



結合離心模型試驗、數值分析與人工智慧的風險評估方法—以淺基礎結構因液化引致之沉陷為例

國立中央大學土木工程學系特聘教授兼系主任 / 洪汶宜
國家實驗研究院國家地震工程研究中心副技術師 / 陳明景
國家實驗研究院國家地震工程研究中心副研究員 / 陳家漢
國立中央大學土木工程學系博士研究生 / 葛偉宸
國立中央大學土木工程學系博士候選人 / 杜志談

摘要

地震引致之土壤液化常造成高地下水位砂土層上淺基礎結構物的沉陷，而影響結構物的使用性與安全性。雖然離心模型試驗與數值模擬被廣泛應用於模擬液化引致沉陷的機制與行為，然而其應用仍受限於實驗設備、試驗材料、輸入參數範圍及電腦計算需求等因素。然而，隨著人工智慧的成熟發展，並為克服上述限制，本文介紹以整合離心模型試驗、三維數值分析模型與機器學習預測之整合式分析架構，用以評估淺基礎於地震作用下因液化引致的沉陷行為。首先以離心模型試驗結果校正並驗證採用 UBC3D-PLM 模式之數值模型模擬結果，隨後透過數值模

型進行參數分析，包括基盤輸入加速度振幅、基礎尺寸、地下水位、基礎與土壤接觸應力及土壤相對密度等參數，建立完整之參數化資料庫。基於數值模擬之資料集，建構隨機森林、人工神經網路及支援向量機模型進行淺基礎因液化引致沉陷的預測。模擬結果顯示，隨機森林與支援向量機模型具有較高之預測準確度，且特徵重要性分析指出尖峰基盤加速度與接觸應力為淺基礎沉陷行為之關鍵因子。本文所提出的混合式架構，係結合離心模型試驗、數值分析與人工智慧的風險評估方法，以液化地盤中淺基礎沉陷評估為例，作為快速且具成本效益之災害評估方法之一。



一、前言

地震是最具破壞力的天然災害之一，其成因源於地殼的板塊運動，亦常引發許多複合式災害，常造成大量人命傷亡、財產損失，並對國家基礎設施帶來嚴重的破壞。2023年發生之土耳其－敘利亞地震 [1]，包含兩次規模分別為 7.8 與 7.5 的強震，造成超過 50,000 人死亡，凸顯建構於高風險地盤之高密度人口城市在地震作用下的極端脆弱性。除了震動與地表變形以外，地震亦會造成其他土壤或土壤－結構間之不穩定行為，例如邊坡滑動 [2-4] 及土壤液化 [5-7] 等災害案例。其中，土壤液化被認為影響位於高地下水位砂土層上基礎設施最關鍵的災害之一，常導致土壤剪力強度與承載力迅速喪失。過去多起重大地震事件中，均記錄嚴重的液化致災案例 [8-11]，顯示其對建築物、管道系統、電力、電信、自來水系統及都市基礎設施與環境構成顯著的威脅。

為了評估民生基礎設施在地震作用下之穩定性，特別是具淺基礎之低樓層建築物，已有大量研究透過離心模型試驗探討地震引致之沉陷行為。離心模型試驗可重塑與現地相同的應力－應變環境，並模擬土壤－基礎受震時的互制機制、超額孔隙水壓生成與消散，以及液化條件下結構物沉陷發展過程等行為，在土木工程物理模型模擬中扮演了重要角色 [12-14]。然而，離心模型試驗受到設備、經費、試驗數量、試驗材料、邊界條件與簡化土層配置等因素，因此，進行離心模型試驗具有較高的門檻，而且為了模擬實際地盤條件的強度、滲透性等特性，在模型準備上需要反覆確認。然而，數值模型模擬

方法在工程上與研究上被廣泛使用作為輔助工具 [15-18]，經過數值模型驗證之後，透過系統化的參數分析，其優點在可以將數值模型模擬條件擴展至更廣泛的土壤性質、基礎幾何條件與地震載重情境，以進行土壤與結構物的行為預測。

儘管數值模擬具備高度彈性與效率，但是本構模型與輸入參數對不同個案之校正相當重要，限制其正規化應用與快速評估之實務價值。在此背景下，人工智慧 (AI) 提供了一項有潛力的方向，可輔助與補充傳統之物理模型－數值分析架構。透過以離心試驗驗證之數值模擬結果作為訓練資料集，AI 模型能有效納入地震特性、土壤條件、基礎條件與沉陷反應之間的高度非線性關係。此方法可大幅降低實體物理模型試驗與數值分析需求的同時，快速預測淺基礎之沉陷行為。本文介紹以淺基礎沉陷作為代表性之性能指標，驗證離心模型試驗－數值模擬－人工智慧混合架構之可行性，並作為未來延伸至其他地工構造物與土壤間互制行為預測奠定基礎。

二、離心模型試驗與數值模擬之驗證

2.1 離心模型試驗

離心模型依據圖 1 所示之配置準備，使用內部尺寸為長 711 mm × 寬 356 mm × 高 355 mm 的積層版試驗箱 (laminar container)，砂土表面下埋置 85 mm × 60 mm 與 125 mm × 85 mm 兩種不同長寬尺寸之淺基礎結構模型，在 80 倍人造地球重力場的試驗環境中，可分別模擬 6.8 m × 4.8 m 與 10.0 m × 6.8 m 的兩種現場基礎尺寸。

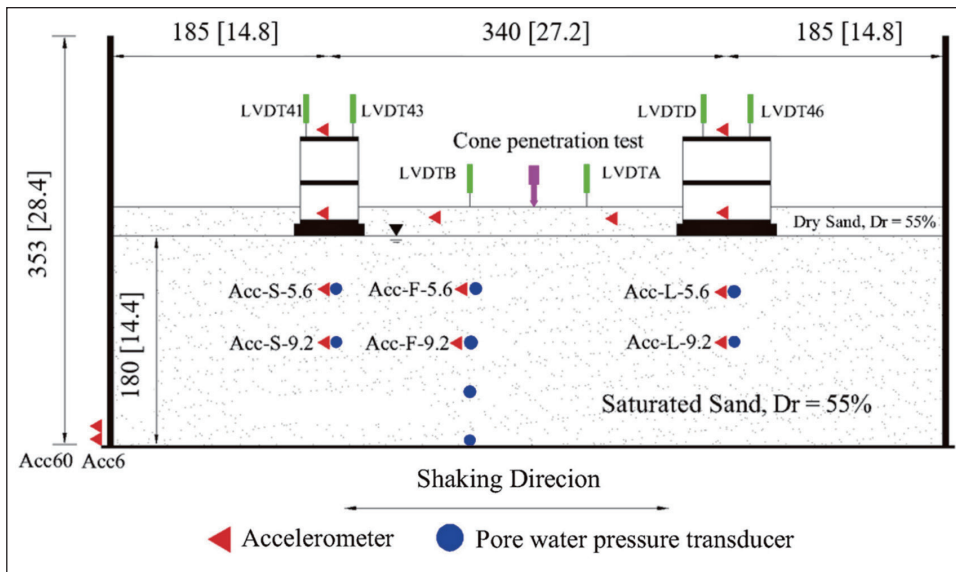


圖 1 離心模型配置剖面 (模型 [原型] (單位 : mm/m))


模型土層採用雙層砂土配置，下層為厚度 180 mm (現場 14.4 m) 之飽和砂土，相對密度為 55%；上層則為厚度 25 mm 之乾砂層 (現場 2.0 m)。地下水位受控並維持於地表下 25 mm (現場 2.0 m)。兩座淺基礎的結構模型以對稱方式配置，分別位於試驗箱中心左右各 170 mm，避免動態實驗時互相影響。

模型基礎下方之特定位置佈設加速度計與孔隙水壓感測器，分別用以量測土層中不同位置加速度反應與超額孔隙水壓激發與消散過程。此外，每一座結構模型上皆安裝線性位移計 (LVDT)，以記錄震動過程中結構之沉陷行為。

離心模型試驗中所使用石英砂最大與最小乾單位重分別為 16.48 kN/m³ 與 13.67 kN/m³，粒徑分佈介於 0.42 mm 至 0.074 mm 之間，平均粒徑 (d_{50}) 為 0.19 mm，均勻係數

(C_u) 為 1.78，曲率係數 (C_c) 為 1.05，比重 (G_s) 為 2.65，依據統一土壤分類法為不良級配砂 (SP)。所有離心模型之乾單位重為 15.09 kN/m³、相對密度 55%，所對應之砂土摩擦角依據直剪試驗結果為 31.05 度。


圖 2 示意離心模型之製備流程。首先於積層版試驗箱內鋪設橡膠囊袋，固定後施加真空使其緊密貼合內壁，接著使用灑降法 (pluviation) 進行砂土試體製作，控制對應之落砂高度確保相對密度為 55%，以分層方式進行灑砂，每層厚度約為 10 mm，並於過程中埋入加速度計與孔隙水壓感測器於預定深度位置。完成試體灑降後，將建築物模型埋置於設計之土壤深度位置，並建築物頂部配置四組線性位移計 (LVDT) 及兩組加速度計，量測試驗期間之沉陷行為與加速度反應。隨後，砂土模型以黏滯度約為水之 80 倍之黏性液體進行連續飽和處理，待模型完全飽和




(a) 基層板試驗箱與橡膠囊袋



(b) 加速度計與孔隙水壓計埋設



(c) 淺基礎結構物設置



(d) 離心模型試體支持準備

圖 2 離心機模型的製備

後，再將其吊放並固定於離心機平台上。完成離心模型試驗前之準備工作，以每 10g 為增量的人造地球重力場直至 80 倍重力場中進行試驗，並逐步輸入基盤尖峰加速度分別為 0.08g、0.18g 與 0.35g 之 15 週期的等振幅類正弦波，進行動態離心模型試驗並記錄相關之物理量，作為下一步數值模型之驗證。

2.2 數值模型模擬

本研究以 MIDAS GTS NX 與 PLAXIS3D 兩種不同的數值模擬軟體，使用 UBCSAND/UBC3D-PLM 模型並輸入離心模型試驗所使用之土壤性質參數進行模擬 [19-22]。數值模型行為係以非線性等向性定律加以描述，參數之定義如下：



$$K = k_B^{*e} p_r \left(\frac{p'}{p_r} \right)^{m_e} \quad (1)$$

$$G = k_G^{*e} p_r \left(\frac{p'}{p_r} \right)^{n_e} \quad (2)$$

其中， K 為彈性體積模數 (bulk modulus)， G 為彈性剪力模數 (shear modulus)， k_B^{*e} 為體積模數係數， k_G^{*e} 為剪力模數係數，而 p_r 為參考應力，取為 100 kPa。參數 m_e 與 n_e 用以描述材料剛度對應力狀態之相依程度，反映土體彈性剛度隨有效應力變化之非線性特性。

本研究採用 UBCSAND / UBC3D-PLM 模式模擬砂土於地震載重作用下之液化行為，此模式採用雙降伏面 (dual yield surface) 之架構，其中次降伏面所產生之塑性應變量小於主降伏面。主降伏面採用等向硬化 (isotropic hardening) 法則，而次降伏面則由簡化之動態硬化 (kinematic hardening) 法則進行控制。該模式能有效描述超額孔隙水壓之生成、材料剛度退化，以及液化後強度衰減等關鍵特性。

於主加載階段 (primary loading) 中，塑性剪力模數 k_G^p 取為使用者所輸入之初始設定值，並主導主降伏面之硬化行為；而在次加載階段 (secondary loading) 中， k_G^p 則被定義為載重循環次數之函數，以反映於排水循環剪力作用下所觀察到之土體緊實化效應。載重循環次數係依據加載與卸載過程中之應力反轉 (stress reversal) 加以判定。

此一數學形式使模型能合理重現非排水循環載重條件下，超額孔隙水壓隨循環次數逐步累積之行為特徵，且當土體狀態逐漸接

近液化時，其孔隙水壓之生成速率將呈現遞減趨勢。於次加載階段中，塑性剪力模數之修正關係可表示如下：

$$k_G^p = k_G^p \times \left(4 + \frac{n_{rev}}{2} \right) \times hard \times fac_{hard} \quad (3)$$


其中， n_{rev} 表示剪應力由加載轉為卸載，或由卸載轉為加載之反轉次數； $hard$ 為一修正係數，用以調整密實化法則於鬆砂條件下之適用性；而 fac_{hard} 則為使用者所輸入之倍率參數，用以調整整體密實化法則之強度。

數值模型之幾何配置與邊界條件係依據離心模型試驗之設定加以建立，包含土層分佈、基礎尺寸、地下水位以及載重條件等，使數值模型能忠實重現離心試驗之物理條件。UBCSAND 本構模式之參數則依據室內試驗結果與砂土之指標性質進行校正，包含相對密度、內摩擦角及單位重等。


動力分析中，透過於模型底部施加輸入地震加速度歷時 (如圖 3 所示) 以模擬基盤輸入加速度，同時於模型邊界配置適當之吸收邊界條件，以降低波動反射對分析結果之影響。為了觀察超孔隙水壓比、加速度反應及基礎沉陷 (圖 4)，在 MIDAS GTS NX 與 PLAXIS 中生成網格。隨後，將數值模擬結果與離心模型試驗測量值進行比較，以評估數值方法的有效性與預測能力。

2.3 模型驗證


為評估數值模型應用於參數化研究之適用性，首先將其模擬結果與離心模型試驗資



(a) PBA = 0.08g




(b) PBA = 0.17g




(c) PBA = 0.35g

圖 3 基底輸入地震動 (Acc6) 之加速度歷時曲線



(a) MIDAS GTS NX



(b) PLAXIS

圖 4 兩套軟體於液化模擬之網格劃分示意圖



料進行驗證比對 [23,24]。本研究將峰值地震加速度 (PBA) 為 0.35g 與 0.08g 的地震動輸入至 MIDAS GTS NX 與 PLAXIS 軟體中，並將數值分析結果與離心模型試驗結果進行比較。圖 5 與圖 6 顯示在 PBA = 0.08g 條件下離心模型試驗與數值模擬之間的比較結果，而較高地震強度 PBA = 0.35g 的對應比較則呈現在圖 7 與圖 8。上述驗證主要針對不同深度下之加速度反應與超額孔隙水壓 (EPWP) 的發展情形，觀測位置分別位於高

度 5.6 m、9.2 m，以及地震動輸入的基底位置。由加速度歷時可觀察到，離心試驗在較高位置呈現明顯之加速度衰減，且高頻成分迅速消散，反映出隨液化發展而產生之高阻尼效應與勁度退化現象。數值模擬結果能重現加速度反應之整體波形、相位特性及隨高度增加之衰減趨勢，惟模擬所得之加速度振幅略高且持續時間較長，顯示數值模型相較於實體模型呈現稍微偏硬之反應特性，未來可以進一步進行探討。

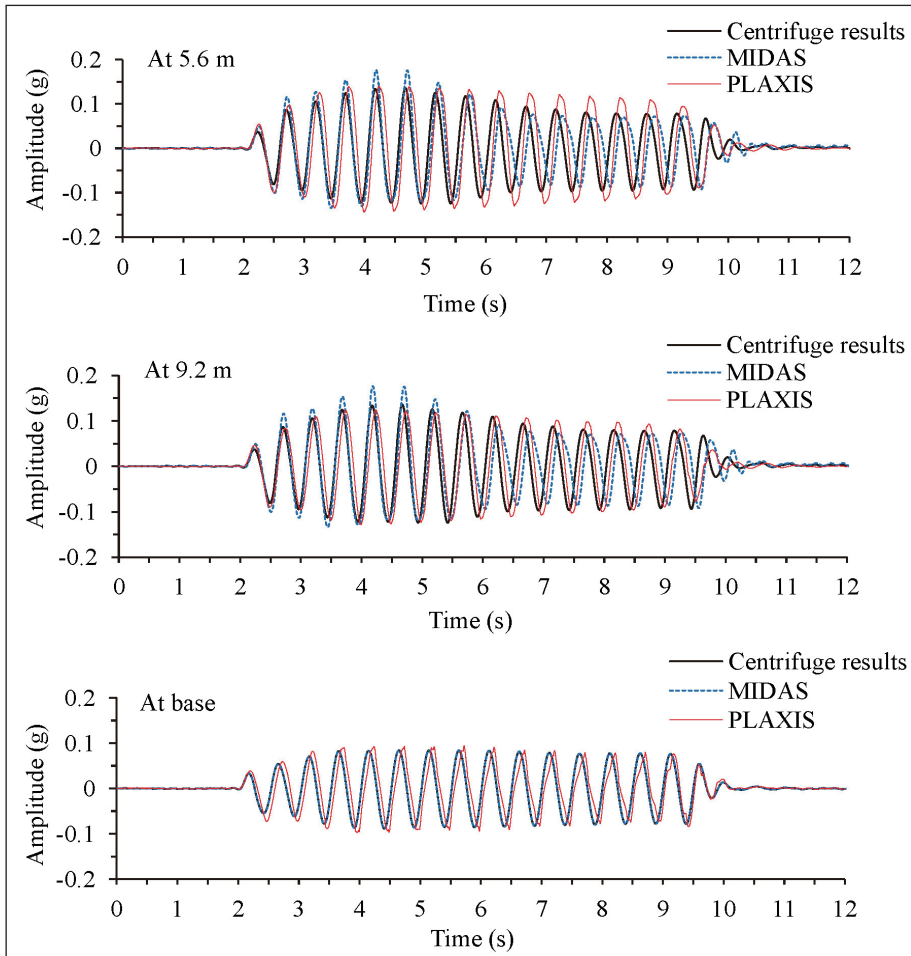


圖 5 數值模擬與離心模型試驗之加速度時程驗證 (PBA = 0.08g)

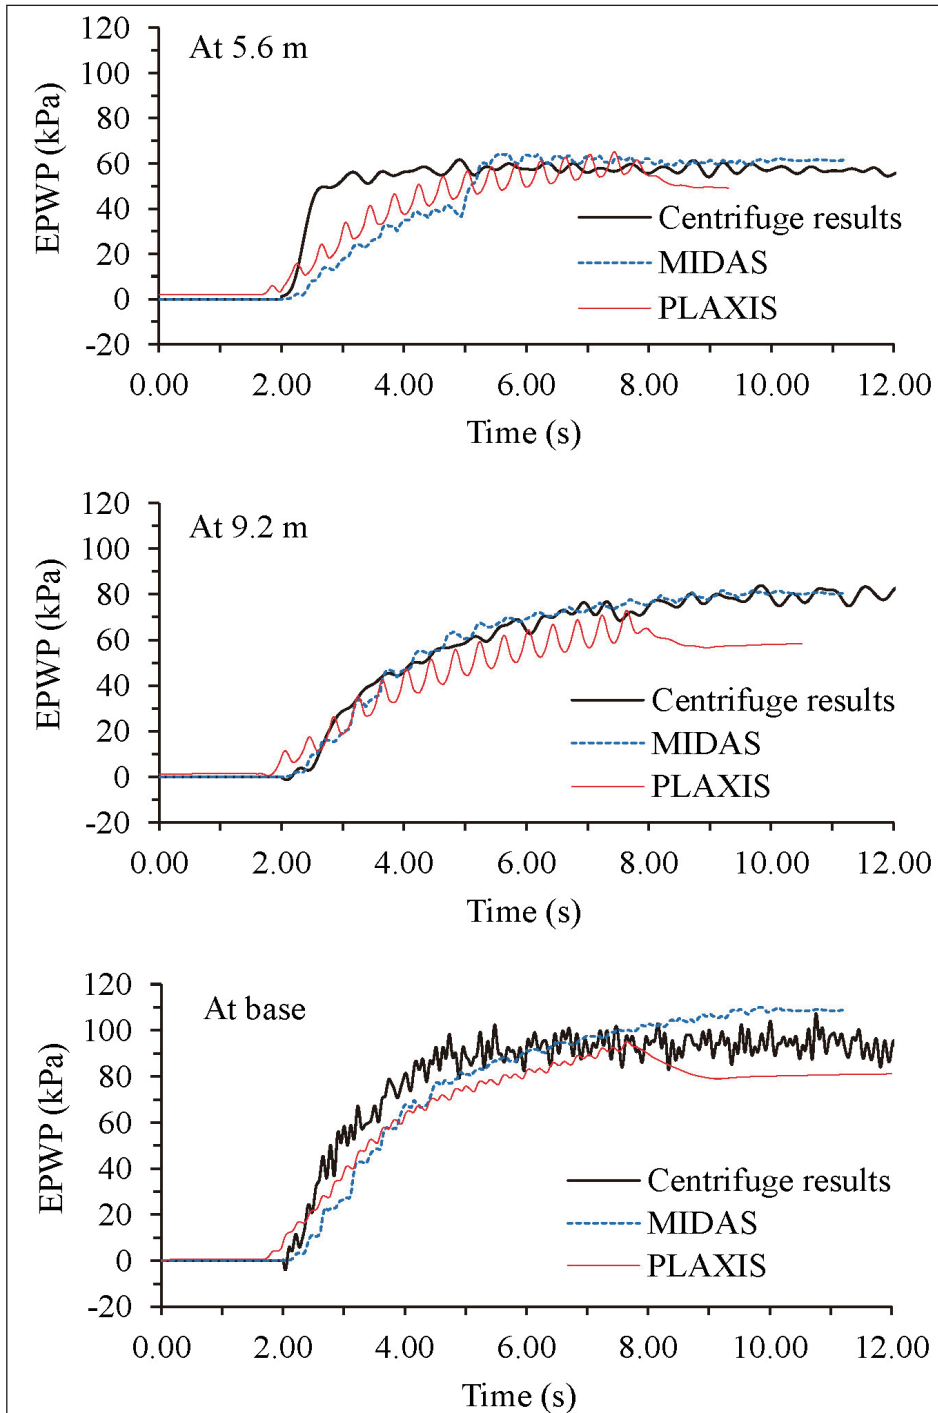


圖 6 不同土層深度超額孔隙水壓 (EPWP) 演化之驗證 (PBA = 0.08g)




圖7 數值模擬與離心模型試驗之加速度時程驗證 (PBA = 0.35g)

值得注意的是，EPWP 歷時結果在各高度位置上，無論在累積速率或最終數值方面，皆顯示出量測與模擬之高度一致性。數值模型能準確捕捉震動初期 EPWP 的快速上升，以及隨土體逐漸接近液化狀態時之穩定趨勢，同時亦合理反映 EPWP 隨高度增加而減小之行為。此一良好的一致性證實數值模型能可靠地描述控制土體軟化與能量消散之主要液化機制。

綜合而言，儘管在加速度振幅上仍存在一些微差異，數值模型在加速度反應趨勢上的一致重現，以及在 EPWP 演化行為上的高度吻合，顯示經校正後之數值模型已能充分掌握離心試驗中所觀察到之關鍵土體行為。因此，本研究認為該數值模型具備足夠之可靠性，可進一步應用於參數化研究，以探討各主控因子對液化誘發反應與基礎沉陷行為之相對影響。

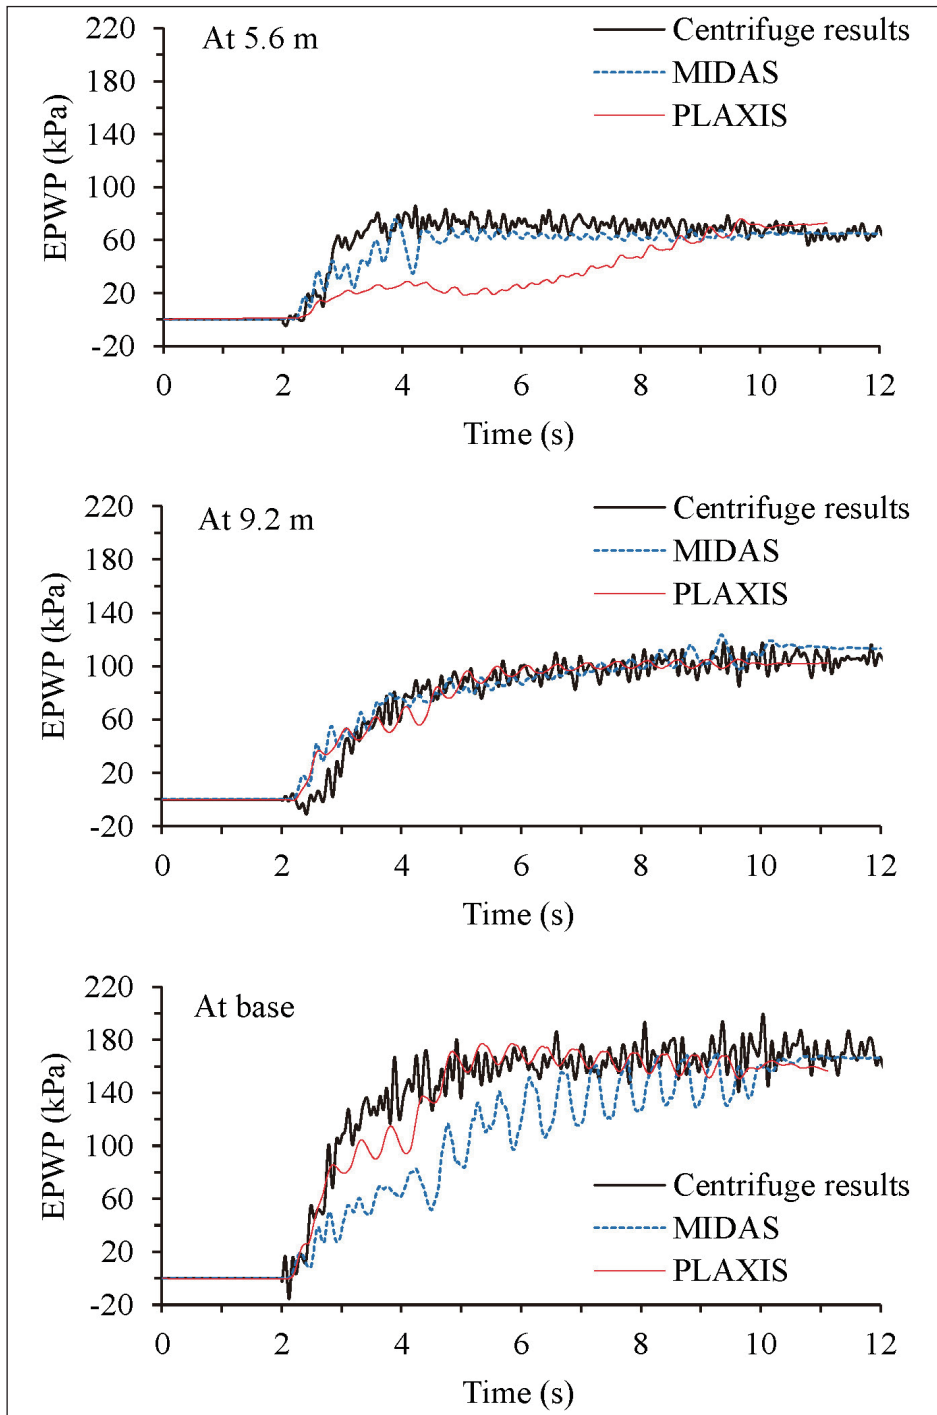


圖 8 不同土層深度超額孔隙水壓 (EPWP) 演化之驗證 (PBA = 0.35g)



三、數值模型參數研究

3.1 尖峰基盤加速度 (PBA) 對基礎行為之影響

為探討尖峰基盤加速度 (Peak Base Acceleration, PBA) 對淺基礎低樓層結構物沉陷行為之影響，本研究進行三組不同震動強度之試驗，其 PBA 分別為 0.08g、0.17g 與 0.35g。表 1 (編號 1-6) 總結了數值模型的初始條件，以及地震作用後基礎中心的沉陷量。

圖 9 顯示小型與大型基礎於不同震動強度下之沉陷反應。試驗結果顯示，小型基礎 (SL-6.8 × 4.8 m) 之沉陷量隨震動強度增加而逐步上升，於 PBA 為 0.08g、0.17g 與 0.35g 時，其沉陷量分別為 0.031 m、0.060 m 與 0.110 m。相同地，大型基礎 (LF-10.0 × 6.8 m) 於相同輸入地震動條件下之沉陷量分別為 0.034 m、0.070 m 與 0.140 m。上述結果清楚顯示，在輸入地震動頻率維持不變之情況下，基礎沉陷量會隨 PBA 的增加而顯著提升。然而，於強震情境 (PBA = 0.35g) 下，兩種不同基礎尺

表 1 數值模擬初始條件及地震作用後基礎中心沉陷量

Test No.	Foundation size (m)	Relative density (%)	PBA (g)	Water level (m)	Impact pressure (kPa)	Settlement after shaking (m)	
							Plaxis
1	6.8 × 4.8	55%	0.08	-2	71	0.024	0.031
2			0.17			0.076	0.060
3			0.35			0.087	0.110
4	10.0 × 6.8		0.08			0.041	0.034
5			0.17			0.087	0.070
6			0.35			0.135	0.140
7	6.8 × 4.8		71	0.17	-2	0.076	0.060
8	10.0 × 6.8					0.087	0.070
9	15.0 × 10.2					0.095	0.071
10	10.0 × 6.8			0.35	-2	0.135	0.140
11					-4	0.101	0.082
12	10.0 × 6.8			0.35	-2	71	0.135
13		152	0.250			0.240	
14		6.8 × 4.8	0.35			-2	71
15	152			0.216	0.210		
16	6.8 × 4.8	75%	0.08	-2	71	0.010	0.009
17			0.17			0.018	0.014
18			0.35			0.102	0.096
19	10.0 × 6.8		0.08	-2	71	0.012	0.009
20			0.17			0.019	0.014
21			0.35			0.130	0.118




圖 9 不同 PBA (g) 下 SF 和 LF 的沉陷狀況

寸之沉陷差異明顯放大；相較之下，在較低震動強度（0.08g 與 0.17g）時，兩種基礎所呈現之沉陷量則相對接近。此一現象顯示，在強震條件下，淺基礎尺寸對因地震引致液化的結構物沉陷行為之影響更為顯著。

3.2 相同地震條件下基礎尺寸對基礎行為之影響

本節透過三組不同基礎尺寸之數值模型，探討基礎寬度對沉陷行為之影響。圖 10 顯示，




圖 10 不同尺寸基礎的沉陷情況

沉陷量隨深度增加而逐漸減小，且主要集中於上部土層中。當基礎寬度分別為 6.8 m、10.0 m 與 15.0 m 時，其最大沉陷量分別為 0.063 m、0.070 m 與 0.071 m。分析結果顯示，較小之基礎寬度通常對應較小之沉陷量；然而，沉陷行為同時亦受地震震重條件所控制，且在特定震動事件下，沉陷量似乎存在一個上限值。在相同地震條件（PBA = 0.17g）及地下水位（-2 m）下，當基礎寬度由 10.0 m 增加至 15.0 m 時，其沉陷量並無明顯之增加，顯示基礎尺寸對結構物因液化沉陷行為之影響，在超過某一臨界基礎寬度後將趨於遞減。

3.3 相同地震條件下地下水位對基礎行為之影響

圖 11 顯示在相同基礎輸入加速度條件（PBA = 0.35g）下，不同地下水位條件（地下水位分別位於 2 m 與 4 m）時，大型基礎（LF）、小型基礎（SF）及自由場（FF）三種情境之沉陷隨深度分佈情形。於地下水位




圖 11 顯示了在兩種地下水位條件（水位分別為 2 公尺和 4 公尺）下，受到 0.35g 振動作用時的沉陷情況



較淺之條件（地下水位 2 m）下，大型基礎之地表最大沉陷量約為 0.14 ~ 0.15 m，顯著大於小型基礎之 0.10 ~ 0.11 m，亦遠高於自由場之 0.05 ~ 0.06 m。此結果顯示，在高地下水位條件下，基礎尺寸對地震液化引致沉陷行為具有明顯之放大效應。

當地下水位降低至 4 m 時，所有情境之沉陷量皆呈現顯著下降趨勢。大型基礎之地表沉陷量降低至約 0.09 ~ 0.10 m，小型基礎降至 0.06 ~ 0.07 m，而自由場則僅為 0.02 ~ 0.03 m，且整體沉陷曲線皆逐漸減小。此一沉陷量之降低反映出較低地下水位下，地表附近土層之超額孔隙水壓生成減少，並伴隨有效應力之提高，進而提升土壤之抗變形能力。

3.4 相同地震條件下接觸應力對基礎行為之影響

圖 12 顯示在強震作用（PBA = 0.35g）下，不同接觸應力條件（71 kPa 與 152 kPa）




圖 12 顯示在強烈震動條件（PBA = 0.35g）下，不同接觸應力水準（71 kPa 與 152 kPa）時，大型基礎（LF）、小型基礎（SF）及自由場（FF）三種情境之沉陷隨深度分佈情形

kPa）時，大型基礎（LF）、小型基礎（SF）及自由場（FF）之沉陷分佈情形。對於兩種基礎尺寸而言，當接觸應力由 71 kPa 增加至 152 kPa 時，基礎下方之沉陷量皆呈現顯著增加，由約 0.14 m 提升至 0.24 m。當接觸應力增加一倍時，最大沉陷量亦接近倍增，顯示在強震作用下，地震液化引致沉陷行為係受到靜載重與動力載重共同作用影響。

相較之下，位於相鄰基礎之間之自由場土體，在較高接觸應力條件下所呈現之震後沉陷反而較小。此一行為可歸因於重載基礎所引致之側向圍束壓力增加，進而抑制循環剪應變之發展，並限制周圍土體中超額孔隙水壓之生成。因此，自由場區域之土體剛度退化程度降低，使其累積沉陷量相較於低接觸應力情境更為有限。

3.5 土壤相對密度對基礎沉陷行為之影響

砂土之相對密度對結構物之沉陷行為具有顯著影響，為探討此一影響，本研究針對相對密度為 75% 之密砂條件進行一系列數值模擬分析，並參考 James Barron 等人所提出之研究案例 [25]。數值分析中所採用的本構參數彙整如表 2 所示，分別對應於鬆砂（相對密度 $D_r = 55\%$ ）與密砂（相對密度 $D_r = 75\%$ ）。

輸入參數係利用 LEAP-UCD-2017 計畫所提供之既有實驗資料進行驗證，並採用兩種相互補充之方法：其一為採用 UBC3D-PLM 本構模式之數值模擬分析，其二為於國立中央大學進行之離心模型試驗。此一



表 2 數值模型輸入參數

Parameters	Dr = 55 %	Dr = 75 %
Peak friction angle, ϕ_p (degree)	31	39.0
Elastic bulk modulus factor, k_B^{*e} (kPa)	600	670
Elastic shear modulus factor, k_G^{*e} (kPa)	650	800
Plastic shear modulus factor, k_G^{*p} (kPa)	650	1600
Elastic bulk index, m_e	0.5	0.5
Elastic shear index, n_e	0.5	0.5
Plastic shear index, n_p	0.4	0.4
Reference pressure, P_r (kPa)	100	100
Tension cut off, σ_t (kPa)	0	0
SPT value, $(N1)_{60}$	10	25.9

結合數值模擬與物理試驗之驗證架構，確保在地震載重作用下，數值預測結果與實際量測之土－結構互制反應具有良好之一致性。在不同相對密度條件下，基礎沉陷行為呈現明顯差異；相較於低相對密度砂土，高相對密度砂土所產生之沉陷量顯著較小，如圖 13 所示。此結果顯示，隨著相對密度提高，砂土之抗液化能力與循環剪切剛度隨之增加，進而有效抑制地震作用下之沉陷發展。




圖 13 不同相對密度條件下之沉陷行為

四、人工智慧的預測分析

4.1 機器學習 (ML) 方法

4.1.1 隨機森林 (Random Forest, RF)

隨機森林 (Random Forest, RF) 是一種集成式學習 (ensemble learning) 演算法，透過整合多棵決策樹之預測結果，以提升模型之準確性與穩健性。RF 的核心原理建立於袋裝法 (bagging, bootstrap aggregating) 之上，即每一棵決策樹皆以原始資料集中隨機抽樣 (含重複抽樣) 所形成之子資料集進行訓練；同時，在每一節點分裂時，亦隨機選取部分輸入特徵作為候選變數。此雙重隨機機制可有效降低各決策樹之相關性，進而抑制過度擬合並提升模型之泛化能力。

在迴歸問題中，最終預測結果通常係透過對所有決策樹輸出值進行平均而獲得。由於隨機森林能在不需對資料分佈作出強假設之情況下，有效捕捉高度非線性關係及變數



間之交互作用，因此已被廣泛應用於各類工程與科學研究領域中 [27]。

4.1.2 人工神經網路 (Artificial Neural Network, ANN)

人工神經網路 (ANN) 為一種受人類大腦結構與運作機制所啟發之計算模型，其由多個相互連結之處理單元 (神經元) 所組成，並依序排列為輸入層、隱藏層與輸出層。每一神經元會對其輸入訊號進行加權求和，並透過非線性激活函數進行轉換，使整體網路具備學習輸入與輸出之間複雜非線性對應關係的能力。於訓練過程中，ANN 透過反向傳播 (backpropagation) 等學習演算法反覆調整連結權重，以最小化預測誤差。

由於 ANN 具備高度彈性與通用逼近能力 (universal approximation capability)，其已被廣泛應用於各類迴歸與分類問題，特別適用於變數間難以建立明確解析關係之情境，並於多個工程與科學領域中展現良好成效 [28]。

4.1.3 支援向量機 (Support Vector Machine, SVM)

支援向量機 (SVM) 為一種監督式學習演算法，其核心目標在於於高維特徵空間中，透過最大化資料點間之間隔 (margin)，以尋找最佳之決策函數。SVM 之基本概念係利用核心函數 (kernel functions) 將原始輸入資料映射至高維空間，使原本於低維空間中無法線性分離之非線性問題，得以在線性超平面下加以處理。

針對迴歸問題，SVM 採用 ϵ 不敏感損失函數 (ϵ -insensitive loss function)，允許預測值在指定容許範圍內之偏差而不予懲罰，並僅對超出該範圍之誤差進行處理。透過僅依賴少數關鍵資料點 (支援向量) 建立模型，SVM 能有效提升泛化能力並降低過度擬合之風險。基於其理論基礎及處理非線性關係之優異表現，SVM 已廣泛應用於各類科學與工程領域中 [29]。

4.2 以相關性為基礎之特徵重要性分析 (Correlation-Based Feature Importance, CFI)

為提升所提出機器學習模型之可解釋性，並量化各輸入參數對基礎沉陷預測之影響程度，本研究採用以相關性為基礎之特徵重要性分析方法 (CFI)。CFI 係透過皮爾森相關係數 (Pearson correlation coefficient, ρ)，評估各輸入特徵與預測沉陷反應 (s) 之間的線性關係強度。其相關係數之計算方式如下：

$$\rho = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2} \sqrt{\sum (Y_i - \bar{Y})^2}} \quad (4)$$

ρ 之絕對值代表該特徵對沉陷預測之相對影響程度，數值越大表示其影響越顯著；正值與負值則分別代表正相關與負相關關係。透過 CFI 分析，可有效辨識主控沉陷行為之關鍵因子，並作為後續風險評估與工程設計參考之依據。其中， x_i 與 y_i 分別代表第 i 筆資料中之輸入變數值與對應之預測輸出值； \bar{x} 與 \bar{y} 則分別為輸入變數與輸出變數之平均值。皮爾森相關係數 ρ 的取值範圍介於 -1 至 $+1$ 之



間，其中數值接近 ± 1 表示兩變數之間具有高度線性相關性，而數值接近 0 則代表線性相關性較弱或幾乎不存在。

本研究將 CFI 方法應用於評估基礎沉陷預測結果對六項關鍵輸入參數之敏感程度，分別為基礎寬度 (B)、基礎長度 (L)、相對密度 (D_r)、尖峰基盤加速度 (PBA)、地下水位 (z_w) 以及施加之接觸應力 (q)。透過皮爾森相關係數之絕對值大小，對各輸入參數之相對重要性進行排序，以辨識主導沉陷行為之關鍵因子。此一分析不僅提升模型之透明度，亦能加深對輸入參數物理意義之理解，進而為地震載重條件下之大地工程設計與決策提供更具依據之參考。

4.3 模型效能評估指標

為嚴謹評估所提出機器學習模型之預測效能，本研究採用一組以迴歸分析為基礎之評估指標，從準確性、穩健性與泛化能力等層面，全面檢視模型在基礎沉陷 (S) 預測上的表現。所選用之評估指標兼顧統計意義與工程實務解釋性，以提供均衡且具代表性之模型效能評估。

決定係數 (coefficient of determination, R^2) 用以量化模型預測結果對實測沉陷變異之解釋能力，其中數值愈接近 1，表示預測值與實測值之間具有越高的一致性。此外，本研究採用平均絕對誤差 (mean absolute error, MAE) 作為衡量預測誤差平均幅度之指標，其具備良好之直觀性，且對極端值 (outliers) 較不敏感。另計算均方根誤差 (root mean squared error, RMSE)，以加重較大預測偏差

之影響，並將誤差以與沉陷量相同之物理單位表示，利於工程應用與解釋。

所有效能評估指標皆分別針對訓練資料集與測試資料集進行計算，以檢驗混合式模型之泛化能力，並確認其於未曾參與訓練之資料上仍能維持良好之預測準確性。各項評估指標之數學定義彙整如式 (5) 至式 (7) 所示。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (7)$$

於上述數學式中， y_i 代表實際量測 (觀測) 值，而 \hat{y}_i 則為模型所預測之對應數值； \bar{y} 表示所有觀測值之平均值， n 為資料樣本之總數。

圖 14 說明本研究所採用之整體方法論流程，涵蓋資料生成、模型建構與效能評估等主要步驟。首先，將數值模擬所建立之資料集隨機分割為訓練資料集與測試資料集，接著分別建立並反覆優化隨機森林 (RF)、人工神經網路 (ANN) 及支援向量機 (SVM) 模型，以降低預測誤差並提升模型之泛化能力。完成模型建構後，透過標準誤差指標、預測值與觀測值之對比分析、特徵重要性評估，以及 Taylor 圖之視覺化方式，全面檢視模型之預測效能與可解釋性。此一整合式分析架構為後續結果之呈現與討論提供了清晰且一致之基礎。

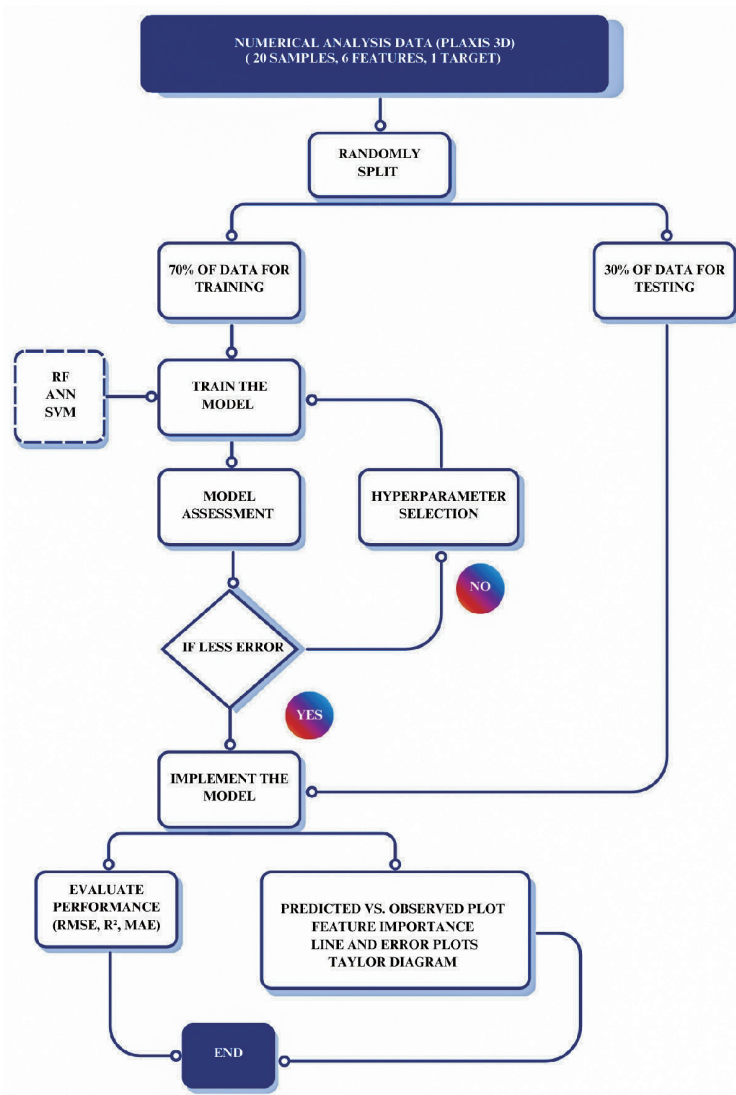


圖 14 方法流程圖

4.4 機器學習 (ML) 之結果與討論

本研究採用網格搜尋 (grid search) 作為超參數最佳化策略，以系統化方式辨識各機器學習模型之最佳參數組合，透過對預先定義之超參數組合進行全面評估，並選取能最

小化預測誤差之設定，此方法確保了隨機森林 (RF)、人工神經網路 (ANN) 及支援向量機 (SVM) 模型之間具備客觀且一致的比較基準。因此，表 3 至表 5 所彙整之最佳化超參數可視為最適用於本研究沉陷資料集之模型設定。



表 3 隨機森林 (RF) 模型之最佳化超參數

Hyper-parameter	Optimized Value
max_depth	None
max_features	None
min_samples_leaf	1
min_samples_split	2
n_estimators	600

表 4 人工神經網路 (ANN) 模型之最佳化超參數

Hyper-parameter	Optimized Value
activation	tanh
alpha	0.01
hidden_layer_sizes	(8,)
learning_rate_init	0.001

表 5 支援向量機 (SVM) 模型之最佳化超參數

Hyper-parameter	Optimized Value
C	10
epsilon	0.01
gamma	scale
kernel	RBF

就隨機森林模型而言，未對樹深度加以限制，且於每一節點分裂時採用所有輸入特徵，顯示模型可藉由高度結構彈性以有效捕捉大地工程變數之間的非線性交互作用。大量決策樹 ($n_{estimators} = 600$) 之配置有助於降低模型變異性，進而提升預測穩定性；同時，節點分裂條件之限制較少 ($minsamples_split = 2$ 、 $minsamples_leaf = 1$)，使模型能更貼近

局部資料特徵進行學習。上述設定整體反映出 RF 模型善於運用集成學習架構，以達成穩健之沉陷預測能力。

對於 ANN 與 SVM 模型而言，其最佳化超參數則顯示出在學習能力與過度擬合控制之間的平衡考量。ANN 採用單一隱藏層之淺層網路架構，並使用 tanh 激活函數，同時結合 L2 正則化項 (alpha) 與較小之學習率，以因應資料量有限之情況並確保訓練過程之穩定收斂。另一方面，SVM 模型則選用徑向基底函數 (RBF) 核心，搭配中等懲罰參數 (C) 與較小之 ϵ - 不敏感區間，使模型能對沉陷反應之細微變化保持敏感，同時維持平滑且穩定之迴歸行為。

整體而言，經最佳化後之超參數配置顯示，三種機器學習模型皆已依據本研究所建立之「資料量有限但行為高度非線性」之數值資料集特性加以調整，並具備有效學習沉陷行為之能力，為後續預測結果與比較分析奠定良好基礎。

表 6 彙整了所建立之隨機森林 (RF)、人工神經網路 (ANN) 及支援向量機 (SVM) 模型，在訓練資料集與測試資料集上之預測效能表現，評估指標包含 R^2 、RMSE 與 MAE。整體而言，RF 與 SVM 模型展現出較

表 6 機器學習模型之預測效能評估結果

Parameter	RF		ANN		SVM	
	Training	Testing	Training	Testing	Training	Testing
R^2	0.976	0.961	0.679	0.719	0.981	0.922
RMSE	0.009	0.010	0.036	0.029	0.008	0.015
MAE	0.007	0.009	0.022	0.023	0.008	0.012



佳之預測準確性，其較高之 R^2 值與較低之誤差指標顯示預測沉陷結果與實測資料之間具有高度一致性。

其中，RF 模型在訓練與測試資料集上皆維持穩定且優異之表現，顯示其具備良好之泛化能力與預測穩健性。SVM 模型則在訓練階段呈現最高之 R^2 值，且於測試資料集上仍維持相對較低之誤差水準，顯示其在處理非線性迴歸問題時具有良好之適應能力。相較之下，ANN 模型之 R^2 值較低，且誤差指標相對偏高，顯示在目前資料量條件下，其學習效率與預測表現較為受限。綜合上述結果可知，於本研究之沉陷預測問題中，集成式模型 (RF) 與核心函數式模型 (SVM) 較人工神經網路更為適用，能更有效捕捉複雜之非線性土 - 結構互制行為。

圖 15 顯示 PLAXIS 3D 數值模擬結果與對應之機器學習模型預測結果之關係，並分別呈現於訓練資料集與測試資料集上。對於隨機森林 (RF) 與支援向量機 (SVM) 模型而言，多數資料點皆緊密分佈於 $Y = X$ 參考線附近，尤以訓練資料集之表現最為明顯，顯示模型預測之沉陷量與數值模擬結果之間具有高度一致性。此種高度聚集之分佈型態反映出 RF 與 SVM 模型能有效捕捉沉陷行為之主要控制機制。

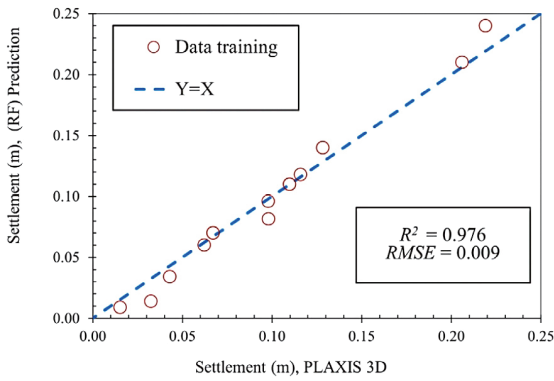
相較之下，人工神經網路 (ANN) 模型之預測結果呈現較為分散之分佈，特別是在訓練資料集中，顯示其配適能力相對較弱。整體而言，資料點與 $Y = X$ 參考線之接近程度進一步驗證 RF 與 SVM 模型在沉陷預測

上的可靠性，且於訓練與測試資料集中皆展現一致之預測趨勢，顯示其具備良好之泛化能力。


圖 16 綜合呈現實際沉陷值與各模型預測結果之比較，並同時顯示其對應之絕對誤差。由折線圖可觀察到，隨機森林 (RF) 與支援向量機 (SVM) 模型之預測結果在多數樣本中能緊密追隨實際沉陷變化趨勢，顯示其與數值模擬結果具有高度一致性。相較之下，人工神經網路 (ANN) 模型於部分樣本索引位置出現較明顯之偏差，且此現象於下方所示之誤差分佈中，以較大的誤差幅度進一步突顯。

誤差分析結果顯示，RF 模型在整體樣本中皆能維持最小之預測誤差，展現出最佳且穩定之預測效能；SVM 模型則呈現與 RF 相近之預測準確度，但其誤差變異性略高。整體而言，此結果再次驗證 RF 與 SVM 模型在沉陷預測方面之可靠性與優越性。

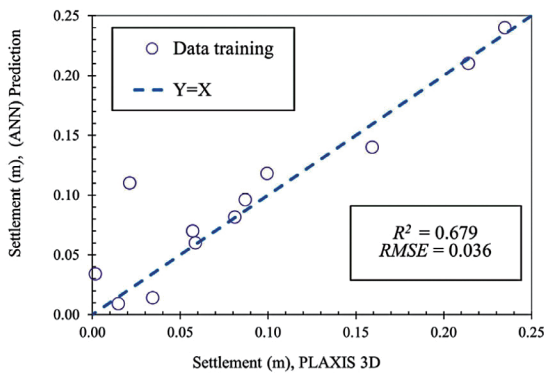
圖 17 透過 Taylor 圖比較隨機森林 (RF)、支援向量機 (SVM) 與人工神經網路 (ANN) 模型之預測效能，該圖同時考量預測結果相對於參考資料之相關係數與標準差。由圖中可觀察到，RF 模型最接近參考點，代表其具有最高之相關性及最佳之變異一致性，顯示其預測表現最為準確且穩定。SVM 模型之表現與 RF 相近，但相較之下與參考點仍存在些微偏離，顯示其預測準確度略為降低。相對而言，ANN 模型距離參考點最遠，反映其相關性較弱且預測結果之離散程度較高。



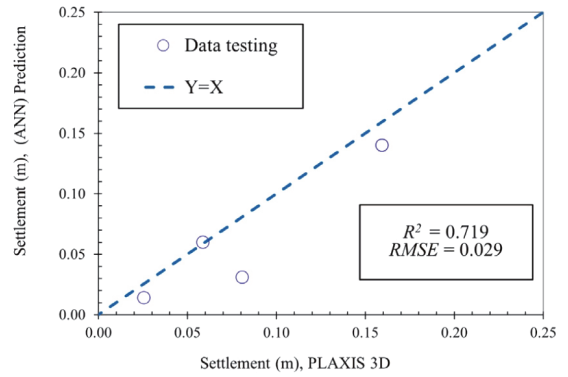
(a) RF 訓練資料集




(b) RF 測試資料集



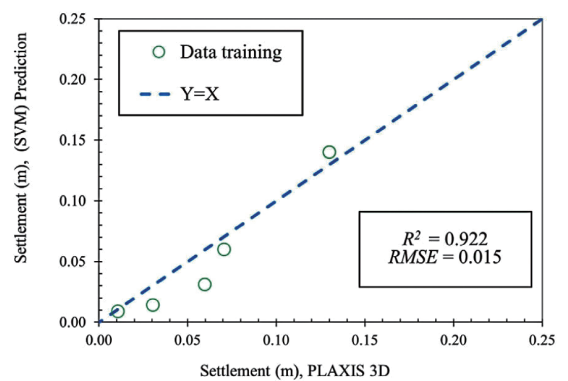
(c) ANN 訓練資料集



(d) ANN 測試資料集



(e) SVM 訓練資料集



(f) SVM 測試資料集

圖 15 PLAXIS 3D 數值模擬結果與機器學習預測結果之比較

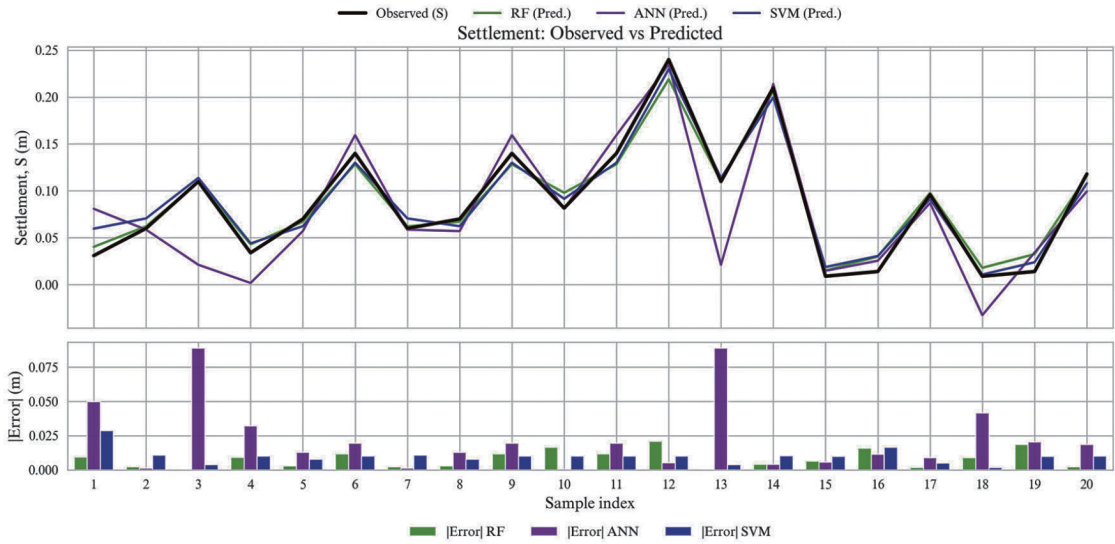


圖 16 機器學習模型之預測效能表現（以折線圖與誤差圖呈現）

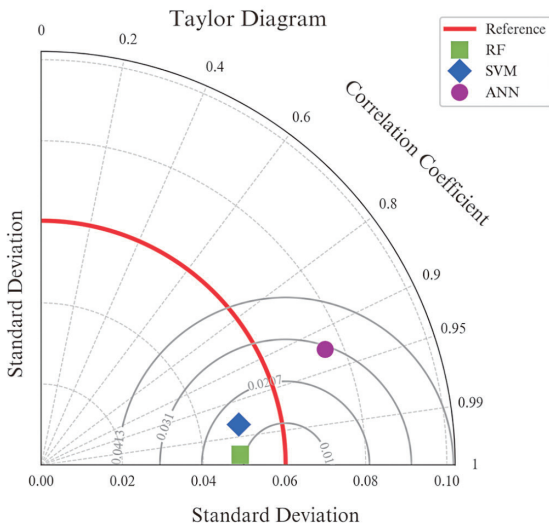


圖 17 Taylor 圖比較結果

整體而言，Taylor 圖之比較結果進一步驗證，在本研究所探討之沉陷預測問題中，隨機森林模型相較於 SVM 與 ANN，能提供最為可靠且穩定之預測成果。

表 7 彙整了根據 PLAXIS 3D 數值模擬結果以及三種機器學習模型所計算之、以相關性為基礎的沉陷特徵重要性分析結果。整體而言，尖峰基盤加速度（PBA）與接觸應力（ q ）在所有分析方法中皆一致呈現為最具影響力之變數，占據最高之重要性比例，凸顯地震載重強度與上覆壓力對沉陷反應所扮演之主導角色。相對密度（ D_r ）則展現中等程度之貢獻，反映土體狀態對變形行為之影響。

表 7 基於相關性之沉陷特徵重要性分析結果（PLAXIS 3D 與機器學習模型）

	Settlement (m)			
	PLAXIS 3D (%)	RF (%)	ANN (%)	SVM (%)
PBA	35.2	36.0	30.6	36.4
q	31.4	32.4	32.5	34.2
D_r	20.0	19.3	18.3	22.8
B	6.2	5.3	9.2	3.1
L	6.2	5.3	9.2	3.1
z_w	1.0	1.7	0.2	0.4



相較之下，基礎尺寸參數（基礎寬度 B 與基礎長度 L ）之重要性較低，僅於 ANN 模型中顯示出略高之敏感性；而與地下水相關之參數（ z_w ）在所有方法中之貢獻皆相對有限。PLAXIS 3D 與各機器學習模型於特徵重要性排序上之高度一致性，顯示所建立之模型能成功捕捉控制沉陷行為之關鍵物理趨勢。

整體而言，研究結果顯示隨機森林（Random Forest, RF）模型在沉陷預測方面具有最佳之整體表現，展現出較高之預測準確度、穩定性，以及與數值模擬參考結果之高度一致性。然而，需特別指出的是，模型效能本質上仍高度依賴於訓練資料集之規模與多樣性；當資料庫進一步擴充且涵蓋更廣泛之地盤與載重條件時，不同機器學習模型之相對準確度與表現排序仍可能有所改變。因此，本研究之主要目的在於展示機器學習方法應用於大地工程沉陷預測問題之可行性與潛力，而非宣稱某一單一模型具有絕對之優越性。

此外，所建立之預測模型亦進一步應用於回推（back-check）數值模擬結果，以驗證其預測效能。分析中考慮四種不同地下水位之情境，而相對密度（55%）、尖峰基盤加速度（0.17g）及接觸應力（71 kPa）則維持不變，其對應條件與結果彙整列於表 8 與表 9。

五、結論與建議

整體而言，離心模型試驗與數值模擬為土木工程，特別是大地工程研究中極為重要且有效之模擬工具。然而，當需進行大量試驗以建立具代表性與可靠性之基準資料時，兩者皆伴隨高昂之時間與經費成本，且對於缺乏完善設備或資源之研究機構而言，實務上亦存在相當限制。隨著人工智慧於現代科學與工程領域之快速發展，提供了一項可有效因應上述限制之新契機。透過導入 AI 為基礎之方法，可在既有資料庫所涵蓋之相似邊界條件下，快速進行模型評估與預測，而無須反覆執行成本高昂之

表 8 數值模擬結果與人工智慧（AI）預測結果之比較

Test No.	Foundation size	Water level (m)	Settlement - numerical modeling (m)	AI prediction (m)		
				RF	ANN	SVM
1	6.8 × 4.8	-2.5	0.057	0.062	-0.243	0.076
2	6.8 × 4.8	-3.0	0.056	0.062	-0.345	0.087
3	10.0 × 6.8	-2.5	0.062	0.067	-0.140	0.067
4	10.0 × 6.8	-3.0	0.060	0.067	-0.216	0.078

表 9 數值模擬結果與預測結果之誤差比較

Test No.	Foundation size	Water level (m)	RF	SVM	RF-Error (%)	ANN-Error (%)
1	6.8 × 4.8	-2.5	0.062	0.076	8.1	25
2	6.8 × 4.8	-3.0	0.062	0.087	9.7	35
3	10.0 × 6.8	-2.5	0.067	0.067	7.5	7.5
4	10.0 × 6.8	-3.0	0.067	0.078	10.4	23



實體試驗或數值分析。因此，人工智慧為加速分析流程並降低試驗與計算成本，提供了一條兼具實用性與效率之可行途徑。

本研究整合 PLAXIS 3D 數值模擬結果與資料驅動模型，驗證機器學習技術於地盤沉陷預測問題上之適用性。研究中建構並系統性最佳化三種常見之機器學習演算法，包括隨機森林 (RF)、人工神經網路 (ANN) 及支援向量機 (SVM)，並採用網格搜尋法進行超參數調校。透過多項效能指標、預測與觀測值之對比、誤差分析以及 Taylor 圖之綜合評估結果顯示，RF 模型在預測準確度與穩定性方面表現最佳，其次為 SVM，而 ANN 在本研究資料條件下之表現相對較弱。特徵重要性分析進一步證實，所建立之模型能成功捕捉控制沉陷行為之主要物理因子，尤其為地震載重強度與接觸應力之影響。

除預測準確性外，所提出之機器學習架構在工程實務應用上亦具顯著優勢。相較於反覆執行複雜之有限元素數值分析，該方法可大幅降低計算時間與資源需求；模型一經訓練完成，即可即時提供預測結果，無須重新進行耗時之數值模擬。此外，所建立之模型可透過調整輸入參數直接應用於不同情境，避免重新建構數值模型之繁複流程。此等特性顯示，機器學習模型具備作為沉陷評估之高效率、易操作替代工具之潛力，有助於支援工程決策與風險評估。

儘管本研究所採用之資料集規模仍有限，研究結果已清楚展現機器學習方法整合於大地工程分析中之可行性與應用潛力。未來若能納入更大且更具多樣性之資料庫，預

期將可進一步提升模型之穩健性與預測能力，並拓展其於實務工程中之應用範圍。

離心模型試驗、數值分析與人工智慧的架構下雖展現出良好之潛力，仍存在若干限制亟待說明。首先，現有資料集之規模相對有限，可能限制所建立之機器學習模型在泛化能力上的表現。因此，未來研究應著重於擴充資料庫規模，並納入更廣泛之載重條件與土壤性質，以提升模型之適用性與可靠度，若能進一步引入其他具影響性之參數，將有助於更全面地描述地震作用下之沉陷行為機制。

隨著資料量與多樣性之顯著提升，未來亦可考慮採用更先進之學習架構，例如可明確描述變數間複雜交互關係之圖論式模型 (graph-based models) 或深度混合式模型 (deep hybrid models)，以進一步強化預測準確度。最後，後續研究亦可將已訓練完成之模型整合至圖形化使用者介面 (GUI) 中，以提升其於工程設計與實務應用之便利性，從而使本研究之貢獻不僅止於學術層面，並能實質延伸至實際工程應用。

參考文獻

1. Ahmed, I. (2023). Key building design and construction lessons from the 2023 Türkiye-Syria earthquakes. *Architecture*, 3(1), 104-106.
2. Shao, X., & Xu, C. (2022). Earthquake-induced landslides susceptibility assessment: A review of the state-of-the-art. *Natural Hazards Research*, 2(3), 172-182.
3. Keefer, D. K. (2002). Investigating landslides caused by earthquakes—a historical review. *Surveys in geophysics*, 23(6), 473-510.
4. Keefer, D. K. (2002). Investigating landslides caused by earthquakes—a historical review. *Surveys in geophysics*, 23(6), 473-510.



5. Mase, L. Z., Tanapalungkorn, W., Likitlersuang, S., Ueda, K., & Tobita, T. (2022). Liquefaction analysis of Izumio sands under variation of ground motions during strong earthquake in Osaka, Japan. *Soils and Foundations*, 62(5), 101218.
6. Seed, H. B., & Idriss, I. M. (1967). Analysis of soil liquefaction: Niigata earthquake. *Journal of the Soil Mechanics and Foundations Division*, 93(3), 83-108.
7. Uyanık, O. (2020). Soil liquefaction analysis based on soil and earthquake parameters. *Journal of applied geophysics*, 176, 104004.
8. Cubrinovski, M., Bray, J. D., Taylor, M., Giorgini, S., Bradley, B., Wotherspoon, L., & Zupan, J. (2011). Soil liquefaction effects in the central business district during the February 2011 Christchurch earthquake. *Seismological Research Letters*, 82(6), 893-904.
9. Cetin, K. O., Soylemez, B., Guzel, H., & Cakir, E. (2025). Soil liquefaction sites following the February 6, 2023, Kahramanmaraş-Türkiye earthquake sequence. *Bulletin of Earthquake Engineering*, 23(3), 921-944.
10. Ortiz-Hernández, E., Chunga, K., Toulkeridis, T., & Pastor, J. L. (2022). Soil liquefaction and other seismic-associated phenomena in the city of Chone during the 2016 Earthquake of Coastal Ecuador. *Applied Sciences*, 12(15), 7867.
11. Anderson, D. J., Franke, K. W., Kayen, R. E., Dashti, S., & Badanagki, M. (2022). The over-prediction of seismically induced soil liquefaction during the 2016 Kumamoto, Japan earthquake sequence. *Geosciences*, 13(1), 7.
12. Mehrzad, B., Jafarian, Y., Lee, C. J., & Haddad, A. H. (2018). Centrifuge study into the effect of liquefaction extent on permanent settlement and seismic response of shallow foundations. *Soils and foundations*, 58(1), 228-240.
13. Mehrzad, B., Haddad, A., & Jafarian, Y. (2016). Centrifuge and numerical models to investigate liquefaction-induced response of shallow foundations with different contact pressures. *International Journal of Civil Engineering*, 14(2), 117-131.
14. Dashti, S., Bray, J. D., Pestana, J. M., Riemer, M., & Wilson, D. (2010). Mechanisms of seismically induced settlement of buildings with shallow foundations on liquefiable soil. *Journal of geotechnical and geoenvironmental engineering*, 136(1), 151-164.
15. Elgamal, A., Yang, Z., Parra, E., & Ragheb, A. (2003). Modeling of cyclic mobility in saturated cohesionless soils. *International journal of plasticity*, 19(6), 883-905.
16. Yang, Z., & Elgamal, A. (2002). Influence of permeability on liquefaction-induced shear deformation. *Journal of Engineering Mechanics*, 128(7), 720-729.
17. Elgamal, A., Lu, J., & Yang, Z. (2005). Liquefaction-induced settlement of shallow foundations and remediation: 3D numerical simulation. *Journal of earthquake engineering*, 9(spec01), 17-45.
18. Ziotopoulou, K., & Montgomery, J. (2017, January). Numerical modeling of earthquake-induced liquefaction effects on shallow foundations. In *Proceedings of 16th world conference on earthquake engineering*.
19. Petalas, A., & Galavi, V. (2013). Plaxis liquefaction model UBC3D-PLM. Plaxis report.
20. Makra, A. (2013). Evaluation of the UBC3D-PLM constitutive model for prediction of earthquake induced liquefaction on embankment dams. Delft University of Technology.
21. Castelli, F., Grasso, S., Lentini, V., & Sammito, M. S. V. (2024). Calibration of the UBC3D-PLM soil model from Dilatometer Marchetti Test (DMT) for the liquefaction behaviour and cyclic resistance ratio (CRR) of sandy soils. *Soil Dynamics and Earthquake Engineering*, 187, 109002.
22. Park, E. S., & Kim, B. I. (2022). A study on the application of UBC3D-PLM for soil liquefaction analysis. *Journal of the Korean Geosynthetics Society*, 21(1), 1-10.
23. Imansyah, M. R., Taborda, D. M. G., Hau, K. W., Chen, L., & Hosseini-Kamal, R. NUMERICAL INVESTIGATION OF OFFSHORE FOUNDATION ON LIQUEFIABLE SANDS.
24. Jalili, J., & Moradi, M. (2025). 3D numerical simulation of a centrifuge test on a soil-nailed wall supporting an excavation under cyclic loading. *Earthquake Engineering and Engineering Vibration*, 24(2), 381-394.
25. Barron, J., Rouainia, M., Charlton, T., Edwards, S., & Gibson, F. (2024). Seismic performance of shared suction caisson anchors installed in liquefiable sand for floating offshore wind turbines. *Soil Dynamics and Earthquake Engineering*, 180, 108598.
26. Besharatinezhad, A., Khodabandeh, M. A., & Naderi, R. (2019). Evaluating liquefaction induced settlement of shallow foundation on layered soil deposit. *SN Applied Sciences*, 1(11), 1498.
27. Salman, H. A., Kalakech, A., & Steiti, A. (2024). Random forest algorithm overview. *Babylonian Journal of Machine Learning*, 2024, 69-79.
28. Zou, J., Han, Y., & So, S. S. (2008). Overview of



artificial neural networks. Artificial neural networks: methods and applications, 14-22.

29. Noble, W. S. (2006). What is a support vector machine? *Nature biotechnology*, 24(12), 1565-1567.