李照,王徐孟,韩敏,等.基于D-S证据理论的建筑震害分层预测方法[J].地震工程学报,2026,48(6):1468-1478.DOI:10.20000/j.1000-0844.20250429002

Li Zhao, Wang Xumeng, Han Min, et al. Stratified prediction method for seismic damage of buildings based on D-S evidence theory [J]. China Earthquake Engineering Journal, 2026, 48(6): 1468-1478. DOI: 10.20000/j.1000-0844.20250429002

基于D-S证据理论的建筑震害分层预测方法

李 照[1], 王徐孟[2], 韩 敏[1], 李瑶瑶[3], 卢向阳[1], 张 峰[1]

(1. 山东省地震局,山东 济南 250102;
2. 中国交通建设股份有限公司总承包分公司,北京 100088;
3. 山东省泰安市气象局,山东 泰安 271000)

摘要: 针对当前建筑震害预测领域存在样本数据不确定性高与预测精度受限的问题,提出一种基于D-S证据理论的多模型融合建筑震害分层预测方法。首先,建立震害数据库,优化训练随机森林(RF)、极端梯度提升(XGBoost)、轻量级梯度提升机(LightGBM)、SAINT、TabNet和TabTransformer六种机器学习模型,通过性能对比与异构组合策略筛选子模型;其次,依据子模型特性构造修正后概率分配函数,应用D-S证据理论计算冲突系数与置信区间宽度,将样本数据的不确定性转化为可量化的决策风险值,依据风险等级实施差异化融合策略。基于"4·25"尼泊尔地震762 106条数据验证,在未分层预测场景下,总体样本的预测准确率为53.70%,较最优单模型XGBoost提升2.21%;在分层预测场景下,确定性样本和不确定性样本的预测准确率分别提升至67.91%和56.41%,较最优单模型准确率分别提升了29.25%和7.35%,验证该方法在量化数据不确定性、提升预测精度与决策可靠性方面的有效性。

关键词: 震害预测;D-S证据理论;机器学习;分层预测

中图分类号: P315.9 **文献标志码**: A **文章编号**: 1000-0844(2026)06-1468-11

DOI:10.20000/j.1000-0844.20250429002

Stratified prediction method for seismic damage of buildings based on D-S evidence theory

Li Zhao[1], Wang Xumeng[2], Han Min[1], Li Yaoyao[3], Lu Xiangyang[1], Zhang Feng[1]

(*1. Shandong Earthquake Agency, Ji'nan 250102, Shandong, China;*
2. Investment & Engineering Company of China Communications Construction Company Ltd., Beijing 100088, China;
3. Tai'an Meteorological Bureau of Shandong Province, Tai'an 271000, Shandong, China)

Abstract: To address the high uncertainty in sample data and limited accuracy in seismic damage prediction of buildings, this study proposes a multimodel fusion stratified prediction method based on Dempster-Shafer (D-S) evidence theory. A seismic damage database was first established, and six machine learning models, namely, random forest (RF), extreme gradient boosting (XGBoost),

收稿日期:2025-04-29

基金项目:山东省地震局一般科研项目(YB2510)

第一作者简介:李 照(1996-),女,硕士,助理工程师,主要从事地震灾害风险管理、评估方面研究。E-mail:1365511697@qq.com。

light gradient boosting machine (LightGBM), self-attention and intersample attention transformer (SAINT), tabular network (TabNet), and tabular transformer (TabTransformer), were trained and optimized. Sub-models were selected through performance comparison and heterogeneous combination strategies. A revised probability assignment function was then constructed based on the characteristics of these sub-models. D-S evidence theory was applied to calculate conflict coefficients and confidence interval widths, converting the uncertainty in sample data into quantifiable decision risk values, and differentiated fusion strategies were implemented according to risk levels. Validation using 762 106 building samples from the April 25, 2015, Nepal earthquake shows that in the non-stratified prediction scenario, the overall accuracy reached 53.70%, an improvement of 2.21% points over the optimal single model (XGBoost). In the stratified prediction scenario, the accuracy for deterministic and uncertain samples increased to 67.91% and 56.41%, respectively, corresponding to improvements of 29.25% and 7.35% points over the optimal single model. These results confirm the effectiveness of the proposed method in quantifying data uncertainty while enhancing prediction accuracy and decision-making reliability.

Keywords: seismic damage prediction; D-S evidence theory; machine learning; stratified prediction

0　引言

建筑物的倒塌与破坏是导致地震灾害损失的主要原因[1]，因此，开展建筑震害预测研究至关重要。常用的建筑震害预测方法包括历史震害统计法、半经验半理论法、结构理论计算方法等[2]。历史震害统计法和半经验半理论法通过分析震害影响因素与破坏程度的关系来建立预测模型，相较结构理论计算方法，参数获取容易、计算过程简单，有助于震后建筑物损伤状态的快速预测。其中，基于历史震害数据的房屋脆弱性曲线已在国内外得到了广泛应用。然而，房屋脆弱性曲线受建筑物特征及地区因素影响较大，其普适性和准确性受到一定限制。

随着人工智能的发展，机器学习方法在建筑震害预测研究中表现出巨大的潜力，它克服了房屋脆弱性曲线方法依赖预设公式和少量变量的局限。目前，中外学者应用k-近邻、决策树、支持向量机和人工神经网络等多种机器学习技术，结合实际震害数据，在地震建筑物损伤评估方面取得了众多成果[3-6]。研究结果显示，这些算法构建的模型分类准确度较高，充分证明了机器学习算法在震后建筑物损伤评估中的可行性。然而，目前大多数的研究都只局限在单模型上，且建筑物震后破坏等级的标定工作存在一定的主观性和模糊性，比如面对同一个建筑物损坏状态，不同的标定者会因主观判断得出不同的标定结果，所以机器学习模型在学习历史震害数据时会被这种不确定性所困扰，从而影响机器学习模型的准确率[3]。因此，如何综合利用单模型的优势和能力、避开算法自身应用的局限性，并进一步提高建筑物震害预测的可靠性和精确性成为新的命题。而这正与Dempster-Shafer(D-S)证据理论信息融合思想的出发点和目标相符合[7]，它属于不确定性推理方法，能够综合多证据源的信息，对事物的不确定性进行量化，在机械设备、故障诊断、目标识别等领域已经得到了广泛应用[8-10]。

鉴于此，本研究探索性地将D-S证据理论应用于建筑震害预测，提出一种新的多模型融合分层预测方法。该方法首先对多种机器学习算法的预测性能进行差异性评估，筛选出最优子模型作为基础预测模型；继而运用D-S证据理论对子模型融合结果进行决策风险量化评价，实现震害分层预测；最终依据决策风险度动态调整融合策略，有效提升建筑震害预测的准确性与可靠性。

1　研究方法

图1所示为基于D-S证据理论的多模型融合建筑震害分层预测方法设计思路。模型构建分为数据预处理、初步预测和分层预测三步，详见以下描述。

1.1　数据预处理

数据预处理阶段主要是对获取数据进行特征选择以及数据标准化处理。采用皮尔森相关系数法[11]与距离相关系数法[12]，量化各特征与建筑震害预测结果的相关性。皮尔森相关系数法能度量特征与建筑震害预测结果之间的线性关系，距离相关

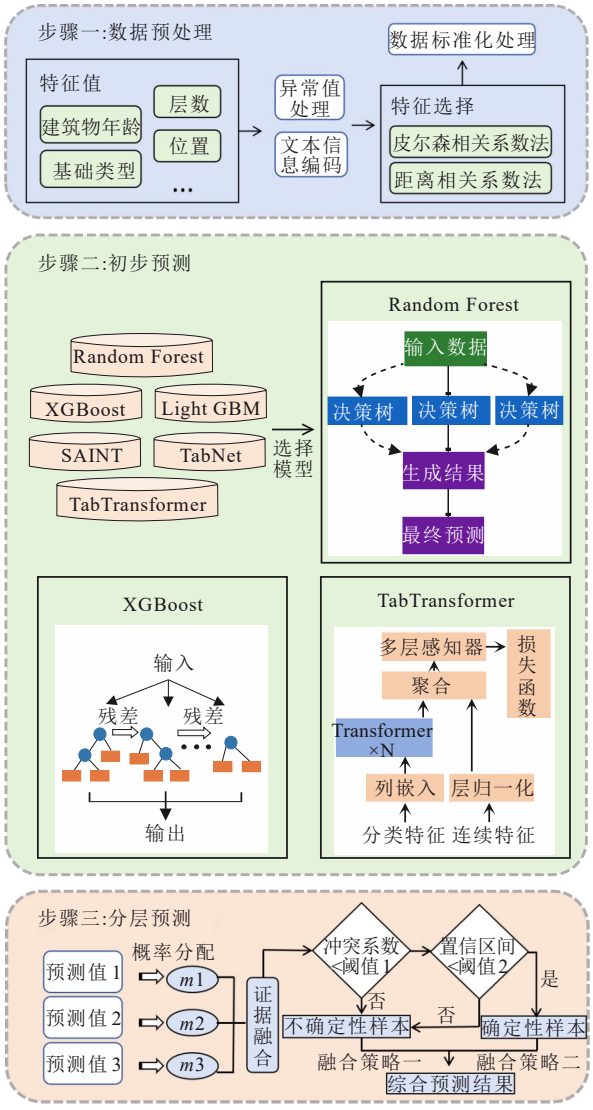


图 1 基于D-S证据理论的多模型融合建筑震害分层预测方法设计思路

Fig. 1 Design framework of the multi-model fusion stratified prediction method for building seismic damage based on D-S evidence theory

系数能够捕捉各特征与建筑震害预测结果的非线性关系。通过综合两种方法的优势,选取与预测值相关性大的特征。其中,皮尔森系数越接近−1或1,表示所选的特征与预测值相关性越强;越接近0,则表示所选的特征与预测值相关性越弱。皮尔森系数为正表明是正相关,为负表明是负相关。距离相关系数越靠近1,表示所选特征与预测值相关性越强;越靠近0,则表示所选特征与预测值相关性越弱。同时,为避免不同类型指标间因量纲不同对预测结果产生影响,对指标原始数据进行标准化处理和编码处理,以提高预测模型的预测性能和收敛速度。

1.2 子模型选择

针对房屋震害数据高维度、强非线性的特点,基于模型性能互补性原则,选择随机森林(Random Forest, RF)、极端梯度提升(eXtreme Gradient Boosting, XGBoost)、轻量级梯度提升机(Light Gradient Boosting Machine, LightGBM)、SAINT(Self-Attention and Intersample Attention Transformer)、TabNet(Tabular Network)以及TabTransformer(Tabular Transformer)作为预选模型。RF、XGBoost、LightGBM是基于决策树的集成学习模型,被广泛应用于医疗诊断、金融服务等领域,预测精度高且高效。SAINT、TabNet和TabTransformer是专门为表格数据设计的深度学习神经网络,这些模型引入了注意力层、特征嵌入和混合架构等机制,从而提高了处理异构表格数据的能力[13]。

基于预选模型进一步筛选子模型。采用不同算法的机器学习模型作为预选模型,能够从不同的空间角度和结构角度去挖掘数据之间存在的内在联系,实现信息增益,从而提高D-S证据理论融合决策的准确性和可靠性,减少单一证据的局限性[14-15]。因此,应用历史震害数据训练预选模型,将模型预测结果使用皮尔逊相关系数和距离相关系数分析,结合各模型预测准确率,以相关性低和准确率高为标准选择子预测模型。

1.3 分层预测

为减少不确定性信息对决策的干扰,应用D-S证据理论评判每个建筑物样本的决策风险度,通过有效融合多个证据源的信息或者简化分类,提高决策的准确性。

1.3.1 构建辨别框架

假设建筑物震后破坏等级有n种,破坏等级相互独立,所有破坏等级的集合即辨识框架$\Theta=\{\theta_1,\theta_2,\cdots,\theta_n\}$,$A$为$\Theta$的任一子集。若有一映射$m$满足:$2^\theta\to[0,1]$,$m(\varnothing)=0$,$\sum m(A)=1$,则把这一映射称为基本概率分配函数。其中,$m(A)$表示证据体对辨识框架中的子集$A$的支持程度,且$m(A)>0$。

在辨识框架Θ中,$Bel(A)$为A全部子集的基本概率分配之和,表示了对A的信任程度,并满足式(1);$pl(A)$为与A相交子集的基本概率分配之和,表示对A不否认的程度,并满足式(2)。$[Bel(A),pl(A)]$为A的信任区间,表达了对A支持

程度的范围，也反应了A的不确定性，也称作不确定区间[16]。

$$\begin{cases} Bel(A)=\sum_{B\subseteq A} m(B) \\ A\subseteq \Theta \end{cases} \tag{1}$$

$$\begin{cases} pl(A)=\sum_{B\cap A\neq \varnothing} m(B) \\ A\subseteq \Theta \end{cases} \tag{2}$$

获取基本概率分配函数是利用D-S证据理论进行决策级融合的一个关键步骤。根据子预测模型的机理特点和输出方式，构造基本概率分配函数，并应用Sklearn库和PyTorch库在PyCharm软件中实现基本概率分配函数计算（表1）。RF模型依据决策树的投票率作为基本概率分配函数。XGBoost和LightGBM模型通过树的集成直接优化损失函数，概率来自叶子权重的逻辑转换；SAINT、TabNet和TabTransformer模型通过神经网络的非线性变换生成概率。

表1　子模型基本概率分配函数计算方法

Table 1　Calculation method of basic probability assignment for sub-models

子模型	学习库	概率计算方法
RF	Sklearn	predict_proba( )
XGBoost	Sklearn	predict_proba( )
LightGBM	Sklearn	predict_proba( )（需probability=True）
SAINT	PyTorch	torch.softmax(logits)
TabNet	PyTorch	predict_proba( )
TabTransformer	PyTorch	torch.softmax(logits)

通过上述计算方式，对子模型的输出结果进行概率分配，得到$m_i(\theta_j)$，其中$i=1,2,\cdots m, j=1,2,\cdots,n$，代表第$i$个子模型的概率分配函数。应用D-S证据理论进行子模型预测结果融合时，还需注意证据间冲突问题，以免融合后出现不可能事件。将模型准确率作为折扣因子修正证据间的冲突，按照式(3)重新定义基本概率分配函数。式中，α_i表示第i个子模型的正确率，$m_i'(\theta_j)$表示修正后的第i个子模型的概率分配函数。

$$m_i'(\theta_j)=\alpha_i m_i(\theta_j) \tag{3}$$

在D-S证据理论中，应用最广泛的组合规则是Dempster合成公式。对于$\forall A\subseteq\Theta$，识别框架Θ上的n个mass函数$m_1,m_2,\cdots,m_n$。合成公式如下：

$$(m_1\oplus m_2\oplus\cdots\oplus m_n)(A)=\frac{1}{1-K}\sum_{A_1\cap A_2\cap\cdots\cap A_n} m_1(A_1)m_2(A_2) \tag{4}$$

式中：K为冲突系数，K越大说明证据体间的冲突越大，K值的计算方法如式(5)所示。

$$K=\sum_{A_1\cap A_2\cap\cdots\cap A_n=\varnothing} m_1(A_1)m_2(A_2)\cdots m_n(A_n) \tag{5}$$

1.3.2　识别样本分类

根据证据源对预测类别的支持程度对样本进行划分。将支持程度高的样本命名为确定性样本，支持程度低的样本命名为不确定性样本。判定规则如下：

（1）预先设定冲突系数阈值K_0。得到子模型的修正概率后，应用式(5)计算每个样本的冲突系数K，若$K<K_0$，则表明模型间分歧较小，融合结果有一定可靠性，接着进行后续判断。反之，意味着模型间冲突大，样本分类结果不确定性高，直接判定该样本为不确定样本。

（2）预先设定信度区间阈值ε_0。将满足上述条件(1)的样本，应用式(4)融合，选取综合概率最大的类别作为预测类别，将该预测类别对应的信任区间宽度ε与ε_0作比较，若$\varepsilon<\varepsilon_0$，则表明在该预测类别上，对样本的分类具有较高的确定性，可以判定该样本为确定性样本。反之，则表明样本在该预测类别上的不确定性较高，判定该样本为不确定样本。

1.3.3　综合预测

采取不同的融合策略进行综合预测。对于确定性样本，我们认定与最大概率值对应的状态为最终预测类别。对于不确定性样本，为减少信息的不确定性对模型准确率的影响，我们参照文献[5]简化分类的方式，提高模型的判别能力。对子模型预测值采取简单的加权平均输出。

1.4　模型评价指标

混淆矩阵作为衡量分类器准确度的一种工具，可用来衡量分类器对测试样本的分类结果与真实样本之间的关系。为了定量评估基于D-S证据理论的多模型融合建筑震害预测方法的有效性，采用准确率（Accuracy）、精确率（Precision）和召回率（Recall）作为模型评价指标，它们越接近1，模型性能越好，计算方式如下：

$$Accuracy=\frac{TP+TN}{TP+FP+TN+FN} \tag{6}$$

$$Precision=\frac{TP}{TP+FP} \tag{7}$$

$$Recall=\frac{TP}{TP+FN} \tag{8}$$

式中：TP为真阳性；TN为真阴性；FP为假阳性；FN为假阴性。

2 实验数据与模型应用

在本节中，介绍了所使用的实验数据，并基于该数据验证所提方法的有效性。

2.1 数据预处理

2.1.1 数据描述

采用2015年4月25日尼泊尔7.8级地震数据作为实验数据。数据来源于开放数据门户(https://eq2015.npc.gov.np)，数据库包含762 106条建筑物的信息，筛掉含异常值特征样本后，有效样本数量共计762 094条。建筑物所属行政区域为尼泊尔11个受灾最严重的地区(图2)，每座建筑物包含21条特征信息，包括建筑楼层、屋龄、层高等工程信息及震后损坏情况。

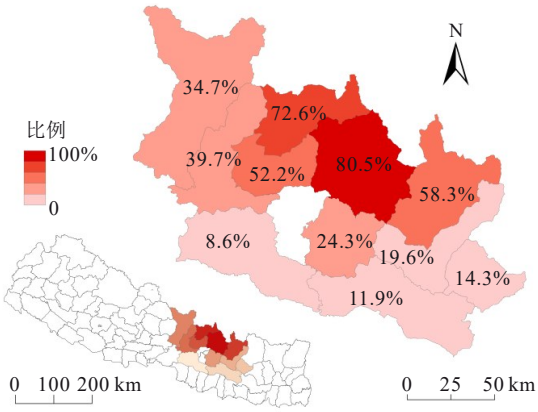


图2 研究区域位置和建筑物标记为毁坏(DG5)的比例

Fig. 2 Location of the study area and proportion of buildings marked as damaged (DG5)

为系统考量地震动对建筑物的破坏影响，引入地震烈度这一关键参数，数据来源于美国地质调查局ShakeMap工具提供的宏观地震烈度空间分布(图3)。参照文献[13]方法，对部分特征信息进行处理，将建筑所处行政区域编号换算为震中距，并按照“编码值与建筑物破坏程度呈有序关联”和“可理解性”原则对文本信息编码，处理后特征信息如表2所列。建筑物的总体损伤等级由专家按照欧洲地震烈度标准[17]来评定，其中损伤等级(Damage Grade，DG)按破坏严重程度从轻到重依次划分为DG1至DG5。

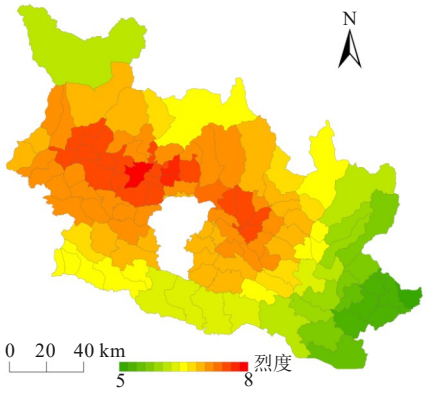


图3 2015年尼泊尔M_W7.8地震宏观地震烈度空间分布

Fig. 3 Spatial distribution of macroseismic intensity of the 2015 Nepal M_W7.8 earthquake

2.1.2 特征选择和数据标准化

将宏观地震烈度、震中距离、楼层、屋龄等22个特征作为自变量，建筑物破坏等级作为因变量，计算自变量与因变量之间的皮尔森相关系数与距离相关系数。为提高模型在训练过程中训练的效率，综合考虑两种相关系数算法的结果，对特征重要性从大到小排序，将累积占比达95%的顶部特征认定为重要特征，其余特征予以排除。由图4可知，应剔除B11(其他)、A10(附着状态)、B5(上部结构为泥浆砌砖)、B1(上部结构为土坯泥)这四个特征，其余特征作为输入特征输入预选子模型。此外，对连续特征应用式(9)进行标准化处理，以消除量纲等因素的影响。其中，X'是标准化处理后的数值，X是原始数据，X_{max}是该变量的最大值，X_{min}是该变量的最小值。

$$X'=\frac{X-X_{min}}{X_{max}-X_{min}} \tag{9}$$

2.2 子模型选择

将18个特征作为输入，建筑物破坏等级作为输出，用RF、XGBoost、LightGBM、SAINT、TabNet、TabTransformer共6种模型分别进行训练。把762 094条样本数据以6∶2∶2的比例划分为训练集、验证集和测试集，训练获得最优模型后，在测试集进行预测。单个预选子模型的预测结果如表3所列，各子模型预测结果的相关性分析如图5所示(图中TabTransformer模型简写为Tab-T)。由表3可以得出，XGBoost、RF和LightGBM模型的准确率、精确率和召回率比较高。但鉴于LightGBM是基于

表 2　建筑物特征信息

Table 2　Building characteristic information

序号	特征	数值
A1	震中距离	(0,191.32) km
A2	楼层	(1,9)
A3	屋龄	(0,200) a
A4	基座面积	(6.50, 464.52) m^2
A5	震前每层高度	(0.30, 30.18) m
A6	地表状况	平坦(0)；缓坡(1)；陡坡(2)
A7	基础类型	其他类型(0)；泥浆-石材/砖基础(1)；水泥-石材/砖基础(2)；竹/木基础(3)；钢筋混凝土基础(4)
A8	屋顶类型	竹/木-重型屋顶(0)；竹/木-轻型屋顶(1)；钢筋混凝土/钢筋砖/钢筋混凝土砖屋顶(2)
A9	地面楼层类型	其他(0)；泥质(1)；砖/石材(2)；木结构(3)；钢筋混凝土(4)
A10	附着状态	未附着(0)；单侧附着(1)；双侧附着(2)；三侧附着(3)
A11	宏观地震烈度	(5,8)
B1	上部结构为土坯泥	0,1(布尔值)
B2	上部结构为泥浆砌石	0,1(布尔值)
B3	上部结构为板石	0,1(布尔值)
B4	上部结构为水泥砂浆砌石	0,1(布尔值)
B5	上部结构为泥浆砌砖	0,1(布尔值)
B6	上部结构为水泥砂浆砌砖	0,1(布尔值)
B7	上部结构为木结构	0,1(布尔值)
B8	上部结构为竹结构	0,1(布尔值)
B9	上部结构为非工程化钢筋混凝土	0,1(布尔值)
B10	上部结构为工程化钢筋混凝土	0,1(布尔值)
B11	其他	0,1(布尔值)

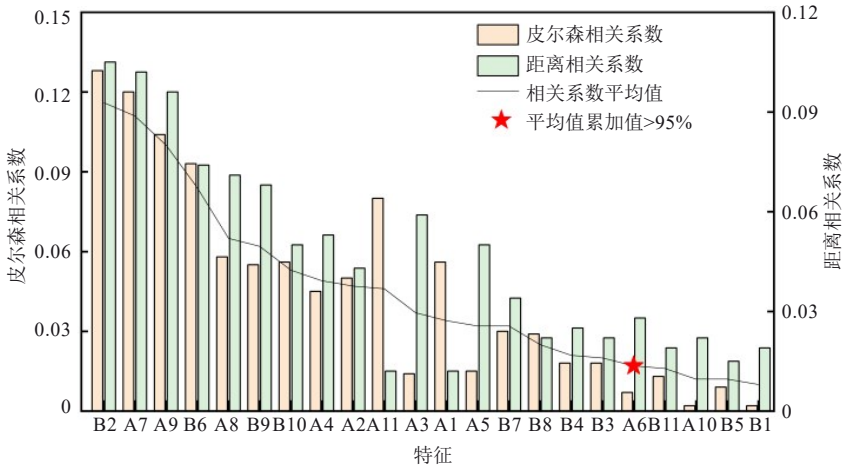


图 4　自变量与因变量之间的皮尔森相关系数与距离相关系数

Fig. 4　Pearson correlation coefficient and distance correlation coefficient between independent and dependent variables

决策树的集成学习模型，与XGBoost、RF相似度比较高，而TabTransformer模型虽然预测性能稍差，但是与其他算法相关性低，所以，最终选择XGBoost、RF和TabTransformer模型作为预测子模型。

2.3　分层预测

首先，获取预测子模型的修正后基本概率分配函数。基于尼泊尔7.8级地震实例，定义辨识框架 $\Theta=\{DG1, DG2, DG3, DG4, DG5\}$，应用表1的基本概率分配函数计算方法得到预测子模型的基本概率分配函数。为避免证据间冲突，将预测子模型的准确率作为折扣因子进行修正。根据子模型预测结果(表3)，XGBoost、RF和TabTransformer模型的折扣因子分别为0.525 4、0.520 7和0.478 2，将折扣因子代入式(3)得到修正后基本概率分配函数。

表 3 预选子模型预测结果(单位:%)

Table 3 Prediction results of pre-selected sub-models (unit:%)

子模型	准确率	精确率	召回率
RF	52.07	46.60	47.04
XGBoost	52.54	47.67	47.31
LightGBM	51.67	46.66	46.31
SAINT	45.24	40.06	36.79
TabNet	47.31	43.93	46.20
TabTransformer	47.82	44.56	40.32

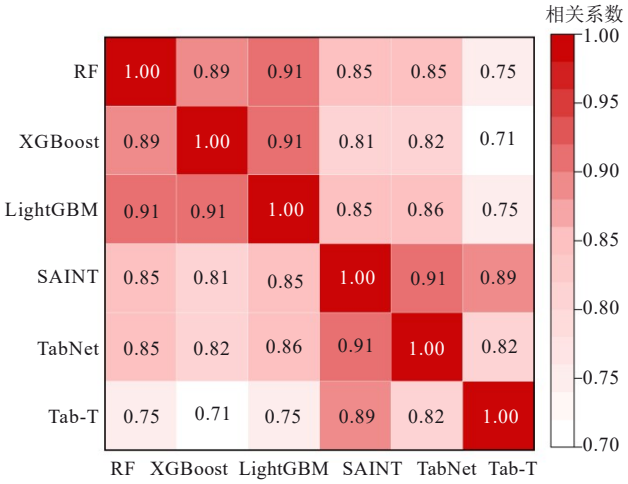


图 5 各子模型预测结果的相关性分析

Fig. 5 Correlation analysis of prediction results among sub-models

其次,对三个预测子模型的修正后基本概率分配函数进行融合。先通过冲突系数计算公式[式(5)]量化子模型预测值之间的冲突水平,再依据Dempster合成公式[式(4)]计算测试样本在各预测类别上的支持程度。通过与预先设定的冲突系数阈值K_0和信度区间阈值ε_0比较,完成对测试样本的划分。

为得到合适的冲突系数阈值K_0和信度区间阈值ε_0,对验证集的样本数据进行分析。如图6所示,152 419个验证样本中,99.9%的样本冲突系数小于0.5,只有57个样本冲突系数大于0.5,且最高冲突系数为0.52,这表明不同证据源的冲突程度较弱,融合结果有一定可靠性。但冲突系数集中在[0.4,0.45],表明系统处于中低冲突但非理想一致状态。所以,将冲突系数阈值设置为0.5,将冲突系数大于0.5的样本判定为不确定性样本,对冲突系数低于阈值的样本,通过计算信任区间宽度进一步分析证据源的可靠程度,量化其不确定性。设定损失函数如下:

$$L(\varepsilon_0)=\arg\min\left[P_1\times(1-A_1)+P_2\times(1-A_2)\right] \tag{10}$$

式中:P_1表示确定性样本占总验证样本的比例;A_1表示确定性样本的准确率;P_2表示不确定性样本占总验证样本的比例;A_2表示不确定性样本的准确率,使得损失函数最小的值为最佳信度区间阈值。

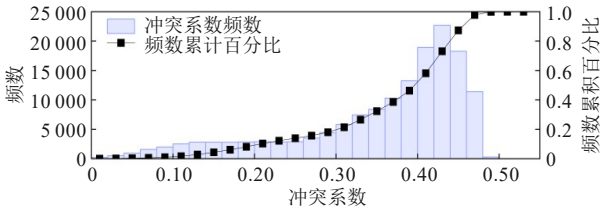


图 6 样本冲突系数分析

Fig. 6 Analysis of sample conflict coefficient

如图7所示,随着信度区间阈值的增加,确定性样本占总样本的比例也在增加,但准确率呈现持续下降的趋势,当阈值趋于0.5时,确定性样本占比接近总样本的100%,准确率稳定在0.52左右;而不确定性样本所占总样本的比例和准确率都呈现一直下降的趋势,损失值则是在信度区间阈值为0时,损

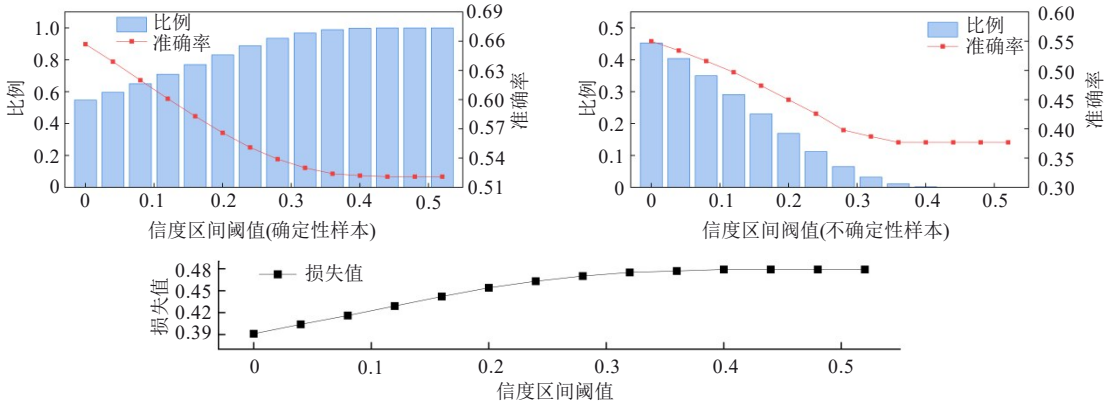


图 7 样本信度区间阈值分析

Fig. 7 Analysis of sample credibility interval threshold

失值最小。这表明，信度区间阈值ε_0设定为0时，整体样本的准确率最高。

接下来，我们将测试样本集输入训练好的子模型中，进行建筑震害的初步诊断。将冲突系数阈值K_0设置为0.5，信度区间阈值ε_0设置为0，使用1.3节所述的融合策略，输出模型的最终预测结果。

需要说明的是，在定义损失函数时是以模型预测总体准确率最高为目标建立的，实际应用中还可据实调整，比如，若不确定性样本决策成本高，可在损失函数中增加对不确定性样本的惩罚项权重，更关注如何减少不确定性样本的比例，即便牺牲部分整体准确率，也能确保在高决策成本场景下，降低因误判不确定性样本损伤分类而导致的严重后果，实现风险可控下的优化预测。

2.4　模型准确性评估

基于D-S证据理论的多模型融合建筑震害分层预测方法在测试集上的混淆矩阵、准确率、召回率和精确率，结果如图8、图9所示。混淆矩阵可视

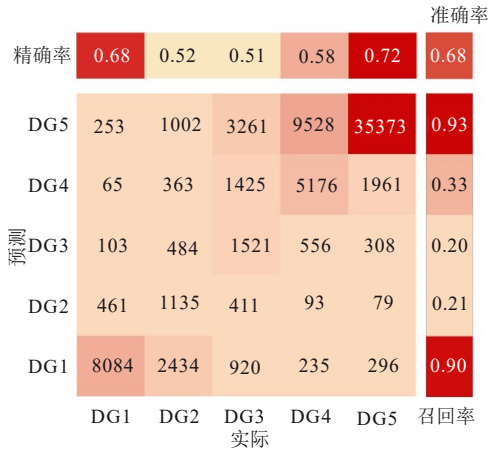


图8　确定性样本模型评价指标

Fig. 8　Model evaluation metrics for deterministic samples

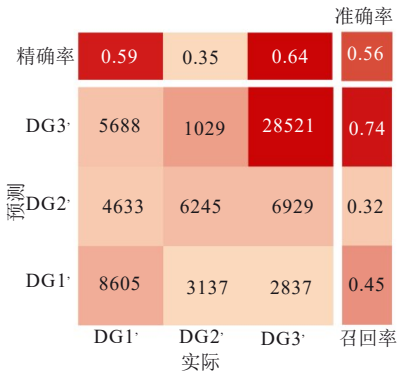


图9　不确定性样本模型评价指标

Fig. 9　Model evaluation metrics for uncertain samples

化了分层预测模型在分类预测任务中的表现。列表示预测的损坏等级，行表示真实的损伤等级，矩阵的对角元素表示正确预测的数量，非对角元素表示不正确的数量，即某一类被分类为其他类的观测值数量。可以看出，对于确定性样本，该模型对1级和5级损伤的预测能力较强，对中等损伤的预测能力较差，模型的总体分类准确率为67.91%；对于不确定性样本，该模型对简化分类后的新1级和新3级损伤预测能力较强，对中等损伤的预测能力表现也较差，模型的总体分类准确率为56.41%。这表明分类预测模型在处理震害损伤等级预测任务时，对具有显著差异的损伤等级表现出较强的预测适配性与准确性。

从研究区域确定性样本的总体分类准确率分布（图10）来看，各区域总体分类准确率差异不大，正确率均高于50%。这一结果表明，基于分层预测模型筛选的确定性样本在震害预测中展现出良好的普适性与稳健性，可有效消解区域差异性对预测结果的干扰。此外，总体分类准确率分布图呈现出震害破坏程度越严重的区域，模型预测准确率越高的显著特征。这种现象归因于建筑物高损伤区域的震害特征更为显著，建筑破坏模式更典型，从而为模型提供了清晰的特征学习样本；而低损伤区域因破坏特征模糊、干扰因素复杂，导致模型识别难度增加。

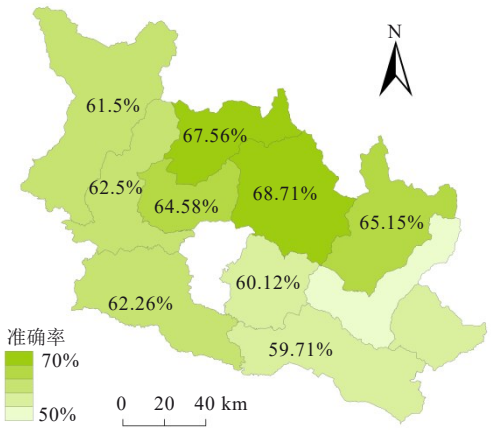


图10　确定性样本总体分类准确率分布

Fig. 10　Distribution of overall classification accuracy for deterministic samples

随机选取测试集中3个确定性样本作为例子，对该样本的证据理论融合过程进行说明（表4）。由于机器学习模型准确率普遍比较低，所以修正后样

表 4 随机 3 组测试样本概率输出

Table 4 Probability output of three randomly selected test samples

样本序号	真实类别	模型	m(DG1)	m(DG2)	m(DG3)	m(DG4)	m(DG5)	$m(\Theta)$	判定类别
344 号	DG4	XGBoost	0.010	0.027	0.093	0.292	0.103	0.475	不定
		RF	0.001	0.009	0.085	0.389	0.036	0.479	不定
		TabTransformer	0.001	0.013	0.064	0.343	0.058	0.522	不定
		融合模型	0.004	0.017	0.096	0.640	0.076	0.166	DG4
37851 号	DG3	XGBoost	0.173	0.150	0.145	0.039	0.019	0.475	不定
		RF	0.074	0.150	0.287	0.009	0.001	0.479	不定
		TabTransformer	0.077	0.105	0.281	0.013	0.001	0.522	不定
		融合模型	0.150	0.198	0.430	0.024	0.008	0.189	DG3
61696 号	DG1	XGBoost	0.414	0.050	0.020	0.010	0.030	0.475	不定
		RF	0.501	0.006	0.010	0.001	0.004	0.479	DG1
		TabTransformer	0.460	0.008	0.004	0.001	0.005	0.522	不定
		融合模型	0.829	0.017	0.008	0.003	0.011	0.132	DG1

本的机器学习模型概率输出结果集中在不确定类别上，但经过D-S证据理论对三种机器学习模型预测结果进行融合后，不确定类别的概率降低了很多，从而正确的预测出了震害损伤结果，体现了D-S证据理论用于多模型融合决策的可靠性。

同时，为验证综合模型在性能上的优越性，绘制了受试者工作特征(Receiver Operating Characteristic, ROC)曲线对XGBoost、RF、TabTransformer三种子模型及分层预测模型进行精度检验。ROC曲线横轴为假阳性率(1-特异性)，纵轴为真阳性率(敏感度)，且其线下的面积大小可作为评价分类模型准确性的指标。ROC曲线的线下面积用曲线下面积(Area Under Curve，AUC)来表示，AUC值越大，代表模型预测的准确率越高，模型预测效果就越好[18]。6种评价模型ROC曲线如图11所示，其中(d)D-S DS和(e)D-S US代表样本分层后确定性样本和不确定性样本的预测模型ROC曲线，(f)D-S All表示未分层场景下对所有样本用D-S证据理论融合的模型ROC曲线。相较之下，只应用D-S证据理论对三种机器学习模型预测结果进行融合，模型性能有一定的提升，但是提升幅度有限；应用D-S证据理论对样本分层后预测，确定性样本的预测准确率有了大幅度的提升，虽然不确定性样本的准确率有待提高，但分层预测模型有效量化了样本中的不确定性信息，为后续决策提供了参考依据，验证了该模型在震害分级预测中的有效性。

查阅文献可知，目前，在2015年尼泊尔地震的震害预测领域，学者已展开大量研究并取得了丰富成果，表5系统汇总了前人研究所应用的各类模型及其对应预测准确率，由此可以看出，机器学习模型在尼泊尔震害预测领域存在普遍准确率较低的问题，准确率集中分布在50%左右。由此可看出，震害预测准确率与震害数据有着密切的联系，在实际应用中，不确定性样本的存在是不可避免的，这也提醒着人们需要搜集更多元化的信息去辅助决策，比如地震遥感影像、场地条件等，以进一步完善决策依据，提高震害预测准确率。

3 结论

3.1 主要结论

震害预测在地震工程和灾害风险管理中具有重要意义。本文提出了一种基于D-S证据理论的多模型融合建筑震害分层预测方法，并结合“4·25”尼泊尔地震案例进行分析，得到结论如下：

(1) 提出的方法可实现对震后建筑样本的分层预测。标记为确定性样本的预测结果可靠，减少了误判风险，可直接用于指导灾后救援和资源分配，同时也为地震破坏预测模型提供高置信度的训练和验证数据，提升模型的可解释性；标记为不确定性样本的建筑样物可提醒决策者需进一步调查(如现场勘察、无人机巡检)，避免盲目决策。

(2) 针对不同样本特性提出了不同的优化预测策略。对于确定性样本，应用D-S证据理论融合子模型预测结果，进一步提高预测的准确率；对于不确定性样本，通过简化类别来减少信息的不确定性，降低预测的误判率。

(3) 实验表明，相较于单一的机器学习模型，基于D-S证据理论的多模型融合决策方法的震害

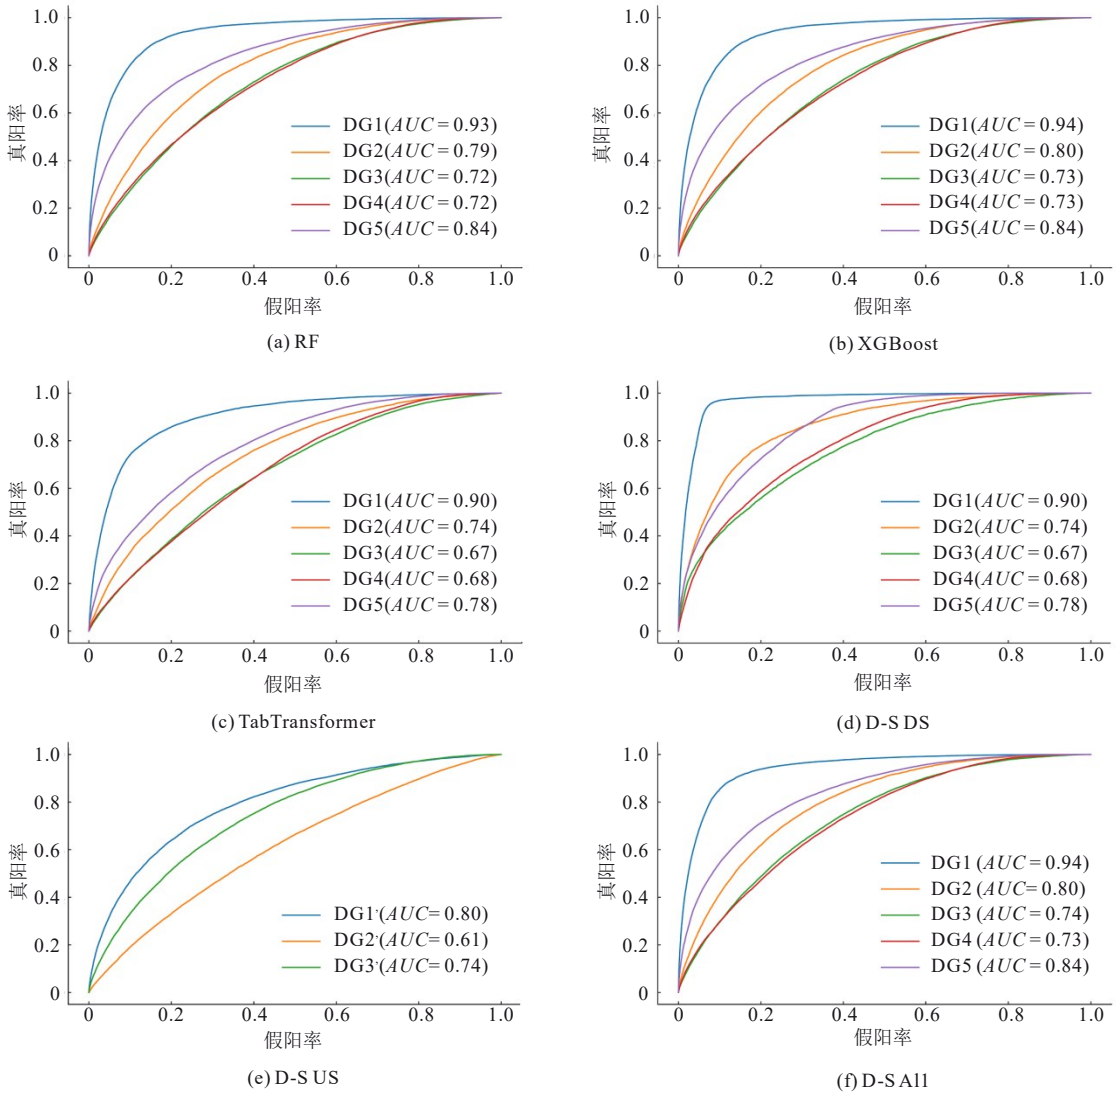


图 11　模型 ROC 曲线

Fig. 11　ROC curves of models

表 5　基于机器学习模型的 2015 年尼泊尔地震震害预测相关研究

Table 5　Related studies on seismic damage prediction for the 2015 Nepal earthquake based on machine learning models

参考文献	模型	准确率/%
Ghimire 等[5]	RF	49.0
Sajan 等[6]	Decision Tree	53.8
	RF	53.0
	XGBoost	57.7
	Logistic Regression	43.5
Li 等[13]	Stacking	51.57
	Boosting	51.60
本文	D-S All	53.70
	D-S Definite	67.91
	D-S Indefinite	56.41

预测准确率更高，能综合三个子模型的优势，实现对建筑物震后损伤等级的有效预测。未对样本数据分层的场景下，模型预测准确率达 53.70%，较最优单模型（XGBoost：52.54%）提升了 2.21%；分层预测机制展现出更强决策区分度，确定性样本预测准确率提升至 67.91%，较最优单模型绝对增幅达 15.37%（相对提升 29.25%），不确定性样本的预测准确率为 56.41%，较最优单模型准确率提升了 7.35%。

3.2　研究展望

本文基于历史震害数据构建了基于D-S证据理论的多模型融合体系对建筑震害进行分层预测。随着多源数据融合技术的进步，图像、文本等非结构化信息在建筑震害预测中展现出巨大潜力，仅依

赖数值型数据进行震害预测是本研究的局限所在。因此，如何从震后遥感图像、现场勘察报告等非结构化信息中，提取表征建筑结构损伤程度和潜在破坏风险的有效特征，将这些特征转化为D-S证据理论中的证据体，深度融入预测模型，构建更为精准、全面的建筑震害预测框架，是后续研究的重要方向。同时，未来可开展跨区域、跨地震事件的迁移学习研究，以评估并提升本方法的泛化性能，实现从单一场景有效性验证到多区域、不同地震事件普适性应用的突破，为建筑物震害预测提供更可靠的技术支撑。

参考文献(References)

[1] 尹之潜. 结构易损性分类和未来地震灾害估计[J]. 中国地震, 1996(1): 49-55.
Yin Zhiqian. Classification of structure vulnerability and evaluating earthquake damage from future earthquake[J]. Earthquake Research in China, 1996(1): 49-55.

[2] 赵真, 郭红梅, 张莹, 等. 基于遥感初判的建筑物震害Fisher判别法研究[J]. 地震工程学报, 2024, 46(6): 1405-1414.
Zhao Zhen, Guo Hongmei, Zhang Ying, et al. A Fisher discriminant method for seismic damage of buildings based on preliminary judgment from remote sensing[J]. China Earthquake Engineering Journal, 2024, 46(6): 1405-1414.

[3] Xu Y J, Lu X Z, Tian Y, et al. Real-time seismic damage prediction and comparison of various ground motion intensity measures based on machine learning[J]. Journal of Earthquake Engineering, 2022, 26(8): 4259-4279.

[4] Bhatta S, Dang J. Seismic damage prediction of RC buildings using machine learning[J]. Earthquake Engineering & Structural Dynamics, 2023, 52(11): 3504-3527.

[5] Ghimire S, GuéGuen P, Giffard-Roisin S, et al. Testing machine learning models for seismic damage prediction at a regional scale using building-damage dataset compiled after the 2015 Gorkha Nepal earthquake[J]. Earthquake Spectra, 2022, 38(4): 2970-2993.

[6] Sajan K C, Bhusal A, Gautam D, et al. Earthquake damage and rehabilitation intervention prediction using machine learning[J]. Engineering Failure Analysis, 2023, 144: 106949.

[7] Inglis J, Shafer G. A mathematical theory of evidence[J]. Technometrics, 1978, 20(1): 106.

[8] 范晓建, 田建艳, 杨英波, 等. 基于改进D-S证据理论的滚抛磨块融合决策模型[J]. 表面技术, 2021, 50(4): 393-401.
Fan Xiaojian, Tian Jianyan, Yang Yingbo, et al. Fusion decision model of tumbling chip abrasives based on improved D-S evidence theory[J]. Surface Technology, 2021, 50(4): 393-401.

[9] 郑丽莎, 尹东亮, 王旋. 基于改进D-S证据理论的相控阵雷达作战效能评估[J]. 系统工程与电子技术, 2024, 46(4): 1330-1336.
Zheng Lisha, Yin Dongliang, Wang Xuan. Operational effectiveness evaluation of phased array radar based on improved D-S evidence theory[J]. Systems Engineering and Electronics, 2024, 46(4): 1330-1336.

[10] 詹仲强, 陈文涛, 郝建, 等. 基于模糊逻辑和D-S证据理论的变压器故障诊断方法[J]. 高压电器, 2022, 58(11): 160-166.
Zhan Zhongqiang, Chen Wentao, Hao Jian, et al. Fault diagnosis method of transformer based on fuzzy logic and D-S evidence theory[J]. High Voltage Apparatus, 2022, 58(11): 160-166.

[11] Pan H, You X M, Liu S, et al. Pearson correlation coefficient-based pheromone refactoring mechanism for multi-colony ant colony optimization[J]. Applied Intelligence, 2021, 51(2): 752-774.

[12] 宋坤骏, 丁建明, 林建辉. 基于改进Fisher准则、VMD、距离相关系数和核极限学习机的轴承故障诊断[J]. 铁道机车车辆, 2018, 38(3): 22-28.
Song Kunjun, Ding Jianming, Lin Jianhui. Rolling bearing fault diagnosis with modified fisher criterion, VMD, distance correlation coefficients and kernel extreme learning machine[J]. Railway Locomotive & Car, 2018, 38(3): 22-28.

[13] Li Z, Lei H, Ma E, et al. Ensemble technique to predict post-earthquake damage of buildings integrating tree-based models and tabular neural networks[J]. Computers & Structures, 2023, 287: 107114.

[14] Zhao K, Li L, Chen Z, et al. A new multi-classifier ensemble algorithm based on D-S evidence theory[J]. Neural Processing Letters, 2022, 54(6): 5005-5021.

[15] Feng T J, Ma H R, Cheng X W. Land-cover classification of high-resolution remote sensing image based on multi-classifier fusion and the improved Dempster-Shafer evidence theory[J]. Journal of Applied Remote Sensing, 2021, 15(1): 014506.

[16] 王嘉玮. 基于D-S证据理论的道路交通事故判决方法研究[D]. 北京: 北京交通大学, 2021: 9-11.
Wang Jiawei. Research on traffic accident judgment method based on D-S evidence theory[D]. Beijing: Beijing Jiaotong University, 2021: 9-11.

[17] Grünthal G. European macroseismic scale 1998 (EMS-98)[M]. Luxembourg: European Seismological Commission, 1998.

[18] Fawcett T. An introduction to ROC analysis[J]. Pattern Recognition Letters, 2006, 27(8): 861-874.

(本文编辑：贾源源)