

文章编号: 1002-1582(2026)04-0500-08

基于深度可分离卷积与通道注意力机制的 枪击残留物高光谱图像检测

王嘉驹, 李云鹏*, 包佳鑫, 武连全, 代雪晶, 张洪国
(中国刑事警察学院, 辽宁 沈阳 110854)

摘 要: 在安检与安防现场, 复杂纺织物背景下枪击残留物(GSR)的高光谱检测受光谱冗余、噪声干扰与样本不平衡等因素影响, 难以实现快速、无损、精准识别。为此, 构建了六类不同材质纺织物表面的GSR高光谱数据集, 并提出一种融合二维-三维深度可分离卷积与通道注意力机制的轻量化检测网络(Hybrid DSCDSENet)。方法采用三层级处理框架: 首先运用三维深度可分离卷积提取跨波段关联特征, 再通过二维深度可分离卷积细化空间结构, 最后引入通道注意力机制自适应增强有效谱段、抑制噪声与冗余信息, 并结合小波软阈值对输入数据进行预处理。实验结果表明, 所提模型在测试集上总体识别精度达到98.55%, 相比3D-Res-CNN与RSSAN等典型方法分别提升16.9%和4.91%, 在参数量与计算复杂度显著降低的同时, 具备更好的鲁棒性与场景泛化能力, 为复杂勘查环境中GSR的现场快速识别提供了可行的技术途径。

关 键 词: 光谱学; 深度可分离卷积; 通道注意力机制; 枪击残留物检测

中图分类号: O433.4

文献标识码: A

Hyperspectral gunshot residue detection based on depth-separable convolution and channel attention mechanism

WANG Jiaju, LI Yunpeng*, BAO Jiaxin, WU Lianquan, DAI Xuejing, ZHANG Hongguo

(Criminal Investigation Police University of China, Shenyang 110854, China)

Abstract: At the security inspection and security protection sites, the high-spectrum detection of gunshot residues (GSR) in complex textile backgrounds is affected by factors such as spectral redundancy, noise interference and sample imbalance, making it difficult to achieve rapid, non-destructive and accurate identification. Therefore, a high-spectrum data set of GSR is constructed on the surfaces of six different types of textile materials, and proposes a lightweight detection network (Hybrid DSCDSENet) that integrates two-dimensional-three-dimensional depth separable convolution and channel attention mechanism. This method adopts a three-level processing framework: first, three-dimensional depth separable convolution is used to extract cross-band correlation features; then, two-dimensional depth separable convolution is used to refine the spatial structure; finally, the channel attention mechanism is introduced to adaptively enhance the effective spectral bands, suppress noise and redundant information, and combine wavelet soft thresholding to preprocess the input data. Experimental results

收稿日期: 2026-03-04; 收到修改稿日期: 2026-05-11

基金项目: 国家自然科学基金青年科学基金(62305397); 公安部科技计划项目(2025JSYJC11); 沈阳市中青年科技创新人才支持计划项目(RC220488); 辽宁省“兴辽英才计划”项目(XLYC2403073); 中国刑事警察学院重点攻关项目(D2025004); 辽宁省应用基础研究计划项目(2022JH2/101300144); 辽宁省研究生教育教学改革研究项目(LNYJG2023316); 辽宁省教育科学“十四五”规划课题(JG22DB685)

作者简介: 王嘉驹(2002—), 男, 硕士研究生, 从事物证的智能识别方面的研究。3160046662@qq.com
李云鹏(1988—), 男, 副教授, 博士, 硕士生导师, 从事生物特征识别技术、现场物证识别技术、警用人工智能技术方面的研究。

* 通讯作者: lypciomp@126.com

show that the proposed model achieves a total recognition accuracy of 98.55% on the test set, which is 16.9% and 4.91% higher than typical methods such as 3D-Res-CNN and RSSAN, respectively. While significantly reducing the parameter quantity and computational complexity, it has better robustness and scene generalization ability, providing a feasible technical approach for the rapid on-site identification of GSR in complex investigation environments.

Keywords: spectroscopy; depth separable convolution; channel attention mechanism; gunshot residue detection

0 引言

枪击残留物 (Gunshot Residue, GSR) 包含火药、底火颗粒、武器金属碎屑等多类组分^[1], 是追溯射击行为、锁定涉案人员的核心微量物证。传统鉴定手段以胶带粘取、真空吸取^[2]完成样本采集, 依靠扫描电镜、质子激发 X 射线、等离子体质谱^[3]实现定性定量分析, 虽可解析弹药化学成分、区分弹药种类, 但操作流程繁琐、易造成微量残留物损耗, 无法实现大范围现场快速筛查。高光谱成像 (HSI) 可非接触同步采集可见光-近红外数百个窄波段信息, 构建空间-光谱一体化三维数据立方, 为 GSR 无损现场检测提供全新技术路线^[4]。已有研究验证了高光谱设备对织物表面射击残留物的成像识别能力: Deliot^[5]采用近红外传感器完成 GSR 可视化试验, Atwater^[6]借助多光谱设备依托织物光谱推算射击距离, 证实 HSI 可替代传统理化检验完成犯罪现场痕迹快速巡检^[7]。伴随人工智能技术发展, 基于高光谱的 GSR 智能识别逐步从实验室理论研究走向实战应用。

早期 GSR 高光谱识别多采用传统机器学习算法, 仅针对单一织物、短距离射击样本完成像素分类^[8], Głomb 搭建多织物基底 GSR 数据集, 对比 RX 异常检测与 SVM 分类效果^[9], 另有学者结合近红外高光谱与荧光标记区分弹药残留^[10]。但该方法依赖人工提取光谱特征, 需针对不同织物单独归一化处理, 面对多材质织物、光谱噪声、正负样本失衡的真实场景稳定性较差。实际案件中 GSR 多附着于棉、涤纶等粗糙织物表面, 痕量颗粒分布稀疏, 织物自身纹理光谱会形成强干扰^[11], 现有传统机器学习模型普遍识别精度偏低、泛化性能不足。深度学习具备端到端自动挖掘空谱深层特征的能力, 可缓解复杂背景干扰与样本不平衡难题, 已在高光谱分类任务中取得性能突破。Arun 等^[12]提出的基于光谱降维的 3D CNN 模型在数据集上取得了优异结果; Asker 等^[13]则结合了 2D 深度可分离卷积与压缩激励网络以兼顾效率与特征表达。然而, 这些研究多用于遥感地物识别, 无法适配 GSR 检测任务。遥感目标光谱波段数量少、样本分布均衡, 而织物 GSR 高光谱包含数百个连续窄波段, 存在严重光谱冗余与空谱耦合, 同时痕量残留

物像素占比低、样本不均衡, 对模型细粒度特征提取与抗干扰能力提出更高要求。

针对现有模型计算成本高、光谱冗余难以消除、痕量残留物特征提取效果差等问题, 本文构建轻量化网络 Hybrid DSC-DSENet, 融合 3D、2D 深度可分离卷积与通道注意力机制。网络分层提取空谱特征: 3D 深度可分离卷积解耦高维光谱耦合信息, 2D 深度可分离卷积细化残留物空间细节, 通道注意力自适应增强有效波段、压制噪声冗余。对比实验表明, 该模型精度、召回率均优于 3D CNN、Hybrid SN 等主流算法。本研究填补了多纺织物背景下枪击残留物智能检测空白, 为刑侦现场快速无损识别 GSR 提供理论与技术支撑。

1 实验方法

1.1 高光谱采集系统

实验采用 FigSpec IQ 便携式高光谱物证分析仪进行光谱采集, 如图 1 所示, 光谱范围为 400~1000nm, 光谱分辨率为 2.5nm, 共 300 个波段, 狭缝宽度为 25 μ m, 在视场范围内的图像分辨率为 1920 $\times$ 1920 像素, 曝光时间为 300ms。相机的两侧各有一个 50W 卤素光源, 与相机光轴呈 45° 夹角。实验样本的高光谱图像采集在暗室环境中进行, 通过精确调节镜头焦距以确保成像清晰度, 并优化光圈与曝光时间参数配置, 以保证样本光谱信息的完整性与准确性。




图1 高光谱采集设备

1.2 实验设计

实验以纺织物上的枪击残留物为研究对象, 选用黑色棉质短袖、黑色涤纶速干短袖、浅蓝色棉质短袖、靛蓝色涤纶衬衫、黑色警裤和蓝色长衬六种成衣, 每种成衣各取三件, 以整件衣物为靶材; 每种衣物均经预洗晾干后套置于木制人台上保持自然平整, 实验样本如表 1 所示。射击在室内弹道实验室进行, 使用 QSZ92G 式 9mm 半自动手枪, 子弹选用 9 $\times$ 19mm 巴拉贝鲁姆弹, 垂直瞄

准衣物胸前中心各实施单发射击，每种衣物分不同距离射击。击发后由佩戴无纤维手套的实验人员立即将衣物从人台上取下并封入预标识真空袋，防止二次污染，为后续高光谱成像分析提供样本。实验所用织物样本实物如图 2 所示，区域 1~6 展示了不同形态的残留物颗粒在高倍率下的细节。将保存的高光谱数据导入 envi 软件，采用 envi 软件手动选取每种织物上枪击残留物样本的感兴趣区域，最终获得共计 260588 个有效像素样本，其中背景类别样本 194704 个（占 74.7%），枪击残留物类别样本 65884 个（占 25.3%）。按照 6:4 的比例随机划分训练集与测试集，其中训练集包含 156353 个像素样本，测试集包含 104235 个像素样本。为确保样本平衡性，采用分层抽样策略为少数类分配更高权重。输入网络前，对高光谱数据立方体进行空间裁剪处理。基于高光谱相机分辨率及残留物颗粒的分布特性，将原始图像裁剪为不重叠的局部块，空间尺寸设置为 15×15 像素。

表 1 6 种射击残留物背景信息表

编号	材质
1	黑色棉织物(T恤)
2	黑色聚酯纤维(T恤)
3	浅蓝色棉织物(T恤)
4	浅蓝色聚酯纤维(T恤)
5	黑色混纺织物(长裤)
6	蓝色聚酯纤维面料(衬衫)




图 2 枪击残留物检测实验用织物样本

1.3 数据预处理

为了消除光谱相机暗电流，需要对采集的高光谱图像进行黑白校正。分别采集相机白板标定图像 R_{white} 和盖上相机盖后的全暗参考图像 R_{dark} ，然后对采集的原始图像 R_{raw} ，处理得到校正图像 R_{norm} ，用于后续分析。处理方法表示为

$$R_{\text{norm}} = \frac{R_{\text{raw}} - R_{\text{dark}}}{R_{\text{white}} - R_{\text{dark}}} \quad (1)$$

同时为解决高光谱数据采集过程中的噪声干扰问题，采用小波软阈值去噪方法^[21]。本研究采用 Daubechies-4 小波基进行 3 层分解，有效保留了光谱特征的边缘信息同时抑制噪声。设原始光谱信号为 $f(t)$ ，经过小波变换后得到小波系数 $W_{(j,k)}$

$$W_{(j,k)} = [f(t), \psi_{(j,k)}(t)] \quad (2)$$

式中， $\psi_{(j,k)}(t)$ 为小波基函数， j 和 k 分别表示尺度参数和平移参数。基于 Donoho-Johnstone 准则，设置自适应阈值

$$\lambda = \sigma \sqrt{2 \ln N} \quad (3)$$

式中 σ 为噪声标准差； N 为信号长度。软阈值函数定义为

$$\eta(W_{(j,k)}) = \begin{cases} \text{sign}(W_{(j,k)}) (|W_{(j,k)}| - \lambda), & |W_{(j,k)}| \geq \lambda \\ 0, & |W_{(j,k)}| < \lambda \end{cases} \quad (4)$$

1.4 识别模型构建

(1) 深度可分离卷积原理

传统卷积神经网络在处理高光谱影像等高维数据时，往往需要大量参数和计算量。例如三维卷积核需要同时在长、宽和光谱维度上进行滑动操作，不仅训练时间长，而且对计算资源需求较高。设输入特征图通道数为 c_F ，输出特征图通道数为 c_G ，卷积核尺寸为 $k \times k \times k$ ，空间维度大小为 $l_F \times w_F \times h_F$ ，则标准三维卷积的计算量为

$$\text{Cost}_{\text{standardconv}} = k^3 \cdot c_F \cdot c_G \cdot l_F \cdot w_F \cdot h_F \quad (5)$$

为解决标准卷积计算开销巨大的问题，MobileNet^[22]提出了一种轻量化卷积方式——深度可分离卷积，其框架如图 3 所示，其中图 3 (a) 为标准卷积结构图，图 3 (b) 为深度可分离卷积结构示意图。其核心思想是将标准卷积分解为两个步骤，从而在保持特征提取能力的同时显著减少参数数量和计算量。第一步是逐通道卷积，在不改变通道数的前提下，对输入的每个通道分别使用一个小的卷积核，独立提取各通道的空间特征。这一过程的计算量为

$$\text{cost}_{\text{DC}} = k^3 \cdot c_F \cdot l_F \cdot w_F \cdot h_F \quad (6)$$




图 3 标准卷积与深度可分离卷积结构

第二步是逐点卷积，使用 $1 \times 1 \times 1$ 卷积核在通道维度上进行线性组合，实现通道间的信息交互与融合，并决定最终输出特征图的数量。其计算量为

$$\text{Cost}_{\text{PC}} = c_G \cdot c_F \cdot l_F \cdot w_F \cdot h_F \quad (7)$$

因此,深度可分离卷积的总计算量为

$$\text{cost}_{\text{DSC}} = \text{cost}_{\text{DC}} + \text{cost}_{\text{PC}} = k^3 \cdot c_F \cdot l_F \cdot w_F \cdot h_F + c_G \cdot c_F \cdot l_F \cdot w_F \cdot h_F \quad (8)$$

与标准卷积相比,二者之比为

$$\frac{\text{Cost}_{\text{DSC}}}{\text{Cost}_{\text{standard conv}}} = \frac{1}{c_G} + \frac{1}{k^3} \approx \frac{1}{k^3} \quad (9)$$

当输出通道数 c_G 较大时,该比值近似为 $\frac{1}{k^3}$,

说明DSC在保持建模能力的同时能显著降低计算复杂度和参数量。这种通过空间特征提取与通道特征融合的分解方式,本质上是对标准三维卷积核的参数因式分解。它不仅能有效压缩模型规模、加速训练,还能保持对空谱联合特征的良好表达能力,因此在高光谱影像分类等计算密集型任务中具有重要应用价值。

(2) 通道注意力机制

DSENet是将深度可分离卷积(DSC)与通道注意力机制(SE)融合的一种改进模块,旨在增强高光谱图像分类中的通道相关性建模能力。通过DC(3×3)提取空间特征,再经PC(1×1)融合通道信息,在保持特征表达能力的同时显著降低计算量。SE模块^[23]如图4所示,压缩阶段对特征图执行全局平均池化(GAP),将每个通道的空间信息压缩为一个全局特征向量

$$z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (10)$$




图4 SE Net结构图

式中 $x_c(i, j)$ 为第 c 个通道的特征图; H 、 W 分别为特征图的高度与宽度; $z_c \in \mathbb{R}$ 为该通道的全局压缩特征。激励阶段通过两层全连接层(FC)与激活函数对压缩后的特征进行非线性变换,学习通道间的依赖关系并生成注意力权重

$$s = \sigma(W_2 \delta(W_1 z)) \quad (11)$$

式中 $W_2 \delta$ 与 $W_1 z$ 为全连接层权重矩阵; σ 为Sigmoid激活函数;输出 s 即为各通道的注意力权重。这种机制不仅提升了分类模型对关键特征的感知能力,也在模型参数几乎不增加的前提下,提高了整体网络的判别力与泛化性能。

(3) 网络整体架构

本文提出的Hybrid DSC-DSE Net模型采用分

层结构设计,主要由三维深度可分离卷积模块、二维深度可分离卷积模块、DSE注意力模块及全连接分类器构成。整体架构旨在实现对高光谱数据光谱特征与空间特征的协同高效提取,网络整体架构如图5所示。网络输入为尺寸 (B, L, C, W, H) 的高光谱图像块,首先经过一个标准3D卷积层进行初步映射,该层使用8个尺寸为 $(7, 3, 3)$ 的卷积核。随后串联三个3D-DSC模块,其深度可分离卷积核尺寸均为 $(7, 3, 3)$,各模块输出通道数依次为16、32、64。经三维卷积组处理后,输出特征张量尺寸为 $(B, 64, 300, 1, 1)$ 。通过重塑操作将其转换为二维结构 $(B, 128, 1, 1)$,以实现三维特征向二维空间的过渡。随后接入二维深度可分离卷积模块,该模块采用 3×3 卷积核进行空间特征细化,进一步建模局部上下文信息。核心的DSE注意力模块通过“挤压-激励”机制实现对关键通道的自适应增强,从而提升光谱-空间特征的判别能力。最后,特征经由全局平均池化与全连接层完成分类预测。




图5 Hybrid DSC-DSE Net整体架构示意

1.5 实验环境及参数配置

实验平台的操作系统为Window10, CPU为Intel Core i7-11800H、内存16GB, GPU为Nvidia GeForce RTX 1650、显存8GB。深度学习框架为PyTorch 2.1.0版本, CUDA版本为12.4。实验中优化器算法选取为Adam, 动量值为0.9, 学习率设定为0.001, 训练集、测试集按照6:4的比例随机进行分配, 共训练100个epoch。针对背景像素与GSR像素数量不均衡的问题, 本文在训练阶段采用加权交叉熵损失函数。设训练集中类别 c 的样本数为 n_c , 类别总数为 C , 训练样本总数为 N , 则类别权重设置为

$$w_c = \frac{N}{C \cdot n_c} \quad (12)$$

加权交叉熵损失函数表示为

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C w_c y_{ic} \log(p_{ic}) \quad (13)$$

式中, y_{ic} 表示样本 i 在类别 c 上的真实标签; p_{ic} 表示模型预测样本 i 属于类别 c 的概率。本文共获得260588个有效像素样本, 其中背景类别样本194704个, GSR类别样本65884个。按照上述公

式计算，背景类别权重约为 0.6692，GSR 类别权重约为 1.9780。网络结构在不同层级具体的输出形状与参数量如表 2 所示。

表 2 网络分层参数

网络层	输出维度	参数量
三维卷积	[B, 8, 300, 15, 15]	512
三维深度可分离卷积	[B, 16, 300, 7, 7]	1024
三维深度可分离卷积	[B, 32, 300, 3, 3]	2048
三维深度可分离卷积	[B, 64, 300, 1, 1]	4096
二维卷积	[B, 128, 1, 1]	8320
二维深度可分离卷积	[B, 128, 1, 1]	17792
DSE2D 特征模块	[B, 128, 1, 1]	16512
全连接层	[B, 2]	258

1.6 评价指标

在图像分类任务中，通常通过混淆矩阵 (Confusion Matrix) 来定义四种基本计数：真正类 (True Positive, TP)、假正类 (False Positive, FP)、假负类 (False Negative, FN) 和真负类 (True Negative, TN)。本研究虽不直接使用混淆矩阵作为主要评价手段，但借助其定义，可以清晰地表达以下三个关键指标：精确度 (precision, P)，其表示所有被预测为正类并且确实是正类的部分占所有分类器认为是正类的比例

$$P = \frac{TP}{TP + FP} \tag{14}$$

召回率 (Recall, R) 又称覆盖率，表示所有被预测为正类并且确实是正类的部分占所有确实是正类的比例

$$R = \frac{TP}{TP + FN} \tag{15}$$

F1 分数 (F1-score) 是精确率与召回率的调和平均，用以综合两者性能

$$F1 = 2 \times \frac{P \times R}{P + R} \tag{16}$$

2 结果与讨论

2.1 光谱曲线分析

为系统评估枪击残留物在不同纺织物背景下的光谱响应特性及小波软阈值去噪方法的有效性，本研究选取三类典型纺织物 (黑色涤纶、黑色混纺、蓝色聚酯纤维) 作为代表性样本，分别对比其原始 GSR 附着区域与经小波软阈值去噪处理后的光谱曲线。如图 6 所示，三类织物背景下的 GSR 原始光谱曲线均表现出典型的低反射特征，反射率普遍低于 0.25，且在整个波段范围内波动平缓，缺乏明显吸收峰。与之相比，三类背景材质的光谱曲线呈现显著高反射特性，尤其在 650~900nm

近红外区域形成宽幅反射平台，最高反射率超过 0.6。不同材质背景的光谱形态也存在明显差异：黑色涤纶背景在中波段的反射率呈缓升趋势，黑色混纺背景在 720nm 附近出现轻微吸收谷，而蓝色聚酯纤维背景则在 450~500nm 蓝光波段和 800~900nm 近红外波段分别形成反射峰。




图 6 三类织物背景上枪击残留物的原始与去噪光谱曲线对比

经小波软阈值去噪处理后，GSR 光谱曲线的噪声成分得到有效抑制，信号平滑度显著提升，同时关键光谱特征得以保留。如图所示，以黑色混纺背景为例，去噪后 GSR 曲线在 600~800nm 区间的标准差降低约 32%，信噪比提升约 4.7dB。此外，去噪处理增强了 GSR 与背景之间的光谱可分性，尤其在 750~950nm 波段，GSR 与背景的反射率差异进一步扩大，为后续分类模型提供了更具判别性的特征输入。

2.2 消融实验

枪击残留物在不同织物背景上通常表现出整体反射率低、光谱对比度弱，且光谱曲线随波长缓慢起伏的特征。为了在轻量化约束下尽可能提取其细粒度的光谱-空间特征，本文对传统高光谱分类网络进行三级结构改造：首先，在输入阶段引入三维深度可分离卷积 (3D DSC)，用于捕捉波段间连续的光谱纹理信息；随后，在各谱面上加入二维深度可分离卷积 (2D DSC)，以细化空间结构表达并进一步压缩模型参数；最后，采用动态通道注意力机制 (DSE 模块) 对特征通道进

行自适应重标定，其中与关键谱段相关的特征通道会获得更高权重。为进一步量化小波软阈值预处理对模型性能的影响，本文在完整模型基础上增加一组去除小波预处理的对照实验。该实验仅保留黑白校正步骤，不再对光谱信号进行小波去噪，其余网络结构、训练参数、损失函数和数据划分方式均与完整模型保持一致。为验证各改进模块对模型性能的具体贡献，本文设计了四组模型变体进行消融实验，结果如表 3 所示。

表 3 消融实验结果对比

	模块组成				评价指标		
	Wavelet	3D DSC	2D DSC	DSE NET	精确率/%	召回率/%	F1分数/%
1	—	—	—	—	98.55	98.75	98.65
2	—	—	—	×	89.63	94.14	91.83
3	—	×	×	—	90.10	93.06	91.56
4	×	—	—	—	96.38	97.02	96.70

实验结果如表 3 所示，完整模型在 Precision、Recall 与 F1-score 三项指标上均取得最佳表现，验证了 3D DSC、2D DSC 与 DSE Net 的协同作用。当去除 DSE Net 时，F1-score 与 Precision 分别下降至 91.83% 和 89.63%，说明通道注意力机制在降低误检与漏检方面不可或缺；当去除 2D DSC 和 3D DSC 模块时，将深度可分离卷积替换为标准卷积结构，Precision 与 F1-score 分别降至 90.10% 和 91.56%，表明细粒度空间纹理在复杂背景下仍然关键。由此可见，三种组件相互补充，在保持模型轻量化的同时显著提升了对枪击残留物的识别能力。

去除小波软阈值预处理后，模型 Precision、Recall 和 F1-score 分别下降至 96.38%、97.02% 和 96.70%，较完整模型 F1-score 降低 1.95 个百分点。该结果说明，原始高光谱数据中的随机噪声会削弱模型对 GSR 弱光谱差异的感知能力。小波软阈值处理能够在保留主要光谱形态的同时降低噪声波动，从而提升后续光谱特征提取的稳定性。

2.3 不同卷积核尺寸对模型性能的影响

为了评估卷积核尺寸在高光谱图像特征提取中的敏感性，以优化 Hybrid DSC-DSENet 网络的空谱建模能力。实验通过控制变量，分别采用 $3\times3\times3$ 、 $3\times3\times5$ 和 $3\times3\times7$ 三种卷积核尺寸训练模型，其余超参数均保持不变。所有实验均基于同一硬件平台及 PyTorch 2.1.0 框架实现，确保结果可比性。

卷积核尺寸直接影响三维深度可分离卷积（3D-DSC）模块的感受野与特征提取粒度。较小的核（ $3\times3\times3$ ）侧重于局部波段关联，计算效率高但可能忽略长程光谱依赖；较大的核（ $3\times3\times7$ ）

能捕获更广的谱段上下文，但会增加计算复杂度。本实验通过对比不同尺寸核的性能指标及资源消耗，旨在平衡模型精度与轻量化需求。实验结果如表 4 所示。随着卷积核的不断增大，模型的性能呈现轻微提升趋势：F1 分数从 98.51% 增至 98.65%，表明扩大光谱维度的覆盖范围有助于增强对关键谱段的识别能力。同时，参数量与 FLOPs 均无显著变化。实验结果表明模型所使用的大尺度卷积核结构的分类效果优于小卷积核残差结构。

表 4 不同卷积核尺寸下的性能对比

卷积核尺寸	精确率/%	召回率/%	F1分数/%	参数量	计算量
$3\times3\times3$	98.42	98.63	98.51	6.962	45.816
$3\times3\times5$	98.50	98.70	98.60	8.150	55.200
$3\times3\times7$	98.55	98.75	98.65	9.570	65.066

2.4 对比实验

为全面评估本文提出的 Hybrid DSC-DSENet 的性能优势，我们在相同实验设置下与五种具有代表性的高光谱图像分类网络进行了对比：经典的 3D-CNN^[24]、基于残差结构的 SSRN^[25] 和 3D-Res-CNN^[26]、混合光谱网络 HyBrid SN^[27] 以及基于注意力机制的 RSSAN^[28]。所有模型均使用相同的数据集（训练集与测试集比例 6:4）和优化器（Adam，学习率 0.001）进行训练，以确保公平比较。为保证对比实验的公平性，所有对比模型均采用相同的数据预处理流程、训练集/测试集划分方式、输入块尺寸、优化器、学习率、训练轮数及评价指标。同时，所有模型均采用相同的加权交叉熵损失函数和分层抽样策略，以排除类别不平衡处理方式差异对实验结果的影响。

实验结果如表 5 所示，参与对比的模型中，3D-CNN 与 SSRN 在复杂纺织物背景下表现不足，F1-score 分别仅为 68.87% 与 78.65%，显示其对高维光谱特征的学习能力有限。3D-Res-CNN 作为基于残差连接的改进模型，在 Precision、Recall 和 F1-score 指标上性能中等，但其参数量（20.500K）和计算成本（155.300 MFLOPs）相对较高，表明残差结构虽能提升特征传递效率，却未显著改善对 GSR 痕量特征的判别能力。HyBrid SN 和 RSSAN 的性能进一步显著提升，F1-score 分别达到 90.41% 与 95.35%，但模型复杂度过大，参数量分别达 12.374K 和 30.850K，难以满足轻量化部署需求。相比之下，本文提出的 Hybrid DSC-DSENet 在 Precision、Recall 与 F1-score 上分别取得 98.55%、98.75% 与 98.65% 的最优结果，且仅需 9.570K 参数与 65.066MFLOPs，体现出在保持轻量化的同时兼顾高精度与高效率的优势。

表 5 不同模型在数据集上的分类准确度

模型名称	精确率/%	召回率/%	F1 分数/%	参数量	计算量
3D-CNN	74.58	63.97	68.87	15.500	120.000
SSRN	83.26	74.52	78.65	25.800	200.047
HyBrid SN	86.06	95.23	90.41	12.374	95.020
3D-Res-CNN	81.65	62.55	70.84	20.512	155.325
RSSAN	93.64	97.37	95.35	30.850	250.147
Hybrid DSCDSE Net	98.55	98.75	98.65	9.570	65.066

2.5 材质独立划分下的泛化验证实验

为进一步验证模型对不同纺织物背景的泛化能力，除像素级随机划分实验外，本文进一步设计了按材质划分的独立验证实验。具体而言，以六类纺织物材质为分组单位，每次选取其中一类材质作为独立测试集，其余五类材质用于模型训练，重复进行六轮实验。该验证方式能够避免同一材质背景的像素同时出现在训练集和测试集中，从而更严格地评估模型对未知材质背景下 GSR 特征的识别能力。

表6给出了按材质划分条件下的模型识别结果。与随机像素划分条件下的结果相比，按材质独立划分后的各项指标有所下降，说明未知纺织物背景会增加模型识别难度。但模型在六类独立材质测试中的平均 F1-score 仍保持在 94% 左右，表明 Hybrid DSC-DSE Net 并非完全依赖特定背景材质纹理，而是能够提取具有一定稳定性的 GSR 光谱-空间特征。

表 6 按材质独立划分条件下的泛化验证结果

测试材质	精确率/%	召回率/%	F1 分数/%
黑色棉质	95.12	94.68	94.90
黑色涤纶	94.35	93.87	94.11
浅蓝棉质	93.64	92.98	93.31
浅蓝涤纶	92.87	92.15	92.51
黑色混纺	95.86	94.89	95.28
蓝色聚酯纤维	94.06	93.41	93.73
均值 ± 标准差	94.29 ± 1.02	93.66 ± 1.01	93.97 ± 1.00

2.6 多材质背景下的可视化识别效果

图 7 以热力图形式直观展示了 Hybrid DSCD-SENet 在六类典型织物背景上的枪击残留物识别效果，其中颜色深浅代表模型预测置信度，暖色调区域对应高置信度残留物预测，冷色调则对应背景或低置信度响应。从结果可以看出，在所有材质上，高置信度区域均准确集中于实际弹着点周围，形成轮廓清晰、连续完整的热力分布，显示出较高的定位精度与稳定性，所有非弹着点区域均未出现显著误响应，表明模型具备较低的误报率与优异的特异性。以上结果充分证明，Hybrid DSCDSENet 能够在多材质、多背景条件下实现对枪击残留物的精准、鲁棒识别，展现出良好的实用潜力。此外，热力图整体显示出极低的误报率，所有非弹着点区域均未出现显著热力响应，印证了模型优异的特异性和背景抑制能力。




图 7 Hybrid DSCDSE Net 在六种织物背景上的枪击残留物识别效果可视化图

3 结 论

本文针对枪击残留物在复杂织物背景下的高光谱识别难题,提出了融合3D与2D深度可分离卷积及通道注意力机制的轻量化网络Hybrid DSCDSE Net。先通过3D-DSC模块提取跨波段联系与局部谱纹理特征信息,随后在重塑后的谱面上增加2D-DSC模块细化空间结构,进一步压缩参数,接着嵌入DSE注意力模块,自适应增强关键谱段、抑制冗余信息与噪声干扰。实验结果表明,该模型在典型纺织物数据集上取得了98.55%的分类精度,F1分数为98.65%,召回率高达98.75%,显著优于传统HyBrid SN与RSSAN等模型,精度提升幅度分别达到12.49%和4.91%。在保证精度和鲁棒性的同时,模型参数量和计算复杂度大幅降低,展现了在便携式高光谱设备或边缘计算平台上实时应用的可行性。未来工作将进一步扩展数据集的材质与场景多样性,并探索弱监督与多模态融合方法,以提升模型的泛化能力和实战适应性。

参考文献:

- [1] Ledergerber T D, Barbosa L, Dalzell K, et al. Characterization and classification of organic gunshot residue from neat smokeless powder, cartridge cases, and the hands of known shooters[J]. *Forensic Chemistry*, 2025, 45: 100683.
- [2] Teng Y, Zhang K, Lv X, et al. Gunshots detection, identification, and classification: Applications to forensic science[J]. *Science & Justice*, 2024, 64(6): 625—636.
- [3] Medici V, Paone N, Pandarese G, et al. Active Thermography for Gunshot Residue (GSR) pattern estimation on textiles [C]//2023 IEEE International Workshop on Technologies for Defense and Security (TechDefense). Bari, Italy: IEEE, 2023: 104—109.
- [4] Bai L, Chen Z, Zhou L, et al. HSI classification: a comprehensive review, dataset, and future trends[J]. *Journal of the Indian Society of Remote Sensing*, 2025, 53(12): 3983—4004.
- [5] Deliot P, Corcelle B, Achard V, et al. Preliminary results to define an active multispectral imager for gunshot residues patterns visualization[C]//2012 4th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). Shanghai, China: IEEE, 2012: 1—4.
- [6] Christina S Atwater, Marie E Durina, John P Durina, et al. Visualization of gunshot residue patterns on dark clothing[J]. *Journal of Forensic Sciences*, 2006, 51(5): 1091—1095.
- [7] Giverts P, Sorokina K, Barash M, et al. The use of machine learning for the determination of a type/model of firearms by the characteristics on cartridge cases[J]. *Forensic Science International*, 2024, 358: 112021.
- [8] Pisantanaroj P, Tanpisuth P, Sinchavanwat P, et al. Automated firearm classification from bullet markings using deep learning[J]. *IEEE Access*, 2020, 8: 78236—78251.
- [9] Głomb P, Romaszewski M, Cholewa M, et al. Application of hyperspectral imaging and machine learning methods for the detection of gunshot residue patterns[J]. *Forensic Science International*, 2018, 290: 227—237.
- [10] 李兴, 孙振文, 刘耀. 法庭科学领域烟火药及其爆炸残留物检验研究进展[J]. *化学研究与应用*, 2022, 34(10): 2265—2273.
- Li Xin, Sun Zhengwen, Liu Yao. Research Progress on pyrotechnic substances and their explosive residues in the Field of Forensic Science[J]. *Chemical Research and Application*, 2022, 34(10): 2265—2273.
- [11] Shrivastava P, Jain V K, Nagpal S. Gunshot residue detection technologies—a review[J]. *Egyptian Journal of Forensic Sciences*, 2021, 11: 1—21.
- [12] Arun S A, Akila A S. Land-cover classification with hyperspectral remote sensing image using CNN and spectral band selection[J]. *Remote Sensing Applications: Society and Environment*, 2023, 31: 100986.
- [13] Asker M E. Hyperspectral image classification method based on squeeze-and-excitation networks, depthwise separable convolution and multibranch feature fusion[J]. *Earth Science Informatics*, 2023, 16(2): 1427—1448.
- [14] 魏林, 陈哲, 尹玉萍. 结合空-谱自注意力与多粒度特征提取的高光谱图像分类[J]. *激光与光电子学进展*, 2024, 61(24): 220—232.
- Wei Ling, Chen Zhe, Yin Yuping. Hyperspectral image classification combining spatial-spectral self-attention and multi-granularity feature extraction[J]. *Advances in Laser & Optoelectronics*, 24, 61(24): 220—232.
- [15] Sandler M, Howard A G, Zhu M, et al. Mobilenetv2: Inverted residuals and linear bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018: 4510—4520.
- [16] Rajendran T, Valsalan P, Amutharaj J, et al. Hyperspectral image classification model using squeeze and excitation network with deep learning[J]. *Computational Intelligence and Neuroscience*, 2022, 2022: 9430779.
- [17] Alfaifi R, Artoli A M. Human action prediction with 3D-CNN [J]. *SN Computer Science*, 2020, 1(5): 286.
- [18] Paoletti M E, Haut J M, Fernandez-Beltran R, et al. Deep pyramidal residual networks for spectral-spatial hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 57(2): 740—754.
- [19] Li W, Chen H, Liu Q, et al. Attention mechanism and depthwise separable convolution aided 3DCNN for hyperspectral remote sensing image classification[J]. *Remote Sensing*, 2022, 14(9): 2215.
- [20] Roy S K, Krishna G, Dubey S R, et al. HybridSN: Exploring 3-D - 2-D CNN feature hierarchy for hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 17(2): 277—281.
- [21] Chhapariya K, Ientilucci E J, Buddhiraju K M, et al. A spectral-spatial classification network for hyperspectral images using a residual attention network[C]//2023 13th Workshop on Hyperspectral Imaging and Signal Processing: Evolution in Remote Sensing (WHISPERS). Athens, Greece: IEEE, 2023: 1—5.