

基于GADF与MobileViT-RMF的网络入侵检测模型

刘泽晋^{1,3}, 赵利辉^{1*}, 刘诗涵¹, 董和磊^{2,3}

(1. 中北大学 软件学院, 山西 太原 030051; 2. 中北大学 半导体与物理学院, 山西 太原 030051;

3. 中北大学 微纳器件与系统教育部重点实验室, 山西 太原 030051)

摘要: 针对现有基于流量图像化的网络入侵检测方法存在时序关联表达不足、特征表征能力有限以及轻量化模型检测精度受限等问题, 提出一种融合格拉姆角差场(Gramian Angular Difference Field, GADF)与残差多粒度聚焦模块(Residual Multi-grain Focus, RMF)的轻量化网络入侵检测模型MobileViT-RMF。该方法首先将网络流量的一维特征序列映射为具有时空关联性的二维GADF图像, 以增强流量演化信息和类别差异特征的表达能力; 随后在MobileViT轻量化骨干网络中嵌入RMF模块, 通过多粒度特征聚焦机制强化局部关键信息提取与全局上下文建模, 从而提升模型对复杂流量图像的判别能力。围绕CICIDS2017和UNSW-NB15两个公开数据集开展了实验验证。实验结果显示, 所提模型在CICIDS2017数据集上的检测准确率达到99.75%, 较基线模型MobileViT_V3_xxs提高2.74个百分点; 在UNSW-NB15数据集上的峰值准确率达到99.89%, 体现出较好的跨数据集检测性能。研究结果表明, 将GADF流量图像表示与RMF特征增强机制相结合, 能够在保持模型轻量化特征的同时, 提高网络流量图像的代表质量和分类性能, 可为轻量化网络入侵检测模型的设计提供参考。

关键词: 入侵检测; 轻量化网络; 图像分类; MobileViT

中图分类号: TP393.08 文献标识码: A doi: 10.62756/jnuc.issn.1673-3193.2025.06.0007

引用格式: 刘泽晋, 赵利辉, 刘诗涵, 等. 基于GADF与MobileViT-RMF的网络入侵检测模型[J]. 中北大学学报(自然科学版), 2026, 47(2): 215-225.

LIU Zejin, ZHAO Lihui, LIU Shihan, et al. Network intrusion detection model based on GADF and MobileViT-RMF[J]. Journal of North University of China(Natural Science Edition), 2026, 47(2): 215-225.

Network Intrusion Detection Model Based on GADF and MobileViT-RMF

LIU Zejin^{1,3}, ZHAO Lihui^{1*}, LIU Shihan¹, DONG Helei^{2,3}

(1. School of Software, North University of China, Taiyuan 030051, China;

2. School of Semiconductor and Physics, North University of China, Taiyuan 030051, China;

3. Key Laboratory of Micro-Nano Devices and Systems, Ministry of Education, North University of China, Taiyuan 030051, China)

Abstract: A lightweight network intrusion detection model, termed MobileViT-RMF, was proposed to address several limitations in existing traffic-visualization-based intrusion detection methods, including insufficient representation of temporal correlations in traffic data, limited feature characterization capability, and restricted

收稿日期: 2025-06-12

基金项目: 国家自然科学基金面上项目(52178825)

作者简介: 刘泽晋(2000—), 男, 硕士生, 主要从事网络测试与网络安全方面的研究。

* 通信作者: 赵利辉(1979—), 男, 副教授, 博士, 主要从事网络测试与网络安全方向的研究。E-mail: leehwi@nuc.edu.cn。

detection accuracy under lightweight model constraints. The proposed method combined the Gramian Angular Difference Field (GADF) with a Residual Multi-grain Focus (RMF) module to improve both traffic representation and feature extraction. Firstly, one-dimensional network traffic feature sequences were converted into two-dimensional GADF images with spatiotemporal correlations, so that the evolutionary characteristics of traffic behavior and the discriminative differences among traffic categories could be more effectively preserved in the image space. On this basis, the RMF module was embedded into the lightweight MobileViT backbone to strengthen local key-feature extraction and global contextual modeling through a multi-granularity feature focusing mechanism, thereby the discriminative capability of the model for complex traffic images was enhanced. Experimental validation was conducted on the CICIDS2017 and UNSW-NB15 public datasets. The proposed model achieves a detection accuracy of 99.75% on CICIDS2017, which is 2.74 percentage points higher than that of the baseline MobileViT_V3_xxs model. On UNSW-NB15, the peak accuracy reaches 99.89%, indicating favorable cross-dataset detection performance. These findings suggest that the combination of GADF-based traffic image representation and RMF-based feature enhancement can improve the representation quality and classification performance of network traffic images while preserving the lightweight nature of the model. The proposed approach provides a feasible idea for the design of lightweight network intrusion detection models.

Key words: intrusion detection; lightweight network; image classification; MobileViT

0 引 言

随着 5G 与物联网技术的规模化部署,全球联网设备数量已突破 289 亿台^[1],根据 Nexusguard^[2]《2024 年全球分布式拒绝服务攻击趋势白皮书》,2023 年全球 DDoS 攻击峰值达到 700 Gbit/s 流量吞吐量,并发冲击突破 8×10^7 数据包/s(pps),较 2021 年最高纪录 (580 Gbit/s) 激增 20.7%。与此同时,加密协议的普及使网络流量加密率超过 83%^[3],传统基于人工特征工程的入侵检测系统 (Intrusion Detection System, IDS) 在密文环境下逐渐失效。面对海量高维流量数据与未知攻击模式的挑战,研究者开始探索基于图像化与深度学习的检测范式,通过将网络流量转换为二维图像,并利用卷积神经网络 (CNN) 的视觉特征提取能力实现高效分类^[4]。

在基于图像的入侵检测技术演进中,网络流量转换图像的方法与深度检测模型架构是两大核心研究领域^[5]。在图像转换层面,现有方法可分为两类:1) 基于原始字节的视觉重构方法,Demmese 等^[6]直接将字节流重塑为二维图像以保留完整信息,但生成的噪声模式显著降低了模型收敛效率;2) 基于统计特征的映射技术,如 Pham 等^[7]通过线性编码流量特征 (持续时间、字节数等) 生成灰度图像,虽简化了特征工程,但丢失了数据包级的细粒度信息;Attack 等^[8]进一步引入协议标志位的 RGB 通道映射,虽增

强协议类型区分度,却因人工特征选择导致跨场景泛化能力受到限制。上述方法普遍面临时空信息割裂与视觉模式模糊的双重困境,制约了后续检测模型的性能上限。

在检测模型层面,研究者尝试通过不同架构平衡精度与效率:刘等^[9]采用 VGG16 提取局部空间特征,但其庞大的参数量导致推理延迟激增。为融合时空信息,Wu 等^[10]提出了 CNN-GRU 混合模型,通过 GRU 层捕获流量时序特征,提升了 DDoS 检测的 F1 值,但模型结构更为复杂,参数量和计算开销比单独使用 CNN 更大,进一步加剧了部署和效率方面的挑战。

Wang 等^[11]和 Avcı 等^[12]开始将 ViT (Vision Transformer) 应用于该领域,其全局注意力机制虽能对长程依赖进行建模,但由于参数量过大而导致训练效率低下。认识到效率的重要性,姚等^[13]使用 MobileViT 来处理流量图像,显著降低了模型的参数量和计算复杂度,提高了部署在资源受限设备上的可行性。但其没有针对网络流量图像的独特性质 (特定纹理模式) 进行优化,性能仍有提升空间。由此可见,现有模型尚未解决全局-局部特征协同与计算-精度均衡优化的关键问题。

针对上述问题,本研究提出融合格拉姆角差场 (Gramian Angular Difference Field, GADF) 编码与改进 MobileViT 的轻量化入侵检测框架。主要贡献包括:

MobileViTv3_xxs模型通过深度可分离卷积与Transformer的混合架构,在参数量与计算量之间实现了最优平衡,成为后续改进 MobileViT-RMF 模型的理想基线,其核心优势在于:1)采用 MV2 模块捕获 GADF 图像中 DoS 攻击的微观纹理特征,通过逐点卷积实现通道维度特征重组;

2) MobileViT 模块建立了像素间的长程依赖关系,可以识别 DoS 攻击的宏观关联模式。然而,该模型对特征图的均匀处理方式难以区分突发流量与正常流量的周期性波动。本研究提出了残差多粒度聚焦 RMF 模块,结构如图 2 所示。




图 2 改进 MobileViT-RMF 结构图

Fig. 2 Structure diagram of the improved MobileViT-RMF

1.2.1 RMF 模块

本研究基于动态聚焦模块 DFB (DynaFocus-Block) 构建了 RMF 模块如图 3 所示, RMF 模块通过分层堆叠的 DFB 单元协同工作, 每个 DFB 包含自适应大核注意力 ALKA (Adaptive Large Kernel Attention)、空间门控注意力 SGA (Spatial Gate Attention) 和自调制注意力 SMA (Self-modulated Attention) 三个核心组件。

将自适应大核注意力 ALKA 与空间门控注意力 SGA 堆叠来构建基础模块 DFB, DFB 通过多尺度和门控方案来改进大核注意力, 生成覆盖不同粒度级别的注意力图。此方法有效促进了全局与局部信息的整合, 并减少了由于大核尺寸可能引发的阻塞伪影问题。受最新视觉注意研究^[15]的启发, 本文使用 ALKA 来解决这些问题, 方法是结合大核注意力和多尺度学习, ALKA 由 3 个主要函数组成。

1) 大核注意力: 给定输入特征图

$X \in \mathbb{R}^{C \times H \times W}$, LKA 通过将一个 $K \times K$ 卷积分解为 3 个分量来自适应地构建长程关系: 一个 $(2d-1) \times (2d-1)$ 深度可分离卷积 $f_{DW}(\cdot)$, 一个 $\lceil k/d \rceil \times \lceil k/d \rceil$ 深度可分离空洞卷积 $f_{DWD}(\cdot)$ 和一个逐点卷积 $f_{PW}(\cdot)$, 上述操作可表述为

$$LKA(X) = f_{PW}(f_{DWD}(f_{DW}(X))). \quad (3)$$

2) 多尺度机制: 假设输入特征图 $X \in \mathbb{R}^{C \times H \times W}$, 该模块首先将其分割为 n 份 $X_1, X_2, \dots, X_n$, 每份的大小为 $\left\lfloor \frac{C}{n} \right\rfloor \times H \times W$ 。对于第 i 组特征 X_i , 一个由 $\{k_i, d_i\}$ 分解的 LKA 被用来生成同质尺度注意力图 LKA_i 。

3) 门控机制: 对于第 i 组输入 X_i , 为了避免块效应, 以及学习更多的局部信息, 利用空间门控来动态地将 $LKA_i(\cdot)$ 适应为 $ALKA_i(\cdot)$, 表示为

$$ALKA_i(X_i) = G_i(X_i) \otimes LKA_i(X_i), \quad (4)$$

式中: $G_i(\bullet)$ 是由 $a_i \times a_i$ 深度可分卷积生成的第 i 个门控, $LKA_i(\bullet)$ 是由 $a_i \cdot b_i - 1$ 分解的 LKA 。特别是,

具有更大感受野的 $MLKA_i$ 更倾向于反应长距离依赖, 而较小的 $MLKA_i$ 倾向于保留局部纹理。




图3 RMF模块结构图

Fig 3 RMF structure diagram

SGA结合了门控机制与空间注意力, 可以剔除不必要的线性层, 并聚集空间上下文信息。为了更有效地捕获空间信息, 采用单层深度可分离卷积来对特征图进行加权。给定密集变换的 X 和 Y , SGA的关键过程可以表示为

$$SGA(X, Y) = f_{DW}(X) \otimes Y, \quad (5)$$

式中: $f_{DW}(\bullet)$ 和 $\otimes$ 分别为深度可分离卷积和逐元素

乘法。

通过应用空间门控, SGA可以移除非线性层, 并在考虑复杂性的情况下捕获局部连续性。ALKA、SGA与SMA的结构如图4所示。ALKA和SGA注意力模块能够分别捕捉长距离依赖且自适应调整特征表示, 从而增强局部特征的表征能力。




图4 ALKA、SGA与SMA结构图

Fig. 4 Structural diagrams of ALKA, SGA, and SMA

DFB的具体计算过程为

$$F_{DFB} = \begin{cases} X_1 = \text{LayerNorm}(X_{in}), \\ X_2 = X_1 + \text{ALKA}(X_1) \\ X_3 = X_2 + \text{SGA}(\text{LayerNorm}(X_2)). \end{cases} \quad (6)$$

对于给定输入特征图 $X_{in} \in \mathbb{R}^{C \times H \times W}$, 经过LayerNorm、ALKA、SGA等结构后得到残差主路径 X_3 。每个DFB堆栈包含 N 个单元, 如式(7)所示。

$$X_{\text{out}}^{(k)} = X_{\text{in}} + \bigoplus_{i=1}^k F_{\text{DFB}}^{(i)}(X_{\text{in}}), \quad (7)$$

式中: k 为 DFB 块堆叠的次数; $\bigoplus$ 为跨堆叠 DFB 单元的残差聚合。通过多次堆叠后在尾部使用 SMA 尾部注意力最终组成 DFBs, 具体计算过程为

$$F_{\text{DFBs}}^{(k)} = \text{SMA}(X_{\text{out}}^{(k)}) + X_{\text{in}o} \quad (8)$$

最终实现两阶段特征调节, 在 MViT3 模块前通过 3 层 DFB 堆栈提取多粒度空间模式, 如式(9)所示。

$$X_{\text{pre}} = F_{\text{DFBs}}^{(k)} + X_{\text{in}}, \quad k=3。 \quad (9)$$

在 MViT3 后使用两层 DFB 堆栈增强上下文感知, 通过跳跃连接实现浅层纹理特征与深层语义特征的跨层融合, 如式(10)所示。

$$X_{\text{post}} = \text{MViT}(X_{\text{pre}}) + F_{\text{DFBs}}^{(k)}(\text{MViT}(X_{\text{pre}})), \quad k=2。 \quad (10)$$

1.2.2 融合 RMF 的 MobileViT 网络

整个训练过程采用焦点损失 Focal Loss 优化分类性能, 以提高对入侵样本的检测能力。该模型结合局部与全局特征, 有效提升了网络入侵检测的准确率。

MobileViT-RMF 网络结构如表 1 所示。*Input* 表示网络中每个模块的输入特征图尺寸, *Operator* 表示每个特征层所经过的模块, *Cout* 表示通过每个特征层后输出的通道数, *L* 表示 MViT3 模块中 Transformer 模块的个数, *s* 表示步长, 即卷积核每次移动的距离^[16]。

表 1 MobileViT-RMF 网络结构

Tab. 1 MobileViT-RMF network structure

<i>Input</i>	<i>Operator</i>	<i>Cout</i>	<i>L</i>	<i>s</i>
$3 \times 256 \times 256$	Conv2d	16	—	2
$16 \times 128 \times 128$	MV2	16	—	1
$16 \times 128 \times 128$	MV2	24	—	2
$24 \times 64 \times 64$	MV2	24	—	1
$24 \times 64 \times 64$	MV2	24	—	1
$24 \times 32 \times 32$	RMF	63	2	1
$63 \times 32 \times 32$	RMF	72	4	1
$72 \times 16 \times 16$	RMF	126	4	1
$126 \times 8 \times 8$	Conv2d	504	—	1
$504 \times 8 \times 8$	AvgPool2d	—	—	—
504	FC	—	—	—

2 实验与分析

2.1 数据准备

本研究采用加拿大网络安全研究所发布的 CICIDS2017 基准数据集, 该数据集通过模拟真实企

业网络环境而构建, 包含连续 5 d 的完整网络流量记录, 涵盖 HTTP、FTP、SSH 等常规协议流量及多种新型攻击模式^[17]。实验选取 BENIGN 正常流量与 DDoS、DoS GoldenEye、DoS Hulk、DoS Slowhttptest、DoS Slowloris 五类典型 DoS 攻击数据, 该分类体系可有效验证模型在泛洪攻击 DDoS、应用层攻击 Slowloris 及混合攻击场景下的检测鲁棒性。

2.1.1 数据预处理

针对 CICIDS2017 数据集存在的非数值型特征、缺失值及异常值问题, 本研究实施三级数据清洗策略:

- 1) 删除包含无限大/小值的异常样本;
- 2) 采用众数填充法补全离散型特征缺失值;
- 3) 对连续型特征缺失值进行相邻时间窗线性插值。

为缓解类别不平衡问题, 采用分层欠采样方法将多数类 BENIGN 样本量与少数类 DoS Slowloris 样本量的比例压缩至 1:1, 相较 Pradipta 等^[18]采用的 SMOTE 数据平衡的方法, 该方法可有效避免过拟合风险。

在数据编码阶段构建多分类编码体系: 采用二进制编码机制, 将良性流量统一标记为 0, 各类攻击流量根据攻击类型分配 1~5 的离散编码值, 实现分类变量的数值化转换。采用 Min-Max 归一化方法将原始序列 $X = \{x_1, x_2, \dots, x_n\}$ 归一化至区间 $[-1, 1]$ 。式中, X 为特征向量, $X_{\min}$ 与 $X_{\max}$ 分别为特征最小值与最大值。相较于文献^[19]采用的 Z-score 标准化, 该方法能更好地保留流量特征的相对比例关系。

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}}。 \quad (4)$$

预处理后的 CICIDS2017 数据集包含 80 维有效特征, 将时间窗同步设为 80 点可实现特征维度与转换矩阵的严格对应。不同时间窗对分类模型准确率的影响如表 2 所示。此设计确保了每个时间窗完整覆盖单次检测所需的全部特征维度, 避免零填充或截断导致的信息损失。

表 2 不同窗口大小对分类准确率的影响

Tab. 2 The impact of different window sizes on classification accuracy

窗口尺寸	图片大小/像素	分类准确率/%
40	256×256	96.53
50	256×256	96.99
60	256×256	98.41
70	256×256	98.44
80	256×256	99.75

最终构建的数据集包含 34 292 个有效样本,按 7:3 比例采用分层随机抽样划分训练集与测试集,具体数据分布如表 3 所示。最终生成具有时空关联性的二维图像数据如图 5 所示。

表 3 数据分布

Tab. 3 Data distribution

攻击名称	训练集	测试集	总计
BENIGN	5 036	1 039	6 075
DDoS	6 000	1 000	7 000
DoS_GoldenEye	6 000	1 000	7 000
DoS_Hulk	6 000	1 000	7 000
DoS_Slowhttptest	5 485	1 000	6 485
DoS_Slowloris	5 771	1 000	6 771




图 5 CICIDS2017 数据集部分样例展示

Fig. 5 A portion of sample displays from the CICIDS2017 dataset

2.2 实验环境

本实验选用 Python 3.9.19 作为编程语言,基于 PyTorch 2.3.1 深度学习框架构建网络模型,并使用 CUDA 12.5 版本进行加速计算。具体硬件配置如表 4 所示。

表 4 实验环境硬件配置

Tab. 4 Hardware configuration of the experimental environment

CPU	GPU	内存	存储
AMD Ryzen9 5900HX	GeForce RTX 3080	SamsungDDR4 16×2GB	SAMSUNG MZVLB

实验的训练与测试环境为 Windows 11 操作系统。本次实验采用带权重衰减的自动梯度 AdamW^[20] 为优化器,具体超参数如表 5 所示。

表 5 实验环境超参数设置

Tab. 5 Hyperparameter settings for the experimental environment

迭代次数	批次大小	优化器	学习率	损失函数
100	32	AdamW	0.003	Focal Loss

2.3 评价指标

实验采用图像分类任务常用的评价指标:精确率 P (Precision)、召回率 R (Recall)、 $F1$ 值 ($F1$ -score) 和预测准确率 Acc (Accuracy)。

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (5)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (6)$$

$$F1 = \frac{2P}{2N_{TP} + N_{FP} + N_{FN}}, \quad (7)$$

$$Acc = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}}, \quad (8)$$

式中: N_{TP} 为正例预测正确的个数; N_{TN} 为正例预测错误的个数; N_{FP} 为负例预测错误的个数; N_{FN} 为负例预测正确的个数。

2.4 对比实验

为了验证本文提出的 MobileViT-RMF 网络模型的性能,在数据集 CICIDS2017 上将其与 EfficientNet、Resnet、Shufflenet、MobileNet、SqueezeNet、MobileViT 等主流轻量级系列模型进行了对比实验。

2.4.1 与主流轻量级网络的对比

实验中,平均预测时间 (Average Predicted Time, APT) 是在稳定输入条件下对同一幅图片重复进行 16 次计算获得的平均推理时间,用以表征即时响应特性。所有评价指标结果如表 6 所示。

由表 6 可以看出,相较于基线模型 MobileViT_V3_xxs, MobileViT-RMF 在准确率上提升了 2.74 百分点,同时标准差由 1.10 降低至 0.59,表明模型的输出结果更加稳定。在保持较低参数规模 (1.03×10^6) 与计算开销的前提下,所提模型在 ACC、 $F1$ 及召回率等指标上均达到当前对比模型中的最优水平。进一步对比可发现, MobileViT-RMF 在各项评价指标上的标准差均控制在 0.6 以内,相较于 MobileViT_V3_0.5 及 MobileViT_V2 的结果均表现出更低波动性,说明引入 RMF 模块后模型在不同测试划分下具有更稳定的性能表现。

为了验证 RMF 模块的有效性,在相同训练条件下对比了 MobileViT-RMF 与基准 MobileViT 模型的分类准确率,结果如图 6 所示。可以看出,改进模型在 90% 的测试周期中保持了 99% 以上的准确率,而基准模型存在 3 次显著波动。面

对混合型DDoS攻击时, RMF模型在第16测试周期的准确率为99.32%, 而基准模型下降至

92.75%。实验结果验证了残差多粒度聚焦模块RMF对异常流量特征的稳定捕捉能力。

表6 MobileViT-RMF网络与轻量级网络各指标对比

Tab. 6 Comparison of MobileViT-RMF network and lightweight network indicators

网络	参数量/ 10^6	APT/ms	FLOPs/ 10^6	Acc/%	F1/%	R/%	P/%
ShuffleNet_V2 ^[21]	7.39	20	780	96.61±2.32	96.60±2.39	96.61±2.31	96.73±1.68
EfficientNet_B0 ^[22]	4.01	37	540	97.18±1.56	97.18±1.55	97.18±1.56	97.22±1.30
MobileNet_V1 ^[23]	3.21	30	587	97.08±1.02	97.08±1.04	97.08±1.02	97.11±0.86
MobileNet_V2 ^[24]	3.50	22	427	95.93±8.93	95.76±10.26	95.93±8.94	96.81±2.84
MobileNet_V3 ^[25]	5.48	28	305	93.72±13.53	93.33±15.41	95.45±13.54	95.45±5.95
MobileViT_V1 ^[26]	1.02	25	350	97.03±0.73	97.03±0.73	97.05±0.73	97.05±0.64
MobileViT_V2 ^[27]	4.39	30	1451	97.08±3.87	97.00±4.49	97.08±3.90	97.39±1.67
MobileViT_V3_xxs ^[28]	0.73	26	278	97.01±1.10	97.02±1.10	97.03±1.10	97.26±0.93
MobileViT_V3_0.5 ^[28]	1.17	28	381	97.68±0.76	97.68±0.77	97.70±0.75	97.70±0.61
SqueezeNet1_1 ^[29]	0.72	21	263	85.11±11.14	81.16±14.62	85.11±11.14	90.66±5.85
MobileViT-RMF(ours)	1.03	23	279	99.75±0.59	99.75±0.59	99.75±0.59	99.76±0.53




图6 模型准确率对比

Fig. 6 Comparison of model accuracy

图7中MobileViT-RMF与基准模型的交叉熵损失在50个测试周期内呈现显著差异。可以看出,改进模型展现出更优的损失收敛稳定性,其平均损失波动幅度较基准模型降低61.4%。具体而言,改进模型自第35测试周期起即进入稳定收敛状态,而基准模型在第47测试周期出现异常激增,突显了潜在梯度失稳的缺陷。RMF模型的最大损失增幅仅为基准模型的48.1%,进一步验证了该模块对异常流量特征的鲁棒性优化。




图7 模型交叉熵损失值对比

Fig. 7 Comparison of model accuracy

2.4.2 与CICIDS2017数据集上较优模型的对比

将本文模型与现有基于CICIDS2017数据集一维数据分类模型OC-SVM / RF^[30]、Random Forest^[31]、CNN-BiLSTM^[32]、DBN^[33]等进行比较,结果如图8所示。由图8可知, MobileViT-RMF在四项关键指标上均显著优于其他模型,展现出近乎完美的检测性能。OC-SVM虽在精确度和F1得分上表现较优,但其召回率与MobileViT-RMF存在1.39%的显著差距。CNN-BiLSTM出现了明显的性能失衡现象,其召回率与精确度差值达8.01个百分点,暗示该模型存在严重的漏报风险。




图8 模型性能对比柱状图

Fig. 8 Comparison of model performance bar chart

2.4.3 模型泛化性验证

为了评估 MobileViT-RMF 模型的跨数据集适应能力,在 UNSW-NB15^[34]数据集上对其进行了泛化验证实验。数据集同样经上述方法进行数据清洗、预处理及下采样至样本均衡,实验结果如图9所示。可以看出, MobileViT-RMF 模型的峰值准确率达到99.89%。

输出混淆矩阵,其中矩阵的行表示真实类别,列表示预测结果,各主对角线元素反映类内

检测的准确率, 非对角线元素揭示误判模式。




图 9 改进模型在 UNSW-NB15 数据集上的指标柱状图

Fig. 9 The improved model's indicator bar chart on the UNSW-NB15 dataset

图 10 为 MobileViT-RMF 模型在 CICIDS2017 数据集中性能检测的结果。可以看出, BENIGN 样本被正确识别, DDoS、DoS_GoldenEye、DoS_Slowloris 与 Hulk 等四类攻击均实现了 100% 的准确检测。GoldenEye 攻击特有的不完整 HTTP 请求特征, 经 GADF 转换后呈现放射状条纹。Hulk 攻击的高并发 GET 请求模式映射为密集块状纹理。实验结果表明, 本文提出的 RMF 模块成功捕获了两类攻击在空间频率域的差异化特征。DoS Slowhttptest 检测的准确率为 99.00%, 1% 的误判可能是由于 Slowloris 混合攻击策略导致了特征重叠。




图 10 改进模型在 CICIDS2017 数据集上的混淆矩阵

Fig. 10 The confusion matrix of the improved model on the CICIDS2017 dataset

图 11 为本文模型在 UNSW-NB15 数据集上输出的混淆矩阵。可以看出, 在对 DoS 攻击进行分类时准确率达到 99.33%, 其中 0.67% 的样本被误

判为 Exploits 攻击, 产生误差的原因可能是部分 Exploits 样本使用了 UDP Flood 技术, 与 DoS 攻击策略产生交叉导致生成图像特征区域重叠。而对 BENIGN、Exploits、Fuzzers、Generic、Reconnaissance 四类样本均实现了 100% 的精确识别, 证明 GADF 转换通过时频域特征增强机制使正常流量与攻击流量具有显著的视觉可分性。




图 11 改进模型在 UNSW-NB15 数据集上的混淆矩阵

Fig. 11 The confusion matrix of the improved model on the UNSW-NB15 dataset

2.4.4 消融实验

为了验证本文改进模型中各个模块的有效性, 在 CICIDS2017 数据集上进行了系统性消融实验, 结果如表 7 所示。可以看出, 基准模型的分类准确率为 98.44%, 单独引入 SMA 组件使准确率提升了 0.44 个百分点, 证明局部卷积与自注意力融合能有效捕获网络流量的空间相关性特征。单独应用 SGA 时准确率达 98.60%, 说明动态空间门控机制可强化关键区域的特征响应。单独部署 ALKA 导致性能下降至 97.87% (下降 0.57 百分点), 这表明多尺度特征融合需依赖其他组件进行通道维度校准。

ALKA 与 SMA 协同, 证实多尺度特征金字塔为局部增强操作提供了层次化语义支撑; ALKA+SGA 组合的准确率达到 99.33%, 表明门控机制能自适应调节多尺度特征的权重分布; SGA+SMA 组合出现性能抑制现象, 推测全局注意力与局部增强可能存在特征响应域冲突, 需通过 ALKA 的多尺度解耦实现协同优化。

表 7 消融实验结果
Tab. 7 Ablation experiment results

RMF			CICIDS2017
ALKA	SGA	SMA	Acc/%
×	×	×	98.44
×	×	✓	98.88
×	✓	×	98.60
✓	×	×	97.87
×	✓	✓	98.21
✓	×	✓	99.10
✓	✓	×	99.33
✓	✓	✓	99.99

当同时集成 ALKA、SGA 与 SMA 时,模型的准确率达到 99.99%,较基准提升 1.55 百分点。此现象表明:ALKA 构建的多尺度特征空间为

表 8 平台硬件配置表

Tab. 8 Hardware configuration

平台	处理器	内存	算力
Jetson Xavier NX	6 核 Carmel CPU + 384 核 Volta GPU	8GB LPDDR4	21 TOPs

表 9 模型检测帧率

Tab. 9 Detection frame rate of models

模型	参数量/ 10^6	FLOPs/ 10^6	帧率/(帧·s ⁻¹)
MobileViT	1.03	350	72
MobileViT-RMF	1.02	279	94

由表 9 可以看出,MobileViT-RMF 实现了 94 帧·s⁻¹ 的实时推理性能,验证了其在边缘设备上的部署优势。与 MobileViT 相比,该模型在资源受限设备上表现出更优的工程适用性,为网络入侵检测等实时边缘计算场景提供了新方案。未来可通过模型剪枝和硬件指令集优化进一步提升性能。

3 结 论

本研究通过融合格拉姆角差场 GADF 编码与残差多粒度聚焦模块 RMF,构建了轻量化入侵检测模型 MobileViT-RMF。实验表明,该模型在 CICIDS2017 和 UNSW-NB15 数据集上的检测准确率分别达到 99.75% 与 99.89%,验证了 GADF 在时空特征编码与 RMF 模块在多粒度特征融合上的有效性。

尽管本研究取得了上述成果,仍存在以下局限性:1) 检测范畴方面,当前 GADF-RMF 框架主要针对已知攻击模式的特征优化,对零日攻击的检测能力尚未验证。这源于 GADF 编码依赖预定义攻击特征的时空模式提取,而未知攻击缺乏此类先验知识。2) 流量适应方面,固定时间窗策略(80 点)在处

SGA 提供了分粒度的注意力计算基础。SGA 的动态门控引导 SMA 聚焦于局部模式的判别。

2.4.5 边缘计算设备部署试验分析

为了验证 MobileViT-RMF 模型在移动端的实际部署性能,将其与 MobileViT 模型共同部署于边缘计算设备 Jetson Xavier NX 平台。该平台硬件配置如表 8 所示。

平台软件环境采用 JetPack 5.0.2 系统,集成 TensorRT 8.4.1.5 推理引擎与 CUDA 11.4 并行计算平台,设置平台最高功耗为 15W 模式。

基于此平台将 MobileViT、MobileViT-RMF 模型设置为 FP16 量化。模型检测帧率结果如表 9 所示。

理非平稳流量时可能产生相位偏移。

针对这些不足,可从以下方面改进:1) 开发动态时间窗机制,通过 LSTM 网络自适应调整分段策略;2) 探索基于小样本学习的未知攻击检测范式,通过元学习(Meta-learning)构建可扩展的特征空间。

利益冲突声明/Conflict of Interests

所有作者声明不存在利益冲突。

All authors declare no relevant conflict of interests.

参考文献:

- [1] KUMARI P, JAIN A K. A comprehensive study of DDoS attacks over IoT network and their countermeasures[J]. Computers & Security, 2023, 127: 103096.
- [2] NEXUSGUARD. Distributed denial of service trend report 2024 [EB/OL]. (2025-02-21) [2025-06-12]. <https://www.nexusguard.com/file/nexusguard-ddos-trend-report-2024>.
- [3] ALI A, YOUSAF M M. Novel three-tier intrusion detection and prevention system in software defined network[J]. IEEE Access, 2020, 8: 109662-109676.
- [4] LIAO H, MURAH M Z, HASAN M K, et al. A survey of deep learning technologies for intrusion detection in Internet of Things [J]. IEEE Access, 2024, 12: 4745-4761.
- [5] MO Y M, LI H, WANG D S, et al. An intrusion detection system based on convolution neural network [J]. PeerJ Computer Science, 2024, 10: e2152.

- [6] DEMMESE F A, NEUPANE A, KHORSANDROO S, et al. Machine learning based fileless malware traffic classification using image visualization[J]. *Cybersecurity*, 2023, 6(1): 32.
- [7] PHAM V, SEO E, CHUNG T M. Lightweight convolutional neural network based intrusion detection system[J]. *Journal of Communications*, 2020, 15(11): 808-817.
- [8] ATTACK W, ATTACK I, ATTACKB F. Ensemble of feature augmented convolutional neural network and deep autoencoder for efficient detection of network attacks [J]. *Scientific Reports*, 2025, 15: 4267.
- [9] 刘文琪, 胡涛, 闫洁, 等. 基于DeepInsight和迁移学习的入侵检测技术[J]. *工程科学学报*, 2024, 46(12): 2238-2245.
- LIU Wenqi, HU Tao, YAN Jie, et al. Network intrusion detection technology based on DeepInsight and transfer learning [J]. *Chinese Journal of Engineering*, 2024, 46(12): 2238-2245. (in Chinese)
- [10] WU Z T, LONG Z H. Research on network traffic classification method based on CNN-RNN[M]. Singapore: Springer Nature, 2023.
- [11] WANG L T, HU W, LIU J Y, et al. Encrypted traffic classification based on fusion of vision transformer and temporal features[J]. *The Journal of China Universities of Posts and Telecommunications*, 2023, 30(2): 73-82.
- [12] AVCI C, TEKINERDOGAN B, CATAL C. Design tactics for tailoring transformer architectures to cybersecurity challenges [J]. *Cluster Computing*, 2024, 27(7): 9587-9613.
- [13] 姚军, 孙方超. 基于MobileViT的轻量型入侵检测模型研究[J]. *现代电子技术*, 2024, 47(19): 33-39.
- YAO Jun, SUN Fangchao. Research on lightweight intrusion detection model based on MobileViT [J]. *Modern Electronics Technique*, 2024, 47(19): 33-39. (in Chinese)
- [14] XIAO F Y, CHEN Y Y, ZHU Y H. GADF/GASF-HOG: Feature extraction methods for hand movement classification from surface electromyography[J]. *Journal of Neural Engineering*, 2020, 17(4): 046016.
- [15] WANG Y, LI Y S, WANG G, et al. Multi-scale attention network for single image super-resolution [C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2024: 5950-5960.
- [16] LUO S S, LI M J, CHEN M, Multi-scale integrated attention mechanism for facial expression recognition network [J]. *Computer Engineering and Applications*, 2023, 59(1): 199-206.
- [17] PANIGRANHI R, BORAH S. A detailed analysis of CICIDS2017 dataset for designing intrusion detection systems [J]. *International Journal of Engineering & Technology*, 2018, 7(3): 479-482.
- [18] PRADIPTA G A, WARDOYO R, MUSDHOLIFAH A, et al. SMOTE for handling imbalanced data problem: A review [C]//2021 Sixth International Conference on Informatics and Computing (ICIC), 2021: 1-8.
- [19] PEDREGOSA F, VAROQUAUX G, GRAMFORT A, et al. Scikit-learn: Machine learning in Python [J]. *Journal of Machine Learning Research*, 2011, 12(10): 2825-2830.
- [20] ZHUANG Z X, LIU M R, CUTKOSKY A, et al. Understanding AdamW through proximal methods and scale-freeness [DB/OL]. (2022-01-31) [2025-06-16]. <https://arxiv.org/abs/2202.00089>.
- [21] MA N N, ZHANG X Y, ZHENG H T, et al. Shufflenet V2: Practical guidelines for efficient CNN architecture design [DB/OL]. (2018-07-30) [2025-06-12]. <https://arxiv.org/abs/1807.11164>.
- [22] BODAVARAPU P N R, SRINIVAS P V V S. Facial expression recognition for low resolution images using convolutional neural networks and denoising techniques[J]. *Indian Journal of Science and Technology*, 2021, 14(12): 971-983.
- [23] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications [DB/OL]. (2017-04-17) [2025-06-12]. <https://arxiv.org/abs/1704.04861>.
- [24] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted residuals and linear bottlenecks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [25] HOWARD A, SANDLER M, CHU B, et al. Searching for MobileNetV3 [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 1314-1324.
- [26] MEHTA S, RASTEGARI M. Mobilevit: Lightweight, general-purpose, and mobile-friendly vision transformer [DB/OL]. (2021-10-05) [2025-06-12]. <https://arxiv.org/pdf/2110.02178v1>.