

基于多时间段优化贝叶斯网络的车载容迟网络路由算法

吴家皋^{1,2}, 郭亚航^{1,2}, 蔡沈磊^{1,2}, 刘林峰^{1,2}

(1. 南京邮电大学计算机学院, 江苏 南京 210023; 2. 江苏省大数据安全与智能处理重点实验室, 江苏 南京 210023)

摘要: 针对车载容迟网络 (VDTN) 中车辆节点高速移动造成的通信链路不稳定性问题, 利用车辆节点移动的规律性和时段性特点, 提出了基于多时间段优化贝叶斯网络 (BN) 的 VDTN 路由算法。首先, 提出了新的多时间段 BN 模型及其节点分类动态奖励机制, 以更准确地描述车辆的移动模式。接着, 提出了 2 种新的 BN 的时间段优化划分算法: 二分搜索 K2GA (BS-K2GA) 算法和模拟退火 K2GA (SA-K2GA) 算法, 其中, BS-K2GA 算法具有简单高效的优势, 而 SA-K2GA 算法则能有效避免陷入局部最优解, 进一步优化算法性能。仿真实验表明, 所提出的基于多时间段优化 BN 的 VDTN 路由算法能显著提高消息的投递率, 降低消息的投递时延, 从而验证了研究方案的有效性。

关键词: 车载容迟网络; 贝叶斯网络; 路由算法; 二分搜索; 模拟退火

中图分类号: TP393

文献标识码: A

DOI: 10.11959/j.issn.1000-436x.2021222

Vehicular delay tolerant network routing algorithm based on optimized multi-period Bayesian network

WU Jiagao^{1,2}, GUO Yahang^{1,2}, CAI Shenlei^{1,2}, LIU Linfeng^{1,2}

1. School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

2. Jiangsu Key Laboratory of Big Data Security & Intelligent Processing, Nanjing 210023, China

Abstract: Aiming at the instability of communication link caused by the high-speed movement of vehicle nodes in vehicular delay tolerant network (VDTN), considering the characteristics of regularity and periodicity of vehicle nodes movement, a VDTN routing algorithm based on optimized multi-period Bayesian network (BN) was proposed. Firstly, a new multi-period BN model and its dynamic reward mechanism for node classification were proposed to describe the movement pattern of vehicle nodes with higher accuracy. Then, two novel time-optimal-partition algorithms of multi-period BN were proposed including binary search K2GA (BS-K2GA) algorithm and simulated annealing K2GA (SA-K2GA) algorithm, where BS-K2GA algorithm had the advantages of simplicity and efficiency, while SA-K2GA could effectively avoid falling into the local optimal solution and further optimize the performance. The simulation results show that the proposed VDTN routing algorithm based on optimized multi-period BN model can significantly improve the message delivery ratio and reduce the delivery delay. Thus, the effectiveness of the approach is validated.

Keywords: vehicle delay tolerant network, Bayesian network, routing algorithm, binary search, simulated annealing

1 引言

传统网络需要依靠端到端的链路以及传输控制协议/网际协议 (TCP/IP, transmission control protocol/Internet protocol) 等来保证数据传输的低时

延与可靠性, 然而当地震、海啸等突发灾难导致端到端链路故障时, 传统的基于“存储-转发”的路由模式将不再有效。因此, Jain 等^[1]提出了延迟容忍网络 (DTN, delay tolerant network) 概念, 并已广泛应用于星际网络^[2]、水下传感网络^[3]、移动自

收稿日期: 2021-09-01; 修回日期: 2021-11-19

基金项目: 国家自然科学基金资助项目 (No.61872191, No.41571389)

Foundation Item: The National Natural Science Foundation of China (No.61872191, No.41571389)

组织网络^[4]、无线传感网络^[5]、车载网络^[6]等领域。其中,车载容迟网络(VDTN, vehicular delay tolerant network)将车载网络与容迟网络相结合,能为未来的自动驾驶和智能交通系统提供新的解决方案。DTN采用新的基于“存储-携带-转发”的路由模式^[7],消息需要通过节点的移动和相遇进行转发。但是,由于车辆的高速运动,可用于消息转发的车辆间的相遇接触时间非常有限。因此,对VDTN路由算法的性能提出了更高的要求。

DTN路由算法已有大量研究工作^[8],其中,较著名的有Epidemic^[9]、Spray and Wait^[10]和Prophet^[11]等。Epidemic是基于泛洪策略的路由算法,通常具有最小的消息传输时延,但泛洪往往会导致网络拥塞。Spray and Wait路由算法则通过限制消息副本的数目来解决消息泛洪问题。Prophet路由算法则利用节点相遇的历史信息估计不同节点与消息目的节点之间的相遇概率,以此决定消息转发策略。然而,在VDTN中,车辆的移动通常具有特定的模式,例如公交车遵循固定的路线和时刻表,私家车的移动倾向于有规律的轨迹,出租车的移动行为则体现了人流的热区等。Prophet路由算法并没有很好地考虑车辆的这些移动模式。近年来,随着机器学习和人工智能技术的兴起,许多机器学习算法被应用到DTN路由算法中,例如决策树^[12]、强化学习^[13]、神经网络^[14]和朴素贝叶斯分类器^[15-16]等。然而,决策树和神经网络容易出现过拟合问题,强化学习收敛速度较慢且容易导致额外的网络路由开销,朴素贝叶斯分类器则无法表达出属性间的依赖关系。贝叶斯网络(BN, Bayesian network)利用概率图模型表示属性间的依赖关系,能显著提高VDTN中节点移动模式预测的准确性^[17]。BN结构学习是BN模型的核心问题之一,已提出的算法包括基于依赖关系的互信息算法^[18]、基于评分搜索策略的K2算法^[19]以及基于遗传算法的K2(K2GA, K2 based on genetic algorithm)算法^[20]等。然而,VDTN中车辆节点的移动由于受到人类行为和生活习惯的影响有着明显的时段性、周期性的特点。因此,单一的BN结构无法准确地表达车辆移动模式的时段性特点。虽然文献[21]也研究了基于多时间段BN的VDTN路由算法,但其采用人工经验的时间段划分方案并非是最优划分。针对上述问题,本文开展了基于多时间段BN的VDTN路由算法研究。本文主要的研究工作如下。

1) 提出了新的多时间段BN模型。引入了更多与节点移动模式相关的属性,包括剩余缓存比、平均时延、行驶距离等属性,以更准确地描述车辆的移动模式;同时,提出了新的节点分类动态奖励机制,使相遇和投递奖励的分配更合理,保证奖励值与节点实际的类别相一致。

2) 提出了2种新的BN时间段的优化划分算法:二分搜索K2GA(BS-K2GA, binary search K2GA)算法和模拟退火K2GA(SA-K2GA, simulated annealing K2GA)算法。BS-K2GA算法以二分贪心策略优化BN的时间段划分和网络结构,具有简单高效优势;SA-K2GA算法则将模拟退火算法和K2GA算法相结合,能克服贪心算法容易陷入局部最优的缺点,进一步优化解的性能。

3) 提出了基于多时间段优化BN的VDTN路由算法,仿真实验结果表明,通过优化后的多时间段BN模型能够准确地描述车辆的移动模式,显著提高消息的投递率,并降低消息的投递时延。

2 系统模型

BN由有向无环图(DAG, directed acyclic graph)和条件概率表(CPT, conditional probability table)组成。令 $G=(V, E)$ 为任意BN,其中, V 是DAG的节点集,表示随机变量; E 是节点间的有向边,表示随机变量之间的直接依赖关系。CPT表示随机变量的联合概率分布,可以定量地描述变量之间的依赖关系。

设在VDTN中,源节点 n_s 产生了一个目的节点为 n_d 的消息,该消息可以经过一系列的中继节点最终被转发到达 n_d ,问题的关键在于如何找到一条较优的传输路径。因此,本文提出了一种优化的BN分类器模型用于估计VDTN传输路径中车辆中继节点的消息投递能力。

在VDTN中,车辆节点的移动模式受人们生活习惯影响具有时段性的特点。基于真实数据集的实验表明节点的活跃度呈现出规律性的分布^[22]。在早晚高峰期,节点活跃度持续上升;在其他时间段,活跃度明显下降。由此可见,单一结构的BN模型显然无法描述所有时间段车辆的移动规律。因此,本文针对一天内的不同时间段构建不同的BN模型,以更好地表达车辆的真实移动模式。如图1所示,将一整天划分为 σ 个时间段,根据各个时间段的数据集来学习构造多个BN,这样的多

时间段 BN 模型能更加准确地描述车辆节点的移动行为。接下来，如何确定最优的时间段划分方案和各时间段对应的 BN 结构则是本文要解决的首要问题。

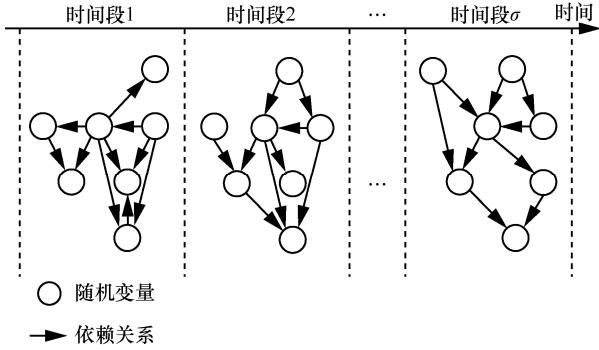


图 1 多时间段贝叶斯网络示意

图 2 是本文的基于多时间段优化 BN 的 VDTN 路由算法框架，主要包含 4 个部分：属性选择、分类标准、结构学习、推理与消息转发策略。下面，先详细介绍 VDTN 的节点属性选择和分类标准，有关 BN 结构优化学习、推理与消息转发策略的内容将在第 3 节中论述。

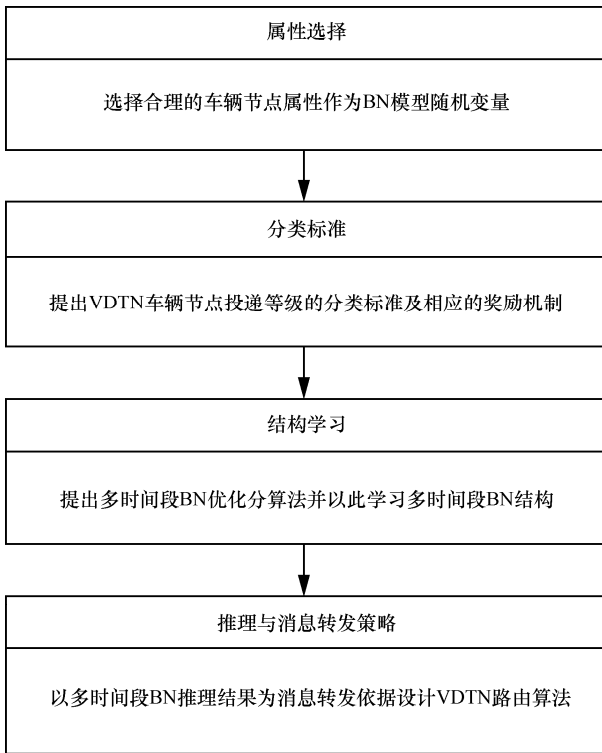


图 2 基于多时间段优化 BN 的 VDTN 路由算法框架

2.1 属性选择

用于构建 BN 的随机变量是与消息转发密切相

关的车辆节点的属性。本文用向量 $X = \langle X_1, X_2, X_3, X_4, X_5, X_6, X_7, X_8, X_9, X_{10} \rangle$ 对其进行描述。

X_1 为区域码， $X_1 \in \{R_1, R_2, \dots, R_{k_1}\}$ ，表示 VDTN 中的节点在转发消息时所处的区域。整张地图被划分为 k_1 个矩形区域，每个区域有相同的长宽和唯一的标识符。在本文中，整个区域的大小为 $35 \text{ km} \times 25 \text{ km}$ ，被划分为 35 个小矩形区域，每个矩形的尺寸为 $5 \text{ km} \times 5 \text{ km}$ 。

X_2 为时隙， $X_2 \in \{T_1, T_2, \dots, T_{k_2}\}$ ，表示 VDTN 中的节点在转发消息时所处的时隙。选取这个属性是因为车辆在一天中不同的时间段有不同的移动模式，根据车辆轨迹历史数据集，车辆的移动主要集中在上午 7 点到下午 7 点。本文将粒度设置为 15 min 来离散化时间，因此共划分为 $k_2 = 48$ 个时隙。

X_3 为运动方向， $X_3 \in \{M_1, M_2, \dots, M_{k_3}\}$ ，表示 VDTN 中的节点在转发消息时的运动方向。本文将方向角粒度设置为 $\pi/4$ ，车辆的运动角度可以离散化为 $k_3 = 8$ 个方向，即东、西、南、北、东南、东北、西南、西北。

X_4 为平均接触时间间隔， $X_4 \in \{I_1, I_2, \dots, I_{k_4}\}$ ，表示 VDTN 中的节点遇见其他节点需要的平均时间。该值越小，说明车辆遇见其他车辆的概率越大，消息的投递能力也越好。根据车辆轨迹历史数据集，如公交车之间的平均相遇时间统计分布，本文设置平均接触时间间隔的最大值为 $3\ 000 \text{ s}$ ，离散化粒度为 300 s ，因此平均接触时间间隔被划分为 $k_4 = 10$ 个时间间隔。

X_5 为速度， $X_5 \in \{V_1, V_2, \dots, V_{k_5}\}$ ，表示 VDTN 中节点的移动速度。根据车辆轨迹历史数据集，VDTN 中车辆的最大速度为 120 km/h ，离散化粒度为 24 km/h ，因此速度被划分为 $k_5 = 5$ 个级别。

X_6 为路线编号， $X_6 \in \{P_1, P_2, \dots, P_{k_6}\}$ ，表示 VDTN 中节点在转发消息时的路线编号。VDTN 中的车辆移动具有一定的模式，而且通常会在固定的路线上行驶，例如公交线路。不同的车辆也可能在同一条道路上行驶，因此这些车辆具有相同的路线编号。本文主要以公交车编号作为线路编号，这个属性可以较好地反映车辆的移动行为。

X_7 为剩余缓存比， $X_7 \in \{Q_1, Q_2, \dots, Q_{k_7}\}$ ，表示 VDTN 中节点剩余可用缓存大小占总缓存的比率。VDTN 节点携带的消息都需要存储在缓存中进行转发。本文将剩余可用缓存占比的离散化粒度设置为

0.1, 将其划分为 $k_6=10$ 个比率。

X_8 为平均时延, $X_8 \in \{A_1, A_2, \dots, A_{k_8}\}$, 表示消息从该节点转发到消息的目的节点所经过的平均时间。平均时延越小, 说明该节点转发消息的效率越高。根据车辆轨迹历史数据集, VDTN 中消息的最大平均时延为 7 000 s, 离散化粒度为 1 000 s, 因此平均时延被划分为 $k_8=7$ 个值。

X_9 为行驶距离, $X_9 \in \{N_1, N_2, \dots, N_{k_9}\}$, 表示 VDTN 中车辆在转发消息时距离上次车辆相遇所行驶的距离。根据车辆轨迹历史数据集, VDTN 中车辆的最大行驶距离为 35 km, 离散化粒度为 5 km, 因此行驶距离可以离散化为 $k_9=7$ 个值。

X_{10} 为投递等级, $X_{10} \in \{L_1, L_2, \dots, L_{k_{10}}\}$, 表示节点转发消息到消息目的节点的能力。投递等级越高, 表示该节点拥有越大的可能性将消息成功转发到目的节点。

在上述的属性变量中, $X_1 \sim X_9$ 均易观测获得, 可当作证据变量; X_{10} 则不能直接得到, 故作为查询变量。为了训练 BN 模型, 本文提出了一种基于动态奖励机制的节点分类标准, 用奖励值的离散化来表示 X_{10} 并对训练数据集进行标注。当 BN 模型训练完成后, X_{10} 便可由证据变量 $X_1 \sim X_9$ 经 BN 推理预测得到。

2.2 分类标准

本节详细介绍基于蚁群优化算法的动态奖励机制及其改进方案, 以此作为节点投递等级的分类标准。蚁群优化算法是一种寻找最优路径的概率算法^[23], 其路径上的信息素会随着时间的推移而挥发。同样, 节点获得的奖励值也应随着时间的推移动态变化。在前期工作的基础上^[20-21], 本文提出新的 VDTN 节点的动态奖励分配机制。首先, 节点间的相遇有利于消息的转发, 如果节点遇见一个消息投递能力更强的中继节点, 那么该节点的消息投递能力也会较高, 因此本文定义了新的相遇奖励值。其次, 投递时延和跳数都是重要的路由性能指标, 因此本文在跳数投递奖励值的基础上进一步加入了时延奖励值。当某一消息经过一系列中继节点, 最终被投递到目的节点时, 该消息的目的节点将广播一个小的确认 (ACK, acknowledgement) 数据包, 该数据包包含该消息投递路径上的所有中继节点的标识 (ID, identification) 以及从各个中继节点到目的节点的时延, 一旦某个中继节点接收到

了该报文, 该节点将会被分配一定的跳数奖励值和时延奖励值。

通过上述方法, 可以得到节点 n_i 在 $t+1$ 时隙的奖励值 $\psi_{n_i}(t+1)$, 即

$$\psi_{n_i}(t+1) = (1-\rho)\psi_{n_i}(t) + \psi_{n_i}^c(t) + \psi_{n_i}^d(t) \quad (1)$$

其中, $\rho \in [0,1]$ 表示奖励值的老化系数, 该系数使消息的奖励值随着时间不断老化; $\psi_{n_i}^c(t)$ 表示节点 n_i 在 t 时隙内获得的相遇奖励值, $\psi_{n_i}^d(t)$ 表示节点 n_i 在 t 时隙内获得的投递奖励值。

相遇奖励值 $\psi_{n_i}^c(t)$ 的计算式为

$$\begin{aligned} \psi_{n_i}^c(t) &= \sum_{j \in C_{n_i}(t)} \psi_c(\Delta\psi_{ij}(t)) \\ \Delta\psi_{ij}(t) &= \psi_{n_i}(t) - \psi_{n_j}(t) \end{aligned}$$

$$\psi_c(\Delta\psi_{ij}(t)) = \begin{cases} R, \Delta\psi_{ij}(t) > 0 \\ R + R_c \text{Tanh}(\gamma |\Delta\psi_{ij}(t)|), \Delta\psi_{ij}(t) \leq 0 \end{cases} \quad (2)$$

其中, $\Delta\psi_{ij}(t)$ 表示在 t 时隙相遇节点 n_i 和 n_j 的奖励值之差; $\psi_c(\Delta\psi_{ij}(t))$ 表示节点 n_i 与节点 n_j 相遇时, 节点 n_i 应分配的相遇奖励值; R 表示基础相遇奖励值; R_c 表示增量相遇奖励值; γ 表示超参数。因此, 相遇奖励值不再以固定值分配, 而是根据相遇节点的奖励值之差来决定。低奖励值节点与高奖励值节点相遇表明该低奖励值节点有机会将消息转发给投递能力更强的中继节点, 有利于提高消息的投递率, 因此低奖励值节点应当得到较高的相遇奖励值。另外, $C_{n_i}(t)$ 表示节点 n_i 在 t 时隙内相遇节点的集合, 因此 $\psi_{n_i}^c(t)$ 表达了节点 n_i 在 t 时隙内获得的累计相遇奖励值。

令 m 表示第 m 个经过节点 n_i 成功投递的消息, O_m 表示消息 m 的投递路径, 则投递奖励值 $\psi_{n_i}^d(t)$ 的计算式为

$$\psi_{n_i}^d(t) = \sum_{m=1}^{r_{n_i}(t)} \left(\frac{2\theta_{n_i,m}}{N_m(N_m+1)} \psi_d + \frac{\psi_l}{T_{n_i,m}} \right) \quad (3)$$

其中, $\theta_{n_i,m}$ 表示节点 n_i 在消息 m 的投递路径 O_m 中的次序, $N_m = |O_m| - 1$ 表示路径 O_m 的总跳数, ψ_d 表示总跳数奖励值。由此可见, ψ_d 是根据中继节点在投递路径 O_m 中的次序被分配到每个中继节

点上, 并且中继节点在 O_m 中的次序越大 (越靠近目的节点), 得到的奖励值也就越大。由于 $\sum_{n_i \in O_m} \theta_{n_i, m} = 1 + 2 + \dots + N_m = [N_m(N_m + 1)] / 2$, 因此中继节点 n_i 应分配的跳数奖励为 $2\theta_{n_i, m} / N_m(N_m + 1)$ 。同时, 本文将消息时延也纳入投递奖励值的分配中。式(3)中, ψ_l 表示消息的时延奖励值, $T_{n_i, m}$ 表示消息 m 通过中继节点 n_i 被转发到目的节点所经历过的时延, 则 n_i 节点应被分配的时延奖励值为 $\psi_l / T_{n_i, m}$ 。因此, 消息的投递奖励值综合了跳数和时延奖励值。当时延较低时, 时延奖励值作为主导, 有利于消息转发时选择时延较低的中继节点; 当时延较高时, 跳数奖励值作为主导, 有利于消息转发时选择跳数最少的中继节点。最后, $r_{n_i(t)}$ 表示节点 n_i 在时隙 t 内成功投递的消息数目。因此 $\psi_{n_i}^d(t)$ 也是对各消息投递奖励值的累计。

综上所述, 节点的奖励值将随着节点的相遇频率、消息的成功投递数、投递跳数和等动态更新。为了将该奖励机制应用于 BN 模型作为节点的分类标准, 本文将奖励值按相同的间隔离散化为 k_{10} 个等级分别对应投递等级 X_{10} 的 $L_1, L_2, \dots, L_{k_{10}}$ 。等级越高, 表明节点有更大的概率将消息转发到目的节点, 因此使用该动态奖励机制当作节点的分类标准可以帮助路由算法做出正确的路由决策。在进行路由决策时, 携带消息的节点可以通过 BN 模型推理并预测其邻居节点的投递等级, 由此来决定是否将消息转发到邻居节点。

3 结构学习及消息转发

当基于属性向量 X 的训练数据集收集完成后, 接下来的任务就是进行 BN 结构的训练和学习。本节将在 K2GA 算法的基础上研究多时间段的最优划分和各时间段对应的 BN 结构学习问题。

3.1 优化问题

设 D 表示时间范围为 $[0, \tau)$ 的全部训练数据集。现要将总时间范围划分成多个时间段; 令 σ 表示要划分的时间段个数, $[t_k^s, t_k^e), k \in [1, \sigma]$ 表示第 k 个时间段, 其中, t_k^s 和 t_k^e 分别表示该时间段的起始时间和终止时间, 且 $t_1^s = 0, t_\sigma^e = \tau, t_{k+1}^s = t_k^e$ 。根据时间段将数据集 D 划分为 σ 个子集, D_k 表示在数据集 D 中处于第 k 个时间段 $[t_k^s, t_k^e)$ 的数据集。利用

K2GA 算法, 可以优化得到数据集 D_k 对应 BN 结构 G_k 及其 CH (Cooper-Herskovits) 评分函数值 F_k 。这里, K2GA 算法采用的 CH 评分函数是 BN 结构学习中用来判断学习结果优劣的常用指标之一^[24]。故上述过程可表示为

$$\langle G_k, F_k \rangle = \text{K2GA}(D_k) \quad (4)$$

对于多时间段 BN 结构学习, 本文定义 σ 段 BN 的平均 CH 评分值为 F , 以最大化 F 作为问题的优化目标, 即

$$\max F = \frac{1}{\sigma} \sum_{k=1}^{\sigma} F_k \quad (5)$$

为了求解上述问题, 需要寻找一个使 F 值最大化的时间段划分方案及相应的 BN 结构。当 σ 较小时, 可以采用遍历算法来搜索; 但是当 σ 较大时, 遍历算法的开销将呈指数上升。为了降低算法的时间复杂度同时提高优化效率, 本文提出了 2 种多时间段 BN 结构学习算法: BS-K2GA 算法和 SA-K2GA 算法。

3.2 BS-K2GA 算法

BS-K2GA 算法以二分搜索方式进行多时间段 BN 结构的学习和优化。该算法首先寻找最佳分割点, 将整个时间范围分成 2 个时间段; 然后对这 2 个时间段分别进行二分搜索; 如此迭代, 直到达到所需要的时间段划分个数。

算法 1 给出 BS-K2GA 的伪代码, 其输入为需要的时间段划分个数 σ 和训练数据集 D , 输出为 $U = \{u_1, u_2, \dots, u_\sigma\}$, 其中, $u_k = \langle [t_k^s, t_k^e), D_k, G_k, F_k \rangle$ 表示第 k 个时间段的解 (包括时间段的划分、BN 结构和评分等)。步骤 1)~步骤 3) 利用 K2GA 算法获得在全部数据集 D 下的初始解 u_1 。步骤 4)~步骤 9) 通过循环迭代从集合 U 中取出 u_k 并利用 BSplit 算法求得最佳的二分方案, 并将结果并入集合 U 中。由于评分较低的 u_k 可能具有更大的优化空间, 因此步骤 5) 每次都选取评分最低的 u_k 进行二分。最后, 步骤 10) 返回结果集 U 。BSplit 算法的伪代码由算法 2 给出, 该算法对输入的当前解 u_k 进一步划分, 得到最佳二分方案 u_l 和 u_r 。步骤 1) 以 t_c 为分割点将数据集 D_k 二分为 D_l 和 D_r ; 步骤 2)~步骤 3) 调用 K2GA 算法分别求得数据集 D_l 和 D_r 对应的 BN 结构及其评分; 步骤 4) 求最佳平均评分最高的最佳分割点 t_c^* ; 步骤 5)~步骤 7) 生成并返回最佳的

二分解。由于将数据集 D_k 二分所生成的 BN 能更好地描述实际规律，因此 BSplit 算法总能找到一个较优的二分方案。

算法 1 BS-K2GA 算法

输入 σ, D

输出 U

- 1) $U \leftarrow \emptyset$
- 2) $\langle G_1, F_1 \rangle \leftarrow \text{K2GA}(D), u_1 = \langle [0, \tau], D, G_1, F_1 \rangle$
- 3) $U \leftarrow U \cup \{u_1\}$
- 4) while($|U| < \sigma$)
- 5) $u_k \leftarrow \arg \min_{u_i \in U} \{F_i \mid i \in [1, |U|]\}$
- 6) $\langle u_l, u_r \rangle \leftarrow \text{BSplit}(u_k)$
- 7) $U \leftarrow U \setminus u_k \cup \{u_l, u_r\}$
- 8) 按照时间顺序对 U 中的解进行排序并重新编号

9) end while

10) return U

算法 2 BSplit 算法

输入 u_k

输出 u_l, u_r

1) 设 $t_c \in [t_k^s, t_k^e)$ 为该时间段的分割点， D_l, D_r 是 D_k 以 t_c 分割点划分的 2 个子集

2) $\langle G_l, F_l \rangle \leftarrow \text{K2GA}(D_l)$

3) $\langle G_r, F_r \rangle \leftarrow \text{K2GA}(D_r)$

4) 计算二分的最佳分割点

$$t_c^* \leftarrow \arg \min_{t_c \in [t_k^s, t_k^e)} \left(\frac{F_l + F_r}{2} \right)$$

5) $u_l \leftarrow \langle [t_k^s, t_c^*], D_l, G_l, F_l \rangle$

6) $u_r \leftarrow \langle [t_c^*, t_k^e), D_r, G_r, F_r \rangle$

7) return u_l, u_r

下面，简要分析 BS-K2GA 算法的时间复杂度。先根据 K2 算法^[25]，得到 K2GA 算法的时间复杂度为 $O(wzhg^2)$ ，其中， w 为遗传算法的迭代次数， z 为遗传算法的种群数， h 为数据集中的样本数， g 为用于构建 BN 的属性个数。对于 BS-K2GA 算法，设 $\Delta\tau$ 表示搜索的时间段步长，则每次最佳分割点的计算时间复杂度为 $O(\tau / \Delta\tau)$ ，而总的时间段划分个数为 σ 。由此，得到 BS-K2GA 的时间复杂度为 $O(\sigma\tau wzhg^2 / \Delta\tau)$ 。BS-K2GA 算法以贪心策略进行时间段划分，时间复杂度较低，但是该算法容易陷入局部最优，无法找到最优的时间段划分方案。

3.3 SA-K2GA 算法

模拟退火 (SA, simulated annealing) 算法^[26]是一种通用的随机搜索算法，其基本思想为从某一较高初温出发，以热力学统计概率在解空间中随机寻找目标函数的最优解，使算法能概率性地从局部最优解中跳出，并随着温度参数的不断降低最终趋于全局最优。在 SA-K2GA 算法中，设温度参数为 C_0 ，目标函数值为多时间段 BN 的平均评分 F 。首先随机将整个时间范围 $[0, \tau)$ 划分为 σ 个时间段，通过 K2GA 算法求得该划分下多时间段 BN 结构及其平均评分 F 的解；根据当前温度和该解的评分值以一定概率接收其作为当前解；降低温度并对当前的时间划分做随机扰动得到新的划分方案，重复上述过程，直到温度降低为最低值。此时，算法的当前解即最优解。

算法 3 给出了 SA-K2GA 算法的伪代码，其中， C_0 表示初始温度， C_{\min} 表示最低温度， λ 表示温度的变化率， Δt 表示时间段调整的步长。步骤 1)~步骤 7) 生成初始化解。首先在整个时间范围 $[0, \tau)$ 内随机产生的 $\sigma-1$ 个时间分割点 $T_c = \{t_1, t_2, \dots, t_{\sigma-1}\}$ ，其中， $0 < t_1 < t_2 < \dots < t_{\sigma-1} < \tau$ 。根据 T_c 将数据集划分成 σ 个子集 $\{D_1, D_2, \dots, D_\sigma\}$ ，其中， D_k 对应第 k 个时间段 $[t_{k-1}, t_k)$ ， $k \in [1, \sigma]$ ， $t_0 = 0$ ， $t_\sigma = \tau$ 。然后利用 K2GA 算法计算 T_c 划分下的 BN 结构及其 CH 评分产生当前解 U 。步骤 9)~步骤 10) 以步长 Δt 对 T_c 中的分割点进行随机扰动产生新的划分 $T'_c = \{t'_1, t'_2, \dots, t'_{\sigma-1}\}$ 。同理，步骤 11)~步骤 15) 利用 K2GA 算法计算 T'_c 划分下的新解 U' 。步骤 16)~步骤 19) 计算解 U' 和 U 的目标函数值之差 ΔF 。若 $\Delta F > 0$ ，则直接将 U' 赋值给 U ，即接受新解为最优解当前解；否则，采用 Metropolis 准则^[27]根据 $\exp(-\Delta F / C) > \text{rand}$ 以一定概率接收新解，其中， rand 为能产生 $[0, 1]$ 范围实数的随机函数。步骤 20) 用于降低当前温度 C ，然后循环执行上述过程，直到 C 小于 C_{\min} ，步骤 8) 的循环条件不再满足，循环结束。步骤 22) 返回的解即当前的最优解。

算法 3 SA-K2GA 算法

输入 $\sigma, D, C_0, C_{\min}, \lambda, \Delta t$

输出 U

1) $T_c \leftarrow \{t_1, t_2, \dots, t_{\sigma-1}\}$

2) 根据 T_c 切分数据集 D 得到 $D_1, D_2, \dots, D_\sigma$

3) $C \leftarrow C_0, U \leftarrow \emptyset$

- 4) for $i=1$ to σ do
- 5) $\langle \mathbf{G}_i, F_i \rangle \leftarrow \text{K2GA}(\mathbf{D}_i)$,
 $u_i = \langle [t_{i-1}, t_i], \mathbf{D}_i, \mathbf{G}_i, F_i \rangle$
- 6) $U \leftarrow U \cup \{u_i\}$
- 7) end for
- 8) while($C > C_{\min}$)
- 9) 以 Δt 为步长, 对 T_c 产生随机扰动, 得到
 $T'_c = \{t'_1, t'_2, \dots, t'_{\sigma-1}\}$
- 10) 根据 T'_c 切分数据集 \mathbf{D} 得到 $\mathbf{D}'_1, \mathbf{D}'_2, \dots, \mathbf{D}'_\sigma$
- 11) $U' \leftarrow \emptyset$
- 12) for $i=1$ to σ do
- 13) $\langle \mathbf{G}'_i, F'_i \rangle \leftarrow \text{K2GA}(\mathbf{D}'_i)$,
 $u'_i = \langle [t'_{i-1}, t'_i], \mathbf{D}'_i, \mathbf{G}'_i, F'_i \rangle$
- 14) $U' \leftarrow U' \cup \{u'_i\}$
- 15) end for
- 16) $F \leftarrow \frac{1}{\sigma} \sum_{i=1}^{\sigma} F_i$, $F' \leftarrow \frac{1}{\sigma} \sum_{i=1}^{\sigma} F'_i$,
 $\Delta F \leftarrow F' - F$
- 17) if $\Delta F > 0 \vee \Delta F < 0 \wedge \exp(-\frac{\Delta F}{C}) > \text{rand}$ then
- 18) $U \leftarrow U', T_c \leftarrow T'_c$
- 19) end if
- 20) $C \leftarrow \lambda C$
- 21) end while
- 22) return U

由于 SA-K2GA 算法在温度变化率 λ 的控制下由初始温度 C_0 降至最低温度 C_{\min} 所需要执行的轮数为 $\log_{1/\lambda}(C_0 / C_{\min})$, 且在每轮循环中利用 K2GA 算法计算 σ 个时间段 BN 结构的评分, 因此 SA-K2GA 算法的时间复杂度为 $O(\sigma \log_{1/\lambda}(C_0 w z h g^2 / C_{\min}))$ 。与 BS-K2GA 算法相比, SA-K2GA 的算法复杂度略高, 但后续仿真实验结果表明, SA-K2GA 的性能要优于前者。

3.4 消息转发策略

为了实现本文提出的 VDTN 路由算法, 首先需要收集所有车辆的历史信息并生成训练数据集。然后使用 BS-K2GA 或 SA-K2GA 算法训练学习最优的时间段划分方案和各时间段最优的 BN 结构。然后, 基于优化后的多时间段 BN 模型, 通过 BN 推理预测 VDTN 中车辆节点的消息投递等级 X_{10} , 由此决定消息的转发策略。而对于某一确定时间段的 BN 模型, X_{10} 推理方法如下。

设 $\mathbf{x} = \{R_{j_1}, T_{j_2}, M_{j_3}, I_{j_4}, V_{j_5}, P_{j_6}, Q_{j_7}, A_{j_8}, N_{j_9}\}$ 表示当前时刻某车辆节点证据变量集 $X_1 \sim X_9$ 的一个实例, 其中 $j_l \in [1, k_l]$, $l \in [1, 9]$ 。则该车辆节点的投递等级 X_{10} 为

$$X_{10} = \underset{j_{10} \in \{1, \dots, k_{10}\}}{\operatorname{argmax}} P(X_{10} = L_{j_{10}} | \mathbf{x}) \quad (6)$$

其中, $P(X_{10} = L_{j_{10}} | \mathbf{x})$ 为证据实例 \mathbf{x} 下 X_{10} 的后验概率, 可根据对应时间段的 BN 模型推理得到。由于传统基于联合概率分布的推理方法的复杂度随 BN 中节点的个数呈指数上升, 无法应用到大型 BN 推理中。因此, 本文采用了更高效的团树算法^[28]来进行 BN 推理。式(6)表明 X_{10} 的推理预测值应使后验概率 $P(X_{10} = L_{j_{10}} | \mathbf{x})$ 取得最大值。

由此, 本文提出基于多时间段优化 BN 的 VDTN 路由算法, 其消息转发策略如下。

设携带消息的当前车辆节点与另一车辆节点相遇, 则当且仅当满足以下 2 种情况时, 当前车辆节点才会把消息转发给相遇车辆节点。

1) 相遇节点为消息的目的节点时, 消息将被直接投递到目的节点。

2) 当相遇节点非消息的目的节点时, 两车将根据所处的时刻, 选择相应时间段的 BN 模型, 并利用式(6)推理得到各自的投递等级 X_{10} 。若当前节点的 X_{10} 低于相遇节点的 X_{10} , 则将消息转发给相遇节点; 否则当前节点不进行消息转发, 继续携带消息移动, 直到遇见目的节点或投递等级更高的相遇节点。

4 实验结果与分析

4.1 移动轨迹与仿真参数

本文进行仿真实验所使用的数据来自巴西里约热内卢公交系统所记录的真实公交车运行轨迹。该数据是从 CRAWDAD^[29]获得的, 其中包含了覆盖 1 200 km²、涉及 17 723 辆公交车的运动轨迹。尽管原始数据集提供了一天完整的 24 h 移动数据, 但为了使实验环境更接近真实的生活环境, 这里选取其中 98 辆车在上午 7 点到下午 7 点的数据, 并将范围缩小为 35 km×25 km 的区域内, 其中包含了这个城市较繁华的商业区。

本文中的多时间段优化 BN 结构学习算法以及团树构造算法是使用 MATLAB^[30]软件来实现的, 同时该算法调用了 BN 工具箱获取 BN 的 CH 评分

值。当离线完成 BN 学习以及团树构造后,使用 DTN 仿真软件 THE ONE (the opportunistic network environment simulator)^[31]对本文提出的路由算法进行仿真实验。仿真参数如表 1 所示。

表 1 仿真参数

参数	值
仿真时间/s	47 000
仿真区域大小	35 km × 25 km
传输范围/m	50
传输速度/(kbit·s ⁻¹)	250
消息大小/KB	50
节点个数	98

4.2 生成训练数据集

由于 BN 结构学习需要 VDTN 中车辆的属性数据,因此需要先采集车辆的历史数据构造训练数据集。虽然数据集包含一个月的数据,但由于采集轨迹数据时的设备故障,导致期间有数天的轨迹数据不连续,因此本文使用了其中 14 天的数据来进行仿真实验。从 14 天的轨迹数据中随机选取 10 天的数据作为训练集,剩下 4 天的数据作为测试集。在构造训练数据集的仿真实验中,VDTN 中车辆的路由算法设置为基于泛洪方式的 Epidemic 算法,这样能获得更全面的路由信息。而动态奖励机制的参数设置为 $\psi_d=600$, $\psi_l=100$, $R=50$, $R_c=100$, $\rho=0.25$ 。车辆的属性数据表起初为空表,当车辆相遇时,车辆当前的属性值($X_1 \sim X_9$)以及奖励值就被记录到属性表内。当仿真结束时,就可以取出所有车辆本地存储的属性表合并成训练数据集了。

4.3 性能指标

为了评价 VDTN 路由算法的有效性,通常采用以下 3 个指标来衡量路由协议性能的好坏。

投递率: 成功投递到目的节点的消息数目与源节点产生的消息个数之比。


投递时延: 成功投递到目的节点的消息所经过的平均时间。

开销: 在消息成功投递到目的节点时,网络中所产生的平均消息副本个数。


在实验中,本文主要采用消息报文的生存时间(TTL, time to live)作为变量对上述性能指标进行评价,这是路由协议中的重要参数之一。

4.4 参数 σ 取值分析


本节主要探讨参数 σ 对多时间段贝叶斯网络性能的影响。通过改变参数 σ 的取值,利用 SA-K2GA 算法学习不同的 BN 结构。根据学习获得的 BN 结构设计 VDTN 路由算法,并对其性能进行对比实验,如图 3 所示。



(a) 投递率与消息生存时间



(b) 投递时延与消息生存时间



(c) 开销与消息生存时间

图 3 不同时间阶段 BN 路由算法性能比较

从图 3(a)可以看出,随着 σ 的增大,多时间段贝叶斯网络路由算法的投递率不断升高, $\sigma=3$ 时的投递率比 $\sigma=1$ 时的投递率高 5%,然而当 $\sigma=4$ 时,虽然在 $TTL < 100$ 时,投递率较高,但是随着 TTL 的增加,投递率反而低于 $\sigma=3$ 时。这是因为较大的 σ 对时间段的划分可能过细,容易造成 BN 模型的“过拟合”问题。从图 3(b)可以看出,随着 σ 的增大,消息投递的平均时延不断减小。同理,当 $\sigma=3$ 时,平均时延达到最低,而 $\sigma=4$ 的平均时延比 $\sigma=3$ 并未有所改进。从图 3(c)可以看出,随着 σ 的增大,路由算法的网络开销不断降低,当 $\sigma=3$ 时,网络开销达到较低水平,而 $\sigma=4$ 的网络开销相比于 $\sigma=3$ 的改进并不明显。综上所述,三阶段 BN 路由算法可以更准确地学习到车辆的移动模式,在消息转发上的性能也更好。本文在后续实验中均取时间段个数 $\sigma=3$ 。

4.5 BN 多时间段优化划分算法的比较


本节主要比较不同的 BN 多时间段优化划分算法对 VDTN 路由性能的影响。除了本文提出的 BS-K2GA 和 SA-K2GA 算法,实验还比较了以下 2 种算法。

Opt 算法: 利用 K2GA 算法通过全局遍历得到评分 F 取值最高的 σ 阶段 BN 结构。


Avg 算法: 将整个时间范围等分为 σ 个阶段,再利用 K2GA 算法学习得到 σ 阶段 BN 结构。

图 4 给出了采用不同 BN 多时间段优化划分算法的 VDTN 路由性能比较结果。从图 4(a)可以看出,采用 Opt 的路由算法在投递率上表现出了最优的性能,而 SA-K2GA 的投递率仅次于 Opt。当 $TTL=120$ min 时,SA-K2GA 的投递率比 BS-K2GA 高 3%,比 Avg 高 7%。由于采用 Opt 的三阶段 BN 是通过遍历得到的,因此该网络结构具有更高的评分,相应的投递率也最高。SA-K2GA 的投递率与 Opt 相差不大,从侧面说明了 SA-K2GA 算法确实能获得较优的多时间段 BN 划分方案。BS-K2GA 的投递率低于 SA-K2GA,因为 BS-K2GA 基于简单的贪心算法进行求解,通常无法获取最优的划分方案。但 BS-K2GA 算法采用了将评分最低的 BN 所对应的时间段进行二分策略,因此其投递率要明显高于采用时间等分策略的 Avg 算法。同理,如图 4(b)所示,投递时延由低到高的算法依次仍为 Opt、SA-K2GA、BS-K2GA 和 Avg。这里,通过 Avg 算法得到的


BN 对节点投递等级的预测效果最差,无法筛选出较优的中继节点,导致消息传递的时延最高,而 Opt 和 SA-K2GA 的 BN 则表现出了较强的节点投递等级预测能力。



(a) 投递率与消息生存时间



(b) 投递时延与消息生存时间



(c) 开销与消息生存时间

图 4 采用不同 BN 多时间段优化划分算法的路由性能比较

图 4(c)表明 Opt 和 SA-K2GA 的路由开销都比较低。当 $TTL \leq 110$ min 时, SA-K2GA 的开销低于 Opt; 当 $TTL > 110$ min 时, Opt 的开销更小。综上所述, 虽然采用 Opt 算法的 VDTN 路由性能总体最好, 但其采用的遍历算法复杂度太高, 当 σ 较大时, 该算法将无法在多项式时间内求得划分方案。SA-K2GA 算法将模拟退火与 K2GA 算法相结合降低了时间复杂度, 并且在路由性能上媲美 Opt, 因此 SA-K2GA 算法对求解多时间段划分方案是可行有效的。

4.6 与经典路由算法的比较

本节将所提出的 VDTN 路由算法与经典的 Epidemic^[9]、Prophet^[11]以及基于朴素贝叶斯的 (NB, naive Bayesian) 路由算法^[15]进行性能比较, 其中, 多时间段优化采用 SA-K2GA 算法。

图 5 为各种路由算法在不同 TTL 条件下的性能仿真结果。图 5(a)表明 SA-K2GA 的投递率高于 Prophet 和 NB。当 $TTL=100$ min 时, SA-K2GA 的投递率比 Prophet 高 10%, 比 NB 高 8%。因为 SA-K2GA 不仅考虑到了消息传递的历史信息, 还可以学习到在不同时间段车辆的移动模式。NB 在投递率上的表现也优于 Prophet, 说明 NB 也能较好地学习车辆的移动模式, 但其条件独立性假设限制了其性能。另外, 由于 Epidemic 采用泛洪策略进行消息转发, 因此其投递率最高。在图 5(b)中, SA-K2GA 的投递时延低于 Prophet 和 NB。这是因为在 SA-K2GA 中节点的投递等级是根据节点的奖励值来划分的, 其中, 在投递奖励值中, 距离目的节点越近或传输时延越低的中继节点都能得到较高的奖励值, 因此路由算法就选择时延较低或跳数较少的传输路径进行消息转发。同理, Epidemic 的投递时延也是最低的。从图 5(c)可以看出, 随着 TTL 的增加, 路由开销总体上呈上升趋势。但是与 Epidemic、Prophet 和 NB 相比, SA-K2GA 的开销最低, 因为 SA-K2GA 只会将消息转发给投递等级较高的中继节点。但是, Epidemic 的开销却明显高于其他算法。

图 6 给出了各种路由算法在不同 VDTN 节点缓存大小条件下的性能仿真结果。如图 6(a)所示, 随着节点缓存的不断增大, 消息的投递率也在不断上升。当节点缓存为 17 MB 时, SA-K2GA 的投递率比 Prophet 高近 7%, 比 NB 高 4%。如图 6(b)所示, SA-K2GA 的投递时延明显低于 Prophet 和 NB, 因为其改进的奖励值机制将消息的投递时延也考虑

在内。如图 6(c)所示, 随着节点缓存的不断增大, SA-K2GA 的网络开销不断下降, 而且相比 Epidemic、Prophet 和 NB, SA-K2GA 具有最低的路由开销。

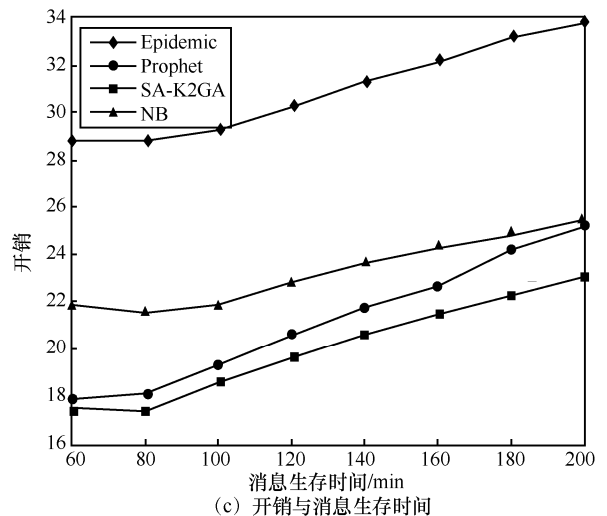




图 5 各种路由算法在不同 TTL 条件下的性能比较




图 6 各种路由算法在不同节点缓存大小条件下的性能比较

5 结束语

本文研究 VDTN 的消息转发问题, 根据车辆节点移动模式的时段性以及节点属性之间的依赖关系, 提出并建立了改进的多时间段 BN 模型。为解决多时间段优化划分和 BN 结构学习问题, 提出了

BS-K2GA 和 SA-K2GA 这 2 种算法。在此基础上, 提出了基于多时间段优化 BN 的 VDTN 路由算法。仿真实验结果验证了多时间段 BN 模型及其优化算法的可行性和有效性。同时, 本文提出的 VDTN 路由算法也具有高投递率、低时延和低开销的性能表现。


在未来的工作中, 笔者将继续优化模型, 如对车辆属性的选择及其离散化标准进行优化, 进一步提高算法效率; 同时, 研究 VDTN 的时变特征, 建立基于时序概率的动态 BN 模型等。

参考文献:


- [1] JAIN S, FALL K, PATRA R. Routing in a delay tolerant network[J]. ACM SIGCOMM Computer Communication Review, 2004, 34(4): 145-158.
- [2] ALAOUI S E, RAMAMURTHY B. Routing optimization for DTN-based space networks using a temporal graph model[C]//Proceedings of 2016 IEEE International Conference on Communications (ICC). Piscataway: IEEE Press, 2016: 1-6.
- [3] LUO J H, CHEN Y P, WU M, et al. A survey of routing protocols for underwater wireless sensor networks[J]. IEEE Communications Surveys & Tutorials, 2021, 23(1): 137-160.
- [4] XIANG S H, YANG J. Performance reliability evaluation for mobile ad hoc networks[J]. Reliability Engineering & System Safety, 2018, 169: 32-39.
- [5] TORNELL S M, CALAFATE C T, CANO J C, et al. DTN protocols for vehicular networks: an application oriented overview[J]. IEEE Communications Surveys & Tutorials, 2015, 17(2): 868-887.
- [6] TIAN J W, GAO M J, GE G S. Wireless sensor network node optimal coverage based on improved genetic algorithm and binary ant colony algorithm[J]. EURASIP Journal on Wireless Communications and Networking, 2016, 2016(1): 104.
- [7] BOCQUILLON R, JOUGLET A. Robust routing in deterministic delay-tolerant networks[J]. Computers & Operations Research, 2018, 92: 77-86.
- [8] VASILAKOS A V, ZHANG Y, SPYROPOULOS T. Delay tolerant networks: protocols and applications[M]. Los Angeles: CRC Press, 2019.
- [9] LI Y, ZHAO L, LIU Z J, et al. N-Drop: congestion control strategy under epidemic routing in DTN[C]//Proceedings of the 2009 International Conference on Wireless Communications and Mobile Computing: Connecting the World Wirelessly. [S.l.:s.n.], 2009: 457-460.
- [10] SPYROPOULOS T, PSOUNIS K, RAGHAVENDRA C S. Spray and wait: an efficient routing scheme for intermittently connected mobile networks[C]//Proceedings of the 2005 ACM SIGCOMM workshop on Delay-tolerant networking. New York: ACM Press, 2005: 252-259.
- [11] LINDGREN A, DORIA A, SCHELÉN O. Probabilistic routing in intermittently connected networks[C]//Service Assurance with Partial and Intermittent Resources. Berlin: Springer, 2004: 239-254.
- [12] SHARMA D K, DHURANDHER S K, WOUNGANG I, et al. A machine learning-based protocol for efficient routing in opportunistic networks[J]. IEEE Systems Journal, 2018, 12(3): 2207-2213.

- [13] ROLLA V G, CURADO M. A reinforcement learning-based routing for delay tolerant networks[J]. *Engineering Applications of Artificial Intelligence*, 2013, 26(10): 2243-2250.
- [14] SEGUNDO F R, FARINES J M, SILVEIRA E. Quasi-opportunistic contact prediction in delay/disruption tolerant network[C]//*Proceedings of Global Information Infrastructure Symposium - GIIS 2013*. Piscataway: IEEE Press, 2013: 1-6.
- [15] AHMED S, KANHERE S S. A Bayesian routing framework for delay tolerant networks[C]//*Proceedings of 2010 IEEE Wireless Communication and Networking Conference*. Piscataway: IEEE Press, 2010: 1-6.
- [16] DUDUKOVICH R, HYLTON A, PAPACHRISTOU C. A machine learning concept for DTN routing[C]//*Proceedings of 2017 IEEE International Conference on Wireless for Space and Extreme Environments (WiSEE)*. Piscataway: IEEE Press, 2017: 110-115.
- [17] LIANG J J, BAI Y B, BI C G, et al. Adaptive routing based on Bayesian network and fuzzy decision algorithm in delay-tolerant network[C]//*Proceedings of 2013 IEEE 10th International Conference on High Performance Computing and Communications & 2013 IEEE International Conference on Embedded and Ubiquitous Computing*. Piscataway: IEEE Press, 2013: 690-697.
- [18] SUTRISNOWATI R A, BAE H, PARK J, et al. Learning Bayesian network from event logs using mutual information test[C]//*Proceedings of 2013 IEEE 6th International Conference on Service-Oriented Computing and Applications*. Piscataway: IEEE Press, 2013: 356-360.
- [19] ZGUROVSKII M Z, BIDYUK P I, TERENT'EV A N. Methods of constructing Bayesian networks based on scoring functions[J]. *Cybernetics and Systems Analysis*, 2008, 44(2): 219-224.
- [20] WU J G, GUO Y H, ZHOU H Y, et al. Vehicular delay tolerant network routing algorithm based on Bayesian network[J]. *IEEE Access*, 2020, 8: 18727-18740.
- [21] ZHOU H Y, WU J G, SHEN L, et al. Vehicle delay-tolerant network routing algorithm based on Multi-period Bayesian network[C]//*Proceedings of 2018 IEEE 37th International Performance Computing and Communications Conference (IPCCC)*. Piscataway: IEEE Press, 2018: 1-8.
- [22] EKMAN F, KERÄNEN A, KARVO J, et al. Working day movement model[C]//*Proceeding of the 1st ACM SIGMOBILE Workshop on Mobility Models*. New York: ACM Press, 2008: 33-40.
- [23] DORIGO M, STÜTZLE T. *Ant colony optimization: overview and recent advances*[M]. Berlin: Springer, 2018.
- [24] DOGUC O, RAMIREZ-MARQUEZ J E. A generic method for estimating system reliability using Bayesian networks[J]. *Reliability Engineering & System Safety*, 2009, 94(2): 542-550.
- [25] 刘彬, 王海羽, 孙美婷, 等. 一种通过节点序寻优进行贝叶斯网络结构学习的算法[J]. *电子与信息学报*, 2018, 40(5): 1234-1241.
- LIU B, WANG H Y, SUN M T, et al. Learning Bayesian network structure from node ordering searching optimal[J]. *Journal of Electronics & Information Technology*, 2018, 40(5): 1234-1241.
- [26] DELAHAYE D, CHAIMATANAN S, MONGEAU M. *Simulated annealing: from basics to applications*[M]. Berlin: Springer, 2018.
- [27] METROPOLIS N, ROSENBLUTH A W, ROSENBLUTH M N, et al. Equation of state calculations by fast computing machines[J]. *The Journal of Chemical Physics*, 1953, 21(6): 1087-1092.
- [28] MADSEN A L, JENSEN F V. Lazy propagation: a junction tree inference algorithm based on lazy evaluation[J]. *Artificial Intelligence*, 1999, 113(1/2): 203-245.
- [29] KOTZ D, HENDERSON T. CRAWDAD: a community resource for archiving wireless data at Dartmouth[J]. *IEEE Pervasive Computing*, 2005, 4(4): 12-14.
- [30] SHAH V, GILBERT J R. *Sparse matrices in Matlab*P: design and implementation*[C]//*Lecture Notes in Computer Science*. Berlin: Springer, 2004: 144-155.
- [31] KERÄNEN A, OTT J, KÄRKKÄINEN T. The ONE simulator for DTN protocol evaluation[C]//*Proceedings of the Second International ICST Conference on Simulation Tools and Techniques*. [S.l.:s.n.], 2009: 1-10.

[作者简介]



吴家皋 (1969-), 男, 江苏苏州人, 博士, 南京邮电大学副教授, 主要研究方向为计算机网络、分布式计算、人工智能等。



郭亚航 (1994-), 男, 河南商丘人, 南京邮电大学硕士生, 主要研究方向为车载容迟网络、路由算法等。



蔡沈磊 (1998-), 男, 江苏南通人, 南京邮电大学硕士生, 主要研究方向为车载容迟网络、路由算法等。



刘林峰 (1981-), 男, 江苏丹阳人, 博士, 南京邮电大学教授, 主要研究方向为计算机网络、机器学习等。