第38卷 第4期(691~707)	中 国 地 震	Vol. 38 No. 4
2022 年 12 月	EARTHQUAKE RESEARCH IN CHINA	Dec. 2022

朱俊清,孙珂,2022. 基于多源数据的机器学习在地震预测中的研究进展. 中国地震,38(4):691~707.

# 基于多源数据的机器学习在地震 预测中的研究进展

# 朱俊清 孙珂

中国地震局地震预测研究所,北京 100036

摘要 近年来,机器学习的快速发展在计算机视觉、自然语言处理和数据挖掘等领域取得 前所未有的成绩。地震研究学科众多,包括地震学、大地测量学、地球化学、地球电磁学和地质 学等,研究产生的多源、复杂、海量数据高度符合机器学习对于训练数据的要求,因此许多学者 将机器学习方法引入到地震预测中。本文基于机器学习背景、地震预测应用流程和评价方法等 方面,回顾了近年来基于机器学习方法,利用不同学科数据进行地震预测的应用概况和主要进 展,并对机器学习在地震预测中的应用进行总结和讨论。

关键词: 机器学习 多源数据 地震预测 研究进展 [文章编号] 1001-4683(2022)04-0691-17 [中图分类号] P315 [文献标识码] A

# 0 引言

地震是一种突发的、剧烈的地壳运动形式,是给人类社会带来人员伤亡、经济损失最严重的自然灾害之一。据相关数据统计,20世纪全球各地发生了多达1100多次破坏性地震,造成150多万人死亡(Yariyan et al,2020)。我国是地震多发国家,地震具有频度高、强度大、震源浅、分布广的特点,地震灾害给我国造成了严重的损失(夏朝旭等,2022)。

为减少地震对人类社会的危害,20世纪90年代全世界地震研究者就地震能否预测展开 讨论。Geller等(1997)认为大量的物理条件决定着小地震能否演化成大地震,而不仅仅取 决于断层,地震破裂高度敏感的非线性影响地震的可预测性;此外,即使已经发现了大量地 震前兆,但没有定量的物理机制把前兆和地震联系起来,因此认为地震是不可预测的。 Brehm等(1999)利用从断裂力学和裂纹拓展中推导出来的中期地震预测的失效时间方法, 来定位和预测未来主震的大小和时间。无论是持地震不可预测观点或是持地震可预测观点 的学者,均认可在当时科学认知和科技发展受限条件下,暂时不能实现地震的准确预测。

近年来,人工智能技术迅速发展,尤其是机器学习和深度学习在自然语言处理、计算机 视觉、数据挖掘等具有多源海量复杂数据的领域取得蓬勃发展,在某些预测应用中获得了比 传统方法明显优异的结果。很多地震工作者将基于数据特征和算法建模的人工智能方法运

<sup>[</sup>收稿日期] 2022-05-25 [修定日期] 2022-08-18

<sup>[</sup>项目类别] 国家自然科学基金联合基金项目(U2039202)资助

<sup>[</sup>作者简介] 朱俊清,男,1996 年生,硕士研究生,研究方向为人工智能地震预测。E-mail:905093543@qq.com

孙珂,通讯作者,男,1981年生,研究员,主要从事空间技术在防震减灾中的应用研究。E-mail;sunke22@126.com

用到地震研究中,试图发现复杂地震数据与地震发生之间的联系,并尝试预测地震。研究算 法从基于规则发展到浅层机器学习和深度学习,研究数据也基本包含了各类地震数据。

本文从机器学习背景、地震预测方法和评价指标等方面,回顾机器学习历史发展过程以 及机器学习在地震预测应用中的常用流程,比较各算法模型的性能评价指标;并将数据按 学科分类,讨论多源数据在基于机器学习的地震预测中的应用进展,在比较各算法表现的基 础上,对机器学习在地震预测中应用的趋势发展进行总结和讨论。

# 1 研究背景

#### 1.1 机器学习背景介绍

人工智能(Artificial Intelligence)是一门涉及计算机科学、逻辑学、信息学、哲学、生物学、 心理学、语言学等多学科的交叉学科,在模式识别、机器学习、计算机视觉、自然语言处理、机 器人学等应用领域获取了前所未有的成果(崔雍浩等,2019)。机器学习是人工智能核心,涉 及概率论、统计学、算法复杂度理论、逼近论、凸分析等多学科,通过计算机技术模拟人类学 习过程,并实现机器的自动识别(袁爱璟等,2021)。机器学习包括监督学习、无监督学习和 半监督学习。监督分类分为分类和回归,现有的大多数地震预测算法均属于监督分类。无 监督分为聚类和降维,聚类包括层次聚类、神经网络聚类等;降维包括主成分分析、线性判 别分析等。深度学习是机器学习的重要组成部分,自 2012 年深度卷积神经网络在 ImageNet 大赛上获取了正确率超越第二名 10%的优越成绩以来,深度学习进入高速发展时期。深度 学习是一种基于深度神经网络算法模型技术,网络深度往往深达几十层,甚至上百层,如 VGG 网络有 16 层或者 19 层,GoogleNet 有 22 层,ResNet 具有从 18 层到 152 层等多个不同层 数的具体模型,但是并不是层数越多性能越好,具体性能由数据、激活函数、模型参数等多个 因素共同决定。人工智能技术自 1943 年诞生以来,发展历经坎坷,但总体上呈现上升趋势, 自 2012 年至今处于快速发展时期。图1 展示了自神经元诞生以来人工智能技术的主要发 展历程。

#### 1.2 机器学习地震预测

机器学习地震预测方法涉及数据输入、数据预处理、算法选择、数据输出和评价指标等5 个部分(图2)。数据输入的类型主要以各类地震观测数据为主,记录震前长时序的某个参 数的持续变化。不同数据的载荷不同,记录的数据中会存在一定数量的无用值或空值,故需 要对数据进行预处理,以满足模型处理的格式要求;算法选择面较广,包括基于规则的算法 以及浅层神经网络和深层神经网络等不同类型的算法;数据的输出包括预测地震的发生时 间、地点、震级和概率等,有些研究不会给出具体的输出,而是给出通过已发生地震验证的算 法精确度;评价指标是评估算法模型好坏的关键,通过比较指标,对比不同模型的性能,从 而选择基于某种数据的最佳模型,以达到最优预测(张荣等,2018)。

#### 1.3 机器学习评价体系

建立良好的评价体系有利于评估机器学习地震预测的性能,有利于对比分析不同特征 参数和不同模型算法的性能,从而有利于选择最优参数和模型。机器学习评价指标根据算 法的不同,一般可以分为2种,一种为分类算法指标,另一种为回归算法指标。

## 1.3.1 分类算法评价指标

传统机器学习分类算法一般为二分类问题,即正例和反例,根据真实情况和预测结果的

692

CMYK



注:该图据陈运泰(2009)、焦李成等(2016)、张荣等(2018)、包俊等(2020)、袁爱璟等(2021)研究中关于人工 智能的历史发展综合绘制。

图1 。	人上智	能技术	历史	友	腰
------	-----	-----	----	---	---



图 2 机器学习地震预测流程(据 Al Banna 等(2020))

组合划分为真正例 TP(true positive)、假正例 FP(false positive)、真反例 TN(true negative)和 假反例 FN(false negative)。在地震预测应用中,正例代表有地震,反例代表无地震。分类结果混淆矩阵如表1 所示。

一般而言,混淆矩阵中做出正确预测的 TP 和 TN 数量多、且做出错误预测的 FN 和 FP 数量少的情况下,认为预测结果较好。但是简单的分类结果尚且不能完全表示模型的好坏,可以从混淆矩阵拓展出很多相关性的评价指标。表2 为分类结果延伸出的 8 个评价指标。

AUC(area under curve)是受试者工作特征曲线(ROC 曲线)下面积,除了表2中的计算 方法外,还可以通过计算面积得到。由于ROC 曲线能有效评价预测模型的性能,因此被广

4 期

СМҮК

693

694		中国地震	38 卷
主 1		公米住田泪泽55匹(捉去受理笙)202	1))
<u>7</u> <u>x</u> 1		刀矢珀未此府足阵(	1))
	百分传加	预测	结果
具头间讥		正例(有地震)	反例(无地震)
	正例(有地震)	TP(有地震且预测有)	FN(有地震但预测无)

表 2

反例(无地震)

分类算法评价指标(据 Asencio-Cortés 等(2017a)、袁爱璟等(2021))

FP(无地震但预测有)

TN(无地震且预测无)

评价指标	数学表达	描述
精确率 PPV	$Precision = \frac{TP}{TP + FP}$	在预测结果是正例的所有结果中,预测正确的比例
召回率 TPR	$Recall = \frac{TP}{TP + FN}$	在真实情况是正例的所有结果中,预测正确的比例
特异度 TNR	Specificity = $\frac{TN}{TN + FP}$	在真实情况是反例的所有结果中,预测正确的比例
阴性预测率 NPV	$NPV = \frac{TN}{TN + FN}$	在预测结果是反例的所有结果中,预测正确的比例
马修斯相关 系数 MCC	$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$	综合考虑 TP、TN、FP 和 FN 的均衡指标
准确率 ACC	$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$	正确预测的样本数占所有样本数的比例
F1 分数	$F1$ -score = $\frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$	精确率和召回率的调和平均数
AUC 值	$AUC = \frac{\sum_{l \in \text{positiveClass}} \operatorname{rank}_{i} - M \frac{1 + M}{2}}{M \times N}$	ROC 曲线下面积

泛使用。一般而言,AUC 值若为1,则为一个完美的分类器,AUC 值为 0.5 则认为是随机猜测,模型预测结果没有具体价值,AUC 值在 0.5~1 之间,越接近1,预测效果越好(袁爱璟等, 2021)。另外,Asencio-Cortés 等(2017a、2017b、2018)使用 PPV、TPR、TNR 和 NPV 的均值评价模型性能。

1.3.2 回归算法评价指标

在震级预测应用中,常运用回归算法将震级预测值和真实震级作回归分析,比较误差,回归值和预测值越接近,算法的预测性能越好。表3给出一些常用的回归算法评价指标。

# 2 多源数据在地震预测中的综合应用

#### 2.1 地震学

#### 2.1.1 地震目录数据

地震目录是按照时间顺序对地震参数进行收录和编目所形成的资料,是开展地震活动 性研究的基础数据(王想等,2017)。地震目录通常包括发震时刻、震中位置、震源深度、震级 等参数,而地震活动性研究的重要内容是分析这些参数在空间和时间维度上的分布特征(王

表3 回归算法评价	↑指标(据 Asencio-Cortés 等(2018)、Salam 等(2021))
评价指标	数学表达
相对误差 RE	$RE = \frac{1}{n \times max(y_i)} \sum_{i=1}^{n}  y_i - \hat{y}_i $
均方误差 MSE	$MSE = \frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2$
平均绝对误差 MAE	$MAE = \frac{1}{n} \sum_{i=1}^{n}  y_i - \hat{y}_i $
均方根误差 RMSE	RMSE = $\sqrt{\frac{1}{N} \sum_{i=1}^{n} (Y_i - \hat{Y}_i)^2}$

#### 想等,2016)。

Aslam 等(2021b)利用统计聚类热点分析方法获取巴基斯坦北部地区地震活动热点区域(图3),分析表明兴都库什地区和 2005 年克什米尔地震发生的主边界逆冲断层所定位的中部地区为主要地震发生率较高地区,即地震活动热点地区;人工智能神经网络模型(ANN)仅使用震级信息作为训练特征对上述地区进行研究,模型训练精度达到 74%,测试精度达 69%,0.69 虽然表现一般,但对于复杂的地区特征,仍是一个较不错的结果。



图3 Anselin 局部莫兰指数聚类分析(a)和热点分析(b)(据 Aslam 等(2021b))

Jain 等(2021)以目标地震震中为中心,根据不同半径值分割整个数据集,不同半径(100km、200km、500km、1000km、1500km、3000km和5000km)范围内地震的经纬度信息和震源深度信息作为特征参数,选用随机森林回归(RF)、多层感知器回归(MLP)和支持向量回归(SVR)对震级信息进行回归分析,获取均方根误差,在所有半径范围内MLP回归算法的RMSE值均最小,回归预测的震级和实际震级的误差最小。

人工智能神经网络在其他领域时间序列的预测上已取得广泛应用。Kaftan 等(2017)为 了验证不同神经网络在地震时间序列应用的性能,获取 1975—2009 年土耳其西部某地区震

MYK

		1.1	æ
Ψ	玉	扣	一震

级大于等于 3.0 级地震,整理得到每月的地震频率,使用多个不同频率数输入多层感知器神 经网络(MLPNN)、径向基函数神经网络(RBFNN)和自适应神经网络模糊推理系统(ANFIS),测试结果表明,RBFNN的 RMSE 值低于 MLPNN和 ANFIS 的结果,在时间序列数 据表现较好。Wang 等(2020)在时间序列基础上加入空间信息,利用 LSTM 网络发现地震之间存在的时空相关性,将中国研究区分为9个区域,使用 1966—2016年相邻地区地震数据,设置时间间隔为一个月,输入为某一子区域在该时间间隔内发生地震的次数,总的数据为一个 600×9 矩阵,总的预测精度为 74.81%,在拥有多条断裂的某些子区域内组合的预测准确 率可达 88.57%。

2.1.2 地震活动性参数

Panakkat 等(2007)和 Adeli 等(2009)根据古登堡-里希特逆幂律和地震震级特征分布, 获得 8 个具有一定数学原理的地震活动性特征参数(表4),利用神经网络预测地震震级,在 当时地震预测性能高度不确定的情况下,取得了较好的效果。

衣 4	地辰山幼庄参致(据Asencio-Cortes 寺(20170)、天	:
参数	数学表达	描述
$T_{\theta}$	$T = t_n - t_1$	第一次和第 n 次之间流逝的时间
$M_{\scriptscriptstyle mean}$	$Mmean = \frac{\sum M_i}{n}$	平均震级
$dE^{1/2}$	$dE^{1/2} = \sum E^{1/2} / T \ (E = 10^{(11.8+1.5M)}  ergs)$	地震能量的平方根释放率
b	$b = \frac{n \sum (M_i \lg N_i) - \sum M_i \ge \lg N_i}{(\sum M_i)^2 - n \ge M_i^2}$	地震 b 值
η	$\eta = \frac{\sum \left( \lg N_i - (a - bM_i) \right)^2}{n - 1} \qquad a = \frac{\sum \left( \lg N_i + bM_i \right)}{n}$	均方偏差
$\Delta M$	$\Delta M = M_{\text{max, observed}} - M_{\text{max, expected}} \left( M_{\text{max, expected}} = \frac{a}{b} \right)$	震级亏损
$\mu$	$\mu = \sum \frac{t_{i \text{ characteristic}}}{n_{\text{characteristic}}}$	平均时间
с	$c = \frac{观测时间的标准偏差}{\mu}$	平均时间变异系数

地震活动性参数(据 Asencio-Cortés 等(2017b)、吴晶晶等(2019))

Asencio-Cortés 等(2017a、2017b、2018)在这些地震活动性参数基础上进行改进,增加了 其他特征参数,包括计算了一定地震间隔的b值增值、使用概率密度函数记录震级大于等于 目标震级的概率和记录最近一周的最大震级等。Asencio-Cortés 等(2017a)在对某些特定位 置且空间分辨率较小的震例分析时,对东京200km范围内中大地震震级进行预测,ANN神 经网络各评价指标均值均大于70%,结果优于其他测试算法。大数据技术的强大计算能力 能够挖掘隐藏在杂乱数据中的有效信息,Asencio-Cortés 等(2017b)在大数据技术加持下,基 于云的大数据计算预测加利福尼亚地区未来7天内地震震级,首先使用4种算法单独训练, 发现随机森林(RF)表现最好,其次将 RF 算法和其他3种算法进行集成学习,利用集成后的 算法重新训练。不同算法集成在不同震级范围的平均绝对误差各不相同,不存在某种表现

696

**=** 1

MYK

38 卷

#### 朱俊清等:基于多源数据的机器学习在地震预测中的研究进展

697

均优异的算法,但总体上相对误差接近10%,绝对误差接近0.5。

СМҮК

4 期

Asim 等(2017b、2018)在对兴都库什地区震级大于等于 5.5 级地震进行预测时,使用 8 个地震活动性参数,验证了地震发生虽然是绝对非线性的,类似于随机事件,但可以根据发 震区地球物理情况和极其复杂的机器学习模型对地震事件进行建模学习。此外,Asim 等 (2017a)对巴基斯坦北部地区地震进行研究时,根据信息增益情况剔除 8 个指标中的震级亏 损和均方误差,选择其余 6 个指标作为神经网络的训练特征,在对预测模型进行 McNemar's 统计测试后,比较各算法的显著性,前馈神经网络(Feed-Forward Neural Network)显著性为 0.005 且准确性为 0.70,因此 FFNN 模型更适合巴基斯坦北部地区的地震预测。短临地震预 报是减少人员伤亡和财产损失的关键所在,Asim 等(2018)为了提高 15 天内对 5.0 级地震预 测的准确性,将基于基因规划的 GP 算法和 AdaBoost 算法的集成算法与标准地震活动性参 数相结合,并在兴都库什、智利和南加州地区进行实验,3 个地区的地震预测精确度分别是 78.7%、84.5%和 86.6%,均取得比前人研究更好的结果。Asim 等(2020)在分析塞浦路斯低 级别地震时,更是创新性地选用总复发时间等多达 60 个地震特征预测未来 5 天、7 天、10 天 和 15 天内发生地震震级,在震级阈值相同的情况下,较长时间阈值预测值 MCC 较好,随着 震级阈值的增加,预测值 MCC 也随着降低。

除上述研究外,其他学者也基于地震活动性参数从算法创新和结合其他指标进行地震 预测研究,其他地震指标作为地震活动性参数的补充,在一定程度上填补了地震活动性参数 未能涉及到的物理机制,算法的优化和其他领域算法的跨领域应用对提升地震预测训练能 力和测试精度上有很大帮助。吴晶晶等(2019)利用反向选择算法生成检测器,减少了对数 据量较少的大地震的依赖性,对四川省历史地震进行训练,对其一个月内发生 5.0 级地震进 行预测,结果明显好于神经网络和支持向量机;周天祥等(2019)和 Zhou 等(2020)将主要运 用于计算机安全领域的树突状细胞算法 DCA(Dendritic Cell Algorithm)应用到地震预测,在 大多数数据集上的表现均优于其他算法;张研等(2020)将 RVM(Relevance Vector Machine) 预测算法与 BP 神经网络及 SOM-BP 神经网络算法进行比较,结果表明 RVM 算法优于其他 2种算法; Salam 等(2021)提出了2个混合机器学习地震预测模型,第一个为花授粉算法 FPA(Flower pollination algorithm)和极限学习机 ELM(Extreme learning machine)的混合模型 FPA-ELM, 第二个为 FPA 和最小二乘支持向量机 LS-SVM 的混合模型 FPA-LS-SVM, 混合了 FPA 算法的 ELM 和 LS-SVM 算法的精度均有所提高,在 90% 训练集和 10% 测试集的情况 下,混合后 ELM 模型的 RMSE 为 0.529,优于 LS-SVM 模型的 0.537。Majhi 等(2020)采用功 能链接神经网络(Function Link Artificial Neural Network)对地震非线性数据建模,并结合最 小二乘回归、飞蛾火焰优化算法(Moth-flame optimalization algorithm)、自适应梯度下降和 LM 反向传播算法,比较预测回归模型的均方根误差,在诸多结合方案中,基于 FLANN 的 MFO 算法的均方根误差最小(0.0565),预测效果较好。Rahmat 等(2020)仅使用地震 b 值作为地 震前兆指标,在极限学习机和深度学习方法中进行 b 值预测,2 种方法在不同训练集下的平 均成功率均达到 85%,但深度学习表现相比极限学习机有 1.61% 的性能优势。Yousefzadeh 等(2021)认为前人的地震预测研究更多侧重于时间参数,而不是空间参数,并且特征分析过 程中会剔除一些相关性较强的变量,所以在地震活动性参数基础上,使用核密度估计和双变 量莫兰指数计算的新参数断层密度进行地震预测研究,在传统机器学习和深度学习算法中,

中	玉	地	震
---	---	---	---

38 卷

用皂颈测的准确性 后续合在再名深度神经框架中评估新条数

新参数均有效提高预测的准确性,后续会在更多深度神经框架中评估新参数对预测性能的 影响。

### 2.2 大地测量学

Karimzadeh 等(2019)将不同的机器学习算法(朴素贝叶斯、K 近邻、支持向量机、随机森林)和滑动分布、相邻活动断层方向、库伦应力变化相结合,研究伊朗克曼沙 7.3 级地震后震级大于 2.5 的余震,利用 70%的余震,基于二进制的方法预测所有余震的空间位置。研究区域滑动分布信息来源于 InSAR 技术,SAR 数据在低噪声水平下识别和获取;库仑应力变化可根据滑动分布模型和摩擦系数以及斯肯普顿系数定义;实验区内共有 HZF、MMF-1、MMF-2 和 MMF-3 四条断层,实验区信息如图4 所示。研究区域余震限制在 100km×80km 范围内,并且将地理坐标转换为二元网格地图,点的缓冲区约为 1.5km,发生余震标记为 1,非余震标记为 0。由于变量较多,绘制基于不同断层和算法的 ROC 曲线有利于直观比较,实验结果表明,除 K 近邻算法外,其他算法在添加断层信息后能有效提高 AUC 值,RF 算法对断层敏感。总的来说,KNN 和 RF 算法表现要优于 NB 算法。

DeVries 等(2018)的研究不需要事先假设断层方向,基于静态应力标准进行余震预测。 利用超过 13.1 万对主震-余震训练数据和超过 3 万多对主震-余震测试数据,在深度学习网 络下预测余震位置并对比经典库仑破裂应力变化预测结果,两者的 ROC 曲线表明,神经网 络(测试数据集中所有滑动分布和网格单元的合并 AUC 值为 0.849)的性能要明显优于经典 库仑破裂应力准则(AUC 值为 0.583),在 1999 年中国台湾集集 7.6 级、1995 年日本神户 7.2 级和 2005 年克什米尔 7.6 级地震的单一震例分析中,神经网络的 AUC 值均优于传统库仑破 裂应力变化准则的 AUC 值。

然而, Mignan 等(2019)对 DeVries 等(2018)的这一结果表示怀疑,其在实验中,使用较为简单的神经网络双参数逻辑回归,基于测量距离和主震平均滑移参数,也能获得与 DNN 模型相同的性能,即 AUC=0.85,实验结果证明,复杂深度神经网络一般情况下不会影响模型的整体性能,但较难准确地解释物理推理过程。

Zhao 等(2022)在上述研究基础上,为了弄清楚特征和模型哪一个对于余震空间分布预测更重要,采用和 DeVries 等(2018)类似方法研究中国近 40 年来 171 次不同主震的 62811 次余震空间分布。特征上选择应力变化传感器、应力变化对数值、物理量( $\Delta$ CFS, $\Delta \tau_{max}$ ,  $\sqrt{3\Delta J_2}$ )、主震震级和网格单元与主震震中距离;模型上选择朴素贝叶斯、支持向量机、梯度提升决策树、K 近邻、逻辑回归和深度神经网络。多种参数和网络的混合使用,最优秀的组合 AUC 值为 0.9530,明显高于前人获取的结果。除此之外,实验还发现余震发生时间和震级对模型预测也存在一定影响。

#### 2.3 地球化学

研究表明,跨断层土壤气体(氡气、二氧化碳、汞、氢气等)在地震发震期间非常活跃(王 喜龙,2021),而在机器学习的方法上,对于氡气的研究较多。氡是一种放射性气体,化学性 质稳定,能溶解于水和有机物,并且具有较强的扩散能力和迁移能力,在地震发生时的高温 高压环境下,容易吸附在其他物质上,从而可以反映物质在地壳内部的迁移情况(史杨等, 2017),震前氡浓度异常变化也已经是地震前兆热点研究对象之一。1978年1月14日本伊 豆大岛 7.0级地震前夕,观测到地下水浓度突然下降,随后并显著增加(Wakita et al,1980);

698



注:(a)为根据 Sentinel-1 和 ALOS-2 数据的联合反演分析得出的克尔曼沙 7.3 级地震的滑动分布图;(b)为 根据弹性半空间中 Sentinel-1 和 ALOS-2 数据集的二次采样相位展开位移结果推导出的克尔曼沙 7.3 级地震 的库仑应力变化图;(c)~(f)为相邻断层的欧氏距离图。

图4 实验区信息图(据 Karimzadeh 等(2019))

1995年1月17日神户7.2级地震前1~2个月,观测到氡浓度比往常增加了约4倍,且于震前9天达到峰值,是初始观测的10倍多(Igarashi et al, 1995);近年来,不少学者将机器学习

**MYK** 

699

38 卷

的方法用于识别震前氡异常,取得的效果优于其他传统技术(Haider et al, 2021; Tareen et al, 2019)。

Külahcu 等(2009)利用三层 Levenberg-Marquardt 前馈学习算法研究东安纳托利亚断层 系统,选取研究区域内 147 次地震,训练参数除经纬度、氡浓度、震源深度外,还包括对氡气 移动影响较大的因素,包括压力和深度分别为 5cm、50cm、100cm 的土壤温度,共 8 个输入特 征,人工神经网络最后的输出是预测的地震震级。当将震级预测结果和真实情况比较时,发 现效果较好,平均相对误差约为 2.3%,可以看出基于氡气的数据特征能较好地应用于非线 性建模。为了验证降雨和大气压力等外部条件对氡气释放的影响,Niksarlioglu 等(2013)在 上述研究的基础上,剔除震源深度,增加了湿球温度和干球温度,土壤温度深度更改为 10cm、20cm 和 50cm。最终训练得到的震级误差在 0%~6.25%之间,误差区间大,效果不佳 的原因是因为本次实验震例选择较少,这也反映出神经网络的一个缺点:需要大量的训练数 据,才能对结果给出一个较好的置信度。

Sikder 等(2009)使用前人研究报告中的数据集,包括 155 个地震活动,每次活动包括 8 个不同地点测量的氡浓度和 7 项气候环境特征参数,算法上选择粗糙集理论算法和决策树 C4.5 算法,进行对比分析,结果表明决策树算法的总体精度高达 93.55%,高于粗糙集算法的 88.39%。

#### 2.4 地球电磁学

电离层是位于 60km 以上的高层大气区域,由于宇宙射线(主要是太阳辐射)的电离作用,大气处于部分电离或者完全电离的状态,通过现有数据研究,科学家们发现强震前后电 离层参数会发生扰动(杨许铂,2015)。震前电离层扰动机制复杂,许多学者尝试利用机器学 习方法去识别电磁扰动并尝试预测地震。

Xiong 等(2020)利用机器学习技术识别震前电磁扰动,从 DEMETER 卫星数据中选择 11 个电场频带和 6 个磁场频带,为了验证机器学习技术的可靠性和鲁棒性,在已经选取的 2005—2010 年 8760 次大于等于 5.0 级地震的基础上,生成 8760 个人工非地震事件,训练算 法包括常用的 15 种机器学习算法和深度神经网络,为了提高模型选择的置信度,利用贝叶 斯优化进行超参数调整和五重交叉验证进行性能评估。实验表明,LightGBM 算法在众多算 法中表现最优,13 个数据集训练下,AUC 基本大于 0.88,最高为 0.986,识别震前电磁扰动最 为准确。Xu 等(2010)基于反向传播神经算法,利用 DEMETER 卫星获取的电子密度、电子 温度、离子温度、氧离子密度、氢离子密度、氦离子密度以及地震带参数作为神经网络特征因 子,其中地震带参数是根据每个震中距地震带的距离计算的,若距离小于 60km 则参数为 1, 否则为 0。模型对 2007 年大于等于 6.0 级地震 DEMETER 数据训练后,在 2008 年的 117 个 震区样本和 106 个非震区样本中进行测试,结果表明该方法对震区预测效果较好,准确率为 81.2%,非震区则为 57.5%。Ma 等(2010)使用相同的神经网络,特征因子剔除了地震带信 息,获取了测试震区 83.9%的地震预测准确率。

Xiong 等(2020)研究表明,强震震区附近震前存在电离层 TEC 异常扰动; Nahornyi 等 (2020)提出一种基于 TEC 变化趋势的预测模型,并且得到±5%的预测偏差,验证了 TEC 作 为地震预测标志的可能性; Akhoondzadeh 等(2013)利用遗传算法检测所罗门群岛 8.0 级地 震所引起的 TEC 异常变化; Xiong 等(2021b)提出一种新的拓展编码器-解码器长短时记忆

拓展神经网络预测 TEC。机器学习技术广泛应用于 TEC 异常检测,有助于基于 TEC 参数的 地震预测的研究。Brum 等(2019)利用 NOAA 提供的 VTEC 文件,开发具有多层感知器的神 经网络并应用于墨西哥恰帕斯州 8.2 级地震,训练后的模型在测试数据集上能达到 85.71% 的准确性,通过对比震前 VTEC 时序变化和台站 3 个不同方向的地震波形图,发现 ANN 模型 在震前 3 小时内给出异常预警。

701

Xiong 等(2021a)使用多源、多参数卫星数据用于震前异常检测,特征参数包括地表温度、表层温度、地球表面大气温度、表面水蒸气质量混合比、总臭氧负荷、反演一氧化碳总柱量、反演甲烷总柱量、出射长波辐射通量(AIRS)、晴空出射长波辐射通量和出射长波辐射通量(NOAA)。通过确定最佳时间特征和空间特征,获得1234次6~7级地震和137次7级以上地震,并生成1371次人工地震事件,基于K均值算法和滑动时间窗方法2种不同方法生成特征,再根据是否包含余震信息,最终获取一个完整的数据集。此外在算法上提出一种新的基于反向提升修剪树(Inverse Boosting Pruning Trees)的地震预报框架(图5),IBPT在不同机器学习方法、不同特征比较、考虑余震效应、不同时间窗和空间窗以及不平衡数据集上均能最优的效果,最后基于该算法,生成全球范围内的地震预测可能性图。



图 5 IBPT 框架流程图(据 Xiong 等(2021a))

#### 2.5 地震地质学

在过去的几十年中,地震数据种类和数据量快速增加,为地震发生概率评估提供一定的条件。Jena等(2020a)首次尝试使用深度学习和 GIS 进行地震概率评估,研究使用的卷积神 经网络使用 9 个特征指标,分别为断层接近度、断层密度、具有地震震动放大效应的岩性、坡 度角、高程、震级密度、震中密度、距震中距离和地面峰值加速度密度。在 GIS 中生成每一指标的全区域专题图,获取地震点和随机创建的非地震点的像素值;设计 CNN 模型,用两类 (0和1)地震预测;训练完成后将预测点的像素转换成格栅,从而生成 GIS 概率图。在整个印度次大陆的研究范围内,训练和测试数据集的整体准确度分别为 96%和 92%,取得较好的 结果。

印度次大陆是一个面积较大的范围,空间分辨率较低,为研究某一特定较小范围区域内 地震概率,Jena等(2021)又以印度东北部为研究区域,选用相同的特征指标,不同的是在卷 积神经网络评估地震概率后,利用层次分析法、维恩交集理论和风险映射集成模型评估脆弱 性,脆弱性评价指标主要为建筑物密度、远离建筑物距离、土地利用密度、远离土地利用距

4 期

离、远离铁路距离和铁路密度,然后再结合区域的灾害应对能力(评价指标为医院数量和灾害预算),最终得到印度东北部的地震灾害风险图。

城市是人口、工业、经济产业密集区,若发生破坏性地震将会带来巨大的人员伤亡和财产损失,对城市抗震减灾和地震风险评估是地震工作者的首要任务。Jena 等(2020b)利用人工神经网络和层次分析法,建立综合模型,研究分析印度尼西亚班达亚齐市地震风险。使用和上述研究相似的 13 个特征指标,通过在 ANN 中进行震例训练后,概率映射到 GIS 中生成各项指标的专题图,再利用 MLP 多层感知器绘制班达亚齐地震概率图(图6),实验获取的地震概率图准确率达到 84%,层次分析法将脆弱性指标映射到 GIS 中生成专题图,并与地震概率图混合,生成地震风险图,通过分析研读风险图,发现班达亚齐市的地震中高风险主要分布在该市的中部和东南部地区,这些研究结果对未来抗震减灾和政府部门的政策制定有一定帮助。



图6 地震发生概率图(据 Jena 等(2020b))

# 3 总结与讨论

机器学习在其他预测领域取得的一定成果让学者们开始利用机器学习方法研究地震预测,在本文整理的近5年来30多篇地震预测应用文献中,基于地震学的地震目录和地震活动性指标数据的地震预测研究热度最高。而其他数据因为数据量、数据特征相关性和预测效能等影响,研究热度较低。现阶段基于机器学习的地震预测并没有最优算法,不同的研究侧重的算法不同,暂不能统计不同算法的研究热度。

地震预测效能是基于机器学习地震预测研究的重点关注内容之一,现阶段以地震活动 性参数为数据并基于复杂算法模型进行地震预测已经达到瓶颈,预测精度较难提升,而基于

702

СМҮК

38 卷

703

震源数据以及延伸出来的地震发生频率、间隔时间等数据的地震预测仍处于发展阶段,研究 成果较少,尚不能总结预测性能;基于库仑应力机器学习方法将余震预测归纳为平面或空 间上,现有研究中不同特征参数和不同算法组合的 AUC 值基本处于 0.75~0.85 的范围内, 少数 AUC 值能超过 0.9,整体预测性能较好;基于氡气数据机器学习方法预测地震的研究 较少,由于氡气特别受外部环境影响,包括不同深度的土壤温度、降雨和大气压力等因素,故 整体研究成果不理想;现有的基于地球电磁地震预测研究准确率超过 80%,但由于数据量 的限制,参考价值有限,然而基于机器学习方法的空间电磁异常识别整体效果能达到较高水 平,提高异常信号的识别能力有利于提升地震预测特征参数的准确性;基于地震地质数据 的地震概率预测对于中长期地震震害防御有所帮助。图7 整理了现有研究中出现较多的算 法有效指标,由于某些算法的训练指标和结果表现形式不一样,无法通过某一特定指标进行 直接比较。



注:基于分类算法和回归算法在地震预测上的表现主要以精确度(a)和均方根误差/均方误差(RMSE/MSE)(b)表示;其中,地震预测精度普遍高于 65%,DCA-BPNN表现最差,约 50%,LightGBM 算法精度最高;回归误差表现差异较大,误差值在 0.1 附近和大于 0.4 的最多,中间表现较少;从数据来源上分析,USGS 数据使用最广泛,其他各国地震研究机构的数据也会偶尔被使用。

图7 不同算法评价指标的比较

基于不同学科的地震研究迅速发展,产生了海量数据,但有效用于机器学习地震预测的 只占地震数据的小部分,仍有大量的观测数据待挖掘;不同数据若能跨学科使用,将有利于 在不同维度上接近地震物理机制;另一方面,具有不同空间特征或时间特征的数据,若可以 相互匹配融合,能够克服单一数据源有限性问题,例如空间范围广、时效性长的空间电磁数 据与定点定位、时效性短的地电磁数据的融合使用。特征参数的选择需要尽可能还原地震 发震的物理机制,另外值得注意的是新兴特征参数的效能也需深入研究,例如地球化学中的 同位素;算法模型对预测结果影响较大,例如 DeVries 等(2018)用多达 13000 多个参数进行 余震预测,而相同震例条件下,Mignan(2019) 仅用 2~3 个参数就获得了类似的结果。地震 预测研究算法繁多,很难找到一个通用的最优算法,更多的目的是基于某一地区寻找可能适

4 期

38 卷

合该地区的最优算法,另外其他领域的一些深度学习优秀算法性能往往优于传统机器算法, 增加这些算法在地震预测的使用是提高地震预测效果的一种途径。

一般意义上的地震预测需要预测出地震发生的大概时间、地点和震级,而现有的大部分 机器学习地震预测并不会提供准确的时间、地点和震级,而是通过比较不同预测算法的效 能,获取在某一区域或基于某一数据集表现最好的算法;基于回归算法地震预测给出的预 测震级,是基于某一区域内震例的震级,预测的范围相对较广,很难定位到某个特定地点。

总体来说,现阶段基于机器学习地震预测很难给出较为准确的地震时间、地点和震级, 主要原因是神经网络有限的特征参数很难完全体现地震孕育的复杂因素,以及神经网络内 部的运算过程难以完全匹配地震的复杂发震机制。基于机器学习地震预测的学术研究到地 震预测的真正应用之间还有很长一段路程。

#### 参考文献

包俊, 董亚超, 刘宏哲, 2020. 卷积神经网络的发展综述. 见: 中国计算机用户协会网络应用分会 2020 年第二十四届网络新 技术与应用年会论文集. 北京,16~21. 陈运泰,2009. 地震预测:回顾与展望. 中国科学:地球科学,39(12):1633~1658. 崔雍浩, 商聪, 陈锶奇, 等, 2019. 人工智能综述: AI的发展. 无线电通信技术, 45(3): 225~231. 焦李成,杨淑媛,刘芳,等,2016.神经网络七十年:回顾与展望.计算机学报,39(8):1697~1716. 史杨,官致君,杨耀,2017. 断层土壤气氡的应用综述. 四川地震,(2):38~44. 王想,王亚茹,宫猛,等,2017. 华北第5活动幕平静时段背景下平静异常综合判定. 地震地磁观测与研究,38(1):21~27. 王想, 王亚茹, 郭蕾, 等, 2016. 2015 年 1 月 11 日河北滦县 ML3.3 震群震兆分析. 地震地磁观测与研究, 37(2):41~47. 王喜龙,贾晓东,杨梦尧,2021. 辽宁金州断裂断层土壤气地球化学调查. 中国地震,37(4):767~779. 吴晶晶,梁意文,谭成予,等,2019. 基于反向选择的地震预测方法. 计算机应用研究,36(4):1097~1100. 夏朝旭,聂高众,李华玥,等,2022. 基于历史地震数据的地震烈度与人员死亡率相关性研究. 中国地震,38(1):153~165. 杨许铂,2015. 岩石圈-大气层-电离层电场耦合机制研究. 博士学位论文. 武汉:武汉大学. 袁爱璟, 王伟君, 彭菲, 等, 2021. 机器学习在地震预测中的应用进展. 地震, 41(1):51~66. 张荣,李伟平,莫同,2018. 深度学习研究综述. 信息与控制,47(4):385~397. 张研, 邝贺伟, 2020. 地震震级预测的相关向量机模型. 世界地震工程, 36(1): 212~221. 周天祥,董红斌,周雯,2019.基于区域分割的混合地震预测算法.计算机工程,45(9):310~315. Adeli H, Panakkat A, 2009. A probabilistic neural network for earthquake magnitude prediction. Neural Netw, 22(7):1018~1024. Akhoondzadeh M, 2013. Genetic algorithm for TEC seismo-ionospheric anomalies detection around the time of the Solomon  $(M_{\rm W} = 8.0)$  earthquake of 06 February 2013. Adv Space Res, 52(4):581~590. Al Banna M H, Taher K A, Kaiser M S, et al, 2020. Application of artificial intelligence in predicting earthquakes: state-of-the-art and future challenges. IEEE Access,8:192880~192923. Asencio-Cortés G, Martínez-Álvarez F, Troncoso A, et al, 2017a. Medium-large earthquake magnitude prediction in Tokyo with artificial neural networks. Neural Comput Appl, 28(5):1043~1055. Asencio-Cortés G, Morales-Esteban A, Shang X, et al, 2018. Earthquake prediction in California using regression algorithms and cloud-based big data infrastructure. Comput Geosci, 115:198~210. Asencio-Cortés G, Scitovski S, Scitovski R, et al, 2017b. Temporal analysis of croatian seismogenic zones to improve earthquake magnitude prediction. Earth Sci Inform, 10(3): 303~320.

Asim K M, Awais M, Martínez-Álvarez F, et al, 2017a. Seismic activity prediction using computational intelligence techniques in northern Pakistan. Acta Geophys, **65**(5):919~930.

Asim K M, Idris A, Iqbal T, et al, 2018. Seismic indicators based earthquake predictor system using Genetic Programming and AdaBoost classification. Soil Dyn Earthq Eng, 111:1~7.

704

**CMY**K

4 期

- Asim K M, Moustafa S S R, Niaz I A, et al, 2020. Seismicity analysis and machine learning models for short-term low magnitude seismic activity predictions in Cyprus. Soil Dyn Earthq Eng, **130**:105932.
- Aslam B, Zafar A, Khalil U, et al, 2021a. Seismic activity prediction of the northern part of Pakistan from novel machine learning technique. J Seismol, 25(2):639~652.
- Aslam B, Zafar A, Qureshi U A, et al, 2021b. Seismic investigation of the northern part of Pakistan using the statistical and neural network algorithms. Environ Earth Sci, 80(2):59.
- Brehm D J, Braile L W, 1999. Intermediate-term earthquake prediction using the modified time-to-failure method in southern California. Bull Seismol Soc Am, 89(1):275~293.
- Brum D, Veronez M R, de Souza E M, et al, 2019. A proposed earthquake warning system based on ionospheric anomalies derived from GNSS measurements and artificial neural networks. In: IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium. Yokohama, Japan: IEEE, 9295 ~ 9298.
- DeVries P M R, Viégas F, Wattenberg M, et al, 2018. Deep learning of aftershock patterns following large earthquakes. Nature, 560 (7720):632~634.
- Geller R J, Jackson D D, Kagan Y Y, et al, 1997. Earthquakes cannot be predicted. Science, 275(5306):1616~1616.
- Haider T, Barkat A, Hayat U, et al, 2021. Identification of radon anomalies induced by earthquake activity using intelligent systems. J Geochem Explor, **222**:106709.
- Igarashi G, Saeki S, Takahata N, et al, 1995. Ground-water radon anomaly before the Kobe earthquake in Japan. Science, **269** (5220);60~61.
- Jain R, Nayyar A, Arora S, et al, 2021a. A comprehensive analysis and prediction of earthquake magnitude based on position and depth parameters using machine and deep learning models. Multimed Tools Appl, **80**(18):28419~28438.
- Jena R, Pradhan B, Al-Amri A, et al, 2020a. Earthquake probability assessment for the Indian subcontinent using deep learning. Sensors, **20**(16):4369.
- Jena R, Pradhan B, Beydoun G, et al, 2020b. Integrated model for earthquake risk assessment using neural network and analytic hierarchy process; Aceh Province, Indonesia. Geosci Front, 11(2):613~634.
- Jena R, Pradhan B, Naik S P, et al, 2021. Earthquake risk assessment in NE India using deep learning and geospatial analysis. Geosci Front, 12(3):101110.
- Kaftan I, Şalk M, Şenol Y, 2017. Processing of earthquake catalog data of Western Turkey with artificial neural networks and adaptive neuro-fuzzy inference system. Arab J Geosci, 10(11):243.
- Karimzadeh S, Matsuoka M, Kuang J M, et al, 2019. Spatial prediction of aftershocks triggered by a major earthquake: A binary machine learning perspective. ISPRS Int J Geo-inf, 8(10):462.
- Külahcı F, İ nceöz M, Doğru M, et al, 2009. Artificial neural network model for earthquake prediction with radon monitoring. Appl Radiat Isot, 67(1):212~219.
- Ma L L, Xu F Z, Wang X H, et al, 2010. Earthquake prediction based on levenberg-marquardt algorithm constrained backpropagation neural network using DEMETER data. In: Proceedings of the 4th International Conference on Knowledge Science, Engineering and Management. Belfast, Northern Ireland, UK: Springer, 591 ~ 596.
- Majhi S K, Hossain S S, Padhi T, 2020. MFOFLANN: moth flame optimized functional link artificial neural network for prediction of earthquake magnitude. Evolv Syst, 11(1):45~63.
- Mignan A, Broccardo M, 2019. One neuron versus deep learning in aftershock prediction. Nature, 574(7776):E1~E3.
- Nahornyi V, Panda A, Pandova I, 2020. Possibility and measurement of earthquake prediction based on trend study of total electron content(TEC) of Earth's Ionosphere. MM Sci J, 3985~3988.
- Niksarlioglu S, Kulahci F, 2013. An artificial neural network model for earthquake prediction and relations between environmental parameters and earthquakes. Int J Geol Environ Eng, 7(2):87~90.
- Panakkat A, Adeli H, 2007. Neural network models for earthquake magnitude prediction using multiple seismicity indicators. Int J

705

- Rahmat B, Joelianto E, Afiadi F, et al, 2020. Comparison of B-value predictions as earthquake precursors using extreme learning machine and deep learning. Internetwork Indo J, 12(1):47~52.
- Salam M A, Ibrahim L, Abdelminaam D S, 2021. Earthquake prediction using hybrid machine learning techniques. Int J Adv Comput Sci Appl, 12(5):654~665.
- Sikder I U, Munakata T, 2009. Application of rough set and decision tree for characterization of premonitory factors of low seismic activity. Expert Syst Appl, 36(1):102~110.
- Tareen A D K, Asim K M, Kearfott K J, et al, 2019. Automated anomalous behaviour detection in soil radon gas prior to earthquakes using computational intelligence techniques. J Environ Radioactiv, 203;48~54.
- Wakita H, Nakamura Y, Notsu K, et al, 1980. Radon anomaly: a possible precursor of the 1978 Izu-Oshima-kinkai earthquake. Science, 207(4433):882~883.
- Wang Q L, Guo Y F, Yu L X, et al, 2020. Earthquake prediction based on spatio-temporal data mining: an LSTM network approach. IEEE Trans Emerg Top Comput, 8(1):148~158.
- Xiong P, Long C, Zhou H Y, et al, 2020. Identification of electromagnetic pre-earthquake perturbations from the DEMETER data by machine learning. Remote Sens, 12(21):3643.
- Xiong P, Tong L, Zhang K, et al, 2021a. Towards advancing the earthquake forecasting by machine learning of satellite data. Sci Total Environ, **771**:145256.
- Xiong P, Zhai D L, Long C, et al, 2021b. Long short-term memory neural network for ionospheric total electron content forecasting over China. Space Wea, 19(4):e2020SW002706.
- Xu F Z, Song X F, Wang X H, et al, 2010. Neural network model for earthquake prediction using DMETER data and seismic belt information. In: Proceedings of the 2010 Second WRI Global Congress on Intelligent Systems. Wuhan, China: IEEE, 180~183.
- Yariyan P, Avand M, Soltani F, et al, 2020. Earthquake vulnerability mapping using different hybrid models. Symmetry, **12**(3): 405.
- Yousefzadeh M, Hosseini S A, Farnaghi M, 2021. Spatiotemporally explicit earthquake prediction using deep neural network. Soil Dyn Earthq Eng, 144:106663.
- Zhao S, Wang H Y, Xue Y, et al, 2022. What are more important for aftershock spatial distribution prediction, features, or models? A case study in China. J Seismol, **26**(1):181~196.
- Zhou W, Dong H B, Liang Y W, 2020. The deterministic dendritic cell algorithm with Haskell in earthquake magnitude prediction. Earth Sci Inform,  $13(2):447 \sim 457$ .

**MYK** 

Neural Syst, **17**(1): 13 ~ 33.

СМҮК

# **Recent Progress of Multi-source Data-based Machine Learning in Earthquake Prediction**

Zhu Junqing, Sun Ke

Institute of Earthquake Forecasting, CEA, Beijing 100036, China

**Abstract** In recent years, the rapid development of machine learning has made unprecedented achievements in the fields of computer vision, natural language processing and data mining. There are many disciplines of earthquake research, including seismology, geodesy, geochemistry, geomagnetism and geology. Therefore, the multi-source, complex and massive data generated by the earthquake research highly meet the requirements of machine learning for training data. In fact, many scholars have applied machine learning methods into earthquake prediction. In the view of the background of machine learning, the application process and evaluation methods of earthquake prediction based on machine learning methods and data from different disciplines in recent years, and summarized and discussed the application of machine learning in earthquake prediction.

Keywords: Machine learning; Multi-source data; Earthquake prediction; Research progress