

基于移动贝叶斯和左右手的 GPSR 协议^①

周德宇, 戴海燕

(广州城市理工学院 汽车与交通工程学院, 广州 510800)
通信作者: 周德宇, E-mail: 740617330@qq.com



摘要: 针对车联网 (Internet of Vehicles, IoV) 中大多数基于位置的路由协议存在传输时延高的问题, 提出一种基于移动贝叶斯和仿生智能算法的路由协议. 首先, 该协议在原贪心周界无状态路由 (greedy perimeter stateless routing, GPSR) 协议的基础上引入动态贝叶斯网络 (dynamic Bayesian network, DBN), 用于预测车辆下一时刻位置, 然后确定下一时刻距离源节点最远且最可靠的节点. 基于所确定的节点确定可信通信范围, 在可信通信范围内添加移动性的概念来选择下一跳. 其次, 如果不符合贪心转发条件而转入周界转发, 该协议采用蛙跳算法 (shuffled frog leaping algorithm, SFLA)、蚁群优化算法 (ant colony optimization algorithm, ACO) 和左右手法则确定下一跳路由路径. 实验结果表明, 该协议在高速公路场景中的数据包丢失率 (packet loss rate, PLR) 和吞吐量均优于经典 GPSR、无线自组网按需平面距离向量路由 (ad-hoc on-demand distance vector routing, AODV) 协议、基于粒子群优化的 GPSR (particle swarm optimization based GPSR, PSO-GPSR) 协议和最大累计通信持续时间最小角度 GPSR (maxduration-minangle GPSR, MM-GPSR) 协议.

关键词: 贪心周界无状态路由; 贝叶斯; 蛙跳算法; 蚁群优化算法; 左右手

引用格式: 周德宇, 戴海燕. 基于移动贝叶斯和左右手的 GPSR 协议. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/10124.html>

GPSR Protocol Based on Mobile Bayesian and Left and Right Hand

ZHOU De-Yu, DAI Hai-Yan

(School of Automobile and Traffic Engineering, Guangzhou City University of Technology, Guangzhou 510800, China)

Abstract: To address the high transmission latency commonly found in location-based routing protocols for the Internet of Vehicles (IoV), a routing protocol for mobile Bayesian and bionic intelligent algorithms is proposed. Firstly, the protocol introduces a dynamic Bayesian network (DBN) on the basis of the original greedy perimeter stateless routing (GPSR) protocol to predict the future position of vehicles, and then determine the farthest and most reliable node from the source node at the next time. Based on this node, a trusted communication range is established, within which the concept of mobility is incorporated to select the next hop. Secondly, if the greedy forwarding condition is not met, causing a switch to perimeter forwarding mode, the protocol uses the shuffled frog leaping algorithm (SFLA), ant colony optimization algorithm (ACO), and left and right hand method to determine the next hop routing path. Experimental results show that, in highway scenarios, the proposed protocol outperforms several benchmark protocols in packet loss rate (PLR) and throughput, including the classical GPSR, ad-hoc on-demand distance vector routing (AODV) protocol, particle swarm optimization based GPSR (PSO-GPSR) protocol, and maximum duration miller GPSR (MM-GPSR) protocol.

Key words: greedy perimeter stateless routing (GPSR); Bayesian; shuffled frog leaping algorithm (SFLA); ant colony optimization algorithm (ACO); left and right hand

^① 基金项目: 广东省普通高校特色创新类项目 (2024KTSCX158)

收稿时间: 2025-09-30; 修改时间: 2025-10-27; 采用时间: 2025-11-17; csa 在线出版时间: 2026-03-02

改革开放以来,随着我国汽车工业飞速发展,汽车从以前的奢侈品转变成现在的生活必需品.虽然汽车的舒适性和独立性给通勤带来了巨大的便利,但车辆数量的飞速增加所导致的拥堵和事故也快速增加,道路和交通问题由此逐渐显现出来.在此期间,车辆的交互产生了提供有效流量的 IoV. IoV 是一种应用于交通领域的物联网技术,它可以让车辆与附近的车辆、人类、特殊设备以及网络/云计算(平台)进行大量的信息交流.在 IoV 中,任意一辆车进入车辆都能够向周围的其他车辆广播路网状态等消息参数,相关车辆收到这些参数后可以获取路网信息,正确调整行驶路径. IoV 能够与路边基础设施共同优化交通,也能够推进配套设施的进步.虽然实际中的 IoV 已支持大量应用和协议.然而,在 IoV 中,存在着大量的车辆节点,这些车辆节点速度较快并且移动性强,这有较大的概率造成通信开销增加并导致 IoV 的处理能力降低,从而使得经典 IoV 路由算法数据包传输能力有限^[1].

贪心周界无状态路由 (greedy perimeter stateless routing, GPSR)^[2]协议是一种基于地理位置的路由协议算法,主要用于 IoV 中的数据包转发决策,是一种比基于拓扑路由协议优秀的路由协议. GPSR 算法有两种转发决策:贪心转发和周界转发决策.贪心转发是该算法的核心部分,其意味着在将数据包发送到目标车辆之前的所有过程都会根据贪心算法策略执行数据包传递过程.周界转发决策是对贪心转发决策的补充,解决了贪心转发执行失败后的数据包转发问题.当没有满足“贪心转发”条件的相邻节点时,数据包进入周界模式,该模式依据右手法则将数据包转发给相邻节点.

但贪心转发和周界转发都有明显的缺点.贪心转发所选的中继节点一般是离源节点最远的节点,故所选中继节点有一定的概率在通信区域的边界上,传输过程中中继节点有一定的概率在源节点通信范围以外,这样会导致数据包丢失率 (packet loss rate, PLR) 增加.而周界转发确定的路由路径存在着路径冗余的情况,导致吞吐量降低.

近年来,大量学者针对 GPSR 贪心转发的缺点进行研究,取得一系列成果,但大多数学者仅针对贪心转发的链路不稳定问题研究优化方案.这些贪心转发优化方案主要分为两大类:一类是传统方案,另一类是基于仿生智能和需要机器学习或者训练的方案.传统方案中,研究者们依赖车辆在路网当中的参数通过加

权等方式进行优化^[3-5],但使用加权技术的协议的权值固定,不能根据拓扑的改变而改变,因此在某些情况下无法获得预期结果.

预测下一时刻节点位置是解决 GPSR 的链路不稳定问题的另一个方案,文献^[6,7]采用该技术解决了 GPSR 链路不稳定问题.文献^[6]的研究成果借助了卡尔曼滤波 (Kalman filter, KF),但仅能应用于线性高斯系统中.而在 IoV 中,有大量速度非恒定的情况,此时需要将非线性系统近似成线性系统,所以预测车辆位置存在误差,故 KF 不适合所有的场景.文献^[7]采用了遗传算法 (genetic algorithm, GA) 预测车辆下一时刻位置,但 GA 对参数较敏感,交叉率、变异率等参数的设置直接影响解的质量,经验性参数调整占比过高,可能导致过早收敛或无效搜索.

除了这些优化方案,还有一些学者通过无监督学习^[8]、机器学习^[9]、神经网络^[10]等需要通过计算机预训练的算法来优化贪心转发.在机器学习中,针对“如何从数据中学习”这一问题形成了不同的理论,贝叶斯理论是其中一种核心理论.贝叶斯理论核心是贝叶斯学习,即模型参数不能确定,核心目标是通过先验概率与观测数据结合,利用贝叶斯公式计算后验概率.为提升车联网预测效果,研究人员将贝叶斯理论应用到车联网,提出动态贝叶斯网络 (dynamic Bayesian network, DBN). DBN 的概率框架可以有效地处理车辆轨迹的不确定性,常用于推理和分类^[11].因此,考虑到车辆间的交互作用, DBN 是一种预测车辆下一时刻位置的合适选择.

还有一部分研究对于两个缺陷均给出了优化方案.目前,有 MM-GPSR^[12]、LQ-GPSR^[13]和 MG-GPSR^[14]同时对贪心转发和周界转发进行优化.尽管这 3 个优化方案在性能上表现较为优秀,但这 3 个方案都是在城市场景或者网格场景中进行验证的,因此在高速公路场景中的应用会存在一定的限制.

随着仿生智能算法的不断发展,其应用在各种不同的方向.比如在求解车辆无人机配送问题中的应用 SLFA^[15];在工程生物学中提出了一种基于多目标洗牌 SLFA 的高效方法,用来解决多目标途径设计存在的问题^[16];在评估大学英语教学质量问题中提出基于反向传播神经网络的改进洗牌 SFLA^[17];在学生心理优化的协作学习机制中采用 SFLA 进行优化^[18];在提高光伏电池板功率中使用 SFLA^[19];在分布式发电中使用改

进 SFLA^[20]. 故研究者们开始尝试使用仿生智能算法来优化周界转发. 这些仿生智能算法不仅降低了对仿真场景的依赖, 还展现出了卓越的自适应学习能力. 然而, 在高速公路场景中, 仿生智能算法存在着一些问题, 这在一定程度上限制了报文传输速度的提高. 这些仿生智能算法在 GPSR 的周界转发路径冗余问题优化中应用较少.

PSO-GPSR^[13]的工作流程可分为 3 步: 首先, 算法依据当前网络邻居的状态信息生成初始粒子群 (particle swarm optimization, PSO); 接着, 通过迭代计算, 动态调整粒子在解空间中的搜索方向与步长, 以逼近理论最优值; 最终, 建立粒子与物理节点的映射关系, 将数值最优解转化为实际的路由决策, 选定下一跳转发节点. 但 PSO 存在易陷入局部最优、参数设置敏感、依赖初始种群等缺陷. MG-GPSR^[14]的贪心转发在确定可信通信范围以后使用累计通信持续时间确定下一跳, 周界转发使用 GA 进行优化. 但 MG-GPSR 未能考虑链路质量和其他参数, 并且 GA 寻找的链路稳定性较弱, 收敛速度较慢, 对参数敏感, 在不同网络密度和速度下性能波动可能较大. 这些缺陷导致 MG-GPSR 在高速公路场景中性能不佳. 为解决配置密码和密钥的安全问题, 文献[21]基于非支配排序的遗传算法 II (non-dominated sorting genetic algorithm II, NSGA-II) 和簇修改了 IoV 路由协议. 文献[21]通过一种结合了 NSGA-II 和 PSO 的新型混合方法, 减少寻找停车位所花费的时间, 降低燃料消耗, 并提高停车位的利用率. 文献[22]提出了一种基于 GA 的方法来检测 IoV 中的黑洞攻击. 文献[23]提出一种分层聚类技术和新的数学公式, 以解决无基础设施的车辆云中的资源供应问题. 这个分层技术还使用文献[23]定制的 GA 来解决最大化问题, 并结合分组机制来高效解决问题. 文献[24]提出了一种基于多目标优化算法的特征选择算法 (feature selection algorithm based on a many-objective optimization algorithm, FS-MOEA). 自适应非显性排序遗传算法 III (adaptive non-dominant sorting genetic algorithm-III, ANSGA-III) 作为多目标优化算法. 在 FS-MOEA 中, 进一步设计了两种改进方法——偏置和加权小生境保留以及信息增益 (information gain, IG)-层次分析法 (analytic hierarchy process, AHP) 优先级排序. 前者通过赋予稀有类更高的优先级来抵消数据集中的不平衡问题, 后者用于搜索 FS-MOEA 的最佳特征子集. 在

IG-AHP 优先级排序中, 平均 IG 是 AHP 决策分析的核心因素. 文献[25]在软件定义网络的基础上提出自适应混合蛙跳算法 (adaptive hybrid-shuffled frog leaping algorithm, AH-SFLA). 首先, AH-SFLA 使用服务质量和全局拓扑信息两个指标设置适应度函数, 计算出适应度值之后查询并优化数据在传输链路上的路由. 选择路由完毕后, AH-SFLA 通过候选链路方案和服务质量资源消耗阈值维护路由路径, 降低了路由错误产生的概率. 文献[26]讨论了基于 ACO 的 GPSR 和连接感知路由协议的实现, 以证明 ACO 技术可以提高 GPSR 和连接感知路由协议的性能. 文献[27]在 ACO 的基础上提出了优化车辆贪心周界无状态路由 (optimize vehicle greedy perimeter stateless routing, OVGPSR) 协议. OVGPSR 在蚁群算法中引入中间节点距离目的节点之间的距离、夹角、通信半径这 3 个参数作为信息素浓度, 来计算能量和信道占用负载之间的信息素影响浓度和空间位置间的影响因素. 文献[28]提出了一种基于自适应服务质量的车载自组织网络路由 (adaptive quality-of-service-based routing for vehicle ad hoc network, AQRV). AQRV 自适应地选择数据包到达目的地的交点, 所选路由应满足服务质量 (quality of service, QoS) 约束, 并在连接概率、数据包传输率和延迟这 3 个指标上满足最佳 QoS. AQRV 使用基于 ACO 的算法解决路由选择问题. AQRV 还提出了终端交叉点概念, 以减少路由探索时间并缓解网络拥塞. 此外, 为了降低网络开销, AQRV 使用本地 QoS 模型来估计城市路段的实时和完整的 QoS. 文献[29]提出了一种延迟敏感车辆路由协议, 该协议使用多跳车辆中继定期估计, 并定义了路线时延的概念. 然后对平均延迟和延迟方差这两个参数进行更新和归一化处理, 以计算路段时延. 该协议利用 ACO 概念来发现从源到最接近目的地的目标交叉路口的端到端最佳延迟路径. 路由设置过程由反应式前向蚂蚁和后向蚂蚁实现, 它们分别负责网络探索和信息素传播. 在每个交叉点实施路由选择, 根据信息素路由表机会性地选择最佳的下一个交叉点. 源头主动维护, 利用周期性主动蚂蚁采样, 对数据传输期间的路由信息进行更新、扩展和完善. 此外, 文献[29]还使用一种贪婪转发技术在相邻的交叉点之间中继数据包.

尽管所提出的优化方案在性能上表现较为优秀, 但它们大多数在城市场景或者网格场景中进行验证, 因此在高速公路场景中应用会存在一定的限制. 还有

一些协议仅针对贪心转发的缺陷进行优化, 没有对周界转发的缺陷进行优化, 优化程度有限. ACO 的深度搜索有优势, 但存在着对节点稳定性评估无力、链路稳定性处理较弱、过于关注路径信息素、对初始信息素和参数敏感、在快速变化拓扑中可能表现不稳定、信道利用率较低等缺陷. SLFA 在广度搜索存在优势, 但存在着处理复杂问题时易陷入局部最优、收敛速度较慢的缺陷.

据此, 本文建立了适用于 GPSR 的高速公路车联网模型, 在兼顾吞吐量与 PLR 的同时, 引入 DBN、移动性和左右手法则来改进 GPSR 的贪心转发和周界转发算法, 提出基于移动贝叶斯和左右手的 GPSR 协议

(GPSR protocol based on mobile Bayesian and left and right hand, GPSR-MBLR) 协议. GPSR-MBLR 基于移动性和 DBN 优化贪心机制, 周界机制选择 SFLA 和 ACO 来避免单一模式缺陷. SFLA 的种群分组和混合机制有助于跳出局部最优, 提供多样性; ACO 则能快速收敛并能挑选出优质路径. 这种组合可以保证搜索的广度和深度, 有效解决了路径冗余问题.

1 GPSR 技术简述

1.1 GPSR 内容

GPSR 有两种转发决策: 贪心转发和周界转发. GPSR 的流程图如图 1 所示.

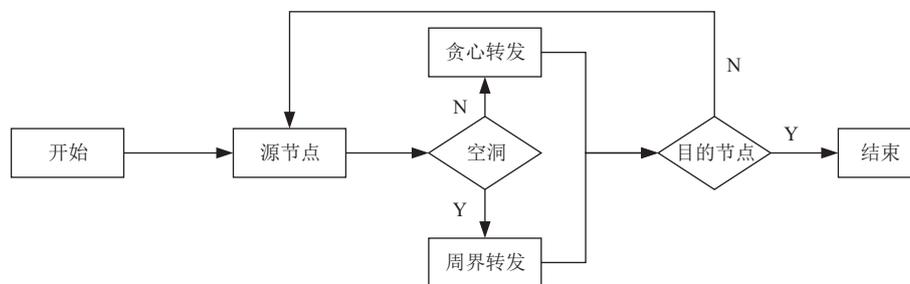


图 1 GPSR 路由协议流程图

根据 GPSR 规则, 如果源节点需要转发数据, 它选取并传递给通信范围内距离自己最远的节点, 这种转发方式称作贪心转发. 如图 2 所示, A 想把报文传递到 C 或 E, 根据 GPSR 的规则, 应该将报文传递至距离 A 最远的 D 节点, 然后再根据这个规则继续寻找邻居, 直至转发到目标节点.

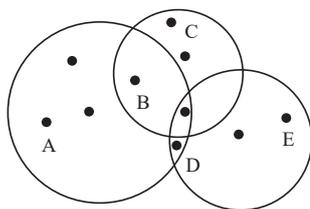


图 2 贪心转发示例

贪心转发存在路由空洞问题, 图 3 描述了路由空洞的一个例子. 此时, D 要和 x 通信, w 和 y 是 x 的邻居, 但 D 的通信区域内没有 w 和 y 两个节点, 所以对于 x 来说, x 不能和 D、v、z 通信. 但对于 D 来说, x 离 D 最远, 根据贪心规则, D 选择 x 作为中继, 将数据转发出去, 这会导致 x 无法接收消息, 导致通信失败. 为了解决这一问题, GPSR 采用周界转发的方式确保所

选取的路由路径能够正确传输报文.

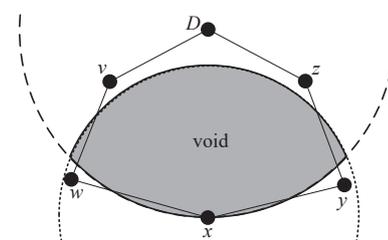


图 3 周界转发示例^[1]

如果节点能构成平面多边形, GPSR 采用“右手法则”来决定传输路径. 右手法则的内容是当报文从源节点到目标节点时, 以目标节点为原点, 顺时针旋转经过的第 1 条边是所需的路由路径. GPSR 将这种通过右手法则获得的路径称作周界转发.

根据右手法则, 若想绕过图 3 的空洞, 传输报文的顺序是 $x \rightarrow w \rightarrow v \rightarrow D \rightarrow z \rightarrow y \rightarrow x$.

1.2 GPSR 缺陷

虽然 GPSR 解决了贪心转发的路由空洞问题, 但是因为源节点根据贪心准则选取的邻居可能会在报文到达之前向通信区域外移动, 这样导致邻居丢失, 贪心

转发依然会失效. 如图 4 所示, 当前时间 A 为源节点, C 为最远离 A 的邻居. 根据贪心转发规则, C 被指定为下一跳的转发节点. 但 C 运动速度较快, 在 C 已经离开 A 的通信范围之后, A 将报文传递到 C 的原始位置. 更新节点后, C 不再是 A 的邻居, 但 A 仍将 C 作为中继, 继续把数据传递给 C. 这样会导致 A 在发现无法将报文传递给 C 之后重新搜索下一跳并且重传数据包, 这会导致网络的 PLR 增加.

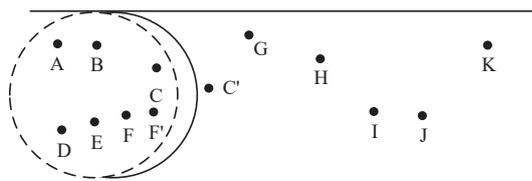


图 4 邻居丢失问题

而在进行周界转发时, 选择路线的时候会有冗余. 在图 5 中, 节点 F 贪心转发失败, 根据 GPSR 的规则需转入周界转发. 根据周界转发规则, 我们需要选取 F→E→D→B→A 这一条路径, 也可以选择 F→C→A 这条路径, 如图 6 所示. 经过对比发现, 路由路径存在冗余, 这导致网络吞吐量减少.

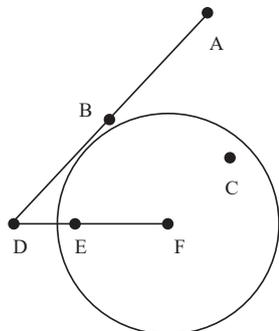


图 5 周界转发冗余

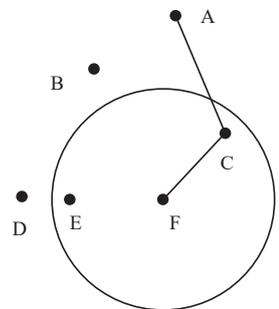


图 6 周界转发最优选择路径

2 系统模型与算法描述

图 7 是 GPSR-MBLR 的系统模型, 系统模型是基

于高速公路稀疏和密集场景设计的. 本文的高速公路为双向 6 车道, 即每个方向为 3 车道, 没有路口. 如图 7 所示, 在高速公路的隔离带中部部署有路侧单元 (RSU), 将路侧单元放在隔离带的中间, 沿运动方向均匀排布.

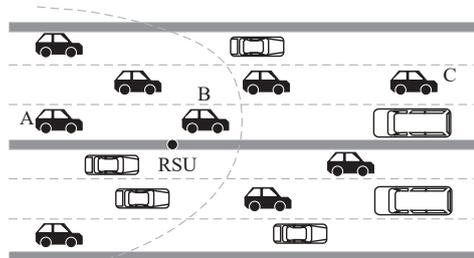


图 7 GPSR-MBLR 系统模型

在传输报文时, 本文假定定位设备均安装在车辆内, 同时, 车辆有获取车辆基本数据的权限, 如车辆可获取其自身和邻居的准确位置、速度值和运动方向等数据. 本文的移动模型是以某速率区间、某运动方向区间等随机产生的. 由于车辆与后方车辆的安全责任主要由后方车辆承担, 因此, 本研究未考虑后方车辆的影响.

2.1 改善的贪心转发邻居决策方案

为了解决邻居丢失问题, 设计了一种算法. 该算法首先依据系统模型研究节点的运动规律, 使用 DBN 预测出目标节点的轨迹, 以此确定距离源节点最远的目标节点 C 下一时刻的位置. 如果能够互相通信则转发到节点 B, 否则定义可信通信范围、移动性和车辆剩余在网时间 (vehicle lifetime metric, VLM) 这 3 个参数, 计算节点 B 与目标节点之间的距离. 根据此距离, 可以求出可信距离. 在可信距离内对所有节点的移动性和 VLM 进行比较, 并对邻居丢失的可能性进行预测, 从而找出稳定的下一跳, 如图 7 所示.

在图 7 中, A 需要向 C 传输报文. 在传输报文时, A 首先依据 DBN 预测车辆轨迹.

在预测高速公路场景的车辆轨迹之前, 由于错误变道引起的事故占很大比例, 并且本文系统模型中没有设置交叉口, 所以如果需要预测车辆轨迹, 则需要知道车辆变道的概率. 图 8 提供了一种高速公路变道场景, 其中, V_4 为需要预测变道意图的车辆, V_5 和 V_3 分别表示 V_4 的前车和后车, V_2 和 V_1 则表示变道后对应车道的前车和后车. 由于车速较快, 若在 V_4 变道前没有办法精确判断是否需要变道, V_3 可能误判导致紧急刹车减

速, 不仅会降低 V_3 驾驶员的驾驶舒适度, 甚至可能造成交通事故.

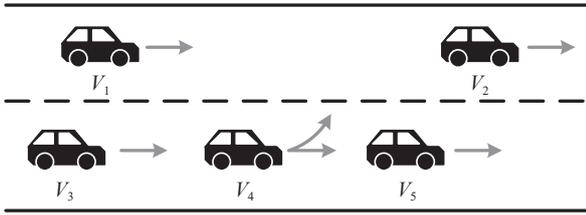


图8 高速公路变道场景

DBN 模型是一种概率图模型, 通过有向无环图来表示属性间的依赖关系, 如图9所示. 该模型由先验贝叶斯网络和时间戳之间的传递贝叶斯网络构成. 网络中的节点用箭头连接表示变量, 父节点与子节点之间

的箭头方向表示因果关系, 参数则代表条件概率分布.

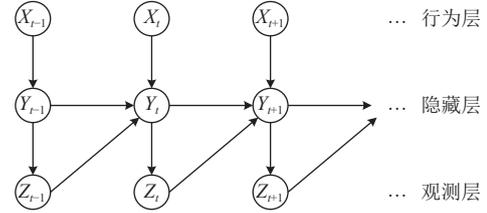


图9 3层动态贝叶斯网络的组成

动态贝叶斯网络因其在描述随机动态过程和推断未观测状态方面的强大能力, 已被广泛用于建模驾驶行为^[30]. 预测的第1步是将DBN模型应用于意图预测, 该模型包含观测层、隐藏层和行为层这3层. 本预测模型的网络结构如图10所示, 变量含义如表1所示.

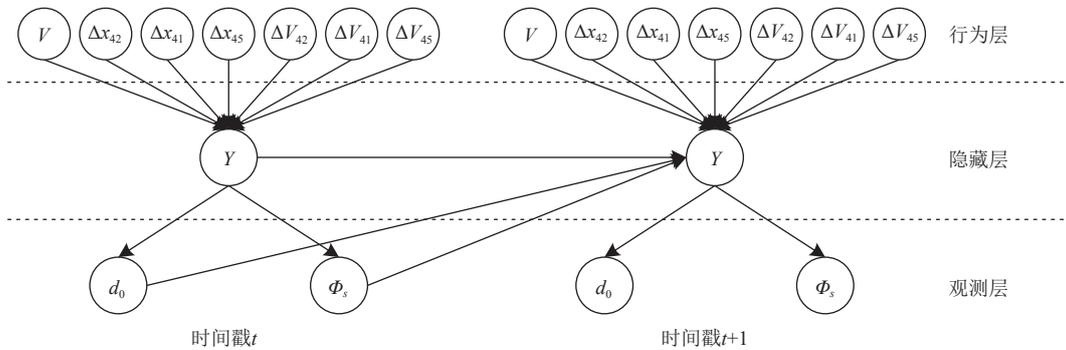


图10 动态贝叶斯网络结构

表1 DBN 预测所需要的符号

符号	说明
V	车辆速度
V_t	t 时刻车辆速度
S_{t+1}	$t+1$ 时刻车辆的横坐标
S_t	t 时刻车辆的横坐标
d_0	从目标车道线到车辆的横向偏移
ΔV_{42}	V_4 与 V_2 之间的纵向速度差
ΔV_{41}	V_4 与 V_1 之间的纵向速度差
ΔV_{45}	V_4 和 V_5 之间的纵向速度差
Δx_{42}	V_4 与 V_2 之间的纵向距离
Δx_{41}	V_4 与 V_1 之间的纵向距离
Δx_{45}	V_4 和 V_5 之间的纵向距离
Φ_s	道路切线方向的偏航率
Y	V_4 的意图

为了计算便捷和快速, 我们将全部连续的变量离散化.

在确定预测变量和网络结构后, 第2步就是估计子节点与父节点之间的条件概率分布. 由于所有变量都是离散变量, 因此将条件概率分布简化为条件概率

分布表. 用于学习参数的方法是最大似然估计法.

假设 $\eta = \{\eta_1, \eta_2, \dots, \eta_m\}$ 是含有 n 个实例的特殊序列, 最大似然估计方法的目的是根据式(1)寻找似然函数最大时对应的 θ :

$$L(\theta) = \sum_{k=1}^n \ln(p(\eta_k)) \quad (1)$$

然后采用期望最大化算法来获得最佳参数:

$$\theta^* = \arg \max_{\theta} L(\theta) \quad (2)$$

依据图9和贝叶斯理论, 可以通过式(3)计算时间戳 t 和时间戳 $t+1$ 之间的联合概率分布:

$$P(X_t, Y_t, Z_t, X_{t+1}, Y_{t+1}, Z_{t+1}) = P(X_t)P(Y_t|X_t) \times P(Z_t|Y_t)P(X_{t+1})P(Y_{t+1}|Y_t, X_{t+1}, Z_t)P(Z_{t+1}|Y_{t+1}) \quad (3)$$

DBN 计算的是某辆车动态意图的概率. 基于已建立的网络和先前学习的参数, 它采用两个连续时间戳中全部可观测的状态来计算, 最终计算出时间戳 $t+1$ 的意图概率, 选择后验概率值最大的意图作为预测结

果. 依据贝叶斯定理, 通过式 (4) 计算在 $X_t, Y_t, Z_t, X_{t+1}, Z_{t+1}$ 条件下 Y_{t+1} 的概率:

$$P(Y_{t+1} | X_t, Y_t, Z_t, X_{t+1}, Z_{t+1}) \propto \sum_{Y_t} P(X_t, Y_t, Z_t, X_{t+1}, Y_{t+1}, Z_{t+1}) \quad (4)$$

通过 DBN 预测车辆意图后, 若车辆无需变道, 由于车辆惯性, 即使下一时刻驾驶员计划改变车速, 时间戳 $t+1$ 的速度也近似等于时间戳 t 的速度, 根据式 (5) 计算出车辆在时间戳 $t+1$ 的位置:

$$S_{t+1} = S_t + V_t \quad (5)$$

若目标车辆需要变道, 该算法需要预测并计算出车辆从变道起始点开始的轨迹, 本文使用余弦函数拟合曲线. 在道路坐标系中, 基于车辆从当前车道中心线移动至目标车道中心线和车辆轨迹平滑且不振荡的运动假设, 可以初步设定轨迹函数的基础形式如式 (6) 所示:

$$y^{\text{horIR}}(\Delta x^{\text{longR}}) = A \cos(\omega \Delta x^{\text{longR}} + \varphi) + B \quad (6)$$

其中, A, B, ω, φ 为待定参数, $\omega > 0$, y^{horIR} 表示 t 时刻 V_4 的横向位置, Δx^{longR} 表示 V_4 从变道起始点到位置的相对纵向距离, 且 $\Delta x^{\text{longR}} \in [0, l_R]$. 假设变道起点为坐标原点 $(0, 0)$, 终点为 $(l_R, \omega l)$, 其中, ωl 表示车道宽度, l_R 表示整个变道操作的长度. 根据车辆轨迹平滑性的假设, 该函数的微分初始条件为 $y^{\text{horIR}'}(0) = y^{\text{horIR}'}(l_R) = 0$.

将式 (6) 进行微分并将微分初始条件代入, 如式 (7) 和式 (8) 所示.

$$y^{\text{horIR}'}(l_R) = -A\omega \sin(\omega \times l_R + \varphi) = 0 \quad (7)$$

$$y^{\text{horIR}'}(0) = -A\omega \sin(\varphi) = 0 \quad (8)$$

将式 (7) 和式 (8) 联立求解可得 $\varphi = k\pi$, $\omega \times l_R = n\pi$, 其中, k 和 n 均是正整数. 依据前文提到的 ω, l_R 的物理意义和取值范围, 可得 $\omega \times l_R > 0$, 即 $n > 0$. 又根据车辆轨迹不振荡假设, 可以得出车辆轨迹不会出现波动这一结论, 故 $n < 2$. 综上所述, 可得 $n = 1$, 代入求解结果可得 $\omega = \frac{\pi}{l_R}$. 将函数的两个初始条件和已求解的参数代入式 (6), 可以得到式 (9) 和式 (10):

$$y^{\text{horIR}}(0) = A \cos(k\pi) + B = 0 \quad (9)$$

$$y^{\text{horIR}}(l_R) = A \cos\left(\frac{\pi}{l_R} \times l_R + k\pi\right) + B = \omega l \quad (10)$$

若 k 为偶数, 联立式 (9) 和式 (10) 可解得 $A = -\frac{\omega l}{2}$,

$B = \frac{\omega l}{2}$, 符合 $(0, 0)$ 与 $(l_R, \omega l)$ 的初始假设; 若 k 为奇数, 联立式 (9) 和式 (10) 计算可得 $A = B = \frac{\omega l}{2}$, 并将所有参数与 $\Delta x^{\text{longR}} = 0$ 和 $\Delta x^{\text{longR}} = l_R$ 代入式 (6), 得到 $y^{\text{horIR}} = \omega l$ 和 $y^{\text{horIR}} = 0$, 这意味着 V_4 从旁边车道变回原车道, 与假设矛盾. 综上所述, $A = -\frac{\omega l}{2}$, $B = \frac{\omega l}{2}$, $\omega = \frac{\pi}{l_R}$, $\varphi = 2m\pi$ (m 为整数). 将 A, B, ω, φ 的值代入式 (6) 化简得到:

$$y^{\text{horIR}}(\Delta x^{\text{longR}}) = \frac{\omega l}{2} - \frac{\omega l}{2} \cos\left(\frac{\pi}{l_R} \Delta x^{\text{longR}}\right) \quad (11)$$

对式 (11) 进行微分简化后获取车辆的偏航率 Φ_k , 如式 (12) 所示:

$$\Phi_k = \arctan\left(\frac{\pi \omega l}{2 l_R} \sin\left(\frac{\pi}{l_R} \Delta x^{\text{longR}}\right)\right) \quad (12)$$

因此, 预测车辆轨迹时需要依据 y^{horIR} 和偏航率 Φ_k 进行调整. 通过求解式 (11) 和式 (12) 可以得到 Δx^{longR} 和 l_R . 随后, 我们就能获得完整的剩余轨迹.

如果通过 DBN 预测车辆轨迹之后发现 B 不在通信范围内, 则需要确定可信通信范围 Q . 如图 7 所示, C 和 B 的距离 d_{cb} 通过式 (13) 来计算, 通过式 (14) 计算 A 到 B 的距离 d_{ab} , 可信距离 d_{\max} 由式 (15) 决定:

$$d_{cb} = \sqrt{(x_c - x_b)^2 + (y_c - y_b)^2} \quad (13)$$

$$d_{ab} = \sqrt{(x_a - x_b)^2 + (y_a - y_b)^2} \quad (14)$$

$$d_{\max} = d_{cb} + \lambda d_{ab} \quad (15)$$

显然, λ 会影响 Q 的大小. 如果 λ 太大, Q 将变得更大, 那么 A 附近的节点更容易被选择为 Q 中的下一跳, 但该节点到 C 的跳数可能会增加. 当 λ 太小时, Q 将变小, 然后 C 附近的节点更容易被选择为 Q 中的下一跳, 从 B 到该节点的距离可能会变长, 链路稳定性可能会变差, 导致 PLR 增加.

通过计算机检验, 发现 $\lambda = 0.3$ 时性能最优. 以 C 为圆心, d_{\max} 为半径作一个圆, 这个圆称作圆 O . 图 7 中的可信通信范围是 A 的通信范围和圆 O 的重叠部分.

使用式 (16) 来计算可信通信范围内每辆车的丢失能力指数 $M(i)$:

$$M(i) = 0.8R(i) + 0.2VLM(i) \quad (16)$$

其中, $R(i)$ 为节点 i 相对 m 个邻居节点的移动性, 如式 (17) 所示. $VLM(i)$ 是前文提到的车辆剩余在网时间, 如式 (18) 所示. 式 (18) 中的 S_i 是节点 i 从目前位置到其

目的地之间的距离。

式 (17) 中的 $R(i, j)$ 为节点 i 和节点 j 的相对移动性的参数, 其计算如式 (19) 所示. 其中, $|V_i - V_j|$ 是节点 i 和节点 j 的相对速度值. 高速公路场景中通常会设置一个速度阈值, V_{\max} 为设置好的速度阈值, 如 120 km/h. 显然, $R(i) \leq 1$.

$$R(i) = \frac{1}{m} \sum_{j=1}^m R(i, j) \times \sum_{j=1}^m R(i, j) \quad (17)$$

$$VLM(i) = \frac{1}{S_i} \quad (18)$$

$$R(i, j) = \ln \left(\frac{V_{\max}}{V_{\max} - |V_i - V_j|} \right) \quad (19)$$

$R(i)$ 越小, 表示节点与其邻居的速度差异越低, 那么, 这个节点就不容易丢失. 当一个节点的 $VLM(i)$ 的值越小, 表示在相似的移动性下车辆节点可以行驶的时间更长, 节点越不容易丢失. 所以, 节点 i 的 $M(i)$ 越小, 就表示节点 i 与其邻居有着更类似的移动性, 节点 i 有着更长的 VLM , 就越不容易丢失. 所以依据式 (16) 选择 $M(i)$ 值最小的节点 i , 意味着尽可能地选择了距离最远且最不容易丢失的邻居节点.

综上所述, 改善后的贪心转发是根据 DBN 预测车辆下一时刻位置之后选取可信通信范围内最小 $M(i)$ 的节点为下一跳, 然后循环地使用这种方案传输报文, 最后把报文发送到目标节点.

2.2 改善周界转发

如图 11 所示, 贪心转发失败的节点 F 希望与目标节点 A 连接. C 和 E 是 F 的邻居, 而贪心失败节点在选取中继时, GPSR 依据周界转发的右手法则确定中继. 为了解决第 1 节提出的周界转发路径冗余问题, 本文提出一种改进的周界转发方案. 首先, 将源节点和目标节点连接并延长, 与 F 通信范围相交于两点, 此时将源节点通信范围平均分成左右两个部分, 如图 11 所示. 本文针对左上半圆使用 SFLA 选择下一跳, 而右下半圆采用 ACO 选择下一跳, 选择两条路径后选择最短的路径作为路由路径.

2.2.1 SFLA 优化周界转发

SFLA 是基于观测和模拟青蛙种群搜索食物量最大的地点时的动作所设计的一个元启发式算法, 综合了模因演算法和粒子群算法的优势. 本文采用 SFLA 来优化周界转发, 详细步骤如下.

1) 种群编码

假设左半圆的车辆节点有 m 个, d_{\max} 为节点的度, 式 (20) 为车辆节点的基因维数 LB .

$$LB = \lceil \ln(d_{\max}) \rceil \quad (20)$$

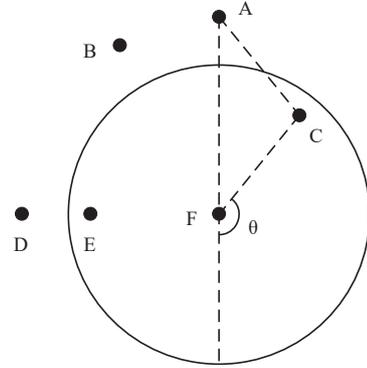


图 11 改善周界转发

SFLA 使用二进制编码来描述节点的基因位. 若节点度为 1, 意味着只有一个可选下一跳, 此时用 0 对该路由编码; 若有 4 个可选下一跳, 则用 00、01、10、11 来描述 4 个可选的路由路径. 如果节点度大于基因维数, 则使用取余数的方案对余下的基因编码. 为了区分正常的编码, SFLA 在余数编码中加一个特殊标记. 如果基因维数大于车辆节点编码数, 则忽视余下的基因位, 以此类推.

2) 评价函数

SLFA 的评价函数如式 (21) 所示:

$$LWF = 0.3D_{id} + 0.3 \left(\frac{1}{density_i} \right) + 0.4S_{id} \quad (21)$$

其中, D_{id} 是发送方和目的节点之间的距离, 如式 (22) 所示. 其中, (x_i, y_i) 表示邻居节点 i 的位置, (x_d, y_d) 表示目标节点位置. S_{id} 表示目标节点和下一跳候选节点之间的相对速度值, 如式 (23) 所示. $density_i$ 是下一跳候选 i 的邻居数, 用于确定每个路径 (稀疏、中等或密集) 中的连接模式, 从而减少稀疏连接问题.

$$D_{id} = \sqrt{(y_i - y_d)^2 + (x_i - x_d)^2} \quad (22)$$

$$S_{id} = |S_i - S_d| \quad (23)$$

3) 初始化种群

假设网络中有 m 个车辆, 根据 SFLA, 这 m 个车辆构成初始种群 $X = \{X_1, X_2, \dots, X_m\}$, $X_i = \{x_{i1}, x_{i2}, \dots, x_{im}\}$ 是在约束 D 维问题的解空间中的第 i 个节点. 初始种群确定以后, 依据式 (21) 来计算种群 m 个车辆的评价

函数值, 然后对评价函数按照降序的方式排序, 最后找到评价函数值最小的车辆, 记作 X_{gb} .

4) 子种群拆分

将 3) 排序以后的车辆节点分为 K 个子种群, 每个子种群内有 I 个节点. 子种群 1 获得排序以后的第 1, $K+1, \dots, (I-1) \times K+1$ 个节点, 子种群 2 获得排序以后的第 2, $K+2, \dots, (I-1) \times K+2$ 个节点, 以此类推. 显然, $m=I \times K$. 分组以后, 将每个子种群中评价函数值最低的节点记作 X_{fb} , 评价函数值最高的节点记作 X_{fw} .

5) 局部搜索

对 X_{fw} 进行进化更新策略, 更新策略如式 (24) 和式 (25) 所示:

$$R_i = \text{rand} \times (X_{fw} - X_{fb}) \quad (24)$$

$$X'_{fw} = R_i + X_{fw} \quad (25)$$

其中, R_i 为移动步长, 满足 $-R_{\max} \leq R_i \leq R_{\max}$ 约束, R_{\max} 为其移动最大步长. 然后根据当前路网状态下的参数计算得到 p , 若 $X'_{fw} < X_{fw}$, 则用调整后的 X'_{fw} 代替目前子种群最差节点 X_{fw} , 否则以概率 p 进行变异. 更新策略如式 (26)–(28) 所示:

$$R_i = \text{rand} \times (X_{fw} - X_{gb}) \quad (26)$$

$$R'_i = R_i + R_i \times p \quad (27)$$

$$X'_{fw} = R'_i + X_{fw} \quad (28)$$

正常情况下, SFLA 依据网络情况使用对应的变异算法, 获得对应的个体. 如果更新后的评价函数值和之前相比效果没有提升, 则按式 (29) 随机产生新的个体并替换原有个体.

$$X'_{fw} = R_i \times (\max - \min) + \min \quad (29)$$

其中, \max 是当前网络状态下随机最大值, \min 为随机最小值.

6) 全局搜索

局部搜索结束以后, 若没有达到最大迭代次数, 则将重新混合构成的下一代种群继续按照第 3)–5) 步更新个体, 若达到最大迭代次数则结束搜索并输出节点.

在确定节点以后, 通过左手法则确定左上半圆的路由路径, 记为 s_1 .

2.2.2 ACO 优化周界转发

求出左上半圆路由路径 s_1 后, 需要确定右下半圆

路由路径 s_2 . ACO 是一种自适应的仿生学算法, 可以解决路由选择等优化问题. 首先, ACO 随机地挑选前往目的节点的路径, 所有路径上都含有启示函数 τ_{ij} 和期望启示函数 η_{ij} , γ 和 ξ 分别为信息启示指数、期望启示指数. 然后依据走过路径上分泌的信息素浓度和状态转移概率查询路径, 最后逐步找到最佳路径. 当蚂蚁抵达目前路径时, 挑选下一个相邻路径的概率如式 (30) 所示:

$$P_{ij}^k = \begin{cases} \frac{[\tau_{ij}]^\gamma [\eta_{ij}]^\xi}{\sum_{s \in \text{unvisited}_k} [\tau_{is}]^\gamma [\eta_{is}]^\xi}, & j \in \text{unvisited}_k \\ 0, & \text{其他} \end{cases} \quad (30)$$

其中, i, j 分别代表每段路径的初始点和终止点, unvisited_k 代表没有访问过的节点集合.

结合 ACO 原理, 将式 (31) 设计为局部信息素, 式 (32) 为全局信息素, 以便与 ACO 结合分析.

$$P_{ij} = a \frac{t_{ij}}{N} + b \left(0.5 \times \frac{R}{R - |d_{ij}(t) - d_{ij}(t-1)|} + 0.5 \times T_{ij} \right) \quad (31)$$

$$Q_{ij} = \frac{\alpha \theta}{2\pi} + \beta \frac{t_{ij}}{N} + \chi \left(\frac{R}{2(R - |d_{ij}(t) - d_{ij}(t-1)|)} + \frac{T_{ij}}{2} \right) \quad (32)$$

其中, t_{ij} 是指 ij 路径下节点 n_i 的邻居节点数量, R 表示节点通信半径, $d_{ij}(t)$ 为 ij 路径下 t 时刻源车辆 j 到邻居 n_i 之间的距离. 显然, $d_{ij}(t)$ 值越低, 链路越稳健. 此外, ij 路径下链路存在时间 T_{ij} 也是影响链路稳定性的核心因素. θ_{ij} 为 ij 路径下的偏离角, 如图 11 所示. 偏离角越大, 离开路由空洞越容易, 可以高效降低路由冗余. 依据余弦定理, θ_{ij} 可由式 (33) 计算:

$$\theta_{ij} = \pi - \arccos \frac{d_{AF}^2 + d_{iJF}^2 - d_{Aij}^2}{2d_{AF}d_{iJF}} \quad (33)$$

将局部信息素和全局信息素代入式 (30) 可以得到改善后的蚁群状态转移概率, 如式 (34) 所示:

$$P_{ij}^k = \begin{cases} \frac{[P_{ij}]^\gamma [Q_{ij}]^\xi}{\sum_{s \in \text{unvisited}_k} [P_{is}]^\gamma [Q_{is}]^\xi}, & j \in \text{unvisited}_k \\ 0, & \text{其他} \end{cases} \quad (34)$$

如果前向蚂蚁抵达目标节点, 前向蚂蚁则会变成后向蚂蚁, 否则丢弃. 后向蚂蚁则携带由前向蚂蚁构建的路由表原路返回目标节点, 此时可以获得最新全局信息素, 依据式 (35) 将旧的全局信息素替换为最新的

全局信息素:

$$Q_{ij}(t+1) = (1-\delta) \times Q_{ij}(t) + \delta \sum_{k=1}^m \Delta Q_{ij}^k \quad (35)$$

式中, δ 是信息素释放系数, $(1-\delta) \times Q_{ij}(t)$ 为释放的全局信息素, $\delta \sum_{k=1}^m \Delta Q_{ij}^k$ 为增加的全局信息素, 且 $0 < \delta < 1$. 全局信息素的更新可以避免出现搜索停滞, 一旦全部的后向蚂蚁回到源节点, 便会选出最大的全局路由链路质量 $L(y)$, 并将此作为本次蚁群迭代的最优路径, 记录为 s_2 .

最后, 将第 2.2.1 节记录的 s_1 和 s_2 进行比较, 选取最短的路径作为最优路径.

2.3 GPSR-MBLR 工作流程

算法 1 给出了 GPSR-MBLR 协议的伪代码. 首先, 提供输入值: ① 最大迭代次数 N_m ; ② 车辆的速度 $V(i)$; ③ 车速最大值 V_m ; ④ 车辆的位置; ⑤ 下一跳候选节点 i 的邻居数 $density_i$. 然后对图 7 进行随机初始化. 最后, 如果满足贪心转发条件和周界转发条件, 则依据第 2.1 节和第 2.2 节所述进入循环过程并且构建拓扑, 否则不构建拓扑.

算法 1. GPSR-MBLR 算法

输入: N_m 、 $V(i)$ 、 V_m 、车辆的位置、 $density_i$.

输出: 建立拓扑结构.

```

1. if 当前状态为路由空洞 //第 1 部分, 周界转发
2. 将源节点和目标节点连接, 将源节点通信范围分为两个部分
3. if 节点为左上半圆
4.   for  $i=0$  to  $N_m$  do
5.     基因编码  $\rightarrow$  Topology_code
6.     根据式 (21) 计算  $LWF$ 
7.     拆分  $K$  个子种群
8.     在子种群中对车辆降序排序
9.      $temp = X_{fw}$ 
10.    for  $j=0$  to  $K$  do //局部搜索
11.      根据式 (24) 和式 (25) 更新  $X_{fw}$ 
12.      if  $X_{fw} < X'_{fw}$  then
13.         $X_{fw} = X'_{fw}$ 
14.      else
15.        根据式 (26)–(28) 更新  $X_{fw}$ 
16.      if  $X_{fw} = X'_{fw}$  then
17.         $X_{fw} = X'_{fw}$ 
18.      else
19.        根据式 (29) 获得新的  $X'_{fw}$ 
20.         $X_{fw} = X'_{fw}$ 
21.      end if
22.    end if
23.  end for

```

```

24.  end for
25.  mix( $K$ ) //将子种群混合起来, 得到新种群
26.  对新种群降序排序, 搜索  $LWF$  值最低的车辆  $X_{gb}$ 
27.  构建并记录路由  $s_1$ 
28.  else //求右下半圆最优路径
29.    for  $k=1$  to  $N_m$  do
30.      for  $m=1$  to  $M$  do (蚂蚁数量)
31.        if 前向蚂蚁到达目标车辆节点 then
32.          前向蚂蚁转为后向蚂蚁回退至源节点, 依据式 (35)
更新全局链路质量
33.        else
34.          根据式 (34) 选择下一条道路, 返回行 31
35.        if  $m=M$  then
36.          选择最优的路径并保存到路由表中
37.        end if
38.      end if
39.    if  $k=N_m$  then
40.      得到并记录路由  $s_2$ 
41.    end for
42.  end if
43.  路由路径  $s = \min(s_1, s_2)$ 
44.  else if 当前状态不是路由空洞且源节点存在邻居 //第 2 部分, 贪心转发阶段
45.    依据 DBN 判断车辆是否需要变道
46.    求解式 (11) 和式 (12), 得到  $\Delta x^{longR}$  和  $I_R$ , 获得完整的剩余轨迹
47.    if 存在路由
48.      发送信息
49.    else
50.      计算可信距离  $D = \text{norm}(D_{Node_i} - D_{Node_{i+1}})$ 
51.      确认可信通信范围
52.      计算可信通信范围内的车辆数  $D_m$ 
53.    for  $l=1$  to  $D_m$  do
54.       $M = \max(M(i))$ 
55.      if 下一节点 = 目标节点
56.        建立路径
57.      break
58.    end if
59.  end for
60. end if

```

3 仿真与实现

仿真实验中使用的性能指标如下.

1) 数据包丢失率 (packet loss rate, PLR): 表示总丢失数据包与源节点发送的数据包总数的比值.

2) 吞吐量: 定义为单位时间内通过整个网络成功传输数据的数目.

本文仿真下面两种情况.

(1) 最大节点速度为 90 km/h, 每公里平均车辆数量为 30、50、70、90、110.

(2) 每公里平均节点数量为 70 个, 最大节点速度为 70、80、90、100、110 km/h.

其他仿真参数如表 2 所示.

表 2 仿真参数

描述	设置	单位
仿真平台	Matlab 2021	—
仿真时间	400	s
仿真场景大小	20 km×24 m	—
车道方向和数量	双向6车道	—
节点传输范围	250	m
数据包大小	512	Byte
传播模型	双射线地面	—
MAC协议	IEEE 802.11p	—
数据包类型	CBR	—

通过对不同节点数目的 MM-GPSR^[12]、GPSR^[2]、AODV^[31]、PSO-GPSR^[13]和 GPSR-MBLR 这 5 个协议进行实验验证, 可以得到各协议在不同节点数和不同速度下的实验结果, 如图 12-图 15 所示.

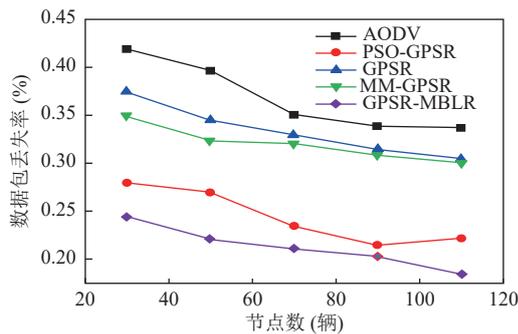


图 12 不同数目节点 PLR 对比

图 12 表明, 5 个协议的 PLR 均随着车辆数量的增加而减少. 当车辆数较小时, 车辆的间距较大, GPSR 和 GPSR-MBLR 均难以找到下一跳; 当车辆数增大时, 车辆的间距变短, PLR 减少. 图 12 还能够看出, GPSR-MBLR 的 PLR 是 5 个协议中最小的. 这是由于 GPSR-MBLR 根据移动性、VLM 和可信通信范围选取下一跳, 下一跳在通信范围内的概率更高. AODV 是一种基于拓扑的路由协议, 源车辆向每个节点均传输目标节点的数据请求, 这样会导致需要传输的数据包增加, 容易造成网络堵塞, 所以 AODV 的 PLR 是 5 个协议中最高的. 而 GPSR 不需要先发送数据请求, 所以 PLR 比 AODV 低一些, 但 GPSR 未考虑节点是否在通信区域边缘, 这导致所选的下一跳可能在通信范围之外, 使得报文不断重传和丢失. MM-GPSR 考虑了这一点, 选取

最大累计通信持续时间的节点作为下一跳, 所以 MM-GPSR 的 PLR 比 GPSR 更低. 但 MM-GPSR 仅考虑累计通信持续时间这一参数优化贪婪转发, 周界转发采用计算角度的方式选取下一跳节点, 这种方式虽然比 GPSR 更优秀, 但参数考虑较少, 所以其 PLR 比 PSO-GPSR 更差一些. 而 PSO-GPSR 在粒子群算法中加入分组接收率、路由负载、平均端到端时延来优化 GPSR, 参数考虑较为全面, 故 PSO-GPSR 比 MM-GPSR、GPSR 和 AODV 的 PLR 更低. 但 PSO 在面对节点数量较多的情况时, 粒子群算法可能需要大量计算时间才能找到最优解, 而 GPSR-MBLR 使用 SFLA 和 ACO 两种优化算法, 这种组合保证了搜索的广度和深度, 所以 PSO-GPSR 的 PLR 比 GPSR-MBLR 更高.

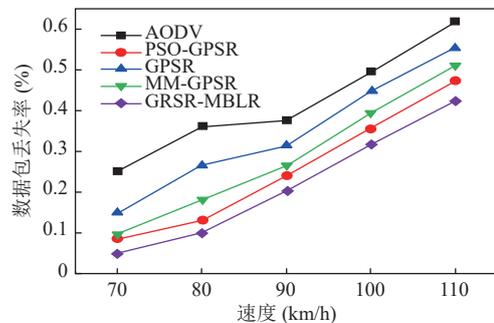


图 13 不同最大节点速度 PLR 对比

图 13 比较了车辆数量平均为 70 个、不同车辆速度下 MM-GPSR、GPSR、AODV、PSO-GPSR 和 GPSR-MBLR 的 PLR 效果. GPSR 和 GPSR-MBLR 的 PLR 随着节点速度的增加而增加. 这是由于节点速度越大, 邻居越容易出通信范围, 更容易丢包. 从图 13 中还能看出一点, GPSR 的 PLR 小于 AODV, 这是因为 AODV 向区域内的所有车辆广播路由请求包, 这样会有大量的路由请求包在网络中需要传输, 同时发送路由请求包和报文网络过载会随着网络规模的放大而增加, 所以 AODV 的 PLR 是 5 个协议中最差的. GPSR 未考虑路径冗余问题, 而 MM-GPSR 的角度计算比 GPSR 的右手法则更精确, 所以 MM-GPSR 的 PLR 比 GPSR 更低. 但和 PSO-GPSR 相比, PSO 考虑的 3 个动态参数比 MM-GPSR 更清楚, 所以 MM-GPSR 的 PLR 比 PSO-GPSR 更高. 而 PSO-GPSR 依据粒子的速度和位置更新策略来查询解, 导致它在应对这些复杂问题时表现出较强的鲁棒性, 而 MM-GPSR、GPSR 和 AODV 的鲁棒性较差, 所以 PSO-GPSR 的 PLR 较低.

但 PSO 有许多参数需要设置,如粒子数量、加速度上限等.这些参数的选择对结果有很大的影响,需要经验和实验来确定,而 GPSR-MBLR 使用 SFLA 和 ACO 两种优化算法,这种组合保证搜索的广度和深度,所以 PSO-GPSR 的 PLR 比 GPSR-MBLR 更高.这是因为 GPSR-MBLR 能够选择更合理的通信连接,还用了两个仿生智能算法优化周界转发,所以 GPSR-MBLR 的丢包数量是 5 个协议中最少的.

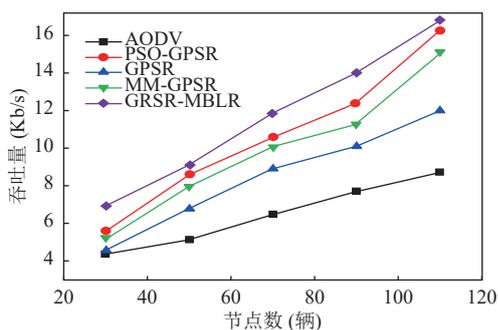


图 14 不同节点数目吞吐量对比

图 14 描述了 5 个协议不同车辆数目的吞吐量.随着节点数增多,网络负载能力逐渐增加,故 5 个协议的吞吐量逐渐增大.图 14 中还能看出,随着网络中节点数量的增长,网络拓扑结构趋于复杂. AODV 协议在进行路由发现时,需要遍历的潜在路径数量急剧上升,导致其确定完整路由的时间显著延长.这种性质会导致 AODV 单位时间内通过的数据包数量少,所以 AODV 的吞吐量是 5 个协议中最差的. GPSR 的贪心转发选择距离最远的节点作为下一跳节点,这意味着下一跳经过的距离尽可能的远,遍历潜在路径较少,所以 GPSR 的吞吐量比 AODV 更高.但 GPSR 贪心转发机制依赖于节点位置的瞬时信息进行决策.然而,在高速移动的网络中,节点的拓扑关系瞬息万变.当源节点基于当前信息选定了最远邻居后,该节点可能在数据包实际发出前已移出通信范围,导致基于过时信息做出的转发决策在实际执行时失效,造成 PLR 增加.而 MM-GPSR 在贪心转发中考虑了这一点,所以 MM-GPSR 的吞吐量比 GPSR 高.然而 MM-GPSR 在周界转发中仅仅考虑角度这一因素,而 PSO-GPSR 考虑了 3 个因素,所以 PSO-GPSR 的吞吐量比 MM-GPSR 更大.但 PSO 在存在多个极值的复杂问题中,粒子群可能在其搜索的初期阶段就快速收敛到某个局部最优解的邻域内.随后,整个种群的搜索范围会急剧收缩,陷入一种停滞

状态,无法挣脱该局部区域的束缚去发现全局范围内更优的解, GPSR-MBLR 的贪心转发依据 DBN 丢失能力指数选择更合理的链路,周界转发将通信区域分为两个半圆来选择下一跳节点,选择的路径更加准确,所以 GPSR-MBLR 的吞吐量比 PSO-GPSR 更高.

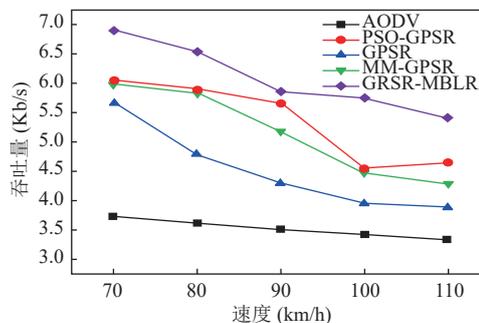


图 15 不同节点最大速度吞吐量对比

图 15 显示了每公里平均车辆数为 70 个的情况下不同协议的最大车辆速度的吞吐量.随着车辆速度的增加,通信链接易断开,网络负载越来越小,所以 5 个协议的吞吐量越来越小.图 15 表明,在高动态网络中,节点快速移动导致拓扑持续变化,这使得 AODV 建立的路由路径极易失效.一旦链路中断, AODV 必须多次重新发起路由发现过程以寻找新路径,这一修复机制会引入显著的通信延迟,所以 AODV 的吞吐量是 5 个协议中最差的. GPSR 重新发起路由发现过程的次数比 AODV 少,所以 GPSR 的吞吐量比 AODV 更大一些.但 GPSR 容易选择到通信边缘的节点,这些节点本身就处于连接稳定性的临界状态.任何微小的移动或延迟都极易使这些边缘节点失联,在实际动态环境中反而成为最不可靠的环节.而 MM-GPSR 确定允许通信区域以后使用累计通信持续时间这一参数优化贪婪转发,解决了 GPSR 的不可靠环节,所以吞吐量比 GPSR 更高.但 MM-GPSR 仅考虑累计通信持续时间和角度来优化贪心转发和周界转发, PSO 整个种群可以被划分为多个子群,在不同的计算节点上独立演化,仅需周期性地交换全局最优解信息.这样不仅减少了通信开销,更使得算法能够利用分布式系统资源来解决单个机器难以承载的超大规模问题,所以 PSO-GPSR 的吞吐量比 MM-GPSR 更高. PSO-GPSR 的优化过程存在显著的路径依赖特性.早期发现的较优解会引导后续整个种群的搜索方向.在本文的模型中,一旦这个初始路径指向了一个局部最优, PSO 越难以发现其他

可能更优的路径。而 GPSR-MBLR 使用 DBN 进行概率图建模,可以预测车辆轨迹和意图,最终预测车辆下一时刻位置,还确定可信通信范围,在可信通信范围内依据丢失能力指数确定下一跳,这样就可以从根本上预判链路的稳定性,所以 GPSR-MBLR 的吞吐量是 5 个协议中最大的。

4 结束语

IoV 具有快速拓扑变化、高速节点、有限传输范围和有限无线信道的不可预测行为,这使得 IoV 中路由协议的设计极具挑战性。本文描述了如何利用可信通信范围、移动性和 VLM 来改进贪心转发中下一跳的选择,还使用 SFLA 和 ACO 来改进 GPSR 的周界模式。我们提出的算法可以避免报文循环发送和路径冗余。本文在 Matlab 的高速公路场景中成功仿真了所提出算法。实验表明, GPSR-MBLR 比 GPSR、AODV、PSO-GPSR 和 MM-GPSR 具有更好的性能,并验证了 GPSR-MBLR 的优越性。

未来,我们将考虑如何对 GPSR-MBLR 进行改进,并应用到高速公路堵车场景或者城市场景中。

参考文献

- 1 毕翔,黄晃,张本宏,等.基于分簇与改进 Q 学习的车联网 V2V 复合路由算法.计算机工程,2023,49(3): 221–230, 247. [doi: 10.19678/j.issn.1000-3428.0063808]
- 2 Karp B, Kung HT. GPSR: Greedy perimeter stateless routing for wireless networks. Proceedings of the 6th Annual International Conference on Mobile Computing and Networking. Boston: ACM, 2000. 243–254. [doi: 10.1145/345910.345953]
- 3 Bengag A, Bengag A, Elboukhari M. A novel greedy forwarding mechanism based on density, speed and direction parameters for Vanets. International Journal of Interactive Mobile Technologies (IJIM), 2020, 14(8): 196–204. [doi: 10.3991/ijim.v14i08.12695]
- 4 Chen C, Liu L, Qiu T, *et al.* Routing with traffic awareness and link preference in internet of vehicles. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(1): 200–214. [doi: 10.1109/TITS.2020.3009455]
- 5 Singh P, Raw RS, Khan SA, *et al.* W-GeoR: Weighted geographical routing for VANET's health monitoring applications in urban traffic networks. IEEE Access, 2022, 10: 38850–38869. [doi: 10.1109/ACCESS.2021.3092426]
- 6 袁学松.路侧装置修正位置预测模型在 Vanet 混合路由算法中的应用.重庆大学学报,2018,41(8): 100–110. [doi: 10.11835/j.issn.1000-582X.2018.08.011]
- 7 朱正国.一种基于路侧装置修正的遗传 VANET 算法.重庆科技学院学报(自然科学版),2022,24(6): 49–54. [doi: 10.19406/j.cnki.cqkxyxbzkb.2022.06.001]
- 8 Shu WN, Nie SL, Hu FJ. AK-GPSR: An adaptive K-medoids-based greedy perimeter stateless routing algorithm for multi-channel vehicular network communication. IEEE Transactions on Intelligent Transportation Systems, 2024, 11(25): 19100–19109. [doi: 10.1109/TITS.2024.3420223]
- 9 何奕达.基于机器学习和模糊逻辑的城市场景 VANET 路由算法[硕士学位论文].大连:大连海事大学,2021. [doi: 10.26989/d.cnki.gdlhu.2021.001505]
- 10 Chen JY, Rajib P, Choi YJ. An efficient neural network-based next-hop selection strategy for multi-hop VANETs. Proceedings of the 2021 International Conference on Information Networking. Jeju Island: IEEE, 2021. 699–702. [doi: 10.1109/ICOIN50884.2021.9333974]
- 11 Schreier M, Willert V, Adamy J. An integrated approach to maneuver-based trajectory prediction and criticality assessment in arbitrary road environments. IEEE Transactions on Intelligent Transportation Systems, 2016, 17(10): 2751–2766. [doi: 10.1109/TITS.2016.2522507]
- 12 Yang XP, Li MJ, Qian ZH, *et al.* Improvement of GPSR protocol in vehicular ad hoc network. IEEE Access, 2018, 6: 39515–39524. [doi: 10.1109/ACCESS.2018.2853112]
- 13 李养君.基于地理位置信息的城市 VANET 路由方法研究[硕士学位论文].哈尔滨:哈尔滨理工大学,2023. [doi: 10.27063/d.cnki.gdlgu.2023.000441]
- 14 周德宇,袁学松.最大累积通信持续时间和遗传算法的 GPSR 协议.数据通信,2023(5): 5–11. [doi: 10.3969/j.issn.1002-5057.2023.05.002]
- 15 段浩浩,李晓玲,路庆昌,等.混合蛙跳算法求解车辆无人机协同配送问题.浙江大学学报(工学版),2024,58(11): 2258–2269. [doi: 10.3785/j.issn.1008-973X.2024.11.007]
- 16 Zhao X, Li HT, Zhang T, *et al.* An efficient multi-objective shuffled frog leaping algorithm-based method for metabolic pathway design. Proceedings of the 2025 IEEE Congress on Evolutionary Computation. Hangzhou: IEEE, 2025. 1–4. [doi: 10.1109/CEC65147.2025.11043073]
- 17 Li H, Li M. Evaluation of college English teaching quality based on back propagation neural network. Proceedings of the 2025 International Conference on Intelligent Systems and Computational Networks. Bidar: IEEE, 2025. 1–6. [doi: 10.1109/ICISCN64258.2025.10934184]

- 18 Zhou M, Hu X, Wei HW, *et al.* An analytical study of learner collaborative learning algorithms for online education based on OSPBO-SFLA algorithm. Proceedings of the 5th IEEE International Conference on Electronic Technology, Communication and Information. Changchun: IEEE, 2025. 374–378. [doi: [10.1109/ICETCI64844.2025.11084116](https://doi.org/10.1109/ICETCI64844.2025.11084116)]
- 19 Suneetha P, Kumar K, Devi VL, *et al.* A novel modified shuffled frog leaping algorithm (MSFLA) MPPT controller for photovoltaic systems. Proceedings of the 3rd International Conference on Trends in Electrical, Electronics, and Computer Engineering. Bangalore: IEEE, 2024. 96–100. [doi: [10.1109/TEECCON64024.2024.10939095](https://doi.org/10.1109/TEECCON64024.2024.10939095)]
- 20 Mohan S, Nayanatara C, Shweta K, *et al.* Distribution system planning through integrated distributed generation using the shuffled frog leaping algorithm. Proceedings of the 2024 International Conference on Power, Energy, Control and Transmission Systems. Chennai: IEEE, 2024. 1–5. [doi: [10.1109/icpects62210.2024.10779996](https://doi.org/10.1109/icpects62210.2024.10779996)]
- 21 Badole MH, Thakare AD. To enhance VANET communication services using a metaheuristic algorithm. Proceedings of the 2024 IEEE International Conference on Information Technology, Electronics and Intelligent Communication Systems. Bangalore: IEEE, 2024. 1–5. [doi: [10.1109/ICITEICS61368.2024.10625345](https://doi.org/10.1109/ICITEICS61368.2024.10625345)]
- 22 Helshani R. Multiobjective optimization of VANET networks for intelligent parking with hybrid PSO-NSGA II algorithm. Proceedings of the 2024 International Conference on Computing, Networking, Telecommunications & Engineering Sciences Applications. Tirana: IEEE, 2024. 80–86. [doi: [10.1109/contesa64738.2024.10891279](https://doi.org/10.1109/contesa64738.2024.10891279)]
- 23 Kaleibar FJ, St-Hilaire M, Barati M. A customized genetic algorithm for SLA-aware service provisioning in infrastructure-less vehicular cloud networks. IEEE Transactions on Services Computing, 2025, 18(2): 499–512. [doi: [10.1109/tsc.2025.3528317](https://doi.org/10.1109/tsc.2025.3528317)]
- 24 Liang JW, Ma MD. FS-MOEA: A novel feature selection algorithm for IDSs in vehicular networks. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(1): 368–382. [doi: [10.1109/TITS.2020.3011452](https://doi.org/10.1109/TITS.2020.3011452)]
- 25 杜欣欣, 胡晓辉, 赵佳楠. 一种软件定义车载自组织网络的 QoS 路由算法. 计算机工程, 2022, 48(11): 184–191, 200. [doi: [10.19678/j.issn.1000-3428.0063131](https://doi.org/10.19678/j.issn.1000-3428.0063131)]
- 26 Deshmukh AR, Nirmal P, Dorle SS. A new approach for position based routing protocols based on ant colony optimization (ACO) technique in vehicular ad hoc network (VANET). Proceedings of the 2021 International Conference on Intelligent Technologies. Hubli: IEEE, 2021. 1–5. [doi: [10.1109/CONIT51480.2021.9498332](https://doi.org/10.1109/CONIT51480.2021.9498332)]
- 27 Jiang Y, Xu GC, Dong HL, *et al.* Improved GPSR protocol and performance evaluation. Proceedings of the 2020 IEEE Eurasia Conference on IOT, Communication and Engineering. Yunlin: IEEE, 2020. 234–238. [doi: [10.1109/ECICE50847.2020.9301937](https://doi.org/10.1109/ECICE50847.2020.9301937)]
- 28 Li GY, Boukhatem L, Wu JS. Adaptive quality-of-service-based routing for vehicular ad hoc networks with ant colony optimization. IEEE Transactions on Vehicular Technology, 2017, 66(4): 3249–3264. [doi: [10.1109/TVT.2016.2586382](https://doi.org/10.1109/TVT.2016.2586382)]
- 29 Li GY, Boukhatem L. A delay-sensitive vehicular routing protocol using ant colony optimization. Proceedings of the 12th Annual Mediterranean Ad Hoc Networking Workshop. Ajaccio: IEEE, 2013. 49–54. [doi: [10.1109/MedHocNet.2013.6767409](https://doi.org/10.1109/MedHocNet.2013.6767409)]
- 30 Kumagai T, Akamatsu M. Prediction of human driving behavior using dynamic Bayesian networks. IEICE-Transactions on Information and Systems, 2006, E89-D(2): 857–860. [doi: [10.1093/ietisy/e89-d.2.857](https://doi.org/10.1093/ietisy/e89-d.2.857)]
- 31 王超. 车联网城市交通移动多场景建模仿真及分析. 计算机系统应用, 2019, 28(11): 29–36. [doi: [10.15888/j.cnki.csa.007103](https://doi.org/10.15888/j.cnki.csa.007103)]

(校对责编: 李慧鑫)