

基于卷积神经网络的单台震中距估计

李山有^{1,2},王禹轩^{1,2},宋晋东^{1,2},姚鹏鹏³,黄鹏杰³,朱景宝^{1,2}

(1. 中国地震局工程力学研究所 地震工程与工程振动重点实验室,黑龙江 哈尔滨 150080; 2. 地震灾害防治应急管理部重点实验室,黑龙江 哈尔滨 150080; 3. 河南辉煌科技股份有限公司 安防产品部,河南 郑州 450012)

摘要:单台震中距估计是现场地震预警的重要工作之一。针对传统的 $B-\Delta$ 方法在震中距估计中存在的利用 P 波信息有限且预测误差较大的局限性,使用日本 K-NET 台网的强震动数据,将 3 s 时间窗长度的三分量加速度波形作为输入,利用卷积神经网络直接从波形中提取特征信息,建立了基于卷积神经网络的单台震中距估计(Convolutional Neural Network for epicentral Distance estimation, CNN-Dis)模型。研究表明:在测试数据集中,通过对输入数据和标签进行归一化处理,CNN-Dis 模型震中距估计的平均绝对误差和标准差分别是 28.1196 和 34.6827 km,且优于未进行归一化处理的模型的性能;对比传统的 $B-\Delta$ 方法,CNN-Dis 模型提高了震中距估计的可靠性;与内陆地震事件相比,CNN-Dis 模型对于海域地震的震中距估计也有相对可靠的结果。所构建的 CNN-Dis 模型在一定程度上提高了震中距估计的准确性,为地震预警技术迭代与性能优化提供了有力的支持。

关键词:地震预警;机器学习;卷积神经网络;震中距估计;P波;归一化

中图分类号:P315.3; P315.7; P315.92

文献标志码:A

Epicentral distance estimation from a single station based on convolutional neural network

LI Shanyou^{1,2}, WANG Yuxuan^{1,2}, SONG Jindong^{1,2}, YAO Kunpeng³, HUANG Pengjie³, ZHU Jingbao^{1,2}

(1. Key Laboratory of Earthquake Engineering and Engineering Vibration, Institute of Engineering Mechanics, China Earthquake Administration, Harbin 150080, China; 2. Key Laboratory of Earthquake Disaster Mitigation, Ministry of Emergency Management, Harbin 150080, China; 3. Department of Security Products, Henan Splendor Science & Technology Co., Ltd., Zhengzhou 450012, China)

Abstract: Estimating the epicentral distance from a single station is a critical task in real-time earthquake early warning systems. To address the limitations of the traditional $B-\Delta$ method, which relies on limited P-wave information and exhibits significant prediction errors, this study utilizes strong-motion data from the Japan K-NET network. A 3-second time window of three-component acceleration waveforms is used as input to a convolutional neural network (CNN), which directly extracts feature information from the waveforms to establish a CNN-based epicentral distance estimation model (CNN-Dis). The results show that in the test dataset, by normalizing both the input data and labels, the CNN-Dis model achieves a mean absolute error (MAE) of 28.1196 km and a standard deviation of 34.6827 km, outperforming the model without normalization. Compared to the traditional $B-\Delta$ method, the CNN-Dis model improves the reliability of epicentral distance estimation. Moreover, the CNN-Dis model provides relatively reliable results for offshore earthquakes, in contrast to inland events. The CNN-Dis model enhances the accuracy of epicentral distance estimation to a certain extent and provides strong support for the iteration and performance optimization of earthquake early warning technologies.

Key words: earthquake early warning; machine learning; convolutional neural network; epicentral distance estimation; P-wave; normalization

收稿日期:2024-10-08; 修回日期:2025-04-10

基金项目:中国地震局工程力学研究所基本科研业务费专项资助项目(2024B08);中国国家铁路集团有限公司科技研究开发计划项目(K2024G008)

作者简介:李山有(1965—),男,研究员,博士,主要从事地震预警与地震紧急处理技术研究。E-mail:shanyou@iem.ac.cn

通信作者:朱景宝(1996—),男,助理研究员,博士,主要从事机器学习地震预警研究。E-mail:zhujingbao@iem.ac.cn

0 引言

地震作为自然界中极具破坏力的灾害之一,地震预警系统的有效性和及时性对于减少人员伤亡与财产损失至关重要^[1-4]。地震预警系统的核心是在破坏性地震波到达目标场地前几秒至几十秒内发出预警信息,使得人们可以提前采取防震避险措施^[5-7]。单台震中距估计是现地地震预警的重要工作之一^[8-9],震中距估计结果对于单台地震定位、地震影响范围和强度的确定、高铁地震预警,以及震级估计等都是尤为重要的^[10-13]。单台震中距估计对于处理海域地震以及台站稀疏区域的地震预警地震定位也是非常重要的。

传统的地震预警单台震中距估计方法主要利用P波信号中提取的单一或少量的特征建立与震中距之间的线性关系^[14-15]。 $B-\Delta$ 方法是一种被广泛用于地震预警单台震中距估计的方法,该方法是利用垂直方向的P波初始加速度幅值增长率建立与震中距的线性关系^[16]。日本、伊朗和韩国等国家验证了 $B-\Delta$ 方法在地震预警震中距估计中的可行性^[17-19]。还有一些研究人员在 $B-\Delta$ 方法的基础上,对 $B-\Delta$ 方法进行简化,提出了用于震中距估计的 $C-\Delta$ 方法^[20-21]。由于提取的单一、有限特征限制了可用于震中距估计的信息量,传统的震中距估计方法多依赖于经验公式或简单的物理模型,难以全面捕捉地震波的复杂特性,这在一定程度上导致震中距估计结果存在较大的不确定性。

随着人工智能特别是机器学习技术的快速发展,机器学习模型以其强大的特征提取和复杂模式识别能力,其在地震学领域得到了广泛的研究和应用并取得了不错的结果^[22-23],包括震相识别^[24-25]、震级估计^[26-29]和现地地震动峰值预测^[30-31]等。机器学习方法在震中距估计中也得到了初步的探索和研究^[32]。BÖSE等^[33]使用人工神经网络对震中距进行估计,将基于加速度波形、速度波形和位移波形计算得到的积分绝对振幅的对数值作为人工神经网络的输入。OCHOA等^[34]使用支持向量机算法建立震中距估计模型,将从地震波形中提取的25个特征作为模型的输入,包括与震级相关的特征、与震中距相关的特征,以及与方位角相关的特征。MOUSAVI等^[35]提出了一种基于贝叶斯深度学习的震中距估计模型,作为模型输入的是60 s的三分量地震动记录且包含P波和S波到时信息,而该方法在地震预警中的时效性较低。利用从地震波形中提取的特征作为机器学习模型的输入,可能会忽视掉尚未从地震波形中提取到的重要特征。

为了提高地震预警震中距估计的可靠性,文中建立了一种基于卷积神经网络的震中距估计模型,称之为CNN-Dis模型。区别于ZHU等^[32]提出的基于机器学习的震中距估计方法,该模型在设计的过程中源于对模型泛化能力、震中距数据的分布范围差异、模型复杂度,以及模型输入方式的考量,进而设计利用卷积神经网络从单个台站记录的三分量加速度波形中提取特征进而估计震中距。具体而言,CNN-Dis模型直接以单台站记录的三分量加速度波形(P波起始后3 s)为输入,通过卷积神经网络提取时频联合特征以估计震中距;同时,针对震中距范围跨度大、震级和台站分布不均衡等因素,对输入和标签进行了归一化处理以提升模型的鲁棒性与泛化能力。

在试验中,我们使用了与ZHU等^[32]研究中相似的日本K-NET台网的强震动数据进行训练与测试。需要指出的是,ZHU等工作所使用的 $B-\Delta$ 方法在其研究数据集上表现出较小的平均绝对误差(mean absolute error, MAE)和标准差(standard deviation, SD),分别约为15 km与20 km,但我们在复现试验中发现,该方法在不同数据覆盖范围和预处理设置下,其估计精度可能会有较大差异。为确保公平性,我们复现的 $B-\Delta$ 方法采用与CNN-Dis模型相同的数据集与预处理流程,结果显示其估计偏差显著增大(详见图7),这表明传统 $B-\Delta$ 方法对数据质量及特征分布较为敏感。相比之下,CNN-Dis模型在同一数据集下表现出更强的适应能力与稳定性,在震中距估计误差整体上优于 $B-\Delta$ 方法,尤其在远震(震中距 ≥ 120 km)场景下性能提升明显。本研究进一步分析了模型估计误差与数据信噪比的关系,发现不同误差的数据在信噪比上略有不同,提示未来模型优化可结合信噪比或质量因子 Q 值等信息进行联合建模。

1 数据

1.1 地震数据

选用2011—2020年日本K-NET台站记录的强震动数据作为数据源。根据前人的研究,使用了数据源中震级大于5.5级且震中距小于300 km的7196组三分量加速度记录。使用的地震数据的震中分布如图1

所示,在选用的地震动数据中,地震事件中海域地震与内陆地震均存在,且海域地震事件的震中主要分布在日本东部沿海地区。对 7 196 组三分量加速度记录通过随机抽样的形式划分为训练集与测试集,划分比例为 8:2,即随机抽取 80%的数据作为训练集,其余 20%的数据作为测试集。图 2 展示了不同震中距范围和不同震级范围下的记录数量的分布。




图 1 使用的地震事件震中分布

Fig. 1 Distribution of earthquake epicenters utilized in this article




图 2 不同震中距和不同震级范围下的记录数量分布

Fig. 2 Distribution of the number of records across different epicentral distances and magnitude ranges

1.2 数据预处理

根据 1.1 节中获取的地震数据,对其进行了相应的数据预处理。

第一步,采用长短时平均与 AIC(Akaike Information Criterion)准则相结合的方法确定 P 波到时,并人工校核 P 波到时结果^[36]。

第二步,根据前人的研究以及考虑地震预警的时效性^[37-38],截取 P 波到时后 3 s 的地震记录作为研究数据。

第三步,对三分量的加速度记录进行带通滤波。

第四步,将滤波后的三分量的加速度记录进行标准化处理,并将标准化后的数据作为卷积神经网络的输入。标准化有助于模型更好地学习和泛化,当数据在不同维度上具有相似的分布时,模型可以更容易地捕捉到数据中的有用特征,而不会因为尺度的不同而忽略某些重要的信息。数据的标准化处理,即将加速度记录按照其均值和标准差进行转换,使得每条记录的均值为 0,标准差为 1。标准化公式如下:

$$X_{\text{norm}} = \frac{X - \mu}{\sigma} \quad (1)$$

式中: X 为标准化前的数据; μ 为数据的均值; σ 为数据的标准差; X_{norm} 为标准化后的数据。

第五步,对模型训练的标签归一化。模型训练的标签震中距,即对所有样本对应的震中距进行归一化处理。进一步对标签数据进行了对数变换和最小最大归一化(min-max normalization)。震中距数据的取值范

围较大,直接使用可能导致训练过程中的梯度不稳定。因此,对震中距取对数变换,然后使用 min-max 归一化将其映射到 $[0,1]$ 的范围内。对数变换是为了缩小震中距的数值范围,减少较大数值对模型训练的不利影响,计算公式如下:

$$y_{\ln} = \ln(1 + y) \quad (2)$$

式中: y 为原始震中距; y_{\ln} 为对数变换后的震中距。然后,将对数变换后的震中距数据进行归一化处理,将其映射到 $[0,1]$ 区间,计算公式如下:

$$y_{\text{scaled}} = \frac{y_{\ln} - \min(y_{\ln})}{\max(y_{\ln}) - \min(y_{\ln})} \quad (3)$$

式中: $\min(y_{\ln})$ 为数据的最小值; $\max(y_{\ln})$ 为数据的最大值; y_{scaled} 为归一化后的数据,且作为模型训练的标签。

2 方法

卷积神经网络(convolutional neural network, CNN)以其独特的局部连接、权重共享和池化层设计,在图像处理、视频分析以及许多其他领域展现了显著的优势。这些特性使得 CNN 能够自动地从原始图像中提取复杂且有用的特征,有效减少网络参数数量,增强模型的泛化能力,同时提高处理效率,尤其是在处理大规模图像数据时,其性能表现尤为突出。卷积神经网络在地震学相关领域表现出显著的优势^[39-41]。

为了提高震中距估计的可靠性,基于卷积神经网络建立 CNN-Dis 模型用于震中距估计,并采用 1.2 节介绍的训练和测试数据对 CNN-Dis 模型进行训练和测试。通过不断调整模型的卷积层深度确定最终 CNN-Dis 模型架构,以 1 个卷积层、归一化层、最大池化层为一层深度,验证不同深度下的估计结果进行对比分析,最终选用 3 层作为最终深度,对比结果见表 1。

表 1 不同卷积层深度下的估计结果对比

Table 1 Comparison of estimation results under different convolutional layer depths

评价指标	深度			
	1 层	2 层	3 层	4 层
MAE/km	29.9946	30.8235	28.1196	31.9856
SD/km	35.6865	37.7159	34.6827	39.6236

图 3 展示了 CNN-Dis 模型的网络架构示意图。CNN-Dis 模型主要由 1 个输入层、3 个卷积层、3 个归一化层、3 个最大池化层、1 个展开层、3 个全连接层和 3 个 Dropout 层组成。

输入层为 1.2 节归一化后的 P 波到达后 3 s 的三分量的加速度数据。卷积层用于自动提取输入数据的局部特征。卷积核在输入数据上滑动,通过计算点积和激活函数的应用,生成特征图。这些特征图不仅捕捉了加速度数据在时间维度上的变化,还隐式地包含了不同方向间的相互关系。每个卷积层的卷积核数量依次为 32、64 和 128,卷积核的大小为 3,卷积核的移动步长为 1,每个卷积层采用了 ReLU 激活函数以提供非线性映射。每个卷积层后使用了批量归一化层(batch normalization),其目的是加速训练并提高模型训练稳定性,通过对每一层的输出进行标准化来减少内部协变量偏移。每个批量归一化层后使用了最大池化层,池化层中池化核的大小为 2,插入池化层可以减少特征图的维度,从而减少计算量并防止模型过拟合。然后通过展开层将池化层输出展平为一维,并输入给全连接层。3 个全连接层的神经元数量分别是 128、64 和 1。前两个全连接层使用的是 ReLU 激活函数,最后一个全连接层使用的是线性激活函数以输出预测震中距,即 1.2 节中对应的 y_{scaled} 。为了防止模型过拟合,每个卷积层和前两个全连接层还采用了 L2 正则化,以及前两个全连接层后使用了 Dropout 层,且每个 Dropout 层的丢弃率设置为 0.3。

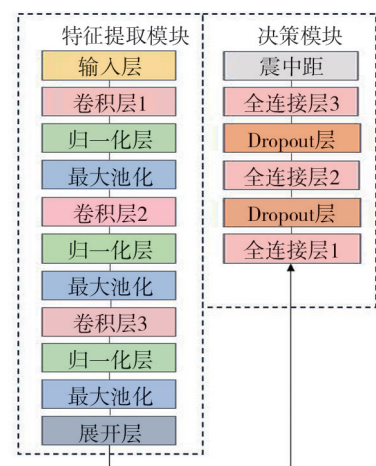


图 3 模型架构示意图

Fig. 3 Schematic diagram of the model architecture

3 结果和讨论

基于测试数据集,在 P 波触发后 3 s,分析输入数据和标签数据归一化对模型性能的影响,比较 CNN-Dis 模型和 $B-\Delta$ 方法的震中距估计结果,分析不同震中距范围下,以及海域地震和内陆地震事件的震中距估计结果。最终以估算震中距与实际震中距的差异作为结果分析,并选用 MAE 和 SD 两者作为误差的评价指标,上述两种评价指标反映了估计值与实际值的误差及误差离散性,根据本研究的目的来看,上述两种评价指标越低,即代表着模型的估计情况越好,可靠性越高。

在带通滤波的选择部分,通过分析在不同带通滤波下的误差评价指标 MAE 与 SD,参考一般选用的中频滤波频段的 0.1~10.0 Hz 的基础上进行改进^[42-43],充分考量在不同频率下地震波所包含的地震信息,可以得出在当前数据集下不同带通滤波下的误差分布折线图,如下图 4 所示。其中在 0.1~40.0 Hz 下的带通滤波取得了最小的估计误差,因此,选用 0.1~40.0 Hz 作为数据处理过程中的带通滤波参数。

在地震预警系统中,震动信息是随时间逐步丰富的:地震发生初期,仅有部分初动信息可用,随着地震波的传播和记录数据的积累,信号的频带、能量及形态逐渐明晰。因此,一个有效的震中距估计模型应具备适应信息逐步增强的能力,即在较短时间窗下提供初步估计,在时间窗延长后进一步提升精度,从而支持“由快至准”的预警响应流程。

本研究中,基于上述分析得到的合理的输入特征,可以得到经过带通滤波及归一化后的加速度作为特征输入,我们进一步讨论了不同时间窗下的地震动特征作为输入,系统地评估了 CNN-Dis 模型在不同信息丰富程度下的震中距估计性能。实验结果见表 2,模型在时间窗逐步扩展的过程中,估计精度表现出明显的渐进式提升趋势。在 2.0 s 时间窗下,模型的 MAE 为 28.57 km,SD 为 35.32 km;随着时间窗增加至 6.0 s,MAE 和 SD 分别降低至 26.76 km 与 33.36 km;在 8.5 s 与 9.0 s 时间窗下,模型达到最优性能,MAE 为 26.21 km,SD 为 32.93 km。整体趋势表明,CNN-Dis 模型能够有效利用逐步丰富的地震动信息,动态提升估计结果的可靠性。最后在充分权衡估计精度与预警时效性的基础上,本文最终选择 P 波触发后 3 s 的加速度波形作为模型输入,作为精度与时效性的折中选择。

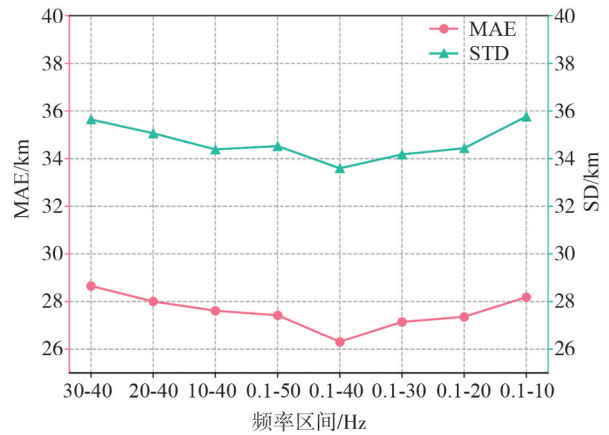


图 4 不同带通滤波下的误差分布折线图

Fig. 4 Error distributions line chart under different bandpass filters

表 2 不同时间窗下 CNN-Dis 模型的震中距估计结果

Table 2 Epicentral distance estimation results of the CNN-Dis model under different time windows

评价指标	2.0 s 时间窗	2.5 s 时间窗	3.0 s 时间窗	3.5 s 时间窗	4.0 s 时间窗	4.5 s 时间窗
MAE/km	28.568 5	28.386 0	28.119 6	28.156 1	27.709 7	27.800 0
SD/km	35.320 2	35.084 7	34.682 7	35.000 2	33.922 5	34.491 7
评价指标	5.0 s 时间窗	5.5 s 时间窗	6.0 s 时间窗	6.5 s 时间窗	7.0 s 时间窗	7.5 s 时间窗
MAE/km	27.348 4	27.216 3	26.771 2	26.760 4	26.730 9	26.741 6
SD/km	33.945 2	33.684 5	33.360 8	33.564 1	33.547 3	33.537 8
评价指标	8.0 s 时间窗	8.5 s 时间窗	9.0 s 时间窗	9.5 s 时间窗	10.0 s 时间窗	
MAE/km	26.720 7	26.536 5	26.205 8	26.236 4	26.075 9	
SD/km	33.532 1	33.103 9	32.934 9	33.951 2	33.508 3	

为了进一步分析 CNN-Dis 模型的性能,文中比较了 CNN-Dis 模型与传统的地震预警震中距估计 $B-\Delta$ 方法在相同测试数据集上的震中距估计结果。参考 ODAKA^[16]提出的震中距估计 $B-\Delta$ 方法,采用和 CNN-Dis 模型相同的训练数据集建立 P 波到达后 3.0 s 的震中距估计等式为

$$\log_{10}(B) = -1.5637 \log_{10}(\Delta) + 3.3135 \quad (4)$$

式中： B 为 P 波包络初始部分的增长率， Δ 为震中距。根据上述震中距预测等式可以对测试数据集的震中距进行预测。

表 3 展示了在 P 波触发后 3.0 s, CNN-Dis 模型与 B - Δ 方法在相同测试数据集上的震中距估计结果。从表 3 中可以发现,和 B - Δ 方法相比,CNN-Dis 模型的震中距估计结果有更小的 MAE 和 SD。这也意味着,CNN-Dis 模型可以从三分量的加速度波形数据中提取更多重要的与震中距相关的信息,提升了震中距估计的可靠性。

表 3 CNN-Dis 模型与 B - Δ 方法的震中距估计结果

评价指标	CNN-Dis 模型	B - Δ 方法
MAE/km	28.1196	55.9751
STD/km	34.6827	75.0513

对 CNN-Dis 模型的震中距估计结果加以分析不难看出,其精度虽相较于传统的 B - Δ 方法有了一定程度上的改进,但仍存在着部分数据估计精度欠佳的问题,针对这部分问题,以估计值与真实值差值的绝对值为评价指标,分别选用参考上述评价指标的震中距估计误差数值较大的 20% 部分地震事件与误差数值较小的 20% 部分地震事件作为研究对象,经过估算得到震中距估计误差较大的部分为估计误差大于 74.36 km 的震中距估计事件,震中距估计误差较小的部分为估计误差小于 17.59 km 的震中距估计事件,以震中距、震级、信噪比作为评价指标加以分析,上述三者的分布关系如图 5 所示。




图 5 误差较大与较小数据的震中距、震级、信噪比对比

Fig. 5 Comparison data with large and small errors of epicentral distance, magnitude, and signal-to-noise ratio

从图 5 可以看出,两组数据在震级及震中距的分布上总体差异不大,这说明模型的震中距估计误差并不显著依赖于事件本身的震级或传播距离。然而,图 5 中信噪比对比所示的信噪比分布呈现出一定的差异性——误差较小的数据集的 SNR (signal-to-noise ratio) 整体略高于误差较大的数据集。

为进一步验证这种趋势,我们在图 6 中绘制了两组数据的 SNR 直方图。可以观察到,尽管存在较大程度的重叠,但误差较小组在较高 SNR 区间(如 >30) 中的样本数量相对更多,这在一定程度上暗示信噪比可能对模型在部分样本上的震中距估计有影响。

为避免主观判断,我们计算了 SNR 与震中距估计误差的 Pearson 相关系数,如公式(5)所示,其计算结果为 $r = -0.17$,表明其相关性较弱。这说明在当前数据条件下,信噪比并非影响模型估计性能的主要因素,推测可能还受到波形复杂性、事件覆盖结构不均或模型泛化能力的影响。

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (5)$$

式中： x_i 为变量 SNR 的第 i 个样本； y_i 为变量估计误差的第 i 个样本； \bar{x} 、 \bar{y} 为变量的平均值； r 为相关系数,取值范围为 $[-1, 1]$,越接近 0 表示线性无关。

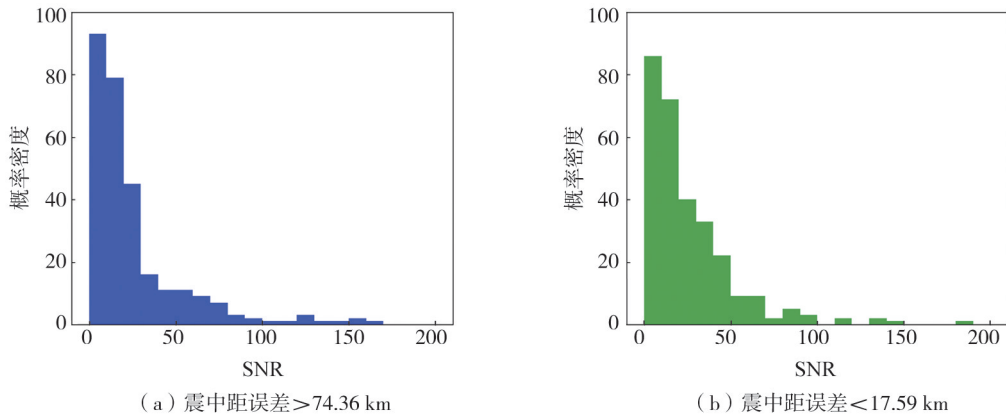


图 6 误差较大与较小数据的信噪比分布柱状图

Fig. 6 Distribution of signal-to-noise for ratio for large and small errors

为了分析 CNN-Dis 模型在不同震中距范围下的震中距预测性能,进一步比较了 CNN-Dis 模型和 $B-\Delta$ 方法在震中距小于 120 km 和震中距大于 120 km 下的震中距估计误差分布。如图 7 所示,其中各子图展示的分别为不同方法及震中距范围下的估计误差(估计值与真实值的差值),从中可以发现,和 $B-\Delta$ 方法相比,不论实际震中距小于 120 km 还是实际震中距大于 120 km 的工况下,CNN-Dis 模型都有更小的震中距估计误差分布。表 4 展示了在测试数据集上,CNN-Dis 模型和 $B-\Delta$ 方法在不同实际震中距范围下的震中距估计误差的平均绝对误差和标准差。从表 4 中可以发现,CNN-Dis 模型在震中距小于 120 km 时的 MAE 和 SD 分别为 26.725 3 和 24.867 5 km 且小于 $B-\Delta$ 方法在震中距小于 120 km 时的 MAE(47.866 0 km)和 SD(68.364 7 km); CNN-Dis 模型在震中距大于 120 km 时的 MAE 和 SD 分别为 29.322 7 km 和 29.396 0 km 且小于 $B-\Delta$ 方法在震中距小于 120 km 时的 MAE(69.168 6 km)和 SD(86.299 1 km)。这也意味着在不同实际震中距范围下,和 $B-\Delta$ 方法相比,CNN-Dis 模型提高了震中距估计的可靠性。

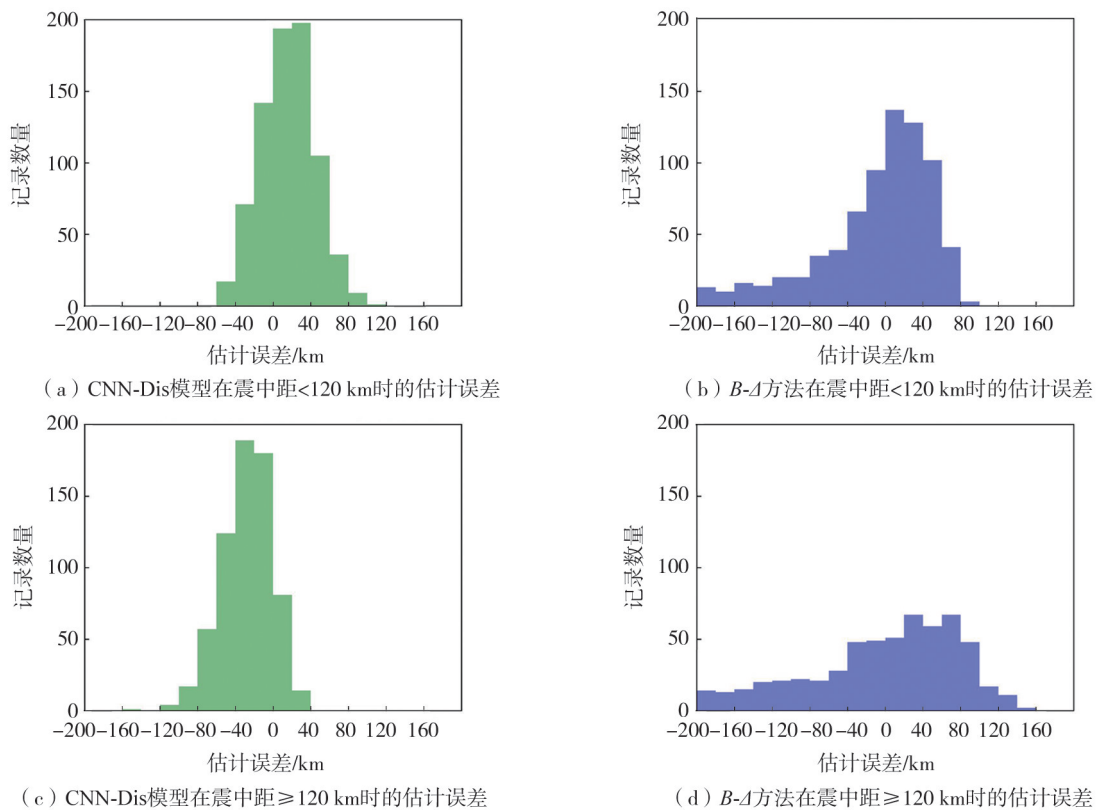


图 7 CNN-Dis 模型和 $B-\Delta$ 方法在不同震中距范围下的估计误差分布

Fig. 7 Distribution of estimation errors for the CNN-Dis model and the $B-\Delta$ method across different epicentral distance ranges

对于上述情况加以进一步分析,研究中所设计的 CNN-Dis 模型考虑到模型的泛化能力要求,在数据集上选用 0~240 km 的震中距范围作为研究对象,模型更倾向于关注 0~240 km 整体的表现,而非局部震中距范围的细节。因此,模型可能在较近震中距区域(0,120]存在一定的过拟合倾向,而在较远震中距区域(120,240]则可能是数据稀缺导致低估现象的出现。(0,120]和(120,240]范围内的近震与远震,其主要影响因素也有所不同,例如近震受地震源特性和传播路径的影响较大,而远震则可能受到较强的地震波衰减和波形畸变的影响,这也是模型估计偏差产生的原因之一。

表 4 不同方法在不同震中距范围上的表现情况

Table 4 Performance of different methods across various epicentral distance ranges

评价指标	0 km<震中距≤120 km		120 km<震中距≤240 km	
	B-Δ 方法	CNN-Dis 模型	B-Δ 方法	CNN-Dis 模型
MAE/km	47.8660	26.7253	69.1686	29.3227
SD/km	68.3647	24.8675	86.2991	29.3960

这里进一步分析了 CNN-Dis 模型对日本内陆地震和日本海域地震的震中距估计误差。表 5 展示了 CNN-Dis 模型和 B-Δ 方法对本研究测试数据集中内陆地震和海域地震的震中距估计误差统计,从中可以发现,CNN-Dis 模型对于内陆地震的震中距估计误差的 MAE 和 SD 分别为 29.1273 km 和 32.8752 km,且小于 B-Δ 方法的 MAE(60.0970 km)和 SD(80.0533 km);CNN-Dis 模型对于海域地震的震中距估计误差的 MAE 和 SD 分别为 26.6168 km 和 32.6741 km,且小于 B-Δ 方法的 MAE(54.9523 km)和 SD(73.4040 km);和内陆地震事件相比,CNN-Dis 模型对于海域地震的震中距估计也有相对可靠的结果。这也说明,和 B-Δ 方法相比,提出的 CNN-Dis 模型对日本的内陆地震和海域地震的震中距估计上具有更好的表现。还可以发现,CNN-Dis 模型在海域地震事件上的表现更好,也侧面印证了近岸单台站用于海域地震预警的科学性与合理性,也为进一步优化海域单台站地震预警提供了思路经验。

表 5 内陆地震和海域地震的震中距估计误差统计

Table 5 Statistical analysis of epicentral distance estimation errors for inland and offshore earthquakes

评价指标	内陆地震		海域地震	
	CNN-Dis 模型	B-Δ 方法	CNN-Dis 模型	B-Δ 方法
MAE/km	29.1273	60.0970	26.6168	54.9523
SD/km	32.8752	80.0533	32.6741	73.4040

对陆域事件和海域事件的估计结果进行了进一步的分析。通过对研究采用的数据集的震中距分布的分析,如图 8 所示,其结果不难看出,陆域事件的震中距整体上是小于海域事件的震中距,考虑到之前模型计算得到其在震中距较小的区间上误差更小效果也更好,因此在仅考虑震中距分布的情况下陆域事件的效果应该是优于海域事件的,但实际结果却与之矛盾。因此,模型训练中的数据分布并不直接影响陆域与海域事件震中距的估计效果。




图 8 陆域事件与海域事件的震中距分布图

Fig. 8 Distribution of epicentral distance for onshore and offshore events

4 结论

为了提高震中距估计的鲁棒性,本研究基于卷积神经网络建立了单台震中距估计 CNN-Dis 模型,并将

单个地震台站记录的P波触发后3s的三分量加速度记录作为CNN-Dis模型的输入,采用日本K-NET台站记录的强震动数据对CNN-Dis模型进行训练和测试。通过分析CNN-Dis模型的震中距估计结果可以得到以下结论:

1)不同于现有的依赖于从地震波形中提取特征的震中距估计方法,CNN-Dis模型可以直接从三分量加速度记录中自动特征提取和模式识别,进而实现震中距估计。

2)通过对CNN-Dis模型的输入数据和标签数据的归一化处理,可以有效提升模型对于震中距估计的可靠性。

3)在本研究的测试数据集中,和传统的用于地震预警震中距估计的 $B-\Delta$ 方法相比,在不同的实际震中距范围、对于内陆和海域地震事件,CNN-Dis模型对于震中距估计都表现出更小的平均绝对误差和标准差。这也表明,CNN-Dis模型可以从三分量波形中提取更多用于震中距估计的重要信息和特征,进而提高震中距估计的可靠性。

虽然提出的深度学习模型在单台站震中距估计方面取得了显著进展,但仍存在进一步优化的空间。例如,可以探索更先进的网络架构、引入更多的先验知识或采用多模态数据融合策略,以进一步提升模型的性能和稳定性。随着大数据和计算能力的提升,未来还可以考虑将模型部署到更广泛的区域,实现更大范围的地震预警覆盖。

参考文献:

- [1] 李山有,金星,马强,等.地震预警系统与智能应急控制系统研究[J].世界地震工程,2004,20(4):21-26.
LI Shanyou, JIN Xing, MA Qiang, et al. Study on earthquake early warning system and intellegent emergency controlling system [J]. World Information on Earthquake Engineering, 2004, 20(4): 21-26. (in Chinese)
- [2] 马强.地震预警技术研究及应用[D].哈尔滨:中国地震局工程力学研究所,2008.
MA Qiang. Research and application on earthquake early warning [D]. Harbin: Institute of Engineering Mechanics, China Earthquake Administration, 2008. (in Chinese)
- [3] 宋晋东.高速铁路运行控制用地震动参数及单台地震预警技术研究[D].哈尔滨:中国地震局工程力学研究所,2013.
SONG Jindong. Research on seismic ground motion indices for operation control and single station earthquake early warning applied for high-speed railway [D]. Harbin: Institute of Engineering Mechanics, China Earthquake Administration, 2013. (in Chinese)
- [4] 张红才.地震预警系统关键技术研究[D].哈尔滨:中国地震局工程力学研究所,2013.
ZHANG Hongcai. Study of key technologies in earthquake early warning system [D]. Harbin: Institute of Engineering Mechanics, China Earthquake Administration, 2013. (in Chinese)
- [5] PENG C Y, JIANG P, MA Q, et al. Performance evaluation of an earthquake early warning system in the 2019—2020 $M6.0$ Changning, Sichuan, China, seismic sequence [J]. Frontiers in Earth Science, 2021, 9: 699941.
- [6] PENG C Y, JIANG P, MA Q, et al. Chinese nationwide earthquake early warning system and its performance in the 2022 Lushan $M6.1$ earthquake [J]. Remote Sensing, 2022, 14(17): 4269.
- [7] ALLEN R M, MELGAR D. Earthquake early warning: Advances, scientific challenges, and societal needs [J]. Annual Review of Earth and Planetary Sciences, 2019, 47: 361-388.
- [8] 马亮.用于地震预警的单台定位技术研究[D].哈尔滨:中国地震局工程力学研究所,2013.
MA Liang. Research on earthquake location using single station for earthquake early warning [D]. Harbin: Institute of Engineering Mechanics, China Earthquake Administration, 2013. (in Chinese)
- [9] 柯星星.地震预警单台定位算法的优化[D].哈尔滨:中国地震局工程力学研究所,2020.
KE Xingxing. Optimization of single-station positioning algorithm for earthquake warning [D]. Harbin: Institute of Engineering Mechanics, China Earthquake Administration, 2020. (in Chinese)
- [10] WU Y M, ZHAO L. Magnitude estimation using the first three seconds P-wave amplitude in earthquake early warning [J]. Geophysical Research Letters, 2006, 33(16): L16312.
- [11] NODA S, YAMAMOTO S, SATO S. Improvement of seismic parameter estimation for the earthquake early warning system [J]. Quarterly Report of RTRI, 2011, 52(4): 206-209.
- [12] NAKAMURA Y. Urgent earthquake detection and alarm system, now and future (UrEDAS) [C]// Proceedings of the 13th World Conference on Earthquake engineering. Vancouver, B.C., Canada: International Association for Earthquake Engineering, 2004, Paper No. 908.
- [13] STEELE H, NODA S, YAMAMOTO S, et al. Improved epicentral distance estimations for railway earthquake early warning [J]. Quarterly Report of RTRI, 2020, 61(3): 222-227.
- [14] KONG Q K, ZHAO M. Evaluation of earthquake signal characteristics for early warning [J]. Earthquake Engineering and Engineering Vibration, 2012, 11(3): 435-443.

- [15] NAKAMURA Y. On the urgent earthquake detection and alarm system (UrEDAS)[C]// Proceeding. of the 9th World Conference on Earthquake Engineering, 1988, 7: 673-678.
- [16] ODAKA T. A new method of quickly estimating epicentral distance and magnitude from a single seismic record[J]. Bulletin of the Seismological Society of America, 2003, 93(1): 526-532.
- [17] KAMIGAICHI O, SAITO M, DOI K, et al. Earthquake early warning in Japan: Warning the general public and future prospects[J]. Seismological Research Letters, 2009, 80(5): 717-726.
- [18] NAZERI S, SHOMALI Z H. Rapid estimation of the epicentral distance in the earthquake early warning system around the Tehran Region, Iran [J]. Seismological Research Letters, 2019, 90(5): 1916-1922.
- [19] JUNG S, RHEE H M, SHEEN D H. Rapid assessment of epicentral distance using the initial P waves observed in south Korea[J]. Bulletin of the Seismological Society of America, 2018, 108(1): 511-516.
- [20] YAMAMOTO S, NODA S, KORENAGA M. An estimation method of epicentral distance based on characteristics of P-wave initial envelope[J]. RTRI Report, 2012, 26(9): 5-10.
- [21] IWATA N, YAMAMOTO S, KORENAGA M, et al. Improved algorithms of seismic parameters estimation and noise discrimination in earthquake early warning[J]. Quarterly Report of RTRI, 2015, 56(4): 291-298.
- [22] MOUSAVI S M, BEROZA G C. Machine learning in earthquake seismology[J]. Annual Review of Earth and Planetary Sciences, 2023, 51: 105-129.
- [23] ZHANG H C, MELGAR D, SAHAKIAN V, et al. Learning source, path and site effects: CNN-based on-site intensity prediction for earthquake early warning[J]. Geophysical Journal International, 2022, 231(3): 2186-2204.
- [24] 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 Ming, CHEN Shi, FANG Lihua, et al. Earthquake phase arrival auto-picking based on U-shaped convolutional neural network [J]. Chinese Journal of Geophysics, 2019, 62(8): 3034-3042. (in Chinese)
- [25] 于子叶, 储日升, 盛敏汉. 深度神经网络拾取地震P和S波到时[J]. 地球物理学报, 2018, 61(12): 4873-4886.
YU Ziyue, CHU Risheng, SHENG Minhan. Pick onset time of P and S phase by deep neural network[J]. Chinese Journal of Geophysics, 2018, 61(12): 4873-4886. (in Chinese)
- [26] 江炳根, 马强, 陶冬旺. 基于卷积神经网络的地震预警震级持续估算方法研究[J]. 世界地震工程, 2022, 38(1): 213-228.
JIANG Binggen, MA Qiang, TAO Dongwang. Continuous estimation of earthquake early warning magnitude based on Convolutional Neural Network[J]. World Earthquake Engineering, 2022, 38(1): 213-228. (in Chinese)
- [27] 宋晋东, 梁坤正, 李山有, 等. 基于机器学习和迁移学习的地震预警震级估计[J]. 世界地震工程, 2024, 40(3): 60-71.
SONG Jindong, LIANG Kunzheng, LI Shanyou, et al. Magnitude estimation for earthquake early warning based on machine learning and transfer learning[J]. World Earthquake Engineering, 2024, 40(3): 60-71. (in Chinese)
- [28] 朱景宝, 何斌, 李山有, 等. 2021年5月21日云南漾濞地震及5月22日青海玛多地震的支持向量机震级估算[J]. 世界地震工程, 2021, 37(3): 65-72.
ZHU Jingbao, HE Bin, LI Shanyou, et al. Magnitude estimation via support vector machine for the earthquakes occur in Yangbi, Yunnan on May 21, 2021 and in Maduo, Qinghai on May 22, 2021[J]. World Earthquake Engineering, 2021, 37(3): 65-72. (in Chinese)
- [29] 王自法, 廖吉安, 王延伟, 等. 基于深层卷积神经网络的震级快速估算方法[J]. 地球物理学报, 2023, 66(1): 272-288.
WANG Zifa, LIAO Jian, WANG Yanwei, et al. A fast magnitude estimation method based on deep convolutional neural networks[J]. Chinese Journal of Geophysics, 2023, 66(1): 272-288. (in Chinese)
- [30] 宋晋东, 余聪, 李山有. 地震预警现地PGV连续预测的最小二乘支持向量机模型[J]. 地球物理学报, 2021, 64(2): 555-568.
SONG Jindong, YU Cong, LI Shanyou. Continuous prediction of onsite PGV for earthquake early warning based on least squares support vector machine[J]. Chinese Journal of Geophysics, 2021, 64(2): 555-568. (in Chinese)
- [31] HSU T Y, HUANG S K, CHANG Y W, et al. Rapid on-site peak ground acceleration estimation based on support vector regression and P-wave features in Taiwan[J]. Soil Dynamics and Earthquake Engineering, 2013, 49: 210-217.
- [32] ZHU J B, SUN W T, ZHOU X Y, et al. Machine learning-based rapid epicentral distance estimation from a single station[J]. Bulletin of the Seismological Society of America, 2024, 114(3): 1507-1522.
- [33] BÖSE M, HEATON T, HAUKSSON E. Rapid estimation of earthquake source and ground-motion parameters for earthquake early warning using data from a single three-component broadband or strong-motion sensor [J]. 2012, 102(2): 738-750.
- [34] OCHOA GUTIERREZ L H, VARGAS JIMENEZ C A, NIÑO VASQUEZ L F. Fast estimation of earthquake epicenter distance using a single seismological station with machine learning techniques[J]. Dyna, 2018, 85(204): 161-168.
- [35] MOUSAVI S M, BEROZA G C. Bayesian-deep-learning estimation of earthquake location from single-station observations[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(11): 8211-8224.
- [36] 马强, 金星, 李山有, 等. 用于地震预警的P波震相到时自动拾取[J]. 地球物理学报, 2013, 56(7): 2313-2321.
MA Qiang, JIN Xing, LI Shanyou, et al. Automatic P-arrival detection for earthquake early warning[J]. Chinese Journal of Geophysics, 2013, 56(7): 2313-2321. (in Chinese)
- [37] 刘辰, 李小军, 景冰冰, 等. 地震预警PGV-Pd关系参数的距离分段特征[J]. 地球物理学报, 2019, 62(4): 1413-1426.
LIU Chen, LI Xiaojun, JING Bingbing, et al. The distance segmentation characters of PGV-Pd relationship parameters for earthquake early

- warning[J]. Chinese Journal of Geophysics, 2019, 62(4): 1413-1426. (in Chinese)
- [38] 彭朝勇, 杨建思, 薛兵, 等. 基于汶川主震及余震的预警参数与震级相关性研究[J]. 地球物理学报, 2013, 56(10): 3404-3415.
PENG Chaoyong, YANG Jiansi, XUE Bing, et al. Research on correlation between early-warning parameters and magnitude for the Wenchuan earthquake and its aftershocks[J]. Chinese Journal of Geophysics, 2013, 56(10): 3404-3415. (in Chinese)
- [39] 朱景宝, 宋晋东, 李山有. 基于深度卷积神经网络的 2021 年 5 月 21—22 日云南漾濞地震和青海玛多地震震级估算[J]. 地球物理学报, 2022, 65(2): 594-603.
ZHU Jingbao, SONG Jindong, LI Shanyou. Magnitude estimation of Yunnan Yangbi earthquake and Qinghai Maduo earthquake on May 21—22, 2021 based on deep convolutional neural network[J]. Chinese Journal of Geophysics, 2022, 65(2): 594-603. (in Chinese)
- [40] PEROL T, GHARBI M, DENOLLE M. Convolutional neural network for earthquake detection and location[J]. Science Advances, 2018, 4(2): e1700578.
- [41] JOZINOVIĆ D, LOMAX A, ŠTAJDUHAR I, et al. Rapid prediction of earthquake ground shaking intensity using raw waveform data and a convolutional neural network[J]. Geophysical Journal International, 2020, 222(2): 1379-1389.
- [42] 范涛. 数字滤波与偏振分析在强震动数据处理中的应用[D]. 哈尔滨: 中国地震局工程力学研究所, 2014.
FAN Tao. Digital filter and polarization analysis's application of data processing of strong motion cords[D]. Harbin: Institute of Engineering Mechanics, China Earthquake Administration, 2014.
- [43] NODA S. Deep learning estimating of epicentral distance for earthquake early warning systems[J]. Bulletin of the Seismological Society of America, 2024, 114(4): 2054-2064.