

## 基于动态图嵌入的车联网拓扑控制

孙雁飞<sup>1,2</sup>, 尹嘉峥<sup>3</sup>, 亓晋<sup>2</sup>, 胡筱旋<sup>2</sup>, 陈梦婷<sup>2</sup>, 董振江<sup>4</sup>

(1. 江苏省高性能计算与智能处理工程研究中心, 江苏 南京 210023;

2. 南京邮电大学物联网学院, 江苏 南京 210003;

3. 南京邮电大学通信与信息工程学院, 江苏 南京 210003;

4. 南京邮电大学计算机学院, 江苏 南京 210023)

**摘 要:** 针对由车联网的高度动态性和复杂性导致网络拓扑难以合理、稳定构建的问题, 提出了关于车联网的范围标签图嵌入方法。首先, 根据路侧单元分割车辆网络, 利用驾驶员辅助系统获取实时车辆信息; 其次, 使用傅里叶变换、模糊推理对车辆信息预处理, 获得车辆低维特征向量, 再对新加入网络的车辆节点进行冷启动处理; 最后, 以所提动态图嵌入方法在区域内进行拓扑控制, 充分利用车辆的特征信息构建车联网, 实现网络的动态更新。实验结果表明, 所提图嵌入方法建立的网络拓扑相对于传统网络及对比图嵌入方法, 具有更好的动态性、连通性以及稳健性。

**关键词:** 车联网; 图嵌入; 拓扑控制; 复杂网络; 模糊推理

**中图分类号:** TN92

**文献标志码:** A

**DOI:** 10.11959/j.issn.1000-436x.2022122

## Topology control based on dynamic graph embedding in Internet of vehicles

SUN Yanfei<sup>1,2</sup>, YIN Jiazheng<sup>3</sup>, QI Jin<sup>2</sup>, HU Xiaoxuan<sup>2</sup>, CHEN Mengting<sup>2</sup>, DONG Zhenjiang<sup>4</sup>

1. Jiangsu Engineering Research Center of HPC and Intelligent Processing, Nanjing 210023, China

2. School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

3. School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

4. College of Computer, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

**Abstract:** Facing the problem that it was difficult to construct the topology of Internet of vehicles (IoV) reasonably and stably due to the high dynamics and complexity of IoV, a label-range graph embedding (LRGE) method was proposed. First, the vehicular network was divided according to the road side unit (RSU). The driver assistance system was used to obtain real-time vehicle information. Then, the vehicle information was preprocessed by Fourier transform and fuzzy inference system to obtain the low-dimensional feature vector of the vehicles. For the newly joined vehicle nodes, the cold boot processing was carried out. Finally, the proposed dynamic graph embedding method was used to control the topology of the network in the region. Using the vehicle information, the IoV was reconstructed to realize the dynamic update. The experimental results show that the network topology established by the proposed method has better dynamics, connectivity and robustness than the traditional network and comparative graph embedding methods.

**Keywords:** Internet of vehicles, graph embedding, topology control, complex network, fuzzy inference

收稿日期: 2022-02-10; 修回日期: 2022-05-09

基金项目: 国家自然科学基金资助项目 (No.62172235); 南京邮电大学引进人才自然科学研究启动基金资助项目 (No.NY221136)

**Foundation Items:** The National Natural Science Foundation of China (No.62172235), Natural Science Research Startup Foundation of Recruiting Talents of Nanjing University of Posts and Telecommunications (No.NY221136)

## 0 引言

近年来,随着汽车市场规模的日益增长,城市道路、高速公路运载负荷的压力也不断增加,致使交通拥堵和交通事故频发,造成了严重的人员伤亡和经济损失。近年来,随着5G、物联网、智慧城市的发展及广泛应用,车载自组织网络(VANET, vehicular ad-hoc network)作为一种提高道路通行效率及车辆行驶安全性的技术被广泛关注并认可,它是一种特殊的移动自组织网络,将每一辆车作为一个信息源,利用无线通信手段,建立以车为节点,人、车、路交互的信息系统<sup>[1]</sup>。但是,相较于传统的蜂窝网络和移动专用网络,车辆移动性导致的网络拓扑结构动态变化使构建的网络稳健性变差<sup>[2]</sup>。车联网具有高度的动态性和复杂性,车辆节点间快速变化的相对距离和车辆间的互相遮挡,导致节点间出现频繁的断链和信号的衰落。因此,如何快速稳定地构建并控制网络拓扑是车联网研究的重点和难点。

为了构建合理的网络拓扑,可以利用驾驶员辅助系统获取的大量车辆特征信息来辅助车联网的组织,由于不同的车辆具有不同的驾驶特征,如果将具有相似驾驶特征的车辆形成一定的聚类结构,建立一定的信息交换集群机制,可以实现更加稳定的车联网<sup>[3]</sup>,从而提高网络的连通度、延长网络的生命周期并且提升链路的有效程度,使网络不会出现频繁的断链和节点丢失。传统方法多着眼于单车智能,并且依据路由算法建立网络,但是这种方法计算复杂,无法充分利用车联网的特点,并且建立的网络拓扑往往具有很高的节点中心性,依赖少数节点和链路,导致网络的动态性、连通性和稳健性较差。为解决这些问题,本文使用图嵌入的方法来构建车联网并进行优化,提高网络的稳定性及链路质量。

图嵌入是将图的节点或边映射到一个低维的向量空间,即将海量、高维、异构、复杂和动态的数据表示为统一、低维、稠密的向量,用以保存图的结构和性质<sup>[4]</sup>。图嵌入技术最初主要用于自然语言处理及推荐领域,但图作为一种复杂的信息载体,可以应用于许多现实的复杂关系,如社交网络、犯罪网络、交通网络等,并且可以很好地实现节点分类、连接预测、节点聚类、可视化、影响力建模及内容推荐的任务<sup>[5]</sup>。近期,图嵌入技术在各方面

的应用研究较为广泛。例如,文献[6]利用静态图快照中项目之间的相似性,对节点的边加上不同类型的权重,改善了新加入节点的冷启动效果。文献[7]捕捉节点边缘的偏好,将兴趣计算从云端下沉到边缘进行推荐。另一种是对动态图嵌入的研究,动态图嵌入不仅针对当前的图,而且针对时间相关的图序列信息进行研究。文献[8]捕捉节点行为随时间的变化,将空间行走与时间行走分为2个问题分步解决,并进行综合判定图嵌入。文献[9]使用演化随机游动,并使用先前的嵌入向量初始化当前图嵌入,实现可伸缩的动态图嵌入。文献[10]将图嵌入技术应用于无人机的自组网中,构建时序化嵌入模型,进行无人机的链路预测。文献[11]提出了一种三方深度网络表示模型,它使用来自三方的信息共同学习最佳节点表示,所提出的耦合架构设计有效地优化了动态图嵌入效果。

由此可见,图嵌入方法计算简单且可以充分利用节点的特征信息快速构建合理的网络拓扑,图嵌入方法目前被引入许多不同的研究领域,并且针对各领域的特点做出了一定的改进。对于车联网的应用环境,图嵌入方法,特别是动态的图嵌入方法优势在于:可以充分利用车辆的特征信息进行拓扑发现,提高网络连通度并减少通信的断链;计算简单、速度快、占用资源较少,能够对动态性较强的车辆节点变化做出快速的反应;建立拓扑的节点度分布,节点中心性较为平均,可以适应快速变化的动态网络,并且不依赖少数中心节点,提高网络的稳健性;链路数量适中,所建立的网络冗余度较低。但是,目前图嵌入研究对动态性较高的网络研究较少,并且建立网络关系时往往在较大范围内进行检索优化,不适用于有明显相对位置关系且相关节点较少的车辆网络环境,会耗费大量无意义的计算资源,因此需要对其架构和优化方法做出相应的改进。

在车联网方面,文献[12]将图嵌入方法应用于车联网领域,使用原始图嵌入方法结合聚类方法对车辆的轨迹进行聚类,实现车辆的分类处理。文献[13]利用车辆轨迹信息结合图嵌入技术,开发了一种车辆轨迹识别模型,可以学习并识别出受攻击的异常车辆轨迹。文献[14]提出了基于虚拟网络的图嵌入方法,用于优化城市网络中车辆节点的资源利用率,减少平均等待时间。综上,目前图嵌入及车联网的研究内容十分广泛,构建合适的图嵌入技术可以充分利用车辆节点的特征信息,有效指导网络的

构建，但是目前图嵌入技术在车联网场景的适配研究较少，也少有适用于真实场景下的网络拓扑发现研究，使网络拓扑的构建不够合理有效。

本文针对真实车联网应用场景，提出了范围标签图嵌入 (LRGE, label-range graph embedding) 方法，改进现有图嵌入方法，结合目标车辆与其相关范围内的车辆特征，并且充分利用其特征标签进行网络的控制。所提方法更好地利用车辆的动态特征和车联网场景特性，实现车联网拓扑在连通性和稳健性上的提升。

本文的主要工作如下。

1) 建立车辆网络模型，将路段进行划分。处理车辆特征信息获得低维特征向量，利用驾驶员辅助系统获得车辆历史信息，并对信息进行预处理，进而推断驾驶员的驾驶风格，得到车辆低维特征向量，对新加入网络的车辆进行节点冷启动处理。

2) 提出 LRGE 方法控制车联网拓扑。LRGE 方法改进图嵌入随机游走方式，以适应车联网的应用场景，并且改进图嵌入模型，融合特征向量与车辆标签信息，使车辆特征聚合更准确高效，更好地利用车辆特征。

3) 使用平坦衰落复合信道模型，结合真实道路数据集进行实际效果的测试，仿真表明，本文所提方法构建的车联网拓扑在连通性和稳健性方面具有一定的优越性。

### 1 图嵌入车辆网络模型

针对图嵌入技术在车联网环境下的应用，本文提出的车辆网络模型架构如图 1 所示。

路侧单元 (RSU, road side unit) 是部署在路边

与车载单元 (OBU, on board unit) 进行通信识别的装置，RSU 与其范围下的 OBU 可以进行计算缓存的配合<sup>[15]</sup>，由于整个车辆网络十分复杂，在道路边缘部署一系列 RSU，然后根据 RSU 分割路段，每一段道路都构成一个网络。同一网络内的车辆节点通过 RSU 根据图嵌入方法统一计算的连接进行连接，网络拓扑直接分发到下属的 OBU，车辆按照分发的网络拓扑进行信息的交互以及通信、计算资源的分配。而处于不同 RSU 范围的车辆则通过 RSU 之间质量更高的有线网络进行信息交互，这种方式可能会存在比车辆之间交互更大的时延，但是只要网络的整体覆盖范围较大且网络切换位置根据道路状况合理设置，再加入网络节点的冷启动机制，就可以较大限度地减少这一交互方式的影响。将网络分割处理，可以更好地优化每个子网络的性能，使整体性能得到提升。

确定车辆网络模型后，需要使用图嵌入技术控制网络拓扑。基于图嵌入的车联网自组织流程如图 2 所示。首先，获取节点的低维特征向量。利用高级驾驶员辅助系统 (ADAS, advanced driver assistance system)<sup>[16]</sup> (至少包含全球导航卫星系统、加速度计、陀螺仪等) 可以在每个车辆节点独立地获取连续车辆信息，再对车辆初始信息做出一定程度的预处理和推断，可以得出对应车辆的低维特征向量，特征向量结合车辆的历史信息和目前的状态信息。然后，根据特征向量进行节点间的随机游走。按照一定随机游走方式进行多次多步随机游走，确定候选的网络连接方式。最后，根据要求和场景确定的优化框架对网络拓扑进行筛选，计算得出最优的拓扑，并进行动态更新，实现动态的车联网拓扑控制。




图 1 车辆网络模型架构

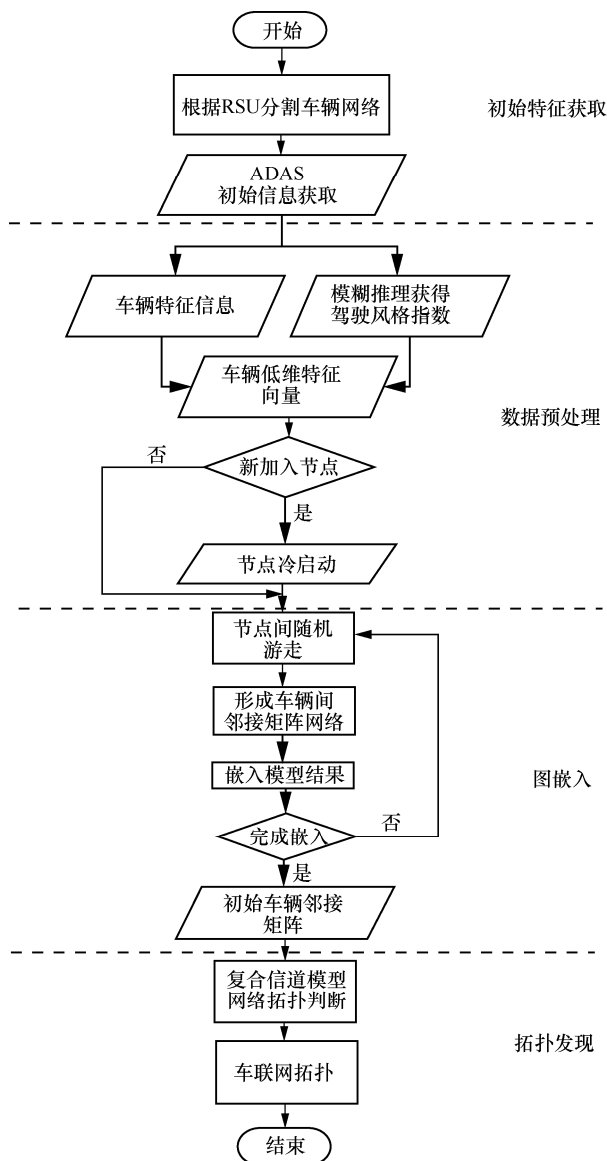


图 2 基于图嵌入的车联网自组织流程

根据上述流程，在划分网络后，为了获得车辆的低维特征向量，首先需要得到目标网络范围内的车辆信息并对其进行预处理。

## 2 车辆信息处理及低维特征向量获取

本节将叙述如何对获取到的车辆信息进行合适的预处理，得到可以充分反映车辆特征的低维特征向量。

### 2.1 车辆初始特征获取

随着 ADAS 的发展，产生了大量的车辆、路况以及驾驶员信息，利用这些信息可以判断驾驶员的驾驶特征、研究车辆行为，进而辅助网络拓扑的控制。

本文使用 ADAS 获取车辆的初始特征。由于特征信息是无关网络切换连续获取的，故每辆车在进入新的网络时都具有一定的初始信息，根据车辆的特征信息构建特征向量，形成归一化的驾驶风格数值，再与经过处理的车辆位置、车辆速度等合并为低维驾驶特征向量，为图嵌入的应用提供数据支撑。

本文将动态图  $G$  表示为一个无向无权图， $G_t = \{V_t, E_t\}$ ，其中， $V_t = \{v_t^1, v_t^2, \dots, v_t^n\}$  表示车辆节点， $E_t = \{e_t^1, e_t^2, \dots, e_t^m\}$  表示车辆之间的连边， $t$  表示对应时间的静态快照， $V_t$  和  $E_t$  都可以用动态变化的矩阵来表示。

通过 ADAS 可以获取目标路段车辆的历史信息，对这些信息进行处理可以获得初始的车辆低维特征向量。本文用七维向量表示车辆特征，分别是车辆 ID、车辆目前的经度和纬度、车辆横向摇摆特征、车辆近期纵向速度均值、加速度均值以及驾驶员驾驶风格指数 (DSI, driving style index)。其中，车辆 ID 由 RSU 定义，车辆目前经度和纬度可以通过全球导航卫星系统直接获取，近期纵向速度均值和加速度均值也可根据历史序列数据获得。下面将详细描述车辆横向摇摆特征和 DSI 的获取方法。

车辆横向摇摆特征旨在反映驾驶员对于超车的尝试行为，这一行为可以通过车辆横向速度信息推断，横向速度在短时间内变化幅度越大、越频繁，说明相应车辆的驾驶员越偏向于超车驾驶，即越易于摆脱当前的车辆集群。将一定时间段的横向速度进行傅里叶变换处理，获取其功率谱密度，然后对其进行振幅求和，获取的数值即可以作为反映车辆横向移动幅度和频率的车辆横向摇摆特征。

为了获取驾驶风格指数，本文使用模糊推理方法预测不同驾驶员的驾驶风格，这种方法有助于将驾驶员的意图与车辆的特征信息联系起来，并提供了一种适当的方式来表达驾驶行为的不确定性<sup>[16]</sup>。首先，将获得的车辆近期绝对速度值、加速度均值以及车辆横向摇摆特征以区域内最大值作为基准进行归一化处理，这样处理是为了得到驾驶员之间的相对属性而不受具体路况影响。然后，使用模糊语言变量描述 3 种属性的程度，分别为(慢速,中速,高速)、(减速,匀速,加速)、(跟车,摇摆,变道)，而输出的驾驶风格的语言变量为(保守,平均,激进)，并根

据驾驶风格推断的模糊逻辑为它们赋予合适的高斯型、三角型、Z 型、S 型的隶属度函数。再根据 4 种属性的逻辑关系设计合适的模糊推理规则。例如，绝对速度为中速、加速度均值为加速、摇摆特征为变道，可以推理为驾驶风格为激进，依次类推，确定 27 条对应的模糊规则。采用 Mamdani 模糊系统建模方式，以最大隶属度法进行反模糊化，得到[0,1]之间的模糊推理输出。这一输出即根据驾驶特征推理而得的 DSI，越偏向 1 说明驾驶风格越激进，反之则越保守。

相关时间内的车辆行驶信息经过上述处理，合并处理后的数据，即可获得车辆节点对应的低维特征向量。

### 2.2 新加入车辆节点冷启动

针对新加入网络区域的车辆节点，由于其刚驶入新的 RSU 范围内，在网络中还未与其他节点建立过连接，故需要对其进行冷启动处理，使其更快地与原有车辆建立合理的连接，以免在切换并加入网络时产生断链，进而导致整个网络连通度下降。故本文对于新加入车辆提出了一种基于范围的冷启动方法，如式(1)所示

$$v_i^0 = \alpha v_i^0 + \frac{1}{n} \sum_{s=1}^n (1 - \alpha) v_i^s \quad (1)$$

其中， $\alpha$  为介于[0,1]的超参数，用于确定特征向量修正的程度； $n$  为纳入考虑的周边车辆数目； $v_i^0$  和  $v_i^s$  分别代表新加入目标车辆与原网络中的参考车辆的特征向量。

根据式(1)，参照与目标车辆加入区域距离最近的数辆车，对新加入车辆进行重点范围的加权修正，更新得到新的特征向量，使修正后的新加入车辆节点特征更接近其驶入区域的特征，可以更快地与其他车辆节点建立稳定连接。

## 3 LRGE 方法

使用傅里叶变换、模糊推理、冷启动方法获得合适的车辆特征向量后，即可在目标区域构建合适的网络拓扑。不同于传统的路由方法以及网络构建方法，本文提出了 LRGE 方法来进行网络的拓扑控制。

### 3.1 随机游走模型

首先，需要对每一个车辆节点进行随机游走，根据应用环境，对 Node2Vec<sup>[17]</sup>随机游走方式进行

改进，此方法结合广度优先搜索与深度优先搜索，用 2 个超参数进行控制，对目标节点邻近的节点进行随机游走，以确定网络拓扑。但是 LRGE 方法根据车联网环境，为了扩展网络的连接范围，相较于原始方法并不会对前向节点进行游走。LRGE 随机游走方式如图 3 所示， $v$  表示目前游走节点， $u$  表示上一步游走的节点， $x$  表示目标节点周围的节点。




图 3 LRGE 随机游走方式

对于图 3 中随机游走路径的选择，需要预先计算一个转移概率矩阵。 $t$  时刻当前游走车辆的未归一化转移概率矩阵元素  $\alpha_{ij}(t, x)$  为

$$\alpha_{ij}(t, x) = \begin{cases} 0, & d_{vx} = 0 \\ p, & d_{vx} = 1 \\ q, & d_{vx} = 2 \end{cases} \quad (2)$$

按照所有相对概率之和确定归一化转移概率矩阵，该矩阵分配随机游动中的转移概率，基于 2 个超参数  $p$  和  $q$  进行随机游走。由于车载自组织网络的高度动态性以及新加入车辆的独立性，并且对车辆间通信造成最大干扰的并不是跳数，而是车辆的互相遮挡，故本文不选择 Node2Vec 常规采用的最小路径长度，而选择距离范围来进行网络的游走，需要控制游动尽量得到深度的随机游走，故应设置较大的  $p$  值和较小的  $q$  值，并且去除前向节点的随机游走路线，由此得到了 LRGE 的随机游走模型。此时  $d_{vx}$  不再是最短路径长度而是相对目标节点不同的欧氏距离范围分级，0 表示节点为先前游动节点或范围外节点，1 表示最近范围节点，2 表示稍远范围节点。

### 3.2 图嵌入优化框架

确定随机游走方式之后，需要对随机游走产生

的结果进行进一步的筛选，图嵌入方法广泛采用 Skip-Gram<sup>[18]</sup>方式，通过给定的输入词向量来预测其上下文，但是这种方式比较单一，无法充分利用其中比较具有特质的信息，故针对车联网应用环境，本文对传统框架进行改进，提出了 LRGE 体系架构，可以充分利用相关车辆信息进行连接的确 定，如图 4 所示。




图 4 LRGE 体系架构

图 4 左侧表示目标车辆特征  $v^0$  与附近的车辆加权进行冷启动的向量修正过程，右侧  $c^0$  表示目标车辆的驾驶风格标签，框架融合车辆的标签信息和内容信息，在给定输入后预测车辆的连接邻居，以辅助随机游走的最终优化目标选取。

根据上述优化思路，为了获取合理的网络拓扑结构，在预测连接方式时，需要最小化以下函数

$$L(t) = \sum_{u=1}^l -\ln \Pr(v_t^u | v_t^0, c_t^0) \quad (3)$$

其中， $v_t^u$  是随机游走产生的连接车辆的特征向量， $v_t^0$  和  $c_t^0$  是目标车辆本身的特征向量与驾驶风格标签， $l$  是范围内的目标车辆数量。其目的是根据随机游走的车辆特征向量进行最终连接的优化，在优化最终车辆邻接矩阵时，需要同时考虑整个网络中所有车辆对应的连接优劣，使最终产生连接的节点具有更相似的性质。由独立性假设，则概率  $\Pr(v_t^u | v_t^0, c_t^0)$  为

$$\prod_{1 \leq j \leq l} \Pr(v_t^j | v_t^0, c_t^0) \quad (4)$$

根据图 4 思路结合车联网的应用场景，LRGE 方法定义的计算方法如下

$$\Pr(v_t^u | v_t^0, c_t^0) = \rho^u \frac{\exp((v_t^0)^T v_t^u)}{\sum_{w=1}^l \rho^w \exp((v_t^0)^T v_t^w)} \quad (5)$$

$$\rho^x = \frac{1}{|c_t^0 - c_t^x| + 1} \quad (6)$$

对于条件概率的定义，使用 soft-max 方式进行计算，即由于车辆行驶速度、加减速等数值存在负数，用指数函数来避免出现负值，LRGE 方法需要利用车辆的特征向量信息，并且很大程度地使用驾驶员驾驶风格指数作为加权，式(5)融合了标签信息和内容信息，使随机游走的构建更具合理性，当车辆驾驶员之间的驾驶风格相似、车辆节点特征相近时，这样的节点可以更大概率被选择连接。综合考虑整个网络的属性，这种方式结合上述游走方法可以更好地达到驾驶风格聚类的效果，例如，后方驾驶速度较快的车辆，会更加倾向与前方车辆形成连接链路，驾驶风格相近的两辆车可以建立更长时间且更加稳定的连接。

根据生成的多条随机游走路线，以式(3)中函数优化根据车辆特征筛选出最为合理的网络连接方法，建立最终的网络拓扑，可以在较少的链路数量和较低的节点度情况下，实现车联网拓扑较好的连通性和稳健性，并且以图嵌入方式建立的网络的节点中心性分布也较为平均，不会出现过高的节点度和对网络影响较大的核心节点，这样在通信条件差、节点动态性强且较不稳定的车联网应用场景下，有很大的优势。

动态图本质上是进化的，如果只根据极大似然法进行单纯的一次随机游走，由于没有考虑到整体的最优，可能会导致不合适的连接，对网络造成很大的压力，因此应该在综合考虑车辆历史图信息的前提下，对网络整体进行优化，在有限次的游走中取得其嵌入的最优值，然后根据时间戳所对应的快照进行实时更新，优化网络邻接矩阵，实现动态的图嵌入网络拓扑控制。

#### 4 性能测试与分析

本节将对建立的车联网拓扑进行性能分析。本文使用真实道路数据集，选定合适的无线信道模型，使用 4 种方法与所提方法进行对比分析。

##### 4.1 道路及信道仿真

本文采用 NGSIM (next generation simulation)

数据集中 I-80 车辆数据集进行仿真，此数据集为 I-80 高速公路上所测得的真实车辆数据集，此路段包含 6 条高速公路车道（其中一条为高乘车道）和一条汇入的斜坡弯道。实验使用 MATLAB 环境进行仿真。

为了模仿真实路况的通信环境，本文采用平坦衰落复合信道模型，包括路径损耗、阴影衰落与多径衰落<sup>[19]</sup>。考虑到阴影衰落与路径损耗的对数正态阴影模型为

$$PL(d_{ij}) = PL_0 + 10n \lg\left(\frac{d}{d_0}\right) + X_\sigma \quad (7)$$

根据式(7)，结合多径衰落得到两车之间的接收信噪比  $r$  为

$$r = \frac{P_T}{\sigma_n^2} K \left(\frac{d_{ij}}{d_0}\right)^{-\alpha} s |h|^2 \quad (8)$$

其中， $P_T$  为发射端信号功率； $\sigma_n^2$  为加性白高斯噪声的方差； $K$  为信道平均衰减特性； $\alpha$  为衰减因子； $d_{ij}$  为相连两车的距离； $s = 10^{0.1X}$  表示阴影衰落， $X$  为均值为 0、方差为  $\sigma_s^2$  的正态随机变量； $h = X_1 + jX_2$  表示多径衰落， $X_1$  和  $X_2$  为均值为 0、方差为  $\sigma_h^2$  的正态随机变量。根据文献[19-21]对于无线信道的研究，结合车联网的较差的通信环境，本文设置仿真参数如表 1 所示。当接收端信噪比小于 3 dB 时，认为通信发生了中断。

表 1 仿真参数

参数	参数值
参考距离 $d_0$ /m	1
衰减因子 $\alpha$	4
阴影衰落标准差 $\sigma_s$ /dB	10
多径衰落方差 $\sigma_h^2$	0.5
发送端信噪比 $\frac{P_T}{\sigma_n^2}$ /dB	23
信道平均衰减特性 $K$	与天线特性及信道的平均衰减有关，初始值设为 $10^5$

## 4.2 网络拓扑性能对比

本文分别使用随机网络、动态生长 (DN, dynamic growth) 方法<sup>[22]</sup>、深度游走 (DeepWalk) 图嵌入<sup>[23]</sup>以及改进的 Node2Vec 图嵌入 4 种方法构建网络拓扑，并与所提出的 LRGE 方法进行性能对比，对比数据采用目标范围内(约 100 米车辆密集路段) 400 帧图快照处理结果的平均值。

### 4.2.1 网络合理性分析

平均连边数目衡量了网络的冗余程度，拥有较大的连边数目的网络冗余过于严重，所产生的网络会产生过多的能耗，过高的连边数产生的较大节点度会使车辆天线难以正常通信。断链概率反映了节点之间建立连接的合理性，较合理的网络拓扑对应着较低的断链概率，断链概率高也会造成严重的通信中断，进而影响整个网络的性能。平均跳数是网络中可达节点之间的平均路径长度。仿真结果如表 2 所示。

表 2 仿真结果

方法	连边数目/条	断链概率	平均跳数
随机网络	<b>28.967 4</b>	0.461 6	3.137 8
DeepWalk	59.619 0	0.103 7	3.264 0
DN	43.784 5	0.393 5	<b>2.782 9</b>
Node2Vec	37.147 9	0.067 5	3.264 0
LRGE	39.944 9	<b>0.062 8</b>	3.286 8

由表 2 结果可知，DeepWalk 方法由于游走方式更加随机，游走范围相较于另 2 种图嵌入方法更加宽泛，导致筛选出的链路过多，网络连边太多，耗费了大量的通信资源，且对实际车辆性能要求过高。随机网络虽然具有较少的连边数目，但是在拓扑发现的过程中，由于方式完全随机，不合理的链路较多，导致其断链概率极高，难以实际应用。DN 方法采用倾向无标度网络的构造方法，连接更倾向于度数高的节点，过于依赖少数中心节点，使断链概率也较高。DeepWalk 次之，Node2Vec 与 LRGE 断链概率最小，可以看出 LRGE 方法所构建的网络最合理，具有较低的断链概率，连边数目适中，目标车辆平均与 3 辆车建立联系，网络的冗余度低、稳健性好。5 种方法的车辆之间平均 3 跳可达较为合理，但 DN 方法在测试条件下，由于其网络在运行的过程中有明显的多个连通片，不可达节点多，故虽然路径较短但参考意义不大。

不同通信条件下，即不同无线信道模型的信道平均衰减特性下，断链概率如图 5 所示。

从图 5 中可以看出，衰减因子越大，通信条件越好，随着信道条件改善，断链概率也逐渐降低。Node2Vec 和 LRGE 的图嵌入方法可以构建更切实可行的网络，由于 DeepWalk 方法连边冗余过高，本文不做比较，本文对 DN 方法及 2 种图嵌入方法

的目标性能进行重点比较，而随机网络的相关数值仅作趋势参考，实际意义不大。

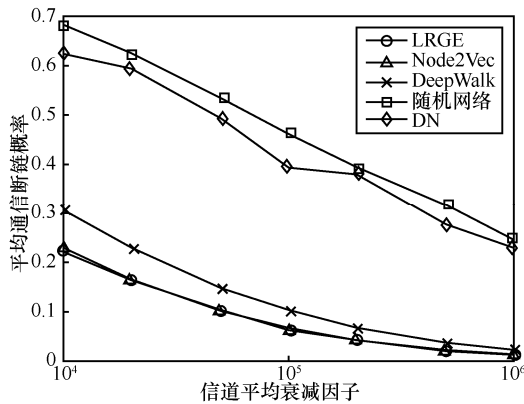


图 5 不同通信条件下断链概率

#### 4.2.2 网络连通性及稳健性分析

车联网构建的主要目标属性为网络的连通性以及稳健性<sup>[22]</sup>，这 2 种属性可以由连通概率、节点重要性分布、割点占比反映。其中，车辆的平均连通概率越高，说明目标车辆之间连通性高，网络连通性好。节点重要性分布越平均，各个节点之间重要性差别越小，即不存在相对中心的节点，说明网络较为平坦，不会因为少数车辆节点的波动或丢失而受到较大的影响，网络的稳健性较为优秀。割点是删除后网络连通片变多的节点，割点占比越低，网络中消失节点越不容易造成网络连通性降低，因此网络的连通性和稳健性都更加有优势。仿真结果如表 3 所示。

表 3 主要目标属性对比

方法	连通概率	重要性分布	割点占比
随机网络	0.406 8	0.022 2	0.504 2
DN	0.555 1	0.031 5	0.409 8
Node2Vec	0.611 0	0.012 9	0.311 3
LRGE	<b>0.644 9</b>	<b>0.012 5</b>	<b>0.250 2</b>

表 2 中属性 Node2Vec 与 LRGE 方法基本持平，表 3 中属性即重点提升的目标属性。由表 3 中数据可知，DN 方法连通概率较低，而 LRGE 方法在此通信条件下在大多数时间快照连通概率较高且形成的连通片较少，平均每个车辆节点可以与大多数车辆连通，结合 RSU 通信可以实现较好的网络连通效果，并且效果优于 Node2Vec 与 DN 方法，网络连通性最优。

节点重要性分布使用节点 PageRank 值的标准差衡量。本文方法的网络重要性分布更为平坦，DN 方法构造无标度网络，节点之间度差异最大，数据表明通

过图嵌入方法构建的网络，不会出现度数和网络位置较为核心的节点，这一优势使车联网动态环境下，每辆车的通信负载不会过高，并且网络不会因为单个或少数车辆节点的移出或异常而产生较大波动，网络更具有稳健性。相反，DN 方法由于大多数连接集中在少数节点上，如果核心节点驶离网络，会造成较大范围的不良影响。LRGE 方法割点占比也明显低于另 3 种方式，说明其构造的网络更加稳健、连通性更可靠。

由此可见，本文所提方法构建的网络拓扑性能较好，在连通性、稳健性上都具有良好的表现，结合图嵌入方法计算简单、速度快的特点，应用历史图数据的情况下，可以在网络快照上进行实时动态更新，网络的动态性也较好。为了进一步衡量网络性能，变更通信条件进行测试，得到主要目标属性效果如图 6~图 8 所示。

从图 6 可以看出，在一般通信条件下，2 种图嵌入方法，特别是 LRGE 方法连通概率较大，能够在通信条件较差的情况下保持良好的连接，DN 方法和随机网络在大部分正常情况下网络连通度较差且测试时波动较大，只有在通信条件极好的情况下连通性较好，这是因为两者断链概率较高，信道条件较好时连边数量大幅增加，但这会导致冗余的连接，车辆节点负载重。从图 7 可以看出，节点的重要性分布依然有一定差距，随着断链概率降低，网络也更容易因为车辆位置差异产生核心节点，但是与随机网络对比，2 种图嵌入方法所形成的网络平坦程度都比较理想，在 Node2Vec 方法趋于平稳后，LRGE 方法依然持续下降，并且 2 种图嵌入方法即使在断链较多的情况下，也没有形成差异大的核心节点。从图 8 可以看出，割点占比差距较为明显，随着通信条件改善，LRGE 方法的割点占比始终低于对比方法。

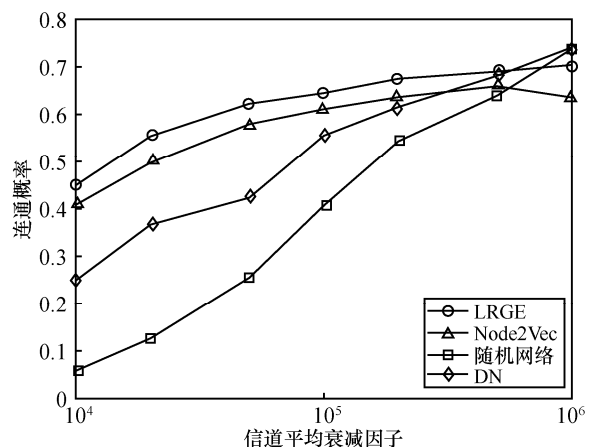


图 6 不同通信条件下的连通概率

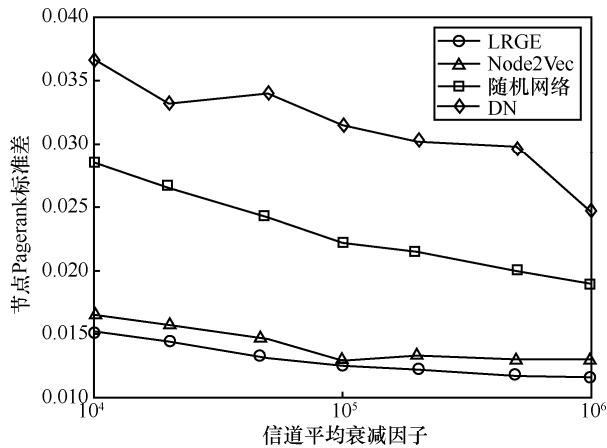


图7 不同通信条件下节点的重要性分布

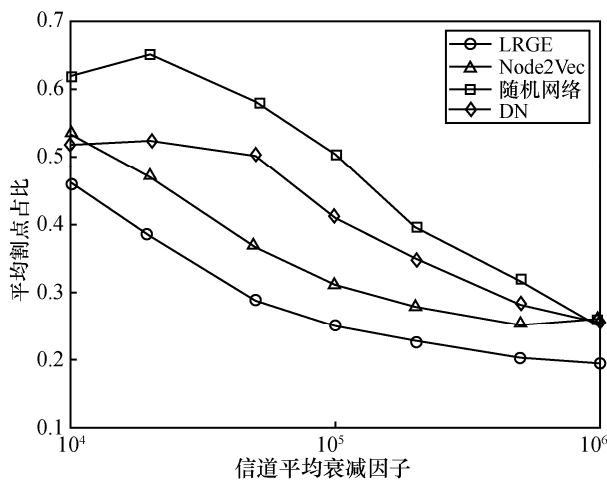


图8 不同通信条件下的平均割点占比

由以上仿真可知,在不同通信条件下 LRGE 在主要目标属性上具有一定优势,效果较为稳定,优于对比方法,网络的连通性、稳健性较好。

## 5 结束语

由于车联网具有高移动性和复杂性,并且通信条件较差,网络拓扑控制较为困难,为了使网络动态快速构建,本文将图嵌入方法引入车联网应用环境并且对其进行适配改进。首先,将路段划分,通过驾驶员辅助系统获取并处理目标车辆信息,使用模糊推理方法得出驾驶员的驾驶风格指数,将原始车辆信息转化为低维特征向量,并对新加入节点进行基于范围的冷启动处理;其次,提出 LRGE 方法,改进随机游走方式,在优化框架中利用驾驶风格指数作为标签信息,构建对应的优化函数;最后,在连续网络快照中判断路段目标范围内的车辆连接,确定动态变化的车辆邻接矩阵,实现网络拓扑的动态控制。经过 NGSIM 真实车辆数据集上的仿真测

试,可以得知,本文所提图嵌入方法构建的车联网拓扑具有良好的动态性、连通性以及稳健性。

## 参考文献:

- [1] 辛燕, 冯霞, 李婷婷. VANET 中位置相关的轻量级 Sybil 攻击检测方法[J]. 通信学报, 2017, 38(4): 110-119.  
XIN Y, FENG X, LI T T. Position related lightweight Sybil detection approach in VANET[J]. Journal on Communications, 2017, 38(4): 110-119.
- [2] 张海波, 王子心, 贺晓帆. SDN 和 MEC 架构下 V2X 卸载与资源分配[J]. 通信学报, 2020, 41(1): 114-124.  
ZHANG H B, WANG Z X, HE X F. V2X offloading and resource allocation under SDN and MEC architecture[J]. Journal on Communications, 2020, 41(1): 114-124.
- [3] KCHAOU A, ABASSI R, GUEMARA S. Towards the performance evaluation of a clustering and trust based security mechanism for VANET[C]//Proceedings of the 15th International Conference on Availability, Reliability and Security. New York: ACM Press, 2020: 1-6.
- [4] 祁志卫, 王筋辉, 岳昆, 等. 图嵌入方法与应用: 研究综述[J]. 电子学报, 2020, 48(4): 808-818.  
QI Z W, WANG J H, YUE K, et al. Methods and applications of graph embedding: a survey[J]. Acta Electronica Sinica, 2020, 48(4): 808-818.
- [5] 袁立宁, 李欣, 王晓冬, 等. 图嵌入模型综述[J]. 计算机科学与探索, 2022, 16(1): 59-87.  
YUAN L N, LI X, WANG X D, et al. Graph embedding models: a survey[J]. Journal of Frontiers of Computer Science and Technology, 2022, 16(1): 59-87.
- [6] WANG J Z, HUANG P P, ZHAO H, et al. Billion-scale commodity embedding for E-commerce recommendation in Alibaba[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM Press, 2018: 839-848.
- [7] GONG Y, JIANG Z W, FENG Y F, et al. EdgeRec: recommender system on edge in mobile Taobao[C]//Proceedings of the 29th ACM International Conference on Information & Knowledge Management. New York: ACM Press, 2020: 2477-2484.
- [8] PANDHRE S, MITTAL H, GUPTA M, et al. STwalk: learning trajectory representations in temporal graphs[C]//Proceedings of the ACM India Joint International Conference on Data Science and Management of Data. New York: ACM Press, 2018: 210-219.
- [9] MAHDAVI S, KHOSHRAFTAR S, AN A J. Dynnode2vec: scalable dynamic network embedding[C]//Proceedings of 2018 IEEE International Conference on Big Data. Piscataway: IEEE Press, 2018: 3762-3765.
- [10] 舒坚, 王启宁, 刘琳岚. 基于深度图嵌入的无人机自组网链路预测[J]. 通信学报, 2021, 42(7): 137-149.  
SHU J, WANG Q N, LIU L L. UAV ad hoc network link prediction based on deep graph embedding[J]. Journal on Communications, 2021, 42(7): 137-149.
- [11] PAN S, WU J, ZHU X, et al. Tri-party deep network representation[J]. Network, 2016, 11(9): 12.
- [12] WANG W, XIA F, NIE H S, et al. Vehicle trajectory clustering based on dynamic representation learning of Internet of vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(6): 3567-3576.
- [13] HUANG S E, FENG Y H, LIU H X. A data-driven method for falsified vehicle trajectory identification by anomaly detection[J]. Transportation Research Part C: Emerging Technologies, 2021, 128: 103196.
- [14] FAN W B, LI P, HAN Z J, et al. Dynamic virtual network embedding

of mobile cloud system based on global resources in Internet of vehicles[J]. IEEE Transactions on Vehicular Technology, 2021, 70(8): 8161-8174.

- [15] 李方伟, 张海波, 王子心. 车联网中基于 MEC 的 V2X 协同缓存和资源分配[J]. 通信学报, 2021, 42(2): 26-36.  
LI F W, ZHANG H B, WANG Z X. V2X collaborative caching and resource allocation in MEC-based IoV[J]. Journal on Communications, 2021, 42(2): 26-36.
- [16] WANG C, SUN Q Y, GUO Y S, et al. Improving the user acceptability of advanced driver assistance systems based on different driving styles: a case study of lane change warning systems[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(10): 4196-4208.
- [17] GROVER A, LESKOVEC J. Node2vec: scalable feature learning for networks[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM Press, 2016:855-864.
- [18] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space[J]. arXiv Preprint, arXiv: 1301.3781, 2013.
- [19] GOLDSMITH A. Wireless communications[M]. Cambridge: Cambridge University Press, 2005.
- [20] ANDERSEN J B, RAPPAPORT T S, YOSHIDA S. Propagation measurements and models for wireless communications channels[J]. IEEE Communications Magazine, 1995, 33(1): 42-49.
- [21] SKLAR B. Rayleigh fading channels in mobile digital communication systems.I. Characterization[J]. IEEE Communications Magazine, 1997, 35(7): 90-100.
- [22] 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.  
HAN T, HE W, DAI J, et al. Connectivity analysis of IoV based on scale-free network[J]. Journal on Communications, 2021, 42(4): 100-108.
- [23] PEROZZI B, AL-RFOU R, SKIENA S. DeepWalk: online learning of social representations[C]//Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM Press, 2014: 701-710.

#### [作者简介]



孙雁飞 (1976- ), 男, 山东济南人, 博士, 南京邮电大学研究员, 主要研究方向为人工智能在工业互联网、能源互联网、智慧供应链等领域的关键技术与应用。



尹嘉峥 (1998- ), 男, 山东济南人, 南京邮电大学硕士生, 主要研究方向为车联网、复杂网络等领域的技术与应用。



亓晋 (1983- ), 男, 山东济南人, 博士, 南京邮电大学副教授, 主要研究方向为人工智能在工业互联网、能源互联网、智慧供应链等领域的关键技术与应用。



胡筱旋 (1992- ), 女, 江苏南京人, 博士, 南京邮电大学讲师, 主要研究方向为机器学习、云计算。



陈梦婷 (1994- ), 女, 安徽桐城人, 博士, 南京邮电大学讲师, 主要研究方向为系统辨识与深度学习。



董振江 (1970- ), 男, 江苏南京人, 博士, 南京邮电大学研究员, 主要研究方向为计算机视觉、知识图谱在车联网、高精度定位等领域的关键技术与应用。