



定点形变数据同震响应检测深度学习模型

彭 钊, 邵永谦, 李颖楠, 刘文兵, 赵黎明

Deep learning model for co-seismic response detection of fixed-point deformation data

Peng Zhao, Shao Yongqian, Li Yingnan, Liu Wenbing, and Zhao Liming

在线阅读 View online: <https://doi.org/10.19987/j.dzqxjz.2024-156>

您可能感兴趣的其他文章

Articles you may be interested in

承德地区宽频带倾斜仪与宽频带地震计同震响应融合分析

Fusion analysis of co-seismic response between broadband tiltmeters and broadband seismometers in Chengde area
地震科学进展. 2025, 55(1): 21-29

天津蓟县地震台两套VP宽频带倾斜仪数据对比分析

Comparative analysis the data of two sets VP broadband inclinometers at Jixian seismic station
地震科学进展. 2024, 54(9): 575-583

湖北黄梅宽频带形变观测仪与地震计数据融合分析

Data fusion analysis of broadband deformation observation meters and seismometers in Huangmei, Hubei Province
地震科学进展. 2024, 54(12): 840-850

云南省双震与数字化定点形变同震阶变初探

Preliminary study on co-seismic deformation steps of digital fixed-point and double earthquakes in Yunnan Province
地震科学进展. 2020, 50(2): 32-35

长汀地震台VP宽频带倾斜仪常见故障分析与处理

Analysis and treatment on common faults for VP broadband tiltmeter at Changting seismic station
地震科学进展. 2023, 53(10): 462-468

江西省赣州地震中心站DSQ型水管倾斜仪与VS型垂直摆倾斜仪同震响应对比分析

Comparative analysis of observation data between DSQ water-tube tiltmeter and VS vertical pendulum tiltmeter at Ganzhou seismic center station in Jiangxi
地震科学进展. 2023, 53(9): 409-415



关注微信公众号, 获得更多资讯信息

彭钊, 邵永谦, 李颖楠, 等. 定点形变数据同震响应检测深度学习模型 [J]. 地震科学进展, 2025, 55(9): 521-528. doi:10.19987/j.dzksjz.2024-156

Peng Z, Shao Y Q, Li Y N, et al. Deep learning model for co-seismic response detection of fixed-point deformation data[J]. Progress in Earthquake Sciences, 2025, 55(9): 521-528. doi:10.19987/j.dzksjz.2024-156

学术论文

定点形变数据同震响应检测深度学习模型

彭 钊^{1)*} 邵永谦²⁾ 李颖楠¹⁾ 刘文兵¹⁾ 赵黎明¹⁾

1) 天津市地震局, 天津 300201

2) 上海市地震局, 上海 200062

摘要 定点形变数据的同震响应识别目前主要依靠人工拣选, 尚未见有自动检测方法投入应用。本文提出专门针对定点形变数据的同震响应检测深度学习模型, 该模型用于在单台 VP 宽频带倾斜仪秒数据上快速准确地检测同震响应信号。使用迁移学习技术构建模型, 引入 3 种代表性测震数据地震检测预训练模型作为特征提取器, 将其在测震数据上地震检测的知识和能力迁移到定点形变数据上, 设计和调整了配套的数据转换器和分类器。真实观测数据上的测试表明模型具备良好的检测性能, 在蓟县台连续数据上的应用证明模型不仅能够检测出人工记录的所有同震响应事件, 还能够发现更多人工未能识别的事件, 精确率不低于 75%, 检测效率、检测能力和一致性相比传统人工处理有了很大的提升。

关键词 定点形变; 同震响应检测; 深度学习; 迁移学习; VP 宽频带倾斜仪

中图分类号: P315.61 文献标识码: A 文章编号: 2096-7780(2025)09-0521-08

doi: 10.19987/j.dzksjz.2024-156

Deep learning model for co-seismic response detection of fixed-point deformation data

Peng Zhao¹⁾, Shao Yongqian²⁾, Li Yingnan¹⁾, Liu Wenbing¹⁾, Zhao Liming¹⁾

1) Tianjin Earthquake Agency, Tianjin 300201, China

2) Shanghai Earthquake Agency, Shanghai 200062, China

Abstract Co-seismic response identification of fixed-point deformation data currently relies on manual selection, and no automatic co-seismic response detection method has yet been applied. This study proposes the first deep learning model for the co-seismic response detection of fixed-point deformation data in China, which is used to detect co-seismic response signals quickly and accurately on the second dataset of a single vertical pendulum broadband tiltmeter. The model was constructed using the transfer learning technique; it introduces three representative pre-trained models for earthquake detection in seismic data as feature extractors, migrates their knowledge and capabilities of earthquake

收稿日期: 2024-10-24; 采用日期: 2024-12-03。

基金项目: 中国地震局监测、预报、科研三结合课题(3JH-202401038)和上海市社会发展科技攻关项目(23DZ1200200)联合资助。

* 通信作者: 彭钊(1991-), 男, 工程师, 主要从事地震监测预报与人工智能交叉研究。E-mail: pengzhao91@163.com。



detection in seismic data to fixed-point deformation data, and then designs and adapts supporting data converters and classifiers. Tests on real observational data showed that the model provided a good detection performance. The application of continuous data from Jixian station proved that the model was not only capable of detecting all the co-seismic response events recorded manually, but it also found events that were not recognized manually, with an accuracy rate of no less than 75%. Compared with traditional manual processing, the detection efficiency, detection capability, and consistency are greatly improved using this model.

Keywords fixed-point deformation; co-seismic response detection; deep learning; transfer learning; vertical pendulum broadband tiltmeter

0 引言

定点形变观测在地震研究中有着广泛的应用,其连续观测形成的定点形变时序数据可应用到地震监测预报及相关地球科学领域的研究中^[1-2]。随着观测技术的进步,定点形变观测能够记录到包括震时同震波形在内的丰富高频地动信息。台站日常数据预处理工作要求记录包括同震响应在内的地球物理事件,很多学者也从不同角度对定点形变观测的同震响应进行了研究^[3-5],但目前定点形变数据同震响应识别仍依赖人工处理,需通过目视判断和人工拣选来判别同震事件,效率较低,且人工判断的检测方式容易受到主观判断的影响,准确性、一致性较差。使用自动检测方法有望提高定点形变数据同震响应检测的精度和可靠性,可在短时间内完成大量数据的处理,提高工作效率。但迄今尚未见有定点形变数据同震响应自动检测方法投入应用。

目前,已有部分针对定点形变数据异常形态自动检测方法的研究。杨德贺等^[6]开发了利用信息熵与双异常因子构建的高幅值变化和低频变化统一识别方法;刘明辉等^[7]开发了基于小波分析的对扰动信号的触发检测方法。但上述方法无法判别异常变化的类型,数据变化的具体性质仍需进一步的人工判断,无法直接用于定点形变数据的同震响应检测。

深度学习作为人工智能领域的一个重要分支,近年来在地球科学领域展现了巨大的潜力和广泛的应用前景。在地球科学上,深度学习已经在地震检测^[8-14]、震相拾取^[15-18]等方面取得了许多卓有成效的进步与发展,发表了许多代表性成果,但在前兆地球物理观测数据处理上的应用目前仍处于探索起步阶段^[19]。

本文通过迁移学习构建了专门针对在单台 VP 宽频带倾斜仪秒数据上检测同震响应信号的定点形变数据同震响应检测深度学习模型。使用模型迁移技术构建目标模型并引入 3 种已发表测震数据地震

检测预训练模型作为特征提取器,将代表性地震检测深度学习模型在测震数据上地震检测的知识和能力迁移到定点形变数据上,设计和调整了配套的数据转换器和分类器。在真实观测数据上评估了模型的检测性能,然后将模型应用于来自蓟县台的连续数据,验证了模型的实际应用效能并与人工处理结果进行了对比。

1 模型构建

1.1 构建思路

深度学习是数据驱动的方法。在定点形变观测领域,VP 宽频带倾斜仪作为监测地面微小倾斜变化的精密仪器得到了广泛应用,积累了大量观测数据,但对于其记录到的地震事件一直缺少结构化标签化整理,未能形成地震事件数据集。这使得从头开发和训练用于 VP 宽频带倾斜仪观测数据同震响应检测的深度学习模型难以实现。因此使用迁移学习进行模型开发。迁移学习是人工智能领域一种流行的泛化方法,将在一个任务中学习到的知识和模式,应用到新的但相关的任务中以提高新任务的性能^[20]。由于 VP 宽频带倾斜仪记录到的同震响应波形和测震数据的地震波形存在一定的相似性^[21](图 1)。任务目标都是地震事件检测,可以使用已发表的测震数据地震检测研究成果来帮助完成定点形变数据同震检测任务。

通过迁移学习中基于模型的迁移方法,将已经训练好的地震检测模型的一部分或全部,即预训练模型(Pre-Trained Model, PTM),用于目标模型的构建,然后针对特定的定点形变数据任务进行微调(Fine-tuning),并添加或修改少量的特定层以满足数据输入输出的要求,这样可以有效地解决定点形变带标签地震数据稀缺的问题,因为预训练模型已经在大量数据上进行了训练。

使用预训练模型作为特征提取器,学习地震信号的通用特征,在特征提取器前端添加数据转换器,

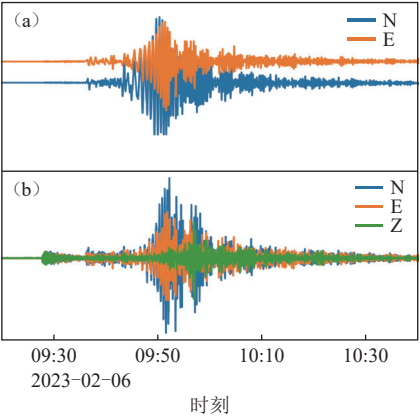


图 1 蓟县台 VP 宽频带倾斜仪(a)与宽频带地震仪(b)记录到的 2023 年土耳其 7.8 级地震

Fig. 1 *M*7.8 Türkiye earthquake in 2023 recorded by (a) vertical pendulum broadband tiltmeter and (b) broadband seismometer at Jixian station

将 VP 宽频带倾斜仪观测数据转换为特征提取器能够识别的数据格式, 调整特征提取器后端的分类器使其输出地震信号预测结果。

1.2 预训练模型的选择

测震数据地震检测深度学习模型的开发方兴未艾, 国内外研究者提出了多种不同模型。综合考虑模

型的网络结构、训练数据集和检测性能等因素, 选择基于 Transformer 结构和注意力机制的 Earthquake Transformer (EQT) 模型^[10]、基于卷积神经网络和循环神经网络的 CNN-RNN Earthquake Detector (CRED) 模型^[9]和本团队自主开发的基于小波与轻量化卷积神经网络的 CWT-CNN Few-shot learning Earthquake (CCFE) 模型^[12]。EQT 预训练模型 (EQT PTM) 使用斯坦福全球地震数据集 (STEAD)^[22]进行训练, CRED 预训练模型 (CRED PTM) 使用美国北加利福尼亚地震数据集进行训练, CCFE 预训练模型 (CCFE PTM) 使用 STEAD 数据集内中国及周边地区地震数据 (STEAD-China) 进行训练。微调阶段, 由于缺乏目标任务地震数据集, 无法使用定点形变数据进行模型的微调训练, STEAD-China 数据集包含最大比例台站周边的地震数据, 可能是目标任务比较适合的微调训练数据集, 因此对于 EQT PTM 和 CRED PTM 模型, 使用 STEAD-China 数据进行微调训练, 对于已经使用 STEAD-China 数据集进行训练的 CCFE PTM, 使用重复数据进行训练可能导致模型过拟合, 因此直接使用预训练模型。上述模型的基本情况如表 1 所示。

表 1 本文选择的预训练模型
Table 1 Pre-trained model selected in this paper

预训练模型	网络架构	训练集	训练集大小/个	检测窗长/s	参考文献
EQT PTM	Transformer	STEAD (pre) + STEAD-China (fine)	1.1 M	60	[10]
CRED PTM	CNN-RNN	N. California (pre) + STEAD-China (fine)	456 K	30	[9]
CCFE PTM	CWT-CNN	STEAD-China (pre) + /	16.2 K	24	[12]

选择网络架构和训练数据各不相同的多种模型, 有利于在实际使用中根据性能评估选择最合适的特征提取模型, 3 种预训练模型根据任务需要既可以单独使用, 也可以联合使用。

1.3 数据转换器

用作特征提取器的 3 种预训练模型都是以测震数据为输入数据设计的, VP 宽频带倾斜仪数据与测震数据在数据格式上存在显著差异, 需要在特征提取器前端添加数据转换器, 将输入数据转换为特征提取器能够识别的数据格式。

VP 宽频带倾斜仪数据与测震数据在数据格式上的差异主要体现在通道数和采样率上。测震数据为 N, E, Z 三通道而 VP 宽频带倾斜仪数据为 N, E 两通道; 测震数据的采样率一般为 50~200 Hz, VP 宽频

带倾斜仪的入库数据最高为秒数据, 即采样率 1 Hz。因此, 数据转换层需要提高输入数据的采样率并增加 Z 通道数据。

提高一段时序数据的采样率可以采用插值法或时间压缩法。VP 宽频带倾斜仪秒数据与测震数据采样率差距较大, 插值法无法准确还原数据的高频信息并可能会产生过拟合或欠拟合现象。时间压缩法可以改变时间窗截取数据的时间长度而不改变数据原始采样率以达到提高窗口数据采样率的目的, 该方法能够较好地保持信号的原始特征, 且 VP 宽频带倾斜仪秒数据记录到的同震响应波形时长一般在数分钟到数十分钟之间, 远大于 3 种预训练模型的检测窗长, 采用原始检测窗长并不适用于 VP 宽频带倾斜仪秒数据, 因此使用时间压缩法提高数据采样率

可能是更好的选择。使用时间压缩法将输入数据的采样率从 1 Hz 提高到 50 Hz, 即将 3 种预训练模型对应的数据转换层输入数据的截取时长分别提高到 50, 25 和 20 min(表 2)。使得数据转换层输出窗口的 VP 宽频带倾斜仪秒数据的样本数与各预训练模型相应检测窗长的 50 Hz 测震数据的样本数一致。

表 2 各预训练模型的检测窗长和输入窗长

Table 2 Detection window length and input window length of each pre-trained model

预训练模型	检测窗长/s	数据转换层输入窗长/min
EQT PTM	60	50
CRED PTM	30	25
CCFE PTM	24	20

为时序数据新增数据通道需要确定新通道的数据来源。由于 VP 宽频带倾斜仪没有 Z 方向的观测, 无法通过测量或计算确定 Z 通道的取值。本文引入的预训练模型使用的地震数据集中都包含一定比例的通道缺失的数据, 在处理通道缺失的数据时具有良好的鲁棒性, 因此我们将新增 Z 通道的数值取为零并在时间上与现有通道数据对齐, 模拟三通道数据存在通道缺失的情况。

1.4 分类器

分类器接收特征提取器从输入数据中提取的信号特征并输出地震检测概率预测结果, 由于引入的预训练模型的源目标与既定目标任务一致, 就可以部分复用预训练模型的分类器。在使用的预训练模型中, EQT PTM 与 CCFE PTM 的分类器输出地震检测预测结果的同时还输出震相识别预测结果, 震相识别不是任务目标, 因此, 在使用 EQT PTM 与 CCFE PTM 时对分类器进行调整, 使其只输出地震检测的预测结果。整个模型的网络架构如图 2 所示。

2 模型评估与应用

2.1 测试数据来源

使用两段蓟县台真实数据测试并评估模型在 VP 宽频带倾斜仪秒数据上的检测性能。一段是 2024 年 1 月 9 日 02:00—20:00, 该时段记录到东南亚地区、日本地区和南太平洋地区发生的 3 次 5 级以上地震, 以检验模型对不同地区不同波形地震的检测性能; 另一段是 2024 年 4 月 23 日 00:30—12:30, 该时段记录到台湾花莲县及附近海域发生的 10 次 5 级以上地震, 以检验模型对短时间内多次地震的检测性

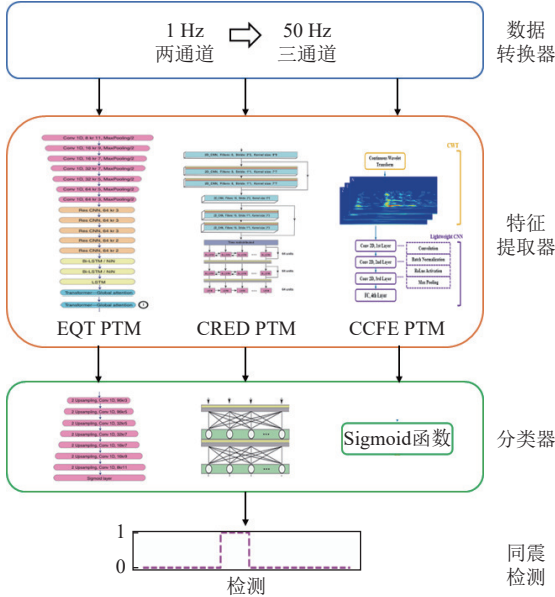


图 2 模型示意图

Fig. 2 Schematic diagram of the model

能。两段测试数据包含的地震事件如表 3 所示。测试数据除记录到多次同震响应事件外, 还记录到台站周边长期存在的抽水干扰, 在数据上表现为多次不定时的同步台阶变化。

表 3 两段测试数据包含的地震事件

Table 3 Seismic events included in the two segments of test data

地震地点	地震时间	震级	震中距/km
印尼塔劳群岛	2024-01-09 04:48	6.6	4011
汤加群岛	2024-01-09 15:53	5.5	9843
日本本州西岸近海	2024-01-09 16:59	5.9	1766
台湾花莲县海域	2024-04-23 02:26	6.3	1863
台湾花莲县	2024-04-23 02:32	6.2	1848
台湾花莲县海域	2024-04-23 04:49	5.8	1862
台湾花莲县	2024-04-23 05:04	5.1	1861
台湾花莲县海域	2024-04-23 05:19	5.2	1854
台湾花莲县	2024-04-23 05:24	5.0	1856
台湾花莲县海域	2024-04-23 05:31	5.3	1849
台湾花莲县	2024-04-23 08:04	6.0	1842
台湾花莲县海域	2024-04-23 09:45	5.0	1850
台湾花莲县海域	2024-04-23 10:21	5.0	1848

2.2 不同预训练模型的性能对比

在测试之前需要对数据完成的唯一预处理步骤是去趋势和归一化。预处理后, 以 1 min 的步长在连续数据中截取 3 种窗长的数据输入模型进行检测,

检测阈值设定为 0.5。

图 3 和图 4 显示了模型在测试数据上的检测结果。2024 年 1 月 29 日的测试数据上, 模型使用 EQT PTM 检测到全部 3 次地震事件, 没有虚报, CCFE PTM 没有虚报但漏报 1 次, CRED PTM 检测到全部 3 次地震事件出现 4 次虚报。2024 年 4 月 23 日的测试数据上, 模型使用 EQT PTM 检测到 10 次地震中的 6 次, 没有虚报, CCFE PTM 检测到 5 次同样没有虚报, CRED PTM 检测到 7 次地震事件出现 4 次虚

报。模型在测试数据上没有出现与受抽水干扰时段对应的错误检测。可以看出, 模型能够在整个测试时段内比较准确的检测到不同地区、不同振幅、不同震中距的地震信号, 没有受到抽水信号的干扰, 除 CRED PTM 外没有出现错误检测, 只有发震间隔较短, 同震信号在输入窗长内相互掩盖的情况下出现部分漏检, 证明模型在测试数据上具有良好的地震检测性能, 有效地将预训练模型在测震数据上的地震检测能力迁移到了 VP 宽频带倾斜仪秒数据上。

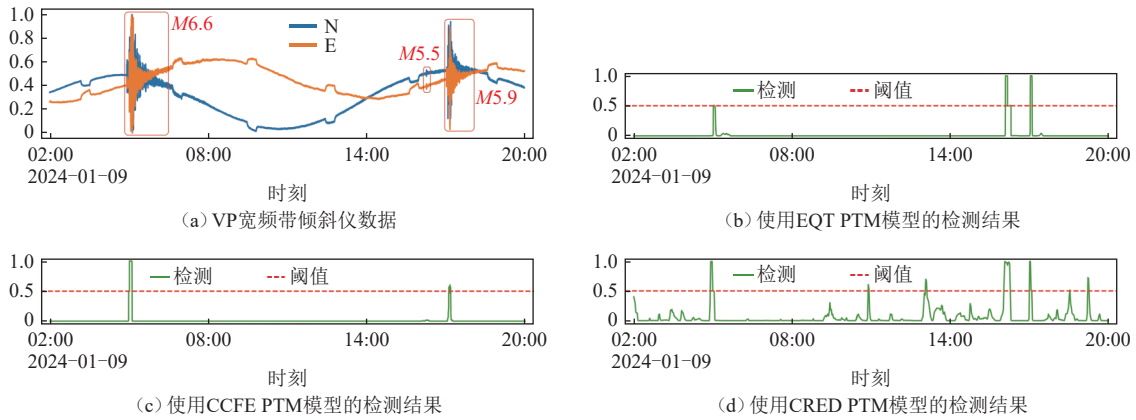


图 3 模型在蓟县台 2024 年 1 月 9 日测试数据上的检测结果

Fig. 3 Test results of model using data from Jixian station recorded on January 9, 2024




图 4 模型在蓟县台 2024 年 4 月 23 日测试数据上的检测结果

Fig. 4 Test results of model using data from Jixian station recorded on April 23, 2024

使用精确率 Pre (Precision)、召回率 Rec (Recall) 和两者的调和平均数 $F1$ 分数 ($F1$ Score) 3 个参数来评估不同预训练模型在测试数据上的检测性能, 参数取值范围为 0~1, 1 表示最佳分类性能, 0 表示最差。其计算公式如下:

$$Pre = \frac{TP}{TP + FP} \quad (1)$$

$$Rec = \frac{TP}{TP + FN} \quad (2)$$

$$F1 = 2 \times \frac{Pre \times Rec}{Pre + Rec} \quad (3)$$

式中, TP (True Positives) 表示正确识别为正例的数量, 即报对数, FP (False Positives) 表示错误识别为正例的数量, 即虚报数, FN (False Negatives) 表示错误识别为负例的正例数量, 即漏报数。测试数据上的混

淆矩阵如表 4 和表 5 所示, EQT PTM 在 F1 分数方面优于其他两种预训练模型, 在精确率和召回率上的

表现更均衡, 表明在蓟县台数据上进行检测时, 使用 EQT PTM 可能是更优的选择。

表 4 不同预训练模型在蓟县台 2024 年 1 月 9 日测试数据上的表现

Table 4 Performance of different pretrained models using test data from Jixian station recorded on January 9, 2024

预训练模型	报对数	虚报数	漏报数	精确率	召回率	F1分数
EQT PTM	3	0	0	1.00	1.00	1.00
CCFE PTM	2	0	1	1.00	0.67	0.80
CRED PTM	3	4	0	0.43	1.00	0.60

表 5 不同预训练模型在蓟县台 2024 年 4 月 23 日测试数据上的表现

Table 5 Performance of different pretrained models using test data from Jixian station recorded on April 23, 2024

预训练模型	报对数	虚报数	漏报数	精确率	召回率	F1分数
EQT PTM	6	0	4	1.00	0.60	0.75
CCFE PTM	5	0	5	1.00	0.50	0.67
CRED PTM	7	4	3	0.64	0.70	0.67

2.3 蓟县台连续数据上的应用

将模型应用于 2024 年 1—6 月蓟县台 VP 宽频带倾斜仪连续数据。模型的特征提取器根据测试数据上的表现选择 EQT PTM, 数据按日进行去趋势和归一化的预处理后以 1 min 步长 50 min 窗长输入模型进行检测, 在配备 3.6 GHz AMD Ryzen 5 的 CPU、NVIDIA GeForce GTX 1070 Ti 的 GPU 和 16.0 GB 内存的电脑上, 完成一日数据检测的总处理时间不超过 5 min。在 6 个月的连续数据上模型共检测出 162 次同震响应事件, 对照中国地震台网中心正式地震目录对检测到的事件进行检查, 有 39 个无法与正式目录里 3 级以上地震对应, 占检测到的事件总数的 24%, 这些检测事件可能与更小震级的地震相关联, 未经进一步确认前不能将它们全部认定为错误检测, 其他 123 个检测事件可以确定为正式目录内地震事件对应的同震响应, 检测精确率不低于 75%, 检测数量是同期台站观测人员通过人工拣选记录在日志中的 38 次同震响应的 3.24 倍。模型检测与人工拣选的同震响应事件数量对比如图 5 所示。对比人工拣选与模型检测的事件列表, 人工拣选的同震响应事件均被模型检出, 表明模型至少达到了人工识别的水平。在各个震级区间, 模型检测出的同震响应事件数量上都不少于人工拣选, 额外事件的检出意味着模型的召回率相较于人工更高, 这种增强的检测能力能够覆盖更长时间或更大规模的定点形变数据, 减少了遗漏的风险。在 4~6 级区间, 模型检出

事件明显多于人工记录, 与台站同志分析讨论后认为, 4~6 级同震事件人工记录偏少和记录人员主观因素导致的判断差异有关, 自动检测模型在各个震级区间具有更高的一致性, 因此在 4~6 级区间能够检测出较人工记录更多的同震事件。4 级以下地震事件, 受仪器性能所限, 记录能力较弱, 模型检出和人工记录的事件数量均较少。




图 5 蓟县台 2024 年 1—6 月模型检测与人工拣选记录地震数量对比

Fig. 5 Comparison of number of earthquakes recorded by model detection and manual selection at Jixian station from January to June 2024

检测时间段内, 蓟县台 VP 宽频带倾斜仪数据出现 3 次短时秒数据缺失等观测系统干扰, 1 次气压扰动造成的环境干扰, 4 次调零标定等造成的人为干扰和 5 次突跳畸变等未知原因的数据变化。经检查, 这些非地震因素数据扰动均未造成模型错误检测, 显示出模型对于非地震扰动信号较强的鲁棒性。

3 结语

针对定点形变数据同震响应识别依靠人工拣选, 尚未有自动检测方法投入应用的问题, 本文提出专门针对定点形变数据的同震响应检测深度学习模型。利用3种代表性测震数据地震检测预训练模型, 即EQT模型、CRED模型和CCFE模型, 这些预训练模型在大规模地震数据集上进行了充分训练。通过迁移学习, 这些模型能够继承预训练模型的检测能力, 获得定点形变数据上良好的检测性能。

模型在蓟县台6个月连续数据上的检测精确率不低于75%, 不仅能够检测出人工记录的所有同震响应事件, 还能够发现更多人工未能识别的事件, 检测数量是人工记录的3.24倍, 显著提高了检测召回率。模型在各个震级区间能够保持一致的性能, 避免因主观因素而产生的判断差异。模型在不同类型的

地震数据和复杂的干扰环境中表现出良好的鲁棒性。与传统的人工拣选方法相比, 模型能够快速处理大规模数据, 大幅提升了检测效率。

除蓟县台数据以外, 模型将在更多台站定点形变数据上进行检测应用与分析, 通过多台数据的测试与检验进一步完善已有模型, 提高检测性能。通过模型协助人工有望实现快速准确的同震响应信号检测, 帮助多台产出各自更完整更准确的同震响应目录, 服务于监测预报和科研工作, 为深度学习在前兆地球物理观测领域的应用拓展提供新的路径。后续通过对检测目录内事件的清洗、结构化和标签化, 可以构建本地定点形变观测地震数据集, 使用本地数据集对模型继续训练微调, 有望进一步提升模型在本地数据上的检测性能, 实现模型的本地化迭代优化。

参考文献

- [1] 吴翼麟. 定点形变前兆预报地震的观测技术与分析方法[J]. 地震, 1990(5): 33-46
Wu Y L. Observatory techniques and data analyses for earthquake prediction by precursors observed at deformation stations[J]. Earthquake, 1990(5): 33-46
- [2] 张燕, 王迪晋, 赵莹, 等. 定点形变观测现状及研究进展[J]. 武汉大学学报(信息科学版), 2022, 47(6): 830-838
Zhang Y, Wang D J, Zhao Y, et al. Present and progress of fixed-point deformation observation[J]. Geomatics and Information Science of Wuhan University, 2022, 47(6): 830-838
- [3] 杨玲英, 崔庆谷, 毛先进, 等. 云龙地震台水管倾斜仪与水平摆倾斜仪同震响应对比分析[J]. 地震研究, 2012, 35(1): 48-52
Yang L Y, Cui Q G, Mao X J, et al. Comparative analysis of the co-seismic response between water-tube and horizontal pendulum tiltmeters in Yunlong seismic station[J]. Journal of Seismological Research, 2012, 35(1): 48-52
- [4] 杨东辉, 纪春玲, 王嘉琦, 等. 承德地区宽频带倾斜仪与宽频带地震计同震响应融合分析[J]. 地震科学进展, 2025, 55(1): 21-29
Yang D H, Ji C L, Wang J Q, et al. Fusion analysis of co-seismic response between broadband tiltmeters and broadband seismometers in Chengde area[J]. Progress in Earthquake Sciences, 2025, 55(1): 21-29
- [5] 狄樑, 陆德明, 丁建国. 常熟地震台水管倾斜仪与垂直摆倾斜仪同震响应对比分析[J]. 大地测量与地球动力学, 2013, 33(增刊1): 79-81
Di L, Lu D M, Ding J G. Comparative analysis of co-seismic response between water-tube and vertical pendulum tiltmeters in Changshu seismostation[J]. Journal of Geodesy and Geodynamics, 2013, 33(S1): 79-81
- [6] 杨德贺, 袁静, 王秀英, 等. 形变观测数据的多异常形态统一识别[J]. 地球物理学报, 2017, 60(12): 4623-4632
Yang D H, Yuan J, Wang X Y, et al. Identification of multi-anomalies of precursory deformation data[J]. Chinese Journal of Geophysics, 2017, 60(12): 4623-4632
- [7] 刘明辉, 李江, 沙成宁, 等. 基于小波分析对形变扰动信号的触发检测方法[J]. 大地测量与地球动力学, 2023, 43(12): 1229-1234
Liu M H, Li J, Sha C N, et al. Trigger detection method of deformation disturbance signal based on wavelet analysis[J]. Journal of Geodesy and Geodynamics, 2023, 43(12): 1229-1234
- [8] 赵明, 陈石, Yuen D. 基于深度学习卷积神经网络的地震波形自动分类与识别[J]. 地球物理学报, 2019, 62(1): 374-382

- Zhao M, Chen S, Yuen D. Waveform classification and seismic recognition by convolution neural network[J]. *Chinese Journal of Geophysics*, 2019, 62(1): 374-382
- [9] Mousavi S M, Zhu W Q, Sheng Y X, et al. CRED: A deep residual network of convolutional and recurrent units for earthquake signal detection[J]. *Scientific Reports*, 2019, 9(1): 10267
- [10] Mousavi S M, Ellsworth W L, Zhu W Q, et al. Earthquake transformer: An attentive deep-learning model for simultaneous earthquake detection and phase picking[J]. *Nature Communications*, 2020, 11(1): 3952
- [11] Saad O M, Huang G T, Chen Y F, et al. SCALODEEP: A highly generalized deep learning framework for real-time earthquake detection[J]. *Journal of Geophysical Research: Solid Earth*, 2021, 126(4): e2020JB021473
- [12] Peng Z, Shao Y Q, Xia S A. CCFE: A few-shot learning model for earthquake detection and phase identification[J]. *IEEE Access*, 2022, 10: 124629-124636
- [13] Bilal M A, Wang Y Z, Ji Y J, et al. Earthquake detection using Stacked Normalized Recurrent Neural Network (SNRNN)[J]. *Applied Sciences*, 2023, 13(14): 8121
- [14] 向健斌, 余腾, 张丹丹, 等. 高泛化性模型在郯庐断裂带中南段 b 值与中强震回溯中的应用 [J]. *地震科学进展*, 2024, 54(12): 868-877
- Xiang J B, Yu T, Zhang D D, et al. Application of high generalization model in the b -value and medium and strong earthquake backtracking of the central and southern section of the Tanlu fault zone[J]. *Progress in Earthquake Sciences*, 2024, 54(12): 868-877
- [15] Dokht R M H, Kao H, Visser R, et al. Seismic event and phase detection using time-frequency representation and convolutional neural networks[J]. *Seismological Research Letters*, 2019, 90(2A): 481-490
- [16] Zhu W Q, Beroza G C. PhaseNet: A deep-neural-network-based seismic arrival-time picking method[J]. *Geophysical Journal International*, 2019, 216(1): 261-273
- [17] 赵明, 陈石, 房立华, 等. 基于 U 形卷积神经网络的震相识别与到时拾取方法研究 [J]. *地球物理学报*, 2019, 62(8): 3034-3042
- Zhao M, Chen S, Fang L H, et al. Earthquake phase arrival auto-picking based on U-shaped convolutional neural network[J]. *Chinese Journal of Geophysics*, 2019, 62(8): 3034-3042
- [18] Saad O M, Chen Y F, Siervo D, et al. EQCCT: A production-ready earthquake detection and phase-picking method using the compact convolutional transformer[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 4507015
- [19] Mousavi S M, Beroza G C. Deep-learning seismology[J]. *Science*, 2022, 377(6607): eabm4470
- [20] Pan S J, Yang Q. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345-1359
- [21] 朱冰清, 王建国, 郭巍, 等. 天津地区 VP 宽频带倾斜仪与宽频带地震仪数据融合分析 [J]. *大地测量与地球动力学*, 2021, 41(7): 759-764
- Zhu B Q, Wang J G, Guo W, et al. Data fusion analysis of vertical pendulum broadband tiltmeter and broadband seismometer in Tianjin[J]. *Journal of Geodesy and Geodynamics*, 2021, 41(7): 759-764
- [22] Mousavi S M, Sheng Y X, Zhu W Q, et al. STanford EArthquake Dataset (STEAD): A global data set of seismic signals for AI[J]. *IEEE Access*, 2019, 7: 179464-179476