

國立臺灣大學理學院地質科學研究所

碩士論文

Department of Geosciences

College of Science

National Taiwan University

Master's Thesis



利用深度學習解析震源機制解以及

完善 AI 地震觀測平台 SeisBlue

Utilizing Deep Learning for Focal Mechanism Analysis
and

Enhancing the SeisBlue AI Seismic Observation Platform

張以昕

I-Hsin Chang

指導教授: 郭陳浩 博士

Advisor: Hao Kuo-Chen Ph.D.

中華民國 113 年 7 月

July, 2024

國立臺灣大學碩士學位論文

口試委員會審定書

MASTER'S THESIS ACCEPTANCE CERTIFICATE
NATIONAL TAIWAN UNIVERSITY

利用深度學習解析震源機制解以及 完善 AI 地震觀測平台 SeisBlue

Utilizing Deep Learning for Focal Mechanism and Enhancing the SeisBlue AI
Seismic Observation Platform

本論文係張以昕 R11224204 在國立臺灣大學地質科學研究所完成之碩士學位論文，於民國 113 年 7 月 22 日承下列考試委員審查通過及口試及格，特此證明。

The undersigned, appointed by the Department of Geosciences on 22/7/2024 have examined a Master's Thesis entitled above presented by I-HSIN CHANG R11224204 candidate and hereby certify that it is worthy of acceptance.

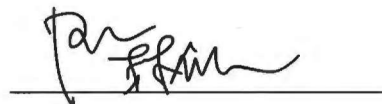
口試委員 Oral examination committee:

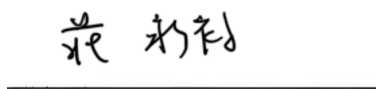


(指導教授 Advisor)











系（所、學位學程）主管 Director: _____

摘要



應對密集地震網和地震資料量劇增的重大挑戰，本研究注重在應用深度學習技術來提高地震資料處理的自動化程度和效率，尤其是在規模大於 0.8 以上的地震觀測領域的發展上。自 2018 年以來，台灣大學構造地震研究室開發 SeisBlue 系統並在 2020 年開始成功應用在多個案例，達到區域性的近即時地震定位。

本研究致力於開發更完善的第三代系統，目標著重在系統擴展、強化和整合。新開發一個以卷積神經網路為基礎的模組 (SeisPolor)，用於分類地震連續資料中的 P 波極性，進而用 FPFIT 等方法自動解析地震震源機制。而在強化部分著重將波相到時偵測模型以 PyTorch 改寫以提升系統靈活性，提高模型調整與實驗的開發效率。

研究結果顯示，在自動識別 P 波極性的模型表現優異，精確率達 95%。將預測極性解析成震源機制，並考量測站方位角與距離的包覆度門檻後，採用 Kagan 測試方法評估預測與真實震源機制解之間的相似性，Kagan 測試方法以最小旋轉角度小於 40 度為預測正確的標準，震源機制解的結果顯示近 80% 的準確率。此外，在重新設計與訓練的波相到時偵測模型，在 P 波和 S 波都解決提早挑選的現象，並使精確率提升約 8%。此外，本研究以資料管線為主軸重新設計整體系統的自動化流程，系統在實現過程中廣泛借鑒了資訊工程的先進技術，整合了硬體、系統環境、資料庫、資料管線、模型開發、任務監控以及資料可視化、Web UI 互動等多方面技術。

本研究在原有基礎上達到系統擴展、強化和整合。目前已實現了從地震連續資料處理到挑波、定位、規模計算及震源機制解析的半自動化流程。並經實驗與調整後，大幅提升波相到時偵測模型的精確率。結合軟體技術的優勢，本系統不僅加快了資料處理速度，系統重構後強調的管線化設計，也為未來提供了快速開發的可能性，使模型性能不斷提升。對於地震活躍的台灣，該系統將大幅提升地

震觀測的速度與品質，抓回大量小規模地震資訊，以高時空解析度的地震目錄協助評估活動構造。



關鍵字：地震監測、深度學習、SeisBlue、SeisPolar、震源機制解

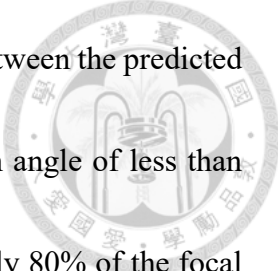
Abstract



To address the significant challenges posed by the rapid increase in dense seismic networks and seismic data, this study focuses on applying deep learning techniques to enhance the automation and efficiency of seismic data processing, particularly advancing microseismic monitoring developments (0.8M+). Since 2018, the Structural Seismology Lab (SGYLAB) at National Taiwan University has developed the SeisBlue system, which has been successfully applied in multiple cases since 2020 to achieve regional near-real-time earthquake localization.

This research is dedicated to developing a more refined third-generation system, with an emphasis on system expansion, enhancement, and integration. A key development is a CNN-based module (SeisPolor), designed for classifying P-wave polarity in continuous seismic data, subsequently utilizing the FPFIT method to automatically analyze earthquake focal mechanisms. The enhancement efforts include redesign the phase picking model in PyTorch to improve system flexibility and increase the efficiency of model adjustments and experimental development.

The results demonstrate that the model for automatic identification of P-wave polarity performs excellently, with a precision of 97%. By converting the predicted polarities into focal mechanisms and considering coverage thresholds based on station azimuth and dis-



tance, the Kagan test method is employed to evaluate the similarity between the predicted and actual focal mechanisms. This method uses a minimum rotation angle of less than 40 degrees as the criterion for a correct prediction, showing that nearly 80% of the focal mechanisms are accurate. Moreover, the redesigned and retrained picking model solved the issue of early picking and showed an 8% increase in precision for both P-wave and S-wave. Furthermore, the study redesigned the overall system automation workflow around a data pipeline, extensively drawing on advanced information engineering technologies. The integration encompasses hardware, system environment, databases, data pipelines, model development, task monitoring, data visualization, and Web UI interaction.

Building on the existing foundation, this study achieves system expansion, enhancement, and integration. A semi-automated workflow from continuous seismic data processing to picking, localization, magnitude estimation, and focal mechanism analysis has been realized. Through experiments and adjustments, the picking model's accuracy has been significantly improved. Leveraging software technology advantages, the system not only speeds up data processing but also emphasizes a pipeline design in its reconstruction, providing potential for rapid development and continual performance enhancement. For Taiwan, a region prone to seismic activity, this system can significantly enhance the speed and quality of earthquake monitoring, capturing a substantial amount of small earthquake

data. It will assist in the evaluation of active structures through a high spatio-temporal resolution earthquake catalog.




Keywords: Seismicity Monitoring, Deep Learning, SeisBlue, SeisPolar, Focal Mechanism

致謝



回想當年立志在地球科學領域與資訊工程之間搭起橋樑，在以往的研究經驗，常發現理論與應用存在鴻溝，研究應用時常常仰賴如黑盒子般的前人所開發的功能，因此強烈希望培養能力解開黑盒子，從了解到修改，甚至到創新。隨著AI科技發展，更加堅定此想法，各領域存在已久的效能需求將有望被解決，如何真正將技術引入並開發成適合此領域的應用是一大令人興奮的挑戰。郭陳濤教授、黃俊銘研究生在2018年開始投入研究並作為地震觀測領域引入AI的先鋒，為提高效能與質量的自動化地震觀測的目標帶來曙光。感謝郭陳在這個燒錢的新興領域大力資助，並帶領團隊持續將這個長期計畫付諸實現，要花更多心思兼顧各種計畫，十分令人敬佩。感謝居米當初看見需求與AI趨勢，勇敢拓荒引入技術一手建立起系統，並以不藏私的精神帶後輩將技術傳承下去，在這兩年相當有幸能跟著居米大佬學習，在軟體技能方面有所突破、飛躍成長。感謝提供研究資料的地震構造研究室，特別是小管、龜姊、小環、Leo、小熊、珏縈、怡君和祥哥，以及長達10年以上所有參與佈站和人工標註的人員，有時甚至還要冒著生命風險在大地震後去追震。兩年前很榮幸加入這個大家庭，延續這個長達六年的系統專案的任務，很快就讓我明白延續一個大專案遠比開創一個小專案來的遠遠不容易，充滿心酸血淚，卻也著實培養在逆境中掙扎成長培養出百折不撓的精神，是接近真實職場社會的一場歷練。

在研究生生涯之前的磨練，也是那般不可或缺。感謝在大學時期啟蒙我對學術研究和寫程式的張午龍老師，感謝在中研院地球所的郭本垣老師，以及彭振謙學長、柯逸寧學姊和林耕需學長，在大學時期的研究實習過程中，踏踏實實領悟到學術研究工作者的精神與心態，面對未知能一步步抽絲剝繭探討結果，我想就是這樣的精神與心態對自己往後的求學生涯影響甚遠。感謝家人的養育之恩，如今也終於可以讓爸媽卸下擔子好好退休，感謝生了一個熱鬧的大家庭讓我有爺爺



奶奶姑姑姊姊的寵愛。感謝男朋友吳佩鴻的學術指點與學霸知識，更陪伴我走過那些挫折與迷茫，給予無盡的力量。感謝羽球小夥伴敬德跟海豹，醫體團和各個羽球好夥伴們，讓我明白寫程式身體不能虛，在社會球的洗禮中快樂打球。感謝在大學時期一起練球吃消夜的校隊溫暖大家庭，一起練就強健體魄與規律作息。感謝室友 Apple、蔡董和 Quorra R 以及那些在宿舍睡不著的夜晚。感謝小璟、小管、居米、Leo 和琇穎來自前輩們的指導與支持，感謝陳承鴻學長、康笑愚學長和小狐學長分享來自博班學長們的經驗談，感謝口委老師們給我滿滿建議，也感謝一路下來系上老師同學和朋友們的鼓勵，希望自己不負這些期待，繼續茁壯。

在這兩年，也感謝自己努力朝當年期待的目標全力奔跑，過程總是無法盡如人意，卻相信踩坑踩滿後，學會的是更從容的面對下一個坑，學會對問題的剖析與解決，直面生命中每一個挑戰。在 2023 年與廈門地震局以及在 2024 年的歐洲地球科學年會，能有機會與世界各地的學者交流，算是完成生命中重要一個里程碑，奠定基礎後，迎接畢業後新的起點。乘著 AI 浪潮，期待自己在不斷進步的世界持續學習新知掌握技能。很高興能在地球科學領域與資訊工程之間搭起橋樑而努力，也希望此篇研究能在地球科學領域有所貢獻。致敬那些在為科學研究奮鬥的人們。謝謝翻開這本論文的你。

目次



	頁碼
口試委員審定書	i
摘要	ii
Abstract	iv
致謝	vii
目次	ix
圖次	xiii
表次	xvii
第一章 緒論	1
1.1 研究動機與目的	1
1.2 文獻回顧	8
1.2.1 應用深度學習的自動化波相到時偵測	8
1.2.2 SeisBlue 的發展與瓶頸 (2022)	8
1.2.3 傳統的震源機制解解析方法	11
1.2.4 應用深度學習的自動化震源機制解解析	12
1.3 論文章節架構	14
第二章 實驗——SeisPolar 震源機制解模組之方法	15
2.1 SeisPolar 架構	16
2.2 問題定義	17
2.3 資料蒐集	18
2.4 資料前處理	20




2.5	標籤	20
2.6	模型設計	21
2.7	模型訓練和驗證	21
2.8	P 波初動極性解析震源機制解—FPFIT	22
2.9	規模估算—AUTOMAG	24
2.10	第一階段測試—極性分類評估	25
2.11	第二階段測試—震源機制解之準確率評估	26
第三章	實驗一— SeisPolar 震源機制解模組之結果	29
3.1	2018 花蓮地震網 (有人工標籤)	30
3.2	2022 池上微震觀測網 (有人工標籤)	35
3.3	2023 寶來地震網 (無人工標籤)	40
第四章	實驗二—波相到時偵測模型在 PyTorch 框架下重設計與訓練	47
4.1	問題定義	47
4.2	資料蒐集	47
4.3	資料前處理	49
4.4	標籤	49
4.5	模型	50
4.6	模型訓練和驗證	53
4.7	測試結果—2020 和平地震網 (有人工標籤)	54
第五章	實驗一和實驗二之討論	57
5.1	解決波相到時提早預測的問題	57
5.2	解析生成對抗式網路 (GAN) 的損失值更新	59
5.3	分析 P 波初動極性模型的信心門檻以及類別權重	61



5.4	分析模型的學習過程	64
5.5	分析模型設計	67
第六章	實驗三—系統整合與永續	68
6.1	如何提高程式碼的維護性與擴展性	69
6.1.1	重構與管線化—管線導向式的程式碼風格 (POP)	69
6.2	如何減少組織中溝通與協作成本	71
6.2.1	程式碼版本控制—Git	71
6.2.2	模型版本控制—MLFlow	71
6.2.3	環境套件版本控制—Docker	72
6.3	如何提高使用者操作的便利性	74
6.3.1	自動化監控任務與問題回朔—Airflow	74
6.3.2	高效的資料儲存與檢視—關聯式資料庫 (SQL) 和階層式資料格式 (HDF5)	75
6.3.3	簡潔的使用者參數配制文件	77
6.3.4	互動式地圖網頁 (Web UI)	78
6.4	技術評估與取捨	80
第七章	結論	82
	參考文獻	85
	附錄 A—深度學習方法簡介	88
A.1	問題定義	91
A.2	模型設計	92
A.2.1	卷積神經網路 (Convolutional Neural Network, CNN)	92
A.2.2	變換器 (Transformer)	94


A.2.3	生成對抗網路 (Generative Adversarial Network, GAN)	98
A.3	模型超參數 (Hyperparameter)	100
A.3.1	批量 (Batch)	100
A.3.2	迭代次數 (Epoch)	100
A.3.3	損失函數 (Loss Function)	101
A.3.4	學習率 (Learning Rate)	101
A.3.5	優化器 (Optimizer)	101
A.3.6	調度器 (Learning Rate Scheduler)	102
A.4	模型性能評估與調整	103
A.4.1	欠擬合與過擬合 (Underfitting and Overfitting)	103
A.4.2	模型性能的評估指標	105
附錄 B	— 震源機制解之實驗結果補充	107
B.1	2018 花蓮地震網	107
B.2	2022 池上微震觀測網	108
B.3	2023 寶來地震網	109




圖次



1.1	IRIS 資料量年變化	2
1.2	三代 Seisblue 的演變 (2018-2024)	2
1.3	臨時地震站密集陣列 (台灣大學地震構造研究室)	3
1.4	密集小規模地震的關鍵作用	3
1.5	前人研究—第二代 Seisblue 的錯誤波相到時偵測案例	5
1.6	震源機制解之 P 波極性法	5
1.7	第三代 SeisBlue 的三大目標	7
1.8	第三代 Seisblue 架構	7
1.9	前人研究—第二代 Seisblue 軟體架構	9
1.10	前人研究—第二代 Seisblue 與其他深度學習模型比較	10
1.11	前人研究—第二代 Seisblue 應用案例	10
1.12	前人研究—震源機制解之全波形反演	12
1.13	前人研究—震源機制解之應用深度學習分類 P 波初動	13
2.1	SeisPolar 流程圖	15
2.2	SeisPolar 詳細流程圖	16
2.3	P 波初動極性方法和全波形反演的比較	17
2.4	2018 花蓮地震網和 2022 池上微震觀測網之資料分布	19
2.5	P 波初動極性分類之模型	21
2.6	三元分類的混淆矩陣	25
2.7	震源機制解的包覆度	27
2.8	震源機制解的測站包覆度門檻分析	27
2.9	測站覆蓋率門檻對應震源機制解之準確率	28
3.1	測站覆蓋率門檻對應震源機制解之準確率—2018 花蓮地震網測試資料	31
3.2	2018 花蓮地震網預測 P 波初動極性範例 1	32
3.3	2018 花蓮地震網預測 P 波初動極性範例 2	32
3.4	2018 花蓮地震網預測 P 波初動極性範例 3	33




3.5	2018 花蓮地震網預測 P 波初動極性範例 4	33
3.6	2018 花蓮地震網預測 P 波初動極性範例 5	34
3.7	2018 花蓮地震網預測 P 波初動極性範例 6	34
3.8	測站覆蓋率門檻對應震源機制解之準確率—2022 池上微震觀測網測 試資料	36
3.9	2022 池上微震觀測網的震源機制解範例	36
3.10	2022 池上微震觀測網 P 波初動極性範例 1	37
3.11	2022 池上微震觀測網 P 波初動極性範例 2	37
3.12	2022 池上微震觀測網 P 波初動極性範例 3	38
3.13	2022 池上微震觀測網 P 波初動極性範例 4	38
3.14	2022 池上微震觀測網 P 波初動極性範例 5	39
3.15	2022 池上微震觀測網 P 波初動極性範例 6	39
3.16	網頁地圖—2023 寶來地震網	41
3.17	網頁地圖—2023 寶來地震網 (放大)	41
3.18	網頁地圖—2023 寶來地震網 (P 軸之應力分布)	42
3.19	震源機制解的測站包覆度門檻分析—2023 寶來地震網	43
3.20	2023 寶來地震網的震源機制解範例	43
3.21	2023 寶來地震網 P 波初動極性範例 1	44
3.22	2023 寶來地震網 P 波初動極性範例 2	44
3.23	2023 寶來地震網 P 波初動極性範例 3	45
3.24	2023 寶來地震網 P 波初動極性範例 4	45
3.25	2023 寶來地震網 P 波初動極性範例 5	46
3.26	2023 寶來地震網 P 波初動極性範例 6	46
4.1	2017 和平地震網 (訓練資料) 之噪訊比。(a) P 波 (b) S 波	48
4.2	2020 和平地震網 (測試資料) 之噪訊比。(a) P 波 (b) S 波	48
4.3	波相到時偵測模型—Transformer + GAN	51
4.4	Transformer 模型架構	52
4.5	隨著訓練週期的損失值變化	53
4.6	波相到時在 0.5 秒內的誤差分布	54
4.7	波相到時偵測模型性能	55



4.8	波相到時偵測範例 1 和 2	55
4.9	波相到時偵測範例 3 和 4	56
4.10	波相到時偵測範例 5 和 6	56
5.1	新舊波相到時偵測模型-模型在 P 波和 S 波的正負 0.5 秒內的到時誤差分布比較	57
5.2	波相到時偵測模型-新舊模型性能比較	58
5.3	生成對抗式網路 (GAN) 損失值更新	60
5.4	精確率與召回率的相對關係	61
5.5	不同信心門檻下的極性模型性能與震源機制解準確率	62
5.6	P 波初動極性模型-類別權重實驗	63
5.7	波相到時偵測模型的訓練過程	65
5.8	P 波初動極性分類模型的訓練過程	65
5.9	模型隨著訓練週期模型的學習傾向	66
6.1	第三代 Seisblue 架構	68
6.2	非功能軟體的用途	69
6.3	管線導向式 (POP) 的重構	70
6.4	減少組織中溝通與協作成本	73
6.5	自動化監控任務與問題回朔—Airflow	74
6.6	關聯式資料庫—MySQL	75
6.7	波形資料儲存文件—階層資料格式 (HDF5)	76
6.8	使用者參數配制文件—YAML	77
6.9	互動式地圖網頁 (Web UI) —Bokeh	79
A.1	深度學習如何優化模型參數	88
A.2	深度學習和機器學習的比較	89
A.3	深度學習專案流程	90
A.4	分類任務和物件切割任務的比較	91
A.5	卷積層 (Convolutional Layers)	93
A.6	池化層 (Pooling Layer)	94
A.7	殘差連接 (Resblock)	94

A.8 長短期記憶網路 (LSTM)	96
A.9 雙向長短期記憶網路 (BiLSTM)	96
A.10 自注意力機制 (Self-attention) 的圖像化解釋	97
A.11 自注意力機制 (Self-attention) 的計算	97
A.12 生成對抗網路 (GAN)	98
A.13 欠擬合與過擬合 (Underfitting and Overfitting)	104
A.14 模型訓練流程與決策	104
A.15 模型性能指標	105
B.16 2018 花蓮地震網測試資料的預測 P 波初動極性的數量分析	107
B.17 2018 花蓮地震網測試資料的混淆矩陣	107
B.18 2022 池上微震觀測網測試資料的預測 P 波初動極性的數量分析	108
B.19 2022 池上微震觀測網測試資料的混淆矩陣	108
B.20 2023 寶來地震網的 P 波和 S 波訊噪比	109
B.21 2023 寶來地震網的極性數量分析	109



表次



2.1	P 波初動極性分類模型的資料詳細資訊	18
2.2	P 波初動極性分類模型的超參數設定	22
3.1	2018 花蓮地震網測試資料的模型性能結果 (%)	30
3.2	2022 池上微震觀測網測試資料的模型性能結果 (%)	35
3.3	P 波初動極性分類模型的資料 (無人工標籤) 詳細資訊	40
4.1	波相到時偵測模型的資料詳細資訊	48
4.2	波相到時偵測模型的主要超參數	50
4.3	2020 和平地震網的波相到時偵測結果 (%)	54
5.1	分析模型設計	67
6.1	技術評估與取捨	81



第一章 緒論



1.1 研究動機與目的

隨著地震儀的發展與密集地震網的趨勢，全球面臨地震資料爆炸性增長（圖 1.1）。尤其在地震頻繁的台灣，每年記錄到的地震就達數千至一萬多次。人力缺乏之下開始出現各種自動化的方法來提升效率，但不論是傳統的 STA / LTA 長短時窗的自動化波相到時偵測方法（Allen, 1978），或是自動化震源機制解的部分，如中研院開發的 AutoBATS 用全波形反演的震源機制解解析，都對訊噪比較低的小規模地震解析能力有限（Jian et al., 2018）。近年來人工智慧蓬勃發展，而地震資料多的特性正好符合人工智慧方法的條件，深度學習漸漸被引入地震觀測領域，例如著名的 EQTransformer 全球型模型（Mousavi et al., 2020）和 PhaseNet 的波相到時偵測模型（Zhu and Beroza, 2019），但對於地體構造特殊的台灣，訓練本土模型才能真正提升地震觀測的效率與有效性。

因此，台灣大學構造地震研究室（SGYLAB）在 2018 年著手研究第一代 SeisBlue AI 地震觀測平台（黃俊銘等，2020），該研究參考 PhaseNet（Zhu and Beroza, 2019），用 U-Net 做深度學習的單分量自動化波相到時偵測，在 2022 年研發出第二代系統（張立衡等，2022），完成三分量自動化波相到時偵測並整合定位功能（圖 1.2），旨在用人工智慧方法逐漸取代耗時利例行性的人工作業，開發一套自動化地震資料處理系統，以深度學習模型做為系統核心，輔助地震觀測流程，高效建立完整可靠的地震目錄，尤其解決台灣密集地震網資料膨脹的情況（圖 1.3）。不但能夠及時掌握孕震構造資訊，還能偵測到大量密集的小規模地震，對於後續如高解析度的層析成像等研究都非常關鍵（圖 1.4）（第二代系統詳情請見章節 1.2.2）。

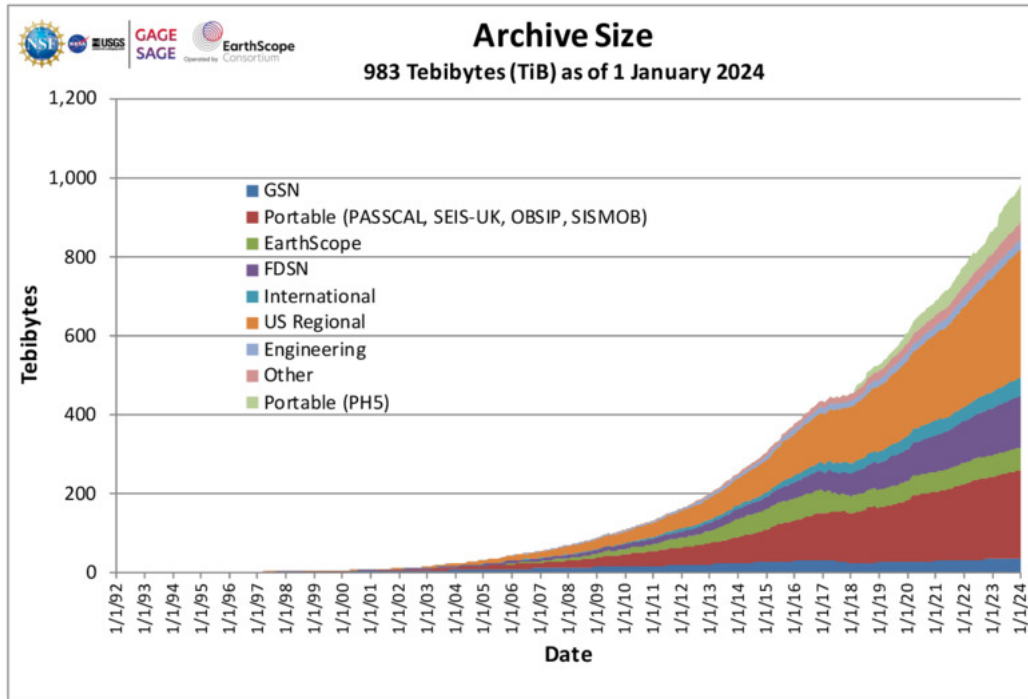


圖 1.1: IRIS 資料管理中心 (IRIS-DMC) 的地震資料量快速膨脹，至 2024 年已達 983 TiB (Center, 2024)。

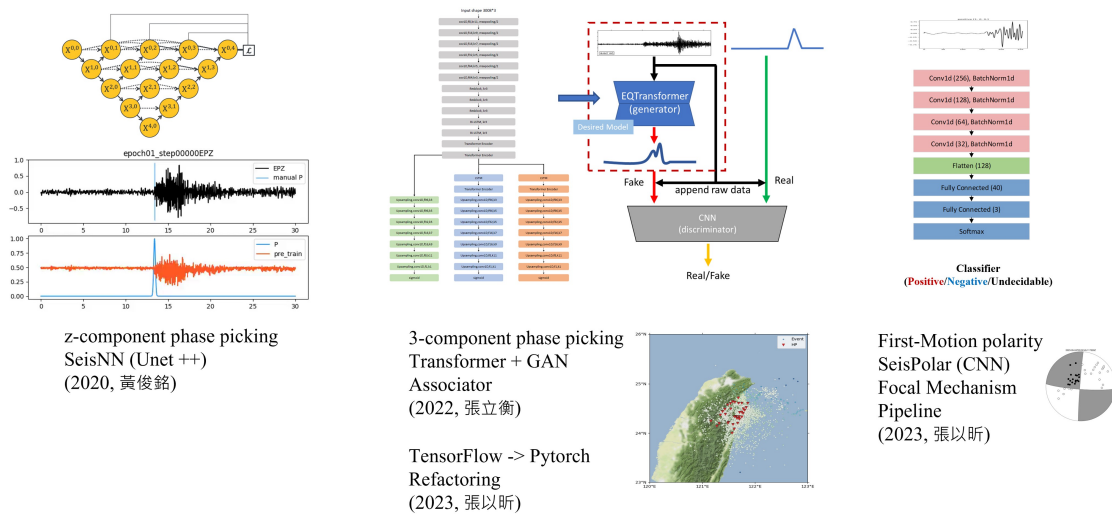


圖 1.2: 三代 Seisblue 的演變 (2018-2024)。第一代完成單分量自動波相到時偵測，第二代完成三分量自動波相到時偵測，整合定位。本研究的第三代系統將改良三分量自動波相到時偵測，並加入自動分辨極性，整合震源機制解解析 (本圖修改自黃俊銘 (2020)、張立衡 (2022))。

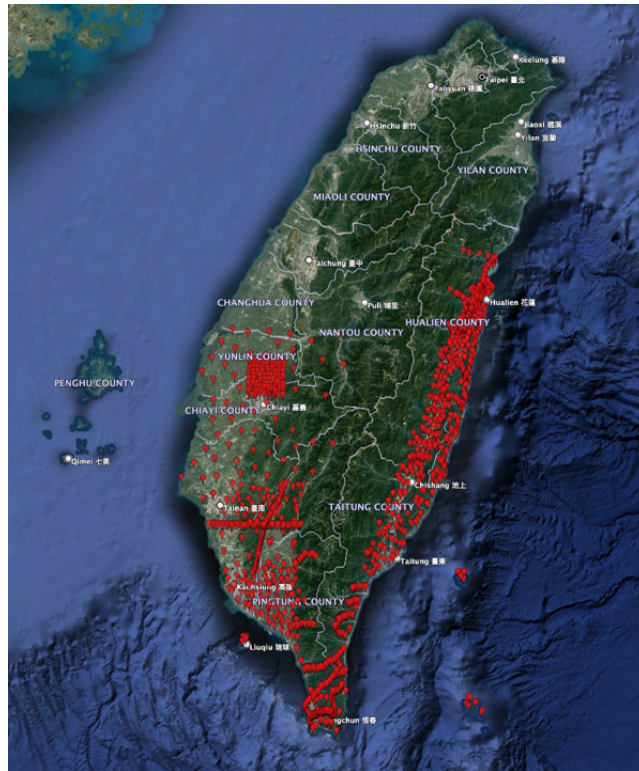


圖 1.3: 臨時地震站密集陣列，由台灣大學地震構造研究室 (SGYLAB) 在 2013 年至 2023 年間累積收集 19.16 TB 原始波形資料 (本圖引用自 SGYLAB)。

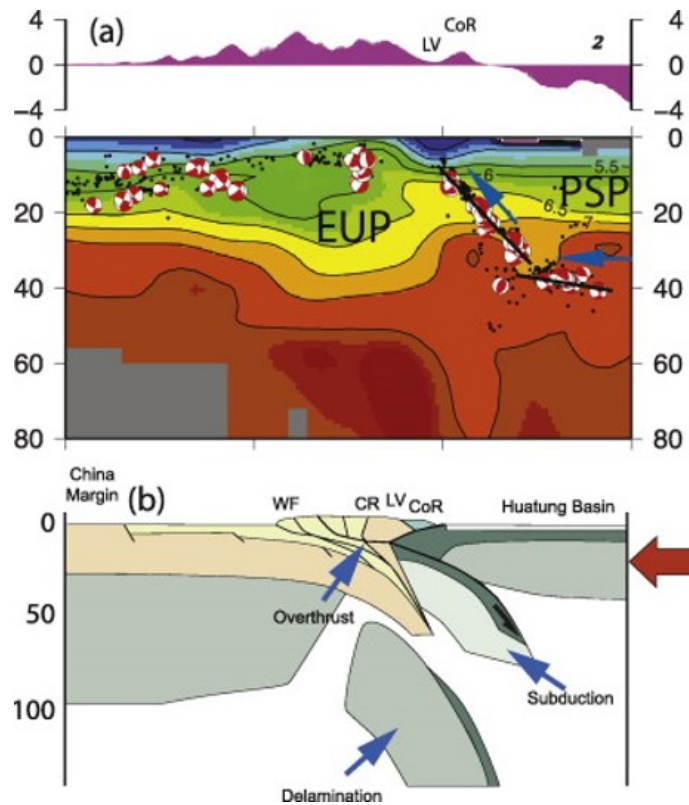




圖 1.4: 密集小規模地震的關鍵作用。目前本團隊專注在區域型密集地震網，測站間距約 5 至 10 公里，可捉回大量密集小規模地震，以此得到高解析度的速度層析成像 (Kuo-Chen et al., 2019)。



由於捕捉小規模地震的任務必須克服訊噪比低的挑戰，在多個地震測網的應用後，人工檢視的回饋指出模型仍有進步空間（圖 1.5），有諸多策略可以進一步提升波相到時偵測的結果，例如利用重定位的過程做物理性篩選，或在關聯相位時實驗多個 P-S 到時差等等，但終究存在局限性，針對模型調整才是治根的方法，不論是將人工檢視後的波相到時偵測進一步更新模型，或是模型專業化使其專注在各專屬區域的資料集，為了長期的系統運作，改進模型並保持模型能持續更新是迫切的需求，該需求卻需要仰賴高靈活的開發環境。回顧第二代系統的波相到時偵測模型，由於其修改自 Mousavi et al. (2020) 的 EQTransformer 模型，延續使用早期的深度學習框架 TensorFlow 1，TensorFlow 1 深度學習框架使模型需要先編譯，難以除錯，可讀性低且僵化等等特性，在開發與調整上有諸多不便。

因此為了解決系統僵化難以提升性能的問題，迫切需要重整系統，打造敏捷式開發環境。本研究將深度學習框架從 TensorFlow 1 轉換成在學術界更受歡迎的 PyTorch，擁有靈活且彈性直觀的物件導向式的程式碼風格，更有利於模型開發，也在未來更具潛力。將模型重設計與重訓練，以及整體系統的對應調整，提升波相到時偵測模型的開發環境與性能，此為本研究致力解決的第一個需求。

此外，在地震觀測中除了波相到時偵測外，同樣耗時的例行性任務還包含地震波初動極性的辨識，即辨別 P 波上動或下動。震源機制解是震源的下投影，震源機制解能顯示出地震斷層面上的運動方向和斷層類型，有助於了解地底下的應力方向。而 P 波初動極性是解析小規模地震之震源機制解不可或缺的要素之一（其他震源機制解方法請見章節 1.2.3）。以往對於密集的餘震分布來說，仰賴耗時的人工辨識地震波初動極性，並且穩定的震源機制解還需考慮到測站在方位角和距離上的包覆度，因此密集的餘震分布通常在定位後，通常只會選擇幾個有測站包覆度高且規模較大的地震做震源機制解解析，得到主要代表的斷層面資訊（例如圖 1.6）。



Stn5
#69 20-0249-05L.S202104
SF21誤判




圖 1.5: 第二代 SeisBlue 的錯誤波相到時偵測案例，顯示出波相到時偵測模型的進步空間，仰賴模型的重訓練，增加訓練資料或將人工檢驗結果回饋給模型（本圖引用孫維芳的人工品管結果）。

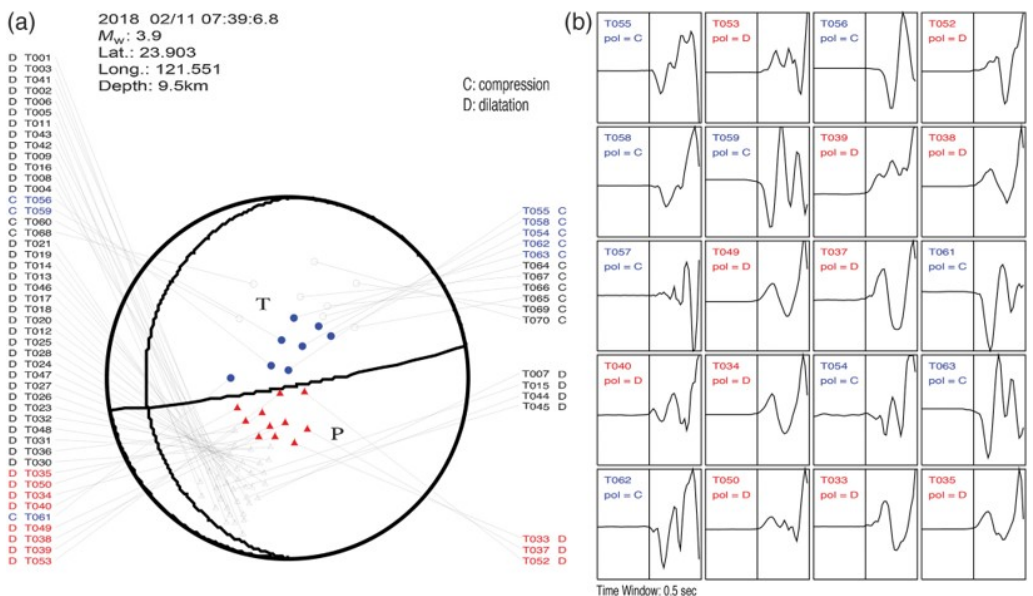



圖 1.6: 震源機制解之 P 波極性法，以 2018 花蓮的密集地震網為例，對於小規模地震觀測，傳統上仰賴人工檢視辨識極性 (Kuo-Chen et al., 2019)。



為了在高解析度定位後，能同樣高效獲得高解析度的震源機制解解析，引入深度學習方法協助自動化辨識初動極性，有了統一判斷標準，在提高效能的同時，解決人工誤判的可能性，達到效能與精確率的提升。因此，本研究開發自動化震源機制解解析的深度學習模組，並加入規模計算模組，獲得完整地震目錄資訊，高效計算精確的震源機制解斷層面和滑動方向，協助對孕震構造的高解析度分析，此為本研究致力解決的第二個需求。

第三個需求則是如何在日漸龐大的系統中，整合功能與非功能需求。實現端到端訓練的平台的同时，還要能夠為了達到系統長期維護與傳承，引入敏捷式開發，強化團隊溝通與協作能力，降低未來開發成本，為未來的變化作準備。

總體而言，本研究旨在第三代系統開發，承接長達七年的 SeisBlue AI 地震觀測專案，解決上述的三個需求。因此，本研究主軸將對應擴展、改善和整合三大目標（圖 1.7），解決第二代 SeisBlue 的瓶頸，增加深度學習自動化震源機制解，持續推動系統運作、維護、創新與整合，提升系統功能與非功能的需求，延續專案的生命週期（圖 1.8）。

對於地震頻繁的台灣地區，SeisBlue 增強地震發生後即時評估的效率，在捕捉大量餘震資訊方面，補足其他自動化方法缺少的小規模地震事件。第三代 SeisBlue 系統提供高時空解析度的震源機制解析結果，配合原有的近即時地震定位，快速掌握初步的孕震構造資訊。除了新增深度學習的震源機制解的功能之外，第三代系統還希望加強波相到時偵測的能力，並加強對於系統重構與整合。本研究的系統不僅提供震後的即時評估，也減少耗時的人工檢視，配合人工品管後，產出的完整地震目錄更對於後續研究如：建構速度模型、解釋地下構造、協助震源分析、災難預防等提供關鍵支持。同時，也能進一步釋放人力資源，使研究人員能夠專注於有價值的研究和分析。

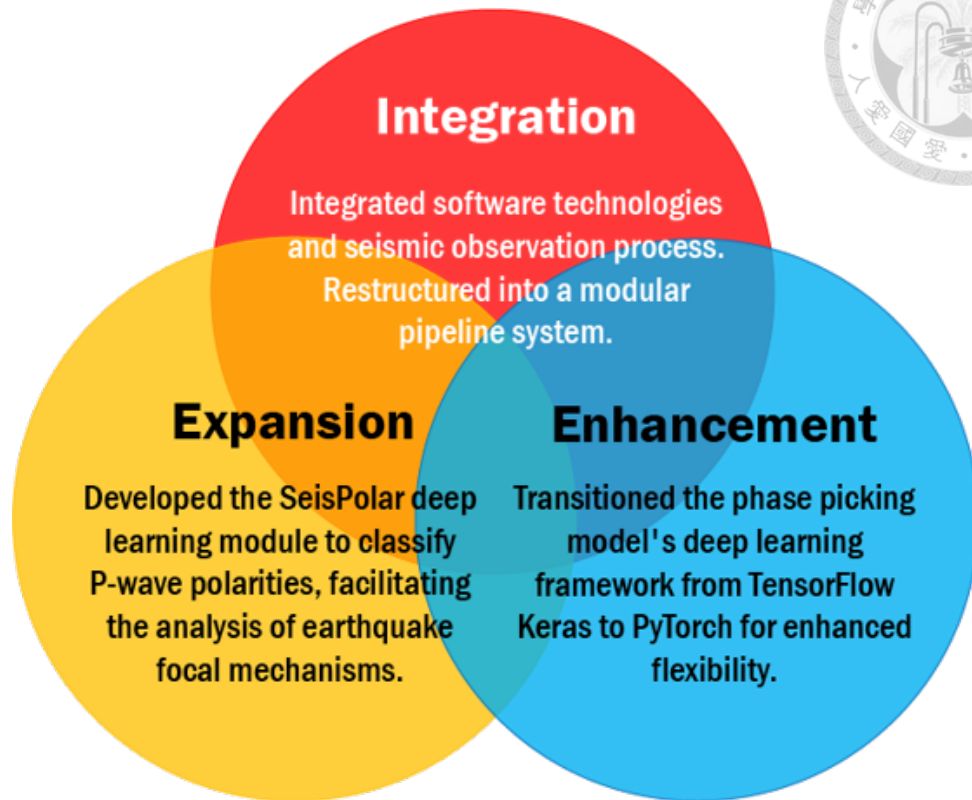


圖 1.7: 第三代 SeisBlue 的三大目標—系統擴張、強化和整合。

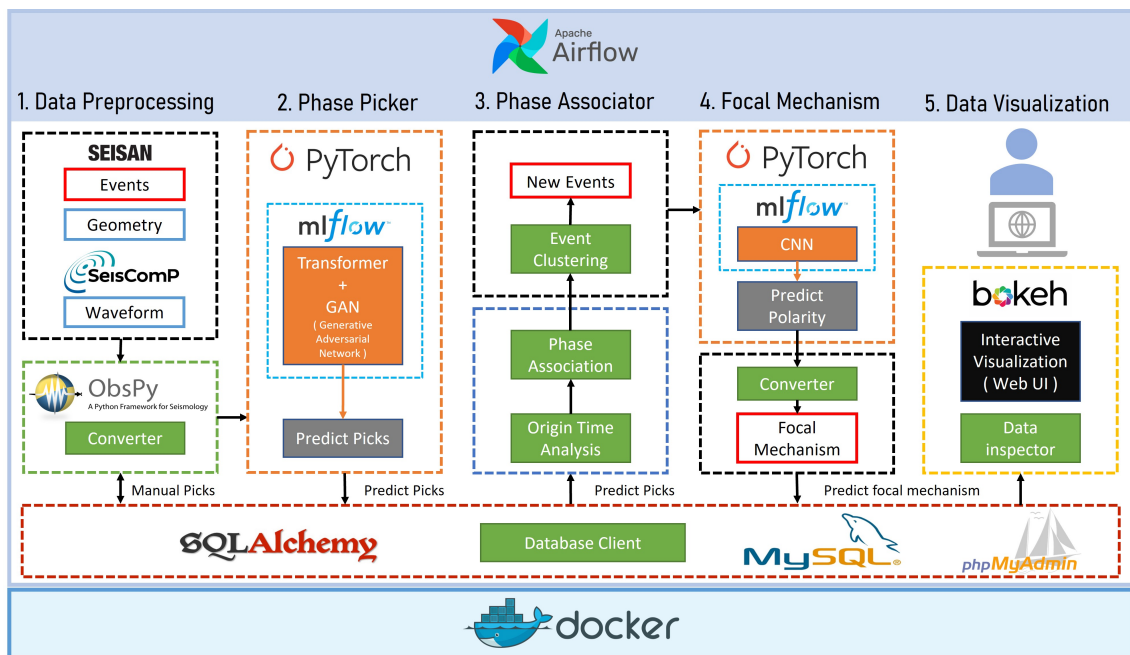


圖 1.8: 第三代 Seisblue 架構



1.2 文獻回顧

1.2.1 應用深度學習的自動化波相到時偵測

在地震波相到時偵測中著名的深度學習模型 EQTransformer (Mousavi et al., 2020), 屬於全球型的波相到時偵測模型, 模型的結構包括一個編碼器和三個解碼器, 分別用於檢測地震訊號、P 波相位和 S 波相位。資料使用了 STanford EArthquake Dataset (STEAD), 標註全球範圍內地震和非地震信號的大規模資料集, 紀錄大約 45 萬次地震事件, 這些事件的震級大多數規模小於 2.5, 並且震央距在 100 公里內。相比以前的深度學習波相到時偵測模型和傳統的波相到時偵測方法, EQTransformer 模型在準確度上均有顯著提高。此研究特點是強調模型的全球通用性, 但對於像台灣這種地體構造複雜的區域, 該全球型模型預測結果不佳, 因此台灣大學構造地震研究室 (SGYLAB) 希望藉由台灣的密集地震網資料, 開發本土模型, 建立 AI 自動化地震觀測系統 (SeisBlue)。

1.2.2 SeisBlue 的發展與瓶頸 (2022)

自 2018 年開始, 第一代系統由台大地震構造研究室 (SGYLAB) 的研究生黃俊銘開發, 該研究參考 PhaseNet (Zhu and Beroza, 2019), 引入 U-Net 深度學習模型發展單分量的自動波相到時偵測 (黃俊銘等, 2020)。在 2020 年由研究生張立衡承接並與黃俊銘協作完成三分量的自動波相到時偵測 (張立衡等, 2022), 其以 Mousavi et al. (2020) 的 Earthquake transformer 為基礎, 主要改良的部分是將第三個解碼器從地震信號改為噪訊訊號, 並且在解碼器後接上一個辨別器, 形生成對抗模型 (GAN) 的架構, 加速波相到時偵測模型的訓練過程。後續整合 PhasePapy 地震關聯程式 (Chang et al., 2019; Chen and Holland, 2016), 並針對部分步驟進行優化, 完成從地震連續資料處理、波相到時偵測、波相關聯與地震定

位、資料儲存，實現第二代 SeisBlue 地震觀測平台 (Huang et al., 2023) (圖 1.9)。針對小規模地震的地震觀測，與其他深度學習模型比較中顯示第二代 SeisBlue 的波相到時偵測模型能有效用在捉回小規模地震 (圖 1.10)。在 2022 年開始陸續在多個測網應用，測網包含本團隊所部署的區域型密集地震網、氣象署的寬頻地震網、台灣陣列地震網 (Formosa Array) 等等。第二代的系統目前已應用在多個案例，如 2024 年孫維芳等人發表，在 2022 年 9 月 18 日發生規模 6.9 的花蓮池上地震影響了台灣東部的縱谷南半部，造成嚴重破壞。利用 SeisBlue 平台，從 2022 年 9 月到 10 月的地震序列中，檢測出超過 14,000 次餘震和 866 個震源機制 (圖 1.11)，快速精確地分析了地震和餘震序列，觀測高時空解析度的餘震活動，揭示了中央山脈斷層和縱谷斷層以及其他未被觀察到的地質結構 (Sun et al., 2024)。整體而言，第二代 SeisBlue 已能在微震地震觀測中有很不錯的表現，但尚缺乏自動化震源機制解，對於深度學習波相到時偵測而言也需要進一步的性能提升。

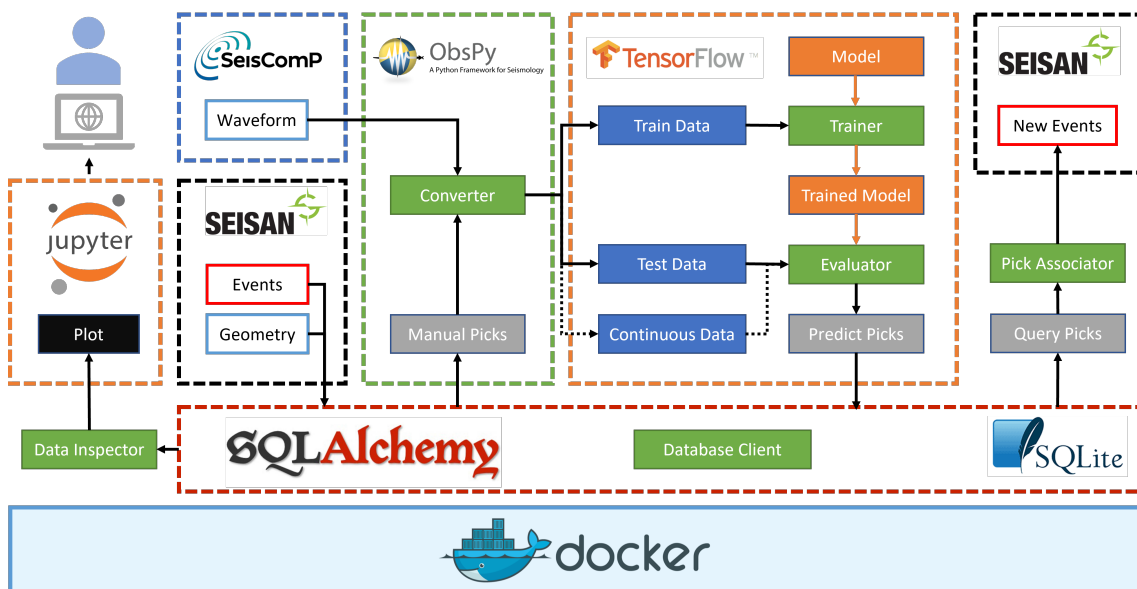


圖 1.9: 第二代 Seisblue 軟體架構 (張立衡等, 2022)。

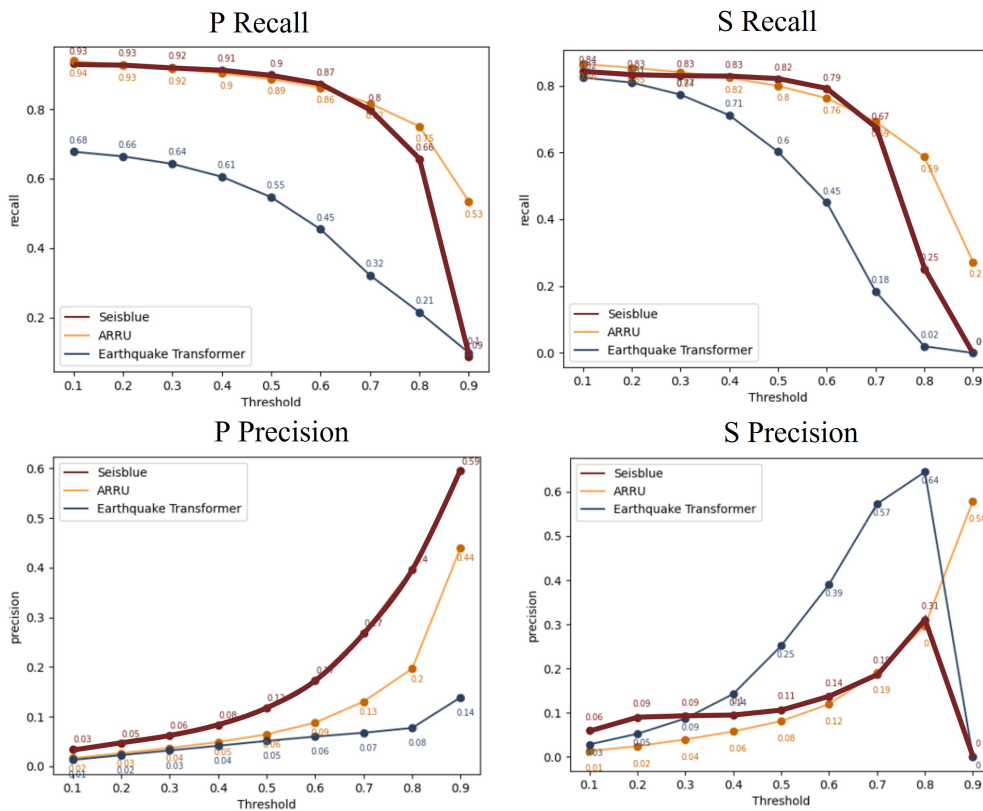



圖 1.10: 第二代 SeisBlue 與其他深度學習模型在 P 波和 S 波的精確率和召回率比較 (張立衡等, 2022), 使用連續波形資料做為測試。紅線為本團隊在 2022 年的第二代波相到時偵測模型, 橘線為 Liao et al. (2021) 的 ARRU 波相到時偵測模型, 而藍線為 Mousavi et al. (2020) 的 Earthquake transformer 波相到時偵測模型。

Usecase: 2022 M_w 6.9 Chihshang earthquake sequence

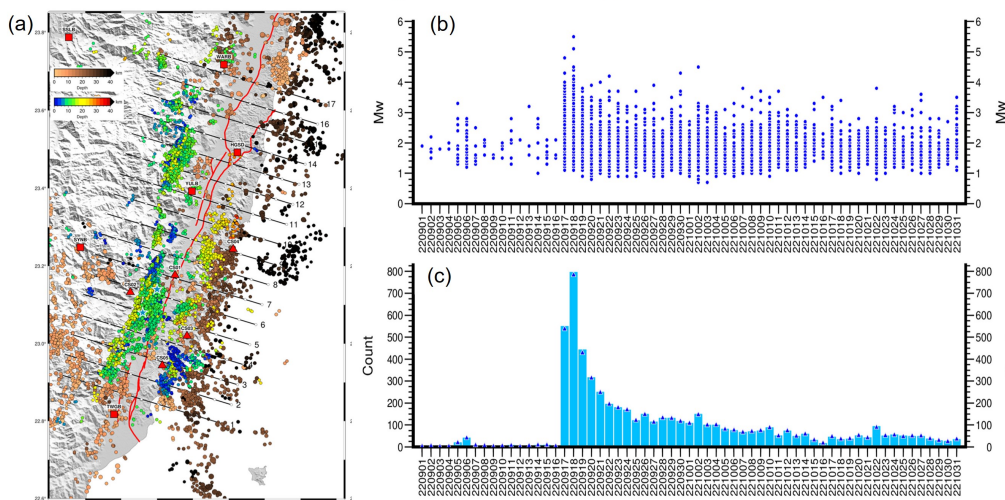


圖 1.11: 第二代 Seisblue 應用案例-2022 M_w 6.9 池上地震。(a) 經人工檢驗與重定位後的地震活動分布。咖啡色系列圓圈為氣象署 2001 至 2020 年規模大於 3 的地震, 彩虹色系列圓圈為第二代 Seisblue 深度學習波相到時偵測後定位出的地震。(b) 規模分布, 最小規模可達 1 M_w (c) 數量分布 (Sun et al., 2024)。



1.2.3 傳統的震源機制解析方法

在震源機制解的解析領域中有兩種主要方法，第一種是依賴 P 波初動解 (Reid, 1910)，簡單卻相當有效，條件是需要足夠的測站數量，並達到良好的測站方位角包覆度和距離包覆度，才能獲得穩定解，除此之外，P 波初動仰賴耗時的人力辨識與高精確度要求。後來，隨著寬頻地震儀的普及以及波形反演技術的提升，開始出現利用波形反演的方式來解析震源機制解，能應對許多測站數量不足或分布不均的情況，例如外海地震事件。最著名的是在 1981 年 Dziewonski 團隊開始開發的全球 CMT (Centroid Moment Tensor) 計畫 (Dziewonski et al., 1981)，以及在近年來改良 CMT 算法於分布全球的地震測站記錄的長週期地震波形 (Ekström et al., 2012)，對重大地震事件給出了全面的分析結果。但如上述所述，波形反演方法仰賴高訊噪比的資料，通常只適用在規模大於等於 4.5 的大地震，對於造訊比較低的測站或小規模地震來說無法解析。

在台灣的震源機制解解析發展，例如中央氣象署在 2020 年更新的自動化震源機制解算 (甘志文等, 2015)，其中包含自動 P 波初動震源機制解算 (AFM)、自動中央地震矩張量震源機制解算 (ACMT) 與截切擬合震源機制解算 (gCAP)。一般而言，自動 P 波初動震源機制的效率最高，gCAP 則能彌補 P 波初動解算時受測站分布不佳的限制，能成功解算地震網外或初動資料不足的地震震源機制，而 CMT 方法就是計算地震矩張量，其中波形反演技術就是將各測站的觀測波形透過格林函數的空間導數與地震矩張量直接線性關聯，用此波形反演的方法來補足大地震的解算精確度。而中研院在 2018 年發布的 AutoBATS 自動化震源機制解算 (Jian et al., 2018)，屬於波形反演的其中一種方式，實時自動決定區域矩張量和其重心深度。雖能達到即時解算震源機制解，但可解算的最小規模地震矩規模約為 3.5 (圖 1.12)。

總體而言，兩種解析震源機制解的方法存在互補性，規模大於 4 以上的地震

適用波形反演；對於規模小於 4 以下的地震適用 P 波初動解，需仰賴良好的測站分布與耗時且精確的人工辨識。針對本研究所專注的小規模地震觀測（規模大於 1），P 波初動解仰賴高精確率的 P 波極性，但傳統自動化方法對小規模地震的能力有限，因此仍仰賴耗時繁複的人工檢視波形做辨識極性。

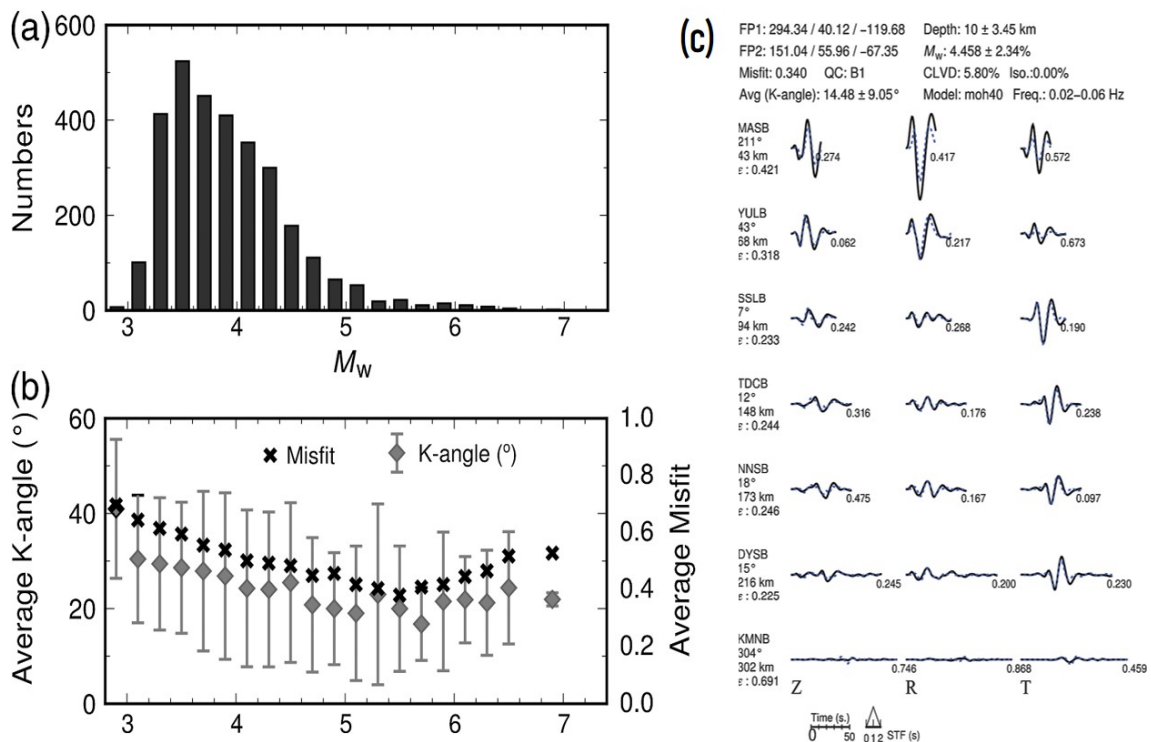


圖 1.12: 全波形反演—中研院 AutoBATS (a) 規模與可解析地震的數量的直方圖，(b) 規模與 kagan 角度的關係 (c) 波型反演範例。由 (a) 可觀察到對該全波形反演方法對規模小於 3.5 的地震解析數量下降，對小規模地震解析存在侷限性 (本圖修改自 Jian et al. (2018))。

1.2.4 應用深度學習的自動化震源機制解解析

本研究為了延續 SeisBlue 系統，其著重在捕捉小規模地震，補足傳統自動化波相到時偵測的缺陷，獲得高解析度的餘震活動，因此在解析震源機制解的部分從適用解析小規模地震的方法開始著手，即開發 P 波初動解的深度學習應用。

對於 P 波初動解方法的前人研究中，Uchide (2020) 利用卷積神經網路自動化分類 P 波初動的上下動 (圖 1.13)，雖然該方法有效提高辨識率，但對於訊噪比

低的小規模地震預測效果仍顯不足。此外，該研究在實驗中提到，為了讓模型後續可對應波相到時的誤差，在訓練集會隨機位移到時，但實驗結果發現模型在較窄的 P 波到時位移能可能有較佳性能，推測可能是測試集的波相到時的準確度所影響，若測試集的波相到時經人工檢驗後極為準確，那訓練集做額外的到時位移反而會達到反效果，需對應訓練與測試集兩者的挑波到時特性作對應參數設定。此外，該研究指出 P 波初動極性的信心門檻對震源機制解的質量和數量有顯著影響。在追求高品質的極性時，需考量到極性數量太少也無法約束產出穩定可靠的震源機制解，Uchide 經實驗後在該研究設定測試集的信心門檻為 0.7，約 40.9% 的極性無通過門檻被篩選為不可辨識。

為了更有效解決信心門檻的設定問題，本研究嘗試直接在模型輸出加入「不可辨識」的類別，Zhao et al. (2023) 也認為加入第三個「不可辨識」類別，有助於模型更有效學習不明顯的極性特徵，解決 P 波初動解仰賴高精確率的限制，提升在小規模地震獲得精確地震源機制解析的可能性。

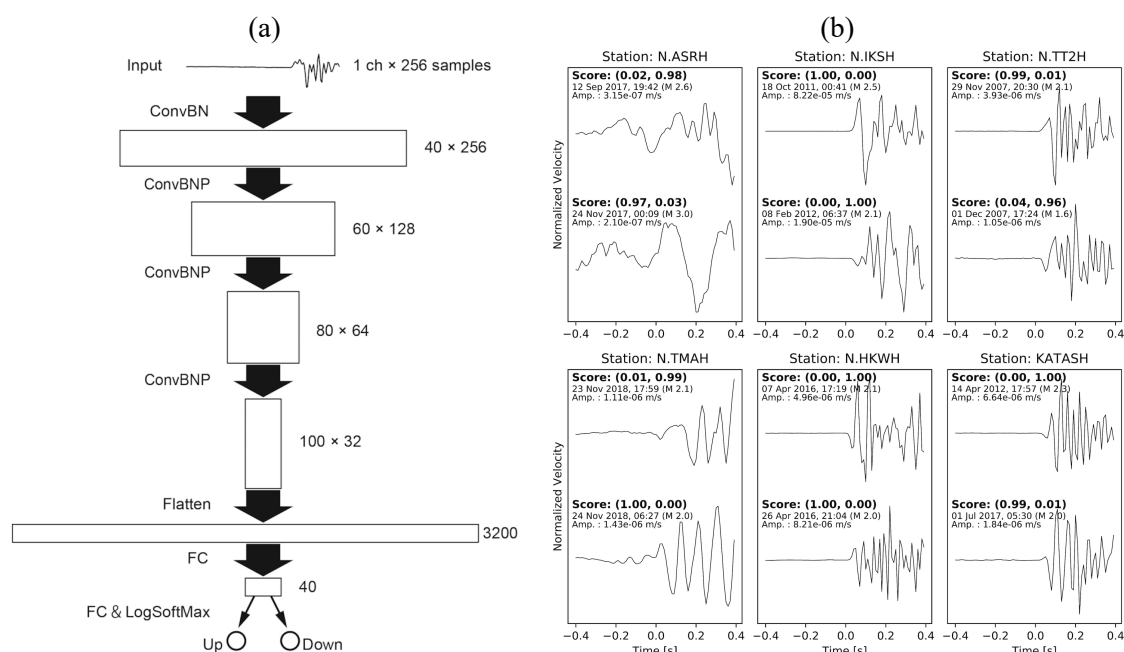



圖 1.13: 應用深度學習做 P 波初動解分類。(a) 該研究使用的卷積神經網路模型。(b) 預測極性的結果 (Uchide, 2020)

1.3 論文章節架構



基於第二代舊系統的問題，本研究將以三個實驗作為研究主軸。本論文主要有八個章節。第一章為緒論，介紹利用深度學習技術在地震觀測中的應用及其優勢，解決舊系統的三個需求所對應的實驗。第二章為實驗一 SeisPolar 震源機制解的深度學習模組，描述實驗方法，包括資料蒐集、資料前處理、標籤生成、模型設計與模型訓練。第三章為實驗一的結果，展示 SeisPolar 模組在不同地震網的實驗結果。第四章為波相到時偵測模型的實驗方法與結果。第五章為實驗一和實驗二的討論。第六章為系統整合與永續，介紹系統功能與非功能的需求，討論軟體工程對於延續系統生命週期的重要性。第七章為結論，總結研究成果，討論貢獻與未來發展。附錄為深度學習方法簡介，涵蓋深度學習的基礎知識、模型設計及其超參數設定、性能評估與調整策略。

第二章 實驗一—SeisPolar 震源機制

解模組之方法



本研究作為第三代 SeisBlue 系統開發者，第三代 SeisBlue 系統的地震觀測流程將波相到時偵測和地震定位，往後延伸到震源機制解解析和規模估算 (SeisPolar)，本章節將說明震源機制解的自動化解析流程及深度學習開發流程，包含問題定義、資料蒐集與資料前處理、模型設計、模型訓練與驗證 (設定模型超參數)、模型性能評估與調整、未知資料預測、整合與部署應用，詳細的深度學習方法請見附錄 A。

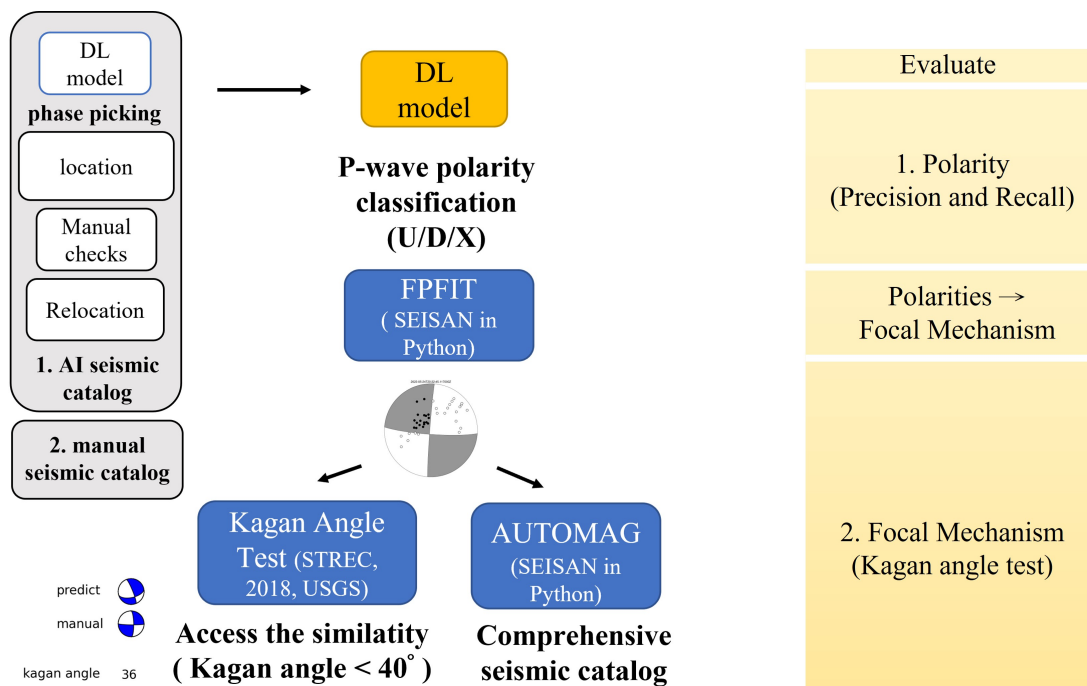


圖 2.1: SeisPolar 流程圖。經過自動挑波定位的地震目錄，以及後續的重定位和人工檢驗後，將進入 SeisPolar 系統，通過 P 波極性分類模型進行分類。分類後的極性資料經過信心門檻篩選，再利用 FPFIT 方法解析為震源機制解。此自動化震源機制解流程整合了自動化規模計算，並更新地震目錄。對於已標註答案的資料集，將進行第一階段的極性評估，並使用 Kagan 測試進行第二階段的震源機制解評估。



2.1 SeisPolar 架構

SeisPolar 核心是訓練深度學習分類器預測 P 波初動極性標籤後，使用傳統方法將極性轉換成震源機制解，並整合地震規模估算，將此流程獲得的震源機制解和地震規模的資訊，更新回資料庫的地震目錄。對於已知答案的測試資料，為了比較預測值與實際值，經以下兩階段評估：首先是針對模型輸出的極性做第一階段模型性能評估，為了實際評估模型對最後產物即震源機制解的性能，預測極性會經由信心門檻篩選並解析成震源機制解後，使用 Kagan 測試 (Kagan, 1991) 提出的最小旋轉角度，量化兩個震源機制解的角度差異，以此來針對震源機制解作第二階段評估 (圖 2.1、圖2.2)。上述的方法會在後續章節進一步說明。

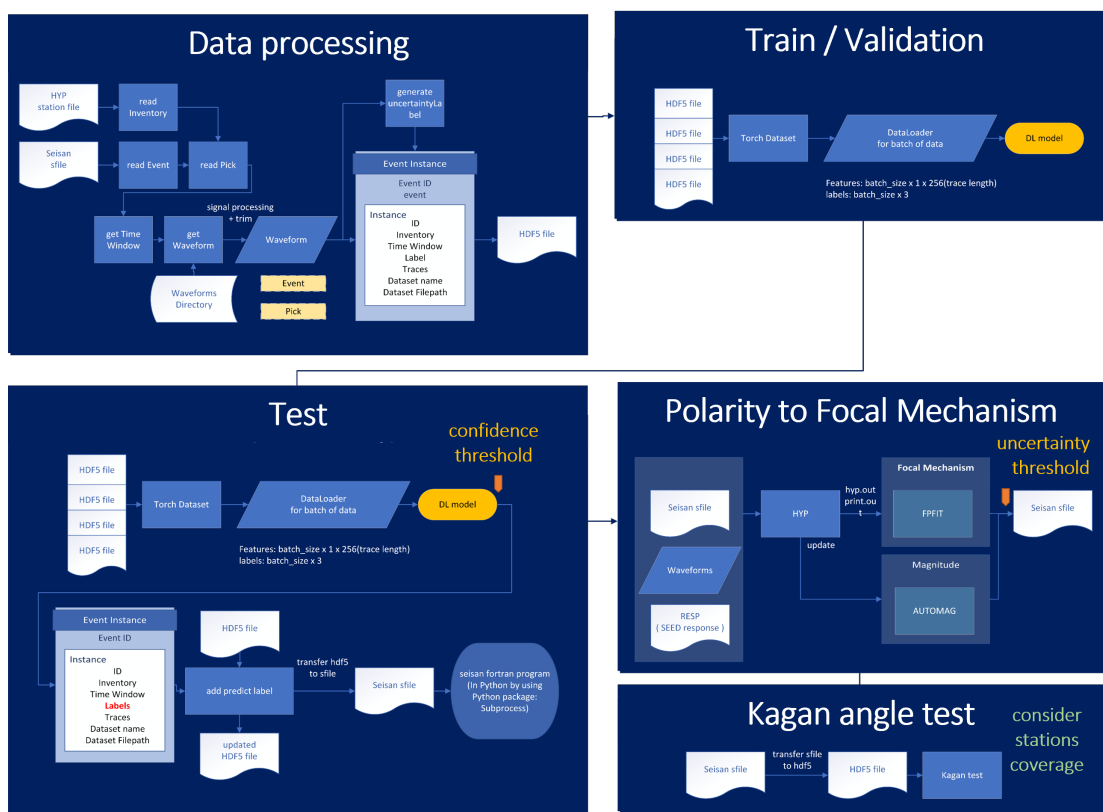


圖 2.2: SeisPolar 詳細流程圖。可分為五大步驟: 資料前處理、模型訓練、模型測試和預測、震源機制解解析和地震規模估算、以及結果輸出與更新資料庫。



2.2 問題定義

在震源機制解解析領域存在兩大類方法—全波形反演與 P 波初動極性分類，如同文獻回顧提到，為了應對區域性密集地震網所捕獲的大量小規模地震，本研究使用 P 波初動極性分類的深度學習模型，可解析規模 4 以下的小規模地震，補足傳統自動化方法的缺陷（圖 2.3）。

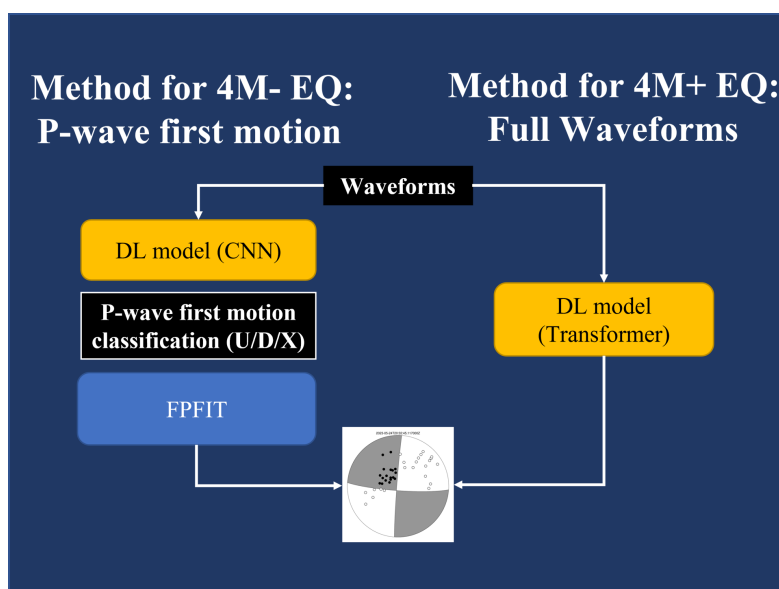


圖 2.3: 在解析震源機制解的兩種方法中，本研究選擇用 P 波初動極性方法的概念訓練深度學習模型，適用於密集地震網所抓回的大量小規模地震資訊。

因此，定義深度學習模型的目標是分類 P 波初動極性，仿人類辨識極性的過程，輸入含有 P 波到時的垂直方向波形資料，使用卷積神經網路萃取局部資訊，輸出 P 波初動極性的分類結果。

此外，本研究在二元的極性分類改為三元分類，因考量到極性的預測的信心門檻對不同資料集來說是高變動因素（Uchide, 2020），並且此模型對於 P 波極性的精確度要求較全波形反演為高，為了有效解決信心門檻的設定問題和高精確率需求，本研究嘗試在模型輸出的分類結果，加入「不可辨識」的類別來應對上述挑戰。Ming Zhao 等人在 2023 發表的研究也認為加入第三個「不可辨識」類別（Zhao et al., 2023），有助於模型更有效學習不明顯的極性特徵，解決 P 波初動解



仰賴高精確率的限制，提升在小規模地震獲得精確地震源機制解析的可能性。即高精確率的要求下，模型能更好的模擬人類在「不可辨識」的標準，更好適應資料在不明確的部分。

2.3 資料蒐集

本研究使用 2018 花蓮地震網與 2022 池上微震觀測網的資料來訓練極性分類的深度學習模型（詳情見表 2.1），圖 2.4 顯示地震事件經測站數量篩選後的資料分析。兩個測網分別使用短週期地震儀和寬頻地震儀，有助於模型掌握不同儀器對應的波形。需特別注意，若使用如 SmartSolo 這種適用震測的短週期地震儀，因硬體設計的不同，在收到的波形資料振幅會與一般的地震儀正負相反，必須在進入模型前先根據儀器種類來判斷是否需要翻轉，以確保所有訓練資料集人工標記規則一致，波形向上即為上動，向下即為下動。此兩筆地震波形資料來源於台灣大學地震構造研究室與中研院地球所，並由管卓康、孫維芳等前輩做人工標記。本研究將 2018 花蓮地震網與 2022 池上微震觀測網資料集分別切割 75%、10% 和 15% 作為訓練、驗證和測試集。

表 2.1: P 波初動極性分類模型的資料詳細資訊

	2018 花蓮地震網	2022 池上微震觀測網
儀器類型	Tesan 單分量短週期地震儀	寬頻地震儀
測站數量	70	14 (5 CSN + 9 BATS)
觀測起始時間	2018/2/8 - 2018/2/19	2022/9/1 - 2022/10/31
觀測時長 (天)	12	60
篩選後的地震事件數量	581	871
P 波數量	22,766	10,213
S 波數量	891	8,556
極性數量 (U/D/X)	(12185, 5494, 4998)	(4105, 4117, 1984)
規模 (Mw)	2 - 4.5	2 - 5
最大深度 (公里)	15	30
地震波相到時偵測	人工	AI + 人工檢視品管

備註: 已篩選測站數量足夠之地震事件

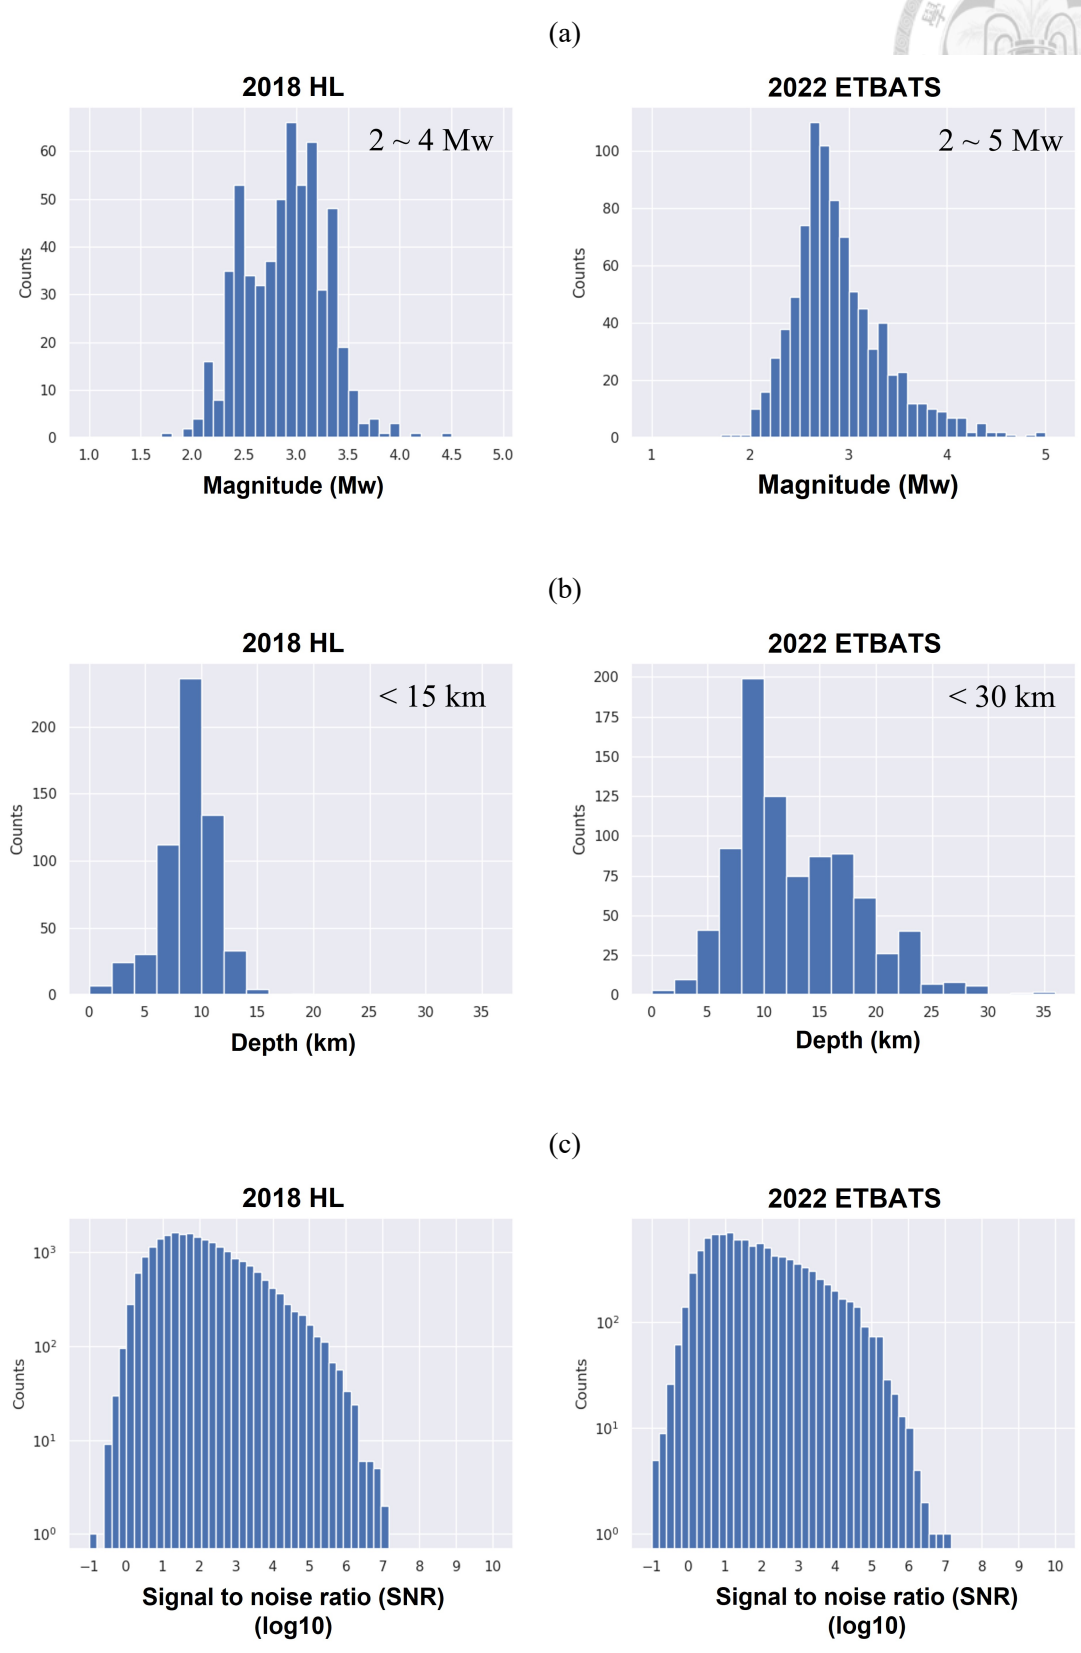



圖 2.4: 2018 花蓮地震網和 2022 池上微震觀測網。篩選測站數量足夠之地震事件後之 (a) 規模分布 (b) 深度分布 (c) P 波訊噪比。



2.4 資料前處理

地震波形做前處理，包含以下七個步驟：

1. 從波形資料庫取出時間框內的三分量地震波形資料
2. 去除平均值與線性趨勢
3. 使用 1-45 Hz 非零相位的帶通濾波器
4. 資料正規化，按比例縮放至 $[0,1]$ 的區間
5. 重採樣至 100 Hz
6. 裁切波形長度為 2.56 秒，並固定 P 波到時在 1.56 秒¹
7. 對應 P 波初動極性分類任務，只取垂直分量的波形即可。

此外，本研究對訓練資料做資料增強 (augmentation technique)。增加上下翻轉後的波形，即振幅乘上 -1，並分別賦予翻轉後所對應的極性，以此加倍資料量，同時有效地促進兩個類別之間的平衡，有助於提升模型的表現。

2.5 標籤

對 P 波極性採用三元分類，分為「上動」、「下動」和「不可辨識」，並用三個 0 至 1 之間的機率值作為極性標籤，例如人工標籤的「上動」會標記為 (1, 0, 0)，「下動」則為 (0, 1, 0)，而預測標籤可能是 (0.05, 0.15, 0.8)，取機率最大值之類別為其預測的極性類別，即預測為「不可辨識」的類別。

¹參考前人研究 (Uchide, 2020) 將波形長度設定為 2.56 秒，當辨別目標包含小規模地震，專注在小尺度的波形特徵。除此之外，二的次方倍數有助於模型計算效能。



2.6 模型設計

本研究基於卷積神經網路對極性分類，模型相對簡單，具有極高的泛化能力，即在未見過的資料表現穩定。模型設計參考 Uchide (2020)，模型內部包含四層卷積層、一層平坦化層、兩層全連接層、最後經過歸一化指數函式，將「上動」、「下動」和「不可辨識」分別的預測機率做為輸出 (圖 2.5) (詳情請見附錄A.2.1)。

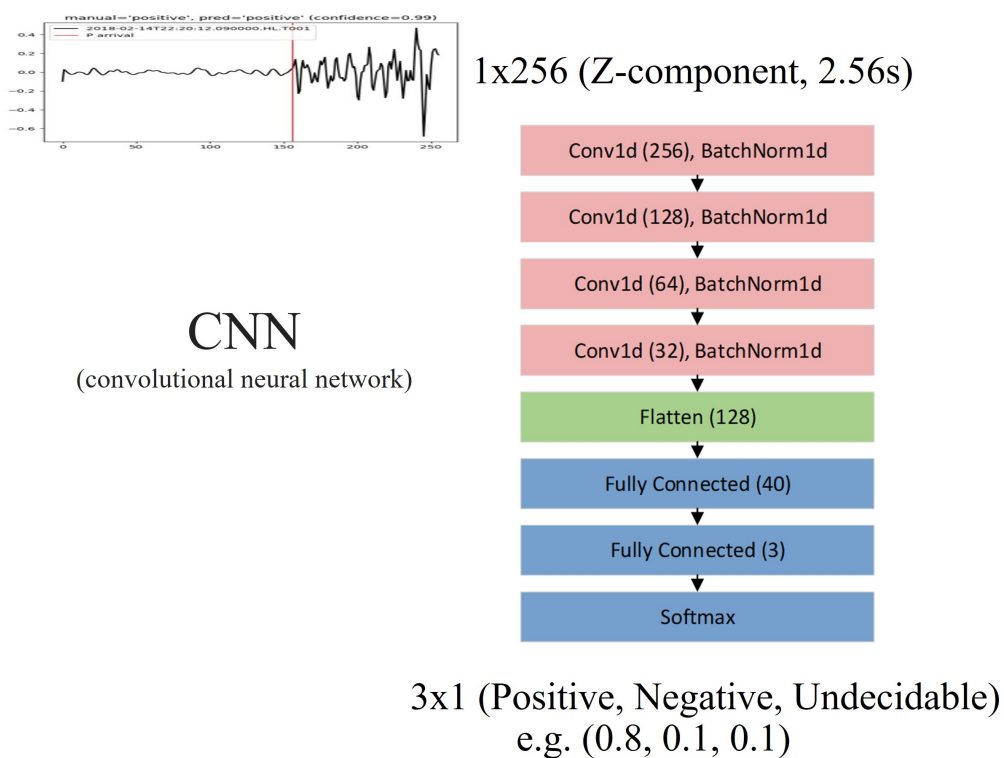


圖 2.5: 基於卷積神經網路之 P 波初動極性分類模型。模型輸入為垂直分量的波形，輸出為三個類別的機率，取最高機率作為預測類別。

2.7 模型訓練和驗證

訓練集資料在訓練週期內用於更新模型權重參數，然後利用驗證集資料在每次訓練週期中評估模型的超參數，如神經元數量、批量大小及學習率等 (表2.2)。在訓練及驗證模型的過程中，將會繪製並紀錄模型預測的結果和損失值的變化，

藉此評估模型的學習情況，並根據訓練記錄決定是否停止訓練或進行問題檢討。模型的訓練歷程有助於模型架構、訓練資料及超參數的設定。為了培養出穩定高效的模型，必須進行大量的模型試驗並不斷調整。此外，人為判斷在這一過程中扮演關鍵角色，需要看懂模型的反饋，並考量該如何提升性能、平行化加速等問題。在後期，需要評估是否出現過擬合或欠擬合情況，並進行相應調整（詳情請見附錄A.4.1）。

表 2.2: P 波初動極性分類模型的超參數設定

超參數	設定值
模型輸入形狀	[16, 1, 256] (批量, 垂直分量, 時間長度)
模型輸出形狀	[16, 1, 3] (批量, 垂直分量, 三個分類類別)
損失函數	交叉熵損失 BCE
批量大小	16
迭代次數	20
優化器	SGD
學習率調度器	CyclicLR
學習率範圍	1e-5 至 1e-2 (三角波形循環變化)

2.8 P 波初動極性解析震源機制解—FPFIT

本研究利用深度學習技術分類 P 波初動極性，後續在轉換成震源機制解時只會使用上動與下動兩個類別，並選取輸出機率超過 90% 的極性資料進行後續震源機制解的解析（信心門檻根據測試集特性進行調整）。

在解析 P 波初動極性為震源機制解的方法中，FPFIT 方法被廣泛使用，最初由 Reasenber 和 Oppenheimer 於 1985 年開發，該方法採用兩階段的格點搜尋法，並可根據測站分布比例（STDR）篩選掉誤差過大的結果（Havskov et al., 2020;

Reasenbergs and Oppenheimer, 1986)。FPFIT 和 HASH 都適用於解析 P 波初動極性為震源機制解，FPFIT 的特色在於其高精度與高容錯率，主要用於規模小的地震，相較於 HASH 方法，FPFIT 的 P 波初動的精確率對震源機制解析的品質影響較小，且能計算參數的不確定性；而 HASH 方法使用 P 波極性、以及 P 波和 S 波的振幅比來決定斷層面解，適合在極性資料少且非常高精確率的情況 (Hardebeck and Shearer, 2003)。因此對應密集地震網時，本研究選用 FPFIT 來解析 P 波初動極性為震源機制解，也提供 HASH 方法來應對測站數量較稀疏的測網。

FPFIT 的計算過程可主要分為，準備資料、定義誤差函數、兩階段網格搜尋、誤差函數信心區間估計、三個主要參數的不確定性（在信心區間內的變化範圍）、輸出每個地震事件的斷層面解參數和相關不確定性。以下將分別進行說明：

1. 準備資料: 定位後的震源資訊、測站對震央的方位角、入射角、P 波初動極性

2. 定義誤差函數:

$$f_{i,j} = \frac{\sum_k |p_o^{j,k} - p_t^{i,k}| \cdot w_o^{j,k} \cdot w_t^{i,k}}{\sum_k w_o^{j,k} \cdot w_t^{i,k}}$$

Po 是觀測的 P 波初動極性，Pt 是網格搜尋的理論值，並且此誤差函數考慮權重和正規化，該權重使靠近斷層面 (nodal planes) 的觀測點權重降低，從而減少這些區域誤差的影響。

3. 兩階段網格搜尋：使用 20 度的網格間距，搜尋具有最小誤差函數值的三個參數，後續再進一步使用 5 度的網格間距搜尋走向和傾角，以 10 度搜尋滑移角。精細搜尋後具有最小誤差函數值的三個參數作為斷層面解。

4. 三個主要參數的不確定性：對於每個確定的解，計算其走向滑移和傾角這三個參數的變動範圍，作為該解的不確定性，單位為度。這一變動範圍是基於誤差函數 90% 信心區間內，也就是在這個範圍內參數的變動不會使誤差函數超過 90% 信心區間的限制，此誤差函數的 90% 信心區間的值是預先根據

極性觀測資料所計算誤差函數的變異數而來。總而言之，三個主要參數的不確定性越小，代表解越穩定可靠。

5. 輸出每個地震事件的斷層面解參數和相關不確定性：輸出走向、滑移和傾角這三個參數值與個別的不確定性。本研究評估單一測站極性數量，目前應用時會篩選三個參數的不確定性皆小於 15 度作為穩定解。

具體而言，本研究整合了 SEISAN 軟體中的 FPFIT Fortran 程式 (Havskov et al., 2020)，在 Python 環境中透過命令列進行操作，使得從極性預測、極性求得震源機制解析、GMT 繪圖檢視、生成互動網頁、輸出震源機制解資訊及更新資料庫的所有過程均可在 Python 模組化環境中自動化運行。

此外，預測極性的輸出機率會先經過信心門檻篩選，預測機率低於 90% 信心門檻時，將會轉為「不可辨識」的類別（信心門檻可根據測試集特性進行調整），篩選後高信心的可辨識極性資料才會進行後續震源機制解的解析。

2.9 規模估算—AUTOMAG

對於規模計算的功能，本研究目前選擇整合 Seisan 軟體中的 AUTOMAG 功能來自動化計算規模 (Havskov et al., 2020)，其仰賴速度模型，並預設使用垂直分量的波形做計算。地震矩規模計算使用 P 波和 S 波在垂直分量的最大振幅，基於 Brune 光譜得到轉角頻率 (Corner Frequency)，由振幅、轉角頻率與介質特性的參數計算代表釋放能量的地震矩 (M_0)，進一步計算地震矩規模 (M_w)，並與其他地震參數如震源深度、斷層參數等結合，得到更全面的規模分析。



2.10 第一階段測試—極性分類評估

由於驗證資料本身會影響模型學習，訓練後的模型需再透過測試資料，才能真實評估該模型的能力值。考量到本研究之 P 波初動極性為三元分類，輸出類別設定為「上動」、「下動」和「不可辨識」。精確率是預測為某一類別中被正確預測為該類別的比例。召回率是實際為某一類別中被正確預測為該類別的比例。本研究中精確率需要考慮的是上動與下動的比例，而須特別注意本研究的召回率探討的是「可辨識」之極性與「不可辨識」之極性兩大類，亦即將上動與下動合併為「可辨識」之極性，以下是本研究對於精確率與召回率所調整的計算公式（基礎的二元分類評估指標請見章節A.4.2）：

- Positive Precision: $\frac{PP}{(PP+NP)}$
- Negative Precision: $\frac{NP}{(NN+PN)}$
- Positive Recall: $\frac{PP+PN}{(PP+PN+PX)}$
- Negative Recall: $\frac{NP+NN}{(NP+NN+NX)}$

Confusion Matrix

Manual (Ground Truth)	Positive	PP	PN	PX
	Negative	NP	NN	NX
	Undecidable	XP	XN	XX
		Positive	Negative	Undecidable
		Prediction		

圖 2.6: 三元分類的混淆矩陣



2.11 第二階段測試—震源機制解之準確率評估

已分類之極性經由信心門檻篩選，解析震源機制解後會進行第二階段評估。根據模型預測與人工標記兩種極性，同樣用 FPFIT 方法轉換震源機制解後，透過 Kagan 測試來計算震源機制解的準確率。此部分本研究選擇整合 SeismoTectonic Regime Earthquake Calculator (STREC) 的開源程式碼 (USGS, 2022) 計算 Kagan 角度。Kagan 角度是兩個震源機制解之間的最小旋轉角度，用最小旋轉角度代表兩個震源機制解的相似度，完全相同則最小旋轉角度為 0 度，完全不同則為 120 度。當最小旋轉角度小於 40 度，認定預測之震源機制解與人工解相似度達到門檻，即預測正確。為了能貼近由極性正確性所導致的震源機制解準確率，除了前面提到會排除主要參數有高不確定性的地震 (第 2.8 章)，Kagan 測試前會先排除測站包覆度差的地震，以下將做進一步說明：

鑒於震源機制解的誤差來源不僅包括極性的正確性和數量，還與測站包覆度有關。極性的正確性和數量是可以通過模型調整的可控因素，而測站包覆度則是由實際的地震網限制的不可控因素。為了在本研究中的震源機制解評估時，貼近極性正確性所影響的震源機制解準確率，在評估準確率前，必須設定測站包覆度的門檻，排除測站包覆度差的地震事件，以此估計的準確率更能真實反映模型對極性正確性的預測能力。

為了排除因測站包覆度受限而導致的不良預測結果，本研究使用方位角包覆度和距離包覆度這兩個因素 (圖 2.7)。一般而言，為獲得穩定的震源機制解，測站的方位角包覆範圍應大於 200 度；對於距離包覆度，則需考慮波線傳播至測站的入射角，其覆蓋範圍通常需大於 40 度 (圖 2.8)。本研究通過方位角缺口 (GAP of azimuth) 和入射角覆蓋 (GAP of incidence angle) 兩個指標來描述這些包覆度。方位角缺口是測站間最大和最小方位角的差值，而入射角覆蓋則是最大和最小入射角之間的差值。




圖 2.7: 討論震源機制解的包覆度時，使用測站包覆度的方位角缺口 (GAP of azimuth) 與入射角覆蓋 (GAP of incidence angle) 兩個參數作為測站包覆度門檻

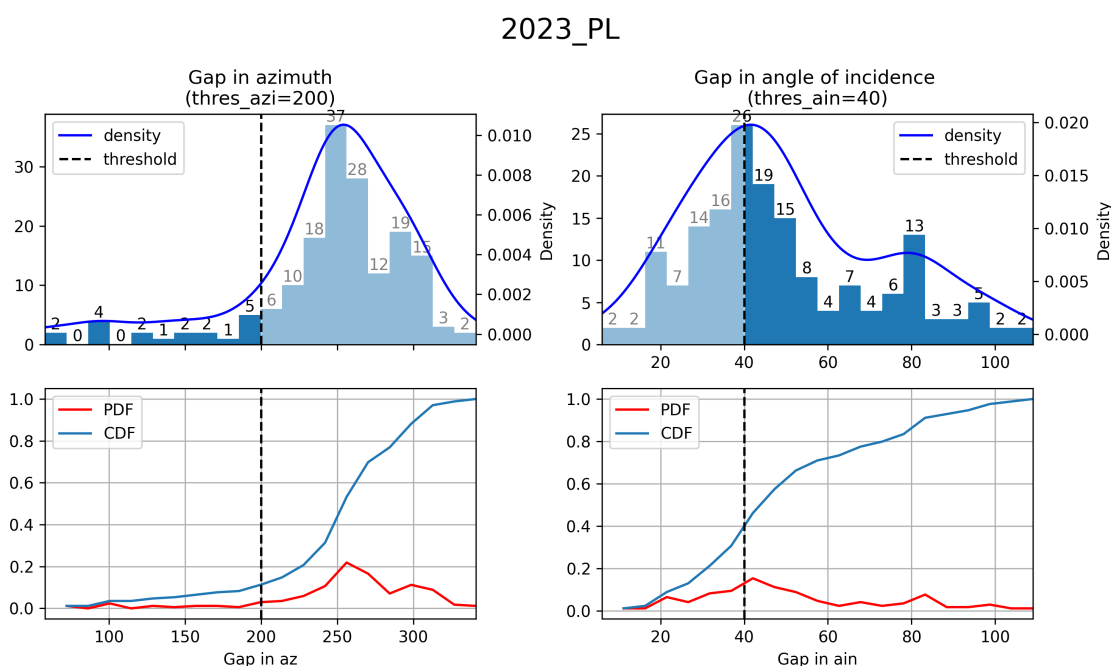


圖 2.8: 震源機制解的測站包覆度門檻分析。左圖代表方位角缺口 (GAP_azi)，右圖代表距離的入射角覆蓋 (GAP_ain)。方位角的缺口越小，以及入射角覆蓋越廣，表明測站在空間上的覆蓋度越完善，從而震源機制解的穩定性與可靠性提高，誤差來源減少。圖中的虛線代表設定的篩選門檻值。透過概率密度函數 (PDF) 和累積分佈函數 (CDF) 的視覺化，可進一步協助使用者選擇合適的門檻值。



由上述可知，在檢視震源機制解的結果時，在測站覆蓋度的篩選門檻，除了影響震源機制解的準確率計算，對篩選穩定的震源機制解尤其重要，但門檻的設定會根據不同地震測網的性質而改變。為了能夠應對根據測網性質而浮動的覆蓋度門檻，本研究透過熱度圖來描述不同覆蓋度門檻下的準確率，有效排除了覆蓋度不佳的測站，從而更貼近由預測極性正確性所影響之震源機制解準確率，也能估計準確率的不確定性（圖 2.9）。

最後，同樣為了能因應每個測網對於覆蓋度門檻的彈性變化，本研究設計互動網頁的使用者介面，可直接在網頁上調整門檻後，從網頁的地圖快速檢視對應的震源機制解的分布結果。




圖 2.9: 測站覆蓋率門檻對應震源機制解之準確率。左圖為準確率，右圖為數量。其中縱軸表示方位角缺口的上限，且縱軸上下相反；橫軸表示入射角覆蓋的下限。熱度圖向右上方延伸時，表示門檻設置更嚴格，有效排除了測站覆蓋度不佳的地震事件，從而更貼近由預測極性正確性所影響之震源機制解準確率。

第三章 實驗一—SeisPolar 震源機制

解模組之結果



模型經由 49,312 筆資料訓練後，利用 3,429 筆資料做驗證，選擇最佳超參數的模型後，測試部分將由訓練時未看過的測試資料，真實評估該模型的能力值。

測試資料分為有人工標籤和無人工標籤兩種。有人工標籤的資料包含 2018 花蓮地震網與 2022 池上微震觀測網的測試資料集，分別為 3,150 筆短週期儀器和 1,648 筆寬頻儀器的波形資料；無人工標籤的資料則以 2023 寶萊密集地震網為例。有人工標籤的資料用做模型評估，比對預測與真實資料來了解模型性能，即了解預測極極性的品質與數量，以及解析成震源機制解後的準確率；而無人工標籤的資料則作為實際應用的測試，並藉由本研究設計的互動式網頁地圖快速檢視震源機制解的分布、應力 P 軸和 T 軸與震源基本資訊。

評估時以單一地震事件為例，此地震所有測站的波形資料會經模型預測極性，預測極性經信心門檻的篩選後，解析成震源機制解。並且考量測站覆蓋度的影響，篩選震源機制解三個參數的不確定性皆小於 15 度、方位角缺口小於 200 度、入射角覆蓋大於 40 度的地震事件。後續透過 Kagan 測試，以最小旋轉角度小於 40 度作為預測正確的標準。根據本研究使用的 2018 花蓮地震網與 2022 池上微震觀測網的測試資料集，在 0.9 的信心門檻下，此模型不僅符合本研究 95% 以上高精確率的目標，並同時達到約 70% 以上的召回率，有效分析密集地震網內的區域性小規模地震之震源機制解。接下來將對各個資料集的結果詳細說明。



3.1 2018 花蓮地震網（有人工標籤）

對於使用短週期儀器的 2018 花蓮地震網，測試資料含 87 個地震事件以及 3,150 個 P 波。表 3.1 顯示在不同信心門檻下，上動與下動的精確度與召回率，以及震源機制解的準確率。當設定門檻為 0.9，上動的分辨有 97% 的精確率和 71% 的召回率；下動的分辨有 90% 的精確率和 71% 的召回率。極性數量分布與混淆矩陣請見附錄 B。在 Kagan 測試後，本研究以熱度圖顯示不同測站包覆度下的準確率，約有 79% 的震源機制解預測正確（圖 3.1），並檢視波形資料的極性辨識結果（圖 3.2 - 3.7）。

表 3.1: 2018 花蓮地震網測試資料的模型性能結果（%）

Threshold	P Precision	N Precision	P Recall	N Recall	FM Accuracy*
0.5	94	84	86	86	65 (32/49)
0.6	95	85	83	84	64 (32/50)
0.7	96	87	79	79	67 (30/45)
0.8	98	88	75	76	70 (31/44)
0.9	97	90	71	71	79 (31/39)
0.95	98	91	65	65	76 (25/33)

Notes:

- Positive Precision: $\frac{PP}{PP+NP}$
- Positive Recall: $\frac{PP+PN}{PP+PN+PX}$
- Negative Precision: $\frac{NN}{NN+PN}$
- Negative Recall: $\frac{NP+NN}{NP+NN+NX}$
- * Before calculating the Accuracy of Focal Mechanism (Kagan test), the events were filtered by error $< 15^\circ$, GAP_azi $< 200^\circ$, GAP_ain $> 40^\circ$.



Accurate predictions of focal mechanism

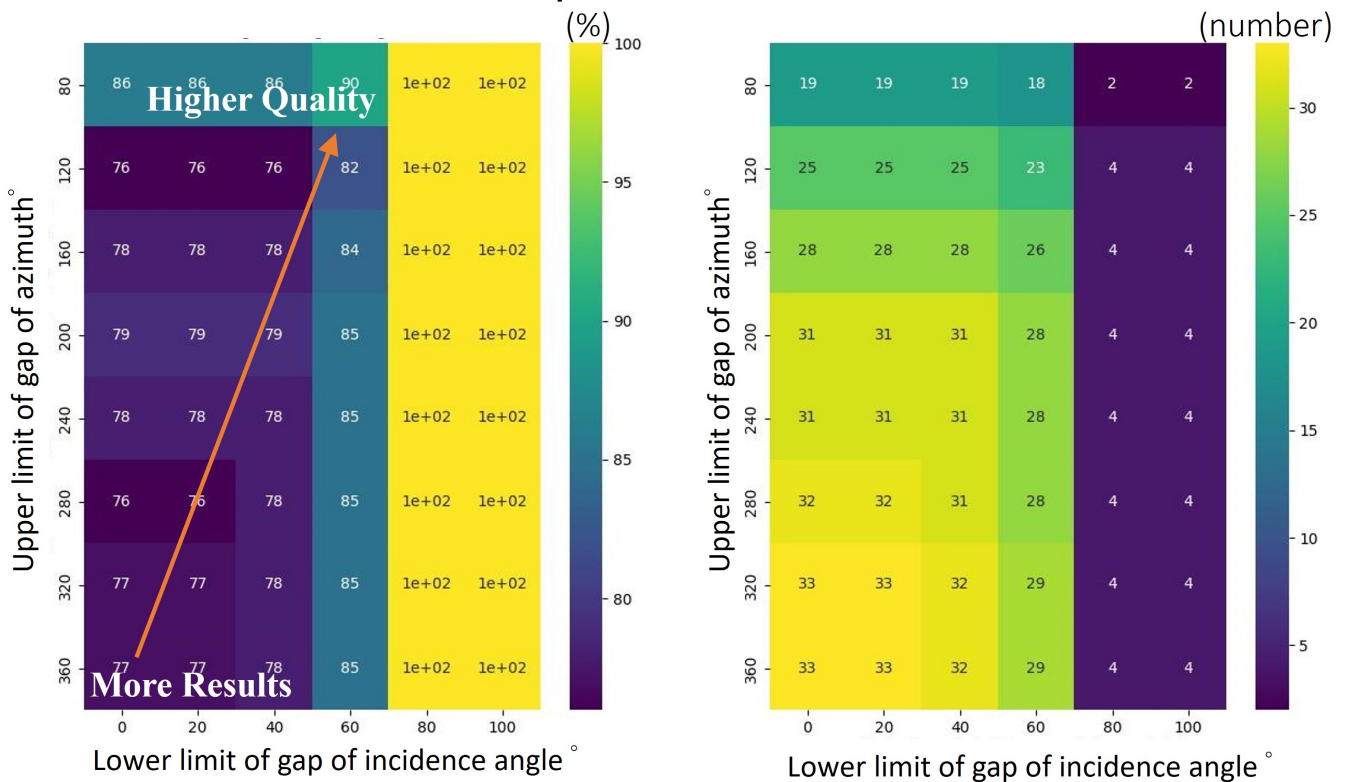


圖 3.1: 測站覆蓋率門檻對應震源機制解之準確率—2018 花蓮地震網測試資料。熱度圖顯示不同測站覆蓋率對震源機制解的準確率影響，包含方位角與距離兩個因素，越往圖的右上方，代表幾何篩選越嚴格，數量越少。左圖為震源機制解準確率，顯示約有 79% 的震源機制解預測正確。右圖為對應準確率的地震事件數量。





圖 3.2: 2018 花蓮地震網預測 P 波初動極性範例 1




圖 3.3: 2018 花蓮地震網預測 P 波初動極性範例 2





圖 3.4: 2018 花蓮地震網預測 P 波初動極性範例 3




圖 3.5: 2018 花蓮地震網預測 P 波初動極性範例 4



manual='negative', pred='undecidable'(raw: positive) (confidence=0.73)




圖 3.6: 2018 花蓮地震網預測 P 波初動極性範例 5

manual='negative', pred='undecidable' (confidence=1.00)




圖 3.7: 2018 花蓮地震網預測 P 波初動極性範例 6



3.2 2022 池上微震觀測網（有人工標籤）

對於使用寬頻儀器的 2022 池上微震觀測網，測試資料含 130 個地震事件以及 1,648 個 P 波。表 3.2 顯示在不同信心門檻下，上動與下動的精確度與召回率，以及震源機制解的準確率。當設定門檻為 0.9，上下動的分辨有 98% 的精確率和 75% 的召回率。極性數量分布與混淆矩陣請見附錄 B。在 Kagan 測試後，本研究以熱度圖顯示不同測站包覆度下的準確率，約有 75% 的震源機制解預測正確（圖 3.8），並檢視波形資料的極性辨識結果（圖 3.10 - 3.15）。

表 3.2: 2022 池上微震觀測網測試資料的模型性能結果 (%)

Threshold	P Precision	N Precision	P Recall	N Recall	FM Accuracy*
0.5	97	96	86	89	79 (30/38)
0.6	97	97	83	88	76 (28/37)
0.7	98	97	81	85	69 (20/29)
0.8	97	97	77	82	63 (17/27)
0.9	98	99	71	77	75 (15/20)

Notes:

- Positive Precision: $\frac{PP}{(PP+NP)}$
- Positive Recall: $\frac{PP+PN}{(PP+PN+PX)}$
- Negative Precision: $\frac{NN}{(NN+PN)}$
- Negative Recall: $\frac{NP+NN}{(NP+NN+NX)}$
- * Before calculating the Accuracy of Focal Mechanism (Kagan test), the events were filtered by error < 15°, GAP_azi < 200°, GAP_ain > 40°.




圖 3.8: 測站覆蓋率門檻對應震源機制解之準確率—2022 池上微震觀測網測試資料。考慮到測站覆蓋率的誤差來源，由熱度圖顯示不同測站覆蓋率對震源機制解的準確率影響，包含方位角與距離兩個因素，越往圖的右上方，代表幾何篩選越嚴格，數量越少。左圖為震源機制解準確率，顯示約有 69% 的震源機制解預測正確。右圖為對應準確率的地震事件數量。

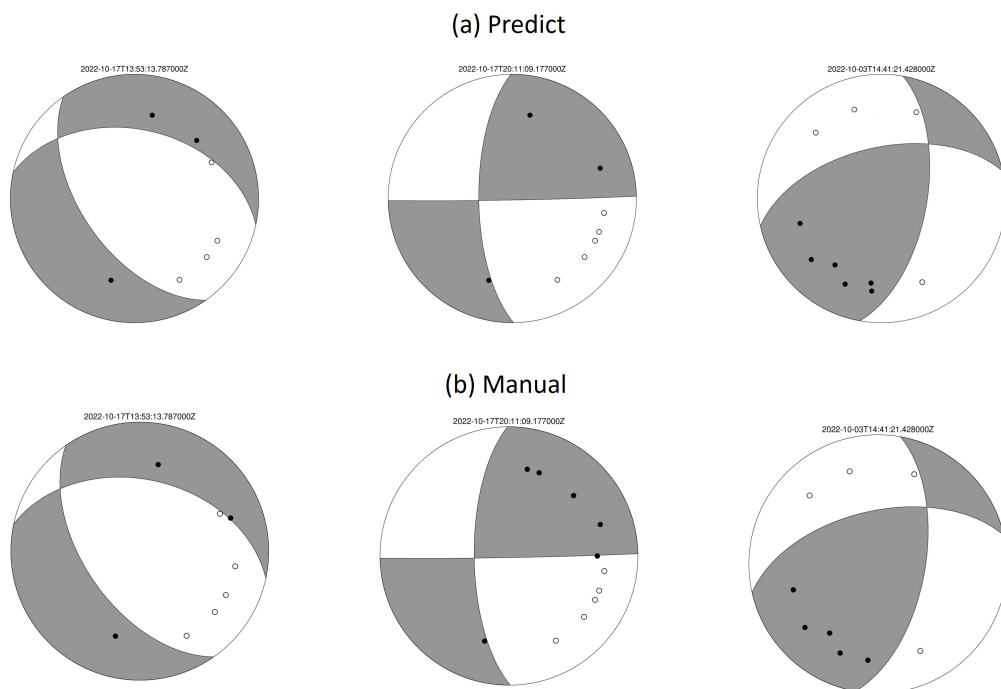


圖 3.9: 2022 池上微震觀測網的震源機制解範例。(a) 模型預測 (b) 人工辨識





圖 3.10: 2022 池上微震觀測網 P 波初動極性範例 1




圖 3.11: 2022 池上微震觀測網 P 波初動極性範例 2





圖 3.12: 2022 池上微震觀測網 P 波初動極性範例 3




圖 3.13: 2022 池上微震觀測網 P 波初動極性範例 4





圖 3.14: 2022 池上微震觀測網 P 波初動極性範例 5




圖 3.15: 2022 池上微震觀測網 P 波初動極性範例 6



3.3 2023 寶來地震網（無人工標籤）

在無人工標籤的測試資料集中，以 2023 寶來地震網為例，使用已篩選測站數量大於 20 之地震事件（詳情見表 3.3），極性數量分布與波相噪訊比（SNR）請見附錄 B。經震源機制解的不穩定度小於 15 度、以及上動與下動數量分別大於 3 的篩選後，得 195 個含有穩定震源機制解的地震事件；進一步限縮震源機制解的不穩定度小於 10 度，得 171 個含有高標準震源機制解的地震事件。透過本研究的自動化流程，處理 2,134 已偵測波相到時和定位的地震事件，若不含波形資料切割與預處理時間，該測網在資料讀取時間約 25 分鐘，極性預測時間約 20 分鐘，解析震源機制解與繪製網頁地圖所花費時間約 10 分鐘。由於預先測站數量大於 20 的地震事件，且多數測站包覆度差的事件被篩選掉，由定位可看出多為網內事件（圖 3.16，圖 3.17，圖 3.19），檢視波形資料的極性辨識結果（圖 3.21 - 3.26）。此外，藉由繪製 P 軸方向，得知應力分布（圖 3.18）。

表 3.3: P 波初動極性分類模型的資料（無人工標籤）詳細資訊

2023 寶來地震網	
儀器類型	SmartSolo 短週期地震儀
測站數量	80
觀測起始時間	2023/5/1 - 2023/6/30
觀測時長（天）	60
篩選後的地震事件數量	2,134
P 波數量	85,008
S 波數量	85,008
可辨識極性數量	53,430
不可辨識極性數量	31,562
地震波相到時偵測	AI + 人工檢視品管

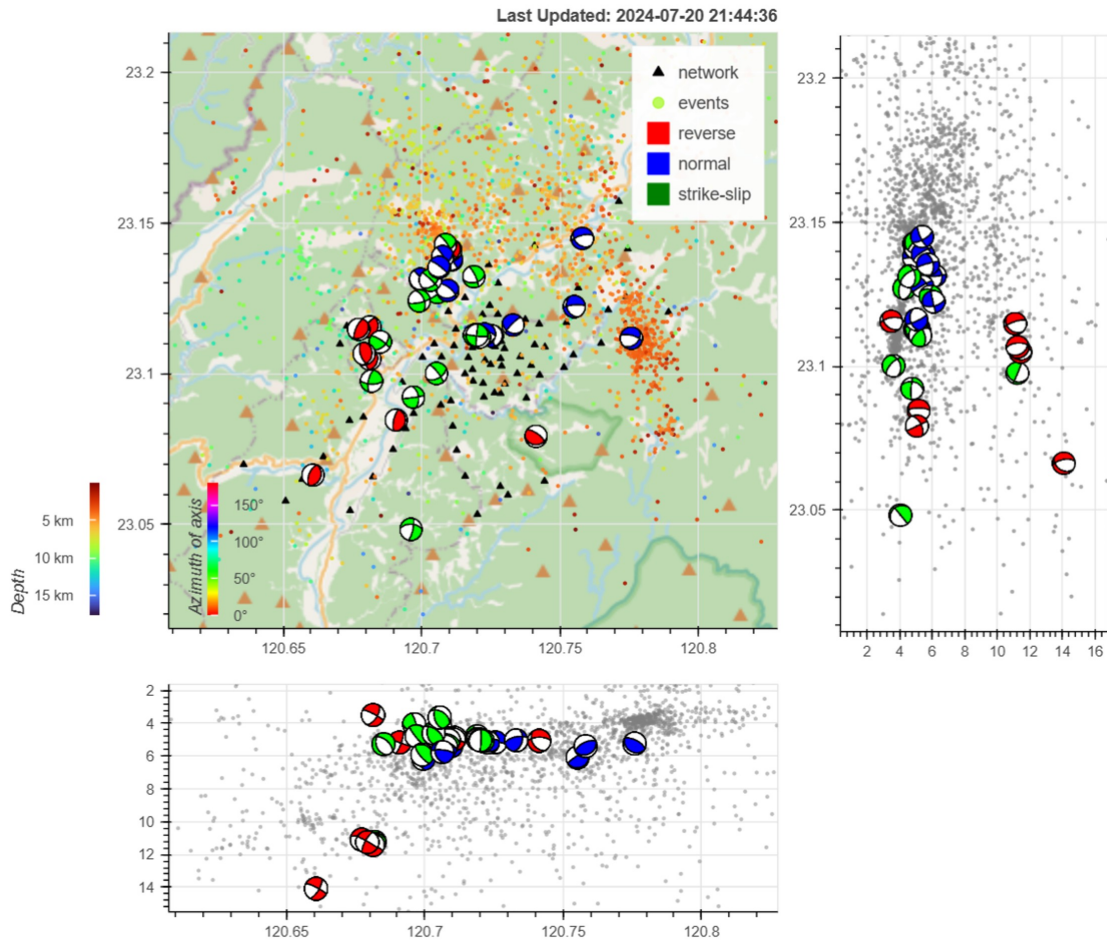



圖 3.16: 網頁地圖—2023 寶來地震網。震源機制解以滑移角簡單區分逆斷層（紅）、正斷層（藍）和走向滑移斷層（綠）。

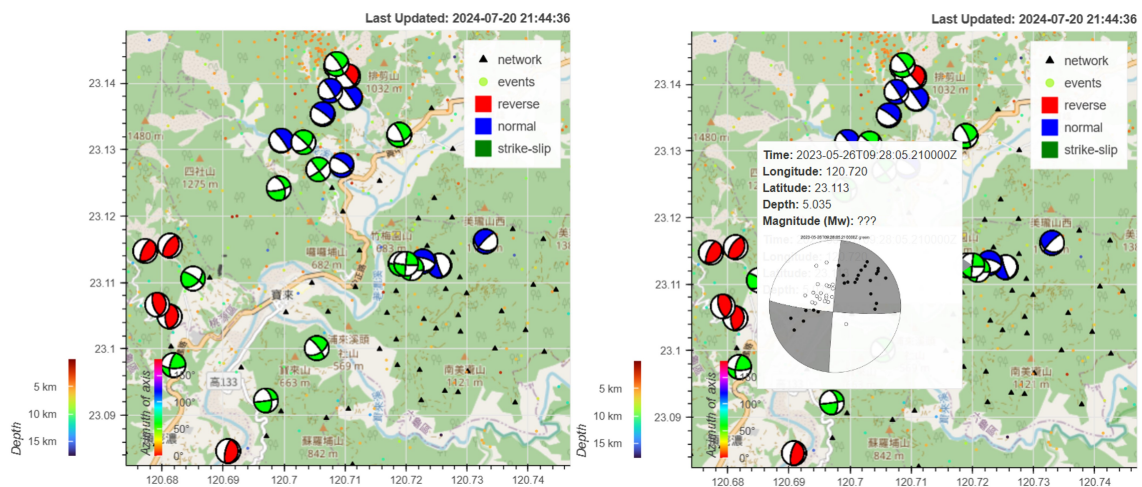


圖 3.17: 網頁地圖—2023 寶來地震網（放大）。震源機制解以滑移角簡單區分逆斷層（紅）、正斷層（藍）和走向滑移斷層（綠）。



Last Updated: 2024-07-20 21:44:36

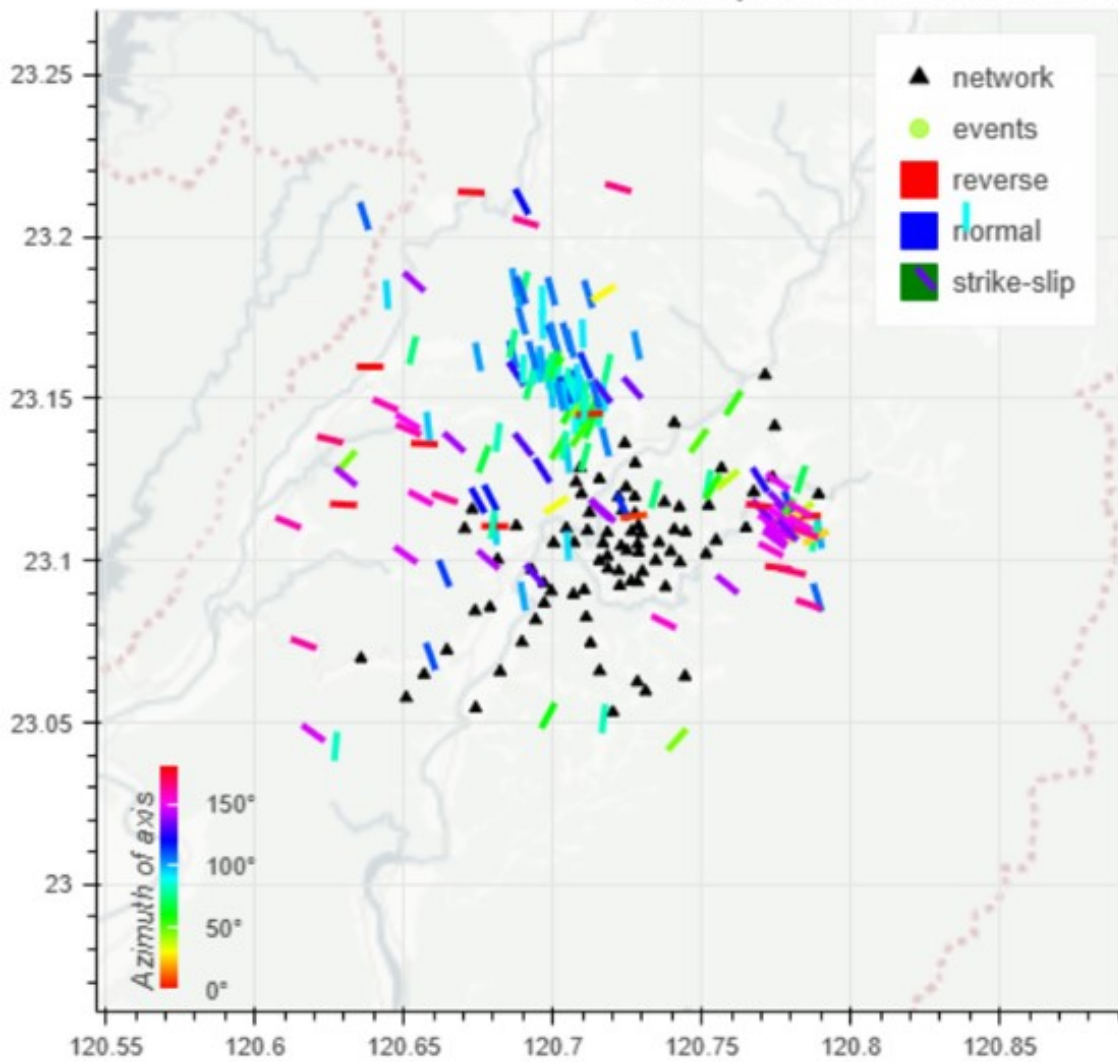


圖 3.18: 網頁地圖—2023 寶來地震網 (P 軸之應力分布) (此圖無篩選測站包覆蓋)。



2023_PL

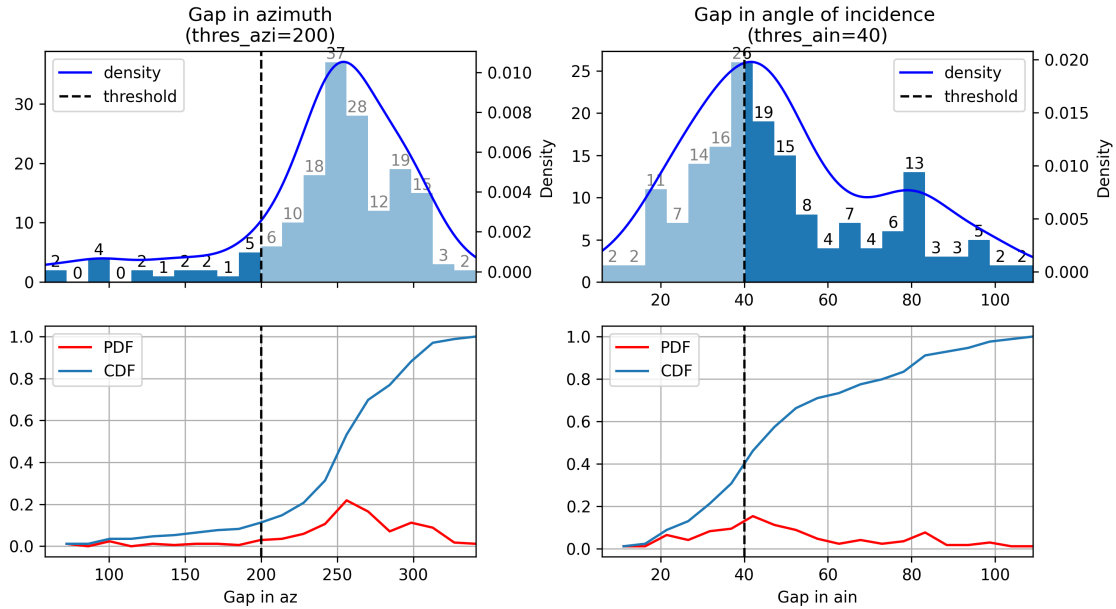


圖 3.19: 震源機制解的測站包覆度門檻分析—2023 寶來地震網。設定方位角缺口小於 200 度 (左圖), 入射角包覆大於 40 度 (右圖)。由不同測站包覆度下的地震數量分布可知, 此地震網大部分發生的都是網外事件, 因此絕大多數的地震事件測站包覆度較差, 導致大量地震事件雖然能解析震源機制解, 但為求穩定解只保留少數測站包覆度佳的結果。此測站包覆度分布圖有助於未來佈站時做參考 (測站包覆度之詳情請見章節 2.11)。




圖 3.20: 2023 寶來地震網模型預測之震源機制解範例。





圖 3.21: 2023 寶來地震網 P 波初動極性範例 1




圖 3.22: 2023 寶來地震網 P 波初動極性範例 2





圖 3.23: 2023 寶來地震網 P 波初動極性範例 3




圖 3.24: 2023 寶來地震網 P 波初動極性範例 4





圖 3.25: 2023 寶來地震網 P 波初動極性範例 5




圖 3.26: 2023 寶來地震網 P 波初動極性範例 6

第四章 實驗二—波相到時偵測模型在 PyTorch 框架下重設計與訓練



本研究為了改進波相到時偵測模型的表現，並增加其未來的維護性，將第二代系統的 TensorFlow 1 深度學習框架轉換到 PyTorch，並將模型內部結構重新設計與訓練。由於深度學習框架的轉換過程，講求對模型與訓練過程的剖析與深入了解，因此本研究基於第二代系統（張立衡，2020），說明波相到時偵測模型的實驗過程，更詳細的深度學習方法請見附錄 A。

4.1 問題定義

為了應對區域性密集地震網，希望抓回大量小規模地震，補足傳統自動化方法的缺陷。因此，定義此深度學習模型的目標是辨識地震波相與到時，仿人類偵測波相到時的過程，輸入三分量資料，經 Transformer 模型，輸出代表機率分布的 P 波、S 波和雜訊的到時的三分量高斯機率分布。針對雜訊的到時標籤，Mousavi et al. (2020) 等前人研究提到在訓練過程中加入雜訊標籤有助於提高 P 波和 S 波的模型預測能力，因此模型除了預測 P 波和 S 波到時，還會一同預測雜訊的到時標籤。

4.2 資料蒐集

本研究在強化波相到時偵測模型的任務中，使用與第二代相同的訓練與測試資料（表4.1），做新舊模型的性能比較。



表 4.1: 波相到時偵測模型的資料詳細資訊

	2017 和平地震網 (訓練資料)	2020 和平地震網 (測試資料)
儀器類型	4 個短週期地震儀, 18 個寬頻地震儀	4 個短週期地震儀, 18 個寬頻地震儀
測站數量	22	22
地震事件數量	11,140	4,250
P 波到時	107,077	31,925
S 波到時	107,031	31,005
觀測起始時間	2017/1/1 - 2017/6/30	2018/4/1 - 2018/6/30
觀測時長	六個月	兩個月




圖 4.1: 2017 和平地震網 (訓練資料) 之噪訊比。(a) P 波 (b) S 波




圖 4.2: 2020 和平地震網 (測試資料) 之噪訊比。(a) P 波 (b) S 波



4.3 資料前處理

地震波形做前處理，包含以下八個步驟：

1. 從波形資料庫取出時間框內的三分量地震波形資料
2. 去除平均值與線性趨勢
3. 使用 1 - 45 Hz 非零相位的帶通濾波器
4. 資料正規化，按比例縮放至 [0,1] 的區間
5. 重採樣至 100 Hz（以上與第四章 P 波初動極性模型相同）
6. 將波形資料前段受濾波影響的部分切除，並在 3 秒內隨機位移窗框，使模型更有效學習連續資料的 P 波和 S 波到時
7. 將資料精準裁切 2,048 個採樣點，以符合模型的輸入長度¹
8. 使用三分量波形 (ENZ) 做為模型輸入

4.4 標籤

對波相到時偵測模型而言目標是輸出 P 波、S 波的到来時，為了彌補波相到時偵測到時的誤差，也為了讓模型能有效計算損失值，用機率分布來取代單純的預測時間。具體而言，根據每段波形，在資料庫中搜尋該時間窗內的 P 波和 S 波到時後，利用三角型標籤在 P 波和 S 波到時的周圍建立一個遞減的機率分布，即產生底長為 0.4 秒的三角形小波，再與到時作卷積，生成到時對應的三角標籤，讓波相到時的高度為 1，兩側擴展各 20 個點並高度遞減，三角之外為 0。此三角標籤的總長度與波形長度一致為 20.48 秒，並以 P 波到時、S 波到時、P 波到 S 波之外的雜訊部分 (PSN) 作為標籤的三個通道。

¹舊模型輸入的波形長度為 30.48 秒，根據新模型設計改用 20.48 秒，即 2,048 個資料點，且二次方倍數有助於模型計算效能。




4.5 模型

第二代的波相到時偵測模型（張立衡等，2022）基於 Transformer 模型做相位到時預測，改良自 Mousavi et al. (2020)（圖 4.3），模型內部主要包含編碼器與解碼器，編碼器將序列逐層萃取資訊後，由解碼器重組回序列。編碼器的部分包含六層卷積層（CNN）、三層殘差連接（ResBlock）、兩層雙向長短期記憶網路（BiLSTM）、兩層自注意力機制（Self-Attention）。解碼器則分為三個部分，個別處理 P 波到時、S 波到時與雜訊。主要由長短期記憶網路（LSTM）、自注意力機制、七層上採樣（UpSampling）、Sigmoid 函數組成（圖 4.4），模型超參數請見表 4.2。

此外，本研究在波相到時偵測任務中引入生成對抗模型，生成對抗網路可以幫助發現標籤和標籤之間的關係，加速生成預期的標籤樣子。詳情請見第 A.2.3 章。


表 4.2: 波相到時偵測模型的主要超參數

主要超參數	值
資料形狀	[256, 3, 2048]（批量，三分量，時間長度）
標籤形狀	[256, 3, 2048]（批量，三分量，標籤長度）
批量大小	256
迭代次數	70
優化器	ADAM
生成器學習率的初始值	1e-4
辨別器學習率的初始值	1e-5



3x2048 (NEZ 3-component, 20.48s)

Transformer & GAN (Generative Adversarial Network)



3x2048 (P-wave, S-wave, Noise)

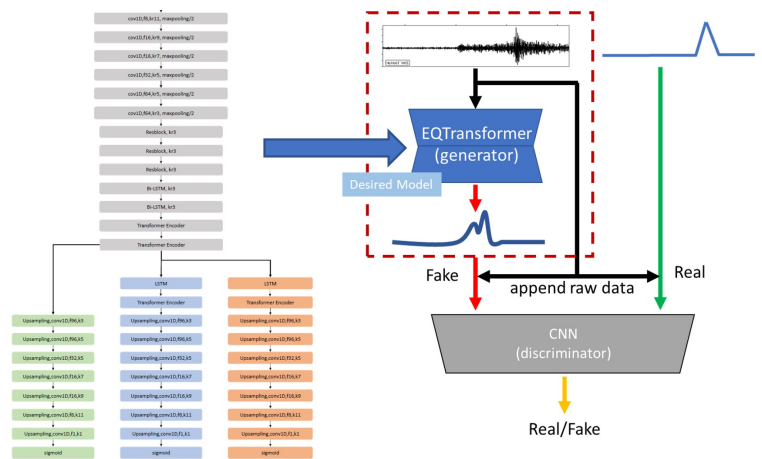


圖 4.3: 波相到時偵測模型架構—Transformer + GAN。模型輸入為三分量的波形，輸出為三個類別的機率分布標籤，其中 P 波和 S 波的三角型標籤代表到時的高斯機率分布。(圖片修改自張立衡等，(2022))

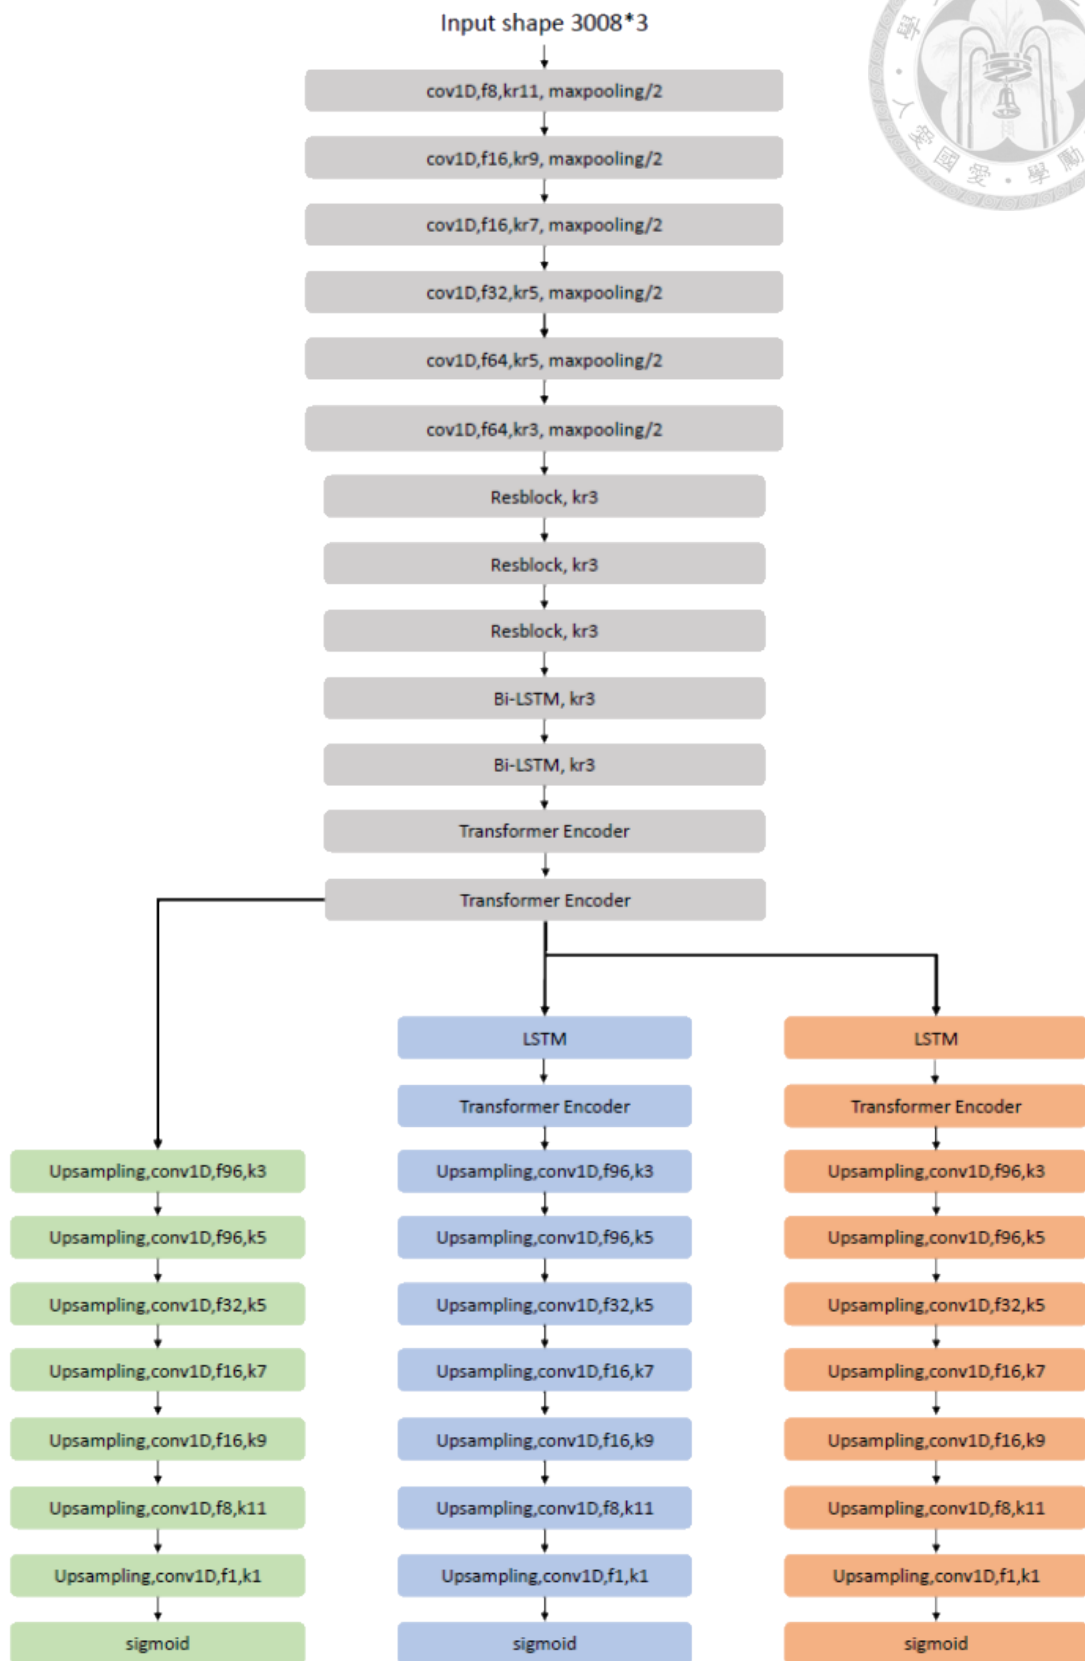


圖 4.4: Transformer 模型架構。圖中以 f 表示 filter 數量，kr 表示卷積核大小。灰色部分為編碼器，在編碼器的尾端接上三個解碼器，分別對應雜訊、P 波與 S 波標籤。(張立衡等，2022)



4.6 模型訓練和驗證

對於波相到時偵測模型的訓練，除了考量到訓練和驗證集的損失值變化，避免欠擬合或過擬合，除了第2.7章提到的訓練過程，還需考量到生成器與辨別器之間須設定為勢均力敵的抗衡，才能讓生成器在此對抗過程中有效學習。




圖 4.5: 隨著訓練週期的損失值變化。上圖是生成器（藍）與辨別器（橘）在對抗過程中的的損失值變化，如圖生成器與辨別器之間勢均力敵的抗衡，達到生成器有效且快速的學習。下圖是訓練集（藍）和驗證集（橘）的損失值變化，當驗證集隨著訓練週期增加不減反升，驗證集損失值與訓練集損失值交叉，此時有最佳模型，即避免過擬合。



4.7 測試結果—2020 和平地震網（有人工標籤）

本研究使用 PyTorch 重設計新版波相到時偵測模型，模型經訓練後，在不同信心門檻下，以到時誤差正負 0.1 秒內作為預測正確的標準，計算精確率與召回率來評估模型（表 4.3），並檢視 0.5 秒內的到時誤差分布（圖 4.6），分析不同信心門檻下精確率與召回率的變化（圖 4.7）並檢視預測結果（圖 4.8 - 4.10）。

在精確率和召回率的權衡之間，波相到時偵測模型因地震定位對波相數量的需求，及測站之間有錯誤到時的篩選機制，相較之下更注重召回率。本團隊目前對密集地震網所預設的信心門檻為 0.5。

表 4.3: 2020 和平地震網的波相到時偵測結果（%）

Threshold	P Precision	P Recall	S Precision	S Recall
0.3	91	91	78	74
0.4	92	90	80	73
0.5	93	89	82	71
0.6	94	88	85	67
0.7	95	85	89	55

Note: Considering errors within $\pm 0.1s$ intervals as correct predictions.




圖 4.6: 波相到時在 0.5 秒內的誤差分布，即人工標記到時減去預測到時。左圖為 P 波，右圖為 S 波的到時誤差分布。

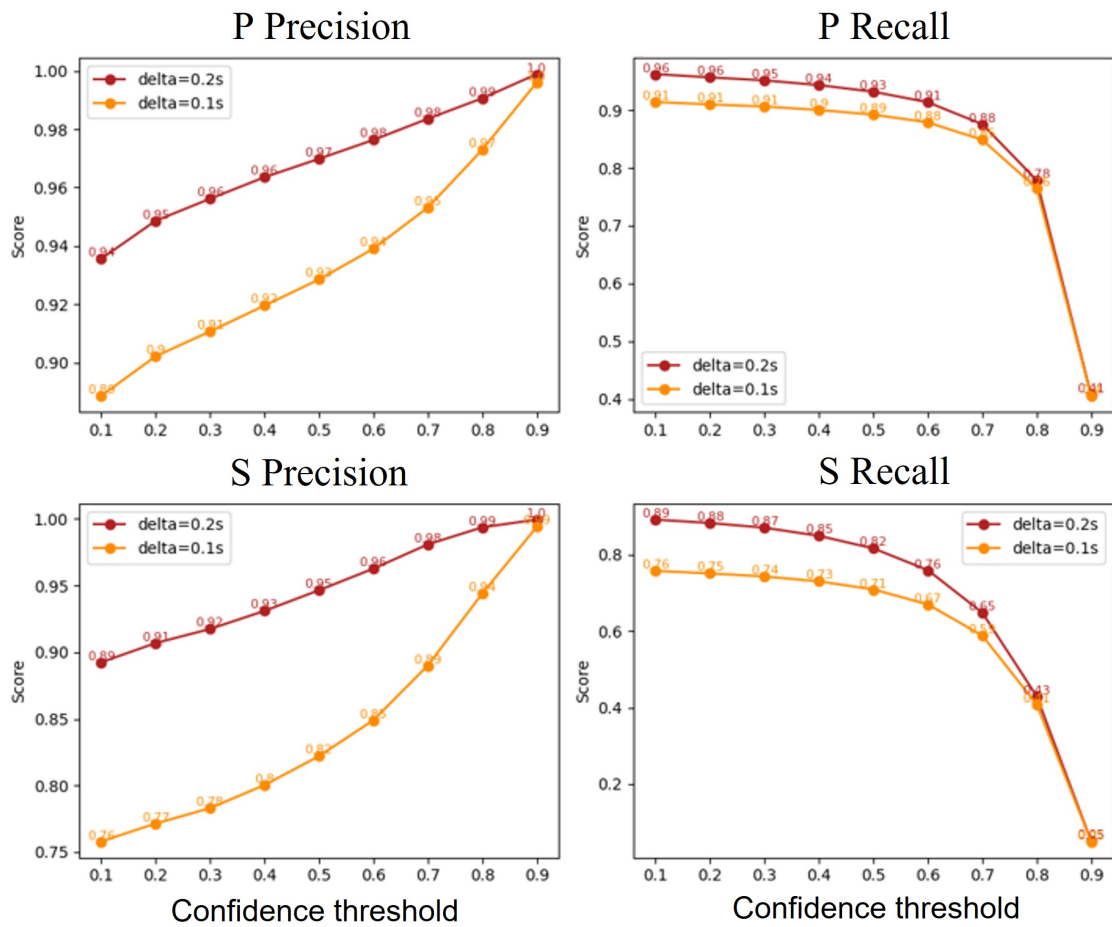


圖 4.7: 波相到時偵測模型性能。以到時誤差正負 0.1 秒內 (紅線) 和 0.2 秒內 (橘線) 作為預測正確的標準。隨著信心門檻的增高, 精確率提升, 而召回率則有所下降。

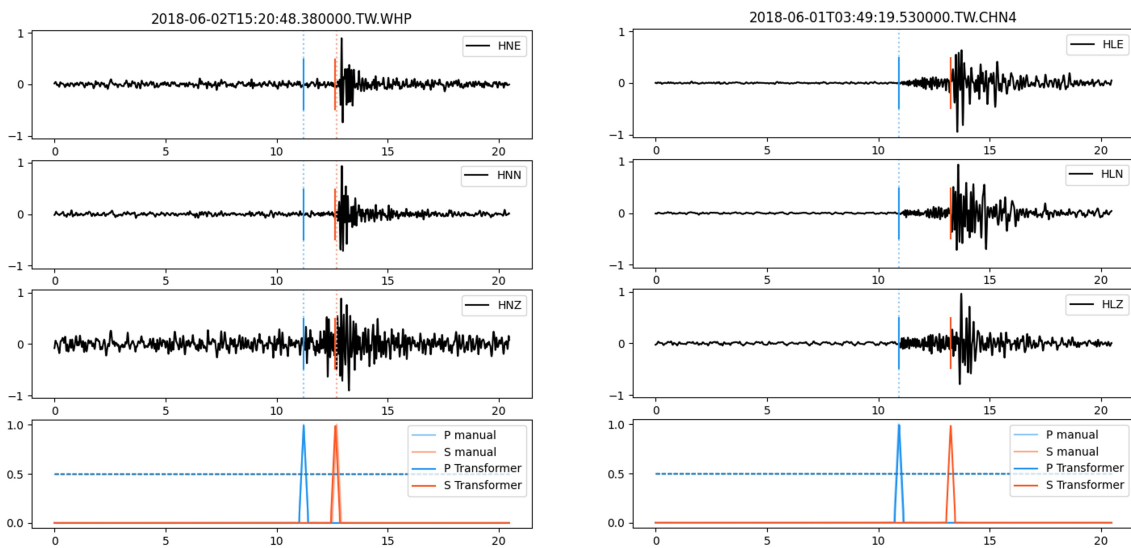


圖 4.8: 波相到時偵測範例 1 和 2

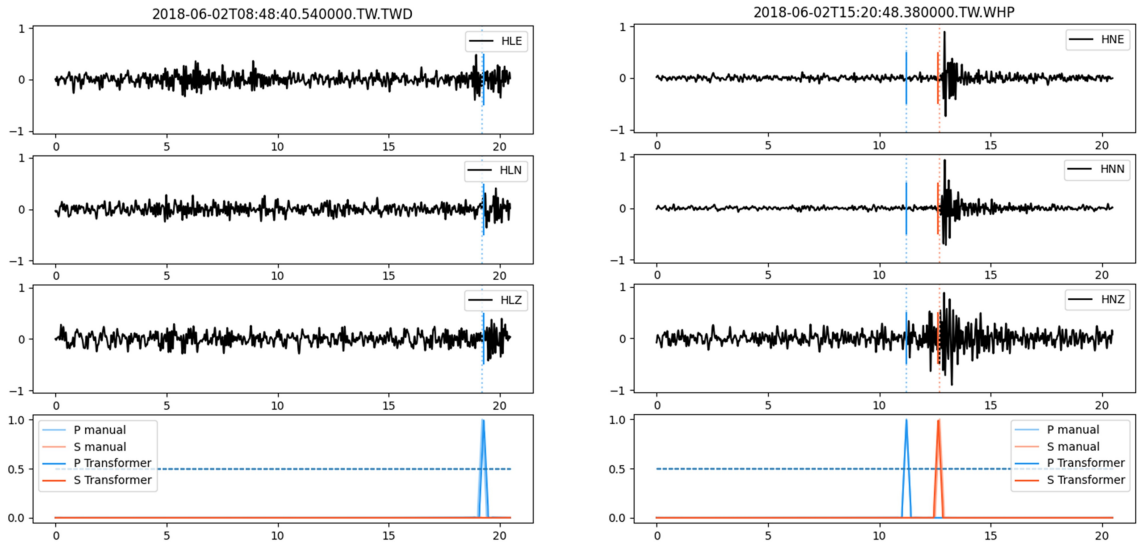


圖 4.9: 波相到時偵測範例 3 和 4

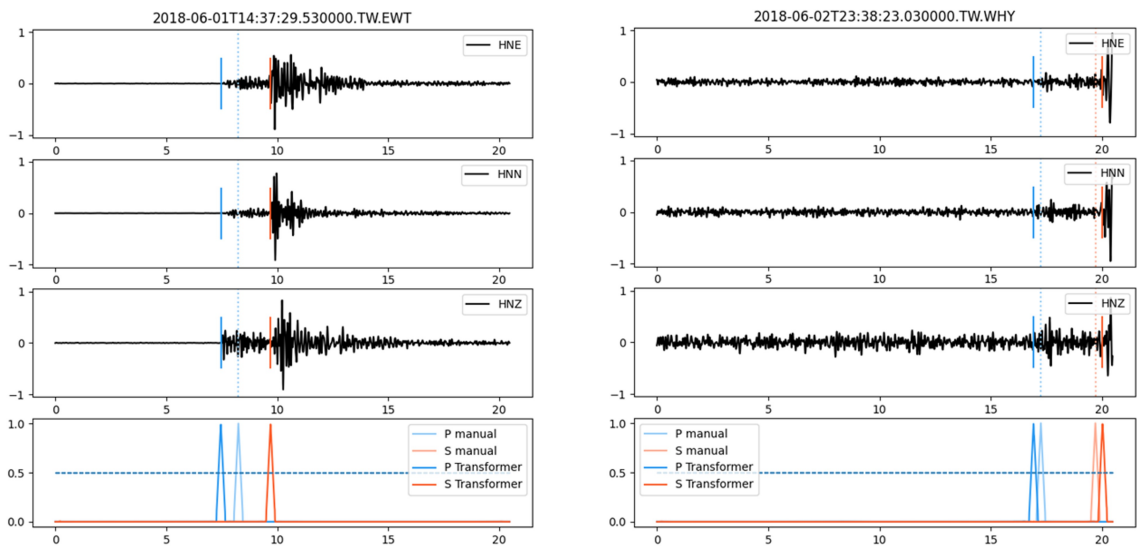


圖 4.10: 波相到時偵測範例 5 和 6

第五章 實驗一和實驗二之討論



5.1 解決波相到時提早預測的問題

本研究改良的第三代波相到時偵測模型，在使用靈活的 PyTorch 重設計並重新訓練模型後，使用與第二代的舊模型相同的資料集做新舊模型的性能比較，由圖 5.1 觀察到新模型解決原有舊模型會「波相到時提早預測」的現象，從而在 P 波和 S 波都提升約 8% 的精確率（圖 5.2）。

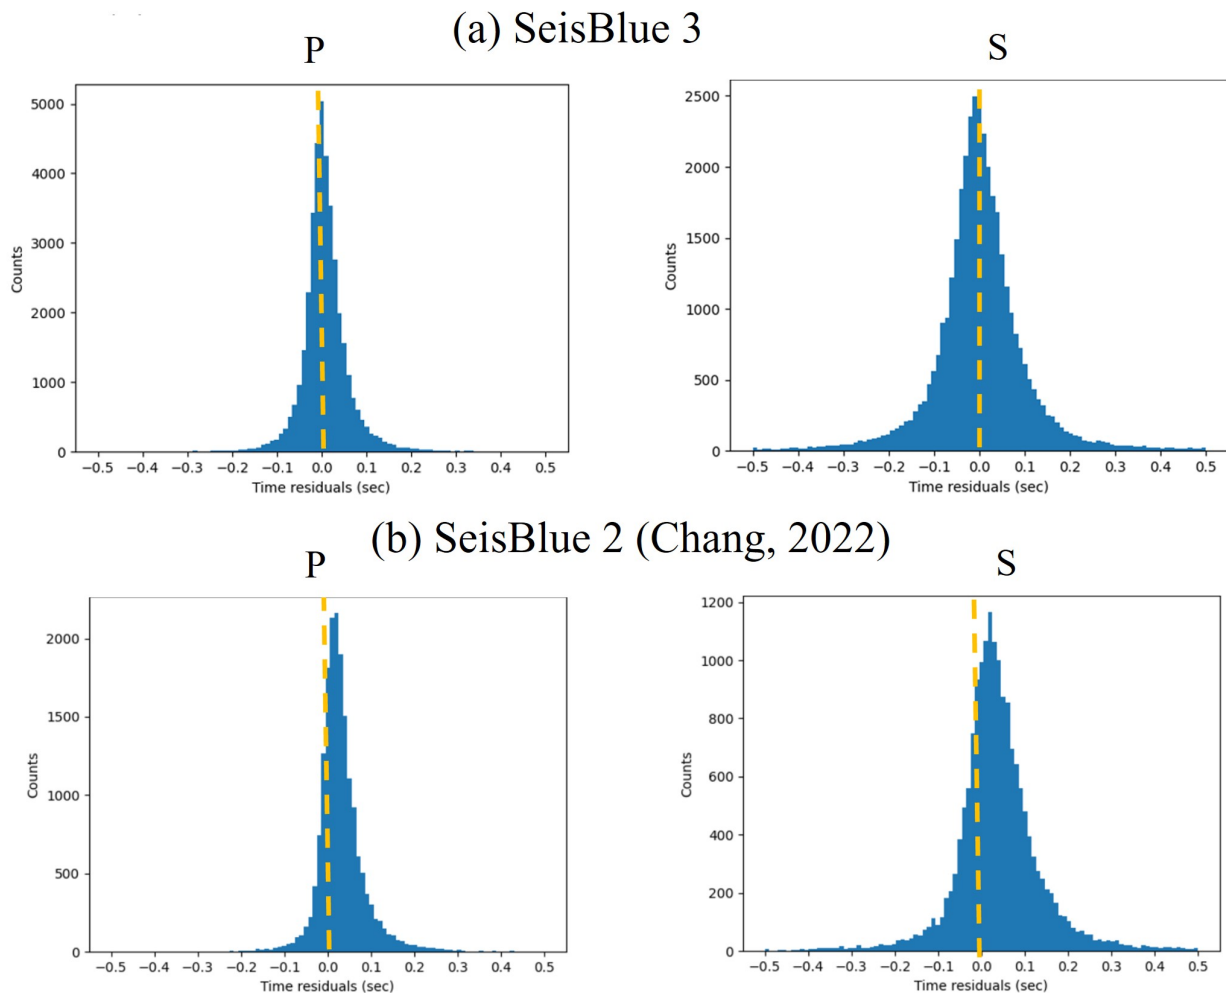


圖 19 和平 2020 年 P 波誤差分布(秒)。橫軸為誤差(秒)，數值大於 0 代表預測到時偏早，小於 0 則代表預測到時偏晚，縱軸為數量。

圖 20 和平 2020 年 S 波誤差分布(秒)。橫軸為誤差(秒)，數值大於 0 代表預測到時偏早，小於 0 則代表預測到時偏晚，縱軸為數量。

圖 5.1: 波相到時偵測模型-新舊模型在 P 波和 S 波的正負 0.5 秒內的到時誤差分布比較，即人工標記到時減去預測到時。(a) 新模型 (b) 第二代舊模型（張立衡等，2022）。由圖顯示第三代新模型改善第二代舊模型會「波相到時提早預測」的現象。

具體而言，依照前人研究與第二代系統的使用經驗選擇信心門檻 0.5，並以正負 0.1 秒作為預測正確的區間時，P 波和 S 波召回率可達 93% 和 85%，精確率可達 97% 和 95%。本研究推測可能是經更多的模型參數實驗，以及使用 PyTorch 重設計模型的過程中，使用現代的運算模組，使第三代波相到時偵測模型的性能大幅提升。

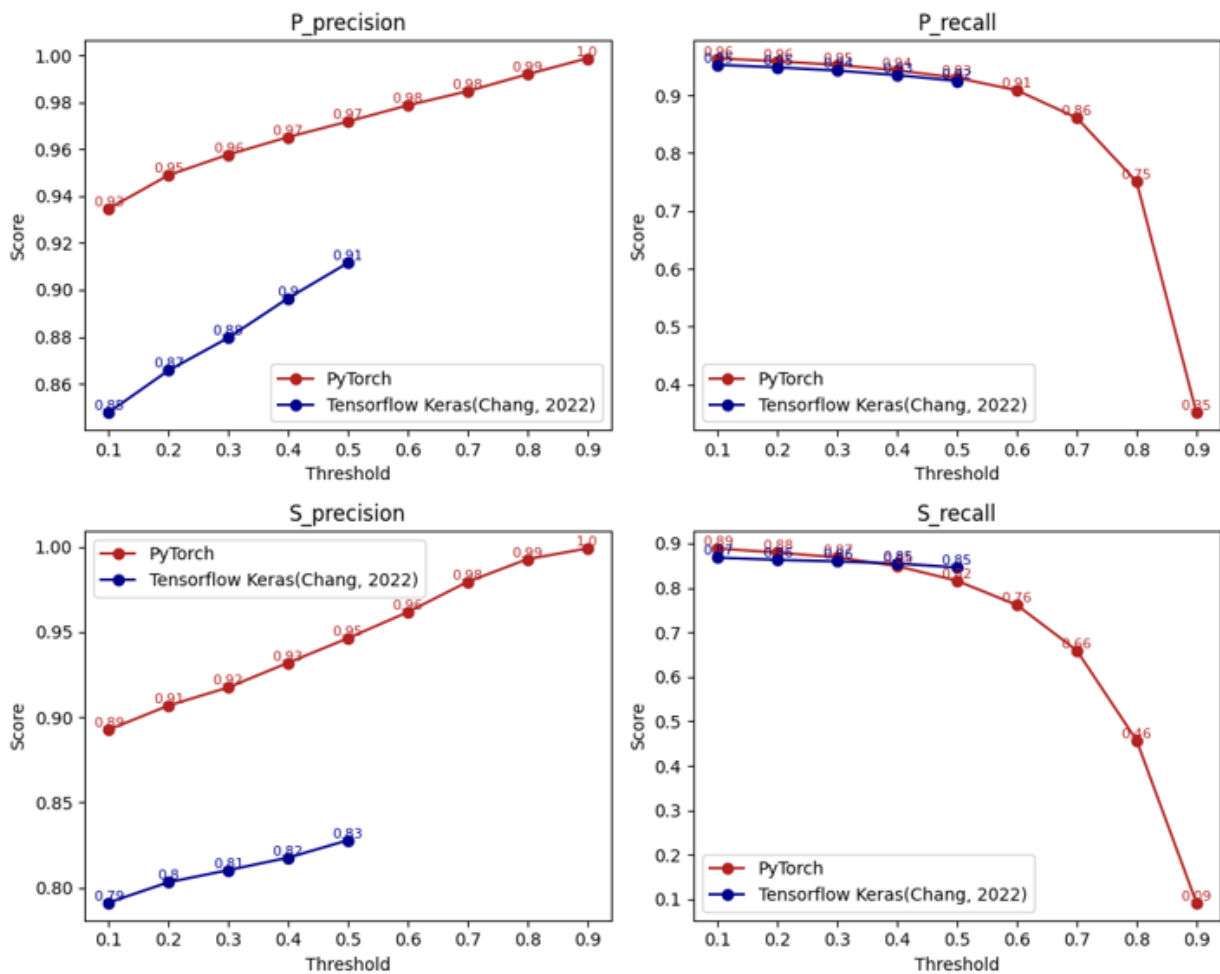


圖 5.2: 波相到時偵測模型-新舊模型性能比較。在不同信心門檻下，第三代的新模型（紅線）和第二代的舊模型的精確率和召回率（藍線），結果顯示第三代新模型的精確率提升約 8%。



5.2 解析生成對抗式網路 (GAN) 的損失值更新

本研究使用靈活的 PyTorch 重設計波相到時偵測模型，在重設計的過程中，發現更詳細的模型運作機制，這在第二代模型相對模糊。例如在 GAN 生成對抗式網路的部分，本研究進一步揭開生成器與辨別器在對抗過程的黑盒子（基本的 GAN 生成對抗式網路請見附錄）。

更新方法對生成對抗式網路 (GAN) 整體是否能被成功訓練起到關鍵因素。如圖 5.3，對於生成器 (Generator) 而言，更新需仰賴兩個損失回饋，其一是資料的回饋，其二是辨別器 (Discriminator) 的回饋。前者是跟據資料標籤的實際值與生成器預測值之間的損失回饋，後者是透過辨別器後，辨別器成功辨識對生成器的損失回饋。已知生成器的更新來源於這兩個回饋，在更新時就面臨兩個問題：

1. 將兩個損失個別更新，抑或是將兩個損失相加後一起更新
2. 兩個損失值之間的權重調整。

本研究實驗後發現，個別更新會讓模型權重值被兩個方向的力量所拉扯，即使調整權重也無法成功被訓練，也就是在損失值的誤差反向傳播中，無法有效找到模型參數的最優解。因此更合適的作法需要先將兩個損失值回饋加總，在一次訓練週期依據加總後損失值只進行一次更新。接著討論是否兩個損失值之間的權重調整，由於兩個損失值來源特性不同，兩個損失值具有尺度上差異，在無法直接進行歸一化的情況下，本研究經測試後對分別來自資料與辨別器的損失，目前使用的權重值為 1,000:1，根據權重將兩個損失值加總，使模型能根據此加權損失的總和學習特徵並達到有效的訓練過程。

而對於辨別器而言，更新則仰賴兩個自身辨識的損失，其一是辨別器辨認「真」資料的損失，其二是辨認「假」資料的損失，前者對應人工標註的資料實際值，後者對應生成器預測值。兩個損失值具有相同尺度，因此不用使用權重，將兩個損失值加總做更新即可。

總而言之，不論是生成器或辨別器，都是在一次訓練週期內，加總各自的兩

個損失值進行一次更新。另外，生成器對於資料損失需有更高的權重來彌補尺度上的差異。

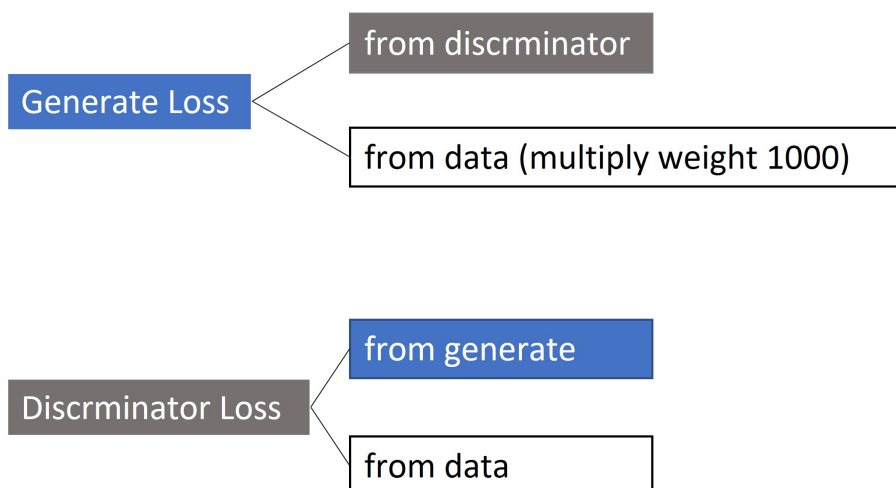


圖 5.3: 生成對抗式網路 (GAN) 之中，生成器與辨別器的損失值計算。



5.3 分析 P 波初動極性模型的信心門檻以及類別權重

	Threshold	P Precision (%)	N Precision (%)	P Recall (%)	N Recall (%)	FM Accuracy (%)*
Aggressive	0.5	97	96	86	89	79 (30/38)
	0.6	97	97	83	88	76 (28/37)
	0.7	98	97	81	85	69 (20/29)
	0.8	97	97	77	82	63 (17/27)
Conservative	0.9	98	99	71	77	75 (15/20)

(Dataset: 2022 ETBATS)

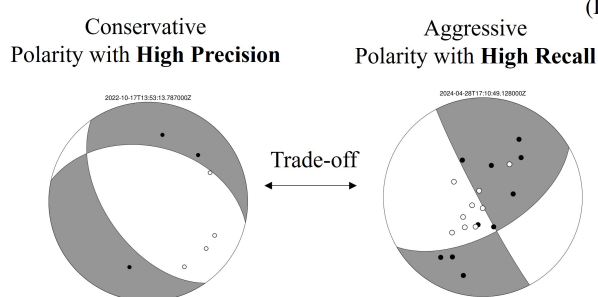
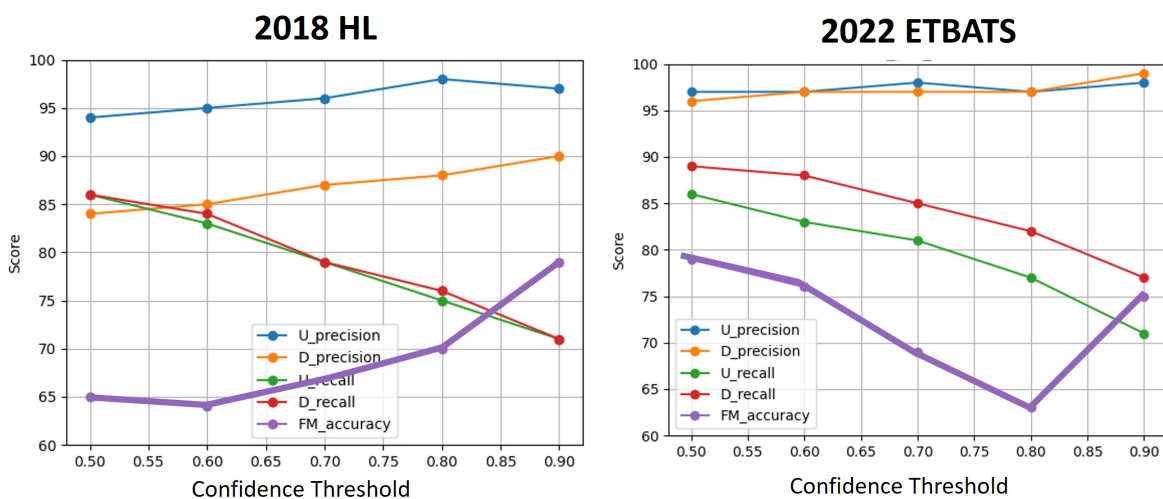


圖 5.4: 精確率與召回率的相對關係

已知隨著信心門檻的變化，精確率跟召回率的變化相反（圖 5.4）。實際應用時，本團隊目前大多使用的資料是如同 2018 花蓮地震網的密集地震網，選用預設的信心門檻為 0.9 即可。以下討論不適用的特例。比較 2018 花蓮地震網和 2022 池上微震觀測網這兩個測站數量不同的地震網，結果表明：2018 年花蓮地震網利用短週期儀器，由於測站較密集，平均可辨識到 20 個極性；而 2020 年池上微震觀測網使用寬頻儀器，由於測站較稀疏，平均極性數量為 7。在測站疏密程度不同的情況下，信心門檻的調整顯示了不同的影響：對於測站密集的地震網，提高信心門檻時，震源機制解總數減少，但預測正確的數量保持不變；對於測站稀疏的地震網，增加信心門檻則導致可辨識的極性數量少到足以影響震源機制解的解析，震源機制解總數和預測正確的數量都下降。也就是說對於極性數量少的資料集，太保守的模型會讓極性數量不夠，反而會讓震源機制解的準確率變差（圖 5.5），所以即使極性預測較精確，當該資料的測站較稀疏，並且信心門檻降低對精確率影響較小的時候，就應該選用較低信心門檻，來補足極性數量。或是反



過來當前一步驟的波相到時偵測準確率不佳，並且具有足夠的極性數量時，應該選用信心門檻更高或是更保守的模型。



Distribution of number of polarities (confidence threshold=0.9)




圖 5.5: 不同信心門檻下的極性模型性能與震源機制解準確率。2018 花蓮地震網 (左) 和 2022 池上微震觀測網 (右)。藍線與橘線分別為上下動的精確率，紅線與綠線為上下動的召回率，紫線為震源機制解的準確率。

除了信心門檻作為保守程度的微幅調整，因為本研究以區域型密集地震網資料為基礎，擁有較多測站資料的優勢使我們能設計更嚴苛的極性分類模型，並且訓練資料本身不可辨識的數量比較少，因此我們還嘗試在不可辨識的類別增加損失值的權重，使模型在不確定狀態下更傾向於選擇「不可辨識」類別，以此訓練不同保守程度的模型，可應對未來資料集的特性來選擇合適的模型（圖 5.6）。




圖 5.6: P 波初動極性模型-類別權重實驗。(a) 當「不可辨識」損失權重為 1 倍 (b) 2 倍 (c) 5 倍，混淆矩陣顯示，模型在不確定狀態下更傾向於選擇「不可辨識」類別，提高了模型的精確率而犧牲了召回率，可辨識極性數量減少。本研究提供不同保守度的模型，使用者可根據資料集選擇合適的模型，目前使用權重為 1 倍。



5.4 分析模型的學習過程

本研究在模型訓練過程中記錄驗證資料的召回率與精確率，隨著模型訓練的訓練週期增加，觀察模型性能的變化，了解模型學習趨勢。

在波相到時偵測模型訓練過程中隨著訓練週期增加，代表機率分布的三角標籤逐漸長出峰值（圖 5.7），精確率與召回率皆逐步提高。

相比之下，在 P 波初動極性模型的訓練過程中，隨著模型訓練的訓練週期增加，本研究發現在訓練初期，混淆矩陣顯示模型傾向預測出可辨識極性，即較高的召回率，較低的精確率。隨著訓練週期增加，模型經人工標籤的影響，逐步學習「不可辨識」的辨識標準，召回率下降，而精確率提升（圖 5.8）。

本研究認為，對波相到時偵測模型來說，隨著訓練週期增加，召回率和精確率都逐漸提升，到 70 個訓練週期後趨於穩定。相比之下，由於 P 波初動極性模型除了原有的「上動」和「下動」，額外增加「不可辨識」的類別，並且在人工標籤「不可辨識」的類別較少。因此隨著訓練週期增加，對 P 波初動極性模型有明顯的召回率和精確率的權衡現象，先有較高的召回率，而後慢慢導正到較高的精確率（圖 5.9）。

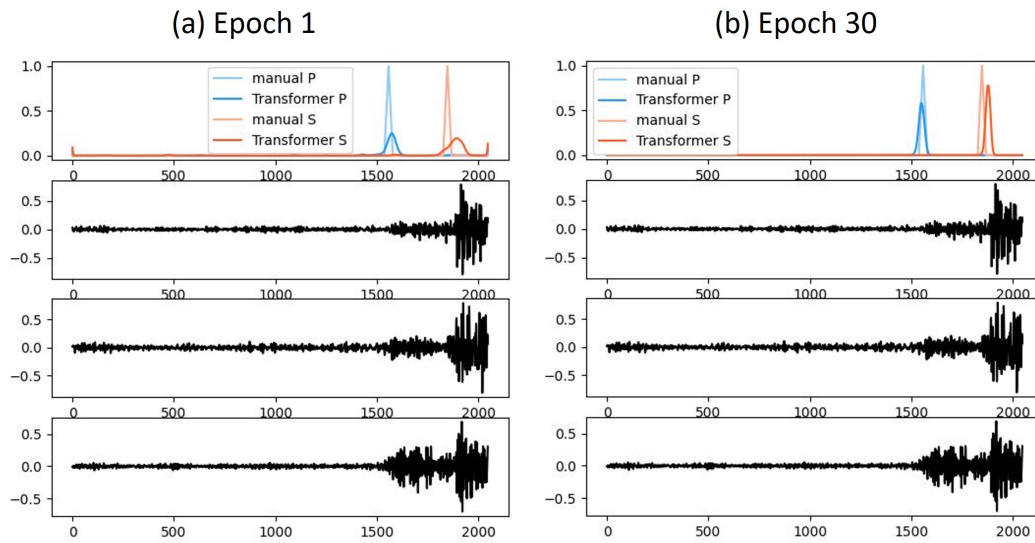



圖 5.7: 波相到時偵測模型的訓練過程。直接觀察預測的到時三角標籤，在訓練第一次預測到時會如同波形；在訓練初期，模型傾向預測為躺平的線，並隨著訓練週期增加，逐步形成三角標籤的尖端。

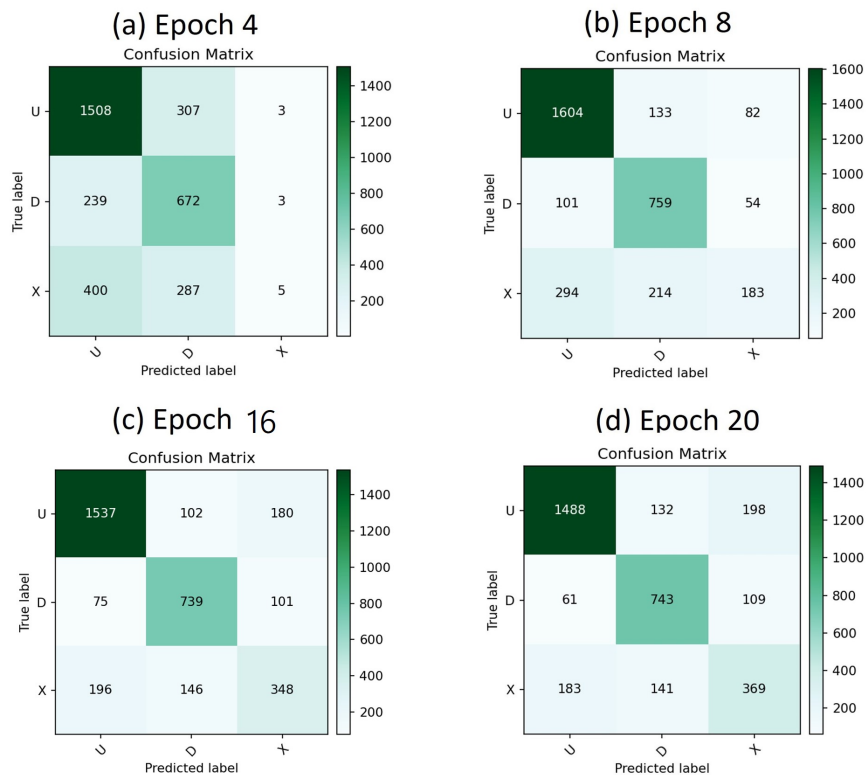



圖 5.8: P 波初動極性分類模型的訓練過程。以混淆矩陣觀察各類別預測情況，推測可能是因為人工標籤「不可辨識」的類別較少，因此極性分類模型初期傾向預測出可辨識極性，隨著訓練週期增加，逐步學習「不可辨識」的辨識標準。



(a)



(b)




圖 5.9: 模型隨著訓練週期模型的學習傾向。(a) 波相到時偵測模型，隨著訓練週期增加，波相到時偵測模型的精確率和召回率都逐漸提升，到 70 個訓練週期後趨於穩定。(b) P 波初動極性分類模型，隨著訓練週期增加，召回率下降，而精確率提升。



5.5 分析模型設計

在本研究中，也探討了波相到時偵測模型與 P 波初動分類模型在模型設計上的差異（表 5.1）。通過對問題定義的了解，適當的模型設計才能有效訓練模型。

以下將進行具體說明：

波相到時偵測模型類似影像辨識中的物件分割，屬於序列轉序列的任務，模型的最後輸出是 P 波、S 波和雜訊的到時機率分布，每個波相的輸出長度與輸入的波形長度相同，即每個資料點會個別獨立地，對應一個介於 0 到 1 之間的機率值，做為預測為正確到時的機率值，這就相當於每個資料點做二元分類。因此在最後的輸出層選用的是 Sigmoid 函數，將每個實數映射到 0 到 1 之間的機率。而在比對預測輸出與實際值之間的損失函數的選擇上，對應二元分類的性質，選擇二元交叉熵損失而非一般的交叉熵損失，才能有效評估。

P 波初動極性分類則是一個標準的多類別分類任務，最後輸出是上動、下動和不可辨識，對應三個介在 0 到 1 之間的一組機率值，總合為 1，即一組向量會對應到一組機率值，這就相當於多元分類。因此在最後的輸出層選用的是 Softmax 函數，將一組向量映射到一組機率，這組機率每個機率值 0 到 1 之間，總和為 1。而對應的損失函數就用一般的交叉熵損失即可。

表 5.1: 分析模型設計

	波相到時偵測模型	P 波初動極性模型
任務類型	物件分割	多類別分類
模型	Transformer	卷積神經網路
輸入	三分量波形	單分量波形（垂直分量）
輸出	三個波相到時（P 波, S 波, 雜訊）	三個極性類別（上動, 下動, 不可辨識）
輸出形狀	(3, 2048)	(1, 3)
輸出層	Sigmoid 函數	Softmax 函數
損失函數	二元交叉熵損失	交叉熵損失

第六章 實驗三一系統整合與永續

SeisBlue AI 地震資料處理平台專注於區域密集地震網的微震偵測，打造屬於台灣本土技術自主的模型。目前系統整合了地震觀測流程與軟體工程，同時增進功能與非功能的部分（圖 6.1 和圖 6.2），持續完善朝自動化平台邁進。SeisBlue 作為一個從 2018 開始的七年專案，為了讓軟體能夠隨著團隊一起成長，解決開發效率的瓶頸，並提升系統使用的便利性，在這裡介紹軟體工程中讓專案持續發展的四個方向：1. 如何提高程式碼的維護性與擴展性 2. 如何減少組織中溝通與協作成本 3. 如何提高使用者操作的便利性 4. 技術評估與取捨。

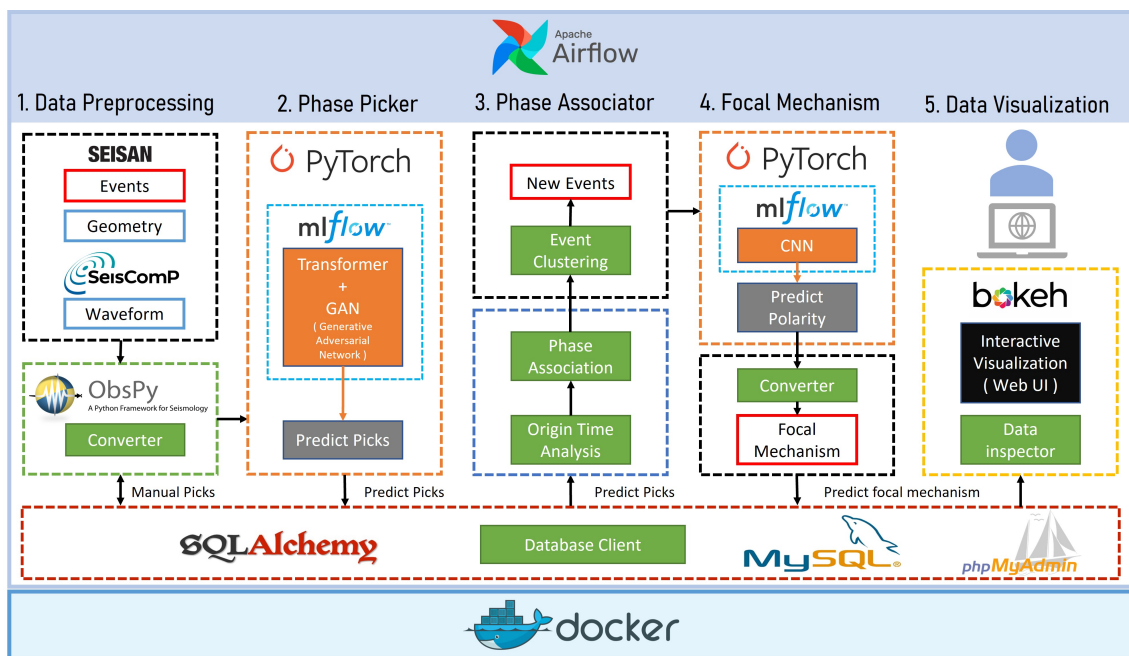


圖 6.1: 第三代 Seisblue 架構



圖 6.2: 非功能軟體的用途。為了讓系統長期維護與傳承，需要打造敏捷開發與良好紀錄，讓團隊溝通有效率，確保能讓大家一起快速朝向同個方向前進。

6.1 如何提高程式碼的維護性與擴展性

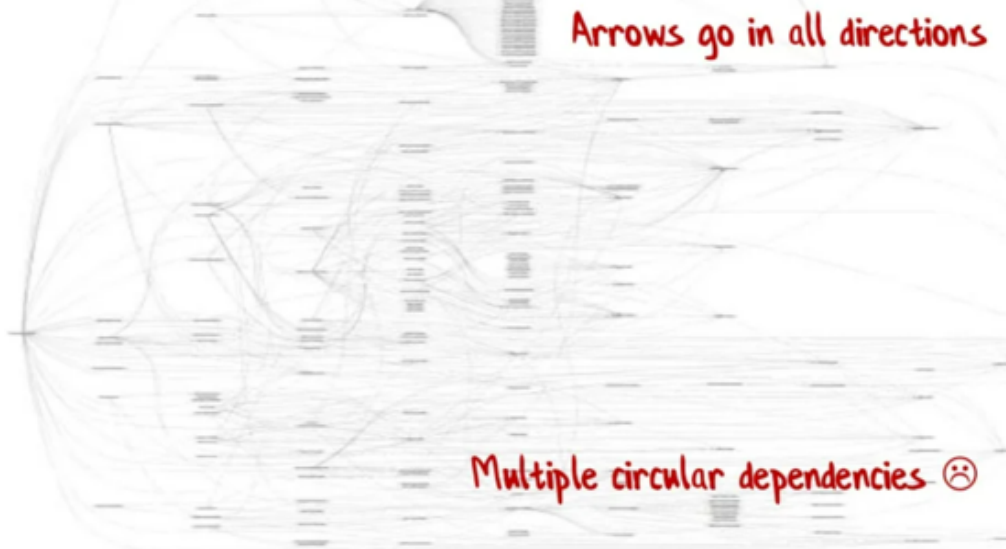
6.1.1 重構與管線化—管線導向式的程式碼風格 (POP)

對於一個希望系統延展生命週期的專案而言，在增加系統功能之前，重構程式碼可說是必經之路。因為系統開發過程並非一步到位，在開發初期，為了能夠讓程式順利執行已經花費了不少精力，往往會留下許多冗余或是特殊解法的程式碼，如果因為時程緊迫沒有辦法花時間處理，這些程式碼經過時間推移後會變得難以理解，漸漸成為未來改動程式碼的阻礙，就像欠債一樣，所以又有人將這種狀況叫做技術債，在發展過程中需要有計劃的透過重構來償還技術債，才能夠在未來減少改變需求所需要的成本。因此，本研究為了縮小功能修改對程式碼範圍的影響，我們採用了資料管線模式作為主架構，重新整理了複雜的物件關係為明確方向的資料流 (圖 6.3)。此外，我們將所有實驗中需調整的參數移到程式的表層，以降低未來潛在的錯誤發生率。



(a)

Object-oriented: Real-world dependency graph



(b)

Pipeline-oriented: Real-world dependency graph



圖 6.3: (a) 物件導向式 (Object-oriented programming, OOP)，強調相關功能由類別打包設計 (b) 管線導向式 (Pipeline-oriented programming, POP)，強調功能由管線化依序設計 (Wlaschin, 2014)。本研究從物件導向式 (OOP) 部分重構成管線導向式 (POP)，能解決程式碼在未來挑整時，牽一髮動全身的問題。



6.2 如何減少組織中溝通與協作成本

在開發和除錯過程中，大約八成的時間花在閱讀現有程式碼上。提高程式碼的可讀性不僅可以縮短開發時間，還方便新成員的加入和接手。此外，由於多人協作時常見的錯誤多源於程式或環境版本差異，因此需要系統地記錄可能隨時間變化的資訊，以專注解決核心問題。目前，我們的專案已引入程式碼版本控制、環境版本控制和模型版本控制。

6.2.1 程式碼版本控制—Git

本研究使用目前廣泛使用的程式碼版本控制系統 Git，不僅提供程式碼存儲和版本控制功能，而且能協調多人工作流程，使團隊成員能夠追蹤和合併變更。此外，Git 還提供了分支管理功能，讓開發者可以在不干擾主線開發的情況下，平行開展多個功能開發或修復工作。通過使用 Git，團隊能夠有效地控制程式碼的版本，解決版本差異引起的問題，並提高程式碼品質與合作效率（圖 6.4a）。


6.2.2 模型版本控制—MLFlow

本研究整合 MLFlow 開源平台，用於實驗過程的追蹤與監控，包括參數記錄、程式碼版本控制、指標評估及實驗結果的紀錄。透過 MLflow 能有效地管理模型在開發階段的實驗，協助在高效實施大規模模型實驗時能記錄模型的超參數、指標、損失值變化與模型路徑等等，如模型的產銷履歷。不僅促進模型開發的高效率，也保障實驗過程的透明度與可重現性，實現模型的版本控制（圖 6.4b）。

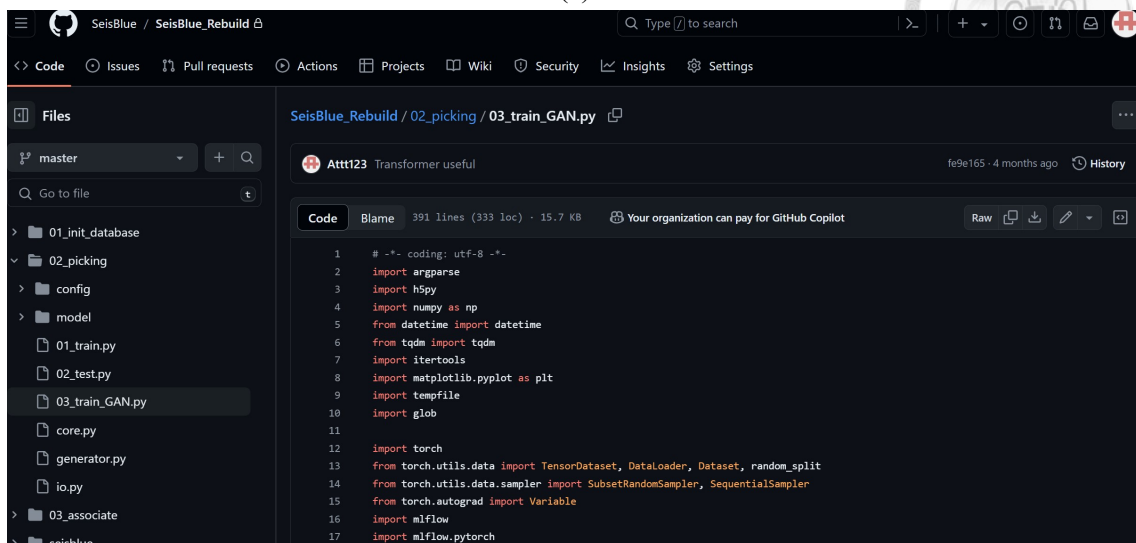


6.2.3 環境套件版本控制—Docker

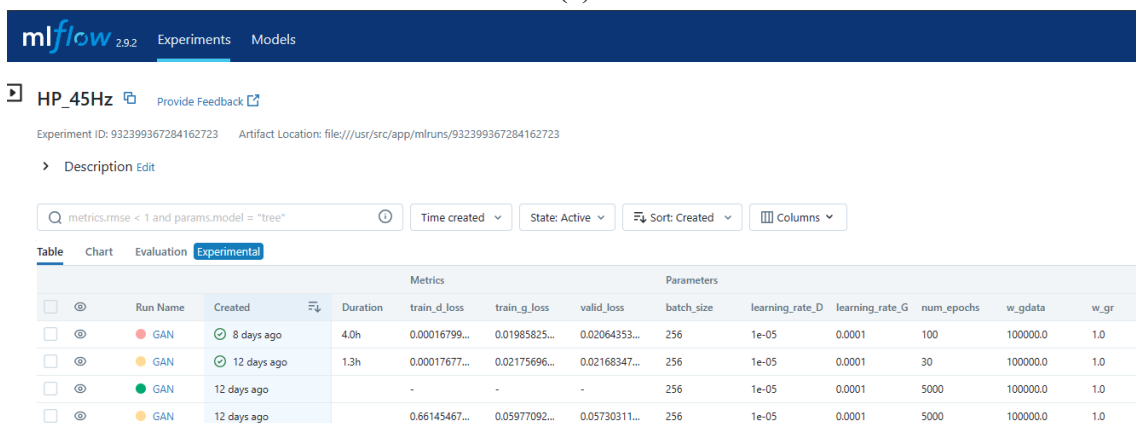
本研究引入 Docker 容器化技術，可以在容器中封裝程式套件的執行環境和配置，從而在不同的開發和生產環境中保持一致性。使用 Docker 可以方便地管理和版本控制應用程式所需的所有環境套件，確保所有團隊成員和部署環境都使用相同的設定，並且能配合管線化模組的系統設計，進一步根據不同的任務環境將環境獨立。這降低了運行環境差異帶來的風險，並提高了應用的可移植性和可重現性。此外，除了原有的 Docker，第三代系統也建置 Docker Compose，應用在 Airflow 中協助多任務之間的環境切割（圖 6.4c）。



(a)



(b)



(c)

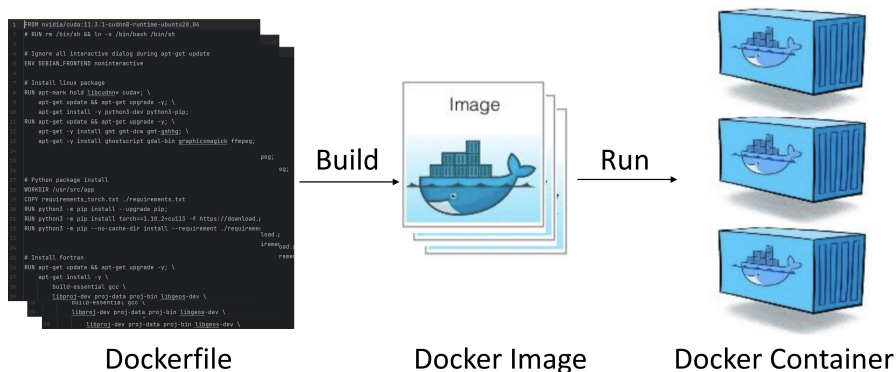


圖 6.4: 為了減少組織中溝通與協作成本，加入 (a) 程式碼 (b) 模型 (c) 環境套件的版本控制。



6.3 如何提高使用者操作的便利性

6.3.1 自動化監控任務與問題回溯—Airflow

本研究整合 Airflow 提供的線上平台，用於自動化、排程和監控複雜的工作流程。通過定義 DAG（有向無環圖），Airflow 可以追蹤任務的依賴性、進度和執行狀態。此外，它能在任務失敗時重新執行任務及錯誤通知，並能追蹤和回溯問題。使用 Airflow 自動化任務不僅提高了操作的效率，同時也減少了人工錯誤，提升了系統的穩定性和可靠性（圖 6.5）。

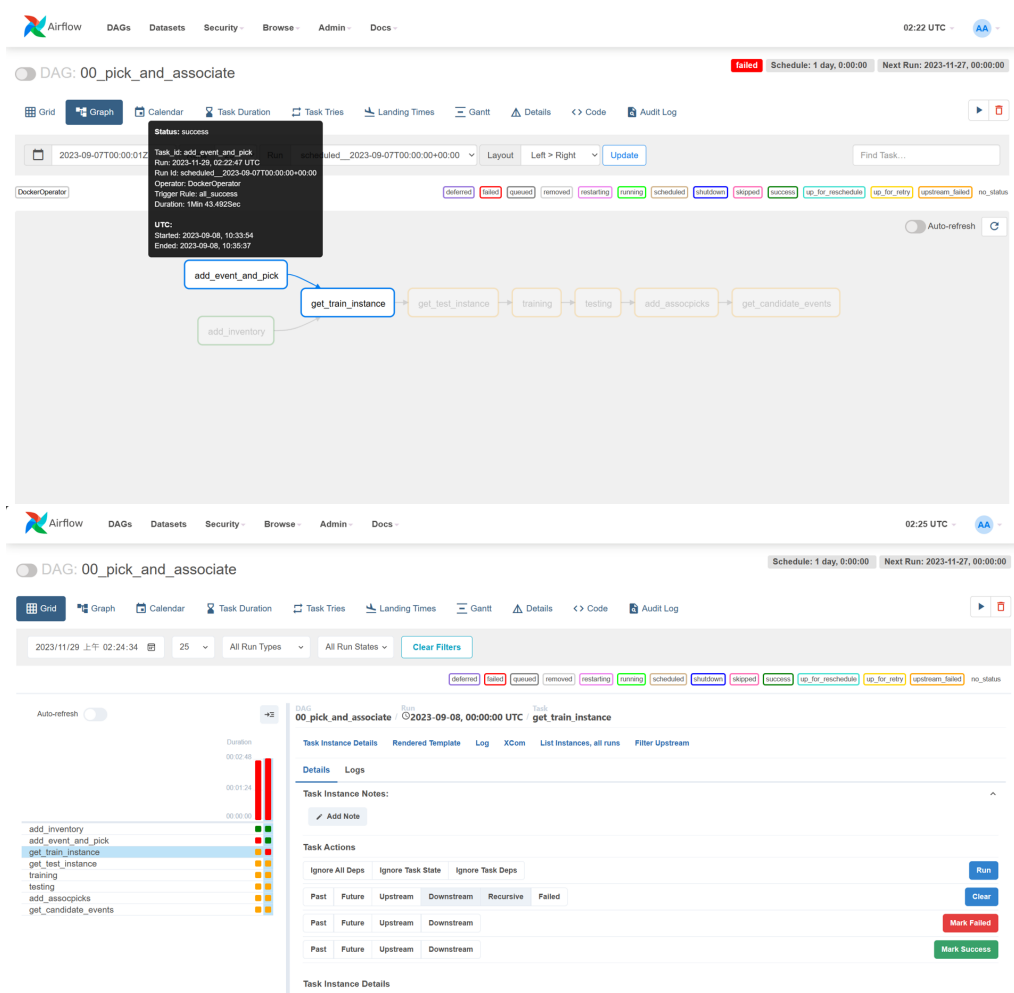


圖 6.5: 自動化監控任務與問題回溯—Airflow，支持大數據的排程與監控，協助自動化流程。



6.3.2 高效的資料儲存與檢視—關聯式資料庫 (SQL) 和階層式資料格式 (HDF5)

本研究為了解決大規模結構化資料的存儲與檢索問題，特別是在處理具挑戰性的波形資料方面。我們採用 MySQL 資料庫以及 HDF5 文件進行資料管理。MySQL 是一個廣泛使用的開源關聯式資料庫管理系統，它允許高速的資料存取與檢索，適合用於存儲除波形資料外的詮釋資料和其他結構化資訊。另一方面，SQLAlchemy 作為一個適用於 Python 的 SQL 工具包和對象關係映射器 (ORM)，提供了一種將資料庫操作映射到物件導向模式的方法，從而簡化了資料操作並提升了開發效率。為了方便資料庫的管理，本研究同時採用 phpMyAdmin 作為與 MySQL 互動的網頁介面，進一步提升用戶的使用體驗 (圖 6.6)。

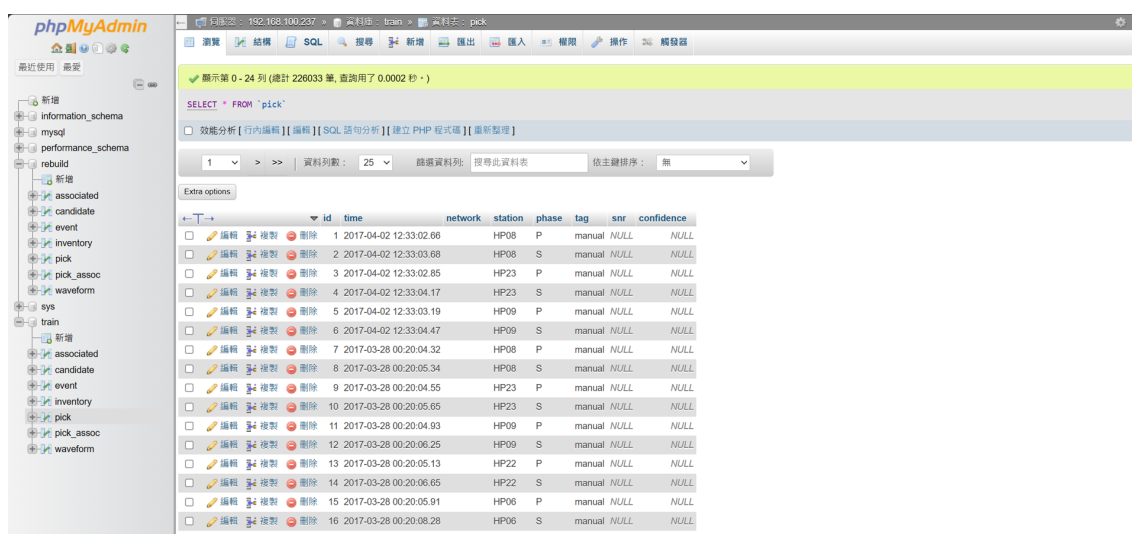


圖 6.6: 關聯式資料庫—MySQL

此外，考慮到波形資料的資料量過於龐大，直接存儲於關聯式資料庫中並不實際。我們在第二代系統使用 TFRecord 二進制文件來儲存波形資料，但在開發階段遇到難以增減欄位，以及二進制資料難以檢視的問題。因此，新一代的系統中，我們引入了 HDF5 格式以處理這類大量複雜或層級化的資料 (圖)。HDF5 提供一種靈活的方式來存儲和組織大資料集，透過其階層化的結構支援多種資料型態。



6.3.3 簡潔的使用者參數配制文件

本研究設計簡潔的 YAML 階層式文檔，使用者只需修改該文檔即可更新配置，配合 Jinja 模板支援在文件中動態替換變數，就可以將常改的路徑參數置頂，用變數的方式將路徑引入不同任務。不僅提高了配置的靈活性，也簡化了系統維護工作，讓使用者參數和源碼分離，使得用戶更容易修改參數而不必深入理解底層程式碼結構（圖 6.8）。

```
1 global:
2   events_dir: /mnt/events/2024_HL
3   dataset_name: 2024_HL
4   waveforms_dir: /mnt/data
5   sub_waveforms_dir: /mnt/data/2024
6   hyp_filepath: /mnt/events/2024_HL/STATION0.HYP
7   def_filepath: /mnt/events/2024_HL/SEISAN.DEF
8   response_dir: /mnt/events/2024_HL/ResponseFiles
9   network: HL
10  reverse: True
11  with_manual: False
12  threshold_error: 15
13  threshold_azi: 200
14  threshold_ain: 40
15  method_id: FPFIT
16  gmt_script_dir: ./gmt_script
17  pick_evaluation_mode: automatic
18  outputfile: gmap_2024_HL.html
19
20 process_inventory:
21   hyp_filepath: "{{ global.hyp_filepath }}"
22   sub_waveforms_dir: "{{ global.sub_waveforms_dir }}"
23   network: "{{ global.network }}"
24
25 process_event:
26   events_dir: "{{ global.events_dir }}"
27   dataset_name: "{{ global.dataset_name }}"
```

圖 6.8: 使用者參數配制文件—YAML 階層式文檔和支援在文件中動態替換變數的 Jinja 模板工具，提高使用者調整參數的便利性。



6.3.4 互動式地圖網頁 (Web UI)

目前本研究以 bokeh 設計測試版的互動網頁 (圖 6.9)，透過研究區域之平面地圖與剖面，快速檢視地震觀測結果。除了基本地圖的功能，透過懸停 (Hover) 可察看對應的地震資訊，並增加對於時間與測站包覆度的結果篩選，增加震源機制解的 P 軸和 T 軸圖層，未來可整合波形資料的顯示以及資料上傳和下載等等功能。以下為功能列表：

1. 地圖移動和縮放
2. 懸停 (Hover) (資訊: 經緯度、時間、深度、規模、含上下動的震源機制解等等)
3. 改變背景地圖樣式 (街道、簡潔、衛星影像)
4. 調整震源機制解的顯示大小
5. 選擇欲顯示圖層 (背景地震、測站、震源機制解)
6. 結果篩選 (時間區間、測站方位角覆蓋率、入射角覆蓋率)
7. 地震目錄
8. 點選地震目錄與地圖點位交互
9. 震源機制解的 P、T 軸
10. 下載
11. 重置


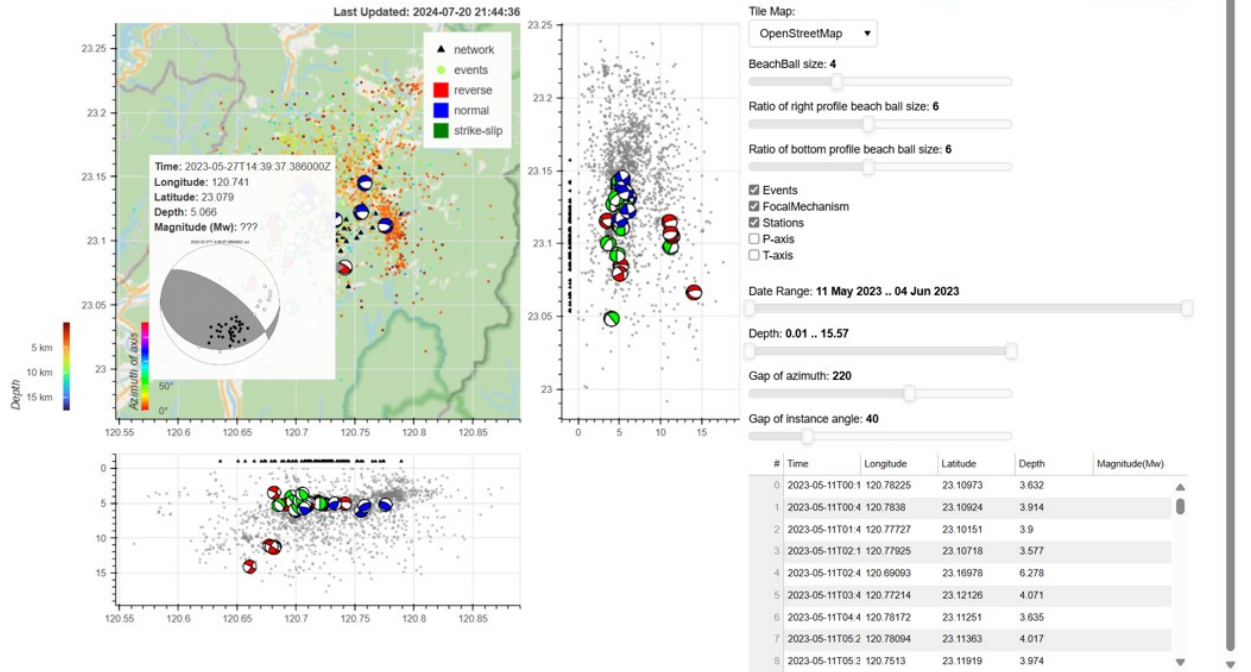


圖 6.9: 互動式地圖網頁 (Web UI)。藉由多功能互動，大幅提升結果檢視的方便性。黑色三角形為測站。原點為背景地震，由淺震到深震標記為由紅到藍。海灘球代表震源機制解，紅色代表逆斷層，藍色代表正斷層，率色代表走向滑移斷層。



6.4 技術評估與取捨

技術導入的決策需考量多方面因素，包括目前技術的成熟度、所面臨的技術瓶頸、團隊的技術能力、實施成本以及風險評估等。因此，一種技術在初期可能適用，但隨著團隊的成長和發展，可能需評估並轉向更合適的技術方案。在硬體技術方面，GPU 加速和平行計算不僅能顯著提高模型訓練和預測的速度，還能增強知識的迅速傳遞和積累。隨系統生命週期增加和科技技術進步，應持續評估和更新使用的軟硬體設施，保持技術競爭力，延續專案系統的生命週期，在技術評估的部分由團隊 SeisBlue 開發者黃俊銘研究生作主要技術評估，再由本研究做開發實踐。表 6.1 顯示第三代系統在軟體部分與第二代系統的異同，將部份技術沿用升級或以其他軟體作替代。本研究做為第三代的系統開發，涉及表 6.1 的第三代所有流程，解決第二代系統的問題，轉型成敏捷式開發環境，並打造更完善的自動化流程。



表 6.1: 技術評估與取捨

Technology	version 1	version 2	version 3 (alpha)
Final Product	Phase Picking	Associated Event	Focal Mechanism
Deep Learning	TensorFlow Keras	–	PyTorch
Picking Model	Unet	Transformer + GAN	Rebuild Transformer + GAN
Polarity Model	x	x	CNN
Programing Style	OOP	–	Pipeline + OOP
Serialization	Pickle	TFRecord	HDF5
ORM	SQLAlchemy	–	–
Database	SQLite	MySQL + PHP-MyAdmin	–
Seismic Data Processing	Obspy	–	Obspy + Seisan
Result Visualization	Jupyter Notebook	–	Bokeh Web UI
Training Record	Manual	–	MLFlow
Model Version Control	Manual	–	MLFlow
Automation	Manual	–	Airflow
Program Version Control	Git + GitHub	–	–
Environment Management	Docker	–	Docker Compose
Hardware (GPU)	1080 Ti	3090 Ti	–

第七章 結論



本研究成功開發與完善了第三代 SeisBlue AI 地震觀測平台，透過深度學習技術的應用，有效提升了地震資料處理的自動化程度和效率，特別是在微震監測領域。本研究的重點在於對舊系統的擴展、強化和整合，並顯著提升了地震波相到時偵測的精確率，以及兼具效率與品質的震源機制解之自動化解析。

在實驗一系統擴展方面，本研究開發了基於卷積神經網絡的模組 SeisPolar，專門用於分類地震資料中的 P 波極性，進一步通過 FPFIT 方法解析地震震源機制。在實驗二系統強化方面，將波相到時偵測模型由原來的 TensorFlow 1 框架轉移到 PyTorch，增加了系統的靈活性，從而提高了未來模型調整和實驗開發的效率，有助於後續將人工檢驗資料回饋，以此來提高模型性能。

研究結果顯示，自動識別 P 波極性的模型在極性解析成震源機制後，透過 Kagan 測試方法評估顯示 80 % 的 Kagan 角度小於 40 度，證明了模型預測的高準確性。此外，目前經過模型重設計和模型訓練時更多的參數實驗，波相到時偵測模型的精確率已相比第二代的舊模型提升約 8%，並解決了舊模型提早波相到時偵測的傾向。

在實驗三系統整合方面，本研究結合軟體技術的優勢，第三代 SeisBlue 系統不僅顯著提升了資料處理的速度，透過模組管線化和更靈活的深度學習框架，更促進了模型性能的持續進步，提供快速開發的新可能性，盡可能達到系統長期應用與運維的需求。相較於其他小規模且生命週期短的系統，本研究須更強調重構與靈活度的重要性，地震波形資料的特徵複雜度是其中一個具體原因。深度學習模型的性能依賴於訓練資料的特徵，因此在實際應用中必須謹慎考慮所要預測的資料是否與訓練資料在特徵上存在顯著差異，如訊噪比過低、地震儀類型差異等。這需要評估是否需要將這些不同的樣本加入到訓練集中，或是對經過人工檢驗的預測資料進行再訓練。在這些情況下，快速開發與調整的系統能力便成為提

升模型性能的關鍵。

總體而言，本研究實現了從地震資料的連續處理到波相到時偵測、地震定位、地震規模計算及震源機制解析的半自動化工作流程。對於地震活躍的台灣地區，該系統將協助即時評估，有效捕捉大量小規模地震資訊，高效獲取活動構造的初步評估。透過人工檢視後的地震目錄為後續地震研究提供了可靠的資料，例如高解析度的速度層析成像。透過本研究的一體化地震觀測系統，有效解決地震觀測的效率瓶頸，兼顧此長期專案的開發與運維，將持續為地震領域做出實質貢獻。





參考文獻



- 張立衡、郭陳濤、郭俊翔 (2022)。利用深度學習辨識地震波 p 與 s 到時以及後續關聯與定位。國立中央大學地球科學系暨研究所碩士論文。
- 甘志文、蒲新杰、李巧盈、許焯志、蕭乃祺 (2015)。中央氣象局自動化震源機制解算。氣象學報，69-86。
- 黃俊銘、郭陳濤、王乾盈 (2020)。利用深度學習為基礎的 p 波自動挑波套件。國立中央大學地球科學系暨研究所碩士論文。
- Allen, R. V. (1978). Automatic earthquake recognition and timing from single trace. *Bulletin of the Seismological Society of America*, 68(5):1521–1532.
- Aybar, B. (2020). What is not machine learning. <https://www.slideshare.net/slideshow/what-is-not-machine-learning-burak-aybar/238644733#15>.
- Center, I. D. M. (2024). Data distribution. <https://ds.iris.edu/data/distribution/>.
- Chang, Y. H., Hung, S. H., and Chen, Y. L. (2019). A fast algorithm for automatic phase picker and event location: Application to the 2018 Hualien earthquake sequences. *Terr. Atmos. Ocean. Sci.*, 30:435–448.
- Chen, C. and Holland, A. A. (2016). PhasePapy: A Robust Pure Python Package for Automatic Identification of Seismic Phases. *Seismological Research Letters*, 87(6):1384–1396.
- Creswell, A., White, T., Dumoulin, V., Arulkumaran, K., Sengupta, B., and Bharath, A. A. (2018). Generative adversarial networks: An overview. *IEEE Signal Processing Magazine*, 35(1):53–65.
- Dziewonski, A., Chou, T., and Woodhouse, J. (1981). Determination of earthquake source parameters from waveform data for studies of global and regional seismicity. *Journal of Geophysical Research: Solid Earth*, 86(B4):2825–2852.
- Ekström, G., Nettles, M., and Dziewoński, A. M. (2012). The global CMT project 2004–2010: Centroid-moment tensors for 13,017 earthquakes. *Physics of the Earth and Planetary Interiors*, 200:1–9.
- Hardebeck, J. L. and Shearer, P. M. (2003). Using s/p amplitude ratios to constrain the focal mechanisms of small earthquakes. *Bulletin of the Seismological Society of America*, 93(6):2434–2444.
- Havskov, J., Voss, P. H., and Ottemöller, L. (2020). Seismological Observatory Software: 30 Yr of SEISAN. *Seismological Research Letters*, 91(3):1846–1852.

Huang, C. M., Chang, L. H., Kuo-Chen, H., and Zhuang, Y. (2023). Seisblue: A deep-learning data processing platform for seismology. In EGU General Assembly Conference Abstracts, pages EGU–13927.

Huang, K. (2023). Backpropagation algorithm. <https://medium.com/%E4%BA%BA%E5%B7%A5%E6%99%BA%E6%85%A7-%E5%80%92%E5%BA%95%E6%9C%89%E5%A4%9A%E6%99%BA%E6%85%A7/%E5%8F%8D%E5%90%91%E5%82%B3%E6%92%AD%E7%AE%97%E6%B3%95-backpropagation-algorithm-71a1845100cf>.

Ihianle, I. K., Nwajana, A. O., Ebebuwa, S. H., Otuka, R. I., Owa, K., and Orisatoki, M. O. (2020). A deep learning approach for human activities recognition from multimodal sensing devices. *IEEE Access*, 8:179028–179038.

Jian, P.-R., Tseng, T.-L., Liang, W.-T., and Huang, P.-H. (2018). A new automatic full-waveform regional moment tensor inversion algorithm and its applications in the Taiwan area. *Bulletin of the Seismological Society of America*, 108(2):573–587.

Kagan, Y. Y. (1991). 3-d rotation of double-couple earthquake sources. *Geophysical Journal International*, 106(3):709–716.

Kuo-Chen, H., Guan, Z. K., Sun, W. F., Jhong, P. Y., and Brown, D. (2019). Aftershock sequence of the 2018 mw 6.4 Hualien earthquake in eastern Taiwan from a dense seismic array data set. *Seismological Research Letters*, 90(1):60–67.

Mallick, S. (2023). Understanding convolutional neural networks (CNN). <https://learnopencv.com/understanding-convolutional-neural-networks-cnn/>.

Mousavi, S. M., Ellsworth, W. L., Zhu, W., Chuang, L. Y., and Beroza, G. C. (2020). Earthquake transformer—an attentive deep-learning model for simultaneous earthquake detection and phase picking. *Nature communications*, 11(1):3952.

Reasenber, P. and Oppenheimer, D. (1986). FPFIT, FPLOT and FPPAGE; Fortran computer programs for calculating and displaying earthquake fault-plane solutions. Technical Report 739, US Geological Survey (USGS).

Reid, H. F. (1910). The California earthquake of April 18, 1906. Report of the State Earthquake Investigation Commission, 2:16–18.

Sanderson, G. (2024). Attention in transformers, visually explained | chapter 6, deep learning. <https://www.youtube.com/watch?v=eMlx5fNoYc>.

Sun, W.-F., Pan, S.-Y., Huang, C.-M., Guan, Z.-K., Yen, I.-C., Ho, C.-W., Chi, T.-C., Ku, C.-S., Huang, B.-S., Fu, C.-C., and Kuo-Chen, H. (2024). Deep learning-based earthquake catalog reveals the seismogenic structures of the 2022 mw 6.9 Chihshang earthquake sequence. *Terrestrial, Atmospheric and Oceanic Sciences*, 35(1):5.

Tang, K., Xu, D., Liu, H., and Zeng, Z. (2021). Context module based multi-patch hierarchical network for motion deblurring. *Neural Processing Letters*, 53:211–226.

Uchide, T. (2020). Focal mechanisms of small earthquakes beneath the Japanese is-lands based on first-motion polarities picked using deep learning. *Geophysical Journal International*, 223(3):1658–1671.

USGS (2022). Seismotectonic regime earthquake calculator (STREC). <https://github.com/usgs/strec>.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., and Polosukhin, I. (2017). Attention is all you need. In *Advances in neural information processing systems*, volume 30.

Wlaschin, S. (2014). Railway oriented programming. <https://fsharpforfunandprofit.com/pipeline/>.

Zhao, M., Xiao, Z., Zhang, M., Yang, Y., Tang, L., and Chen, S. (2023). Ditingmotion: A deep-learning first-motion-polarity classifier and its application to focal mechanism inversion. *Frontiers in Earth Science*, 11:1103914.

Zhu, W. (2020). Technical background: Classification vs segmentation. https://www.bilibili.com/video/BV19K4y1Y7uC/?spm_id_from=333.337.search-card.all.click&vd_source=58f19edb1780051260726b99d81422b0.

Zhu, W. and Beroza, G. C. (2019). Phasenet: a deep-neural-network-based seismic arrival-time picking method. *Geophysical Journal International*, 216(1):261–273.

Zvornicanin, E. (2023). Understanding k-fold cross-validation. <https://www.baeldung.com/cs/k-fold-cross-validation>.

附錄 A — 深度學習方法簡介



深度學習屬於機器學習的一個子領域，都是為了達到人工智慧的目的。深度學習主要基於神經網路架構，透過神經元的疊加和非線性激發函數的結合形成深層複雜的神經網路，並透過誤差反向傳播法（Back Propagation）進行參數更新，以此解決複雜的非線性問題（圖 A.1）。神經網路相比其他機器學習方法，其特點是能夠從大量資料中自動學習複雜的特徵，無需人工設計特徵萃取的規則，協助繁複和例行性的工作（圖 A.2）。通常要開發一個深度學習專案會經歷問題定義、模型設計、資料前處理、模型訓練與驗證（人工調整模型的超參數）、模型測試和性能評估、未知資料預測、整合與部署應用（如圖 A.3）。而對於監督式的深度學習，模型訓練的部分具體而言，在每次訓練週期會經歷從訓練資料中學習特徵，轉化為模型參數，神經網路輸出預測答案，對答案然後將結果反饋，最後根據反饋來優化模型參數。以下將依上述流程簡介本研究所涵蓋的深度學習領域。

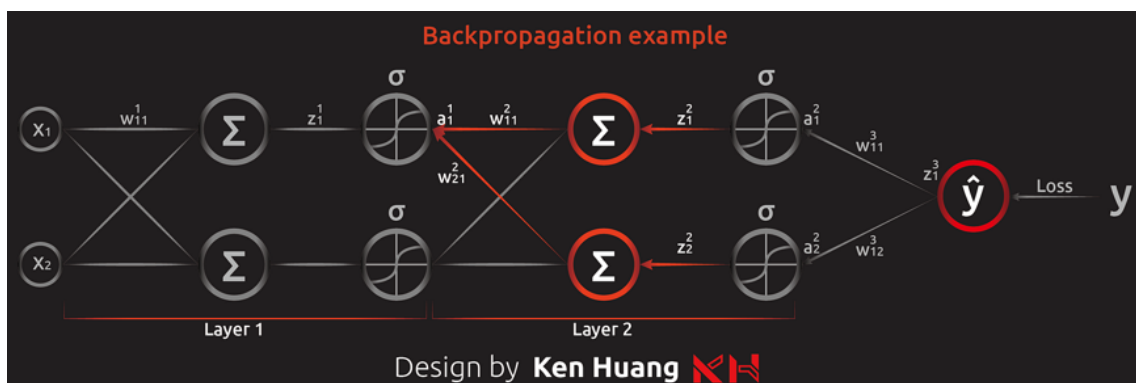


圖 A.1: 深度學習的模型參數優化過程—誤差反向傳播法（Back Propagation）。誤差反向傳播法結合梯度下降法和連鎖率，是一種用於優化神經網路權重的方法。此方法首先進行正向傳播以計算損失函數的值，然後利用連鎖律進行反向傳播，計算出每個權重對損失函數的梯度，以便進行梯度下降法的更新（Huang, 2023）。

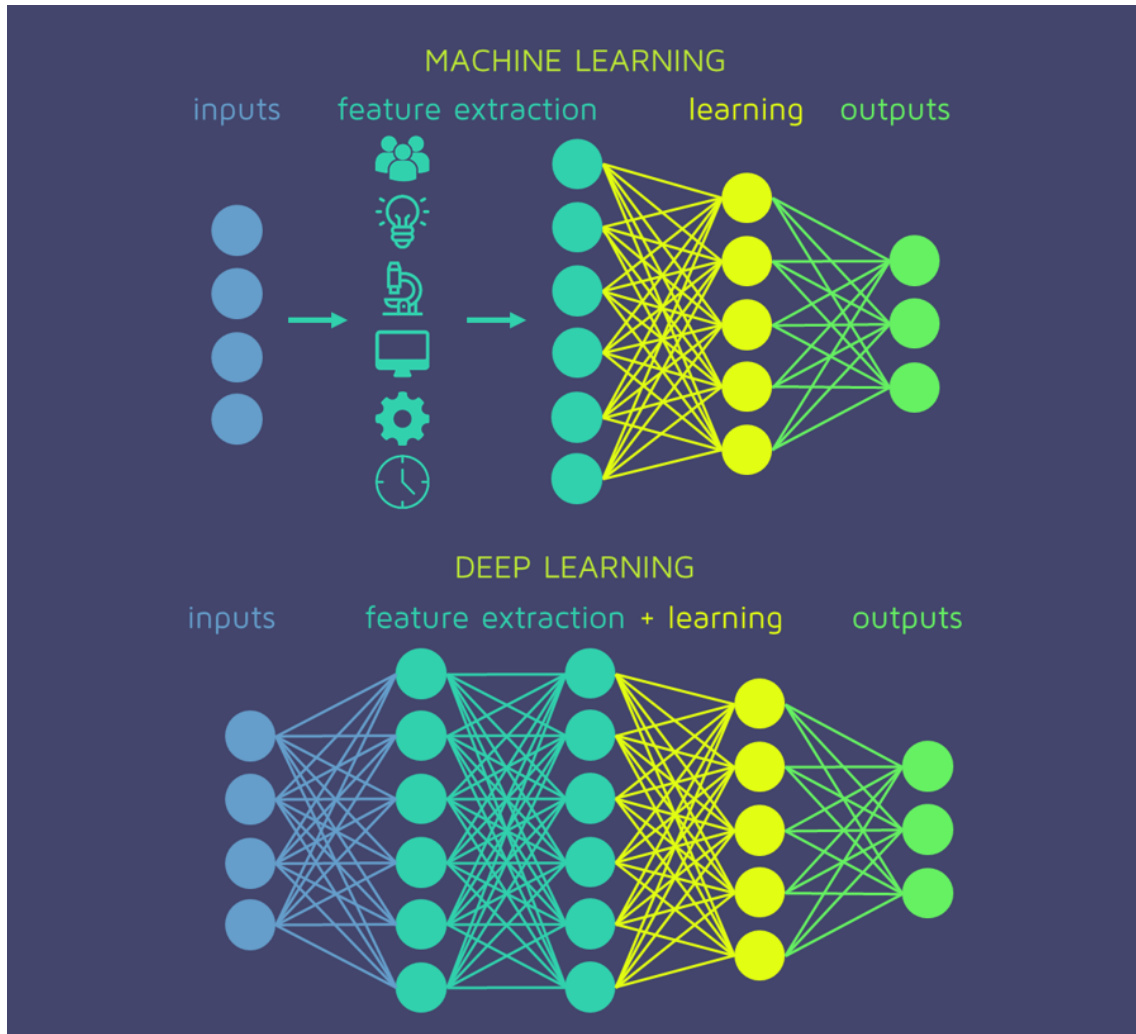


圖 A.2: 深度學習和機器學習的比較。深度學習屬於機器學習的一個子領域，深度學習相比其他機器學習方法，無需人工設計特徵萃取的規則，深度學習模型能夠從大量資料中自動學習複雜的特徵 (Aybar, 2020)。

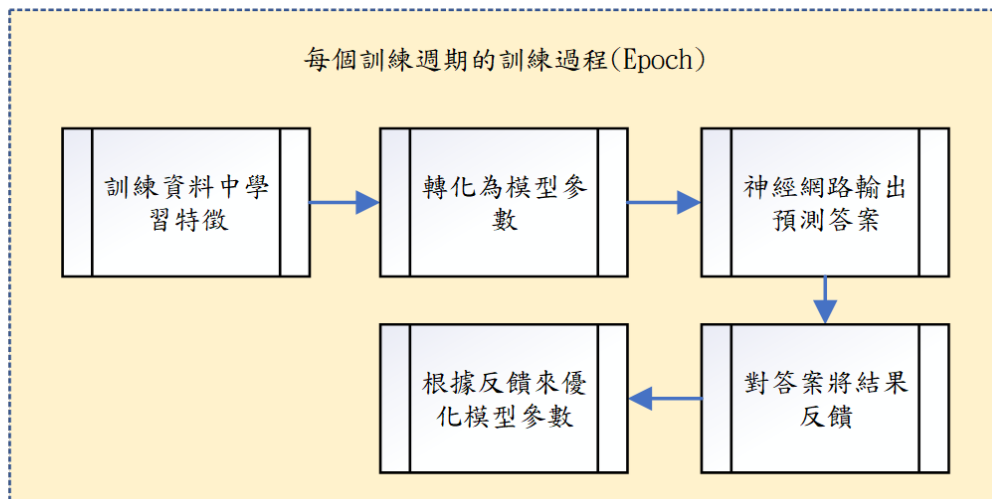
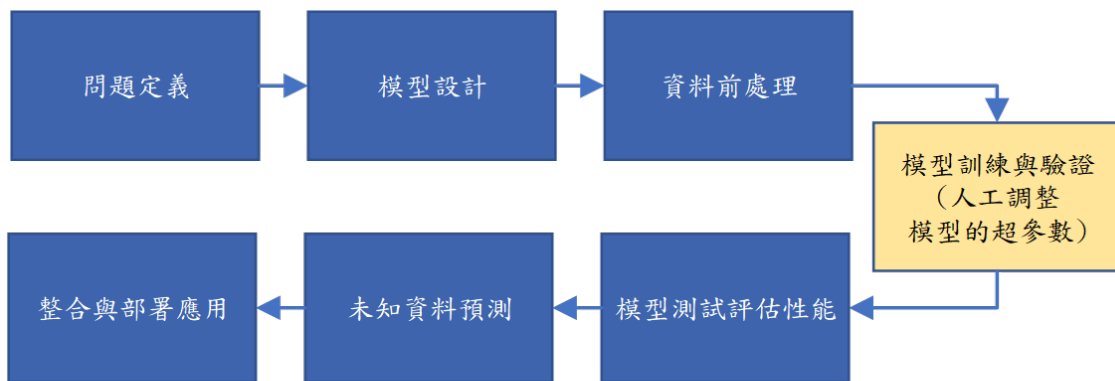


圖 A.3: 深度學習專案流程。



A.1 問題定義

對於專案而言，首先要剖析需求與問題，規劃如何引入深度學習。例如，在地震觀測中，最為耗時的例行性工作包含挑波相到時，以及辨識 P 波初動極性這兩個部分。辨識 P 波初動極性是較簡單的分類問題，萃取局部特徵並判斷，可使用基於卷積網路 (CNN) 的分類器；挑波相到時則是較複雜類似於物件切割的任務，屬於其中一種序列轉序列的任務 (Sequence to Sequence)，除了局部特徵，還需考慮序列與序列之間的關聯性，即全局特徵，此類應用適用 U-Net、Transformer 等具有編碼器與解碼器的模型 (圖 A.4)。此外，未來可考量在關聯定位的部分，利用圖神經網路 (GNN) 處理非結構化資料，能有效轉換測站的地理位置資訊和挑波資訊，達到引入深度學習的自動化定位。

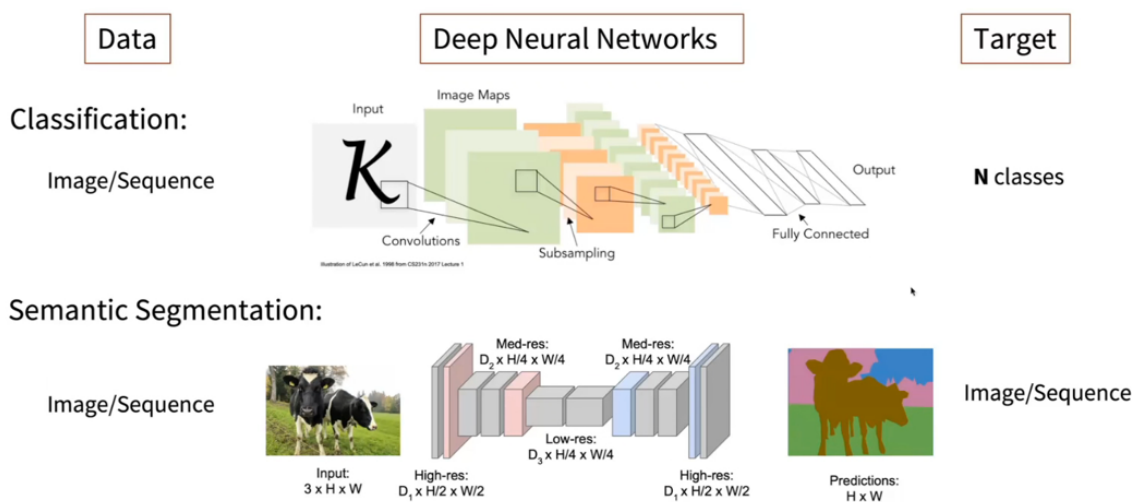


圖 A.4: 分類任務和物件切割任務的比較。辨識 P 波初動極性是較簡單的分類問題；挑波相到時則是較複雜類似於物件切割的任務，屬於其中一種序列轉序列的任務。依據任務類型選擇合適的模型 (Zhu, 2020)。



A.2 模型設計

A.2.1 卷積神經網路 (Convolutional Neural Network, CNN)

卷積神經網路 (CNN) 是專門設計用於處理圖像或二維時間序列資料的深度學習模型，其核心利用卷積層提取特徵。其核心包括卷積層用於提取圖像特徵，批量正規化使模型學習更穩定，激發函數增加非線性處理能力，池化層降低特徵維度增加效率，以及全連接層和輸出層負責進行資料分類。以下將進一步介紹：

1. 卷積層 (Convolutional Layers)：擅長萃取局部特徵。卷積被廣泛運用於圖像，因為特徵在圖像中通常只佔一部分，並且會重複出現。卷積層的局部感受區 (Receptive Field) 能夠捕捉低層次特徵，逐層組合形成高層次特徵表示，增強模型的圖像理解和分類能力。相比全連接層 (Fully-connected)，卷積層的多個神經元會共享一個卷積核 (一組權重)，可大幅減少參數量 (圖 A.5)。
2. 批量正規化 (Batch Normalization)：對每一批資料進行標準化處理，使得每一批資料的均值為 0 且標準差為 1。主要解決「內部共變量偏移」(Internal Covariate Shift) 的問題，使模型學習更穩定，從而使用更大的學習率，加快收斂速度。並且具有輕微的正則化效果，可一定程度抑制過擬合。
3. ReLU 函數：屬於激發函數的一種，在深度學習中最為常用。當輸入 x 為正時，輸出就是 x 本身；當輸入 x 為負或等於零時，輸出為零。其數學表達式為：

$$\text{ReLU}(x) = \max(0, x)$$

4. 平坦化層 (Flatten Layer)：將多維特徵圖拉平為一維向量。這是將卷積層的輸出轉換為全連接層所需的格式，為後續的全連接層提供輸入。



5. 全連接層 (Fully Connected Layers, or Dense Layer)：前一層的每一個神經元都與後一層的每一個神經元相接。本研究將全連接層用於在卷積層萃取特徵後，學習非線性組合。
6. Softmax 函數：屬於激發函數的一種，將輸入向量轉換為機率分布，常見於多類別的分類問題，輸入一組機率值，輸出也是一組機率值，這些機率加總為 1，每個機率對應一個類別，反映了給定樣本屬於每個類別的機率。其數學表達式為：

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}$$

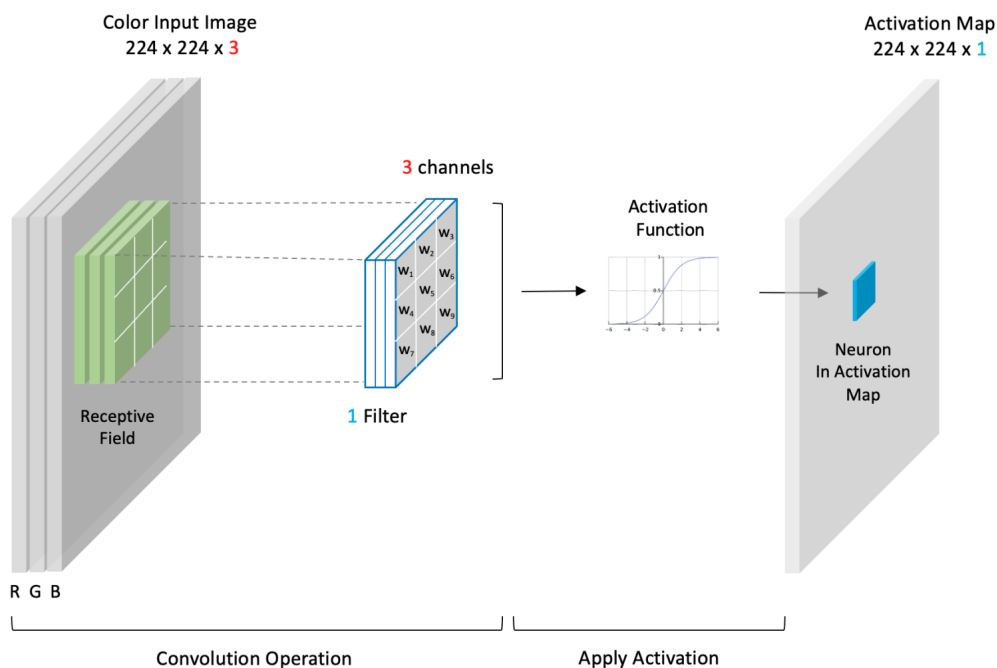


圖 A.5: 卷積層 (Convolutional Layers) (Mallick, 2023)。



A.2.2 變換器 (Transformer)

Transformer 是一種基於自注意力機制的深度學習模型，特別擅長處理長時間序列資料。其核心利用自注意力機制高效捕捉序列中向量與向量之間的關係，無需依賴傳統的遞歸結構，從而提高計算效率並改善長距離依賴問題。Transformer 模型主要由編碼器與解碼器組成：編碼器包含卷積層、雙向長短期記憶網路、自注意力機制等等萃取局部與全局特徵。以下做進一步介紹：

1. 卷積層 (Convolutional Layers)：請見 A.2.1 章。
2. 池化層 (Pooling Layer)：通過對輸入特徵圖進行降維操作，簡化參數量，保留關鍵特徵，有助於抑制過擬合 (圖 A.6)。

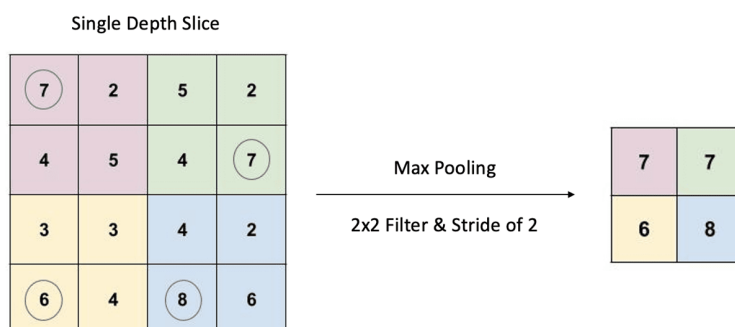


圖 A.6: 池化層 (Pooling Layer) (Mallick, 2023)。

3. 殘差連接 (Resblock)：輸入直接添加到輸出，有助於緩解深層網絡中的梯度消失問題，從而使網絡可以成功訓練更多層，也能加快速度 (圖 A.7)。




圖 A.7: 殘差連接 (Resblock) (Tang et al., 2021)。

4. 雙向長短期記憶網路 (Bi-directional Long Short-Term Memory, BiLSTM) : 長短期記憶網路 (LSTM) 是一種特殊的循環神經網路 (RNN) 結構，擅長處理序列資料，通過長時間記憶可解決長時間依賴關係。包含三個閘門，輸入門決定該輸入值的權重 (重要程度)，遺忘門決定是否保留該權重，輸出門決定輸出什麼到下一層 (圖 A.8)。雙向長短期記憶網路 (BiLSTM) 包含兩個 LSTM，一個負責處理正向序列 (從過去到未來)，另一個處理反向序列 (從未來到過去)。這樣對於序列中的每一點，雙向長短期記憶網路 (BiLSTM) 包含兩個長短期記憶網路 (LSTM)，能同時考慮其前後的訊息 (圖 A.9)。與順序緊密相關的任務，雙向長短期記憶網路可能會優於自注意力機制，可結合兩者搭配使用。
5. 自注意力機制 (Self-attention) : 結合卷積層與循環神經網路的優點，透過計算向量之間的關聯性，能學習局部與全局的關係 (圖 A.10)。具體而言，自注意力機制透過 query、key、value 三個矩陣計算向量間的相關性。query 捕捉特定特性；key 代表其他向量的特性；value 儲存輸入資料信息。多頭自注意力使用多個 query，增強模型捕捉多種關聯性的能力。計算過程中，query 與 key 的點積經 Softmax 函數轉換後得到的權重與 value 結合，產生加權輸出。這種方式使模型能夠靈活地關注不同部分的輸入資料，實現更高效的特徵提取和資訊融合 (圖 A.11)。
6. Sigmoid 函數：屬於激發函數的一種，將實數映射到 (0,1) 的區間，具有非線性、連續、可微的特性。常見於二元分類的問題，輸入一個實數，輸出一個單一的機率值，表示樣本屬於正類的機率。其數學表達式為：

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

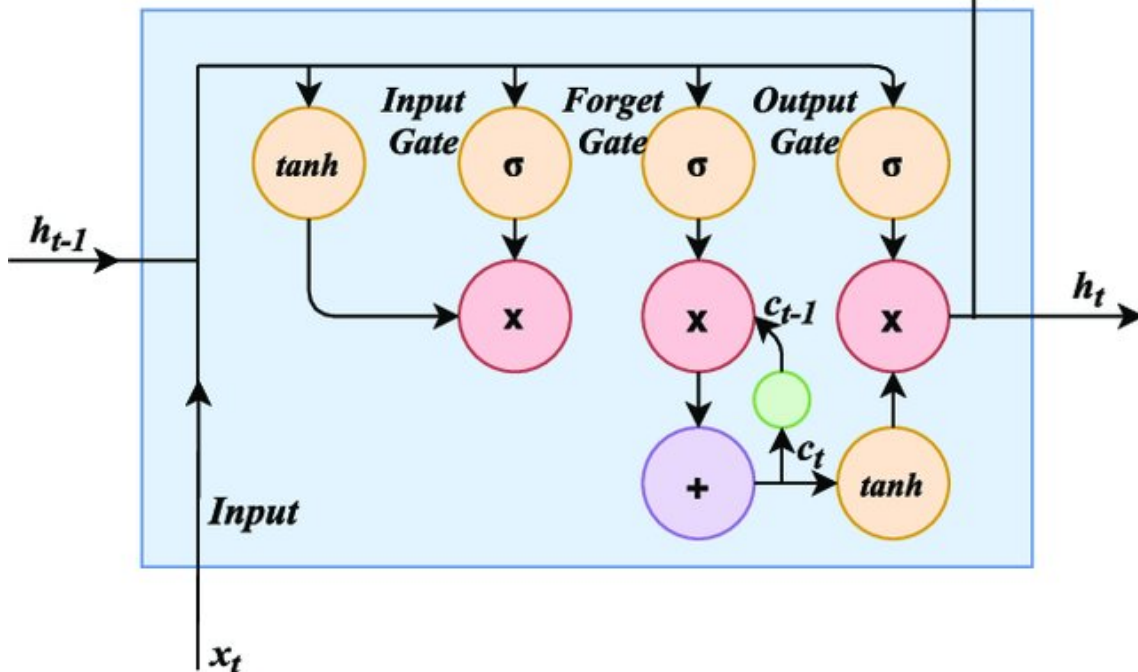



圖 A.8: 長短期記憶網路 (Ihianle et al., 2020)。




圖 A.9: 雙向長短期記憶網路 (BiLSTM) (Ihianle et al., 2020)。



A.2.3 生成對抗網路 (Generative Adversarial Network, GAN)

本研究在挑波任務中引入生成對抗模型，生成對抗網路可以幫助發現標籤和標籤之間的關係，加速生成預期的標籤樣子。由於我們設計的挑波標籤應用到機率函數，機率函數的高峰在整個時間序列只佔了其中一小部分，因此高峰相對於整條水平線的損失值影響太小，以至於在沒有加入生成對抗網路時，需要迭代多次才能讓模型逐漸發展出標籤的高峰，模型的更新緩慢。當使用生成對抗網路，利用雙模型對抗的概念來促進生成器的訓練。具體來說，在訓練過程中生成器和鑑別器會相互競爭，生成器試圖生成越來越逼真的數據來「欺騙」鑑別器，而鑑別器則試圖變得更擅長區分真假數據，生成器為了欺騙鑑別器會試圖發現標籤和標籤之間的關係，創造出極其逼真的標籤（圖 A.12）。此對抗過程解決了模型學習機率函數尖峰的困難，加速生成預期的標籤樣子。

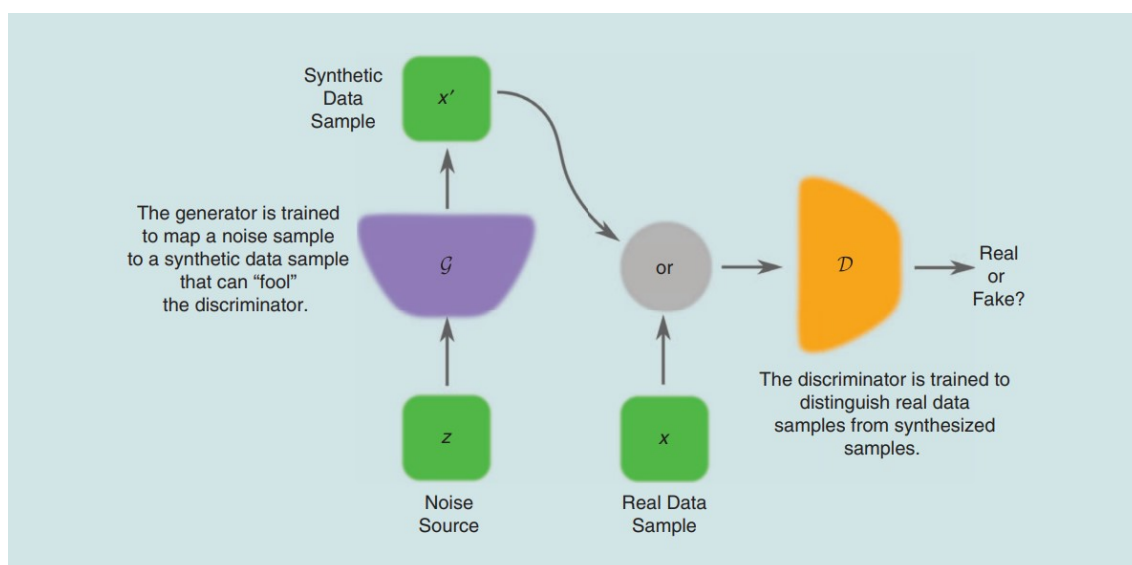


圖 A.12: 生成對抗網路 (GAN) 利用雙模型對抗的概念來促進生成器的訓練 (Creswell et al., 2018)。

為了有效訓練模型，本研究選用條件式生成對抗網路 (conditional GAN)，這種變形與普通生成對抗網路的區別在於透過人為在鑑別器的輸入加了其他的條件。我們使鑑別器的輸入包含原始的波型和標籤 (串接在最後一個維度)，因此加入波型這個「條件」後，鑑別器判定標籤形狀之外，需根據波型資料提供的標籤

相位到時來做判斷，增強模型的物理意義與有效性。以下是本研究對於生成對抗網路的訓練過程：



1. 將原先的模型作為生成器 (Generator)
2. 另外設計較小規模的卷積網路作為鑑別器 (Discriminator)
3. 生成器輸入波型，輸出的預測標籤，串接原始波型 (Concatenated Predict)
4. 真實的人工標籤也串接原始波型 (Concatenated Manual)
5. 鑑別器會輸入 Concatenated Predict (偽) 和 Concatenated Manual (真)，判斷真偽並輸出個別損失值，綜合對兩者的識別損失，以此更新鑑別器
6. 生成器的損失也包含兩個來源，第一個是鑑別器正確識別 Concatenated Predict 的時候反饋給生成器的一種損失，第二個是預測標籤與人工標籤本身的損失，在綜合上述兩個損失的過程非常關鍵，多次實驗後設定前者與後者的損失最佳權重比例為 1:10000，以此更新生成器。
7. 在生成對抗網路的訓練過程中，生成器和鑑別器的更新是交替進行的。
8. 在對抗過程中常會遇到鑑別器過強的情況，以至於生成器在對抗過程中不斷碰壁、無法找到學習方向而訓練失敗（生成器的損失值往上衝、下不來），有幾個調整策略：降低鑑別器的複雜度、降低鑑別器的更新次數、降低鑑別器的學習率、調整生成器的兩個損失權重等等，理想的結果是達到一種生成器與鑑別器的均衡對抗。
9. 藉由觀察對抗過程中預測標籤、生成器與鑑別器的損失值變化，通常生成器在經歷幾次均衡對抗後，生成器失敗前的最後一次損失值低谷，此時通常是鑑別器無法區分真實樣本和假樣本，並且生成器生成的假樣本質量非常高時，以此階段的生成器作為最佳模型。



A.3 模型超參數 (Hyperparameter)

訓練模型前要設定的主要超參數包含批量大小、迭代次數、損失函數、學習率、優化器等。以下會分別進行介紹，並說明超參數常見的調整策略。

A.3.1 批量 (Batch)

一個批次的資料量稱為批量。在效率和性能的權衡中，當批量愈小，模型看完小部分的資料就更新參數，有較高的隨機性 (Stochastic) 較能跳脫區域最小值；當批量越大，GPU 能將批量向量轉換為矩陣，用平行運算力可以更快達到最小值，但最後較難以收斂，容易在最低點附近震盪。因此要選用合適的批量大小 (Mini-batch) 達到折中的效果，選擇合適的批量大小通常需要考慮幾個因素：例如硬體資源、模型複雜度以及訓練資料的特性。在未知批量的情況下，通常會從 32 或 64 作為標準批量大小。當記憶體不足就要降低批量，當損失值變化過於震盪就要增加批量，並且要注意大批量也可能讓小資料集過擬合。本研究的策略是在前期使用小批量，可快速地看損失值趨勢變化，有助於快速調整並縮小其他超參數的範圍，確定模型訓練的基本方向後，再進一步增加批量。

A.3.2 迭代次數 (Epoch)

迭代次數指的是算法在訓練資料集上重複更新模型參數的次數，每一次的迭代包括前向傳播、損失計算、反向傳播和參數更新。當迭代次數不足，則會出現欠擬合；迭代次數過多，則會出現過擬合，可加入提早停止技術 (Early Stopping) 來終止訓練。在模型超參數實驗中，若要固定更新次數，當批量大小增加 k 倍，則迭代次數也要增加 k 倍。



A.3.3 損失函數 (Loss Function)

損失函數是深度學習中用來評估模型預測與實際資料之間差異的一種方法，即量化模型預測的錯誤程度，這個量化的結果用於指導模型的學習。另外一提，之所以使用損失值而不是直接用精度做為學習指標，是因為精度並非連續變化，即精度的導數大部分都會是 0，僅僅微調模型參數，精度的值無法改善，則會呈現離散不連續的值；而損失函數的導數是連續變化，相當於每個路口都有指標，有助於學習。應對 P 波初動極性分類的任務，本研究使用交叉熵損失，能計算兩個機率分佈之間的距離，對於預測錯誤的標籤具有高敏感度，有效評估模型的預測輸出標籤與人工標籤的差異。另外，二元交叉熵損失 (Binary Cross Entropy) 是交叉熵損失的特例，當標籤類別是無競爭關係、個別獨立的應用情境，例如挑波的任務，輸出的標籤含有三個機率分布分別為 P 波、S 波和噪訊，這三個機率分布彼此是獨立的，因此使用二元交叉熵損失來量化挑波模型的錯誤程度。

A.3.4 學習率 (Learning Rate)

控制模型參數更新的幅度，與批量大小的調整策略類似，當學習率越小，有較高的隨機性 (stochastic)，使用大批量時相應提高學習率。在模型超參數實驗中，通常當批量大小增加 k 倍時，學習率可以增加到原來的 \sqrt{k} 倍。需多次試驗後設定適合的初始學習率。配合選用自適應學習率的優化器，在訓練過程中根據模型的訓練反饋自動調整學習率，這樣初始學習率對整體的影響較小。

A.3.5 優化器 (Optimizer)

有損失函數的局部梯度計算結果之後，由優化器計算權重和偏差的梯度，然後更新參數。優化器需要輸入模型參數、學習率，最廣泛運用的是利用一階和二階矩估計來自適應學習率的 ADAM 優化器。以下列出幾個常見的優化器：



- SGD 隨機梯度下降法: 簡單容易實現, 但缺點是對於形狀是非均向的函數, 其搜尋路徑就會低效耗時間, 而且可能被困在鞍點。
- Momentum 優化器: 添加了慣性項, 可以加速收斂。
- AdaGrad 優化器: 對每個參數定製不同的學習率衰減速率, 對頻繁出現的參數進行較小的更新, 對不經常出現的參數進行較大的更新。但缺點是到後期的學習率會變太小 (累積梯度平方和作為分母)。
- RMSProp 優化器 (AdaGrad 的變體): 引入遞減均方根作為學習率的分母, 來避免長時間訓練中學習率過小。
- Adadelta 優化器 (AdaGrad 的變體): 採用距離當前時間比較近的累積項, 作為學習率的分母, 也是避免長時間訓練中學習率過小。
- Adam 優化器 (融合 Momentum 和 RMSProp): 最廣泛使用的優化器之一, 融合 Momentum 和 RMSProp 的概念獲得加速收斂與自適應學習率的兩個優點, 並做偏差修正。能利用一階和二階矩估計, 根據每個參數的過去梯度的平方的平均值來個別調整每個參數的學習率。
- 其他更高級的優化算法, 如 L-BFGS、AMSGrad 等

A.3.6 調度器 (Learning Rate Scheduler)

自適應學習率的優化器是對每個參數進行更細緻的學習率調整, 而調度器則是調整全局的學習率, 並且依賴於人工設定的規則, 例如 CyclicLR 的週期性調度器。在某些情況下, 可以同時使用調度器和自適應優化器。例如, 使用 Adam 進行初期的快速收斂, 隨後配合學習率衰減來確保模型穩定地達到最優。



A.4 模型性能評估與調整

A.4.1 欠擬合與過擬合 (Underfitting and Overfitting)

擬合過程的偏差和方差這兩種誤差來源，產生偏差-方差權衡 (Bias-variance trade-off)，隨著訓練週期增加，從欠擬合到過擬合的過程，偏差減少但方差增加，因此，需透過驗證資料來檢驗何時停止訓練。通常訓練與驗證資料的誤差都逐漸下降，代表模型逐漸擬合，而當驗證資料的誤差最小時有最佳模型，此檢驗方法可有效避免欠擬合或過擬合 (圖 A.13)。因此當遇到模型訓練後性能不佳，應檢視在訓練和驗證過程中的損失值變化，搭配預測波型來檢視模型的狀態，是否因為過度訓練而過擬合，或是模型本身仍欠擬合導致預測能力不夠，制定訓練決策 (圖A.14)。

- 欠擬合 (Underfitting)：當訓練資料的損失值與驗證資料的損失值皆尚未下降到接近低點屬於欠擬合，代表模型還太簡單，通常會有較小的方差，但較大的偏差，須延長訓練過程讓模型持續學習訓練資料來更新參數，或是回到模型設計的部分增加模型複雜度。
- 過擬合 (Overfitting)：當驗證資料的損失值從低點又逐漸升高，驗證資料的損失值變化曲線與訓練資料的損失值變化曲線逐漸分離，也就是在訓練資料表現好，但在測試資料表現不好，則為過擬合現象，通常會有較小的偏差，但較大的方差。此時過擬合模型的預測能力也不佳，須提早停止回到訓練資料與驗證資料皆最低點時的模型，或是增加訓練資料、增加正則化來減少噪音的影響、使用 Drop Out 在訓練過程中隨機刪除神經元等等方式可以抑制過擬合的現象。

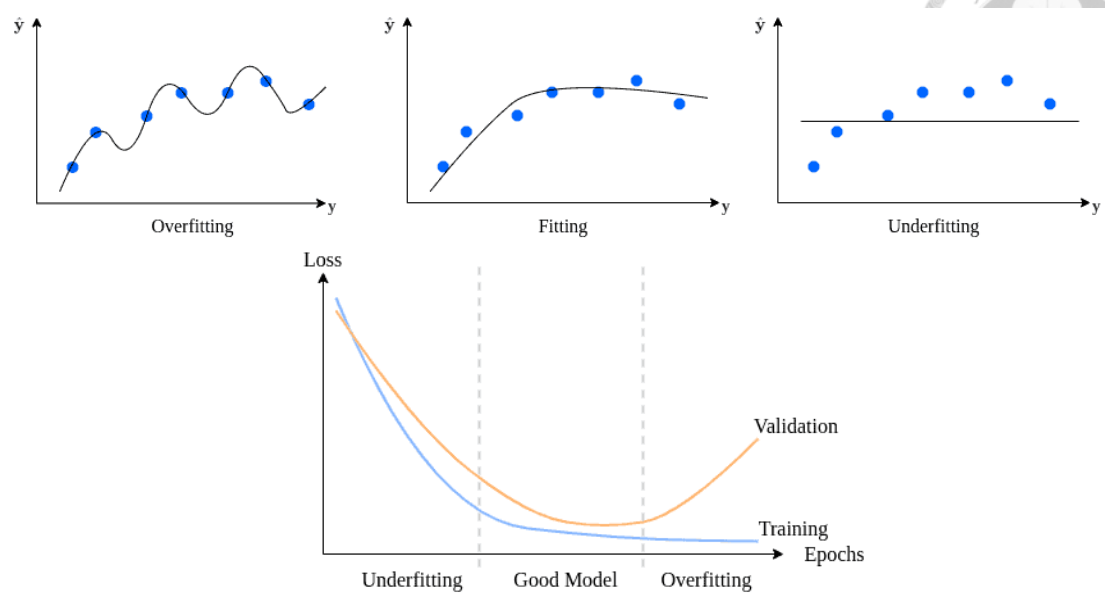



圖 A.13: 欠擬合與過擬合 (Underfitting and Overfitting) (Zvornicanin, 2023)。

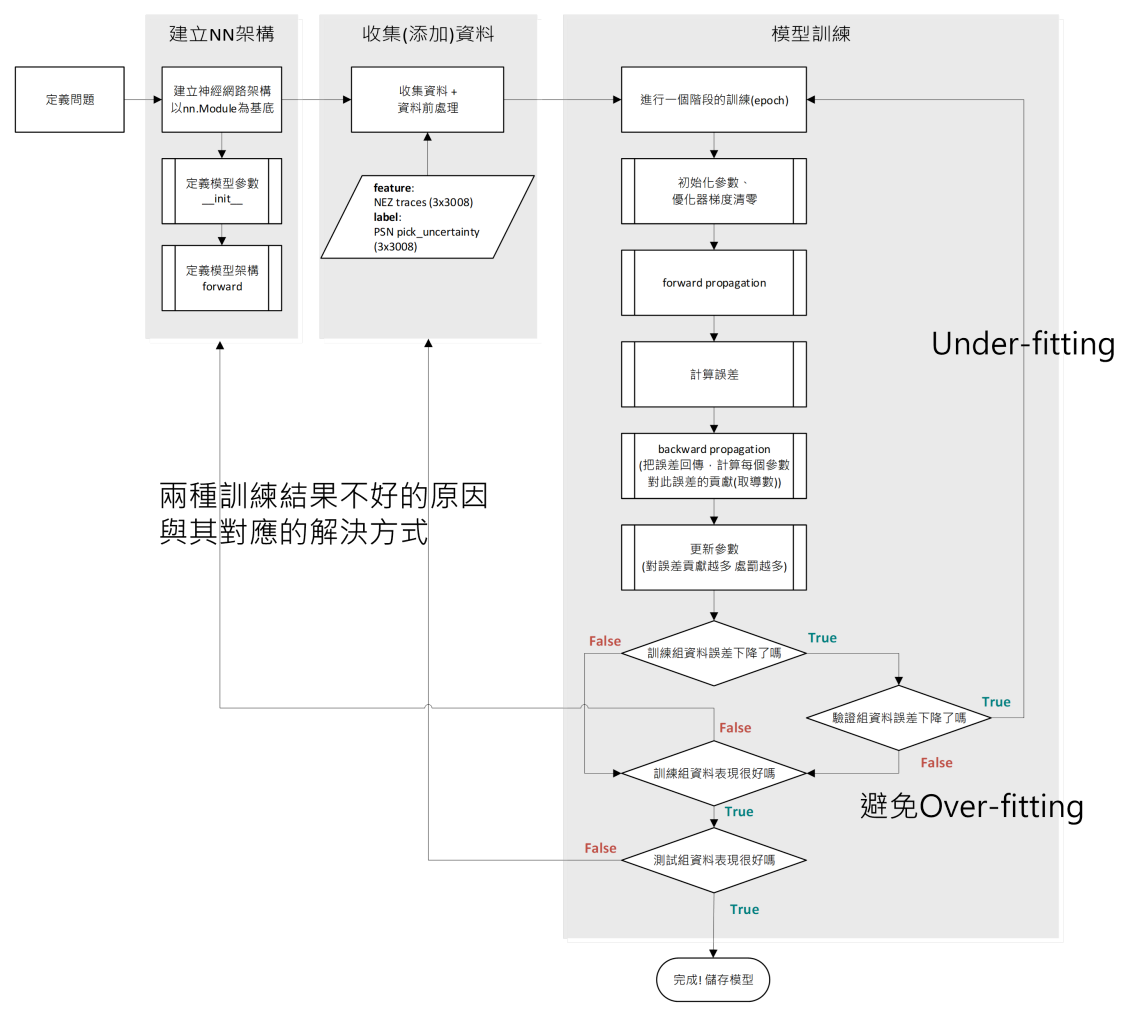


圖 A.14: 模型訓練流程與決策



A.4.2 模型性能的評估指標

在深度學習模型的性能評估中，當樣本的類別數量不均衡時，單一的準確率（Accuracy）可能不足以提供全面的性能評估。此時，我們通常會計算混淆矩陣（Confusion Matrix）以獲取更詳細的預測結果分布，並進一步利用精確率（Precision）和召回率（Recall）來評估模型（圖 A.15）。以疫情為例，疫情初期，寧可抓錯也不要漏抓，那我們就會注重要有高召回率到後期，會想要避免沒得病但抓錯人，也就是偽陽性的代價相對變高，就會想要犧牲一點召回率，來提升精確率。以下為各指標的說明：

		Manual Class	
		Positive	Negative
Predict Class	Positive	TP	FP
	Negative	FN	TN

$$\text{precision} = \frac{TP}{(TP + FP)}$$
$$\text{recall} = \frac{TP}{(TP + FN)}$$
$$\text{f1 score} = \frac{2}{\frac{1}{\text{recall}} + \frac{1}{\text{precision}}} = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}}$$

圖 A.15: 混淆矩陣、精確率、召回率和 F1 分數等模型性能指標

- 準確率（Accuracy）：基本的指標是準確率，即在所有樣本中，有多少比例是被正確預測的。
- 混淆矩陣（Confusion Matrix）：用來檢視各類別中模型預測與實際標籤之間的關係，這對於理解模型在各個類別上的表現非常有幫助。
- 精確率（Precision）：衡量在所有預測為陽性的樣本中，有多少是真正的正例。這個指標在偽陽性的成本很高時尤為重要，例如在垃圾郵件檢測中，提高精確率意味著減少錯誤地將正常郵件標記為垃圾郵件的情況。
- 召回率（Recall）：衡量在所有真實為正的樣本中，有多少被模型正確識別。

當偽陰性的後果很嚴重時，提高召回率變得極其重要，比如在醫學診斷中，高召回率能確保盡可能少的病症被漏診。



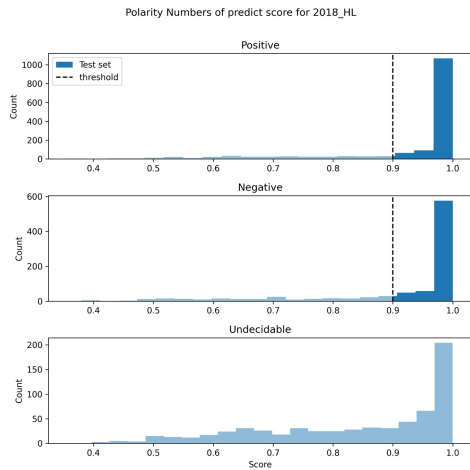
- F1-Score：若要同時評估精確率與召回率，F1-Score 做為精確率和召回率的調和平均數，當 F1-score 越接近 1，則同時有良好的精確率與召回率，越接近 0 則反之。

附錄 B — 震源機制解之實驗結果補充



B.1 2018 花蓮地震網

(a) Threshold of polarities for #confidence > 0.9



(b) #Polarities Distribution




圖 B.16: 預測 P 波初動極性的數量分析—2018 花蓮地震網測試資料。(a) 地震預測極性在各類別的信心分數，保留信心分數大於 0.9 的預測極性，後續解析成震源機制解。(b) 經 (a) 篩選後的極性數量分析。




圖 B.17: 混淆矩陣—2018 花蓮地震網測試資料。信心門檻為 0.9。



B.2 2022 池上微震觀測網

(a) Threshold of polarities for #confidence > 0.9

(b) #Polarities Distribution




圖 B.18: 預測 P 波初動極性的數量分析—2022 池上微震觀測網測試資料。(a) 地震預測極性在各類別的信心分數，保留信心分數大於 0.9 的預測極性，後續解析成震源機制解。(b) 經 (a) 篩選後的極性數量分析。




圖 B.19: 混淆矩陣—2022 池上微震觀測網測試資料。信心門檻為 0.9。

B.3 2023 寶來地震網




圖 B.20: P 波和 S 波訊噪比—2023 寶來地震網 (依 P 波做極性判斷)。

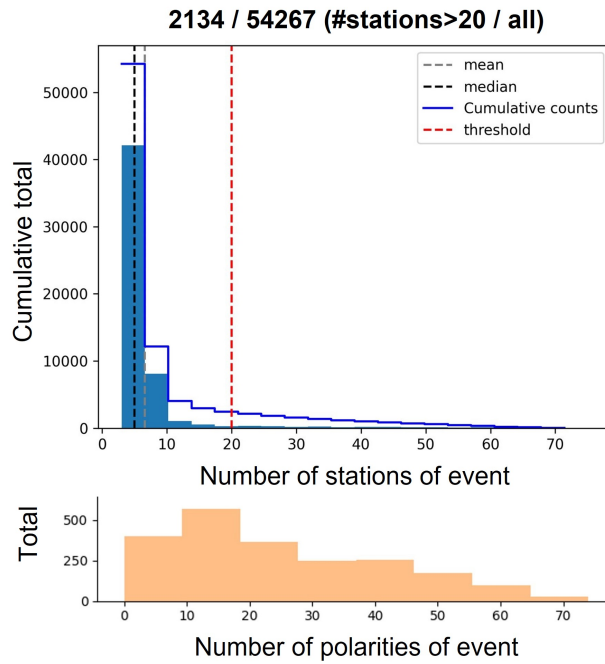


圖 B.21: 極性數量分析—2023 寶來地震網。上圖為地震定位後的測站數量分布圖，在 54,267 筆地震篩選出 2,134 筆測站數量大於 20 的地震事件預測極性。下圖為保留信心分數大於 0.9 的預測極性，後續解析成震源機制解的極性數量分布