

基于交通流信息融合的汽车车速预测模型研究

胡志远¹ 杨锐¹ 房亮* 王卓¹ 赵瀛华¹

(1.同济大学, 上海 201804)

摘要: 汽车行业的发展受到资源短缺的影响, 同时也会带来严重的环境问题。我国提出 2030 年前达到碳达峰; 2060 年前达到碳中和的双碳目标, 逐步推进能源发展绿色低碳转型。发展新能源汽车是我国在汽车行业实现能源结构转型的重要途径。HEV 作为汽车能源转型的过渡型产品, 它同时拥有内燃机汽车和电动汽车的优点, 既能够在一定程度上改善内燃机汽车的排放问题, 也能够改善电动汽车行驶里程短的问题, 目前对于 HEV 的研究中重要的环节之一为整车能量管理策略的设计, 基于模型预测控制是当下最为主流的能量管理策略之一, 它的优化效果主要受制于模型预测精度的影响, 本研究通过仿真手段搭建了局部路段的 ITS 环境, 通过融合本车历史信息、前车车速、车距、信号灯状态、距离和剩余时间等多元信息有效提高了车速预测模型的预测精度, 进而构建了基于信息融合的 PHEV 能量管理策略, 以期在 ITS 环境得到局部覆盖后为改善 PHEV 整车经济性提供切实可行的解决方案。

关键词: 交通流; 多元信息融合; 车速预测

1.背景

汽车行业的发展受到资源短缺的影响, 同时也会带来严重的环境问题^[1, 2], 中国能源结构具有明显的“富煤、贫油、少气”特点^[3]。根据国家统计局数据显示, 中国原油进口量自 2010 年起连续十年逐渐递增, 2022 年已达到 50829 万吨。我国提出 2030 年前达到碳达峰; 2060 年前达到碳中和^[4]的双碳目标, 逐步推进能源发展绿色低碳转型。发展新能源汽车是我国在汽车行业实现能源结构转型的重要途径^[5], 自 2009 年以来, 我国推出一系列优惠政策支持发展新能源汽车。新能源汽车主要包括纯电动汽车、燃料电池电动汽车(Fuel Cell Vehicle, FCV)、混合动力汽车(Hybrid Electric Vehicle, HEV)和氢能源动力汽车等^[6], 我国作为新能源汽车第一大市场, 含 PHEV 在内的电动汽车保有量达到 450 万辆。中国汽车工程学会在《节能与新能源汽车技术路线 2.0》中明确指出, 至 2035 年我国的传统能源动力乘用车将全部被混合动力汽车替代。HEV 作为汽车能源转型的过渡型产品, 它同时拥有内燃机汽车和电动汽车的优点, 既能够在一定程度上改善内燃机汽车的排放问题, 也能够改善电动汽车行驶里程短的问题^[7]。当前大量的学者对混合动力汽车进行了研究: Jiankun Peng^[8]等研究了基于层次强化学习的插电式混合动力汽车生态跟随过程能量管理策略, 此策略相较于离线全局最优算法显著提高了训练速度和稳定性, 并且能耗差小于 3%, 计算负荷小于 600 次; Wissam Bou Nader^[9]等研究了混合动力汽车发动机辅助动力单元, 在 WLTC 中进行油耗测试发现其可以节省 20%以上的燃油, 且燃油消耗与传统内燃机相当; Zhen Zhang^[10]等研究了基于深度强化学习和熵评价的新型并联电液混合动力汽车能量管理策略, 在 WLTC

和 NEDC 下的能耗率分别提高了 18.51%和 15.74%。Maobing Li^[11]等研究了一种将锂离子电池与超级电容器集成在一起作为混合动力系统的电动汽车动力总成结构,发现其在使用混合电源时能够显著节省 30%的电池容量能量,同时电池的电压和电流曲线比单电源更加平滑。目前对于 HEV 的研究中重要的环节之一为整车能量管理策略的设计,HEV 能量管理策略^[12]用来将需求功率按不同的分配规则分配到不同的动力源,以此达到不同的优化目标。目前的研究主要集中在使整车经济性最优,即等效燃油消耗量最低。未来的能量管理策略可能会更加注重排放性及驾驶舒适性的优化。

随着 5G 技术的快速发展,智慧交通系统(Intelligent Traffic System, ITS)的建设已经成为我国“新基建”的重要任务^[13, 14],车路协同是智慧交通的必然途径,它将车、路、人三者紧密联系在一起,从而提供安全、高效、便捷的智慧交通服务。同时车联网也为 HEV 能量管理问题带来了新的思路,利用车间通信 V2V、车与路测单元通信 V2X 获取更加充分的行车信息,进行 HEV 能量管理策略的开发已然成为了当下的研究热点。基于模型预测控制是当下最为主流的能量管理策略之一,它的优化效果主要受制于模型预测精度的影响,过去的研究主要基于历史信息进行随机预测,无法适应瞬息万变的交通场景。随着车联网技术的发展,ITS 正逐渐从概念转变为现实,V2X 通信可使车辆实时掌握周围的路况信息,为建立高精度的车速预测模型提供了可能。本研究通过仿真手段搭建了局部路段的 ITS 环境,通过融合本车历史信息、前车车速、车距、信号灯状态、距离和剩余时间等多元信息有效提高了车速预测模型的预测精度,进而构建了基于信息融合的 PHEV 能量管理策略,以期在 ITS 环境得到局部覆盖后为改善 PHEV 整车经济性提供切实可行的解决方案。

2. 基于实车数据的车速预测模型建立

如图 1 所示为车辆在现实环境中实际的行车路线,从同济大学嘉定校区东南门出发,至真如地铁站结束,全长约 21km 左右,行车数据采集时间主要在上 7:30-9:30,选取其中 30 天的数据作为试验样本进行模型的预测。如图 2 所示为实车运行工况下的车速坡面图,该工况共计运行 2277s,全长约 20.55 km,最高车速为 90.15 km/h,平均行驶车速为 38.35 km/h,最大加速度为 2.73 m/s^2 ,最大减速度为 -3.41 m/s^2 。



图 1 实车数据采集路线




图 2 实际运行工况

2.1 基于指数的车速预测

指数预测（Exponential Prediction, EP）^[15]是假设未来时刻的车速与当前车速满足某种指数关系，如式 1 所示：

$$V'_{t+k} = V_t * (1 + \delta)^k \quad (1)$$

式中 V_t 代表 t 时刻的车速， V'_{t+k} 代表 $t+k$ 时刻时的车速， δ 代表车速衰退因子，当 δ 取 0 时代表车速恒定。由式 1 可知，基于指数的预测方法当前车速对未来车速的影响，此预测方法简单，用到的信息较少，本文会选取不同步长将其预测结果与实际车速进行比较，观察其预测精度。

2.2 基于滑动平均值的车速预测

滑动平均值预测（Exponential Moving Average Prediction, EMAP）方法^[16]考虑了历史车速数据对未来车速的影响，并且不同时刻的历史车速赋予不同的比重，使得历史数据对未来车速的影响随着时间的增长逐渐消失，如式 2、3 所示为基于滑动平均值的预测通式

$$V'_{t+1} = \alpha V_t + \alpha(1 - \alpha)V_{t-1} + \cdots + \alpha(1 - \alpha)^m V_{t-m} + (1 - \alpha)^{m+1} V'_{t-m} \quad (2)$$

$$(V_t^k)' = \alpha(V_t^{k-1})' + (1 - \alpha)(V_{t-1}^k)' \quad (3)$$

如式 2 所示为基于滑动平均值的单步预测方法，其中 V_t 代表 t 时刻的车速， V_{t+1}' 代表 $t+1$ 时刻的车速， α 代表当前车速所占的比重， V_{t-m} 为 $t-m$ 时刻的车速；式 3 所示为基于滑动平均值的多步预测方法， $(V_t^k)'$ 表示在 t 时刻对 $t+k$ 时刻车速的预测值， $(V_t^{k-1})'$ 为 t 时刻对 $t+k-1$ 时刻的预测值， $(V_{t-1}^k)'$ 表示在 $t-1$ 时刻对 $t-1+k$ 时刻车速的预测值。同上本文会选取不同步长将其预测结果与实际车速进行比较，观察其预测精度。

2.3 基于马尔可夫的车速预测

马尔可夫预测（Markov）方法^[17]是一种统计预测方法，针对时间和状态都离散的情况就可称为马尔可夫预测。车辆在行驶过程中车速变化情况被认为是无后续性的条件，即车辆车速满足式 4：

$$P(V_{t+1}|V_t, V_{t-1}, \dots, V_1) = P(V_{t+1}|V_t) \quad (4)$$

通过历史数据可以建立起马尔可夫状态矩阵，并通过求解马尔可夫状态矩阵可以求解出马尔可夫的状态转移过程。同上本文会选取不同步长将其预测结果与实际车速进行比较，观察其预测精度。

2.4 基于深度学习的车速预测

N-BEATS (Neural Basis Expansion Analysis)是由 Bengio 等人提出的用于单变量预测的可释义深度学习网络^[18, 19]，具体结构示意图如图 3 所示：




图 3 N-BEATS 网络结构图^[20]

N-BEATS 网络已被证明在时间序列预测问题上性能优于传统的统计学方法和主流的深

度学习方法，因此本文选择 N-BEATS 通用模型作为未来工况的预测模型，模型的主要参数如表 1 所示，对于回溯窗口小于 3H 的情况，通过置 0 的方式进行补全。同理本文会选取不同步长将其预测结果与实际车速进行比较，观察其预测精度。

表 1 N-BEATS 网络主要训练参数

参数	指标
回溯窗口长度	3H
学习率	1e-4
单次训练样本数	64
栈数	5
每个模块内全连接层参数	{6, 6, 6, 6, 6}
损失函数	RMSE

3. 基于交通流的车速预测模型建立和验证

3.1 车速预测模型建立

车辆可以通过感知雷达、车路通信等手段获取更多的交通信息，这些信息能够帮助车辆掌握更多的未来工况，从而为车辆能量管理策略的设计提供了一定的思路^[21, 22]。本文通过 VISSIM 仿真软件，基于上文对路段的实际调研，在仿真软件中对此路段进行还原，为基于多元信息的预测模型提供数据支撑。

VISSIM 作为模拟交通流的仿真软件，已经广泛应用于车路协同的仿真研究中^[23]，本文根据车辆实际行驶路线在 VISSIM 中建立了对应的仿真路网模型如图 4 所示，其中共包含 98 个子路口（两叉口间的路段），40 个交叉路口，共需标定的车流量输入路口达到 57 处，信号灯配时组 40 处，路口行为概率分布 133 处。由于同路段同时段的车流量统计难度较大，根据相关文献^[23, 24]，路段的车流量和实际运行速度满足式（5）所示的关系：

$$U = \frac{\alpha_1 U_s}{1 + \left(\frac{V}{c}\right)^\beta} \quad \beta = \alpha_2 + \alpha_3 \left(\frac{V}{c}\right)^3 \quad (5)$$




图 4 VISSIM 仿真模型

如式 5 所示， U 代表车辆实际运行速度， km/h ； U_s 代表路段的设计车速， km/h ； V 代表路段的单车道车流量， pcu/h ； C 代表路段的单车道通行能力， pcu/h ； α_1 、 α_2 、 α_3 为经验参数。本文首先通过实际调研得到路段的设计车速，同时确定了路段的单车道通行能力，并通过相关文献^[24, 25]确定经验参数的取值。平均行驶车速的获取主要是通过自编脚本并调用高德地图的 API 接口，再通过式 5 将其转化为路段的车流量数据，然后用实际调研得到的车流量数据对所建立的模型进行修正，如图 5 所示为通过此方法得到的某一时刻的仿真路段的平均车速和车流量标定数据。




图 5 某一时刻交通流量标定数据

信号灯配时通过实际调研的方式获取，具体数据如图 6 所示，并且每一路段的期望行驶车速首先要满足当前路段的车速限制标准，同时以线性概率在一定的范围内随机变化。同时对于交叉路口的通行规律为“右转让直行，直行让左转”。如图 7 所示为某一路段的通行规则设置。




图 6 信号灯配时信息




图 7 交叉口通行规则

此外仿真浮点车跟驰模型选取的是 Wiedemann 心理-生理跟驰模型，此模型考虑到驾驶员不能通过精准的物理模型操控车辆，它强调驾驶员心理安全距离的阈值，能够将驾驶行为分为自由行驶、接近过程、跟驰过程和紧急制动。当驾驶员认为与前车距离过小时，会踩下刹车踏板进行减速；当驾驶员认为与前车距离过大时，会踩下加速踏板缓慢加速，并重复。此交通流模型未考虑行人和非机动车，轿车、重型货车和公交车分别以 90%、4%和 6%的比例分布，同时公交车不涉及到站停车行为。

3.2 车速预测模型验证

在完成对仿真模型的标定之后，进行仿真模型的交通流仿真，如图 8 所示。仿真的前 1000s 模型处于热机状态，目的是让浮点车能够分布在整个路网。热机结束后，再对相应路段的车辆进行追踪，得到了如图 9 所示的车辆运行工况图。



图 8 交通流仿真运行图





图 9 试验路段的仿真工况


由图 9 可知，完整工况的运行时间共 2124s，全长约 19.68 km，最高车速为 79.80 km/h，平均行驶车速为 44.98 km/h，最大加速度为 3.09m/s^2 ，最大减速度为 -3.74m/s^2 ，将其与实车数据进行比较，其最高车速低于实际车速，主要是因为浮点车根据路段的期望车速行驶，车速不会超过道路的车速限制（此处最高限速为 80 km/h），仿真的平均车速与实际平均车速差异主要是在交通流的拥堵程度。

如图 10 所示为不同时段仿真车速与实际车速的对比图，由图 a 可知，实际车速片段 1 与仿真车速片段 2、3 相对应，可以推测片段 1 在 50-76s 通过了交叉路口且在到达信号灯前经历了信号灯从红灯变为绿灯的情况，所以仅有减速过程并未停车。同时图 b 中实际车速片


段 2 与仿真车速片段 2、3、4、5 相对应，实际车速片段 2 代表车辆连续经过三个信号灯路口但并未停车等待。图 c 中实际车速片段 1、2 和仿真车速片段 1、2 拟合度较好，实际片段 3 可以与仿真片段 3、4 相对应。



a. 0-480s 仿真片段与实际片段对比图



b. 826~1209 s 仿真片段与实际片段对比图



c. 1224~1701 s 仿真片段与实际片段对比图

图 10 不同时段仿真车速与实际车速对比图

由以上的分析可以得到，建立的仿真模型能够较为真实的还原车辆在实际道路上行驶时

的工况变化,且车辆的仿真速度片段与实际速度片段契合度比较高。因此可以使用在 VISSIM 中搭建的仿真模型近似代替真实情况,通过获取前车信息、信号灯信息等多元信息来得到更加准确的车速预测模型。

4. 车速预测结果分析

4.1 无信息的车速预测结果

为了衡量车速预测模型的准确性,本文选取某一天的实车数据作为测试集,分别对预测时域为 1s、5s 和 10s 不同情况下不同方法进行比较。同时预测效果的评价指标选择均方根误差 (Root Mean Square Error, RMSE),其中单步、多步预测的 RMSE 可分别由式 6、7 得到。

$$RMSE_{1Step} = \sqrt{\frac{\sum_n (V_{real} - V_{predict})^2}{n}} \quad (6)$$

$$RMSE_{MultiStep} = \overline{RMSE} = \frac{\sum_{Horizon} RMSE_{HStep}}{Horizon}$$

(7)

4.1.1 单步预测

如图 11 所示为预测时长为 1s 时,经指数、滑动平均值、马尔可夫和深度学习方法预测的车速和实际车速的分布图,从图中可以看出,由于时间的限制,车速在 1s 内的变化有限,四种方法的车速预测结果都较好。其中指数预测^[26]和滑动平均值预测效果受到衰退因子 δ 和权重系数 α 的影响,此次指数预测的衰退因子 δ 为-0.002,滑动平均值预测的权重系数 α 为 1.5。同时对于马尔可夫预测预测结果,其在处理之前需对变量进行离散处理,使得预测结果呈现明显阶梯化、拟合度不足,基于 N-BEATS 的预测方法预测车速与实际车速的整体重合度最高,但在车速为 0 的怠速段效果稍差于指数和滑动平均值预测方法。

如表 2 为单步预测的具体结果,预测效果依次排序为 N-BEATS>EMAP>EP>Markov,基于深度学习的预测方法平均均方根误差为 1.884 km/h,相较于指数、滑动平均值、马尔可夫链,预测精度分别提高 28.12%、15.15%和 35.50%。




图 11 单步预测结果

表 2 单步预测结果 RMSE (km/h)

1	EP_-0.002	EMAP_1.5	Markov	N-BEATS
<i>RMSE</i>	2.621	2.274	2.921	1.884

4.1.2 五步预测

图 12 所示为预测时域为 5s 时不同方法的预测结果，其中，指数预测的衰退因子取值 -0.005，滑动平均值预测的权重因子取为 1.2。因为衰退因子为负数，即认为未来车速与当前车速呈指数衰减的趋势，此预测方法结果单一，加速过程中效果较差。而滑动平均值预测^[27]方法中未来时刻的车速变化情况符合当前车速的变化趋势，其预测效果优于指数预测。对于马尔可夫链^[28]的预测，其满足统计学规律，其在相同车速的加速和减速过程中，预测结果一样，导致预测曲线和实际曲线重合度最差。对于深度学习的预测效果与实际情况基本符合，仅当车辆从怠速工况转入加速工况时，预测效果稍有欠缺。

如表 3 所示为五步预测的具体结果，预测效果依次为 N-BEATS>EMAP>EP>Markov，与单步预测结果相同。相较于其它三种方法，使用深度学习进行车速预测后预测精度分别提高 24.22、18.35 和 28.38%，相较于单步预测 N-BEATS，精度降低 147.93%。




图 12 五步预测结果

表 3 五步预测结果 RMSE (km/h)

5	EP_-0.005	EMAP_1.2	Markov	N-BEATS
$\overline{RMSE}$	6.164	5.721	6.522	4.671

4.1.3 十步预测

如图 13 所示为预测时域为 10s 时不同预测方法的预测结果，其中指数预测的衰退因子取为-0.007，滑动平均值预测的权重系数取为 1.1。指数预测的结果仅在高车速刹车及怠速停机情况下估计较为准确，其余情况预测效果均较差。滑动平均值预测结果的整体变化趋势与实际值相吻合，但对未来工况的变化程度预测均偏小，且在预测初期出现了严重的车速漂移现象。基于马尔可夫链的预测效果最差，预测结果呈现明显的阶梯状变化趋势，不能较好地反映车速的动态变化过程。基于深度学习的预测方法整体预测效果最好，对未来时段内车速的变化估计较为准确，尤其是在加速或减速的初始阶段吻合度最高，在怠速及加速度较小的区域内效果有所欠缺。

表 4 给出了十步预测时各方法的平均均方根误差，预测效果仍与之前相同，依次为 N-BEATS>EMAP>EP>Markov，相较于其它方法，基于深度学习的预测方法预测精度分别提高 18.04、15.27 和 23.25%，相较于五步预测 N-BEATS，预测精度降低 67.89%。





图 13 十步预测结果

表 4 十步预测结果 RMSE (km/h)

10	EP_-0.007	EMAP_1.1	Markov	N-BEATS
$\overline{RMSE}$	9.568	9.255	10.217	7.842

4.2 单、多元信息融合车速预测

在使用 VISSIM 进行仿真时，可以调用 COM 接口以获取目标车的前车信息和信号灯状态^[29]，本文通过自编脚本的方式跟踪了前车车速、车距以及当前信号灯的状态、状态剩余时间和和信号灯的距離，用来模拟真实环境下使用车联网或雷达等设备获得到的多元信息。






图 14 仿真环境下前车、信号灯信息

如图 14 所示为仿真环境下前车、信号灯信息。其中前车的检测距离阈值为 250m。信号灯的检测距离阈值为 200m，红灯、绿灯、黄灯所对应的状态码为 3，1，4，当状态码为 0 时表示检测距离内未出现信号灯。

为了对比驾驶前车、信号灯信息对车速预测的影响，本文在上述的 N-BEATS 的基础上加入了多元信息，保证其中参数不变，在不同预测步长下单输入变量（即历史车速）与多输入变量（即历史车速、前车车距、车速、信号灯状态、信号灯间距、信号灯剩余时间）N-BEATS 模型的预测效果。

4.2.1 单步预测




图 15 单步预测结果

图 15 所示为单步预测下实际车速与仿真车速的对比，从图中可以看出，在单输入变量的情况下，仿真车速总是低于实际车速，而在加入多元信息之后，预测值与实际值的重合度更高，仅有些时刻会出现实际值稍高的情况^[30]。

4.2.2 五步预测




图 16 五步预测结果

图 16 所示为五步预测下实际车速与仿真车速的对比，从图中可以看出，在引入多元信息后，使得车辆在加速和减速过程中预测更加准确，但在车辆匀速过程中可能会出现多余的急减速预测部分，这主要是因为突然出现的前车信息导致预测结果产生了偏差，但这种误差可以通过增加训练样本来避免^[31]。

4.2.3 十步预测




图 17 十步预测结果

图 17 所示为十步预测下实际车速与仿真车速的对比，从图中可以看出，加入多元信息后，模型在怠速段预测不准的问题得到了显著的改善，这主要归因于引入了信号灯信息，使得红灯状态下模型可识别出车辆可能处于停车状态，并根据信号灯剩余时间掌握车辆未来的

车速变化趋势。

表 5 单输入和多输入 N-BEATS 模型 RMSE (km/h)

预测时间窗 (s)	EMAP	单输入	多输入	改善率 (%)	
		N-BEATS	N-BEATS	EMAP	单输入
1	4.120	3.340	2.863	30.51	14.28
5	8.763	6.943	5.989	31.66	13.74
10	12.967	10.544	8.713	32.81	17.19

表 5 给出了不同预测时间下滑动平均值预测、单输入 N-BEATS 和多输入 N-BEATS 预测模型的 RMSE，可以看出引入多元信息后模型预测精度有较明显的改善，且改善率随预测时域的增加而增大。相较于滑动平均值预测 EMAP，多输入 N-BEATS 模型预测精度提升率均大于 30%，而相较于单输入 N-BEATS 模型，预测精度的改善率也均大于 10%。随着预测时域的增大，预测精度的衰减率依次为 109.19%、45.48%和 54.03%。对于模型预测型能量管理策略而言，模型预测精度越高，所得到的优化效果越好，但同时预测时间越长，最终得到的结果越接近全局最优结果。

5 结论

在本文中，提出了一种基于多元信息融合的车速预测模型，首先基于实车数据建立了车速预测模型，通过指数、滑动平均值、马尔可夫链和 N-BEATS 在不同预测步长下对车速进行预测，结果发现在不同预测步长下均发现预测效果为 N-BEATS>EMAP>EP>Markov，且 N-BEATS 的预测精度相较于其它方法都有不同程度的提高。其次，为获取前车车速、车距、信号灯状态、距离和剩余时间等多元信息，本文以实际路测数据为核心，结合高德地图开发接口在 VISSIM 软件中搭建了试验路段的微观交通流仿真模型，使用试验数据验证了仿真结果的有效性，并通过自编脚本的方式建立了与仿真软件间的通信，获取了仿真环境下的驾驶工况及多元信息，随后在不同预测时域内比较了基于指数、滑动平均值、马尔可夫链和 N-BEATS 深度学习模型的预测效果，其中当模型输入仅为历史车速序列时，基于深度学习的预测模型可提高至少 15%的预测精度，而在引入多元信息之后，该模型的预测结果更加稳定，相较传统预测方法和单一输入变量的深度学习模型，在仿真工况下预测精度可分别提高约 30%和 13%以上。

参考文献：

[1] HU Z Y, LU Z Y, ZHANG H C, et al. Effect of oxidation temperature on oxidation reactivity and

- nanostructure of particulate matter from a China VI GDI vehicle [J]. *Atmos Environ*, 2021, 256(9).
- [2] LUO Y, WU Y, LI B, et al. Development and application of fuel cells in the automobile industry [J]. *Journal of Energy Storage*, 2021, 42(103124).
- [3] WANG Z, WEI L, ZHANG X, et al. Impact of demographic age structure on energy consumption structure: Evidence from population aging in mainland China [J]. *Energy*, 2023, 273(127226).
- [4] HUANG R, ZHANG S, WANG P. Key areas and pathways for carbon emissions reduction in Beijing for the “Dual Carbon” targets [J]. *Energy Policy*, 2022, 164(112873).
- [5] ZHENG P, PEI W, PAN W. Impact of different carbon tax conditions on the behavioral strategies of new energy vehicle manufacturers and governments - A dynamic analysis and simulation based on prospect theory [J]. *Journal of Cleaner Production*, 2023, 407(137132).
- [6] YE Y, ZHANG J, PILLA S, et al. Application of a new type of lithium-sulfur battery and reinforcement learning in plug-in hybrid electric vehicle energy management [J]. *Journal of Energy Storage*, 2023, 59(106546).
- [7] YANG C, LU Z, WANG W, et al. Energy management of hybrid electric propulsion system: Recent progress and a flying car perspective under three-dimensional transportation networks [J]. *Green Energy and Intelligent Transportation*, 2023, 2(1): 100061.
- [8] ZHANG H, PENG J, DONG H, et al. Hierarchical reinforcement learning based energy management strategy of plug-in hybrid electric vehicle for ecological car-following process [J]. *Applied Energy*, 2023, 333(120599).
- [9] NADER W B, CHAMOUN J, DUMAND C. Optimization of the thermodynamic configurations of a thermoacoustic engine auxiliary power unit for range extended hybrid electric vehicles [J]. *Energy*, 2020, 195(116952).
- [10] ZHANG Z, ZHANG T, HONG J, et al. Energy management strategy of a novel parallel electric-hydraulic hybrid electric vehicle based on deep reinforcement learning and entropy evaluation [J]. *Journal of Cleaner Production*, 2023, 403(136800).
- [11] LI M, XU H, LI W, et al. The structure and control method of hybrid power source for electric vehicle [J]. *Energy*, 2016, 112(1273-85).
- [12] QUAN S, WANG Y-X, XIAO X, et al. Real-time energy management for fuel cell electric vehicle using speed prediction-based model predictive control considering performance degradation [J]. *Applied Energy*, 2021, 304(117845).
- [13] BARODI A, ZEMMOURI A, BAJIT A, et al. Intelligent Transportation System Based on Smart Soft-Sensors to Analyze Road Traffic and Assist Driver Behavior Applicable to Smart Cities [J]. *Microprocessors and Microsystems*, 2023, 100(104830).
- [14] LI Z, GONG C, LIN Y, et al. Continual Driver Behaviour Learning for Connected Vehicles and Intelligent Transportation Systems: Framework, Survey and Challenges [J]. *Green Energy and Intelligent Transportation*, 2023, 100103.
- [15] DING W, LI J, MAO W, et al. Rolling bearing remaining useful life prediction based on dilated causal convolutional DenseNet and an exponential model [J]. *Reliability Engineering & System Safety*, 2023, 232(109072).
- [16] ARROUCH I, AHMAD N S, GOH P, et al. Close Proximity Time-to-collision Prediction for Autonomous Robot Navigation: An Exponential GPR Approach [J]. *Alexandria Engineering Journal*, 2022, 61(12): 11171-83.
- [17] GUAN H, WANG H, MENG Q, et al. Markov chain-based traffic analysis on platooning effect among mixed semi- and fully-autonomous vehicles in a freeway lane [J]. *Transportation Research Part*

B: Methodological, 2023, 173(176-202.

- [18] ZHANG D, WANG C, WEI Y, et al. Analysis of motion interference characteristics of underwater vehicles salvo based on the RBF Neural Network [J]. Ocean Engineering, 2023, 277(114254.
- [19] OLIVARES K G, CHALLU C, MARCJASZ G, et al. Neural basis expansion analysis with exogenous variables: Forecasting electricity prices with NBEATSx [J]. International Journal of Forecasting, 2023, 39(2): 884-900.
- [20] LIANG S, ZHAO Y, MENG C, et al. Method for predicting gross domestic product (GDP) based on neural basis expansion analysis for interpretable time series forecasting (N-BEATS), involves obtaining trained N-BEATS model, and using trained N-BEATS model to predict GDP to be predicted based on original GDP data set, CN114298411-A [P/OL]. <Go to ISI>://DIIDW:2022618455.
- [21] SHUNMUGA PERUMAL P, WANG Y, SUJASREE M, et al. LaneScanNET: A Deep-Learning Approach for Simultaneous Detection of Obstacle-Lane States for Autonomous Driving Systems [J]. Expert Systems with Applications, 2023, 120970.
- [22] ZHANG Z, LIU W, ZHANG F. On the joint network equilibrium of parking and travel choices under mixed traffic of shared and private autonomous vehicles [J]. Transportation Research Part C: Emerging Technologies, 2023, 153(104226.
- [23] KUČERA T, CHOCHOLÁČ J. Design of the City Logistics Simulation Model Using PTV VISSIM Software [J]. Transportation Research Procedia, 2021, 53(258-65.
- [24] YAN M, LI G, LI M, et al. Hierarchical predictive energy management of fuel cell buses with launch control integrating traffic information [J]. Energy Conversion and Management, 2022, 256(115397.
- [25] LIU Y, ZHAO J, LI S, et al. Adaptive energy management for plug-in hybrid electric vehicles considering real-time traffic information [J]. IFAC-PapersOnLine, 2021, 54(10): 138-43.
- [26] LI X, WANG P, WANG J, et al. State of health estimation and prediction of electric vehicle power battery based on operational vehicle data [J]. Journal of Energy Storage, 2023, 72(108247.
- [27] MA W, HE Z, WANG L, et al. Active traffic management strategies for expressways based on crash risk prediction of moving vehicle groups [J]. Accident Analysis & Prevention, 2021, 163(106421.
- [28] LIN X, ZHANG G, WEI S. Velocity prediction using Markov Chain combined with driving pattern recognition and applied to Dual-Motor Electric Vehicle energy consumption evaluation [J]. Applied Soft Computing, 2021, 101(106998.
- [29] ZHOU Z, YANG Z, ZHANG Y, et al. A comprehensive study of speed prediction in transportation system: From vehicle to traffic [J]. iScience, 2022, 25(3): 103909.
- [30] ZHANG H, ZOU Y, YANG X, et al. A temporal fusion transformer for short-term freeway traffic speed multistep prediction [J]. Neurocomputing, 2022, 500(329-40.
- [31] QIU Z, ZHU T, JIN Y, et al. A graph attention fusion network for event-driven traffic speed prediction [J]. Information Sciences, 2023, 622(405-23.