

114 年地震預警作業技術研發之相關研究

子計畫一

分散式光纖感測技術於現地預警系統之開發與應用

黃信樺 陳芸仟

中華民國地球物理學會

摘要

分散式光纖感測技術(Distributed fiber-optic sensing technique, DFOS)是一項能將任一光纖纜線轉換成能紀錄地震動的感應器陣列的新興科技。此技術使得現存在我們生活週遭的光纖纜線(例如建物內的網路通訊光纖)都能成為地震儀,為現地型預警系統提供真正在不同樓層或捷運軌道上的真正現地觀測紀錄。然而,由於光纖纜線可能與地面(或建物)的耦合程度不一,並且只能紀錄順著纜線方向的單分量振動訊號,讓振幅的資訊有較高的不確定性,因此過去的光纖研究主要著重在相位而非振幅的分析,但進行地震預警需要仰賴振幅的資訊。因此,本計畫將利用花蓮米崙深鑽計畫(MiDAS)有良好耦合與三維路線(含井下光纖能提供垂直向資料)的光纖資料來進行地震預警之開發研究。

現地型地震預警主要是利用先抵達的 P 波前幾秒的資訊來預估後抵達的 S 波會有多大的地振動。例如被廣泛使用的兩種方法： τ_c 與 P_d , 是用前 3 秒 P 波的特徵週期與最大位移振幅來與 S 波的最大地動加速度(Peak Ground Acceleration, PGA)或速度值(Peak Ground Velocity, PGV)求取他們之間的線性回歸關係,來進行地震預警。由於 MiDAS 位處地震好發的花蓮地區,自 2022 年 1 月開始紀錄以來已經記錄到超過 400 起芮氏規模大於 4 的地震事件,有足夠的地震事件可進行回歸分析,我們將利用當地共站之強地動站資料建立光纖紀錄之應變率(1/s)與最大地動加速度(cm/s^2)與速度(cm/s)之回歸關係。探討光纖纜線方向性之影響,並實測此回歸式在普遍存在的水平光纖纜線資料的表現。期能朝未來整合光纖資料的新一代現地型地震預警系統邁進。

關鍵字：分散式光纖感測技術、現地型地震預警、MiDAS、井下光纖、經驗式回歸。

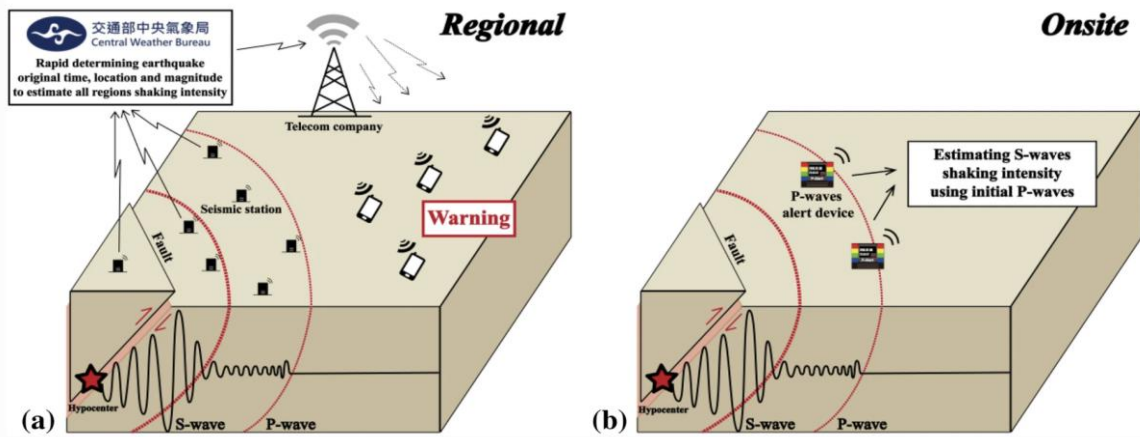
Abstract

Distributed fiber-optic sensing (DFOS) is an emerging technique that can turn a fiber cable into distributed seismic sensors. The ubiquitously existing telecom fiber cables in high-population areas and buildings are particularly useful for providing actual on-site ground motion measurements (e.g. on different floors and elevated metro rails) in the on-site earthquake early warning (EEW) systems. However, since the difference in cable coupling condition and cable orientation would all influence the amplitudes of DFOS recording, most of the literature to date focus mostly on the phase rather than amplitude information of the DFOS data. Here, the project aims to make use of well-coupled 3-D fiber network of the Milun fault drilling and all-inclusive sensing project (MiDAS) in eastern Taiwan to explore the potential of using DFOS for on-site EEW applications.

On-site EEW systems utilize the information of first-arriving P-waves to estimate how big the latter S-wave shaking would be. Two prevailing methods in on-site EEW systems are τ_c and P_d , which establish a linear relationship between the characteristic period (τ_c) and the maximum vertical displacement amplitude (P_d) of the initial 3-second P waves, and the peak ground acceleration (PGA) or peak ground velocity (PGV) of the upcoming S-wave shaking for EEW alerts. Because the MiDAS is located right in the earthquake-prone area of Hualien, it has recorded more than 400 ML 4+ earthquakes since January 2022 for the regression analysis. With a co-located strong motion station, we will conduct a linear regression between the maximum amplitude of the DFOS-recorded strain rate in the initial 3-sec P waves and the PGA or PGV recorded by the strong motion station to establish their empirical relationship. We will then investigate the effect of cable orientation on this relationship, apply and evaluate the performance of this relationship to other horizontal fiber cables, and move forward to next-generation EEW systems that integrate the ubiquitously existing fiber cables in the future.

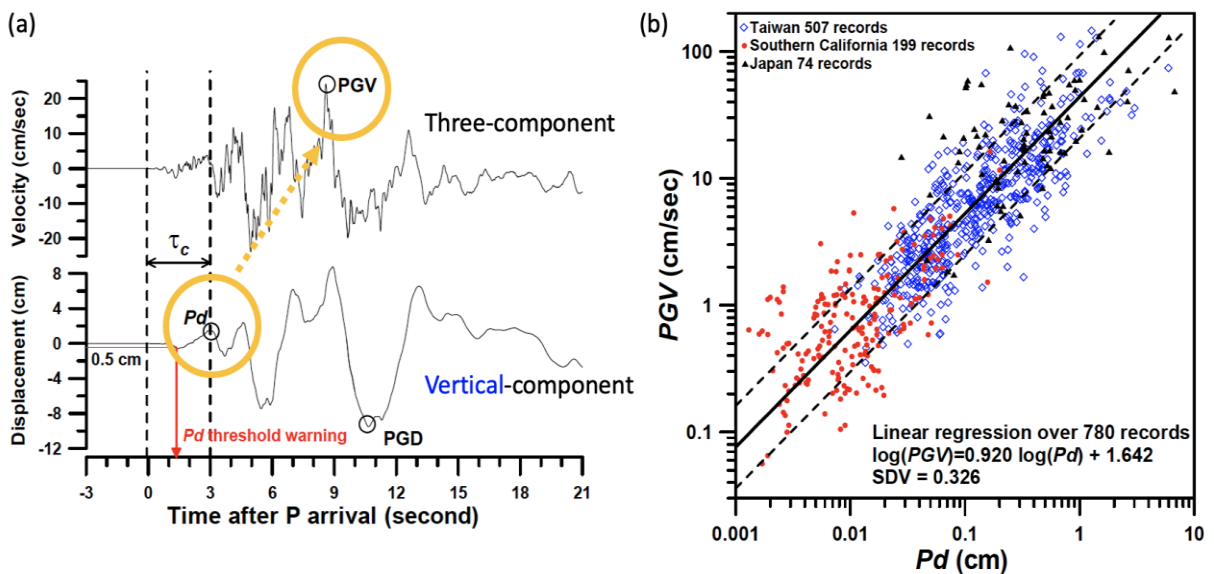
壹、研究背景與目的

地震預警系統 (Earthquake Early Warning, EEW) 是現今地震減災最有效實用的方法，能爭取寶貴的數秒到十數秒時間，讓人們採取防護措施、讓交通系統減速以及讓重要設施緊急關閉 (Satriano et al., 2011; Allen and Melgar, 2019; Wu and Mittal, 2021)。地震預警系統主要可分為區域型和現地型兩種(圖一)。區域型地震預警是透過分布於大範圍內的地震測站網，利用震央附近的測站快速估算地震位置與規模，向較遠的地區提供警報 (Wu et al., 1998; Satriano et al., 2011)。而現地型地震預警則是透過建立初始 P 波特徵與後續 S 波最大振幅之間的線性關係，來為震央附近地區或特定地點 (例如單一建築或關鍵設施) 提供即時的反應能力 (Wu and Kanamori, 2005; Wu and Kanamori, 2008; Bose et al., 2009)。



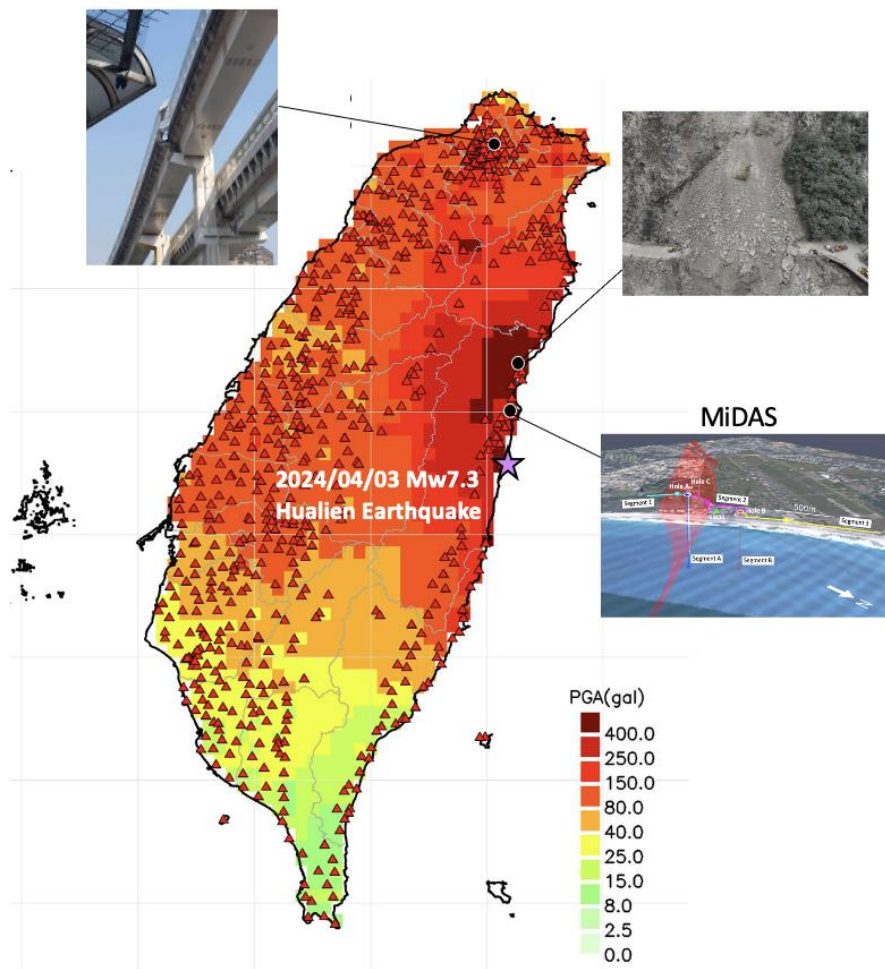
圖一、區域型地震預警(a)與現地型地震預警(b)的示意圖。

現地型地震預警在過去幾十年間已有許多不同的回歸分析方法被陸續提出 (Nakamura, 1998; Odaka et al., 2003; Kanamori, 2005; Allen et al., 2009; Zollo et al., 2010; Böse et al., 2012; Carranza et al., 2013; Hsu et al., 2013; Hsu et al., 2016; Hsieh et al., 2015; Wu et al., 2013; Peng et al., 2015; Emolo et al., 2016; Caruso et al., 2017)。其中，最廣為被使用的 Pd 和 τ_c 兩種方法是利用 P 波初始 3 秒內的垂直位移峰值振幅與主導週期，來與 PGA 和 PGV 進行線性回歸分析 (Wu and Kanamori, 2005; Wu and Kanamori, 2008) (圖二)。其他多數的研究主要使用相似概念的延伸與變形，近期則有機器學習的應用出現 (Jozinović et al., 2021; Wang et al., 2022; Liu et al., 2024)。



圖二、 Pd 方法的回歸分析。(a)為 P 波前三秒垂直最大振幅與 S 波最大地動速度值(PGV)的波形對應關係、(b)線性回歸的結果，不同符號代表不同地區的地震資料。

近期火速發展的分散式光纖感測技術(Distributed fiber-optic sensing technique, DFOS)是一項將光纖纜線轉化為具有公尺級解析度的地動感測器陣列的新技術，為地震學帶來了新的發展契機 (Lindsey et al., 2017; Zhan, 2020)。在地震預警的應用中，DFOS 的一個顯著優勢是利用海底光纜來接近位於隱沒帶的大地震高風險區域，提升區域型地震預警系統的時效 (Lior et al., 2021; Farghal et al., 2022; Yin et al., 2023)。在智利的試驗研究已初步證實，將海底光纜納入地震預警系統可將警報時間提升超過 3 秒 (Lior et al., 2023; Yin et al., 2023)。另一方面，城市與建築物中廣泛分布的通信光纜亦可為現地型地震預警系統所用，但目前受到的關注較少。在傳統地震儀難以安裝的城市地區，例如高樓或捷運、高鐵等高架設施，已存在的通信光纜就能提供立即的幫助。此外，相較於通常安裝在地表的地震站，DFOS 更可以提供真正的「現地」觀測與警報，對建築物內不同的樓層以及高架設施，例如捷運系統及高鐵軌道等提供預警。這些地方實際感受到的地震動往往比地表的地震動大，僅用在地表的地震站可能有震度低估的風險。2024 年 4 月 3 日芮氏規模 7.3 的花蓮地震就是一個很好的例子：雖然臺北市地表震動未達地震預警的警報標準，但高架捷運系統上的放大震動卻導致鐵軌的錯位位移 (圖三)，所幸列車即時緊急剎車，並未造成傷亡，但也凸顯了運用光纖進行現地型預警的重要性。



圖三、2024/04/03 Mw7.3 花蓮地震最大地動加速度分佈圖。左上與右上照片顯示強地動所造成的捷運軌道位移與蘇花公路坍塌。右下圖為 MiDAS 計劃所建立的三維光纖陣列。

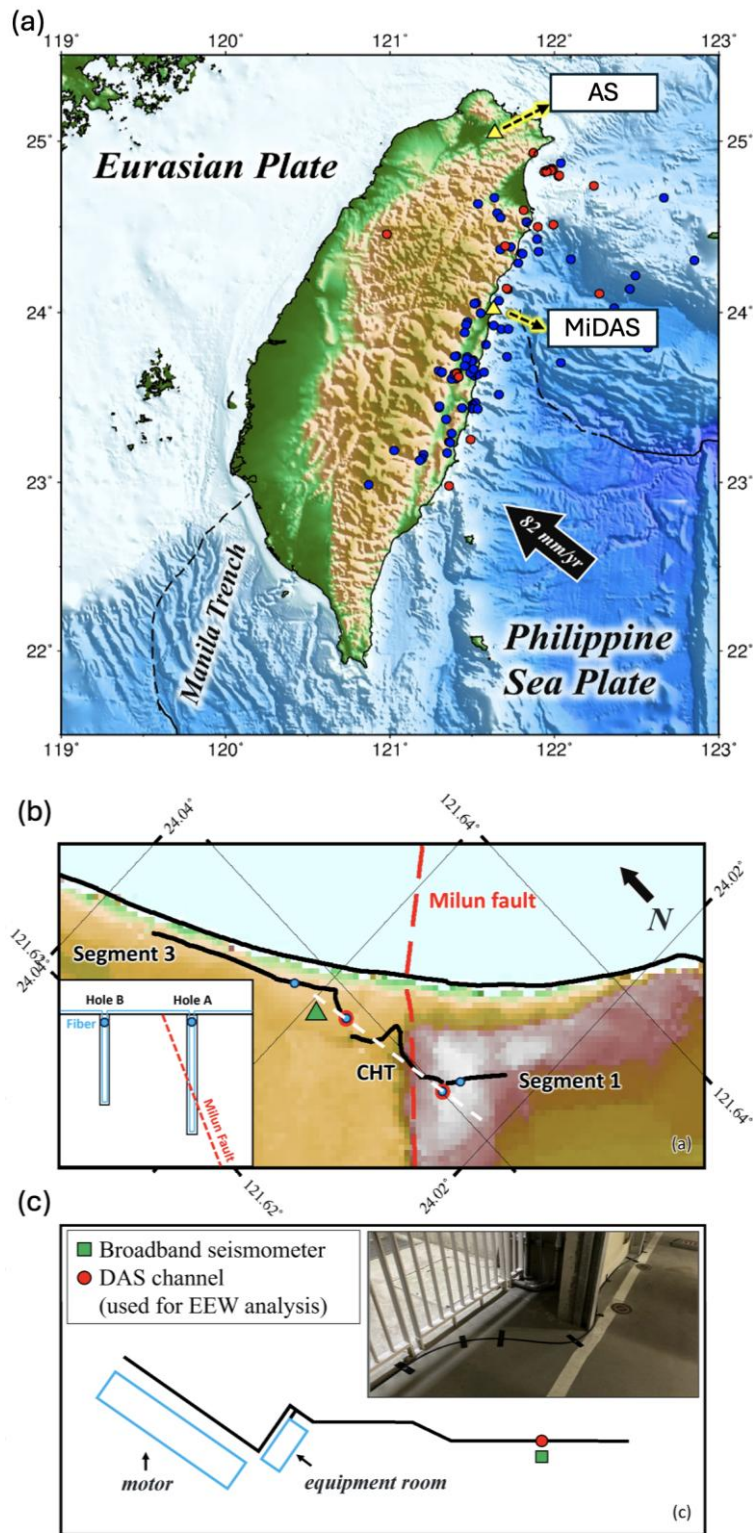
然而 DAS 記錄的是應變或應變率，並不是地震儀所記錄的粒子速度或加速度，因此傳統現地型預警的方法與建立的經驗式無法直接的應用在 DAS 資料上。為解決這一問題，其中一個作法是使用如 f-k 尺度轉換、傾斜疊加(Slant-stacking)或曲波技術(Curvelet techniques)等方法將應變或應變率資料轉換成速度或加速度(Lindsey et al., 2020; Lior et al., 2021; Atterholt et al., 2022)。然而，這些轉換方法仍然存在許多挑戰，尚未被廣泛的採用。因此，我們採取另一個作法，那就是直接建立光纖資料與地震站記錄的最大地動速度(Peak Ground Velocity, PGV)或如最大地動加速度(Peak Ground Acceleration, PGA)之間的經驗關係式。

建立經驗式的方法需要收集相當數量之光纖資料，這在現今多數光纖試驗皆為臨時試驗並不容易(Wuestefeld et al., 2023)。但所幸的是，自2022年9月建立完工以來，位處近年地震頻發的花蓮地區的米崙斷層深鑽計劃(MiDAS)連續運作至今(Huang et al., 2023; Ma et al., 2024)，已經記錄收集到超過400起芮氏規模大於4的地震事件，有足夠的地震事件與共站之地震站的資料，直接進行對 DAS 記錄的 P 波最大應變率振幅與共站之地震站記錄的 S 波最大速度或加速度振幅(即 PGA 或 PGV)的回歸分析，研究探討其是否如傳統地震資料一樣具有良好的線性關係？並且此線性關係在不同方向與不同地區的光纖資料是否有通用性？檢驗新型態的光纖資料在未來現地型預警應用的可行性。

貳、資料收集與處理

2.1 臺灣光纖資料

花蓮米崙斷層鑽探與光纖監測計劃(Milun Fault Drilling and All-inclusive Sensing, MiDAS)於2021年底啟動，2022年九月完工。建立了前沿的三維光纖觀測陣列，包含上盤700公尺(Hole A)與下盤500公尺(Hole B)兩口井的井下光纖，以及地表的Segment 1、Segment 3和CHT三段光纖(圖四b)。上盤的井A更在約510-540公尺的地方穿過米崙斷層的斷層帶，提供了全球第一手的活動斷層帶光纖紀錄(Huang et al., 2023; Ma et al., 2024)。由於MiDAS位處地震好發的花蓮地區，自2022年1月開始紀錄以來已經記錄到芮氏規模大於4的地震事件超過400餘起。我們從中挑選出在MiDAS光纖紀錄中P波訊噪比較好的86筆事件進行迴歸分析(圖四a)。選取建立迴歸關係式的地震站為位在MiDAS地表光纖中段旁的SM09測站(綠色三角形，圖四b)。為驗證關係式的泛用性，我們也收集了在中研院環境變遷大樓B3停車場的簡易光纖試驗的資料，該試驗為模擬實際未來若使用在大樓中的通訊光纖未必與地面有很好耦合的情形，僅以膠帶黏貼在地面進行觀測(圖四c)，挑選2022年的24個地震來進行分析。

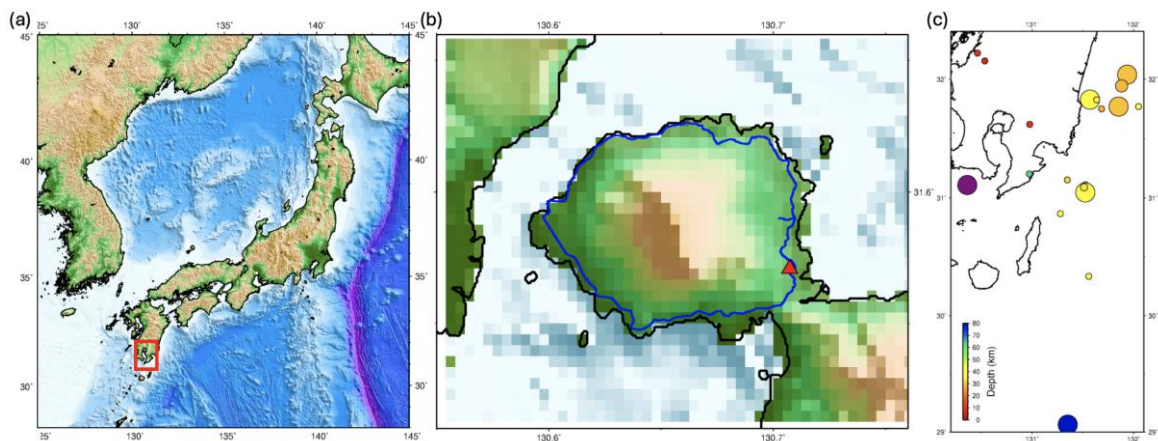


圖四、MiDAS 三維光纖觀測與地震紀錄。(a)經挑選之 MiDAS 計劃所收集到的地震事件分佈。(b)MiDAS 光纖纜線三維路線。分為 Hole A 與 Hole B 兩段井下光纖與 Segment 1、Segment 3 與 CHT 三段地表光纖，串連成三維的光纖觀測陣列。內圖為地圖上沿白色虛線之剖面圖。紅色虛線為米崙斷層在地表與剖面的位置，Hole A 在約 500 公尺穿過該斷層。綠色三角形為研究使用的地震站 SM09。(c)為中研院(AS)

環變大樓地下停車站的光纖試驗路線圖與現場照片。紅色圓點與綠色正方形為選取之光纖節點與共站的地震測站。

2.2 日本光纖資料

由日本學術振興會(JSPS)科研費補助金支持，日本東北大學、九州大學與京都大學三校合作在櫻島火山島上利用日本國土交通省管理的環島光纖纜線，建立了非常獨特的環形光纖監測網，長度約 40 公里，可提供相當於 7,820 部地震站的密集觀測，進行即時的火山活動監測與火山構造分析(圖五 a 與 b)。本團隊在 2024 年開始與該櫻島光纖計劃領頭的日本東北大學 Hisashi Nakahara 教授進行臺日雙邊的光纖研究合作交流，因此藉此機會使用櫻島的光纖資料能進行關係式跨地區的適用性檢驗。在 2023-2025 年觀測期間挑選出 20 筆地震事件來進行分析，空間分佈如圖五 c 所示，芮氏規模範圍在 1.5-6.6。



圖五、日本櫻島火山光纖觀測。(a)櫻島火山位置位於日本西南端的紅色方框處。(b)櫻島火山的放大圖，藍色實線為光纖監測的纜線路線，紅色三角形為用於回歸分析之地震站。(c)2023-2025年間挑選之地震事件分佈。

參、研究方法與回歸關係式

由於光纖只能紀錄平行其纜線走向的振動，如同許多回歸式使用的是地震站垂直向的資料一樣，我們首先選取 Hole A 與 Hole B 井下光纖段近地表的兩個節點所紀錄之資料（藍色圓點，圖四 b）來分析，取光纖資料 P 波前三秒之最大振幅，稱為 Peak strain rate (PSR)，與共站之 SM09 的垂直向加速度資料的 PGA 進行線性回歸分析（圖六）。如公式 1 所示

$$\log(PGA_i) = \alpha \log(PSR_i) + \beta \quad (1)$$


其中第一項係數為斜率、第二項則為截距。考慮到未來在應用到都會區的通訊光纖上時，我們無法決定光纖的走向，光纖纜線可能是沿著主要幹道的水平分佈，也可能是進到大樓建物內走不同樓層間的垂直分佈。因此在使用井下光纖的垂直

向資料得到回歸式後，我們也在 Segment 1 和 Segment 3 兩段水平光纖中選取了兩個節點（藍色圓點，圖四 b），以及中研院環變大樓地下停車場的光纖試驗（簡稱 AS 試驗）作為當光纖為水平向時的情境測試。並進一步以日本櫻島火山的光纖資料來驗證回歸式在跨地區時的泛用性。


圖七為選取之 86 個地震資料的回歸結果，橫軸為垂直井下光纖節點的 PSR、縱軸為共站之 SM09 測站的垂直向 PGA。可以看到兩者呈現高度的線性相關，得到的係數如公式 2 所示

$$\log(PGA) = 1.088 \log(PSR) - 3.163 \quad (2)$$

計算之標準差為 0.259，相關係數為 0.93。這個數字與傳統地震站資料回歸的相關係數相當或更高，代表將 DAS 所紀錄之光纖資料納入未來現地型預警系統中是有可能的。



圖六、光纖與地震波形資料。(上) 地震站 SM09 的垂直向加速度波形；(下) Hole A 井下近地表光纖節點之應變率波形。垂直虛線標示出 P 波前三秒的時窗。藍色圓圈分別為選取之最大應變率 (PSR) 與最大地動加速度 (PGA)。



圖七、光纖 P 波前三秒最大應變率振幅 (PSR) 與共站地震站垂直向最大地動加速度 (PGA) 的線性回歸分析。

肆、結果與討論

4.1 水平向光纖資料的測試與修正

如同地震站的場址放大效應分析，不同的場址會影響到紀錄振幅的大小。位處不同地區的光纖纜線除不同場址條件外，還有可能因纜線走向的不同（垂直 vs. 水平）與施工之耦合情形（Coupling）的不同影響振幅大小，乃至影響回歸關係式的準確性。因此，AS 試驗的資料即可作為模擬實際通訊光纖走在建物中並不會有 MiDAS 井下水泥固封與地表深埋的良好耦合的情形。櫻島火山的資料則可作為代表不同地區與地質條件的測試（沈積岩 vs. 火成岩）。我們將此回歸公式套用到 MiDAS 水平向光纖段所選取的兩個節點的資料、中研院 AS 試驗的水平向光纖資料，以及日本櫻島火山的水平向光纖資料，結果如圖八 a 所示。綠色、黃色、藍色與紅色圓點分別代表 MiDAS Segment 1、Segment 3、AS 試驗與日本櫻島火山的光


織資料。可以看到 AS 試驗量測到 P 波前三秒最大應變率 (PSR) 略低於回歸線，合理顯示較差的耦合條件會低估地振動的振幅。另外三組的 PSR 則一致的大於回歸線。櫻島火山的資料猶是，可能反應區域地質的差異。雖然這四組水平向光纖的資料並沒有很好的集中在一個標準差之內，但在分佈趨勢與垂直向資料得到的回歸線斜率大致吻合。因此，我們可以定義一個誤差公式 (Misfit function)，如公式 3，定義三組水平向資料與垂直向資料的差距。

$$E_k = \sum_{i=1}^n (\log(PGA_i^k) - \log(PGA_i))^2 \quad (3)$$

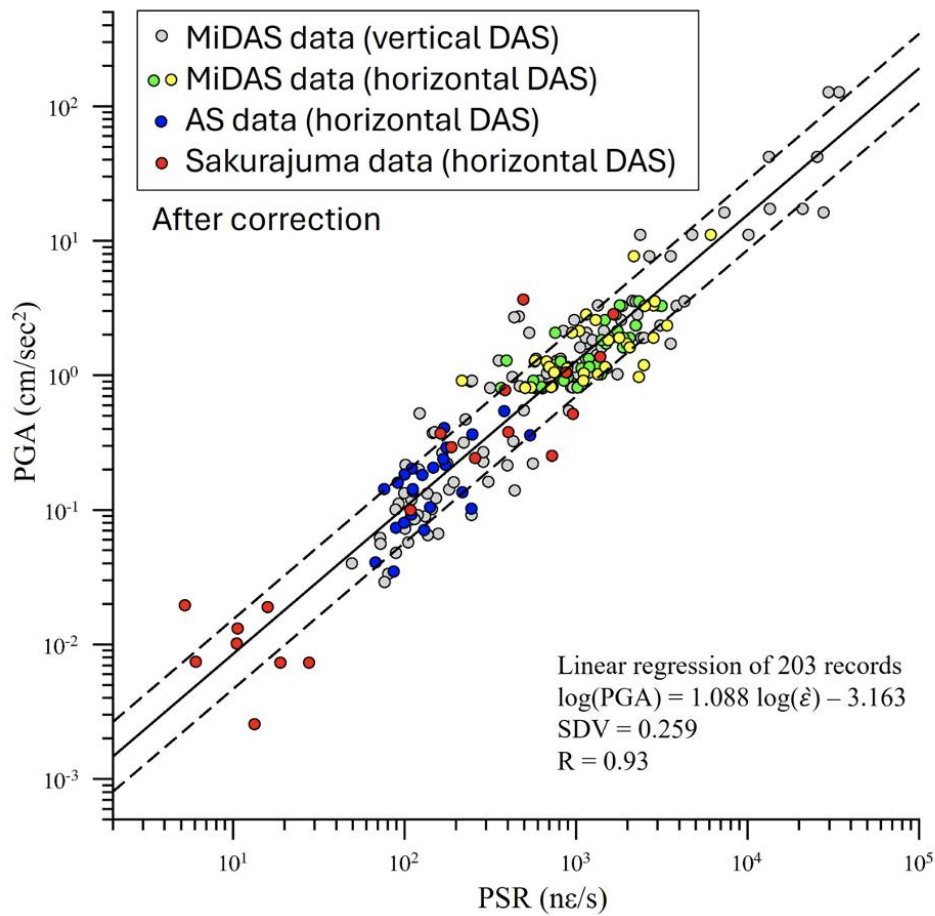
接著假設斜率不變，將原先的回歸式加上一個修正項 r_k ，如下公式 4 所示。再用格點搜尋法 (Grid search) 的方式來求取最佳的修正值，作為一包含場址、纜線走向與耦合程度的綜合振幅修正項。

$$\log(PGA_i^k) = 1.088 \log(PSR_i) - 3.163 + \gamma_k \quad (4)$$

圖九 b 為修正後的結果，四組水平向資料經修正項的平移後，皆能很好的集中在回歸線上。這也證實了雖然光纖資料有走向、耦合等問題，但其振幅的影響與平時地震站處理場址效應相同，能合併為一振幅修正項，做有效的回歸校正。加入了日本櫻島火山的資料後，更是大大地驗證了此關係式跨地區的泛用性。可用在不同國家的現地型地震預警系統之中。



(a)
356

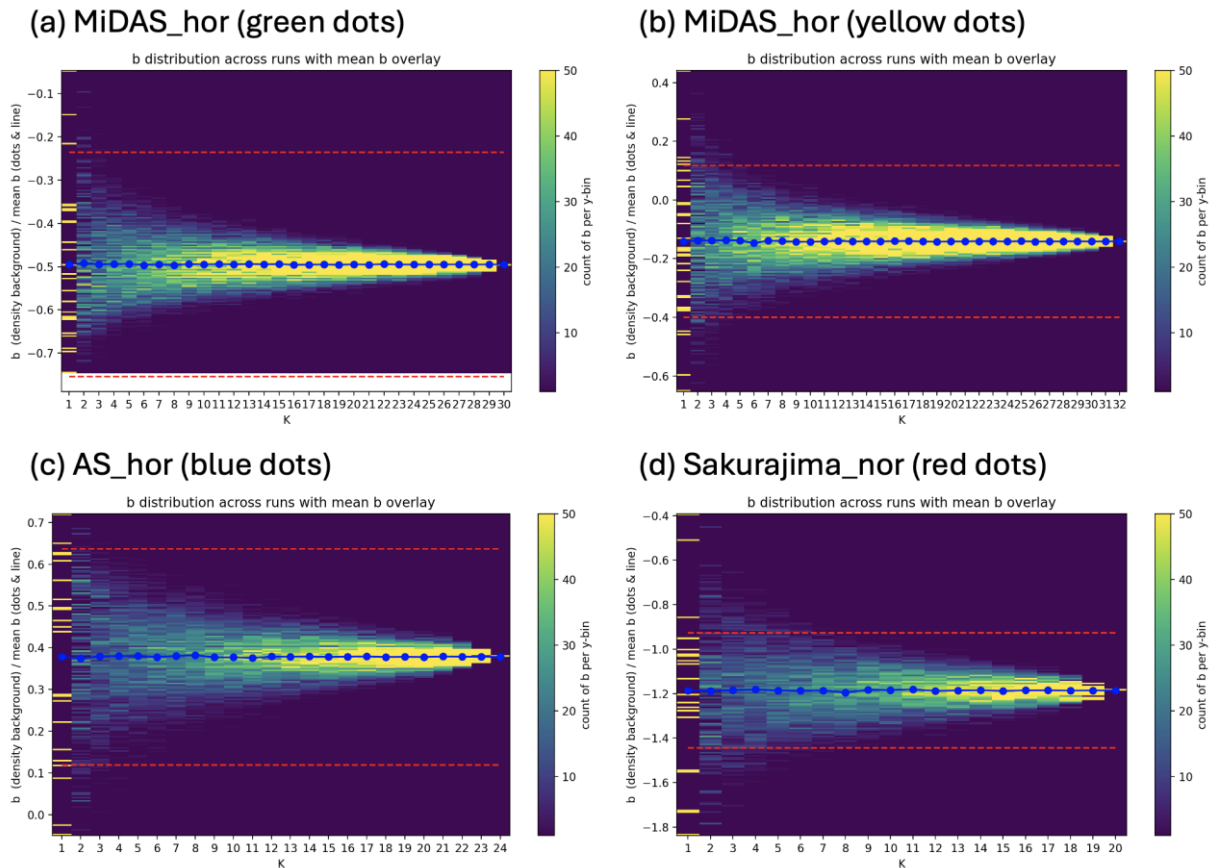


(b)

圖八、線性回歸式對水平向光纖資料之測試。綠色、黃色與紅色圓點分別代表 MiDAS Segment 1、Segment 3 與 AS 試驗的資料。(a) 與 (b) 分別為修正前、後的結果。

4.2 修正項所需的最小地震數目

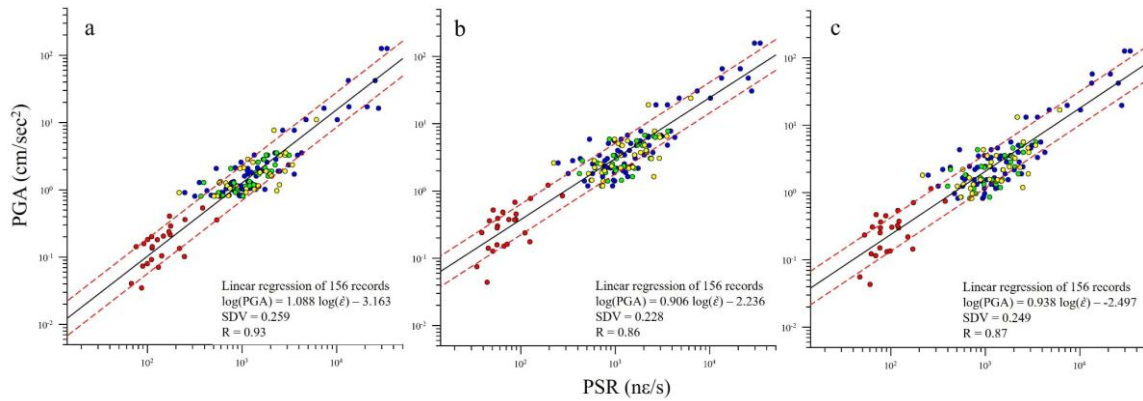
雖然我們驗證了此關係式的泛用性，但仍需要有至少一個夠近的地震站與記錄到數個地震事件才能進行修正與使用。為了了解此一局限，我們對四組水平向資料所記錄到的 20-30 個事件不等的資料進行不同地震數目的需求測試。我們隨機選取 1 到 K 個事件來進行 4.1 節的修正項搜尋，並重複進行 50 次，計算其機率密佈分佈。如圖九所示，(a)-(d) 分別代表 MiDAS Segment 1、Segment 3、AS 試驗與日本櫻島火山的 50 次結果的平均修正項值(藍色圓點)與機率密度分佈(背景亮度)。結果顯示大概在 K=3 的時候就可以有相當集中收斂且落在回歸線一個標準差(紅色虛線)內的修正值了。這代表對於任一要用於現地型預警的光纖纜線，只需要臨時布放一個地震站在任一纜線節點旁一段時間，收集到 3 個地震紀錄即可使用。同一纜線不同節點間的振幅修正，則可以透過任一單一地震的相對振幅來做進一步的修正即可。



圖九、修正項所需最小地震數目的隨機抽樣測試。(a)-(d)分別是 MiDAS Segment 1、MiDAS Segment 3、AS 試驗與日本櫻島火山的光纖地震資料。K 為每次隨機選取的地震數目，在重複進行 50 次修正項搜尋後，藍色圓點為平均修正項數值，背景亮度代表機率密度分布，紅色虛線則是回歸關係式（公式 2）的一個標準差範圍。

4.3 不同 PGA 計算方式的影響

若細究過去的回歸分析方法（Nakamura, 1998; Odaka et al., 2003; Kanamori, 2005; Allen et al., 2009; Zollo et al., 2010; Böse et al., 2012; Carranza et al., 2013; Hsu et al., 2013; Hsu et al., 2016; Hsieh et al., 2015; Wu et al., 2013; Peng et al., 2015; Emolo et al., 2016; Caruso et al., 2017），事實上會發現各研究團隊在 PGA 的計算方式上並不統一。有本研究圖七採用的垂直向 PGA，也有人使用三個分量的向量和的最大值，或三個分量中的最大值作為 PGA 的計算。因此，我們也測試了另外兩種方式的回歸結果。如圖十所示，基本上三種 PGA 的計算方式都與 PSR 有良好的線性關係，僅在回歸係數上有所不同。但若就相關係數來看，仍然是以垂直向計算 PGA 的 0.93 最高。但另外兩者也都在 0.8 以上。證實光纖資料就如同傳統的地震資料一樣，前三秒的 P 波振幅峰值與後到的 S 波最大振幅有普遍存在的線性關係。



圖十、不同 PGA 計算方式的回歸結果，分別是以(a)垂直向最大振幅、(b)三分量向量和最大振幅與(c)三分量中的最大振幅作為 PGA 的計算。

伍、計畫成果與未來規劃

分散式光纖感測技術能將遍佈在我們日常周遭的通訊光纖轉換成高度密集的地震陣列，能為現地型地震預警系統提供在都會區、建物與高架設施更好的測站覆蓋率。本計劃得利於 MiDAS 觀測站的長期運作與近年花東地區頻繁的地震活動，收集到良好的事件數量與規模範圍，讓我們有機會利用垂直向的井下光纖資料建立第一個光纖最大應變率 (PSR) 對應最大地動加速度 (PGA) 的現地型預警回歸經驗式。其資料分佈呈高度線性相關，相關係數高達 0.93。並且在不同纜線走向 (MiDAS Segment 1&3)、不同耦合程度 (AS 試驗) 與不同區域地質條件 (日本櫻島火山) 的情形，都能透過增加一個綜合性的修正項來進行振幅校正，集中落在關係式的一個標準差之內，代表此關係式有普遍通用性。此線性關係的普遍存在性並不受 PGA 計算方式的影響。並且透過隨機取樣測試，在實際應用上僅需約 3 個地震紀錄即可求得相對準確的修正項數值，進行此關係式的預警應用。此研究成果為日後結合光纖的混合型地震預警系統發展鋪路，傳統地震儀可作為 DAS 系統校正的錨點，而 DAS 則能補足傳統地震網未覆蓋區域的空間資訊。該系統結合現有城市與離岸地區的光纖網路與 DAS 技術，將有潛力延長區域性警報的預警時間，並實現更密集、在地化的現地型警報。

參考文獻

- Allen, R. M., Gasparini, P., Kamigaichi, O., & Bose, M. (2009). The status of earthquake early warning around the world: An introductory overview. *Seismological Research Letters*, 80(5), 682–693.
- Atterholt, J., Z. Zhan, Z. Shen, and Z. Li (2022), A unified wavefield-partitioning approach for distributed acoustic sensing, *Geophys. J. Int.*, 228, 1410–1418.
- Bose, M., Heaton, T., & Hauksson, E. (2012). Rapid estimation of earthquake source and ground-motion parameters for earthquake early warning using data from a single three-component broadband or strong-motion sensor. *Bulletin of the Seismological Society of America*, 102(2), 738–750.
- Carranza, M., Buforn, E., Colombelli, S., & Zollo, A. (2013). Earthquake early warning for Southern Iberia: A p wave threshold-based approach. *Geophysical Research Letters*, 40(17), 4588–4593.
- Caruso, A., Colombelli, S., Elia, L., Picozzi, M., & Zollo, A. (2017). An on-site alert level early warning system for Italy. *Journal of Geophysical Research: Solid Earth*, 122(3), 2106–2118.
- Emolo, A., Picozzi, M., Festa, G., Martino, C., Colombelli, S., Caruso, A., Elia, L., Zollo, A., Brondi, P., & Miranda, N. (2016). Earthquake early warning feasibility in the Campania region (southern Italy) and demonstration system for Public School Buildings. *Bulletin of Earthquake Engineering*, 14(9), 2513–2529.
- Farghal, N. S., Saunders, J. K., & Parker, G. A. (2022). The potential of using fiber optic distributed acoustic sensing (DAS) in earthquake early warning applications. *Bulletin of the Seismological Society of America*, 112(3), 1416–1435.
- Hsieh, C.-Y., Chao, W.-A., & Wu, Y.-M. (2015). An examination of the threshold-based earthquake early warning approach using a low-cost seismic network. *Seismological Research Letters*, 86(6), 1664–1667.
- Hsu, T.-Y., Huang, S.-K., Chang, Y.-W., Kuo, C.-H., Lin, C.-M., Chang, T.-M., Wen, K.-L., & Loh, C.-H. (2013). Rapid on-site peak ground acceleration estimation based on support vector regression and P-wave features in Taiwan. *Soil Dynamics and Earthquake Engineering*, 49, 210–217.
- Hsu, T., Wang, H., Lin, P., Lin, C., Kuo, C., & Wen, K. (2016). Performance of the NCREE's on-site warning system during the 5 February 2016 Mw 6.53 Meinong earthquake. *Geophysical Research Letters*, 43(17), 8954–8959.
- Huang, H.-H., K.-F. Ma, E.-S. Wu, Y.-Z. Cheng, C.-J. Lin, C.-S. Ku, P.-L. Su, and MiDAS working group (2023), Spatiotemporal monitoring of a frequently-slip fault zone using downhole distributed acoustic sensing at the MiDAS Project, in Li, Y., Mellors, R. & Zhan, G., eds, *AGU Book Series*, Wiley, in press.
- Jozinović, D., Lomax, A., Štajduhar, I., & Michelini, A. (2021). Rapid prediction of earthquake ground shaking intensity using raw waveform data and a convolutional neural network. 1st Croatian Conference on Earthquake Engineering.

- Kanamori, H. (2005), Real-time seismology and earthquake damage mitigation. *Annu. Rev. Earth Planet. Sci.*, 33, 195–214.
- Lindsey, N. J., E. R. Martin, D. S. Dreger, B. Freifeld, S. Cole, S. R. James, G. L. Biondi, and J. B. Ajo-Franklin (2017). Fiber-optic network observations of earthquake wavefields. *Geophysical Research Letters*, 44. <https://doi.org/10.1002/2017GL075722>.
- Lindsey, N. J., Rademacher, H., & Ajo-Franklin, J. B. (2020). On the broadband instrument response of fiber-optic DAS arrays. *Journal of Geophysical Research: Solid Earth*, 125, e2019JB018145. <https://doi.org/10.1029/2019JB018145>
- Lior, I., A. Sladen, D. Mercerat, J.-P. Ampuero, D. Rivet, and S. Sambolian1 (2021), Strain to ground motion conversion of distributed acoustic sensing data for earthquake magnitude and stress drop determination. *Solid Earth* 12, 1421–1442.
- Lior, I., D. Rivet, J.-P. Ampuero, A. Sladen, S. Barrientos, R. Sánchez-Olavarría, G. A. Villarroel Opazo, and J. A. Bustamante Prado (2023). Magnitude estimation and ground motion prediction to harness fiber optic distributed acoustic sensing for earthquake early warning, *Sci. Rep.* 13, no. 1, 424.
- Liu, Y., Zhao, Q., & Wang, Y. (2024). Peak ground acceleration prediction for on-site earthquake early warning with deep learning. *Scientific Reports*, 14(1).
- Ma, K.-F., S. von Specht, L.-W. Kuo, H.-H. Huang, C.-R. Lin, C.-J. Lin, C.-S. Ku, E.-S. Wu, C.-Y. Wang, W.-Y. Chang, and P. Jousset (2024), Broad-band strain amplification in an asymmetric fault zone observed from borehole optical fiber and core, *Communications Earth & Environment*, 5, 402.
- Nakamura, Y. (2003). A new concept for the earthquake vulnerability estimation and its application to the early warning system. *Early Warning Systems for Natural Disaster Reduction*, 693–699.
- Odaka, T. (2003). A new method of quickly estimating epicentral distance and magnitude from a single seismic record. *Bulletin of the Seismological Society of America*, 93(1), 526–532.
- Peng, C., Yang, J., Chen, Y., Zhu, X., Xu, Z., Zheng, Y., & Jiang, X. (2015). Application of a threshold-based earthquake early warning method to the MW 6.6 lushan earthquake, Sichuan, China. *Seismological Research Letters*, 86(3), 841–847.
- Satriano, C., Elia, L., Martino, C., Lancieri, M., Zollo, A., Iannaccone, G. PRESTo (2011), the Earthquake Early Warning System for Southern Italy: Concepts, Capabilities and Future Perspectives. *Soil Dyn. Earthq. Eng.* 31, 137–153.
- Wang, C.-Y., T.-C. Huang, and Y.-M. Wu (2022), Using LSTM Neural Networks for Onsite Earthquake Early Warning, *Seismological Research Letters*, 93, 814–826, doi: 10.1785/0220210197.
- Wu, Y.-M., Shin, T.-C., Tsai, Y.-B. (1998), Quick and reliable determination of magnitude for seismic early warning. *Bull. Seismol. Soc. Am.*, 88, 1254–1259.
- Wu, Y.-M., Chen, D.-Y., Lin, T.-L., Hsieh, C.-Y., Chin, T.-L., Chang, W.-Y., Li, W.-S., & Ker, S.-H. (2013). A high-density seismic network for earthquake early warning in

- Taiwan based on low cost sensors. *Seismological Research Letters*, 84(6), 1048–1054.
- Wu, Y.-M., Kanamori, H. (2005), Rapid assessment of damaging potential of earthquakes in Taiwan from the beginning of P Waves. *Bull. Seismol. Soc. Am.*, 95, 1181–1185.
- Wu, Yih-Min, & Kanamori, H. (2008). Development of an earthquake early warning system using real-time strong motion signals. *Sensors*, 8(1), 1–9.
- Wu, Yih-Min, Hsiao, N.-C., & Teng, T.-L. (2004). Relationships between strong ground motion peak values and seismic loss during the 1999 Chi-chi, Taiwan earthquake. *Natural Hazards*, 32(3), 357–373.
- Wu, Y.-M.* and H. Mittal (2021), A review on the development of earthquake warning system using low-cost sensors in Taiwan, *Sensors*, 21, 7649, doi: 10.3390/s21227649.
- Yin, J., M. A. Soto, J. Ramírez, V. Kamalov, W. Zhu, A. Husker, and Z. Zhan (2023). Real-Data Testing of Distributed Acoustic Sensing for Offshore Earthquake Early Warning, *The Seismic Record*. 3(4), 269–277, doi: 10.1785/0320230018.
- Zollo, A., Amoroso, O., Lancieri, M., Wu, Y.-M., & Kanamori, H. (2010). A threshold-based earthquake early warning using dense accelerometer networks. *Geophysical Journal International*, 183(2), 963–974.
- Zhan, Z. (2020). Distributed Acoustic Sensing Turns Fiber-Optic Cables into Sensitive Seismic Antennas. *Seismol. Res. Lett.* 91, 1-15, doi: 10.1785/0220190112.

114 年地震預警作業技術研發之相關研究

子計畫二

人工智慧技術建立微分區地震預警系統相關研究

詹忠翰 馬國鳳 呂奇祝 謝銘哲

中華民國地球物理學會

摘要

本計畫提出一套以深度學習為核心的區域型地震預警模型——臺灣轉換器震動警報模型 (Taiwan Transformer Shaking Alert Model, 簡稱:「TT-SAM」)。模型以 PGV 作為主要預測指標,目標為更貼近實際建築結構損害情形,提升預警系統的實用性與精確度。與多數深度學習地震預警方法僅依賴原始波形不同,TT-SAM 模型除了使用速度波形外,亦納入低頻率速度波形以及三項具物理意義的震波特徵: Pd、CVAV 與 TP,強化模型對震源破裂特性與強震區辨識的能力。模型訓練採用滾動式預警策略,可於 P 波初達後 3 秒即提供初步預測,並隨時間推進持續更新預警結果。為模擬真實應用場景中波形尚未完整的情況,訓練階段設計了波形秒數遮罩,以提升模型泛化能力。另外透過 Magnitude Oversample 與 Bias to Close Station 策略,緩解訓練資料中高震度樣本不足所造成的預測低估問題。於 2016 年臺灣地震事件測試資料中,本模型在震度等級分類任務中 97.8% 預測結果落於 ± 1 級範圍內,展現優異的震度預測能力與穩定性。

關鍵字: 地震預警、深度學習。

Abstract

This project proposes a deep-learning-based regional earthquake early warning model, the Taiwan Transformer Shaking Alert Model (TT-SAM). The model adopts peak ground velocity (PGV) as its primary prediction metric, aiming to better reflect actual structural damage and thereby enhance the practical utility and accuracy of the warning system. Unlike most deep learning earthquake warning approaches that rely solely on raw waveforms, TT-SAM integrates velocity waveforms, low-frequency velocity waveforms, and three physically meaningful seismic features—Pd, CVAV, and TP—to strengthen the model's ability to capture source rupture characteristics and identify strong-motion regions. A rolling-update prediction strategy enables preliminary forecasts within 3 s of P-wave arrival, with continuous updates as additional waveform data become available. To simulate real-world conditions of incomplete waveform

acquisition, a time-masking mechanism is applied during training to improve generalization. Furthermore, magnitude oversampling and bias-to-close-station strategies are employed to alleviate underprediction arising from scarce high-intensity samples in the training data. When evaluated on the 2016 Taiwan seismic events dataset, TT-SAM achieved 97.8 % of its intensity-level predictions within ± 1 level, demonstrating outstanding predictive capability and stability.

Keywords: earthquake early warning, deep learning

壹、研究目的

地震預警 (Earthquake early warning 簡稱:「EEW」) 為在地震發生後, 透過快速分析地震波資訊, 針對即將受到強地動的區域發布提前警報, 因而此技術在地震減災扮演著舉足輕重的角色。現存地震預警系統主要可分為現地型與區域型地震預警, 前者透過單站的地震資訊對於現地發布警報, 後者則透過分析近場的地震資訊對於其他面臨強地動的潛在區域發布警報。在 Allen et al. (2019) 提及全球目前的地震預警技術中, 包含了基於點震源法的 EPIC (Chung et al., 2019), 使用有限斷層法的 FinDer (Böse et al., 2015) 以及針對即時觀測的地震訊號監測波場, 預估地震強度的 PLUM (Kodera et al., 2018)。

近年來, 隨著機器學習技術的發展, 諸多研究將機器學習與地震學連結, 其中也包含使用機器學習的方法, 以提升地震預警的精度與效率 (Münchmeyer et al., 2021; Bloemheuver et al., 2023)。透過預訓練的深度學習模型, 能夠有效提取地震波形中的特徵, 使地震預警系統在保持高準確度的同時, 提供更長的預警時間。

基於上述深度學習之優勢, 本研究參考 Transformer Earthquake Alert Model (TEAM, Münchmeyer et al., 2021), 構建基於深度學習的地震預警模型。TEAM 屬於區域型地震預警模型, 其優勢在於採用端對端的深度學習架構, 相較於傳統依賴震源參數估計的預警方法, 該模型能夠直接從原始地震波形和觸發測站資訊進行計算, 並對目標測站進行震動的預估, 毋需事先估算震源參數。由於具備端對端特性, 並透過大量地震波型進行預訓練, 該方法提升地震預警系統的準確性與運行效率, 為即時地震預測提供更可靠的技術基礎。傳統 TEAM 以波型預測峰值地表加速度 (Peak Ground Acceleration, 簡稱:「PGA」)。然而, 前人研究指出, 峰值地表速度 (Peak Ground Velocity, 簡稱:「PGV」) 與實際地震災害的關聯性較 PGA 更高, 特別是在建築物損壞與基礎設施受損的評估方面, PGV 更能有效反映地震對結構物的影響 (Wu et al., 2004; Wu et al., 2016)。因此, 本計畫將透過速度波形進行深度學習模型訓練預測 PGV, 從而改善地震預警系統的可靠性與實用性。

貳、資料

為建立地震預警模型，本研究使用臺灣強地動觀測網（Taiwan Strong Motion Instrumentation Program，簡稱：「TSMIP」；Liu et al., 1999）所收錄之地震資料進行訓練。TSMIP 具備高密度的地震測站分布（圖 1），提供大量高品質的地震紀錄，適合用於深度學習模型所需的大規模訓練資料集中。資料篩選方面，本研究採用 1999–2008 年間規模大於 5.5，以及 2009–2019 年間規模大於 3.5 的地震事件，包含 1,259 起地震事件、952 個測站，總計 51,902 筆地震紀錄。此外，所選地震事件皆至少包含一測站紀錄震度達 4 級以上（中央氣象署發布地震預警的條件為規模大於 5.0 且震度達 4 級以上，或規模大於 6.5 且震度達 3 級以上，表 1）。

在模型訓練資料劃分上，本研究將數據集分為訓練集、驗證集與測試集三部分，其中 2016 年的地震事件作為測試集，其餘資料則以 80% 作為訓練集、20% 作為驗證集進行隨機分割，訓練集與測試集在規模、深度、空間上分布相似（圖 2），確保模型從訓練集學習到的特徵能有效泛化到測試集。本研究資料集包含速度波形資料、低頻速度波形資料與三種物理特徵：垂直分量累積速度（Cumulative Vertical Absolute Velocity, CVAV）、最大位移振幅（Peak Displacement, Pd）、與頻率相關的 TP（Huang et al., 2015），測站資料則包括經度、緯度、高程及 Vs30（近地表 30 公尺內 S 波平均波速）。

表 1 CWA 的震度採用 PGA 結合 PGV 分級，在震度 4 級以下時使用 PGA，5-以上則使用 PGV，而本研究主要注重於 PGV 的預測，因此僅使用 PGV 的部分。

Intensity	0	1	2	3	4	5-	5+	6-	6+	7
PGA (cm/s ²)	<0.8	0.8~ 2.5	2.5~ 8.0	8.0~ 25	25~ 80	80~ 140	140~ 250	250~ 440	440~ 800	>800
PGV (cm/s)	<0.2	0.2~ 0.7	0.7~ 1.9	1.9~ 5.7	5.7~ 15	15~ 30	30~ 50	50~ 80	80~ 140	>140

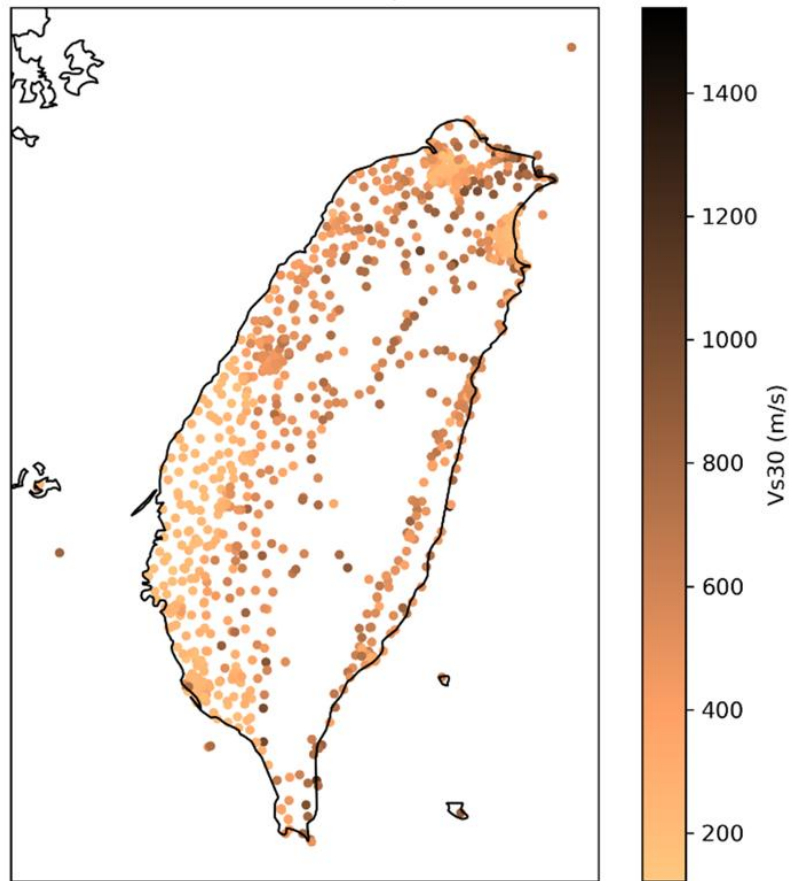





圖 1、測站在空間上的分布圖，其中測站顏色呈現測站場址 V_{s30} （近地表 30 公尺內 S 波平均波速）數值。



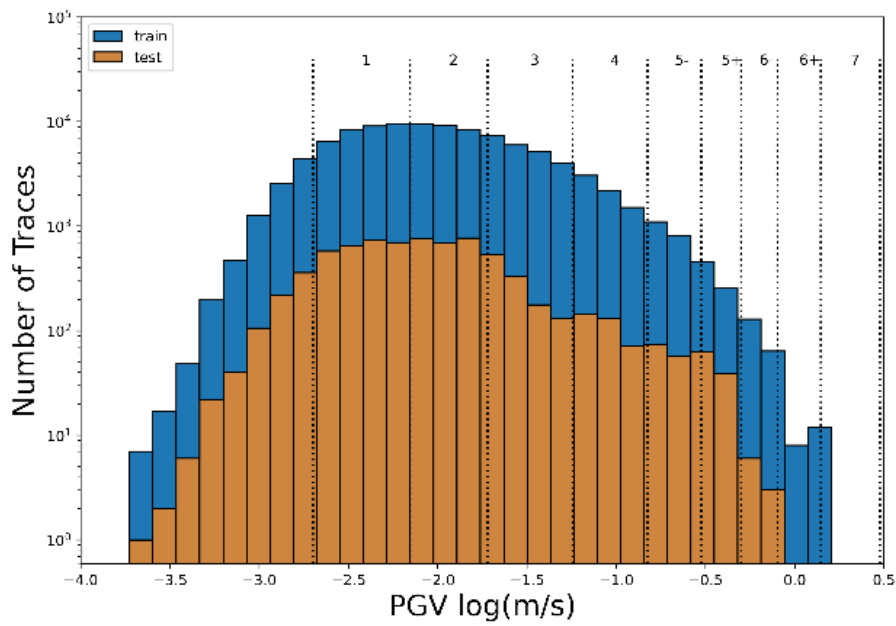
(a)



(b)



(c)



(d)

圖 2、1999-2019 年 TSMIP 記錄的地震事件分布，圖中分別呈現(a)規模、(b)深度、(c)空間、(d)PGV 的分布圖，其中訓練集資料以藍色表示，測試集為橘色。

引用低頻速度波形資料乃根據 Lin et al. (2018) 指出，於 2016 年美濃地震震央附近的波形中，可辨識出兩組 P 波與 S 波波相，分別對應於前震與主震，兩者相隔約 1.8 至 5.0 秒，進一步對波形進行 0.33Hz 低通濾波後，因前震規模較小而被濾除，僅留下主震明顯的波形特徵（圖 3）。因此，對於規模較大的地震而言，低頻濾波可有效消除與主震時間接近的小型地震影響，避免造成誤判。




圖 3、(a)速度波型、(b)使用 0.33Hz 低通濾波後的波形，上方的波形為 2016 年美濃地震；下方則為一震央與美濃地震相近，規模較小的地震，在美濃地震波形以 P₁、S₁ 為前震，P₂、S₂ 為主震，經由低通濾波後，P₁、S₁ 變的非常小，留下 P₂、S₂ 主要部分。（Lin et al., 2018）

近年來，有研究於 AI 模型訓練時不僅使用波形資料，更將波形轉換為其他物理特徵進行訓練（如：Zhu et al., 2022）。這種特徵工程（feature engineering）的方式屬於機器學習中常用手法，在透過提取或轉換原始數據中的關鍵特徵，以提升模型預測效果。因此，本研究針對原始波形進行特徵萃取，計算出三種具物理意義之特徵，包含：垂直方向的速度波形進行時間累加，用以反映地震動能量的累積所得到的 CVAV (Reed et al., 1990)、作為地震初期振福強度代表的 Pd (Wu et al., 2005)，與頻率相關的 \sqrt{Pd} 與 $\sqrt{\tau_c}$ 乘積所得之 TP (Huang et al., 2015)。

傳統地震預警系統常藉由震源參數估計與地動預估式預測地表震動，地動預估式能夠考慮地震波衰減特性及不同區域的場址效應，這些均為影響震度估計的重要因素 (Hsiao et al., 2011; Chen et al., 2012)。然而，傳統 TEAM 模型 (Münchmeyer et al., 2021) 僅使用加速度波形作為輸入，並未直接考慮場址效應。因此，本研究進一步將場址效應的代表性指標-- V_{s30} 作為測站資訊的額外輸入特徵。低 V_{s30} 值表示鬆軟地層，容易產生明顯的地震波放大效應；而高 V_{s30} 值則表示堅硬地層，放大效應相對較小 (Kuo et al., 2012)。

在資料前處理方面 (圖 4)，本研究利用 AR-AIC 自動挑波法 (Akazawa, 2004

自動判定 P 波到時，並透過人工檢視比對結果。意即，若自動與人工挑選之 P 波到時差超過 1 秒，則排除該筆紀錄；剔除波形存在損壞或明顯異常之資料，以確保資料品質。接著，將三分量波形以歐幾里得範數 (Euclidean Norm) 合成，計算每筆紀錄之 PGV。為進一步提升 P 波到時的精確性，本研究採用 Huang et al.(2014) 所建立的三維速度模型進行修正，以確保波形資料對應正確的地震事件。最終，根據第一個觸發測站的 P 波到時，擷取前 5 秒的背景噪訊及後 15 秒的地震波形作為輸入時間窗，提供模型進行訓練使用。

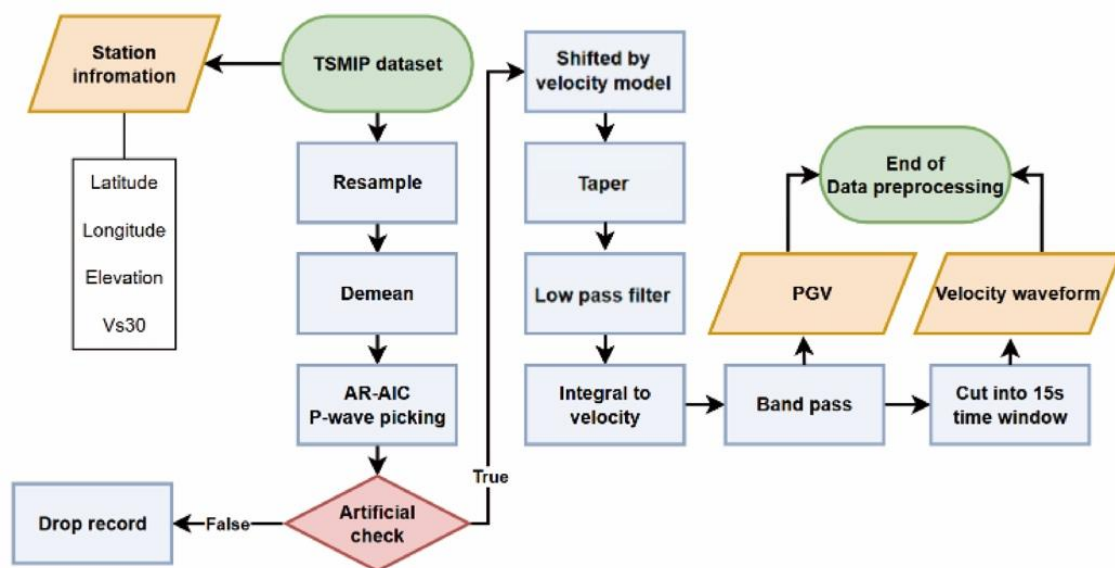


圖 4 本研究資料前處理流程圖。流程始於獲取 TSMIP 資料 (綠色膠囊形)，在波形前處理 (藍色矩形) 後，進行人工篩選波形 (紅色菱形)，最後將前處理成果輸出 (橘色平行四邊形)。通過此流程可以得到波形資料、測站資料 (包含：經度、緯度、高程、Vs30) 以及每個測站紀錄的 PGV。

參、研究方法

本研究之模型乃參考 TEAM (Münchmeyer et al., 2021) 的基礎所建立的。然而 TEAM 是依據日本及義大利的地震資料所設計，若模型直接套用於臺灣資料可能面臨準確度與適用性的限制，因此 TT-SAM 將模型架構微調，另外也在本研究中額外加入 V_{s30} 參數，提升模型在臺灣地區的預估表現。此外，原始 TEAM 模型採用 TensorFlow 1.14 與 CUDA 10.0 編寫，而現時 GPU 已不再支援此舊版驅動程式，模型在執行上將產生相容性問題，為此，我們將模型重構至 PyTorch 1.10.2 框架，以確保其能支援最新的硬體設備。

3.1 模型架構

本研究提出臺灣轉換器震動警報模型 (TT-SAM)，以針對臺灣的強地動特性及地震預警需求，其架構由三個主要部分組成 (圖 5)。

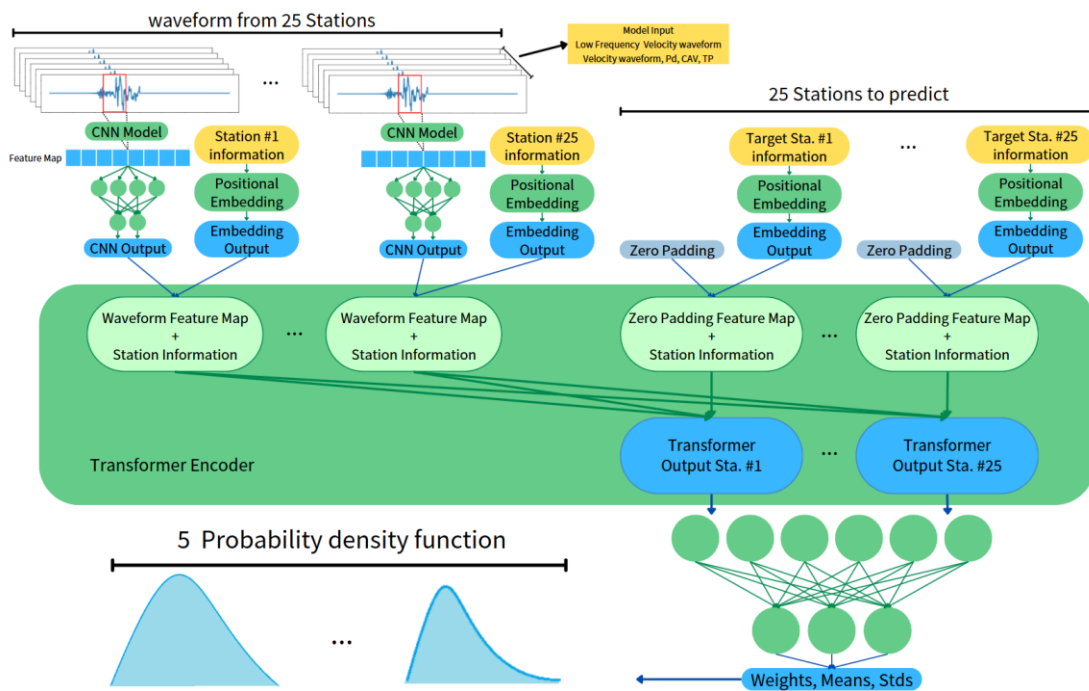


圖 5、此圖為本研究所提出之 TT-SAM 模型架構，圖中以不同顏色標示各模組功能：綠色區塊為模型主要結構、黃色為輸入資料、藍色則為模型輸出。模型輸入包括 25 個觸發測站的波形資料與測站資料，若輸入測站數不足 25 個，則以全零矩陣進行補足。輸入波形首先經由 CNN 進行特徵擷取，並輸出一組特徵圖。同時，測站資料 (如：經緯度、 V_{s30} 等) 經過 Positional Embedding 處理後，與 CNN 輸出進行特徵融合。結合後的資料輸入 Transformer Encoder 模組，透過自注意力機制建構輸入測站與目標測站之間的關聯性。最後，Transformer Encoder 的輸出將由五個高斯分布混合的方式表示預測之 PGV 的機率密度分布。

特徵擷取

在模型的起始，使用卷積神經網路（Convolution Neural Network，簡稱：「CNN」，O'shea et al., 2015）擷取波型特徵，在 CNN 中主要包含：正規化、卷積層、池化層和全連接層。輸入資料為觸發測站所記錄的三分量速度波形，擷取時間窗為 P 波初達第一個測站前 5 秒為起始時間到 P 波後 15 秒共 4,000 個數據點（每秒 200Hz）。

此外，本研究亦納入測站空間資訊，透過位置編碼（Positional Embedding, Vaswani et al., 2017）將測站地理資訊轉換為向量化表徵。轉換後的編碼向量與 CNN 輸出的波形特徵矩陣進行融合（採用矩陣加法方式），以結合時間序列特徵與空間資訊，作為後續模型運算之輸入。

建立測站關係

本研究導入基於自注意力機制的 Transformer Encoder 模型（Vaswani et al., 2017），以建構測站之間的空間與場址關聯。Transformer 架構最初應用於自然語言處理（Chowdhary et al., 2020）領域，並已成為目前主流大型語言模型（Large Language Models, Achiam et al., 2023）的核心技術，其於建立時間序列間交互關係方面展現出卓越能力。

在本研究中，Transformer Encoder 接收上個步驟特徵擷取的輸出，透過自注意力機制計算測站間的關聯程度。透過該模組，模型不僅能考慮地震波從震源傳遞至各測站的空間距離，亦能將場址效應與地層條件納入關聯建構中，進而提高對空間變異的辨識能力。

PGV 預估

在綜合目標測站和觸發測站的資訊後，透過混合密度網路（Mixture Density Network, Bishop, 1994），為每個目標測站生成五個高斯函數以進行預測，並賦予這些函數相應的權重。這種方法不僅提供 PGV 的估計值（以密度函數的平均值呈現），同時定義預估不確定性。意即，當混合密度函數的分布較窄時，表示模型對 PGV 的預估有較高的信心。

3.2 模型訓練流程

在模型訓練階段，資料被劃分為輸入測站與目標測站。模型輸入來自 P 波最先觸發的 25 個測站，包含其地震波形與測站特徵資訊；模型則需根據這些輸入預測目標測站的 PGV 值。

為提升數據分布的穩定性與模型學習效率，目標 PGV 在訓練前進行對數轉換，以壓縮數值範圍、減少極端值影響。模型訓練採用負對數似然損失函數（Negative Log Likelihood, Yao et al., 2020）作為目標函數，並使用 Adam 優化器

(Kingma et al., 2014) 進行參數更新。為避免過度擬合，採用 early stopping 機制，當驗證集損失值於若干個訓練週期 (epoch) 內未再下降時，自動終止訓練並保留驗證誤差最低的模型權重。

為模擬地震預警系統在資料尚未完全收集時進行預測的真實情境，本研究於訓練階段引入隨機時間遮罩策略。即對每筆輸入資料，於 P 波初達第一個測站後 3 至 15 秒之間，隨機選擇遮罩區間，將該段波形以全零矩陣取代。此設計可強化模型依賴地震初期訊號進行預測的能力，並能在地震進行中不同時間點持續提供即時預估。藉由學習不同長度波形資料下的特徵變化，模型可實現滾動式預測，隨著接收波形時間逐漸延長，自動更新預測結果，使預警系統能在震後提供逐步修正之預估值，提升其動態反應能力與實用價值。

此外，為強化模型在資料缺失狀況下的穩健性，亦針對輸入測站進行隨機測站遮罩，將其中隨機個數的輸入測站的波形與測站資訊以零矩陣替代。此策略可避免模型對特定測站過度依賴，並模擬地震期間測站可能異常或中斷的情境，有助於提升模型的泛化能力。

過往研究指出，使用深度學習方法進行震度預測時，常對於高震度樣本出現系統性低估的情形 (Böse et al., 2012; Münchmeyer et al., 2021)，主因可能為訓練集高震度樣本稀缺所致。為提升模型對高震度情境的學習能力，本研究採用以下兩種樣本增強策略：

Magnitude Oversample

針對規模大於 4.0 的地震事件，依照事件規模與設定之 oversample 係數：

$$\overline{\text{Repeat time}} = \text{int}(\alpha^{\text{mag}-1} - 1), \text{mag} \geq 4 \quad \text{式 1}$$

其中， α : oversample 係數， mag : 規模。當規模越大，在訓練中的重複次數越多。本研究設定 oversample 係數為 1.25。

此方式可增加大型地震事件在訓練週期中的出現頻率，提升模型暴露於高震度樣本的機會。

Bias to Close Station

當單一地震事件觸發的測站超過 25 個時，表示地震振幅可傳遞至較遠地區，而靠近震央的測站更可能觀測到高震度資料。訓練過程中，模型每次僅接收 25 個測站作為輸入，當超過該數量時，會將靠近震央的前 25 個測站重複用於多組訓練資料中，提升高震度樣本在訓練過程中出現頻率 (圖 6)。

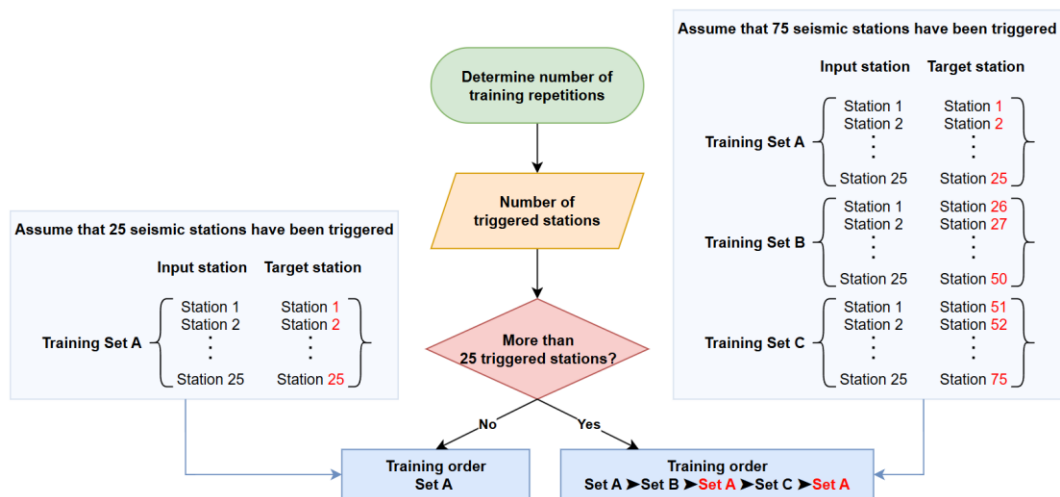


圖 6、Bias to Close Station 示意範例。測站依照 P 波初達時間進行排序，每 25 筆資料為一組，分別作為輸入與目標測站，若單一事件中觸發測站超過 25 個，訓練過程中會重複使用第一組（圖中的 Set A，也就是最早收到 P 波的 25 個測站）作為輸入資料，增加其在訓練中的出現頻率，以提升高震度資料比例。

綜合上述兩種策略，本研究有效提升了 TSMIP 資料中震度大於 4 級的樣本比例，有助於減少高震度預測的系統性低估。然而，由於樣本重複使用可能增加模型過擬合風險，本研究透過時間遮罩與測站遮罩機制導入隨機性，以提升樣本多樣性並增進模型的泛化能力。

肆、各模型與成果

4.1 速度波形

為驗證模型效能，本研究選擇 2016 年的地震事件作為測試資料集。使用準確率最高的第一個觸發測站收到 P 波後 7 秒所估算的結果，並與實際觀測震度（CWA 震度）進行比較。結果顯示，有 45.2% 的預測與觀測震度完全一致，且有 87.6% 的預測震度與實際值誤差在 ± 1 級以內（圖 7a）。

值得注意的是，模型在處理實際震度大於 3 級之事件時存在較明顯之低估現象（圖 7a-b）。特別是在震度 3 至 5+ 的區間中，部分樣本被低估至僅為震度 1 級，這些資料多源於 2016 年美濃地震。

造成模型低估的原因可能是美濃地震在速度波形上有較為明顯的多區域破裂特性（Lin et al., 2018），其主能量釋放並非集中於地震初期，而是分布於波形後段，導致模型於早期波形階段未能充分捕捉震動強度特徵，進而出現預估震度偏低之情形（圖 3）。

此外，TT-SAM 模型可依實際應用場景，自行設定不同之 PGV 閾值作為地震預警的觸發門檻。當模型預測 PGV 值超過該閾值，即視為需發布預警之事件。由於不同應用對震度容忍度之需求各異，本研究模型具備閾值靈活調整之特性，可依使用者實際情境與需求進行彈性設定。

為評估模型之預測效能，本研究採用精確率（Precision）、召回率（Recall）與 F1-score，分別分析模型於不同案例下之表現。其中，精確率（Precision）用於衡量模型所預測為正類的樣本中，實際為正類的比例，反映模型在「正類預測」上的可靠程度。高精確率代表模型產生較少的假陽性（false positives），因此在錯誤預測正類成本較高的應用情境中尤為重要；召回率（Recall）衡量所有實際為正類的樣本中，被模型正確識別出來的比例，反映模型捕捉正類樣本的能力。高召回率表示模型能有效降低假陰性（false negatives），適合應用於漏判正類後果嚴重的任務；F1-score 為精確率與召回率的調和平均數，用於在兩者之間取得平衡。當模型需要同時兼顧降低假陽性與假陰性，且資料類別分布不均時，F1-score 提供了一個整體且穩健的效能評估指標。

根據中央氣象署之預警發報標準，當地震預估規模達 5.0 以上且預估震度達 4 級，或規模達 6.5 以上且震度達 3 級時，系統將發布地震預警。若以震度 3 級作為警報觸發門檻，此模型之預測精確率為 71%，但召回率僅為 6%（圖 8a）。

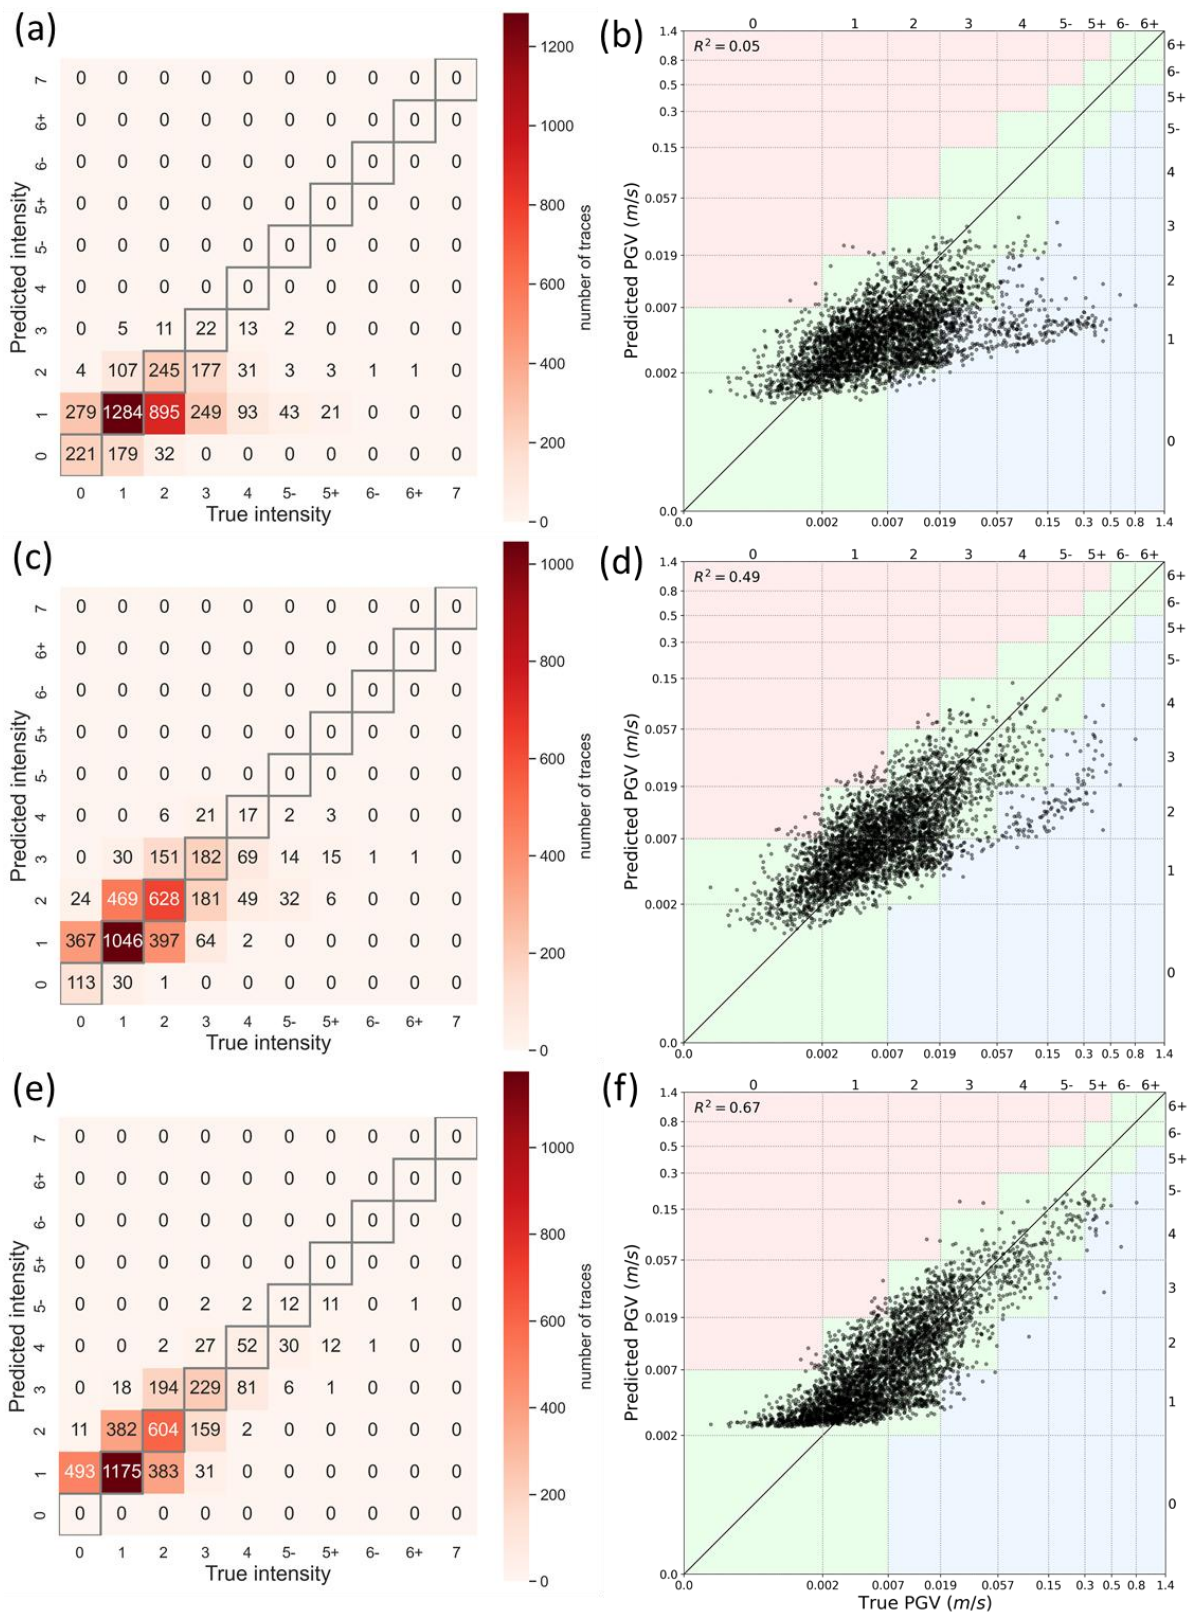


圖 7、三種模型在震度預測任務中的整體表現。圖 (a)(c)(e) 為預測震度與實際震度的混淆矩陣，格內數字表示對應震度配對之樣本數；圖 (b)(d)(f) 為預測與實際震度之散佈圖，對角線為理想預測線，並以 R^2 表示兩者之相關程度。(a)(b) 為僅

使用速度波形之模型，整體呈現低估現象， R^2 為 0.05；(c)(d) 為加入低頻速度波形後之模型，準確度提升，但在高震度區仍有低估情形， R^2 為 0.49；(e)(f) 為進一步加入 Pd、CVAV 與 TP 特徵後之模型，預測落於 ± 1 級範圍內者顯著增加，整體預測準確度最佳， R^2 提升至 0.67。

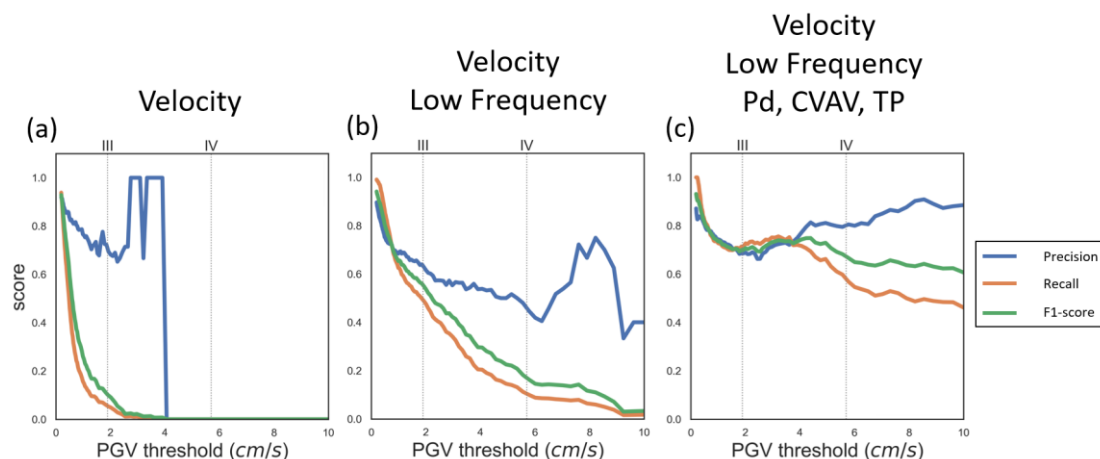


圖 8、本圖顯示三種模型於各自最佳預測秒數下的預警表現，分別為：(a) 7 秒、(b) 7 秒、(c) 13 秒。圖中以藍色、橘色與綠色曲線分別表示精確率 (Precision)、召回率 (Recall) 與 F1-score 隨 PGV 閾值變化之趨勢。虛線對應震度 3 級、4 級位置。整體而言，F1-score 與召回率隨著閾值提高而下降、隨時間延後而提升，第三種模型在各個閾值與時間秒數下表現皆最穩定。

此結果顯示，儘管模型在預測將發布警報事件時具有相對較高的正確性，但對實際應發布警報的事件，多數未能成功預測，反映其預警涵蓋能力極為有限，警報觸發靈敏度偏低。因此，在僅使用速度波形作為輸入的情況下，雖能保持較高的精確率，但在強震事件中仍可能產生嚴重漏報風險，對實務地震預警系統之應用將形成限制因素。

4.2 速度波形與低頻率速度波形

本模型在輸入資料中，除使用原始速度波形外，另納入經 0.33 Hz 低通濾波處理之低頻速度波形，以提升模型對地震事件內長周期訊號的感知能力。結果顯示，模型預測與觀測震度完全一致之比例由前模型之 45.2% 提升至 50.7%，而預測震度誤差落於 ± 1 級範圍內之比例亦由 87.6% (圖 7a) 提升至 93.7% (圖 7c)。

對高震度事件進一步分析發現，低頻速度波形的加入有助於緩解原模型在震度 3 級以上事件中所呈現之系統性低估情形。在原模型中被低估為震度 1 級之部分資料點，於加入低頻波形後，其預測結果更接近實際震度，顯示模型對高震度樣本表現略有提升，但整體仍存在低估現象 (圖 7d)。加入低頻成分可減少初期波形震動較小造成的誤判，有助於改善強震預測表現。

此外，以震度 3 級作為警報觸發門檻時，該模型之預測精確率為 63%，召回率則大幅提升至 49%（圖 8b），顯示其預估能力優於僅使用速度波形之模型。

整體而言，第二種模型在提升召回率方面成效顯著，雖然精確率略低於第一種模型，但穩定性更高。在分析不同 PGV 閾值下的變化趨勢可觀察到，當閾值超過 4 cm/s 後，精確率呈現上升趨勢。此現象顯示，模型在高閾值下預估傾向保守，減少預警次數，從而提升預測準確性，但相對地亦可能增加漏報風險，顯示在誤報與漏報之間仍存在取捨空間。

4.3 加入物理特徵

此模型在原有的速度波形與低頻速度波形基礎上，進一步加入三項以波形處理為基礎之物理特徵：Pd、CVAV 與 TP。這些特徵皆可視為來自原始地震波形的轉換特徵，透過對地震初期訊號進行擷取與加工，強化模型對震源物理意涵的感知能力。此一設計概念源自於特徵工程--將原始數據進行處理與轉換，以擷取更具代表性、與預測目標高度相關的關鍵資訊。三者在地震度預測任務中，均提供了額外的物理判別依據，有助於模型理解地震規模與震動強度之潛在關聯。

模型訓練與評估方式與前述相同，選用 2016 年地震事件作為測試資料集，並使用準確率最高的第一個觸發測站收到 P 波後 13 秒所估算的結果。結果顯示，預測與觀測震度完全一致之比例進一步提升至 52.8%，而預測誤差落於 ± 1 級範圍內之比例亦達 97.8%（圖 7e），為本研究所有模型中整體準確性最佳者。

進一步觀察高震度事件之預測表現，本模型幾乎所有樣本皆落於 ± 1 級的誤差範圍內，顯著緩解初始模型在震度 3 級以上事件中系統性低估現象。預測與實際震度間的相關性亦大幅提升， R^2 值由初始模型之 0.05（圖 7b），經加入低頻波形後提升至 0.49（圖 7d），並於本模型中進一步上升至 0.67（圖 7f），顯示其對震度預估的能力最為優越。

此外，在 P 波初達後 13 秒之輸入條件下，以震度 3 級作為警報觸發門檻時，模型的精確率達 69%，召回率達 71%（圖 8c），為三種模型中整體表現最佳者。

此模型在更高震度對應之 PGV 閾值（如震度 4 級 ≈ 5.7 cm/s）下，精確率可提升至 80%，而召回率仍維持在 58% 的水準（圖 8c），顯示其在提升預測準確度的同時，仍能保有良好的警報涵蓋能力。整體而言，第三種模型在精確率與召回率之間取得相對平衡，能有效兼顧誤報與漏報問題，顯示其具備高度實務應用潛力。進一步觀察其 F1-score（圖 8c），在震度 3 級與 4 級對應之 PGV 閾值下分別達 0.70 與 0.67，為三種模型中最高者。F1-score 為精確率與召回率的調和平均，可作為衡量模型整體預警效能之指標，反映模型在誤報控制與警報覆蓋間的綜合表現。

透過引入 Pd、CVAV 與 TP 等轉換後的物理特徵，模型得以兼具波形時序與震源物理特性的多重資訊來源，進一步提升了對震度強弱之判別能力。此結果亦證實特徵工程應用於地震預警中的潛力，未來可進一步探索其他物理量作為輔助特徵，以強化模型在不同震源類型下的泛化與適應能力。

綜合分析可見，三種模型在輸入特徵的逐步增強下，預測效能有明顯改善。第一種模型雖能大幅降低誤報，但召回率極低，顯示其對應警報事件的辨識能力不足。隨著模型納入低頻訊號與多項物理特徵，預測準確度與警報涵蓋率均同步提升，第三種模型則在精確率與召回率之間達到最佳平衡，整體效能最為穩定。此外，隨著預警秒數延長，模型接收到的波形資訊越多，F1-score 與召回率均隨之上升（圖 9）。未來地震預警系統的實務應用，可考慮加入更多物理特徵，並在預警時效與預測準確性之間尋求最佳平衡。

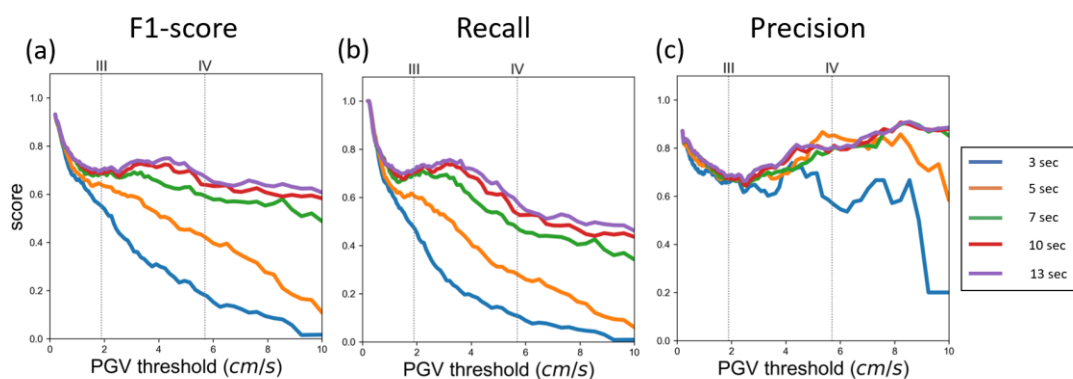


圖 9、加入低頻波形與三項物理特徵（Pd、CVAV、TP）之模型在不同預警秒數下的預警效能表現。圖中分別顯示該模型於不同預警秒數下的 F1-score (a)、召回率 Recall (b) 與精確率 Precision (c) 曲線。由圖中不同顏色曲線可見，隨著預警秒數延長，模型接收到的波形資訊越多，F1-score 與召回率皆穩定上升，顯示預警時間對模型效能具有正向影響。

4.4 預警時間

在地震預警系統中，預警時間意指系統發出警報至最大強地動（PGV）抵達測站之間的時間差，預警時間越長，代表使用者有越多時間採取緊急應變。本節將針對 2016 年兩起規模大於 6.0 的地震事件，分析本研究模型於預警時間之表現。

在發布警報的部分，我們採取滾動式預測的方式，以提升效率。先前提及如何在預警速度與準確率之間取得平衡，是地震預警中的重要部分，若等候模型收集更多資料以獲得更穩定的預測結果，雖有助於提升預測精確度，卻也可能導致近震區失去寶貴的反應時間。有鑑於此，滾動式預測策略允許模型在地震初期即快速預測，當模型在早期即判定某測站可能達到預警閾值時，即立即發出警報，無需等候預測完全收斂。隨著更多波形資料接收與處理，模型會逐步更新預測結果，並針對尚未收到預警的測站陸續發布預報，使召回率隨時間提升（圖 8）。

在美濃地震的回測中，模型可在 P 波初達 3 秒後，立即給出預測，並且能夠提供平均 14.21 秒的預警時間（圖 10a）。然而，此時能夠預警的測站數量只有 85 個。此案例中滾動式預測的策略就能發揮作用，在 P 波初達 13 秒後，模型能給出

平均 11.29 秒的預警時間，雖然因為時間多了 10 秒，提供的預警時間有所降低，但是成功發出警報的測站增加到了 203 個，以此兼具了預警速度以及預估準確率。而在臺東外海地震的回測中，模型在 P 波初達 3 秒後，能給出平均 10.11 秒的預警時間，並且對 32 個測站發出警報（圖 10b），但因為此地震影響的範圍較小，因此在 P 波初達 13 秒後，大部分需要發布預警的地區，已經接收到 PGV，造成地震預警盲區，導致發出有效警報的測站數量下降到 10 個，也應證了在地震早期發布警報，能有效避免追求準確率而錯失預警時間。

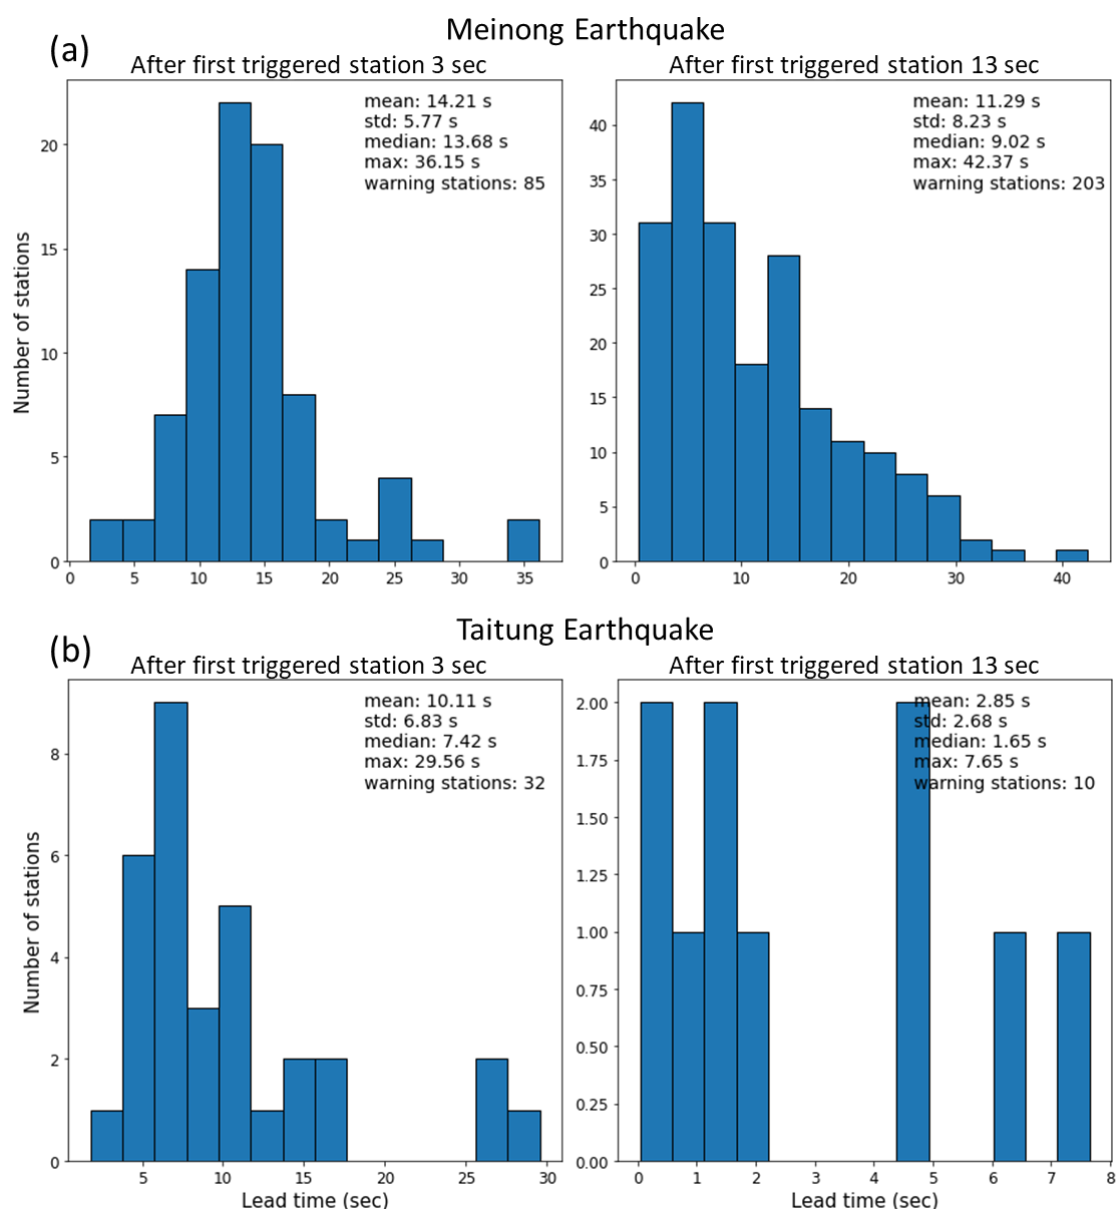


圖 10、(a) 美濃地震與 (b) 臺東外海地震事件中，模型於 P 波初達後第 3 秒與第 13 秒所產生之預警時間統計分布。圖中以直方圖呈現不同測站所獲得之預警時間，預警時間定義為模型發布警報至該站最大地動（PGV）抵達之時間差。

伍、討論與結論

5.1 低頻率波形及其他物理特徵的影響（美濃地震低估及改善方法）

在過去的地震預警研究中，多數經典方法僅依賴單一物理特徵（Brondi et al., 2015, Wu et al, 2016）進行震度或地震強度估算，亦有部分機器學習方法僅使用原始加速度波形或速度波形作為模型輸入（Münchmeyer et al., 2021; Bloemheugel et al., 2023），忽略了其他具代表性的震波特徵與頻率資訊。

在本研究初期階段，亦嘗試以單一的速度波形資料訓練模型，但訓練結果顯示預測效能明顯不足。對模型預測錯誤進行分析後發現，其主要問題集中於對高震度事件的系統性低估（圖 7），此現象可能與大規模地震具有複雜破裂特性有關。

因此本研究嘗試引入低頻率速度波型作為輸入，低頻率波型能有效過濾掉較小的地震，並保留較大地震的特徵，避免造成誤判（Lin et al., 2018）。另外本研究導入了三項具物理意義的特徵參數：Pd、CVAV、TP，作為機器學習常用之特徵工程的一環，協助模型提取原始波形中難以直接學習的震動特徵與破裂模式。

實驗結果顯示，加入低頻波形與物理特徵後，模型在召回率、F1-score 與 R^2 等評估指標上皆有顯著提升，預測準確性明顯優於僅使用速度波形的模型（圖 8）。以測試資料中的 2016 年美濃地震為例（圖 11），初期模型在該事件中出現明顯低估現象，在導入低頻波形後已有改善，最終結合多項物理特徵後，預測結果與實際觀測震度的整體分布最為接近，證實這些物理特徵於強震辨識中的幫助。

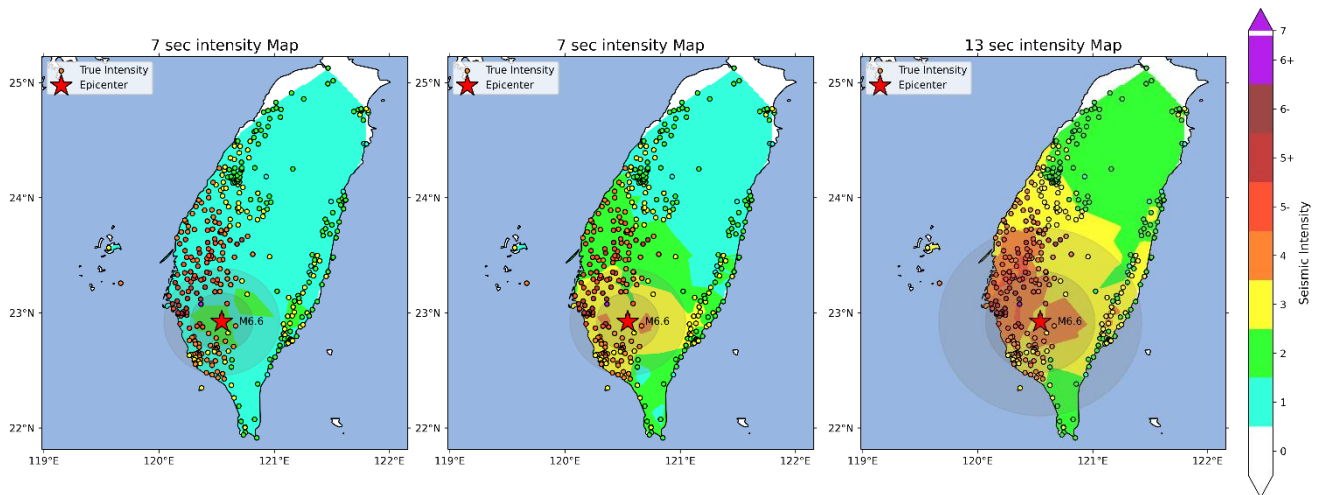


圖 11、本研究針對 2016 年 2 月 6 日美濃地震（規模 6.6）進行震度預測結果比較。圖中圓點表示測站位置，其顏色代表該站實際觀測震度，背景色區則為模型預估震度分布。左、中、右三圖分別對應三種模型輸入：速度波形、速度波形結合低頻速度波形，以及整合三項具物理意義之特徵（Pd、CVAV、TP）。第一種模型呈現明顯低估；加入低頻波形後，震度分布趨於合理但仍偏低；最終整合多項物理特徵後，模型成功捕捉更完整之震度擴散區域，整體預測表現最佳。

5.2 訓練秒數對結果的影響

為模擬地震發生初期波形尚不完整的實際情境，本研究於模型訓練階段設計「秒數遮罩策略」，即在每筆訓練資料中，隨機選取 P 波初達後 1 至 15 秒中的任一時刻作為遮罩點，將其後段波形以全零矩陣取代。此策略可提升模型在早期波形資訊不足時之預測能力，並加強模型的泛化性能。

然而，實驗發現此策略可能導致偏誤：由於遮罩時間為平均隨機，模型在訓練中接收到的多為 P 波後段以前的波形，對於波形尾端的學習相對不足。例如，若遮罩設於第 7 秒，模型實際可見之有效波形即僅至 P 波後第 7 秒，其後為零（圖 12）。長期累積下，模型偏重早期特徵，難以學習完整訊號。




圖 12、本圖顯示 2016 年美濃地震中一筆速度波形資料，五組波形分別對應不同訓練秒數遮罩設定。紅線為 P 波初達時刻，灰色區域代表遮罩區段，其波形以全 0 矩陣取代。上兩圖為模型輸入長度為 P 波初達前 5 秒至後 10 秒之情境，分別對應遮罩起始於 P 波後 7 秒，以及未進行遮罩之設定。下三圖則為輸入長度延長至 P 波後 15 秒，遮罩起始時刻分別為 P 波後 7 秒、13 秒與無遮罩情況。

此現象亦反映於第二種模型（使用速度與低頻率速度波形）之實驗結果中。觀察結果顯示，模型於 P 波後第 7 秒時的預測表現，反而優於第 10 秒（圖 13(a)），即使後者具備更完整波形，推測原因為模型對後段特徵學習不足所致。

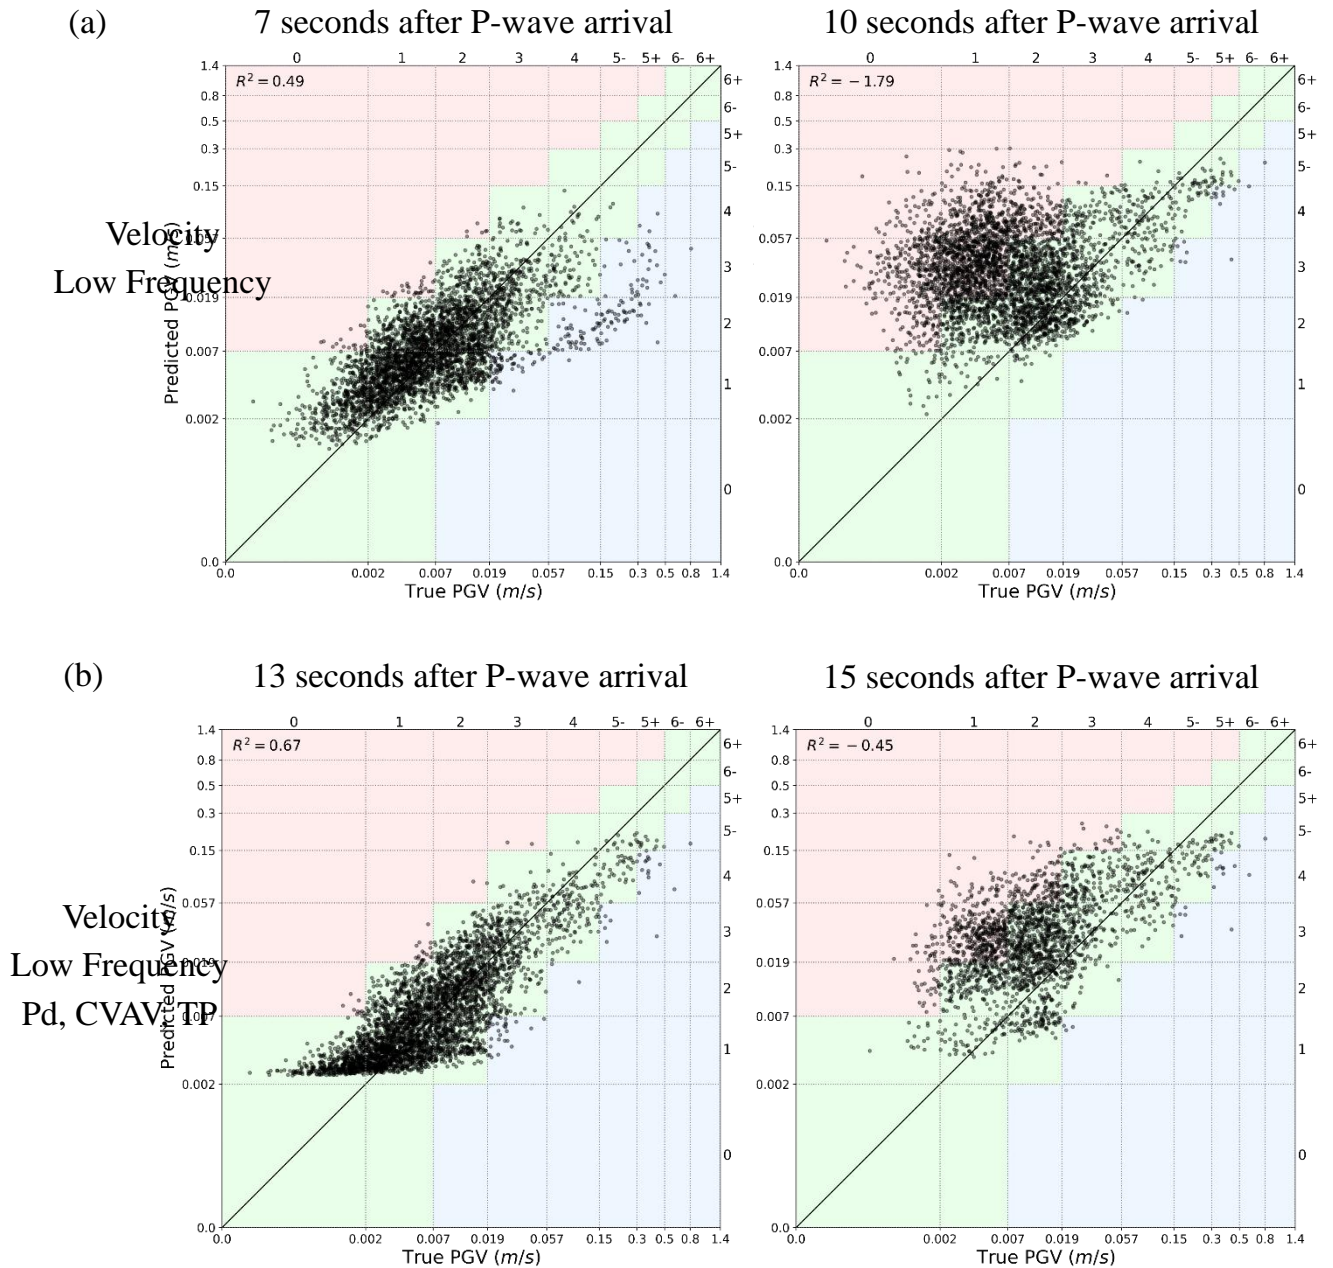


圖 13、 在不同預警秒數下之 PGV 預測準確度比較。(a) 模型輸入包含速度波形與低頻率速度波形，圖中顯示模型於 P 波初達後第 7 秒與第 10 秒的預測結果。第 7 秒之 R^2 為 0.49，具一定預測準確度，但至第 10 秒時反而降至 -1.79，顯示模型於後段波形特徵的學習成效不佳，可能導致預測結果與實際值的相關性下降。(b) 當模型輸入額外加入三項具物理意義之特徵 (Pd、CVAV、TP) 後， R^2 整

體表現顯著提升，且能準確預估更後段時間的波形資訊。然而，模型在第 15 秒的 R^2 亦呈現下降，驗證了我們對於模型於後段波形特徵學習能力仍有限的推測。

為改善上述問題，本研究於第三種模型中調整訓練波形長度，將原先的 P 波前 5 秒至後 10 秒延長為前 5 秒至後 15 秒（圖 12），以強化模型對震波後段特徵的學習能力。儘管第三種模型同時也加入了三種具物理意義之特徵，但從實驗結果可觀察到，預測效能隨時間推進而穩定提升，於 P 波後第 13 秒達到最佳分數。相較於第二種模型在第 10 秒出現預測下滑，第三種模型的預測表現直到第 15 秒才有所下降（圖 13(b)）。此一趨勢間接驗證了遮罩偏誤對模型學習結果之影響。透過延長訓練波形長度，不僅能彌補遮罩設計所造成之缺口，也有助於延長預測涵蓋的時間範圍，配合本研究所採用之滾動式預警策略，可提供更為連續與完整的預測更新。

而延長波形長度也需要權衡模型的計算效率以及實際應用時的時效性。雖然更長的輸入有助於提升預測準確性，但亦增加模型複雜度與計算成本，且實務上過於延後之預警訊息可能已失去意義。因此，本研究認為將訓練波形設為 P 波初達後 15 秒，在預測準確性與運算效率之間取得良好平衡。

參考文獻

- Achiam, J., Adler, S., Agarwal, S., Ahmad, L., Akkaya, I., Aleman, F. L., ... & McGrew, B. (2023). Gpt-4 technical report. arXiv preprint arXiv:2303.08774.
- ALLEN, Richard M.; KANAMORI, Hiroo. The potential for earthquake early warning in southern California. *Science*, 2003, 300.5620: 786-789.
- ALLEN, Richard M.; MELGAR, Diego. Earthquake early warning: Advances, scientific challenges, and societal needs. *Annual Review of Earth and Planetary Sciences*, 2019, 47.1: 361-388.
- Bishop, C. M. (1994). Mixture density networks.
- BLOEMHEUVEL, Stefan, et al. Graph neural networks for multivariate time series regression with application to seismic data. *International Journal of Data Science and Analytics*, 2023, 16.3: 317-332.
- Böse, M., Heaton, T. H., & Hauksson, E. (2012). Real-time finite fault rupture detector (FinDer) for large earthquakes. *Geophysical Journal International*, 191(2), 803-812.
- Brondi, P., Picozzi, M., Emolo, A., Zollo, A., & Mucciarelli, M. (2015). Predicting the macroseismic intensity from early radiated P wave energy for on-site earthquake early warning in Italy. *Journal of Geophysical Research: Solid Earth*, 120(10), 7174-7189.
- Chen, D. Y., Lin, T. L., Wu, Y. M., & Hsiao, N. C. (2012). Testing a P-wave earthquake early warning system by simulating the 1999 Chi-Chi, Taiwan, Mw 7.6

- earthquake. *Seismological Research Letters*, 83(1), 103-108.
- Chowdhary, K., & Chowdhary, K. R. (2020). Natural language processing. *Fundamentals of artificial intelligence*, 603-649.
- Chung, A. I., Henson, I., & Allen, R. M. (2019). Optimizing earthquake early warning performance: ElarmS-3. *Seismological Research Letters*, 90(2A), 727-743.
- Gutenberg, B., & Richter, C. F. (1942). Earthquake magnitude, intensity, energy, and acceleration. *Bulletin of the Seismological society of America*, 32(3), 163-191.
- Hoshiya, M. (2013). Real-time prediction of ground motion by Kirchhoff-Fresnel boundary integral equation method: Extended front detection method for earthquake early warning. *Journal of Geophysical Research: Solid Earth*, 118(3), 1038-1050.
- Hsiao, N. C., Wu, Y. M., Zhao, L., Chen, D. Y., Huang, W. T., Kuo, K. H., ... & Leu, P. L. (2011). A new prototype system for earthquake early warning in Taiwan. *Soil Dynamics and Earthquake Engineering*, 31(2), 201-208.
- Huang, P. L., Lin, T. L., & Wu, Y. M. (2015). Application of $\tau_c^* Pd$ in earthquake early warning. *Geophysical Research Letters*, 42(5), 1403-1410.
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- KODERA, Yuki, et al. The propagation of local undamped motion (PLUM) method: A simple and robust seismic wavefield estimation approach for earthquake early warning. *Bulletin of the Seismological Society of America*, 2018, 108.2: 983-1003.
- Kuo, C. H., Wen, K. L., Hsieh, H. H., Lin, C. M., Chang, T. M., & Kuo, K. W. (2012). Site classification and V_{s30} estimation of free-field TSMIP stations using the logging data of EGDT. *Engineering Geology*, 129, 68-75.
- Lin, Y. Y., Yeh, T. Y., Ma, K. F., Song, T. R. A., Lee, S. J., Huang, B. S., & Wu, Y. M. (2018). Source characteristics of the 2016 Meinong (ML 6.6), Taiwan, earthquake, revealed from dense seismic arrays: Double sources and pulse-like velocity ground motion. *Bulletin of the Seismological Society of America*, 108(1), 188-199.
- Liu, Kun-Sung, Tzay-Chyn Shin, and Yi-Ben Tsai. (1999). A free-field strong motion network in Taiwan: TSMIP. *Terrestrial, Atmospheric and Oceanic Sciences*, 10(2), 377-396.
- MEIER, Men-Andrin, et al. How often can earthquake early warning systems alert sites with high-intensity ground motion?. *Journal of Geophysical Research: Solid Earth*, 2020, 125.2: e2019JB017718.
- Münchmeyer, J., Bindi, D., Leser, U., & Tilmann, F. (2021). The transformer earthquake alerting model: A new versatile approach to earthquake early warning. *Geophysical Journal International*, 225(1), 646-656.
- O'shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. *arXiv*

preprint arXiv:1511.08458.

- Reed, J. W., & Kassawara, R. P. (1990). A criterion for determining exceedance of the operating basis earthquake. *Nuclear Engineering and Design*, 123(2-3), 387-396.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- Wu, Y. M., Hsiao, N. C., & Teng, T. L. (2004). Relationships between strong ground motion peak values and seismic loss during the 1999 Chi-Chi, Taiwan earthquake. *Natural Hazards*, 32(3), 357-373.
- Wu, Y. M., & Kanamori, H. (2005). Rapid assessment of damage potential of earthquakes in Taiwan from the beginning of P waves. *Bulletin of the Seismological Society of America*, 95(3), 1181-1185.
- Wu, Y. M., Liang, W. T., Mittal, H., Chao, W. A., Lin, C. H., Huang, B. S., & Lin, C. M. (2016). Performance of a low-cost earthquake early warning system (P-alert) during the 2016ML 6.4 Meinong (Taiwan) earthquake. *Seismological Research Letters*, 87(5), 1050-1059.
- Yao, H., Zhu, D. L., Jiang, B., & Yu, P. (2020). Negative log likelihood ratio loss for deep neural network classification. In *Proceedings of the Future Technologies Conference (FTC) 2019: Volume 1* (pp. 276-282). Springer International Publishing.
- ZHU, Jingbao; LI, Shanyou; SONG, Jindong. Hybrid deep-learning network for rapid on-site peak ground velocity prediction. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-12.

114 年地震預警作業技術研發之相關研究

子計畫三

基於人工智慧技術開發以震度預測為基礎之地震預警系統

金台齡 鄭師漢 黃淞峰 黃煥廷 黃恩祈

國立臺灣科技大學

摘要

地震為臺灣常見且具破壞性的天然災害，快速而準確的地震預警系統對於降低災損至關重要。然而，傳統預警系統在事件初期的有限資訊下，常面臨即時性與準確度的挑戰。為此，本研究利用先進的人工智慧技術，開發一套以震度預測為基礎的地震預警系統，專注於提升地震發生初期的預測效能與穩定性。

本研究報告涵蓋三大核心方向：(1) 區域型地震預測模型：提出一項優化的 C-GAT (Contrastive-enhanced Multi-Perspective Graph Attention Network) 模型，其結合多視角圖注意力網路 (MP-GAT) 骨幹與 BYOL (Bootstrap Your Own Latent) 自監督預訓練框架。此「無負樣本」設計專注於學習純粹的波形動態，成功解決了標準對比學習的「負樣本衝突」問題，顯著提升了模型在地震初期 (P 波後數秒) 有限資訊下的預測準確度，尤其強化了對高 PGA 事件的早期辨識能力。(2) 地震資料生成應用：為解決高震度樣本稀少所導致的模型低估問題，本研究成功開發一條條件式地震波形生成模型，用以合成物理上合理的地震資料。研究證實，使用此「生成資料增強」之數據集，能顯著改善預警模型對大規模地震的低估現象。(3) 即時地震預警系統：建構一套整合 AI 模型的即時預警系統，透過引入 MQTT 協議加速資料傳輸，並利用 Docker 容器化技術實現模組化部署。此系統能即時處理測站波形、預測 PGA，並透過 Telegram Bot 發送警報，驗證了 AI 模型在無需傳統 Earthworm 系統下的可行性。

綜合而言，本研究成功建立了一套從 AI 模型優化、資料生成補強，到即時系統部署的完整地震預警解決方案。研究成果證實，所提出的 C-GAT 模型能有效提升地震初期的預測敏感度與準確性；資料生成技術則為解決強震樣本不足提供了關鍵手段；而基於 MQTT 與 Docker 的即時系統，更展示了高效能、具擴展性的新一代預警架構。本研究展現了深度學習技術在提升地震預警效能上的顯著效益與實務價值。

關鍵字：類神經網路、地震預警系統、最大加速度預測、資料生成。

Abstract

Earthquakes are a common and destructive natural disaster in Taiwan, making a rapid and accurate earthquake early warning (EEW) system crucial for mitigating damage and loss. However, traditional warning systems often face challenges in timeliness and accuracy due to limited information in the initial moments of an event. To address this, this study utilizes advanced artificial intelligence technologies to develop an EEW system based on ground-shaking level prediction, focusing on enhancing the predictive performance and stability during the early stages of an earthquake.

This research report covers three core directions: (1) Regional Earthquake Prediction Model: An optimized C-GAT (Contrastive-enhanced Multi-Perspective Graph Attention Network) model is proposed, combining an MP-GAT (Multi-Perspective Graph Attention Network) backbone with a BYOL self-supervised pre-training framework. This "negative-sample-free" design focuses on learning pure waveform dynamics, successfully resolving the "negative sample conflict" problem of standard contrastive learning. It significantly improves the model's prediction accuracy under the limited information available in the early stages of an earthquake (seconds after the P-wave arrival), especially enhancing the early recognition capabilities for high-PGA events. (2) Earthquake Data Generation Application: To solve the model underestimation problem caused by the scarcity of high-intensity event samples, this study successfully developed a conditional waveform generation model to synthesize physically plausible seismic data. Research confirms that using this "generative data augmentation" dataset can significantly ameliorate the underestimation of large-scale earthquakes by the warning model. (3) Real-time Earthquake Early Warning System: A real-time warning system integrating AI models was constructed. It accelerates data transmission by introducing the MQTT protocol and achieves modular deployment using Docker containerization technology. This system can process station waveforms in real-time, predict PGA, and send alerts via a Telegram Bot, validating the feasibility of AI models operating without the traditional Earthworm system.

In summary, this study establishes a complete EEW solution, from AI model optimization and data augmentation to real-time system deployment. Results show the C-GAT model enhances early-stage prediction sensitivity and accuracy. The data generation technology solves the challenge of insufficient strong-motion samples. Furthermore, the MQTT and Docker-based real-time system provides a high-performance, scalable, new-generation architecture. This research highlights the benefits and practical value of deep learning in advancing EEW performance.

Keywords : Neural Network · Earthquake Early Warning System · PGA Prediction · Data Generation.

壹、前言

臺灣位處環太平洋地震帶，地震活動頻繁，對基礎設施與民眾安全構成實質威脅。2024年4月的花蓮地震再次凸顯了地震預警系統之重要性，唯有在地震波抵達前數秒即完成地動強度估算，方能爭取足夠反應時間、有效降低災損。然而，傳統預警系統在處理地震初期（P波後3至15秒）的有限資訊時，常面臨預測精度與即時性的權衡。本研究旨在引入深度學習等先進人工智慧技術，以提升地震預警核心模組的效能與穩定性。

本報告書涵蓋三大研究方向。首先，針對區域型預警情境，本研究提出一項優化的C-GAT（Contrastive-enhanced Multi-Perspective Graph Attention Network）模型。此架構改採BYOL（Bootstrap Your Own Latent）自監督預訓練框架，透過「無負樣本」的設計，成功解決了標準對比學習中的「負樣本衝突」問題，使模型能從地震初期的短時間窗波形中，學習到穩健且具代表性的特徵。

其次，為解決高震度事件樣本稀少所導致的模型低估問題，本研究開發一條件式地震波形生成模型。接著，利用此模型與GMPE經驗公式，合成關鍵的高震度地震資料以增強訓練集。實驗證實，此「生成資料增強」方法能顯著改善預警模型對大規模地震的低估現象。

最後，本研究建構一套即時地震預警系統，其無需傳統Earthworm系統即可整合AI模型。系統透過引入MQTT協議加速資料傳輸，並以Docker容器化實現彈性部署。此架構能即時接收測站數據、進行AI驅動的PGA預測，並迅速透過Telegram Bot發送警報。

本報告將詳述上述各項技術模組之設計與執行成果，並透過實際地震事件進行效能評估，以作為後續預警系統整合應用與擴充佈署之基礎。

貳、類神經網路應用於區域型地震預警

2.1 簡介

本研究致力於發展一項結合圖神經網路（GNN）技術，利用P波抵達前後的早期三軸加速度波形資料，進行目標測站峰值地動加速度（PGA）即時預測之方法。核心目標為透過鄰近震央的少數偵測站點，於地震波傳抵其他都會區域前，迅速且準確地預估其PGA，以達成有效的區域型地震早期預警。本研究特別聚焦於優化地震發生後3至15秒內，此類極短時間窗波形資訊的PGA預測效能。

本研究延續期中報告所提出之多視角圖注意力網路（Multi-Perspective Graph Attention Network, MP-GAT）作為模型骨幹，該架構已證實能有效融合測站間的空間傳播關係，期中研究也已初步驗證，引入對比學習（Contrastive Learning）預訓練策略，有助於模型在僅觀測地震剛發生時短時間的波形時，學習到更穩定的特徵表示。

然而，為進一步提升模型在地震初期的預測精準度，本研究深入探討了原預訓

練策略的潛在限制。我們發現標準對比學習不僅存在「負樣本衝突」問題，可能錯誤地將相似 PGA 事件推開；同時，在使短窗對齊長窗的過程中，也存在「特徵毀損」的風險，亦即長窗的穩定特徵表示可能反被短窗的不完整資訊所干擾。

為此，本期末報告提出一項優化的自監督學習框架。我們改採 BYOL (Bootstrap Your Own Latent) 策略，此一「無負樣本」的設計從根本上避免了表示衝突問題。此一設計旨在強迫模型專注於從純粹的波形動態中提取關鍵特徵，讓短時間窗的輸入得以學習到完整波形的穩定表示，同時確保長窗特徵的準確性不被影響，最終建立更具區辨性的短窗表徵。

本研究旨在驗證此一新型策略，能更有效地學習短時間窗內的地震動態特徵，進而顯著提升模型在地震發生初期（3 至 15 秒）的 PGA 預測準確性，為地震早期預警系統奠定更穩健的技術基礎。

2.2 模型介紹

本研究採用的模型核心骨幹依然是多視角圖注意力網路 (MP-GAT)，透過多個視角的注意力機制，為每個節點分配不同的權重，從而更全面地捕捉節點之間的關聯。

基於此骨幹，本研究提出一組新的自監督學習與微調架構 (Contrastive-enhanced Multi Perspective Graph Attention Network, C-GAT)。此架構由輸入模組、卷積神經網路 (CNN) 特徵提取器、位置嵌入 (Position Embedding) 模組、MP-GAT 骨幹網路，以及依據訓練階段切換的對比學習模組與回歸模組所共同組成。

本模型的核心設計重點，在於引入 BYOL 對比學習框架，並將其應用於節點級的特徵表示。更關鍵的是，在對比學習預訓練階段，我們刻意將位置嵌入模組移除，僅讓 C-GAT 學習純粹的波形特徵。此「位置解耦」策略旨在強迫模型專注於短時間窗波形本身的動態變化，而非依賴地理位置此一靜態特徵，期望學習到更具預測性的特徵表示。

2.2.1 骨幹網路架構 (MP-GAT)

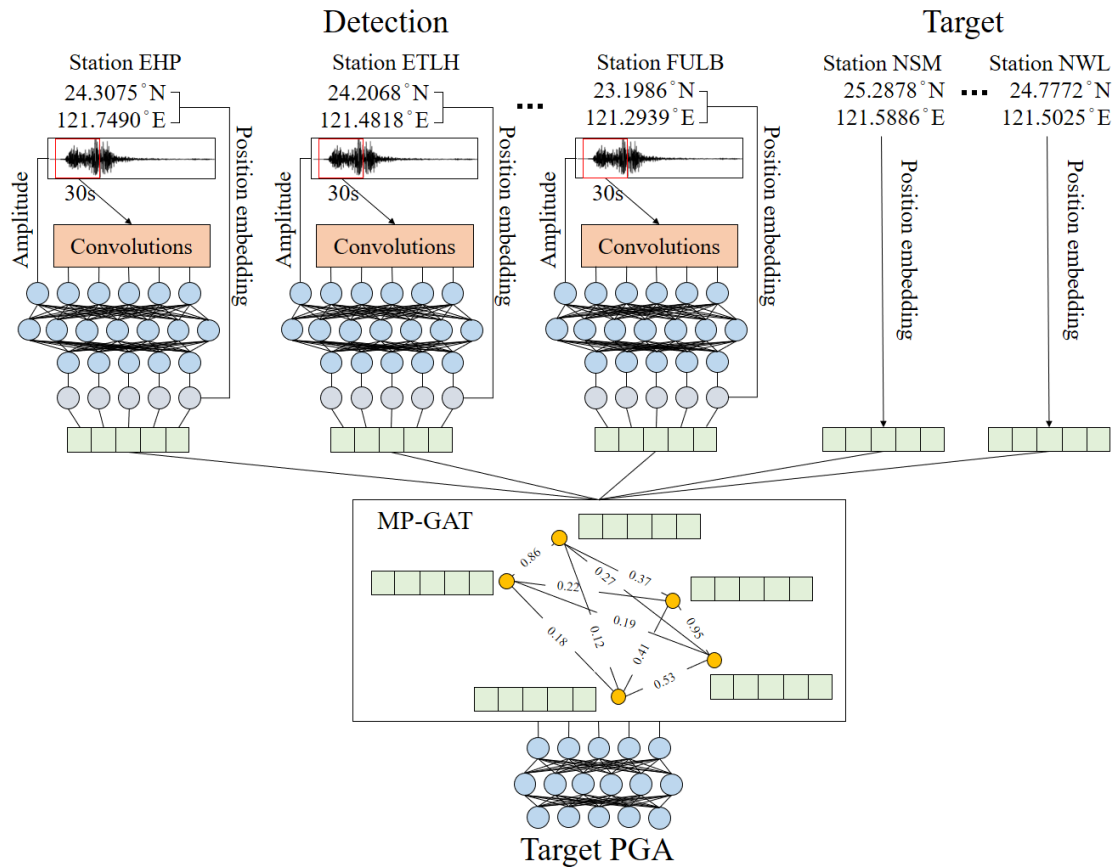


圖 1、MP-GAT 架構圖。

骨幹網路 (Backbone) 負責將原始的測站資料 (波形、位置) 轉換為富有資訊的特徵。如圖 1 所示，其資料流如下：

在輸入部分，模型將地震測站分為偵測測站與目標測站。偵測區域為花蓮測站，輸入資料包括長度 30 秒的三軸加速度波形與測站經緯度位置。波形經由 2 層 2D 卷積 (kernel size 為 (1,1)、(1,3)，filter 為 8、32) 及 1 層 1D 卷積 (kernel 為 5，filter 為 64) 提取初始特徵，每層卷積後接 ReLU 激活函數。為保留全局訊號強度資訊，波形最大絕對振幅也被加入至卷積特徵中，經 2 層全連接層 (units 分別為 1024、400，Dropout 機率為 0.1) 得到特徵矩陣 M ， $M \in \mathbb{R}^{n \times d}$ ，其中 n 為偵測測站數， d 為特徵維度。位置資訊部分，將每個測站的經緯度位置透過嵌入函數分別投影至 d 維向量，得到位置特徵矩陣 P ， $P \in \mathbb{R}^{n \times d}$ 。在微調階段會將波形特徵與位置特徵相加形成混合特徵表示 E ， $E \in \mathbb{R}^{n \times d}$ ，如式 (1)。而在預訓練階段，位置嵌入我們會先捨棄，僅使用純粹的波形特徵 M 作為輸入 (目標測站的波形特徵為零向量)。

$$E_{n \times d} = M + P \quad (\text{式 } 1)$$

目標測站 (臺北、新北) 不輸入波形，僅以其經緯度生成嵌入特徵矩陣 T ， $T \in$

$\mathbb{R}^{k \times d}$ ，其中 k 為目標測站數， d 為特徵維度。完整輸入特徵為偵測與目標測站特徵的串接，形成具有各測站特徵的矩陣 X ， $X \in \mathbb{R}^{(n+k) \times d}$ ，如式 (2)。

$$X_{(n+k) \times d} = [E \parallel T] \quad (\text{式 } 2)$$

為建構圖結構，透過測站間地理距離 $D_{i,j}$ 建立鄰接矩陣 A_{ij} ， $A \in \mathbb{R}^{(n+k) \times (n+k)}$ ，如式 (3)，距離愈大權重愈小。

$$A_{ij} = 1 - \frac{D_{i,j}}{D_{max}} \quad (\text{式 } 3)$$

特徵矩陣 X 與鄰接矩陣 A 將輸入兩層 MP-GAT 模組進行圖訊息傳遞。MP-GAT 建構於 GATv2 架構，具備全局與局部雙視角注意力能力。每一層的輸特徵 $h_i^{(l+1)}$ 同時整合了節點 i 全鄰居節點集合 $N(i)$ 與節點 i 最相關的鄰近節點的集合 $N_{loc}(i)$ 的訊息，如式 (4)：

$$h_i^{(l+1)} = \sigma \left(\sum_{j \in N_i} \alpha_{ij} A_{ij} W^{(l)} h_j^{(l)} + \sum_{k \in N_{loc}(i)} \beta_{ik} A_{ik} W^{(l)} h_k^{(l)} \right), \quad (\text{式 } 4)$$

$$h_i^{(0)} = X_i$$

其中 α_{ij} 與 β_{ik} 分別為全局與局部注意力分數，由注意力評分函數 (式 5) 所導出，並經 Softmax 正規化後得。每個測站節點最終將輸出一個特徵向量 h_i ， $h_i \in \mathbb{R}^d$ ，形成完整節點嵌入矩陣 H ， $H \in \mathbb{R}^{(n+k) \times d}$ 。 H 即為對比學習投影到低維空間前的特徵表示。

2.2.2 預訓練階段 (Pre-train)：BYOL 學習框架

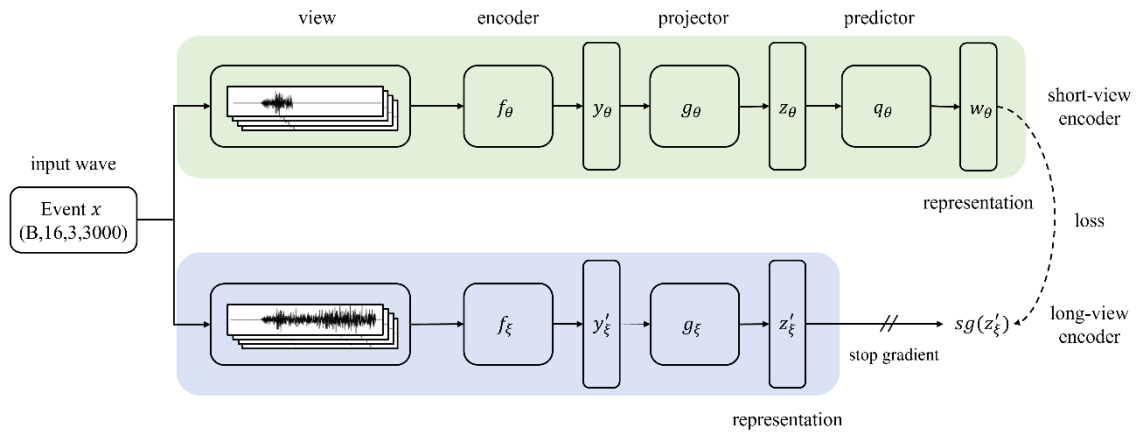


圖 2、BYOL 架構圖。

在預訓練階段，模型採用 BYOL 框架，如圖 2 所示。此架構包含一對結構相同但權重更新方式相異的編碼器：短窗編碼器 (short-view encoder, f_θ) 與長窗編碼器 (long-view encoder, f_ξ)。

此二者共享骨幹網路架構作為編碼器 (encoder)，具體而言，即 4.2.1 節所述的 CNN 模組加上 MP-GAT 模組，並且在此階段不使用位置嵌入。

此階段的設計核心是為地震事件的波形資料建立兩種輸入：

1. 短窗波形：代表地震初期的短時間窗波形（如 P+3 秒 至 P+29 秒），並補零 (padding) 至 30 秒的長度。
2. 長窗波形：代表該地震事件的完整資訊，即固定的 30 秒完整波形。

短窗編碼器 (f_θ) 負責處理「短窗波形」，經骨幹網路計算後，產出特徵表示 (y_θ)。此特徵隨後通過投影層 (Projector, g_θ) 與預測層 (Predictor, q_θ) 得到最終的預測向量 w_θ 。

同時，長窗編碼器 (f_ξ) 處理「長窗波形」，同樣經骨幹網路產出特徵 (y'_ξ)，但僅通過投影層 (g_ξ) 得到目標向量 z'_ξ 。

本研究的自監督學習任務旨在最小化短窗網路的預測向量 $q_\theta (z_\theta)$ 與長窗網路的投影向量 z'_ξ 之間的均方誤差 (MSE) 損失。此損失函數會驅使短窗編碼器 (短窗輸入) 學習到與長窗編碼器 (長窗輸入) 一致的特徵表示。

關鍵的是，只有短窗編碼器 ($f_\theta, g_\theta, q_\theta$) 的權重會透過梯度下降進行更新。長窗編碼器 (f_ξ, z'_ξ) 的權重則不會透過反向傳播更新，而是設定為短窗編碼器權重的指數移動平均 (Exponential Moving Average, EMA)，如式 (5) 所示。

$$\xi \leftarrow \tau \xi + (1 - \tau) \theta \quad (\text{式 } 5)$$

2.2.3 微調階段 (Finetune)：位置感知回歸

在預訓練完成後，模型進入監督式微調階段，以進行最終的 PGA 預測。此階段最大的改變是，我們將位置嵌入模組重新加回 MP-GAT 骨幹網路中。骨幹網路的輸入 (即 E) 此時為波形特徵與位置特徵的總和，使其具備感知地理空間資訊的能力。

我們載入在預訓練階段學習到的短時間窗編碼器權重，我們會丟棄投影層及預測層，只載入編碼器的權重到骨幹模型，並將其數層全連接層串接。最後以較低的學習率，對包含位置嵌入的整體網路進行端到端的監督式訓練。此階段的目標函數為標準的 PGA 回歸損失 (如加權均方誤差)，使模型在已具備強大波形表徵能力的基礎上，進一步學習如何結合位置資訊以準確預測 PGA。

2.3 資料處理

本研究使用的地震波形數據來源為交通部中央氣象署 (CWA) 地震觀測網，包含位於臺北、新北與花蓮的各個測站，測站分布如下圖 3。資料涵蓋 2012 至 2023 年間花蓮地區發生的地震事件，並僅針對臺北測站有偵測到峰值地動加速度

(PGA) 的事件進行分析。我們以最先偵測到 P 波的測站作為基準，統一截取該測站在 P 波到時前 5 秒至到時後 25 秒的 30 秒波形資料作為資料處理基礎。為了滿足即時預測需求，本研究對原始波形數據進行了特殊處理：在訓練階段，我們從 P 波到時後第 3 秒開始，以每秒為間隔持續到第 25 秒，分別截取不同時間點 T 的三軸加速度波形進行模型訓練，同時將時間點 T 之後的波形資料全部補零，以維持模型輸入結構的完整性。

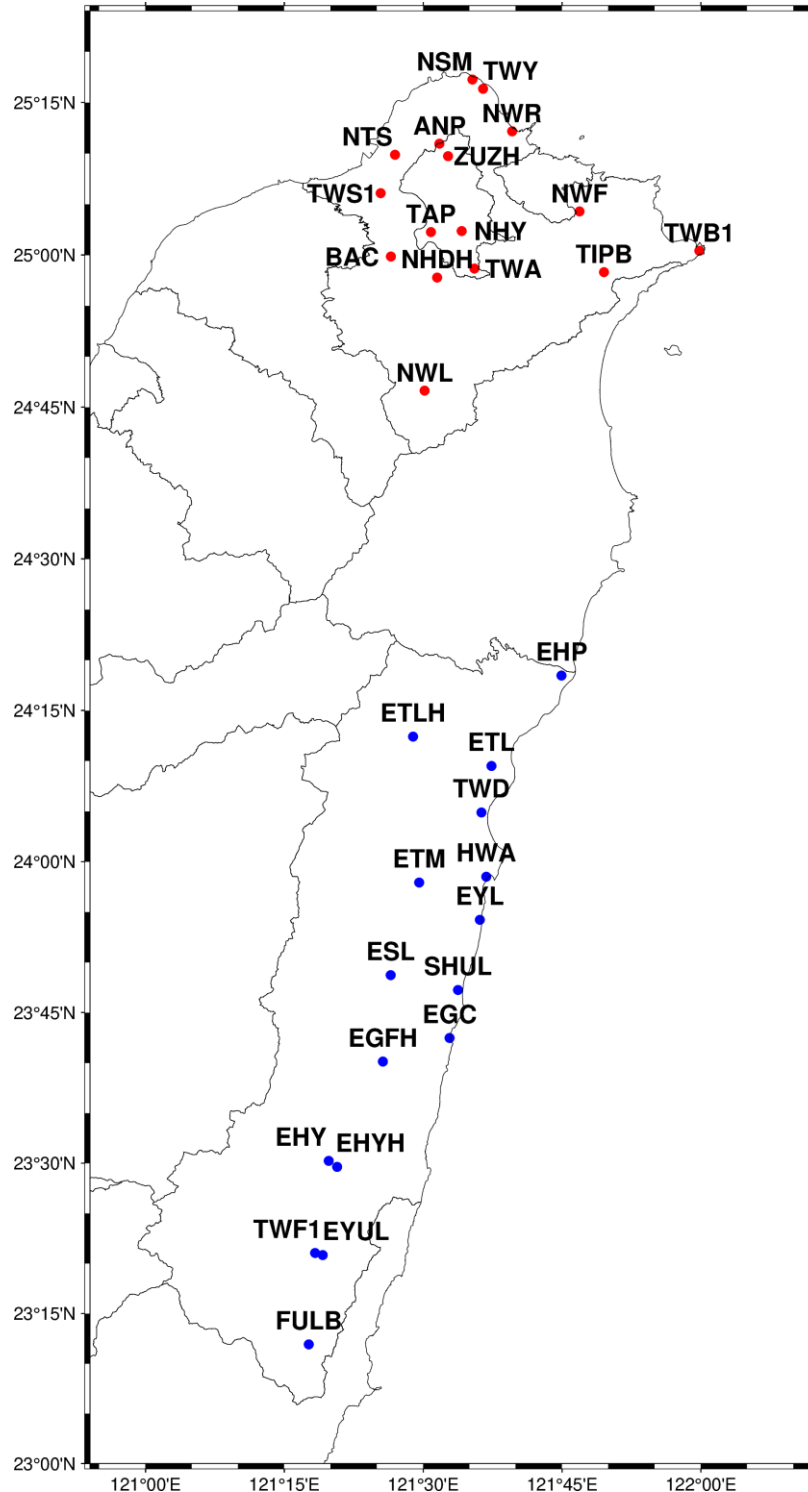


圖 3、測站分布圖。

資料集的分割以年份為依據，其中訓練集涵蓋了 2012 至 2020 年的地震事件，共計 8073 筆，依規模分布為規模 2-3 有 69 筆、規模 3-4 有 3289 筆、規模 4-5 有 4025 筆，以及規模 5 以上有 690 筆；測試集則選取 2021 至 2023 年間的地震事件，共有 3910 筆，其中規模 3-4 為 943 筆、規模 4-5 為 2116 筆、規模 5 以上為 851 筆。規模分佈如下圖 4。




圖 4、訓練集和測試集規模分布圖。

此外，考慮到較大規模地震在資料集中所占比例較少，本研究特別進行了數據增強處理，以解決資料分佈不均勻的問題，同時也增加波形資料的多樣性。數據增強的步驟如下：首先，根據每個事件在臺北測站記錄到的 PGA 數值範圍將資料分為五類，分別為小於 0.8、0.8 至 2.5、2.5 至 8、8 至 25 以及大於 25。接著，根據這些類別設定增強倍率，對較少出現的類別給予較高的權重，以確保每個類別的事件數量達到平衡。進一步的資料多樣化操作包含隨機選擇花蓮地區測站的波形數據，並對其三軸加速度波形進行隨機正負顛倒處理(即波形沿基線隨機翻轉)。此數據增強方法有效提升了資料集的多樣性，並強化了模型對不同類型波形的辨識能力。圖 5 為原始數據集與資料增強後數據集的 PGA 分布。

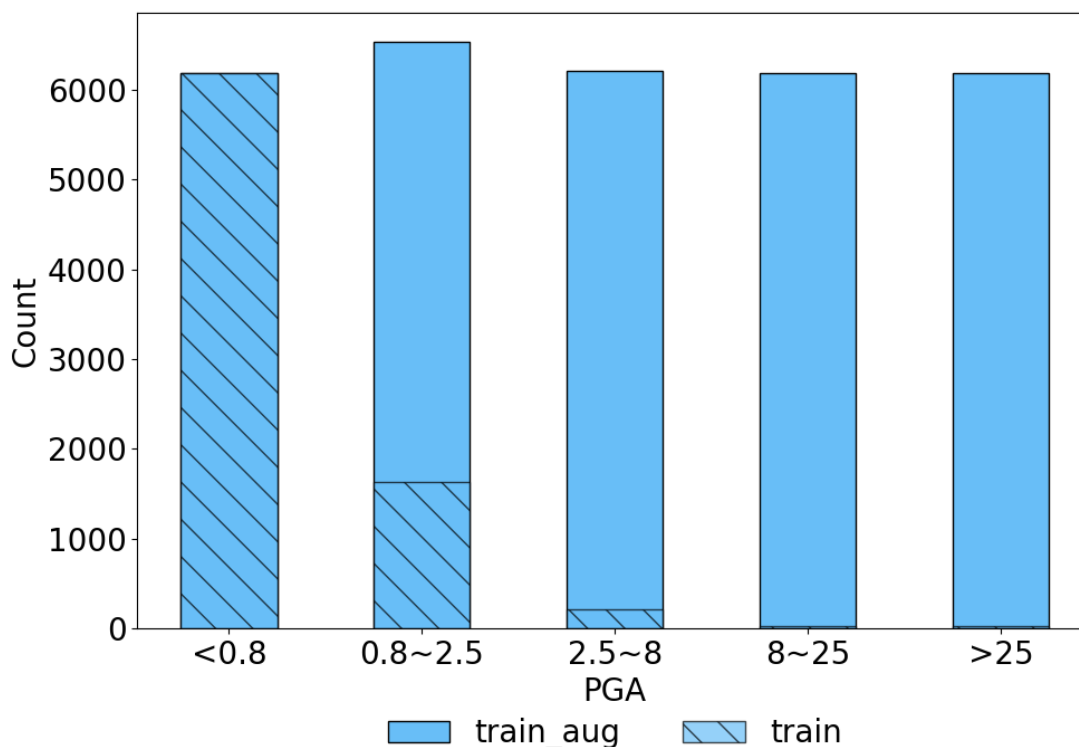


圖 5、原始資料集與數據增強後資料集 PGA 分布圖。

2.4 訓練過程

本研究採用兩階段訓練策略，以提升模型在早期時間窗下之 PGA 預測能力。第一階段為位置解耦的對比學習預訓練；第二階段則進行位置感知的監督式微調，專注於目標測站的 PGA 預測。

第一階段為對比學習預訓練。此階段的核心目標是訓練一個能將短時間窗波形特徵映射至其對應之完整波形特徵的編碼器 (Encoder)，藉此獲得高品質的早期特徵表示，為後續微調階段的 PGA 預測奠定基礎。為達成此目標，我們使用節點級 BYOL 框架，且 C-GAT 不包含位置嵌入。此階段的資料配對策略是本研究的核心之一：我們為單一地震事件建立多個正樣本對。「長時間窗波形」固定為該事件的完整 30 秒波形；而「短時間窗波形」則是一系列代表地震早期發展的時間窗，具體而言，我們擷取 P 波到時後第 3 秒、第 9 秒、...、直至第 29 秒的所有短時間窗。訓練時，這些短時間窗會被補零 (zero-padding) 至 30 秒標準長度，並各自與完整的 30 秒「目標波形」進行配對。此「多對一」的配對策略，旨在強迫模型學習一個完整波形的特徵表示，無論輸入是多早期的波形，其節點表示都能被映射到接近完整波形 (30 秒) 的表示。損失函數採用均方誤差 (MSE)，計算在線網路預測層與目標網路投影層在節點級表示上的差異。此階段使用 AdamW 優化器，學習率設為 1×10^{-5} ，batch size 設為 32，最大訓練 epoch 數為 100，並加入 Early Stopping (patience=20) 以避免過擬合。

在第二階段微調過程中，我們將預訓練好的 C-GAT 權重載入，並重新導入位

置嵌入模組。與期中報告的策略不同，此階段我們解凍包含骨幹網路、位置嵌入及回歸分支在內的所有網路層，使模型能夠學習如何將已學會的波形特徵與空間資訊進行最佳融合。我們使用增強資料集進行訓練，並持續採用 AdamW 優化器，設定一組較低的統一學習率 1×10^{-5} 。Batch size 設為 64，最大訓練 100 個 epoch，Early Stopping 的耐心值設為 20。損失函數採用加權均方誤差（Weighted Mean Square Error），當預測值低於實際值且 PGA 達到門檻時，將對應誤差項放大以強化對低估風險的懲罰能力。最終僅透過此回歸損失優化模型以穩定收斂，提升對目標測站 PGA 的預測準確度。

2.5 模型評估

為驗證模型於不同地震規模下的預測能力與穩定性，本研究額外選用 2024 年 4 月 3 日花蓮主震（規模 7.2）及其 18 起餘震事件作為獨立測試資料集。這些事件規模分布於 5.00 至 7.2 之間，總計 437 筆樣本，每筆代表地震發生後 23 秒內的時間窗截取，可有效觀察模型在震後即時預測的行為與提前性。

本節比較了兩種模型：(1) **Baseline（基準模型）**，即未經自監督預訓練的 MP-GAT；(2) **C-GAT**，即本研究提出採用 BYOL 預訓練後，再進行位置感知微調的新架構。評估重點旨在驗證新架構是否能達成研究目標：提升在地震早期（P 波到時後 3 至 15 秒）的 PGA 預測表現。

首先，在涵蓋所有評估時間窗（P+3 秒至 P+25 秒）的整體評估中，本研究提出的 C-GAT 模型在所有指標上均優於基準模型。C-GAT 的整體 MAE 為 5.61，低於 Baseline 的 5.76；RMSE 亦從 20.54 降至 19.63； R^2 值則從 0.238 提升至 0.304，顯示 BYOL 預訓練策略對整體效能具備正面的助益。

本研究的核心目標是優化極短時間窗的預測。如圖 6 所示，在 P+3 秒時，由於資訊極度稀缺，兩模型表現均不理想，C-GAT（MAE: 6.90）相較 Baseline（MAE: 6.83）並未展現優勢。

然而，關鍵的改善發生在 P+4 秒之後。如圖 7 所示，在 P+5 秒時，C-GAT 的 MAE 已降至 6.50，顯著優於 Baseline 的 6.8，且 R^2 值開始轉正（C-GAT: 0.06 vs Baseline: -0.07）。此一趨勢在 P+10 秒（如圖 8）更加明顯，C-GAT 的 MAE（6.28）持續優於基準模型（6.49）， R^2 值（0.14）更是基準模型（0.025）的數倍。這證實了 C-GAT 模型能更早開始進行有效的預測。隨著時間窗增長（如 P+15 秒、P+20 秒、P+25 秒，如圖 9、10、11 所示），兩模型的預測能力均穩定提升，C-GAT 雖仍保持小幅領先，但兩者表現已逐漸趨於一致。




圖 6、第 3 秒預測結果




圖 7、第 5 秒預測結果




圖 8、第 10 秒預測結果




圖 9、第 15 秒預測結果




圖 10、第 20 秒預測結果




圖 11、第 25 秒預測結果

PGA 區間及誤差分析:

進一步的效能評估聚焦於模型對不同震度區間的預測能力，特別是高風險、高震度（PGA > 25 gal）事件的早期預測表現。

在 P+3 秒時，C-GAT 在 >25 gal 區間的 MAE（82.86 gal）略優於 Baseline（83.52 gal），但改善幅度有限。這也呼應了前述結論，在 P+3 秒的資訊量尚不足以讓預訓練策略發揮顯著優勢，如表 1 所示。

然而，自 P+4 秒起，C-GAT 的優勢開始顯現。在此時間點，C-GAT 於 >25 gal 區間的 MAE 降至 72.99 gal，相較 Baseline 的 81.99 gal，誤差顯著降低了 11.0%，如表 2 所示。

此一優勢在 P+5 秒得到延續。C-GAT 在 >25 gal 區間的 MAE 為 77.66 gal，持續優於 Baseline 的 83.11 gal（誤差降低 6.6%）。到了 P+10 秒（Window 15s），C-GAT 在此高震度區間的 MAE（74.11 gal）仍明顯低於 Baseline（79.38 gal）（誤差降低 6.6%）如表 3 所示。

如表 4 所示，到了 P+15 秒（Window 20s），兩個模型在高震度（>25）區間的 MAE 表現已趨於一致（Baseline: 66.52 vs C-GAT: 67.51），顯示本研究的預訓練策略，其效益主要集中在 P+3 秒至 P+115 秒的關鍵早期預警階段。

值得注意的是，此一高震度區間的顯著改善，是透過犧牲部分低震度區間（<0.8 gal）的預測精度換來的。此一結果完全符合本研究的預期：我們的 BYOL 預訓練策略成功地將模型的學習重心轉移至高震度事件的關鍵特徵上，實務上高震度事件才是我們關注的，低震度些微誤差並不會造成影響。

綜合而言，PGA 區間誤差分析證實 C-GAT 模型成功達成了本研究的核心目標：雖然在 P+3 秒時提升有限，但在 P 波到時後 4 至 15 秒的關鍵黃金時間內，

C-GAT 對於高震度、高風險事件的預測準確性，顯著優於傳統的基準模型。

表 1、3 秒 PGA 各區間 MAE 與 RMSE

PGA Range	Baseline MAE	C-GAT MAE	Baseline RMSE	C-GAT RMSE
<0.8	0.2327	0.2758	0.2823	0.3252
0.8-2.5	1.0069	1.1313	1.1216	1.2493
2.8-8	3.2720	3.6167	3.5892	3.9283
8-25	14.2055	14.3989	15.1477	15.2582
>25	83.5197	82.8576	94.9314	94.2007

表 2、5 秒 PGA 各區間 MAE 與 RMSE

PGA Range	Baseline MAE	C-GAT MAE	Baseline RMSE	C-GAT RMSE
<0.8	0.2113	0.2729	0.2707	0.3234
0.8-2.5	1.0330	1.1318	1.1701	1.2441
2.8-8	3.4629	3.3228	3.7493	3.6620
8-25	14.1216	13.8323	15.0405	14.6062
>25	83.1150	77.6648	94.4595	88.3108

表 3、10 秒 PGA 各區間 MAE 與 RMSE

PGA Range	Baseline MAE	C-GAT MAE	Baseline RMSE	C-GAT RMSE
<0.8	0.1642	0.2541	0.2145	0.3037
0.8-2.5	0.8599	1.1307	1.0440	1.2741
2.8-8	3.3915	3.5450	3.7453	3.8386
8-25	13.8953	13.6524	14.6634	14.2966
>25	79.3817	74.1073	90.1458	84.3423

表 4、15 秒 PGA 各區間 MAE 與 RMSE

PGA Range	Baseline MAE	C-GAT MAE	Baseline RMSE	C-GAT RMSE
<0.8	0.1572	0.2359	0.2081	0.2854
0.8-2.5	0.8291	0.9652	1.0151	1.1344
2.8-8	3.2546	3.2236	3.5983	3.6114
8-25	12.9121	12.8998	13.4800	13.4599
>25	66.5248	67.5120	75.7792	77.1456

2.6 具體成果

0403 花蓮地震事件預警測試

為進一步探討模型對震度達到警戒閾值的預測能力，我們挑選 7 個在 2024 年 4 月 3 日花蓮主震事件中，真實 PGA 同時超過震度三級與四級閾值的測站 (NHDH、TAP、NHY、NWF、TWS1、ZUZH、NTS)，繪製其對應的預測時間序列曲線，如圖 12 至圖 17 所示。

在這些圖表中，橫軸為 P 波到時後的時間(秒)，縱軸為預測的 PGA (cm/s^2)。藍色實線 (Baseline) 代表基準模型的預測值，紅色實線 (C-GAT) 則代表本研究提出的 BYOL 預訓練模型。圖中亦標示了震度三級 ($\text{PGA} > 8$) 與四級 ($\text{PGA} > 25$) 的閾值，以及該測站真實 PGA 首次超過閾值的時間點。

從圖中可清晰觀察到本研究 C-GAT 模型的關鍵優勢：在地震發生的最初幾秒內 (約 3 至 15 秒)，C-GAT 的預測值 (紅線) 幾乎在所有測站均顯著地「率先跳升」，其預測的 PGA 數值遠高於 Baseline (藍線)，且更迅速地接近並跨越預警閾值。這顯示 C-GAT 模型憑藉其在預訓練階段學習到的完整波形特徵，在僅觀測到極短時間窗時，即具備更強的強震辨識潛力，能更早發出有效警報。

相比之下，Baseline 基準模型在早期階段的預測則相對保守滯後，其預測值 (藍線) 需要更長的時間窗才能緩慢爬升至預警閾值附近，顯示其對早期特徵的辨識能力不足。

值得注意的是，隨著時間窗推進 (如 15 秒後)，C-GAT 模型的預測值在達到高點後便趨於穩定持平，並未因為後續持續輸入短窗 (如 20s、25s) 而被「拉低」。此現象證明了本研究 BYOL 策略的成功：模型在預訓練時確實學習到了完整 30 秒波形的穩定特徵表示，使其在短窗預測時能提取出更好的特徵，同時在長窗預測時亦不會喪失其準確性。

就整體平均表現而言，C-GAT 模型的預警效益也顯著提升。對於震度三級 ($\text{PGA} > 8$) 的警報，C-GAT 的平均領先時間為 **17.61 秒**，相較於 Baseline 的

13.07 秒，爭取了 **4.54 秒** 的額外預警時間。對於震度四級（ $PGA > 25$ ）的警報，C-GAT 的平均領先時間為 15.74 秒，亦優於 Baseline 的 15.31 秒。

此一系列結果證實，C-GAT 所採用的對比學習策略，能有效強化模型在地震初期的預測敏感度與準確度，對於強震的早期快速反應與警報發布具有實質應用價值。




圖 12、NHDH 測站預測。




圖 13、TAP 測站預測。




圖 13、NHY 測站預測。




圖 14、NWF 測站預測。




圖 15、TWS1 測站預測。




圖 16、ZUZH 測站預測。




圖 17、NTS 測站預測。

2.7 結論

本研究提出一項優化的 C-GAT 模型架構，透過整合 BYOL 式對比學習預訓練，成功提升了地震初期僅依賴短時間窗波形資料時的 PGA 預測能力。模型以 MP-GAT 為骨幹，但透過新型的自監督學習設計，有效解決了原先策略中負樣本衝突以及長時間窗特徵崩壞的問題。此設計使模型得以在預訓練階段專注於學習一個由短窗（如 P+3 秒）映射至完整波形（P+30 秒）的穩定節點級特徵表示。

實驗結果證實，本研究提出的 C-GAT 模型在效能上顯著優於 Baseline。在 0403 花蓮地震序列的獨立測試中，C-GAT 在 P 波到時後 3 至 15 秒的關鍵預警黃金時間內，展現出更強的強震辨識能力。尤其在 PGA 大於 25 gal 的高震度區間，C-GAT 的預測誤差（MAE）相較基準模型降低了 6% 至 11%。

更重要的是，此策略成功達成了「短窗優化」與「長窗穩定」的雙重目標。如 0403 事件的預測曲線所示，C-GAT 的預測值在早期便迅速爬升至準確區間，證實

了模型已學習到完整波形特徵；且其預測在長窗時亦能保持穩定，並未因 BYOL 的對應任務而受到短窗輸入的負面影響。在預警時效上，C-GAT 對於震度三級警報的平均領先時間提前了 4.54 秒。

綜合而言，本研究證實了無負樣本的自監督學習策略，是解決區域型地震預警中短窗預測難題的有效路徑。此模型不僅提高了高震度事件的預測準確性，其架構設計亦確保了長窗預測的穩定性，為地震快速預警應用提供了高準確性且邏輯穩健的解決方案。未來可持續將此預訓練框架應用於不同分區模型，並整合更多強震資料，以進一步強化模型的泛化能力與實務應用價值。

參、地震資料生成應用於區域型地震預警

3.1 簡介

在地震預警系統中，強震波形資料的完整性與分布平衡性，對深度學習模型訓練結果具有關鍵的影響。特別是大地震事件中，對應的高峰值地面加速度（Peak Ground Acceleration, PGA）波形樣本於實際觀測中極為稀少，導致模型難以學習高震度的特徵，常出現對強震風險的系統性低估，進而影響預警可靠性與反應速度。

為應對此困境，本研究延續期中階段已驗證可行的條件式生成對抗網路（CFGAN）技術，將其從現地型預測進一步拓展至區域型預警任務。本段落將首先透過一系列嚴謹的評估（包含時域比對、頻譜分析與 PGA 驗證），證實所提出之生成模型的有效性與物理一致性。

最終，本研究將展示基於生成資料擴增和傳統擴增方法的效能比較以及事件評估。研究結果將證明，使用生成資料擴增訓練的預警模型，能顯著改善對大規模地震的低估現象，證實本生成模型在提升預警系統的實際應用價值。

3.2 生成模型架構

本研究提出一個基於條件式生成對抗網路（Conditional Generative Adversarial Network, cGAN）的波形生成模型，架構如圖 18 所示，此架構由兩個相互博弈的神經網路所組成：生成器（Generator）與判別器（Discriminator）。生成器的主要任務是學習真實地震波形的複雜分佈，並根據一組給定的物理條件（包含地震規模、震源距離、方位角與測站 Vs30）來合成出高度逼真的三軸加速度波形。與此同時，判別器則扮演評估者的角色，其任務不僅是辨別輸入波形的真偽，還需要判斷該波形是否與其對應的物理條件相匹配。在整個訓練過程中，兩個網路透過對抗式學習（Adversarial Learning）不斷地自我優化與演進，最終驅使生成器具備產生高保真度（high-fidelity）且符合物理約束的地震動（ground motion）之能力。

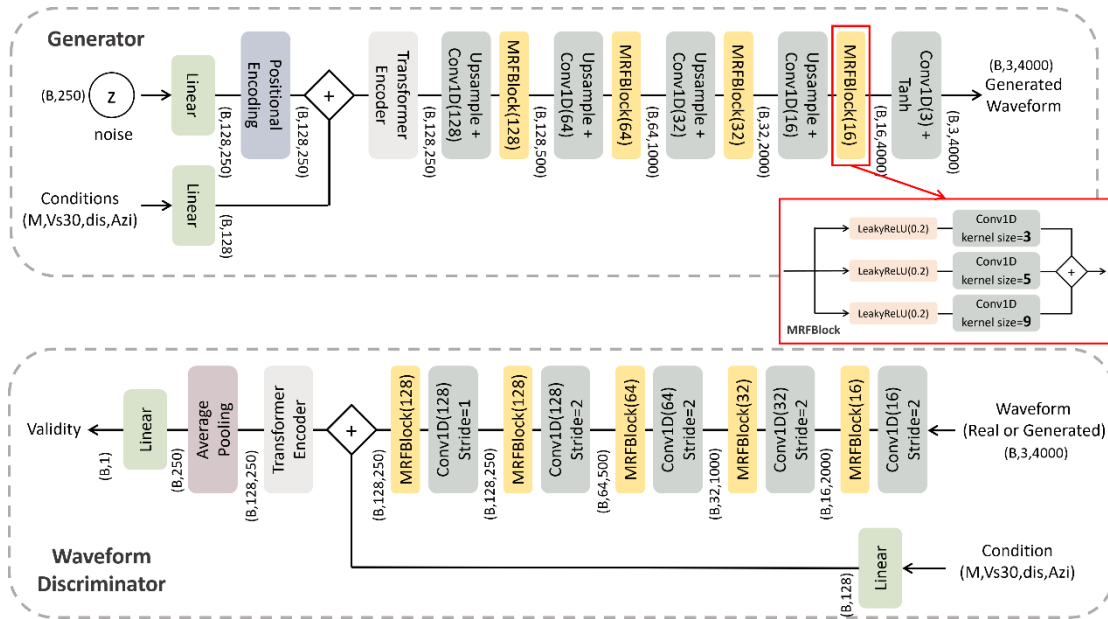


圖 18、模型架構圖。

生成器架構:

生成器的任務是根據給定的地震條件，合成出逼真的三軸地震加速度波形。其輸入由一個隨機噪聲向量 (noise) 和一個條件向量所組成。條件向量包含了四個關鍵的物理參數：地震規模 (Magnitude)、震源距離 (Hypocentral Distance)、方位角 (Azimuth) 以及測站 Vs30。

在生成器內部，噪聲向量首先通過一個線性層被投影並重塑為一個初始向量，並加入位置編碼 (Positional Encoding) 以注入時序資訊；條件向量則被另一個線性層處理為特徵嵌入。兩者融合後，被送入一個由多層堆疊的 Transformer 編碼器 (Transformer Encoder) 中。Transformer 的自注意力機制使模型能夠學習地震波形內部的全局依賴關係與長時間之特徵。

接著，Transformer 編碼器所輸出的特徵向量，會進入一個上採樣解碼器中。此解碼器由一系列的上採樣階段所構成。在每一個階段，特徵圖首先通過線性插值 (Linear Interpolation) 的方式將序列長度加倍，再通過一個一維卷積層 (Conv1D) 調整通道數與進行特徵學習。在此之後，一個多尺度感受野 (Multi-Receptive Field, MRF) 模組被串聯，用以進行多尺度特徵細化。MRF 模組允許網路同時使用多種不同大小的卷積核 (Kernel) 來提取特徵，小的 Kernel size 使模型能同時捕捉到波形的局部細節 (高頻成分)，而大的 size 捕捉全局趨勢 (低頻成分)。最後，一個輸出的卷積層會將解碼後的特徵合成為最終的三軸 (E、N、Z) 地震波形。

判別器架構:

判別器的任務是判斷輸入的波形是真實的還是由生成器合成的，並且也需要

接收相對應的條件向量作為輔助資訊。

在判別器中，輸入的波形首先會通過一個由多個降採樣階段組成的特徵提取器。每一個階段由一個用於降採樣的一維卷積 (Conv1D) 與 LeakyReLU 激活函數所組成，其後緊接著一個 MRF 模組，以豐富特徵的尺度。這使判別器也能在多個尺度上審視波形特徵。為了穩定對抗式訓練的過程，判別器中所有的卷積層均採用了譜歸一化 (Spectral Normalization)。

降採樣後的特徵序列會與處理過的條件向量(規模、震源距離、方位角、Vs30)相融合，並一同送入一個 Transformer 編碼器中。這個設計讓判別器不僅能評估波形的真實性，還能判斷波形與其對應的物理條件是否匹配。最終，Transformer 的輸出序列經過全局平均池化 (Global Average Pooling) 後，通過一個線性層輸出一個單一的純量值，代表模型對該波形真實性的最終評分。

3.3 資料處理

本研究使用中央氣象署 CWASN (Central Weather Administration Seismic Network) 觀測網中，2012 年至 2021 年間的地震事件當作訓練資料，只選取來自地表測站的加速度波形，並限定震央距離 200 km 以內。

對於每一筆通過篩選的紀錄，我們以最早接收到 P 波的測站到時為基準，截取該測站 P 波前 5 秒至後 35 秒的時間窗，總計 40 秒 (4000 個樣本點) 的三軸波形數據作為模型輸入。接著將所有波形進行零均值化處理 (zero-mean)，消除數據偏移，使波形均勻分布於基準線周圍，提高模型在數據變異性下的穩定性。隨後進行帶通濾波 (bandpass filtering)，去除目標頻段以外的噪聲，提高資料中有效訊號特徵在各頻率範圍內的代表性。

在處理波形數據的同時，我們也準備了模型所需的條件向量。此向量包含地震規模、震源距離、方位角及測站 Vs30 四項參數。其中，震源距離與方位角是根據震源的經緯度、深度和測站的經緯度、高程即時計算得出的。最後，為了確保模型訓練的穩定性，所有條件向量在輸入模型前，都會使用從整個訓練數據集中預先計算好的平均值和標準差，進行標準化 (Z-Score Normalization) 處理。

5.4 訓練過程

我們的訓練設備選用了 i5-13500 的 CPU、16GB 的 DDR5 記憶體，以及具備 16GB VRAM 的 RTX4080 顯示卡，以支持高效能的訓練過程。由於我們的模型在運行時需要處理大量地震數據，這樣的硬體配置確保了運算的穩定性和模型的流暢訓練。在參數設置方面，batch size 設定為 32，以平衡訓練的速度和計算的需求；生成器與判別器均採用 Adam 優化器，學習率設置為 10^{-4} 。

整體的訓練流程遵循 WGAN-GP (Wasserstein GAN with Gradient Penalty) 的策略。在此策略下，判別器的訓練頻率高於生成器 (比例設定為 5)，以確保判別器能提供穩定且可靠的梯度。在每一次的判別器更新中，我們將真實波形與生成器

合成的波形同時送入判別器，其總損失函數 L_D 如式 (6) 所示：

$$L_D = L_{WGAN} + \lambda_{gp} \cdot L_{GP} \quad (式 6)$$

其中，第一部分為 Wasserstein 損失 L_{WGAN} ，如式 (7) 所示。此損失旨在最大化真實樣本 x 與生成樣本 \tilde{x} 經判別器 D 評分後的期望差距， c 為條件：

$$L_{WGAN} = \mathbb{E}[D(\tilde{x}, c)] - \mathbb{E}[D(x, c)] \quad (式 7)$$

第二部分為梯度懲罰 (Gradient Penalty) L_{GP} ，如式 (8) 所示。此項用於懲罰判別器 D 對於隨機插值樣本 \hat{x} 的梯度範數，使其趨近於 1， λ_{gp} 則為其權重，此處設為 10：

$$L_{GP} = \mathbb{E}[(\|\nabla_{\hat{x}} D(\hat{x}, c)\| - 1)^2] \quad (式 8)$$

生成器的更新目標則較為複雜，其總損失函數由三個部分加權組成，如式 (9) 所示：

$$L_G = L_{adv} + \lambda_{fm} \cdot L_{fm} + \lambda_{stft} \cdot L_{stft} \quad (式 9)$$

第一部分為對抗損失 (Adversarial Loss) L_{adv} ，此損失旨在最大化判別器對虛假波形的評分 $D(\tilde{x})$ ，如式 (10) 所示：

$$L_{adv} = -\mathbb{E}[D(\tilde{x}, c)] \quad (式 10)$$

第二部分為特徵匹配損失 (Feature Matching Loss) L_{fm} ，為了使生成波形在感知上更接近真實波形，我們從判別器的 M 個中間層中提取特徵 $D^{(m)}(\cdot)$ 。此損失計算的是真實波形 x 與虛假波形 \tilde{x} 在這些特徵層上的 L1 距離總和，如式 (11) 所示 (λ_{fm} 設為 10)。這促使生成器不僅要騙過判別器的最終評分，還要在特徵表達上模仿真實數據。

$$L_{fm} = \sum_{m=1}^M \mathbb{E}[\|D^{(m)}(x, c) - D^{(m)}(\tilde{x}, c)\|_1] \quad (式 11)$$

第三部分為多解析度 STFT 損失 (Multi-Resolution STFT Loss) L_{stft} ，為了確保生成的波形不僅在時域上相似，在時頻譜結構上也與真實波形一致，我們引入了時頻譜 L1 損失 (λ_{stft} 設為 10)。此損失會將生成波形 \tilde{x} 與真實波形 x 分別進行短時距傅立葉變換 (STFT)，並計算兩者頻譜圖的 L1 距離。如式 (12) 所示，此損失是通過一組 R 種多解析度 (Multi-Resolution) 的 STFT 參數分別計算後再進行平均，參數設置如表 5 所示，從而全面地約束波形的時頻譜特性。

$$L_{stft} = \frac{1}{R} \sum_{r=1}^R \mathbb{E}[\|STFT_r(x) - STFT_r(\tilde{x})\|_1] \quad (式 12)$$

表 5、STFT 參數設定值。

STFT loss	FFT size	Window size	Frame shift
High Time-Res	64	20 (0.2s)	5

Balanced Res	256	100 (1s)	25
High Freq-Res	512	256 (2.56s)	64

為了對模型的收斂情況與生成品質進行量化評估，系統會保存訓練過程中每一個 epoch 的生成器權重。訓練結束後，我們使用這些檢查點基於給定的條件生成一批波形。透過一個綜合性的評估框架來選出最優的生成器權重，此框架主要基於三項指標：首先，是真實波形與生成波形之間的平均頻率域損失；其次，是兩者之間的平均時頻域損失；最後，我們還會評估生成波形的 PGA 分布，並將其與真實數據集的 PGA 統計分布進行比較。最終，我們會選出一個在時域、頻域以及關鍵地震工程參數 (PGA) 上，表現最均衡且最接近真實數據的生成器權重，用於後續的數據擴增任務。

3.5 生成資料評估

本節對生成模型近零地震波形之合成實驗，並以頻譜特性分析、PGA 之量化驗證以及時域波形可視化比對三種方法評估其生成的品質以及條件的控制能力。

頻譜特性分析:

在頻譜特性分析方面，如圖 19 所示，首先比較了整體資料集的平均傅立葉振幅譜 (Fourier Amplitude Spectrum, FAS)，以檢視模型在總體趨勢上的頻譜合成能力。從圖中可觀察到，生成波形的平均 FAS (橘色虛線) 與真實資料的平均 FAS (藍色實線) 在 1 Hz 至 10 Hz 的主要地震頻率範圍內高度吻合。然而，生成資料的標準差範圍 (淺橘色區域) 明顯小於真實資料 (淺藍色區域)，顯示模型所生成波形在頻譜上的多樣性 (variance) 較低。




圖 19、整體資料集平均傅立葉振幅譜。

接著，為了更深入地評估模型在不同條件下的表現，我們採用整體資料集的「規模中位數」與「距離中位數」作為門檻值，將數據切分為「大/小規模」與「近/遠距離」四組情境。如圖 20 顯示了在此四種情境下，真實與生成資料的平均傅立葉振幅譜（FAS）及其標準差範圍，用以驗證模型是否能準確捕捉不同地震情境的主要頻率成分與能量分佈。

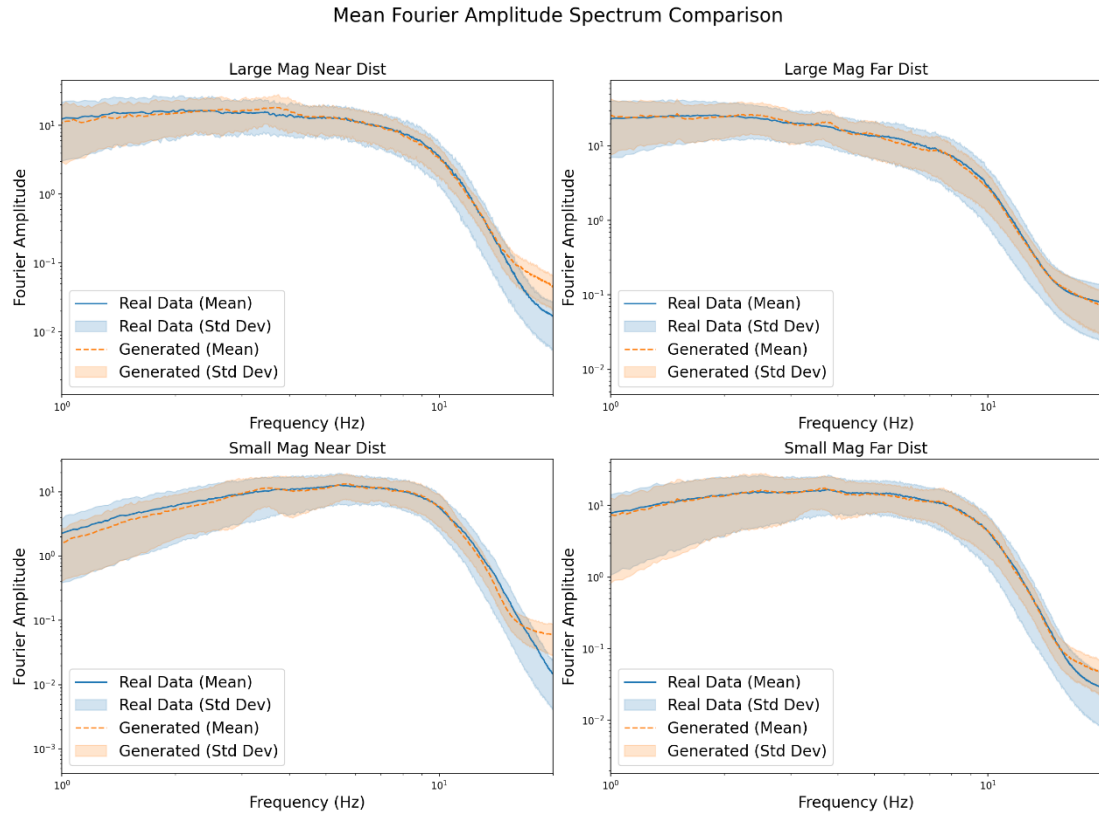


圖 20、四種特定情境之平均傅立葉振幅譜。

PGA 量化驗證:

在頻率域分析之外，本研究進一步評估了合成波形在關鍵量化指標上的表現。峰值地表加速度（PGA）作為地震工程的核心參數，其與真實波形的一致性是驗證模型成效的重要依據，因此對其進行了專門的評估。

在此次分析中，我們選用驗證集中的所有事件之條件生成每一個測站的三分量加速度波形，並評估其 PGA 表現。如圖 21 所示，這張散點圖即是將此次分析結果進行可視化。圖中的橫軸代表從真實觀測紀錄中量測到的 PGA 值，而縱軸則代表模型生成的合成波形所計算出的 PGA 值。

因此，圖中的每一個數據點，即代表該地震事件在某一個測站上的「真實 PGA」與「合成 PGA」的成對比較。此圖中的紅色虛線（ $y=x$ ）是一條理想線，代表真實值與預測值的完美對應。本分析的目標，即是檢視所有數據點是否緊密地分佈在這條理想線的周圍。數據點分佈得越集中、越貼近理想線，即表示模型對於此事件在

不同測站上的 PGA 預測越準確且穩定。





圖 21、真實 PGA 與合成 PGA 對比圖。

時域波形可視化比對:

在時域波形的可視化比對方面，本研究採用了直接的波形疊圖比較，以直觀地評估合成波形的真實性。如圖 22 所示，此圖展示了單一地震事件在多個不同測站上的觀測結果。此圖由三個子圖組成，由左至右分別展示了 Z(垂直)、N(南北)、E(東西)三個分量的加速度時程圖。在每個子圖中，所有測站均依震央距由近至遠(由上至下)排列，並將真實地震紀錄(紅色波形)與本模型生成的合成波形(黑色波形)並列繪製，以便進行直接的時域比對。

從圖中可清晰觀察到，模型成功地重現了多項關鍵物理特徵：首先，合成波形的整體波形包絡，與真實資料展現了高度的相似性。其次，模型亦準確重現了 P-S 波到時差，合成波形與真實波形同樣顯示了 P-S 波差隨震央距變遠而穩定增長的規律。這兩點共同證明了模型不僅學習到了波形的形態，也掌握了地震波在介質中傳播的基本物理特性。



M: 5.0

圖 22、時域波形對比圖。

3.6 區域型預警模型評估

為驗證本研究所提出之地震波形生成模型的實際應用成效，本節將其應用於一項關鍵的下游任務：區域型地震預警。我們將評估使用「生成資料」進行訓練，是否能有效改善上一期計畫中所開發的 MP-GAT 預警模型之效能，特別是針對大規模地震事件的預測能力。

3.6.1 實驗設計

本研究將 MP-GAT 區域型預警模型 的訓練分為兩組進行比較：

1. 第一組 (Baseline)：

此組採用與上一期計畫當中 MP-GAT 模型訓練完全相同的訓練資料集，如圖 23 所示。此資料集包含原始地震事件，以及透過數據增強(如波形正負隨機翻轉)所擴增的資料。此組的訓練結果將作為效能比較的基礎。




圖 23、原始資料集與數據增強後資料集。

2. 第二組 (Gen-Aug)：

此組為本研究的實驗組，其訓練資料集由原始地震事件搭配兩類合成資料所組成，旨在全面替換並增補 Baseline 的數據增強：

(a) 基礎增強替換：

將第一組中所有透過隨機變換生成的「數據增強」資料，全部替換為使用本研究之生成模型，在相同地震條件下所產生的合成波形。

(b) GMPE 尺度放大增強：

為了彌補原始資料中缺乏大規模地震樣本的問題，我們額外使用簡文郁(2001)所提出的 GMPE 經驗公式，如式 13 所示，進行小規模地震事件的尺度放大。

$$y(g) = A_0 e^{aM} [R + b e^{cM}]^{-d} \quad (\text{式 13})$$

其中 y 為震動強度的參數， M 為芮氏規模， R 為場址至震源的距離， A_0 、 a 、 b 、 c 、 d 分別為迴歸分析之係數。我們選用此 GMPE 的原因在於其計算相較之下較為單純，使我們能根據放大的目標規模 M ，相應計算出各測站 PGA 所需放大的比例。透過此方法，我們創造了一批臺北地區最大 PGA 大於 80 (cm/s^2) 的罕見強震情境，並使用本研究的生成模型產出對應的合成波形。此方法所增補的事件個數，與前面 (a) 點中各類別的數量相同。透過此二組實驗設計，我們得以直接比較「傳統數據增強」與「生成模型增強」在改善 MP-GAT 模型上的具體成效。

3.6.2 區域型預警效能比較

本節比較了「Baseline」擴增方法與「Gen-Aug」擴增方法在 2021 年至 2023 年測試集上的預測效能。

測試集效能散點圖分析：

圖 24 到圖 29 顯示了兩組實驗在 P 波到達後不同時間窗格 (3、5、10、15、20 及 25 秒) 下的 $\log_{10} \text{PGA}$ 預測散點圖。圖中藍點為 Baseline，紅點為 Gen-Aug，黑色虛線為 $y=x$ 理想線。




圖 24、第 3 秒預測結果。

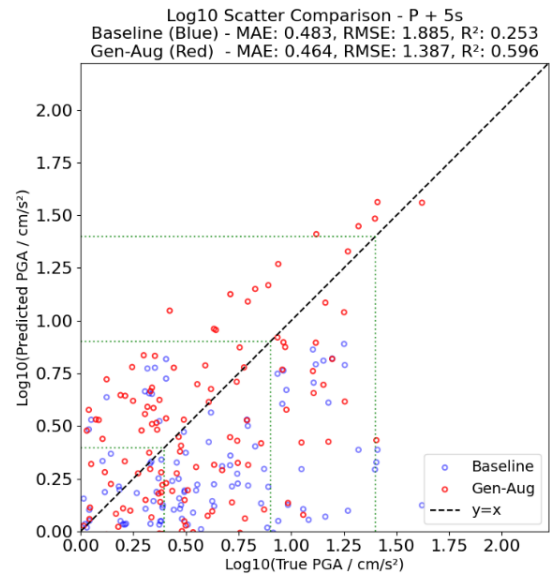


圖 25、第 5 秒預測結果。




圖 26、第 10 秒預測結果。




圖 27、第 15 秒預測結果。




圖 28、第 20 秒預測結果。




圖 29、第 25 秒預測結果。

從結果可以看出在早期階段 (3、5、10 秒), Gen-Aug 的表現明顯優於 Baseline。以 5 秒的時間窗格為例, Gen-Aug 的 R^2 值 (0.596) 遠高於 Baseline (0.253), 且 RMSE (1.387) 也顯著低於 Baseline (1.885)。這顯示 Gen-Aug 的紅點分佈更緊密地收斂於理想線周圍, 證明了經生成資料訓練的模型, 在資訊不足的早期階段具有更強的預測穩定性。然而, 隨著時間推進至 15 秒以上, 兩組實驗在此測試集當中的預測表現越來越接近, 兩者的 R^2 值變得較為接近。

PGA 區間及誤差分析:

為了更嚴謹地評估模型在真實大型地震上的預測表現, 並分析生成資料在「預警初期」與「預測最終值」上的不同貢獻, 我們使用了一個獨立的、更具挑戰性的

測試資料集。此資料集專門由 2024 年 4 月 3 日花蓮主震 (ML7.2) 及其 18 起相關餘震所組成，規模分布於 5.00 至 7.2 之間。選用此資料集的原因，是為了專門測試並量化兩組模型在真實、且普遍偏大的地震事件上的預測穩健性。

我們詳細比較了 Baseline 與 Gen-Aug 方法在 P 波抵達後在兩個不同時間點的預測誤差。首先，在預警反應初期 (P 波抵達後 5 秒)，如表 6 所示，兩組實驗在高震度區間 ($PGA > 25 \text{ cm/s}^2$) 的誤差都非常高，顯示了僅憑 10 秒波形預測強震的極端困難性。Gen-Aug 的 MAE (82.28) 僅略優於 Baseline (83.11)，改善尚不顯著。這表明在觀測資料極度受限時，生成資料的幫助有限。

然而，當波形資訊更完整時 (P 波抵達後 30 秒)，Gen-Aug 的優勢便體現出來，如表 7 所示。在高震度區間 ($PGA > 25 \text{ cm/s}^2$)，Baseline 的 MAE 高達 51.26，Gen-Aug 的 MAE 則顯著降低至 44.50，RMSE 也從 58.94 大幅下降至 52.58。

此測試的結果證實，本研究提出的擴增方法，尤其是加入了 GMPE 經驗公式所創造的高風險情境樣本後，確實能有效改善模型在傳統資料集中學習不足的「高震度」區間。雖然在極短的初期時間窗內改善有限，但它顯著提升了模型對大地震「最終 PGA」的預測準確性與可靠性，有效修正了模型的系統性低估偏誤。

表 6、P + 5 秒 PGA 各區間 MAE 與 RMSE

PGA Range	Baseline MAE	Gen-Aug MAE	Baseline RMSE	Gen-Aug RMSE
<0.8	0.2113	0.3540	0.2707	0.4783
0.8-2.5	1.0330	1.0573	1.1701	1.3660
2.8-8	3.4629	2.8793	3.7493	3.2344
8-25	14.1216	12.8833	15.0405	14.6504
>25	83.1150	82.2806	94.4595	93.6362

表 7、P + 25 秒 PGA 各區間 MAE 與 RMSE

PGA Range	Baseline MAE	Gen-Aug MAE	Baseline RMSE	Gen-Aug RMSE
<0.8	0.1571	0.2193	0.2103	0.3322
0.8-2.5	0.8304	0.7798	1.0068	0.9802
2.8-8	3.2754	2.4407	3.6061	2.7745
8-25	12.2408	9.5513	12.6153	10.8038

3.6.3 0403 花蓮地震事件預警測試

上一節的整體效能分析顯示，Gen-Aug 在高 PGA 區間的統計誤差顯著降低。本節將進一步聚焦於此一改進的實際成效，即直接評估模型在 2024 年 4 月 3 日規模 7.2 的花蓮地震事件上的預警表現。在前一期計畫當中 Baseline 模型在面對此一罕見大規模地震時，存在嚴重的低估問題。本研究的核心目的之一，便是利用生成的資料來解決此一難題。為此，我們將針對臺北地區的數個關鍵測站，並列比較兩組實驗的預測結果。

下圖 30-36 中，展示每個測站隨時間的 PGA 預測變化：橫軸代表自 P 波初達後的时间（秒）。縱軸為預測的 PGA（ cm/s^2 ），並以對數尺度顯示。紅色實線代表該測站的真實 PGA（True PGA），而綠色和橘色的虛線則分別代表震度 3 級（ $\text{PGA} > 8$ ）與震度 4 級（ $\text{PGA} > 25$ ）的警報閾值。從圖中對比可清晰見得，Gen-Aug 方法最終的 PGA 預測值明顯高於 Baseline。此結果表明，Gen-Aug 方法更有效地逼近了此次強震的真實 PGA（圖中紅色實線所示），從而顯著緩解了 Baseline 模型原有的嚴重低估問題。




圖 30、ANP 測站預測。




圖 31、NHY 測站預測。

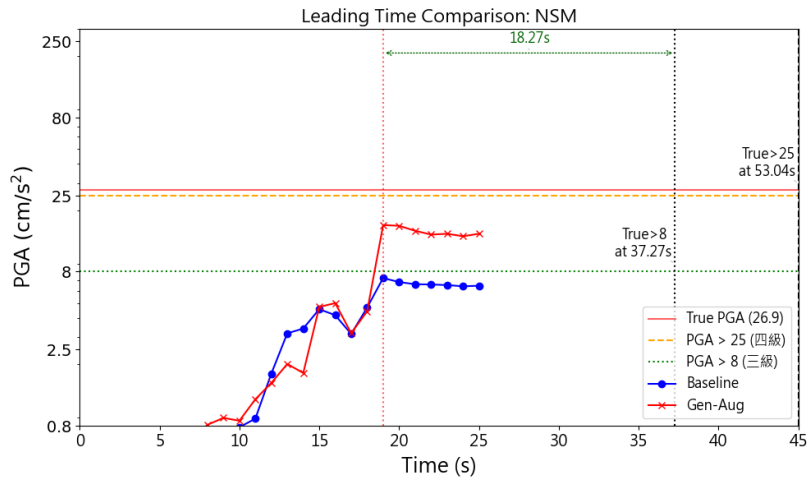


圖 32、NSM 測站預測。




圖 33、TAP 測站預測。




圖 34、TWA 測站預測。




圖 35、TWS1 測站預測。




圖 36、TWY 測站預測。

3.7 結論

本研究旨在開發一個高品質的條件式地震波形生成模型，並驗證其在解決區域型地震預警中「大規模地震樣本缺失」此一關鍵問題上的實際應用成效。

首先提出了一個以 cGAN 為基礎的生成模型。此模型的核心創新在於結合了 Transformer 架構的生成器與鑑別器，用於捕捉複雜的時序依賴性；並引入時頻域（STFT）損失，以確保生成波形在時域形態與頻譜結構上均能與真實資料高度一致。

隨後的模型評估結果證實了此架構的有效性：時域波形可視化比對中，模型成功重現了隨距離衰減的振幅、P-S 波到時差等關鍵物理特徵；頻譜特性分析中，無論是總體平均 FAS 或是基於規模與距離的情境 FAS，生成波形的平均頻譜均與真實資料高度吻合。PGA 量化驗證中，合成波形的 PGA 亦與真實值展現了良好的一致性。

基於上述成果，本研究最後將此模型應用於下游的區域型預警任務，比較了使用基準組（Baseline）與生成資料增強組（Gen-Aug）訓練的 MP-GAT 預警模型。實驗結果明確證實，針對 0403 花蓮地震的個案測試中，Gen-Aug 方法的最終預測 PGA 值明顯高於 Baseline，成功緩解了 MP-GAT 模型因缺乏樣本而產生的嚴重低估問題，並爭取到了更長的預警領先時間。

總而言之，本研究不僅提出了一個先進的地震波形生成模型，更透過嚴謹的下游任務驗證，證實了此模型作為數據增強工具，在改善地震預警系統效能、解決罕見樣本不足的難題上，具有重大的實務應用價值。

肆、即時地震預警系統

4.1 簡介

本研究開發的即時地震預警系統（EWS）是一套基於 Cloud-Native 理念所重構的新一代平台，目的在透過全面導入容器化服務架構，取代傳統地震監測領域中常見的單體式系統。系統的設計核心在於模組化，它將地震數據處理的關鍵環節，從初始的波形接收、P 波觸發偵測、震央定位、發報，乃至於關鍵的峰值地動加速度（PGA）預測等流程，切分並封裝成獨立運作的服務單元。這些服務之間完全獨立，並透過高效能、低負荷的 MQTT 訊息中介層進行協同運作與即時資料交換，從而確保整個預警流程具備極高的彈性、優異的可維護性以及高效的水平擴展能力。

在實作層面，本平臺藉由 Docker 容器技術，實現了應用程式的容器化封裝與快速部署，克服了傳統系統對於複雜原始碼編譯和依賴關係管理的繁瑣需求，確保了在不同環境下（開發、測試、生產）的部署一致性與可攜性。在資料傳輸環節，系統選用 MQTT 協議來傳送輕量級 JSON 格式的地震波形資料，極大化了資料交換的即時性。在核心預測功能上，本系統則以深度學習模型（包括 UNet 和 Transformer）作為核心引擎，取代了傳統的經驗公式或統計方法，大幅提升了預警

的準確性。更關鍵的是，系統設計充分利用了 GPU 加速運算能力進行模型推論，確保在地震發生的黃金時間內，能夠以極致的低延遲完成所有預測計算，從而最大化即時預警系統的實用價值。

4.2 系統架構

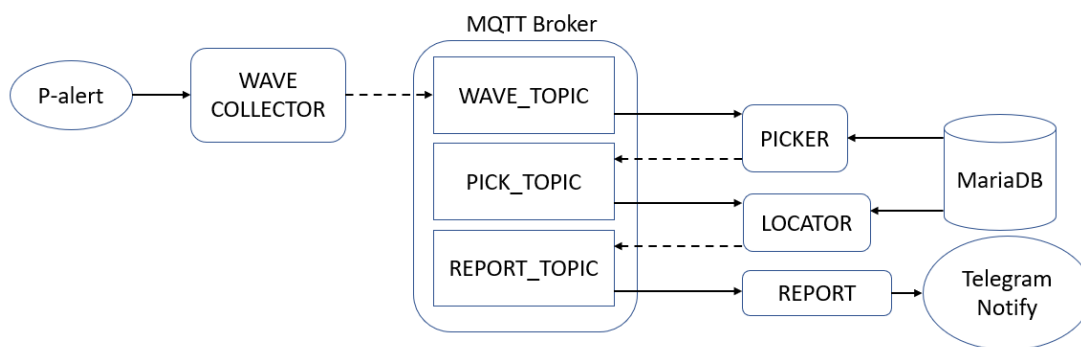


圖 37、平臺架構。

4.2.1 MQTT 協議

MQTT (Message Queuing Telemetry Transport) 協議是為了克服低頻寬環境下，數據傳輸高延遲與網路連線不可靠等問題。由於其協定頭開銷被設計得極小，能夠以最低的網路流量負載傳送數據，此特性完美契合了地震預警系統對毫秒級別低延遲的嚴格要求。在實際運作中，各服務模組，例如 Picker、Locator、Report 等，無需預先知道彼此的網路位址或運行狀態，僅需透過 MQTT Broker 進行發布或訂閱特定主題 (Topic) 的訊息即可。例如，Wave Collector 模組發佈波形數據至 waveform 主題，而 Locator 模組則訂閱 pick 主題以接收 P 波到時資訊。這種非同步、發布、訂閱的機制極大地提升了數據傳輸的效率，並避免了傳統系統中常見的效率較低且複雜的輪詢 (Polling) 機制。

導入 MQTT 協議，徹底解決了傳統單體式架構中模組之間高度依賴的問題。Broker 集中管理訊息佇列與分發，使每個 AI 推論模組都能獨立啟動與運行，僅依賴於 Broker 所提供的訊息流，大大增強了系統的容錯性與彈性。系統透過定義清晰的 MQTT 主題層級結構，實現了複雜數據流的有序管理：waveform 主題負責原始波形數據的分發，pick 主題傳遞 P 波觸發點，locator 主題承載震央定位的估算成果，而 report 主題則用於發送最終的警報資訊。這種分層管理使得系統具備卓越的擴展性，未來當需要引入新的預警模型或功能時，只需讓新模組訂閱既有的主題，即可直接整合並開始工作，無需修改任何現存模組的程式碼。

4.2.2 WAVE COLLECTOR 模組

此模組作為地震預警數據進入系統的統一入口，其功能是將來自 P-alert 儀器

的即時波形資料進行格式轉換與發佈。它主動連接至臺大 Earthworm Forward 模組所中繼的 TCP 封包流，執行解包操作，提取 P-alert Mode 1 封包頭、測站代碼、通道、採樣率以及原始加速度 counts。隨後，模組將這些數據重新結構化，轉換為標準化的 Miniseed 格式，並封裝成輕量級的 JSON 訊息。此訊息會即時發佈到特定的 MQTT 主題，發佈品質 (QoS) 設為 0。這項設計將儀器端複雜的數據格式與上層 AI 模型的處理邏輯徹底分開，使得系統各部分可以獨立運行與更新。

4.2.3 PICKER 模組

Picker 模組專責於地震 P 波的即時觸發偵測，訂閱 waveform 主題，利用內部快取 (Cache) 保留各測站最近約 10 秒的三分量波形資料。此模組的計算密集型核心是一個獨立的推論執行緒池 (Inference thread pool)，它會以每秒滑動一次的頻率，將批次 (Batch) 處理的波形數據送入訓練好的 TC-UNet 深度學習模型進行 P 波到時 (Ptime) 的預測。預測完成後，模組會將包含 Ptime、機率等資訊的 Pick Info JSON 訊息發佈至 pick 主題。

4.2.4 LOCATOR 模組

Locator 模組負責地震事件的快速震央定位，是系統中涉及多站點數據融合與 AI 推論的核心決策單元。此模組同時啟動了多個獨立進程 ($N=4, 6, 8, 10$)，每個進程各自預載專屬的 Transformer 定位模型，以支援多門檻同時觸發的需求。其運作核心是利用獨立的執行緒持續訂閱 pick 主題，將到達的 Pick 訊息寫入時間窗快取。當在設定的短時間窗內 (例如 3 秒) 累積到足夠數量的不同測站 Pick 後，即視為有效事件並觸發一次定位推論。模組將選定的 N 筆 Pick 資訊 (包含經緯度、Ptime 等) 轉換為向量，批次送入對應的 Transformer 模型，迅速估算震央經緯度、海拔高度、與發震時刻。最終的定位結果連同參與站點清單被封裝為 JSON，發佈至 report 主題。

4.2.5 REPORT 模組

發報模組是系統管線的最終環節，專門處理警報訊息的視覺化與推送。它持續監聽 report 主題，一旦收到規模計算模組發來的完整地震報告 JSON 訊息，即刻啟動發報流程。模組首先會根據定位結果與參與站點清單，生成地震震央的圖片。隨後，它利用 Telegram Bot API，將包含震央、Picks 站點等訊息的圖文警報，推送到指定的 Telegram Chat 頻道或群組，完成對終端用戶的即時通知。

4.3 具體成果

為驗證本系統在真實地震事件中的預警效能與準確性，我們選取了近期發生的兩起規模相近、最大震度皆達 3 級的地震事件進行對比分析，分別是 2025 年

10 月 31 日與 2025 年 11 月 05 日的事件。本研究將系統發出的第一報預警結果與交通部中央氣象署 (CWA) 的正式地震報告進行比對，評估本系統的震央估算精度與預警時效性。

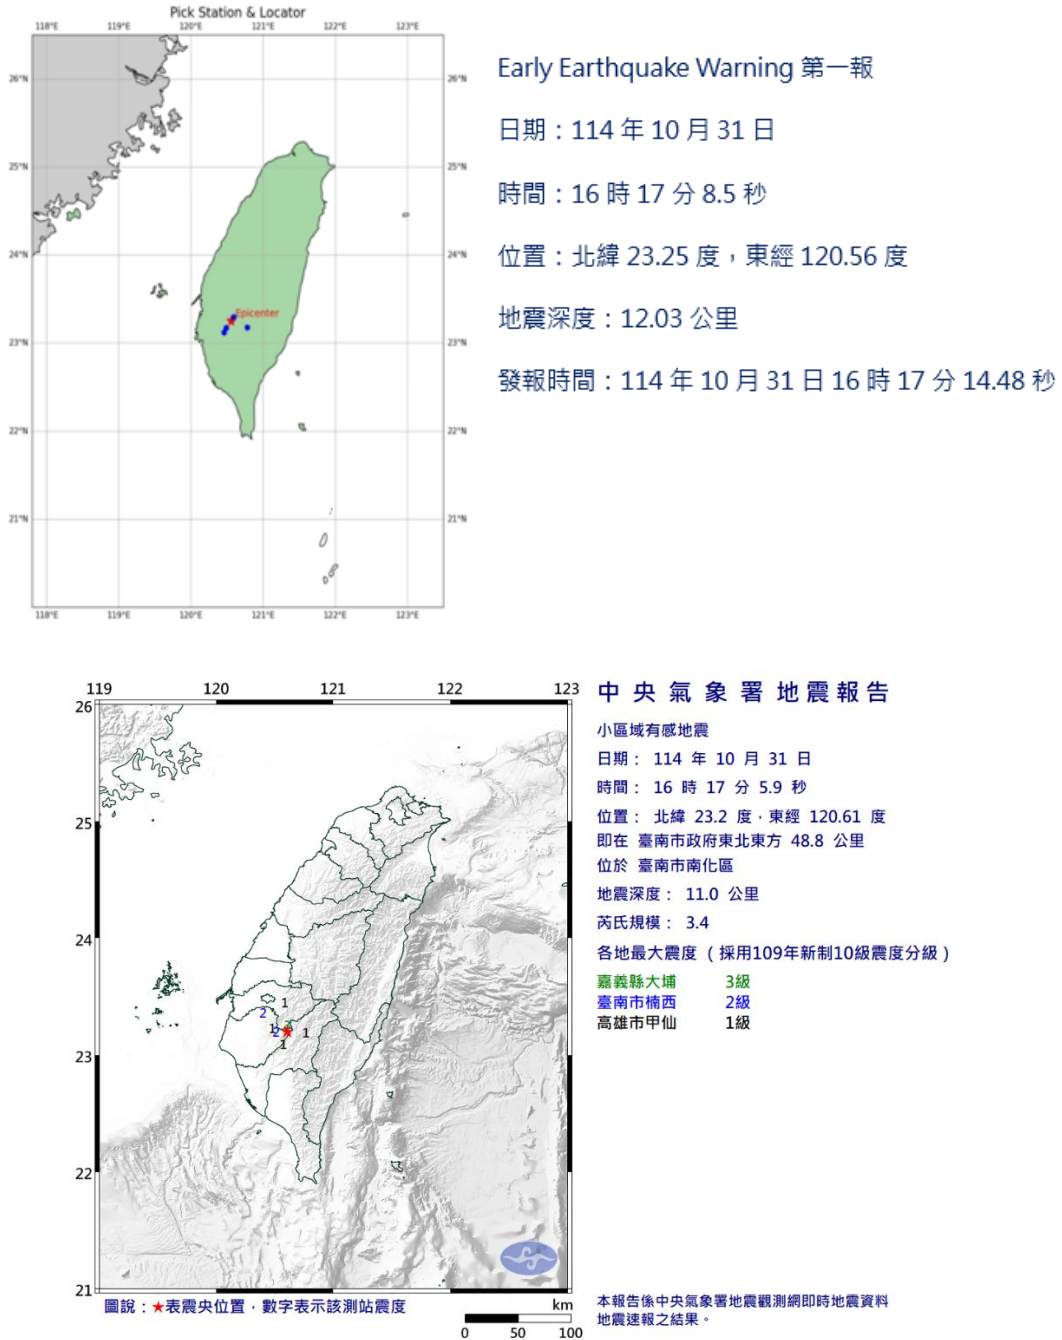



圖 38

圖 38 為一起小區域有感地震，氣象署報告的芮氏規模為 3.4，最大震度達 3 級。系統的第一報發震時間和氣象署的報告時間差約 2 秒。系統預警的震央位置估與氣象署報告位置相差 7.64 公里。系統預測的地震深度與氣象署報告的深度相

差約 1 公里。整體而言，本系統在事件發生後迅速捕捉到訊號，並在事件開始後約 8 秒完成多站點數據接收、模型推論與發報準備，體現了微服務架構的即時性。



Early Earthquake Warning 第一報

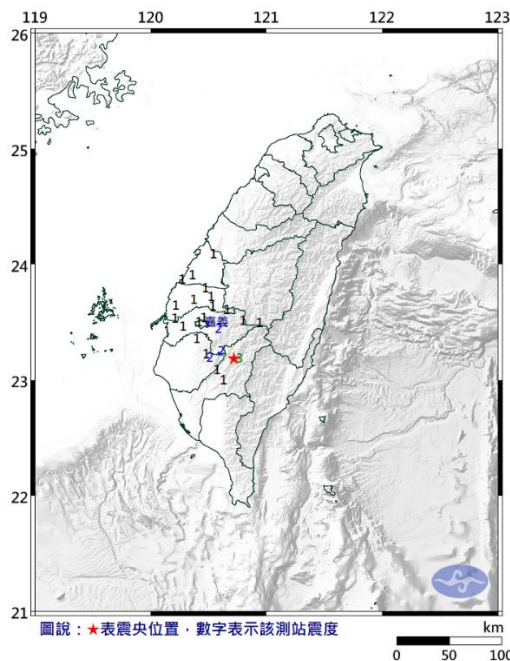
日期：114 年 11 月 5 日

時間：8 時 12 分 0.1 秒

位置：北緯 23.19 度，東經 120.73 度

地震深度：8.68 公里

發報時間：114 年 11 月 5 日 8 時 12 分 02.92 秒



中央氣象署地震報告

小區域有感地震

日期：114 年 11 月 5 日

時間：8 時 11 分 57.8 秒

位置：北緯 23.18 度·東經 120.72 度

即在 高雄市政府東北方 75.0 公里

位於 高雄市桃源區

地震深度：8.2 公里

芮氏規模：3.9

各地最大震度 (採用109年新制10級震度分級)

高雄市桃源	3級
嘉義縣大埔	2級
臺南市楠西	2級
南投縣玉山	1級
嘉義市	1級
雲林縣草嶺	1級
嘉義縣太保市	1級
雲林縣斗六市	1級
彰化縣二林	1級
彰化縣彰化市	1級

圖說：★表震央位置，數字表示該測站震度

本報告係中央氣象署地震觀測網即時地震資料地震速報之結果。

圖 39

圖 39 同樣為小區域有感地震，氣象署報告的芮氏規模為 3.9，最大震度亦達 3 級。系統的第一報發震時間估和氣象署的報告時間差約 2 秒。系統預警的震央位置與氣象署報告的位置相差 1.41 公里，匹配度極高。系統預測的地震深度與氣象署報告的深度相差 0.5 公里，深度也非常接近。系統從事件開始到發布第一報

僅耗時約 4 秒，展現了極高的預警速度。



圖 40、警報通知範例。

在定位準確性與響應速度方面，系統都有著不錯的表現。透過對近期兩起最大震度 3 級地震事件的分析，本系統發出的第一報震央位置與氣象署正式報告的吻合度極高，例如在 2025 年 11 月 05 日的案例中，兩者震央位置僅相差約 1.41 公里。更關鍵的是，系統在該案例中能夠在事件開始後約 4 秒內完成多站點數據的接收、Transformer 模型推論與警報發布，充分驗證了 AI 模型結合微服務架構所帶來的極致預警速度。

4.4 結論

本研究成果確立了一套以 Docker 容器化技術為核心的地震即時預警微服務架構，將地震波形數據流中的關鍵模組，如波形資料接收、P 波觸發、震央定位等功能，獨立封裝為容器化服務單元。系統利用 MQTT 訊息中介層實現了數據的低延遲與高可靠傳輸。相較於傳統 Earthworm 架構中繁瑣的程式碼編譯與依賴項管理問題，本架構透過 Docker Compose 達成了環境的一致性、快速部署與彈性擴展，極大地提升了系統的可維護性。此外，系統原生支援在 CPU 與 GPU 兩種模式下運行 AI 模型，並利用 Telegram Bot API 完成對終端使用者的即時警報推送。

總結來說，此平臺的建構不僅展示了深度學習模型在即時地震預警任務中具備的高度可行性與精確性，同時也證明了容器化與微服務架構在提升系統可維護性與水平擴展能力方面的顯著優勢。此系統為未來結合更複雜的 AI 模型、物聯網感測器以及大規模雲端分析奠定了堅實的技術基礎。

參考文獻

- A. Vaswani et al., "Attention is all you need," in *Proc. Int. Conf. Neural Inf. Process. Syst. (NeurIPS)*, 2017, pp. 5998–6008.
- O. M. Saad et al., "Deep Learning Peak Ground Acceleration Prediction Using Single-Station Waveforms," *IEEE Trans. Geosci. Remote Sens.*, vol. 62, pp. 1–13, 2024.
- I. J. Goodfellow et al., "Generative adversarial networks," *Commun. ACM*, vol. 63, no. 11, pp. 139–144, 2020.
- J.-B. Grill et al., "Bootstrap your own latent a new approach to self-supervised learning," in *Proc. 34th Int. Conf. Neural Inf. Process. Syst. (NIPS)*, 2020, pp. 21,271–21,284.
- R. Yamamoto, E. Song, and J.-M. Kim, "Parallel wavegan: A fast waveform generation model based on generative adversarial networks with multi-resolution spectrogram," in *Proc. IEEE Int. Conf. Acoust., Speech Signal Process. (ICASSP)*, 2020, pp. 6199–6203.

114 年地震預警作業技術研發之相關研究

子計畫四

新穎的地震基石模型與即時系統

陳冠宇 林怡萱 徐旻暄 陳曉宣

國立臺灣科技大學

摘要

臺灣位於歐亞大陸板塊與菲律賓海板塊交界，為全球地震活動最為頻繁的區域之一，每年約發生兩萬起地震事件，其中不乏具高度破壞性的震災，對民眾安全與基礎設施造成重大威脅。因此，提升地震監測與預警系統的準確性與即時性一直是地震學領域的核心課題。近年來，深度學習技術於多項地震研究中展現卓越表現，包括 P 波自動拾取 (P-wave Picking) 與地表最大加速度 (Peak Ground Acceleration, PGA) 預測等任務，皆能有效從複雜地震波形中萃取關鍵特徵。然而，傳統模型仍依賴大量人工標註資料，限制了其可擴展性。本研究延續地震基石模型 (Earthquake Foundation Model) 的開發方向，聚焦於運用自監督學習 (Self-Supervised Learning, SSL) 技術，從海量未標註的地震波形中自動提取高價值特徵。我們將語音領域中最具代表性的兩種 SSL 預訓練架構：Wav2Vec 2.0 與 HuBERT 引入地震學領域，並建構以地震資料為核心的預訓練流程。透過大規模自監督預訓練與多項下游任務微調，本研究驗證地震基石模型的可行性與泛化能力，並展現其在地震監測與預警應用上的實際潛力。

關鍵字：深度學習、預訓練模型、單測站、多測站。

Abstract

Taiwan is located at the boundary between the Eurasian Plate and the Philippine Sea Plate, making it one of the most seismically active regions in the world. Approximately twenty thousand earthquakes occur annually, and among them, many events exhibit high destructive potential, posing significant threats to public safety and critical infrastructure. Consequently, improving the accuracy and timeliness of earthquake monitoring and early warning systems has long been a central challenge in seismology. In recent years, deep learning techniques have demonstrated remarkable success across various seismic applications, including P-wave picking and Peak Ground Acceleration (PGA) prediction, by effectively extracting key features from complex seismic waveforms. However, traditional models still rely heavily on large quantities of manually annotated data,

limiting their scalability. Building upon the development of the Earthquake Foundation Model, this study focuses on leveraging Self-Supervised Learning (SSL) techniques to automatically extract high-value representations from vast amounts of unlabeled seismic waveforms. We introduce two of the most influential SSL pre-training architectures from the speech processing domain, Wav2Vec 2.0 and HuBERT, into seismology and design a pre-training pipeline tailored to seismic data. Through large-scale SSL pre-training and fine-tuning across multiple downstream tasks, this work verifies the feasibility and generalization capability of the Earthquake Foundation Model, demonstrating its practical potential for improving earthquake monitoring and early warning applications.

Keywords : Deep Learning, Pre-trained Models, Single-station, Multi-station.

壹、P 波到時拾取任務與微調方法

1.1 背景

P 波到時拾取 (P-phase Picking) 是地震預警系統 (EEW) 的核心環節，其精度直接決定了預警的提前時間與準確率。傳統的訊號處理方法 (如 STA/LTA) 在高雜訊環境下表現不穩，而近年來以深度學習為基礎的監督式學習模型 (如 PhaseNet, EQTransformer) 則高度依賴大量、高品質的人工標註數據。面對地震學數據的標註成本高昂與數據量巨大但標註稀疏的矛盾，本研究嘗試探討以自監督學習 (Self-supervised Learning, SSL) 為基礎的模型作為解決方案。

我們選擇了語音處理領域最成功的兩種 SSL 模型：Wav2Vec2.0 (對比學習範式) 和 HuBERT (遮罩預測範式)，將其客製化為地震基石模型 (Earthquake Foundation Model) 的骨幹，旨在從海量的未標註地震波形中提取通用的、具時序感的特徵。實驗涵蓋 Freeze, Weighted-sum, Fine-tune 三種微調策略，並將這兩種模型命名為 SeisWav2Vec2.0 和 SeisHuBERT。

1.2 下游任務應用

P 波到時拾取為地震波形分析中的關鍵任務。輸入為三分量波形 (Z、N、E)，輸出為對應時間序列的 P 波到達機率分佈。預測結果可用高斯標註 (Gaussian labeling) 作為訓練目標，以提升時間定位的連續性。本章介紹 P 波拾取任務之設定與評估指標，為後續模型 (SeisWav2Vec2.0 與 SeisHuBERT) 微調與性能比較提供基礎。本研究在相同資料集上評估不同模型與策略，以確保結果具可比性。

1.2.1 資料集及前處理

- 資料集：如表 1.1 所示，下游任務微調使用了包含 P 波、S 波和雜訊 (noise) 的綜合標註數據集。加入 Noise 數據的目的是提高模型在真實雜訊環境下的

魯棒性 (Robustness)，降低誤報率。

表 1.1：P 波到時拾取任務使用的資料集

	Training	Development	Test
CWASN	505k	52k	111k
TSMIP	69k	11k	8k
CWASN Noise	599k	71k	135k

- CWASN (中央氣象署地震觀測網)：共計使用約 1,473k 筆事件；涵蓋時間範圍為 2012 年至 2021 年。
- TSMIP (臺灣強地動儀資料庫)：共計使用約 88k 筆事件；涵蓋時間範圍為 2012 年至 2021 年。
- 輸入格式：所有波形均為 3-Channel(Z/N/E)，長度為 30 秒(3000 採樣點)，採樣率 100Hz。

1.2.2 下游任務模型與微調策略

我們在預訓練之後接上一個任務導向的 CNN 解碼器 (Decoder)，並採用三種策略進行微調：




圖 1.1：微調策略的示意圖

1. **Freeze / Decoder-only Training**：凍結預訓練地震基石模型（即 SeisWav2Vec2.0 或 SeisHuBERT）所有參數，僅訓練 CNN 解碼器。
2. **Weighted-sum Training**：凍結預訓練地震基石模型，但訓練一組層級權重，對 Transformer 各層級輸出進行加權，然後輸入給解碼器。此策略用於評估各層特徵對拾取任務的相對重要性，其優勢在於不改變預訓練地震基石模型的通用特徵，但能動態選擇對拾取任務最有貢獻的特徵層次。
3. **Fine-tuning**：更新預訓練地震基石模型及解碼器的所有參數。此策略用於達到該任務的最佳性能，允許模型對預訓練特徵進行任務優化，以達到該任務的最佳性能。

表 1.2：四個判斷成績的指標

名稱	英文全名	含義	範例
TP	True Positive	預測有，實際也有	模型正確偵測到一次真實的 P 波到達
FP	False Positive	預測有，實際沒有	模型誤報：把雜訊誤當成 P 波
TN	True Negative	預測沒有，實際沒有	模型正確判斷這段沒有地震訊號
FN	False Negative	預測沒有，實際有	模型漏報：真有 P 波卻沒偵測到

表 1.3：六個評估模型性能的指標

指標名稱	趨勢	解釋
F1-score	↑	綜合 Precision 和 Recall 的調和平均數，是判斷模型綜合能力的主要指標。
Precision	↑	預測為正樣本中，真實為正的比例（衡量誤報率）。
Recall	↑	真實為正樣本中，被成功預測的比例（衡量漏報率）。
Mean Error	↓	預測到時與真實到時的平均偏差。
Standard Deviation	↓	預測到時誤差的標準差，衡量預測的穩定性與一致性。
Mean Absolute Error	↓	預測到時與真實到時的平均絕對誤差。

1.2.2 評估指標與到時誤差計算

我們採用地震學界常用的六個指標來全面評估模型的性能，同時考慮分類準確性與時間精度。

- 指標定義：參照表 1.2 的四個判斷成績的指標，與表 1.3 的六個評估模型性能的指標。
- True Positive 定義：當模型預測的 P 波到時與真實 P 波之間的絕對時間差小於 0.5 秒（50 個採樣點）時，視為 True Positive。

貳、預訓練地震基石模型 SeisWav2Vec2.0 之研究

2.1 背景

地震監測和預警是災害預警系統中至關重要的組成部分。隨著深度學習的發展，許多研究已探索這些方法在相關任務中的應用 [1][2][3][4]。其中，自監督學習因其能夠從未標註答案的資料中學習有用的特徵，而成為一項極具潛力的技術，並引起了廣泛關注 [7]。通過這種方式訓練的模型可以對參數進行微調，以適應特定任務，通常能夠獲得更好的效果，或顯著減少所需的標註資料。

儘管已有大量關於深度學習應用於地震監測和預警的研究，但在此領域中對自監督學習的應用仍然較少。因此我們提出了一種大型地震模型 (Large Earthquake Model, LEM)，以探討自監督學習在構建地震預訓練模型方面的有效性和效率。

近年來，自監督學習的預訓練模型在許多研究領域取得了顯著成效，如自然語言處理和語音處理。這些預訓練模型最具吸引力的特點是訓練時不需要使用標註答案的資料。換句話說，它們通過簡單的目標（如掩碼預測和對比學習）利用資料本身來學習具有訊息量和通用性的表示 (Representations)。基於這些表示，可以進行微調以獲得任務導向的模型，通常能在幾乎所有下游任務中達到最先進的性能。

鑑於這些優勢，越來越多的基礎模型被提出並證明可以提升各類任務的性能，同時減少了數據標記需求，降低了複雜或耗時任務的入門門檻。

2.2 方法

對比學習 (Contrastive Learning) 方法已在語音處理中展現了出色的表現。Wav2Vec 2.0 [8] 使用對比學習作為自監督學習的訓練目標，通過提取特徵後掩蓋部分語音特徵，並對掩蓋特徵和其他區域的量化向量 [12]，進行對比學習，在多種語音任務中達到卓越的效果。

延續此一研究，我們提出了一種新穎的大型地震模型 (LEM)，基於先進的深度學習技術。LEM 以大量未經過標註答案的地震波形進行自監督預訓練，旨在學

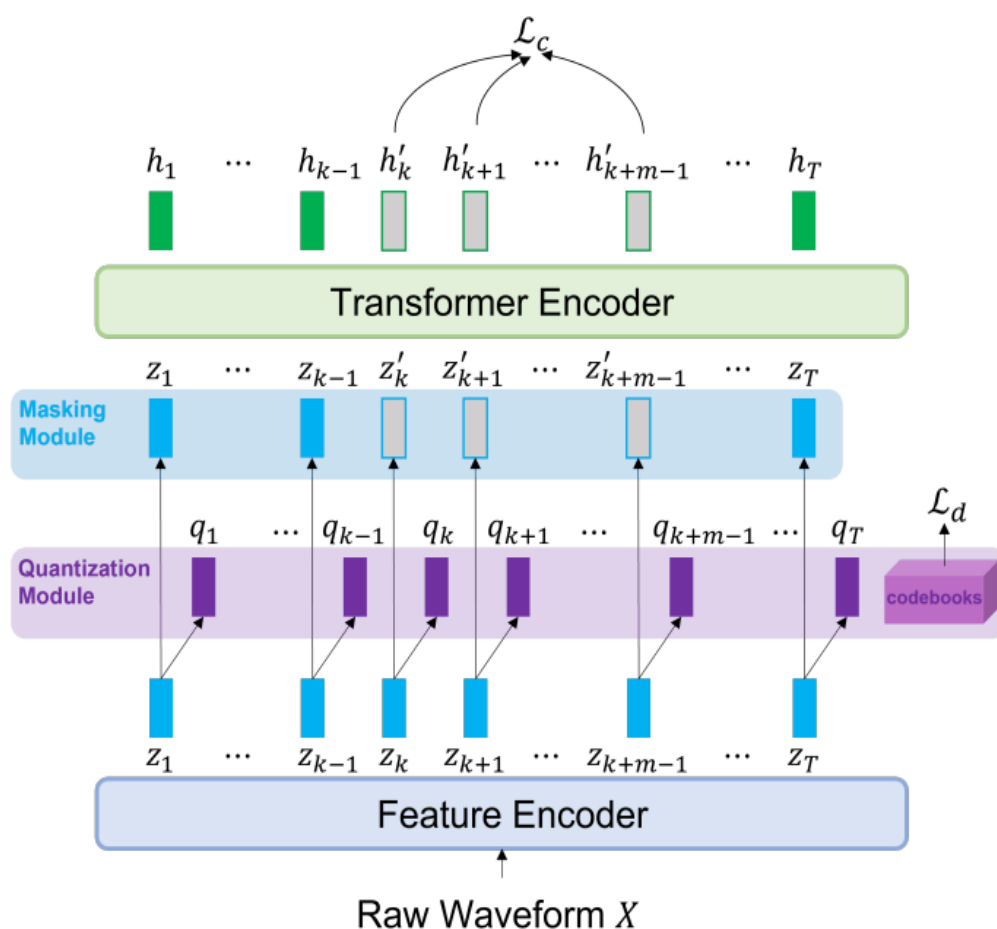


圖 2.1：SeisWav2Vec 2.0 模型架構圖

習通用且具訊息量的地震特徵。經過預訓練後，LEM 允許高效利用大量未標註地震資料進行地震監測任務，無需為每個特定地震任務從頭開始訓練新模型。換句話說，LEM 在經過少量任務導向的標註數據微調後，可有效適應各種地震監測和預警任務。

我們首先探究 Wav2Vec2.0 [8] 模型在大型地震模型中的可行性。它是一種基於對比學習的自監督方法，其核心思想是訓練模型從大量候選樣本中，區分出正確的目標（正樣本）與錯誤的干擾項（負樣本）。我們將其原應用於語音波形改為地震波形，並將此模型命名為 SeisWav2Vec 2.0。

SeisWav2Vec 2.0 模型由特徵編碼器 (Feature Encoder)、上下文編碼器 (Transformer Encoder)、量化模組 (Quantization Module) 和遮罩模組 (Masking Module) 組成，如圖 2.1 所示。特徵編碼器用於將原始波形轉換為一系列的向量特徵，由兩層包含層正規化和 GELU 激活函數的時間卷積組成。特徵編碼器將波形數據轉換為連續 embedding，這些 embedding 捕捉地震訊號的局部結構，並作為後續處理的基礎；上下文編碼器位於 SeisWav2Vec 2.0 的末端，引導這些向量學習上

表 2.1：SeisWav2Vec 2.0 預訓練所使用之資料集

	Training	Development	Test
CWASN	505k	52k	111k
TSMIP	69k	11k	8k

下文資訊，該編碼器包含 12 層 Transformer；我們使用量化模組來離散化密集特徵，以模仿自然語言處理中學習字符（token）預測。先前的研究顯示此步驟有助於表徵學習。因此受大型基礎模型訓練成功的啟發，我們引入遮罩預測任務，遮罩模組引入了一個特殊向量，以遮罩部分嵌入，使模型能以自監督方式進行訓練。

2.3 預訓練使用資料集與前處理

SeisWav2Vec 2.0 使用臺灣地震波形資料進行訓練，如表 2.1 所示，包含：

- 資料集：
 - CWASN（中央氣象署地震觀測網）
 - TSMIP（臺灣強地動儀資料庫）
- 輸入格式：所有波形均為 3-Channel（Z/N/E），長度為 60 秒（6000 採樣點），採樣率 100Hz。

2.4 實驗結果與討論

微調過程對於將預訓練期間學習的通用特徵適應於特定的下游任務至關重要。為了緩解不同任務的不同目標，我們將在 SeisWav2Vec 2.0 上堆疊一個簡單的任務導向解碼器。本研究提出並比較了三種微調策略：整個模型訓練（Finetune）、僅解碼器訓練（Freeze）以及加權和僅解碼器（Weighted Sum）訓練 [13]。

我們選擇了 P 波到時拾取和規模估算任務作為範例，來評估預訓練的 SeisWav2Vec 2.0 模型的能力。對於 P 波到時拾取，我們先選用 EQTransformer [6] 和 PhaseNet [5] 作為我們的基線模型(Baseline)。對於規模估算，我們選用 MagNet [11] 作為我們的基線模型。表 2.2 是 SeisWav2Vec 2.0 於 P 波拾取任務的表現。Fine-tune 策略取得最高 F1-score（Dev: 0.9719, Test: 0.9570），顯示完全開放參數微調可最有效利用預訓練特徵。Weighted-sum 表現次之（F1-score Test: 0.9596, Dev: 0.9460），代表不同層特徵的加權組合仍可提供豐富震相資訊。Freeze 模式雖不調整地震基石模型，但仍顯著優於監督式模型，顯示 SeisWav2Vec 2.0 預訓練特徵具良好可遷移性。這代表 SeisWav2Vec 2.0 的對比學習機制能捕捉長時序震波特徵，而非僅依賴局部振幅變化。Fine-tune 進一步使模型調整至地震資料分佈，故表現最佳。

表 2.2：使用完整資料集時，P 波到時拾取的實驗結果

原始實驗模型效能比較		P 波 Picking 成績					
Model	Dataset	Precision	Recall	F1	Mean	Std.	MAE
EQTransformer	Dev	0.9379	0.9824	0.9596	0.0009	0.0210	0.0051
	Test	0.9118	0.9741	0.9419	0.0017	0.0252	0.0064
PhaseNet	Dev	0.9320	0.9453	0.9386	0.0008	0.0259	0.0061
	Test	0.9106	0.9393	0.9247	0.0010	0.0280	0.0067
SeisWav2Vec 2.0 Freeze	Dev	0.9439	0.9668	0.9552	0.0005	0.0222	0.0056
	Test	0.9257	0.9513	0.9383	0.0007	0.0251	0.0064
SeisWav2Vec 2.0 Weighted Sum	Dev	0.9381	0.9821	0.9596	0.0015	0.0216	0.0053
	Test	0.9234	0.9698	0.9460	0.0010	0.0249	0.0064
SeisWav2Vec 2.0 Finetune	Dev		0.9926	0.9719	0.0001	0.0162	0.0038
	Test	0.9286	0.9871	0.9570	0.0003	0.0199	0.0047

表 2.3 顯示 SeisWav2Vec2.0 在地震規模估算 (Magnitude Estimation) 任務的結果，並與傳統監督式模型 MagNet 比較。Weighted-sum 策略在各項指標中表現最佳 (Dev MAE=0.1943、 $R^2=0.8912$)，其誤差明顯低於基線模型 MagNet (MAE=0.3063)。Freeze 模式次之，Fine-tune 的表現不如前兩者。在規模估算任務中，SeisWav2Vec2.0 的對比學習能捕捉震波整體能量與振幅分佈，因此不需全面微調即可獲得穩定結果。Weighted-sum 能同時利用不同層級的時間-頻率資訊，使預測誤差降低。

表 2.3：使用完整資料集時，規模估算的實驗結果

原始實驗模型效能 比較		所有規模值實驗結果				規模值大於 4 之實驗結果			
		MAE	MSE	Std.	R2	MAE	MSE	Std	R2
MagNet	Dev	0.3063	0.1818	0.2965	0.7137	0.3471	0.2291	0.3296	0.5339
	Test	0.4141	0.2919	0.3470	0.4511	0.4965	0.4004	0.3924	0.4523
SeisWav2Vec 2.0 Freeze	Dev	0.2258	0.0934	0.2059	0.8630	0.2581	0.1199	0.2308	0.7289
	Test	0.2863	0.1374	0.2355	0.7789	0.3212	0.1717	0.2618	0.6069
SeisWav2Vec 2.0 Weighted Sum	Dev	0.1943	0.0702	0.1801	0.8912	0.2209	0.0862	0.1933	0.7668
	Test	0.2488	0.1044	0.2062	0.8258	0.2792	0.1285	0.2248	0.6752
SeisWav2Vec 2.0 Finetune	Dev	0.3010	0.1424	0.2276	0.7666	0.3625	0.1975	0.2571	0.4765
	Test	0.3970	0.2237	0.2572	0.5998	0.4536	0.2854	0.2821	0.2548

接著，我們測試在僅有少量標註資料的狀況下，地震基石模型是否可以發揮預訓練模型的價值。表 2.4 展示了少樣本實驗結果，當我們僅使用 0.01% 的訓練資料時，SeisWav2Vec2.0 的 Fine-tune 仍可達到較好的成績 (F1-score Dev: 0.9470, Test: 0.9291)，相較於 PhaseNet (Dev: 0.3237, Test: 0.3133) 有巨大差距。這證明自監督預訓練可在標註資料稀缺時維持穩定效能，對實際地震預警資料環境具有重要意義。

表 2.4：使用 0.01%資料集時，P 波到時拾取的實驗結果

僅使用 0.01%資料實驗模型效能比較		P 波 Picking 成績					
		Precision	Recall	F1	Mean	Std.	MAE
EQTransformer	Dev	0.2399	0.8670	0.3759	0.0010	0.0557	0.0152
	Test	0.2329	0.8597	0.3665	0.0012	0.0560	0.0154
PhaseNet	Dev	0.1935	0.9889	0.3237	0.1971	0.0728	0.2094
	Test	0.1863	0.9820	0.3133	0.1983	0.0725	0.2105
SeisWav2Vec 2.0 Freeze	Dev	0.9183	0.9418	0.9299	0.0059	0.0349	0.0102
	Test	0.9132	0.9202	0.9167	0.0062	0.0367	0.0110
SeisWav2Vec 2.0 Weighted Sum	Dev	0.9211	0.9626	0.9414	0.0077	0.0346	0.0110
	Test	0.9089	0.9475	0.9278	0.0082	0.0373	0.0120
SeisWav2Vec 2.0 Finetune	Dev	0.9276	0.9673	0.9470	0.0006	0.0298	0.0076
	Test	0.9034	0.9563	0.9291	0.0007	0.0328	0.0082

表 2.5 顯示 SeisWav2Vec2.0 僅使用 0.01%標註資料時，在規模估算任務的少樣本表現。Weighted-sum 策略表現最穩定 (Dev MAE=0.4191, $R^2=0.4719$)，Freeze 其次；MagNet 在相同資料量下 R^2 為負值，顯示預測幾乎失效。實驗結果顯示，對比學習的預訓練特徵具有良好可遷移性，能在低標註環境下保持能量與頻譜分佈的一致性。Weighted-sum 則能根據任務選取適合的特徵，因此在少量標註資料的狀況下，不僅避免了模型產生過擬合的狀況，也仍能維持合理的估算精度。

表 2.5：使用 0.01%資料集時，規模估算的實驗結果

僅使用 0.01%資料 實驗模型效能比較		Normal				M4 (mag≥4)			
		MAE	MSE	Std.	R2	MAE	MSE	Std	R2
MagNet	Dev	0.6365	0.6783	0.5226	- 39.144	0.7577	0.9154	0.5842	- 28.589
	Test	0.6226	0.6833	0.5438	- 64.500	0.7650	0.9616	0.6135	- 55.756
SeisWav2Vec 2.0 Freeze	Dev	0.5233	0.4464	0.4154	0.3815	0.6350	0.6258	0.4718	0.0729
	Test	0.6046	0.5922	0.4760	0.0814	0.7323	0.8138	0.5267	- 0.2885
SeisWav2Vec 2.0 Weighted Sum	Dev	0.4191	0.3013	0.3545	0.4719	0.5149	0.4251	0.4000	0.0065
	Test	0.4887	0.3961	0.3966	0.2331	0.5922	0.5384	0.4332	- 0.2811
SeisWav2Vec 2.0 Finetune	Dev	0.5062	0.4214	0.4065	0.3323	0.6183	0.5942	0.4603	- 0.1303
	Test	0.5924	0.5577	0.4548	- 0.0076	0.7117	0.7573	0.5007	- 0.5914

根據這組實驗，我們可以發現地震基石模型確實已捕捉地震波的通用模式，使模型在少量標註條件下仍能有不錯的任務表現。這顯示自監督學習所提取的特徵在下游任務上具備更強的可遷移性 (transferability)，印證自監督學習在標註不足環境的優勢。其中，Weighted-sum 策略亦表現接近完整微調，反映各層 Transformer 特徵對地震波形的表徵具有層次性貢獻。Freeze 策略的 F1-score 雖低於 Fine-tune，但已超越監督式模型，顯示 SeisWav2Vec2.0 在預訓練階段已學得具區分性的波形特徵。

我們的這項實驗顯示，SeisWav2Vec 2.0 不僅能夠提供具有競爭力甚至更優於當前最先進模型的結果，且僅需 0.01% 的數據即可達到滿意的性能。除其卓越的性​​能外，SeisWav2Vec 2.0 還提供了一種可能的解決方案，能有效應對地震數據標記耗時且費力的挑戰，從而使用極少的標記數據完成任務。

參、預訓練地震基石模型 SeisHuBERT 之研究

3.1 背景

臺灣位處於環太平洋地震帶，地震活動頻繁，平均每年發生上萬起地震事件。為提升地震預警系統的即時性與準確性，地震初期的快速參數判定如 P 波到時預測 (P-wave picking) 至關重要。傳統常用的方法如 STA/LTA (短時能量比) 或經驗法則，雖然易於實作，但在高雜訊環境下準確率不佳，不利於規模化部署，且仰賴手動設定參數，對於大規模自動化預警系統而言存在瓶頸。

HuBERT (Hidden-Unit BERT) [14] 旨在結合 BERT 的遮罩預測能力和語音領域的離散單元概念；是一種源自語音辨識領域的自監督學習模型，透過無標記資料進行預訓練後，可用於下游的語音識別、情緒辨識等任務。其架構適合處理一維時間序列資料，與地震波形訊號形式類似。

本研究嘗試導入源自語音領域的 HuBERT 模型，一種自監督學習架構，藉由其對一維序列訊號 (如語音或地震波形) 結構建模的優勢，探討其應用於地震預測任務的可行性，並分析其在無需大量標註資料下的效能表現與應用潛力。

3.2 方法

HuBERT [4] 沿用了 Wav2Vec2.0 的遮罩結構，但將預訓練目標從對比學習替換為遮罩預測隱藏單元 (Masked Prediction of Hidden Units)，即使用 K-Means 聚類產生的偽標籤 (Pseudo Labels) 作為訓練目標，整體流程如圖 3.1 所示。當我們將 HuBERT 介紹於地震領域中時，SeisHuBERT 與 SeisWav2Vec 2.0 採用完全相同的 CNN Feature Encoder 和 Transformer Encoder 骨幹。相較於 SeisWav2Vec 2.0 的對比學習，SeisHuBERT 使用 K-Means 聚類產生的偽標籤作為訓練目標，訓練複雜度相對較低，且更專注於語義連貫性的學習。我們訓練了 base、large、xlarge，三種不同大小的 SeisHuBERT 模型，模型規模與架構如圖 3.2 所示。

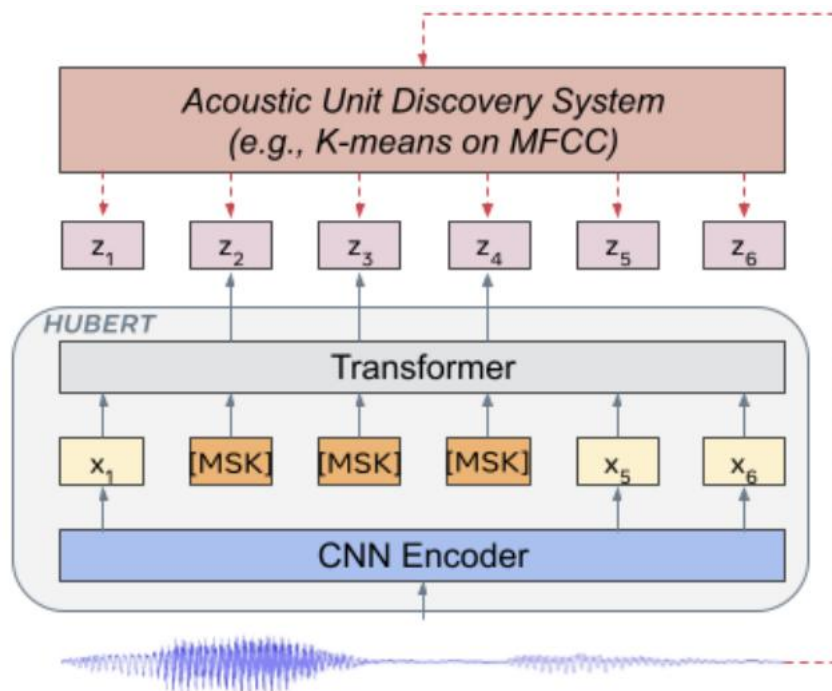


圖 3.1: HuBERT 預訓練架構: 模型以遮蔽輸入片段為目標, 預測其 pseudo label

3.2.1 預訓練目標

HuBERT 的核心是其兩階段的偽標籤生成與訓練策略:

1. Stage 1: 低階特徵學習
 - 目標: 訓練模型預測基於 STFT 頻譜特徵的 100 類聚類結果。STFT 更能放映地震波的頻率成分, 提供更具地震學意義的低階特徵。
 - 機制: 此階段讓模型學習波形的基本頻率和能量特性, 避免在低階特徵上過度擬合。

表 3.1: HuBERT 預訓練所使用之資料集

	Training	Development	Test
CWASN	505k	52k	111k
TSMIP	69k	11k	8k

		BASE	LARGE	X-LARGE
CNN Encoder	strides	5, 2, 2, 2, 2, 2, 2		
	kernel width channel	10, 3, 3, 3, 3, 2, 2 512		
Transformer	layer	12	24	48
	embedding dim.	768	1024	1280
	inner FFN dim.	3072	4096	5120
	layerdrop prob	0.05	0	0
	attention heads	8	16	16
Projection	dim.	256	768	1024
Num. of Params		95M	317M	964M

圖 3.2：BASE、LARGE、X-LARGE HuBERT 模型架構概述

2. Stage 2: 高階語意學習

- 目標：使用 Stage 1 訓練好的模型，Transformer 第 6 層（for base）或第 9 層（for large or xlarge）的輸出作為新特徵，並再次進行 K-Means 聚類（500 類），生成更精細的偽標籤。
- 機制：模型被訓練來預測這些更抽象的 500 類偽標籤，從而模型將學習到波形內部的語意關係，有助於捕捉波形之間的長程時序結構。

3.2.2 損失函數

SeisHuBERT 的損失函數是使用遮罩交叉熵損失 (Masked Cross-Entropy Loss)。模型只在被遮罩的片段上計算損失，強制其利用前後文推斷被遮蔽部分的 K-Means 偽標籤，以達到更強的上下文推斷能力。

3.3 預訓練使用資料集與前處理

本研究 SeisHuBERT 使用臺灣地震波形資料，包含：

- 資料集：如表 3.1 所示
 - CWASN (中央氣象署地震觀測網)

- TSMIP (臺灣強地動儀資料庫)
- 輸入格式:所有波形均為 3-Channel(Z/N/E),長度為 60 秒(6000 採樣點),採樣率 100Hz。

3.4 實驗結果與討論

我們訓練了 base、large、xlarge，三種不同大小的 SeisHuBERT 模型。微調過程對於將預訓練期間學習的通用特徵適應於特定的下游任務至關重要。為了緩解不同任務的不同目標，我們將在 SeisHuBERT 上堆疊一個簡單的任務導向解碼器。本研究也提出並比較了三種微調策略：整個模型訓練 (Finetune)、僅解碼器訓練 (Freeze)以及加權和僅解碼器 (Weighted Sum) 訓練。

表 3.2 為 SeisHuBERT Base 模型進行三種微調策略的結果。Fine-tune 模式表現最佳；Weighted-sum 次之；Freeze 明顯較差。因 SeisHuBERT 的遮罩預測需透過完整模型參數調整來適應不同震相特徵，若僅凍結地震基石模型，模型難以更新語義分群邊界，造成準確率下降。

表 3.2：使用完整資料集，base 模型的 P 波到時拾取的實驗結果

Model	Dataset	Precision	Recall	F1	Mean	Std.	MAE
Base SeisHuBERT Freeze	Dev	0.6408	0.7321	0.6835	0.0001	0.0583	0.0186
	Test	0.6316	0.7135	0.6701	0.0002	0.0585	0.0188
Base SeisHuBERT Weighted Sum	Dev	0.7337	0.7656	0.7493	0.0012	0.0564	0.0184
	Test	0.7313	0.7373	0.7343	0.0014	0.0567	0.0186
Base SeisHuBERT Finetune	Dev	0.9508	0.9869	0.9685	0.0003	0.0184	0.0043
	Test	0.9261	0.9799	0.9523	0.0002	0.0220	0.0052

表 3.3 顯示 SeisHuBERT Large 模型的實驗結果。Fine-tune 模式為全體最佳，Weighted-sum 與 Freeze 明顯落後。隨模型規模增大，SeisHuBERT 能學得更複雜的時序模式。其基於 pseudo label 的遮罩預測更適合捕捉震相漸變區間，故能提升時間對準準確率與收斂穩定性。

表 3.4 顯示 SeisHuBERT XLarge 模型的實驗結果。Fine-tune 模式表現與 Large 模型相近。模型深度增加使梯度傳遞困難，雖可捕捉更多全域資訊，但在有限資料下易過擬合，因此性能提升有限。

表 3.3：使用完整資料集，large 模型的 P 波到時拾取的實驗結果

Model	Dataset	Precision	Recall	F1	Mean	Std.	MAE
Large SeisHuBERT Freeze	Dev	0.5180	0.6313	0.5691	0.0023	0.0604	0.0180
	Test	0.5220	0.6183	0.5661	0.0022	0.0601	0.0180
Large SeisHuBERT Weighted Sum	Dev	0.7482	0.8711	0.8050	0.0010	0.0535	0.0160
	Test	0.7553	0.8475	0.7987	0.0011	0.0534	0.0161
Large SeisHuBERT Finetune	Dev	0.9328	0.9813	0.9564	0.0006	0.0204	0.0049
	Test	0.9527	0.9907	0.9713	0.0004	0.0170	0.0040

表 3.4：使用完整資料集，xlarge 模型的 P 波到時拾取的實驗結果

Model	Dataset	Precision	Recall	F1	Mean	Std.	MAE
XLarge SeisHuBERT Freeze	Dev	0.2407	0.1577	0.1905	0.0008	0.0631	0.0215
	Test	0.2520	0.1615	0.1969	0.0008	0.0627	0.0213
XLarge SeisHuBERT Weighted Sum	Dev	0.6023	0.7516	0.6687	0.0045	0.0607	0.0228
	Test	0.6090	0.7354	0.6663	0.0044	0.0605	0.0226
XLarge SeisHuBERT Finetune	Dev	0.9459	0.9794	0.9624	0.0003	0.0215	0.0051
	Test	0.9231	0.9704	0.9461	0.00002	0.0247	0.0060

接著，我們同樣探討在少樣本的情況時，SeisHuBERT 的實驗結果。表 3.5 顯示，在少樣本（1/5 資料）實驗中，SeisHuBERT 在僅使用 20% 資料訓練下的結果，用以測試模型在資料稀缺條件的泛化能力。SeisHuBERT Fine-tune 的 F1-score 達到 Test=0.9455, Dev=0.9635，顯示其遮罩預測方法比對比學習更能維持穩定性與泛化性。其原因在於 SeisHuBERT 預訓練過程中的「語義重構」(semantic reconstruction) 可透過上下文推論缺失訊號，減少對標註依賴，因此在低資料條件下仍維持高準確率與低誤差。

表 3.5：僅使用 1/5 資料集，base 模型的 P 波到時拾取的實驗結果

Model	Dataset	Precision	Recall	F1	Mean	Std.	MAE
1/5 Base SeisHuBERT Freeze	Dev	0.7938	0.9117	0.8487	0.0063	0.0506	0.0158
	Test	0.7981	0.8752	0.8349	0.0002	0.0511	0.0163
1/5 Base SeisHuBERT Weighted Sum	Dev	0.8108	0.9433	0.8720	0.0002	0.0479	0.0147
	Test	0.8539	0.8697	0.8617	0.0004	0.0484	0.0152
1/5 Base SeisHuBERT Finetune	Dev	0.9466	0.9809	0.9635	0.0001	0.0200	0.0048
	Test	0.9241	0.9680	0.9455	0.00002	0.0234	0.0056

實驗結果總結了 SeisHuBERT 在不同模型規模 (base、large、xlarge) 及微調策略下的 P 波拾取結果。整體而言，Fine-tune 策略的表現最佳，特別是在 Large 規模的 SeisHuBERT 時達到最優平衡 (Test: F1=0.9713, MAE=0.0004)，是目前所有測試策略中表現最佳，在性能和計算資源之間取得了最佳平衡。這顯示在 Transformer 深層結構中，SeisHuBERT 的遮罩預測機制能有效捕捉波形上下文資訊，提升時間定位精度。

XLarge 模型在 Fine-tune 下的提升 (Test: F1=0.9461) 相較於 Large (Test: F1=0.9713) 的提升極小，但參數量與訓練時間卻大幅增加，存在明顯的邊際效益遞減。另外，在僅用 1/5 資料訓練下游時，SeisHuBERT Fine-tune 仍有還不錯的成績，顯示遮罩預測式學習對低樣本場景較具韌性。

肆、預訓練地震基石模型之比較分析

4.1 模型綜合比較結果

SeisWav2Vec2.0 和 SeisHuBERT 的成績比較，會先使用 Test Set 測試集做測試後，再把成績來進行比較。最後我們把成績畫成柱狀圖，以便可以直覺的觀察出差別。六個指標的柱狀體如圖 4.1、圖 4.2、圖 4.3、圖 4.4、圖 4.5、圖 4.6 所示，分別展示了不同模型與微調策略在 Precision、Recall、F1-score、Mean、Std 及 MAE 等六項指標的綜合表現。

從實驗結果可以發現，Fine-tune 策略在兩種模型中皆為最佳；SeisWav2Vec2.0 在 Precision 及 F1 上略優，而 SeisHuBERT 在 MAE 與 Std 上更穩定。也可以看到在 SeisWav2Vec2.0 上的綜合平均表現的成績是最好的。

雖然 SeisWav2Vec2.0 在 Freeze 策略下表現優異，但 SeisHuBERT 的偽標籤目標在 Fine-tune 階段能更有效的引導模型參數，達到更高的時間精度。三種策略也在兩模型上均呈現 Fine-tune > Weighted-sum > Freeze 的一致排序；且 Fine-tune 在 Std/MAE 指標也最小。




圖 4.1：在 Test 測試集的 Precision 成績

圖 4.1 顯示各個模型在 Test 測試集上 Precision 成績，成績越高代表誤報越少。表現得最好的模型是 Large SeisHuBERT Fine-tune，成績為 0.9328，表示在所有預測為有 P 波的結果中誤報率最低的。接著是成績為 0.9286 的 SeisWav2Vec2.0 Fine-tune，和成績為 0.9261 的 Base SeisHuBERT Fine-tune。




圖 4.2：在 Test 測試集的 Recall 成績

圖 4.2 顯示各個模型在 Test 測試集上 Recall 成績，成績越高代表漏報越少。表現得最好的模型是 SeisWav2Vec2.0 Fine-tune，成績為 0.9871，表示在所有預測為有 P 波的結果中漏報率是最低的。接著是成績為 0.9813 的 Large SeisHuBERT Fine-tune，和成績為 0.9799 的 Base SeisHuBERT Fine-tune。




圖 4.3：在 Test 測試集的 F1-score 成績

圖 4.3 顯示各個模型在 Test 測試集上 F1-score 成績，表示綜合 Precision 和 Recall 的調和平均數，是判斷模型綜合能力的主要指標；分數越高代表綜合能力越好。表現得最好的模型是 SeisWav2Vec2.0 Fine-tune，成績為 0.9570。接著是成績為 0.9564 的 Large SeisHuBERT Fine-tune。然後是成績為 0.9523 的 Base SeisHuBERT Fine-tune。SeisWav2Vec2.0 在 Freeze 策略下的 F1-score 顯著高於 SeisHuBERT 的 Freeze 策略，證明其對比學習產生的特徵具有更強健的性質，可被簡單架構的解碼器直接利用。




圖 4.4：在 Test 測試集的 Mean 成績

圖 4.4 顯示各個模型在 Test 測試集上 Mean 成績，判斷模型預測的整體偏差，分數越低越好。表現得最好的模型是 1/5 Base 和 XLarge SeisHuBERT Fine-tune，成績為 0.00002，表示模型整體預測偏差最小。接著是成績為 0.0002 的 1/5 SeisHuBERT Freeze、Base SeisHuBERT Freeze、Base SeisHuBERT Fine-tune。




圖 4.5：在 Test 測試集的 Std. 成績

圖 4.5 顯示各個模型在 Test 測試集上 Std. 成績，表示預測到時與真實到時的平均偏差值，成績越低越好。表現得最好的模型是 SeisWav2Vec2.0 Fine-tune，成績為 0.0199，表示模型預測穩定性最高、時間定位最一致。接著是成績為 0.0204 的 Large SeisHuBERT Fine-tune，和成績為 0.0220 的 Base SeisHuBERT Fine-tune。




圖 4.6：在 Test 測試集的 MAE 成績

圖 4.6 顯示各個模型在 Test 測試集上 MAE 成績，表示預測值與實際值之間差異的絕對值的平均，分數越低越好。表現得最好的模型是 SeisWav2Vec2.0 Fine-tune，成績為 0.0047，驗證了其在到時預測精度上的卓越表現。接著是成績為 0.0049 的 Large SeisHuBERT Fine-tune，和成績為 0.0052 的 Base SeisHuBERT Fine-tune。

4.2 模型效能與推論時間

本研究評估多種預訓練與微調之深度學習模型在真實地震事件中的 P 波到時 (P-phase picking) 任務效能表現。評估指標包含 precision、recall、F1-score、mean、standard deviation、MAE。在真實地震事件之測試中，各模型皆採用其效能表現最佳之微調 (fine-tuned) 版本進行評估。模型效能評估所使用之資料，為 2025 年 11 月 1 日至 11 月 14 日期間實際發生之地震事件資料。

為進一步分析模型對不同類型地震事件之敏感度與表現差異，本研究依據事件特性，將測試資料區分為三類進行評估，分別為：全資料集、有感地震 (felt earthquake, FE) 資料集，以及無感小地震 (non-felt earthquake, NFE) 資料集。

此外，考量地震預警系統（Earthquake Early Warning, EEW）對即時性的高度需求，本研究亦同步量測模型於推論階段之單筆推論時間（Inference Time, ms/trace），以評估模型於即時地震應用情境中的可行性。

由表 4.1 至表 4.3 可觀察到，不同模型在效能表現與推論時間之間呈現明顯的取捨關係。整體而言，SeisWav2Vec 2.0 Fine-tune 在三類資料集上皆展現出穩定且均衡的表現，其 F1-score 與到時誤差指標（Std.、MAE）皆維持在良好水準，同時具備相對較低的推論延遲時間（約 9–15 ms/trace），顯示其在效能與即時性之間取得良好平衡。

表 4.1：彙整各模型於全資料集上的效能指標與推論時間

Model	Precision	Recall	F1	Mean	Std.	MAE	Inferences Time (ms/trace)
SeisWav2Vec2.0	0.7772	0.7036	0.7386	0.0078	0.0866	0.0197	11.9750
Base SeisHuBERT	0.7107	0.7448	0.7274	0.0085	0.0901	0.0208	10.8661
Large SeisHuBERT	0.7517	0.6908	0.7200	0.0076	0.0882	0.0205	17.4306
XLarge SeisHuBERT	0.5174	0.8564	0.6451	0.0115	0.1051	0.0254	187.1211

表 4.2：彙整各模型於有感資料集上的效能指標與推論時間

Model	Precision	Recall	F1	Mean	Std.	MAE	Inferences Time (ms/trace)
SeisWav2Vec2.0	0.7625	0.9236	0.8353	0.0033	0.0741	0.0174	9.5081
Base SeisHuBERT	0.7538	0.9237	0.8302	0.0046	0.0765	0.0178	8.6991
Large SeisHuBERT	0.7332	0.9517	0.8283	0.0030	0.0767	0.0182	40.6374
XLarge SeisHuBERT	0.7050	0.8884	0.7861	0.0041	0.0903	0.0238	193.4097

表 4.3：彙整各模型於無感小地震資料集上的效能指標與推論時間

Model	Precision	Recall	F1	Mean	Std.	MAE	Inferences Time (ms/trace)
SeisWav2Vec2.0	0.6597	0.9182	0.7678	0.0079	0.0870	0.0198	14.4781
Base SeisHuBERT	0.6141	0.9265	0.7387	0.0086	0.0899	0.0207	13.7526
Large SeisHuBERT	0.6185	0.9423	0.7468	0.0077	0.0884	0.0205	41.2187
XLarge SeisHuBERT	0.5144	0.8551	0.6424	0.0117	0.1055	0.0254	184.3405

綜合效能指標與推論時間結果，本研究認為 SeisWav2Vec 2.0 Fine-tune 在目前架構下為最適合部署於即時地震預警系統的模型，能在維持高拾取準確率與低到時誤差的同時，確保模型於地震事件發生初期即完成 P 波拾取與後續分析，滿足 EEW 系統對即時性與穩定性的雙重需求。

4.3 分析

SeisWav2Vec 2.0 的目標是區分正負樣本，學到的特徵更偏向於局部差異和判別性，因此適合在 Freeze 狀態下快速部署。SeisHuBERT 則因為目標是預測語義單元，學到的特徵更偏向於長程結構和抽象語義，必須通過 Fine-tune 策略來調整整個骨幹的參數，才能將這些深層語義特徵轉化為精確的到時預測。

與 SeisWav2Vec2.0 相比，SeisHuBERT 的主要差異在於其使用 K-Means 聚類的偽標籤作為預訓練目標，使模型更專注於學習結構化的序列特徵而非對比距離。這種方式在低雜訊樣本下能有效降低訓練震盪，因此 MAE 表現更低。

4.4 結論與未來展望

本研究成功將 Wav2Vec 2.0 與 HuBERT 兩種自監督預訓練模型引入地震學，證明了 Fine-tune 策略在 P 波拾取任務中的普適性和高效性。以現在的研究來看 SeisWav2Vec 2.0 是目前 LEM 的最佳選擇，但 SeisHuBERT 也證實了其在 Fine-tune 策略上的可行性。本研究成果為未來地震基石模型的選擇和部署提供了關鍵的證實參考。未來規劃將 SeisHuBERT 也拓展至規模估算 (Magnitude Estimation) 任務上。

伍、EEW 即時系統與模型整合

5.1 系統架構

本系統以 MQTT 訊息傳輸協定為核心，整合波形接收、P 波拾取、地震即時預測(EQ-RAG)、以及結果通報四大模組。整體流程採多進程架構(multiprocessing)，能在事件發生後於數秒內完成分析與發布。

主要功能模組：

1. mqtt_msg：接收氣象署即時波形與 P 波 pick 資訊。
2. wave_process：整理波形並儲入 waveform_buffer，提供後續模型輸入。
3. pick_process：收集測站 pick 時間，建立模型輸入佇列。
4. model_predict：呼叫 EQ-RAG 模型執行 PGA 與震度預測。
5. telegram_notify：透過 Telegram 回報 pick 結果與 EEW 預測。

透過 Telegram 群組 NLPLAB_EEW(CWA)與 NLPLAB_PICK(CWA)進行即時回報，如圖 5.1 所示：

- NLPLAB_PICK(CWA)：顯示已 pick 測站分佈圖與到時。
- NLPLAB_EEW(CWA)：顯示 EQ-RAG 模型預測結果。
- NLPLAB_LOG(CWA)：每日自動推送 log 狀態摘要。

此設計使氣象署端能即時監控模型運作狀態，並追蹤震度預測是否與實測結果一致。

5.2 模型與即時結果回報

本系統採用實驗室先前提出的 EQ-RAG (Retrieval-Augmented Ground-motion model) 作為地震震度預測模型。模型輸入包含測站位置、三分量波形 (Z/N/E)，以及與第一
個
P




圖 5.1：即時系統進行即時回報的 Telegram 群組

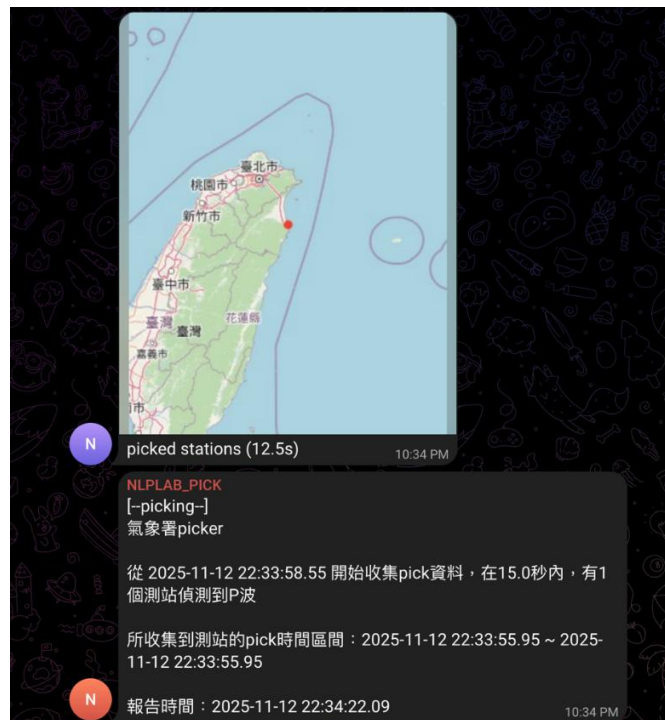


圖 5.2：NLPLAB_PICK(CWA) 群組即時系統通報範例畫面

波 pick 的相對時間；模型輸出為 249 個訓練測站的最大震度預測結果。當任何測站預測 PGA 超過 25 gal（震度三級）時，系統會自動發送即時通報訊息。如圖 5.2 和圖 5.3 所示，在收集到測站的 P 波訊號後，系統完成資料收集，並完成 PGA 預測，再顯示結果有無測站震度大於或小於三級。

5.3 實際部署與氣象署端整合

系統部署於氣象署內部伺服器 (192.168.20.45)，以 tmux 持續執行 EEW 主程式。

運行環境為 Conda 環境 eq_rag，核心執行檔為 eew2mqtt_process.py。所有預測結果皆由程式自動儲存並整理成 log 檔，每日再把 log 檔發送至群組：

- pick.log：紀錄所有測站 P 波到時
- eew.log：模型預測結果

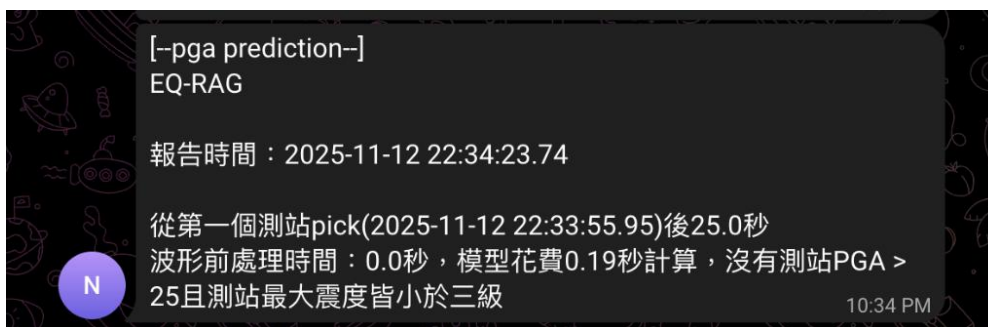


圖 5.3：NLPLAB_EEW(CWA) 群組即時系統通報範例畫面

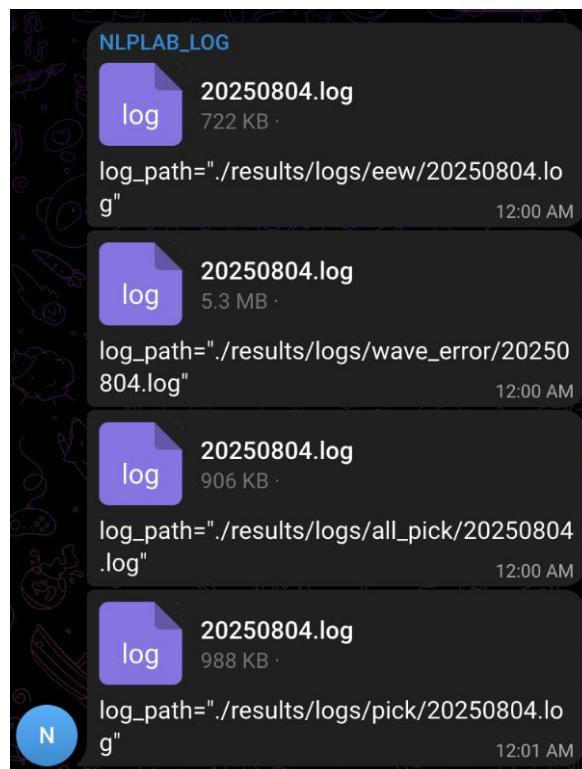


圖 5.4：即時系統通報範例畫面

- wave_error.log：波形異常檢查
- all_pick.log：完整拾取資料集

此流程目的是方便透過 log 檢查每日的訊息，有問題就可以立即發現並即時解決。

5.4 結論

本系統成功實現了從 P 波拾取到震度預測的自動化流程，並完成與氣象署內部 MQTT 服務的整合，未來將持續優化 EQ-RAG 模型的運算效率與誤報過濾機制。

參考文獻

- [1] S. M. Mousavi and G. C. Beroza, “Deep-learning seismology,” *Science*, vol. 377, no. 6607, eabm4470, 2022.
- [2] S. M. Mousavi and G. C. Beroza, “Machine learning in earthquake seismology,” *Annual Review of Earth and Planetary Sciences*, vol. 51, pp. 105–129, 2023.
- [3] J. Woollam, J. Munchmeyer, F. Tilmann, “ et al., “Seisbench—a toolbox for machine learning in seismology,” *Seismological Society of America*, vol. 93, no. 3, pp. 1695–1709, 2022.
- [4] E. Pardo, C. Garfias, and N. Malpica, “Seismic phase picking using convolutional networks,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 57, no. 9, pp. 7086–7092, 2019.
- [5] W. Zhu and G. C. Beroza, “Phasenet: A deep-neuralnetwork-based seismic arrival-time picking method,” *Geophysical Journal International*, vol. 216, no. 1, pp. 261–273, 2019.
- [6] S. M. Mousavi, W. L. Ellsworth, W. Zhu, L. Y. Chuang, and G. C. Beroza, “Earthquake transformer—an attentive deep-learning model for simultaneous earthquake detection and phase picking,” *Nature communications*, vol. 11, no. 1, p. 3952, 2020.
- [7] A. Mohamed, H.-y. Lee, L. Borgholt, et al., “Selfsupervised speech representation learning: A review,” *IEEE Journal of Selected Topics in Signal Processing*, vol. 16, no. 6, pp. 1179–1210, 2022.
- [8] A. Baevski, Y. Zhou, A. Mohamed, and M. Auli, “Wav2vec 2.0: A framework for self-supervised learning of speech representations,” *Advances in neural information processing systems*, vol. 33, pp. 12 449– 12 460, 2020.
- [9] Central Weather Administration, Central weather administration seismographic network, 2012. DOI: 10 . 7914/SN/T5.
[Online]. Available: <https://www.fdsn.org/networks/detail/T5/>.
- [10] S. M. Mousavi, Y. Sheng, W. Zhu, and G. C. Beroza, “Stanford earthquake dataset (stead): A global data set of seismic signals for ai,” *IEEE Access*, vol. 7, pp. 179 464–455

179 476, 2019.

- [11] S. M. Mousavi and G. C. Beroza, “A machine learning approach for earthquake magnitude estimation,” *Geophysical Research Letters*, vol. 47, no. 1, e2019GL085976, 2020.
- [12] H. Jegou, M. Douze, and C. Schmid, “Product quantization for nearest neighbor search,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 33, no. 1, pp. 117–128, 2010.
- [13] Z.-C. Chen, C.-L. Fu, C.-Y. Liu, S.-W. D. Li, and H.-y. Lee, “Exploring efficient-tuning methods in self-supervised speech models,” in *2022 IEEE Spoken Language Technology Workshop (SLT)*, IEEE, 2023, pp. 1120–1127.
- [14] Hsu, W.-Y., Bolte, B., Tsai, Y.-H. H., Lakhotia, K., Salakhutdinov, R., & Mohamed, A. (2021). HuBERT: Self-Supervised Speech Representation Learning by Masked Prediction of Hidden Units. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 29, 3451–3460.
- [15] SeisBench: A Toolbox for Machine Learning on Seismological Time Series, *Journal of Open Source Software*, 2021.
- [16] Facebook AI (2021). fairseq HuBERT Codebase. Retrieved from <https://github.com/facebookresearch/fairseq/tree/main/examples/hubert>
- [17] Baevski, A., et al. (2022). Data2Vec: A General Framework for Self-supervised Learning in Speech, Vision and Language. *ICML 2022*.

114 年地震預警作業技術研發之相關研究

子計畫五

AI 現地型地震預警應用於 PWS 之研究-以花東地區為例

許丁友 李柏陞 王之寬

國立臺灣科技大學

摘要

本研究旨在提升現地型地震預警系統的準確性與可靠性，通過引入第二發報門檻及網格化預警方式來優化系統效能。本研究分析不同參數（如 PGA、Pd、Pv、CAV、 τ_c 等）與實際地表加速度之關聯性，並針對不同門檻設定進行 FPR（False Positive Rate）與 FNR（False Negative Rate）分析。結果顯示，CAV 在多數條件下可有效降低誤報，特別是在大地震事件中，作為 PGA 之外的第二門檻能顯著提升預測準確率。然而，在誤報降低的同時，FNR 亦可能上升，顯示預警系統需依應用需求在誤報與漏報間進行平衡。針對小地震事件，CNN 模型整體表現穩定。

此外，為解決現行預警以「縣市」為單位（如花蓮、臺東等幅員廣闊地區）所導致的不必要警報問題，本研究進一步探討「網格化」預警的效益。分析顯示，將預警單位細緻化（例如依測站數劃分），能更精準地反映實際震度分佈，有效避免向小震度地區發出警報。同時，分析亦證實現地型預警對於近震央區域能比區域型更快發報。

關鍵詞：卷積神經網路、單站法、強震預警、時間窗、額外參數法、網格化

Abstract

This study aims to enhance the accuracy and reliability of on-site earthquake early warning systems by introducing a secondary alert threshold and a grid-based warning approach to optimize overall system performance. This study analyzes the relationships between various parameters—such as PGA, Pd, Pv, CAV, and τ_c —and actual ground acceleration, followed by an evaluation of the False Positive Rate (FPR) and False Negative Rate (FNR) under different threshold settings. The results indicate that CAV can

effectively reduce false alarms under most conditions, particularly during large earthquakes, and can serve as a secondary threshold to PGA to significantly improve prediction accuracy. However, while reducing false alarms, the FNR may increase, suggesting that the warning system must balance false alarms and missed detections according to specific application needs. For small earthquake events, the CNN model demonstrates stable overall performance.

In addition, to address the issue of unnecessary alerts caused by current early warning systems that operate on a “county-level” basis (e.g., in large areas such as Hualien and Taitung), this study further explores the advantages of a “grid-based” warning approach. The analysis shows that refining the warning unit (e.g., dividing regions according to station density) can more accurately represent the actual intensity distribution and effectively prevent alerts from being issued to areas with only minor shaking. Furthermore, the results confirm that on-site (single-station) early warning systems can issue alerts faster than regional systems for near-epicenter events.

Keywords: Single Station , Earthquake Early Warning , Time Window , Supplemental Parameter Method , Grid-based Method

壹、前言

地震預警系統可分為區域型與現地型兩類。區域型系統雖然能提前預警遠距離地區，但通常會在震央附近形成預警盲區；而現地型系統較能即時回應震央周圍的震動，但若僅依賴單站 PGA 作為預警門檻，則可能產生不必要的誤報。為提升現地型系統的準確性，本研究提出將多項 P 波相關參數作為第二發報門檻，藉此強化模型對地震強度的判斷能力，降低誤報率，並提高警報的可信度與實用性。此部分主要在第二章進行介紹，其內容包含(1)研究目的；(2)研究方法；(3)研究成果；(4)地震事件分析

此外，在分析地震事件時，發現對於地域範圍較大的縣市，若依縣市為單位發佈警報，可能會產生不必要的警報。例如，當地震震央位於某縣市的南端且最大震度達四級時，整個縣市將收到預警通知，但實際上北端居民可能未感受到明顯的震動。因此，現行的預警機制可能無法精確反映地震的實際影響範圍，容易造成過度或不足的警報。為了克服此一問題，本研究提出以網格化的方式來細化預警區域，進一步提高不同區域震度分佈的精確性。這種方法不僅能夠更好地反映震央附近的震動情況，還能有效避免向未受震動影響的區域發送不必要的警報，此部分主要在第三章進行介紹，其內容包含(1)研究目的；(2)劃分方式；(3)區域型預警與區域型加現地型預警結果比較

貳、利用額外參數以降低現地型地震預警單站誤報

2.1 研究目的

臺灣位於板塊交界帶，地震頻繁，因此地震預警系統的開發至關重要。目前地震預警系統主要分為區域型與現地型。區域型預警系統透過震源附近的多個測站定位地震的震央、深度與規模，並將資訊傳送至氣象署，再由電信業者發布預警訊息。然而，由於 P 波傳播速度快於 S 波，S 波到達時可能仍未收到預警訊息，導致震央周圍形成「預警盲區」。為減少盲區，我們開發了現地型地震預警系統，使測站在偵測到 P 波後，能直接對鄰近區域發送警報。然而，若僅依賴單一測站的 PGA 作為警報門檻，可能會導致過多誤報。因此，本研究在 PGA 門檻的基礎上，加入與 PGA 高度相關的多項參數作為第二門檻，以降低單站誤報率，提升預警準確性。目前本研究預測 PGA 仍是使用 TSMIP 測站所訓練之 2 秒 CNN 模型。

2.2 研究方法

2.2.1 發報機制

為了降低現地型地震預警模型單站之誤報率，本研究嘗試在原本只有 PGA 作為發報門檻的基礎下，額外新增了 PGA 相關參數當作第二門檻值，使發報的條件變得較為嚴苛，發報門檻之二元混淆矩陣如下圖所示。當實際 PGA 大於等於 25gal 且預測 PGA 大於等於 25gal 和額外參數也大於等於門檻值則為正確發報；當實際 PGA 小於 25gal 且預測 PGA 大於等於 25gal 和額外參數也大於等於門檻值則為誤報；當實際 PGA 小於 25gal 且預測 PGA 和額外參數為上述其他種組合情況則為正確不用發報；當實際 PGA 大於等於 25gal 且預測 PGA 和額外參數為上述其他種組合情況則為漏報。

		Real	
		PGA < 25	PGA ≥ 25
Predicted	PGA ≥ 25 and Parameter ≥ threshold	FP	TP
	Another	TN	FN

(gal)

圖 貳-1 二元混淆矩陣

2.2.2 參數介紹

本研究除考慮傳統 P 波參數外，亦選取多組與地表最大加速度（Peak Ground Acceleration, PGA）具有高度相關性之震動參數作為第二發報門檻。這些參數涵蓋位移、速度、加速度、能量及頻率等多種面向，能有效提升模型對震動強度與破壞潛勢之預測能力。所採參數包括最大位移 Pd(Wu 等人[2])、最大速度 Pv(Nakamura 等人 [3])、最大加速度 Pa(Erdik 等人[4])、加速度與速度內積最大值 Pav(Nakamura 等人 [3])、累積絕對加速度 CAV(Erdik 等人[4])、速度平方積分 IV2 (Iaccarino 等人[5])、位移平方積分 ID2 (Iaccarino 等人[5]) 以及 Pd 與主要週期 τ_c 乘積 (Alcik 等人[6])，這些參數的選擇是基於其與 PGA 之間的高度相關性，能有效補充傳統 P 波參數的不足，提升預測準確性。公式如下所示：

- 最大位移(Pd)：

$$P_d = \max(|u(t)|), \text{ for } 0 \leq t \leq t_p \quad (2-1)$$

- 最大速度(Pv)：

$$P_v = \max(|\dot{u}(t)|), \text{ for } 0 \leq t \leq t_p \quad (2-2)$$

- 最大加速度(Pa)：

$$P_a = \max(|\ddot{u}(t)|), \text{ for } 0 \leq t \leq t_p \quad (2-3)$$

- 加速度與速度內積最大值(Pav)：

$$P_{av} = \max|\ddot{u}(t)_{xi} \cdot \dot{u}(t)_{xi} + \ddot{u}(t)_{yi} \cdot \dot{u}(t)_{yi} + \ddot{u}(t)_{zi} \cdot \dot{u}(t)_{zi}| \quad (2-4)$$

- 累積絕對加速度(CAV)：

$$CAV = \int_0^{t_p} |\ddot{u}(t)| dt \quad (2-5)$$

- 速度平方積分 (IV2)：

$$IV2 = \int_0^{t_p} \dot{u}(t)^2 dt \quad (2-6)$$

- 位移平方積分 (ID2)：

$$ID2 = \int_0^{t_p} u(t)^2 dt \quad (2-7)$$

- 最大位移與主要週期乘積 (Pd* τ_c)

$$Pd * \tau_c \quad (2-8)$$

$$\text{其中 } \tau_c = 2\pi/\sqrt{r} \cdot r = \int_0^{t_p} \dot{u}(t)^2 dt / \int_0^{t_p} u(t)^2 dt$$

本研究中，除 Pav 外，其餘所有參數皆以垂直向（vertical component）資料為基礎進行計算。符號定義如下： $u(t)$ 為垂直向位移時間序列， $\dot{u}(t)$ 與 $\ddot{u}(t)$ 分別為其一階與二階導數，對應於速度與加速度，皆由原始加速度資料經數值積分或微分取得。 tp 表示 P 波初至後所選取的時間長度。在 $Pav(2-4)$ 中，則使用東西向 (x)、南北向 (y) 與垂直向 (z) 三分量的加速度與速度分量，計算其逐時點的內積後取最大值。

2.2.3 資料介紹

本研究將使用 2012 至 2021 年之部分地震資料進行測試。2012 至 2021 年間位於井上之加速度計的測站共含有 70462 筆地震紀錄，為確保不同震度資料的平衡，僅選取其中的 5261 筆地震加速度歷時資料；且為確保訓練資料的代表性，將最大地表加速度 25gal 以上的資料全部取用，而剩餘的資料則由震度 1、2、3 級資料平均分配數量。各加速度區間資料量分布如下表 貳-1 所示。

表 貳-1 本研究所取用 2012 至 2021 年地震加速度資料分布

年份	80gal 以上	25-80gal	8-25gal	2.5-8gal	0.8-8gal	Total
2012	11	79	48	56	72	266
2013	36	89	66	73	81	345
2014	7	33	60	53	75	228
2015	21	108	136	122	122	509
2016	42	170	120	169	153	654
2017	18	80	86	117	111	412
2018	51	187	166	216	227	847
2019	43	133	125	117	129	547
2020	19	126	212	137	116	610
2021	53	235	221	180	154	843
	301	1240	1240	1240	1240	5261

2.3 研究成果

為探討不同參數門檻設定對地震預警系統發報準確性的影響，本研究首先繪製各參數與實際 PGA 之對數分布圖(如圖 貳-2 至 2-9 所示)，觀察其對應關係及分

布趨勢。以 Pd 為例(如圖 貳-2)，橫軸為對數尺度下的 Pd 值 ($\log(\text{Pd}^2)$)，縱軸為對數尺度下的實際 PGA 值 ($\log(\text{PGA})$)。圖中每個藍色點代表一筆實際觀測資料，紅色虛線表示發報臨界值 $\text{PGA} = 25 \text{ gal}$ (對應於 $\log(\text{PGA}) \approx 1.4$)，而兩條垂直的紫色虛線分別代表 Pd 門檻設定的兩個極端值： $\text{Pd} = 0.0001 \text{ cm}$ ($\log(\text{Pd}^2) \approx -4$) 與 $\text{Pd} = 10 \text{ cm}$ ($\log(\text{Pd}^2) \approx 1$)。藉由改變 Pd 的門檻值，可觀察發報結果中誤報 (FP) 與漏報 (FN) 的變化情形。當門檻設定於較低值 (左側紫色虛線)，系統將大多數事件視為需發報情況，使得實際應發報事件 (右上區域) 的正確發報數 (TP) 最大化，但同時也大幅提高誤報數 (右下區域的 FP)。相對地，當門檻設定於較高值 (右側紫色虛線)，系統發報的情況大幅減少，雖然能有效降低誤報數，但也會導致大量實際應發報事件被忽略，增加漏報數 (FN)。

因此，本研究選擇以 FPR (False Positive Rate) 與 FNR (False Negative Rate) 作為主要的統計指標，其計算公式如式 (2-9) 與 (2-10) 所示：

$$FPR = \frac{FP}{TN + FP} \quad (2-9)$$

$$FNR = \frac{FN}{TP + FN} \quad (2-10)$$

其中，FPR 表示在實際不需發報的情況下卻誤發報的比例，FNR 則為實際需要發報卻未發報的比例。相較於傳統常用之 Precision 與 Recall 指標，因各參數在不同門檻設定下 Precision 的母數 ($TP + FP$) 變動較大，易導致評估結果不穩定，本研究因而改採 FPR 與 FNR 作為判別準確性的依據，提供更穩定且直觀的觀察依據。




圖 貳-2 實際 PGA 和 Pd 對數分布圖




圖 貳-3 實際 PGA 和 Pv 對數分布圖




圖 貳-4 實際 PGA 和 Pa 對數分布圖




圖 貳-5 實際 PGA 和 Pav 對數分布圖

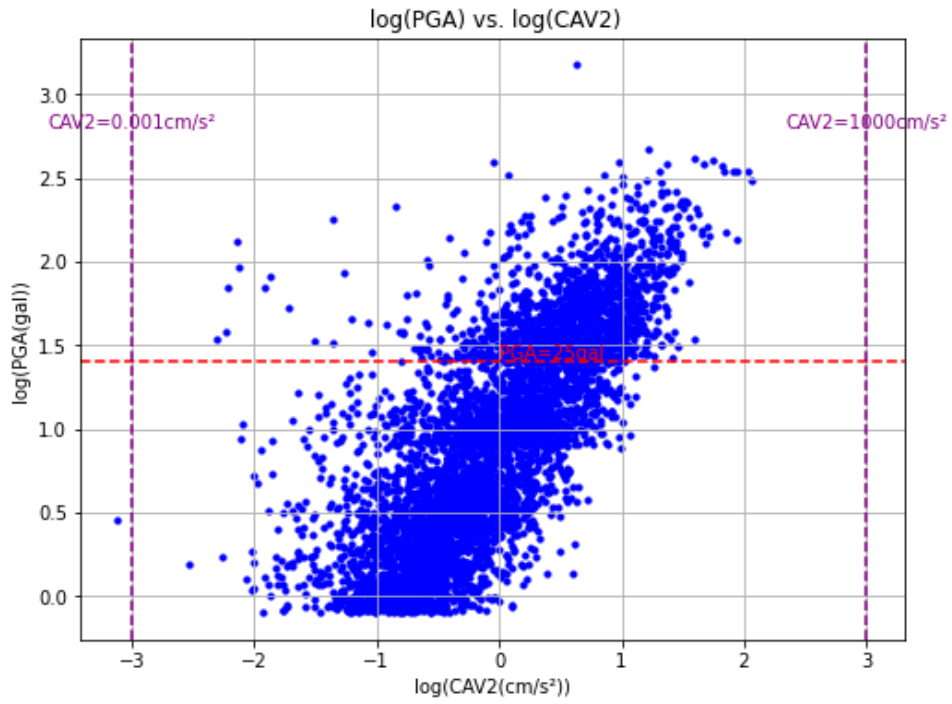


圖 貳-6 實際 PGA 和 CAV 對數分布圖




圖 貳-7 實際 PGA 和 IV2 對數分布圖




圖 貳-8 實際 PGA 和 ID2 對數分布圖




圖 貳-9 實際 PGA 和 $Pd \cdot \tau_c$ 對數分布圖

本研究進一步以固定 FPR 值的方式，比較不同參數在各自門檻設定下所對應的 FNR 之表現，並以測站為單位進行統計。以下為結果展示。首先將兩個極端門

檻值之間均勻取 100 個點進行分析，並繪製出相對應的 FPR (左圖) 與 FNR (右圖) 變化曲線。其中，紅色虛線代表僅以 PGA 作為發報門檻時所產生的 FPR 與 FNR 值。本研究選取三種 FPR 作為值作為固定條件，以觀察各參數在相同 FPR 標準下的漏報情形：第一種為單純以 PGA 為門檻時所對應 FPR 值的一半 (圖中綠色虛線) 約為 3%，第二種為 FPR 約為 1% (藍色虛線)，第三種則為 FPR 等於 0% 的情況。表 貳-2 統計各參數 FPR 和 FNR 值之結果，其中可以觀察到 CAV 於三種 FPR 固定條件中皆展現最低的 FNR 值，搭配 PGA 作為第二門檻值之效果最好。

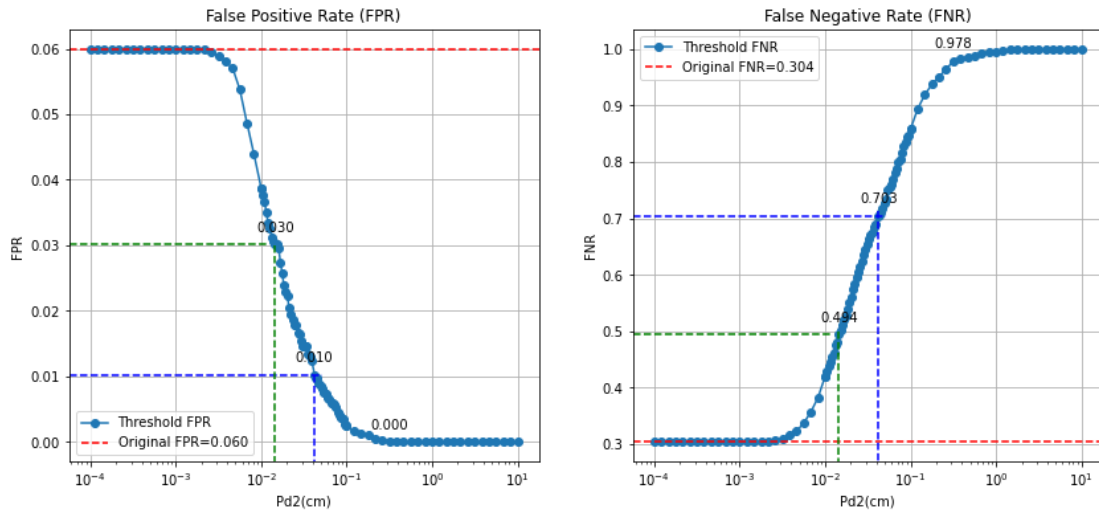


圖 貳-10 Pd 之 FPR 和 FNR 曲線比較結果




圖 貳-11 Pv 之 FPR 和 FNR 曲線比較結果





圖 貳-12 Pa 之 FPR 和 FNR 曲線比較結果





圖 貳-13 Pav 之 FPR 和 FNR 曲線比較結果




圖 貳-14 CAV 之 FPR 和 FNR 曲線比較結果




圖 貳-15 IV2 之 FPR 和 FNR 曲線比較結果

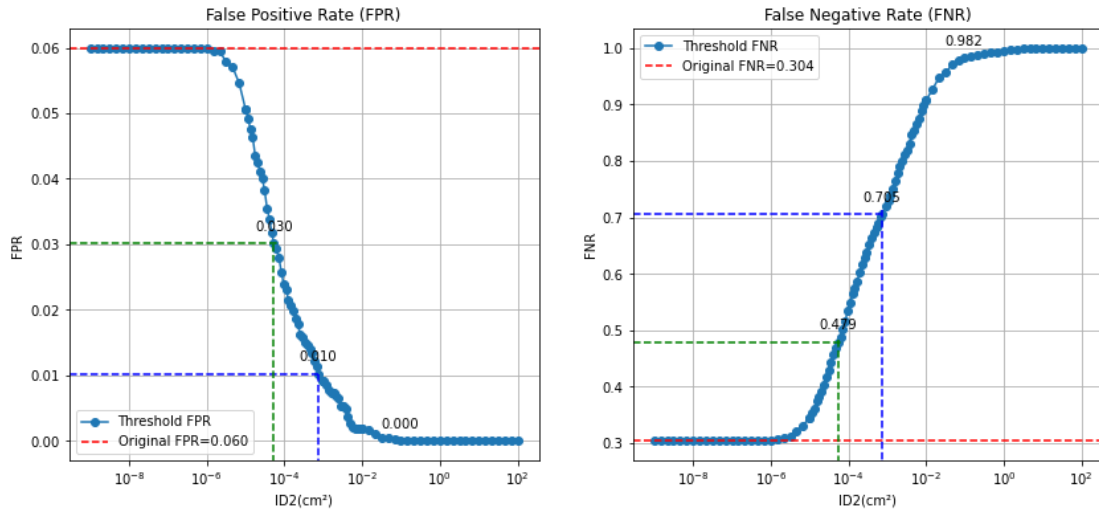


圖 貳-16 ID2 之 FPR 和 FNR 曲線比較結果




圖 貳-17 Pd*τ_c 之 FPR 和 FNR 曲線比較結果

表 貳-2 各參數之 FPR 和 FNR 結果

	When FPR≈3%			When FPR≈1%			When FPR≈0%		
	FPR (%)	FNR (%)	Threshold	FPR (%)	FNR (%)	Threshold	FPR (%)	FNR (%)	Threshold
<i>Pd₂</i> (cm)	3.01	49.38	0.0146	1.02	70.34	0.0422	0	97.73	0.3162
<i>Pv₂</i> (cm/s)	3.01	46.85	0.1727	1.02	66.39	0.2915	0	93.06	0.9249
<i>Pa₂</i>	3.01	43.67	4.0088	1.02	65.41	7.2326	0	90.59	20.691

(cm/s^2)									
Pav_2 (cm^2/s^3)	3.01	44.13	0.5197	1.02	63.79	1.9845	0	90.33	20.691
CAV_2 (cm/s^2)	3.01	42.38	2.8661	1.02	62.17	5.4159	0	88.51	13.257
$IV2_2$ (cm^2/s^2)	3.01	45.75	0.0064	1.02	63.21	0.0173	0	94.55	0.2466
$ID2_2$ (cm^2)	3.01	47.89	5.34-05	1.02	70.54	0.0007	0	98.18	0.0933
$Pd_2 * \tau c_2$ ($cm * s$)	3.01	53.54	0.0097	1.02	75.15	0.0691	0	98.51	2.4771

2.4 地震事件分析

綜合前述分析結果，CAV 於三種固定 FPR 條件中皆展現出最低的 FNR 值，整體表現最佳。因此，本研究在後續模擬分析中，決定採用 CAV 作為第二發報門檻，並延續先前設定的三種門檻條件：第一，僅使用 PGA 為門檻時所對應 FPR 值的一半（約為 3%）；第二，FPR 固定為約 1%；第三，FPR 嚴格等於 0%。本節的統計係以測站為單位進行。

2.4.1 大地震事件

本研究挑選最大震度大於五級之地震事件進行分析，以探討大地震情況下不同發報門檻之分析結果。所選取的三個地震事件分別為：2024 年 4 月 3 日 07 時 58 分 09 秒花蓮地震、2018 年 2 月 6 日 23 時 50 分 41 秒花蓮地震、以及 2016 年 2 月 6 日 03 時 57 分 26 秒高雄美濃地震。以下分別說明各地震事件之分析結果：

首先針對 2024 年 4 月 3 日花蓮地震事件，圖 貳-18 中顯示使用 PGA 作為單一發報門檻時之單站二元混淆矩陣分析結果。由圖可觀察到，僅使用 PGA 作為發報門檻即無誤報產生。顯示本研究使用之 CNN 模型在該事件中具有良好的預測準確率，且能有效避免誤報。

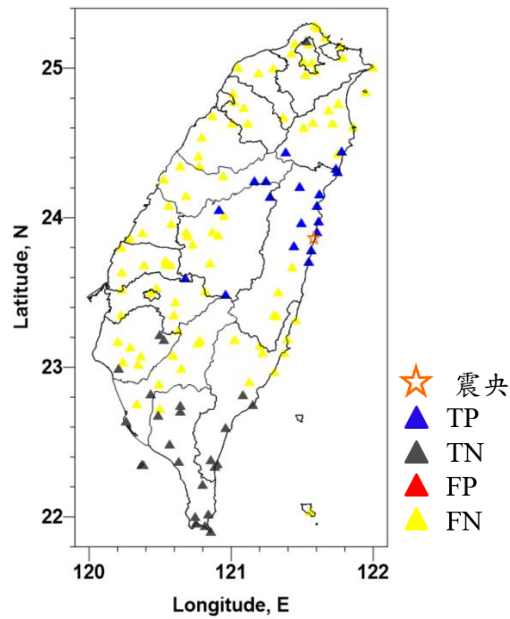


圖 貳-18 使用 PGA 為發報門檻之二元混淆矩陣分布(240403)

表 貳-3 二元混淆矩陣數量分布(240403)

Threshold (cm/s^2)	TP	TN	FP	FN
$PGA = 25gal$	19	28	0	93
$PGA = 25gal \cdot CAV = 2.87 cm/s^2$	17	67	0	56
$PGA = 25gal \cdot CAV = 5.42 cm/s^2$	15	67	0	58
$PGA = 25gal \cdot CAV = 13.26 cm/s^2$	12	67	0	61

接著針對 2018 年 2 月 6 日花蓮地震事件，圖 貳-19 中同樣為以 PGA 作為單一門檻時之單站二元混淆矩陣結果。分析結果顯示，有 1 個測站出現誤報（圖中紅色三角形標記）。進一步引入第二門檻值 CAV 作為第二門檻值，並設定三組不同的 CAV 門檻值（如前節所述），其結果如圖 貳-19 所示，由左至右分別對應三種門檻設定。從結果可見，加入 CAV 後誤報情況得以消除，在門檻值最低情況下僅增加了 1 筆漏報。

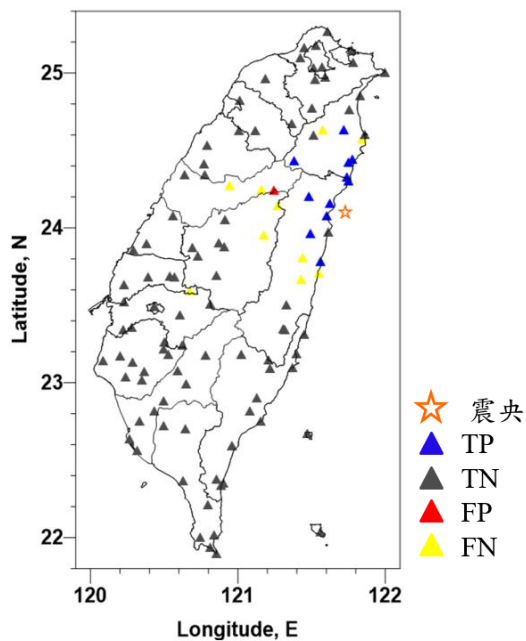


圖 貳-19 使用 PGA 為發報門檻之二元混淆矩陣分布(180206)

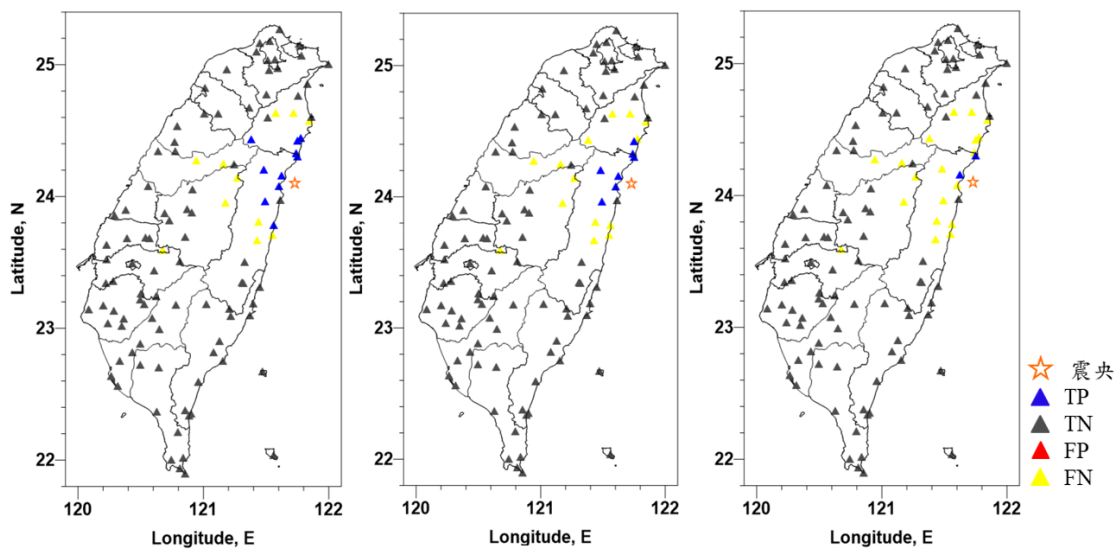


圖 貳-20 加入 CAV 為發報門檻之二元混淆矩陣分布

(左： $CAV = 2.87 \text{ cm/s}^2$ 、中： $CAV = 5.42$ 、右： $CAV = 13.26 \text{ cm/s}^2$)

表 貳-4 二元混淆矩陣數量分布(180206)

Threshold (cm/s^2)	TP	TN	FP	FN
$PGA = 25\text{gal}$	11	95	1	10

$PGA = 25gal \cdot CAV = 2.87 cm/s^2$	10	96	0	11
$PGA = 25gal \cdot CAV = 5.42 cm/s^2$	7	96	0	14
$PGA = 25gal \cdot CAV = 13.26 cm/s^2$	2	96	0	19

最後針對 2016 年 2 月 6 日高雄美濃地震事件，使用 PGA 作為發報門檻的二元混淆矩陣分析結果亦如圖所示，有 9 個測站發生誤報（紅色三角形標記）。為進一步改善誤報情況，本研究亦嘗試加入 CAV 作為第二門檻，並使用三種不同的 CAV 門檻值進行分析。結果顯示，誤報數量明顯下降，由原先的 9 筆減少為 1 至 2 筆，但漏報數量則相對增加，在門檻值最低情況下，從原本的 15 筆上升至 30 筆，顯示在誤報與漏報之間仍需權衡取捨。

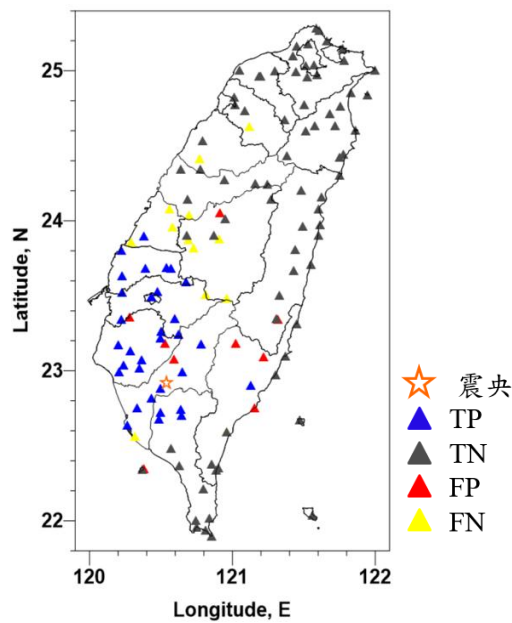


圖 貳-21 使用 PGA 為發報門檻之二元混淆矩陣分布(160206)

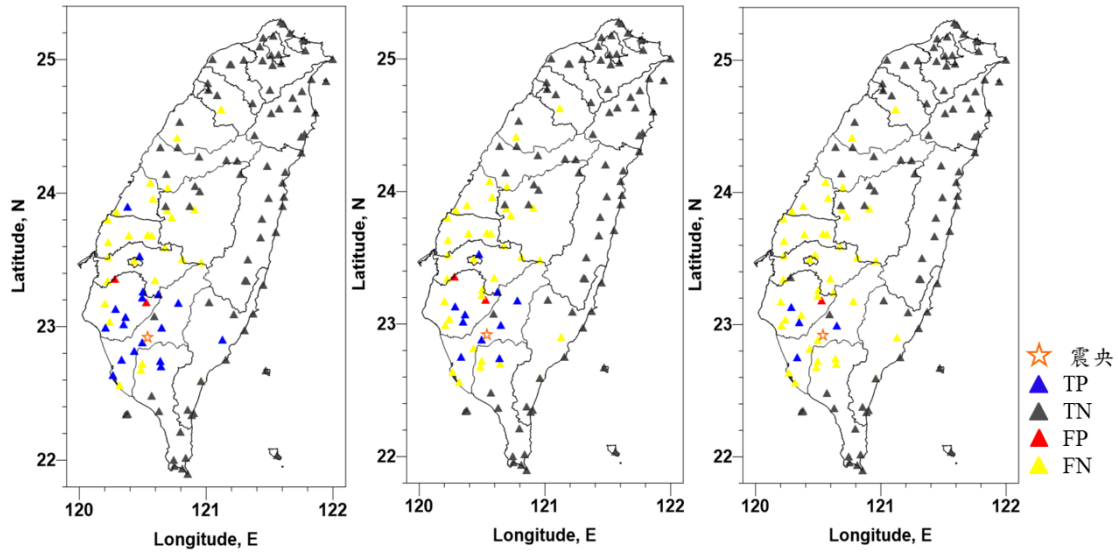


圖 貳-22 加入 CAV 為發報門檻之二元混淆矩陣分布

(左 : $CAV = 2.87 \text{ cm/s}^2$ 、中 : $CAV = 5.42$ 、右 : $CAV = 13.26 \text{ cm/s}^2$)

表 貳-5 二元混淆矩陣數量分布(160206)

Threshold (cm/s^2)	TP	TN	FP	FN
$PGA = 25gal$	33	78	9	15
$PGA = 25gal \cdot CAV = 2.87 \text{ cm/s}^2$	18	85	2	30
$PGA = 25gal \cdot CAV = 5.42 \text{ cm/s}^2$	10	85	2	38
$PGA = 25gal \cdot CAV = 13.26 \text{ cm/s}^2$	4	86	1	44

本研究進一步針對上述三筆地震事件，分別比較 FPR 與 FNR，比較結果如表貳-6 所示。在 2024 年 4 月 3 日花蓮地震事件於僅採用 PGA 為發報門檻時，其 FPR 均為 0%，顯示本研究所建立之 CNN 模型在此事件中具備良好的預測準確度，並能有效避免誤報之產生。2018 年 2 月 6 日花蓮地震事件中，雖使用 PGA 門檻時出現少量誤報 (FPR = 1.04%)，但在引入 CAV 為第二門檻後，FPR 下降為 0%，然而 FNR 明顯上升，反映出誤報雖降低，卻犧牲了預警靈敏度。至於 2016 年 2 月 6 日高雄美濃地震事件，當使用 PGA 作為門檻時，FPR 為 10.3%，FNR 為 31.2%，顯示雖可維持一定預測靈敏度，但誤報比例較高；改採 CAV 門檻後，FPR 降至 1.2–2.3%，但 FNR 明顯升高，呈現出誤報與漏報間的明顯取捨關係。

整體而言，CAV 雖可有效降低誤報風險，但亦會導致 FNR 明顯上升，需依

實際應用需求於準確度與靈敏度間取得平衡。

表 貳-6 三地震事件不同門檻值 FPR 和 FNR 比較

Event	FPR (%)	FNR (%)	FPR (%)	FNR (%)	FPR (%)	FNR (%)	FPR (%)	FNR (%)
	<i>PGA = 25gal</i>		<i>CAV = 2.87 cm/s²</i>		<i>CAV = 5.42 cm/s²</i>		<i>CAV = 13.26 cm/s²</i>	
20240403	0	83.0	0	88.4	0	92.9	0	97.3
20180206	1.04	47.6	0	52.4	0	66.7	0	90.5
20160206	10.3	31.2	2.3	62.5	2.3	79.2	1.2	91.7

2.4.2 小地震事件

本研究亦挑選震度小於或等於四級之地震事件進行分析，探討小地震情境下不同發報門檻之發報結果。所選取之三筆地震事件分別為：2021 年 11 月 14 日 21 時 05 分 15 秒宜蘭地震事件、2021 年 9 月 26 日 06 時 21 分 19 秒花蓮地震事件、以及 2016 年 5 月 30 日 01 時 48 分 05 秒臺東地震事件。以下分別說明各地震事件之分析結果：

首先針對 2021 年 11 月 14 日宜蘭縣地震事件進行分析，圖 貳-23 中顯示使用 PGA 作為單一發報門檻時之單站二元混淆矩陣結果。由分析結果可知，共有 3 個測站出現誤報（圖中以紅色三角形標記）。進一步引入第二門檻值 CAV，並設定三組不同門檻（如前節所述），其分析結果如圖 貳-24 所示，左中右分別對應三種門檻設定。由結果可觀察到，加入 CAV 作為輔助門檻後可完全消除誤報，顯示此方法可有效提升模型發報之準確性與穩定性。

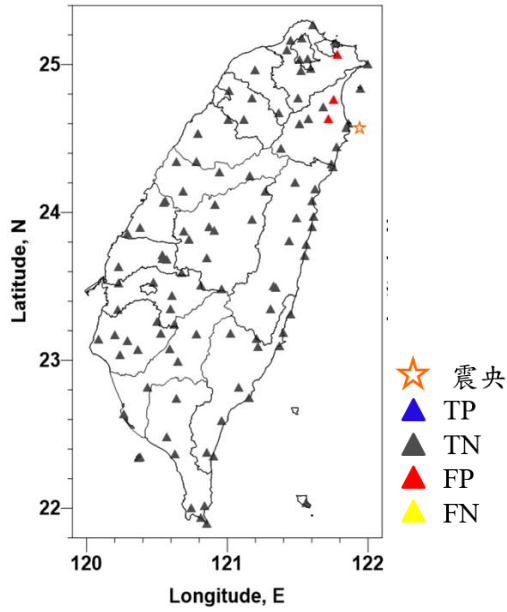


圖 貳-23 使用 PGA 為發報門檻之二元混淆矩陣分布(211114)

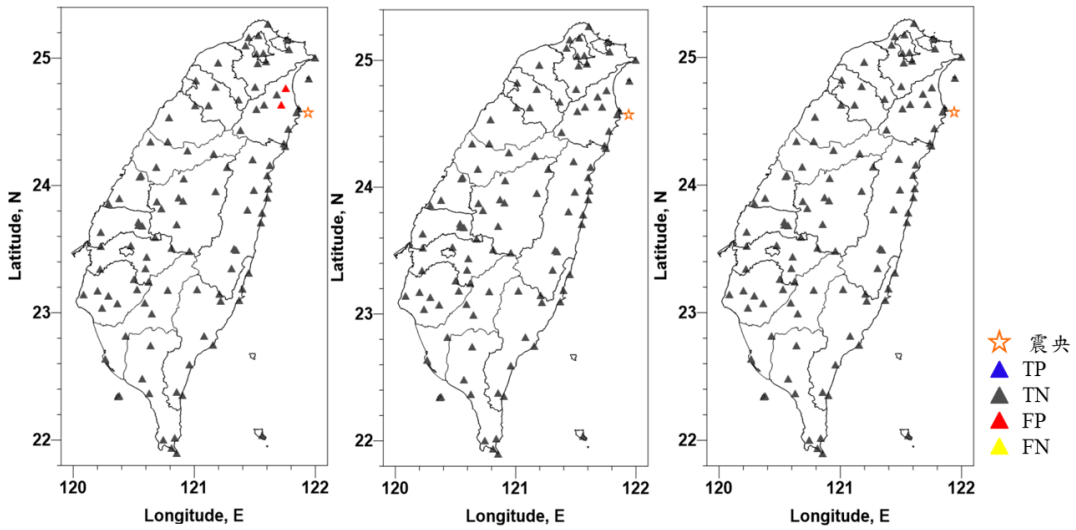


圖 貳-24 加入 CAV 為發報門檻之二元混淆矩陣分布

(左： $CAV = 2.87 \text{ cm/s}^2$ 、中： $CAV = 5.42$ 、右： $CAV = 13.26 \text{ cm/s}^2$)

表 貳-7 二元混淆矩陣數量分布(211114)

Threshold (cm/s^2)	TP	TN	FP	FN
$PGA = 25gal$	0	107	3	0

$PGA = 25gal$ 、 $CAV = 2.87 cm/s^2$	0	108	2	0
$PGA = 25gal$ 、 $CAV = 5.42 cm/s^2$	0	110	0	0
$PGA = 25gal$ 、 $CAV = 13.26 cm/s^2$	0	110	0	0

接著
分析
2021

年9月26日花蓮縣地震事件，圖 貳-25 中同樣為使用 PGA 作為單一門檻值時之混淆矩陣分析結果。結果顯示，共7個測站出現誤報。當引入 CAV 為第二門檻值後，結果如圖 貳-26 所示，左中右分別對應三組不同門檻設定。可見隨著 CAV 門檻值提高，誤報逐漸減少，最終可達零誤報，但漏報數量亦相對提升，從原本2個最多增加至12個。

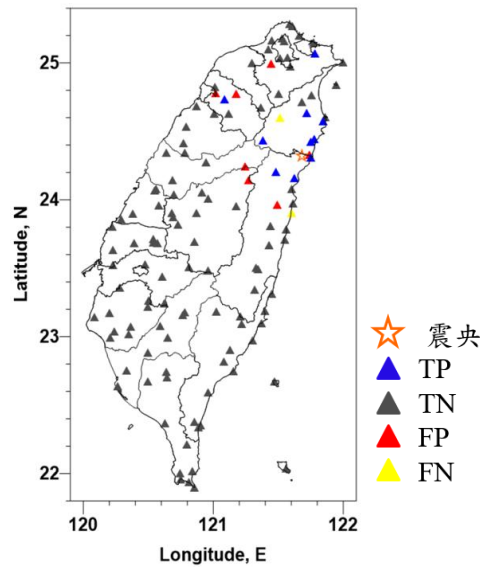


圖 貳-25 使用 PGA 為發報門檻之二元混淆矩陣分布(210926)

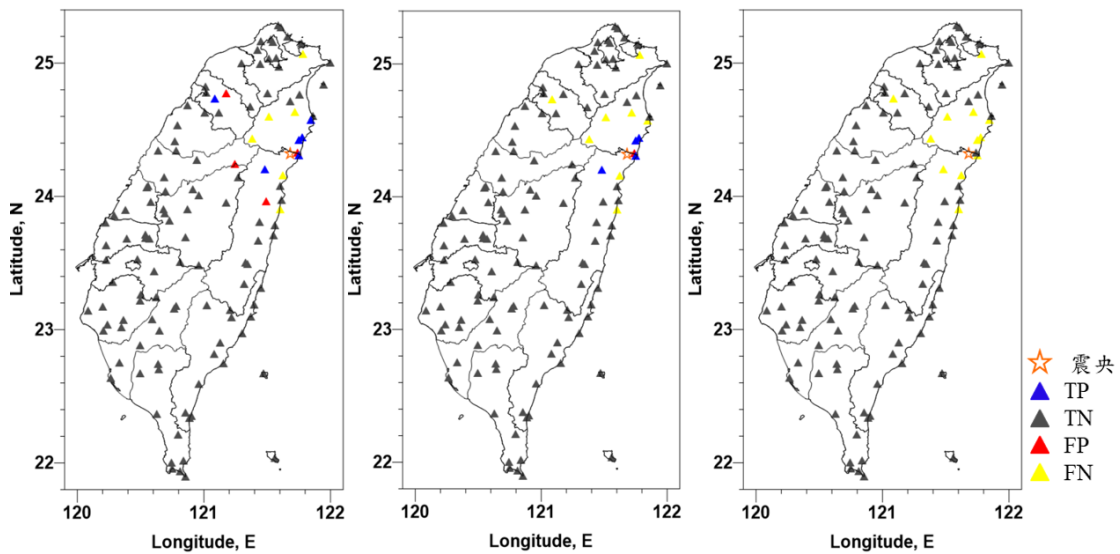


圖 貳-26 加入 CAV 為發報門檻之二元混淆矩陣分布

(左： $CAV = 2.87 cm/s^2$ 、中： $CAV = 5.42$ 、右： $CAV = 13.26 cm/s^2$)

表 貳-8 二元混淆矩陣數量分布(210926)

Threshold (cm/s^2)	TP	TN	FP	FN
$PGA = 25gal$	10	111	7	2
$PGA = 25gal \cdot CAV = 2.87 cm/s^2$	6	114	4	6
$PGA = 25gal \cdot CAV = 5.42 cm/s^2$	4	117	1	8
$PGA = 25gal \cdot CAV = 13.26 cm/s^2$	0	118	0	12

最後
針對
2016
年 5
月 30
日臺
東縣
地震

事件進行分析，其 PGA 發報門檻之混淆矩陣如圖 貳-27 所示。分析結果顯示，僅 1 個測站出現誤報。進一步引入三組 CAV 門檻後，結果如圖 貳-28 所示，由左至右為三種門檻設定。結果顯示，所有門檻設定皆可成功消除原先誤報，且不會增加漏報數量，證明 CAV 為有效之輔助指標，有助於提升模型整體預測表現。

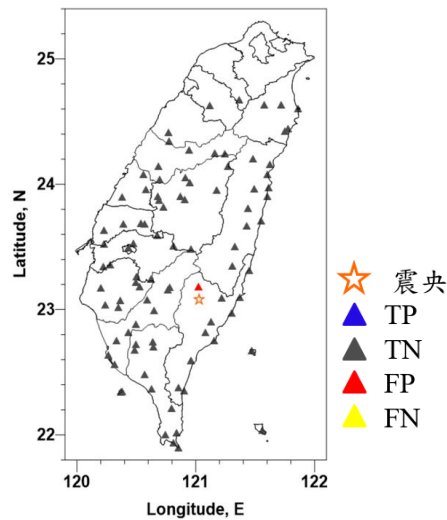


圖 貳-27 使用 PGA 為發報門檻之二元混淆矩陣分布(160530)

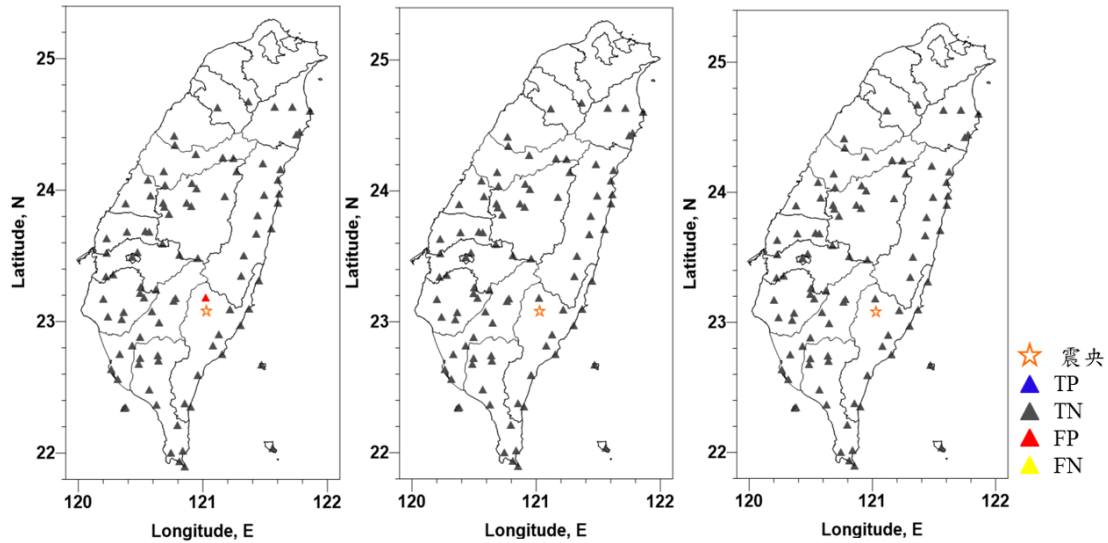


圖 貳-28 加入 CAV 為發報門檻之二元混淆矩陣分布

(左：CAV = 2.87 cm/s^2 、中：CAV = 5.42、右：CAV = 13.26 cm/s^2)

表 貳-9 誤差二元混淆矩陣數量分布(160530)

Threshold (cm/s^2)	TP	TN	FP	FN
<i>PGA = 25gal</i>	0	95	1	0
<i>PGA = 25gal</i> 、 <i>CAV = 2.87 cm/s^2</i>	0	95	1	0
<i>PGA = 25gal</i> 、 <i>CAV = 5.42 cm/s^2</i>	0	96	0	0
<i>PGA = 25gal</i> 、 <i>CAV = 13.26 cm/s^2</i>	0	96	0	0

本研究進一步針對三筆震度四級以下之小地震事件，分別比較單一 PGA 門檻與引入 CAV 為第二門檻時之 FPR 與 FNR 表現，分析結果如表 貳-10 所示。2021 年 11 月 14 日宜蘭地震事件中，單採用 PGA 為門檻時，FPR 為 2.72%，FNR 為 0%，顯示誤報情形輕微，但無漏報現象，說明模型在事件中的準確性良好。引入 CAV 作為第二門檻後，誤報可完全消除 (FPR = 0%)，且 FNR 維持為 0%，顯示提升 CAV 門檻值並未影響預警準確性，反而有效避免誤報。在 2021 年 9 月 26 日花蓮地震事件中，使用 PGA 門檻時 FPR 為 5.93%，FNR 為 36.66%，顯示誤報比例相對偏高。採用 CAV 門檻後，FPR 可降至 0-3.38%，惟 FNR 則明顯上升至 50-100%，呈現與大地震相同之誤報與漏報間權衡關係。此結果亦指出，雖可有效壓制誤報，但同時可能導致預警靈敏度降低。至於 2016 年 5 月 30 日臺東地震事件，單採用 PGA 為門檻時，FPR 為 1.4%，FNR 為 0%，顯示誤報情形輕微，但無漏報現象，說明模型在事件中的準確性良好。引入 CAV 作為第二

門檻後，誤報可完全消除 (FPR=0%)，且 FNR 維持為 0%，顯示提升 CAV 門檻值並未影響預警準確性，反而有效避免誤報。

表 貳-10 三地震事件不同門檻值 FPR 和 FNR 比較

Event	FPR (%)	FNR (%)	FPR (%)	FNR (%)	FPR (%)	FNR (%)	FPR (%)	FNR (%)
	<i>PGA = 25gal</i>		<i>CAV = 2.87 cm/s</i>		<i>CAV = 5.42 cm/s</i>		<i>CAV = 13.26 cm/s²</i>	
20211114	2.72	0	1.81	0	0	0	0	0
20210926	5.93	16.66	3.38	50	0.84	66.67	0	100
20160530	1.4	0	1.4	0	0	0	0	0

參、網格化區域警報結果分析

3.1 研究目的


在分析地震事件時，發現對於地域範圍較大的縣市，若依現行地震預警系統以縣市為單位發佈警報，可能會產生不必要的警報。例如，當一地震震央位於某縣市的北端，最大震度達四級，整個縣市將皆會收到預警通知，然而實際上南端居民可能完全沒有感受到此地震事件。本研究嘗試以網格化的方式細化預警單位，以提升不同區域預警的準確度，並使其更能反映地震震度的真實分佈情形。以下將根據面積大小及測站數量劃分網格區域，分別分析不同劃分依據下的發報結果。

3.2 劃分方式

3.2.1 以面積大小作為依據劃分

首先考量面積大小，圖 參-1 為花蓮縣各鄉鎮市區的面積分布，圖 參-2 為臺東縣各鄉鎮市區的面積分布（參考 112 年鄉鎮市區界線圖），各鄉鎮市區的面積分布將花蓮縣臺東縣細分為不同大小的網格，依次設定為約 2000、1500 及 1000 平方公里，以便觀察網格大小對預警發報的影響。嘗試透過面積劃分，希望能夠更清楚地評估震源遠離的區域是否仍需發佈警報。這樣的劃分方式可能有助於避免較小甚至無震感的區域收到不必要的預警，從而提升預警的準確性。

花蓮縣鄉鎮分區與編號



各鄉鎮面積 (km²)

1. 花蓮縣 秀林鄉: 1621.99 km²
2. 花蓮縣 新城鄉: 29.14 km²
3. 花蓮縣 花蓮市: 30.95 km²
4. 花蓮縣 吉安鄉: 62.90 km²
5. 花蓮縣 壽豐鄉: 207.21 km²
6. 花蓮縣 鳳林鎮: 119.16 km²
7. 花蓮縣 萬榮鄉: 659.02 km²
8. 花蓮縣 光復鄉: 132.65 km²
9. 花蓮縣 豐濱鄉: 159.68 km²
10. 花蓮縣 瑞穗鄉: 154.50 km²
11. 花蓮縣 卓溪鄉: 1045.07 km²
12. 花蓮縣 玉里鎮: 211.08 km²
13. 花蓮縣 富里鄉: 171.93 km²

圖 參-1 花蓮鄉鎮市區面積大小分布圖

臺東縣鄉鎮分區與編號




各鄉鎮面積 (km²)

1. 臺東縣 長濱鄉: 151.06 km²
2. 臺東縣 海端鄉: 892.99 km²
3. 臺東縣 成功鎮: 146.31 km²
4. 臺東縣 池上鄉: 79.22 km²
5. 臺東縣 關山鎮: 60.33 km²
6. 臺東縣 東河鄉: 216.45 km²
7. 臺東縣 鹿野鄉: 79.75 km²
8. 臺東縣 延平鄉: 480.64 km²
9. 臺東縣 卑南鄉: 425.67 km²
10. 臺東縣 臺東市: 113.01 km²
11. 臺東縣 綠島鄉: 14.25 km²
12. 臺東縣 金峰鄉: 387.54 km²
13. 臺東縣 太麻里鄉: 103.50 km²
14. 臺東縣 大武鄉: 63.16 km²
15. 臺東縣 達仁鄉: 321.05 km²
16. 臺東縣 蘭嶼鄉: 47.28 km²

圖 參-2 臺東鄉鎮市區面積大小分布圖


以面積 1000 平方公里進行劃分，可以將花蓮縣大致劃分成四個區域，臺東縣劃分成三個區域如圖 參-3 所示。



面積1000km²區分

圖 參-3 以面積 1000km²劃分區域圖

面積 1500 平方公里進行劃分，可以將花蓮縣大致劃分成三個區域，臺東縣劃分成兩個區域如圖 參-4 所示。



面積1500km²區分

圖 參-4 以面積 1500km²劃分區域圖

面積 2000 平方公里進行劃分，可以將花蓮縣大致劃分成兩個區域，臺東縣劃分成兩個區域如圖 參-5 所示。




圖 參-5 以面積 2000km²劃分區域圖

3.2.2 以測站數量作為依據劃分

本研究也依測站數量進行劃分，圖 參-6 圖 參-7 顯示了花蓮縣與臺東縣各鄉鎮市區的測站數量分布（CWASN 測網），根據區域內的測站配置將網格劃分為包含約 5 和 7 個測站的網格單位。此方式能夠充分利用現有測站的監測數據，提升各區域震度監測的精確度。透過不同測站密度的網格劃分，能更快速而有效地掌握各區域的地震強度，從而提高預警系統的靈敏度與可靠性。

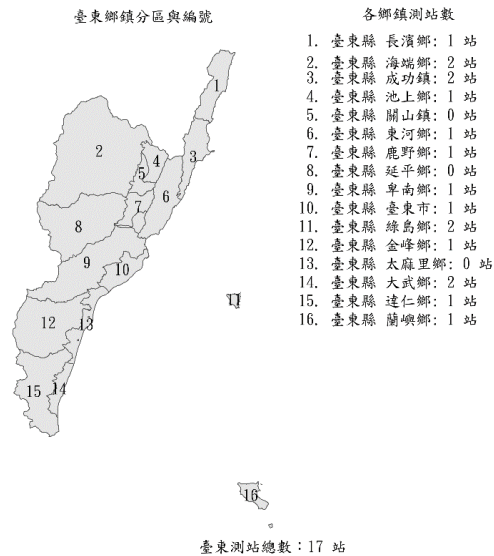



圖 參-6 花蓮鄉鎮市區測站數量分布圖

圖 參-7 臺東鄉鎮市區測站數量分布圖

若以測站數量 5 個進行劃分，花蓮縣可分為三個區域，臺東縣可分為三個區域。




圖 參-8 以測站數量 5 個劃分區域圖

若以測站數量 7 個進行劃分，花蓮縣可分為兩個區域，臺東縣可分為兩個區域。




圖 參-9 以測站數量 7 個劃分區域圖

3.2.3 小結

本研究之區域型的警報發布規則為：當該區域的任意一個代表測站之預測 PGA 達發報門檻時，便向該區域進行發報。因此，本研究在考量網格化之區域時，必須確保每一區都至少擁有一個以上的代表測站，以確保每一區都能有至少一個代表測站進行發報。依據上述原則劃分網格化之區域後，關於本研究之現地型的警報發布規則為：當該區域內有任意一個測站之預測 PGA 達發報門檻時，便向該區域進行發報。

3.3 網格化區域警報結果

3.3.1 區域型預警

由於地震事件在 Earthworm 系統上進行回放模擬時僅能得到地震的預測震央與規模，為了得到各縣市的預測 PGA，會將各縣市政府的所在位置當代表座標，若縣市的幅員較大則會視情況增加 1 到 4 個座標來輔助計算，花蓮縣與臺東縣的代表測站可參考

表 參-1

表 參-2。之後根據 Shin(1998)提出的 PGA 衰減公式來推算各縣市的預測 PGA，基本算式如式(參-1)，M 為地震規模、R 為測站與震央距離、si 為場址效應。

在以面積大小及測站數量為基準對花蓮縣與臺東縣進行網格化的劃分之後，分別選擇以面積 2000km²如圖 參-5 以及每 7 個左右測站數為一組如圖 參-9 的劃分方式。

$$PGA = 12.44 * e^{1.31 * M} * R^{-1.837} * si \quad (參-1)$$

表 參-1 花蓮縣代表座標與 si 值

花蓮代表測站	經度	緯度	si 值
HWA	121.616	24.002	1.520
EGFH	121.423	23.669	1.918
EYUL	121.315	23.335	1.254

表 參-2 臺東縣代表座標與 si 值

臺東代表測站	經度	緯度	si 值
TTN	121.15	22.755	1.148
ECS	121.215	23.122	1.669
TAWH	120.87	22.340	1.266

3.3.2 地震事件分析

本研究以 2021 年 10 月 24 日 13:11:34 規模 6.5 之宜蘭地震事件為例，並針對花蓮縣和臺東縣進行網格化，以觀察對縣市進行劃分後的發布情況。此次地震事件震央位於宜蘭縣南澳鄉，各地震度分布圖如所示，其中花蓮縣最大震度達 4 級以上，若是依現行地震預警系統以縣市為單位發布警報，會對整個花蓮縣市進行發報，但實際上花蓮縣南部的居民可能並未感受到明顯的震動。

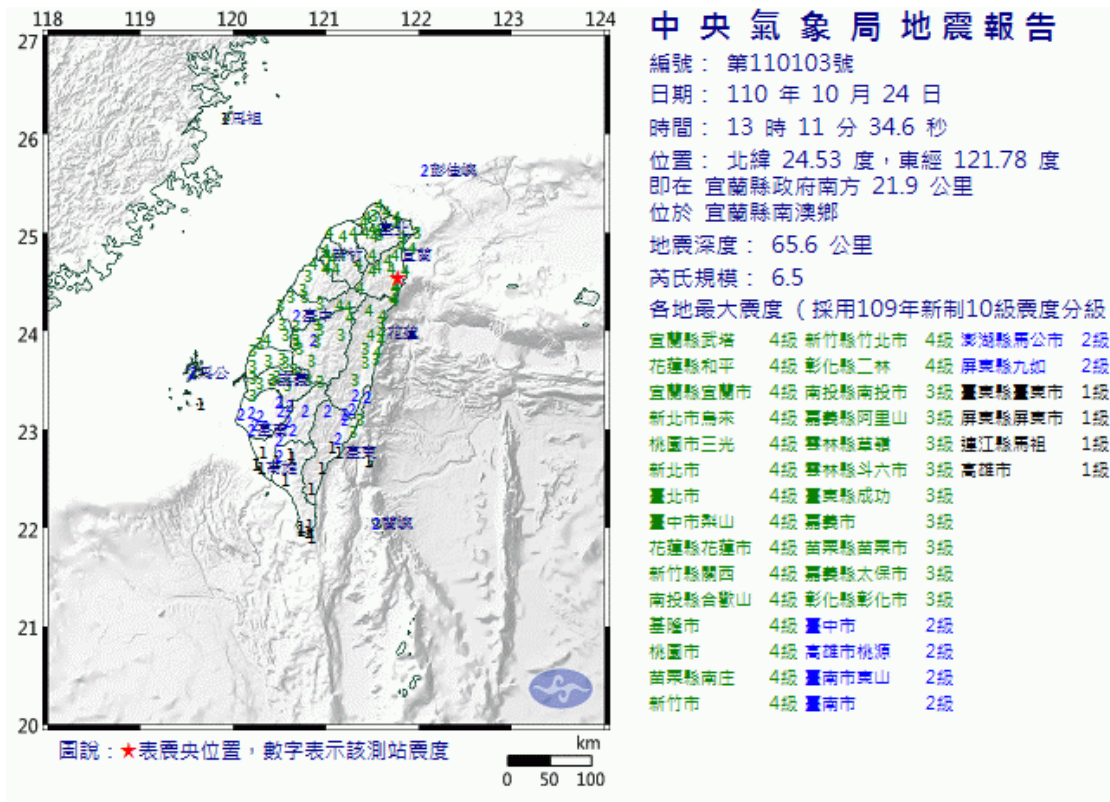


圖 參-10 20211024 事件各地震度圖

以測站數量為 7 個條件下進行網格化後的結果，實際震度分布圖、現地型預測震度圖及區域型預測震度圖分別如圖 參-11 所示。

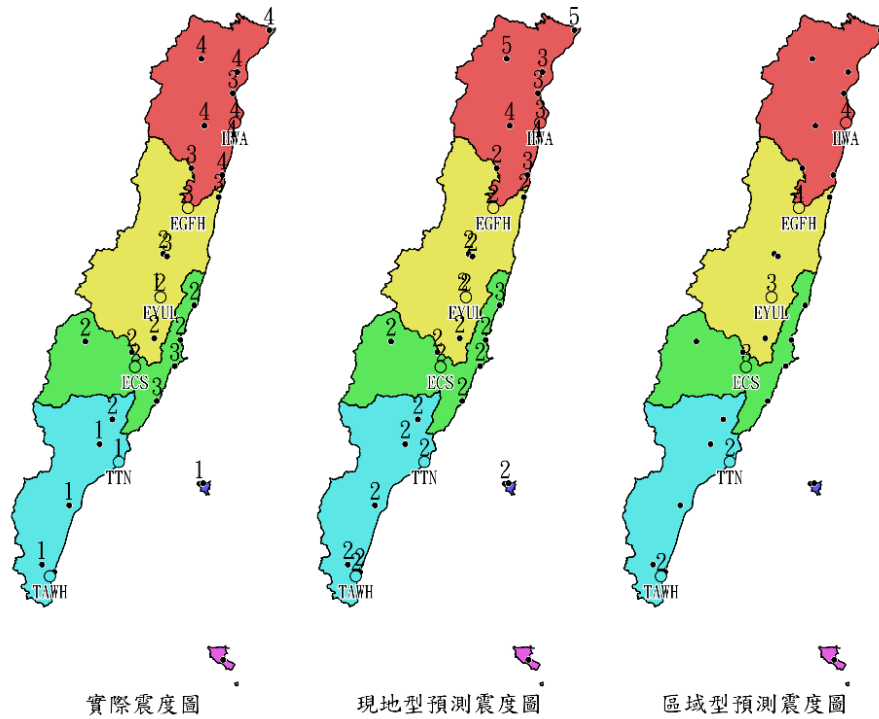


圖 參-11 以測站數量 7 個劃分之網格化結果

根據現地型預測震度與實際震度的結果分布，可繪製網格化後的現地型發報的分佈結果如圖 參-12。圖中左 1 為現地型的結果，花蓮縣北部為正確發報，花蓮縣南部與臺東縣為正確不報，因此四個區域皆發報正確。左 2 為現地型加上 CAV 門檻值(2.87cm/s)的結果，也是四個區域皆發報正確。左 3 為純區域型的結果，花蓮縣北部為正確發報，花蓮縣南部為誤報，臺東縣為正確不報。左 4 區域型+現地型(含 CAV 門檻)的結果，花蓮縣北部為正確發報，花蓮縣南部為誤報(區域型控制)，臺東縣為正確不報。

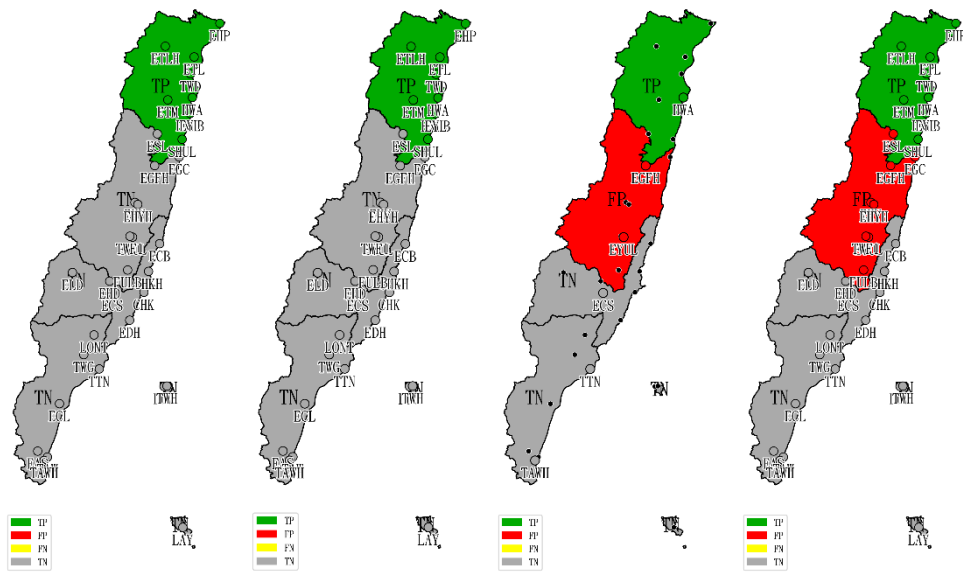


圖 參-12 網格化後發報的分佈結果 (左 1：純現地型；左 2：現地型加上 CAV 門檻值；左 3：純區域型；左 4：區域型+現地型(含 CAV 門檻))

在預警時間方面，若觸發後 2 秒採用 CNN 模型進行預測，圖 參-13 為現地型網格化各區之發震後所需的預警時間，圖中亦標示每個區域最早發布警報的測站。為了瞭解是否可在近震央區域提早預警，亦根據 REP 紀錄檔取得區域型第 3 報的預警時間，其近震央區域(花蓮北部)比較如表 參-3 所示，區域型第 3 報的預警時間為 15.2 秒，得知若結合現地型的發報，對於震央區域(花蓮北部)的發報時間可能提早約 1.88 秒。




圖 參-13 現地型網格化各區之發震後預警時間

表 參-3 預警時間

	近震央區域預警時間
區域型	15.2 秒
現地型	13.32 秒

以面積 2000 平方公里條件下進行網格化後的結果，實際震度分布圖、現地型預測震度圖及區域型預測震度圖分別如圖 參-14 所示。

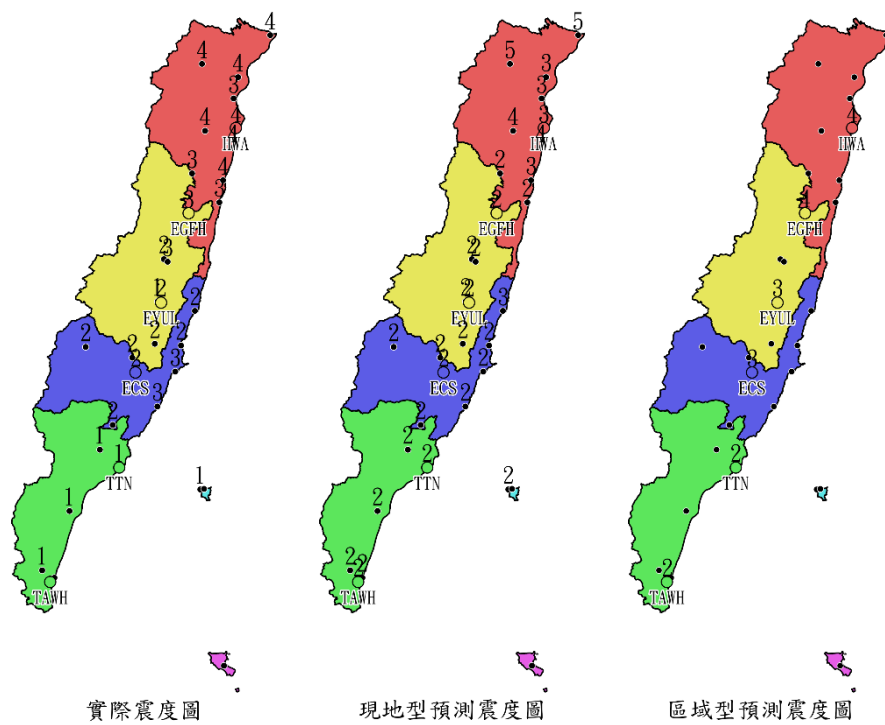


圖 參-14 以面積 2000km²劃分之網格化結果

根據現地型預測震度與實際震度的結果分布，可繪製網格化後的現地型發報的分佈結果如圖 參-15。圖中左 1 為現地型的結果，花蓮縣北部為正確發報，花蓮縣南部與臺東縣為正確不報，因此四個區域皆發報正確。左 2 為現地型加上 CAV 門檻值(2.87cm/s)的結果，也是四個區域皆發報正確。左 3 為純區域型的結果，花蓮縣北部為正確發報，花蓮縣南部為誤報，臺東縣為正確不報。左 4 區域型+現地型(含 CAV 門檻)的結果，花蓮縣北部為正確發報，花蓮縣南部為誤報(區域型控制)，臺東縣為正確不報。

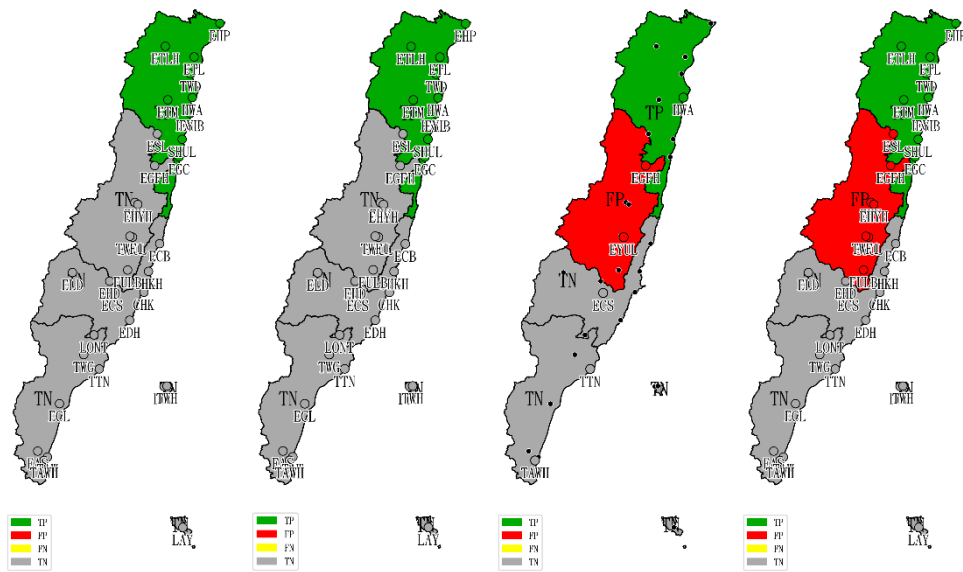


圖 參-15 網格化後發報的分佈結果 (左 1：純現地型；左 2：現地型加上 CAV 門檻值；左 3：純區域型；左 4：區域型+現地型(含 CAV 門檻))

在預警時間方面，若觸發後 2 秒採用 CNN 模型進行預測，圖 參-16 為現地型網格化各區之發震後預警時間，圖中亦標示每個區域最早發布警報的測站。為了瞭解是否可在近震央區域提早預警，亦根據 REP 紀錄檔取得區域型第 3 報的預警時間，其近震央區域(花蓮北部)比較如表 參-4 預警時間 所示，區域型第 3 報的預警時間為 15.2 秒，得知若結合現地型的發報，對於震央區域(花蓮北部)的發報時間可能提早約 1.88 秒。




圖 參-16 每區最早接收 P 波的測站

表 參-4 預警時間

	近震央區域預警時間
區域型	15.2 秒
現地型	13.32 秒

此外本研究也以 2021 年 6 月 12 日 5:58:58 規模 5.3 之臺東地震事件為例，並針對花蓮縣和臺東縣進行網格化，以觀察對縣市進行劃分後的發布情況。此次地震事件震央位於臺東縣近海，各地震度分布圖如所示，其中臺東縣最大震度達 4 級以上，若是依現行地震預警系統以縣市為單位發布警報，會對整個臺東縣市進行發報，但實際上臺東縣北部的居民可能並未感受到明顯的震動。

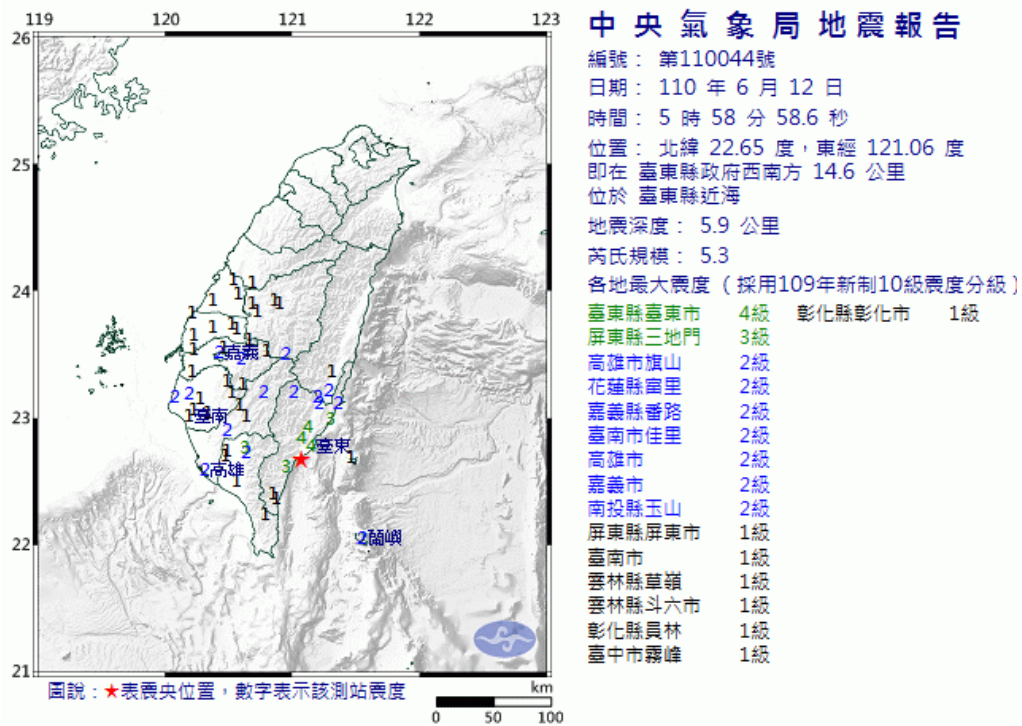


圖 參-17 20210612 事件各地震度圖

以測站數量為 7 個條件下進行網格化後的結果，實際震度分布圖、現地型預測震度圖及區域型預測震度圖分別如圖 參-18 所示。

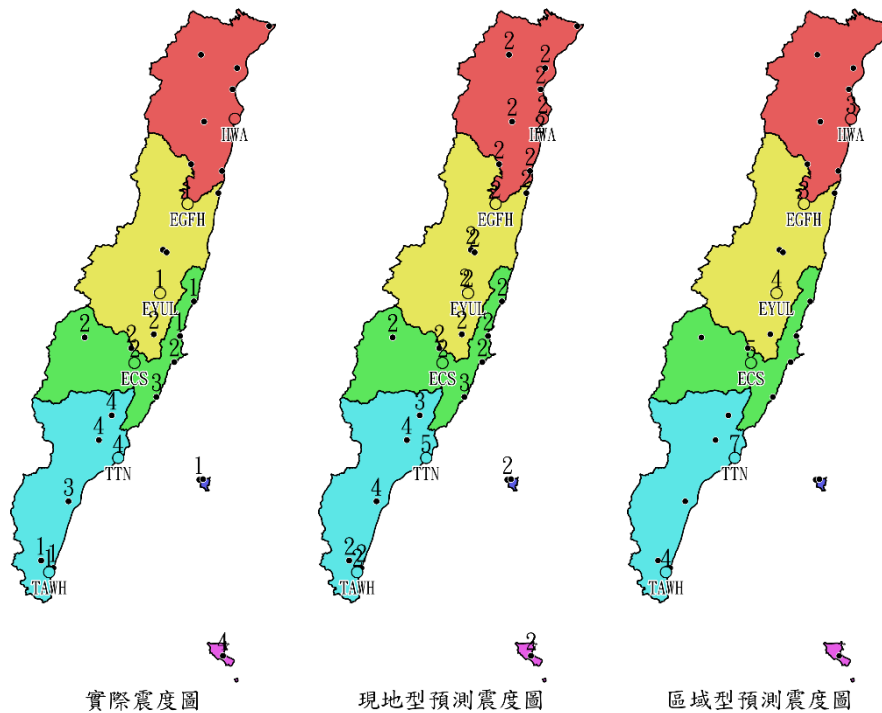


圖 參-18 以測站數量 7 個劃分之網格化結果

根據現地型預測震度與實際震度的結果分布，可繪製網格化後的現地型發報的分佈結果如圖 參-19。圖中左 1 為現地型的結果，臺東縣南部為正確發報，臺東縣北部與花蓮縣為正確不報，因此四個區域皆發報正確。左 2 為現地型加上 CAV 門檻值(2.87cm/s)的結果，也是四個區域皆發報正確。左 3 為純區域型的結果，臺東縣南部為正確發報，臺東縣與花蓮縣南部為誤報，花蓮縣北部為正確不報。左 4 區域型+現地型(含 CAV 門檻)的結果，臺東縣南部為正確發報，臺東縣與花蓮縣南部為誤報，花蓮縣北部為正確不報。

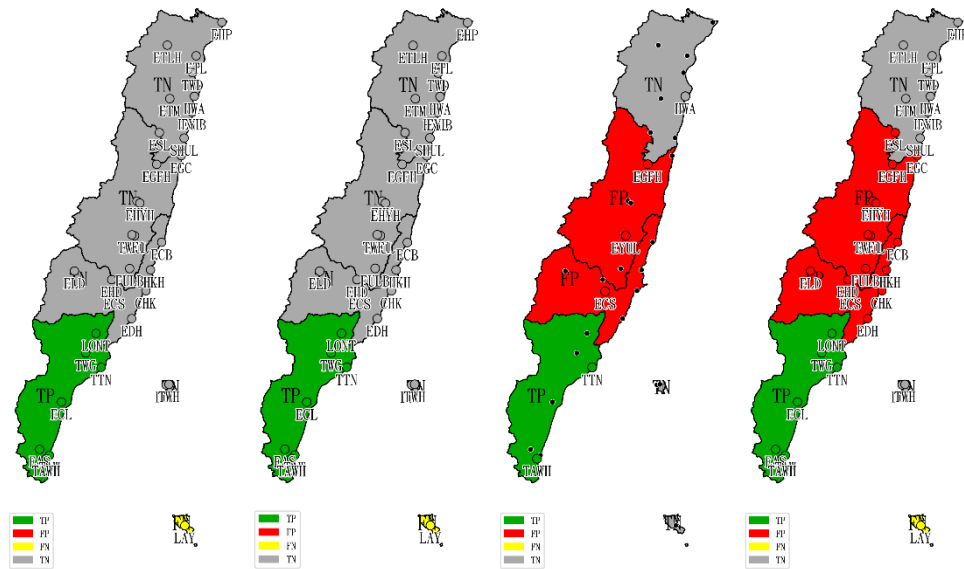


圖 參-19 網格化後發報的分佈結果 (左 1：純現地型；左 2：現地型加上 CAV 門檻值；左 3：純區域型；左 4：區域型+現地型(含 CAV 門檻))

在預警時間方面，若觸發後 2 秒採用 CNN 模型進行預測，圖 參-20 為現地型網格化各區之發震後預警時間，圖中亦標示每個區域最早發布警報的測站。為了瞭解是否可在近震央區域提早預警，亦根據.REP 紀錄檔取得區域型第 3 報的預警時間，其震央區域(臺東南部)比較如表 參-5 預警時間所示，區域型第 3 報的預警時間為 9.79 秒，得知若結合現地型的發報，發報時間可能提早約 4.28 秒。




圖 參-20 每區最早接收 P 波的測站

表 參-5 預警時間

	近震央區域預警時間
區域型	9.79 秒
現地型	5.51 秒

以面積 2000 平方公里條件下進行網格化後的結果，實際震度分布圖、現地型預測震度圖及區域型預測震度圖分別如圖 參-21 所示。

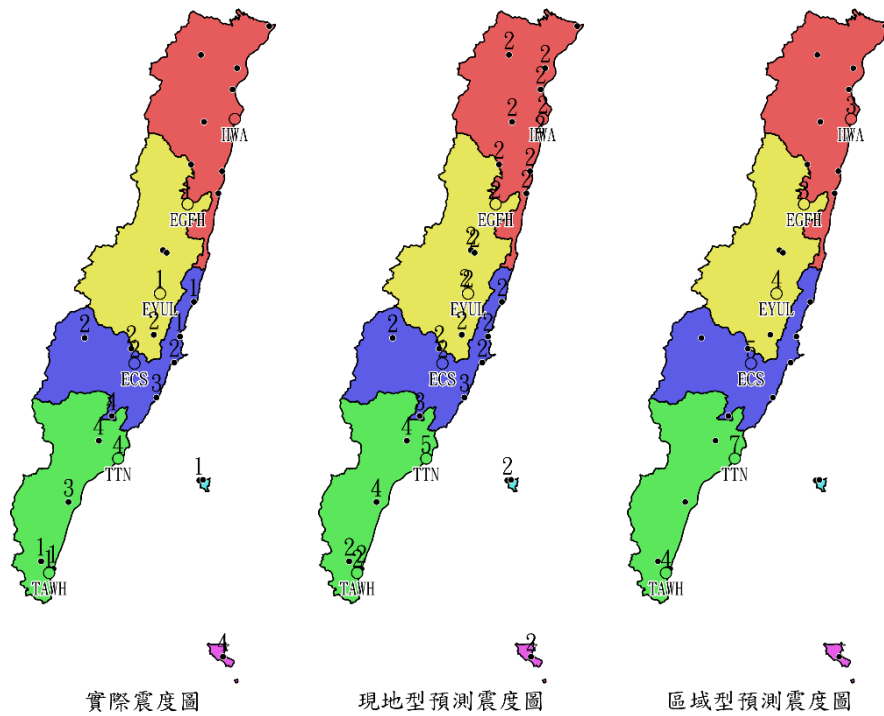


圖 參-21 以面積 2000km²劃分之網格化結果

根據現地型預測震度與實際震度的結果分布，可繪製網格化後的現地型發報的分佈結果如圖 參-22。圖中左 1 為現地型的結果，臺東縣南部為正確發報，臺東縣北部為漏報，花蓮縣為正確不報。左 2 為現地型加上 CAV 門檻值(2.87cm/s)的結果，臺東縣南部為正確發報，臺東縣北部為漏報，花蓮縣為正確不報。左 3 為純區域型的結果，臺東縣南部為正確發報，臺東縣與花蓮縣南部為誤報，花蓮縣北部為正確不報。左 4 區域型+現地型(含 CAV 門檻)的結果，臺東縣為正確發報，花蓮縣南部為誤報，花蓮縣北部為正確不報。

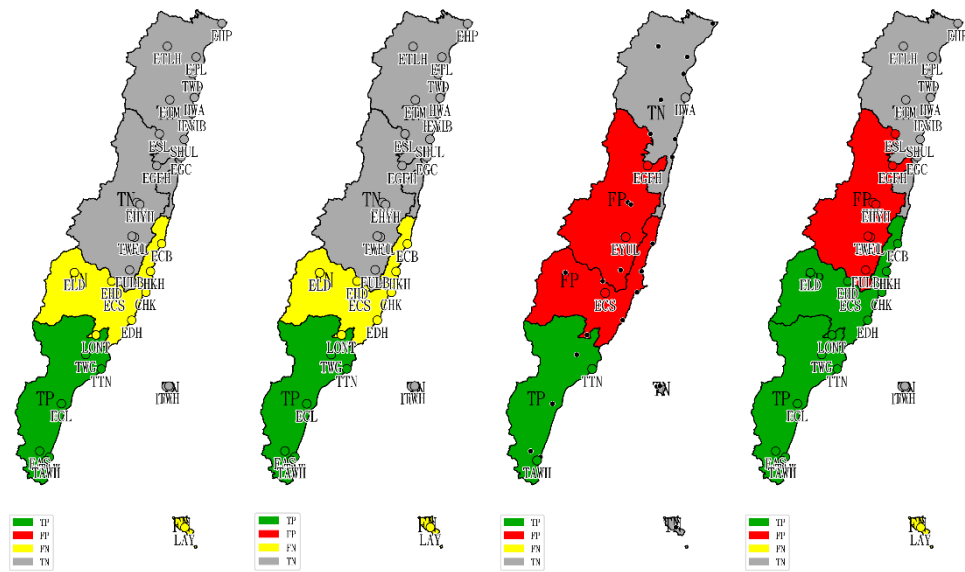


圖 參-22 網格化後發報的分佈結果 (左 1：純現地型；左 2：現地型加上 CAV 門檻值；左 3：純區域型；左 4：區域型+現地型(含 CAV 門檻))

在預警時間方面，若觸發後 2 秒採用 CNN 模型進行預測，圖 參-23 為現地型網格化各區之發震後預警時間，圖中亦標示每個區域最早發布警報的測站。為了瞭解是否可在近震央區域提早預警，亦根據.REP 紀錄檔取得區域型第 3 報的預警時間，其震央區域(臺東南部)比較如表 參-6 所示，區域型第 3 報的預警時間為 9.79 秒，得知若結合現地型的發報，發報時間可能提早約 4.28 秒。




圖 參-23 每區最早接收 P 波的測站

表 參-6 預警時間

	近震央區域預警時間
區域型	9.79 秒
現地型	5.51 秒

肆、結論

針對不同參數門檻設定對地震預警系統發報準確性的影響，本研究進行了各參數與實際 PGA 間對數尺度下的關聯性分析，並評估不同門檻設定下的誤報與漏報情形。本研究選用 FPR (False Positive Rate) 與 FNR (False Negative Rate) 作為主要評估指標，以提供穩定且具判別性的比較依據。分析結果顯示，CAV 於各種固定 FPR 條件下均展現出最低的 FNR，亦即維持在相同誤報程度下，CAV 漏報的情形最低，顯示其作為發報參數具有較佳的準確性。

針對最大震度大於五級之大地震事件分析結果顯示，CNN 模型在部分情境下可僅透過 PGA 單一門檻即達成無誤報 (FPR = 0%) 的預測效果，特別是在 2024 年花蓮地震事件中皆無誤報產生，顯示 CNN 模型具備良好準確性。然而，在 2016 年美濃地震與 2018 年花蓮地震中，使用 PGA 為單一門檻仍出現誤報情形。當引入 CAV 作為第二門檻後，可顯著降低誤報，顯示其對於提升預警系統準確性具有

明顯成效。然而，誤報減少的代價為漏報（FNR）明顯上升，顯示需在誤報與靈敏度之間進行權衡。

針對震度小於或等於四級之小地震事件分析顯示，雖然部分事件仍會出現誤報，在引入 CAV 作為第二門檻的情境下，多數小地震案例可完全消除誤報，且不造成漏報增加，顯示其輔助判斷效果顯著。但在少數案例中，如 2021 年花蓮地震事件，儘管誤報完全消除，但隨門檻提升亦導致漏報數量顯著上升，顯示即便在小地震情境下，仍存在誤報與漏報之間的取捨問題。整體而言，CAV 的引入對提升模型準確率具正面效果，仍需依事件特性調整參數設定以兼顧靈敏度。

本研究探討了基於網格化的警報發布方式，旨在解決目前以「縣市」為單位發佈警報所帶來的誤報問題，特別是在震央位於較大範圍的縣市時，可能會對未感受到震動的區域發出不必要的警報。透過將預警單位細化為不同大小的網格區域，能更準確地反映實際震度分佈，並避免向無感地區發佈預警，從而提高預警系統的準確性。

分析結果顯示，依據面積大小或測站數量劃分網格，能顯著改善大範圍區域的預警準確性。這樣的網格化方法能反映震源遠離區域的震度分佈，並避免誤報情況的發生。此外，依據目前的地震事件分析結果表明，若將區域型預警結合現地型預警的警報，網格化預警系統在近震央區域的發報速度較快，能有效縮短近震央區域的預警時間。

參考文獻

- [1] 黃昭文, "卷積神經網路應用於初達波預估當站最大地表加速度之研究," 碩士, 營建工程系, 國立臺灣科技大學, 台北市, 2020.
- [2] Y.-M. Wu and H. Kanamori, "Rapid assessment of damage potential of earthquakes in Taiwan from the beginning of P waves," *Bull. Seismol. Soc. Am.*, vol. 95, no. 3, pp. 1181–1185, Jun. 2005, doi: 10.1785/0120040193.
- [3] Y. Nakamura, J. Saita, and T. Sato, "On an earthquake early warning system (EEW) and its applications," *Soil Dyn. Earthq. Eng.*, vol. 31, pp. 127–136, 2011.
- [4] M. Erdik, Y. Fahjan, O. Ozel, H. Alcik, A. Mert, and M. Gul, "Istanbul earthquake rapid response and the early warning system," *Bull. Earthq. Eng.*, vol. 1, pp. 157–163, 2003.
- [5] A. G. Iaccarino, M. Picozzi, D. Bindi, and D. Spallarossa, "Onsite earthquake early warning: Predictive models for acceleration response spectra considering site effects," *Bull. Seismol. Soc. Am.*, vol. 110, no. 3, pp. 1289–1304, 2020, doi: 10.1785/0120190272.
- [6] H. Alcik, O. Ozel, Y.-M. Wu, N. M. Ozel, and M. Erdik, "An alternative approach for the Istanbul earthquake early warning system," *Soil Dyn. Earthq. Eng.*, vol. 31, pp. 181–187, 2011.