

## 卷積神經網路於擁擠指標之研究

# Analysis of Congestion Index using Convolution Neural Network Approach

劉士仙 Liu, Shih-Sien<sup>1</sup>

陳瑋翔 Chen, Wei-Hsiang<sup>2</sup>

徐偉哲 Hsu, Wei-Che<sup>3</sup>

### 摘要

以不同顏色提供道路交通擁擠 (Congestion) 資訊，是目前國內外用來描述路況資訊最普遍的一種型式，主要在於簡單、畫面易懂；國內外的交通控制中心的路況擁擠程度，目前主要仍以道路速限為準，主觀地將速率高低分為幾種級距，以反應用路人對道路擁擠感知的等級，常會發生與用路人主觀之行車擁擠感知經驗不一致的現象。過去學術研究爰用進階之分類方法，雖有改善，仍有諸多改善空間。由於用路人係以視覺感知來判讀交通擁擠狀態，有鑑於此，本研究嘗試以圖像辨識之卷積神經網路技術，預測擁擠指標類別，並以路段固定偵測器之即時交通參數為基礎，比較過去使用轉換之判讀方法，以高速公路為例，比較分析，結果顯示，以卷積神經網路深度學習預測之模式績效，準確度之改善有大幅提升，準確率達 82.9%。

**關鍵詞：**擁擠指標、卷積神經網路

### Abstract

*Congestion Index with color remarks a common way in traffic control area, mainly for its easy application and simplicity. Currently, the traffic congestion index are grouped into different levels in terms of speed range addressed for its inconsistency with the congestion perception of driver's experience. Although, emerged advanced technologies improve its accuracy, it remains rooms for refinement. Since road users identify the states of road congestion by perception, which is obviously equivalent to sets of image extraction processing. It motivates this paper applying convolution neural network to predict the states of congestion classification. Compared with real-time traffic parameters from roadside detector by previous works, the proposed approach yields promising results with over 82.9% accuracy.*

**Keywords:** congestion index, convolution neural network

## 一、前言

交通壅塞是現代化都會區自然發展的現象，具有重現性、又帶有隨機的變動特性，用路人如何聰明、智慧地避開壅塞路段，端視交通資訊的準確性與後端路徑導航模式的應用。近年來，

<sup>1</sup> 私立淡江大學運輸管理學系副教授 (聯絡地址：新北市淡水區英專路 151 號，電話：02-26236517，E-mail: adrain728@gmail.com)。

<sup>2</sup> 私立淡江大學運輸管理學系學生。

<sup>3</sup> 私立淡江大學運輸管理學系學生。

智慧運輸科技在自駕車、車聯網範圍的應用與日俱進，在大數據、影像處理與人工智慧的領域部分，都取得驚人的成就。早期的交通資訊處理方式納入新科技方法，在各種不同類別的研究上，都有顯著改善的效果。

道路服務水準反應的是路段、路口的擁擠程度，從早期路段服務水準參考的車流量與服務容量比率(Volume/Capacity, V/C)指標數值，到更精確的車輛速率，道路交通數據也從靜態的資訊應用，進階到以時階為單位的動態交通即時管理與控制階段。即時路段資訊的蒐集，包括路段偵測器與閉路電視(Closed-Circuit Television, CCTV)，參數的取得包括不同車種的流量、佔有率與點速率；而早期之交通車流的 CCTV 影像畫面多只停留在用路人自我解讀的階段，難以進階加值，未能將資訊進一步整合。

路況擁擠，從資訊角度來看，從過去一維的點速率，擴展到偵測器蒐集路段的三維資料，從早期業務單位依道路車輛平均速率，主觀地將路況擁擠指標作分群，逐漸調整到客觀量化進階的理論分群方法，結果反應的是速率無法有效呈現道路壅塞的現象。

實務上，用路人都係以視覺感知，依個人主觀經驗來判讀交通狀態，因此以圖像辨識之卷積神經網路深度學習技術，來預測擁擠指標類別，不但符合實務的情境，邏輯上，理論模式更能反應實際路況。

道路「擁擠指標」分級訂定，目前國內外各業務單位仍無一致的標準，且常與用路人主觀之感受有所差距，使得資訊使用的效率與品質，備受質疑與挑戰，也因此能反應「主觀感受」之擁擠指標訂定成為目前重要之探討議題。

## 二、道路擁擠指標

### 2.1 擁擠指標分級現況

目前道路擁擠指標的分級方式，交控中心大多使用路側偵測器所測得的資料進行統計分析，經由長期觀察之車流情形，再透過經驗法則轉換後，即可呈現該路段的壅塞狀態。擁擠指標的分級，國內外交控中心皆以不同的顏色來區分，如圖 1。



圖 1 即時路況資訊圖

通常擁擠指標類別係以不同的速度區間範圍來定義擁擠的級距類別，依路側偵測器所蒐集之平均車輛速度，直接以不同的顏色顯示；另一種方式，則是由主管機關的主觀經驗來定義

擁擠分級，直接透過顏色呈現，描述路況。在辨識過程中常搭配 CCTV 回傳的即時道路影像，進而辨識道路擁擠程度(劉士仙，2011)。

對於道路擁擠指標之分級，目前採行之擁擠指標訂定方法，其分級之級數設計皆因地而異，如圖 2。國內各交控中心在擁擠指標訂定上多以三級制與四級制分類為主，高快速道路以三級制與四級制分類為主，而市區幹道則以三級制分類為主；交通部科技顧問室曾對專家學者以及一般用路人進行資訊需求內容及顯示方式分析調查，其結果顯示有關資訊「質」的顯示，皆偏好以提供三級壅塞程度為最佳。

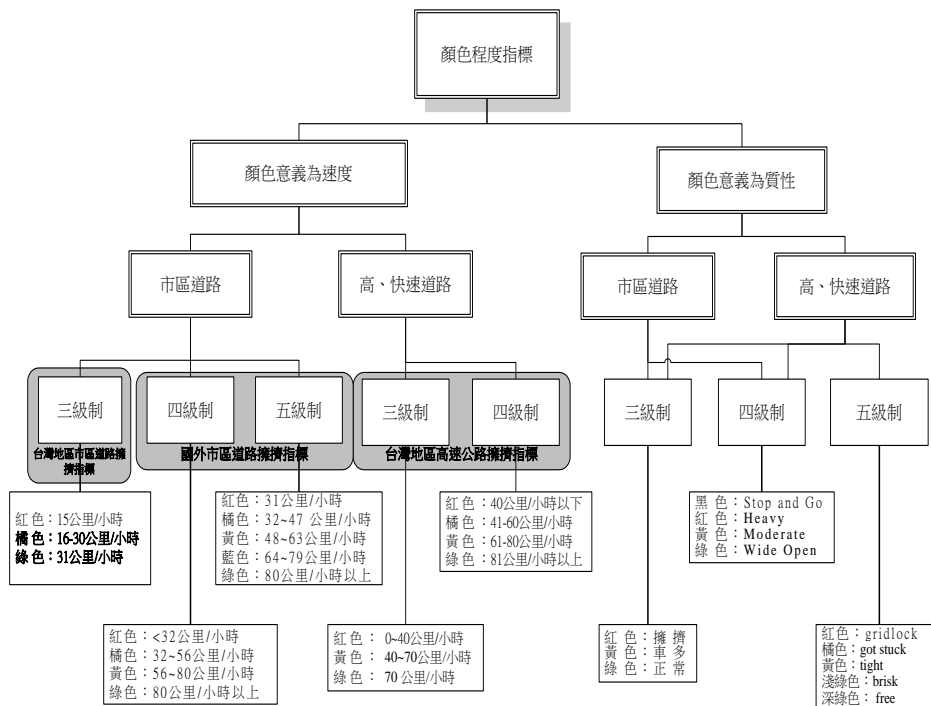


圖 2 交控中心顏色指標分類圖

目前不管係以速率、亦或者透過業務單位之經驗法則，若依規劃者主觀在數據上之分析來判斷用路人對壅塞的感知，容易發生現實與數據上預期的落差，賴長偉(2007)指出現有路況資訊的呈現方式，擁擠程度與用路人之主觀感受存在著極大落差；羅孝賢等人(2007)也有相同的結論，研究顯示，官方訂定之擁擠等級類別與用路人的主觀擁擠分級感受相比，準確率偏低，因此依照上述研究之結論，可歸因於擁擠指標訂定時，缺少用路人的主觀擁擠感受資料，也沒有針對重要輸入資料項目來深究，是造成駕駛人主觀感受擁擠程度與主管機關標準存在差異的主要原因，若能結合用路人主觀感受與客觀的資料，模式有效整合二者，再進行擁擠指標區間界定之分類準則，將更臻完備。

## 2.2 擁擠指標之參數選擇

道路的交通分析參數，包括流量、密度、空間平均速率；實務上路況之道路資訊蒐集，包括時間平均速率、佔有率與流量等，一般利用路側偵測器或感應線圈所量出的速率為現點速率，端視偵測器安裝位置，是否能反應車流之空間平均速率(劉士仙等人，2006；Liu，2007；梁志安，2008)；呂柏彥(2014)認為要減少人力的花費與縮小統計的誤差，可以利用SUMUL8

建構出高速公路模擬模型，參考高公局提出之數據與國道即時影像，當作模型輸入參數，可有效辨識不同路段之車流量。

以圖像為基礎之影像處理，將路段車流資訊以灰階、或色彩 RGB 的方式解構，亦可以擷取空間範圍內之車速、車種流量與密度，以影像裝置取代路側偵測器，以圖像處理取代偵測器之直接數值數據，已係智慧運輸發展之未來趨勢(朱柏嘉，2020)。

## 2.3 擁擠指標之分類方法

有效的擁擠指標應具一定之信度與效度，且發佈之資訊須具備即時反應用路人主觀擁擠感知之狀態；因此直觀上，主觀擁擠指標是一種擁擠感知與道路交通參數對應的一種邏輯關係、與分類的方法。

目前以車速或道路偵測器之交通參數(車速、佔有率、車流量)直接分類的方法，主要問題是所調查之交通參數資料，無法有效地與用路人主觀擁擠感知聯結，是以無法有效反應用路人之感受。Liu et. al(2007)以線性判別分析建構三等級之號誌化幹道用路人主觀擁擠指標，與傳統之路段速率等級劃分方式相比，其準確度由原來之67%，提昇至87%，改善20%，擁擠之中間等級判讀歸類，相較以速率為主之分級方式，有顯著改善，但仍有錯判機率過大的現象。因此劉士仙等人(2011)採用類神經網路之分類方式，以改善產生不易辨識之交通擁擠程度狀況，結果非線性方法較線性判別分析有微幅的改善。

近年來，人工智慧技術應用於圖像之深度學習已有長足之進步，類神經網路理論與技術的改良，對於圖像之解讀，納入卷積層(Convolution)運算，透過一個指定較原圖尺寸更小的視窗，定義適當數量的濾波器Filter，由上而下依序滑動，取得圖像中各局部特徵，作為下一層的輸入，這個滑動視窗簡稱為卷積核(Convolution Kernel)，可以簡化問題處理的尺度，並保留重要資訊的特徵。後端之池化(Pooling)則可以達到簡化、降低產生誤差干擾之效果，在輸出前之降維；經驗證，對於權重組合之推估與分類預測的結果，有較佳的分析績效(Krizhevsky, 2013)。

總言之，應用非線性方法之深度學習，以圖像為輸入資料，卷積層與池化的併入，係現況影像辨識最佳分類之預測推估方式。

# 三、卷積神經網路

## 3.1 倒傳遞神經網路架構

倒傳遞神經網路(Back Propagation Neural Network, BPN)是機器學習常用的模式，屬於監督式學習型，先隨機選取部份實際樣本來訓練學習，再測試剩餘樣本，若機器預測與實際結果誤差在合理範圍內，才符合實務線上作業分析之基本要求。

Werbos(1974)提出隱藏層的學習演算法，為最早之倒傳遞網路模式。類神經網路可分為(1)處理單元(Processing Element)(2)層(Layer)(3)網路(Network)等三個層次，網路架構一般分為輸入層、隱藏層、輸出層三層。一般倒傳遞網路為多層(Multilayers)的網路模型，學習

過程由前傳遞和倒傳遞所共同組成，傳統倒傳遞網路演算法之最佳解搜尋方向是利用最陡坡降法(Steepest Descent Method)逐次搜尋，步幅則採取經驗法則，以固定的學習速度，將誤差函數予以最小化。

以預測道路擁擠指標之倒傳遞神經網路架構來看，如圖3，輸入層為原始交通參數，包括流量、車速、佔有率，輸出層則為擁擠的三種不同等級：擁擠、車多、順暢；中間之隱藏層則為集成與轉換函數，將輸入參數與輸出結果，找出最優之映射方式(劉士仙, 2011)。Hirose(1991)指出對傳統網路學習結構而言，增加隱藏層結點數，可達到縮小收斂誤差之目的，然而過多隱藏層結點數會使目標函數形成之非凸函數過於複雜，只是徒增執行時間，若隱藏層處理單元數取輸入與輸出單元數之平均值，一般可獲得較佳的績效。

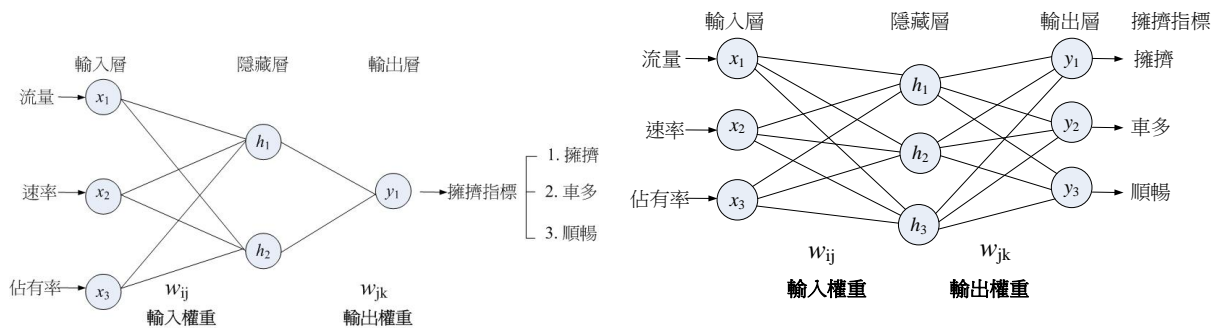



圖 3 擁擠指標之倒傳遞網路架構

### 3.2 卷積神經網路架構

卷積神經網路(Convolution Neural Network, CNN)係目前影像辨識最常被應用的方法，源於LeCun(1998)對於手寫數字之辨識，主要由卷積層(Convolution)、池化層(Pooling)和全連接層(Full Connection)所組成，概念架構如圖4。技術已在諸多領域，如自駕車、人臉辨識、車聯網、醫學影像診斷等的應用上，取得驚人的成果。



來源：LeCun(1998)

圖 4 卷積神經網路示意圖

卷積神經網路與傳統倒傳遞網路之主要差異，在於多了圖4中段的特徵擷取，由於資料分析前，增加擷取影像中重要特徵，因此可以忽略畫面中大部份無關的訊息，達到減噪、降低雜

訊的干擾，因此在影像處理上，優勢特別明顯。扣除特徵擷取時，結構等同於傳統神經網路。

將大尺度影像依據濾波器Filter，從鄰域中提取影像特徵，需要先定義卷積核(Kernel)的尺度，除可以降低影像計算的複雜度，並達到過濾雜訊干擾的效果，卷積核(或稱濾波器)的數量與核內之數值定義，決定通道數與圖形特徵的擷取，由此產生多個卷積層，得到影像中各個區域的特徵，並透過權重共享的方式，對局部影像作運算。卷積可以對各種影像大小的目標做特徵擷取，影像中相同特徵之權重共享可以節省訓練過程所需調整的參數個數；池化層功能是為了減少影像維度，減少資訊量並簡化問題處理，亦可減少不易收斂的現象，使特徵達到最佳的活化效果。不同池化層對不同的資料集也有著不一樣的影響，因此如何設計池化層也值得探究，全連接層則如同傳統之神經網路推估。

林美伶(2016)使用卷積神經網路進行人臉辨識，其卷積神經網路組成為一層輸入層、多層的卷積層、池化層及全連接層和一層輸出層。

對於超大尺度又複雜的影像之處理，Simonyan(2015)認為，以16-19層之卷積層，以小尺度(3x3)卷積核與較小的移動步幅，加上五次池化效果，最後有三層全連接之神經網路深度學習，輸出層利用ReLU(Krizhevsky et al., 2012)所推得之權重，對複雜影像的處理有較準確的結果。

### 3.3 參數設定

卷積神經網路的組成因子皆需要參數的設定，主要包括卷積核、層數、維度、參數總數；焦點在於卷積核中的權重值，係定義影像特徵之關鍵(胡依淳, 2018)。卷積層中的設定，卷積核大小、激活函數和卷積使用濾波器Filter數量，前面三項作不同的設定，對結果會有一定程度的影響，周柏宇(2017)指出最常使用的池化層參數，Kernel Size與跨步都為2的最大池化，這種方法可以減少75%的資料量。王哲秋(2010)提出當擷取的特徵有顯著差異時，資料會有最佳的配適，可以使用主成份分析方法來檢視特徵之差異。對於模式的績效測試，Murugan(2017)將灰階圖像作為輸入信息圖像，使用ReLU和Sigmoid激活函數，並使用交叉熵損失函數來計算預測值和實際值之間的差異。

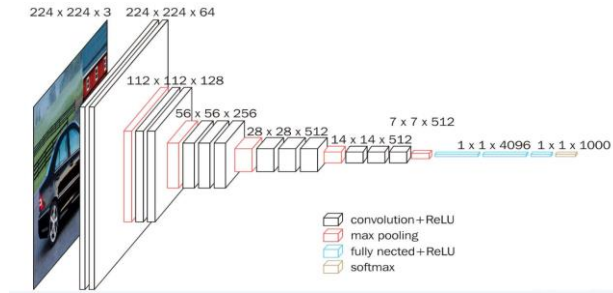
### 3.4 遷移學習

交通路況的影像資料，受限於多變的外在環境，帶標記的訓練樣本與一般優秀模型之影像存在很大的差異。

網路式的深度遷移學習(Deep Transfer Learning)，雖然多數應用並不影響模型準確性，但會影響可傳遞性，Tan(2018)提到在深度遷移學習的應用上，LeNet，AlexNet，VGG，Inception，ResNet模型對於傳遞性上的影響較低，皆是網路深度遷移學習的良好選擇，其中Simonyan(2015)發展的VGG16的架構易懂、操作容易上手，如圖4。

所謂的深度遷移學習，即是將之前已經學習過的預模型繼承到其他領域的預訓練模型上。實際上，透過擴展之前預訓練的複雜深度網絡，替換最後第二層對圖像的輸出特徵轉為新的訓練輸入，再訓練一個迷你的淺層網絡應用在其他領域。省去重新從頭訓練所需要的工作，以達成降低訓練時特徵提取時間與淺層網絡訓練時間，避免訓練資料太少造成的過度適配情形，如

圖5。



資料來源：Simonyan(2015)

圖 4 VGG16 架構




圖 5 VGG16 模型訓練方式

VGG16使用之卷積核專注於擴大通道數、池化專注於縮小圖像的寬和高，使得模型架構上涵蓋影像更深、更寬的特徵，並能控制計算量增加的規模，使模式不會因為計算量的爆增，而降低模式的預測效能與增加訓練的困難度。在網絡測試階段，將訓練階段的三個全連接層換成卷積層，因為沒有全連接的限制，因而可以接收任意寬或高為的輸入，即為無需對原圖做重新縮放處理。

在類別標籤方面，若存在兩個以上的值，如順暢=1、車多=2、擁擠=3，若影像標籤(Label)不是數字，且每一個特徵若有m個可能值，經過編碼後，就變成了m個二元特徵，如擁擠為(1, 0, 0)、車多為(0, 1, 0)，而順暢為(0, 0, 1)。並且，這些特徵互斥，每次只有一個激活。因此，數據會變成稀疏的。當辨識完成後，再轉換為原本的標籤。Softmax函數用以估計每一種分類結果出現的機率，輸出一個一維的向量(向量元素的和為1)，因此Softmax函數亦稱歸一化指數函數。

## 四、模式建構

### 4.1 模式架構

為比較以傳統交通參數分析之傳統倒傳遞神經網路，與以影像為輸入之卷積神經網路。首先，若將三種擁擠指標視為不同之輸出型態類別，則問題可以定位為型態辨識的特別問題，每一種型態皆有個別對應不同之輸出向量資料，而原來之輸出單元將以含三項變數之向量定義，

如圖6。




圖 6 模式架構

對於隱藏層之集成與轉換函數，本問題可以根據上圖設定集成函數，如下式(1)，轉換函數一般取非線性之雙彎曲 Sigmoid 函數，如(2)。

$$net_j = \sum_{i=1}^{i=3} w_{ij} x_i \quad (1)$$

$$h_j = \frac{1}{1 + e^{-net_j}} \quad (2)$$

對於隱藏層至輸出層之集成與轉換函數，可以設定集成函數，如式(3)，至於輸出層之轉換函數一般有多種選擇，可以取線性、非線性或其它特殊函數，若仍取前述之非線性函數，如式(4)，則輸出為界於[0, 1]間之數值。

$$net_k = \sum_{j=1}^{j=2} w_{jk} h_j \quad (3)$$

$$y_k = \frac{1}{1 + e^{-net_k}} \quad (4)$$

而類神經網路之目標函數，可以定義為求解各聯結之權重值，使得測試樣本之觀測結果與預測結果誤差平方和最小，如式(5)。

$$Min_{w_{ij}, w_{jk}} SSE = \frac{1}{2} \sum_k (y_k^{obs} - y_k(w_{jk}(h_j(w_{ij}))))^2 \quad (5)$$

其中，

- $x_i$ ：輸入資料項( $i=1,2,3$ ；代表輸入之流量、佔有率、車速)
- $y_k^{obs}$ ：輸出結果之觀測值(用路人回答之擁擠、車多、順暢之擁擠指標分級類別)
- $y_k$ ：輸出結果之預測值( $k=1,2,3$ ；代表輸出端模式預測之擁擠、車多、順暢之擁擠指標分級類別)
- $net_j$ ：第  $j$  個隱藏層之集成函數
- $h_j$ ：第  $j$  個隱藏層轉換激活函數。
- $SSE$ ：誤差平方和
- 決策變數；
- $w_{ij}$ ：輸入資料  $i$  項連接  $j$  隱藏層之權重變數
- $w_{jk}$ ：輸出資料  $k$  項連接  $j$  隱藏層之權重變數

在搜尋權重值部份，由於存在多個區域極小值，因此步幅不特定推估，採用最陡坡降法，學習率設為 100%。

## 4.2 分析工具



人工智慧在影像處理應用上發展迅速，市場上相關分析工具的選擇很多，端看個人的偏好與未來使用上的彈性與擴充性，各項框架之比較如表1。顯示Tensorflow為目前最廣泛使用的分析工具。

表 1 不同框架在 github 上之相關統計數據

框架	機構	支持語言	Star	Fork	Contributors
<b>Tensorflow</b>	Google	Python、C++、 java、GO等	41628	19339	568
<b>Caffe</b>	BVLC	C++/Python	14956	9282	221
<b>Keras</b>	fchollet	Python	10727	3575	322
<b>Theano</b>	U.Monteral	Python	5352	1868	271
<b>CNTK M</b>	Microsoft	C++	9063	2144	100
<b>Torch7</b>	Facebook	Lua	6111	1784	113
<b>Neon</b>	NervanaSys	Python	2633	573	52

Tensorflow具開源的深度學習框架，適用於機器學習和深度神經網路方面的研究，此系統也可廣泛用於其他計算領域，一旦輸入端的所有張量準備好，節點將被分配到各種計算設備，完成非同步並行地執行運算，易於圖像和影片識別，以及物體、地標活動的分類。

Tensorflow的環境搭建，需要Windows10作業系統，主體工具為Anaconda 4.8.3、Python 3.6、Tensorflow1.5。輔助工具為Numpy、Matplotlib、Pyplot、Keras、Pandas、Pillow、Protobuf、Scipy、Tensorboard。

函數庫集的應用，1.在Keras部份，基於Python高階深度學習的程式庫，已內建各式類神經網路層級，而其只處理模型的建立、訓練、預測等功能，至於深度學習底層的操作細節，則必須配合使用後端引擎(Tensorflow)進行演算。2.在Matplotlib部份，主要用於繪製2D圖形之套件，架構主要分三個部分，分別是Backend Layer為處理輸入資料，接下來Artist Layer處理數據排列方式及其位置，最後Scripting Layer輸出最後圖形。3.Numpy部份，為Python 語言的一個擴展程序庫，支持大量的維度數組與矩陣運算，在CNN 模型內利用NumPy來建立三層模組，分別為卷積層 (Conv)、ReLU啟用函式和最大池化 (Max pooling)。4.Pandas部份，為python的一個數據分析lib，提供高效能、簡易使用的資料格式，讓使用者可以快速操作及分析資料，而本研究主要使用DataFrame，用以處理結構化(Table like)的資料，並以此快速地進行資料的前處理，如資料補值，空值去除或取代等。5.Pillow部份，為Python的一個集合影像處理函數的專門套件，用作圖像幾何變換、圖像裁剪、圖像分離與合併、黏貼圖片、格式轉換等功能。6.Pip部份，為Python電腦程式語言寫成的軟體包管理系統，用以安裝和管理軟體包，本研究以此安裝TensorFlow pip 套件。7.Protobuf部份，又名Protocol Buffers，類似於XML能夠將結構化數據序列化，用於數據儲存。8.Scipy部份，在Numpy的基礎上，在主數據結構增加一個多維數組，有助於解決更多的數學計算的模組。

## 五、案例資料調查與分析討論

### 5.1 資料調查

為了解用路人對於道路的主觀擁擠感知，交通參數的數值資料來源主要是透過交通部國道高速公路局之開放交通資料庫，其中的路側車輛偵測器（Vehicle Detector，VD）資料有固定樁號位置資訊，擷取資料前，可以預先規劃研究範圍，實驗設計使用之探針車在路況影像錄影之外，同步彙整路段位置每分鐘各類交通參數（速度、佔有率、流量），資料如表2。

表 2 交通部高速公路局開放之偵測器即時交通參數

1	B	C	D	E	F	G	H	I	J	K	L	M
listname	updateTime	interval	vdid	status	datacollecttime	vsdDir	vsrid	speed	laneoccupy	carid	volume	
21755	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-E-2.660-M-Loop	0	2020/06/12 07:54:00	0	1	84	8 S	24	
21756	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-E-2.660-M-Loop	0	2020/06/12 07:54:00	0	1	84	8 T	0	
21757	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-E-2.660-M-Loop	0	2020/06/12 07:54:00	0	1	84	8 L	0	
21758	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-E-2.660-M-Loop	0	2020/06/12 07:54:00	0	2	91	8 S	16	
21759	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-E-2.660-M-Loop	0	2020/06/12 07:54:00	0	2	91	8 T	7	
21760	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-E-2.660-M-Loop	0	2020/06/12 07:54:00	0	2	91	8 L	0	
21761	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-E-2.660-M-Loop	0	2020/06/12 07:54:00	0	3	81	6 S	9	
21762	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-E-2.660-M-Loop	0	2020/06/12 07:54:00	0	3	81	6 T	7	
21763	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-E-2.660-M-Loop	0	2020/06/12 07:54:00	0	3	81	6 L	0	
22085	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-W-20.000-N-Loop	0	2020/06/12 07:54:00	0	1	105	8 S	13	
22086	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-W-20.000-N-Loop	0	2020/06/12 07:54:00	0	1	105	8 T	0	
22087	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-W-20.000-N-Loop	0	2020/06/12 07:54:00	0	1	105	8 L	0	
22088	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-W-20.000-N-Loop	0	2020/06/12 07:54:00	0	2	94	3 S	5	
22089	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-W-20.000-N-Loop	0	2020/06/12 07:54:00	0	2	94	3 T	0	
22090	VD一分鐘動態資訊	2020/06/12 07:55:00	60	nfbVD-N10-W-20.000-N-Loop	0	2020/06/12 07:54:00	0	2	94	3 L	0	

問卷設計的背景資料，除了影像之外，並結合了路側固定車輛偵測器所蒐集的即時交通參數，受測者可以根據其所看到影片中的實際路況，表達個人主觀的擁擠感受外，即時的交通參數亦可提供準確的全程資訊，以作為數值輸入與影像輸入之神經網路分析比較。

研究範圍主要以國道高速公路為範圍，選擇原因主要在於部份路段壅塞狀態具有平日尖離峰差異明顯，流量變化大，因此用路人會隨路況改變而有不同的擁擠感受，選擇國道3號南投交流道到南投服務區、國道3號三鶯交流道到鶯歌系統交流道、國道1號麻豆交流道到下營系統交流道、國道1號台中交流道到大雅交流道、汐五高架之下塔悠交流道到環北交流道，共計五個區段，示意如圖7，此外，高公局之擁擠指標具有全國一致性，利於進行後續研究分析。



圖 7 研究範圍示意圖

探針車係以浮動車輛法（Floating Car Method）進行路網道路實境拍攝，如圖8。於車內駕駛者視點位置裝設行車紀錄器，拍攝車外影像，同時在影片的變數上分為平假日與尖離峰，再

將各路段影片資料整理彙整成表格，並依各路段進行編號分組；另一方面，車上行車紀錄器亦有GPS，能提供每段道路之行駛車速與定位資料。

問卷資料係同步整合偵測器每分鐘記錄之實際路況資訊，比對拍攝影片之各項交通參數資訊，之後從影片資料庫進行路況影片選取，選取標準為各路段皆依三種不同擁擠情境，分別選取影片資料，再透過程式剪輯各段影片成每段1分鐘的問卷影片，並經過人工篩選後，最終影片數量共計為1600筆。每組影片透過路段與時間點對照高公局之開放交通資料庫中VD蒐集交通參數（車速、佔有率、流量），並匯集整理而成，如表3。



圖 8 浮車法錄影之實際路況資料畫面

表 3 影片資料彙整表

	A	B	C	D	E
1	影片編號	路段	佔有率	車速	流量
2	A0	中寮	8	97	74
3	A1	中寮	6	105	107
4	A2	中寮	3	97	75
5	A3	中寮	7	112	94
6	A4	中寮	7	123	92
7	A5	草屯	9	97	85
8	A6	草屯	9	98	99
9	A7	草屯	7	100	118
10	A8	草屯	8	97	84
11	A9	草屯	8	103	119
12	A10	霧峰	7	107	126
13	A11	霧峰	3	71	16
14	A12	霧峰	8	103	132
15	A13	霧峰	11	86	138
16	A14	霧峰	9	87	106
17	A15	霧峰	4	80	27
18	A16	霧峰	5	73	35
19	A17	霧峰	8	84	127
20	A18	霧峰	10	85	56

本研究採取網路問卷，調查採行分層抽樣方法，以男、女駕駛比例進行。總計發放400份問卷，每份問卷含4個路段，分別為平日尖峰時段、平日離峰時段、假日尖峰時段、假日離峰時段之路段影片，基本上，問卷作答的方式係給予各路段的連續影片，以填答的方式來進行，其目的在使受測者接收當時路況後，能作出較真實的擁擠感受反應。最後回收之樣本數為360份，回收率為90%，男性佔58%、女性佔42%，同時透過程式分割CNN所需的照片輸入檔。一半樣本用在CNN模型之訓練，另一半作驗證；筆數皆為720筆，label為擁擠指標的三種不同類別，擁擠、車多、順暢。用於測試的720筆，分類標籤用於預測結果之驗證。

## 5.2 前置設定

在操作Keras上，引入建立完成的VGG16網路架構，並進程式碼上的改寫，建立VGG16的遷移學習模型，在輸入的圖像上依VGG16支持的224\*224的圖像大小，調用keras API的trainable函數將參數設為false，目的在訓練的階段中不會改變原有的參數權重，完整的保留原本VGG16所有卷積與池化層的狀態，對於最後一層替換為針對擁擠指標設計的網路，透過keras Sequential進行多個網路層的線性建構，以model.add的指令添加一個Flatten層、兩個Dense層、一個Dropout層，Flatten層是為了將前面卷積與池化運算後的2D的特徵圖，進入全連接層時，進行轉化成1D的佈局處理，透過一層的全連接作特徵提取，利用ReLU激活函數特性達成收斂快速，並讓丟棄層阻止特徵檢測器的共同作用，主要防止過擬合的問題，最後在由一個全連接層的softmax函數進行分類輸出。

在學習過程的配置上，利用keras API的model.compile進行設定，優化器選擇adam演算法，是一種較優的隨機梯度下降法，效率介於一階與二階之間，且有計算效率高與內存需求少的特色，達到更好的適配，adam演算法的參數設定則是依照keras官方建議設定，模型訓練與測試的評估上採用常見的accuracy，而對於損失函數則是基於擁擠指標上為多分類課題，因此採用cross-entropy的方法，衡量不同策略下之消耗成本機率，最後採用分支的categorical cross entropy，為契合實際的應用課題，而經過多次的實際測驗後，訓練回合數於16次時表現最佳。

## 5.3 擁擠指標辨識模型效能

CNN 模型之準確率以及錯誤率可以由圖9與10來說明，學習越多回合其準確率就會隨之提升，而錯誤率也能逐漸下降，而從模型適配程度來看，訓練資料及驗證資料在圖10呈現了良好的模型該有的劃分曲線，並無出現Underfitting與Overfitting的狀況。

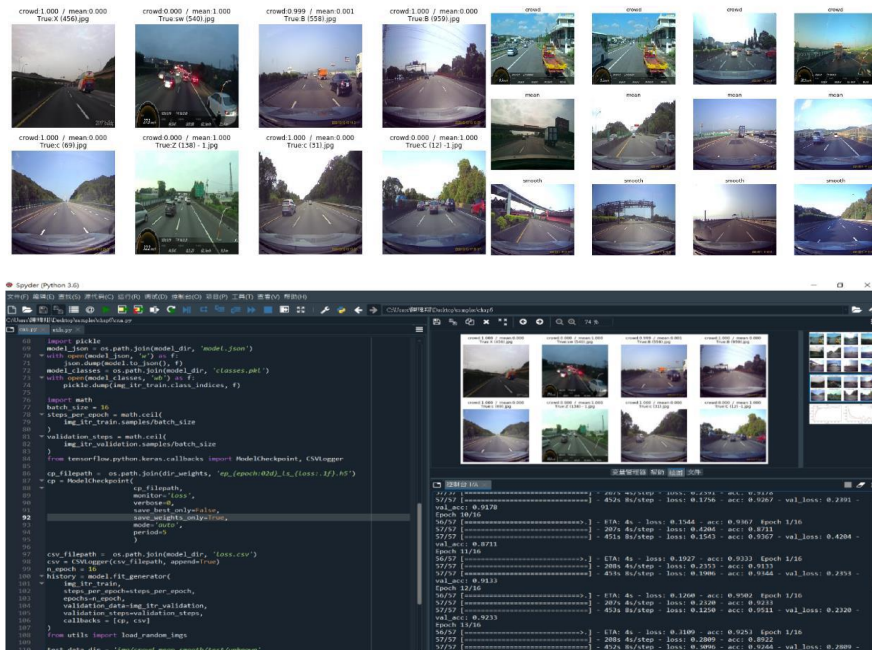


圖 9 VGG16 模型訓練過程結果




圖 10 VGG16 模型訓練結果

## 5.4 擁擠指標分類績效分析與討論

目前台灣各級交控中心對於道路擁擠指標之分級，主要仍以速度為主，多數是透過CCTV與偵測器所獲得之即時車流資訊、或輔以車道佔有率，再依固定之速率範圍標準進行分級。國道高速公路局之路段擁擠分為三個級距，平均車速小於40公里定義為擁擠、路段以紅色顯示，平均車速在40至79公里區間，定義為車多、路段以黃色呈現，車速大於80公里定義為順暢，路段以綠色顯示。

若以國道行控中心之擁擠定義標準來看，實際之720份測試樣本，僅433筆對路況感受符合高速公路局之三級制擁擠分類定義。然而路段是否壅塞，本就是用路人直接的感知，是以官方整體擁擠指標的準確率僅60.1%，用路人對於主管機關以速率分級之順暢狀態判斷較一致，正確率高達92%；用路人對壅塞之主觀感受與速率分群在車速為40至70公里之間的车多狀態，判斷落差最大，準確率僅15.5%，駕駛在主觀感受有很高的比例會偏向順暢，可能與車多之中間等級具有加減速率較大的現象，對於車速40公里以下的低速路段，正確率達56.9%，對走走停停之加減速率，仍有很多用路人對以速度分群，產生不一致的現象，如表4。

表 4 高速公路局擁擠分類績效

指標	順暢	車多	擁擠	合計
順暢	286(92.0%)	25(8.0%)	0(0.0%)	311
車多	173(83.6%)	32(15.5%)	2(0.9%)	207
擁擠	29(14.4%)	58(28.7%)	115(56.9%)	202
合計	488	115	117	720

比對類神經網路之訓練學習模式架構(劉士仙, 2011)，測試結果如表5所示。對於駕駛者的主觀擁擠程度(順暢、車多、擁擠)，判斷正確的次數，從之前的433次，提升至504次，總體結果之正確率達70%，較高公局之標準，提升9.9%。對於之前不易判讀之車多與擁擠狀態，大幅改善。車多狀態之擁擠感知，從之前15.5%的正確率上升至60.0%；擁擠狀態的正確率，更從56.9%提升至87.1%。在順暢部份，倒傳遞類神經網路對擁擠感知之預測，較之前下降，準確率僅為66.6%。

表 5 倒傳遞神經網路擁擠分類績效

指標	順暢	車多	擁擠	合計
順暢	204(66.6%)	93(29.9%)	14(3.5%)	311
車多	64(30.9%)	124(60.0%)	19(9.1%)	207
擁擠	0(0.0%)	26(12.9%)	176(87.1%)	202
合計	268	243	209	720

綜合而言，以視覺為感知基礎的用路人，反應路況擁擠等級現象，除了車流平均速率之外，仍有其他因素干擾，影響用路人對路段擁擠等級之感知。

當偵測器之交通數值參數，轉換成路況影像為輸入資料，只要影像特徵符合用路人之實際路況情境，擁擠等級之預測，準確度應該要接近用路人實際感受。

利用行車紀錄器影片之片段截圖，再進行卷積神經網路訓練學習，測試結果如前圖10所示。對於用路人的主觀擁擠感知程度（順暢、車多、擁擠），判斷結果如表6。總體判斷正確的次數，從高公局定義擁擠類別之433次，倒傳遞網路之504次，最後進步至597次；總體結果之正確率達82.9%，相較倒傳遞神經網路大幅提升12.9%。順暢部份預測的正確率分別為93.3%，三種方法裡準確度最高；擁擠中間級距之車多等級，卷積神經網路之正確率達60.4%，仍係最高；分類結果與倒傳遞網路預測相比，預測分佈在左側之順暢預測，錯判次數大幅下降，正確預測之中間分佈次數微幅上升，右側之擁擠狀態歸類預錯誤之測次數上升。簡言之，神經網路映射之對應預測分佈函數。最後，卷積神經網路對路況為擁擠之預測，正確率依然最高達91.6%。

在路況擁擠狀態的兩端，順暢與擁擠的部份，卷積神經網路的預測正確率皆高於九成，錯判的情形多發生於車多等級的感受，且判別為擁擠的數量略多於順暢。

從分佈型態來看，倒傳遞神經網路映射的預測結果，順暢部份有右偏的現象，而車多與擁擠部份又有左偏的現象，整體偏誤較大；卷積神經網路已修正擁擠指標偏誤之映射關係，順暢與擁擠的兩端已明顯修正，在車多之誤判部份，預測分佈的修正已近似常態，曲度微幅偏右，轉換之映射函數有大幅的改善。

表 6 卷積神經網路擁擠分類績效

指標	順暢	車多	擁擠	合計
順暢	287(92.3%)	51(7.7%)	0(0.0%)	311
車多	24(11.6%)	125(60.4%)	58(28.0%)	207
擁擠	0(0.0%)	17(8.4%)	185(91.6%)	202
合計	338	193	216	720

若將上述三種擁擠分類方法預測正確率結果以成對t檢定來兩兩比較，對角線值愈接近1愈好，非對角線值為0最優，可以整理成表7。對於路況擁擠指標等級之預測，三種方法存在顯著差異，以影像輸入之卷積神經網路(CNN)，在道路各種擁擠指標級別的預測上，都有絕對的優勢。傳統的倒傳遞網路(BPN)也較以速率為標準之擁擠分類較符合用路人的預期。

表 7 道路擁擠分類預測比較

比較項目	T_value	顯著差異
CNN vs BPN	7.97	成立
CNN vs 高公局分類	6.91	成立
BPN vs 高公局分類	11.36	成立

綜合而言，對於擁擠指標內容資訊與用路人感受，影像處理的卷積神經網路預測結果表現績效最好，總準確率已達82.9%，已具有實務應用參考價值。傳統倒傳遞網路之績效次之；單一速率來分級之實務作法較不理想。

卷積神經網路對擁擠指標關於車多類別之中間等級，預測結果的誤差，除了反應仍存在灰色區域難以辨識，個別感知的確存在很大差異之外，未來可以增加交通參數的推估，引入路段加減速變化，當可解釋影像與路段偵測器資料的盲點，目前無法觀測部份的誤差，將可能再改善。

## 六、結論與建議

### 6.1 結論

擁擠指標係目前國內外最常使用的一種即時路況資訊，多以速率區間表示，所呈現之程度資訊與用路人主觀擁擠感知存有差異；在資料調查方面，本研究結合了路側偵測器即時的交通參數資料蒐集，並配合GPS浮車之實況錄影，多方資訊整合之下，擷取適當影片並作為實體問卷之一部份，經由本研究廣泛的文獻評析，以影像處理的擁擠分類方法論進行課題之探討，最後得到下列重要結論。

1. 採用VGG16模型架構，對交通影像辨識，訓練回合數於16次時表現最佳。
2. 卷積神經網路、倒傳遞神經網路與速率區間分級方法，三者之預測績效存在顯著差異。
3. 影像處理的卷積神經網路預測結果，表現績效最好，總準確率已達82.9%，已具有實務應用參考價值。傳統倒傳遞網路之績效次之；單一速率來分級之實務作法較不理想。
4. 從預測結果之分佈型態來看，倒傳遞神經網路的預測有偏誤過大的現象，卷積神經網路在車多之誤判部份已修正，預測分佈已近似常態，曲度微幅偏右，轉換之映射函數有大幅的修正。

### 6.2 建議

1. 未來可嘗試納入額外之加減速率，以反應用路人對路段擁擠之感知，以提升分類方法的準確度。
2. 卷積神經網路在車多之誤判部份已大幅修正，近似常態分佈，然變異仍大，顯示轉換函數形式選擇部份，還可以再嘗試其它類型的可能。

## 參考文獻

- 王哲秋(2010)，*函數型主成份分析於曲線資料分類問題之應用*，淡江大學統計系碩士論文。
- 朱柏嘉(2020)，「AI+DATA 激盪智慧移動數位轉型新契機」，*ITS 研討會論文集*。
- 呂柏彥(2014)，*計算高速公路車流量之系統模擬*，東吳大學資訊管理系碩士論文。
- 林美伶(2016)，*以深度卷積神經網路做人臉辨識*，中央大學碩士論文。
- 周柏宇(2017)，*基於卷積神經網路之影像超解析*，義守大學碩士論文。
- 胡依淳(2018)，*深度卷積神經網路中卷積層之分析及比較*，暨南大學碩士論文。
- 梁志安(2008)，*不同長度隧道車流特性之比較分析-以國道5號為例*，交通大學碩士論文。
- 葉怡成編著(1997)，*類神經網路模式應用與實作*，儒林圖書有限公司。
- 劉士仙(2011)，「類神經網路於擁擠指標之研究」，*中華民國運輸學會第23屆論文研討會論文集*。
- 劉士仙、張勝雄、羅孝賢等(2006)，*智慧型交通資訊蒐集、處理、傳播與旅行者行為之系列研究(三)*，交通部科技顧問室委託計畫。
- 賴長偉(2007)，*用路人動態擁擠感知行為分析*，淡江大學碩士論文。
- 羅孝賢、劉士仙、張勝雄等(2007)，*智慧型交通資訊蒐集、處理、傳播與旅行者行為之系列研究(四)*，交通部科技顧問室委託計畫。
- Hensman, P. (2015), *The Impact of Imbalanced Training Data for Convolutional Neural Networks*, Thesis of Department of Computer Science, Royal Institute of Technology.
- Hirose, Y., Yam, A. K., Hijiya, S. (1991), "Back-propagation Algorithm which Varies the Number of Hidden Unit," *Neural Networks*, Vol. 4, pp.61-66.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012), "ImageNet Classification with Deep Convolutional Neural Networks." *In NIPS*, pp. 1106-1114.
- LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998), "Gradient-Based Learning Applied to Document Recognition," *Proc. of IEEE*.
- Liu, S. and Yang, C. (2007), "Analysis of subjective congestion index and its transferability," *Proc.*



*of 14th World Congress on ITS, Beijing.*

Liu, S. and Yang, C. (2007), “Design Experiments of Detector Density Layout on Travel Information of Arterials,” *Proc. of 14th World Congress on ITS, Beijing.*

Murugan, P.(2017). *Feed Forward and Backward Run in Deep Convolution*, Thesis of School of Mechanical and Aerospace Engineering, Nanyang Technological Univeristy, Singapore 639815

Simonyan, K., and Zisserman, A.(2015), “Very Deep Convolutional Networks for Large-Scale Image Recognition, Computer Vision and Pattern Recognition,” *Proc. of ICLR.*

Tan,C., Sun, F., Kong, T., Zhang, W. (2018), “A Survey on Deep Transfer Learning,” *Proc. of the 27th International Conference on Artificial Neural Networks.*

Werbos, J. P.(1974), *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*, PhD thesis, Harvard University