DOI: 10.3901/JME.2020.16.155

基于真实驾驶数据的运动基元提取与再生成*

王博洋 龚建伟 张瑞增 陈慧岩
(北京理工大学机械与车辆学院 北京 100081)

摘要: 类人驾驶系统是通过学习人类驾驶员知识与经验来提升无人驾驶系统适用性与接受度的重要技术途径。为解决驾驶员轨迹和操控层面经验的表述问题,以采集得到的大量真实驾驶数据为依托,提出一种基于轨迹基元与操控基元的分层式驾驶员经验表述模型。轨迹基元以动态运动基元算法进行表征,并由概率提取算法完成基元从无标签连续轨迹数据中的分割提取。操控基元在轨迹基元的提取分类结果上,利用高斯混合模型完成基元的训练,并利用高斯回归算法完成转向操控序列的预测。结果表明,概率提取算法既利用到了表征与提取之间的相互关联关系,又借助于初始分割点的合理设置,提升了算法的效率并使得提取得到的运动基元符合特定的驾驶假设。此外,所提出的运动基元既能以较高精度完成对驾驶员轨迹和操控层面数据的表征,又具备良好的泛化能力以应对运动基元再生成时在期望位置和时间尺度上的变化需求。最终构建了描述全工况驾驶行为的运动基元库,并大幅提升了运动基元应对不同行车环境时的适用性。

关键词: 智能车辆; 运动基元; 驾驶数据; 动态运动基元(DMP); 高斯混合模型(GMM); 高斯回归算法(GMR)

中图分类号: TP242

Motion Primitives Extraction and Regeneration Based on Real Driving Data

WANG Boyang GONG Jianwei ZHANG Ruizeng CHEN Huiyan
(School of Mechanical Engineering, Beijing Institute of Technology, Beijing 100081)

Abstract: The human-like driving system is an essential technical way to improve the applicability and acceptance of an unmanned driving system by learning the knowledge and experience of human drivers. In order to solve the driving skills representation problem at trajectory and control level, by utilizing a large amount of collected real driving data, a hierarchical driver model based on trajectory primitives and operation primitives is proposed. The trajectory primitives are represented by the dynamic movement primitive, and the probabilistic extraction algorithm is applied to extract primitives from the unlabeled continuous trajectory data. The operation primitives use the Gaussian mixture model to complete the training process based on the extraction and classification results of the trajectory primitives. The Gaussian mixture regression(GMR) algorithm is applied to predict the steering angle. The results show that the probabilistic extraction algorithm not only utilizes the correlation between representation and extraction but also uses the reasonable setting of the initial segmentation point, which improves the efficiency of the algorithm and makes the extracted motion primitives conform to specific driving assumptions. The proposed motion primitives can not only represent the driver's driving data with high precision but also have good generalization ability to deal with the desired position and time duration change when the motion primitives are regenerated. Finally, the motion primitive library describing the driving behavior under all conditions is established, and the applicability of the motion primitives to different driving situations is significantly improved.

Key words: intelligent vehicle; motion primitive; driving data; dynamic movement primitives(DMP); gaussian mixture model(GMM); gaussian mixture regression(GMR)

0 前言

随着无人车^[1-2]以及辅助驾驶技术^[3-7]的不断发

展,在系统中融入驾驶员的人为因素,对于进一步提升智能驾驶系统的接受程度具有重大意义^[8-9]。示教学习是一种从驾驶示范数据中学习驾驶员经验,继而将所学习得到的经验用于新驾驶场景下的一种典型方法^[10]。对于轨迹和操控层面的驾驶行为学习而言,将复杂的运动分解成基本的运动基元,并在

* 国家自然科学基金资助项目(61703041)。20191106 收到初稿,20200303 收到修改稿

此基础上进行示教学习,将有效提升算法的效率与精度^[11]。

在类机器人和机械臂领域,运动基元这种表征形式被广泛用于示教学习中。**KRUGER**等^[12]通过隐马尔科夫模型完成了对人类抓取动作的运动基元分解与学习,并将所学习得到的运动基元重新组合用于类机器人的抓取动作。**MANSCHITZ**等^[13]利用图论表征运动基元的切换序列,继而利用支持向量机和高斯混合模型(Gaussian mixture model, GMM)表征基元之间的切换规律,并成功将人类的操作经验用于机械臂的实际操作任务中。**MULLING**等^[14]利用动态运动基元(Dynamic movement primitives, DMP)算法对人类球类击打运动基元进行学习,并在所建立运动基元库的基础上,进行运动基元的选择与泛化,最终生成机械臂击打操作控制指令序列。虽然上述基于运动基元的学习算法,在各自的运用过程中都取得了极大的成功,但他们采集得到并处理的训练数据都是在有限空间里的小幅度机器人关节运动数据,并且进行的试验都为重复性单一试验。而车辆行驶数据的采集往往针对一般并且多样的驾驶场景,所采集得到轨迹和操控数据的变化幅度也较大。如何从上述驾驶员行为数据集中提取出符合满足自动驾驶使用需求的运动基元是本文的一个重要挑战。

在轨迹基元的提取与再生成领域,现有的研究主要针对典型的换道轨迹基元。**MORI**等^[15]利用非监督的学习方法,以运动基元序列的组合形式为依据,从驾驶数据中提取出相应的换道轨迹。**ZHAO**等^[16-18]在获取得到周边车辆的行车轨迹集后,开展了一系列关于换道轨迹的提取与生成的工作,这其中既包含了利用支持向量机算法的换道轨迹提取,也包含了类人换道轨迹的匹配生成。**孙杨**等^[19]利用五次多项式结合优秀驾驶员数据对换道工况下的行驶轨迹进行相空间重构,并利用混沌理论对无人车的行驶轨迹进行量化分析。但上述研究仅仅针对一种特定类型的单一运动基元,其运用场景也仅限于特定的驾驶情况,并未针对描述驾驶员一般驾驶任务的轨迹库整体开展研究,也未对轨迹基元在一般情况下的再生成利用开展研究,存在一定的局限性。

对于操控基元的研究主要集中在辅助驾驶领域,并且已经有众多研究表明,构建双层的预测模型有助于提升对驾驶员行为的预测精度。**YI**等^[20]在对驾驶员行车轨迹进行聚类分析的基础上,构建轨迹类别与操控行为的对应关系,通过该双层结构提升了对驾驶员驾驶意图的预测精度。**BENDER**等^[21]则是利用横摆角速度和加速度完成对操控基元的分类,

构建与分类结果相对应的分层关系提升预测精度。**TANIGUCHI**等^[22-23]也通过构建复杂驾驶行为与简单多个操控基本行为的对应关系,实现对驾驶员离散操控行为预测和连续操控行为的预测。但上述研究主要针对辅助驾驶系统中驾驶员意图的预测分析,即通过实时获取的历史数据,以及所构建的驾驶员模型,对下一时刻的驾驶员驾驶意图进行预测,而非利用生成的无人车期望轨迹数据对未来一段时间内的操控指令进行预测。并且这些研究中所构建双层驾驶员模型的上层结构仅仅具备分类功能,并未考虑上层轨迹基元的泛化再生成问题。

本文针对一般驾驶环境下所采集的驾驶员行驶数据,采用双层基元结构对单一驾驶员在各种典型场景下的轨迹和操控层面的行为进行表述。上层结构利用基于特定驾驶假设的初始分割点和概率提取算法,完成了轨迹基元的分割提取和分类,并且实现了轨迹基元中用于基元分类的形状表征参量与用于再生成时的调整参量之间的分离;底层结构则利用轨迹基元的分类结果对训练数据进行重组,并在此基础上完成操控基元的训练,实现了对驾驶员转向操控指令的预测。整体的处理流程图如图1所示。

图1 分层式驾驶员经验表述模型训练流程

1 问题陈述

运动基元的提取就是从真实的驾驶数据中获取能够表征驾驶员轨迹与操控层面行为的基本单元。所提取得到的运动基元不仅要具备对真实驾驶数据的拟合能力,也要具备一定的泛化能力,以应对运动基元再生成过程中运动规划系统的实际需求。

本文所使用主要参量的定义与解释说明如下所述。

(1) $\mathbf{O}(t)=[\Delta\theta(t), v(t), \delta(t)]^T \in \mathbf{R}^{3 \times 1}$ 是所采集得到用于表征驾驶员轨迹与操控行为的时序点, 其中 $\Delta\theta(t)$ 是 t 时刻的航向变化偏差, $v(t)$ 是车辆行驶速度, $\delta(t)$ 是转向盘转角。

(2) $\mathbf{m}_i(t)=[x_m(t), y_m(t)]^T \in \mathbf{R}^{2 \times 1}$ 表征所提取出轨迹基元的相对位置时序点, 其中 $x_m(t)$ 和 $y_m(t)$ 是相对于基元起始点的相对坐标。

(3) $\phi_m=[v_{\text{init}}, \omega_x, \omega_y]$ 是轨迹基元的属性特征, 是轨迹基元提取过程中判定基元类型的依据, 其中 v_{init} 是所选定基元的初始速度; ω_x 和 ω_y 是利用 DMP 算法对轨迹基元进行表征时高斯内核参量的权重系数, 直接决定了轨迹的形状特征。

(4) $\gamma_m=[b, g, T]^T \in \mathbf{R}^{5 \times 1}$ 是轨迹基元的调整参量集, 是轨迹基元再生成时能做出调整变化的参量, 其中 b 和 g 分别是基元的初始位置与终止位置, T 则是基元持续的时间。

(5) $\mathbf{r}_{id}(t)=[\mathbf{O}(t-1), \mathbf{O}(t), \mathbf{O}(t+1)]^T \in \mathbf{R}^{9 \times 1}$ 于操控基元模型训练的多维时间序列数据, 包含了 $(t-1)$ 、 t 和 $(t+1)$ 这三个时刻的航向变化偏差, 速度和转向盘转角。

本文所提出的方法致力于解决如下的两个问题: 其一, 如何利用轨迹基元表征与分割提取的相关关系, 从连续的无标签轨迹数据中提取出离散的不同种类的轨迹基元; 其二, 如何构建操控基元与轨迹基元之间的关联, 继而提升操控基元对于驾驶操控行为的预测能力。

2 轨迹基元的表征与提取

轨迹基元表征与提取的具体流程如图2所示, 整个处理流程可被分解为初始分割点的设置, 基于 DMP 的轨迹基元表征以及轨迹基元概率提取算法这三个主要的组成部分。初始分割点集的设置既使得轨迹基元相对位置表征量的计算成为可能, 又可被作为概率提取算法分割点设置的初始集合; 基于 DMP 的表征算法在表征驾驶员行为的基础上, 又实现了轨迹基元属性特征集与调整参量集的分隔; 概率提取算法一方面基于一组加权的轨迹分段获取轨迹基元库特征参量集, 另一方面也通过将现有轨迹分段与轨迹基元库特征参量集进行匹配, 降低与基元库相似性较差的分割段的权重系数, 上述过程通过最大期望算法(Expectation-maximization, EM)算法反复迭代完成, 当算法收敛时便可同时得到轨迹基元特征参量集与合并后的分割点集。

图2 轨迹基元表征与提取算法流程

2.1 初始分割点的设置

由于轨迹基元的提取算法只是合并错误的轨迹初始分割点来获取最终的分割点, 而非直接找寻适当的轨迹分割点, 因此初始分割点的设置直接影响了基元提取算法的性能。为了保证提取算法的效率并实现对于连续轨迹数据一定程度上的过度分割, 初始分割点 C 的设置采用过零检测算法, 分别找寻航向变化偏差 $\Delta\theta$ 的过零点与直驶段中速度变化 Δv 的过零点。

基于航向变化偏差过零点所设定的初始分割点保证了转向过程的完整性, 使得转向过程中的驾驶员横纵向协同操控行为得以完整保留; 在直驶段中采用速度变化的过零点进行初始分割, 既消除了航向偏差在零位附近波动所生成的一系列错误初始分割点, 又保留了加减速和速度维持等一系列纵向驾驶操控基本行为。

由于所设定的初始分割点是过分割的结果, 因此它的每一个子集 $d \subseteq C$ 都将被视作可能的轨迹分割结果, 基元提取算法的任务就是从中找寻最适宜的分割结果 $d^* \subseteq C$ 。每一个轨迹分段 $s_{i,j} \in S$ 都由初始分割点 c_i 和 c_j 定义。由 d 所生成的轨迹分段 S , 将作为训练数据集用于后续轨迹基元的表征与提取算法中。

2.2 轨迹基元的表征算法

轨迹基元经由 DMP 分别对生成的相对位置变化量 x_m 和 y_m 进行表征, 具体表示形式为

$$\dot{v}_m = \tau \alpha_m (\beta_m (g_m - d_m) - v_m) + \tau (g_m - b_m) f(z_m) \quad (1)$$

$$\dot{d}_m = \tau v_m \quad (2)$$

$$\dot{z}_m = -\tau\alpha_z z_m \quad (3)$$

式中, $\mathbf{d}_m = [x_m, y_m]$ 和 $\mathbf{v}_m = [\dot{x}_m, \dot{y}_m]$ 分别是轨迹基元表征过程中的位置参量与速度参量。 $\mathbf{b}_m = [x_m(0), y_m(0)]$ 和 $\mathbf{g}_m = [x_m(T), y_m(T)]$ 分别是所选定基元的初始位置和终止时刻 T 的位置坐标, τ 为时间尺度参量, 用于时间基元在时间尺度上的伸缩调整。轨迹基元的表征形式为一个典型的弹簧阻尼系统附加一个非线性函数 $f(z_m)$ 。通过对 α_m 和 β_m 数值的设定使得系统为临界阻尼系统, 确保其能迅速稳定地收敛到所设定的最终位置。非线性函数 $f(z_m)$ 的存在是为了表征轨迹生成过程中的非线性变化, 该非线性函数由指数衰减函数 z_m 控制, z_m 的初始值被设定为 1, 经由预设参量 α_z 控制, 在终止时刻 T 收敛到 0, 确保非线性函数的作用在末尾处消除, 不对原有的临界弹簧阻尼系统产生影响。非线性函数 $f(z_m)$ 的定义如式(4)所示

$$f(z_m) = \frac{\sum_{n=1}^N \omega_n \psi_n(z_m) z_m}{\sum_{n=1}^N \psi_n(z_m)} \quad (4)$$

式中, $\psi_n(z_m) = \exp(-p_n(z_m - \mu_n)^2)$ 为高斯内核函数, μ_n 表征了高斯内核的位置参量, p_n 表征了内核的分布幅度, N 为高斯内核的总数目。 ω_n 为其中单一高斯内核的权重参量。

轨迹基元的学习就是推算非线性函数的权重系数集 ω_x 和 ω_y 以使得示范轨迹与学习得到的轨迹偏差最小的过程。参量 ω_x 和 ω_y 可以通过局部加权回归算法计算得到^[10]。对每一个经由分割点集 $\mathbf{d}$ 生成的轨迹分段集 $\mathbf{S}$ 使用上述求解方法, 便能够得到该分割结果下每一个轨迹基元的属性特征集 $\phi_m = [v_{\text{init}}, \omega_x, \omega_y]$, 该特征集将被用于后续的基元提取算法中, 作为不同种类轨迹基元的表征特征。此外, 由式(1)可知调整参量集 $\gamma_m = [\mathbf{b}, \mathbf{g}, T]$ 完全独立于属性特征参量之外, 该参量集只在轨迹基元再生成时应规划系统的实际需求做设定, 并未作为属性特征参量参与到轨迹基元的提取算法中。

2.3 轨迹基元的概率提取算法

在轨迹基元的概率提取算法中, 我们假设每一个轨迹分段 $\mathbf{s}$ 都是最终所建立的轨迹基元库中的一部分。轨迹基元库则是不同种类基元 $\mathbf{m}_m$ 的混合物, 因此所提取出的轨迹分段 $\mathbf{s}$ 属于该基元库的概率被定义为

$$p(\mathbf{s} | \Phi) = \sum_{m=1}^M \lambda_m p(\mathbf{s} | \phi_m) \quad (5)$$

$$\Phi = \{(\lambda_1, \phi_1), \dots, (\lambda_M, \phi_M)\} \quad (6)$$

式中, M 为基元库中基元种类的总个数, λ_m 为不

同种类基元的混合系数。所有观测到的轨迹数据 $\mathbf{o}$ 可以通过如下的参量模型表述

$$\mathbf{o} \sim p(\mathbf{o} | \Phi, \mathbf{S}^*) = \prod_{\mathbf{s} \in \mathbf{S}^*} p(\mathbf{s} | \Phi) \quad (7)$$

式中, $\mathbf{S}^*$ 为基于最适宜的分割点 $\mathbf{d}^*$ 所获取得到的适宜轨迹分段集, 但由于分割点 $\mathbf{d}^*$ 是要求解的参量, 因此将其视作待求解的隐变量代入到参量模型中去

$$p(\mathbf{o} | \Phi) = \sum_{\mathbf{S} \in \mathbf{D}} p(\mathbf{S}) \prod_{\mathbf{s} \in \mathbf{S}} p(\mathbf{s} | \Phi) \quad (8)$$

式中, $\mathbf{D}$ 为观测到的轨迹数据 $\mathbf{o}$ 所有可能的分割结果。所要求解的轨迹基元库表征参量可以通过下述的最大似然函数计算得到

$$\Phi^* = \arg \max_{\Phi} \sum_{\mathbf{o} \in \mathcal{O}} \lg p(\mathbf{o} | \Phi) \quad (9)$$

在 EM 中被用于反复最大化直到收敛的辅助函数被定义为

$$\Phi = \arg \max_{\Phi} Q(\Phi, \Phi') \quad (10)$$

$$Q(\Phi, \Phi') = \sum_{\mathbf{o} \in \mathcal{O}} \sum_{\mathbf{S} \in \mathbf{D}} p(\mathbf{S} | \mathbf{o}, \Phi') \times \lg(p(\mathbf{S}) p(\mathbf{o} | \Phi, \mathbf{S})) \quad (11)$$

式中, Φ' 为前一次迭代过程所获取的模型优化参量, 先验概率 $p(\mathbf{S})$ 被定义为

$$p(\mathbf{S}) = p_c \prod_{\mathbf{s} \in \mathbf{S}} p(c_s) \quad (12)$$

$$p(c_s) = (1 - p_c)^{c_s} p_c \quad (13)$$

式中, c_s 是轨迹分段 $\mathbf{s}$ 中所包含的初始分割点数目。 $p_c \in [0, 1]$ 表征了每一个初始分割点是适宜分割点的概率。

通过 EM 算法, 表征在现有轨迹基元库特征参量 Φ' 下分割结果 $\mathbf{S}$ 适宜程度的权重系数 $\alpha_s = \sum_{\mathbf{S} \in \mathbf{D}} p(\mathbf{S} | \mathbf{o}, \Phi')$ 在 E 步骤中依据式被更新; 基于 GMM 模型表征的特征参量 Φ 在 M 步骤中被更新, GMM 模型的最优总个数由贝叶斯判据决定^[24]。当算法收敛后, 便能够同时获得适宜的轨迹分割点 $\mathbf{d}^*$ 和表征不同类型轨迹基元的特征参量集 Φ^* 。

此外, 为了与概率提取算法相对比, 传统的非监督学习方法 EM-GMM 被用于直接对观测轨迹数据 $[\Delta\theta(t), v(t)]$ 进行聚类分析, 并利用离散的分类标签实现对连续轨迹数据的分割。

3 操控基元的表征与泛化

3.1 操控基元的表征

操控基元表征算法的具体处理流程如图 3 所示。

图3 操控基元表征算法流程

基于轨迹基元提取与分类的结果，首先对采集得到的驾驶数据进行标签化后，新生成的数据集为

$$\xi(t) = [\Delta\theta(t), v(t), \delta(t), id] = [O(t), id] \quad (14)$$

$$\bigcup_{id=1}^M O_{id} = O \quad \bigcap_{id=1}^M O_{id} = \emptyset \quad id = 1, 2, \dots, M \quad (15)$$

式中， id 表征轨迹基元的类型， O 为观测到的所有驾驶数据， O_{id} 是基于轨迹基元类型重新分组提取之后的数据集， M 是轨迹基元类型的总数目。

重组之后的数据集被用于构建操控基元的训练数据集

$$r_{id}(t) = [O_{id}(t-1), O_{id}(t), O_{id}(t+1)] \quad (16)$$

式中， $r_{id} \in \mathbf{R}^{9 \times 1}$ 是用于表征操控基元的 9 维时间序列数据组，分别针对每一个类型的操控基元数据组使用 GMM 模型进行训练，相应的操控基元 GMM 模型被表示为

$$G(r_{id} | \beta) = \sum_{i=1}^K p_i g_i(r_{id}; \mu_i, \Sigma_i) \quad (17)$$

$$g_i(r_{id}; \mu_i, \Sigma_i) = \frac{1}{\sqrt{(2\pi)^d |\Sigma_i|}} \exp \left[-\frac{1}{2} (r_{id} - \mu_i)^T \Sigma_i^{-1} (r_{id} - \mu_i) \right] \quad (18)$$

式中， $\mu_i \in \mathbf{R}^{9 \times 1}$ 和 $\Sigma_i \in \mathbf{R}^{9 \times 9}$ 分别是 GMM 模型的均值矩阵与协方差矩阵， p_i 是其中一个高斯模型的权重系数，并且 $\sum_{i=1}^K p_i = 1$ ， K 为高斯模型的总个数。所求解的高斯模型参量为 $\beta = \{\beta_i\}_{i=1}^K$ ，其中 $\beta_i = \{\mu_i, \Sigma_i, p_i\}$ 。

利用极大似然函数和 EM 算法^[24]，可求得相应的高斯模型参量 β 。为了避免算法陷入局部最小，K 平均算法被用于参量初始值的估计。

当针对重组后的操控基元数据进行训练后，便可以获得针对每一个轨迹基元类型的 GMM 模型参量集 $\beta_{id} = \{\mu_{id}, \Sigma_{id}, p_{id}\}$ 。该参量集将被用于后续的操控基元泛化算法中。

3.2 操控基元的泛化

基于轨迹基元泛化再生成的操控基元泛化生成

的具体步骤如图 4 所示。

图4 操控基元泛化再生的算法流程

操控基元的泛化由高斯回归算法 (Gaussian mixture regression, GMR) 算法完成，基元泛化的过程可以由下式表示，即在给定 GMM 模型 λ_{id} 与 t 时刻操控基元泛化的输入量 $\eta(t)$ 的前提下，对驾驶员下一时刻的转向盘转角 $\hat{\delta}(t+1)$ 进行预测估计

$$\lambda_{id}(r_{id}(t)): \eta(t) \mapsto \hat{\delta}(t+1) \quad (19)$$

$$\eta(t) = \{[\Delta\theta(t-1), v(t-1), \delta(t-1)], [\Delta\theta(t), v(t), \delta(t)], [\Delta\theta(t+1), v(t+1)]\} \quad (20)$$

对给定 GMM 模型 λ_{id} 中每一个高斯模型的表征参量进行输入量与输出量的参量分离，是实现泛化的基础，分离后第 k 个高斯模型的参量可表示为

$$\mu_k = \{\mu_k^{in}, \mu_k^{es}\} \quad (21)$$

$$\Sigma_k = \begin{pmatrix} \Sigma_k^{in} & \Sigma_k^{in,es} \\ \Sigma_k^{es,in} & \Sigma_k^{es} \end{pmatrix} \quad (22)$$

式中，上标 in 表征输入的参量， es 表征输出的参量。经由给定模型参量与输入参量估计得到的输出量 $\hat{\mu}_k^{es}$ 和 $\hat{\Sigma}_k^{es}$ 如式(23)、(24)所示

$$\hat{\mu}_k^{es} = \mu_k^{es} + \Sigma_k^{es,in} (\Sigma_k^{in})^{-1} (\eta(t) - \mu_k^{in}) \quad (23)$$

$$\hat{\Sigma}_k^{es} = \Sigma_k^{es} - \Sigma_k^{es,in} (\Sigma_k^{in})^{-1} \Sigma_k^{in,es} \quad (24)$$

在基于 GMM 模型中第 k 个高斯模型对预测量的均值与方差进行估计后，将 GMM 模型中共 K 个高斯模型所得的预测量进行合并，得到最终的驾驶员转向盘转角估计量的均值 $\hat{\mu}^{es}$ 和方差 $\hat{\Sigma}^{es}$ 可由下式计算得到

$$\varphi_k = \frac{p_k}{\sum_{i=1}^K p_i} \quad (25)$$

$$\hat{\mu}^{es} = \sum_{k=1}^K \varphi_k \hat{\mu}_k^{es} \quad (26)$$

$$\hat{\Sigma}^{es} = \sum_{k=1}^K \varphi_k^2 \hat{\Sigma}_k^{es} \quad (27)$$

4 试验结果与讨论

4.1 数据采集平台及所建立的驾驶员数据库

驾驶员行为数据由如图5所示的智能车辆平台采集得到。该平台搭载了 OxTs Inertial+GNSS/INS 组合导航系统, 前向的两台 Mako 相机, 32 线激光雷达 Velodyne LIDAR HDL-32E, 以及两台工控计算机 ARK-3520P-U8A1E 组成, 和一个 CAN 数据采集单元 CANoe。车辆自身的数据参量经由 CAN 网获取, 其余的信息传输由两台 EKI-2528PAI 数据交换机完成。所采集的来自不同传感器的数据都标注有统一的时间戳信息, 便于后续的数据同步处理。

图5 驾驶员数据数据采集智能车平台

为了尽可能多地采集不同交通场景下的驾驶员驾驶数据, 整个数据采集试验囊括了高速公路, 路口, 环路等典型驾驶情况。所采集的数据集共包含 81 h 的数据, 速度涵盖了 0~120 km/h 的整个区间, 并包含了直角弯, 换道, 超车等典型驾驶行为基本单元。由于运动基元的提取与泛化仅用于表征单一驾驶员的个性化操控特性, 因此只从整个数据集中挑选出了一个驾驶员的操控数据进行建模分析, 数据总时长为 12 h。

轨迹基元与操控基元的数据集 $\mathcal{O}$, 由 CAN 网所采集的车辆行驶速度 v 和转向盘转角 δ , 以及经由组合导航系统所获取的航向偏差 $\Delta\theta$ 组成, 数据的采样周期为 0.1 s。此外, 由于所提出的算法不具备对紧急情况下突变操控量的拟合能力, 因此所有的突发情况借助于所采集的图像数据完成剔除, 得到最终的模型训练用数据集。轨迹基元 m 中的相对位置参量, 由速度和航向偏差根据采样时间积分生成。

4.2 轨迹基元的表征能力分析

轨迹提取算法共生成了 53 种不同类型的轨迹基元, 基元的种类数量由表征轨迹基元属性特征集 ϕ_m 的高斯模型的数目决定。当随机选择的数据量达到 7 h, 基元库总体的类别数目达到稳定状态, 不再

随数据量的增加而出现较大变化。所提取出轨迹基元的总体情况如表1所示, 表1中根据是否有转向操作和轨迹基元的初始速度 v_{init} 对行驶场景进行了划分, 并列举了每一个场景下的轨迹基元种类个数 N_m 以及该场景数据占训练数据的百分比。此处仅选择一种典型的包含驾驶员横纵向操控配合规律的直角弯基元作为表征能力分析的依据。

表1 轨迹基元库总体情况

行驶场景	初始速度 $v_{\text{init}} / (\text{km/h})$	种类个数 N_m	百分比 $N_m/M(\%)$
直驶	0~120	19	69.34
低速转向	0~30	14	5.12
中速转向	30~75	12	17.01
高速转向	75~120	8	8.53

轨迹基元对于驾驶员轨迹数据的拟合能力以位置偏差 Δd 和速度偏差 Δv 作为评价指标。由于 DMP 算法中的非线性函数是表征轨迹形状变化的重要因素, 非线性函数中的高斯内核又是其中核心的组成部分。因此, 轨迹基元表征试验共选定了三组高斯内核参量对表征精度进行对比分析, 这三组内核参量为: $(N=10, \sigma=0.1)$, $(N=20, \sigma=0.05)$, $(N=20, \sigma=0.025)$ 。其中 N 表示高斯内核的总个数, σ 表示高斯内核的分布幅度, σ 的数值是基元时间尺度 T 归一化之后的结果。最终轨迹基元的表征结果如图6所示。

图6 轨迹基元表征结果

图6分别呈现了不同内核参量的轨迹基元对驾驶员数据从位置和速度两个层面的拟合结果,以及相应的表征偏差。从中可以得到,虽然基于三种不同内核参数表征的轨迹基元都能够以较高的精度完成对驾驶员示范轨迹的拟合,但随着高斯内核参量数目 N 的提升,以及内核分布幅度 σ 的缩减,位置偏差 Δd 和速度偏差 Δv 都有不同程度的减少。其中,当高斯内核的分布规律 $\sigma = 1/N$ 维持不变,高斯内核的数目 N 从10提升为20时,平均位置偏差 $\Delta \bar{d}$ 减少69.12%,平均速度偏差 $\Delta \bar{v}$ 减少68.76%;当高斯内核的数目 $N=20$ 不变,而高斯内核的重叠区域变小时, $\Delta \bar{d}$ 减少72.67%, $\Delta \bar{v}$ 减少48.29%。一般意义上来说,越密集的高斯内核对轨迹在整个时间周期里的非线性变化描述越细致,但在增大高斯内核数目 N 的同时,也需要适当的调整分布幅度 σ ,避免出现过大的重叠区域,使得临近高斯内核之间产生相互干扰。

此外,无论是何种高斯内核参量组合在基元的结尾处都会出现远高于平均偏差水平的差值,原因是 $f(z_m)$ 是衰减量 z_m 的函数,当 z_m 在结尾处趋近于0时,非线性函数对于轨迹形状的拟合能力将大幅度削弱,因此也就形成了较大的速度偏差,三组内核参量在结尾处的速度偏差 Δv 分别是平均值的5.3

倍、8.2倍和10.4倍。

4.3 轨迹基元的提取分析

为了评估概率提取算法的效果,轨迹基元提取试验共选定了两个典型的驾驶片段,每个片段里又分别包含了多个基本的轨迹基元。此外,典型的非监督学习算法EM-GMM也被引入作为对比,来凸显提出的概率提取算法在对连续轨迹进行分割时的优势。图7、8针对每一个驾驶片段,分别展示了算法所设定的初始分割点,概率提取算法合并之后的分割点,概率提取算法给定的最终提取结果以及对比算法EM-GMM给定的提取结果。

在低速驾驶片段中(图7),基于航向偏差的初始分割点为42个,基于加速度的初始分割点为34个;概率提取算法最终形成的分割点为初始分割点总数的26.19%。有效合并了由于行车速度抖动所形成的

(a) 初始分割点

(b) 概率提取算法合并后的分割点

(c) 概率提取算法轨迹基元提取结果

图7 低速情况下的轨迹基元提取结果

初始分割点; 概率提取算法最终共形成 10 个分段, 提取出 8 种不同类型的轨迹基元, EM-GMM 算法最终共形成 26 个分段, 提取出 9 种不同类型的轨迹基元。

图8 高速情况下的轨迹基元提取结果

在高速驾驶片段中(图8), 概率提取算法合并了 50% 的基于航向偏差的初始分割点, 以及 93.55% 的基于加速度的初始分割点, 并最终形成了 5 个分段, 提取出 3 种不同类型的基元; EM-GMM 算法则形成了 17 个分段, 提取出 3 种不同类型的轨迹基元。

从图 7c、7d 和图 8c、8d 中可以观察得到, 概率提取算法总能保证转向过程与加减速过程的完整性, 而 EM-GMM 算法总是中断完整的转向过程, 这一现象在包含最多转向控制操纵可能的低速行驶情况下显得尤为明显。此外, EM-GMM 算法也未能对直驶过程中的加减速分段进行分割提取。这主要是因为提出的概率提取算法是在初始分割点的基础上对错误的初始分割点进行合并, 而非利用非监督学习算法直接去找寻正确的分割点。因此, 只要确保初始分割点是基于先验的驾驶经验所设定的, 最终的分割结果就会更贴近于实际的驾驶情况。

4.4 操控基元的表征能力分析

操控基元的表征分析采用与轨迹基元提取算法同样的驾驶分段数据进行, 并以转向盘转角预测值与真实值的平均偏差 $\Delta\bar{\delta}$ 和所生成预测值的确定度两方面进行评价, 其中不确定度以预测值的方差 $\hat{\Sigma}^{es}$ 表征。图 9、10 分别呈现了利用轨迹基元与操控基元之间关联关系进行转向操控量预测的结果, 以及不考虑上述关联关系的预测结果。转向操控量预测的误差带以 $[\hat{\mu}^{es} - 3 \times \hat{\sigma}^{es}, \hat{\mu}^{es} + 3 \times \hat{\sigma}^{es}]$ 呈现。

图 9 低速情况下的操控量预测结果

(a) 基于双层结构的操控量预测结果

(b) 未考虑分层关系的操控量预测结果

图 10 高速情况下的操控量预测结果

从图 9、10 中可以观察到，考虑双层基元架构得到的预测结果无论从预测值与真实值的偏差还是预测的不确定度两个方面都明显优于不考虑轨迹与操控关联关系的预测结果。其中，平均预测偏差 $\Delta\bar{\delta}$ 在低速驾驶段中为 1.95°，仅为对比方案的 10.91%；在高速驾驶片段中，相应的数值变为 0.32° 和 19.35%。此外，双层架构生成的预测误差带总能囊括真实的驾驶操控数据；从不确定度的数值角度分析，低速驾驶片段的平均不确定度仅为对比方案的 17.56%，高速段则为 29.37%。

4.5 动基元的再生成分析

此处，以调整参量集 γ_m 为依托，对运动基元的目标位置和时间尺度进行调整，运动基元选用与轨

迹基元表征分析中相同的直角弯基元进行。期望位置和时间尺度调整时，运动基元再生成时的位置坐标，纵向速度以及横向转向盘转角变化如图 11、12 所示。

(a) 调整后位置变化

(b) 调整后速度变化

(c) 调整后转向盘转角变化

图 11 期望位置调整后的运动基元各参量变化

(a) 调整后位置变化

图12 时间尺度调整后的运动基元各参量变化

在对目标位置的调整过程中,以期调整量 Δd 与实际调整量之间的差值 e_d 作为评价指标,具体的偏差结果如表2所示。在时间尺度的调整过程中,速度和转向盘转角随时间尺度进行伸缩,所设定的期望时间值与实际生成的时间值始终一致。

表2 目标位置调整产生的偏差分析

期望调整量 Δd /m	差值 e_d /m	偏差率 $e_d/ \Delta d $ (%)
+0.5	0.029 3	5.85
-0.5	0.035 8	7.16
+1	0.026 3	2.63
-1	0.039 1	3.91
+5	0.064 5	1.29
-5	0.068 1	1.36

依据DMP基元表征算法中的调整参量集 γ_m 所进行的期望位置和时间尺度的调整,是所学习得到的运动基元用于运动规划算法时所必须具备的调整能力。基于上述调整能力,同一类型的运动基元能够根据规划系统的实际需求在再生成时做出相适应的调整,极大程度上提升了单一运动基元应对交通场景变化时的适应能力;此外,在以DMP表征算法为依据的基元类型辨识过程中,不同目标位置和时间尺度的轨迹基元能够被辨识为同一类型的运动基元,只要轨迹基元的属性特征 ϕ_m 维持不变,从而大幅度缩减了运动基元库中基元的种类。

5 结论

(1) 分别运用DMP和GMM算法对轨迹基元和操控基元进行表征,在构建两者关联关系的基础上,实现了对驾驶员操控数据的高精度表征。其中轨迹形状表征属性参量集 ϕ_m 满足了纵横向协同控制规律的学习表征需求,调整参量集 γ_m 满足了基元应对期望轨迹生成时的泛化再生需求。

(2) 概率提取算法基于基元表征参量集 ϕ_m 与基于特定驾驶假设的分割点集 C ,利用EM算法实现了对初始分割点中错误分割点的合并,最终生成了较为紧凑并且符合特定驾驶假设的基元提取与分类结果。

(3) 运动基元的提取与再生成可以实现对驾驶员经验的表征与复现,从而为打造符合个性化驾驶员感受的无人车运动规划控制系统打下良好的基础。

参 考 文 献

- [1] GUO C, KIDONO K, MACHIDA T, et al. Humanlike behavior generation in urban environment based on learning-based potentials with a low-cost lane graph[J]. IEEE Transactions on Intelligent Vehicles, 2018, 3(1): 197-203.
- [2] GU T, DOLAN J M. Toward human-like motion planning in urban environments[C]// 2014 IEEE Intelligent Vehicles Symposium Proceedings. IEEE, 2014: 350-355.
- [3] DUAN J, LI R, HOU L, et al. Driver braking behavior analysis to improve autonomous emergency braking systems in typical Chinese vehicle-bicycle conflicts[J]. Accident Analysis & Prevention, 2017, 108: 74-82.
- [4] LI G, LI S E, CHENG B. Field operational test of advanced driver assistance systems in typical Chinese road conditions: The influence of driver gender, age and aggression[J]. International Journal of Automotive Technology, 2015, 16(5): 739-750.
- [5] 胡满江, 边有钢, 许庆, 等. 自适应驾驶员行为特征的车道偏离防范系统[J]. 汽车工程, 2017, 39(10): 1152-1157. HU Manjiang, BIAN Yougang, XU Qing, et al. Lane departure prevention system adapted to driver behavior characteristics[J]. Automotive Engineering, 2017, 39(10): 1152-1157.
- [6] 王其东, 魏振亚, 陈无畏, 等. 基于参数时变人工势场的车道保持协调控制[J]. 机械工程学报, 2018, 54(18): 105-114. WANG Qidong, WEI Zhenya, CHEN Wuwei, et al.

- Lane keeping coordination control based on parameter-varying artificial potential field[J]. *Journal of Mechanical Engineering*, 2018, 54(18): 105-114.
- [7] 陈无畏, 胡振国, 汪洪波, 等. 基于可拓决策和人工势场法的车道偏离辅助系统研究[J]. *机械工程学报*, 2018, 54(16): 134-143.
- CHEN Wuwei, HU Zhenguo, WANG Hongbo, et al. Study on extension decision and artificial potential field based lane departure assistance system[J]. *Journal of Mechanical Engineering*, 2018, 54(16): 134-143.
- [8] MARTINZE C M, HEUCKE M, WANG F Y, et al. Driving style recognition for intelligent vehicle control and advanced driver assistance: A survey[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 19(3): 666-676.
- [9] OLAVERRI-MONREAL C, JIZBA T. Human factors in the design of human-machine interaction: An overview emphasizing V2X communication[J]. *IEEE Transactions on Intelligent Vehicles*, 2016, 1(4): 302-313.
- [10] ARGALL B D, CHERNOVA S, VELSOLO M, et al. A survey of robot learning from demonstration[J]. *Robotics and Autonomous Systems*, 2009, 57(5): 469-483.
- [11] IJSPEERT A J, NAKANISHI J, HOFFMANN H, et al. Dynamical movement primitives: Learning attractor models for motor behaviors[J]. *Neural Computation*, 2013, 25(2): 328-373.
- [12] KRUGER V, HERZOG D L, BABY S, et al. Learning actions from observations[J]. *IEEE Robotics & Automation Magazine*, 2010, 17(2): 30-43.
- [13] MANSCHITZ S, KOBER J, GIENGER M. Learning to sequence movement primitives from demonstrations[C]// 2014 IEEE/RSJ International Conference on Intelligent Robots and Systems. IEEE, 2014: 4414-4421.
- [14] MULLING K, KOBER J, KROEMER O, et al. Learning to select and generalize striking movements in robot table tennis[J]. *The International Journal of Robotics Research*, 2013, 32(3): 263-279.
- [15] MORI M, TAKENAKA K, BANDO T, et al. Automatic lane change extraction based on temporal patterns of symbolized driving behavioral data[C]// 2015 IEEE Intelligent Vehicles Symposium(IV). IEEE, 2015: 976-981.
- [16] ZHAO H, WANG C, LIN Y, et al. On-road vehicle trajectory collection and scene-based lane change analysis: Part I[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 18(1): 192-205.
- [17] YAO W, ZENG Q, XU D, et al. On-road vehicle trajectory collection and scene-based lane change analysis: Part II[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 18(1): 206-220.
- [18] HE X, XU D, ZHAO H, et al. A human-like trajectory planning method by learning from naturalistic driving data[C]// 2018 IEEE Intelligent Vehicles Symposium (IV). IEEE, 2018: 339-346.
- [19] 孙杨, 熊光明, 陈慧岩, 等. 基于混沌理论的无人驾驶车辆行驶轨迹量化分析[J]. *机械工程学报*, 2016, 52(2): 127-133.
- SUN Yang, XIONG Guangming, CHEN Huiyan, et al. Quantitative analysis of unmanned ground vehicles trajectories based on chaos theory[J]. *Journal of Mechanical Engineering*, 2016, 52(2): 127-133.
- [20] YI D, SU J, LIU C, et al. Trajectory clustering aided personalized driver intention prediction for intelligent vehicles[J]. *IEEE Transactions on Industrial Informatics*, 2018, 15(6): 3693-3702.
- [21] BENDER A, AGAMENNONI G, WARD J, et al. An unsupervised approach for inferring driver behavior from naturalistic driving data[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2015, 16(6): 3325-3336.
- [22] TANIGUCHI T, NAGASAKA S, HITORNI K, et al. Sequence prediction of driving behavior using double articulation analyzer[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2016, 46(9): 1300-1313.
- [23] HAMADA R, KUBO T, IKEDA K, et al. Modeling and prediction of driving behaviors using a nonparametric bayesian method with ar models[J]. *IEEE Transactions on Intelligent Vehicles*, 2016, 1(2): 131-138.
- [24] 王博洋, 龚建伟, 高天云, 等. 基于高斯混合-隐马尔可夫模型的速差转向履带车辆横向控制驾驶员模型[J]. *兵工学报*, 2017, 38(12): 2301-2308.
- WANG Boyang, GONG Jianwei, GAO Tianyun, et al. Steering control driver model of skid steering vehicle based on gaussian mixture model-hidden markov model[J]. *Acta Armamentarii*, 2017, 38(2): 2301-2308.

作者简介: 王博洋, 男, 1991年出生, 博士研究生。主要研究方向为无人车运动规划和控制。

E-mail: wbythink@163.com

龚建伟(通信作者), 男, 1969年出生, 博士, 教授, 博士研究生导师。主要研究方向为无人驾驶车辆、机器学习、运动规划与控制、车辆动力学建模和环境感知。

E-mail: gongjianwei@bit.edu.cn