_acc: 0.3750
16/60
0 [=====] - 14s 57ms/sample - loss: 0.5354 - acc: 0.8333 - val_loss: 2.8242 - val_acc: 0.3750
17/60
0 [=====] - 15s 61ms/sample - loss: 0.4652 - acc: 0.8500 - val_loss: 3.0192 - val_acc: 0.3750
18/60
0 [=====] - 15s 62ms/sample - loss: 0.4587 - acc: 0.8417 - val_loss: 2.9168 - val_acc: 0.2500
19/60
0 [=====] - 13s 55ms/sample - loss: 0.3955 - acc: 0.8708 - val_loss: 4.2468 - val_acc: 0.3750
20/60
0 [=====] - 13s 56ms/sample - loss: 0.4471 - acc: 0.8208 - val_loss: 3.2392 - val_acc: 0.3750
21/60
0 [=====] - 13s 56ms/sample - loss: 0.3724 - acc: 0.8750 - val_loss: 3.7026 - val_acc: 0.3750
22/60
0 [=====] - 13s 55ms/sample - loss: 0.3618 - acc: 0.8750 - val_loss: 3.9759 - val_acc: 0.3750
23/60
0 [=====] - 13s 55ms/sample - loss: 0.3934 - acc: 0.8417 - val_loss: 3.3614 - val_acc: 0.3750
24/60
0 [=====] - 14s 57ms/sample - loss: 0.3655 - acc: 0.8542 - val_loss: 2.9671 - val_acc: 0.3750
25/60
0 [=====] - 14s 57ms/sample - loss: 0.3350 - acc: 0.8875 - val_loss: 3.5810 - val_acc: 0.3750
26/60
0 [=====] - 16s 65ms/sample - loss: 0.3714 - acc: 0.8750 - val_loss: 3.1107 - val_acc: 0.3750
27/60
0 [=====] - 14s 60ms/sample - loss: 0.4015 - acc: 0.8542 - val_loss: 2.9330 - val_acc: 0.3750
28/60
0 [=====] - 16s 68ms/sample - loss: 0.3598 - acc: 0.8667 - val_loss: 3.3605 - val_acc: 0.3750
29/60
0 [=====] - 15s 64ms/sample - loss: 0.2649 - acc: 0.9042 - val_loss: 3.5249 - val_acc: 0.3750
30/60
0 [=====] - 15s 62ms/sample - loss: 0.2903 - acc: 0.8875 - val_loss: 3.7352 - val_acc: 0.3750
31/60
0 [=====] - 15s 63ms/sample - loss: 0.3160 - acc: 0.8917 - val_loss: 3.9609 - val_acc: 0.3750
32/60
0 [=====] - 14s 56ms/sample - loss: 0.2371 - acc: 0.9250 - val_loss: 4.2233 - val_acc: 0.3750
33/60
0 [=====] - 13s 56ms/sample - loss: 0.2821 - acc: 0.8917 - val_loss: 4.1124 - val_acc: 0.3750
34/60
0 [=====] - 13s 55ms/sample - loss: 0.2592 - acc: 0.8917 - val_loss: 4.7011 - val_acc: 0.3750
35/60
0 [=====] - 13s 54ms/sample - loss: 0.2272 - acc: 0.9000 - val_loss: 4.9089 - val_acc: 0.3750
36/60
0 [=====] - 13s 55ms/sample - loss: 0.2489 - acc: 0.9083 - val_loss: 3.8795 - val_acc: 0.3750
37/60
0 [=====] - 13s 55ms/sample - loss: 0.2239 - acc: 0.9042 - val_loss: 4.2030 - val_acc: 0.3750
38/60
0 [=====] - 14s 60ms/sample - loss: 0.2330 - acc: 0.9083 - val_loss: 5.0004 - val_acc: 0.3750

```

圖 4.10 CNN 執行過程(部分)




圖 4.11 CNN 模式訓練測試震盪圖(60 次)

ID	原始	預測	實際	Predicted_class	Actual
[1,]	0.3561002	0.3230282	0.3208716	0	0
[2,]	0.3464722	0.3352493	0.3182785	0	0
[3,]	0.3569186	0.3233403	0.319741	0	0
[4,]	0.3433385	0.3360894	0.3205721	0	0
[5,]	0.3429779	0.3362229	0.3207992	0	0
[6,]	0.3433588	0.3357966	0.3208447	0	0
[7,]	0.3444863	0.3369384	0.3185752	0	0
[8,]	0.3527385	0.3272388	0.3200227	0	0
[9,]	0.3528875	0.3273565	0.3197561	0	0
[10,]	0.3527482	0.3486309	0.298621	1	0
[11,]	0.355432	0.3276439	0.3169241	1	1
[12,]	0.3479427	0.3636776	0.2883796	2	1
[13,]	0.35251	0.3279145	0.3195754	1	1
[14,]	0.3502978	0.3337161	0.3159862	1	1
[15,]	0.3558051	0.2945804	0.3396145	0	1
[16,]	0.349043	0.333851	0.317106	1	1
[17,]	0.3506584	0.3337793	0.3155622	1	1
[18,]	0.3439835	0.338658	0.3173585	1	1
[19,]	0.3498564	0.3331829	0.3169607	1	1
[20,]	0.3388083	0.3381817	0.32301	1	1
[21,]	0.3501838	0.3313647	0.3184514	1	1

圖 4.12 預測分類結果(部分)

4.5 管理意涵

本研究使用 R 語言開發工具建置 CNN 演算法，完成 1,260 張客運司機於行車間之影像資料訓練與測試，具良好之辨識能力，足見透過影像辨識方式分析客運司機行車間之行為有效。由於目前客運業者內部針對司機的績效管制以事後評鑑為主，難以針對司機行車間之異常行為制定績效評估制度，使績效評鑑制度始終難以完善，故本研究實證透過深度學習針對客運司機行車間行為之正常、異常駕駛行為的辨識，在管理層面上具有將司機行為量化的意義，使評鑑作業可藉此量化數據予以訂定。

而為更進一步提升客運業者對於司機在行車間之正常、異常駕駛行為了解，以及評估與管理機制之制定，本研究以 Power BI 視覺化工具結合 CNN 辨識結果進行呈現，再加入即時之客運運行狀況，使管理單位與決策者可掌控司機是否有發生異常駕駛行為之現象，並可提早與客運司機進行聯繫，了解其是否疲勞，或針對其他不良行為進行口頭勸導改善，以提升司機行車間之安全性，目前已將測試訓練之部分資料與當日個時間點之待命、運行與返回之車輛數建置於 Power BI 儀表板中，如圖 4.13 所示。




圖 4.13 客運司機正常、異常駕駛行為與管理儀表板圖

1. 到站駕駛員不合格駕駛動作統計

在 Power BI 儀表板中，增加駕駛員、不合格駕駛動作統計與各站站點進行呈現，如圖 4.14 所示。在圖 4.14 中，可透過點選各站位置觀察目前到站駕駛員的資訊，以及前次行程中累積的不合格駕駛動作統計，如圖 4.15 示。




圖 4.14 到站駕駛員不合格動作統計總表



圖 4.15 單一到站駕駛員不合格動作統計

2. 到站駕駛員累計行車時間統計

在此儀表板中，可檢視到站駕駛員與駕駛車輛車號車號，以及目前的累計行車時間，可結合前頁的不合格駕駛動作統計資訊，觀察駕駛員是否有因長時間駕車疲勞造成不合格駕駛動作上升，即時與駕駛員聯繫，進行事故預防，如圖 4.16、4.17 所示。




圖 4.16 到站駕駛員與累計行車時間儀表板




圖 4.17 單一到站駕駛員與累計行車時間儀表板

3. 到站駕駛員各別異常行為分析統計

在此儀表板中，可檢視到站駕駛員目前累計的各種不合格駕駛行為，可從中觀察各駕駛員主要出現的異常駕駛行為，並可結合與駕駛員訪談以了解造成原因，從而達到駕駛員的身、心狀況管理，同時提升行車安全與效率，如圖 4.18 所示。




圖 4.18 到站駕駛員各別異常行為分析統計

4. 累計行車時間與駕駛員異常行為分析統計

在此儀表板中，可從累計行車時間角度了解最常發生的駕駛員異常行為，以及最主要會發生的異常行為行車時間，如圖 4.19 所示。從圖中可見最主要的異常行為發生時間以 1 個半小時為主，其次為 50 分鐘、45 分鐘等，其中最主要的異常駕駛行為又以不標準駕駛動作、使用手機以及不合格肢體動作為主，顯示駕駛員在中長時間段的行中時間中，常會發生分心以及使用手機的情況。




圖 4.19 以累計行車時間分析主要異常駕駛行為

5. 出發時間與累計異常行為

在此儀表板中，可了解各出發時間駕駛員的異常行為統計，從圖中可見異常駕駛行為發生次數與發車時間的早晚有較明顯關係，時間越早異常行為越多，並主要以開車分神、不合標準駕駛動作與使用手機為大宗，顯示對於早班發車的駕駛員，應更加注意其精神狀況與集中力。




圖 4.20 從出發時間分析累計異常駕駛行為

綜上所述，本研究因受限於現場環境硬體與運算資源條件，經訪談葛瑪蘭客運公司高階主管，決定採用後台駕駛影像資料進行司機異常駕駛行為影像辨識模型訓練與建置，藉由 R 語言開發工具建置 CNN 演算法，並同時進行模型測試與修正，最終模型辨識率可達 94%，具良好之辨識能力，顯示透過影像辨識方式分析客運司機行車間之行為，證明可行。為使辨識結果可應用於管理輔助，本研究加入後台之營運資料，並以視覺化軟體進行呈現，最終建立一有助於客運業者管理、輔導司機正常駕駛之決策輔助機制，以此提升安全效益。



第五章 結論與建議

5.1 結論

1. 目前多數客運業者雖多已裝設閉路電視攝影機於客運車輛，可針對司機行車行為進行錄影，但前述之錄影內容仍由少數人員進行調閱與審查，在實務面上難以完全針對所有司機進行檢視，因此部分違規司機常以「其他駕駛人也有相同行為，為何只有我受罰」作為理由，對於管理單位基於乘客與用路人安全考量所提出之輔導與教育措施，表現出激烈之抵抗心態，長久以來難以制定公平之評估機制。
2. 本研究以此為發想，提出結合 CNN 演算法與 Power BI 資料視覺化工具，針對客運司機行車間之影像進行辨識，由機器判斷司機之正常、異常駕駛行為，並以儀表板方式進行呈現。在模型訓練過程中，亦檢視模型辨識結果進行修正，最終模型辨識準確率可達 94%，顯示本研究期望建立之自動判斷客運司機於行車間之正常、異常駕駛行為之機制確實具可行性。
3. 透過 Power BI 資料視覺化工具進行呈現，使客運業管理單位或決策者可更了解各司機之駕駛行為，如是否屬於過勞人員，或是具有不良駕駛行為傾向，並以此建立輔導改善措施，如：針對過勞人員進行溝通與了解是否個人私下作息不正常，又或身體健康發生問題，需要透過排班調整進行改善、或是針對不良駕駛行為之司機進行勸導並勒令改善不良行為等，從而提升交通安全。

5.2 建議

1. 本研究雖已實證公路客運司機行車間之行為可透過 CNN 演算法進行辨識與分類計算，因受限於硬體運算能力不足而縮減輸入影像資料，使目前公路客運司機異常行為分類定義仍有限，建議未來研究應拉長資料時間跨度，定義更加多元之正常、異常行車行為，在電腦可處理的範圍內指派更多可處理工作，以此減少後端人力需求。
2. 目前有關安全辨識的相關應用雖多可見於一線人員產業(如產線勞工、作業員、飯店房務人員等)，但其主要方向仍重於人的行為監測，其出發點仍以人的安全為主，建議考慮納入近年漸趨成熟的 Openpose 演算法，進行未來相關研究，期望可藉此提升管理決策人員掌控現場司機異常駕駛行為之能力，以達到完善企業運營效率之目的。



參考文獻

1. Shinar, D. (1978). *Psychology on the Road: The Human Factor in Traffic Safety*: Wiley.
2. Spolander, K. (1983). DRIVERS' ASSESSMENT OF THEIR OWN DRIVING ABILITY.
3. Gulian, E., Matthews, G., Glendon, A. I., Davies, D. R., & Debney, L. M. (1989). Dimensions of driver stress. *Ergonomics*, 32(6), 585-602.
4. Reason, J.T., Manstead, A., Stradling, S.G., Baxter, J. & Campbell, K. (1990). Errors and violations on the road- areal distinction. *Ergonomic*, 33(10/11), 1315-1332.
5. Parker, D., Manstead, A., Stradling, S., Reason, J., & Baxter, J. (1992). Intention to Commit Driving Violations: An Application of the Theory of Planned Behavior. *Journal of Applied Psychology*, 77, 94-101.
6. Elander, J., West, R., & French, D. (1993). Behavioral correlates of individual differences in road-traffic crash risk: An examination of methods and findings. *Psychological bulletin*, 113, 279-294.
7. Deffenbacher, J. L., Oetting, E. R., & Lynch, R. S. (1994). Development of a driving anger scale. *Psychol Rep*, 74(1), 83-91.
8. Lajunen, T., & Summala, H. (1995). Driving experience, personality, and skill and safety-motive dimensions in drivers' self-assessments. *Personality and Individual Differences*, 19(3), 307-318.

9. Rimmö, P.-A., & Åberg, L. (1999). On the distinction between violations and errors: Sensation seeking associations. *Transportation Research Part F: Traffic Psychology and Behaviour*, 2(3), 151–166.
10. Owsley, C., Stalvey, B., Elgin, J., & Sloane, M. (1999). Older Drivers and Cataract: Driving Habits and Crash Risk. *The journals of gerontology. Series A, Biological sciences and medical sciences*, 54, M203-211.
11. Westerman, S. J., & Haigney, D. (2000). Individual differences in driver stress, error and violation. *Personality and Individual Differences*, 29(5), 981–998.
12. Xie, C.Q. and Parker, D. (2002) A Social Psychological Approach to Driving Violations in Two Chinese Cities. *Transportation Research Part F: Traffic Psychology and Behavior*, 5, 293-308.
13. Sullman, M. J. M., Meadows, M. L. & Pajo, K. B. (2002). Aberrant driving behaviours amongst New Zealand truck drivers. *Transportation Research Part F: Traffic psychology and behavior*, Vol. 5, 217-232.
14. Deffenbacher, J., Filetti, L., Lynch, R., Dahlen, E., & Oetting, E. (2002). Cognitive-behavioral treatment of high anger drivers. *Behaviour Research and Therapy*, 40, 895-910. *Behaviour research and therapy*, 40, 895-910.
15. Lajunen, T., & Summala, H. (2003). Can we trust self-reports of driving? Effects of impression management on Driver Behaviour Questionnaire responses. *Transportation Research Part F: Traffic Psychology and Behaviour*, 6, 97-107.
16. Taubman-Ben-Ari, O., Mikulincer, M., & Gillath, O. (2004). The multidimensional driving style inventory—scale construct and validation. *Accident Analysis & Prevention*, 36(3), 323-332.

17. Anderson, C., & Horne, J. (2006). Sleepiness Enhances Distraction During a Monotonous Task. *Sleep*, 29, 573-576.
18. Britt, T., & Garrity, M. (2006). Attribution and Personality as Predictors of the Road Rage Response. *The British journal of social psychology / the British Psychological Society*, 45, 127-147.
19. Chang, H.-L., & Yeh, T.-H. (2007). Motorcyclist accident involvement by age, gender, and risky behaviors in Taipei, Taiwan. *Transportation Research Part F: Traffic Psychology and Behaviour*, 10(2), 109-122.
20. Sundström, A. (2011). The validity of self-reported driver competence: Relations between measures of perceived driver competence and actual driving skill. *Transportation Research Part F-traffic Psychology and Behaviour - TRANSPORT F-TRAFFIC PSYCH*, 14, 155-163.
21. Goldenbeld, C., de Groot-Mesken, J., & Schagen, I. (2013). The effect of severity and type of traffic penalties on car drivers' emotions, perceptions of fairness, and behavioural intentions.
22. Abegaz, T., Berhane, Y., Worku, A., & Assrat, A. (2014). Effectiveness of an improved road safety policy in Ethiopia: An interrupted time series study. *BMC public health*, 14, 539.
23. Penmetsa, P., & Pulugurtha, S. (2016). Risk Drivers Pose to Themselves and Other Drivers by Violating Traffic Rules. *Traffic injury prevention*, 18, 00-00.
24. Stephens, A., & Fitzharris, M. (2016). Validation of the Driver Behaviour Questionnaire in a representative sample of drivers in Australia. *Accident Analysis & Prevention*, 86, 186-198.
25. Rafael C. Gonzalez and Richard E. Woods. (2018) *Digital Image Processing*, 4th

Edition, Pearson Education, Inc.

26. 陳少旭 (1997)，交通執法勤務績效評估指標模式建立之研究。中央警察大學警政研究所，桃園縣。
27. 蘇昭安 (2003)，應用倒傳遞類神經網路在颱風波浪預報之研究。國立台灣大學工程科學與海洋工程學系碩士班，臺北市。
28. 張宏銘 (2004)，道路交通違規相關資料整合探討與先進安全車輛改善之研究。國立中央大學機械工程研究所，桃園市。
29. 姚文翰、蔡孟修、陳宜賢、王聖智 (2005)，以視覺為基礎之智慧型環境的建構四年計畫。經濟部學界科專電子報，第 2 期。
30. 尹維龍 (2005)，應用駕駛行為量表探討偏差駕駛行為與事故傾向關係之研究。國立交通大學運輸科技與管理學系碩士班，新竹市。
31. 陳芳正 (2005)，長途客運業駕駛績效之探討。國立成功大學交通管理學系碩博士班，臺南市。
32. 陳加增、劉景富、翁銘聰、林炘 (2008)。先進安全車輛的第三隻眼。彰化縣：財團法人車輛研究測試中心。
33. 翁銘聰、陳加增、高祥鈞 (2008)，以主動外觀模型實現駕駛者人臉追蹤。彰化縣：財團法人車輛研究測試中心。
34. 陳協成、游展昆、吳旭祐、賴尚敬 (2009)，影像辨識。嘉義縣：南華大學資訊工程學系。
35. 黃仲平 (2010)，汽車駕駛人錯誤駕駛行為之影響因素探討。國立交通大學運輸科技與管理學系碩士班，新竹市。
36. 孫志軍、薛磊、許陽明、王正 (2012)，深度學習研究綜述。計算機應用研究，第 29 卷，第 8 期。

37. 鍾昌翰 (2012)，影像處理技術應用於河床粒徑分析及魚類數量調查。國立台灣大學生物資源暨農學院生物環境系統工程學研究所，臺北市。
38. 林品喬 (2013)，利用影像處理與類神經網路進行人體坐姿判讀。國立台灣大學應用力學研究所，臺北市。
39. 陳信丞 (2014)，國道客運公司駕駛員人因特性、車輛駕駛行為與駕駛績效之研究。國立成功大學交通管理科學系碩博士班，臺南市。
40. 許立佑、柯明寬 (2014)，駕駛行為及狀態監控系統。車輛工程學術研討會，新北市。
41. 伊寶才、王文通、王立春 (2015)，深度學習綜述。北京工業大學學報，第 41 卷，第 1 期。
42. 張斐章、張麗秋 (2015)，類神經網路導論原理與應用 (第二版)。臺中市：蒼海圖書。
43. 李嘉洲 (2016)，應用深度學習於財經新聞來源對股價趨勢預測之研究。淡江大學資訊管理學系碩士在職專班，新北市。
44. 李宏毅 (2016)，什麼是深度學習。數理人文第十期。
45. 蔡國永、夏彬彬 (2016)，基於卷積神經網路的圖文融合媒體情感預測。計算機應用第 2 期，頁 428-431。
46. 張銘方 (2017)，駕駛者異常行為偵測技術。彰化縣：財團法人車輛研究測試中心。
47. 葉名山、郭昀禧、陳紫琳、莊喆硯、黃百祿 (2018)，利用行車輔助系統探討駕駛行為之研究。逢甲大學運輸科技與物流學系，臺中市。
48. 陳翰 (2018)，從社群媒體挖掘以感測日常交通滿意度之研究。淡江大學運輸科學碩士班碩士班，新北市。

49. 陳奕瑄 (2018)，以 CNN 進行植物圖片的辨識以及經過處理後的再辨識。
台灣大學電機資訊學院資訊工程學系碩士班，臺北市。
50. 林宥豪、蔡玉娟 (2018)，基於卷積神經網路之智慧型人物影像追蹤系統，
黃埔學報，第 74 期，頁 29-48。
51. Brandon，卷積神經網路的運作原理，https://brohrer.mcknote.com/zh-Hant/how_machine_learning_works/how_convolutional_neural_networks_work.html，擷取日期：2018/11/12。
52. Tommy Huang (2018)，卷積神經網路，
<https://medium.com/@chih.sheng.huang821/%E5%8D%B7%E7%A9%8D%E7%A5%9E%E7%B6%93%E7%B6%B2%E8%B7%AF-convolutional-neural-network-cnn-%E5%8D%B7%E7%A9%8D%E9%81%8B%E7%AE%97-%E6%B1%A0%E5%8C%96%E9%81%8B%E7%AE%97-856330c2b703>，擷取日期：2018/11/13。
53. 維基百科，深度學習，網址：
<https://zh.wikipedia.org/wiki/%E6%B7%B1%E5%BA%A6%E5%AD%A6%E4%B9%A0>，擷取日期：2018/11/14。
54. 交通部高速公路局 (2018)，交通安全資訊，
<https://www.freeway.gov.tw/Publish.aspx?cnid=516&p=2849>，擷取日期：2018/11/14。
55. 彩色轉灰階原理，網址：<http://atlaboratory.blogspot.com/2013/08/rgb-g-rey-l-gray-r0.html>，擷取日期：2018/11/18。
56. 紅黑聯盟，深度學習筆記五：卷積神經網絡 CNN，網址：
<https://read01.com/zh-tw/RE37gy.html#.WgktBWiCxf>，擷取日期：2018/11/18。

57. Huy Bui (2020), From Convolutional Neural Network to Variational Auto Encoder, website: <https://medium.com/analytics-vidhya/from-convolutional-neural-network-to-variational-auto-encoder-97694e86bb51>.
58. 公路客運評鑑制度，
https://www.thb.gov.tw/sites/ch/modules/download/download_list?node=adbd51b5-26e6-4a58-a9c6-c39a142fd9c0&c=e7873b4a-ba8a-4b0f-b5ba-5e16eb83eeb5，擷取日期：2021/7/19。

