

生成式人工智慧在非重現性壅塞應用之探討

An Exploration of Generative AI Applications in Non-Recurrent Traffic Congestion

運輸科技及資訊組 周家慶

研究期間：民國114年5月至114年11月

摘要

近年來隨著大型語言模型的快速發展，生成式人工智慧在交通運輸應用逐漸受到重視。大型語言模型是一種特定類型的生成式人工智慧，專門用於自然語言處理，大型語言模型透過深度學習訓練，能夠理解、生成並回應人類語言；而生成式人工智慧則泛指所有能夠「生成」新內容的人工智慧技術，包括文字、圖像、音樂、影片、程式碼等。生成式人工智慧利用各種機器學習技術，如變分自動編碼器(VAE)、生成對抗網絡(GAN)、擴散模型(Diffusion Models)等來生成不同類型的內容；而大型語言模型主要基於變換器架構，透過大量語言資料訓練，以生成文字內容，如文章、程式碼、對話等。

非重現性壅塞是指因突發事件，例如：突發狀況應變(事故與緊急事件)之交通事故、天氣變化、道路施工、大型活動等，此類突發事件導致的短期交通壅塞，與日常的尖峰時段壅塞不同，通常不易預測且變化迅速。生成式人工智慧可透過即時數據分析與自適應調整，例如：動態號誌控制策略、壅塞應對計畫、智慧疏導方案、最佳繞行路徑等的動態生成，來減少非重現性壅塞的影響，進而提升交通效率與安全性；雖然具有發展潛力，但在非重現性壅塞課題的應用，尚未有明確的研究案例，仍需進一步探索。本研究對象與範圍，主要包含生成式人工智慧、非重現性壅塞、生成式人工智慧非重現性壅塞應用等議題，另考量道路施工與大型活動舉辦通常須於事前提出交通維持計畫，因此本研究將不納入探討。

關鍵詞：

生成式人工智慧、智慧型運輸系統、非重現性壅塞。

生成式人工智慧在非重現性壅塞應用之探討

一、計畫背景與目的

近年來隨著大型語言模型的快速發展，生成式人工智慧 (Generative AI, Gen-AI) 在交通運輸應用逐漸受到重視。大型語言模型是一種特定類型的 Gen-AI，專門用於自然語言處理，大型語言模型透過深度學習訓練，能夠理解、生成並回應人類語言；而 Gen-AI 則泛指所有能夠「生成」新內容的人工智慧技術，包括文字、圖像、音樂、影片、程式碼等。Gen-AI 利用各種機器學習技術，如變分自動編碼器 (VAE)、生成對抗網絡 (GAN)、擴散模型 (Diffusion Models) 等來生成不同類型的內容；而大型語言模型主要基於變換器架構，透過大量語言資料訓練，以生成文字內容，如文章、程式碼、對話等。

Gen-AI 在都市交通號誌控制中的應用，預期可以大幅提升交通流量管理的效率，減少壅塞，並優化能源消耗。主要應用方式有號誌控制的智慧化、交通預測與模擬、突發狀況應變 (事故與緊急事件)、環境與能源優化。非重現性壅塞是指因突發事件，例如：突發狀況應變 (事故與緊急事件) 之交通事故、天氣變化、道路施工、大型活動等，此類突發事件導致的短期交通壅塞，與日常的尖峰時段壅塞不同，通常不易預測且變化迅速。

Gen-AI 可透過即時數據分析與自適應調整，例如：動態號誌控制策略、壅塞應對計畫、智慧疏導方案、最佳繞行路徑等的動態生成，來減少非重現性壅塞的影響，進而提升交通效率與安全性；雖然具有發展潛力，但在非重現性壅塞課題的應用，尚未有明確的研究案例，仍需進一步探索。本研究對象與範圍，主要包含 Gen-AI、非重現性壅塞、Gen-AI 非重現性壅塞應用等議題，另考量道路施工與大型活動舉辦通常須於事前提出交通維持計畫，因此不納入本研究探討。本研究成果將可提供本所與道路主管機關在後續研究之參考。

二、非重現性交通壅塞

交通壅塞 (Traffic Congestion) 通常根據其發生的原因與可預測性，科區分為「重現性」與「非重現性」兩大類。都會區的重現性壅塞多集中在特定時段與節點 (或區段)，由於交通需求量超過道路容量而規律發生的現象，其發生具周期性與可預測性，在交通管理與控制上通

常透過號誌控制最佳化、動態路徑導引、即時交通資訊發布等手段來紓解壅塞現象。同時交通管理相關研究與實務案例。亦多著重於非重現性交通壅塞問題的處理與解決。非重現性壅塞可分為預期性與突發性兩種；所謂預期性管制措施，如道路封閉、施工管制、路段清潔管制等，至於突發性事件則是由於突發事件(例如：交通事故、惡劣氣候、特殊事件(施工或活動)、突發路況等)導致道路容量臨時下降，或是交通需求突然激增所引發的異常壅塞；由於非重現性壅塞的本質是脆弱性，以及發生率低、隨機性強、影響大的特性，因此其對策應為快速偵測(congestion detection)、即時應變(congestion avoidance)與路網導引(congestion distribution)。

俞紫娟(2007)探討在市區道路發生阻斷性意外事件下之全動態交控號誌(COMDYCS-3e)應變績效研究，在模擬分析與評估後發現，在多數情況下，全動態交控模式均可於意外事件結束後，快速地恢復正常交通，並獲致較佳之交通績效。黃益三(2016)指出非重現性壅塞的解決方法主要在於及早發現，立即反應處理，以及平時備妥臨時替代方案可供因應。張鈞凱(2014)回顧中介紹可藉由可變速限、Metaline 匝道儀控演算法，以及 Gang-Len Chang (1994)所發展的儀控演算法等來因應非重現性壅塞，以增進行車安全。

Chung (2017)透過案例研究，對交通事故造成非重現性壅塞的總延誤時間進行量化，同時運用 Cox 統計模型探討都會區高速公路交通事故造成的非重現性壅塞的成因，研究結果顯示主要成因包括事故路段 5 分鐘佔用率和貨車比例、「3 車或 3 車以上側撞」和「3 車或 3 車以上追撞」的碰撞類型、事故發生在夜間以及高速公路路段車道數為 3 或以下等 7 個因子。但由於事故發生機率難以準確預測，因而預防交通事故造成的非重現性壅塞的能力受限。

Chen 等(2020)認為交通事故所造成的非重現性壅塞是影響都市路網運作效率的重要因素之一。該研究利用中國大陸武漢市的浮動車(Floating Car Data, FCD)和交通事故數據，分析事故地點附近的車流特徵。分析結果顯示車流明顯受到事故的影響。在空間面向，事故地點前車輛的速度顯著降低，事故的影響會波及上游道路，而下游道路由於車輛數量減少，車速則有所提高；在時間面向，隨著時間的推移，車隊等候線長度和擁擠情況愈發嚴重，車輛延滯時間也隨著事故的持續而增加。因此事故地點附近的浮動車數據特徵，可用於交通事故的

自動偵測。

Grigorev 等(2024)回顧應用機器學習(Machine learning, ML)技術在預測交通事件持續時間文獻，該研究採用 Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA)方法，來分析各交通事件持續時間預測模型文獻。分析結果顯示傳統的機器學習模型(如 XGBoost 和隨機森林法)應用廣泛，但雙層模型和混合框架(Bilevel and hybrid frameworks.)等先進方法仍具有相當潛力。探討結果顯示主要挑戰包括：資料品質問題、模型可解釋性，以及高維度資料集帶來的複雜性。該研究建議未來研究方向包括：(1)開發資料融合模型，整合異質事件報告資料集，以增強預測建模；(2)利用自然語言處理(NLP)從文字事件報告中提取上下文資訊；(3)實施包含異常偵測、超參數最佳化和複雜特徵選擇技術的先進機器學習流程。研究結果凸顯先進機器學習方法在交通事件管理中的變革潛力，有助於建構更安全、更有效率、更環保的交通運輸系統。

Oh 等(2026)探討由交通事故與施工等意外事件引起的非重現性壅塞，其不規則的時空動態分布，因此難以預測。該研究提出結合加權 K 最近鄰(Weighted K-nearest neighbor, WK-NN)演算法與動態時間規則(Dynamic time warping, DTW)模型，用於非重現性壅塞的影響預測。該模型用來估計速度下降率(Speed drop ratios, SDR)，並將預測的影響傳播到相鄰路段，從而掌握非重現性壅塞對路網衝擊的評估。該模型使用韓國 2780 件真實交通事件資料進行評估，實驗結果顯示該模型具備提供交通控制中心進行即時，且易於理解的擁塞影響預測與決策的應用潛力。

美國聯邦公路總署(FHWA)指出非重現性壅塞的三大主要原因是：從爆胎到危險品運輸車側翻等各種事故(佔壅塞的 25%)、施工(佔壅塞的 10%)和天氣(佔壅塞的 15%)。此會顯著降低整個交通系統的可用容量和可靠性，積極的非重現性壅塞交通管理可以減少這些中斷的影響，並使交通系統恢復到「滿載運作」。FHWA 以交通事件管理(Traffic Incident Management, TIM)來系統系的偵測、應對和清除交通事件，以盡可能安全、快速地恢復交通秩序。有效的交通事件管理能夠縮短交通事件的持續時間和影響，提高用路人的安全，並降低二次事故的發生頻率。美國傳統上交通事件管理透過車輛偵測器與人工通報來掌握交通事件與非重現性壅塞，在其下一代(Next-Generation TIM)則強

調透過改進 TIM 策略，例如佇列後方預警(Back-of-queue warning)、導航 APP 程式、群眾外包資料(Crowdsourced data)來掌握事件的發生。基本上著重在事件發生的多元偵測強化。

至於大型在災害發生時疏散計畫，美國於 2018 年 10 月 5 日通過 2018 年災後重建改革法案(The Disaster Recovery Reform Act, DRRA)，該法案第 1209 條要求聯邦公路總署(FHWA)和聯邦緊急事務管理局(The Federal Emergency Management Agency, FEMA)協調制定疏散路線指南，內容涉及路線的設計、建設、疏散和維修。當需要疏散大量居民時，政府官員會考慮是否實施逆向車道方案，逆向車道(或調撥車道)是指將一條或多條進城車道的車流方向反轉，用於出城方向，目的是提高車流通行能力。逆向車道通常用於大規模疏散場景，並在主要封閉式道路(如高速公路)上實施，以縮短疏散時間。道路系統於緊急疏散時，道路主管機關須提前提供時間和地點訊息，包括逆向車道運作的開始和結束時間。可變資訊標誌(CMS)和其它交通控制設備必須清晰地引導用路人在逆向行駛期間駛入正確的車道。

三、生成式人工智慧在交通管理應用

根據微軟¹對 Gen-AI 介紹，人工智慧從電腦必須完全遵循的簡單規則開始，人工智慧進化為機器學習，讓系統學習資料。現今人工智慧會自動化工作、分析資料，並解決各種產業的複雜問題。Gen-AI 會研究訓練資料的基本結構，並使用進階機器學習來產生新內容，而不是遵循一組規則。近年來人工智慧已廣泛應用於交通運輸領域，且人工智慧在技術上已從早期的「規則化自動處理」演進至現今的「主動感知、因果推理與生成式應變」，目前發展趨勢與技術應用內容可歸納為以下四大核心範疇：(1)智慧交通管理與動態控制、(2)自駕車、(3)公共運輸與物流優化、(4)交通安全與法規科技²。

Gen-AI 常見模型包括：兩個模型互相競爭生成逼真內容的生成對抗網路(GAN)、學習資料分布再生成的變分自編碼器(VAE)、高品質圖片生成的擴散模型(Diffusion Models)等三種模型，每種類型的學習方式都有些許差異，以下摘要說明。

(一) 生成式對抗網路模型(Generative adversarial networks, GANs)：是

¹ <https://www.microsoft.com/zh-tw/ai/ai-101/what-is-generative-ai>

² 彙整自 Gemini

由鑑別網路(Discriminating Network)與生成網路(Generative Network)構成。生成網路努力生成更逼近真實的資料，而鑑別網路則努力分辨該資料的真偽，最後透過二者相互對抗，便可以學習生成出非常接近真實的內容。

生成網路根據鑑別網路的反饋，調整自己的生成策略，力求創作出更難被識破的贗品；鑑別網路則透過同時學習真實樣本和偽造樣本，提升自己辨別真偽的準確性。在訓練過程中，兩者將不斷進行博弈對抗，直到生成網路產生的數據足以以假亂真，讓鑑別網路無法有效分辨(即準確率接近 50%)，此時系統達到一種「納許均衡(Nash Equilibrium)」狀態，GAN 透過這種方式，能夠生成非常清晰與高度擬真的數據。然而 GAN 的訓練過程以不穩定著稱，容易出現模式崩潰(Mode Collapse)，即生成網路只學會產生少數幾種能夠騙過鑑別網路的樣本，而喪失了生成數據的多樣性。此外要達到理想的均衡狀態，往往需要精細的參數調整和大量的實驗。而 GAN 透過生成網路與鑑別網路的對抗學習，能夠生成高擬真的交通數據，應用範圍涵蓋交通模擬、異常檢測與號誌優化。

- (二) 變分自動編碼器模型(Variational Autoencoder, VAE)：變分自動編碼器可以將資料壓縮、編碼成「潛空間」，並加入一些隨機元素，之後再嘗試解碼、重構，進而生成帶有原資料特徵的新內容。

VAE 運作原理可以直觀地理解為兩個步驟：編碼(Encoding)與解碼(Decoding)。VAE 與標準自動編碼器的關鍵區別在於其潛在空間的「機率性」。標準自動編碼器將一個輸入精確地映射到潛在空間中的一個「點」，而 VAE 則將其映射到一個「機率分佈」，通常是一個高斯分佈，由平均值(μ)和變異數(σ)兩個向量來定義，這種設計迫使潛在空間變得連續且平滑。VAE 主要可應用於交通數據補全與交通預測，其透過學習數據的潛在表示(Latent Representation)來生成合理的數據樣本，特別適合處理交通數據缺失的填補與具不確定性的壅塞預測建模。

- (三) 擴散模型(Diffusion Model)：擴散模型會隨機加入雜訊，改變原始資料，讓資料越來越模糊，隨後再學習移除雜訊、修復原始資料，進而達到生成新資料的目的。

Mingxing Peng 等(2025)介紹擴散模型核心思想源於非平衡熱力學，整個過程可以分解為兩個對稱的階段。首先是前向過程(Forward Process)的逐步添加雜訊，此為固定且無需學習的過程，其運作邏輯為從目標數據開始(如一張清晰的原始圖像)開始，於數百甚至數千個 Timestep 中，每一步都向圖像中添加微量高斯雜訊(Gaussian noise)，並隨著時間推進，圖像結構和資訊被逐漸破壞，最終變成一張完全無法辨識且純粹之隨機雜訊圖像，整個過程如同一滴墨水滴入清水中逐漸擴散，最終均勻分佈的過程。接下來是學習去除雜訊的反向過程(Reverse Process)，擴散模型的關鍵在於學習如何逆轉前述過程，訓練一個神經網路(通常為 U-Net 架構)，使其具備「去噪」的能力。在每一個 Timestep t ，模型會觀察一張帶有雜訊的圖像 x_t ，並學習預測從 $t-1$ 步到 t 步時被添加進去的雜訊，透過從 x_t 中減去這個預測出的雜訊，模型就能夠將圖像還原到上一個、稍微清晰一點的狀態 x_{t-1} 。當需要生成一個全新樣本時，從一張隨機雜訊圖像開始，反覆應用訓練模型一步步從雜訊中雕塑出一個連貫、清晰、高擬真度的全新樣本，此樣本雖為新創，但其統計特徵與訓練數據完全一致。圖 1 為擴散模型的訓練架構。

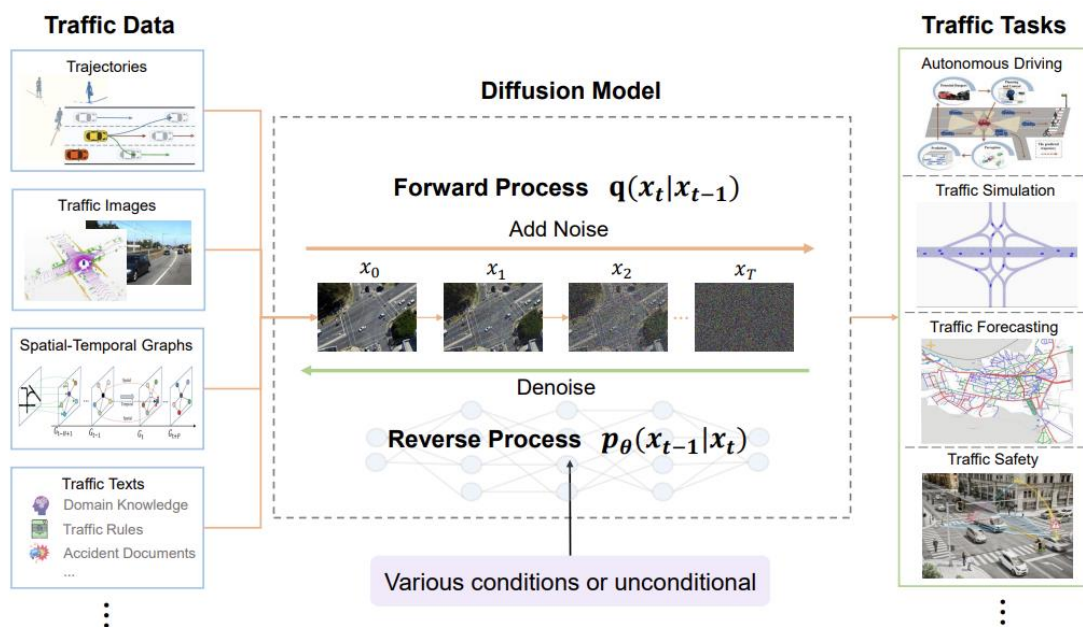


圖 1 擴散模型訓練架構(Mingxing Peng 等, 2025)

Mingxing Peng 等(2025)認為人工智慧在智慧運輸應用的挑戰有：(1)有品質資料的缺乏、(2)隱私權課題、(3)事件的稀少性或缺乏、(4)複雜車流時空動態模式的困難度、(5)解決方案在擴充性(Scalability)與

泛化性(Generalization)的挑戰、(6)良好與有效使用者界面的不足。擴散模型的優勢有：(1)高真實的生成(High-fidelity Generation)：相較於生成對抗網路(GAN)與變分自編碼器(VAE)，擴散模型展現出更易於訓練的特性與更優越的生成能力同時，透過生成合成數據；同時擴散模型可以解決交通數據的隱私疑慮，在保持生成場景品質與可靠性的同時，減少對敏感真實數據的依賴、(2)可控的生成(Controllable Generation)：條件式擴散模型(Conditional Diffusion Models)可以生成符合特定目標或情境的輸出，使模擬自定義交通場景成為可能，包括稀有或未見過的情況，從而有助於解決稀有事件樣本不足的問題、(3)強大的彈性(Strong Flexibility)：可以靈活地與其他技術結合，包括圖神經網路(GNNs)、強化學習，甚至可與 GAN 或 VAE 等其他生成模型融合，以捕捉複雜的時空依賴關係和外部影響，有效地模擬複雜的交通動態，來提高跨區域的遷移能力，有助於實現更好的擴展性與泛化性、(4)機率建模(Probabilistic Modeling)：機率特性可捕捉交通系統中的不確定性、變異性與隨機性，有助於涉及多代理人在複雜交通動態時的建模、(5)多模態能力(Multimodal Capabilities)：交通數據具多元與多模態特性，擴散模型藉由去噪機制、靈活的條件策略和潛在空間(Latent Space)建模，能有效處理此類數據，潛在擴散模型(LDM)將不同模態編碼至緊湊的潛在空間中，有助於整合異質數據源，並透過自然語言方式來提供智慧運輸使用者界面的挑戰。

基於上述擴散模型特色，因此擴散模型在智慧運輸具潛在的應用課題包括：(1)智慧運輸中的感測器特徵/空間特徵/時間/語義或符號條件的輸入；(2)自動駕駛中的感知(包括語義分割、物件追蹤、感知數據生成)與行人/車輛軌跡預測；(3)自駕車與機器人的規劃與決策；(4)交通模擬中的交通軌跡生成、交通場景生成(包括以圖像或點雲為基礎的行車場景生成)、車流生成；(5)交通流預測與旅行時間推估；(6)交通安全中的異常檢測與事故預防。

Somvanshi(2024)、Rong(2025)、Yan(2024)、Da(2025)等進一步回顧與探討 Gen-AI 在運輸規劃、智慧運輸與運輸管理等領域應用的文獻回顧，以下為摘要說明。

一、Longchao Da(2025)探討將 Gen-AI 整合至運輸規劃時，在需求預測、基礎設施設計、政策評估及交通模擬等任務的潛力與課題，然而將 Gen-AI 導入運輸規劃領域是一個跨領域的專業結合。

該研究從運輸規劃角度探討 Gen-AI 在自動化描述性、預測性、生成式模擬及可解釋性任務中的角色，以強化移動(Mobility)系統；從運算技術角度探討數據準備、特定領域微調(Fine-tuning)以及推論策略(如檢索增強生成(Retrieval-Augmented Generation, RAG)和零樣本學習(Zero-shot learning))方面的進展，並針對運輸領域應用進行優化。此外也探討 Gen-AI 導入運輸規劃時在數據匱乏、可解釋性、偏差緩解，以及在永續性、公平性和系統效率等目標的挑戰。該研究摘要探討傳統運輸規劃、以 AI 為基礎的運輸規劃，以及以 Gen-AI 為基礎的運輸規劃等三階段運輸規劃演進。對於以 Gen-AI 為基礎的運輸規劃，該研究認為相較於傳統運輸規劃方法，Gen-AI 透過情境生成、需求預測與交通模擬等能力來強化運輸規劃的各項任務。以下摘要說明該研究提出的九項 Gen-AI 可以扮演與增強的角色。

在情境生成(Scenario Generation)部分，利用 Gen-AI 探索替代運輸策略，例如：基礎設施設計、政策干預以及針對突發事件的應變計畫。Gen-AI 模型可以模擬擁堵定價的影響、優化大眾運輸導向型開發(TOD)，或模擬極端天氣條件下的基礎設施韌性。透過分析這些情境，規劃人員可以找出具成本效益且環境永續的解決方案。在需求預測(Demand Forecasting)部分，Gen-AI 模型可應用於多運具旅運需求模式預測，透過微調起訖矩陣以符合觀測到的交通量、估算共享移動服務的採用率，並模擬因人口或經濟變化引起的長期需求轉移，以利規劃人員能有效平衡交通網絡的旅運負荷。

交通模擬與優化(Traffic Simulation and Optimization)則專注於模擬交通動態並優化系統性能，Gen-AI 模型能夠模擬「混合自主系統」(有人駕駛與自動駕駛共存)，以改善車輛協調並減少走走停停現象，另 Gen-AI 模型還可優化號誌控制和路徑選擇策略，以減少延滯來提升城市移動效率。在永續性與韌性規劃(Sustainability and Resilience Planning)方面則突顯 Gen-AI 模型在推動低碳與氣候韌性運輸系統中的角色，Gen-AI 模型可以模擬節能駕駛行為、預測電動車的普及率，並評估天然災害等極端情境下的基礎設施韌性；另 Gen-AI 工具還可評估運輸系統的可及性，確保為弱勢群體提供公平的移動解決方案。

數據集基準(Benchmark Datasets)是評估 Gen-AI 在 OD 矩陣校正、交通模擬和基礎設施規劃等任務中的效能。在面對人口增長、土地利用變化和演變中的旅運行為等不確定性與動態變化的預測工作，全面

的知識庫供運輸規劃模型使用仍是一項重大挑戰。然目前缺乏標準化、交互操作性和即時更新的運輸規劃數據，成為導入 Gen-AI 的瓶頸。數據前處理策略(Data Preprocessing Strategies)則要確保 Gen-AI 模型有乾淨、平衡且具代表性的輸入資料。運輸規劃數據通常需要對運輸模式、基礎設施屬性或用戶回饋進行人工或自動標註(Labeling)，Gen-AI 在應對標註挑戰的同時能確保保持數據品質。數據增強技術(如合成 OD 矩陣生成)則進一步擴充數據集，來模擬罕見或極端的運輸規劃情境。微調技術(Fine-Tuning Techniques)使 Gen-AI 能有效地適應運輸規劃特定任務。例如：鏈式思考(Chain-of-Thought)提示(Prompting)可增強模型在以前所偵測車流量，來校估 OD 矩陣過程的推理能力。

生成式推論技術(Generative Inference Techniques)允許 Gen-AI 模型在訓練數據有限的情況下處理新任務。以代理人為基礎的推理(Agent-based reasoning)進一步使 Gen-AI 能夠模擬混合自主系統中的車輛協作或不同條件下的車流匯流行為的動態互動行為。進階推論策略(Advanced Inference Strategies)則進一步提升 Gen-AI 對真實運輸挑戰的適應性。檢索增強生成(RAG)動態整合外部數據(例如即時車輛偵測器或政策紀錄)，以產生準確且具備上下文意識(context-aware)預測。透過模擬代理人與環境之間的相互作用，Graph-RAG 在路徑規劃等多模態任務中證明其有效性，並可推廣或泛化(generalized)至壅塞管理和交通安全關鍵決策上。此外自我一致性解碼(Self-Consistency Decoding)減少生成輸出的變異性，號誌優化或路徑規劃等任務的建議結果。

二、Rong 等(2025)認為 Gen-AI 在文字、圖像、語音、多模態生成，對於智慧運輸在 Gen-AI 演算法、自然語言處理(NLP)與電腦視覺(Computer vision)發展所需的對話與推理(Dialogue and reasoning)、預測與決策(Prediction and decision-making)、多模態資料生成(Multimodal generation)能力非常重要。

該研究歸納 Gen-AI 在智慧運輸的應用有：(1)有關對話與推理應用：包括人與車輛互動介面、智慧虛擬助理(Intelligent virtual assistants, IVA)、智慧交通事故分析；(2)有關預測與決策應用：包括智慧道路基礎建設、駕駛輔助決策支援、智慧交通預測與管理；(3)有關多模態資料生成應用：包括路網規劃與設計、自駕車運行情境生成、駕駛行為模擬、車流資料與情境生成、交通安全教育與公眾關心事務內容的生

成。然也提出 Gen-AI 在智慧運輸應用的潛在挑戰有假造內容的安全風險、人力轉換與人機協作、社會認知與情感信任問題、法律與道德課題。圖 2 為其所提出之 Gen-AI 與智慧運輸整合框架。

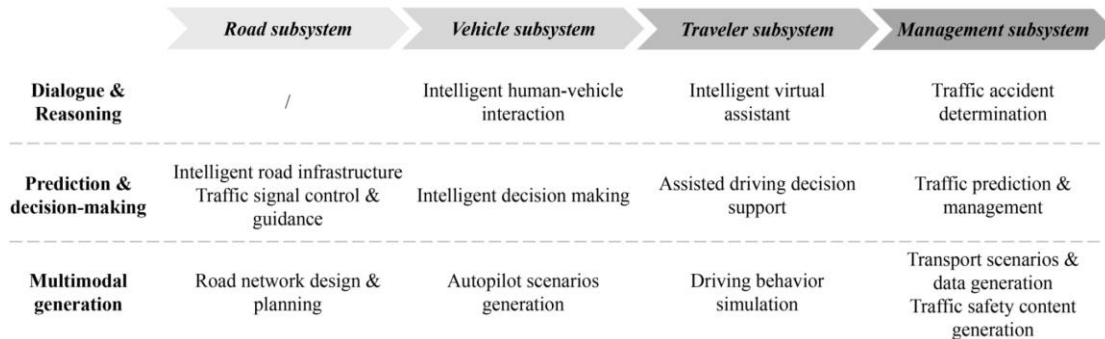


圖 2 Gen-AI 與智慧運輸整合框架(Rong 等, 2025)

三、Huan Yan(2025)從智慧運輸的感知(Perception)、預測(Prediction)、模擬(Simulation)、決策(Decision-Making)等 4 個面向，來回顧與探討 Gen-AI 模型在智慧運輸的文字、影像、影片和跨模態資料生成應用(如圖 3 與圖 4 所示)。智慧運輸的文字、影像、影片和跨模態資料生成內容說明如下。

- (一)文本生成(Text generation)技術著重於利用人工智慧技術自主生成合理且有意義的文本，在智慧運輸中，文字產生被用於產生即時交通報告和自動事件警報等任務，這項功能能夠洞察交通狀況，並對動態交通狀況做出及時回應，從而提升整體交通管理水準和安全性。
- (二)影像生成(Image generation)是指利用人工智慧演算法，根據給定資訊產生新的圖像或視覺內容，在智慧運輸領域，影像產生用於產生合成影像，以測試自動駕駛車輛的駕駛演算法。透過產生反映各種交通場景、天氣狀況和光照環境的逼真影像，產生方法有助於提高智慧運輸中使用的駕駛行為決策模型的穩健性和性能。
- (三)視訊生成(Video generation)是指產生一連串且語義連貫的框(frame)，從而形成一段影片，在智慧運輸領域，可用於模擬交通場景、訓練自動駕駛系統以及分析車輛行為。視訊生成可以產生逼真的交通影片，以利在各種條件下測試和驗證演算法，而無需收集大量的實際數據。

(四)跨模態資料生成(Cross-modality data generation)是指基於一種模態的特徵產生另一種模態的資料，在智慧運輸領域，這對於將交通狀況的文字描述轉換為視覺表示(文字轉影像)、從路況監視交通攝影機影像產生文字報告(影像轉文字)或基於文字輸入建立交通場景模擬等任務至關重要。這些技術能夠提供多樣化且豐富的數據，從而進行全面的交通分析，並支援開發穩健的自動駕駛演算法。

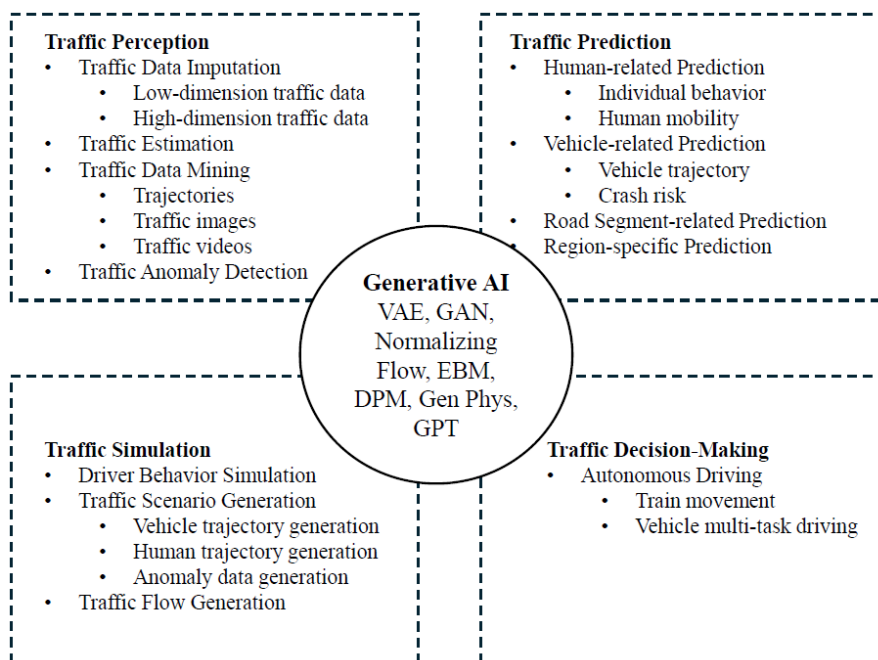


圖 3 Gen-AI 在智慧型運輸系統應用概述(Huan Yan, Yong Li, 2025)

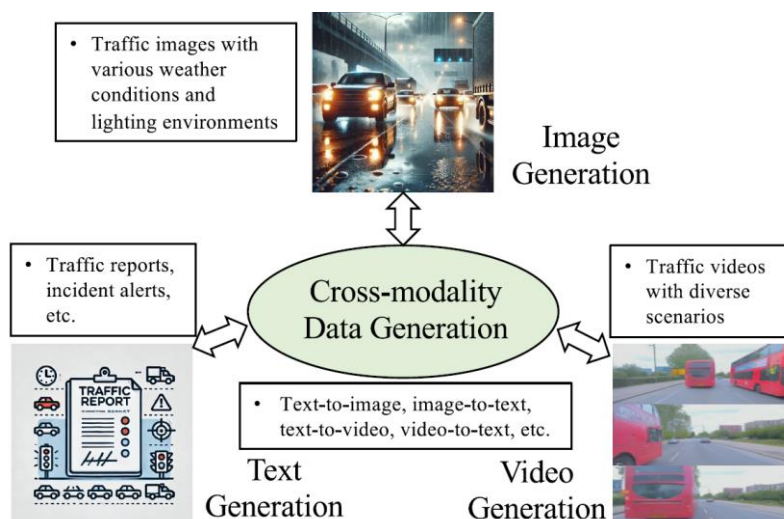


圖 4 Gen-AI 模型在智慧運輸的文字、影像、影片和跨模態資料生成應用(Huan Yan, Yong Li, 2025)

以下摘要說明 Gen-AI 與智慧運輸在感知(Perception)、預測(Prediction)、模擬(Simulation)、決策(Decision-Making)等 4 個面向關係。

(一) Gen-AI 與交通感知(Traffic perception)部分，

指的是智慧運輸資料蒐集和理解交通環境感知資訊的能力，這些資訊包括監視攝影機的影像數據、透過 GNSS 與加速規所蒐集的車輛軌跡與運動數據、天氣和路況等的環境數據，以及其他與交通相關數據(例如：其它車輛、行人和道路標誌的存在)。交通感知對於做出有效決策和確保安全至關重要。在自動駕駛車輛中，交通感知通常依賴攝影機、雷射雷達(LiDAR)、毫米波雷達和其它技術來蒐集和處理車輛周圍環境的數據，從而實現自動駕駛和導航。然而，準確的感知和理解交通環境中複雜動態面臨幾個重大挑戰。首先，在某些情況下，例如：攝影機被遮蔽時，感測器可能無法提供資料。這些數據缺失會干擾對交通狀況的持續監測，並將導致數據不完整或缺失。其次，在交通環境中蒐集的感測器數據會受到各種「雜訊」影響(包括感測器誤差、天氣狀況和光照變化)。「雜訊」會引起不確定性，使取得精確資訊變得更加困難。再者交通環境本身就是複雜且動態，涉及人車路的交互作用，因此準確地建模和理解交通行為極具挑戰性。

(二) Gen-AI 與交通預測(Traffic prediction)部分，

是指對未來交通狀況進行估計或預測，涵蓋旅次需求、旅行時間、車流量以及車輛與和行人的移動和行為等各個面向。交通預測對於都市交通規劃和管理至關重要，然而準確預測面臨著許多挑戰，首先都市交通系統呈現出複雜的時空動態特性。其次，交通特性屬高度動態變化，且易受即時事件(例如：施工或活動)等因素因而快速變化。再者從各種感測器、攝影機和 GNSS 設備獲取高品質數據對於交通預測至關重要，但此類數據常因通訊或其它因素因而不完整或品質不佳。

(三) Gen-AI 與交通模擬(Traffic simulation)部分，

涉及交通系統的建模，可用於產生車輛和行人的運動和行為，然而高逼真的交通模擬面臨許多挑戰，首先真實世界的交通場景資料通常透過道路攝影機或各式感測器收集。然而，取得此類數

據不僅成本高昂，而且在罕見或危險情況下也難以取得。其次交通屬性因為人的行為與決策因素，以及天氣或突發事件等的不可預測性，因而實務上取得此動態資訊具備相當的挑戰。若以傳統的深度學習方法通常需要大量的標註數據，並且可能無法掌握到稀少性的情境或場景。此時 Gen-AI 利用先前所提到的文字、影像、影片和跨模態數據生成，提供潛在的解決方案。

(四) Gen-AI 與交通決策(Traffic decision-making)部分，

是指車輛或其他道路使用者在動態交通環境與完成旅次需求而做出的一系列決策過程。在這些過程包括路徑規劃、號誌控制和車輛控制等三個面向。交通決策面臨的重大挑戰在於因路況、駕駛者的意外操作以及行人和自行車的突發行為等所產生的不可預測性，同時這些情境通常是數據蒐集困難，因而影響決策品質。傳統的決策方法或強化學習(Reinforcement Learning, RL)在處理複雜的交通場景往往效果有限，此時 Gen-AI 透過其在資料生成、推理和序列建模方面的優勢，為應對這些挑戰提供了極具前景的解決方案。例如：為降低罕見事件的影響，Gen-AI 可以產生模擬真實駕駛環境不可預測性的逼真訓練場景。

其中與本研究非重現性交通壅塞相關的為智慧交通管理與動態控制，當發生重大交通事故與極端天氣的事件時，交通控制中心立即啟動「動態路徑導引」，透過資訊可變標誌(CMS)進行資訊發布將車流疏散至替代道路，以及搭配動態號誌控制來配合此路網流量變化，以防止回堵。其中生成式人工智慧在交通號誌控制的應用，主要涵蓋動態號誌控制、流量預測、突發事件應變及環境優化等領域。特別是在利用生成對抗網絡(GAN)或變換器(Transformer)模型來預測高峰時段的交通情況、基於擴散模型(Diffusion Model)或強化學習生成不同的交通場景(例如：突發事件、交通事故)。

四、Shriyank Somvanshi (2025)在回顧 Gen-AI 在運輸系統管理與營運(TSMO)應用中指出知識管理(knowledge management)在 TSMO 中扮演重要角色，然而，知識管理的有效整合與應用受到來自數據碎片化與整合課題的主要挑戰。

數據碎片化指的是關鍵資訊往往如孤島般的被孤立於不同單位與系統。TSMO 所依賴的多元數據來源，例如：車流與人流數據、公

共運輸動態數據、事故與事件報告及天氣資料，往往來自不同主管機關，其資料格式不盡相同且可能存在不同定義或語意(Semantic)，導致整合與應用上的困難。另 TSMO 常須要在資源有限且具時效性，以及存在不確定性的情境下(如緊急事故或尖峰擁塞時段)，須處理複雜與龐大數據以進行快速決策，對決策工作形成重大挑戰。該文認為藉由生成式人工智慧來處理龐大數據的整合與合成、自動化知識萃提取、識別模式並生成預測等三項模組，能夠解決 TSMO 的複雜挑戰，來提升決策能力與品質。以下摘要說明此三項模組。

- (一) 在數據整合與合成模組方面，Gen-AI 利用先進的機器學習技術，例如：自動編碼器(Autoencoders)與神經嵌入(Neural Embeddings)，來協調多元數據集，確保其一致性與互操作性]。此外 Gen-AI 透過數據插補(Imputation)、降噪及異常檢測等技術解決不一致、缺失值與異常問題，進而提升數據品質。另 Gen-AI 藉由結合小客車、大眾運輸及行人的動態資訊，進行多元運具數據整合，來掌握完整的道路交通狀況，以強化交通控制與交通安全。
- (二) 在自動化知識萃取模組方面，交通管理單位所蒐集的海量與多元數據(包括：車流與人流、大眾運輸、事故事件及天氣資料)，可藉由生成式人工智慧來從此海量與多元的數據中，以自動化與高效地分析數據，來產生明智的決策。文中提到 Zhang 等人(2024)推出 TrafficGPT 模型，該模型將大型語言模型(LLMs)與交通基礎模型結合，來強化數據分析、交通控制與情境規劃；同時也提到 Zhao 等人(2024)提出 Gen-AI 的 TDS-GAN 模型，以及將之應用於模擬混合車流，來提升對自駕車與非自駕車行為的洞察能力。此外，Wang 等人(2023)將嵌入 LLMs 的 Co-Pilot(副駕駛)框架，能使車輛操作與駕駛者的意圖保持一致。Gen-AI 也應用於災後基礎設施評估也應用，例如：利用卷積神經網路(CNNs)與生成對抗網路(GANs)進行自動化交通標誌檢測。Wang 等人(2024)發展 TransGPT 來展示 Gen-AI 在生成交通情境並提供解決方案建議的潛力。
- (三) 在預測建模與情境規劃模組方面，Gen-AI 透過處理龐大數據集、揭示隱藏模式及模擬複雜情境，強化了這些流程。Yan 與 Li(2023)探討 Gen-AI 在智慧型運輸系統中對於交通感知、預

測與決策的應用，並強調其變革潛力與相關挑戰。

Gen-AI 透過以代理人為基礎的建模(Agent-based Modeling)與強化學習(Reinforcement Learning, RL)來進行情境模擬，以利於分析如車道封閉及緊急疏散等異常事件的應變預為準備。Qu 等人(2023)強調大型語言模型(如 ChatGPT 等)藉由整合多元數據源來優化車流預測。Zhang 等人(2021)的 SATP-GAN 結合自注意機制(Self-attention)、生成對抗網路(GANs)與強化學習，將車流預測的準確度提升 6.5%。此外 Yuan 等人(2024)提出一種混合增強智慧框架，將人類的回饋納入強化學習中，進而提升車輛決策的安全與效率。本文回顧 Gen-AI 在運輸系統管理與營運(TSMO)的應用領域包括在適應性號誌控制(Adaptive Traffic Control)、交通事故動態反應管理(Crash management)、運作績效監控(Performance Monitoring)。其中在交通事故動態反應管理屬本研究非重現性壅塞課題，因此進一步摘錄其文章內容如下。

Gen-AI 藉由自動化生成交通事故與事件期間的動態反應策略，帶來改變此反應策略產生的作業模式，例如：IncidentResponseGPT 框架能分析即時交通數據，並生成相對應的事件反應計畫，如車道封閉、可變資訊標誌(CMS)資訊發布等措施，最大限度地減少擁塞並加速事故排除。該框架利用區域性特定指引與排序機制，來追求反應效率最佳化，以將衝擊降到最低，讓它成為交通管理的主動性工具。

Gen-AI 同時也強化路網模型的預測能力，透過預測性維護與交通管理策略來提升交通安全。此外生成式模型與聯網自駕車(CAV)的整合將可改良交通模擬與預測模型，進而提升交通安全。再者多代理人強化學習(multi-agent reinforcement learning, MARL)的號誌控制系統，可支援交通事故/事件發生時的緊急車輛最佳化運行。整體而言，透過利用 Gen-AI 與 AI 驅動的交通管理解決方案，管理單位能提升作業效率，並確保及時且有效的事件反應。

四、生成式人工智慧在非重現性壅塞應用

如前所述，非重現性壅塞可分為預期性與突發性兩種，對於突發事件(例如：交通事故、惡劣氣候、特殊事件或突發路況等)導致道路容量臨時下降，其本質是脆弱性，以及發生率低、隨機性強、影響大的特性。對於非重現性交通壅塞的本質與特性，透過適當設計的 Gen-AI 模型，即有機會來透過歷史資料在事件發生前生成各項「極端情

境」及其對應之疏導措施，並利用交通模擬(例如：結合 VISSIM 或 SUMO 的數位孿生(Digital Twin))平台來評估各項「極端情境」下疏導措施的運作績效，以選擇最佳解決方案，並於事件發生時，迅速生成多個備選的疏導措施與號誌調整建議，並以自然語言解釋「為什麼這條路最好」，以輔助交控中心人員進行決策。從極端天氣所引發的非重現性交通壅塞觀點，上述作為同時可提高道路系統韌性，以及呼應政府在公路系統因應氣候變遷強化調適能力的政策方向。

以下回顧 Artur Grigorev 等(2024)的 IncidentResponseGPT、Siyao Zhang 等(2024)的 TrafficGPT、Qi Liu 等(2025)的 GATSim、Chengyang Zhang 等(2025)的 ChatTraffic，以及本所於 2025 年引用 ChatTraffic 的擴散模型利用臺北市 113 年資料所進行非重現性壅塞的研究。

一、Artur Grigorev 等(2024)的 IncidentResponseGPT 是一個即時在交通事件管理中產生自適應反應方案的 AI 框架(Framework)，該模型能夠綜合事件回應指南，並產生適用於特定區域的事件回應計劃，旨在幫助交通管理部門進行決策。此方法透過建議採取各種措施(例如：使用可變資訊標誌)來最大限度地減少對都市交通網絡的整體影響，從而加快事件解決速度。

IncidentResponseGPT 的建議措施，包括封閉車道、發佈公告和調度相應的緊急資源。此外該研究還提出了一種基於理想解相似度排序法(The Technique for Order Preference by Similarity to Ideal Solution, TOPSIS)用於根據影響最小化和資源效率等標準對生成的響應計畫進行排序，並根據其與人工提出的解決方案的接近程度來比較各個方案。

OpenAI ChatGPT 先前已被探索用於自然災害管理，並展示 LLM 在加速災害管理流程(災前、災中、災後等階段)中的適用性。這些模型已被證明能夠透過快速處理和分析大量數據來進行快速有效的決策，以及有效產生快速回應計畫並在事件發生期間傳播關鍵訊息，但在即時數據處理和專業準確性方面存在局限性。最近提出的 DisasterResponseGPT (2023)框架依賴 LLM 在災害情況下產生快速行動計畫，但在處理視覺和即時資料輸入方面有其限制。關於使用諸如交通演算法視覺化互動系統(Visual Interactive System for Transport Algorithms, VISTA)等模擬模型來模擬交通狀況和測試事件管理策略

的討論，進一步強調動態建模在有效應對不斷變化的交通狀況方面的優勢。這些模擬有助於進行預先規劃，對於縮短反應時間和有效管理交通事件期間的壅塞至關重要。另將地理資訊系統與人工智慧結合，可以顯著提高事件回應的效率，以及資源分配優化和即時交通中斷的處理。先前資料驅動模型在緊急應變管理系統中的整合已被廣泛研究，但傳統靜態模型與現實世界緊急應變管理動態需求之間的脫節，因此該研究提出向更具適應性與思維鏈視覺化的 IncidentResponseGPT 模型(Gen-AI 事件應變計畫生成)來根據即時數據輸入對反應策略進行即時調整和驗證。

IncidentResponseGPT 框架中採用多種 Gen-AI 模型，根據事故報告與緊急應變指南生成應變計畫(資料流程如圖 5)。該流程包含兩個主要步驟：(a)指南合成步驟：利用大型語言模型將應變指南處理成綜合形式，與(b)計畫生成步驟：將合成後的指南表示與事故報告串接至提示詞(Prompt)，以獲得最終的事件應變計畫。該研究採用美國聯邦公路總署(FHWA)交通事件管理手冊(Traffic Incident Management Handbook)作為應變指南，該手冊主要使用者為負責開發與改進事故管理計畫的管理人員與負責執行日常計畫的現場人員。該手冊內容包括：(1)事件管理定義及其重要性與參與單位、(2)事件管理的組織、規劃與設計、(3)提供建立或強化計畫的逐步流程，強調協作、數據分析、目標設定與評估的重要性、(4)概述改進事件管理流程的操作與技術方法，並提及事件管理各階段(如偵測、核實、用路人資訊提供、應變、現場管理、交通管理及清障)的具體技術與策略、(5)結合計畫開發的流程導向指南，以及適用於實際事件應變的策略與技術工具箱。IncidentResponseGPT 先透過生成式 AI 模型進行指南的預處理，以萃取有關事件嚴重程度評估、應變人員安全、交通管制及資訊發布的關鍵指令，萃取後的指令會被轉換為結構化的表格格式。

美國「事故報告」(US-Accidents)數據透過多個 API 蒐集即時交通事件，該數據集包含每筆事故記錄的下列屬性：地點詳情、事故開始與結束時間、環境狀況(氣候條件，如溫度、風寒指數、濕度、能見度及降水量)、事故詳情(嚴重程度、描述及受影響距離)、周邊特徵(是否存在交通號誌、平交道、交叉路口及其它 POI、光線狀況)。IncidentResponseGPT 是由 OpenAI ChatGPT、Microsoft Copilot、Google Gemini 等生成式語言模型組合來驅動。透過前述 LLM 的文

字處理能力，應變計畫不僅能根據符合區域特定準則的輸入事故數據來制定，還能結合操作員的即時回饋，以及交通事故當前與發展中的狀態。最後該研究利用差異分值(Difference Score)來比較各 LLM 所產生應變計畫與人工解決方案間之差異，差異分值越低，表示該模型的應變計畫越接近理想方案。

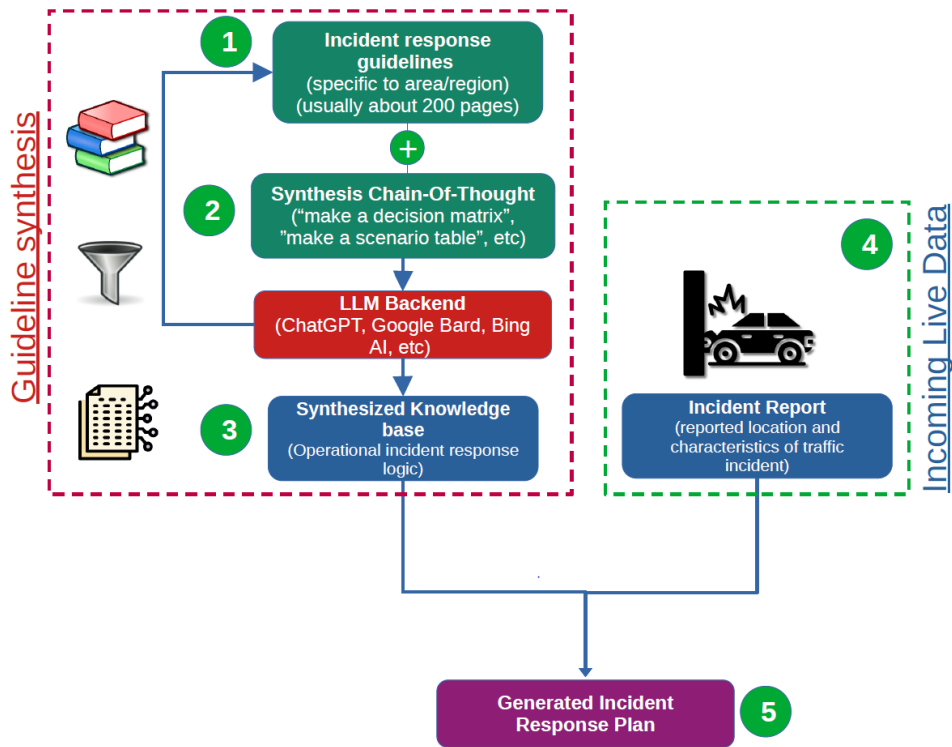


圖 5 IncidentResponseGPT 資料流(Artur Grigorev 等, 2024)

由於 LLM 發展迅速，因此該研究(2024)所分析各 LLM 與人工解決方案差異如後僅供參考。Gemini 1.5 Pro 與 Gemini 1.5 Flash 的差異分值在大多數事故中明顯偏高，該模型傾向於納入過多行動方案。GPT-4 在大多數事故中與人工解決方案的差異極低，這顯示 GPT-4 的應變措施經過良好校準，因此與人工應變計畫高度一致。GPT-4 Omni (GPT-4o)與 ChatGPT 3.5 模型與人工解決方案的對齊程度尚可，然而它們的穩定性不如 GPT-4。雖然 GPT-4o 的表現優於 Gemini 1.5 Pro，但與人工解決方案相比仍存在一些偏差。

該研究結果顯示 Gen-AI 模型在交通事故管理創新具有巨大潛力，然而分析顯示各類語言模型在生成應變計畫時，其準確性與有效性存在顯著差異。最後該研究認為在交通管理中部署數據驅動 Gen-AI 時面臨著諸多挑戰，例如：潛在的數據與指南偏差，以及自動化決策的倫理考量，然儘管存在這些挑戰，AI 驅動的交通管理能夠迅速生成

複雜、具適應性且透明的應變計畫，對於提升安全性、減輕事故對車流的衝擊，以及降低道路事故帶來的經濟與環境衝擊，具有深遠的意義，後續仍應持續進行探討。

二、Siyao Zhang 等(2024)認為隨著大型語言模型(例如：ChatGPT)的逐漸普及，大型語言模型在常識、推理和規劃能力方面展現出卓越的性能，為此人們正在嘗試將其應用到各個應用場景。

該研究嘗試將大型語言模型應用到都市交通控制管理，順利將其與交通專業知識相融合，使 ChatGPT 能夠查看、分析、處理交通數據，並為都市交通系統管理提供富有洞察力的決策支援。在交通管理領域，也有各式各樣的交通基礎模型(Traffic Foundation Models, TFM)，此模型大多經過精心設計，用來解決與交通相關的具體問題。雖然這些 TFM 在特定任務中表現出色，然由於 TFM 數量很多且具有相當專業性，學習曲線很長。因此本研究透過「彌合大型語言模型與 TFM 中嵌入的專業知識之間的差距」的 TrafficGPT，使 LLMs 理解自己的行為，進而讓 LLMs 完成一些複雜的操作並為人類提供決策建議，藉由無縫整合來縮短學習曲線，來降低學習門檻，進而加強對交通管理領域的理解和問題解決。

TrafficGPT 使用來自多元(視訊、偵測器、模擬系統)的多模態交通資料，透過中間資料庫管理層來實現資料存取，架構最外層利用大型語言模型(LLM)來了解使用者需求，並經由 TFM 來完成任務執行，圖 6 為其架構圖。圖 7 說明 TrafficGPT 利用大語言模型來解構和執行複雜任務的機制與 8 個步驟，以下摘要說明此 8 個步驟。

- (一)步驟 1：自然語言輸入(Natural Language Input)：首先由使用者透過 TrafficGPT 前端以自然語言方式輸入任務需求。此輸入文字將作為提示，並傳遞到下一步進行提示管理。
- (二)步驟 2：提示管理(Prompt Management)：作為基礎步驟，「提示管理」用於定義 LLM 代理程式的執行框架，內容包括描述代理的工作機制、明確關鍵考慮因素以及傳達可用 TFM 的訊息。此外，此步驟還允許整合歷史對話上下文，以促進多次互動。
- (三)步驟 3：自然語言理解與任務規劃(Natural Language Understanding and Task Planning)：利用大型語言模型(LLM)及

其認知能力，代理人可以理解自然語言提示與進行演繹推理，透過整合任務請求、可用的任務模型(TFM)集以及推理歷史庫來完成。此智慧處理過程最終形成可辨識且可操作的見解(insights)，這些見解被稱為「想法(Thought)」。圖 2 為推理流程的說明。

- (四)步驟 4：交通基礎模型執行(Traffic Foundation Model Execution)：基於已建立的思路，代理人使用選定的交通基礎模型(TFM)，並依照 TFM 定義的相關參數執行不同的資料庫檢索和分析、資料視覺化，以及系統最佳化等任務，最後產生結果與輸出。
- (五)步驟 5：結果輸出與中間答案(Result Output and Intermediate Answer)：TFM 執行完畢後，代理人透過應用程式介面(API)擷取 TFM 輸出，將輸出中間答案以自然語言形式呈現，供 LLM 進行進一步的規劃。
- (六)步驟 6：任務評估與延續(Task Assessment and Continuation)：代理人對使用者任務請求和正在進行的中間答案進行比較分析，以評估任務完成狀態。如果任務仍未解決，則流程將回到步驟 2 至步驟 5，以確保執行過程的迭代(iterative)持續。
- (七)步驟 7：產生最終答案(Final Answer Generation)：在步驟 6 確認任務完成後，代理人利用 LLM 功能，整合 TFM 產生結果轉化為最後結果與透過前端介面提供使用者。
- (八)步驟 8：對話記憶儲存(Dialogue Memory Storage)：在此步驟中，將使用者與 LLM 對話互動內容儲存為話歷史紀錄，以為後續互動中提示管理的輸入與對話上下文參考之用。

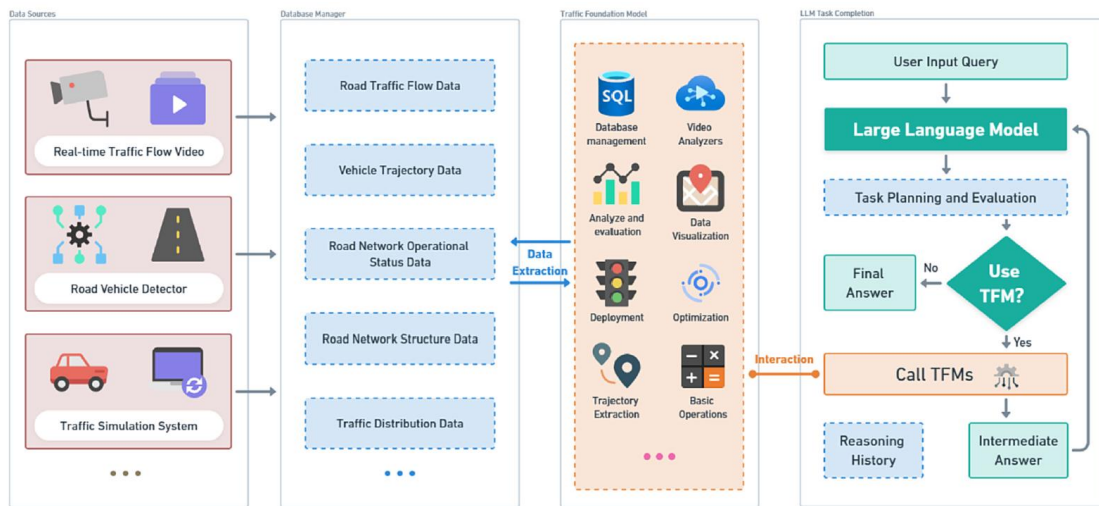


圖 6 TrafficGPT 架構(包括 Traffic Foundation Models (TFM)與大型語言模型(LLM))

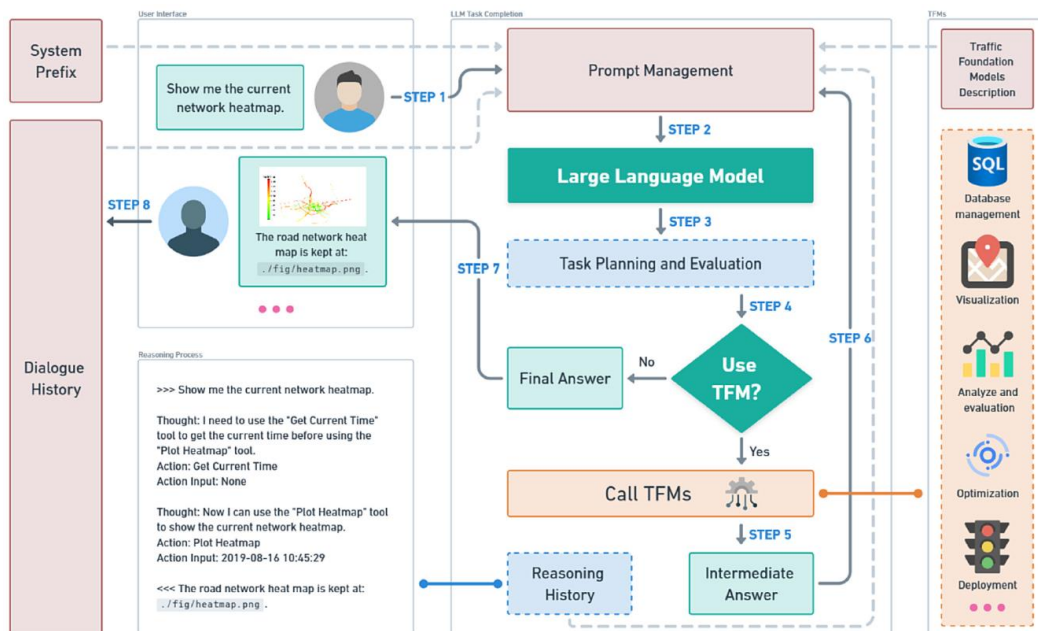


圖 7 TrafficGPT 運作流程概述

三、Qi Liu 等(2025)認為傳統多依賴代理人以規則系統為基礎的都市交通模擬(例如：AIMSUN, VISSIM, CUBE)，無法掌握旅次決策過程的複雜性、適應性(adaptability)和多樣性。

近年來，大型語言模型和人工智慧代理人技術(AI agent)的發展提供與構建代理人具有推理能力、持久記憶和自適應學習機制的契機，例如：進行都市規模交通預測的 UrbanGPT 與 OpenCity，或著重在運輸控制的 TransGPT 與 TrafficGPT，又如每日旅次產生的需求導向自主代理人(Desire-driven Autonomous Agents, D2A)。該研究提出具有豐

富行為特徵的生成式代理人以進行都市交通模擬的生成式交通模擬代理人 (Generative-Agent Transport Simulation, GATSim) 框架。GATSim 代理人具有多樣化的社會經濟屬性、個人生活方式和不斷變化的偏好，這些屬性和用路人旅運決策偏好係透過心理學記憶系統 (Psychologically-informed memory systems) 來掌握、工具使用能力和終身學習機制來形塑。

四、Chengyang Zhang 等(2025)認為交通預測是智慧運輸最重要的基礎之一，傳統預測方法多依賴歷史交通數據來預測交通趨勢，面臨兩大挑戰，一為對異常事件不敏感，二為長期預測性能有限。

因此該研究探討如何將 Gen-AI 與描述交通系統狀況的文本結合，用於交通情境生成，並將這項任務命名為文字到交通情境生成(Text-to-Traffic Generation, TTG)(如圖 8 所示)。TTG 任務的關鍵挑戰在於如何將文字與道路網路的空間結構和交通數據連結起來，以產生交通情境。本研究提出以 Gen-AI 擴散模型(Diffusion models)來發展用於文字到交通情境生成的 ChatTraffic。為確保生成資料和真實資料之間的一致性，以圖卷積網路(Graph Convolutional Networks, GCN)的空間感知能力，來增強擴散模型在擷取交通數據的空間相關性，同時也為 TTG 任務建立了一個包含文字-車流量對的大型資料集。最後以中國大陸北京市五環內 1260 條道路交通數據，以及對應描述交通系統狀態的 22320 文本，來進行模型定性和定量基準測試。交通數據的三個維度是每條道路上的速度(Speed)、每條道路的壅塞程度(Congestion Level)、旅行時間(Passing Time)，文本內容包括異常事件發生的時間、類型和地點。

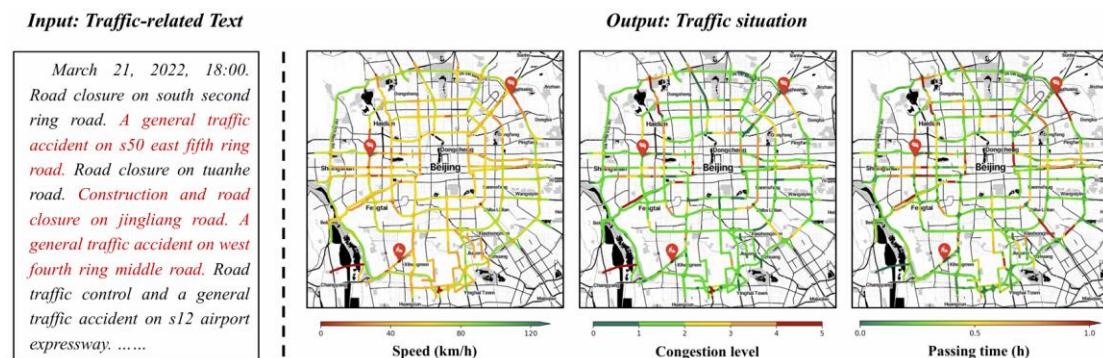


圖 8 ChatTraffic 擴散模型的文字到交通情境生成(TTG)(Chengyang Zhang 等, 2025)

該研究於提出以擴散模型構建 ChatTraffic 前，先行回顧生成對抗網路(GAN)與變異自動編碼器(VAE)在文本與交通情境生成應用的可行性分析。該研究認為 GAN 透過對抗訓練來隱式擬合資料分佈，從而實現高品質的生成，然而 GAN 方法易受到模式崩潰(model collapse)和訓練不穩定的限制；而 VAE 方法訓練相對穩定，但與 GAN 相比，其細節模糊，輸出品質較低。與 GAN 和 VAE 相比，該研究認為擴散模型更容易訓練，而且具有更強的生成能力，是當今最穩健的生成模型之一。

該研究將流量產生視為一系列擴散步驟，並針對 TTG 任務導入基於 Latent Diffusion Model (LDM)框架的 ChatTraffic。LDM 是最早提出擴散模型的演算法之一「去噪擴散機率模型(Denoising Diffusion Probabilistic Models, DDPM)」的高效率版本，可以通過在特徵數更少的潛空間(Latent Space)上計算來提升生成效率。為克服傳統流量預測方法所面臨的挑戰，該研究使用包含時間和事件的文字來指導去噪過程，從而產生流量；此外也利用圖卷積網路來增強擴散模型。除時間和事件外，交通狀況也受到道路網路結構的影響。有鑑於此，引入 GCN 的主要想法是利用路網的空間資訊作為約束條件，調整交通特徵，從而實現更準確的條件交通生成。

圖 9 為 ChatTraffic 的方法概述。ChatTraffic 核心組件包括由 ResNet 和交叉注意力機制所構成的 UNet，以及一個 GCN。首先對數據進行填充(populate)和重塑(reshape)，使其更適合做為擴散模型的輸入；使用文字編碼器從描述交通系統狀態的文字中提取出特徵來嵌入。此外導入 GCN 來讓生成資料與道路路網的空間性關聯較為一致。GCN 以帶有雜訊的交通資料 x_t 和描述路網空間相關性的鄰接矩陣 A 作為輸入，將結構和資訊關聯起來。在完成 ChatTraffic 的訓練後，給定一段描述交通狀況的文本，可得到預測的交通資料。每個圖片像素點對應一條特定的道路，並可以在地圖上以視覺化方式來呈現這些道路的交通狀況。三種不同顏色線條來表示三種不同的特徵，其中速度和通過時間是連續數據，擁塞水平是離散數據如圖 8 所示。

該研究將 ChatTraffic 與傳統流量預測方法進行定量比較分析，實驗結果顯示 ChatTraffic 相較於其它流量預測方法擁有產生未來交通狀況的能力，特別是在受異常事件影響的場景下。對於 ChatTraffic 感知道路異常事件的能力部分，經由視覺化的定性分析比較，

ChatTraffic 對異常交通較敏感，可以較準確地預測交通狀況，其結果輸出與真實路況一致，顯示它有能力反映異常事件對道路的影響。

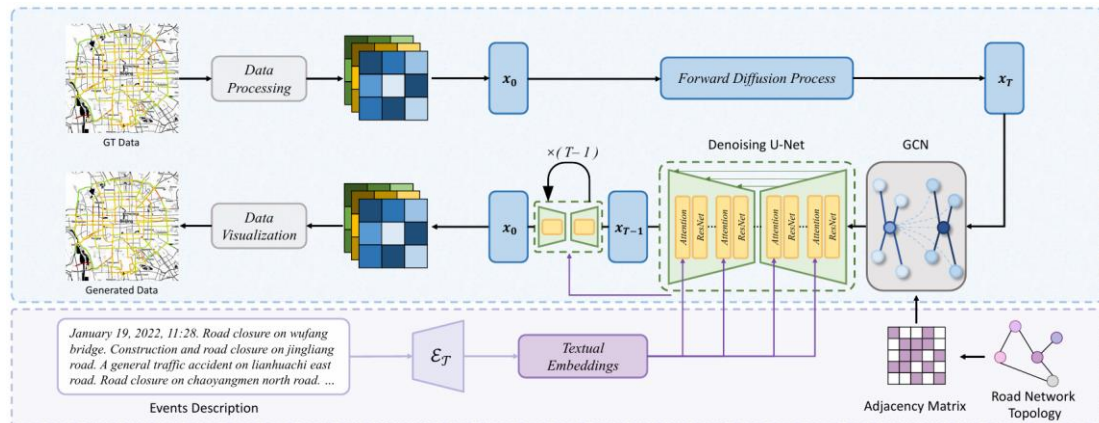


圖 9 ChatTraffic 方法概述(Chengyang Zhang 等, 2025)

五、本所於 2025 年進行國內首次導入生成式人工智慧在非重現性交通壅塞研究，該研究參考 ChatTraffic 模型，並以臺北市內各區域之相關資料使其為增加訓練資料量與提高生成資料針對各種路口特性產出更為多樣化與準確之輸出。

資料內容包括 113 年度臺北市的車輛偵測器即時交通資料、交通事故資料以及天候資料，資料涵蓋研究場域內主要幹道、匝道與交叉口路段，並橫跨平日與週末、尖峰與離峰時段，確保資料具多樣性與代表性。車輛偵測器資料內容包括資料時間、設備編號、偵測方向、各車種流量(大小機車，聯結車，與自行車)、平均速率、平均佔有率；天候資料內容包括資料時間、偵測區域、能見度、降水量、降水時間、風速；事故資料內容事故發生時間、區域、地址、路口型態、發生位置、事故類別。

ChatTraffic 屬多模態交通生成模型，可根據自然語言提示產生對應時間點之城市交通狀態圖像，其核心架構結合語意理解、圖神經網路與潛在擴散模型(Latent Diffusion Model, LDM)。在資料輸入端，以自然語言書寫的提示文字，用以描述特定時間、地點及事件的交通狀況。這些描述可包含多筆事件，並可靈活擴展至任意區域或事故組合，使模型具備極高的語意適應性。輸入文字提示將被送入預訓練的 Bert 模型(Bidirectional Encoder Representations from Transformers)，以將前述的自然語言轉換為機器可理解之數值向量，並透過 cross-attention 融入至去噪 U-Net 網路中，來擷取文字中的語意訊息(如時間、地點、

事件類型)，作為後續擴散模型之「指導」或「條件」，以及「引導」生成過程。

ChatTraffic 模型核心為 U-Net 網路，負責執行擴散模型的去噪工作，同時 U-Net 網路又藉由圖卷積網路(GCN)來強化模型理解道路網絡之拓撲結構。圖卷積網路(GCN)透過鄰接矩陣(Adjacency matrix)讓去噪 U-Net 網路在處理 VD_i 的數據時，能夠「參考」其所有相鄰節點(如 $VD_j, k...$)的狀態，因此當模型決定某個偵測點車速時，透過 GCN 可同時考慮周邊其他偵測點的資訊，如此可確保生成結果之「空間連貫性」，且生成交通模式是合乎邏輯與接近真實世界的。實作時以圖注意力網路(Graph Attention Network, GAT)模型取代 GCN，GAT 模型透過可學習的注意力權重分配機制，自動調整節點間訊息傳遞強度，理論上可更靈活建模複雜的道路關聯，其餘架構則維持不變。在完成資料處理(包含創建 VD 特徵資料、語意提示文本與鄰接矩陣 A)後，依時間順序將數據分為訓練集(70%)、驗證集(10%)、測試集(20%)。圖 10 為交通部運輸研究所在非重現性交通壅塞研究的 Gen-AI 擴散模型訓練流程。經訓練與生成後的資料則透過 SUMO 來進行模擬與評估。

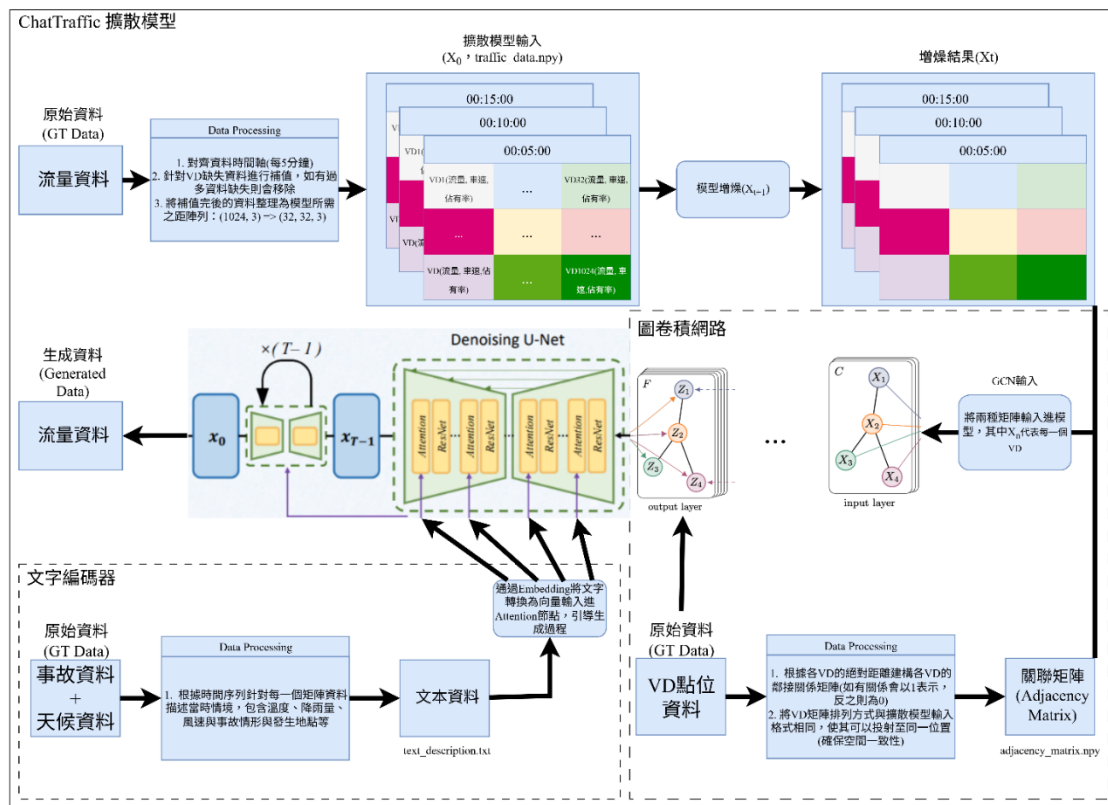


圖 10 交通部運輸研究所的 Gen-AI 擴散模型訓練架構

六、結論與建議

近年來人工智慧已廣泛應用於交通運輸領域，且人工智慧在技術上已從早期的「規則化自動處理」演進至現今的 Gen-AI 的「主動感知、因果推理與生成式應變」。Gen-AI 在文本生成、影像生成、視訊生成、跨模態資料生成等能力，提供智慧運輸在交通感知、交通預測、模擬、決策上有著強大的應用潛力，例如：Somvanshi、Rong、Yan、Da 等所探討 Gen-AI 透過情境生成、交通模擬與優化、生成式推論技術等在運輸規劃、智慧運輸與運輸管理等領域應用。

對於非重現性壅塞真實樣本少課題，在交通模擬的關鍵是在數據擴增(Data augmentation)，數據擴增作法包括：(1)在微觀交通模擬軟體中，隨機在不同路段、不同時間點「插入」事件情境，來觀察路網的承受極限，(2)利用具代表性的大型事件(如重大車禍、極端暴雨)，在模擬環境中還原當下的車流分配與時空軌跡，(3)利用 Gen-AI 的擴散模型或生成對抗網路，學習少量的真實歷史數據，進而生成大量「統計特徵相似但情境各異」的「虛擬」壅塞情境，解決樣本不足的問題。在數據擴增程序完成後，其所產生的「虛擬」壅塞情境，即可協助管理單位據以研擬對應策略(例如：動態號誌或路徑導引)，策略之研擬係利用非重現性壅塞發生成因(天氣、事故)數據，來訓練 AI 模型以掌握未來事件的發生機率與車流時空擴散型態。

所研擬策略並不能在現實環境中進行實驗，因此可透過「數位雙生」(Digital Twin)來進行分析與效益評估。此作業模式不單是將原非重現性壅塞的交通管理，從「被動反應」轉化為「主動預警」，同時將增強交通路網在遭受衝擊後的韌性。交通路網的韌性增強係因為導入預測性管理機制，此機制預先利用 AI 或擴散模型預測事故後的衝擊範圍，在壅塞衝擊抵達前就先行介入，這將非重現性事件帶來的「不確定性」轉化為可控管的風險。對於突發性的非重現性壅塞，其本質是脆弱性，以及發生率低、隨機性強、影響大，透過適當設計的 Gen-AI 模型，即有機會來透過歷史資料在事件發生前生成各項「極端情境」及其對應之疏導措施，並利用交通模擬來評估各項「極端情境」下疏導措施的運作績效，以選擇最佳解決方案，並於事件發生時，迅速生成多個備選的疏導措施與號誌調整建議。

IncidentResponseGPT 利用事故歷史資料及其應變指南，結合大

型語言模型來生成事件應變計畫；TrafficGPT 使用來自多模態交通資料，利用大型語言模型來結合各種交通基礎模型，以應對不同的事件與處理；GATSim 則透過生成式交通模擬代理人機制來應對各種交通課題；ChatTraffic 與本所均利用擴散模型結合圖卷積網路來進行「文本轉交通生成(TTG)」，ChatTraffic 已初步驗證透過文字輸入生成城市級交通情境的可行性，展現將此方法與現有交通監控基礎設施整合的潛力，相對之下，本所利用臺北市資料所發展的 TTG 模型則待後續進行探討。然 ChatTraffic 所提及其實務應用限制，例如：目前僅接受結構化文本輸入、僅在北京市的數據上得到驗證、僅適用定時號誌控制環境，並期望後續可以結合大型語言模型、擴充至其他城市環境、適用於動態交通環境等 3 點，此 3 點亦可為本所或我國相關研究之後續研究的參考。

參考文獻

1. 董尚義等，2025，人工智慧號誌控制精進—多任務強化學習期中報告書初稿，交通部運輸研究所
2. 黃益三，2016，改善塞車問題-以臺北市內湖區交通壅塞為例，105 年道路交通安全與執法研討會
3. 俞紫娟，2007，市區道路發生阻斷性意外事件下之全動態交控號誌應變績效研究，國立嘉義大學碩士論文
4. 張鈞凱，2007，高速公路可變速限聯合匝道儀控最佳化模式，國立臺灣大學碩士論文
5. Artur Grigorev, Adriana-Simona Mihaita, and Fang Chen, 2024, Traffic Incident Duration Prediction: A Systematic Review of Techniques, Journal of Advanced Transportation
6. Artur Grigorev, Khaled Saleh, Yuming Ou, Adriana-Simona Mihaita, 2024, IncidentResponseGPT: Generating Traffic Incident Response Plans with Generative Artificial Intelligence, arXiv:2404.18550v4.
7. Chengyang Zhang; Yong Zhang; Qitan Shao; Bo Li; Yisheng Lv; Xinglin Piao, and Baocai Yin, 2025, ChatTraffic: Text-to-Traffic Generation via Diffusion Model, IEEE Transactions on Intelligent Transportation Systems, Volume: 26, Issue: 2.
8. Huan Yan, Yong Li, 2024, A Survey of Generative AI for

Intelligent Transportation Systems: Road Transportation Perspective, Association for Computing Machinery (ACM) Computing Surveys, Volume 57, Issue 12.

9. Linwu Chen, Junqing Shi†, Minghui Cheng, Hongwei Zhu, Lin Sun, 2020, Characteristics of Urban Road Non-recurrent Traffic Congestion Based on Floating Car Data, Association for Computing Machinery (ACM) ISBN 978-1-4503-8781-1.
10. Longchao Da, Tiejin Chen, Zhuoheng Li, Shreyas Bachiraju, Huaiyuan Yao, Li Li, Yushun Dong, Xiyang Hu, Zhengzhong Tu, Dongjie Wang, Yue Zhao, Ben Zhou, Ram Pendyala, Benjamin Stabler, Yezhou Yang, Xuesong Zhou, Hua Wei, 2025, Generative AI in Transportation Planning: A Survey, arXiv:2503.07158.
11. Mingxing Peng, Kehua Chen, Xusen Guo, Qiming Zhang, Hui Zhong, Meixin Zhu, and Hai Yang, 2025, Diffusion Models for Intelligent Transportation Systems: A Survey, IEEE Transaction on Intelligent Transportation System, Vol. 26, No. 12.
12. Qi Liu, Can Li, and Wanjing Ma, 2025, GATSim: Urban Mobility Simulation with Generative Agents, arXiv:2506.23306v2
13. Rui RONG, Shoufeng MA, Nianlu REN, Qinqing LIN, Ning JIA, 2025, Generative artificial intelligence in intelligent transportation systems: A systematic review of applications, Frontiers of Engineering Management, Springer Nature.
14. Shriyank Somvanshi, Jinli Liu, Subasish Das, 2025, A Survey on Generative AI in Transportation Systems Management and Operation, IEEE Conference on Artificial Intelligence.
15. Shriyank Somvanshi, Swastika Barua, Jinli Liu, and Subasish Das, 2024, Generative artificial intelligence for Transportation Planning, Journal of Association for Computing Machinery (ACM) 37, 4.
16. Siyao Zhang, Daocheng Fu, Wenzhe Liang, Zhao Zhang,

Bin Yu, Pinlong Cai, Baozhen Yao, 2024, TrafficGPT: Viewing, processing and interacting with traffic foundation models, *Transport Policy* 150, 95-105.

17. The Federal Highway Administration (FHWA), 2021, Disaster Recovery Reform Act Section 1209 (Contraflow Provision)
18. YongKyung Oh, Jiin Kwak, Sungil Kim, 2026, Predicting non-recurrent congestion impact: A pattern-based approach for speed drop ratio prediction using weighted K-nearest neighbors, *Computers and Industrial Engineering*
19. Younshik Chung, 2017, Identification of Critical Factors for Non-Recurrent Congestion Induced by Urban Freeway Crashes and Its Mitigating Strategies, *Sustainability* 9, 2331
20. https://ops.fhwa.dot.gov/program_areas/reduce-non-cong.htm