

基于卷积神经网络的互联网流量异常检测研究

陈心怡

辽宁工程技术大学理学院, 辽宁 阜新 123000

摘要: 随着蓝牙技术的广泛应用, 其网络流量日益增大, 安全问题日益凸显。传统的异常检测方法在处理复杂、高维网络数据时存在效率低、依赖人工特征提取等局限性。本文提出一种基于卷积神经网络(CNN)的蓝牙网络异常检测模型。首先, 利用随机森林算法对网络流量特征进行重要性评估与筛选, 排除IP地址、端口等易误导模型的属性; 随后, 基于公开数据集 ISCX-IDS-2012 进行数据预处理, 将原始流量划分为统一长度的数据流; 最后, 构建包含四个卷积层、一个池化层和一个全连接层的 CNN 模型进行训练与验证。实验结果表明, 该模型在准确率和损失率方面均随迭代趋于稳定, 验证了 CNN 在蓝牙网络异常检测中的有效性与可行性。

关键词: 网络异常检测; 蓝牙网络; 卷积神经网络

1 引言

蓝牙凭借简易操作获得认可, 节能型数据传输手段, 是日常生活中实用的技术手段, 和有网络依赖的传输手段相区别, 借助蓝牙技术, 若干设备可组成临时无线网络, 若存在控制数据流量的需要, 即便身处网络服务中断的场所, 皆可传递文件, 伴随蓝牙连接的大规模覆盖, 通信流量稳步上升, 威胁态势随之形成, 既有异常检测方法中, 普遍采用时间序列分析手段, 神经网络及其衍生方法。

采用神经网络架构的卷积神经网络模型, 在视觉分类、语音转写及文本挖掘等多个维度体现显著价值, 现已拓展至异常检测场景, 该网络架构可实现特征的自动提取与降维处理, 实施多层卷积与池化组合, 具备数据多层次特征的挖掘能力, 从而在网络异常检测中显示出强大的实用性。

2 相关理论

2.1 卷积神经网络概述

卷积神经网络是一类结构较深的神经网络, 其核心在于卷积运算。鉴于此模型在处理图像输入时表现优异, 研究者可将图像直接作为输入, 从而规避了传统识别算法中繁冗的人工特征提取与数据管理流程。通过端到端的网络训练, 便能完成基础的异常检测。其典型架构包含输入层、卷积层、池化层、激活函数层以及全连接层。

2.2 蓝牙网络异常检测技术概述

网络攻击主要分为三类: 未经授权窃取信息、利用漏洞获取系统权限, 以及通过大量异常连接消耗资源的拒绝服务攻击。网络异常检测旨在通过技术手段提前发现这些异常行为, 以保障网络安全。

在检测方法上, 机器学习通过建立正常行

为基准识别异常, 主要包括统计模型、监督分类模型和无监督模型等。其中, 监督模型依赖标记数据进行训练, 而无监督模型可直接在线学习, 无需大量离线训练数据。

近年来, 深度学习被广泛应用于异常检测, 典型模型包括全连接神经网络(FNN)、卷积神经网络(CNN)及循环神经网络(RNN)等。相比传统方法, 深度学习凭借其非线性处理能力, 在海量数据环境中具有更高检测效率; 同时具备更强的自主学习能力, 减少了人工干预需求, 使检测过程更为高效和智能。

3 异常检测模型和方案设计

3.1 特征选择

3.1.1 随机森林

本文实验采用随机森林模型, 借助随机森林(RF)筛选显著特征, 随机森林由多棵决策树构成, 每棵决策树的创建阶段, 通过 Bootstrap 自助采样方法从原始数据集中进行随机抽取, 之后综合这些决策树的预测, 最终经筛选得出相应结论, 该模型对极端值和干扰因素表现出较强的抗干扰能力, 面对数据量庞大的情形时, 可于数据分析阶段即时获取特征重要性指标(variable importance measures, VIM)。

运用随机森林对流量特征做重要性分析, 即在特征分裂的节点, 决策结点分裂时的 Gini 改善量, 就样本集包含的每个特征量开展计算, 采用特征基尼指数差与全部特征差之和的比值, 求得归一化处理后的特征权重, 得出特征间的权重分布, 对各特征权重进行重要性对比与排序。

3.1.2 重要度评分

实施重要性权重核算时, 权重计算过程中不应涉及流ID、源/目的IP与端口、协议、时间戳以及外部IP这八项特征, 即便传统方案采用了这些机制, 攻击者或刻意避开常用端口以

逃避管控及系统规则限制，或是借助生成的虚假 IP 地址躲避追踪，大量端口采用动态分配机制，数据传输过程中存在多应用复用端口现象，模型训练若依据端口号易引发数据误判。

基于这一前提，区分攻击属性主次时，去除 IP 地址、端口号以及时间戳等无关特征的干扰，采用通用性强且稳定的特征定义攻击行为

效果更佳，因为数据的统计特征（如包长、流速等）能更稳定、有效地反映攻击行为的本质。

基于运算结果，各分析特征（后向流量包长度均值，数据包长度极值，流持续时长，前向报文平均长度，流速等成分的优先级得分见图 1：

重要度评分




图 1 重要度评分

3.2 数据处理

3.2.1 数据集的选择

本文选择以公开数据集 ISCX-IDS-2012 为实验数据集，此数据集来自加拿大的一个网络安全研究室，ISCX-IDS-2012 入侵检测评估数据集包含以下 7 天的网络活动（正常和恶意），如表 1 所示：

表 1 数据集的网络活动

攻击类型	包大小 (G)
正常活动，无恶意活动	16.1
正常活动，无恶意活动	4.22
从内部渗透网络 + 正常活动	3.95
HTTP 拒绝服务 + 正常活动	6.85
使用 IRC 僵尸网络的分布式拒绝服务	23.4
正常活动，无恶意活动	17.6
暴力 SSH+ 正常活动	12.3

由于它是使用真实设备构建的，所以创建了真实的正常和恶意流，包括 FTP，SMTP，HTTP，IMAP，SSH 等协议，且所有数据均已被标记。其中攻击种类繁多，包括渗透，拒绝服务，分布式拒绝服务和暴力 SSH，更真实的模拟了被攻击的环境，有利于真实环境的模拟，对现实的网络攻击环境更有参考和实用意义。

3.2.2 数据预处理

从下载的 pcap 文件数据集中，通过 Wireshark 可查看流量详情。由于网络流量数据高维，直接处理开销大，需进行预处理。首先，根据五元组（如 IP 和 MAC 地址）将数据包划分为数据流，每个数据流提取前 125 字节，并仅保留 4 个数据包；若数据包超过 4 个，则将该数据流分割成新流。随后，每种攻击类型的流量分别保存到 Excel 中。为消除无关特征影响（如 MAC 和 IP 地址），进行数据清理，去除这些特征，并对结果进行长度统一，以便后续使用随机森林算法筛选重要特征，并适配卷积神经网络处理。

3.3 网络异常检测模型

3.3.1 实验环境的搭建

本文使用的硬件环境：采用 Win10 操作系统，采用 Python 3.7 环境下的 PyTorch 深度学习平台，借助 PyTorch 功能完成模型拓扑设计及训练样本优化，实验样本的检验，PyTorch 作为 Python 生态中实现深度学习的核心工具库，初始操作应为 Python 环境集成 PyTorch 组件，采用 Anaconda 捆绑的 Python 环境，模块安装就绪后便可立即投入实验。

3.3.2 异常检测模型

基于卷积神经网络的蓝牙异常检测方案包括数据输入、数据预处理、卷积神经网络模型介绍及分类等模块和流程，具体如图 2 所示。

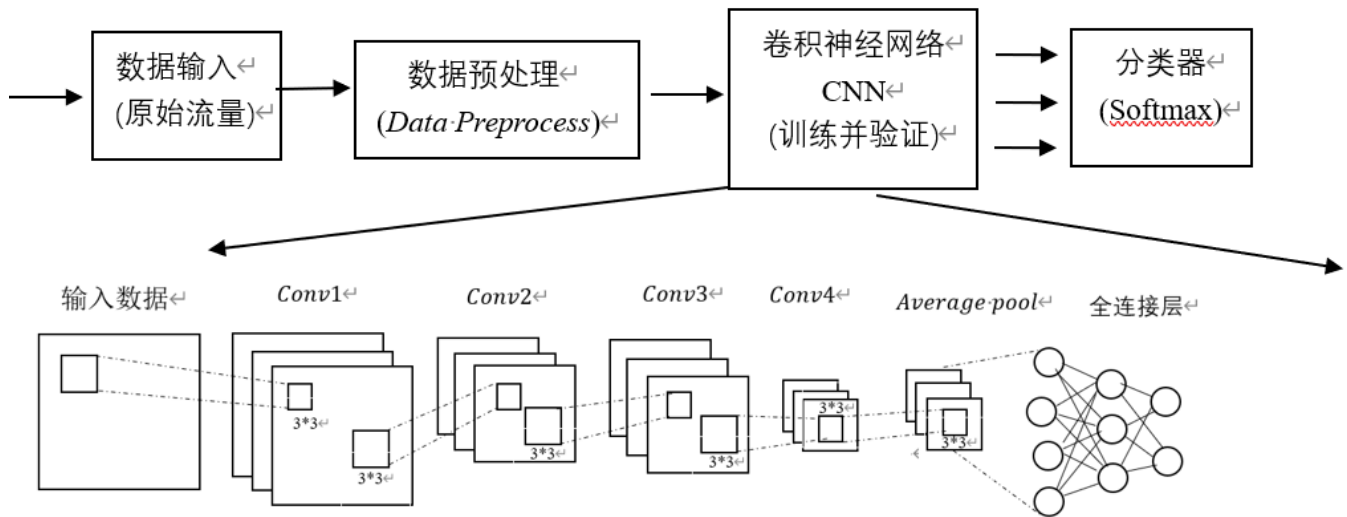


图 2 基于卷积神经网络的蓝牙异常检测方案

从图中可见，系统整合了四个卷积处理阶段，由均值池化层配合 Linear 全连接层组成，针对卷积层的配置阶段，四个卷积层统一采用 3×3 核结构，第三卷积模块采用 2 像素的滑动步长，特征图采用单像素宽度的填充，第四层卷积采用单位步长 $\text{stride}=1$ ，特征图采用单位宽度边界填充，经过单次卷积运算后，输出矩阵大小为 16 乘以 16，经过第二层卷积处理后，得到 8×8 规格的特征图，实施三层卷积变换后，得到的特征图依然是 8×8 大小；网络最终卷积输出阶段，得到 4×4 大小的输出特征图。平均池化层会得到整个窗口的平均值，可以消除局部极大或极小值带来的影响，使结果会更加稳定。全连接层（或称稠密层）的核心运算是线性变换 $y = Wx + b$ 。该运算本身结构简单。然而，

为了赋予网络非线性建模能力，每个全连接层之后通常会连接一个非线性激活函数。正是这种线性与非线性操作的交替堆叠，构成了深度神经网络强大的学习基础。

3.4 模型验证

将预处理后的数据集按 1:1 比例进行分割，规范化后的数据平均分配至训练集与实验集，数据准备工作就绪后，采用训练集样本对卷积神经网络实施模型训练，采用 PyTorch 作为 Python 的深度学习架构，进而通过实验数据集检验模型的可靠性，以检验模型的实用价值，进而输出训练精度及损失数值，实验结果显示，随着训练轮次增多，准确度与损失值最终趋于平稳，如图 3 呈现，准确率（Accuracy）伴随迭代次数累积趋向稳定。

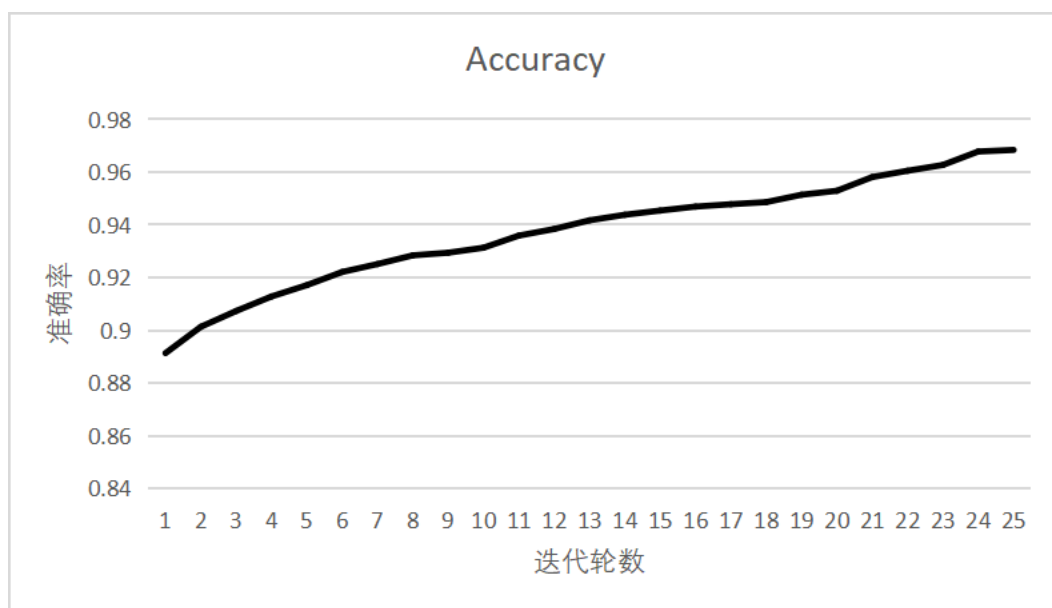


图 3 准确率随迭代轮数变化图

如图 4，表示随着迭代轮数的上升，数据损失率也会下降至平稳。




图 4 损失率随迭代轮数变化图

4 结论

本文针对蓝牙网络中的异常检测问题，设计并实现了一种基于卷积神经网络的检测模型。通过随机森林算法筛选关键特征，并结合 CNN 自动提取高维流量特征的能力，有效提升了检测的准确性与效率。实验采用公开数据集进行

训练与验证，结果表明模型在处理复杂网络流量时具有良好的稳定性和识别能力。该方法不仅减少了对人工特征工程的依赖，还为蓝牙网络安全提供了一种智能化的检测思路。未来研究可进一步优化模型结构，引入更多真实场景数据，以增强模型的泛化能力与实用性。

参考文献：

- [1] 吴迪锋, 孙昊翔, 曹浪等. 网络流量异常检测综述 [J]. 信息安全与通信保密, 2022, (08):101-111.
- [2] 刘海燕, 丛菲. 基于深度学习的网络入侵异常检测综述 [J]. 信息系统工程, 2020, (09):50-51.
- [3] 陈卓, 吕娜. 基于随机森林和 XGBoost 的网络入侵检测模型 [J]. 信号处理, 2020, 36(07):1055-1064.
- [4] 李光华, 李俊清, 张亮等. 一种融合蚁群算法和随机森林的特征选择方法 [J]. 计算机科学, 2019, 46(S2):212-215.
- [5] 邓华伟, 李喜旺. 基于深度学习的网络流量异常识别与检测 [J]. 计算机系统应用, 2023, 32(2): 274-280.

作者简介：陈心怡（2005.08—），女，汉族，河北省保定市，本科在读，研究方向：机器学习。