

基于多尺度特征的网络流量异常检测方法

段雪源^{1,2,3}, 付钰¹, 王坤^{1,4}, 刘涛涛¹, 李彬¹

(1. 海军工程大学信息安全系, 湖北 武汉 430033; 2. 信阳师范学院计算机与信息技术学院, 河南 信阳 464000;
3. 信阳师范学院河南省教育大数据分析与应用重点实验室, 河南 信阳 464000;
4. 信阳职业技术学院数学与信息工程学院, 河南 信阳 464000)

摘要: 针对传统的网络流量异常检测方法大都只关注流量数据的细粒度特征, 对多尺度特征信息利用不充分, 可能导致异常检测结果准确率不高的问题, 提出了一种基于多尺度特征的网络流量异常检测方法。使用多个不同尺度的滑动窗口将原始流量划分为多个观察跨度的子序列, 利用小波变换技术重构各个子序列的多层级序列, 链式 SAE 通过特征空间映射生成多层级重构序列, 各层级的分类器根据重构序列的误差进行异常的初步判定, 采用加权投票策略对各层级的初步判定结果进行汇总, 形成最终结果判定。实验结果表明, 所提方法可有效挖掘网络流量的多尺度特征信息, 对异常流量的检测性能较传统方法有明显提升。

关键词: 网络流量; 异常检测; 多尺度特征; 小波变换

中图分类号: TP391

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2022195

Network traffic anomaly detection method based on multi-scale characteristic

DUAN Xueyuan^{1,2,3}, FU Yu¹, WANG Kun^{1,4}, LIU Taotao¹, LI Bin¹

1. Department of Information Security, Naval University of Engineering, Wuhan 430033, China
2. College of Computer and Information Technology, Xinyang Normal University, Xinyang 464000, China
3. Henan Key Laboratory of Analysis and Applications of Education Big Data, Xinyang Normal University, Xinyang 464000, China
4. School of Mathematics and Information Engineering, Xinyang Vocational and Technical College, Xinyang 464000, China

Abstract: Aiming at the problem that most of the traditional network traffic anomaly detection methods only pay attention to the fine-grained features of traffic data, and make insufficient use of multi-scale feature information, which may lead to low accuracy of anomaly detection results, a network traffic anomaly detection method based on multi-scale features was proposed. The original traffic was divided into sub-sequences with multiple observation spans by using multiple sliding windows of different scales, and the multi-level sequences of each sub-sequence were reconstructed by wavelet transform technology. Multi-level reconstructed sequences were generated by Chain SAE through feature space mapping, and a preliminary judgment of abnormality was made by the classifiers of each level according to the errors of the reconstructed sequences. The weighted voting strategy was adopted to summarize the preliminary judgment results of each level to form the final result judgment. Experimental results show that the proposed method can effectively mine the multi-scale feature information of network traffic, and the detection performance of abnormal traffic is obviously improved compared with traditional methods.

Keywords: network traffic, anomaly detection, multi-scale characteristic, wavelet transformation

收稿日期: 2022-07-06; 修回日期: 2022-09-27

通信作者: 付钰, fuyu0219@163.com

基金项目: 国家重点研发计划基金资助项目 (No.2018YFB0804104)

Foundation Item: The National Key Research and Development Program of China (No.2018YFB0804104)

0 引言

互联网科技的迅猛发展, 不仅转变了人们的生活方式, 也给网络安全带来了前所未有的挑战^[1]。由于网络协议的开放性, 木马、病毒等恶意软件借助互联网广泛传播, 各种针对网络协议和应用程序漏洞的网络入侵攻击从未间断。这些恶意为不仅影响网络空间的正常运行, 还会扰乱社会秩序, 给国民经济带来巨大损失, 甚至威胁国家安全。

网络流量异常检测就是利用各种检测技术发现网络中的异常流量数据^[2], 揭露网络中潜藏的攻击行为, 对网络安全的防护起着关键作用。传统的异常流量检测的研究中, 常用基于机器学习的检测方法包括 K-Means^[3]、朴素贝叶斯^[4-5]、支持向量机^[6]、决策树^[7]以及它们的组合^[8]等, 但检测所用的流量特征需要人工提前完成设计。随着网络边界不断向外延伸, 以及各种网络服务的激增, 网络流量数据呈现多样性、爆炸式增长。传统的机器学习方法在应对海量、高维、动态的网络流量时, 往往表现出特征设计困难、误报率高和泛化能力弱等问题。

深度学习有着强大的表征能力, 能够从原始数据中自主地提取特征, 完成分类判断, 被应用于自然语言处理、机器视觉、智能诊断等领域。在网络流量的异常检测中, 深度学习技术也有着广泛的使用, 循环神经网络 (RNN, recurrent neural network) 常被用来捕捉流量数据中当前连接与之前连接的潜在联系^[9], 即时间信息的关联性; 卷积神经网络 (CNN, convolutional neural network) 通过卷积计算捕捉流量信号在频域上信息的相互关系^[10]。此外, 还有很多生成式神经网络被用来解决流量样本类别不平衡的问题, 主要有生成对抗网络 (GAN, generative adversarial network)^[11]、自编码 (AE, autoencode) 神经网络^[12], 它们利用正常流量建模, 可以很好地完成正常流量的重构, 而异常流量在重构时将会产生较大的误差, 利用这个误差可进行异常流量的判别。虽然这些基于神经网络结构的异常检测模型能够完成特征网络环境中异常识别问题, 但模型本身大都是单层体系结构, 即只利用了流量在单尺度的特征, 并没有充分利用流量数据在不同尺度下的多样性特征, 存在着检测精度低、误报率高、对不同网络环境的适应性弱等问题。

针对当前基于深度学习的网络流量异常检测方法大都只用到了流量的单尺度信息, 没有充分利

用网络流量在不同尺度下多样性特征信息的问题, 本文提出了一种基于多尺度特征的网络流量异常检测方法。多尺度特征具有 2 个维度的含义: 一是流量的观察跨度, 由一些不同尺度的滑动窗口对流量序列划分后获取到多个观察尺度的子序列特征; 二是时频域维度, 利用小波变换对流量序列进行逐级分解、重构, 得到流量序列多层的特征。原始流量经过滑动窗口、小波变换后得到多个不同尺度的重构序列。利用正常流量的重构序列数据训练链式堆叠自编码 (SAE, stacking autoencode), SAE 学习到正常重构序列的特征分布, 并构建特征空间, 该空间可完成对输入序列进行再次重构。由于使用正常流量对 SAE 建模, 因此 SAE 可对正常样本很好地重构, 但对于输入的异常样本, SAE 将不能有效地重构, 此时重构样本与输入样本之间存在较大的重构误差。分类器将重构误差与判定阈值进行比较, 大于阈值的样本则被判定为异常流量。

1 相关工作

研究发现, 正常流量和异常流量的时变信号在频率上存在较大差异, 因此有学者尝试利用流量的频域特征设计异常检测的方法, 较典型的是以傅里叶变换或小波变换为基础的检测方法。Brynielsson 等^[13]对网络流量进行离散傅里叶变换后, 利用频谱分析的方法评估不同攻击场景下模型的检测效果。何炎祥等^[14]以数据包数量为研究对象, 通过小波多尺度分析, 结合低速率拒绝服务攻击规律, 提取攻击流量特征指标, 作为攻击流量异常检测的依据。Cheng 等^[15]利用离散小波变换将原始流量变换为不同频域下的数据序列, 为异常检测提供了网络流量的多样性信息。Wang 等^[16]将小波频率分析嵌入深度学习框架, 利用小波分解技术在频率学习中的优势, 提取网络流量中的频域特征进行无监督的异常检测。Fouladi 等^[17]提出基于离散小波变换和 AE 神经网络的软件定义网络 (SDN, software defined network) 分布式拒绝服务攻击检测方案, 利用小波变换中提取流量的统计特征, AE 神经网络根据交换机流表中的平均命中率启动对攻击的检测, 取得了较好的效果。然而, 上述研究只计算了流量在某一观察跨度的特征, 没有充分利用流量在不同观察跨度上的关联信息。而网络安全事件在时间上有很强的关联性, 研究表明, 网络流量聚集观测的跨度能够对检测结果产生较大的影响^[15]。

利用深度学习检测大规模网络流量中的异常是当前研究的热点,按使用神经网络模型的结构可分为单结构模型和多结构模型。单结构模型是指使用单一类型神经网络搭建的检测模型,包括 RNN、CNN、AE 或 GAN 等网络结构。Albahar^[18]针对 SDN 安全方面存在的设计缺陷,提出了一种基于新的正则化技术的 RNN 模型,在不影响网络性能的情况下,实现对 SDN 入侵的有效检测。Pei 等^[19]提出了一种基于长短期记忆 (LSTM, long short-term memory) 结构自编码的网络流量异常检测方法,在保护隐私的前提下对数据进行聚合,构建针对网络流量异常的个性化联合检测框架,提升了模型对不同数据的泛化能力。Zong 等^[20]设计的 DAGMM 将深度 AE 压缩网络和改进的高斯混合模型 (GMM, Gaussian mixture model) 相结合,实现数据降维和密度估计同时优化的异常检测,常被用来检测网络流量中的异常数据。Yang 等^[21]提出集成式无监督网络异常检测方法,使用正常网络流量数据训练自编码器,并将自编码器每层输出的马氏距离与重构损失进行合并,计算出检测流量数据的异常得分,将大于阈值的判定为异常流量,性能优于单独使用马氏距离或重构损失的模型。除了自编码网络,GAN 也是生成式模型中常用的结构,Geiger 等^[22]提出的 TadGAN 异常检测模型就是典型的生成式模型,它利用正常数据训练双向 GAN (BiGAN, bidirectional GAN) 模型;训练好的模型能较好地完成对正常数据样本的重构,对异常样本则无法实现有效重构,TadGAN 已经成为异常检测领域性能比较的基准之一。类似地,Patil 等^[23]提出一种智能化的轻型网络流量异常检测框架 PCA-BiGAN,利用主成分分析 (PCA, principal component analysis) 对原始数据进行特征提取和降维,采用双向 GAN 检测异常的网络流量,验证了较少的特征有利于提高模型的检测效率。邹福泰等^[24]提出基于 GAN 的僵尸流量特征生成算法,分别从时间和空间 2 个维度产生僵尸网络特征样本,扩充僵尸网络训练集,并利用 GAN 的反馈机制提升检测的准确性。

随着深度学习的发展,很多研究人员尝试设计多结构模型,即由不同类型神经网络组合搭建的模型。Chen 等^[25]提出的 DAEMON 也是基于重构的模型,与 TadGAN 不同的是,DAEMON 是由变分自编码器 (VAE, variational autoencoder) 与 GAN 组合构建的,VAE 得到的是对输入数据的重构而非对

数据本身的重构,因此 DAEMON 对异构数据有较强的适应性。麻文刚等^[26]使用 3 层堆叠 LSTM 网络来提取不同深度的网络流量特征,并利用带跳跃连接线的改进型残差神经网络对 LSTM 进行优化,改善了神经网络中的过拟合与梯度消失的缺点。Chouhan 等^[27]提出基于信道增强和残差学习的深度卷积神经网络 (CBR-CNN, channel boosted and residual learning based deep CNN) 模型,利用多个 SAE 对原始信号进行多路映射实现信道增强,再利用残差卷积网络学习各个信道的特征,为流量分类提供依据。Yang^[28]将 SAE 与 LSTM 神经网络相结合,由多个串联的 SAE 提取连续流量的有效特征,LSTM 网络提取有效特征的时间结构,同时为了提升检测效率,对检测数据采取去除介质访问控制 (MAC, medium access control) 地址的预处理操作。Ullah 等^[29]将卷积神经网络和循环神经网络相结合搭建混合深度学习模型,利用卷积神经网络学习输入数据特征,由 LSTM、双向 LSTM 和门控循环单元 (GRU, gated recurrent unit) 构成新的 RNN 轻量级二值分类模型,实现对物联网中异常流量的检测。

当前的网络流量异常检测方法中,无论是单结构模型还是多结构模型,大多都是以抽取流量中的细粒度特征来获得更高层次的时间关联性信息,而没有考虑在不同尺度下的影响,很难确定模型的放样深度,因此难以生成最优结构。另外,这些方法仅使用了网络信号在某一频域的特征,并没有充分挖掘出它们的多频域信息。事实上,高频的特征更能反映流量数据中细粒度的差异性;而低频的特征是信号的原生状态,反映流量数据的未来趋势走向^[30]。因此,网络流量在不同的观察尺度上表现出不同的行为特征,在不同的频域尺度上反映出信号的原生状态和细粒度差异。虽然有研究曾将小波变换和序贯模型结合使用^[31],使检测的性能得到了改进,但只进行了初步的组合,小波变换只是用于缩短序列长度,而各层次的小波分解结果是相互独立的,且没有考虑到多尺度关系的问题。

2 模型

为充分获取和利用网络流量的多尺度特征信息,提升网络流量异常检测的准确性,本文把小波变换与深度学习相结合,提出了基于多尺度特征的异常流量检测模型,其架构如图 1 所示。首先,网

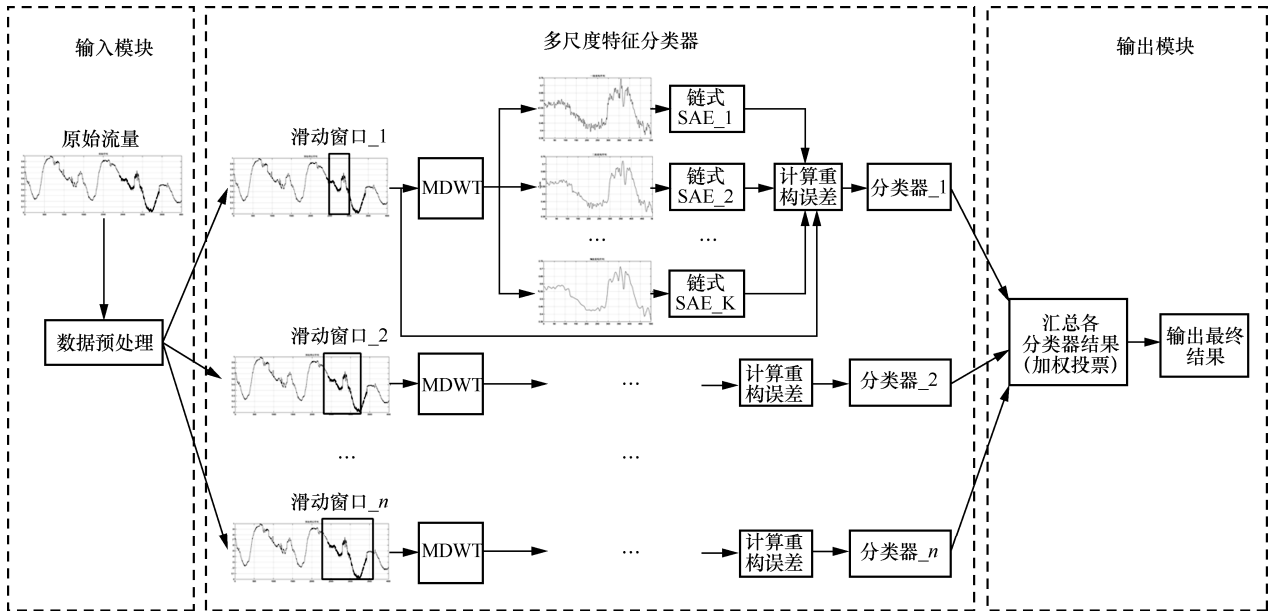


图 1 基于多尺度特征的异常流量检测模型架构

络流量数据序列被不同尺度的滑动窗口划分为不同观察尺度的多个子序列，利用小波变换技术对每个尺度下的所有子序列进行分解、重构，生成不同层级的重构序列数据；然后，利用训练好的链式SAE对每个重构序列进行特征提取和转换生成重构序列，通过计算重构序列与原始序列的重构误差进行异常判定，分类器得出每个观察尺度下的分类结果；最后，根据“加权投票”策略汇总各观察尺度上分类结果，作为最终检测结果输出。模型主要由输入模块、多尺度特征分类器（MFC, multiscale feature classifier）和输出模块组成。输入模块主要完成原始流量数据的预处理，删除缺损、冗余的数据，将字符型特征转换为数值型；为了便于运算，采用Max-Min的方法将各属性值做归一化处理。MFC模块是异常检测模型的核心，主要完成预处理后流量的多观察尺度划分、多层次序列重构、重构误差计算、异常流量样本的初步判定等任务。输出模块主要是根据规则汇总各尺度分类器的结果，并完成最终检测结果的输出。

2.1 多观察尺度划分

大观察尺度可以展示信号数据的全局趋势，而小尺度则提供更多细节信息。因此，本文利用滑动窗口将流量数据划分为不同观察跨度的子序列，以获得原始流量的多样性信息。滑动窗口主要是将流量序列截取为不同观察尺度的子序列，为了避免子序列间重叠，将滑动窗口尺度与步长均设置为 S ，

即观测流量的窗口尺度。

2.2 多层次序列重构

为得到原始流量的多层次重构序列，本文使用多级离散小波变换（MDWT, multilevel discrete wavelet transform）将原始流量数据在不同层级上进行分解与重构。离散小波变换是利用有限区间的母小波 $\psi(x)$ 通过平移和缩放而将原始信号分解为一组小波基函数 $\{\psi_{a,b}(x)\}$ ，表示为

$$\psi_{a,b}(x) = \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) \quad (1)$$

其中， a 为缩放参数， b 为平移参数。

利用 Mallat 算法将原始序列 $x = \{x_1, x_2, \dots, x_n\}$ 分解为近似部分 x^l 和细节部分 x^h 。从信号处理的角度看，近似部分代表原始信号的低频分量，包含比原始信号更粗略的信息，而细节部分则是原始信号的高频分量，包含原始信号中的局部细碎信息^[15]。通过对低频分量再进行分解，可得到更多分辨率较低的低频分量，这种迭代过程可表示为

$$x_{i-1}^l = c_i^h x_i^h + c_i^l x_i^l, \quad i \in N \quad (2)$$

其中， $x_0^l = x$ ； c^l 和 c^h 分别为小波变换的近似系数和细节系数，近似系数通过低通滤波器卷积原始信号获得，细节系数则是通过高通滤波器与原始信号卷积获得。当原始信号经过 k 个层级小波变换后可生成系数列表 $c = [c_k^l, c_k^h, c_{k-1}^h, \dots, c_2^h, c_1^h]$ ，根据系数列表计算出各层级上对原始信号的重建序

列，如式(3)所示。

$$R_j = f\left(\sum_{i=j}^k c_i^h x_i^{h,\uparrow} + c_i^l x_i^{l,\uparrow}\right), j \in [1, k] \quad (3)$$

其中， $f(\cdot)$ 表示重构函数， $x_i^{h,\uparrow}$ 、 $x_i^{l,\uparrow}$ 可分别通过对

x_i^h 、 x_i^l 升采样得到。当 j 取不同值时，原始数据序列即可变换为不同尺度的重构序列。图 2 展示了数据经小波滤波器进行多级分解与重构的过程，其中， H_1 和 H_2 为高通滤波器， L_1 和 L_2 为低通滤波器。

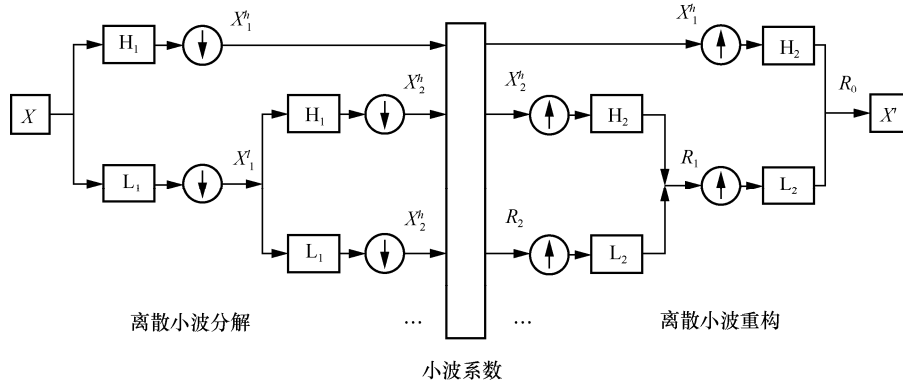


图 2 多级分解与重构的过程

对于给定输入流量数据 $X_n = \{x_1, x_2, \dots, x_i, \dots\}$ ， $x_i \in \mathbb{R}^d$ ，经过小波变换后的多尺度重构序列可表示为 $\{R_1, R_2, \dots, R_k\}$ ， $R_k = (x_s^1, x_s^2, \dots, x_s^k)$ 是通过最大层级 K 的分解和重构得到的， x_s^k 表示观察尺度为 S 的第 k 级输出， $k \in (1, K)$ 。多尺度的近似部分和细节部分能从多个层面反应数据的丰富信息，其中，更高级别的近似部分表示一种整体的趋势行为，而每个级别的细节部分可以表征更多的局部信息。

2.3 重构误差计算

使用 SAE 计算经过编码、解码后的重构序列与原始输入序列之间的误差。SAE 是由多个 AE 堆叠而成的多层神经网络，其结构如图 3 所示。




图 3 SAE 结构

前层 AE 编码器输出的潜在变量作为后层 AE 编码器的输入，这种连接方式可在原始特征向量到目的特征向量转换的过程中，帮助捕获原始特征空间的更多细节。AE 是前馈型的神经网络，由输入层、隐藏层、输出层组成，通常输入层和输出层具有相同大小，AE 将输入映射到潜在特征空间（编码），再由潜在空间映射回重构输出（解码），此编

码、解码过程可表示为

$$\begin{aligned} z &= W_e x + b_e \\ h &= f(z) \\ x' &= \sigma(W_d h + b_d) \end{aligned} \quad (4)$$

其中， x 为给定输入， h 为潜在变量， x' 为 x 经编码、解码后的重构输出； $f(\cdot)$ 、 $\sigma(\cdot)$ 为各自的激活函数； W_e 、 W_d 和 b_e 、 b_d 为编码器、解码器的权重和偏置；AE 通过最小化重建误差 $\min(x - x')^2$ 进行优化。利用正常流量数据对 SAE 进行训练，采取贪婪分层的方法，可分为预训练和微调 2 个阶段。

预训练阶段。使用无监督方法，利用最小化重建误差的均方误差 $\min\left(\frac{1}{m} \sum_{i=1}^m (x_i - x'_i)^2\right)$ ，对 AE 逐层进行初步训练。训练好的前层 AE 将学习到的潜在表示作为后层 AE 的输入，训练好的后层 AE 再将学习到的新表示继续向后传递，帮助下一层 AE 进行训练，直到所有 AE 完成训练，这种预训练的做法可以为整个 SAE 提供良好的初始参数。

微调阶段。输入正常数据，采用最小化交叉熵损失函数 $\min\left(-\frac{1}{n} \sum_{i=1}^n (x_i \log x_i + (1 - x_i) \log(1 - x_i))\right)$ 和随机梯度下降优化算法，对 SAE 的参数进行精确调整。这样，SAE 能够学习正常样本的分布，使其对正常样本的重构比异常样本更准确。

将训练好的编码器逐个连接，并将对应的解码器按相反顺序连接，构造链式 SAE 结构，如图 4 所示。




图 4 链式 SAE 结构

令 ϕ_i 和 φ_i 分别为第 i 个 AE 的编码器函数和解码器函数, 那么 SAE 的编码过程可以由各 AE 编码器的转换函数叠加表示, 即

$$x_w = x_{\text{encoded}} = \phi_w(\cdots(\phi_1(x))) = \phi_w \circ \phi_{w-1} \circ \cdots \circ \phi_2 \circ \phi_1(x) \quad (5)$$

其中, \circ 为联合函数, x_w 为原始输入 x 经过一系列转换后从第 w 个激活函数输出的高阶特征表示。解码过程则按相反的顺序, 利用各个 AE 的解码器转换函数对 x_w 进行反向重构, 其过程可表示为

$$\hat{x} = x_{\text{decoded}} = \varphi_1(\cdots(\varphi_w(x_w))) = \varphi_1 \circ \varphi_2 \circ \cdots \circ \varphi_{w-1} \circ \varphi_w(x_w) \quad (6)$$

由于 SAE 的编码器和解码器是在正常数据上训练, 可对正常样本进行有效的重构, 对异常样本重构则会产生较大偏差, 重构样本和原始样本对应分量之间的绝对差值为整个样本的重构误差, 可表示为

$$e_i = \sum_{k=1}^K |x_i^k - \hat{x}_i^k| \quad (7)$$

其中, x_i 为原始流量特征的第 i 个分量; \hat{x}_i 为第 i 分量的重构特征; e_i 为该分量经过小波变换的多层级分解、重构, 再由 SAE 编码、解码后计算出的重构误差。各观察尺度的分类器将得到的重构误差与本尺度的异常判定阈值比较, 当重构误差大于阈值时, 则将该观察尺度的初步检测结果暂时划分为异常。

判定阈值的设定, 参照“三西格玛”准则, 将验证集的正常样本输入训练好的模型, 将验证集所有正常样本产生的重构误差的均值加 3 个标准差作为异常判定的阈值, 即 $S_{\text{threshold}} = \mu + 3\sigma$ 。

2.4 异常流量样本的初步判定

本文采取“加权投票”的方法汇总各观察尺度的初步检测结果作为流量异常检测的最终判定结果。由于大的观察尺度反映了网络流量长时的关联性, 展示了数据的全局趋势; 而小的观察尺度反映了网络流量的局部相关性, 提供更细节的流量信息。因此, 相对大的观察尺度提供初步检测结果可

被赋予更大的权重, 而对小观察尺度的初步检测结果可被赋予相对小的权重。对 N 个观察尺度的模型, 将观察尺度按从小到大排列分别被赋予 $1 \sim N$, 则第 i 个观察尺度初步检测结果 $h_i(x)$ 的权重可表示为

$$w_i = \frac{2^i}{\sum_{i=1}^N 2^{N+1-i}} \quad (8)$$

将异常的初步检测结果设置为“1”, 正常设置为“0”, 汇总初步检测结果后可得到最终的汇总检测值为

$$H(x) = \sum_{i=1}^N w_i h_i(x) \quad (9)$$

将检测该值与汇总阈值比较, 若不小于汇总阈值, 则判定输入样本为异常。汇总阈值利用超参数搜索法设置, 将验证集中全部样本输入训练好的模型进行测试, 当模型的异常检测性能指标 F1 值达到最大时确定。

3 实验及结果分析

3.1 实验环境

本文实验在支持 GPU 的设备上进行, GPU 型号为 GeForce RTX 3090, 具有 24 GB 的 RAM。软件为 Ubuntu 18.04LTS、CUDA11.2、Pytorch1.8。

3.2 评估指标

实验的最终目标是将网络中的正常流量和异常流量进行区分, 因此异常检测工作实际是二分类问题, 可将异常流量定义为正样例, 正常流量定义为负样例。为全面评估所提方法对网络中异常流量的检测性能, 使用准确率 Accuracy、精确率 Precision、召回率 Recall、误报率 (FPR, false positive rate) 以及 F1 值等 5 个检测指标, 计算式分别为

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

$$\text{Precision} = \frac{TP}{TP + FP}$$

$$\text{Recall} = \frac{TP}{TP + FN}$$

$$F1 = \frac{2\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

$$\text{FPR} = \frac{FP}{FP + TN}$$

其中, TP、TN、FP、FN 为样例的真实分类与预测分类的相互关系, 真实分类与预测分类的关系矩阵如表 1 所示。

表 1 真实分类与预测分类的关系矩阵

| 真实分类结果 | 预测为正 | 预测为负 |
|--------|------|------|
| 真实为正 | TP | FN |
| 真实为负 | FP | TN |

3.3 数据设计

3.3.1 数据集构建

为了检验 MFC 的分类性能，本文在多个网络流量数据集上进行评估测试，使用 4 个公开网络流量数据集 KDD99、NSL-KDD、UNSW-NB15 以及

CIC-IDS2018，这些数据集都被划分了训练集、测试集，并标注了标签。为缩减运算开销，使用这些数据集的部分数据作为本文研究的原始数据，其中，KDD99、NSL-KDD、UNSW-NB15 这 3 个数据集使用各自的子集，CIC-IDS2018 则使用 Thursday-01-03-2018 子数据集。所选的数据子集的基本信息如表 2 所示，包括样本总数、正常样本数、异常样本数、特征数等信息，另外，数据集中每个异常位置也都是已知的。

表 2 原始网络流量数据集信息

| 数据集 | 数据子集 | 样本总数/个 | 正常样本数/个 | 异常样本数/个 | 特征数/个 |
|-------------|----------------------|---------|---------|---------|-------|
| KDD99 | 10_percent_corrected | 494 021 | 97 278 | 396 743 | 41 |
| | corrected | 253 727 | 26 053 | 227 674 | 41 |
| NSL-KDD | NSL-KDD-Train+ | 25 191 | 13 448 | 11 743 | 41 |
| | NSL-KDD-Test+ | 22 543 | 9 711 | 12 832 | 41 |
| UNSW-NB15 | NB15_training-set | 82 332 | 37 000 | 45 332 | 49 |
| | NB15_testing-set | 175 341 | 56 000 | 119 341 | 49 |
| CIC-IDS2018 | CIC-IDS2018-train | 198 675 | 142 822 | 55 853 | 79 |
| | CIC-IDS2018-test | 132 425 | 95 215 | 37 210 | 79 |

由于训练模型和计算阈值仅使用正常流量，故将全部正常样本按 40%、30%、30% 的比例随机划分，其中，40% 的正常样本作为训练集；30% 的正常样本作为验证集的正常样本，原训练集的异常样本作为验证集的异常样本；剩下 30% 的正常样本与原测试集中异常样本组合为新的测试集。表 3 汇总了新构建的各数据集的基本信息。每个数据集都各有特点，使异常检测研究更具挑战性，同时有助于确认模型的有效性以及对不同网络数据的适应性。

3.3.2 数据预处理

数据预处理是为保证流量数据的可读性和统一性而进行的数据清洗、文本数值化、流量匿名、数值归一化等操作。

1) 数据清洗。真实网络环境中抓取的流量数据，可能存在重复或残缺的无效数据，需要利用数据清洗技术对这些冗余和缺失数据进行清除。

2) 文本数值化。原始流量数据的特征值并不完全是数字，还有些可能是用字符表示的，因此需要将这些字符特征做 one-hot 编码，转换成相应的离散数值，以便参与运算。

3) 流量匿名。各流量特有的 IP 地址和 MAC 地址等信息可能会影响分类特征提取。为消除这些

因素的影响，使用随机生成的新地址替换原来的地址。这一步是可选的，如果待检测的流量来自同一个网络环境则不需要此操作。

4) 数值归一化。不同属性特征的量纲不同，特征值的取值范围也不尽相同，数据差异较大时会影响模型训练，以及最终检测结果的精确，在实验前使用 Max-Min 方法对数据进行归一化处理，使特征值分布在 [0,1] 区间。

表 3 新构建的各数据集的基本信息

| 数据集 | 数据子集 | 样本总数/个 | 正常样本数/个 | 异常样本数/个 |
|-------------|------|---------|---------|---------|
| KDD99 | 训练集 | 49 332 | 49 332 | — |
| | 验证集 | 433 742 | 36 999 | 396 743 |
| | 测试集 | 264 672 | 36 998 | 227 674 |
| NSL-KDD | 训练集 | 9 264 | 9 264 | — |
| | 验证集 | 18 691 | 6 948 | 117 43 |
| | 测试集 | 19 780 | 6 948 | 12 832 |
| UNSW-NB15 | 训练集 | 37 200 | 37 200 | — |
| | 验证集 | 73 233 | 27 901 | 45 332 |
| | 测试集 | 147 241 | 27 900 | 119 341 |
| CIC-IDS2018 | 训练集 | 95 215 | 95 215 | — |
| | 验证集 | 127 264 | 71 411 | 55 853 |
| | 测试集 | 108 621 | 71 411 | 37 210 |

3.4 实验结果与分析

3.4.1 单尺度窗口模型性能检测实验

本节实验主要检验模型在单一观察尺度（单尺度窗口）下的性能，滑动窗口的尺度设置为 800；使用 DB3 小波滤波器，小波分解的最大分解层级为 6 级；SAE 结构为 3 层 AE 链式连接，链式 SAE 的结构参数如表 4 所示。

表 4 链式 SAE 的结构参数

| 自编码器 | 输入尺寸 | 输出尺寸 |
|--------|------|------|
| 编码器层 1 | 150 | 110 |
| 编码器层 2 | 110 | 90 |
| 编码器层 3 | 90 | 64 |
| 解码器层 1 | 64 | 90 |
| 解码器层 2 | 90 | 110 |
| 解码器层 3 | 110 | 150 |

使用 Adam 算法优化，学习率为 0.000 01，BN=16，使用 NSL-KDD 的训练集对模型进行 100 次完整训练。模型训练完成后达到稳态，重构误差不再随训练次数增加而明显减小。模型训练好后，利用验证集数据计算出异常判定阈值和汇总阈值。

为缓解样本类别不平衡可能带来的计算偏差，客观地评价模型的性能，采用五折交叉运算的方式检验 MFC 对异常流量的检测能力。具体是将 NSL-KDD 的测试集数据平均分为 5 部分，每次选择 4 部分进行测试，最终检测结果取 5 次测试指标的均值，单尺度窗口模型在 NSL-KDD 上的检测性能如表 5 所示。通过检测结果可以看出，单尺度窗口下的 MFC 模型在 5 次检测中对异常样本的召回率均超过 94%，准确率和精确率均在 90% 以上，平均 F1 值为 0.938 6，平均误报率为 5.15%，说明所提方法能够较有效地检测出 NSL-KDD 数据集中的异常样本。

表 5 单尺度窗口模型在 NSL-KDD 上的检测性能

| 测试序号 | 准确率 | 精确率 | 召回率 | 误报率 | F1 值 |
|------|---------|---------|---------|---------|---------|
| 1 | 0.900 6 | 0.915 0 | 0.948 9 | 0.049 2 | 0.931 6 |
| 2 | 0.902 1 | 0.918 0 | 0.948 1 | 0.050 3 | 0.932 8 |
| 3 | 0.908 5 | 0.932 2 | 0.943 5 | 0.055 8 | 0.937 8 |
| 4 | 0.919 7 | 0.942 3 | 0.948 9 | 0.050 8 | 0.945 6 |
| 5 | 0.919 4 | 0.942 4 | 0.948 4 | 0.051 3 | 0.945 4 |
| 平均 | 0.910 1 | 0.929 9 | 0.947 6 | 0.051 5 | 0.938 6 |

3.4.2 多尺度窗口模型性能检测实验

本节的实验主要检验模型在 3 个不同观察尺度（多尺度窗口）下的检测性能，仍然使用 DB3 小波滤波器，滑动窗口大小分别设置为 600、800、1 200，其余实验条件设置同 3.4.1 节。仍然使用 NSL-KDD 训练集数据对模型进行 100 次的完整训练；利用验证集数据计算出异常判定阈值和汇总阈值。利用测试集数据进行性能检验，仍采用五折交叉运算的方式获取最终结果。单尺度窗口模型与多尺度窗口模型检测性能对比如图 5 所示。




图 5 单尺度窗口模型与多尺度窗口模型检测性能对比

从图 5 可以看出，在相同的最大分解层级和检测数据集下，多尺度窗口模型对异常样本的检测性能无论是检测精确率、准确率还是召回率都高于单尺度窗口模型，并且能够取得更低的误报率。这说明多个观察尺度的流量特征相对于单一尺度特征更能够反映流量数据本质的区别，对流量分类有着积极作用。直观的解释为，观察尺度越多，包含的信息越丰富，挖掘出的特征关联性越充足，对流量中异常的发现有着积极作用。

3.4.3 多尺度窗口多变换层级模型性能检测实验

本节实验主要为了验证在多尺度窗口下，不同的分解层级对异常检测性能的影响，将小波分解的最大分解层级分别取 2、4、6、8，其余模型设置和训练条件与 3.4.2 节的实验条件相同。由于不同的分解层级需要单独进行训练、求取阈值和检验性能，在 3.4.2 节实验中已经在最大分解层级为 6 时进行了检测，因此本节的实验还需在最大分解层级为 2、4 和 8 时对模型进行训练，同样还需利用验证集分别求出对应的阈值，再用测试集

进行性能检验。多尺度窗口多变换层级模型检测性能对比如图 6 所示。




图 6 多尺度窗口多变换层级模型检测性能对比

从图 6 可以看出，随着分解层级的增加，模型的准确率、精确率及 F1 值等检测指标总体呈现逐步上升趋势，误报率也不断下降，即更多的尺度特征信息可以让模型的检测性能更加出色。然而，最大分解层级为 6 时的异常召回率为 95.06%，最大分解层级为 8 时的召回率为 95.05%，出现这种情况是由于变换尺度过深，产生了过多的重构序列，导致训练时产生过拟合，从而引发模型的泛化能力退化。另外，最大层级为 6 和 8 时的 F1 值较接近，2 个模型的总体性能相当，对比其他 2 个分解层级的检测性能，考虑到计算开支问题，可以选择 3 个尺度窗口和最大 6 个变换层级作为 MFC 模型的最优结构。

3.4.4 与典型检测方法的对比实验

为了检验 MFC 模型对不同数据的泛化能力，除了 NSL-KDD 外，本节还在 KDD99、UNSW-NB15 和 CIC-IDS2018 几个公开数据集上进行实验，同时与 Tad-GAN^[22]、DAGMM^[24]以及 CBR-CNN^[26]等经典的检测模型性能进行比较，其中，Tad-GAN 为双 GAN 结构的生成式模型，常作为时间序列异常检测研究中的比较基准；DAGMM 为深度自编码高斯混合模型，因巧妙地把降维与密度估计结合在一起训练，避免了模型陷入局部最优，受到学术界的关注；CBR-CNN 为采用了信道增强技术的 SAE 与 CNN 的多结构模型，也经常作为参照来评估其他流量异常检测模型性能。表 6 展示了不同模型在 4 个数据集上的异常检测性能。

表 6 不同模型在 4 个数据集上的异常检测性能

| 模型 | 数据集 | 精确率 | 召回率 | F1 值 |
|---------|-------------|---------|---------|---------|
| Tad-GAN | KDD99 | 0.788 5 | 0.778 6 | 0.783 5 |
| | NSL-KDD | 0.834 3 | 0.887 1 | 0.859 9 |
| | UNSW-NB15 | 0.868 1 | 0.899 1 | 0.883 3 |
| | CIC-IDS2018 | 0.838 9 | 0.822 1 | 0.830 4 |
| | 平均 | 0.832 5 | 0.846 7 | 0.839 3 |
| DAGMM | KDD99 | 0.929 7 | 0.944 2 | 0.936 9 |
| | NSL-KDD | 0.864 2 | 0.855 3 | 0.859 7 |
| | UNSW-NB15 | 0.856 7 | 0.836 9 | 0.846 7 |
| | CIC-IDS2018 | 0.840 3 | 0.846 4 | 0.843 3 |
| | 平均 | 0.858 9 | 0.857 4 | 0.858 1 |
| CBR-CNN | KDD99 | 0.847 9 | 0.823 7 | 0.835 6 |
| | NSL-KDD | 0.894 3 | 0.896 1 | 0.895 2 |
| | UNSW-NB15 | 0.888 9 | 0.902 3 | 0.895 5 |
| | CIC-IDS2018 | 0.778 4 | 0.800 8 | 0.789 4 |
| | 平均 | 0.852 4 | 0.855 7 | 0.854 0 |
| MFC | KDD99 | 0.922 3 | 0.948 9 | 0.935 4 |
| | NSL-KDD | 0.946 1 | 0.950 6 | 0.948 3 |
| | UNSW-NB15 | 0.890 3 | 0.906 8 | 0.898 5 |
| | CIC-IDS2018 | 0.849 2 | 0.865 4 | 0.857 2 |
| | 平均 | 0.879 5 | 0.904 3 | 0.891 6 |

从表 6 可以发现，所提的基于多尺度特征的异常检测方法（MFC）在 NSL-KDD、UNSW-NB15 和 CIC-IDS2018 这 3 个数据集上的精确率、召回率和 F1 值均最高，在 KDD99 数据集上的召回率也是最好的，并且在 4 个数据集上的精确率、召回率和 F1 值三项指标的均值都为最高。MFC 在不同数据集上的优异表现，说明 MFC 能较好地适应不同类型的网络流量数据。虽然这 4 个数据集产自不同的网络环境，具有不同的特征数量和攻击类型，但从广义上来讲它们都是在计算机网络中生成的，具有网络流量数据的共性时频域特征。可以说，本文方法不仅可以从原始数据的低频分量中获取到原生态的本质特征，还能从高频分量中提取出流量数据的细粒度差异，具有很好的检测性能，同时也表现出对异构数据较强的泛化能力。

另外，DAGMM 在 KDD99 和 NSL-KDD 这 2 个数据集上表现也比较出色，这是由于 DAGMM 建模之初就使用 KDD 数据集，经过多次优化调整，因

此对于 KDD 系列的数据集具有较好的适应能力。观察表 6 还可以发现,除了 DAGMM 和 MFC 外, Tad-GAN 和 CBR-CNN 模型在 UNSW-NB15 数据集上的综合指标 F1 值均高于另外 3 个数据集。其原因可能是由于 UNSW-NB15 测试集中异常样本占比较大,约为 81.05%,这种样本类别的不平衡性给以这些发现异常为目的检测任务带来了便利。而对于同样是异常样本占比高达 86.02%的 KDD99 数据集,检测表现不佳的原因与数据集本身的特征量有关,虽然 KDD99 中的特征数据有 41 个,真正独立的特征量较少。另外,时间信息是网络流量异常检测的重要依据,KDD99 的 41 个特征中虽然有 10 个特征与时间有关,但是除了第一个连接时间的特征外,其余 9 个均是连接前 2 s 的统计特征,包括 5 个同主机的连接特征和 4 个同服务的连接特征,且它们间关联性很强,故而出现了“信息冗余”。而 UNSW-NB15 的 49 个特征中有 9 个与时间有关,除了链路的连接时间外,还包含数据包到达时间间隔等特征,以及一些数据包的其他特征,这些特征是区分正常流量和异常流量最主要的特征,也是各模型对 UNSW-NB15 的检测结果相对其他数据集更加出色的原因。

3.4.5 与新的检测方法性能对比

本文还与 3 种新检测方法进行了性能对比,分

别为基于 K-Means 聚类与支持向量机混合概念漂移的网络异常检测技术 K-Means & SVM^[8]、基于主成分分析与双 GAN 相结合的流量异常检测方法 PCA-BiGAN^[23]、以重建损失和马氏距离 (RL-MD, reconstruction loss and Mahalanobis distance) 为损失函数的自编码器网络流量异常检测方法^[21],具体结果如表 7 所示。从表 7 可以看出, MFC 相比其他几种方法在对应数据集上的表现似乎并不出众,只有在 UNSW-NB15 数据集上的召回率和 F1 值指标优于 RL-MD; 在 KDD99 和 NSL-KDD 数据集上的性能不如另外 2 个模型。虽然 K-Means & SVM 方法在 NSL-KDD 上表现出色,但是作为机器学习的检测方法,需要提前设计数据特征才能达到较好的检测效果,且无法做到对未知异常的检测。MFC 是深度学习模型不需要过多的特征工程辅助;另外,由于 MFC 使用正常数据建模,原则上还具备对未知异常流量的检测能力。PCA-BiGAN 在 KDD99 上的检测性能也优于本文方法,但仔细对比可以发现,PCA-BiGAN 的性能只是略好于 MFC,2 种检测方法的性能差距并不大,并且 MFC 的精确率和召回率都在 92%以上, MFC 在 KDD99 的表现也不错。总体看来,本文方法能够自动提取流量数据特征,具有较好的检测性能,对不同数据有较强的泛化能力,还可对未知异常进行检测。

表 7 与新检测方法的性能对比

| 模型 | 数据集 | 精确率 | 召回率 | F1 值 | 提前设计特征 | 检测未知异常 |
|---------------|-----------|---------|---------|---------|--------|--------|
| K-Means & SVM | NSL-KDD | 0.991 0 | 0.992 0 | 0.991 5 | 需要 | 不能 |
| PCA-BiGAN | KDD99 | 0.944 2 | 0.959 2 | 0.951 6 | 不需要 | 能 |
| RL-MD | UNSW-NB15 | 0.950 0 | 0.750 0 | 0.840 0 | 不需要 | 能 |
| MFC | KDD99 | 0.922 3 | 0.948 9 | 0.935 4 | 不需要 | 能 |
| | NSL-KDD | 0.946 1 | 0.950 6 | 0.948 3 | | |
| | UNSW-NB15 | 0.890 3 | 0.906 8 | 0.898 5 | | |

4 结束语

本文提出了一种基于多尺度特征的网络流量异常检测方法,通过提取网络流量在不同观察尺度和变换层级下的多尺度特征,以获取流量特征的多样性信息,用于识别和检测网络中的异常流量。本文主要利用滑动窗口和小波变换技术,捕获网络流量不同观察尺度和变换层级下的特征信息;利用链式 SAE 学习正常流量样本的分布,构建特征空间,

在特征空间可生成输入样本的重构样本。待测数据输入到训练好的模型,通过比较重构样本与输入样本之间的差异得到重构误差;各尺度的分类器将重构误差与阈值进行比较,进行初步的异常判定;最后按照“加权投票”的方式,对各尺度的初步判定结果进行汇总,完成最终结果的判别和输出。

实验结果证明,本文方法能够充分挖掘原始网络流量的多样性信息,有利于更好地发现网络中的异常数据,并且较其他传统的检测方法具有更加出

色的检测性能和泛化能力, 为实现大规模非平衡类别网络流量的异常检测提供了新思路。同时也验证了网络流量数据在不同尺度特征下能够表现出差异性的行为模式, 与仅从最细粒度的流量序列中提取特征相比, 充分考虑流量数据多尺度信息, 可在更大范围挖掘流量数据潜在的深层特征, 对于异常检测具有积极影响。

参考文献:

- [1] YUAN X Y, HE P, ZHU Q L, et al. Adversarial examples: attacks and defenses for deep learning[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2019, 30(9): 2805-2824.
- [2] 张成磊, 付玉龙, 李晖, 等. 6G 网络安全场景分析及安全模型研究[J]. *网络与信息安全学报*, 2021, 7(1): 28-45.
ZHANG C L, FU Y L, LI H, et al. Research on security scenarios and security models for 6G networking[J]. *Chinese Journal of Network and Information Security*, 2021, 7(1): 28-45.
- [3] AL-SANJARY O I, ROSLAN M A B, HELMI R A A, et al. Comparison and detection analysis of network traffic datasets using K-means clustering algorithm[J]. *Journal of Information & Knowledge Management*, 2020, 19(3): 2050026.
- [4] PARMAR N, SHARMA A, JAIN H, et al. Email spam detection using naive Bayes and particle swarm optimization[J]. 2020, 6(10): 367-373
- [5] 李洪成, 吴晓平, 姜洪海. 基于改进聚类分析的网络流量异常检测方法[J]. *网络与信息安全学报*, 2015, 1(1): 66-71.
LI H C, WU X P, JIANG H H. Traffic anomaly detection method in networks based on improved clustering algorithm[J]. *Chinese Journal of Network and Information Security*, 2015, 1(1): 66-71.
- [6] VIJAYANAND R, DEVARAJ D, KANNAPIRAN B. Support vector machine based intrusion detection system with reduced input features for advanced metering infrastructure of smart grid[C]//*Proceedings of 4th International Conference on Advanced Computing and Communication Systems*. Piscataway: IEEE Press, 2017: 1-7.
- [7] DA T, QU Y R, PRASANNA V K. Accelerating decision tree based traffic classification on FPGA and multicore platforms[J]. *IEEE Transactions on Parallel and Distributed Systems*, 2017, 28(11): 3046-3059.
- [8] JAIN M, KAUR G, SAXENA V. A K-Means clustering and SVM based hybrid concept drift detection technique for network anomaly detection[J]. *Expert Systems with Applications*, 2022, 193: 116510.
- [9] KHAN M, WANG H Z, RIAZ A, et al. Bidirectional LSTM-RNN-based hybrid deep learning frameworks for univariate time series classification[J]. *The Journal of Supercomputing*, 2021, 77(7): 7021-7045.
- [10] GOODFELLOW I, BENGIO Y, et al. *Deep learning*[M]. Cambridge: MIT Press, 2016.
- [11] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//*Proceedings of the 27th International Conference on Neural Information Processing Systems*. Massachusetts: MIT Press, 2014: 2672-2680.
- [12] KINGMA D P, WELING M. Auto-encoding variational Bayes[J]. *Statistics*, 2014, 10: 1-14.
- [13] BRYNIELSSON J, SHARMA R. Detectability of low-rate HTTP server DoS attacks using spectral analysis[C]//*Proceedings of IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining*. Piscataway: IEEE Press, 2015: 954-961.
- [14] 何炎祥, 曹强, 刘陶, 等. 一种基于小波特征提取的低速率 DoS 检测方法[J]. *软件学报*, 2009, 20(4): 930-941.
HE Y X, CAO Q, LIU T, et al. A low-rate DoS detection method based on feature extraction using wavelet transform[J]. *Journal of Software*, 2009, 20(4): 930-941.
- [15] CHENG M, LI Q, LV J M, et al. Multi-scale LSTM model for BGP anomaly classification[J]. *IEEE Transactions on Services Computing*, 2021, 14(3): 765-778.
- [16] WANG J Y, WANG Z, LI J F, et al. Multilevel wavelet decomposition network for interpretable time series analysis[C]//*Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM Press, 2018: 2437-2446.
- [17] FOULADI R F, ERMIŞ O, ANARIM E. A DDoS attack detection and countermeasure scheme based on DWT and auto-encoder neural network for SDN[J]. *Computer Networks*, 2022, 214: 109140.
- [18] ALBAHAR M A. Recurrent neural network model based on a new regularization technique for real-time intrusion detection in SDN environments[J]. *Security and Communication Networks*, 2019, 2019: 1-9.
- [19] PEI J M, ZHONG K Y, JAN M A, et al. Personalized federated learning framework for network traffic anomaly detection[J]. *Computer Networks*, 2022, 209: 108906.
- [20] ZONG B, SONG Q, MIN M R, et al. Deep autoencoding gaussian mixture model for unsupervised anomaly detection[C]//*Proceedings of International Conference on Learning Representations*. Vancouver: ICLR Press, 2018: 1-19.
- [21] YANG D H, HWANG M. Unsupervised and ensemble-based anomaly detection method for network security[C]//*Proceedings of 14th International Conference on Knowledge and Smart Technology*. Piscataway: IEEE Press, 2022: 75-79.
- [22] GEIGER A, LIU D Y, ALNEGHEIMISH S, et al. TadGAN: time series anomaly detection using generative adversarial networks[C]//*Proceedings of IEEE International Conference on Big Data (Big Data)*. Piscataway: IEEE Press, 2020: 33-43.
- [23] PATIL R, BIRADAR R, RAVI V, et al. Network traffic anomaly detection using PCA and BiGAN[J]. *Internet Technology Letters*, 2022, 5(1): e235.
- [24] 邹福泰, 谭越, 王林, 等. 基于生成对抗网络的僵尸网络检测[J]. *通信学报*, 2021, 42(7): 95-106.
ZOU F T, TAN Y, WANG L, et al. Botnet detection based on generative adversarial network[J]. *Journal on Communications*, 2021, 42(7): 95-106.
- [25] CHEN X H, DENG L W, HUANG F T, et al. DAEMON: unsupervised anomaly detection and interpretation for multivariate time series[C]//*Proceedings of IEEE 37th International Conference on Data Engineering*. Piscataway: IEEE Press, 2021: 2225-2230.

[26] 麻文刚, 张亚东, 郭进. 基于 LSTM 与改进残差网络优化的异常流量检测方法[J]. 通信学报, 2021, 42(5): 23-40.
 MA W G, ZHANG Y D, GUO J. Abnormal traffic detection method based on LSTM and improved residual neural network optimization[J]. Journal on Communications, 2021, 42(5): 23-40.

[27] CHOUHAN N, KHAN A, KHAN H U R. Network anomaly detection using channel boosted and residual learning based deep convolutional neural network[J]. Applied Soft Computing, 2019, 83: 105612.

[28] YANG S. Anomaly traffic detection based on LSTM[C]//Proceedings of IEEE 10th Joint International Information Technology and Artificial Intelligence Conference. Piscataway: IEEE Press, 2022: 667-670.

[29] ULLAH I, MAHMOUD Q H. Design and development of RNN anomaly detection model for IoT networks[J]. IEEE Access, 2022, 10: 62722-62750.

[30] SUGIARTAWAN P, PULUNGAN R, KARTIKA A. Prediction by a hybrid of wavelet transform and long-short-term-memory neural network[J]. International Journal of Advanced Computer Science and Applications, 2017, 8(2): 326-332.

[31] CHEN J L, LI Z P, PAN J, et al. Wavelet transform based on inner product in fault diagnosis of rotating machinery: a review[J]. Mechanical Systems and Signal Processing, 2016, 70/71: 1-35.



付钰 (1982-), 女, 湖北武汉人, 博士, 海军工程大学教授、博士生导师, 主要研究方向为信息安全、人工智能。



王坤 (1981-), 女, 河南信阳人, 海军工程大学博士生, 主要研究方向为信息安全。




刘涛涛 (1996-), 男, 江西吉水人, 海军工程大学博士生, 主要研究方向为网络安全、网络信息对抗。

[作者简介]



段雪源 (1981-), 男, 河南开封人, 海军工程大学博士生, 主要研究方向为人工智能、信息处理、网络安全。



李彬 (1998-), 男, 湖南娄底人, 海军工程大学硕士生, 主要研究方向为信息安全、人工智能。