

文章编号 1672-6634(2023)06-0018-09

DOI 10.19728/j.issn1672-6634.2023040003

基于MDT-Net的物联网安全性能智能预测

曹书博¹,高志贺¹,李玉芳¹,周新鹏¹,徐凌伟^{1,2}

(1. 青岛科技大学 信息科学技术学院, 山东 青岛 266061; 2. 数字化学习技术集成与应用教育部工程研究中心, 北京 100039)

摘要 人工智能和大数据等新兴技术推动了多样化智能物联网(Internet of Things, IoT)应用的发展。物联网将在满足多样化智能应用的高吞吐量需求方面发挥重要作用。然而,由于物联网信道的开放性和多样性使得安全信息容易受到非法窃取,从而导致物联网通信网络中断和严重的信息安全问题,这限制了物联网在传输敏感数据领域的运用。为了实时处理复杂的物联网通信安全事件,准确的安全性能预测对于支持移动物联网网络至关重要。建立了基于解码转发协作的多天线安全通信系统模型,并对其性能进行了分析。此外,给出了安全中断概率(Security Outage Probability, SOP)表达式,并用于评估安全性能。为此,提出了一种基于MDT-Net的智能SOP预测算法。设计了MDT-Net模型,融合了MobileNet网络中深度可分离卷积模块,空洞卷积(Depthwise separable convolution)和Transformer网络结构,由多个深度可分离卷积模块,空洞卷积模块和Transformer模块组成。该方法适合物联网安全数据的非线性。实验证明,相比于其他算法,可以获得更好的物联网安全性能预测。特别是在预测精度方面,智能算法提高了98.9%。

关键词 物联网,物理层安全,安全性能预测,MDT-Net

中图分类号 TN929.5

文献标识码 A

开放科学(资源服务)标识码(OSID)



Internet of Things Security Performance Intelligent Prediction Based on MDT-Net

CAO Shubo¹, GAO Zhihe¹, LI Yufang¹,
ZHOU Xinpeng¹, XU Lingwei^{1,2}

(1. School of Information Science and Technology, Qingdao University of Science and Technology, Qingdao 266061, China;

2. Engineering Research Center of Integration and Application of Digital Learning
Technology, Ministry of Education, Beijing 100039, China)

Abstract Emerging technologies such as artificial intelligence and big data are driving the development of diversified Intelligent Internet of Things (Internet of Things, IoT) applications. IoT will play an important role in meeting the high throughput needs of diverse smart applications. However, due to the openness and diversity of IoT channels, security information is vulnerable to illegal theft, resulting in IoT communication network interruptions and serious information security problems, which limits the use of IoT in the

收稿日期: 2023-04-04

基金项目: 国家自然科学基金项目(62201313); 数字化学习技术集成与应用教育部工程研究中心创新基金项目(1221042)资助

通讯作者: 徐凌伟, 男, 汉族, 博士, 副教授, 研究方向: 智能信息与通信, E-mail: gaomilaojia2009@163.com。

field of transmitting sensitive data. To handle complex IoT security incidents in real time, accurate security performance predictions are critical to support mobile IoT networks. In this paper, a model of multi-antenna secure communication system based on decode-forward(DF) relay is proposed, and its performance is analyzed. In addition, the security outage probability(SOP) expressions are derived and used to evaluate security performance. Therefore, an intelligent SOP prediction algorithm based on MDT-Net is proposed. An improved MDT-Net model is designed, and it combines the characteristics of deep separable convolution, hollow convolution and transformer network structure. The model is composed of multiple deep separable convolution blocks, hollow convolution blocks and transformer modules. This method is suitable for the nonlinearity of the security data of the Internet of Things. Experiments show that compared with other algorithms, the intelligent algorithm proposed in this paper can achieve better security performance prediction of the Internet of Things. Especially in the prediction accuracy, the intelligent algorithm has improved by 98.9%.

Key words IoT; physical layer Security; security performance prediction; MDT-Net

1 引言

随着大数据、互联网+、区块链等前沿技术的充分整合和运用,物联网(Internet of Things, IoT)越来越呈现出强大的影响力和生命力^[1-3]。然而,由于物联网本身具有的开放性和多样性,如医疗和军事等信息安全传输过程中容易收到潜在的窃听风险,可能严重的信息安全问题。因此,越来越多的研究焦点聚集到物联网数据的安全可靠传输^[4-6]。文献[4]提出了一种用于IoT的区块链辅助隐私感知认证方案,以提供数据安全和隐私保护。在文献[5]中,提出了一种考虑属性加密的物联网隐私数据跨域安全共享模型,以解决数据共享时存在的安全隐患。文献[6]提出了集成多种安全技术的IoT安全框架。结果表明,这种方法可以有效地减小对物联网的威胁。

IoT环境的复杂性使得可靠的移动通信更加具有挑战性。例如,移动通信系统中的动态天线由于诸如衰落和散射的影响而导致信号退化。双瑞利和Nakagami-m信道衰落被广泛用于物理层安全性的研究^[7,8],但它们仅适用于单散射环境^[9]。文献[10]表明N-Nakagami信道模型能更好地表征多散射环境下的移动通信。因此,N-Nakagami信道模型得到了广泛应用。

为了保证安全可靠的通信,需要实时准确地预测安全性能。因此,移动IoT通信环境需要快速准确地监测和分析。机器学习,特别是深度学习广泛应用于IoT^[11-14]。文献[12]提出了一种基于深度信念神经网络的IoT威胁检测方案。文献[13]提出了一种基于深度学习的隐私保护与数据分析系统,可以防止存储在云服务器上的数据被泄露和窃取。

IoT移动通信环境的复杂性使得深度学习算法难以用于安全性能分析和预测。目前,基于物理层安全的通信安全性能预测算法研究尚处于起步阶段,特别是对于复杂多变的物联网通信场景,如何实现实时精确的物联网安全性能预测这一问题仍然没有得到较好的解决。为此,本文提出了一种改进神经网络智能算法作为一种新的解决方案,以实现对物联网系统的SOP性能进行实时高效预测。本文研究提出(1)建立了基于译码转发协作的移动安全通信系统模型,分析了该模型的安全中断概率(Secrecy Outage Probability, SOP)性能,并推导了其闭合表达式。(2)根据IoT通信数据的特点和要求,设计了融合MobileNet网络中深度可分离卷积模块,空洞卷积(Depthwise separable convolution)和Transformer的MDT-Net模型。模型有两个分支,第一个分支通过多个空洞卷积模块来减少参数的数量,而第二个分支使用深度可分离的卷积块来代替标准卷积。利用分支间的特征融合,提高了模型的精度,减少了模型参数的数量,从而减少了计算量。最后通过Transformer使用自注意力机制捕获输入序列的特征。MDT-Net模型可用于从物联网通信数据中提取重要特征。(3)提出了一种基于MDT-Net的智能SOP预测算法,实现了IoT通信安全性能的实时准确预测。将所提方法与MobileNet、Elman和小波神经网络(wavelet neural network, WNN)算法进行了性能比

较。实验证明,本文提出的 MDT-Net 算法能获得更好的安全性能预测,均方误差降低了 98.9%。

本文组织如下:第 2 节介绍了 IoT 通信系统模型。第 3 节分析了该模型的安全性,给出了闭式 SOP 表达式,第 4 节提出智能 MDT-Net 预测算法,第 5 节进行了性能分析,第 6 节给出了结论性评论。

2 IoT 安全通信系统模型

如图 1 所示 IoT 安全通信系统模型,移动源(MS)在中继(MR)的支持下与目的端(MD)进行通信,同时存在一个窃听端(ME)。\$G_{SR}, G_{RD}, G_{RE}\$ 分别为链路 \$MS \rightarrow MR\$, \$MR \rightarrow MD\$ 和 \$MR \rightarrow ME\$ 的位置增益。信道衰落系数 \$h_{(SR, RD, RE)}\$ 服从 2-Nakagami 分布^[15], MS 有 \$N_t\$ 天线。




图 1 IoT 安全通信系统模型

在第一个通信阶段, \$MS_i\$ 传输信号 \$x\$, MR 接收到的相应信号为

$$y_{SRi} = \sqrt{G_{SR}KE}h_{SRi}x + n_{SRi}, \quad (1)$$

式中 \$K\$ 和 \$E\$ 分别表示功率分配系数和系统的发射功率, \$n_{SRi}\$ 是均值和方差分别为 0 和 1 高斯噪声。

在第二阶段,在中继处采用 DF 译码转发该信号。在该策略中,如果中继 MR 能够恢复传输数据,它将会被重传到目的端 MD。否则,MD 不会接收任何数据。因此在 MD 和 ME 的接收信号为

$$y_{RD i} = \alpha (\sqrt{G_{RD}(1-K)}\bar{E}h_{RD i}x + n_{RD i}), \quad (2)$$

$$y_{RE i} = \alpha (\sqrt{G_{RE}(1-K)}\bar{E}h_{RE i}x + n_{RE i}), \quad (3)$$

式中 \$n_{RD i}\$ 和 \$n_{RE i}\$ 是均值和期望分别为 0 和 1 高斯噪声。当数据在中继 MR 处被恢复时, \$\alpha = 1\$, 否则 \$\alpha = 0\$。

MS 和 MR 之间的互信息表达为

$$I_{SRi} = \frac{1}{2} \log_2 (1 + \gamma_{SRi}), \quad (4)$$

式中 \$\gamma_{SRi}\$ 是 \$MS_i\$ 到 MR 链路的信噪比。考虑存在阈值 \$R_0\$, 如果 \$I_{SRi} > R_0\$, MR 可以恢复传输数据, 否则在 MR 处会发生中断。

3 SOP 分析

系统的信噪比为 \$\gamma_{ki}\$, \$k \in \{D, E\}\$, 系统安全容量阈值为 \$r_{th}\$。经过分析, \$\gamma_{ki}\$ 的概率密度函数和累积分布函数可以表示为

$$f_{\gamma_{ki}}(r) = \left(\begin{aligned} & \frac{1}{\prod_{t=1}^2 \Gamma(m_t)} G_{1,3}^{2,1} \left[\frac{r_{th}}{\gamma} \prod_{t=1}^2 \frac{m_t}{\Omega_t} \middle| \begin{matrix} 1, 1, 0 \\ 1, 1, 0 \end{matrix} \right] \delta(f) \\ & + \left(1 - \frac{1}{\prod_{t=1}^2 \Gamma(m_t)} G_{1,3}^{2,1} \left[\frac{r_{th}}{\gamma_{SRi}} \prod_{t=1}^2 \frac{m_t}{\Omega_t} \middle| \begin{matrix} 1, 1, 0 \\ 1, 1, 0 \end{matrix} \right] \right) \\ & \times \left(\frac{1}{r \prod_{t=1}^2 \Gamma(m_t)} G_{0,2}^{2,0} \left[\frac{r}{\gamma} \prod_{t=1}^2 \frac{m_t}{\Omega_t} \middle| \begin{matrix} 1, 1 \\ 1, 1 \end{matrix} \right] \right) \end{aligned} \right), \quad (5)$$

$$F_{\gamma_{ki}}(r) = \left(\frac{1}{\prod_{t=1}^2 \Gamma(m_t)} G_{1,3}^{2,1} \left[\frac{r_{th}}{\gamma_{SRi}} \prod_{t=1}^2 \frac{m_t}{\Omega_t} \mid_{1,1,0}^1 \right] + \left(1 - \frac{1}{\prod_{t=1}^2 \Gamma(m_t)} G_{1,3}^{2,1} \left[\frac{r_{th}}{\gamma_{SRi}} \prod_{t=1}^2 \frac{m_t}{\Omega_t} \mid_{1,1,0}^1 \right] \right) \times \frac{1}{\prod_{u=1}^2 \Gamma(m_u)} G_{1,3}^{2,1} \left[\frac{r}{\gamma_{Rki}} \prod_{u=1}^2 \frac{m_u}{\Omega_u} \mid_{1,1}^1 \right] \right), \quad (6)$$

式中

$$\bar{\gamma} = \frac{E}{N_0}, \quad (7)$$

$$\overline{\gamma_{SRi}} = G_{SRi} K \bar{\gamma}, \quad (8)$$

$$\overline{\gamma_{Rki}} = (1 - K) G_{Rki} K \bar{\gamma}. \quad (9)$$

瞬时安全容量表示为^[16]

$$C_i(\gamma_D, \gamma_E) = \max\{\ln(1 + \gamma_D) - \ln(1 + \gamma_E), 0\}. \quad (10)$$

安全中断概率(SOP)是评价通信系统安全性的常用方法。采用发射天线选择技术,安全中断概率为

$$F_{SOP} = \Pr\{\max_{1 \leq i \leq N_t} [C_i(\gamma_D, \gamma_E)] < \gamma_{th}\} \\ = \Pr\{\max\{\ln(1 + \gamma_D) - \ln(1 + \gamma_E), 0\} < \gamma_{th}\}^{N_t} \quad (11)$$

$$= \left\{ \int_0^\infty F_D(\beta\gamma_E + \beta - 1) f_E(\gamma_E) d\gamma_E \right\}^{N_t}, \\ \beta = \exp(\gamma_{th}). \quad (12)$$

4 基于 MDT-Net 的 SOP 智能预测算法

本节提出一种基于 MDT-Net 的 SOP 智能预测算法,该算法有以下 4 个步骤(1) 从收集到的数据中提取特征,创建通信数据集。将数据集划分为训练集和测试集;(2) 使用训练集训练网络模型;(3) 调整网络参数,得到最优网络模型;(4) 对优化模型进行测试,得到 SOP 预测结果。

4.1 数据集

MDT-Net 预测的数据集为 $\{T_n\}$, $T_n = (X_n, y_n)$ 。 y_n 利用公式(11)计算得到。6 个特征 K 、 G_{SR} 、 G_{RD} 、 G_{RE} 、 r_{th} 和 $\bar{\gamma}$, 分别是功率分配系数、MS 到 MR 链路的相对增益、MR 到 MD 链路的相对增益、MR 到 ME 链路的相对增益、安全容量阈值和平均信噪比。它们是影响 SOP 性能的关键参数。一方面确保这些关键参数在模型训练乃至预测过程中体现出影响和作用,另一方面不会因为过多的输入参数而导致数据集过大、训练速度慢等问题。这些特征构成了向量

$$X_n = (x_{n1}, x_{n2}, \dots, x_{n6}). \quad (13)$$

4.2 MDT-Net 网络结构

4.2.1 数据预处理。数据集中是二维条状数据,但输入数据最好是三维图像数据。因此,在数据预处理中, 1×6 数据被重

新塑造为 $1 \times 12 \times 12$ 。卷积已经被证明更适合于图像数据而不是条状数据。此外,图像维数据具有更多的特征信息,相关性通常更高,这有利于提取更多有效的特征。因此,对数据进行转换,如图 2 所示。




图 2 数据预处理过程

4.2.2 网络结构。所提出的轻量级 MDT-Net 结构如图 3 所示。MDT-Net 采用了三种网络结构构成了双分支网络。第一个是深度可分离卷积模块,第二个是空洞卷积模块,第三个是 Transformer 模块。深度可分离卷积分为深度卷积和点卷积,可以实现信道间的特征融合,增加或减少信道方向维数。文献结果表明,深度可分离卷积具有与标准卷积相似的性能,但计算复杂度较低。空洞卷积模块主要用来解决普通小卷积核卷积-池化-上采样中的信息丢失问题,可以在增加感受野的同时保持特征图的尺寸不变,从而代替下采样和上采样操作。Transformer 模块分为编码器和解码器,通过自注意力机制捕获输入序列的特征,相较于传统的循环神经网络模型具有更强大的模型表达能力和更高效的并行计算能力。




图 3 MDT-Net 网络结构




图 4 MDT-Net 网络结构第一分支模型

在 MDT-Net 结构的第一分支中,输入数据首先经过三层深度可分离的卷积块,然后通过批量归一化层

并使用 ReLU 激活函数进行激活得到 $400 \times 64 \times 2 \times 2$ 矩阵,深度可分离模块如图 4 所示。




图 5 MDT-Net 网络结构第二分支模型

在 MDT-Net 结构的第二个分支中,输入数据通过三层空洞卷积模块,空洞率分别是 1,2,2。然后通过批量归一化层并使用 ReLU 激活函数进行激活得到 $400 \times 64 \times 2 \times 2$ 矩阵,空洞卷积模块如图 5 所示。

通过特征融合连接两个分支的输出,以获得 $400 \times 64 \times 4 \times 4$ 矩阵。这些结果通过 Reshape 后得到 $1 \times 400 \times 512$ 的矩阵并输入到 Transformer 模块中,Transformer 的编码维度设为 512,head 设为 2。将输出降维后通过批量归一化层并使用 ReLU 激活函数进行激活得到 400×512 矩阵。将该矩阵输入到全连接层平化为 400×1 的一维矩阵,返回最终结果。

4.2.3 性能评价指标。在本文中,采用的性能指标是均方误差 (MSE),决定系数 (R^2),绝对误差 (MAE)和执行时间。MSE 和 R^2 为

$$MSE = \frac{\sum_{n=1}^k (x_n - \hat{x}_n)^2}{k}, \quad (14)$$

$$R^2 = 1 - \frac{\sum_{n=1}^k (x_n - \hat{x}_n)^2}{\sum_{n=1}^k (x_n - \bar{x}_n)^2}, \quad (15)$$

式中 k , x_n , $\hat{x}_n$ 分别为样本数,真实值和预测值。

4.2.4 基于 MDT-Net 的 SOP 预测。智能 SOP 预测算法如图 6 所示,其步骤如下。(1) 特征选择和数据集构建。将 6 个通信系统参数 $K, G_{SR}, G_{RD}, G_{RE}, r_{th}, \bar{\gamma}$ 作为特征 X_n ,通过式(11)得到输出 y_n 。那么数据集的元素是 $T_n = (X_n, y_n), n=1, 2, \dots, 2050$ 。(2) 网络初始化。采用均匀分布实现网络权重和偏差的随机初始化。学习率也被初始化。(3) MDT-Net 训练。训练集用于训练网络,通过对权重进行加权,直到误差达到可接受的水平。(4) MDT-Net 测试。利用测试集对训练好的 MDT-Net 进行测试验证,获得 SOP 预测精度。




图 6 基于 MDT-Net 的智能预测算法

5 SOP 性能结果

本节对 SOP 进行分析,将 MDT-Net 算法与 WNN^[17]、MobileNet^[18]、GR^[19]、ELM^[20] 和 LeNet^[21] 方法进行了比较。训练参数如表 1 所示,其中 x 和 y 分别为输入和输出的数量, lr 和 τ 分别为训练的学习率和扩散系数。

表 1 六种算法训练参数

MDT-Net	WNN	MobilNet	GR	ELM	LeNet
$x=6$	$x=6$	$x=6$	$x=6$	$x=6$	$x=6$
$y=1$	$y=1$	$y=1$	$y=1$	$y=1$	$y=1$
$lr=0.001$	$lr=0.0004$	$lr=0.001$	$\tau=0.02$		$lr=0.001$

如图 7-12 所示为 MDT-Net、WNN、MobileNet、GR、ELM 和 LeNet 算法的预测结果。这些结果表明,所提出的 MDT-Net 算法相比于其他算法可以提供了更好的 SOP 预测性能。




图 7 MDT-Net 预测




图 8 WNN 预测




图 9 MobileNet 预测




图 10 GR 预测




图 11 ELM 预测




图 12 LeNet 预测




图13 六种算法均方误差




图14 六种算法决定系数




图15 六种算法测试时间




图16 六种算法绝对误差

图13-16给出了六种算法的均方误差MSE、决定系数 R^2 、测试时间和绝对误差。从图13可以看出,本文采用的MDT-Net算法的MSE为0.00017,远低于其他算法。例如,该算法在MSE上比LeNet提高了98.9%。由图14可知,MDT-Net算法的决定系数为0.998,优于其他方法。同时,根据图15,MDT-Net网络具有较短的测试时间。由图16可知,所提出的MDT-Net网络也具有较低的MAE。因此,本文提出的MDT-Net算法具有最佳的综合性能。

6 总结

本文对物联网通信的安全性能分析和预测进行了研究。分析了SOP性能,并构建了深度学习的数据集,然后提出了一种基于MDT-Net的安全性能预测算法,用于实时分析物联网通信安全性能。仿真结果表明,该算法比WNN、MobileNet、GR、ELM、LeNet等方法具有更好的SOP预测效果。

参 考 文 献

- [1] 李源,张雨露,丁郁,等. 无源物联网通信研究进展与演进思考[J]. 物联网学报, 2023, 7(3): 1-13.
- [2] 蒋宇娜,葛晓虎,杨畅,等. 面向6G的区块链物联网数据共享和存储机制[J]. 通信学报, 2020, 41(10): 48-58.
- [3] 徐凌伟,林文. 移动多用户通信系统的中断概率性能研究[J]. 聊城大学学报(自然科学版), 2020, 33(2): 43-49.
- [4] JIA X Y, LUO M, WANG H Q, et al. A blockchain-assisted privacy-aware authentication scheme for internet of medical things[J]. IEEE Internet of Things Journal, 2022, 9(21): 21838-21850.
- [5] 徐凌伟,权天祺. 基于BP神经网络的移动安全性能预测[J]. 聊城大学学报(自然科学版), 2020, 33(3): 34-40.
- [6] KUMARI, MUTHULAKSHMI S, AGARWAL P D. Deployment of machine learning based internet of things networks for tele-medical and remote healthcare[J]. Data Engineering and Communications Technologies, 2022, 116: 305-317.
- [7] AI Y, CHEFFENA M, MATHUR A, et al. On physical layer security of double rayleigh fading channels for vehicular communications[J]. IEEE Wireless Communications Letters, 2018, 7(6): 1038-1041.

- [8] PANDEY A, YADAV S. Physical layer security in cooperative af relaying networks with direct links over mixed rayleigh and double-rayleigh fading channels[J]. IEEE Transactions on Vehicular Technology, 2018, 11(67): 10615-10630.
- [9] ILHAN H, UYSAL M, ALTUNBAS I. Cooperative diversity for intervehicular communication: performance analysis and optimization [J]. IEEE Transactions on Vehicular Technology, 2009, 7(58): 3301-3310.
- [10] KARAGIANNIDIS G K, SAGIAS N C, MATHIOPOULOS P T. N-Nakagami: A novel stochastic model for cascaded fading channels [J]. IEEE Transactions on Communications, 2007, 8(55): 1453-1458.
- [11] SUN H, LIU Z, WANG G Z, et al. Intelligent analysis of medical big data based on deep learning[J]. IEEE Access, 2019, 7: 142022-142037.
- [12] MANIMURUGAN S, ALMUTAIRI S, ABOROKBAH M M, et al. Effective attack detection in internet of medical things smart environment using a deep belief neural network[J]. IEEE Access, 2020, 8: 77396-77404.
- [13] BI H L, LIU J J, KATO N. Deep learning-based privacy preservation and data analytics for IoT enabled healthcare[J]. IEEE Transactions on Industrial Informatics, 2022, 7(18): 4798-4807.
- [14] 徐凌伟, 权天祺. 移动协作通信系统中断概率性能智能预测[J]. 聊城大学学报(自然科学版), 2020, 33(6): 33-39.
- [15] XU L W, WANG H, GULLIVER T A. Outage probability performance analysis and prediction for mobile IoV networks based on ICS-BP neural network[J]. IEEE Internet of Things Journal, 2021, 8(5): 3524-3533.
- [16] BLOCH M, BARROS J, RODRIGUES M R, et al. Wireless information-theoretic security[J]. IEEE Transactions on Information Theory, 2008, 54(6): 2515-2534.
- [17] KISKIN I, ZILLI D, LI Y P, et al. Bioacoustic detection with wavelet-conditioned convolutional neural networks[J]. Neural Computing and Applications, 2020, 32(4): 915-927.
- [18] YANG J, WANG Y, ZHAO H T, et al. MobileNet and knowledge distillation-based automatic scenario recognition method in vehicle-to-vehicle systems[J]. IEEE Transactions on Vehicular Technology, 2022, 71(10): 11006-11016.
- [19] FALAHATRAFTAR F, PIERRE S, CHAMBERLAND S. An intelligent congestion avoidance mechanism based on generalized regression neural network for heterogeneous vehicular networks[J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(4): 3106-3118.
- [20] ZHU Y C, ZHENG Y. Traffic identification and traffic analysis based on support vector machine[J]. Neural Computing and Applications, 2020, 32(7): 1903-1911.
- [21] DU B L, HE Y G, HE Y Z, et al. Intelligent classification of silicon photovoltaic cell defects based on eddy current thermography and convolution neural network[J]. IEEE Transactions on Industrial Informatics, 2020, 16(10): 6242-6251.

(责任编辑:刘庆松)