

結合大型語言模型與隨機森林之酒精相關交通事故成因分類與分析研究

Alcohol-Related Traffic Accident Causation Analysis Using Large Language Models and Machine Learning

陳靖佑 Jing-Ji Chen¹
陳侑潔 You-Jie Chen¹
游筑閔 Chu-Min Yu¹
陳聿琦 Yu-Chi Chen¹
李昱捷 Yu-Jie Lee²

摘要

近年來，道路交通事故持續對交通安全構成重大挑戰，其中酒精駕駛被認為是導致嚴重事故之關鍵風險因子之一，主要係酒精攝取會削弱駕駛人的反應、判斷及注意力，提高事故發生機率，惟既有交通事故分析多著重於道路設計、交通設施及天候條件等外在因素，對於駕駛人行為面之探討雖有但相對不足，特別是在酒精影響下，事故發生機制可能與一般情境存在系統性差異，顯示有必要進一步釐清其成因結構。故本研究旨在探討酒精介入是否改變交通事故之成因分布，分析兩類事故於內在因素（駕駛人因素）與外在因素（環境與設施因素）之比例分布特性，分析酒駕事故相較於一般事故，是否更集中於駕駛人因素，以及歸納酒駕事故中常見之肇事行為類型，另本文亦透過統計方法檢定兩類事故成因分布是否存在顯著差異，並建構事故原因分類模型，評估其判別之可行性與準確性，期藉由客觀且系統化之分析結果，提供交通安全改善及酒駕防制政策之實證依據。

本研究以交通部高速公路局中區養護工程分局為資料來源，經資料清理後取得24,344筆有效樣本，首先採用大型語言模型分析事故原因文字，建立內、外在因素分類準則，並轉換為Python以完成大量資料標註，透過隨機森林建構事故成因分類模型，進行模型訓練與優化，以評估事故成因判別之可行性並支援後續分析應用，最後採用費雪精確檢定比較有無接觸酒精事故於成因分布之差異，顯示兩組在統計上具有顯著差異。結果顯示，酒駕事故較集中於駕駛人違規或不當駕駛等內在因素，而無接觸酒精事故則相對較易受外在環境與設施因素影響。此外，本研究建構之事故原因分類模型具備良好之分類效能，顯示事故成因之自動化判別具有實務應用潛力，綜上，本研究不僅釐清酒精因素對事故成因結構之影響，亦有助於降低事故資料人工分類成本，並可作為交通安全分析、酒駕防制及相關政策規劃之參考依據。

關鍵詞：酒駕防制、事故成因分析、機器學習

¹ 逢甲大學運輸與物流學系學士班學士生

² 逢甲大學運輸與物流學系學士班學士生，臺中市西屯區鵬程里文華路100號，04-24517250#4652，D1358822@o365.fcu.edu.tw

一、緒論

本章主要說明本研究之研究背景、研究動機及研究目的，藉由探討酒精駕駛與交通事故之關聯性，建立本研究之研究方向與分析基礎。

1.1 研究背景及動機

交通事故長期以來皆為影響道路交通安全之重要議題，其中酒精駕駛更被視為導致重大交通事故的重要因素之一。酒精進入人體後，會影響中樞神經系統運作，使駕駛人的反應能力、判斷能力及注意力下降，進而增加事故發生風險。

在事故發生後，事故責任的判定通常涉及駕駛人、車輛以及道路環境等多項因素。然而社會大眾在討論交通事故時，往往傾向將事故原因歸因於道路設計、交通設施或天候等外在環境因素，而忽略駕駛人本身行為所造成之影響。

當酒精成為事故中的重要變因時，事故責任的歸屬可能與一般事故有所不同。因此本研究希望透過交通事故資料分析，比較有接觸酒精與無接觸酒精事故案件在事故成因上的差異，探討酒精介入後事故原因是否更集中於駕駛人本身因素，並進一步分析酒駕事故中最常見之肇事行為，以了解酒精對駕駛行為所造成之影響。

交通安全治理上，事故成因可大致區分為駕駛人相關因素與外部環境、車輛或道路設施因素，而此一區分具有實務上的政策意義，主要係不同成因類型所對應之改善策略並不相同，若事故主要來自駕駛人內在因素，例如未注意車前狀況、未保持安全距離、超速或酒後駕車，則改善方向較偏向執法強化、交通安全教育、駕駛行為管理與高風險駕駛防制；若事故主要來自外部環境或硬體因素，例如道路缺陷、掉落物、視線遮蔽、照明不足或車輛機件故障，則較需透過道路工程改善、巡檢維護、設施管理與車輛安全檢驗等方式處理。故將事故原因區分為內在因素與外在因素，有助於釐清事故防制作為應著重於「人」或「環境與設備」，亦有助於判斷酒精介入後是否使事故責任與防制重點更加集中於駕駛人行為。

1.2 研究目的及方法

為探討酒精因素對交通事故成因之影響，本研究透過事故資料分析，比較有接觸酒精與無接觸酒精事故案件在事故成因結構上的差異，並進一步分析酒駕事故中常見之肇事行為。此外，本研究亦透過統計推論與分類模型建構，驗證研究結果之可靠性及事故原因分類之可行性。基於上述研究方向，本研究之研究目的如下：

1. 探討無接觸酒精組與有接觸酒精組在內在因素及外在因素上的比例差異。
2. 分析有接觸酒精組事故案件之主要肇事行為與事故特徵。
3. 利用統計推論方法驗證兩組事故成因是否存在顯著差異。
4. 建立事故原因分類模型，以驗證事故原因分類之可行性。

二、文獻回顧

2.1 酒駕與事故風險之國內外實證研究

酒精對駕駛能力的損害是交通安全領域公認的核心風險因子。酒精進入人體後會直接干擾中樞神經系統，顯著降低駕駛人的反應速度、距離判斷力及注意力，進而大幅提高事故發生的機率。根據美國國家公路交通安全管理局的界定，血液酒精濃度（BAC）達 0.08 g/dL 或更高時，即被視為酒精受損駕駛（National Center for Statistics and Analysis, 2023; 2026）。

國際實證數據進一步證明酒精接觸與致死風險的強烈相關性。在 2021 年與 2024 年，美國交通致死事故中涉及至少一名酒精受損駕駛員的比例分別高達 31% 與 30%（National Center for Statistics and Analysis, 2023; 2026）。研究指出，酒駕風險具有顯著的時間性，夜間酒精受損駕駛的比例約為白天的 3 倍（National Center for Statistics and Analysis, 2026）。此外，BAC 數值雖與法律責任掛鉤，但實證顯示，在酒駕致死案中約有 67% 至 68% 的案例涉及 BAC 達 0.15 g/dL 以上的高度受損者，突顯酒精接觸會從根本上改變事故本質（National Center for Statistics and Analysis, 2023; 2026）。跨文化分析亦證實，酒駕是導致許多發達國家道路致命傷亡的共通關鍵因子（Jaradat et al., 2025）。

2.2 交通事故文字探勘相關研究

傳統交通安全分析高度依賴結構化表格資料，但此類資料常面臨資訊缺失、編碼錯誤或無法捕捉事故發生連續序列等瓶頸（Sayed, 2022）。相對而言，員警紀錄的「事故敘述（Crash Narratives）」作為非結構化文字，則能提供豐富的語境資訊以彌補結構化欄位之不足（Sayed, 2022）。隨著人工智慧技術演進，文字探勘已從早期的語意分析發展至以 BERT 為首的 Transformer 深度學習架構。

近年來，預訓練語言模型已廣泛應用於交通事故文字分析。BERT、Sentence Transformer 等模型皆屬於預訓練語言模型架構，可將文字轉換為具語意資訊之向量表徵。部分研究進一步結合 Bi-LSTM 或其他深度學習分類器，採用端對端訓練方式進行事故嚴重程度或事故類型分類，並取得良好分類表現。然而，端對端深度學習方法通常需要大量具品質保證之標註資料，且模型訓練、參數調整與解釋成本相對較高。

相較之下，本研究並未主張所採用之 Sentence Transformer 加隨機森林方法優於 BERT、Bi-LSTM 或其他深度學習模型，而是基於研究資料缺乏專家標註 ground truth 之限制，採取較具操作性之兩段式流程。首先將事故原因文字轉換為語意向量，再以傳統機器學習模型檢驗其對規則標註結果之再現能力。此設計之價值在於提供一套可重複、計算成本較低且便於後續人工審查之事故文字整理流程，作為未來建立專家標註資料庫與發展正式分類模型之前置基礎。

2.3 不平衡資料分類方法

交通事故資料集普遍存在嚴重的類別不平衡現象，即致命或嚴重違規案件（少數派）遠少於一般事故（多數派）。若未妥善處理，模型往往會偏向預測多數類別以換取虛假的高總準確率，導致系統失去對關鍵安全風險的偵測能力（Alanazi and Suleiman, 2025）。為解決此問題，研究多採用重採樣技術，如 SMOTE（人工少數類過採樣法）透過插值生成合成樣本（Chen, 2026），或使用 ADASYN（自適應合成抽樣法）將學習重心放在難度較高的邊界樣本上（Alanazi and Suleiman, 2025）。

系統性元分析指出，單純的「準確率」在處理不平衡資料時具有誤導性，應改採 Macro F1-score、G-mean 或敏感度 (Sensitivity) 作為核心效能指標 (Kotsyubynska et al., 2026)。實證研究顯示，結合重採樣技術與類別權重調整的方法效果最為顯著，能將致命事故的偵測靈敏度從 42.1% 提升至 73.6% (Kotsyubynska et al., 2026)。此外，透過 SHAP 特徵解釋工具可以觀察到，在經過資料平衡處理後，模型對「傷亡人數」、「照明狀況」與「路面狀況」等核心風險因子的感應度會顯著提升，進而產出更具備工程防禦價值的決策建議 (Chen, 2026)。

三、研究方法

3.1 資料探討

本章旨在說明本研究之分析流程與方法論架構，包含原始資料之分類挑戰、自動化文字探勘技術之應用，以及後續機器學習分類模型之建構邏輯，作為本研究實證分析之基礎。

3.1.1 原始事故資料之分類困境

在分析交通事故時，交通部原始資料庫中的初步研判原因高達七十九種，而且均為第一線執法人員人工輸入的文字敘述。這些非結構化的文本資料不僅混亂，而且因為每個人的輸入習慣不同，經常夾雜著不同的標點符號、錯別字，或是省略了相關的說明文字。如果直接進行統計分析，難以直接進行量化分析，若用人工一筆一筆分類則需耗費大量時間成本，而且容易有主觀判斷上的偏差。因此，如何將這七十九種複雜的原因客觀地歸類為駕駛內在因素與外部環境因素，是本研究的首要挑戰。

3.1.2 文字探勘與資料前處理技術

為了克服這個困境，本研究採用人工智慧文本分析技術來進行初步研判與自動化分類。本研究於資料前處理階段，透過大型語言模型建立一 Python 自動化分類函式。這個方法可以很有效率的將上萬筆資料快速的歸類到內部因素和外部因素之範疇。即使原始紀錄中因為每個人的輸入習慣不同而產生標點符號的差異，我們還是能透過關鍵詞歸納正確的因果歸類，成功將非結構化文字資料變成可以進行分析的結構化資料。

【檢查：駕駛本身內在因素】的實際原始資料（隨機抽 10 筆）： 1. 開啟或關閉車門不當 2. 未保持行車安全距離 3. 未保持行車安全距離 4. 變換車道不當 5. 未依規定減速 6. 打瞌睡或疲勞駕駛(包括連續駕車8小時) 7. 未保持行車安全距離 8. 未保持行車安全距離 9. 未保持行車安全距離 10. 車輛或機械操作不當(慎)
【檢查：外部環境與硬體因素】的實際原始資料（隨機抽 10 筆）： 1. 物品(件)滾(滑)行或飛(掉)落 2. 被車輛輾壓之不明物體彈飛 3. 物品(件)滾(滑)行或飛(掉)落 4. 物品(件)滾(滑)行或飛(掉)落 5. 因光線、視線遮蔽致生事故 6. 因光線、視線遮蔽致生事故 7. 車輛零件脫落 8. 車輪脫落或輪胎爆裂 9. 被車輛輾壓之不明物體彈飛 10. 車輛零件脫落

圖 1 抽樣驗證圖

3.2 資料建模

3.2.1 原始資料清洗與過濾

在正式進行模型訓練之前，原始交通事故資料集必須經過嚴謹的預處理與資料清洗。本研究之核心目標在於建構一個能精準辨識人為疏失或外部客觀因素的二元因果歸類模型。然而，在原始資料集的「34.初步分析研判子類別-主要」欄位中，存在因資訊缺失而無法提供明確因果線索的文本描述。

此類描述主要包含以下三種標籤：第一、因事故現場跡證不足或當事人說詞衝突而標註之「無法釐清原因」；第二、因肇事逃逸或現場遭到破壞而標註之「尚未查獲」；第三、其餘無實質分析價值的無效文字紀錄。

因此，本研究在特徵轉換前，優先執行了資料過濾，將上述所有無法釐清原因、尚未查獲及無效標籤之樣本進行完整剔除。經過清洗後，資料集僅保留因果關係明確之駕駛本身內在因素，以及外部環境與硬體因素兩大核心類別，總計篩選出 24,344 筆乾淨樣本，並以此作為後續語意向量化與模型訓練的資料。

3.2.2 基於大型語言模型之自動化因果標註與蒸餾機制

由於交通事故原因文字屬於非結構化資料，且原始分類項目種類繁多，若完全仰賴人工逐筆判讀，將耗費大量時間與人力成本，此外本研究受限於資料來源並未提供經交通安全專家重新判讀之二元成因標籤，因此未能取得嚴格意義下之 ground truth。為利後續統計分析，本研究採用大型語言模型輔助歸納事故原因文字之分類邏輯，並依據該邏輯建立規則式分類函式，將事故原因初步區分為駕駛人內在因素與外部環境與硬體因素兩類。

惟本研究所產生之分類標籤屬於規則式弱標籤，其目的在於建立一致化之資料整理基準，並非代表經專家審查確認之真實事故成因標籤，因此，後續隨機森林模型之訓練與測試，主要用於檢驗語意向量特徵是否能有效重現此一規則化分類結果，屬於分類流程自動化與一致性驗證，而非直接證明模型已掌握事故成因之真實邊界。

綜上，本研究依據事故原因文字內容建立兩類標註原則：第一類為駕駛人內在因素(標籤 1)，包括超速、未注意車前狀況、不依規定讓車、酒後駕車、未保持安全距離等與駕駛操作、注意力、判斷或違規行為有關之因素；第二類(標籤 0)為外部環境與硬體因素，包括輪胎爆裂、車輛零件脫落、路面缺陷、掉落物、天候或視線遮蔽等較非駕駛人即時可控制之因素。透過上述分類流程，本研究將原始事故原因文字轉換為可供後續統計分析之二元分類資料。

本研究後續隨機森林模型之特徵(X 變數)係由同一段事故原因文字轉換而成之語意向量。此設定實質上為規則標註之自動化重現實驗，旨在驗證隨機森林能否重現由大型語言模型所建立之分類邏輯，作為未來批次處理巨量交通文字資料時，能夠替代大型語言模型且具效益與速度之方案。

```
df.columns = df.columns.str.strip()
df = df.dropna(subset=['34.初步分析研判子類別-主要'])

# 2. 修正後的超級精準分類函數
def perfect_classify(text):
    text = str(text)

    # 【第一階段：先判定外因】(必須是純環境或硬體故障，排除人為分心)
    external_keywords = [
        '光線', '視線遮蔽', '車輪脫落', '輪胎爆裂', '爆裂',
        '零件脫落', '不明物體彈飛', '滑行或飛落'
    ]
    # 這裡很關鍵：如果是「物品掉落」算外因，但「拿物品分心」算內因
    if any(word in text for word in external_keywords) or ('物品' in text and '分心' not in text and '拿' not in text):
        return '外部環境與硬體因素'

    # 【第二階段：判定無法釐清/資訊缺失】
    unknown_keywords = ['無法釐清', '跡證不足', '尚未發現', '肇事逃逸', '未查獲', '無法查明']
    if any(word in text for word in unknown_keywords):
        return '無法釐清/資訊缺失'

    # 【第三階段：其餘百分之百都是人為內因】(包含操作不當、飲食分心、未保持距離等)
    return '駕駛本身內在因素'

# 3. 重新執行分類
df['因果歸類'] = df['34.初步分析研判子類別-主要'].apply(perfect_classify)
```

圖 2 Python 自動化篩選函數

3.2.3 特徵工程與語意向量化

在傳統的自然語言處理任務中，文字通常透過詞頻矩陣或反文件頻率向量化工具進行轉換。然而，此類方法僅能捕捉字面上的精確匹配，一旦測試樣本中出現訓練集未曾包含的生字或口語化變形，模型便會因缺乏特徵而失去判斷能力。

為了提升模型對自然語言的泛化能力與理解深度，本研究改採預訓練之多語言雙向編碼器表徵模型 (Sentence Transformer)。該模型將原始 X 變數「34.初步分析研判子類別-主要」的車禍主因文字描述，映射至一個高維度的連續數學空間中，生成 384 個維度的語意向量。在此空間中，字面完全不同但語意相近的語句，例如柏油路面凹陷與路基掏空，將會被賦予極為接近的空間坐標。這使得後續的機器學習演算法能夠基於核心語意進行邏輯推理，而非死記字面單字。

需注意的是，Sentence Transformer 於本研究中僅作為文字向量化工具，其功能在於將事故原因文字轉換為可供機器學習模型處理之數值特徵。本研究未進行 BERT、Bi-LSTM 或其他端對端深度學習模型之比較實驗，因此不對不同預訓練語言模型或深度學習架構之優劣作推論。後續若能取得專家標註之標準資料集，可進一步比較 TF-IDF、Sentence Transformer、BERT fine-tuning、BERT-BiLSTM 等方法於事故成因分類任務上之表現差異。

3.2.4 隨機森林分類模型建立

本研究選用隨機森林作為核心分類器。該演算法透過建立多棵獨立的決策樹，並藉由多數決投票機制輸出最終的預測結果，具備極佳的抗過擬合能力與高維度特徵處理效率。

在資料集結構方面，本研究之車禍事故因果標籤存在顯著的不平衡現象。其中，駕駛本身內在因素佔據絕大多數（22,228 筆），而外部環境與硬體因素則屬於極少數派（2,116 筆）。若在未經調整的模型下進行訓練，隨機森林會受到龐大的人數優勢引導，將分類邊界嚴重偏向多數派，導致少數派樣本在預測時遭到忽視。

為了在不破壞原始數據空間的前提下解決不平衡問題，本研究引入了平衡子樣本權重機制（balanced_subsample）。不同於 SMOTE 或 ADASYN 會在少數派插值生成資料，製造不必要的雜訊，balanced_subsample 機制在隨機森林建立每棵決策樹與每次隨機抽樣時，皆會根據當前樣本的類別比例動態平衡抽樣（欠採樣）。此舉能夠降低模型偏向多數類別之情形，使模型必須敏銳捕捉邊界上屬於少數派的環境與硬體特徵。經數據切分驗證，將 80% 的資料用於模型訓練，其餘 20% 作為獨立測試集。

此舉旨在不改變原始數據分佈語意的前提下，透過決策樹訓練過程中的動態權重調整，更精準地捕捉少數派（環境因素）之特徵，以兼顧模型的效率與語意真實性。

3.2.5 基於加權 F2 分數之門檻優化策略

隨機森林分類器預設以 50% 的機率作為判定類別的切換點。然而，在母體極度不平衡的情境下，即使模型內部經過權重調整，少數派樣本在決策邊界上所計算出的絕對預測機率，在實務上依然難以突破半數。若直接沿用預設門檻，將導致環境與硬體特徵等少數派樣本在多數決投票機制下被完全淹沒，進而使環境因素的召回率歸零。

在交通安全管理的實務運作中，這類統計偏誤將帶來嚴重的社會成本。倘若系統遺漏判別外部環境與硬體因素，將會使相關工程與道路維護單位因缺乏預警而忽略潛在的環境缺陷，未能及時修補路面、改善照明或維護故障機械，進而引發後續更多重複性的交通事故。因此，基於防範二次事故的工程防禦立場，系統判定門檻必須跳脫傳統對稱分類的限制，盡可能地向下逼近至理想的靈敏值，以極小化漏判風險為首要目標。

本研究透過繪製精準度-召回率與決策門檻關係圖（Precision-Recall vs. Threshold Plot），動態觀察隨機森林模型在不同分類臨界點下的指標位移。圖中綠色實線代表外部環境因素的召回率（Recall），藍色虛線則代表精準度（Precision）。由走勢可明顯觀察出，當門檻設定極低時，召回率能穩定維持在 100% 的完美水平，而精準度則在跨越特定微小門檻後迅速攀升並趨於平穩。

為了修正統計學上的偏誤，本研究建構一套基於 F1 分數基準之加權 F2 分數門檻優化模型，並分為雙階段進行臨界點調校。

第一階段為測試集門檻評估。演算法首先在包含 4869 筆標準化文本的獨立測試集上進行全域掃描，以 F1 分數最大化作為數學依據，在理論上初步選取 3.0% 作為分類門檻。在此臨界點下，測試集能達到 99.5% 的精準度與 100.0% 的召回率。

第二階段為外部驗證與門檻微調。由於理論最佳解往往建構於高度標準化的官方文本環境，為了評估系統面對非結構化口語描述時的泛化防禦能力，本研究以 3.0% (F1 分數最大化之選取結果) 為中心建立安全掃描區間，掃描範圍涵蓋 0.5% 至 13.0%，並引入 17 筆日常口語之外部壓力測試數據。

決策模型在此階段將原始測試集與外部測試集依權重進行加權評估，將原始測試集給予權重 0.8，外部壓力集給予權重 0.2，並進行加權融合。考量到交通安全系統對於防範遺漏的實務需求，效用指標改採加重召回率權重的 F2 分數演算法。

經評估不同分類門檻之模型效能後，系統最終選定 4.0% 為最適分類門檻，較理論基準值微幅修正 1.0%。此門檻表示，在隨機森林的一百棵決策樹中，只要有四棵以上的決策樹認為該語意具備環境特徵，系統即判定為外部環境與硬體因素，判定為外部環境與硬體因素。




圖 3 精準度－召回率與決策門檻關係圖

3.2.6 測試集實測評估報告

本研究將最終推導出之 4.0%最佳分類門檻，分別套用至包含 4869 筆未知樣本的內部獨立測試集，以及包含 17 筆口語化樣本的外部極端干擾數據中進行多情境壓力實測。

關於內部測試集之分類效能實測，實測結果呈現出呈現良好的分類表現。在 4.0% 最適門檻的限制下，原本分類難度極高的 423 筆真正外部環境案件全數被模型成功偵測，環境召回率達到 100.00%。同時，4446 筆真正的駕駛內在因素案件亦達到 100.00% 的正確判定，未產生任何誤判與遺漏判別，總體測試集準確量高達 100.00%。這成功驗證了 4.0%門檻在處理高密度官方標準化文本時，具備極佳的分類精準度。

表 1 內部獨立測試集之模型分類效能實測表

	評估類別	精確度 (Precision)	召回率 (Recall)	F1 - Score	原本總 件數	模型預測 正確(件)	模型判斷 錯誤(件)
0	外部環境與 硬體因素(0)	100.00%	100.00%	100.00%	423	423 件	0 件(漏報)
1	駕駛本身內 在因素(1)	100.00%	100.00%	100.00%	4446	4446	0 件(誤判)

四、實證結果分析

4.1 圖表數據分析

本章主要透過圖表與統計分析，比較有無接觸酒精事故案件之事故成因差異，並探討酒駕事故中常見的肇事行為。同時利用統計檢定與分類模型驗證分析結果，以了解酒精因素對交通事故成因之影響。

4.1.1 有無接觸酒精之圓餅圖對比

透過前一章的資料前處理，我們將資料區分為無接觸酒精組與有接觸酒精組，並呈現有無接觸酒精的圓餅圖對比。觀察圓餅圖中之藍色的部分，可知無接觸酒精之樣本，因為駕駛人本身的內在因素而發生的車禍比例，約佔 91.28%，表示在正常清醒的情況下，外部環境仍具備約 8.72%之影響力。然而，針對有接觸酒精之個案，因駕駛本身內在因素而造成之事故比例直接提高至 97%。這項對比數據代表，一旦駕駛接觸酒精，肇事成因就會高度集中在駕駛人自身的行為上，而外部環境的影響力幾乎降到可以忽略不計，酒精的介入徹底改變了車禍成因的比例分布。




圖 4 無接觸酒精組




圖 5 有接觸酒精組

4.1.2 非內在因素之事故剖析

本節進一步針對有接觸酒精組中，那佔了約 3%的非內在因素進行事故剖析。在駕駛人保持清醒的正常狀態下，車禍並不完全是由人的問題所引起，那些外部環境與硬體問題仍保有客觀的影響力。這些非內在因素具體包含了車輛零件突然脫落、行駛中車輪脫落或輪胎爆裂、路面有物品掉落飛散，或者是因為光線太刺眼或視線被遮蔽導致看不清楚而發生事故。數據顯示，在沒有酒精干擾時，這些非駕駛人所能控制的物理與環境干擾，是交通事故中無法被忽略的重要成因。

4.1.3 關鍵肇事行為分析

與前一節的環境干擾不同，當我們深入分析有接觸酒精組中那高達 97%的內在因素時，可以發現出事原因主要集中於駕駛人的行為失誤。酒精會嚴重干擾駕駛人的距離感與反應力，進而引發致命的關鍵肇事行為。在這些行為當中，最主要且發生頻率最高的關鍵肇事行為，就是未保持行車安全距離以及酒醉駕駛。這代表酒精的介入，會讓駕駛人失去應有的應變與決策能力，使得車禍的本質完全轉變成駕駛人接觸酒精之後，完全需要自主負責的嚴重違規行為。




圖 6 有接觸酒精組之內在因素事故分析

4.2 有接觸酒精組與無接觸酒精組事故成因分布之統計檢定

為了驗證有接觸酒精組與無接觸酒精組在事故成因分布上是否存在統計差異，本研究依據飲酒狀態（有接觸酒精組、無接觸酒精組）及事故成因分類（內在因素、外在因素）建立二維列聯表，作為後續統計檢定之依據。

表 2 有接觸酒精組與無接觸酒精組事故成因分布列聯表

飲酒狀態	外在因素	內在因素	合計
有接觸酒精組	3	97	100
無接觸酒精組	2,113	22,131	24,244
合計	2,116	22,228	24,344

為檢驗有接觸酒精組與無接觸酒精組在事故成因分布上是否具有統計顯著差異，本研究首先採用卡方檢定（Chi-square Test）進行分析。

表 3 卡方檢定結果

項目	數值
檢定方法	Chi-square Test
卡方統計量(χ^2)	3.4107
自由度(df)	1
p 值	0.0648
檢定結果	未達顯著($p>0.05$)

卡方檢定結果顯示， $\chi^2=3.4107$ ，p 值為 0.0648，大於顯著水準 $\alpha=0.05$ ，因此未能拒絕虛無假設，表示依據卡方檢定結果，尚無足夠證據顯示有接觸酒精組與無接觸酒精組在事故成因比例分布上具有顯著差異。

然而，由於本研究有接觸酒精組樣本數相對較少，且列聯表中存在低次數儲存格，在此情況下卡方檢定結果可能受到小樣本影響而降低統計推論之可靠性。因此，本研究進一步採用較適用於小樣本二維列聯表之 Fisher's Exact Test（費雪精確檢定）進行分析，以驗證上述結果。

表 4 費雪精確檢定結果

項目	數值
檢定方法	Fisher's Exact Test
Odds Ratio	0.3239
p 值	0.0475
檢定結果	達顯著($p<0.05$)

費雪精確檢定結果顯示，p 值為 0.0475，小於顯著水準 $\alpha=0.05$ ，因此拒絕虛無假設，表示有接觸酒精組與無接觸酒精組在事故成因比例分布上具有顯著差異。由表 2 可知，有接觸酒精組事故屬於駕駛人內在因素之比例為 97.00%，高於無接觸酒精組之 91.28%，顯示有接觸酒精組之事故成因較集中於駕駛人本身的內在因素。

綜合上述分析結果，考量卡方檢定於小樣本情況下可能影響統計推論之可靠性，本研究以費雪精確檢定作為最終統計推論依據。檢定結果顯示，有接觸酒精組與無接觸酒精組之事故成因分布具有顯著差異，其中有接觸酒精組之事故較傾向集中於駕駛人本身之內在因素，此結果亦與前述事故成因分析一致。

本研究中有接觸酒精組之樣本量僅 100 筆(表 2)，雖經統計檢定達顯著水準，但未來研究可進一步擴大樣本規模以增進統計推論之穩健性，使研究結果更具代表性。

五、結論與建議

5.1 結論

從分析結果可以發現，沒有接觸酒精的事故案件中，約有 91.28% 的事故原因屬於駕駛人本身的內在因素，而有接觸酒精的事故案件中，比例則提高至 97%。這代表當駕駛人接觸酒精後，事故原因會更加集中在駕駛人自身的行為問題上，外部環境或車輛因素所造成的影響相對降低，也顯示酒精確實會對駕駛人的判斷能力與反應能力造成明顯影響。

進一步分析酒駕事故中的肇事原因後發現，未保持行車安全距離以及酒醉駕駛是最常出現的事故原因。由此可見，酒精不僅會影響駕駛人的注意力與反應速度，也容易讓駕駛人在行車過程中做出錯誤判斷，進而提高事故發生的風險。

在統計推論方面，本研究利用費雪精確檢定驗證兩組事故成因的差異，結果顯示 p 值為 0.0475，低於 0.05 的顯著水準，表示酒精介入確實改變了交通事故的成因結構。這項結果也進一步支持本研究的分析發現。

此外，本研究利用文字探勘技術、語意向量化以及隨機森林模型建立事故原因分類機制，並成功完成事故原因的自動化分類。本研究透過文字規則化標註、語意向量化與隨機森林模型，初步建立事故原因文字之輔助分類流程。惟本研究標籤來源為規則式弱標籤，而非專家標註之真實標籤，故模型評估結果應解讀為對既有分類規則之再現能力，而非事故成因真實分類能力之最終驗證。經研究後發現，透過自然語言處理技術協助整理大量事故原因文字，具有降低資料前處理成本與提升分類一致性之應用潛力。未來若能結合專家標註資料進行外部驗證，將可進一步提升模型結果之可信度與政策應用價值。

綜合以上結果可以發現，酒精駕駛會明顯提高事故原因集中於駕駛人本身因素的比例，並增加危險駕駛行為發生的可能性。因此，相關單位除了持續加強酒駕取締與宣導外，也應透過交通安全教育提升駕駛人對酒駕風險的認知，使民眾了解酒精對反應能力、判斷能力及駕駛行為所造成的負面影響。透過強化預防觀念與建立酒後不開車的正確認知，從源頭降低酒後駕車行為的發生，進一步減少交通事故與傷亡事件，提升整體道路交通安全。

5.2 研究限制

本研究仍有若干限制如下：

- 1.本研究使用之內在因素與外在因素標籤係依據大型語言模型輔助建立之規則式分類邏輯產生，並非由多位交通安全、事故鑑定或執法專家逐筆標註後形成之 ground truth。因此，本文後續模型評估結果應解讀為對規則標註結果之再現能力，而非對真實事故成因分類能力之直接證明。
- 2.隨機森林模型所使用之訓練與測試標籤皆來自同一套規則式標註流程，因此模型可能主要學習該規則所形成之分類邊界。即使內部測試結果呈現高度一致，也不宜直接推論模型已具備一般化事故成因判斷能力。未來研究應納入專家人工標註樣本，並進行多標註者一致性檢驗，例如 Cohen's Kappa 或 Fleiss' Kappa，以建立更可靠之驗證基準。
- 3.本研究之有接觸酒精樣本數相對較少，僅有 100 筆，雖費雪精確檢定結果達顯著水準，但統計推論仍可能受到小樣本影響。因此，本研究結論應限縮為特定資料來源與研究期間下之初步發現，未來仍需擴大樣本範圍、納入不同地區與不同道路類型資料，以提升結果之穩健性與應用性。

參考資料

- Alanazi, F. and Suleiman, A. (2025), "Impact of Data Balancing and Feature Engineering on Accident Severity Models," *Promet – Traffic & Transportation*, Vol. 37, No. 3, pp. 665-690.
- Bhagat, S., Shihab, I. F., and Sharma, A. (arXiv), "Accuracy is Not Agreement: Expert-Aligned Evaluation of Crash Narrative Classification Models," arXiv preprint.
- Chen, Y. (2026), "Research and Analysis of Traffic Accident Severity Prediction Based on Data Augmentation and Feature Interpretation," *Proceedings of the International Workshop on Advances in Deep Learning for Image Analysis and Computer Vision (IWADIC 2025)*, pp. 686-692.
- Jaradat, S., Elhenawy, M., Paz, A., Alhadidi, T. I., Ashqar, H. I., and Nayak, R. (2025), "A Cross-Cultural Crash Pattern Analysis in the United States and Jordan Using BERT and SHAP," *Electronics*, Vol. 14, No. 2, 272.
- Kirley, B. B., Robison, K. L., Goodwin, A. H., Harmon, K. J., O'Brien, N. P., West, A., Harrell, S. S., Thomas, L., and Brookshire, K. (2023), *Countermeasures That Work: A Highway Safety Countermeasure Guide for State Highway Safety Offices*, 11th edition, Report No. DOT HS 813 490, National Highway Traffic Safety Administration.
- Kotsyubynska, Y., Kozan, N., Chadiuk, V., Kostyshyn, A., Kotsyubynsky, A., and Fentsyk, V. (2026), "Machine Learning and Deep Learning for Predicting Traffic Crash Injury Severity: A Systematic Review and Meta-Analysis (2014-2025)," *Journal of Road Safety*, Vol. 37, No. 1.
- National Center for Statistics and Analysis (2023), *Alcohol-Impaired Driving: 2021 Data, Traffic Safety Facts*, Report No. DOT HS 813 450, National Highway Traffic Safety Administration.

- National Center for Statistics and Analysis (2026), Alcohol-Impaired Driving: 2024 Data, Traffic Safety Facts, Report No. DOT HS 813 815, National Highway Traffic Safety Administration.
- Sayed, M. A. (2022), Use of Machine Learning and Natural Language Processing to Enhance Traffic Safety Analysis, Doctoral Dissertation, University of Wisconsin-Milwaukee.