

文章编号:1006-9941(XXXX)XX-0001-13

基于音频信号的含能材料撞击感度机器学习识别

张炳儒¹,李明¹,文玉史¹,郭峰²,于绍钧¹,纪春亮³,林聪妹¹,郝利霄¹,韩勇¹,邓川¹,代晓淦¹

(1. 中国工程物理研究院化工材料研究所,四川 绵阳 621999; 2. 聊城大学物理科学与信息工程学院,山东 聊城 252059; 3. 北京理工大学机电学院,北京 100081)

摘要: 为了提高炸药撞击感度测试的准确性和客观性,采用机器学习方法对炸药撞击响应声信号的智能识别进行了研究。基于落锤式撞击感度测试装置针对混合炸药开展了试验,利用音频采集系统同步采集了撞击过程中的声信号,提取了最大值、带宽等一维的时域和频域特征,用短时傅里叶变换(STFT)将音频数据转换为二维的频谱图,采用条件生成对抗网络(cGAN)对一维数据进行数据增强,采用深度卷积生成对抗网络(DCGAN)对二维频谱图进行数据增强,采用了多种机器学习模型包括随机森林(RF)、极端梯度提升(XGBoost)、反向传播神经网络(BPNN)、支持向量机(SVM)、k-means聚类算法、卷积神经网络(CNN)、视觉Transformer(ViT)进行判爆分类。结果表明,RF、XGBoost、BPNN和SVM在原始数据集上的准确率均超过99.5%,在cGAN增强数据上最终达到100%,而k-means聚类算法初始达到了98.5%的准确率,在增强数据上呈现准确率先上升后下降的趋势。CNN和ViT在原始数据上的准确率分别为98.1%和98.4%,在增强数据上达到98.4%和98.9%,在增强数据上的表现有所提升,但受限于小样本环境和轻微的过拟合问题,准确率还有一定的提升空间。总体而言,本研究提出的基于机器学习的炸药撞击感度智能识别方法取得了较高的准确率,验证了其在爆炸声信号判爆任务中的可靠性与实用性,同时能够在一定程度上改善传统人工判爆的主观性和效率低的问题,为炸药使用安全性提供了可靠的技术方案。

关键词: 撞击感度;机器学习;深度学习;数据增强;卷积神经网络;声信号识别

中图分类号: TJ55; TP18

文献标志码: A

DOI: 10.11943/CJEM2024300

0 引言

炸药广泛应用于国防安全、矿产资源开采及基础设施建设等军事和民用领域,具有重要的战略与经济意义^[1-2]。然而,其能量特性与安全特性通常相互矛盾,高能量输出往往伴随着对外界刺激的高度敏感性,而潜在的意外爆炸风险可能导致严重的人员伤亡和财产损失。当前含能材料领域致力于实现“高能低感”的发展目标,即在保持高能量输出的同时降低其对机械、热等外界刺激的敏感性。因此,准确评估炸药安全性

具有重要的理论意义和实践价值。撞击感度作为衡量炸药安全性的关键指标之一,是指炸药在机械撞击作用下发生燃烧或爆炸的敏感程度,它直接影响炸药在研制、生产、运输、储存和应用全过程中的安全性^[3]。

GJB772A-97^[4]中关于撞击感度的测试方法,主要包括特性落高法和爆炸概率法。特性落高法通过“升降法”改变固定质量落锤的下落高度,找到试样发生50%爆炸时的特性落高来表征撞击感度;爆炸概率法通过观察固定质量落锤在固定高度落下时试样发生爆炸的概率,来表征撞击感度。这些方法采用下述方法判定试样是否发生爆炸:当观察到有声、光、烟、试样变色、烧蚀痕迹、气体产物等现象之一时,均判为爆炸,否则判为不爆;此外使用声级计时,声压级大于或等于试样不爆时最大声压级2 dB时,也应判为爆炸。

声级计作为一种常用的声音测量仪器,可以测量试验声音的声压级。为了提高撞击感度评估的客观性,Lease等^[5]和Marrs等^[6]将声级计应用于落锤冲击试验中的爆炸判定。通过对声压级的实时监测,声级

收稿日期: 2024-12-17; 修回日期: 2025-01-13

网络出版日期: 2025-01-24

基金项目: 国家自然科学基金面上项目(12372342); 院长基金自强项目(YZJJZQ2023008)

作者简介: 张炳儒(1999-),男,博士研究生,主要从事炸药安全性研究。e-mail: zbr1334563553@163.com

通信联系人: 文玉史(1982-),男,研究员,主要从事炸药安全性研究。e-mail: wenys@caep.cn

引用本文: 张炳儒,李明,文玉史,等. 基于音频信号的含能材料撞击感度机器学习识别[J]. 含能材料, DOI:10.11943/CJEM2024300.

ZHANG Bing-ru, LI Ming, WEN Yu-shi, et al. Machine Learning Recognition of Impact Sensitivity of Energetic Materials Based on Acoustic Signals[J]. *Chinese Journal of Energetic Materials (Hanneng Cailiao)*, DOI:10.11943/CJEM2024300.

计能够在一定程度上为炸药的撞击感度提供一个简便、快速的评估手段,理想情况下在爆炸事件发生时能够及时捕捉到显著的声压变化,比主观判断更加标准化。然而,作为一种探索性的自动化判爆方法,声级计具有一定的局限性。首先是单一声压级指标难以准确表征爆炸现象^[7],爆炸过程具有极高的复杂性,爆炸声包含冲击波、燃烧噪声^[8]和落锤撞击等多种物理过程产生的声学成分,这些成分在频率、幅值和持续时间等特性上存在显著差异,导致其时频特性呈现出显著的复杂特性,甚至某些炸药(如TNT)由于声音现象不明显,并不适合通过简单的声压级进行测试^[6]。其次是测试环境中的噪声干扰等因素引入系统误差^[8],测试环境中的噪声干扰、传感器空间布置和判爆阈值设定等多种因素会引入系统性测量误差。由于不同炸药的声压级存在显著差异,例如炸药的爆炸能量、高能基团的数量、落锤的高度也会对声压级产生影响^[5],因此每种炸药都需要单独进行标定,这使得测试流程复杂且缺乏广泛适用性。因此,尽管声级计在落锤冲击试验的爆炸判定中具有一定的应用价值和必要性,但其局限性也不容忽视,需要结合其他判爆方法或进一步的技术改进,才能更加准确可靠地评估炸药的撞击感度。

传统的撞击感度测试方法如特性落高法和爆炸概率法,存在主观性强、一致性差、效率低等缺陷^[9],难以满足日益增长的安全性评估需求。作为炸药反应的直接产物,爆炸声音蕴含了与炸药特性及反应程度密切相关、却尚未被充分挖掘和利用的信息;同时,得益于声学传感技术的发展,爆炸声信号的采集也变得便捷且易于实现自动化。因此可以利用现代信号处理技术,深入挖掘爆炸声信号中蕴含的丰富特征信息,并结合机器学习算法强大的模式识别能力,构建智能分类模型,从而实现更为客观、准确的撞击感度自动评估。

机器学习技术在语音识别^[10]、异常声音检测^[11]、环境声音分类^[12]、音乐流派分类^[13]等声信号处理领域取得了显著突破,在含能材料领域也取得了广泛应用^[14-18],为炸药撞击感度的智能判爆提供了创新思路。现有研究采用了支持向量机(SVM)^[19]、K近邻(KNN)^[20]、随机森林(RF)^[21]等传统机器学习方法和浅层人工神经网络(ANN)^[22],这些方法通常基于短时能量、短时过零率、频谱质心等一维特征^[23-24],对复杂声信号中的关键信息进行分析。另一方面,深度学习模型如卷积神经网络(CNN)^[10]、循环神经网络(RNN)^[25]、视觉Transformer(ViT)^[26]等作为非传统的深度学习方法也在声信号处理领域展现出良好的应用效

果,结合多模态信息融合^[27]和数据增强技术^[28-29]等方法,为判爆模型的构建提供了新的研究思路和技术手段。

为了提高炸药撞击感度测试判爆结果的准确性和客观性,本研究采用机器学习方法对炸药撞击响应声信号的智能识别进行了研究。首先采集撞击感度测试过程中的声信号,利用信号处理技术提取带宽、过零率等一维时域和频域特征,并以此为基础,构建基于传统机器学习算法(例如SVM、RF等)的基准模型,并分析其性能表现。同时,结合无监督学习中的K-means聚类算法,对撞击声信号特征进行聚类分析,以探索数据的潜在分布结构和类别特性,为判爆提供辅助依据。随后,又将声信号转化为时频域特征的频谱图,利用CNN和ViT两种深度学习模型进行训练,系统地对比两种模型在炸药撞击感度识别任务中的性能差异。此外,考虑到炸药撞击实验数据获取的难度和高成本,研究采用条件对抗生成网络(cGAN)和深度卷积生成对抗网络(DCGAN)进行数据增强,通过学习真实爆炸声数据的潜在分布特征,生成新的样本,以此扩充训练数据集,从而提高模型的泛化能力和鲁棒性。

1 数据收集与模型构建

1.1 数据采集与预处理

研究依据国军标 GJB772A-97 中的爆炸概率法^[4],采用落锤式撞击感度测试装置进行实验,以获取可靠的炸药撞击感度声音数据。实验中的炸药包括以 1,3,5,7-四硝基-1,3,5,7-四氮杂环辛烷(HMX)、1,3,5-三硝基-1,3,5-三氮杂环己烷(RDX)、1,3,5-三氨基-2,4,6-三硝基苯(TATB)、1,1-二氨基-2,2-二硝基乙烯(FOX-7)和 2,6-二氨基-3,5-二硝基吡嗪-1-氧化物(LLM-105)为主要成分的五种不同混合炸药,每种炸药样品质量均为 50 mg。实验参数设置如下:落锤质量 2 kg,落高 25 cm,环境温度控制在 10~35 °C,相对湿度(RH)维持在(70±10%)。

声信号采集系统采用 AWA6290L 型声音采集分析仪,该系统包含 AWA14435 型电容传声器和 AWA14614 型前置放大器、支撑三脚架,具有高灵敏度,能够捕捉细微的声学信号变化。采样率设定为声谱采集常用的 96 kHz,音频数据以 wav 格式进行存储。为保证数据的一致性和可比性,传声器通过三脚架固定于距离撞击点水平距离 1.5 m、距离地面高度 1.2 m 处。

实验的布局与流程如图 1 所示,操作台发出指令启动落锤,落锤自由下落撞击装置,位于两个击柱之间

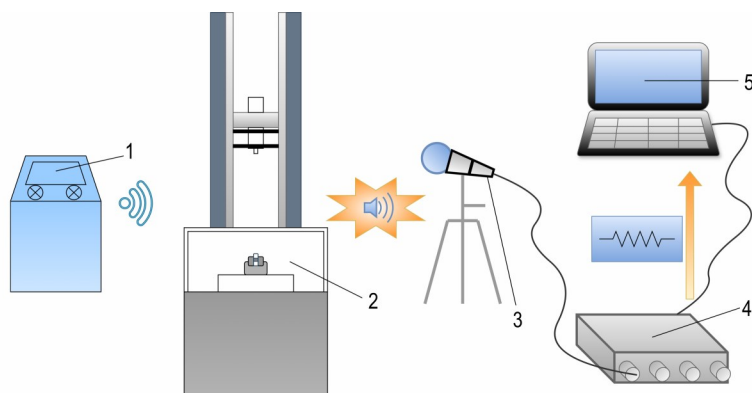


图1 撞击感度音频采集系统

1—控制台, 2—撞击感度落锤仪, 3—麦克风, 4—声音采集分析仪, 5—计算机

Fig.1 Audio acquisition system for impact sensitivity

1—console, 2—drop hammer apparatus for impact sensitivity, 3—microphone, 4—audio acquisition and analysis instrument, 5—computer

的炸药样品受到撞击后发生反应并产生声信号。该信号由麦克风拾取, 经由延伸电缆传输至AWA6290L声音采集分析仪, 最终通过配套软件在计算机端进行实时显示与数据存储。

在每次落锤冲击试验过程中, 均进行了长时间的声信号采集, 并同步记录了试验过程中的反应现象。试验结果的分类标签为“爆炸”或“未爆炸”, 该标签的确定主要基于试验人员对声信号的人工听音判断, 并辅以对火光、白烟及烧蚀痕迹等现象的观察。采集的声音数据包含整个撞击过程中的声学信息, 包括撞击声、爆炸声以及可能的燃烧噪声等。考虑到有效的数据均发生在撞击前后3秒内, 为提高数据分析的有效性, 仅截取撞击前后共计3秒的音频片段作为研究对象。每个音频片段对应一次撞击实验, 并根据现场实验结果标记为“爆炸”或“未爆炸”。实验共采集到3058条数据, 其中有360条爆炸数据与2698条未爆炸数据, 在类别分布上存在较为严重的不平衡性。

1.2 特征提取

从音频数据中提取多种声纹特征, 用于构建判爆模型。所提取的特征包括时域特征、频域特征和时频域特征, 旨在全面表征爆炸声音的特性。

时域和频域特征是直接从声信号中提取的一维特征信息, 研究中共选取了11种特征, 包括过零率、均值、方差、偏度、峰度、最大值、最小值、质心、带宽、平坦度和谱熵。根据图2所示的特征相关性热图, 去除了方差、最小值和谱熵3种特征, 最终选择出8种特征作为研究对象。过零率反映信号波形过零点的次数, 用于区分有声与无声或高频与低频信号。均值表示信号的整体强度水平, 偏度和峰度揭示信号分布的不对称

性与尖锐程度。最大值反映信号的最高能量。频谱质心表示频率分布的重心, 衡量信号的“明亮度”, 频谱带宽反映频率分量的分布范围, 体现声音的复杂性, 频谱平坦度衡量频谱平坦程度, 用于区分声音是否接近噪声。

时频域特征结合了时域和频域信息, 能够更全面地描述声信号的特性。提取的时频域特征为短时傅里叶变换(STFT)得到的频谱图, 可反映爆炸声音的时频特性。STFT生成的频谱图被统一缩放为 224×224 像素的图像, 并作为输入特征用于CNN和ViT模型的训练与分析。

1.3 基于GAN的数据生成

为了应对类别不平衡问题并提高模型的泛化能力, 采用了生成对抗网络(GAN)进行数据增强。具体来说, 我们使用了cGAN生成一维声音数据样本和DCGAN生成二维频谱图数据。

cGAN是一种扩展了传统GAN的深度学习方法, 其核心在于引入条件信息^[30], 指导生成器根据指定的条件标签(如“爆炸”或“未爆炸”)生成符合特定类别的样本。在实验中, 原始一维音频数据(如过零率、均值、偏度、峰度等特征)用于指导cGAN的训练过程。生成器接收随机噪声和类别标签作为输入, 生成目标类别对应的一维音频数据; 判别器则同时输入真实数据与生成数据, 学习区分数据的真实性以及生成数据是否与指定类别标签匹配。经过对抗训练, 生成器逐步提高生成数据的质量。最终, cGAN生成了3000条“爆炸”类别数据和5000条“未爆炸”类别数据, 显著平衡了数据集中类别样本的分布, 提高了数据的多样性和模型的泛化能力。图3展示了8种特征在经过cGAN

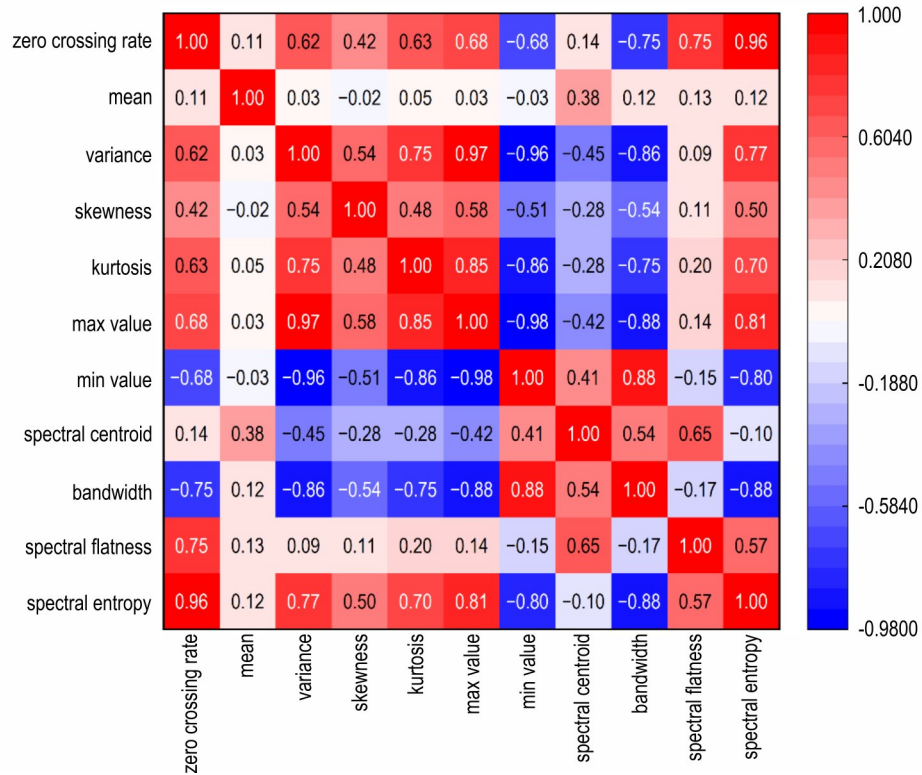


图 2 十一种特征的相关性热图

Fig.2 Correlation heatmap of eleven features

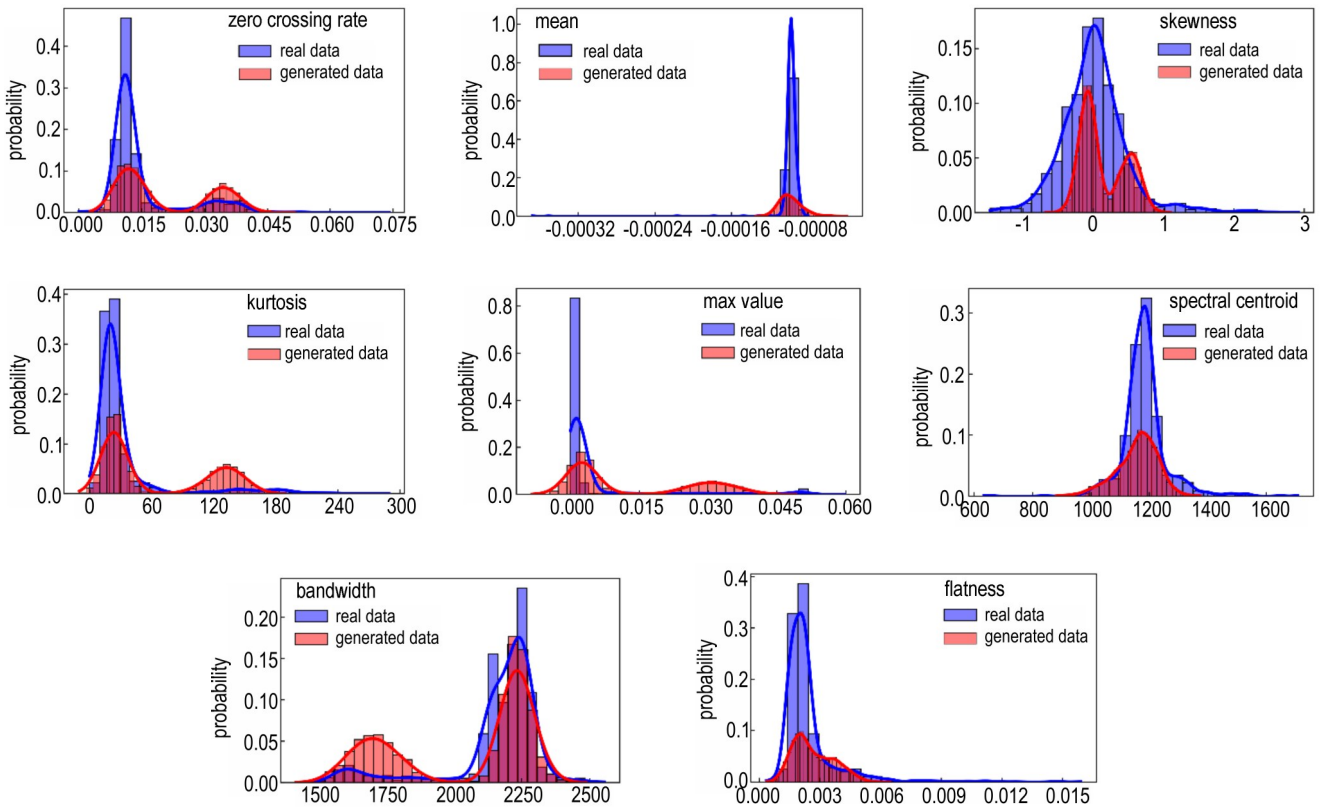


图 3 真实数据与模拟生成数据的 8 种特征分布对比

Fig.3 Comparison of eight features' distributions for real and generated data

训练 50 轮后生成数据与原始数据的直方图与核密度估计(KDE)曲线对比。从图 3 中可以观察到,生成数据的分布与真实数据的分布较为接近。

采用了 DCGAN 生成频谱图数据,进一步扩展音频数据的时频特性,模型结构如图 4 所示。DCGAN 是一类由 Goodfellow 等^[28]提出的生成模型,已在各个领域(包括图像^[31]、音频^[32]和时间序列数据^[33])生成逼真的数据方面取得了显著的成功。其生成器通过多层反卷积将随机噪声转换为图像数据,判别器则通过卷

积操作判断输入频谱图的真实性。两者通过对抗训练不断优化,最终生成与真实数据分布接近的高质量频谱图。在实验中,生成器输入随机噪声,通过反卷积生成频谱图,判别器学习真实与生成频谱图之间的差异。经过多轮训练,DCGAN 的生成数据逐渐接近原始数据。最终通过 DCGAN 生成了 3000 条数据,为后续基于图像的深度学习模型(如 CNN 和 ViT)提供了更加丰富的训练数据。图 5 为真实样本与生成样本的频谱图,由图 5a~b 可直观看出 DCGAN 生成样本的能力。

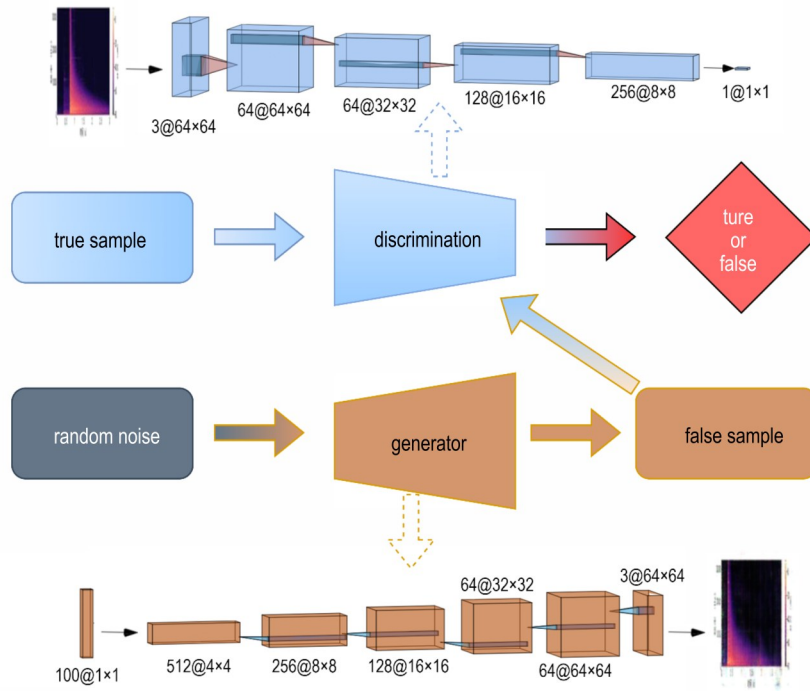


图 4 DCGAN 模型结构

Fig.4 DCGAN model architecture

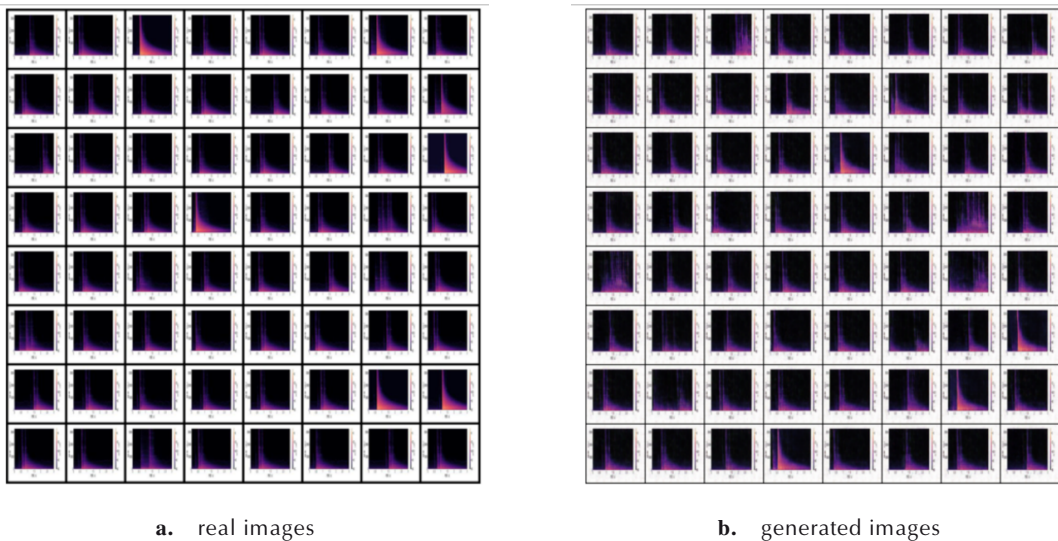


图 5 真实和生成图片对比

Fig.5 Comparison of real and generated images

1.4 模型构建与训练

本研究旨在构建智能判爆模型,通过采用多种机器学习和深度学习方法,对爆炸事件进行准确判别。首先,选取4种传统机器学习模型——RF、极端梯度提升(XGBoost)、SVM和反向传播神经网络(BPNN),基于8种一维时域和频域特征进行训练与学习。同时,结合无监督学习中的K-means聚类算法,对音频信号的特征分布进行聚类分析。随后,采用了2种深度学习模型,即CNN和ViT,分别通过提取音频信号的局部特征和全局特征来进行学习。

在深度学习部分,基于PyTorch框架构建的CNN模型采用多层卷积与池化结构。具体如图6所示,模型以STFT得到的频谱图作为输入,依次通过2个卷积层提取特征图。每个卷积层后使用修正线性单元(ReLU)作为激活函数,以增强模型的非线性表达能

力,并通过最大池化层降低特征维度,从而提升模型的鲁棒性。最终,经过全连接层和Softmax函数处理,CNN模型输出爆炸与不爆炸的判断。

ViT模型采用了基于Transformer的视觉架构。首先,模型将输入的频谱图均匀地划分为固定大小为 16×16 的图像块。每个图像块经过线性变换后,添加位置编码以保留其空间位置信息。接下来,这些带有位置编码的图像块被输入到多层Transformer编码器中。在每一层编码器中,多头自注意力机制用于捕捉图像块之间的长程依赖关系,随后通过前馈神经网络对特征进行进一步处理。最终,模型通过全连接层和Softmax函数输出分类结果。所采用的ViT模型是一个简化版本,类似于ViT-B/16架构,但仅包含4层编码器。这一简化设计旨在降低模型的复杂度和计算成本,同时保持较高的分类性能。

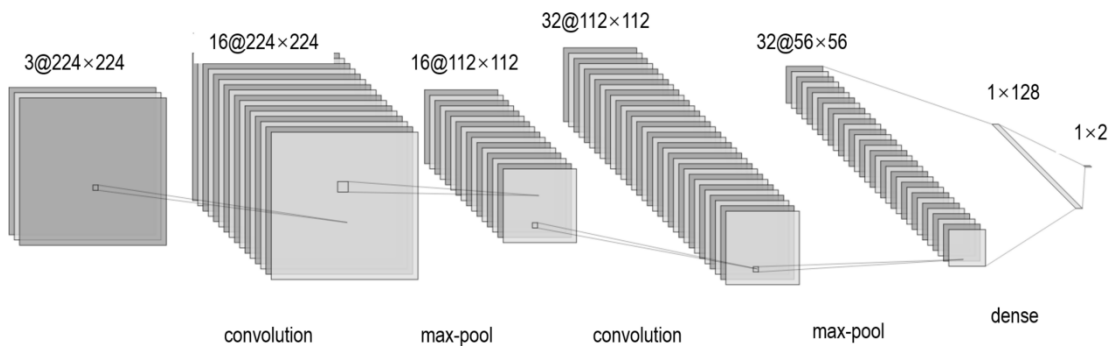


图6 CNN模型结构

Fig.6 CNN model architecture

训练数据集包含3058条原始采集的音频特征数据,按照8:1:1的比例划分为训练集、验证集和测试集。在模型训练过程中,CNN及ViT模型均采用交叉熵损失函数(Cross-Entropy Loss)来度量预测误差,设定批量大小(Batch Size)为32,最大训练轮次为200。随后,研究进一步采用扩增后的6058条数据对深度学习模型进行了再训练,以提升模型的泛化能力和性能表现。

为了全面评估不同模型的性能,具体而言,对RF、XGBoost、BPNN和SVM模型采用准确率评估,即测试集中预测正确样本数与测试集样本总数之比;K-means作为无监督聚类算法,采用准确率和二维PCA图进行评估,其中准确率计算需先将聚类标签映射到真实标签,所有样本的正确率即是准确率;深度学习模型主要基于损失值和准确率曲线进行性能分析,

这里的准确率同样是验证集和测试集中预测正确样本数与其对应样本总数之比。

2 结果与讨论

2.1 模型的数据准确率与特征重要性

为评估不同模型在原始数据和增强数据(包含原始数据与生成数据)上的性能表现,对5种模型(BPNN、XGBoost、SVM、RF和k-means)在不同训练次数下的准确率进行了比较分析。表1展示了各模型在原始数据及不同增强数据集上的准确率结果。

从表1可以看出,RF、XGBoost、BPNN和SVM在原始数据上的准确率都很高,其中RF的准确率达到100%,BPNN和XGBoost为99.8%,SVM为99.5%。在增强数据上,4种模型随着cGAN训练次数的增加,准确率呈现显著上升趋势,并最终趋于接近100%。

表 1 五种模型在真实与增强数据上的准确率

Table 1 Accuracies of five models on real and augmented data

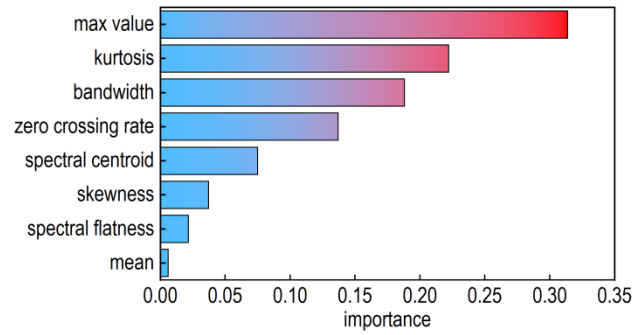
data type	accuracy / %				
	RF	XGBoost	BPNN	SVM	k-means
real data	100	99.8	99.8	99.5	98.5
augmented data (10)	73.8	71.7	75	73.9	66.4
augmented data (30)	97.8	98.3	98.4	98.6	97.3
augmented data (50)	99.8	99.9	99.8	99.9	99.7
augmented data (100)	99.7	99.9	99.9	99.9	94.7
augmented data (150)	100	100	100.0	100	95.7

在训练次数较少(如 10 次)时,四种模型准确率都较低,在达到 50 次时趋于稳定,与原始数据准确率相当。总体来看,这 4 种监督学习模型在原始数据上表现优异,能够充分利用生成数据的特征。

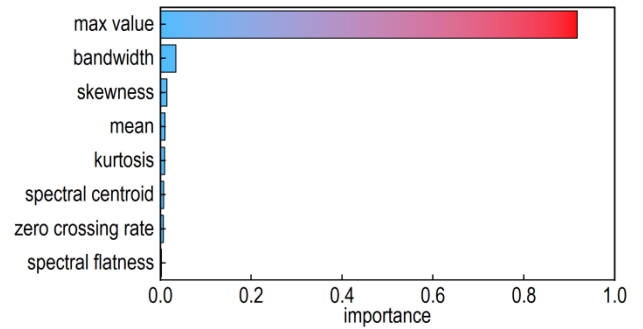
同时,从表 1 中可以观察到,k-means 聚类算法的准确率随训练次数增加呈现先上升后下降的趋势。反映出生成数据质量和分布的变化对无监督学习方法的影响。在训练次数从 10 次增加到 50 次时,生成数据逐渐接近原始数据分布,特征较为明显,因此准确率提升。然而,随着训练次数进一步增加,生成数据可能逐渐偏离原始数据的真实分布,或引入更多的噪声和异常模式,导致 k-means 聚类效果下降。相比于监督学习模型(如 RF 和 XG-Boost)能够利用标签信息进行纠正,k-means 对数据分布更为敏感,无法适应生成数据分布的恶化。因此,这一趋势表明在使用无监督方法时,应注意控制训练数据生成的次数与质量,避免因数据分布偏差而影响模型性能。

为了进一步探讨监督学习模型的内部特性和决策机制,特别是 RF 和 XGBoost 模型在判爆任务中的特征使用情况,对这两种模型的特征重要性进行了深入分析,特征重要性排序如图 7 所示。从图 7a 可观察到,RF 模型中最大值、峰度、带宽等特征贡献度依次降低且相对均衡;而图 7b 显示出 XGBoost 模型中最大值这一特征的贡献度超过了 0.8,其他特征的重要性评分较低。这些差异表明,不同模型在利用特征进行决策时的策略与偏好存在一定差别。两种模型均显示最大值是最重要的特征,这可能表明爆炸事件在信号幅值上可能存在显著的极大值特征。

此外,为了更直观地分析 k-means 聚类算法在原始数据和生成数据上的表现,对原始数据及不同训练次数的增强数据与 k-means 聚类结果进行了 PCA 分布



a. RF



b. XGBoost

图 7 特征重要性对比

Fig.7 Comparison of feature importance

的对比,如图 8 所示。图 8a 可以看出原始数据 PCA 分布具有明显的两簇结构,两种标签分界清晰,图 8b 展现了 k-means 聚类基本能够捕捉这种簇结构,但存在少部分标签混淆。图 8c 可以看出在 cGAN 训练 10 次时,增强数据两种标签分界模糊,图 8d 展示出聚类效果很差。在训练 50 次时,图 8e 中增强数据的分布更清晰,与原始数据较为一致,从图 8f 中可以看出聚类性能显著提升。图 8g 中可以看出,在训练 150 次时,增强数据的分布已经偏离原始分布,可能引入了更多噪声和异常模式,从而图 8h 表现出聚类效果下降。整体来看,k-means 聚类性能随着增强数据训练次数的变化而显著波动,与表 1 中的准确率变化趋势一致。这表明,当增强数据的分布接近原始数据时,聚类性能可以得到有效提升;然而,随着训练次数的进一步增加,数据分布逐渐偏离原始结构,引入噪声或异常模式,导致聚类效果下降。

2.2 深度学习模型的训练与验证

构建了基于 CNN 和 ViT 的深度学习模型,以自动提取爆炸声信号的深层特征。图 9 展示了 CNN 模型在训练过程中的损失函数值和准确率变化曲线。从

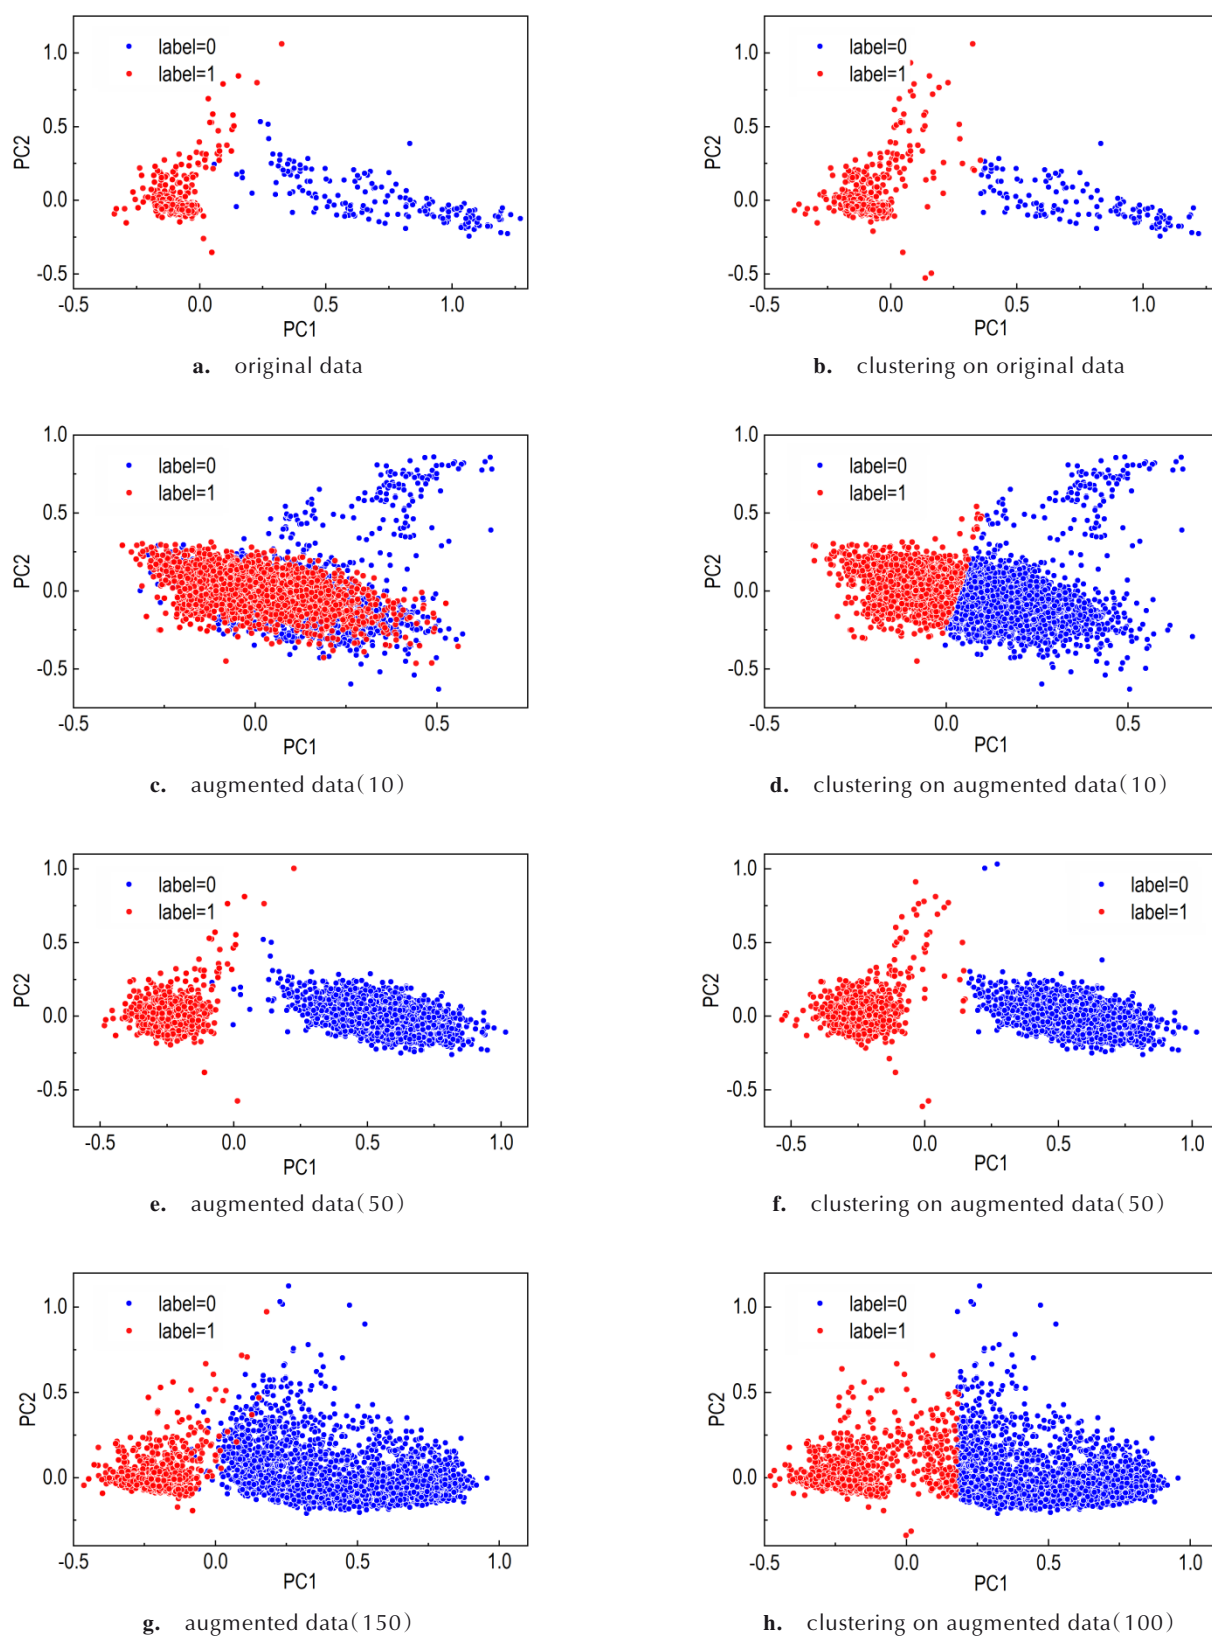
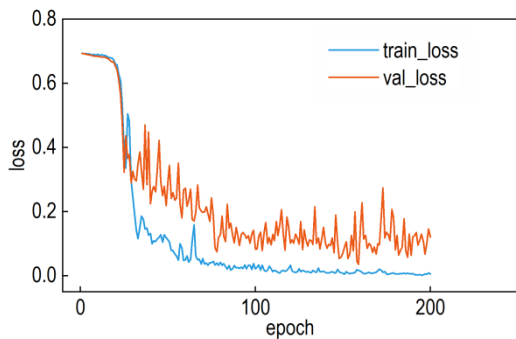


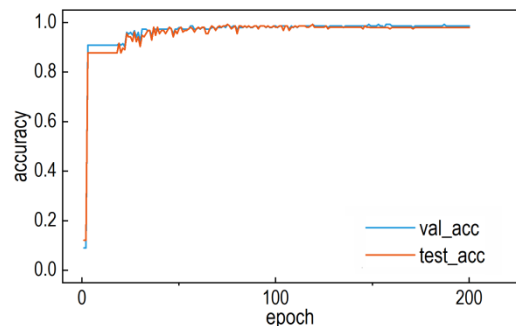
图8 原始数据与k-means聚类结果的PCA分布对比

Fig.8 PCA distribution comparison of original data and k-means clustering results

图 9a 可以看出,训练集损失值随着迭代次数的增加持续下降,表明模型在训练数据上拟合能力逐渐增强。然而,验证集损失值虽然整体也呈现下降趋势,但后期出现了较为明显的波动。这表明模型可能存在一定程度的过拟合现象,导致在未见过的数据上的泛化能力下降,但是从图 9b 中的准确率来看影响并不明显。图 9b 显示,尽管验证集的损失值出现波动,但模型的准确率仍然保持在较高水平。最终,CNN 模型在测试集上的准确率达到到了 98.1%,显示出该模型在爆炸声信号分类任务中具有较强的表现和可靠性。



a. training and validation loss curves

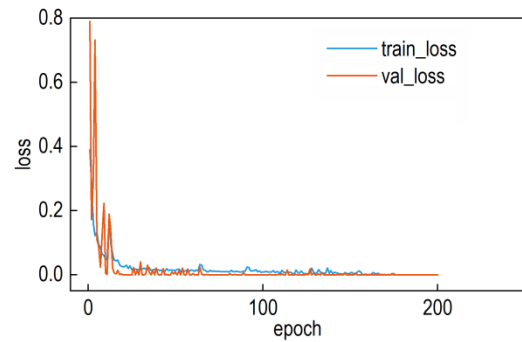


b. validation and testing accuracy curves

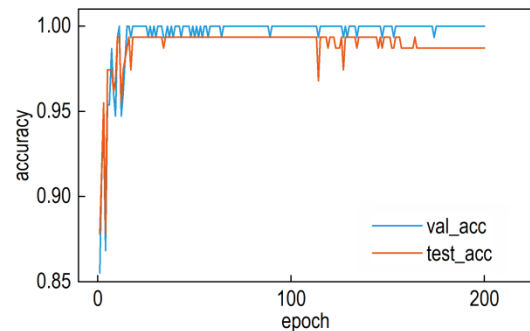
图 9 CNN 模型结果

Fig.9 Results of CNN model

从图 10a 可以看出,ViT 模型的训练集和验证集损失值随着训练轮次的增加迅速下降,并在大约 50 个训练轮次后趋于平稳,接近于零。这表明 ViT 模型在训练数据和验证数据上均拟合良好,能够有效捕捉信号的深层特征。此外,与 CNN 模型相比,ViT 模型的损失值曲线更加平滑,说明其训练过程中的波动较小,预测结果更加稳定可靠。图 10b 显示,ViT 模型在训练过程中的准确率整体较高,但验证集准确率在某些阶段出现了轻微的波动,表明可能存在一定的过拟合现象。尽管如此,ViT 模型在测试集上的准确率最终达



a. training and validation loss curves



b. validation and testing accuracy curves

图 10 ViT 模型结果

Fig.10 Results of ViT model

到了 98.7%。

为了缓解模型训练过程中可能出现的过拟合现象,尝试利用 DCGAN 来增加训练样本的多样性和数量。图 11 展示了数据扩增后,CNN 和 ViT 模型在验证集和测试集上的准确率变化情况,并与原始数据训练结果进行了对比分析。从图 11a 可以看出,引入扩增数据后,CNN 模型的验证集准确率相较于原始数据训练时有轻微的提升,达到了 98.4%。曲线整体更加平滑,表明数据扩增有效减少了训练过程中的波动,增强了模型在验证集上的泛化能力。图 11b 显示了数据扩增对 ViT 模型性能的改善。数据扩增后,ViT 模型的测试集准确率提升至 98.9%。尽管提升幅度有限,但在高准确率基础上的这一程度提升,证明数据扩增策略对模型性能的优化具有积极作用。此外,扩增数据的引入也使得测试集准确率曲线更加稳定,进一步验证了其对于缓解过拟合现象的有效性。

值得进一步探讨的是,本研究所使用的数据集涵盖了几种具有代表性的炸药类型,尽管其化学成分和爆炸特性各不相同,但传统机器学习和深度学习模型在当前数据条件下仍能较为准确地地区分爆炸与未爆炸

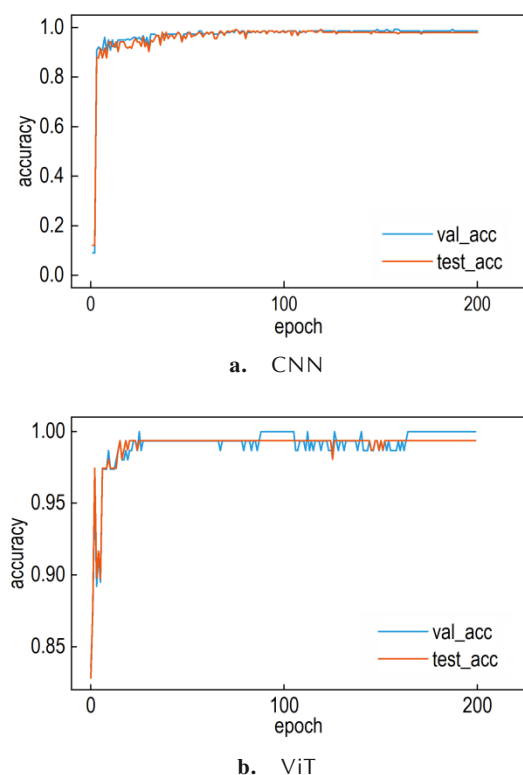


图 11 数据扩增后 CNN 和 ViT 模型的准确率对比

Fig. 11 Accuracy comparison of CNN and ViT models after data augmentation

事件。这在一定程度上表明,不同炸药爆炸时产生的声学信号中可能存在着一些共通的深层特征,而这些特征能够被机器学习模型有效地学习和提取。然而,由于尚未涵盖全部炸药类型,上述结论仍需要在更广泛的炸药种类和更大规模数据集上进行进一步验证,以确保模型在更复杂、多样的真实场景中保持可靠的判别能力。即进一步探究这些共通特征的物理本质和形成机制,以及它们在更广泛炸药类型上的普适性,将有助于构建更加鲁棒和泛化的爆炸事件智能判别系统。

3 结论

本研究基于机器学习技术,通过对爆炸声信号进行分析,提出了一种高效且精确的自动化判爆方案。主要结论如下:

(1) 实验结果表明,传统机器学习模型 RF、XGBoost、BPNN 和 SVM 能够有效提取一维声音特征中的信息,在原始数据集上的准确率均达到 99.5% 以上,k-means 聚类算法在原始数据集上的准确率也达到了 98.5%。这一结果可能与样本比例严重不平衡,

以及爆炸声音数据较少有关。

(2) 在采用 cGAN 生成了新的数据之后,发现随着训练次数的增长,RF、XGBoost、BPNN 和 SVM 在增强数据中的准确率也逐渐升高最终达到 100%,而 k-means 聚类算法随着 cGAN 训练次数的增加,准确率呈现先上升后下降的趋势。可能是随着训练次数的进一步增加,数据分布逐渐偏离原始结构,引入了噪声或异常模式。

(3) 深度学习模型 CNN 和 ViT 在原始数据集上的准确率分别为 98.1% 和 98.4%,且都发生了轻微的过拟合现象,而在 DCGAN 生成数据之后,准确率分别达到了 98.4% 和 98.9%。这可能是由于深度学习在处理小样本量时可能无法充分捕捉到数据内在的、本质的特征。此外,过拟合现象也可能对模型的泛化能力产生了一定限制。然而,总体来看,研究中所采用的机器学习方法均取得了较高的准确率,验证了其在爆炸声信号自动化判爆任务中的有效性。

进一步研究表明,尽管实验采用了多种不同类型的炸药样品,且模型训练过程中未将炸药类型作为标记信息,机器学习模型仍然表现出优异的爆炸与非爆炸事件识别能力。这一现象表明不同类型炸药在爆炸过程中可能存在共通的声学特征。后续实验将覆盖更广泛的炸药种类,对相关结论的普适性进行进一步的验证。在后续研究中,计划通过扩充数据集和融合多模态信息(如声学、视觉和力学特征),进一步提升模型的泛化能力和鲁棒性,从而为炸药撞击感度的智能化、安全性评估提供更加全面的技术支撑。

参考文献:

- [1] RUS D C, MIRON C, MICLEA O, et al. Computerized simulations and modelling for evaluation of ballistic and security parameters of explosives for civil use[C]//MATEC Web of Conferences. EDP Sciences, 2022, 373: 00047.
- [2] SALINI M, PAUNILA S. Recognizing and reducing risks from ammunition and explosives[J]. *The Journal of Conventional Weapons Destruction*, 2021, 25(1): 21.
- [3] 陈皓,徐洪涛,邹洪辉,等.典型炸药药柱撞击感度的试验研究[J]. *火炸药学报*, 2018, 41(2): 127-30+36.
CHEN Hao. XU Hong-tao, ZOU Hong-hu, et al. Experimental study on impact sensitivity of typical explosive grain[J]. *Chinese Journal of Explosives & Propellants*, 2018, 41(2): 127-30+36.
- [4] 国防科学技术工业委员会. GJB 772A-97: 炸药试验方法[S]. 北京: 中国标准出版社, 1997.
Commission of Science, Technology and Industry for National

- Defense. GJB 772A-97: Test methods for explosives[S]. Beijing: China Standard Press, 1997.
- [5] LEASE N, KLAMBOROWSKI L M, PERRIOT R, et al. Identifying the molecular properties that drive explosive sensitivity in a series of nitrate esters[J]. *The Journal of Physical Chemistry Letters*, 2022, 13(40): 9422-8.
- [6] MARRS F W, MANNER V W, BURCH A C, et al. Sources of variation in drop-weight impact sensitivity testing of the explosive pentaerythritol tetranitrate [J]. *Industrial & Engineering Chemistry Research*, 2021, 60(13): 5024-33.
- [7] SALOMONS E. Analytical model for sound of explosives and firearms[J]. *The Journal of the Acoustical Society of America*, 2024, 156(3): 2034-44.
- [8] MAN H, DESAI S. Acoustic analysis of explosions in high noise environment [C]//Unattended Ground, Sea, and Air Sensor Technologies and Applications X. SPIE, 2008, 6963: 108-115.
- [9] 费轶, 张晨, 张帆, 等. 提高撞击感度试验精确度的方法: CN201410145677.4[P], 2014.
FEI Tie, ZHANG Chen, ZHANG Fan, et al. Methods for Improving the Accuracy of Impact Sensitivity Tests, CN201410145677.4[P], 2014.
- [10] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *nature*, 2015, 521(7553): 436-44.
- [11] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. *Advances in neural information processing systems*, 2012, 25.
- [12] 徐科, 姚凌云, 姚静怡, 等. 基于改进VGG-16网络的交通声音事件分类方法研究[J]. *西南大学学报(自然科学版)*, 2023, 45(12): 145-56.
XU Ke, YAO Ling-yun, YAO Jing-yi, et al. Research on traffic sound event classification method based on improved VGG-16 network[J]. *Journal of Southwest University(Natural Science Edition)*, 2023, 45(12): 145-56.
- [13] TZANETAKIS G, COOK P. Musical genre classification of audio signals[J]. *IEEE Transactions on speech and audio processing*, 2002, 10(5): 293-302.
- [14] HUANG X, LI C, TAN K, et al. Applying machine learning to balance performance and stability of high energy density materials[J]. *Iscience*, 2021, 24(3).
- [15] SONG T, GUO F, JIANG H, et al. HGAT-BR: Hyperedge-based graph attention network for basket recommendation[J]. *Applied Intelligence*, 2023, 53(2): 1435-51.
- [16] GUO F, WEN Y S, FENG S Q, et al. Intelligent-ReaxFF: evaluating the reactive force field parameters with machine learning[J]. *Computational Materials Science*, 2020, 172: 109393.
- [17] XUE L Y, GUO F, WEN Y S, et al. ReaxFF-MPNN machine learning potential: a combination of reactive force field and message passing neural networks[J]. *Physical chemistry chemical physics*, 2021, 23(35): 19457-64.
- [18] ZENG J, CAO L, CHIN C H, et al. ReacNetGenerator: an automatic reaction network generator for reactive molecular dynamics simulations [J]. *Physical chemistry chemical physics*, 2020, 22(2): 683-91.
- [19] CORTES C. Support-Vector Networks [J]. *Machine Learning*, 1995, 20: 273-297.
- [20] COVER T, HART P. Nearest neighbor pattern classification [J]. *IEEE transactions on information theory*, 1967, 13(1): 21-7.
- [21] BREIMAN L. Random forests[J]. *Machine learning*, 2001, 45: 5-32.
- [22] MUSCAR L, TELEMBICI T, RUSU C. Deep learning-based sound classification algorithms for enhanced service robots audio capabilities [C]//2024 15th International Conference on Communications (COMM). IEEE, 2024: 1-6.
- [23] BRAUSCH L, HEWENER H, LUKOWICZ P. Classifying muscle states with one-dimensional radio-frequency signals from single element ultrasound transducers[J]. *Sensors*, 2022, 22(7): 2789.
- [24] 郑子强, 何得淮, 廖潇楠, 等. 基于音频的罪犯自杀危险性评估[J]. *四川大学学报(自然科学版)*, 2023, 60(6): 144-150.
ZHENG Zi-qiang, HE De-huai, LIAO Xiao-nan, et al. Audio based suicide risk assessment of criminals[J]. *Journal of Sichuan University(Natural Science Edition)*, 2023, 60(06): 144-150.
- [25] GRAVES A, MOHAMED A, HINTON G. Speech recognition with deep recurrent neural networks [C]//2013 IEEE international conference on acoustics, speech and signal processing. IEEE, 2013: 6645-6649.
- [26] DOSOVITSKIY A. An image is worth 16x16 words: Transformers for image recognition at scale[OL]. *arXiv preprint arXiv: 2010.11929*, 2020.
- [27] ATREY P K, HOSSAIN M A, EL SADDIK A, et al. Multimodal fusion for multimedia analysis: A survey [J]. *Multimedia systems*, 2010, 16: 345-79.
- [28] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[J]. *Advances in neural information processing systems*, 2014, 27.
- [29] SHORTEN C, KHOSHGOFTAAR T M. A survey on image data augmentation for deep learning[J]. *Journal of big data*, 2019, 6(1): 1-48.
- [30] FANG J, ZHANG W, MANG H, ZHOU Z. A Method for Generating Small Sample Data and Evaluating the Effectiveness of Combat Weapons Based on Conditional Adversarial Nets [C]//2023 2nd International Conference on Artificial Intelligence and Computer Information Technology (AICIT). IEEE, 2023: 1-6.
- [31] WU Q, CHEN Y, MENG J. DCGAN-based data augmentation for tomato leaf disease identification [J]. *IEEE access*, 2020, 8: 98716-98728.
- [32] ENGEL J, AGRAWAL K K, CHEN S, et al. Gansynth: Adversarial neural audio synthesis[OL]. *arXiv preprint arXiv: 1902.08710*, 2019.
- [33] PK M K, GURRAM M R, HOSSAIN A A, AMSAAD F. ARIMA-DCGAN Synergy: A Novel Adversarial Approach to Outlier Detection in Time Series Data [C]//NAECON 2024-IEEE National Aerospace and Electronics Conference. IEEE, 2024: 423-427.

Machine Learning Recognition of Impact Sensitivity of Energetic Materials Based on Acoustic Signals

ZHANG Bing-ru¹, LI Ming¹, WEN Yu-shi¹, GUO Feng², YU Shao-jun¹, JI Chun-liang³, LIN Cong-mei¹, HAO Li-xiao¹, HAN Yong¹, DENG Chuan¹, DAI Xiao-gan¹

(1. Institute of Chemical Materials, CAEP, Mianyang 621999, China; 2. School of Physical Science and Information Technology, Liaocheng University, Liaocheng 252059, China; 3. School of Mechatronical Engineering, Beijing Institute of Technology, Beijing 100081, China)

Abstract: To improve the accuracy and objectivity of explosives' impact sensitivity testing, machine learning methods were applied in the intelligent recognition of explosives' impact response acoustic signals. Experiments on mixed explosives were conducted using a drop-weight impact sensitivity test device, with an audio acquisition system synchronously capturing acoustic signals during the impact process. One-dimensional time domain and frequency domain features, such as maximum value and bandwidth, were extracted. Short-Time Fourier Transform (STFT) was employed to convert audio data into frequency spectrograms. Data augmentation for one-dimensional data was performed using a Conditional Generative Adversarial Network (cGAN), while a Deep Convolutional Generative Adversarial Network (DCGAN) was applied to enhance spectrogram data. Multiple machine learning models were employed for explosion classification, including Random Forest (RF), eXtreme Gradient Boosting (XGBoost), Back-propagation Neural Network (BPNN), Support Vector Machine (SVM), k-means clustering, Convolutional Neural Network (CNN), and Vision Transformer (ViT). Results demonstrate that RF, XGBoost, BPNN, and SVM achieve accuracy rates exceeding 99.5% on the real dataset and achieve 100% on the cGAN-augmented dataset. In contrast, k-means clustering initially reaches an accuracy of 98.5% on the real dataset, but accuracy shows a trend of increase followed by decline on augmented data. CNN and ViT achieve accuracies of 98.1% and 98.4% on the real dataset, respectively, and improved to 98.4% and 98.9% on augmented data. However, their performance remains slightly lower than traditional models due to the constraints of small sample sizes and minor overfitting issues. The proposed deep learning-based intelligent recognition method for explosives' impact sensitivity in this study achieved a high level of accuracy, demonstrating its reliability and practicality in the task of detecting explosive sound signals. At the same time, it effectively mitigates the subjectivity and inefficiency associated with traditional manual recognition methods, providing a reliable technical solution for the safety use of explosives.

Key words: impact sensitivity; machine learning; deep learning; data augmentation; convolutional neural network; acoustic signal recognition

CLC number: TJ55; TP18

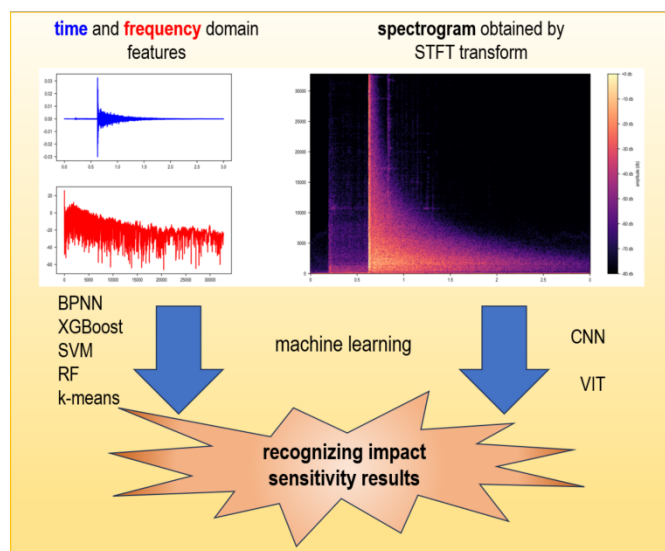
Document code: A

DOI: 10.11943/CJEM2024300

Grant Support: National Natural Science Foundation of China(No.12372342); Presidential Foundation of CAEP(YZJJZQ2023008)

(责编:姜梅)

图文摘要:



Acoustic data from impact sensitivity experiments were collected and augmented using deep learning techniques. Four traditional machine learning algorithms, one unsupervised learning algorithm, and two deep learning models were compared for their ability to classify explosion and non-explosion sounds. This approach overcomes the limitations of manual judgment and enhances the intelligence of impact sensitivity assessment.