

doi: 10.3969/j.issn.1673-6478.2023.05.001

插电式混合动力汽车绿色路径规划研究

何智杨, 丁 烨

(东莞理工学院计算机, 广东 东莞 523808)

摘要: 为了降低插电式混合动力汽车 (Plug-in Hybrid Electric Vehicle, PHEV) 在驾驶过程中的能耗, 本文对插电式混合动力汽车绿色路径规划问题 (Plug-in Hybrid Electric Vehicle Green Routing Problem, PHEVGRP) 进行了研究。基于脉冲耦合神经网络提出了用时间依赖神经网络求解时间依赖车辆路径规划问题。基于可实时获取的道路交通状态量建立 PHEV 能耗计算模型。采用硬参数共享多任务学习建立道路交通状态量的预测模型。结合两个模型, 将时间依赖神经网络应用于 PHEVGRP 的求解。采用真实数据进行试验, 结果表明所提出的方法能够求得 PHEVGRP 的基于预测模型的最优解且求解速度优于启发式算法。

关键词: 车辆绿色路径规划; 多任务学习; 脉冲耦合神经网络; 插电式混合动力汽车; 时间依赖最短路径问题

中图分类号: U491.1

文献标识码: A

文章编号: 1673-6478 (2023) 05-0001-06

Research on the Green Routing of Plug-in Hybrid Electric Vehicle

HE Zhiyang, DING Ye

(Dongguan University of Technology, Dongguan Guangdong 523808, China)

Abstract: In order to reduce the energy consumption of plug-in hybrid electric vehicle (PHEV) during driving, this paper studies the Plug-in Hybrid Electric Vehicle Green Routing Problem (PHEVGRP). A time-dependent relay neural network based on pulse-coupled neural network is proposed to solve time-dependent vehicle routing problem. Based on the road traffic status data that can be acquired in real time, a PHEV energy consumption calculation model is established. Hard parameter sharing multi-task learning is used to establish a prediction model of road traffic status. Combining the two models, the time-dependent relay neural network is applied to the solve PHEVGRP. By using real data for experiments, the result show that the proposed method can obtain the optimal solution of PHEVGRP and is faster than heuristic algorithm.

Key words: vehicle green routing; muti-task learning; pulse-coupled neural network; plug-in hybrid electric vehicles; time-dependent shortest path problem

0 引言

车辆路径规划问题 (Vehicle Routing Problem, VRP) 是交通领域中的重要问题。时间依赖车辆路径规划问题 (Time Dependent Vehicle Routing Problem, TDVRP) 是在动态网络中的 VRP。动态网络是指网络中边的属性值具有时变性, 严格依赖于出发时间。动态网络边的属性定义决定了 TDVRP 的规划目标。根

据规划路径过程中所涉及时间节点的网络变化是否已知, TDVRP 可以分为已知网络变化和未知网络变化两种情况。前者在历史时间节点开始规划路径, 规划过程中根据到达时间直接使用已知的数据进行计算, 能够求得真实的最优解。但该最优解已失去时效性, 不能满足现实生活中实时规划的需求。后者则是在实时时间点开始规划路径, 规划过程中需要根据到达时间对相应时间点的数据进行预测, 并基于预测得

收稿日期: 2022-12-30

基金项目: 国家自然科学基金项目 (61976051); 国家自然科学基金联合基金重点支持项目 (U19A2067)

作者简介: 何智杨 (1995-), 男, 广东梅州人, 硕士, 研究方向为时空大数据挖掘。(642997840@qq.com)

到的数据进行计算。由于预测值和真实值之间会存在误差,后者只能取得基于预测结果的最优解,与真实的最优解之间的差距取决于预测模型的精度。

过去对 TDVRP 的研究主要是以时间最短为规划目标来展开的。随着社会节能减排意识的加强,车辆绿色路径规划问题 (Vehicle Green Routing Problem, VGRP) 引起了学者的重视。VGRP 是将动态网络中边的属性定义为能耗值,以能耗最少作为规划目标的 TDVRP。PHEV 是从传统燃油汽车向纯电动汽车转型过渡过程中的有效解决方案,随着 PHEVGRP 市场占比不断上升,求解 PHEVGRP 对节能减排有着重要的意义。

PHEVGRP 的现有求解方法主要包括能耗计算和路径规划两个部分。在能耗计算方面,Cela 等^[1]建立车辆纵向动力学模型,根据实时速度计算车辆总功率需求进而计算能耗。Nunzio 等^[2-3]根据平均速度将道路分为三类并分别对应一种已知工况。同时提出了一种基于庞特里亚金最小原理的方法,根据速度和加速度求解工况中控制策略的半解析解,得到最优控制策略下的能耗,计算得到单位距离能耗值。Houshmand 等^[4]根据车流量将道路分为三类并分别对应一种已知工况,通过仿真得到每种工况的能耗值,计算得到单位公里能耗值。在路径规划方面,Cela 等^[1]提出了一种结合 A*算法和 Dijkstra 算法的方法规划路径。Nunzio 等^[2-3]通过求解时间和能耗的组合优化问题规划路径。Houshmand 等^[4]采用电量消耗优先的控制策略结合 Dijkstra 算法规划路径,同时对求解得出的路径进行控制策略的优化,进一步减少能耗。以上文献均采用查询时刻的交通道路状态计算得出的能耗值进行路径规划。

PHEVGRP 的现有研究中存在以下不足:

能耗计算方面。根据车辆瞬时状态来计算能耗的方式,因在全程瞬时状态的预测方法上有所限制,无法应用于全局空间的搜索。采用少量道路流量状态或平均速度对能耗进行表征的方法不能够充分覆盖真实中的交通状况。

路径规划方法方面。简化控制策略来规划路径的方式过于理想化,不符合真实的驾驶情况。采用传统路径规划算法以及组合优化的方法求解速度缓慢。以查询时刻的交通道路状态进行规划仅考虑了二维空间的静态信息,而忽略了时间维度的动态信息,在搜索路径过程中并未对道路交通状态量进行更新。

本文基于脉冲耦合神经网络 (Pulse Coupled Neural Network, PCNN) 提出了一种在时空维度搜索最优路径的时间依赖中继神经网络 (Time-Dependent Relay Neuron Network, TDRNN) 用于求解未知网络

变化的 TDVRP。通过在仿真软件中模拟不同的道路拥挤程度得到覆盖各种交通状况的能耗数据,基于能够实时获取的道路状态量建立 PHEV 能耗计算模型。同时为每条道路建立一个硬参数共享多任务学习模型预测未来的道路状态量,用于实时更新能耗。将两个模型与 TDRNN 相结合用于求解 PHEVGRP。本文基于真实的道路交通状态数据,在真实场景下对所提出的 PHEVGRP 求解方法进行了验证。

1 基于 PCNN 的 TDRNN 求解 TDVRP 最优解

1.1 PCNN 求解静态图最短路径问题

PCNN 是一种有生物学背景的,拥有脉冲耦合、可变阈值和发放同步脉冲特性的新一代人工神经网络。PCNN 最早由 Caulfield 和 Kinser^[5]提出用于求解迷宫问题。顾等^[6]提出了时延 PCNN (Delay Pulsed Coupled Neuron Network, DPCNN) 来求解静态图最短路径问题,解决了 Caulfield 和 Kinser^[6]提出的方法中需要大量神经元的问题。DPCNN 神经元结构如图 1 所示。在 DPCNN 神经元中,内部状态量 U_j 用于表示其他神经元的输入,阈值 θ_j 用于控制脉冲的发放。当 U_j 大于等于 θ_j 时,神经元发放脉冲。

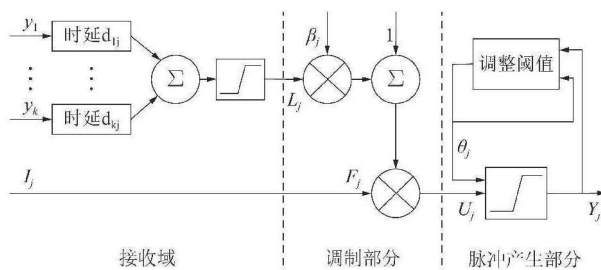


图 1 DPCNN 神经元结构

Fig.1 The neuron structure of DPCNN

求解静态网络最短路径问题时,时延 PCNN 以路网结构初始化神经网络的拓扑结构,然后将起点神经元点火并发放脉冲。脉冲沿着所有可能的路径并行地传播,分别经过等于各路径长度的时延后,使其相连的神经元点火并发放脉冲继续在网络中传播。当终点神经元点火时,得到全局最短路径。DPCNN 中脉冲的传播具有并行性,求解最短路径问题的效率比传统最短路径算法的效率更高。在静态网络中,最短路径的全局最优解由局部最优解构成。因此在脉冲传播过程中,神经元在第一次点火后将阈值升高到固定值,使神经元不再点火。第一个到达神经元的脉冲所经过的路径即为起点神经元到该神经元的 shortest 路径。

1.2 TDRNN 求解 TDVRP

求解 TDVRP 需要在空间和时间维度上进行路径

搜索, 搜索过程中局部最优解并不一定能构成全局最优解。本文基于 DPCNN 提出了 TDRNN 用于求解已知网络变化的 TDVRP。TDRNN 在神经元中记录所有到达的脉冲信息, 并根据到达道路的时间实时预测相应的交通状态值生成脉冲。TDRNN 包括脉冲中继器 PR 和神经元集合 N, 整体结构如图 2 所示。




图 2 TDRNN 网络结构
Fig.2 The structure of TDRNN




图 3 时间依赖中继神经元结构
Fig.3 The neuron structure of TDRNN

脉冲传播过程中, 对 PR 中的所有脉冲 p , 以传播速度 δ 对 ec_p 进行更新。当 ec_p 大于等于 ec 时, PS 将 p 输出到 p_d 中。在脉冲 p 输入神经元 n 时, n_{PF} 根据 p_a 判断是否已经有脉冲在时间窗 p_a 中到达 n 。若已有脉冲到达, 则神经元不点火。若尚未有脉冲到达, 则 n 在 p_a 时间窗点火, 将 p_a 和 p_{pl} 添加到 n_{PL} 中并传递给 n_o 。 n_o 的每条输出边根据 p_a 计算出脉冲长度和脉冲耗时, 生成脉冲输出到 PR 中。当求解以时间最短为规划目标的 TDVRP 时, 即边的属性定义为道路的耗时, 输出边的 $f_{nm}(t)$ 和 $k_{nm}(t)$ 仅保留其中一个即可。TDRNN 采用中继的方式管理脉冲, 能够在脉冲传播阶段对脉冲统一更新, 减少了实际运行代码时对神经元的访问次数, 提高网络运行的速率。

TDRNN 求解 TDVRP 时, 使起点神经元 s 在当前时间窗 t 点火并发放脉冲。脉冲以速度 δ 在网络中传播并激发沿途其他神经元点火发放脉冲。当终点神经元 d 点火时, 得到全局最短路径。求解的具体过程由表 1~表 4 中的算法进行说明。

PR 包含网络中正在传播的脉冲。N 包含了网络中的神经元。神经元对应动态网络中的节点。TDRNN 的神经元之间并不直接相连, 而是通过 PR 传递脉冲来进行通信。TDRNN 的神经元 n 内部包含了脉冲输入、脉冲过滤器 n_{PF} 、记录器 n_{PL} 和输出部分 n_o , 结构如图 3 所示。 n_o 中的每条输出边对应网络中的边, 包含神经元 n 到其后继神经元 m 的脉冲长度预测函数 $f_{nm}(t)$ 、脉冲耗时更新函数 $k_{nm}(t)$ 。脉冲长度和耗时依赖于神经元点火时间 t 。前者对应动态网络中边的属性值, 后者用于计算 t 。脉冲 p 中记录了脉冲的来源神经元 p_s 、脉冲在来源神经元记录器的位置 p_{pl} 、脉冲的目标神经元 p_d 、脉冲进度 ec_p 、脉冲长度 ec 以及脉冲到达时间窗 p_a 。

表 1 TDRNN 整体算法

Tab.1 Overall TDRNN algorithm

算法 1: 整体网络运行	
输入:	N, PR, s, d, t, δ ;
输出:	最短路径
1	$PT = \text{Fire}(-1, -1, s, 0, 0, t, N)$; \\\起点神经元点火生成的脉冲
2	foreach $p \in PT$ do
3	$PR.append(p, N)$; \\\append()表示从尾部加入
4	$\text{PulseUpdate}(PR, \delta, d, N)$;
5	print $\text{GetShortestPath}(d)$;

表 2 神经元点火算法

Tab.2 Neuron firing algorithm

算法 2: 神经元点火	
输入:	N, p
输出:	点火产生的脉冲
1	Function $\text{Fire}(p, N)$:
2	$PT = []$; \\\记录神经元 p_d 点火产生的脉冲
3	$n = N[p_d]$;
4	if $p_a \in n_{PF}$ then \\\判断在时间窗 p_a 是否有脉冲到达神经元
5	return;
6	else:
7	$n_{PF}.append(p_a)$;
8	$n_{PL}.append((p_s, p_{PL}))$;
9	foreach $m \in n_o$ do \\\输出部分生成脉冲
10	$ec = f_{nm}(p_a)$;
11	$t_p = k_{nm}(p_a)$;
12	$t_c = p_a + t_p$;
13	$PT.append((p_d, len(n_{PF}), m, 0, ec, t_c))$; \\\len()表示取得长度
14	return PT ;

表 3 脉冲更新算法

Tab.3 Pulse updating algorithm

算法 3: 脉冲传播

```

输入:  $PR, \delta, d, N$ 
输出: 完成脉冲传播的神经元集合  $N$ 
1 Function PulseUpdate( $PR, \delta, d, N$ ):
2 while True do
3  $FTP = []$ ; \记录单次脉冲更新时神经元点火生成的脉冲
4  $DT = []$ ; \记录到达目标神经元的脉冲
5 foreach  $p \in PR$  do
6  $ec_p = ec_p + \delta$ ;
7 if  $ec_p == ec$  then
8  $FTP.extend(Fire(p, N))$ ; \extend()表示合并
9  $DT.append(p)$ ;
10 if  $p_d == d$  then \目标神经元点火
11 return;
12 foreach  $p \in DT$  do
13  $PR.remove(p)$ ; \remove()表示删除
14 foreach  $p \in FPT$  do
15  $PR.append(p)$ ;

```

表 4 输出最短路径算法

Tab.4 Print shortest path algorithm

算法 4: 输出最短路径

```

输入: 目标神经元  $d$ , 神经元集合  $N$ 
输出: 最短路径  $path$ 
1 Function GetShortestPath( $d$ ):
2  $path = []$ ;
3  $(i, j) = d_{PL}[0]$ ;
4  $path.inserthead(d)$ ; \从 path 头部插入  $d$ 
5 while  $(i, j) \neq (-1, 1)$  do
6  $(i, j) = N[i][PL][j]$ ;
7  $path.inserthead(i)$ ; \从 path 头部插入  $i$ 
8 return  $path$ ;

```

2 TDRNN 求解 PHEVGRP

将脉冲长度定义为 PHEV 的能耗值, 即可将 TDRNN 应用于求解 PHEVGRP, 求解过程中需要根据到达时间来对道路的通行能耗进行更新。预测道路某个量在未来时间的值是一个时序数据预测问题, 需要结合历史数据来进行预测。某条道路上的通行能耗并非实时可观测的量, 无法根据历史数据进行预测。本文通过仿真软件建立能耗数据, 基于能够通过高德地图 API 实时获取的道路拥堵系数、平均速度数据, 以及地图数据中已知的道路长度和道路限速, 建立 PHEV 能耗计算模型。拥堵系数影响汽车的加减速频率, 平均速度反映整体功率需求, 两者都是能耗的重要影响因素。同时为每条道路建立硬参数共享多任务学习预测模型对两个可实时获取的量的未来状态进行预测。结合上述两个模型, 实现对未来道路通行能耗的预测。

2.1 PHEV 能耗计算模型

本文采用 SUMO 仿真软件在广州市海珠区部分

路网上进行仿真来获取能耗数据。采用 P2 插电式混合动力车型^[7]作为仿真车型。通过在仿真过程中设置不同的车流来模拟不同的道路拥堵状况。SUMO 仿真过程中可提取出车辆所处的道路 r 、在道路上的平均驾驶速度 v_{mean} 、道路的通行时间 t_p 以及产生的油耗 c_f 和电耗 c_e 。将 c_f 和 c_e 的单位统一为千焦 (kJ)。同时计算道路的拥堵系数 α , 计算方式如式 (1) 所示, 其中 l_r , t_p , v_r 分别为 r 的长度、畅通时的通行时间以及最高限速。

$$\alpha = \frac{t_p}{t_r} = \frac{t_p}{l_r/v_r} \quad (1)$$

对多次仿真产生的能耗数据采用随机森林模型对 c_f 与 c_e 进行拟合得到的多输出计算模型 f_c 如式 (2) 所示。将计算得出的 c_f 与 c_e 相加, 得到总能耗 c 计算模型 f_d , 如式 (3) 所示。由于不同道路状况对 PHEV 油耗和电耗的影响程度不同, 相比直接拟合总能耗的单输出回归模型, 多输出回归模型在分别输出油耗和电耗后相加得到的总能耗准确度更高。

$$c_f, c_e = f_c(\alpha, v_{\text{mean}}, l_r) \quad (2)$$

$$c = f_d(\alpha, v_{\text{mean}}, l_r) \quad (3)$$

2.2 硬参数共享多任务学习预测模型

多任务学习 (Multi-Task Learning, MTL) 是一种联合多个任务同时学习的方法。相比单任务学习 (Single-Task Learning, STL), MTL 可以捕捉多个任务之间的关联性来增强模型表示和泛化能力的方法。硬参数共享多任务学习是在参数共享层中将多个任务的数据嵌入到同一个语义空间中, 再为每个任务使用一个任务特定层提取任务特定特征表示。本文采用长短期记忆网络 (Long Short Term Memory, LSTM) 作为多任务学习的参数共享层和任务特定层。LSTM 改善了循环神经网络 RNN 中梯度消失和梯度爆炸的情况, 能够很好地捕捉时序数据中的时间特征, 在时序数据预测上的准确度较高。

本文为每条道路建立了一个多任务学习预测模型, 以当前时间前 20 个时间窗道路的拥挤系数和平均速度数据预测下一个时间窗的数据。模型如图 4 所示。LSTM 只能进行固定时间步长的预测, 当需要预测的时间步长大于 1 时, 将预测结果与原输入数据结合, 进行循环预测。循环预测模型如式 (4) 所示, 其中 d_r 表示道路 r 在当前时间前 20 个时间窗的数据, $step$ 表示预测的时间步长。

$$\alpha, v_{\text{mean}} = MTL_r(d_r, step) \quad (4)$$




图 4 硬参数共享多任务预测模型

Fig.4 Hard-share multi-task learning predict model

2.3 求解 PHEVGRP

在 TDRNN 神经元的输出部分, 以式 (3)、(4) 结合作为脉冲长度预测函数, 以 (1)、(4) 式结合作为脉冲耗时预测函数。当脉冲 p 激发神经元 n 点火时, 以 p_a 作为 $step$, 结合式 (4) 预测得到 α 和 v_{mean} , 进一步结合式 (3) 计算得出能耗作为脉冲长度。结合 α 和式 (1) 得到道路的通行时间作为脉冲耗时。根据以上得到的值生成脉冲并传播, 实现 PHEVGRP 的求解。

3 实验

本文基于广州市海珠区道路网络对所提出的 PHEVGRP 求解方法进行验证。道路网络包含 16 947 条边, 7 765 个节点。通过高德地图开发者 API, 连续 15 天间隔 2 分钟采集每条道路的拥堵系数、平均速度。每条道路共有 10 080 条数据。前 14 天的数据和第 15 天的数据分别作为 MTL 模型的训练集和测试集。在第 15 天整天时间范围内间隔 20 分钟进行一次单步预测来测试模型的泛化效果。每条道路的预测模型共进行 72 次测试, 同时计算测试结果的相对误差, 并在每个时间点统计所有道路预测模型的平均相对误差。图 5 和图 6 分别为平均速度和拥堵系数在测试时间点的平均相对误差。平均速度的平均相对误差在 0.012 和 0.028 之间, 拥堵系数的平均相对误差在 0.032 至 0.052 之间。模型在高峰期 (8:00 至 10:00、18:00 至 20:00) 的相对误差升高, 是因为高峰期的道路状况波动较大, 模型在该情况下的预测准确度会有所下降。

在第 15 天中随机选择 7 个出发时间, 每个出发时间在路网中随机选择起点和终点, 进行 7 组实验。在实验中, TDRNN 将基于平均精度的预测模型进行路径规划。为 TDRNN 设置三个对照组:

(1) 对照实验 1: 根据完整的数据即在已知网络变化的情况下, 采用杨传印等^[8]提出的基于优先队列的方法求出 PHEVGRP 的真实最优路径和能耗。

(2) 对照组 2: 假设所选地图范围内任意两个点之间的通行时间小于或等于 1 小时, 预测出发时间未来 1 小时所有道路的平均速度和拥堵系数。以预测得到的数据作为已知网络变化的情况, 采用杨传印等^[8]提出的方法求解出 PHEVGRP 基于预测数据的最优路径和能耗作为对照组 2。

(3) 对照组 3: 以能耗和距离为启发式函数 A*算法求解 PHEVGRP 的路径和能耗, 求解过程中根据到达时间实时预测道路的平均速度和拥堵系数并计算能耗。

用 IP 和 IR 值分别表示路径是否与真实最优解路径、基于预测数据的最优解路径相同, 值为 1 时表示相同, 值为 0 时表示不相同。实验结果如表 5 所示, TDRNN 能够求得基于预测结果的最优路径和能耗, 且求解速度优于 A*算法, 但未必能够求得真实的最优解。由于预测模型存在误差, 即使在求得真实最优路径的情况下, TDRNN 求得的能耗与真实最优解之间仍然存在误差。




图 5 平均速度在测试时间点的平均相对误差

Fig.5 Average relative error of average velocity at test time points




图 6 拥堵系数在测试时间点的平均相对误差

Fig.6 Average relative error of the congestion coefficient at the test time point

表 5 实验结果

Tab.5 The result of experiment		实验 1	实验 2	实验 3	实验 4	实验 5	实验 6	实验 7
能耗 /kJ	对照组 1	36.8	43.7	43.9	28.5	54.6	37.5	56.4
	对照组 2	35.4	42.3	48.4	27.2	53.5	38.4	58.3
	对照组 3	45.5	42.3	55.6	32.6	53.5	45.5	66.2
	TDRNN	35.4	42.3	48.4	27.2	53.5	38.4	58.3
运行时间/s	对照组 3	87.2	95.2	92.4	88.5	102.6	92.6	108.7
	TDRNN	8.9	10.2	9.5	8.2	10.8	9.4	10.7
IR	对照组 2	1	1	0	1	1	1	1
	对照组 3	0	1	0	0	1	0	0
	TDRNN	1	1	0	1	1	1	1
IP	对照组 3	0	1	0	0	1	0	0
	TDRNN	1	1	1	1	1	1	1

在高峰期和非高峰期时间段随机各选取了 100 个出发时间, 每个出发时间在路网中随机选择起点和终点, 进行 200 组实验来测试 TDRNN 基于平均精度的预测模型求解的能耗和真实最优解之间的相对误差, 以及相应路径解与真实路径最优解的符合情况。如图 7 所示, 实验中 TDRNN 求解的能耗与真实最优解之间的相对误差, 在非高峰期集中在 0.03 至 0.06 之间, 在高峰期集中在 0.07 至 0.1 之间。如图 8 所示, TDRNN 在大部分实验中能够求解得到真实的最优解。相比非高峰期, TDRNN 在高峰期规划的路径更容易偏离真实的最优路径解。




图 7 TDRNN 的能耗解与真实最优能耗解的相对误差箱形图
Fig.7 The box plot of the relative error of the TDRNN energy solution and the true optimal energy solution




图 8 TDRNN 的路径解与真实最优路径解对比结果直方图
Fig.8 The histogram of the path solution of TDRNN compared to the true optimal path solution

4 结语

为了降低 PHEV 在驾驶过程中的能耗, 本文对 PHEVGRP 进行了研究。由于 VGRP 属于 TDVRP 的分支领域, 本文首先基于 DPCNN 提出了 TDRNN, 实现求解未知网络变化 TDVRP 基于相应预测模型的

最优解。再基于能够实时获取的道路拥挤系数和平均速度数据, 建立 PHEV 能耗计算模型和用于预测两个可实时获取的量的硬参数共享多任务学习模型。结合两个模型, 将 TDRNN 应用于 PHEVGRP 的求解。采用真实数据进行实验, 实验表明 TDRNN 能够求得 PHEVGRP 基于预测模型的最优解且求解速度优于启发式算法。在不同时间段对预测模型的预测能力、TDRNN 的解与真实最优解之间的误差进行评估。结果表明, 与非高峰期相比, 预测模型的预测值以及 TDRNN 求解的能耗在高峰期的相对误差更高, 且 TDRNN 在高峰期规划的路径更容易偏离真实的最优解路径。TDRNN 求解结果所产生的误差是由预测模型中单步预测的误差以及循环多步预测中单步误差的积累导致的。可以通过增加时序数据在时间维度上的特征提取来提升预测模型的精度, 进而减小 TDRNN 求解 PHEVGRP 产生的误差。

参考文献:

- [1] Cela A, Jurik T, Hamouche R, et al. Energy optimal real-time navigation system[J]. IEEE. Intelligent Transportation Systems Magazine, 2014, (6): 66-79.
- [2] Nunzio GD, Sciarretta A, Gharbia IB, et al. A constrained eco-routing strategy for hybrid electric vehicles based on semi-analytical energy management[C]. 2018 21st International Conference on Intelligent Transportation Systems (ITSC), 2018: 355-361.
- [3] Salazar M, Houshmand A, Cassandras C G, et al. Optimal routing and energy management strategies for plug-in hybrid electric vehicles[C]. 2019 IEEE Intelligent Transportation Systems Conference (ITSC). 2019: 733-739.
- [4] Houshmand A, Cassandras C G, Zhou N, et al. Combined eco-routing and power-train control of plug-in hybrid electric vehicles in transportation networks[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, (23): 11287-11300.
- [5] 顾晓东, 余道衡, 张立明. 时延 PCNN 及其用于求解最短路径[J]. 电子学报, 2004, (9): 1441-1443.
- [6] Caulfield H J, Kinser J M. Finding the shortest path in the shortest time using PCNN's[J]. IEEE. Transactions on Neural Networks. 1999, 10(3): 604-6.
- [7] 贺伟. 插电式混合动力汽车控制策略设计及硬件在环研究[D]. 成都: 西华大学, 2022.
- [8] 杨传印, 黄玮, 薛少聪, 等. 基于优先队列的时变网络最短路径算法[J]. 计算机应用研究, 2019, 36(5): 1403-1408.