

引用:李天成,薛培友,徐凌伟. 基于 GConvGRU-GAT 的车联网安全性能智能预测方法研究[J]. 聊城大学学报(自然科学版),2025,38(4):507-515.

Citation:LI Tiancheng,XUE Peiyou,XU Lingwei. Research on intelligent prediction method of internet of vehicles security performance based on GConvGRU-GAT[J]. Journal of Liaocheng University (Natural Science Edition),2025,38(4):507-515.

文章编号 1672-6634(2025)04-0507-09

DOI 10.19728/j.issn1672-6634.2024090010

基于 GConvGRU-GAT 的车联网安全性能 智能预测方法研究

李天成^{1,2},薛培友¹,徐凌伟^{1,2}

(1. 安徽省普通高校交通信息与安全重点实验室,安徽 合肥 230601; 2. 青岛科技大学 信息科学技术学院,山东 青岛 266061)

摘要 随着 5G 技术和物联网的不断发展,车联网业务层出不穷,其应用场景也越来越复杂多变。在车联网通信过程中,安全性能受车联网复杂多变环境的影响,难以进行实时准确的预测。因此,本文提出了一种基于 GConvGRU-GAT 的车联网安全性能智能预测方法。首先在 N -Nakagami 信道下,建立了车联网安全通信系统模型,并通过检测通信链路信噪比来进行安全性能分析,有效分析不同影响因素对安全性能的影响,构建了通信数据集。为了更好的对通信系统进行实时预测,本文融合了图注意力神经网络(Graph Attention Network,GAT)、图卷积神经网络(Graph Convolutional Network,GCN)和门控循环单元(Gated Recurrent Unit,GRU),设计了基于 GConvGRU-GAT 的移动安全性能预测网络模型。试验结果表明,相较于其他算法,GConvGRU-GAT 算法具有更好的预测效果,比 GCN 模型性能提高了 84.6%。

关键词 车联网;安全通信;安全性能预测;图注意力神经网络

中图分类号 TP183;TN915.08

文献标志码 A

开放科学(资源服务)标识码(OSID)



Research on intelligent prediction method of internet of vehicles security performance based on GConvGRU-GAT

LI Tiancheng^{1,2},XUE Peiyou¹,XU Lingwei^{1,2}

(1. Key Laboratory of Traffic Information and Safety of Anhui Higher Education Institutes, Anhui Sanlian University, Hefei 230601, China; 2. College of Information Science and Technology, Qingdao University of Science and Technology, Qingdao 266061, China)

Abstract With the continuous development of 5G technology and the Internet of Things, the Internet of Vehicles business is emerging in an endless stream, and its application scenarios are becoming more and more complex and changeable. In the communication process of Internet of Vehicles, the security performance is affected by the complex and ever-changing environment of the vehicle networking, making it difficult to make real-time and accurate predictions. Therefore, this paper proposes an intelligent prediction method for the security performance of the Internet of Vehicles based on GConvGRU-GAT in this paper. Firstly, under the N -Nakagami channel, a model of the secure communication system of the Internet of

收稿日期:2024-09-19

基金项目:国家自然科学基金项目(62201313);安徽省普通高校交通信息与安全重点实验室开放课题(JTX202404)资助

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

Vehicles was established, and the security performance was analyzed by detecting the signal-to-noise ratio of the communication link, and the influence of different influencing factors on the security performance was effectively analyzed, and the communication dataset was constructed. In order to better predict the communication system in real time, this paper integrates Graph Attention Network (GAT), Graph Convolutional Network (GCN) and Gated Recurrent Unit (GRU) to design a mobile security performance prediction network model based on GConvGRU-GAT by integrating Graph Attention Network (GAT), Graph Convolutional Network (GCN) and Gated Recurrent Unit (GRU). Experimental results show that compared with other algorithms, the GConvGRU-GAT algorithm has better prediction effect, and the performance is improved by 84.6% compared with the GCN model.

Keywords internet of vehicles; secure communications; security performance prediction; graph attention neural network

0 引言

随着 5G、云计算、大数据等新一代信息技术的飞速发展,车联网已成为全球新一轮科技革命与产业变革的重要驱动力^[1]。车联网能够实现车与车、车与基础设施、车与行人之间的互联互通,提高交通运行效率 and 安全性^[2]。5G 技术具有大带宽、高速连接能力和低时延等优势,可支持车联网应用的实时性和安全性要求。在大数据、大算力、大模型等技术的加持下,5G 与人工智能正加速在车联网领域实现融合应用。车联网的网络通信能力、感知计算水平以及创新业务应用都在快速发展^[3]。车联网的应用场景日趋多元,无人驾驶巴士、无人配送物流车等新型交通工具的出现,进一步丰富了车联网的应用领域,推动了智慧交通的发展^[4]。

随着车联网技术的快速发展,车联网兼容多种智能交通应用,车辆数据传输安全和用户隐私保护成为日益重要的议题^[5-6]。张文芳等人提出了基于无证书聚合签名的车联网匿名认证与密钥协商协议^[7]。刘健等人通过对椭圆曲线的数字签名算法的研究,设计了一个可溯源车联网匿名签名和批量验证方案^[8]。张海波等人提出了一种双阶段的认证密钥协商协议,提高了通勤车辆在车联网中向路边单元获取服务的安全与效率^[9]。为了更好的保护车联网中的数据隐私安全,刘雪艳等人提出了一种支持批量验证的非线性对的无证书匿名认证方案^[10]。除此之外,郭显等人提出了基于区块链的去中心化可撤销隐私保护自主管理身份方案^[11]。

但是车联网移动终端分布于动态环境中,通信特征与传统网络有很大差异,带来了复杂变化的新型网络安全环境 and 安全风险。为了进一步提升车联网数据传输的安全性,深度学习方法在安全通信中得到了广泛研究。王为念等人提出了一种基于多智能体深度强化学习的车联网频谱分配算法来收集和管理瞬时信道状态信息^[12]。雒江涛等人提出一种基于强化学习的联合内容缓存和功率分配算法来解决接入设备和缓存设备之间有限资源矛盾问题^[13]。廖勇等人提出基于图神经网络的单载波频分多址智能信道估计算法^[14]。张海波等人设计了一种基于深度学习网络的博弈算法,通过神经网络的迭代学习来帮助车辆用户进行信道选择^[15]。谭国平等人提出一种基于近端策略优化的分布式深度强化学习算法来使得处理任务时延与能耗之间达到最佳均衡^[16]。章坚武等人提出了深度强化学习双阶段在线卸载算法来缓解任务卸载决策不理想的问题^[17]。

车联网安全通信性能预测是车联网技术发展的重要方向,其目的是通过对车联网系统中各种因素的影响进行分析和预测,优化系统安全性能,提高车联网的可靠性和安全性^[18]。但是,移动车联网用户具有动态性,通信环境复杂多变,这使得车联网安全通信面临很大挑战。现有方法多从单一视角出发,关注个别影响因素,未能全面反映车联网在复杂动态环境下的安全需求。此外,部分方法依赖于固定基础设施,导致在移动场景中无法实现即时响应与自适应。因此,本文提出了一种基于 GConvGRU-GAT 的车联网安全性能智能预测方法:在 N -Nakagami 信道下,建立了移动多用户通信系统模型,并对其安全性能进行了分析,研究了移动多用户通信系统的安全性能;本文提出的网络结合了图卷积(Graph Convolution)的拓扑结构感知能力和门控循环单元(GRU)的时序建模能力,并在每个门中都有对应的 ChebConv 层来进行卷积,除此之

外,模型在每个 ChebConv 层后有添加了 GAT 卷积层来进一步提取特征,能够更好的处理邻居节点的信息,提高模型的预测性能;同 Graph Convolution Network(GCN),GCN-LSTM,Wavelet Neural Network(WNN)和 MDT-NET 模型相比,本文提出的 GConvGRU-GAT 模型在均方误差(Mean Squared Error, MSE),绝对误差(Mean Absolute Error, MAE),决定系数以及运行时间方面均有更好的表现。MSE 和 MAE 分别为 0.022 和 0.103,均为对比网络中的最低值,预测性能最佳;决定系数为 0.826,比 GCN 网络提高了 84.6%。

1 车联网安全性能分析

1.1 车联网安全通信系统模型

车联网安全通信系统模型,模型由四部分组成(图 1 所示),分别为移动源(MS),中继(MR),目的端(MD)和窃听端(ME)。MS 通过 MR 与 MD 进行通信,ME 窃听用户信息。移动源有 N_t 根天线。MS 到 MR,MR 到 ME 和 MR 到 MD 三条链路对应的位置增益分别标记为 G_{SR} , G_{RE} , G_{RD} 。三条链路的信道增益 $h_{(SR, RD, RE)}$ 都服从 N -Nakagami 分布^[19]。

在 MS 到 MR 的通信过程中,MS_{*i*} 的传输信号表示为 x ,MR 端接收的信号计算公式为 $y_{SR_i} = \sqrt{G_{SR}KE}h_{SR_i}x + n_{SR_i}$ 其中,功率分配系数由 K 表示,系统的发射功率由 E 表示, n_{SR} 表示的是均值为 0,期望为 1 的高斯噪声。

在通信的第二阶段,MR 采用译码转发的策略。具体来说,当 MR 能够成功恢复传输的数据时,它会将数据重新发送给 MD;而如果无法恢复数据,MD 将无法接收到任何信号。因此,MD 和 ME 接收到的信号为: $y_{RD_i} = \alpha(\sqrt{G_{RD}(1-K)E}h_{RD_i}x + n_{RD_i})$, $y_{RE_i} = \alpha(\sqrt{G_{RE}(1-K)E}h_{RE_i}x + n_{RE_i})$ 其中, n_{RD_i} 和 n_{RE_i} 表示均值为 0、方差为 1 的高斯噪声。当 MR 成功恢复数据时, α 取值为 1;如果无法恢复,则 α 为 0。

MS 与 MR 之间的互信息计算公式为: $I_{SR_i} = \frac{1}{2} \log_2(1 + \gamma_{SR_i})$ 其中, γ_{SR_i} 表示 MS_{*i*} 到 MR 的信噪比。

R_0 表示门限信息速率,是预先给定好的。如果 $I_{SR_i} > R_0$,则 MR 能够实现完全译码。MD 和 ME 的接收信噪比表示为 $\gamma_k = \frac{G_{Rk}(1-K)|h_{Rk}|^2E}{N_0} = G_{Rk}(1-K)|h_{Rk}|^2\bar{\gamma}$, N_0 为噪声功率。

如果 $I_{SR_i} < R_0$,则 MR 不能完成完全译码,会发生中断现象,ME 和 MD 的瞬时接收信噪比为 0。

1.2 安全性能分析

γ_{ki} 表示系统的信噪比,其中 $k \in \{D, E\}$,系统的安全容量阈值用 r_{th} 表示。信噪比 γ_{ki} 的累积分布函数和概率密度函数的计算公式^[20]为

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

$$\left(\frac{1}{r \prod_{t=1}^2 \Gamma(m_t)} G_{0,2}^{2,0} \left(\frac{r}{\gamma} \prod_{t=1}^2 \frac{m_t}{\Omega_t} \middle| \begin{matrix} 1 \\ 1, 1 \end{matrix} \right) \right), F_{\gamma_{ki}}(r) = \frac{1}{\prod_{t=1}^2 \Gamma(m_t)} G_{1,3}^{2,1} \left[\frac{r_{th}}{\gamma_{SR_i}} \prod_{t=1}^2 \frac{m_t}{\Omega_t} \middle| \begin{matrix} 1 \\ 1, 1, 0 \end{matrix} \right] + \left(1 - \frac{1}{\prod_{t=1}^2 \Gamma(m_t)} G_{1,3}^{2,1} \times \right.$$

$$\left. \left[\frac{r_{th}}{\gamma_{SR_i}} \prod_{t=1}^2 \frac{m_t}{\Omega_t} \middle| \begin{matrix} 1 \\ 1, 1, 0 \end{matrix} \right] \right) \times \frac{1}{\prod_{tt=1}^2 \Gamma(m_{tt})} G_{1,3}^{2,1} \left[\frac{r}{\gamma_{Rki}} \prod_{tt=1}^2 \frac{m_{tt}}{\Omega_{tt}} \middle| \begin{matrix} 1 \\ 1, 1, 0 \end{matrix} \right] \text{ 其中 } \bar{\gamma} = E/N_0, \gamma_{SR_i} = G_{SR_i}K\bar{\gamma}, \gamma_{Rki} = (1 -$$




图1 车联网安全通信系统模型

Fig. 1 Internet of Vehicles security communication system model

$K)G_{Rki}K\gamma$ 。瞬时安全容量表示为 $C_i(\gamma_D, \gamma_E) = \max\{\ln(1 + \gamma_D) - \ln(1 + \gamma_E), 0\}$ 。

非零安全中断概率是衡量通信系统安全性的重要指标。本文采用了发射天线选择技术,那么其表示为 $F = 1 - \Pr\{\max\{\ln(1 + \gamma_D) - \ln(1 + \gamma_E), 0\} < 0\}^{N_t}$ 。

通过以上公式计算车联网系统的非零安全中断概率,并将其作为评估系统安全性能的指标,结合系统中的各个特征指标生成训练数据集,用于预测模型的训练。

2 基于 GConvGRU-GAT 的安全性能智能预测算法

如图 2 所示,本文提出了一种 GConvGRU-GAT 的安全性能智能预测算法。本文设计了 GConvGRU-GAT 神经网络,其在 GConvGRU 每个门结构中融入 GAT 卷积层,可以更好的捕捉时间序列数据中的时空依赖关系。

2.1 数据预处理

本文的数据集为 $\{T_n\}$, $T_n = (X_n, y_n)$ 。 X_n 主要包括 6 个特征,分别是 $K, G_{SR}, G_{RD}, G_{RE}, r_{th}$ 和 γ 。

将生成的 X_n 转化为图结构数据,包括节点特征矩阵和邻接矩阵。其中节点特征矩阵的大小为 $M \times D$,行数 M 代表的是节点的数量,列数 D 表示每个节点的特征向量维度,这个矩阵可以用来表示图中所有节点的特征向量。在此数据集中, M 为 368, D 为 6。邻接矩阵是一个 $2 \times n$ 的稀疏矩阵,表示图中节点之间的连接关系,第一行代表边的起点,第二行代表边的终点。

首先将每一条原始数据作为图中的节点,数据的特征向量表示图中节点的特征向量,构建出图节点的特征矩阵。然后,基于特征矩阵通过使用传递熵来构建图的邻接矩阵。图 3 是数据预处理流程图:




图 2 智能预测算法

Fig. 2 Intelligent prediction algorithm




图 3 数据预处理

Fig. 3 Data preprocessing

2.2 GConvGRU-GAT 网络

GConvGRU-GAT 网络可以很好的处理图结构数据中的时序信息。网络结构主要由三个部分组成:GRU 循环神经网络,ChebConv 卷积层,GAT 卷积层。它融合了图卷积 (Graph Convolution) 的拓扑结构感知能力和门控循环单元 (GRU) 的时序建模能力,并且在 GRU 每个门后插入 GAT 卷积层,使得网络能够更有效地从图结构数据中提取时空特征,可以应用于各种时序预测任务。GConvGRU-GAT 网络结构如图 4 所示。




图4 GConvGRU-GAT 网络结构图

Fig. 4 GConvGRU-GAT network structure diagram




图5 GRU 结构图

Fig. 5 GRU structure diagram

2.2.1 GRU 结构。门控循环单元 (GRU) 是一种循环神经网络,能够学习时序数据中的依赖关系。GConvGRU-GAT 网络使用 GRU 来建模节点特征随时间的变化。GRU 包含 3 个门:更新门 (Update Gate)、重置门 (Reset Gate) 和候选状态 (Candidate State),各门之间的关系如图 5 所示。

更新门 (Update Gate): 更新门控制着当前状态和前一状态的融合比例, $\tilde{h}_t$ 决定了当前状态对历史信息的依赖程度。更新门的值介于 0 到 1 之间,接近 1 表示更多地保留前一状态的信息,接近 0 表示更多地使用当前输入的信息。更新门为 $Z_t = \sigma(X_t W_{xz} + H_{t-1} W_{hz} + b_z)$ 。

重置门 (Reset Gate): 前一状态信息的遗忘状态由重置门控制,同时也控制着当前状态对历史信息的记忆程度。重置门的值也介于 0 到 1 之间,接近 1 表示完全保留前一状态的信息,接近 0 表示完全遗忘前一状态的信息。重置门为: $R_t = \sigma(X_t W_{xr} + H_{t-1} W_{hr} + b_r)$ 。

候选状态 (Candidate State): 候选状态是基于当前输入和前一状态计算得到的,反映了当前状态的潜在变化趋势。候选状态通过一个非线性激活函数 (例如 $\tanh$) 来计算,它决定了当前状态的具体变化方向。候选状态为: $\tilde{H}_t = \tanh(X_t W_{xh} + (R_t \odot H_{t-1}) W_{hh} + b_h)$ 。

其中 $(R_t \odot H_{t-1})$ 使用了上一时刻的隐状态和重置门进行哈达玛积。哈达玛积就是对应元素按乘法运算,即 $c_{ij} = a_{ij} \times b_{ij}$, 这里 a, b 矩阵同维。

2.2.2 ChebConv 层。ChebConv 图卷积层是 GConvGRU-GAT 网络的核心,它利用 Chebyshev 多项式来近似图卷积操作,能够有效地捕获图结构中的局部信息。ChebConv 层都使用 $K=4$ 的卷积核,并将输出通道数设置为 1。Chebyshev 图卷积层通过对节点的邻居节点进行加权求和,来计算每个节点的特征,权重由 Chebyshev 多项式决定,从而实现了图结构的感知,图 6 为 Chebyshev 卷积示意图。

2.2.3 GAT 卷积层。每个 ChebConv 层之后都连接着两层 GAT 卷积层,以进一步提取图中的特征。GAT 卷积层使用注意力机制来学习不同节点之间的关系,并聚合来自邻居节点的信息。GATConv 能够同时考虑节点之间的关系和节点状态之间的演化,利用 GAT 的信息传递能力来处理复杂的图序列数据,具有很强的适应性和泛化性,并且可以在一定程度上缓解图卷积的过拟合问题。GAT 通过注意力机制来学习不同节点之间的权重,从而更好地聚合不同节点的信息。捕捉长距离的上下文信息,提高模型的表示能力,在不同尺度上共享参数,减少了模型的参数量,提高了训练和推理的效率,图 7 为 GAT 卷积层计算过程。




图6 ChebConv 图卷积层

Fig. 6 ChebConv diagram convolution layer




图7 GAT卷积层计算流程

Fig. 7 GAT convolutional layer calculation flow

2.2.4 模型输出。最终,数据经过 GRU、ChebConv 卷积层和 GAT 卷积层后分别进行输出,得到 Z 、 R 和 H_{tilde} 三个值,将三个输出值进行如下公式计算后得到最终的隐藏状态 H 。计算公式为: $H = Z * H + (1 - Z) * H_{\text{tilde}}$

本文设计的网络结构对于时空特征提取有一定的优势,使得 GConvGRU-GAT 网络能够有效地从图结构数据中提取时空特征,适用于处理具有时间依赖性的图结构数据。不仅如此,还可以加强拓扑结构的感知,GRU 模块能够学习时序数据中的依赖关系,提高网络对时间变化的建模能力。ChebConv 图卷积层和 GAT 卷积层能够有效地捕获图结构中的局部信息,提高网络对图结构数据的理解能力。很好的利用了网络的时序建模能力。

2.3 安全性能智能预测算法

安全性能智能预测算法如图 8 所示。算法代码如算法 1 所示。

3 仿真结果

在本节中,本文采用的评估指标分别为均方误差 (M_{SE}),计算公式为 $M_{\text{SE}} = \frac{1}{k} \sum_{n=1}^k (x_n - \hat{x}_n)^2$, 绝对误差 (M_{AE}),计算公式为 $M_{\text{AE}} = \frac{1}{k} \sum_{n=1}^k |y_n - \hat{y}_n|$, 决定




图8 算法流程图

Fig. 8 Algorithm flow chart

算法1 GConvGRU-GAT 安全性能智能预测算法

输入:节点特征 X ,边索引 $edge_index$,边权重 $edge_weight$,隐藏状态 H ,拉普拉斯矩阵最大特征值 λ_{max}

输出:隐藏状态 H

1. 初始化参数

```
in_channels = 6 # 输入通道数
out_channels = 1 # 输出通道数
K = 4 # Chebyshev 滤波器大小
normalization = "sym" # 归一化方案
bias = True # 是否使用偏置
```

2. 创建更新门参数和层

```
conv_x_z = ChebConv(in_channels, out_channels, K, normalization, bias) # ChebConv 层用于处理节点特征
conv_h_z = ChebConv(out_channels, out_channels, K, normalization, bias) # ChebConv 层用于处理隐藏状态
GAT_x_z = GATConv(in_channels, out_channels, heads=1, dropout=0.6) # GATConv 层用于处理节点特征
GAT_h_z = GATConv(out_channels, out_channels, heads=1, dropout=0.6) # GATConv 层用于处理隐藏状态
```

3. 创建重置门参数和层

```
conv_x_r = ChebConv(in_channels, out_channels, K, normalization, bias) # ChebConv 层用于处理节点特征
conv_h_r = ChebConv(out_channels, out_channels, K, normalization, bias) # ChebConv 层用于处理隐藏状态
GAT_x_r = GATConv(in_channels, out_channels, heads=1, dropout=0.6) # GATConv 层用于处理节点特征
GAT_h_r = GATConv(out_channels, out_channels, heads=1, dropout=0.6) # GATConv 层用于处理隐藏状态
```

4. 创建候选状态参数和层


```
conv_x_h = ChebConv(in_channels, out_channels, K, normalization, bias) # ChebConv 层用于处理节点特征
conv_h_h = ChebConv(out_channels, out_channels, K, normalization, bias) # ChebConv 层用于处理隐藏状态
GAT_x_h = GATConv(in_channels, out_channels, heads=1, dropout=0.6) # GATConv 层用于处理节点特征
GAT_h_h = GATConv(out_channels, out_channels, heads=1, dropout=0.6) # GATConv 层用于处理隐藏状态
```

5. 前向传播

```
def forward(X, edge_index, edge_weight, H, lambda_max):
    # 初始化隐藏状态
    if H is None:
        H = torch.zeros(X.shape[0], out_channels).to(X.device) # 如果没有提供隐藏状态,则将其初始化为零
    # 计算更新门
    Z = conv_x_z(X, edge_index, edge_weight, lambda_max) # 使用 ChebConv 层处理节点特征
    Z = Z + conv_h_z(H, edge_index, edge_weight, lambda_max) # 使用 ChebConv 层处理隐藏状态
    Z = Z + GAT_x_z(X, edge_index, edge_weight) # 使用 GATConv 层处理节点特征
    Z = Z + GAT_h_z(H, edge_index, edge_weight) # 使用 GATConv 层处理隐藏状态
    Z = torch.sigmoid(Z) # 使用 sigmoid 函数激活更新门
    # 计算重置门
    R = conv_x_r(X, edge_index, edge_weight, lambda_max) # 使用 ChebConv 层处理节点特征
    R = R + conv_h_r(H, edge_index, edge_weight, lambda_max) # 使用 ChebConv 层处理隐藏状态
    R = R + GAT_x_r(X, edge_index, edge_weight) # 使用 GATConv 层处理节点特征
    R = R + GAT_h_r(H, edge_index, edge_weight) # 使用 GATConv 层处理隐藏状态
    R = torch.sigmoid(R) # 使用 sigmoid 函数激活重置门
    # 计算候选状态
    H_tilde = conv_x_h(X, edge_index, edge_weight, lambda_max) # 使用 ChebConv 层处理节点特征
    H_tilde = H_tilde + conv_h_h(H * R, edge_index, edge_weight, lambda_max) # 使用 ChebConv 层处理隐藏状态
    H_tilde = H_tilde + GAT_x_h(X, edge_index, edge_weight) # 使用 GATConv 层处理节点特征
    H_tilde = H_tilde + GAT_h_h(H * R, edge_index, edge_weight) # 使用 GATConv 层处理隐藏状态
    H_tilde = torch.tanh(H_tilde) # 使用 tanh 函数激活候选状态
    # 计算隐藏状态
    H = Z * H + (1 - Z) * H_tilde # 更新隐藏状态
    return H # 返回隐藏状态
```

系数(R^2),计算公式为 $R^2 = 1 - (\sum_{n=1}^k (x_n - \hat{x}_n)^2 / \sum_{n=1}^k (x_n - \bar{x}_n)^2)$ 和运行时间。

训练参数如表 1 所示,其中 x 和 y 分别为输入和输出的通道数, lr 为训练的学习率。图 9 展示了 GConvGRU-GAT,GCN^[21],GCN-LSTM^[22],WNN^[23] 和 MDT-Net^[24] 模型的预测结果。与其他模型相比,本文所提出的 GConvGRU-GAT 模型有更好的预测性能。



注:(a) GCN 预测结果;(b) GCN-LSTM 预测结果;(c) WNN 预测结果;(d) MDT-Net 预测结果;(e) GConvGRU-GAT 预测结果。

图 9 GConvGRU-GAT 及各对比模型预测结果

Fig. 9 The prediction results of GConvGRU-GAT and various comparison models

GConvGRU-GAT 算法在多个指标上都展现出优异的性能。从表 2 中可以看出,该算法在均方误差方面表现出色,仅为 0.022,比 GCN 算法提高了 84.6%,表明其在预测精度方面更为优秀。同时,GConvGRU-GAT 算法在绝对误差指标上也优于其他算法,说明其预测结果更加准确可靠。此外,GConvGRU-GAT 算法的决定系数 R^2 高达 0.826,优于其他四种算法,表明该算法在捕捉样本数据特征和规律方面更有优势,预测效果更加准确。不仅如此,GConvGRU-GAT 算法在测试时间方面也表现出色,运行速度更快,这意味着该算法在实际应用中能够提供更高的计算效率和响应速度。

综上所述,GConvGRU-GAT 算法在多个重要指标上都展现出卓越的表现,包括预测精度、准确性和运行效率等,这些优势使其在实际应用中具有明显的优势。因此,该算法可以被认为是一种性能优异的预测模型。

表 1 不同模型的训练参数

Tab. 1 Training parameters of different models

GConvGRU-GAT	GCN	GCN-LSTM	WNN	MDT-Net
$x = 6$	$x = 6$	$x = 6$	$x = 6$	$x = 6$
$y = 1$	$y = 1$	$y = 1$	$y = 1$	$y = 1$
$l_r = 0.08$	$l_r = 0.04$	$l_r = 0.001$	$l_r = 0.001$	$l_r = 0.08$

表 2 不同模型的训练效果

Tab. 2 Training effects of the different models

	GCN	GCN-LSTM	WNN	MDT-Net	GConvGRU-GAT
M_{SE}	0.143	0.057	0.064	0.027	0.022
M_{AE}	0.325	0.157	0.183	0.146	0.103
R^2	0.471	0.664	0.554	0.756	0.826
Time	0.187	0.647	0.156	0.253	0.026

4 结论

本文提出了一种基于 GConvGRU-GAT 的安全性能智能预测模型。GConvGRU-GAT 在网络结构中加入了 GAT 卷积模块,可以更有效地捕捉移动通信网络中节点之间的时空依赖关系,利用图卷积和门控循环单元的优势,对网络安全通信性能进行准确预测。实验结果表明,GConvGRU-GAT 模型在预测准确率方面优于 GCN,GCN-LSTM,WNN 和 MDT-Net 网络模型。

参 考 文 献

- [1] KUMAR G, MIKKILI S. Critical review of vehicle-to-everything(V2X) topologies: communication, power flow characteristics, challenges and opportunities[J]. CPSS Transactions on Power Electronics and Applications, 2024, 9(1): 10-26.
- [2] 张海霞, 李贻麟, 李东阳, 等. 基于车辆行为分析的智能车联网关键技术研究[J]. 电子与信息学报, 2020, 42(1): 36-49.
- [3] ZHANG X Z, FANG S C, SHEN Y P, et al. Hierarchical velocity optimization for connected automated vehicles with cellular vehicle-to-everything communication at continuous signalized intersections[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(3): 2944-2955.
- [4] 程翔, 张浩天, 杨宗辉, 等. 车联网通信感知一体化研究: 现状与发展趋势[J]. 通信学报, 2022, 43(8): 188-202.
- [5] ZHANG X Z, CAO X, ZHANG H, et al. An intelligent obstacle detection for autonomous mining transportation with electric locomotive via cellular vehicle-to-everything and vehicular edge computing[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(3): 3177-3190.
- [6] DING C, Ho I W-H, CHUNG E, et al. V2X and deep reinforcement learning-aided mobility-aware lane changing for emergency vehicle preemption in connected autonomous transport systems[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(7): 7281-7293.
- [7] 张文芳, 雷丽婷, 王小敏, 等. 面向云服务的安全高效无证书聚合签名车联网认证密钥协商协议[J]. 电子学报, 2020, 48(9): 1814-1823.
- [8] 刘健, 李艳俊, 郑继虎, 等. 可溯源车联网匿名签名和批量验证方案设计[J]. 计算机工程与应用, 2024, 60(23): 268-274.
- [9] 张海波, 余艺, 王冬宇, 等. 面向车联网通勤的双阶段认证密钥协商协议[J]. 通信学报, 2024, 45(5): 128-139.
- [10] 刘雪艳, 王力, 邹丽娟, 等. 车联网环境下无证书匿名认证方案[J]. 电子与信息学报, 2022, 44(1): 295-304.
- [11] 郭显, 袁建鹏, 冯涛, 等. 车联网隐私保护自主管理身份方案[J]. 电子与信息学报, 2024, 46(7): 2783-2792.
- [12] 王为念, 苏健, 陈勇, 等. 基于多智能体深度强化学习的车联网频谱共享[J]. 电子学报, 2024, 52(5): 1690-1699.
- [13] 雒江涛, 杨和平, 冉泳屹. 基于参数化强化学习的车联网内容缓存和功率分配联合优化[J]. 电子与信息学报, 2023, 45(7): 2476-2483.
- [14] 廖勇, 尹子松, 田肖懿. 车联网 V2I 场景下基于 GNN 的 SC-FDMA 智能信道估计[J]. 电子学报, 2024, 52(3): 772-782.
- [15] 张海波, 刘香渝, 荆昆伦, 等. 车联网中基于 NOMA-MEC 的卸载策略研究[J]. 电子与信息学报, 2021, 43(4): 1072-1079.
- [16] 谭国平, 易文雄, 周思源, 等. 无人机辅助 MEC 车辆任务卸载与功率控制近端策略优化算法[J]. 电子与信息学报, 2024, 46(6): 2361-2371.
- [17] 章坚武, 芦泽韬, 章谦骅, 等. 基于拟牛顿法的深度强化学习在车联网边缘计算中的研究[J]. 通信学报, 2024, 45(5): 90-100.

(下转第 526 页)

- [17] WU Y N, YANG F, LIU Y, et al. A comparison of 1-D and 2-D deep convolutional neural networks in ECG classification[C]// Annual International Conference of the IEEE Engineering in Medicine and Biology Society, July 18-21, 2018, Honolulu, HI, USA. New York: IEEE, 2018:324-327.
- [18] MUSHTAQ S, MANJURUL ISLAM M M, SOHAIB M. Deep learning aided data-driven fault diagnosis of rotatory machine: a comprehensive review[J]. *Energies*, 2021,14(16):5150.
- [19] 皮骏, 刘鹏, 胡超. 基于 GA-PNN 网络的滚动轴承故障诊断方法[J]. *机械设计与制造*, 2024,(12):91-94,103.
- [20] LIANG P F, WANG W H, YUAN X M, et al. Intelligent fault diagnosis of rolling bearing based on wavelet transform and improved ResNet under noisy labels and environment[J]. *Engineering Applications of Artificial Intelligence*, 2022,115:105269.
- [21] 龚俊, 张月义, 陈思戢, 等. 基于 SWT 与改进卷积神经网络的轴承故障诊断[J]. *现代电子技术*, 2024,47(6): 68-74.
- [22] ANDÉN J, MALLAT S. Deep scattering spectrum[J]. *IEEE Transactions on Signal Processing*, 2014,62(16):4114-4128.
- [23] MALLAT S. Group invariant scattering[J]. *Communications on Pure and Applied Mathematics*, 2012,65(10):1331-1398.
- [24] MAVROFORAKIS M E, THEODORIDIS S. A geometric approach to Support Vector Machine (SVM) classification[J]. *IEEE Transactions on Neural Networks*, 2006,17(3):671-682.
- [25] 代永潇, 李晓萌, 范丽亚. 改进的非线性 RMPSVM 及 TMPSVM[J]. *聊城大学学报(自然科学版)*, 2022,35(5):8-20.
- [26] CHANG R Y, PODGURSKI A, YANG J. Case Western Reserve Univ., Cleveland, OH[J]. *Software Engineering IEEE Transactions*, 2008,34:579-596.
- [27] 李可, 熊檬, 宿磊, 等. 基于改进深层极限学习机的故障诊断方法[J]. *振动、测试与诊断*, 2020,40(6):1120-1127.
- [28] 文征, 段俊勇, 杨化林. 基于改进麻雀搜索算法优化 SVM 的轴承故障诊断研究[J]. *舰船电子工程*, 2023,43(9):151-155.
- [29] 刘杰, 谭玉涛, 杨娜, 等. SSA-SqueezeNet 在轴承损伤程度识别中的应用[J]. *工业工程与管理*, 2024,29(3):78-88.
- [30] 田心平, 钱云祥, 张浩楠, 等. 基于自适应降噪和改进 CNN 的轴承故障诊断方法[J]. *机电工程技术*, 2024,53(1):228-232,252.

(责任编辑:赵海军)

(上接第 515 页)

- [18] 韩涛, 贺威, 代俊, 等. 基于无标度网络的车联网连通性研究[J]. *通信学报*, 2021,42(4):100-108.
- [19] MAGABLEH A M, ALDALGAMOUNI T, BADARNEH O, et al. Performance of non-orthogonal multiple access (NOMA) systems over n-nakagami-m multipath fading channels for 5G and beyond[J]. *IEEE Transactions on Vehicular Technology*, 2022,71(11):11615-11623.
- [20] KARAGIANNIDIS G K, SAGIAS N C, MATHIOPOULOS P T. N * nakagami: a novel stochastic model for cascaded fading channels [J]. *IEEE Transactions on Communications*, 2007,55(8):1453-1458.
- [21] KIM I, JEONG J, OH Y, et al. Analyzing GCN aggregation on GPU[J]. *IEEE Access*, 2022,10:113046-113060.
- [22] ABDELRAOUF A, ABDEL-ATY M, MAHMOUD N. Sequence-to-sequence recurrent graph convolutional networks for traffic estimation and prediction using connected probe vehicle data[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2023,24(1):1395-1405.
- [23] ZHANG J, LU J, WANG C, et al. Hyperspectral and multispectral image fusion via superpixel-based weighted nuclear norm minimization[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023,61(8):1-12.
- [24] 曹书博, 高志贺, 李玉芳, 等. 基于 MDT-Net 的物联网安全性能智能预测[J]. *聊城大学学报(自然科学版)*, 2023,36(6):18-26.

(责任编辑:赵海军)