

doi: 10.11835/j.issn.1000-582X.2021.118

基于 DK 聚类模型的多工况速度预测器

马荣鸿¹, 许家敏¹, 李进², 袁洪根², 张财志¹

(1. 重庆大学机械与运载工程学院, 重庆 400044; 2. 重庆宗申氢能动力科技有限公司, 重庆 400054)

摘要: 车辆速度预测能为新能源汽车的能量管理策略提供重要的信息, 但要准确地预测车速存在诸多困难。为克服交通状况、车辆类型和驾驶员意图等确定或随机因素对车速预测造成干扰的问题, 提出了一种基于 DK (DTW-based K-means) 聚类模型的多工况速度预测器, 该预测器通过 DK 模型对车速序列进行工况划分, 并结合一维卷积神经网络和长短期记忆神经网络预测各工况下的未来车速。基于所提出的预测器, 讨论了不同的输入序列长度及聚簇数对该预测器的影响, 并比较了该预测器与其他常用模型的性能。结果表明, 该预测器具有较好的多工况适应性, 预测精度比其他模型更高。

关键词: 预测车速; 聚类; 多工况; 一维卷积神经网络; 长短期记忆神经网络

中图分类号: U279

文献标志码: A

文章编号: 1000-582X(2023)04-001-12

A multi-condition speed predictor based on a DK clustering model

MA Ronghong¹, XU Jiamin¹, LI Jin², YUAN Honggen², ZHANG Caizhi¹

(1. College of Mechanical and Vehicle Engineering, Chongqing University, Chongqing 400044,

P. R. China; 2. Chongqing Zongshen Hydrogen Energy Power Technology Co., Ltd.,

Chongqing 400054, P. R. China)

Abstract: Vehicle speed prediction provides important information for the energy management strategy of new energy vehicles, but accurate vehicle speed prediction is challenging. In order to overcome the interference of deterministic or stochastic factors, e.g., the driving condition, driver's intention and vehicle type, in this paper, a multi-condition speed predictor is proposed based on a DK (DTW-based K-means) clustering model. The speed predictor splits the vehicle speed sequences into different driving conditions by the DK clustering model, and the future vehicle speeds under different driving conditions are predicted by the sub-predictor which combines one-dimensional convolutional neural network (conv1D) and long short-term memory neural network (LSTM). Based on the proposed predictor, the effects of different input-sequence lengths and the number of clusters on the predictor are discussed. Moreover, the performance of the proposed predictor is compared with other commonly used models. The results show that the proposed predictor has better adaptability to multiple driving conditions,

收稿日期: 2021-03-05 网络出版日期: 2021-06-08

基金项目: 国家自然科学基金资助项目(51806024); 重庆市研究生科研创新项目(CYS19020); 国家重点研发计划资助项目(2018YFB0105703)。

Supported by National Natural Science Foundation of China (51806024), the Graduate Scientific Research and Innovation Foundation of Chongqing, China (CYS19020), and the National Key Research and Development Program (2018YFB0105703).

作者简介: 马荣鸿(1995—), 男, 硕士研究生, 主要从事燃料电池汽车智能化研究, (E-mail) 839936427@qq.com。

通信作者: 张财志, 男, 研究员, 主要从事燃料电池汽车与系统集成研究, (E-mail) czzhang@cqu.edu.cn。

and the prediction accuracy is higher than other models.

Keywords: vehicle speed prediction; clustering; multiple driving conditions; one-dimensional convolutional neural network; long short-term memory neural network

由于全球变暖、环境污染等问题日益凸显,利用车速预测来优化新能源车的能量管理策略正成为当前的研究热点之一^[1]。未来车速中包含着未来行驶工况的信息,同时也能表征驾驶员未来意图等不可观测信息,不少已发表的研究^[2-4]表明,准确的车速预测能够提高汽车燃油经济性和剩余行驶里程,具有重要的应用价值。虽然目前对车速预测的方法已进行了大量的研究,但仍然存在瓶颈和潜在的优化方法。常用的速度预测方法可分为参数模型和非参数模型两种^[5]。Lefèvre等^[6]比较了参数模型与非参数模型在车速预测方面的效果,仿真结果说明参数模型在长期车速预测中表现较差,而非参数模型在短期、长期车速预测中都能保持较好的预测效果。多项研究^[7-8]也表明,非参数模型通常比参数模型具有更好的精度。这是由于非参数模型参数设计是基于数据驱动的,而参数模型是基于数据分布假设预先定义的,应用时会有一定的局限性。先进的非参数模型如递归神经网络RNN(recurrent neural network)及其变体,由于其具有独特的记忆结构设计,比较适合应用于时间序列预测领域^[9-11],同时也是进行车速预测的重要方法。Ruan等^[12]以当前车速、加速踏板开度和变化率、刹车踏板开度为输入,建立了预测精度良好的LSTM(long short-term memory neural network)速度预测模型。Yeon等^[5]基于LSTM网络建立了短期车速预测模型,以过去历史车速、轮速、车前距、GPS位置信息、车辆内部信息为输入,预测未来15 s的车辆速度,同时为有效地找到每个LSTM层的最优隐藏状态数,使用了径向基函数和动态坐标搜索进行超参数优化。然而GPS信号会在诸如桥梁开口、隧道或高架桥下等情况下被屏蔽,因此利用车上可用的数据更合理,成本更低,同时效果也是可接受的^[13]。上述研究中的预测模型都是以多维信息作为输入,可能会涉及多传感器数据融合、冗余等问题,为减少数据处理成本,降低模型复杂度,只依赖一种传感器信息来进行车速预测的模型值得深入研究,但应注意的是并不是所有的传感器信息都适合作为预测模型的单源信息,如只使用轮速来预测车速,在车轮发生打滑、抱死时,预测的车速可能会存在较大的误差。目前大多数研究所提出的预测模型并未考虑到历史速度工况变化对未来车速的影响,或者只根据历史速度工况的某些统计学特征来对历史速度工况进行聚类^[14],如加速度标准差、平均速度等,但这些统计学特征都可由历史速度推导得到,将其作为聚类模型的输入可能无法很好地对历史速度工况进行分类。实际上,历史速度曲线的变化趋势比人为选取的统计学特征包含着更丰富的潜在信息,因此笔者考虑以历史速度曲线变化的相似性作为速度工况聚类的依据,建立聚类模型,为历史速度工况聚类提供新的思路。

综上所述,为减少数据处理成本并提高预测精度,提出了一种仅以历史速度序列为输入的基于DK(DTW-based K-means)聚类模型的多工况速度预测器,该预测器主要由聚类模型和非参数预测模型两部分组成。与常见的根据特征聚类的聚类模型不同,本研究中提出的聚类模型由根据速度曲线的变化趋势聚类的K-means模型构成,为了更好地描述速度序列间的相似性,引入目前在语音识别、签名识别等方面应用较广泛的DTW(dynamic time warping)算法^[15]作为速度序列的相似性度量方法。非参数预测模型主要由一维卷积神经网络conv1D(one-dimensional convolutional neural network)与LSTM网络构成,简称conv1D-LSTM模型。所提出的多工况速度预测器先根据历史速度序列的变化趋势,由DK聚类模型划分到特定的簇中,每个簇表示一种速度工况,每种工况都对应着一个conv1D-LSTM子模型,然后通过该子模型预测未来速度序列。多工况速度预测器考虑到各种速度工况,并结合conv1D可捕获局部高维数据特征与LSTM网络可提取时间序列关联性的优点,完成对未来速度序列的预测。

1 数据集及数据处理

用于模型训练和测试的数据集来源于公共数据集 Comma2k19,该数据集记录了通勤车在加州 280 高速公路上行驶超过 33 h 的各项行驶数据。从 Comma2k19 数据集中随机选择了约 200 min 的连续行驶数据来训练及验证本模型。在对原始数据集进行数据清洗后,按照时间维度将前 60% 的数据划分为模型的训练集,紧接着的 20% 作为验证集,剩下的 20% 作为测试集。测试集的速度曲线如图 1 所示,包含有加速、减速、停车、平稳等不同的速度工况,表明该测试集能较好地检验在多种速度工况下速度预测器的性能。为获得多工况速度预测器的输入,以滑动步长为 1、时间跨度为 4 的滑动窗口对数据集进行分割,得到多个等长的历史速度输入序列。此外,考虑到预测的速度序列的时间跨度过长会导致模型预测精度降低,将预测的速度序列的时间跨度设置为 $2\text{ s}^{[6]}$ 。本研究中所有模型的训练与测试均在同一硬件平台上进行,处理器为 Intel i5-7400,内存为 16 GB,显卡为 NVIDIA 1050TI 4G,使用 Pytorch 搭建网络模型框架。

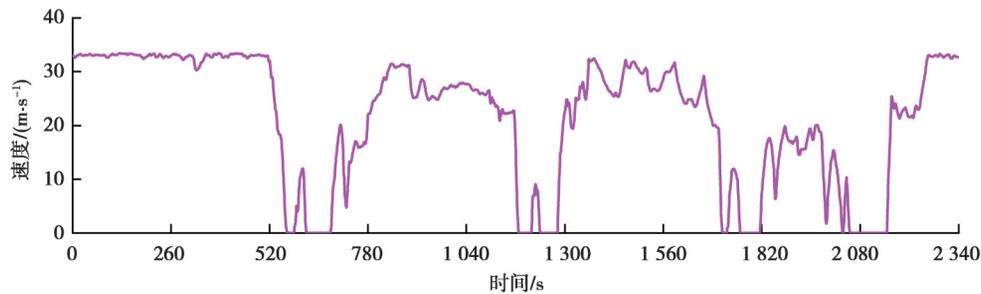


图 1 测试集速度曲线

Fig. 1 The speed curve of the test set

2 多工况速度预测器

车辆的未来速度会随着历史速度工况不同而发生变化。因此,如果使用单速度工况预测器来预测多个驾驶周期内车辆的未来速度,则在某些速度工况下预测器的性能可能会下降。提出基于 DK 聚类模型的多工况速度预测器来解决这一问题。预测器的整体设计框架如图 2 所示,主要由 DK 聚类模型与非参数预测模型两大部分构成。DK 聚类模型负责速度工况的分类;非参数预测模型由多个 conv1D-LSTM 子模型组成,负责特定速度工况下未来速度的预测。预测速度前,首先要对输入的历史速度序列进行标准化处理,接着 DK 聚类模型根据输入序列的变化趋势特征进行簇划分,得到簇标签后,再将未经标准化处理的原始速度序列直接输入到簇标签所对应的 conv1D-LSTM 子模型中进行速度序列预测。显然,连续预测速度序列会产生重复预测的数据,因此,多工况速度预测器的最终未来速度序列输出由重叠部分取算术平均值后得到。下面将详细介绍该速度预测器的设计。

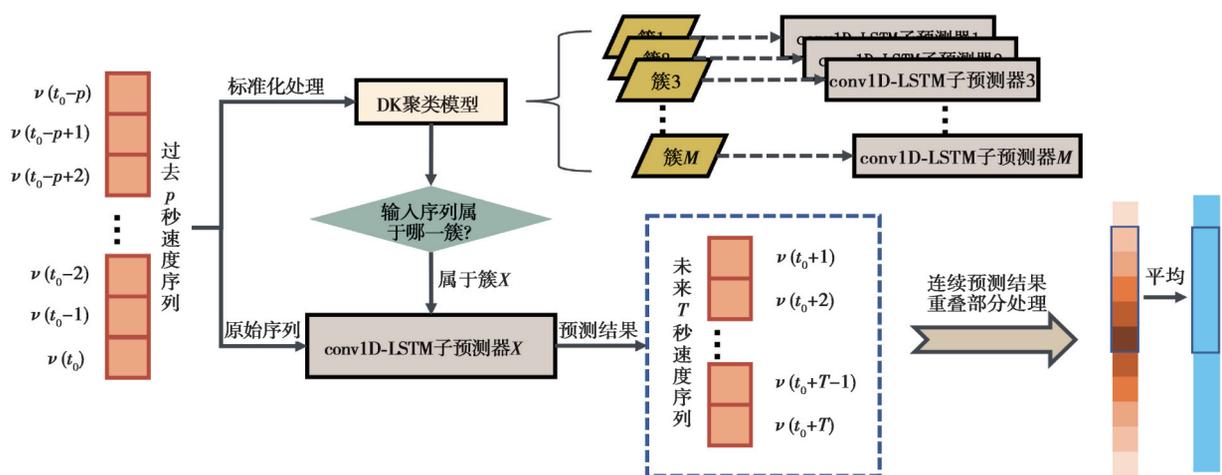


图 2 基于 DK 聚类模型的多工况速度预测器框架图

Fig. 2 The structure of multi-conditions speed predictor based on the DK clustering model

2.1 基于DTW的K-means聚类模型

K-means是一种经典的基于迭代求解的非监督聚类算法^[17]。对于一个给定的数据集,K-means聚类模型根据样本之间的距离将数据集划分成多个簇,优化目标是 minimized 同簇样本点与其聚类中心之间距离的平方和。在时间序列聚类中,由于不能将时间序列简单地视为高维特征向量,在求解时间序列相似度问题时,首先应明确两个时间序列的相似性度量标准。欧氏距离是一种比较直接的相似性度量标准。然而,由于时间序列具有高度异质性,如采集传感器中的噪声值、缺失值、异常值等,时间序列可能会被扭曲。在这种情况下,基于欧氏距离的聚类模型适应性较差^[18]。DTW (dynamic time wrapping) 距离是度量两个时间序列之间相似性的常用算法之一^[19],其通过适当的尺度变换和非线性变形对两个序列上的数据点进行匹配,可较好地减少时间移位和扭曲的影响,因此适用于速度序列的相似性度量。

给定2个长度分别为 n 与 m 的速度序列 $\mathbf{v}_a = \{v_{a1}, v_{a2}, \dots, v_{an}\}$ 与 $\mathbf{v}_b = \{v_{b1}, v_{b2}, \dots, v_{bm}\}$,构建 $n \times m$ 的局部距离矩阵 \mathbf{C} 如下:

$$\mathbf{C} = \begin{bmatrix} \text{dist}(v_{a1}, v_{b1}) & \dots & \text{dist}(v_{a1}, v_{bm}) \\ \vdots & \text{dist}(v_{ai}, v_{bj}) & \vdots \\ \text{dist}(v_{an}, v_{b1}) & \dots & \text{dist}(v_{an}, v_{bm}) \end{bmatrix} \quad (1)$$

式中: $\text{dist}(v_{ai}, v_{bj})$ 表示 v_{ai} 与 v_{bj} 之间的欧氏距离, $i=1,2,\dots,n,j=1,2,3,\dots,m$ 。以 w_k 表示 v_{ai} 与 v_{bj} 之间的映射关系, $k=1,2,\dots,K$,则序列 \mathbf{v}_a 与序列 \mathbf{v}_b 间的一条翘曲路径 $\mathbf{w} = \{w_1, w_2, \dots, w_k, \dots, w_K\}$ 需同时满足以下条件:

$$\text{s.t.} \begin{cases} \max\{m, n\} \leq K \leq m + n - 1, \\ w_1 = (1, 1), w_K = (m, n), \\ \text{对于 } w_k = (p, q), w_{k'} = (p', q'), \text{ 应有 } 0 \leq p - p' \leq 1, 0 \leq q - q' \leq 1. \end{cases} \quad (2)$$

式中: p, p' 为 \mathbf{v}_a 上的元素点, q, q' 为 \mathbf{v}_b 上的元素点, $k' = k + 1$ 。

在所有满足条件(2)的翘曲路径中,存在一条使翘曲成本最小的最优路径,将其定义为:

$$\text{DTW}(\mathbf{v}_a, \mathbf{v}_b) = \sqrt{\sum_{k=1}^K w_k / K} \quad (3)$$

为求解公式(3),使用动态规划构造一个累积成本矩阵 \mathbf{R} :

$$\mathbf{R}(i, j) = \text{dist}(v_{ai}, v_{bj}) + \min\{\mathbf{R}(i, j-1), \mathbf{R}(i-1, j), \mathbf{R}(i-1, j-1)\}, \quad (4)$$

则 $\mathbf{R}(n, m)$ 即为序列 \mathbf{v}_a 与序列 \mathbf{v}_b 的最短DTW距离。

DBA(DTW barycenter averaging)算法^[20]是Petitjean等提出的一种基于DTW距离求解平均序列的启发式全局优化算法。DBA算法通过计算每个序列样本与待优化的平均序列之间的DTW距离来找到坐标之间的关联,然后对待优化的平均序列上的每个点进行迭代更新,最终得到高质量的平均序列。DK聚类模型根据输入序列与各簇的平均序列之间的DTW距离大小来决定将该输入序列划分到哪一簇,最终达到聚类的目的。

2.2 conv1D-LSTM模型

DK聚类模型根据输入的历史速度序列的变化趋势特征将其划分到不同的簇,每个簇都是一个子数据库,用于训练各簇所对应的conv1D-LSTM子模型,将各簇的conv1D-LSTM子模型组合起来即可得到高度适应各种速度工况的混合速度预测器。具体而言,本研究中提出的conv1D-LSTM模型是一个由conv1D网络和LSTM网络构成的序列到序列的多步速度预测模型,该模型的输入与输出都是速度序列,其输出的速度序列由多步迭代预测得到。虽然卷积神经网络一般都应用于图像处理领域,但近年来多项研究表明,卷积神经网络在空间层面上捕获水平相关信息的能力可为预测模型提供丰富的横向信息,在多个时间序列预测领域中也具有较好的效果^[21-25]。但由于卷积神经网络无法学习点与点之间的时间关联性,使用卷积神经网络构建时间序列预测模型时,一般要结合LSTM网络进行设计。

LSTM网络是Hochreiter等^[26]在RNN网络的基础上提出的一种改进的神经网络,由输入层、隐含层和输出层组成。LSTM网络的基本单元结构如图3所示,隐含层包含多个相同的基本构成单元,每个单元对应输

入序列中某个点。得益于单元中输入门、输出门和遗忘门的三门设计,LSTM网络能够学习时间维度上长期的信息特征。给定LSTM网络的输入、输出序列分别为 $\mathbf{x}=\{\mathbf{x}_1,\mathbf{x}_2,\dots,\mathbf{x}_n\}$ 和 $\mathbf{h}=\{\mathbf{h}_1,\mathbf{h}_2,\dots,\mathbf{h}_m\}$ 。当前时刻 t 的遗忘部分由输入 \mathbf{x}_t 、上一个时刻的细胞状态 \mathbf{C}_{t-1} 以及中间输出 \mathbf{h}_{t-1} 共同决定;输入部分由输入门决定,如果输入门处于开启状态,则允许输入层信号进入,否则不允许;中间输出 \mathbf{h}_t 由遗忘门决定。计算方法如下:

$$\mathbf{f}_t = \sigma(\mathbf{W}_{fx}\mathbf{x}_t + \mathbf{W}_{fh}\mathbf{h}_{t-1} + \mathbf{b}_f), \quad (5)$$

$$\mathbf{i}_t = \sigma(\mathbf{W}_{ix}\mathbf{x}_t + \mathbf{W}_{ih}\mathbf{h}_{t-1} + \mathbf{b}_i), \quad (6)$$

$$\mathbf{g}_t = \varnothing(\mathbf{W}_{gx}\mathbf{x}_t + \mathbf{W}_{gh}\mathbf{h}_{t-1} + \mathbf{b}_g), \quad (7)$$

$$\mathbf{o}_t = \sigma(\mathbf{W}_{ox}\mathbf{x}_t + \mathbf{W}_{oh}\mathbf{h}_{t-1} + \mathbf{b}_o), \quad (8)$$

$$\mathbf{C}_t = \mathbf{g}_t \odot \mathbf{i}_t + \mathbf{W}_{oh}\mathbf{h}_{t-1} + \mathbf{b}_o, \quad (9)$$

$$\mathbf{h}_t = \varnothing(\mathbf{C}_t) \odot \mathbf{o}_t. \quad (10)$$

式中: \odot 表示向量中的元素按位相乘; σ 表示sigmoid函数; \varnothing 表示tanh函数; \mathbf{f}_t 、 \mathbf{i}_t 、 \mathbf{g}_t 、 \mathbf{o}_t 、 \mathbf{h}_t 、 \mathbf{C}_t 分别表示遗忘门、输入门、输入节点、输出门、中间输出和细胞状态; \mathbf{W}_{fx} 、 \mathbf{W}_{fh} 、 \mathbf{W}_{ix} 、 \mathbf{W}_{ih} 、 \mathbf{W}_{gx} 、 \mathbf{W}_{gh} 、 \mathbf{W}_{ox} 、 \mathbf{W}_{oh} 分别表示相对应门与输入 \mathbf{x}_t 或与中间输出 \mathbf{h}_t 相乘的权值矩阵; \mathbf{b}_f 、 \mathbf{b}_i 、 \mathbf{b}_g 、 \mathbf{b}_o 为相对应门的偏置项。

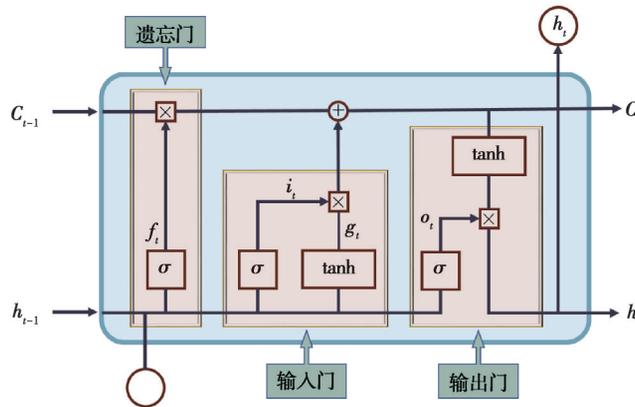


图3 LSTM隐含层的基本单元结构

Fig. 3 The basic unit structure of LSTM hidden layer

conv1D-LSTM模型的具体设计结构如图4所示。训练过程中,模型输入的数据形状为 (B, C, L) ,其中 B 为批大小,即每次输入到conv1D-LSTM模型中的样本数量; C 是输入数据的通道数,由于输入是一个速度序列,因此 C 设置为1; L 为输入的历史速度序列的长度。conv1D-LSTM模型由主要由3个一维卷积层以及1个LSTM层组成。考虑到输入的速度序列长度较短,只有4个数据点,因此每个卷积层中的卷积核大小都设置为2,滑动步长设置为1。为了使模型能够较好地捕获数据的高维特征,卷积核个数逐层递增,分别设置为4、8和16。此外,为避免出现过拟合现象,在每一个卷积层后都设有随机失活层^[27]。将最后的一维卷积层的输出结果展平,并输入到单层LSTM网络,其隐含层维度设置为128,然后将单层LSTM网络与全连接层连接,得到conv1D-LSTM模型的中间输出。为进一步提高速度序列预测的精度,conv1D-LSTM模型的预测结果由多步迭代预测得到^[28],其核心设计思想是通过单点多步迭代预测来获得完整的速度预测序列。输入的历史速度序列通过一维卷积层、LSTM网络层和全连接层后,得到下一时刻的预测速度点,将该预测速度点插入到输入序列的尾部,并移除输入序列头部的速度点,在预测下一时刻速度时,则以更新后的历史速度序列作为输入,如此进行迭代预测,直至得到完整的预测速度序列。该过程如式(11)~(13)所示:

$$\mathbf{v}_{\text{pred}}(t_0+1) = f[\mathbf{v}(t_0-p), \mathbf{v}(t_0-p+1), \mathbf{v}(t_0-p+2), \dots, \mathbf{v}(t_0)], \quad (11)$$

$$\mathbf{v}_{\text{pred}}(t_0+2) = f[\mathbf{v}(t_0-p+1), \mathbf{v}(t_0-p+2), \mathbf{v}(t_0-p+3), \dots, \mathbf{v}(t_0), \mathbf{v}_{\text{pred}}(t_0+1)], \quad (12)$$

$$\mathbf{v}_{\text{pred}} = \{\mathbf{v}_{\text{pred}}(t+1), \mathbf{v}_{\text{pred}}(t+2), \dots, \mathbf{v}_{\text{pred}}(t+T)\}. \quad (13)$$

式中: t_0 表示当前时刻; v_{pred} 表示每次迭代预测得到的速度点; 速度采样频率为 1 Hz, 则 $v(t_0 - p)$, $v(t_0 - p + 1)$, $v(t_0 - p + 2)$, \dots , $v(t_0)$ 表示前 $\{p\}$ s 的历史速度序列; v_{pred} 为预测的未来 $\{T\}$ s 的速度序列。本研究中的预测器是利用历史 4 s 的速度序列来预测未来 2 s 的速度序列, 因此 p 、 T 分别为 4 s 和 2 s。

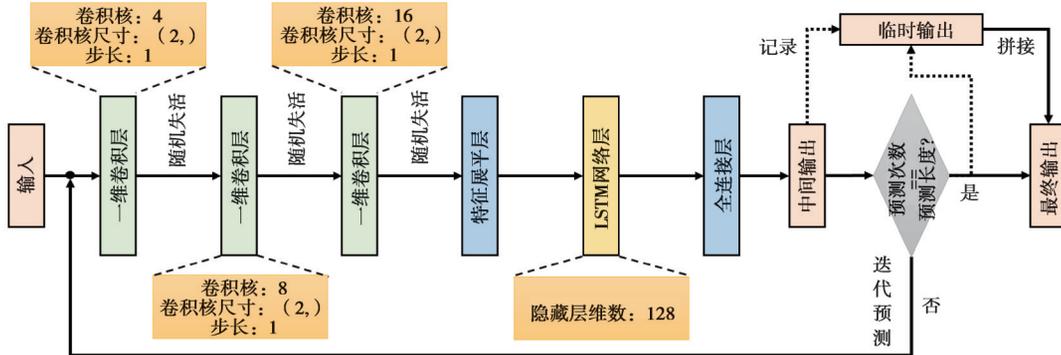


图4 序列到序列的 conv1D-LSTM 多步速度预测器的结构图

Fig. 4 The structure of Sequence-to-sequence conv1D-LSTM multi-step speed predictor

3 实验结果及分析

3.1 聚类模型参数优化及讨论

输入的历史速度序列长度 L 和聚簇数 M 的设置会对 DK 聚类模型的性能产生影响, 从而进一步影响多工况速度预测器的准确性。DK 聚类模型经过多轮训练后, 根据 DBA 算法可得到各簇优化后的平均序列, 各簇内的速度序列样本与该簇的平均序列具有相似的变化趋势。虽然较大的 M 可以使簇内样本之间的相关性更高, 但簇间样本的差异性会变小^[14], 进而带来过度分类的风险。此外, 训练时间成本也是一个值得关注的问题, 因为更大的 M 意味着需要训练大量的 conv1D-LSTM 子模型。 L 是另一个影响 DK 聚类模型性能的重要参数。较小的 L 很难全面地描述历史速度信息和获得未来速度的变化趋势, 但过大的 L 也会增加训练成本, 因为较长的历史速度序列会包含更多的潜在信息, 但有些信息可能是冗余的, 使模型难以训练。因此, 正确设置输入序列长度 L 和聚簇数 M 是非常有必要的。为研究 (L, M) 参数组合对 DK 聚类模型聚类效果的影响, 构建关于 L 和 M 的 8×8 参数扫描矩阵(其中 L 和 M 的初始值均为 3, 递增步长均为 1), 在其他参数相同的情况下, 根据矩阵对 L 和 M 的取值进行参数扫描。评估指标采用平均绝对误差 MAE:

$$\text{MAE} = \frac{1}{Y} \sum_{i=1}^Y \sum_{j=1}^T |v_{i,\text{pred}}(t_0 + j) - v_i^*(t_0 + j)| \quad (14)$$

式中: Y 为所有速度序列样本总数; $v_{i,\text{pred}}(t_0 + j)$ 表示第 i 个预测序列的 j 时刻的速度值; $v_i^*(t_0 + j)$ 表示第 i 个真实速度序列的 j 时刻的速度值。

图 5 为不同 (L, M) 参数组合下的 MAE 值结果。可以看出, 当 M 取值小于 9 时, MAE 值相对较低, 当 M 取 5 且 L 取 4 时, MAE 值最小, 即多工况速度预测器的预测精度最高, 表明聚簇数为 5 是比较合适的取值。 $M \in [9, 10]$ 时的 MAE 值明显高于 $M \in [3, 6]$ 时, 说明过大的 M 设置是没有必要的, 因为聚簇数过多会稀释每个子数据库的样本量, 导致某些 conv1D-LSTM 子模型无法获得足够的样本量进行训练, 使多工况速度预测器的整体预测精度降低, 若要使各个 conv1D-LSTM 子模型之间的预测性能相似且良好, 则需要为每个簇都采集到相当数量的速度序列样本, 但会显著增加成本。图 6(c) 是 M 取 10 且 L 取 4 时 DK 聚类模型的具体聚类情况, 可以看到, 簇 1、簇 4 是非常相似的, 同为加速工况, 实际上可以归并为一簇, 这说明了过大的 M 会导致模型过度分类; 而当 M 取值过小时, 如图 6(a) 表示的是 M 取 3 且 L 取 4 时的聚类情况, 虽然模型将输入的速度序列样本大致上划分为加速、减速、平稳运行 3 类速度工况, 但从平稳速度工况簇发现, 许多应划分到加速或减速工况的速度序列样本被划分到平稳工况簇中, 这样的划分结果显然是存在争议的。当 M 取 5 且 L 取 4

时,从图 6(b)中可具体看出,与平均序列变化趋势相似的速度序列样本都被划分到同一簇,得到先加速后减速、加速、减速、先减速后加速、停车共 5 类工况。因此,可以确定, M 取 5 且 L 取 4 即是适合该 DK 聚类模型的参数组合,本研究中使用该参数组合作为最终的参数优化结果。

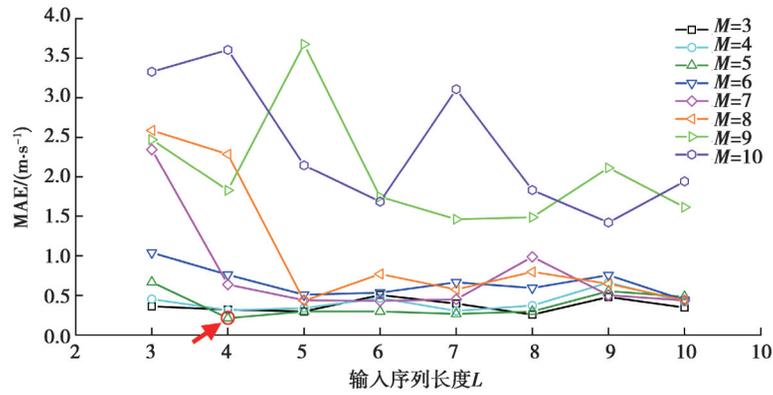
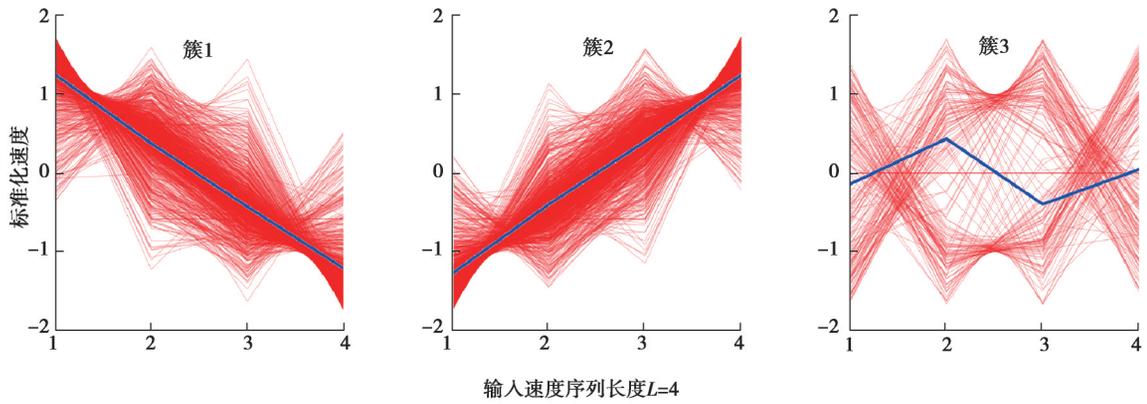
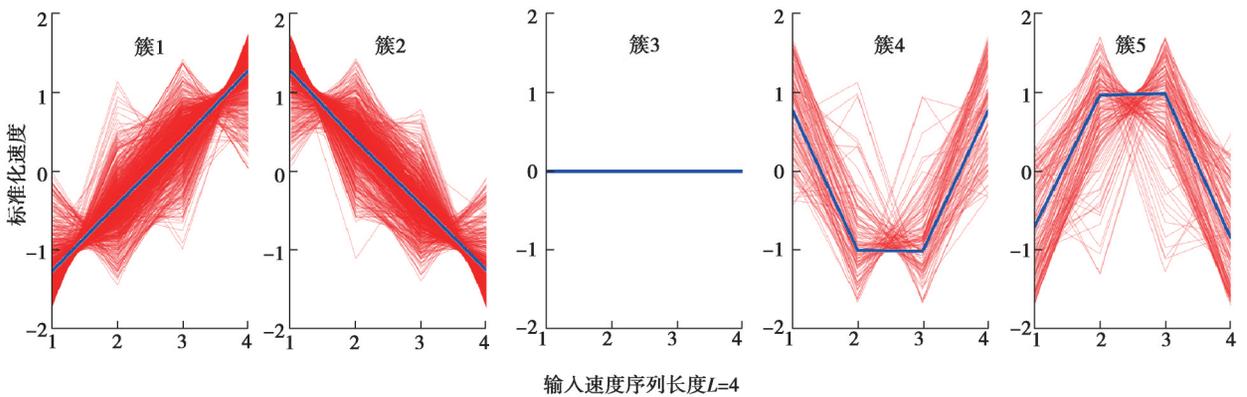


图 5 不同 (L, M) 下多工况速度预测器的 MAE 值结果

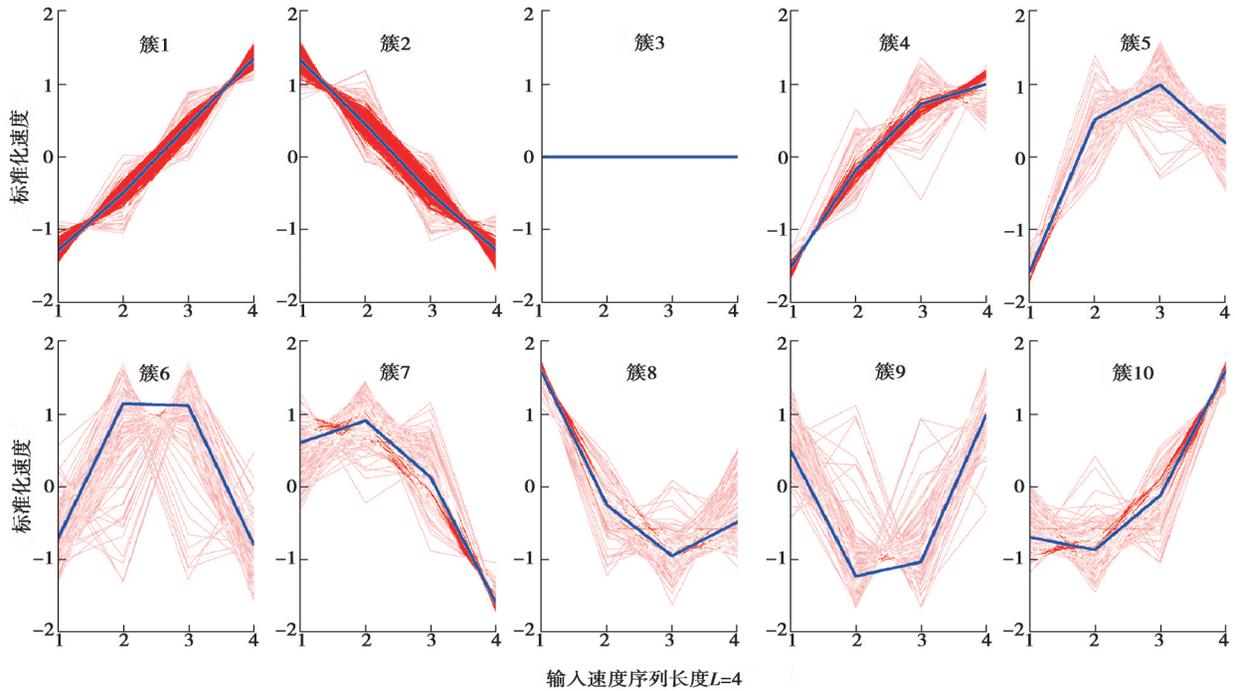
Fig. 5 MAE result of the multi-conditions speed predictor with different (L, M) settings



(a) DK模型聚类结果(聚簇数 $M=3$)



(b) DK模型聚类结果(聚簇数 $M=5$)

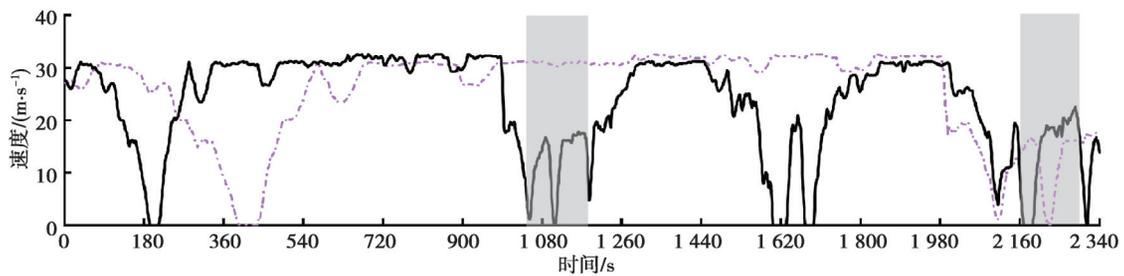
(c) DK模型聚类结果(聚簇数 $M=10$)

图例: ———— 标准化速度输入序列 ———— 平均序列

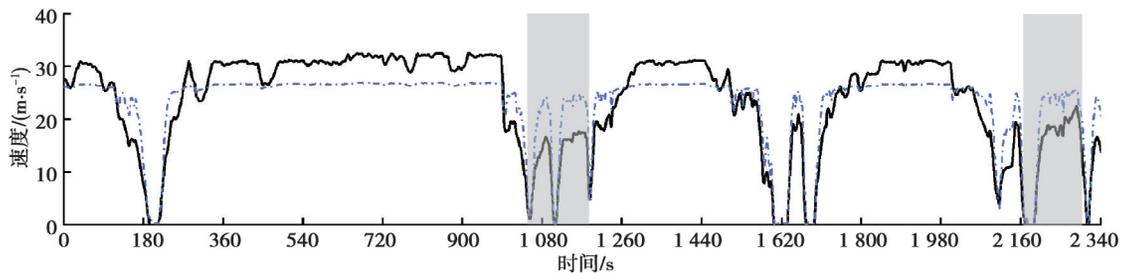
图6 L 取4时DK模型的具体聚类结果Fig. 6 The detailed clustering results of the DK model ($L=4$)

3.2 速度预测器效果评估

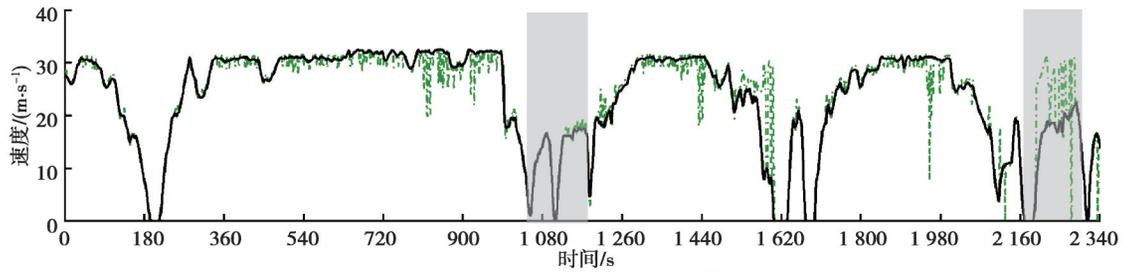
为比较多工况速度预测器的性能,设置了ARIMA、单层LSTM、基于DK聚类的LSTM共3种速度预测模型。其中,基于DK聚类的LSTM模型由本研究中的多工况速度预测器删减变形得到,该模型只保留了DK聚类模型和单层LSTM网络两部分。图7(a)~(d)给出了在输入序列长度为4 s、预测序列长度为2 s的情况下各模型的预测速度曲线,同时MAE值结果如表1所示。



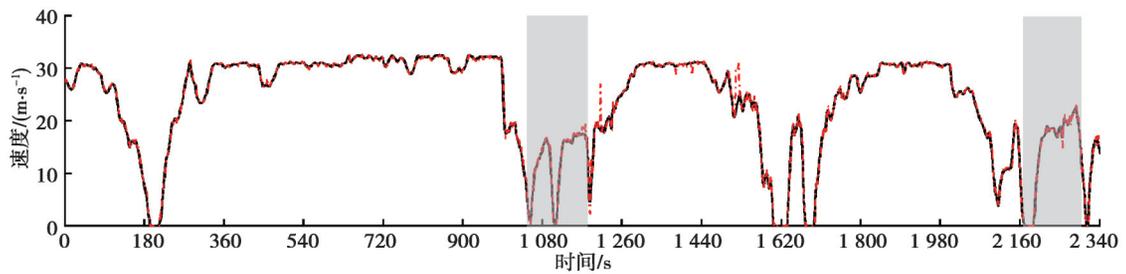
(a) ARIMA模型



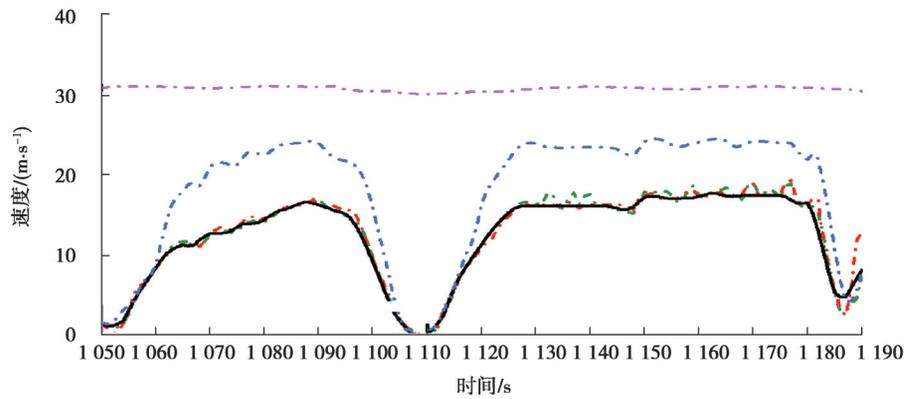
(b) 单层LSTM模型



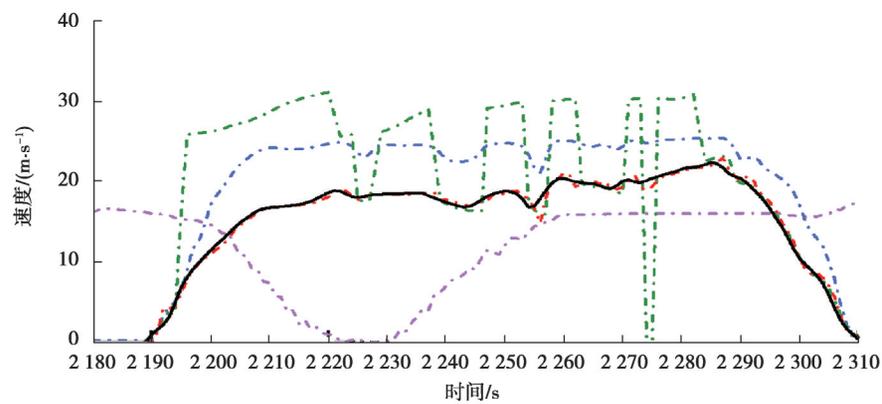
(c) 基于DK聚类的LSTM模型



(d) 基于DK聚类的多工况预测模型



(e) 局部放大图1



(f) 局部放大图2

图例: — 真实速度 — ARIMA模型 — 单层LSTM模型 - - 基于DK聚类的LSTM模型
- - 基于DK聚类的多工况预测模型

图 7 模型的预测速度曲线与真实速度曲线的对比结果

Fig. 7 Predicted and actual speed curves of models

从总体上看,在整个驾驶周期内,基于DK聚类的LSTM模型与本文多工况速度预测器的预测效果明显优于ARIMA和单层LSTM模型,且本文多工况速度预测器的MAE值最小。从单层LSTM模型与基于DK聚

类的 LSTM 模型的预测结果对比可以发现,在进行速度预测前,先进行速度工况分类可有效地提高模型预测精度。从局部放大图 7(e)中可以看出,ARIMA 预测效果最差,单层 LSTM 模型次之,而基于 DK 聚类的 LSTM 模型的预测结果与本文多工况速度预测器相似且预测精度均较高。当车速变化频率加快且有较大波动时,如局部放大图 7(f)所示,ARIMA 模型已经失效,而基于 DK 聚类的 LSTM 模型预测的速度曲线波动陡然增大,预测结果与单层 LSTM 模型相似甚至更差,只有本文多工况速度预测器仍然保持较高的预测精度,这表明一维卷积神经网络可捕获局部高维特征的特点对模型预测精度的提高有着积极作用。此外,为直观地比较预测速度与真实速度的相关性,图 8(a)~(d)给出了不同预测模型下的真实值与预测值的散点图,散点图中点的重合度越高且重合点所构成的轮廓与对角线之间形成的夹角越小,说明真实值与预测值的相关性越高^[16]。从图 8 可以看出,相较于其他预测模型,本文多工况速度预测器的散点重合度最高且夹角最小,表明该预测器的预测结果与真实值间具有更高的相关性,进一步证明本文多工况速度预测器的优越性。

表 1 模型预测结果

Table 1 The prediction results of models

模型	训练轮次	测试集 MAE/(m·s ⁻¹)
ARIMA	200	8.862
单层 LSTM	200	3.758
基于 DK 聚类的 LSTM	200	1.270
基于 DK 聚类的多工况速度预测器	200	0.212

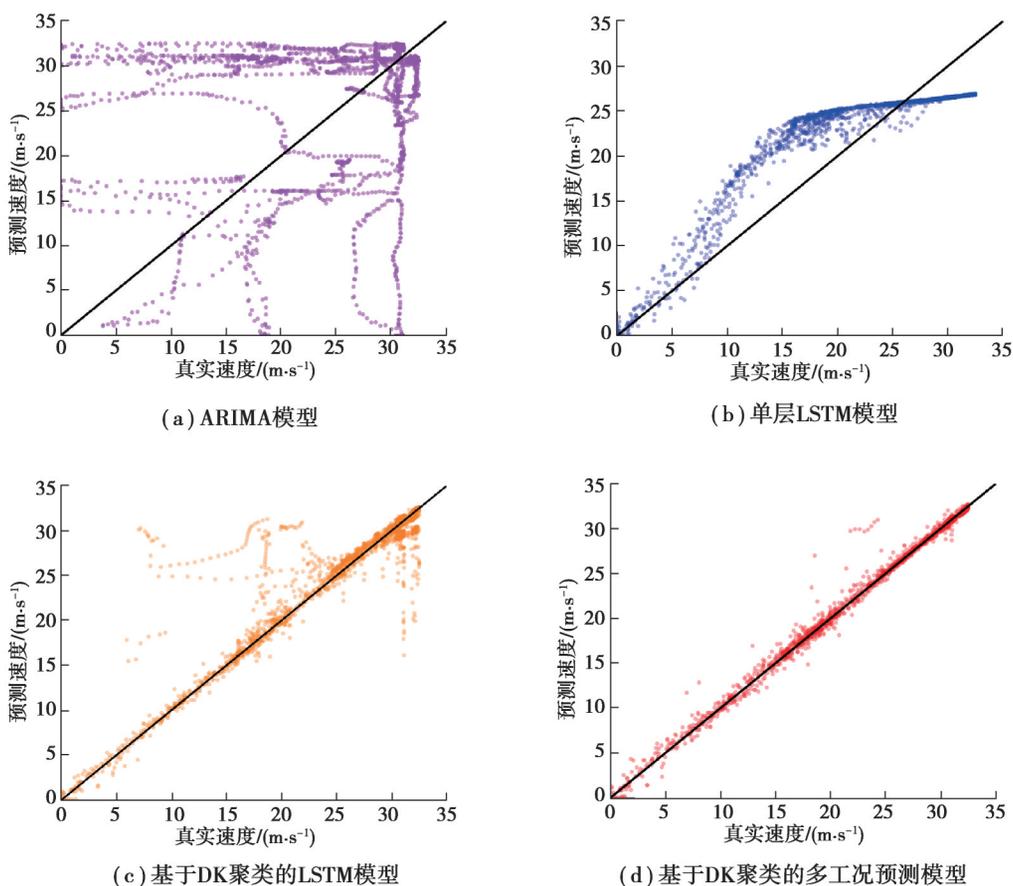


图 8 模型预测速度与实际速度的散点图

Fig. 8 Scatter plots of predicted speed against actual speed of models

4 结 论

针对速度工况的多变性,提出了一种基于DK聚类模型的多工况速度预测器。为实现对速度工况分类,建立了基于DTW距离的K-means聚类模型。结合一维卷积神经网络和LSTM网络的优点,设计了conv1D-LSTM多步预测模型对未来速度进行预测。讨论了输入速度序列长度和聚簇数对多工况速度预测器的影响,结果表明,当输入序列长度取4且聚簇数取5时,多工况速度预测器可取得最优性能,MAE值仅为0.212 m/s。多工况速度预测器与ARIMA、单层LSTM、基于DK聚类的LSTM模型对比的结果表明,多工况速度预测器具有更高的预测精度以及更好的工况适应性,证明该多工况速度预测器可有效地进行未来速度预测。

参考文献

- [1] Zhou Y, Ravey A, Péra M C. A survey on driving prediction techniques for predictive energy management of plug-in hybrid electric vehicles[J]. *Journal of Power Sources*, 2019, 412: 480-495.
- [2] Baker D, Asher Z D, Bradley T. V2V communication based real-world velocity predictions for improved HEV fuel economy[J/OL]. *SAE Technical Papers*, 2018-04-03 [2021-01-05]. <https://doi.org/10.4271/2018-01-1000>.
- [3] Yuan J N, Yang L, Chen Q. Intelligent energy management strategy based on hierarchical approximate global optimization for plug-in fuel cell hybrid electric vehicles[J]. *International Journal of Hydrogen Energy*, 2018, 43(16): 8063-8078.
- [4] Liu K, Asher Z, Gong X, et al. Vehicle velocity prediction and energy management strategy part 1: deterministic and stochastic vehicle velocity prediction using machine learning[J/OL]. *SAE Technical Papers*, 2019-04-02 [2021-01-05]. <https://doi.org/10.4271/2019-01-1051>.
- [5] Yeon K, Min K, Shin J, et al. Ego-vehicle speed prediction using a long short-term memory based recurrent neural network[J]. *International Journal of Automotive Technology*, 2019, 20(4): 713-722.
- [6] Lefèvre S, Sun C, Bajcsy R, et al. Comparison of parametric and non-parametric approaches for vehicle speed prediction[C]// 2014 American Control Conference, June 4-6, 2014, Portland, OR, USA. IEEE, 2014: 3494-3499.
- [7] Vlahogianni E I, Golias J C, Karlaftis M G. Short-term traffic forecasting: Overview of objectives and methods[J]. *Transport Reviews*, 2004, 24(5): 533-557.
- [8] Sun C, Hu X S, Moura S J, et al. Velocity predictors for predictive energy management in hybrid electric vehicles[J]. *IEEE Transactions on Control Systems Technology*, 2015, 23(3): 1197-1204.
- [9] Che Z, Purushotham S, Cho K, et al. Recurrent neural networks for multivariate time series with missing values[J]. *Scientific Reports*, 2018, 8: 6085.
- [10] Xu J, Rahmatizadeh R, Bölöni L, et al. Real-time prediction of taxi demand using recurrent neural networks[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 19(8): 2572-2581.
- [11] Xing Y, Lv C. Dynamic state estimation for the advanced brake system of electric vehicles by using deep recurrent neural networks[J]. *IEEE Transactions on Industrial Electronics*, 2020, 67(11): 9536-9547.
- [12] Ruan S M, Ma Y. Real-time energy management strategy based on driver-action-impact MPC for series hybrid electric vehicles [J]. *Complexity*, 2020, 2020: 1-15.
- [13] Wang R, Lukic S M. Review of driving conditions prediction and driving style recognition based control algorithms for hybrid electric vehicles[C]//2011 IEEE Vehicle Power and Propulsion Conference, September 6-9, 2011, Chicago, IL, USA. IEEE, 2011: 1-7.
- [14] Zhou Y, Li H, Ravey A, et al. An integrated predictive energy management for light-duty range-extended plug-in fuel cell electric vehicle[J]. *Journal of Power Sources*, 2020, 451: 227780.
- [15] Bellman R, Kalaba R. On adaptive control processes[J]. *IRE Transactions on Automatic Control*, 1959, 4(2): 1-9.
- [16] Zhang Y Z, Huang Z Y, Zhang C Z, et al. Improved short-term speed prediction using spatiotemporal-vision-based deep neural network for intelligent fuel cell vehicles[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(9): 6004-6013.
- [17] Fisher D H. Knowledge acquisition via incremental conceptual clustering[J]. *Machine Learning*, 1987, 2(2): 139-172.
- [18] Huang S T, Dai G H, Sun Y L, et al. DTW-based subsequence similarity search on AMD heterogeneous computing platform[C]//

- 2013 IEEE 10th International Conference on High Performance Computing and Communications & 2013 IEEE International Conference on Embedded and Ubiquitous Computing, November 13-15, 2013, Zhangjiajie, China. IEEE, 2013: 1054-1063.
- [19] Berndt D J, Clifford J. Using dynamic time warping to find patterns in time series[C]//KDD Workshop 1994, Seattle, WA, USA, 1994: 359-370.
- [20] Petitjean F, Ketterlin A, Gançarski P. A global averaging method for dynamic time warping, with applications to clustering[J]. *Pattern Recognition*, 2011, 44(3): 678-693.
- [21] Jin X B, Yu X H, Wang X Y, et al. Prediction for time series with CNN and LSTM[M]//Proceedings of the 11th International Conference on Modelling, Identification and Control (ICMIC2019). Singapore: Springer Singapore, 2019: 631-641.
- [22] Corizzo R, Ceci M, Zdravevski E, et al. Scalable auto-encoders for gravitational waves detection from time series data[J]. *Expert Systems With Applications*, 2020, 151: 113378.
- [23] Sadaei H J, de Lima e Silva P C, Guimarães F G, et al. Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series[J]. *Energy*, 2019, 175: 365-377.
- [24] Shen Z P, Zhang Y M, Lu J W, et al. A novel time series forecasting model with deep learning[J]. *Neurocomputing*, 2020, 396: 302-313.
- [25] Koprinska I, Wu D S, Wang Z. Convolutional neural networks for energy time series forecasting[C]//2018 International Joint Conference on Neural Networks (IJCNN), July 8-13, 2018, Rio de Janeiro, Brazil. IEEE, 2018: 1-8.
- [26] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [27] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. *Journal of Machine Learning Research*, 2014, 15: 1929-1958.
- [28] Zhang F Q, Xi J Q, Langari R. Real-time energy management strategy based on velocity forecasts using V2V and V2I communications[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 18(2): 416-430.

(编辑 罗敏)