基于弹性分析与函数回归模型的示教轨迹学习与泛化方法

肖宏远, 刘成菊*, 陈启军

同济大学电子与信息工程学院, 上海 201804

* 通信作者. E-mail: liuchengju@tongji.edu.cn

收稿日期: 2021-08-02; 修回日期: 2021-09-30; 接受日期: 2021-11-15; 网络出版日期: 2022-10-09

国家自然科学基金 (批准号: 61733013, 62173248, 62073245) 资助项目

摘要 示教学习是解决仿人机器人动态轨迹规划问题的高效方法. 示教轨迹作为一种函数型数据, 天然地具有耦合的时空特征, 需要在函数型数据分析的理论框架下进行研究. 传统的示教学习成果以“预处理”的形式解决上述耦合问题, 不能充分利用示教轨迹的函数型数据本质. 为了充分利用这一本质, 本文采用弹性分析方法, 将示教轨迹视作函数型数据, 解决它们的时-空特征解耦问题. 基于解耦后的示教轨迹, 本文建立函数型回归模型并将其应用于动态轨迹的生成, 实现示教轨迹在不同任务参数下的泛化. 在实验中, JACO-2 机械臂学习形态各异的技能并在不同的任务参数下完成任务, 验证了提出方法的有效性. 本文在统一的数学框架下, 基于函数型数据分析的数学方法, 解决一类仿人机器人的示教轨迹学习与泛化问题, 具有较好的理论统一性与可实践性.

关键词 示教学习, 轨迹生成, 函数型数据, 弹性分析, 函数回归模型

1 引言

机器人逐渐开始在动态环境下扮演“人类协同者”的角色, 这一趋势要求它们具有运动层面的学习能力, 并能够在所学运动的基础上产生新的行为, 从而完成期望的任务. 对于机器人, 特别是仿人机器人, 完成任务离不开其机构的运动, 机构的运动又可以通过工作空间轨迹或关节空间轨迹描述. 于是, 运动的学习和新运动的生成问题就自然地成为了轨迹的学习问题与动态轨迹的生成问题.

示教学习在动态轨迹生成上的应用得到广泛关注. 示教学习解决动态轨迹生成问题的基本思想是: 施教者通过示教的方式让机器人完成某个任务, 得到一系列示教轨迹. 示教学习算法从示教轨迹中提取动作基元 (movement primitive), 描述蕴含在示教轨迹中关于任务的先验知识, 用于动态轨迹的生成. 动态轨迹的生成在很大程度上依赖于动作基元是否对示教轨迹特征进行了完备、正确的描述.

引用格式: 肖宏远, 刘成菊, 陈启军. 基于弹性分析与函数回归模型的示教轨迹学习与泛化方法. 中国科学: 信息科学, 2022, 52: 1822–1836, doi: 10.1360/SSI-2021-0259
Xiao H Y, Liu C J, Chen Q J. Learning and generalizing demonstration trajectories based on elastic analysis and the functional regression model (in Chinese). Sci Sin Inform, 2022, 52: 1822–1836, doi: 10.1360/SSI-2021-0259

动作基元的数学模型包括确定性模型和随机性模型. 确定性模型是对单一示教轨迹的抽象, 随机性模型则包含了对多个示教轨迹的统计学分析. 作为示教学习应用于轨迹生成的经典工作, 由 Ijspeert 等^[1]提出的动态动作基元 (dynamic movement primitive, DMP) 是一种基于非线性系统的确定性模型. DMP 在虚拟的二阶弹簧-阻尼系统中引入非线性的强迫项, 赋予动作基元模仿能力和改变轨迹末端特性的能力. 该非线性项以径向基函数进行参数化并通过示教轨迹离线学习. 类似地, 这种在动态系统中引入未知项并进行学习的方法, 被 Sun 等^[2]应用在磁悬浮列车的稳定性控制中, 在线估计参数化的周期干扰. 以 Ijspeert 的工作^[1]为基础, 后续的研究者既着眼于单个 DMP 模型泛化能力的提高, 也着眼于研究多个 DMP 模型之间的联系. 由 Kober 等^[3,4]提出的多项式方法, 使得新的 DMP 模型具有直至加速度的控制能力, 并应用于仿人机器人的击球动作学习与泛化中; 王健发等^[5]使用四元数 DMP (quaternion-based DMP) 实现无奇异的姿态表示, 通过引入新的非线性项以应对示教轨迹起-终点相近时产生的规划失效问题. Kulvicius 等^[6,7]通过显式时间相关的 DMP 模型实现多 DMP 轨迹之间的光滑拼接, 并应用于手写字母的连笔书写.

DMP 作为一种仅使用单一示教轨迹的动作基元, 它天然地不能描述一族示教轨迹的统计特性, 仅依赖于动态系统的收敛域来描述轨迹族在空间上的分布. 为了解决由“单示教轨迹-确定性模型组合”带来的问题, 后续的研究者开始转向基于多示教轨迹和随机模型的动作基元. 其中, 得到广泛研究的是基于高斯混合模型 (Gaussian mixture model, GMM) 与高斯混合回归 (Gaussian mixture regression, GMR) 的 GMM-GMR 方法. 该方法使用 GMM 描述输入-输出序列的联合分布, 将该联合分布作为先验知识, 基于 GMR 在新的输入下进行推理, 产生光滑的动态轨迹. 上述的联合分布既可以是“时间-状态”的联合分布, 也可以是“状态-状态变化率”的联合分布. Calinon 等^[8]使用 GMM 建立时间与机器人状态的联合分布, 产生无限时间可微的光滑泛化轨迹. Khansari-Zadeh 等^[9,10]则复用 DMP 方法的思想, 使用 GMM 建模机器人状态与其变化率的联合分布, 建立隐式的动态系统作为动作基元, 并应用于各类离散型运动 (discrete movements) 的示教学习与泛化.

在经典 GMM-GMR 方法的基础上, 为了使用参数化的任务输入控制轨迹的泛化, 一些研究者致力于研究 GMM-GMR 方法的任务参数化 (task-parametrization). Calinon 在其 GMM-GMR 方法研究^[8]的基础上提出了任务参数化 GMM 方法 (task-parametrized GMM, TP-GMM), 该方法引入多个任务相关的参考坐标系, 利用泛化轨迹在这些坐标系下的一致性实现参数化的轨迹泛化^[11,12]. 以此为基础, Sena 等^[13]通过引入参考坐标系的任务关联性评估, 使得新的模型具有良好的局部特性还原能力, 从而增强 TP-GMM 的泛化能力; Huang 等^[14]从强化学习的角度对任务参数 (task-parameters) 进行优化, 解决了人工选择参考坐标系所带来的不合理性.

在示教学习的两类代表性方法中, DMP 方法具有简单的数学形式与良好的收敛性质, 并且能够通过关联任务与吸引子, 自然地实现任务参数化. 但是, 由于采用单示教轨迹, DMP 方法并不能够学习示教轨迹族的统计特性, 其产生的泛化轨迹依赖于非线性系统的收敛行为, 限制了轨迹的末端特性. GMM-GMR 方法极大地拓展了动作基元从多个示教轨迹中学习的能力, 却需要复杂的额外设计才能实现任务参数化的轨迹泛化. 另一方面, 示教轨迹是对仿人机器人执行技能与完成任务过程的观测, 是一种函数型数据^[15]. 一系列示教轨迹 (对上述光滑过程的多次观测) 之间既具有空域上的可变性, 也具有时域上的可变性, 这是函数型数据的重要特征. GMM-GMR 方法的相关研究为了应对这种时-空域可变性, 采用动态时间规整^[16,17] (dynamic time warping, DTW) 在时间上对齐一系列示教轨迹. DTW 方法是解决示教轨迹时间对齐问题的朴素方法, 通过寻找满足一定约束的离散规整路径, 在标准 $\mathbb{L}^2$ 范数下最小化一对轨迹之间的距离. 在示教学习领域外, 示教轨迹的时间对齐问题具有更为宽泛的形式, 包括一维曲线的时间对齐问题^[18,19], 医学影像的配准问题^[20,21]与高维曲线^[22,23]、曲

图 1 (网络版彩图) 完成“提起袋子”任务的 4 条原始示教轨迹, 展示其空域特征 (a) 与时域特征 (b)

Figure 1 (Color online) Un-warped demonstrations of the bag-lifting skill, showing their spatial (a) and temporal (b) features

面^[24]的连续形态分析问题. 在这些方法中, 一系列基于弹性分析 (elastic analysis) 的方法^[21~23]通过引入平方根速度函数 (square-root velocity function, SRVF) 表示, 辅助以良好定义的度量, 在函数空间的角度赋予高维配准问题良好的数学形式, 解决了 DTW 方法存在的挤压效应 (pinching effect) 与不对称度量问题.

为了充分利用示教轨迹的函数型数据本质, 从具有时-空耦合特征的一系列示教轨迹中建立动作基元, 自然地实现任务参数化, 本文引入弹性分析方法对示教轨迹进行时-空特征解耦. 对于解耦后的示教轨迹, 本文进一步引入函数型回归模型, 利用它对标量与函数的兼容性建立具有任务参数化能力的动作基元, 并利用它产生动态轨迹. 最后, 本文针对 3 个在工作空间具有各异形态的技能与任务, 在 JACO-2 机械臂上验证了本文提出方法的有效性.

2 基于弹性分析的示教轨迹空域特征学习方法

正如前文所指出的, 示教轨迹是一种函数型数据^[15], 具有内在光滑性与耦合的时-空特征. 我们以图 1 为例, 说明示教轨迹具有的耦合时-空特征. 图 1(a) 记录了 4 条关于“提起袋子”技能的示教轨迹, 表现它们的空域 (spatial) 特征; 图 1(b) 从上至下分别为 x, y, z 轴上各个示教轨迹的时域 (temporal) 特征. 观察各示教轨迹在 z 轴的时域特征 (图 1(b) 第 3 行) 可以直观地感受到, 尽管各个示教轨迹在空域的运动模式 (pattern) 较为相似, 从时域角度来看也具有相位的差别. 换言之, “相似的空域特征”受到了“不一致的时域特征”的影响, 导致“相似的空域特征”在示教轨迹的观测区间内先后出现.

在函数型数据分析 (functional data analysis) 中, 可以通过函数配准 (functional registration) 解决上述的时-空特征耦合问题. 在其他的研究领域, 函数配准被赋予规整 (warping)、对齐 (aligning)、同步 (synchronization) 等不同的名字. 虽然称呼各异, 但是这些称呼背后具有一致的数学本质. 在下文中我们统称这类问题为函数配准问题. 弹性分析方法是解决函数配准问题的一类良好方法. 本节将示教轨迹视作函数型数据, 使用弹性分析方法解决示教轨迹的配准问题. 进而从时间对齐的示教轨迹中, 学习它们所蕴含的空域特征.

2.1 示教轨迹的表示与规整函数

考虑参数化曲线 $f: D \rightarrow \mathbb{R}^n$, 其中 $D \subset \mathbb{R}$ 为某个合适的参数域. 不失一般性地, 令抽象时间区间 $D = [0, 1]$ 为参数域, 并且要求上述参数化曲线 f 在 D 上绝对连续. 将满足上述性质的曲线作为示教轨迹的表示.

进一步地, 为表述示教轨迹的时间域特征, 考虑广义规整函数空间 (warping space) Γ , 其中每个元素 $\gamma: [0, 1] \rightarrow [0, 1]$ 都是定义在参数域 D 上的规整函数 (warping function), 并满足如下的数学性质: 边界条件 $\gamma(0) = 0, \gamma(1) = 1$; 复合封闭性 $\forall \gamma_1, \gamma_2 \in \Gamma, \gamma_1 \circ \gamma_2 \in \Gamma$; 逆元 γ^{-1} 与单位元 $\gamma_{\text{id}} \triangleq t$ 的存在性. 对于满足上述条件的一系列规整函数, 使用 Γ 指代它们的全体. 规整函数 $\gamma \in \Gamma$ 作用于示教轨迹 f , 得到规整后的示教轨迹 $f \circ \gamma: D \rightarrow \mathbb{R}^n$, $f \circ \gamma$ 给出了示教轨迹的空域特征, γ 给出了示教轨迹的时域特征.

通过引入示教轨迹的参数化曲线表示与规整函数, 能够定义示教轨迹的时-空特征, 进而在弹性分析方法的框架下解决示教轨迹的函数配准问题. 为了使用弹性分析方法, 首先定义参数化曲线的 SRVF 表示. 一个具有式 (1) 形式的连续映射:

$$F(v) = \begin{cases} v\sqrt{\|v\|}, & \|v\| \neq 0, \\ 0, & \|v\| = 0, \end{cases} \quad (1)$$

作用于 $\dot{f}$, 得到 f 的 SRVF 表示

$$q = F(\dot{f}) = \dot{f}/\sqrt{\|\dot{f}\|}, \quad (2)$$

并且 q 是平方可积的, 可以简记 q 的全体为 $\mathbb{L}^2$. 在 SRVF 表示下, 规整函数对示教轨迹的规整作用记作 $f \circ \gamma$, 在规整函数作用下, f 和其 SRVF 表示 q 分别为

$$f(t) \rightarrow f \circ \gamma(t), \quad q(t) \rightarrow (q, \gamma) = q \circ \gamma(t) \cdot \sqrt{\dot{\gamma}(t)}.$$

2.2 基于弹性分析的示教轨迹配准方法

为了求解函数配准问题, 需要定义一个合适的度量来表示函数的“配准程度”. 较为直观的做法是使用参数化曲线全体 $\mathcal{F}$ 上的 $\mathbb{L}^2$ 度量来表达配准的最优性, 并相应地寻求 $\inf_{\gamma \in \Gamma} \|f_1 - f_2 \circ \gamma\|$ 得到一个 $\mathbb{L}^2$ 度量意义下最优的配准结果. 具体而言, 可以建立如下的优化问题:

$$\gamma_i^* = \min_{\gamma \in \Gamma} \|f_i \circ \gamma - \nu\|^2 + \lambda_{\mathcal{R}} \cdot \mathcal{R}(\gamma), \quad (3)$$

从而求解一系列待配准函数 f_i 关于某个共通模板 ν 的族配准 (group registration) 问题. 式 (3) 中 $\|\cdot\|$ 为标准的 $\mathbb{L}^2$ 范数, $\mathcal{R}: \Gamma \rightarrow \mathbb{R}$ 是正则化算子, 与正则化参数 $\lambda_{\mathcal{R}}$ 一同描述关于规整函数的粗糙惩罚 (roughness penalty).

式 (3) 的直觉做法的深层理念在于: 引入一个待估计的、影响时域的规整函数 γ 描述被观测函数 f_i 与模板 ν 之间的差异, 并由一个给定的度量 $\|\cdot\|$ 进行衡量; 进一步地, 为了控制规整函数 γ 的形态, 往往引入正则化算子. 这种直觉做法在非弹性方法 (non-elastic methods) 中得到较为广泛的应用. 以一些基于非弹性方法的早期工作为例: Ramsay 和 Li^[25] 关于函数配准的早期工作采用了式 (3) 的直觉做法, 解决一系列函数型数据关于某个目标函数 (target function) 的配准问题, 并采用微分算子 $D(\cdot)$ 构成正则化项 $\mathcal{R}(\gamma) \triangleq \frac{D^2(\gamma)}{D(\gamma)}$, 以确保规整函数是接近于单调递增的; 类似地, James^[26] 采用了更

为复杂的正则化项组合; Tang 等^[27] 引入分段线性基对规整函数进行参数化, 同时采用规整函数与标准规整函数的 $\mathbb{L}^2$ 距离 $\|\gamma_{\text{id}} - \gamma\|^2$ 作为正则化算子.

在医学图像配准的相关研究中, 也有学者利用式 (3) 构建损失函数. Christensen 和 Johnson^[20] 在关于 MRI (magnetic resonance imaging) 数据配准的研究中基于式 (3) 构建前 - 后向损失, 形成对称损失函数 $\mathcal{C}(T \circ \gamma_T, S) + \mathcal{C}(S \circ \gamma_S, T)$, 以解决一对三维图像 $\{S, T\}$ 的配准 (pair-wise registration) 问题. 为了更好地估计规整函数 γ_T, γ_S , Christensen 和 Johnson^[20] 在粗糙惩罚以外还引入了逆一致性 (inverse consistency) 约束, 确保前 - 后向规整函数之间的逆元关系, 从而得到一致的配准结果. Aganj 等^[28] 则在理论上分析了上述由前 - 后向损失一同构成的对称损失函数, 提出得到一致性配准结果的条件并加以满足.

与直觉做法不同的是, 弹性方法本质地替换直觉方法中使用的 $\mathbb{L}^2$ 度量为弹性度量 (elastic metric), 从而避免式 (3) 中损失函数的挤压效应与非一致性问题. Srivastava 等^[21~23, 29] 对弹性方法在曲线表示与配准方面的应用进行了充分的研究, 并针对一维函数型数据提出了基于 Fisher-Rao 度量的族配准方法^[29]. 弹性度量相较于 $\mathbb{L}^2$ 度量的优点在于其关于 $\mathcal{SO}(n)$ 作用^[22] 和重参数作用^[22, 29] 的不变性. 在一维的情形下, 弹性度量成为 Fisher-Rao 度量 $d_{\text{FR}}(\cdot, \cdot)$, 并且仅需考虑重参数作用 (即配准函数的右结合作用) $(\cdot) \circ \gamma$, 无需考虑 $\mathcal{SO}(n)$ 作用.

为了基于 Fisher-Rao 度量对示教轨迹进行配准, 我们考虑示教轨迹的每一个维度 $f^{(d)}$, 应用 Fisher-Rao 度量在重参数作用下的不变性可以得到

$$d_{\text{FR}}(f_1^{(d)}, f_2^{(d)}) = d_{\text{FR}}(f_1^{(d)} \circ \gamma, f_2^{(d)} \circ \gamma). \quad (4)$$

进一步地, 由于在 SRVF 表示下 Fisher-Rao 度量成为 $\mathbb{L}^2$ 上的 $\mathbb{L}^2$ 度量^[29], 将这一事实带入至式 (4) 得到

$$\|q_1^{(d)} - q_2^{(d)}\| = \|(q_1^{(d)}, \gamma) - (q_2^{(d)}, \gamma)\|. \quad (5)$$

至此, 我们能够使用具有良好性质的 Fisher-Rao 度量, 并通过 SRVF 快速计算. 可以利用 SRVF 重述示教轨迹每个维度 d 上的族配准问题:

$$\gamma_i^{(d)*} = \min_{\gamma \in \Gamma} \|\mu_n^{(d)} - (q_i^{(d)}, \gamma)\|, \quad (6)$$

其中 $\mu_n^{(d)}$ 是各个轨道空间 $[q_i^{(d)}]$ 的 Karcher 均值 $[\mu]_n^{(d)}$ 的中心^[29].

综上所述, 给定一族示教轨迹 f_i 并考虑它的每一个维度 $f_i^{(d)}$, 我们可以通过在每个维度上求解由式 (6) 所定义的族配准问题, 得到规整的示教轨迹 $\tilde{f}_i$. 这一规整示教轨迹的每个维度满足 $\tilde{f}_i^{(d)} = f_i^{(d)} \circ \gamma_i^{(d)*}$. 应用上述方法, 我们对图 1 中“提起袋子”技能的 4 条示教轨迹进行配准, 得到的一系列规整示教轨迹如图 2 所示.

图 2(a) 为规整后示教轨迹的空域特征, 图 2(b) 为 x, y, z 轴上规整示教轨迹的时域特征. 从图 2(b) 中我们可以看出, 弹性分析方法能够排除“不一致的时域特征”造成的影响, 充分地捕捉 (capture) 各个示教轨迹之间“相似的空域特征”.

2.3 示教轨迹的空域特征学习

我们将示教轨迹建模为绝对连续的参数化曲线, 通过弹性分析方法得到一系列规整示教轨迹 $\tilde{f}_i$. 规整示教轨迹的每个维度 $\tilde{f}_i^{(d)}$ 是原始示教轨迹的每个维度 $f_i^{(d)}$ 在最优规整函数 $\gamma_i^{(d)*}$ 作用下的结果. 一系列规整示教轨迹 $\tilde{f}$ 逐维度规整, 避免了时域特征的影响, 我们能够从其中学习空域特征. 为了学

图 2 (网络版彩图) 完成“提起袋子”任务的一系列规整示教轨迹, 展示其空域特征 (a) 与时域特征 (b)

Figure 2 (Color online) Warped demonstrations of the bag-lifting skill, showing their spatial (a) and temporal (b) features

习规整示教轨迹的空域特征, 将规整示教轨迹 $\tilde{f}: D \rightarrow \mathbb{R}^n$ 建模为某个线性时变随机微分方程的解, 并采用这一线性时变随机微分方程的离散形式^[30]. 考虑 M 个 N 点示教数据:

$$\mathbf{X}_m = [\mathbf{x}_m(t_0), \mathbf{x}_m(t_1), \dots, \mathbf{x}_m(t_N)], \quad \mathbf{x}_m(t_i) \in \mathbb{R}^n, \quad t_i \in D, \quad (7)$$

每一个示教数据都需要在时间区间 $[t_i, t_{i+1}]$ 上满足如下的状态转移关系:

$$\mathbf{x}_m(t_{i+1}) = \Phi(t_{i+1}, t_i) \mathbf{x}_m(t_i) + \mathbf{u}_{i,i+1} + \mathbf{w}_{i,i+1}, \quad \mathbf{w}_{i,i+1} \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}_{i,i+1}). \quad (8)$$

式 (8) 中的未知参数 $\Theta_{i,i+1} = \{\Phi_{i,i+1}, \mathbf{u}_{i,i+1}, \mathbf{Q}_{i,i+1}\}$ 可通过求解如下的最优化问题得到:

$$\Phi_{i,i+1}, \mathbf{u}_{i,i+1} = \min_{\Phi_{i,i+1}, \mathbf{u}_{i,i+1}} \sum_{m=1}^M \|\mathbf{r}_m\|^2 + \lambda \|\Phi_{i,i+1}\|_F^2, \quad \mathbf{Q}_{i,i+1} = \frac{1}{M} \sum_{m=1}^M \mathbf{r}_m \cdot (\mathbf{r}_m)^T, \quad (9)$$

其中 $\mathbf{r}_m = \mathbf{u}_{i,i+1} - \mathbf{x}_m(t_{i+1}) + \Phi_{i,i+1} \mathbf{x}_m(t_i)$ 为误差, λ 为正则化系数. 上述的最小化问题可以使用线性岭回归求解, 最终得到离散化的过程均值 $\boldsymbol{\mu} = \mathbf{A}\mathbf{u}$ 与过程方差 $\mathbf{K} = \mathbf{A}\mathbf{Q}\mathbf{A}^T$.

$\mathbf{A}, \mathbf{u}, \mathbf{Q}$ 由各时间区间 $[t_i, t_{i+1}]$ 上的参数 $\Theta_{i,i+1}$ 按照式 (10) 给出:

$$\mathbf{A} = \begin{bmatrix} \mathbf{1} & \mathbf{0} & \cdots & \mathbf{0} & \mathbf{0} \\ \Phi_{1,0} & \mathbf{1} & \cdots & \mathbf{0} & \mathbf{0} \\ \Phi_{2,0} & \Phi_{2,1} & \ddots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \mathbf{1} & \mathbf{0} \\ \Phi_{N,0} & \Phi_{N,1} & \cdots & \Phi_{N,N-1} & \mathbf{1} \end{bmatrix}, \quad (10)$$

$$\mathbf{u} = [\boldsymbol{\mu}_0, \mathbf{u}_{0,1}, \mathbf{u}_{1,2}, \dots, \mathbf{u}_{N-1,N}]^T, \quad \mathbf{Q} = \text{diag}(\mathbf{Q}_0, \mathbf{Q}_{0,1}, \mathbf{Q}_{1,2}, \dots, \mathbf{Q}_{N-1,N}).$$

至此, 我们得到了一系列示教轨迹在空域的均值 $\boldsymbol{\mu}$ 与方差 $\mathbf{K}$, 它们描述了完成某一个技能的轨迹族的空域分布, 是示教轨迹的重要空域特征. 我们将均值 $\boldsymbol{\mu}$ 视作“基本技能组分”, 并应用于后文的轨迹生成中.

3 基于函数回归模型的动态轨迹生成

我们已经通过弹性分析方法在时间上对齐示教轨迹, 蕴含在规整示教轨迹中的空域特征以离散化过程均值和过程方差的形式表现出来. 本节研究如何利用上述空域特征, 在不同的任务参数下产生能够完成相应任务的动态轨迹 (dynamic trajectory). 需要再次指出的是, 我们将示教轨迹 (的每一个维度) 视作函数型数据. 函数回归模型 (functional regression model) 则是研究函数型数据间关系的有力工具, 我们使用它来解决动态轨迹的生成问题. Greven^[31] 指出函数回归模型能够解决以下 3 类回归问题: 函数对标量回归 (function-on-scalar regression) 问题, 标量对函数回归 (scalar-on-function regression) 问题以及函数对函数回归 (function-on-function regression) 问题. 本文解决动态轨迹的生成问题, 于是考虑具有函数响应 (functional response) 的函数回归模型.

3.1 动态轨迹的拓扑约束与任务约束

我们启发性地认为, 动态轨迹 $\mathbf{y}_{\text{dyn}}$ 可以视作动态增量 $(\Delta \mathbf{y})_{\text{dyn}}$ 对基本技能 $\mathbf{x}_{\text{basic}}$ 的“扰动”, 从而得到式 (11). 式 (11) 中, 基本技能 $\mathbf{x}_{\text{basic}}$ 由示教轨迹的空域特征 $\boldsymbol{\mu}$ 给出. 由于动态增量 $(\Delta \mathbf{y})_{\text{dyn}}$ 的非任意性, 我们启发性地认为它是关于基本技能的函数, 以限制其在空域的形态.

$$\mathbf{y}_{\text{dyn}} = \mathbf{x}_{\text{basic}} + (\Delta \mathbf{y})_{\text{dyn}}. \quad (11)$$

考虑每一个维度 d 上的动态轨迹 $\mathbf{y}_{\text{dyn}}^{(d)}$, 它也应该满足由式 (11) 确定的关系, 于是有

$$\mathbf{y}_{\text{dyn}}^{(d)} = \mathbf{x}_{\text{basic}}^{(d)} + (\Delta \mathbf{y})_{\text{dyn}}^{(d)}. \quad (12)$$

需要指出的是, 式 (12) 中维度 d 上的动态增量 $(\Delta \mathbf{y})_{\text{dyn}}^{(d)}$ 依然是关于基本技能 $\mathbf{x}_{\text{basic}}$ 的函数.

由于动态增量与基本技能都是函数型数据, 我们可以在每一个维度 d 上使用函数回归模型建立动态增量 $(\Delta \mathbf{y})_{\text{dyn}}^{(d)}$ 与基本技能 $\mathbf{x}_{\text{basic}}$ 之间的关系. 进一步地, 为了赋予模型接受参数化的任务输入的能力, 我们以工作空间中的点集 $\mathbf{P} = \{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_{N_P}\}$ 作为参数化任务输入, 其中的每一个元素 $\mathbf{p}_i = [p_i^{(1)}, p_i^{(2)}, \dots, p_i^{(n)}]^T$, $\mathbf{p}_i \in \mathbb{R}^n$ 代表由工作空间点确定的任务约束. 这种将工作空间点作为任务约束的做法已在现有的示教学习工作中^[1, 3, 4, 11~14] 得到了广泛应用. 至此, 我们启发性地从形态约束 $\mathcal{C}_{\text{top}}^{(d)}$ 和任务约束两个角度 $\mathcal{C}_{\text{task}}^{(d)}$ 出发, 按照式 (13) 使用基本技能 $\mathbf{x}_{\text{basic}}$ 和参数化任务输入 $\mathbf{P}$ 描述动态增量为

$$(\Delta \mathbf{y})_{\text{dyn}}^{(d)} = \mathcal{C}_{\text{top}}^{(d)} + \mathcal{C}_{\text{task}}^{(d)}. \quad (13)$$

式 (13) 中形态约束 $\mathcal{C}_{\text{top}}^{(d)}$ 具有如下所示的函数 - 函数回归模型形式:

$$\mathcal{C}_{\text{top}}^{(d)} = \sum_{i \in \mathcal{D}^{(d)}} \int_{\mathbb{S}} x_{\text{basic}}^{(i)}(s) \xi_i^{(d)}(s, t) ds. \quad (14)$$

形态约束描述了每一个维度 d 上的动态轨迹增量与其他维度 $\mathcal{D}^{(d)} = \{1, 2, \dots, d-1, d+1, \dots, n\}$ 上的基本技能组分 $\mathbf{x}_{\text{basic}}^{(i)}$, $i \in \mathcal{D}^{(d)}$ 通过光滑曲面 $\xi_i^{(d)}: D \times D \rightarrow \mathbb{R}$, $i \in \mathcal{D}^{(d)}$ 产生的光滑耦合关系^[32]. 任务约束 $\mathcal{C}_{\text{task}}^{(d)}$ 具有如下所示的函数 - 标量回归模型的形式:

$$\mathcal{C}_{\text{task}}^{(d)} = \sum_{i=1}^{N_P} p_i^{(d)} \psi_i^{(d)}(t), \quad (15)$$

其描述了每一个维度 d 上的动态轨迹增量与该维度的任务参数 $p_i^{(d)}$ 通过光滑的时间函数 $\psi_i^{(d)}$ 产生的耦合关系.

图 3 (网络版彩图) 以“提起袋子”技能为例, 设计轨迹生成模型的约束项 (a) 和每个维度上的动态增量 (b)
Figure 3 (Color online) Constrains (a) and dimension-wise dynamic increments (b) of the trajectory generation model. The trajectory-generation model is designed using these elements to dynamically perform the bag-lifting skill

3.2 动态轨迹生成模型

从拓扑约束 (式 (14)) 和任务约束 (式 (15)), 我们建立动态轨迹生成模型. 具体而言, 考虑动态轨迹在每一个维度上的动态增量 $(\Delta \mathbf{y})_{\text{dyn}}^{(d)}$, 建立每个维度 d 上的动态轨迹生成模型 $\mathcal{M}^{(d)}$:

$$\mathbb{E} \left((\Delta Y)_{\text{dyn}}^{(d)} \mid \mathbf{x}_{\text{basic}}, \mathbf{p}_1, \dots, \mathbf{p}_{N_P} \right) = \sum_{i \in \mathcal{D}^{(d)}} \int_{\mathbb{S}} \mathbf{x}_{\text{basic}}^{(i)}(s) \xi_i^{(d)}(s, t) \, ds + \sum_{i=1}^{N_P} p_i^{(d)} \psi_i^{(d)}(t). \quad (16)$$

式 (16) 是一类具有函数响应 (functional response) 的函数回归模型. 这一类模型得到了 Brockhaus 等 [33] 和 Scheipl 等的研究 [34]. Greven 和 Scheipl 指出广义的、具有函数响应的回归模型具有如下形式 [34]:

$$\mathbb{E}(Y \mid \mathbf{X} = \mathbf{x}) = \sum_{j=1}^J h_j(\mathbf{x}) \triangleq h(\mathbf{x}), \quad (17)$$

$$\sum_i \int [y_i(t) - h(\mathbf{x}_i, t)]^2 \, dt, \quad (18)$$

其中 Y 为函数响应, $\mathbf{x}$ 可以是函数, 可以是标量, 也可以是两者的组合; $h_j(\cdot)$ 则是 J 个效应 (effect) 中的其中一个. Brockhaus 等 [33] 进一步指出可以使用基展开方法将 $h_j(\mathbf{x}, t)$ 线性化为 $(b_j(\mathbf{x})^T \otimes b_Y(\mathbf{x})^T) \boldsymbol{\theta}_j$, 当式 (17) 中 $\mathbf{x}$ 均为标量时 $b_Y \equiv 1$, 模型退化为函数对标量回归模型.

为了解式 (17) 的模型, Brockhaus 引入岭惩罚项 (ridge-type penalty term), 采用 Boosting 方法求解, 并将该求解方法实现为 FDboost [35]. 对于每一组数据 $\{y_i(t), \mathbf{x}_i\}$, Brockhaus 的方法最小化由式 (18) 确定的损失函数 [33] (其中的定积分由数值积分替代). 我们使用 FDboost 求解式 (16) 中的模型参数 $\{\xi_i^{(d)}, \psi_j^{(d)}\}, i \in \mathcal{D}^{(d)}, j = 1, 2, \dots, N_P$, 最终得到完整的动态轨迹生成模型 $\{\mathcal{M}^{(d)}\}_{d=1,2,\dots,n}$.

以“提起袋子”技能为例, 我们在图 2 所示规整示教轨迹应用本小节提出的动态轨迹生成模型, 应用方式如图 3 所示. 图 3(a) 中, 4 条轨迹 $\mathbf{y}_{\text{dyn},i}, i = 1, 2, 3, 4$ 是“提起袋子”技能的规整示教轨迹 $\{\mathbf{y}_{\text{dyn},i}(t_0), \mathbf{y}_{\text{dyn},i}(t_1), \dots, \mathbf{y}_{\text{dyn},i}(t_N)\}$, 它们的起始点 $\{\mathbf{y}_{\text{dyn},i}(t_0)\}$ 以实心圆点标出. 对于

图 4 (网络版彩图) 实验环境设定示意图. 实验平台由 JACO-2 机械臂、上位机以及相关互动道具构成

Figure 4 (Color online) Experimental platform containing a JACO-2 robotic manipulator, a monitoring PC and interactive gadgets

式 (14) 中的基本技能 $\mathbf{x}_{\text{basic}}$, 我们使用第 2 节中的空域特征学习方法进行提取, 结果如图 3(a) 中的粗实线所示; 对于式 (15) 中的 N_P 个参数化任务输入, 我们使用各个规整示教轨迹的起点 $\mathbf{y}_{\text{dyn},i}(t_0)$, 此时 $\mathbf{P} \equiv \{\mathbf{y}_{\text{dyn},i}(t_0) \mid i = 1, 2, 3, 4\}$. 进一步地, 我们依照式 (12) 使用 $\mathbf{y}_{\text{dyn}} - \mathbf{x}_{\text{basic}}$ 作为式 (16) 左端的响应 (response), 由 4 条示教轨迹计算得到的响应如图 3(b) 所示. 至此, 动态轨迹生成模型的输入输出都得到了确定, 可以使用 FDBoost 进行求解.

作为式 (16) 动态轨迹生成模型的应用, 我们首先通过 4 条示教轨迹, 使用 FDBoost 构建关于某一个技能的动态轨迹生成模型. 之后以基本技能 $\mathbf{x}_{\text{basic}}$ 为基础和新的起始点 (未出现在示教轨迹中的起始点) $\mathbf{x}^*(t_0)$ 构成式 (16) 的新输入, 推理出在未知起始点下的动态增量 $(\Delta\mathbf{y})_{\text{dyn}}^*$, 最终根据式 (11) 得到新起始点下的动态轨迹 $\mathbf{y}_{\text{dyn}}^*$. 该动态轨迹能够满足新的起始点约束, 并完成相应的技能. 我们将在实验部分说明动态轨迹生成模型的实体应用结果.

4 实验验证

我们在理论部分提出了基于弹性分析的示教轨迹学习与泛化方法. 该方法首先将示教轨迹进行规整并学习其空域特征, 从而建立具有函数回归模型形式的动态轨迹生成模型. 该动态轨迹生成模型能够接受新的任务输入, 输出新的动态轨迹. 我们基于图 4 所示的实验平台, 在 JACO-2 机械臂上验证本文提出的方法. 图 4 中, JACO-2 机械臂 (JACO-2 robotic arm) 的末端附有“手指”, 用于和桌面上的物件 (盒子、袋子以及抽屉) 进行互动. 上位机 (monitoring PC) 用于与 JACO-2 交互. 为了记录示教轨迹, 我们通过上位机控制 JACO-2 机械臂处于“零力”状态^[36], 从而能够直接拖动其末端的执行机构, 完成相关任务, 实现动觉示教 (kinesthetic teaching). 在施教者的动觉示教下, JACO-2 机械臂与一系列物件进行互动, 完成“打开盖子 (case-opening)”, “拉开抽屉 (drawer-opening)”和“提起袋子 (bag-lifting)”任务.

图 5 (网络版彩图) 示教学习阶段: 记录示教轨迹并进行配准, 得到规整示教轨迹与基本技能

Figure 5 (Color online) The LfD stage, where demonstrations are recorded and registered to obtain the basic skill

图 6 (网络版彩图) 轨迹生成阶段: JACO-2 机械臂在新起始状态下, 通过新轨迹完成任务

Figure 6 (Color online) The generation stage, where JACO-2 manipulator finishes the related task with the help of generated trajectories

4.1 实验流程

我们以“提起袋子”技能为例, 说明我们的实验流程. 实验流程包括两个阶段: 示教学习阶段 (the LfD stage) 与轨迹生成阶段 (the generation stage), 如图 5 和 6 所示. 在图 5 所示的示教学习阶段, JACO-2 机械臂在示教者的辅助下, 从不同的起始点出发 (图 5 左栏), 完成“提起袋子”任务 (图 5 中栏), 最终获得规整示教轨迹以及基本技能 (图 5 右栏). 选取每个示教轨迹的起始点作为参数化的任务输入, 各起始点由实心圆点在图 5 右栏中标出. 在图 6 所示的轨迹生成阶段, 我们选取新的起始点 (图 6 左栏, 实心圆点) 产生新的轨迹 (图 6 左栏); 在新轨迹的帮助下, JACO-2 机械臂从新的起始点出发 (图 6 中栏), 完成“提起袋子”任务 (图 6 右栏).

4.2 “提起袋子”技能的示教学习与泛化

在执行“提起袋子”任务时, JACO-2 机械臂使用其末端的“手指”, 提起位于实验平台的袋子. 我们从不同的起始点出发 (图 7 上栏), 示教 JACO-2 机械臂完成“打开盖子”任务 (图 7 下栏) 记录下系列示教轨迹. 在对示教轨迹进行规整之前, 我们使用图 8 说明示教轨迹配准对其空域特征提取的重要性. 图 8 以等时间间隔图片序列的方式, 展示了“提起袋子”技能的 4 条示教轨迹其中的两条.

图 7 (网络版彩图) 从不同的起始状态动觉示教“提起袋子”技能 (上栏); JACO-2 完成任务 (下栏)

Figure 7 (Color online) Kinesthetic teaching of the bag-lifting skill (the upper row); JACO-2’s task-fulfillment (the lower row)

图 8 (网络版彩图) 使用“提起袋子”技能的示教序列 A (上栏)、示教序列 B (下栏) 展示示教轨迹的时 – 空特征耦合

Figure 8 (Color online) Two recorded demonstrations of the bag-lifting skill, illustrating the coupling between spatial and temporal features

图 8 的上、下两栏分别为两个不同的示教序列, 记作示教序列 A, 示教序列 B. 在示教序列 A 中, 末端机构接触到袋子提手 (图 8 上栏, 第 4 列, 矩形框出部分) 时, 示教序列 B 中的末端机构仍需要一段时间 (图 8 下栏, 第 5 列, 矩形框出部分) 才接触到袋子提手. 对于“提起袋子”这一技能而言, “末端机构接触到袋子提手”属于重要的空域特征. 示教序列 A, B 则展示出示教轨迹之间发生的时 – 空特征耦合: 相同的空域特征出现在不同的观测时刻. 以上的事实进一步地说明, 为了充分地捕捉各个示教轨迹之间“相似的空域特征”, 需要对示教轨迹进行配准. 我们利用规整的示教轨迹来构建动态轨迹生成模型, 进而进行“提起袋子”技能关于不同起始位置的泛化, 如图 9 所示. 图 9 左栏 $y_{\text{dyn},1} \sim y_{\text{dyn},4}$ 为“提起袋子”技能的规整示教轨迹; $y_{\text{dyn},1}^* \sim y_{\text{dyn},3}^*$ 为模型产生的动态轨迹; x_{basic} 为“提起袋子”技能

图 9 (网络版彩图) 基于动态轨迹,在新的起始状态下完成“提起袋子”任务

Figure 9 (Color online) Lifting the bag with generated dynamic trajectories under different initial states

图 10 (网络版彩图) JACO-2 从新的起始位置出发,通过动态轨迹完成“打开盖子”任务

Figure 10 (Color online) JACO-2's case-opening skill under different initial states

的基本技能组分. 图 9 的右栏为 3 组动态轨迹序列, 对应 $y_{\text{dyn},1}^* \sim y_{\text{dyn},3}^*$, 它们展示 JACO-2 机械臂如何从新的起始位置出发, 完成“提起袋子”任务. 我们从规整的示教轨迹中提取基本技能, 以新的起始位置作为输入产生动态轨迹. 各动态轨迹在满足新的起始位置约束的前提下, 既能够保持与基本技能、示教轨迹的相似性, 也能够导引 JACO-2 机械臂完成相关的任务.

4.3 “打开盖子”、“拉开抽屉”技能的学习与泛化

我们使用与“提起袋子”相同的方式, 验证本文方法之于“打开盖子”, “拉开抽屉”技能的有效性, 如图 10 和 11 所示. 在施教者的动觉示教下, JACO-2 机械臂从不同的起始位置出发, 完成“打开盖

图 11 (网络版彩图) JACO-2 从新的起始位置出发, 通过动态轨迹完成“拉开抽屉”任务

Figure 11 (Color online) JACO-2's drawer-opening skill under different initial states

子”、“拉开抽屉”任务. 应用弹性方法, 我们得到规整的示教轨迹 $y_{\text{dyn},i}$ 与基本技能 x_{basic} . 进一步地, 我们以起始位置作为任务参数训练动态轨迹生成模型: 动态生成模型将接受新的起始位置作为输入, 产生与基本技能相似的、新的动态轨迹 $y_{\text{dyn},i}^*$. 在新的动态轨迹的帮助下, JACO-2 机械臂从新的起始位置出发, 分别完成“打开盖子”任务 (图 10 右栏) 和“拉开抽屉”任务 (图 11 右栏).

5 结论

示教学习方法利用示教轨迹作为先验知识, 高效地解决一类仿人机器人的动态轨迹规划问题. 示教轨迹具有鲜明的函数型数据特性, 需要在函数型数据分析的理论框架下加以分析利用. 为此, 本文提出了基于函数型数据分析的示教轨迹学习与泛化方法. 该方法使用弹性分析处理示教轨迹的时-空耦合性, 进而对解耦的示教轨迹建立函数回归模型, 生成任务参数化的动态轨迹. 通过 JACO-2 在不同任务参数下执行“打开盖子”、“提起袋子”与“拉开抽屉”技能, 本文提出方法的实体有效性得到了验证. 后续研究预期着眼于建立更为复杂的、多机械臂实体相关联的函数型回归模型, 探索本文方法在协同轨迹规划方面的应用.

参考文献

- 1 Ijspeert A J, Nakanishi J, Hoffmann H, et al. Dynamical movement primitives: learning attractor models for motor behaviors. *Neural Comput*, 2013, 25: 328–373
- 2 Sun Y, Qiang H, Mei X, et al. Modified repetitive learning control with unidirectional control input for uncertain nonlinear systems. *Neural Comput Applic*, 2018, 30: 2003–2012
- 3 Kober J, Peters J. Movement templates for learning of hitting and batting. In: *Learning Motor Skills*. Cham: Springer, 2014. 69–82
- 4 Mülling K, Kober J, Kroemer O, et al. Learning to select and generalize striking movements in robot table tennis. *Int J Robot Res*, 2013, 32: 263–279
- 5 Wang J F, Wang Y N, Chen W R, et al. 6D trajectories planning based on improved dynamic movement primitives. *Control Theory Appl*, 2021, 38: 1–10 [王健发, 王耀南, 陈文锐, 等. 基于改进动态运动基元的 6D 轨迹规划. *控制理论与应用*, 2021, 38: 1–10]

- 6 Kulvicius T, Ning K J, Tamosiunaite M, et al. Modified dynamic movement primitives for joining movement sequences. In: Proceedings of 2011 IEEE International Conference on Robotics and Automation, 2011. 2275–2280
- 7 Kulvicius T, Ning K J, Tamosiunaite M, et al. Joining movement sequences: modified dynamic movement primitives for robotics applications exemplified on handwriting. *IEEE Trans Robot*, 2012, 28: 145–157
- 8 Calinon S, Guenter F, Billard A. On learning, representing, and generalizing a task in a humanoid robot. *IEEE Trans Syst Man Cybern B*, 2007, 37: 286–298
- 9 Khansari-Zadeh S M, Billard A. BM: an iterative algorithm to learn stable non-linear dynamical systems with Gaussian mixture models. In: Proceedings of IEEE International Conference on Robotics and Automation, 2010. 2381–2388
- 10 Khansari-Zadeh S M, Billard A. Learning stable nonlinear dynamical systems with Gaussian mixture models. *IEEE Trans Robot*, 2011, 27: 943–957
- 11 Calinon S. A tutorial on task-parameterized movement learning and retrieval. *Intel Serv Robot*, 2016, 9: 1–29
- 12 Calinon S. Robot learning with task-parameterized generative models. In: *Robotics Research*. Cham: Springer, 2018. 2: 111–126
- 13 Sena A, Michael B, Howard M J. Improving task-parameterised movement learning generalisation with frame-weighted trajectory generation. In: Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2019. 4281–4287
- 14 Huang Y, Silvério J, Roza L D, et al. Generalized task-parameterized skill learning. In: Proceedings of IEEE International Conference on Robotics and Automation (ICRA), 2018. 1–5
- 15 Ramsay J O, Silverman B W. *Functional Data Analysis*. New York: Springer, 2005. 1–18
- 16 Wang K, Gasser T. Alignment of curves by dynamic time warping. *Ann Statist*, 1997, 25: 1251–1276
- 17 Myers C S, Rabiner L R. A comparative study of several dynamic time-warping algorithms for connected-word recognition. *Bell Syst Technical J*, 1981, 60: 1389–1409
- 18 Liu X, Müller H G. Functional convex averaging and synchronization for time-warped random curves. *J Am Stat Assoc*, 2004, 99: 687–699
- 19 Kneip A, Ramsay J O. Combining registration and fitting for functional models. *J Am Stat Assoc*, 2008, 103: 1155–1165
- 20 Christensen G E, Johnson H J. Consistent image registration. *IEEE Trans Med Imag*, 2001, 20: 568–582
- 21 Kurtek S, Srivastava A, Klassen E, et al. Statistical modeling of curves using shapes and related features. *J Am Statistical Association*, 2012, 107: 1152–1165
- 22 Srivastava A, Klassen E, Joshi S H, et al. Shape analysis of elastic curves in Euclidean spaces. *IEEE Trans Pattern Anal Mach Intell*, 2011, 33: 1415–1428
- 23 Joshi S H, Klassen E, Srivastava A, et al. A novel representation for Riemannian analysis of elastic curves in R^n . In: Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2007. 1–7
- 24 Kurtek S, Klassen E, Ding Z, et al. Parameterization-invariant shape comparisons of anatomical surfaces. *IEEE Trans Med Imag*, 2011, 30: 849–858
- 25 Ramsay J O, Li X. Curve registration. *J R Stat Soc-Ser B (Stat Methodology)*, 1998, 60: 351–363
- 26 James G M. Curve alignment by moments. *Ann Appl Stat*, 2007, 1: 480–501
- 27 Tang R, Müller H G. Pairwise curve synchronization for functional data. *Biometrika*, 2008, 95: 875–889
- 28 Aganj I, Reuter M, Sabuncu M R, et al. Symmetric non-rigid image registration via an adaptive quasi-volume-preserving constraint. In: Proceedings of IEEE 10th International Symposium on Biomedical Imaging, 2013. 230–233
- 29 Srivastava A, Wu W, Kurtek S, et al. Registration of functional data using Fisher-Rao metric. *Statistics*, 2011, 306: 242–251
- 30 Rana M A, Mukadam M, Ahmadzadeh S R, et al. Towards robust skill generalization: unifying learning from demonstration and motion planning. In: Proceedings of the 1st Annual Conference on Robot Learning, 2017. 78: 109–118
- 31 Greven S, Scheipl F. A general framework for functional regression modelling. *Stat Model*, 2017, 17: 1–35
- 32 Ramsay J O, Dalzell C J. Some tools for functional data analysis. *J R Stat Soc-Ser B (Methodological)*, 1991, 53: 539–561
- 33 Brockhaus S, Scheipl F, Hothorn T, et al. The functional linear array model. *Stat Model*, 2015, 15: 279–300
- 34 Scheipl F, Gertheiss J, Greven S. Generalized functional additive mixed models. *Electron J Statist*, 2016, 10: 1455–1492
- 35 Brockhaus S, Rügamer D, Greven S. Boosting functional regression models with FDboost. *J Stat Soft*, 2020, 94: 1–50

- 36 Kushida D, Nakamura M, Goto S, et al. Human direct teaching of industrial articulated robot arms based on force-free control. *Artif Life Robot*, 2001, 5: 26–32

Learning and generalizing demonstration trajectories based on elastic analysis and the functional regression model

Hongyuan XIAO, Chengju LIU* & Qijun CHEN

College of Electronic and Information Engineering, Tongji University, Shanghai 201804, China

* Corresponding author. E-mail: liuchengju@tongji.edu.cn

Abstract Learning from demonstration (LfD) has been confirmed to be an effective method for solving humanoid trajectory-planning problems under dynamic scenarios. Demonstrations, as functional data, can have coupled spatial and temporal features, which need to be treated carefully under the framework of functional data analysis. Previous studies in LfD use a separate pre-processing step to decouple spatial and temporal features. To fully utilize the intrinsic functional feature of demonstrations, an elastic method is used to extract their spatial and temporal features. Based on the decoupled spatial feature, a functional regression model is built to generate dynamic trajectories under varying task parameters. Experiments on a JACO-2 manipulator are conducted by performing different skills and fulfilling related tasks dynamically with new task-parameters. Results demonstrate that a category of humanoid LfD problems can be solved with a theoretically unified and applicable method.

Keywords learning from demonstration, trajectory generation, functional data, elastic analysis, functional regression model