

毫米波成像威胁目标分类算法对比研究

修素朴¹, 牟光臣², 闫雷兵¹, 洪国庆²

(1. 河南工学院 电子信息工程学院, 河南 新乡 453003; 2. 河南工学院 理学部, 河南 新乡 453003)

摘要: 为提高毫米波成像隐匿威胁目标识别的准确性和推理速度, 构建了基于 CI 物理模型的四类威胁目标数据集。并通过实验对 KNN、RF 及 CNN 三种算法的性能进行了比较。实验结果表明: 在分类准确性方面, CNN 算法以 90% 的 F1 分数显著优于 RF 算法 (86%) 与 KNN 算法 (82%); 在推理速度方面, CNN 算法单样本处理时间仅 3.5 ms, RF 算法为 63.1 ms, KNN 算法为 38.5 ms。CNN 算法在毫米波成像威胁目标分类任务中准确性与推理速度较高, 可为安检场景提供有效技术支撑。

关键词: 威胁目标分类; CI; KNN; RF; CNN

中图分类号: TN918

文献标志码: A

文章编号: 2096-7772-(2025)05-0019-04

0 引言

毫米波 (30—300 GHz) 成像作为新兴的无线电成像技术, 凭借其亚厘米级空间分辨率、强穿透特性、非电离辐射安全性以及多模态工作能力等显著优势^[1-2], 在安全检测、无损检测等领域获得广泛应用^[3-5]。然而, 因其图像信噪比低、分辨率差、伪影重, 隐匿目标细节易被淹没, 成像效果不佳。合成孔径雷达^[6-7]与相控阵雷达^[8]需逐点或多通道扫描, 相位校准复杂、硬件庞大, 成像耗时需数十毫秒; 太赫兹多元高斯异常检测^[9]因受扫描机制限制, 也难达安检通道毫秒级要求。为了提高检测的准确性和即时性, 可以采用机器学习和深度学习算法对目标进行实时分类检测。

机器学习和深度学习需要大量数据样本, 但数据样本获取成本较高, 本文采用了一种利用编码孔径计算成像 (Coded-Aperture Computational Imaging, CI) 的物理模型, 该模型基于计算机辅助设计目标仿真生成高保真毫米波数据样本, 无需物理原型即可实现训练数据集的规模化构建。基于该数据集, 本文将通过实验, 比较机器学习算法中典型的 K-近邻

(K-Nearest Neighbor, KNN)、随机森林 (Random Forest, RF) 以及深度学习算法中经典的卷积神经网络 (Convolutional Neural Network, CNN) 的威胁目标实时分类性能, 为毫米波成像安检提供兼顾高精度与毫秒级响应的最优技术路径。

1 数据集构建

本文针对“手榴弹、枪支、刀具、剪刀”四类隐匿威胁目标构建了基于 CI 物理模型和仿真威胁目标数据集。该数据集通过混合增强策略提升了样本多样性, 共生成 3255 例有效样本, 并按 7 : 3 比例划分为训练集 (2655 例) 与独立测试集 (600 例)。

为保证模型评估的统计可靠性, 训练阶段统一采用五折交叉验证: 训练数据集被随机划分为五份互斥子集, 每轮取其中四份用于训练, 占总数据量的 80%, 剩余一份作为验证集, 占 20%, 循环五次以确保每一子集均有一次机会充当验证角色。该策略既保持了充足的训练样本, 又提供了独立且稳定的性能估计, 为后续 KNN、RF 与 CNN 三种算法的全面对比奠定了坚实的数据基础。

收稿日期: 2025-03-12

基金项目: 国家自然科学基金项目 (12301149); 河南省科技厅科技攻关项目 (222102210212)

第一作者简介: 修素朴 (1985—), 男, 河南新野人, 讲师, 博士, 主要从事电子信息技术应用研究。

通信作者简介: 牟光臣 (1970—), 男, 河南新乡人, 教授, 硕士, 主要从事电子通信技术应用研究。

2 威胁目标分类算法

2.1 K-近邻 (KNN)

(1) 算法原理

KNN 算法假设相似样本在特征空间中距离相近, 分类决策通过统计测试样本周围 K 个最近邻训练样本的多数类别实现^[10]。最常见的距离度量是欧氏距离, 其公式为:

$$D(a, b) = \sqrt{\sum_{i=1}^N (b_i - a_i)^2} \quad (1)$$

式中: a 和 b 为 N 个样本中的两个数据集。

(2) 数据处理

首先, 将 CI 物理模型生成的图像统一缩放至 150×150 像素, 随后按 RGB 三通道顺序展开为 67,500 维像素级特征向量。采用 StandardScaler 对各向量执行零均值、单位方差标准化。该预处理流程覆盖全部 2655 幅训练图像, 并为每幅图像赋予对应的威胁类别标签, 最终形成特征-标签对作为 KNN 模型的输入。

(3) 参数选择

K 值的选择对 KNN 算法的分类性能具有显著影响^[11]。为确定最优参数, 本文基于欧氏距离度量, 在毫米波数据集上评估 K 值与分类错误率的关系。采用五折交叉验证计算各 K 值对应的平均分类错误率, 实验结果如图 1 所示。误差曲线呈现典型的 U 型分布, 验证了模型复杂度随 K 值增加的演变规律: 当 $K < 20$ 时, 错误率随 K 减小而陡升; 当 $K \in [20, 50]$ 时, 平均错误率稳定在 0.53 ± 0.03 的低位区间 ($K=26$ 时, 错误率最小); 当 $K > 50$ 时, 错误率呈单调上升趋势。故确定 $K=26$ 为最优参数。




图 1 K 值与平均错误率的关系图

2.2 随机森林 (RF)

(1) 算法原理

RF 算法是一种集成学习方法, 通过组合多个决

策树来完成分类或回归任务, 从而提高模型的准确性和鲁棒性^[12]。在 RF 算法中, 不同决策树之间没有任何相关性。为了进一步降低模型的方差, RF 算法引入了随机性, 即在构建每个决策树时使用随机选择的特征子集, 这样既能够减少过拟合的风险, 也能够提高模型的泛化能力。

(2) 数据处理

RF 数据处理方法同 KNN 数据处理方法相同。

(3) 参数选择

RF 算法的性能受决策树数量的影响显著。本文通过固定随机森林模型的树深度与节点分裂准则, 在毫米波成像数据集上系统实施决策树数量参数遍历实验。采用五折交叉验证评估分类误差均值, 实验结果如图 2 所示。随着决策树数量的增加, 模型平均错误率呈现先快速下降后逐渐饱和的趋势。具体而言, 当决策树数量达到约 50 棵时, 错误率降至较低水平, 且进一步增加树的数量对性能提升有限。基于上述分析, 并综合考虑计算效率与模型性能的平衡, 本文确定最优决策树数量为 50。




图 2 决策树数量与平均错误率的关系图

2.3 卷积神经网络 (CNN)

(1) 架构设计

CNN 算法模型结构如图 3 所示。该模型包含 5 个卷积层和两个全连接层。卷积层 1 至卷积层 5 中的滤波器数量分别为 32、64、128、256 和 512。每个卷积层后面都有一个 ReLU 激活函数和一个最大池化层。在最大池化层 5 之后数据被展平, 并通过两个分别包含 1,024 个和 512 个神经元的全连接层进行传递。输出层使用 Softmax 激活函数进行预测。在训练过程中, 选择分类交叉熵作为损失函数, 并使用 Adam 优化器进行模型优化。

(2) 数据处理

CNN 模型直接接收来自 CI 物理模型生成并统一缩放至 150×150 像素的图像作为输入, 无需进行手工特征提取、复杂的标准化等预处理步骤。




图3 CNN 算法模型的结构图

(3) 训练配置

在深度学习模型训练中, 损失函数与优化算法的合理选择对模型的收敛速度与泛化能力起着决定性作用。针对分类任务, 研究者常采用分类交叉熵损失函数作为目标函数, 并结合 Adam 优化器进行模型优化, 以实现高效且稳定的模型训练^[13]。

其中, 分类交叉熵损失函数的定义如下:

$$L(y, \hat{y}) = -\sum_i y_i \log(\hat{y}_i) \quad (2)$$

式中: y 为真实标签向量, $\hat{y}$ 为模型的预测输出向量。

Adam 优化器的参数更新规则可分解为以下步骤:

$$m \leftarrow \beta_1 m + (1 - \beta_1) \nabla L \quad (3)$$

$$v \leftarrow \beta_2 v + (1 - \beta_2) (\nabla L)^2 \quad (4)$$

$$\hat{m} = \frac{m}{1 - \beta_1^t} \quad (5)$$

$$\hat{v} = \frac{v}{1 - \beta_2^t} \quad (6)$$

$$\theta \leftarrow \theta - \alpha \frac{\hat{m}}{\sqrt{\hat{v}} + \epsilon} \quad (7)$$

式中: ∇L 表示分类交叉熵损失函数 L 的梯度, m 和 v 分别为梯度的一阶矩估计和二阶矩估计, β_1 和

β_2 为衰减率, α 为学习率, t 为当前迭代次数。 ϵ 为一常数, 作用为稳定数值。

3 实验设置与评估指标

3.1 实验环境

实验环境配置如表 1 所示, 包括硬件、软件和依赖库。

表 1 实验环境

要素	训练配置	测试配置
硬件	NVIDIA GRID M60-8Q	Intel Core
	GPU (Pascal 架构, 8GB 显存)	i5-12500H CPU, 16GB DDR4 RAM
软件	TensorFlow 2.8.0 + Keras 2.8.0	Windows 11 22H2
依赖库	Scikit-learn 1.0.2, CUDA 11.6	Python 3.9, NumPy 1.22.3

3.2 评估指标

针对四类威胁目标分类任务的特性和实时性要求, 本文选取以下核心评估指标进行多维度性能实验:

(1) 精确率 (Precision): 正确预测为正例的样本占所有预测为正例样本的比例。

(2) 召回率 (Recall): 正确预测为正例的样本占所有真实正例样本的比例。

(3) F1 分数 (F1-score): 精确率与召回率的调和平均值 ($F1 = 2 * Precision * Recall / (Precision + Recall)$)。该指标更平衡且对极端值敏感, 是衡量分类器整体准确性的重要指标。

(4) 推理速度 (Inference Speed): 处理单个测试样本所需时间 (ms/样本), 是评估实时性的关键指标。测试基于测试集的 600 个样本进行。

4 结果分析

通过实验, 我们得出了评估指标的各项数据, 在对这些数据进行分析的基础上, 对 KNN、RF 和 CNN 三种分类算法的准确性和推理速度进行分析。

4.1 分类准确性

三种算法的分类准确性分别如表 2、表 3、表 4 所示。从表中可以看出 CNN 以 90% 的 F1 分数显著领先于 RF 的 86% 和 KNN 的 82%, 其优势在刀具和剪刀类别尤为突出。刀具召回率 97% 显著高于 RF 的 87% 与 KNN 的 81%, 表明 CNN 对刀具特征的捕捉能力极强; 剪刀精确率 98% 高于 RF 的 90% 和 KNN

的 89%，显示 CNN 对剪刀的误判率最低。

表 2 KNN 算法分类准确性分析

种类	精确率	召回率	F1 分数	支持数据数
手榴弹	0.80	0.86	0.82	146
枪支	0.84	0.78	0.80	156
刀具	0.78	0.81	0.79	168
剪刀	0.89	0.88	0.88	130
平均值	-	-	0.82	-

表 3 RF 算法分类准确性分析

种类	精确率	召回率	F1 分数	支持数据数
手榴弹	0.87	0.88	0.87	146
枪支	0.90	0.84	0.86	156
刀具	0.81	0.87	0.83	168
剪刀	0.90	0.89	0.89	130
平均值	-	-	0.86	-

表 4 CNN 算法分类准确性分析

种类	精确率	召回率	F1 分数	支持数据数
手榴弹	0.91	0.88	0.89	146
枪支	0.91	0.86	0.88	156
刀具	0.88	0.97	0.92	168
剪刀	0.98	0.91	0.94	130
平均值	-	-	0.90	-

4.2 推理速度

KNN、RF 和 CNN 三种算法的推理速度比较如图 4 所示。该柱状图直观反映了三种算法在实时性上的差异。CNN 速度为 3.5 ms/ 样本，仅为 KNN 的 9% (38.5 ms/ 样本) 和 RF 的 5.5% (63.1 ms/ 样本)。由于 KNN 和 RF 需处理 67,500 维像素特征向量，其中像素提取与展平预处理需花费较多时间；RF 额外受限于 50 棵决策树的串行投票机制，耗时更多。而 CNN 是直接对图像进行处理。




图 4 KNN、RF 和 CNN 三种算法的推理速度比较图

综上所述，从准确性方面来说 CNN 在四类目标中 F1 分数最高，推理速度能满足毫秒级实时检测需求。

5 结束语

本文基于 CI 物理模型构建的低成本、高保真数据集，系统比较了 KNN、RF 与 CNN 算法在毫米波成像隐匿威胁目标分类中的性能。实验结果表明，CNN 算法在准确性和推理速度上均显著优于 KNN 和 RF，确立了其在毫米波即时安检系统中的工程应用优势。后续工作将围绕轻量化 CNN 架构设计、迁移学习及数据增强策略开展，以进一步提升模型的现场适应性。

参考文献：

[1] 蒋留兵, 黄乾超, 车俐. 近场毫米波雷达非视距全息成像算法[J]. 火力与指挥控制, 2025, 50(1): 33–40.

[2] 车蕴佳, 张彦敏, 王运华, 等. 针对非稳定运动平台的毫米波雷达三维成像优化算法[J]. 中国海洋大学学报(自然科学版), 2024, 54(12): 120–129.

[3] 杨茹冰, 朱莉, 王玺昊. 毫米波亚毫米波成像在人体检测中的研究综述[J]. 微波学报, 2023, 39(S1): 318–323.

[4] 高炳西, 胡广骁, 夏禹, 等. 国内民航领域毫米波人体成像安检设备应用现状研究与展望[J]. 中国安全防范技术与应用, 2022(Z2): 11–17.

[5] 叶学义, 韩卓, 蒋甜甜, 等. 多尺度反向校正增强和无损下采样的毫米波图像目标检测方法[J]. 电子测量与仪器学报, 2025, 39(4): 50–61.

[6] WU S, DING L, LI P, et al. Millimeter-wave SAR sparse imaging with 2-D spatially pseudorandom spiral-sampling pattern[J]. IEEE Trans Microwave Theory Tech, 2020, 68(11): 4672–4683.

[7] HIEN P, HONG I. Millimeter wave SAR imaging denoising and classification by combining image-to-image translation with ResNet[J]. IEEE Access, 2023, 11: 70203–70215.

[8] 袁孟北, 晋良念. 车载毫米波 FMCW SAR 扩展目标聚焦成像方法[J]. 雷达科学与技术, 2023, 21(6): 689–696.

[9] LU S, LI S. Fast fmcw terahertz imaging for in-process defect detection in press sleeves for the paper industry and image evaluation with a machine learning approach[J]. Sensors, 2021, 21(19): 1–19.

[10] 李泽一, 王攀. 基于代价敏感度的改进型 K 近邻异常流量检测算法[J]. 南京邮电大学学报, 2022, 42(2): 85–92.

[11] 刘家玉, 韩军, 陈宝文. 基于 KNN 信道识别算法的无前后缀频域均衡技术[J]. 计算机测量与控制, 2023, 31(1): 174–180.

[12] 穆海蓉, 丁丽萍, 宋宇宁, 等. DiffPRFs: 一种面向随机森林的差分隐私保护算法[J]. 通信学报, 2016, 37(9): 175–182.

[13] SHARMA R, HUSSUNG R, KEIL A, et al. Coded-aperture computational millimeter-wave image classifier using convolutional neural network[J]. IEEE Access, 2021, 9: 119830–119844.

(下转第 66 页)

Basic Connotation, Realistic Patterns, and Optimization Paths of Visualized Communication in College Ideological and Political Education under the New Media Environment

ZHANG Liyuan¹, LOU Jiaping²

(1. Department of Teacher Work of Party Committee, Henan Normal University, Xinxiang 453007, China;

2. School of Marxism, Henan Normal University, Xinxiang 453007, China)

Abstract: In the new media era, images, as a carrier of ideological communication, are increasingly becoming an important source of knowledge and information for people. Ideological and political education in colleges and universities uses images as a medium to carry out ideological propaganda for college students through symbols, narratives, empathy and demonstrations, which has a good ideological and political education effect. Faced with the diversified, diverse and changeable development trend of college students' ideology and culture in the new era, it is urgent to optimize the path of image communication of ideological and political education in colleges and universities. To this end, we can promote the widespread implementation of image communication of ideological and political education in colleges and universities by strengthening the foundation of image representation, enhancing the ability of image narrative, constructing scenes of image empathy and improving the skills of image demonstration, so as to promote the full, all-round and whole-process education of colleges and universities, and effectively implement the important task of cultivating morality and cultivating people.

Key words: new media era; ideological and political education in colleges and universities; image communication

(责任编辑 杨文忠)

(上接第 22 页)

Comparative Study of Classification Algorithms for Threatening Objects in Millimeter-Wave Imaging

XIU Supu¹, MU Guangchen², YAN Leibing¹, HONG Guoqing²

(1. School of Electronic and Information Engineering, Henan Institute of Technology, Xinxiang 453003, China;

2. Department of Science, Henan Institute of Technology, Xinxiang 453003, China)

Abstract: To enhance the accuracy and inference speed of concealed threat object recognition in millimeter-wave imaging, a four-category threat object dataset was constructed using a Coded-Aperture Computational Imaging (CI) physical model. A comparative experiment was conducted to evaluate three classification algorithms: K-Nearest Neighbors (KNN), Random Forest (RF), and Convolutional Neural Network (CNN). The results demonstrate that: For classification accuracy, CNN achieves a significantly superior F1-score of 90%, outperforming RF (86%) and KNN (82%); Regarding inference speed, CNN requires only 3.5 ms per sample, compared to 63.1 ms for RF and 38.5 ms for KNN. The CNN algorithm exhibits high accuracy and computational efficiency in millimeter-wave threat object classification, serving as a reliable solution for security screening applications.

Key words: threat target classification; CI; KNN; RF; CNN

(责任编辑 王磊)