


National Yang Ming Chiao Tung University
Department of Transportation & Logistics Management
Working Paper

Traffic Conflict Indicators for Opposing Left-Turn
based on Vehicle Trajectory Data with Prediction

Chun-Kai Kao and Ka Io Wong

Working paper NYCU-TLM-WP-22-016

A handwritten signature in black ink, likely belonging to Chun-Kai Kao, consisting of stylized Chinese characters.

August 14 2022

基於軌跡預測方法下之交通衝突指標探討：以機會左轉為例

Traffic Conflict Analysis for Opposing Left-Turn based on Vehicle Trajectory Data with Prediction

高群凱

黃家耀

摘要

機會左轉情境，是指左轉車與對向直行車同時具有路權的左轉行為，為國內路口中，最容易造成衝突的左轉行為之一。過去評估多是以路口的碰撞資料進行分析；然而近年來，使用人工智慧(Artificial Intelligence, AI)，從影像中擷取路口車輛資料進行分析，逐漸受到學者重視。相較於碰撞資料的分析，具有低成本以及資料龐大等優點。目前最常使用的兩個交通衝突指標，分別是碰撞時間(Time-to-Collision, TTC)以及後侵占時間(Post-Encroachment Time, PET)；實際觀察兩指標運用在左轉與對向衝突中，發現其計算結果，可能會產生低估或高估風險之情形。因此，本研究將基於軌跡預測方法，提出考量車輛變化的角度速度變化法，計算出指標 TTC-SC；以及考量車輛互動的 LSTM 法，計算出指標 PET-L。研究結果顯示，兩個交通衝突指標，於特定左轉行為中，確實能得到比 TTC 與 PET 更能衡量風險情境的指標值。

關鍵詞：交通衝突指標、軌跡預測、機會左轉、無人機、空拍影像

Abstract

Opposing left-turn conflict is the scenario that both left-turn vehicle and opposing straight vehicle have the legal right of way. The reason for using this conflict as our research scenario, is according to the statistics from the ministry of communications in Taiwan, side collision is the most common type of accident, which manifests the value of the safety evaluation of related conflict type. In the past decades, researchers usually evaluate the road safety by collision data. However, by the enhancement of computing power of computer, using the trajectory data, which is extracted from the video data with Artificial Intelligence, has become value in the field of transportation safety recently. Compared to the traditional safety analysis by collision data, it not only spends lower cost, but also get the stable results due to numerous data than original method in the constant period. Time-to-Collision (TTC) and Post-Encroachment(PET) are two of the best-known indicators, and widely used in traffic conflict analysis. However, it might overestimated or underestimated the degree of hazard of conflict events, especially in the scenario of opposing left-turn conflict, by the complex real situation and the unreal prediction method. To tackle with the problems, our research proposes two advanced indicators based on the different trajectory prediction methods, which take the changing of vehicle status and the road geometry facilities into account. As stated by research results, the advanced indicators are more adapted than TTC and PET, to better measure the hazard in specific type of opposing left-turn conflict.

Keywords: Traffic Conflict Indicators, Trajectory Prediction, Opposing Left-Turn Conflict, Unmanned Aerial Vehicle (UAV), Aerial video

一、研究背景

根據世界衛生組織(World Health Organization, WHO)所公布的 2019 年死亡數據統計中顯示，交通事故是除了醫療相關疾病外，造成人類死亡占比最高的原因之一，並且在低收入、中低收入及中高收入國家，皆排名為前十名行列。其一年約會造成 1300 萬人死亡，以及使 2000 到 5000 萬人受到傷害。因此，交通安全也成為運輸領域中，相當重視的一個部分。

傳統的交通安全分析方法，是以分析該路口之交通事故統計資料進行分析。然而事故統計資料會因肇事雙方是否有通知交通執法人員進行紀錄，或是記錄格式是否具有一致性等影響，導致資料的可靠性降低。除此之外，碰撞事件在單一路口不會時常發生，因此研究人員往往需要長時間的資料蒐集，才可以有足夠的資料數目對路口安全進行分析。

為了降低研究的成本以及增加資料的穩定性，一種使用中介指標(Surrogate indicator)去替代事故統計資料的新方法開始受到研究人員的重視。此方法主要是藉由中介指標去量化衝突發生的次數，並以衝突次數作為安全分析所使用的資料。這樣的做法不只大幅度降低蒐集資料所需的時間成本外，也因資料筆數較多，使得後續所得到的分析結果更加穩固。

在眾多的中介指標當中，又以其中兩個指標所使用的頻率最高，分別是碰撞時間(Time-to-Collision, TTC)及後侵占時間(Post-Encroachment time, PET)。碰撞時間是使用固定角度速度法預測軌跡資料，並計算兩車將會發生碰撞的時間；而後侵占時間，則是使用真實軌跡資料，計算兩車駛入及駛出軌跡交會區域的時間差。然而此兩指標在實際運用上，並不能完全反應出路口之間的衝突情形。為了能夠蒐集到更為精確的衝突資料，本研究將會提出運用不同的軌跡預測方法，進行中介指標的計算，期望能夠得到更符合真實衝突情形的指標。

「機會左轉」是指左轉車與對向直行車同時具有路權的左轉行為。本研究之研究範圍為臺灣的市區道路，根據臺灣交通部道安資訊平台所提供之民國 109 年車與車事故類型及型態的資料顯示，總計約 30 萬個碰撞事件中，有約 11 萬個事件為「車與車側撞」所導致，佔所有事故類型中比例最高，約 36%；並且「車與車側撞」的事件數相較民國 108 年，增加了約 8%。此結果不僅說明「車與車側撞」是最常見的事故類型外，且發生的次數也仍在增加。路口轉向衝突即是發生車與車側撞之衝突類別，且如上述所述，可以知道此衝突具有高度評估安全之價值；而機會左轉需要駕駛人自行判斷車輛的接受間距，更是路口轉向衝突中，難以單純利用肇事事事件所評估之衝突行為。除此之外，與直行車輛之軌跡預測相比，轉彎車輛還需考慮轉向角度，其難度更甚於預測直行車輛。依上述所論，本研究將會以機會左轉作為分析情境，並使用不同的預測軌跡方法，進行軌跡預測，藉此計算出我們所要探討的交通衝突指標。

綜合上述，本研究將針對臺灣具有機會左轉事件之路口，利用不同的軌跡預測方法，分別進行左轉車與直行車的軌跡預測，並使用預測的軌跡資料進行交通衝突指標計算，最後根據計算結果，探討不同的交通衝突指標用來評估路口安全性上的差異。

二、文獻回顧

2.1 傳統常用之交通衝突指標

目前文獻及研究當中使用最為廣泛的交通衝突指標分別為碰撞時間(time-to-collision)以及後侵占時間(post-encroachment time)，也是本研究將使用之指標。後侵占時間(post-encroachment time, PET)之定義為第一個道路使用者離開路徑及第二個道路使用者進入路徑的時間差。其指標不但考量到碰撞事件，同時也將瀕臨撞擊(near-misses)事件衡量在內(Horst et al., 2014)；碰撞時間(time-to-collision, TTC)定義為，兩車在維持相同的速度差及方向的情況下，將會在時間 t

秒發生碰撞(Hyden, 1987)。圖 2. 1 是利用兩車所在的位置來描述碰撞時間之計算方法，而其中的 t (instant t) 也就是我們所要計算的數值。




圖 2. 1 兩車碰撞時間圖

資料來源：Minderhoud & Bovy (2001)

無論是使用碰撞時間(TTC)亦或是後侵占時間(PET)，其嚴重程度的衡量方式大多是以設定臨界值(critical value)作為一個門檻(threshold)，當指標所計算出來的值小於門檻值時，即會視為一個衝突事件。除此之外，門檻值會受不同地域的駕駛型態影響，而有不同之數值。以碰撞時間為例，美國為 1.0 秒，瑞典則為 1.5 秒(Horst, 2014)，並且除了單一門檻值外，有些研究也會設定多個門檻值，做為嚴重程度之區分依據。如中國研究學者項喬君等人(2008)的研究當中，將門檻值設為 1.0 秒以及 2.0 秒，當 $TTC \leq 1.0$ 秒時視為嚴重衝突；而當 $1.0 \text{ 秒} < TTC \leq 2.0$ 秒時視為一般衝突。Alhajyaseen(2014)的研究是以 5.0 秒作 PET 之臨界值；而 Tageldin and Sayed(2016)則是將門檻值設為 1.5 秒以及 3.0 秒，當 $PET \leq 3.0$ 秒時為衝突之依據， $PET \leq 1.5$ 秒時則視為嚴重衝突。

考量到上述回顧內容，以及分析地點與資料取得來源；本研究將參考溫基信等人(2021)，同樣使用臺灣路口資料，所訂定的指標門檻值。以 1.0 秒做為嚴重衝突與一般衝突之區分門檻值，2.0 秒做為一般衝突與輕微衝突之區分門檻值，3.0 秒做為輕微衝突與無衝突之區分門檻值。

2.2 左轉車之接受間距

本研究以機會左轉情境作為研究分析對象，而此情境下的左轉車輛，需要自行判斷間距進行左轉行為；為了能夠更清楚其間距選擇的影響因素為何，此處進行接受間距的相關文獻回顧。

Davis and Swenson(2004)利用羅吉特模型(Logit model)，進行左轉車輛接收間距的研究。其結果顯示，對向直行車到路口的距離是最為顯著的影響變數，而對向直行車的速度(Speed)、以及到達路口的時間(time to arrival)僅會造成些微影響。Zohdy 等人(2010)探討左轉車於路口的等待時間(waiting time)，以及降雨強度(rain intensity)對接收間距的影響。其結果顯示，等待時間增加將會使駕駛人的行為變得激進，而降低左轉的接受間距；而降雨強度的增加，則會使駕駛人的行為較為保守，而增價左轉的接受間距。Lee 等人(2016)使用韓國的路口資料，建立左轉車的接受間距模型。其結果顯示，間距與左轉車車種將會顯著影響其接受間距。當間距增加時，將會提升左轉車進行左轉行為的機率；當車種為大型車(公車、貨車等)時，同樣也會增加左轉車進行左轉行為的機率。Zhou 等人(2017)探討幹道左轉車在非號誌化路口的接受間距影響因素，其結果顯示，幹道的車道數並不顯著影響駕駛人的接受間距，反而是駕駛人拒絕間距的

數量、以及在路口的等待時間，呈現顯著影響接受間距的結果。

綜合上述內容可知，關於左轉車之接受間距，除了自身的駕駛特性以及車種以外，也會受到對向車輛狀態、以及氣候等因素影響。考量本研究會以 LSTM 法進行模型學習，將會參考上述文獻回顧，作為變數的選擇依據之一。

2.3 車輛軌跡預測方法

隨著電腦運算速度的提升以及人工智慧技術的進步，目前已可從影片資料中擷取出車輛的微觀軌跡資料。此資料除了能夠進行交通衝突指標的計算外，也具有諸多其他分析價值。其中一個最具價值且與交通衝突指標相關的分析項目為軌跡預測，軌跡資料使得此分析項目能用更多方法(如深度學習等)，而得到更為準確之預測結果。本研究即是基於不同的軌跡預測方法，提出改良指標；為了能對預測方法有更深入地了解，將在以下進行車輛軌跡預測方法的文獻回顧。

Lefèvre 等人(2014)整理了軌跡預測之方法，並分為物理運動模型(Physics-based motion models)、機動運動模型(Maneuver-based motion models)以及感知互動運動模型(Interaction-aware motion models)。物理運動模型為車輛預測僅考慮物理特性，意即車輛會隨著當下的瞬間車速以及車角度進行預測；機動運動模型除了考量本身的物理特性外，更加上駕駛人與道路環境間的互動；最後的感知互動運動模型則是在機動運動模型的基礎下，考量駕駛人之間的互動關係，為三種裡面最為複雜，但其預測結果最符合現實之模型。

為了能夠更清楚知道軌跡預測模式的發展，本研究整理了近年來軌跡預測的相關文獻，並整理成下表：

表 2. 1 近年來軌跡預測之文獻整理表

作者	預測物體	預測地點	使用資料	預測方法
Bahari et al. (2021)	汽車	市區道路	軌跡資料	Knowledge-driven、Data-driven
Lin et al. (2021)	汽車	高速公路	軌跡資料	Spatial-temporal LSTM
Choi et al. (2019)	汽車	市區道路	軌跡資料	Attention-based LSTM
Huang et al. (2019)	汽車	市區道路	軌跡資料	Gaussian Mixture model
Sadeghian et al. (2019)	行人	人行道	軌跡資料	LSTM + Social pooling
Deo & Trivedi (2018)	汽車	高速公路	軌跡資料	LSTM + Social pooling
Park et al. (2018)	汽車	高速公路	軌跡資料	LSTM
Florent & Fortelle (2017)	汽車	高速公路	軌跡資料	LSTM
Alahi et al. (2016)	行人	人行道	軌跡資料	LSTM + Social pooling
Wiest et al. (2012)	汽車	市區道路	軌跡資料	Gaussian Mixture model

於表 2. 1 可以知道，無論預測物體或地點為何，所使用的分析資料皆為軌跡資料。並且隨著巨量資料的蒐集以及電腦計算能力的增加，近年來越來越多使用資料驅動(Data-driven)的預測方法，特別是以長短期記憶模型(LSTM)作為主要的模式架構。因此，本研究將參考研究趨勢，嘗試使用 LSTM 模型架構進行軌跡資料之預測，期望能夠得到更為準確之預測軌跡。

2.4 軌跡預測對交通衝突指標計算之影響

Mohamed 等人(2017)於機會左轉情境中，使用固定速度法(Constant Velocity Method, CV)、常態適應法(Normal Adaption Method, NA)以及運動型樣匹配法(Motion Pattern Matching Method)，進行軌跡預測方法對指標計算結果影響之研究。固定速度法即為常用之交通衝突指

標—TTC 所使用之預測方式，意即車輛加速度及轉向角度不變下的預測軌跡；常態適應法為考慮駕駛人在行駛時，其轉向角度以及加速度皆會有些微變動的情形，因此在使用軌跡預測模式時，因將此現象納入考慮；運動型樣匹配法，是將待預測的軌跡，以序列的方式，與過去真實軌跡比較。藉由最長共同子序列(Longest common sub-sequence, LCSS)的方法，計算待預測軌跡與真實軌跡之距離，並選取距離最相近的軌跡作為預測軌跡。其結果顯示，不同的預測方法確實會影響指標的計算結果，進而改變得到的衝突數量；除此之外，不只證明交通衝突指標分析方法將可以得到與碰撞事件數同樣的趨勢，也證明可靠的軌跡預測方法對交通衝突指標安全分析具有一定的重要性。

2.5 小結

綜合以上回顧，可以知道交通衝突指標安全分析中，目前最常用的指標為 TTC 以及 PET；然而此兩指標實際應用在左轉與對向衝突中，仍無法完全表達此衝突情境下所蘊含的資訊。已知軌跡預測方法將會影響交通衝突指標之計算結果，在傳統常用的兩指標當中，PET 是使用真實軌跡，不受預測方法而影響；TTC 則是使用物理運動模型方法進行預測，其預測結果除了無法反映出駕駛人與道路之間的互動關係，更無法考量駕駛人之間的互動關係。為了能夠得到更為精確地預測軌跡，本研究將參考目前常用的 LSTM 模型進行軌跡預測，並且基於感知互動模型，除了考量左轉車車輛資訊外，也將對向直行車車輛資訊以及號誌資訊一併納入，使得預測結果能夠考量駕駛人間的互動關係，進而增加預測精準度。期望藉由更準確的軌跡預測結果，計算出改良指標，使得交通衝突指標分析方法運用在左轉對向衝突中，能夠得到與現實更為相符的分析結果。

三、研究方法

本研究之研究方法可以分成四個方向，分別是計算所使用之軌跡資料處理、適合機會左轉情境之軌跡預測方法、交通衝突指標之計算方法以及最後的結果分析。軌跡預測與交通衝突指標的計算皆會使用微觀軌跡資料進行分析，為了瞭解資料的品質，在分析前，會先量化軌跡資料的正確性，並根據使用需求，盡可能地提高資料品質；研究最後會根據不同的交通衝突指標計算結果，提出軌跡預測方法之準確度分析以及微觀談討不同交通衝突指標運用在交通衝突分析上之差異，其架構可以參考下方圖 3.1。




圖 3. 1 研究架構圖

3.1 軌跡資料之篩選與處理

本研究使用之資料來自交通部運研所計畫《路口俯視攝影技術於交通衝突分析之案例應用與比較》(溫基信等人, 2020)以及《以無人機探勘人車流動資訊之應用情境規劃與先導測試(1/3)》(溫基信等人, 2021)。該計畫是使用空拍機至多個路口上方進行正射攝影, 並且受限於空拍機的電池容量, 一次拍攝的影片時間約為 10-15 分鐘, 而一個路口將會進行 2-4 次拍攝。接著會將蒐集到的影像資料, 進行車輛偵測以及追蹤之資料萃取。車輛的偵測是使用 Yang 等人(2019)提出的 SCRDet 架構, 結合目前小型物件偵測中, 最為普及之一的 YOLOv4 架構(Bochkovskiy 等人, 2020), 所產生的綜合方法。SCRDet 是基於 Faster R-CNN 之基礎進行修改, 其架構主要分為精細採樣與特徵融合網路層(Finer Sampling and Feature Fusion Network, SF-Net)、多維度特徵注意力網路層(Multidimensional Attention Network, MDA-Net)、旋轉分支網路(Rotation Branch)以及損失函數(Loss function)四個部分, 如圖 3. 2 所示。實際使用上, 是透過 SCRDet 偵測出具方向性的四輪車輛矩形範圍, 再以 YOLOv4 進行兩輪車輛(小型物件)的矩形範圍偵測, 即可得到表示各車輛的長寬的物件框格(bounding box), 如圖 3. 3 所示。




圖 3. 2 SCRDet 之架構圖

資料來源: Yang et al. (2019)




圖 3. 3 車輛偵測示意圖

資料來源: 溫基信等人 (2021)

然而現階段使用人工智慧所萃取之資料, 尚會產生一定誤差, 像是車輛追蹤誤差, 導致軌跡出現斷軌等錯誤。為了能夠避免此類錯誤對於分析結果的影響, 本研究會排除未完整通過路口的軌跡資料, 並且進行資料處理, 以提升後續分析的有效性。以下進行其詳細說明。

3.1.1 資料篩選

於運研所計畫中, 共進行了 11 個與機會左轉事件有關之路口拍攝, 本研究最終根據機會左轉之潛在衝突的事件數, 挑選其中的 3 個路口, 分別是臺北市市民大道八段與向陽路路口(路口 1)、臺北市市民大道七段與東新街路口(路口 2)以及高雄市經武路與博愛路路口(路口 3), 做為分析資料。機會左轉之潛在衝突, 是計算左轉車與對向直行車同時出現在影片中的配對數量, 其並非表示數值越高, 該路口的風險程度越嚴重。

3.1.2 資料處理




圖 3. 4 資料處理流程示意圖

圖 3. 4 為本研究資料處理的流程示意圖，以下進行說明。原始軌跡是以時間為基礎(time-based)，並根據影片中的每一個影格，輸出其資訊。資訊內容包括該車輛的影片時間、車輛編號、前輪中點座標位置、後輪中點座標位置、長度、寬度、速度、加速度、車輛進入路口方向以及車輛離開路口方向；而藉由影片辨識得到的微觀軌跡資料，會出現較為劇烈之抖動現象，導致資料出現過多雜訊；為了使得資料與現實更為相符，本研究會使用滾動平均濾波器進行平滑處理，並使用平滑後得到的資料，進行後續的分析研究。

實際觀察影片，本研究發現當左轉車輛以極慢速靠近路口或路口中停等時，會發生車角度錯誤的情形，推測是受到車輛偵測所使用的深度學習演算法機制所導致，而這將嚴重影響指標計算出的結果。因此，本研究提出一個角度修正演算法，其概念即是找出車輛於極慢速時，角度發生改變的時間段，並以靜止狀態看待，將角度變化修正為零，即可計算出正確的车角度，修正結果如上圖中所示。

最後，本研究將參考溫雲晨(2020)提出的四角座標計算公式(圖 3. 5)，得出車輛的四角座標，以利後續能夠計算出精準的衝突指標值，增加研究結果的穩固性。




圖 3. 5 四角座標參數與公式圖

3.2 軌跡預測

本研究將會使用三種預測方法進行軌跡之預測，分別是固定角度速度法以及考量加速度及角速度的角度速度變化法，最後一個方法則是參考近年來軌跡預測相關文獻中，使用頻率相當高的長短期記憶模型(LSTM)預測方法，本研究稱此方法為 LSTM 法。進行軌跡預測之後，會將預測結果分為位置以及角度兩類，進行預測準確度分析，以分析各預測方法之優劣。以下針對上述內容進行詳細說明。

3.2.1 固定角度速度法

固定角度速度法為最基本之預測方法，即是假設車輛在角度與速度不變的情況下，依照物理特性進行預測，因此為軌跡預測模式中的物理運動模型。其預測軌跡的計算方式，主要是根據當下的車輛資訊，計算出預測時間點的前輪中點座標；有了預測時間點的前輪中點座標，就可以使用四角座標公式得到車輛完整的預測位置。其預測時間點的前輪中點座標軌跡計算方法

如下方式(1)、式(2)所示。

$$\hat{y}_{t+k}^{CF} = y_t^{CF} + S_t * \sin(\theta_t) * k, \forall k > 0 \quad (1)$$

$$\hat{x}_{t+k}^{CF} = \begin{cases} x_t^{CF} + S_t * \cos(\theta_t) * k, & \text{if } 0 \leq \cos(\theta_t) < 1 \\ x_t^{CF} - S_t * \cos(\theta_t) * k, & \text{if } -1 \leq \cos(\theta_t) < 0 \end{cases}, \forall k > 0 \quad (2)$$

此處新增了一個常數 k ，表示所要預測的第 k 筆資料(以 0.1 秒為單位)，以及參數 S_t ，表示車輛於 t 秒時的瞬間速度(m/s)。藉由此兩資訊，即可結合車輛 t 秒時的資訊(座標及車角度)，進行軌跡預測。

3.2.2 角度速度變化法

本研究欲分析機會左轉情境，其中的左轉車若是以固定角度速度法進行預測，明顯不符合實際駕駛情況。為了改善此現象，本研究提出考量加速度與角速度影響的角度速度變化法，其預測軌跡的計算方式與 3.2.1 固定角度速度法節相似，差別在與此方法考量車輛當下的變化資訊，因此在計算上會先根據當下車輛資訊計算出第一個時間點的預測資料，再利用第一筆的預測資料，計算出第二個時間點的預測資料，以此類推，其計算公式如式(3)~式(8)所示。

$$S_t^k = S_t + A_t * 0.1 * k, \forall k > 0 \quad (3)$$

$$\theta_t^k = \theta_t + \omega_t * 0.1 * k, \forall k > 0 \quad (4)$$

$$\hat{y}_t^{CF} = y_t^{CF} \quad (5)$$

$$\hat{x}_t^{CF} = x_t^{CF} \quad (6)$$

$$\hat{y}_{t+k}^{CF} = \hat{y}_{t+k-1}^{CF} + S_t^k * \sin(\theta_t^k) * 0.1, \forall k > 0 \quad (7)$$

$$\hat{x}_{t+k}^{CF} = \begin{cases} \hat{x}_{t+k-1}^{CF} + S_t^k * \cos(\theta_t^k) * 0.1, & \text{if } 0 \leq \cos(\theta_t^k) < 1 \\ \hat{x}_{t+k-1}^{CF} - S_t^k * \cos(\theta_t^k) * 0.1, & \text{if } -1 \leq \cos(\theta_t^k) < 0 \end{cases}, \forall k > 0 \quad (8)$$

其中，

A_t ：表示車輛於第 t 秒時的加速度

ω_t ：表示車輛於第 t 秒時的角速度

S_t^k ：車輛於第 t 秒時的第 k 筆預測資料之速度

θ_t^k ：車輛於第 t 秒時的第 k 筆預測資料之角度

$\hat{x}_{t+k}^{CF}$ ：第 k 筆預測資料的前輪中點 x 位置

$\hat{y}_{t+k}^{CF}$ ：第 k 筆預測資料的前輪中點 y 位置

由於加速度與角速度皆是以秒(sec)為單位，而預測的計算是以 0.1 秒(sec)為單位，因此會在公式中乘以 0.1 進行單位換算。有了前輪中點位置以及角度，即可根據四角座標公式，計算出車輛的完整位置資訊。

3.2.3 LSTM 法

LSTM 法是將軌跡相關資訊及期望輸出的實際結果，輸入至長短期記憶模型進行學習，屬於循環神經網路(Recurrent Neural Network, RNN)的一個模型，其模型最早是由 Hochreiter &

Schmidhuber 於 1997 年所提出，並廣泛的應用在包括文字翻譯及軌跡預測等領域。其細胞架構相較於原始的 RNN 而言，多了三個門閥架構，分別是遺忘門(Forget gate)、輸入門(Input gate)以及輸出門(Output gate)，藉由此設計，可以改善了過往 RNN 在後期的狀態預測中，無法獲得最初資料所接受到的資訊，增加了模型的學習能力。

而隨著資訊技術的進步，目前模型的參數計算，以及預測模型的學習，都可以使用由 Google 團隊所開發及維護的深度學習套件 Keras，於 Python 編譯器中進行計算。然而模型除了於訓練中會自動校估神經網路中的參數外，仍存在幾個需要自行設定的超參數(hyperparameters)，分別是損失函數(loss function)、優化器(optimizer)以及學習停止條件(termination criteria)。損失函數參考 Ketkar 於 2017 年發表的書中對連續型變數之建議，將會以均方誤差(Mean Squared Error, MSE)作為設定；優化器會使用 Kingma & Ba 於 2014 年提出一個基於一階梯度優化的搜尋方法，稱為適應性矩估計(Adaptive moment estimation, Adam)，原因在於此方法除了因應不同的參數找到最適合的學習率(learning rate)外，作者也證明此方法的收斂速度相較其他方法更快。最後的停止條線，根據試誤法(trial and error)，設定為迭代 500 次，或者當損失函數的計算超過 20 次沒有更好的結果時，即會提早終止訓練。

並且根據文獻回顧，左轉車的接受間距會受左轉車之駕駛特性、對向直行車之狀態以及天氣狀態所影響。考量本研究預期建立出普遍車輛行駛狀態的預測方法，以得到極端事件的計算指標，因此並未將各車輛的編號(ID)，也就是左轉車的駕駛特性，納入學習變數中；而分析路口的拍攝天氣均為晴天，因此也未納入天氣的變數。在對向直行車的狀態中，已知會受其與路口的距離、以及速度所影響。然而當其具有多台車輛時，速度將會難以取出具有代表性之值，因此，本研究僅將對向直行車與路口的距離納入考量，以對向直行車的車流分布情況，作為其動態的變數資訊。最終放入模型中的學習變數如表 3. 1 所示，考量機會左轉情境，是探討左轉車與對向直行車的互動關係，兩者都需要考慮前車動態，也就是車間距的部分；然而在左轉車的部分，由於要尋找合適之左轉接受間距進行轉彎，更多了考慮對向直行車之動態，如先前所述，將會以直行車與路口的距離，也就是對向停止線前方的車輛數，作為其動態的判斷依據。

表 3. 1 LSTM 模型之變數表

變數	變數類型	單位	左轉車輛	對向直行車輛
車輛中心 X 座標	連續	m	✓	✓
車輛中心 Y 座標	連續	m	✓	✓
速度	連續	m/s	✓	✓
角度	連續	rad	✓	✓
加速度	連續	m/s^2	✓	✓
角速度	連續	rad/s	✓	✓
紅燈開始秒數	連續	sec	✓	✓
黃燈開始秒數	連續	sec	✓	✓
綠燈開始秒數	連續	sec	✓	✓
車間距	連續	sec	✓	✓
對向停止線前的車輛數	離散	輛	✓	

變數選擇完成以後，即可開始進行模型之預測。模型主要是根據輸入(inputs)變數，校估神經網路中的各項參數，使得輸出(outputs)結果能夠與實際值更為相近。實際測試「多變數輸入—多變數輸出」以及「多變數輸入—單變數輸出」的模型架構，發現單變數輸出之預測模型會較多變數預測模型結果來的好，並且考量交通衝突指標之計算結果多是以小於 3 秒為臨界值，因此，此處之預測模型將會以前 3 秒之軌跡資料(共 30 筆)預測後 3 秒之軌跡資料，其架

構如圖 3. 6 所示，而預期的預測結果如錯誤！找不到參照來源。所示。




圖 3. 6 LSTM 之預測模型架構圖

3.2.4 軌跡預測準確度分析

已知各車輛之四角座標，可以由車輛中點座標、車角度、車長以及車寬推導得知，而車長及車寬皆為固定資料，不會隨著不同的預測方法而有所變動。因此於預測準確度的分析上面，本研究將會以中點座標和角度作為計算值，其計算公式如式(9)、式(10)所示。

$$Dis_i^{loc} = \frac{\sum_1^j \sum_1^k \sqrt{(x_{it}^R - x_{ijk}^P)^2 + (y_{it}^R - y_{ijk}^P)^2}}{j} \quad (9)$$

$$Dis_i^{ang} = \frac{\sum_1^j \sum_1^k \sqrt{(\theta_{it}^R - \theta_{ijk}^P)^2}}{j} \quad (10)$$

其中，

A_t 、 Dis_i^{ang} ：表示第 i 輛車與實際中點座標與角度之差異

x_{it}^R 、 y_{it}^R ：表示第 i 輛車於 t 秒的實際座標位置

S_t^k 、 y_{ijk}^P ：表示第 i 輛車的第 j 筆資料所預測的第 k 筆預測座標位置

θ_{it}^R ：表示第 i 輛車於 t 秒的實際角度

θ_{ijk}^P ：表示第 i 輛車的第 j 筆資料所預測的第 k 筆預測角度

$t = j + k$ ：為挑選出該預測軌跡所對應到的真實軌跡資料

藉由上述公式，可以比較不同的軌跡預測方法於各分析資料上的預測結果差異；並且，為了能夠有更深入的了解，本研究會將行駛方向分為左轉車以及對向直行車，探討其預測結果是否依上述分類的不同而有不一樣的結果。

3.3 交通衝突指標之定義說明

本研究認為在機會左轉情境中，當對向直行車緊急煞車，至車輛趨近於停止狀態時，傳統中介指標 TTC 與 PET 將無法準確的衡量實際風險情形，以下利用時空圖進行詳細說明。




圖 3. 7 機會左轉情境之對向直行車急煞車之時空關係示意圖

從圖 3. 7 的時空圖中可以看到，兩車在靠近衝突點時，B 車發現即將與 A 車發生碰撞，因此緊急進行煞車，讓 A 車先行通過。此時的 t_1 、 t_2 、 t_3 以及 t_4 分別代表兩車開始進行固定角度速度預測法之時間資訊、兩車預測軌跡同時到達碰撞點之時間資訊、A 車到達碰撞點之時間資訊以及 B 車到達碰撞點之時間資訊。藉由上述資訊，即可計算此情境的 TTC 以及 PET。從圖中可以看到，PET 所計算出的值，將會低估此情境之風險；而 TTC 所計算出來的值，甚至會比 PET 高。從以上內容可知，不論是 TTC 或是 PET，皆無法準確衡量此情境之衝突，說明了目前傳統常用的中介指標，可能存在著高估或低估衝突風險之情形。

為了使得中介指標可以更加符合機會左轉事件中的現實狀況，本研究將會使用 3.2 軌跡預測節中的軌跡預測方法進行車輛軌跡預測，提出基於 TTC 與 PET 原始定義的改良指標。分別是以角度速度變化法所計算而得的碰撞時間，因其為考量速度變化(Speed Changed, SC)的衝突指標，本研究將其稱為 TTC-SC(Time-to-Collision-Speed Changed)；以及使用 LSTM 法所計算而得的預測後侵占時間，稱為 PET-L(Post-Encroachment Time-LSTM)。以下進行兩指標的定義說明

3.3.1 碰撞時間—角度速度變化法(TTC-SC)

TTC-SC 之定義和 TTC 雷同，唯一差別在於此處所使用的軌跡預測方法為 3.2.2 角度速度變化法節中的角度速度變化法。其目的在於已知固定角度速度法使用在車輛預測時，是假設車輛狀態不變的情況，並且左轉車在預測時，會產生預測衝突點與實際位置不符合的現象。因此，本研究提出使用車輛角度速度變化的軌跡預測方法，利用碰撞時間的概念計算出一個改良指標，期望可以得到更符合現實情況的衝突指標值，其時空位置如圖 3. 8 所示。




圖 3. 8 TTC-SC 之時空位置示意圖

於時空圖中， t_1 、 t_2 、 t_3 、 t_4 、 t_5 以及 t_6 分別代表兩車開始進行固定角度速度預測法之時間資訊、兩車開始進行角度速度變化預測法之時間資訊、兩車使用固定角度速度法同時到達碰撞點之時間資訊、兩車使用角度速度變化法同時到達碰撞點之時間資訊、A 車到達碰撞點之時間

資訊以及 B 車到達碰撞點之時間資訊。從圖中可以知道角度速度變化法所計算之 TTC-SC 將小於 TTC 與 PET，更可以說明此情境之風險；並且在右側位置圖中，可以看出因考量角速度變化，左轉車的預測軌跡將更符合現實，使得預測衝突點與實際衝突點更加相近。本研究將會於下一章進行微觀資料分析，探討此指標的計算結果。

3.3.2 預測後侵占時間(PET-L)

PET-L 是使用 LSTM 法所預測的軌跡資料，計算兩車於不同時間點，駛入及駛出預測衝突區域的時間差，其時空位置如所示。




圖 3. 9 PET-L 之時空位置示意圖

於圖 3. 9 的時空圖中， t_1 、 t_2 、 t_3 、 t_4 、 t_5 以及 t_6 分別代表兩車開始進行固定角度速度預測法之時間資訊、兩車使用固定角度速度法同時到達碰撞點之時間資訊、兩車開始進行 LSTM 預測法之時間資訊、A 車使用 LSTM 法到達碰撞點之時間資訊與 A 車實際到達碰撞點之時間資訊、B 車使用 LSTM 法到達碰撞點之時間資訊以及 B 車實際到達碰撞點之時間資訊。從圖中可以看出，PET-L 所得之值將會小於 TTC 與 PET，且預測衝突點將會與實際衝突點非常接近，預期能夠彌補 TTC 與 PET 無法涵蓋的資訊。實際計算結果，將會於下一章進行探討。

3.4 交通衝突指標之適用衝突行為探討

進行軌跡預測以及交通衝突指標之計算後，即可取得兩車互動下的各指標計算結果。本研究認為目前常用的交通衝突指標 TTC 以及 PET，於機會左轉情境中，無法準確的表達所有衝突行為之風險，因此提出基於不同預測方法下，所計算得到的改良指標。

為了能夠探討各個指標的適用衝突行為，本研究會從分析資料的拍攝影片中，歸納出不同的左轉行為，並以微觀的角度進行指標計算結果的探討。期望能夠找出 TTC 與 PET 無法準確衡量，卻能以本研究提出之改善指標(TTC-SC 以及 PET-L)進行衡量之事件；藉此，除了說明交通衝突指標於機會左轉情境中，尚有改善之處外，也說明了本研究具體的研究貢獻。

3.5 小結

本研究根據計算所需以及原始資料的優化，會進行軌跡平滑、車角度修正以及四角座標計算。藉由此三個步驟的資料處理，減少後續分析受資料品質影響所導致的誤差。接著進行軌跡預測的方法說明，以及交通衝突指標的定義以及計算方法說明。藉由時空位置圖之關係，說明目前常用之交通衝突指標 TTC 以及 PET 可能會發生低估或高估衝突風險之情形。因此，本研究根據考量車輛狀態變化的角度速度變化法，以及考量車輛間互動的 LSTM 法，進行軌跡預測，並使用其預測軌跡，計算出本研究提出的改良指標(TTC-SC 以及 PET-L)。最後根據影片歸納出不同的左轉行為，以微觀角度進行探討，期望能夠說明各指標的適用情境，使交通衝突指標的分析結果能夠與現實更為相符。

四、研究結果

本研究之結果將會分成三點進行說明。首先，會先比較不同軌跡預測方法的準確度，接著以進行微觀事件的分析，最後根據分析結果，提出衝突左轉行為之適用指標探討。

4.1 軌跡預測之結果

此處會將行駛方向分為左轉車與對向直行車，藉此觀察不同車種的預測準確度。單一車輛的準確度計算方法如式(9)、式(10)所述一般，然而此處本研究會將路口拍攝的架次分開計算，以避免不同架次拍攝的比例尺差異，導致 LSTM 法學習上的誤差。考量各路口將會得到不同數量的車輛樣本數，為了能夠使其具備比較基礎，誤差之計算將會以平均誤差，做為該路口的計算結果。利用平均誤差來比較各路口以及不同預測方法之差異，計算結果如下方表格所示。

表 4. 1 左轉車預測準確度之指標計算結果表

路口	架次	左轉車輛					
		左轉車位置指標			左轉車角度指標		
		固定角度 速度法	角度速度 變化法	LSTM 法	固定角度 速度法	角度速度 變化法	LSTM 法
1	A	32.001	131.320	0.537	1.364	3.141	0.004
	B	24.889	122.226	0.383	1.313	0.364	0.001
2	A	27.248	136.029	0.565	1.047	0.631	0.002
	B	23.862	113.252	0.459	0.896	0.967	0.001
3	A	41.958	178.223	0.484	3.013	1.536	0.002
	B	34.233	146.190	0.517	2.424	1.553	0.003
	C	34.217	131.783	0.342	2.361	1.343	0.001

4. 2 對向直行車預測準確度之指標計算結果表

路口	架次	對向直行車輛					
		位置指標			角度指標		
		固定角度 速度法	角度速度 變化法	LSTM 法	固定角度 速度法	角度速度 變化法	LSTM 法
1	A	33.028	265.400	0.837	0.041	0.210	<0.001
	B	20.527	151.612	0.489	0.047	0.141	<0.001
2	A	22.930	185.877	0.889	0.055	0.217	0.001
	B	24.400	205.408	0.922	0.061	0.222	0.001
3	A	27.788	213.672	0.758	0.029	0.119	<0.001
	B	23.129	178.810	0.772	0.105	0.186	0.001
	C	29.463	242.052	0.755	0.033	0.126	0.001

從計算結果表中可以發現，平均來說，LSTM 法不論是在車輛行駛方向的不同，或是衡量指標的不同，其平均誤差值皆最小，是當中最好的預測方法。在左轉車角度的部分，趨勢呈現兩種狀態，第一種為固定速度法優於角度速度變化法，如路口 1—A 架次與路口 2—B 架次；第二種為固定角度速度法劣於角度速度變化法，如路口 1—B 架次、路口 2—A 架次、路口 3—A 架次、路口 3—B 架次以及路口 3—C 架次；在左轉車位置的部分，皆是 LSTM 優於固定角度速度法，而固定角度速度法，又優於角度速度變化法。在對向直行車的部分，趨勢呈現相當一致的狀態，不論是角度衡量指標，又或是位置衡量指標，皆是 LSTM 法優於固定角度速度法，而固定角度速度法又優於角度速度變化法。

綜合上述內容，本研究所提出之角度速度變化法，在左轉車的角度預測上，會優於 TTC 使用的固定角度速度法；而 LSTM 法，不論是左轉車或對向直行車的位置及角度，皆會大幅度的優於 TTC 使用的固定角度速度法。此結果證明了本研究所提出之軌跡預測方法，確實可以得到更符合實際車輛軌跡之結果，接著將進行不同預測方法下，各指標計算結果的探討。

4.2 交通衝突指標之計算結果

為了能夠提出指標使用建議，本研究根據人工觀察實際影片資料，將機會左轉情境分成無衝突之情境與有衝突之情境，其具體差異在於左轉行為是否使兩車中的其中一車，改變駕駛行為，如速度的變化或是軌跡的變化等。並且從實際影片中，觀察到有衝突之情境，於不同的號誌資訊與駛入衝突區的先後順序中，可以將左轉行為分成搶快左轉、左轉車先通過衝突區以及對向直行車先通過衝突區。搶快左轉，理應屬於左轉車先通過衝突區之類型，然而因對向直行車之號誌為綠燈初始期間，其直行車的行駛狀態是從靜止開始進行加速，由於速度較慢且視距較大之緣故，儘管仍會造成衝突，本研究認為其風險程度，會與直行車已有初速的情況不同，因此將其另外進行探討；左轉車先通過衝突區或後通過衝突區之差別在於，臺灣的道路交通安全規則中說明「轉彎車應讓直行車先行」，意即機會左轉情境中的衝突左轉行為，理應只出現對向直行車先通過衝突區之類型；然而，實際調閱影片，除了搶快左轉類型外，還有發現左轉車先通過衝突區的衝突行為，不但符合規範，也會迫使對向直行車減速讓道，因此，其風險也該獨立進行探討。綜合以上說明，本研究根據機會左轉情境，依不同的左轉行為與類型進行探討，詳細內容及定義請參考表 4. 3。

表 4. 3 機會左轉之左轉行為定義表

情境	左轉行為	定義
無衝突之情境		左轉車不會影響對向直行車輛的速度或行駛軌跡，且兩車間存在一定長度的最短距離
有衝突之情境	搶快左轉	左轉車之路口燈號具有早開設計，並且於對向直行車之燈號於綠燈初始的加速時間間隔，搶先進行左轉行為
	左轉車先通過衝突區	左轉車較直行車先通過衝突區域的衝突左轉行為
	對向直行車先通過衝突區	直行車較左轉車先通過衝突區域的衝突左轉行為

已知各項事件之定義後，接下來會按照此依據，實際根據不同的軌跡預測方法，得到不同的交通衝突指標值，最後探討其適合的指標為何。然而在一般左轉行為中，其定義為左轉行為不會與對向直行車產生任何互動，因此也不存在衝突。因此，在後續內容的分析資料中，將以

衝突左轉行為中的類型進行探討。而在兩車之互動關係中，同一個指標將會產生多個值，本研究會以其中的最小值，作為該指標的代表值。原因在於數值越小，表示其風險程度越高，因此取最小值，將是以最具風險之程度來看待此事件；本研究認為此值最能夠代表兩車之衝突行為，而這也是目前交通衝突指標分析中最常用的方法之一。並且如參考文獻中所述，以下分析將會以 1.0 秒、2.0 秒以及 3.0 秒做為衝突情形的判斷依據。在進行交通衝突指標計算結果比較以前，本研究會根據影片，主觀判定該事件的風險程度，並將風險程度分為嚴重風險程度、一般風險程度以及輕微風險程度。以下即對不同的事件進行微觀分析。

4.2.1 衝突左轉行為—搶快左轉



表 4. 4 衝突左轉行為—搶快左轉之計算結果表

路口架次	左轉車編號	對向直行車編號	TTC	TTC－SC	PET	PET-L
3－A	2158	1863	1.4	1.2	0.6	0.4
空拍影片圖	交會前		交會中		交會後	
						
	影片時間		07:33.4		07:34.4	
	左轉車					
－速度	5.65 m/s ²		5.76 m/s ²		7.09 m/s ²	
－加速度	－1.85 m/s ²		0.26 m/s ²		0.84 m/s ²	
對向直行車						
－速度	2.77 m/s ²		4.36 m/s ²		5.42 m/s ²	
－加速度	1.26 m/s ²		－0.58 m/s ²		1.81 m/s ²	

搶快左轉事件，即為左轉車於對向直行車之燈號，由紅轉綠的期間，搶先跨越中央車道，進行左轉行為。探討表 4. 4 中的事件，左轉車趁對向直行車在綠燈剛亮時的起步延遲，先行進入兩車相交的衝突區域，迫使對向直行車禮讓。此事件明顯屬於衝突行為，然而綠燈初始時，對向直行車正由靜止開始加速，如本次事件於交會前直行車速度僅約 10km/hr，一直到交會中以及交會後，皆是呈現上升趨勢，最後到達約 20km/hr。考量直行車是從靜止狀態進行改變，以及車輛速度的變化，本研究認為此事件應屬於一般衝突行為。此事件之交通衝突指標計算結果，分別得出 TTC、TTC-SC、PET 以及 PET-L，而數值分別是 1.4 秒、1.2 秒、0.6 秒以及 0.4 秒。由數值可以知道，PET 以及 PET-L 的計算結果會視此事件為嚴重衝突行為，然而考量到兩車的速度關係，並不會造成嚴重的碰撞事件。此時 TTC 與 TTC-SC 計算出來的數值，相較起來，更能夠反應出此事件之風險程度。因此，本研究會以 TTC 與 TTC-SC 之指標，代表此事件之風險程度。

4.2.2 衝突左轉行為—左轉車先通過衝突區

表 4. 5 衝突左轉行為—左轉車先通過衝突區之計算結果表

路口架次	左轉車編號	對向直行車編號	TTC	TTC－SC	PET	PET-L
3－A	1383	1447	1.8	2.2	0.6	
空拍影片圖	交會前		交會中		交會後	
						
	影片時間		04:59.4		05:02.5	
					05:03.3	
左轉車						
－速度	1.52 m/s ²		4.44 m/s ²		5.53 m/s ²	
－加速度	0.15 m/s ²		1.91 m/s ²		1.77 m/s ²	
對向直行車						
－速度	9.36 m/s ²		4.78 m/s ²		5.46 m/s ²	
－加速度	－1.51 m/s ²		0.45 m/s ²		1.55 m/s ²	

探討表 4. 5 中的事件，從空拍影片圖中可以看到，對向直行車於交會前的速度約為 34km/hr，其減速度高達 -1.51 m/s^2 ，使得兩車於交會中時不至於發生碰撞；一直到交會中，兩車的距離僅剩約 1~1.5 台機車長度，儘管對向直行車以預測左轉車會順利通過路口，因此沒有持續進行減速行為，但是如此近的交流距離以及減速度程度，本研究認為此事件為一個嚴重衝突之行為。此事件共計算出三個交通衝突指標，分別是 TTC、TTC-SC 以及 PET，其值分別是 1.8、2.2 以及 0.6，分別代表不同風險情形。然而從上述之推論，已知此事件應屬於一個嚴重衝突行為，指標中，惟有 PET 計算結果符合此行為，因此本研究將會已 PET 之指標值，作為此事件之風險依據。

4.2.3 衝突左轉行為—對向直行車先通過衝突區

表 4. 6 衝突左轉行為—對向直行車先通過衝突區之計算結果表

路口架次	左轉車編號	對向直行車編號	TTC	TTC-SC	PET	PET-L
3-A	2535	2589	4.7s	1.6s	0.4s	1.2s
空拍影片圖	交會前		交會中		交會後	
						
	影片時間		08:57.9		08:58.9	
	左轉車					
一速度	2.31 m/s ²		2.77 m/s ²		3.41 m/s ²	
一加速度	1.30 m/s ²		1.08 m/s ²		1.10 m/s ²	
對向直行車						
一速度	8.79 m/s ²		8.95 m/s ²		9.17 m/s ²	
一加速度	0.49 m/s ²		0.02 m/s ²		0.44 m/s ²	


探討表 4. 6 中的事件，左轉車為了能夠能夠更快速通過路口，於對向直行車通過衝突區域後，立刻加速通過路口。從速度資訊中，可以觀察出兩車的互動屬於一般衝突行為；然而以交通衝突指標之計算結果來看，會發現此時 PET 計算出來的數值為 0.4 秒，將會以嚴重衝突行為看待此事件，明顯呈現高度現象；而 TTC 計算出來的數值為 4.7 秒，此數值一般在交通

衝突指標分析中不視為衝突行為，又顯得低估此衝突。然而利用本研究所提出的 TTC-SC 以及 PET-L，分別得到 1.6 秒以及 1.2 秒，相較傳統常用的交通衝突指標，更能夠代表此事件之衝突行為。

4.2.4 衝突左轉行為之事件進階探討

為了能夠更加了解不同左轉行為的兩車互動關係，對其計算指標可能造成的影響，以下將會使用兩車速度、加速度以及角度的時間關係圖，深入探討上述因素對指標計算的影響。

表 4. 7 各左轉行為之車輛微觀變化表



探討搶快左轉行為的車輛變化關係，可以發現 PET 在約 454.5 秒時數值最低，為 0.6；PET-L 在約 455 秒時數值最低，為 0.4，兩者皆判斷此事件為嚴重衝突行為；然而從真實影片以及速度圖中可以看出，直行車於靜止開始加速，到約 452.5 秒時，意識到左轉車欲進行左轉行為，而降低行車速度，到了 454 秒後，預測左轉車即將通過，而呈現穩定加速狀態。由此可知，兩車皆有注意到彼此行車狀態，應不屬於嚴重衝突行為。其中 TTC 計算出之指標值數量最多，並且介於 452.5~453.5 秒間，其數值最低為 1.4 秒；TTC-SC 則是在約 452.2 秒時出現最低數值，為 1.2 秒。兩個指標皆判斷此事件為一般衝突行為，更符合實際互動行為。

談討左轉車先通過衝突區的車輛變化關係，考量到直行車於 299 秒時，意識到左轉車欲進行左轉行為，將車速從 10m/s 降低至約 4m/s，如此劇烈變化，惟有 PET 得到 0.6 的數值，將此事件視為嚴重衝突行為，準確描述此互動行為。TTC 於此事件同樣計算出最多指標值，介於 299 秒至 302 秒間，為左轉車正好進行變化以及兩車開始產生互動之期間，其中的最小值為 1.8；而 TTC-SC 則是在約 297.5 秒時，計算出最小的數值，為 2.2，較 TTC 更早計算出數值。兩數值分別得到一般衝突事件與輕微衝突事件之結果，不符合實際的兩車互動行為。

探討直行車先通過衝突區的車輛變化關係，從真實影片及速度圖中，可以看出左轉車於約 535 秒時，開始緩緩加速，而直行車察覺到此行為，因次進行減速行為，到了 538 秒時，直行車準備通過衝突區域，此時左轉車才開始有較大的角度及速度變化，考量左轉車仍然有影響直行車，儘管直行車有進行禮讓動作，本研究仍視此事件為一般衝突事件。指標計算上，PET-L 與 TTC-SC 得到的最小值皆可以描述此事件的風險；其中 TTC-SC 所計算出來的指標最多，與前兩個事件不同之處在於較 TTC 晚計算出指標；PET 計算出的數值為 0.4 秒，TTC 計算出來的數值為 4.7 秒，兩者皆不符合實際的衝突情形。

綜合上述，藉由車輛微觀變化表，深入探討速度、角度以及速度變化，對於指標計算結果的影響，其結論與 4.2.1 衝突左轉行為一搶快左轉節~4.2.3 衝突左轉行為一對向直行車先通過衝突區節中，所得到的結果一致。除此之外，可以發現指標計算出來的數值大多在不同的時間

點，TTC 與 TTC-SC 將會早於 PET 以及 PET-L；而 PET-L 多在 PET 正負 0.5 秒內。藉此可以說明，兩車互動會於每個瞬間產生不同的結果，而藉由本研究提出的改善指標(TTC-SC、PET-L)，將盡可能地捕捉到每個瞬間可能產生的風險情形，使得研究人員能夠得到更為全面的資訊，最終再從中挑選出最符合的指標；這同時也說明，本研究基於軌跡預測方法所提出的指標，確實能夠得到傳統中介指標 TTC 與 PET，所沒有蘊含到的資訊內容。

4.3 衝突左轉行為之適用指標探討

本研究根據上述方法，分別針對各左轉行為，進行 2-3 次的事件探討，並整理出分析路口中，左轉行為的適用指標，如表 4. 8 所示。

表 4. 8 左轉行為之適用指標

衝突左轉行為 指標	搶快左轉	左轉車先通過衝突區	對向直行車先通過衝突區
PET	▲	✓	
TTC	▲		
TTC-SC	▲		▲
PET-L			✓

✓：表適用指標

▲：表潛在適用指標

於衝突左轉行為—搶快左轉中，本研究觀察到的三個事件，第一個建議使用 TTC 與 TTC-SC；第二個無找出合適之指標；第三個則建議使用 PET。從以上結果可知，本研究僅可得出此事件的潛在適用指標；即使如此，卻也說明若是以傳統常用的交通衝突指標 TTC、PET 來衡量的話，可能會發生無法準確衡量衝突程度之情形。

於衝突左轉行為—左轉車先通過衝突區中，三個事件使用 PET 指標，皆可以準確衡量出實際的風險行為。此部分與圖 3. 7 中所預期的結果不同，原因應在於原先假設對向直行車輛，會急煞車至車輛趨近於停止的狀態，因此會受駕駛的反應時間，與起步的延滯時間影響，導致計算出的數值不符合真實風險情形；然而本研究的分析資料中，並未發現此類事件，因次無法得出是否會如預期的結果一般。儘管如此，由本研究仍可得知，排除車輛緊急煞車至趨近於停止的事件，PET 指標將可以準確衡量左轉車先通過衝突區的風險情形。

於衝突左轉行為—對向直行車先通過衝突區中，本研究觀察到的三個事件，第一個建議使用 PET-L 指標；第二個建議使用 TTC-SC 與 PET-L 指標；第三個建議使用 PET-L 指標。結合上述所說，使用 p-PET 指標最能準確衡量搶快左轉行為中的風險情形。這個結果也說明本研究所提出之改善指標，對於機會左轉情境中的交通衝突指標分析，能夠具體增加搶快左轉行為中的風險評估精準度。

4.4 小結

於軌跡預測的部分，左轉車的角度預測上，綜觀來說，以 LSTM 法最佳，再來是角度速度變化法，最後是固定角度速度法；左轉車的位置預測上，皆是 LSTM 法最佳，再來是固定角度速度法，最後是角度速度變化法；對向直行車的角度預測以及位置預測上，皆是 LSTM 法最佳，再來是固定角度速度法，最後是角度速度變化法。

於交通衝突指標的部分，衝突左轉行為—搶快左轉中，TTC、PET 與 TTC-SC 皆有得出符合實際風險之結果，意即此情境並未找出最適用之指標；儘管如此，此行為所得結果，也說明常用之交通衝突指標，可能發生高估或低估風險之指標結果；衝突左轉行為—左轉車先通過衝突區中，建議使用 PET 作為衡量衝突之交通衝突指標；衝突左轉行為—對向直行車先通過衝突區

中，建議使用本研究根據 LSTM 法，所提出的改良指標—PET-L，作為衡量衝突之交通衝突指標。

五、結論與建議

本研究基於運輸安全領域中，傳統常用的交通衝突指標 TTC 以及 PET 之定義，提出兩個改良版的交通衝突指標，並以機會左轉情境為例，期望能夠探討左轉對向衝突的指標分析方法。改良指標的最大差異在於使用了不同的軌跡預測方法，本研究提出了兩個軌跡預測方法，分別是考量加速度以及角速度的角度速度變化法，以及利用長短期記憶模型進行深度學習的 LSTM 法。前者可以計算出改良指標中的 TTC-SC，後者可以計算出 PET-L。藉由計算的指標值，微觀比較實際應用之差異，並給予預測方法的準確度比較，以下兩節提出本研究的結論與後續研究建議。

5.1 結論

藉由無人機至路口上方，進行正射空拍攝影，將可以獲得精度佳的路口軌跡資料，使研究人員能夠繪製車輛行駛軌跡，觀察實際駕駛狀況，並根據各車輛微觀的資訊，如速度、角度等，加深對於交通衝突之了解。本研究即以此資料，發現到傳統衝突指標尚有不足之處。TTC 是使用物理運動模型的軌跡預測方法，進行碰撞時間的計算，其並沒有考慮軌跡預測的準確度，將會使得預測碰撞點的位置與實際不同；PET 則會因車輛的減速行為，而有無法確實表達衝突風險之情形。因此，本研究提出考量加速度以及角速度的預測方法—角度速度變化法，以及同時考量左轉車以及對向直行車資訊的車輛軌跡預測方法—LSTM 法。其結果顯示，前者雖然在位置預測上準確度不佳，然而在角度的預測上，相較 TTC 使用的固定角度速度法更為精確；後者則不論是在位置或是角度上，皆可以得到更為準確的預測結果。利用提出的軌跡預測方法，改良傳統常用的交通衝突指標，稱為 TTC-SC 以及 PET-L，並從微觀資料分析中，實際說明提出的指標確實能夠提升風險評估的準確程度，尤其是在衝突左轉行為一對向直行車先通過衝突區中，PET-L 相較其他指標將可以得到最為準確的結果。

5.2 後續研究之建議

於交通衝突指標分析當中，本研究以微觀角度進行車輛間的互動探討。建議後續研究能以巨觀角度，實際比較不同指標於各衝突情境的具體差異，並且考量路口的幾何差異，以了解此方法是否具備地區的轉移性；於衝突左轉行為一左轉車先通過衝突區中，本研究原先欲觀察因兩車衝突，致使其中一車於交會中減速致速度趨近於零的事件，然而本次分析資料並無觀察到此類事件。建議後續研究能夠探討此類衝突，並找出此衝突適合之指標；本研究所使用的軌跡預測模型，以 LSTM 法為基礎，其架構是將單一方向的軌跡預測，各別建構三個模型。此架構所得到之預測結果雖好，然而因單一方向即需訓練三個深度模型，其效率明顯不佳。建議後續研究可以針對其預測架構進行優化，將單一方向的模型數進行縮減，藉由架構簡化，增進整體效率；本研究僅使用單一交通衝突指標，進行風險衡量之探討，然而其結果顯示，單一衝突事件能夠利用不只一種指標進行衡量；因此，建議後續研究可以以多指標的方式，進行衝突相關探討。

參考文獻

交通部道安資訊平台，交通部道安會碰撞型態與位置X車種統計表。

項喬君、陸鍵、盧川、葛興(2008)，道路交通衝突分析技術及應用[M]，北京：科學出版社

溫基信、王宏生、黃家耀、胡守任、蘇志文、周業凱、彭千純、張開國、葉祖宏、賴靜慧、孔垂昌(2020)，路口俯視攝影技術於交通衝突分析之案例應用與比較，交通部運輸研究所(尚未出版)。

溫基信、王宏生、黃家耀、胡守任、蘇志文、周業凱、彭千純、葉祖宏、賴靜慧、黃明正(2021)，以無人機探勘人車流動資訊之應用情境規劃與先導測試(1/3)，交通部運輸研究所(期中報告書)。

溫雲晨(2020)，空拍影像車流軌跡之重建與應用，國立交通大學運輸與物流管理學系，碩士論文。

Alahi, A., Goel, K., Ramanathan, V., Robicquet, A., Fei-Fei, L., & Savarese, S. (2016). Social lstm: Human trajectory prediction in crowded spaces. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 961-971).

Alhajyaseen, W. K. (2014). The development of conflict index for the safety assessment of intersections considering crash probability and severity. Procedia computer science, 32, 364-371.

Altché, F., & de La Fortelle, A. (2017, October). An LSTM network for highway trajectory prediction. In 2017 IEEE 20th international conference on intelligent transportation systems (ITSC) (pp. 353-359). IEEE.

Bahari, M., Nejjar, I., & Alahi, A. (2021). Injecting knowledge in data-driven vehicle trajectory predictors. Transportation research part C: emerging technologies, 128, 103010.

Choi, S., Kim, J., & Yeo, H. (2019). Attention-based recurrent neural network for urban vehicle trajectory prediction. Procedia Computer Science, 151, 327-334.

Deo, N., & Trivedi, M. M. (2018). Convolutional social pooling for vehicle trajectory prediction. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (pp. 1468-1476).

Davis, G. A., & Swenson, T. (2004). Field study of gap acceptance by left-turning drivers. Transportation Research Record, 1899(1), 71-75.

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. Neural computation, 9(8), 1735-1780.

Huang, X., McGill, S. G., Williams, B. C., Fletcher, L., & Rosman, G. (2019, May). Uncertainty-aware driver trajectory prediction at urban intersections. In 2019 International conference on robotics and automation (ICRA) (pp. 9718-9724). IEEE.

Hydén, C. (1987). The development of a method for traffic safety evaluation: The Swedish Traffic Conflicts Technique. Bulletin Lund Institute of Technology, Department(70).

- Ketkar, N., & Santana, E. (2017). *Deep learning with Python* (Vol. 1). Berkeley: Apress.
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980.
- Lee, C. W., Lee, D. M., & Hwang, S. C. (2016). Development of Gap Acceptance Models for Permitted Left Turn Intersections. *International Journal of Highway Engineering*, 18(5), 95-103.
- Lefèvre, S., Vasquez, D., & Laugier, C. (2014). A survey on motion prediction and risk assessment for intelligent vehicles. *ROBOMECH journal*, 1(1), 1-14.
- Lin, L., Li, W., Bi, H., & Qin, L. (2021). Vehicle trajectory prediction using LSTMs with spatial-temporal attention mechanisms. *IEEE Intelligent Transportation Systems Magazine*.
- Minderhoud, M. M., & Bovy, P. H. (2001). Extended time-to-collision measures for road traffic safety assessment. *Accident Analysis & Prevention*, 33(1), 89-97.
- Mohamed, M. G., & Saunier, N. (2017). The impact of motion prediction methods on surrogate safety analysis: A case study of left-turn and opposite-direction interactions at a signalized intersection in Montreal. *Journal of Transportation Safety&Security*, 10(4), 265-287. <https://doi.org/10.1080/19439962.2016.1255690>
- Park, S. H., Kim, B., Kang, C. M., Chung, C. C., & Choi, J. W. (2018, June). Sequence-to-sequence prediction of vehicle trajectory via LSTM encoder-decoder architecture. In *2018 IEEE Intelligent Vehicles Symposium (IV)* (pp. 1672-1678). IEEE.
- Sadeghian, A., Kosaraju, V., Sadeghian, A., Hirose, N., RezaTofighi, H., & Savarese, S. (2019). Sophie: An attentive gan for predicting paths compliant to social and physical constraints. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 1349-1358).
- Tageldin, A., & Sayed, T. (2016). Developing evasive action-based indicators for identifying pedestrian conflicts in less organized traffic environments. *Journal of Advanced Transportation*, 50(6), 1193-1208.
- van der Horst, A. R., de Goede, M., de Hair-Buijsen, S., & Methorst, R. (2014). Traffic conflicts on bicycle paths: a systematic observation of behaviour from video. *Accid Anal Prev*, 62, 358-368. <https://doi.org/10.1016/j.aap.2013.04.005>
- WHO Global Health Estimates (2020). The top 10 causes of death. World Health Organization.
- Wiest, J., Höffken, M., Kreßel, U., & Dietmayer, K. (2012, June). Probabilistic trajectory prediction with Gaussian mixture models. In *2012 IEEE Intelligent Vehicles Symposium* (pp. 141-146). IEEE.
- Yang, X., Yang, J., Yan, J., Zhang, Y., Zhang, T., Guo, Z., ... & Fu, K. (2019). Srdet: Towards more robust detection for small, cluttered and rotated objects. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 8232-8241).
- Zhou, H., Ivan, J. N., Gärder, P. E., & Ravishanker, N. (2017). Gap acceptance for left turns from the major road at unsignalized intersections. *Transport*, 32(3), 252-261.
- Zohdy, I., Sadek, S., & Rakha, H. A. (2010). Empirical analysis of effects of wait time and rain intensity on driver left-turn gap acceptance behavior. *Transportation research record*, 2173(1), 1-10.