

ADCSM:一种细粒度汽车行驶工况模型构建方法

罗靖杰 王永利

南京理工大学 南京 210000

(ljj19970324@163.com)

摘要 汽车行驶工况体现了汽车道路行驶的运动学特征,现有的行驶工况构建方法往往存在着构建粒度不细、精度不高的问题。为了解决工况构建的粒度和精度问题,提出了一种细粒度汽车行驶工况模型构建方法(Construction method of Automobile Driving Cycles based on SOM and Markov model,ADCSM)。首先行驶数据进行 Daubechies-4 阶小波分析降噪,划分短行程,对短行程提取了 10 个特征,将短行程特征输入 SOM 神经网络,然后聚类到(1 * 3)神经网络中,得到聚类结果序列,并建立了马尔可夫模型,最终通过 ADCSM 算法完成工况构建。对所构建的工况进行了验证,并将所得工况与传统的 K-means 聚类构建方法的结果进行了比较分析。实验结果表明,ADCSM 最终误差为 4.07%,而传统的 K-means 误差为 8.77%,ADCSM 利用了 SOM 神经网络聚类的方法,比传统 K-means 方法聚类精度更高,并具备了工况自学习能力。ADCSM 利用马尔可夫模型方法体现了城市行驶状况的转换关系,与传统 K-means 行驶工况构建方法相比粒度更细,故合成的行驶工况效果更好,更能反映城市特征。

关键词: 汽车行驶工况;小波分析;SOM 神经网络;马尔可夫模型

中图分类号 TP183

ADCSM: A Fine-grained Driving Cycle Model Construction Method

LUO Jing-jie and WANG Yong-li

Nanjing University of Science and Technology, Nanjing 210000, China

Abstract The driving cycles of the car reflect the kinematic characteristics of the car driving on the road. Existing methods of constructing driving cycles often have the problems of poor granularity and low accuracy. In order to solve these problems in constructing of driving cycles, a fine-grained method for constructing vehicle driving cycles model is proposed, called Construction method of automobile driving cycles based on SOM and Markov model (ADCSM). First, the data is cleaned by Daubechies-4 wavelet. The cleaned data is divided into many short strokes. The 10 features of the short stroke are extracted. 10 feature parameters are clustered by using SOM network, and clustered into the (1 * 3) neural network to obtain the clustering result sequence. Markov model is established through sequence. Finally constructing driving cycle is completed through the ADCSM algorithm. The obtained driving cycles are compared with the results of the traditional K-means clustering construction method. The experimental data show that the final error of ADCSM is 4.07%, while the traditional K-means Means error is 8.77%. ADCSM uses the SOM neural network clustering method to have higher clustering accuracy than the traditional K-means method, and has the ability to self-learn working conditions. ADCSM uses the Markov model method to reflect the conversion relationship of urban driving conditions. Compared with the traditional K-means driving conditions construction method, the granularity is finer, so the synthesized driving conditions are more effective than the traditional driving cycles and reflect the driving feature of the city.

Keywords Vehicle driving cycles, Wavelet analysis, SOM neural network, Markov model

1 引言

汽车行驶工况是指汽车在行驶过程中的工作状态,是汽

车在行驶时的运动学特征,也可以称其为描述汽车行驶特征的速度-时间曲线。在当今这个经济快速发展的时代,汽车数量急剧增多。汽车行驶工况成为标定优化汽车的各项性能指

基金项目:国家自然科学基金(61941113);中央高校基本科研业务费专项资金项目(30916011328,30918015103);南京市科技计划项目(201805036);“十三五”装备领域基金(61403120501);中国工程院 2019 年度咨询研究项目(2019-ZD-1-02-02);国家社科基金项目(18BTQ073);国家重点研发计划项目(2016YFC0401604);国家电网科技项目(5211XT190033)

This work was supported by the National Natural Science Foundation of China(61941113), Special Funds for Basic Scientific Research Business Expenses of Central Colleges and Universities(30916011328,30918015103), Nanjing Science and Technology Planning Project(201805036), Thirteenth Five-Year Plan Equipment Field Fund(61403120501), Chinese Academy of Engineering's 2019 Consulting Project(2019-ZD-1-02-02), National Social Science Fund Project(18BTQ073), National Key R & D Program Project(2016YFC0401604) and National Grid Technology Project(5211XT190033).

通信作者:王永利(yongliwang@njust.edu.cn)

标的主要基准,是汽车在能源消耗(尤指油耗)和尾气排放方面的测试方法以及限制标准的基础,是一项核心的共性基础技术^[1-3]。行驶周期有关的研究是必要的,因为它在评估和改进汽车设计中起着至关重要的作用^[4],也是未来智能交通领域一项不可或缺的技术。行驶工况的构建的方法主要有短行程法、聚类法^[5]、马尔可夫链法^[6-7]、微路径法^[8]、随机过程选择法等。

文献[9]采用基于小波分析降噪的方法对道路行驶工况进行分析与仿真并拟合出城市的代表性工况。文献[10]采用改进后的K均值聚类,采用90%区间作为K均值聚类初始聚类中心的选择区间。文献[11]利用SOFM神经网络算法和K均值聚类法相结合的组合聚类技术构建汽车行驶工况。文献[12]利用了马尔可夫模型生成构建汽车行驶工况。文献[13]利用了一种新型k-MPSO聚类算法对工况进行构建。利用通过对比分析发现,单纯的K均值聚类法往往不能拟合精度较高的行驶工况,也不能体现城市汽车行驶工况的特征性;传统的短行程法往往不能体现城市行驶工况的特征;而基于单纯的马尔可夫的状态片段随机选择生成,实验结果参差不齐,往往差异较大。

通过对比分析发现,现有的汽车行驶工况构建方法存在以下不足:1)构建的汽车行驶数据特征与原始数据特征差距较大,精度不高;2)构建的汽车行驶工况仅仅拟合特征数据,不能有效体现城市道路之间运行状态的转换,粒度不够细;3)对于城市道路基础设施不断的建设,道路交通流量的不断变化,适应能力差。

文献[14]有效利用了SOM聚类技术的自适应性,并提出了一种基于SOM聚类技术的微电网自适应保护方案。文献[15]利用马尔可夫模型完成了时间序列的建模与预测,并验证了马尔可夫模型是一种有效的时间序列预测方法。通过分析发现,SOM聚类具有良好的自适应性,且在某些类型数据的聚类方面也有着良好的精度。

综上,本文提出一种结合SOM自组织神经网络与马尔可夫模型的汽车行驶工况构建方法,可用于城市汽车行驶工况的细粒度制定。本文的贡献如下:1)对短行程的聚类采用自组织神经网络的方式,聚类精度更高,更能体现短行程特征;2)针对体现城市道路特征问题,采用马尔可夫模型得到城市道路状态转化序列,利用转换概率构建短行程序列,更能体现城市道路多粒度特点;3)利用SOM神经网络的自学习能力,可以良好地适应汽车道路行驶状况的不断更新。其中细粒度主要体现在两个部分:1)利用SOM神经网络对短行程进行了聚类,对行驶工况的构建效果更佳;2)本文提出的工况构建算法可以有效体现城市道路行驶状态的转变,粒度更细,能有效体现城市行驶状态转换关系。本方法对于城市道路工况预测^[16]、智能交通建设^[17]具有广泛的理论研究与应用研究意义。

2 ADCSM 模型构建

ADCSM (Construction method of Automobile Driving Cycles based on SOM and Markov model)模型的构建主要分为4个部分:数据预处理、特征提取、SOM神经网络聚类、马尔可夫模型的构建。




图1 ADCSM模型的构建

Fig. 1 Construction of ADCSM model

2.1 数据预处理

首先对原始数据进行预处理,去除少量毛刺数据,收集到的数据有部分缺失片段,采用插值法对短行程部分缺失数据进行补充,并删除部分不符合常理标准的数据,如图2所示。采用具有自适应变化的时窗频窗结构的小波变换来处理车速信号,使用离散小波变(Discrete Wavelet Transformation, DWT)对数据进行处理。利用Daubechies-4阶小波作为母小波 $\psi(t)$,将尺度因子 a 按幂级数离散化,在同一尺度下,位移因子 τ 均匀离散化,得到小波奇函数为:

$$\psi_{a_0, k\tau_0}^m(t) = a_0^{-\frac{m}{2}} \psi(a_0^{-m}t - k\tau_0) \quad (1)$$

通常取常数为:

$$a_0 = 2, \tau_0 = 1 \quad (2)$$

于是,小波奇函数记为:

$$\psi_{m,k} = 2^{-\frac{m}{2}} \psi(2^{-m}t - k) \quad (3)$$

离散后的小波变换系数可以表示为:

$$WT_f(m, k) \leq f(t) \quad (4)$$

$$\psi_{m,k}(t) \geq 2^{-\frac{m}{2}} \int_R f(t) \psi * (2^{-m}t - k) dt \quad (5)$$

按照式(1)~式(5)对车辆速度信号进行小波分析,计算小波变换系数,采用门限消噪处理方法对小波分解所得的高频系数使用阈值处理,将大于阈值的系数保留,将低于阈值的系数置零。




图2 数据预处理过程

Fig. 2 Process of data preprocessing

运动学片段是指汽车从怠速状态开始至下一个怠速状态开始之间的车速区间。本文方法对行程进行划分,得到短行程集合。

2.2 特征提取

对每一个短行程进行特征提取,并使其映射到特征向量空间,对短行程提取了表1中的10个特征。运动学片段中含有的运动学特征用来分析行驶工况的特征参数,根据相关的技术文献以及本研究实验中获取数据的特点,我们发现表1

中的 10 个特征值参数能有效表示短行程特征^[18-19]。特征值名称及含义如图 3 所示。

表 1 特征值名称及含义

Table 1 Characteristic value name and meaning

序号	特征值	含义
1	V_m	平均速度 (m/s)
2	σ_v	速度标准差 (m/s)
3	V_{mr}	平均行驶速度 (m/s)
4	A_a	平均加速度
5	A_d	平均减速度
6	P_i	怠速时间比
7	P_a	加速时间比
8	P_d	减速时间比
9	σ_a	加速度标准差
10	σ_d	减速度标准差

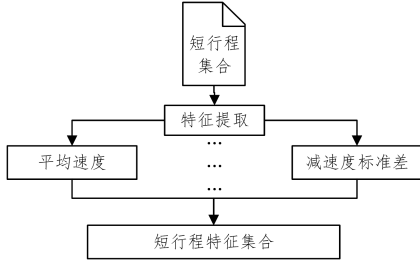


图 3 特征提取流程图

Fig. 3 Flowchart of feature extraction

2.3 SOM 网络聚类

将提取的短行程特征参数矩阵作为 SOM 网络的输入,学习率为 0.5,迭代次数为 1 000,输出神经网络结构为 (1 * 3),最终聚类为 3 个网络节点,SOM 网络模型如图 4 所示,其中距离判别公式为:

$$d_j(x) = \sum_{i=1}^{10} (x_i - w_{ji})^2, j \in 1, 2, 3 \quad (6)$$

其中, $d_j(x)$ 为第 x 个行程与第 j 个特征的中心距离; x_i 为第 i 个特征参数值; w_{ji} 为 j 个特征中心的第 i 个参数。

节点调整公式为:

$$w_{ij}(t+1) = w_{ij}(t) + \eta(t, N)[x_i^t - w_{ij}(t)] \quad (7)$$

最终得到聚类结果,得到短行程类别序列。

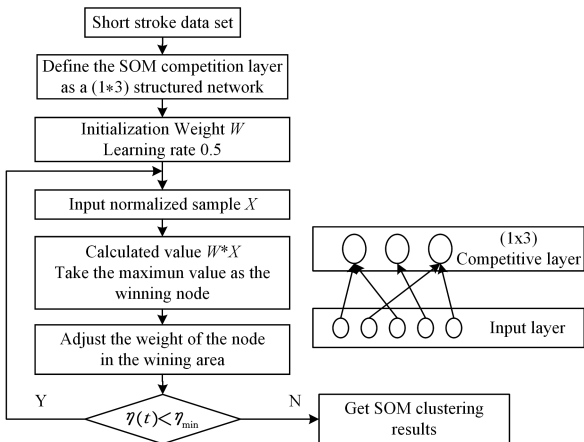


图 4 SOM 网络模型构建示意图

Fig. 4 Schematic diagram of construction of SOM network model

2.4 马尔可夫模型的建立

在得到汽车短行程聚类结果序列后利用下式即可得到短行程类别转换序列。

$$P_{ij} = \frac{n_{i-j}}{N_i} \quad (8)$$

其中, P_{ij} 代表转移矩阵第 i 行、 j 列的数据, N_i 代表状态 i 在序列中出现的次数, n_{i-j} 代表出现 i 状态转换为 j 状态的次数。得到马尔可夫模型后,构建行驶曲线先预测短行程粒度,再对不同粒度进行不同的处理,最终构建行驶曲线。马尔可夫模型如图 5 所示。

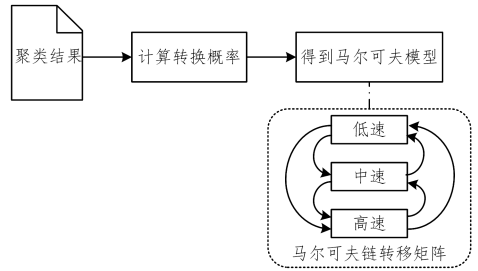


图 5 马尔可夫模型构建示意图

Fig. 5 Schematic diagram of Markov model construction

3 ADCSM 算法描述

3.1 行驶工况状态序列构建算法

为得到最终的行驶工况曲线,首先需要得到行驶工况状态序列,为解决行驶工况状态序列构建的精度问题,ADCSM 利用行驶工况状态序列构建算法(见图 6),通过工况总需求时长按总工况状态类别时长占比划分各类别状态数,其公式为:

$$n_s = T * \frac{t_s}{\sum_{i=1}^n t_i} * \frac{N_s}{t_s} = T * \frac{N_s}{\sum_{i=1}^n t_i} \quad (9)$$

其中, N_s 代表预测的 s 状态个数, T_s 代表映射的行驶工况时长, t_i 表示属于第 i 状态的短行程总时长, N_i 表示 i 状态短行程个数。

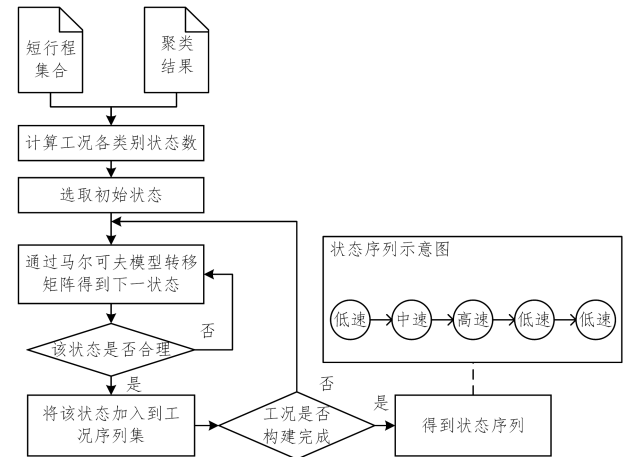


图 6 行驶工况状态序列构建算法

Fig. 6 Algorithm for constructing driving cycle state sequence

通过上一节得到的马尔可夫模型的转移矩阵选取下一状态类别,最终生成了行驶工况的状态序列。

算法 1 构建工况状态序列

输入: 马尔可夫转移矩阵 P , 需构建的行驶工况总时长 t , 各状态时长占比, 各状态短行程平均时长 σ_d

输出: 状态序列 Seq

1. 根据总时长以及个状态时长占比得到 3 个状态分配时长 $[t_{s1}, t_{s2}, t_{s3}]$
2. 根据个状态平均时长得到分配得各状态数: $[n_{s1}, n_{s2}, n_{s3}] = [t_{s1}/t_{a1}, t_{s2}/t_{a2}, t_{s3}/t_{a3}]$

3. 选取低速类状态为初始态 S_{pre} ;
4. 将 S_{pre} 加入到状态序列 Seq;
5. while $[n_{s1}, n_{s2}, n_{s3}]$ 不全为 0 do
6. 根据转移矩阵 P , 调用 Algorithm 2 选取下一个状态 S_{ne}
7. if S_{ne} 对应的状态数 n_s 不为 0 then
8. $n_s = n_s - 1$;
9. 将 S_{ne} 加入到状态序列 Seq;
10. $S_{pre} = S_{ne}$;
11. else 将 P 中 S_{ne} 对应列置为 0;
12. end while
13. return 状态序列 Seq。

算法 2 状态选择算法

输入: 马尔可夫转移矩阵 P , 上一状态 S_{pre}

输出: 选取的下一个状态 S_{ne}

1. 随机生成一个 $[0, 1]$ 区间的浮点数 a
2. 初始化 $sum=0, i=0$;
3. While $sum > a$
4. $sum + P[S_{pre}][i]$; (其中 p 为上一状态对应的转换矩阵)
5. $i + 1$;
6. end while
7. $S_{ne} = i$;
8. return S_{ne} 。

算法时间复杂度分析如下: 算法 2 中步骤 3 循环次数最多为状态数 3, 故算法 2 的时间复杂度为 $O(s)$ 。算法 1 步骤 4 列表尾部插入的时间复杂度为 $O(1)$, 步骤 5—12 是迭代循环迭代, 次数为 n (总状态个数), 步骤 7 调用算法 2 的时间复杂度为 $O(1)$, 故算法 1 的时间复杂度为 $O(n * s)$ 。

引入状态序列构建算法后, 可以利用该算法得到城市道路中短行程转换状态序列, 从而最终得到行驶工况的曲线。这也为今后的行驶工况状态预测有着重大的意义。

3.2 行驶工况构建算法

为了解决在得到状态序列后生成最终的行驶工况曲线, 本文提出了行驶工况构建算法 (见图 7)。通过得到的状态序列, 在原始切分好的短行程序列集中随机挑选评价函数较小的行程长度合适的短行程序列, 并最终拼接为能描述城市工况的全局曲线, 重复进行多次, 生成工况序列集合, 选取误差最小的工况代表最终生成的曲线。文中利用的评价函数为:

$$Eva(cur, scur) = \frac{\sum_{i=0}^{10} (a_i - b_i)}{10} \quad (10)$$

其中, $cur, scur$ 分别为需要做评价的短行程序列, 即该短行程状态的所有短行程; a_i, b_i 分别为 cur 的特征参数, 即该状态总体短行程的特征参数; i 代表第 i 个特征参数。

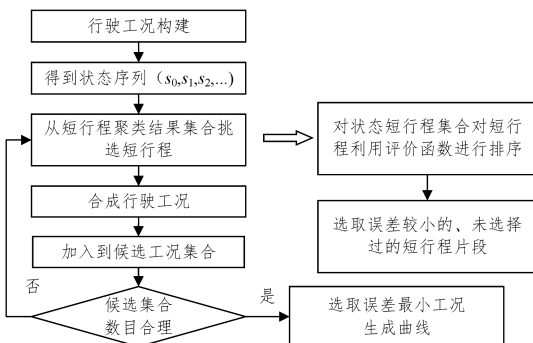


图 7 行驶工况构建算法流程

Fig. 7 Algorithmic process of driving cycle construction

算法 3 构建行驶工况

输入: 状态序列 Seq, 短行程集合

输出: 行驶工况曲线 Final

1. 工况集合 Acur
2. do
3. 初始化工况曲线 Cur;
4. while 状态序列状态选完
5. 顺序选取 Seq 中状态 S;
6. 从该 S 对应的短行程集合选取短行程片段 cur;
7. 将 cur 加入到 Cur 中;
8. end while
9. 将 Cur 加入到集合 Acur 中;
10. while 集合 Acur 数目小于 100
11. 对 Acur 集合中工况调用 $Eva(Cur, AllCur)$ 排序得到误差最小曲线 Final
12. return Final

算法 4 选择短行程片段

输入: 分类好的短行程片段集合, 短行程各类别的平均时长 t_i

输出: 选择的片段 cur

1. 对每一个状态内所有短行程片段进行评价函数 Eva 得到评价分数
2. 对每一状态内部评价分数排序并删除掉时间不符合标准的短行程 (超过或低于总类别短行程长度的 20%)
3. 按评价分数从小到大依次选取短行程片段

算法时间复杂度分析: 算法 4 步骤 1 中调用 Eva 函数为比较 10 个特征参数, 复杂度为 $O(1)$, 一共有 N 条短行程, 故步骤 1 的时间复杂度为 $O(N)$; 对 N 个数据进行排序采用快速排序的方式, 时间复杂度为 $O(N * \log N)$, 故最终算法 4 的时间复杂度为 $O(N * \log N)$ 。算法 3 步骤 2—10 为迭代, 迭代次数为 100 次, 步骤 4—6 为迭代, 迭代次数为 n , 调用算法 4 的时间复杂度为 $O(N * \log N)$, 步骤 11 的时间复杂度为 $O(1)$, 故算法 3 的时间复杂度为 $O(n * N * \log N)$ 。

最终通过算法得到构建的城市道路行驶工况映射, 可以为城市汽车油耗分析、智能交通领域、行驶工况预测提供进一步分析的素材。

4 实验

4.1 实验数据集及实验环境

ADCSM 实验的数据集是采用 CAN 通讯总线和 GPS 模块采集到的来自福州轻型汽车多天运行的汽车行驶数据, 行驶路线分布均匀, 能真实有效地反映当前的道路交通状况, 采集车速精度为 0.1, 采样频率 1 Hz。最终共采集到 1 843 245 条行驶数据, 主要包括汽车当前时刻行驶速度、经纬度、油门开度、当前时间等信息。实验环境如表 2 所列。

表 2 实验环境

Table 2 Lab environment

system	Windows 10
CPU	Intel i7-7700HQ
RAM	16 GB

4.2 实验步骤和分析描述

在 ADCSM 中, 由于汽车行驶工况基本和汽车速度相关, 故仅提取汽车速度数据得到行驶工况曲线, 利用小波分析降噪对行驶工况曲线进行降噪使曲线变得更为平滑, 毛刺更少。并且对部分缺失以及不符合常理的数据进行处理, 处理前后的效果图如图 8 所示。

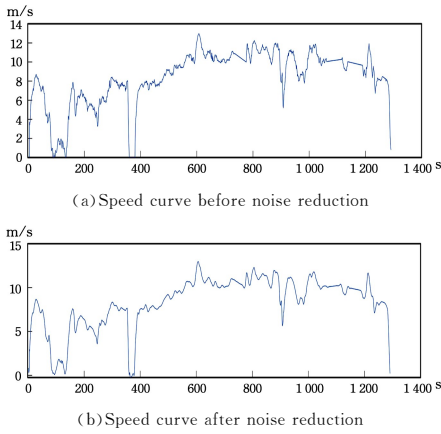


图 8 数据预处理前后图

Fig. 8 Effect diagram before and after data preprocessing

对总体数据预处理后,将两个怠速过程之间的短行程分割开来得到短行程集合,共 28525 个短行程数据,对短行程集合中短行程的 10 个特征进行了特征提取,部分短行程特征如表 3 所列。

表 3 部分短行程特征参数

Table 3 Partial short stroke characteristic parameters

V_m	σ_v	V_{mr}	...	σ_a	σ_d
1.92	1.45	2.21	...	0.25	0.44
7.25	5.13	9.86	...	0.24	0.41
5.62	3.94	7.10	...	0.28	0.57
7.55	6.32	11.4	...	0.27	0.43
10.84	7.13	13.6	...	0.37	0.61

将提取的短行程特征参数矩阵集合作为 SOM 网络的输入,迭代次数为 1000,学习率为 0.5,输出神经网络结构为 (1×3) ,最终聚类为 3 个网络节点。为了更好地观察聚类结果,如图 9、图 10 为利用 PCA 分别降维至 2 维以及 3 维的聚类示意图。




图 9 SOM 聚类结果降维至 2 维示意图

Fig. 9 Two-dimensional schematic diagram of SOM clustering results after dimensionality reduction




图 10 SOM 聚类结果降维至 3 维示意图

Fig. 10 Three-dimensional schematic diagram of SOM clustering results after dimensionality reduction

聚类结果评价指标主要有轮廓系数和 CHI,值越高评价效果越好,实验结果如表 4 所列。

表 4 SOM 与 K-means 评价指标的对比

Table 4 Comparison of SOM and K-means evaluation indicators

	K-means	SOM
轮廓系数	0.4968	0.4668
CHI	5049.77	4549.77
新增数据得到结果需时间/ms	57	5

通过实验结果可知,在聚类评价方面 K-means 同 SOM 方式聚类效果相差不大,在后续构建行驶工况结果中,运用 SOM 聚类在最终结果的精确度上体现为较为良好,且对于新增数据 K-means 需要全程重新聚类,而 SOM 只用将新增数据放入已训练的 SOM 神经网络迭代一次就能得到结果,满足汽车控制策略根据行驶线路不断优化要求,为汽车基于道路行驶工况控制策略自适应优化提供基础环节。

对聚类结果进行分析,将属于同一类的行程片段拼接起来,得到的每一类别的特征,如表 5 所列。

表 5 同一类别特征参数

Table 5 Feature parameters of the same category

类	V_m	σ_v	V_{mr}	...	σ_a	σ_d
1	2.74	2.99	4.29	...	0.51	0.48
2	4.26	4.74	7.56	...	0.57	0.67
3	11.21	7.04	12.3	...	0.45	0.58

可明显观察出短行程大致分为了 3 个部分,3 个部分特征较为明显,可以命名为低速类、中速类、高速类,这符合道路真实状况,聚类合理。

最终根据短行程状态序列建立马尔可夫模型,得到类别转换概率如表 6 所列。当行程处于工况低速状态时下一个状态较大概率也处于低速状态行程(概率高达 65%),当处于中速状态时下一个状态较大概率处于高速状态,当处于高速状态时下一段路程较大概率出现低速工况,符合实际情况。

表 6 行驶工况状态转换概率

Table 6 Driving state transition probability

	低速类	中速类	高速类
低速类	65.9	8.7	25.3
中速类	43.6	18.3	38.0
高速类	34.1	11.2	54.6

然后对其进行行驶工况构建,为构建一个工况时间大致为 1500~2000s 的曲线,首先分配行驶工况总体时间 2000s,根据各类别时长占比,得到各类别所得时间大致为 597s,180s,1221s,又已知聚类后个状态平均时长分别为 101s,146s,286s 可得每个类别数分别为 5,1,4。选取低速类为初始状态随机生成工况序列为 $[0,2,2,0,2,0,0,1,0,2]$ 。

按照行驶工况构建方法对短行程进行选取,最终得到了如图 11 所示行驶工况曲线,对该曲线进行特征参数提取,特征参数如表 7 所列。

如图 11 所示,K-means 构建的行驶曲线不能体现真实行驶过程中的行驶状态的转变,短行程转换较为平滑,粒度更粗;ADCSM 构建的行驶工况映射曲线更为平滑,噪声较小,能够有效体现城市真实短行程状态的转换,粒度更细,满足要求。




图 11 ADCSM 与 k-means 的汽车行驶工况曲线

Fig. 11 ADCSM and k-means vehicle driving cycles curve

表 7 构建的曲线与原始数据特征的比较

Table 7 Comparison of characteristics of constructed curve and original data

	V_m	σ_v	V_{mr}	...	σ_a	σ_d	整体
原始数据	8.06	7.13	10.13	...	0.48	0.56	
WSM	7.91	6.56	10.27	...	0.48	0.54	
WSM 误差/%	1.8	7.9	1.3	...	3.1	4	4.07
K-means	7.42	6.31	9.56	...	0.5	0.6	
K-means 误差/%	7.9	11.5	5.6	...	4.10	5.9	8.77

由表 7 可见,本研究拟合的福州道路行驶工况的平均相对误差仅有 4.07%,在平均速度方面误差仅有 1.8%,在减速度时间占比方面误差仅 0.3%,能够有效表达全局汽车行驶工况;而 K-means 聚类方法拟合的曲线平均相对误差为 8.77%,在平均速度方面误差为 7.9%。可见本方法精度略高于传统 K-means 方法。通过本研究方法所给出的行驶工况一定程度上能够反映该区域的实际道路交通状况。

结束语 本文给出了一种基于 SOM 自组织神经网络与马尔可夫模型来构建汽车行驶工况的方法(ADCSM),可用于城市汽车行驶工况的制定。1)对短行程的聚类采用自组织神经网络的方式,效果更好,更能体现短行程特征,自适应学习能力强,构建效果更好,粒度更细;2)针对体现城市道路特征问题,采用马尔可夫模型得到城市道路状态转化序列,利用转换概率构建短行序列,更能体现城市道路特点,粒度更细。该方法精度为 4.07%,优于传统的 K-means 聚类构建马尔可夫模型的方法。但本文算法在短行程片段选取时,短行程评估会有一定误差,从而导致最终形成的工况模型曲线不是最优解。因此,提高短行程评估效果、改良评估函数和工况构建算法以及行驶工况预测成为后续的研究工作。

参考文献

[1] LIN J, NIEMEIER D A. Exploratory analysis comparing a stochastic driving cycle to California's regulatory cycle[J]. Atmospheric Environment, 2002, 36(38): 5759-5770.

[2] KNEZ M, MUNEEER T, JEREB B, et al. The estimation of a driving cycle for Celje and a comparison to other European cities

[J]. Sustainable Cities and Society, 2014, 11: 56-60.

- [3] HEREIJGERS K, SILVAS E, HOFMAN T, et al. Effects of using synthesized driving cycles on vehicle fuel consumption[J]. IFAC-Papers OnLine, 2017, 50(1): 7505-7510.
- [4] GONG H M, ZOU Y, YANG Q K, et al. Dietmar Goehlich. Generation of a driving cycle for battery electric vehicles[C]// A case study of Beijing, Energy, 2018: 901-912.
- [5] QIAN C, WANG L, ZOU X, et al. Construction and Simulation Analysis of Driving Cycle of Urban Electric Logistic Vehicles [OL]. <https://www.sae.org/publications/technical-papers/content/2020-01-1042/>.
- [6] PENG Y, ZHUANG Y, YANG Y. A driving cycle construction methodology combining k-means clustering and Markov model for urban mixed roads[C]// Proceedings of the Institution of Mechanical Engineers, 2020: 714-724.
- [7] LIN J. A Markov process approach to driving cycle development. [OL]. <https://search.proquest.com/openview/4013d81fe9e3b3e6dabcb8a8cd2c1239/1?pq-origsite=gscholar&cbl=18750&diss=y>.
- [8] ZHANG J, WANG Z, LIU P, et al. Driving cycles construction for electric vehicles considering road environment: A case study in Beijing [OL]. <https://www.sciencedirect.com/science/article/abs/pii/S0306261919311882>.
- [9] JIANG P, SHI Q, CHEN W, et al. A Research on the Construction of City Road Driving Cycle Based on Wavelet Analysis [J]. Automotive Engineering, 2011, 33(1): 70-73, 51.
- [10] LIU Z, ZHU P, LIU X, et al. Research on K-means clustering improvement and driving condition construction [J]. Automotive Technology.
- [11] SHI Q, QIU D, ZHOU J. Construction and precision analysis of driving conditions based on combined clustering method [J]. Automotive Engineering, 2012, 34(2): 164-169.
- [12] JIANG P. Research on the construction of urban mixed road driving conditions [D]. Hefei: Hefei University of Technology, 2011.




图 6 通信半径变化时算法定位误差图


Fig. 6 Location error diagram of different communication radii

结束语 通过对传统 DV-Hop 算法以及 HC-GASA-Hop 算法进行了相同参数环境下的定位误差分析可以看出, HC-GASA-Hop 算法相比传统的 DV-Hop 算法具有更强的定位精度。但是其提升定位精度的同时未能兼顾改进其时间复杂度, 因此如何进一步降低算法复杂度也是今后研究的重点。

参 考 文 献

- [1] CHONG C Y, KUMAR S P. Sensor Networks: Evolution, opportunities, and Challenges [J]. IEEE Communications Magazine, 2002, 40(8): 102-114.
- [2] 王泽兵, 李贯峰. 无线传感器网络技术在物联网中的应用及其发展趋势[J]. 信息记录材料, 2019, 20(11): 179-180.
- [3] ESTRIN D, CULLER D, PISTER K, et al. Connecting the physical world with pervasive networks[J]. IEEE Pervasive Computing, 2002, 1(1): 59-69.
- [4] CHENG X, SHU H, LIANG Q, et al. Silent Positioning in Underwater Acoustic Sensor Networks[J]. IEEE Transactions on Vehicular Technology, 2008, 57(3): 1756-1766.
- [5] HUANG Y, ZHANG L. Weighted DV-Hop Localization Algorithm for Wireless Sensor Network based on Differential Evolution Algorithm[C]// 2019 IEEE 2nd International Conference on Information and Computer Technologies (ICICT). IEEE, 2019.
- [6] HUANG H, CHEN H, CHENG S, et al. An improved DV-HOP algorithm for indoor positioning based on Bacterial Foraging Optimization[C]// 2016 8th International Conference on Wireless

- Communications & Signal Processing (WCSP). IEEE, 2016.
- [7] YANG X, ZHANG W. An Improved DV-Hop Localization Algorithm Based on Bat Algorithm[J]. Cybernetics & Information Technologies, 2016, 16(1): 89-98.
- [8] 高清源, 徐曾春, 胡平. 基于跳数修正与 LM 优化的 DV-Hop 改进算法[J]. 计算机应用研究, 2019, 36(1): 206-209, 219.
- [9] 周子昂, 徐坤, 程全, 等. 人工蜂群优化神经网络的无线传感器节点定位算法[J]. 南京理工大学学报, 2017, 41(4): 466-471.
- [10] NICULESCU D, NATH B. DV Based Positioning in Ad Hoc Networks[J]. Telecommunication Systems, 2003, 22(1-4): 267-280.
- [11] PENG B, LI L. An improved localization algorithm based on genetic algorithm in wireless sensor networks[J]. Cognitive Neurodynamics, 2015, 9(2): 249-256.
- [12] 张万礼, 宋启祥. 遗传算法的 DV-Hop 算法改进[J]. 重庆大学学报, 2015, 38(3): 159-166.
- [13] KUMAR G, RAI M K. An energy efficient and optimized load balanced localization method using CDS with one-hop neighbourhood and genetic algorithm in WSNs[J]. Journal of Network and Computer Applications, 2017, 78: 73-82.
- [14] FERREIRA M, BAGARI J, LANZA-GUTIERREZ J M, et al. On the Use of Perfect Sequences and Genetic Algorithms for Estimating the Indoor Location of Wireless Sensors[J]. International Journal of Distributed Sensor Networks, 2015, 2015: 1-12.
- [15] 张治华, 张玲华. 基于模拟退火的加权 DV-Hop 的 WSN 定位算法[J]. 计算机技术与发展, 2018, 28(6): 201-204.
- [16] 何庆, 吴意乐, 徐同伟. 改进遗传模拟退火算法在 TSP 优化中的应用[J]. 控制与决策, 2018, 33(2): 219-225.



WANG Guo-wu, born in 1996, postgraduate. His main research interests include computer network and artificial intelligence.

(上接第 294 页)

- [13] YAN W, LI M, ZHONG Y, et al. A Novel k-MPSO Clustering Algorithm for the Construction of Typical Driving Cycles[C]// IEEE Access. 2020, 88: 64028-64036.
- [14] SEYYED M E G, MAZLUMI K. Adaptive protection scheme for microgrids based on SOM clustering technique[J]. Applied Soft Computing, 2020: 106062.
- [15] WILINSKI A. Time series modeling and forecasting based on a Markov chain with changing transition matrices[J]. Expert Systems with Applications, 2019, 133: 163-172.
- [16] WU Y, ZHANG W, ZHANG L, et al. A Multi-Clustering Algorithm to Solve Driving Cycle Prediction Problems Based on Unbalanced Data Sets: A Chinese Case Study[J]. Sensors, 2020, 20: 2448.
- [17] YAN J, LIU J, TSENG F M. An evaluation system based on the self-organizing system framework of smart cities: A case study of smart transportation systems in China [J]. Technological Forecasting and Social Change, 2020, 153: 119371
- [18] SHI Q, ZHENG Y, JIANG P. Research on driving conditions of

urban roads based on kinematic fragments [J]. Automotive Engineering, 2011, 33(3): 256-261.

- [19] LI J. Research on related technologies of data processing and analysis platform for operating vehicle operating conditions [D]. Beijing: Beijing Jiaotong University, 2014.



LUO Jing-jie, born in 1997, postgraduate. His main research interests include machine learning and intelligent traffic.



WANG Yong-li, born in 1974, Ph. D., professor, is a member of China Computer Federation. His main research interests include database technology, knowledge graph, data mining, internet of things data processing, massive data analysis, and machine learning.