光电技术及应用

DOI：10.16818/j.issn1001－5868.20251009003

基于DCL-Net与异构集成模型周界安防非均衡信号识别方法

尚秋峰[1,2,3]，王茹妍[1,2,3]*

（华北电力大学 1. 电子与通信工程系；2. 河北省电力物联网技术重点实验室；
3. 电力物联智慧化技术河北省工程研究中心，河北 保定 071003）

摘　要： 针对周界安防中实际采集的振动信号类别存在样本量非均衡分布的问题，提出一种基于DCL-Net与异构AdaBoost集成学习模型的信号识别方法。该方法以深度可分离卷积（DSC）为基础构建特征提取器，引入卷积块注意力机制（CBAM）增强特征判别能力，并结合长短期记忆网络（LSTM）捕捉时序信号的长期依赖关系，构建DCL-Net网络结构。进一步将DSC，DSC-LSTM和DCL-Net三种网络作为弱分类器，改进AdaBoost集成学习算法进行迭代训练与加权投票，形成异构强分类器。为验证该方法的有效性，搭建了基于分布式声波传感的周界安防系统，模拟了攀爬、敲击、步行及无入侵事件。实验结果表明，所提方法在非均衡数据集上识别准确率达到94.00%，相较于同构集成模型、CNN-LSTM及SqueezeNet等对比模型分别提升了5.03%，8.26%，8.46%，验证了其在周界安防非均衡信号识别中的有效性与鲁棒性。

关键词： 分布式声波传感；集成学习；注意力机制；周界安防；信号识别

中图分类号： TP391.41　**文章编号：** 1001－5868(2025)06－1101－08

DCL-Net and Heterogeneous Ensemble-Based Method for Imbalanced Signal Recognition in Perimeter Security

SHANG Qiufeng[1,2,3], WANG Ruyan[1,2,3]

（1. Department of Electronic and Communication Engineering; 2. Hebei Key Laboratory of Power Internet of Things Technology; 3. Hebei Engineering Research Center of Intelligent Technology for Power Internet of Things, North China Electric Power University, Baoding 071003, CHN）

Abstract: A signal-recognition method that combines DCL-Net and a heterogeneous AdaBoost ensemble model is proposed to address the imbalanced sample distribution in vibration signals from perimeter-security applications. A feature extractor based on depth-wise separable convolution (DSC) is constructed. It is augmented with a convolutional block attention module to enhance feature discrimination and integrated with a long short-term memory (LSTM) network to capture long-term dependencies in time-series signals, thus forming the DCL-Net architecture. An improved AdaBoost algorithm iteratively trains three weak classifiers, i.e., DSC, DSC-LSTM, and DCL-Net, by combining them via weighted voting to form a strong heterogeneous classifier. A perimeter-security system based on distributed acoustic sensing is established to simulate climbing, knocking, walking, and no-intrusion events. Experimental results show that the proposed method

收稿日期：2025－10－09.
基金项目：河北省省级科技计划项目（SZX2020034）.
* 通信作者：王茹妍

achieves 94.00% recognition accuracy on an imbalanced dataset, thereby outperforDming homogeneous ensemble models CNN-LSTM and SqueezeNet by 5.03%, 8.26%, and 8.46%, respectively. Thus, its effectiveness and robustness are validated.

Key words: distributed acoustic sensing; ensemble learning; attention mechanism; perimeter security; signal recognition

0 引言

相位敏感光时域反射计(Phase-sensitive Optical Time Domain Reflectometer, Φ-OTDR)可通过提取传感光纤中后向瑞利散射光的相位变化实现对外界振动信号的定位,具有抗电磁干扰、高灵敏度、低成本等多重优势[1-4]。基于Φ-OTDR的分布式声波传感(Distributed Acoustic Sensing, DAS)系统能够实时、长距离地监测光纤沿线处各位置点的振动信息[5],响应速度快且布设方式灵活,适用于各类复杂地形与环境,同时可结合分类算法进行入侵事件识别,在周界安防领域应用广泛[6-8]。

随着人工智能技术的快速发展,采用深度学习模型的数据处理方法凭借其独特的神经网络结构和端到端的学习机制,在周界安防领域获得广泛关注[9-11]。卷积神经网络(Convolutional Neural Networks,CNN)作为深度学习模型的典型代表,将特征学习与模式分类整合于统一的框架之中,已成为当前的重要研究方向之一。相关学者提出将Φ-OTDR技术与CNN相结合,构建出一套周界防护系统,通过多种信号预处理方法实现对事件的分类,验证了CNN在复杂环境下具备较高的识别准确率[12-13]。由于CNN在时序信号准确表达和分析方面存在不足[14],陆续有学者进一步探索将长短期记忆网络(Long Short-Term Memory, LSTM)与CNN进行模型拼接,通过联合提取信号的时序特征与空间特征,在Φ-OTDR系统中实现对周界安防事件的高精度识别,有效提升了模式识别的综合性能[15-16]。以上方法多是在各类事件样本充足、类别均衡的条件下进行模型训练与评估,由此得到较准确的分类识别效果。然而现实环境存在复杂性与不可预测性,实际安防数据中的异常事件样本相较于无入侵事件样本表现出数量失衡性。当将以上基于均衡数据集训练的算法模型直接应用于实际非均衡事件场景时,模型识别准确性则会受到影响。

为提升系统的实用性与可靠性,本文借助DAS周界安防实验系统对攀爬、敲击、步行及无入侵四类事件进行数据采集以及非均衡数据集制作,提出一种基于DCL-Net的异构AdaBoost集成学习模型。以深度可分离卷积(Depthwise Separable Convolution, DSC)模块为基础构建特征提取器,引入卷积块注意力机制(Convolutional Block Attention Module, CBAM)提升特征的判别性,同时利用LSTM捕捉入侵事件信号的长期依赖关系,构建DCL-Net网络架构。集成DSC,DSC-LSTM和DCL-Net三种网络模型构成AdaBoost算法的异构强分类器,通过加权投票的方式获取到最终输出,实现非均衡数据的信号识别。实验结果表明,该模型各项指标均优于传统的同构AdaBoost模型(三个相同的基础CNN网络作为弱分类器)、CNN-LSTM以及轻量级卷积神经网络SqueezeNet。该方法为周界安防领域的非均衡数据识别提供有益参考。

1 基本原理

1.1 算法流程

为了提升网络模型在周界安防常见非均衡数据分布中的准确率,本文提出一种基于DCL-Net与异构集成学习模型的信号识别方法。方法原理如图1所示,包括数据采集、权重更新、模型训练和加权投票四部分。首先,进行原始数据采集,针对DAS系统采集到的周界安防信号进行IQ解调,获得对应的相位信息。接着,使用赋予初始权值的样本数据集进行模型训练第一个弱分类器,提取数据特征,获得数据的重要性分布权重。随后进一步对数据集进行相应调整,即根据权重更新数据集,来迭代训练下一弱分类器。最终,对三个弱分类器的结果进行加权投票可获得最终分类结果,从而提高模型的分类识别能力。

1.2 异构AdaBoost模型

AdaBoost作为一种经典的集成学习算法[17],通过集成多个弱分类器,自适应地调整训练样本的权重分布。该算法在当前弱分类器的每轮迭代训练中动态更新权值,从而增大数据集中模型错误分类

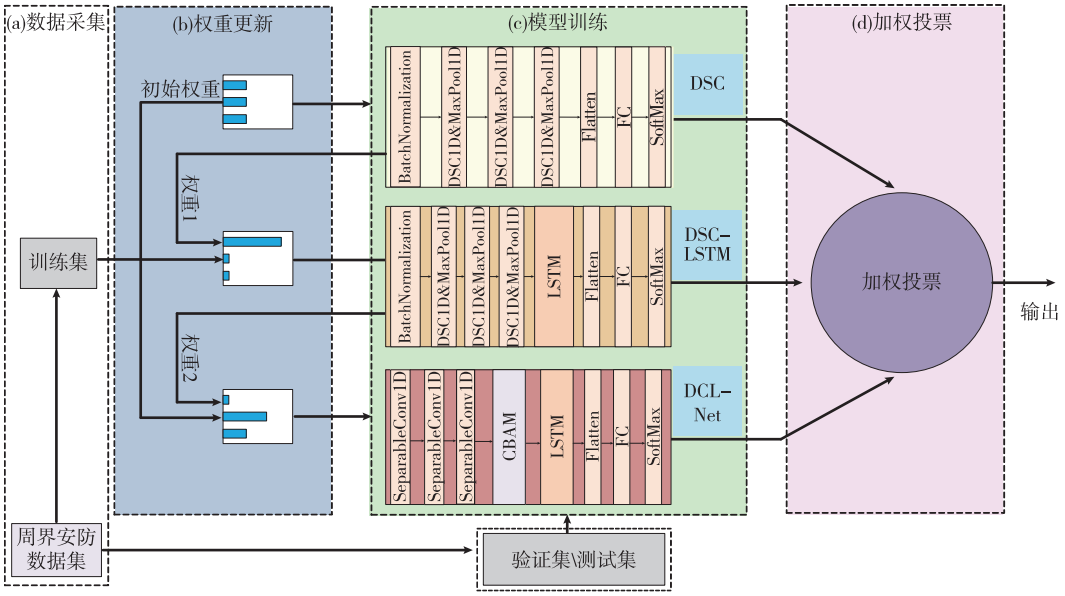


图1　异构AdaBoost集成学习模型原理图

样本占比，随后动态更新的数据集输入到下一个弱分类器，优化下一分类器性能，最终可通过集成多个弱分类器构成识别准确性更高的强分类器。与传统AdaBoost使用同类型弱分类器不同，本文引入异构AdaBoost集成模型，选取三种不同类型的弱分类器，分别为：DSC，DSC-LSTM和DCL-Net。通过结合各个弱分类器的优势，构建出模型识别效果更好和泛化能力更强的强分类器，同时提升模型鲁棒性，适用于周界安防实际非均衡数据集。AdaBoost集成算法具体实现步骤如下所示：

步骤1：初始化训练样本权值。首先为每个训练样本赋予相同的权值：

$$D_1(i)=w_{1i}=\frac{1}{m},i=1,2,\cdots,m \tag{1}$$

式中，w_{1i}为每个训练样本对应的初始权值，m为训练样本总数。

步骤2：迭代训练与权重更新。基于当前样本权值分布$D_t(i)$训练一个弱分类器，计算当前数据集中弱分类器的加权错误率ε_t：

$$\varepsilon_t=\sum_{i=1}^{m} w_{ti}\cdot I\left[h_t(x_i)\neq y_i\right] \tag{2}$$

式中，w_{ti}为当前样本权值；$h_t(x_i)$为训练样本预测输出标签；y_i为样本实际标签；$I(\cdot)$为指示函数，当预测标签与实际标签不一致时值为1，否则为0。

根据上述错误率计算当前分类器在最终集成模型中的权重α_t：

$$\alpha_t=\frac{1}{2}\ln\left(\frac{1-\varepsilon_t}{\varepsilon_t}\right) \tag{3}$$

当误差率越低时，该分类器的权重就越大。接下来更新样本权值分布D_{t+1}，根据当前一轮分类结果，自适应地调整每个样本的权重，增大数据集中模型错误分类样本占比：

$$w_{t+1,i}=\frac{w_{ti}\cdot\exp\left[-\alpha_t y_i h_t(x_i)\right]}{Z_t} \tag{4}$$

式中，Z_t为样本权值归一化因子，使得$\sum_{i=1}^{m} w_{t+1,i}=1$。

步骤3：构建异构强分类器。通过符号函数$sign$作用，按照权重α_t集成三个训练完毕的弱分类器，构成异构强分类器，最终的分类决策由三个弱分类器的加权投票结果决定：

$$H(x)=\mathrm{sign}\left[\sum_{t=1}^{3}\alpha_t h_t(x)\right] \tag{5}$$

1.3　深度可分离卷积模块

深度可分离卷积（DSC）是一种高效的卷积神经网络结构[18-19]，可在保持较高准确性的同时减少标准卷积计算所需的参数量与计算复杂度，极大提升模型的效率。

在标准卷积操作中，卷积核同时在空间维度和通道维度上进行操作，并一次性生成N个输出通道的特征。设定输入一个尺寸为$D_F\times D_F\times M$的特征图，通过一个尺寸为$D_K\times D_K\times M\times N$的卷积核进行处理，$N$为卷积核数量。同时在空间维度对特征图进行一一对应的卷积操作，从而得出N个卷积的总计算量为：

$$D_K \times D_K \times D_F \times D_F \times M \times N \tag{6}$$

在深度可分离卷积操作中，深度卷积负责对输入特征图的每一个通道进行独立的空间滤波，而不组合或生成新的通道。通过使用M个尺寸为$D_K \times D_K \times 1$的卷积核，每个核仅与输入特征图的一个对应通道进行卷积。由此可知，深度卷积的输出、输入特征图通道数均为M。此步骤的计算量为：

$$D_K \times D_K \times D_F \times D_F \times M \tag{7}$$

DSC中的逐点卷积用于组合深度卷积输出的通道信息，只操作通道维度，而不改变特征图的空间尺寸。通过使用N个标准的1×1卷积核，对深度卷积输出的M个通道进行线性组合，从而生成最终的N个输出通道。该步骤的计算量为：

$$1 \times 1 \times M \times N \times D_F \times D_F \tag{8}$$

由此可知，DSC的总计算量为：

$$D_K \times D_K \times D_F \times D_F \times M + M \times N \times D_F \times D_F \tag{9}$$

将DSC与标准卷积的计算量相比，可得计算量的缩减比例为：

$$\frac{D_K \times D_K \times D_F \times D_F \times M + M \times N \times D_F \times D_F}{D_K \times D_K \times D_F \times D_F \times M \times N} = \frac{1}{N} + \frac{1}{D_K^2} \tag{10}$$

由此可知，当采用$D_K = 3$大小的卷积核时，计算量大约可减少到标准卷积的1/8～1/9，计算效率大幅提升。

1.4 卷积块注意力机制

卷积块注意力模块（CBAM）是一种轻量化的注意力机制，通过融合通道注意力机制（Channel Attention Mechanism，CAM）和空间注意力机制（Spatial Attention Mechanism，SAM）的双重优势[20]，为模型提供了更加全面和有效的特征提取能力。CBAM结构如图2所示，整体计算过程如下：

$$\begin{cases} F_C = M_C(F) \otimes F \\ F_O = M_S(F_C) \otimes F_C \end{cases} \tag{11}$$

式中，$M_C(F)$与$M_S(F_C)$分别为CAM权重矩阵与SAM权重矩阵。

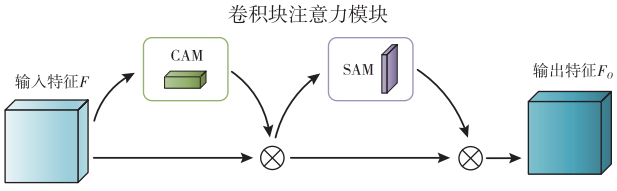


图2 CBAM结构图

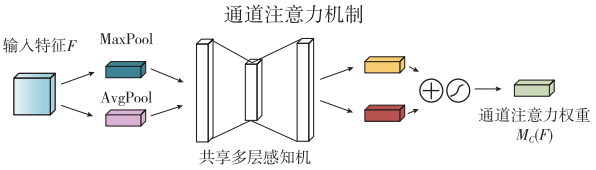
在输入一个尺寸为$C \times H \times W$的特征图F后，CAM模块会利用AvgPool和MaxPool压缩特征图F，得到两个尺寸为$C \times 1 \times 1$的张量F_{avgc}与F_{maxc}。两者经过一个MLP模块对特征图进行降维升维操作，从而生成两个特征向量后，再以add操作对两个特征向量进行特征融合，最终经过Sigmoid激活函数生成CAM权重$M_C(F)$。通道注意力机制结构如图3(a)所示，计算过程可表示为：

$$M_C(F) = \sigma\{\mathrm{MLP}[\mathrm{AvgPool}(F)] + \mathrm{MLP}[\mathrm{MaxPool}(F)]\} \tag{12}$$

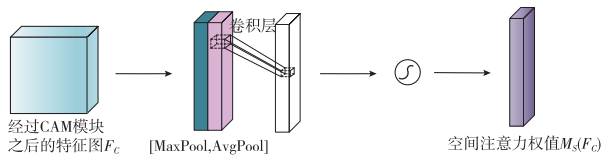
式中，σ为Sigmoid激活函数。

经过CAM细化后的特征图F_C输入SAM模块，借助AvgPool和MaxPool操作进行通道压缩，生成两个尺寸为$1 \times H \times W$的空间特征F_{avgs}与F_{maxs}。将两者通过concatenate操作进行特征拼接，形成一个2通道的特征图，再使用一个标准的7×7卷积层对该特征图进行处理，将其通道数从2降为1，最终通过Sigmoid激活函数将特征图映射为[0,1]分布后得到SAM权重$M_S(F_C)$。空间力机制结构如图3(b)所示，计算过程可表示为：

$$M_S(F_C) = \sigma\left\{f^{7\times7}\left\{\left[\mathrm{AvgPool}(F_C); \mathrm{MaxPool}(F_C)\right]\right\}\right\} \tag{13}$$



(a) CAM结构图



(b) SAM结构图

图3 CAM与SAM结构图

2 实验系统与数据

2.1 实验系统设计

采用DAS系统采集各类周界信号，系统结构如图4所示。本系统由输出功率为13 dBm以及中心波长为1 550 nm的窄线宽激光器产生稳定连续的窄

线宽光，光通过90∶10耦合器后以9∶1比例分为探测光和本地光。其中3 dB耦合器接收本地光，而声光调制器则对探测光进行频率调制，将其输出为脉冲宽度100 ns、频移量50 MHz的脉冲光。脉冲光在经过掺铒光纤放大器放大后，进入传感光纤并返回携带信息的后向瑞利散射光（RBS）。RBS经过光纤环形器后进入3 dB耦合器，随后经过拍频的传感信号进入平衡光电探测器转变为电信号。电信号通过采样率为250 MSa/s的数据采集卡和计算机处理信号获得信息。

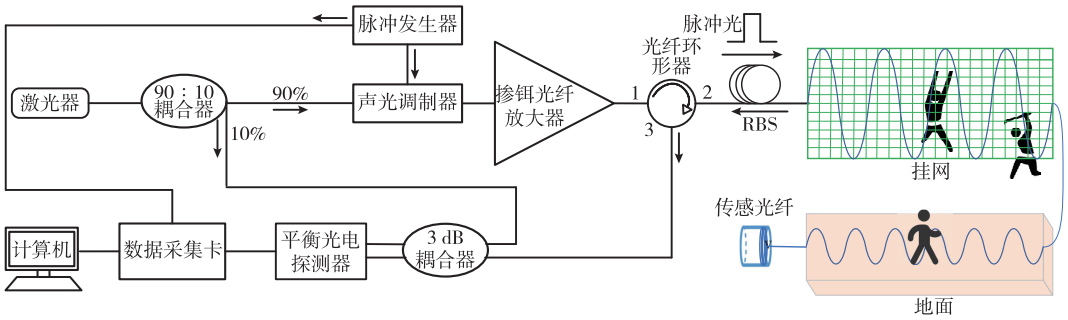


图4　实验系统结构

2.2　数据集制作

基于上述内容搭建了周界安防实验系统，测试光纤以“波浪”形状固定于2 m高的围栏上，后续光纤以同样形状铺设于地面，组织三名实验人员进行实验，以此采集周界安防中的攀爬、敲击、步行及无入侵信号。

为保证数据集的非均衡性，无入侵信号采集到2 000组数据，步行信号采集到1 600组数据，攀爬与敲击信号均采集到1 200组信号，共计6 000组样本。将实验所采集到的每类事件样本按照7∶2∶1的比例划分为训练集、验证集与测试集。训练过程中采用Adam优化器，损失函数为交叉熵损失函数。本研究使用的电脑软件环境为64位的Win11操作环境，开发语言为Python 3.9，网络模型使用TensorFlow 2.10.0。

3　结果与分析

3.1　评价标准

为评估深度学习集成模型的性能，使用准确率（Accuracy）、精确率（Precision）、召回率（Recall）以及F_1-score值进行模型性能对比与评价[21-22]，并对测试集应用十重交叉验证，以10次测试的平均值作为评价参数，定义混淆矩阵如表1所示。在混淆矩阵中，True Positive（TP）表示标签为正的数据被正确识别，False Negative（FN）表示标签为正的数据被错误识别。False Positive（FP）表示标签为负的数据被错误识别，True Negative（TN）表示标签为负的数据被正确识别。

表1　混淆矩阵定义

标签	Positive	Negative
Ture	TP	TN
False	FP	FN

准确率以最终数据样本中被正确分类的个数除以总样本数的方式进行计算，所得数值越高分类性能越强，如下所示：

$$Accuracy=\frac{TP+TN}{TP+TN+FP+FN} \tag{14}$$

精确率仅对正类别样本进行计算，通过使用实际与预测都为正标签的样本量与预测为正标签的所有样本量进行对比，如下所示：

$$Precision=\frac{TP}{TP+FP} \tag{15}$$

召回率也是对正类别样本进行计算，但其通过使用实际与预测都为正标签的样本量与实际为正标签的所有样本量进行对比，从而表示模型能够捕捉实际为正类别样本的能力，如下所示：

$$Recall=\frac{TP}{TP+FN} \tag{16}$$

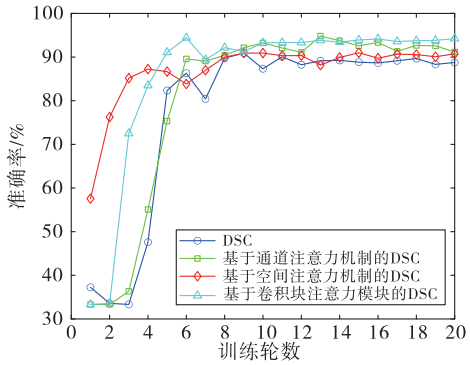
F_1-score值以精确率和召回率作为计算对象，通过均衡二者的关系，获取对模型性能准确且全面的描述，以调和平均数的形式表示模型性能的优劣，如下所示：

$$F_1\text{-}score=\frac{Precision\cdot Recall}{Precision+Recall} \tag{17}$$

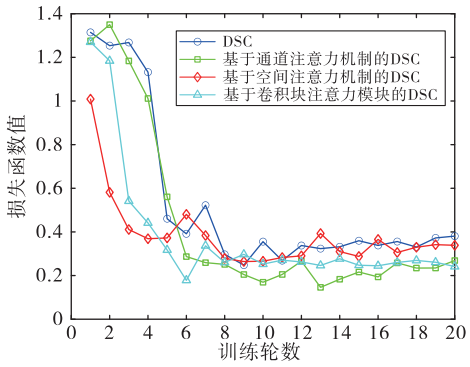
3.2　消融实验

为客观验证CBAM机制在周界安防模式识别中表现出的优异性能，使用相同的数据集对其进行消融实验对比。设计了四种网络进行对比研究，分

别为Net1(DSC),Net2(基于通道注意力机制的DSC),Net3(基于空间注意力机制的DSC)和Net4(基于卷积块注意力模块的DSC),保持训练参数一致,实验对比结果如图5所示。可观察到,Net1的准确率上升及损失函数下降较慢,最终准确率收敛值最低、最终损失函数值最高,表明基础DSC提取特征能力有限;引入注意力机制的Net2和Net3在准确率提升和损失函数下降速度上均优于Net1,表明注意力机制的有效性;Net4在验证样本上表现出最优的识别性能,训练过程较为平稳,模型鲁棒性和特征提取能力均得到提升。



(a)验证集准确率对比

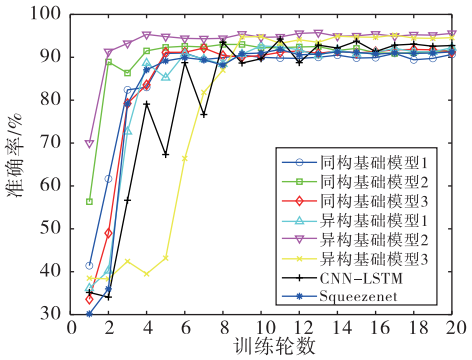


(b)验证集损失函数值对比

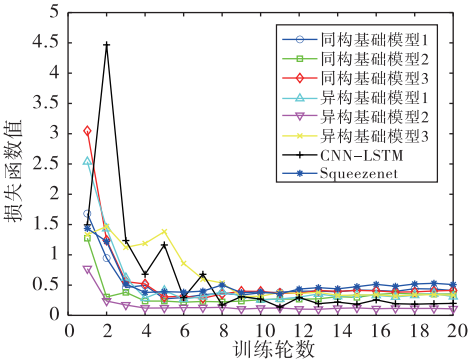
图5 基于不同注意力机制的DSC性能对比

3.3 模型训练

在模型训练阶段,对比了同构基础模型、异构基础模型、CNN-LSTM以及轻量级卷积神经网络SqueezeNet四种网络结构。其中,同构基础模型1,2,3为三个相同的基础CNN网络;异构基础模型使用三种不同类型的弱分类器,分别为异构基础模型1(DSC)、异构基础模型2(DSC-LSTM)、异构基础模型3(DCL-Net)。四种网络结构训练阶段各模型相关参数保持一致,结果如图6所示。由图可知,异构基础模型2的识别率与损失函数值均优于同构基础模型以及另外两种典型网络,且模型鲁棒性好,训练曲线平稳。



(a)验证集准确率对比

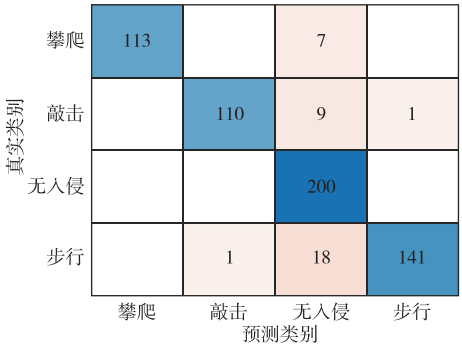


(b)验证集损失函数值对比

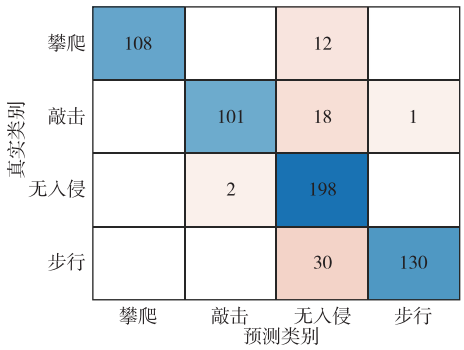
图6 不同网络结构在验证集上的性能对比

3.4 模型对比

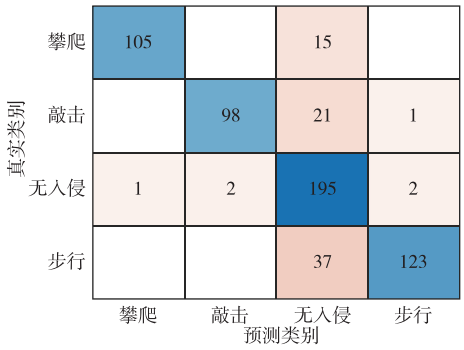
采用制作的测试集数据验证异构AdaBoost集成模型在处理周界安防非均衡数据集时表现的优异性能,每类事件均采用one-hot encoding设置标签类别。图7为四种网络结构对测试集进行识别的混淆矩阵图。表2为四种网络结构对测试集识别的准确率、精确率、召回率以及F1-score值,定义异构集成模型(DSC,DSC-LSTM,DCL-Net作为弱分类器)为Model 1,同构集成模型(3个基础CNN作为弱分类器)为Model 2,SqueezeNet模型为Model 3,CNN-LSTM模型为Model 4。



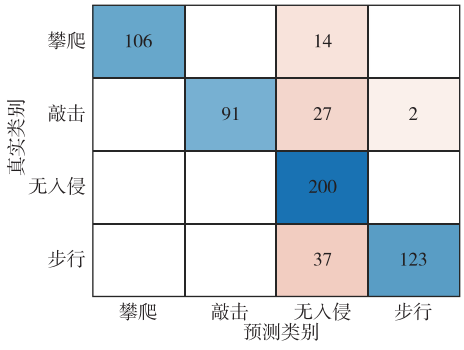
(a)异构集成模型混淆矩阵



（b）同构集成模型混淆矩阵



（c）SqueezeNet混淆矩阵



（d）CNN-LSTM混淆矩阵

图7　不同网络模型在测试集上的混淆矩阵对比

表2　各模型的评价指标对比

模型	*Accuracy*/%	*Precision*/%	*Recall*/%	F_1-*score*/%
Model 1	94.00	93.49	95.97	94.44
Model 2	89.50	88.60	93.51	90.28
Model 3	86.83	85.89	91.86	87.84
Model 4	86.67	85.85	92.64	87.90

由结果可知，异构AdaBoost集成模型在四个关键评价指标上均优于其他模型，事件识别的准确率相比于Model 2，Model 3，Model 4分别提升了5.03%，8.26%，8.46%，在整体分类任务中具有更高的判别能力，在周界安防领域的常见非均衡数据分布中表现出良好的稳定性。该结果充分体现出该模型的优势，具有一定实用价值。

4　结论

本文针对周界安防中实际信号类别分布不均衡的问题，提出一种融合DCL-Net与异构AdaBoost集成学习的识别方法。通过构建包含深度可分离卷积、注意力机制与LSTM的DCL-Net网络，有效提取信号的时空特征并增强特征判别能力。进一步将三种网络作为弱分类器异构集成于AdaBoost框架中，通过样本权值动态调整与加权投票机制，显著提升了模型在非均衡数据上的分类性能。实验结果表明，所提方法在准确率、精确率、召回率和F_1-score等评价指标上均优于传统同构集成模型及其他典型深度学习模型，为周界安防系统中非均衡信号的识别提供了一定的参考价值。

参考文献：

[1] Li J, Wang Y, Wang P, et al. Pattern recognition for distributed optical fiber vibration sensing: a review[J]. IEEE Sensors Journal, 2021, 21(10): 11983-11998.

[2] 黄麟景，周　霄，樊昕昱，等. 多机理融合分布式光纤传感技术研究[J]. 光学学报，2024，44(1)：161-172.
Huang Linjing, Zhou Xiao, Fan Xinyu, et al. Multi-mechanism distributed fiber-optic sensing technology[J]. Acta Optica Sinica, 2024, 44(1): 161-172.

[3] 张旭苹，张益昕，王　亮，等. 分布式光纤传感技术研究和应用的现状及未来[J]. 光学学报，2024，44(1)：0106001.
Zhang Xuping, Zhang Yixin, Wang Liang, et al. Present situation and future of research and application of distributed optical fiber sensing technology[J]. Acta Optica Sinica, 2024, 44(1): 0106001.

[4] Hernández P D, Ramírez J A, Soto M A. Deep-learning-based earthquake detection for fiber-optic distributed acoustic sensing[J]. Journal of Lightwave Technology, 2022, 40(8): 2639-2650.

[5] 赵航航，张明红，范　敏，等. 分布式光纤多参数融合传感系统研究[J]. 半导体光电，2024，45(6)：1024-1030.
Zhao Hanghang, Zhang Minghong, Fan Min, et al. Research on distributed fiber optic multi-parameter fusion sensing system[J]. Semiconductor Optoelectronics, 2024, 45(6): 1024-1030.

[6] Wu D, Liang Q Q, Hu B X, et al. Research progress of event intelligent perception based on DAS[J]. Sensors, 2025, 25(16): 5052.

[7] Marie T F B, Yang B, Han D, et al. Principle and application state of fully distributed fiber optic vibration detection technology based on Φ-OTDR: a review[J]. IEEE Sensors Journal, 2021, 21(15): 16428-16442.

[8] Dejdar P, Záviška P, Valach S, et al. Image edge detection

methods in perimeter security systems using distributed fiber optical sensing[J]. Sensors, 2022, 22(12): 4573.

[9] 吴慧娟, 王新蕾, 廖海贝, 等. 全智能化分布式光纤声波传感器的信号处理方法[J]. 光学学报, 2024, 44(1): 0106009.
Wu Huijuan, Wang Xinlei, Liao Haibei, et al. Signal processing in smart fiber-optic distributed acoustic sensor[J]. Acta Optica Sinica, 2024, 44(1): 0106009.

[10] Li Y, Cao X, Ni W, et al. A deep learning model enabled multi-event recognition for distributed optical fiber sensing[J]. Science China Information Sciences, 2024, 67(3): 132404.

[11] Liu Z, Zhang F, Sun Z, et al. Distributed fiber optic sensing signal recognition based on class-incremental learning [J]. Optical Fiber Technology, 2024, 87: 103940.

[12] Tomasov A, Zaviska P, Dejdar P, et al. Advancing perimeter security: integrating DAS and CNN for object classification in fiber vicinity[J]. IEEE Access, 2025, 13: 63600-63610.

[13] 吴 俊, 管鲁阳, 鲍 明, 等. 基于多尺度一维卷积神经网络的光纤振动事件识别[J]. 光电工程, 2019, 46(5): 180493.
Wu Jun, Guan Luyang, Bao Ming, et al. Vibration events recognition of optical fiber based on multi-scale 1-D CNN[J]. Opto-Electronic Engineering, 2019, 46(5): 180493.

[14] 张耀鲁, 于 淼, 常天英, 等. 基于波网络的相位敏感光时域反射系统模式识别方法研究[J]. 光子学报, 2021, 50(3): 58-69.
Zhang Yaolu, Yu Miao, Chang Tianying, et al. Phase-sensitive optical time-domain reflectometric system pattern recognition method based on wavenet[J]. Acta Photonica Sinica, 2021, 50(3): 58-69.

[15] 王 鸣, 沙 洲, 封 皓, 等. 基于LSTM-CNN的φ-OTDR模式识别[J]. 光学学报, 2023, 43(5): 19-30.
Wang Ming, Sha Zhou, Feng Hao, et al. φ-OTDR pattern recognition based on LSTM-CNN[J]. Acta Optica Sinica, 2023, 43(5): 19-30.

[16] Wang Z, Lou S, Wang X, et al. Multi-branch long short-time memory convolution neural network for event identification in fiber-optic distributed disturbance sensor based on φ-OTDR[J]. Infrared Physics & Technology, 2020, 109: 103414.

[17] 司江宽, 吐松江·卡日, 范 想, 等. 基于SO-PAA-GAF和AdaBoost集成学习的高压断路器故障诊断[J]. 电力系统保护与控制, 2024, 52(3): 152-160.
Si Jiangkuan, Tosongjiang Kari, Fan Xiang, et al. Fault diagnosis of high-voltage circuit breaker based on SO-PAA-GAF and AdaBoost ensemble learning[J]. Power System Protection and Control, 2024, 52(3): 152-160.

[18] Howard A G, Zhu M L, Chen B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[J]. arXiv preprint, 2017: arXiv:1704.0486.

[19] 程镕杰, 杨 耘, 李龙威, 等. 基于深度可分离卷积的轻量化残差网络高光谱影像分类[J]. 光学学报, 2023, 43(12): 1228010.
Cheng Rongjie, Yang Yun, Li Longwei, et al. Lightweight residual network based on depthwise separable convolution for hyperspectral image classification[J]. Acta Optica Sinica, 2023, 43(12): 1228010.

[20] 陈志刚, 陶子纯, 王衍学, 等. 基于逐次变分模态分解和CBAM-ResNet的滚动轴承故障诊断方法[J]. 振动与冲击, 2025, 44(4): 298-304, 312.
Chen Zhigang, Tao Zichun, Wang Yanxue, et al. Fault diagnosis method of rolling bearing based on SVMD and CBAM-ResNet[J]. Journal of Vibration and Shock, 2025, 44(4): 298-304, 312.

[21] Ding Y, Zhu H, Chen R, et al. An efficient AdaBoost algorithm with the multiple thresholds classification [J]. Applied Sciences, 2022, 12(12): 5872.

[22] Mienye I D, Sun Y. A survey of ensemble learning: concepts, algorithms, applications, and prospects[J]. IEEE Access, 2022, 10: 99129-99149.

作者简介：

尚秋峰(1968—),女,博士,教授,主要研究方向为光电子与光传感;

王茹妍(1999—),女,硕士研究生,主要研究方向为分布式光纤传感。