

NCDR 109-T07

以機器學習方法與社群媒體訊息應用於
災害情資空間定位分析

Location Reference Identification during Natural
Disasters using Social Media and Machine Learning



行政法人

國家災害防救科技中心

National Science and Technology Center
for Disaster Reduction

國家災害防救科技中心

中華民國 110 年 01 月

NCDR 109-T07

以機器學習方法與社群媒體訊息應用於 災害情資空間定位分析

Location Reference Identification during Natural
Disasters using Social Media and Machine Learning

張智昌、劉致灝



國家災害防救科技中心
中華民國 110 年 01 月

中文摘要

本研究利用神經網路模型判斷災害訊息中是否包含相關地點的資訊，以利於實際災害發生時，可快速地找到災害發生相關地點之訊息，並過濾掉假新聞與假訊息，節省大量比對的人力與時間。本研究使用資料是以社群媒體文字訊息與災情照片來進行空間定位分析，因此除了透過民眾打卡的資訊可利用訊息中的文字提取地理空間詞彙如地名、地標等進行定位，本研究亦利用影像辨識技術，對民眾上傳的影像進行分析，提供影像所在位置的資訊，相關定位結果可提供與文字訊息定位結果的交叉比對，提升災情訊息的可信度以及災害位置的準確度，並輔助災害應變的決策支援。

關鍵字：社群媒體、機器學習、空間資訊

ABSTRACT

Natural disasters are often unpredictable, in that they may occur anytime. Such disasters can cause significant damage to infrastructure and have an adverse effect on human life. Therefore, instant messaging is critical for sending out early warnings during and after a natural disaster. However, in the past, when a major natural disaster occurred, the government would often be burdened by excess information and thus unable to effectively transmit warnings and deal with a disaster in real time. This study presents several contributions to the future analysis of large volumes of disaster information taken from social media during emergency operations. For any social media comment, the relevant location can be identified.

Keywords: Social Media, Machine Learning, Location Reference

目錄

第一章 前言.....	7
第二章 相關研究	12
2.1 社群媒體與災害防救	12
2.2 文字自動辨識與定位	13
2.3 影像自動辨識與定位	17
第三章 研究方法	21
3.1 資料收集與標記	21
3.2 文字訊息資料前處理	24
3.2.1 文本分詞及數字序列	25
3.2.2 序列的 Zero padding 及 One-hot Encoding	26
3.2.3 詞嵌入(Word Embedding)	28
3.3 長短期記憶(Long Short-Term Memory).....	28
3.3.1 標註地名與檢視定位	32
3.3.2 標記(Label)在輸出層的表示	33
3.3.3 損失函數(Loss Function)與優化器(Optimizer)	34
3.4 卷積神經網路	34
3.5 定位方法	38

3.5.1	文字定位	38
3.5.2	影像定位	39
第四章	文字訊息實驗	40
4.1	評量指標	40
4.2	資料量與詞彙量對預測結果之比較	44
4.3	比較不同社群平台之有效留言	46
4.4	社群媒體之災害留言分析	52
第五章	影像特徵辨識實驗	61
5.1	Vision API	62
5.2	AutoML Vision	66
5.3	自行開發程式之結果及驗證	76
5.4	綜合評估	82
第六章	結論與未來展望	84

圖目錄

圖 1 近六年相關災害地點現地相片與相關災害訊息蒐集結果	22
圖 2 20160926 梅姬颱風現地相片蒐集結果	22
圖 3 20190929 米塔颱風現地相片蒐集結果	22
圖 4 臺灣的颱風、豪雨、水災之相關災害文字訊息資料	23
圖 5 LSTM 架構圖	29
圖 6 LSTM 第一步驟之示意圖	30
圖 7 LSTM 第二步驟之示意圖	31
圖 8 LSTM 第三步驟之示意圖	31
圖 9 LSTM 第四步驟之示意圖	32
圖 10 卷積神經網路基本架構圖(Rawat & Wang, 2017)	35
圖 11 卷積層運算式意圖(擷取自 Towards Data Science 網頁)	37
圖 12 池化示意圖(Rewat & Wang, 2017)	38
圖 13 影像定位示意圖	39
圖 14 不同資料筆數對訓練資料量與詞彙量之比較	46
圖 15 不同網站之有效留言數比較	51
圖 16 2017 年臺灣豪雨資料之柏拉圖分析	53
圖 17 2018 年臺灣豪雨資料之柏拉圖分析	54

圖 18 2019 年臺灣豪雨資料之柏拉圖分析	54
圖 19 大安路降雨 600mm 的淹水潛勢圖（水利署，2016 年）	58
圖 20 大湖山莊街降雨 600mm 的淹水潛勢圖（水利署，2016 年）	59
圖 21 大同路降雨 600mm 的淹水潛勢圖（水利署，2016 年）	59
圖 22 Google Vision API 及 AutoML Vision 影像分析流程圖	62
圖 23 Cloud Vision API 的執行結果	64
圖 24 以 Cloud Vision API 進行 logos 的辨識結果	64
圖 25 Cloud Vision API 的各種執行結果	65
圖 26 以 JSON 格式顯示 Cloud Vision API 的辨識結果	65
圖 27 AutoML 的運作方式	66
圖 28 不同超商的商標及標籤	67
圖 29 上傳到 AutoML 的商標影像及標籤	68
圖 30 完成訓練的模型評估結果	69
圖 31 精確率與召回率曲線	69
圖 32 訓練結果之誤差矩陣	70
圖 33 影像內容預測結果(正確判釋).....	70
圖 34 影像內容預測結果(誤判).....	71
圖 35 AutoML Vision 的物件偵測功能	71

圖 36 不同的商標及所對應的標籤名稱	72
圖 37 手動標示商標位置並指定所對應的標籤名稱	73
圖 38 完成訓練的模型評估結果	74
圖 39 影像內容預測結果(物件成功偵測).....	75
圖 40 影像物件(7-Eleven 商標)無法偵測(漏判)	75
圖 41 各種機器學習框架於 GitHub 的活躍程度(來源：Google).....	77
圖 42 本研究所使採用的卷積神經網路(CNN)	77
圖 43 特徵偵測層的基本參數設定	79
圖 44 本研究所使採用的卷積神經網路(CNN)	79
圖 45 模型相關參數設定	80
圖 46 影像訓練樣本的收集與分群	80
圖 47 影像擴增成果	81
圖 48 模型訓練時之訓練集與驗證集準確度與損失值	81

表目錄

表 1 近六年相關災害時間表	21
表 2 以莫蘭蒂颱風為例的相關災害資訊進行人工標記	24
表 3 包含地名或地標的範例留言	24
表 4 混淆矩陣.....	42
表 5 LSTM 測試結果.....	43
表 6 不同訓練資料量時的準確率	45
表 7 不同詞彙量時的準確率	45
表 8 三組不同的災害資料來源之比較	50
表 9 三組不同的災害資料來源之預測比較	51
表 10 經濟部統計之臺灣縣市常發生之淹水排行	55
表 11 近三年之臺灣豪雨資料中縣市的出現次數	56
表 12 2017、2018、2019 年臺灣豪雨資料中路段的重複詞彙	58

第一章 前言

隨著資訊科技的蓬勃發展，網際網路被視為生活不可或缺的必需品，網路不僅打破了地域性的藩籬，更可以拉近人與人之間的距離。近年來，社群網站成為全球最受歡迎的網路媒介，使用者透過社群網站獲得大量的最新資訊或者與不同背景的網友相互討論、彼此腦力激盪產生多元的新觀點。社群網路是近年興起的熱門議題，也帶動了巨量資料的技術發展，網路使用者藉由資訊散佈、分享及回饋在社群網路傳遞資訊。於實務應用中，透過不同社群網站分析提供的數位足跡，掌握有關受眾喜好和特性的輿情數據，再與傳統客戶關係管理(customer Relationship Management, CRM)資料結合後，更能夠針對不同族群進行精準的分眾行銷，進而挖掘出潛在商機。或者是在災害發生期間，使用者藉由行動裝置將災情資訊傳遞到社群網站，然而透過社群網站傳遞、分享及回饋的機制，將社群災情資訊收集、分析與統整。

地震、颱風、暴雨等在現今為常見的自然災害，這些災害事件常在不可預測的時期發生，造成人類生活和基礎設施的重大影響，因此，即時訊息對於自然災害事件發生期間和之後的預警就變得至關重要。隨著資訊科技的蓬勃發展，網際網路被視為生活不可或缺的必需品，

網路不僅打破了地域性的藩籬，更可以拉近人與人之間的距離。同時也帶動了巨量資料的技術發展，可以藉由資訊散佈、分享及回饋在社群網路傳遞資訊。

在自然災害的防範上，過去 Subasinghe, Nittel, Cressey, Landon, and Bajracharya (2020)曾研究來自受災害影響的市民發出的訊息是否足以生成自然災害圖的問題，構建了市民災難反應多智能體模擬 (CDR-MAS)，其為一種多智能體系統，可以模擬市民對自然災害發生在城市的反應，研究結果指出市民更新流可以在智慧城市中提供即時的訊息。近年來，社群網站成為全球最受歡迎的網路媒介，經由社群網站獲得大量的最新資訊或者與不同背景的網友相互討論、彼此腦力激盪產生多元的新觀點。透過資料探勘(Data Mining) (Barbier & Liu, 2011)與文字探勘(Text Mining) (Salloum, Al-Emran, Shaalan, & Systems, 2017)等技術應用，也可以從 Facebook、LINE、Instagram 等社群媒體上挖掘有用的資訊。災害防治方面，使用者藉由行動裝置將災情資訊傳遞到社群網路，並透過社群網站傳遞、分享及回饋的機制，將社群災情資訊收集、分析與統整，讓使用者能即時獲取相關的自然災害訊息 (Farinosi & Treré, 2010; Starbird & Palen, 2011; Sutton, Palen, & Shklovski, 2008)。社群媒體在災害管理 (Moe, Pathranarakul, & Journal,

2006)中扮演重要的角色， Middleton, Middleton, and Modafferi (2013)提到災害防救必須快速收集統整來自不同社群網路的災害資訊，建立社群資料中心，再透過資料技術分析，擷取出相關的災害資訊，並且進行地理位置資訊轉換。針對社群媒體是否可以協助災難防治和損失評估的問題，Kryvasheyev et al. (2016)對珊迪颶風前後的 Twitter 推文進行了多重尺度分析，研究美國 50 個大都市地區的線上回應，發現珊迪路徑的接近程度與颶風相關的社群媒體活動之間有著密切的關係，研究結果指出社群網絡可以對於大規模的災害事件進行快速評估。另一方面，災時或災後復原時，民眾亦可透過社群網路尋求協助、聯繫朋友家人，分享文字、影音圖片等即時資訊以獲得食物、收容所、物資供給、以及交通狀態等的協助。目前國家災害防救科技中心已針對災害期間社群資料進行收集，來源有臉書(Facebook)、批踢踢(PTT)等，收集的資料包含文字訊息內容以及使用者上傳的相片等資料，政府內部已逐步建立資料整合的工作，並藉由資料加值與整合來輔助災害應變中心面對各種天然災害。

大數據當道的時代，在網路上「海量級」的資料中，蘊藏可觀、極具潛力的「礦產」，也就是有價值的資訊，透過資料探勘(data Mining)與文字探勘(text Mining)等技術應用，可以從大量的資料中挖掘出有

用的資訊。在我們生活當中，除了具有結構性的資料之外，也有大量的文字資料。現代人依賴社群媒體，每天人們都在 Facebook、LINE、Instagram 上所發表近況，或者在個人部落格上更新文章，也有與多鄉民在 PTT 上發表個人意見，每日不斷的產出，隨著轉發、分享，這些自然語言文字型的資料，不斷累積成龐大的數據。這些文字資料長短不一、沒有規律，卻也隱含重要資訊，透過文字探勘的技術應用，即可從這些看似毫無意義的試著利用一些方式或是統計而把它變成資源。而從災害防救科技的發展來看，民眾可透過行動裝置，以文字描述、照片或影片的方式將災害資訊散布至社群網路上，這些較即時性的災害資訊有助於災情的掌握與資訊驗證。

社群網路於災害防救的應用，必須快速收集統整來自不同社群網路的災害資訊，建立社群資料中心，再透過資料技術分析，擷取出相關的災害資訊，並且進行地理位置資訊轉換。本研究擬導入社群網路上所散播的災害訊息資訊，利用社群媒體中，民眾所上傳的文字敘述進行災情的研判，並制定文字資料分析流程，以利未來於實際災害發生時，可利用社群網路上的即時災害文字資訊進行災害的初步位置定位，以輔助災害應變的決策支援。然而目前網路上也流傳著許多假新聞與假訊息，因此除了透過民眾打卡的資訊、訊息中提到的地理詞彙

如地名、地標等進行定位，提升災情訊息的可信度以及災害位置的準確度。

但過去發生重大天然災害時，政府常會陷入資訊超載而無法即時有效傳遞並處理災情，且資料數量龐大，為方便未來於應變作業中能即時分析社群網站內大量出現的災情資訊，對於災害的應變有所幫助，本研究針對社群媒體文字訊息空間定位分析進行研究，導入社群網路上所散播的災害訊息資訊，利用社群媒體中，民眾所上傳的文字敘述進行災情的研判，並制定文字資料分析流程，以利未來於實際災害發生時，可利用社群網路上的即時災害文字資訊進行災害的初步位置定位，以輔助災害應變的決策支援。然而目前網路上也流傳著許多假新聞與假訊息，因此除了透過民眾打卡的資訊、訊息中提到的地理詞彙如地名、地標等進行定位，提升災情訊息的可信度以及災害位置的準確度，因此本研究嘗試導入以人工智慧的方式，針對具有空間資訊的影像與文字訊息進行分析，進一步進行位置的定位，除對於初期災情的彙整能更全面且快速外，對於訊息的真偽，也可透過相關訊息的綜整與比對進行過濾篩選，供災情綜整人員作為判斷參考。

第二章 相關研究

2.1 社群媒體與災害防救

隨著網路的普及以及行動裝置使用率的增加，社群網路已經成為一種新興的資訊傳遞管道，並成為熱門的社群媒體，在社群媒體的環境下，各種類型的資訊在網路上不斷的被分享，其資訊量龐大且快速被產生。這些數據特性符合大數據(Big Data)的 3V 資料特性(Lu, Zhu, Liu, Liu, & Shao, 2014)，並可協助決策者做出適當的決策(Felt & Society, 2016)，近年來，社交媒體網絡儼然成為目前大眾分享觀察結果的主要平台，主要是因為社群媒體的好處可以即時與潛在的關注者共同分享各自發布的訊息(Brynielsson et al., 2018; Goodchild & Glennon, 2010; Mills, Chen, Lee, Raghav Rao, & Security, 2009)。

在災害應變的演進過程中，對於第一手災害訊息的即時掌握逐漸成為重要的資訊之一，而即時的社群互動資料成為提供緊急災難防治與搶救的分析基礎。最近，很多工作也利用這些媒體數據來支持各種與災難相關的分析和管理，例如災難事件的檢測和追蹤(Sakaki, Okazaki, & Matsuo, 2010)；救災相關(S. Kumar, Barbier, Abbasi, & Liu, 2011)和災害評估(Cervone et al., 2016)。過去有人嘗試針對 Twitter 的社交媒體訊息主題，進行了一些嘗試。將自然災害期間發布的推文分

為幾類，包括警告、建議、人員傷亡和損壞。透過在災難管理的各個階段將社交媒體訊息編碼為不同類別，收集包括在災難事件發生之前或之後發布的有用訊息(Xiao, Huang, & Wu, 2015)；透過 Twitter 推文對於北美同時發生的兩起緊急事件進行分析，增加人們在緊急事件發生前的相關預警(Vieweg, Hughes, Starbird, & Palen, 2010)；Imran, Elbassuoni, Castillo, Diaz, and Meier (2013)利用機器學習方法自動地萃取 Twitter 中與災害有關的訊息，並針對類似災害訊息進行相對應的措施。除了透過 Twitter 的社交媒體訊息主題，Yin et al. (2015)也在其他社群文字訊息蒐集熱門的社群網路資訊，並利用關鍵字詞的方式先取得災害訊息相關的災害訊息集合，取得災害訊息集合後，再依災害訊息本身的資料元素：災害時間、地點、災害描述以及現場照片來擷取災害訊息。

2.2 文字自動辨識與定位

文字探勘 (Text Mining, TM) 為處理非結構化的文字資料，透過各種量化技巧，藉由量化後的特性找出文件間的相關性，找出隱藏在其中有趣或有用的訊息。Tan, Steinbach, and Kumar (2006)認為文字探勘是一個多學科領域，涉及資訊檢索、文本分析、資訊提取、聚類、分類、可視化、資料庫技術、機器學習和資料探勘。文字探勘也是從非結構化資料源中提取知識的半自動化過程(Struhl, 2015)，旨在透過

提取訊息，提取事實，發現隱含連接以及產生與用戶需求相關的假設理解大量文本(Spasic, Ananiadou, McNaught, & Kumar, 2005)。因為文字探勘從文本中提取有用訊息，所以它也稱為文字資料探勘或「從文本資料庫中發現知識」(Gaikwad, Chaugule, & Patil, 2014)。Fayyad, Piatetsky-Shapiro, and Smyth (1996)認為文字資料探勘通常包括五個步驟：資料選擇、資料清理、資料轉換、資料探勘、結果評估和解釋。文字探勘整合了許多傳統資訊檢索技術，包括關鍵字萃取(Bafna, Pramod, & Vaidya, 2016)、文件自動分類(Adeva, Atxa, Carrillo, & Zengotitabengoa, 2014)、自動摘要(FU & CHEN, 2005)等等，以提供對文字處理更強大的功能。

近年來隨著 Twitter、Facebook、Instagram 等大量社群網站的崛起，因此有越來越多的研究應用主題偵測與追蹤技術於社群網站中(Ritter, Etzioni, & Clark, 2012)，研究主要包含分群方法、關鍵字萃取、機率分佈的主題模型。在分群中大多使用 K-Means 分群以及階層式分群的技術，將接收到的重要資訊進行分群，用來辨識性質相近的主題，Wartena and Brussee (2008)將維基百科(Wikipedia)的文章進行主題偵測，透過使用 Jensen-Shannon divergence 的方法來計算文章間的相似程度，在透過 Bisecting K-means Clustering 方法將剛計算出的文章

間距離進行主題分群；關鍵字萃取則是以詞頻與逆向文件頻率(Term Frequency-Inverse Document Frequency, TF-IDF)為基礎，提取關鍵字並進行分群，或使用關連分析找出其中相關性，作為主題偵測依據，Bafna et al. (2016)利用 TF-IDF 和模糊 K-Means 進行聚類分析，在不同主題的研究論文上進行了實驗，並針對不同研究主題進行分類；機率分佈的主題模型是目前最常被使用的方法，透過模型的設計，進行主題、文章以及字詞之間機率分佈與抽樣的學習，了解社群媒體中出現了哪些主題，以及每篇文章中不同主題出現的機率大小，He, Chang, Lim, Banerjee, and Intelligence (2010)提出了一個簡單有效的機率判別模型 (Discriminative Probabilistic Model, DPM)，並針對文章主題進行分類。

深度學習技術被用於常見的文字挖掘任務，例如情感分析 (Severyn & Moschitti, 2015)、文字分類(Liu, Qiu, Chen, Wu, & Huang, 2015)、文字生成(Graves, 2013)和社交事件檢測(Yubo, Liheng, Kang, Daojian, & Jun, 2015)。在眾多深度學習方法中，卷積神經網路 (Convolutional Neural Networks, CNN)為最受矚目，也已經被廣泛使用的一個方法(LeCun, Bengio, & Hinton, 2015)。Zhang, Zhao, and LeCun (2015)將深度學習應用到文字並使用卷積神經網路進行了實驗，其中

包括本體分類、情緒和文字分類。並使用大規模數據集將 CNN 應用於文字，並且實驗結果表明，分析深層的 CNN 能夠對單詞進行分類，不需要單詞、片語、句子以及任何其他關於人類語言的句法或語義結構的知識，也無需了解字詞或語言的句法和語義結構。

針對自然語言處理(Natural Language Processing)和機器學習(Machine Learning)的應用，過去從簡短文字訊息學習分類的問題，到有些研究是利用與比較各種機器學習的演算法 (像是 Naive Bayes、SVM、Logistic Regression 和 Decision Trees)，來解決識別簡短訊息的垃圾訊息問題 (Cormack, Gómez Hidalgo, & Sánz, 2007)，或是針對線上問題的對話內容 (例如：Yahoo Answers 或 Google Answers) 進行分類比對(Gupta & Ratinov, 2008)。另有研究者則是利用部落格的文本內容，自動抽取關鍵字和階層式分類改善文章註解的方式(Brooks & Montanez, 2006)，或是透過對醫療方面的文字訊息分類，協助非洲偏遠地區的醫療問題(Munro & Manning, 2010)。在災害防治的應用方面，Nguyen, Joty, Imran, Sajjad, and Mitra (2016)在社交媒體數據集上將深度學習方法應用於災難響應領域、以及使用 CNN 模型分別識別洪水事件和地震事件的相關推文。Aipe, Mukuntha, Ekbal, and Kurohashi (2018)利用 CNN 模型從推文中提取語言特徵，透過這些特

徵將推文分為不同的訊息類別以進行危機管理。Neppalli, Caragea, and Caragea (2018)使用基於卷積神經網絡和遞迴神經網路 (Recurrent Neural Network, RNN) 的模型，識別災害期間發布的訊息性推文。

本研究使用長短期記憶 (Long short-term memory)當作主要的神經網路模型，以社群網站收集新聞以及社群言論為分析對象，進行文字的空間定位分析方法研發，包括災害地點現地媒體資料與相關災害訊息蒐集及彙整、資料的前處理、神經網路訓練與測試、標記相關災害地名與地標，最後檢視定位的結果。

2.3 影像自動辨識與定位

影像辨識(image recognition)的主要目的是以電腦自動根據影像灰值的分布及變化進行感興趣物件的判識(object identification)，其應用包含影像分類(image classification)、人臉判識(facial recognition)、移動偵測(motion detection)等。在現今非常熱門的先進駕駛輔助(advanced driver assistance)相關研究中，影像自動辨識亦扮演相當重要的角色，如自動駕駛(self-driving)、車道偵測(lane detection)、行人偵測(pedestrian detection)、及自動停車(autonomous parking)等皆依賴影像自動判識來完成(Wang & Ren, 2011; Berger, 2014)。

近幾年來隨著訊號及影像處理技術的發展，影像自動辨識的能力

也越來越強，從傳統需以人工知識進行輔助的半自動辨識，到當今則已經發展出以機器學習(machine learning)技術進行全自動的影像辨識。機器學習是人工智慧(artificial intelligence, AI)的一個分支，其主要模仿人類從經驗中學習(learn from experience)的自然學習(natural learning)方式；不同的是，機器學習是以電腦計算的方式直接從資料中學習(learn directly from the data)，且不需依賴任何預先建立的模式(Sarkar et al., 2018)。通常用來學習的樣本越多，機器學習演算法的效能會越好。常見的機器學習演算法有人工神經網路(artificial neural networks)、貝式分類器(Bayesian classifiers)、決策樹(decision tree)、隨機森林(random forests)、支持向量機(support vector machines)、群聚(clustering)、稀疏表示(sparse representation)、基因演算法(genetic algorithm)等(Kubat, 2015; Sarkar et al., 2018)。

人工神經網路是機器學習中的一個重要演算法，其發展主要來自生物神經系統(biological nervous systems)的啟發。一般的神經網路架構係由許多非線性處理層(nonlinear processing layers)組合在一起，並可以平行的方式處理每一個層中的簡單單元(simple elements)，一般稱為神經元(neurons)。神經網路藉由神經元之間的相互連結，藉由感知外部資訊的變化而調整網路內部參數，因此屬於一種自適應的計算模

型。深度學習(deep learning)則是傳統神經網路的重要延伸，也被歸類為是機器學習中的一種方法，其利用神經網路的深層架構直接從大數據中學習資料內部的複雜結構。深度學習利用多個處理層(multiple processing layers)所組成的計算模型來學習具有多種抽象級別的資料表徵(data representations)(LeCun et al., 2015)，因此具有比淺層神經網路更強大的學習能力。

在眾多深度學習方法中，卷積神經網路(convolutional neural networks, 簡稱 ConvNet 或 CNNs)可以說是最受矚目，也已被廣泛使用的一個方法(LeCun et al., 1990; LeCun et al., 2015)。在神經網路的研究歷程中，ConvNets 技術並非是一種嶄新的概念，早在 1980 年代，已有許多研究提出 ConvNets 的架構及相關應用，但因為 ConvNets 通常需要大量的訓練資料，以及較長的計算時間，故相關研究工作及應用較為缺乏。一直到 2000 年代中期，因為電腦硬體的進步（尤其是 GPU 的發展）、資料大量的累積（即大數據）、以及許多改進過的演算法，才使得 CNNs 成為目前神經網路技術中最熱門的技術之一(Rawat & Wang, 2017)，且成功地應用在影像辨識中。例如由 Krizhevsky 等人(2012)基於 CNNs 所發展的 AlexNet 架構獲得了 2012 年 ILSVRC(ImageNet Large-Scale Visual Recognition Challenge)競賽的首

獎，而同樣以 CNNs 為基礎的 GoogleNet 則是 2014 年 ILSVRC 的贏家。在其他研究及實際應用方面，Sermanet 等人(2013)以 CNNs 為基礎，提出一個非監督式的卷積稀疏編碼方法(convolutional sparse coding)，以多層特徵學習(multi-stage feature learning)方式有效偵測路上的行人。在人臉的偵測及定位上，以 CNNs 為基礎的相關研究亦有許多不錯的成果(Garcia & Delakis, 2004; Sun et al., 2014; Zhang et al., 2016)。在衛星遙測影像(remote sensing images)的應用上，Cheng 等人(2016)提出一個具旋轉不變性的 CNN 模型(RICNN)，克服了不同時期、不同角度衛星影像所造成物體偵測的問題。Long 等人 (2017) 則利用 CNNs 於高解析度衛星影像上進行油槽、飛機、交流道等物體的定位及偵測，獲得相當高準確性的成果。

基於上述 CNNs 於影像辨識上的發展及應用成效，本研究主要以 CNNs 為基本研究方法，評估其對災害地點現地照片進行影像辨識的可行性，並與本研究所蒐集的地標資料進行比對，以完成災害地點的定位。

第三章 研究方法

3.1 資料收集與標記

本研究彙整近六年（2014 年至 2019 年）相關災害事件之災情相片與災情訊息，資料範圍如表 1 所示，包含颱風、豪雨、地震等災害事件，其中以颱風事件居多。

表 1 近六年相關災害時間表

2019 年災害		2018 年災害		2017 年災害	
09/29	米塔颱風	09/14	山竹颱風	10/11	豪雨
08/23	白鹿颱風	09/09	熱帶低壓	09/12	泰利颱風
08/07	利奇馬颱風	08/23	熱帶低壓水災	09/06	谷超颱風
07/17	丹娜絲颱風	07/09	瑪莉亞颱風	08/21	天鴿颱風
05/20	豪雨	06/13	豪雨	07/28	尼莎暨海棠颱風
04/18	地震	02/06	地震	06/13	豪雨
				06/01	豪雨
2016 災害		2015 災害		2014 年災害	
09/26	梅姬颱風	09/27	杜鵑颱風	09/19	鳳凰颱風
09/16	馬勒卡颱風	08/06	蘇迪勒颱風	07/21	麥德姆颱風
09/13	莫蘭蒂颱風	07/09	昌鴻颱風	06/15	哈吉貝颱風
07/06	尼伯特颱風	07/06	蓮花颱風		
02/06	地震				

除了彙整上述各年度代表性災害之發生時間、地點與災損情形等資訊外，亦整理蒐集相關災害圖片，如圖 1 至圖 3 所示，以供後續

比對使用。

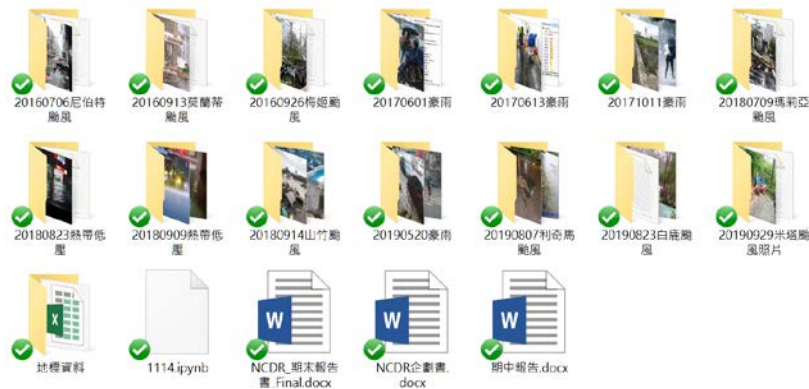


圖 1 近六年相關災害地點現地相片與相關災害訊息蒐集結果



圖 2 20160926 梅姬颱風現地相片蒐集結果

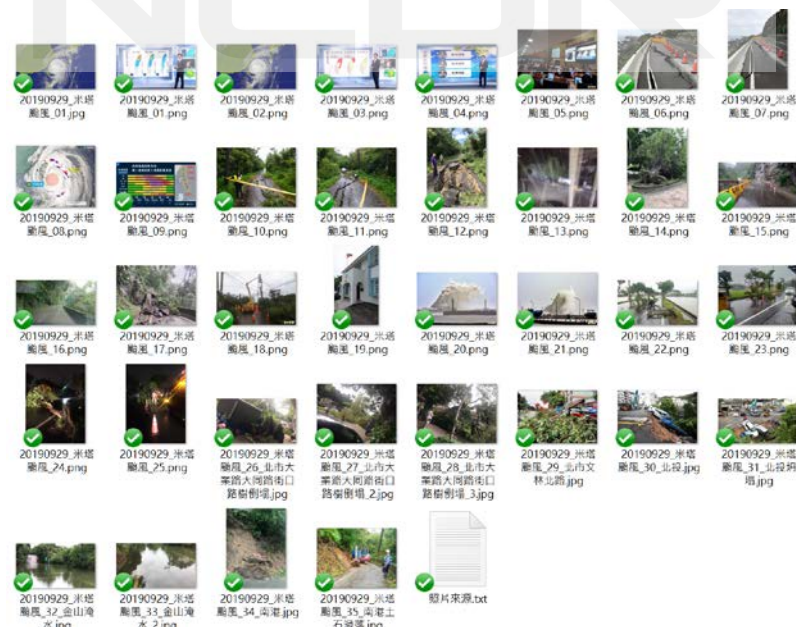


圖 3 20190929 米塔颱風現地相片蒐集結果

社群災害相關文字訊息，主要使用的資料為發生在臺灣的颱風、豪雨、水災之相關災害資料，資料來源包括 Facebook、Mobile01 論壇、PTT 電子佈告欄、ETtoday 新聞雲、蘋果日報即時新聞、中時電子報、工商時報、聯合新聞網、自由時報、伊莉討論區等相關文字訊息。主要的災害事件包括 2015 至 2019 年的颱風、豪雨以及水災資料，圖 4 為蒐集之臺灣的颱風、豪雨、水災之相關災害文字訊息資料。



圖 4 臺灣的颱風、豪雨、水災之相關災害文字訊息資料

原始資料包括了災害主題、留言標題、留言內容、留言來源、來源網站等等標題。本研究取用災害主題和留言內容的資料並作後續的資料分析，並同時進行人工標記的動作，主要的準則為人工判定此留

言內是否包含地名或地標，若 A 留言內有包含地名或地標，則將其人工標記為「有」，B 留言內無包含地名或地標，因此將此篇留言人工標記為「無」。本研究蒐集不同社群媒體災害事件之相關訊息，作為後續演算法的訓練與驗證使用，並以社群媒體的文字內容的關鍵詞彙進行文字的空間定位。表 2 為以莫蘭蒂颱風為例的相關災害資訊進行人工標記，表 3 為包含地名或地標的範例留言。

表 2 以莫蘭蒂颱風為例的相關災害資訊進行人工標記

災害留言	標記
莫蘭蒂颱風造成屏東縣佳冬鄉嚴重淹水，一度水淹及胸	有
莫蘭蒂颱風重創南台，橫掃澎湖及金門地區	有
接連的災難搞得大家人心惶惶	無

表 3 包含地名或地標的範例留言

留言	地名或地標
今年七月尼伯特颱風肆虐，台東森林公園受創嚴重	台東
莫蘭蒂颱風呼嘯而過，金門吹起破紀錄的 17 級強風	金門
中度颱風馬勒卡逼進臺灣，台北市昨天風雨漸強	臺灣、台北
颱風過後，四艘船舶擱淺在西子灣，開始漏油	西子灣
中央氣象局解除莫蘭蒂颱風警報，但是颱風尾威力仍然驚人	中央氣象局

3.2 文字訊息資料前處理

由於輸入的資料為相關災害文字訊息，為了要讓神經網路模型理解文字訊息代表的意義，無法將人類習慣的語言文字直接當成神經網

路的輸入，而是要轉換成數字才能讓神經網路模型完整地處理文字訊息。而在將文字訊息在輸入神經網路模型前，通常會將原始資料進行進一步的轉換，大致會分為四個步驟，文本分詞(Text Segmentation)、將文句轉成數字序列、序列的 Zero Padding、One-hot Encoding、Word Embedding，並將資料前處理完的資料輸入到神經網路進行訓練。

3.2.1 文本分詞及數字序列

文本分詞 (Text Segmentation) 為將一連串文字切割成多個有意義的單位的步驟。本研究使用 Jieba 來當成主要的文本分詞工具，Jieba 是以 Python 為基礎的開源中文分詞程式，每當使用神經網路模型進行文本分析研究，通常需要先將文本分詞到最小且有意義的單位來進行分析、整理。Jieba 的預設詞庫為簡體中文，因此在繁體中文的分詞結果較為差的，經常會將繁體中文的字句分詞成跟原本語意相差甚大的結果，本研究使用 Jieba 提供的切換詞庫功能，以及 Jieba 另外提供的繁體中文詞庫，利用切換詞庫的功能來改善分詞結果。在利用 Jieba 進行分詞時，常遇到文句中重要的詞彙因為不常見或者是專有名詞，導致分詞的結果無法得到原有的語意，像是人物角色名稱、特定地標、特殊名詞等等，因此為了解決此問題，本研究利用 Jieba 提供的自訂詞庫功能，事先增加詞彙到自訂詞庫中，並將自訂詞庫載入

Jieba，讓自訂的詞彙在分詞結果中能完整地分出來，避免重要的詞彙被斷開。

將一連串文字完整的切割成一個個有意義的詞彙 (Token) 以後，下一步就是將這些詞彙轉換成一個數字序列，方便後續的資料處理。首先需要建立一個原始資料集，查看所有分詞完的文句，每當出現一個資料集裡頭沒有的詞彙，就為該詞彙指定一個資料集中還沒出現的索引數字，並將該詞彙放入資料集中，利用建立的資料集，將每句分詞完的文句包含的詞彙轉換成數字。

3.2.2 序列的 Zero padding 及 One-hot Encoding

當詞彙全部轉換成數字序列，每筆數字會對應到資料集裡頭特定的詞彙 (Token)，但會發現每則留言的數字序列長度不盡相同。為了方便後續的神經網路模型處理，本研究設定特定的長度來讓所有序列的長度一致，利用 Keras 來協助進行 Zero padding 的工作，Keras 是以 Python 為基礎的開源神經網路庫，若有某序列長度超過設定長度的情況發生，超過此設定長度的序列尾巴會被刪除；而針對原本長度不足的序列，則會在詞彙前面補上 0。Zero padding 是指將 0 的嵌入向量填充到數字序列中。例如設定最大數字序列的長度為 10，因此每則留言的長度將變為長度為 10 的數字序列；長度為 7 的數字序列會

在前面補上 3 個 0；長度為 13 的數字序列則會將超過預設長度的部分刪除。Zero padding 的主要目的不是補上多少 0，而是要考慮最大詞彙數，因為每則留言的長度不盡相同，因此就有多則刪除、少則補 0 的法則來因應長度的差異性。

編碼 (Encoding) 在前處理上占了很大一部分，也是將分類變數轉換為更好預測的形式給神經網路模型的過程，將每則留言分詞完的詞彙轉換成數字序列後，還需將標記欄位進行文本到數字的轉換，目的即是讓計算機可以理解每筆數據的意義，編碼方式又分為 Label Encoding 和 One-hot Encoding，Label Encoding 有一個問題使得它通常不適用於分類數據，在於 Label Encoding 會讓分類數據具有順序關係，因此會有數字大小的差異，例如有三個水果類別：蘋果，西瓜和柳橙。使用 Label Encoding 將每組類別分配一個數字進行分類：蘋果 = 1，西瓜 = 2，柳橙 = 3，並讓分類數據具有順序關係，但是實際上類別資料並沒有順序大小之分。本研究利用 One-hot Encoding 進行文本到數字的轉換，利用 Keras 來協助進行 One-hot Encoding 的工作，將分類數據由 0、1 替代，當某一行資料存在該類別則顯示 1，反之則顯示 0。本研究總共有兩種分類數據，一是針對某留言內有包含地名或地標，將其標記為「有」，設定為 1；二是某留言內沒有包含地名或地

標，將其標記為「無」，設定為 0。

3.2.3 詞嵌入(Word Embedding)

要讓神經網路能夠處理數字序列，需要將序列表示成向量。A. Kumar and Singh (2019)使用 Word Embedding 將 Twitter 推文作為模型的輸入，Word Embedding 表示資料集中的詞彙在預先定義的固定維度中以實數向量表示，並對相似含義的詞彙創建相似的向量。Embedding Layer 是 Word Embedding 在文本分類上使用的神經網路層，並與整個神經網路進行學習，Embedding Layer 用於神經網路的前端，並使用反向傳播算法 (Backpropagation Algorithm) 讓神經網路自動學到一組適合當前自然語言處理任務的詞向量(Goldberg, 2017)。本研究利用 Word Embedding 將數字序列轉換成實數向量，利用 Keras 協助將長度 k 的任意數字序列，輸出為長度 k 相同的序列，而輸出序列中為 n 維的詞向量。假設預設固定維度為 $n=3$ ，使用 $k=1$ 第一筆的數字序列，經由 Keras 提供的 Embedding Layer 處理後，數字序列中的每組數字將被轉換成 3 維的詞向量，而同組數字則會對應到相同的詞向量，

3.3 長短期記憶(Long Short-Term Memory)

長短期記憶 (Long Short-Term Memory, LSTM) 的詳細描述以及

利用圖示的步驟教學皆是參照(Olah, 2015)。LSTM 是循環神經網絡 (Recurrent neural network, RNN) 的延伸。RNN 引進遞歸 (Recurrent) 的概念，利用內在迴圈以及細胞內的「記憶狀態」來處理序列資料，以及使用既有的記憶來理解當下遇到的問題，在處理自然語言處理 (Natural Language Processing, NLP) 的研究上，則是從過往知識或是文章的上下文來理解文意，但在長期記憶的表現上，即出現很大的缺點，RNN 無法處理和預測時間序列中間隔和延遲非常長的重要事件。本研究利用 LSTM 當作主要的神經網路模型，LSTM 的核心概念是透過閘門 (Gates) 來控制神經元在不同時間點的記憶狀態，透過閘門可以將長遠的記憶儲存下來，圖 5 為 LSTM 的架構。

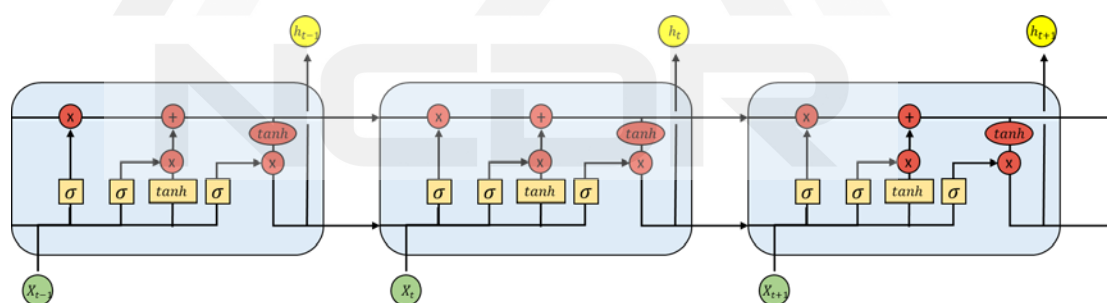


圖 5 LSTM 架構圖

LSTM 主要閘門總共分為三個，Forget Gate、Input Gate、Output Gate，以及一條表示神經元狀態的 Cell state，第一步驟為決定哪些資訊要從 Cell state 捨棄，此步驟主要透過 Forget Gate 來執行，根據 h_{t-1} 和 x_t 在 Cell state C_{t-1} 中利用 sigmoid function 輸出介於 0 和 1 之間

的數字。1 代表「完全保留此條件」，0 代表「完全捨去此條件」。其中 f_t 代表 Forget Gate； W 為權重向量； σ 為 sigmoid function； h_{t-1} 為前次各 Cell 輸出值組成之向量； x_t 為本次輸入層的輸入值組成之向量； b 為偏誤值。第一步驟可以用以下方程式(1)表示，圖 6 為第一步驟之示意圖：

$$f_t = \sigma \times (W_f \times [h_{t-1}, x_t] + b_f) \quad (1)$$

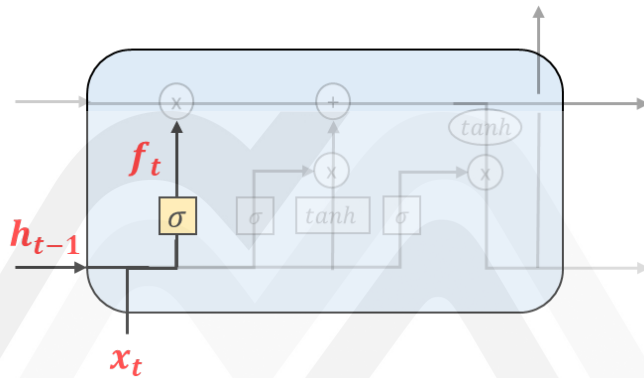


圖 6 LSTM 第一步驟之示意圖

第二步驟是確定在 Cell State 下要儲存哪些新訊息，包括 Input Gate 決定更新值，以及利用 tanh function 計算出向量 \tilde{C}_t 。其中 i_t 代表 Input Gate，第二步驟可以用以下方程式(1)、(2)表示，圖 7 為第二步驟之示意圖：

$$i_t = \sigma \times (W_i \times [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh \times (W_C \times [h_{t-1}, x_t] + b_C) \quad (3)$$




圖 7 LSTM 第二步驟之示意圖

第三步驟是將舊 Cell State C_{t-1} 更新為新 Cell State C_t ，捨去之前決定的資訊。加入新的候選值 $i_t \times \tilde{C}_t$ ，並根據需要更新的狀態值大小進行調整。第三步驟可以用以下方程式(3)表示，圖 8 為第三步驟之示意圖：

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (4)$$

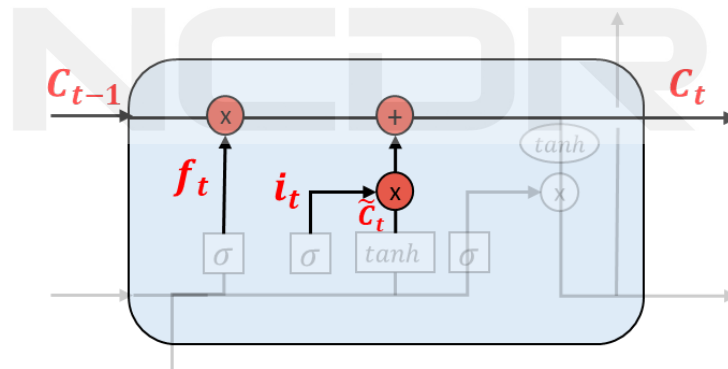


圖 8 LSTM 第三步驟之示意圖

第四步驟決定有多少資訊要輸出，利用 Output Gate 確定要輸出 Cell State 的哪些部分，並基於先前計算的 Cell State C_t ，通過 tanh function 後，將 Cell State 轉換至-1 和 1 之間之值，最後透過和 Output

Gate 的乘積得到輸出。其中 o_t 代表 Output Gate，可以用方程式(4)、(5)公式表示，圖 9 為第四步驟之示意圖：

$$o_t = \sigma \times (W_o \times [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \times \tanh(C_t) \quad (6)$$

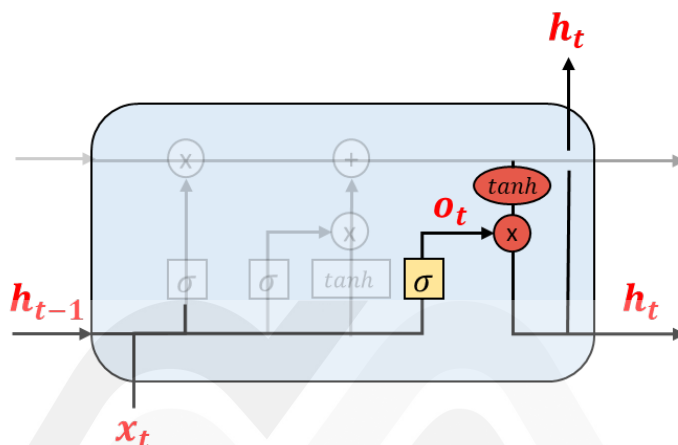


圖 9 LSTM 第四步驟之示意圖

3.3.1 標註地名與檢視定位

針對 LSTM 訓練完的模型進行測試，利用測試資料得知此模型的表現，同樣進行資料前處理並進行預測，若此留言內有包含地名或地標，模型將其標記為「有」，反之則標記為「無」。本研究將會針對標記為「有」的留言進行篩選，將標記為「有」的留言進行利用 Jieba 的詞性標記功能將詞性標記出來，Jieba 的詞性標記功能為基於簡體中文並透過隱藏式馬可夫模型 (Hidden Markov Model, HMM) 所訓練出來的成果，可以標記文本分詞後每組詞彙的詞性，目前採用的詞性標記方法主要有基於統計模型的標記方法、基於規則的標記方法、統

計方法與規則方法相結合的方法、基於有限狀態轉換機 (Finite-State Machine, FSM) 的標記方法和基於神經網絡的詞性標記方法。本研究採用的 Jieba 的詞性標記功能屬於採用基於統計模型的標記方法，詞性標記的資料來源採用北京大學計算的詞性標記集。將詞性標記出來後，根據屬於地名的詞性將地名新增在新的欄位，得到標記「有」的留言的每組地名，例如「臺灣是個美麗的地方」，因為臺灣屬於地名詞性，因此將其新增在新的欄位。

將留言的每組地名新增完後，本研究利用 Google Maps 提供的 Geocoding API 來檢視每組地名的定位，Geocoding 是將地址轉換為地理坐標的過程，並可以使用該地理坐標在地圖上放置標記或定位地圖。假設地址為臺灣大學即可透過 Geocoding API 將其轉換為緯度 25.0173405 和經度 121.5397518 的地理坐標。本研究利用 Geocoding API 執行大量地址，並得到多個地址的地理坐標，以避免一次只能在 Google Maps 中執行一個地址的問題。

3.3.2 標記(Label)在輸出層的表示

在 LSTM 神經網路模型最後的全連接層 (Dense) 使用 sigmoid function 來進行最後的結果分類，常用於二元分類，每組數值皆位於 0 到 1 之間，sigmoid function 可以用方程式(7)表示：

$$f(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

本研究總共有兩種分類數據，一是針對某留言內有包含地名或地標，將其標記為「有」，設定為 1；二是某留言內沒有包含地名或地標，將其標記為「無」，設定為 0。

3.3.3 損失函數(Loss Function)與優化器(Optimizer)

本研究使用二元交叉熵 (Binary Cross Entropy) 當成損失函數 (Loss Function)，損失函數用於計算輸出層的實際值和預測值之間的差距，透過損失函數的回饋，模型透過不斷地修正差距將訓練的損失降到最低。二元交叉熵可以用方程式(6)表示，其中 y_i 和 \hat{y}_i 分別代表實際值和預測值：

$$loss = - \sum_{i=1}^n y_i \log \hat{y}_i + (1 - y_i) \log (1 - \hat{y}_i) \quad (8)$$

比較不同的優化器(Optimizer)，例如隨機梯度下降法 (Stochastic Gradient Decent, SGD)、Adam 和 RMSProp，最後挑選測試效果最佳的 Adam 當成本研究訓練神經網路的優化器，利用優化器修正參數，使得新參數算出來的損失函數的值能夠持續往下降。

3.4 卷積神經網路

卷積神經網路(convolution neural networks, CNNs)是目前深度學

習技術中最具代表性的神經網路之一，其在影像分析、場景辨識上具有廣泛的應用。CNNs 的優點之一是不需要繁複的影像前處理過程，CNNs 可以直接輸入原始影像進行一系列的影像處理工作。圖 10 所示為 CNNs 的基本架構，與大多數前饋式神經網路(feedforward networks)架構類似，CNNs 由一個輸入層(input layer)，一個輸出層(output layer)，及許多隱藏層(hidden layers)所組成；隱藏層依據網路功能又可分為兩大部分，第一部分為特徵偵測層(feature detection layers)，其主要由卷積層(convolution layers)、池化層(pooling layers)所組成。特徵偵測層可重複多次，使得每一次可以對應到物體不同層級的特徵；第二部分為全連結層(fully connected layer, FC)，可用來進行影像分類或辨識，主要目的是將前一層所偵測到的特徵對應到欲分類的類別。以下針對各層的功能進行簡單說明：

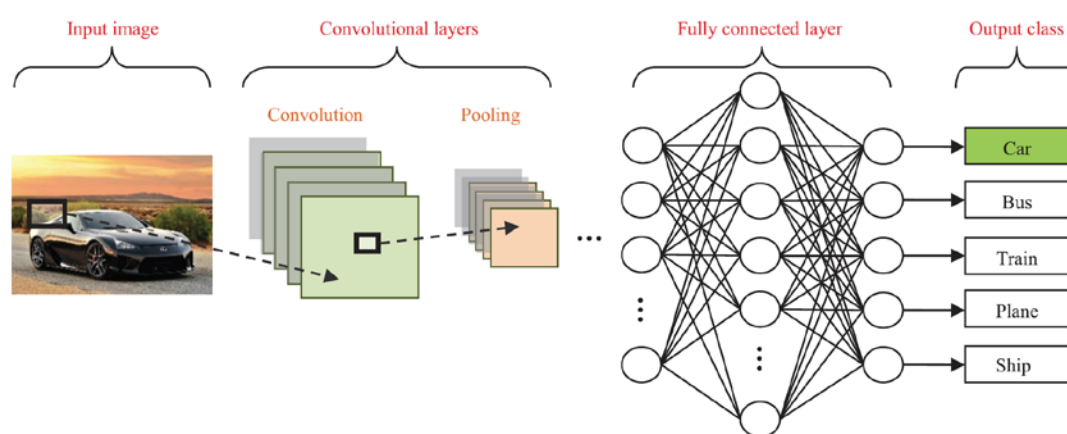


圖 10 卷積神經網路基本架構圖(Rawat & Wang, 2017)

卷積層：從數學意義上來看，卷積層的作用即是利用一個濾波器 (filter) 對輸入影像進行卷積運算，並獲得一張特徵響應圖 (feature map)，若同時使用多個不同的濾波器，則可以獲得一組特徵響應圖。如圖 11 所示為一卷積層運算的例子，圖 11 中左邊為一大小為 32×32 的 3 波段彩色影像，經過以大小為 5×5 的濾波器進行卷積運算後可獲得一大小同為 32×32 的特徵響應圖，即圖 11 中右邊紅色的正方形區塊，若採用 10 種不同的濾波器，則可獲得 10 張特徵響應圖 (Dertat, 2017)。若從網路連結的意義來看，卷積層隱含有兩種 CNNs 特有的特性，即局部連結性 (local connections) 及權值共享 (shared weights) (LeCun et al., 2015)。從圖中可以看到濾波器只針對影像的局部區域進行加權計算，此局部區域在神經科學中又稱為感受域 (receptive field)，而影像中欲偵測的物體通常只在影像局部區域具有高相關性，這是為何 CNNs 特別適合用來進行影像辨識的主要原因。而權值共享又稱為參數共享，其意思是在卷積運算的過程中，濾波器對不同影像位置的計算權值都是不變的，此將引發另一個 CNNs 的特性，稱為同變性 (equivariance)，其好處是當影像中欲偵測的物體變動其位置時，利用卷積運算仍然可以將此物體找出來。

在許多 CNNs 架構中，卷積運算後的加權總合會經再經由一校正線性單元(ReLU, Rectified Linear Unit)進行轉換，ReLU 是一種非線性轉換函數，可以使得 CNNs 的訓練更快速且更有效性。ReLU 函數的具體作法是將負值對應到 0，而正值則維持不變。




圖 11 卷積層運算式意圖(擷取自 Towards Data Science 網頁)

池化層：池化層的主要是利用非線性降取樣(downsampling)簡化捲積層的輸出，以降低網路所需訓練的參數數目。從統計意義上來看，池化相當於從特徵響應圖上一個給定的區域範圍計算出一個能代表此區域的特徵統計值，此特徵統計值具有微小平移及影像變形的不變性(invariance to small shifts and distortions)，因此可以增加特徵偵測的可靠性。在一般的 CNNs 中最常見的兩種池化計算方式為最大值池化(max pooling)及平均值池化(average pooling)，其計算方式如圖 12 所示(Rewat & Wang, 2017)。




圖 12 池化示意圖(Rewat & Wang, 2017)

全連結層：輸入影像經過特徵偵測後，即可以開始進行影像辨識或分類，分類層通常為一全連結層(fully connected layer, FC)，若有 K 個欲辨識或分類的項目，則輸出層的維度大小即為 K。

一個完整的 CNNs 架構通常會將許多卷積層、池化層依序堆疊在一起，以獲得不同層級的特徵，較低層的特徵(lower-level features)經過組合後將獲得較高層的特徵(higher-level features)，此與自然界中訊號的階層式結構是相符合的。例如在影像中，將偵測到的邊緣線(edges)特徵組合在一起可以形成一個圖案(motif)，而許多圖案可以組合一個部件(part)，將部件組合在一起就形成一個完整的物體(object)。這是 CNNs 可以用來進行影像辨識最主要的基本概念。

3.5 定位方法

3.5.1 文字定位

本研究彙整之社群媒體相關災害訊息與災害地點現地媒體資料，

利用 LSTM 模型進行預測，判斷災害訊息中是否包含地名、地標或路段的詞彙，若此災害訊息內有包含地名、地標或路段，模型將其標記為「有」，反之則標記為「無」，針對標記為「有」的災害訊息將其地名、地標或路段擷取出來，使用 Google Maps 的 Geocoding API 得到每組地名、地標或路段的經緯度，同時檢視其定位。

3.5.2 影像定位

本研究擬定影像定位方式，首先由社群資訊所提供之影像經由預先訓練好的卷積神經網路進行影像辨識，獲得影像內含的地標(POI)名稱後，再搭配社群資訊所提供其他的文字訊息，以比對的方式從本研究所蒐集的 POI 基礎資料庫中，找到相對應的 POI 紀錄，攫取出該筆紀錄的地理坐標後即可完成影像定位。

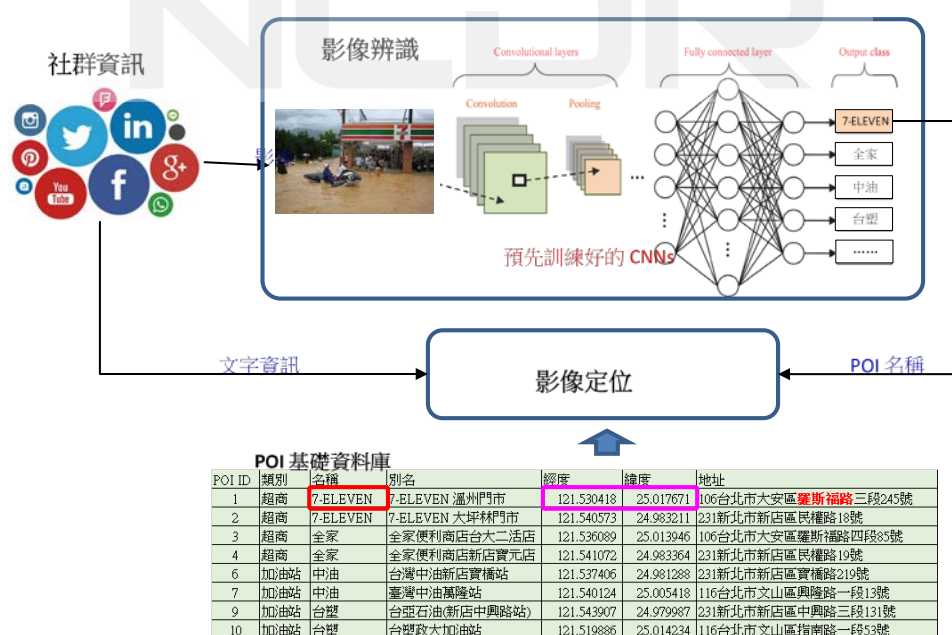


圖 13 影像定位示意圖

第四章 文字訊息實驗

針對 LSTM 訓練完的模型進行測試，主要使用的資料為發生在臺灣的颱風相關災害資料，從 2014 年至 2020 年在各大網站上蒐集，包含社群媒體、新聞媒體和論壇討論區網站。資料庫來源主要為眾多社群網站上抓取之文字訊息，相關資料筆數共為 61,082 筆，資料來源包括 Facebook、Mobile01 論壇、PTT 電子佈告欄、ETtoday 新聞雲、蘋果日報即時新聞、中時電子報、工商時報、聯合新聞網、自由時報、伊莉討論區等等。

在資料前處理的設定上，設定資料集裡有 10,000 組詞彙；數字序列的最大長度 1,315；詞向量的維度為 256；LSTM 輸出的向量維度為 128。本研究將輸入資料分為 80% 的訓練資料集和 20% 的驗證資料集，使用的 LSTM 模型以批量大小 (Batch Size) 100 進行測試；模型的週期數 (Epochs) 則設定為 10。

4.1 評量指標

本節使用準確度 (Accuracy) 精確度 (Precision)、召回率 (Recall) 和 F1 分數 (F1-Score) 等評量指標來評估模型的表現，True Positives 表示正確的正向預測；True Negatives 表示正確的負向預測；False Positive 表示錯誤的正向預測；False Negative 表示錯誤的負向預測；Total

Examples 表示所有的情形個數，以下為各個評量指標的詳細介紹：

準確度是將所有正確的情況加總起來除上所有情形個數，即時告訴模型是否被正確訓練以及其總體表現為何，並計算如方程式(9)表示：

$$Accuracy = \frac{True\ Positives + True\ Negatives}{Total\ Examples} \quad (9)$$

精確度為預測正向的情形下，實際上也為正向的情形，並計算如方程式(10)表示：

$$Precision = \frac{True\ Positives}{True\ Positives + False\ Positives} \quad (10)$$

召回率為實際情形為正向的狀況下，實際上也為正向的情形，並計算如方程式(11)表示：

$$Recall = \frac{True\ Positives}{True\ Positives + False\ Negatives} \quad (11)$$

F1 分數為將同時考慮精確度與召回率的總體指標，並計算如方程式(12)表示：

$$F_1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (12)$$

在機器學習中，混淆矩陣 (Confusion Matrix) 是種可視化工具，

通常在已知測試資料真實值的情況下，用於描述分類模型的表現。本節使用混淆矩陣表示研究情境，透過準確度、精確度、召回率、F1 分數來評估本研究使用模型的表現，參數設定如表所示，並說明每組指標在本研究情境的計算方式。

表 4 混淆矩陣

實際情況 \ 預測結果	留言有地名、地標	留言無地名、地標
留言有地名、地標	C_{11}	C_{12}
留言無地名、地標	C_{21}	C_{22}

準確度為所有預測正確的資料，計算如下所示：

$$Accuracy = \frac{C_{11} + C_{22}}{C_{11} + C_{12} + C_{21} + C_{22}} \quad (13)$$

精確度為預測結果為留言有地名、地標的情況下，正確預測出留言有地名、地標的資料，計算如下所示：

$$Precision = \frac{C_{11}}{C_{11} + C_{12}} \quad (14)$$

召回率為實際情形為留言有地名、地標的情況下，正確預測出留言有地名、地標的資料，計算如下所示：

$$Recall = \frac{C_{11}}{C_{11} + C_{21}} \quad (15)$$

F1 分數為將同時考慮精確度與召回率的總體指標，計算如下所示：

$$F_1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (16)$$

總共 45,603 筆原始災害資料，將其進行人工標記的動作，主要的準則為人工判定此留言內是否包含地名或地標，若 A 留言內有包含地名或地標，則將其人工標記為「有」，B 留言內無包含地名或地標，因此將此篇留言人工標記為「無」，14,731 筆的資料留言中包含地名或地標；30,872 筆的資料留言中沒有包含地名或地標。將原始資料分為 80% 的訓練資料集和 20% 的驗證資料集，並使用 10,000 筆測試資料讓模型測試，2,578 筆的資料留言中包含地名或地標；7,422 筆的資料留言中沒有包含地名或地標，表 5 為模型測試結果。

表 5 LSTM 測試結果

實際情況 \ 預測結果	留言有地名、地標	留言無地名、地標
留言有地名、地標	2,147	202
留言無地名、地標	431	7,220

由表 5 可得到所有預測正確的資料為 9,367 筆，準確率為 94%；預測結果為留言有地名、地標的情況下，正確預測出留言有地名、地標的資料為 2,349 筆，精確度為 91%；實際情形為留言有地名、地標

的情況下，正確預測出留言有地名、地標的資料為 2,578 筆，召回率為 83%；綜合精確度和召回率得到的 F1 分數為 87%，結果顯示從整體的資料來看，模型預測之準確率高達 94%，在判別留言中有無地名或地標的機率是相當高的；但在預測結果為留言有地名、地標的情況下，實際正確的精確率為 91%，表示誤判(False Positive)的機率不高；而在實際結果為留言有地名、地標的情況下，模型預測正確的召回率為 83%，表示漏判(False Negative)的機率相較誤判的機率相對較高；綜合指標 F1 分數為 87%，未來研究將持續增加資料量，或者挑選精進的神經網路、改良原始網路結構，預期準確率能持續增加。

4.2 資料量與詞彙量對預測結果之比較

為了提升神經網路模型預測的效果，除了可以增加訓練資料量，讓神經網路模型能透過大量的資料學習資料的特徵值，也可以透過 Jieba 提供的自訂詞庫功能，增加詞彙量到自訂詞庫中，避免文句中重要的詞彙因為不常見或者是專有名詞導致分詞的結果有所錯誤，上述方法皆可增加模型的預測效果，但兩種方法何者能帶給模型較佳的效益是值得探討的議題，本節將比較訓練資料量與詞彙量對預測結果的影響，使得在增加模型預測效果的同時，可選定有效的方法來增加預測效果，避免消耗大量的人力與時間。

本節分別使用 10,000、20,000、30,000 筆的訓練資料量和詞彙量來測試神經網路模型在不同資料筆數的準確率，首先針對訓練資料量的多寡進行測試，將詞彙量固定為 20,000 筆，分別測試訓練資料量在 10,000、20,000、30,000 筆時的準確率，表 6 為模型在不同訓練資料量時的準確率。接著針對詞彙量的多寡進行測試，將訓練資料量固定為 20,000 筆，分別測試詞彙量在 10,000、20,000、30,000 筆時的準確率，表 7 為模型在不同詞彙量時的準確率。圖 14 為不同資料筆數對訓練資料量與詞彙量之比較。

表 6 不同訓練資料量時的準確率

訓練資料量	準確率
10,000 筆	85.41%
20,000 筆	89.08%
30,000 筆	91.03%

表 7 不同詞彙量時的準確率

詞彙量	準確率
10,000 筆	88.74%
20,000 筆	90.25%
30,000 筆	89.56%

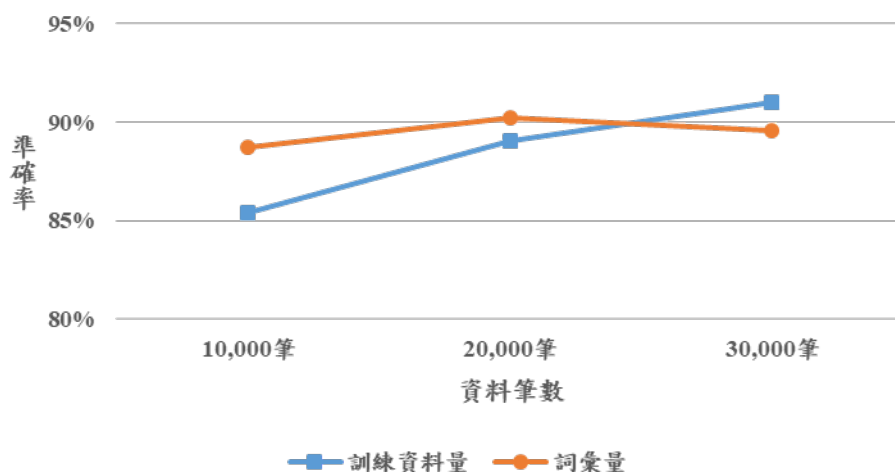


圖 14 不同資料筆數對訓練資料量與詞彙量之比較

結果顯示若分別增加訓練資料量或詞彙量，準確率皆會增加，但若訓練資料筆數慢慢增加的情況下，訓練資料量之準確率有逐漸增加的趨勢；反之詞彙量資料筆數在增加的情況下，準確率反而有收斂的趨勢。本研究發現當資料筆數增加時，詞彙量之準確率將會陷入瓶頸，但訓練資料量之準確率可以持續地增加，因此若要增加模型預測的準確率，可適時地增加訓練資料量以增加預測效果，避免同時增加詞彙量和訓練資料量，節省大量的人力與時間。

4.3 比較不同社群平台之有效留言

Web 2.0 的出現，使用者除了可以自行發表各式各樣的內容，也可以透過網路上大量的資訊進行互動，包括各種形式的社群網站、圖片、影片、部落格、論壇、評論、新聞等。隨著不同形式社群平台的出現，使用者透過不同的社群平台發表資訊或者互動的方式也有所不

同(Choi, Matni, Shah, & Technology, 2016)。常見之國外社群平台類型包括社群網站、微網誌以及電子佈告欄，分別以 Facebook、Twitter、Reddit 為主要使用的平台，社群網站主要之特色為使用者可以透過不同的形式進行互動，包括文本、圖片、影片等，通常也以使用者為導向，可創作與分享各種不同的內容。社群網站也可建立社團，透過建立共同目標或興趣的社團，讓志同道合的人進行喜好交流；微網誌則可限制發文字數，例如 Twitter 限制使用者不能更新超過 280 字元的訊息，稱作「Tweet」，透過限制字數可以讓使用者利用極短的文字表達訊息重點，同時增加發文和閱讀的意願；電子佈告欄通常沒有建立社團的功能，但有不同主題之討論區，每位使用者皆可以針對有興趣之主題參與討論。

為了比較不同社群平台之有效留言，本研究將收集三組不同的災害資料來源，利用本研究之模型對每組資料來源進行預測，並比較不同社群平台中的留言內有包含地名或地標並標記為「有」之數量，目的為災害發生時可迅速地針對特定的社群平台之災害留言進行收集，避免收集到有效留言數量較少之社群網站，以防止消耗大量之人力與時間。本研究使用之資料來源為臺灣常使用之社群平台留言，包括 Facebook、PTT、Plurk。Facebook 為大眾廣泛使用的社群平台，允許

用戶創建個人資料，可在個人頁面中發布有關訊息，範圍從職業到宗教和政治觀點，再到喜愛的電影和音樂家。在個人頁面上，用戶和其好友皆可發布感興趣的網絡文章、圖片和影片；Facebook 也提供向其他用戶發送私人和公共消息，擁有即時消息傳遞的功能。加上群組和粉絲專頁的創建使得 Facebook 廣泛流行於線上社交活動(Hughes, Rowe, Batey, & Lee, 2012)，且其入門門檻低，因此受到廣泛的年齡層喜愛，但由於缺少個人隱私，以及無用的資訊量過多，在特定年齡層的使用上比例相對地較低；PTT 中文名稱為台大批踢踢實業坊，是臺灣知名的電子佈告欄系統(Bulletin Board System, BBS)，同時也是目前臺灣使用人最多、最具代表性的網路社群論壇，PTT 通常以文字討論為主，不會存在大量的廣告訊息，特色在於各版分類明確，擁有特定的討論版可供使用者選擇，各類型的話題都可在不同討論版進行討論，同時也為即時性互動的平台，透過不同討論的議題讓使用者擁有參與網路運動的空間，PTT 受到 25 至 45 歲的特定年齡層喜愛，產生許多熱門文章與新興的網路用語，也常被新聞媒體當成題材使用；Plurk 是微網誌社群網站，利用簡短的訊息提供使用者作文字或影像、圖片的內容發表，並透過網頁的即時更新，可即時回應其他使用者之訊息；比起其他社群網站存在大量文字的文章，Plurk 最大特色為一則訊息只能有 360 字的限制，且存在「時間軸」，可讓訊息皆依時間由左至

右排序。本節將使用 Facebook、PTT、Plurk 進行相關災害地點現地媒體資料預測，分別針對以 Facebook、PTT、Plurk 為來源社群網站的相關災害資料進行收集，使用 45,603 筆原始資料輸入到神經網路模型訓練，使用 80% 訓練資料和 20% 筆驗證資料，並對三組不同的資料來源分別收集 1,000 筆原始資料進行測試。

在第一組 Facebook 預測資料集中，共有 1,000 筆測試資料，其中留言包含地名、地標的有 292 筆，而無包含地名、地標的有 708 筆。在第二組 PTT 預測資料集中，共有 1,000 筆測試資料，其中留言包含地名、地標的有 275 筆，而無包含地名、地標的有 725 筆。在第三組 Plurk 預測資料集中，共有 1,000 筆測試資料，其中留言包含地名、地標的有 137 筆，而無包含地名、地標的有 863 筆，表 8 為三組不同的災害資料來源之預測比較。

本節將使用 Facebook、PTT、Plurk 進行相關災害地點現地媒體資料預測，分別針對以 Facebook、PTT、Plurk 為來源社群網站的相關災害資料進行收集，使用 45,603 筆原始資料輸入到神經網路模型訓練，使用 80% 訓練資料和 20% 筆驗證資料，並對三組不同的資料來源分別收集 1,000 筆原始資料進行測試。

在第一組 Facebook 預測資料集中，共有 1,000 筆測試資料，其中

留言包含地名、地標的有 292 筆，而無包含地名、地標的有 708 筆。

在第二組 PTT 預測資料集中，共有 1,000 筆測試資料，其中留言包含地名、地標的有 275 筆，而無包含地名、地標的有 725 筆。在第三組 Plurk 預測資料集中，共有 1,000 筆測試資料，其中留言包含地名、地標的有 137 筆，而無包含地名、地標的有 863 筆，表 8 為三組不同的災害資料來源之預測比較。

表 8 三組不同的災害資料來源之比較

Facebook	PTT	Plurk
受到廣泛年齡層喜愛	受到 25 至 45 歲的特定年齡層喜愛	受到年輕族群喜愛
可看到好友發布的文章以及加入社團和按讚粉絲團的文章	各版分類明確，擁有特定的討論版可供使用者選擇	微網誌社群網站，利用簡短的訊息作文字或影像、圖片的內容發表
缺少個人隱私	訊息以文字為主	訊息有 360 字限制
廣告訊息量過多	廣告訊息量較少	使用者比例相對較低

表 9 三組不同的災害資料來源之預測比較

	Facebook	PTT	Plurk
留言有地名、地標	292	275	137
留言無地名、地標	708	725	863




圖 15 不同網站之有效留言數比較

圖 15 為不同社群平台之有效留言比較，結果顯示若資料來源為 Facebook 時的留言有地名、地標數量為最多，而其他兩大社群網站包括 PTT 和 Plurk 的留言無地名、地標數量較多，雖然三組資料來源中常有無關乎災害的訊息，例如「都說了颱風天沒四千萬不要出門」，或者「恭喜您得 87 分已經不能再高分了」，但卻有特定之社群平台的無效留言相對較少的情況，推測可能為其擁有特定之災害社團或粉絲專頁可供使用者討論，例如台南市淹水、爆料公社、新聞類粉絲專頁等，因此在災害相關之有效留言數量較其他兩者多，若災害發生時，可適時地針對特定社群平台之災害留言進行收集，避免收集過多之無

效留言，提升災害留言之收集效率。

4.4 社群媒體之災害留言分析

本研究在進行人工標記的過程中，發現標記為「有」之社群媒體災害留言常出現特定的地名和路段，推測原因可能為此區域有較多的人在使用社群網路，才會讓災害留言中的地名和路段持續地出現。本節將找出近三年常出現在災害留言內的地名和路段，主要分成兩個部分討論，第一部分先找出常出現的臺灣縣市，觀察其出現次數的多寡，可驗證災害發生的區域排行，同時可以觀察在災害留言高頻率出現的縣市，以及找出使用社群網路之人口較少的區域，本節將利用柏拉圖分析(Pareto Chart)的手法，找出特定區域在災害留言中出現的次數多寡，並加以分析。柏拉圖分析通常是用來表示產品瑕疵發生頻率及其累積影響的圖表分析，可用於發現不同類型之瑕疵並對其進行優先排序，以明顯地觀察到重要的要因並予以改進；第二部分為找出常出現的臺灣路段，觀察其出現之重複性，判斷其是否為頻繁發生的詞彙，可在災害發生前，加強重點地方的災害防治，建立警戒與監測系統，例如加裝警報器、監視器等，在災害發生前可以有完善的災害防治措施。本節以 2017、2018、2019 近三年的臺灣豪雨資料為例，每年分別使用不同筆數的原始資料，找出豪雨留言在近三年內常出現的地名和路段。

2017 年的臺灣豪雨共有 1,130 筆原始災害留言資料，利用神經網路模型對原始災害留言進行預測，結果有 341 筆災害留言被標記為「有」，本研究利用被標記為「有」之災害留言進行進一步分析，將有包含臺灣縣市之詞彙全部彙整出來，並使用柏拉圖分析彙整出來之詞彙，結果顯示最常出現之詞彙前三名包括臺北市、新北市、臺中市，圖 16 為針對 2017 年之臺灣豪雨資料的柏拉圖分析。

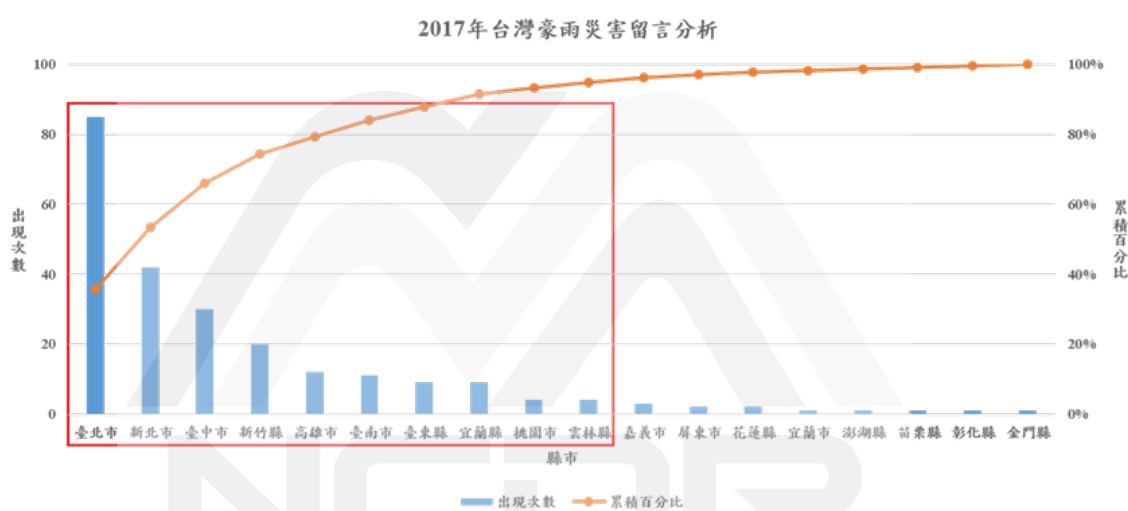


圖 16 2017 年臺灣豪雨資料之柏拉圖分析

2018 年的臺灣豪雨共有 3,006 筆原始災害留言資料，利用神經網路模型對原始災害留言進行預測，結果有 963 筆災害留言被標記為「有」，利用柏拉圖分析彙整出來之詞彙，結果顯示最常出現之詞彙前三名包括臺北市、高雄市、台南市，圖 17 為針對 2018 年之臺灣豪雨資料的柏拉圖分析。

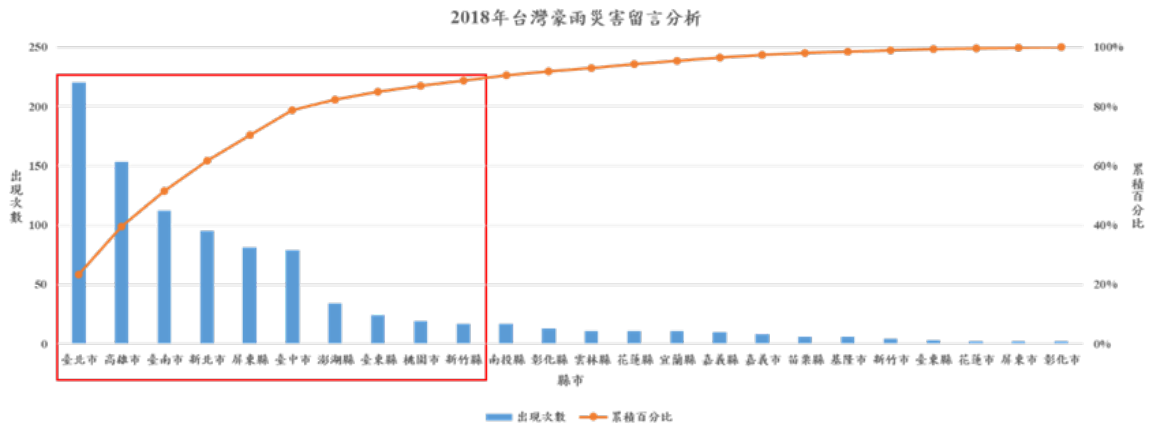


圖 17 2018 年臺灣豪雨資料之柏拉圖分析

2019 年的臺灣豪雨共有 1,467 筆原始災害留言資料，利用神經網路模型對原始災害留言進行預測，結果有 533 筆災害留言被標記為「有」，利用柏拉圖分析彙整出來之詞彙，結果顯示最常出現之詞彙前三名包括臺北市、新北市、臺中市，圖 18 為針對 2019 年之臺灣豪雨資料的柏拉圖分析。

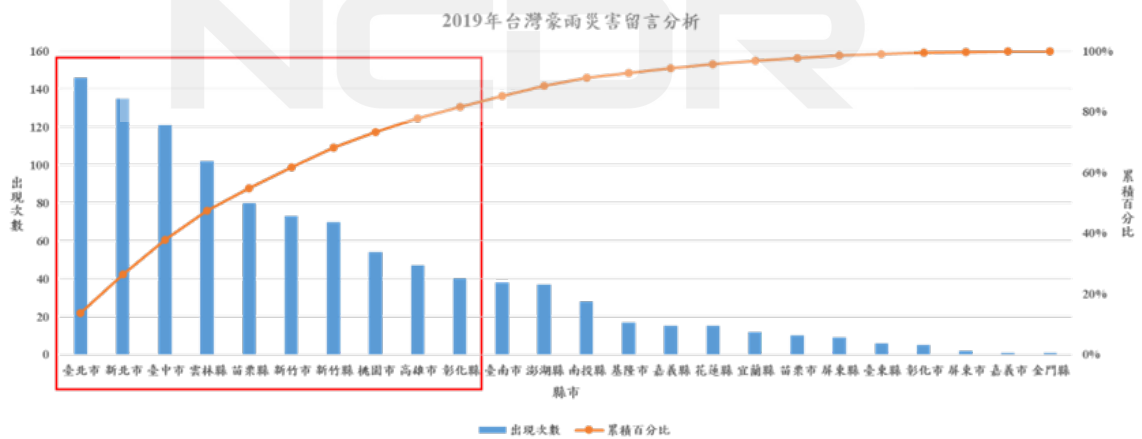


圖 18 2019 年臺灣豪雨資料之柏拉圖分析

本研究以經濟部統計之淹水災情為參考資料，列出臺灣縣市常發生之淹水排行，並利用上述近三年臺灣豪雨資料，統計常出現的臺灣

縣市之詞彙出現次數多寡，驗證實際災害發生的區域排行，表 10 為經濟部統計之臺灣縣市常發生之淹水排行，表 11 為近三年之臺灣豪雨資料中縣市的出現次數排行。

表 10 經濟部統計之臺灣縣市常發生之淹水排行

臺灣縣市之淹水排名	縣市
1	臺南市
2	高雄市
3	嘉義縣
4	嘉義市
5	雲林縣
6	屏東縣
7	臺中市
8	南投縣

表 11 近三年之臺灣豪雨資料中縣市的出現次數

2017、2018、2019 年臺灣豪雨資料中縣市之前十名						
臺灣淹水排行	2017	與排行重複	2018	與排行重複	2019	與排行重複
臺南市	臺北市		臺北市		臺北市	
高雄市	新北市		高雄市	✓	新北市	
嘉義縣	臺中市	✓	臺南市	✓	臺中市	✓
嘉義市	新竹縣		新北市		雲林縣	✓
雲林縣	高雄市	✓	屏東縣	✓	苗栗縣	
屏東縣	臺南市	✓	臺中市	✓	新竹市	
臺中市	臺東縣		澎湖縣		新竹縣	✓
南投縣	宜蘭縣		臺東縣		桃園市	
	桃園市		桃園市		高雄市	✓
	雲林縣	✓	新竹縣		彰化縣	

柏拉圖分析的結果顯示臺灣豪雨的災害留言在三年內皆以臺北市占的比例為最高，而三年內最常出現之詞彙前三名皆屬於都會區，推測原因可能為此區域有較多的人在使用社群網路，才會讓災害留言中的地名或地段持續地出現，而某些區域較無使用社群網路，例如本研究在臺灣豪雨資料中縣市出現次數之前十名無發現嘉義、南投等區域，可能會導致某些區域真正有發生災害，而無法根據災害留言找到相關災害地址。

再進一步分析，分別找出臺灣豪雨的災害留言在近三年常出現的路段，2017 年的臺灣豪雨常用之共出現 75 種不同的地標和路段；2018 年的臺灣豪雨常用之路段共出現 291 種不同的地標和路段；2017 年的臺灣豪雨常用之路段共出現 295 種不同的地標和路段，進行特色比對並觀察近三年內重複出現之路段，表 12 為臺灣豪雨資料中路段的重複詞彙，圖 19、圖 20、圖 21 為災害潛勢圖(2016 年水利署產製)，表示過去常發生災害，或者未來有較高的致災機會之區域或路段，本研究使用 600mm 淹水潛勢圖當作佐證資料。

表 12 2017、2018、2019 年臺灣豪雨資料中路段的重複詞彙

2017、2018、2019 年臺灣豪雨資料中常見路段之重複詞彙
辛亥路
大安路
基金一路
大湖山莊街
基金一路
大同路
民義路
龍米路

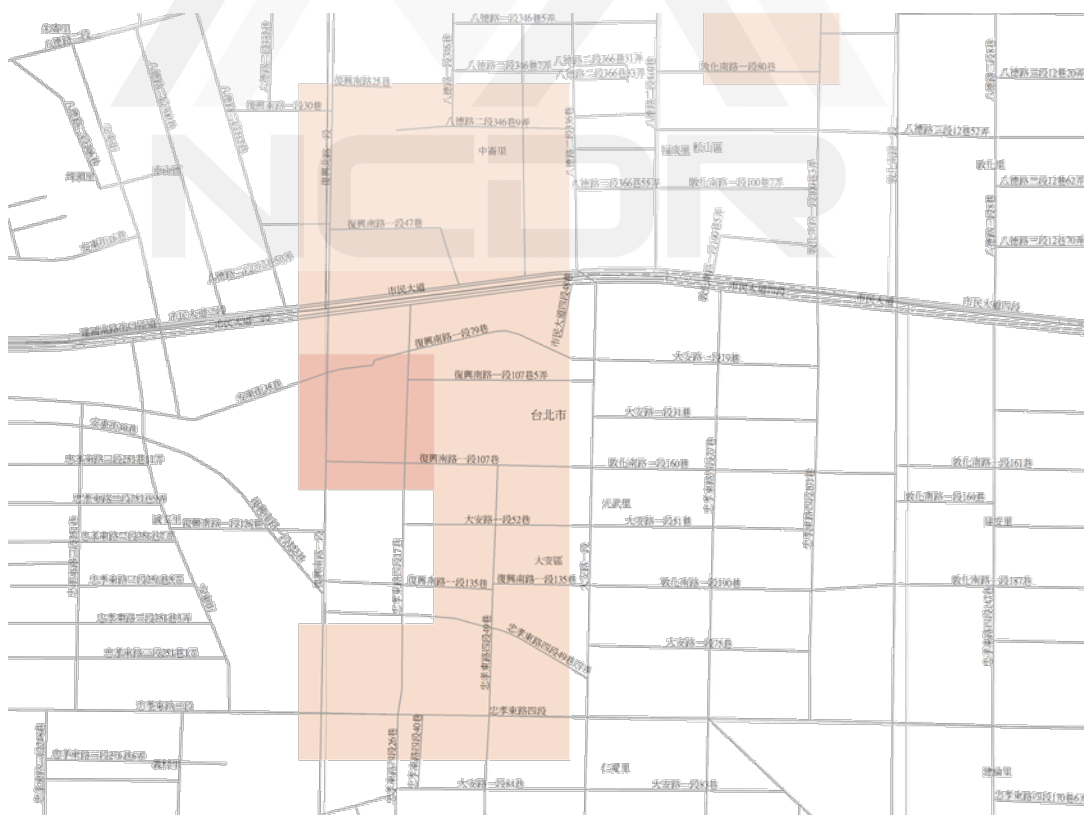


圖 19 大安路降雨 600mm 的淹水潛勢圖 (水利署, 2016 年)



圖 20 大湖山莊街降雨 600mm 的淹水潛勢圖 (水利署, 2016 年)




圖 21 大同路降雨 600mm 的淹水潛勢圖 (水利署, 2016 年)

觀察近三年重複出現之路段，可在災害發生時，加入這些特定詞彙在自訂字典中並加重權重，提高分詞結果，讓常出現的路段能準確地被找出來，透過在災害留言中出現比例較高之路段，建立警戒與監測系統，在災害發生前加強此區域的災害防治。



第五章 影像特徵辨識實驗

近年來由於人工智慧及機器學習的盛行，需多資訊大廠如 Microsoft、Google、及 Amazon 等紛紛推出線上機器學習的服務，藉由高速運算資源、雲端技術、機器學習演算法及網路的整合，提供給想使用機器學習於特定應用的專業開發者或一般使用一個線上的工具及平台。大部分的線上機器學習服務皆設計有簡單明瞭的使用者介面(GUI)，方便使用者根據自己的需求進行機器學習，包括資料輸入、訓練、評估、改善及發布模型等。即使使用者沒有專業的機器學習知識，依舊可以利用這些線上機器學習服務輕鬆自訂符合自身應用需求的機器學習模型。

本研究利用 Google 所提供的 Vision API 及 AutoML Vision 兩個服務進行影像辨識的測試及比較，以驗證本研究設計之研究流程與方法。圖 22 所示為此兩種服務進行影像分析的流程圖，其主要目的皆是進行影像辨識及分析，兩者所使用的機器學習演算法及運算資源都是一樣的，而主要差別是 Google Vision 的模型為 Google 已經預先訓練好的模型，因為沒有針對特別應用，因此屬於一種廣泛的應用模型；而 AutoML Vision 則可以由使用者根據自己的應用需求訓練所需的模

型，能夠滿足特殊的應用需求，相較於 Cloud Vision API，AutoML Vision 的模型準確度較高，且能更快速地建立可投入實作環境的模型。

以下說明兩個服務進行影像辨識的測試結果。

5.1 Vision API

Vision API 為 Google Cloud 服務中有關於 AI & Machine Learning 產品的其中一個，其運用 Google 平時所蒐集的影像預先訓練了一個通用模型，使用者只須將影像輸入到此模型中便能獲取影像中的資訊，如偵測影像中的個別物件或進行臉部辨識，甚至可以辨識影像中的文字。此外 Cloud Vision 提供 REST API 供開發人員更容易使用此預先訓練過的模型以進行影像分析。

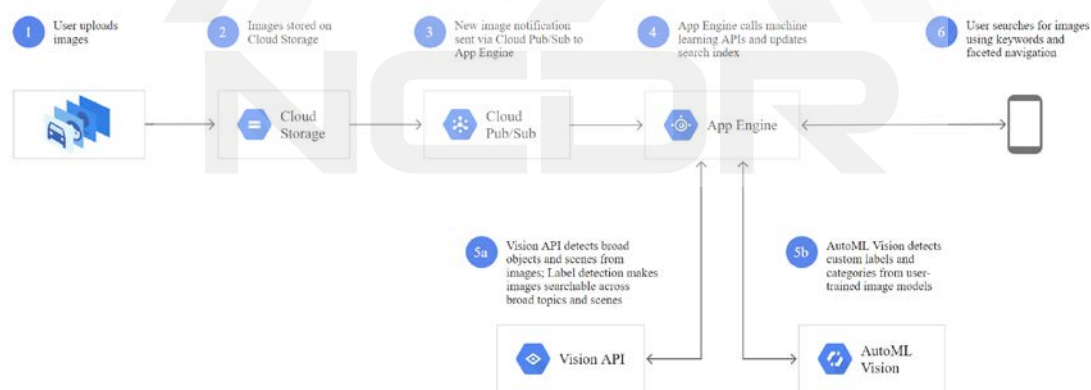


圖 22 Google Vision API 及 AutoML Vision 影像分析流程圖

將影像輸入後，Vision API 將根據 Google Vision 已經預先訓練過的模型進行影像辨識及分析，其輸出結果包括物件(objects)的偵測、給予影像標籤(labels)、商標(logos)辨識、找出網路(web)上類似的影像、

進行文字辨識(document)、影像特性(properties)分析、網路安全搜尋(Safe Search)、最後將所有影像分析結果彙整成 JSON 格式供使用者進一步使用。以圖 23 中的道路淹水影像為例，Vision API 依照內容相似度(百分比)，依序給予交通模式(Mode of Transport)、下雨(Rain)、城市(City)、淹水(Flood)等不同標籤的順序；在商標方面， Vision API 辨識出此張影像中含有麥當勞(McDonald's)的商標，相似度高達 95%，如圖 24 所示；此外藉由 Google 影像辨識功能，Vision API 可偵測此影像所包含的各種物件，如圖 25(a)顯示此影像中有兩部汽車(Cars)；圖 25(b)則偵測出影像中的文字，並進行文字辨識；圖 25(c)所示為此張影像顏色(影像特性之一)的比例分布；圖 25(d)則是採用 Google 的安全搜尋(SafeSearch)技術，可以審核使用者提供的影像內容，並偵測出不適當的內容，如成人、詐欺、醫療、暴力、兒童不宜等內容；上述各種結果最後將儲存成 JSON 格式供使用者進一步使用，如圖 26 所示。

由上可知，針對本計畫的影像定位目標，Vision API 確實可以自動偵測出符合本計畫需求的影像內容，即淹水及麥當勞商標。然而受限於預先訓練模式的限制，某些具本土在地化的元素(如 OK 便利商店、萊爾富便利商店、中油加油站等)可能無法利用 Vision API 偵測

出來。

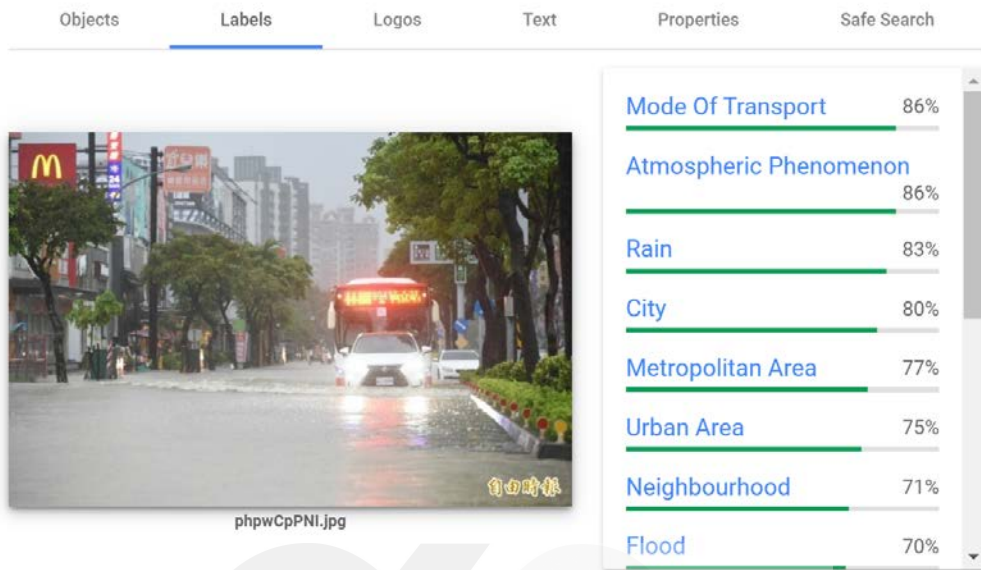


圖 23 Cloud Vision API 的執行結果

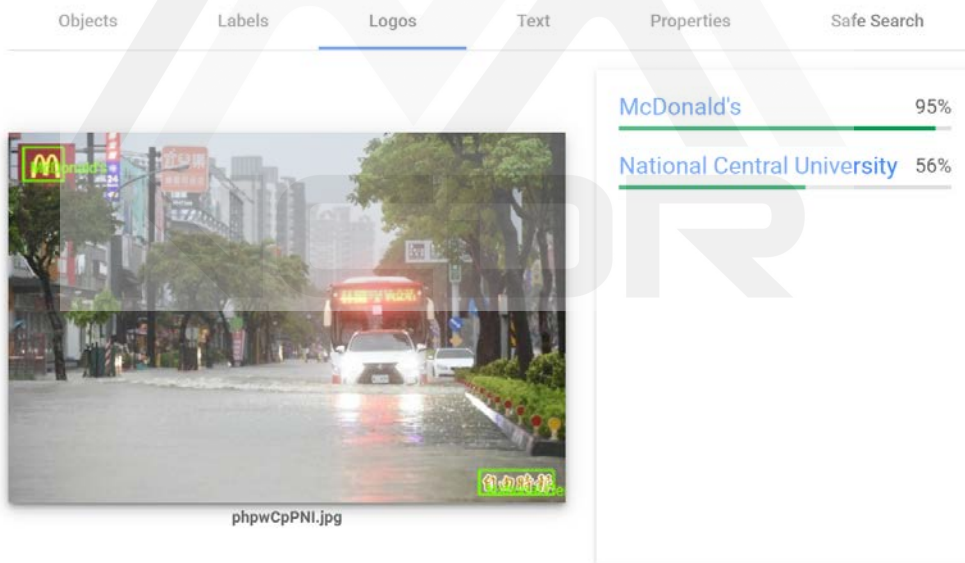




圖 24 以 Cloud Vision API 進行 logos 的辨識結果




(a) Objects



(b) Text



(c) Document



(d) Properties

圖 25 Cloud Vision API 的各種執行結果

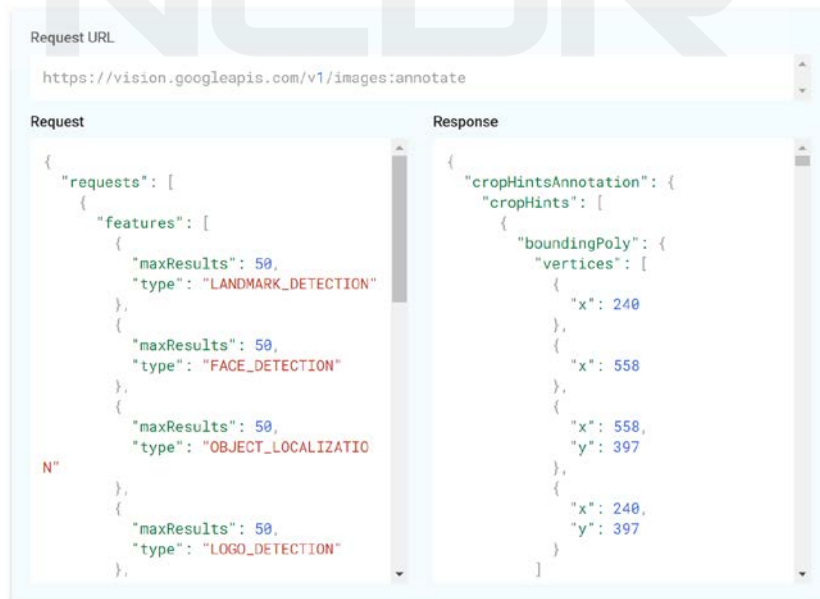


圖 26 以 JSON 格式顯示 Cloud Vision API 的判識結果

5.2 AutoML Vision

Google AutoML Vision 產品包含有 AutoML Natural Language、AutoML Tables、AutoML Translation、AutoML Video Intelligence、以及 AutoML Vision，其中 AutoML Natural Language 則提供強大的文字分析功能、AutoML Translation 則可讓使用者進行快速的動態翻譯，而 AutoML Vision 主要提供強大的影像分析功能。本計畫目的主要是進行影像辨識及分類，因此採用 AutoML Vision 進行測試。AutoML Vision 的運作方式如圖 27 所示，首先由使用者準備訓練用的影像資料(Dataset)，並根據每張影像內容賦予影像標籤(label)後上傳到 google 儲存空間(google storage)，接著由 Google Machine Learning Engine 進行模型的訓練及評估後，之後隨時都可以使用此訓練過的模型進行影像辨識。

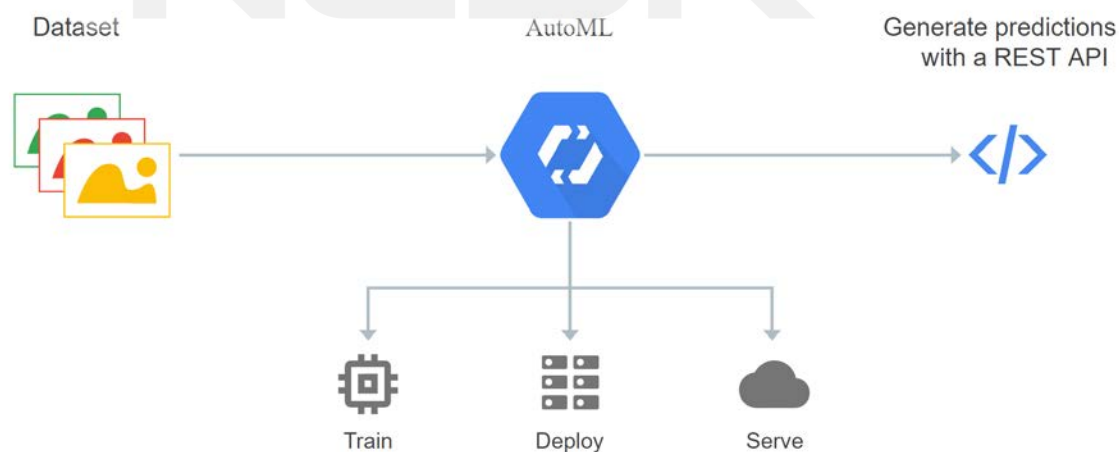


圖 27 AutoML 的運作方式

(1) 單一標籤影像分類成果

本研究的主要目標是從影像中辨識出特定關鍵字後，再從 POI 資料庫中找出該影像內容的地理空間坐標，本案於 107 年度先以超商做為測試目標，所辨識的超商包含統一超商(Seven_Eleven)、全家便利商店(FamilyMart)、大潤發(RTMart)、以及全聯福利中心(PXMart)為辨識目標，各家超商的商標(logo)如圖 28 所示，各商標圖底下所示的文字為其標籤(label)。為了訓練模型，必須蒐集大量已知標籤的影像資料作為訓練資料，圖 29 所示為本實驗所蒐集的影像資料及所對應的標籤，AutoML Vision 要求每一類至少需蒐集 100 張影像，事實上影像數量越多，所訓練出來的模型將會更準確。





			
Seven_Eleven	FamilyMart	RTMart	PXMart

圖 28 不同超商的商標及標籤

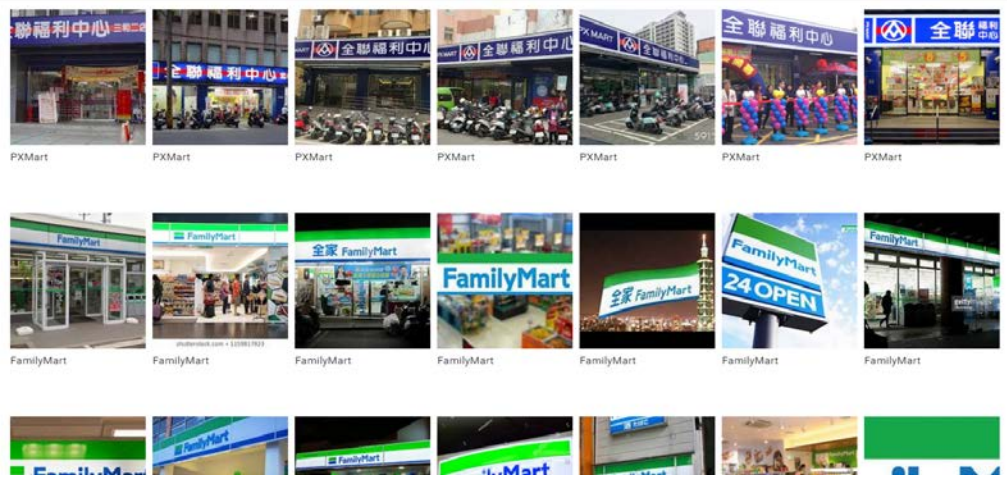


圖 29 上傳到 AutoML 的商標影像及標籤

準備好訓練樣本之後，即可以進行模型訓練，圖 30 所示為本次實驗的訓練結果，在監督式的機器學習方法中，一般會將已知樣本分成獨立的三個部分，即訓練集(train set)，驗證集(validation set)、以及測試集(test set)。其中訓練集為訓練模型的主要資料集；驗證集則用來輔助訓練集，以確定網絡結構或者控制模型複雜程度的參數，同時避免模型有過度擬合的現象；而測試集則用來測試最終完成訓練的模型性能，測試集並不參與訓練過程。在預設的情況下，AutoML 會自動挑選 80%的樣本進行訓練，10%用於驗證、剩下 10%用於測試。圖 31 所示為本實驗之訓練結果，其中精確率(precision)為 95.455%，表示誤判的機率很低，而召回率(recall)則高達 91.304%，表示漏判的機率約為 8.696%。本實驗的樣本數並不多，此結果算是不錯的訓練結果。圖 32 則為本次訓練的混淆矩陣(confusion matrix)或稱誤差矩陣(error matrix)。

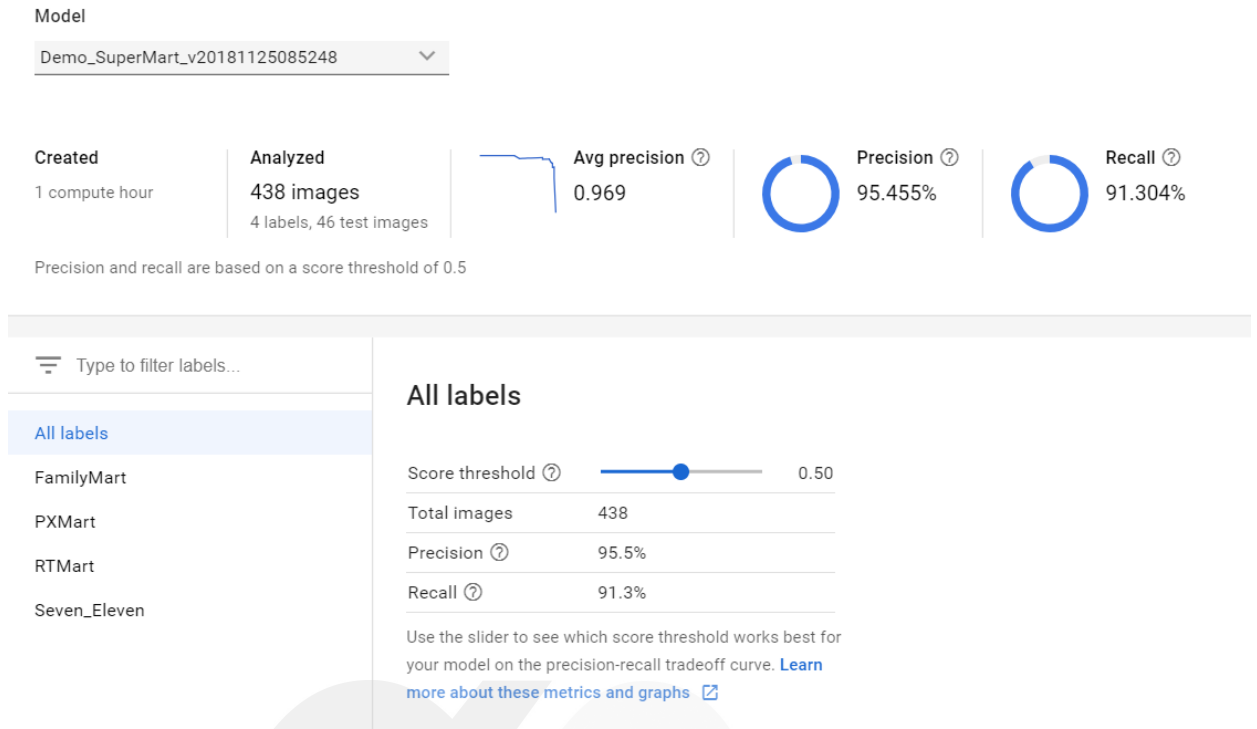


圖 30 完成訓練的模型評估結果




圖 31 精確率與召回率曲線

Confusion matrix

This table shows how often the model classified each label correctly (in blue), and which labels were most often confused for that label (in orange).

True label	Predicted label			
	RTMart	PXMart	Seven_Eleven	FamilyMart
RTMart	90.9%	9.1%	-	-
PXMart	7.1%	92.9%	-	-
Seven_Eleven	-	12.5%	75.0%	12.5%
FamilyMart	-	-	-	100.0%

圖 32 訓練結果之誤差矩陣

當模型訓練完後，使用者隨時可以使用此模型進行其他影像的判釋，圖 33 為輸入一張全家便利商店的影像後，模型正確地判釋出 FamilyMart 標籤，然而當輸入一張還有統一超商的影像時，模型卻誤判為 FamilyMart 標籤，如圖 34，顯示此模型仍有改善的空間。

Test your model on new images

If your model will be used to make predictions on people, test your model on images that capture the diversity of your userbase. [Learn more](#) 

Label	Score
FamilyMart	0.577
PXMart	0.216
Seven_Eleven	0.139
RTMart	0.064
--other--	0.004

圖 33 影像內容預測結果(正確判釋)

Test your model on new images

If your model will be used to make predictions on people, test your model on images that capture the diversity of your userbase. [Learn more](#)




圖 34 影像內容預測結果(誤判)

(2) 物件偵測成果

採用 AutoML Vision 的物件偵測功能，其可以找出辨識物件於影像中的位置，如圖 35 所示。



圖 35 AutoML Vision 的物件偵測功能

本次測試一共蒐集了十個不同的標籤進行測試，如圖 36，其中包含了統一超商、全家便利商店、OK 超商(OkMart)、萊爾富(HiLife)、頂好(Wellcome)、家樂福(Carrefour)、麥當勞(McDonlads)、漢堡王(BurgerKing)、中油(CPC)、台塑石油(Formosa)等。


			
7-Eleven	FamilyMart	OkMart	HiLife
			
Wellcome	Carrefour	McDonald's	BurgerKing
			
CPC	Formosa		

圖 36 不同的商標及所對應的標籤名稱

與單一標籤分類一樣，為了訓練物件辨識模型，必須蒐集大量已知標籤的影像資料作為訓練資料，圖 37 所示為本實驗所蒐集的影像資料及所對應的標籤，AutoML Vision 要求每一類至少需蒐集 100 張影像，事實上影像數量越多，所訓練出來的模型將會更準確。準備好

訓練樣本之後，需在訓練影像上標示出各商標的確切位置，並指定其標籤。

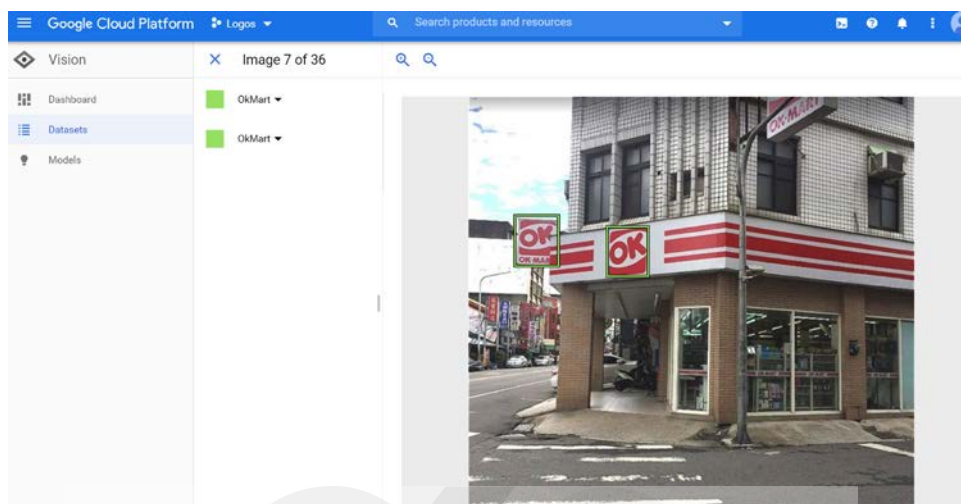


圖 37 手動標示商標位置並指定所對應的標籤名稱

影像手動標籤完成後即可以進行模型訓練，圖 38 所示為本次實驗的訓練結果，與單一標籤分類一樣，進行物件偵測時會將已知樣本分成獨立的訓練集(train set)，驗證集(validation set)、以及測試集(test set)。在預設的情況下，AutoML 自動挑選 80%的樣本進行訓練，10%用於驗證、剩下 10%用於測試。本實驗之訓練結果，其中平均精度(average precision)為 0.864，精確率(precision)為 100%，表示本次實驗沒有誤判，而召回率(recall)為 76.74%，表示漏判的機率約為 25.26%，漏判主要出現在 7-Eleven 商標的漏判，研判是訓練樣本數及影像解析度不足所造成。

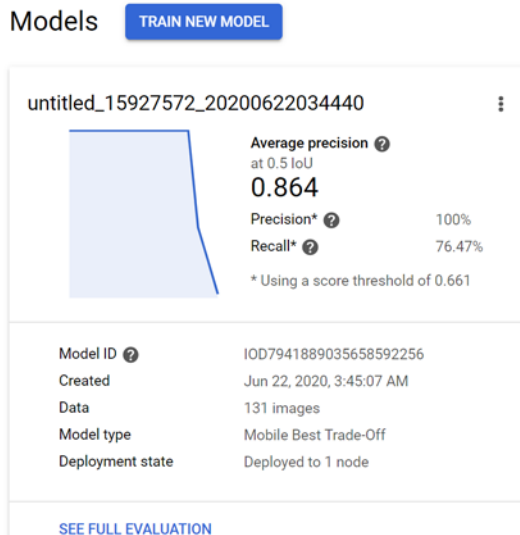


圖 38 完成訓練的模型評估結果

當模型訓練完後，使用者隨時可以使用此模型進行其他影像的物件偵測，圖 39 為輸入兩張統一超商及一張同時具有統一超商及全家便利商店的影像後，模型皆能正確地辨識出 7-Eleven 及 FamilyMart 標籤，然而圖 40 的統一超商影像卻出現無法預測的情形，顯示此模型仍有改善的空間，例如增加訓練樣本數、以及針對不同解析度的影像進行訓練。



圖 39 影像內容預測結果(物件成功偵測)

Test your model

UPLOAD IMAGES

Up to 10 images can be uploaded at a time



圖 40 影像物件(7-Eleven 商標)無法偵測(漏判)

5.3 自行開發程式之結果及驗證

上述利用功能強大的網路線上機器學習服務確實可以達到影像判釋的目的，然而若網路中斷，或是無法連結到這些線上服務時，將無法進行影像判釋。因此本計畫另行撰寫可以用來辨識災害影像之影像辨識模型程式，而用來進行影像辨識的方法卷積神經網路(CNN)。前一節所述的資訊大廠除了提供線上機器學習服務之外，事實上也推出許多機器學習框架(backend)，如 Google 的 TensorFlow、Microsoft 的 CNTK (Cognitive Toolkit)、Amazon 的 MXNet、以及 Facebook 的 Torch 等。這些框架大都提供開源(open source)的程式庫(library)，支援多種程式語言，如 C++、Java、R 語言、以及 Python 等，而且安裝方便。開發者只要根據自己的應用需求，引用適當的模型訓練方式，可以很快地建立自己的應用程式或是開發系統。圖 41 所示為各框架於 GitHub 的活躍程度，其中 Google TensorFlow 雖然較晚推出，但因其具有很高的支援性及擴展性，很快就成為最受歡迎的機器學習框架。此外，TensorFlow 可以充分應用許多硬體資源，包括 CPU、GPU、TPU 等，其中 TPU 為 Google 專門用來執行 TensorFlow 的一個服務，這使得 TensorFlow 具有相當不錯的程式執行效能及擴展性。因此本計畫主要以 Google TensorFlow 為基礎，並採用架構在此框架之上的 Keras 為主要的程式開發核心，所使用的程式語言則為 Python。




圖 41 各種機器學習框架於 GitHub 的活躍程度(來源：Google)

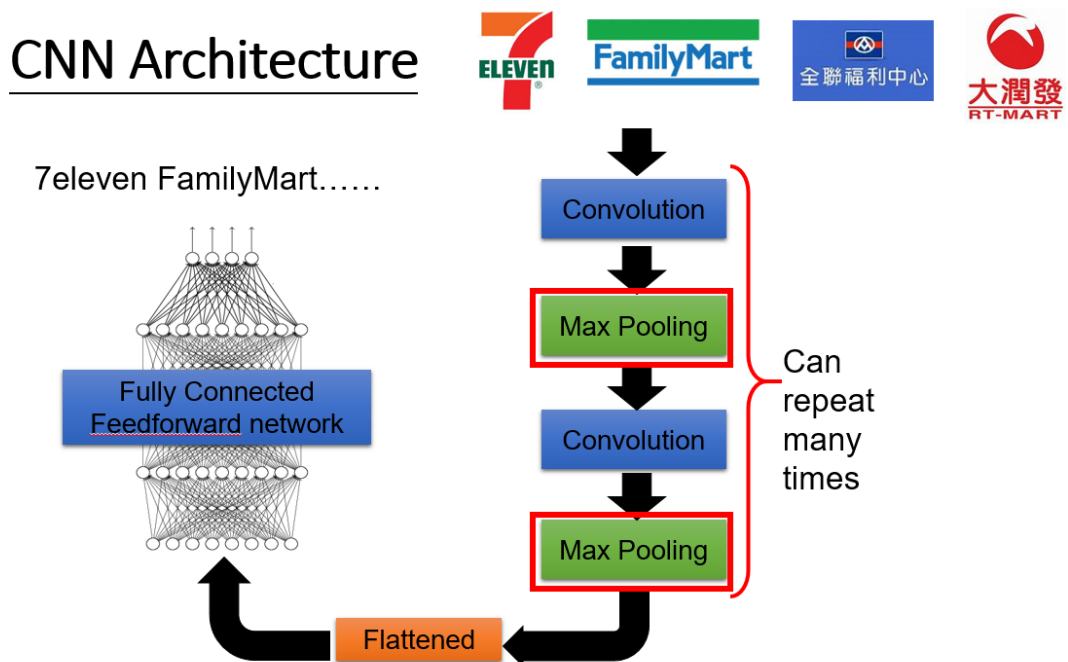


圖 42 本研究所使採用的卷積神經網路(CNN)

圖 42 所示為本計畫進程式開發時所採用的卷積神經網路 (CNN)基本架構圖，欲辨識的對象主要為漢堡王(Burgerking)、麥當勞 (McDonalds)、肯德基(KFC)、屈臣氏(Watson)、中油(CPC)及台塑石油等(Formosa)等六個商標。如同第三章所述，此網路架構由特徵偵測層與全連結層所構成，前者主要用來進行特徵萃取、而後者用來進行影

像辨識。圖 43 所示為本實驗於特徵偵測層的一些參數設定，包括設定輸入的影像大小為 128×128 、影像主要還是以三波段彩色影像為主，而在池化的部分則選用最大值池化(max pooling)。圖 44 所示為本實驗使用 Keras 實現此 CNN 架構的示意圖，主要由三個特徵萃取層及一個全連結層所構成，整個模型的參數設定及參數數量則顯示於圖 45 中。圖 46 所示為本實驗用來進行訓練的影像儲存路徑示意圖，與前一小節一樣將影像樣本分成訓練集、驗證集、及測試集。由於實驗影像蒐集不易，為了增加影像的數量，在機器學習中常見的作法是對既有影像進行擴增(image augmentation)，如圖 47 所示，藉由對原始影像進行旋轉、加入雜訊、或是對影像進行切割後，原始影像可以擴增出 6 張影像。本實驗依此方式，讓每一個標籤皆具有 1000 張影像，訓練時以隨機的方式選取其中 4500 張影像進行訓練，1100 張影像進行驗證，600 張影像用來進行測試，圖 48 顯示模型訓練後的結果，可以發現訓練集的準確度可達 91.71%，驗證集的準確度則在第 23 個 epoch 達到 98.75%，但隨即在第 25 個 epoch 時降到 77.05%顯示此模型在超過 23 個 epoch 後開始出現過度擬合的現象。

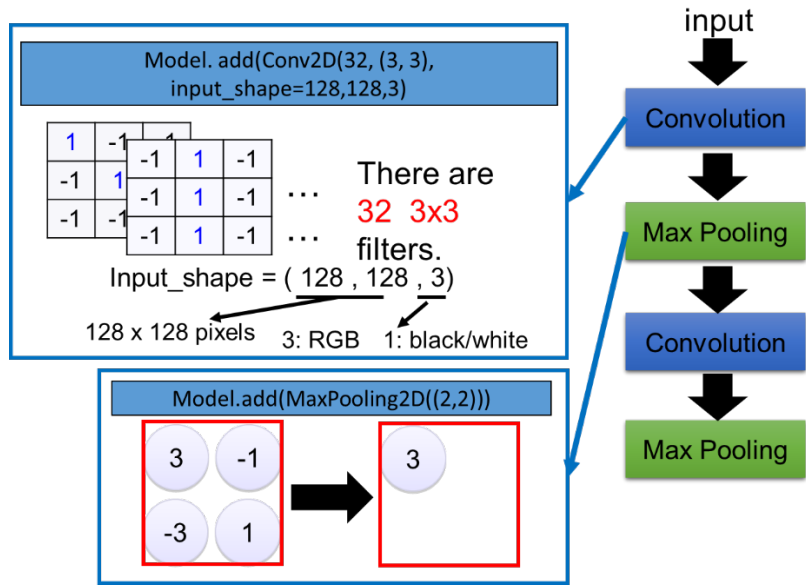


圖 43 特徵偵測層的基本參數設定

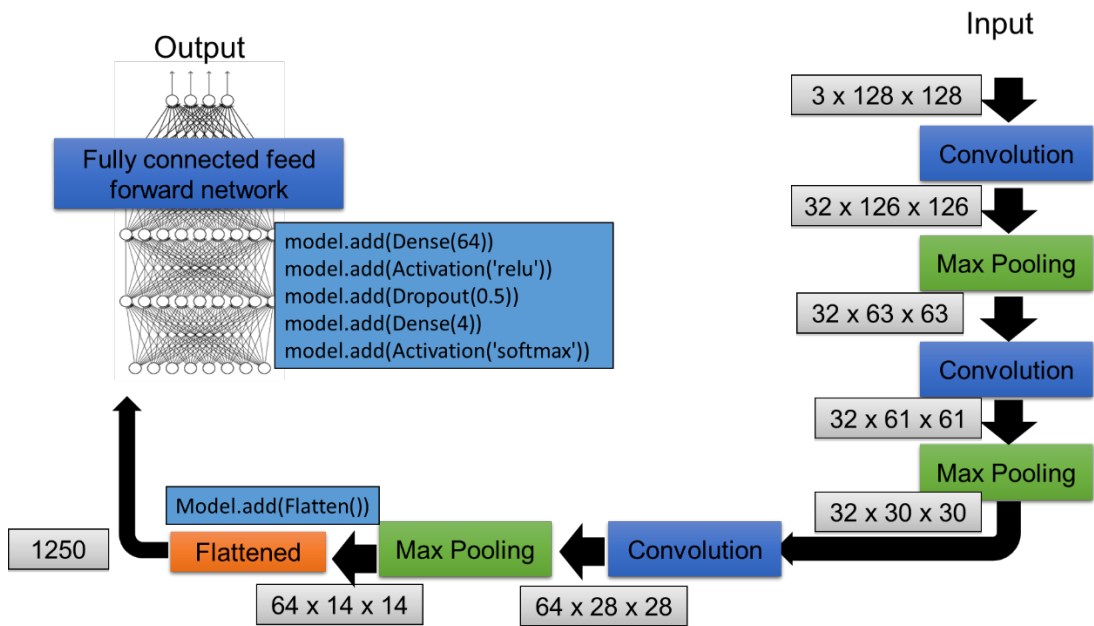


圖 44 本研究所使採用的卷積神經網路(CNN)

In [9]: `model.summary()`

Layer (type)	Output Shape	Param #
conv2d_1 (Conv2D)	(None, 126, 126, 32)	896
activation_1 (Activation)	(None, 126, 126, 32)	0
max_pooling2d_1 (MaxPooling2)	(None, 63, 63, 32)	0
conv2d_2 (Conv2D)	(None, 61, 61, 32)	9248
activation_2 (Activation)	(None, 61, 61, 32)	0
max_pooling2d_2 (MaxPooling2)	(None, 30, 30, 32)	0
conv2d_3 (Conv2D)	(None, 28, 28, 64)	18496
activation_3 (Activation)	(None, 28, 28, 64)	0
max_pooling2d_3 (MaxPooling2)	(None, 14, 14, 64)	0
flatten_1 (Flatten)	(None, 12544)	0
dense_1 (Dense)	(None, 64)	802880
activation_4 (Activation)	(None, 64)	0
dropout_1 (Dropout)	(None, 64)	0
dense_2 (Dense)	(None, 4)	260
activation_5 (Activation)	(None, 4)	0

Total params: 831,780
Trainable params: 831,780
Non-trainable params: 0

圖 45 模型相關參數設定

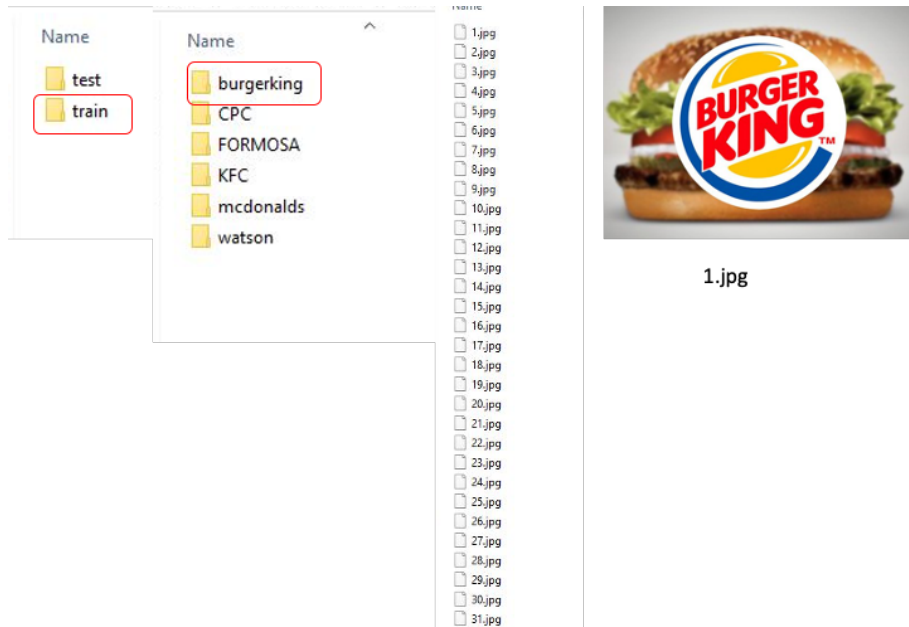


圖 46 影像訓練樣本的收集與分群



圖 47 影像擴增成果




圖 48 模型訓練時之訓練集與驗證集準確度與損失值

當模型訓練完成後，便可利用此模型進行影像辨識。本實驗所訓練的模型能判釋出正確的內容並輸出相對相對應的標籤，此標籤將可以當作下一章用來搜尋 POI 資料庫的關鍵字。

5.4 綜合評估

本小節綜合上述 Google Cloud Vision、Google AutoML Vision、及自行開發程式之適用性及效能。

Google Cloud Vision 功能非常強大，能同時辨識影像中的標籤、進行文字辨識(OCR)、偵測地標、公司標誌等多重功能。Google Cloud Vision 在使用上並無特別限制，使用者無需特別預先對模型進行訓練，但進行影像辨識時，須依照影像數量收費，收費方式詳 <https://cloud.google.com/vision/pricing>，此外其模型並非針對本研究之空間定位應用所訓練，因此所判釋出的結果可能非本研究所需之資訊。相對於 Cloud Vision，AutoML Vision 可讓使用者預先訓練與特定應用相關的模型，且提供簡單明瞭的 GUI 介面，方便使用者對自己的資料進行訓練、評估、改善模型佈署。AutoML Vision 目前仍為測試版，提供使用者 300 美金的免費額度，正式版的收費標準則尚未公布。相對於線上機器學習服務，本研究自行開發之程式將更具彈性，且可以在沒有網路環境的狀況下執行，但需要較佳的硬體設備進行模型的訓練及學習。

在模型訓練時及影像判釋效率方面，若針對模型學習與訓練，Cloud Vision 為 Google 預先訓練過的模型，實際應用時無須自行訓

練；AutoML Vision 在類別樣本數各為 100 的情況下，訓練時間大約 4 分鐘；自行開發程式在類別樣本數各為 1000 的情況下，訓練時間則大約為 19 分鐘(1131 秒)。若考量模型的學習時間，此三者影像判釋速度上皆小於 1 秒。

第六章 結論與未來展望

自然災害常對於人類健康安全、財產、基礎設施以及國土安全構成威脅，包括颱風、地震、土石流、洪水等等，這些災害事件常在不可預測的時期發生，造成人類生活的重大影響，因此，即時訊息對於自然災害事件發生期間和之後的預警就變得至關重要。但過去發生重大天然災害時，救援單位常會陷入資訊超載而無法即時有效傳遞並處理災情，且資料數量十分龐大。本研究針對社群媒體文字訊息空間定位分析進行研究，導入社群網路上所散播的災害訊息資訊，利用社群媒體中，民眾所上傳的文字敘述進行災情的研判，並制定文字資料分析流程，以利未來於實際災害發生時，可利用社群網路上的即時災害文字資訊進行災害的初步位置定位，以輔助災害應變的決策支援。本研究使用長短期記憶 (Long short-term memory, LSTM) 當作主要的神經網路模型，以社群網站收集新聞以及社群言論為分析對象，進行文字的空間定位分析方法研發，首先蒐集及彙整災害地點現地媒體資料與相關災害訊息，接著進行資料前處理，包括人工標記資料、文本分詞、數字序列的轉換和處理，將資料輸入神經網路進行訓練與測試、標記相關災害地名與地標，最後檢視定位的結果。

本研究利用不同的評量指標驗證使用的模型能有效地判別留言

中有無地名或地標；透過訓練資料量與詞彙量對預測結果之比較，得知當資料筆數慢慢增加的情況下，訓練資料量能使準確率增加的幅度增大，因此適時地增加訓練資料量可增加預測效果，避免同時增加詞彙量和訓練資料量，節省大量的人力與時間；為了比較不同社群平台之有效留言，本研究使用臺灣常使用之社群平台留言，包括三種平台，結果顯示若資料來源為電子佈告欄時的有效留言的數量為最多，因此災害發生時可適時地針對電子佈告欄之災害留言進行收集，避免收集過多社群網站之無效留言；本研究同時對災害留言進行分析，找出臺灣之災害留言常出現的臺灣縣市和路段，透過縣市來驗證臺灣災害發生的區域排行，以及找出特定路段出現之重複性，在災害發生前加強重點地方的災害防治。本研究方法於實際災害發生時，可利用社群網路上的即時災害文字資訊進行災害的初步位置定位，以輔助災害應變的決策支援分析，並在災害地名判定上，減少大量的人力與時間。

本研究在實驗的過程中，發現許多相關災害留言的特性，例如在社群媒體的留言中，與一般文字訊息不同的是社群媒體常存在口語化的詞彙於留言中，可能只有當地人或者熟悉此區域的人會知道的口語化詞彙，例如「光復路新郵局附近有淹水嗎」、請問「張家食堂那條路有淹水嗎」、「台北車站」，口語常會表示為「北車」；「國立台北科

技大學」，本校生或者熟悉此學校的人常會表示為「北科大」；「桃園機場」，網路上常將其口語化為「國家門面」；或者某些字彙可能會出現特殊的寫法，以數字代替文字的地名，例如「3 多四維」、「臺 21 線」；某些字彙可能會以簡寫方式代替原本地名的寫法，例如「台北市」表示為「北市」、「高雄市」表示為「高市」，上述表達災害留言之方式可能會導致模型在預測結果發生誤判，建議未來的研究可以針對此類特殊留言方式作進一步的處理。

本研究建議未來的研究方向可以加入情緒分析，在原始資料中定義正面強度和負面強度值，透過文字中正面和負面的情緒計算，可判斷特定句子之真正語意，同時過濾掉龐大資料庫內的無關災害之資訊，包括常出現只標記人名的留言，例如「Jing Ting」、無關乎災害的垃圾訊息，例如「沒困飽」，或者非真正表達實際災害發生地點之文句，例如「台北有淹水嗎？」，皆可視為無用資訊並直接忽略；本研究利用 Google Maps 提供的 Geocoding API 來檢視每組地名的定位，並使用該地理坐標在地圖上放置標記或定位地圖，但 Geocoding API 只能在同一則留言中檢視一組地名或地標，如果同一則留言有多組地名或地標，將無法對多組災害地名進行定位，建議未來研究可加入精進的方法，讓一則留言中可檢視多組地名或地標的定位。另外在神經網路

方面，可挑選精進的神經網路或者改良原始網路結構，使得預測準確率能增高，希望未來能基於本研究方法之基礎，更進一步地進行此研究，使災害防治的應用能夠更加完善與便利。

本研究導入社群網路上所散播的災害訊息資訊，利用社群媒體中，民眾所拍攝的影像來進行災情的研判，並制定影像分析流程，以利未來於實際災害發生時，可利用社群網路上的即時災害影像資訊進行災害的初步位置定位，以輔助災害應變的決策支援。本年度已順利完成相關文獻與方法彙整、POI 基礎資料庫蒐集與彙整、災害地點現地相片與相關災害訊息蒐集及彙整，以及空間定位方法研發、流程設計與定位結果驗證等工作項目，研究結果顯示利用機器學習演算法確實可以進行災害影像的分析及辨識，其正確率皆高達 90% 以上，其結果可與其他關鍵字結合後進行影像定位及災情位置的展示。

本研究目前僅針對十個品牌商標進行判釋，若要增加影像可判釋的內容範圍，必須再蒐集更多的影像樣本，並對本研究已經建立的模型進行更進一步的訓練。此外，除了影像辨識結果之外，社群媒體的另一個重要資訊為網路文章資訊，未來將朝向結合文字語意分析技術，並搭配影像辨識成果，達到災害情資多元空間定位的目標。

參考文獻

- Adeva, J. G., Atxa, J. P., Carrillo, M. U., & Zengotitabengoa, E. A. J. E. S. w. A. (2014). *Automatic text classification to support systematic reviews in medicine*. 41(4), 1498-1508.
- Aipe, A., Mukuntha, N., Ekbal, A., & Kurohashi, S. (2018). *Deep Learning Approach towards Multi-label Classification of Crisis Related Tweets*. Paper presented at the Proceedings of the 15th ISCRAM Conference.
- Bafna, P., Pramod, D., & Vaidya, A. (2016). *Document clustering: TF-IDF approach*. Paper presented at the 2016 International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT).
- Barbier, G., & Liu, H. (2011). *Data mining in social media*. In Social network data analytics (pp. 327-352): Springer.
- Berger, C. (2014). *From a Competition for Self-Driving Miniature Cars to a Standardized Experimental Platform: Concept, Models, Architecture and Evaluation*. *Journal of Software Engineering for Robotics*, 5(1), 63-79.
- Brooks, C. H., & Montanez, N. (2006). *Improved annotation of the blogosphere via autotagging and hierarchical clustering*. Paper presented at the Proceedings of the 15th international conference on World Wide Web.
- Brynielsson, J., Granåsen, M., Lindquist, S., Narganes Quijano, M., Nilsson, S., Trnka, J. J. J. o. C., & Management, c. (2018). *Informing crisis alerts using social media: Best practices and proof of concept*. 26(1), 28-40.
- Cervone, G., Sava, E., Huang, Q., Schnebele, E., Harrison, J., & Waters, N. J. I. J. o. R. S. (2016). *Using Twitter for tasking remote-sensing data collection and damage assessment: 2013 Boulder flood case study*. 37(1), 100-124.
- Cheng, G., Zhou, P., & Han, J. (2016). *Learning Rotation-Invariant Convolutional*

- Neural Networks for Object Detection in VHR Optical Remote Sensing Images.* IEEE Transactions on Geoscience and Remote Sensing, 54(12), 7405-7415. doi:10.1109/TGRS.2016.2601622
- Choi, D., Matni, Z., Shah, C. J. P. o. t. A. f. I. S., & Technology. (2016). *What social media data should i use in my research?: A comparative analysis of twitter, youtube, reddit, and the new york times comments.* 53(1), 1-6.
- Cormack, G. V., Gómez Hidalgo, J. M., & Sáenz, E. P. (2007). *Spam filtering for short messages.* Paper presented at the Proceedings of the sixteenth ACM conference on Conference on information and knowledge management.
- Dertat, A. (2017). *Applied Deep Learning - Part 4: Convolutional Neural Networks.* Towards Data Science. Retrieved from <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2>
- Farinosi, M., & Treré, E. J. T. J. o. C. I. (2010). *Inside the " People of the Wheelbarrows": participation between online and offline dimension in the post-quake social movement.* 6(3), 2010.
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. J. A. m. (1996). *From data mining to knowledge discovery in databases.* 17(3), 37-37.
- Felt, M. J. B. D., & Society. (2016). *Social media and the social sciences: How researchers employ Big Data analytics.* 3(1), 2053951716645828.
- FU, J.-l., & CHEN, Q.-x. J. J. o. C. I. P. (2005). *Study on Topic Partition in Automatic Abstracting System.* 19, 28-35.
- Gaikwad, S. V., Chaugule, A., & Patil, P. J. I. J. o. C. A. (2014). *Text mining methods and techniques.* 85(17).
- Garcia, C., & Delakis, M. (2004). *Convolutional face finder: a neural architecture for fast and robust face detection.* IEEE Transactions on Pattern Analysis and

- Machine Intelligence, 26(11), 1408-1423.
- Goldberg, Y. J. S. L. o. H. L. T. (2017). *Neural network methods for natural language processing*. 10(1), 1-309.
- Goodchild, M. F., & Glennon, J. A. J. I. J. o. D. E. (2010). *Crowdsourcing geographic information for disaster response: a research frontier*. 3(3), 231-241.
- Graves, A. J. a. p. a. (2013). *Generating sequences with recurrent neural networks*.
- Gupta, R., & Ratnoff, L.-A. (2008). *Text Categorization with Knowledge Transfer from Heterogeneous Data Sources*. Paper presented at the AAAI.
- He, Q., Chang, K., Lim, E.-P., Banerjee, A. J. I. T. o. P. A., & Intelligence, M. (2010). *Keep it simple with time: A reexamination of probabilistic topic detection models*. 32(10), 1795-1808.
- Hughes, D. J., Rowe, M., Batey, M., & Lee, A. J. C. i. H. B. (2012). *A tale of two sites: Twitter vs. Facebook and the personality predictors of social media usage*. 28(2), 561-569.
- Imran, M., Elbassuoni, S., Castillo, C., Diaz, F., & Meier, P. (2013). *Extracting information nuggets from disaster-related messages in social media*. Paper presented at the Iscram.
- Kaplan, A. M., & Haenlein, M. (2009). *Users of the world, unite! The challenges and opportunities of Social Media*. Business Horizons, 53(1), 59-68.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). *ImageNet classification with deep convolutional neural networks*. Paper presented at the Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1, Lake Tahoe, Nevada.
- Kryvasheyeu, Y., Chen, H., Obradovich, N., Moro, E., Van Hentenryck, P., Fowler, J., & Cebrian, M. J. S. a. (2016). *Rapid assessment of disaster damage using social*

media activity. 2(3), e1500779.

- Kumar, A., & Singh, J. P. J. I. j. o. d. r. r. (2019). *Location reference identification from tweets during emergencies: A deep learning approach*. 33, 365-375.
- Kumar, S., Barbier, G., Abbasi, M. A., & Liu, H. (2011). *Tweettracker: An analysis tool for humanitarian and disaster relief*. Paper presented at the Fifth international AAAI conference on weblogs and social media.
- Kubat, M. (2015). *An Introduction to Machine Learning*. Cham: Springer.
- LeCun, Y., Bengio, Y., & Hinton, G. J. n. (2015). *Deep learning*. 521(7553), 436-444.
- LeCun, Y., Boser, B. E., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. E., & Jackel, L. a. D. (1990). *Handwritten Digit Recognition with a Back-Propagation Network*. Paper presented at the Neural Information Processing Systems 1998.
- Liu, P., Qiu, X., Chen, X., Wu, S., & Huang, X.-J. (2015). *Multi-timescale long short-term memory neural network for modelling sentences and documents*. Paper presented at the Proceedings of the 2015 conference on empirical methods in natural language processing.
- Long, Y., Gong, Y., Xiao, Z. h., & Liu, Q. (2017). *Accurate Object Localization in Remote Sensing Images Based on Convolutional Neural Networks*. IEEE Transactions on Geoscience and Remote Sensing, 55(5), 2486-2498. doi:10.1109/TGRS.2016.2645610
- Lu, R., Zhu, H., Liu, X., Liu, J. K., & Shao, J. J. I. N. (2014). *Toward efficient and privacy-preserving computing in big data era*. 28(4), 46-50.
- Middleton, S. E., Middleton, L., & Modafferi, S. J. I. I. S. (2013). *Real-time crisis mapping of natural disasters using social media*. 29(2), 9-17.
- Mills, A., Chen, R., Lee, J., Raghav Rao, H. J. J. o. I. P., & Security. (2009). *Web 2.0 emergency applications: How useful can Twitter be for emergency response?* , 5(3),

3-26.

Moe, T. L., Pathranarakul, P. J. D. P., & Journal, M. A. I. (2006). *An integrated approach to natural disaster management*.

Munro, R., & Manning, C. D. (2010). *Subword variation in text message classification*.

Paper presented at the Human language technologies: The 2010 annual conference of the north American chapter of the association for computational linguistics.

Neppalli, V. K., Caragea, C., & Caragea, D. (2018). *Deep Neural Networks versus Naive Bayes Classifiers for Identifying Informative Tweets during Disasters*. Paper presented at the ISCRAM.

Nguyen, D. T., Joty, S., Imran, M., Sajjad, H., & Mitra, P. J. a. p. a. (2016). *Applications of online deep learning for crisis response using social media information*.

Olah, C. (2015). *Understanding lstm networks*.

Rawat, W., & Wang, Z. (2017). *Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review*. *Neural Computation*, 29(9), 2352-2449.

Ritter, A., Etzioni, O., & Clark, S. (2012). *Open domain event extraction from twitter*. Paper presented at the Proceedings of the 18th ACM SIGKDD international conference on Knowledge discovery and data mining.

Sakaki, T., Okazaki, M., & Matsuo, Y. (2010). *Earthquake shakes Twitter users: real-time event detection by social sensors*. Paper presented at the Proceedings of the 19th international conference on World wide web.

Sarkar, D., Bali, R., & Sharma, T. (2018). *Practical Machine Learning with Python: A Problem-Solver's Guide to Building Real-World Intelligent Systems*. Berkeley, CA: Apress

Salloum, S. A., Al-Emran, M., Shaalan, K. J. I. J. o. C., & Systems, D. (2017). *Mining social media text: extracting knowledge from Facebook*. 6(02), 73-81.

- Sermanet, P., Kavukcuoglu, K., Chintala, S., & Lecun, Y. (2013). *Pedestrian Detection with Unsupervised Multi-stage Feature Learning*. Paper presented at the Proceedings of the 2013 IEEE Conference on Computer Vision and Pattern Recognition.
- Severyn, A., & Moschitti, A. (2015). *Twitter sentiment analysis with deep convolutional neural networks*. Paper presented at the Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval.
- Spasic, I., Ananiadou, S., McNaught, J., & Kumar, A. J. B. i. b. (2005). *Text mining and ontologies in biomedicine: making sense of raw text*. 6(3), 239-251.
- Starbird, K., & Palen, L. (2011). "*Voluntweeters*" *self-organizing by digital volunteers in times of crisis*. Paper presented at the Proceedings of the SIGCHI conference on human factors in computing systems.
- Struhl, S. (2015). *Practical text analytics: Interpreting text and unstructured data for business intelligence: Kogan Page Publishers*.
- Subasinghe, I., Nittel, S., Cressey, M., Landon, M., & Bajracharya, P. J. I. J. o. G. I. S. (2020). *Real-time mapping of natural disasters using citizen update streams*. 34(2), 393-421.
- Sun, Y., Chen, Y., Wang, X., & Tang, X. (2014). *Deep learning face representation by joint identification-verification*. Paper presented at the Proceedings of the 27th International Conference on Neural Information Processing Systems - Volume 2, Montreal, Canada.
- Sutton, J. N., Palen, L., & Shklovski, I. (2008). *Backchannels on the front lines: Emergency uses of social media in the 2007 Southern California Wildfires*.
- Tan, P.-N., Steinbach, M., & Kumar, V. J. I. t. d. m. (2006). *Classification: basic concepts, decision trees, and model evaluation*. 1, 145-205.

- Travis, E. A., & Sykes, T. F. (2012). *Social Media and Disasters: Uses, Options, Considerations*. New York: Nova Science Publishers.
- Vieweg, S., Hughes, A. L., Starbird, K., & Palen, L. (2010). *Microblogging during two natural hazards events: what twitter may contribute to situational awareness*. Paper presented at the Proceedings of the SIGCHI conference on human factors in computing systems.
- Wang, H., & Ren, M. (2011). *Lane Markers Detection based on Consecutive Threshold Segmentation*. *Journal of Information and Computing Science*, 6(3), 207-212.
- Wartena, C., & Brussee, R. (2008). *Topic detection by clustering keywords*. Paper presented at the 2008 19th International Workshop on Database and Expert Systems Applications.
- Xiao, Y., Huang, Q., & Wu, K. J. N. h. (2015). *Understanding social media data for disaster management*. 79(3), 1663-1679.
- Yin, J., Karimi, S., Lampert, A., Cameron, M., Robinson, B., & Power, R. (2015). *Using social media to enhance emergency situation awareness*. Paper presented at the Twenty-fourth international joint conference on artificial intelligence.
- Yubo, C., Liheng, X., Kang, L., Daojian, Z., & Jun, Z. (2015). *Event extraction via dynamic multi-pooling convolutional neural networks*.
- Zhang, K., Zhang, Z., Li, Z., & Qiao, Y. (2016). *Joint Face Detection and Alignment Using Multitask Cascaded Convolutional Networks*. *IEEE Signal Processing Letters*, 23(10), 1499-1503.
- Zhang, X., Zhao, J., & LeCun, Y. (2015). *Character-level convolutional networks for text classification*. Paper presented at the Advances in neural information processing systems.
- Zomaya, A. Y., & Sakr, S. (Eds.). (2017). *Handbook of Big Data Technologies*. Cham:

Springer.

以機器學習方法與社群媒體訊息應用於災害情資空間定位分析

發行人：陳宏宇

出版機關：國家災害防救科技中心

地址：新北市新店區北新路三段 200 號 9 樓

電話：02-8195-8600

報告完成日期：中華民國 109 年 12 月

出版年月：中華民國 110 年 01 月

版 次：第一版

非賣品

地址：23143新北市新店區北新路三段200號9樓

電話：++886-2-8195-8600

傳真：++886-2-8912-7766

網址：<http://www.ncdr.nat.gov.tw>