

國立臺灣大學管理學院國際企業學系暨研究所

碩士論文

Department of International Business

College of Management

National Taiwan University

Master's Thesis

CEO 大學時期受災經驗對新上任公司的非系統性風

險指標影響

The Impact of CEOs' University-Era Disaster Experience
on the Idiosyncratic Risk of Their New Employers

林雁婷

Yen-Ting Lin

指導教授：林修葳 博士

Advisor: Hsiou-Wei Lin, Ph.D.

中華民國 115 年 6 月

June, 2026



謝辭

撰寫論文的過去一年不知不覺成為了我人生中最重要養分，十分感謝林修葳教授從一開始的題目發想、模型設定以及資料處理方面皆教導了我許多。回首過去的種種時光，不論是在家中、圖書館或芬蘭的宿舍裡，都有著由論文編織起的記憶流淌著，且教授總是會配合我的時差和我討論，真的非常感謝。除此之外也感謝口試委員羅秉政教授及李柏樂教授給予許多建議，讓本篇論文更趨完整。

林雁婷

2026/06/25

摘要



本研究檢視 CEO 大學受災經驗與其新接任公司的非系統性風險指標之間的關聯，以 CEO 大學就讀時期之所在區域之受災資料作為主要解釋變數，首度建立災害衝擊程度指標，可供後續相關研究為實證變數，並灌輸指令集予 AI 工具、就災害嚴重度作評分與分組，探討高等教育階段的經歷如何對個體的風險態度與決策行為產生長期影響。樣本資料涵括北美企業之財務與股市非系統性風險衡量變數。實證結果顯示：(1) 具大學受災經驗之 CEO，上任後公司股價非系統性風險顯著降低；(2) 相比中度受災者，高度受災 CEO 上任後公司的利息保障倍數顯著較高；(3) 若 CEO 兼任董事，高度受災者較低度受災者上任後之公司最大商譽顯著較低。本研究結果提供關於 CEO 大學成長背景與公司風險指標間關聯的實證證據--有大學受災經驗之 CEO 會採取較趨避非系統性風險的決策模式。

關鍵字：CEO 大學受災經驗、CEO 經驗、非系統性風險、公司風險指標


Abstract



This paper examines the relationship between a CEO's experience in encountering natural disaster during the university-era and the changes in idiosyncratic risk measures of their new employers subsequent to his/her taking the office. Adopting disaster data from the regions where the CEOs received undergraduate education as the explanatory variable, this study, for the first time, establishing a disaster impact index that can serve as an empirical variable in subsequent related research. Furthermore, by feeding prompt sets to AI tools for severity scoring and categorization, this study investigates how exposure during the higher education stage has a long-term impact on an individual's risk attitudes and decision-making behaviors. The sample comprises North American companies with the data available for estimating corporate financial and stock market idiosyncratic risk measures to investigate whether the severity of disaster experience during a CEO's university years influences subsequent corporate risk-taking decisions. The empirical results show that: (1) CEOs with university-era disaster experience significantly reduce the idiosyncratic risk of firm stock returns after taking office; (2) compared to those with moderate exposure, CEOs with high-severity exposure demonstrate a significantly higher interest coverage ratio after taking office; (3) when the CEO also serves as a director, those with high-severity exposure exhibit significantly lower maximum goodwill compared to those with low-severity exposure. These findings provide empirical evidence linking whether a CEO had encountered disasters to corporate idiosyncratic risk appetites, supporting the notion that university-era disaster exposures lead to more risk-averse decision-making patterns.

Keywords: CEO university-era disaster experience, CEO experience, Idiosyncratic risk, Corporate risk indicators

目次



謝辭.....	i
摘要.....	ii
Abstract.....	iii
目次.....	iv
圖次.....	v
表次.....	vi
第一章 緒論.....	1
第二章 假說建立.....	4
第三章 研究設計.....	6
第一節 模型發展.....	6
第二節 樣本選取.....	8
第三節 研究模型與變數.....	10
第四節 AI 輔助產生的執行長大學受災程度研究變數	12
第四章 實證結果.....	15
第一節 敘述性統計.....	15
第二節 相關性係數.....	27
第三節 迴歸分析結果.....	31
第四節 額外分析.....	42
第五節 穩健性分析.....	48
第五章 結論.....	57
參考文獻.....	59
附錄一、AI 模型評分原始設定詞與 25 則報導清單	62
附錄二、AI 災害評分訓練三大類用詞	64
附錄三、AI 災害因子權重生成比較	66

圖次

圖 1、AI 訓練災害評分流程圖	13
------------------------	----



表次

表 1、敘述型統計	16
表 2、極端受災 CEO 名單	21
表 3、相關係數表	28
表 4、迴歸結果分析	33
表 5、顯著迴歸結果統整	41
表 6、額外分析結果	43
表 7、穩健性分析結果	49



第一章 緒論



本研究檢測 CEO 讀大學時期學校所在及鄰近區域遭受災害的程度 (1)與其新上任後公司之股市報酬的非系統性風險變動間關聯，(2)與其新上任後公司之財務槓桿變動間關聯，(3)與其新上任後公司之持有現金比例變動間關聯。相關研究顯示 CEO 的教育背景、成長經歷或性格皆會影響企業決策，本研究以真實決策情境檢視 CEO 高等教育階段的經歷是否會對風險態度及決策產生長期影響。其中，在個人成長時期所處環境受災會在其心理認知中佔有顯著地位。身體受傷或財物損失之經驗或顧慮會提高個體風險感知 (Risk Perception)，而情感經驗則需要透過持續產生的憂慮情緒而讓人覺得風險高 (Bronfman et al., 2020)。在投資行為方面，根據本研究建立之受災衝擊度指標，發現大學時期有受災經驗或受災經驗較為嚴重的 CEO 更為風險趨避。

家庭遭受的總災害次數愈多，會降低對未來股市報酬的預期，避開高風險資產市場，即使家庭搬遷至災害較少發生的地區，此種保守的投資態度仍然不會改變 (Bharath and Cho, 2023)。亦有相關研究顯示早期災害經歷會影響 CEO 決策管理與風格。CEO 的早期或童年的創傷災害經歷，不僅對企業社會責任 (Corporate Social Responsibility, CSR) 行為有正向的影響，也會和企業社會績效 (Corporate Social Performance, CSP) 呈正相關；相反地，CEO 會減少企業不負社會責任 (Corporate Social Irresponsibility, CsiR) 行為，更容易產生利社會價值觀 (Prosocial Values) 行為 (Choi, Shin, and Kim, 2023；O'Sullivan, Zolotoy, and Fan, 2021)。

執行長在童年時期的受災經驗會影響其成年後的風險承擔傾向 (Risk-Taking Propensity)。然而，有早期災害經驗的 CEO 不一定皆會產生風險趨避 (Risk Aversion) 的行為模式，有可能更為風險愛好 (Risk Loving)。早期經歷過災害事件的 CEO 或許風險容忍度 (Risk Tolerance) 更高，更願意承擔隱瞞壞消息

的風險，從而導致股價崩盤 (Stock Price Crash)，同時也有較高的現金流波動度 (Cash Flow Volatility) 和股票報酬波動度 (Stock Return Volatility) (Chen et al., 2021)。若兒時經歷致命卻未產生極端負面影響之災難的 CEO，會使用更激進的方式領導公司；若兒時目睹災難帶來的極端負面影響的 CEO，領導公司時會愈會趨於保守 (Bernile, Bhagwat, and Rau, 2017)。經歷中國大飢荒的高層管理人員更傾向於採取擔保債務結構 (Secured Debt Structure) 與有效的內部控制 (Effective Internal Control)，對於風險有更謹慎和趨避的態度，並減少高風險的欺詐行為 (Yao et al., 2020)。

雖童年經歷對 CEO 的人格養成有衝擊性，但大學時期的經歷也足以影響 CEO 對於風險承擔和創新的表現 (Chen et al., 2023)。本研究被解釋變數為非系統性風險因素，因為非系統性風險反映 CEO 之態度如何影響公司績效，而系統性風險的改變常是產品大方向調整，如高單價耐久商品變成低單價消耗商品，一是未必基於風險考量，二是 CEO 短期內難以顯著操控產品組合，三是系統性風險水準或與 CEO 風險態度無關，反而多源自於總體經濟效應與市場雜訊，故超出 CEO 的影響範疇 (Bushman, Dai, and Wang, 2010; Jenter and Kanaan, 2015)。CEO 的表現多使用相對績效評估 (Relative performance evaluation, RPE)，因其能過濾市場的總體環境波動，不會因系統性風險受責 (Angelis and Grinstein, 2020)，且新任 CEO 權力較小，會接受嚴格的非系統性風險考核，對他們的職位安全威脅較大 (Dikolli et al., 2018)。本研究延伸上段之三個研究，不同之處為 (1) 以 CEO 就讀大學時期該地區有無遭受災害作為研究之解釋變數，且目前尚無類似之研究。(2) 除透過資料上的死傷人數、財產損失、持續時間作為衡量災害嚴重度的依據外，亦加入 AI 評分系統，考量情緒性用詞、嚴重度用詞對於 CEO 所造成的成長陰影與個性養成，指示 AI 進行綜合嚴重度評分。(3) 應變數納入非系統性風險、公司財務結構和現金水準中，比對各指標受大學災害經歷的影響。

本研究以就讀在災害資料含括範圍內的美國大學及擁有在新任企業三年資

歷的 CEO 作為研究樣本，以該 CEO 大學時期學校所遭受到的災害嚴重程度作為主要解釋變數，以檢測 CEO 於大學時期暴露於不同程度的災害下是否影響公司於其新任後三年的風險決策。實證結果顯示：(1) 有受災經驗的 CEO 其新上任後公司三年之股價報酬的非系統性風險較低。(2) 高度受災經驗的 CEO 其新上任後公司三年之利息保障倍數較中度受災經驗的 CEO 其新上任後公司三年之利息保障倍數低。(3) 董事會成員的身分調節了 CEO 受災經驗與併購政策之間的關係，身兼董事且高度受災的 CEO 其新上任後公司三年之最大商譽低於低度受災的 CEO 其新上任後公司三年之最大商譽。

本研究其他章節依序為第二章假說建立；第三章研究設計包含模型發展、樣本選取、研究模型與變數及 AI 輔助產生的執行長大學受災程度研究變數；第四章實證結果包含敘述性統計、相關性係數、迴歸分析結果、額外分析及穩健性分析與第五章結論。

第二章 假說建立



一、北美執行長之大學受災程度與股價報酬的非系統性風險之關聯

系統性風險和市場整體變動相關，無法透過分散化消除，當投資人風險增加時，經理人風險也會增加；非系統性風險可被分散化消除，當投資人風險不變時，經理人風險會增加 (Sharpe, 1964; Amihud and Lev, 1981)。為精確捕捉 CEO 個體經驗對企業風險配置的即時影響，使用市場基礎的衡量指標能更有效地反映市場對經理人行為的評價，並避開會計平滑機制帶來的干擾 (Kothari, 2001)，本研究認為若執行長在大學時期遭受災害，可能會影響其新上任後公司的股價報酬的非系統性風險。綜上所述，本研究建立以下假說：

假說 1：執行長大學受災程度愈高，其新上任後三年間公司的股價報酬的非系統性風險較上任前三年間低。

二、北美執行長之大學受災程度與企業財務槓桿之關聯

企業可透過調整財務結構 (Financial Structure) 以減緩盈餘波動、提升財務績效。本研究觀察變數涵括會計的負債比率，復因利息保障倍數 (Interest Coverage Ratio) 被廣泛用作評估企業償債能力與潛在財務風險的指標，該比率反映企業以營運獲利 (EBIT) 支付利息費用的能力，其水準下降往往意味企業盈利能力不足、現金流壓力上升，進而增加財務困境或破產風險 (Kliestik et al., 2020)。本研究認為若執行長在大學時期遭受災害，有可能影響其企業財務結構指標。綜上所述，本研究建立以下假說：

假說 2a：執行長大學受災程度愈高，其新上任後公司的總負債比率三年間相較於上任前三年間會降低。

假說 2b：執行長大學受災程度愈高，其新上任後公司的籌資活動負債比率三年間相較於上任前三年間會降低。

假說 2c：執行長大學受災程度愈高，其新上任後公司的利息保障倍數比三年間相較於上任前三年間會提高。



三、北美執行長之大學受災程度與企業現金管理之關聯

CEO 的個人價值觀會影響其資源分配的方式 (Gupta, Briscoe, and Hambrick, 2018)。當企業面臨風險時，企業會重新考量其資本配置 (David, Schmid, and Zeke, 2022)。在面臨高度外部不確定性與潛在的現金流衝擊時，企業為提升財務應變彈性，會傾向採取較為保守且具備彈性的股利與支付政策，以保留內部資金並降低陷入財務困境的機率 (Adra et al., 2023; Arena and Julio, 2023)。當市場或政策的不確定性急遽升高時，企業為避免不可逆的決策錯誤，會選擇延遲或大幅削減資本支出，以此作為最重要的現金防禦機制 (Gulen and Ion, 2016)。資本支出在一般情況下能夠增加企業價值，然而當資本支出伴隨著避險策略時，則會降低企業價值 (Ullah et al., 2023)。CEO 的背景導致其特性更傾向為通才型 (Generalist) 或專才型 (Specialist)，亦會影響其對於併購的態度，相對保守或是大膽，並進而影響商譽的變動 (Chen et al., 2020)。綜上所述，本研究建立以下假說：

假說 3a：執行長大學受災程度愈高，其新上任後公司的（以期初股價）標準化後之股利變動三年間相較於上任前三年間會降低。

假說 3b：執行長大學受災程度愈高，其新上任後公司的資本支出占比三年間相較於上任前三年間會降低。

假說 3c：執行長大學受災程度愈高，其新上任後公司的三年間的最大商譽相較於上任前三年間會降低。

第三章 研究設計

第一節 模型發展



本研究採取分組測試和線性測試模型。分組測試仿照 Bernile, Bhagwat, and Rau (2017)方法，將災害分數分為低 (*Low*)、中 (*Mid*)、高 (*High*)三種，並且建立對應的虛擬變數。¹

本研究發展 7 個模型以檢測 7 個假說，其中模型 1 以股價報酬的非系統性風險作為應變數檢測假說 1；模型 2-1、模型 2-2 及模型 2-3 分別以總負債比率、籌資活動負債比率及利息保障倍數比作為應變數檢測假說 2a、假說 2b 及假說 2c；模型 3-1、模型 3-2 及模型 3-3 分別以期初股價標準化後之股利變動、資本支出及最大商譽為應變數檢測假說 3a、假說 3b 及假說 3c。各模型皆採虛擬變數迴歸方法，以得出各模型中之係數。以下為分組測試之模型：

模型 1、2-1、2-2、2-3、3-1、3-2 與 3-3:

$$CORPORATE_RISK_{i,t} = \sum_{s \in \{L,M,H\}} \beta_s D_{s,i} + \sum_{s \in \{L,M,H\}} \theta_s (D_{s,i} \times Z_{i,t}) + \Phi X_{i,t} + Year_{i,t} + Industry_{i,t} + \varepsilon_{i,t},$$

其中，就 i 企業第 t 年度， $CORPORATE_RISK_{i,t}$ 包含 $\Delta RETVOL_IDIO_{i,t}$ 、 $\Delta LEV_{i,t}$ 、 $\Delta DEBT_{i,t}$ 、 $\Delta ICR_{i,t}$ 、 $\Delta DIV_{i,t}$ 、 $\Delta CAPEX_{i,t}$ 和 $\Delta MAXGW_{i,t}$ 共七項，分別為模型 1、2-1、2-2、2-3、3-1、3-2 與 3-3 之應變數。 β_s 衡量被歸類在低、中和高三類不同受災經驗的 CEO，對於其新上任公司風險指標的效應。 θ_s 衡量不同的 CEO 分

1 根據 Bernile, Bhagwat, and Rau (2017)，重大災害指的是達到致死或經濟損失任一門檻。本研究使用本章第四節的 AI 輔助自變數為基礎，藉由 AI 建立輕、中、重每一等級的加權總分。輕度災害分數為 0 至 0.15，中度災害分數為 0.15 至 0.45，重度災害分數為 0.45 至 1，同樣為 AI 所計算與設計。

組主要解釋變數 $Z_{i,t}$ 影響公司風險指標的調節效果。

模型 1 檢測執行長大學受災程度是否對新上任後公司三年間 (t 至 $t+3$ ，以下定義同) 的股市報酬的非系統性風險 ($\Delta RETVOL_IDIO_{i,t}$) 相較於上任前三年間 ($t-3$ 至 t 年，以下定義同) 是否影響顯著；模型 2-1 檢測執行長大學受災程度是否對新上任後公司三年間的總負債比率 (ΔLEV_i) 相較於上任前三年間是否影響顯著；模型 2-2 檢測執行長大學受災程度是否對新上任公司三年間的籌資活動負債比率 ($\Delta DEBT_i$) 相較於上任前三年間是否影響顯著；模型 2-3 檢測執行長大學受災程度是否對新上任後公司三年間的利息保障倍數比 (ΔICR_i) 相較於上任前三年間是否影響顯著；模型 3-1 檢測執行長大學受災程度是否對新上任後公司三年間的以期初股價標準化後之股利變動 (ΔDIV_i) 相較於上任前三年間是否影響顯著；模型 3-2 檢測執行長大學受災程度是否對新上任後公司三年間的資本支出占比 ($\Delta CAPEX_i$) 相較於上任前三年間是否影響顯著；模型 3-3 檢測執行長大學受災程度是否對新上任後公司三年間的最大商譽 ($\Delta MAXGW_i$) 相較於上任前三年間是否影響顯著。

$D_{s,i}$ 為該執行長大學受災程度的分類，分為輕度 (*Low*)、中度 (*Mid*) 和重度 (*High*) 三種、 $Z_{i,t}$ 為與受災程度產生交互作用的控制變數，包括執行長學士學位種類 (BS 或 BA) 的虛擬變數 (*Degree*)、執行長年齡 (*Age*)、執行長性別的虛擬變數 (*Gender*)、執行長新任 i 公司三年間公司淨利為正或負的虛擬變數 (*niq_dummy*)、執行長新任 i 公司三年間是否兼任董事會成員的虛擬變數 (*brd_dummy*)、執行長新任 i 公司之日期距離取得學士學位後的年數，以十年為單位 (*years*)。而 $X_{i,t}$ 為其他未與受災程度產生交互作用的控制變數，包括執行長新任後 i 公司之期初公司資產規模取自然對數 (*SIZE*)、執行長新任後 i 公司三年前公司 ROE 平均 (*ROE_mean*)、執行長新上任 i 公司三年後與上任三年前公司 ROE 平均的差異 (ΔROE_mean) 執行長新任 i 公司三年前該公司所屬產業的 ROE 平均 (*ROE_ind_mean*)。此外，加入 $Year_{i,t}$ 和 $Industry_{i,t}$ 作為年

份固定效果和產業固定效果。 β_s 為不同受災程度的執行長在新任三年間和上任前三年間，該公司之會計系統性風險的變化。



本研究亦採多元線性迴歸方法，以得出各模型中之係數。以下為線性測試之模型：

模型 1、2-1、2-2、2-3、3-1、3-2 與 3-3:

$$\begin{aligned} CORPORATE_RISK_{i,t} = & \beta_0 + \sum_{s \in \{Local, Neighbor\}} \beta_{1s} Severity_{s,i}^{GPT/Gemini} + \\ & \sum_{s \in \{Local, Neighbor\}} \beta_{2s} Severity_{s,i}^{2GPT/Gemini} + \\ & \sum_{s \in \{Local, Neighbor\}} \theta_{1s} Severity_{s,i}^{GPT/Gemini} \times Z_{i,t} + \\ & \sum_{s \in \{Local, Neighbor\}} \theta_{2s} Severity_{s,i}^{2GPT/Gemini} \times Z_{i,t} + \Phi X_{i,t} + Year_{i,t} + Industry_{i,t} + \\ & \varepsilon_{i,t}, \end{aligned}$$

其中， $CORPORATE_RISK$ 包含 $\Delta RETVOL_IDIO_i$ 、 ΔLEV_i 、 $\Delta DEBT_i$ 、 ΔICR_i 、 ΔDIV_i 、 $\Delta CAPEX_i$ 和 $\Delta MAXGW_i$ 共七項，分別為模型 1、2-1、2-2、2-3、3-1、3-2 與 3-3 之應變數。各模型檢測目標皆和上述分組測試之目標相同。

$Severity_{s,i}^{GPT/Gemini}$ 為該執行長大學受災程度，其中又分為當地嚴重度與鄰近區域嚴重度。² β_0 為大學無受災經驗的執行長在新任三年間和上任前三年間，該公司之風險指標的變化。 β_{1s} 為大學有受災經驗的執行長在新任三年間和上任前三年間，該公司之風險指標變化的一階效應。 β_{2s} 則衡量二階效應，用以捕捉風險變化的非線性特徵。

第二節 樣本選取

本研究樣本分為三部分，執行長相關資料取自 BoardEX 資料庫，資料自

² 本章第三節與第四節將詳細說明該變數之計算方式與來源。

1920 年 1 月截至 2025 年 10 月，高層管理人員學士學歷資料共 2,017,039 筆，排除公司代碼缺失、取得日期缺失之資料後，剩餘有效資料筆數 334,619 筆；歷史及現職職位中包含 CEO 的資料共 8,309,958 筆，排除就任與卸任時間缺失、ISIN 缺失、任職低於三年之資料後，剩餘有效資料 25,009 筆。將處理過之 CEO 資料和學士學歷資料進行交叉比對後，剩餘有效資料筆數為 9,368 筆。再將 BoardEx 資料以模糊比對串連美國國家教育統計中心 (National Center for Education Statistics, NCES) 之各大學聯邦資訊處理標準代碼 (Federal Information Processing Standards, FIPS)，得到含 FIPS 之 CEO 學士學歷與職位資料 6,939 筆。³

企業財報資料取自 Compustat 資料庫，資料自 1961 年 3 月截至 2025 年 10 月，包含資產負債表及綜合損益表之季資料共 2,084,476 筆，排除所需變數缺失的資料後，剩餘 901,277 筆。將上述 BoardEx 資料和 Compustat 資料交叉比對，(1) 只留下 CEO 新任後的三年，剩餘有效資料 3,292 筆，(2) 只留下 CEO 上任前三年，剩餘有效資料 2,987。再將之與災害資料串連，剩餘有效季資料 2,177 筆。而當中以期初股價標準化後之股利變動⁴與最大商譽作為應變數時，

³ 本研究的模糊比對分為三階段。首先對大學名稱進行標準化處理：移除標點和噪音詞(包含 of、the、at、and、for、university、college、institute、state、national 和 central)。第一階段對標準化後的大學名稱進行精確比對。第二階段比對排序後的關鍵詞，以解決詞序差異(例如：University of Washington 和 Washington University 是兩個不同的大學)。第三階段針對未匹配樣本，採用 Jaro-Winkler Distance 進行 Guarded Fuzzy Matching：(1) 小於八個字的短字串要求極高的相似度，而大於十二個字的長字串則要求較小的相似度。(2) 兩個進行比對的名稱中至少要有一個關鍵單字完全相同。(3) 若兩個進行比對的學校名稱都有分校名，分校名必須完全相同。最後，手動剔除缺乏分校資訊的樣本以確保比對正確無誤。

⁴ 計算過程分為兩階段：首先，計算每一季度以期初股價標準化後之股利變動，公式為 (本期股利-前一期股利)/期初股價，用以衡量每 1 單位期初股價所產生之股利增減比例，以消除企業規模效應確保跨公司之可比性。接著，分別取新任 CEO 上任後三年與上任前三年之季平均值，並將兩者相減。第三節研究模型與變數詳列計算公式。

則因篩選較嚴謹，剩餘資料筆數 1,675 筆。⁵

企業股票市場資料取自 CRSP 資料庫，資料自 1925 年 12 月截至 2025 年 10 月，包含報酬率之月資料共 4,831,896 筆，排除所需變數缺失的資料後，剩餘月資料 4,640,560 筆。將上述 BoardEx 資料和 CRSP 資料交叉比對後，(1) 只留下 CEO 新任後的三年，剩餘有效資料 3,004 筆，(2) 只留下 CEO 上任前三年，剩餘有效資料 2,676 筆。再將之與災害資料串連，剩餘有效月資料 1,275 筆。

上述提到的災害資料取自 SHELDUS 資料庫，記錄各種形式的氣象、地理及環境災害，包含這些災害所導致的傷亡人數、財產損失金額、持續時間，共 784,025 筆，用來串聯企業財報資料和股市資料。

第三節 研究模型與變數

針對假說 1，本研究以新任三年間和上任前三年間的股市報酬非系統性風險的差作為應變數，如式 (1)。

$$\Delta RETVOL_IDIO_i = \left[Var\left(RET_i^{(t,t+3)}\right) - RETVOL_SYS_i^{(t,t+3)} \right] - \left[Var\left(RET_i^{(t-3,t)}\right) - RETVOL_SYS_i^{(t-3,t)} \right], \quad (1)$$

式 (1) 中，股市報酬率使用月報酬率。

針對假說 2a、2b、2c、3a、3b 和 3c，本研究以新任後三年間和上任前三年間總負債比率的差、籌資活動負債比率的差、利息保障倍數比的差、以期初股價

⁵ 在本研究中，由於計算以期初股價標準化後之股利變動需具備連續六年的股價觀測值，其篩選標準較為嚴謹，故該變數所涉之迴歸模型樣本數相對較小，此舉旨在確保指標計算之準確性，同時避免對其他無此限制之檢定造成不必要的樣本犧牲。而若該季缺少股利和商譽的資料，則補 0 以避免更多的樣本缺失。

標準化後之股利變動、資本支出占比的差和最大商譽的差作為應變數，如式 (2) 至式 (7)。

$$\Delta LEV_i = \text{mean} \left(\frac{TL_i}{TA_i} \right)^{(t,t+3)} - \text{mean} \left(\frac{TL_i}{TA_i} \right)^{(t-3,t)}, \quad (2)$$

$$\Delta DEBT_i = \text{mean} \left(\frac{NCL_i + STD_i}{TA_i} \right)^{(t,t+3)} - \text{mean} \left(\frac{NCL_i + STD_i}{TA_i} \right)^{(t-3,t)}, \quad (3)$$

$$\Delta ICR_i = \text{mean} \left(\frac{\text{Operating_Income}_i}{\text{Interest}_i} \right)^{(t,t+3)} - \text{mean} \left(\frac{\text{Operating_Income}_i}{\text{Interest}_i} \right)^{(t-3,t)}, \quad (4)$$

$$\Delta DIV_i = \text{mean} \left(\frac{\Delta \text{Div_Cash}_i}{\text{Lag_Price_Close}_i} \right)^{(t,t+3)} - \left(\frac{\Delta \text{Div_Cash}_i}{\text{Lag_Price_Close}_i} \right)^{(t-3,t)}, \quad (5)$$

$$\Delta CAPEX_i = \text{mean} \left(\frac{\text{Capital_Exp}_i}{TA_i} \right)^{(t,t+3)} - \text{mean} \left(\frac{\text{Capital_Exp}_i}{TA_i} \right)^{(t-3,t)}, \quad (6)$$

$$\Delta MAXGW_i = MAXGW_i^{(t,t+3)} - MAXGW_i^{(t-3,t)}, \quad (7)$$

本研究以執行長大學受災程度作為自變數。Caldera and Wirasinghe (2022) 提出全球統一的災害嚴重性分類系統 (Universal Disaster Severity Classification Scheme, UDSCS)，以量化和質性的方式將災害嚴重程度由低至高分為 0 級到 10 級，共 11 個等級。基於上述文獻之災害嚴重程度辨別方式，本研究將近十年之災害事件報導共 25 則上傳以訓練 ChatGPT-5.1 和 Gemini 3 Pro，得到其自定義之包含死亡人數 (F)、受傷人數 (I)、財產損失 (P)、持續時間 (D) 四項指標的災害嚴重程度加權計算方式：

$$\text{Severity} = (W_F \times N_F) + (W_I \times N_I) + (W_P \times N_P) + (W_D \times N_D),$$

其中，財產損失 (P) 根據美國每年的 GDP 平減指數 (GDP deflator) 進行調整，詳細指令將於本章第四節說明。⁶

⁶ 美國的 GDP 平減指數來源為世界銀行 (World Bank)

<https://data.worldbank.org/indicator/NY.GDP.DEFL.KD.ZG.AD?locations=US>。

第四節 AI 輔助產生的執行長大學受災程度研究變數

本研究之自變數為執行長大學受災程度，因尚未有文獻明確定義出災害嚴重程度的計算方式，故本研究以 AI 輔助，透過上傳不同種類的用詞及 Bloomberg 新聞文字，訓練 AI 以得到其自定義之災害嚴重程度加權計算方式，作為本研究之自變數，附錄一說明指令 AI 之原始設定詞及新聞報導清單。機器學習的核心目標為優化預測能力，而非傳統計量側重之因果推論 (Varian, 2014; Mullainathan and Spiess, 2017)。近年來，將此預測優勢應用於文字等非結構化資料，藉以萃取潛藏的經濟訊號，已成為學界高度認可的研究途徑，本研究的 AI 評分系統便是建構在此邏輯之上。

首先自行閱讀 Bloomberg 之災害報導，找出三大類用詞：情緒用詞、災害用詞及嚴重度用詞，並找出其同義名詞、形容詞及副詞並上傳 AI，詳細詞彙列表在附錄二說明。其中情緒用詞與嚴重度用詞之語言分數為 AI 自定義，而災害用詞之語言分數則採用本章第三節中提到由 Caldera and Wirasinghe (2022) 提出的「全球統一的災害嚴重性分類系統」所定義。結合本研究指示之各項詞彙出現段落位置之加權分數與情緒用詞最為重要之指示，得到三大類語言加權分數，而後 AI 依據性質將三大類語言加權分數分配給死亡人數 (F)、受傷人數 (I)、財產損失 (P)、持續時間 (D) 四個要素，得到此四個要素的最終權重。⁷

⁷ 有關段落位置加權分數本研究指示標題最為重要，首段次之，其餘內文再次之。




圖 1、AI 訓練災害評分流程圖 (資料來源: 本研究擬制)

最終得到 ChatGPT 對於此四個要素的權重為死亡人數 (F): 32%、受傷人數 (I): 24%、財產損失 (P): 26%、持續時間 (D): 18%；Gemini 對於此四個要素的權重為死亡人數 (F): 45%、受傷人數 (I): 30%、財產損失 (P): 20%、持續時間 (D): 5%，詳細評分過程在附錄三說明。

除災害中心點地區以外，定義中心點半徑 200 英里內的區域為鄰近區域。本研究採用球面三角法 (Haversine Formula) 計算各 FIPS 中心點的直線距離，透過交叉連接 (Cross-join) 將目標 FIPS 與全美 FIPS 座標進行比對，篩選出所有落在 200 英里範圍內的鄰居 FIPS。⁸ 本研究產生兩種互補的嚴重度指標，分別

⁸ 本研究將鄰近地區的篩選基準設定為 200 英里，主要基於交通可及性與風險感知兩項考量。

以美國高速公路平均速限估算，200 英里約為 2 至 3 小時車程，屬於區域內頻繁互動的生活圈。在此地緣範圍內，若周遭發生重大災難，非災區居民不僅在地理空間上感到威脅，亦容易因媒體傳播、同儕遭遇或生活圈重疊，產生感同身受的恐慌心理，因此界定其為受災影響之鄰近範圍。

空間距離 d 係透過 Haversine 公式計算： $d = 2R \times \arcsin \left(\sqrt{\sin^2 \left(\frac{\Delta\varphi}{2} \right) + \cos\varphi_1 \cos\varphi_2 \sin^2 \left(\frac{\Delta\lambda}{2} \right)} \right)$ ，

其中 φ 與 λ 分別代表緯度與經度，其計算基準為全美縣級 FIPS 之中心點座標。本研究篩選 $d \leq 200$ miles 之觀察值作為鄰近樣本，藉此計算災害中心點周圍地區的災害嚴重程度分數。

基於 ChatGPT 和 Gemini 的評分模型：(1) 當地嚴重度 ($Severity_{Local}^{GPT/Gemini}$)：CEO 就讀大學所在地於畢業前五年至畢業後一年的災害嚴重度總和，代表最直接的衝擊；(2) 鄰近區域嚴重度 ($Severity_{Neighbor}^{GPT/Gemini}$)：CEO 就讀大學 200 英里內所有鄰近區域於畢業前五年至畢業後一年的災害嚴重度總和，反映區域性災害對周邊環境或生活圈的間接影響。

第四章 實證結果



第一節 敘述性統計

模型 1 原始樣本來源為企業市場資料串連災害資料，相關敘述性統計整理於表 1 第一部分。應變數 $\Delta RETVOL_IDIO$ 的平均值皆接近 0，顯示新上任後公司股市報酬的非系統性風險未有明顯差異，其亦呈現些微右偏態，但峰度高，顯示極端觀測值的影響顯著。在自變數方面，災害發生地的嚴重度分數 ($Severity_{Local}^{GPT/Gemini}$ 、 $Severity_{Neighbor}^{GPT/Gemini}$) 呈現高度右偏態、峰度高。在控制變數方面，執行長年齡與公司規模呈現穩健的常態分佈，性別的平均值為 0.9631 高度集中於男性。和 ROE 相關的三項控制變數 (ROE_mean 、 ΔROE_mean 、 ROE_ind_mean) 皆呈現非對稱分布，其中 ROE_mean 呈現高度左偏、 ΔROE_mean 和 ROE_ind_mean 則呈現高度右偏，且三者皆峰度高，同樣顯示極端觀測值的影響顯著。因此，本研究使用 *Winsorize* 縮尾處理第一部分所有應變數和控制變數，且本章第三節所列示之迴歸係數及統計量皆為利用 *Cook's Distance* 判斷並排除離群之後再次做迴歸之結果。

模型 2-1、2-2、2-3、3-1、3-2 和 3-3 原始樣本來源為企業財報資料串連災害資料，相關敘述性統計整理於表 1 第二部分。其中 ΔDIV 和 $\Delta CAPEX$ 的平均值小於 0，而 ΔLEV 、 $\Delta DEBT$ 、 ΔICR 和 $\Delta MAXGW$ 平均值大於 0。在這五個指標當中， ΔLEV 的偏態與峰態較接近常態分布， $\Delta DEBT$ 的分布呈現對稱但峰度高，其餘變數皆呈現高度右偏或左偏，且峰度高，受極端觀測值的影響顯著。自變數和控制變數的敘述統計結果大致和表 1 第一部分相同，顯示樣本增加並沒有造成樣本偏誤。本研究同樣使用 *Winsorize* 縮尾處理第二部分所有應變數和控制變數，且本章第三節所列示之迴歸係數及統計量皆為利用 *Cook's Distance* 判斷並排除離群之後再次做迴歸之結果。





表 1、敘述型統計

第一部分 模型 1-1 敘述性統計量

變數名稱	樣本數	平均值	標準差	中位數	最大值	最小值	偏態	峰度
<i>ΔRETVOL_IDIO</i>	1,275	0.0005	0.0242	-0.0001	0.1111	-0.0856	0.9872	8.3959
<i>Severity^{GPT}_{Local}</i>	1,275	0.0248	0.0394	0.0163	0.3513	0.0000	5.0417	29.2616
<i>Severity^{GPT}_{Neighbor}</i>	1,275	1.4335	0.9463	1.4319	5.3784	0.0000	0.3589	-0.2150
<i>Severity^{Gemini}_{Local}</i>	1,275	0.0594	0.0829	0.0405	0.6208	0.0000	4.4273	22.2146
<i>Severity^{Gemini}_{Neighbor}</i>	1,275	3.7525	2.5269	3.7445	14.6860	0.0000	0.4147	-0.0364
<i>Degree</i>	1,275	0.6158	0.4866	1.0000	1.0000	0.0000	-0.4754	-1.7754
<i>Age</i>	1,275	70.5027	9.5198	70.0000	103.0000	41.0000	0.1668	-0.0401
<i>Gender</i>	1,275	0.9631	0.1885	1.0000	1.0000	0.0000	-4.9101	22.1465
<i>niq_dummy</i>	1,275	0.7255	0.4464	1.0000	1.0000	0.0000	-1.0094	-0.9819
<i>brd_dummy</i>	1,275	0.8784	0.3269	1.0000	1.0000	0.0000	-2.3133	3.3542
<i>years</i>	1,275	2.8929	0.7481	2.9301	6.1600	0.0000	-0.2701	0.5478



SIZE	1,275	6.7580	2.2511	6.7815	14.4647	0.2844	0.1053	-0.0894
ROE_mean	1,275	-0.0246	2.3499	-0.0000	42.1656	-54.5857	-8.7244	372.8810
ΔROE_mean	1,275	0.1361	4.1606	0.0002	116.2189	-42.1877	19.4030	521.0511
ROE_ind_mean	1,275	0.0412	0.9926	0.0001	29.4681	-3.4089	22.1675	618.5215

第二部分 模型 2-1、2-2、2-3、3-1、3-2 和 3-3 敘述性統計量

變數名稱	樣本數	平均值	標準差	中位數	最大值	最小值	偏態	峰度
ΔLEV	2,177	0.0061	0.1089	0.0007	0.7126	-0.5803	0.1684	3.2626
$\Delta DEBT$	2,177	0.0035	0.1126	-0.0004	0.6571	-0.7426	0.1081	5.7117
ΔICR	2,177	6.5616	506.5721	0.2127	11,516.0868	-6,990.8133	6.5815	210.7336
ΔDIV	1,675	-0.3360	8.5008	0.0000	3.9097	-9.2031	-4.8344	38.0686
$\Delta CAPEX$	2,177	-0.0036	0.0275	-0.0005	0.2215	-0.3831	-3.0982	39.6740
$\Delta MAXGW$	1,675	159.0878	757.4481	0.0000	5,880.3340	-581.9221	6.0099	38.6589
$Severity_{Local}^{GPT}$	2,177	0.0259	0.0421	0.0169	0.4039	0.0000	4.9184	27.5358



Severity^{GPT}_{Neighbor}	2,177	1.4342	0.9475	1.4319	6.3514	0.0000	0.3935	-0.0211
Severity^{Gemini}_{Local}	2,177	0.0617	0.0872	0.0424	0.6208	0.0000	4.2714	20.2507
Severity^{Gemini}_{Neighbor}	2,177	3.7547	2.5304	3.7204	17.3776	0.0000	0.4516	-0.1806
Degree	2,177	0.6021	0.4896	1.0000	1.0000	0.0000	-0.4168	-1.8272
Age	2,177	70.7426	9.4786	70.0000	103.0000	42.0000	0.1030	-0.2261
Gender	2,177	0.9570	0.2029	1.0000	1.0000	0.0000	-4.5037	18.2914
niq_dummy	2,177	0.7678	0.4223	1.0000	1.0000	0.0000	-1.2677	-0.3932
brd_dummy	2,177	0.8478	0.3593	1.0000	1.0000	0.0000	-1.9350	1.7450
years	2,177	2.8722	0.7293	2.9115	5.1855	0.0000	-0.2040	0.2406
SIZE	2,177	7.1743	2.3785	7.1551	14.4647	0.2844	0.1480	-0.0208
ROE_mean	2,177	-0.0371	1.5970	0.0000	19.3668	-54.5857	-26.0906	848.9125
ΔROE_mean	2,177	0.1087	3.1364	0.0004	116.2189	-19.3483	29.2101	984.8194
ROE_ind_mean	2,177	0.0229	0.5719	0.0001	11.3724	-5.1415	10.5614	178.2022

表 1 變數與定義：ΔRETVOL_IDIO 為 CEO 新任三年間企業股市報酬非系統性風險和該 CEO 上任前三年企業市場非系統性風險的差；ΔLEV 為 CEO 新任三年



間企業負債比率和該 CEO 上任前三年企業負債比率的差； $\Delta DEBT$ 為 CEO 新任三年間企業籌資活動負債比率和該 CEO 上任前三年企業籌資活動負債比率的差； ΔICR 為 CEO 新任三年間企業利息保障倍數比和該 CEO 上任前三年企業利息保障倍數比的差； ΔDIV 為 CEO 新任三年間企業以期初股價標準化後之股利和該 CEO 上任前三年企業以期初股價標準化後之股利變動； $\Delta CAPEX$ 為 CEO 新任三年間企業資本支出占比和該 CEO 上任前三年企業資本支出占比的差； $\Delta MAXGW$ 為 CEO 新任三年間企業最大商譽和該 CEO 上任前三年企業最大商譽的差。

$Severity_{Local}^{GPT}$ 為 ChatGPT-5.1 定義之災害所在地嚴重程度分數，分數範圍為 0 至 1 之間， $Severity_{Neighbor}^{GPT}$ 為 ChatGPT-5.1 定義之災害鄰近地嚴重程度分數，分數範圍為 0 至 1 之間； $Severity_{Local}^{Gemini}$ 為 Gemini 3 Pro 定義之災害所在地嚴重程度分數，分數範圍為 0 至 1 之間， $Severity_{Neighbor}^{Gemini}$ 為 Gemini 3 Pro 定義之災害鄰近地嚴重程度分數，分數範圍為 0 至 1 之間； $Degree$ 為 CEO 取得學位種類之虛擬變數，若取得文學士學位 (BA) 則為 1，若取得理學士學位 (BS) 則為 0； Age 為 CEO 的年齡； $Gender$ 為 CEO 的性別的虛擬變數，若為女性則為 0，若為男性則為 1； niq_dummy 為 CEO 新任三年間企業淨利是否為正的虛擬變數，若為正則為 1，若為負則為 0； brd_dummy 為 CEO 在新任公司是否為董事會成員的虛擬變數，若是董事會成員則為 1，若非董事會成員則為 0； $years$ 為 CEO 新任該職位距離大學畢業的年數差距，以十年為單位進行縮放； $SIZE$ 為 CEO 新任企業取對數之期初資產； ROE_mean 為 CEO 新任三年前企業 ROE 之平均； ΔROE_mean 為 CEO 新任三年間企業 ROE 和該 CEO 上任前三年企業 ROE 的差； ROE_ind_mean 為 CEO 新任三年前該企業所屬產業的 ROE 之平均。

為進一步探究極端受災樣本特徵，本研究交叉比對 GPT 與 Gemini 評分位居前二十名之 CEO，整理於表 2。單一地區受災度 ($Severity_{Local}^{GPT}$ 和 $Severity_{Local}^{Gemini}$) 之排名極端值集中於美西，其中以加州洛杉磯郡 (Los Angeles County, California) 為主要，當中又以為南加州大學 (University of Southern California, USC)、加州大學洛杉磯分校 (University of California Los Angeles, UCLA) 佔大多數。畢業時間段 (awarddate) 部分，集中在 1970-1974 年畢業，對應了 1971 年 2 月發生於加州洛杉磯郡的聖費爾南多大地震 (San Fernando Earthquake)。




表 2、極端受災 CEO 名單
第一部分、以 GPT 計算之名單

排名	directorid	$Severity_{Local}^{GPT}$	FIPS	地區	大學	awarddate
1	1089482	0.4039	17031	Cook County, Illinois	Northwestern University	1998/12/28
2	1318511	0.3513	6037	Los Angeles County, California	University of Southern California (USC)	1996/12/28
3	597747	0.3510	6037	Los Angeles County, California	California State University Los Angeles	1994/12/28
4	1484011	0.3503	6037	Los Angeles County, California	University of California Los Angeles (UCLA)	1997/12/28
5	1404508	0.3318	17031	Cook County, Illinois	Northwestern University	1995/12/28
6	86732	0.3137	6037	Los Angeles County, California	University of Southern California (USC)	1970/12/31
7	88647	0.3137	6037	Los Angeles County, California	University of California Los Angeles (UCLA)	1970/12/31

8	203064	0.3137	6037	Los Angeles County, California	University of Southern California (USC)	1970/12/31
9	34490	0.3123	6037	Los Angeles County, California	California State University Los Angeles	1971/12/31
10	106627	0.3124	6037	Los Angeles County, California	University of California Los Angeles (UCLA)	1971/12/31
11	202943	0.3093	6037	Los Angeles County, California	University of Southern California (USC)	1974/12/31
12	57976	0.3080	6037	Los Angeles County, California	University of Southern California (USC)	1973/12/31
13	81187	0.3080	6037	Los Angeles County, California	University of California Los Angeles (UCLA)	1973/12/31
14	204960	0.3080	6037	Los Angeles County, California	University of California Los Angeles (UCLA)	1973/12/31



15	375014	0.2684	6037	Los Angeles County, California	University of California Los Angeles (UCLA)	1983/12/28
16	1284848	0.2684	6037	Los Angeles County, California	Pomona College	1983/12/28
17	1481452	0.2684	6037	Los Angeles County, California	California Institute of Technology (CALTECH)	1983/12/28
18	64087	0.2679	6037	Los Angeles County, California	University of California Los Angeles (UCLA)	1982/12/28
19	1958681	0.2654	6037	Los Angeles County, California	University of California Los Angeles (UCLA)	1984/12/28
20	2102074	0.2499	26161	Washtenaw County, Michigan	Eastern Michigan University (EMU)	1995/12/28



第二部分、以 Gemini 計算之名單

排名	directorid	Severity ^{Gemini} _{Local}	FIPS	地區	大學	awarddate
1	1284848	0.6208	6037	Los Angeles County, California	Pomona College	1983/12/28
2	375014	0.6208	6037	Los Angeles County, California	University of Southern California (USC)	1983/12/28
3	1481452	0.3510	6037	Los Angeles County, California	California Institute of Technology (CALTECH)	1983/12/28
4	64087	0.6200	6037	Los Angeles County, California	University of California Los Angeles (UCLA)	1982-12-28
5	1958681	0.6160	17031	Cook County, Illinois	University of California Los Angeles (UCLA)	1984-12-28
6	203064	0.6008	6037	Los Angeles County, California	University of Southern California (USC)	1970-12-31



7	88647	0.6008	6037	Los Angeles County, California	University of California Los Angeles (UCLA)	1970/12/31
8	86732	0.6008	6037	Los Angeles County, California	University of Southern California (USC)	1970/12/31
9	34490	0.5973	6037	Los Angeles County, California	California State University Los Angeles	1971/12/31
10	106627	0.5973	6037	Los Angeles County, California	University of California Los Angeles (UCLA)	1971/12/31
11	202943	0.5884	6037	Los Angeles County, California	University of Southern California (USC)	1974/12/31
12	1089482	0.5851	17031	Cook County, Illinois	Northwestern University	1998-12-28
13	81187	0.5850	6037	Los Angeles County, California	University of California Los Angeles (UCLA)	1973/12/31





14	204960	0.5850	6037	Los Angeles County, California	University of California Los Angeles (UCLA)	1973/12/31
15	57976	0.5850	6037	Los Angeles County, California	University of Southern California (USC)	1973/12/31
16	33179	0.5756	6075	San Francisco County, California	University of San Francisco (USF)	1972/12/31
17	220105	0.5505	6073	San Diego County County, California	San Diego State University (SDSU)	1980/12/28
18	1091037	0.5472	6073	San Diego County, California	University of California San Diego (UCSD)	1983/12/28
19	329147	0.5472	6073	San Diego County County, California	San Diego State University (SDSU)	1982/12/28
20	372028	0.5472	6073	San Diego County, California	University of California San Diego (UCSD)	1982/12/28

第二節 相關性係數

表 3 第一部分列示模型 1 之相關係數，其中 GPT 或 Gemini 定義之災害所在地之嚴重分數 ($Severity_{Local}^{GPT}$ 和 $Severity_{Local}^{Gemini}$) 和災害鄰近地區 ($Severity_{Neighbor}^{GPT}$ 和 $Severity_{Neighbor}^{Gemini}$) 之 Pearson 和 Spearman 相關係數皆僅為 (0.0177、0.4005；0.0486、0.4296)，顯示兩者雖有正向關聯，但不完全重疊，若僅採用單一地點之嚴重度 ($Severity_{Local}$) 作為自變數，將低估災害對 CEO 的實質衝擊。

GPT 自定義之災害所在地嚴重分數 ($Severity_{Local}^{GPT}$) 和 Gemini 自定義之災害所在地嚴重分數 ($Severity_{Local}^{Gemini}$) 的 Pearson 和 Spearman 係數都呈現高度正向相關性 (0.9628 和 0.9886)；GPT 自定義之災害鄰近地嚴重分數 ($Severity_{Neighbor}^{GPT}$) 和 Gemini 自定義之災害鄰近地嚴重分數 ($Severity_{Neighbor}^{Gemini}$) 的 Pearson 和 Spearman 係數亦都呈現高度正向相關性 (0.9986 和 0.9986)，顯示 AI 評分的高度穩定性。

模型 2-1、2-2、2-3 和 3-2 之相關係數整理於表 3 第二部分，其中公司的總負債比率變動 (ΔLEV) 和公司的籌資活動負債比率變動 ($\Delta DEBT$) 的 Pearson 和 Spearman 係數都呈現高度正相關 (0.7137 和 0.7471)；公司的總負債比率變動 (ΔLEV) 和公司的利息保障倍數比變動 (ΔICR) 的 Spearman 係數呈負相關 (-0.1972)；公司的籌資活動負債比率變動 ($\Delta DEBT$) 和公司的利息保障倍數比變動 (ΔICR) 的 Spearman 係數呈負相關 (-0.1639)，符合現實邏輯。而自變數部分所呈現之相關性和第一部分相同。

模型 3-1 和 3-3 之相關係數整理於表 3 第三部分，公司規模 ($SIZE$) 和以股價標準化後之股利變動 (ΔDIV) 的 Pearson 和 Spearman 係數都呈負相關 (-0.0060 和 -0.1279)；相反地公司規模和最大商譽的差 ($\Delta MAXGW$) 的 Pearson 和 Spearman 係數都呈現顯著正相關 (0.2122 和 0.3118)，顯示企業規模影響公司資本結構和積極性投資行為。




表 3、相關係數表

第一部分、模型 1

	$\Delta RETVOL_IDIO$	$Severity_{Local}^{GPT}$	$Severity_{Neighbor}^{GPT}$	$Severity_{Local}^{Gemini}$	$Severity_{Neighbor}^{Gemini}$	$SIZE$	ROE_mean
$\Delta RETVOL_IDIO$	1.0000	-0.0131	0.0273	-0.0131	0.0275	-0.0141	0.0816**
$Severity_{Local}^{GPT}$	0.0045	1.0000	0.4005***	0.9886***	0.4020***	0.0308	0.0232
$Severity_{Neighbor}^{GPT}$	0.0213	0.0177	1.0000	0.0526.	0.9986***	0.0485.	0.0150
$Severity_{Local}^{Gemini}$	0.0077	0.9628***	0.4261***	1.0000	0.4296***	0.0290	0.0290
$Severity_{Neighbor}^{Gemini}$	0.0219	0.0088	0.9986***	0.0486.	1.0000	0.0492.	0.0274
$SIZE$	-0.0202	0.0072	0.0531.	-0.0011	0.0532.	1.0000	-0.0151
ROE_mean	0.0202	-0.0022	-0.0057	0.0208	0.0208	-0.0476.	1.0000

第二部分、模型 2-1、2-2、2-3 和 3-2

	ΔLEV	$\Delta DEBT$	ΔICR	$\Delta CAPEX$	$Severity_{Local}^{GPT}$	$Severity_{Local}^{Gemini}$	$Severity_{Neighbor}^{GPT}$	$Severity_{Neighbor}^{Gemini}$	ROE_mean
ΔLEV	1.0000	0.7471***	-0.1972***	-0.0772***	-0.0160	-0.0149	-0.0376.	-0.0386.	0.0642**
$\Delta DEBT$	0.7137***	1.0000	-0.1639***	-0.1096***	-0.0027	-0.0044	-0.0225	-0.0249	0.0586**



ΔICR	0.0494*	0.0478*	-0.2432***	-0.1096***	-0.0112	-0.0109	-0.0268	-0.0253	-0.0187
$\Delta CAPEX$	-0.0121	-0.0478*	-0.0559**	1.000	0.0407.	0.0426*	0.0212	0.0195	-0.0001
$Severity_{Local}^{GPT}$	-0.0195	-0.0458*	-0.0193	0.0097	1.000	0.9884***	0.4108***	0.4122***	0.0098
$Severity_{Local}^{Gemini}$	-0.0201	-0.0298	-0.0200	0.0160	0.9640***	1.000	0.4398***	0.4433***	0.0067
$Severity_{Neighbor}^{GPT}$	-0.0301	-0.0285	-0.0268	-0.0078	0.0239	0.0595**	1.000	0.9987***	0.0149
$Severity_{Neighbor}^{Gemini}$	-0.0305	-0.0791***	-0.0286	-0.0079	0.0147	0.0552*	0.9987***	1.000	0.0136
ROE_mean	0.0004	-0.1850***	0.0350	0.0189	-0.0189	-0.0251	0.0404.	0.0396.	1.0000

第三部分、模型 3-1 和 3-3

	ΔDIV	$\Delta MAXGW$	$Severity_{Local}^{GPT}$	$Severity_{Local}^{Gemini}$	$Severity_{Neighbor}^{GPT}$	$Severity_{Neighbor}^{Gemini}$	$SIZE$	ROE_mean
ΔDIV	1.0000	0.0578*	0.0157	0.0107	-0.1071***	-0.1085***	-0.1279***	0.0231
$\Delta MAXGW$	-0.0449.	1.0000	0.0119	0.0227	0.0508*	0.0522*	0.3118***	0.0172
$Severity_{Local}^{GPT}$	0.0045	0.0898***	1.000	0.9869***	0.3827***	0.3850***	0.0612*	0.0014
$Severity_{Local}^{Gemini}$	0.0045	0.0881***	0.9650***	1.000	0.4148***	0.4190***	0.0625*	0.0023
$Severity_{Neighbor}^{GPT}$	0.0078	0.0770**	0.0046	0.0392	1.000	0.9987***	0.1285***	0.0062
$Severity_{Neighbor}^{Gemini}$	0.0066	0.0757**	-0.0037	0.0357	0.9986***	1.000	0.1255***	0.0057



SIZE	-0.0060	0.2122***	0.0306	0.0312	0.1341***	0.1345***	1.000	0.0050
ROE_mean	0.0264	0.0054	-0.0115	-0.0101	0.0110	0.0143	0.0617*	1.0000

1. 矩陣左下角呈現皮爾森相關係數 (Pearson Correlation)，右上角則為史皮爾曼等級相關係數 (Spearman Rank Correlation)；第一部分樣本數為 1,275，第二部分樣本數為 2,177，第三部分樣本數為 1,675。
2. . 為 p 值小於 0.1，*為 p 值小於 0.05，**為 p 值小於 0.01，***為 p 值小於 0.001。
3. 變數定義如同表 1。

第三節 迴歸分析結果

模型 1、2-1、2-2、2-3、3-1、3-2 和 3-3 迴歸結果統整於表 4，以下分別針對各模型結果分析。第一部分分組迴歸結果中，模型 1 結果顯示以 GPT 和 Gemini 計算之受災害嚴重度的係數相等性結果 F 檢定值均未達統計顯著標準，假說 1 未獲支持。模型 2-1 結果顯示以 GPT 和 Gemini 計算之受災害嚴重度的係數相等性結果 F 檢定值均未達統計顯著標準，假說 2a 未獲支持。模型 2-2 結果顯示以 GPT 和 Gemini 計算之受災害嚴重度的係數相等性結果 F 檢定值均未達統計顯著標準，假說 2b 未獲支持。模型 2-3 結果顯示以 GPT 計算之受災害嚴重度的係數相等性結果顯示中度受災 (*Mid*) 和高度受災 (*High*) 有顯著差異，而對照兩者的係數得知高度受災的 CEO 新上任後公司三年的利息保障倍數會較中度受災的 CEO 新上任後的利息保障倍數高，較為風險趨避，結果支持假說 2c；而以 Gemini 計算之 F 值未達統計顯著標準。模型 3-1 以 GPT 和 Gemini 計算之受災害嚴重度的係數相等性結果 F 檢定值均未達統計顯著標準，假說 3a 未獲支持；模型 3-2 以 GPT 和 Gemini 計算之受災害嚴重度的係數相等性結果 F 檢定值均未達統計顯著標準，假說 3b 未獲支持；模型 3-3 顯示 CEO 是否為董事會成員對併購政策有調節作用，在以 Gemini 計算之受災害嚴重度的係數相等性結果顯示低度受災 (*Low*) 的 CEO 和高度受災 (*High*) 的 CEO 有顯著差異，而對照兩者的係數得知高度受災的 CEO 新上任後公司三年的最大商譽較低度受災的 CEO 新上任後公司三年的最大商譽低，較為風險趨避，結果支持假說 3c；而以 GPT 計算之 F 值未達統計顯著標準。

第二部分線性迴歸結果中，模型 1 結果顯示以 GPT 和 Gemini 計算之災害鄰近區域之受災分數係數顯著為負，表示有受災經驗的 CEO 新上任後三年的公司市場非系統性風險降低，較為風險趨避，結果支持假說 1，顯示線性顯著但分組不顯著。模型 2-1 結果顯示以 GPT 和 Gemini 計算之災害所在地和鄰近區域之受災分數影響於顯性及分組設計皆未達顯著標準，假說 2a 未獲支持。模型 2-

2 結果顯示以 GPT 和 Gemini 計算之災害所在地和鄰近區域之受災分數影響於顯性及分組設計皆未達顯著標準，假說 2b 未獲支持。模型 2-3 結果顯示以 GPT 和 Gemini 計算之災害所在地和鄰近區域之受災分數皆未達顯著標準，假說 2c 未獲支持，分組顯著但線性不顯著。模型 3-1 結果顯示以 GPT 和 Gemini 計算之災害所在地和鄰近區域之受災分數影響於顯性及分組設計皆未達顯著標準，假說 3a 未獲支持。模型 3-2 結果顯示以 GPT 和 Gemini 計算之災害所在地和鄰近區域之受災分數影響於顯性及分組設計皆未達顯著標準，假說 3b 未獲支持。模型 3-3 結果顯示以 GPT 和 Gemini 計算之災害所在地和鄰近區域之受災分數皆未達顯著標準，假說 3c 未獲支持，分組有調節效果但線性不顯著。

綜上本研究實證結果和 Bernile, Bhagwat, and Rau (2017) 的實證結果不完全一致，災害經驗反而會讓 CEO 決策時更為風險趨避，迴歸整體結果如表 5 所示。本研究推論原因為災害經驗的經歷時期不同，發生在兒時和大學時期會對 CEO 的人格發展造成不同的影響。





表 4、迴歸結果分析

第一部分、分組迴歸

	模型 1		模型 2-1		模型 2-2		模型 2-3		模型 3-1		模型 3-2		模型 3-3	
應變數	$\Delta RETVOL_IDIO$		ΔLEV		$\Delta DEBT$		ΔICR		ΔDIV		$\Delta CAPEX$		$\Delta MAXGW$	
	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini
High	0.008	0.009	-0.043	0.029	0.060	0.048	-132.400	-89.600	0.301	0.274	0.017	0.020	259.000	261.500
	(0.35)	(0.38)	(-0.70)	(0.31)	(0.65)	(0.53)	(-1.11)	(-0.48)	(0.27)	(0.25)	(1.30)	(0.96)	(0.41)	(0.42)
Mid	-0.004	0.060	0.089	-0.114	0.117	-0.034	-513.200***	-217.000	0.788	1.468	0.008	0.054	-379.100	522.800
	(-0.13)	(1.16)	(1.15)	(-0.74)	(1.03)	(-0.23)	(-3.37)	(-0.71)	(0.52)	(0.72)	(0.46)	(1.62)	(-0.44)	(0.45)
Low	0.029	0.008	-0.123	-0.001	0.010	0.178	-246.500	95.920	1.311	1.435	0.024	0.071*	480.400	434.000
	(0.75)	(0.16)	(-1.29)	(-0.01)	(0.08)	(1.12)	(-1.32)	(0.29)	(0.88)	(0.67)	(1.17)	(1.99)	(0.57)	(0.36)
Degree	-0.001	-0.001	-0.008	-0.009	-0.007	-0.007	29.130**	25.610**	-0.075	-0.071	-0.001	-0.001	18.550	12.330
	(-1.50)	(-0.50)	(-1.44)	(-1.51)	(-1.24)	(-1.30)	(2.26)	(2.27)	(-0.96)	(-0.95)	(-0.49)	(-0.46)	(0.42)	(0.29)
Age	0.000	0.000	0.000	0.000	-0.001	-0.000	0.020	1.496	0.017	0.015	0.000	0.000	14.460**	13.290**
	(-0.40)	(0.05)	(-0.28)	(0.25)	(-0.83)	(-0.30)	(0.01)	(0.87)	(1.42)	(1.30)	(-0.76)	(-0.62)	(2.19)	(2.00)
Gender	-0.001	0.003	-0.021	-0.021	-0.025**	-0.027**	-9.471	-36.550	-0.207	-0.185	0.008**	0.005*	101.700	121.100

	(-0.49)	(0.67)	(-1.42)	(-1.63)	(-1.98)	(-2.17)	(-0.32)	(-1.42)	(-1.22)	(-1.12)	(2.41)	(1.92)	(1.05)	(1.29)
niq_dummy	-0.002**	-0.006***	-0.044***	-0.043***	-0.025***	-0.027***	45.030***	41.580***	0.226**	0.199	0.003*	0.003*	93.810*	85.030
	(-2.03)	(-2.83)	(-5.63)	(-6.22)	(-3.69)	(-4.22)	(2.94)	(3.06)	(2.36)	(2.18)	(1.68)	(1.88)	(1.73)	(1.64)
brd_dummy	0.000	0.000	0.017*	0.017**	0.005	0.003	17.210	3.959	0.106	0.067	-0.000	-0.000	-359.500***	-357.600***
	(0.19)	(0.18)	(1.72)	(2.00)	(0.62)	(0.35)	(0.90)	(0.23)	(0.86)	(0.57)	(-0.14)	(-0.03)	(-5.16)	(-5.37)
brd × High	0.000	0.000	0.017*	0.017**	0.005	0.003	17.210	3.959	0.106	0.067	-0.000	-0.000	-359.500***	-357.600***
	(0.19)	(0.18)	(1.72)	(2.00)	(0.62)	(0.35)	(0.90)	(0.23)	(0.86)	(0.57)	(-0.14)	(-0.03)	(-5.16)	(-5.37)
brd × Mid	-0.005	-0.000	-0.020	0.039	-0.030	-0.028	-14.946	98.349	-0.350	0.052	-0.006	0.009	70.196	451.019
	(-0.53)	(-0.00)	(-0.70)	(0.63)	(-1.12)	(-0.47)	(-0.27)	(0.80)	(-0.94)	(0.06)	(-0.97)	(0.64)	(0.33)	(0.96)
brd × Low	-0.006	-0.008	0.046	0.079	0.007	0.097	46.079	-1.815	-0.708	-0.963	0.003	-0.010	517.392*	458.409
	(-0.28)	(-0.31)	(0.91)	(0.93)	(0.15)	(1.18)	(0.47)	(-0.01)	(-1.50)	(-1.67)	(0.32)	(-0.52)	(1.93)	(1.40)
years	-0.001	-0.001	-0.012	-0.015*	0.001	-0.004	-13.796	-15.638	-0.609	-0.665	0.002	0.001	-83.430	-76.577
	(-0.33)	(-0.25)	(-1.37)	(-1.77)	(0.13)	(-0.52)	(-0.83)	(-0.92)	(-1.02)	(-1.12)	(0.98)	(0.59)	(-1.31)	(-1.23)
years × High	-0.001	-0.001	-0.012	-0.015*	0.001	-0.004	-13.796	-15.638	-0.609	-0.665	0.002	0.001	-83.430	-76.577
	(-0.33)	(-0.25)	(-1.37)	(-1.77)	(0.13)	(-0.52)	(-0.83)	(-0.92)	(-1.02)	(-1.12)	(0.98)	(0.59)	(-1.31)	(-1.23)
years × Mid	-0.002	-0.004	-0.009	-0.006	0.000	0.009	-4.412	-57.214	0.138	0.304	-0.003	0.000	42.586	40.588





	(-0.45)	(-0.68)	(-0.67)	(-0.32)	(0.03)	(0.48)	(-0.17)	(-1.48)	(0.17)	(1.48)	(-0.95)	(0.10)	(0.45)	(0.27)
<i>years</i> × <i>Low</i>	0.001	0.002	-0.023	-0.025	-0.015	-0.019	-23.488	-9.214	0.194	0.129	-0.001	-0.003	58.640	42.559
	(0.25)	(0.31)	(-1.59)	(-1.37)	(-1.04)	(-1.06)	(-0.81)	(-0.25)	(1.47)	(0.84)	(-0.40)	(-0.84)	(0.61)	(0.38)
<i>SIZE</i>	0.000	-0.000	0.005***	0.005***	0.002	0.002*	-1.989	-1.667	-0.061***	-0.063***	0.000	0.000	66.880***	66.820***
	(0.11)	(-0.33)	(3.48)	(3.50)	(1.64)	(1.68)	(-0.70)	(-0.59)	(-3.26)	(-3.34)	(1.38)	(1.40)	(6.26)	(6.27)
<i>ROE_mean</i>	-0.003	-0.023	-0.033	-0.027	-0.108*	-0.099	-159.500	-165.400	-1.648*	-1.576	0.002	0.002	143.600	111.300
	(-0.49)	(-1.32)	(-0.54)	(-0.45)	(-1.79)	(-1.64)	(-1.33)	(-1.37)	(-1.67)	(-1.60)	(0.16)	(0.16)	(0.26)	(0.20)
<i>ROE_ind_mean</i>	0.003	0.001	-0.027	-0.030*	-0.014	-0.016	-30.860	-29.690	-0.045	-0.040	0.005	0.004	-79.150	-107.200
	(1.54)	(0.28)	(-1.63)	(-1.81)	(-0.91)	(-1.04)	(-0.95)	(-0.92)	(-0.15)	(-0.14)	(1.29)	(1.19)	(-0.47)	(-0.63)
<i>ΔROE_mean</i>	-0.001	-0.014	-0.036	-0.033	-0.078**	-0.072**	-81.670	-88.300	-0.558	-0.512	-0.005	-0.005	-24.800	-49.030
	(-0.28)	(-1.48)	(-1.07)	(-0.99)	(-2.34)	(-2.18)	(-1.24)	(-1.34)	(-1.00)	(-0.92)	(-0.75)	(-0.72)	(-0.08)	(-0.16)

係數相等性檢定

<i>H0: Low=Mid</i>	0.664	0.691	3.412*	0.356	0.983	1.352	1.400	0.694	0.122	0.000	0.430	0.177	0.240	0.004
<i>H0: Mid=High</i>	0.218	1.520	2.167	1.273	0.615	0.455	4.708**	0.257	0.194	0.442	0.228	1.561	0.143	0.066
<i>H0: Low=High</i>	0.381	0.034	0.589	0.045	0.297	0.899	0.307	0.434	0.819	0.375	0.097	2.809*	0.115	0.026

調節效果檢定

<i>H0: (1)=(2)</i>	0.002	0.047	1.339	0.143	0.456	1.523	0.300	0.230	0.382	1.020	0.592	0.636	1.508	0.000
<i>H0: (2)=(3)</i>	0.189	0.001	1.372	0.128	1.343	0.254	0.101	0.564	1.140	0.000	0.699	0.450	0.315	2.792*
<i>H0: (1)=(3)</i>	0.069	0.079	0.289	0.527	0.002	1.291	0.160	0.001	2.530	2.896*	0.104	0.233	3.060*	5.647**
<i>H0: (4)=(5)</i>	0.266	0.519	0.695	0.575	0.702	1.228	0.336	0.909	0.007	0.496	0.151	0.442	1.029	0.093
<i>H0: (5)=(6)</i>	0.049	0.266	0.052	0.156	0.002	0.386	0.111	0.983	3.281*	3.285*	1.706	0.020	1.032	0.892
<i>H0: (4)=(6)</i>	0.115	0.124	0.403	0.252	0.770	0.475	0.082	0.019	3.194*	1.206	0.584	0.860	0.122	1.956
<i>Year Effect</i>	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included
<i>Industry Effect</i>	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included
<i>Uni Effect</i>	No	No	No	No	No	No	No	No	No	No	No	No	No	No
<i>N</i>	1,275	1,275	2,177	2,177	2,177	2,177	2,177	2,177	1,675	1,675	2,177	2,177	1,675	1,675
<i>F</i>	1.210	1.234	1.335	1.377	1.265***	1.303***	0.856	0.118	0.890	0.886	1.440	1.453	2.548	2.517
<i>Adj – R²</i>	0.036	0.032	0.044	0.048	0.032	0.037	-0.012	-0.020	0.044	0.044	0.037	0.038	0.171	0.173
<i>Within – R²</i>	0.039	0.035	0.047	0.050	0.026	0.030	0.024	0.015	0.063	0.062	0.017	0.018	0.103	0.105

第二部分、線性迴歸

模型 1	模型 2-1	模型 2-2	模型 2-3	模型 3-1	模型 3-2	模型 3-3
------	--------	--------	--------	--------	--------	--------

應變數	$\Delta RETVOL_IDIO$		ΔLEV		$\Delta DEBT$		ΔICR		ΔDIV		$\Delta CAPEX$		$\Delta MAXGW$	
	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini
Intercept	0.028	0.027	-0.147	-0.147	0.013	0.002	-374.100	-394.300	-0.617	-0.725	0.030	0.030	-724.500	-635.900
	(0.66)	(0.63)	(-0.92)	(-0.92)	(0.09)	(0.01)	(-1.19)	(-1.26)	(-0.28)	(-0.33)	(0.87)	(0.89)	(-0.57)	(-0.50)
Severity^{GPT}_{Local}	2.205		1.845		1.379		1472.000		5.113		-0.270		13170.000	
	(1.40)		(1.34)		(0.89)		(0.71)		(0.23)		(-0.92)		(1.02)	
Severity^{2GPT}_{Local}	-45.050		-8.830		-5.728		-3102.000		11.710		0.605		-19120.000	
	(-1.30)		(-1.64)		(-1.06)		(-0.48)		(0.13)		(0.65)		(-0.36)	
Severity^{GPT}_{Neighbor}	-0.060**		0.015		0.030		143.200		0.114		-0.005		-108.000	
	(-2.03)		(0.17)		(0.49)		(1.07)		(0.12)		(-0.30)		(-0.20)	
Severity^{2GPT}_{Neighbor}	0.020**		-0.010		-0.013		-8.361		-0.119		-0.000		87.820	
	(1.99)		(-0.42)		(-0.76)		(-0.33)		(-0.43)		(-0.19)		(0.55)	
Severity^{Gemini}_{Local}		0.617		0.845		0.528		1634.000		-2.946		-0.222		10600.000
		(1.04)		(1.19)		(0.67)		(1.02)		(-0.26)		(-1.21)		(1.63)
Severity^{2Gemini}_{Local}		-5.089		-1.823		-0.832		-3658.000		11.790		0.415		-16750.000
		(-0.99)		(-1.08)		(-0.49)		(-0.96)		(0.51)		(1.07)		(-1.26)

Severity^{Gemini}_{Neighbor}

-0.020*

0.007

0.014

53.380

0.046

-0.001

-55.280

(-1.84)

(0.18)

(0.58)

(1.03)

(0.13)

(-0.16)

(-0.27)

Severity^{2Gemini}_{Neighbor}

0.003**

-0.002

-0.002

-1.677

-0.015

-0.000

13.100

(1.80)

(-0.52)

(-0.96)

(-0.43)

(-0.38)

(-0.25)

(0.57)

Degree

0.003

0.004

-0.008

-0.009

-0.003

-0.004

-7.461

-4.934

-0.044

-0.044

-0.002

-0.003

-48.560

-36.280

(0.68)

(0.96)

(-0.75)

(-0.86)

(-0.21)

(-0.33)

(-0.37)

(-0.26)

(-0.26)

(-0.27)

(-0.84)

(-0.92)

(-0.50)

(-0.38)

Age

0.000

0.000

0.002*

0.002*

0.001

0.000

3.796

3.812*

0.004

0.003

-0.000

-0.000

7.794

8.920

(0.02)

(-0.05)

(1.81)

(1.71)

(0.62)

(0.48)

(1.65)

(1.68)

(0.30)

(0.26)

(-0.74)

(-0.85)

(0.99)

(1.14)

Gender

0.000

0.000

-0.030

-0.028

-0.007

-0.008

17.150

37.860

-0.380

-0.331

-0.005

-0.003

621.300*

584.700

(0.04)

(-0.01)

(-0.64)

(-0.64)

(-0.23)

(-0.26)

(0.17)

(0.34)

(-0.72)

(-0.64)

(-0.58)

(-0.51)

(2.04)

(1.94)

niq_dummy

-0.010

-0.010

-0.080***

-0.080***

-0.065***

-0.065***

44.270

39.220

0.078

0.074

0.004

0.004

-20.120

-32.320

(-1.63)

(-1.59)

(-4.18)

(-4.34)

(-3.65)

(-3.81)

(1.43)

(1.31)

(0.43)

(0.42)

(0.87)

(0.85)

(-0.19)

(-0.31)

brd_dummy

-0.007

-0.006

0.019

0.020

-0.006

-0.004

-27.150

-30.840

0.134

0.087

-0.001

-0.001

32.340

26.450

(-1.13)

(-0.91)

(0.92)

(1.04)

(-0.23)

(-0.16)

(-0.54)

(-0.66)

(0.47)

(0.32)

(-0.43)

(-0.25)

(0.20)

(0.17)

years

-0.001

-0.000

-0.028**

-0.001**

-0.010

-0.006

-0.419

-0.376

-0.003

-0.009

0.001

0.001

-7.501

-8.442

(-0.13)

(-0.04)

(-2.56)

(-2.29)

(-0.93)

(-0.61)

(-0.56)

(-0.51)

(-0.15)

(-0.43)


(0.22)

(0.24)

(-1.08)

(-1.22)





SIZE	-0.000	-0.000	0.005***	0.005***	0.002*	0.003*	-1.890	-1.844	-0.052**	-0.052**	0.000	0.000	67.390***	67.140***
	(-0.35)	(-0.30)	(3.52)	(3.58)	(1.75)	(1.72)	(-0.60)	(-0.57)	(-2.83)	(-2.83)	(1.45)	(1.52)	(6.31)	(6.30)
ROE_mean	-0.022	-0.024	-0.016	-0.025	-0.093	-0.097	-166.300	-163.800	-1.843	-1.794	0.002	0.002	114.600	70.580
	(-1.21)	(-0.79)	(-0.25)	(-0.40)	(-1.54)	(-0.64)	(-0.77)	(-0.76)	(-1.90)	(-1.86)	(0.11)	(1.29)	(0.20)	(0.13)
ROE_ind_mean	0.002	0.001	-0.028	-0.028	-0.013	-0.014	-30.960	-29.810	-0.067	-0.057	0.004	0.004	-122.600	-126.400
	(0.22)	(0.20)	(-1.39)	(-1.37)	(-0.60)	(-0.91)	(-0.62)	(-0.60)	(-0.23)	(-0.20)	(0.90)	(0.91)	(-0.72)	(-0.74)
ΔROE_mean	-0.011	-0.013	-0.019	-0.024	-0.064	-0.067**	-98.150	-95.670	-0.596	-0.562	-0.006	-0.006	-33.680	-59.630
	(-0.59)	(-0.72)	(-0.70)	(-0.78)	(-1.30)	(-1.34)	(-0.88)	(-0.86)	(-1.09)	(-1.03)	(-0.79)	(-0.78)	(-0.11)	(-0.19)
Year Effect	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included
Industry Effect	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included
Uni Effect	No	No	No	No	No	No	No	No	No	No	No	No	No	No
N	1,275	1,275	2,177	2,177	2,177	2,177	2,177	2,177	1,675	1,675	2,177	2,177	1,675	1,675
F	1.112	1.095	1.333***	1.311***	1.249***	1.256***	0.820	0.828	1.168	1.174	1.291	1.308	2.200	2.211
Adj – R²	0.027	0.023	0.045	0.043	0.033	0.033	-0.026	-0.025	0.028	0.029	0.040	0.042	0.171	0.173
Within – R²	0.039	0.035	0.055	0.053	0.033	0.034	0.027	0.028	0.080	0.081	0.029	0.031	0.099	0.101



1. *為 p 值小於 0.1, **為 p 值小於 0.05, ***為 p 值小於 0.01。括弧內為 t 值。為解決公司內部可能存在的異質性與序列相關問題, 本研究採用公司層級之叢集穩健標準誤 (Cluster-robust standard errors) 計算 t 值。
2. (1)、(2)和(3)分別代表調節項 $brd \times Low$ 、 $brd \times Mid$ 和 $brd \times High$; (4)、(5)和(6)分別代表調節項 $years \times Low$ 、 $years \times Mid$ 和 $years \times High$ 。
3. 係數相等性檢定及調節效果檢定顯示之統計量為 F 值。

表 5、顯著迴歸結果統整

研究模型	風險指標	指標來源	關鍵變數	係數
分組檢定	ΔICR	GPT	$Mid=High$	$Mid = -513.200^{***}$ $High = -132.400$
調節效果	$\Delta MAXGW$	Gemini	$brd*Low=brd*High$	$Brd*Low = 458.409$ $Brd*High = -357.600^{***}$
線性	$\Delta RETVOL_IDIO$	GPT	$Severity_{Neighbor}^{GPT}$	-0.06^{**}

第四節 額外分析



上述的實證分析考慮股市報酬決定的風險指標，其概念是基於效率市場假說 (Efficient Market Hypothesis, EMH)，以捕捉資本市場對標的公司風險溢酬的即時評價。模型 4-1 和 4-2 使用會計決定的風險指標，使用分組迴歸和線性迴歸從基本面的角度驗證公司的經營風險是否與市場表現一致。

$$\Delta ROEVOL_SYS_i = \beta_i^{(t,t+3)^2} \times Var\left(ROE_m^{(t,t+3)}\right) - \beta_i^{(t-3,t)^2} \times Var\left(ROE_m^{(t-3,t)}\right), \quad (8)$$

$$\begin{aligned} \Delta ROEVOL_IDIO_i = & \left[Var\left(ROE_i^{(t,t+3)}\right) - ROEVOL_SYS_i^{(t,t+3)} \right] - \\ & \left[Var\left(ROE_i^{(t-3,t)}\right) - ROEVOL_SYS_i^{(t-3,t)} \right], \quad (9) \end{aligned}$$

式 (8) 和式 (9) 中，變異數使用去季節性標準差計算，且普通股股東權益 (Common Shareholders' Equity) 皆使用期初值以計算 ROE。Alawattagama (2018) 認為權益報酬率 (ROE) 被作為企業財務績效的代理變數，因公開的財報資料更能準確反映企業的財務績效。

模型 4-1 和 4-2

$$\begin{aligned} CORPORATE_RISK = & \beta_0 + \sum_{s \in \{Local, Neighbor\}} \beta_{1s} Severity_{s,i}^{GPT/Gemini} + \\ & \sum_{s \in \{Local, Neighbor\}} \beta_{2s} Severity_{s,i}^{2GPT/Gemini} + \\ & \sum_{s \in \{Local, Neighbor\}} \theta_{1s} Severity_{s,i}^{GPT/Gemini} \times Z_{i,t} + \\ & \sum_{s \in \{Local, Neighbor\}} \theta_{2s} Severity_{s,i}^{2GPT/Gemini} \times Z_{i,t} + \Phi X_{i,t} + Year_{i,t} + Industry_{i,t} + \\ & \varepsilon_{i,t}, \end{aligned}$$

$$\begin{aligned} CORPORATE_RISK_{i,t} = & \beta_0 + \sum_{s \in \{Local, Neighbor\}} \beta_{1s} Severity_{s,i}^{GPT/Gemini} + \\ & \sum_{s \in \{Local, Neighbor\}} \beta_{2s} Severity_{s,i}^{2GPT/Gemini} + \\ & \sum_{s \in \{Local, Neighbor\}} \theta_{1s} Severity_{s,i}^{GPT/Gemini} \times Z_{i,t} + \end{aligned}$$

$$\sum_{s \in \{Local, Neighbor\}} \theta_{2s} Severity_{s,i}^{2^{GPT/Gemini}} \times Z_{i,t} + \Phi X_{i,t} + Year_{i,t} + Industry_{i,t} + \varepsilon_{i,t},$$

其中，*CORPORATE_RISK* 包含 $\Delta ROEVOL_SYS_i$ 和 $\Delta ROEVOL_IDIO_i$ 。實證結果如表 6 所示。第一部分分組迴歸結果，模型 4-1 中以 GPT 和 Gemini 計算之受災害嚴重度的係數相等性結果 *F* 檢定值均未達統計顯著標準。模型 4-2 顯示 CEO 是否為董事會成員對會計非系統性風險有調節作用，在以 GPT 計算之受災害嚴重度的係數相等性結果顯示中度受災 (*Mid*) 和高度受災 (*High*) 有顯著差異，而對照兩者的係數得知高度受災的 CEO 新任公司三年的會計非系統性風險較中度受災的 CEO 新任公司三年的會計非系統性風險低，較為風險趨避；而以 Gemini 計算之 *F* 值未達統計顯著標準。

第二部分顯示模型 4-1 結果以 GPT 和 Gemini 計算之災害所在地和鄰近區域之受災分數線性迴歸結果，皆未達顯著標準，線性及分組皆不顯著。模型 4-2 結果顯示以 GPT 和 Gemini 計算之災害所在地和鄰近區域之受災分數皆未達顯著標準，顯示分組顯著但線性不顯著。

表 6、額外分析結果

第一部分、分組迴歸

	模型 4-1		模型 4-2	
應變數	$\Delta ROEVOL_SYS$		$\Delta ROEVOL_IDIO$	
	GPT	Gemini	GPT	Gemini
High	-0.050	-0.058	-0.826**	-0.836**
	(-0.58)	(-0.68)	(-2.09)	(-2.12)
Mid	-0.089	-0.117	-0.981*	-1.222*
	(-0.80)	(-0.81)	(-1.90)	(-1.83)
Low	-0.005	0.106	-0.919*	-0.195



	(-0.05)	(0.70)	(-1.69)	(-0.28)
Degree	-0.002	-0.003	0.002	0.004
	(-0.43)	(-0.51)	(0.09)	(0.16)
Age	0.001	0.001	0.002	0.004
	(0.96)	(1.10)	(0.64)	(1.15)
Gender	-0.006	-0.006	0.014	0.012
	(-0.47)	(-0.50)	(0.26)	(0.21)
niq_dummy	0.000	-0.001	-0.010	-0.008
	(0.02)	(-0.10)	(-0.32)	(-0.28)
brd_dummy	-0.008	-0.008	-0.001	0.003
	(-0.98)	(-0.98)	(-0.02)	(0.10)
brd × High	-0.008	-0.008	-0.001	0.003
	(-0.98)	(-0.98)	(-0.02)	(0.10)
brd × Mid	-0.007	0.008	0.278**	0.030
	(-0.25)	(0.14)	(2.21)	(0.12)
brd × Low	0.002	0.022	0.005	0.001
	(0.04)	(0.29)	(0.03)	(0.00)
years	-0.047	-0.068*	-0.010	-0.010
	(-1.29)	(-1.85)	(-1.28)	(-1.30)
years × High	-0.047	-0.068*	-0.010	-0.010
	(-1.29)	(-1.85)	(-1.28)	(-1.30)
years × Mid	-0.052	-0.157*	0.009	0.007
	(-0.88)	(-1.88)	(0.74)	(0.38)
years × Low	-0.063	0.061	0.014	0.017
	(-0.98)	(0.73)	(1.00)	(0.94)
SIZE	-0.003*	-0.003*	0.002	0.003
	(-1.96)	(-1.90)	(0.40)	(0.53)




<i>ROE_mean</i>	0.025 (0.40)	0.026 (0.43)	-3.049*** (-10.82)	-3.072*** (-10.89)
<i>ROE_ind_mean</i>	-0.052*** (-3.29)	-0.051*** (-3.24)	0.077 (1.05)	0.077 (1.06)
<i>ΔROE_mean</i>	0.093*** (2.94)	0.093*** (2.91)	-0.470*** (-3.22)	-0.487*** (-3.33)
係數相等性檢定				
<i>H0: Low=Mid</i>	0.564	1.591	0.015	1.593
<i>H0: Mid=High</i>	0.257	0.232	0.188	0.479
<i>H0: Low=High</i>	0.255	1.581	0.052	1.132
調節效果檢定				
<i>H0: (1)=(2)</i>	0.028	0.024	1.285	0.004
<i>H0: (2)=(3)</i>	0.001	0.079	3.933**	0.000
<i>H0: (1)=(3)</i>	0.043	0.156	0.001	0.005
<i>H0: (4)=(5)</i>	0.028	0.181	0.016	3.452*
<i>H0: (5)=(6)</i>	1.701	0.695	0.004	0.822
<i>H0: (4)=(6)</i>	1.786	1.681	0.033	1.692
<i>Year Effect</i>	Included	Included	Included	Included
<i>Industry Effect</i>	Included	Included	Included	Included
<i>Uni Effect</i>	No	No	No	No
<i>N</i>	2,177	2,177	2,177	2,177
<i>F</i>	0.975	0.971	1.659	1.669
<i>Adj – R²</i>	-0.004	-0.004	0.086	0.089
<i>Within – R²</i>	0.026	0.027	0.106	0.106

第二部分、線性迴歸

模型 4-1	模型 4-2
--------	--------

應變數	$\Delta ROEVOL_SYS$		$\Delta ROEVOL_IDIO$	
Intercept	0.073	0.082	-0.516	-0.467
	(0.57)	(0.64)	(-0.88)	(-0.79)
Severity^{GPT}_{Local}	-0.383		3.811	
	(-0.26)		(0.55)	
Severity^{2GPT}_{Local}	-1.336		-9.489	
	(-0.24)		(-0.37)	
Severity^{GPT}_{Neighbor}	-0.064		0.259	
	(-0.95)		(0.83)	
Severity^{2GPT}_{Neighbor}	0.018		-0.048	
	(0.95)		(-0.53)	
Severity^{Gemini}_{Local}		-0.272		1.119
		(-0.33)		(0.29)
Severity^{2Gemini}_{Local}		0.037		-1.649
		(0.02)		(-0.20)
Severity^{Gemini}_{Neighbor}		-0.025		0.095
		(-0.99)		(0.80)
Severity^{2Gemini}_{Neighbor}		0.003		-0.007
		(1.00)		(-0.53)
Degree	-0.024*	-0.022*	-0.065	-0.066
	(-1.95)	(-1.87)	(-1.14)	(-1.19)
Age	0.000	0.000	0.005	0.004
	(-0.08)	(-0.20)	(1.00)	(0.94)
Gender	0.027	0.027	0.058	0.057
	(0.69)	(0.69)	(0.32)	(0.32)
niq_dummy	-0.022	-0.020	0.088	0.082
	(-1.48)	(-1.34)	(1.24)	(1.18)



<i>brd_dummy</i>	-0.015 (-0.75)	-0.017 (-0.87)	0.075 (0.80)	0.070 (0.77)
<i>years</i>	-0.005 (-0.60)	-0.004 (-0.35)	-0.056 (-1.05)	-0.055 (-1.04)
<i>SIZE</i>	-0.003*** (-2.06)	-0.003** (-2.03)	0.002 (0.28)	0.002 (0.27)
<i>ROE_mean</i>	0.016 (0.26)	0.014 (0.24)	-3.081*** (-10.81)	-3.079*** (-10.83)
<i>ROE_ind_mean</i>	-0.051*** (-3.21)	-0.051*** (-3.23)	0.085 (1.15)	0.083 (1.13)
<i>ΔROE_mean</i>	0.091*** (2.84)	0.088*** (2.75)	-0.502*** (-3.37)	-0.504*** (-3.41)
<i>Year Effect</i>	Included	Included	Included	Included
<i>Industry Effect</i>	Included	Included	Included	Included
<i>Uni Effect</i>	No	No	No	No
<i>N</i>	2,177	2,177	2,177	2,177
<i>F</i>	1.013	1.006	1.512	1.522
<i>Adj – R²</i>	0.002	0.001	0.071	0.073
<i>Within – R²</i>	0.037	0.036	0.103	0.104

1. *為 p 值小於 0.1**為 p 值小於 0.05***為 p 值小於 0.01。括弧內為 t 值。

為解決公司內部可能存在的異質性與序列相關問題，本研究採用公司層級之叢集穩健標準誤（Cluster-robust standard errors）計算 t 值。

2. (1)、(2)和(3)分別代表調節項 $brd \times Low$ 、 $brd \times Mid$ 和 $brd \times High$ ；(4)、(5)和(6)分別代表調節項 $years \times Low$ 、 $years \times Mid$ 和 $years \times High$ 。

3. 係數相等性檢定及調節效果檢定顯示之統計量為 F 值。

第五節 穩健性分析

為確保本研究實證結果之可靠性，並排除 CEO 潛在背景特徵之干擾，本研究加入大學固定效果 (Uni Effect)，控制 CEO 母校不隨時間改變之未觀測特徵對企業風險決策可能產生的偏誤。

如表 7 所示，在控制大學固定效果後，分組迴歸之檢驗結果仍然和主模型結果高度相似，其一為高度受災 (*High*) 與中度受災 (*Mid*) 的 CEO 新上任後公司的利息保障倍數顯著不同，且高度受災之 CEO 其公司展現較高的利息保障倍數，證實較強的風險趨避傾向。其二為在探討董事會成員身份之調節作用時，高度受災與低度受災之 CEO 差異顯著，高度受災之 CEO 其公司最大商譽顯著較低，決策態度更保守。


惟在線性迴歸模型中，原先顯著之災害鄰近區域受災分數在加入大學固定效果後，股市報酬非系統性風險之差異未能達到統計顯著水準，可能為組內變異之吸收。




表 7、穩健性分析結果

第一部分、分組迴歸

	模型 1		模型 2-1		模型 2-2		模型 2-3		模型 3-1		模型 3-2		模型 3-3	
應變數	$\Delta RETVOL_IDIO$		ΔLEV		$\Delta DEBT$		ΔICR		ΔDIV		$\Delta CAPEX$		$\Delta MAXGW$	
	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini
High	0.025	0.020	0.331*	0.336**	0.426***	0.426***	50.634	12.693	-0.872	-0.792	0.057	0.060*	-69.832	-10.435
	(0.65)	(0.54)	(1.93)	(1.97)	(2.62)	(2.62)	(0.16)	(0.04)	(-0.63)	(-0.58)	(1.58)	(1.66)	(-0.07)	(-0.01)
Mid	0.011	0.072	0.479**	0.193	0.495***	0.280	-394.733	-246.027	-0.578	-0.304	0.050	0.037	-27.583	350.871
	(0.20)	(1.13)	(2.46)	(0.86)	(2.67)	(1.31)	(-1.07)	(-0.58)	(-0.37)	(-0.15)	(1.23)	(0.79)	(-0.02)	(0.24)
Low	0.034	-0.065	0.214	0.289	0.328*	0.451	-25.261	308.065	-1.459	-1.346	0.043	0.057	-29.581	-664.602
	(0.63)	(-0.81)	(1.06)	(1.18)	(1.70)	(1.93)	(-0.07)	(0.67)	(-0.88)	(-0.61)	(1.01)	(1.10)	(-0.02)	(-0.41)
Degree	-0.001	-0.001	-0.009	-0.009	-0.012	-0.011	35.106**	34.146**	0.052	0.039	0.003	0.002	56.417	50.186
	(-0.43)	(-0.28)	(-1.09)	(-1.05)	(-1.50)	(-1.42)	(2.20)	(2.22)	(0.58)	(0.45)	(1.56)	(0.92)	(0.85)	(0.79)
Age	-0.000	-0.000	0.001	0.002	-0.000	0.000	0.786	1.370	0.003	0.002	-0.002	-0.002	7.778	6.540
	(-0.53)	(-0.60)	(1.15)	(1.41)	(-0.28)	(0.23)	(0.38)	(0.63)	(0.23)	(0.15)	(-0.96)	(-1.00)	(0.91)	(0.75)
Gender	-0.001	-0.001	-0.011	-0.018	-0.030*	-0.032*	-29.335	-16.726	-0.350	-0.331	0.004	0.004	600.210	550.462



	(-0.24)	(-0.09)	(-0.64)	(-1.11)	(-1.87)	(-2.04)	(-0.93)	(-0.54)	(-0.60)	(-0.65)	(1.25)	(1.24)	(1.05)	(1.63)
niq_dummy	-0.003	-0.003	-0.043***	-0.044***	-0.027***	-0.030***	22.926	23.574	0.207**	0.175**	0.001	0.001	35.486	28.645
	(-1.29)	(-1.36)	(-5.23)	(-5.64)	(-3.49)	(-4.06)	(1.49)	(1.60)	(2.24)	(1.98)	(0.65)	(0.62)	(0.52)	(0.44)
brd_dummy	0.000	-0.000	0.022**	0.021**	0.011	0.007	-4.026	1.912	0.133	0.086	0.001	0.001	-435.969***	-410.789
	(0.01)	(-0.13)	(2.10)	(2.22)	(1.10)	(0.77)	(-0.21)	(0.10)	(1.14)	(0.77)	(0.04)	(0.15)	(-5.08)	(-5.01)
brd × High	0.000	-0.000	0.022**	0.021**	0.011	0.007	-4.026	1.912	0.133	0.086	0.001	0.001	-435.969***	-410.789
	(0.01)	(-0.13)	(2.10)	(2.22)	(1.10)	(0.77)	(-0.21)	(0.10)	(1.14)	(0.77)	(0.04)	(0.15)	(-5.08)	(-5.01)
brd × Mid	-0.003	-0.009	0.052	0.054	-0.050	-0.021	65.883	38.798	-0.428	0.055	0.003	0.008	-119.275	-853.274***
	(-0.21)	(-0.67)	(0.92)	(0.77)	(-1.56)	(-0.32)	(1.03)	(0.30)	(-1.23)	(0.09)	(0.43)	(0.54)	(-0.66)	(-3.26)
brd × Low	-0.006	-0.006	-0.018	0.095	-0.010	0.071	49.197	21.446	-0.051	-0.114	0.001	-0.021	-321.719**	-39.766
	(-0.23)	(-0.53)	(-0.52)	(0.91)	(-0.19)	(0.72)	(0.46)	(0.11)	(-0.10)	(-0.12)	(0.08)	(-0.94)	(-2.00)	(-0.21)
years	-0.000	0.000	-0.001**	-0.001**	-0.000	-0.000	-0.006	-0.700	-0.001	-0.000	0.000	0.000	-0.800	-0.900
	(-0.07)	(0.05)	(1.97)	(-2.35)	(-0.08)	(-0.69)	(-1.08)	(-1.18)	(-0.18)	(-0.01)	(0.64)	(0.53)	(-0.35)	(-0.38)
years × High	-0.000	0.000	-0.001**	-0.001**	-0.000	-0.000	-0.006	-0.700	-0.001	-0.000	0.000	0.000	-0.800	-0.900
	(-0.07)	(0.05)	(1.97)	(-2.35)	(-0.08)	(-0.69)	(-1.08)	(-1.18)	(-0.18)	(-0.01)	(0.64)	(0.53)	(-0.35)	(-0.38)
years × Mid	0.000	-0.000	-0.001	-0.001	-0.000	-0.000	0.001	0.600	0.005	0.001	-0.000	0.000	-0.025	0.017



	(0.59)	(-0.51)	(-0.86)	(-1.02)	(-0.66)	(-0.54)	(0.16)	(0.50)	(1.18)	(1.14)	(-0.85)	(0.61)	(-0.82)	(0.36)
<i>years</i> × <i>Low</i>	-0.000	-0.000	-0.001	-0.000	-0.000	-0.000	-0.001	-0.300	0.005	0.001	0.000	0.000	0.037	0.027
	(-0.54)	(-0.51)	(-1.16)	(-0.81)	(-0.56)	(-0.08)	(-0.06)	(-0.23)	(1.00)	(0.89)	(0.28)	(0.10)	(1.04)	(0.58)
<i>SIZE</i>	0.000	0.000	0.006***	0.006***	0.004**	0.004**	0.038	0.135	-0.053***	-0.053***	0.001	0.001	74.770***	74.904***
	(0.10)	(0.24)	(3.22)	(3.25)	(2.23)	(2.31)	(0.01)	(0.04)	(-3.02)	(-3.00)	(1.60)	(1.60)	(5.76)	(5.79)
<i>ROE_mean</i>	-0.023	-0.024	-0.016	-0.020	-0.069	-0.068	-339.305**	-330.85**	-1.296	-1.186	-0.008	0.005	210.774	216.221
	(-1.03)	(-1.09)	(-0.20)	(-0.26)	(-0.96)	(-0.94)	(-2.37)	(-2.31)	(-1.38)	(-1.26)	(-0.95)	(0.34)	(0.31)	(0.31)
<i>ROE_ind_mean</i>	-0.003	-0.003	-0.020	-0.023	0.003	-0.000	-72.394**	-75.632**	-0.115	-0.112	0.004	0.004	-22.818	-25.225
	(-0.46)	(-0.49)	(-1.10)	(-1.27)	(0.18)	(-0.02)	(-2.11)	(-2.20)	(-0.67)	(-0.65)	(0.93)	(0.97)	(-0.18)	(-0.20)
<i>ΔROE_mean</i>	-0.005	-0.005	-0.018	-0.019	-0.050	-0.049	-137.076*	-136.343*	-0.253	-0.176	0.006	-0.009	41.995	39.915
	(-0.38)	(-0.46)	(-0.45)	(-0.45)	(-1.29)	(-1.26)	(-1.77)	(-1.76)	(-0.49)	(-0.34)	(0.40)	(-1.03)	(0.11)	(0.10)

係數相等性檢定

<i>H0: Low=Mid</i>	0.138	2.317	3.332*	0.164	1.462	0.576	1.816	1.530	0.500	0.197	0.063	0.153	2.697	0.348
<i>H0: Mid=High</i>	0.086	0.877	2.190	0.869	0.529	1.014	5.573**	0.797	0.127	0.097	0.093	0.486	0.005	0.099
<i>H0: Low=High</i>	0.046	1.386	0.194	0.064	0.766	0.019	0.117	0.709	0.315	0.093	0.323	0.006	0.003	0.242

調節效果檢定

<i>H0: (1)=(2)</i>	0.015	1.108	1.185	0.108	0.430	0.604	0.019	0.005	0.386	0.022	0.025	1.168	1.923	0.437
<i>H0: (2)=(3)</i>	0.036	0.216	1.071	0.209	2.850*	0.179	0.948	0.075	1.987	0.002	0.138	0.253	4.511*	5.430*
<i>H0: (1)=(3)</i>	0.051	0.900	0.267	0.494	0.141	0.412	0.228	0.010	0.111	0.043	0.004	0.902	9.363***	5.705**
<i>H0: (4)=(5)</i>	0.729	0.000	0.090	0.037	0.001	0.118	0.026	0.247	0.000	0.046	0.674	0.144	2.042	0.022
<i>H0: (5)=(6)</i>	0.258	0.212	0.204	0.012	0.210	0.031	0.539	0.803	0.880	1.035	1.107	0.093	0.157	0.230
<i>H0: (4)=(6)</i>	0.141	0.215	0.013	0.116	0.141	0.052	0.244	0.103	0.701	0.550	0.011	0.020	0.911	0.405
<i>Year Effect</i>	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included
<i>Industry Effect</i>	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included
<i>Uni Effect</i>	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included
<i>N</i>	1,275	1,275	2,177	2,177	2,177	2,177	2,177	2,177	1,675	1,675	2,177	2,177	1,675	1,675
<i>F</i>	1.167**	1.179**	1.037	1.045	1.056	1.063	1.097*	1.084	1.024	1.013	1.232***	1.223***	1.650***	1.663***
<i>Adj – R²</i>	0.080	0.086	0.012	0.015	0.019	0.021	0.031	0.027	0.009	0.005	0.072	0.070	0.197	0.201
<i>Within – R²</i>	0.040	0.037	0.055	0.053	0.034	0.034	0.027	0.028	0.064	0.064	0.028	0.031	0.104	0.106

第二部分、線性迴歸

模型 1	模型 2-1	模型 2-2	模型 2-3	模型 3-1	模型 3-2	模型 3-3
------	--------	--------	--------	--------	--------	--------

應變數	$\Delta RETVOL_IDIO$		ΔLEV		$\Delta DEBT$		ΔICR		ΔDIV		$\Delta CAPEX$		$\Delta MAXGW$	
	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini	GPT	Gemini
Intercept	-0.170	0.027	0.116	0.114	0.335	0.340	-97.592	-398.422	-0.710	-0.612	0.027	0.030	-806.724	-831.778
	(-0.21)	(0.64)	(0.52)	(0.51)	(1.56)	(1.59)	(-0.23)	(-1.27)	(-0.49)	(-0.42)	(0.58)	(0.64)	(-0.74)	(-0.58)
Severity^{GPT}_{Local}	0.296		0.666		1.499		720.250		0.854		-0.687		-3413.921	
	(0.31)		(0.33)		(0.79)		(0.19)		(0.06)		(-1.64)		(-0.30)	
Severity^{2GPT}_{Local}	0.102		-6.364		-6.38		107.208		22.337		1.690		43363.810	
	(0.023)		(-0.90)		(-0.94)		(0.01)		(0.35)		(1.13)		(0.92)	
Severity^{GPT}_{Neighbor}	-0.017		0.017		0.047		95.388		1.105*		0.028		-45.904	
	(-0.51)		(0.19)		(0.55)		(0.57)		(1.69)		(1.53)		(-0.10)	
Severity^{2GPT}_{Neighbor}	0.004		-0.009		-0.018		-6.285		-0.416**		-0.005		36.502	
	(0.44)		(-0.36)		(-0.75)		(-0.13)		(-2.23)		(-1.02)		(0.26)	
Severity^{Gemini}_{Local}		0.631		0.578		0.617		1651.823		-2.483		-0.367		-6451.238
		(1.00)		(0.50)		(0.57)		(0.94)		(-0.31)		(-1.52)		(-0.79)
Severity^{2Gemini}_{Local}		-5.067		-1.837		-0.952		-3707.309		9.661		0.511		13484.350
		(-1.06)		(-0.75)		(-0.41)		(-0.96)		(0.57)		(0.99)		(0.79)

Severity^{Gemini}
Neighbor

-0.020*

0.003

0.017

60.743

0.392*

0.010

-103.763

(-1.92)

(0.10)

(0.53)

(1.13)

(1.74)

(1.46)

(-0.47)

Severity^{2Gemini}
Neighbor

0.003**

-0.001

-0.003

-2.521

-0.060

-0.001

1.684

(2.13)

(-0.38)

(-0.83)

(-0.43)

(-2.27)

(-0.92)

(0.07)

Degree

0.001

0.004

-0.015

-0.015

0.003

0.002

-28.675

-5.935

-0.065

-0.061

-0.004

-0.004

-75.082

-98.173

(0.17)

(0.84)

(-0.89)

(-0.91)

(0.21)

(0.12)

(-0.90)

(-0.23)

(-0.52)

(-0.49)

(-1.20)

(-1.27)

(-0.80)

(-0.82)

Age

-0.002

0.000

0.003***

0.003***

0.002

0.002

3.245

3.944*

0.004

0.004

-0.001

-0.001

9.13

5.858

(-0.37)

(0.001)

(2.60)

(2.545)

(1.44)

(1.34)

(1.31)

(1.94)

(0.385)

(0.40)

(-0.41)

(-0.47)

(1.21)

(0.60)

Gender

-0.001

-0.001

-0.048

-0.050

-0.028

-0.032

-31.464

40.774

-0.002

-0.002

0.002

0.001

0.001

0.001

(-0.05)

(-0.04)

(-0.96)

(-1.01)

(-0.059)

(-0.68)

(-0.34)

(0.50)

(-0.29)

(-0.15)

(0.17)

(0.04)

(0.02)

(0.01)

niq_dummy

-0.010*

-0.010**

-0.090***

-0.090***

-0.08***

-0.082***

25.344

39.647

0.003

0.017

0.007*

0.006*

-29.386

-84.498

(-1.72)

(-2.06)

(-4.84)

(-4.95)

(-4.56)

(-4.72)

(0.72)

(1.27)

(0.02)

(0.11)

(1.74)

(1.66)

(-0.27)

(-0.63)

brd_dummy

-0.002

-0.007

0.026

0.029

-0.005

-0.001

19.601

-37.763

0.125

0.131

-0.002

-0.001

104.797

-13.525

(-0.25)

(-0.95)

(0.96)

(1.11)

(-0.20)

(-0.02)

(0.39)

(-0.90)

(0.55)

(0.60)

(-0.30)

(-0.10)

(0.62)

(-0.06)

years

-0.001

-0.001

-0.041***

-0.001**

-0.017

-0.001

-0.400

-0.400

0.000

0.000

0.001

0.001

-0.026

-0.016

(-0.27)

(-0.08)

(-2.86)

(-2.73)

(-1.27)

(-1.09)

(-0.51)

(-0.57)

(0.87)


(0.63)

(0.77)


(0.77)

(-1.13)

(-0.55)



SIZE	-0.001	-0.001	0.006***	0.006***	0.004**	0.004**	0.405	-1.919	-0.031	-0.031	0.001*	0.001*	82.523***	73.280***
	(-0.07)	(-0.48)	(3.25)	(3.32)	(2.24)	(2.32)	(0.13)	(-0.67)	(-2.13)	(-2.13)	(1.72)	(1.79)	(7.53)	(5.61)
ROE_mean	-0.019	-0.024	-0.016	-0.007	-0.049	-0.056	-356.388***	-153.555	-1.82**	-1.81	0.006	0.006	20.744	248.561
	(-0.83)	(1.33)	(-0.25)	(-0.08)	(-0.67)	(-0.78)	(-2.46)	(-1.24)	(-2.24)	(-2.24)	(0.40)	(0.36)	(0.03)	(0.36)
ROE_ind_mean	-0.003	0.001	-0.019	-0.019	0.005	0.004	-76.703**	-33.360	-0.047	-0.049	0.004	0.004	-65.447	-35.820
	(-0.48)	(0.25)	(-1.02)	(-1.01)	(0.26)	(0.213)	(-2.23)	(-1.08)	(-0.31)	(-0.32)	(1.04)	(0.98)	(-0.57)	(-0.28)
ΔROE_mean	-0.001	-0.013	0.001	-0.007	-0.034	-0.038	-157.279***	-90.151	-0.601	-0.594	-0.008	-0.008	-80.878	66.884
	(-0.04)	(-1.34)	(0.01)	(-0.16)	(-0.85)	(-0.97)	(-2.00)	(-1.32)	(-1.34)	(-1.33)	(-0.91)	(-0.94)	(-0.24)	(0.17)
Year Effect	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included
Industry Effect	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included
Uni Effect	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included	Included
N	1,275	1,275	2,177	2,177	2,177	2,177	2,177	2,177	1,675	1,675	2,177	2,177	1,675	1,675
F	1.167**	1.141*	1.037	1.023	1.060	1.058	1.094*	0.820	1.170**	2.237***	1.148**	1.160***	2.237***	1.508***
Adj – R²	0.082	0.024	0.012	0.008	0.020	0.019	0.031	-0.026	0.026	0.164	0.048	0.052	0.164	0.163
Within – R²	0.040	0.037	0.055	0.053	0.034	0.034	0.027	0.028	0.064	0.064	0.028	0.031	0.104	0.106





1. *為 p 值小於 0.1, **為 p 值小於 0.05, ***為 p 值小於 0.01。括弧內為 t 值。為解決公司內部可能存在的異質性與序列相關問題，本研究採用公司層級之叢集穩健標準誤 (Cluster-robust standard errors) 計算 t 值。
2. (1)、(2)和(3)分別代表調節項 $brd \times Low$ 、 $brd \times Mid$ 和 $brd \times High$; (4)、(5)和(6)分別代表調節項 $years \times Low$ 、 $years \times Mid$ 和 $years \times High$ 。
3. 係數相等性檢定及調節效果檢定顯示之統計量為 F 值。

第五章 結論



本文研究 CEO 於大學期間遭受災害的程度是否影響新任公司之非系統性風險指標，本研究貢獻在於首次將 CEO 於大學期間遭受災害的程度作為主要變數，並且利用 AI 工具量化災害經驗，探討其與公司非系統性風險指標的關聯。

實證結果顯示，在股市報酬的非系統性風險方面，有受災經驗的 CEO 其新上任後公司三年之非系統風險較低，為避免對公司不利的極端事件，CEO 傾向於採取更穩健的營運策略。在財務槓桿方面，高度受災經驗的 CEO 其新上任後公司三年之利息保障倍數較中度受災經驗的 CEO 其新任公司之利息保障倍數低，他們為預防未來的黑天鵝事件，保留較多的閒置現金。在現金管理方面，董事會成員的身分調節 CEO 受災經驗與併購政策之間的關係，身兼董事且高度受災的 CEO 其新上任後公司三年之最大商譽低於低度受災的 CEO 其新上任後公司三年之最大商譽。當 CEO 身兼董事，擁有更高的決策主導權時，他們更能將對風險的趨避轉化為實際政策，拒絕具高度投機性的擴張計畫。若考量會計風險，董事會成員的身分亦調節了 CEO 受災經驗與會計非系統性風險的關係。身兼董事且高度受災的 CEO 其新上任後公司三年之會計非系統性風險低於中度受災的 CEO 其新上任後公司三年之會計非系統性風險。這類 CEO 會將其對於風險的恐懼轉化為嚴謹的組織制度，不僅在財務決策上保守，更在經營上追求穩定與可預測性。本研究結果也對重視風險管理的企業在選聘 CEO 時，除 CEO 性別與年齡外，亦可將其大學受災經驗納入考量，因其可能影響 CEO 決策並進而幫助解釋公司不同面向之風險指標變動。

在未來研究方面，其一為由於 SHELDUS 災害資料以美國為主，因和 BoardEx 資料配對後致本研究資料筆數較少、亦無法掌握非於美國就讀大學的 CEO 之風險行為表現，若未來能取得其他地區災害統計資料作為解釋變數，應

可增益準確性與代表性。其二為雖有本研究所建立災害嚴重度分數影響執行長新上任公司的非系統性風險指標之實證結果，此新型指標之計量本質仍有待更深度的探討，未來研究可將 AI 分數與國際公認災害基準度 (UDSCS) 進行吻合度檢驗，並進一步拆解 AI 分數的增額資訊、對未來成長的衝擊及邊際優勢。

參考文獻



- Adra, Samer, Yang Gao, Jin Huang, and Jiayi Yuan (2023), “Geopolitical risk and corporate payout policy,” *International Review of Financial Analysis*, 87, 102613.
- Alawattegama, Kingsley K. (2018), “The impact of enterprise risk management on firm performance: Evidence from Sri Lankan banking and finance industry,” *International Journal of Business and Management*, 13(1), 225-237.
- Amihud, Yakov and Baruch Lev (1981), “Risk reduction as a managerial motive for conglomerate mergers,” *The Bell Journal of Economics*, 605-617.
- Angelis, David D., and Yaniv Grinstein (2020), “Relative performance evaluation in CEO compensation: A talent-retention explanation,” *Journal of Financial and Quantitative Analysis*, 55(7), 2099-2123.
- Arena, Matteo P. and Brandon Julio (2023), “Litigation risk management through corporate payout policy,” *Journal of Financial and Quantitative Analysis*, 58(1), 148-174.
- Bernile, Gennaro, Vineet Bhagwat, and P. Raghavendra Rau (2017), “What doesn't kill you will only make you more risk-loving: Early-life disasters and CEO behavior,” *The Journal of Finance*, 72(1), 167-206.
- Bharath, Sreedhar T., and DuckKi Cho (2023), “Do natural disaster experiences limit stock market participation?,” *Journal of Financial and Quantitative Analysis*, 58(1), 29-70.
- Bronfman, Nicolás C., Pamela C. Cisternas, Paula B. Repetto, Javiera V. Castañeda, and Eliana Guic (2020), “Understanding the relationship between direct experience and risk perception of natural hazards,” *Risk Analysis*, 40(10), 2057-2070.
- Bushman, Robert, Zhonglan Dai, & Xue Wang (2010), “Risk and CEO turnover,” *Journal of Financial Economics*, 96(3), 381-398.
- Caldera, H. Jithamala, and S. C. Wirasinghe (2022), “A universal severity classification for natural disasters,” *Natural Hazards*, 111(2), 1533-1573.

Chen, Guoli, Shuqing Luo, Yi Tang, and Jamie Y. Tong (2023), “Back to school: CEOs’ pre-career exposure to religion, firm’s risk-taking, and innovation,” *Journal of Management*, 49(3), 881-912.

Chen, Guoli, Sterling Huang, Philipp Meyer-Doyle, Denisa Mindruta (2020), “Generalist versus specialist CEOs and acquisitions: Two-sided matching and the impact of CEO characteristics on firm outcomes,” *Strategic Management Journal*, 42(6), 1184-1214.

Chen, Yangyang, Qingliang Fan, Xin Yang, and Leon Zolotoy (2021), “CEO early-life disaster experience and stock price crash risk,” *Journal of Corporate Finance*, 68, 101928.

Choi, Daewoung, Hyunju Shin, and Kyoungmi Kim (2023), “CEO’s childhood experience of natural disaster and CSR activities,” *Journal of Business Ethics*, 188(2), 281-306.

David, Joel M., Lukas Schmid, and David Zeke (2022), “Risk-adjusted capital allocation and misallocation,” *Journal of Financial Economics*, 145(3), 684-705.

Dikolli, Shane S., Viktoria Diser, Christian Hofmann, and Thomas Pfeiffer (2018), “CEO power and relative performance evaluation,” *Contemporary Accounting Research*, 35(3), 1279-1296.

Gulen, Huseyin and Mihai Ion (2016), “Policy uncertainty and corporate investment,” *The Review of financial studies*, 29(3), 523-564.

Gupta, Abhinav, Forrest Briscoe, and Donald C. Hambrick (2018), “Evenhandedness in resource allocation: Its relationship with CEO ideology, organizational discretion, and firm performance,” *Academy of Management Journal*, 61(5), 1848-1868.

Jenter, Dirk and Fadi Kanaan (2015), “CEO turnover and relative performance evaluation,” *The Journal of Finance*, 70(5), 2155-2184.

Kliestik, Tomas, Katarina Valaskova, George Lazaroiu, Maria Kovacova, and Jaromir Vrbka (2020), “Remaining financially healthy and competitive: The role of financial predictors,” *Journal of Competitiveness*, 12(1), 74-92.

Kothari, S. P. (2001), “Capital markets research in accounting,” *Journal of Accounting and Economics*, 31(1-3), 105-231.

Mullainathan, Sendhil, and Jann Spiess (2017), “Machine learning: an applied econometric approach,” *Journal of Economic Perspectives*, 31(2), 87-106.

O'Sullivan, Don, Leon Zolotoy, and Qingliang Fan (2021), “CEO early-life disaster experience and corporate social performance,” *Strategic Management Journal*, 42(11), 2137-2161.

Sharpe, William F. (1964), “Capital asset prices: A theory of market equilibrium under conditions of risk,” *The Journal of Finance*, 19(3), 425-442.

Ullah, Subhan, Muhammad Irfan, Ja Ryong Kim, and Farid Ullah (2023), “Capital expenditures, corporate hedging and firm value,” *The Quarterly Review of Economics and Finance*, 87, 360-366.

Varian, Hal R. (2014), “Big data: New tricks for econometrics,” *Journal of Economic Perspectives*, 28(2), 3-28.

Yao, Shouyu, Zhuoqun Wang, Mengyue Suna, Jing Liaoc, and Feiyang Chenga (2020), “Top executives’ early-life experience and financial disclosure quality: impact from the Great Chinese Famine,” *Accounting and Finance*, 60(5), 4757-4793.

附錄一、AI 模型評分原始設定詞與 25 則報導清單

1. 請找出 Bloomberg 美國近十年之災害報導 25 篇，並且給予標題和網址。
2. 請找出這些報導中最經常使用的情緒性用詞和嚴重度用詞，並且找出與他們同義的形容詞、名詞和副詞。
3. 請根據三大類用詞的語意與段落位置給予分數，並得出災害分數的加權計算方式，其中三大類用詞的重要性以出現在標題、首段和內文其他部分遞減。

Bloomberg 近十年之 25 則災害報導：

標題	日期
Where Fires Are Burning in the U.S. West (2020 wildfires map)	2020/09/14
Hurricane Ian Photos: Florida Sees Widespread Damage	2022/09/29
Wildfire Recovery in Paradise Holds Lessons for Lahaina	2023/08/30
Texas' Extreme Weather Pileups Point to World's Climate Future	2024/06/26
After Natural Disasters, Electric Vehicles Come to the Rescue	2022/11/07
It's All-Consuming.' Wildfire Whispering Is Now a Year-Round Job	2023/10/19
California and Australia Wildfires: Why Firefighting Aircraft Are in Short Supply	2020/04/09
Amid Wildfire Smoke, Here's How to Gauge Air Quality in Your Area	2023/06/07
What East Coast Cities Can Learn From West Coast Wildfire Policies	2023/06/09
The Quest for the Smoke-Proof Building	2023/06/12
Harvey Wasn't Just Bad Weather. It Was Bad City Planning	2017/08/31
Adding Up the Price of Tragedy in Storm-Ravaged Texas	2017/09/05
Mobile Homes Are So Expensive Now, Hurricane Victims Can't Afford Them	2017/11/21

A Weird Buyer's Market Is Brewing for Hurricane Cars	2017/10/04
Business Is Booming for America's Survival Food King	2017/11/22
Texas's Energy Elite Are Listening to a Climate Lawyer	2020/03/03
These Pictures Reveal California's Largest-Ever Wildfire (2018)	2018/08/07
Louisiana's Sinking Coast Is a \$100 Billion Nightmare for Big Oil	2016/08/17
The Fighting Has Begun Over Who Owns Land Drowned by Rising Seas	2018/04/25
Rising Pacific Drives Native Village's Quest for Higher Ground	2021/11/05
America's Great Climate Exodus Is Starting in the Florida Keys	2019/09/20
Deadly Floods Reinforce Texas' Challenge as Crisis Epicenter	2025/07/06
Hurricane Harvey Could Be a Disaster for Houston	2017/08/25
The LA Fires Destroyed 11,000 Homes. Less Than 10% Have Permits to Rebuild	2025/09/25



附錄二、AI 災害評分訓練三大類用詞



1. 情緒性用詞

關鍵字	同義形容詞	同義副詞	同義名詞
Shocking 震驚	astonishing, astounding, startling, staggering, appalling, horrifying, jaw- dropping, stunning, unbelievable	astonishingly, astoundingly, startlingly, staggeringly, appallingly, horrifyingly, jaw- droppingly, stunningly, unbelievably	astonishment, amazement, surprise, horror, shock, outrage, disbelief, stupefaction, consternation, alarm
Helpless 無助	powerless, defenseless, vulnerable, incapable, paralyzed, impotent	powerlessly, defenselessly, vulnerably, incapably, paralyzingly, impotently,	powerlessness, vulnerability, incapacity, weakness, disability, impotence, defenselessness, subordination, reliance
Pain 痛苦	painful, aching, sore, excruciating, agonizing, unbearable, torturous, distressing, grueling	painfully, achingly, sorely, excruciatingly, agonizingly, unbearably, torturously, distressingly, gruelingly	ache, agony, suffering, torment, distress, misery, discomfort, anguish, soreness, hurt
Fear 害怕	afraid, scared, frightened, terrified, petrified, horrified, panicked, alarmed, apprehensive, fearful	fearfully, in fear, in fright, in terror, petrified with fear, in horror, in panic, alarmedly, apprehensively, fearfully	fright, terror, horror, panic, dread, anxiety, apprehension, alarm, trepidation

2. 災害用詞⁹

關鍵字	同義詞	程度
Emergency	crisis, urgency, predicament, exigency, contingency	1
Disaster	misfortune, tragedy, adversity, debacle	2
Calamity	affliction, hardship, mishap, scourge	3
Cataclysm	upheaval, convulsion, devastation, deluge, meltdown	4
Catastrophe	ruin, annihilation, collapse, downfall, havoc	5

⁹ 該用詞及程度分級來源為 Caldera & Wirasinghe (2022)。


Apocalypse	armageddon, doomsday, extinction, end-time, Ragnarok	6
------------	--	---

3. 嚴重度用詞¹⁰

關鍵字	同義形容詞	同義副詞	同義名詞
Devastating 毀滅性的	desolating, wrecking, ravaging, crippling, obliterative, demolishing, collapsing, corrosive, scathing, fatal, ruin- inducing, heart- wrenching, disabling, earth-shattering, life- altering	brutally, tragically, fatally, mercilessly, relentlessly, hopelessly, irreparably, painfully, grievously, deplorably, savagely, cruelly, mournfully	wreckage, havoc, wreck, decimation, ravage, collapse, breakdown, meltdown, disintegration, ruination, upheaval, downfall, tragedy, desolation, grief
Extreme 極端的、非常嚴重的	severe, excessive, radical, utmost, intense, fierce, drastic, acute, outrageous, inordinate	severely, excessively, radically, acutely immensely, exceedingly, exceptionally, extremely, outrageously, unbelievably	extremity, excess, severity, intensity, brink, acuteness, polarization, strain, tension

¹⁰ 若同義詞中有較為中性、容易被誤用之詞彙，在指令 AI 時會特別提醒其注意上下文，避免誤判。

附錄三、AI 災害因子權重生成比較



項目	ChatGPT	Gemini
權重	F (死亡人數): 32% I (受傷人數): 24% P (財產損失): 26% D (持續時間): 18%	F (死亡人數): 45% I (受傷人數): 30% P (財產損失): 20% D (持續時間): 5%
段落位置加權	標題: 3 首段: 2 內文: 1	標題: 2 首段: 1 內文: 0
頻率衰減	對每個詞彙用 $\log(1 + \text{count})^{11}$ 轉換 類別得分 = 位置加權後的詞彙 頻率相加再做 log 衰減	無
計算方式	情緒總分: $E_{\text{total}} = E_{\text{shock}} + E_{\text{helpless}} + E_{\text{pain}} + E_{\text{fear}}$ (皆已含位置加權與 log 衰減)	情緒用詞 (B_emo): Shocking: 4 Helpless: 3 Pain: 4 Fear: 3
	災害總分: $Z_{\text{level}} = \log(1 + \sum(\text{level_coef} \times \text{position_weight}))$ (對每次匹配到的災害詞, 取其 所屬等級係數 $\times$ 位置權重, 最 後再做 log 衰減求和)	災害用詞 (B_dis): 依文獻的等 級 Emergency: 1 Disaster: 2 Calamity: 3 Cataclysm: 4 Catastrophe: 5 Apocalypse: 6
	嚴重度總分: $S_{\text{total}} = S_{\text{devastating}} + S_{\text{extreme}}$ (皆已含位置加權與 log 衰減)	嚴重度用詞 (B_sev): Devastating: 5 Extreme: 4
三大類詞彙對照到 F/I/P/D	情緒用詞: F (死亡): 受 Shock + Fear 影響 I (受傷): 受 Pain 影響 P (財損): 受 Helpless (無助/脆	我們計算在標題和首段中, 每一 類詞彙 (包含其所有同義詞) 的 總加權分數。

¹¹ 本附錄中提到的 log 皆指以 e 為底之自然對數 (natural logarithm)。

弱、求援) + Fear (恐慌性破壞
敘事) 影響

D(持續): 受 Helpless (持續無
力) + Fear (長期不安) 影響

情緒比例: 這類詞彙 (震驚、無
助、痛苦、害怕) 明顯指向人類
的苦難。因此, 將其權重全部分
配給 F (死亡) 和 I (受傷)。

災害用詞:

越高層級越偏向 F、P、D (系統
性、廣域、長期)

災害比例:

這類詞彙描述災害的整體性, 涵
蓋所有面向。因此, 我們將 其
權重分配到所有四個要素 (F, I,
P, D), 並依據它們的「基礎重要
性」進行分配。

嚴重度用詞:

Devastating 偏向 F 與 P

Extreme 偏向 I 與 D (緊急負荷
與延續性)

嚴重度比例:

這類詞彙 (毀滅性的、極端的、
破紀錄的) 主要描述災害的物理
規模和強度。因此, 我們將 其
權重全部分配給 P (財產損失)
和 D (持續時間)。
