

引用:程涵冰,方珺,李天成,等. 基于 GTM-Net 的隐蔽通信系统安全传输性能智能预测方法[J]. 聊城大学学报(自然科学版),2026,39(4):518-527.

Citation:CHENG Hanbing,FANG Jun,LI Tiancheng,XU Lingwei. Intelligent prediction algorithm of secure transmission performance of covert communication systems based on GTM-Net [J]. Journal of Liaocheng University (Natural Science Edition),2026,39(4):518-527.

文章编号 1672-6634(2026)04-0518-10

DOI 10.19728/j.issn1672-6634.2025050013

基于 GTM-Net 的隐蔽通信系统安全传输 性能智能预测方法

程涵冰¹,方珺¹,李天成¹,徐凌伟^{1,2,3}

(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;3. 广西民族大学 广西混杂计算与集成电路设计分析重点实验室, 南宁 530006)

摘要 鉴于无线传输媒介的开放性与广播性,确保无线网络用户数据隐私已成为信息传输安全领域的重要研究课题。隐蔽通信在传输媒介上对传输过程进行隐藏,以防第三方对通信行为的检测,可以更好的保护隐蔽信息。但是移动通信环境复杂多变,安全传输性能受复杂多变的环境影响,难以进行实时准确的预测。因此,提出了一种基于 GTM-Net 神经网络的隐蔽通信系统安全传输性能智能预测方法。首先,在 N -Nakagami 信道下,建立了由智能反射面和人工噪声辅助的隐蔽通信系统,通过链路信噪比分析了系统的安全传输性能。为了对安全传输性能进行实时预测,设计了 GTM-Net 模型。该模型采用双分支结构,一条分支是两层基于采样的图卷积网络进行局部随机采样,每层 GraphSAGE 后添加一层 Transformer 进行全局特征提取,另一分支是通过 MLP-Mixer 网络进行特征交互。实验结果表明,相较于其他模型,GTM-Net 模型具有更好的预测性能。在预测准确度方面,GTM-Net 比图卷积神经网络提高了 85.36%。

关键词 隐蔽通信;智能反射面;安全传输;智能预测;图卷积神经网络

中图分类号 TN929.5

文献标志码 A

开放科学(资源服务)标识码(OSID)



Intelligent prediction algorithm of secure transmission performance of covert communication systems based on GTM-Net

CHENG Hanbing¹, FANG Jun¹, LI Tiancheng¹, XU Lingwei^{1,2,3}

(1. College of Information Science and Technology, Qingdao University of Science and Technology, Qingdao 266061, Shandong, China;2. Engineering Research Center of Integration and Application of Digital Learning Technology, Ministry of Education, Beijing 100039, China; 3. Guangxi Key Laboratory of Hybrid Computation and IC Design Analysis(Guangxi Minzu University), Nanning 530006, China)

Abstract: Due to the broadcast and open nature of channels in wireless communication systems, the issue of protecting the privacy and security of wireless communication users faces great challenges. Covert com-

收稿日期:2025-05-29

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(1321012);广西混杂计算与集成电路设计分析重点实验室开放基金项目(GXIC2401)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。

munication can better protect the hidden information by hiding the transmission process on the transmission medium to prevent the third party from detecting the communication behavior. However the mobile communication environment is complex and changeable, and the secure transmission performance is affected by the complex and changeable environment, which makes it difficult to make real-time accurate prediction. Therefore, this paper proposes an intelligent prediction algorithm for secure transmission performance of covert communication system based on GTM-Net neural network. First, a covert communication system assisted by Intelligent Reconfigurable Surface and Artificial Noise is established under N -Nakagami channel, and the secure transmission performance is analyzed by the link signal-to-noise ratio. In order to predict the secure transmission performance in real time, the GTM-Net model is designed in this paper. The model adopts a two-branch structure, one branch is a two-layer sampling-based Graph Convolutional Network for local random sampling, and a layer of Transformer is added after each layer of GraphSAGE for global feature extraction, and the other branch is a feature interaction through MLP-Mixer network. The experimental results show that, compared to other algorithms, the GTM-Net algorithm has better prediction performance. In terms of prediction accuracy, GTM-Net improves 85.36% over Graph Convolutional Network.

KeyWords: covert communication; intelligent reflective surface; secure transmission; intelligent prediction; Graph Convolutional Network

0 引言

随着第六代移动通信(6G)与物联网技术的快速发展,网络连接规模与数据传输速率正以前所未有的速度增长^[1]。6G 预计将实现太比特级传输能力,并支持海量异构设备的低时延、超可靠互联,这为智能制造、自动驾驶和远程医疗等新兴应用场景提供了坚实基础。然而,庞大网络规模与多样化终端也带来了更为严峻的安全与隐私挑战,在空中开放的无线信道中,传统的物理层加密技术尽管能够对信息进行加密处理,却依然面临被非法窃取并解密的风险。为了解决这个问题,Bash 等人首次提出了隐蔽通信技术^[2]。该技术是在现有的传输媒介中对要发送的信息隐蔽,其目的是在不引起非法者怀疑的情况下进行传输,确保传输内容的安全性和通信行为的不可检测性。随着隐蔽通信技术的提出,该领域的学者对隐蔽通信技术展开了更深刻的探索。文献[3]研究了在噪声不确定情况下的隐蔽通信系统,证明正的隐蔽通信速率是可以实现的。文献[4]考虑在不同衰落信道环境下,在隐蔽通信系统中引入了一个干扰器来干扰监听者的检测。文献[5]提出了人工噪声(Artificial Noise, AN)全双工中继与信道不确定性辅助的隐蔽通信系统,验证了中继与信道不确定性可以增强隐蔽性能。除此之外,文献[6-7]考虑了人工噪声辅助的隐蔽通信系统,研究表明接收端发射的人工噪声可以恶化监听者的探测性能。

为了避免被非法者检测到通信行为,隐蔽通信发送方通常要降低发射功率,这导致通信范围有限,容量下降。为了改善这一问题,智能反射面(Intelligent Reconfigurable Surface, IRS)作为一种新兴的无线通信技术,近年来被学者广泛关注。IRS 使用大量可调节的反射单元组成的平面结构,每个反射单元都能够独立地调节入射信号的幅度和相位,从而改变信号的传播环境。因此,通过合理的设计反射单元的反射系数,可以显著地提升隐蔽传输效率^[8]。文献[9]提出了将 IRS 与有延时的隐蔽通信系统结合的方案,揭示了各个参数对隐蔽吞吐量的影响。文献[10]在更加实际的噪声不确定场景下,研究了双向 IRS 与随机 AN 功率辅助的隐蔽通信系统,结果表明该工作提高了隐蔽通信覆盖与鲁棒性。文献[11]考虑了 IRS 与 AN 联合辅助的隐蔽通信系统在非完美信道状态下的方案,研究表明该方法能够更好的适应信道不确定性。

以上研究多依赖传统的性能分析方法,难以灵活应对实际环境中不断演变的动态干扰与对抗策略。为此,本文将性能预测融入隐蔽通信研究,通过深度学习技术对系统传输性能指标进行预测,从而提升系统在复杂多变场景下的鲁棒性。深度学习技术已在智能通信预测领域得到广泛应用。文献[12]提出了一种加入了门控单元的 GConvGRU-GAT 网络来进行车联网安全性能预测,结果表明该网络与图注意力网络(Graph

Attention Network, GAT)等网络相比具有更好的预测性能。文献[13]提出了一种融合空洞卷积、深度可分离卷积与 Transformer 自注意力的轻量级双分支 MDT-Net,用于对物联网物理层安全中断概率进行高精度、低延迟的智能预测。上述方法虽然在各自领域取得了一定成效,但隐蔽通信的性能受多因素的耦合影响,单分支只集中于相似模态的特征提取,双分支的融合方式也为浅层拼接,难以充分应对隐蔽通信复杂多变的动态特性。因此,本文提出了一种基于双分支 GTM-Net 神经网络的安全传输性能智能预测方法。本文的主要贡献如下:首先,本文在 N-Nakagami 信道下建立了 IRS 与 AN 辅助的系统模型,并以隐蔽吞吐量 (Covert Throughput, CT)作为性能指标进行分析。其次,提出了一种双分支 GTM-Net 模型,第一个分支首先通过 GraphSAGE 模块进行局部邻居采样和信息聚合,再经过 Transformer 的自注意力机制来捕捉更全局的节点关系。第二个分支是利用 MLP-Mixer 交替进行特征混合,捕捉特征间更复杂关系。两者通过 Cross-Attention 模块进行分支间的特征融合,既能捕捉全局拓扑依赖,又能捕捉局部特征交互,提高模型的精度。GTM-Net 实现了局部—全局建模与特征交互的结合,在动态信道环境下能有效提升对隐蔽通信传输性能的表达能。最后,实验结果表明,所提方法在预测精度和稳定性上显著优于现有模型,其中均方误差较传统 GCN 降低 85.36%,决定系数达到 0.893,验证了所提方法的有效性与优越性。

1 隐蔽通信传输性能分析

1.1 隐蔽通信系统模型

图 1 为 IRS 和 AN 辅助的隐蔽通信系统模型。模型由四部分组成,分别为发送端 (Alice),接收端 (Bob),监听端 (Willie) 和智能反射面 (IRS)。Alice 希望在不被 Willie 发现的情况下与 Bob 进行通信,Willie 则通过接收到的信号来判断是否存在通信行为。为了增强接收端的信号强度并且抑制 Willie 的检测性能,在 Alice 与 Bob 之间部署了一块由 N 个反射单元组成的 IRS,并且定义 IRS 的相移矩阵为 $\theta = \text{diag}(e^{j\theta_1}, e^{j\theta_2}, \dots, e^{j\theta_N})$ 。Alice 只配有一根天线来发送隐蔽信息。Bob 配有一根发送天线和一根接收天线,并且在工作在全双工模式下同时接收来自 Alice 的信号和发送人工噪声来干扰 Willie 的探测。链路 Alice 到 IRS, IRS 到 Bob, Alice 到 Bob, Alice 到 Willie, Bob 到 IRS, IRS 到 Willie, Bob 到 Willie 的信道位置增益分别为 $G_{AR}, G_{RB}, G_{AB}, G_{AW}, G_{BR}, G_{RW}, G_{BW}$ 。七条链路的信道衰落系数分别为 $h_{\{AR, RB, AB, AW, BR, RW, BW\}}$ 。为了更精准的描述在复杂环境下信号通过多路径传播时的衰落,本文的信道衰落系数均服从 N-Nakagami 分布^[14]。

在 Alice 到 Bob 的通信过程中, x_a 为 Alice 的发送的信号, x_b 为 Bob 发射的人工造声信号,则 Bob 的接收信号为:

$$y_b = \sqrt{P_a} (\sqrt{G_{RB}G_{AR}} \mathbf{h}_{RB}^H \boldsymbol{\theta} \mathbf{h}_{AR} + \sqrt{G_{AB}} h_{AB}) x_a + \sqrt{\lambda P_b} x_b + n_b, \quad (1)$$

其中 Alice 的发射功率和 Bob 的发射的人工噪声功率分别由 P_a 和 P_b 表示, n_b 是 Bob 处均值为 0, 方差为 1 高斯噪声, λ 是 Bob 的自干扰消除系数,取值为 0 到 1。Bob 的 SINR 为:

$$\gamma_b = \frac{P_a |\sqrt{G_{RB}G_{AR}} \mathbf{h}_{RB}^H \boldsymbol{\theta} \mathbf{h}_{AR} + \sqrt{G_{AB}} h_{AB}|^2}{\lambda P_b + \sigma_b^2}, \quad (2)$$

当 Alice 向 Bob 发送隐蔽信息时,Willie 会同时接收到来自 Alice 发送的 x_a 和来自 Bob 发送的人工噪声 x_b 。Willie 接受到的信号为:

$$y_w = \sqrt{P_a} (\sqrt{G_{RW}G_{AR}} \mathbf{h}_{RW}^H \boldsymbol{\theta} \mathbf{h}_{AR} + \sqrt{G_{BW}} h_{BW}) x_a + \sqrt{P_b} (\sqrt{G_{RW}G_{BR}} \mathbf{h}_{RW}^H \boldsymbol{\theta} \mathbf{h}_{BR} + \sqrt{G_{BW}} h_{BW}) x_b + n_w \quad (3)$$

Willie 处的 SINR 为:




图 1 IRS 和 AN 辅助的隐蔽通信系统

Fig. 1 IRS and AN-assisted covert communication system

$$\gamma_w = \frac{P_a |\sqrt{G_{RW}G_{AR}} \mathbf{h}_{RW}^H \boldsymbol{\theta} \mathbf{h}_{AR} + \sqrt{G_{AW}} h_{AW}|^2}{P_b |\sqrt{G_{RW}G_{BR}} \mathbf{h}_{RW}^H \boldsymbol{\theta} \mathbf{h}_{BR} + \sqrt{G_{BW}} h_{BW}|^2 + \sigma_w^2} \quad (4)$$

1.2 传输性能分析

在本文中,隐蔽吞吐量作为衡量隐蔽通信系统传输性能的指标。隐蔽吞吐量 η 定义为在满足隐蔽性的前提下,实际传输的有效数据量。 η 可以表示为传输中断概率(Transmission Outage Probability, TOP) δ 和目标传输速率 R 的乘积^[15]:

$$\eta = R(1 - \delta), \quad (5)$$

基于 Bob 处和 Willie 处的信噪比,可以得到 Bob 和 Willie 的可达速率分别为:

$$C_B = \log_2(1 + \gamma_b), \quad (6)$$

$$C_W = \log_2(1 + \gamma_w), \quad (7)$$

因此可以得到瞬时信道容量为^[16]:

$$C = \max\{\log_2(1 + \gamma_b) - \log_2(1 + \gamma_w), 0\}. \quad (8)$$

由(5)可以得出,隐蔽吞吐量需要先对传输中断概率进行分析。如果瞬时信道安全容量大于目标传输速率,即 $C \geq R$, 则认为 Alice 可以成功与 Bob 进行通信。反之,则认为 Alice 和 Bob 之间发生了中断,没有进行信息传输。基于此,传输中断概率表示为

$$\delta = \Pr(C < R). \quad (9)$$

将(9)带入到(5)中,最终可以计算得到隐蔽吞吐量。

2 基于 GTM-Net 神经网络的安全传输性能智能预测算法

如图 2 所示,本文提出了一种基于 GTM-Net 神经网络的安全传输性能智能预测算法。该算法的实现有以下几个步骤:(1)对通信模型收集到的数据进行特征选取,获得通信数据集;(2)对数据集进行划分,划分成 70% 的训练集,15% 的测试集和 15% 的验证集;(3)使用训练集训练 GTM-Net 网络模型,并进行模型评估;(4)调整模型的参数,得到最优模型;(5)对最优模型进行测试,得到最终的预测结果。




图 2 预测算法结构图

Fig. 2 Prediction algorithm structure diagram

2.1 数据预处理

本文的数据集为 $\{D_n\}$, $D_n = (X_n, y_n)$ 。 X_n 主要包括 P_a , P_b , λ , m , N 以及 G 等 11 个特征。分别

表示为 Alice 的发射功率、Bob 的人工噪声功率、Bob 的自干扰消除系数、Nakagami 参数、智能反射面反射单元个数,6 条链路之间的信道位置增益。

$$\mathbf{X}_n = (x_{n1}, x_{n2}, \dots, x_{n11}), \quad (10)$$

将生成的 $\mathbf{X}_n$ 转化为图结构数据,首先将原始数据中的 M 条样本视图中 M 个节点,并提取每个样本 D 维特征向量,构成节点特征矩阵,其大小为 $M \times D$ 。

为了让图神经网络能够利用节点间的相似性信息,在对特征进行标准化后,采用 K 最邻近算法(K-Nearest Neighbors, K-NN)^[17]构造了边列表

$$\text{edge_index} \in \{0, 1, \dots, 4999\}^{2 \times E}, \quad (11)$$

其中第一行存放每条边的起点索引,第二行存放对应的终点索引。图 3 是数据预处理流程图:




图 3 数据预处理流程图

Fig. 3 Data preprocessing flowchart

2.2 GTM-Net 网络结构

GTM-Net 结构如图 4 所示。GTM-Net 是由 GraphSAGE 模块,Transformerd 模块以及 MLP-Mixer 模块组成的双分支网络。第一分支由是 GraphSAGE 和 Transformerd 的交替堆叠组成。GraphSAGE 在每层只需要随机采样固定数量的邻居节点,相比于传统的图卷积网络(Graph Convolutional Network, GCN),前者显著降低了大规模图上的计算和内存开销,使训练更加高效。Transformer 的核心作用是通过自注意力机制在序列内动态建模任意两节点之间的依赖关系,从而弥补 GraphSAGE 缺乏的全局建模能力。第一分支关注的是节点与节点之间的关系。第二分支的 MLP-Mixer 模块与普通的全连接层或简单拼接不同,该模块强化了表格数据列间的非线性关系,提升了结构化数据的建模能力。第二分支关注的是节点内部特征之间的关系。再经过一个 Cross-Attention 注意力特征融合模块,将第一分支的图拓扑与第二分支的特




图 4 GTM-Net 网络结构图

Fig. 4 GTM-Net network architecture diagram

征交互信息进行融合。最后通过一个 MLP 回归头将输出从高维映射到低维完成预测。

2.3 第一分支结构

在 GTM-Net 的第一个分支中,输入的数据是构建的图数据,即将节点特征矩阵和边列表输入到 GraphSAGE 层中,进行邻居采样和邻居聚合,其过程如图 5 所示。




图 5 GraphSAGE 采样聚合流程图

Fig. 5 GraphSAGE sampling and aggregation flowchart

首先对于每个节点 v ,从它们的邻居中随机采样 k 个节点,形成一个邻居集合 $N(v)$ 。采样固定数量的节点可以控制每层的计算复杂度,减少计算开销。本文采取的聚合策略是平均聚合,即对所有邻居节点的特征取平均值。聚合后自身节点的特征更新为

$$\mathbf{h}_v^k = \sigma([\mathbf{W}_k \cdot \text{AGG}(\{\mathbf{h}_u^{k-1}, \forall u \in N(v)\}), \mathbf{B}_k \mathbf{h}_v^{k-1}]), \quad (12)$$

其中 $\mathbf{h}_v^k$ 表示第 k 轮采样后节点 v 的向量; $\mathbf{W}_k$ 表示第 k 层用在聚合后邻居向量的权重矩阵; AGG 表示聚合器; $\mathbf{B}_k$ 表示第 k 层用在节点自身表示的权重矩阵。

每经过一层 GraphSAGE,就用一层 Transformer 的全局子注意力机制来捕捉更全局的节点关系,这样既融合节点自身属性,又拓展到了全图范围内的全局信息。最终得到第一分支的输出是一个 $5\,000 \times 32$ 的矩阵。

2.4 第二分支结构

在 GTM-Net 的第二分支中,输入数据是未经处理的原始结构化数据。传统的 MLP 在高维、非线性、强相关特征下容易丢失交互信息。而 MLP-Mixer 把 11 个特征看作是 11 个“token”,通过 token 方向混合和 channel 方向混合,可以更好的建模输入特征之间的复杂耦合关系。在动态信道条件下,这种建模能力可以捕捉非平稳特征之间的潜在交互,从而提升预测能力。




图 6 GTM-Net 第二分支结构图

Fig. 6 GTM-Net second branch structure diagram

在每层 MLP-Mixer 中,先在 token 维度上使用 MLP 混合特征简的交互,再在 channel 维度上使用另一组 MLP 提取通道内部表示,辅以残差链接、LayerNorm 和非线性激活,最后将得到大小为 $5\,000 \times 256$ 的输出矩阵。

2.5 特征融合

第二分支输出首先经过一个全连接层将特征映射到与第一分支输出同一维度 $5\,000 \times 32$ 。然后再将两分支的输出一同输入到 Cross-Attention 模块,该模块将第一分支的输出作为查询矩阵 Query,第二分支的输出作为键矩阵 Key 和值矩阵 Value,喂入多头注意力层计算跨分支的注意力加权输出

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V. \quad (13)$$

再经过一段两层前馈网络得到最终形状为 $5\,000 \times 32$ 的输出。最后的 MLP 回归头将融合后的特征压缩到标量进行输出。




图 7 特征融合模块

Fig. 7 Feature fusion module

2.6 基于 GTM-Net 神经网络的安全传输性能智能预测算法

该算法的伪代码如表 1 所示。具体步骤如下:(1) 将通信系统的 11 个参数 P_a, P_b, λ, m, I 以及 G 等作为特征 X_n , 并通过公式(9)计算输出 $\hat{y}$, 得到数据集 $D_n = (X_n, y_n), n = 1, 2, \dots, 5\,000$ 。(2) 对 GTM-Net 所有权重和偏置采用均匀分布随机初始化,同时设定初始学习率。(3) 利用训练集对网络进行迭代训练,通过不断调整权重,使模型的损失函数下降直至达到预设的收敛标准。(4) 利用独立的测试集评估训练好的 GTM-Net 模型,得到 CT 的预测值。智能预测算法的流程图如图 8 所示。

算法:GTM-Net 传输性能智能预测算法

输入:图结构/表结构移动通信数据集 $D_n = (X_n, y_n)$

输出:本地模型参数

步骤 1:搭建模型

图分支:GraphSAGE $\leftrightarrow$ Transformer 交替 L 层

表分支:MLP-Mixer R 层(token $\times$ channel)

融合:Cross-Attention(Q=图分支,K/V=表分支)

头部:MLP 回归头

步骤 2:超参数设置

epochs = 100, batch_size = 1, lr

优化器 Adam

步骤 3: 训练循环

```

for  $t = 1 \cdots \text{epochs}$ :
    # 前向
     $G \leftarrow X$ 
    for  $l = 1 \cdots L$ :
         $G \leftarrow \text{ReLU}(\text{SAGE}_l(G, \text{SAMPLE}(E, K)))$ 
         $G \leftarrow \text{Transformer}_l(G)$ 
     $Z \leftarrow \text{Linear}(T)$ 
    for  $r = 1 \cdots R$ :
         $Z \leftarrow \text{Mixer}_r(Z)$ 
     $F \leftarrow \text{CrossAttention}(Q=G, K=Z, V=Z)$ 
     $\hat{y} \leftarrow \text{MLP}(F)$ 
     $\text{loss} \leftarrow \text{MSE}(\hat{y}, y)$ 
    # 反向
    optimizer.zero_grad()
    optimizer.step()
end

```

4 仿真结果

为了全面评估所提 GTM-Net 模型的性能, 本文将该模型在同一测试集上与 GCN^[18]、GAT^[19]、FNet^[20] 和 MLP^[21] 进行了对比。本文采用均方误差 (M_{SE}), 绝对误差 (M_{AE}) 和决定系数 (R^2) 等性能指标来衡量模型性能。计算公式分别为:

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

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

$$M_{AE} = \frac{1}{k} \sum_{i=1}^k |(y_n - \hat{y}_n)|. \quad (16)$$

训练参数如表 2 所示, 其中 C_{in} 和 C_{out} 分别为输入和输出的通道数, lr 为模型训练的学习率。图 9 分别展示了 GCN、GAT、FNet、MLP 和 GTM-Net 模型的预测结果。实验结果表明, 本文所提出的 GTM-Net 在预测性能方面优于其他模型。





图 8 基于 GTM-Net 的 CT 智能预测算法

Fig. 8 GTM-Net-based intelligent CT prediction algorithm

表 1 不同网络的训练参数

Tab. 1 Training parameters for different networks

GCN	GAT	MLP	GTM-Net	FNeT
$C_{in}=11$	$C_{in}=11$	$C_{in}=11$	$C_{in}=11$	$C_{in}=11$
$C_{out}=1$	$C_{out}=1$	$C_{out}=1$	$C_{out}=1$	$C_{out}=1$
$l_r=0.1$	$l_r=0.05$	$l_r=0.1$	$l_r=0.05$	$l_r=0.05$



注:(a) GCN 预测结果;(b) GAT 预测结果;(c) MLP 预测结果;(d) GTM-Net 预测结果;(e) FNet 预测结果。

图 9 预测结果

Fig. 9 Prediction results




图 10 均方误差

Fig. 10 Mean square error




图 11 绝对误差

Fig. 11 Mean absolute error

图 10-12 展示了几种模型的均方差(M_{SE}),绝对误差(M_{AE})和决定系数(R^2)。从图 10 可以看出,GTM-Net 模型的 M_{SE} 仅为 0.009,表现最佳,比 GCN 模型提高了 85.36%。同时,从图 11 可知,GTM-Net 模型的 M_{AE} 也是几种模型中最低的,说明其平均预测偏差最小、预测更精准。最后,图 12 表明 GTM-Net 具有最高

的 R^2 , 高达 0.893, 能够更好地捕捉数据变化趋势。综上所述, 本文所提出的 GTM-Net 模型在多个性能指标上都表现优异, 在预测任务中具有最佳的综合性能。

4 结论

本文提出了面向隐蔽通信的双分支 GTM-Net 预测模型, 第一分支以 GraphSAGE 与 Transformer 协同进行特征提取, 第二分支通过 MLP-Mixer 深度刻画多参数的非线性交互, 并以 Cross-Attention 动态融合两类表征。在 IRS 与 AN 辅助、N-Nakagami 信道场景下, 以隐蔽吞吐量为指标, 均方误差 (M_{SE}) 为 0.006, 较 GCN 降低 85.36%, 平均绝对误差 (M_{AE}) 为 0.054, 决定系数 (R^2) 为 0.893, 所提方法在精度与稳定性上显著优于对比方法。论文后续工作考虑通过剪枝或量化等操作, 在保证模型精度基础之上, 降低模型复杂度, 减少计算开销; 设计多层融合或门控机制, 以实现更加深层的信息交互。




图 12 决定系数 (R^2)

Fig. 12 Coefficient of determination (R^2)

参考文献

- [1] 周小波, 阮丹阳, 周修颖, 等. IRS 辅助的感知与隐蔽通信一体化资源分配算法[J]. 电子与信息报, 2025, 47(2): 375-385.
- [2] BASH B A, GOECKEL D, TOWSLEY D. Limits of reliable communication with low probability of detection on AWGN channels[J]. IEEE Journal on Selected Areas in Communications, 2013, 31(9): 1921-1930.
- [3] HE B, YAN S H, ZHOU X Y, et al. On covert communication with noise uncertainty[J]. IEEE Communications Letters, 2017, 21(4): 941-944.
- [4] SOBERS T V, BASH B A, GUHA S, et al. Covert communication in the presence of an uninformed jammer[J]. IEEE Transactions on Wireless Communications, 2017, 16(9): 6193-6206.
- [5] 杜刘通, 文富鹏, 张硕, 等. 环境反向散射辅助 NOMA 网络的隐蔽性能分析[J]. 无线电工程, 2024, 54(3): 573-579.
- [6] SHU F, XU T Z, HU J S, et al. Delay-constrained covert communications with a full-duplex receiver[J]. IEEE Wireless Communications Letters, 2019, 8(3): 813-816.
- [7] SHAHZAD K, ZHOU X Y, YAN S H, et al. Achieving covert wireless communications using a full-duplex receiver[J]. IEEE Transactions on Wireless Communications, 2018, 17(12): 8517-8530.
- [8] 周小波, 于辉, 彭旭, 等. 智能反射面辅助及人工噪声增强的无线隐蔽通信[J]. 电子与信息学报, 2022, 44(7): 2392-2399.
- [9] WU Y J, CHEN X Y, LIU M Q, et al. IRS-assisted covert communication with equal and unequal transmit prior probabilities[J]. IEEE Transactions on Communications, 2024, 72(5): 2897-2912.
- [10] WANG C, XIONG Z H, ZHENG M, et al. Covert communications via two-way IRS with noise power uncertainty[J]. IEEE Transactions on Communications, 2024, 72(8): 4803-4815.
- [11] 冯友宏, 张彦峨, 张玉峰, 等. 非完美信道状态信息下分布式智能反射面辅助安全通信研究[J]. 电子与信息学报, 2024, 46(7): 2860-2868.
- [12] 李玉芳, 王锴, 张力良, 等. 一种基于 FL-TransCNN 神经网络的水声智能频谱感知算法[J]. 电讯技术, 2026, 66(1): 11-20.
- [13] 廖希, 蔺瑞甲, 郑相全, 等. 基于成本敏感 CNN-BiLSTM 网络的目标可见性预测方法[J]. 通信学报, 2026, 47(3): 112-122.
- [14] 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.
- [15] ZHENG T X, YANG Z T, WANG C, et al. Wireless covert communications aided by distributed cooperative jamming over slow fading channels[J]. IEEE Transactions on Wireless Communications, 2021, 20(11): 7026-7039.
- [16] BLOCH M, BARROS J, RODRIGUES M R D, et al. Wireless information-theoretic security[J]. IEEE Transactions on Information Theory, 2008, 54(6): 2515-2534.
- [17] WANG J F, ZHAO W L, XIAO S H, et al. Dynamic NN-descent: an efficient k-NN graph construction method[J]. IEEE Transactions on Big Data, 2025, 11(2): 879-886.
- [18] SHI C P, LIAO D L, WANG L G. Hybrid CNN-GCN network for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2025, 18: 10530-10546.
- [19] WANG Q Y, MA L S, ZHANG J P, et al. Double-branch multilevel skip sparse graph attention network for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2024, 17: 12421-12432.
- [20] CHEN Y X, WANG Q C, ZHAO Y C, et al. Bilinear parallel Fourier transformer for multimodal remote sensing classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2025, 63: 1-14.
- [21] HASNAT A, HEIRMAN W, AKRAM S. Analyzing and exploiting memory hierarchy parallelism with MLP stacks[J]. IEEE Computer Architecture Letters, 2025, 24(1): 125-128.

(责任编辑: 赵海军)